

清华大学

计算机系列教材

邓俊辉 编著

数据结构(C++语言版)

(第3版)



清华大学出版社

清华大学计算机系列教材

本套教材已伴随着计算机科学与技术的发展茁壮成长了三十余年，获得了中华人民共和国教育部科技进步奖、普通高等学校优秀教材全国特等奖、全国优秀畅销书金奖等三十多项部级以上奖励，被近千所高校选作教材，教学效果非常好。本套教材经过多次修订改版和增加新品种、新内容、新技术，基本涵盖了本科生和硕士研究生的主要课程。本套教材的作者全部是清华大学计算机系的教师，教材的内容、语言特点、课时安排体现了他们治学严谨的特点，概念表述严谨，逻辑推理严密，语言精炼。同时，本套教材体系完整、结构严谨，理论结合实际，注重素质培养。

内容简介

本书按照面向对象程序设计的思想，根据作者多年的教学积累，系统地介绍各类数据结构的功能、表示和实现，对比各类数据结构适用的应用环境；结合实际问题展示算法设计的一般性模式与方法、算法实现的主流技巧，以及算法效率的评判依据和分析方法；以高度概括的体例为线索贯穿全书，并通过对比和类比揭示数据结构与算法的内在联系，帮助读者形成整体性认识。

配套的习题解析涵盖验证型、拓展型、反思型、实践型和研究型习题，总计290余道大题、525多道小题，激发读者的求知欲，培养自学能力和独立思考习惯。本书及《习题解析》共计配有340多组、400余幅插图结合简练的叙述，40多张表格列举简明的规范、过程及要点，280余段代码及算法配合详尽而简洁的注释，使深奥抽象的概念和过程得以具体化且便于理解和记忆；推荐20余册经典的专著与教材，提供40余篇重点的学术论文，便于读者进一步钻研和拓展。

结合学生基础、专业方向、教学目标及允许课时总量等各种因素，本书推荐了若干种典型的教学进度及学时分配方案，供授课教师视具体情况参考和选用。

勘误表、插图、代码以及配套讲义等相关教学资料，均以电子版形式向公众开放，读者可从本书主页直接下载：<http://dsa.cs.tsinghua.edu.cn/~deng/ds/dsacpp/>

作者介绍



邓俊辉 清华大学计算机系副教授。1993年、1997年分别于清华大学计算机系获工学学士和工学博士学位。主要研究方向为科学计算可视化、计算几何及计算机图形学。长期承担清华大学计算机本科生专业基础课程“数据结构”和研究生基础理论课“计算几何”的教学工作，编著的《数据结构与算法（Java描述）》入选“北京市高等教育精品教材”，参与编著的《数据结构（用面向对象方法与C++语言描述）》入选“国家级高等教育精品教材”，曾获清华大学“青年教师教学优秀奖”、清华大学“教书育人奖”、清华大学“教学成果奖”二等奖、清华大学“教学成果奖”一等奖、中国高校科学技术奖二等奖、宝钢教育基金“宝钢教育奖”。

清华大学985名优教材立项资助

数据结构（C++语言版）

第 3 版

邓俊辉

清华大学出版社

2013年9月·北京

丛书序

“清华大学计算机系列教材”已经出版发行了30余种，包括计算机科学与技术专业的基础数学、专业技术基础和专业等课程的教材，覆盖了计算机科学与技术专业本科生和研究生的主要教学内容。这是一批至今发行数量很大并赢得广大读者赞誉的书籍，是近年来出版的大学计算机专业教材中影响比较大的一批精品。

本系列教材的作者都是我熟悉的教授与同事，他们长期在第一线担任相关课程的教学工作，是一批很受本科生和研究生欢迎的任课教师。编写高质量的计算机专业本科生（和研究生）教材，不仅需要作者具备丰富的教学经验和科研实践，还需要对相关领域科技发展前沿的正确把握和了解。正因为本系列教材的作者们具备了这些条件，才有了这批高质量优秀教材的产生。可以说，教材是他们长期辛勤工作的结晶。本系列教材出版发行以来，从其发行的数量、读者的反映、已经获得的国家级与省部级的奖励，以及在各个高等院校教学中所发挥的作用上，都可以看出本系列教材所产生的社会影响与效益。

计算机学科发展异常迅速，内容更新很快。作为教材，一方面要反映本领域基础性、普遍性的知识，保持内容的相对稳定性；另一方面，又需要跟踪科技的发展，及时地调整和更新内容。本系列教材都能按照自身的需要及时地做到这一点。如王爱英教授等编著的《计算机组成与结构》、戴梅萼教授等编著的《微型计算机技术及应用》都已经出版了第四版，严蔚敏教授的《数据结构》也出版了三版，使教材既保持了稳定性，又达到了先进性的要求。

本系列教材内容丰富，体系结构严谨，概念清晰，易学易懂，符合学生的认知规律，适合于教学与自学，深受广大读者的欢迎。系列教材中多数配有丰富的习题集、习题解答、上机及实验指导和电子教案，便于学生理论联系实际地学习相关课程。

随着我国进一步的开放，我们需要扩大国际交流，加强学习国外的先进经验。在大学教材建设上，我们也应该注意学习和引进国外的先进教材。但是，“清华大学计算机系列教材”的出版发行实践以及它所取得的效果告诉我们，在当前形势下，编写符合国情的具有自主版权的高质量教材仍具有重大意义和价值。它与国外原版教材不仅不矛盾，而且是相辅相成的。本系列教材的出版还表明，针对某一学科培养的要求，在教育部等上级部门的指导下，有计划地组织任课教师编写系列教材，还能促进对该学科科学、合理的教学体系和内容的研究。

我希望今后有更多、更好的我国优秀教材出版。

清华大学计算机系教授
中国科学院院士

张钹

序

为适应快速发展的形势,计算机专业基础课的教学必须走内涵发展的道路,扎实的理论基础、计算思维能力和科学的方法论是支撑该学科从业人员进行理性思维和理性实践的重要基础。“程序设计基础”、“面向对象技术”、“离散数学”以及“数据结构”等相关课程,构成了清华大学计算机系专业基础课程体系中的一条重要脉络。近年来为强化学生在计算思维 and 实践能力方面的训练力度,课程组通过研究,探索和实践,着力对该课程系列的教学目标、内容、方法和各门课的分工,以及如何衔接等进行科学而系统的梳理,进一步明确了教学改革的方向。在这样的背景下,由邓俊辉撰写的《数据结构(C++语言版)》正式出版了。

为了体现教材的先进性,作者研读并参考了计算学科教学大纲(ACM/IEEE Computing Curricula),结合该课程教学的国际发展趋势和对计算机人才培养的实际需求,对相关知识点了做了精心取舍,从整体考虑加以编排,据难易程度对各章节内容重新分类,给出了具体的教学计划方案。

为了不失系统性,作者依据多年的教学积累,对各种数据结构及其算法,按照分层的思想精心进行归纳和整理,并从数据访问方式、数据逻辑结构、算法构成模式等多个角度,理出线索加以贯穿,使之构成一个整体,使学生在学学习数据结构众多知识点的同时,获得对这门学问相关知识结构的系统性和全局性的认识。

计算机学科主张“抽象第一”,这没有错,但弄不好会吓倒或难倒学生。本书从具体实例入手,运用“转换-化简”、“对比-类比”等手法,借助大量插图和表格,图文并茂地展示数据结构组成及其算法运转的内在过程与规律,用形象思维帮助阐释抽象过程,给出几乎所有算法的具体实现,并通过多种版本做剖析和对比,引领读者通过学习提升抽象思维能力。

计算机学科实践性极强,不动手是学不会的。为了强化实践,本书除了每章都布置人人必做的习题和思考题外,还有不少于授课学时的上机编程要求,旨在培养学生理性思维和理性实践的动脑动手能力。

《中国计算机科学与技术学科教程2002》曾批评国内有关程序设计类的课,一是淡化算法,二是“一开始就扎进程序设计的语言细节中去”。本书十分重视从算法的高度来讲述数据结构与算法的相互依存关系,在书的开篇就用极其精彩的例子讲清了算法效率和算法复杂度度的基本概念和方法,这就给全书紧密结合算法来讲数据结构打下了很好的基础。

这本书是精心策划和撰写的,结构严整,脉络清晰,行文流畅,可读性强。全书教学目标明确,内容丰富,基本概念和基本方法的阐述深入浅出,最大的特点是将算法知识、数据结构和编程实践有机地融为一体。我以为,引导学生学好本书,对于奠定扎实的学科基础,提高计算思维能力能够起到良好的作用。

清华大学计算机系教授



2011年9月

第3版说明

在第2版的基础上，本书第3版推出了配套的《习题解析》，故在体例上也做了相应的调整，主要包括以下方面：

- 原各章所附习题，均统一摘出并汇编为《习题解析》；除了部分实践型和研究型习题，大部分习题均提供了详尽的分析和解答。
- 删除了少量习题，同时也补充了若干。大题的总数，已增至292道；因多数习题都是逐层递进式的，小题的总数已超过500道。
- 关于伸展树性能分摊分析的原8.1.4小节，作为习题转入《习题解析》。
- 图灵机模型、RAM模型等基本概念，以及（线性）归约、封底估算及基本技巧，也结合对应的习题予以介绍。

同时，结合读者反馈以及新一轮教学实践效果，也在以下方面做了相应修订：

- 1.4节补充了对记忆策略与动态规划策略的介绍，并通过实例展示二者的联系与区别。
- 鉴于前四章已经充分地展示了相关技巧，后续Bintree和Dictionary等结构不再过于严格地封装，使读者更好地将注意力集中于这些结构的机理本身。
- 通过多重继承，统一了ComplHeap、LeftHeap、ListHeap等结构的实现方式，使之封装更紧凑、代码更简洁。
- 精简了Vector<T>::mergesort()、GraphMatrix::insert()、Splay::splay()、RedBlack::solveDoubleRed()、trivialMedian()等算法的实现。
- 关于函数调用栈、栈与递归、Huffman编码算法等各节的叙述与讲解，也尽可能地做了精简。
- 统一了“环路”、“众数”、“最左/右侧通路”、“波峰集”、“输入/输出敏感”等概念。
- 严格了“完全二叉树”等概念以及“黑高度”等指标的定义。
- 参照BFS和DFS的实现方式改进PFS框架，使之支持多个连通域（或可达域）。
- 借助几何分布等概率模型，简化对跳转表、散列表的平均性能分析。
- 插图、表格、代码等均有大幅增加，关键词索引项进一步细化。
- 增加了若干重要的参考文献。
- 修正了原书及代码中的若干错误，详细对比请见勘误表。

最后，鉴于第3版采用双色印刷方式，故在版面及样式等方面也做了相应的调整。

第2版说明

本书的初稿完成于2009年冬季，随后在清华大学经过了三个学期共四个课堂的试用，根据各方的反馈意见做过调整补充之后，第1版于2011年夏季由清华大学出版社正式出版发行。此后，又在清华大学经过两个学期共三个课堂的教学实践，并汇总读者的反馈进一步修订完善之后，第2版终于2012年夏季出版发行，也就是目前读者所看到的这个版本。

第2版继承并强化了此前版本的叙述风格，基本保留了总体的体例结构，同时在针对性、简洁性、实用性和拓展性等方面，也做了大量的修改、删节与扩充。与此前的版本相比较，主要的变化包括以下几个方面：

- 针对多种数据结构的算法实现及其性能分析，精简了行文叙述与代码实现，比如有序向量的查找、树和图的遍历、Huffman编码、平衡二叉搜索树的重平衡、二叉堆的调整等。
- 更换并补充了大量的实例和插图，比如向量、词典、关联数组、高级平衡二叉搜索树和优先级队列等数据结构，以及表达式求值、KMP、BM、平衡二叉搜索树的重平衡、字符串散列、快速排序、中位数及众数等算法的原理及过程等等，插图增至260多组。
- 重写了多个章节的总结部分，比如针对各类查找算法、串匹配算法，就其性能特点均做了统一的归纳与梳理，指明其中的关键因素以及不同的适用范围。
- 进一步规范 and 统一了几个基本概念的定义及其表述方式，使得各章节之间的相互引述更趋一致，比如栈混洗、真二叉树、完全二叉树、满树、闭散列策略等概念的定义，以及遍历序列、红黑树不同类型节点等概念的图解示意方式。
- 细化了针对一些关键知识点的讲解，比如第1章的渐进复杂度层次和伪复杂度、第8章中B-树及kd-树的引入动机、第11章中BM算法好后缀策略中的GS[]表构造算法等。
- 添加了大量的习题，总量已超过280道。在帮助读者梳理主要知识点、加深对讲解内容理解的同时，还从以下方面为他们的进一步拓展，提供了必要的线索：插入排序算法性能与逆序对的关系、选择排序算法性能与循环节的关系、插值查找、指数查找、马鞍查找、CBA式排序算法平均性能的下界、栈混洗甄别、栈堆、队堆、算术表达式的组合搜索、键树、关联矩阵、Prim算法与Krusal算法的正确性、欧氏最小支撑树、并查集、计数排序、四叉树、八叉树、范围树、优先级搜索树、树堆、AVL树节点删除算法的平均性能、AVL树的合并与分裂、堆节点插入算法的平均性能、支持重复元素的二叉搜索树、双向平方试探、轴点构造算法版本C、希尔排序算法的正确性，等等。
- 提供了一批相关的参考文献，包括经典的教材专著20余册、拓展的学术论文30余篇。
- 修正了多处排版问题及若干实质错误。请此前版本的读者下载勘误表并做相应更正，同时感谢我的读者、学生和同行，他们的意见与建议是本教材不断完善的保证。

第1版前言

背景

伴随着计算学科 (Computing Discipline) 近年来的迅猛发展, 相关专业方向不断细化和分化, 相应地在计算机教育方面, 人才培养的定位与目标呈现明显的多样化趋势, 在知识结构与专业素养方面对人才的要求也在广度与深度上拓展到空前的水平。以最新版计算学科教学大纲 (ACM/IEEE Computing Curricula, 以下简称CC大纲) 为例, 2001年制定的CC2001因只能覆盖狭义的计算机科学方向而更多地被称作CS2001。所幸的是, CC2001的意义不仅在于针对计算机科学方向的本科教学提出了详细的指导意见, 更在于构建了一个开放的CC2001框架 (CC2001 Model)。按照这一规划, 首先应该顺应计算学科总体发展的大势, 沿着计算机科学 (CS)、计算机工程 (CE)、信息系统 (IS)、信息技术 (IT) 和软件工程 (SE) 以及更多潜在的新学科方向, 以分卷的形式制订相应的教学大纲计划, 同时以综述报告的形式概括统领; 另外, 不宜仍拘泥于十年的周期, 而应更为频繁地调整和更新大纲, 以及时反映计算领域研究的最新进展, 满足应用领域对人才的现实需求。

饶有意味的是, 无论从此后发表的综述报告还是各分卷报告都可看出, 作为计算学科知识结构的核心与技术体系的基石, 数据结构与算法的基础性地位不仅没有动摇, 反而得到进一步的强化和突出, 依然是计算学科研究开发人员的必备素养, 以及相关应用领域专业技术人员的看家本领。以CC大纲的综述报告 (Computing Curricula 2005 - The Overview Report) 为例, 在针对以上五个专业方向本科学位所归纳的共同要求中, 数据结构与算法作为程序设计概念与技能的核心, 紧接在数学基础之后列第二位。这方面的要求可进一步细分为五个层次: 对数据结构与算法核心地位的充分理解与认同, 从软件视角对处理器、存储器及显示器等硬件资源的透彻理解, 通过编程以软件方式实现数据结构与算法的能力, 基于恰当的数据结构与算法设计并实现大型结构化组件及其之间通讯接口的能力, 运用软件工程的原理与技术确保软件鲁棒性、可靠性及其面向特定目标受众的针对性的能力。

自20世纪末起, 我有幸参与和承担清华大学计算机系以及面向全校“数据结构”课程的教学工作, 在学习和吸收前辈们丰富而宝贵教学经验的同时, 通过悉心体会与点滴积累, 逐步摸索和总结出一套较为完整的教学方法。作为数据结构与算法一线教学工作者中的一员, 我与众多的同行一样, 在为此类课程的重要性不断提升而欢欣鼓舞的同时, 更因其对计算学科人才培养决定性作用的与日俱增而倍感责任重大。尽管多年来持续推进的教学改革已经取得巨大的进展, 但面对新的学科发展形势和社会发展需求, 为从根本上提高我国计算机理论及应用人才的培养质量, 我们的教学理念、教学内容与教学方法仍然有待于进一步突破。

与学校“高素质、高层次、多样化、创造性”人才培养总体目标相呼应, 我所在的清华大学计算机系长期致力于培养“面向基础或应用基础的科学技术问题, 具备知识创新、技术创新或集成创新能力的研究型人才”。沿着这个大方向, 近年来我与同事们从讲授、研讨、作业、实践、考核和教材等方面入手, 在系统归纳已有教学资源 and 成果的基础上, 着力推进数据结构的课程建设与改革。其中, 教材既为所授知识提供了物化的载体, 也为传授过程指明了清晰的脉络, 更为

教师与学生之间的交流建立了统一的平台，其重要性不言而喻。继2006年出版《数据结构与算法（Java语言描述）》之后，本教材的出版也是作者对自己数据结构与算法教学工作的又一次系统总结与深入探索。

原则

在读者群体定位、体例结构编排以及环节内容取舍等方面，全书尽力贯彻以下原则。

■ 兼顾基础不同、目标不同的多样化读者群体

全书12章按四大部分组织，既相对独立亦彼此呼应，难度较大的章节以星号标注，教员与学生可视具体情况灵活取舍。其中第1章绪论旨在尽快地将背景各异的读者引导至同一起点，为此将系统地引入计算与算法的一般性概念，确立时空复杂度的度量标准，并以递归为例介绍算法设计的一般模式；第2至7章为基础部分，涵盖序列、树、图、初级搜索树等基本数据结构及其算法的实现方法及性能分析，这也是多数读者在实际工作中最常涉及的内容，属于研读的重点；第8至10章为进阶部分，介绍高级搜索树、词典和优先级队列等高级数据结构，这部分内容对更加注重计算效率的读者将很有帮助；最后两章分别以串匹配和高级排序算法为例，着重介绍算法性能优化以及针对不同应用需求的调校方法与技巧，这部分内容可以帮助读者深入理解各类数据结构与算法在不同实际环境中适用性的微妙差异。

■ 注重整体认识，着眼系统思维

全书体例参照现代数据结构普遍采用的分类规范进行编排，其间贯穿以具体而本质的线索，帮助读者在了解各种具体数据结构之后，通过概括与提升形成对数据结构家族的整体性认识。行文从多个侧面体现“转换-化简”的技巧，引导读者逐步形成和强化计算思维（**computational thinking**）的意识与习惯，从方法论的高度掌握利用计算机求解问题的一般性规律与方法。

比如从逻辑结构的角度，按照线性、半线性和非线性三个层次对数据结构进行分类，并以遍历算法为线索，点明不同层次之间相互转换的技巧。又如，通过介绍动态规划、减而治之、分而治之等算法策略，展示如何将人所擅长的概括化简思维方式与计算机强大的枚举迭代能力相结合，高效地求解实际问题。再如，从数据元素访问形式的角度，按照循序访问、循位置访问或循链接访问、循关键码访问、循值访问、循优先级访问等方式，对各种数据结构做了归类，并指明它们之间的联系与区别。

通过引入代数判定树模型以及对应的下界等概念，并讲解如何针对具体计算模型确定特定问题的复杂度下界，破除了部分读者对计算机计算能力的盲目迷信。按照CC大纲综述报告的归纳结论，这也是对计算学科所有专业本科毕业生共同要求中的第三点——不仅需要了解计算机技术可以做什么（**possibilities**）以及如何做，更需要了解不能做什么（**limitations**）以及为什么不能做。

■ 尊重认知规律，放眼拓展提升

在相关学科众多的专业基础课程中，数据结构与算法给学生留下的印象多是内容深、难度大，而如何让学生打消畏难情绪从而学有所乐、学有所获，则是摆在每位任课教师面前的课题。计算机教学有其独特的认知规律，整个过程大致可以分为记忆（**remember**）、理解（**understand**）、应用（**apply**）、分析（**analyze**）、评估（**evaluate**）和创造（**create**）等若干阶段，本书也按照这一脉络，在叙述方式上做了一些粗浅的尝试。

为加深记忆与理解，凡重要的知识点均配有插图。全书共计230多组300余幅插图，借助视觉通道，从原理、过程、实例等角度使晦涩抽象的知识点得以具体化、形象化，也就是鲁迅先生“五到”读书法中的第一条“眼到”。

为加深对类似概念或系列概念的综合理解，完成认识上的提升，还普遍采用“对比”的手法。例如，优先级队列接口不同实现方式之间的性能对比、快速排序算法不同版本在适用范围上的对比，等等。又如，通过Dijkstra算法和Prim算法的横向对比，提炼和抽象出更具一般性的优先级搜索框架，并反过来基于这一认识实现统一的搜索算法模板。

为强化实践能力的培养，多从具体的应用问题入手，经逐步分析导出具体的解决方法。所列230余段代码，均根据讲述的侧重按模块划分，在力求简洁的同时也配有详实的备注解说。读者可以下载代码，边阅读边编译执行，真正做到“手到”和“心到”。几乎所有实现的数据结构均符合对应的抽象数据类型接口标准，在强化接口规范的同时，从习惯与方式上为读者日后的团队协作做铺垫与准备。

在分析与评估方面，介绍了算法复杂度的典型层次及分析技巧，包括常规的最坏情况和平均情况分析，以及分摊分析。针对递归算法，还着重介绍了递归跟踪法与递推方程法。另外从实用的角度，还引入了稳定性、就地性等更为精细的性能评估尺度，并结合部分算法做了相关的分析对比。

数据结构与算法这二者之间相辅相成的关系，也是本书着重体现的一条重要线索。为此，本书的体例与多数同类教材不尽相同。以排序算法为例，除最后一章外，大部分排序算法都作为对应数据结构的应用实例，分散编入相应的章节：其中起泡排序、归并排序、插入排序、选择排序等算法以排序器的形式归入序列部分；桶排序和基数排序归入散列部分；而堆排序则归入优先级队列部分。再如，图算法及其基本实现均前置到第6章，待到后续章节引入高级数据结构时再介绍其优化方法，如此前后呼应。行文讲述中也着力突出数据结构对高效算法的支撑作用，以及源自应用的算法问题对数据结构发展的反向推动作用，优先级队列之于Huffman编码算法、完全二叉堆之于就地堆排序、伸展树之于基于局部性原理的缓存算法、散列表之于数值空间与样本空间规模差异的弥合算法等，均属于这方面的实例。

与许多课程的规律类似，习题对于数据结构与算法而言也是强化和提升学习效果的必由之途，否则无异于“入宝山而空返”。本书各章均针对性地附有大量习题，累计逾270道。当然，好的习题不应仅限于对讲授内容的重复与堆砌，而应更多地侧重于拓展与反思。其中，拓展型习题既包括对书中数据结构接口的扩充、算法性能的改进，也包括通过查阅文献资料补充相关的知识点。另外，一些难度极大或者难度不大但过程繁琐的内容，在这里也以习题的形式留待课后进一步探讨。在求知求真的过程中，质疑与批判是难能可贵的精神，反诘与反思更是创造创新的起点。从吸收到反思，在某种意义上也就是学习（learning）与反学习（unlearning）反复迭代、不断上升的过程。为此，部分习题的答案并非简单地重复正文的结论，甚至并不具有固定的答案，以给读者日后灵活的运用与创新留下足够的空间。

说明

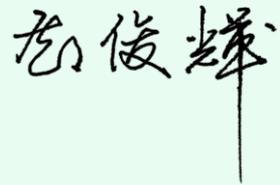
书中凡重要的专业词汇均注有原文，插图中的标注也多以英文给出，因为作者认为这都是进一步钻研以及与国际同行交流的基础。公式多采用接近代码的风格，而非严格的数学格式，以利

于按照代码注释的方式描述和理解算法。

书中涉及的所有代码以及大量尚未在书中列出的辅助代码，均按Visual Studio工程形式分成50多组，并统一到名为DSACPP的解决方案之下，完整的代码包可从本书主页下载后直接编译执行。

为精简篇幅、突出重点，在一定程度上牺牲了软件规范性甚至计算效率，读者不必盲目效仿。比如，为尽量利用页面宽度和便于投影式播放，全文源代码统一采用Java风格编排，但代码的层次感却因此有所削弱，代码片段的切分也有过度之嫌。同样出于简化的考虑，代码中一些本可优化但可能影响总体思路的细节也被忽略。另外，对错误与意外的处理也采用了简化的处理方式。

限于本人的水平与经验，书中一定不乏纰漏与谬误之处，恳请读者及专家批评指正。

Handwritten signature in black ink, reading '赵俊辉' (Zhao Junhui). The signature is written in a cursive style with a long vertical line extending downwards from the bottom character.

2011年夏末于清华园

教学计划编排方案建议

采用本书作为教材时，视学生基础、专业方向、教学目标及允许课时总量的不同，授课教师可参照以下典型方案分配课内学时，通常还需另外设置约50%的课外编程实验学时。

教学方案与课内学时分配			方案A	方案B	方案C	方案D	方案E	方案F	方案G	
教学内容	部分	章	节 (视学时可省带*小节)	64	48	64	64	48	32	48
一 基础知识	第1章 绪论	1.1~1.3 + 1.5		2.5	2.5	3.5	4.5	3.5	2.5	3
		1.4*		1.5	1.5	2	2.5	2.5	0	2
二 基本数据 结构	第2章 向量	2.1 ~ 2.6		3	3	3	4	3	2.5	3
		2.7*		1	0	1.5	2	1	0	0
		2.8		2	2	2	3	2	2	2
	第3章 列表	3.1 ~ 3.4		2	2	3	4	3	2	3
		3.5		2	2	3	4	3	2	3
	第4章 栈与队列	4.1 ~ 4.3		2	2	2	3	2	2	2
		4.4*		3	3	3	3	3	0	3
		4.5 ~ 4.6		1	1	1	2	1	2	1
	第5章 二叉树	5.1 + 5.3		2	2	2	2	2	2	2
		5.4		2	2	3	3	3	2	2
		5.2 + 5.5		2	2	3	3	3	0	3
	第6章 图	6.1 ~ 6.4		1.5	1.5	2	2	2	2	2
		6.5 ~ 6.8		2.5	2.5	2	4	3	3	3
		6.9*		1	1	2	2	0	0	0
		6.10 ~ 6.12		2	2	2	4	3	2	2
	第7章 搜索树	7.1 ~ 7.2		2	2	3	6	4	3	3
7.3 ~ 7.4		2	2	3	6	4	3	3		
三 高级数据 结构	第8章 高级搜索树	8.1 ~ 8.2		2	2	3	0	0	0	0
		8.3* ~ 8.4*		3	0	3	0	0	0	0
	第9章 词典	9.1 + 9.3		2	2	2	0	0	0	0
		9.2* + 9.4*		4	0	4	0	0	0	0
	第10章 优先级队列	10.1 ~ 10.2		4	4	4	0	0	0	0
10.3*		2	0	2	0	0	0	0		
四 算法	第11章 串	11.1 ~ 11.3		2	2	0	0	0	0	2
		11.4* ~ 11.5*		2	0	0	0	0	0	2
	第12章 排序	12.1		2	2	0	0	0	0	2
		12.2* ~ 12.3*		4	0	0	0	0	0	0

本书所有相关教学资料均向公众开放，包括勘误表、插图、代码以及配套讲义等。欢迎访问教材主页：<http://dsa.cs.tsinghua.edu.cn/~deng/dsacpp/>

致 谢

感谢严蔚敏教授，廿多年前是她引领我进入数据结构的殿堂；感谢吴文虎教授，在追随他参与信息学相关竞赛组织工作的过程中，我更加切实地感受到了算法之宏之美。感谢殷人昆、王宏、朱仲涛、徐明星、尹霞等老师，在与他们的教学合作过程中我获益良多。感谢众多的同行，与他们的交流和探讨每每令我思路顿开。感谢数以千计的学生，他们是我写作的最终动机与不竭动力，无论是在课堂或是课后，与他们相处的时光都属于我在清华园最美好的记忆。

历年的助教研究生不仅出色地完成了繁重的课外辅导与资源建设工作，他们丰富的想象力和创造力更是我重要的灵感来源，在此我要感谢他们对我的帮助！

截至2012年秋季，按担任助教时间先后，他们分别是：

王智、李云翀、赵乐、肖晶、刘汝佳、高岳、沈超慧、李锐喆
于泽、白彦冰、夏龙、向阳、姚姜源、刘雨辰、姜禹、方宇剑

在本书各版次的使用过程中，收到了学生及读者的大量反馈，其中杨凯峪、李雨田、许婷婷、郑斯陶、石梦凯、陈逸翀、王紫、朱剑男、李仁杰、许建林、吴育昕、刘苏齐、陈键飞、唐骞璘、徐霜晴等同学，分别指出了多处纰漏及错误。王笑尘同学作为第3版的试验读者，杨凯峪、李雨田同学作为配套《习题解析》的试验读者，均提出了许多很好的修改建议。清华美院的郭清华同学，对第3版的版式和色调设计提出了极具价值的建议。在此也谨向他们表示感谢！

感谢清华大学出版社的各位编辑，正是依靠他们的鼎力支持，本书才得以顺利出版。特别感谢龙启铭先生，他出色而高效的协调工作，使我得以将更多精力集中于书稿本身；在体例编排及编写风格等方面，他的许多建议都极具价值。

本教材第3版的撰写工作，得到了“清华大学985名优教材”立项资助，在此谨向清华大学，特别是校、系教务部门的大力支持表示感谢！

简要目录

第1章 绪论 1

- §1.1 计算机与算法 2
- §1.2 复杂度度量 8
- §1.3 复杂度分析 11
- §1.4 *递归 16
- §1.5 抽象数据类型 26

第2章 向量 27

- §2.1 从数组到向量 28
- §2.2 接口 29
- §2.3 构造与析构 32
- §2.4 动态空间管理 33
- §2.5 常规向量 37
- §2.6 有序向量 44
- §2.7 *排序与下界 57
- §2.8 排序器 59

第3章 列表 65

- §3.1 从向量到列表 66
- §3.2 接口 67
- §3.3 列表 71
- §3.4 有序列表 77
- §3.5 排序器 78

第4章 栈与队列 85

- §4.1 栈 86
- §4.2 栈与递归 88
- §4.3 栈的典型应用 90

§4.4 *试探回溯法 99

§4.5 队列 105

§4.6 队列应用 107

第5章 二叉树 109

§5.1 二叉树及其表示 110

§5.2 编码树 114

§5.3 二叉树的实现 117

§5.4 遍历 124

§5.5 Huffman编码 136

第6章 图 149

§6.1 概述 150

§6.2 抽象数据类型 153

§6.3 邻接矩阵 155

§6.4 邻接表 158

§6.5 图遍历算法概述 159

§6.6 广度优先搜索 159

§6.7 深度优先搜索 162

§6.8 拓扑排序 165

§6.9 *双连通域分解 168

§6.10 优先级搜索 172

§6.11 最小支撑树 174

§6.12 最短路径 178

第7章 搜索树 181

§7.1 查找 183

§7.2 二叉搜索树 184

§7.3 平衡二叉搜索树 _____ 191

§7.4 AVL树 _____ 194

第8章 高级搜索树 203

§8.1 伸展树 _____ 204

§8.2 B-树 _____ 212

§8.3 *红黑树 _____ 227

§8.4 *kd-树 _____ 239

第9章 词典 245

§9.1 词典ADT _____ 247

§9.2 *跳转表 _____ 249

§9.3 散列表 _____ 259

§9.4 *散列应用 _____ 277

第10章 优先级队列 281

§10.1 优先级队列ADT _____ 282

§10.2 堆 _____ 286

§10.3 *左式堆 _____ 297

第11章 串 305

§11.1 串及串匹配 _____ 306

§11.2 蛮力算法 _____ 309

§11.3 KMP算法 _____ 311

§11.4 *BM算法 _____ 317

§11.5 *Karp-Rabin算法 _____ 327

第12章 排序 333

§12.1 快速排序 _____ 334

§12.2 *选取与中位数 _____ 341

§12.3 *希尔排序 _____ 350

附录 357

参考文献 _____ 358

插图索引 _____ 362

表格索引 _____ 369

算法索引 _____ 370

代码索引 _____ 371

关键词索引 _____ 377

详细目录

第1章 绪论

1

§1.1 计算机与算法 2

- 1.1.1 古埃及人的绳索 2
- 1.1.2 欧几里得的尺规 3
- 1.1.3 起泡排序 4
- 1.1.4 算法 5
- 1.1.5 算法效率 7

§1.2 复杂度度量 8

- 1.2.1 时间复杂度 8
- 1.2.2 渐进复杂度 9
- 1.2.3 空间复杂度 11

§1.3 复杂度分析 11

- 1.3.1 常数 $O(1)$ 12
- 1.3.2 对数 $O(\log n)$ 12
- 1.3.3 线性 $O(n)$ 13
- 1.3.4 多项式 $O(\text{polynomial}(n))$
..... 14
- 1.3.5 指数 $O(2^n)$ 14
- 1.3.6 复杂度层次 15
- 1.3.7 输入规模 16

§1.4 *递归 16

- 1.4.1 线性递归 17
- 1.4.2 递归分析 17
- 1.4.3 递归模式 19
- 1.4.4 递归消除 21
- 1.4.5 二分递归 22

§1.5 抽象数据类型 26

第2章 向量

27

§2.1 从数组到向量 28

- 2.1.1 数组 28

- 2.1.2 向量 29

§2.2 接口 29

- 2.2.1 ADT接口 29
- 2.2.2 操作实例 30
- 2.2.3 Vector模板类 30

§2.3 构造与析构 32

- 2.3.1 默认构造方法 32
- 2.3.2 基于复制的构造方法 32
- 2.3.3 析构方法 33

§2.4 动态空间管理 33

- 2.4.1 静态空间管理 33
- 2.4.2 可扩充向量 34
- 2.4.3 扩容 34
- 2.4.4 分摊分析 35
- 2.4.5 缩容 36

§2.5 常规向量 37

- 2.5.1 直接引用元素 37
- 2.5.2 置乱器 37
- 2.5.3 判等器与比较器 38
- 2.5.4 无序查找 39
- 2.5.5 插入 40
- 2.5.6 删除 40
- 2.5.7 唯一化 42
- 2.5.8 遍历 43

§2.6 有序向量 44

- 2.6.1 比较器 44
- 2.6.2 有序性甄别 44
- 2.6.3 唯一化 45
- 2.6.4 查找 47
- 2.6.5 二分查找 (版本A) 48
- 2.6.6 Fibonacci查找 52
- 2.6.7 二分查找 (版本B) 54
- 2.6.8 二分查找 (版本C) 56

§2.7 *排序与下界 _____ 57

- 2.7.1 有序性 57
- 2.7.2 排序及其分类 57
- 2.7.3 下界 57
- 2.7.4 比较树 58
- 2.7.5 估计下界 59

§2.8 排序器 _____ 59

- 2.8.1 统一入口 59
- 2.8.2 起泡排序 60
- 2.8.3 归并排序 61

第3章 列表 _____ **65**

§3.1 从向量到列表 _____ 66

- 3.1.1 从静态到动态 66
- 3.1.2 由秩到位置 67
- 3.1.3 列表 67

§3.2 接口 _____ 67

- 3.2.1 列表节点 67
- 3.2.2 列表 68

§3.3 列表 _____ 71

- 3.3.1 头、尾节点 71
- 3.3.2 默认构造方法 71
- 3.3.3 由秩到位置的转换 72
- 3.3.4 查找 72
- 3.3.5 插入 72
- 3.3.6 基于复制的构造 74
- 3.3.7 删除 75
- 3.3.8 析构 76
- 3.3.9 唯一化 76
- 3.3.10 遍历 77

§3.4 有序列表 _____ 77

- 3.4.1 唯一化 77
- 3.4.2 查找 78

§3.5 排序器 _____ 78

- 3.5.1 统一入口 78

- 3.5.2 插入排序 79
- 3.5.3 选择排序 80
- 3.5.4 归并排序 82

第4章 栈与队列 _____ **85**

§4.1 栈 _____ 86

- 4.1.1 ADT接口 86
- 4.1.2 操作实例 87
- 4.1.3 Stack模板类 88

§4.2 栈与递归 _____ 88

- 4.2.1 函数调用栈 88
- 4.2.2 避免递归 89

§4.3 栈的典型应用 _____ 90

- 4.3.1 逆序输出 90
- 4.3.2 递归嵌套 91
- 4.3.3 延迟缓冲 94
- 4.3.4 逆波兰表达式 96

§4.4 *试探回溯法 _____ 99

- 4.4.1 试探与回溯 99
- 4.4.2 八皇后 100
- 4.4.3 迷宫寻径 102

§4.5 队列 _____ 105

- 4.5.1 概述 105
- 4.5.2 ADT接口 105
- 4.5.3 操作实例 106
- 4.5.4 Queue模板类 106

§4.6 队列应用 _____ 107

- 4.6.1 循环分配器 107
- 4.6.2 银行服务模拟 107

第5章 二叉树 _____ **109**

§5.1 二叉树及其表示 _____ 110

- 5.1.1 树 110
- 5.1.2 二叉树 111
- 5.1.3 多叉树 112

§5.2 编码树	114
5.2.1 二进制编码	114
5.2.2 二叉编码树	116
§5.3 二叉树的实现	117
5.3.1 二叉树节点	117
5.3.2 二叉树节点操作接口	119
5.3.3 二叉树	120
§5.4 遍历	124
5.4.1 递归式遍历	124
5.4.2 *迭代版先序遍历	126
5.4.3 *迭代版中序遍历	128
5.4.4 *迭代版后序遍历	132
5.4.5 层次遍历	133
§5.5 Huffman编码	136
5.5.1 PFC编码及解码	136
5.5.2 最优编码树	139
5.5.3 Huffman编码树	141
5.5.4 Huffman编码算法	143

第6章 图 149

§6.1 概述	150
§6.2 抽象数据类型	153
6.2.1 操作接口	153
6.2.2 Graph模板类	153
§6.3 邻接矩阵	155
6.3.1 原理	155
6.3.2 实现	155
6.3.3 时间性能	157
6.3.4 空间性能	157
§6.4 邻接表	158
6.4.1 原理	158
6.4.2 复杂度	158
§6.5 图遍历算法概述	159
§6.6 广度优先搜索	159
6.6.1 策略	159

6.6.2 实现	160
6.6.3 实例	161
6.6.4 复杂度	161
6.6.5 应用	161

§6.7 深度优先搜索 162

6.7.1 策略	162
6.7.2 实现	162
6.7.3 实例	163
6.7.4 复杂度	165
6.7.5 应用	165

§6.8 拓扑排序 165

6.8.1 应用	165
6.8.2 有向无环图	166
6.8.3 算法	166
6.8.4 实现	167
6.8.5 实例	168
6.8.6 复杂度	168

§6.9 *双连通域分解 168

6.9.1 关节点与双连通域	168
6.9.2 蛮力算法	169
6.9.3 可行算法	169
6.9.4 实现	170
6.9.5 实例	171
6.9.6 复杂度	172

§6.10 优先级搜索 172

6.10.1 优先级与优先级数	172
6.10.2 基本框架	173
6.10.3 复杂度	174

§6.11 最小支撑树 174

6.11.1 支撑树	174
6.11.2 最小支撑树	174
6.11.3 歧义性	175
6.11.4 蛮力算法	175
6.11.5 Prim算法	175

§6.12 最短路径 178

6.12.1 最短路径树	178
--------------	-----

6.12.2 Dijkstra算法178

第7章 搜索树 181

§7.1 查找 183

7.1.1 循关键词访问183

7.1.2 词条.....183

7.1.3 序与比较器183

§7.2 二叉搜索树 184

7.2.1 顺序性.....184

7.2.2 中序遍历序列184

7.2.3 BST模板类.....185

7.2.4 查找算法及其实现.....185

7.2.5 插入算法及其实现.....188

7.2.6 删除算法及其实现.....189

§7.3 平衡二叉搜索树 191

7.3.1 树高与性能191

7.3.2 理想平衡与适度平衡...192

7.3.3 等价变换192

7.3.4 旋转调整193

§7.4 AVL树 194

7.4.1 定义及性质194

7.4.2 节点插入196

7.4.3 节点删除198

7.4.4 统一平衡算法200

第8章 高级搜索树 203

§8.1 伸展树 204

8.1.1 局部性.....204

8.1.2 逐层伸展205

8.1.3 双层伸展206

8.1.4 伸展树的实现208

§8.2 B-树 212

8.2.1 多路平衡查找212

8.2.2 ADT接口及其实现215

8.2.3 关键词查找216

8.2.4 性能分析218

8.2.5 关键词插入219

8.2.6 上溢与分裂219

8.2.7 关键词删除222

8.2.8 下溢与合并223

§8.3 *红黑树 227

8.3.1 概述.....228

8.3.2 红黑树接口定义230

8.3.3 节点插入算法231

8.3.4 节点删除算法234

§8.4 *kd-树 239

8.4.1 范围查询239

8.4.2 kd-树242

8.4.3 基于2d-树的范围查询..243

第9章 词典 245

§9.1 词典ADT 247

9.1.1 操作接口247

9.1.2 操作实例247

9.1.3 接口定义248

9.1.4 实现方法248

§9.2 *跳转表 249

9.2.1 Skiplist模板类.....249

9.2.2 总体逻辑结构250

9.2.3 四联表250

9.2.4 查找.....252

9.2.5 空间复杂度253

9.2.6 时间复杂度254

9.2.7 插入.....255

9.2.8 删除.....258

§9.3 散列表 259

9.3.1 完美散列259

9.3.2 装填因子与空间利用率 .260

9.3.3 散列函数261

9.3.4 散列表264

9.3.5 冲突及其排解266

9.3.6 闭散列策略	268
9.3.7 查找与删除	271
9.3.8 插入	272
9.3.9 更多闭散列策略	273
9.3.10 散列码转换	275

§9.4 *散列应用 _____ 277

9.4.1 桶排序	277
9.4.2 最大间隙	278
9.4.3 基数排序	279

第10章 优先级队列 281

§10.1 优先级队列ADT _____ 282

10.1.1 优先级与优先级队列 ..	282
10.1.2 关键码、比较器与偏序关系	283
10.1.3 操作接口	283
10.1.4 操作实例：选择排序 ..	283
10.1.5 接口定义	284
10.1.6 应用实例：Huffman编码树	284

§10.2 堆 _____ 286

10.2.1 完全二叉堆	286
10.2.2 元素插入	289
10.2.3 元素删除	291
10.2.4 建堆	292
10.2.5 就地堆排序	295

§10.3 *左式堆 _____ 297

10.3.1 堆合并	297
10.3.2 单侧倾斜	298
10.3.3 PQ_LeftHeap模板类 ..	298
10.3.4 空节点路径长度	299
10.3.5 左倾性与左式堆	299
10.3.6 最右侧通路	300
10.3.7 合并算法	300
10.3.8 实例	301
10.3.9 合并操作merge()的实现	

.....	302
10.3.10 复杂度	303
10.3.11 基于合并的插入和删除	303

第11章 串 305

§11.1 串及串匹配 _____ 306

11.1.1 串	306
11.1.2 串匹配	307
11.1.3 测评标准与策略	308

§11.2 蛮力算法 _____ 309

11.2.1 算法描述	309
11.2.2 算法实现	309
11.2.3 时间复杂度	310

§11.3 KMP算法 _____ 311

11.3.1 构思	311
11.3.2 next表	312
11.3.3 KMP算法	312
11.3.4 next[0] = -1	313
11.3.5 next[j + 1]	313
11.3.6 构造next表	314
11.3.7 性能分析	314
11.3.8 继续改进	315

§11.4 *BM算法 _____ 317

11.4.1 思路与框架	317
11.4.2 坏字符策略	318
11.4.3 好后缀策略	321
11.4.4 GS[]表构造算法	323
11.4.5 算法纵览	326

§11.5 *Karp-Rabin算法 _____ 327

11.5.1 构思	327
11.5.2 算法与实现	328

第12章 排序 333

§12.1 快速排序 _____ 334

12.1.1 分治策略	334
-------------------	-----

12.1.1.2 轴点.....	334
12.1.1.3 快速排序算法	335
12.1.1.4 快速划分算法	335
12.1.1.5 复杂度.....	338
12.1.1.6 应对退化	339
§12.2 * 选取与中位数	341
12.2.1 概述.....	341
12.2.2 众数.....	342
12.2.3 归并向量的中位数...	343
12.2.4 基于优先级队列的选取	346
12.2.5 基于快速划分的选取..	347
12.2.6 k-选取算法	348
§12.3 * 希尔排序	350

12.3.1 递减增量策略	350
12.3.2 增量序列	353

附录 **357**

参考文献	358
插图索引	362
表格索引	369
算法索引	370
代码索引	371
关键词索引	377

第1章

绪论

作为万物之灵的人，与动物的根本区别在于理性，而计算则是理性的一种重要而具体的表现形式。计算机是人类从事计算的工具，是抽象计算模型的具体物化。基于图灵模型是现代计算机，既是人类现代文明的标志与基础，更是人脑思维的拓展与延伸。

尽管计算机的性能日益提高，但这种能力在解决实际问题时能否真正得以发挥，决定性的关键因素仍在于人类自身。具体地，通过深入思考与分析获得对问题本质的透彻理解，按照长期积淀而成的框架与模式设计出合乎问题内在规律的算法，选用、改进或定制足以支撑算法高效实现的数据结构，并在真实的应用环境中充分测试、调校和改进，构成了应用计算机高效求解实际问题的典型流程与不二法门。任何一位有志于驾驭计算机的学生，都应该从这些方面入手，不断学习，反复练习，勤于总结。

本章将介绍与计算相关的基本概念，包括算法构成的基本要素、算法效率的衡量尺度、计算复杂度的分析方法与界定技巧、算法设计的基本框架与典型模式，这些也构成了全书所讨论的各类数据结构及相关算法的基础与出发点。

§ 1.1 计算机与算法

1946年问世的ENIAC开启了现代电子数字计算机的时代，计算机科学（computer science）也在随后应运而生。计算机科学的核心在于研究计算方法与过程的规律，而不仅仅是作为计算工具的计算机本身，因此E. Dijkstra及其追随者更倾向于将这门科学称作计算科学（computing science）。

实际上，人类使用不同工具从事计算的历史可以追溯到更为久远的时代，计算以及计算工具始终与我们如影相随地穿越漫长的时光岁月，不断推动人类及人类社会的进化发展。从最初颜色各异的贝壳、长短不一的刻痕、周载轮回的日影、粗细有别的绳结，以至后来的直尺、圆规和算盘，都曾经甚至依然是人类有力的计算工具。

1.1.1 古埃及人的绳索

古埃及人以其复杂而浩大的建筑工程而著称于世，在长期规划与实施此类工程的过程中，他们逐渐归纳并掌握了基本的几何度量 and 测绘方法。考古研究发现，公元前2000年的古埃及人已经知道如何解决如下实际工程问题：通过直线 l 上给定的点 P ，作该直线的垂线。

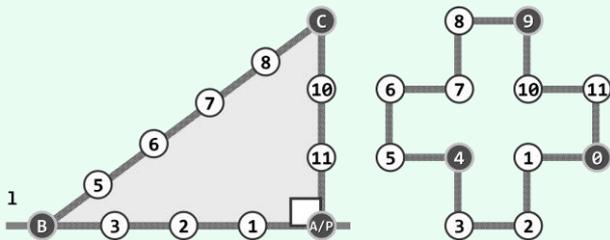


图1.1 古埃及人使用的绳索计算机及其算法

他们所采用的方法，原理及过程如图1.1所示，翻译成现代的算法语言可描述如下。

```
perpendicular(l, P)
```

输入：直线 l 及其上一点 P

输出：经过 P 且垂直于 l 的直线

1. 取12段等长绳索，依次首尾联结成环 //联结处称作“结”，按顺时针方向编号为0..11
2. 奴隶A看管0号结，将其固定于点 P 处
3. 奴隶B牵动4号结，将绳索沿直线 l 方向尽可能地拉直
4. 奴隶C牵动9号结，将绳索尽可能地拉直
5. 经过0号和9号结，绘制一条直线

算法1.1 过直线上给定点作直角

以上由古希腊人发明、由奴隶与绳索组成的这套计算工具，乍看起来与现代的电子计算机相去甚远。但就本质而言，二者之间的相似之处远多于差异，它们同样都是用于支持和实现计算过程的物理机制，亦即广义的计算机。因此就这一意义而言，将其称作“绳索计算机”毫不过分。

1.1.2 欧几里得的尺规

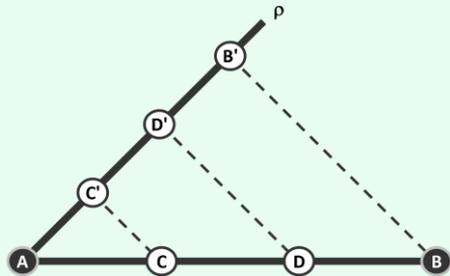
欧几里得几何是现代公理系统的鼻祖。从计算的角度来看，针对不同的几何问题，欧氏几何都分别给出了一套几何作图流程，也就是具体的算法。比如，经典的线段三等分过程可描述为如算法1.2所示。该算法的一个典型的执行实例如图1.2所示。

```
tripartition(AB)
```

输入：线段 AB

输出：将 AB 三等分的两个点 C 和 D

1. 从 A 发出一条与 AB 不重合的射线 ρ
2. 任取 ρ 上三点 C' 、 D' 和 B' ，使 $|AC'| = |C'D'| = |D'B'|$
3. 联接 $B'B$
4. 过 D' 做 $B'B$ 的平行线，交 AB 于 D
5. 过 C' 做 $B'B$ 的平行线，交 AB 于 C



算法1.2 三等分给定线段

图1.2 古希腊人的尺规计算机

在以上算法中，输入为所给的直线段 AB ，输出为将其三等分的 C 和 D 点。我们知道，欧氏几何还给出了大量过程与功能更为复杂的几何作图算法，为将这些算法变成可行的实际操作序列，欧氏几何使用了两种相互配合的基本工具：不带刻度的直尺，以及半径跨度不受限制的圆规。同样地，从计算的角度来看，由直尺和圆规构成的这一物理机制也不妨可以称作“尺规计算机”。在尺规计算机中，可行的基本操作不外乎以下五类：

- 过两个点作一直线
- 确定两条直线的交点
- 以任一点为圆心，以任意半径作一个圆
- 确定任一直线和任一圆的交点（若二者的确相交）
- 确定两个圆的交点（若二者的确相交）

每一欧氏作图算法均可分解为一系列上述操作的组合，故称之为基本操作恰如其分。

1.1.3 起泡排序

D. Knuth^[3]曾指出，四分之一以上的CPU时间都用于执行同一类型的计算：按照某种约定的次序，将给定的一组元素顺序排列，比如将 n 个整数按通常的大小次序排成一个非降序列。这类操作统称排序（**sorting**）。

就广义而言，我们今天借助计算机所完成的计算任务中，有更高的比例都可归入此类。例如，从浩如烟海的万维网中找出与特定关键词最相关的前100个页面，就是此类计算的一种典型形式。排序问题在算法设计与分析中扮演着重要的角色，以下不妨首先就此做一讨论。为简化起见，这里暂且只讨论对整数的排序。

■ 局部有序与整体有序

在由一组整数组成的序列 $A[0, n - 1]$ 中，满足 $A[i - 1] \leq A[i]$ 的相邻元素称作顺序的；否则是逆序的。不难看出，有序序列中每一对相邻元素都是顺序的，亦即，对任意 $1 \leq i < n$ 都有 $A[i - 1] \leq A[i]$ ；反之，所有相邻元素均顺序的序列，也必然整体有序。

■ 扫描交换

由有序序列的上述特征，我们可以通过不断改善局部的有序性实现整体的有序：从前向后依次检查每一对相邻元素，一旦发现逆序即交换二者的位置。对于长度为 n 的序列，共需做 $n - 1$ 次比较和不超过 $n - 1$ 次交换，这一过程称作一趟扫描交换。

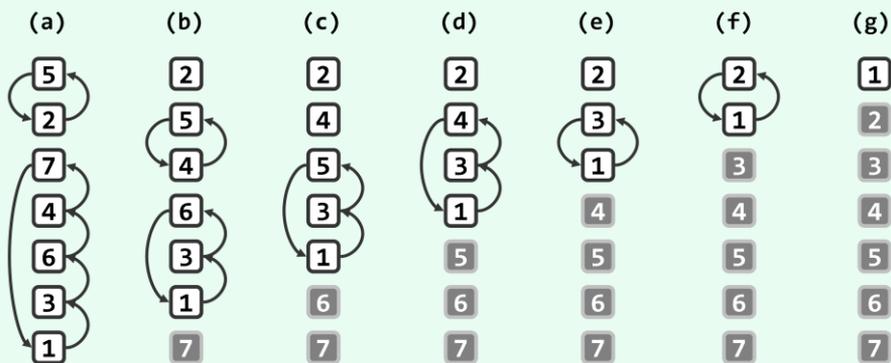


图1.3 通过6趟扫描交换对七个整数排序（其中已就位的元素以深色示意）

以图1.3(a)中由7个整数组成的序列 $A[0, 6] = \{ 5, 2, 7, 4, 6, 3, 1 \}$ 为例。

在第一趟扫描交换过程中， $\{ 5, 2 \}$ 交换位置， $\{ 7, 4, 6, 3, 1 \}$ 循环交换位置，扫描交换后的结果如图(b)所示。

■ 起泡排序

可见，经过这样的一趟扫描，序列未必达到整体有序。果真如此，则可对该序列再做一趟扫描交换，比如，图(b)再经一趟扫描交换的结果如图(c)。事实上，很有可能如图(c~f)所示，需要反复进行多次扫描交换，直到如图(g)所示，在序列中不再含有任何逆序的相邻元素。多数的这类交换操作，都会使得越小（大）的元素朝上（下）方移动（习题[1-3]），直至它们抵达各自应处的位置。

排序过程中，所有元素朝各自最终位置亦步亦趋的移动过程，犹如气泡在水中的上下沉浮，起泡排序（**bubblesort**）算法也因此得名。

■ 实现

上述起泡排序的思路，可准确描述和实现为如代码1.1所示的函数**bubblesort1A()**。

```

1 void bubblesort1A(int A[], int n) { //起泡排序算法 (版本1A) : 0 <= n
2     bool sorted = false; //整体排序标志, 首先假定尚未排序
3     while (!sorted) { //在尚未确认已全局排序之前, 逐趟进行扫描交换
4         sorted = true; //假定已经排序
5         for (int i = 1; i < n; i++) { //自左向右逐对检查当前范围A[0, n)内的各相邻元素
6             if (A[i - 1] > A[i]) { //一旦A[i - 1]与A[i]逆序, 则
7                 swap(A[i - 1], A[i]); //交换之, 并
8                 sorted = false; //因整体排序不能保证, 需要清除排序标志
9             }
10        }
11        n--; //至此未元素必然就位, 故可以缩短待排序序列的有效长度
12    }
13 } //借助布尔型标志位sorted, 可及时提前退出, 而不致总是蛮力地做n - 1趟扫描交换

```

代码1.1 整数数组的起泡排序

1.1.4 算法

以上三例都可称作算法。那么，究竟什么是算法呢？所谓算法，是指基于特定的计算模型，旨在解决某一信息处理问题而设计的一个指令序列。比如，针对“过直线上一点作垂直线”这一问题，基于由绳索和奴隶构成的计算模型，由古埃及人设计的算法1.1；针对“三等分线段”这一问题，基于由直尺和圆规构成的计算模型，由欧几里得设计的算法1.2；以及针对“将若干元素按大小排序”这一问题，基于图灵机模型而设计的**bubblesort1A()**算法，等等。

一般地，本书所说的算法还应必须具备以下要素。

■ 输入与输出

待计算问题的任一实例，都需要以某种方式交给对应的算法，对所求解问题特定实例的这种描述统称为输入（**input**）。对于上述三个例子而言，输入分别是“某条直线及其上一点”、“某条线段”以及“由n个整数组成的某一序列”。其中，第三个实例的输入具体地由**A[]**与n共同描述和定义，前者为存放待排序整数的数组，后者为整数的总数。

经计算和处理之后得到的信息，即针对输入问题实例的答案，称作输出（**output**）。比如，对于上述三个例子而言，输出分别是“垂直线”、“三等分点”以及“有序序列”。在物理上，输出有可能存放于单独的存储空间中，也可能直接存放于原输入所占的存储空间中。比如，第三个实例即属于后一情形，经排序的整数将按非降次序存放在数组**A[]**中。

■ 基本操作、确定性与可行性

所谓确定性和可行性是指，算法应可描述为由若干语义明确的基本操作组成的指令序列，且每一基本操作在对应的计算模型中均可兑现。以上述算法1.1为例，整个求解过程可以明白无误地描述为一系列借助绳索可以兑现的基本操作，比如“取等长绳索”、“联结绳索”、“将绳结固定于指定点”以及“拉直绳索”等。再如算法1.2中，“从一点任意发出一条射线”、“在直线上任取三个等距点”、“联接指定两点”等，也都属于借助尺规可以兑现的基本操作。

细心的读者可能会注意到，算法1.2所涉及的操作并不都是基本的，比如，最后两句都要求“过直线外一点作其平行线”，这本身就是另一几何作图问题。幸运的是，借助基本操作的适当组合，这一子问题也可圆满解决，对应的算法则不妨称作是算法1.2的“子算法”。

从现代程序设计语言的角度，可以更加便捷而准确地理解算法的确定性与可行性。具体地，一个算法满足确定性与可行性，当且仅当它可以通过程序设计语言精确地描述，比如，起泡排序算法可以具体地描述和实现为代码1.1中的函数**bubblesort1A()**，其中“读取某一元素的内容”、“修改某一元素的内容”、“比较两个元素的大小”、“逻辑表达式求值”以及“根据逻辑判断确定分支转向”等等，都属于现代电子计算机所支持的基本操作。

■ 有穷性与正确性

不难理解，任意算法都应在执行有限次基本操作之后终止并给出输出，此即所谓算法的有穷性（**finiteness**）。进一步地，算法不仅应该迟早会终止，而且所给的输出还应该能够符合由问题本身在事先确定的条件，此即所谓算法的正确性（**correctness**）。

对以上前两个算法实例而言，在针对任一输入实例的计算过程中，每条基本操作语句仅执行一次，故其有穷性不证自明。另外，根据勾股定理以及平行等比原理，其正确性也一目了然。然而对于更为复杂的算法，这两条性质的证明往往颇需费些周折（习题[1-27]和[1-28]），有些问题甚至尚无定论（习题[1-29]）。即便是简单的起泡排序，**bubblesort1A()**算法的有穷性和正确性也不是由代码1.1自身的结构直接保证的。以下就以此为例做一分析。

■ 起泡排序

图1.3给出了**bubblesort1A()**的一次具体执行过程和排序结果，然而严格地说，这远不足以证明起泡排序就是一个名副其实的算法。比如，对于任意一组整数，经过若干趟的起泡交换之后该算法是否总能完成排序？事实上，即便是其有穷性也值得怀疑。就代码结构而言，只有在前一趟扫描交换中未做任何元素交换的情况下，外层循环才会因条件“**!sorted**”不再满足而退出。但是，这一情况对任何输入实例都总能出现吗？反过来，是否存在某一（某些）输入序列，无论做多少趟起泡交换也无济于事？这种担心并非毫无道理。细心的读者或许已注意到，在起泡交换的过程中，尽管多数时候元素会朝着各自的最终位置不断靠近，但有的时候某些元素也的确会暂时朝着远离自己应处位置的方向移动（习题[1-3]）。

证明算法有穷性和正确性的一个重要技巧，就是从适当的角度审视整个计算过程，并找出其所具有的某种不变性和单调性。其中的单调性通常是指，问题的有效规模会随着算法的推进不断递减。不变性则不仅应在算法初始状态下自然满足，而且应与最终的正确性相呼应——当问题的有效规模缩减到0时，不变性应随即等价于正确性。

那么，具体到**bubblesort1A()**算法，其单调性和不变性应如何定义和体现呢？

反观图1.3不难看出，每经过一趟扫描交换，尽管并不能保证序列立即达到整体有序，但从“待求解问题的规模”这一角度来看，整体的有序性必然有所改善。以全局最大的元素（图1.3中的整数7）为例，在第一趟扫描交换的过程中，一旦触及该元素，它必将与后续的所有元素依次交换。于是如图1.3(b)所示，经过第一趟扫描之后，该最大元素必然就位；而且在此后的各趟扫描交换中，该元素将绝不会参与任何交换。这就意味着，经过一趟扫描交换之后，我们只需要关注前面更小的那 $n - 1$ 个元素。实际上，这一结论对后续的各趟扫描交换也都成立——考查图1.3(c~g)中的元素6~2，不难验证这一点。

于是，起泡排序算法的不变性和单调性可分别概括为：**经过k趟扫描交换之后，最大的前k个元素必然就位；经过k趟扫描交换之后，待求解问题的有效规模将缩减至n - k。**

反观如代码1.1所示的**bubblesort1A()**算法，外层while循环会不断缩减待排序序列的有效长度n。现在我们已经可以理解，该算法之所以能够如此处理，正是基于以上不变性和单调性。

特别地，初始状态下k = 0，这两条性质都自然满足。另一方面，由以上单调性可知，无论如何，至多经n - 1趟扫描交换后，问题的有效规模必将缩减至1。此时，仅含单个元素的序列，有序性不言而喻；而由该算法的不变性，其余n - 1个元素在此前的n - 1步迭代中业已相继就位。因此，算法不仅必然终止，而且输出序列必然整体有序，其有穷性与正确性由此得证。

■ 退化与鲁棒性

同一问题往往不限于一种算法，而同一算法也常常会有多种实现方式，因此除了以上必须具备的基本属性，在应用环境中还需从实用的角度对不同算法及其不同版本做更为细致考量和取舍。这些细致的要求尽管应纳入软件工程的范畴，但也不失为成熟算法的重要标志。

比如其中之一就是，除一般性情况外，实用的算法还应能够处理各种极端的输入实例。仍以排序问题为例，极端情况下待排序序列的长度可能不是正数（参数n = 0甚至n < 0），或者反过来长度达到或者超过系统支持的最大值（n = INT_MAX），或者A[]中的元素不见得互异甚至全体相等，以上种种都属于所谓的退化（degeneracy）情况。算法所谓的鲁棒性（robustness），就是要求能够尽可能充分地应对此类情况。请读者自行验证，对于以上退化情况，代码1.1中bubblesort1A()算法依然可以正确返回而不致出现异常。

■ 重用性

从实用角度评判不同算法及其不同实现方式时，可采用的另一标准是：算法的总体框架能否便捷地推广至其它场合。仍以起泡排序为例。实际上，起泡算法的正确性与所处理序列中元素的类型关系不大，无论是对于float、char或其它类型，只要元素之间可以比较大小，算法的整体框架就依然可以沿用。算法模式可推广并适用于不同类型基本元素的这种特性，即是重用性的一种典型形式。很遗憾，代码1.1所实现的bubblesort1A()算法尚不满足这一要求；而稍后的第2章和第3章，将使包括起泡排序在内的各种排序算法具有这一特性。

1.1.5 算法效率

■ 可计算性

相信本书的读者已经学习并掌握了至少一种高级程序设计语言，如C、C++或Java等。学习程序设计语言的目的，在于学会如何编写合法（即合乎特定程序语言的语法）的程序，从而保证编写的程序或者能够经过编译和链接生成执行代码，或者能够由解释器解释执行。然而从通过计算有效解决实际问题的角度来看，这只是第一个层次，仅仅做到语法正确还远远不够。很遗憾，算法所应具备的更多基本性质，合法的程序并非总是自然具备。

以前面提到的有穷性为例，完全合乎语法的程序却往往未必能够满足。相信每一位编写过程序的读者都有过这样的体验：很多合法的程序可以顺利编译链接，但在实际运行的过程中却因无穷循环或递归溢出导致异常。更糟糕的是，就大量的应用问题而言，根本就不可能设计出必然终止的算法。从这个意义讲，它们都属于不可解的问题。当然，关于此类问题的界定和研究，应归入可计算性（computability）理论的范畴，本书将不予过多涉及。

■ 难解性

实际上我们不仅需要确定，算法对任何输入都能够在有穷次操作之后终止，而且更加关注该过程所需的时间。很遗憾，很多算法即便满足有穷性，但在终止之前所花费的时间成本却太高。比如，理论研究的成果显示，大量问题的最低求解时间成本，都远远超出目前实际系统所能提供的计算能力。同样地，此类难解性（*intractability*）问题，在本书中也不予过多讨论。

■ 计算效率

在“编写合法程序”这一基础之上，本书将更多地关注于非“不可解和难解”的一般性问题，并讨论如何高效率地解决这一层面的计算问题。为此，首先需要确立一种尺度，用以从时间和空间等方面度量算法的计算成本，进而依此尺度对不同算法进行比较和评判。当然，更重要的是研究和归纳算法设计与实现过程中的一般性规律与技巧，以编写出效率更高、能够处理更大规模数据的程序。这两点既是本书的基本主题，也是贯穿始终的主体脉络。

■ 数据结构

由上可知，无论是算法的初始输入、中间结果还是最终输出，在计算机中都可以数据的形式表示。对于数据的存储、组织、转移及变换等操作，不同计算模型和平台环境所支持的具体形式不尽相同，其执行效率将直接影响和决定算法的整体效率。数据结构这一学科正是以“数据”这一信息的表现形式为研究对象，旨在建立支持高效算法的数据信息处理策略、技巧与方法。要做到根据实际应用需求自如地设计、实现和选用适当的数据结构，必须首先对算法设计的技巧以及相应数据结构的特性了然于心，这些也是本书的重点与难点。

§ 1.2 复杂度度量

算法的计算成本涵盖诸多方面，为确定计算成本的度量标准，我们不妨先从计算速度这一主要因素入手。具体地，如何度量一个算法所需的计算时间呢？

1.2.1 时间复杂度

上述问题并不容易直接回答，原因在于，运行时间是由多种因素综合作用而决定的。首先，即使是同一算法，对于不同的输入所需的运行时间并不相同。以排序问题为例，输入序列的规模、其中各元素的数值以及次序均不确定，这些因素都将影响到排序算法最终的运行时间。为针对运行时间建立起一种可行、可信的评估标准，我们不得不首先考虑其中最为关键的因素。其中，问题实例的规模往往是决定计算成本的主要因素。一般地，问题规模越接近，相应的计算成本也越接近；而随着问题规模的扩大，计算成本通常也呈上升趋势。

如此，本节开头所提的问题即可转化为：随着输入规模的扩大，算法的执行时间将如何增长？执行时间的这一变化趋势可表示为输入规模的一个函数，称作该算法的时间复杂度（*time complexity*）。具体地，特定算法处理规模为 n 的问题所需的时间可记作 $T(n)$ 。

细心的读者可能注意到，根据规模并不能唯一确定具体的输入，规模相同的输入通常都有多个，而算法对其进行处理所需时间也不尽相同。仍以排序问题为例，由 n 个元素组成的输入序列有 $n!$ 种，有时所有元素都需交换，有时却无需任何交换（习题[1-3]）。故严格说来，以上定义的 $T(n)$ 并不明确。为此需要再做一次简化，即从保守估计的角度出发，在规模为 n 的所有输入中选择执行时间最长者作为 $T(n)$ ，并以 $T(n)$ 度量该算法的时间复杂度。

1.2.2 渐进复杂度

至此，对于同一问题的两个算法A和B，通过比较其时间复杂度 $T_A(n)$ 和 $T_B(n)$ ，即可评价二者对于同一输入规模 n 的计算效率高低。然而，藉此还不足以就其性能优劣做出总体性的评判，比如对于某些问题，一些算法更适用于小规模输入，而另一些则相反（习题[1-5]）。

幸运的是，在评价算法运行效率时，我们往往可以忽略其处理小规模问题时的能力差异，转而关注其在处理更大规模问题时的表现。其中的原因不难理解，小规模问题所需的处理时间本来就相对更少，故此时不同算法的实际效率差异并不明显；而在处理更大规模的问题时，效率的些许差异都将对实际执行效果产生巨大的影响。这种着眼长远、更为注重时间复杂度的总体变化趋势和增长速度的策略与方法，即所谓的渐进分析（*asymptotic analysis*）。

那么，针对足够大的输入规模 n ，算法执行时间 $T(n)$ 的渐进增长速度，应如何度量和评价呢？

■ 大 \mathcal{O} 记号

同样地出于保守的估计，我们首先关注 $T(n)$ 的渐进上界。为此可引入所谓“大 \mathcal{O} 记号”（*big- \mathcal{O} notation*）。具体地，若存在正的常数 c 和函数 $f(n)$ ，使得对任何 $n \gg 2$ 都有

$$T(n) \leq c \cdot f(n)$$

则可认为在 n 足够大之后， $f(n)$ 给出了 $T(n)$ 增长速度的一个渐进上界。此时，记之为：

$$T(n) = \mathcal{O}(f(n))$$

由这一定义，可导出大 \mathcal{O} 记号的以下性质：

- (1) 对于任一常数 $c > 0$ ，有 $\mathcal{O}(f(n)) = \mathcal{O}(c \cdot f(n))$
- (2) 对于任意常数 $a > b > 0$ ，有 $\mathcal{O}(n^a + n^b) = \mathcal{O}(n^a)$

前一性质意味着，在大 \mathcal{O} 记号的意义下，函数各项正的常系数可以忽略并等同于1。后一性质则意味着，多项式中的低次项均可忽略，只需保留最高次项。可以看出，大 \mathcal{O} 记号的这些性质的确体现了对函数总体渐进增长趋势的关注和刻画。

■ 环境差异

在实际环境中直接测得的执行时间 $T(n)$ ，虽不失为衡量算法性能的一种指标，但作为评判不同算法性能优劣的标准，其可信度值得推敲。事实上，即便是同一算法、同一输入，在不同的硬件平台上、不同的操作系统中甚至不同的时间，所需要的计算时间都不尽相同。因此，有必要按照超脱于具体硬件平台和软件环境的某一客观标准，来度量算法的时间复杂度，并进而评价不同算法的效率差异。

■ 基本操作

一种自然且可行的解决办法是，将时间复杂度理解为算法中各条指令的执行时间之和。在图灵机（*Turing Machine, TM*）和随机存取机（*Random Access Machine, RAM*）等计算模型^[4]中，指令语句均可分解为若干次基本操作，比如算术运算、比较、分支、子程序调用与返回等；而在大多数实际的计算环境中，每一次这类基本操作都可在常数时间内完成。

如此，不妨将 $T(n)$ 定义为算法所执行基本操作的总次数。也就是说， $T(n)$ 决定于组成算法的所有语句各自的执行次数，以及其中所含基本操作的数目。以代码1.1中起泡排序**bubblesort1A()**算法为例，若将该算法处理长度为 n 的序列所需的时间记作 $T(n)$ ，则按照上述分析，只需统计出该算法所执行基本操作的总次数，即可确定 $T(n)$ 的上界。

■ 起泡排序

`bubblesort1A()`算法由内、外两层循环组成。内循环从前向后，依次比较各对相邻元素，如有必要则将其交换。故在每一轮内循环中，需要扫描和比较 $n - 1$ 对元素，至多需要交换 $n - 1$ 对元素。元素的比较和交换，都属于基本操作，故每一轮内循环至多需要执行 $2(n - 1)$ 次基本操作。另外，根据1.1.4节对该算法正确性的分析结论，外循环至多执行 $n - 1$ 轮。因此，总共需要执行的基本操作不会超过 $2(n - 1)^2$ 次。若以此来度量该算法的时间复杂度，则有

$$T(n) = O(2(n-1)^2)$$

根据大 O 记号的性质，可进一步简化和整理为：

$$T(n) = O(2n^2 - 4n + 2) = O(2n^2) = O(n^2)$$

■ 最坏、最好与平均情况

由上可见，以大 O 记号形式表示的时间复杂度，实质上是对算法执行时间的一种保守估计——对于规模为 n 的任意输入，算法的运行时间都不会超过 $O(f(n))$ 。比如，“起泡排序算法复杂度 $T(n) = O(n^2)$ ”意味着，该算法处理任何序列所需的时间绝不会超过 $O(n^2)$ 。的确需要这么长计算时间的输入实例，称作最坏实例或最坏情况（**worst case**）。

需强调的是，这种保守估计并不排斥更好情况甚至最好情况（**best case**）的存在和出现。比如，对于某些输入序列，起泡排序算法的内循环的执行轮数可能少于 $n - 1$ ，甚至只需执行一轮（习题[1-3]）。当然，有时也需要考查所谓的平均情况（**average case**），也就是按照某种约定的概率分布，将规模为 n 的所有输入对应的计算时间加权平均。

比较而言，“最坏情况复杂度”是人们最为关注且使用最多的，在一些特殊的场合甚至成为唯一的指标。比如控制核电站运转、管理神经外科手术室现场的系统而言，从最好或平均角度评判算法的响应速度都不具有任何意义，在最坏情况下的响应速度才是唯一的指标。

■ 大 Ω 记号

为了对算法的复杂度最好情况做出估计，需要借助另一个记号。如果存在正的常数 c 和函数 $g(n)$ ，使得对于任何 $n \gg 2$ 都有

$$T(n) \geq c \cdot g(n)$$

就可以认为，在 n 足够大之后， $g(n)$ 给出了 $T(n)$ 的一个渐进下界。此时，我们记之为：

$$T(n) = \Omega(g(n))$$

这里的 Ω 称作“大 Ω 记号”（**big-omega notation**）。与大 O 记号恰好相反，大 Ω 记号是对算法执行效率的乐观估计——对于规模为 n 的任意输入，算法的运行时间都不低于 $\Omega(g(n))$ 。比如，即便在最好情况下，起泡排序也至少需要 $T(n) = \Omega(n)$ 的计算时间（习题[1-4]）。

■ 大 Θ 记号

借助大 O 记号、大 Ω 记号，可以对算法的时间复杂度作出定量的界定，亦即，从渐进的趋势看， $T(n)$ 介于 $\Omega(g(n))$ 与 $O(f(n))$ 之间。若恰巧出现 $g(n) = f(n)$ 的情况，则可以使用另一记号来表示。

如果存在正的常数 $c_1 < c_2$ 和函数 $h(n)$ ，使得对于任何 $n \gg 2$ 都有

$$c_1 \cdot h(n) \leq T(n) \leq c_2 \cdot h(n)$$

就可以认为在 n 足够大之后， $h(n)$ 给出了 $T(n)$ 的一个确界。此时，我们记之为：

$$T(n) = \Theta(h(n))$$

这里的 Θ 称作“大 Θ 记号”（big-theta notation），它是对算法复杂度的准确估计——对于规模为 n 的任何输入，算法的运行时间 $T(n)$ 都与 $\Theta(h(n))$ 同阶。

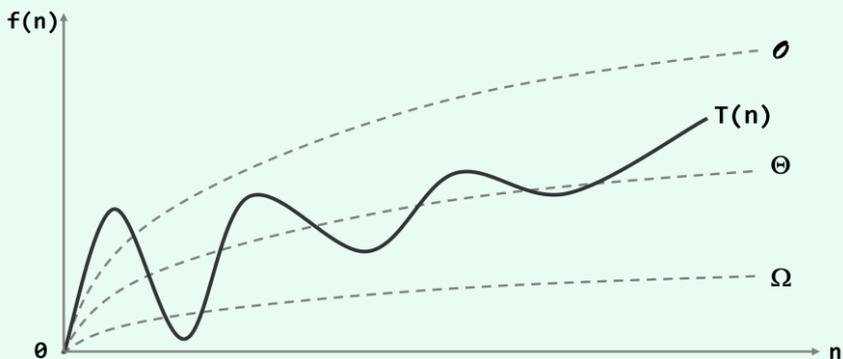


图1.4 大 O 记号、大 Ω 记号和大 Θ 记号

以上主要的这三种渐进复杂度记号之间的联系与区别，可直观地由图1.4示意。

1.2.3 空间复杂度

除了执行时间的长短，算法所需存储空间的多少也是衡量其性能的一个重要方面，此即所谓的空间复杂度（space complexity）。实际上，以上针对时间复杂度所引入的几种渐进记号，也适用于对空间复杂度的度量，其原理及方法基本相同，不再赘述。

需要注意的是，为了更为客观地评价算法性能的优劣，除非特别申明，空间复杂度通常并不计入原始输入本身所占用的空间——对于同一问题，这一指标对任何算法都是相同的。反之，其它（如转储、中转、索引、映射、缓冲等）各个方面所消耗的空间，则都应计入。

另外，很多时候我们都是更多地甚至仅仅关注于算法的时间复杂度，而不必对空间复杂度做专门的考查。这种简便评测方式的依据，来自于以下事实：就渐进复杂度的意义而言，在任一算法的任何一次运行过程中所消耗的存储空间，都不会多于其间所执行基本操作的累计次数。

实际上根据定义，每次基本操作所涉及的存储空间，都不会超过常数规模；纵然每次基本操作所占用或访问的存储空间都是新开辟的，整个算法所需的空间总量，也不过与基本操作的次数同阶。从这个意义上说，时间复杂度本身就是空间复杂度的一个天然的上界。

当然，对空间复杂度的分析也有其自身的意义，尤其在对空间效率非常在乎的应用场合中，或当问题的输入规模极为庞大时，由时间复杂度所确立的平凡上界已经难以令人满意。这类情况下，人们将更为精细地考查不同算法的空间效率，并尽力在此方面不断优化。本书的后续章节，将结合一些实际问题介绍相关的方法与技巧。

§ 1.3 复杂度分析

在明确了算法复杂度的度量标准之后，如何分析具体算法的复杂度呢？1.2.2节所引入的三种记号中，大 O 记号是最基本的，也是最常用到的。从渐进分析的角度，大 O 记号将各算法的复杂度由低到高划分为若干层次级别。以下依次介绍若干典型的复杂度级别，并介绍主要的分析方法与技巧。读者可参照以下介绍的方法，做进一步的练习（习题[1-30]和[1-32]）。

1.3.1 常数 $O(1)$

■ 问题与算法

考查如下常规元素的选取问题，该问题一种解法如算法1.3所示。

```
ordinaryElement(S[], n) //从 $n \geq 3$ 个互异整数中，除最大、最小者以外，任取一个“常规元素”
    任取三个元素 $x, y, z \in S$ ; //这三个元素亦必互异
    通过比较，对它们做排序; //设经排序后，依次重命名为： $a < b < c$ 
    输出 $b$ ;
```

算法1.3 取非极端元素

该算法的正确性不言而喻，但它需要运行多少时间？与输入的规模 n 有何联系？

■ 复杂度

既然 S 是有限集，故其中的最大、最小元素各有且仅有一个。因此，无论 S 的规模有多大，在任意三个元素中至少都有一个是非极端元素。不妨取前三个元素 $x = S[0]$ 、 $y = S[1]$ 和 $z = S[2]$ ，这一步只需执行三次（从特定单元读取元素的）基本操作，耗费 $O(3)$ 时间。接下来，为确定这三个元素的大小次序，最多需要做三次比较（习题[2-37]），也需 $O(3)$ 时间。最后，输出居中的非极端元素只需 $O(1)$ 时间。因此综合起来，算法1.3的运行时间为：

$$T(n) = O(3) + O(3) + O(1) = O(7) = O(1)$$

运行时间可表示和度量为 $T(n) = O(1)$ 的这一类算法，统称作“常数时间复杂度算法”（constant-time algorithm）。此类算法已是最为理想的，因为不可能奢望“不劳而获”。

一般地，仅含一次或常数次基本操作的算法（如算法1.1和算法1.2）均属此类。此类算法通常不含循环、分支、子程序调用等，但也不能仅凭语法结构的表面形式一概而论（习题[1-7]）。

采用1.2.3节的分析方法不难看出，除了输入数组等参数之外，该算法仅需常数规模的辅助空间。此类仅需 $O(1)$ 辅助空间的算法，亦称作就地算法（in-place algorithm）。

1.3.2 对数 $O(\log n)$

■ 问题与算法

考查如下问题：对于任意非负整数，统计其二进制展开中数位1的总数。

该问题的一个算法可实现如代码1.2所示。

该算法使用一个计数器ones记录数位1的数目，其初始值为0。随后进入一个循环：通过二进制的与（and）运算，检查 n 的二进制展开的最低位，若该位为1则累计至ones。由于每次循环都将 n 的二进制展开右移一位，故整体效果等同于逐个检验所有数位是否为1，该算法的正确性也不难由此得证。

以 $n = 441_{(10)} = 110111001_{(2)}$ 为例，采用以上算法，变量 n 与计数器ones在计算过程中的演变过程如表1.1所示。

表1.1 countOnes(441)的执行过程

十进制	二进制	数位1计数
441	110111001	0
220	11011100	1
110	1101110	1
55	110111	1
27	11011	2
13	1101	3
6	110	4
3	11	4
1	1	5
0	0	6

```

1 int countOnes(unsigned int n) { //统计整数n的二进制展开中数位1的总数:  $O(\log n)$ 
2     int ones = 0; //计数器复位
3     while (0 < n) { //在n缩减至0之前,反复地
4         ones += (1 & n); //检查最低位,若为1则计数
5         n >>= 1; //右移一位
6     }
7     return ones; //返回计数
8 } //等效于glibc的内置函数int __builtin_popcount (unsigned int n)

```

代码1.2 整数二进制展开中数位1总数的统计

■ 复杂度

根据右移运算的性质,每右移一位, n 都至少缩减一半。也就是说,至多经过 $1 + \lfloor \log_2 n \rfloor$ 次循环, n 必然缩减至0,从而算法终止。实际上从另一角度来看, $1 + \lfloor \log_2 n \rfloor$ 恰为 n 二进制展开的总位数,每次循环都将其右移一位,总的循环次数自然也应是 $1 + \lfloor \log_2 n \rfloor$ 。后一解释,也可以从表1.1中 n 的二进制展开一列清晰地看出。

无论是该循环体之前、之内还是之后,均只涉及常数次(逻辑判断、位与运算、加法、右移等)基本操作。因此,`countOnes()`算法的执行时间主要由循环的次数决定,亦即:

$$O(1 + \lfloor \log_2 n \rfloor) = O(\lfloor \log_2 n \rfloor) = O(\log_2 n)$$

由大 O 记号定义,在用函数 $\log_r n$ 界定渐进复杂度时,常底数 r 的具体取值无所谓(习题[1-8]),故通常不予专门标出而笼统地记作 $\log n$ 。比如,尽管此处底数为常数2,却可直接记作 $O(\log n)$ 。此类算法称作具有“对数时间复杂度”(logarithmic-time algorithm)。

实际上,代码1.2中的`countOnes()`算法仍有巨大的改进余地(习题[1-12])。

■ 对数多项式复杂度

更一般地,凡运行时间可以表示和度量为 $T(n) = O(\log^c n)$ 形式的这一类算法(其中常数 $c > 0$),均统称作“对数多项式时间复杂度的算法”(polylogarithmic-time algorithm)。上述 $O(\log n)$ 即 $c = 1$ 的特例。此类算法的效率虽不如常数复杂度算法理想,但从多项式的角度看仍能无限接近于后者(习题[1-9]),故也是极为高效的一类算法。

1.3.3 线性 $O(n)$

■ 问题与算法

考查如下问题:计算给定 n 个整数的总和。该问题可由代码1.3中的算法`sumI()`解决。

```

1 int sumI(int A[], int n) { //数组求和算法(迭代版)
2     int sum = 0; //初始化累加器,  $O(1)$ 
3     for (int i = 0; i < n; i++) //对全部共 $O(n)$ 个元素,逐一
4         sum += A[i]; //累计,  $O(1)$ 
5     return sum; //返回累加值,  $O(1)$ 
6 } // $O(1) + O(n) \cdot O(1) + O(1) = O(n+2) = O(n)$ 

```

代码1.3 数组元素求和算法sumI()

■ 复杂度

`sumI()`算法的正确性一目了然，它需要运行多少时间呢？

首先，对`s`的初始化需要 $O(1)$ 时间。算法的主体部分是一个循环，每一轮循环中只需进行一次累加运算，这属于基本操作，可在 $O(1)$ 时间内完成。每经过一轮循环，都将一个元素累加至`s`，故总共需要做 n 轮循环，于是该算法的运行时间应为：

$$O(1) + O(1) \times n = O(n + 1) = O(n)$$

凡运行时间可以表示和度量为 $T(n) = O(n)$ 形式的这一类算法，均统称作“线性时间复杂度算法”（**linear-time algorithm**）。比如，算法1.2只需略加修改，即可解决“ n 等分给定线段”问题，这个通用版本相对于输入 n 就是一个线性时间复杂度的算法。

也就是说，对于输入的每一单元，此类算法平均消耗常数时间。就大多数问题而言，在对输入的每一单元均至少访问一次之前，不可能得出解答。以数组求和为例，在尚未得知每一元素的具体数值之前，绝不可能确定其总和。故就此意义而言，此类算法的效率亦足以令人满意。

1.3.4 多项式 $O(\text{polynomial}(n))$

若运行时间可以表示和度量为 $T(n) = O(f(n))$ 的形式，而且 $f(x)$ 为多项式，则对应的算法称作“多项式时间复杂度算法”（**polynomial-time algorithm**）。比如根据1.2.2节的分析，1.1.3节所实现起泡排序`bubblesort1A()`算法的时间复杂度应为 $T(n) = O(n^2)$ ，故该算法即属于此类。当然，以上所介绍的线性时间复杂度算法，也属于多项式时间复杂度算法的特例，其中线性多项式 $f(n) = n$ 的次数为1。

在算法复杂度理论中，多项式时间复杂度被视作一个具有特殊意义的复杂度级别。多项式级的运行时间成本，在实际应用中一般被认为是可接受的或可忍受的。某问题若存在一个复杂度在此范围以内的算法，则称该问题是可有效求解的或易解的（**tractable**）。

请注意，这里仅要求多项式的次数为一个正的常数，而并未对其最大取值范围设置任何具体上限，故实际上该复杂度级别涵盖了很大的一类算法。比如，从理论上讲，复杂度分别为 $O(n^2)$ 和 $O(n^{2012})$ 算法都同属此类，尽管二者实际的计算效率有天壤之别。之所以如此，是因为相对于以下的指数级复杂度，二者之间不超过多项式规模的差异只是小巫见大巫。

1.3.5 指数 $O(2^n)$

■ 问题与算法

考查如下问题：在禁止超过1位的移位运算的前提下，对任意非负整数 n ，计算 2^n 。

```

1 __int64 power2BF_I(int n) { //幂函数 $2^n$ 算法（蛮力迭代版）， $n \geq 0$ 
2   __int64 pow = 1; // $O(1)$ ：累积器初始化为 $2^0$ 
3   while (0 < n --) // $O(n)$ ：迭代 $n$ 轮，每轮都
4     pow <<= 1; // $O(1)$ ：将累积器翻倍
5   return pow; // $O(1)$ ：返回累积器
6 } // $O(n) = O(2^r)$ ， $r$ 为输入指数 $n$ 的比特位数

```

代码1.4 幂函数算法（蛮力迭代版）

■ 复杂度

如代码1.4所示的算法power2BF_I()由n轮迭代组成，各需做一次累乘和一次递减，均属于基本操作，故整个算法共需 $\mathcal{O}(n)$ 时间。若以输入指数n的二进制位数 $r = 1 + \lfloor \log_2 n \rfloor$ 作为输入规模，则运行时间为 $\mathcal{O}(2^r)$ 。稍后在1.4.3节我们将看到，该算法仍有巨大的改进余地。

一般地，凡运行时间可以表示和度量为 $T(n) = \mathcal{O}(a^n)$ 形式的算法 ($a > 1$)，均属于“指数时间复杂度算法” (exponential-time algorithm)。

■ 从多项式到指数

从常数、对数、线性、平方到多项式时间复杂度，算法效率的差异还在可接受的范围。然而，在多项式与指数时间复杂度之间，却有着—道巨大的鸿沟。当问题规模较大后，指数复杂度算法的实际效率将急剧下降，计算时间之长很快就会达到令人难以忍受的地步。因此通常认为，指数复杂度算法无法真正应用于实际问题中，它们不是有效算法，甚至不能称作算法。相应地，不存在多项式复杂度算法的问题，也称作难解的 (intractable) 问题。

需注意的是，在问题规模不大时，指数复杂度反而可能在较长一段区间内均低于多项式复杂度。比如，在 $1 \leq n \leq 116,690$ 以内，指数复杂度 1.0001^n 反而低于多项式复杂度 $n^{1.0001}$ ；但前者迟早必然超越后者，且随着n的进一步增大，二者的差距无法保持在多项式倍的范围。因此，从渐进复杂度的角度看，多项式与指数是无法等量齐观的两个截然不同的量级。

实际上很遗憾，绝大多数计算问题并不存在多项式时间的算法 (习题[1-16]、[1-23]和[1-27])，也就是说，试图求解此类问题的任一算法，都至少需要运行指数量级的时间。特别地，很多问题甚至需要无穷的时间，由于有穷性不能满足或者尚未得到证明 (习题[1-29])，也可以说不存在解决这些问题的算法。不过，这类问题均不属于本书的讨论范围。

1.3.6 复杂度层次

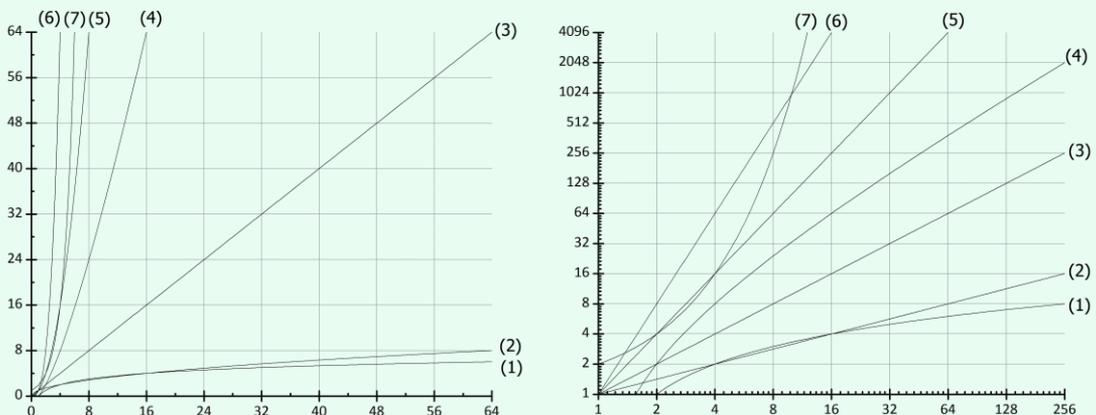


图1.5 复杂度的典型层次：(1)~(7)依次为 $\mathcal{O}(\log n)$ 、 $\mathcal{O}(\sqrt{n})$ 、 $\mathcal{O}(n)$ 、 $\mathcal{O}(n \log n)$ 、 $\mathcal{O}(n^2)$ 、 $\mathcal{O}(n^3)$ 和 $\mathcal{O}(2^n)$

利用大 \mathcal{O} 记号，不仅可以定量地把握算法复杂度的主要部分，而且可以定性地从低至高将复杂度划分为若干层次。典型的复杂度层次包括 $\mathcal{O}(1)$ 、 $\mathcal{O}(\log^* n)$ 、 $\mathcal{O}(\log \log n)$ 、 $\mathcal{O}(\log n)$ 、 $\mathcal{O}(\sqrt{n})$ 、 $\mathcal{O}(n)$ 、 $\mathcal{O}(n \log^* n)$ 、 $\mathcal{O}(n \log \log n)$ 、 $\mathcal{O}(n \log n)$ 、 $\mathcal{O}(n^2)$ 、 $\mathcal{O}(n^3)$ 、 $\mathcal{O}(n^c)$ 、 $\mathcal{O}(2^n)$ 等，图1.5绘出了其中七个层次复杂度函数对应的渐进增长趋势。

请注意，在图1.5的左图中，层次(7)的 2^n 显得比层次(6)的 n^3 更低，但这只是在问题规模 n 较小时的暂时现象。从覆盖更大范围的右图可以看出，当问题规模不小于10之后，层次(7)的复杂度将远远高于层次(6)。另外，右图还采用了双对数坐标，将层次(6)、(5)、(3)和(2)表示为直线，从而更为清晰地显示出各层次之间的高低关系。

1.3.7 输入规模

对算法复杂度的界定，都是相对于问题的输入规模而言的。然而，细心的读者可能已经注意到，不同的人在不同场合下关于“输入规模”的理解、定义和度量可能不尽相同，因此也可能导致复杂度分析的结论有所差异。比如，1.3.2节中关于“countOnes()算法的复杂度为 $\mathcal{O}(\log n)$ ”的结论，是相对于输入整数本身的数值 n 而言；而若以 n 二进制展开的宽度 $r = 1 + \lfloor \log_2 n \rfloor$ 作为输入规模，则应为线性复杂度 $\mathcal{O}(r)$ 。再如，1.3.5节中关于“power2BF_I()算法的复杂度为 $\mathcal{O}(2^r)$ ”的结论，是相对于输入指数 n 的二进制数位 r 而言；而若以 n 本身的数值作为输入规模，却应为线性复杂度 $\mathcal{O}(n)$ 。

严格地说，所谓待计算问题的输入规模，应严格定义为“用以描述输入所需的空间规模”。因此就上述两个例子而言，将输入参数 n 二进制展开的宽度 r 作为输入规模更为合理。也就是说，将这两个算法的复杂度界定为 $\mathcal{O}(r)$ 和 $\mathcal{O}(2^r)$ 更妥。对应地，以输入参数 n 本身的数值作为基准而得出的 $\mathcal{O}(\log n)$ 和 $\mathcal{O}(n)$ 复杂度，则应分别称作伪对数的（pseudo-logarithmic）和伪线性的（pseudo-linear）复杂度。

§ 1.4 *递归

分支转向是算法的灵魂；函数和过程及其之间的相互调用，是在经过抽象和封装之后，实现分支转向的一种重要机制；而递归则是函数和过程调用的一种特殊形式，即允许函数和过程进行自我调用。因其高度的抽象性和简洁性，递归已成为多数高级程序语言普遍支持的一项重要特性。比如在C++语言中，递归调用（recursive call）就是某一方法调用自身。这种自我调用通常是直接的，即在函数体中包含一条或多条调用自身的语句。递归也可能以间接的形式出现，即某个方法首先调用其它方法，再辗转通过其它方法的相互调用，最终调用起始的方法自身。

递归的价值在于，许多应用问题都可简洁而准确地描述为递归形式。以操作系统为例，多数文件系统的目录结构都是递归定义的。具体地，每个文件系统都有一个最顶层的目录，其中可以包含若干文件和下一层的子目录；而在每一子目录中，也同样可能包含若干文件和再下一层的子目录；如此递推，直至不含任何下层的子目录。通过如此的递归定义，文件系统目录就可以根据实际应用的需要嵌套任意多层（只要系统的存储资源足以支持）。

递归也是一种基本而典型的算法设计模式。这一模式可以对实际问题中反复出现的结构和形式做高度概括，并从本质层面加以描述与刻画，进而导出高效的算法。从程序结构的角度看，递归模式能够统筹纷繁多变的具体情况，避免复杂的分支以及嵌套的循环，从而更为简明地描述和实现算法，减少代码量，提高算法的可读性，保证算法的整体效率。

以下将从递归的基本模式入手，循序渐进地介绍如何选择和应用（线性递归、二分递归和多分支递归等）不同的递归形式，以实现（遍历、分治等）算法策略，以及如何利用递归跟踪和递推方程等方法分析递归算法的复杂度。

1.4.1 线性递归

■ 数组求和

仍以1.3.3节的数组求和问题为例。易见，若 $n = 0$ 则总和必为 0 ，这也是最终的平凡情况；否则一般地，总和可理解为前 $n - 1$ 个整数 ($A[0, n - 1]$) 之和，再加上末元素 ($A[n - 1]$)。按这一思路，可基于线性递归模式，设计出另一`sum()`算法如代码1.5所示。

```

1 int sum(int A[], int n) { //数组求和算法 (线性递归版)
2     if (1 > n) //平凡情况, 递归基
3         return 0; //直接 (非递归式) 计算
4     else //一般情况
5         return sum(A, n - 1) + A[n - 1]; //递归: 前n - 1项之和, 再累计第n - 1项
6 } //O(1)*递归深度 = O(1)*(n + 1) = O(n)

```

代码1.5 数组求和算法 (线性递归版)

由此实例，可以看出保证递归算法有穷性的基本技巧：首先判断并处理 $n = 0$ 之类的平凡情况，以免因无限递归而导致系统溢出。这类平凡情况统称“递归基” (base case of recursion)。平凡情况可能有多种，但至少要有有一种（比如此处），且迟早必然会出现。

■ 线性递归

算法`sum()`可能朝着更深一层进行自我调用，且每一递归实例对自身的调用至多一次。于是，每一层次上至多只有一个实例，且它们构成一个线性的次序关系。此类递归模式因而称作“线性递归” (linear recursion)，它也是递归的最基本形式。

这种形式中，应用问题总可分解为两个独立的子问题：其一对应于单独的某个元素，故可直接求解（比如 $A[n - 1]$ ）；另一个对应于剩余部分，且其结构与原问题相同（比如 $A[0, n - 1]$ ）。另外，子问题的解经简单的合并（比如整数相加）之后，即可得到原问题的解。

■ 减而治之

线性递归的模式，往往对应于所谓减而治之 (decrease-and-conquer) 的算法策略：递归每深入一层，待求解问题的规模都缩减一个常数，直至最终蜕化为平凡的小（简单）问题。

按照减而治之策略，此处随着递归的深入，调用参数将单调地线性递减。因此无论最初输入的 n 有多大，递归调用的总次数都是有限的，故算法的执行迟早会终止，即满足有穷性。当抵达递归基时，算法将执行非递归的计算（这里是返回 0 ）。

1.4.2 递归分析

递归算法时间和空间复杂度的分析与常规算法很不一样，有其自身的规律和特定的技巧，以下介绍递归跟踪与递推方程这两种主要的方法。

■ 递归跟踪

作为一种直观且可视的方法，递归跟踪 (recursion trace) 可用以分析递归算法的总体运行时间与空间。具体地，就是按照以下原则，将递归算法的执行过程整理为图的形式：

- ① 算法的每一递归实例都表示为一个方框，其中注明了该实例调用的参数
- ② 若实例 M 调用实例 N ，则在 M 与 N 对应的方框之间添加一条有向联线

按上述约定，代码1.5中sum()算法的递归跟踪如图1.6所示。其中，sum()算法的每一递归实例分别对应于一个方框，并标有相应的调用参数。每发生一次递归调用，就从当前实例向下引出一条有向边，指向下层对应于新实例的方框。

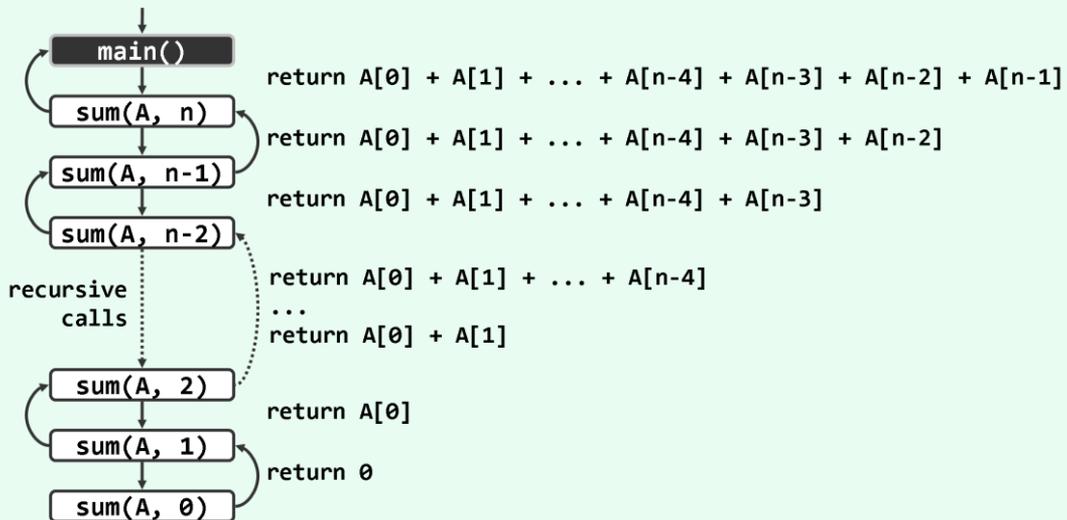


图1.6 对sum(A, 5)的递归跟踪分析

该图清晰地给出了算法执行的整个过程：首先对参数n进行调用，再转向对参数n - 1的调用，再转向对参数n - 2的调用，...，直至最终的参数0。在抵达递归基后不再递归，而是将平凡的解（长度为0数组的总和0）返回给对参数1的调用；累加上A[0]之后，再返回给对参数2的调用；累加上A[1]之后，继续返回给对参数3的调用；...；如此依次返回，直到最终返回给对参数n的调用，此时，只需累加A[n - 1]即得到整个数组的总和。

从图1.6可清楚地看出，整个算法所需的计算时间，应该等于所有递归实例的创建、执行和销毁所需的时间总和。其中，递归实例的创建、销毁均由操作系统负责完成，其对应的时间成本通常可以近似为常数，不会超过递归实例中实质计算步骤所需的时间成本，故往往均予忽略。为便于估算，启动各实例的每一条递归调用语句所需的时间，也可以计入被创建的递归实例的账上，如此我们只需统计各递归实例中非递归调用部分所需的时间。

具体地，就以上的sum()算法而言，每一递归实例中非递归部分所涉及的计算无非三类（判断n是否为0、累加sum(n - 1)与A[n - 1]、返回当前总和），且至多各执行一次。鉴于它们均属于基本操作，每个递归实例实际所需的计算时间都应为常数 $O(3)$ 。由图1.6还可以看出，对于长度为n的输入数组，递归深度应为n + 1，故整个sum()算法的运行时间为：

$$(n + 1) \times O(3) = O(n)$$

那么，sum()算法的空间复杂度又是多少呢？由图1.6不难看出，在创建了最后一个递归实例（即到达递归基）时，占用的空间量达到最大——准确地说，等于所有递归实例各自所占空间量的总和。这里每一递归实例所需存放的数据，无非是调用参数（数组A的起始地址和长度n）以及用于累加总和的临时变量。这些数据各自只需常数规模的空间，其总量也应为常数。故此可知，sum()算法的空间复杂度线性正比于其递归的深度，亦即 $O(n)$ 。

■ 递推方程

递归算法的另一常用分析方法，即递推方程（recurrence equation）法。与递归跟踪分析相反，该方法无需绘出具体的调用过程，而是通过对递归模式的数学归纳，导出复杂度定界函数的递推方程（组）及其边界条件，从而将复杂度的分析，转化为递归方程（组）的求解。

在总体思路，该方法与微分方程法颇为相似：很多复杂函数的显式表示通常不易直接获得，但是它们的微分形式却往往遵循某些相对简洁的规律，通过求解描述这些规律的一组微分方程，即可最终导出原函数的显式表示。微分方程的解通常并不唯一，除非给定足够多的边界条件。类似地，为使复杂度定界函数的递推方程能够给出确定的解，也需要给定某些边界条件。以下我们将看到，这类边界条件往往可以通过对递归基的分析而获得。

仍以代码1.5 中线性递归版sum()算法为例，将该算法处理长度为n的数组所需的时间成本记作T(n)。我们将该算法的思路重新表述如下：为解决问题sum(A, n)，需递归地解决问题sum(A, n - 1)，然后累加上A[n - 1]。按照这一新的理解，求解sum(A, n)所需的时间，应该等于求解sum(A, n - 1)所需的时间，另加一次整数加法运算所需的时间。

根据以上分析，可以得到关于T(n)的如下一般性的递推关系：

$$T(n) = T(n - 1) + \mathcal{O}(1) = T(n - 1) + c_1, \quad \text{其中 } c_1 \text{ 为常数}$$

另一方面，当递归过程抵达递归基时，求解平凡问题sum(A, 0)只需（用于直接返回0的）常数时间。如此，即可获得如下边界条件：

$$T(0) = \mathcal{O}(1) = c_2, \quad \text{其中 } c_2 \text{ 为常数}$$

联立以上两个方程，最终可以解得：

$$T(n) = c_1 n + c_2 = \mathcal{O}(n)$$

这一结论与递归跟踪分析殊途同归。

另外，运用以上方法，同样也可以界定sum()算法的空间复杂度（习题[1-18]）。

1.4.3 递归模式

■ 多递归基

为保证有穷性，递归算法都必须设置递归基，且确保总能执行到。为此，针对每一类可能出现的平凡情况，都需设置对应的递归基，故同一算法的递归基可能（显式或隐式地）不止一个。

以下考查数组倒置问题，也就是将数组中各元素的次序前后翻转。比如，若输入数组为：

$$A[] = \{ 3, 1, 4, 1, 5, 9, 2, 6 \}$$

则倒置后为：

$$A[] = \{ 6, 2, 9, 5, 1, 4, 1, 3 \}$$

这里先介绍该问题的一个递归版算法，1.4.4节还将介绍另一等效的迭代版算法。无论何种实现，均由如下reverse()函数作为统一的启动入口。

```
1 void reverse(int*, int, int); //重载的倒置算法原型
2 void reverse(int* A, int n) //数组倒置（算法的初始入口，调用的可能是reverse()的递归版或迭代版）
3 { reverse(A, 0, n - 1); } //由重载的入口启动递归或迭代算法
```

代码1.6 数组倒置算法的统一入口

借助线性递归不难解决这一问题,为此只需注意到并利用如下事实:为得到整个数组的倒置,可以先对其首、末元素,然后递归地倒置除这两个元素以外的部分。按照这一思路,可实现如代码1.7所示的算法。通过递归跟踪可以证明(习题[1-31]),其时间复杂度为 $O(n)$ 。

```

1 void reverse(int* A, int lo, int hi) { //数组倒置(多递归基递归版)
2     if (lo < hi) {
3         swap(A[lo], A[hi]); //交换A[lo]和A[hi]
4         reverse(A, lo + 1, hi - 1); //递归倒置A(lo, hi)
5     } //else隐含了两种递归基
6 } //O(hi - lo + 1)

```

代码1.7 数组倒置的递归算法

■ 实现递归

在设计递归算法时,往往需要从多个角度反复尝试,方能确定对问题的输入及其规模的最佳划分方式。有时,还可能需要从不同的角度重新定义和描述原问题,使得经分解所得的子问题与原问题具有相同的语义形式。

例如,在代码1.7线性递归版reverse()算法中,通过引入参数lo和hi,使得对全数组以及其后各子数组的递归调用都统一为相同的语法形式。另外,还利用C++的函数重载(overload)机制定义了名称相同、参数表有别的另一函数reverse(A, n),作为统一的初始入口。

■ 多向递归

递归算法中,不仅递归基可能有多个,递归调用也可能有多种可供选择的分支。以下的简单实例中,每一递归实例虽有多个可能的递归方向,但只能从中选择其一,故各层次上的递归实例依然构成一个线性次序关系,这种情况依然属于线性递归。至于一个递归实例可能执行多次递归调用的情况,稍后将于1.4.5节再做介绍。

再次讨论1.3.5节中,计算幂函数 $\text{power}(2, n) = 2^n$ 的问题。按照线性递归的构思,该函数可以重新定义和表述如下:

$$\text{power2}(n) = \begin{cases} 1 & (\text{若 } n = 0) \\ 2 \cdot \text{power2}(n-1) & (\text{否则}) \end{cases}$$

由此不难直接导出一个线性递归的算法,其复杂度与代码1.4中蛮力的power2BF_I()算法完全一样,总共需要做 $O(n)$ 次递归调用(习题[1-13])。但实际上,若能从其它角度分析该函数并给出新的递归定义,完全可以更为快速地完成幂函数的计算。以下就是一例:

$$\text{power2}(n) = \begin{cases} 1 & (\text{若 } n = 0) \\ \text{power2}(\lfloor n/2 \rfloor)^2 \times 2 & (\text{若 } n > 0 \text{ 且为奇数}) \\ \text{power2}(\lfloor n/2 \rfloor)^2 & (\text{若 } n > 0 \text{ 且为偶数}) \end{cases}$$

按照这一新的表述和理解,可按二进制展开n之后的各比特位,通过反复的平方运算和加倍运算得到 $\text{power2}(n)$ 。比如:

$$\begin{aligned} 2^1 &= 2^{001}_{(2)} = (2^{2^2})^0 \times (2^2)^0 \times 2^1 = (((1 \times 2^0)^2 \times 2^0)^2 \times 2^1) \\ 2^2 &= 2^{010}_{(2)} = (2^{2^2})^0 \times (2^2)^1 \times 2^0 = (((1 \times 2^0)^2 \times 2^1)^2 \times 2^0) \\ 2^3 &= 2^{011}_{(2)} = (2^{2^2})^0 \times (2^2)^1 \times 2^1 = (((1 \times 2^0)^2 \times 2^1)^2 \times 2^1) \end{aligned}$$

$$\begin{aligned}
2^4 &= 2^{100}_{(2)} = (2^{2^2})^1 \times (2^2)^0 \times 2^0 = (((1 \times 2^1)^2 \times 2^0)^2 \times 2^0) \\
2^5 &= 2^{101}_{(2)} = (2^{2^2})^1 \times (2^2)^0 \times 2^1 = (((1 \times 2^1)^2 \times 2^0)^2 \times 2^1) \\
2^6 &= 2^{110}_{(2)} = (2^{2^2})^1 \times (2^2)^1 \times 2^0 = (((1 \times 2^1)^2 \times 2^1)^2 \times 2^0) \\
2^7 &= 2^{111}_{(2)} = (2^{2^2})^1 \times (2^2)^1 \times 2^1 = (((1 \times 2^1)^2 \times 2^1)^2 \times 2^1) \\
&\dots
\end{aligned}$$

一般地，若 n 的二进制展开式为 $b_1b_2b_3\dots b_k$ ，则有

$$2^n = (\dots(((1 \times 2^{b_1})^2 \times 2^{b_2})^2 \times 2^{b_3})^2 \dots \times 2^{b_k})$$

若 n_{k-1} 和 n_k 的二进制展开式分别为 $b_1b_2\dots b_{k-1}$ 和 $b_1b_2\dots b_{k-1}b_k$ ，则有

$$2^{n_k} = (2^{n_{k-1}})^2 \times 2^{b_k}$$

由此可以归纳得出如下递推式：

$$\text{power2}(n_k) = \begin{cases} \text{power2}(n_{k-1})^2 \times 2 & (\text{若 } b_k = 1) \\ \text{power2}(n_{k-1})^2 & (\text{若 } b_k = 0) \end{cases}$$

基于这一递推式，即可如代码1.8所示，实现幂函数的多向递归版本`power2()`：

```

1 inline __int64 sqr(__int64 a) { return a * a; }
2 __int64 power2(int n) { //幂函数2^n算法 (优化递归版), n >= 0
3     if (0 == n) return 1; //递归基
4     return (n & 1) ? sqr(power2(n >> 1)) << 1 : sqr(power2(n >> 1)); //视n的奇偶分别递归
5 } //O(logn) = O(r), r为输入指数n的比特位数

```

代码1.8 优化的幂函数算法 (线性递归版)

针对输入参数 n 为奇数或偶数的两种可能，这里分别设有不同的递归方向。尽管如此，每个递归实例都只能沿其中的一个方向深入到下层递归，整个算法的递归跟踪分析图的拓扑结构仍然与图1.6类似，故依然属于线性递归。可以证明（习题[1-31]），该算法的时间复杂度为：

$$O(\log n) \times O(1) = O(r)$$

与此前代码1.4中蛮力版本的 $O(n) = O(2^r)$ 相比，计算效率得到了极大提高。

1.4.4 递归消除

由上可见，按照递归的思想可使我们得以从宏观上理解和把握应用问题的实质，深入挖掘和洞悉算法过程的主要矛盾和一般性模式，并最终设计和编写出简洁优美且精确紧凑的算法。然而，递归模式并非十全十美，其众多优点的背后也隐含着某些代价。

■ 空间成本

首先，从递归跟踪分析的角度不难看出，递归算法所消耗的空间量主要取决于递归深度（习题[1-17]），故较之同一算法的迭代版，递归版往往需耗费更多空间，并进而影响实际的运行速度。另外，就操作系统而言，为实现递归调用需要花费大量额外的时间以创建、维护和销毁各递归实例，这些也会令计算的负担雪上加霜。有鉴于此，在对运行速度要求极高、存储空间需精打细算的场合，往往应将递归算法改写成等价的非递归版本。

一般的转换思路，无非是利用栈结构（第4章）模拟操作系统的工作过程。这类的通用方法已超出本书的范围，以下仅针对一种简单而常见的情况，略作介绍。

■ 尾递归及其消除

在线性递归算法中，若递归调用在递归实例中恰好以最后一步操作的形式出现，则称作尾递归（tail recursion）。比如代码1.7中reverse(A, lo, hi)算法的最后一步操作，是对去除了首、末元素之后总长缩减两个单元的子数组进行递归倒置，即属于典型的尾递归。实际上，属于尾递归形式的算法，均可以简捷地转换为等效的迭代版本。

仍以代码1.7中reverse(A, lo, hi)算法为例。如代码1.9所示，首先在起始位置插入一个跳转标志next，然后将尾递归语句调用替换为一条指向next标志的跳转语句。

```
1 void reverse(int* A, int lo, int hi) { //数组倒置（直接改造而得的迭代版）
2 next: //算法起始位置添加跳转标志
3     if (lo < hi) {
4         swap(A[lo], A[hi]); //交换A[lo]和A[hi]
5         lo++; hi--; //收缩待倒置区间
6         goto next; //跳转至算法体的起始位置，迭代地倒置A(lo, hi)
7     } //else隐含了迭代的终止
8 } //O(hi - lo + 1)
```

代码1.9 由递归版改造而得的数组倒置算法（迭代版）

新的迭代版与原递归版功能等效，但其中使用的goto语句有悖于结构化程序设计的原则。这一语句虽仍不得不被C++等高级语言保留，但最好还是尽力回避。为此可如代码1.10所示，将next标志与if判断综合考查，并代之以一条逻辑条件等价的while语句。

```
1 void reverse(int* A, int lo, int hi) { //数组倒置（规范整理之后的迭代版）
2     while (lo < hi) //用while替换跳转标志和if，完全等效
3         swap(A[lo++], A[hi--]); //交换A[lo]和A[hi]，收缩待倒置区间
4 } //O(hi - lo + 1)
```

代码1.10 进一步调整代码1.9的结构，消除goto语句

请注意，尾递归的判断应依据对算法实际执行过程的分析，而不仅仅是算法外在的语法形式。比如，递归语句出现在代码体的最后一行，并不见得就是尾递归；严格地说，只有当该算法（除平凡递归基外）任一实例都终止于这一递归调用时，才属于尾递归。以代码1.5中线性递归版sum()算法为例，尽管从表面看似最后一行是递归调用，但实际上却并非尾递归——实质的最后一次操作是加法运算。有趣的是，此类算法的非递归化转换方法仍与尾递归如出一辙，相信读者不难将其改写为类似于代码1.3中sumI()算法的迭代版本。

1.4.5 二分递归

■ 分而治之

面对输入规模庞大的应用问题，每每感慨于头绪纷杂而无从下手的你，不妨从先哲孙子的名言中获取灵感——“凡治众如治寡，分数是也”。是的，解决此类问题的有效方法之一，就是将其分解为若干规模更小的子问题，再通过递归机制分别求解。这种分解持续进行，直到子问题规模缩减至平凡情况。这也就是所谓的分而治之（divide-and-conquer）策略。

与减而治之策略一样，这里也要求对原问题重新表述，以保证子问题与原问题在接口形式上的一致。既然每一递归实例都可能做多次递归，故称作“多路递归”（multi-way recursion）。通常都是将原问题一分为二，故称作“二分递归”（binary recursion）。需强调的是，无论是分解为两个还是更大常数个子问题，对算法总体的渐进复杂度并无实质影响。

■ 数组求和

以下就采用分而治之的策略，按照二分递归的模式再次解决数组求和问题。新算法的思路是：以居中的元素为界将数组一分为二；递归地对子数组分别求和；最后，子数组之和相加即为原数组的总和。具体过程可描述如代码1.11，算法入口的调用形式为`sum(A, 0, n)`。

```

1 int sum(int A[], int lo, int hi) { //数组求和算法（二分递归版，入口为sum(A, 0, n - 1)）
2   if (lo == hi) //如遇递归基（区间长度已降至1），则
3     return A[lo]; //直接返回该元素
4   else { //否则（一般情况下lo < hi），则
5     int mi = (lo + hi) >> 1; //以居中单元为界，将原区间一分为二
6     return sum(A, lo, mi) + sum(A, mi + 1, hi); //递归对各子数组求和，然后合计
7   }
8 } //O(hi - lo + 1)，线性正比于区间的长度

```

代码1.11 通过二分递归计算数组元素之和

该算法的正确性无需解释。为分析其复杂度，不妨只考查 $n = 2^m$ 形式的长度。

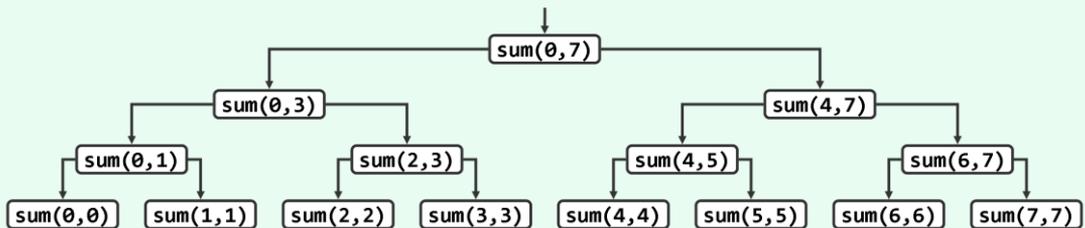


图1.7 对`sum(A, 0, 7)`的递归跟踪分析

图1.7针对 $n = 8$ 的情况给出了`sum(A, 0, 7)`执行过程的递归跟踪。其中各方框都标注有对应的`lo`和`hi`值，即子数组区间的起、止单元。可见，按照调用的关系及次序，该方法的所有实例构成一个层次结构（即第5章将介绍的二叉树）。沿着这个层次结构每下降一层，每个递归实例`sum(lo, hi)`都分裂为一对更小的实例`sum(lo, mi)`和`sum(mi + 1, hi)`——准确地说，每经过一次递归调用，子问题对应的数组区间长度 $hi - lo + 1$ 都将减半。

算法启动后经连续 $m = \log_2 n$ 次递归调用，数组区间的长度从最初的 n 首次缩减至1，并到达第一个递归基。实际上，刚到达任一递归基时，已执行的递归调用总是比递归返回多 $m = \log_2 n$ 次。更一般地，到达区间长度为 2^k 的任一递归实例之前，已执行的递归调用总是比递归返回多 $m - k$ 次。因此，递归深度（即任一时刻的活跃递归实例的总数）不会超过 $m + 1$ 。鉴于每个递归实例仅需常数空间，故除数组本身所占的空间，该算法只需要 $\mathcal{O}(m + 1) = \mathcal{O}(\log n)$ 的附加空间。我们还记得，代码1.5中线性递归版`sum()`算法共需 $\mathcal{O}(n)$ 的附加空间，就这一点而言，新的二分递归版`sum()`算法有很大改进。

与线性递归版`sum()`算法一样，此处每一递归实例中的非递归计算都只需要常数时间。递归实例共计 $2n - 1$ 个，故新算法的运行时间为 $\mathcal{O}(2n - 1) = \mathcal{O}(n)$ ，与线性递归版相同。

此处每个递归实例可向下深入递归两次，故属于多路递归中的二分递归。二分递归与此前介绍的线性递归有很大区别。比如，在线性递归中整个计算过程仅出现一次递归基，而在二分递归过程中递归基的出现相当频繁，总体而言有超过半数的递归实例都是递归基。

■ 效率

当然，并非所有问题都适宜于采用分治策略。实际上除了递归，此类算法的计算消耗主要来自两个方面。首先是子问题划分，即把原问题分解为形式相同、规模更小的多个子问题，比如代码1.11中`sum()`算法将待求和数组分为前、后两段。其次是子解答合并，即由递归所得子问题的解，得到原问题的整体解，比如由子数组之和累加得到整个数组之和。

为使分治策略真正有效，不仅必须保证以上两方面的计算都能高效地实现，还必须保证子问题之间相互独立——各子问题可独立求解，而无需借助其它子问题的原始数据或中间结果。否则，或者子问题之间必须传递数据，或者子问题之间需要相互调用，无论如何都会导致时间和空间复杂度的无谓增加。以下就以Fibonacci数列的计算为例说明这一点。

■ Fibonacci数：二分递归

考查Fibonacci数列第 n 项`fib(n)`的计算问题，该数列递归形式的定义如下：

$$\text{fib}(n) = \begin{cases} n & (\text{若 } n \leq 1) \\ \text{fib}(n-1) + \text{fib}(n-2) & (\text{若 } n \geq 2) \end{cases}$$

据此定义，可直接导出如代码1.12所示的二分递归版`fib()`算法：

```
1 __int64 fib(int n) { //计算Fibonacci数列的第n项（二分递归版）：O(2^n)
2     return (2 > n) ?
3         (__int64)n //若到达递归基，直接取值
4         : fib(n - 1) + fib(n - 2); //否则，递归计算前两项，其和即为正解
5 }
```

代码1.12 通过二分递归计算Fibonacci数

基于Fibonacci数列原始定义的这一实现，不仅正确性一目了然，而且简洁自然。然而不幸的是，在这种场合采用二分递归策略的效率极其低下。实际上，该算法需要运行 $\mathcal{O}(2^n)$ 时间才能计算出第 n 个Fibonacci数。这一指数复杂度的算法，在实际环境中毫无价值。

为确切地界定该算法的复杂度，不妨将计算`fib(n)`所需的时间记作 $T(n)$ 。按该算法的思路，为计算出`fib(n)`，先花费 $T(n - 1)$ 时间计算`fib(n - 1)`，再花费 $T(n - 2)$ 时间计算`fib(n - 2)`，最后花费一个单位的时间将它们累加起来。由此，可得 $T(n)$ 的递推式如下：

$$T(n) = \begin{cases} 1 & (\text{若 } n \leq 1) \\ T(n - 1) + T(n - 2) + 1 & (\text{否则}) \end{cases}$$

若令 $S(n) = [T(n) + 1]/2$ ，则有：

$$S(n) = \begin{cases} 1 & (\text{若 } n \leq 1) \\ S(n - 1) + S(n - 2) & (\text{否则}) \end{cases}$$

我们发现， $S(n)$ 的递推形式与`fib(n)`完全一致，只是起始项不同：

$$S(0) = (T(0) + 1) / 2 = 1 = \text{fib}(1)$$

$$S(1) = (T(1) + 1) / 2 = 1 = \text{fib}(2)$$

亦即， $S(n)$ 整体上相对于 $\text{fib}(n)$ 提前了一个单元。由此可知：

$$S(n) = \text{fib}(n + 1) = (\Phi^{n+1} - \hat{\Phi}^{n+1})/\sqrt{5}, \quad \Phi = (1 + \sqrt{5})/2, \quad \hat{\Phi} = (1 - \sqrt{5})/2$$

$$T(n) = 2 \cdot S(n) - 1 = 2 \cdot \text{fib}(n + 1) - 1 = o(\Phi^{n+1}) = o(2^n)$$

这一版本 $\text{fib}()$ 算法的时间复杂度高达指数量级，究其原因在于，计算过程中所出现的递归实例的重复度极高——只需画出递归跟踪分析图的前几层，即不难验证这一点。若需更为精确的界定，可以借助递推方程（习题[1-19]），将得到相同的结论。

■ 优化策略

为消除递归算法中重复的递归实例，一种自然而然的思路 and 技巧，可以概括为：

借助一定量的辅助空间，在各子问题求解之后，及时记录下其对应的解答

比如，可以从原问题出发自顶而下，每当遇到一个子问题，都首先查验它是否已经计算过，以期通过直接调阅记录获得解答，从而避免重新计算。也可以从递归基出发，自底而上递推地得出各子问题的解，直至最终原问题的解。前者即所谓的制表(tabulation)或记忆(memoization)策略，后者即所谓的动态规划(dynamic programming)策略。

■ Fibonacci数：线性递归

为应用上述制表的策略，首先需从改造Fibonacci数的递归定义入手。

反观代码1.12，原 $\text{fib}()$ 算法之所以采用二分递归模式，完全是因为受到该问题原始定义的表面特征—— $\text{fib}(n)$ 由 $\text{fib}(n - 1)$ 和 $\text{fib}(n - 2)$ 共同决定——的误导。然而不难看出，子问题 $\text{fib}(n - 1)$ 和 $\text{fib}(n - 2)$ 实际上并非彼此独立。比如，只要转而采用定义如下的递归函数，计算一对相邻的Fibonacci数：

$$(\text{fib}(k-1), \text{fib}(k))$$

即可如代码1.13所示，得到效率更高（习题[1-21]）的线性递归版 $\text{fib}()$ 算法。

```

1 __int64 fib(int n, __int64& prev) { //计算Fibonacci数列第n项 (线性递归版) : 入口形式fib(n, prev)
2     if (0 == n) //若到达递归基, 则
3         { prev = 1; return 0; } //直接取值: fib(-1) = 1, fib(0) = 0
4     else { //否则
5         __int64 prevPrev; prev = fib(n - 1, prevPrev); //递归计算前两项
6         return prevPrev + prev; //其和即为正解
7     }
8 } //用辅助变量记录前一项, 返回数列的当前项, 0(n)

```

代码1.13 通过线性递归计算Fibonacci数

请注意，原二分递归版本中对应于 $\text{fib}(n - 2)$ 的另一递归，在这里被省略掉了。其对应的解答，可借助形式参数的机制，通过变量 prevPrev “调阅”此前的记录直接获得。

该算法呈线性递归模式，递归的深度线性正比于输入 n ，前后共计仅出现 $o(n)$ 个递归实例，累计耗时不超过 $o(n)$ 。遗憾的是，该算法共需使用 $o(n)$ 规模的附加空间。如何进一步改进呢？

■ Fibonacci数: 迭代

反观以上线性递归版`fib()`算法可见, 其中所记录的每一个子问题的解答, 只会用到一次。在该算法抵达递归基之后的逐层返回过程中, 每向上返回一层, 以下各层的解答均不必继续保留。

若将以上逐层返回的过程, 等效地视作从递归基出发, 按规模自小而大求解各子问题的过程, 即可采用动态规划的策略, 将以上算法进一步改写为如代码1.14所示的迭代版。

```
1 __int64 fibI(int n) { //计算Fibonacci数列的第n项 (迭代版) : O(n)
2   __int64 f = 0, g = 1; //初始化: fib(0) = 0, fib(1) = 1
3   while (0 < n--) { g += f; f = g - f; } //依据原始定义, 通过n次加法和减法计算fib(n)
4   return f; //返回
5 }
```

代码1.14 基于动态规划策略计算Fibonacci数

这里仅使用了两个中间变量`f`和`g`, 记录当前的一对相邻Fibonacci数。整个算法仅需线性步的迭代, 时间复杂度为 $O(n)$ 。更重要的是, 该版本仅需常数规模的附加空间, 空间效率也有了极大提高。

§ 1.5 抽象数据类型

各种数据结构都可看作是由若干数据项组成的集合, 同时对数据项定义一组标准的操作。现代数据结构普遍遵从“信息隐藏”的理念, 通过统一接口和内部封装, 分层次从整体上加以设计、实现与使用。

所谓封装, 就是将数据项与相关的操作结合为一个整体, 并将其从外部的可见性划分为若干级别, 从而将数据结构的外部特性与其内部实现相分离, 提供一致且标准的对外接口, 隐藏内部的实现细节。于是, 数据集合及其对应的操作可超脱于具体的程序设计语言、具体的实现方式, 即构成所谓的抽象数据类型 (**abstract data type, ADT**)。抽象数据类型的理论催生了现代面向对象的程序设计语言, 而支持封装也是此类语言的基本特征。

本书将尽可能遵循抽象数据类型的规范来设计、实现并分析各种数据结构。具体地, 将从各数据结构的对外功能接口 (**interface**) 出发, 以C++语言为例逐层讲解其内部具体实现 (**implementation**) 的原理、方法与技巧, 并就不同实现方式的效率及适用范围进行分析与比较。为体现数据结构的通用性, 也将普遍采用模板类的描述模式。

第2章

向量

数据结构是数据项的结构化集合，其结构性表现为数据项之间的相互联系及作用，也可以理解为定义于数据项之间的某种逻辑次序。根据这种逻辑次序的复杂程度，大致可以将各种数据结构划分为线性结构、半线性结构与非线性结构三大类。在线性结构中，各数据项按照一个线性次序构成一个整体。最为基本的线性结构统称为序列（**sequence**），根据其中数据项的逻辑次序与其物理存储地址的对应关系不同，又可进一步地将序列区分为向量（**vector**）和列表（**list**）。在向量中，所有数据项的物理存放位置与其逻辑次序完全吻合，此时的逻辑次序也称作秩（**rank**）；而在列表中，逻辑上相邻的数据项在物理上未必相邻，而是采用间接定址的方式通过封装后的位置（**position**）相互引用。

本章的讲解将围绕向量结构的高效实现而逐步展开，包括其作为抽象数据类型的接口规范以及对应的算法，尤其是高效维护动态向量的技巧。此外，还将针对有序向量，系统介绍经典的查找与排序算法，并就其性能做一分析对比，这也是本章的重点与难点所在。最后，还将引入复杂度下界的概念，并通过建立比较树模型，针对基于比较式算法给出复杂度下界的统一界定方法。

§ 2.1 从数组到向量

2.1.1 数组

C、C++和Java等程序设计语言，都将数组作为一种内置的数据类型，支持对一组相关元素的存储组织与访问操作。具体地，若集合S由n个元素组成，且各元素之间具有一个线性次序，则可将它们存放于起始于地址A、物理位置连续的一段存储空间，并统称作数组（**array**），通常以A作为该数组的标识。具体地，数组A[]中的每一元素都唯一对应于某一下标编号，在多数高级程序设计语言中，一般都是从0开始编号，依次是0号、1号、2号、...、n-1号元素，记作：

$$A = \{ a_0, a_1, \dots, a_{n-1} \} \quad \text{或者}$$

$$A[0, n) = \{ A[0], A[1], \dots, A[n-1] \}$$

其中，对于任何 $0 \leq i < j < n$ ，A[i]都是A[j]的前驱（**predecessor**），A[j]都是A[i]的后继（**successor**）。特别地，对于任何 $i \geq 1$ ，A[i-1]称作A[i]的直接前驱（**intermediate predecessor**）；对于任何 $i \leq n-2$ ，A[i+1]称作A[i]的直接后继（**intermediate successor**）。任一元素的所有前驱构成其前缀（**prefix**），所有后继构成其后缀（**suffix**）。

采用这一编号规范，不仅可以使得每个元素都通过下标唯一指代，而且可以使我们直接访问到任一元素。这里所说的“访问”包含读取、修改等基本操作，而“直接”则是指这些操作都可以在常数时间内完成——只要从数组所在空间的起始地址A出发，即可根据每一元素的编号，经过一次乘法运算和一次加法运算，获得待访问元素的物理地址。具体地，若数组A[]存放空间的起始地址为A，且每个元素占用s个单位的空间，则元素A[i]对应的物理地址为：

$$A + i \times s$$

因其中元素的物理地址与其下标之间满足这种线性关系，故亦称作线性数组（**linear array**）。

2.1.2 向量

按照面向对象思想中的数据抽象原则，可对以上的数组结构做一般性推广，使得其以上特性更具普遍性。向量（vector）就是线性数组的一种抽象与泛化，它也是由具有线性次序的一组元素构成的集合 $V = \{ v_0, v_1, \dots, v_{n-1} \}$ ，其中的元素分别由秩相互区分。

各元素的秩（rank）互异，且均为 $[0, n)$ 内的整数。具体地，若元素 e 的前驱元素共计 r 个，则其秩就是 r 。以前介绍的线性递归为例，运行过程中所出现过的所有递归实例，按照相互调用的关系可构成一个线性序列。在此序列中，各递归实例的秩反映了它们各自被创建的时间先后，每一递归实例的秩等于早于它出现的实例总数。反过来，通过 r 亦可唯一确定 $e = v_r$ 。这是向量特有的元素访问方式，称作“循秩访问”（call-by-rank）。

经如此抽象之后，我们不再限定同一向量中的各元素都属于同一基本类型，它们本身可以是来自于更具一般性的某一类的对象。另外，各元素也不见得同时具有某一数值属性，故而并不保证它们之间能够相互比较大小。

以下首先从向量最基本的接口出发，设计并实现与之对应的向量模板类。然后在元素之间具有大小可比性的假设前提下，通过引入通用比较器或重载对应的操作符明确定义元素之间的大小判断依据，并强制要求它们按此次序排列，从而得到所谓有序向量，并介绍和分析此类向量的相关算法及其针对不同要求的各种实现版本。

§ 2.2 接口

2.2.1 ADT接口

作为一种抽象数据类型，向量对象应支持如下操作接口。

表2.1 向量ADT支持的操作接口

操作接口	功能	适用对象
size()	报告向量当前的规模（元素总数）	向量
get(r)	获取秩为r的元素	向量
put(r, e)	用e替换秩为r元素的数值	向量
insert(r, e)	e作为秩为r元素插入，原后继元素依次后移	向量
remove(r)	删除秩为r的元素，返回该元素中原存放的对象	向量
disordered()	判断所有元素是否已按非降序排列	向量
sort()	调整各元素的位置，使之按非降序排列	向量
find(e)	查找等于e且秩最大的元素	向量
search(e)	查找目标元素e，返回不大于e且秩最大的元素	有序向量
deduplicate()	剔除重复元素	向量
uniquify()	剔除重复元素	有序向量
traverse()	遍历向量并统一处理所有元素，处理方法由函数对象指定	向量

以上向量操作接口，可能有多种具体的实现方式，计算复杂度也不尽相同。而在引入秩的概念并将外部接口与内部实现分离之后，无论采用何种具体的方式，符合统一外部接口规范的任一实现均可直接地相互调用和集成。

2.2.2 操作实例

按照表2.1定义的ADT接口，表2.2给出了一个整数向量从被创建开始，通过ADT接口依次实施一系列操作的过程。请留意观察，向量内部各元素秩的逐步变化过程。

表2.2 向量操作实例

操作	输出	向量组成 (自左向右)	操作	输出	向量组成 (自左向右)
初始化			disordered()	3	4 3 7 4 9 6
insert(0, 9)		9	find(9)	4	4 3 7 4 9 6
insert(0, 4)		4 9	find(5)	-1	4 3 7 4 9 6
insert(1, 5)		4 5 9	sort()		3 4 4 6 7 9
put(1, 2)		4 2 9	disordered()	0	3 4 4 6 7 9
get(2)	9	4 2 9	search(1)	-1	3 4 4 6 7 9
insert(3, 6)		4 2 9 6	search(4)	2	3 4 4 6 7 9
insert(1, 7)		4 7 2 9 6	search(8)	4	3 4 4 6 7 9
remove(2)	2	4 7 9 6	search(9)	5	3 4 4 6 7 9
insert(1, 3)		4 3 7 9 6	search(10)	5	3 4 4 6 7 9
insert(3, 4)		4 3 7 4 9 6	uniquify()		3 4 6 7 9
size()	6	4 3 7 4 9 6	search(9)	4	3 4 6 7 9

2.2.3 Vector模板类

按照表2.1确定的向量ADT接口，可定义Vector模板类如代码2.1所示。

```

1 typedef int Rank; //秩
2 #define DEFAULT_CAPACITY 3 //默认的初始容量 (实际应用中可设置为更大)
3
4 template <typename T> class Vector { //向量模板类
5 protected:
6     Rank _size; int _capacity; T* _elem; //规模、容量、数据区
7     void copyFrom(T const* A, Rank lo, Rank hi); //复制数组区间A[lo, hi)
8     void expand(); //空间不足时扩容
9     void shrink(); //装填因子过小时压缩
10    bool bubble(Rank lo, Rank hi); //扫描交换
11    void bubbleSort(Rank lo, Rank hi); //起泡排序算法
12    Rank max(Rank lo, Rank hi); //选取最大元素
13    void selectionSort(Rank lo, Rank hi); //选择排序算法
14    void merge(Rank lo, Rank mi, Rank hi); //归并算法
15    void mergeSort(Rank lo, Rank hi); //归并排序算法
16    Rank partition(Rank lo, Rank hi); //轴点构造算法
17    void quickSort(Rank lo, Rank hi); //快速排序算法
18    void heapSort(Rank lo, Rank hi); //堆排序 (稍后结合完全堆讲解)
19 public:

```

```

20 // 构造函数
21 Vector(int c = DEFAULT_CAPACITY, int s = 0, T v = 0) //容量为c、规模为s、所有元素初始为v
22 { _elem = new T[_capacity = c]; for (_size = 0; _size < s; _elem[_size++] = v); } //s <= c
23 Vector(T const* A, Rank lo, Rank hi) { copyFrom(A, lo, hi); } //数组区间复制
24 Vector(T const* A, Rank n) { copyFrom(A, 0, n); } //数组整体复制
25 Vector(Vector<T> const& V, Rank lo, Rank hi) { copyFrom(V._elem, lo, hi); } //向量区间复制
26 Vector(Vector<T> const& V) { copyFrom(V._elem, 0, V._size); } //向量整体复制
27 // 析构函数
28 ~Vector() { delete [] _elem; } //释放内部空间
29 // 只读访问接口
30 Rank size() const { return _size; } //规模
31 bool empty() const { return !_size; } //判空
32 int disordered() const; //判断向量是否已排序
33 Rank find(T const& e) const { return find(e, 0, _size); } //无序向量整体查找
34 Rank find(T const& e, Rank lo, Rank hi) const; //无序向量区间查找
35 Rank search(T const& e) const //有序向量整体查找
36 { return (0 >= _size) ? -1 : search(e, 0, _size); }
37 Rank search(T const& e, Rank lo, Rank hi) const; //有序向量区间查找
38 // 可写访问接口
39 T& operator[](Rank r) const; //重载下标操作符,可以类似于数组形式引用各元素
40 Vector<T> & operator=(Vector<T> const&); //重载赋值操作符,以便直接克隆向量
41 T remove(Rank r); //删除秩为r的元素
42 int remove(Rank lo, Rank hi); //删除秩在区间[lo, hi)之内的元素
43 Rank insert(Rank r, T const& e); //插入元素
44 Rank insert(T const& e) { return insert(_size, e); } //默认作为末元素插入
45 void sort(Rank lo, Rank hi); //对[lo, hi)排序
46 void sort() { sort(0, _size); } //整体排序
47 void unsort(Rank lo, Rank hi); //对[lo, hi)置乱
48 void unsort() { unsort(0, _size); } //整体置乱
49 int deduplicate(); //无序去重
50 int uniquify(); //有序去重
51 // 遍历
52 void traverse(void (*)(T&)); //遍历(使用函数指针,只读或局部性修改)
53 template <typename VST> void traverse(VST&); //遍历(使用函数对象,可全局性修改)
54 }; //Vector

```

代码2.1 向量模板类Vector

这里通过模板参数T,指定向量元素的类型。于是,以Vector<int>或Vector<float>之类的形式,可便捷地引入存放整数或浮点数的向量;而以Vector<Vector<char>>之类的形式,则可直接定义存放字符的二维向量等。这一技巧有利于提高数据结构选用的灵活性和运行效率,并减少出错,因此将在本书中频繁使用。

在表2.1所列基本操作接口的基础上,这里还扩充了一些接口。比如,基于size()直接实现

的判空接口`empty()`，以及区间删除接口`remove(lo, hi)`、区间查找接口`find(e, lo, hi)`等。它们多为上述基本接口的扩展或变型，可使代码更为简洁易读，并提高计算效率。

这里还提供了`sort()`接口，以将向量转化为有序向量。为此可有多种排序算法供选用，本章及后续章节，将陆续介绍它们的原理、实现并分析其效率。排序之后，向量的很多操作都可更加高效地完成，其中最基本和最常用的莫过于查找。因此，这里还针对有序向量提供了`search()`接口，并将详细介绍若干种相关的算法。为便于对`sort()`算法的测试，这里还设有一个`unsort()`接口，以将向量随机置乱。在讨论这些接口之前，我们首先介绍基本接口的实现。

§ 2.3 构造与析构

由代码2.1可见，向量结构在内部维护一个元素类型为`T`的私有数组`_elem[]`：其容量由私有变量`_capacity`指示；有效元素的数量（即向量当前的实际规模），则由`_size`指示。此外还进一步地约定，在向量元素的秩、数组单元的逻辑编号以及物理地址之间，具有如下对应关系：

向量中秩为`r`的元素，对应于内部数组中的`_elem[r]`，其物理地址为`_elem + r`

因此，向量对象的构造与析构，将主要围绕这些私有变量和数据区的初始化与销毁展开。

2.3.1 默认构造方法

与所有的对象一样，向量在使用之前也需首先被系统创建——借助构造函数（`constructor`）做初始化（`initialization`）。由代码2.1可见，这里为向量重载了多个构造函数。

其中默认的构造方法是，首先根据创建者指定的初始容量，向系统申请空间，以创建内部私有数组`_elem[]`；若容量未明确指定，则使用默认值`DEFAULT_CAPACITY`。接下来，鉴于初生的向量尚不包含任何元素，故将指示规模的变量`_size`初始化为`0`。

整个过程顺序进行，没有任何迭代，故若忽略用于分配数组空间的时间，共需常数时间。

2.3.2 基于复制的构造方法

向量的另一典型创建方式，是以某个已有的向量或数组为蓝本，进行（局部或整体的）克隆。代码2.1中虽为此功能重载了多个接口，但无论是已封装的向量或未封装的数组，无论是整体还是区间，在入口参数合法的前提下，都可归于如代码2.2所示的统一的`copyFrom()`方法：

```
1 template <typename T> //元素类型
2 void Vector<T>::copyFrom(T const* A, Rank lo, Rank hi) { //以数组区间A[lo, hi)为蓝本复制向量
3     _elem = new T[_capacity = 2 * (hi - lo)]; _size = 0; //分配空间, 规模清零
4     while (lo < hi) //A[lo, hi)内的元素逐一
5         _elem[_size++] = A[lo++]; //复制至_elem[0, hi - lo)
6 }
```

代码2.2 基于复制的向量构造器

`copyFrom()`首先根据待复制区间的边界，换算出新向量的初始规模；再以双倍的容量，为内部数组`_elem[]`申请空间。最后通过一趟迭代，完成区间`A[lo, hi)`内各元素的顺次复制。

若忽略开辟新空间所需的时间，运行时间应正比于区间宽度，即 $O(hi - lo) = O_size)$ 。

需强调的是，由于向量内部含有动态分配的空间，默认的运算符“=”不足以支持向量之间的直接赋值。例如，6.3节将以二维向量形式实现图邻接表，其主向量中的每一元素本身都是一维向量，故通过默认赋值运算符，并不能复制向量内部的数据区。

为适应此类赋值操作的需求，可如代码2.3所示，重载向量的赋值运算符。

```
1 template <typename T> Vector<T>& Vector<T>::operator=(Vector<T> const& V ) { //重载赋值操作符
2     if (_elem) delete [] _elem; //释放原有内容
3     copyFrom(V._elem, 0, V.size()); //整体复制
4     return *this; //返回当前对象的引用，以便链式赋值
5 }
```

代码2.3 重载向量赋值操作符

2.3.3 析构方法

与所有对象一样，不再需要的向量，应借助析构函数（**destructor**）及时清理（**cleanup**），以释放其占用的系统资源。与构造函数不同，同一对象只能有一个析构函数，不得重载。

向量对象的析构过程，如代码2.1中的方法`~Vector()`所示：只需释放用于存放元素的内部数组`_elem[]`，将其占用的空间交还操作系统。`_capacity`和`_size`之类的内部变量无需做任何处理，它们将作为向量对象自身的一部分被系统回收，此后既无需也无法被引用。

若不计系统用于空间回收的时间，整个析构过程只需 $O(1)$ 时间。

同样地，向量中的元素可能不是程序语言直接支持的基本类型。比如，可能是指向动态分配对象的指针或引用，故在向量析构之前应该提前释放对应的空间。出于简化的考虑，这里约定并遵照“谁申请谁释放”的原则。究竟应释放掉向量各元素所指的對象，还是需要保留这些对象，以便通过其它指针继续引用它们，应由上层调用者负责确定。

§ 2.4 动态空间管理

2.4.1 静态空间管理

内部数组所占物理空间的容量，若在向量的生命期内不允许调整，则称作静态空间管理策略。很遗憾，该策略的空间效率难以保证。一方面，既然容量固定，总有可能在此后的某一时刻，无法加入更多的新元素——即导致所谓的上溢（**overflow**）。例如，若使用向量来记录网络访问日志，则由于插入操作远多于删除操作，必然频繁溢出。注意，造成此类溢出的原因，并非系统不能提供更多的空间。另一方面反过来，即便愿意为降低这种风险而预留出部分空间，也很难在程序执行之前，明确界定一个合理的预留量。以上述`copyFrom()`方法为例，即便将容量取作初始规模的两倍，也只能保证在此后足够长的一段时间内（而非永远）不致溢出。

向量实际规模与其内部数组容量的比值（即`_size/_capacity`），亦称作装填因子（**load factor**），它是衡量空间利用率的重要指标。从这一角度，上述难题可归纳为：

如何才能保证向量的装填因子既不致于超过1，也不致于太接近于0？

为此，需要改用动态空间管理策略。其中一种有效的方法，即使用所谓的可扩充向量。

2.4.2 可扩充向量

经过一段时间的生长，每当身体无法继续为其外壳所容纳，蝉就会蜕去外壳，同时换上一身更大的外壳。扩充向量（**extendable vector**）的原理，与之相仿。若内部数组仍有空余，则操作可照常执行。每经一次插入（删除），可用空间都会减少（增加）一个单元（图2.1(a)）。一旦可用空间耗尽（图(b)），就动态地扩大内部数组的容量。这里的难点及关键在于：

如何实现扩容？新的容量取作多少才算适宜？

首先解决前一问题。直接在原有物理空间的基础上追加空间？这并不现实。数组特有的定址方式要求，物理空间必须地址连续，而我们却无法保证，其尾部总是预留了足够空间可供拓展。

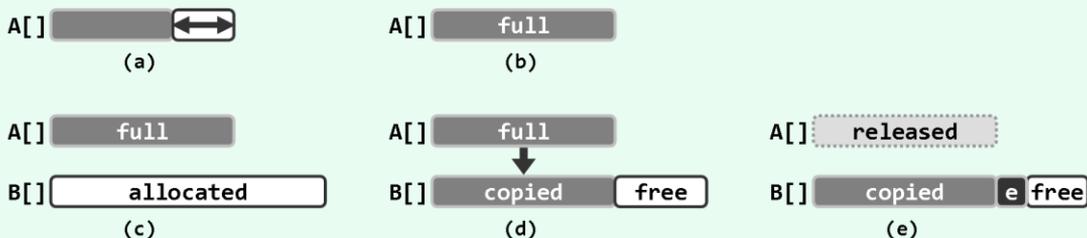


图2.1 可扩充向量的溢出处理

一种可行的方法，如图2.1(c~e)所示。我们需要另行申请一个容量更大的数组B[]（图(c)），并将原数组中的成员集体搬迁至新的空间（图(d)），此后方可顺利地插入新元素e而不致溢出（图(e)）。当然，原数组所占的空间，需要及时释放并归还操作系统。

2.4.3 扩容

基于以上策略的扩容算法expand()，可实现如代码2.4所示。

```

1 template <typename T> void Vector<T>::expand() { //向量空间不足时扩容
2     if (_size < _capacity) return; //尚未满员时，不必扩容
3     if (_capacity < DEFAULT_CAPACITY) _capacity = DEFAULT_CAPACITY; //不低于最小容量
4     T* oldElem = _elem; _elem = new T[_capacity <<= 1]; //容量加倍
5     for (int i = 0; i < _size; i++)
6         _elem[i] = oldElem[i]; //复制原向量内容 (T为基本类型，或已重载赋值操作符'=')
7     delete [] oldElem; //释放原空间
8 }

```

代码2.4 向量内部数组动态扩容算法expand()

实际上，在调用insert()接口插入新元素之前，都要先调用该算法，检查内部数组的可用容量。一旦当前数据区已满（_size == _capacity），则将原数组替换为一个更大的数组。

请注意，新数组的地址由操作系统分配，与原数据区没有直接的关系。这种情况下，若直接引用数组，往往会导致共同指向原数组的其它指针失效，成为野指针（wild pointer）；而经封装为向量之后，即可继续准确地引用各元素，从而有效地避免野指针的风险。

这里的关键在于，新数组的容量总是取作原数组的两倍——这正是上述后一问题的答案。

2.4.4 分摊分析

■ 时间代价

与常规数组实现相比，可扩充向量更加灵活：只要系统尚有可用空间，其规模将不再受限于初始容量。不过，这并非没有代价——每次扩容，元素的搬迁都需要花费额外的时间。

准确地，每一次由 n 到 $2n$ 的扩容，都需要花费 $\mathcal{O}(2n) = \mathcal{O}(n)$ 时间——这也是最坏情况下，单次插入操作所需的时间。表面看来，这一扩容策略似乎效率很低，但这不过是一种错觉。

请注意，按照此处的约定，每花费 $\mathcal{O}(n)$ 时间实施一次扩容，数组的容量都会加倍。这就意味着，至少要再经过 n 次插入操作，才会因为可能溢出而再次扩容。也就是说，随着向量规模的不断扩大，在执行插入操作之前需要进行扩容的概率，也将迅速降低。故就某种平均意义而言，用于扩容的时间成本不至很高。以下不妨就此做一严格的分析。

■ 分摊复杂度

这里，不妨考查对可扩充向量的足够多次连续操作，并将其间所消耗的时间，分摊至所有的操作。如此分摊平均至单次操作的时间成本，称作分摊运行时间（**amortized running time**）。

请注意，这一指标与平均运行时间（**average running time**）有着本质的区别（习题[2-1]）。后者是按照某种假定的概率分布，对各种情况下所需执行时间的加权平均，故亦称作期望运行时间（**expected running time**）。而前者则要求，参与分摊的操作必须构成和来自一个真实可行的操作序列，而且该序列还必须足够地长。

相对而言，分摊复杂度可以针对计算成本和效率，做出更为客观而准确的估计。比如在这里，在任何一个可扩充向量的生命期内，在任何足够长的连续操作序列中，以任何固定间隔连续出现上述最坏情况的概率均为 θ ，故常规的平均复杂度根本不具任何参考意义。作为评定算法性能的一种重要尺度，分摊分析（**amortized analysis**）的相关方法与技巧将在后续章节陆续介绍。

■ $\mathcal{O}(1)$ 分摊时间

以可扩充向量为例，可以考查对该结构的连续 n 次（查询、插入或删除等）操作，将所有操作中用于内部数组扩容的时间累计起来，然后除以 n 。只要 n 足够大，这一平均时间就是用于扩容处理的分摊时间成本。以下我们将看到，即便排除查询和删除操作而仅考查插入操作，在可扩充向量单次操作中，用于扩容处理的分摊时间成本也不过 $\mathcal{O}(1)$ 。

假定数组的初始容量为某一常数 N 。既然是估计复杂度的上界，故不妨设向量的初始规模也为 N ——即将溢出。另外不难看出，除插入操作外，向量其余的接口操作既不会直接导致溢出，也不会增加此后溢出的可能性，因此不妨考查最坏的情况，假设在此后需要连续地进行 n 次 `insert()` 操作， $n \gg N$ 。首先定义如下函数：

```
size(n) = 连续插入n个元素后向量的规模
capacity(n) = 连续插入n个元素后数组的容量
T(n) = 为连续插入n个元素而花费于扩容的时间
```

其中，向量规模从 N 开始随着操作的进程逐步递增，故有：

$$\text{size}(n) = N + n$$

既然不致溢出，故装填因子绝不会超过100%。同时，这里的扩容采用了“懒惰”策略——只有在的确即将发生溢出时，才不得不将容量加倍——因此装填因子也始终不低于50%。

概括起来，始终应有：

$$\text{size}(n) \leq \text{capacity}(n) < 2 \cdot \text{size}(n)$$

考虑到 N 为常数，故有：

$$\text{capacity}(n) = \Theta(\text{size}(n)) = \Theta(n)$$

容量以2为比例按指数速度增长，在容量达到 $\text{capacity}(n)$ 之前，共做过 $\Theta(\log_2 n)$ 次扩容，每次扩容所需时间线性正比于当时的容量（或规模），且同样以2为比例按指数速度增长。因此，消耗于扩容的时间累计不过：

$$T(n) = 2N + 4N + 8N + \dots + \text{capacity}(n) < 2 \cdot \text{capacity}(n) = \Theta(n)$$

将其分摊到其间的连续 n 次操作，单次操作所需的分摊运行时间应为 $\mathcal{O}(1)$ 。

■ 其它扩容策略

以上分析确凿地说明，基于加倍策略的动态扩充数组不仅可行，而且就分摊复杂度而言效率也足以令人满意。当然，并非任何扩容策略都能保证如此高的效率。比如，早期可扩充向量多采用另一策略：一旦有必要，则追加固定数目的单元。实际上，无论采用的固定常数多大，在最坏情况下，此类数组单次操作的分摊时间复杂度都将高达 $\Omega(n)$ （习题[2-3]）。

2.4.5 缩容

导致低效率的另一情况是，向量的实际规模可能远远小于内部数组的容量。比如在连续的一系列操作过程中，若删除操作远多于插入操作，则装填因子极有可能远远小于100%，甚至非常接近于0。当装填因子低于某一阈值时，我们称数组发生了下溢（underflow）。

尽管下溢不属于必须解决的问题，但在格外关注空间利用率的场合，发生下溢时也有必要适当缩减内部数组容量。代码2.5给出了一个动态缩容`shrink()`算法：

```
1 template <typename T> void Vector<T>::shrink() { //装填因子过小时压缩向量所占空间
2     if (_capacity < DEFAULT_CAPACITY << 1) return; //不致收缩到DEFAULT_CAPACITY以下
3     if (_size << 2 > _capacity) return; //以25%为界
4     T* oldElem = _elem; _elem = new T[_capacity >>= 1]; //容量减半
5     for (int i = 0; i < _size; i++) _elem[i] = oldElem[i]; //复制原向量内容
6     delete [] oldElem; //释放原空间
7 }
```

代码2.5 向量内部功能`shrink()`

可见，每次删除操作之后，一旦空间利用率已降至某一阈值以下，该算法随即申请一个容量减半的新数组，将原数组中的元素逐一搬迁至其中，最后将原数组所占空间交还操作系统。这里以25%作为装填因子的下限，但在实际应用中，为避免出现频繁交替扩容和缩容的情况，可以选用更低的阈值，甚至取作0（相当于禁止缩容）。

与`expand()`操作类似，尽管单次`shrink()`操作需要线性量级的时间，但其分摊复杂度亦为 $\mathcal{O}(1)$ （习题[2-4]）。实际上`shrink()`过程等效于`expand()`的逆过程，这两个算法相互配合，在不致实质地增加接口操作复杂度的前提下，保证了向量内部空间的高效利用。当然，就单次扩容或缩容操作而言，所需时间的确会高达 $\Omega(n)$ ，因此在对单次操作的执行速度极其敏感的应用场合以上策略并不适用，其中缩容操作甚至可以完全不予考虑。

§ 2.5 常规向量

2.5.1 直接引用元素

与数组直接通过下标访问元素的方式(形如“A[i]”)相比,向量ADT所设置的get()和put()接口都显得不甚自然。毕竟,前一访问方式不仅更为我们所熟悉,同时也更加直观和便捷。那么,在经过封装之后,对向量元素的访问可否沿用数组的方式呢?答案是肯定的。

解决的方法之一就是重载操作符“[]”,具体实现如代码2.6所示。

```
1 template <typename T> T& Vector<T>::operator[](Rank r) const //重载下标操作符
2 { return _elem[r]; } // assert: 0 <= r < _size
```

代码2.6 重载向量操作符[]

2.5.2 置乱器

■ 置乱算法

可见,经重载后操作符“[]”返回的是对数组元素的引用,这就意味着它既可以取代get()操作(通常作为赋值表达式的右值),也可以取代set()操作(通常作为左值)。例如,采用这种形式,可以简明清晰地描述和实现如代码2.7所示的向量置乱算法。

```
1 template <typename T> void permute(Vector<T>& V) { //随机置乱向量,使各元素等概率出现于每一位置
2     for (int i = V.size(); i > 0; i--) //自后向前
3         swap(V[i - 1], V[rand() % i]); //V[i - 1]与V[0, i)中某一随机元素交换
4 }
```

代码2.7 向量整体置乱算法permute()

该算法从待置乱区间的末元素开始,逆序地向前逐一处理各元素。如图2.2(a)所示,对每一个当前元素V[i - 1],先通过调用rand()函数在[0, i)之间等概率地随机选取一个元素,再令二者互换位置。注意,这里的交换操作swap(),隐含了三次基于重载操作符“[]”的赋值。

于是如图(b)所示,每经过一步这样的迭代,置乱区间都会向前拓展一个单元。因此经过 $O(n)$ 步迭代之后,即实现了整个向量的置乱。

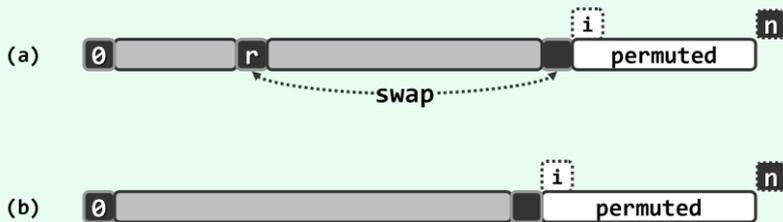


图2.2 向量整体置乱算法permute()的迭代过程

在软件测试、仿真模拟等应用中,随机向量的生成都是一项至关重要的基本操作,直接影响测试的覆盖面或仿真的真实性。从理论上说,使用这里的算法permute(),不仅可以枚举出同一向量所有可能的排列,而且能够保证生成各种排列的概率均等(习题[2-6])。

■ 区间置乱接口

为便于对各种向量算法的测试与比较，这里不妨将以上`permute()`算法封装至向量ADT中，并如代码2.8所示，对外提供向量的置乱操作接口`Vector::unsort()`。

```
1 template <typename T> void Vector<T>::unsort(Rank lo, Rank hi) { //等概率随机置乱向量区间[lo, hi)
2     T* V = _elem + lo; //将子向量_elem[lo, hi)视作另一向量V[0, hi - lo)
3     for (Rank i = hi - lo; i > 0; i--) //自后向前
4         swap(V[i - 1], V[rand() % i]); //将V[i - 1]与V[0, i)中某一元素随机交换
5 }
```

代码2.8 向量区间置乱接口`unsort()`

通过该接口，可以均匀地置乱任一向量区间`[lo, hi)`内的元素，故通用性有所提高。可见，只要将该区间等效地视作另一向量`V`，即可从形式上完整地套用以上`permute()`算法的流程。

尽管如此，还请特别留意代码2.7与代码2.8的细微差异：后者是通过下标，直接访问内部数组的元素；而前者则是借助重载的操作符“`[]`”，通过秩间接地访问向量的元素。

2.5.3 判等器与比较器

从算法的角度来看，“判断两个对象是否相等”与“判断两个对象的相对大小”都是至关重要的操作，它们直接控制着算法执行的分支方向，因此也是算法的“灵魂”所在。在本书中为了以示区别，前者多称作“比对”操作，后者多称作“比较”操作。当然，这两种操作之间既有联系也有区别，不能相互替代。比如，有些对象只能比对但不能比较；反之，支持比较的对象未必支持比对。不过，出于简化的考虑，在很多场合并不需要严格地将二者区分开来。

算法实现的简洁性与通用性，在很大程度上体现于：针对整数等特定数据类型的某种实现，可否推广至可比较或可比对的任何数据类型，而不必关心如何定义以及判定其大小或相等关系。若能如此，我们就可以将比对和比较操作的具体实现剥离出来，直接讨论算法流程本身。

为此，通常可以采用两种方法。其一，将比对操作和比较操作分别封装成通用的判等器和比较器。其二，在定义对应的数据类型时，通过重载“`<`”和“`==`”之类的操作符，给出大小和相等关系的具体定义及其判别方法。本书将主要采用后一方式。为节省篇幅，这里只给出涉及到的比较和判等操作符，读者可以根据实际需要，参照给出的代码加以扩充。

```
1 template <typename T> static bool lt(T* a, T* b) { return lt(*a, *b); } //less than
2 template <typename T> static bool lt(T& a, T& b) { return a < b; } //less than
3 template <typename T> static bool eq(T* a, T* b) { return eq(*a, *b); } //equal
4 template <typename T> static bool eq(T& a, T& b) { return a == b; } //equal
```

代码2.9 重载比较器以便比较对象指针

在一些复杂的数据结构中，内部元素本身的类型可能就是指向其它对象的指针；而从外部更多关注的，则往往是其所指对象的大小。若不加处理而直接根据指针的数值（即被指对象的物理地址）进行比较，则所得结果将毫无意义。

为此，这里不妨通过如代码2.9所示的机制，将这种情况与一般情况予以区分，并且约定在这种情况下，统一按照被指对象的大小做出判断。

2.5.4 无序查找

■ 判等器

代码2.1中`Vector::find(e)`接口，功能语义为“查找与数据对象`e`相等的元素”。这同时也暗示着，向量元素可通过相互比对判等——比如，元素类型`T`或为基本类型，或已重载操作符“`==`”或“`!=`”。这类仅支持比对，但未必支持比较的向量，称作无序向量(`unsorted vector`)。

■ 顺序查找

在无序向量中查找任意指定元素`e`时，因为没有更多的信息可以借助，故在最坏情况下——比如向量中并不包含`e`时——只有在访遍所有元素之后，才能得出查找结论。



图2.3 无序向量的顺序查找

因此不妨如图2.3所示，从末元素起自后向前，逐一取出各个元素并与目标元素`e`进行比对，直至发现与之相等者（查找成功），或者直至检查过所有元素之后仍未找到相等者（查找失败）。这种依次逐个比对的查找方式，称作顺序查找(`sequential search`)。

■ 实现

针对向量的整体或区间，代码2.1分别定义了一个顺序查找操作的入口，其中前者作为特例，可直接通过调用后者而实现。因此，只需如代码2.10所示，实现针对向量区间的查找算法。

```
1 template <typename T> //无序向量的顺序查找：返回最后一个元素e的位置；失败时，返回lo - 1
2 Rank Vector<T>::find(T const& e, Rank lo, Rank hi) const { //assert: 0 <= lo < hi <= _size
3     while ((lo < hi--) && (e != _elem[hi])); //从后向前，顺序查找
4     return hi; //若hi < lo, 则意味着失败；否则hi即命中元素的秩
5 }
```

代码2.10 无序向量元素查找接口`find()`

其中若干细微之处，需要体会。比如，当同时有多个命中元素时，本书统一约定返回其中秩最大者——稍后介绍的查找接口`find()`亦是如此——故这里采用了自后向前的查找次序。如此，一旦命中即可立即返回，从而省略掉不必要的比对。另外，查找失败时约定统一返回`-1`。这不仅简化了对查找失败情况的判别，同时也使此时的返回结果更加易于理解——只要假想着在秩为`-1`处植入一个与任何对象都相等的哨兵元素，则返回该元素的秩当且仅当查找失败。

最后还有一处需要留意。`while`循环的控制逻辑由两部分组成，首先判断是否已抵达通配符，再判断当前元素与目标元素是否相等。得益于C/C++语言中逻辑表达式的短路求值特性，在前一判断非真后循环会立即终止，而不致因试图引用已越界的秩(`-1`)而出错。

■ 复杂度

最坏情况下，查找终止于首元素`_elem[lo]`，运行时间为 $O(hi - lo) = O(n)$ 。最好情况下，查找命中于末元素`_elem[hi - 1]`，仅需 $O(1)$ 时间。对于规模相同、内部组成不同的输入，渐进运行时间却有本质区别，故此类算法也称作输入敏感的(`input sensitive`)算法。

2.5.5 插入

■ 实现

按照代码2.1的ADT定义，插入操作`insert(r, e)`负责将任意给定的元素`e`插到任意指定的秩为`r`的单元。整个操作的过程，可具体实现如代码2.11所示。

```

1 template <typename T> //将e作为秩为r元素插入
2 Rank Vector<T>::insert(Rank r, T const& e) { //assert: 0 <= r <= size
3     expand(); //若有必要, 扩容
4     for (int i = _size; i > r; i--) _elem[i] = _elem[i-1]; //自后向前, 后继元素顺次后移一个单元
5     _elem[r] = e; _size++; //置入新元素并更新容量
6     return r; //返回秩
7 }

```

代码2.11 向量元素插入接口`insert()`

如前所述，插入之前必须首先调用`expand()`算法，核对是否即将溢出；若有必要（图2.4(a)），则加倍扩容（图2.4(b)）。

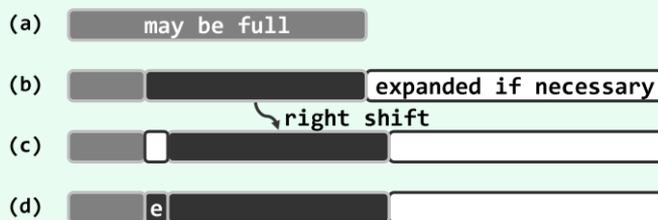


图2.4 向量元素插入操作`insert(r, e)`的过程

为保证数组元素物理地址连续的特性，随后需要将后缀`_elem[r, _size)`（如果非空）整体后移一个单元（图(c)）。这些后继元素自后向前的搬迁次序不能颠倒，否则会因元素被覆盖而造成数据丢失。在单元`_elem[r]`腾出之后，方可将待插入对象`e`置入其中（图(d)）。

■ 复杂度

时间主要消耗于后继元素的后移，线性正比于后缀的长度，故总体为 $O(\text{size} - r + 1)$ 。

可见，新插入元素越靠后（前）所需时间越短（长）。特别地，`r`取最大值`_size`时为最好情况，只需 $O(1)$ 时间；`r`取最小值`0`时为最坏情况，需要 $O(\text{size})$ 时间。一般地，若插入位置等概率分布，则平均运行时间为 $O(\text{size}) = O(n)$ （习题[2-9]），线性正比于向量的实际规模。

2.5.6 删除

删除操作重载有两个接口，`remove(lo, hi)`用以删除区间`[lo, hi)`内的元素，而`remove(r)`用以删除秩为`r`的单个元素。乍看起来，利用后者即可实现前者：令`r`从`hi - 1`到`lo`递减，反复调用`remove(r)`。不幸的是，这一思路似是而非。

因数组中元素的地址必须连续，故每删除一个元素，所有后继元素都需向前移动一个单元。若后继元素共有 $m = \text{size} - hi$ 个，则对`remove(r)`的每次调用都需移动 m 次；对于整个区间，元素移动的次数累计将达到 $m * (hi - lo)$ ，为后缀长度和待删除区间宽度的乘积。

实际可行的思路恰好相反，应将单元素删除视作区间删除的特例，并基于后者来实现前者。稍后就会看到，如此可将移动操作的总次数控制在 $O(m)$ 以内，而与待删除区间的宽度无关。

■ 区间删除: `remove(lo, hi)`

向量区间删除接口`remove(lo, hi)`，可实现如代码2.12所示。

```
1 template <typename T> int Vector<T>::remove(Rank lo, Rank hi) { //删除区间[lo, hi)
2     if (lo == hi) return 0; //出于效率考虑,单独处理退化情况,比如remove(0, 0)
3     while (hi < _size) _elem[lo++] = _elem[hi++]; //[hi, _size)顺次前移hi - lo个单元
4     _size = lo; //更新规模,直接丢弃尾部[lo, _size = hi)区间
5     shrink(); //若有必要,则缩容
6     return hi - lo; //返回被删除元素的数目
7 }
```

代码2.12 向量区间删除接口`remove(lo, hi)`

设 $[lo, hi)$ 为向量(图2.5(a))的合法区间(图(b)),则其后缀 $[hi, n)$ 需整体前移 $hi - lo$ 个单元(图(c))。与插入算法同理,这里后继元素自前向后的移动次序也不能颠倒(习题[2-10])。



图2.5 向量区间删除操作`remove(lo, hi)`的过程

向量规模更新为`_size - hi + lo`后,还要调用`shrink()`,若有必要则做缩容处理(图(d))。

■ 单元素删除`remove(r)`

利用以上`remove(lo, hi)`通用接口,通过重载即可实现如下另一同名接口`remove(r)`。

```
1 template <typename T> T Vector<T>::remove(Rank r) { //删除向量中秩为r的元素, 0 <= r < size
2     T e = _elem[r]; //备份被删除元素
3     remove(r, r + 1); //调用区间删除算法,等效于对区间[r, r + 1)的删除
4     return e; //返回被删除元素
5 }
```

代码2.13 向量单元素删除接口`remove()`

■ 复杂度

`remove(lo, hi)`的计算成本,主要消耗于后续元素的前移,线性正比于后缀的长度,总体不过 $O(m + 1) = O(_size - hi + 1)$ 。

这与此前的预期完全吻合:区间删除操作所需的时间,应该仅取决于后继元素的数目,而与待删除区间本身的宽度无关。特别地,基于该接口实现的单元素删除接口`remove(r)`需耗时 $O(_size - r)$ 。也就是说,被删除元素在向量中的位置越靠后(前)所需时间越短(长),最好为 $O(1)$,最坏为 $O(n) = O(_size)$ 。

■ 错误及意外处理

请注意，上述操作接口对输入都有一定的限制和约定。其中指定的待删除区间，必须落在合法范围 $[0, _size)$ 之内，为此输入参数必须满足 $0 \leq lo \leq hi \leq _size$ 。

一般地，输入参数超出接口所约定合法范围的此类问题，都属于典型的错误（**error**）或意外（**exception**）。除了以注释的形式加以说明，还应该尽可能对此类情况做更为周全的处理。

尽管如此，本书还是沿用了相对简化的处置方式，将入口参数合法性检查的责任统一交由上层调用例程，这也是出于对本书的重点——算法效率、讲解重点以及叙述简洁——的优先考虑。当然，在充分掌握了本书的内容之后，读者不妨再按照软件工程的规范，就此做进一步的完善。

2.5.7 唯一化

很多应用中，在进一步处理之前都要求数据元素互异。以网络搜索引擎为例，多个计算节点各自获得的局部搜索结果，需首先剔除其中重复的项目，方可合并为一份完整的报告。类似地，所谓向量的唯一化处理，就是剔除其中的重复元素，即表2.1所列deduplicate()接口的功能。

■ 实现

视图向量是否有序，该功能有两种实现方式，以下首先介绍针对无序向量的唯一化算法。

```
1 template <typename T> int Vector<T>::deduplicate() { //删除无序向量中重复元素（高效版）
2     int oldSize = _size; //记录原规模
3     Rank i = 1; //从_elem[1]开始
4     while (i < _size) //自前向后逐一考查各元素_elem[i]
5         (find(_elem[i], 0, i) < 0) ? //在其前缀中寻找与之雷同者（至多一个）
6         i++ : remove(i); //若无雷同则继续考查其后继，否则删除雷同者
7     return oldSize - _size; //向量规模变化量，即被删除元素总数
8 }
```

代码2.14 无序向量清除重复元素接口deduplicate()

如代码2.14所示，该算法自前向后逐一考查各元素_elem[i]，并通过调用find()接口，在其前缀中寻找与之雷同者。若找到，则随即删除；否则，转而考查当前元素的后继。

■ 正确性

算法的正确性由以下不变性保证：

在while循环中，在当前元素的前缀_elem[0, i)内，所有元素彼此互异

初次进入循环时 $i = 1$ ，只有唯一的前驱_elem[0]，故不变性自然满足。

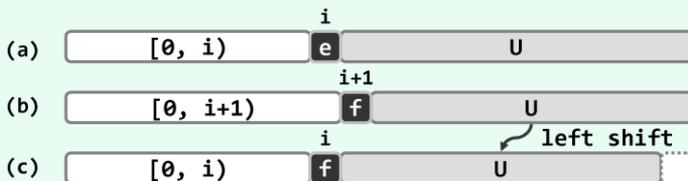


图2.6 无序向量deduplicate()算法原理

一般地如图2.6(a)所示，假设在转至元素 $e = _elem[i]$ 之前不变性一直成立。于是，经过

针对该元素的一步迭代之后，无非两种结果：

1) 若元素e的前缀`_elem[0, i)`中不含与之雷同的元素，则如图(b)，在做过`i++`之后，新的前缀`_elem[0, i)`将继续满足不变性，而且其规模增加一个单位。

2) 反之，若含存在与e雷同的元素，则由此前一直满足的不变性可知，这样的雷同元素不超过一个。因此如图(c)，在删除e之后，前缀`_elem[0, i)`依然保持不变性。

■ 复杂度

由图2.6(a)和(b)也可看出该算法过程所具有的单调性：

随着循环的不断进行，当前元素的后继持续地严格减少

因此，经过 $n - 2$ 步迭代之后该算法必然终止。

这里所需的时间，主要消耗于`find()`和`remove()`两个接口。根据2.5.4节的结论，前一部分时间应线性正比于查找区间的宽度，即前驱的总数；根据2.5.6节的结论，后一部分时间应线性正比于后继的总数。因此，每步迭代所需时间为 $O(n)$ ，总体复杂度应为 $O(n^2)$ 。

经预排序转换之后，借助2.6.3节将要介绍的相关算法，还可以进一步提高向量唯一化处理的效率（习题[2-12]）。

2.5.8 遍历

■ 功能

在很多算法中，往往需要将向量作为一个整体，对其中所有元素实施某种统一的操作，比如输出向量中的所有元素，或者按照某种运算流程统一修改所有元素的数值（习题[2-13]）。针对此类操作，可为向量专门设置一个遍历接口`traverse()`。

■ 实现

向量的遍历操作接口，可实现如代码2.15所示。

```
1 template <typename T> void Vector<T>::traverse(void (*visit)(T&)) //利用函数指针机制的遍历
2 { for (int i = 0; i < _size; i++) visit(_elem[i]); }
3
4 template <typename T> template <typename VST> //元素类型、操作器
5 void Vector<T>::traverse(VST& visit) //利用函数对象机制的遍历
6 { for (int i = 0; i < _size; i++) visit(_elem[i]); }
```

代码2.15 向量遍历接口`traverse()`

可见，`traverse()`遍历的过程，实质上就是自前向后地逐一对各元素实施同一基本操作。而具体采用何种操作，可通过两种方式指定。前一种方式借助函数指针`*visit()`指定某一函数，该函数只有一个参数，其类型为对向量元素的引用，故通过该函数即可直接访问或修改向量元素。另外，也可以函数对象的形式，指定具体的遍历操作。这类对象的操作符“`()`”经重载之后，在形式上等效于一个函数接口，故此得名。

相比较而言，后一形式的功能更强，适用范围更广。比如，函数对象的形式支持对向量元素的关联修改。也就是说，对各元素的修改不仅可以相互独立地进行，也可以根据某个（些）元素的数值相应地修改另一元素。前一形式虽也可实现这类功能，但要繁琐很多。

■ 实例

在代码2.16中，`Increase<T>()`即是按函数对象形式指定的基本操作，其功能是将作为参数的引用对象的数值加一（假定元素类型`T`可直接递增或已重载操作符"`++`"）。于是可如`increase()`函数那样，以此基本操作做遍历即可使向量内所有元素的数值同步加一。

```
1 template <typename T> struct Increase //函数对象：递增一个T类对象
2   { virtual void operator()(T& e) { e++; } }; //假设T可直接递增或已重载++
3
4 template <typename T> void increase(Vector<T> & V) //统一递增向量中的各元素
5 { V.traverse(Increase<T>()); } //以Increase<T>()为基本操作进行遍历
```

代码2.16 基于遍历实现`increase()`功能

■ 复杂度

遍历操作本身只包含一层线性的循环迭代，故除了向量规模的因素之外，遍历所需时间应线性正比于所统一指定的基本操作所需的时间。比如在上例中，统一的基本操作`Increase<T>()`只需常数时间，故这一遍历的总体时间复杂度为 $O(n)$ 。

§ 2.6 有序向量

若向量`S[0, n)`中的所有元素不仅按线性次序存放，而且其数值大小也按此次序单调分布，则称作有序向量（`sorted vector`）。例如，所有学生的学籍记录可按学号构成一个有序向量（学生名单），使用同一跑道的所有航班可按起飞时间构成一个有序向量（航班时刻表），第二十九届奥运会男子跳高决赛中各选手的记录可按最终跳过的高度构成一个（非增）序列（名次表）。与通常的向量一样，有序向量依然不要求元素互异，故通常约定其中的元素自前（左）向后（右）构成一个非降序列，即对任意 $0 \leq i < j < n$ 都有`S[i] ≤ S[j]`。

2.6.1 比较器

当然，除了与无序向量一样需要支持元素之间的“判等”操作，有序向量的定义中实际上还隐含了另一更强的先决条件：各元素之间必须能够比较大小。这一条件构成了有序向量中“次序”概念的基础，否则所谓的“有序”将无从谈起。

多数高级程序语言所提供的基本数据类型都满足上述条件，比如C++语言中的整型、浮点型和字符型等，然而字符串、复数、矢量以及更为复杂的类型，则未必直接提供了某种自然的大小比较规则。采用很多方法，都可以使得大小比较操作对这些复杂数据对象可以明确定义并且可行，比如最常见的就是在内部指定某一（些）可比较的数据项，并由此确立比较的规则。这里沿用2.5.3节的约定，假设复杂数据对象已经重载了"`<`"和"`<=`"等操作符。

2.6.2 有序性甄别

作为无序向量的特例，有序向量自然可以沿用无序向量的查找算法。然而，得益于元素之间的有序性，有序向量的查找、唯一化等操作都可更快地完成。因此在实施此类操作之前，都有必要先判断当前向量是否已经有序，以便确定是否可采用更为高效的接口。

```

1 template <typename T> int Vector<T>::disordered() const { //返回向量中逆序相邻元素对的总数
2     int n = 0; //计数器
3     for (int i = 1; i < _size; i++) //逐一检查_size - 1对相邻元素
4         if (_elem[i - 1] > _elem[i]) n++; //逆序则计数
5     return n; //向量有序当且仅当n = 0
6 }

```

代码2.17 有序向量甄别算法disordered()

代码2.17即为有序向量的一个甄别算法，其原理与1.1.3节起泡排序算法相同：顺序扫描整个向量，逐一比较每一对相邻元素——向量已经有序，当且仅当它们都是顺序的。

2.6.3 唯一化

相对于无序向量，有序向量中清除重复元素的操作更为重要。正如2.5.7节所指出的，出于效率的考虑，为清除无序向量中的重复元素，一般做法往往是首先将其转化为有序向量。

■ 低效版

```

1 template <typename T> int Vector<T>::uniquify() { //有序向量重复元素剔除算法（低效版）
2     int oldSize = _size; int i = 1; //当前比对元素的秩，起始于首元素
3     while (i < _size) //从前向后，逐一比对各对相邻元素
4         _elem[i - 1] == _elem[i] ? remove(i) : i++; //若雷同，则删除后者；否则，转至后一元素
5     return oldSize - _size; //向量规模变化量，即被删除元素总数
6 }

```

代码2.18 有序向量uniquify()接口的平凡实现

唯一化算法可实现如代码2.18所示，其正确性基于如下事实：有序向量中的重复元素必然前后紧邻。于是，可以自前向后地逐一检查各对相邻元素：若二者雷同则调用remove()接口删除靠后者，否则转向下一对相邻元素。如此，扫描结束后向量中将不再含有重复元素。

这里的运行时间，主要消耗于while循环，共需迭代 $_size - 1 = n - 1$ 步。此外，在最坏情况下，每次循环都需执行一次remove()操作，由2.3节的分析结论，其复杂度线性正比于被删除元素的后继元素总数。因此如图2.7所示，当大量甚至所有元素均雷同时，用于所有这些remove()操作的总量将高达：

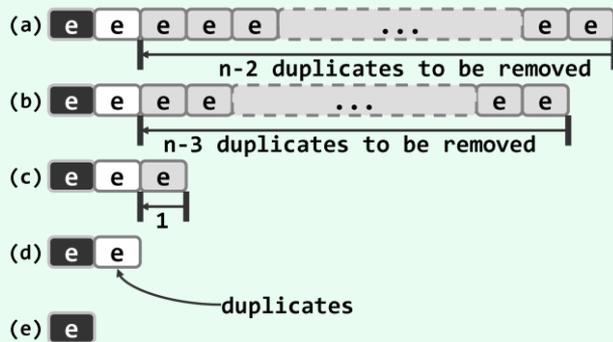


图2.7 低效版uniquify()算法的最坏情况

$$\begin{aligned}
 & (n - 2) + (n - 3) + \dots + 2 + 1 \\
 & = o(n^2)
 \end{aligned}$$

这一效率竟与向量未排序时相同，说明该方法未能充分利用此时向量的有序性。

改进思路

稍加分析即不难看出，以上唯一化过程复杂度过高的根源是，在对`remove()`接口的各次调用中，同一元素可能作为后继元素向前移动多次，且每次仅移动一个单元。

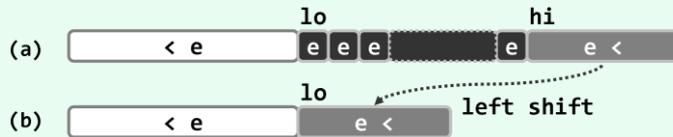


图2.8 有序向量中的重复元素可批量删除

如上所言，此时的每一组重复元素，都必然前后紧邻地集中分布。因此如图2.8所示，可以区间为单位成批地删除前后紧邻的各组重复元素，并将其后继元素（若存在）统一地大跨度前移。具体地，若 $V[lo, hi)$ 为一组紧邻的重复元素，则所有的后继元素 $V[hi, _size)$ 可统一地整体前移 $hi - lo - 1$ 个单元。

高效版

按照上述思路，可如代码2.19所示得到唯一化算法的新版本。

```

1 template <typename T> int Vector<T>::uniquify() { //有序向量重复元素剔除算法（高效版）
2     Rank i = 0, j = 0; //各对互异“相邻”元素的秩
3     while (++j < _size) //逐一扫描，直至末元素
4         if (_elem[i] != _elem[j]) //跳过雷同者
5             _elem[++i] = _elem[j]; //发现不同元素时，向前移至紧邻于前者右侧
6     _size = ++i; shrink(); //直接截除尾部多余元素
7     return j - i; //向量规模变化量，即被删除元素总数
8 }

```

代码2.19 有序向量`uniquify()`接口的高效实现

图2.9针对一个有序向量的实例，完整地给出了该算法对应的执行过程。

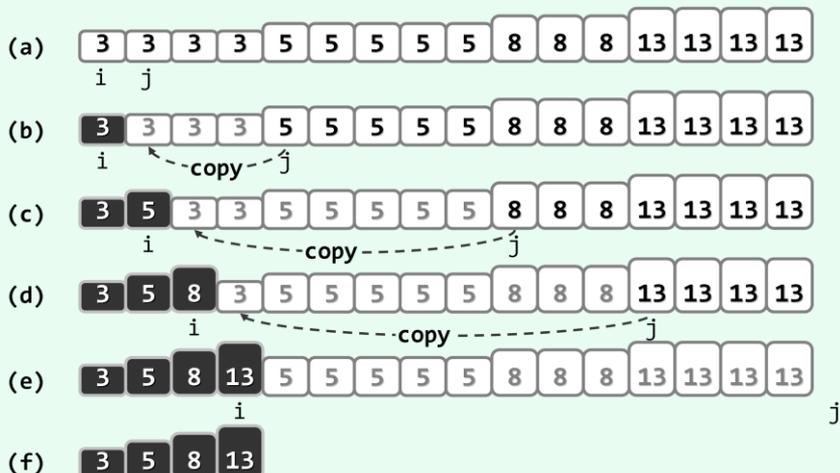


图2.9 在有序向量中查找互异的相邻元素

同样地，既然各组重复元素必然彼此相邻地构成一个子区间，故只需依次保留各区间的起始元素。于是，这里引入了变量*i*和*j*。每经过若干次移动，*i*和*j*都将分别指向下一对相邻子区间的首元素；在将后者转移至前者的后继位置之后，即可重复上述过程。具体地如图(a)所示，初始时*i* = 0和*j* = 1分别指向最靠前两个元素。

接下来，逐位后移*j*，直至指向A[*j*=4] = 5 ≠ A[*i*=0]。如图(b)，此时可见，*i*和*j*的确分别指向3和5所在分组的首元素。接下来，令*i* = 1，并将A[*j*=4] = 5前移至A[*i*=1]处。此时的*i*指向刚被前移的A[1] = 5；令*j* = *j* + 1 = 5指向待扫描的下一元素A[5] = 5，并继续比较。如图(c)，此轮比较终止于 A[*j*=9] = 8 ≠ A[*i*=1] = 5。

于是，令*i* = *i* + 1 = 2，并将A[*j*=9] = 8前移至A[*i*=2]处。此时的*i*指向刚被前移的A[2] = 8；令*j* = *j* + 1 = 10指向待扫描的下一元素A[10] = 8，并继续比较。如图(d)，此轮比较终止于A[12] = 13 ≠ A[*i*=2] = 8。于是，令*i* = *i* + 1 = 3，并将A[*j*=12] = 13前移至A[*i*=3]处。此时的*i*指向刚被前移的A[3] = 13；令*j* = *j* + 1 = 13指向待扫描的下一元素A[13] = 13，并继续比较。如图(e)，至*j* = 16 ≥ *_size*时，循环结束。最后如图(f)，只需将向量规模更新为*_size* = *i* + 1 = 4，算法随即结束。鉴于在删除重复元素之后内部数组的空间利用率可能下降很多，故需调用shrink()，如有必要则做缩容处理。

■ 复杂度

while循环的每一步迭代，仅需对元素数值做一次比较，向后移动一到两个位置指针，并至多向前复制一个元素，故只需常数时间。而在整个算法过程中，每经过一步迭代秩*j*都必然加一，鉴于*j*不能超过向量的规模*n*，故共需迭代*n*次。由此可知，uniquify()算法的时间复杂度应为 $O(n)$ ，较之uniquifySlow()的 $O(n^2)$ ，效率整整提高了一个线性因子。

反过来，在遍历所有元素之前不可能确定是否有重复元素，故就渐进复杂度而言，能在 $O(n)$ 时间内完成向量的唯一化已属最优。当然，之所以能够做到这一点，关键在于向量已经排序。

2.6.4 查找

有序向量S中的元素不再随机分布，秩*r*是S[*r*]在S中按大小的相对位次，位于S[*r*]前（后）方的元素均不致于更大（小）。当所有元素互异时，*r*即是S中小于S[*r*]的元素数目。一般地，若小于、等于S[*r*]的元素各有*i*、*k*个，则该元素及其雷同元素应集中分布于S[*i*, *i* + *k*)。

利用上述性质，有序向量的查找操作可以更加高效地完成。尽管在最坏情况下，无序向量的查找操作需要线性时间，但我们很快就会看到，有序向量的这一效率可以提升至 $O(\log n)$ 。

为区别于无序向量的查找接口find()，有序向量的查找接口将统一命名为search()。与find()一样，代码2.1也针对有序向量的整体或区间查找重载了两个search()接口，且前者作为特例可直接调用后者。因此，只需如代码2.20所示实现其中的区间查找接口。

```
1 template <typename T> //在有序向量的区间[lo, hi)内，确定不大于e的最后一个节点的秩
2 Rank Vector<T>::search(T const& e, Rank lo, Rank hi) const { //assert: 0 <= lo < hi <= _size
3     return (rand() % 2) ? //按各50%的概率随机使用
4         binSearch(_elem, e, lo, hi) : fibSearch(_elem, e, lo, hi); //二分查找或Fibonacci查找
5 }
```

代码2.20 有序向量各种查找算法的统一search()接口

鉴于有序查找的算法多样且各具特点，为便于测试，这里的接口不妨随机选择查找算法。实际应用中可根据问题的特点具体确定，并做适当微调。以下将介绍两类典型的查找算法。

2.6.5 二分查找（版本A）

■ 减而治之

循序访问的特点加上有序性，使得我们可将“减而治之”策略运用于有序向量的查找。具体地如图2.10所示，假设在区间 $S[lo, hi)$ 中查找目标元素 e 。

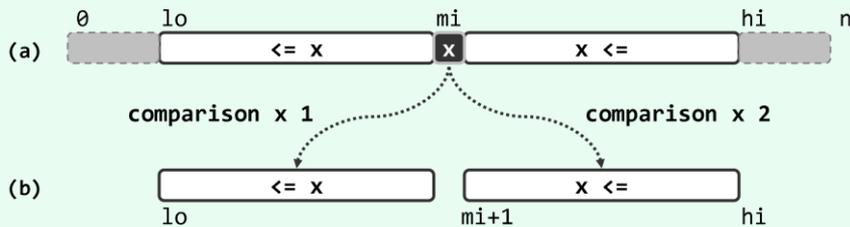


图2.10 基于减治策略的有序向量二分查找算法（版本A）

以任一元素 $S[mi] = x$ 为界，都可将区间分为三部分，且根据此时的有序性必有：

$$S[lo, mi) \leq S[mi] \leq S(mi, hi)$$

于是，只需将目标元素 e 与 x 做一比较，即可视比较结果分三种情况做进一步处理：1) 若 $e < x$ ，则目标元素如果存在，必属于左侧子区间 $S[lo, mi)$ ，故可深入其中继续查找；2) 若 $x < e$ ，则目标元素如果存在，必属于右侧子区间 $S(mi, hi)$ ，故也可深入其中继续查找；3) 若 $e = x$ ，则意味着已经在此处命中，故查找随即终止。

也就是说，每经过至多两次比较操作，我们或者已经找到目标元素，或者可以将查找问题简化为一个规模更小的新问题。如此，借助递归机制即可便捷地描述和实现此类算法。实际上，以下将要介绍的各种查找算法都可归入这一模式，不同点仅在于其对切分点 mi 的选取策略，以及每次深入递归之前所做比较操作的次数。

■ 实现

按上述思路实现的第一个算法如代码2.21所示。为区别于稍后将要介绍的同类算法的其它版本，不妨将其记作版本A。

```

1 // 二分查找算法（版本A）：在有序向量的区间[lo, hi)内查找元素e, 0 <= lo <= hi <= _size
2 template <typename T> static Rank binSearch(T* A, T const& e, Rank lo, Rank hi) {
3     while (lo < hi) { //每步迭代可能要做两次比较判断，有三个分支
4         Rank mi = (lo + hi) >> 1; //以中点为轴点
5         if (e < A[mi]) hi = mi; //深入前半段[lo, mi)继续查找
6         else if (A[mi] < e) lo = mi + 1; //深入后半段(mi, hi)继续查找
7         else return mi; //在mi处命中
8     } //成功查找可以提前终止
9     return -1; //查找失败
10 } //有多个命中元素时，不能保证返回秩最大者；查找失败时，简单地返回-1，而不能指示失败的位置

```

代码2.21 二分查找算法（版本A）

为在有序向量区间 $[lo, hi)$ 内查找元素 e ，该算法以中点 $mi = (lo + hi) / 2$ 为界，将其大致平均地分为前、后两个子向量。随后通过一至两次比较操作，确定问题转化的方向。通过快捷的整数移位操作回避了相对更加耗时的除法运算。另外，通过引入 lo 、 hi 和 mi 等变量，将递归算法通常的递归模式改成了迭代模式。

■ 实例

如图2.11左侧所示，设通过调用`search(8, 0, 7)`，在有序向量区间 $S[0, 7)$ 内查找目标元素8。第一步迭代如图(a1)所示，取 $mi = (0 + 7) / 2 = 3$ ，经过1次失败的比较另加1次成功的比较后确认 $S[mi = 3] = 7 < 8$ ，故深入后半段 $S[4, 7)$ 。第二步迭代如图(a2)所示，取 $mi = (4 + 7) / 2 = 5$ ，经过1次成功的比较后确认 $8 < S[mi = 5] = 9$ ，故深入前半段 $S[4, 5)$ 。最后一步迭代如图(a3)所示，取 $mi = (4 + 5) / 2 = 4$ ，经过2次失败的比较后确认 $8 = S[mi = 4]$ 。前后总共经过3步迭代和5次比较操作，最终通过返回合法的秩 $mi = 4$ ，指示对目标元素8的查找在元素 $S[4]$ 处成功命中。



图2.11 二分查找算法（版本A）实例：`search(8, 0, 7)`成功，`search(3, 0, 7)`失败

再如图2.11右侧所示，设通过调用`search(3, 0, 7)`，在同一向量区间内查找目标元素3。第一步迭代如图(b1)所示，取 $mi = (0 + 7) / 2 = 3$ ，经过1次成功的比较后确认 $3 < S[mi = 3] = 7$ ，故深入前半段 $S[0, 3)$ 。第二步迭代如图(b2)所示，取 $mi = (0 + 3) / 2 = 1$ ，经过1次成功的比较后确认 $3 < S[mi = 1] = 4$ ，故深入前半段 $S[0, 1)$ 。第三步迭代如图(b3)所示，取 $mi = (0 + 1) / 2 = 0$ ，经过1次失败的比较另加1次成功的比较后确认 $S[mi = 0] = 2 < 3$ ，故深入“后半段” $S[1, 1)$ 。此时因为 $lo = 1 = hi$ ，故最后一步迭代实际上并不会执行；`while`循环退出后，算法通过返回非法的秩-1指示查找失败。纵观整个查找过程，前后总共经过4步迭代和4次比较操作。

■ 复杂度

以上算法采取的策略可概括为，以“当前区间内居中的元素”作为目标元素的试探对象。从应对最坏情况的保守角度来看，这一策略是最优的——每一步迭代之后无论沿着哪个方向深入，新问题的规模都将缩小一半。因此，这一策略亦称作二分查找（`binary search`）。

也就是说，随着迭代的不断深入，有效的查找区间宽度将按 $1/2$ 的比例以几何级数的速度递减。于是，经过至多 $\log_2(hi - lo)$ 步迭代后，算法必然终止。鉴于每步迭代仅需常数时间，故总体时间复杂度不超过：

$$O(\log_2(hi - lo)) = O(\log n)$$

与代码2.10中顺序查找算法的 $O(n)$ 复杂度相比， $O(\log n)$ 几乎改进了一个线性因子。

■ 查找长度

以上迭代过程所涉及的计算，主要分为两类：元素的大小比较、秩的算术运算及其赋值。虽然二者均属于 $O(1)$ 复杂度的基本操作，但元素的秩无非是（无符号）整数，而向量元素的类型则通常更为复杂，甚至复杂到未必能够保证在常数时间内完成（习题[2-17]）。因此就时间复杂度的常系数而言，前一类计算的权重远远高于后者，而查找算法的整体效率也更主要地取决于其中所执行的元素大小比较操作的次数，即所谓查找长度（search length）。

通常，可针对查找成功或失败等情况，从最好、最坏和平均情况等角度，分别测算查找长度，并凭此对查找算法的总体性能做一评估。

■ 成功查找长度

对于长度为 n 的有序向量，共有 n 种可能的成功查找，分别对应于某一元素。实际上，每一种成功查找所对应的查找长度，仅取决于 n 以及目标元素所对应的秩，而与元素的具体数值无关。比如，回顾图2.11中的实例不难看出，无论怎样修改那7个元素的数值，只要它们依然顺序排列，则针对 $S[4]$ 的查找过程（包括各步迭代的比较次数以及随后的深入方向）必然与在原例中执行 $\text{search}(8, 0, 7)$ 的过程完全一致。

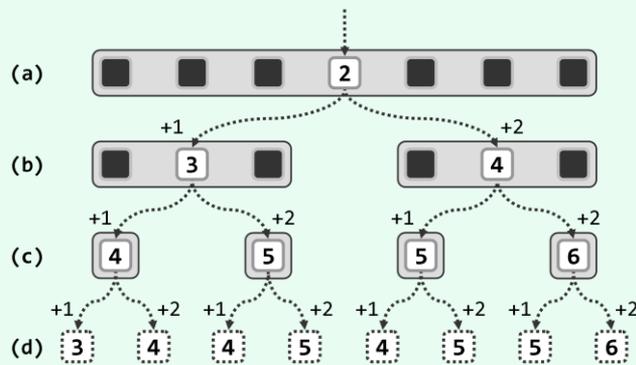


图2.12 二分查找算法（版本A）的查找长度（成功、失败查找分别以实线、虚线白色方框示意）

当 $n = 7$ 时由图2.12不难验证，各元素所对应的成功查找长度分别为：

$$\{ 4, 3, 5, 2, 5, 4, 6 \}$$

若假定查找的目标元素按等概率分布，则平均查找长度即为：

$$(4 + 3 + 5 + 2 + 5 + 4 + 6) / 7 = 29 / 7 = 4.14$$

为了估计出一般情况下的成功查找长度，不失一般性地，仍在等概率条件下考查长度为 $n = 2^k - 1$ 的有序向量，并将其对应的平均成功查找长度记作 $c_{\text{average}}(k)$ ，将所有元素对应的查找长度总和记作 $C(k) = c_{\text{average}}(k) \cdot (2^k - 1)$ 。

特别地，当 $k = 1$ 时向量长度 $n = 1$ ，成功查找仅有一种情况，故有边界条件：

$$c_{\text{average}}(1) = C(1) = 2$$

以下采用递推分析法。对于长度为 $n = 2^k - 1$ 的有序向量，每步迭代都有三种可能的分支：经过1次成功的比较后，转化为一个规模为 $2^{k-1} - 1$ 的新问题（图2.12中的左侧分支）；经2次失败的比较后，终止于向量中的某一元素，并确认在此处成功命中；经1次失败的比较另加1次成功的比较后，转化为另一个规模为 $2^{k-1} - 1$ 的新问题（图2.12中的右侧分支）。

根据以上递推分析的结论，可得递推式如下：

$$\begin{aligned} C(k) &= [C(k-1) + (2^{k-1} - 1)] + 2 + [C(k-1) + 2 \times (2^{k-1} - 1)] \quad (\text{式2-1}) \\ &= 2 \cdot C(k-1) + 3 \cdot 2^{k-1} - 1 \end{aligned}$$

若令：

$$F(k) = C(k) - 3k \cdot 2^{k-1} - 1$$

则有：

$$\begin{aligned} F(1) &= -2 \\ F(k) &= 2 \cdot F(k-1) = 2^2 \cdot F(k-2) = 2^3 \cdot F(k-3) = \dots \\ &= 2^{k-1} \cdot F(1) = -2^k \end{aligned}$$

于是：

$$\begin{aligned} C(k) &= F(k) + 3k \times 2^{k-1} + 1 \\ &= -2^k + 3k \times 2^{k-1} + 1 \\ &= (3k/2 - 1) \cdot (2^k - 1) + 3k/2 \end{aligned}$$

进而：

$$\begin{aligned} C_{\text{average}}(k) &= C(k) / (2^k - 1) \\ &= 3k/2 - 1 + 3k/2 / (2^k - 1) \\ &= 3k/2 - 1 + o(\varepsilon) \end{aligned}$$

也就是说，若忽略末尾趋于收敛的波动项，平均查找长度应为：

$$o(1.5k) = o(1.5 \cdot \log_2 n)$$

■ 失败查找长度

按照代码2.21，失败查找的终止条件必然是“ $lo \geq hi$ ”，也就是说，只有在有效区间宽度缩减至0时，查找方以失败告终。因此，失败查找的时间复杂度应为确定的 $\Theta(\log n)$ 。

不难发现，就各步迭代后分支方向的组合而言，失败查找可能的情况，恰好比成功查找可能的情况多出一种。例如在图2.12中，失败查找共有 $7 + 1 = 8$ 种可能。由图2.12不难验证，各种可能所对应的查找长度分别为：

$$\{ 3, 4, 4, 5, 4, 5, 5, 6 \}$$

其中，最好情况下需要做3次元素比较，最坏情况下需要做6次元素比较。若同样地假定待查找目标元素按等概率分布，则平均查找长度应为：

$$(3 + 4 + 4 + 5 + 4 + 5 + 5 + 6) / 8 = 36 / 8 = 4.50$$

仿照以上对平均成功查找长度的递推分析方法，不难证明（习题[2-20]），一般情况下的平均失败查找长度亦为 $o(1.5 \cdot \log_2 n)$ 。

■ 不足

尽管二分查找算法（版本A）即便在最坏情况下也可保证 $o(\log n)$ 的渐进时间复杂度，但就其常系数1.5而言仍有改进余地。以成功查找为例，即便是迭代次数相同的情况，对应的查找长度也不尽相等。究其根源在于，在每一步迭代中为确定左、右分支方向，分别需要做1次或2次元素比较，从而造成不同情况所对应查找长度的不均衡。尽管该版本从表面上看完全均衡，但我们通过以上细致的分析已经看出，最短和最长分支所对应的查找长度相差约两倍。

那么，能否实现更好的均衡呢？具体又应如何实现呢？

2.6.6 Fibonacci查找

■ 递推方程

递推方程既是复杂度分析的重要方法，也是我们优化算法时确定突破口的有力武器。为改进以上二分查找算法的版本A，不妨从刻画查找长度随向量长度递推变化的式2-1入手。

实际上，最终求解所得到的平均复杂度，在很大程度上取决于这一等式。更准确地讲，主要取决于 $(2^{k-1} - 1)$ 和 $2 \times (2^{k-1} - 1)$ 两项，其中的 $(2^{k-1} - 1)$ 为子向量的宽度，而系数1和2则是算法为深入前、后子向量，所需做的比较操作次数。以此前的二分查找算法版本A为例，之所以存在均衡性方面的缺陷，根源正在于这两项的大小不相匹配。

基于这一理解，不难找到解决问题的思路，具体地不外乎两种：

- 其一，调整前、后区域的宽度，适当地加长（缩短）前（后）子向量
- 其二，统一沿两个方向深入所需要执行的比较次数，比如都统一为一次

后一思路的实现将在稍后介绍，以下首先介绍前一思路的具体实现。

■ 黄金分割

实际上，减治策略本身并不要求子向量切分点 mi 必须居中，故按上述改进思路，不妨按黄金分割比来确定 mi 。为简化起见，不妨设向量长度 $n = fib(k) - 1$ 。

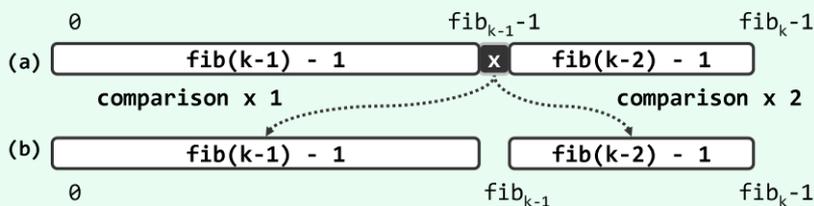


图2.13 Fibonacci查找算法原理

于是如图2.13所示， $fibSearch(e, 0, n)$ 查找可以 $mi = fib(k - 1) - 1$ 作为前、后子向量的切分点。如此，前、后子向量的长度将分别是：

$$fib(k - 1) - 1$$

$$fib(k - 2) - 1 = (fib(k) - 1) - (fib(k - 1) - 1) - 1$$

于是，无论朝哪个方向深入，新向量的长度从形式上都依然是某个Fibonacci数减一，故这一处理手法可以反复套用，直至因在 $S[mi]$ 处命中或向量长度收缩至零而终止。这种查找算法，亦称作Fibonacci查找（Fibonacci search）。

■ 实现

按照以上思路，可实现Fibonacci查找算法如代码2.22所示。

```
1 #include "..\fibonacci\Fib.h" //引入Fib数列类
2 // Fibonacci查找算法(版本A)：在有序向量的区间[lo, hi)内查找元素e, 0 <= lo <= hi <= _size
3 template <typename T> static Rank fibSearch(T* A, T const& e, Rank lo, Rank hi) {
4     Fib fib(hi - lo); //用O(log_phi(n = hi - lo))时间创建Fib数列
5     while (lo < hi) { //每步迭代可能要做两次比较判断，有三个分支
6         while (hi - lo < fib.get()) fib.prev(); //通过向前顺序查找(分摊O(1))——至多迭代几次?
7         Rank mi = lo + fib.get() - 1; //确定形如Fib(k) - 1的轴点
```

```

8     if      (e < A[mi]) hi = mi; //深入前半段[lo, mi)继续查找
9     else if (A[mi] < e) lo = mi + 1; //深入后半段(mi, hi)继续查找
10    else          return mi; //在mi处命中
11  } //成功查找可以提前终止
12  return -1; //查找失败
13 } //有多个命中元素时, 不能保证返回秩最大者; 失败时, 简单地返回-1, 而不能指示失败的位置

```

代码2.22 Fibonacci查找算法

算法主体框架与二分查找大致相同, 主要区别在于以黄金分割点取代中点作为切分点。为此, 需要借助Fib对象(习题[1-22]), 实现对Fibonacci数的高效设置与获取。

尽管以下的分析多以长度为 $\text{fib}(k) - 1$ 的向量为例, 但这一实现完全可适用于长度任意的向量中的任意子向量。为此, 只需在进入循环之前调用构造器 $\text{Fib}(n = \text{hi} - \text{lo})$, 将初始长度设置为“不小于 n 的最小Fibonacci项”。这一步所需花费的 $\mathcal{O}(\log_{\phi} n)$ 时间, 分摊到后续的 $\mathcal{O}(\log_{\phi} n)$ 步迭代中, 并不影响算法整体的渐进复杂度。

■ 定性比较

可见, Fibonacci查找倾向于适当加长(缩短)需1次(2次)比较方可确定的前端(后端)子向量。故定性粗略估计, 应可(在常系数的意义上)进一步提高查找的效率。

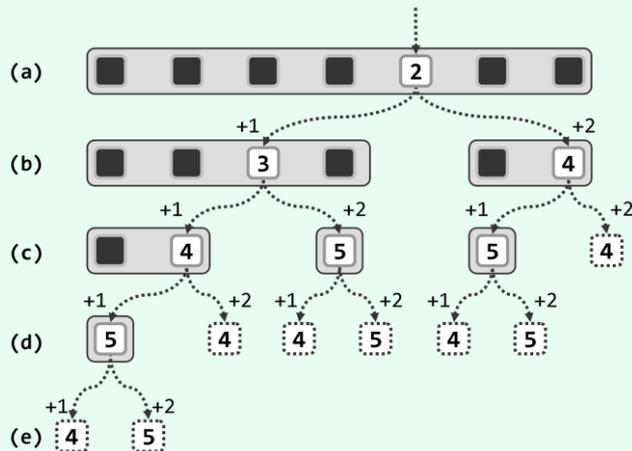


图2.14 Fibonacci查找算法的查找长度(成功、失败查找分别以实线、虚线白色方框示意)

作为验证, 不妨仍以 $n = \text{fib}(6) - 1 = 7$ 为例, 就平均查找长度与二分查找做一对比。

如图2.14所示, 7种成功情况、8种失败情况的查找长度分别为:

$$\{ 5, 4, 3, 5, 2, 5, 4 \}$$

$$\{ 4, 5, 4, 4, 5, 4, 5, 4 \}$$

若依然假定各种情况出现的概率相等, 则平均成功查找长度和平均失败查找长度应分别为:

$$(5 + 4 + 3 + 5 + 2 + 5 + 4) / 7 = 28 / 7 = 4.00$$

$$(4 + 5 + 4 + 4 + 5 + 4 + 5 + 4) / 8 = 35 / 8 = 4.38$$

相对于二分查找算法版本A实例(图2.12)的4.14和4.50, 的确有所改进。

■ 定量分析

参照2.6.5节的方法，也可对Fibonacci查找算法的成功查找长度做出更为精确的分析。其中关于最好、最坏情况的结论完全一致，故以下仅讨论等概率条件下的平均情况。

依然将长度为 $n = \text{fib}(k) - 1$ 的有序向量的平均成功查找长度记作 $C_{\text{average}}(k)$ ，将所有元素对应的查找长度总和记作 $C(k) = C_{\text{average}}(k) \cdot (\text{fib}(k) - 1)$ 。

同理，可得边界条件及递推式如下：

$$C_{\text{average}}(2) = C(2) = 0$$

$$C_{\text{average}}(3) = C(3) = 2$$

$$\begin{aligned} C(k) &= [C(k-1) + (\text{fib}(k-1) - 1)] + 2 + [C(k-2) + 2 \times (\text{fib}(k-2) - 1)] \\ &= C(k-2) + C(k-1) + \text{fib}(k-2) + \text{fib}(k) - 1 \end{aligned}$$

结合以上边界条件，可以解得：

$$C(k) = \textcircled{1} k \cdot \text{fib}(k) - \text{fib}(k+2) + 1 = (k - \Phi^2) \cdot \text{fib}(k) + 1 + o(\varepsilon)$$

其中， $\Phi = (\sqrt{5} + 1) / 2 = 1.618$

于是

$$\begin{aligned} C_{\text{average}}(k) &= C(k) / (\text{fib}(k) - 1) \\ &= k - \Phi^2 + 1 + (k - \Phi^2) / (\text{fib}(k) - 1) + o(\varepsilon) \\ &= k - \Phi^2 + 1 + o(\varepsilon) \end{aligned}$$

也就是说，忽略末尾趋于收敛的波动项，平均查找长度的增长趋势为：

$$o(k) = o(\log_{\Phi} n) = o(\log_{\Phi} 2 \cdot \log_2 n) = o(1.44 \cdot \log_2 n)$$

较之2.6.5节二分查找算法（版本A）的 $o(1.50 \cdot \log_2 n)$ ，效率略有提高。

2.6.7 二分查找（版本B）

■ 从三分支到两分支

2.6.6节开篇曾指出，二分查找算法版本A的不均衡性体现为复杂度递推式中 $(2^{k-1} - 1)$ 和 $2 \times (2^{k-1} - 1)$ 两项的不均衡。为此，Fibonacci查找算法已通过采用黄金分割点，在一定程度上降低了时间复杂度的常系数。实际上还有另一更为直接的方法，即令以上两项的常系数同时等于1。也就是说，无论朝哪个方向深入，都只需做1次元素的大小比较。相应地，算法在每步迭代中（或递归层次上）都只有两个分支方向，而不再是三个。

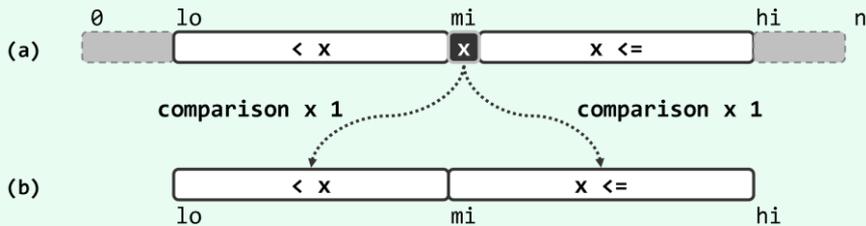


图2.15 基于减治策略的有序向量二分查找算法（版本B）

^① 令 $F(k) = -C(k) + k \cdot \text{fib}(k) + 1$ ，则有 $F(0) = 1, F(1) = 2, F(k) = F(k-1) + F(k-2) = \text{fib}(k+2)$

具体过程如图2.15所示，与二分查找算法的版本A基本类似。不同之处是，在每个切分点A[mi]处，仅做一次元素比较。具体地，若目标元素小于A[mi]，则深入前端子向量A[lo, mi)继续查找；否则，深入后端子向量A[mi, hi)继续查找。

■ 实现

按照上述思路，可将二分查找算法改进为如代码2.23所示的版本B。

```
1 // 二分查找算法(版本B)：在有序向量的区间[lo, hi)内查找元素e, 0 <= lo <= hi <= _size
2 template <typename T> static Rank binSearch(T* A, T const& e, Rank lo, Rank hi) {
3     while (1 < hi - lo) { //每步迭代仅需做一次比较判断, 有两个分支; 成功查找不能提前终止
4         Rank mi = (lo + hi) >> 1; //以中点为轴点
5         (e < A[mi]) ? hi = mi : lo = mi; //经比较后确定深入[lo, mi)或[mi, hi)
6     } //出口时hi = lo + 1, 查找区间仅含一个元素A[lo]
7     return (e == A[lo]) ? lo : -1; //查找成功时返回对应的秩; 否则统一返回-1
8 } //有多个命中元素时, 不能保证返回秩最大者; 查找失败时, 简单地返回-1, 而不能指示失败的位置
```

代码2.23 二分查找算法(版本B)

请再次留意与代码2.21中版本A的差异。首先，每一步迭代只需判断是否 $e < A[mi]$ ，即可相应地更新有效查找区间的右边界($hi = mi$)或左边界($lo = mi$)。另外，只有等到区间的宽度已不足2个单元时迭代才会终止，最后再通过一次比对判断查找是否成功。

■ 性能

尽管版本B中的后端子向量需要加入A[mi]，但得益于mi总是位于中央位置，整个算法 $O(\log n)$ 的渐进复杂度不受任何影响。

在这一版本中，只有在向量有效区间宽度缩短至1个单元时算法才会终止，而不能如版本A那样，一旦命中就能及时返回。因此，最好情况下的效率有所倒退。当然，作为补偿，最坏情况下的效率相应地有所提高。实际上无论是成功查找或失败查找，版本B各分支的查找长度更加接近，故整体性能更趋稳定。

■ 进一步的要求

在更多细微之处，此前实现的二分查找算法(版本A和B)及Fibonacci查找算法仍有改进的余地。比如，当目标元素在向量中重复出现时，它们只能“随机”地报告其一，具体选取何者取决于算法的分支策略以及当时向量的组成。而在很多场合中，重复元素之间往往会隐含地定义有某种优先级次序，而且算法调用者的确可能希望得到其中优先级最高者。比如按照表2.1的定义，在有多个命中元素时，向量的search()接口应以它们的秩为优先级，并返回其中最靠后者。

这种进一步的要求并非多余。以有序向量的插入操作为例，若通过查找操作不仅能够确定可行的插入位置，而且能够在同时存在多个可行位置时保证返回其中的秩最大者，则不仅可以尽可能低减少需移动的后继元素，更可保证重复的元素按其插入的相对次序排列。对于向量的插入排序等算法(习题[3-8])的稳定性而言，这一性质更是至关重要。

另外，对失败查找的处理方式也可以改进。查找失败时，以上算法都是简单地统一返回一个标识“-1”。同样地，若在插入新元素e之前通过查找确定适当的插入位置，则希望在查找失败时返回不大(小)于e的最后(前)一个元素，以便将e作为其后继(前驱)插入向量。同样地，此类约定也使得插入排序等算法的实现更为便捷和自然。

2.6.8 二分查找（版本C）

■ 实现

在版本B的基础上略作修改，即可得到如代码2.24所示二分查找算法的版本C。

```

1 // 二分查找算法（版本C）：在有序向量的区间[lo, hi)内查找元素e, 0 <= lo <= hi <= _size
2 template <typename T> static Rank binSearch(T* A, T const& e, Rank lo, Rank hi) {
3     while (lo < hi) { //每步迭代仅需做一次比较判断, 有两个分支
4         Rank mi = (lo + hi) >> 1; //以中点为轴点
5         (e < A[mi]) ? hi = mi : lo = mi + 1; //经比较后确定深入[lo, mi)或(mi, hi)
6     } //成功查找不能提前终止
7     return --lo; //循环结束时, lo为大于e的元素的最小秩, 故lo - 1即不大于e的元素的最大秩
8 } //有多个命中元素时, 总能保证返回秩最大者; 查找失败时, 能够返回失败的位置

```

代码2.24 二分查找算法（版本C）

该版本的主体结构与版本B一致，故不难理解，二者的时间复杂度相同。

■ 正确性

版本C与版本B的差异，主要有三点。首先，只有当有效区间的宽度缩短至0（而不是1）时，查找方告终止。另外，在每次转入后端分支时，子向量的左边界取作 $mi + 1$ 而不是 mi 。

表面上看，后一调整存在风险——此时只能确定切分点 $A[mi] \leq e$ ，“贸然”地将 $A[mi]$ 排除在进一步的查找范围之外，似乎可能因遗漏这些元素，而导致本应成功的查找以失败告终。

然而这种担心大可不必。通过数学归纳可以证明，版本C中的循环体，具有如下不变性：

$A[0, lo)$ 中的元素皆不大于 e ； $A[hi, n)$ 中的元素皆大于 e

首次迭代时， $lo = 0$ 且 $hi = n$ ， $A[0, lo)$ 和 $A[hi, n)$ 均空，不变性自然成立。

如图2.16(a)所示，设在某次进入循环时以上不变性成立，以下无非两种情况。若 $e < A[mi]$ ，则如图(b)，在令 $hi = mi$ 并使 $A[hi, n)$ 向左扩展之后，该区间内的元素皆不小于 $A[mi]$ ，当然也仍然大于 e 。反之，若 $A[mi] \leq e$ ，则如图(c)，在令 $lo = mi + 1$ 并使 $A[0, lo)$ 向右拓展之后，该区间内的元素皆不大于 $A[mi]$ ，当然也仍然不大于 e 。总之，上述不变性必然得以延续。

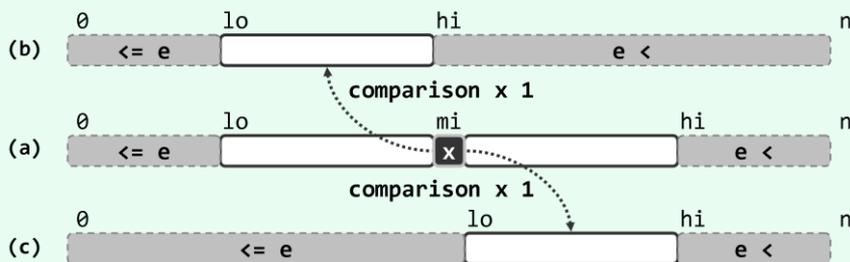


图2.16 基于减治策略的有序向量二分查找算法（版本C）

循环终止时， $lo = hi$ 。考查此时的元素 $A[lo - 1]$ 和 $A[lo]$ ：作为 $A[0, lo)$ 内的最后一个元素， $A[lo - 1]$ 必不大于 e ；作为 $A[lo, n) = A[hi, n)$ 内的第一个元素， $A[lo]$ 必大于 e 。也就是说， $A[lo - 1]$ 即是原向量中不大于 e 的最后一个元素。因此在循环结束之后，无论成功与否，只需返回 $lo - 1$ 即可——这也是版本C与版本B的第三点差异。

§ 2.7 *排序与下界

2.7.1 有序性

从数据处理的角度看，有序性在很多场合都能够极大地提高计算的效率。以查找算法为例，对于无序向量，正如此前的分析结论，代码2.10中`Vector::find()`算法 $O(n)$ 的复杂度已属最优。而对于有序向量，代码2.20中`Vector::search()`接口的效率，则可优化到 $O(\log n)$ 。我们知道，为此需要借助二分查找策略，而之所以这一策略可行，正是因为所有元素已按次序排列。

2.7.2 排序及其分类

由以上介绍可见，有序向量的诸如查找等操作，效率远高于一般向量。因此在解决许多应用问题时我们普遍采用的一种策略就是，首先将向量转换为有序向量，再调用有序向量支持的各种高效算法。这一过程的本质就是向量的排序。为此，正如2.6.1节所指出的，向量元素之间必须能够定义某种全序关系，以保证它们可相互比较大小。

排序算法是个庞大的家族，可从多个角度对其中的成员进行分类。比如，根据其处理数据的规模与存储的特点不同，可分为内部排序算法和外部排序算法：前者处理的数据规模相对不大，内存足以容纳；后者处理的数据规模很大，必须借助外部甚至分布式存储器，在排序计算过程的任一时刻，内存中只能容纳其中一小部分数据。

又如，根据输入形式的不同，排序算法也可分为离线算法（**offline algorithm**）和在线算法（**online algorithm**）。前一情况下，待排序的数据以批处理的形式整体给出；而在网络计算之类的环境中，待排序的数据通常需要实时生成，在排序算法启动后数据才陆续到达。再如，针对所依赖的体系结构不同，又可分为串行和并行两大类排序算法。另外，根据排序算法是否采用随机策略，还有确定式和随机式之分。

本书讨论的范围，主要集中于确定式串行脱机的内部排序算法。

2.7.3 下界

根据1.2.2节的分析，1.1.3节起泡排序算法的复杂度为 $O(n^2)$ 。那么，这一效率是否已经足够高？能否以更快的速度完成排序？实际上，在着手优化算法之前，这都是首先必须回答的问题。以下结合具体实例，从复杂度下界的角度介绍回答此类问题的一般性方法。

■ 苹果鉴别

考虑如下问题：三只苹果外观一样，其中两只重量相同另一只不同，利用一架天平如何从中找出重量不同的那只？一种直观的方法可以描述为算法2.1。

该算法的可行性、正确性毋庸置疑。该算法在最好情况下仅需执行一次比对操作，最坏情况下两次。那么，是否存在其它算法，即便在最坏情况下也至多只需一次比对呢？

```
identifyApple(A, B, C)
```

输入：三只苹果A、B和C，其中两只重量相同，另一只不同
输出：找出重量不同的那只苹果

```
{
    称量A和B；若A和B重量相等，则返回C；
    称量A和C；若A和C重量相等，则返回B；
    否则，返回A；
}
```

算法2.1 从三个苹果中选出重量不同者

■ 复杂度下界

尽管很多算法都可以优化,但有一个简单的事实却往往为人所忽略:对任一特定的应用问题,随着算法的不断改进,其效率的提高必然存在某一极限。毕竟,我们不能奢望不劳而获。这一极限不仅必然存在,而且其具体的数值,应取决于应用问题本身以及所采用的计算模型。

一般地,任一问题在最坏情况下的最低计算成本,即为该问题的复杂度下界(lower bound)。一旦某一算法的性能达到这一下界,即意味着它已是最坏情况下最优的(worst-case optimal)。可见,尽早确定一个问题的复杂度下界,对相关算法的优化无疑会有巨大的裨益。比如上例所提出的问题,就是从最坏情况的角度,质疑“2次比对操作”是否为解决这一问题的最低复杂度。

以下结合比较树模型,介绍界定问题复杂度下界的一种重要方法。

2.7.4 比较树

■ 基于比较的分支

如果用节点(圆圈)表示算法过程中的不同状态,用有方向的边(直线段或弧线段)表示不同状态之间的相互转换,就可以将以上算法2.1转化为图2.17的树形结构(第5章)。

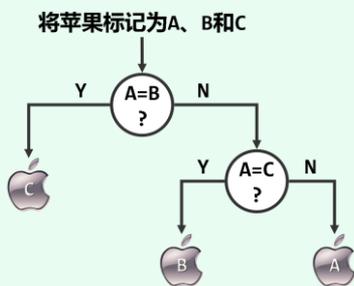


图2.17 从三只苹果中挑出重量不同者

仍以图2.17为例,从根节点到叶节点C的路径对应于,在经过一次称量比较并确定A与B等重后,即可断定C是所要查找的苹果。再如,从根节点到叶节点B的路径对应于,在经过两次称量比较并确定A与B不等重、A与C等重之后,即可判定B是所要查找的苹果。

■ 比较树

算法所有可能的执行过程,都可涵盖于这一树形结构中。具体地,该树具有以下性质:

- ① 每一内部节点各对应于一次比对(称量)操作;
- ② 内部节点的左、右分支,分别对应于在两种比对结果(是否等重)下的执行方向;
- ③ 叶节点(或等效地,根到叶节点的路径)对应于算法某次执行的完整过程及输出;
- ④ 反过来,算法的每一运行过程都对应于从根到某一叶节点的路径。

按上述规则与算法相对应的树,称作比较树(comparison tree)。

不难理解,无论什么算法,只要其中的分支都如算法2.1那样,完全取决于不同变量或常量的比对或比较结果,则该算法所有可能的执行过程都可表示和概括为一棵比较树。反之,凡可如此描述的算法,都称作基于比较式算法(comparison-based algorithm),简称CBA式算法。比如在本书中,除散列之外的算法大多属于此类。

以下我们将看到,CBA式算法在最坏情况下的最低执行成本,可由对应的比较树界定。

这一转化方法也可以推广并应用于其它算法。一般地,树根节点对应于算法入口处的起始状态(如此处三个苹果已做好标记);内部节点(即非末端节点,图中以白色大圈示意)对应于过程中的某步计算,通常属于基本操作;叶节点(即末端节点,图中以黑色小圈示意)则对应于经一系列计算后某次运行的终止状态。如此借助这一树形结构,可以涵盖对应算法所有可能的执行流程。

2.7.5 估计下界

■ 最小树高

考查任一CBA式算法A，设CT(A)为与之对应的一棵比较树。

根据比较树的性质，算法A每一次运行所需的时间，将取决于其对应叶节点到根节点的距离（称作叶节点的深度）；而算法A在最坏情况下的运行时间，将取决于比较树中所有叶节点的最大深度（称作该树的高度，记作 $h(\text{CT}(\text{A}))$)。因此就渐进的意义而言，算法A的时间复杂度应不低于 $\Omega(h(\text{CT}(\text{A})))$ 。

对于存在CBA式算法的计算问题，既然其任一CBA式算法均对应于某棵比较树，该问题的复杂度下界就应等于这些比较树的最小高度。问题在于，如何估计这些比较树的最小高度呢？

为此，只需考查树中所含叶节点（可能的输出结果）的数目。具体地，在一棵高度为 h 的二叉树中，叶节点的数目不可能多于 2^h 。因此反过来，若某一问题的输出结果不少于 N 种，则比较树中叶节点也不可能少于 N 个，树高 h 不可能低于 $\log_2 N$ （习题[7-3]）。

■ 苹果鉴别

仍以算法2.1为例。就该问题而言，可能的输出结果共计 $N = 3$ 种（不同的苹果分别为A、B或C），故解决该问题的任一CBA式算法所对应比较树的高度为：

$$h \geq \lceil \log_2 3 \rceil = 2$$

因此，只要是采用CBA式算法来求解该问题，则无论如何优化，在最坏情况下都至少需要2次称量——尽管最好情况下的确仍可能仅需1次。这也意味着，算法2.1虽平淡无奇，却已是解决苹果鉴别问题的最佳CBA式算法。

■ 排序

再以CBA式排序算法为例。就 n 个元素的排序问题而言，可能的输出共有 $N = n!$ 种。与上例略有不同之处在于，元素之间不仅可以判等而且可以比较大小，故此时的比较树应属于三叉树，即每个内部节点都有三个分支（分别对应小于、相等和大于的情况）。不过，这并不影响上述分析方法的运用。按照以上思路，任一CBA式排序算法所对应比较树的高度应为：

$$h \geq \lceil \log_3(n!) \rceil = \lceil \log_3 e \cdot \ln(n!) \rceil =^{\textcircled{2}} \Omega(n \log n)$$

可见，最坏情况下CBA式排序算法至少需要 $\Omega(n \log n)$ 时间，其中 n 为待排序元素数目。

需强调的是，这一 $\Omega(n \log n)$ 下界是针对比较树模型而言的。事实上，还有很多不属此类的排序算法（比如9.4.1节的桶排序算法和9.4.3节的基数排序算法），而且其中一些算法在最坏情况下的运行时间，有可能低于这一下界，但与上述结论并不矛盾。

§ 2.8 排序器

2.8.1 统一入口

鉴于排序在算法设计与实际应用中的重要地位和作用，排序操作自然应当纳入向量基本接口的范围。这类接口也是将无序向量转换为有序向量的基本方法和主要途径。

^② 由Stirling逼近公式， $n! \sim \sqrt{2\pi n} \cdot (n/e)^n$

```

1 template <typename T> void Vector<T>::sort(Rank lo, Rank hi) { //向量区间[lo, hi)排序
2     switch (rand() % 5) { //随机选取排序算法。可根据具体问题的特点灵活选取或扩充
3         case 1: bubbleSort(lo, hi); break; //起泡排序
4         case 2: selectionSort(lo, hi); break; //选择排序(习题)
5         case 3: mergeSort(lo, hi); break; //归并排序
6         case 4: heapSort(lo, hi); break; //堆排序(稍后介绍)
7         default: quickSort(lo, hi); break; //快速排序(稍后介绍)
8     }
9 }

```

代码2.25 向量排序器接口

针对任意合法向量区间的排序需求，代码2.25定义了统一的入口，并提供起泡排序、选择排序（习题[3-9]）、归并排序、堆排序（10.2.5节）和快速排序（12.1节）等多种算法。为便于测试和对比，这里暂以随机方式确定每次调用的具体算法。在了解这些算法各自所长之后，读者可结合各自具体的应用，根据实际需求灵活地加以选用。

以下先将起泡排序算法集成至向量ADT中，然后讲解归并排序算法的原理、实现。

2.8.2 起泡排序

起泡排序算法已在1.1.3节讲解并实现，这里只需将其集成至向量ADT中。

■ 起泡排序

```

1 template <typename T> //向量的起泡排序
2 void Vector<T>::bubbleSort(Rank lo, Rank hi) //assert: 0 <= lo < hi <= size
3 { while (!bubble(lo, hi--)); } //逐趟做扫描交换，直至全序

```

代码2.26 向量的起泡排序

代码2.26给出了起泡排序算法的主体框架，其功能等效于代码1.1中的外层循环：反复调用单趟扫描交换算法，直至逆序现象完全消除。

■ 扫描交换

单趟扫描交换算法，可实现如代码2.27所示。

```

1 template <typename T> bool Vector<T>::bubble(Rank lo, Rank hi) { //一趟扫描交换
2     bool sorted = true; //整体有序标志
3     while (++lo < hi) //自左向右，逐一检查各对相邻元素
4         if (_elem[lo - 1] > _elem[lo]) { //若逆序，则
5             sorted = false; //意味着尚未整体有序，并需要
6                 swap(_elem[lo - 1], _elem[lo]); //通过交换使局部有序
7         }
8     return sorted; //返回有序标志
9 }

```

代码2.27 单趟扫描交换

该算法的功能等效于第5页代码1.1中**bubblesort1A()**的内层循环：依次比较各对相邻元素，每当发现逆序即令二者彼此交换；一旦经过某趟扫描之后未发现任何逆序的相邻元素，即意味着排序任务已经完成，则通过返回标志“sorted”，以便主算法及时终止。

■ 重复元素与稳定性

稳定性 (**stability**) 是对排序算法更为细致的要求，重在考查算法对重复元素的处理效果。具体地，在将向量 **A** 转换为有序向量 **S** 之后，设 **A**[*i*] 对应于 **S**[*k_i*]。若对于 **A** 中每一对重复元素 **A**[*i*] = **A**[*j*] (相应地 **S**[*k_i*] = **S**[*k_j*])，都有 *i* < *j* 当且仅当 *k_i* < *k_j*，则称该排序算法是稳定算法 (**stable algorithm**)。简而言之，稳定算法的特征是，重复元素之间的相对次序在排序前后保持一致。反之，不具有这一特征的排序算法都是不稳定算法 (**unstable algorithm**)。

比如，依此标准反观起泡排序可以发现，该算法过程中元素相对位置有所调整的唯一可能是，某元素 **_elem**[*i* - 1] 严格大于其后继 **_elem**[*i*]。也就是说，在这种亦步亦趋的交换过程中，重复元素虽可能相互靠拢，但绝对不会相互跨越。由此可知，起泡排序属于稳定算法。

稳定的排序算法，可用以实现同时对多个关键码按照字典序的排序。比如，后面9.4.3节基数排序算法的正确性，就完全建立在桶排序稳定性的基础之上。

若需兼顾其它方面的性能，以上起泡排序仍有改进的余地（习题[2-25]）。

2.8.3 归并排序

■ 历史与发展

归并排序^⑨ (**mergesort**) 的构思朴实却亦深刻，作为一个算法既古老又仍不失生命力。在排序算法发展的历史上，归并排序具有特殊的地位，它是第一个可以在最坏情况下依然保持 $O(n \log n)$ 运行时间的确定性排序算法。

时至今日，在计算机早期发展过程中曾经出现的一些难题在更大尺度上再次呈现，归并排序因此重新焕发青春。比如，早期计算机的存储能力有限，以至于高速存储器不能容纳所有的数据，或者只能使用磁带机或卡片之类的顺序存储设备，这些既促进了归并排序的诞生，也为该算法提供了施展的舞台。信息化无处不在的今天，我们再次发现，人类所拥有信息之庞大，不仅迫使我们更多地将它们存放和组织于分布式平台之上，而且对海量信息的处理也必须首先考虑，如何在跨节点的环境中高效地协同计算。因此在许多新算法和技术的背后，都可以看到归并排序的影子。

■ 有序向量的二路归并

与起泡排序通过反复调用单趟扫描交换类似，归并排序也可以理解为是通过反复调用所谓二路归并 (**2-way merge**) 算法而实现的。所谓二路归并，就是将两个有序序列合并成为一个有序序列。这里的序列既可以是向量，也可以是第3章将要介绍的列表，这里首先考虑有序向量。归并排序所需的时间，也主要决定于各趟二路归并所需时间的总和。

二路归并属于迭代式算法。每步迭代中，只需比较两个待归并向量的首元素，将小者取出并追加到输出向量的末尾，该元素在原向量中的后继则成为新的首元素。如此往复，直到某一向量为空。最后，将另一非空的向量整体接至输出向量的末尾。

^⑨ 由冯·诺依曼于1945年在EDVAC上首次编程实现

如图2.18(a)所示, 设拟归并的有序向量为{ 5, 8, 13, 21 }和{ 2, 4, 10, 29 }。

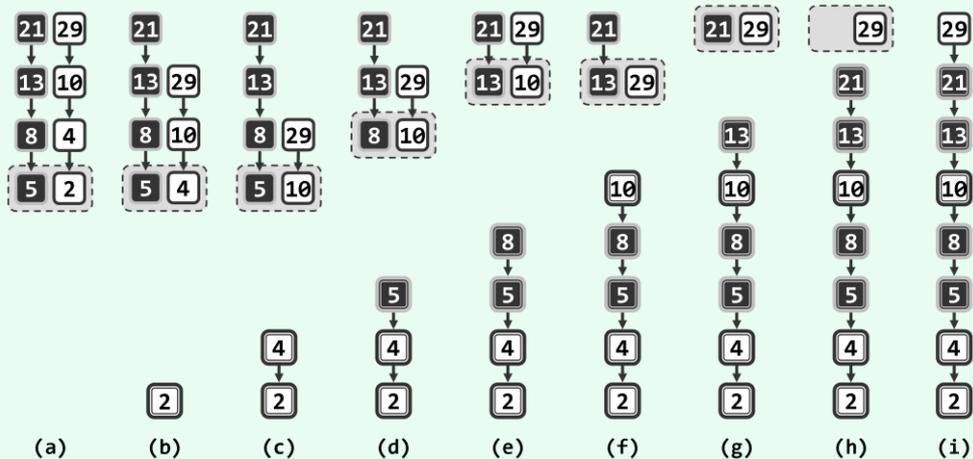


图2.18 有序向量的二路归并实例

(来自两个向量的元素分别以黑、白方框区分, 其各自的当前首元素则以灰色长方形示意)

第一步迭代经比较, 取出右侧向量首元素2并归入输出向量, 同时其首元素更新为4(图(b))。此后各步迭代均与此类似, 都需比较首元素, 将小者取出, 并更新对应的首元素(图(c~h))。如此, 即可最终实现整体归并(图(i))。

可见, 二路归并算法在任何时刻只需载入两个向量的首元素, 故除了归并输出的向量外, 仅需要常数规模的辅助空间。另外, 该算法始终严格地按顺序处理输入和输出向量, 故特别适用于使用磁带机等顺序存储器的场合。

■ 分治策略

归并排序的主体结构属典型的分治策略, 可递归地描述和实现如代码2.28所示。

```

1 template <typename T> //向量归并排序
2 void Vector<T>::mergeSort(Rank lo, Rank hi) { //0 <= lo < hi <= size
3     if (hi - lo < 2) return; //单元素区间自然有序, 否则...
4     int mi = (lo + hi) >> 1; //以中点为界
5     mergeSort(lo, mi); mergeSort(mi, hi); merge(lo, mi, hi); //分别对前、后半段排序, 然后归并
6 }

```

代码2.28 向量的归并排序

可见, 为将向量 $S[lo, hi)$ 转换为有序向量, 可以均匀地将其划分为两个子向量:

$S[lo, mi)$

$S[mi, hi)$

以下, 只要通过递归调用将二者分别转换为有序向量, 即可借助以上的二路归并算法, 得到与原向量 S 对应的整个有序向量。

请注意, 这里的递归终止条件是当前向量长度:

$n = hi - lo = 1$

既然仅含单个元素的向量必然有序, 这一处理分支自然也就可以作为递归基。

■ 实例

归并算法的一个完整实例，如图2.19所示。从递归的角度，也可将图2.19看作对该算法的递归跟踪，其中绘出了所有的递归实例，并按照递归调用关系将其排列成一个层次化结构。

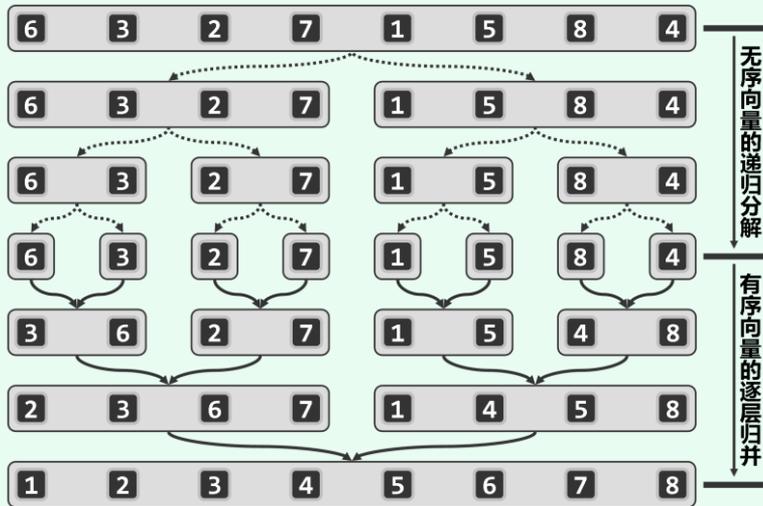


图2.19 归并排序实例：S = { 6, 3, 2, 7, 1, 5, 8, 4 }

可以看出，上半部分对应于递归的不断深入过程：不断地均匀划分（子）向量，直到其规模缩减至1从而抵达递归基。此后如图中下半部分所示，开始递归返回。通过反复调用二路归并算法，相邻且等长的子向量不断地捉对合并为规模更大的有序向量，直至最终得到整个有序向量。由此可见，归并排序可否实现、可否高效实现，关键在于二路归并算法。

■ 二路归并接口的实现

针对有序向量结构，代码2.29给出了二路归并算法的一种实现。

```

1 template <typename T> //有序向量的归并
2 void Vector<T>::merge(Rank lo, Rank mi, Rank hi) { //以mi为界、各自有序的子向量[lo, mi)和[mi, hi)
3     T* A = _elem + lo; //合并后的向量A[0, hi - lo) = _elem[lo, hi)
4     int lb = mi - lo; T* B = new T[lb]; //前子向量B[0, lb) = _elem[lo, mi)
5     for (Rank i = 0; i < lb; B[i] = A[i++]); //复制前子向量
6     int lc = hi - mi; T* C = _elem + mi; //后子向量C[0, lc) = _elem[mi, hi)
7     for (Rank i = 0, j = 0, k = 0; (j < lb) || (k < lc); ) { //将B[j]和C[k]中的小者续至A末尾
8         if ( (j < lb) && ( !(k < lc) || (B[j] <= C[k]) ) ) A[i++] = B[j++];
9         if ( (k < lc) && ( !(j < lb) || (C[k] < B[j]) ) ) A[i++] = C[k++];
10    }
11    delete [] B; //释放临时空间B
12 } //归并后得到完整的有序向量[lo, hi)

```

代码2.29 有序向量的二路归并

这里约定，参与归并的子向量在原向量中总是前、后相邻的，故借助三个入口参数即可界定其范围[lo, mi)和[mi, hi)。另外，为保证归并所得的子向量能够原地保存以便继续参与更高层的归并，这里使用了临时数组B[]存放前一向量[lo, mi)的副本（习题[2-28]）。

■ 归并时间

不难看出，以上二路归并算法`merge()`的渐进时间成本，取决于其中循环迭代的总次数。

实际上，每经过一次迭代，`B[j]`和`C[k]`之间的小者都会被移出并接至`A`的末尾（习题[2-29]和[2-30]）。这意味着，每经过一次迭代，总和 $s = j + k$ 都会加一。

考查这一总和 s 在迭代过程中的变化。初始时，有 $s = 0 + 0 = 0$ ；而在迭代期间，始终有：

$$s < lb + lc = (mi - lo) + (hi - mi) = hi - lo$$

因此，迭代次数及所需时间均不超过 $\mathcal{O}(hi - lo) = \mathcal{O}(n)$ 。

反之，按照算法的流程控制逻辑，无论子向量的内部元素组成及其相对大小如何，只有待到 $s = hi - lo$ 时迭代方能终止。因此，该算法在最好情况下仍需 $\mathcal{O}(n)$ 时间，概括而言应为 $\Theta(n)$ 。

请注意，借助二路归并算法可在严格少于 $\mathcal{O}(n \log n)$ 时间内完成排序的这一事实，与此前2.7.3节关于排序算法下界的结论并不矛盾——毕竟，这里的输入并非一组完全随机的元素，而是已经划分为各自有序的两组，故就总体而言已具有相当程度的有序性。

■ 推广

二路归并只需线性时间的结论，并不限于相邻且等长的子向量。实际上，即便子向量在物理空间上并非前后衔接，且长度相差悬殊，该算法也依然可行且仅需线性时间。

更重要地，正如我们在后面（82页代码3.22）将要看到的，这一算法框架也可应用于另一类典型的序列结构——列表——而且同样可以达到线性的时间效率。

■ 排序时间

那么，基于以上二路归并的线性算法，归并排序算法的时间复杂度又是多少呢？

不妨采用递推方程分析法，为此首先将归并排序算法处理长度为 n 的向量所需的时间记作 $T(n)$ 。根据算法构思与流程，为对长度为 n 的向量归并排序，需递归地对长度各为 $n/2$ 的两个子向量做归并排序，再花费线性时间做一次二路归并。如此，可得以下递推关系：

$$T(n) = 2 \times T(n/2) + \mathcal{O}(n)$$

另外，当子向量长度缩短到1时，递归即可终止并直接返回该向量。故有边界条件

$$T(1) = \mathcal{O}(1)$$

联立以上递推式，可以解得（习题[2-26]）：

$$T(n) = \mathcal{O}(n \log n)$$

也就是说，归并排序算法可在 $\mathcal{O}(n \log n)$ 时间内对长度为 n 的向量完成排序。因二路归并算法的效率稳定在 $\Theta(n)$ ，故更准确地讲，归并排序算法的时间复杂度应为 $\Theta(n \log n)$ 。

实际上，利用图2.19中算法整个执行过程的递归跟踪图，也可殊途同归。为此只需如该图所示，按照规模大小将各递归实例分层排列。既然每次二路归并均只需线性时间，故同层的所有二路归并累计也只需线性时间（当然，这两个“线性”的含义不同：前者是指线性正比于一对递归并子向量长度之和，后者则是指线性正比于所有参与归并的子向量长度之和）。由图不难看出，原向量中每个元素在同一层次恰好出现一次，故同层递归实例所消耗时间之和应为 $\Theta(n)$ 。另外，递归实例的规模以2为倍数按几何级数逐层变化，故共有 $\Theta(\log_2 n)$ 层，共计 $\Theta(n \log n)$ 时间。

第3章

列表

上一章介绍的向量结构中，各数据项的物理存放位置与逻辑次序完全对应，故可通过秩直接访问对应的元素，此即所谓“循秩访问”（call-by-rank）。这种访问方式，如同根据具体的城市名、街道名和门牌号，直接找到某人。本章将要介绍的列表，与向量同属序列结构的范畴，其中的元素也构成一个线性逻辑次序；但与向量极为不同的是，元素的物理地址可以任意。

为保证对列表元素访问的可行性，逻辑上互为前驱和后继的元素之间，应维护某种索引关系。这种索引关系，可抽象地理解为被索引元素的位置（position），故列表元素是“循位置访问”（call-by-position）的；也可形象地理解为通往被索引元素的链接（link），故亦称作“循链接访问”（call-by-link）。这种访问方式，如同通过你的某位亲朋，找到他/她的亲朋、亲朋的亲朋、……。注意，向量中的秩同时对应于逻辑和物理次序，而位置仅对应于逻辑次序。

本章的讲解，将围绕列表结构的高效实现逐步展开，包括其ADT接口规范以及对应的算法。此外还将针对有序列表，系统地介绍排序等经典算法，并就其性能做一分析和对比。

§ 3.1 从向量到列表

不同数据结构内部的存储与组织方式各异，其操作接口的使用方式及时空性能也不尽相同。在设计或选用数据结构时，应从实际应用的需求出发，先确定功能规范及性能指标。比如，引入列表结构的目的，就在于弥补向量结构在解决某些应用问题时，在功能及性能方面的不足。二者之间的差异，表面上体现于对外的操作方式，但根源则在于其内部存储方式的不同。

3.1.1 从静态到动态

数据结构支持的操作，通常无非静态和动态两类：前者仅从中获取信息，后者则会修改数据结构的局部甚至整体。以第2章基于数组实现的向量结构为例，其size()和get()等静态操作均可在常数时间内完成，而insert()和remove()等动态操作却都可能需要线性时间。究其原因，在于“各元素物理地址连续”的约定——此即所谓的“静态存储”策略。

得益于这种策略，可在 $O(1)$ 时间内由秩确定向量元素的物理地址；但反过来，在添加（删除）元素之前（之后），又不得不移动 $O(n)$ 个后继元素。可见，尽管如此可使静态操作的效率达到极致，但就动态操作而言，局部的修改可能引起大范围甚至整个数据结构的调整。

列表（list）结构尽管也要求各元素在逻辑上具有线性次序，但对其物理地址却未作任何限制——此即所谓“动态存储”策略。具体地，在其生命期内，此类数据结构将随着内部数据的需要，相应地分配或回收局部的数据空间。如此，元素之间的逻辑关系得以延续，却不必与其物理次序相关。作为补偿，此类结构将通过指针或引用等机制，来确定各元素的实际物理地址。

例如，链表（linked list）就是一种典型的动态存储结构。其中的数据，分散为一系列称作节点（node）的单位，节点之间通过指针相互索引和访问。为了引入新节点或删除原有节点，只需在局部，调整少量相关节点之间的指针。这就意味着，采用动态存储策略，至少可以大大降低动态操作的成本。

3.1.2 由秩到位置

改用以上动态存储策略之后，在提高动态操作效率的同时，却又不得不舍弃原静态存储策略中循序访问的方式，从而造成静态操作性能的下降。

以采用动态存储策略的线性结构（比如链表）为例。尽管按照逻辑次序，每个数据元素依然具有秩这一指标，但为了访问秩为 r 的元素，我们只能顺着相邻元素之间的指针，从某一端出发逐个扫描各元素，经过 r 步迭代后才能确定该元素的物理存储位置。这意味着，原先只需 $O(1)$ 时间的静态操作，此时的复杂度也将线性正比于被访问元素的秩，在最坏情况下等于元素总数 n ；即便在各元素被访问概率相等的情况下，平均而言也需要 $O(n)$ 时间。

对数据结构的访问方式，应与其存储策略相一致。此时，既然继续沿用循序访问的方式已非上策，就应更多地习惯于通过位置，来指代并访问动态存储结构中的数据元素。与向量中秩的地位与功能类似，列表中的位置也是指代各数据元素的一个标识性指标，借助它可以便捷地（比如在常数时间内）得到元素的物理存储地址。各元素的位置，通常可表示和实现为联接于元素之间的指针或引用。因此，基于此类结构设计算法时，应更多地借助逻辑上相邻元素之间的位置索引，以实现目标元素的快速定位和访问，并进而提高算法的整体效率。

3.1.3 列表

与向量一样，列表也是由具有线性逻辑次序的一组元素构成的集合：

$$L = \{ a_0, a_1, \dots, a_{n-1} \}$$

列表是链表结构的一般化推广，其中的元素称作节点（node），分别由特定的位置或链接指代。与向量一样，在元素之间，也可定义前驱、直接前驱，以及后继、直接后继等关系；相对于任意元素，也有定义对应的前缀、后缀等子集。

§ 3.2 接口

如上所述，作为列表的基本组成单位，列表节点除需保存对应的数据项，还应记录其前驱和后继的位置，故需将这些信息及相关操作组成列表节点对象，然后参与列表的构建。

本节将给出列表节点类与列表类的接口模板类描述，稍后逐一讲解各接口的具体实现。

3.2.1 列表节点

■ ADT接口

作为一种抽象数据类型，列表节点对象应支持以下操作接口。

表3.1 列表节点ADT支持的操作接口

操作接口	功能
data()	当前节点所存数据对象
pred()	当前节点前驱节点的位置
succ()	当前节点后继节点的位置
insertAsPred(e)	插入前驱节点，存入被引用对象e，返回新节点位置
insertAsSucc(e)	插入后继节点，存入被引用对象e，返回新节点位置

■ ListNode模板类

按照表3.1所定义的ADT接口，可定义列表节点模板类如代码3.1所示。出于简洁与效率的考虑，这里并未对ListNode对象做封装处理。列表节点数据项的类型，通过模板参数T指定。

```

1 typedef int Rank; //秩
2 #define ListNodePosi(T) ListNode<T>* //列表节点位置
3
4 template <typename T> struct ListNode { //列表节点模板类（以双向链表形式实现）
5 // 成员
6     T data; ListNodePosi(T) pred; ListNodePosi(T) succ; //数值、前驱、后继
7 // 构造函数
8     ListNode() {} //针对header和trailer的构造
9     ListNode( T e, ListNodePosi(T) p = NULL, ListNodePosi(T) s = NULL)
10         : data(e), pred(p), succ(s) {} //默认构造器
11 // 操作接口
12     ListNodePosi(T) insertAsPred(T const& e); //紧靠当前节点之前插入新节点
13     ListNodePosi(T) insertAsSucc(T const& e); //紧随当前节点之后插入新节点
14 };

```

代码3.1 列表节点模板类^①

每个节点都存有数据对象data。为保证叙述简洁，在不致歧义的前提下，本书将不再区分节点及其对应的data对象。此外，每个节点还设有指针pred和succ，分别指向其前驱和后继。

为了创建一个列表节点对象，只需根据所提供的参数，分别设置节点内部的各个变量。其中前驱、后继节点的位置指针若未予指定，则默认取作NULL。

3.2.2 列表

■ ADT接口

作为一种抽象数据类型，列表对象应支持以下操作接口。

表3.2 列表ADT支持的操作接口

操作接口	功能	适用对象
size()	报告列表当前的规模（节点总数）	列表
first()、last()	返回首、末节点的位置	列表
insertAsFirst(e) insertAsLast(e)	将e当作首、末节点插入	列表
insertBefore(p, e) insertAfter(p, e)	将e当作节点p的直接前驱、后继插入	列表

^① 请注意，这里所“定义”的ListNodePosi(T)并非真正意义上“列表节点位置”类型。

巧合的是，就在本书第1版即将付印之际，C++.0x标准终于被ISO接纳。

新标准所拓展的特性之一，就是对模板别名（template alias）等语法形式的支持。因此可以期望在不久的将来，C++编译器将能够支持如下更为直接和简明的描述和实现：

```
template <typename T> typedef ListNode<T>* ListNodePosi;
```

操作接口	功能	适用对象
remove(p)	删除位置p处的节点, 返回其数值	列表
disordered()	判断所有节点是否已按非降序排列	列表
sort()	调整各节点的位置, 使之按非降序排列	列表
find(e)	查找目标元素e, 失败时返回NULL	列表
search(e)	查找目标元素e, 返回不大于e且秩最大的节点	有序列表
deduplicate()	剔除重复节点	列表
uniquify()	剔除重复节点	有序列表
traverse()	遍历并统一处理所有节点, 处理方法由函数对象指定	列表

请留意用以指示插入和删除操作位置的节点p。这里约定, 它或者在此前经查找已经确定, 或者从此前的其它操作返回或沿用。这些也是列表类结构的典型操作方式。

这里也设置一个disordered()接口, 以判断列表是否已经有序。同时, 也分别针对有序和无序列表, 提供了去重操作的两个版本(deduplicate()和uniquify()), 以及查找操作的两个版本(find()和search())。与向量一样, 有序列表的唯一化, 比无序列表效率更高。然而正如我们将要看到的, 由于只能通过位置指针以局部移动的方式访问节点, 尽管有序列表中节点在逻辑上始终按照大小次序排列, 其查找操作的效率并没有实质改进(习题[3-1])。

■ List模板类

按照表3.2定义的ADT接口, 可定义List模板类如下。

```

1 #include "listNode.h" //引入列表节点类
2
3 template <typename T> class List { //列表模板类
4
5 private:
6     int _size; ListNodePosi(T) header; ListNodePosi(T) trailer; //规模、头哨兵、尾哨兵
7
8 protected:
9     void init(); //列表创建时的初始化
10    int clear(); //清除所有节点
11    void copyNodes(ListNodePosi(T), int); //复制列表中自位置p起的n项
12    void merge(ListNodePosi(T)&, int, List<T>&, ListNodePosi(T), int); //有序列表区间归并
13    void mergeSort(ListNodePosi(T)&, int); //对从p开始连续的n个节点归并排序
14    void selectionSort(ListNodePosi(T), int); //对从p开始连续的n个节点选择排序
15    void insertionSort(ListNodePosi(T), int); //对从p开始连续的n个节点插入排序
16
17 public:
18 // 构造函数
19     List() { init(); } //默认
20     List(List<T> const& L); //整体复制列表L
21     List(List<T> const& L, Rank r, int n); //复制列表L中自第r项起的n项
22     List(ListNodePosi(T) p, int n); //复制列表中自位置p起的n项

```

```

23 // 析构函数
24 ~List(); //释放 ( 包含头、尾哨兵在内的 ) 所有节点
25 // 只读访问接口
26 Rank size() const { return _size; } //规模
27 bool empty() const { return _size <= 0; } //判空
28 T& operator[](Rank r) const; //重载, 支持循秩访问 ( 效率低 )
29 ListNodePosi(T) first() const { return header->succ; } //首节点位置
30 ListNodePosi(T) last() const { return trailer->pred; } //末节点位置
31 bool valid(ListNodePosi(T) p) //判断位置p是否对外合法
32 { return p && (trailer != p) && (header != p); } //将头、尾节点等同于NULL
33 int disordered() const; //判断列表是否已排序
34 ListNodePosi(T) find(T const& e) const //无序列表查找
35 { return find(e, _size, trailer); }
36 ListNodePosi(T) find(T const& e, int n, ListNodePosi(T) p) const; //无序区间查找
37 ListNodePosi(T) search(T const& e) const //有序列表查找
38 { return search(e, _size, trailer); }
39 ListNodePosi(T) search(T const& e, int n, ListNodePosi(T) p) const; //有序区间查找
40 ListNodePosi(T) selectMax(ListNodePosi(T) p, int n); //在p及其前n-1个后继中选出最大者
41 ListNodePosi(T) selectMax() { return selectMax(header->succ, _size); } //整体最大者
42 // 可写访问接口
43 ListNodePosi(T) insertAsFirst(T const& e); //将e当作首节点插入
44 ListNodePosi(T) insertAsLast(T const& e); //将e当作末节点插入
45 ListNodePosi(T) insertBefore(ListNodePosi(T) p, T const& e); //将e当作p的前驱插入
46 ListNodePosi(T) insertAfter(ListNodePosi(T) p, T const& e); //将e当作p的后继插入
47 T remove(ListNodePosi(T) p); //删除合法位置p处的节点,返回被删除节点
48 void merge(List<T>& L) { merge(first(), size, L, L.first(), L._size); } //全列表归并
49 void sort(ListNodePosi(T) p, int n); //列表区间排序
50 void sort() { sort(first(), _size); } //列表整体排序
51 int deduplicate(); //无序去重
52 int uniquify(); //有序去重
53 void reverse(); //前后倒置 ( 习题 )
54 // 遍历
55 void traverse(void (*)(T&)); //遍历, 依次实施visit操作 ( 函数指针, 只读或局部性修改 )
56 template <typename VST> //操作器
57 void traverse(VST&); //遍历, 依次实施visit操作 ( 函数对象, 可全局性修改 )
58 }; //List

```

代码3.2 列表模板类

由代码3.2可见, 列表结构的实现方式与第2章的向量结构颇为相似: 通过模板参数T指定列表元素的类型 (同时亦为代码3.1中列表节点数据项的类型); 在内部设置私有变量以记录当前规模等状态信息; 基于多种排序算法提供统一的sort()接口, 以将列表转化为有序列表。

以下, 分别介绍列表的内部结构、基本接口, 以及主要算法的具体实现。

§ 3.3 列表

3.3.1 头、尾节点

List对象的内部组成及逻辑结构如图3.1所示，其中私有的头节点（header）和尾节点（trailer）始终存在，但对外并不可见。对外部可见的数据节点如果存在，则其中的第一个和最后一个节点分别称作首节点（first node）和末节点（last node）。

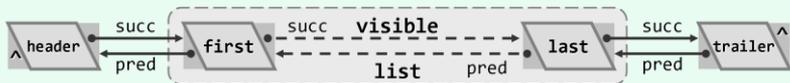


图3.1 首（末）节点是头（尾）节点的直接后继（前驱）

就内部结构而言，头节点紧邻于首节点之前，尾节点紧邻于末节点之后。这类经封装之后从外部不可见的节点，称作哨兵节点（sentinel node）。由代码3.2中List::valid()关于合法节点位置的判别准则可见，此处的两个哨兵节点从外部被等效地视作NULL。

设置哨兵节点之后，对于从外部可见的任一节点而言，其前驱和后继在列表内部都必然存在，故可简化算法的描述与实现。比如，在代码3.2中为实现first()和last()操作，只需直接返回header->succ或trailer->pred。此外更重要地，哨兵节点的引入，也使得相关算法不必再对各种边界退化情况做专门的处理，从而避免出错的可能，我们稍后将对此有更实际的体会。

尽管哨兵节点也需占用一定的空间，但只不过是常数规模，其成本远远低于由此带来的便利。

3.3.2 默认构造方法

创建List对象时，默认构造方法将调用如代码3.3所示的统一初始化过程init()，在列表内部创建一对头、尾哨兵节点，并适当地设置其前驱、后继指针构成一个双向链表。

```

1 template <typename T> void List<T>::init() { //列表初始化，在创建列表对象时统一调用
2     header = new ListNode<T>; //创建头哨兵节点
3     trailer = new ListNode<T>; //创建尾哨兵节点
4     header->succ = trailer; header->pred = NULL;
5     trailer->pred = header; trailer->succ = NULL;
6     _size = 0; //记录规模
7 }
```

代码3.3 列表类内部方法init()

如图3.2所示，该链表对外的有效部分初始为空，哨兵节点对外不可见，此后引入的新节点都将陆续插入于这一对哨兵节点之间。



图3.2 刚创建的List对象

在列表的其它构造方法中，内部变量的初始化过程与此相同，因此都可统一调用init()过程。该过程仅涉及常数次基本操作，共需运行常数时间。

3.3.3 由秩到位置的转换

鉴于偶尔可能需要通过秩来指定列表节点，可通过重载操作符“[]”，提供一个转换接口。

```
1 template <typename T> //重载下标操作符，以通过秩直接访问列表节点（虽方便，效率低，需谨慎）
2 T& List<T>::operator[](Rank r) const { //assert: 0 <= r < size
3     ListNodePosi(T) p = first(); //从首节点出发
4     while (0 < r--) p = p->succ; //顺数第r个节点即是
5     return p->data; //目标节点，返回其中所存元素
6 }
```

代码3.4 重载列表类的下标操作符

具体地如代码3.4所示，为将任意指定的秩 r 转换为列表中对应的元素，可从首节点出发，顺着后继指针前进 r 步。只要秩 r 合法，该算法的正确性即一目了然。其中每步迭代仅需常数时间，故该算法的总体运行时间应为 $\mathcal{O}(r + 1)$ ，线性正比于目标节点的秩。

相对于向量同类接口的 $\mathcal{O}(1)$ 复杂度，列表的这一效率十分低下——其根源在于，列表元素的存储和访问方式已与向量截然不同。诚然，当 r 大于 $n/2$ 时，从trailer出发沿pred指针逆行查找，可以在一定程度上减少迭代次数，但就总体的平均效率而言，这一改进并无实质意义。

3.3.4 查找

■ 实现

在代码3.2中，列表ADT针对整体和区间查找，重载了操作接口find(e)和find(e, p, n)。其中，前者作为特例，可以直接调用后者。因此，只需如代码3.5所示，实现后一接口。

```
1 template <typename T> //在无序列表内节点p（可能是trailer）的n个（真）前驱中，找到等于e的最后者
2 ListNodePosi(T) List<T>::find(T const& e, int n, ListNodePosi(T) p) const { //0<=n<=rank(p)<_size
3     while (0 < n--) //对于p的最近的n个前驱，从右向左
4         if (e == (p = p->pred)->data) return p; //逐个比对，直至命中或范围越界
5     return NULL; //p越出左边界意味着区间内不含e，查找失败
6 } //失败时，返回NULL
```

代码3.5 无序列表元素查找接口find()

■ 复杂度

以上算法的思路及过程，与无序向量的顺序查找算法Vector::find()（代码2.10）相仿，故时间复杂度也应是 $\mathcal{O}(n)$ ，线性正比于查找区间的宽度。

3.3.5 插入

■ 接口

为将节点插至列表，可视具体要求的不同，在代码3.6所提供的多种接口中灵活选用。

```
1 template <typename T> ListNodePosi(T) List<T>::insertAsFirst(T const& e)
2 { _size++; return header->insertAsSucc(e); } //e当作首节点插入
3
```

```

4 template <typename T> ListNodePosi(T) List<T>::insertAsLast(T const& e)
5 { _size++; return trailer->insertAsPred(e); } //e当作末节点插入
6
7 template <typename T> ListNodePosi(T) List<T>::insertBefore(ListNodePosi(T) p, T const& e)
8 { _size++; return p->insertAsPred(e); } //e当作p的前驱插入
9
10 template <typename T> ListNodePosi(T) List<T>::insertAfter(ListNodePosi(T) p, T const& e)
11 { _size++; return p->insertAsSucc(e); } //e当作p的后继插入

```

代码3.6 列表节点插入接口

可见，这些接口的实现，都可转化为列表节点对象的前插入或后插入接口。

■ 前插入

将新元素 e 作为当前节点的前驱插至列表的过程，可描述和实现如代码3.7所示。

```

1 template <typename T> //将e紧靠当前节点之前插入于当前节点所属列表(设有哨兵头节点header)
2 ListNodePosi(T) ListNode<T>::insertAsPred(T const& e) {
3     ListNodePosi(T) x = new ListNode(e, pred, this); //创建新节点
4     pred->succ = x; pred = x; //设置正向链接
5     return x; //返回新节点的位置
6 }

```

代码3.7 ListNode::insertAsPred()算法

图3.3给出了整个操作的具体过程。插入新节点之前，列表局部的当前节点及其前驱如图(a)所示。该算法首先如图(b)所示创建新节点 new ，构造函数同时将其数据项置为 e ，并令其后继链接 $succ$ 指向当前节点，令其前驱链接 $pred$ 指向当前节点的前驱节点。随后如图(c)所示，使 new 成为当前节点前驱节点的后继，使 new 成为当前节点的前驱（次序不能颠倒）。最终如图(d)所示，经过如此调整，新节点即被顺利地插至列表的这一局部。

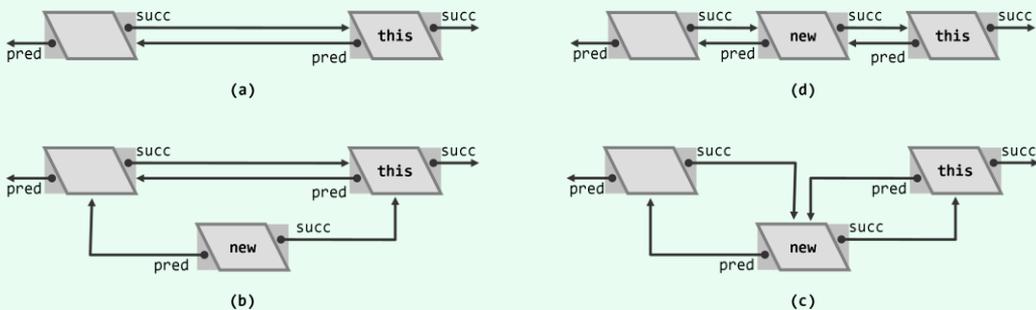


图3.3 ListNode::insertAsPred()算法

请注意，列表规模记录的更新由代码3.6中的上层调用者负责。另外，得益于头哨兵节点的存在，即便当前节点为列表的首节点，其前驱也如图(a)所示必然存在，故不必另做特殊处理。当然，在当前节点即首节点时，前插入接口等效于List::insertAsFirst()。

■ 后插入

将新元素 e 作为当前节点的后继插至列表的过程，可描述和实现如代码3.8所示。

```
1 template <typename T> //将e紧随当前节点之后插入于当前节点所属列表 (设有哨兵尾节点trailer)
2 ListNodePosi(T) ListNode<T>::insertAsSucc(T const& e) {
3     ListNodePosi(T) x = new ListNode(e, this, succ); //创建新节点
4     succ->pred = x; succ = x; //设置逆向链接
5     return x; //返回新节点的位置
6 }
```

代码3.8 ListNode::insertAsSucc()算法

后插入的操作过程以及最终效果与前插入完全对称，不再赘述。

■ 复杂度

上述两种插入操作过程，仅涉及局部的两个原有节点和一个新节点，且不含任何迭代或递归。若假设当前节点已经定位，不计入此前的查找所消耗的时间，则它们都可在常数时间内完成。

3.3.6 基于复制的构造

与向量一样，列表的内部结构也是动态创建的，故利用默认的构造方法并不能真正地完复制列表的复制创建。为此，需要专门编写相应的构造方法，通过复制某一已有列表来构造新列表。

■ copyNodes()

尽管这里提供了多种形式，以允许对原列表的整体或局部复制，但其实质过程均大同小异，都可概括和转化为如代码3.9所示的底层内部方法copyNodes()。在输入参数合法的前提下，copyNodes()首先调用init()方法，创建头、尾哨兵节点并做相应的初始化处理，然后自 p 所指节点起，从原列表中取出 n 个相邻的节点，并逐一作为末节点插至新列表中。

```
1 template <typename T> //列表内部方法：复制列表中自位置p起的n项
2 void List<T>::copyNodes(ListNodePosi(T) p, int n) { //p合法，且至少有n-1个真后继节点
3     init(); //创建头、尾哨兵节点并做初始化
4     while(n--) { insertAsLast(p->data); p = p->succ; } //将起自p的n项依次作为末节点插入
5 }
```

代码3.9 列表类内部方法copyNodes()

根据此前的分析，init()操作以及各步迭代中的插入操作均只需常数时间，故copyNodes()过程总体的运行时间应为 $O(n + 1)$ ，线性正比于待复制列表区间的长度 n 。

■ 基于复制的构造

如代码3.10所示，基于上述copyNodes()方法可以实现多种接口，通过复制已有列表的区间或整体，构造出新列表。其中，为了复制列表 L 中自秩 r 起的 n 个相邻节点，List(L, r, n)需借助重载后的下标操作符，找到待复制区间起始节点的位置，然后再以此节点作为参数调用copyNodes()。根据3.3.3节的分析结论，需要花费 $O(r + 1)$ 的时间才能将 r 转换为起始节点的位置，故该复制接口的总体复杂度应为 $O(r + n + 1)$ ，线性正比于被复制节点的最高秩。由此也可再次看出，在诸如列表之类采用动态存储策略的结构中，循序访问远非有效的方式。

```

1 template <typename T> //assert: p为合法位置,且至少有n-1个后继节点
2 List<T>::List(ListNodePosi(T) p, int n) { copyNodes(p, n); } //复制列表中自位置p起的n项
3
4 template <typename T>
5 List<T>::List(List<T> const& L) { copyNodes(L.first(), L._size); } //整体复制列表L
6
7 template <typename T> //assert: r+n <= L._size
8 List<T>::List(List<T> const& L, int r, int n) { copyNodes(L[r], n); } //复制L中自第r项起的n项

```

代码3.10 基于复制的列表构造方法

3.3.7 删除

■ 实现

在列表中删除指定节点 p 的算法,可以描述并实现如代码3.11所示。

```

1 template <typename T> T List<T>::remove(ListNodePosi(T) p) { //删除合法位置p处节点,返回其数值
2     T e = p->data; //备份待删除节点的数值(假定T类型可直接赋值)
3     p->pred->succ = p->succ; p->succ->pred = p->pred; //后继、前驱
4     delete p; _size--; //释放节点,更新规模
5     return e; //返回备份的数值
6 }

```

代码3.11 列表节点删除接口remove()

图3.4给出了整个操作的具体过程。删除节点之前,列表在位置 p 附近的局部如图(a)所示。为了删除位置 p 处的节点,首先如图(b)所示,令其前驱节点与后继节点相互链接。然后如图(c)所示,释放掉已经孤立出来的节点 p ,同时相应地更新列表规模计数器 $_size$ 。最终如图(d)所示,经过如此调整之后,原节点 p 即被顺利地从列表中摘除。

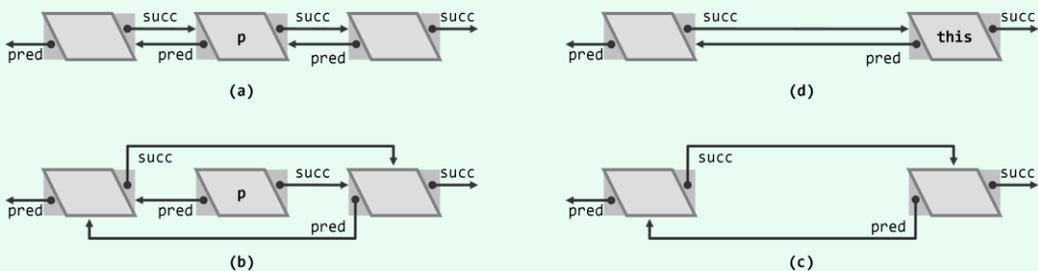


图3.4 List::remove()算法

这里,可以清晰地体会到哨兵节点的作用。不难验证,即便 p 所指的是列表中唯一对外有效的节点(其前驱和后继都是哨兵节点), $\text{remove}()$ 算法依然可以正常运转。

■ 复杂度

以上过程仅涉及常数次基本操作,故若不计入此前为查找并确定位置 p 所消耗的时间,列表的节点删除操作可在常数时间内完成。

3.3.8 析构

■ 释放资源及清除节点

与所有对象一样，列表对象析构时也需如代码3.12所示，将其所占用的资源归还操作系统。

```
1 template <typename T> List<T>::~~List() //列表析构器
2 { clear(); delete header; delete trailer; } //清空列表，释放头、尾哨兵节点
```

代码3.12 列表析构方法

可见，列表的析构需首先调用clear()接口删除并释放所有对外部有效的节点，然后释放内部的头、尾哨兵节点。而clear()过程则可描述和实现如代码3.13所示。

```
1 template <typename T> int List<T>::clear() { //清空列表
2     int oldSize = _size;
3     while (0 < _size) remove(header->succ); //反复删除首节点，直至列表变空
4     return oldSize;
5 }
```

代码3.13 列表清空方法clear()

■ 复杂度

这里的时间消耗主要来自clear()操作，该操作通过remove()接口反复删除列表的首节点。因此，clear()方法以及整个析构方法的运行时间应为 $O(n)$ ，线性正比于列表原先的规模。

3.3.9 唯一化

■ 实现

旨在剔除无序列表中重复元素的接口deduplicate()，可实现如代码3.14所示。

```
1 template <typename T> int List<T>::deduplicate() { //剔除无序列表中的重复节点
2     if (_size < 2) return 0; //平凡列表自然无重复
3     int oldSize = _size; //记录原规模
4     ListNodePosi(T) p = header; Rank r = 0; //p从首节点开始
5     while (trailer != (p = p->succ)) { //依次直到末节点
6         ListNodePosi(T) q = find(p->data, r, p); //在p的r个(真)前驱中查找雷同者
7         q ? remove(q) : r++; //若的确存在，则删除之；否则秩加一
8     } //assert: 循环过程中的任意时刻，p的所有前驱互不相同
9     return oldSize - _size; //列表规模变化量，即被删除元素总数
10 }
```

代码3.14 无序列表剔除重复节点接口deduplicate()

与算法Vector::deduplicate() (42页代码2.14)类似，这里也是自前向后依次处理各节点p，一旦通过find()接口在p的前驱中查到雷同者，则随即调用remove()接口将其删除。

■ 正确性

向量与列表中元素的逻辑次序一致，故二者的deduplicate()算法亦具有类似的不变性和单调性(习题[3-4])，故正确性均可保证。

■ 复杂度

与无序向量的去重算法一样，该算法总共需做 $O(n)$ 步迭代。由3.3.4节的分析结论，每一步迭代中`find()`操作所需的时间线性正比于查找区间宽度，即当前节点的秩；由3.3.7节的分析结论，列表节点每次`remove()`操作仅需常数时间。因此，总体执行时间应为：

$$1 + 2 + 3 + \dots + n = n \cdot (n + 1) / 2 = O(n^2)$$

相对于无序向量，尽管此处节点删除操作所需的时间减少，但总体渐进复杂度并无改进。

3.3.10 遍历

列表也提供支持节点批量式访问（习题[3-5]）的遍历接口，其实现如代码3.15所示。

```
1 template <typename T> void List<T>::traverse(void (*visit)(T&)) //利用函数指针机制的遍历
2 { for (ListNodePosi(T) p = header->succ; p != trailer; p = p->succ) visit(p->data); }
3
4 template <typename T> template <typename VST> //元素类型、操作器
5 void List<T>::traverse(VST& visit) //利用函数对象机制的遍历
6 { for (ListNodePosi(T) p = header->succ; p != trailer; p = p->succ) visit(p->data); }
```

代码3.15 列表遍历接口`traverse()`

该接口的设计思路与实现方式，与向量的对应接口（2.5.8节）如出一辙，复杂度也相同。

§ 3.4 有序列表

若列表中所有节点的逻辑次序与其大小次序完全一致，则称作有序列表（`sorted list`）。为保证节点之间可以定义次序，依然假定元素类型`T`直接支持大小比较，或已重载相关操作符。与有序向量一致地，这里依然约定采用非降次序。

3.4.1 唯一化

与有序向量同理，有序列表中的雷同节点也必然（在逻辑上）彼此紧邻。利用这一特性，可实现重复节点删除算法如代码3.16所示。位置指针`p`和`q`分别指向每一对相邻的节点，若二者雷同则删除`q`，否则转向下一对相邻节点。如此反复迭代，直至检查过所有节点。

```
1 template <typename T> int List<T>::uniquify() { //成批剔除重复元素，效率更高
2     if (_size < 2) return 0; //平凡列表自然无重复
3     int oldSize = _size; //记录原规模
4     ListNodePosi(T) p; ListNodePosi(T) q; //依次指向紧邻的各对节点
5     for (p = header, q = p->succ; trailer != q; p = q, q = q->succ) //从左向右扫描
6         if (p->data == q->data) { remove(q); q = p; } //若p和q雷同，则删除后者
7     return oldSize - _size; //列表规模变化量，即被删除元素总数
8 }
```

代码3.16 有序列表剔除重复节点接口`uniquify()`

整个过程的运行时间为 $O(_size) = O(n)$ ，线性正比于列表原先的规模。

3.4.2 查找

■ 实现

有序列表的节点查找算法，可实现如代码3.17所示。

```

1 template <typename T> //在有序列表内节点p (可能是trailer)的n个(真)前驱中,找到不大于e的最后者
2 ListNodePosi(T) List<T>::search(T const& e, int n, ListNodePosi(T) p) const {
3 // assert: 0 <= n <= rank(p) < _size
4   while (0 <= n--) //对于p的最近的n个前驱,从右向左逐个比较
5       if (((p = p->pred)->data) <= e) break; //直至命中、数值越界或范围越界
6 // assert: 至此位置p必符合输出语义约定——尽管此前最后一次关键码比较可能没有意义(等效于与-inf比较)
7   return p; //返回查找终止的位置
8 } //失败时,返回区间左边界的前驱(可能是header)——调用者可通过valid()判断成功与否

```

代码3.17 有序列表查找接口search()

与有序向量类似，无论查找成功与否，返回的位置都应便于后续（插入等）操作的实施。

■ 顺序查找

与2.6.5节至2.6.8节有序向量的各种查找算法相比，该算法完全不同；反过来，除了循环终止条件的细微差异，多数部分反倒与3.3.4节无序列表的顺序查找算法几乎一样。

究其原因在于，尽管有序列表中的节点已在逻辑上按次序单调排列，但在动态存储策略中，节点的物理地址与逻辑次序毫无关系，故无法像有序向量那样自如地应用减治策略，从而不得不继续沿用无序列表的顺序查找策略。

■ 复杂度

与无序向量的查找算法同理：最好情况下的运行时间为 $O(1)$ ，最坏情况下为 $O(n)$ 。在等概率的前提下，平均运行时间也是 $O(n)$ ，线性正比于查找区间的宽度。

§ 3.5 排序器

3.5.1 统一入口

与无序向量一样，针对无序列表任意合法区间的排序需求，这里也如代码3.18所示，设置了一个统一的排序操作接口。

```

1 template <typename T> void List<T>::sort(ListNodePosi(T) p, int n) { //列表区间排序
2   switch (rand() % 3) { //随机选取排序算法。可根据具体问题的特点灵活选取或扩充
3     case 1: insertionSort(p, n); break; //插入排序
4     case 2: selectionSort(p, n); break; //选择排序
5     default: mergeSort(p, n); break; //归并排序
6   }
7 }

```

代码3.18 有序列表基于排序的构造方法

这里提供了插入排序、选择排序和归并排序三种算法，并依然以随机方式确定每次调用的具体算法，以便测试和对比。以下，将依次地讲解这几种算法的原理、实现，并分析其复杂度。

3.5.2 插入排序

■ 构思

插入排序 (insertionsort) 算法适用于包括向量与列表在内的任何序列结构。

算法的思路可简要描述为：始终将整个序列视作并切分为两部分：有序的前缀，无序的后缀；通过迭代，反复地将后缀的首元素转移至前缀中。由此亦可看出插入排序算法的不变性：

在任何时刻，相对于当前节点 $e = S[r]$ ，前缀 $S[0, r)$ 总是业已有序

算法开始时该前缀为空，不变性自然满足。

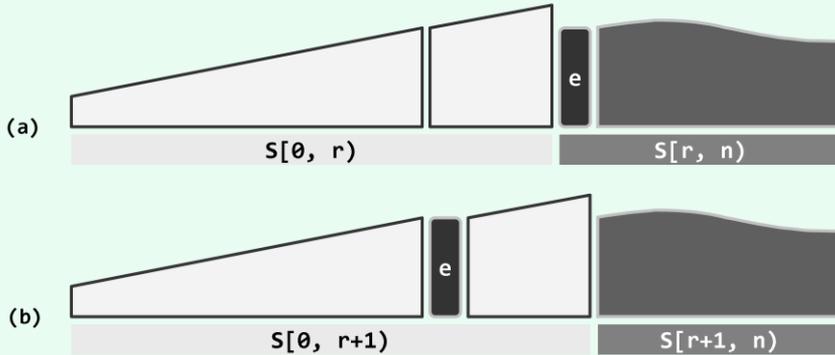


图3.5 序列的插入排序

假设如图3.5(a)所示，前缀 $S[0, r)$ 已经有序。接下来，借助有序序列的查找算法，可在该前缀中定位到不大于 e 的最大元素。于是只需将 e 从无序后缀中取出，并紧邻于查找返回的位置之后插入，即可如图(b)所示，使得有序前缀的范围扩大至 $S[0, r+1)$ 。

如此，该前缀的范围可不断拓展。当其最终覆盖整个序列时，亦即整体有序。

■ 实例

如表3.3所示，即为序列插入排序算法的一个实例。

表3.3 插入排序算法实例

#迭代	前缀有序子序列	后缀无序子序列
0	^	5 2 7 4 6 3 1
1	5	2 7 4 6 3 1
2	2 5	7 4 6 3 1
3	2 5 7	4 6 3 1
4	2 4 5 7	6 3 1
5	2 4 5 6 7	3 1
6	2 3 4 5 6 7	1
7	1 2 3 4 5 6 7	^

这里，前后共经7步迭代。输入序列中的7个元素以秩为序，先后作为首元素被取出，并插至有序前缀子序列中的适当位置。新近插入的元素均以方框注明，为确定其插入位置而在查找操作过程中接受过大小比较的元素以下划线示意。

■ 实现

依照以上思路，可针对列表实现插入排序算法如代码3.19所示。

```

1 template <typename T> //列表的插入排序算法：对起始于位置p的n个元素排序
2 void List<T>::insertionSort(ListNodePosi(T) p, int n) { //valid(p) && rank(p) + n <= size
3     for (int r = 0; r < n; r++) { //逐一为各节点
4         insertAfter(search(p->data, r, p), p->data); //查找适当的位置并插入
5         p = p->succ; remove(p->pred); //转向下一节点
6     }
7 }

```

代码3.19 列表的插入排序

按3.4.2节的约定，有多个元素命中时`search()`接口将返回其中最靠后者，排序之后重复元素将保持其原有次序，故以上插入排序算法属于稳定算法。

■ 复杂度

插入排序算法共由 n 步迭代组成，故其运行时间应取决于，各步迭代中所执行的查找、删除及插入操作的效率。根据此前3.3.5节和3.3.7节的结论，插入操作`insertAfter()`和删除操作`remove()`均只需 $\mathcal{O}(1)$ 时间；而由3.4.2节的结论，查找操作`search()`所需时间可在 $\mathcal{O}(1)$ 至 $\mathcal{O}(n)$ 之间浮动（从如表3.3所示的实例，也可看出这一点）。

不难验证，当输入序列已经有序时，该算法中的每次`search()`操作均仅需 $\mathcal{O}(1)$ 时间，总体运行时间为 $\mathcal{O}(n)$ 。但反过来，若输出序列完全逆序，则各次`search()`操作所需时间将线性递增，累计共需 $\mathcal{O}(n^2)$ 时间。在等概率条件下，平均仍需要 $\mathcal{O}(n^2)$ 时间（习题[3-10]）。

3.5.3 选择排序

选择排序（selectionsort）也适用于向量与列表之类的序列结构。

■ 构思

与插入排序类似，该算法也将序列划分为无序前缀和有序后缀两部分；此外，还要求前缀不大于后后缀。如此，每次只需从前缀中选出最大者，并作为最小元素转移至后缀中，即可使有序部分的范围不断扩张。

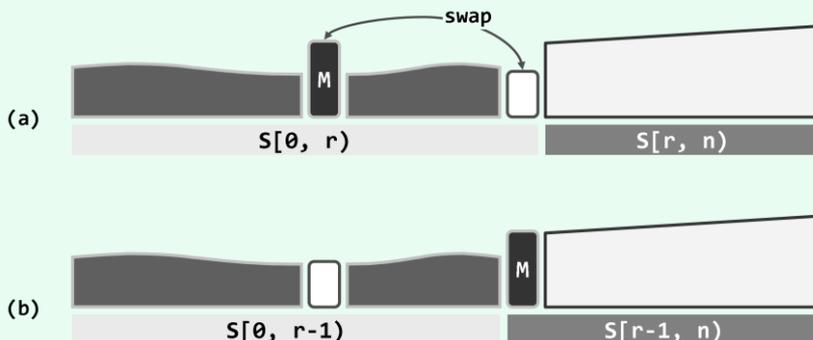


图3.6 序列的选择排序

同样地，上述描述也给出了选择排序算法过程所具有的不变性：

在任何时刻，后缀 $S[r, n)$ 已经有序，且不小于前缀 $S[0, r)$

在算法的初始时刻，后缀为空，不变性自然满足。如图3.6(a)所示，假设不变性已满足。于是，可调用无序序列的查找算法，从前缀中找出最大者 M 。接下来，只需将 M 从前缀中取出并作为首元素插入后缀，即可如图(b)所示，使得后缀的范围扩大，并继续保持有序。

如此，该后缀的范围可不断拓展。当其最终覆盖整个序列时，亦即整体有序。

■ 实例

表3.4 选择排序算法实例

#迭代	前缀无序子序列	后缀有序子序列
0	5 2 7 4 6 3 1	^
1	5 2 4 6 3 1	7
2	5 2 4 3 1	6 7
3	2 4 3 1	5 6 7
4	2 3 1	4 5 6 7
5	2 1	3 4 5 6 7
6	1	2 3 4 5 6 7
7	^	1 2 3 4 5 6 7

序列选择排序算法的一个实例如表3.4所示。其中，前后共经7步迭代，输入序列中的7个元素按由大到小的次序，依次被从无序前缀子序列中取出，并作为首元素插至初始为空的有序后缀序列中。无序子序列在各步迭代中的最大元素用方框注明。

■ 实现

依照以上思路，可针对列表实现选择排序算法如代码3.20所示。

```

1 template <typename T> //列表的选择排序算法：对起始于位置p的n个元素排序
2 void List<T>::selectionSort(ListNodePosi(T) p, int n) { //valid(p) && rank(p) + n <= size
3     ListNodePosi(T) head = p->pred; ListNodePosi(T) tail = p;
4     for (int i = 0; i < n; i++) tail = tail->succ; //待排序区间为(head, tail)
5     while (1 < n) { //在至少还剩两个节点之前，在待排序区间内
6         ListNodePosi(T) max = selectMax(head->succ, n); //找出最大者（歧义时后者优先）
7         insertBefore(tail, remove(max)); //将其移至无序区间末尾（作为有序区间新的首元素）
8         tail = tail->pred; n--;
9     }
10 }
```

代码3.20 列表的选择排序

其中的`selectMax()`接口用于在无序列表中定位最大节点，其实现如代码3.21所示。

```

1 template <typename T> //从起始于位置p的n个元素中选出最大者
2 ListNodePosi(T) List<T>::selectMax(ListNodePosi(T) p, int n) {
3     ListNodePosi(T) max = p; //最大者暂定为首节点p
4     for (ListNodePosi(T) cur = p; 1 < n; n--) //从首节点p出发, 将后续节点逐一与max比较
5         if (!lt((cur = cur->succ)->data, max->data)) //若当前元素不小于max, 则
6             max = cur; //更新最大元素位置记录
7     return max; //返回最大节点位置
8 }

```

代码3.21 列表最大节点的定位

■ 复杂度

与插入排序类似地, 选择排序亦由 n 步迭代组成, 故其运行时间取决于各步迭代中查找及插入操作的效率。根据3.3.5和3.3.7节的结论, `insertBefore()`和`remove()`均只需 $\mathcal{O}(1)$ 时间。`selectMax()`每次必须遍历整个无序前缀, 耗时应线性正比于前缀长度; 全程累计耗时 $\mathcal{O}(n^2)$ 。

实际上进一步地仔细观察之后不难发现, 无论输入序列中各元素的大小次序如何, 以上 n 次`selectMax()`调用的累计耗时总是 $\Theta(n^2)$ 。因此与插入排序算法不同, 以上选择排序算法的时间复杂度为固定的 $\Theta(n^2)$ 。也就是说, 其最好和最坏情况下的渐进效率相同。

选择排序属于CBA式算法, 故相对于2.7.5节所给出的 $\Omega(n \log n)$ 下界, $\Theta(n^2)$ 的效率应有很大的改进空间。正如我们将在10.2.5节看到的, 借助更为高级的数据结构, 可以令单次`selectMax()`操作的复杂度降至 $\mathcal{O}(\log n)$, 从而使选择排序的整体效率提高至 $\mathcal{O}(n \log n)$ 。

3.5.4 归并排序

2.8.3节介绍过基于二路归并的向量排序算法, 其构思也同样适用于列表结构。实际上, 有序列表的二路归并不仅可以实现, 而且能够达到与有序向量二路归并同样高的效率。

■ 二路归并算法的实现

代码3.22针对有序列表结构, 给出了二路归并算法的一种实现。

```

1 template <typename T> //有序列表的归并: 当前列表中自p起的n个元素, 与列表L中自q起的m个元素归并
2 void List<T>::merge(ListNodePosi(T)& p, int n, List<T>& L, ListNodePosi(T) q, int m) {
3     // assert: this.valid(p) && rank(p) + n <= size && this.sorted(p, n)
4     //         L.valid(q) && rank(q) + m <= L._size && L.sorted(q, m)
5     // 注意: 在归并排序之类的场合, 有可能 this == L && rank(p) + n = rank(q)
6     ListNodePosi(T) pp = p->pred; //借助前驱(可能是header), 以便返回前 ...
7     while (0 < m) //在q尚未移出区间之前
8         if ((0 < n) && (p->data <= q->data)) //若p仍在区间内且v(p) <= v(q), 则
9             { if (q == (p = p->succ)) break; n--; } //将p替换为其直接后继(等效于将p归入合并的列表)
10            else //若p已超出右界或v(q) < v(p), 则
11                { insertBefore(p, L.remove((q = q->succ)->pred)); m--; } //将q转移至p之前
12    p = pp->succ; //确定归并后区间的(新)起点
13 }

```

代码3.22 有序列表的二路归并

作为有序列表的内部接口，`List::merge()`可以将另一有序列表L中起始于节点q、长度为m的子列表，与当前有序列表中起始于节点p、长度为n的子列表做二路归并。

为便于递归地实现上层的归并排序，在二路归并的这一版本中，归并所得的有序列表依然起始于节点p。在更为通用的场合，不见得需要采用这一约定。

■ 归并时间

代码3.22中二路归并算法`merge()`的时间成本主要消耗于其中的迭代。该迭代反复地比较两个子列表的首节点p和q，并视其大小相应地令p指向其后继，或将节点q取出并作为p的前驱插入前一子列表。当且仅当后一子列表中所有节点均处理完毕时，迭代才会终止。因此，在最好情况下，共需迭代m次；而在最坏情况下，则需迭代n次。

总体而言，共需 $O(n + m)$ 时间，线性正比于两个子列表的长度之和。

■ 特例

在List模板类（70页代码3.2）中，作为以上二路归并通用接口的一个特例，还重载并开放了另一个接口`List::merge(L)`，用以将有序列表L完整地归并到当前有序列表中。

请注意，以上二路归并算法的通用接口，对列表L没有过多的限定，因此同样作为一个特例，该算法也适用于L同为当前列表的情形。此时，待归并的列表实际上是来自同一列表的两个子列表（当然，此时的两个子列表不得相互重叠。也就是说，在两个首节点中，p应是q的前驱，且二者的间距不得小于n）。对以下归并排序算法的简捷实现而言，这一特性至关重要。

■ 分治策略

仿照向量的归并排序算法`mergesort()`（62页代码2.28），采用分治策略并基于以上有序列表的二路归并算法，可如代码3.23所示，递归地描述和实现列表的归并排序算法。

```
1 template <typename T> //列表的归并排序算法：对起始于位置p的n个元素排序
2 void List<T>::mergeSort(ListNodePosi(T)& p, int n) { //valid(p) && rank(p) + n <= size
3     if (n < 2) return; //若待排序范围已足够小，则直接返回；否则...
4     int m = n >> 1; //以中点为界
5     ListNodePosi(T) q = p; for (int i = 0; i < m; i++) q = q->succ; //均分列表
6     mergeSort(p, m); mergeSort(q, n - m); //对前、后子列表分别排序
7     merge(p, m, *this, q, n - m); //归并
8 } //注意：排序后，p依然指向归并后区间的（新）起点
```

代码3.23 列表的归并排序

■ 排序时间

根据该算法的流程，为对长度为n的列表做归并排序，首先需要花费线性时间确定居中的切分节点，然后递归地对长度均为n/2的两个子列表做归并排序，最后还需花费线性的时间做二路归并。因此，仿照2.8.3节对向量归并排序算法的分析方法，同样可知其复杂度应为 $O(n \log n)$ 。另外，以上列表归并排序算法的递归跟踪过程，与如图2.19所示的向量版本别无二致。故从递归跟踪的角度，亦可得出同样的结论。

请注意，在子序列的划分阶段，向量与列表归并排序算法之间存在细微但本质的区别。前者支持循序访问的方式，故可在 $O(1)$ 时间内确定切分中点；后者仅支持循位置访问的方式，故不得不为此花费 $O(n)$ 时间。幸好在有序子序列的合并阶段二者均需 $O(n)$ 时间，故二者的渐进时间

复杂度依然相等。

最后，尽管二路归并算法并未对子列表的长度做出任何限制，但这里出于整体效率的考虑，在划分子列表时宁可花费 $O(n)$ 时间使得二者尽可能接近于等长。反之，若为省略这部分时间而不保证划分的均衡性，则反而可能导致整体效率的下降（习题[3-16]）。

第4章

栈与队列

本章将定制并实现更加基本，且更为常用的两类数据结构——栈与队列。与此前介绍的向量和列表一样，它们也属于线性序列结构，故其中存放的数据对象之间也具有线性次序。相对于一般的序列结构，栈与队列的数据操作范围仅限于逻辑上的特定某端。然而，得益于其简洁性与规范性，它们既成为构建更复杂、更高级数据结构的基础，同时也是算法设计的基本出发点，甚至常常作为标准配置的基本数据结构以硬件形式直接实现。因此无论就工程或理论而言，其基础性地位都是其它结构无法比拟的。

在信息处理领域，栈与队列的身影随处可见。许多程序语言本身就是建立于栈结构之上，无论PostScript或者Java，其实时运行环境都是基于栈结构的虚拟机。再如，网络浏览器多会将用户最近访问过的地址组织为一个栈。这样，用户每访问一个新页面，其地址就会被存放至栈顶；而用户每按下一次“后退”按钮，即可沿相反的次序返回此前刚访问过的页面。类似地，主流的文本编辑器也大都支持编辑操作的历史记录功能，用户的编辑操作被依次记录在一个栈中。一旦出现误操作，用户只需按下“撤销”按钮，即可取消最近一次操作并回到此前的编辑状态。

在需要公平且经济地对各种自然或社会资源做管理或分配的场合，无论是调度银行和医院的服务窗口，还是管理轮耕的田地和轮伐的森林，队列都可大显身手。甚至计算机及其网络自身内部的各种计算资源，无论是多进程共享的CPU时间，还是多用户共享的打印机，也都需要借助队列结构实现合理和优化的分配。

相对于向量和列表，栈与队列的外部接口更为简化和紧凑，故亦可视作向量与列表的特例，因此C++的继承与封装机制在此可以大显身手。得益于此，本章的重点将不再拘泥于对数据结构内部实现机制的展示，并转而更多地从其外部特性出发，结合若干典型的实际问题介绍栈与队列的具体应用。

在栈的应用方面，本章将在1.4节的基础上，结合函数调用栈的机制介绍一般函数调用的实现方式与过程，并将其推广至递归调用。然后以降低空间复杂度的目标为线索，介绍通过显式地维护栈结构解决应用问题的典型方法和基本技巧。此外，还将着重介绍如何利用栈结构，实现基于试探回溯策略的高效搜索算法。在队列的应用方面，本章将介绍如何实现基于轮值策略的通用循环分配器，并以银行窗口服务为例实现基本的调度算法。

§ 4.1 栈

4.1.1 ADT接口

■ 入栈与出栈

栈（stack）是存放数据对象的一种特殊容器，其中的数据元素按线性的逻辑次序排列，故也可定义首、末元素。不过，尽管栈结构也支持对象的插入和删除操作，但其操作的范围仅限于栈的某一特定端。也就是说，若约定新的元素只能从某一端插入其中，则反过来也只能从这一端删除已有的元素。禁止操作的另一端，称作盲端。



图4.1 一摞椅子即是一个栈

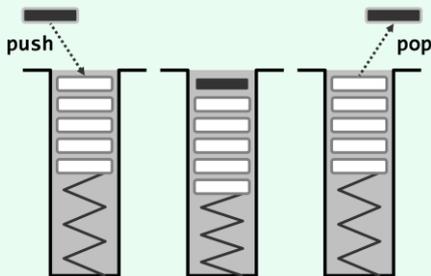


图4.2 栈操作

如图4.1所示，数把椅子叠成一摞即可视作一个栈。为维持这一放置形式，对该栈可行的操作只能在其顶部实施：新的椅子只能叠放到最顶端；反过来，只有最顶端的椅子才能被取走。因此比照这类实例，栈中可操作的一端更多地称作栈顶（**stack top**），而另一无法直接操作的盲端则更多地称作栈底（**stack bottom**）。

作为抽象数据类型，栈所支持的操作接口可归纳为表4.1。其中除了引用栈顶的**top()**等操作外，如图4.2所示，最常用的插入与删除操作分别称作入栈（**push**）和出栈（**pop**）。

表4.1 栈ADT支持的操作接口

操作接口	功能
size()	报告栈的规模
empty()	判断栈是否为空
push(e)	将e插至栈顶
pop()	删除栈顶对象
top()	引用栈顶对象

■ 后进先出

由以上关于栈操作位置的约定和限制不难看出，栈中元素接受操作的次序必然始终遵循所谓“后进先出”（**last-in-first-out, LIFO**）的规律：从栈结构的整个生命期来看，更晚（早）出栈的元素，应为更早（晚）入栈者；反之，更晚（早）入栈者应更早（晚）出栈。

4.1.2 操作实例

表4.2给出了一个存放整数的栈从被创建开始，按以上接口实施一系列操作的过程。

表4.2 栈操作实例

操作	输出	栈 (左侧为栈顶)	操作	输出	栈 (左侧为栈顶)
Stack()			push(11)		11 3 7 5
empty()	true		size()	4	11 3 7 5
push(5)		5	push(6)		6 11 3 7 5
push(3)		3 5	empty()	false	6 11 3 7 5
pop()	3	5	push(7)		7 6 11 3 7 5
push(7)		7 5	pop()	7	6 11 3 7 5
push(3)		3 7 5	pop()	6	11 3 7 5
top()	3	3 7 5	top()	11	11 3 7 5
empty()	false	3 7 5	size()	4	11 3 7 5

4.1.3 Stack模板类

既然栈可视为序列的特例，故只要将栈作为向量的派生类，即可利用C++的继承机制，基于2.2.3节定义的向量模板类实现栈结构。当然，这里需要按照栈的习惯，对各接口重新命名。

按照表4.1所列的ADT接口，可描述并实现Stack模板类如代码4.1所示。

```

1 #include "../Vector/Vector.h" //以向量为基类，派生出栈模板类
2 template <typename T> class Stack: public Vector<T> { //将向量的首/末端作为栈底/顶
3 public: //size()、empty()以及其它开放接口，均可直接沿用
4     void push(T const& e) { insert(size(), e); } //入栈：等效于将新元素作为向量的末元素插入
5     T pop() { return remove(size() - 1); } //出栈：等效于删除向量的末元素
6     T& top() { return (*this)[size() - 1]; } //取顶：直接返回向量的末元素
7 };

```

代码4.1 Stack模板类

既然栈操作都限制于向量的末端，参与操作的元素没有任何后继，故由2.5.5节和2.5.6节的分析结论可知，以上栈接口的时间复杂度均为常数。

套用以上思路，也可直接基于3.2.2节的List模板类派生出Stack类（习题[4-1]）。

§ 4.2 栈与递归

习题[1-17]指出，递归算法所需的空间量，主要决定于最大递归深度。在达到这一深度的时刻，同时活跃的递归实例达到最多。那么，操作系统具体是如何实现函数（递归）调用的？如何记录调用与被调用函数（递归）实例之间的关系？如何实现函数（递归）调用的返回？又是如何维护同时活跃的所有函数（递归）实例的？所有这些问题的答案，都可归结于栈。

4.2.1 函数调用栈

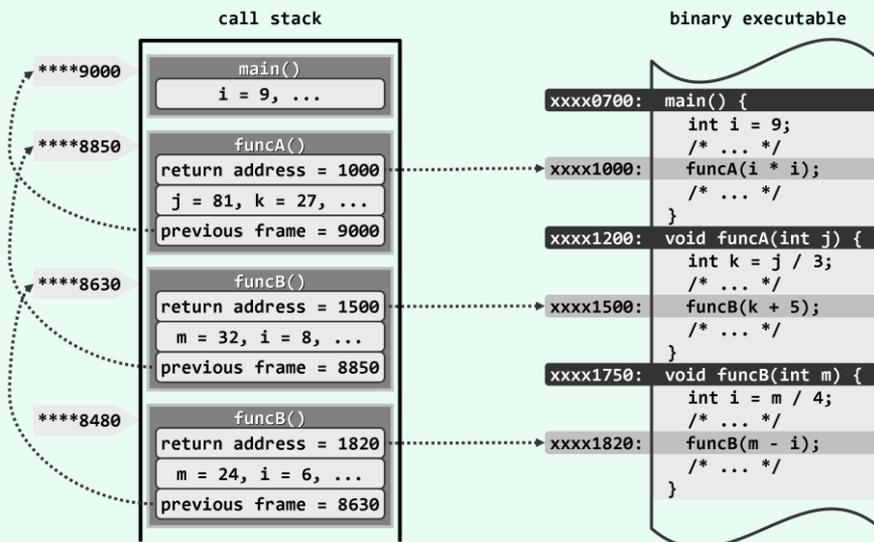


图4.3 函数调用栈实例：主函数main()调用funcA()，funcA()调用funcB()，funcB()再自我调用

在Windows等大部分操作系统中，每个运行中的二进制程序都配有一个调用栈（`call stack`）或执行栈（`execution stack`）。借助调用栈可以跟踪属于同一程序的所有函数，记录它们之间的相互调用关系，并保证在每一调用实例执行完毕之后，可以准确地返回。

■ 函数调用

如图4.3所示，调用栈的基本单位是帧（`frame`）。每次函数调用时，都会相应地创建一帧，记录该函数实例在二进制程序中的返回地址（`return address`），以及局部变量、传入参数等，并将该帧压入调用栈。若在该函数返回之前又发生新的调用，则同样地要将与新函数对应的一帧压入栈中，成为新的栈顶。函数一旦运行完毕，对应的帧随即弹出，运行控制权将被交还给该函数的上层调用函数，并按照该帧中记录的返回地址确定在二进制程序中继续执行的位置。

在任一时刻，调用栈中的各帧，依次对应于那些尚未返回的调用实例，亦即当时的活跃函数实例（`active function instance`）。特别地，位于栈底的那帧必然对应于入口主函数`main()`，若它从调用栈中弹出，则意味着整个程序的运行结束，此后控制权将交还给操作系统。

仿照递归跟踪法，程序执行过程出现过的函数实例及其调用关系，也可构成一棵树，称作该程序的运行树。任一时刻的所有活跃函数实例，在调用栈中自底到顶，对应于运行树中从根节点到最新活跃函数实例的一条调用路径。

此外，调用栈中各帧还需存放其它内容。比如，因各帧规模不一，它们还需记录前一帧的起始地址，以保证其出栈之后前一帧能正确地恢复。

■ 递归

作为函数调用的特殊形式，递归也可借助上述调用栈得以实现。比如在图4.3中，对应于`funcB()`的自我调用，也会新压入一帧。可见，同一函数可能同时拥有多个实例，并在调用栈中各自占有一帧。这些帧的结构完全相同，但其中同名的参数或变量，都是独立的副本。比如在`funcB()`的两个实例中，入口参数`m`和内部变量`i`各有一个副本。

4.2.2 避免递归

今天，包括C++在内的各种高级程序设计语言几乎都允许函数直接或间接地自我调用，通过递归来提高代码的简洁度和可读性。而Cobol和Fortran等早期的程序语言虽然一开始并未采用栈来实现过程调用，但在其最新的版本中也陆续引入了栈结构来支持过程调用。

尽管如此，系统在后台隐式地维护调用栈的过程中，难以区分哪些参数和变量是对计算过程有实质作用的，更无法以通用的方式对它们进行优化，因此不得不将描述调用现场的所有参数和变量悉数入栈。再加上每一帧都必须保存的执行返回地址以及前一帧起始位置，往往导致程序的空间效率不高甚至极低；同时，隐式的入栈和出栈操作也会令实际的运行时间增加不少。

因此在追求更高效率的场合，应尽可能地避免递归，尤其是过度的递归。实际上，我们此前已经介绍过相应的方法和技巧。例如，在1.4.4节中将尾递归转换为等效的迭代形式；在1.4.5节中采用动态规划策略，将Fibonacci数算法中的二分递归改为线性递归，直至完全消除递归。

既然递归本身就是操作系统隐式地维护一个调用栈而实现的，我们自然也可以通过显式地模拟调用栈的运转过程，实现等效的算法功能。采用这一方式，程序员可以精细地裁剪栈中各帧的内容，从而尽可能降低空间复杂度的常系数。尽管算法原递归版本的高度概括性和简洁性将大打折扣，但毕竟在空间效率方面可以获得足够的补偿。

§ 4.3 栈的典型应用

4.3.1 逆序输出

在栈所擅长解决的典型问题中，有一类具有以下共同特征：首先，虽有明确的算法，但其解答却以线性序列的形式给出；其次，无论是递归还是迭代实现，该序列都是依逆序计算输出的；最后，输入和输出规模不确定，难以事先确定盛放输出数据的容器大小。因其特有的“后进先出”特性及其在容量方面的自适应性，使用栈来解决此类问题可谓恰到好处。

■ 进制转换

考查如下问题：任给十进制整数 n ，将其转换为 λ 进制的表示形式。比如 $\lambda = 8$ 时有

$$12345_{(10)} = 30071_{(8)}$$

一般地，设 $n = (d_m \dots d_2 d_1 d_0)_{(\lambda)} = d_m \times \lambda^m + \dots + d_2 \times \lambda^2 + d_1 \times \lambda^1 + d_0 \times \lambda^0$

若记 $n_i = (d_m \dots d_{i+1} d_i)_{(\lambda)}$

则有 $d_i = n_i \% \lambda$ 和 $n_{i+1} = n_i / \lambda$

这一递推关系对应的计算流程如下。可见，其输出的确为长度不定的逆序线性序列。

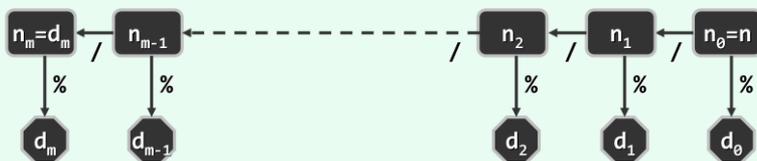


图4.4 进制转换算法流程

■ 递归实现

根据如图4.4所示的计算流程，可得到如代码4.2所示递归式算法。

```

1 void convert(Stack<char>& S, __int64 n, int base) { //十进制数n到base进制的转换（递归版）
2     static char digit[] //0 < n, 1 < base <= 16, 新进制下的数位符号，可视base取值范围适当扩充
3     = { '0', '1', '2', '3', '4', '5', '6', '7', '8', '9', 'A', 'B', 'C', 'D', 'E', 'F' };
4     if (0 < n) { //在尚有余数之前，不断
5         convert(S, n / base, base); //通过递归得到所有更高位
6         S.push(digit[n % base]); //输出低位
7     }
8 } //新进制下由高到低的各数位，自顶而下保存于栈S中

```

代码4.2 进制转换算法（递归版）

尽管新进制下的各数位须按由低到高次序逐位算出，但只要引入一个栈并将算得的数位依次入栈，则在计算结束后只需通过反复的出栈操作即可由高到低地将其顺序输出。

■ 迭代实现

这里的静态数位符号表在全局只需保留一份，但与一般的递归函数一样，该函数在递归调用栈中的每一帧都仍需记录参数 S 、 n 和 $base$ 。将它们改为全局变量固然可以节省这部分空间，但依然不能彻底地避免因调用栈操作而导致的空间和时间消耗。为此，不妨考虑改写为如代码4.3所示的迭代版本，既能充分发挥栈处理此类问题的特长，又可将空间消耗降至 $O(1)$ 。

```

1 void convert(Stack<char>& S, __int64 n, int base) { //十进制数n到base进制的转换(迭代版)
2     static char digit[] //0 < n, 1 < base <= 16, 新进制下的数位符号, 可视base取值范围适当扩充
3     = { '0', '1', '2', '3', '4', '5', '6', '7', '8', '9', 'A', 'B', 'C', 'D', 'E', 'F' };
4     while (n > 0) { //由低到高, 逐一计算出新进制下的各数位
5         int remainder = (int) (n % base); S.push(digit[remainder]); //余数(当前位)入栈
6         n /= base; //n更新为其对base的除商
7     }
8 } //新进制下由高到低的各数位, 自顶而下保存于栈S中

```

代码4.3 进制转换算法(迭代版)

4.3.2 递归嵌套

具有自相似性的问题多可嵌套地递归描述, 但因分支位置和嵌套深度并不固定, 其递归算法的复杂度不易控制。栈结构及其操作天然地具有递归嵌套性, 故可用以高效地解决这类问题。以下先从混洗的角度介绍栈的递归嵌套性, 然后再讲解其在具体问题中的应用。

■ 栈混洗

考查三个栈A、B和S, 其中A含有n个元素, 自顶而下构成输入序列:

$$\{ a_1, a_2, \dots, a_n \}$$

B和S初始为空。若只允许通过S.push(A.pop())弹出栈A的顶元素并压入栈S中, 或通过B.push(S.pop())弹出S的顶元素并压入栈B中, 则在经过一系列这样的操作后, 当栈A和S均为空时, 原A中的元素应均已转入栈B。此时, 若将B中元素自底而上构成的序列记作:

$$\{ a_{k_1}, a_{k_2}, \dots, a_{k_n} \}$$

则该序列称作原输入序列的一个栈混洗(stack permutation)。

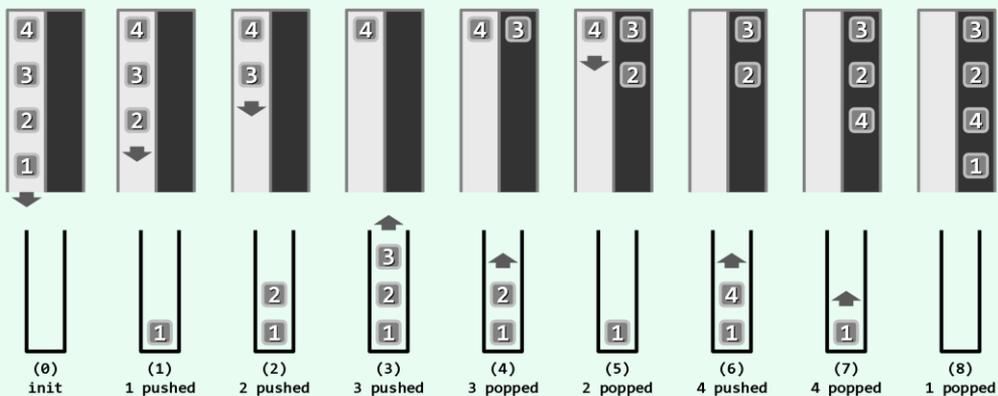


图4.5 栈混洗实例: 从{ 1, 2, 3, 4 }到{ 3, 2, 4, 1 } (上方左侧为栈A, 右侧为栈B; 下方为栈S)

如图4.5所示, 设初始状态下栈A = { 1, 2, 3, 4 }, 栈S和B均为空; 经过“随机的”8次操作, A中的元素全部转入栈B中。此时, 栈B中元素自底而上对应的序列{ 3, 2, 4, 1 }, 即是原序列{ 1, 2, 3, 4 }的一个栈混洗。除了“实施出栈操作的栈不得为空”, 以上过程并无更多限制, 操作序列具有很大的随机性, 故同一输入序列的栈混洗并不唯一。比如就上例而言, { 1, 2, 3, 4 }、{ 4, 3, 2, 1 }以及{ 3, 2, 1, 4 }等也是栈混洗。

从图4.5也可看出，一般地对于长度为 n 的输入序列，每一栈混洗都对应于由栈 S 的 n 次push和 n 次pop构成的某一合法操作序列，比如{ 3, 2, 4, 1 }即对应于操作序列：

{ push, push, push, pop, pop, push, pop, pop }

反之，由 n 次push和 n 次pop构成的任何操作序列，只要满足“任一前缀中的push不少于pop”这一限制，则该序列也必然对应于某个栈混洗（习题[4-4]）。

■ 括号匹配

对源程序的语法检查是代码编译过程中重要而基本的一个步骤，而对表达式括号匹配的检查则又是语法检查中必需的一个环节。其任务是，对任一程序块，判断其中的括号是否在嵌套的意义下完全匹配（简称匹配）。比如在以下两个表达式中，前者匹配，而后者不匹配。

$a / (b [i - 1] [j + 1] + c [i + 1] [j - 1]) * 2$

$a / (b [i - 1] [j + 1]) + c [i + 1] [j - 1]) * 2$

■ 递归实现

不妨先只考虑圆括号。用 '+' 表示表达式的串接。

不难理解，一般地，若表达式 S 可分解为如下形式：

$S = S_0 + "(+ S_1 +)" + S_2 + S_3$

其中 S_0 和 S_3 不含括号，且 S_1 中左、右括号数目相等，则 S 匹配当且仅当 S_1 和 S_2 均匹配。

按照这一理解，可采用分治策略设计算法如下：将表达式划分为子表达式 S_0 、 S_1 和 S_2 ，分别递归地判断 S_1 和 S_2 是否匹配。这一构思可具体实现如代码4.4所示。

```

1 void trim(const char exp[], int& lo, int& hi) { //删除表达式exp[lo, hi]不含括号的最长前缀、后缀
2     while ((lo <= hi) && (exp[lo] != '(') && (exp[lo] != ')) lo++; //查找第一个和
3     while ((lo <= hi) && (exp[hi] != '(') && (exp[hi] != ')) hi--; //最后一个括号
4 }
5
6 int divide(const char exp[], int lo, int hi) { //切分表达式exp[lo, hi]，使exp匹配仅当它们匹配
7     int mi = lo; int crc = 1; //crc为[lo, mi]范围内左、右括号数目之差
8     while ((0 < crc) && (++mi < hi)) //逐个检查各字符，直到左、右括号数目相等，或者越界
9         { if (exp[mi] == ')') crc--; if (exp[mi] == '(') crc++; } //左、右括号分别计数
10    return mi; //若mi <= hi，则为合法切分点；否则，意味着局部不可能匹配
11 }
12
13 bool paren(const char exp[], int lo, int hi) { //检查表达式exp[lo, hi]是否括号匹配（递归版）
14    trim(exp, lo, hi); if (lo > hi) return true; //清除不含括号的前缀、后缀
15    if (exp[lo] != '(') return false; //首字符非左括号，则必不匹配
16    if (exp[hi] != ')') return false; //末字符非右括号，则必不匹配
17    int mi = divide(exp, lo, hi); //确定适当的切分点
18    if (mi > hi) return false; //切分点不合法，意味着局部以至整体不匹配
19    return paren(exp, lo + 1, mi - 1) && paren(exp, mi + 1, hi); //分别检查左、右子表达式
20 }

```

代码4.4 括号匹配算法（递归版）

其中, `trim()` 函数用于截除表达式中不含括号的头部和尾部, 即前缀 S_0 和后缀 S_3 。 `divide()` 函数对表达式做线性扫描, 并动态地记录已经扫描的左、右括号数目之差。如此, 当已扫过同样多的左、右括号时, 即确定了一个合适的切分点 mi , 并得到子表达式 $S_1 = \text{exp}(lo, mi)$ 和 $S_2 = \text{exp}(mi, hi]$ 。以下, 经递归地检查 S_1 和 S_2 , 即可判断原表达式是否匹配。

在最坏情况下 `divide()` 需要线性时间, 且递归深度为 $O(n)$, 故以上算法共需 $O(n^2)$ 时间。此外, 该方法也难以处理含有多种括号的表达式 (习题 [4-5] 和 [4-15]), 故有必要进一步优化。

■ 迭代实现

实际上, 只要将 `push`、`pop` 操作分别与左、右括号相对应, 则长度为 n 的栈混洗, 必然与由 n 对括号组成的合法表达式彼此对应 (习题 [4-4])。比如, 栈混洗 { 3, 2, 4, 1 } 对应于表达式 "((()) ())"。按照这一理解, 借助栈结构, 只需扫描一趟表达式, 即可在线性时间内, 判定其中的括号是否匹配。这一新的算法, 可简明地实现如代码 4.5 所示。

```

1 bool paren(const char exp[], int lo, int hi) { //表达式括号匹配检查,可兼顾三种括号
2     Stack<char> S; //使用栈记录已发现但尚未匹配的左括号
3     for (int i = 0; exp[i]; i++) /* 逐一检查当前字符 */
4         switch (exp[i]) { //左括号直接进栈;右括号若与栈顶失配,则表达式必不匹配
5             case '(': case '[': case '{': S.push(exp[i]); break;
6             case ')': if ((S.empty()) || ('(' != S.pop())) return false; break;
7             case ']': if ((S.empty()) || ('[' != S.pop())) return false; break;
8             case '}': if ((S.empty()) || ('{' != S.pop())) return false; break;
9             default: break; //非括号字符一律忽略
10        }
11    return S.empty(); //整个表达式扫描过后,栈中若仍残留(左)括号,则不匹配;否则(栈空)匹配
12 }

```

代码4.5 括号匹配算法(迭代版)

新算法的流程控制简单,而且便于推广至多类括号并存的情况。它自左向右逐个考查各字符,忽略所有非括号字符。凡遇到左括号,无论属于哪类均统一压入栈 S 中。若遇右括号,则弹出栈顶的左括号并与之比对。若二者属于同类,则继续检查下一字符;否则,即可断定表达式不匹配。当然,栈 S 提前变空或者表达式扫描过后栈 S 非空,也意味着不匹配。

图 4.6 给出了一次完整的计算过程。表达式扫描完毕时,栈 S 恰好为空,故知表达式匹配。

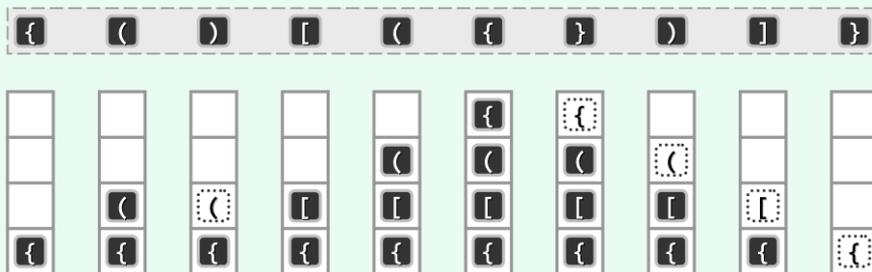


图 4.6 迭代式括号匹配算法实例

(上方为输入表达式;下方为辅助栈的演变过程;虚框表示在(右)括号与栈顶(左)括号匹配时对应的出栈操作)

4.3.3 延迟缓冲

在一些应用问题中，输入可分解为多个单元并通过迭代依次扫描处理，但过程中的各步计算往往滞后于扫描的进度，需要待到必要的信息已完整到一定程度之后，才能作出判断并实施计算。在这类场合，栈结构则可以扮演数据缓冲区的角色。

■ 表达式求值

在编译C++程序的预处理阶段，源程序中的所有常量表达式都需首先计算并替换为对应的具体数值。而在解释型语言中，算术表达式的求值也需随着脚本执行过程中反复进行。

比如，在UNIX Shell、DOS Shell和PostScript交互窗口中分别输入：

```
$ echo $(( 0 + ( 1 + 23 ) / 4 * 5 * 67 - 8 + 9 ))
\> set /a (( 0 + ( 1 + 23 ) / 4 * 5 * 67 - 8 + 9 ))
GS> 0 1 23 add 4 div 5 mul 67 mul add 8 sub 9 add =
```

都将返回“2011”。

可见，不能简单地按照“先左后右”的次序执行表达式中的运算符。关于运算符执行次序的规则（即运算优先级），一部分决定于事先约定的惯例（比如乘除优先于加减），另一部分则决定于括号。也就是说，仅根据表达式的某一前缀，并不能完全确定其中各运算符可否执行以及执行的次序；只有在已获得足够多后续信息之后，才能确定其中哪些运算符可以执行。

■ 优先级表

我们首先如代码4.6所示，将不同运算符之间的运算优先级关系，描述为一张二维表格。

```
1 #define N_OPTR 9 //运算符总数
2 typedef enum {ADD, SUB, MUL, DIV, POW, FAC, L_P, R_P, EOE} Operator; //运算符集合
3 //加、减、乘、除、乘方、阶乘、左括号、右括号、起始符与终止符
4
5 const char pri[N_OPTR][N_OPTR] = { //运算符优先等级 [栈顶] [当前]
6     /*          |----- 当前运算符 -----| */
7     /*          +   -   *   /   ^   !   (   )   \0 */
8     /* -- + */ '>', '>', '<', '<', '<', '<', '<', '>', '>',
9     /* | - */ '>', '>', '<', '<', '<', '<', '<', '>', '>',
10    /* 栈 * */ '>', '>', '>', '>', '<', '<', '<', '>', '>',
11    /* 顶 / */ '>', '>', '>', '>', '<', '<', '<', '>', '>',
12    /* 运 ^ */ '>', '>', '>', '>', '>', '<', '<', '>', '>',
13    /* 算 ! */ '>', '>', '>', '>', '>', '>', ' ', '>', '>',
14    /* 符 ( */ '<', '<', '<', '<', '<', '<', '<', '=', ' ',
15    /* | ) */ ' ', ' ', ' ', ' ', ' ', ' ', ' ', ' ', ' ',
16    /* -- \0 */ '<', '<', '<', '<', '<', '<', '<', ' ', '='
17 };
```

代码4.6 运算符优先级关系的定义

在常规的四则运算之外，这里还引入了乘方和阶乘运算。其中阶乘属于一元运算，且优先级最高。为统一算法的处理流程，将左、右括号以及标识表达式尾部的字符'\0'，也视作运算符。

■ 求值算法

基于运算符优先级如上的定义和判定规则，可实现表达式求值算法如代码4.7所示。

```

1 float evaluate(char* S, char*& RPN) { //对(已剔除空白格的)表达式S求值,并转换为逆波兰式RPN
2     Stack<float> opnd; Stack<char> optr; //运算数栈、运算符栈
3     optr.push('\0'); //尾哨兵'\0'也作为头哨兵首先入栈
4     while (!optr.empty()) { //在运算符栈非空之前,逐个处理表达式中各字符
5         if (isdigit(*S)) { //若当前字符为操作数,则
6             readNumber(S, opnd); append(RPN, opnd.top()); //读入操作数,并将其接至RPN末尾
7         } else //若当前字符为运算符,则
8             switch(orderBetween(optr.top(), *S)) { //视其与栈顶运算符之间优先级高低分别处理
9                 case '<': //栈顶运算符优先级更低时
10                    optr.push(*S); S++; //计算推迟,当前运算符进栈
11                    break;
12                 case '=': //优先级相等(当前运算符为右括号或者尾部哨兵'\0')时
13                    optr.pop(); S++; //脱括号并接收下一个字符
14                    break;
15                 case '>': { //栈顶运算符优先级更高时,可实施相应的计算,并将结果重新入栈
16                    char op = optr.pop(); append(RPN, op); //栈顶运算符出栈并续接至RPN末尾
17                    if ('!' == op) { //若属于一元运算符
18                        float pOpnd = opnd.pop(); //只需取出一个操作数,并
19                        opnd.push(calcu(op, pOpnd)); //实施一元计算,结果入栈
20                    } else { //对于其它(二元)运算符
21                        float pOpnd2 = opnd.pop(), pOpnd1 = opnd.pop(); //取出后、前操作数
22                        opnd.push(calcu(pOpnd1, op, pOpnd2)); //实施二元计算,结果入栈
23                    }
24                    break;
25                }
26                default : exit(-1); //逢语法错误,不做处理直接退出
27            } //switch
28        } //while
29        return opnd.pop(); //弹出并返回最后的计算结果
30 }

```

代码4.7 表达式的求值及RPN转换

该算法自左向右扫描表达式，并对其中字符逐一做相应的处理。那些已经扫描过但（因信息不足）尚不能处理的操作数与运算符，将分别缓冲至栈opnd和栈optr。一旦判定已缓存的子表达式优先级足够高，便弹出相关的操作数和运算符，随即执行运算，并将结果压入栈opnd。

请留意这里区分操作数和运算符的技巧。一旦当前字符由非数字转为数字，则意味着开始进入一个对应于操作数的子串范围。由于这里允许操作数含有多个数位，甚至可能是小数，故可调用readNumber()函数（习题[4-6]），根据当前字符及其后续的若干字符，利用另一个栈解析出当前的操作数。解析完毕，当前字符将再次聚焦于一个非数字字符。

■ 不同优先级的处置

按照代码4.7，若当前字符为运算符，则在调用`orderBetween()`函数（习题[4-7]），将其与栈`optr`的栈顶操作符做一比较之后，即可视二者的优先级高低，分三种情况相应地处置。

1) 若当前运算符的优先级更高，则`optr`中的栈顶运算符尚不能执行

以表达式“`1 + 2 * 3 ...`”为例，在扫描到运算符`*`时，`optr`栈顶运算符为此前的`+`，由于`pri['+']['*'] = '<'`，当前运算符`*`优先级更高，故栈顶运算符`+`的执行必须推迟。

请注意，由代码4.6定义的优先级表，无论栈顶元素如何，当前操作符为`(`的所有情况均统一归入这一处理方式；另外，无论当前操作符如何，栈顶操作符为`(`的所有情况也统一按此处理。也就是说，所有左括号及其后紧随的一个操作符都会相继地被直接压入`optr`栈中，而此前的运算符则一律押后执行——这与左括号应有的功能完全吻合。

2) 反之，一旦栈顶运算符的优先级更高，则可以立即弹出并执行对应的运算

以表达式“`1 + 2 * 3 - 4 ...`”为例，在扫描到运算符`-`时，`optr`栈顶运算符为`*`，由于`pri['*']['-'] = '>'`，意味着当前运算符的优先级更低，故栈顶运算符`*`可立即执行。

类似地，根据代码4.6定义的优先级表，无论栈顶元素如何，当前操作符为`)`的情况也几乎全部归入这一处理方式。也就是说，一旦抵达右括号，此前在`optr`栈缓冲的运算符大都可以逐一弹出并执行——这与右括号应有的功能也完全吻合。

3) 当前运算符与栈顶运算符的优先级“相等”

对右括号的上述处理方式，将在`optr`栈顶出现操作符`(`时终止——由代码4.6可知，`pri['('][')'] = '='`。此时，将弹出栈顶的`(`，然后继续处理`)`之后的字符。不难看出，这对左、右括号在表达式中必然相互匹配，其作用在于约束介乎二者之间的那段子表达式的优先级关系，故在其“历史使命”完成之后，算法做如上处置理所应当。

除左、右括号外，还有一种优先级相等的合法情况，即`pri['\0']['\0'] = '='`。由于在算法启动之初已经首先将字符`\0`压入`optr`栈，故在整个表达式已被正确解析并抵达表达式结束标识符`\0`时，即出现这一情况。对于合法的表达式，这种情况只在算法终止前出现一次。既然同是需要弹出栈顶，算法不妨将这种情况按照优先级相等的方式处置。

■ 语法检查及鲁棒性

为简洁起见，以上算法假设输入表达式的语法完全正确；否则，有可能会产生荒诞的结果。读者可在此基础上，尝试扩充语法检查以及对各种非法情况的处理功能（习题[4-12]）。

4.3.4 逆波兰表达式

■ RPN

逆波兰表达式（reverse Polish notation, RPN）是数学表达式的一种，其语法规则可概括为：操作符紧邻于对应的（最后一个）操作数之后。比如“`1 2 +`”即通常习惯的“`1 + 2`”。

按此规则，可递归地得到更复杂的表达式，比如RPN表达式

$$1\ 2\ +\ 3\ 4\ \wedge\ *$$

即对应于常规的表达式

$$(1 + 2) * 3 \wedge 4$$

RPN表达式亦称作后缀表达式（*postfix*），原表达式则称作中缀表达式（*infix*）。尽管RPN表达式不够直观易读，但其对运算符优先级的表述能力，却毫不逊色于常规的中缀表达式；而其在计算效率方面的优势，更是常规表达式无法比拟的。RPN表达式中运算符的执行次序，可更为简捷地确定，既不必在事先做任何约定，更无需借助括号强制改变优先级。具体而言，各运算符被执行的次序，与其在RPN表达式中出现的次序完全吻合。以上面的“1 2 + 3 4 ^ * ”为例，三次运算的次序{ +, ^, * }，与三个运算符的出现次序完全一致。

■ 求值算法

根据以上分析，采用算法4.1即可高效地实现对RPN表达式的求值。

```
rpnEvaluation(expr)
输入：RPN表达式expr（假定语法正确）
输出：表达式数值
{
    引入栈S，用以存放操作数；
    while (expr尚未扫描完毕) {
        从expr中读入下一元素x；
        if (x是操作数) 将x压入S；
        else { //x是运算符
            从栈S中弹出运算符x所需数目的操作数；
            对弹出的操作数实施x运算，并将运算结果重新压入S；
        } //else
    } //while
    返回栈顶；//也是栈底
}
```

算法4.1 RPN表达式求值

可见，除了一个辅助栈外，该算法不需要借助任何更多的数据结构。此外，算法的控制流程也十分简明，只需对RPN表达式做单向的顺序扫描，既无需更多判断，也不含任何分支或回溯。

算法4.1的一次完整运行过程，如表4.3所示。

表4.3 RPN表达式求值算法实例（当前字符以方框注明，操作数栈的底部靠左）

操作数栈	表达式	注解
	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	初始化，引入操作数栈
0	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	操作数0入栈
1	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	0出栈，运算'!'结果入栈
1 1	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	操作数1入栈
2	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	1和1出栈，运算'+'结果入栈
2 2	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	操作数2入栈
2 2 3	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	操作数3入栈
2 2 6	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	3出栈，运算'!'结果入栈
2 2 6 4	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 6 7 - 8 9 + - -	操作数4入栈

操作数栈	表达式	注解
2 2 10	0 ! 1 + 2 3 ! 4 + $\boxed{+}$ ^ * 5 ! 67 - 8 9 + - -	6和4出栈, 运算 '+' 结果入栈
2 1024	0 ! 1 + 2 3 ! 4 + $\boxed{\wedge}$ * 5 ! 67 - 8 9 + - -	2和10出栈, 运算 '^' 结果入栈
2048	0 ! 1 + 2 3 ! 4 + $\boxed{*}$ 5 ! 67 - 8 9 + - -	2和1024出栈, 运算 '*' 结果入栈
2048 5	0 ! 1 + 2 3 ! 4 + ^ * $\boxed{5}$! 67 - 8 9 + - -	操作数5入栈
2048 120	0 ! 1 + 2 3 ! 4 + ^ * 5 $\boxed{!}$ 67 - 8 9 + - -	5出栈, 运算 '!' 结果入栈
2048 120 67	0 ! 1 + 2 3 ! 4 + ^ * 5 ! $\boxed{67}$ - 8 9 + - -	操作数67入栈
2048 53	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 $\boxed{-}$ 8 9 + - -	120和67出栈, 运算 '-' 结果入栈
2048 53 8	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - $\boxed{8}$ 9 + - -	操作数8入栈
2048 53 8 9	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - 8 $\boxed{9}$ + - -	操作数9入栈
2048 53 17	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - 8 9 $\boxed{+}$ - -	8和9出栈, 运算 '+' 结果入栈
2048 36	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - 8 9 + $\boxed{-}$ -	53和17出栈, 运算 '-' 结果入栈
2012	0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - 8 9 + - $\boxed{-}$	2048和36出栈, 运算 '-' 结果入栈

可见, 只有操作数可能需要借助栈S做缓存, 运算符则均可直接执行而不必保留。

另外, 只要RPN表达式合法, 在整个求值计算的过程中, 当前运算符所需的操作数无论多少, 都必然恰好按次序存放在当前栈的顶部。当上例处理到运算符 '^' 时, 对应的操作数2和10恰为次栈顶和栈顶; 当处理到运算符 '*' 时, 对应的操作数2和1024也恰为次栈顶和栈顶。

■ 手工转换

按照以下步骤, 即可完成从中缀表达式到RPN的转换。以如下中缀表达式为例(习题[4-9]):

$$(0! + 1) * 2^{\wedge}(3! + 4) - (5! - 67 - (8 + 9))$$

首先, 假设在事先并未就运算符之间的优先级做过任何约定。于是, 我们不得不通过增添足够多的括号, 以如下方式, 显式地指定该表达式的运算次序:

$$(((0!) + 1) * (2^{\wedge}((3!) + 4))) - (((5!) - 67) - (8 + 9))$$

然后, 将各运算符后移, 使之紧邻于其对应的右括号的右侧:

$$(((0!) 1) + (2((3!) 4) +)^{\wedge}) * (((5!) 67) - (8 9) +) -) -$$

最后抹去所有括号:

$$0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - 8 9 + - -$$

稍事整理, 即得到对应的RPN表达式:

$$0 ! 1 + 2 3 ! 4 + ^ * 5 ! 67 - 8 9 + - -$$

可见, 操作数之间的相对次序, 在转换前后保持不变; 而运算符在RPN中所处的位置, 恰好就是其对应的操作数均已就绪且该运算可以执行的位置。

■ 自动转换

实际上, 95页代码4.7中evaluate()算法在对表达式求值的同时, 也顺便完成了从常规表达式到RPN表达式的转换。在求值过程中, 该算法借助append()函数(习题[4-8])将各操作数和运算符适时地追加至串rpn的末尾, 直至得到完整的RPN表达式(习题[4-9])。

这里采用的规则十分简明: 凡遇到操作数, 即追加至rpn; 而运算符只有在从栈中弹出并执行时, 才被追加。这一过程, 与上述手工转换的方法完全等效, 其正确性也因此得以确立。

将RPN自动转换过程与RPN求值过程做一对照, 即不难看出, 后者只不过是前者的忠实再现。

§ 4.4 * 试探回溯法

4.4.1 试探与回溯

■ 忒修斯的法宝

古希腊神话中半人半牛的怪物弥诺陶洛斯（Minotaur），藏身于一个精心设计、结构极其复杂的迷宫之中。因此，找到并消灭它绝非易事，而此后如何顺利返回而不致困死更是一个难题。不过，在公主阿里阿德涅（Ariadne）的帮助下，英雄忒修斯（Theseus）还是想出了个好办法，他最终消灭了怪物，并带着公主轻松地走出迷宫。

实际上，忒修斯所使用的法宝，只不过是一团普通的线绳。他将线绳的一端系在迷宫的入口处，而在此后不断检查各个角落的过程中，线团始终握在他的手中。线团或收或放，跟随着忒修斯穿梭于蜿蜒曲折的迷宫之中，确保他不致迷路。

忒修斯的高招，与现代计算机中求解很多问题的算法异曲同工。事实上，很多应用问题的解，在形式上都可看作若干元素按特定次序构成的一个序列。以经典的旅行商问题（traveling salesman problem, TSP）为例，其目标是计算出由给定的 n 个城市构成的一个序列，使得按此序列对这些城市的环游成本（比如机票价格）最低。尽管此类问题本身的描述并不复杂，但遗憾的是，由于所涉及元素（比如城市）的每一排列都是一个候选解，它们往往构成一个极大的搜索空间。通常，其搜索空间的规模与全排列总数大体相当，为 $n! = O(n^n)$ 。因此若采用蛮力策略，逐一生成可能的候选解并检查其是否合理，则必然无法将运行时间控制在多项式的范围以内。

■ 剪枝

为此，必须基于对应用问题的深刻理解，利用问题本身具有的某些规律尽可能多、尽可能早地排除搜索空间中的候选解。其中一种重要的技巧就是，根据候选解的某些局部特征，以候选解子集为单位批量地排除。通常如图4.7所示，搜索空间多呈树状结构，而被排除的候选解往往隶属于同一分支，故这一技巧也可以形象地称作剪枝（pruning）。

与之对应的算法多呈现为如下模式。从零开始，尝试逐步增加候选解的长度。更准确地，这一过程是在成批地考查具有特定前缀的所有候选解。这种从长度上逐步向目标解靠近的尝试，称作试探（probing）。作为解的局部特征，特征前缀在试探的过程中一旦被发现有与目标解不合，则收缩到此前一步的长度，然后继续试探下一可能的组合。特征前缀长度缩减的这类操作，称作回溯（backtracking），其效果等同于剪枝。如此，只要目标解的确存在就迟早会被发现，而且只要剪枝所依据的特征设计得当，计算的效率就会大大提高。

■ 线绳与粉笔

回到开头的传说故事。不难看出，忒修斯藉以探索迷宫的正是试探回溯法。当然，这一方法的真正兑现还依赖于有形的物质基础——忒修斯的线绳。忒修斯之所以能够在迷宫中有条不紊地进行搜索，首先是得益于这团收放自如的线绳。这一点不难理解，所有算法的实现都必须建立在特定的数据结构之上。

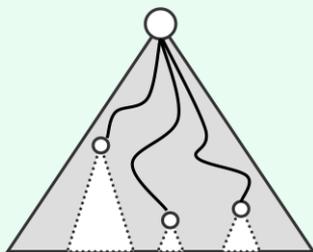


图4.7 通过剪枝排除候选解子集

以下两个实例，将介绍如何借助适当的数据结构以高效地实现试探回溯策略。我们将看到，栈结构在此过程中所扮演的正是忒修斯手中线绳的角色。当然，这里还需解决故事中隐含的另一技术难点：如何保证搜索过的部分不被重复搜索。办法之一就是，在剪枝的位置留下某种标记。同样地，这类标记也需兑现为具体的数据结构。倘若建议忒修斯在回溯时不妨用粉笔就地做个记号，那么我们的算法也应配有以数据结构形式实现的“粉笔”。

4.4.2 八皇后

■ 问题描述

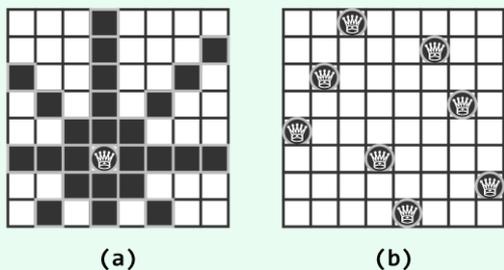


图4.8 (a)皇后的控制范围；(b)8皇后问题的一个解

如图4.8(a)，国际象棋中皇后的势力范围覆盖其所在的水平线、垂直线以及两条对角线。现考查如下问题：在 $n \times n$ 的棋盘上放置 n 个皇后，如何使得她们彼此互不攻击——此时称她们构成一个可行的棋局。对于任何整数 $n \geq 4$ ，这就是 n 皇后问题。

由鸽巢原理可知，在 n 行 n 列的棋盘上至多只能放置 n 个皇后。反之， n 个皇后在 $n \times n$ 棋盘上的可行棋局通常也存在，比如图4.8(b)即为在 8×8 棋盘上，由8个皇后构成的一个可行棋局。

■ 皇后

皇后是组成棋局和最终解的基本单元，故可如代码4.8所示实现对应的Queen类。

```

1 struct Queen { //皇后类
2     int x, y; //皇后在棋盘上的位置坐标
3     Queen(int xx = 0, int yy = 0) : x(xx), y(yy) {};
4     bool operator==(Queen const& q) const { //重载等操作符，以检测不同皇后之间可能的冲突
5         return (x == q.x) //行冲突 (这一情况其实并不会发生，可省略)
6             || (y == q.y) //列冲突
7             || (x + y == q.x + q.y) //沿正对角线冲突
8             || (x - y == q.x - q.y); //沿反对角线冲突
9     }
10    bool operator!=(Queen const& q) const { return !(*this == q); } //重载不等操作符
11 };

```

代码4.8 皇后类

可见，每个皇后对象均由其在棋盘上的位置坐标确定。此外，这里还通过重载等操作符，实现了对皇后位置是否相互冲突的便捷判断。具体地，这里按照以上棋规，将同行、同列或同对角线的任意两个皇后视作“相等”，于是两个皇后相互冲突当且仅当二者被判作“相等”。

■ 算法实现

基于试探回溯策略，可如代码4.9所示，实现通用的N皇后算法。

既然每行能且仅能放置一个皇后，故不妨首先将各皇后分配至每一行。然后，从空棋盘开始，逐个尝试着将她们放置到无冲突的某列。每放置好一个皇后，才继续试探下一个。若当前皇后在任何列都会造成冲突，则后续皇后的试探都必将是徒劳的，故此时应该回溯到上一皇后。

```

1 void placeQueens(int N) { //N皇后算法(迭代版):采用试探/回溯的策略,借助栈记录查找的结果
2     Stack<Queen> solu; //存放(部分)解的栈
3     Queen q(0, 0); //从原点位置出发
4     do { //反复试探、回溯
5         if (N <= solu.size() || N <= q.y) { //若已出界,则
6             q = solu.pop(); q.y++; //回溯一行,并继续试探下一列
7         } else { //否则,试探下一行
8             while ((q.y < N) && (0 <= solu.find(q))) //通过与已有皇后的比对
9                 { q.y++; nCheck++; } //尝试找到可摆放下一皇后的列
10            if (N > q.y) { //若存在可摆放的列,则
11                solu.push(q); //摆上当前皇后,并
12                if (N <= solu.size()) nSolu++; //若部分解已成为全局解,则通过全局变量nSolu计数
13                q.x++; q.y = 0; //转入下一行,从第0列开始,试探下一皇后
14            }
15        }
16    } while ((0 < q.x) || (q.y < N)); //所有分支均已或穷举或剪枝之后,算法结束
17 }

```

代码4.9 N皇后算法

这里借助栈solu来动态地记录各皇后的列号。当该栈的规模增至N时,即得到全局解。该栈即可依次给出各皇后在可行棋局中所处的位置。

■ 实例

图4.9给出了利用以上算法,得到四皇后问题第一个解的完整过程。

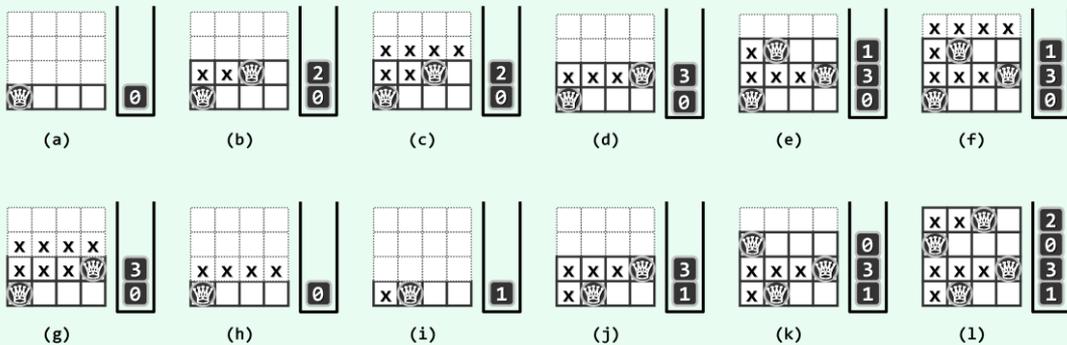


图4.9 四皇后问题求解过程(棋盘右侧为记录解的栈solu)

首先试探第一行皇后,如图(a)所示将其暂置于第0列,同时列号入栈。接下来试探再第二行皇后,如图(b)所示在排除前两列后,将其暂置于第2列,同时列号入栈。然而此后试探第三行皇后时,如图(c)所示发现所有列均有冲突。于是回溯到第二行,并如图(d)所示将第二行皇后调整到第3列,同时更新栈顶列号。后续各步原理相同,直至图(l)栈满时得到一个全局解。

如此不断地试探和回溯,即可得到所有可行棋局。可见,通过剪枝我们对原规模为 $4! = 24$ 的搜索空间实现了有效的筛选。随着问题规模的增加,这一技巧的优化效果将更为明显。

4.4.3 迷宫寻径

■ 问题描述

路径规划是人工智能的基本问题之一，要求依照约定的行进规则，在具有特定几何结构的空间区域内，找到从起点到终点的一条通路。以下考查该问题的一个简化版本：空间区域限定为由 $n \times n$ 个方格组成的迷宫，除了四周的围墙，还有分布其间的若干障碍物；只能水平或垂直移动。我们的任务是，在任意指定的起始格点与目标格点之间，找出一条通路（如果的确存在）。

■ 迷宫格点

格点是迷宫的基本组成单位，故首先需要实现Cell类如代码4.10所示。

```

1 typedef enum { AVAILABLE, ROUTE, BACKTRACKED, WALL } Status; //迷宫单元状态
2 //原始可用的、在当前路径上的、所有方向均尝试失败后回溯过的、不可使用的（墙）
3
4 typedef enum { UNKNOWN, EAST, SOUTH, WEST, NORTH, NO_WAY } ESWN; //单元的相对邻接方向
5 //未定、东、南、西、北、无路可通
6
7 inline ESWN nextESWN(ESWN eswn) { return ESWN (eswn + 1); } //依次转至下一邻接方向
8
9 struct Cell { //迷宫格点
10     int x, y; Status status; //x坐标、y坐标、类型
11     ESWN incoming, outgoing; //进入、走出方向
12 };
13
14 #define LABY_MAX 24 //最大迷宫尺寸
15 Cell laby[LABY_MAX][LABY_MAX]; //迷宫

```

代码4.10 迷宫格点类

可见，除了记录其位置坐标外，格点还需记录其所处的状态。共有四种可能的状态：原始可用的(AVAILABLE)、在当前路径上的(ROUTE)、所有方向均尝试失败后回溯过的(BACKTRACKED)、不可穿越的(WALL)。属于当前路径的格点，还需记录其前驱和后继格点的方向。既然只有上、下、左、右四个连通方向，故以EAST、SOUTH、WEST和NORTH区分。特别地，因尚未搜索到而仍处于初始AVAILABLE状态的格点，邻格的方向都是未知的(UNKNOWN)；经过回溯后处于BACKTRACKED状态的格点，与邻格之间的连通关系均已关闭，故标记为NO_WAY。

■ 邻格查询

在路径试探过程中需反复确定当前位置的相邻格点，可如代码4.11所示实现查询功能。

```

1 inline Cell* neighbor(Cell* cell) { //查询当前位置的相邻格点
2     switch (cell->outgoing) {
3         case EAST : return cell + LABY_MAX; //向东
4         case SOUTH : return cell + 1; //向南
5         case WEST : return cell - LABY_MAX; //向西
6         case NORTH : return cell - 1; //向北

```

```

7     default    : exit(-1);
8   }
9 }

```

代码4.11 查询相邻格点

■ 邻格转入

在确认某一相邻格点可用之后,算法将朝对应的方向向前试探一步,同时路径延长一个单元。为此,需如代码4.12所示实现相应的格点转入功能。

```

1 inline Cell* advance(Cell* cell) { //从当前位置转入相邻格点
2   Cell* next;
3   switch (cell->outgoing) {
4     case EAST: next = cell + LABY_MAX; next->incoming = WEST; break; //向东
5     case SOUTH: next = cell + 1; next->incoming = NORTH; break; //向南
6     case WEST: next = cell - LABY_MAX; next->incoming = EAST; break; //向西
7     case NORTH: next = cell - 1; next->incoming = SOUTH; break; //向北
8     default : exit(-1);
9   }
10  return next;
11 }

```

代码4.12 转入相邻格点

■ 算法实现

在以上功能的基础上,可基于试探回溯策略实现寻径算法如代码4.13所示。

```

1 // 迷宫寻径算法:在格单元s至t之间规划一条通路(如果的确存在)
2 bool labyrinth(Cell Laby[LABY_MAX][LABY_MAX], Cell* s, Cell* t) {
3   if ((AVAILABLE != s->status) || (AVAILABLE != t->status)) return false; //退化情况
4   Stack<Cell*> path; //用栈记录通路(Theseus的线绳)
5   s->incoming = UNKNOWN; s->status = ROUTE; path.push(s); //起点
6   do { //从起点出发不断试探、回溯,直到抵达终点,或者穷尽所有可能
7     Cell* c = path.top(); //检查当前位置(栈顶)
8     if (c == t) return true; //若已抵达终点,则找到了一条通路;否则,(沿尚未试探的方向)向前试探
9     while (NO_WAY > (c->outgoing = nextESWN(c->outgoing))) //逐一检查所有方向
10      if (AVAILABLE == neighbor(c)->status) break; //试图找到尚未试探的方向
11      if (NO_WAY <= c->outgoing) //若所有方向都已尝试过
12        { c->status = BACKTRACKED; c = path.pop(); } //则向后回溯一步
13      else //否则,向前试探一步
14        { path.push(c = advance(c)); c->outgoing = UNKNOWN; c->status = ROUTE; }
15    } while (!path.empty());
16  return false;
17 }

```

代码4.13 迷宫寻径

该问题的搜索过程中，局部解是一条源自起始格点的路径，它随着试探、回溯相应地伸长、缩短。因此，这里借助栈path按次序记录组成当前路径的所有格点，并动态地随着试探、回溯做入栈、出栈操作。路径的起始格点、当前的末端格点分别对应于path的栈底和栈顶，当后者抵达目标格点时搜索成功，此时path所对应的路径即可作为全局解返回。

■ 实例

图4.10给出了以上迷宫寻径算法的一次运行实例。

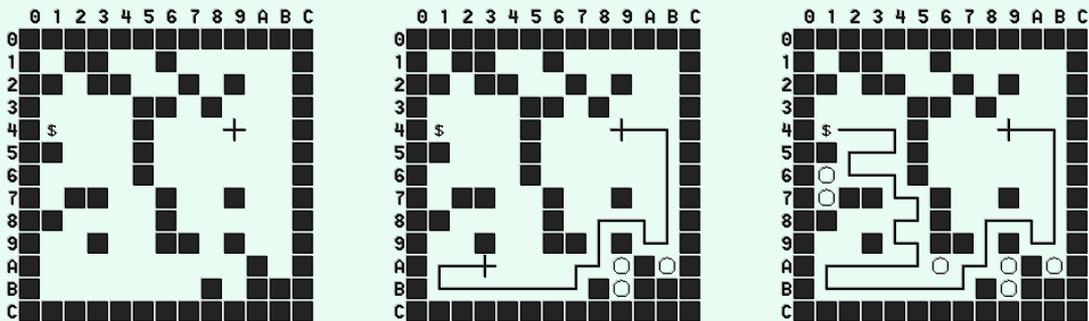


图4.10 迷宫寻径算法实例

左侧为随机生成的13×13迷宫。算法启动时，其中格点分为可用（AVAILABLE，白色）与障碍（WALL，黑色）两种状态。在前一类中，随机指定了起始格点（+）和目标格点（\$）。中图为算法执行过程的某一时刻，可见原先为可用状态的一些格点已经转换为新的状态：转入ROUTE状态的格点，依次联接构成一条（尚未完成的）通路；曾参与构成通路但因所有前进方向均已尝试完毕而回溯的格点，则进而从ROUTE转入TRIED状态（以圆圈注明）。

■ 正确性

该算法会尝试当前格点的所有相邻格点，因此通过数学归纳可知，若在找到全局解后依然继续查找，则该算法可以抵达与起始格点连通的所有格点。因此，只要目标格点与起始格点的确相互连通，则这一算法必将如右图所示找出一条联接于二者之间的通路。

从算法的中间过程及最终结果都可清晰地看出，这里用以记录通路的栈结构的确相当于忒修斯手中的线绳，它确保了算法可沿着正确方向回溯。另外，这里给所有回溯格点所做的状态标记则等效于用粉笔做的记号，正是这些标记确保了格点不致被重复搜索，从而有效地避免了沿环路的死循环现象。

■ 复杂度

算法的每一步迭代仅需常数时间，故总体时间复杂度线性正比于试探、回溯操作的总数。由于每个格点至多参与试探和回溯各一次，故亦可度量为所有被访问过的格点总数——在图4.10中，也就是最终路径的总长度再加上圆圈标记的数目。

§ 4.5 队列

4.5.1 概述

■ 入队与出队

与栈一样，队列（queue）也是存放数据对象的一种容器，其中的数据对象也按线性的逻辑次序排列。队列结构同样支持对象的插入和删除，但两种操作的范围分别被限制于队列的两端——若约定新对象只能从某一端插入其中，则只能从另一端删除已有的元素。允许取出元素的一端称作队头（front），而允许插入元素的另一端称作队尾（rear）。

以如图4.11所示顺序盛放羽毛球的球桶为例。通常，我们总是从球托所指的一端将球取出，而从另一端把球纳入桶中。因此如果将球托所指的一端理解为队头，另一端理解为队尾，则桶中的羽毛球即构成一个队列，其中每只球都属于该队列的一个元素。

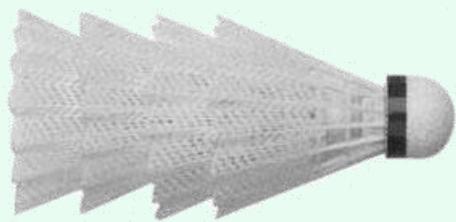


图4.11 在球桶中顺序排列的一组羽毛球可视为一个队列

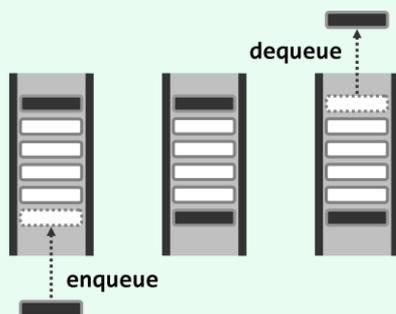


图4.12 队列操作

一般地如图4.12所示，元素的插入与删除也是修改队列结构的两种主要方式，站在被操作对象的角度，分别称作入队（enqueue）和出队（dequeue）操作。

■ 先进先出

由以上的约定和限制不难看出，与栈结构恰好相反，队列中各对象的操作次序遵循所谓先进先出（first-in-first-out, FIFO）的规律：更早（晚）出队的元素应为更早（晚）入队者，反之，更早（晚）入队者应更早（晚）出队。

4.5.2 ADT接口

作为一种抽象数据类型，队列结构必须支持以下操作接口。

表4.4 队列ADT支持的操作接口

操 作	功 能
size()	报告队列的规模（元素总数）
empty()	判断队列是否为空
enqueue(e)	将e插入队尾
dequeue()	删除队首对象
front()	引用队首对象

4.5.3 操作实例

按照表4.4定义的ADT接口，表4.5给出了一个队列从被创建开始，经过一系列操作的过程。

表4.5 队列操作实例（元素均为整型）

操作	输出	队列（右侧为队头）	操作	输出	队列（右侧为队头）
Queue()			enqueue(11)		11 3 7 3
empty()	true		size()	4	11 3 7 3
enqueue(5)		5	enqueue(6)		6 11 3 7 3
enqueue(3)		3 5	empty()	false	6 11 3 7 3
dequeue()	5	3	enqueue(7)		6 11 3 7 3
enqueue(7)		7 3	dequeue()	3	7 6 11 3 7
enqueue(3)		3 7 3	dequeue()	7	7 6 11 3
front()	3	3 7 3	front()	3	7 6 11 3
empty()	false	3 7 3	size()	4	7 6 11 3

4.5.4 Queue模板类

既然队列也可视作序列的特例，故只要将队列作为列表的派生类，即可利用C++的继承机制，基于3.2.2节已实现的列表模板类，实现队列结构。同样地，也需要按照队列的习惯对各相关的接口重新命名。按照表4.4所列的ADT接口，可描述并实现Queue模板类如下。

```

1 #include "../List/List.h" //以List为基类
2 template <typename T> class Queue: public List<T> { //队列模板类（继承List原有接口）
3 public: //size()、empty()以及其它开放接口均可直接沿用
4     void enqueue(T const& e) { insertAsLast(e); } //入队：尾部插入
5     T dequeue() { return remove(first()); } //出队：首部删除
6     T& front() { return first()->data; } //队首
7 };

```

代码4.14 Queue模板类

由代码4.14可见，队列的enqueue()操作等效于将新元素作为列表的末元素插入，dequeue()操作则等效于删除列表的首元素，front()操作可直接返回对列表首元素的引用。而size()及empty()等接口，均可直接沿用基类的同名接口。

这里插入和删除操作的位置分别限制于列表的末端和首端，故由3.3.5节的分析结论可知，队列结构以上接口的时间复杂度均为常数。

套用以上思路，也可直接基于2.2.3节的Vector模板类派生出Stack类（习题[4-2]）。

§ 4.6 队列应用

4.6.1 循环分配器

为在客户（**client**）群体中共享的某一资源（比如多个应用程序共享同一CPU），一套公平且高效的分配规则必不可少，而队列结构则非常适于定义和实现这样的一套分配规则^①。

具体地，可以借助队列Q实现一个资源循环分配器，其总体流程大致如算法4.2所示。

```
RoundRobin { //循环分配器
    Queue Q(clients); //参与资源分配的所有客户组成队列Q
    while (!ServiceClosed()) { //在服务关闭之前，反复地
        e = Q.dequeue(); //队首的客户出队，并
        serve(e); //接受服务，然后
        Q.enqueue(e); //重新入队
    }
}
```

算法4.2 利用队列结构实现的循环分配器

在以上所谓轮值（**round robin**）算法中，首先令所有参与资源分配的客户组成一个队列Q。接下来是一个反复轮回式的调度过程：取出当前位于队头的客户，将资源交予该客户使用；在经过固定的时间之后，回收资源，并令该客户重新入队。得益于队列“先进先出”的特性，如此既可在所有客户之间达成一种均衡的公平，也可使得资源得以充分利用。

这里，每位客户持续占用资源的时间，对该算法的成败至关重要。一方面，为保证响应速度，这一时间值通常都不能过大。另一方面，因占有权的切换也需要耗费一定的时间，故若该时间值取得过小，切换过于频繁，又会造成整体效率的下降。因此，往往需要通过实测确定最佳值。

反过来，在单一客户使用多个资源的场合，队列也可用以保证资源的均衡使用，提高整体使用效率。针式打印机配置的色带，即是这样的一个实例，环形^②色带收纳于两端开口的色带盒内。在打印过程中，从一端不断卷出的色带，在经过打印头之后，又从另一端重新卷入盒中，并如此往复。可见，此处色带盒的功能等效于一个队列，色带的各部分按照“先进先出”的原则被均衡地使用，整体使用寿命因而得以延长。

4.6.2 银行服务模拟

以下以银行这一典型场景为例，介绍如何利用队列结构实现顾客服务的调度与优化。

通常，银行都设有多个窗口，顾客按到达的次序分别在各窗口排队等待办理业务。为此，可首先定义顾客类**Customer**如下，以记录顾客所属的队列及其所办业务的服务时长。

```
1 struct Customer { int window; unsigned int time; }; //顾客类：所属窗口（队列）、服务时长
```

代码4.15 顾客对象

^① 更复杂条件和需求下的调度分配算法，可参考排队论（**queuing theory**）的相关资料

^② 严格地说，色带是个Möbius环，如此可进一步保证其“两”面都能被均衡使用

顾客在银行中接受服务的整个过程，可由如代码4.16所示的simulate()函数模拟。

```

1 void simulate(int nWin, int servTime) { //按指定窗口数、服务总时间模拟银行业务
2     Queue<Customer>* windows = new Queue<Customer>[nWin]; //为每一窗口创建一个队列
3     for (int now = 0; now < servTime; now++) { //在下班之前，每隔一个单位时间
4         if (rand() % (1 + nWin)) { //新顾客以nWin/(nWin + 1)的概率到达
5             Customer c ; c.time = 1 + rand() % 98; //新顾客到达，服务时长随机确定
6             c.window = bestWindow(windows, nWin); //找出最佳（最短）的服务窗口
7             windows[c.window].enqueue(c); //新顾客加入对应的队列
8         }
9         for (int i = 0; i < nWin; i++) //分别检查
10            if (!windows[i].empty()) //各非空队列
11                if (-- windows[i].front().time <= 0) //队首顾客的服务时长减少一个单位
12                    windows[i].dequeue(); //服务完毕的顾客出列，由后继顾客接替
13     } //while
14     delete [] windows; //释放所有队列（此前，~List()会自动清空队列）
15 }

```

代码4.16 银行服务模拟

这里，首先根据银行所设窗口的数量相应地建立多个队列。以下以单位时间为间隔反复迭代，直至下班。每一时刻都有一位顾客按一定的概率抵达，随机确定所办业务服务时长之后，归入某一“最优”队列。每经单位时间，各队列最靠前顾客（如果有的话）的待服务时长均相应减少一个单位。若时长归零，则意味着该顾客的业务已办理完毕，故应退出队列并由后一位顾客（如果有的话）接替。可见，顾客归入队列和退出队列的事件可分别由enqueue()和dequeue()操作模拟，查询并修改队首顾客时长的事件则可由front()操作模拟。

```

1 int bestWindow(Queue<Customer> windows[], int nWin) { //为新到顾客确定最佳队列
2     int minSize = windows[0].size(), optiWin = 0; //最优队列（窗口）
3     for (int i = 1; i < nWin; i++) //在所有窗口中
4         if (minSize > windows[i].size()) //挑选出
5             { minSize = windows[i].size(); optiWin = i; } //队列最短者
6     return optiWin; //返回
7 }

```

代码4.17 查找最短队列

为更好地为新到顾客确定一个队列，这里采用了“最短优先”的原则。如代码4.17所示，为此只需遍历所有的队列并通过size()接口比较其规模，即可找到其中的最短者。

第5章

二叉树

通过前面的章节，我们已经了解了一些基本的数据结构。根据其实现方式，这些数据结构大致可以分为两种类型：基于数组的实现与基于链表的实现。正如我们已经看到的，就其效率而言，二者各有长短。具体来说，前一实现方式允许我们通过下标或秩，在常数的时间内找到目标对象；然而，一旦需要对这类结构进行修改，那么无论是插入还是删除，都需要耗费线性的时间。反过来，后一实现方式允许我们借助引用或位置对象，在常数的时间内插入或删除元素；但是为了找出居于特定次序的元素，我们却不得不花费线性的时间，对整个结构进行遍历查找。能否将这两类结构的优点结合起来，并回避其不足呢？本章所讨论的树结构，将正面回答这一问题。

在此前介绍的这些结构中，元素之间都存在一个自然的线性次序，故它们都属于所谓的线性结构（**linear structure**）。树则不然，其中的元素之间并不存在天然的直接后继或直接前驱关系。不过，正如我们马上就要看到的，只要附加某种约束（比如遍历），也可以在树中的元素之间确定某种线性次序，因此树属于半线性结构（**semi-linear structure**）。

无论如何，随着从线性结构转入树结构，我们的思维方式也将有个飞跃；相应地，算法设计的策略与模式也会因此有所变化，许多基本的算法也将得以更加高效地实现。以第7章和第8章将要介绍的平衡二叉搜索树为例，若其中包含 n 个元素，则每次查找、更新、插入或删除操作都可在 $O(\log n)$ 时间内完成——相对于线性结构，几乎提高了一个线性因子（习题[1-9]）。

树结构有着不计其数的变种，在算法理论以及实际应用中，它们都扮演着最为关键的角色。之所以如此，是因得益于其独特而又普适的逻辑结构。树是一种分层结构，而层次化这一特征几乎蕴含于所有事物及其联系当中，成为其本质属性之一。从文件系统、互联网域名系统和数据库系统，一直到地球生态系统乃至人类社会系统，层次化特征以及层次结构均无所不在。

有趣的是，作为树的特例，二叉树实际上并不失其一般性。本章将指出，无论就逻辑结构或算法功能而言，任何有根有序的多叉树，都可等价地转化并实现为二叉树。因此，本章讲解的重点也将放在二叉树上。我们将以通讯编码算法的实现这一应用实例作为线索贯穿全章。

§ 5.1 二叉树及其表示

5.1.1 树

■ 有根树

从图论的角度看，树等价于连通无环图。因此与一般的图相同，树也由一组顶点（**vertex**）以及联接与其间的若干条边（**edge**）组成。在计算机科学中，往往还会在此基础上，再指定某一特定顶点，并称之为根（**root**）。在指定根节点之后，我们也称之为有根树（**rooted tree**）。此时，从程序实现的角度，我们也更多地将顶点称作节点（**node**）。

■ 深度与层次

由树的连通性，每一节点与根之间都有一条路径相联；而根据树的无环性，由根通往每个节点的路径必然唯一。因此如图5.1所示，沿每个节点 v 到根 r 的唯一通路所经过边的数目，称作 v 的深度（depth），记作 $\text{depth}(v)$ 。依据深度排序，可对所有节点做分层归类。特别地，约定根节点的深度 $\text{depth}(r) = 0$ ，故属于第0层。

■ 祖先、后代与子树

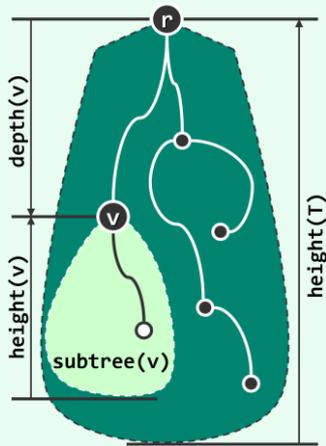


图5.1 有根树的逻辑结构

任一节点 v 在通往树根沿途所经过的每个节点都是其祖先（ancestor）， v 是它们的后代（descendant）。特别地， v 的祖先/后代包括其本身，而 v 本身以外的祖先/后代称作真祖先（proper ancestor）/真后代（proper descendant）。

节点 v 历代祖先的层次，自下而上以1为单位逐层递减；在每一层次上， v 的祖先至多一个。特别地，若节点 u 是 v 的祖先且恰好比 v 高出一层，则称 u 是 v 的父亲（parent）， v 是 u 的孩子（child）。

v 的孩子总数，称作其度数或度（degree），记作 $\text{deg}(v)$ 。无孩子的节点称作叶节点（leaf），包括根在内的其余节点皆为内部节点（internal node）。

v 所有的后代及其之间的联边称作子树（subtree），记作 $\text{subtree}(v)$ 。在不致歧义时，我们往往不再严格区分节点（ v ）及以之为根的子树（ $\text{subtree}(v)$ ）。

■ 高度

树 T 中所有节点深度的最大值称作该树的高度（height），记作 $\text{height}(T)$ 。

不难理解，树的高度总是由其中某一叶节点的深度确定的。特别地，本书约定，仅含单个节点的树高度为0，空树高度为-1。

推而广之，任一节点 v 所对应子树 $\text{subtree}(v)$ 的高度，亦称作该节点的高度，记作 $\text{height}(v)$ 。特别地，全树的高度亦即其根节点 r 的高度， $\text{height}(T) = \text{height}(r)$ 。

5.1.2 二叉树

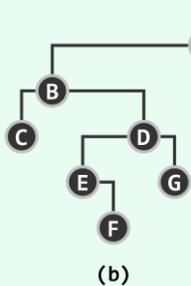
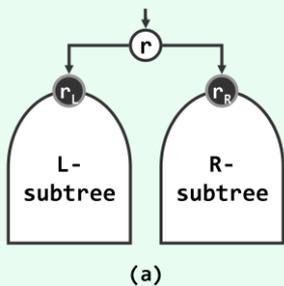


图5.2 二叉树：(a)逻辑结构；(b)实例

如图5.2所示，二叉树（binary tree）中每个节点的度数均不超过2。

因此在二叉树中，同一父节点的孩子都可以左、右相互区分——此时，亦称作有序二叉树（ordered binary tree）。本书所提到的二叉树，默认地都是有序的。

特别地，不含一度节点的二叉树称作真二叉树（proper binary tree）（习题[5-2]）。

5.1.3 多叉树

一般地，树中各节点的孩子数目并不确定。每个节点的孩子均不超过k个的有根树，称作k叉树（k-ary tree）。本节将就此类树结构的表示与实现方法做一简要介绍。

父节点

由如图5.3(a)实例不难看出，在多叉树中，根节点以外的任一节点有且仅有一个父节点。

因此可如图5.3(b)所示，将各节点组织为向量或列表，其中每个元素除保存节点本身的信息（node）外，还需要保存父节点（parent）的秩或位置。可为树根指定一个虚构的父节点-1或NULL，以便统一判断。

如此，所有向量或列表所占的空间总量为 $O(n)$ ，线性正比于节点总数n。时间方面，仅需常数时间，即可确定任一节点的父节点；但反过来，孩子节点的查找却不得不花费 $O(n)$ 时间访遍所有节点。

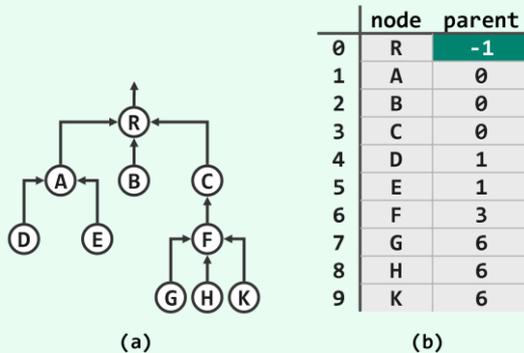


图5.3 多叉树的“父节点”表示法

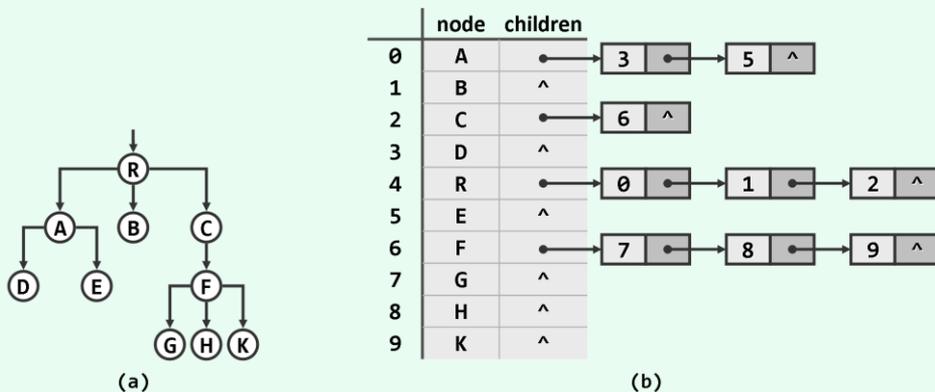


图5.4 多叉树的“孩子节点”表示法

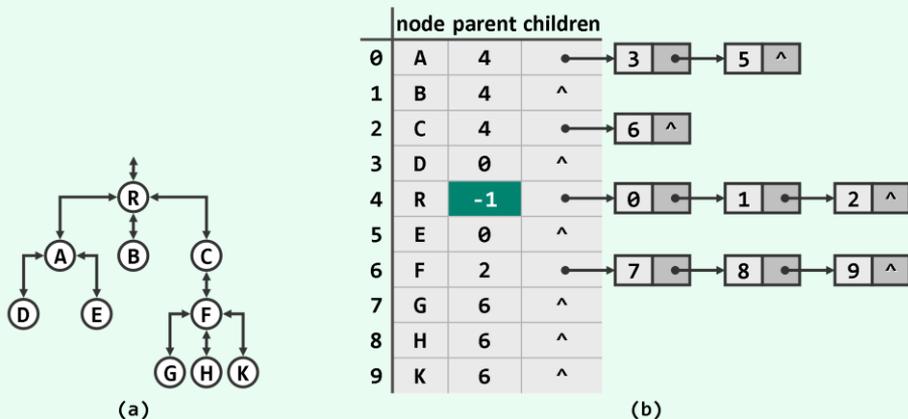


图5.5 多叉树的“父节点 + 孩子节点”表示法

■ 孩子节点

若注重孩子节点的快速定位，可如图5.4所示，令各节点将其所有的孩子组织为一个向量或列表。如此，对于拥有 r 个孩子的节点，可在 $O(r + 1)$ 时间内列举出其所有的孩子。

■ 父节点 + 孩子节点

以上父节点表示法和孩子节点表示法各有所长，但也各有所短。为综合二者的优势，消除缺点，可如图5.5所示令各节点既记录父节点，同时也维护一个序列以保存所有孩子。

尽管如此可以高效地兼顾对父节点和孩子的定位，但在节点插入与删除操作频繁的场合，为动态地维护和更新树的拓扑结构，不得不反复地遍历和调整一些节点所对应的孩子序列。然而，向量和列表等线性结构的此类操作都需耗费大量时间，势必影响到整体的效率。

■ 有序多叉树 = 二叉树

解决上述难题的方法之一，就是采用支持高效动态调整的二叉树结构。为此，必须首先建立起从多叉树到二叉树的某种转换关系，并使得在此转换的意义下，任一多叉树都等价于某棵二叉树。当然，为了保证作为多叉树特例的二叉树有足够的表示任何一棵多叉树，我们只需给多叉树增加一项约束条件——同一节点的所有孩子之间必须具有某一线性次序。

仿照有序二叉树的定义，凡符合这一条件的多叉树也称作有序树（ordered tree）。幸运的是，这一附加条件在实际应用问题中往往自然满足。以互联网域名系统所对应的多叉树为例，其中同一域名下的分支通常即按照字典序排列。

■ 长子 + 兄弟

由图5.6(a)的实例可见，有序多叉树中任一非叶节点都有唯一的“长子”，而且从该“长子”出发，可按照预先约定或指定的次序遍历所有孩子节点。因此可如图(b)所示，为每个节点设置两个指针，分别指向其“长子”和下一“兄弟”。

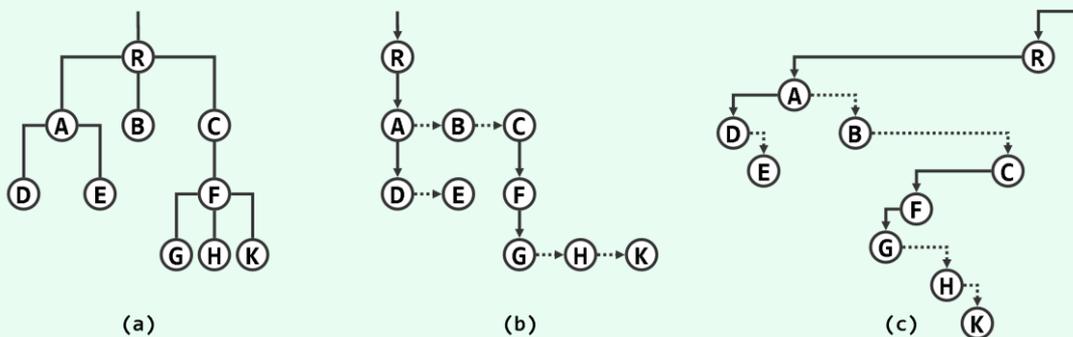


图5.6 多叉树的“长子 + 兄弟”表示法 (b)中长子和兄弟指针，分别以垂直实线和水平虚线示意)

现在，若将这两个指针分别与二叉树节点的左、右孩子指针统一对应起来，则可进一步地将原有序多叉树转换为如图(c)所示的常规二叉树。

在这里，一个饶有趣味的现象出现了：尽管二叉树只是多叉树的一个子集，但其对应用问题的描述与刻画能力绝不低于后者。实际上以下我们还将进一步发现，即便是就计算效率而言，二叉树也并不逊色于一般意义上的树。反过来，得益于其定义的简洁性以及结构的规范性，二叉树所支撑的算法往往可以更好地得到描述，更加简捷地得到实现。二叉树的身影几乎出现在所有的应用领域当中，这也是一个重要的原因。

§ 5.2 编码树

本章将以通讯编码算法的实现作为二叉树的应用实例。通讯理论中的一个基本问题是，如何在尽可能低的成本下，以尽可能高的速度，尽可能忠实地实现信息在空间和时间上的复制与转移。在现代通讯技术中，无论采用电、磁、光或其它任何形式，在信道上传递的信息大多以二进制比特的形式表示和存在，而每一个具体的编码方案都对应于一棵二叉编码树。

5.2.1 二进制编码

在加载到信道上之前，信息被转换为二进制形式的过程称作编码（encoding）；反之，经信道抵达目标后再由二进制编码恢复原始信息的过程称作解码（decoding）。

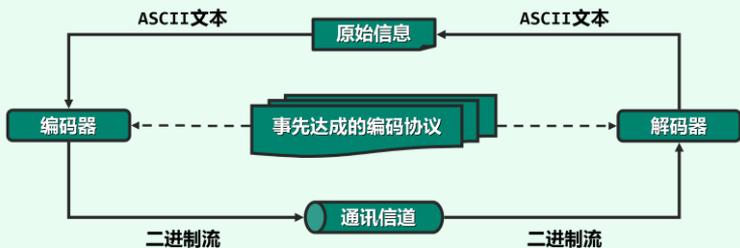


图5.7 完整的通讯过程由预处理、编码和解码阶段组成

如图5.7所示，编码和解码的任务分别由发送方和接收方分别独立完成，故在开始通讯之前，双方应已经以某种形式，就编码规则达成过共同的约定或协议。

■ 生成编码表

原始信息的基本组成单位称作字符，它们都来自于某一特定的有限集合 Σ ，也称作字符集（alphabet）。而以二进制形式承载的信息，都可表示为来自编码表 $\Gamma = \{ 0, 1 \}^*$ 的某一特定二进制串。从这个角度理解，每一编码表都是从字符集 Σ 到编码表 Γ 的一个单射，编码就是对信原文本中各字符逐个实施这一映射的过程，而解码则是逆向映射的过程。

表5.1 $\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 的一份二进制编码表

字符	A	E	G	M	S
编码	00	01	10	110	111

表5.1即为二进制编码表的实例。编码表一旦制定，信息的发送方与接收方之间也就建立起了一个约定与默契，从而使得独立的编码与解码成为可能。

■ 二进制编码

现在，所谓编码就是对于任意给定的文本，通过查阅编码表逐一将其中的字符转译为二进制编码，这些编码依次串接起来即得到了全文的编码。比如若待编码文本为“MESSAGE”，则根据由表5.1确定的编码方案，对应的二进制编码串应为“110⁰¹111¹¹¹00¹⁰01”^①。

表5.2 二进制解码过程

二进制编码	当前匹配字符	解出原文
11001111111001001	M	M
011111111001001	E	ME
111111001001	S	MES
111001001	S	MESS
001001	A	MESSA
1001	G	MESSAG
01	E	MESSAGE

① 这里对各比特位做了适当的上下移位，以便读者区分各字符编码串的范围；在实际编码中，它们并无“高度”的区别

■ 二进制解码

由编码器生成的二进制流经信道送达之后，接收方可以按照事先约定的编码表（表5.1），依次扫描各比特位，并经匹配逐一转译出各字符，从而最终恢复出原始的文本。

仍以二进制编码串"110⁰¹111¹¹¹00¹⁰01"为例，其解码过程如表5.2所示。

■ 解码歧义

请注意，编码方案确定之后，尽管编码结果必然确定，但解码过程和结果却不见得唯一。

表5.3 $\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 的另一份编码表

字符	A	E	G	M	S
编码	00	01	10	11	111

比如，上述字符集 Σ 的另一编码方案如表5.3所示，与表5.1的差异在于，字符'M'的编码由"110"改为"11"。此时，原始文本"MESSAGE"经编码得到二进制编码串"11⁰¹111¹¹¹00¹⁰01"，但如表5.4左侧和右侧所示，解码方法却至少有两种。

表5.4 按照表5.3“确定”的编码协议，可能有多种解码结果

二进制编码	当前匹配字符	解出原文	二进制编码	当前匹配字符	解出原文
1101111111001001	M	M	1101111111001001	M	M
011111111001001	E	ME	011111111001001	E	ME
111111001001	S	MES	111111001001	M	MEM
111001001	S	MESS	1111001001	M	MEMM
001001	A	MESSA	11001001	M	MEMMM
1001	G	MESSAG	001001	A	MEMMMA
01	E	MESSAGE	1001	G	MEMMAG
			01	E	MEMMAGE

进一步推敲之后不难发现，按照这份编码表，有时甚至还会出现无法完成解码的情况。

■ 前缀无歧义编码

解码过程之所以会出现上述歧义甚至错误，根源在于编码表制订不当。这里的解码算法采用的是，按顺序对信息比特流做子串匹配的策略，因此为消除匹配的歧义性，任何两个原始字符所对应的二进制编码串，相互都不得是前缀。比如在表5.3中，字符'M'的编码("11")即为字符'S'的编码("111")的前缀，于是编码串"111111"既可以解释为：

$$"SS" = "111^{111}"$$

也可以解释为

$$"MMM" = "11^{11}_{11}"$$

反过来，只要各字符的编码串互不为前缀，则即便出现无法解码的错误，也绝对不致歧义。这类编码方案即所谓的“前缀无歧义编码”（prefix-free code），简称PFC编码。此类编码算法，可以明确地将二进制编码串，分割为一系列与原字符对应的片段，从而实现无歧义的解码。得益于这一特点，此类算法在整个解码过程中，对信息比特流的扫描不必回溯。

那么，PFC编码的以上特点，可否直观解释？从算法角度看，PFC编码与解码过程，又该如何准确描述？从数据结构角度看，这些过程的实现，需要借助哪些功能接口？支持这些接口的数据结构，又该如何高效率地实现？以下以二叉树结构为模型，逐步解答这些疑问。

5.2.2 二叉编码树

■ 根通路与节点编码

任一编码方案都可描述为一棵二叉树：从根节点出发，每次向左（右）都对应于一个0（1）比特位。于是如图5.8所示，由从根节点到每个节点的唯一通路，可以为各节点 v 赋予一个互异的二进制串，称作根通路串（root path string），记作 $rps(v)$ 。当然， $|rps(v)| = depth(v)$ 就是 v 的深度。

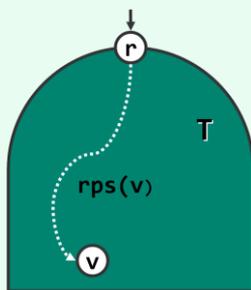


图5.8 二叉树中每个节点都由根通路串唯一确定

若将 Σ 中的字符分别映射至二叉树的节点，则字符 x 的二进制编码串即可取作 $rps(v(x))$ 。以下，在不致引起混淆的前提下，不再区分字符 x 和与之对应的节点 $v(x)$ 。于是， $rps(v(x))$ 可简记作 $rps(x)$ ； $depth(v(x))$ 可简记作 $depth(x)$ 。

■ PFC编码树

仍以字符集 $\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 为例，表5.1、表5.3所定义的编码方案分别对应于如图5.9左、右所示的二叉编码树。

易见， $rps(u)$ 是 $rps(v)$ 的前缀，当且仅当节点 u 是 v 的祖先，故表5.3中编码方案导致解码歧义的根本在于，在其编码树（图5.9(b)）中字符'M'是'S'的父亲。

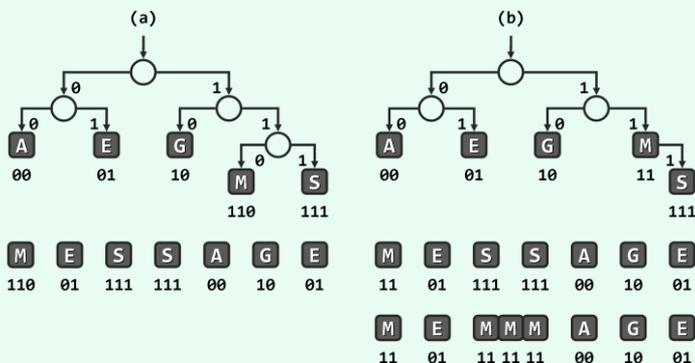


图5.9 $\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 两种编码方案对应的二叉编码树

反之，只要所有字符都对应于叶节点，歧义现象即自然消除——这也是实现PFC编码的简明策略。

比如，图5.9(a)即为一种可行的PFC编码方案。

■ 基于PFC编码树的解码

反过来，依据PFC编码树可便捷地完成编码串的解码。依然以图5.9(a)中编码树为例，设对编码串"110⁰¹111¹¹¹00¹⁰01"解码。从前向后扫描该串，同时在树中相应移动。起始时从树根出发，视各比特位的取值相应地向左或右深入下一层，直到抵达叶节点。比如，在扫描过前三位"110"后将抵达叶节点'M'。此时，可以输出其对应的字符'M'，然后重新回到树根，并继续扫描编码串的剩余部分。比如，再经过接下来的两位"01"后将抵达叶节点'E'，同样地输出字符'E'并回到树根。如此迭代，即可无歧义地解析出原文中的所有字符（习题[5-6]）。

实际上，这一解码过程甚至可以在二进制编码串接收过程中实时进行，而不必等到所有比特位都到达之后才开始，因此这类算法属于在线算法。

■ PFC编码树的构造

由上可见，PFC编码方案可由PFC编码树来描述，由编码树不仅可以快速生成编码表，而且直接支持高效的解码。那么，任意给定一个字符集 Σ ，如何构造出PFC编码方案呢？

为此，需要首先解决二叉树本身作为数据结构的描述和实现问题。

§ 5.3 二叉树的实现

作为图的特殊形式，二叉树的基本组成单元是节点与边；作为数据结构，其基本的组成实体是二叉树节点（binary tree node），而边则对应于节点之间的相互引用。

5.3.1 二叉树节点

■ BinNode模板类

以二叉树节点BinNode模板类，可定义如代码5.1所示。

```

1 #define BinNodePosi(T) BinNode<T>* //节点位置
2 #define stature(p) ((p) ? (p)->height : -1) //节点高度（与“空树高度为-1”的约定相统一）
3 typedef enum { RB_RED, RB_BLACK} RBColor; //节点颜色
4
5 template <typename T> struct BinNode { //二叉树节点模板类
6 // 成员（为简化描述起见统一开放，读者可根据需要进一步封装）
7     T data; //数值
8     BinNodePosi(T) parent; BinNodePosi(T) lChild; BinNodePosi(T) rChild; //父节点及左、右孩子
9     int height; //高度（通用）
10    int npl; //Null Path Length（左式堆，也可直接用height代替）
11    RBColor color; //颜色（红黑树）
12 // 构造函数
13    BinNode() : parent(NULL), lChild(NULL), rChild(NULL), height(0), npl(1), color(RB_RED) { }
14    BinNode(T e, BinNodePosi(T) p = NULL, BinNodePosi(T) lc = NULL, BinNodePosi(T) rc = NULL,
15            int h = 0, int l = 1, RBColor c = RB_RED)
16        : data(e), parent(p), lChild(lc), rChild(rc), height(h), npl(l), color(c) { }
17 // 操作接口
18    int size(); //统计当前节点后代总数，亦即以其为根的子树的规模
19    BinNodePosi(T) insertAsLC(T const&); //作为当前节点的左孩子插入新节点
20    BinNodePosi(T) insertAsRC(T const&); //作为当前节点的右孩子插入新节点
21    BinNodePosi(T) succ(); //取当前节点的直接后继
22    template <typename VST> void travLevel(VST&); //子树层次遍历
23    template <typename VST> void travPre(VST&); //子树先序遍历
24    template <typename VST> void travIn(VST&); //子树中序遍历
25    template <typename VST> void travPost(VST&); //子树后序遍历
26 // 比较器、判等器（各列其一，其余自行补充）
27    bool operator<(BinNode const& bn) { return data < bn.data; } //小于
28    bool operator==(BinNode const& bn) { return data == bn.data; } //等于
29 };

```

代码5.1 二叉树节点模板类BinNode

为简化起见，这里也未做严格的封装。通过宏BinNodePosi来指代节点位置，可以简化后续代码描述；通过定义宏stature，则可以保证从节点返回的高度值，能够与“空树高度为-1”的约定相统一。

■ 成员变量

如图5.10所示, BinNode节点由多个成员变量组成, 它们分别记录了当前节点的父亲和孩子的位置、节点内存放的数据以及节点的高度等指标, 这些都是二叉树相关算法赖以实现的基础。



图5.10 BinNode模板类的逻辑结构

其中, `data`的类型由模板变量`T`指定, 用于存放各节点所对应的数值对象。`lChild`、`rChild`和`parent`均为指针类型, 分别指向左、右孩子以及父节点的位置。如此, 既可将各节点联接起来, 也可在它们之间漫游移动。比如稍后5.4节将要介绍的遍历算法, 就必须借助此类位置变量。当然, 通过判断这些变量所指位置是否为`NULL`, 也可确定当前节点的类型。比如, `v.parent = NULL`当且仅当`v`是根节点, 而`v.lChild = v.rChild = NULL`当且仅当`v`是叶节点。

后续章节将基于二叉树实现二叉搜索树和优先级队列等数据结构, 而节点高度`height`在其中的具体语义也有所不同。比如, 8.3节的红黑树将采用所谓的黑高度 (`black height`), 而10.3节的左式堆则采用所谓的空节点通路长度 (`null path length`)。尽管后者也可以直接沿用`height`变量, 但出于可读性的考虑, 这里还是专门设置了一个变量`npl`。

有些种类的二叉树还可能需要其它的变量来描述节点状态, 比如针对其中节点的颜色, 红黑树需要引入一个属于枚举类型`RB_Color`的变量`color`。

根据不同应用需求, 还可以针对节点的深度增设成员变量`depth`, 或者针对以当前节点为根的子树规模 (该节点的后代数) 增设成员变量`size`。利用这些变量固然可以加速静态的查询或搜索, 但为保持这些变量的时效性, 在所属二叉树发生结构性调整 (比如节点的插入或删除) 之后, 这些成员变量都要动态地更新。因此, 究竟是否值得引入此类成员变量, 必须权衡利弊。比如, 在二叉树结构改变频繁以至于动态操作远多于静态操作的场合, 舍弃深度、子树规模等变量, 转而在实际需要时再直接计算这些指标, 应是更为明智的选择。

■ 快捷方式

在`BinNode`模板类各接口以及后续相关算法的实现中, 将频繁检查和判断二叉树节点的状态与性质, 有时还需要定位与之相关的 (兄弟、叔叔等) 特定节点, 为简化算法描述同时增强可读性, 不妨如代码5.2所示将其中常用功能以宏的形式加以整理归纳。

```

1 /*****
2  * BinNode状态与性质的判断
3  *****/
4 #define IsRoot(x) (!(x).parent)
5 #define IsLChild(x) (!IsRoot(x) && (&(x) == (x).parent->lChild))
6 #define IsRChild(x) (!IsRoot(x) && (&(x) == (x).parent->rChild))
7 #define HasParent(x) (!IsRoot(x))
8 #define HasLChild(x) ((x).lChild)
9 #define HasRChild(x) ((x).rChild)
10 #define HasChild(x) (HasLChild(x) || HasRChild(x)) //至少拥有一个孩子
11 #define HasBothChild(x) (HasLChild(x) && HasRChild(x)) //同时拥有两个孩子
12 #define IsLeaf(x) (!HasChild(x))

```

```

13
14 /*****
15 * 与BinNode具有特定关系的节点及指针
16 *****/
17 #define sibling(p) ( \
18     IsLChild(*(p)) ? \
19     (p)->parent->rChild : \
20     (p)->parent->lChild \
21 ) //兄弟
22
23 #define uncle(x) ( \
24     IsLChild(*(x->parent)) ? \
25     (x->parent->parent->rChild : \
26     (x->parent->parent->lChild \
27 ) //叔叔
28
29 #define FromParentTo(x) ( \
30     IsRoot(x) ? _root : ( \
31     IsLChild(x) ? (x).parent->lChild : (x).parent->rChild \
32     ) \
33 ) //来自父亲的指针

```

代码5.2 以宏的形式对基于BinNode的操作做一归纳整理

5.3.2 二叉树节点操作接口

由于BinNode模板类本身处于底层，故这里也将所有操作接口统一设置为开放权限，以简化描述。同样地，注重数据结构封装性的读者可在此基础上自行修改扩充。

■ 插入孩子节点

```

1 template <typename T> //将e作为当前节点的左孩子插入二叉树
2 BinNodePosi(T) BinNode<T>::insertAsLC(T const& e) { return lChild = new BinNode(e, this); }
3
4 template <typename T> //将e作为当前节点的右孩子插入二叉树
5 BinNodePosi(T) BinNode<T>::insertAsRC(T const& e) { return rChild = new BinNode(e, this); }

```

代码5.3 二叉树节点左、右孩子的插入

可见，为将新节点作为当前节点的左孩子插入树中，可如图5.11(a)所示，先创建新节点；再如图(b)所示，将当前节点作为新节点的父亲，并令新节点作为当前节点的左孩子。这里约定，在插入新节点之前，当前节点尚无左孩子。

右孩子的插入过程完全对称，不再赘述。

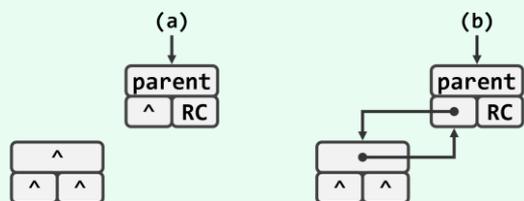


图5.11 二叉树节点左孩子插入过程

■ 定位直接后继

稍后在5.4.3节我们将会看到，通过中序遍历，可在二叉树各节点之间定义一个线性次序。相应地，各节点之间也可定义前驱与后继关系。这里的succ()接口，可以返回当前节点的直接后继（如果存在）。该接口的具体实现，将在130页代码5.16中给出。

■ 遍历

稍后的5.4节，将从递归和迭代两个角度，分别介绍各种遍历算法的不同实现。为便于测试与比较，不妨将这些算法的不同版本统一归入统一的接口中，并在调用时随机选择。

```

1 template <typename T> template <typename VST> //元素类型、操作器
2 void BinNode<T>::travIn(VST& visit) { //二叉树中序遍历算法统一入口
3     switch (rand() % 5) { //此处暂随机选择以做测试，共五种选择
4         case 1: travIn_I1(this, visit); break; //迭代版#1
5         case 2: travIn_I2(this, visit); break; //迭代版#2
6         case 3: travIn_I3(this, visit); break; //迭代版#3
7         case 4: travIn_I4(this, visit); break; //迭代版#4
8         default: travIn_R(this, visit); break; //递归版
9     }
10 }
```

代码5.4 二叉树中序遍历算法的统一入口

比如，中序遍历算法的五种实现方式（其中travIn_I4留作习题[5-17]），即可如代码5.4所示，纳入统一的BinNode::travIn()接口。其余遍历算法的处理方法类似，不再赘述。

5.3.3 二叉树

■ BinTree模板类

在BinNode模板类的基础之上，可如代码5.5所示定义二叉树BinTree模板类。

```

1 #include "BinNode.h" //引入二叉树节点类
2 template <typename T> class BinTree { //二叉树模板类
3 protected:
4     int _size; //规模
5     BinNodePosi(T) _root; //根节点
6     virtual int updateHeight(BinNodePosi(T) x); //更新节点x的高度
7     void updateHeightAbove(BinNodePosi(T) x); //更新节点x及其祖先的高度
8 public:
9     BinTree() : _size(0), _root(NULL) { } //构造函数
10    ~BinTree() { if (0 < _size) remove(_root); } //析构函数
11    int size() const { return _size; } //规模
12    bool empty() const { return !_root; } //判空
13    BinNodePosi(T) root() const { return _root; } //树根
14    BinNodePosi(T) insertAsRoot(T const& e); //插入根节点
15    BinNodePosi(T) insertAsLC(BinNodePosi(T) x, T const& e); //e作为x的左孩子(原无)插入
```

```

16 BinNodePosi(T) insertAsRC(BinNodePosi(T) x, T const& e); //e作为x的右孩子(原无)插入
17 BinNodePosi(T) attachAsLC(BinNodePosi(T) x, BinTree<T>* &t); //t作为x左子树接入
18 BinNodePosi(T) attachAsRC(BinNodePosi(T) x, BinTree<T>* &t); //t作为x右子树接入
19 int remove(BinNodePosi(T) x); //删除以位置x处节点为根的子树,返回该子树原先的规模
20 BinTree<T>* secede(BinNodePosi(T) x); //将子树x从当前树中摘除,并将其转换为一棵独立子树
21 template <typename VST> //操作器
22 void travLevel(VST& visit) { if (_root) _root->travLevel(visit); } //层次遍历
23 template <typename VST> //操作器
24 void travPre(VST& visit) { if (_root) _root->travPre(visit); } //先序遍历
25 template <typename VST> //操作器
26 void travIn(VST& visit) { if (_root) _root->travIn(visit); } //中序遍历
27 template <typename VST> //操作器
28 void travPost(VST& visit) { if (_root) _root->travPost(visit); } //后序遍历
29 // 比较器、判等器(各列其一,其余自行补充)
30 bool operator<(BinTree<T> const& t) { return _root && t._root && lt(_root, t._root); }
31 bool operator==(BinTree<T> const& t) { return _root && t._root && (_root == t._root); }
32 }; //BinTree

```

代码5.5 二叉树模板类BinTree

其中, `_root`指向树根, `_size`动态记录树的规模,且 `_root = NULL`当且仅当 `_size = 0`。

■ 高度更新

二叉树任一节点的高度,都等于其孩子节点的最大高度加一。于是,每当某一节点的孩子或后代有所增减,其高度都有必要及时更新。然而实际上,节点自身很难发现后代的变化,因此这里反过来采用另一处理策略:一旦有节点加入或离开二叉树,则更新其所有祖先的高度。请读者自行验证,这一原则实际上与前一个等效(习题[5-3])。

在每一节点 `v`处,只需读出其左、右孩子的高度并取二者之间的大者,再计入当前节点本身,就得到了 `v`的新高度。通常,接下来还需要从 `v`出发沿 `parent`指针逆行向上,依次更新各代祖先的高度记录。这一过程可具体实现如代码5.6所示。

```

1 template <typename T> int BinTree<T>::updateHeight(BinNodePosi(T) x) //更新节点x高度
2 { return x->height = 1 + max(stature(x->lChild), stature(x->rChild)); } //具体规则因树不同而异
3
4 template <typename T> void BinTree<T>::updateHeightAbove(BinNodePosi(T) x) //更新v及祖先的高度
5 { while (x) { updateHeight(x); x = x->parent; } } //可优化:一旦高度未变,即可终止

```

代码5.6 二叉树节点的高度更新

更新每一节点本身的高度,只需执行两次 `getHeight()`操作、两次加法以及两次取最大操作,不过常数时间,故 `updateHeight()`算法总体运行时间也是 $O(\text{depth}(v) + 1)$,其中 `depth(v)`为节点 `v`的深度。当然,这一算法还可进一步优化(习题[5-4])。

在某些种类的二叉树(例如8.3节将要介绍的红黑树)中,高度的定义有所不同,因此这里将 `updateHeight()`定义为保护级的虚方法,以便派生类在必要时重写(`override`)。

■ 节点插入

二叉树节点可以通过三种方式插入二叉树中，具体实现如代码5.7所示。

```

1 template <typename T> BinNodePosi(T) BinTree<T>::insertAsRoot(T const& e)
2 { _size = 1; return _root = new BinNode<T>(e); } //将e当作根节点插入空的二叉树
3
4 template <typename T> BinNodePosi(T) BinTree<T>::insertAsLC(BinNodePosi(T) x, T const& e)
5 { _size++; x->insertAsLC(e); updateHeightAbove(x); return x->lChild; } //e插入为x的左孩子
6
7 template <typename T> BinNodePosi(T) BinTree<T>::insertAsRC(BinNodePosi(T) x, T const& e)
8 { _size++; x->insertAsRC(e); updateHeightAbove(x); return x->rChild; } //e插入为x的右孩子

```

代码5.7 二叉树根、左、右节点的插入

`insertAsRoot()`接口用于将节点插入空树中，当然，该节点随即也应成为树根。

为此，只需创建一个新节点并存入指定的数据项，再令其作为根节点，同时更新全树的规模。

如图5.12(a)所示，若二叉树T中某个节点x的右孩子为空，则可通过`T.insertAsRC()`接口为其添加一个右孩子。为此可如图(b)所示调用`x->insertAsRC()`接口，将二者按照父子关系相互联接，同时通过`updateHeightAbove()`接口更新x所有祖先的高度，并更新全树规模。请注意这里的两个同名`insertAsRC()`接口，它们各自所属的对象类型不同。

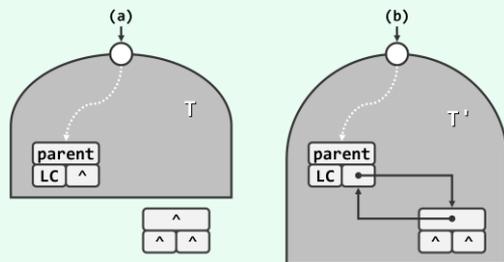


图5.12 右节点插入过程：(a)插入前；(b)插入后

左侧节点的插入过程与此相仿，可对称地调用`insertAsLC()`完成。

■ 子树接入

如代码5.8所示，任一二叉树均可作为另一二叉树中指定节点的左子树或右子树，植入其中。

```

1 template <typename T> //二叉树子树接入算法：将S当作节点x的左子树接入，S本身置空
2 BinNodePosi(T) BinTree<T>::attachAsLC(BinNodePosi(T) x, BinTree<T>* &S) { //x->lChild == NULL
3     if (x->lChild = S->_root) x->lChild->parent = x; //接入
4     _size += S->_size; updateHeightAbove(x); //更新全树规模与x所有祖先的高度
5     S->_root = NULL; S->_size = 0; release(S); S = NULL; return x; //释放原树，返回接入位置
6 }
7
8 template <typename T> //二叉树子树接入算法：将S当作节点x的右子树接入，S本身置空
9 BinNodePosi(T) BinTree<T>::attachAsRC(BinNodePosi(T) x, BinTree<T>* &S) { //x->rChild == NULL
10    if (x->rChild = S->_root) x->rChild->parent = x; //接入
11    _size += S->_size; updateHeightAbove(x); //更新全树规模与x所有祖先的高度
12    S->_root = NULL; S->_size = 0; release(S); S = NULL; return x; //释放原树，返回接入位置
13 }

```

代码5.8 二叉树子树的接入

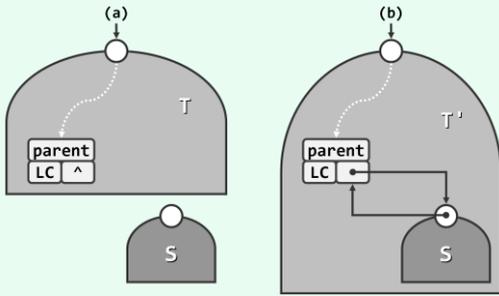


图5.13 右子树接入过程：(a)接入前；(b)接入后

如图5.13(a)，若二叉树T中节点x的右孩子为空，则attachAsRC()接口首先将待植入的二叉树S的根节点作为x的右孩子，同时令x作为该根节点的父亲；然后，更新全树规模以及节点x所有祖先的高度；最后，将树S中除已接入的各节点之外的其余部分归还系统。

左子树接入过程与此类似，可对称地调用attachAsLC()完成。

■ 子树删除

子树删除的过程与如图5.13所示的子树接入过程恰好相反，不同之处在于，需要将被摘除子树中的节点逐一释放并归还系统（习题[5-5]）。具体实现如代码5.9所示。

```

1  template <typename T> //删除二叉树中位置x处的节点及其后代，返回被删除节点的数值
2  int BinTree<T>::remove(BinNodePosi(T) x) { //assert: x为二叉树中的合法位置
3      FromParentTo(*x) = NULL; //切断来自父节点的指针
4      updateHeightAbove(x->parent); //更新祖先高度
5      int n = removeAt(x); _size -= n; return n; //删除子树x，更新规模，返回删除节点总数
6  }
7
8  template <typename T> //删除二叉树中位置x处的节点及其后代，返回被删除节点的数值
9  static int removeAt(BinNodePosi(T) x) { //assert: x为二叉树中的合法位置
10     if (!x) return 0; //递归基：空树
11     int n = 1 + removeAt(x->lChild) + removeAt(x->rChild); //递归释放左、右子树
12     release(x->data); release(x); return n; //释放被摘除节点，并返回删除节点总数
13 }

```

代码5.9 二叉树子树的删除

■ 子树分离

子树分离的过程与以上的子树删除过程基本一致，不同之处在于，需要对分离出来的子树重新封装，并返回给上层调用者。具体实现如代码5.10所示。

```

1  template <typename T> //二叉树子树分离算法：将子树x从当前树中摘除，将其封装为一棵独立子树返回
2  BinTree<T>* BinTree<T>::secede(BinNodePosi(T) x) { //assert: x为二叉树中的合法位置
3      FromParentTo(*x) = NULL; //切断来自父节点的指针
4      updateHeightAbove(x->parent); //更新原树中所有祖先的高度
5      BinTree<T>* S = new BinTree<T>; S->_root = x; x->parent = NULL; //新树以x为根
6      S->_size = x->size(); _size -= S->_size; return S; //更新规模，返回分离出来的子树
7  }

```

代码5.10 二叉树子树的分离

■ 复杂度

就二叉树拓扑结构的变化范围而言，以上算法均只涉及局部的常数个节点。因此，除了更新祖先高度和释放节点等操作，只需常数时间。

§ 5.4 遍历

对二叉树的访问多可抽象为如下形式：按照事先约定的某种规则或次序，对节点各访问一次而且仅一次。与向量和列表等线性结构一样，二叉树的这类访问也统称为遍历（traversal）。同样地，遍历操作之于二叉树的意义，在于为许多相关算法的实现提供了通用框架和基本接口。从算法策略的角度看，这一过程也等效于将半线性的树形结构转换为线性结构。

不过，因为二叉树已经不再属于线性结构，故相对于向量和列表等序列结构，二叉树的遍历略显复杂。为此，以下首先从递归的角度，给出若干种典型的二叉树遍历次序的定义，并按照117页代码5.1和121页代码5.5所列接口，给出相应的递归式实现；然后，为了提高遍历算法的实际效率，再分别介绍各种遍历接口的迭代式实现。

5.4.1 递归式遍历

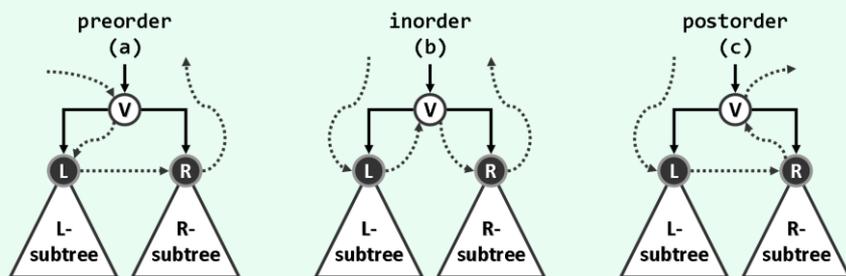


图5.14 二叉树遍历的全局次序由局部次序规则确定

二叉树本身并不具有天然的全局次序，故为实现遍历，需通过在各节点与其孩子之间约定某种局部次序，间接地定义某种全局次序。

按惯例左兄弟优先于右兄弟，故若将节点及其孩子分别记作V、L和R，则如图5.14所示，局部访问的次序可有VLR、LVR和LRV三种选择。根据节点V在其中的访问次序，三种策略也相应地分别称作先序遍历、中序遍历和后序遍历，分述如下。

■ 先序遍历

得益于递归定义的简洁性，如代码5.11所示，只需数行即可实现先序遍历算法。

```

1 template <typename T, typename VST> //元素类型、操作器
2 void travPre_R(BinNodePosi(T) x, VST& visit) { //二叉树先序遍历算法（递归版）
3     if (!x) return;
4     visit(x->data);
5     travPre_R(x->lChild, visit);
6     travPre_R(x->rChild, visit);
7 }
```

代码5.11 二叉树先序遍历算法（递归版）

为遍历（子）树x，首先核对x是否为空。若x为空，则直接退出——其效果相当于递归基。反之，若x非空，则按照先序遍历关于局部次序的定义，优先访问其根节点x；然后，依次深入左子树和右子树，递归地进行遍历。实际上，这一实现模式也同样可以应用于中序和后序遍历。

经过遍历之后，即可相应地在节点之间定义出某种线性次序，称作遍历（生成）序列。图5.15以一棵具体的二叉树为例，给出了完整的先序遍历过程以及生成的遍历序列。

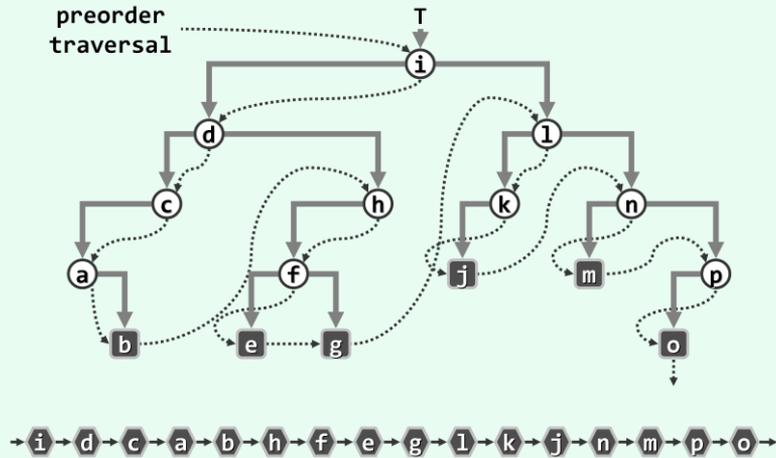


图5.15 二叉树先序遍历序列

■ 后序遍历

```

1 template <typename T, typename VST> //元素类型、操作器
2 void travPost_R(BinNodePosi(T) x, VST& visit) { //二叉树后序遍历算法（递归版）
3     if (!x) return;
4     travPost_R(x->lChild, visit);
5     travPost_R(x->rChild, visit);
6     visit(x->data);
7 }
    
```

代码5.12 二叉树后序遍历算法（递归版）

仿照以上先序遍历的模式，可如代码5.12所示实现递归版后序遍历算法。

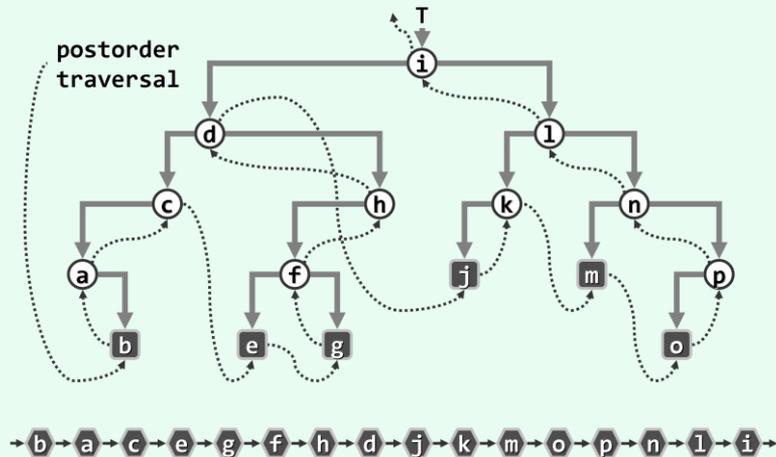


图5.16 二叉树的后序遍历序列

按照后序遍历规则，为遍历非空的（子）树 x ，将在依次递归遍历其左子树和右子树之后，才访问节点 x 。对于以上二叉树实例，其完整的后序遍历过程以及生成的遍历序列如图5.16所示。与图5.15做一对比可见，先序遍历序列与后序遍历序列并非简单的逆序关系。

■ 中序遍历

再次仿照以上模式，可实现递归版中序遍历算法如代码5.13所示。

```

1 template <typename T, typename VST> //元素类型、操作器
2 void travIn_R(BinNodePosi(T) x, VST& visit) { //二叉树中序遍历算法（递归版）
3     if (!x) return;
4     travIn_R(x->lChild, visit);
5     visit(x->data);
6     travIn_R(x->rChild, visit);
7 }

```

代码5.13 二叉树中序遍历算法（递归版）

按照中序遍历规则，为遍历非空的（子）树 x ，将依次递归遍历其左子树、访问节点 x 、递归遍历其右子树。以上二叉树实例的中序遍历过程以及生成的遍历序列，如图5.17所示。

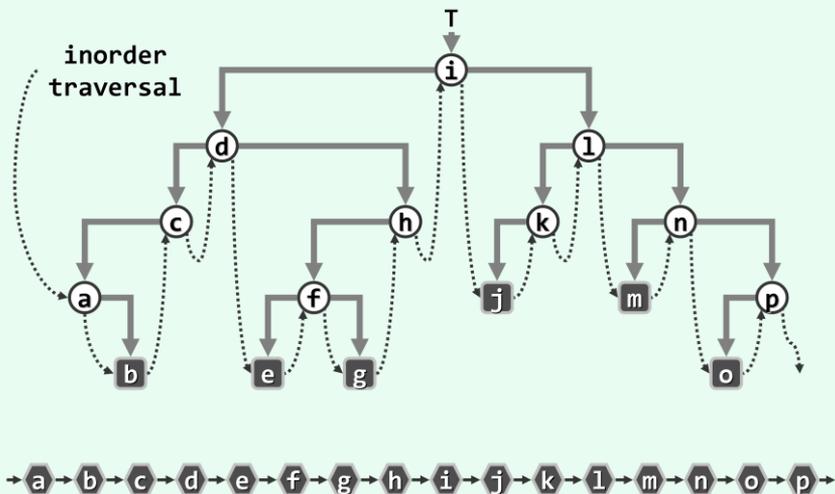


图5.17 二叉树的中序遍历序列

与以上的先序和后序遍历序列做一对比不难发现，各节点在中序遍历序列中的局部次序，与按照有序树定义所确定的全局左、右次序完全吻合。这一现象并非巧合，在第7章和第8章中，这正是搜索树及其等价变换的原理和依据所在。

5.4.2 *迭代版先序遍历

无论以上各种递归式遍历算法还是以下各种迭代式遍历算法，都只需渐进的线性时间（习题[5-9]和[5-11]）；而且相对而言，前者更加简明。既然如此，有何必要介绍迭代式遍历算法呢？

首先，递归版遍历算法时间、空间复杂度的常系数，相对于迭代版更大。同时，从学习的角度来看，从底层实现迭代式遍历，也是加深对相关过程与技巧理解的有效途径。

■ 版本1

观察先序遍历的递归版（代码5.11）可发现，其中针对右子树的递归属于尾递归，左子树的则接近于尾递归。故参照消除尾递归的一般性方法，不难将其改写迭代版（习题[5-10]）。

■ 版本2

很遗憾，以上思路并不容易推广到非尾递归的场合，比如在中序或后序遍历中，至少有一个递归方向严格地不属于尾递归。此时，如下另一迭代式版本的实现思路，则更具参考价值。

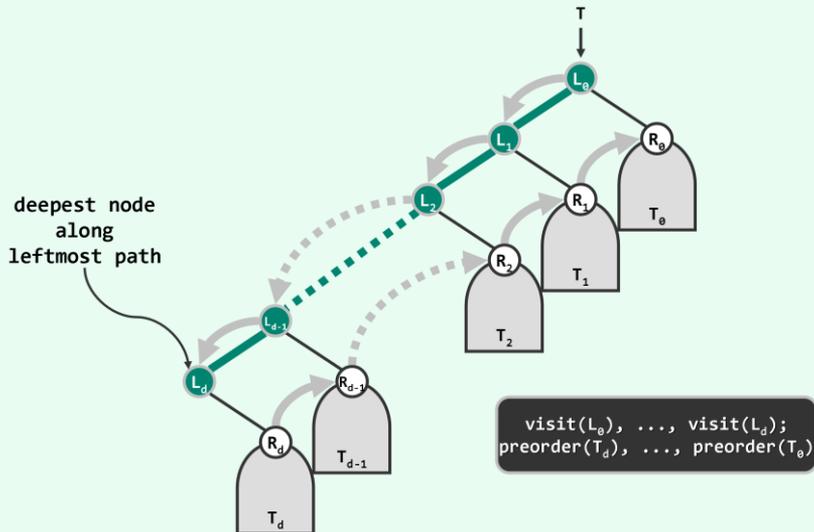


图5.18 先序遍历过程：先沿最左侧通路自顶而下访问沿途节点，再自底而上依次遍历这些节点的右子树

如图5.18所示，在二叉树 T 中，从根节点出发沿着左分支一直下行的那条通路（以粗线示意），称作最左侧通路（leftmost path）。若将沿途节点分别记作 L_k ， $k = 0, 1, 2, \dots, d$ ，则最左侧通路终止于没有左孩子末端节点 L_d 。若这些节点的右孩子和右子树分别记作 R_k 和 T_k ， $k = 0, 1, 2, \dots, d$ ，则该二叉树的先序遍历序列可表示为：

$$\begin{aligned} \text{preorder}(T) = & \text{visit}(L_0), \quad \text{visit}(L_1), \quad \dots, \quad \text{visit}(L_d); \\ & \text{preorder}(T_d), \quad \dots, \quad \text{preorder}(T_1), \quad \text{preorder}(T_0) \end{aligned}$$

也就是说，先序遍历序列可分解为两段：沿最左侧通路自顶而下访问的各节点，以及自底而上遍历的对应右子树。基于对先序遍历序列的这一理解，可以导出以下迭代式先序遍历算法。

```

1 //从当前节点出发，沿左分支不断深入，直至没有左分支的节点；沿途节点遇到后立即访问
2 template <typename T, typename VST> //元素类型、操作器
3 static void visitAlongLeftBranch(BinNodePosi(T) x, VST& visit, Stack<BinNodePosi(T)>& S) {
4     while (x) {
5         visit(x->data); //访问当前节点
6         S.push(x->rChild); //右孩子入栈暂存（可优化：通过判断，避免空的右孩子入栈）
7         x = x->lChild; //沿左分支深入一层
8     }
9 }

```

```

10
11 template <typename T, typename VST> //元素类型、操作器
12 void travPre_I2(BinNodePosi(T) x, VST& visit) { //二叉树先序遍历算法 (迭代版#2)
13     Stack<BinNodePosi(T)> S; //辅助栈
14     while (true) {
15         visitAlongLeftBranch(x, visit, S); //从当前节点出发, 逐批访问
16         if (S.empty()) break; //直到栈空
17         x = S.pop(); //弹出下一批的起点
18     }
19 }

```

代码5.14 二叉树先序遍历算法 (迭代版#2)

如代码5.14所示, 在全树以及其中每一棵子树的根节点处, 该算法都首先调用函数 `VisitAlongLeftBranch()`, 自顶而下访问最左侧通路沿途的各个节点。这里也使用了一个辅助栈, 逆序记录最左侧通路上的节点, 以便确定其对应右子树自底而上的遍历次序。

5.4.3 *迭代版中序遍历

如上所述, 在中序遍历的递归版本 (126页代码5.13) 中, 尽管右子树的递归遍历是尾递归, 但左子树绝对不是。实际上, 实现迭代式中序遍历算法的难点正在于此, 不过好在迭代式先序遍历的版本2可以为我们提供启发和借鉴。

■ 版本1

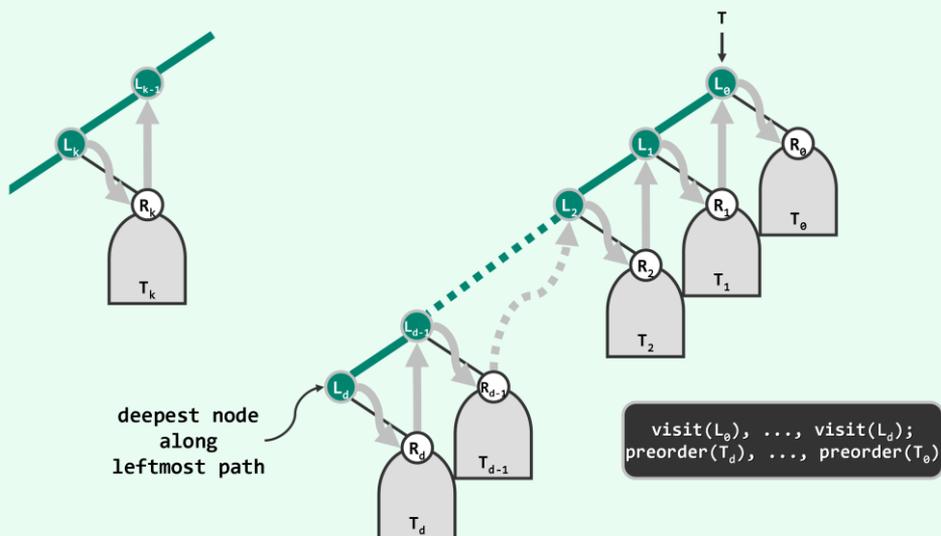


图5.19 中序遍历过程：

顺着最左侧通路，自底而上依次访问沿途各节点及其右子树

如图5.19所示, 参照迭代式先序遍历版本2的思路, 再次考查二叉树 T 的最左侧通路, 并对其中的节点和子树标记命名。于是, T 的中序遍历序列可表示为:

```

inorder(T) = visit(Ld), inorder(Td);
            ..., ...;
            visit(L1), inorder(T1);
            visit(L0), inorder(T0)

```

也就是说，沿最左侧通路自底而上，以沿途各节点为界，中序遍历序列可分解为 $d + 1$ 段。如图5.19左侧所示，各段均包括访问来自最左侧通路的某一节点 L_k ，以及遍历其右子树 T_k 。

基于对中序遍历序列的这一理解，即可导出如代码5.15所示的迭代式中序遍历算法。

```

1 template <typename T> //从当前节点出发，沿左分支不断深入，直至没有左分支的节点
2 static void goAlongLeftBranch(BinNodePosi(T) x, Stack<BinNodePosi(T)>& S) {
3     while (x) { S.push(x); x = x->lChild; } //当前节点入栈后随即向左侧分支深入，迭代直到无左孩子
4 }
5
6 template <typename T, typename VST> //元素类型、操作器
7 void travIn_I1(BinNodePosi(T) x, VST& visit) { //二叉树中序遍历算法（迭代版#1）
8     Stack<BinNodePosi(T)> S; //辅助栈
9     while (true) {
10        goAlongLeftBranch(x, S); //从当前节点出发，逐批入栈
11        if (S.empty()) break; //直至所有节点处理完毕
12        x = S.pop(); visit(x->data); //弹出栈顶节点并访问之
13        x = x->rChild; //转向右子树
14    }
15 }

```

代码5.15 二叉树中序遍历算法（迭代版#1）

在全树及其中每一棵子树的根节点处，该算法首先调用函数 `goAlongLeftBranch()`，沿最左侧通路自顶而下抵达末端节点 L_d 。在此过程中，利用辅助栈逆序地记录和保存沿途经过的各个节点，以便确定自底而上各段遍历子序列最终在宏观上的拼接次序。

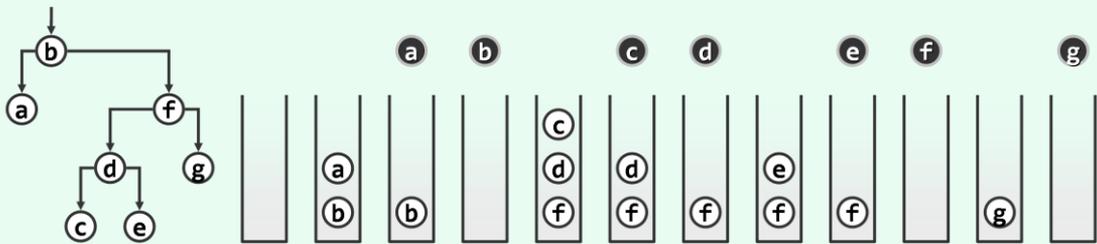


图5.20 迭代式中序遍历实例（出栈节点以深色示意）

图5.20以左侧二叉树为例，给出了中序遍历辅助栈从初始化到再次变空的演变过程。

■ 直接后继及其定位

与所有遍历一样，中序遍历的实质功能也可理解为，为所有节点赋予一个次序，从而将半线性的二叉树转化为线性结构。于是一旦指定了遍历策略，即可与向量和列表一样，在二叉树的节点之间定义前驱与后继关系。其中没有前驱（后继）的节点称作首（末）节点。

对于后面将要介绍的二叉搜索树,中序遍历的作用至关重要。相关算法必需的一项基本操作,就是定位任一节点在中序遍历序列中的直接后继。为此,可实现succ()接口如代码5.16所示。

```

1 template <typename T> BinNodePosi(T) BinNode<T>::succ() { //定位节点v的直接后继
2     BinNodePosi(T) s = this; //记录后继的临时变量
3     if (rChild) { //若有右孩子,则直接后继必在右子树中,具体地就是
4         s = rChild; //右子树中
5         while (HasLChild(*s)) s = s->lChild; //最靠左(最小)的节点
6     } else { //否则,直接后继应是“将当前节点包含于其左子树中的最低祖先”,具体地就是
7         while (IsRChild(*s)) s = s->parent; //逆向地沿右向分支,不断朝左上方移动
8         s = s->parent; //最后再朝右上方移动一步,即抵达直接后继(如果存在)
9     }
10    return s;
11 }

```

代码5.16 二叉树节点直接后继的定位

这里,共分两大类情况。若当前节点有右孩子,则其直接后继必然存在,且属于其右子树。此时只需转入右子树,再沿该子树的最左侧通路朝左下方深入,直到抵达子树中最靠左(最小)的节点。以图5.20中节点b为例,如此可确定其直接后继为节点c。

反之,若当前节点没有右子树,则若其直接后继存在,必为该节点的某一祖先,且是将当前节点纳入其左子树的最低祖先。于是首先沿右侧通路朝左上方上升,当不能继续前进时,再朝右上方移动一步即可。以图5.20中节点e为例,如此可确定其直接后继为节点f。

作为后一情况的特例,出口时s可能为NULL。这意味着此前沿着右侧通路向上的回溯,抵达了树根。也就是说,当前节点全树右侧通路的终点——它也是中序遍历的终点,没有后继。

■ 版本2

代码5.15经进一步改写之后,可得到如代码5.17所示的另一迭代式中序遍历算法。

```

1 template <typename T, typename VST> //元素类型、操作器
2 void travIn_I2(BinNodePosi(T) x, VST& visit) { //二叉树中序遍历算法(迭代版#2)
3     Stack<BinNodePosi(T)> S; //辅助栈
4     while (true)
5         if (x) {
6             S.push(x); //根节点进栈
7             x = x->lChild; //深入遍历左子树
8         } else if (!S.empty()) {
9             x = S.pop(); //尚未访问的最低祖先节点退栈
10            visit(x->data); //访问该祖先节点
11            x = x->rChild; //遍历祖先的右子树
12        } else
13            break; //遍历完成
14 }

```

代码5.17 二叉树中序遍历算法(迭代版#2)

虽然版本2只不过是版本1的等价形式,但借助它可便捷地设计和实现以下版本3。

■ 版本3

以上的迭代式遍历算法都需使用辅助栈，尽管这对遍历算法的渐进时间复杂度没有实质影响，但所需辅助空间的规模将线性正比于二叉树的高度，在最坏情况下与节点总数相当。

为此，可对代码5.17版本2继续改进，借助BinNode对象内部的parent指针，如代码5.18所示实现中序遍历的第三个迭代版本。该版本无需使用任何结构，总体仅需 $O(1)$ 的辅助空间，属于就地算法。当然，因需要反复调用succ()，时间效率有所倒退（习题[5-16]）。

```

1 template <typename T, typename VST> //元素类型、操作器
2 void travIn_I3(BinNodePosi(T) x, VST& visit) { //二叉树中序遍历算法（迭代版#3，无需辅助栈）
3     bool backtrack = false; //前一步是否刚从右子树回溯——省去栈，仅O(1)辅助空间
4     while (true)
5         if (!backtrack && HasLChild(*x)) //若有左子树且不是刚刚回溯，则
6             x = x->lChild; //深入遍历左子树
7         else { //否则——无左子树或刚刚回溯（相当于无左子树）
8             visit(x->data); //访问该节点
9             if (HasRChild(*x)) { //若其右子树非空，则
10                x = x->rChild; //深入右子树继续遍历
11                backtrack = false; //并关闭回溯标志
12            } else { //若右子树空，则
13                if (!(x = x->succ())) break; //回溯（含抵达末节点时的退出返回）
14                backtrack = true; //并设置回溯标志
15            }
16        }
17 }

```

代码5.18 二叉树中序遍历算法（迭代版#3）

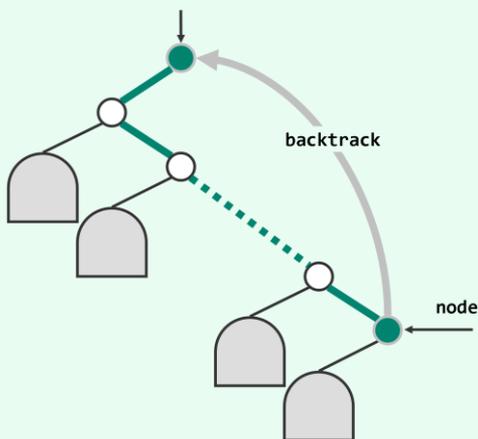


图5.21 中序遍历过程中，在无右孩子的节点处需做回溯

可见，这里相当于将原辅助栈替换为一个标志位backtrack。每当抵达一个节点，借助该标志即可判断此前是否刚做过一次自下而上的回溯。若不是，则按照中序遍历的策略优先遍历左子树。反之，若刚发生过一次回溯，则意味着当前节点的左子树已经遍历完毕（或等效地，左子树为空），于是便可访问当前节点，然后再深入其右子树继续遍历。

每个节点被访问之后，都应转向其在遍历序列中的直接后继。按照以上的分析，通过检查右子树是否为空，即可在两种情况间做出判断：该后继要么在当前节点的右子树（若该子树非空）中，要么（当右子树为空时）是其某一祖先。如图5.21所示，后一情况即所谓的回溯。

请注意，由succ()返回的直接后继可能是NULL，此时意味着已经遍历至中序遍历意义下的末节点，于是遍历即告完成。

5.4.4 *迭代版后序遍历

在如代码5.12所示后序遍历算法的递归版本中，左、右子树的递归遍历均严格地不属于尾递归，因此实现对应的迭代式算法难度更大。不过，仍可继续套用此前的思路和技巧。

我们思考的起点依然是，此时首先访问的是哪个节点？如图5.22所示，将树T画在二维平面上，并假设所有节点和边均不透明。于是从左侧水平向右看去，未被遮挡的最高叶节点v——称作最高左侧可见叶节点（HLVFL）——即为后序遍历首先访问的节点。请注意，该节点既可能是左孩子，也可能是右孩子，故在图中以垂直边示意与其父节点之间的联边。

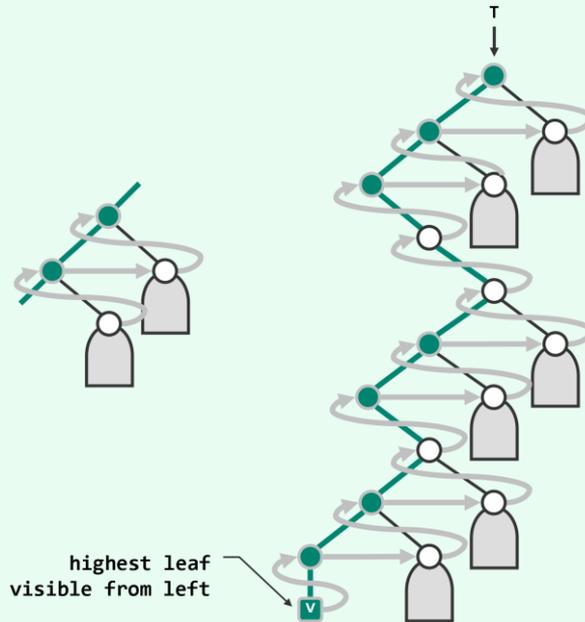


图5.22 后序遍历过程也可划分为模式雷同的若干段

考查联接于v与树根之间的唯一通路（以粗线示意）。与先序与中序遍历类似地，自底而上地沿着该通路，整个后序遍历序列也可分解为若干个片段。每一片段，分别起始于通路上的一个节点，并包括三步：访问当前节点，遍历以其右兄弟（若存在）为根的子树，以及向上回溯至其父节点（若存在）并转入下一片段。

基于以上理解，即可导出如代码5.19所示的迭代式后序遍历算法。

```

1 template <typename T> //在以S栈顶节点为根的子树中，找到最高左侧可见叶节点
2 static void gotoHLVFL(Stack<BinNodePosi(T)>& S) { //沿途所遇节点依次入栈
3     while (BinNodePosi(T) x = S.top()) //自顶而下，反复检查当前节点（即栈顶）
4         if (HasLChild(*x)) { //尽可能向左
5             if (HasRChild(*x)) S.push(x->rChild); //若有右孩子，优先入栈
6             S.push(x->lChild); //然后才转至左孩子
7         } else //实不得已
8             S.push(x->rChild); //才向右
9     S.pop(); //返回之前，弹出栈顶的空节点
10 }
11

```

```

12 template <typename T, typename VST>
13 void travPost_I(BinNodePosi(T) x, VST& visit) { //二叉树的后序遍历 (迭代版)
14     Stack<BinNodePosi(T)> S; //辅助栈
15     if (x) S.push(x); //根节点入栈
16     while (!S.empty()) {
17         if (S.top() != x->parent) //若栈顶非当前节点之父 (则必为其右兄), 此时需
18             gotoHLVFL(S); //在以其右兄为根之子树中, 找到HLVFL (相当于递归深入其中)
19         x = S.pop(); visit(x->data); //弹出栈顶 (即前一节点之后继), 并访问之
20     }
21 }

```

代码5.19 二叉树后序遍历算法 (迭代版)

可见, 在每一棵 (子) 树的根节点, 该算法都首先定位对应的HLVFL节点。同时在此过程中, 依然利用辅助栈逆序地保存沿途所经各节点, 以确定遍历序列各个片段在宏观上的拼接次序。

图5.23以左侧二叉树为例, 给出了后序遍历辅助栈从初始化到再次变空的演变过程。

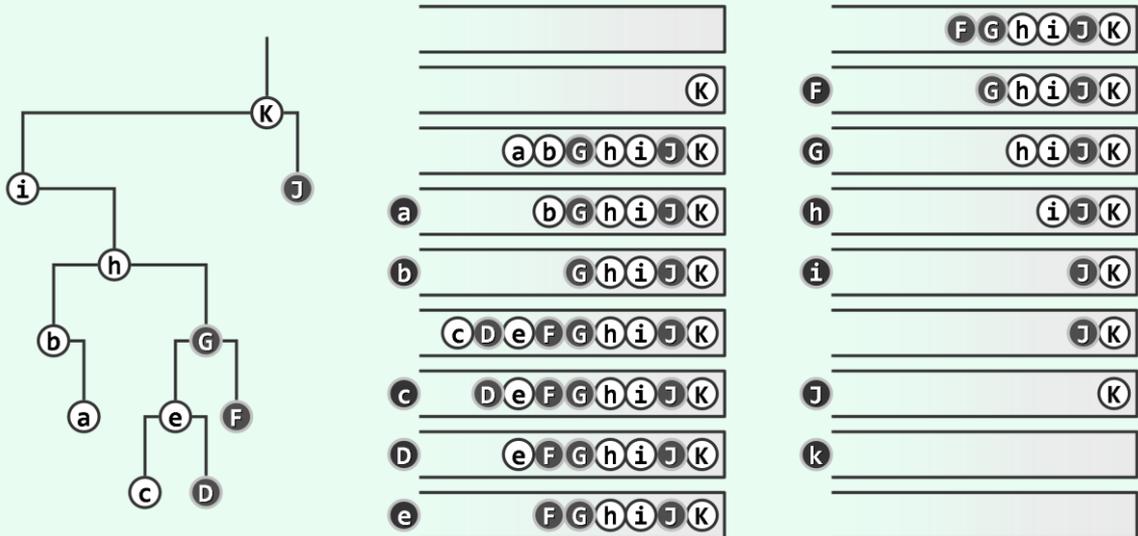


图5.23 迭代式后序遍历实例 (出栈节点以深色示意, 发生gotoHLVFL()调用的节点以大写字母示意)

请注意此处的入栈规则。在自顶而下查找HLVFL节点的过程中, 始终都是尽可能向左, 只有在左子树为空时才向右。前一情况下, 需令右孩子 (若有) 和左孩子先后入栈, 然后再转向左孩子。后一情况下, 只需令右孩子入栈。因此, 在主函数travPost_I()的每一步while迭代中, 若当前节点node的右兄弟存在, 则该兄弟必然位于辅助栈顶。按照后序遍历约定的次序, 此时应再次调用gotoHLVFL()以转向以该兄弟为根的子树, 并模拟以递归方式对该子树的遍历。

5.4.5 层次遍历

在所谓广度优先遍历或层次遍历 (level-order traversal) 中, 确定节点访问次序的原则可概括为“先上后下、先左后右”——先访问树根, 再依次是左孩子、右孩子、左孩子的左孩子、左孩子的右孩子、右孩子的左孩子、右孩子的右孩子、..., 依此类推。

当然，有根性和有序性是层次遍历序列得以明确定义的基础。正因为确定了树根，各节点方可拥有深度这一指标，并进而依此排序；有序性则保证孩子有左、右之别，并依此确定同深度节点之间的次序。

为对比效果，同样考查此前图5.15、图5.16和图5.17均采用二叉树实例。该树完整的层次遍历过程以及生成的遍历序列，如图5.24所示。

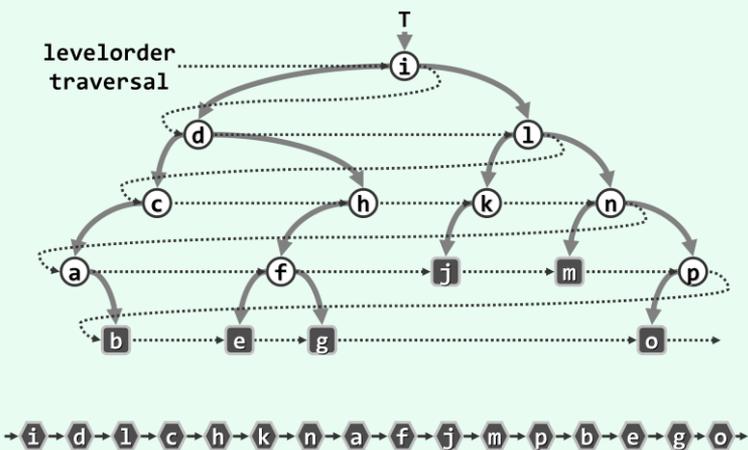


图5.24 二叉树的层次遍历序列

■ 算法实现

此前介绍的迭代式遍历，无论先序、中序还是后序遍历，大多使用了辅助栈，而迭代式层次遍历则需要使用与栈对称的队列结构，算法的具体实现如代码5.20所示。

```

1  template <typename T> template <typename VST> //元素类型、操作器
2  void BinNode<T>::travLevel(VST& visit) { //二叉树层次遍历算法
3      Queue<BinNodePosi(T)> Q; //辅助队列
4      Q.enqueue(this); //根节点入队
5      while (!Q.empty()) { //在队列再次变空之前，反复迭代
6          BinNodePosi(T) x = Q.dequeue(); visit(x->data); //取出队首节点并访问之
7          if (HasLChild(*x)) Q.enqueue(x->lChild); //左孩子入队
8          if (HasRChild(*x)) Q.enqueue(x->rChild); //右孩子入队
9      }
10 }
    
```

代码5.20 二叉树层次遍历算法

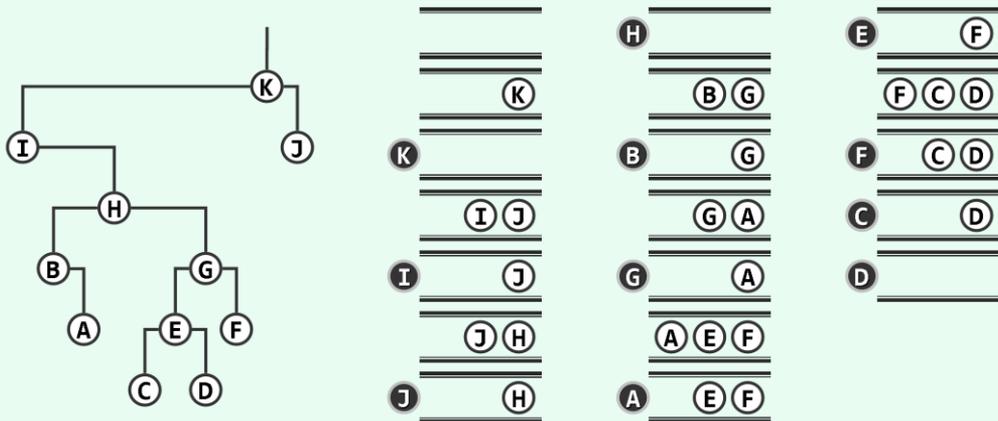


图5.25 层次遍历实例（出队节点以深色示意）

初始化时先令树根入队，随后进入循环。每一步迭代中，首先取出并访问队首节点，然后其左、右孩子（若存在）将顺序入队。一旦在试图进入下一代前发现队列为空，遍历即告完成。

图5.25以左侧二叉树为例，给出了层次遍历辅助队列从初始化到再次变空的演变过程。

■ 完全二叉树

反观代码5.20，在层次遍历算法的每一次迭代中，必有一个节点出队（而且不再入队），故累计恰好迭代 n 次。然而，每次迭代中入队节点的数目并不确定。若在对某棵二叉树的层次遍历过程中，前 $\lfloor n/2 \rfloor$ 次迭代中都有左孩子入队，且前 $\lfloor n/2 \rfloor - 1$ 次迭代中都有右孩子入队，则称之为完全二叉树（complete binary tree）。

图5.26给出了完全二叉树的实例，及其一般性的宏观拓扑结构特征：叶节点只能出现在最底部的两层，且最底层叶节点均处于次底层叶节点的左侧（习题[5-18]和[5-19]）。由此不难验证，高度为 h 的完全二叉树，规模应该介于 2^h 至 $2^{h+1} - 1$ 之间；反之，规模为 n 的完全二叉树，高度 $h = \lfloor \log_2 n \rfloor = O(\log n)$ 。另外，叶节点虽不致少于内部节点，但至多多出一个。以图5.26左侧的完全二叉树为例，高度 $h = 4$ ；共有 $n = 20$ 个节点，其中内部节点和叶节点各10个。

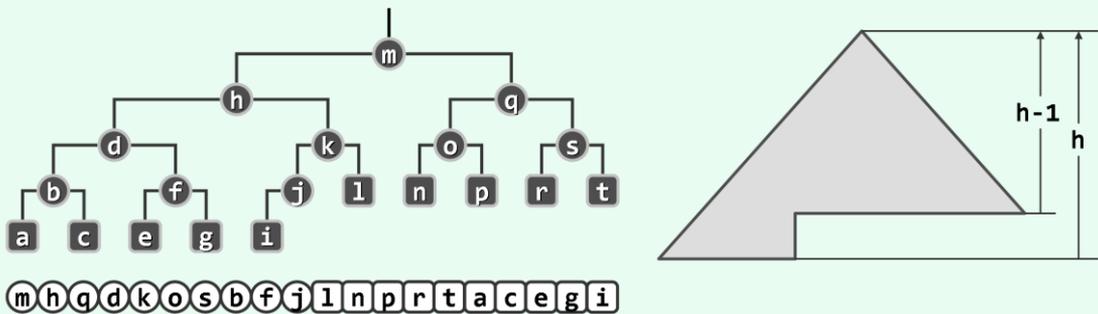


图5.26 完全二叉树实例及其宏观结构

得益于以上特性，完全二叉树可以借助向量结构，实现紧凑存储和高效访问（习题[5-20]）。

■ 满二叉树

完全二叉树的一种特例是，所有叶节点同处于最底层（非底层节点均为内部节点）。于是根据数学归纳法，每一层的节点数都应达到饱和，故将称其为满二叉树（full binary tree）。

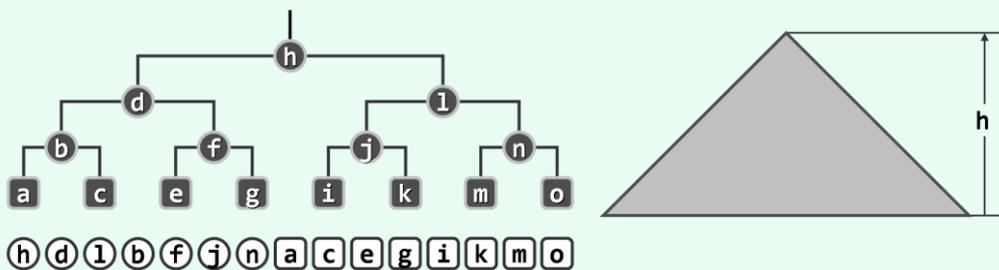


图5.27 满二叉树实例及其宏观结构

类似地不难验证，高度为 h 的满二叉树由 $2^{h+1} - 1$ 个节点组成，其中叶节点总是恰好比内部节点多出一个。图5.27左侧即为一棵包含 $n = 15$ 个节点、高度 $h = 3$ 的满二叉树，其中叶节点8个，内部节点7个；右侧则给出了满二叉树的一般性宏观结构。

§ 5.5 Huffman编码

5.5.1 PFC编码及解码

以下基于二叉树结构，按照图5.28的总体框架，介绍PFC编码和解码算法的具体实现。

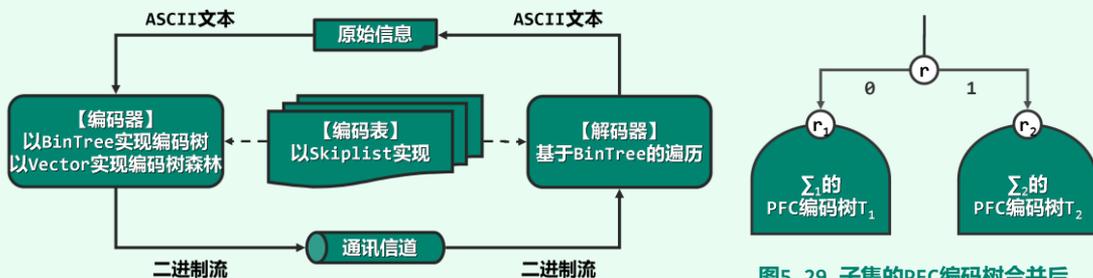


图5.28 为实现PFC编码和解码过程所需的数据结构和算法

图5.29 子集的PFC编码树合并后，即是全集的一棵PFC编码树

如图5.29所示，若字符集 Σ_1 和 Σ_2 之间没有公共字符，且PFC编码方案分别对应于二叉树 T_1 和 T_2 ，则通过引入一个根节点合并 T_1 和 T_2 之后所得到的二叉树，就是对应于 $\Sigma_1 \cup \Sigma_2$ 的一种PFC编码方案。请注意，无论 T_1 和 T_2 的高度与规模是否相等，这一性质总是成立。

利用上述性质，可自底而上地构造PFC编码树。首先，由每一字符分别构造一棵单节点二叉树，并将它们视作一个森林。此后，反复从森林中取出两棵树并将其合二为一。如此，经 $|\Sigma| - 1$ 步迭代之后，初始森林中的 $|\Sigma|$ 棵树将合并成为一棵完整的PFC编码树。接下来，再将PFC编码树转译为编码表，以便能够根据待编码字符快捷确定与之对应的编码串。至此，对于任何待编码文本，通过反复查阅编码表，即可高效地将其转化为二进制编码串。

与编码过程相对应地，接收方也可以借助同一棵编码树来记录双方约定的编码方案。于是，每当接收到经信道传送过来的编码串后，（只要传送过程无误）接收方都可通过在编码树中反复从根节点出发做相应的漫游，依次完成对信息文本中各字符的解码。

■ 总体框架

以上编码和解码过程可描述为代码5.21，这也是同类编码、解码算法的统一测试入口。

```

1 int main(int argc, char* argv[]) { //PFC编码、解码算法统一测试入口
2     PFCForest* forest = initForest(); //初始化PFC森林
3     PFCtree* tree = generateTree(forest); release(forest); //生成PFC编码树
4     PFCtable* table = generateTable(tree); //将PFC编码树转换为编码表
5     for (int i = 1; i < argc; i++) { //对于命令行传入的每一明文串
6         Bitmap codeString; //二进制编码串
7         int n = encode(table, codeString, argv[i]); //将根据编码表生成（长度为n）
8         decode(tree, codeString, n); //利用编码树，对长度为n的二进制编码串解码（直接输出）
9     }
10    release(table); release(tree); return 0; //释放编码表、编码树
11 }

```

代码5.21 基于二叉树的PFC编码

■ 数据结构的选取与设计

如代码5.22所示, 这里使用向量实现PFC森林, 其中各元素分别对应于一棵编码树; 使用9.2节将要介绍的跳转表式词典结构实现编码表, 其中的词条各以某一待编码字符为关键码, 以对应的编码串为数据项; 使用位图Bitmap (习题[2-34]) 实现各字符的二进制编码串。

```

1 /*****
2  * PFC编码使用的数据结构
3  *****/
4 #include "../BinTree/BinTree.h" //用BinTree实现PFC树
5 typedef BinTree<char> PFCTree; //PFC树
6
7 #include "../Vector/Vector.h" //用Vector实现PFC森林
8 typedef Vector<PFCTree*> PFCForest; //PFC森林
9
10 #include "../Bitmap/Bitmap.h" //使用位图结构实现二进制编码串
11 #include "../Skiplist/Skiplist.h" //引入Skiplist式词典结构实现
12 typedef Skiplist<char, char*> PFCTable; //PFC编码表, 词条格式为:(key = 字符, value = 编码串)
13
14 #define N_CHAR (0x80 - 0x20) //只考虑可打印字符

```

代码5.22 实现PFC编码所需的数据结构

以下, 分别给出各功能部分的具体实现, 请读者对照注解自行分析。

■ 初始化PFC森林

```

1 PFCForest* initForest() { //PFC编码森林初始化
2     PFCForest* forest = new PFCForest; //首先创建空森林, 然后
3     for (int i = 0; i < N_CHAR; i++) { //对每一个可打印字符[0x20, 0x80)
4         forest->insert(i, new PFCTree()); //创建一棵对应的PFC编码树, 初始时其中
5         (*forest)[i]->insertAsRoot(0x20 + i); //只包含对应的一个(叶、根)节点
6     }
7     return forest; //返回包含N_CHAR棵树的森林, 其中每棵树各包含一个字符
8 }

```

代码5.23 初始化PFC森林

■ 构造PFC编码树

```

1 PFCTree* generateTree(PFCForest* forest) { //构造PFC树
2     srand((unsigned int)time(NULL)); //这里将随机取树合并, 故先设置随机种子
3     while(1 < forest->size()) { //共做|forest|-1次合并
4         PFCTree* s = new PFCTree; s->insertAsRoot('^'); //创建新树(根标记为"^")
5         Rank r1 = rand() % forest->size(); //随机选取r1, 且
6         s->attachAsLC(s->root(), (*forest)[r1]); forest->remove(r1); //作为左子树接入后随即剔除
7         Rank r2 = rand() % forest->size(); //随机选取r2, 且
8         s->attachAsRC(s->root(), (*forest)[r2]); forest->remove(r2); //作为右子树接入后随即剔除

```

```

9     forest->insert(forest->size(), s); //合并后的PFC树重新植入PFC森林
10  }
11  return (*forest)[0]; //至此,森林中尚存的最后一棵树,即全局PFC编码树
12 }

```

代码5.24 构造PFC编码树

■ 生成PFC编码表

```

1 void generateCT //通过遍历获取各字符的编码
2 (Bitmap* code, int length, PFCTable* table, BinNodePosi(char) v) {
3     if (IsLeaf(*v)) //若是叶节点
4         { table->put(v->data, code->bits2string(length)); return; }
5     if (HasLChild(*v)) //Left = 0
6         { code->clear(length); generateCT(code, length + 1, table, v->lChild); }
7     if (HasRChild(*v)) //right = 1
8         { code->set(length); generateCT(code, length + 1, table, v->rChild); }
9 }
10
11 PFCTable* generateTable(PFCTree* tree) { //构造PFC编码表
12     PFCTable* table = new PFCTable; //创建以Skiplist实现的编码表
13     Bitmap* code = new Bitmap; //用于记录RPS的位图
14     generateCT(code, 0, table, tree->root()); //遍历以获取各字符(叶节点)的RPS
15     release(code); return table; //释放编码位图,返回编码表
16 }

```

代码5.25 生成PFC编码表

■ 编码

```

1 int encode(PFCTable* table, Bitmap& codeString, char* s) { //PFC编码算法
2     int n = 0;
3     for (size_t m = strlen(s), i = 0; i < m; i++) { //对于明文s[]中的每个字符
4         char** pCharCode = table->get(s[i]); //取出其对应的编码串
5         if (!pCharCode) pCharCode = table->get(s[i] + 'A' - 'a'); //小写字母转为大写
6         if (!pCharCode) pCharCode = table->get(' '); //无法识别的字符统一视作空格
7         printf("%s", *pCharCode); //输出当前字符的编码
8         for (size_t m = strlen(*pCharCode), j = 0; j < m; j++) //将当前字符的编码接入编码串
9             '1' == (*(pCharCode + j) ? codeString.set(n++) : codeString.clear(n++));
10    }
11    return n; //二进制编码串记录于codeString中,返回编码串总长
12 }

```

代码5.26 PFC编码

■ 解码

```

1 void decode(PFCTree* tree, Bitmap& code, int n) { //PFC解码算法
2     BinNodePosi(char) x = tree->root(); //根据PFC编码树
3     for (int i = 0; i < n; i++) { //将编码 (二进制位图)
4         x = code.test(i) ? x->rChild : x->lChild; //转译为明码并
5         if (IsLeaf(*x)) { printf("%c", x->data); x = tree->root(); } //打印输出
6     }
7 }

```

代码5.27 PFC解码

■ 优化

在介绍过PFC及其实现方法后，以下将就其编码效率做一分析，并设计出更佳的编码方法。

同样地，我们依然暂且忽略硬件成本和信道误差等因素，而主要考查如何高效率地完成文本信息的编码和解码。不难理解，在计算资源固定的条件下，不同编码方法的效率主要体现于所生成二进制编码串的总长，或者更确切地，体现于二进制码长与原始文本长度的比率。

那么，面对千变万化、长度不一的待编码文本，从总体上我们应该按照何种尺度来衡量这一因素呢？基于这一尺度，又该应用哪些数据结构来实现相关的算法呢？

5.5.2 最优编码树

在实际的通讯系统中，信道的使用效率是个很重要的问题，这在很大程度上取决于编码算法本身的效率。比如，高效的编码算法生成的编码串应该尽可能地短。那么，如何做到这一点呢？在什么情况下能够做到这一点呢？以下首先来看如何对编码长度做“度量”。

■ 平均编码长度与叶节点平均深度

由5.2.2节的结论，字符 x 的编码长度 $|rps(x)|$ 就是其对应叶节点的深度 $depth(v(x))$ 。于是，各字符的平均编码长度就是编码树 T 中各叶节点的平均深度（average leaf depth）：

$$ald(T) = \sum_{x \in \Sigma} |rps(x)| / |\Sigma| = \sum_{x \in \Sigma} depth(x) / |\Sigma|$$

以如图5.9(a)所示编码树为例，字符'A'、'E'和'G'的编码长度为2，'M'和'S'的编码长度为3，故该编码方案的平均编码长度为：

$$ald(T) = (2 + 2 + 2 + 3 + 3) / 5 = 2.4$$

既然 $ald(T)$ 值是反映编码效率的重要指标，我们自然希望这一指标尽可能地小。

■ 最优编码树

同一字符集的所有编码方案中，平均编码长度最小者称作最优方案；对应编码树的 $ald()$ 值也达到最小，故称之为最优二叉编码树，简称最优编码树（optimal encoding tree）。

对于任一字符集 Σ ，深度不超过 $|\Sigma|$ 的编码树数目有限，故在其中 $ald()$ 值最小者必然存在。需注意的是，最优编码树不见得唯一（比如，同层节点互换位置后，并不影响全树的平均深度），但从工程的角度看，任取其中一棵即可。

为导出最优编码树的构造算法，以下需从更为深入地了解最优编码树的性质入手。

■ 双子性

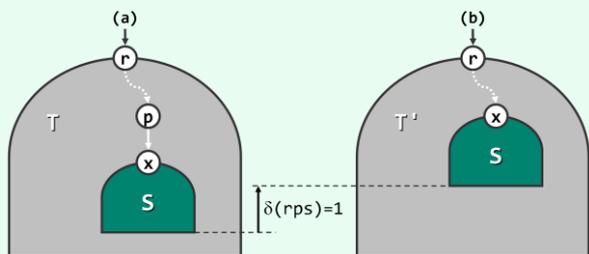


图5.30 最优编码树的双子性

首先，最优二叉编码树必为真二叉树：内部节点的左、右孩子全双（习题[5-2]）。

若不然，如图5.30(a)所示假设在某棵最优二叉编码树T中，内部节点p拥有唯一的孩子x。于是如图(b)，此时只需将节点p删除并代之以子树x，即可得到原字符集的另一棵编码树T'。

不难看出，除了子树x中所有叶节点的编码长度统一缩短1层之外，其余叶节点的编码长度不变，因此相对于T，T'的平均编码长度必然更短——这与T的最优性矛盾。

■ 层次性

最优编码树中，叶节点位置的选取有严格限制——其深度之差不得超过1。

为证明这一重要特性，可如图5.31(a)假设，某棵最优二叉编码树T含有深度之差不小于2的一对叶节点x和y。不失一般性设x更深，并令p为x的父亲。于是由双子性，作为内部节点的p必然还有另一孩子q。

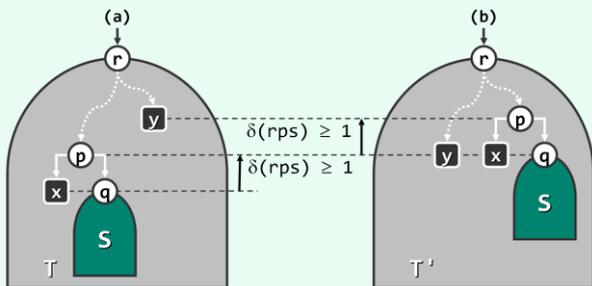


图5.31 最优编码树的层次性

如图(b)所示，令叶节点y与子树p互换位置，从而得到一棵新树T'。易见，T'依然是原字符集的一棵二叉编码树。更重要的是，就深度而言，除了x、y以及子树q中的叶节点外，其余叶节点均保持不变。其中，x的提升量与y的下降量相互抵消，而子树q中的叶节点都至少提升1层。因此相对于T，T'的平均编码长度必然更短——这与T的最优性矛盾。

以上的节点位置互换是一种十分重要的技巧，藉此可从任一编码树出发，不断提高编码效率，直至最优。以图5.32为例，对同一字符集 $\Sigma = \{ 'A', 'I', 'M', 'N' \}$ ，左、右两棵编码树的ald()值均为9/4，而经一次交换转换为居中的编码树后，ald()值均降至8/4。

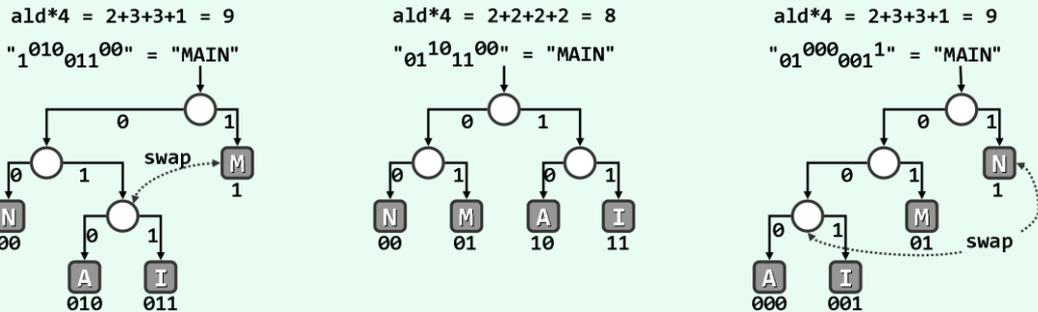


图5.32 通过节点交换提高编码效率完全二叉树与满二叉树

■ 最优编码树的构造

由上可知，最优编码树中的叶节点只能出现于最低两层，故这类树的一种特例就是真完全树。由此，可以直接导出如下构造最优编码树的算法：创建一棵规模为 $2|\Sigma| - 1$ 的完全二叉树T，再将 Σ 中的字符任意分配给T的 $|\Sigma|$ 个叶节点。

仍以字符集 $\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 为例，只需创建包含 $2 \times 5 - 1 = 9$ 个节点的一棵完全二叉树，并将各字符分配至5个叶节点，即得到一棵最优编码树。再适当交换同深度的节点，即可得到如116页图5.9(a)所示的编码树——由于此类节点交换并不改变平均编码长度，故它仍是一棵最优编码树。

5.5.3 Huffman编码树

■ 字符出现概率

以上最优编码树算法的实际应用价值并不大，除非 Σ 中各字符在文本串中出现的次数相等。遗憾的是，这一条件往往并不满足，甚至不确定。为此，需要从待编码的文本中取出若干样本，通过统计各字符在其中出现的次数（亦称作字符的频率），估计各字符实际出现的概率。

当然，每个字符x都应满足 $p(x) \geq 0$ ，且同一字符集 Σ 中的所有字符满足 $\sum_{x \in \Sigma} p(x) = 1$ 。

表5.5 在一篇典型的英文文章中，各字母出现的次数

字符	A	B	C	D	E	F	G	H	I	J	K	L	N	O	P	Q	R	S	T	U	V	W	X	Y	Z
次数	623	99	239	290	906	224	136	394	600	5	56	306	586	622	148	10	465	491	732	214	76	164	16	139	13

实际上，多数应用所涉及的字符集 Σ 中，各字符的出现频率不仅极少相等或相近，而且往往相差悬殊。如表5.5所示的英文字符集为例，'e'、't'等字符的出现频率通常是'z'、'j'等字符的数百倍。这种情况下，应该从另一角度更为准确地衡量平均编码长度。

■ 带权平均编码长度与叶节点带权平均深度

若考虑字符各自的出现频率，则可将带权平均编码长度取作编码树T的叶节点带权平均深度（weighted average leaf depth），亦即：

$$wald(T) = \sum_{x \in \Sigma} p(x) \cdot |rps(x)|$$

以字符集 $\Sigma = \{ 'A', 'I', 'M', 'N' \}$ 为例，若各字符出现的概率依次为 $2/6$ 、 $1/6$ 、 $2/6$ 和 $1/6$ （比如文本串"MAMANI"），则按照图5.33的编码方案，各字符对 $wald(T)$ 的贡献分别为：

$3 \times (2/6) = 1$ ； $2 \times (1/6) = 1/3$ ； $3 \times (2/6) = 1$ ； $1 \times (1/6) = 1/6$
相应地，这一编码方案对应的平均带权深度就是：

$$wald(T) = 1 + 1/3 + 1 + 1/6 = 2.5$$

若各字符出现的概率依次为 $3/8$ 、 $1/8$ 、 $4/8$ 和 $0/8$ （比如文本串"MAMMAMIA"），则有

$$wald(T) = 3 \times (3/8) + 2 \times (1/8) + 3 \times (4/8) + 1 \times (0/8) = 2.875$$

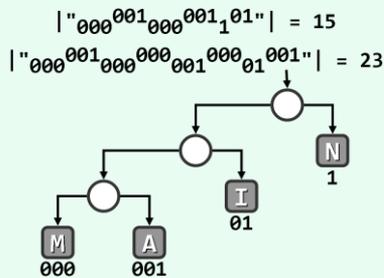


图5.33 考虑字符出现频率，以平均带权深度衡量编码效率

■ 完全二叉编码树 ≠ wald()最短

那么，wald()值能否进一步降低呢？仍然以Σ = { 'A', 'I', 'M', 'N' }为例。

我们首先想到的是前节提到的完全二叉编码树。如图5.34所示，由于此时各字符的编码长度都是2，故无论其出现概率具体分布如何，其对应的平均带权深度都将为2。



图5.34 若考虑出现频率，完全二叉树或满树未必最优 图5.35 若考虑出现频率，最优编码树往往不是完全二叉树

然而，在考虑各字符出现概率的不同之后，某些非完全二叉编码树的wald()值却可能更小。以图5.35的二叉编码树为例，当各字符频率与“MAMANI”相同时，wald(T) = 2，与图5.34方案相当；但当字符频率与“MAMMAMIA”相同时，wald(T) = 1.625，反而更优。

■ 最优带权编码树

若字符集Σ中各字符的出现频率分布为p()，则wald()值最小的编码方案称作Σ（按照p()分布的）的最优带权编码方案，对应的编码树称作最优带权编码树。当然，与不考虑字符出现概率同理，此时的最优带权编码树也必然存在（尽管通常并不唯一）。

为得出最优带权编码树的构造算法，以下还是从分析其性质入手。一方面不难验证，此时的最优编码树依然必须满足双子性。另一方面，尽管最优编码树不一定仍是完全的（比如在图5.35中，叶节点的深度可能相差2层以上），却依然满足某种意义上的层次性。

■ 层次性

具体地，若字符x和y的出现概率在所有字符中最低，则必然存在某棵最优带权编码树，使x和y在其中同处于最底层，且互为兄弟。为证明这一重要特性，如图5.36(a)所示任取一棵最优带权编码树T。根据双子性，必然可以在最低层找到一对兄弟节点a和b。不妨设它们不是x和y。

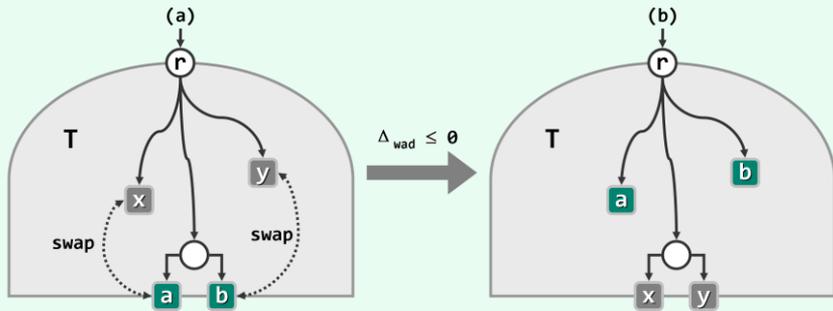


图5.36 最优编码树的层次性

现在，交换a和x，再交换b和y，从而得到该字符集的另一编码树T'，x和y成为其中最低层的一对兄弟。因字符x和y权重最小，故如此交换之后，wald(T')不致增加。

于是根据T的最优性，T'必然也是一棵最优编码树。

5.5.4 Huffman编码算法

■ 原理与构思

设字符 x 和 y 在 Σ 中的出现概率最低。考查另一字符集 $\Sigma' = (\Sigma \setminus \{x, y\}) \cup \{z\}$ ，其中新增字符 z 的出现概率取作被剔除字符 x 和 y 之和，即 $p(z) = p(x) + p(y)$ ，其余字符的概率不变。任取 Σ' 的一棵最优带权编码树 T' ，于是根据层次性，只需将 T' 中与字符 z 对应的叶节点替换为内部节点，并在其下引入分别对应于 x 和 y 的一对叶节点，即可得到 Σ 的一棵最优带权编码树。

仍以142页图5.35中字符集 $\Sigma = \{ 'A', 'I', 'N', 'M' \}$ 为例，设各字符出现的频率与编码串'MAMMAMIA'吻合，则不难验证，图5.37左侧即为 Σ 的一棵最优带权编码树 T 。

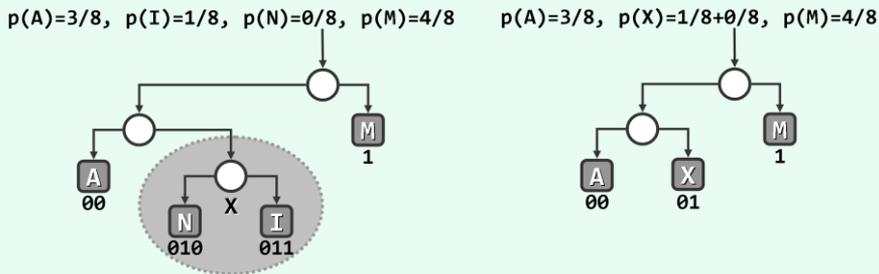


图5.37 最优编码树中底层兄弟节点合并后，依然是最优编码树

现在，将其中出现频率最低的' N '和' I '合并，代之以新字符' X '，且令' X '的出现频率为二者之和 $1/8 + 0/8 = 1/8$ 。若 T 中也做相应的调整之后，则可得图5.37右侧所示的编码树 T' 。不难验证， T' 是新字符集 $\Sigma' = \{ 'A', 'X', 'M' \}$ 的一棵最优带权编码树；反之，在 T' 中将' X '拆分为' N '和' I '后，亦是 Σ 的一棵最优带权编码树（习题[5-28]）。

■ 策略与算法

因此，对于字符出现概率已知的任一字符集 Σ ，都可采用如下算法构造其对应的最优带权编码树：首先，对应于 Σ 中的每一字符，分别建立一棵单个节点的树，其权重取作该字符的频率，这 $|\Sigma|$ 棵树构成一个森林 \mathcal{F} 。接下来，从 \mathcal{F} 中选出权重最小的两棵树，创建一个新节点，并分别以这两棵树作为其左、右子树，如此将它们合并为一棵更高的树，其权重取作二者权重之和。实际上，此后可以将合并后的新树等效地视作一个字符，称作超字符。

这一选取、合并的过程反复进行，每经过一轮迭代， \mathcal{F} 中的树就减少一棵。当最终 \mathcal{F} 仅包含一棵树时，它就是一棵最优带权编码树，构造过程随即完成。

以上构造过程称作Huffman编码算法^②，由其生成的编码树称作Huffman编码树（Huffman encoding tree）。需再次强调的是，Huffman编码树只是最优带权编码树中的一棵。

■ 实例

表5.6 由6个字符构成的字符集 Σ ，以及各字符的出现频率

字符	A	B	C	D	E	F
频率	623	99	239	290	906	224

^② 由David A. Huffman于1952年发明

考查表5.6所列由6个字符构成的字符集 Σ 。为构造与之相对应的一棵Huffman编码树，在初始化之后共需经过5步迭代，具体过程如图5.38(a~f)所示。

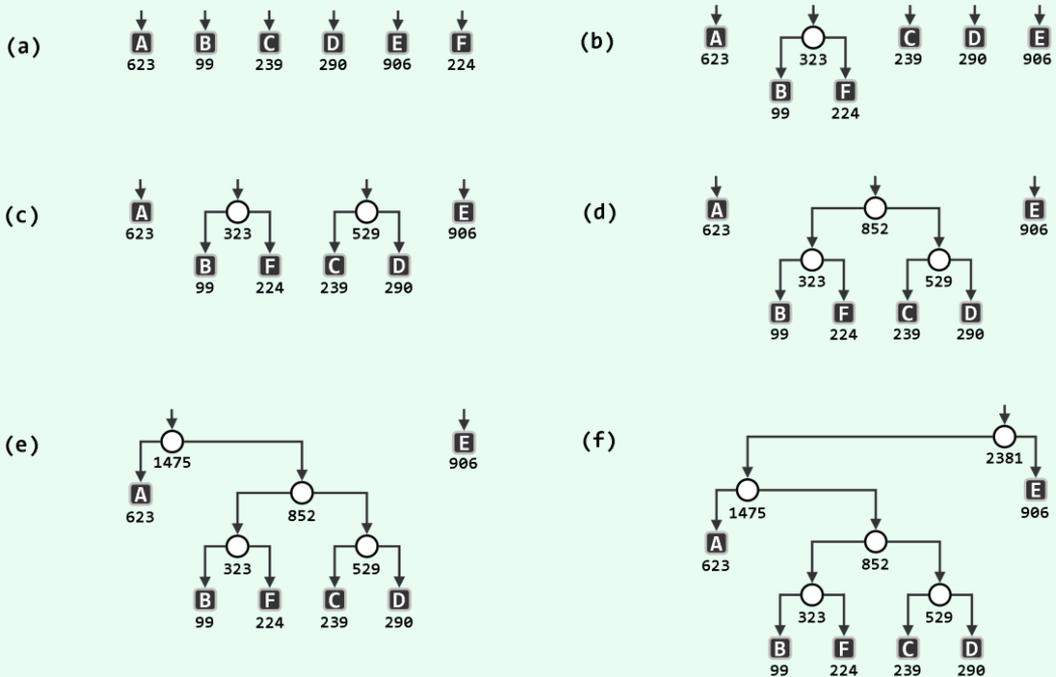


图5.38 Huffman树构造算法实例

请注意，以上构造过程不见得是确定的，在选取、合并子树时都可能出现歧义。幸运的是，这一问题不难解决（习题[5-29]）。

以下，我们分别介绍Huffman编码算法各个环节的具体实现。

■ 总体框架

以上编码和解码过程可描述为代码5.28，这也是同类编码、解码算法的统一测试入口。

```

1 /*****
2 * 无论编码森林由列表、完全堆还是左式堆实现，本测试过程都可适用
3 * 编码森林的实现方式采用优先级队列时，编译前对应的工程只需设置相应标志：
4 *   DSA_PQ_List、DSA_PQ_Comp1Heap或DSA_PQ_LeftHeap
5 *****/
6 int main(int argc, char* argv[]) { //Huffman编码算法统一测试
7     int* freq = statistics(argv[1]); //根据样本文件，统计各字符的出现频率
8     HuffForest* forest = initForest(freq); release(freq); //创建Huffman森林
9     HuffTree* tree = generateTree(forest); release(forest); //生成Huffman编码树
10    HuffTable* table = generateTable(tree); //将Huffman编码树转换为编码表
11    for (int i = 2; i < argc; i++) { //对于命令行传入的每一明文串
12        Bitmap* codeString = new Bitmap; //二进制编码串
13        int n = encode(table, codeString, argv[i]); //将根据编码表生成（长度为n）

```

```

14     decode(tree, codeString, n); //利用Huffman编码树,对长度为n的二进制编码串解码
15     release(codeString);
16 }
17 release(table); release(tree); return 0; //释放编码表、编码树
18 }

```

代码5.28 基于二叉树的Huffman编码

■ (超) 字符

如前所述,无论是输入的字符还是合并得到的超字符,在构造Huffman编码树过程中都可等效地加以处理——就其本质而言,相关信息无非就是对应的字符及其出现频率。

```

1 #define N_CHAR (0x80 - 0x20) //仅以可打印字符为例
2 struct HuffChar { //Huffman(超)字符
3     char ch; int weight; //字符、频率
4     HuffChar(char c = '^', int w = 0) : ch(c), weight(w) {};
5 // 比较器、判等器(各列其一,其余自行补充)
6     bool operator<(HuffChar const& hc) { return weight > hc.weight; } //此处故意大小颠倒
7     bool operator==(HuffChar const& hc) { return weight == hc.weight; }
8 };

```

代码5.29 HuffChar结构

因此如代码5.29所示,可相应地定义一个HuffChar类。对于经合并生成的超字符,这里统一用'^'表示,同时其权重weight设为被合并字符的权重之和。作为示例,这里字符集取ASCII字符集在[0x20, 0x80)区间内的子集,包含所有可打印字符。

另外,为便于超字符做权重的比较和判等,这里还重载了相关的操作符。

■ 数据结构的选取与设计

如代码5.30所示,可借助BinTree模板类定义Huffman编码树类型HuffTree。

```

1 #define HuffTree BinTree<HuffChar> //Huffman树,由BinTree派生,节点类型为HuffChar

```

代码5.30 Huffman编码树结构

如代码5.31所示,可借助List模板类定义Huffman森林类型HuffForest。

```

1 #include "../List/List.h" //用List实现
2 typedef List<HuffTree*> HuffForest; //Huffman森林

```

代码5.31 Huffman森林结构

如代码5.32所示,可借助位图类Bitmap(习题[2-34])定义Huffman二进制编码串类型HuffCode。

```

1 #include "../Bitmap/Bitmap.h" //基于Bitmap实现
2 typedef Bitmap HuffCode; //Huffman二进制编码

```

代码5.32 Huffman二进制编码串

作为PFC编码表的一种，Huffman编码表与代码5.22一样，自然可以由跳转表实现。作为对后面第9章中词典结构的统一测试，这里选择了与跳转表接口相同的散列表结构（9.3节），并基于该结构实现HuffTable类型。

```
1 #include "../Hashtable/Hashtable.h" //用HashTable实现
2 typedef Hashtable<char, char*> HuffTable; //Huffman编码表
```

代码5.33 Huffman编码表

如代码5.33所示，可以9.3节将要介绍的Hashtable结构来实现HuffTable。其中，词条的关键码key（即带编码的字符）为字符类型char，数值value（即字符对应的二进制编码串）为字符串类型char*。

■ 字符出现频率的样本统计

如代码5.34所示，这里通过对样例文本的统计，对各字符的出现频率做出估计。

```
1 int* statistics(char* sample_text_file) { //统计字符出现频率
2     int* freq = new int[N_CHAR]; //以下统计需随机访问，故以数组记录各字符出现次数
3     memset(freq, 0, sizeof(int) * N_CHAR); //清零
4     FILE* fp = fopen(sample_text_file, "r"); //assert: 文件存在且可正确打开
5     char ch;
6     while (0 < fscanf(fp, "%c", &ch)) //逐个扫描样本文件中的每个字符
7         if (ch >= 0x20) freq[ch - 0x20]++; //累计对应的出现次数
8     fclose(fp); return freq;
9 }
```

代码5.34 Huffman算法：字符出现频率的样本统计

为方便统计过程的随机访问，这里使用了数组freq。样例文件（假设存在且可正常打开）的路径作为函数参数传入。文件打开后顺序扫描，并累计各字符的出现次数。

■ 初始化Huffman森林

```
1 HuffForest* initForest(int* freq) { //根据频率统计表，为每个字符创建一棵树
2     HuffForest* forest = new HuffForest; //以List实现的Huffman森林
3     for (int i = 0; i < N_CHAR; i++) { //为每个字符
4         forest->insertAsLast(new HuffTree); //生成一棵树，并将字符及其频率
5         forest->last()->data->insertAsRoot(HuffChar(0x20 + i, freq[i])); //存入其中
6     }
7     return forest;
8 }
```

代码5.35 初始化Huffman森林

■ 构造Huffman编码树

```
1 HuffTree* minHChar(HuffForest* forest) { //在Huffman森林中找出权重最小的（超）字符
2     ListNodePosi(HuffTree*) p = forest->first(); //从首节点出发查找
3     ListNodePosi(HuffTree*) minChar = p; //最小Huffman树所在的节点位置
```

```

4   int minWeight = p->data->root()->data.weight; //目前的最小权重
5   while (forest->valid(p = p->succ)) //遍历所有节点
6       if (minWeight > p->data->root()->data.weight) //若当前节点所含树更小, 则
7           { minWeight = p->data->root()->data.weight; minChar = p; } //更新记录
8   return forest->remove(minChar); //将挑选出的Huffman树从森林中摘除, 并返回
9 }
10
11 HuffTree* generateTree(HuffForest* forest) { //Huffman编码算法
12     while (1 < forest->size()) {
13         HuffTree* T1 = minHChar(forest); HuffTree* T2 = minHChar(forest);
14         HuffTree* S = new HuffTree();
15         S->insertAsRoot(HuffChar('^', T1->root()->data.weight + T2->root()->data.weight));
16         S->attachAsLC(S->root(), T1); S->attachAsRC(S->root(), T2); forest->insertAsLast(S);
17     } //assert: 循环结束时, 森林中唯一(列表首节点中)的那棵树即Huffman编码树
18     return forest->first()->data;
19 }

```

代码5.36 构造Huffman编码树

根据以上的构思, `generateTree()`实现为一个循环迭代的过程。如代码5.36所示, 每一步迭代都通过调用`minHChar()`, 从当前的森林中找出权值最小的一对超字符, 将它们合并为一个更大的超字符, 并重新插入森林。每迭代一次, 森林的规模即减一, 故共需迭代 $n - 1$ 次, 直到只剩一棵树。`minHChar()`每次都要遍历森林中所有的超字符(树), 所需时间线性正比于当时森林的规模。因此总体运行时间应为:

$$O(n) + O(n - 1) + \dots + O(2) = O(n^2)$$

■ 生成Huffman编码表

```

1   static void //通过遍历获取各字符的编码
2   generateCT(Bitmap* code, int length, HuffTable* table, BinNodePosi(HuffChar) v) {
3       if (IsLeaf(*v)) //若是叶节点(还有多种方法可以判断)
4           { table->put(v->data.ch, code->bits2string(length)); return; }
5       if (HasLChild(*v)) //Left = 0
6           { code->clear(length); generateCT(code, length + 1, table, v->lChild); }
7       if (HasRChild(*v)) //Right = 1
8           { code->set(length); generateCT(code, length + 1, table, v->rChild); }
9   }
10
11 HuffTable* generateTable(HuffTree* tree) { //将各字符编码统一存入以散列表实现的编码表中
12     HuffTable* table = new HuffTable; Bitmap* code = new Bitmap;
13     generateCT(code, 0, table, tree->root());
14     release(code); return table;
15 };

```

代码5.37 生成Huffman编码表

■ 编码

```

1 int encode(HuffTable* table, Bitmap* codeString, char* s) { //按编码表对Bitmap串做Huffman编码
2     int n = 0; //待返回的编码串总长n
3     for (size_t m = strlen(s), i = 0; i < m; i++) { //对于明文中的每个字符
4         char** pCharCode = table->get(s[i]); //取出其对应的编码串
5         if (!pCharCode) pCharCode = table->get(s[i] + 'A' - 'a'); //小写字母转为大写
6         if (!pCharCode) pCharCode = table->get(' '); //无法识别的字符统一视作空格
7         printf("%s", *pCharCode); //输出当前字符的编码
8         for (size_t m = strlen(*pCharCode), j = 0; j < m; j++) //将当前字符的编码接入编码串
9             '1' ==>(*pCharCode + j) ? codeString->set(n++) : codeString->clear(n++);
10    }
11    printf("\n"); return n;
12 } //二进制编码串记录于位图codeString中

```

代码5.38 Huffman编码

■ 解码

```

1 void decode(HuffTree* tree, Bitmap* code, int n) { //根据编码树对长为n的Bitmap串做Huffman解码
2     BinNodePosi(HuffChar) x = tree->root();
3     for (int i = 0; i < n; i++) {
4         x = code->test(i) ? x->rChild : x->lChild;
5         if (IsLeaf(*x)) { printf("%c", x->data.ch); x = tree->root(); }
6     }
7 } //解出的明码，在此直接打印输出；实用中可改为根据需要返回上层调用者

```

代码5.39 Huffman解码

第6章



4.4节曾仿效古希腊英雄忒修斯，以栈等基本数据结构模拟线绳和粉笔，展示了试探回溯策略的应用技巧。实际上，这一技巧可进一步推广至更为一般性的场合，包括可以图结构描述的应用问题，从而导出一系列对应的图算法。

忒修斯取得成功的关键在于，借助线绳掌握迷宫内各通道之间的联接关系。在很多应用中，能否有效描述和利用这类信息，同样至关重要。一般地，这类信息往往可表述为定义于一组对象之间的二元关系，比如城市交通图中，联接于各公交站之间的街道，或者互联网中，联接于IP节点之间的路由，等等。尽管在某种程度上，第5章所介绍的树结构也可用以表示这种二元关系，但仅限于父、子节点之间。相互之间均可能存在二元关系的一组对象，从数据结构的角度的分类，属于非线性结构（non-linear structure）。此类一般性的二元关系，属于图论（Graph Theory）的研究范畴。从算法的角度对此类结构的处理策略，与上一章相仿，也是通过遍历将其转化为半线性结构，进而借助树结构已有的处理方法和技巧，最终解决问题。

以下首先简要介绍图的基本概念和术语，已有相关基础的读者可直接跳过。接下来，介绍如何实现作为抽象数据类型的图结构，主要讨论邻接矩阵和邻接表两种实现方式。然后，从遍历的角度介绍将图转化为树的典型方法，包括广度优先搜索和深度优先搜索。进而，分别以拓扑排序和双连通域分解为例，介绍利用基本数据结构并基于遍历模式，设计图算法的主要方法。最后，从“数据结构决定遍历次序”的观点出发，将所有遍历算法概括并统一为最佳优先遍历这一模式。如此，我们不仅能够更加准确和深刻地理解不同图算法之间的共性与联系，更可以学会通过选择和改进数据结构，高效地设计并实现各种图算法——这也是本章的重点与精髓。

§ 6.1 概述

■ 图

图结构是描述和解决实际应用问题的一种基本而有力的工具。所谓的图（graph），可定义为 $G = (V, E)$ 。其中，集合 V 中的元素称作顶点（vertex）；集合 E 中的元素分别对应于 V 中的某一对顶点 (u, v) ，表示它们之间存在某种关系，故亦称作边（edge）^①。一种直观显示图结构的方法是，用小圆圈或小方块代表顶点，用联接于其间的直线段或曲线弧表示对应的边。

从计算的需求出发，我们约定 V 和 E 均为有限集，通常将其规模分别记 $n = |V|$ 和 $e = |E|$ 。

■ 无向图、有向图及混合图

若边 (u, v) 所对应顶点 u 和 v 的次序无所谓，则称作无向边（undirected edge），例如表示同学关系的边。反之若 u 和 v 不对等，则称 (u, v) 为有向边（directed edge），例如描述企业与银行之间的借贷关系，或者程序之间的相互调用关系的边。

^① 在某些文献中，顶点也称作节点（node），边亦称作弧（arc），本章则统一称作顶点和边。

如此，无向边 (u, v) 也可记作 (v, u) ，而有向的 (u, v) 和 (v, u) 则不可混淆。这里约定，有向边 (u, v) 从 u 指向 v ，其中 u 称作该边的起点（origin）或尾顶点（tail），而 v 称作该边的终点（destination）或头顶点（head）。

若 E 中各边均无方向，则 G 称作无向图（undirected graph，简称undigraph）。例如在描述影视演员相互合作关系的图 G 中，若演员 u 和 v 若曾经共同出演过至少一部影片，则在他（她）们之间引入一条边 (u, v) 。反之，若 E 中只含有向边，则 G 称作有向图（directed graph，简称digraph）。例如在C++类的派生关系图中，从顶点 u 指向顶点 v 的有向边，意味着类 u 派生自类 v 。特别地，若 E 同时包含无向边和有向边，则 G 称作混合图（mixed graph）。例如在北京市内交通图中，有些道路是双行的，另一些是单行的，对应地可分别描述为无向边和有向边。

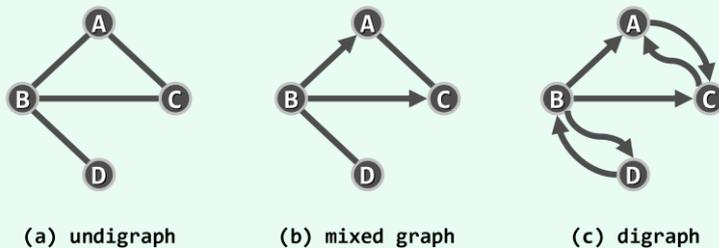


图6.1 (a)无向图、(b)混合图和(c)有向图

相对而言，有向图的通用性更强，因为无向图和混合图都可转化为有向图——如图6.1所示，每条无向边 (u, v) 都可等效地替换为对称的一对有向边 (u, v) 和 (v, u) 。因此，本章将主要针对有向图，介绍图结构及其算法的具体实现。

度

对于任何边 $e = (u, v)$ ，称顶点 u 和 v 彼此邻接（adjacent），互为邻居；而它们都与边 e 彼此关联（incident）。在无向图中，与顶点 v 关联的边数，称作 v 的度数（degree），记作 $\text{deg}(v)$ 。以图6.1(a)为例，顶点 $\{A, B, C, D\}$ 的度数为 $\{2, 3, 2, 1\}$ 。

对于有向边 $e = (u, v)$ ， e 称作 u 的出边（outgoing edge）、 v 的入边（incoming edge）。 v 的出边总数称作其出度（out-degree），记作 $\text{outdeg}(v)$ ；入边总数称作其入度（in-degree），记作 $\text{indeg}(v)$ 。在图6.1(c)中，各顶点的出度为 $\{1, 3, 1, 1\}$ ，入度为 $\{2, 1, 2, 1\}$ 。

简单图

联接于同一顶点之间的边，称作自环（self-loop）。在某些特定的应用中，这类边可能的确具有意义——比如在城市交通图中，沿着某条街道，有可能不需经过任何交叉路口即可直接返回原处。不含任何自环的图称作简单图（simple graph），也是本书主要讨论的对象。

通路与环路

所谓路径或通路（path），就是由 $m + 1$ 个顶点与 m 条边交替而成的一个序列：

$$\pi = \{ v_0, e_1, v_1, e_2, v_2, \dots, e_m, v_m \}$$

且对任何 $0 < i \leq m$ 都有 $e_i = (v_{i-1}, v_i)$ 。也就是说，这些边依次地首尾相联。其中沿途的总数 m ，亦称作通路的长度，记作 $|\pi| = m$ 。

为简化描述，也可依次给出通路沿途的各个顶点，而省略联接于其间的边，即表示为：

$$\pi = \{ v_0, v_1, v_2, \dots, v_m \}$$

图6.2(a)中的{ C, A, B, A, D }, 即是从顶点C到D的一条通路, 其长度为4。可见, 尽管通路上的边必须互异, 但顶点却可能重复。沿途顶点互异的通路, 称作简单通路 (simple path)。在图6.2(b)中, { C, A, D, B }即是从顶点C到B的一条简单通路, 其长度为3。

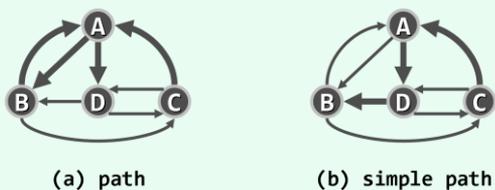


图6.2 通路与简单通路

特别地, 对于长度 $m \geq 1$ 的通路 π , 若起止顶点相同 (即 $v_0 = v_m$), 则称作环路 (cycle), 其长度也取作沿途边的总数。图6.3(a)中, { C, A, B, A, D, B, C }即是一条环路, 其长度为6。反之, 不含任何环路的有向图, 称作有向无环图 (directed acyclic graph, DAG)。

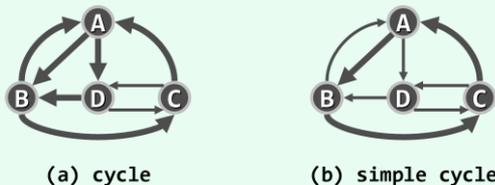


图6.3 环路与简单环路

同样, 尽管环路上的各边必须互异, 但顶点却也可能重复。反之若沿途除 $v_0 = v_m$ 外所有顶点均互异, 则称作简单环路 (simple cycle)。例如, 图6.3(b)中的{ C, A, B, C }即是一条简单环路, 其长度为3。特别地, 经过图中各边一次且恰好一次的环路, 称作欧拉环路 (Eulerian tour) ——当然, 其长度也恰好等于图中边的总数 e 。

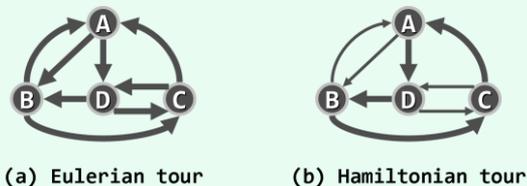


图6.4 欧拉环路与哈密顿环路

图6.4(a)中的{ C, A, B, A, D, C, D, B, C }即是一条欧拉环路, 其长度为8。对偶地, 经过图中各顶点一次且恰好一次的环路, 称作哈密顿环路 (Hamiltonian tour), 其长度亦等于构成环路的边数。图6.4(b)中, { C, A, D, B, C }即是一条长度为4的哈密顿环路。

■ 带权网络

图不仅需要表示顶点之间是否存在某种关系, 有时还需要表示这一关系的具体细节。以铁路运输为例, 可以用顶点表示城市, 用顶点之间的联边, 表示对应的城市之间是否有客运铁路联接; 同时, 往往还需要记录各段铁路的长度、承运能力, 以及运输成本等信息。

为适应这类应用要求, 需通过一个权值函数, 为每一边 e 指定一个权重 (weight), 比如 $w_t(e)$ 即为边 e 的权重。各边均带有权重的图, 称作带权图 (weighted graph) 或带权网络 (weighted network), 有时也简称网络 (network), 记作 $G(V, E, wt())$ 。

■ 复杂度

与其它算法一样, 图算法也需要就时间性能和空间性能, 进行分析和比较。相应地, 问题的输入规模, 也应该以顶点数与边数的总和 ($n + e$) 来度量。不难看出, 无论顶点多少, 边数都有可能为 0 。那么反过来, 在包含 n 个顶点的图中, 至多可能包含多少条边呢?

对于无向图, 每一对顶点至多贡献一条边, 故总共不超过 $n(n - 1)/2$ 条边, 且这个上界由完全图达到。对于有向图, 每一对顶点都可能贡献 (互逆的) 两条边, 因此至多可有 $n(n - 1)$ 条边。总而言之, 必有 $e = o(n^2)$ 。

§ 6.2 抽象数据类型

6.2.1 操作接口

作为抽象数据类型，图支持的操作接口分为边和顶点两类，分列于表6.1和表6.2。

表6.1 图ADT支持的边操作接口

操作接口	功能描述
e()	边总数 E
exist(v, u)	判断联边(v, u)是否存在
insert(v, u)	引入从顶点v到u的联边
remove(v, u)	删除从顶点v到u的联边
status(v, u)	边(v, u)的状态
edge(v, u)	边(v, u)对应的数据域
weight(v, u)	边(v, u)的权重

表6.2 图ADT支持的顶点操作接口

操作接口	功能描述
n()	顶点总数 V
insert(v)	在顶点集V中插入新顶点v
remove(v)	将顶点v从顶点集中删除
inDegree(v) outDegree(v)	顶点v的入度、出度
firstNbr(v)	顶点v的首个邻接顶点
nextNbr(v, u)	在v的邻接顶点中，u的后继
status(v)	顶点v的状态
dTime(v)、fTime(v)	顶点v的时间标签
parent(v)	顶点v在遍历树中的父节点
priority(v)	顶点v在遍历树中的权重

6.2.2 Graph模板类

代码6.1以抽象模板类的形式，给出了图ADT的具体定义。

```

1 typedef enum { UNDISCOVERED, DISCOVERED, VISITED } VStatus; //顶点状态
2 typedef enum { UNDETERMINED, TREE, CROSS, FORWARD, BACKWARD } EStatus; //边状态
3
4 template <typename Tv, typename Te> //顶点类型、边类型
5 class Graph { //图Graph模板类
6 private:
7     void reset() { //所有顶点、边的辅助信息复位
8         for (int i = 0; i < n; i++) { //所有顶点的
9             status(i) = UNDISCOVERED; dTime(i) = fTime(i) = -1; //状态, 时间标签
10            parent(i) = -1; priority(i) = INT_MAX; // (在遍历树中的) 父节点, 优先级数
11            for (int j = 0; j < n; j++) //所有边的
12                if (exists(i, j)) status(i, j) = UNDETERMINED; //状态
13        }
14    }
15    void BFS(int, int&); // (连通域) 广度优先搜索算法
16    void DFS(int, int&); // (连通域) 深度优先搜索算法
17    void BCC(int, int&, Stack<int>&); // (连通域) 基于DFS的双连通分量分解算法
18    bool TSort(int, int&, Stack<Tv>*&); // (连通域) 基于DFS的拓扑排序算法
19    template <typename PU> void PFS(int, PU); // (连通域) 优先级搜索框架

```

```

20 public:
21 // 顶点
22     int n; //顶点总数
23     virtual int insert(Tv const&) = 0; //插入顶点, 返回编号
24     virtual Tv remove(int) = 0; //删除顶点及其关联边, 返回该顶点信息
25     virtual Tv& vertex(int) = 0; //顶点v的数据 (该顶点的确存在)
26     virtual int inDegree(int) = 0; //顶点v的入度 (该顶点的确存在)
27     virtual int outDegree(int) = 0; //顶点v的出度 (该顶点的确存在)
28     virtual int firstNbr(int) = 0; //顶点v的首个邻接顶点
29     virtual int nextNbr(int, int) = 0; //顶点v的 (相对于顶点j的) 下一邻接顶点
30     virtual VStatus& status(int) = 0; //顶点v的状态
31     virtual int& dTime(int) = 0; //顶点v的时间标签dTime
32     virtual int& fTime(int) = 0; //顶点v的时间标签fTime
33     virtual int& parent(int) = 0; //顶点v在遍历树中的父亲
34     virtual int& priority(int) = 0; //顶点v在遍历树中的优先级数
35 // 边: 这里约定, 无向边均统一转化为方向互逆的一对有向边, 从而将无向图视作有向图的特例
36     int e; //边总数
37     virtual bool exists(int, int) = 0; //边(v, u)是否存在
38     virtual void insert(Te const&, int, int, int) = 0; //在顶点v和u之间插入权重为w的边e
39     virtual Te remove(int, int) = 0; //删除顶点v和u之间的边e, 返回该边信息
40     virtual EStatus& status(int, int) = 0; //边(v, u)的状态
41     virtual Te& edge(int, int) = 0; //边(v, u)的数据 (该边的确存在)
42     virtual int& weight(int, int) = 0; //边(v, u)的权重
43 // 算法
44     void bfs(int); //广度优先搜索算法
45     void dfs(int); //深度优先搜索算法
46     void bcc(int); //基于DFS的双连通分量分解算法
47     Stack<Tv>* tSort(int); //基于DFS的拓扑排序算法
48     void prim(int); //最小支撑树Prim算法
49     void dijkstra(int); //最短路径Dijkstra算法
50     template <typename PU> void pfs(int, PU); //优先级搜索框架
51 };

```

代码6.1 图ADT操作接口

仍为简化起见, 这里直接开放了变量n和e。除以上所列的操作接口, 这里还明确定义了顶点和边可能处于的若干状态, 并通过内部接口reset()复位顶点和边的状态。

图的部分基本算法在此也以操作接口的形式供外部用户直接使用, 比如广度优先搜索、深度优先搜索、双连通分量分解、最小支撑树、最短路径等。为求解更多的具体应用问题, 读者可照此模式, 独立地补充相应的算法。

就功能而言, 这些算法均超脱于图结构的具体实现方式, 借助统一的顶点和边ADT操作接口直接编写。尽管如此, 正如下即将看到的, 图算法的时间、空间性能, 却与图结构的具体实现方式紧密相关, 在这方面的理解深度, 也将反映和决定我们对图结构的驾驭与运用能力。

§ 6.3 邻接矩阵

6.3.1 原理

邻接矩阵 (adjacency matrix) 是图ADT最基本的实现方式, 使用方阵 $A[n][n]$ 表示由 n 个顶点构成的图, 其中每个单元, 各自负责描述一对顶点之间可能存在的邻接关系, 故此得名。

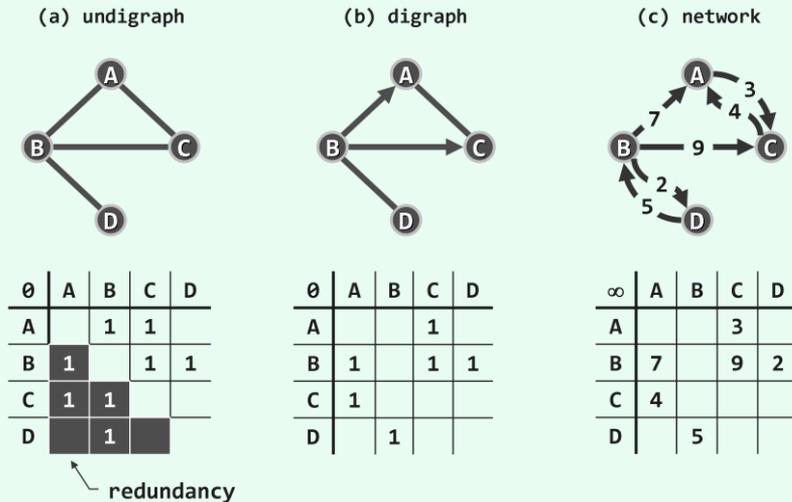


图6.5 邻接矩阵 (空白单元对应的边不存在, 其统一取值标注于矩阵左上角)

对于无权图, 存在 (不存在) 从顶点 u 到 v 的边, 当且仅当 $A[u][v] = 1$ (\emptyset)。图6.5(a)和(b)即为无向图和有向图的邻接矩阵实例。

这一表示方式, 不难推广至带权网络。此时如图(c)所示, 矩阵各单元可从布尔型改为整型或浮点型, 记录所对应边的权重。对于不存在的边, 通常统一取值为 ∞ 或 \emptyset 。

6.3.2 实现

基于以上原理与构思实现的图结构如代码6.2所示。

```

1 #include "../Vector/Vector.h" //引入向量
2 #include "../Graph/Graph.h" //引入图ADT
3
4 template <typename Tv> struct Vertex { //顶点对象 (为简化起见, 并未严格封装)
5     Tv data; int inDegree, outDegree; VStatus status; //数据、出入度数、状态
6     int dTime, fTime; //时间标签
7     int parent; int priority; //在遍历树中的父节点、优先级数
8     Vertex(Tv const& d = (Tv) 0) : //构造新顶点
9         data(d), inDegree(0), outDegree(0), status(UNDISCOVERED),
10        dTime(-1), fTime(-1), parent(-1), priority(INT_MAX) {} //暂不考虑权重溢出
11 };
12
13 template <typename Te> struct Edge { //边对象 (为简化起见, 并未严格封装)
14     Te data; int weight; EStatus status; //数据、权重、状态
15     Edge(Te const& d, int w) : data(d), weight(w), status(UNDETERMINED) {} //构造新边
16 };
17

```

```

18 template <typename Tv, typename Te> //顶点类型、边类型
19 class GraphMatrix : public Graph<Tv, Te> { //基于向量, 以邻接矩阵形式实现的图
20 private:
21     Vector<Vertex<Tv>> V; //顶点集(向量)
22     Vector<Vector<Edge<Te>*>> E; //边集(邻接矩阵)
23 public:
24     GraphMatrix() { n = e = 0; } //构造
25     ~GraphMatrix() { //析构
26         for (int j = 0; j < n; j++) //所有动态创建的
27             for (int k = 0; k < n; k++) //边记录
28                 delete E[j][k]; //逐条清除
29     }
30 // 顶点的基本操作: 查询第i个顶点 (0 <= i < n)
31     virtual Tv& vertex(int i) { return V[i].data; } //数据
32     virtual int inDegree(int i) { return V[i].inDegree; } //入度
33     virtual int outDegree(int i) { return V[i].outDegree; } //出度
34     virtual int firstNbr(int i) { return nextNbr(i, n); } //首个邻接顶点
35     virtual int nextNbr(int i, int j) //相对于顶点j的下一邻接顶点
36     { while ((-1 < j) && (!exists(i, --j))); return j; } //逆向线性试探(改用邻接表可提高效率)
37     virtual VStatus& status(int i) { return V[i].status; } //状态
38     virtual int& dTime(int i) { return V[i].dTime; } //时间标签dTime
39     virtual int& fTime(int i) { return V[i].fTime; } //时间标签fTime
40     virtual int& parent(int i) { return V[i].parent; } //在遍历树中的父亲
41     virtual int& priority(int i) { return V[i].priority; } //在遍历树中的优先级数
42 // 顶点的动态操作
43     virtual int insert(Tv const& vertex) { //插入顶点, 返回编号
44         for (int j = 0; j < n; j++) E[j].insert(NULL); n++; //各顶点预留一条潜在的关联边
45         E.insert(Vector<Edge<Te>*>(n, n, (Edge<Te>*) NULL)); //创建新顶点对应的边向量
46         return V.insert(Vertex<Tv>(vertex)); //顶点向量增加一个顶点
47     }
48     virtual Tv remove(int i) { //删除第i个顶点及其关联边 (0 <= i < n)
49         for (int j = 0; j < n; j++) //所有出边
50             if (exists(i, j)) { delete E[i][j]; V[j].inDegree--; } //逐条删除
51         E.remove(i); n--; //删除第i行
52         for (int j = 0; j < n; j++) //所有出边
53             if (exists(j, i)) { delete E[j].remove(i); V[j].outDegree--; } //逐条删除
54         Tv vBak = vertex(i); V.remove(i); //删除顶点i
55         return vBak; //返回被删除顶点的信息
56     }
57 // 边的确认操作
58     virtual bool exists(int i, int j) //边(i, j)是否存在
59     { return (0 <= i) && (i < n) && (0 <= j) && (j < n) && E[i][j] != NULL; }
60 // 边的基本操作: 查询顶点i与j之间的联边 (0 <= i, j < n且exists(i, j))

```

```

61  virtual EStatus& status(int i, int j) { return E[i][j]->status; } //边(i, j)的状态
62  virtual Te& edge(int i, int j) { return E[i][j]->data; } //边(i, j)的数据
63  virtual int& weight(int i, int j) { return E[i][j]->weight; } //边(i, j)的权重
64  // 边的动态操作
65  virtual void insert(Te const& edge, int w, int i, int j) { //插入权重为w的边e = (i, j)
66      if (exists(i, j)) return; //确保该边尚不存在
67      E[i][j] = new Edge<Te>(edge, w); //创建新边
68      e++; V[i].outDegree++; V[j].inDegree++; //更新边计数与关联顶点的度数
69  }
70  virtual Te remove(int i, int j) { //删除顶点i和j之间的联边(exists(i, j))
71      Te eBak = edge(i, j); delete E[i][j]; E[i][j] = NULL; //备份后删除边记录
72      e--; V[i].outDegree--; V[j].inDegree--; //更新边计数与关联顶点的度数
73      return eBak; //返回被删除边的信息
74  }
75 };

```

代码6.2 基于邻接矩阵实现的图结构

可见，这里利用第2章实现并封装的**Vector**结构，在内部将所有顶点组织为一个向量**V[]**；同时通过嵌套定义，将所有（潜在的）边组织为一个二维向量**E[][]**——亦即邻接矩阵。

每个顶点统一表示为**Vertex**对象，每条边统一表示为**Edge**对象。

边对象的属性**weight**统一简化为整型，既可用于表示无权图，亦可表示带权网络。

6.3.3 时间性能

按照代码6.2的实现方式，各顶点的编号可直接转换为其在邻接矩阵中对应的秩，从而使得图ADT中所有的静态操作接口，均只需 $O(1)$ 时间——这主要是得益于向量“循秩访问”的特长与优势。另外，边的静态和动态操作也仅需 $O(1)$ 时间——其代价是邻接矩阵的空间冗余。

然而，这种方法并非完美无缺。其不足主要体现在，顶点的动态操作接口均十分耗时。为了插入新的顶点，顶点集向量**V[]**需要添加一个元素；边集向量**E[][]**也需要增加一行，且每行都需要添加一个元素。顶点删除操作，亦与此类似。不难看出，这些恰恰也是向量结构固有的不足。

好在通常的算法中，顶点的动态操作远少于其它操作。而且，即便计入向量扩容的代价，就分摊意义而言，单次操作的耗时亦不过 $O(n)$ （习题[6-2]）。

6.3.4 空间性能

上述实现方式所用空间，主要消耗于邻接矩阵，亦即其中的二维边集向量**E[][]**。每个**Edge**对象虽需记录多项信息，但总体不过常数。根据2.4.4节的分析结论，**Vector**结构的装填因子始终不低于50%，故空间总量渐进地不超过 $O(n \times n) = O(n^2)$ 。

当然，对于无向图而言，仍有改进的余地。如图6.5(a)所示，无向图的邻接矩阵必为对称阵，其中除自环以外的每条边，都被重复地存放了两次。也就是说，近一半的单元都是冗余的。为消除这一缺点，可采用压缩存储等技巧，进一步提高空间利用率（习题[6-4]）。

§ 6.4 邻接表

6.4.1 原理

即便就有向图而言， $\Theta(n^2)$ 的空间亦有改进的余地。实际上，如此大的空间足以容纳所有潜在的边。然而实际应用所处理的图，所含的边通常远远少于 $\Theta(n^2)$ 。比如在平面图之类的稀疏图（sparse graph）中，边数渐进地不超过 $\Theta(n)$ ，仅与顶点总数大致相当（习题[6-3]）。

由此可见，邻接矩阵的空间效率之所以低，是因为其中大量单元所对应的边，通常并未在图中出现。因静态空间管理策略导致的此类问题，并非首次出现，比如此前的2.4节，就曾指出这类缺陷并试图改进。既然如此，为何不仿照3.1节的思路，将这里的向量替换为列表呢？

是的，按照这一思路，的确可以导出图结构的另一种表示与实现形式。

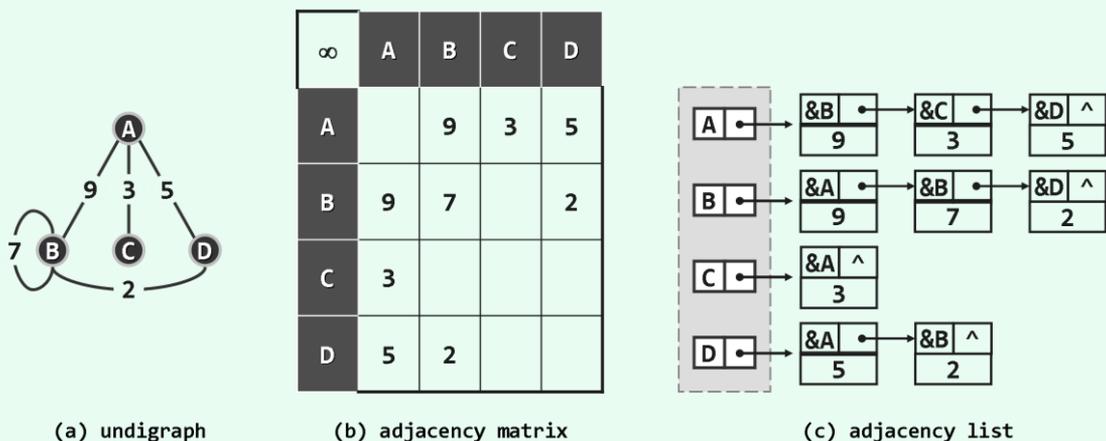


图6.6 以邻接表方式描述和实现图

以如图6.6(a)所示的无向图为例，只需将如图(b)所示的邻接矩阵，逐行地转换为如图(c)所示的一组列表，即可分别记录各顶点的关联边（或等价地，邻接顶点）。这些列表，也因此称作邻接表（adjacency list）。实际上，这种通用方法不难推广至有向图（习题[6-5]）。

6.4.2 复杂度

可见，邻接表所含列表数等于顶点总数 n ，每条边在其中仅存放一次（有向图）或两次（无向图），故空间总量为 $\Theta(n + e)$ ，与图自身的规模相当，较之邻接矩阵有很大改进。

当然，空间性能的这一改进，需以某些方面时间性能的降低为代价。比如，为判断顶点 v 到 u 的联边是否存在， $\text{exists}(v, u)$ 需在 v 对应的邻接表中顺序查找，共需 $\Theta(n)$ 时间。

与顶点相关操作接口，时间性能依然保持，甚至有所提高。比如，顶点的插入操作，可在 $\Theta(1)$ 而不是 $\Theta(n)$ 时间内完成。当然，顶点的删除操作，仍需遍历所有邻接表，共需 $\Theta(e)$ 时间。

尽管邻接表访问单条边的效率并不算高，却十分擅长于以批量方式，处理同一顶点的所有关联边。在以下图遍历等算法中，这是典型的处理流程和模式。比如，为枚举从顶点 v 发出的所有边，现在仅需 $\Theta(1 + \text{outDegree}(v))$ 而非 $\Theta(n)$ 时间。故总体而言，邻接表的效率较之邻接矩阵更高。因此，本章对以下各算法的复杂度分析，多以基于邻接表的实现方式为准。

§ 6.5 图遍历算法概述

图算法是个庞大的家族，其中大部分成员的主体框架，都可归结于图的遍历。与5.4节中树的遍历类似，图的遍历也需要访问所有顶点一次且仅一次；此外，图遍历同时还需要访问所有的边一次且仅一次——尽管对树而言这显而易见——并对边做分类，以便后续的处理。

实际上，无论采用何种策略和算法，图的遍历都可理解为，将非线性结构转化为半线性结构的过程。经遍历而确定的边类型中，最重要的一类即所谓的树边，它们与所有顶点共同构成了原图的一棵支撑树（森林），称作遍历树（traversal tree）。以遍历树为背景，其余各种类型的边，也能提供关于原图的重要信息，比如其中所含的环路等。

图中顶点之间可能存在多条通路，故为避免对顶点的重复访问，在遍历的过程中，通常还要动态地设置各顶点不同的状态，并随着遍历的进程不断地转换状态，直至最后的“访问完毕”。图的遍历更加强调对处于特定状态顶点的甄别与查找，故也称作图搜索（graph search）。

与树遍历一样，作为图算法基石的图搜索，本身也必须能够高效地实现。幸运的是，正如我们马上就会看到的，诸如深度优先、广度优先、最佳优先等基本而典型的图搜索，都可以在线性时间内完成。准确地，若顶点数和边数分别为 n 和 e ，则这些算法自身仅需 $O(n + e)$ 时间。既然图搜索需要访问所有的顶点和边，故这已经是我们所能期望的最优的结果。

§ 6.6 广度优先搜索

6.6.1 策略

各种图搜索之间的区别，体现为边分类结果的不同，以及所得遍历树（森林）的结构差异。其决定因素在于，搜索过程中的每一步迭代，将依照何种策略来选取下一接受访问的顶点。

通常，都是选取某个已访问到的顶点的邻居。同一顶点所有邻居之间的优先级，在多数遍历中不必讲究。因此，实质的差异应体现在，当有多个顶点已被访问到，应该优先从谁的邻居中选取下一顶点。比如，广度优先搜索（breadth-first search, BFS）采用的策略，可概括为：

越早被访问到的顶点，其邻居越优先被选用

于是，始自图中顶点 s 的BFS搜索，将首先访问顶点 s ；再依次访问 s 所有尚未访问到的邻居；再按后者被访问的先后次序，逐个访问它们的邻居；...；如此不断。在所有已访问到的顶点中，仍有邻居尚未访问者，构成所谓的波峰集（frontier）。于是，BFS搜索过程也可等效地理解为：

反复从波峰集中找到最早被访问到顶点 v ，若其邻居均已访问到，则将其逐出波峰集；否则，随意选出一个尚未访问到的邻居，并将其加入到波峰集中

不难发现，若将上述BFS策略应用于树结构，则效果等同于层次遍历（5.4.5节）——波峰集内顶点的深度始终相差不超过一，且波峰集总是优先在更浅的层次沿广度方向拓展。实际上，树层次遍历的这些特性，在一定程度上也适用于图的BFS搜索（习题[6-7]）。

由于每一步迭代都有一个顶点被访问，故至多迭代 $O(n)$ 步。另一方面，因为不会遗漏每个刚被访问顶点的任何邻居，故对于无向图必能覆盖 s 所属的连通分量（connected component），对于有向图必能覆盖以 s 为起点的可达分量（reachable component）。倘若还有来自其它连通分量或可达分量的顶点，则不妨从该顶点出发，重复上述过程。

6.6.2 实现

图的广度优先搜索算法，可实现如代码6.3所示。

```

1  template <typename Tv, typename Te> //广度优先搜索BFS算法 ( 全图 )
2  void Graph<Tv, Te>::bfs(int s) { //assert: 0 <= s < n
3      reset(); int clock = 0; int v = s; //初始化
4      do //逐一检查所有顶点
5          if (UNDISCOVERED == status(v)) //一旦遇到尚未发现的顶点
6              BFS(v, clock); //即从该顶点出发启动一次BFS
7      while (s != (v = (++v % n))); //按序号检查, 故不漏不重
8  }
9
10 template <typename Tv, typename Te> //广度优先搜索BFS算法 ( 单个连通域 )
11 void Graph<Tv, Te>::BFS(int v, int& clock) { //assert: 0 <= v < n
12     Queue<int> Q; //引入辅助队列
13     status(v) = DISCOVERED; Q.enqueue(v); //初始化起点
14     while (!Q.empty()) { //在Q变空之前, 不断
15         int v = Q.dequeue(); dTime(v) = ++clock; //取出队首顶点v
16         for (int u = firstNbr(v); -1 < u; u = nextNbr(v, u)) //枚举v的所有邻居u
17             if (UNDISCOVERED == status(u)) { //若u尚未被发现, 则
18                 status(u) = DISCOVERED; Q.enqueue(u); //发现该顶点
19                 status(v, u) = TREE; parent(u) = v; //引入树边拓展支撑树
20             } else { //若u已被发现, 或者甚至已访问完毕, 则
21                 status(v, u) = CROSS; //将(v, u)归类于跨边
22             }
23         status(v) = VISITED; //至此, 当前顶点访问完毕
24     }
25 }

```

代码6.3 BFS算法

算法的实质功能，由子算法BFS()完成。对该函数的反复调用，即可遍历所有连通或可达域。仿照树的层次遍历，这里也借助队列Q，来保存已被发现，但尚未访问完毕的顶点。因此，任何顶点在进入该队列的同时，都被随即标记为DISCOVERED（已发现）状态。

BFS()的每一步迭代，都先从Q中取出当前的首顶点v；再逐一核对其各邻居u的状态并做相应处理；最后将顶点v置为VISITED（访问完毕）状态，即可进入下一步迭代。

若顶点u尚处于UNDISCOVERED（未发现）状态，则令其转为DISCOVERED状态，并随即加入队列Q。实际上，每次发现一个这样的顶点u，都意味着遍历树可从v到u拓展一条边。于是，将边(v, u)标记为树边（tree edge），并按照遍历树中的承袭关系，将v记作u的父节点。

若顶点u已处于DISCOVERED状态（无向图），或者甚至处于VISITED状态（有向图），则意味着边(v, u)不属于遍历树，于是将该边归类为跨边（cross edge）（习题[6-11]）。

BFS()遍历结束后，所有访问过的顶点通过parent[]指针依次联接，从整体上给出了原图某一连通或可达域的一棵遍历树，称作广度优先搜索树，或简称BFS树（BFS tree）。

6.6.3 实例

图6.7给出了一个含8个顶点和11条边的有向图，起始于顶点S的BFS搜索过程。请留意观察辅助队列（下方）的演变，顶点状态的变化，边的分类与结果，以及BFS树的生长过程。

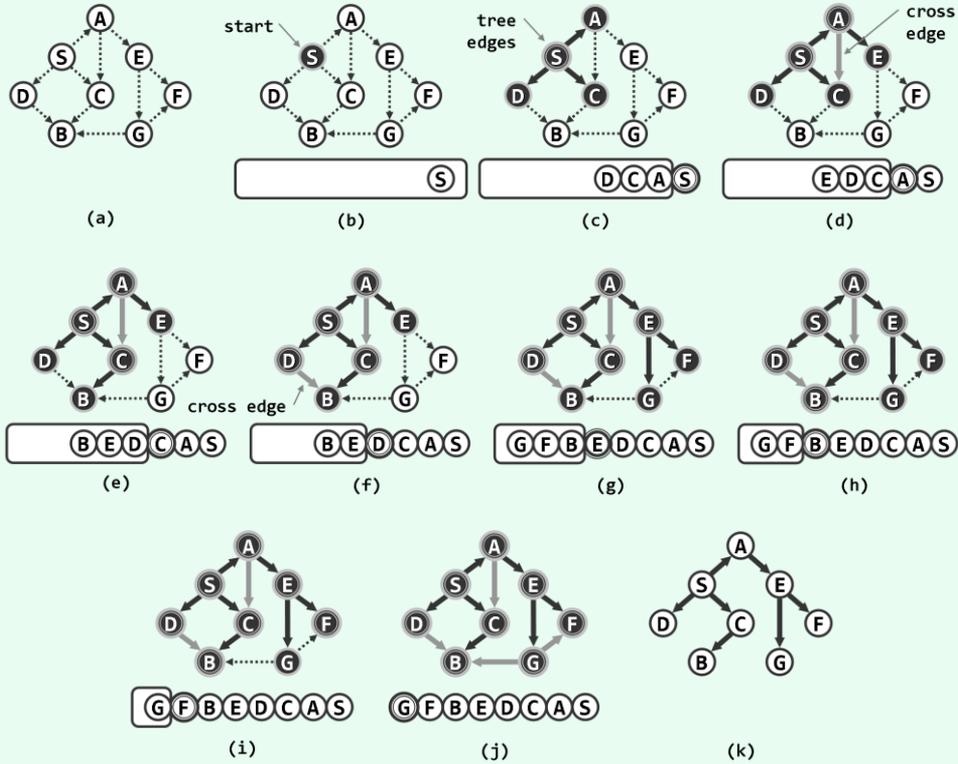


图6.7 广度优先搜索示例

不难看出， $BFS(s)$ 将覆盖起始顶点 s 所属的连通分量或可达分量，但无法抵达此外的顶点。而上层主函数 $bfs()$ 的作用，正在于处理多个连通分量或可达分量并存的情况。具体地，在逐个检查顶点的过程中，只要发现某一顶点尚未被发现，则意味着其所属的连通分量或可达分量尚未触及，故可从该顶点出发再次启动 $BFS()$ ，以遍历其所属的连通分量或可达分量。如此，各次 $BFS()$ 调用所得的BFS树构成一个森林，称作BFS森林（BFS forest）。

6.6.4 复杂度

除作为输入的图本身外，BFS搜索所使用的空间，主要消耗在用于维护顶点访问次序的辅助队列、用于记录顶点和边状态的标识位向量，累计 $O(n) + O(n) + O(e) = O(n + e)$ 。

时间方面，首先需花费 $O(n + e)$ 时间复位所有顶点和边的状态。不计对子函数 $BFS()$ 的调用， $bfs()$ 本身对所有顶点的枚举共需 $O(n)$ 时间。而在对 $BFS()$ 的所有调用中，每个顶点、每条边均只耗费 $O(1)$ 时间，累计 $O(n + e)$ 。综合起来，BFS搜索总体仅需 $O(n + e)$ 时间。

6.6.5 应用

基于BFS搜索，可有效地解决连通域分解（习题[6-6]）、最短路径（习题[6-8]）等问题。

§ 6.7 深度优先搜索

6.7.1 策略

深度优先搜索 (Depth-First Search, DFS) 选取下一顶点的策略, 可概括为:

优先选取最后一个被访问到的顶点的邻居

于是, 以顶点 s 为基点的DFS搜索, 将首先访问顶点 s ; 再从 s 所有尚未访问到的邻居中任取其一, 并以之为基点, 递归地执行DFS搜索。故各顶点被访问到的次序, 类似于树的先序遍历 (5.4.2节); 而各顶点被访问完毕的次序, 则类似于树的后序遍历 (5.4.4节)。

6.7.2 实现

深度优先遍历算法可实现如代码6.4所示。

```

1 template <typename Tv, typename Te> //深度优先搜索DFS算法 ( 全图 )
2 void Graph<Tv, Te>::dfs(int s) { //assert: 0 <= s < n
3     reset(); int clock = 0; int v = s; //初始化
4     do //逐一检查所有顶点
5         if (UNDISCOVERED == status(v)) //一旦遇到尚未发现的顶点
6             DFS(v, clock); //即从该顶点出发启动一次DFS
7     while (s != (v = (++v % n))); //按序号检查, 故不漏不重
8 }
9
10 template <typename Tv, typename Te> //深度优先搜索DFS算法 ( 单个连通域 )
11 void Graph<Tv, Te>::DFS(int v, int& clock) { //assert: 0 <= v < n
12     dTime(v) = ++clock; status(v) = DISCOVERED; //发现当前顶点v
13     for (int u = firstNbr(v); -1 < u; u = nextNbr(v, u)) //枚举v的所有邻居u
14         switch (status(u)) { //并视其状态分别处理
15             case UNDISCOVERED: //u尚未发现, 意味着支撑树可在此拓展
16                 status(v, u) = TREE; parent(u) = v; DFS(u, clock); break;
17             case DISCOVERED: //u已被发现但尚未访问完毕, 应属被后代指向的祖先
18                 status(v, u) = BACKWARD; break;
19             default: //u已访问完毕 ( VISITED, 有向图 ), 则视承袭关系分为前向边或跨边
20                 status(v, u) = (dTime(v) < dTime(u)) ? FORWARD : CROSS; break;
21         }
22     status(v) = VISITED; fTime(v) = ++clock; //至此, 当前顶点v方告访问完毕
23 }

```

代码6.4 DFS算法

算法的实质功能, 由子算法DFS()递归地完成。每一递归实例中, 都先将当前节点 v 标记为DISCOVERED (已发现) 状态, 再逐一核对其各邻居 u 的状态并做相应处理。待其所有邻居均已处理完毕之后, 将顶点 v 置为VISITED (访问完毕) 状态, 便可回溯。

若顶点 u 尚处于UNDISCOVERED (未发现) 状态, 则将边 (v, u) 归类为树边 (tree edge),

并将 v 记作 u 的父节点。此后，便可将 u 作为当前顶点，继续递归地遍历。

若顶点 u 处于DISCOVERED状态，则意味着在此处发现一个有向环路。此时，在DFS遍历树中 u 必为 v 的祖先（习题[6-13]），故应将边 (v, u) 归类为后向边（back edge）。

这里为每个顶点 v 都记录了被发现的和访问完成的时刻，对应的时间区间 $[dTime(v), fTime(v)]$ 均称作 v 的活跃期（active duration）。实际上，任意顶点 v 和 u 之间是否存在祖先/后代的“血缘”关系，完全取决于二者的活跃期是否相互包含（习题[6-12]）。

对于有向图，顶点 u 还可能处于VISITED状态。此时，只要比对 v 与 u 的活跃期，即可判定在DFS树中 v 是否为 u 的祖先。若是，则边 (v, u) 应归类为前向边（forward edge）；否则，二者必然来自相互独立的两个分支，边 (v, u) 应归类为跨边（cross edge）。

DFS(s)返回后，所有访问过的顶点通过parent[]指针依次联接，从整体上给出了顶点s所属连通或可达分量的一棵遍历树，称作深度优先搜索树或DFS树（DFS tree）。与BFS搜索一样，此时若还有其它的连通或可达分量，则可以其中任何顶点为基点，再次启动DFS搜索。

最终，经各次DFS搜索生成的一系列DFS树，构成了DFS森林（DFS forest）。

6.7.3 实例

图6.8针对含7个顶点和10条边的某有向图，给出了DFS搜索的详细过程。请留意观察顶点时间标签的设置，顶点状态的演变，边的分类和结果，以及DFS树（森林）的生长过程。

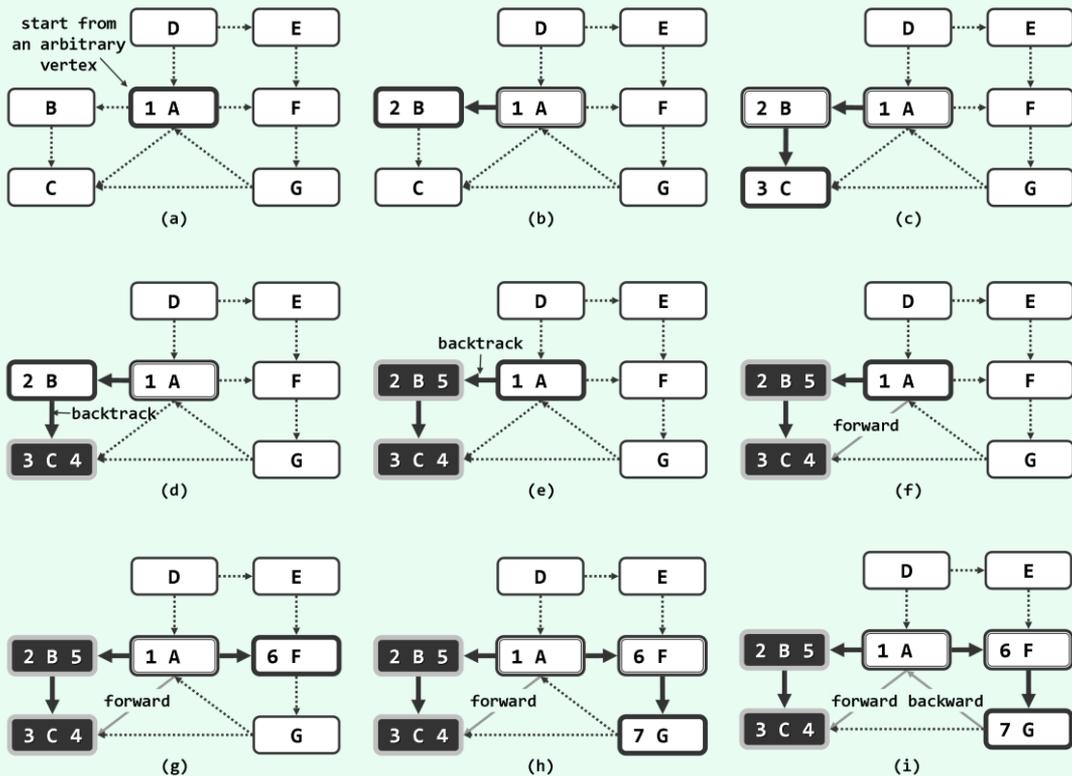


图6.8 深度优先搜索实例（粗边框白色，为当前顶点；细边框白色、双边框白色和黑色，分别为处于UNDISCOVERED、DISCOVERED和VISITED状态的顶点；dTime和fTime标签，分别标注于各顶点的左右）

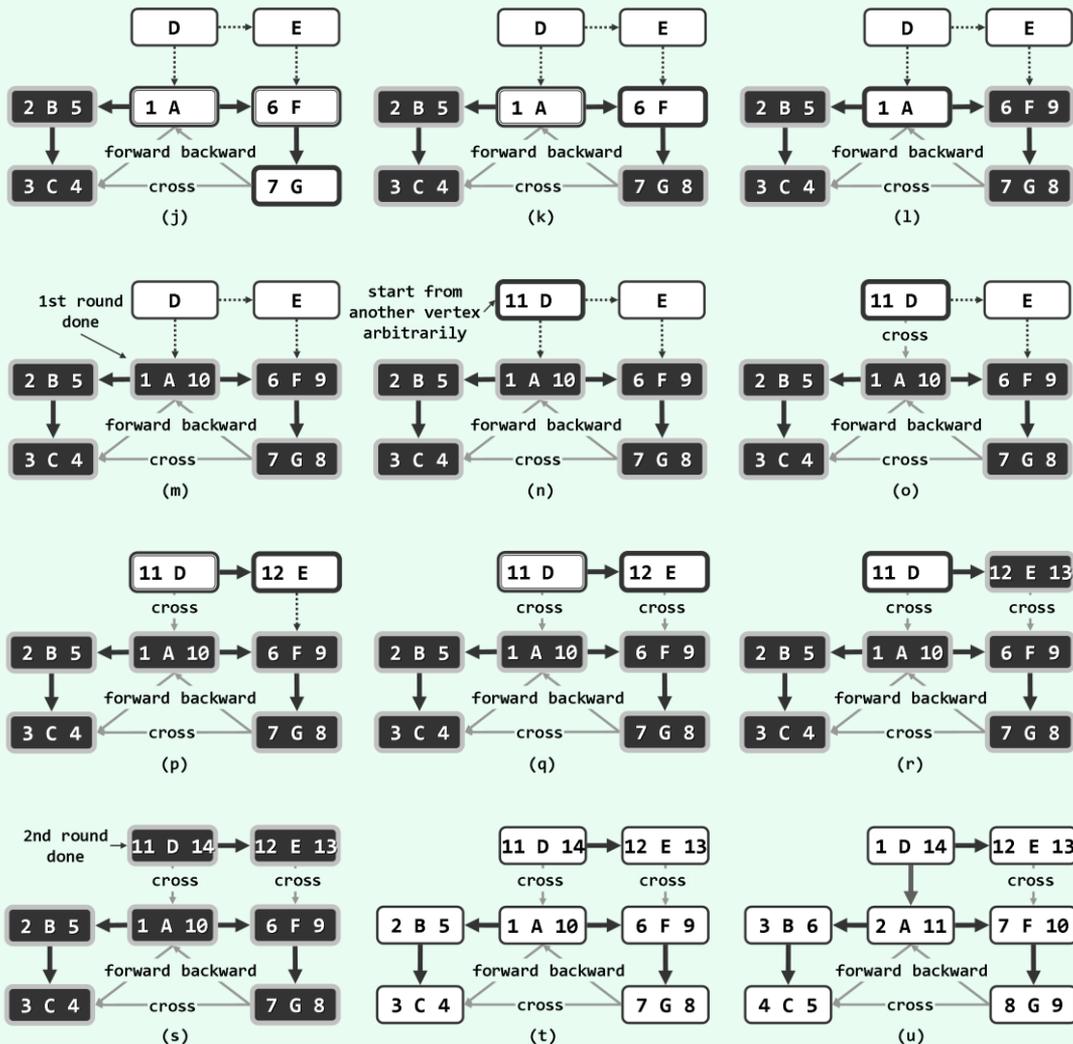


图6.8 深度优先搜索实例(续)：(a~m)对应于DFS(A)，(n~s)为随后的DFS(D)

最终结果如图(t)所示，为包含两棵DFS树的一个DFS森林。可以看出，选用不同的起始基点，生成的DFS树(森林)也可能各异。如本例中，若从D开始搜索，则DFS森林可能如图(u)所示。

图6.9以时间为横坐标，绘出了图6.8(u)中DFS树内各顶点的活跃期。可以清晰地看出，活跃期相互包含的顶点，在DFS树中都是“祖先-后代”关系(比如B之于C，或者D之于F)；反之亦然。

这种对应关系并非偶然，籍此可以便捷地判定节点之间的承袭关系(习题[6-12])。故无论是对DFS搜索本身，还是对基于DFS的各种算法而言，时间标签都至关重要。

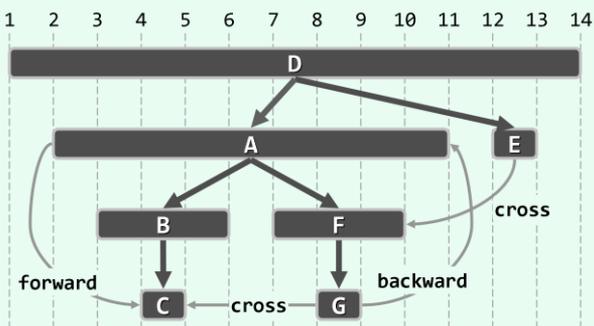


图6.9 活跃期与“祖先-后代”关系之间的对应关系

6.7.4 复杂度

除了原图本身,深度优先搜索算法所使用的空间,主要消耗于各顶点的时间标签和状态标记,以及各边的分类标记,二者累计不超过 $O(n) + O(e) = O(n + e)$ 。当然,如采用以上代码6.4的直接递归实现方式,操作系统为维护运行栈还需耗费一定量的空间——尽管这部分增量在渐进意义下还不足以动摇以上结论。为此,不妨仿照5.4节的做法,通过显式地引入并维护一个栈结构,将DFS算法改写为迭代版本(习题[6-14])。

时间方面,首先需要花费 $O(n + e)$ 时间对所有顶点和边的状态复位。不计对子函数DFS()的调用,dfs()本身对所有顶点的枚举共需 $O(n)$ 时间。不计DFS()之间相互的递归调用,每个顶点、每条边只在子函数DFS()的某一递归实例中耗费 $O(1)$ 时间,故累计亦不过 $O(n + e)$ 时间。综合而言,深度优先搜索算法也可在 $O(n + e)$ 时间内完成。

6.7.5 应用

深度优先搜索无疑是最为重要的图遍历算法。基于DFS的框架,可以导出和建立大量的图算法。以4.4节英雄忒修斯营救公主的故事为例,为寻找从迷宫入口(起始顶点)至公主所在位置(目标顶点)的通路,可将迷宫内不同位置之间的联接关系表示为一幅图,并将问题转化为起点和终点之间的可达性判定,从而可利用DFS算法便捷地加以解决。非但如此,一旦找到通路,则不仅可以顺利抵达终点与公主会合,还能沿这条通路安全返回。当然,与广度优先搜索一样,深度优先搜索也可用作连通分量的分解,或者有向无环图的判定。

下面仅以拓扑排序和双连通域分解为例,对DFS模式的应用做更为具体的介绍。

§ 6.8 拓扑排序

6.8.1 应用

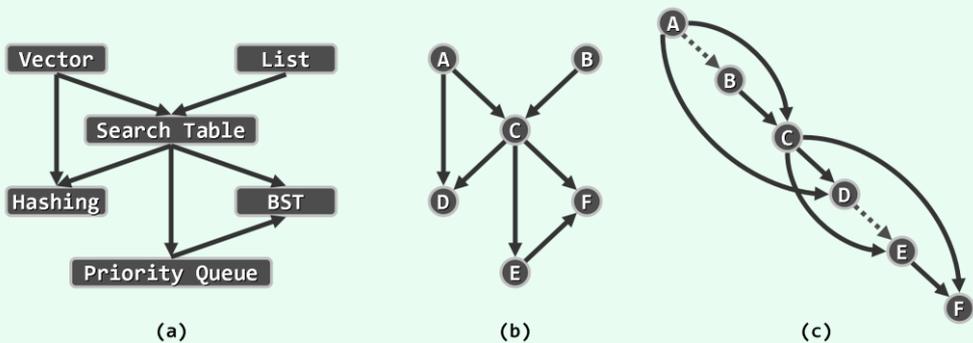


图6.10 拓扑排序

以教材的编写这一实际问题为例。首先,作者可借助有向图结构,整理出相关知识点之间的依赖关系。如图6.10(a)所示,因向量是散列表和查找表的基础知识点,故从Vector发出两条边分别指向Hashing和Search Table;同理,查找表是二叉搜索树的基础知识点,故也从前者引出一条边指向后者;...;诸如此类。那么,如何将这些知识点串联为一份教学计划,以保证在整个授课进程中,每堂课的基础知识点均在此前业已讲授呢?

若将图6.10(a)抽象为图(b)，则不难看出，图(c)就是一份可行的教材目录和授课计划。实际上，许多应用问题，都可转化和描述为这一标准形式：给定描述某一实际应用（图(a)）的有向图（图(b)），如何在与该图“相容”的前提下，将所有顶点排成一个线性序列（图(c)）。

此处的“相容”，准确的含义是：每一顶点都不会通过边，指向其在此序列中的前驱顶点。这样的一个线性序列，称作原有向图的一个拓扑排序（topological sorting）。

6.8.2 有向无环图

那么，拓扑排序是否必然存在？若存在，又是否唯一？

这两个问题都不难回答。在图6.10(c)中，顶点A和B互换之后依然是一个拓扑排序，故同一有向图的拓扑排序未必唯一。若在图(b)中引入一条从顶点F指向B的边，使顶点B、C和F构成一个有向环路，则无论如何也不可能得到一个“相容”的线性序列，故拓扑排序也未必存在。

反之，不含环路的有向图——有向无环图——一定存在拓扑排序吗？答案是肯定的。

有向无环图的拓扑排序必然存在；反之亦然。这是因为，有向无环图对应于偏序关系，而拓扑排序则对应于全序关系。在顶点数目有限时，与任一偏序相容的全序必然存在。

任一有限偏序集，必有极值元素（尽管未必唯一）；类似地，任一有向无环图，也必包含入度为零的顶点。否则，每个顶点都至少有一条入边，意味着要么顶点有无穷个，要么包含环路。

于是，只要将入度为0的顶点m（及其关联边）从图G中取出，则剩余的G'依然是有向无环图，故其拓扑排序也必然存在。从递归的角度看，一旦得到了G'的拓扑排序，只需将m作为最大顶点插入，即可得到G的拓扑排序。如此，我们已经得到了一个拓扑排序的算法（习题[6-18]）。

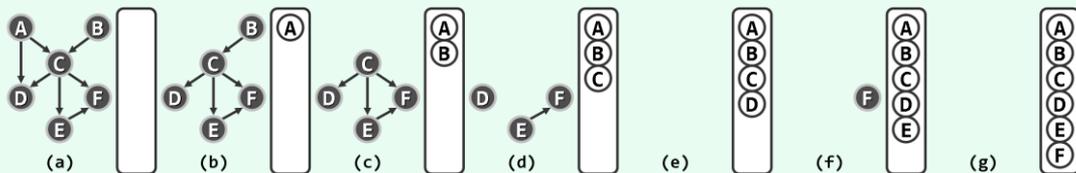


图6.11 利用“DAG必有零入度顶点”的特性，实现拓扑排序

图6.11给出了该算法的一个实例。以下，将转而从BFS搜索入手，给出另一拓扑排序算法。

6.8.3 算法

不妨将关注点，转至与极大顶点相对称的极小顶点。

同理，有限偏序集中也必然存在极小元素（同样，未必唯一）。该元素作为顶点，出度必然为零——比如图6.10(b)中的顶点D和F。而在对有向无环图的DFS搜索中，首先因访问完成而转换至VISITED状态的顶点m，也必然具有这一性质；反之亦然。

进一步地，根据DFS搜索的特性，顶点m（及其关联边）对此后的搜索过程将不起任何作用。于是，下一转换至VISITED状态的顶点可等效地理解为是，从图中剔除顶点m（及其关联边）之后的出度为零者——在拓扑排序中，该顶点应为顶点m的前驱。由此可见，DFS搜索过程中各顶点被标记为VISITED的次序，恰好（按逆序）给出了原图的一个拓扑排序。

此外，DFS搜索善于检测环路的特性，恰好可以用来判别输入是否为有向无环图。具体地，搜索过程中一旦发现后向边，即可终止算法并报告“因非DAG而无法拓扑排序”。

6.8.4 实现

基于DFS搜索框架的拓扑排序算法，可实现如代码6.5所示。

```

1  template <typename Tv, typename Te> //基于DFS的拓扑排序算法
2  Stack<Tv>* Graph<Tv, Te>::tSort(int s) { //assert: 0 <= s < n
3      reset(); int cclock = 0; int v = s;
4      Stack<Tv>* S = new Stack<Tv>; //用栈记录排序顶点
5      do {
6          if (UNDISCOVERED == status(v))
7              if (!TSort(v, cclock, S)) { //cclock并非必需
8                  while (!S->empty()) //任一连通域(亦即整图)非DAG
9                      S->pop(); break; //则不必继续计算,故直接返回
10             }
11         } while (s != (v = (++v % n)));
12         return S; //若输入为DAG,则S内各顶点自顶向底排序;否则(不存在拓扑排序),S空
13     }
14
15     template <typename Tv, typename Te> //基于DFS的拓扑排序算法(单趟)
16     bool Graph<Tv, Te>::TSort(int v, int& cclock, Stack<Tv>* S) { //assert: 0 <= v < n
17         dTime(v) = ++cclock; status(v) = DISCOVERED; //发现顶点v
18         for (int u = firstNbr(v); -1 < u; u = nextNbr(v, u)) //枚举v的所有邻居u
19             switch (status(u)) { //并视u的状态分别处理
20                 case UNDISCOVERED:
21                     parent(u) = v; status(v, u) = TREE;
22                     if (!TSort(u, cclock, S)) //从顶点u处出发深入搜索
23                         return false; //若u及其后代不能拓扑排序(则全图亦必如此),故返回并报告
24                     break;
25                 case DISCOVERED:
26                     status(v, u) = BACKWARD; //一旦发现后向边(非DAG),则
27                     return false; //不必深入,故返回并报告
28                 default: //VISITED (digraphs only)
29                     status(v, u) = (dTime(v) < dTime(u)) ? FORWARD : CROSS;
30                     break;
31             }
32         status(v) = VISITED; S->push(vertex(v)); //顶点被标记为VISITED时,随即入栈
33         return true; //v及其后代可以拓扑排序
34     }

```

代码6.5 基于DFS搜索框架实现拓扑排序算法

相对于标准的DFS搜索算法，这里增设了一个栈结构。一旦某个顶点被标记为VISITED状态，便随即令其入栈。如此，当搜索终止时，所有顶点即按照被访问完毕的次序——亦即拓扑排序的次序——在栈中自顶而下排列。

6.8.5 实例

图6.12以含6个顶点和7条边的有向无环图为例，给出了以上算法的执行过程。共分三步迭代，分别对应于起始于顶点C、B和A的三趟DFS搜索。请留意观察，各顶点的入栈次序。

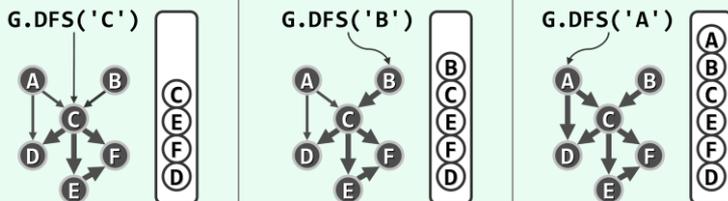


图6.12 基于DFS搜索的拓扑排序实例

另外，对照图6.11中的结果可见，因多个极大、极小元素（入度、出度为零顶点）并存而导致拓扑排序的不唯一性并未消除，而是转由该算法对每趟DFS起点的选择策略决定。

6.8.6 复杂度

这里仅额外引入的栈，规模不超过顶点总数 $O(n)$ 。总体而言，空间复杂度与基本的深度优先搜索算法同样，仍为 $O(n + e)$ 。该算法的递归跟踪过程与标准DFS搜索完全一致，且各递归实例自身的执行时间依然保持为 $O(1)$ ，故总体运行时间仍为 $O(n + e)$ 。

为与基本的DFS搜索算法做对比，代码6.5保留了代码6.4的通用框架，但并非所有操作都与拓扑排序直接相关。因此通过精简代码，还可进一步地优化（习题[6-19]）。

§ 6.9 *双连通域分解

6.9.1 关节点与双连通域

考查无向图G。若删除顶点v后G所包含的连通域增多，则v称作切割节点（cut vertex）或关节点（articulation point）。如图6.13中的C即是一个关节点——它的删除将导致连通域增加两块。反之，不含任何关节点的图称作双连通图。任一无向图都可视作由若干个极大的双连通子图组合而成，这样的每一子图都称作原图的一个双连通域（bi-connected component）。例如图6.14(a)中的无向图，可分解为如图(b)所示的三个双连通域。

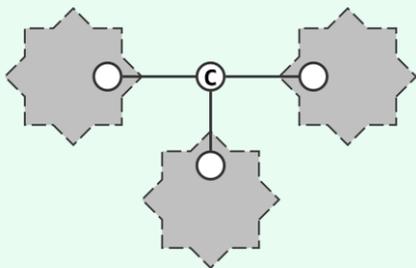


图6.13 关节点

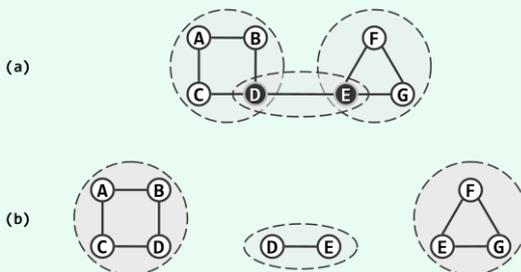


图6.14 双连通域

较之其它顶点，关节点更为重要。在网络系统中它们对应于网关，决定子网之间能否连通。在航空系统中，某些机场的损坏，将同时切断其它机场之间的交通。故在资源总量有限的前提下，找出关节点并重点予以保障，是提高系统整体稳定性和鲁棒性的基本策略。

6.9.2 蛮力算法

那么，如何才能找出图中的关节点呢？

由其定义，可直接导出蛮力算法大致如下：首先，通过BFS或DFS搜索统计出图G所含连通域的数目；然后逐一枚举每个顶点v，暂时将其从图G中删去，并再次通过搜索统计出图G\{v}所含连通域的数目。于是，顶点v是关节点，当且仅当图G\{v}包含的连通域多于图G。

这一算法需执行n趟搜索，耗时 $O(n(n + e))$ ，如此低的效率无法令人满意。

以下将介绍基于DFS搜索的另一算法，它不仅效率更高，而且可同时对原图做双连通域分解。

6.9.3 可行算法

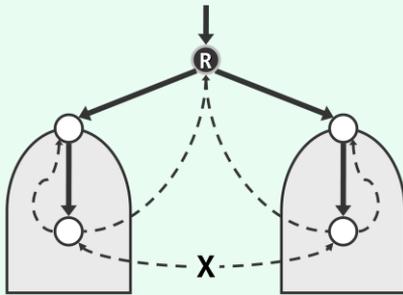


图6.15 DFS树根节点是关节点，当且仅当它拥有多个分支

经DFS搜索生成的DFS树，表面上看似乎“丢失”了原图的一些信息，但实际上就某种意义而言，依然可以提供足够多的信息。

比如，DFS树中的叶节点，绝不可能是原图中的关节点——此类顶点的删除既不致影响DFS树的连通性，也不致影响原图的连通性。此外，DFS树的根节点若至少拥有两个分支，则必是一个关节点。如图6.15所示，在原无向图中，根节点R的不同分支之间不可能通过跨边相联，R是它们之间唯一的枢纽。反之，若根节点仅有一个分支，则与叶节点同理，它也不可能是关节点。

那么，又该如何甄别一般的内部节点是否为关节点呢？

考查图6.16中的内部节点C。若节点C的移除导致其某一棵（比如以D为根的）真子树与其真祖先（比如A）之间无法连通，则C必为关节点。反之，若C的所有真子树都能（如以E为根的子树那样）与C的某一真祖先连通，则C就不可能是关节点。

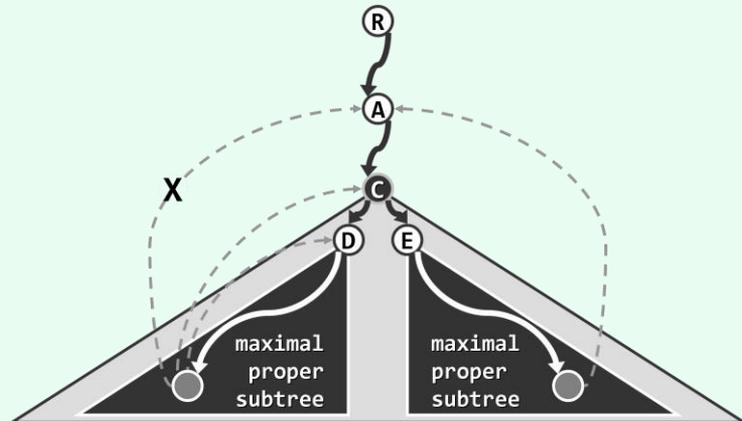


图6.16 内部节点C是关节点，当且仅当C的某棵极大真子树不（经后向边）联接到C的真祖先

当然，在原无向图的DFS树中，C的真子树只可能通过后向边与C的真祖先连通。因此，只要在DFS搜索过程记录并更新各顶点v所能（经由后向边）连通的最高祖先（highest connected ancestor, HCA） $hca[v]$ ，即可及时认定关节点，并报告对应的双连通域。

6.9.4 实现

根据以上分析，基于DFS搜索框架的双连通域分解算法，可实现如代码6.6所示。

```

1  template <typename Tv, typename Te> void Graph<Tv, Te>::bcc(int s) { //基于DFS的BCC分解算法
2      reset(); int clock = 0; int v = s; Stack<int> S; //栈S用以记录已访问的顶点
3      do
4          if (UNDISCOVERED == status(v)) { //一旦发现未发现的顶点(新连通分量)
5              BCC(v, clock, S); //即从该顶点出发启动一次BCC
6              S.pop(); //遍历返回后,弹出栈中最后一个顶点——当前连通域的起点
7          }
8      while (s != (v = (++v % n)));
9  }
10 #define hca(x) (fTime(x)) //利用此处闲置的fTime[]充当hca[]
11 template <typename Tv, typename Te> //顶点类型、边类型
12 void Graph<Tv, Te>::BCC(int v, int& clock, Stack<int>& S) { //assert: 0 <= v < n
13     hca(v) = dTime(v) = ++clock; status(v) = DISCOVERED; S.push(v); //顶点v被发现并入栈
14     for (int u = firstNbr(v); -1 < u; u = nextNbr(v, u)) //枚举v的所有邻居u
15         switch (status(u)) { //并视u的状态分别处理
16             case UNDISCOVERED:
17                 parent(u) = v; status(v, u) = TREE; BCC(u, clock, S); //从顶点u处深入
18                 if (hca(u) < dTime(v)) //遍历返回后,若发现u(通过后向边)可指向v的真祖先
19                     hca(v) = min(hca(v), hca(u)); //则v亦必如此
20                 else { //否则,以v为关节点(u以下即是一个BCC,且其中顶点此时正集中于栈S的顶部)
21                     while (v != S.pop()); //依次弹出当前BCC中的节点,亦可根据实际需求转存至其它结构
22                     S.push(v); //最后一个顶点(关节点)重新入栈——总计至多两次
23                 }
24                 break;
25             case DISCOVERED:
26                 status(v, u) = BACKWARD;
27                 if (u != parent(v)) hca(v) = min(hca(v), dTime(u)); //更新hca[v]——越小越高
28                 break;
29             default: //VISITED (digraphs only)
30                 status(v, u) = (dTime(v) < dTime(u)) ? FORWARD : CROSS;
31                 break;
32         }
33     status(v) = VISITED; //对v的访问结束
34 }
35 #undef hca

```

代码6.6 基于DFS搜索框架实现双连通域分解算法

由于处理的是无向图，故DFS搜索在顶点v的孩子u处返回之后，通过比较hca[u]与dTime[v]的大小，即可判断v是否关节点。

这里将闲置的fTime[]用作hca[]。故若hca[u] ≥ dTime[v]，则说明u及其后代无法通过

后向边与 v 的真祖先连通，故 v 为关节点。既然栈 S 存有搜索过的顶点，与该关节点相对应的双连通域内的顶点，此时都应集中存放于 S 顶部，故可依次弹出这些顶点。 v 本身必然最后弹出，作为多个连通域的联接枢纽，它应重新进栈。

反之若 $hca[u] < dTime[v]$ ，则意味着 u 可经由后向边连通至 v 的真祖先。果真如此，则这一性质对 v 同样适用，故有必要将 $hca[v]$ ，更新为 $hca[v]$ 与 $hca[u]$ 之间的更小者。

当然，每遇到一条后向边 (v, u) ，也需要及时地将 $hca[v]$ ，更新为 $hca[v]$ 与 $dTime[u]$ 之间的更小者，以保证 $hca[v]$ 能够始终记录顶点 v 可经由后向边向上连通的最高祖先。

同样地，为便于与基本的DFS搜索算法相对比，代码6.6也保留了代码6.4的通用框架。因此，通过清理与双连通域分解无关的操作并精简代码，也可降低时间复杂度的常系数（习题[6-20]）。

6.9.5 实例

图6.17以一个包含10个顶点和12条边的无向图为例，详细给出了以上算法的完整计算过程。

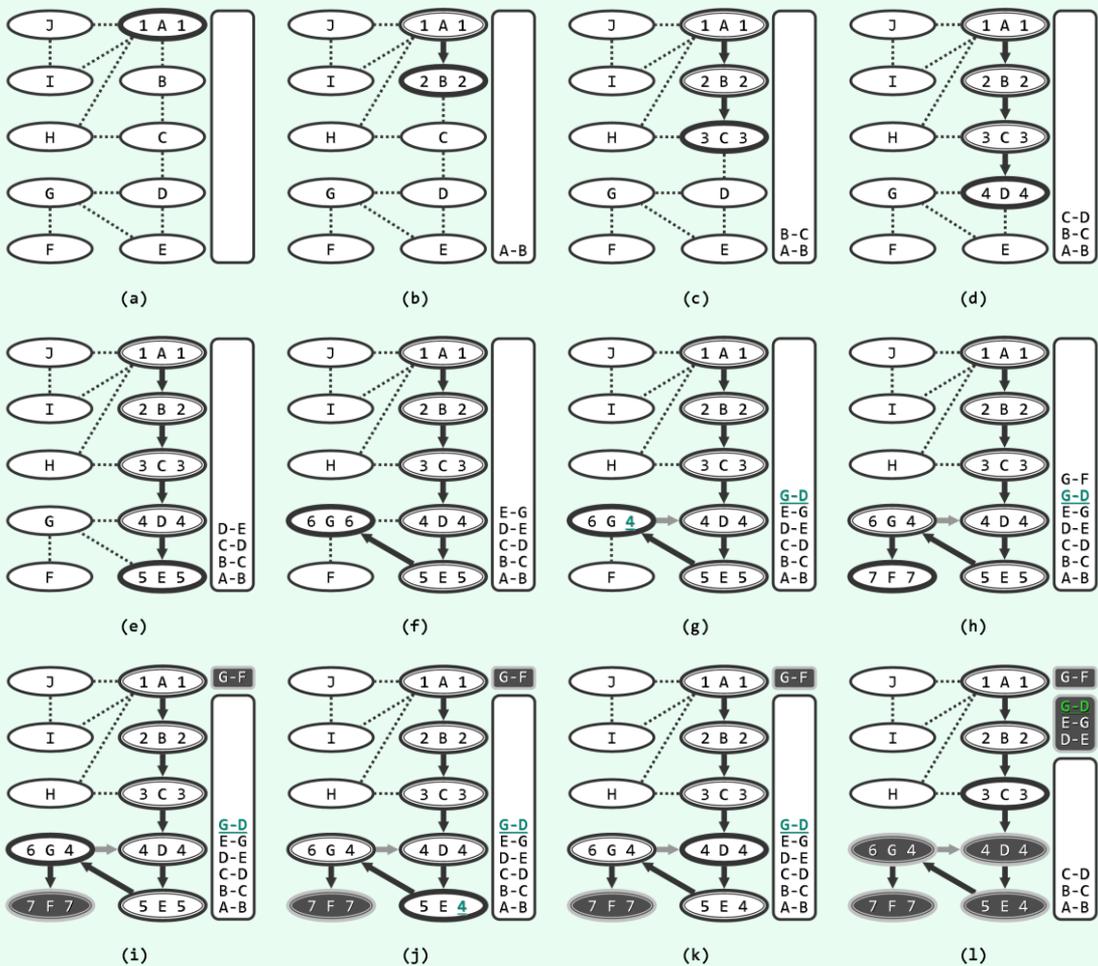


图6.17 基于DFS搜索的双连通域分解实例

(细边框白色、双边框白色和黑色分别示意处于UNDISCOVERED、DISCOVERED和VISITED状态的顶点，粗边框白色示意当前顶点；dTime和fTime (hca) 标签分别标注于各顶点的左、右)

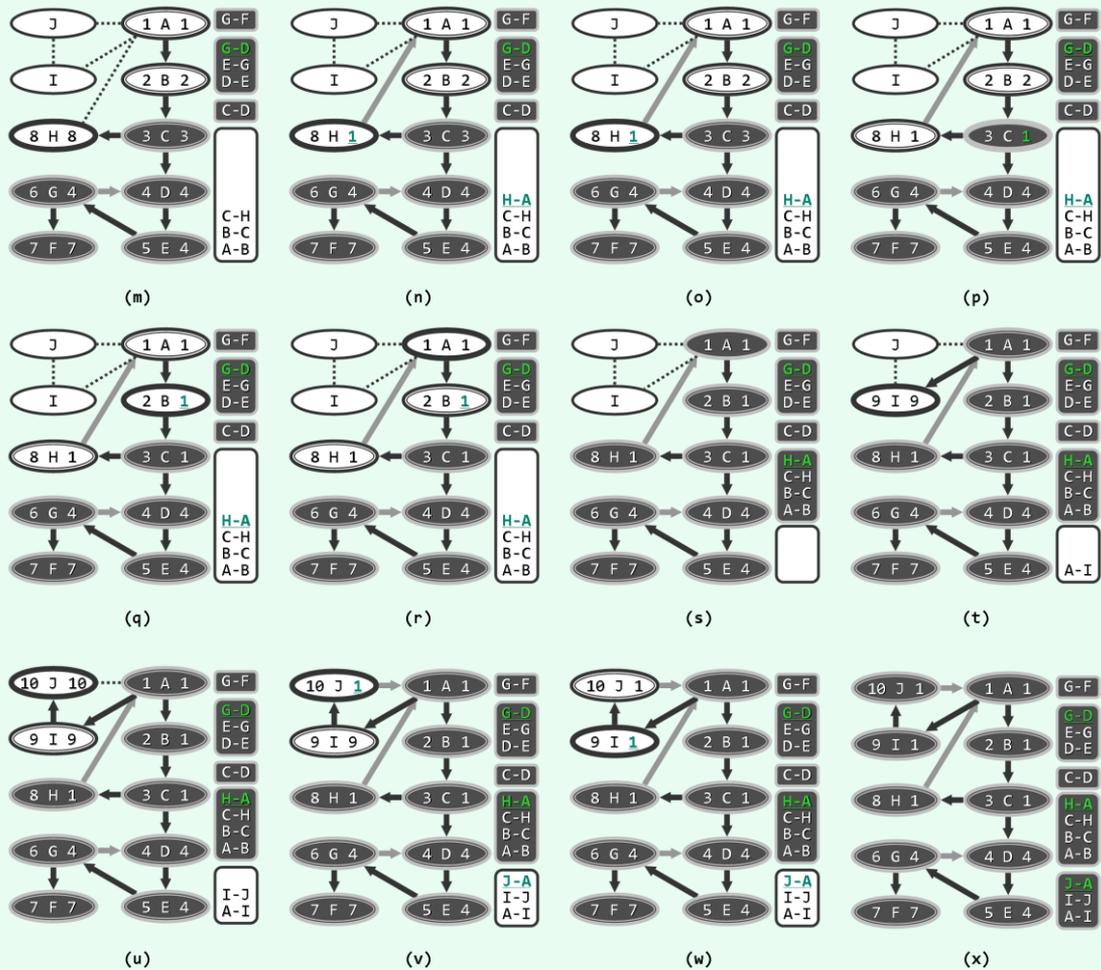


图6.17 基于DFS搜索的双连通域分解实例 (续)

6.9.6 复杂度

与基本的DFS搜索算法相比，这里只增加了一个规模 $O(n)$ 的辅助栈，故整体空间复杂度仍为 $O(n + e)$ 。时间方面，尽管同一顶点 v 可能多次入栈，但每一次重复入栈都对应于某一新发现的双连通域，与之对应地必有至少另一顶点出栈且不再入栈。因此，这类重复入栈操作不会超过 n 次，入栈操作累计不超过 $2n$ 次，故算法的整体运行时间依然是 $O(n + e)$ 。

§ 6.10 优先级搜索

6.10.1 优先级与优先级数

以上图搜索应用虽各具特点，但其基本框架却颇为相似。总体而言，都需通过迭代逐一发现各顶点，将其纳入遍历树中并做相应处理，同时根据应用问题的需求，适时给出解答。各算法在功能上的差异，主要体现为每一步迭代中对新顶点的选取策略不同。比如，BFS搜索会优先考查更早被发现的顶点，而DFS搜索则恰好相反，会优先考查最后被发现的顶点。

每一种选取策略都等效于，给所有顶点赋予不同的优先级，而且随着算法的推进不断调整；而每一步迭代所选取的顶点，都是当时的优先级最高者。按照这种理解，包括BFS和DFS在内的几乎所有图搜索，都可纳入统一的框架。鉴于优先级在其中所扮演的关键角色，故亦称作优先级搜索（**priority-first search, PFS**），或最佳优先搜索（**best-first search, BFS**）。

为落实以上理解，图ADT（表6.2和代码6.1）提供了**priority()**接口，以支持对顶点优先级数（**priority number**）的读取和修改。在实际应用中，引导优化方向的指标往往对应于某种有限的资源或成本（如光纤长度、通讯带宽等），故不妨约定优先级数越大（小）顶点的优先级越低（高）。相应地，在算法的初始化阶段（如代码6.1中的**reset()**），通常都将顶点的优先级数统一置为最大（比如**INT_MAX**）——或等价地，优先级最低。

6.10.2 基本框架

按照上述思路，优先级搜索算法的框架可具体实现如代码6.7所示。

```

1 template <typename Tv, typename Te> template <typename PU> //优先级搜索 ( 全图 )
2 void Graph<Tv, Te>::pfs(int s, PU prioUpdater) { //assert: 0 <= s < n
3     reset(); int v = s; //初始化
4     do //逐一检查所有顶点
5         if (UNDISCOVERED == status(v)) //一旦遇到尚未发现的顶点
6             PFS(v, prioUpdater); //即从该顶点出发启动一次PFS
7         while (s != (v = (++v % n))); //按序号检查, 故不漏不重
8     }
9
10 template <typename Tv, typename Te> template <typename PU> //顶点类型、边类型、优先级更新器
11 void Graph<Tv, Te>::PFS(int s, PU prioUpdater) { //优先级搜索 ( 单个连通域 )
12     priority(s) = 0; status(s) = VISITED; parent(s) = -1; //初始化, 起点s加至PFS树中
13     while (1) { //将下一顶点和边加至PFS树中
14         for (int w = firstNbr(s); -1 < w; w = nextNbr(s, w)) //枚举s的所有邻居w
15             prioUpdater(this, s, w); //更新顶点w的优先级及其父顶点
16         for (int shortest = INT_MAX, w = 0; w < n; w++)
17             if (status(w) == UNDISCOVERED) //从尚未加入遍历树的顶点中
18                 if (shortest > priority(w)) //选出下一个
19                     { shortest = priority(w); s = w; } //优先级最高的顶点s
20         if (VISITED == status(s)) break;
21         status(s) = VISITED; status(parent(s), s) = TREE; //将s及其与父顶点的联边加入遍历树
22     }
23 } //通过定义具体的优先级更新策略prioUpdater, 即可实现不同的算法功能

```

代码6.7 优先级搜索算法框架

可见，PFS搜索的基本过程和功能与常规的图搜索算法一样，也是以迭代方式逐步引入顶点和边，最终构造出一棵遍历树（或者遍历森林）。如上所述，每次都是引入当前优先级最高（优先级数最小）的顶点s，然后按照不同的策略更新其邻接顶点的优先级数。

这里借助函数对象**prioUpdater**，使算法设计者得以根据不同的问题需求，简明地描述和实

现对应的更新策略。具体地，只需重新定义`prioUpdater`对象即可，而不必重复实现公共部分。比如，此前的BFS搜索和DFS搜索都可按照此模式统一实现（习题[6-21]）。

下面，以最小支撑树和最短路径这两个经典的图算法为例，深入介绍这一框架的具体应用。

6.10.3 复杂度

PFS搜索由两重循环构成，其中内层循环又含并列的两个循环。若采用邻接表实现方式，同时假定`prioUpdater()`只需常数时间，则前一内循环的累计时间应取决于所有顶点的出度总和，即 $O(e)$ ；后一内循环固定迭代 n 次，累计 $O(n^2)$ 时间。两项合计总体复杂度为 $O(n^2)$ 。

实际上，借助稍后第10章将要介绍的优先级队列等结构，PFS搜索的效率还有进一步提高的余地（习题[10-16]和[10-17]）。

§ 6.11 最小支撑树

6.11.1 支撑树

如图6.18所示，连通图 G 的某一无环连通子图 T 若覆盖 G 中所有的顶点，则称作 G 的一棵支撑树或生成树（spanning tree）。

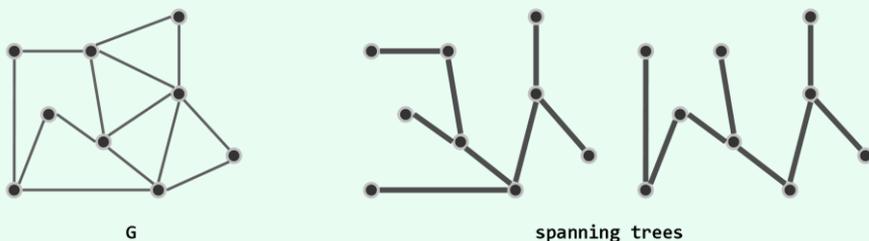


图6.18 支撑树

就保留原图中边的数目而言，支撑树既是“禁止环路”前提下的极大子图，也是“保持连通”前提下的最小子图。在实际应用中，原图往往对应于由一组可能相互联接（边）的成员（顶点）构成的系统，而支撑树则对应于该系统最经济的联接方案。确切地，尽管同一幅图可能有多棵支撑树，但由于其中的顶点总数均为 n ，故其采用的边数也均为 $n - 1$ 。

6.11.2 最小支撑树

若图 G 为一带权网络，则每一棵支撑树的成本（cost）即为其所采用各边权重的总和。在 G 的所有支撑树中，成本最低者称作最小支撑树（minimum spanning tree, MST）。

聚类分析、网络架构设计、VLSI布线设计等诸多实际应用问题，都可转化并描述为最小支撑树的构造问题。在这些应用中，边的权重大多对应于某种可量化的成本，因此作为对应优化问题的基本模型，最小支撑树的价值不言而喻。另外，最小支撑树构造算法也可为一些NP问题提供足够快速、足够接近的近似解法（习题[6-22]）。正因为受到来自众多应用和理论领域的需求推动，最小支撑树的构造算法也发展得较为成熟。

6.11.3 歧义性

尽管同一带权网络通常都有多棵支撑树，但总数毕竟有限，故必有最低的总体成本。然而，总体成本最低的支撑树却未必唯一。以包含三个顶点的完全图为例，若三条边的权重相等，则其中任意两条边都构成总体成本最低的一棵支撑树。

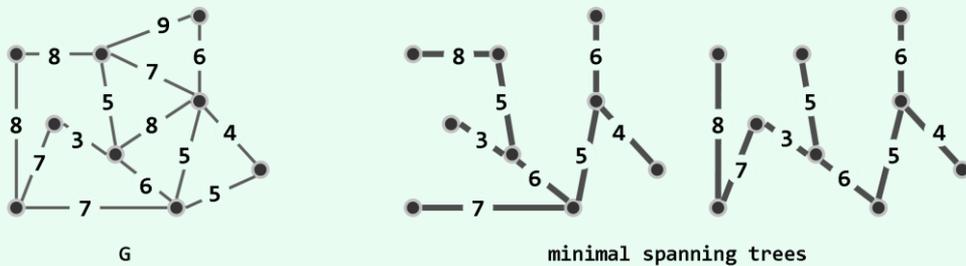


图6.19 极小支撑树与最小支撑树

更一般的例子如图6.19所示，对应于左侧的带权网络，有两棵支撑树的总体成本均达到最低（44）。故严格说来，此类支撑树应称作极小支撑树（minimal spanning tree）。当然，通过强制附加某种次序即可消除这种歧义性（习题[6-23]），故不妨仍称之为最小支撑树。

6.11.4 蛮力算法

由最小支撑树的定义，可直接导出蛮力算法大致如下：逐一考查 G 的所有支撑树并统计其成本，从而挑选出其中的最低者。然而根据Cayley公式，由 n 个互异顶点组成的完全图共有 n^{n-2} 棵支撑树，即便忽略掉构造所有支撑树所需的成本，仅为更新最低成本的记录就需要 $\mathcal{O}(n^{n-2})$ 时间。

事实上基于PFS搜索框架，并采用适当的顶点优先级更新策略，即可得出如下高效的最小支撑树构造算法。

6.11.5 Prim算法

为更好地理解这一算法的原理，以下先从最小支撑树的性质入手。为简化起见，不妨假定各边的权重互异。实际上，为将最小支撑树的以下性质及其构造算法的正确性等结论推广到允许多边等权的退化情况，还需补充更为严格的分析与证明（习题[6-25]、[6-26]和[6-27]）。

■ 割与极短跨越边

图 $G = (V; E)$ 中，顶点集 V 的任一非平凡子集 U 及其补集 $V \setminus U$ 都构成 G 的一个割（cut），记作 $(U : V \setminus U)$ 。若边 uv 满足 $u \in U$ 且 $v \notin U$ ，则称作该割的一条跨越边（crossing edge）。因此类边联接于 V 及其补集之间，故亦形象地称作该割的一座桥（bridge）。

Prim算法^②的正确性基于以下事实：最小支撑树总是会采用联接每一割的最短跨越边。

否则，如图6.20(a)所示假设 uv 是割 $(U : V \setminus U)$ 的最短跨越边，而最小支撑树 T 并未采用该边。于是由树的连通性，如图(b)所示在 T 中必有至少另一跨边 st 联接该割（有可能 $s = u$ 或 $t =$

^② 由R. C. Prim于1956年发明

v ，尽管二者不能同时成立）。同样由树的连通性， T 中必有分别联接于 u 和 s 、 v 和 t 之间的两条通路。由于树是极大的无环图，故倘若将边 uv 加至 T 中，则如图(c)所示，必然出现穿过 u 、 v 、 t 和 s 的唯一环路。接下来，只要再删除边 st ，则该环路必然随之消失。

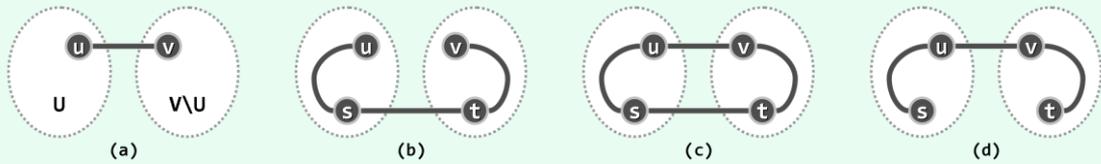


图6.20 最小支撑树总是会采用联接每一割的最短跨越边

经过如此的一出一入，若设 T 转换为 T' ，则 T' 依然是连通图，且所含边数与 T 相同均为 $n - 1$ 。这就意味着， T' 也是原图的一棵支撑树。就结构而言， T' 与 T 的差异仅在于边 uv 和边 st ，故二者的成本之差就是这两条边的权重之差。不难看出，边 st 的权重必然大于身为最短跨越边的 uv ，故 T' 的总成本低于 T ——这与 T 总体权重最小的前提矛盾。

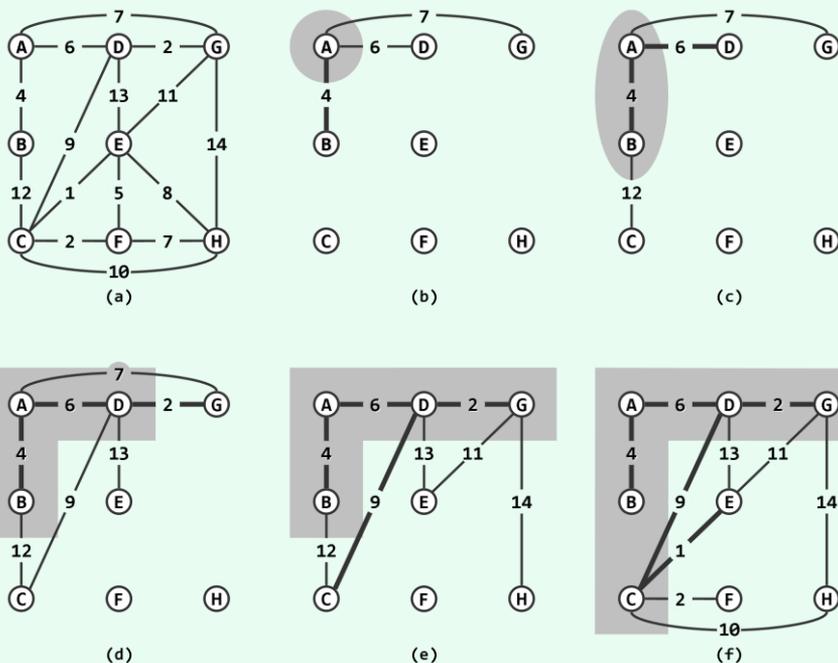
注意，以上性质并不意味着同一割仅能为最小支撑树贡献一条跨越边（习题[6-17]）。

■ 贪心迭代

由以上性质，可基于贪心策略导出一个迭代式算法。每一步迭代之前，假设已经得到最小支撑树 T 的一棵子树 $T_k = (V_k; E_k)$ ，其中 V_k 包含 k 个顶点， E_k 包含 $k - 1$ 条边。于是，若将 V_k 及其补集视作原图的一个割，则在找到该割的最短跨越边 $e_k = (v_k, u_k)$ ($v_k \in V_k$ 且 $u_k \notin V_k$)之后，即可将 T_k 扩展为一棵更大的子树 $T_{k+1} = (V_{k+1}; E_{k+1})$ ，其中 $V_{k+1} = V_k \cup \{u_k\}$ ， $E_{k+1} = E_k \cup \{e_k\}$ 。最初的 T_1 不含边而仅含单个顶点，故可从原图的顶点中任意选取。

■ 实例

图6.21以一个含8个顶点和15条边的无向图 G （图(a)）为例，给出了Prim算法的执行过程。



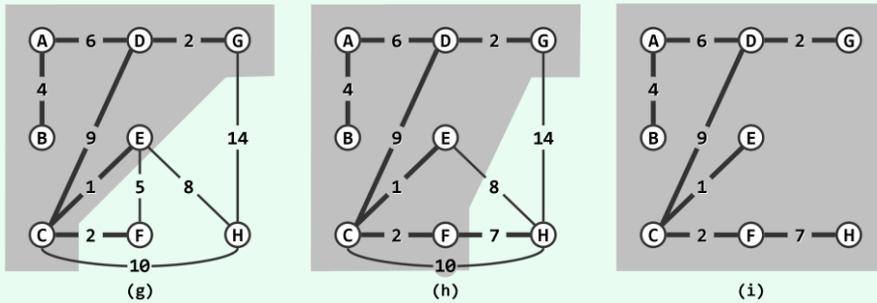


图6.21 Prim算法示例 (阴影区域示意不断扩展的子树 T_k ,粗线示意树边)

首先如图(b)所示, 任选一个顶点A作为初始的子树 $T_1 = (\{A\}; \emptyset)$ 。此时, T_1 所对应的割共有AB、AD和AG三条跨越边, 故选取其中最短路AB, 如图(c)所示将 T_1 扩充至 $T_2 = (\{A, B\}; \{AB\})$ 。此时, T_2 所对应的割共有BC、AD和AG三条跨越边, 依然选取其中最短路AD, 如图(d)所示将 T_2 扩充至 $T_3 = (\{A, B, D\}; \{AB, AD\})$ 。如此反复, 直至最终如图(i)所示得到:

$$T_8 = (\{A, B, D, G, C, E, F, H\}; \{AB, AD, DG, DC, CE, CF, FH\})$$

此即原图的最小支撑树。

可以证明, 即便出现多条极短跨越边共存的退化情况, 以上方法依然可行(习题[6-27])。

■ 实现

以上Prim算法完全可以纳入6.10.2节的优先级搜索算法框架。为此, 每次由 T_k 扩充至 T_{k+1} 时, 可以将 V_k 之外每个顶点u到 V_k 的距离视作u的优先级数。如此, 每一最短跨越边 e_k 对应的顶点 u_k 都会因拥有最小的优先级数(即最高的优先级)而自然地选中。

```

1 template <typename Tv, typename Te> struct PrimPU { //针对Prim算法的顶点优先级更新器
2     virtual void operator()(Graph<Tv, Te>* g, int uk, int v) {
3         if (g->status(v) == UNDISCOVERED) //对于uk每一尚未被发现的邻接顶点v
4             if (g->priority(v) > g->weight(uk, v)) { //按Prim策略做松弛
5                 g->priority(v) = g->weight(uk, v); //更新优先级(数)
6                 g->parent(v) = uk; //更新父节点
7             }
8     }
9 };

```

代码6.8 Prim算法的顶点优先级更新器

那么, u_k 和 e_k 加入 T_k 之后, 应如何快速更新 V_{k+1} 以外顶点的优先级数呢? 实际上, 与 u_k 互不关联的顶点都无需考虑, 故只需遍历 u_k 的每一邻居v, 若边 $u_k v$ 的权重小于v当前的优先级数, 则将后者更新为前者。这一思路可具体落实为如代码6.8所示的优先级更新器。

■ 复杂度

不难看出, 以上顶点优先级更新器只需常数的运行时间, 故由6.10.3节对优先级搜索算法性能的分析结论, 以上Prim算法的时间复杂度为 $O(n^2)$ 。作为PFS搜索的特例, Prim算法的效率也可借助优先级队列进一步提高(习题[10-16]和[10-17])。

§ 6.12 最短路径

若以带权图来表示真实的通讯、交通、物流或社交网络，则各边的权重可能代表信道成本、交通运输费用或交往程度。此时我们经常关心的一类问题（习题[6-8]），可以概括为：

给定带权网络 $G = (V, E)$ ，以及源点 (source) $s \in V$ ，对于所有的其它顶点 v ， s 到 v 的最短通路有多长？该通路由哪些边构成？

6.12.1 最短路径树

■ 单调性

如图6.22所示，设顶点 s 到 v 的最短路径为 ρ 。于是对于该路径上的任一顶点 u ，若其在 ρ 上对应的前缀为 σ ，则 σ 也必是 s 到 u 的最短路径（之一）。否则，若从 s 到 u 还有另一严格更短的路径 τ ，则易见 ρ 不可能是 s 到 v 的最短路径。

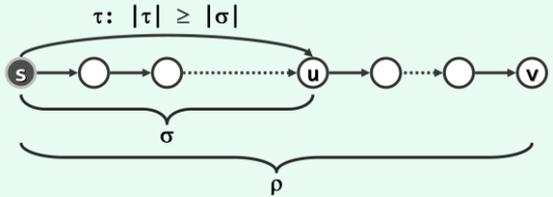


图6.22 最短路径的任一前缀也是最短路径

■ 歧义性

较之最小支撑树，最短路径的歧义性更难处理。首先，即便各边权重互异，从 s 到 v 的最短路径也未必唯一（习题[6-31]）。另外，当存在非正权重的边，并导致某个环路的总权值非正时，最短路径甚至无从定义。因此以下不妨假定，带权网络 G 内各边权重均大于于零。

■ 无环性

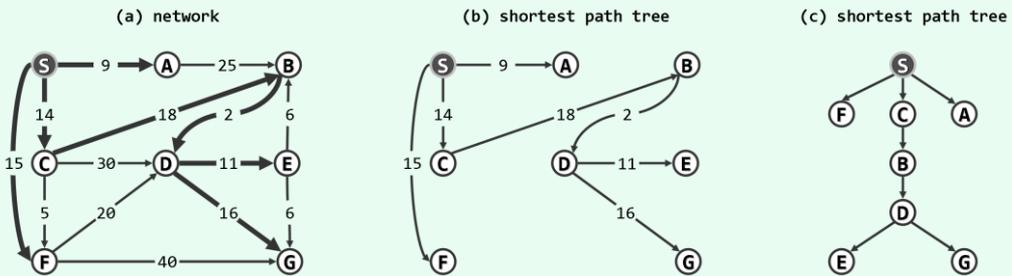


图6.23 有向带权图(a)，及其最短路径树(b)和(c)

在如图6.23(a)所示的任意带权网络中，考查从源点到其余顶点的最短路径（若有多条，任选其一）。于是由以上单调性，这些路径的并集必然不含任何（有向）回路。这就意味着，它们应如图(b)和图(c)所示，构成所谓的最短路径树（shortest-path tree）。

6.12.2 Dijkstra[®]算法

■ 最短路径子树序列

将顶点 u_i 到起点 s 的距离记作： $d_i = \text{dist}(s, u_i)$ ， $1 \leq i \leq n$ 。不妨设 d_i 按非降序排列，即 $d_i \leq d_j$ 当且仅当 $i \leq j$ 。于是与 s 自身相对应地必有： $u_1 = s$ 。

[®] E. W. Dijkstra (1930/05/11-2002/08/06)，杰出的计算机科学家，1972年图灵奖得主

在从最短路径树 T 中删除顶点 $\{u_{k+1}, u_{k+2}, \dots, u_n\}$ 及其关联各边之后,将残存的子图记作 T_k 。于是 $T_n = T$, T_1 仅含单个顶点 s 。实际上, T_k 必为一棵树。为验证这一点, 只需归纳证明 T_k 是连通的。为从 T_{k+1} 转到 T_k 而删除的顶点 u_{k+1} , 在 T_{k+1} 中必是叶节点。而根据最短路径的单调性, 作为 T_{k+1} 中距离最远的顶点, u_{k+1} 不可能拥有后代。

于是, 如上定义的子树 $\{T_1, T_2, \dots, T_n\}$, 便构成一个最短路径子树序列。

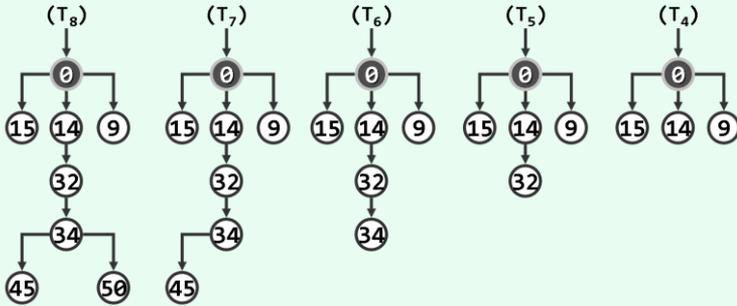


图6.24 最短路径子树序列

仍以图6.23中的最短路径树为例, 最后五棵最短路径子树, 如图6.24所示。

为便于相互比对, 其中每个顶点都注有其到 s 的距离。可见, 只需从 T_{k+1} 中删除距离最远的顶点 u_{k+1} , 即可将 T_{k+1} 转换至 T_k 。

■ 贪心迭代

颠倒上述思路可知, 只要能够确定 u_{k+1} , 便可反过来将 T_k 扩展为 T_{k+1} 。如此, 便可按照到 s 距离的非降次序, 逐一确定各个顶点 $\{u_1, u_2, \dots, u_n\}$, 同时得到各棵最短路径子树, 并得到最终的最短路径树 $T = T_n$ 。现在, 问题的关键就在于:

如何才能高效地找到 u_{k+1} ?

实际上, 由最短路径子树序列的上述性质, 每一个顶点 u_{k+1} 都是在 T_k 之外, 距离 s 最近者。若将此距离作为各顶点的优先级数, 则与最小支撑树的Prim算法类似, 每次将 u_{k+1} 加入 T_k 并将其拓展至 T_{k+1} 后, 需要且只需要更新那些仍在 T_{k+1} 之外, 且与 T_{k+1} 关联的顶点的优先级数。

可见, 该算法与Prim算法仅有一处差异: 考虑的是 u_{k+1} 到 s 的距离, 而不再是其到 T_k 的距离。

■ 实现

与Prim算法一样, Dijkstra算法也可纳入此前6.10.2节的优先级搜索算法框架。

为此, 每次由 T_k 扩展至 T_{k+1} 时, 可将 V_k 之外各顶点 u 到 V_k 的距离看作 u 的优先级数(若 u 与 V_k 内顶点均无联边, 则优先级数设为 $+\infty$)。如此, 每一最短跨越边 e_k 所对应的顶点 u_k , 都会因拥有最小的优先级数(或等价地, 最高的优先级)而被选中。

```

1 template <typename Tv, typename Te> struct DijkstraPU { //针对Dijkstra算法的顶点优先级更新器
2     virtual void operator()(Graph<Tv, Te>* g, int uk, int v) {
3         if (g->status(v) == UNDISCOVERED) //对于uk每一尚未被发现的邻接顶点v
4             if (g->priority(v) > g->priority(uk) + g->weight(uk, v)) { //按Dijkstra策略做松弛
5                 g->priority(v) = g->priority(uk) + g->weight(uk, v); //更新优先级(数)
6                 g->parent(v) = uk; //更新父节点
7             }
8     }
9 };

```

代码6.9 Dijkstra算法的顶点优先级更新器

唯一需要专门处理的是，在 u_k 和 e_k 加入 T_k 之后，应如何快速地更新 V_{k+1} 以外顶点的优先级数。实际上，只有与 u_k 邻接的那些顶点，才有可能在此后降低优先级数。因此与Prim算法一样，也可遍历 u_k 的每一个邻居 v ，只要边 u_kv 的权重加上 u_k 的优先级数，小于 v 当前的优先级数，即可将后者更新为前者。具体地，这一思路可落实为如代码6.9所示的优先级更新器。

■ 实例

依然以图6.21(a)中无向图为例，一次Dijkstra算法的完整执行过程如图6.25所示。

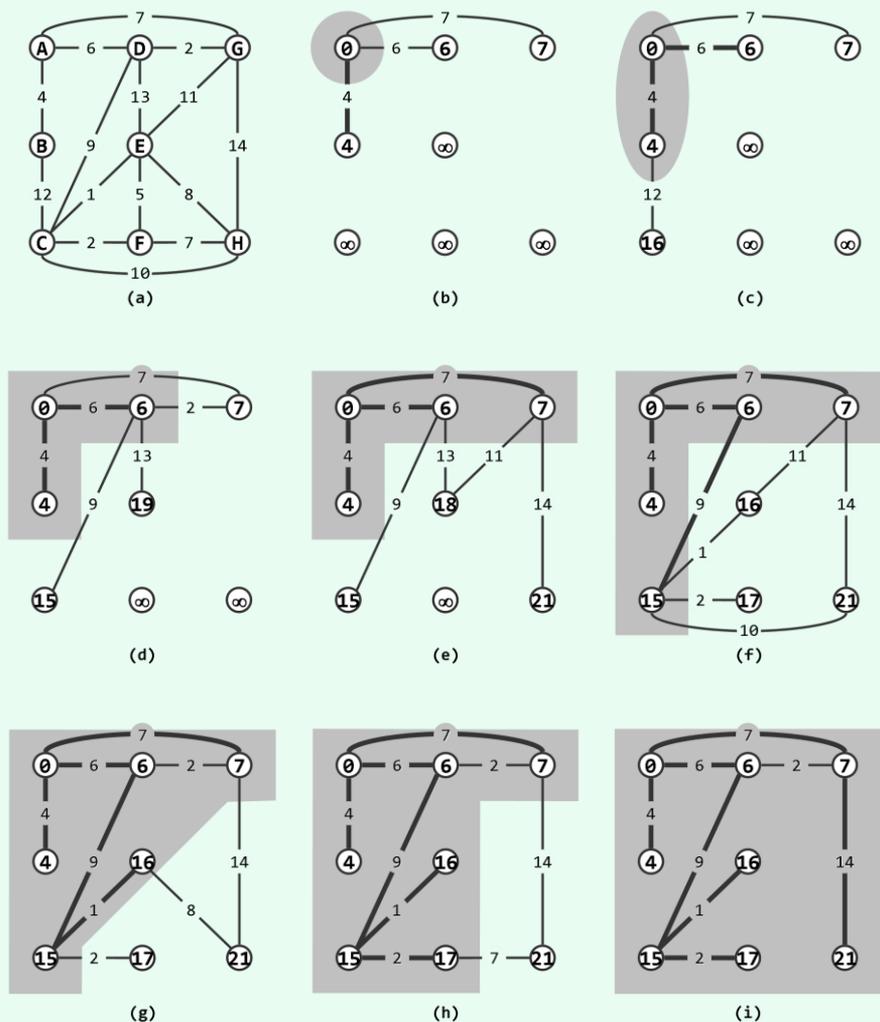


图6.25 Dijkstra算法示例（阴影区域示意不断扩展的子树 T_k ，粗线示意树边）

■ 复杂度

不难看出，以上顶点优先级更新器只需常数运行时间。同样根据6.10.3节对PFS搜索性能的分析结论，Dijkstra算法这一实现版本的时间复杂度为 $O(n^2)$ 。

作为PFS搜索的特例，Dijkstra算法的效率也可借助优先级队列进一步提高（习题[10-16]和[10-17]）。

第7章

搜索树

从本章开始，讨论的重点将逐步转入查找技术。实际上，此前的若干章节已经就此做过一些讨论，在向量与列表等结构中，甚至已经提供并实现了对应的ADT接口。然而遗憾的是，此前这类接口的总体效率均无法令人满意。

以31页代码2.1中的向量模板类Vector为例，其中针对无序和有序向量的查找，分别提供了find()和search()接口。前者的实现策略只不过是目标对象与向量内存放的对象逐个比对，故最坏情况下需要运行 $O(n)$ 时间。后者利用二分查找策略尽管可以确保在 $O(\log n)$ 时间内完成单次查找，但一旦向量本身需要修改，无论是插入还是删除，在最坏情况下每次仍需 $O(n)$ 时间。而就代码3.2中的列表模板类List(70页)而言，情况反而更糟：即便不考虑对列表本身的修改，无论find()或search()接口，在最坏情况或平均情况下都需要线性的时间。另外，基于向量或列表实现的栈和队列，一般地甚至不提供对任意成员的查找接口。总之，若既要求对象集合的组成可以高效率地动态调整，同时也要求能够高效率地查找，则以上线性结构均难以胜任。

那么，高效率的动态修改和高效率的静态查找，究竟能否同时兼顾？如有可能，又应该采用什么样的数据结构？接下来的两章，将逐步回答这两个层次的问题。

因为这部分内容所涉及的数据结构变种较多，它们各具特色、各有所长，也有其各自的适用范围，故按基本和高级两章分别讲解，相关内容之间的联系如图7.1所示。

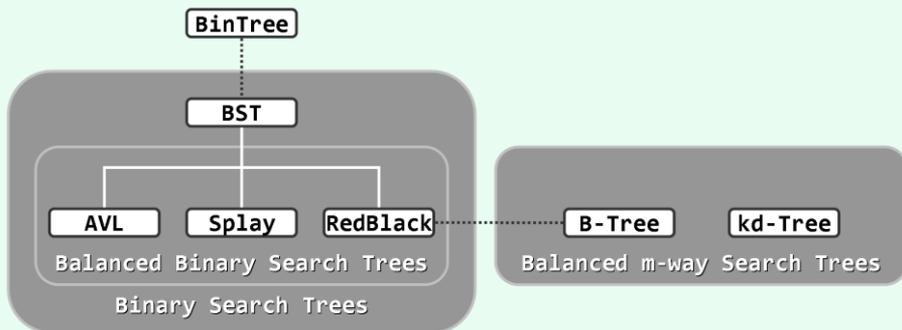


图7.1 第7章和第8章内容纵览

本章将首先介绍树式查找的总体构思、基本算法以及数据结构，通过对二分查找策略的抽象与推广，定义并实现二叉搜索树结构。尽管就最坏情况下的渐进时间复杂度而言，这一方法与此前相比并无实质的改进，但这部分内容依然十分重要——基于半线性的树形结构的这一总体构思，正是后续内容的立足点和出发点。比如，本章的后半部分将据此提出理想平衡和适度平衡等概念，并相应地引入和实现AVL树这一典型的平衡二叉搜索树。借助精巧的平衡调整算法，AVL树可以保证，即便是在最坏情况下，单次动态修改和静态查找也均可以在 $O(\log n)$ 时间内完成。这样，以上关于兼顾动态修改与静态查找操作效率的问题，就从正面得到了较为圆满的回答。接下来的第8章将在此基础上，针对更为具体的应用需求和更为精细的性能指标，介绍平衡搜索树家族的其它典型成员。

§ 7.1 查找

7.1.1 循关键词访问

所谓的查找或搜索（search），指从一组数据对象中找出符合特定条件者，这是构建算法的一种基本而重要的操作。其中的数据对象，统一地表示和实现为词条（entry）的形式；不同词条之间，依照各自的关键词（key）彼此区分。根据身份证号查找特定公民，根据车牌号查找特定车辆，根据国际统一书号查找特定图书，均属于根据关键词查找特定词条的实例。

请注意，与此前的“循秩访问”和“循位置访问”等完全不同，这一新的访问方式，与数据对象的物理位置或逻辑次序均无关。实际上，查找的过程与结果，仅仅取决于目标对象的关键词，故这种方式亦称作循关键词访问（call-by-key）。

7.1.2 词条

一般地，查找集内的元素，均可视作如代码7.1所示词条模板类Entry的实例化对象。

```

1 template <typename K, typename V> struct Entry { //词条模板类
2     K key; V value; //关键词、数值
3     Entry(K k = K(), V v = V()) : key(k), value(v) {}; //默认构造函数
4     Entry(Entry<K, V> const& e) : key(e.key), value(e.value) {}; //基于克隆的构造函数
5     bool operator<(Entry<K, V> const& e) { return key < e.key; } //比较器：小于
6     bool operator>(Entry<K, V> const& e) { return key > e.key; } //比较器：大于
7     bool operator==(Entry<K, V> const& e) { return key == e.key; } //判等器：等于
8     bool operator!=(Entry<K, V> const& e) { return key != e.key; } //判等器：不等于
9 }; //得益于比较器和判等器，从此往后，不必严格区分词条及其对应的关键词

```

代码7.1 词条模板类Entry

词条对象拥有成员变量key和value。前者作为特征，是词条之间比对和比较的依据；后者为实际的数据。若词条对应于商品的销售记录，则key为其条形码扫描码，value可以是其单价或库存量等信息。设置词条类只为保证查找算法接口的统一，故不必过度封装。

7.1.3 序与比较器

由代码7.1可见，通过重载对应的操作符，可将词条的判等与比较等操作转化为关键词的判等与比较（故在不致歧义时，往往无需严格区分词条及其关键词）。当然，这里隐晦地做了一个假定——所有词条构成一个全序关系，可以相互比对和比较。需指出的是，这一假定条件不见得总是满足。比如在人事数据库中，作为姓名的关键词之间并不具有天然的大小次序。另外，在任务相对单纯但更加讲求效率的某些场合，并不允许花费过多时间来维护全序关系，只能转而付出有限的代价维护一个偏序关系。后者的一个实例，即第10章将要介绍的优先级队列——根据其ADT接口规范，只需高效地跟踪全局的极值元素，其它元素一般无需直接访问。

实际上，任意词条之间可相互比较大小，也是此前（2.6.5节至2.6.8节）有序向量得以定义，以及二分查找算法赖以成立的基本前提。以下将基于同样的前提，讨论如何将二分查找的技巧融入二叉树结构，进而借助二叉搜索树以实现高效的查找。

§ 7.2 二叉搜索树

7.2.1 顺序性

若二叉树中各节点所对应的词条之间支持大小比较，则在不致歧义的情况下，我们可以不必严格区分树中的节点、节点对应的词条以及词条内部所存的关键码。

如图7.2所示，在所谓的二叉搜索树（binary search tree）中，处处都满足顺序性：

任一节点 r 的左（右）子树中，所有节点（若存在）均不大于（不小于） r

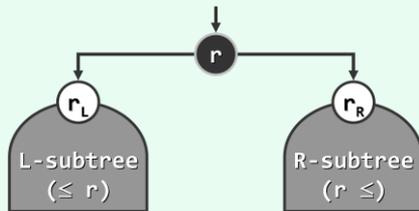


图7.2 二叉搜索树即处处满足顺序性的二叉树

为回避边界情况，这里不妨暂且假定所有节点互不相等。于是，上述顺序性便可简化表述为：

任一节点 r 的左（右）子树中，所有节点（若存在）均小于（大于） r

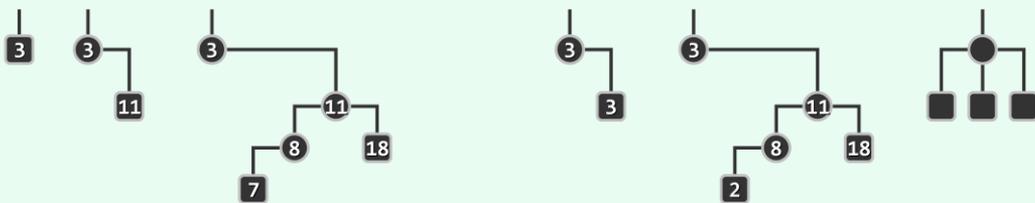
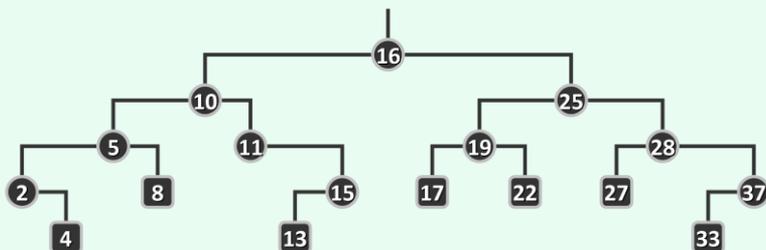


图7.3 二叉搜索树的三个实例（左），以及三个反例（右）

当然，在实际应用中，对相等元素的禁止既不自然也不必要。读者可在本书所给代码的基础上继续扩展，使得二叉搜索树的接口支持相等词条的同时并存（习题[7-10]）。比如，在去掉这一限制之后，图7.3中原来的第一个反例，将转而为合法的二叉搜索树。

7.2.2 中序遍历序列



2 4 5 8 10 11 13 15 16 17 19 22 25 27 28 33 37

图7.4 二叉搜索树（上）的中序遍历序列（下），必然单调非降

顺序性是一项很强的条件。实际上，搜索树中节点之间的全序关系，已完全“蕴含”于这一

条件之中。以如图7.4所示的二叉搜索树为例，只需采用5.4.3节的算法对该树做一次中序遍历，即可将该树转换为一个线性序列，且该序列中的节点严格按照其大小次序排列。

这一现象，并非巧合。借助数学归纳法，可以证明更具一般性的结论（习题[7-1]）：

任何一棵二叉树是二叉搜索树，当且仅当其中序遍历序列单调非降

7.2.3 BST模板类

既然二叉搜索树属于二叉树的特例，故自然可以基于BinTree模板类（121页代码5.5），派生出如代码7.2所示的BST模板类。

```

1 #include "../BinTree/BinTree.h" //引入BinTree
2
3 template <typename T> class BST : public BinTree<T> { //由BinTree派生BST模板类
4 protected:
5     BinNodePosi(T) _hot; //BST::search()最后访问的非空（除非树空）的节点位置
6     BinNodePosi(T) connect34( //按照“3 + 4”结构，联接3个节点及四棵子树
7         BinNodePosi(T), BinNodePosi(T), BinNodePosi(T),
8         BinNodePosi(T), BinNodePosi(T), BinNodePosi(T), BinNodePosi(T));
9     BinNodePosi(T) rotateAt(BinNodePosi(T) x); //对x及其父亲、祖父做统一旋转调整
10 public: //基本接口：以virtual修饰，强制要求所有派生类（BST变种）根据各自的规则对其重写
11     virtual BinNodePosi(T) & search(const T& e); //查找
12     virtual BinNodePosi(T) insert(const T& e); //插入
13     virtual bool remove(const T& e); //删除
14 };

```

代码7.2 由BinTree派生的二叉搜索树模板类BST

可见，在继承原模板类BinTree的同时，BST内部也继续沿用了二叉树节点模板类BinNode。

按照二叉搜索树的接口规范定义，这里新增三个标准的对外接口search()、insert()和remove()，分别对应于基本的查找、插入和删除操作。这三个标准接口的调用参数，都是属于元素类型T的对象引用——这正是此类结构“循关键词访问”方式的具体体现。

另外，既然这些操作接口的语义均涉及词条的大小和相等关系，故这里也假定基本元素类型T或者直接支持比较和判等操作，或者已经重载过对应的操作符。

本章以及下一章还将以BST为基类，进一步派生出二叉搜索树的多个变种。无论哪一变种，既必须支持上述三个基本接口，同时在内部的具体实现方式又有所不同。因此，它们均被定义为虚成员函数，从而强制要求派生的所有变种，根据各自的规则对其重写。

7.2.4 查找算法及其实现

■ 算法

二叉搜索树的查找算法，亦采用了减而治之的思路与策略，其执行过程可描述为：

从树根出发，逐步地缩小查找范围，直到发现目标（成功）或缩小至空树（失败）

例如，在图7.5中查找关键词22的过程如下。

首先, 经与根节点16比较确认目标关键码更大, 故深入右子树25递归查找; 经比较发现目标关键码更小, 故继续深入左子树19递归查找; 经再次比较确认目标关键码更大后, 深入右子树22递归查找; 最终在节点22处匹配, 查找成功。

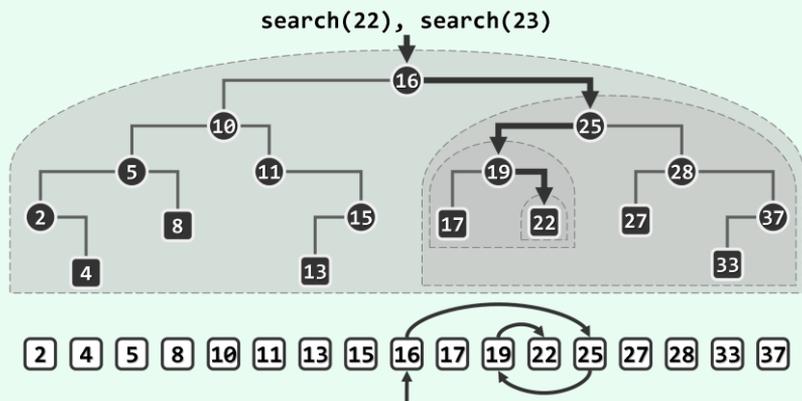


图7.5 二叉搜索树的查找过程 (查找所经过的通路, 以粗线条示意)

当然, 查找未必成功。比如针对关键码20的查找也会经过同一查找通路并抵达节点22, 但在因目标关键码更小而试图继续向左深入时发现左子树为空^①, 至此即可确认查找失败。

一般地, 在上述查找过程中, 一旦发现当前节点为NULL, 即说明查找范围已经缩小至空, 查找失败; 否则, 视关键码比较结果, 向左 (更小) 或向右 (更大) 深入, 或者报告成功 (相等)。

对照中序遍历序列可见, 整个过程与有序向量的二分查找过程等效, 故可视作后者的推广。

■ searchIn()算法与search()接口

一般地, 在子树v中查找关键码e的过程, 可实现为如代码7.3所示的算法searchIn()。

```
1 template <typename T> //在以v为根的 (AVL、SPLAY、rbTree等) BST子树中查找关键码e
2 static BinNodePosi(T) & searchIn (BinNodePosi(T)& v, const T& e, BinNodePosi(T)& hot) {
3     if (!v || (e == v->data)) return v; //递归基: 在节点v (或假想的通配节点) 处命中
4     hot = v; //一般情况: 先记下当前节点, 然后再
5     return searchIn(((e < v->data) ? v->lChild : v->rChild), e, hot); //深入一层, 递归查找
6 } //返回时, 返回值指向命中节点 (或假想的通配哨兵), hot指向其父亲 (退化时为初始值NULL)
```

代码7.3 二叉搜索树searchIn()算法的递归实现

节点的插入和删除操作, 都需要首先调用查找算法, 并根据查找结果确定后续的处理方式。因此, 这里以引用方式传递 (子) 树根节点, 以为后续操作提供必要的信息。

如代码7.4所示, 通过调用searchIn()算法, 即可实现二叉搜索树的标准接口search()。

```
1 template <typename T> BinNodePosi(T) & BST<T>::search(const T& e) //在BST中查找关键码e
2 { return searchIn(_root, e, _hot = NULL); } //返回目标节点位置的引用, 以便后续插入、删除操作
```

代码7.4 二叉搜索树search()接口

^① 此类空节点通常对应于空孩子指针或引用, 也可假想地等效为“真实”节点, 后一方式不仅可简化算法描述以及退化情况的处理, 也可直观地解释 (B-树之类) 纵贯多级存储层次的搜索树。故在后一场合, 空节点也称作外部节点 (external node), 并等效地当作叶节点的“孩子”。这里暂采用前一方式, 故空节点不在插图中出现。

■ 语义约定

以上查找算法之所以如此实现，是为了统一并简化后续不同搜索树的各种操作接口的实现。其中的技巧，主要体现于返回值和`hot`变量（即`BinTree`对象内部的`_hot`变量）的语义约定。

若查找成功，则`searchIn()`以及`search()`的返回值都将如图7.6(a)所示，指向一个关键码为`e`且真实存在的节点；若查找失败，则返回值的数值虽然为`NULL`，但是它作为引用将如图(b)所示，指向最后一次试图转向的空节点。对于后一情况，不妨假想地将此空节点转换为一个数值为`e`的哨兵节点——如此，无论成功与否，查找的返回值总是等效地指向“命中节点”。

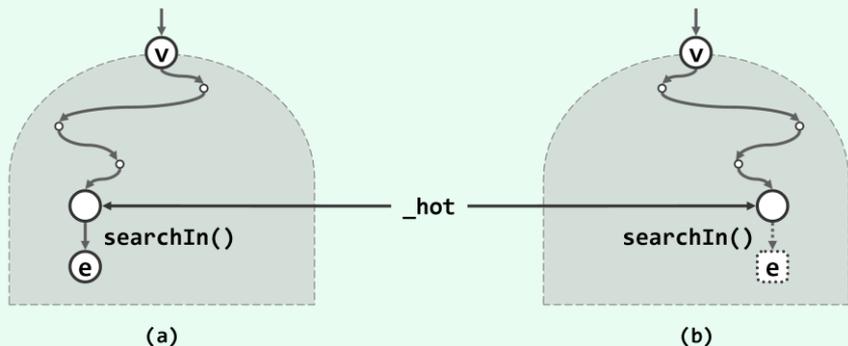


图7.6 `searchIn()`算法对返回值和`_hot`的语义定义：(a) 查找成功；(b) 查找失败

在调用`searchIn()`算法之前，`search()`接口首先将内部变量`_hot`初始化为`NULL`，然后作为引用型参数`hot`传递给`searchIn()`。在整个查找的过程中，`hot`变量始终指向当前节点的父亲。因此在算法返回时，按照如上定义，`_hot`亦将统一指向“命中节点”的父亲。

请注意，`_hot`节点是否拥有另一个孩子，与查找成功与否无关。查找成功时，节点`e`可能是叶子，也可能是内部节点；查找失败时，假想的哨兵`e`等效于叶节点，但可能有兄弟。

同时也请读者对照代码7.3验证，即便在退化的情况下（比如查找终止并返回于树根处），算法`searchIn()`的输出依然符合以上语义约定。

在7.2.6节将要介绍的删除操作中，也首先要进行查找（不妨设查找成功）。按照如上语义，命中节点必然就是待摘除节点；该节点与其父亲`_hot`，联合指示了删除操作的位置。7.2.5节将要介绍的插入操作，亦首先需做查找（不妨设查找失败）。按照如上语义，假想的“命中节点”也就是待插入的新节点；`_hot`所指向的，正是该节点可行的接入位置。

■ 效率

在二叉搜索树的每一层，查找算法至多访问一个节点，且只需常数时间，故总体所需时间应线性正比于查找路径的长度，或最终返回节点的深度。在最好情况下，目标关键码恰好出现在树根处（或其附近），此时只需 $O(1)$ 时间。然而不幸的是，对于规模为 n 的二叉搜索树，深度在最坏情况下可达 $O(n)$ 。比如，当该树退化为（接近于）一条单链时，发生此类情况的概率将很高。此时的单次查找可能需要线性时间并不奇怪，因为实际上这样的一棵“二分”搜索树，已经退化成了一个不折不扣的一维有序列表，而此时的查找则等效于顺序查找。

由此我们可得到启示：若要控制单次查找在最坏情况下的运行时间，须从控制二叉搜索树的高度入手。后续章节将要讨论的平衡二叉搜索树，正是基于这一思路而做的改进。

7.2.5 插入算法及其实现

■ 算法

为了在二叉搜索树中插入一个节点，首先需要利用查找算法`search()`确定插入的位置及方向，然后才能将新节点作为叶子插入。

以如图7.7(a)所示的二叉搜索树为例。若欲插入关键码40，则在执行`search(40)`之后，如图(b)所示，`_hot`将指向比较过的最后一个节点46，同时返回其左孩子（此时为空）的位置。于是接下来如图(c)所示，只需创建新节点40，并将其作为46的左孩子接入，拓扑意义上的节点插入即告完成。不过，为保持二叉搜索树作为数据结构的完整性和一致性，还需从节点`_hot`（46）出发，自底而上地逐个更新新节点40历代祖先的高度。

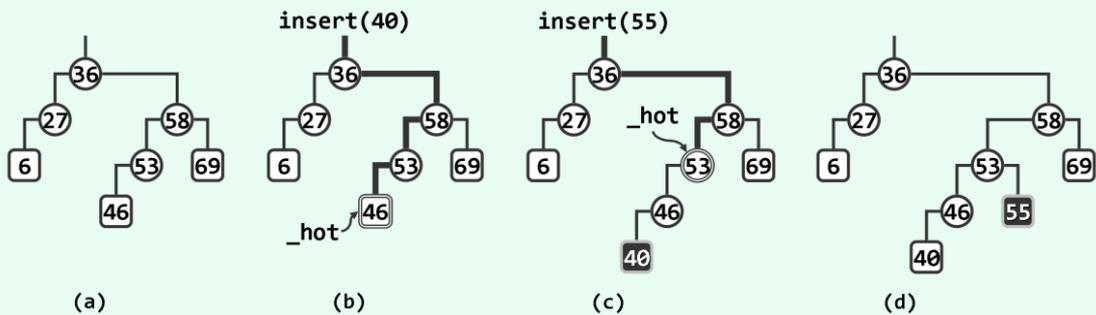


图7.7 二叉搜索树节点插入算法实例

接下来若欲插入关键码55，则在执行`search(55)`之后如图(c)所示，`_hot`将指向比较过的最后一个节点53，同时返回其右孩子（此时为空）的位置。于是如图(d)所示，创建新节点55，并将其作为53的右孩子接入。当然，此后同样需从节点`_hot`出发，逐代更新祖先的高度。

■ `insert()`接口的实现

一般地，在二叉搜索树中插入新节点`e`的过程，可描述为代码7.5中的函数`insert()`。

```

1 template <typename T> BinNodePosi(T) BST<T>::insert(const T& e) { //将关键码e插入BST树中
2     BinNodePosi(T) & x = search(e); if (x) return x; //确认目标节点不存在（留意对_hot的设置）
3     x = new BinNode<T>(e, _hot); //创建新节点x：以e为关键码，以_hot为父
4     _size++; //更新全树规模
5     updateHeightAbove(x); //更新x及其历代祖先的高度
6     return x; //新插入的节点，必为叶子
7 } //无论e是否存在于原树中，返回时总有x->data == e

```

代码7.5 二叉搜索树`insert()`接口

首先调用`search()`查找`e`。若返回位置`x`非空，则说明已有雷同节点，插入操作失败。否则，`x`必是`_hot`节点的某一空孩子，于是创建这个孩子并存入`e`。此后，更新全树的规模记录，并调用代码5.6中的`updateHeightAbove()`更新`x`及其历代祖先的高度。

注意，按照以上实现方式，无论插入操作成功与否，都会返回一个非空位置，且该处的节点与拟插入的节点相等。如此可以确保一致性，以简化后续的操作。另外，也请对照代码7.3和代码7.4中的查找算法，体会这里对“首个节点插入空树”等特殊情况的处理手法。

效率

由上可见, 节点插入操作所需的时间, 主要消耗于对算法`search()`及`updateHeightAbove()`的调用。后者与前者一样, 在每一层次至多涉及一个节点, 仅消耗 $O(1)$ 时间, 故其时间复杂度也同样取决于新节点的深度, 在最坏情况下不超过全树的高度。

7.2.6 删除算法及其实现

为从二叉搜索树中删除节点, 首先也需要调用算法`BST::search()`, 判断目标节点是否的确存在于树中。若存在, 则需返回其位置, 然后方能相应地具体实施删除操作。

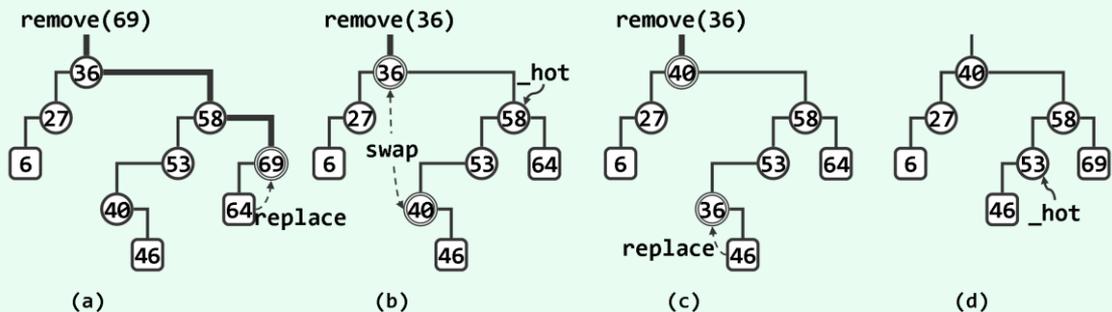


图7.8 二叉搜索树节点删除算法实例

单分支情况

以如图7.8(a)所示二叉搜索树为例。若欲删除节点69, 需首先通过`search(69)`定位待删除节点(69)。因该节点的右子树为空, 故只需如图(b)所示, 将其替换为左孩子(64), 则拓扑意义上的节点删除即告完成。当然, 为保持二叉搜索树作为数据结构的完整性和一致性, 还需更新全树的规模记录, 释放被摘除的节点(69), 并自下而上地逐个更新替代节点(64)历代祖先的高度。注意, 首个需要更新高度的祖先(58), 恰好由`_hot`指示。

不难理解, 对于没有左孩子的目标节点, 也可以对称地予以处理。当然, 以上同时也已涵盖了左、右孩子均不存在(即目标节点为叶节点)的情况。

那么, 当目标节点的左、右孩子双全时, 删除操作又该如何实施呢?

双分支情况

继续上例, 设拟再删除二度节点36。如图7.8(b)所示, 首先调用`BinNode::succ()`算法, 找到该节点的直接后继(40)。然后, 只需如图(c)所示交换二者的数据项, 则可将后继节点等效地视作待删除的目标节点。不难验证, 该后继节点必无左孩子, 从而相当于转化为此前相对简单的情况。于是最后可如图(d)所示, 将新的目标节点(36)替换为其右孩子(46)。

请注意, 在中途互换数据项之后, 这一局部如图(c)所示曾经一度并不满足顺序性。但这并不要紧——不难验证, 在按照上述方法完成整个删除操作之后, 全树的顺序性必然又将恢复。

同样地, 除了更新全树规模记录和释放被摘除节点, 此时也要更新一系列祖先节点的高度。不难验证, 此时首个需要更新高度的祖先(53), 依然恰好由`_hot`指示。

`remove()`

一般地, 删除关键码`e`的过程, 可描述为如代码7.6所示的函数`remove()`。

```

1 template <typename T> bool BST<T>::remove(const T& e) { //从BST树中删除关键码e
2     BinNodePosi(T) & x = search(e); if (!x) return false; //确认目标节点存在 (留意对_hot的设置)
3     removeAt(x, _hot); _size--; //实施删除
4     updateHeightAbove(_hot); //更新_hot及其历代祖先的高度
5     return true;
6 } //删除成功与否, 由返回值指示

```

代码7.6 二叉搜索树remove()接口

首先调用search()查找e。若返回位置x为空, 则说明树中不含目标节点, 故删除操作随即可以失败返回。否则, 调用removeAt()删除目标节点x。同样, 此后还需更新全树的规模, 并调用函数updateHeightAbove(_hot) (121页代码5.6), 更新被删除节点历代祖先的高度。

■ removeAt()

这里, 实质的删除操作由removeAt()负责分情况实施, 其具体实现如代码7.7所示。

```

1 /*****
2  * BST节点删除算法: 删除位置x所指的节点 (全局静态模板函数, 适用于AVL、Splay、RedBlack等各种BST)
3  * x由此前的查找确定, 并经确认非NULL后方调用本函数, 故必删除成功
4  * 与searchIn不同, 调用之前不必将hot置空
5  * 返回值指向实际被删除节点的接替者, hot指向实际被删除节点的父亲——二者均有可能是NULL
6  *****/
7 template <typename T> static BinNodePosi(T) removeAt(BinNodePosi(T) & x, BinNodePosi(T) & hot) {
8     BinNodePosi(T) w = x; //实际被摘除的节点, 初值同x
9     BinNodePosi(T) succ = NULL; //实际被删除节点的接替者
10    if (!HasLChild(*x)) //若*x的左子树为空, 则可
11        succ = x = x->rChild; //直接将*x替换为其右子树
12    else if (!HasRChild(*x)) //若右子树为空, 则可
13        succ = x = x->lChild; //对称地处理——注意: 此时succ != NULL
14    else { //若左右子树均存在, 则选择x的直接后继作为实际被摘除节点, 为此需要
15        w = w->succ(); // (在右子树中) 找到*x的直接后继*w
16        swap(x->data, w->data); //交换*x和*w的数据元素
17        BinNodePosi(T) u = w->parent;
18        ((u == x) ? u->rChild : u->lChild) = succ = w->rChild; //隔离节点*w
19    }
20    hot = w->parent; //记录实际被删除节点的父亲
21    if (succ) succ->parent = hot; //并将被删除节点的接替者与hot相联
22    release(w->data); release(w); return succ; //释放被摘除节点, 返回接替者
23 }

```

代码7.7 二叉搜索树removeAt()算法

■ 效率

删除操作所需的时间, 主要消耗于对search()、succ()和updateHeightAbove()的调用。在树中的任一高度, 它们至多消耗 $O(1)$ 时间。故总体的渐进时间复杂度, 亦不超过全树的高度。

§ 7.3 平衡二叉搜索树

7.3.1 树高与性能

根据7.2节对二叉搜索树的实现与分析，`search()`、`insert()`和`remove()`等主要接口的运行时间，均线性正比于二叉搜索树的高度。而在最坏情况下，二叉搜索树可能彻底地退化为列表，此时的查找效率甚至会降至 $\mathcal{O}(n)$ ，线性正比于数据集的规模。因此，若不能有效地控制树高，则就实际的性能而言，较之此前的向量和列表，二叉搜索树将无法体现出明显优势。

那么，出现上述最坏（或较坏）情况的概率有多大？或者，至少从平均复杂度的角度来看，二叉搜索树的性能是否还算令人满意？

以下，将按照两种常用的随机统计口径，就二叉搜索树的平均性能做一比较。

■ 随机生成

不妨设各节点对应于 n 个互异关键字 $\{e_1, e_2, \dots, e_n\}$ 。于是按照每一排列：

$$\sigma = (e_{i_1}, e_{i_2}, \dots, e_{i_n})$$

只要从空树开始，通过依次执行`insert(e_{i_k})`，即可得到这 n 个关键字的一棵二叉搜索树 $T(\sigma)$ 。与随机排列 σ 如此相对应的二叉搜索树 $T(\sigma)$ ，称作由 σ “随机生成”（randomly generated）。

图7.9以三个关键字 $\{1, 2, 3\}$ 为例，列出了由其所有排列所生成的二叉搜索树。

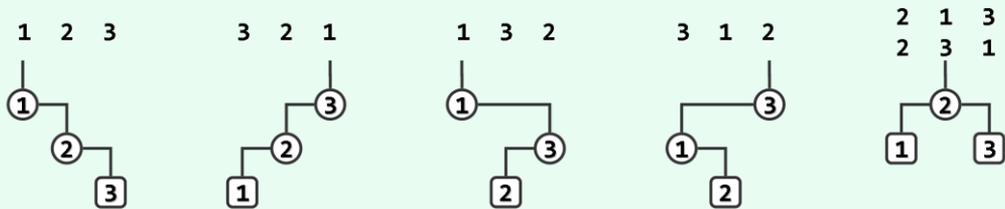


图7.9 由三个关键字 $\{1, 2, 3\}$ 的6种全排列生成的二叉搜索树

显然，任意的 n 个互异关键字，都可以构成 $n!$ 种全排列。若各排列作为输入序列的概率均等，则只要将它们各自所生成二叉搜索树的平均查找长度进行平均，即可在一定程度上反映二叉搜索树的平均查找性能。可以证明^{[29][30]}，在这一随机意义下，二叉搜索树的平均高度为 $\Theta(\log n)$ 。

■ 随机组成

另一随机策略是，假定 n 个互异节点同时给定，然后在遵守顺序性的前提下，随机确定它们之间的拓扑联接。如此，称二叉搜索树由这组节点“随机组成”（randomly composed）。

实际上，由 n 个互异节点组成的二叉搜索树，总共可能有 $(2n)!/n!/(n+1)!$ 棵（习题[7-2]）。若这些树出现的概率均等，则通过对其高度做平均可知^[30]，平均查找长度为 $\Theta(\sqrt{n})$ 。

■ 比较

前一口径的 $\Theta(\log n)$ 与后一口径的 $\Theta(\sqrt{n})$ 之间，就渐进意义而言有实质的差别。原因何在？

读者也许已经发现，同一组关键字的不同排列所生成的二叉搜索树，未必不同。仍以图7.9为例，排列 $(2, 1, 3)$ 与 $(2, 3, 1)$ 生成的，实际上就是同一棵二叉搜索树。而在按照前一口径估计平均树高时，这棵树被统计了两次。实际上一般而言，越是平衡的树，被统计的次数亦越多。从这个角度讲，前一种平均的方式，在无形中高估了二叉搜索树的平均性能。因此相对而言，按照后一口径所得的估计值更加可信。

■ 树高与平均树高

实际上，即便按照以上口径统计出平均树高，仍不足以反映树高的随机分布情况。实际上，树高较大情况的概率依然可能很大。另外，理想的随机并不常见，实际应用中的情况恰恰相反，一组关键码往往会按照（接近）单调次序出现，因此频繁出现极高的搜索树也不足为怪。

另外，若`removeAt()`操作的确如代码7.7所示，总是固定地将待删除的二度节点与其直接后继交换，则随着操作次数的增加，二叉搜索树向左侧倾斜的趋势将愈发明显（习题[7-9]）。

7.3.2 理想平衡与适度平衡

■ 理想平衡

既然二叉搜索树的性能主要取决于高度，故在节点数目固定的前提下，应尽可能地降低高度。相应地，应尽可能地使兄弟子树的高度彼此接近，即全树尽可能地平衡。当然，包含 n 个节点的二叉树，高度不可能小于 $\lfloor \log_2 n \rfloor$ （习题[7-3]）。若树高恰好为 $\lfloor \log_2 n \rfloor$ ，则称作理想平衡树。例如，如图5.26所示的完全二叉树，甚至如图5.27所示的满二叉树，均属此列。

遗憾的是，完全二叉树“叶节点只能出现于最底部两层”的限制过于苛刻。略做简单的组合统计不难发现，相对于二叉树所有可能的形态，此类二叉树所占比例极低；而随着二叉树规模的增大，这一比例还将继续锐减（习题[7-2]）。由此可见，从算法可行性的角度来看，有必要依照某种相对宽松的标准，重新定义二叉搜索树的平衡性。

■ 适度平衡

在渐进意义下适当放松标准之后的平衡性，称作适度平衡。

幸运的是，适度平衡的标准的确存在。比如，若将树高限制为“渐进地不超过 $\theta(\log n)$ ”，则下节将要介绍的AVL树，以及下一章将要介绍的伸展树、红黑树、kd-树等，都属于适度平衡。这些变种，因此也都可归入平衡二叉搜索树（balanced binary search tree, BBST）之列。

7.3.3 等价变换

■ 等价二叉搜索树

如图7.10所示，若两棵二叉搜索树的中序遍历序列相同，则称它们彼此等价；反之亦然。

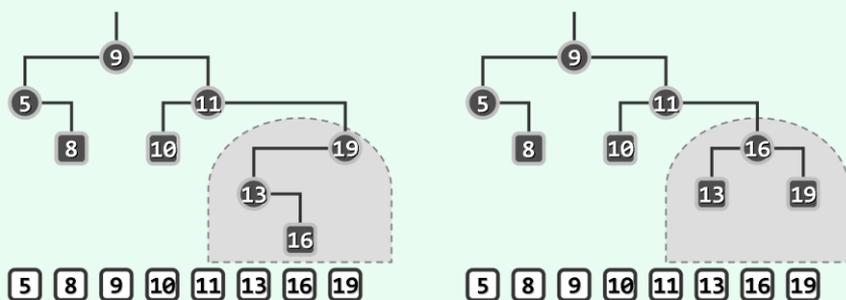


图7.10 由同一组共11个节点组成，相互等价的两棵二叉搜索树（二者在拓扑上的差异，以阴影圈出）

由该图也不难看出，虽然等价二叉搜索树中各节点的垂直高度可能有所不同，但水平次序完全一致。这一特点可概括为“上下可变，左右不乱”，它也是以下等价变换的基本特性。

■ 局部性

平衡二叉搜索树的适度平衡性,都是通过对树中每一局部增加某种限制条件来保证的。比如,在红黑树中,从树根到叶节点的通路,总是包含一样多的黑节点;在AVL树中,兄弟节点的高度相差不过1。事实上,这些限制条件设定得非常精妙,除了适度平衡性,还具有如下局部性:

- 1) 经过单次动态修改操作后,至多只有 $O(1)$ 处局部不再满足限制条件
- 2) 总可在 $O(\log n)$ 时间内,使这 $O(1)$ 处局部(以至全树)重新满足限制条件

这就意味着:刚刚失去平衡的二叉搜索树,必然可以迅速转换为一棵等价的平衡二叉搜索树。等价二叉搜索树之间的上述转换过程,也称作等价变换。

这里的局部性至关重要。比如,尽管任何二叉搜索树都可等价变换至理想平衡的完全二叉树,然而鉴于二者的拓扑结构可能相去甚远,在最坏情况下我们为此将不得不花费 $O(n)$ 时间。反观图7.10中相互等价的两棵二叉搜索树,右侧属于AVL树,而左侧不是。鉴于二者的差异仅限于某一局部(阴影区域),故可轻易地将后者转换为前者。

那么,此类局部性的失衡,具体地可以如何修复?如何保证修复的速度?

7.3.4 旋转调整

最基本的修复手段,就是通过围绕特定节点的旋转,实现等价前提下的局部拓扑调整。

■ zig和zag

如图7.11(a)所示,设 c 和 Z 是 v 的左孩子、右子树, X 和 Y 是 c 的左、右子树。所谓以 v 为轴的zig旋转,即如图(b)所示,重新调整这两个节点与三棵子树的联接关系:将 X 和 v 作为 c 的左子树、右孩子, Y 和 Z 分别作为 v 的左、右子树。

可见,尽管局部结构以及子树根均有变化,但中序遍历序列仍是 $\{ \dots, X, c, Y, v, Z, \dots \}$,故zig旋转属于等价变换。

对称地如图7.12(a)所示,设 X 和 c 是 v 的左子树、右孩子, Y 和 Z 分别是 c 的左、右子树。所谓以 v 为轴的zag旋转,即如图(b)所示,重新调整这两个节点与三棵子树的联接关系:将 v 和 Z 作为 c 的左孩子、右子树, X 和 Y 分别作为 v 的左、右子树。

同样地,旋转之后中序遍历序列依然不变,故zag旋转亦属等价变换。

■ 效率与效果

zig和zag旋转均属局部操作,仅涉及常数个节点及其之间的联接关系,故均可在常数时间内完成。正因如此,在后面实现各种二叉搜索树平衡化算法时,它们都是支撑性的基本操作。

就与树相关的指标而言,经一次zig或zag旋转之后,节点 v 的深度加一,节点 c 的深度减一;这一局部子树(乃至全树)的高度可能发生变化,但上、下幅度均不超过一层。

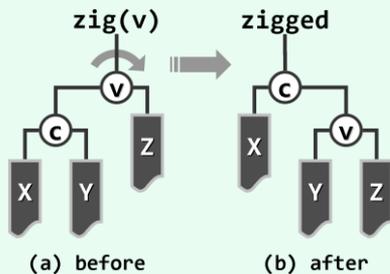


图7.11 zig(v): 顺时针旋转

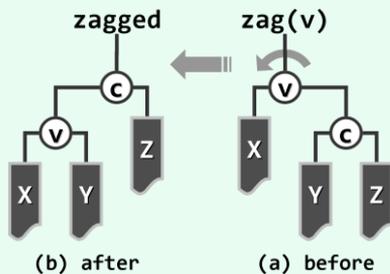


图7.12 zag(v): 逆时针旋转

§ 7.4 AVL树

通过合理设定适度平衡的标准，并借助以上等价变换，AVL树（AVL tree）^②可以实现近乎理想的平衡。在渐进意义下，AVL树可始终将其高度控制在 $\mathcal{O}(\log n)$ 以内，从而保证每次查找、插入或删除操作，均可在 $\mathcal{O}(\log n)$ 的时间内完成。

7.4.1 定义及性质

■ 平衡因子

任一节点 v 的平衡因子（balance factor）定义为“其左、右子树的高度差”，即

$$\text{balFac}(v) = \text{height}(\text{lc}(v)) - \text{height}(\text{rc}(v))$$

请注意，本书中空树高度取-1，单节点子树（叶节点）高度取0，与以上定义没有冲突。

所谓AVL树，即平衡因子受限的二叉搜索树——其中各节点平衡因子的绝对值均不超过1。

■ 接口定义

基于BST模板类（185页代码7.2），可直接派生出AVL模板类如代码7.8所示。

```
1 #include "../BST/BST.h" //基于BST实现AVL树
2 template <typename T> class AVL : public BST<T> { //由BST派生AVL树模板类
3 public:
4     BinNodePosi(T) insert(const T& e); //插入（重写）
5     bool remove(const T& e); //删除（重写）
6 // BST::search()等其余接口可直接沿用
7 };
```

代码7.8 基于BST定义的AVL树接口

可见，这里直接沿用了BST模板类的search()等接口，并根据AVL树的重平衡规则与算法，重写了insert()和remove()接口，其具体实现将在后续章节陆续给出。

另外，为简化对节点平衡性的判断，算法实现时可借用以下宏定义：

```
1 #define Balanced(x) (stature((x).lChild) == stature((x).rChild)) //理想平衡条件
2 #define BalFac(x) (stature((x).lChild) - stature((x).rChild)) //平衡因子
3 #define AvlBalanced(x) ((-2 < BalFac(x)) && (BalFac(x) < 2)) //AVL平衡条件
```

代码7.9 用于简化AVL树算法描述的宏

■ 平衡性

在完全二叉树中各节点的平衡因子非0即1，故完全二叉树必是AVL树；不难举例说明，反之不然。完全二叉树的平衡性可以自然保证（习题[7-3]），那AVL树的平衡性又如何呢？可以证明，高度为 h 的AVL树至少包含 $\text{fib}(h + 3) - 1$ 个节点。为此需做数学归纳。

作为归纳基，当 $h = 0$ 时， T 中至少包含 $\text{fib}(3) - 1 = 2 - 1 = 1$ 个节点，命题成立；当 $h = 1$ 时， T 中至少包含 $\text{fib}(4) - 1 = 3 - 1 = 2$ 个节点，命题也成立。

^② 由G. M. Adelson-Velsky和E. M. Landis与1962年发明^[36]，并以他们名字的首字母命名

假设对于高度低于 h 的任何AVL树，以上命题均成立。现考查高度为 h 的所有AVL树，并取 S 为其中节点最少的任何一棵（请注意，这样的 S 可能不止一棵）。

如图7.13，设 S 的根节点为 r ， r 的左、右子树分别为 S_L 和 S_R ，将其高度记作 h_L 和 h_R ，其规模记作 $|S_L|$ 和 $|S_R|$ 。于是就有：

$$|S| = 1 + |S_L| + |S_R|$$

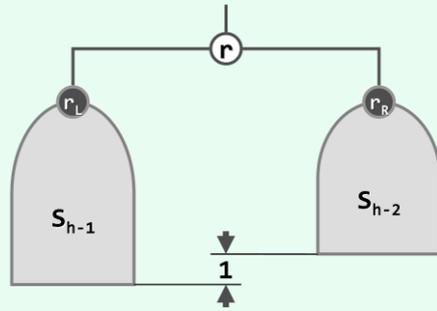


图7.13 在高度固定为 h 的前提下，节点最少的AVL树

作为 S 的子树， S_L 和 S_R 也都是AVL树，而且高度不超过 $h - 1$ 。进一步地，在考虑到AVL树有关平衡因子的要求的同时，既然 S 中的节点数最少，故 S_L 和 S_R 的高度只能是一个为 $h - 1$ ，另一个为 $h - 2$ 不失一般性，设 $h_L = h - 1$ ， $h_R = h - 2$ 。而且，在所有高度为 h_L (h_R) 的AVL树中， S_L (S_R) 中包含的节点也应该最少。因此，根据归纳假设，可得如下关系：

$$|S| = 1 + (\text{fib}(h + 2) - 1) + (\text{fib}(h + 1) - 1)$$

根据Fibonacci数列的定义，可得：

$$|S| = \text{fib}(h + 2) + \text{fib}(h + 1) - 1 = \text{fib}(h + 3) - 1$$

总而言之，高度为 h 的AVL树的确至少包含 $\text{fib}(h + 3) - 1$ 个节点。于是反过来，包含 n 个节点的AVL树的高度应为 $O(\log n)$ 。因此就渐进意义而言，AVL树的确是平衡的。

■ 失衡与重平衡

AVL树与常规的二叉搜索树一样，也应支持插入、删除等动态修改操作。但经过这类操作之后，节点的高度可能发生变化，以致于不再满足AVL树的条件。

以插入操作为例，考查图7.14(b)中的AVL树，其中的关键码为字符类型。现按代码7.5中二叉搜索树的通用算法`BST::insert()`插入关键码'M'，于是如图(c)所示，节点'N'、'R'和'G'都将失衡。类似地，按代码7.6中二叉搜索树的通用算法`BST::remove()`摘除关键码'Y'之后，也会如图(a)所示导致节点'R'的失衡。

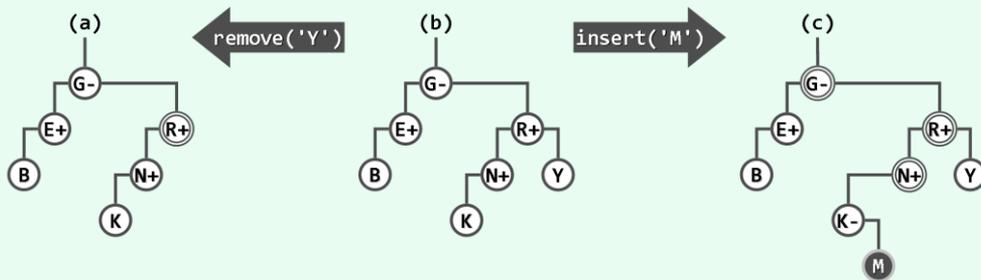


图7.14 经节点删除和插入操作后，AVL树可能失衡（加减号示意平衡因子，双圈表示失衡节点）

如此因节点 x 的插入或删除而暂时失衡的节点，构成失衡节点集，记作 $UT(x)$ 。请注意，若 x 为被摘除的节点，则 $UT(x)$ 仅含单个节点；但若 x 为被引入的节点，则 $UT(x)$ 可能包含多个节点（习题[7-13]）。由以上实例，也可验证这一性质。

以下，我们从对 $UT(x)$ 的分析入手，分别介绍使失衡搜索树重新恢复平衡的调整算法。

7.4.2 节点插入

■ 失衡节点集

不难看出，新引入节点 x 后， $UT(x)$ 中的节点都是 x 的祖先，且高度不低于 x 的祖父。以下，将其中的最深者记作 $g(x)$ 。在 x 与 $g(x)$ 之间的通路上，设 p 为 $g(x)$ 的孩子， v 为 p 的孩子。注意，既然 $g(x)$ 不低于 x 的祖父，则 p 必是 x 的真祖先。

■ 重平衡

首先，需要找到如上定义的 $g(x)$ 。为此，可从 x 出发沿`parent`指针逐层上行并核对平衡因子，首次遇到的失衡祖先即为 $g(x)$ 。既然原树是平衡的，故这一过程只需 $O(\log n)$ 时间。

请注意，既然 $g(x)$ 是因 x 的引入而失衡，则 p 和 v 的高度均不会低于其各自的兄弟。因此，借助如代码7.10所示的宏`tallerChild()`，即可反过来由 $g(x)$ 找到 p 和 v 。

```

1 /*****
2  * 在左、右孩子中取更高者，若等高，则与父亲p同侧者优先
3  * 在AVL平衡调整前，借此确定重构方案
4  *****/
5 #define tallerChild(x) ( \
6     stature((x)->lChild) > stature((x)->rChild) ? (x)->lChild : ( \
7     stature((x)->rChild) > stature((x)->lChild) ? (x)->rChild : ( \
8     IsLChild(*(x)) ? (x)->lChild : (x)->rChild \
9     ) \
10    ) \
11 )
    
```

代码7.10 恢复平衡的调整方案，决定于失衡节点的更高孩子、更高孙子节点的方向

这里并未显式地维护各节点的平衡因子，而是在需要时通过比较子树的高度直接计算。

以下，根据节点 $g(x)$ 、 p 和 v 之间具体的联接方向，将采用不同的局部调整方案。分述如下。

■ 单旋

如图7.15(a)所示，设 v 是 p 的右孩子，且 p 是 g 的右孩子。

这种情况下，必是由于在子树 v 中刚插入某节点 x ，而使 $g(x)$ 不再平衡。图中以虚线联接的每一对灰色方块中，其一一对应于节点 x ，另一为空。

此时，可采用7.3.4节的技巧，做逆时针旋转 $zag(g(x))$ ，得到如图(b)所示的另一棵等价二叉搜索树。

可见，经如此调整之后， $g(x)$ 必将恢复平衡。不难验证，通过 $zig(g(x))$ 可以处理对称的失衡。

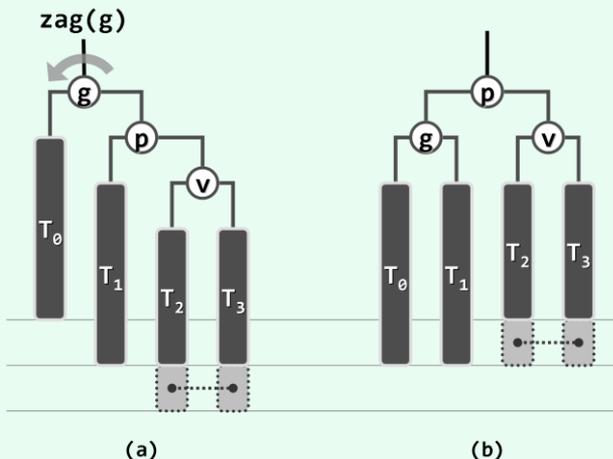


图7.15 节点插入后，通过单旋操作使AVL树重新平衡

■ 双旋

如图7.16(a)所示, 设节点 v 是 p 的左孩子, 而 p 是 $g(x)$ 的右孩子。

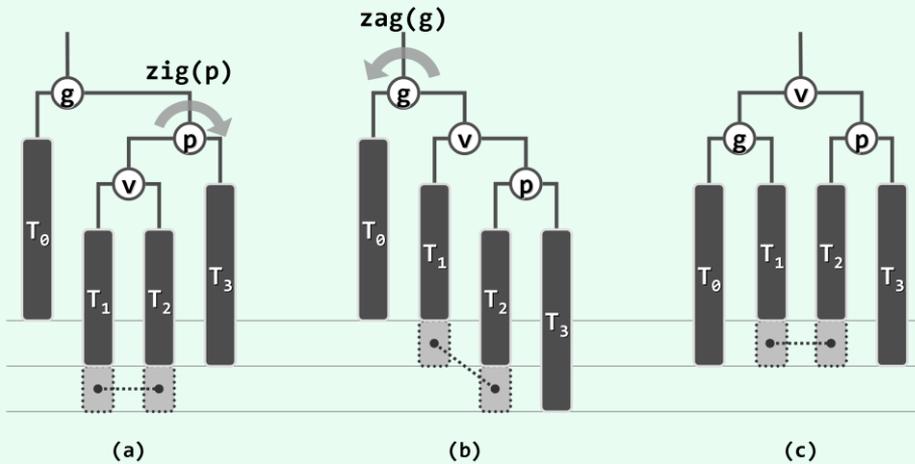


图7.16 节点插入后通过连续的两次旋转操作使AVL树重新平衡

这种情况, 也必是由于在子树 v 中插入了新节点 x , 而致使 $g(x)$ 不再平衡。同样地, 在图中以虚线联接的每一对灰色方块中, 其一一对应于新节点 x , 另一为空。

此时, 可先做顺时针旋转 $\text{zig}(p)$, 得到如图(b)所示的一棵等价二叉搜索树。再做逆时针旋转 $\text{zag}(g(x))$, 得到如图(c)所示的另一棵等价二叉搜索树。

此类分别以父子节点为轴、方向互逆的连续两次旋转, 合称“双旋调整”。可见, 经如此调整之后, $g(x)$ 亦必将重新平衡。不难验证, 通过 $\text{zag}(p)$ 和 $\text{zig}(g(x))$ 可以处理对称的情况。

■ 高度复原

纵观图7.15和图7.16可见, 无论单旋或双旋, 经局部调整之后, 不仅 $g(x)$ 能够重获平衡, 而且局部子树的高度也必将复原。这就意味着, $g(x)$ 以上所有祖先的平衡因子亦将统一地复原——换言之, 在AVL树中插入新节点后, 仅需不超过两次旋转, 即可使整树恢复平衡。

■ 实现

```

1 template <typename T> BinNodePosi(T) AVL<T>::insert(const T& e) { //将关键码e插入AVL树中
2     BinNodePosi(T) & x = search(e); if (x) return x; //确认目标节点不存在 (留意_hot的设置)
3     x = new BinNode<T>(e, _hot); _size++; //创建节点x (此后, 其父_hot可能增高, 祖父可能失衡)
4     for (BinNodePosi(T) g = _hot; g; g = g->parent) { //从x之父出发向上, 逐层检查各代祖先g
5         if (!AvlBalanced(*g)) { //一旦发现g失衡, 则 (采用“3 + 4”算法) 使之复衡
6             FromParentTo(*g) = rotateAt(tallerChild(tallerChild(g))); //将该子树联至原父亲
7             break; //g复衡后, 局部子树高度必然复原; 其祖先亦必如此, 故调整随即结束
8         } else //否则 (g依然平衡), 只需简单地
9             updateHeight(g); //更新其高度 (注意: 即便g未失衡, 高度亦可能增加)
10    } //至多只需一次调整; 若果真做过调整, 则全树高度必然复原
11    return x; //返回新节点
12 } //无论e是否存在于原树中, 返回时总有x->data == e

```

代码7.11 AVL树节点的插入

■ 效率

如代码7.11所示,该算法首先按照二叉搜索树的常规算法,在 $\mathcal{O}(\log n)$ 时间内插入新节点 x 。既然原树是平衡的,故至多检查 $\mathcal{O}(\log n)$ 个节点即可确定 $g(x)$;如有必要,至多旋转两次,即可使局部乃至全树恢复平衡。由此可见,AVL树的节点插入操作可以在 $\mathcal{O}(\log n)$ 时间内完成。

7.4.3 节点删除

■ 失衡节点集

与插入操作十分不同,在摘除节点 x 后,以及随后的调整过程中,失衡节点集 $UT(x)$ 始终至多只含一个节点(习题[7-13])。而且若该节点 $g(x)$ 存在,其高度必与失衡前相同。

另外还有一点重要的差异是, $g(x)$ 有可能就是 x 的父亲。

■ 重平衡

与插入操作同理,从_hot节点(7.2.6节)出发沿parent指针上行,经过 $\mathcal{O}(\log n)$ 时间即可确定 $g(x)$ 位置。作为失衡节点的 $g(x)$,在不包含 x 的一侧,必有一个非空孩子 p ,且 p 的高度至少为1。于是,可按以下规则从 p 的两个孩子(其一可能为空)中选出节点 v :若两个孩子不等高,则 v 取作其中的更高者;否则,优先取 v 与 p 同向者(亦即, v 与 p 同为左孩子,或者同为右孩子)。

以下不妨假定失衡后 $g(x)$ 的平衡因子为+2(为-2的情况完全对称)。根据祖孙三代节点 $g(x)$ 、 p 和 v 的位置关系,通过以 $g(x)$ 和 p 为轴的适当旋转,同样可以使得这一局部恢复平衡。

■ 单旋

如图7.17(a)所示,由于在 T_3 中删除了节点而致使 $g(x)$ 不再平衡,但 p 的平衡因子非负时,通过以 $g(x)$ 为轴顺时针旋转一次即可恢复局部的平衡。平衡后的局部子树如图(b)所示。

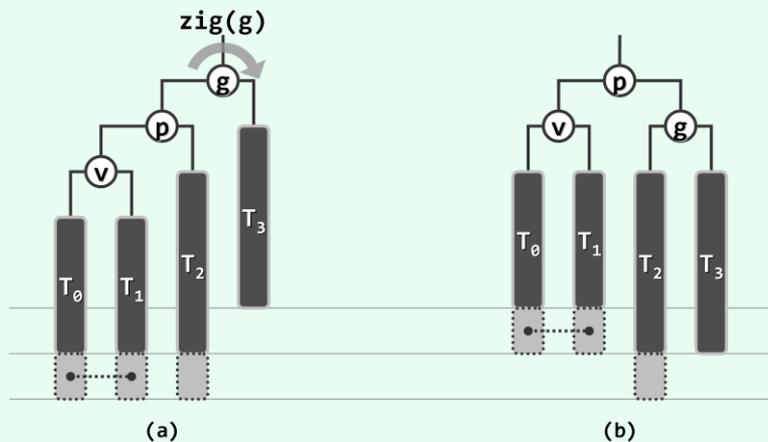


图7.17 节点删除后经一次旋转恢复局部平衡

同样地这里约定,图中以虚线联接的灰色方块所对应的节点,不能同时为空; T_2 底部的灰色方块所对应的节点,可能为空,也可能非空。

■ 双旋

如图7.18(a)所示, $g(x)$ 失衡时若 p 的平衡因子为-1,则经过以 p 为轴的一次逆时针旋转之后(图(b)),即可转化为图7.17(a)的情况。

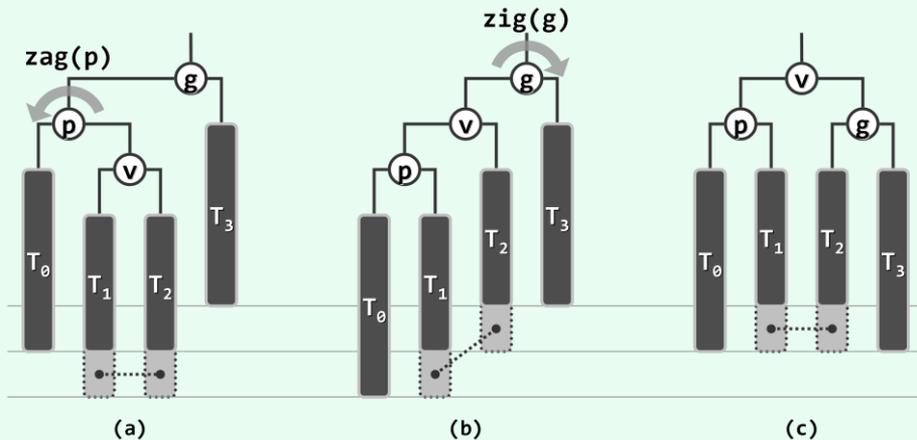


图7.18 节点删除后通过两次旋转恢复局部平衡

接着再套用上一情况的处理方法，以 $g(x)$ 为轴顺时针旋转，即可恢复局部平衡（图(c)）。

■ 失衡传播

与插入操作不同，在删除节点之后，尽管也可通过单旋或双旋调整使局部子树恢复平衡，但就全局而言，依然可能再次失衡。若能仔细观察图7.17(b)和图7.18(c)，则不难发现： $g(x)$ 恢复平衡之后，局部子树的高度却可能降低。这与引入节点之后的重平衡后完全不同——在上一节我们已看到，后者不仅能恢复子树的平衡性，也同时能恢复子树的高度。

设 $g(x)$ 复衡之后，局部子树的高度的确降低。此时，若 $g(x)$ 原本属于某一更高祖先的更短分支，则因为该分支现在又进一步缩短，从而会导致该祖先失衡。在摘除节点之后的调整过程中，这种由于低层失衡节点的重平衡而致使其更高层祖先失衡的现象，称作“失衡传播”。

请注意，失衡传播的方向必然自底而上，而不致于影响到后代节点。在此过程中的任一时刻，至多只有一个失衡的节点；高层的某一节点由平衡转为失衡，只可能发生在下层失衡节点恢复平衡之后。因此，可沿parent指针逐层遍历所有祖先，每找到一个失衡的祖先节点，即可套用以上方法使之恢复平衡（习题[7-19]）。

■ 实现

以上算法过程，可描述并实现如代码7.12所示。

```

1 template <typename T> bool AVL<T>::remove(const T& e) { //从AVL树中删除关键码e
2     BinNodePosi(T) & x = search(e); if (!x) return false; //确认目标节点存在（留意对_hot的设置）
3     removeAt(x, _hot); _size--; //先按BST规则删除之（此后，原节点之父_hot及其祖先均可能失衡）
4     for (BinNodePosi(T) g = _hot; g; g = g->parent) { //从_hot出发向上，逐层检查各代祖先g
5         if (!AvlBalanced(*g)) //一旦发现g失衡，则（采用“3 + 4”算法）使之复衡
6             g = FromParentTo(*g) = rotateAt(tallerChild(tallerChild(g))); //将该子树联至原父亲
7             updateHeight(g); //并更新其高度（注意：即便g未失衡，高度亦可能降低）
8     } //可能需做Omega(logn)次调整——无论是否做过调整，全树高度均可能降低
9     return true; //删除成功
10 } //若目标节点存在且被删除，返回true；否则返回false

```

代码7.12 AVL树节点的删除

■ 效率

由上可见，较之插入操作，删除操作可能需在重平衡方面多花费一些时间。不过，既然需做重平衡的节点都是 x 的祖先，故重平衡过程累计只需不过 $O(\log n)$ 时间（习题[7-17]）。综合各方面的消耗，AVL树的节点删除操作总体的时间复杂度依然是 $O(\log n)$ 。

7.4.4 统一重平衡算法

上述重平衡的方法，需要根据失衡节点及其孩子节点、孙子节点的相对位置关系，分别做单旋或双旋调整。按照这一思路直接实现调整算法，代码量大且流程繁杂，必然导致调试困难且容易出错。为此，本节将引入一种更为简明的统一处理方法。

无论对于插入或删除操作，新方法也同样需要从刚发生修改的位置 x 出发逆行而上，直至遇到最低的失衡节点 $g(x)$ 。于是在 $g(x)$ 更高一侧的子树内，其孩子节点 p 和孙子节点 v 必然存在，而且这一局部必然可以 $g(x)$ 、 p 和 v 为界，分解为四棵子树——按照图7.15至图7.18中的惯例，将它们按中序遍历次序重命名为 T_0 至 T_3 。

若同样按照中序遍历次序，重新排列 $g(x)$ 、 p 和 v ，并将其命名为 a 、 b 和 c ，则这一局部的中序遍历序列应为：

$$\{ T_0, a, T_1, b, T_2, c, T_3 \}$$

这就意味着，这一局部应等价于如图7.19所示的子树。更重要的是，纵观图7.15至图7.18可见，这四棵子树的高度相差不超过一层，故只需如图7.19所示将这三个节点与四棵子树重新“组装”起来，恰好即是一棵AVL树！

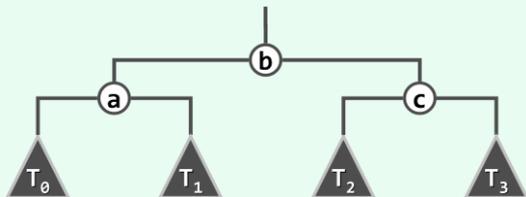


图7.19 节点插入后的统一重新平衡

实际上，这一理解涵盖了此前两节所有的单旋和双旋情况。相应的重构过程，仅涉及局部的三个节点及其四棵子树，故称作“3 + 4”重构。其具体实现如代码7.13所示。

```

1  /*****
2  * 按照“3 + 4”结构联接3个节点及其四棵子树，返回重组之后的局部子树根节点位置（即b）
3  * 子树根节点与上层节点之间的双向联接，均须由上层调用者完成
4  * 可用于AVL和RedBlack的局部平衡调整
5  *****/
6  template <typename T> BinNodePosi(T) BST<T>::connect34(
7      BinNodePosi(T) a, BinNodePosi(T) b, BinNodePosi(T) c,
8      BinNodePosi(T) T0, BinNodePosi(T) T1, BinNodePosi(T) T2, BinNodePosi(T) T3
9  ) {
10     a->lChild = T0; if (T0) T0->parent = a;
11     a->rChild = T1; if (T1) T1->parent = a; updateHeight(a);

```

```

12  c->lChild = T2; if (T2) T2->parent = c;
13  c->rChild = T3; if (T3) T3->parent = c; updateHeight(c);
14  b->lChild = a; a->parent = b;
15  b->rChild = c; c->parent = b; updateHeight(b);
16  return b; //孩子树新的根节点
17 }

```

代码7.13 “3 + 4”重构

利用以上connect34()算法，即可视不同情况，按如下具体方法完成重平衡：

```

1  /*****
2  * BST节点旋转变换统一算法（3节点 + 4子树），返回调整之后局部子树根节点的位置
3  * 注意：尽管子树根会正确指向上层节点（如果存在），但反向的连接须由上层函数完成
4  *****/
5  template <typename T> BinNodePosi(T) BST<T>::rotateAt(BinNodePosi(T) v) { //v为非空的孙辈节点
6      BinNodePosi(T) p = v->parent; BinNodePosi(T) g = p->parent; //视v、p和g相对位置分四种情况
7      if (IsLChild(*p)) /* zig */
8          if (IsLChild(*v)) { /* zig-zig */
9              p->parent = g->parent; //向上联接
10             return connect34(v, p, g, v->lChild, v->rChild, p->rChild, g->rChild);
11         } else { /* zig-zag */
12             v->parent = g->parent; //向上联接
13             return connect34(p, v, g, p->lChild, v->lChild, v->rChild, g->rChild);
14         }
15     else /* zag */
16         if (IsRChild(*v)) { /* zag-zag */
17             p->parent = g->parent; //向上联接
18             return connect34(g, p, v, g->lChild, p->lChild, v->lChild, v->rChild);
19         } else { /* zag-zig */
20             v->parent = g->parent; //向上联接
21             return connect34(g, v, p, g->lChild, v->lChild, v->rChild, p->rChild);
22         }
23 }

```

代码7.14 AVL树的统一重平衡

将图7.19与图7.15至图7.18做一比对即可看出，统一调整算法的效果，的确与此前的单旋、双旋算法完全一致。另外不难验证，新算法的复杂度也依然是 $O(1)$ 。

第8章

高級搜索树

除了AVL树，本章将按照如图7.1所示的总体框架，继续介绍平衡二叉搜索树家族中的其它成员。首先，鉴于数据访问的局部性在实际应用中普遍存在，将按照“最常用者优先”的启发策略，引入并实现伸展树。尽管最坏情况下其单次操作需要 $O(n)$ 时间，但分摊而言仍在 $O(\log n)$ 以内。构思巧妙，实现简洁，加上适用广泛，这些特点都使得伸展树具有别样的魅力。

接下来，通过对平衡二叉搜索树的推广，引入平衡多路搜索树，并着重讨论作为其中典型代表的B-树。借助此类结构，可以有效地弥合不同存储级别之间，在访问速度上的巨大差异。

对照4阶B-树，还将引入并实现红黑树。红黑树不仅能保持全树的适度平衡，从而有效地控制单次操作的时间成本，而且可以将每次重新平衡过程执行的结构调整，控制在常数次数以内。后者也是该树有别于其它变种的关键特性，它不仅保证了红黑树更高的实际计算效率，更为持久性结构（persistent structure）之类高级数据结构的实现，提供了直接而有效的方法。

最后，将针对平面范围查询应用，介绍基于平面子区域正交划分的kd-树结构。该结构是对二叉树（quadtree）和八叉树（octree）等结构的一般性推广，它也为计算几何类应用问题的求解，提供了一种基本的模式和有效的方法。

§ 8.1 伸展树

与前一章的AVL树一样，伸展树（splay tree）^①也是平衡二叉搜索树的一种形式。相对于前者，后者的实现更为简捷。伸展树无需时刻都严格地保持全树的平衡，但却能够在任何足够长的真实操作序列中，保持分摊意义上的高效率。伸展树也不需要基本的二叉树节点结构，做任何附加的要求或改动，更不需要记录平衡因子或高度之类的额外信息，故适用范围更广。

8.1.1 局部性

信息处理的典型模式是，将所有数据项视作一个集合，并将其组织为某种适宜的数据结构，进而借助操作接口高效访问。本书介绍的搜索树、词典和优先级队列等，都可归于此类。

为考查和评价各操作接口的效率，除了从最坏情况的角度出发，也可假定所有操作彼此独立、次序随机且概率均等，并从平均情况的角度出发。然而，后一尺度所依赖的假定条件，往往并不足以反映真实的情况。实际上，通常在任意数据结构的生命期内，不仅执行不同操作的概率往往极不均衡，而且各操作之间具有极强的相关性，并在整体上多呈现出极强的规律性。其中最为典型的，就是所谓的“数据局部性”（data locality），这包括两个方面的含义：

- 1) 刚刚被访问过的元素，极有可能在不久之后再次被访问到
- 2) 将被访问的下一元素，极有可能就处于不久之前被访问过的某个元素的附近

充分利用好此类特性，即可进一步地提高数据结构和算法的效率。比如习题[3-6]中的自调

^① 由D. D. Sleator和R. E. Tarjan于1985年发明^[41]

整列表，就是通过“即用即前移”的启发式策略，将最为常用的数据项集中于列表的前端，从而使得单次操作的时间成本大大降低。同样地，类似的策略也可应用于二叉搜索树。

就二叉搜索树而言，数据局部性具体表现为：

- 1) 刚刚被访问过的节点，极有可能在不久之后再次被访问到
- 2) 将被访问的下一节点，极有可能就处于不久之前被访问过的某个节点的附近

因此，只需将刚被访问的节点，及时地“转移”至树根（附近），即可加速后续的操作。当然，转移前后的搜索树必须相互等价，故为此仍需借助7.3.4节中等价变换的技巧。

8.1.2 逐层伸展

■ 简易伸展树

一种直接方式是：每访问过一个节点之后，随即反复地以它的父节点为轴，经适当的旋转将其提升一层，直至最终成为树根。以图8.1为例，若深度为3的节点E刚被访问——无论查找或插入，甚至“删除”——都可通过3次旋转，将该树等价变换为以E为根的另一棵二叉搜索树。

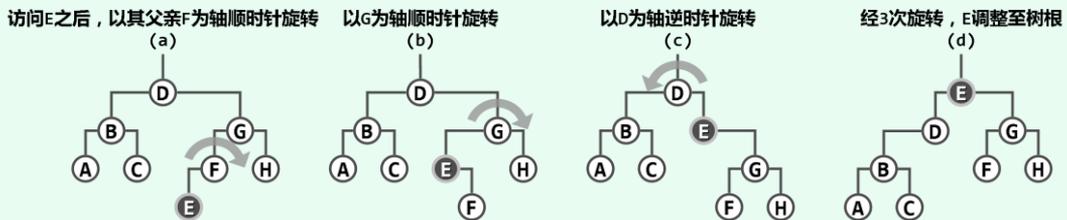


图8.1 通过自下而上的一系列等价变换，可使任一节点上升至树根

随着节点E的逐层上升，两侧子树的结构也不断地调整，故这一过程也称作伸展(splaying)，而采用这一调整策略的二叉搜索树也因此得名。不过，为实现真正意义上的伸展树，还须对以上策略做点微妙而本质的改进。之所以必须改进，是因为目前的策略仍存在致命的缺陷——对于很多访问序列，单次访问的分摊时间复杂度在极端情况下可能高达 $\Omega(n)$ 。

■ 最坏情况

不难验证，若从空树开始依次插入关键字{ 1, 2, 3, 4, 5 }，且其间采用如上调整策略，则可得到如图8.2(a)所示的二叉搜索树。接下来，若通过search()接口，再由小到大依次访问各节点一次，则该树在各次访问之后的结构形态将如图(b~f)所示。

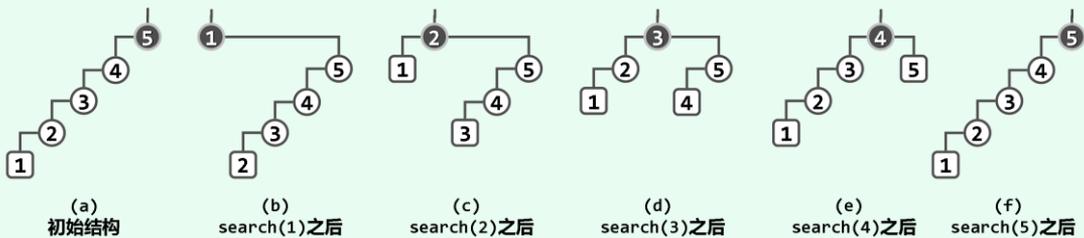


图8.2 简易伸展树的最坏情况

可见，在各次访问之后，为将对应节点伸展调整至树根，分别需做4、4、3、2和1次旋转。

一般地，若节点总数为 n ，则旋转操作的总次数应为：

$$(n - 1) + \{ (n - 1) + (n - 2) + \dots + 1 \} = (n^2 + n - 2)/2 = \Omega(n^2)$$

如此分摊下来，每次访问平均需要 $\Omega(n)$ 时间。很遗憾，这一效率不仅远远低于AVL树，而且甚至与原始的二叉搜索树的最坏情况相当。而事实上，问题还远不止于此。

稍做比对即不难发现，图8.2(a)与(f)中二叉搜索树的结构完全相同。也就是说，经过以上连续的5次访问之后，全树的结构将会复原！这就意味着，以上情况可以持续地再现。

当然，这一实例，完全可以推广至规模任意的二叉搜索树。于是对于规模为任意 n 的伸展树，只要按关键码单调的次序，周期性地反复进行查找，则无论总的访问次数 $m \gg n$ 有多大，就分摊意义而言，每次访问都将需要 $\Omega(n)$ 时间！

那么，这类最坏的访问序列能否回避？具体地，又应该如何回避？

8.1.3 双层伸展

为克服上述伸展调整策略的缺陷，一种简便且有效的方法就是：将逐层伸展改为双层伸展。具体地，每次都从当前节点 v 向上追溯两层（而不是仅一层），并根据其父亲 p 以及祖父 g 的相对位置，进行相应的旋转。以下分三类情况，分别介绍具体的处理方法。

■ zig-zig/zag-zag

如图8.3(a)所示，设 v 是 p 的左孩子，且 p 也是 g 的左孩子；设 W 和 X 分别是 v 的左、右子树， Y 和 Z 分别是 p 和 g 的右子树。

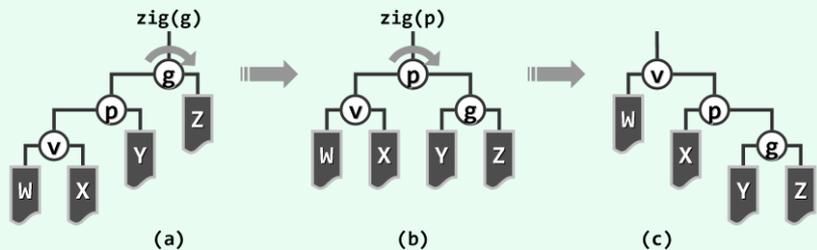


图8.3 通过zig-zig操作，将节点 v 上推两层

针对这种情况，首先以节点 g 为轴做顺时针旋转 $\text{zig}(g)$ ，其效果如图(b)所示。然后，再以 p 为轴做顺时针旋转 $\text{zig}(p)$ ，其效果如图(c)所示。如此连续的两次 zig 旋转，合称 zig-zig 调整。

自然地，另一完全对称的情形—— v 是 p 的右孩子，且 p 也是 g 的右孩子——则可通过连续的两次逆时针旋转实现调整，合称 zag-zag 操作。这一操作的具体过程，请读者独立绘出。

■ zig-zag/zag-zig

如图8.4(a)所示，设 v 是 p 的左孩子，而 p 是 g 的右孩子；设 W 是 g 的左子树， X 和 Y 分别是 v 的左、右子树， Z 是 p 的右子树。

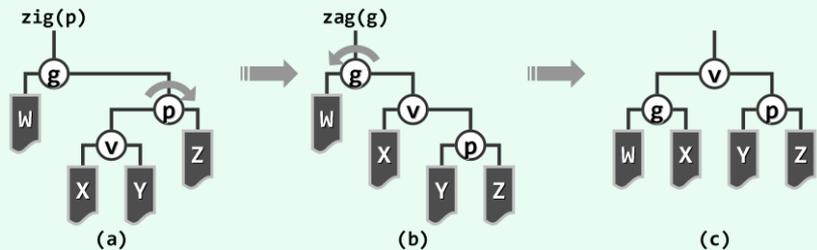


图8.4 通过zig-zag操作，将节点 v 上推两层

针对这种情况，首先以节点 p 为轴做顺时针旋转 $\text{zig}(p)$ ，其效果如(b)所示。然后，再以 g 为轴做逆时针旋转 $\text{zag}(g)$ ，其效果如图(c)所示。如此 zig 旋转再加 zag 旋转，合称 zig-zag 调整。

同样地，另一完全对称的情形—— v 是 p 的右孩子，而 p 是 g 的左孩子——则可通过 zag 旋转再加 zig 旋转实现调整，合称 zag-zig 操作。这一操作的具体过程，请读者独立绘出。

■ zig/zag

如图8.5(a)所示，若 v 最初的深度为奇数，则经过若干次双层调整至最后一次调整时， v 的父亲 p 即是树根 r 。将 v 的左、右子树记作 X 和 Y ，节点 $p = r$ 的另一子树记作 Z 。

此时，只需围绕 $p = r$ 做顺时针旋转 $zig(p)$ ，即可如图(b)所示，使 v 最终攀升至树根，从而结束整个伸展调整的过程。

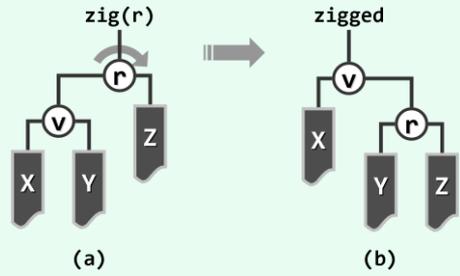


图8.5 通过zig操作，将节点 v 上推一层，成为树根

zag调整与之对称，其过程请读者独立绘出。

■ 效果与效率

综合以上各种情况，每经过一次双层调整操作，节点 v 都会上升两层。若 v 的初始深度 $depth(v)$ 为偶数，则最终 v 将上升至树根。若 $depth(v)$ 为奇数，则当 v 上升至深度为1时，不妨最后再相应地做一次zig或zag单旋操作。无论如何，经过 $depth(v)$ 次旋转后， v 最终总能成为树根。

重新审视图8.2的最坏实例不难发现，这一访问序列导致 $\Omega(n)$ 平均单次访问时间的原因，可以解释为：在这一可持续重复的过程中，二叉搜索树的高度始终不小于 $\lfloor n/2 \rfloor$ ；而且，至少有一半的节点在接受访问时，不仅没有如最初设想的那样靠近树根，而且反过来恰恰处于最底层。从树高的角度看，问题根源也可再进一步地解释为：在持续访问的过程中，树高依算术级数逐步从 $n - 1$ 递减至 $\lfloor n/2 \rfloor$ ，然后再逐步递增回到 $n - 1$ 。那么，采用上述双层伸展的策略将每一刚被访问过的节点推至树根，可否避免如图8.2所示的最坏情况呢？

稍作对比不难看出，就调整之后的局部结构而言，zig-zag和zag-zig调整与此前的逐层伸展完全一致（亦等效于AVL树的双旋调整），而zig-zig和zag-zag调整则有所不同。事实上，后者才是双层伸展策略优于逐层伸展策略的关键所在。以如图8.6(b)所示的二叉搜索树为例，在find(1)操作之后采用逐层调整策略与双层调整策略的效果，分别如图(a)和图(c)所示。

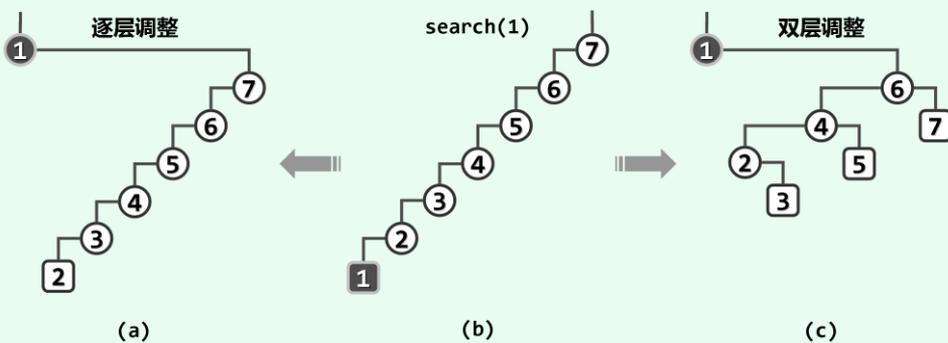


图8.6 双层调整策略的高度折半效果

可见，最深节点（1）被访问之后再经过双层调整，不仅同样可将该节点伸展至树根，而且同时可使树的高度接近于减半。就树的形态而言，双层伸展策略可“智能”地“折叠”被访问的子树分支，从而有效地避免对长分支的连续访问。这就意味着，即便节点 v 的深度为 $\Omega(n)$ ，双层伸展策略既可将 v 推至树根，亦可令对应分支的长度以几何级数（大致折半）的速度收缩。

图8.7则给出了一个节点更多、更具一般性的例子，从中可更加清晰地看出这一效果。

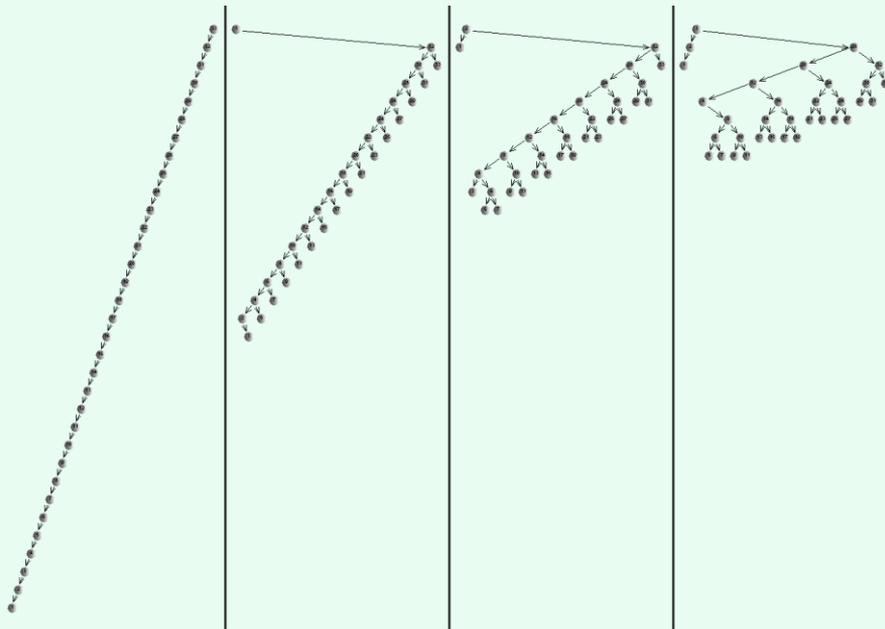


图8.7 伸展树中较深的节点一旦被访问到，对应分支的长度将随即减半

尽管在任一时刻伸展树中都可能存在很深的节点，但与含羞草类似地，一旦这类“坏”节点被“碰触”到，经过随后的双层伸展，其对应的分支都会收缩至长度大致折半。于是，即便每次都“恶意地”试图访问最底层节点，最坏情况也不会持续发生。可见，伸展树虽不能杜绝最坏情况的发生，却能有效地控制最坏情况发生的频度，从而在分摊意义下保证整体的高效率。

更准确地，Tarjan等人^[41]采用势能分析法（potential analysis）业已证明，在改用“双层伸展”策略之后，伸展树的单次操作均可在分摊的 $O(\log n)$ 时间内完成（习题[8-2]）。

8.1.4 伸展树的实现

■ 伸展树接口定义

基于BST类，可定义伸展树模板类Splay如代码8.1所示。

```

1 #include "../BST/BST.h" //基于BST实现Splay
2 template <typename T> class Splay : public BST<T> { //由BST派生的Splay树模板类
3 protected:
4     BinNodePosi(T) splay(BinNodePosi(T) v); //将节点v伸展至根
5 public:
6     BinNodePosi(T) & search(const T& e); //查找(重写)
7     BinNodePosi(T) insert(const T& e); //插入(重写)
8     bool remove(const T& e); //删除(重写)
9 };

```

代码8.1 基于BST定义的伸展树接口

可见，这里直接沿用二叉搜索树类，并根据伸展树的平衡规则，重写了三个基本操作接口

search()、insert()和remove()，另外，针对伸展调整操作，设有一个内部保护型接口splay()。

这些接口的具体实现将在以下数节陆续给出。需强调的是，与一般的二叉搜索树不同，伸展树的查找也会引起整树的结构调整，故search()操作也需重写。

■ 伸展算法的实现

8.1.3节所述的伸展调整方法，可具体实现如代码8.2所示。

```

1  template <typename NodePosi> inline //在节点*p与*lc (可能为空)之间建立父(左)子关系
2  void attachAsLChild(NodePosi p, NodePosi lc) { p->lChild = lc; if (lc) lc->parent = p; }
3
4  template <typename NodePosi> inline //在节点*p与*rc (可能为空)之间建立父(右)子关系
5  void attachAsRChild(NodePosi p, NodePosi rc) { p->rChild = rc; if (rc) rc->parent = p; }
6
7  template <typename T> //Splay树伸展算法：从节点v出发逐层伸展
8  BinNodePosi(T) Splay<T>::splay(BinNodePosi(T) v) { //v为因最近访问而需伸展的节点位置
9      if (!v) return NULL;
10     BinNodePosi(T) p; BinNodePosi(T) g; //v的父亲与祖父
11     while ((p = v->parent) && (g = p->parent)) { //自下而上，反复对*v做双层伸展
12         BinNodePosi(T) gg = g->parent; //每轮之后*v都以原曾祖父(great-grand parent)为父
13         if (IsLChild(*v))
14             if (IsLChild(*p)) { //zig-zig
15                 attachAsLChild(g, p->rChild); attachAsLChild(p, v->rChild);
16                 attachAsRChild(p, g); attachAsRChild(v, p);
17             } else { //zig-zag
18                 attachAsLChild(p, v->rChild); attachAsRChild(g, v->lChild);
19                 attachAsLChild(v, g); attachAsRChild(v, p);
20             }
21         else if (IsRChild(*p)) { //zag-zag
22             attachAsRChild(g, p->lChild); attachAsRChild(p, v->lChild);
23             attachAsLChild(p, g); attachAsLChild(v, p);
24         } else { //zag-zig
25             attachAsRChild(p, v->lChild); attachAsLChild(g, v->rChild);
26             attachAsRChild(v, g); attachAsLChild(v, p);
27         }
28         if (!gg) v->parent = NULL; //若*v原先的曾祖父*gg不存在，则*v现在应为树根
29         else //否则，*gg此后应该以*v作为左或右孩子
30             (g == gg->lChild) ? attachAsLChild(gg, v) : attachAsRChild(gg, v);
31         updateHeight(g); updateHeight(p); updateHeight(v);
32     } //双层伸展结束时，必有g == NULL，但p可能非空
33     if (p = v->parent) { //若p果真非空，则额外再做一次单旋
34         if (IsLChild(*v)) { attachAsLChild(p, v->rChild); attachAsRChild(v, p); }
35         else { attachAsRChild(p, v->lChild); attachAsLChild(v, p); }
36         updateHeight(p); updateHeight(v);
37     }

```

```

38     v->parent = NULL; return v;
39 } //调整之后新树根应为被伸展的节点,故返回该节点的位置以便上层函数更新树根

```

代码8.2 伸展树节点的调整

■ 查找算法的实现

在伸展树中查找任一关键码 e 的过程,可实现如代码8.3所示。

```

1 template <typename T> BinNodePosi(T) & Splay<T>::search(const T& e) { //在伸展树中查找关键码e
2     BinNodePosi(T) p = searchIn(_root, e, _hot = NULL);
3     _root = splay((p ? p : _hot)); //将最后一个被访问的节点伸展至根
4     return _root;
5 } //与其它BST不同,无论查找成功与否,_root都指向最后被访问的节点

```

代码8.3 伸展树节点的查找

首先,调用二叉搜索树的通用算法`searchIn()`(代码7.3)尝试查找具有关键码 e 的节点。无论查找是否成功,都继而调用`splay()`算法,将查找终止位置处的节点伸展到树根。

■ 插入算法的实现

为将节点插至伸展树中,固然可以调用二叉搜索树的标准插入算法`BST::insert()`(188页代码7.5),再通过双层伸展,将新插入的节点提升至树根。

然而,以上接口`Splay::search()`已集成了`splay()`伸展功能,故查找返回后,树根节点要么等于查找目标(查找成功),要么就是`_hot`,而且恰为拟插入节点的直接前驱或直接后继(查找失败)。因此,不妨改用如下方法实现`Splay::insert()`接口。

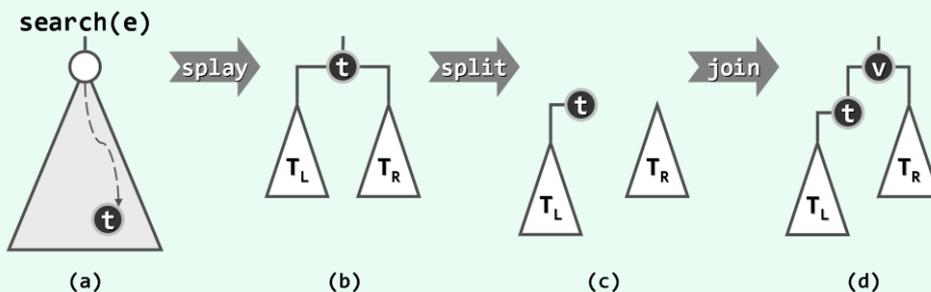


图8.8 伸展树的节点插入

如图8.8所示,为将关键码 e 插至伸展树 T 中,首先调用伸展树查找接口`Splay::search(e)`,查找该关键码(图(a))。于是,其中最后被访问的节点 t ,将通过伸展被提升为树根,其左、右子树分别记作 T_L 和 T_R (图(b))。

接下来,根据 e 与 t 的大小关系(不妨排除二者相等的情况),以 t 为界将 T 分裂为两棵子树。比如,不失一般性地设 e 大于 t 。于是,可切断 t 与其右孩子之间的联系(图(c)),再将 e 为关键码的新节点 v 作为树根,并以 t 作为其左孩子,以 T_R 作为其右子树(图(d))。

v 小于 t 的情况与此完全对称,请读者独立做出分析。

上述算法过程,可具体实现如代码8.4所示。

```

1 template <typename T> BinNodePosi(T) Splay<T>::insert(const T& e) { //将关键字e插入伸展树中
2     if (!_root) { _size++; return _root = new BinNode<T>(e); } //处理原树为空的退化情况
3     if (e == search(e)->data) return _root; //确认目标节点不存在
4     _size++; BinNodePosi(T) t = _root; //创建新节点。以下调整<=7个指针以完成局部重构
5     if (_root->data < e) { //插入新根,以t和t->rChild为左、右孩子
6         t->parent = _root = new BinNode<T>(e, NULL, t, t->rChild); //2 + 3个
7         if (HasRChild(*t)) { t->rChild->parent = _root; t->rChild = NULL; } //<= 2个
8     } else { //插入新根,以t->lChild和t为左、右孩子
9         t->parent = _root = new BinNode<T>(e, NULL, t->lChild, t); //2 + 3个
10        if (HasLChild(*t)) { t->lChild->parent = _root; t->lChild = NULL; } //<= 2个
11    }
12    updateHeightAbove(t); //更新t及其祖先(实际上只有_root一个)的高度
13    return _root; //新节点必然置于树根,返回之
14 } //无论e是否存在于原树中,返回时总有_root->data == e

```

代码8.4 伸展树节点的插入

尽管伸展树并不需要记录和维持节点高度,为与其它平衡二叉搜索树的实现保持统一,这里还是对节点的高度做了及时的更新。出于效率的考虑,实际应用中可视情况,省略这类更新。

■ 删除算法的实现

为从伸展树中删除节点,固然也可以调用二叉搜索树标准的节点删除算法BST::remove() (190页代码7.6),再通过双层伸展,将该节点此前的父节点提升至树根。

然而,同样鉴于Splay::search()已集成了splay()伸展功能,且在成功返回后,树根节点恰好就是待删除节点。因此,亦不妨改用如下方法实现Splay::remove()接口。

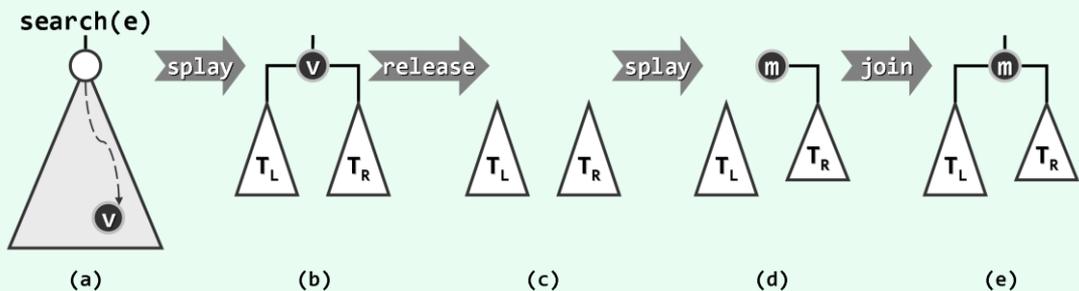


图8.9 伸展树的节点删除

如图8.9所示,为从伸展树 T 中删除关键字为 e 的节点,首先亦调用接口Splay::search(e),查找该关键字,且不妨设命中节点为 v (图(a))。于是, v 将随即通过伸展被提升为树根,其左右子树分别记作 T_L 和 T_R (图(b))。接下来,将 v 摘除(图(c))。然后,在 T_R 中再次查找关键字 e 。尽管这一查找注定失败,却可以将 T_R 中的最小节点 m ,伸展提升为该子树的根。

得益于二叉搜索树的顺序性,此时节点 m 的左子树必然为空;同时, T_L 中所有节点都应小于 m (图(d))。于是,只需将 T_L 作为左子树与 m 相互联接,即可得到一棵完整的二叉搜索树(图(e))。如此不仅删除了 v ,而且既然新树根 m 在原树中是 v 的直接后继,故数据局部性也得到了利用。

上述算法过程，可具体实现如代码8.5所示。

```

1 template <typename T> bool Splay<T>::remove(const T& e) { //从伸展树中删除关键词e
2     if (!_root || (e != search(e)->data)) return false; //若树空或目标关键词不存在，则无法删除
3     BinNodePosi(T) w = _root; //assert: 经search()后节点e已被伸展至树根
4     if (!HasLChild(*_root)) { //若无左子树，则直接删除
5         _root = _root->rChild; if (_root) _root->parent = NULL;
6     } else if (!HasRChild(*_root)) { //若无右子树，也直接删除
7         _root = _root->lChild; if (_root) _root->parent = NULL;
8     } else { //若左右子树同时存在，则
9         BinNodePosi(T) lTree = _root->lChild;
10        lTree->parent = NULL; _root->lChild = NULL; //暂时将左子树切除
11        _root = _root->rChild; _root->parent = NULL; //只保留右子树
12        search(w->data); //以原树根为目标，做一次（必定失败的）查找
13        //assert: 至此，右子树中最小节点必伸展至根，且（因无雷同节点）其左子树必空，于是
14        _root->lChild = lTree; lTree->parent = _root; //只需将原左子树接回原位即可
15    }
16    release(w->data); release(w); _size--; //释放节点，更新规模
17    if (_root) updateHeight(_root); //此后，若树非空，则树根的高度需要更新
18    return true; //返回成功标志
19 } //若目标节点存在且被删除，返回true；否则返回false

```

代码8.5 伸展树节点的删除

当然，其中的第二次查找也可在 T_L （若非空）中进行。读者不妨独立实现这一对称的版本。

§ 8.2 B-树

8.2.1 多路平衡查找

■ 分级存储

现代电子计算机发展速度空前。就计算能力而言，ENIAC[®]每秒只能够执行5000次加法运算，而今天的超级计算机每秒已经能够执行 3×10^{16} 次以上的浮点运算^①。就存储能力而言，情况似乎也是如此：ENIAC只有一万八千个电子管，而如今容量以TB计的硬盘也不过数百元，内存的常规容量也已达GB量级。

然而从实际应用的需求来看，问题规模的膨胀却远远快于存储能力的增长。以数据库为例，在20世纪80年代初，典型数据库的规模为10~100 MB，而三十年后的今天，典型数据库的规模已需要以TB为单位来计量。计算机存储能力提高速度相对滞后，是长期存在的现象，而且随着时间的推移，这一矛盾将日益凸显。鉴于在同等成本下，存储器的容量越大（小）则访问速度越慢（快），因此一味地提高存储器容量，亦非解决这一矛盾的良策。

^① 第一台电子计算机，1946年2月15日诞生于美国宾夕法尼亚大学工学院

^② 2013年6月，天河-2以此运算速度，荣登世界超级计算机500强榜首

实践证明，分级存储才是行之有效的方法。在由内存与外存（磁盘）组成的二级存储系统中，数据全集往往存放于外存中，计算过程中则可将内存作为外存的高速缓存，存放最常用数据项的副本。借助高效的调度算法，如此便可将内存的“高速度”与外存的“大容量”结合起来。

两个相邻存储级别之间的数据传输，统称I/O操作。各级存储器的访问速度相差悬殊，故应尽可能地减少I/O操作。仍以内存与磁盘为例，其单次访问延迟大致分别在纳秒（ns）和毫秒（ms）级别，相差5至6个数量级。也就是说，对内存而言的一秒/一天，相当于磁盘的一星期/两千年。因此，为减少对外存的一次访问，我们宁愿访问内存百次、千次甚至万次。也正因为此，在衡量相关算法的性能时，基本可以忽略对内存的访问，转而更多地关注对外存的访问次数。

■ 多路搜索树

当数据规模大到内存已不足以容纳时，常规平衡二叉搜索树的效率将大打折扣。其原因在于，查找过程对外存的访问次数过多。例如，若将 10^9 个记录在外存中组织为AVL树，则每次查找大致需做30次外存访问。那么，如何才能有效减少外存操作呢？

为此，需要充分利用磁盘之类外部存储器的另一特性：就时间成本而言，读取物理地址连续的一千个字节，与读取单个字节几乎没有区别。既然外部存储器更适宜于批量式访问，不妨通过时间成本相对极低的多次内存操作，来替代时间成本相对极高的单次外存操作。相应地，需要将通常的二叉搜索树，改造为多路搜索树——在中序遍历的意义下，这也是一种等价变换。

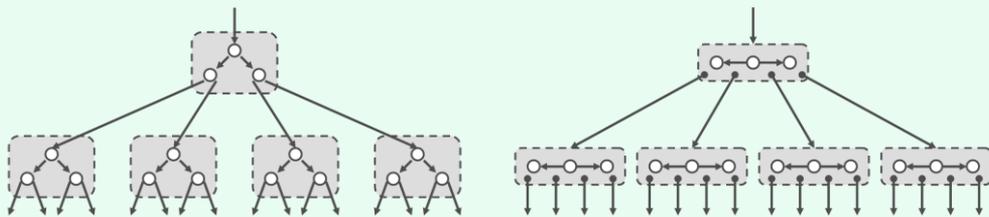


图8.10 二叉搜索树与四路搜索树

具体地如图8.10所示，比如可以两层为间隔，将各节点与其左、右孩子合并为“大节点”：原节点及其孩子的共三个关键码予以保留；孩子节点原有的四个分支也予以保留并按中序遍历次序排列；节点到左、右孩子的分支转化为“大节点”内部的搜索，在图中表示为水平分支。如此改造之后，每个“大节点”拥有四个分支，故称作四路搜索树。

这一策略还可进一步推广，比如以三层为间隔，将各节点及其两个孩子、四个孙子合并为含有七个关键码、八个分支的“大节点”，进而得到八路搜索树。一般地，以 k 层为间隔如此重组，可将二叉搜索树转化为等价的 2^k 路搜索树，统称多路搜索树（multi-way search tree）。

不难验证，多路搜索树同样支持查找等操作，且效果与原二叉搜索树完全等同；然而重要的是，其对外存的访问方式已发生本质变化。实际上，在此时的搜索每下降一层，都以“大节点”为单位从外存读取一组（而不再是单个）关键码。更为重要的是，这组关键码在逻辑上与物理上都彼此相邻，故可以批量方式从外存一次性读出，且所需时间与读取单个关键码几乎一样。

当然，每组关键码的最佳数目，取决于不同外存的批量访问特性。比如旋转式磁盘的读写操作多以扇区为单位，故可根据扇区的容量和关键码的大小，经换算得出每组关键码的最佳规模。例如若取 $k = 8$ ，则每个“大节点”将拥有255个关键码和256个分支，此时同样对于1G个记录，每次查找所涉及的外存访问将减至4~5次。

■ 多路平衡搜索树

所谓m阶B-树^④ (B-tree)，即m路平衡搜索树 ($m \geq 2$)，其宏观结构如图8.11所示。

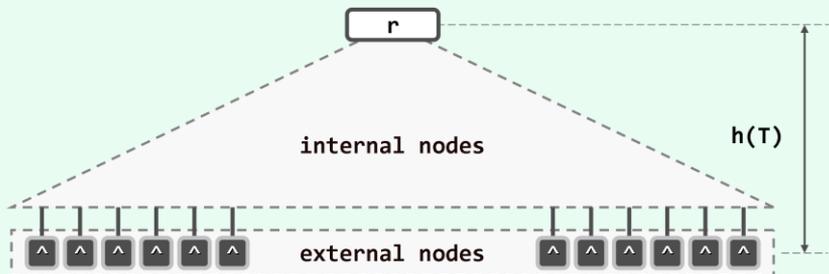


图8.11 B-树的宏观结构 (外部节点以深色示意, 深度完全一致, 且都同处于最底层)

其中, 所有外部节点均深度相等。同时, 每个内部节点都存有不超过 $m - 1$ 个关键码, 以及用以指示对应分支的不超过 m 个引用。具体地, 存有 $n \leq m - 1$ 个关键码:

$$K_1 < K_2 < K_3 < K_4 < \dots < K_n$$

的内部节点, 同时还配有 $n + 1 \leq m$ 个引用:

$$A_0 < A_1 < A_2 < A_3 < A_4 < \dots < A_n$$

反过来, 各内部节点的分支数也不能太少。具体地, 除根以外的所有内部节点, 都应满足:

$$n + 1 \geq \lceil m/2 \rceil$$

而在非空的B-树中, 根节点应满足:

$$n + 1 \geq 2$$

由于各节点的分支数介于 $\lceil m/2 \rceil$ 至 m 之间, 故m阶B-树也称作 $(\lceil m/2 \rceil, m)$ -树, 如 $(2, 3)$ -树、 $(3, 6)$ -树或 $(7, 13)$ -树等。

B-树的外部节点 (external node) 更加名副其实——它们实际上未必意味着查找失败, 而可能表示目标关键码存在于更低层次的某一外部存储系统中, 顺着该节点的指示, 即可深入至下一级存储系统并继续查找。正因为如此, 不同于常规的搜索树, 如图8.11所示, 在计算B-树高度时, 还需要计入其最底层的外部节点。

例如, 图8.12(a)即为一棵由9个内部节点、15个外部节点以及14个关键码组成的4阶B-树, 其高度 $h = 3$, 其中每个节点包含1~3个关键码, 拥有2~4个分支。

作为与二叉搜索树等价的“扁平化”版本, B-树的宽度 (亦即最底层外部节点的数目) 往往远大于其高度。因此在以图形描述B-树的逻辑结构时, 我们往往需要简化其中分支的画法, 并转而采用如图(b)所示的紧凑形式。

另外, 既然外部节点均同处于最底层, 且深度完全一致, 故在将它们省略之后, 通常还不致造成误解。因此, 还可以将B-树的逻辑结构, 进一步精简为如图(c)所示的最紧凑形式。

由这种最紧凑的表示形式, 也可同时看出, B-树叶节点 (即最深的内部节点) 的深度也必然完全一致, 比如 $[7]$ 、 $[19, 22]$ 、 $[28]$ 、 $[37, 40, 41]$ 、 $[46]$ 和 $[52]$ 。

^④ 由R. Bayer和E. McCreight于1970年合作发明^[43]

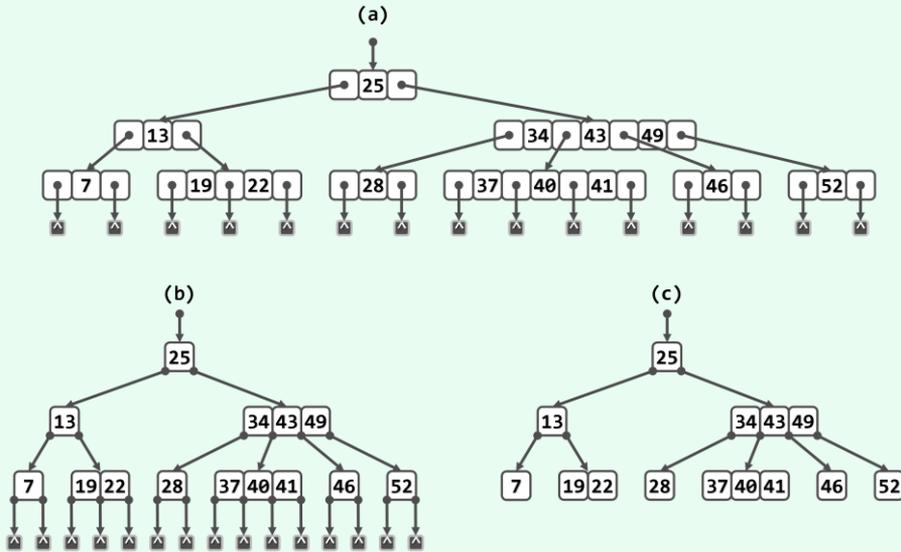


图8.12 (a) 4阶B-树；(b) B-树的紧凑表示；(c) B-树的最紧凑表示

8.2.2 ADT接口及其实现

按照以上定义，可以模板类的形式描述并实现B-树节点以及B-树结构本身如下。

■ 节点

B-树节点BTreeNode类，可实现如代码8.6所示。

```

1 #include "../vector/vector.h"
2 #define BTreeNodePosi(T) BTreeNode<T>* //B-树节点位置
3
4 template <typename T> struct BTreeNode { //B-树节点模板类
5 // 成员（为简化描述起见统一开放，读者可根据需要进一步封装）
6     BTreeNodePosi(T) parent; //父节点
7     Vector<T> key; //密钥向量
8     Vector<BTreeNodePosi(T)> child; //孩子向量（其长度总比key多一）
9 // 构造函数（注意：BTreeNode只能作为根节点创建，而且初始时有0个密钥和1个空孩子指针）
10    BTreeNode() { parent = NULL; child.insert(0, NULL); }
11    BTreeNode(T e, BTreeNodePosi(T) lc = NULL, BTreeNodePosi(T) rc = NULL) {
12        parent = NULL; //作为根节点，而且初始时
13        key.insert(0, e); //只有一个密钥，以及
14        child.insert(0, lc); child.insert(1, rc); //两个孩子
15        if (lc) lc->parent = this; if (rc) rc->parent = this;
16    }
17 };

```

代码8.6 B-树节点

这里，同一节点的所有孩子组织为一个向量，各相邻孩子之间的密钥也组织为一个向量。当然，按照B-树的定义，孩子向量的实际长度总是比密钥向量多一。

■ B-树

B-树模板类，可实现如代码8.7所示。

```

1 #include "BTreeNode.h" //引入B-树节点类
2
3 template <typename T> class BTree { //B-树模板类
4 protected:
5     int _size; //存放的关键词总数
6     int _order; //B-树的阶次，至少为3——创建时指定，一般不能修改
7     BTreeNodePosi(T) _root; //根节点
8     BTreeNodePosi(T) _hot; //BTree::search()最后访问的非空（除非树空）的节点位置
9     void solveOverflow(BTreeNodePosi(T)); //因插入而上溢之后的分裂处理
10    void solveUnderflow(BTreeNodePosi(T)); //因删除而下溢之后的合并处理
11 public:
12    BTree(int order = 3) : _order(order), _size(0) //构造函数：默认为最低的3阶
13    { _root = new BTreeNode<T>(); }
14    ~BTree() { if (_root) release(_root); } //析构函数：释放所有节点
15    int const order() { return _order; } //阶次
16    int const size() { return _size; } //规模
17    BTreeNodePosi(T) & root() { return _root; } //树根
18    bool empty() const { return !_root; } //判空
19    BTreeNodePosi(T) search(const T& e); //查找
20    bool insert(const T& e); //插入
21    bool remove(const T& e); //删除
22 }; //BTree

```

代码8.7 B-树

后面将会看到，B-树的关键词插入操作和删除操作，可能会引发节点的上溢和下溢。因此，这里设有内部接口solveOverflow()和solveUnderflow()，分别用于修正此类问题。在稍后的8.2.6节和8.2.8节中，将分别讲解其具体原理及实现。

8.2.3 关键词查找

■ 算法

如前述，B-树结构非常适宜于在相对更小的内存中，实现对大规模数据的高效操作。

一般地如图8.13所示，可以将大数据集组织为B-树并存放于外存。对于活跃的B-树，其根节点会常驻于内存；此外，任何时刻通常只有另一节点（称作当前节点）留驻于内存。

B-树的查找过程，与二叉搜索树的查找过程基本类似。

首先以根节点作为当前节点，然后再逐层深入。若在当前节点（所包含的一组关键词）中能够找到目标关键词，则成功返回。否则（在当前节点中查找“失败”），则必可在当前节点中确定某一个引用（“失败”位置），并通过它转至逻辑上处于下一层的另一节点。若该节点不是外部节点，则将其载入内存，并更新为当前节点，然后继续重复上述过程。

整个过程如图8.13所示，从根节点开始，通过关键码的比较不断深入至下一层，直到某一关键码命中（查找成功），或者到达某一外部节点（查找失败）。

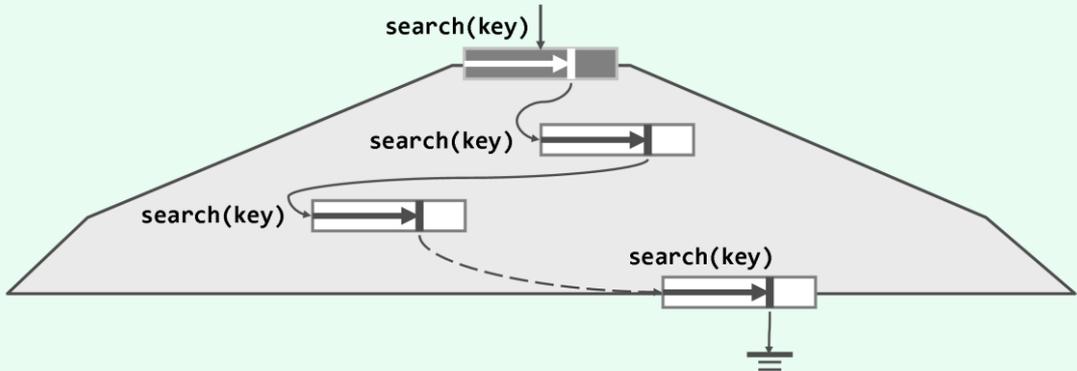


图8.13 B-树的查找过程

与二叉搜索树的不同之处在于，因此时各节点内通常都包含多个关键码，故有可能需要经过（在内存中的）多次比较，才能确定应该转向下一层的哪个节点并继续查找。

仍以如图8.12所示的4阶B-树为例，查找关键码41的过程大致如下：在根节点处经过一次关键码比较（25）之后，即可确定应转入第2个分支；再经过两次比较（34，43）之后，确定转入第2个分支；最后经过三次比较（37，40，41）之后，才成功地找到目标关键码。查找关键码42的过程与之类似，只是在最底层的内部节点内，需要经过三次关键码比较（37，40，41）之后，才确定应转入关键码41右侧的外部节点，从而最终确定查找失败。

可见，只有在切换和更新当前节点时才会发生I/O操作，而在同一节点内部的查找则完全在内存中进行。因内存的访问速度远远高于外存，再考虑到各节点所含关键码数量通常在128~512之间，故可直接使用顺序查找策略，而不必采用二分查找之类的复杂策略。

■ 实现

如代码8.8所示，为简化代码，节点内部的查找直接借用了有序向量的search()接口。

```

1 template <typename T> BTreeNodePosi(T) BTree<T>::search(const T& e) { //在B-树中查找关键码e
2     BTreeNodePosi(T) v = _root; _hot = NULL; //从根节点出发
3     while (v) { //逐层查找
4         Rank r = v->key.search(e); //在当前节点中，找出不大于e的最大关键码
5         if ((0 <= r) && (e == v->key[r])) return v; //成功：在当前节点中命中目标关键码
6         _hot = v; v = v->child[r + 1]; //否则，转入对应子树（_hot指向其父）——需做I/O，最费时间
7     } //这里在向量内是二分查找，但对通常的_order可直接顺序查找
8     return NULL; //失败：最终抵达外部节点
9 }

```

代码8.8 B-树关键码的查找

与二叉搜索树的实现类似，这里也约定查找结果由返回的节点位置指代：成功时返回目标关键码所在的节点，上层调用过程可在该节点内进一步查找以确定准确的命中位置；失败时返回对应外部节点，其父节点则由变量_hot指代。

8.2.4 性能分析

由上可见，B-树查找操作所需的时间不外乎消耗于两个方面：将某一节点载入内存，以及在内存中对当前节点进行查找。鉴于内存、外存在访问速度上的巨大差异，相对于前一类时间消耗，后一类时间消耗可以忽略不计。也就是说，B-树查找操作的效率主要取决于查找过程中的外存访问次数。那么，至多需要访问多少次外存呢？

由前节分析可见，与二叉搜索树类似，B-树的每一次查找过程中，在每一高度上至多访问一个节点。这就意味着，对于高度为 h 的B-树，外存访问不超过 $\mathcal{O}(h - 1)$ 次。

B-树节点的分支数并不固定，故其高度 h 并不完全取决于树中关键码的总数 n 。对于包含 N 个关键码的 m 阶B-树，高度 h 具体可在多大范围内变化？就渐进意义而言， h 与 m 及 N 的关系如何？

■ 树高

可以证明，若存有 N 个关键码的 m 阶B-树高度为 h ，则必有：

$$\log_m(N + 1) \leq h \leq \log_{\lceil m/2 \rceil} \lfloor (N + 1) / 2 \rfloor + 1 \dots\dots\dots \text{(式8-1)}$$

首先证明 $h \leq \log_{\lceil m/2 \rceil} \lfloor (N+1)/2 \rfloor + 1$ 。关键码总数固定时，为使B-树更高，各内部节点都应包含尽可能少的关键码。于是按照B-树的定义，各高度层次上节点数目至少是：

$$\begin{aligned} n_0 &= 1 \\ n_1 &= 2 \\ n_2 &= 2 \times \lceil m / 2 \rceil \\ n_3 &= 2 \times \lceil m / 2 \rceil^2 \\ &\dots \\ n_{h-1} &= 2 \times \lceil m / 2 \rceil^{h-2} \\ n_h &= 2 \times \lceil m / 2 \rceil^{h-1} \end{aligned}$$

现考查外部节点。这些节点对应于失败的查找，故其数量 n_h 应等于失败查找可能情形的总数，即应比成功查找可能情形的总数恰好多1，而后者等于关键码的总数 N 。于是有

$$N + 1 = n_h \geq 2 \times (\lceil m / 2 \rceil)^{h-1}, \quad h \geq 1$$

即 $h \leq 1 + \log_{\lceil m/2 \rceil} \lfloor (N + 1) / 2 \rfloor = \mathcal{O}(\log_m N)$

再来证明 $h \geq \log_m(N + 1)$ 。同理，关键码总数固定时，为使B-树更矮，每个内部节点都应该包含尽可能多的关键码。按照B-树的定义，各高度层次上的节点数目至多是：

$$\begin{aligned} n_0 &= 1 \\ n_1 &= m \\ n_2 &= m^2 \\ &\dots \\ n_{h-1} &= m^{h-1} \\ n_h &= m^h \end{aligned}$$

与上同理，有

$$N + 1 = n_h \leq m^h$$

即 $h \geq \log_m(N + 1) = \Omega(\log_m N)$

总之，式8-1必然成立。也就是说，存有 N 个关键码的 m 阶B-树的高度 $h = \Theta(\log_m N)$ 。

■ 复杂度

因此，每次查找过程共需访问 $O(\log_m N)$ 个节点，相应地需要做 $O(\log_m N)$ 次外存读取操作。由此可知，对存有 N 个关键码的 m 阶B-树的每次查找操作，耗时不超过 $O(\log_m N)$ 。

需再次强调的是，尽管没有渐进意义上的改进，但相对而言极其耗时的I/O操作的次数，却已大致缩减为原先的 $1/\log_2 m$ 。鉴于 m 通常取值在256至1024之间，较之此前大致降低一个数量级，故使用B-树后，实际的访问效率将有十分可观的提高。

8.2.5 关键码插入

B-树的关键码插入算法，可实现如代码8.9所示。

```

1 template <typename T> bool BTree<T>::insert(const T& e) { //将关键码e插入B树中
2     BTreeNodePosi(T) v = search(e); if (v) return false; //确认目标节点不存在
3     Rank r = _hot->key.search(e); //在节点_hot的有序关键码向量中查找合适的插入位置
4     _hot->key.insert(r + 1, e); //将新关键码插至对应的位置
5     _hot->child.insert(r + 2, NULL); //创建一个空子树指针
6     _size++; //更新全树规模
7     solveOverflow(_hot); //如有必要，需做分裂
8     return true; //插入成功
9 }

```

代码8.9 B-树关键码的插入

为在B-树中插入一个新的关键码 e ，首先调用 $\text{search}(e)$ 在树中查找该关键码。若查找成功，则按照“禁止重复关键码”的约定不予插入，操作即告完成并返回 false 。

否则，按照代码8.8的出口约定，查找过程必然终止于某一外部节点 v ，且其父节点由变量 $_hot$ 指示。当然，此时的 $_hot$ 必然指向某一叶节点（可能同时也是根节点）。接下来，在该节点中再次查找目标关键码 e 。尽管这次查找注定失败，却可以确定 e 在其中的正确插入位置 r 。最后，只需将 e 插至这一位置。

至此， $_hot$ 所指的节点中增加了一个关键码。若该节点内关键码的总数依然合法（即不超过 $m - 1$ 个），则插入操作随即完成。否则，称该节点发生了一次上溢（overflow），此时需要通过适当的处理，使该节点以及整树重新满足B-树的条件。由代码8.9可见，这项任务将借助调整算法 $\text{solveOverflow}(_hot)$ 来完成。

8.2.6 上溢与分裂

■ 算法

一般地，刚发生上溢的节点，应恰好含有 m 个关键码。若取 $s = \lfloor m/2 \rfloor$ ，则它们依次为：

$$\{ k_0, \dots, k_{s-1}; k_s; k_{s+1}, \dots, k_{m-1} \}$$

可见，以 k_s 为界，可将该节点分前、后两个子节点，且二者大致等长。于是，可令关键码 k_s 上升一层，归入其父节点（若存在）中的适当位置，并分别以这两个子节点作为其左、右孩子。这一过程，称作节点的分裂（split）。

不难验证，如此分裂所得的两个孩子节点，均符合 m 阶B-树关于节点分支数的条件。

■ 可能的情况

以如图8.14(a1)所示的6阶B-树局部为例，其中节点{ 17, 20, 31, 37, 41, 56 }，因所含关键码增至6个而发生上溢。为完成修复，可以关键码37为界，将该节点分裂为{ 17, 20, 31 }和{ 41, 56 }；关键码37则上升一层，并以分裂出来的两个子节点作为左、右孩子。

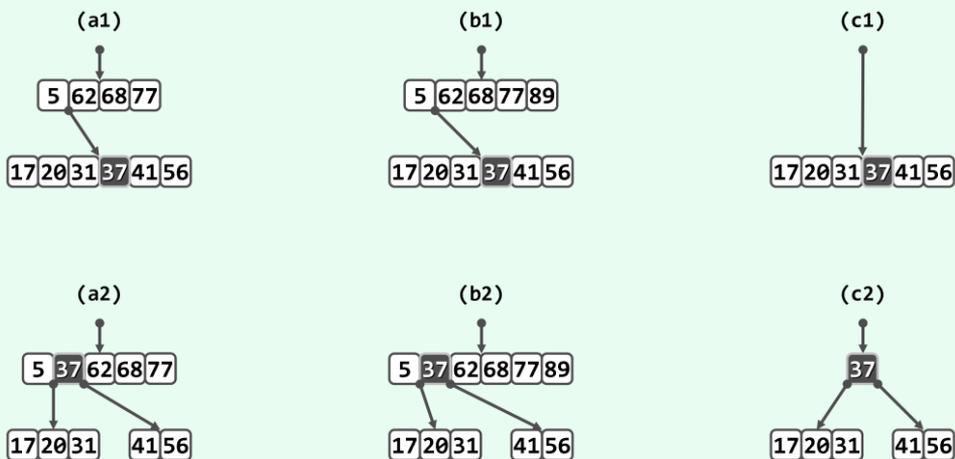


图8.14 通过分裂修复上溢节点

被提升的关键码，可能有三种进一步的处置方式。首先如图(a1)所示，设原上溢节点的父节点存在，且足以接纳一个关键码。此种情况下，只需将被提升的关键码(37)按次序插入父节点中，修复即告完成，修复后的局部如图(a2)所示。

其次如图(b1)所示，尽管上溢节点的父节点存在，但业已处于饱和状态。此时如图(b2)，在强行将被提升的关键码插入父节点之后，尽管上溢节点也可得到修复，却会导致其父节点继而发生上溢——这种现象称作上溢的向上传递。好在每经过一次这样的修复，上溢节点的高度都必然上升一层。这意味着上溢的传递不至于没有尽头，最远不至超过树根。

最后如图(c1)所示，若上溢果真传递至根节点，则可令被提升的关键码(37)自成一个节点，并作为新的树根。于是如图(c2)所示，至此上溢修复完毕，全树增高一层。可见，整个过程中所做分裂操作的次数，必不超过全树的高度——根据8.2.4节结论，即 $O(\log_m N)$ 。

■ 实现

以上针对上溢的处理算法，可实现如代码8.10所示。

```

1 template <typename T> //关键码插入后若节点上溢，则做节点分裂处理
2 void BTree<T>::solveOverflow(BTNodePosi(T) v) {
3     if (_order >= v->child.size()) return; //递归基：当前节点并未上溢
4     Rank s = _order / 2; //轴点（此时应有_order = key.size() = child.size() - 1）
5     BTNodePosi(T) u = new BTNode<T>(); //注意：新节点已有一个空孩子
6     for (Rank j = 0; j < _order - s - 1; j++) { //v右侧的_order-s-1个孩子及关键码分裂为右侧节点u
7         u->child.insert(j, v->child.remove(s + 1)); //逐个移动效率低
8         u->key.insert(j, v->key.remove(s + 1)); //此策略可改进
9     }
10    u->child[_order - s - 1] = v->child.remove(s + 1); //移动v最靠右的孩子

```

```

11  if (u->child[0]) //若u的孩子们非空, 则
12      for (Rank j = 0; j < _order - s; j++) //将它们父节点统一
13          u->child[j]->parent = u; //指向u
14  BTreeNodePosi(T) p = v->parent; //v当前的父节点p
15  if (!p) { _root = p = new BTreeNode<T>(); p->child[0] = v; v->parent = p; } //若p为空则创建之
16  Rank r = 1 + p->key.search(v->key[0]); //p中指向u的指针的秩
17  p->key.insert(r, v->key.remove(s)); //轴点关键码上升
18  p->child.insert(r + 1, u); u->parent = p; //新节点u与父节点p互联
19  solveOverflow(p); //上升一层, 如有必要则继续分裂——至多递归O(logn)层
20 }

```

代码8.10 B-树节点的上溢处理

请特别留意上溢持续传播至根的情况：原树根分裂之后，新创建的树根仅含单关键码。由此也可看出，就B-树节点分支数的下限要求而言，树根节点的确应该作为例外。

■ 实例

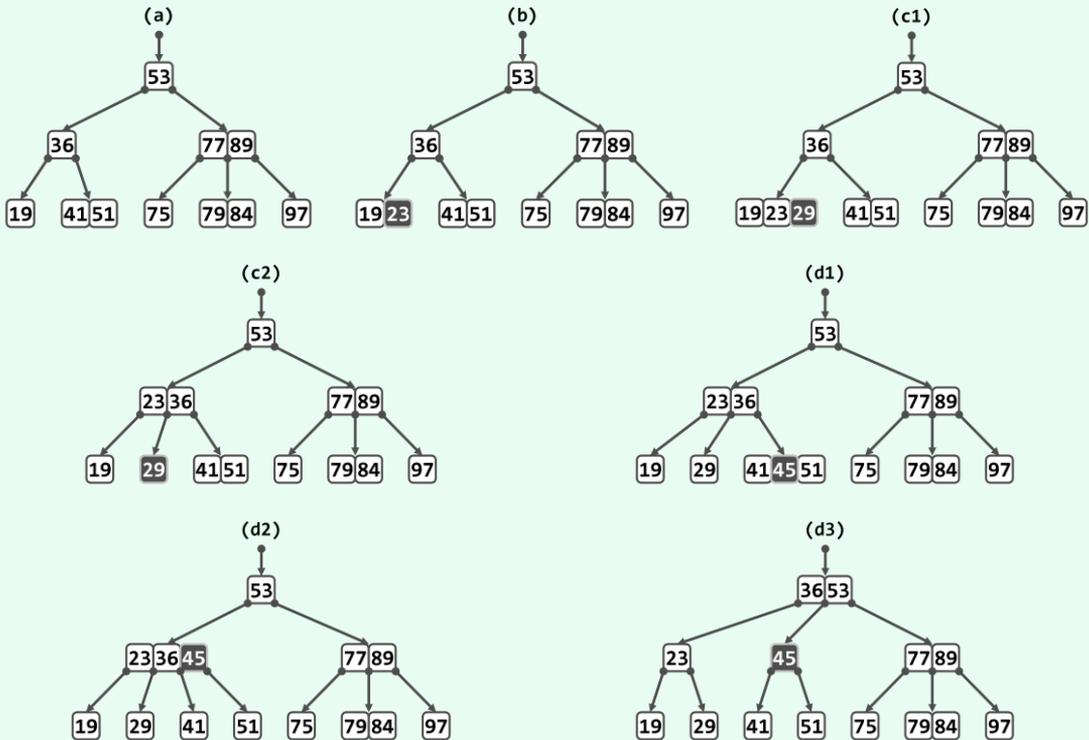


图8.15 3阶B-树插入操作实例 (I)

考查如图8.15(a)所示的3阶B-树。执行insert(23)后未发生任何上溢；如(b)所示不必做任何调整。接下来执行insert(29)后，如图(c1)所示发生上溢；经一次分裂即完全修复，结果如图(c2)所示。继续执行insert(45)后，如图(d1)所示发生上溢；经分裂做局部修复之后，如图(d2)所示上一层再次发生上溢；经再次分裂后，方得以实现全树的修复，结果如图(d3)所示。

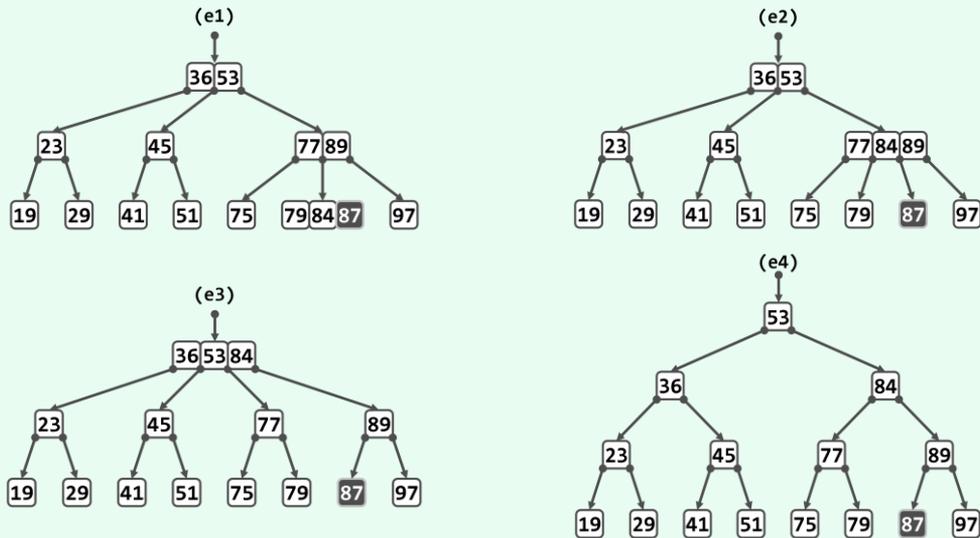


图8.16 3阶B-树插入操作实例 (II)

最后, 执行`insert(87)`后如图8.16(e1)所示亦发生上溢; 经局部分裂调整后, 在更高层将持续发生上溢, 故如图(e2)、(e3)和(e4)所示, 先后总共经三次分裂, 方得以实现全树的修复。此时因一直分裂至根节点, 故最终全树高度增加一层——这也是B-树长高的唯一可能。

■ 复杂度

若将B-树的阶次 m 视作为常数, 则关键码的移动和复制操作所需的时间都可以忽略。至于`solveOverflow()`算法, 其每一递归实例均只需常数时间, 递归层数不超过B-树高度。由此可知, 对于存有 N 个关键码的 m 阶B-树, 每次插入操作都可在 $O(\log_m N)$ 时间内完成。

实际上, 因插入操作而导致 $\Omega(\log_m N)$ 次分裂的情况极为罕见, 单次插入操作平均引发的分裂次数, 远远低于这一估计(习题[8-6]), 故时间通常主要消耗于对目标关键码的查找。

8.2.7 关键码删除

```

1 template <typename T> bool BTree<T>::remove(const T& e) { //从BTree树中删除关键码e
2     BTreeNodePosi(T) v = search(e); if (!v) return false; //确认目标关键码存在
3     Rank r = v->key.search(e); //确定目标关键码在节点v中的秩(由上, 肯定合法)
4     if (v->child[0]) { //若v非叶子, 则e的后继必属于某叶节点
5         BTreeNodePosi(T) u = v->child[r+1]; //在右子树中一直向左, 即可
6         while (u->child[0]) u = u->child[0]; //找出e的后继
7         v->key[r] = u->key[0]; v = u; r = 0; //并与其交换位置
8     } //至此, v必然位于最底层, 且其中第r个关键码就是待删除者
9     v->key.remove(r); v->child.remove(r + 1); _size--; //删除e, 以及其下两个外部节点之一
10    solveUnderflow(v); //如有必要, 需做旋转或合并
11    return true;
12 }

```

代码8.11 B-树关键码的删除

B-树的关键码删除算法的实现如代码8.11所示。

为从B-树中删除关键码 e ，也首先需要调用 $\text{search}(e)$ 查找 e 所属的节点。倘若查找失败，则说明关键码 e 尚不存在，删除操作即告完成；否则按照代码8.8的出口约定，目标关键码所在的节点必由返回的位置 v 指示。此时，通过顺序查找，即可进一步确定 e 在节点 v 中的秩 r 。

不妨假定 v 是叶节点——否则， e 的直接前驱（后继）在其左（右）子树中必然存在，而且可在 $O(\text{height}(v))$ 时间内确定它们的位置，其中 $\text{height}(v)$ 为节点 v 的高度。此处不妨选用直接后继。于是， e 的直接后继关键码所属的节点 u 必为叶节点，且该关键码就是其中的最小者 $u[0]$ 。既然如此，只要令 e 与 $u[0]$ 互换位置，即可确保待删除的关键码 e 所属的节点 v 是叶节点。

于是，接下来可直接将 e （及其左侧的外部空节点）从 v 中删去。如此，节点 v 中所含的关键码以及（空）分支将分别减少一个。

此时，若该节点所含关键码的总数依然合法（即不少于 $\lceil m/2 \rceil - 1$ ），则删除操作随即完成。否则，称该节点发生了下溢（underflow），并需要通过适当的处置，使该节点以及整树重新满足B-树的条件。由代码8.11可见，这项任务将借助调整算法 $\text{solveUnderflow}(v)$ 来完成。

8.2.8 下溢与合并

由上，在 m 阶B-树中，刚发生下溢的节点 v 必恰好包含 $\lceil m/2 \rceil - 2$ 个关键码和 $\lceil m/2 \rceil - 1$ 个分支。以下将根据其左、右兄弟所含关键码的数目，分三种情况做相应的处置。

■ v 的左兄弟 L 存在，且至少包含 $\lceil m/2 \rceil$ 个关键码



图8.17 下溢节点向父亲“借”一个关键码，父亲再向左兄弟“借”一个关键码

如图8.17(a)所示，不妨设 L 和 V 分别是其父节点 P 中关键码 y 的左、右孩子， L 中最大关键码为 x ($x \leq y$)。此时可如图(b)所示，将 y 从节点 P 转移至节点 V 中（作为最小关键码），再将 x 从 L 转移至 P 中（取代原关键码 y ）。至此，局部乃至整树都重新满足B-树条件，下溢修复完毕。

■ v 的右兄弟 R 存在，且至少包含 $\lceil m/2 \rceil$ 个关键码

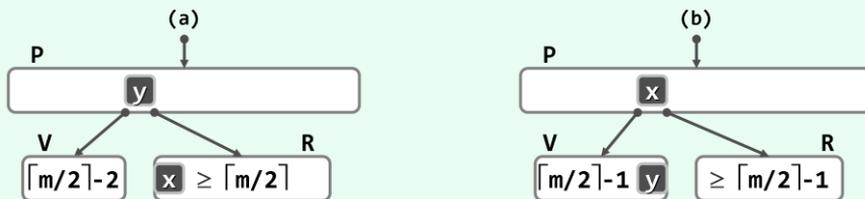


图8.18 下溢节点向父亲“借”一个关键码，父亲再向右兄弟“借”一个关键码

如图8.18所示，可参照前一情况对称地修复，不再赘述。

■ V的左、右兄弟L和R或者不存在，或者其包含的关键码均不足 $\lceil m/2 \rceil$ 个

实际上，此时的L和R不可能同时不存在。如图8.19(a)所示，不失一般性地设左兄弟节点L存在。当然，此时节点L应恰好包含 $\lceil m/2 \rceil - 1$ 个关键码。



图8.19 下溢节点向父亲“借”一个关键码，然后与左兄弟“粘接”成一个节点

于是为修复节点V的下溢缺陷，可如图(b)所示，从父节点P中抽出介于L和V之间的关键码y，并通过该关键码将节点L和V“粘接”成一个节点——这一过程称作节点的合并(merge)。注意，在经如此合并而得新节点中，关键码总数应为：

$$(\lceil m/2 \rceil - 1) + 1 + (\lceil m/2 \rceil - 2) = 2 \times \lceil m/2 \rceil - 2 \leq m - 1$$

故原节点V的下溢缺陷得以修复，而且同时也不致于反过来引发上溢。

接下来，还须检查父节点P——关键码y的删除可能致使该节点出现下溢。好在，即便如此，也尽可套用上述三种方法继续修复节点P。当然，修复之后仍可能导致祖父节点以及更高层节点的下溢——这种现象称作下溢的传递。特别地，当下溢传递至根节点且其中不再含有任何关键码时，即可将其删除并代之以其唯一的子节点，全树高度也随之下降一层。

与上溢传递类似地，每经过一次下溢修复，新下溢节点的高度都必然上升一层。再次由8.2.4节的式8-1可知，整个下溢修复的过程中至多需做 $O(\log_m N)$ 次节点合并操作。

■ 实现

对下溢节点的整个处理过程，如代码8.12所示。

```

1 template <typename T> //关键码删除后若节点下溢，则做节点旋转或合并处理
2 void BTree<T>::solveUnderflow(BTNodePosi(T) v) {
3     if ((order + 1) / 2 <= v->child.size()) return; //递归基：当前节点并未下溢
4     BTNodePosi(T) p = v->parent;
5     if (!p) { //递归基：已到根节点，没有孩子的下限
6         if (!v->key.size() && v->child[0]) {
7             //但倘若作为树根的v已不含关键码，却有(唯一的)非空孩子，则
8             _root = v->child[0]; _root->parent = NULL; //这个节点可被跳过
9             v->child[0] = NULL; release(v); //并因不再有用而被销毁
10        } //整树高度降低一层
11    }
12    return;
13    Rank r = 0; while (p->child[r] != v) r++;
14    //确定v是p的第r个孩子——此时v可能不含关键码，故不能通过关键码查找
15    //另外，在实现了孩子指针的判等器之后，也可直接调用Vector::find()定位
16    //情况1：向左兄弟借关键码

```

```

17  if (0 < r) { //若v不是p的第一个孩子，则
18      BTreeNodePosi(T) ls = p->child[r - 1]; //左兄弟必存在
19      if ((l_order + 1) / 2 < ls->child.size()) { //若该兄弟足够“胖”，则
20          v->key.insert(0, p->key[r - 1]); //p借出一个关键码给v（作为最小关键码）
21          p->key[r - 1] = ls->key.remove(ls->key.size() - 1); //ls的最大关键码转入p
22          v->child.insert(0, ls->child.remove(ls->child.size() - 1));
23          //同时ls的最右侧孩子过继给v
24          if (v->child[0]) v->child[0]->parent = v; //作为v的最左侧孩子
25          return; //至此，通过右旋已完成当前层（以及所有层）的下溢处理
26      }
27  } //至此，左兄弟要么为空，要么太“瘦”
28 // 情况2：向右兄弟借关键码
29  if (p->child.size() - 1 > r) { //若v不是p的最后一个孩子，则
30      BTreeNodePosi(T) rs = p->child[r + 1]; //右兄弟必存在
31      if ((l_order + 1) / 2 < rs->child.size()) { //若该兄弟足够“胖”，则
32          v->key.insert(v->key.size(), p->key[r]); //p借出一个关键码给v（作为最大关键码）
33          p->key[r] = rs->key.remove(0); //rs的最小关键码转入p
34          v->child.insert(v->child.size(), rs->child.remove(0));
35          //同时rs的最左侧孩子过继给v
36          if (v->child[v->child.size() - 1]) //作为v的最右侧孩子
37              v->child[v->child.size() - 1]->parent = v;
38          return; //至此，通过左旋已完成当前层（以及所有层）的下溢处理
39      }
40  } //至此，右兄弟要么为空，要么太“瘦”
41 // 情况3：左、右兄弟要么为空（但不可能同时），要么都太“瘦”——合并
42  if (0 < r) { //与左兄弟合并
43      BTreeNodePosi(T) ls = p->child[r - 1]; //左兄弟必存在
44      ls->key.insert(ls->key.size(), p->key.remove(r - 1)); p->child.remove(r);
45      //p的第r - 1个关键码转入ls，v不再是p的第r个孩子
46      ls->child.insert(ls->child.size(), v->child.remove(0));
47      if (ls->child[ls->child.size() - 1]) //v的最左侧孩子过继给ls做最右侧孩子
48          ls->child[ls->child.size() - 1]->parent = ls;
49      while (!v->key.empty()) { //v剩余的关键码和孩子，依次转入ls
50          ls->key.insert(ls->key.size(), v->key.remove(0));
51          ls->child.insert(ls->child.size(), v->child.remove(0));
52          if (ls->child[ls->child.size() - 1]) ls->child[ls->child.size() - 1]->parent = ls;
53      }
54      release(v); //释放v
55  } else { //与右兄弟合并
56      BTreeNodePosi(T) rs = p->child[r + 1]; //右兄弟必存在
57      rs->key.insert(0, p->key.remove(r)); p->child.remove(r);
58      //p的第r个关键码转入rs，v不再是p的第r个孩子

```

```

59     rs->child.insert(0, v->child.remove(v->child.size() - 1));
60     if (rs->child[0]) rs->child[0]->parent = rs; //v的最左侧孩子过继给1s做最右侧孩子
61     while (!v->key.empty()) { //v剩余的关键词和孩子,依次转入rs
62         rs->key.insert(0, v->key.remove(v->key.size() - 1));
63         rs->child.insert(0, v->child.remove(v->child.size() - 1));
64         if (rs->child[0]) rs->child[0]->parent = rs;
65     }
66     release(v); //释放v
67 }
68 solveUnderflow(p); //上升一层,如有必要则继续分裂——至多递归O(logn)层
69 return;
70 }

```

代码8.12 B-树节点的下溢处理

如前所述,若下溢现象持续传播至树根,且树根当时仅含一个关键词。于是,在其仅有的两个孩子被合并、仅有的一个关键词被借出之后,原树根将退化为单分支节点。对这一特殊情况,需删除该树根,并以刚合并而成的节点作为新的树根——整树高度也随之降低一层。

实例

考查如图8.20(a)所示的3阶B-树。

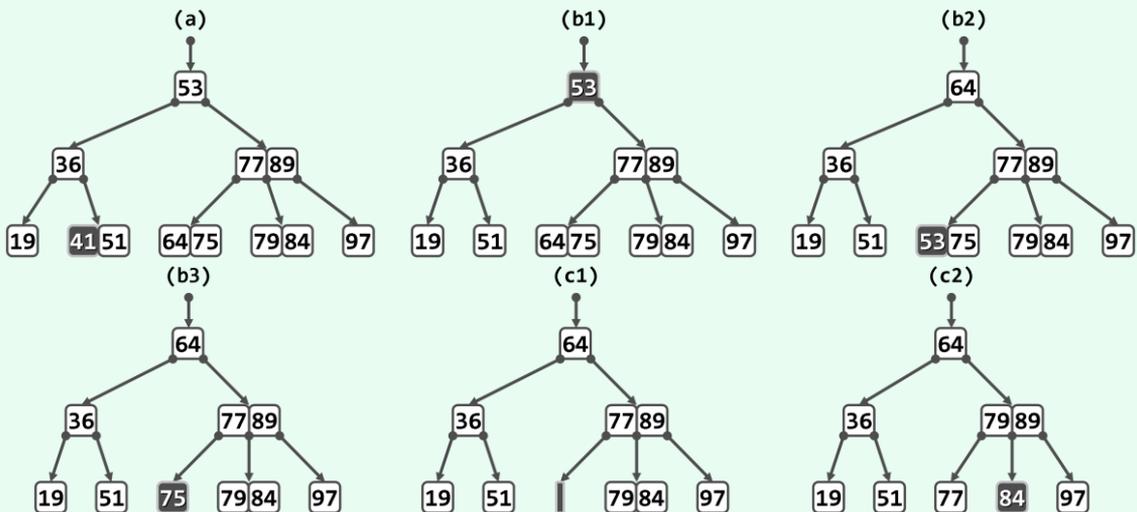


图8.20 3阶B-树删除操作实例 (I)

首先执行`remove(41)`: 因关键词41来自底层叶节点,且从中删除该关键词后未发生下溢,故无需修复,结果如图(b1)所示。接下来执行`remove(53)`: 因关键词53并非来自底层叶节点,故在将该关键词与其直接后继64交换位置之后,如图(b2)所示关键词,53必属于某底层叶节点;在删除该关键词之后,其所属节点并未发生下溢,故亦无需修复,结果如图(b3)所示。

然后执行`remove(75)`: 关键词75来自底层叶节点,故被直接删除后其所属节点如图(c1)所示发生下溢;在经父节点中转,从右侧兄弟间接借得一个关键词之后,结果如图(c2)所示。

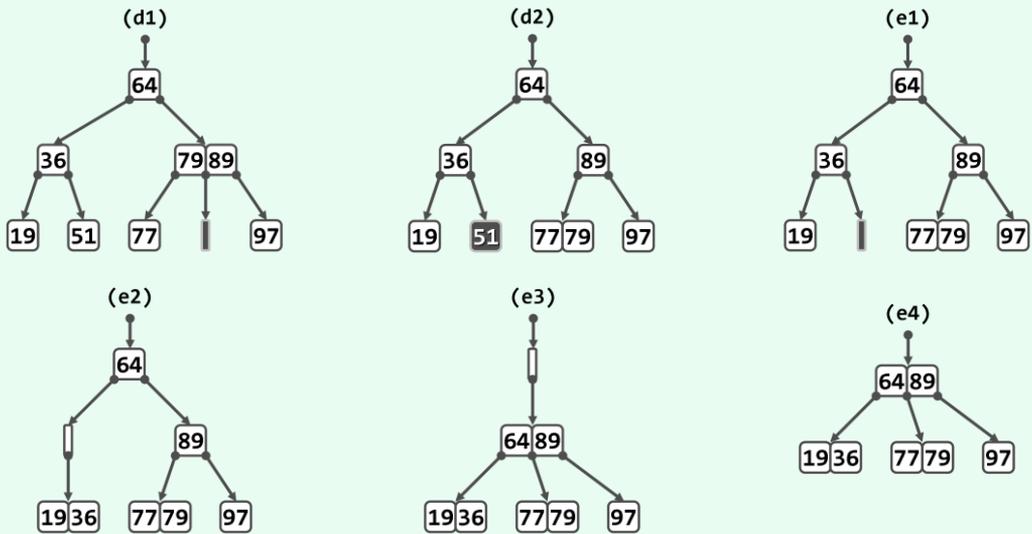


图8.21 3阶B-树删除操作实例(II)

继续执行`remove(84)`: 同样地, 删除关键码84后, 其原属底层叶节点如以图8.21(d1)所示发生下溢; 此时左、右兄弟均无法借出关键码, 故在从父节点借得关键码79后, 该下溢节点可与其左侧兄弟合并; 父节点借出一个关键码之后尚未下溢, 故结果如图(d2)所示。

最后执行`remove(51)`: 删除关键码51后, 其原属底层叶节点如图(e1)所示发生下溢; 从父节点借得关键码36后, 该节点可与左侧兄弟合并, 但父节点如图(e2)所示因此发生下溢; 从祖父(根)节点借得关键码64后, 父节点可与其右侧兄弟合并, 但祖父节点如图(e3)所示因此发生下溢。此时已抵达树根, 故直接删除空的根节点, 如图(e4)所示全树高度降低一层。

■ 复杂度

与插入操作同理, 在存有 N 个关键码的 m 阶B-树中的每次关键码删除操作, 都可以在 $\mathcal{O}(\log_m N)$ 时间内完成。另外同样地, 因某一关键码的删除而导致 $\Omega(\log_m N)$ 次合并操作的情况也极为罕见, 单次删除操作过程中平均只需做常数节点的合并。

§ 8.3 *红黑树

平衡二叉搜索树的形式多样, 且各具特色。比如, 8.1节的伸展树实现简便、无需修改节点结构、分摊复杂度低, 但可惜最坏情况下的单次操作需要 $\Omega(n)$ 时间, 故难以适用于核电站、医院等对可靠性和稳定性要求极高的场合。反之, 7.4节的AVL树尽管可以保证最坏情况下的单次操作速度, 但需在节点中嵌入平衡因子等标识; 更重要的是, 删除操作之后的重平衡可能需做多达 $\Omega(\log n)$ 次旋转, 从而频繁地导致全树整体拓扑结构的大幅度变化。

红黑树即是针对后一不足的改进。通过为节点指定颜色, 并巧妙地动态调整, 红黑树可保证: 在每次插入或删除操作之后的重平衡过程中, 全树拓扑结构的更新仅涉及常数个节点。尽管最坏情况下需对多达 $\Omega(\log n)$ 个节点重染色, 但就分摊意义而言仅为 $\mathcal{O}(1)$ 个(习题[8-14])。

当然, 为此首先需在AVL树“适度平衡”标准的基础上, 进一步放宽条件。实际上, 红黑树所采用的“适度平衡”标准, 可大致表述为: **任一节点左、右子树的高度, 相差不得超过两倍。**

8.3.1 概述

■ 定义与条件

为便于对红黑树的理解、实现与分析，这里不妨仿照8.2.1节中B-树的做法，如图8.22所示统一地引入 $n + 1$ 个外部节点，以保证原树中每一节点（现称作内部节点，白色八角形）的左、右孩子均非空——尽管有可能其中之一甚至二者同时是外部节点。当然，这些外部节点的引入只是假想式的，在具体实现时并不一定需要兑现为真实的节点。如此扩展之后的便利之处在于，我们的考查范围只需覆盖真二叉树。

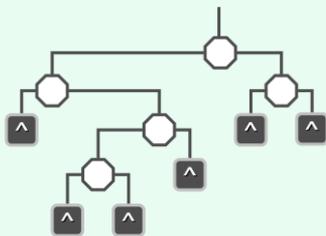


图8.22 通过假想式地引入外部节点（黑色正方形），将二叉树扩展为真二叉树

由红、黑两色节点组成的二叉搜索树若满足以下条件，即为红黑树^①（red-black tree）：

- (1) 树根始终为黑色
- (2) 外部节点均为黑色
- (3) 其余节点若为红色，则其孩子节点必为黑色
- (4) 从任一外部节点到根节点的沿途，黑节点的数目相等

其中，条件(1)和(2)意味着红节点均为内部节点，且其父节点及左、右孩子必然存在。另外，条件(3)意味着红节点之父必为黑色，因此树中任一通路都不含相邻的红节点。

由此可知，在从根节点通往任一节点的沿途，黑节点都不少于红节点。除去根节点本身，沿途所经黑节点的总数称作该节点的黑深度（black depth）——根节点的黑深度为0，其余依此类推。故条件(4)亦可等效地理解和描述为“所有外部节点的黑深度统一”。

由条件(4)可进一步推知，在从任一节点通往其任一后代外部节点的沿途，黑节点的总数亦必相等。除去（黑色）外部节点，沿途所经黑节点的总数称作该节点的黑高度（black height）。如此，所有外部节点的黑高度均为0，其余依此类推。

特别地，根节点的黑高度亦称作全树的黑高度，在数值上与外部节点的黑深度相等。

■ (2,4)-树

红黑树的上述定义，不免令人困惑和费解。幸运的是，借助此前已掌握的概念，我们完全可以清晰地理解和把握红黑树的定义，及其运转过程。为此，需注意到如下有趣的事实：在红黑树与8.2节的4阶B-树之间，存在极其密切的联系；经适当转换之后，二者相互等价！

具体地，自顶而下逐层考查红黑树各节点。每遇到一个红节点，都将对应的子树整体提升一层，从而与其父节点（必黑）水平对齐，二者之间的联边则相应地调整为横向。

如此转换之后，横向边或向左或向右，但由红黑树的条件(3)，同向者彼此不会相邻；即便不考虑联边的左右方向，沿水平方向相邻的边至多两条（向左、右各一条），涉及的节点至多三个（一个黑节点加上零到两个红节点）。此时，若将原红黑树的节点视作关键码，沿水平方向相邻的每一组（父子至多三个）节点即恰好构成4阶B-树的一个节点。

^① 其雏形由R. Bayer于1972年发明^[44]，命名为对称二叉B-树（symmetric binary B-tree）后由L. J. Guibas与R. Sedgwick于1978年做过改进^[45]，并定名为红黑树（red-black tree）

图8.23针对所有可能的四种情况，分别给出了具体的转换过程。可见，按照上述对应关系，每棵红黑树都等价于一棵(2,4)-树；前者的每一节点都对应于后者的一个关键码。通往黑节点的边，对黑高度有贡献，并在(2,4)-树中得以保留；通往红节点的边对黑高度没有贡献，在(2,4)-树中对应于节点内部一对相邻的关键码。在本节的插图中，这两类边将分别以实线、虚线示意。

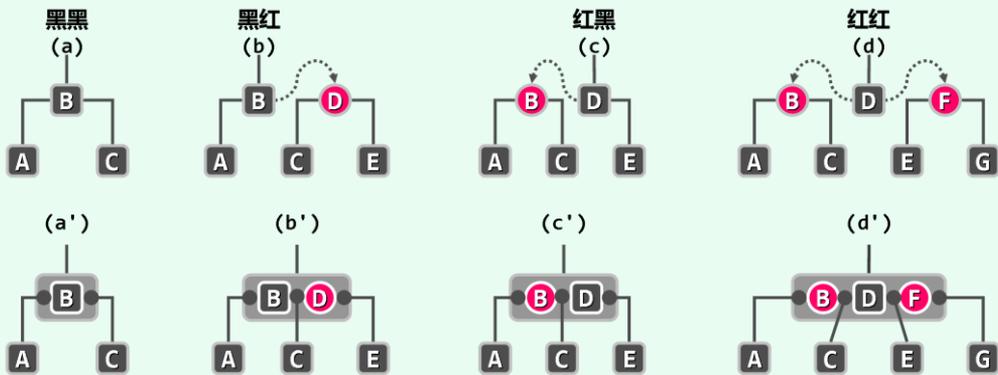


图8.23 红黑树到4阶B-树的等价转换（在完全彩色版尚未出版之前本书约定，分别以圆形、正方形和八角形表示红黑树的红节点、黑节点和颜色未定节点，以长方形表示B-树节点）

为使讲解简洁，在不致引起歧义的前提下，以下将不再严格区分红黑树中的节点及其在(2,4)-树中对应的关键码。当然，照此理解，此时的关键码也被赋予了对应的颜色。对照红黑树的条件，(2,4)-树中的每个节点应包含且仅包含一个黑关键码，同时红关键码不得超过两个。而且，若某个节点果真包含两个红关键码，则黑关键码的位置必然居中。

■ 平衡性

与所有二叉搜索树一样，红黑树的性能首先取决于其平衡性。那么，红黑树的高度可以在多大范围之内变化呢？实际上，即便计入扩充的外部节点，包含n个内部节点的红黑树T的高度h也不致超过 $O(\log n)$ 。更严格地有：

$$\log_2(n + 1) \leq h \leq 2 \cdot \log_2(n + 1)$$

左侧的“ \leq ”显然成立，故以下只需证明右侧“ \leq ”也成立。

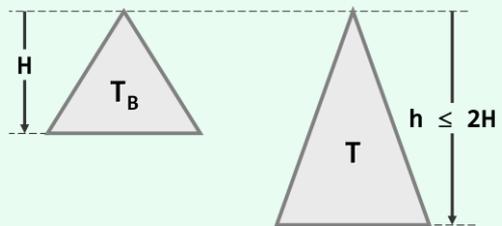


图8.24 红黑树的黑高度不低于高度的一半；反之，高度不超过黑高度的两倍

如图8.24所示，若将T的黑高度记作H，则H也是T所对应(2,4)-树 T_B 的高度，故由8.2.4节关于B-树高度与所含关键码总数关系的结论，有：

$$H \leq \log_{\lceil 4/2 \rceil} \left\lfloor \frac{n+1}{2} \right\rfloor + 1 \leq \log_2 \left\lfloor \frac{n+1}{2} \right\rfloor + 1 \leq \log_2(n+1)$$

另一方面，既然任一通路都不含相邻的红节点，故必有：

$$h \leq 2H \leq 2 \cdot \log_2(n+1) = O(\log n)$$

也就是说，尽管红黑树不能如完全树那样可做到理想平衡，也不如AVL树那样可做到较严格的适度平衡，但其高度仍控制在最小高度的两倍以内（习题[8-11]），从渐进的角度看仍是 $O(\log n)$ ，依然保证了适度平衡——这正是红黑树可高效率支持各种操作的基础。

8.3.2 红黑树接口定义

基于185页代码7.2中的BST模板类，可派生出RedBlack模板类如代码8.13所示。

```

1 #include "../BST/BST.h" //基于BST实现RedBlack
2 template <typename T> class RedBlack : public BST<T> { //RedBlack树模板类
3 protected:
4     void solveDoubleRed(BinNodePosi(T) x); //双红修正
5     void solveDoubleBlack(BinNodePosi(T) x); //双黑修正
6     int updateHeight(BinNodePosi(T) x); //更新节点x的高度
7 public:
8     BinNodePosi(T) insert(const T& e); //插入(重写)
9     bool remove(const T& e); //删除(重写)
10 // BST::search()等其余接口可直接沿用
11 };

```

代码8.13 基于BST定义的红黑树接口

可见，这里直接沿用了二叉搜索树标准的查找算法search()，并根据红黑树的重平衡规则与算法，重写了insert()和remove()接口；新加的两个内部功能接口solveDoubleRed()和solveDoubleBlack()，分别用于在节点插入或删除之后恢复全树平衡。其具体实现稍后介绍。

另外，这里还需使用此前二叉树节点模板类BinNode（117页代码5.1）中预留的两个成员变量height和color。如代码8.14所示，仿照AVL树的实现方式，可借助辅助宏来检查节点的颜色以及判定是否需要更新（黑）高度记录，如此可大大简化相关算法的描述。

```

1 #define IsBlack(p) (!(p) || (RB_BLACK == (p)->color)) //外部节点也视作黑节点
2 #define IsRed(p) (!IsBlack(p)) //非黑即红
3 #define BlackHeightUpdated(x) ( \
4     (stature((x).lChild) == stature((x).rChild) && \
5     ((x).height == (IsRed(&x) ? stature((x).lChild) : stature((x).lChild) + 1)) \
6 ) //RedBlack高度更新条件

```

代码8.14 用以简化红黑树算法描述的宏

可见，这里的确并未真正地实现图8.22中所引入的外部节点，而是将它们统一地直接判定为黑“节点”——尽管它们实际上只不过是NULL。其余节点，则一概视作红节点。

```

1 template <typename T> int RedBlack<T>::updateHeight(BinNodePosi(T) x) { //更新红黑树节点高度
2     x->height = max(stature(x->lChild), stature(x->rChild)); //孩子一般黑高度相等，除非出现双黑
3     return IsBlack(x) ? x->height++ : x->height; //若当前节点为黑，则计入黑深度
4 } //因统一定义stature(NULL) = -1，故height比黑高度少一，好在不致影响到各种算法中的比较判断

```

代码8.15 红黑树节点的黑高度更新

此处的height已不再是指常规的树高，而是红黑树的黑高度。故如代码8.15所示，节点黑高度需要更新的情况共分三种：或者左、右孩子的黑高度不等；或者作为红节点，黑高度与其孩子不相等；或者作为黑节点，黑高度不等于孩子的黑高度加一。

8.3.3 节点插入算法

■ 节点插入与双红现象

如代码8.16所示，不妨假定经调用接口`search(e)`做查找之后，确认目标节点尚不存在。于是，在查找终止的位置`x`处创建节点，并随即将其染成红色（除非此时全树仅含一个节点）。现在，对照红黑树的四项条件，唯有(3)未必满足——亦即，此时`x`的父亲也可能是红色。

```

1 template <typename T> BinNodePosi(T) RedBlack<T>::insert(const T& e) { //将关键码e插入红黑树
2     BinNodePosi(T) & x = search(e); if (x) return x; //确认目标节点不存在(留意对_hot的设置)
3     x = new BinNode<T>(e, _hot, NULL, NULL, -1); _size++; //创建红节点x:以_hot为父,黑高度-1
4     solveDoubleRed(x); return x; //经双红修正后,即可返回
5 } //无论e是否存在于原树中,返回时总有x->data == e

```

代码8.16 红黑树`insert()`接口

因新节点的引入，而导致父子节点同为红色的此类情况，称作“双红”（double red）。为修正双红缺陷，可调用`solveDoubleRed(x)`接口。每引入一个关键码，该接口都可能迭代地调用多次。在此过程中，当前节点`x`的兄弟及两个孩子（初始时都是外部节点），始终均为黑色。

将`x`的父亲与祖父分别记作`p`和`g`。既然此前的红黑树合法，故作为红节点`p`的父亲，`g`必然存在且为黑色。`g`作为内部节点，其另一孩子（即`p`的兄弟、`x`的叔父）也必然存在，将其记作`u`。以下，视节点`u`的颜色不同，分两类情况分别处置。

■ 双红修正（RR-1）

首先，考查`u`为黑色的情况。此时，`x`的兄弟、两个孩子的黑高度，均与`u`相等。图8.25(a)和(b)即为此类情况的两种可能（另两种对称情况，请读者独立补充）。

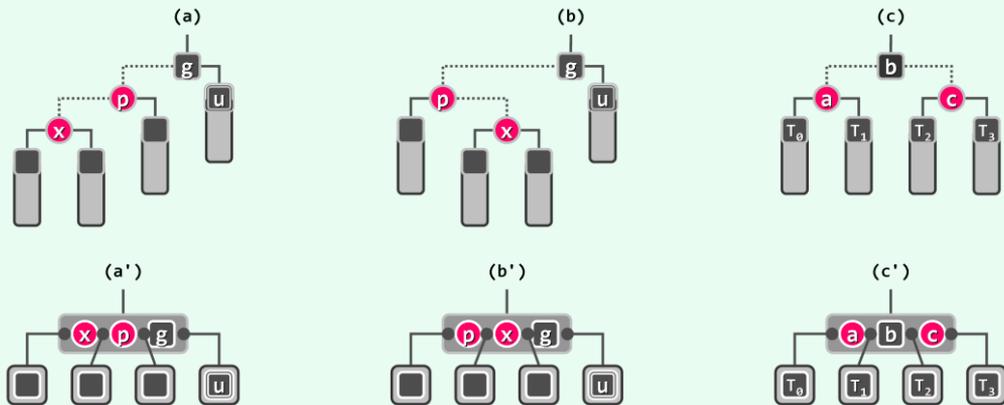


图8.25 双红修正第一种情况（RR-1）及其调整方法（上方、下方分别为红黑树及其对应B-树的局部）

此时红黑树条件(3)的违反，从B-树角度等效地看，即同一节点不应包含紧邻的红色关键码。故如图8.25(c')所示，只需令黑色关键码与紧邻的红色关键码互换颜色。从图(c)红黑树的角度看，这等效于按中序遍历次序，对节点`x`、`p`和`g`及其四棵子树，做一次局部“3 + 4”重构。

不难验证，如此调整之后，局部子树的黑高度将复原，这意味着全树的平衡也必然得以恢复。同时，新子树的根节点`b`为黑色，也不致引发新的双红现象。至此，整个插入操作遂告完成。

■ 双红修正 (RR-2)

再考查节点u为红色的情况。此时，u的左、右孩子非空且均为黑色，其黑高度必与x的兄弟以及两个孩子相等。图8.26(a)和(b)给出了两种可能的此类情况（另两种对称情况，请读者独立补充）。此时红黑树条件(3)的违反，从B-树角度等效地看，即该节点因超过4度而发生上溢。

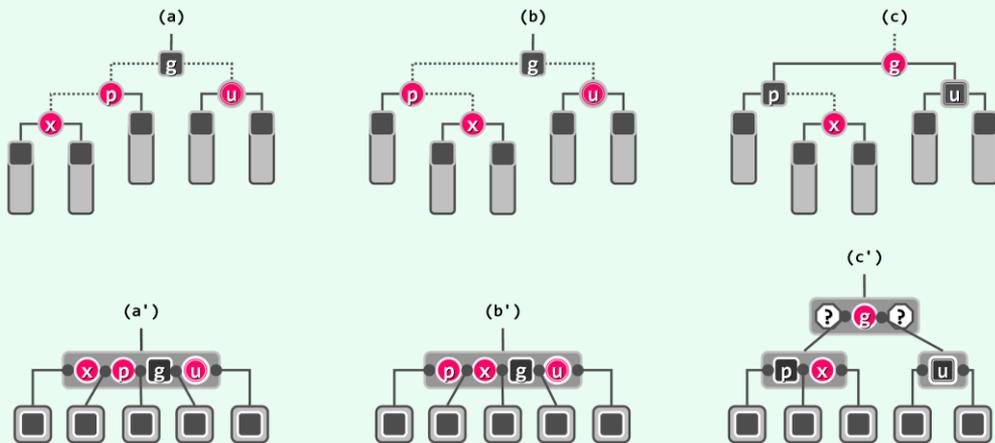


图8.26 双红修正第二种情况 (RR-2) 及其调整方法 (带问号的关键码可能存在)

以图8.26(b)为例。从图(c)红黑树的角度来看，只需将红节点p和u转为黑色，黑节点g转为红色，x保持红色。从图(c')B-树的角度来看，等效于上溢节点的一次分裂。

不难验证，如此调整之后局部子树的黑高度复原。然而，子树根节点g转为红色之后，有可能在更高层再次引发双红现象。从图8.26(c')B-树的角度来看，对应于在关键码g被移出并归入上层节点之后，进而导致上层节点的上溢——即上溢的向上传播。

若果真如此，可以等效地将g视作新插入的节点，同样地分以两类情况如法处置。请注意，每经过一次这样的迭代，节点g都将在B-树中（作为关键码）上升一层，而在红黑树中存在双红缺陷的位置也将相应地上升两层，故累计至多迭代 $O(\log n)$ 次。

特别地，若最后一步迭代之后导致原树根的分裂，并由g独立地构成新的树根节点，则应遵照红黑树条件(1)的要求，强行将其转为黑色——如此，全树的黑高度随即增加一层。

■ 双红修正的复杂度

以上情况的处理流程可归纳为图8.27。其中的重构、染色等局部操作均只需常数时间，故只需统计这些操作在修正过程中被调用的总次数。

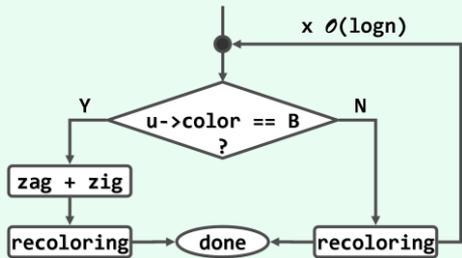


图8.27 双红修正流程图

表8.1 双红修正算法所涉及局部操作的统计

情况	#旋转	#染色	单轮修正之后
RR-1 u为黑	1~2	2	调整随即完成
RR-2 u为红	0	3	或再次双红 但必上升两层

具体统计，可归纳为表8.1。可见，对于前一种情况，只需做一轮修正；后一种情况虽可有

能需要反复修正，但由于修正位置的高度会严格单调上升，故总共也不过 $O(\log n)$ 轮。另外从该表也可看出，每一轮修正只涉及到常数次的节点旋转或染色操作。

因此，节点插入之后的双红修正，累计耗时不会超过 $O(\log n)$ 。即便计入此前的关键词查找以及节点接入等操作，红黑树的每次节点插入操作，都可在 $O(\log n)$ 时间内完成。

需要特别指出的是，只有在RR-1修复时才需做1~2次旋转；而且一旦旋转后，修复过程必然随即完成。故就全树拓扑结构而言，每次插入后仅涉及常数次调整；而且稍后将会看到，红黑树的节点删除操作亦是如此——回顾7.4节的AVL树，却只能保证前一点。

■ 双红修正算法的实现

以上针对双红缺陷的各种修正方法，可以概括并实现如代码8.17所示。

```

1  /*****
2  * RedBlack双红调整算法：解决节点x与其父均为红色的问题。分为两大类情况：
3  *   RR-1：2次颜色翻转，2次黑高度更新，1~2次旋转，不再递归
4  *   RR-2：3次颜色翻转，3次黑高度更新，0次旋转，需要递归
5  *****/
6  template <typename T> void RedBlack<T>::solveDoubleRed(BinNodePosi(T) x) { //x当前必为红
7      if (IsRoot(*x)) //若已（递归）转至树根，则将其转黑，整树黑高度也随之递增
8          { _root->color = RB_BLACK; _root->height++; return; } //否则，x的父亲p必存在
9      BinNodePosi(T) p = x->parent; if (IsBlack(p)) return; //若p为黑，则可终止调整。否则
10     BinNodePosi(T) g = p->parent; //既然p为红，则x的祖父必存在，且必为黑色
11     BinNodePosi(T) u = uncle(x); //以下，视x叔父u的颜色分别处理
12     if (IsBlack(u)) { //u为黑色（含NULL）时
13         if (IsLChild(*x) == IsLChild(*p)) //若x与p同侧（即zIg-zAg或zAg-zAg），则
14             p->color = RB_BLACK; //p由红转黑，x保持红
15         else //若x与p异侧（即zIg-zAg或zAg-zIg），则
16             x->color = RB_BLACK; //x由红转黑，p保持红
17         g->color = RB_RED; //g必定由黑转红
18     } //以上虽保证总共两次染色，但因增加了判断而得不偿失
19     //在旋转后将根置黑、孩子置红，虽需三次染色但效率更高
20     BinNodePosi(T) gg = g->parent; //曾祖父（great-grand parent）
21     BinNodePosi(T) r = FromParentTo(*g) = rotateAt(x); //调整后的子树根节点
22     r->parent = gg; //与原曾祖父联接
23 } else { //若u为红色
24     p->color = RB_BLACK; p->height++; //p由红转黑
25     u->color = RB_BLACK; u->height++; //u由红转黑
26     if (!IsRoot(*g)) g->color = RB_RED; //g若非根，则转红
27     solveDoubleRed(g); //继续调整g（类似于尾递归，可优化为迭代形式）
28 }
29 }

```

代码8.17 双红修正solveDoubleRed()

8.3.4 节点删除算法

■ 节点删除与双黑现象

```

1 template <typename T> bool RedBlack<T>::remove(const T& e) { //从红黑树中删除关键字e
2     BinNodePosi(T) & x = search(e); if (!x) return false; //确认目标节点存在 (留意对_hot的设置)
3     BinNodePosi(T) r = removeAt(x, _hot); if (0 >= --_size) return true; //实施删除
4 // assert: _hot某一孩子刚被删除, 且被r所指节点 (可能是NULL) 接替。以下检查是否失衡, 并做必要调整
5     if (!_hot) //若刚被删除的是根节点, 则将其置黑, 并更新黑高度
6         { _root->color = RB_BLACK; updateHeight(_root); return true; }
7 // assert: 以下, 原x (现r) 必非根, _hot必非空
8     if (BlackHeightUpdated(*(_hot))) //若所有祖先的黑深度依然平衡, 则无需调整
9         return true;
10    if (IsRed(r)) //否则, 若r为红, 则只需令其转黑
11        { r->color = RB_BLACK; r->height++; return true; }
12 // assert: 以下, 原x (现r) 均为黑色
13    solveDoubleBlack(r); return true; //经双黑调整后返回
14 } //若目标节点存在且被删除, 返回true; 否则返回false

```

代码8.18 红黑树remove()接口

如代码8.18所示, 为删除关键字 e , 首先调用标准接口 $BST::search(e)$, 查找目标节点 x 。若查找成功, 则调用内部接口 $removeAt(x)$ 实施删除。按照7.2.6节对该接口所做的语义约定, 其间无论是否做过一次节点交换, 均以 r 指向实际被删除节点 x 的接替者, $p = _hot$ 为其父亲。

不难验证, 此时红黑树的前两个条件继续满足, 但后两个条件却未必依然满足。

如图8.28所示, 除了其接替者 r , x 还应有另一个孩子 w 。既然 x 是实际被删除者, 故 w 必为(黑色的)外部节点NULL。

如图(a)和(a')所示, 若 x 为红色, 则在删除 x 并代之以 r 后, 条件(3~4)依然满足; 反之, 若 x 为黑色, 则要看其替代者 r 的颜色。

如图(b)和(b')所示, 若 r 为红色, 则只需将其翻转为黑色, 即可使条件(3~4)重新满足。

然而如图(c)和(c')所示, 若 x 和 r 均为黑色, 则为使条件(3~4)重新成立, 还需要做略微复杂一些的处理。

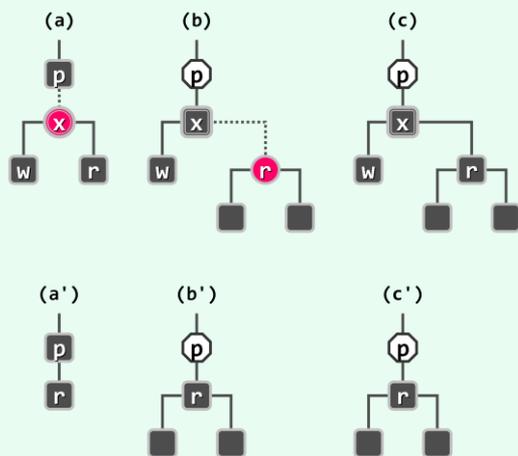


图8.28 删除节点 x 之后, 红黑树条件(4):
(a)或依然满足, (b)或经重染色后重新满足, (c)或不再满足

因某一无红色孩子的黑节点被删除, 而导致的此类复杂情况, 称作“双黑”(double black)现象。此时, 需从 r 出发调用 $solveDoubleBlack(r)$ 算法予以修正。

自然, 原黑节点 x 的兄弟必然非空, 将其记作 s ; x 的父亲记作 p , 其颜色不确定(故在图中以八角形示意)。以下视 s 和 p 颜色的不同组合, 按四种情况分别处置。

■ 双黑修正 (BB-1)

既然节点x的另一孩子w = NULL，故从B-树角度（图8.29(a'））看节点x被删除之后的情况，可以等效地理解为：关键码x原所属的节点发生下溢；此时，t和s必然属于B-树的同一节点，且该节点就是下溢节点的兄弟。故可参照B-树的调整方法，下溢节点从父节点借出一个关键码（p），然后父节点从向下溢节点的兄弟节点借出一个关键码（s），调整后的效果如图(b'）。

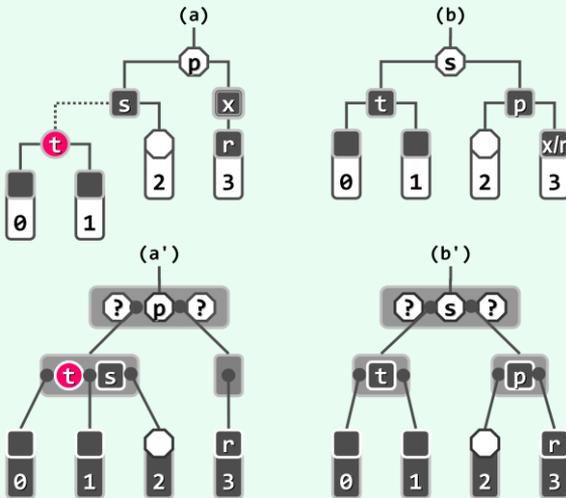


图8.29 双黑修正 (情况BB-1)
(带问号的关键码可能存在, 且颜色不定)

从红黑树的角度（图(b)）来看，上述调整过程等效于，对节点t、s和p实施“3 + 4”重构。

此外，根据红黑树与B-树的对应关系不难理解，若这三个节点按中序遍历次序重命名为a、b和c，则还需将a和c染成黑色，b则继承p此前的颜色。就图8.29的具体实例而言，也就是将t和p染成黑色，s继承p此前的颜色。注意，整个过程中节点r保持黑色不变。

由图8.29(b)（及其对称情况）不难验证，经以上处理之后，红黑树的所有条件，都在这一局部以及全局得到恢复，故删除操作遂告完成。

■ 双黑修正 (BB-2-R)

节点s及其两个孩子均为黑色时，视节点p颜色的不同，又可进一步分为两种情况。

先考虑p为红色的情况。如图8.30(a)所示，即为一种典型的此类情况（与之对称的情况，请读者独立补充）。

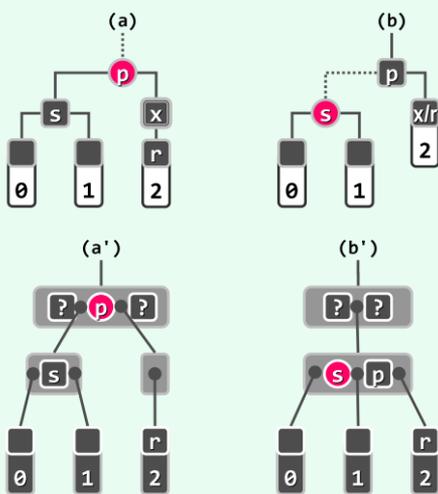


图8.30 双黑修正 (情况BB-2-R)
(带问号的黑关键码可能但不会同时存在)

与BB-1类似，在对应的B-树中，关键码x的删除导致其所属的节点下溢。但因此时关键码s所在节点只有两个分支，故下溢节点无法从父节点借出关键码（p）。

按照8.2.8节的B-树平衡算法，此时应如图(b')所示，将关键码p取出并下降一层，然后以之为“粘合剂”，将原左、右孩子合并为一个节点。从红黑树角度看，这一过程可如图(b)所示等效地理解为：s和p颜色互换。

由图8.30(b)（及其对称情况）可知，经过以上处理，红黑树的所有条件都在此局部得以恢复。另外，由于关键码p原为红色，故如图8.30(a')所示，在关键码p所属节点中，其左或右必然还有一个黑色关键码（当然，不可能左、右兼有）——这意味着，在关键码p从其中取出之后，不致引发新的下溢。至此，红黑树条件亦必在全局得以恢复，删除操作即告完成。

■ 双黑修正 (BB-2-B)

接下来，再考虑节点s、s的两个孩子以及节点p均为黑色的情况。

如图8.31(a)所示，即为一种典型的此类情况（与之对称的情况，请读者独立补充）。此时与BB-2-R类似，在对应的B-树中，因关键码x的删除，导致其所属节点发生下溢。

因此可如图(b')所示，将下溢节点与其兄弟合并。从红黑树的角度来看，这一过程可如图(b)所示等效地理解为：节点s由黑转红。

由图8.31(b)（及其对称情况）可知，经以上处理，红黑树所有条件都在此局部得到恢复。

然而，因s和x在此之前均为黑色，故如图8.31(a')所示，p原所属的B-树节点必然仅含p这一个关键码。于是在p被借出之后，该节点必将继而发生下溢，故有待于后续进一步修正。

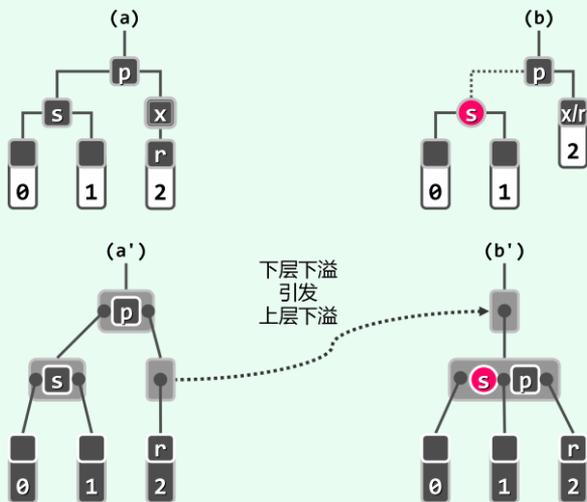


图8.31 双黑修正 (情况BB-2-B)

从红黑树的角度来看，此时的状态可等效地理解为：节点p的父节点刚被删除。当然，可以按照本节所介绍的算法，视具体的情况继续调整。

实际上稍后总结时将会看出，这也是双黑修正过程中，需要再次迭代的唯一可能。幸运的是，尽管此类情况可能持续发生，下溢的位置也必然不断上升，故至多迭代 $O(\log n)$ 次后必然终止。

■ 双黑修正 (BB-3)

最后，考虑节点s为红色的情况。如图8.32(a)所示，即为一种典型的此类情况（与之对称的情况，请读者独立补充）。此时，作为红节点s的父亲，节点p必为黑色；同时，s的两个孩子也应均为黑色。

于是从B-树的角度来看，只需如图(b')所示，令关键码s与p互换颜色，即可得到一棵与之完全等价的B-树。而从红黑树的角度来看，这一转换对应于以节点p为轴做一次旋转，并交换节点s与p的颜色。

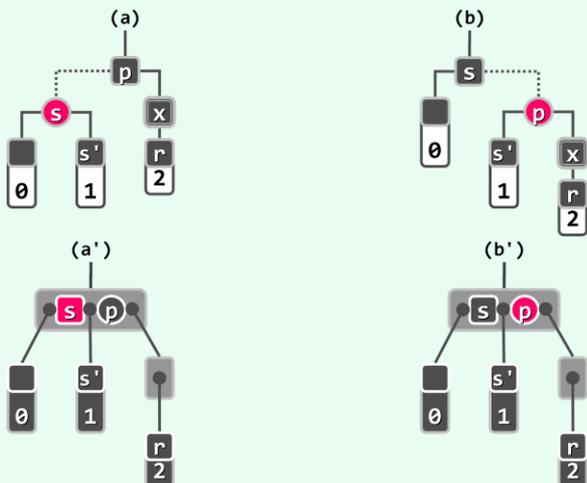


图8.32 双黑修正 (情况BB-3)

读者可能会发现，经过如此处理之后，双黑缺陷依然存在，而且缺陷位置的高度也并未上升。既然如此，这一步调整的意义又何在呢？

实际上，经过这一转换之后，情况已经发生了微妙而本质的变化。仔细观察图(b)不难发现，在转换之后的红黑树中，被删除节点x（及其替代者节点r）有了一个新的兄弟s'——与此前的兄弟s不同，s'必然是黑的！这就意味着，接下来可以套用此前所介绍其它情况的处置方法，继续并最终完成双黑修正。

还有一处本质的变化，同样需要注意：现在的节点p，也已经黑色转为红色。因此接下来即便需要继续调整，必然既不可能转换回此前的情况BB-3，也不可能转入可能需要反复迭代的情况BB-2-B。实际上反过来，此后只可能转入更早讨论过的两类情况——BB-1或BB-2-R。这就意味着，接下来至多再做一步迭代调整，整个双黑修正的任务即可大功告成。

■ 双黑修正的复杂度

以上各种情况的处理流程，可以归纳为图8.33。

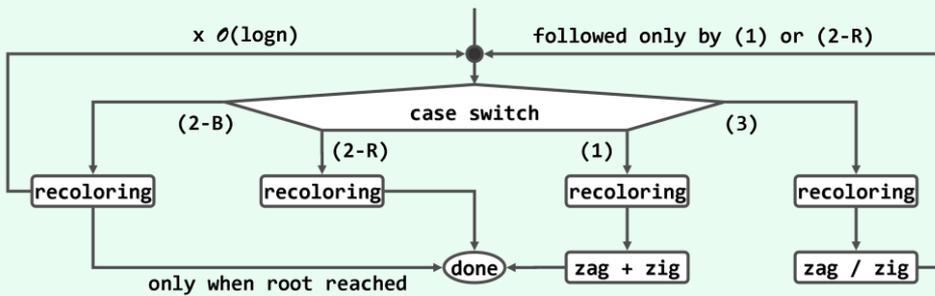


图8.33 双黑修正流程图

其中涉及的重构、染色等局部操作，均可在常数时间内完成，故为了估计整个双黑修正过程的时间复杂度，也只需统计这些操作各自的累计执行次数。具体统计可归纳为表8.2。

表8.2 双黑修正算法所涉及局部操作的统计

情况	#旋转	#染色	单轮修正之后	
BB-1	黑s有红子t	1~2	3	调整随即完成
BB-2-R	黑s无红子，p红	0	2	调整随即完成
BB-2-B	黑s无红子，p黑	0	1	必然再次双黑，但将上升一层
BB-3	红s	1	2	转为(BB-1)或(BB-2-R)

可见，前两种情况各自只需做一轮修正，最后一种情况亦不过两轮。

情况BB-2-B虽可能需要反复修正，但由于待修正位置的高度严格单调上升，累计也不致过 $O(\log n)$ 轮，故双黑修正过程总共耗时不超过 $O(\log n)$ 。即便计入此前的关键码查找和节点摘除操作，红黑树的节点删除操作总是可在 $O(\log n)$ 时间内完成。

纵览各种情况，不难确认：一旦在某步迭代中做过节点的旋转调整，整个修复过程便会随即完成。因此与双红修正一样，双黑修正的整个过程，也仅涉及常数次的拓扑结构调整操作。

这一有趣的特性同时也意味着，在每此插入操作之后，拓扑联接关系有所变化的节点绝不会超过常数个——这一点与AVL树（的删除操作）完全不同，也是二者之间最本质的一项差异。

■ 双黑修正算法的实现

以上针对双黑缺陷的各种修正方法，可以概括并实现如代码8.19所示。

```

1  /*****
2  * RedBlack双黑调整算法：解决节点x与被其替代的节点均为黑色的问题
3  * 分为三大类共四种情况：
4  *   BB-1  : 2次颜色翻转，2次黑高度更新，1~2次旋转，不再递归
5  *   BB-2R: 2次颜色翻转，2次黑高度更新，0次旋转，不再递归
6  *   BB-2B: 1次颜色翻转，1次黑高度更新，0次旋转，需要递归
7  *   BB-3  : 2次颜色翻转，2次黑高度更新，1次旋转，转为BB-1或BB2R
8  *****/
9  template <typename T> void RedBlack<T>::solveDoubleBlack(BinNodePosi(T) r) {
10     BinNodePosi(T) p = r ? r->parent : _hot; if (!p) return; //r的父亲
11     BinNodePosi(T) s = (r == p->lChild) ? p->rChild : p->lChild; //r的兄弟
12     if (IsBlack(s)) { //兄弟s为黑
13         BinNodePosi(T) t = NULL; //s的红孩子(若左、右孩子皆红，左者优先；皆黑时为NULL)
14         if (HasLChild(*s) && IsRed(s->lChild)) t = s->lChild;
15         else if (HasRChild(*s) && IsRed(s->rChild)) t = s->rChild;
16         if (t) { //黑s有红孩子：BB-1
17             RBColor oldColor = p->color; //备份原子树根节点p颜色，并对t及其父亲、祖父
18             BinNodePosi(T) b = FromParentTo(*p) = rotateAt(t); //重平衡，并将新子树的左、右孩子染黑
19             if (HasLChild(*b)) b->lChild->color = RB_BLACK; updateHeight(b->lChild); //左孩子
20             if (HasRChild(*b)) b->rChild->color = RB_BLACK; updateHeight(b->rChild); //右孩子
21             b->color = oldColor; updateHeight(b); //新子树根节点继承原根节点的颜色
22         } else { //黑s无红孩子
23             s->color = RB_RED; s->height--; //s转红
24             if (IsRed(p)) { //BB-2R
25                 p->color = RB_BLACK; //p转黑，但黑高度不变
26             } else { //BB-2B
27                 p->height--; //p保持黑，但黑高度下降
28                 solveDoubleBlack(p);
29             }
30         }
31     } else { //兄弟s为红：BB-3
32         s->color = RB_BLACK; p->color = RB_RED; //s转黑，p转红
33         BinNodePosi(T) t = IsLChild(*s) ? s->lChild : s->rChild; //取t与其父s同侧
34         _hot = p; FromParentTo(*p) = rotateAt(t); //对t及其父亲、祖父做平衡调整
35         solveDoubleBlack(r); //继续修正r处双黑——此时的p已转红，故后续只能是BB-1或BB-2R
36     }
37 }

```

代码8.19 双黑修正solveDoubleBlack()

§ 8.4 *kd-树

8.4.1 范围查询

■ 一维范围查询

如图8.34所示，许多实际应用问题，都可归结为如下形式的查询：给定直线 L 上的点集 $P = \{ p_0, \dots, p_{n-1} \}$ ，对于任一区间 $R = [x_1, x_2]$ ， P 中的哪些点落在其中？



图8.34 一维范围查询

比如，在校友数据库中查询1970至2000级的学生，或者查询IP介于166.111.68.1至166.111.68.255之间的在线节点等，此类问题统称为一维范围查询（range query）。

■ 蛮力算法

表面看来，一维范围查询问题并不难解决。比如，只需遍历点集 P ，并逐个地花费 $\mathcal{O}(1)$ 时间判断各点是否落在区间 R 内——如此总体运行时间为 $\Theta(n)$ 。这一效率甚至看起来似乎还不差——毕竟在最坏情况下，的确可能有多达 $\Omega(n)$ 个点命中，而直接打印报告也至少需要 $\Omega(n)$ 时间。

然而，当我们试图套用以上策略来处理更大规模的输入点集时，就会发现这种方法显得力不从心。实际上，蛮力算法的效率还有很大的提升空间，这一点可从以下角度看出。

首先，当输入点集的规模大到需要借助外部存储器时，遍历整个点集必然引发大量I/O操作。正如8.2.1节所指出的，此类操作往往是制约算法实际效率提升的最大瓶颈，应尽量予以避免。

另外，当数据点的坐标分布范围较大时，通常的查询所命中的点，在整个输入点集中仅占较低甚至极低的比例。此时，“查询结果的输出需要 $\Omega(n)$ 时间”的借口，已难以令人信服。

■ 预处理

在典型的范围查询应用中，输入点集数据与查询区域的特点迥异。一方面，输入点集 P 通常会在相当长的时间内保持相对固定——数据的这种给出及处理方式，称作批处理（batch）或离线（offline）方式。同时，对于同一输入点集，往往需要针对大量的随机定义区间 R ，反复地进行查询——数据的这种给出及处理方式，称作在线（online）方式。

因此，只要通过适当的预处理，将输入点集 P 提前整理和组织为某种适当的数据结构，就有可能进一步提高此后各次查询操作的效率。

■ 有序向量

最为简便易行的预处理方法，就是在 $\mathcal{O}(n \log n)$ 时间内，将点集 P 组织为一个有序向量。

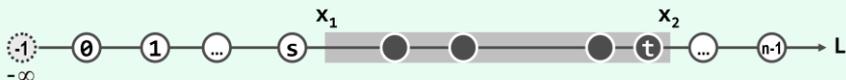


图8.35 通过预先排序，高效地解决一维范围查询问题（ p_{-1} 为假想着引入的哨兵，数值等于 $-\infty$ ）

如图8.35所示，此后对于任何 $R = [x_1, x_2]$ ，首先利用有序向量的查找算法（代码2.20），在 $\mathcal{O}(\log n)$ 时间内找到不大于 x_2 的最大点 p_t 。然后从 p_t 出发，自右向左地遍历向量中的各点，直至第一个离开查询区间的点 p_s 。其间经过的所有点，既然均属于区间范围，故可直接输出。

如此，在每一次查询中， p_t 的定位需要 $\mathcal{O}(\log n)$ 时间。若接下来的遍历总共报告出 r 个点，则总体的查询时间成本为 $\mathcal{O}(r + \log n)$ 。

请注意，此处估计时间复杂度的方法，不免有点特别。这里，需要同时根据问题的输入规模和输出规模进行估计。一般地，时间复杂度可以这种形式给出的算法，也称作输出敏感的(output sensitive)算法。从以上实例可以看出，与此前较为粗略的最坏情况估计法相比，这种估计方法可以更加准确和客观地反映算法的实际效率。

■ 二维范围查询

接下来的难点和挑战在于，在实际应用中，往往还需要同时对多个维度做范围查找。以人事数据库为例，诸如“年龄介于某个区间，而且工资介于某个区间”之类的组合查询十分普遍。

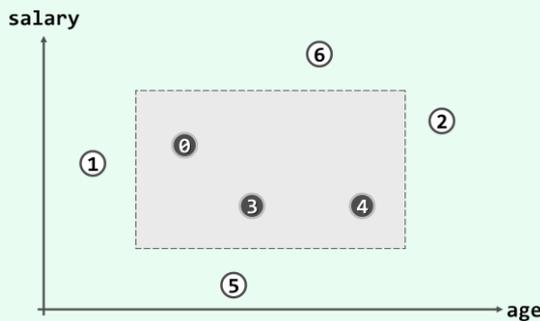


图8.36 平面范围查询 (planar range query)

如图8.36所示，若将年龄与工资分别表示为两个正交维度，则人事数据库中的记录，将对应于二维平面上（第一象限内）的点。于是相应地，这类查询都可以抽象为在二维平面上，针对某一相对固定的点集的范围查询，其查询范围可描述为矩形 $R = [x_1, x_2] \times [y_1, y_2]$ 。

很遗憾，上述基于二分查找的方法并不能直接推广至二维情况，更不用说更高维的情况了，因此必须另辟蹊径，尝试其它策略。

■ 平衡二叉搜索树

我们还是回到该问题的一维版本，并尝试其它可以推广至二维甚至更高维版本的方法。比如，不妨在 $\mathcal{O}(n \log n)$ 时间内，将输出点集组织并转化为如图8.37所示的一棵平衡二叉搜索树。

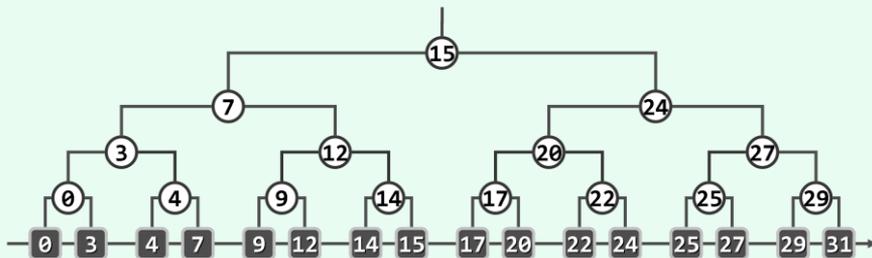


图8.37 平衡二叉搜索树：叶节点存放输入点，内部节点等于左子树中的最大者

请注意，其中各节点的关键码可能重复。不过，如此并不致于增加渐进的空间和时间复杂度：每个关键码至多重复一次，总体依然只需 $\mathcal{O}(n)$ 空间；尽管相对于常规二叉搜索树仅多出一层，但树高依然是 $\mathcal{O}(\log n)$ 。

如此在空间上所做的些许牺牲，可以换来足够大的收益：查找的过程中，在每一节点处，至多只需做一次（而不是两次）关键码的比较。当然另一方面，无论成功与否，每次查找因此都必然终止于叶节点——不小于目标关键码的最小叶节点。

不难验证，就接口和功能而言，此类形式二叉搜索树，完全对应于和等价于2.6.8节所介绍二分查找算法的版本C（代码2.24）。

■ 查询算法

借助上述形式的平衡二叉搜索树，如何高效地解决一维范围查询问题呢？

仍然继续上例，如图8.38所示，设查询区间为 $[1, 23]$ 。

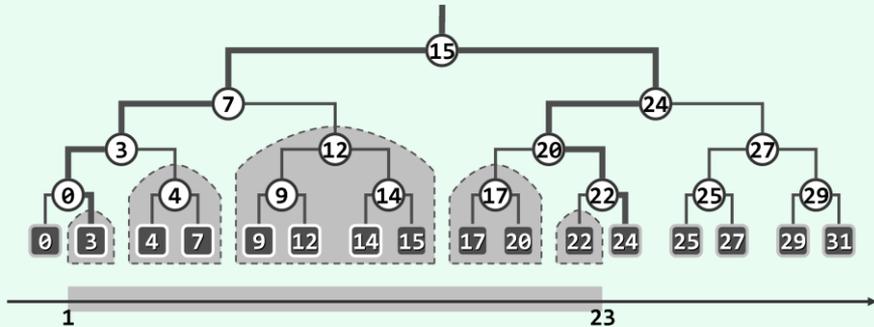


图8.38 借助平衡二叉搜索树解决一维范围查询问题（针对区间端点的两条查找路径加粗示意）

首先，在树中分别查找这一区间的左、右端点1和23，并分别终止于叶节点3和24。

接下来，考查这两个叶节点共同祖先中的最低者，即所谓的最低共同祖先（lowest common ancestor, LCA），具体地亦即

$$\text{lca}(3, 24) = 15$$

然后，从这一共同祖先节点出发，分别重走一遍通往节点3和24的路径（分别记作 $\text{path}(3)$ 和 $\text{path}(24)$ ）。在沿着 $\text{path}(3)/\text{path}(24)$ 下行的过程中，忽略所有的右转/左转；而对于每一次左转/右转，都需要遍历对应的右子树/左子树（图中以阴影示意），并将其中的叶节点悉数报告出来。

就本例而言，沿 $\text{path}(3)$ 被报告出来的叶节点子集，依次为：

$$\{ 9, 12, 14, 15 \}、\{ 4, 7 \}、\{ 3 \}$$

沿 $\text{path}(24)$ 被报告出来的叶节点子集，依次为：

$$\{ 17, 20 \}、\{ 22 \}$$

■ 正确性

不难看出，如此分批报告出来的各组节点，都属于查询输出结果的一部分，且它们相互没有重叠。另一方面，除了右侧路径的终点24需要单独地判断一次，其余的各点都必然落在查询范围以外。因此，该算法所报告的所有点，恰好就是所需的查询结果。

■ 效率

在每一次查询过程中，针对左、右端点的两次查找及其路径的重走，各自不过 $O(\log n)$ 时间（实际上，这些操作还可进一步合并精简）。

在树中的每一层次上，两条路径各自至多报告一棵子树，故累计不过 $O(\log n)$ 棵。幸运的是，根据习题[5-11]的结论，为枚举出这些子树中的点，对它们的遍历累计不超过 $O(r)$ 的时间，其中 r 为实际报告的点数。

综合以上分析，每次查询都可在 $O(r + \log n)$ 时间内完成。该查询算法的运行时间也与输出规模相关，故同样属于输出敏感的算法。

新算法的效率尽管并不高于基于有序向量的算法，却可以便捷地推广至二维甚至更高维。

8.4.2 kd-树

循着上一节采用平衡二叉搜索树实现一维查询的构思,可以将待查询的二维点集组织为所谓的kd-树(kd-tree)[®]结构。在任何的维度下,kd-树都是一棵递归定义的平衡二叉搜索树。

以下不妨以二维情况为例,就2d-树的原理以及构造和查询算法做一介绍。

■ 节点及其矩形区域

具体地,2d-树中的每个节点,都对应于二维平面上的某一矩形区域,且其边界都与坐标轴平行。当然,有些矩形的面积可能无限。

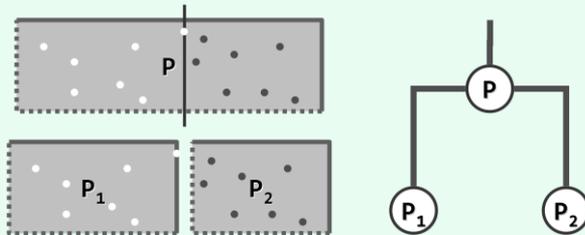


图8.39 2d-树中各节点对应的区域,逐层递归地按所包含的输入点数均衡切分

后面将会看到,同层节点各自对应的矩形区域,经合并之后恰好能够覆盖整个平面,同时其间又不得有任何交叠。因此,不妨如图8.39所示统一约定,每个矩形区域的左边和底边开放,右边和顶边封闭。

■ 构造算法

作为以上条件的特例,树根自然对应于整个平面。一般地如图8.39所示,若P为输入点集与树中当前节点所对应矩形区域的交集(即落在其中的所有点),则可递归地将该矩形区域切分为两个子矩形区域,且各包含P中的一半点。

若当前节点深度为偶(奇)数,则沿垂直(水平)方向切分,所得子区域随同包含的输入点分别构成左、右孩子。如此不断,直至子区域仅含单个输入点。每次切分都在中位点(median point)——按对应的坐标排序居中者——处进行,以保证全树高度不超过 $O(\log n)$ 。

具体地,2d-树的整个构造过程,可形式化地递归描述如算法8.1所示。

```

1 KdTree* buildKdTree(P, d) { //在深度为d的层次,构造一棵对应于(子)集合P的(子)2d-树
2   if (P == {p}) return CreateLeaf(p); //递归基
3   root = CreateKdNode(); //创建(子)树根
4   root->splitDirection = Even(d) ? VERTICAL : HORIZONTAL; //确定划分方向
5   root->splitLine = FindMedian(root->splitDirection, P); //确定中位点
6   (P1, P2) = Divide(P, root->splitDirection, root->splitLine); //子集划分
7   root->lChild = buildKdTree(P1, d + 1); //在深度为d + 1的层次,递归构造左子树
8   root->rChild = buildKdTree(P2, d + 1); //在深度为d + 1的层次,递归构造右子树
9   return root; //返回(子)树根
10 }
```

算法8.1 构造2d-树

[®] 由J. L. Bentley于1975年发明^[46],其名字来源于“k-dimensional tree”的缩写适用于任意指定维度的欧氏空间,并视具体的维度,相应地分别称作2d-树、3d-树、...,等故上节所介绍的一维平衡二叉搜索树,也可称作1d-树

■ 实例

以图8.40(a)为例，首先创建树根节点，并指派以整个平面以及全部7个输入点。

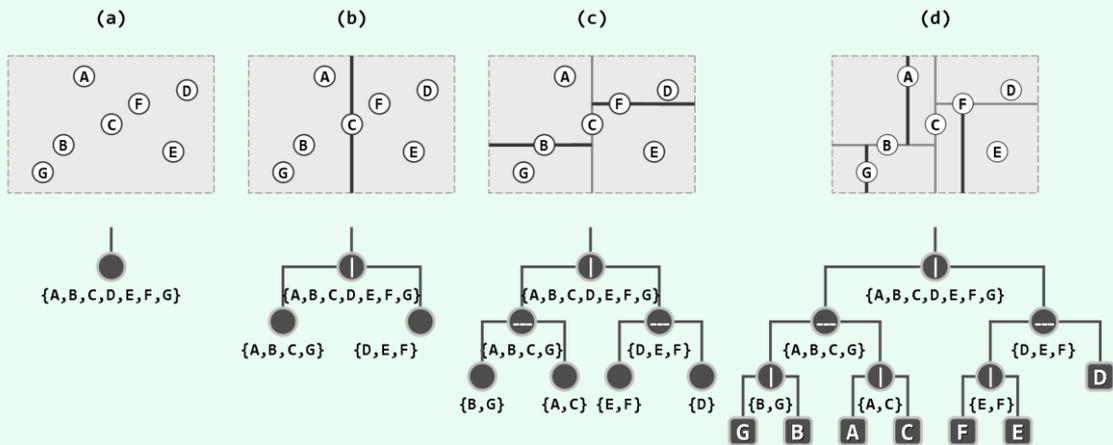


图8.40 2d-树的构造过程，就是对平面递归划分的过程

第一轮切分如图(b)所示。以水平方向的中位点C为界，将整个平面分作左、右两半，点集P也相应地被划分为子集{ A, B, C, G }和{ D, E, F }，它们随同对应的半平面，被分别指派给深度为1的两个节点。

第二轮切分如图(c)所示。对于左半平面及其对应的子集{ A, B, C, G }，以垂直方向的中位点B为界，将其分为上、下两半，并分别随同子集{ B, G }和{ A, C }，指派给深度为2的一对节点；对于右半平面及其对应的子集{ D, E, F }，以垂直方向的中位点F为界，将其分为上、下两半，并分别随同子集{ E, F }和{ D }，指派给深度为2的另一对节点。

最后一轮切分如图(d)所示。对树中仍含有至少两个输入点的三个深度为2的节点，分别沿其各自水平方向的中位点，将它们分为左、右两半，并随同对应的子集分配给三对深度为3的节点。至此，所有叶节点均只包含单个输入点，对平面的整个划分过程遂告完成，同时与原输入点集P对应的一棵2d-树也构造完毕。

8.4.3 基于2d-树的范围查询

■ 过程

经过如上预处理，将待查询点集P转化为一棵2d-树之后，对于任一矩形查询区域R，范围查询的过程均从树根节点出发，按如下方式递归进行。因为不致歧义，以下叙述将不再严格区分2d-树节点及其对应的矩形子区域和输入点子集。

在任一节点v处，若子树v仅含单个节点，则意味着矩形区域v中仅覆盖单个输入点，此时可直接判断该点是否落在R内。否则，不妨假定矩形区域v中包含多个输入点。

此时，视矩形区域v与查询区域R的相对位置，无非三种情况。情况A：若矩形区域v完全包含于R内，则其中所有的输入点亦均落在R内，于是只需遍历一趟子树v，即可报告这部分输入点。情况B：若二者相交，则有必要分别深入到v的左、右子树中，继续递归地查询。情况C：若二者彼此分离，则子集v中的输入点绝不可能落在R内，故对应的递归分支至此即可终止。

■ 算法

以上查询过程，可递归地描述如算法8.2所示。

```

1 kdSearch(v, R) { //在以v为根节点的(子)2d-树中，针对矩形区域R做范围查询
2   if (isLeaf(v) //若抵达叶节点，则
3     { if (inside(v, R)) report(v); return; } //直接判断，并终止递归
4
5   if (region(v->lChild) ⊆ R) //情况A：若左子树完全包含于R内，则直接遍历
6     reportSubtree(v->lChild);
7   else if (region(v->lChild) ∩ R ≠ ∅) //情况B：若左子树对应的矩形与R相交，则递归查询
8     kdSearch(v->lChild, R);
9
10  if (region(v->rChild) ⊆ R) //情况A：若右子树完全包含于R内，则直接遍历
11    reportSubtree(v->rChild);
12  else if (region(v->rChild) ∩ R ≠ ∅) //情况B：若右子树对应的矩形与R相交，则递归查询
13    kdSearch(v->rChild, R);
14 }
    
```

算法8.2 基于2d-树的平面范围查询

可见，递归只发生于情况B；对于其余两种情况，递归都会随即终止。特别地，情况C只需直接返回，故在算法中并无与之对应的显式语句。

■ 实例

考查图 8.41 中的 2d- 树，设采用 kdSearch() 算法，对阴影区域进行查询。

不难验证，递归调用仅发生于黑色节点（情况B）；而在灰色节点处，并未发生递归调用（情况C或父节点属情况A）。

命中的节点共分两组：{ C } 作为叶节点经直接判断后确定；{ F, H } 则因其所对应区域完全包含于查询区域内部（情况A），经遍历悉数输出（习题[8-17]）。

■ 正确性

由上可见，凡被忽略的子树，其对应的矩形区域均完全落在查询区域之外，故该算法不致漏报。反之，凡被报告的子树，其对应的矩形区域均完全包含在查询区域以内（且互不相交），故亦不致误报。

■ 复杂度

平面范围查询与一维情况不同，在同一深度上可能递归两次以上，并报告出多于两棵子树。但更精细的分析（习题[8-16]）表明，被报告的子树总共不超过 $O(\sqrt{n})$ 棵，累计耗时 $O(\sqrt{n})$ 。

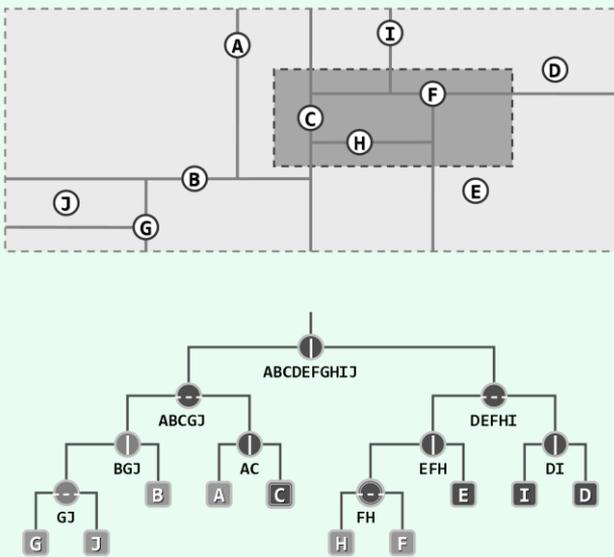


图8.41 基于2d-树的平面范围查询

(A~J共计10个输入点；命中子树的根节点，以双线圆圈示意)

第9章

词典

第10章

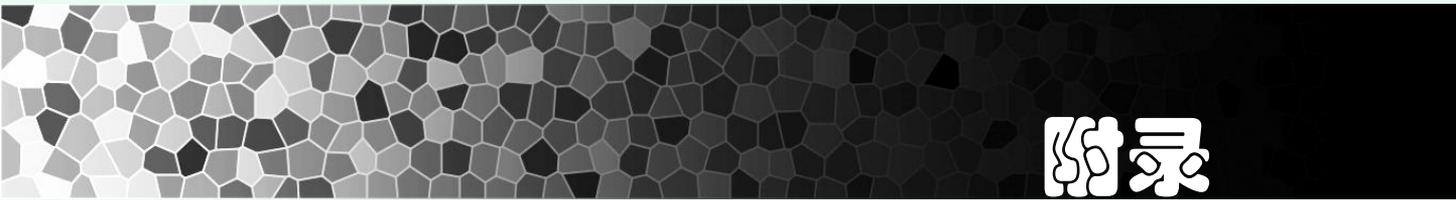
优先级队列

第11章

串

第12章

排序



附录

参考文献

- [1] D. E. Knuth. The Art of Computer Programming, Volume 1: Fundamental Algorithms (3rd edn.). Addison-Wesley (1997), ISBN:0-201-89683-1
- [2] D. E. Knuth. The Art of Computer Programming, Volume 2: Seminumerical Algorithms (3rd edn.). Addison-Wesley (1997), ISBN:0-201-89684-8
- [3] D. E. Knuth. The Art of Computer Programming, Volume 3: Sorting and Searching (2nd edn.). Addison-Wesley (1998), ISBN:0-201-89685-0
- [4] A. V. Aho, J. E. Hopcroft, J. D. Ullman. The Design and Analysis of Computer Algorithms (1st edn.). Addison-Wesley (1974), ISBN:0-201-00029-0
- [5] J. Bentley. Writing Efficient Programs. Prentice-Hall (1982), ISBN:0-139-70251-2
- [6] J. Bentley. More Programming Pearls: Confessions of a Coder. Addison Wesley (1988), ISBN:0-201-11889-0
- [7] R. L. Graham, D. E. Knuth, O. Patashnik. Concrete Mathematics: A Foundation for Computer Science (2nd edn.). Addison-Wesley (1994), ISBN:0-201-55802-5
- [8] 严蔚敏 等. 数据结构 (C语言版). 北京: 清华大学出版社, 1997年4月第1版, ISBN:7-302-02368-9
- [9] J. Bentley. Programming Pearls (2nd edn.). Addison-Wesley (2000), ISBN:0-201-65788-0
- [10] T. Budd. Classic Data Structures in Java. Addison-Wesley (2000), ISBN:0-201-70002-6
- [11] J. Hromkovic. Design And Analysis Of Randomized Algorithms: Introduction to Design Paradigms. Springer-Verlag (2005), ISBN:3-540-23949-9
- [12] H. Samet. Foundations of Multidimensional and Metric Data Structures. Morgan Kaufmann (2006), ISBN:0-123-69446-9
- [13] M. A. Weiss. Data Structures and Algorithm Analysis in C++ (3rd edn.). Addison Wesley (2006), ISBN:0-321-44146-1
- [14] E. Horowitz, S. Sahni, D. Mehta. Fundamentals of Data Structures in C++ (2nd edn.). Silicon Press (2006), ISBN:0-929-30637-6
- [15] A. Drozdek. Data Structures and Algorithms in C++ (2nd edn.). Thomson Press (2006), ISBN:8-131-50115-9
- [16] 殷人昆 等. 数据结构 (C++语言描述). 北京: 清华大学出版社, 2007年6月第2版, ISBN:7-302-14811-1
- [17] P. Brass. Advanced Data Structures. Cambridge University Press, ISBN:0-521-88037-8
- [18] J. Edmonds. How to Think about Algorithms. Cambridge University Press (2008), ISBN:0-521-61410-8
- [19] K. Mehlhorn & P. Sanders. Algorithms and Data Structures: The Basic Tools. Springer (2008), ISBN:3-540-77977-9
- [20] T. H. Cormen, C. E. Leiserson, R. L. Rivest, C. Stein. Introduction to Algorithms (3rd edn.). MIT Press (2009), ISBN:0-262-03384-4

- [21] R. Bird. *Pearls of Functional Algorithm Design*. Cambridge University Press (2010), ISBN:0-521-51338-8
- [22] M. L. Hetland. *Python Algorithms: Mastering Basic Algorithms in the Python Language*. Apress (2010), ISBN:1-430-23237-4
- [23] M. T. Goodrich, R. Tamassia, D. M. Mount. *Data Structures and Algorithms in C++ (2nd edn.)*. John Wiley & Sons (2011), ISBN:0-470-38327-5
- [24] R. Sedgewick & K. Wayne. *Algorithms (4th edn.)*. Addison-Wesley (2011), ISBN:0-321-57351-X
- [25] Y. Perl, A. Itai and H. Avni, Interpolation Search: A $\log(\log(n))$ Search, *Commun. ACM*, 21 (1978), pp. 550-553
- [26] A. C. Yao & F. F. Yao. The Complexity of Searching an Ordered Random Table. 17th Annual Symposium on Foundations of Computer Science (1976), 173-177
- [27] A. C. Yao & J. M. Steele. Lower Bounds to Algebraic Decision Trees. *Journal of Algorithms* (1982), 3:1-8
- [28] A. C. Yao. Lower Bounds for Algebraic Computation Trees with Integer Inputs. *SIAM J. On Computing* (1991), 20:655-668
- [29] L. Devroye. A Note on the Height of Binary Search Trees. *J. of ACM* (1986), 33(3):489-498
- [30] P. Flajolet & A. Odlyzko. The Average Height of Binary Trees and Other Simple Trees. *Journal of Computer and System Sciences* (1982), 25(2):171-213
- [31] J. B. Kruskal. On the Shortest Spanning Subtree of a Graph and the Traveling Salesman Problem. *Proc. of the American Mathematical Society*, 7(1):48-50
- [32] B. W. Arden, B. A. Galler, R. M. Graham. An Algorithm for Equivalence Declarations. *Communications ACM* (1961), 4:310-314
- [33] B. A. Galler, M. J. Fisher. An Improved Equivalence Algorithm. *Communications ACM* (1964), 7:301-303
- [34] R. E. Tarjan. Efficiency of a Good but not Linear Set Union Algorithm. *Journal of the ACM* (1975), 22:215-225
- [35] R. Seidel & M. Sharir. Top-Down Analysis of Path Compression. *SIAM Journal Computing* (2005), 34:515-525
- [36] G. Adelson-Velskii & E. M. Landis. An Algorithm for the Organization of Information. *Proc. of the USSR Academy of Sciences* (1962), 146:263-266
- [37] D. S. Hirschberg. An Insertion Technique for One-Sided Heightbalanced Trees. *Comm. ACM* (1976), 19(8):471-473
- [38] S. H. Zweben & M. A. McDonald. An Optimal Method for Deletion in One-Sided Height-Balanced Trees. *Commun. ACM* (1978), 21(6):441-445
- [39] K. Culik, T. Ottman, D. Wood. Dense Multiway Trees. *ACM Transactions on Database Systems* (1981), 6:486-512
- [40] E. Gudes & S. Tsur. Experiments with B-tree Reorganization. *SIGMOD* (1980), 200-206
- [41] D. D. Sleator & R. E. Tarjan. Self-Adjusting Binary Trees. *JACM* (1985), 32:652-686

- [42] R. E. Tarjan. Amortized Computational Complexity. *SIAM. J. on Algebraic and Discrete Methods* 6(2):306-318
- [43] R. Bayer & E. McCreight. Organization and Maintenance of Large Ordered Indexes. *Acta Informatica* (1972), 1(3):173-189
- [44] R. Bayer. Symmetric Binary B-Trees: Data Structure and Maintenance Algorithms. *Acta Informatica* (1972), 1(4):290-306
- [45] L. J. Guibas & R. Sedgwick. A Dichromatic Framework for Balanced Trees. *Proc. of the 19th Annual Symposium on Foundations of Computer Science* (1978), 8-21
- [46] J. L. Bentley. Multidimensional Binary Search Trees Used for Associative Searching. *Communications of the ACM* (1975), 18(9):509-517
- [47] H. J. Olivie. A New Class of Balanced Search Trees: Half Balanced Binary Search Trees. *ITA* (1982), 16(1):51-71
- [48] J. L. Bentley. Decomposable Searching Problems. *Information Processing Letters* (1979), 8:244-251
- [49] J. H. Hart. Optimal Two-Dimensional Range Queries Using Binary Range Lists. Technical Report 76-81, Department of Computer Science, University of Kentucky (1981)
- [50] D. E. Willard. New Data Structures for Orthogonal Range Queries. *SIAM Journal on Computing* (1985), 14:232-253
- [51] H. Samet, An Overview of Quadrees, Octrees, and Related Hierarchical Data Structures, in R. Earnshaw, ed., *Theoretical Foundations of Computer Graphics and Cad*, Springer Berlin Heidelberg, 1988, pp. 51-68
- [52] W. Pugh. Skip Lists: a Probabilistic Alternative to Balanced Trees. *Lecture Notes in Computer Science* (1989), 382:437-449
- [53] R. de la Briandais. File Searching Using Variable Length Keys. *Proc. of the Western Joint Computer Conference 1959*, 295-298
- [54] E. H. Sussenguth. Use of Tree Structures for Processing Files. *Communications of the ACM* (1963), 6:272-279
- [55] D. R. Morrison. PATRICIA - Practical Algorithm to Retrieve Information Coded in Alphanumeric. *Journal of the ACM* (1968), 15:514-534
- [56] J. L. Bentley & R. Sedgwick. Fast Algorithms for Sorting and Searching Strings. *Proc. of 8th ACM-SIAM Symposium on Discrete Algorithms* (1997), 360-369
- [57] R. W. Floyd. Algorithm 113: Treesort. *Communications of the ACM* (1962), 5:434
- [58] C. A. Crane. Linear Lists and Priority Queues as Balanced Binary Trees. PhD thesis, Stanford University (1972)
- [59] E. M. McCreight. Priority Search Trees. *SIAM J. Comput.* (1985), 14(2):257-276
- [60] D. E. Knuth, J. H. Morris, V. R. Pratt. Fast Pattern Matching in Strings. *SIAM Journal of Computing* (1977), 6(2):323-350

-
- [61] R. S. Boyer & J. S. Moore. A Fast String Searching Algorithm. *Communications of the ACM* (1977), 20:762-772
 - [62] L. J. Guibas & A. M. Odlyzko. A New Proof of the Linearity of the Boyer-Moore String Search Algorithm. *SIAM Journal on Computing* (1980), 9(4):672-682
 - [63] R. Cole. Tight Bounds on the Complexity of the Boyer-Moore Pattern Matching Algorithm. *SIAM Journal on Computing* 23(5):1075-1091
 - [64] C. A. R. Hoare. Quicksort. *Computer Journal* (1962), 5(1):10-15
 - [65] D. L. Shell. A High-Speed Sorting Procedure. *Communications of the ACM* (1959), 2(7):30-32
 - [66] R. Sedgewick, A New Upper Bound for Shellsort, *J. Algorithms*, 7 (1986), pp. 159-173

插图索引

图1.1 古埃及人使用的绳索计算机及其算法	2
图1.2 古希腊人的尺规计算机	3
图1.3 通过6趟扫描交换对七个整数排序（其中已就位的元素以深色示意）	4
图1.4 大 O 记号、大 Ω 记号和大 Θ 记号	11
图1.5 复杂度的典型层次：(1)~(7)依次为 $O(\log n)$ 、 $O(\sqrt{n})$ 、 $O(n)$ 、 $O(n \log n)$ 、 $O(n^2)$ 、 $O(n^3)$ 和 $O(2^n)$	15
图1.6 对 $\text{sum}(A, 5)$ 的递归跟踪分析	18
图1.7 对 $\text{sum}(A, 0, 7)$ 的递归跟踪分析	23
图2.1 可扩充向量的溢出处理	34
图2.2 向量整体置乱算法 $\text{permute}()$ 的迭代过程	37
图2.3 无序向量的顺序查找	39
图2.4 向量元素插入操作 $\text{insert}(r, e)$ 的过程	40
图2.5 向量区间删除操作 $\text{remove}(lo, hi)$ 的过程	41
图2.6 无序向量 $\text{deduplicate}()$ 算法原理	42
图2.7 低效版 $\text{uniquify}()$ 算法的最坏情况	45
图2.8 有序向量中的重复元素可批量删除	46
图2.9 在有序向量中查找互异的相邻元素	46
图2.10 基于减治策略的有序向量二分查找算法（版本A）	48
图2.11 二分查找算法（版本A）实例： $\text{search}(8, 0, 7)$ 成功， $\text{search}(3, 0, 7)$ 失败	49
图2.12 二分查找算法（版本A）的查找长度（成功、失败查找分别以实线、虚线白色方框示意）	50
图2.13 Fibonacci查找算法原理	52
图2.14 Fibonacci查找算法的查找长度（成功、失败查找分别以实线、虚线白色方框示意）	53
图2.15 基于减治策略的有序向量二分查找算法（版本B）	54
图2.16 基于减治策略的有序向量二分查找算法（版本C）	56
图2.17 从三只苹果中挑出重量不同者	58
图2.18 有序向量的二路归并实例（来自两个向量的元素分别以黑、白方框区分，其各自的当前首元素则以灰色长方形示意）	62
图2.19 归并排序实例： $S = \{ 6, 3, 2, 7, 1, 5, 8, 4 \}$	63
图3.1 首（末）节点是头（尾）节点的直接后继（前驱）	71
图3.2 刚创建的List对象	71
图3.3 $\text{ListNode}::\text{insertAsPred}()$ 算法	73
图3.4 $\text{List}::\text{remove}()$ 算法	75
图3.5 序列的插入排序	79
图3.6 序列的选择排序	80
图4.1 一摞椅子即是一个栈	87
图4.2 栈操作	87

图4.3 函数调用栈实例：主函数main()调用funcA(), funcA()调用funcB(), funcB()再自我调用	88
图4.4 进制转换算法流程	90
图4.5 栈混洗实例：从{ 1, 2, 3, 4 }到{ 3, 2, 4, 1 } (上方左侧为栈A, 右侧为栈B; 下方为栈S)	91
图4.6 迭代式括号匹配算法实例 (上方为输入表达式; 下方为辅助栈的演变过程; 虚框表示在(右)括号与栈顶(左)括号匹配时对应的出栈操作)	93
图4.7 通过剪枝排除候选解子集	99
图4.8 (a)皇后的控制范围; (b)8皇后问题的一个解	100
图4.9 四皇后问题求解过程 (棋盘右侧为记录解的栈solu)	101
图4.10 迷宫寻径算法实例	104
图4.11 在球桶中顺序排列的一组羽毛球可视为一个队列	105
图4.12 队列操作	105
图5.1 有根树的逻辑结构	111
图5.2 二叉树: (a)逻辑结构; (b)实例	111
图5.3 多叉树的“父节点”表示法	112
图5.4 多叉树的“孩子节点”表示法	112
图5.5 多叉树的“父节点 + 孩子节点”表示法	112
图5.6 多叉树的“长子 + 兄弟”表示法 ((b)中长子和兄弟指针, 分别以垂直实线和水平虚线示意)	113
图5.7 完整的通讯过程由预处理、编码和解码阶段组成	114
图5.8 二叉树中每个节点都由根通路串唯一确定	116
图5.9 $\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 两种编码方案对应的二叉编码树	116
图5.10 BinNode模板类的逻辑结构	118
图5.11 二叉树节点左孩子插入过程	119
图5.12 右节点插入过程: (a)插入前; (b)插入后	122
图5.13 右子树接入过程: (a)接入前; (b)接入后	123
图5.14 二叉树遍历的全局次序由局部次序规则确定	124
图5.15 二叉树先序遍历序列	125
图5.16 二叉树的后序遍历序列	125
图5.17 二叉树的中序遍历序列	126
图5.18 先序遍历过程: 先沿最左侧通路自顶而下访问沿途节点, 再自底而上依次遍历这些节点的右子树	127
图5.19 中序遍历过程: 顺着最左侧通路, 自底而上依次访问沿途各节点及其右子树	128
图5.20 迭代式中序遍历实例 (出栈节点以深色示意)	129
图5.21 中序遍历过程中, 在无右孩子的节点处需做回溯	131
图5.22 后序遍历过程也可划分为模式雷同的若干段	132
图5.23 迭代式后序遍历实例 (出栈节点以深色示意, 发生gotoHLVFL()调用的节点以大写字母示意)	133
图5.24 二叉树的层次遍历序列	134
图5.25 层次遍历实例 (出队节点以深色示意)	134
图5.26 完全二叉树实例及其宏观结构	135
图5.27 满二叉树实例及其宏观结构	135

图5.28 为实现PFC编码和解码过程所需的数据结构和算法	136
图5.29 子集的PFC编码树合并后,即是全集的一棵PFC编码树	136
图5.30 最优编码树的双子性	140
图5.31 最优编码树的层次性	140
图5.32 通过节点交换提高编码效率完全二叉树与满二叉树	140
图5.33 考虑字符出现频率,以平均带权深度衡量编码效率	141
图5.34 若考虑出现频率,完全二叉树或满树未必最优	142
图5.35 若考虑出现频率,最优编码树往往不是完全二叉树	142
图5.36 最优编码树的层次性	142
图5.37 最优编码树中底层兄弟节点合并后,依然是最优编码树	143
图5.38 Huffman树构造算法实例	144
图6.1 (a)无向图、(b)混合图和(c)有向图	151
图6.2 通路 with 简单通路	152
图6.3 环路 with 简单环路	152
图6.4 欧拉环路与哈密尔顿环路	152
图6.5 邻接矩阵(空白单元对应的边不存在,其统一取值标注于矩阵最左上角)	155
图6.6 以邻接表方式描述和实现图	158
图6.7 广度优先搜索实例	161
图6.8 深度优先搜索实例(粗边框白色,为当前顶点;细边框白色、双边框白色和黑色,分别为处于UNDISCOVERED、DISCOVERED和VISITED状态的顶点;dTime和fTime标签,分别标注于各顶点的左右)	163
图6.9 活跃期与“祖先-后代”关系之间的对应关系	164
图6.10 拓扑排序	165
图6.11 利用“DAG必有零入度顶点”的特性,实现拓扑排序	166
图6.12 基于DFS搜索的拓扑排序实例	168
图6.13 关节点	168
图6.14 双连通域	168
图6.15 DFS树根节点是关节点,当且仅当它拥有多个分支	169
图6.16 内部节点C是关节点,当且仅当C的某棵极大真子树不(经后向边)联接到C的真祖先	169
图6.17 基于DFS搜索的双连通域分解实例	171
图6.18 支撑树	174
图6.19 极小支撑树与最小支撑树	175
图6.20 最小支撑树总是会采用联接每一割的最短跨越边	176
图6.21 Prim算法示例(阴影区域示意不断扩展的子树 T_k ,粗线示意树边)	177
图6.22 最短路径的任一前缀也是最短路径	178
图6.23 有向带权图(a),及其最短路径树(b)和(c)	178
图6.24 最短路径子树序列	179
图6.25 Dijkstra算法示例(阴影区域示意不断扩展的子树 T_k ,粗线示意树边)	180
图7.1 第7章和第8章内容纵览	182

图7.2 二叉搜索树即处处满足顺序性的二叉树	184
图7.3 二叉搜索树的三个实例（左），以及三个反例（右）	184
图7.4 二叉搜索树（上）的中序遍历序列（下），必然单调非降	184
图7.5 二叉搜索树的查找过程（查找所经过的通路，以粗线条示意）	186
图7.6 searchIn()算法对返回值和_hot的语义定义：(a) 查找成功；(b) 查找失败	187
图7.7 二叉搜索树节点插入算法实例	188
图7.8 二叉搜索树节点删除算法实例	189
图7.9 由三个关键字{ 1, 2, 3 }的6种全排列生成的二叉搜索树	191
图7.10 由同一组共11个节点组成，相互等价的两棵二叉搜索树（二者在拓扑上的差异，以阴影圈出）	192
图7.11 zig(v)：顺时针旋转	193
图7.12 zag(v)：逆时针旋转	193
图7.13 在高度固定为h的前提下，节点最少的AVL树	195
图7.14 经节点删除和插入操作后，AVL树可能失衡（加减号示意平衡因子，双圈表示失衡节点）	195
图7.15 节点插入后，通过单旋操作使AVL树重新平衡	196
图7.16 节点插入后通过连续的两次旋转操作使AVL树重新平衡	197
图7.17 节点删除后经一次旋转恢复局部平衡	198
图7.18 节点删除后通过两次旋转恢复局部平衡	199
图7.19 节点插入后的统一重新平衡	200
图8.1 通过自下而上的一系列等价变换，可使任一节点上升至树根	205
图8.2 简易伸展树的最坏情况	205
图8.3 通过zig-zig操作，将节点v上推两层	206
图8.4 通过zig-zag操作，将节点v上推两层	206
图8.5 通过zig操作，将节点v上推一层，成为树根	207
图8.6 双层调整策略的高度折半效果	207
图8.7 伸展树中较深的节点一旦被访问到，对应分支的长度将随即减半	208
图8.8 伸展树的节点插入	210
图8.9 伸展树的节点删除	211
图8.10 二叉搜索树与四路搜索树	213
图8.11 B-树的宏观结构（外部节点以深色示意，深度完全一致，且都同处于最底层）	214
图8.12 (a) 4阶B-树；(b) B-树的紧凑表示；(c) B-树的最紧凑表示	215
图8.13 B-树的查找过程	217
图8.14 通过分裂修复上溢节点	220
图8.15 3阶B-树插入操作实例（I）	221
图8.16 3阶B-树插入操作实例（II）	222
图8.17 下溢节点向父亲“借”一个关键字，父亲再向左兄弟“借”一个关键字	223
图8.18 下溢节点向父亲“借”一个关键字，父亲再向右兄弟“借”一个关键字	223
图8.19 下溢节点向父亲“借”一个关键字，然后与左兄弟“粘接”成一个节点	224
图8.20 3阶B-树删除操作实例（I）	226

图8.21 3阶B-树删除操作实例(II)	227
图8.22 通过假想式地引入外部节点(黑色正方形),将二叉树扩展为真二叉树	228
图8.23 红黑树到4阶B-树的等价转换(在完全彩色版尚未出版之前本书约定,分别以圆形、正方形和八角形表示红黑树的红节点、黑节点和颜色未定节点,以长方形表示B-树节点)	229
图8.24 红黑树的黑高度不低于高度的一半;反之,高度不超过黑高度的两倍	229
图8.25 双红修正第一种情况(RR-1)及其调整方法(上方、下方分别为红黑树及其对应B-树的局部)	231
图8.26 双红修正第二种情况(RR-2)及其调整方法(带问号的关键码可能存在)	232
图8.27 双红修正流程图	232
图8.28 删除节点x之后,红黑树条件(4):(a)或依然满足,(b)或经重染色后重新满足,(c)或不再满足	234
图8.29 双黑修正(情况BB-1)(带问号的关键码可能存在,且颜色不定)	235
图8.30 双黑修正(情况BB-2-R)(带问号的黑关键码可能但不会同时存在)	235
图8.31 双黑修正(情况BB-2-B)	236
图8.32 双黑修正(情况BB-3)	236
图8.33 双黑修正流程图	237
图8.34 一维范围查询	239
图8.35 通过预先排序,高效地解决一维范围查询问题(p_{-1} 为假想着引入的哨兵,数值等于 $-\infty$)	239
图8.36 平面范围查询(planar range query)	240
图8.37 平衡二叉搜索树:叶节点存放输入点,内部节点等于左子树中的最大者	240
图8.38 借助平衡二叉搜索树解决一维范围查询问题(针对区间端点的两条查找路径加粗示意)	241
图8.39 2d-树中各节点对应的区域,逐层递归地按所包含的输入点数均衡切分	242
图8.40 2d-树的构造过程,就是对平面递归划分的过程	243
图8.41 基于2d-树的平面范围查询(A~J共计10个输入点;命中子树的根节点,以双线圆圈示意)	244
图9.1 三国人物的词典结构	247
图9.2 跳转表的总体逻辑结构	250
图9.3 跳转表节点插入过程(a~d),也是节点删除的逆过程(d~a)	256
图9.4 四联表节点插入过程	257
图9.5 直接使用线性数组实现电话簿词典	260
图9.6 散列函数	261
图9.7 除余法	262
图9.8 素数表长可降低冲突的概率并提高空间的利用率	262
图9.9 MAD法可消除散列过程的连续性	263
图9.10 通过槽位细分排解散列冲突	267
图9.11 利用建立独立链排解散列冲突	267
图9.12 利用公共溢出区解决散列冲突	268
图9.13 线性试探法	268
图9.14 线性试探法对应的查找链	269
图9.15 通过设置懒惰删除标记,无需大量词条的重排即可保证查找链的完整	270
图9.16 线性试探法会加剧聚集现象,而平方试探法则会快速跳离聚集区段	273

图9.17 平方试探法	274
图9.18 即便散列表长取为素数 ($M = 11$), 在装填因子 $\lambda > 50\%$ 时仍可能找不到实际存在的空桶	274
图9.19 分两步将任意类型的密钥码, 映射为桶地址	275
图9.20 利用散列表对一组互异整数排序	277
图9.21 利用散列表对一组可能重复的整数排序	277
图9.22 利用散列法, 在线性时间内确定 n 个共线点之间的最大间隙	278
图10.1 以获奖先后为优先级, 由前12届图灵奖得主构成的完全二叉堆	286
图10.2 按照层次遍历序列, 对完全二叉树节点做编号 (其中圆形表示内部节点, 方形表示外部节点)	287
图10.3 完全二叉堆词条插入过程	289
图10.4 完全二叉堆词条插入操作实例	290
图10.5 完全二叉堆词条删除过程	291
图10.6 完全二叉堆词条删除操作实例	292
图10.7 堆合并算法原理	293
图10.8 Floyd算法实例 (虚线示意下滤过程中的交换操作)	294
图10.9 就地堆排序	295
图10.10 就地堆排序实例: 建堆	296
图10.11 就地堆排序实例: 迭代	296
图10.12 堆合并	297
图10.13 整体结构向左倾斜, 右侧通路上的节点不超过 $O(\log n)$ 个	298
图10.14 空节点路径长度 (其中有个节点违反左倾性, 以双圈标出)	299
图10.15 左式堆: 左孩子的 $np1$ 值不小于右孩子, 而前者的高度却可能小于后者	299
图10.16 左式堆的最右侧通路	300
图10.17 左式堆合并算法原理	300
图10.18 左式堆合并算法实例	301
图10.19 基于堆合并操作实现删除接口	303
图10.20 基于堆合并操作实现词条插入算法	304
图11.1 串模式匹配的蛮力算法	309
图11.2 蛮力算法的最坏情况 (也是基于坏字符策略BM算法的最好情况)	310
图11.3 蛮力算法的最好情况 (也是基于坏字符策略BM算法的最坏情况)	310
图11.4 利用以往的成功比对所提供的信息, 可以避免主串字符指针的回退	311
图11.5 利用以往的成功比对所提供的信息, 有可能使模式串大跨度地右移	311
图11.6 利用此前成功比对所提供的信息, 在安全的前提下尽可能大跨度地右移模式串	312
图11.7 $P[j] = P[\text{next}[j]]$ 时, 必有 $\text{next}[j + 1] = \text{next}[j] + 1$	313
图11.8 $P[j] \neq P[\text{next}[j]]$ 时, 必有 $\text{next}[j + 1] = \text{next}[\dots \text{next}[j] \dots] + 1$	314
图11.9 按照此前定义的next表, 仍有可能进行多次本不必要的字符比对操作	315
图11.10 坏字符策略: 通过右移模式串 P , 使 $T[i + j]$ 重新得到匹配	318
图11.11 借助 $BC[]$ 表的串匹配	320
图11.12 好后缀策略: 通过右移模式串 P , 使与 P 后缀 U 匹配的 w 重新得到匹配	321

图11.13 借助GS[]表的串匹配：(a) 模式串P及其GS[]表；(b) 主串T	322
图11.14 MS[j]和SS[j]表的定义与含义	323
图11.15 由SS[]表构造GS[]表	324
图11.16 构造SS[]表	325
图11.17 典型串匹配算法的复杂度概览	326
图11.18 随着单次比对成功概率（横轴）的提高，串匹配算法的运行时间（纵轴）通常亦将增加	327
图11.19 Karp-Rabin串匹配算法实例：模式串指纹hash("82818") = 82,818 % 97 = 77	329
图11.20 Karp-Rabin串匹配算法实例：模式串指纹hash("18284") = 18,284 % 97 = 48	330
图11.21 相邻子串内容及指纹的相关性	331
图12.1 序列的轴点（这里用高度来表示各元素的大小）	334
图12.2 有序向量经循环左移一个单元后，将不含任何轴点	335
图12.3 轴点构造算法的构思	336
图12.4 轴点构造过程	337
图12.5 轴点构造算法实例	337
图12.6 partition()算法的退化情况，也是最坏情况	339
图12.7 选取与中位数	341
图12.8 通过减治策略计算众数	342
图12.9 采用减治策略，计算等长有序向量归并后的中位数	344
图12.10 基于堆结构的选取算法	346
图12.11 基于快速划分算法逐步逼近选取目标元素	347
图12.12 k-选取目标元素所处位置的三种可能情况	349
图12.13 各子序列的中位数以及全局中位数	349
图12.14 将待排序向量视作二维矩阵	350
图12.15 递减增量、逐渐逼近策略	351
图12.16 希尔排序实例：采用增量序列{ 1, 2, 3, 5, 8, 13, 21, ... }	352
图12.17 (g, h)-有序向量必然(mg + nh)-有序	354
图12.18 经多步迭代，逆序元素可能的范围必然不断缩小	355

表格索引

表1.1	countOnes(441)的执行过程	12
表2.1	向量ADT支持的操作接口	29
表2.2	向量操作实例	30
表3.1	列表节点ADT支持的操作接口	67
表3.2	列表ADT支持的操作接口	68
表3.3	插入排序算法实例	79
表3.4	选择排序算法实例	81
表4.1	栈ADT支持的操作接口	87
表4.2	栈操作实例	87
表4.3	RPN表达式求值算法实例(当前字符以方框注明,操作数栈的底部靠左)	97
表4.4	队列ADT支持的操作接口	105
表4.5	队列操作实例(元素均为整型)	106
表5.1	$\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 的一份二进制编码表	114
表5.2	二进制解码过程	114
表5.3	$\Sigma = \{ 'A', 'E', 'G', 'M', 'S' \}$ 的另一份编码表	115
表5.4	按照表5.3“确定”的编码协议,可能有多种解码结果	115
表5.5	在一篇典型的英文文章中,各字母出现的次数	141
表5.6	由6个字符构成的字符集 Σ ,以及各字符的出现频率	143
表6.1	图ADT支持的边操作接口	153
表6.2	图ADT支持的顶点操作接口	153
表8.1	双红修正算法所涉及局部操作的统计	232
表8.2	双黑修正算法所涉及局部操作的统计	237
表9.1	词典ADT支持的标准操作接口	247
表9.2	词典结构操作实例	247
表9.3	基数排序实例	280
表10.1	优先级队列ADT支持的操作接口	283
表10.2	优先级队列操作实例:选择排序(当前的最大元素以方框示意)	284
表11.1	串ADT支持的操作看接口	307
表11.2	串操作实例	307
表11.3	next表实例:假想地附加一个通配符P[-1]	313
表11.4	next表仍有待优化的实例	315
表11.5	改进后的next表实例	316
表11.6	模式串P = "DATA STRUCTURES"及其对应的BC表	319
表11.7	模式串P = "ICED RICE PRICE"对应的GS表	322
表11.8	模式串P = "ICED RICE PRICE"对应的SS表	323

算法索引

算法1.1 过直线上给定点作直角	3
算法1.2 三等分给定线段	3
算法1.3 取非极端元素	12
算法2.1 从三个苹果中选出重量不同者	57
算法4.1 RPN表达式求值	97
算法4.2 利用队列结构实现的循环分配器	107
算法8.1 构造2d-树	242
算法8.2 基于2d-树的平面范围查询	244
算法12.1 线性时间的k-选取	348
算法12.2 希尔排序	351

代码索引

代码1.1 整数数组的起泡排序	5
代码1.2 整数二进制展开中数位1总数的统计	13
代码1.3 数组元素求和算法sumI()	13
代码1.4 幂函数算法(蛮力迭代版)	14
代码1.5 数组求和算法(线性递归版)	17
代码1.6 数组倒置算法的统一入口	19
代码1.7 数组倒置的递归算法	20
代码1.8 优化的幂函数算法(线性递归版)	21
代码1.9 由递归版改造而得的数组倒置算法(迭代版)	22
代码1.10 进一步调整代码1.9的结构,消除goto语句	22
代码1.11 通过二分递归计算数组元素之和	23
代码1.12 通过二分递归计算Fibonacci数	24
代码1.13 通过线性递归计算Fibonacci数	25
代码1.14 基于动态规划策略计算Fibonacci数	26
代码2.1 向量模板类Vector	31
代码2.2 基于复制的向量构造器	32
代码2.3 重载向量赋值操作符	33
代码2.4 向量内部数组动态扩容算法expand()	34
代码2.5 向量内部功能shrink()	36
代码2.6 重载向量操作符[]	37
代码2.7 向量整体置乱算法permute()	37
代码2.8 向量区间置乱接口unsort()	38
代码2.9 重载比较器以便比较对象指针	38
代码2.10 无序向量元素查找接口find()	39
代码2.11 向量元素插入接口insert()	40
代码2.12 向量区间删除接口remove(lo, hi)	41
代码2.13 向量单元素删除接口remove()	41
代码2.14 无序向量清除重复元素接口deduplicate()	42
代码2.15 向量遍历接口traverse()	43
代码2.16 基于遍历实现increase()功能	44
代码2.17 有序向量甄别算法disordered()	45
代码2.18 有序向量uniquify()接口的平凡实现	45
代码2.19 有序向量uniquify()接口的高效实现	46
代码2.20 有序向量各种查找算法的统一search()接口	47
代码2.21 二分查找算法(版本A)	48

代码2.22 Fibonacci查找算法	53
代码2.23 二分查找算法 (版本B)	55
代码2.24 二分查找算法 (版本C)	56
代码2.25 向量排序器接口	60
代码2.26 向量的起泡排序	60
代码2.27 单趟扫描交换	60
代码2.28 向量的归并排序	62
代码2.29 有序向量的二路归并	63
代码3.1 列表节点模板类	68
代码3.2 列表模板类	70
代码3.3 列表类内部方法init()	71
代码3.4 重载列表类的下标操作符	72
代码3.5 无序列表元素查找接口find()	72
代码3.6 列表节点插入接口	73
代码3.7 ListNode::insertAsPred()算法	73
代码3.8 ListNode::insertAsSucc()算法	74
代码3.9 列表类内部方法copyNodes()	74
代码3.10 基于复制的列表构造方法	75
代码3.11 列表节点删除接口remove()	75
代码3.12 列表析构方法	76
代码3.13 列表清空方法clear()	76
代码3.14 无序列表剔除重复节点接口deduplicate()	76
代码3.15 列表遍历接口traverse()	77
代码3.16 有序列表剔除重复节点接口uniquify()	77
代码3.17 有序列表查找接口search()	78
代码3.18 有序列表基于排序的构造方法	78
代码3.19 列表的插入排序	80
代码3.20 列表的选择排序	81
代码3.21 列表最大节点的定位	82
代码3.22 有序列表的二路归并	82
代码3.23 列表的归并排序	83
代码4.1 Stack模板类	88
代码4.2 进制转换算法 (递归版)	90
代码4.3 进制转换算法 (迭代版)	91
代码4.4 括号匹配算法 (递归版)	92
代码4.5 括号匹配算法 (迭代版)	93
代码4.6 运算符优先级关系的定义	94
代码4.7 表达式的求值及RPN转换	95

代码4.8 皇后类	100
代码4.9 N皇后算法	101
代码4.10 迷宫格点类	102
代码4.11 查询相邻格点	103
代码4.12 转入相邻格点	103
代码4.13 迷宫寻径	103
代码4.14 Queue模板类	106
代码4.15 顾客对象	107
代码4.16 银行服务模拟	108
代码4.17 查找最短队列	108
代码5.1 二叉树节点模板类BinNode	117
代码5.2 以宏的形式对基于BinNode的操作做一归纳整理	119
代码5.3 二叉树节点左、右孩子的插入	119
代码5.4 二叉树中序遍历算法的统一入口	120
代码5.5 二叉树模板类BinTree	121
代码5.6 二叉树节点的高度更新	121
代码5.7 二叉树根、左、右节点的插入	122
代码5.8 二叉树子树的接入	122
代码5.9 二叉树子树的删除	123
代码5.10 二叉树子树的分离	123
代码5.11 二叉树先序遍历算法(递归版)	124
代码5.12 二叉树后序遍历算法(递归版)	125
代码5.13 二叉树中序遍历算法(递归版)	126
代码5.14 二叉树先序遍历算法(迭代版#2)	128
代码5.15 二叉树中序遍历算法(迭代版#1)	129
代码5.16 二叉树节点直接后继的定位	130
代码5.17 二叉树中序遍历算法(迭代版#2)	130
代码5.18 二叉树中序遍历算法(迭代版#3)	131
代码5.19 二叉树后序遍历算法(迭代版)	133
代码5.20 二叉树层次遍历算法	134
代码5.21 基于二叉树的PFC编码	136
代码5.22 实现PFC编码所需的数据结构	137
代码5.23 初始化PFC森林	137
代码5.24 构造PFC编码树	138
代码5.25 生成PFC编码表	138
代码5.26 PFC编码	138
代码5.27 PFC解码	139
代码5.28 基于二叉树的Huffman编码	145

代码5.29 HuffChar结构	145
代码5.30 Huffman编码树结构	145
代码5.31 Huffman森林结构	145
代码5.32 Huffman二进制编码串	145
代码5.33 Huffman编码表	146
代码5.34 Huffman算法：字符出现频率的样本统计	146
代码5.35 初始化Huffman森林	146
代码5.36 构造Huffman编码树	147
代码5.37 生成Huffman编码表	147
代码5.38 Huffman编码	148
代码5.39 Huffman解码	148
代码6.1 图ADT操作接口	154
代码6.2 基于邻接矩阵实现的图结构	157
代码6.3 BFS算法	160
代码6.4 DFS算法	162
代码6.5 基于DFS搜索框架实现拓扑排序算法	167
代码6.6 基于DFS搜索框架实现双连通域分解算法	170
代码6.7 优先级搜索算法框架	173
代码6.8 Prim算法的顶点优先级更新器	177
代码6.9 Dijkstra算法的顶点优先级更新器	179
代码7.1 词条模板类Entry	183
代码7.2 由BinTree派生的二叉搜索树模板类BST	185
代码7.3 二叉搜索树searchIn()算法的递归实现	186
代码7.4 二叉搜索树search()接口	186
代码7.5 二叉搜索树insert()接口	188
代码7.6 二叉搜索树remove()接口	190
代码7.7 二叉搜索树removeAt()算法	190
代码7.8 基于BST定义的AVL树接口	194
代码7.9 用于简化AVL树算法描述的宏	194
代码7.10 恢复平衡的调整方案，决定于失衡节点的更高孩子、更高孙子节点的方向	196
代码7.11 AVL树节点的插入	197
代码7.12 AVL树节点的删除	199
代码7.13 “3 + 4”重构	201
代码7.14 AVL树的统一重平衡	201
代码8.1 基于BST定义的伸展树接口	208
代码8.2 伸展树节点的调整	210
代码8.3 伸展树节点的查找	210
代码8.4 伸展树节点的插入	211

代码8.5 伸展树节点的删除	212
代码8.6 B-树节点.....	215
代码8.7 B-树	216
代码8.8 B-树关键码的查找	217
代码8.9 B-树关键码的插入	219
代码8.10 B-树节点的上溢处理.....	221
代码8.11 B-树关键码的删除	222
代码8.12 B-树节点的下溢处理.....	226
代码8.13 基于BST定义的红黑树接口	230
代码8.14 用以简化红黑树算法描述的宏	230
代码8.15 红黑树节点的黑高度更新	230
代码8.16 红黑树insert()接口	231
代码8.17 双红修正solveDoubleRed()	233
代码8.18 红黑树remove()接口	234
代码8.19 双黑修正solveDoubleBlack()	238
代码9.1 词典结构的操作接口规范	248
代码9.2 Skiplist模板类.....	249
代码9.3 Quadlist模板类.....	251
代码9.4 QuadlistNode模板类.....	251
代码9.5 Quadlist对象的创建	252
代码9.6 Skiplist::get()查找	252
代码9.7 Skiplist::skipSearch()查找	253
代码9.8 Skiplist::put()插入	255
代码9.9 Quadlist::insertAfterAbove()插入.....	257
代码9.10 QuadlistNode::insertAsSuccAbove()插入.....	257
代码9.11 Skiplist::remove()删除	258
代码9.12 Quadlist::remove()删除	258
代码9.13 基于散列表实现的映射结构	265
代码9.14 散列表构造	265
代码9.15 确定散列表的素数表长	266
代码9.16 散列表析构	266
代码9.17 散列表的查找	271
代码9.18 散列表的查找probe4Hit()	271
代码9.19 散列表元素删除(采用懒惰删除策略)	271
代码9.20 散列表元素插入	272
代码9.21 散列表的查找probe4Free()	272
代码9.22 散列表的重散列	273
代码9.23 散列表转换函数hashCode()	276

代码10.1 优先级队列标准接口	284
代码10.2 利用统一的优先级队列接口, 实现通用的Huffman编码	285
代码10.3 为简化完全二叉堆算法的描述及实现而定义的宏	288
代码10.4 完全二叉堆接口	288
代码10.5 完全二叉堆getMax()接口	289
代码10.6 完全二叉堆insert()接口的主体框架	289
代码10.7 完全二叉堆的上滤	290
代码10.8 完全二叉堆delMax()接口的主体框架	291
代码10.9 完全二叉堆的下滤	292
代码10.10 Floyd建堆算法	294
代码10.11 基于向量的就地堆排序	297
代码10.12 左式堆PQ_LeftHeap模板类定义	298
代码10.13 左式堆合并接口merge()	302
代码10.14 左式堆节点删除接口delMax()	303
代码10.15 左式堆节点插入接口insert()	304
代码11.1 蛮力串匹配算法(版本一)	309
代码11.2 蛮力串匹配算法(版本二)	310
代码11.3 KMP主算法	313
代码11.4 next表的构造	314
代码11.5 改进的next表构造算法	316
代码11.6 BM主算法	317
代码11.7 BC表的构造	319
代码11.8 GS表的构造	326
代码11.9 Karp-Rabin算法相关的预定义	328
代码11.10 Karp-Rabin算法主体框架	329
代码11.11 指纹相同时还需逐个字符地比对	330
代码11.12 串指纹的快速更新	331
代码11.13 提前计算 $M^{(m-1)}$	331
代码12.1 向量的快速排序	335
代码12.2 轴点构造算法(版本A)	336
代码12.3 轴点构造算法(版本B)	340
代码12.4 众数查找算法主体框架	342
代码12.5 候选众数核对算法	342
代码12.6 候选众数选取算法	343
代码12.7 中位数蛮力查找算法	343
代码12.8 等长有序向量归并后中位数算法	344
代码12.9 不等长有序向量归并后中位数算法	346
代码12.10 基于快速划分的k-选取算法	348

关键词索引

(按关键词中各汉字的声母及各英文单词的首字母排序, 比如“大O记号”对应于“DOJH”)

A

AVL树 (AVL tree) 194

B

边 (edge) 110, 150

八叉树 (octree) 204

波峰集 (frontier) 159

比较树 (comparison tree) 58

遍历 (traversal) 124, 150

遍历树 (traversal tree) 159

编码 (encoding) 114

Boyer-Moore算法 (Boyer-Moore Algorithm) 317

B-树 (B-tree) 214

闭散列 (closed hashing) 268

不稳定算法 (unstable algorithm) 61, 337

半线性结构 (semi-linear structure) 110, 150

C

层 (level) 250

出边 (outgoing edge) 151

成本 (cost) 174

层次遍历 (level-order traversal) 133

出队 (dequeue) 105

出度 (out-degree) 151

词典 (dictionary) 246, 247, 248

持久性结构 (persistent structure) 204

串模式匹配 (string pattern matching) 308

插入排序 (insertionsort) 79, 353

初始化 (initialization) 32

重散列 (rehashing) 273

常数时间复杂度算法 (constant-time algorithm)	12
词条 (entry)	183, 246, 283
错误 (error)	42
槽位 (slot)	267
重写 (override)	121, 185, 279
抽象数据类型 (abstract data type, ADT)	26
除余法 (division method)	262
出栈 (pop)	87
重载 (overload)	20, 37, 100, 145, 276, 285
查找长度 (search length)	50, 191, 269
查找链 (probing chain)	269

D

堆 (heap)	286
底层 (bottom)	250
顶层 (top)	250
对称二叉B-树 (symmetric binary B-tree)	228
多重继承 (multiple inheritance)	249, 288, 298
多槽位法 (multiple slots)	267
顶点 (vertex)	110, 150
迭代式后序遍历 (iterative postorder traversal)	132
迭代式先序遍历 (iterative preorder traversal)	126
迭代式中序遍历 (iterative inorder traversal)	128
递归调用 (recursive call)	16
递归跟踪 (recursion trace)	17, 63, 83, 89, 168, 303
递归基 (base case of recursion)	17
递归式后序遍历 (recursive postorder traversal)	125
递归式先序遍历 (recursive preorder traversal)	124
递归式中序遍历 (recursive inorder traversal)	126
递减增量 (diminishing increment)	351
队列 (queue)	105
多路递归 (multi-way recursion)	23
独立链 (separate chaining)	267
多路搜索树 (multi-way search tree)	213
大 Ω 记号 (big-omega notation)	10
大 O 记号 (big-O notation)	9
堆排序 (heapsort)	295

带权图 (weighted graph)	152
度数 (degree)	111, 151
对数多项式时间复杂度算法 (polylogarithmic-time algorithm)	13
Dijkstra算法 (Dijkstra Algorithm)	178
对数时间复杂度算法 (logarithmic-time algorithm)	13
队头 (front)	105
递推方程 (recurrence equation)	19, 52, 64
动态规划 (dynamic programming)	25
大 Θ 记号 (big-theta notation)	11
队尾 (rear)	105
对外功能接口 (interface)	26
低位字段优先 (least significant digit first)	279
多项式时间复杂度算法 (polynomial-time algorithm)	14
多项式散列码 (polynomial hash code)	276
调用栈 (call stack)	89
地址空间 (address space)	259

E

二叉编码树 (binary encoding tree)	116
二叉树 (binary tree)	111
二叉树节点 (binary tree node)	117
二叉搜索树 (binary search tree)	184
二分查找 (binary search)	48, 49, 50, 54, 55, 56, 183, 217, 239, 240
二分递归 (binary recursion)	23

F

封闭定址 (closed addressing)	268
Fibonacci查找 (Fibonacci search)	52
分而治之 (divide-and-conquer)	22, 23
符号表 (symbol table)	246
返回地址 (return address)	89
父节点 (parent)	111, 112
Floyd算法 (Floyd Algorithm)	293
分摊分析 (amortized analysis)	35, 53, 204, 206, 227, 273, 315
分摊运行时间 (amortized running time)	35
范围查询 (range query)	239

非线性结构 (non-linear structure)	150
复杂度下界 (lower bound)	58

G

根 (root)	110
割 (cut)	175
归并排序 (mergesort)	61, 83
高度 (height)	111
广度优先搜索 (Breadth-First Search, BFS)	159
广度优先搜索树 (BFS tree)	160
广度优先搜索森林 (BFS forest)	161
公共溢出区 (overflow area)	268
关节点 (articulation point)	168
关键码 (key)	61, 137, 146, 213, 246, 248, 283, 327
关联 (incident)	151
关联数组 (associative array)	247
根通路串 (root path string)	116
构造函数 (constructor)	32

H

弧 (arc)	150
Huffman编码树 (Huffman encoding tree)	143
后代 (descendant)	111
黑高度 (black height)	118, 228, 230
红黑树 (red-black tree)	228
混合图 (mixed graph)	151
好后缀 (good suffix)	321
后继 (successor)	28, 67
画家算法 (painter's algorithm)	320, 324
后进先出 (last-in-first-out, LIFO)	87, 90
环路 (cycle)	152
h-排序 (h-sorting)	354
回溯 (backtracking)	99
黑深度 (black depth)	228
后向边 (back edge)	163
活跃函数实例 (active function instance)	89

活跃期 (active duration)	163
h-有序 (h-ordered)	354
后缀 (suffix)	28, 67, 306
后缀表达式 (postfix)	97
坏字符 (bad character)	318
孩子节点 (child)	111

J

节点 (node)	66, 67, 110, 112, 150, 186
建堆 (heapification)	292
节点的分裂 (split)	219
节点的合并 (merge)	61, 224
简单环路 (simple cycle)	152
就地算法 (in-place algorithm)	12
简单图 (simple graph)	151
简单通路 (simple path)	152
减而治之 (decrease-and-conquer)	17, 48, 185, 343, 344
几何分布 (geometric distribution)	254
聚集 (clustering)	263
渐进分析 (asymptotic analysis)	9
解码 (decoding)	114
计算机科学 (computer science)	2
计算科学 (computing science)	2
基数排序 (radixsort)	279
具体实现 (implementation)	26
极小支撑树 (minimal spanning tree, MST)	175
记忆 (memoization)	25
基于比较式算法 (comparison-based algorithm, CBA)	58, 59, 82, 246, 277, 278
剪枝 (pruning)	99

K

跨边 (cross edge)	160, 163
空串 (null string)	306
k叉树 (k-ary tree)	112
可达分量 (reachable component)	159
kd-树 (kd-tree)	242

开放定址 (open addressing)	268
客户 (client)	107
空节点路径长度 (null path length)	118, 299
空间复杂度 (space complexity)	11
可计算性 (computability)	7
可扩充向量 (extendable vector)	33, 34
KMP算法 (KMP Algorithm)	311
Karp-Rabin算法 (Karp-Rabin Algorithm)	327
快速划分 (quick partitioning)	336
开散列 (open hashing)	268
快速排序 (quicksort)	334
k-选取 (k-selection)	341
跨越边 (crossing edge)	175
可有效求解的 (tractable)	14

L

列表 (list)	28, 66
链表 (linked list)	66
鲁棒性 (robustness)	7
连通分量 (connected component)	159
懒惰删除 (lazy removal)	270
邻接 (adjacent)	151
链接 (link)	66
路径 (path)	151
邻接表 (adjacency list)	158, 174
邻接矩阵 (adjacency matrix)	155
离线算法 (offline algorithm)	57
旅行商问题 (traveling salesman problem)	99
轮值 (round robin)	107

M

MAD法 (multiply-add-divide method)	263
满二叉树 (full binary tree)	135, 192, 293, 294, 300
末节点 (last node)	71, 131, 251
模式定位 (pattern location)	308
模式检测 (pattern detection)	308

模式计数 (pattern counting)	308
模式枚举 (pattern enumeration)	308

N

内部节点 (internal node)	111
逆波兰表达式 (reverse Polish notation, RPN)	96
难解的 (intractable)	15
难解性 (intractability)	8
逆序对 (inversion)	355

O

欧拉环路 (Eulerian tour)	152
----------------------------	-----

P

排队论 (queuing theory)	107
PFC编码树 (PFC encoding tree)	116
平凡后缀 (trivial suffix)	306
平凡前缀 (trivial prefix)	306
平方取中法 (mid-square)	264
平方试探 (quadratic probing)	274
平凡子串 (trivial substring)	306
平衡二叉搜索树 (balanced binary search tree, BBST)	192
平衡因子 (balance factor)	194
平均情况 (average case)	10
平均运行时间 (average running time)	35
平面范围查询 (planar range query)	240
Prim算法 (Prim Algorithm)	175
偏序 (partial order)	282
排序 (sorting)	4

Q

桥 (bridge)	175
起点 (origin)	151
起点 (source)	178

切割节点 (cut vertex)	168
清理 (cleanup)	33
起泡排序 (bubblesort)	4, 5, 9, 10, 14, 60
前驱 (predecessor)	28, 67
期望运行时间 (expected running time)	35
全序 (full order)	282
前向边 (forward edge)	163
权重 (weight)	152
前缀 (prefix)	28, 67
前缀 (prefix)	306
前缀无歧义编码 (prefix-free code)	115

R

入边 (incoming edge)	151
入队 (enqueue)	105
入度 (in-degree)	151
入栈 (push)	87

S

树边 (tree edge)	160, 162
哨兵节点 (sentinel node)	71, 73, 74, 75, 239, 250
输出 (output)	5
输出敏感的 (output sensitive)	240, 241
四叉树 (quadtree)	204
深度 (depth)	111
深度优先搜索 (Depth-First Search, DFS)	162
深度优先搜索树 (DFS tree)	163
深度优先搜索森林 (DFS forest)	163
双红 (double red)	231
双黑 (double black)	234
随机存储器 (Random Access Machine, RAM)	9
首节点 (first node)	71, 76, 83, 135, 251, 253
时间复杂度 (time complexity)	8
数据局部性 (data locality)	204, 269, 274
随机生成 (randomly generated)	191
随机组成 (randomly composed)	191

上滤 (percolate up)	289
散列 (hashing)	259
四联表 (quadlist)	250
散列表 (hashtable)	146
散列表 (hashtable)	259
散列冲突 (collision)	261
散列地址 (hashing address)	259
散列函数 (hash function)	259
散列码 (hash code)	275
双连通域 (bi-connected component)	168
势能分析法 (potential analysis)	208
输入 (input)	5
输入敏感的 (input sensitive)	39, 353
搜索 (search)	183
试探 (probing)	99
顺序查找 (sequential search)	39
上溢 (overflow)	33, 219
伸展 (splaying)	205
数组 (array)	28
数字分析法 (selecting digits)	264
伸展树 (splay tree)	204

T

图 (graph)	150
塔 (tower)	250
桶 (bucket)	259
头顶点 (head)	151
退化 (degeneracy)	7
头节点 (header)	71
通路 (path)	151
图灵机 (Turing Machine, TM)	9
拓扑排序 (topological sorting)	166
桶排序 (bucketsort)	277
图搜索 (graph search)	159
桶数组 (bucket array)	259
跳转表 (skip list)	249

W

外部节点 (external node)	111, 186, 214
尾顶点 (tail)	151
尾递归 (tail recursion)	22
伪对数的 (pseudo-logarithmic)	16
稳定算法 (stable algorithm)	61, 80, 277
稳定性 (stability)	55, 61, 280
尾节点 (trailer)	71, 255
网络 (network)	152
完美散列 (perfect hashing)	260
完全二叉堆 (complete binary heap)	286
完全二叉树 (complete binary tree)	135, 194, 286, 287, 293, 298
伪随机试探法 (pseudo-random probing)	275
无向边 (undirected edge)	150
无向图 (undigraph)	151
伪线性的 (pseudo-linear)	16
无序向量 (unsorted vector)	39
位异或法 (xor)	264
位置 (position)	28, 66, 118

X

希尔排序 (Shellsort)	350
析构函数 (destructor)	33
循关键码访问 (call-by-key)	183, 185
先进先出 (first-in-first-out, FIFO)	105, 107, 282
下滤 (percolate down)	291
向量 (vector)	28, 29
序列 (sequence)	28
相邻 (adjacent)	151
循链接访问 (call-by-link)	66
选取 (selection)	341
稀疏图 (sparse graph)	158
循位置访问 (call-by-position)	66
线性递归 (linear recursion)	17
线性结构 (linear structure)	110

线性时间复杂度算法 (linear-time algorithm)	14
线性试探 (linear probing)	268
线性数组 (linear array)	28
下溢 (underflow)	36, 223
循优先级访问 (call-by-priority)	282
循值访问 (call-by-value)	246
循秩访问 (call-by-rank)	29, 66, 157
循秩访问 (call-by-rank)	344
选择排序 (selectionsort)	80, 283

Y

源点 (source)	178
有根树 (rooted tree)	110
叶节点 (leaf)	111
易解的 (tractable)	14
叶节点带权平均深度 (weighted average leaf depth)	141
叶节点平均深度 (average leaf depth)	139
有穷性 (finiteness)	6
映射 (map)	246
意外 (exception)	42
有向边 (directed edge)	150
有序二叉树 (ordered binary tree)	111
优先级 (priority)	283
优先级队列 (priority queue)	283
优先级数 (priority number)	173
优先级搜索 (Priority-First Search, PFS)	173
有序列表 (sorted list)	77
有序树 (ordered tree)	113
有向图 (digraph)	151
有向无环图 (directed acyclic graph, DAG)	152, 166
有序向量 (sorted vector)	29, 44
野指针 (wild pointer)	34

Z

帧 (frame)	89
栈 (stack)	86

秩 (rank)	28, 29
制表 (tabulation)	25
子串 (substring)	306
支撑树 (spanning tree)	174
终点 (destination)	151
栈底 (stack bottom)	87
栈顶 (stack top)	87
轴点 (pivot)	335
折叠法 (folding)	264
最低共同祖先 (lowest common ancestor, LCA)	241
最大间隙 (maximum gap)	278
最短路径树 (shortest-path tree)	178
字典序 (lexicographical order)	61, 113, 279
真二叉树 (proper binary tree)	111, 228
字符表 (alphabet)	306
字符串 (string)	306
字符集 (alphabet)	114, 116, 136, 139
最高连通祖先 (highest connected ancestor, HCA)	169
最高左侧可见叶节点 (highest leaf visible from left, HLVFL)	132
自环 (self-loop)	151
组合 (combination)	354
真后代 (proper descendant)	111
最好情况 (best case)	10
最坏情况 (worst case)	10
最坏情况下最优的 (worst-case optimal)	58
栈混洗 (stack permutation)	91
真后缀 (proper suffix)	306
直接后继 (intermediate successor)	28, 67
直接前驱 (intermediate predecessor)	28, 67
最佳优先搜索 (Best-First Search, BFS)	173
增量 (increment)	350
正确性 (correctness)	6
真前缀 (proper prefix)	306
子树 (subtree)	111
众数 (majority)	342
左式堆 (leftist heap)	298
再散列 (double hashing)	275
指数时间复杂度算法 (exponential-time algorithm)	15

装填因子 (load factor)	33, 261, 272
自调整列表 (self-adjusting list)	205
指纹 (fingerprint)	328
中位点 (median point)	242
中位数 (median)	341
祖先 (ancestor)	111
在线算法 (online algorithm)	57, 116
执行栈 (execution stack)	89
最小支撑树 (minimum spanning tree, MST)	175
最优编码树 (optimal encoding tree)	139
最右侧通路 (rightmost path)	300
中缀表达式 (infix)	97
真子串 (proper substring)	306
最左侧通路 (leftmost path)	127
真祖先 (proper ancestor)	111

内容简介

本书按照面向对象程序设计的思想,根据作者多年的教学积累,系统地介绍各类数据结构的功能、表示和实现,对比各类数据结构适用的应用环境;结合实际问题展示算法设计的一般性模式与方法、算法实现的主流技巧,以及算法效率的评判依据和分析方法;以高度概括的体例为线索贯穿全书,并通过对比和类比揭示数据结构与算法的内在联系,帮助读者形成整体性认识。

配套《习题解析》涵盖验证型、拓展型、反思型、实践型和研究型习题,总计**290**余道大题、**525**多道小题,激发读者的求知欲,培养自学能力和独立思考习惯。本书及《习题解析》共计配有**340**多组、**400**余幅插图结合简练的叙述,**40**多张表格列举简明的规范、过程及要点,**280**余段代码及算法配合详尽而简洁的注释,使深奥抽象的概念和过程得以具体化且便于理解和记忆;推荐**20**余册经典的专著与教材,提供**40**余篇重点的学术论文,便于读者进一步钻研和拓展。

结合学生基础、专业方向、教学目标及允许课时总量等各种因素,本书推荐了若干种典型的教学进度及学时分配方案,供授课教师视具体情况参考和选用。

勘误表、插图、代码以及配套讲义等相关教学资料,均以电子版形式向公众开放,读者可从本书主页直接下载: <http://dsa.cs.tsinghua.edu.cn/~deng/ds/dsacpp/>

清华大学

计算机系列教材

邓俊辉 编著

数据结构习题解析

(第3版)



清华大学出版社

清华大学计算机系列教材

本套教材已伴随着计算机科学与技术的发展茁壮成长了三十余年，获得了中华人民共和国教育部科技进步奖、普通高等学校优秀教材全国特等奖、全国优秀畅销书金奖等三十多项部级以上奖励，被近千所高校选作教材，教学效果非常好。本套教材经过多次修订改版和增加新品种、新内容、新技术，基本涵盖了本科生和硕士研究生的主要课程。本套教材的作者全部是清华大学计算机系的教师，教材的内容、语言特点、课时安排体现了他们治学严谨的特点，概念表述严谨，逻辑推理严密，语言精炼。同时，本套教材体系完整、结构严谨，理论结合实际，注重素质培养。

内容简介

本书按照面向对象程序设计的思想，根据作者多年的教学积累，系统地介绍各类数据结构的功能、表示和实现，对比各类数据结构适用的应用环境；结合实际问题展示算法设计的一般性模式与方法、算法实现的主流技巧，以及算法效率的评判依据和分析方法；以高度概括的体例为线索贯穿全书，并通过对比和类比揭示数据结构与算法的内在联系，帮助读者形成整体性认识。

配套的习题解析涵盖验证型、拓展型、反思型、实践型和研究型习题，总计290余道大题、525多道小题，激发读者的求知欲，培养自学能力和独立思考习惯。本书及《习题解析》共计配有340多组、400余幅插图结合简练的叙述，40多张表格列举简明的规范、过程及要点，280余段代码及算法配合详尽而简洁的注释，使深奥抽象的概念和过程得以具体化且便于理解和记忆；推荐20余册经典的专著与教材，提供40余篇重点的学术论文，便于读者进一步钻研和拓展。

结合学生基础、专业方向、教学目标及允许课时总量等各种因素，本书推荐了若干种典型的教学进度及学时分配方案，供授课教师视具体情况参考和选用。

勘误表、插图、代码以及配套讲义等相关教学资料，均以电子版形式向公众开放，读者可从本书主页直接下载：<http://dsa.cs.tsinghua.edu.cn/~deng/ds/dsacpp/>

作者介绍



邓俊辉 清华大学计算机系副教授。1993年、1997年分别于清华大学计算机系获工学学士和工学博士学位。主要研究方向为科学计算可视化、计算几何及计算机图形学。长期承担清华大学计算机本科生专业基础课程“数据结构”和研究生基础理论课“计算几何”的教学工作，编著的《数据结构与算法（Java描述）》入选“北京市高等教育精品教材”，参与编著的《数据结构（用面向对象方法与C++语言描述）》入选“国家级高等教育精品教材”，曾获清华大学“青年教师教学优秀奖”、清华大学“教书育人奖”、清华大学“教学成果奖”二等奖、清华大学“教学成果奖”一等奖、中国高校科学技术奖二等奖、宝钢教育基金“宝钢教育奖”。

清华大学985名优教材立项资助

数据结构习题解析 (C++语言版)

第 3 版

邓俊辉

清华大学出版社

2013年9月·北京

目录

第1章 绪论

1

[1-1]	2
[1-2]	2
[1-3]	4
[1-4]	4
[1-5]	5
[1-6]	5
[1-7]	6
[1-8]	7
[1-9]	7
[1-10]	7
[1-11]	7
[1-12]	8
[1-13]	10
[1-14]	10
[1-15]	11
[1-16]	12
[1-17]	12
[1-18]	13
[1-19]	13
[1-20]	14
[1-21]	15
[1-22]	16
[1-23]	17
[1-24]	18
[1-25]	19
[1-26]	21
[1-27]	22
[1-28]	22
[1-29]	23
[1-30]	23
[1-31]	24
[1-32]	24

第2章 向量

35

[2-1]	36
[2-2]	36
[2-3]	36
[2-4]	37
[2-5]	37
[2-6]	38
[2-7]	39
[2-8]	40
[2-9]	41
[2-10]	41
[2-11]	42
[2-12]	42
[2-13]	44
[2-14]	45
[2-15]	45
[2-16]	46
[2-17]	46
[2-18]	46
[2-19]	48
[2-20]	48
[2-21]	50
[2-22]	51
[2-23]	52
[2-24]	53
[2-25]	56
[2-26]	57
[2-27]	57
[2-28]	58
[2-29]	58
[2-30]	59
[2-31]	60
[2-32]	61

[2-33]	61
[2-34]	61
[2-35]	65
[2-36]	66
[2-37]	68
[2-38]	68
[2-39]	68
[2-40]	69
[2-41]	70

第3章 列表

73

[3-1]	74
[3-2]	74
[3-3]	74
[3-4]	75
[3-5]	75
[3-6]	76
[3-7]	76
[3-8]	77
[3-9]	77
[3-10]	78
[3-11]	79
[3-12]	79
[3-13]	81
[3-14]	81
[3-15]	83
[3-16]	84
[3-17]	84
[3-18]	84
[3-19]	86

第4章 栈与队列

87

[4-1]	88
[4-2]	89
[4-3]	89
[4-4]	91
[4-5]	91

[4-6]	92
[4-7]	92
[4-8]	93
[4-9]	93
[4-10]	95
[4-11]	95
[4-12]	96
[4-13]	97
[4-14]	97
[4-15]	99
[4-16]	99
[4-17]	99
[4-18]	100
[4-19]	100
[4-20]	101
[4-21]	101
[4-22]	101
[4-23]	102
[4-24]	102
[4-25]	102
[4-26]	102

第5章 二叉树

103

[5-1]	104
[5-2]	104
[5-3]	105
[5-4]	106
[5-5]	106
[5-6]	106
[5-7]	107
[5-8]	107
[5-9]	107
[5-10]	108
[5-11]	108
[5-12]	109
[5-13]	110
[5-14]	110

[5-15]	110
[5-16]	110
[5-17]	112
[5-18]	112
[5-19]	113
[5-20]	113
[5-21]	114
[5-22]	114
[5-23]	114
[5-24]	115
[5-25]	115
[5-26]	116
[5-27]	116
[5-28]	116
[5-29]	117
[5-30]	118

第6章 图

119

[6-1]	120
[6-2]	121
[6-3]	121
[6-4]	122
[6-5]	122
[6-6]	124
[6-7]	124
[6-8]	125
[6-9]	125
[6-10]	126
[6-11]	127
[6-12]	127
[6-13]	128
[6-14]	128
[6-15]	128
[6-16]	128
[6-17]	130
[6-18]	130
[6-19]	131

[6-20]	131
[6-21]	132
[6-22]	133
[6-23]	134
[6-24]	134
[6-25]	135
[6-26]	135
[6-27]	136
[6-28]	136
[6-29]	138
[6-30]	138
[6-31]	141
[6-32]	142

第7章 搜索树

145

[7-1]	146
[7-2]	146
[7-3]	146
[7-4]	147
[7-5]	147
[7-6]	148
[7-7]	148
[7-8]	148
[7-9]	148
[7-10]	149
[7-11]	150
[7-12]	150
[7-13]	150
[7-14]	151
[7-15]	151
[7-16]	152
[7-17]	153
[7-18]	154
[7-19]	154
[7-20]	155

第8章 高级搜索树

157

[8-1]	158
[8-2]	158
[8-3]	160
[8-4]	160
[8-5]	162
[8-6]	163
[8-7]	165
[8-8]	165
[8-9]	166
[8-10]	167
[8-11]	167
[8-12]	167
[8-13]	168
[8-14]	169
[8-15]	170
[8-16]	170
[8-17]	172
[8-18]	172
[8-19]	173
[8-20]	176

第9章 词典

179

[9-1]	180
[9-2]	180
[9-3]	180
[9-4]	181
[9-5]	181
[9-6]	182
[9-7]	183
[9-8]	183
[9-9]	183
[9-10]	183
[9-11]	184
[9-12]	184
[9-13]	184

[9-14]	184
[9-15]	185
[9-16]	186
[9-17]	186
[9-18]	188
[9-19]	189
[9-20]	189
[9-21]	190
[9-22]	190
[9-23]	190
[9-24]	192
[9-25]	192
[9-26]	193

第10章 优先级队列

195

[10-1]	196
[10-2]	196
[10-3]	197
[10-4]	197
[10-5]	198
[10-6]	199
[10-7]	199
[10-8]	199
[10-9]	200
[10-10]	200
[10-11]	200
[10-12]	201
[10-13]	201
[10-14]	201
[10-15]	201
[10-16]	202
[10-17]	202
[10-18]	204
[10-19]	206
[10-20]	207
[10-21]	208
[10-22]	210

第11章 串 211

[11-1]	212
[11-2]	212
[11-3]	212
[11-4]	214
[11-5]	214
[11-6]	214
[11-7]	215
[11-8]	217
[11-9]	217
[11-10]	218

第12章 排序 219

[12-1]	220
[12-2]	221
[12-3]	222
[12-4]	222
[12-5]	223

[12-6]	223
[12-7]	223
[12-8]	224
[12-9]	224
[12-10]	225
[12-11]	225
[12-12]	226
[12-13]	226
[12-14]	228

附录 229

参考文献	230
插图索引	234
表格索引	237
算法索引	238
代码索引	239
关键词索引	241

第1章

绪论

[1-1] 试借助基本的几何作图操作描述一个算法过程，实现“过直线外一点作其平行线”的功能。

【解答】

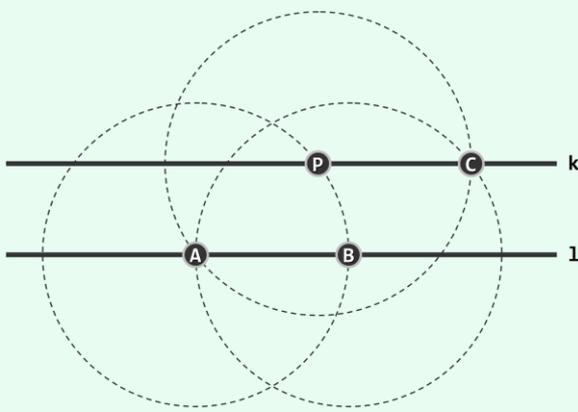
算法x1.1^①给出了一个可行的算法，其原理及操作过程如图x1.1所示。

```
parallel(l, P)
```

输入：直线l及其外一点P

输出：经过P且平行于l的直线

1. 以l上任意一点A为中心、以|AP|为半径作圆
2. 在该圆与l的两个交点中，任取其一记作B
3. 分别以B和P为中心、以|AP|为半径各作一圆
4. 两圆相交于A及另一点，将后者记作C
5. 过P和C绘制一条直线k



算法x1.1 过直线外一点作其平行线

图x1.1 过直线外一点作其平行线

[1-2] 《海岛算经》讨论了如下遥测海岛高度的问题：

今有望海岛，立两表，齐高三丈，前后相去千步，令后表与前表参相直。从前表却行一百二十三步，人目著地取望岛峰，与表末参合。从后表却行一百二十七步，人目著地取望岛峰，亦与表末参合。问岛高及去表各几何？

刘徽所给出的解法是：

以表高乘表间为实；相多为法，除之。所得加表高，即得岛高。

求前表去岛远近者，以前表却行乘表间为实。相多为法。除之，得岛去表数。

a) 该算法的原理是什么？

【解答】

刘徽通过设立两根立柱（表），利用光线直线传播的性质，根据海岛峰顶经过立柱顶端后到地面的投影位置，巧妙地计算出远方海岛的高度。

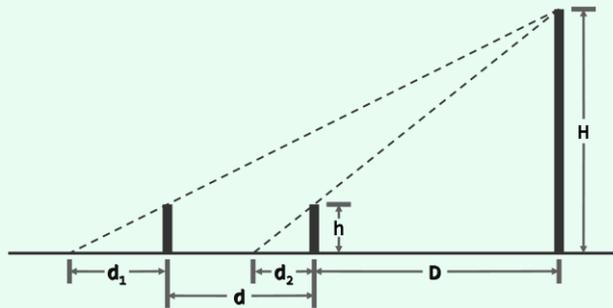
具体地如图x1.2所示，若将立柱高度（表高）记作h，后立柱、前立柱间距（表间）记作d，对应的投影距离分别记作d₁和d₂，则不难导出：

$$\begin{aligned} \text{海岛高度} H &= d \times h / (d_1 - d_2) + h \\ &= 1000 \times 3 / (127 - 123) + 3 \\ &= 753 \text{ (丈)} \end{aligned}$$

$$\text{海岛距离} D = d \times d_2 / (d_1 - d_2)$$

^① 为与主教材相互区别，本习题解析中所有插图、表格、算法、代码等编号前，均增加“x”标识

$$\begin{aligned}
 &= 1000 \times 123 / (127 - 123) \\
 &= 30750 \text{ (步)}
 \end{aligned}$$



图x1.2 《海岛算经》算法原理

按古制，1丈合10尺，1步合6尺，3丈合5步，1里合300步，故前者为1255步（4里又55步），后者为102里又150步。

b) 试以伪代码形式描述该算法的过程。

【解答】

按照以上原理，计算海岛高度H的算法可形式地描述如代码x1.1所示：

```

1 float islandHeight(float d1, float d2, float d, float h) { //后表却步、前表却步、表间、表高
2   float pha = d1 - d2; //二去表相减为相多，以为法
3   float shi = d * h; //前后表相去为表间，以表高乘之为实
4   return shi / pha + h; //以法除之，加表高，即是岛高积步
5 }

```

代码x1.1 《海岛算经》中计算海岛高度的算法

而计算前立柱至海岛距离D的算法，可形式地描述如代码x1.2所示：

```

1 float islandDistance(float d1, float d2, float d) { //后表却步、前表却步、表间
2   float shi = d2 * d; //前去表乘表间（得一十二万三千步）
3   float pha = d1 - d2; //以相多（四步）为法
4   return shi / pha; //除之（得三万七百五十步；又以里法三百步除之，得一百二里一百五十步）
5 }

```

代码x1.2 《海岛算经》中计算海岛距离的算法

以上算法中的注释，引自（唐）李淳风等对原书的注解。

c) 该算法借助了哪些计算工具？

【解答】

可见，以上算法利用了（垂直地面、等长的）两根立柱、（沿直线传播的）光线，以及度量立柱高度、立柱间距及其投影距离的直尺。当然，人眼在此也不可或缺，否则难以确定投影位置。

[1-3] 试分别举出实例说明，在对包含 n 个元素的序列做起泡排序的过程中，可能发生以下情况：

a) 任何元素都无需移动（从而内循环仅执行一轮即可终止算法）；

【解答】

比如，所有元素已经按序排列。

b) 某元素会一度（朝着远离其最终位置的方向）逆向移动；

【解答】

比如序列：

$$\{ n, \boxed{n-1}, 1, 2, \dots, n-2 \}$$

经首轮扫描交换后为

$$\{ \boxed{n-1}, 1, 2, \dots, n-2, n \}$$

其中的次大元素 $n-1$ ，最终位置在初始位置的右侧，在上述过程中却向左侧移动一个单元。

c) 某元素的初始位置与其最终位置相邻，甚至已经处于最终位置，却需要参与 $n-1$ 次交换；

【解答】

当 n 为偶数时，考查序列：

$$\{ n/2 + 2, n/2 + 3, \dots, n, \boxed{n/2 + 1}, 1, 2, \dots, n/2 \}$$

其中元素 $n/2 + 1$ 只需右移一个单元，即是最终位置。但按照起泡排序算法，在前 $n/2 - 1$ 轮扫描交换中，它都左移一个单元。在此后的第 $n/2$ 轮扫描交换中，它连续地右移 $n/2$ 个单元，方抵达最终位置。整个过程累计参与 $n-1$ 次交换。

当 n 为奇数时，考查序列：

$$\{ (n+1)/2 + 1, (n+1)/2 + 2, \dots, n, \boxed{(n+1)/2}, 1, 2, \dots, (n-1)/2 \}$$

其中元素 $(n+1)/2$ 已经处于最终位置。但按照起泡排序算法，在前 $(n-1)/2$ 轮扫描交换中，它都左移一个单元。在此后的第 $n/2$ 轮扫描交换中，它连续地右移 $(n-1)/2$ 个单元，方抵达最终位置。整个过程累计参与 $n-1$ 次交换。

d) 所有元素都需要参与 $n-1$ 次交换。

【解答】

仔细观察以上实例不难看出：对于序列中的任何一个元素，只要更小（大）的元素均处于其右（左）侧，则该元素或早或晚必然与其余元素各交换一次，累计 $n-1$ 次。也就是说，这类元素与其余的每个元素均构成一个逆序对（inversion）——参见习题[3-11]。

实际上，若所有元素均具有这种特性，则必为完全逆序的序列，比如：

$$\{ n, n-1, \dots, 2, 1 \}$$

其中共包含 $n(n-1)/2$ 个逆序对。

[1-4] 对 n 个整数的排序，能否保证在最坏情况下仍可在少于 $O(n)$ 的时间内完成？为什么？

【解答】

不能。这一结论，可以从几个方面来理解。

首先，为确定 n 个整数的排列次序，至少需要对每个元素访问一次。否则，即便其余 $n - 1$ 个整数业已排序，在未读取该整数的准确数值之前，仍无法确定整体的排列次序。

其次，同一组整数的输入次序可能不同，其中必有一种是完全错位的，即没有任何一个元素是就位的。此种情况下，每个整数都至少需要参与一次比较或者移动操作。

最后，即便排序结果已知，在输出的过程中每个整数也必须花费常数的时间。在后面的第2.7节，将就此问题给出并证明一个更强的结论。

[1-5] 随着问题输入规模的不断扩大，同一算法所需的计算时间通常都呈单调递增趋势，但情况亦并非总是如此。试举实例说明，随着输入规模的扩大，同一算法所需的计算时间可能上下波动。

【解答】

例如，对任意整数 $n \geq 2$ 做素因子分解的一种蛮力算法是，反复地从2到 n 递增地逐一尝试。采用这一算法，对于不同的输入 n ，所需的时间 $T(n)$ 如下表所示。

n	2	3	4	5	6	7	8	...
$T(n)$	1	2	2	4	3	6	3	...

n	47	48	49	50	51	52	53	...
$T(n)$	46	6	12	9	18	14	52	...

n	62	63	64	65	66	67	68	...
$T(n)$	31	10	6	16	13	66	18	...

实际上，任意素数 n 都对应于该算法的最坏情况，即：

$$T(n) = n - 1 = O(n)$$

而任意形如 $n = 2^k$ 的整数都对应于最好情况，即：

$$T(n) = k = O(\log n)$$

因此，该算法的运行时间将在这两种极端情况之间，呈波动形式上下起伏。

[1-6] 在一台速度为 1G flops 的电脑上使用教材中代码 1.1 中的 bubblesort1A() 算法，大致需要多长时间才能完成对全国人口记录的排序？

【解答】

输入规模按 $n = 10^9$ （十亿人口）计，计算量为 $n^2 = 10^{18}$ 。

该电脑的计算能力按 10^9 计，则大致需要 $10^{18} / 10^9 = 10^9$ 秒 = 30年。

根据数据结构和算法的渐进复杂度，凭借在实际计算环境中积累的经验，针对计算过程主要部分进行的此类粗略估算，也称作封底估算（back-of-the-envelope calculation），意指只需在废信封背面寥寥数行即可完成的估算。

好的封底估算不仅简便易行，而且可以大体上对数据结构和算法的实际性能做出较为准确的比较和判断。这种对总体计算效率的把握能力，也是优秀程序员必备的一项基本素质。

[1-7] 试用 C++语言描述一个包含循环、分支、子函数调用，甚至递归结构的算法，要求具有常数的总体时间复杂度。

【解答】

一个综合多种情况的实例，如代码x1.3所示。

这个名为O1()的函数虽然设有一个循环，但无论其输入参数n有多大，循环控制变量i总是以 $1 + n/2013$ 为步长，从0逐次递增至n。因此迭代步数大致为 $2013 = O(1)$ 。

该函数还设有一个转向标志UNREACHABLE，但转向条件“ $1 + 1 \neq 2$ ”永远无法满足，故这个转向分支实质上形同虚设。

以下，是经过条件判断之后对某个子函数doSomething()的“调用”。然而，这里的转向条件“ $n * n < 0$ ”依然属于逻辑上的永非式，因此相应的调用绝不可能发生。

```

1 void O1(unsigned int n) {
2     for (unsigned int i = 0; i < n; i += 1 + n/2013) { //循环：但迭代至多2013次，与n无关
3 UNREACHABLE: //无法抵达的转向标志
4         if (1 + 1 != 2) goto UNREACHABLE; //分支：条件永非，转向无效
5         if (n * n < 0) doSomething(n); //分支：条件永非，调用无效
6         if ((n + i) * (n + i) < 4 * n * i) doSomething(n); //分支：条件永非，调用无效
7         if (2 == (n * n) % 5) O1(n + 1); //分支：条件永非，递归无效
8         int f = fib(n); if ((12 < n) && (sqrt(f) * sqrt(f) == f)) O1(n - 1); //分支：条件永非
9     }
10 }
```

代码x1.3 包含循环、分支、子函数调用甚至递归结构，但具有常数时间复杂度的算法

目前某些高级的编译器，已经能够识别前一类完全由常数定义的永非式，并在编译过程中作相应的自动优化。然而不幸的是，对于由变量参与定义的这种（以及更为复杂的）逻辑条件，编译器尚不能有效地判别和优化。

例如，接下来经过条件判断“ $(n + i) * (n + i) < 4 * n * i$ ”之后对子函数doSomething()的“调用”，也绝对不可能被执行。实际上，作为关于不等式的基本常识我们知道，非负整数的算术平均不可能小于其几何平均。

又如，再接下来经过条件判断“ $2 == (n * n) \% 5$ ”之后的“递归调用”，也绝对不可能被执行。实际上，由基本的数论知识不难验证，任意整数的平方关于5整除之后的余数，断乎不可能是2（或3）。

最后，经过条件判断“ $(12 < n) \&\& (sqrt(f) * sqrt(f) == f)$ ”之后的“递归调用”，依然绝对不可能被执行——实际上在Fibonacci数中，只有fib(0)、fib(1)、fib(2)、fib(12)是平方数，fib(n > 12)必然都不是。

不难理解，相对于前两种情况，后三种无效的分支语句几乎无法有效地辨别。由以上可见，对于程序时间复杂度的估算，不能完全停留和依赖于其外在的流程结构；更为准确而精细的分析，必然需要以对其内在功能语义的充分理解为基础。

[1-8] 试证明, 在用对数函数界定渐进复杂度时, 常底数的具体取值无所谓。

【解答】

设某函数的上界可表示为 $f(n) = O(\log_a n)$, 其中 $a > 1$ 为常数。

则对任一常数 $b > 1$, 因 $\ln b / \ln a$ 为常数, 故根据大 O 记号的性质有:

$$f(n) = O(\log_a n) = O((\ln b / \ln a) \log_b n) = O(\log_b n)$$

由此可见, 无论更换为任一常数底, 只会影响到常系数。

[1-9] 试证明, 对于任何 $\varepsilon > 0$, 都有 $\log n = O(n^\varepsilon)$ 。

【解答】

我们知道, 函数 $\ln n$ 增长得极慢, 故总存在 $M > 0$, 使得 $n > M$ 之后总有 $\ln n < \varepsilon n$ 。

令 $N = e^M$, 则当 $n > N$ (即 $\ln n > M$) 之后, 总有: $\ln(\ln n) < \varepsilon \ln n$, 亦即: $\ln n < n^\varepsilon$ 。

实际上从另一角度来看, 既然 $n^{1-\varepsilon/2} \cdot \ln n$ 是凹函数 (concave function, 导数递减), $n^{1+\varepsilon/2}$ 是凸函数 (convex function, 导数递增), 则也不难得出以上结论。

[1-10] 试证明, 在大 O 记号的意义上

a) 等差级数之和与其中最大一项的平方同阶;

【解答】

考查首项为常数 x 、公差为常数 $d > 0$ 、长度为 n 的等差级数:

$$\{ x, x + d, x + 2d, \dots, x + (n - 1)d \}$$

其中末项 $(n - 1)d = \Theta(n)$, 各项总和为:

$$(d/2)n^2 + (x - d/2)n = \Theta(n^2)。$$

b) 等比级数之和与其中最大一项同阶。

【解答】

考查首项为常数 x 、公比为常数 $d > 1$ 、长度为 n 的等比级数:

$$\{ x, xd, xd^2, \dots, xd^{n-1} \}$$

其中末项 $xd^{n-1} = \Theta(d^n)$, 各项总和为:

$$x(d^n - 1)/(d - 1) = \Theta(d^n)$$

[1-11] 若 $f(n) = O(n^2)$ 且 $g(n) = O(n)$, 则以下结论是否正确:

a) $f(n) + g(n) = O(n^2)$;

【解答】

正确。根据大 O 记号的性质, 多项式中的低次项可以忽略。

b) $f(n) / g(n) = O(n)$;

【解答】

错误。

比如, 对于 $f(n) = n \log n = O(n^2)$ 和 $g(n) = 1 = O(n)$, 有 $f(n)/g(n) = n \log n \neq O(n)$ 。

c) $g(n) = O(f(n));$

【解答】

错误。

比如，对于 $f(n) = \log n = O(n^2)$ 和 $g(n) = n = O(n)$ ，有 $g(n) \neq O(f(n))$ 。

d) $f(n) * g(n) = O(n^3)$

【解答】

正确。

由大O记号定义，存在常数 $c_1 > 0$ 和 $N_1 > 0$ ，使得当 $n > N_1$ 后总有 $f(n) < c_1 n^2$ 。

同理，存在常数 $c_2 > 0$ 和 $N_2 > 0$ ，使得当 $n > N_2$ 后总有 $g(n) < c_2 n$ 。

于是，若令 $c = c_1 c_2$ ， $N = \max(N_1, N_2)$ ，则当 $n > N$ 后，总有：

$$f(n)*g(n) < c n^3 = O(n^3)$$

[1-12] 改进教材 13 页代码 1.2 中 countOnes() 算法，使得时间复杂度降至

a) $O(\text{countOnes}(n))$ ，线性正比于数位 1 的实际数目；

【解答】

如代码x1.4所示，这里通过位运算的技巧，自低（右）向高（左）逐个地将数位1转置为0。

```

1 int countOnes1(unsigned int n) { //统计整数n的二进制展开中数位1的总数：O(ones)正比于数位1的总数
2     int ones = 0; //计数器复位
3     while (0 < n) { //在n缩减至0之前，反复地
4         ones++; //计数（至少有一位为1）
5         n &= n - 1; //清除当前最靠右的1
6     }
7     return ones; //返回计数
8 } //等效于glibc的内置函数int __builtin_popcount (unsigned int n)

```

代码x1.4 countOnes() 算法的改进版

对于任意整数 n ，不妨设其最低（右）的数位1对应于 2^k ，于是 n 的二进制展开应该如下：

x x ... x 1 0 0 ... 0

其中数位 x 可能是0或1，而最低的 $k + 1$ 位必然是 "1 0 0 ... 0"，即数位1之后是 k 个0。

于是相应地， $n - 1$ 的二进制展开应该如下：

x x ... x 0 1 1 ... 1

也就是说，其最低的 $k + 1$ 位与 n 恰好相反，其余的（更高）各位相同。

因此，二者做位与运算 $(n \& (n - 1))$ 的结果应为：

x x ... x 0 0 0 ... 0

等效于将原 n 二进制展开中的最低位1转置为0。

以上计算过程，仅涉及整数的减法和位与运算各一次。若不考虑机器的位长限制，两种运算均可视作基本运算，各自只需 $O(1)$ 时间。因此，新算法的运行时间，应线性正比于 n 的二进制展开中数位1的实际数目。

b) $O(\log_2 W)$, $W = O(\log_2 n)$ 为整数的位宽。

【解答】

一种可行的实现方式，如代码x1.5所示。

```

1 #define POW(c) (1 << (c)) //2^c
2 #define MASK(c) (((unsigned long) -1) / (POW(POW(c)) + 1)) //以2^c位为单位分组，相间地全0和全1
3 // MASK(0) = 55555555(h) = 01010101010101010101010101010101(b)
4 // MASK(1) = 33333333(h) = 00110011001100110011001100110011(b)
5 // MASK(2) = 0f0f0f0f(h) = 00001111000011110000111100001111(b)
6 // MASK(3) = 00ff00ff(h) = 00000000111111110000000011111111(b)
7 // MASK(4) = 0000ffff(h) = 00000000000000001111111111111111(b)
8
9 //输入：n的二进制展开中，以2^c位为单位分组，各组数值已经分别等于原先这2^c位中1的数目
10 #define ROUND(n, c) (((n) & MASK(c)) + ((n) >> POW(c) & MASK(c))) //运算优先级：先右移，再位与
11 //过程：以2^c位为单位分组，相邻的组两两捉对累加，累加值用原2^(c + 1)位就地记录
12 //输出：n的二进制展开中，以2^(c + 1)位为单位分组，各组数值已经分别等于原先这2^(c + 1)位中1的数目
13
14 int countOnes2(unsigned int n) { //统计整数n的二进制展开中数位1的总数
15     n = ROUND(n, 0); //以02位为单位分组，各组内前01位与后01位累加，得到原先这02位中1的数目
16     n = ROUND(n, 1); //以04位为单位分组，各组内前02位与后02位累加，得到原先这04位中1的数目
17     n = ROUND(n, 2); //以08位为单位分组，各组内前04位与后04位累加，得到原先这08位中1的数目
18     n = ROUND(n, 3); //以16位为单位分组，各组内前08位与后08位累加，得到原先这16位中1的数目
19     n = ROUND(n, 4); //以32位为单位分组，各组内前16位与后16位累加，得到原先这32位中1的数目
20     return n; //返回统计结果
21 } //32位字长时，O(log_2(32)) = O(5) = O(1)

```

代码x1.5 countOnes()算法的再改进版

这里运用了多种二进制位运算的技巧，其数学原理及计算过程，请读者参照所附的注解，细心理解、体会和记忆。

可见，若计算模型支持的整数字长为 W ，则对于任意整数 $n \in [0, 2^W)$ ，都可在：

$$T(n) = O(\log_2 W) = O(\log W) = O(\log \log n)$$

时间内统计出 n 所含比特1的总数。

通常， $O(\log \log n)$ 可以视作常数。比如，就人类目前所能感知的整个宇宙范围而言，所有基本粒子的总数约为：

$$N = 10^{81} = 2^{270}$$

即便如此之大的 N ，也不过：

$$\log \log N = \log 270 < 9$$

而在目前主流计算环境中，unsigned int类型的位宽多为 $W = 32$ ，有：

$$\log \log N = \log W = 5$$

[1-13] 实现教材 14 页代码 1.4 中 power2BF_I() 算法的递归版, 要求时间复杂度保持为 $O(n) = O(2^r)$ 。

【解答】

一种可行的实现方式, 如代码x1.6所示。

```
1 __int64 power2BF(int n) { //幂函数2^n算法(蛮力递归版), n >= 0
2     return (n > 0) ? 1 : power2BF(n - 1) << 1; //递归
3 } //O(n) = O(2^r), r为输入指数n的比特位数
```

代码x1.6 power2BF_I() 算法的递归版

与原先的迭代版相比, 该版本的原理完全一致, 只不过计算方向恰好颠倒过来:

- 为计算出 2^n , 首先通过递归计算出 $2^{(n - 1)}$, 然后通过左移返回值加倍
- 经向下递归深入 n 层并抵达递归基 $\text{power2BF}(0)$ 之后, 再逆向地逐层返回
- 每返回一层, 都执行一次加倍

就空间复杂度而言, 该版本无形中提高至 $O(n)$ 。相对于原就地的迭代版, 反而有所倒退。

[1-14] 实现教材 21 页代码 1.8 中 power2() 算法的迭代版, 要求时间复杂度保持为 $O(\log n) = O(r)$ 。

【解答】

一种可行的实现方式, 如代码x1.7所示。

```
1 __int64 power2_I(int n) { //幂函数2^n算法(优化迭代版), n >= 0
2     __int64 pow = 1; //O(1): 累积器初始化为2^0
3     __int64 p = 2; //O(1): 累乘项初始化为2
4     while (n < n) { //O(logn): 迭代log(n)轮, 每轮都
5         if (n & 1) //O(1): 根据当前比特位是否为1, 决定是否
6             pow *= p; //O(1): 将当前累乘项计入累积器
7         n >>= 1; //O(1): 指数减半
8         p *= p; //O(1): 累乘项自乘
9     }
10    return pow; //O(1): 返回累积器
11 } //O(logn) = O(r), r为输入指数n的比特位数
```

代码x1.7 power2() 算法的迭代版

与原先的递归版相比, 该版本的原理完全一致, 只不过计算方向却恰好颠倒过来: 由低到高, 依次检查 n 二进制展开中的各比特, 在该比特为 1 时累乘以累乘项 p 。

这里的辅助变量 p , 应始终等于各比特所对应的指数权重, 亦即:

$$2^1, \quad 2^2, \quad 2^4, \quad 2^8, \quad 2^{16}, \quad \dots$$

因此, 其初始值应置为:

$$2^1 = 2$$

而此后每经过一步迭代(并进而转向更高一位), p 都会通过自平方完成更新。

不难看出, 这个版本仅需 $O(1)$ 的辅助空间, 故就空间复杂度而言, 较之原递归的版本有了很大改进。

以上算法不难推广至一般的情况。比如，对于任意的整数 a 和 n ，计算 a^n 的一个通用算法，可实现如代码x1.8所示。

```

1 __int64 power(__int64 a, int n) { //a^n算法: n >= 0
2     __int64 pow = 1; //O(1)
3     __int64 p = a; //O(1)
4     while (0 < n) { //O(logn)
5         if (n & 1) //O(1)
6             pow *= p; //O(1)
7         n >>= 1; //O(1)
8         p *= p; //O(1)
9     }
10    return pow; //O(1)
11 } //power()

```

代码x1.8 通用的迭代版幂函数算法

请读者参照注释，对该算法的时间复杂度做一分析。

[1-15] 考查最大元素问题：从 n 个整数中找出最大者。

- a) 试分别采用迭代和递归两种模式设计算法，在线性时间内解决该问题；
- b) 用 C++ 语言实现你的算法，并分析它们的复杂度。

【解答】

该问题迭代版算法一种可行的实现方式，如代码x1.9所示。

```

1 int maxI(int A[], int n) { //求数组最大值算法(迭代版)
2     int m = INT_MIN; //初始化最大值纪录, O(1)
3     for (int i = 0; i < n; i++) //对全部共O(n)个元素, 逐一
4         m = max(m, A[i]); //比较并更新, O(1)
5     return m; //返回最大值, O(1)
6 } //O(1) + O(n) * O(1) + O(1) = O(n + 2) = O(n)

```

代码x1.9 数组最大值算法(迭代版)

该问题线性递归版算法一种可行的实现方式，如代码x1.10所示。

```

1 int maxR(int A[], int n) { //数组求最大值算法(线性递归版)
2     if (2 > n) //平凡情况, 递归基
3         return A[n - 1]; //直接(非递归式)计算
4     else //一般情况
5         return max(maxR(A, n - 1), A[n - 1]); //递归: 在前n - 1项中的最大值与第n - 1项之间, 取大者
6 } //O(1) * 递归深度 = O(1) * (n + 1) = O(n)

```

代码x1.10 数组最大值算法(线性递归版)

该问题二分递归版算法一种可行的实现方式，如代码x1.11所示。

```

1 int maxR(int A[], int lo, int hi) { //计算数组区间A[lo, hi)的最大值 (二分递归)
2     if (lo + 1 == hi) //如遇递归基 (区间长度已降至1), 则
3         return A[lo]; //直接返回该元素
4     else { //否则 (一般情况下lo + 1 < hi), 则
5         int mi = (lo + hi) >> 1; //以中位单元为界, 将原区间一分为二: A[lo, mi)和A[mi, hi)
6         return max(maxR(A, lo, mi), maxR(A, mi, hi)); //递归地计算子区间的最大值, 再从中取大者
7     }
8 } //O(hi - lo), 线性正比于区间的长度

```

代码x1.11 数组最大值算法 (二分递归版)

以上诸版本时间复杂度的分析结论，请参见所附注释。

就空间复杂度而言，迭代版为 $O(1)$ ，已属于就地算法。递归版的所需的量均取决于最大的递归深度，对二分递归而言为 $O(\log n)$ ，对线性递归而言为 $O(n)$ 。

[1-16] 考查如下问题：设 S 为一组共 n 个正整数，其总和为 $2m$ ，判断是否可将 S 划分为两个不相交的子集，且各自总和均为 m ？美国总统选举即是该问题的一个具体实例：

若有两位候选人参选，并争夺 $n = 51$ 个选举人团（50 个州和 1 个特区）的共计 $2m = 538$ 张选举人票，是否可能因两人恰好各得 $m = 269$ 张，而不得不重新选举？

a) 试设计并实现一个对应的算法，并分析其时间复杂度；

【解答】

采用蛮力策略，逐一枚举 S 的每一子集，并统计其中元素的总和。一旦发现某个子集的元素总和恰为 m ，即成功返回。若直至枚举完毕均未发现此类子集，即失败返回。

b) 若没有其它（诸如限定整数取值范围等）附加条件，该问题可否在多项式时间内求解？

【解答】

此问题已被证明是NP完全的（NP-complete）。这意味着，就目前的计算模型而言，不存在可在多项式时间内回答此问题的算法。反过来，上述基于直觉的蛮力算法已属最优。

[1-17] 试证明，若每个递归实例仅需使用常数规模的空间，则递归算法所需的空间总量将线性正比于最大的递归深度。

【解答】

根据递归跟踪分析法，在递归程序的执行过程中，系统必须动态地记录所有活跃的递归实例。在任何时刻，这些活跃的递归实例都可按照调用关系，构成一个调用链，该程序执行期间所需的量，主要用于维护上述调用链。不难看出，按照题目所给的条件，这部分空间量应线性正比于调用链的最大长度，亦即最大的递归深度。

在教材的4.2.1节，还将针对递归实现机制——函数调用栈——做详细的介绍。届时，我们将了解上述过程更多的具体细节。简而言之，以上所定义的调用链，实际上就对应于该栈中的所

有帧。在任何时刻，其中每一对相邻的帧，都对应于存在“调用与被调用”关系的一对递归实例。若各递归实例所需空间均为常数量，则空间占用量与栈内所含帧数成正比，并在递归达到最深层时达到最大。

总而言之由上可见，递归算法所需的空间总量，并不直接取决于计算过程中出现过的递归实例总数，与总体消耗的计算时间也没有必然的关系。

[1-18] 试采用递推方程法，分析教材 17 页代码 1.5 中线性递归版 sum() 算法的空间复杂度。

【解答】

设采用该算法对长度为 n 的数组统计总和，所需空间量为 $S(n)$ ，于是可得递推方程如下：

$$S(1) = O(1)$$

$$S(n) = S(n - 1) + O(1)$$

两式联合求解即得：

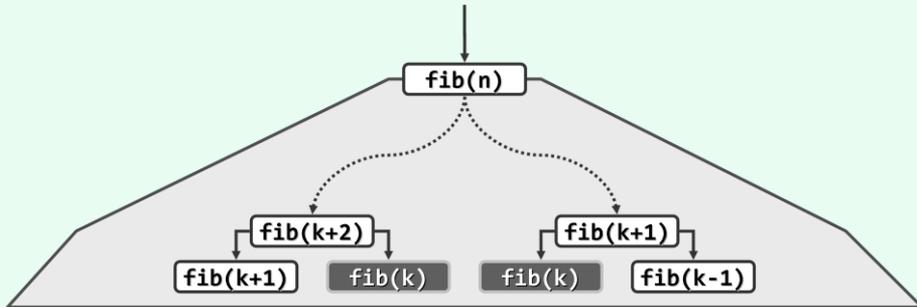
$$S(n) = O(n)$$

[1-19] 考查如教材 24 页代码 1.12 所示的二分递归版 fib(n) 算法，试证明：

- a) 对任一整数 $1 \leq k \leq n$ ，形如 $\text{fib}(k)$ 的递归实例，在算法执行过程中都会先后重复出现 $\text{fib}(n - k + 1)$ 次；

【解答】

在该算法的递归跟踪图中，每向下递归深入一层，入口参数就减一（向左）或减二（向右）。在从入口 $\text{fib}(n)$ 通往每一 $\text{fib}(k)$ 递归实例的沿途，各递归实例的入口参数只能依次减一或减二。因此， $\text{fib}(k)$ 出现的次数，应该等于从 n 开始，经每次减一或减二，最终减至 k 的路径总数。



图x1.3 fib() 算法中递归实例 $\text{fib}(k)$ 的两种出现可能

考查这些路径的最后一步，如图x1.3所示无非两种可能：或由 $\text{fib}(k + 1)$ 向左抵达 $\text{fib}(k)$ ，或由 $\text{fib}(k + 2)$ 向右抵达 $\text{fib}(k)$ 。因此，若将 $\text{fib}(k)$ 出现的次数记作 $F(k)$ ，则可得递推式如下：

$$F(n) = 1$$

$$F(k) = F(k + 1) + F(k + 2)$$

两式联合求解，即得：

$$F(k) = \text{fib}(n - k + 1)$$

b) 该算法的时间复杂度为指数量级；**【解答】**

该算法每个递归实例自身仅消耗常数时间，故总体运行时间应线性正比于递归实例的总数：

$$\begin{aligned} \sum_{k=0}^n F(k) &= \sum_{k=0}^n \text{fib}(n - k + 1) \\ &= \sum_{k=1}^{n+1} \text{fib}(k) = \text{fib}(n + 3) - 1 = o(\Phi^n) \end{aligned}$$

其中， $\Phi = (1 + \sqrt{5})/2 = 1.618$ 。

为便捷而准确地估计此类算法的时间和空间复杂度，我们不妨记住以下关于 Φ 的近似估计：

$$\begin{aligned} \Phi^5 &\approx 10, & \Phi^{67} &\approx 10^{14} \\ \Phi^3 &\approx 2^2, & \Phi^{36} &\approx 2^{25} \end{aligned}$$

就以这里的二分递归版 $\text{fib}(n)$ 算法为例。如读者编译并运行该算法，就会发现在其计算至第45项之后，即可感觉到明显的（秒量级以上的）延迟。

其实，只要注意到目前常见的CPU主频大致在 $1\text{G Hz} = 10^9 \text{ Hz}$ 量级，而且由以上近似经验值可估算出 $\Phi^{45} \approx 10^9$ ，即不难解释和理解上述现象。

c) 该算法的最大递归深度为 $o(n)$ ；**【解答】**

在该算法运行过程中的任一时刻，（在函数调用栈内）活跃的递归实例所对应的入口参数，必然从 n （栈底）到 $k \geq 0$ （栈顶）严格单调地递减。因此，活跃实例的总数不可能多于 n 个。

d) 该算法具有线性的空间复杂度。**【解答】**

既然最大的递归深度不超过 n ，故由习题[1-18]的结论，该算法所需的空间亦不超过 $o(n)$ 。

[1-20] 考查 Fibonacci 数的计算。**a) 试证明，任意算法哪怕只是直接打印输出 $\text{fib}(n)$ ，也至少需要 $\Omega(n)$ 的时间；**

（提示：无论以任何常数为进制， $\text{fib}(n)$ 均由 $\Theta(n)$ 个数位组成）

【解答】

从渐进角度看， $\text{fib}(n) = \Theta(\Phi^n)$ 。因此采用任何常数进制展开， $\text{fib}(n)$ 均由 $\Theta(n)$ 个数位组成。这就意味着，即便已知 $\text{fib}(n)$ 的数值大小，将该数值逐位打印出来也至少需要 $\Theta(n)$ 时间。

b) 试参考教材 21 页代码 1.8 中 $\text{power2}()$ 算法设计一个算法，在 $o(\log n)$ 时间内计算出 $\text{fib}(n)$ ；**【解答】**

根据Fibonacci数的定义，可得如下矩阵形式的递推关系：

$$\begin{pmatrix} 0 & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} \text{fib}(k-1) \\ \text{fib}(k) \end{pmatrix} = \begin{pmatrix} \text{fib}(k) \\ \text{fib}(k+1) \end{pmatrix}$$

由此，可进一步得到如下通项公式：

$$\begin{pmatrix} \text{fib}(n) \\ \text{fib}(n+1) \end{pmatrix} = \begin{pmatrix} 0 & 1 \\ 1 & 1 \end{pmatrix}^n \begin{pmatrix} \text{fib}(0) \\ \text{fib}(1) \end{pmatrix} = \begin{pmatrix} 0 & 1 \\ 1 & 1 \end{pmatrix}^n \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

于是，若套用power2()算法的流程，只要将其中的整数平方运算sqr()换成矩阵的平方运算，即可实现fib(n)的计算。更重要的是，这里仅涉及2×2矩阵的计算，每次同样只需常数时间，故整体的运行时间也是 $\mathcal{O}(\log n)$ 。

c) 以上结论是否矛盾？为什么？

【解答】

以上结论在表面上的确构成悖论。究其根源在于，以上对power2()与fib()等算法的时间复杂度分析都假定，整数的乘法、位移和打印等基本操作各自只需 $\mathcal{O}(1)$ 时间——即采用所谓的常数代价准则（uniform cost criterion）——而这只是在一定程度上的近似。

设参与运算的整数（的数值）为k。不难看出，上述基本操作都需要逐个地读取k的二进制展开的每一有效比特位，故更为精确地，这些操作的时间成本应该线性正比于k的有效位的总数 $\mathcal{O}(\log k)$ ——即采用所谓的对数代价准则（logarithmic cost criterion）。

当k不是很大时，两种准则之间的差异并不是不大；而当k很大甚至远远超出机器字长之后，二者之间的差异将不容忽略。仍以Fibonacci数为例。因 $\text{fib}(n) = \Theta(\Phi^n)$ ，故该数列应以 Φ 为比率呈指数递增，各项的二进制展开长度 $\log_2(\Phi^n)$ 则以匀速呈线性递增。根据习题[1-19]所给的估算经验，相邻项约相差 $\log_2 \Phi = 0.694$ 个比特，大致每隔36项相差25个比特。也就是说，自fib(48)后便会导出32位无符号整数的溢出，自fib(94)后便会导出64位无符号整数的溢出。

[1-21] 考查 fib()算法的二分递归版、线性递归版和迭代版。

a) 分别编译这些算法，针对 $n = 64$ 实际运行并测试对比；

b) 三者的运行速度有何差别？为什么？

【解答】

请读者通过实际动手，独立完成实测和对比任务，并根据测试结果给出结论。

需要特别留意的是，根据上述分析，中途很快即会发生字长溢出的现象。另外，若采用时间复杂度为 $\mathcal{O}(\Phi^n)$ 的二分递归版，在计算出fib(64)之前我们大致需要等待：

$$\begin{aligned} \Phi^{64} / 10^9 &= \Phi^{67-3} / 10^9 = (10^{14}/4) / 10^9 \\ &= 10^5 / 4 \text{ 秒} = 1/4 \text{ 天} = 6 \text{ 小时} \end{aligned}$$

而多少令我们惊讶的是，若计算的目标是fib(92)，则需要等待

$$\begin{aligned} \Phi^{92} / 10^9 &= \Phi^{67+25} / 10^9 = 10^{14+5} / 10^9 \\ &= 10^{10} \text{ 秒} = 3 \text{ 世纪} \end{aligned}$$

但愿我们都能如此长寿！不过，即便不考虑电脑老化或故障等因素，在经过一个世纪之后，或许你倒是可以甚至应该更换一台更快速的新型电脑——当然，那台“电脑”未必仍然需要电能驱动，届时我们也将不再会因计算的中途停电而懊恼沮丧了。

[1-22] 参照教材 26 页代码 1.14 中迭代版 fibI() 算法，实现支持如下接口的 Fib 类。

```
1 class Fib { //Fibonacci数列类
2 public:
3     Fib(int n); //初始化为不小于n的最小Fibonacci项 (如, Fib(6) = 8), O(log $\Phi$ (n))时间
4     int get(); //获取当前Fibonacci项 (如, 若当前为8, 则返回8), O(1)时间
5     int next(); //转至下一Fibonacci项 (如, 若当前为8, 则转至13), O(1)时间
6     int prev(); //转至上一Fibonacci项 (如, 若当前为8, 则转至5), O(1)时间
7 };
```

【解答】

Fib类一种可行的实现方式，如代码x1.12所示。

```
1 class Fib { //Fibonacci数列类
2 private:
3     int f, g; //f = fib(k - 1), g = fib(k)。均为int型, 很快就会数值溢出
4 public:
5     Fib(int n) //初始化为不小于n的最小Fibonacci项
6     { f = 1; g = 0; while (g < n) next(); } //fib(-1), fib(0), O(log $\Phi$ (n))时间
7     int get() { return g; } //获取当前Fibonacci项, O(1)时间
8     int next() { g += f; f = g - f; return g; } //转至下一Fibonacci项, O(1)时间
9     int prev() { f = g - f; g -= f; return g; } //转至上一Fibonacci项, O(1)时间
10 };
```

代码x1.12 Fib类的实现

套用教材1.4.5节介绍的动态规划 (dynamic programming) 策略，这里也设置了两个内部的私有成员变量f和g，始终分别记录当前的一对相邻Fibonacci数，在构造函数中，它们分别被初始化为：

$$\begin{aligned} f &= \text{fib}(-1) = 1 \\ g &= \text{fib}(0) = 0 \end{aligned}$$

为定位至不小于n的最小项，以下反复调用next()接口依次递增地遍历，直至首次达到或者超过n。因n与Fibonacci数的第 $\log_{\Phi}(n)$ 项渐进地同阶，故整个遍历过程不超过 $O(\log_{\Phi}(n))$ 步。

next()接口对f和g的更新方式，与教材26页代码1.14完全一致：经过滚动式的叠加，使之继续指向下一对相邻的Fibonacci项。

取前一项的方法亦与此相似，只不过方向颠倒而已。

[1-23] 法国数学家 Edouard Lucas 于 1883 提出的 Hanoi 塔问题，可形象地描述如下：

有 n 个中心带孔的圆盘贯穿在直立于地面的一根柱子上，各圆盘的半径自底而上不断缩小；需要利用另一根柱子将它们转运至第三根柱子，但在整个转运的过程中，游离于这些柱子之外的圆盘不得超过一个，且每根柱子上的圆盘半径都须保持上小下大。

试将上述转运过程描述为递归形式，并进而实现一个递归算法。

【解答】

将三根柱子分别记作X、Y和Z，则整个转运过程可递归描述为：

为将X上的 n 只盘子借助Y转运至Z，只需（递归地）
 将X上的 $n - 1$ 只盘子借助Z转运至Y
 再将X上最后一只盘子直接转移到Z
 最后再将Y上的 $n - 1$ 只盘子借助X转运至Z

按照这一理解，即可如代码x1.13所示实现对应的递归算法。

```

1 // 按照Hanoi规则，将柱子Sx上的n只盘子，借助柱子Sy中转，移到柱子Sz上
2 void hanoi(int n, Stack<Disk>& Sx, Stack<Disk>& Sy, Stack<Disk>& Sz) {
3     if (n > 0) { //没有盘子剩余时，不再递归
4         hanoi(n - 1, Sx, Sz, Sy); //递归：将Sx上的n - 1只盘子，借助Sz中转，移到Sy上
5         move(Sx, Sz); //直接：将Sx上最后一只盘子，移到Sz上
6         hanoi(n - 1, Sy, Sx, Sz); //递归：将Sy上的n - 1只盘子，借助Sx中转，移到Sz上
7     }
8 }
```

代码x1.13 Hanoi塔算法

关于时间复杂度，该算法对应的边界条件和递推式为：

$$T(1) = O(1)$$

$$T(n) = 2 \cdot T(n - 1) + O(1)$$

若令：

$$S(n) = T(n) + O(1)$$

则有：

$$S(1) = O(2)$$

$$S(n) = 2 \cdot S(n - 1)$$

$$= 2^2 \cdot S(n - 2)$$

$$= 2^3 \cdot S(n - 3)$$

$$= \dots$$

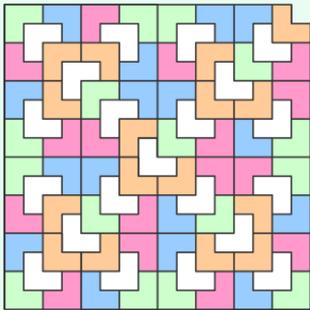
$$= 2^{n-1} \cdot S(1)$$

$$= 2^n$$

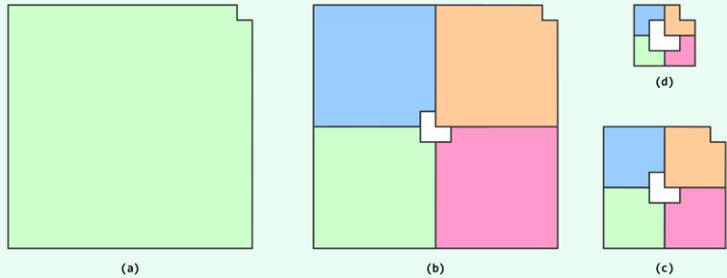
故有：

$$T(n) = O(2^n)$$

[1-24] 如图 x1.4 所示, 考查缺失右上角 (面积为 $4^n - 1$) 的 $2^n \times 2^n$ 棋盘, $n \geq 1$ 。



图x1.4 使用85块L形积木, 可以恰好覆盖缺失一角的16×16棋盘



图x1.5 采用分治策略, 将大棋盘的覆盖问题转化为四个小棋盘的覆盖问题

a) 试证明, 使用由三个 1×1 正方形构成、面积为 3 的 L 形积木, 可以恰好覆盖此类棋盘;

【解答】

将 n 称作此类棋盘的阶次, 并对 n 做数学归纳。作为归纳基, $n = 1$ 时显然。

故假设阶次低于 n 的此类棋盘都可被 L 形积木覆盖, 考查如图 x1.5(a) 所示的 n 阶棋盘。先将一块 L 形积木摆放至棋盘中心处, 缺口方向与棋盘缺口一致。

于是如图(b)所示, 棋盘的剩余部分可以划分为四个 $n - 1$ 阶的棋盘。由归纳假设, 它们均可被 L 形积木覆盖, 故原 n 阶棋盘亦是如此。

b) 试给出一个算法, 对于任意 $n \geq 1$, 给出覆盖方案;

【解答】

参照以上归纳证明的思路, 即可得出构造覆盖方案的如下递归算法。

```

1 // 覆盖基准点在(x, y)的n ≥ 1阶棋盘
2 // 四种缺口方向, 由(dx, dy)指定: (+1, +1)东北、(+1, -1)东南、(-1, +1)西北、(-1, -1)西南
3 // 算法的起始调用入口为cover(n, 0, 0, 1, 1): 基准点在(0, 0)、缺口朝向东北的n阶棋盘
4 void cover(int n, int x, int y, int dx, int dy) {
5     int s = 1 << (n-1); //子棋盘的边长: 2^(n-1)
6     place(x + dx * (s - 1), y + dy * (s - 1), dx, dy); //首先用一块L形积木覆盖中心
7     if (1 < n) { //只要棋盘仍未完全覆盖, 则继续递归地覆盖四个子棋盘
8         cover(n - 1, x, y, dx, dy); //递归: 覆盖西南方子棋盘
9         cover(n - 1, x + dx * s, y + dy * s, dx, dy); //递归: 覆盖东北方子棋盘
10        cover(n - 1, x + dx * (2*s - 1), y, -dx, dy); //递归: 覆盖东南方子棋盘
11        cover(n - 1, x, y + dy * (2*s - 1), dx, -dy); //递归: 覆盖西北方子棋盘
12    }
13 }

```

算法x1.2 缺角棋盘的覆盖算法

有兴趣的读者, 不妨尝试实现与该递归算法对应的迭代版本。

c) 该算法的时间复杂度是多少?

【解答】

以上算法的每一递归实例本身只需常数时间，根据算法流程可得如下递推式：

$$T(1) = O(1)$$

$$T(n) = 4 * T(n - 1) + O(1)$$

两式联合求解，即得：

$$T(n) = O(4^n)$$

若以棋盘的边长 $N = 2^n$ （而非棋盘的阶次 n ）为依据，则有

$$T(N) = O(N^2)$$

若以棋盘的面积 $M = 4^n - 1$ 为依据，则有

$$T(M) = O(M)$$

也可从另一角度简便而精准地估计出本算法的时间复杂度。为此，需要注意到以下事实：

每个递归实例，都对应于覆盖方案中的某一块L形积木，反之亦然

这就意味着，递归实例的总数恰好等于所用L形积木的总数，后者恰为棋盘面积的三分之一，渐进地即是 $O(M)$ 。

[1-25] 《九章算术》记载的“中华更相减损术”可快速地计算正整数 a 和 b 的最大公约数，其过程如下：

```

1 令 p = 1
2 若 a 和 b 不都是偶数，则转 5)
3 令 p = p * 2, a = a / 2, b = b / 2
4 转 2)
5 令 t = |a - b|
6 若 t = 0，则返回并输出 a * p
7 若 t 为奇数，则转 10)
8 令 t = t / 2
9 转 7)
10 若 a ≥ b，则令 a = t；否则，令 b = t
11 转 5)

```

a) 按照上述流程，编写一个算法 `int gcd(int a, int b)`，计算 a 和 b 的最大公约数；

【解答】

运用“中华更相减损术”的最大公约数算法，可实现如代码 x1.14 所示。

```

1 __int64 gcdCN(__int64 a, __int64 b) { //assert: 0 < min(a, b)
2     int r = 0; //a和b的2^r形式的公因子
3     while (!(a & 1) || (b & 1)) { //若a和b都是偶数
4         a >>= 1; b >>= 1; r++; //则同时除2（右移），并累加至r
5     } //以下，a和b至多其一为偶

```

```

6   while (1) {
7       while (!(a & 1)) a >>= 1; //若a偶 ( b奇), 则剔除a的所有因子2
8       while (!(b & 1)) b >>= 1; //若b偶 ( a奇), 则剔除b的所有因子2
9       (a > b) ? a = a - b : b = b - a; //简化为: gcd(max(a, b) - min(a, b), min(a, b))
10      if (0 == a) return b << r; //简化至平凡情况: gcd(0, b) = b
11      if (0 == b) return a << r; //简化至平凡情况: gcd(a, 0) = a
12  }
13 }

```

代码x1.14 运用“中华更相减损术”的最大公约数算法

b) 与功能相同的欧几里得算法相比，这一算法有何优势？

【解答】

不妨将两个算法分别简称作“中”和“欧”。

首先可以证明，算法“中”的渐进时间复杂度依然是 $O(\log(a + b))$ 。

考查该算法的每一步迭代，紧接于两个内部while循环之后设置一个断点，观察此时的a和b。实际上，在a和b各自剔除了所有因子2之后，此时它们都将是奇数。接下来，无论二者大小如何，再经一次互减运算，它们必然将成为一奇一偶。比如，不失一般性地设 $a > b$ ，则得到：

$$\begin{array}{l} a - b \quad (\text{偶}) \\ b \quad \quad (\text{奇}) \end{array}$$

再经一步迭代并重新回到断点时，前者至多是：

$$(a - b)/2$$

两个变量之和至多是：

$$(a - b)/2 + b \leq (a + b)/2$$

可见，每经过一步迭代， $a + b$ 至少减少一半，故总体迭代步数不超过：

$$\log_2(a + b)$$

另外，尽管从计算流程来看，算法“中”的步骤似乎比算法“欧”更多，但前者仅涉及加减、位测试和移位（除2）运算，而不必做更复杂的乘除运算。因此，前者更适于在现代计算机上编程实现，而且实际的计算效率更高。

反之，无论是图灵机模型还是RAM模型^②，除法运算在底层都是通过减法实现的。因此，对于算法“欧”所谓的“除法加速”效果，不可过于乐观——而在输入整数大小悬殊时，尤其如此。

最后，较之算法“欧”，算法“中”更易于推广至多个整数的情况。

^② 关于这两种典型的计算模型的定义、性质及其关系，建议读者阅读文献[4]的第一章。

[1-26] 试设计并实现一个就地的算法 $\text{shift}(\text{int } A[], \text{int } n, \text{int } k)$ ，在 $O(n)$ 时间内将任一数组 $A[0, n)$ 中的元素整体循环左移 k 位。例如，数组 $A[] = \{ 1, 2, 3, 4, 5, 6 \}$ 经 $\text{shift}(A, 6, 2)$ 之后，有 $A[] = \{ 3, 4, 5, 6, 1, 2 \}$ 。（提示：利用教材 20 页代码 1.7 中 $\text{reverse}()$ 算法）

【解答】

一个可行的算法，如代码 x1.15 所示。

```

1 int shift2(int* A, int n, int k) { //借助倒置算法，将数组循环左移k位，O(3n)
2   k %= n; //确保k <= n
3   reverse(A, k); //将区间A[0, k)倒置：O(3k/2)次操作
4   reverse(A + k, n - k); //将区间A[k, n)倒置：O(3(n - k)/2)次操作
5   reverse(A, n); //倒置整个数组A[0, n)：O(3n/2)次操作
6   return 3 * n; //返回累计操作次数，以便与其它算法比较：3/2 * (k + (n - k) + n) = 3n
7 }

```

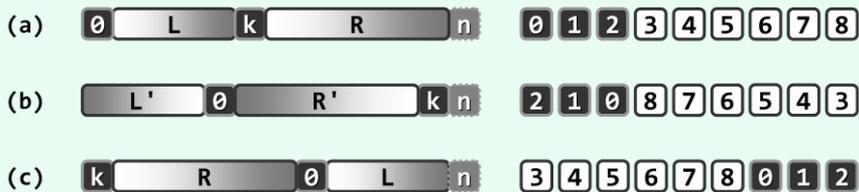
代码x1.15 借助reverse()算法在O(n)时间内就地移位

若在原向量 V 中前 k 个元素组成的前缀为 L ，剩余的（后缀）部分为 R ，则如图 x1.6 所示，经整体左移之后的向量应为：

$R + L$

这里约定，任意向量 V 整体倒置后的结果记作 V' 。于是该算法的原理来自如下恒等式：

$$R + L = (L' + R')'$$



图x1.6 借助reverse()算法在O(n)时间内就地移位的过程及原理

该算法的运行时间主要消耗于元素的互换操作。在整个三轮兑换中，每个元素至多参与两次互换操作。通常，每一对元素的互换需要 3 次移动操作，因此移动操作的累计次数不超过：

$$n \times 2 \times 3 / 2 = 3n$$

该算法的其它版本有可能只需更少的交换操作，故单就此指标而言，似乎更加“优于”以上版本。然而就实际的计算效率而言，以上版本却要远远优于其它版本。

究其原因在于， $\text{reverse}()$ 之类的操作所涉及的数据元素，在物理上是连续分布的，因此操作系统的缓存机制可以轻易地被激活，并充分发挥作用；其它版本的交换操作尽管可能更少，但数据元素在空间往往相距很远，甚至随机分布，缓存机制将几乎甚至完全失效。

在实际的算法设计与编程中，这些方面也是首先必须考虑的因素；在当下，面对规模日益膨胀的大数据，这方面的技巧对算法的实际性能更是举足轻重。在教材的 8.2 等节，我们还将结合 B-树等数据结构，就此深入讨论。

[1-27] 试实现一个递归算法，对任意非负整数 m 和 n ，计算以下 Ackermann 函数值：

$$\text{Ackermann}(m, n) = \begin{cases} n + 1 & (\text{若 } m = 0) \\ \text{Ackermann}(m - 1, 1) & (\text{若 } m > 0 \text{ 且 } n = 0) \\ \text{Ackermann}(m - 1, \text{Ackermann}(m, n - 1)) & (\text{若 } m > 0 \text{ 且 } n > 0) \end{cases}$$

对于每一 (m, n) 组合，这个算法是否必然终止？

【解答】

以上定义本身就是递归式的，故不难将其转换为一个递归算法。请读者独立完成这一任务。

在可计算性理论中，Ackermann 函数是典型的非原始递归的递归函数。尽管其定义和计算过程较为复杂，依然可以证明其计算过程必然终止，故对任何 (m, n) 参数组合均有明确的定义。以下，可以采用超限数学归纳法 (transfinite induction) 来证明上述论断。

为此，我们首先需要在所有非负整数的组合 (m, n) 之间，定义如下次序：

对于任何 (m_1, n_1) 与 (m_2, n_2) ，若 $m_1 < m_2$ ，或者 $m_1 = m_2$ 且 $n_1 < n_2$ ，则称前者小于后者，记作 $(m_1, n_1) < (m_2, n_2)$

实际上，所有的 (m, n) 组合与平面上第一象限内的整点一一对应。不难看出，任何两个整点都可按照这一定义比较大小，故这是一个全序。更重要地，该整点集的任何一个子集，都有最小元素——即该子集中的最左最低点 (leftmost-then-lowest point)。其中特别地，全集的最小元素即为坐标原点 $(0, 0)$ 。因此，如上定义的次序“ $<$ ”，的确是一个良序 (well order)。

由定义，任意形如 $(0, n)$ 的输入都会立即终止——这可作为归纳基础。

作为归纳假设，不妨假定：对于任意小于 (m, n) 的输入，Ackermann 函数均能终止。现考虑输入参数为 (m, n) 时，该函数的可终止性。

依然由定义可见，此时可能引发的递归实例无非三类：

Ackermann($m - 1, 1$)
Ackermann($m - 1, *$)
Ackermann($m, n - 1$)

可见，根据如上约定的次序，其对应的参数组合均小于 (m, n) 。故由归纳假设，以此参数组合对该函数的调用，亦必然会终止。

[1-28] 考查所谓咖啡罐游戏 (Coffee Can Game)：在咖啡罐中放有 n 颗黑豆与 m 颗白豆，每次取出两颗：若同色，则扔掉它们，然后放入一颗黑豆；若异色，则扔掉黑豆，放回白豆。

a) 试证明，该游戏必然终止 (当罐中仅剩一颗豆子时)；

【解答】

尽管游戏的每一步都有 (同色或异色) 两个分支，但不难验证：无论如何，每经过一次迭代，罐中豆子的总数 $(n + m)$ 必然减一。因此就总体而言，罐中豆子的数目必然不断地单调递减，直至最终因不足两颗而终止。

b) 对于哪些(n, m)的组合, 最后剩下的必是白豆?**【解答】**

类似地, 尽管这里有两个分支, 但无论如何迭代, 罐中白色豆子总数(m)的奇偶性始终保持不变。因此若最终仅剩一颗白豆, 则意味着白色豆子始终都是奇数颗。反之, 只要初始时白豆共计奇数颗, 则最终剩余的也必然是一颗白豆。

[1-29] 序列 Hailstone(n)是从 n 开始, 按照以下规则依次生成的一组自然数:

$$\text{Hailstone}(n) = \begin{cases} \{1\} & (\text{若 } n = 1) \\ \{n\} \cup \text{Hailstone}(n/2) & (\text{若 } n \text{ 为偶数}) \\ \{n\} \cup \text{Hailstone}(3n+1) & (\text{若 } n \text{ 为奇数}) \end{cases}$$

比如:

$\text{Hailstone}(7) = \{ 7, 22, 11, 34, 17, 52, 26, 13, 40, 20, 10, 5, 16, 8, 4, 2, 1 \}$

试编写一个非递归程序^①, 计算 Hailstone(n)的长度 hailstone(n)。

【解答】

由题中所给的定义, 可以直接导出该算法的递归实现。

该算法的一种可行的非递归实现方式, 则如代码x1.16所示。

```
1 template <typename T> struct Hailstone { //函数对象:按照Hailstone规则转化一个T类对象
2     virtual void operator()(T& e) { //假设T可直接做算术运算
3         int step = 0; //转换所需步数
4         while (1 != e) { //按奇、偶逐步转换,直至为1
5             (e % 2) ? e = 3 * e + 1 : e /= 2;
6             step++;
7         }
8         e = step; //返回转换所经步数
9     }
10 };
```

代码x1.16 计算Hailstone(n)序列长度的“算法”

正如教材中已经指出的, “序列Hailstone(n)长度必然有限”的结论至今尚未得到证明, 故以上程序未必总能终止, 因而仍不能称作是一个真正的算法。

[1-30] 在分析并界定其渐进复杂度时, 迭代式算法往往体现为级数求和的形式, 递归式算法则更多地体现为递推方程的形式。针对这两类主要的分析技巧, 参考文献[7]做了精辟的讲解和归纳。试研读其中的相关章节。

【解答】

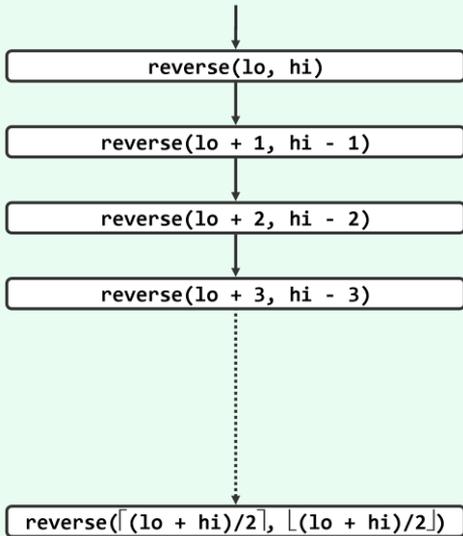
请读者独立完成研读任务, 并根据自己的理解进行归纳总结。

^① 据作者所知, “序列Hailstone(n)长度必然有限”的结论尚未得到证明, 故你编写的程序可能并非一个真正的算法

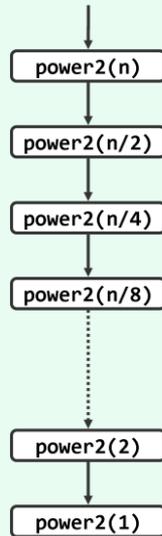
[1-31] 试针对教材 20 页代码 1.7 中的 `reverse()` 算法和 21 页代码 1.8 中的 `power2()` 算法，运用递归跟踪法分析其时间复杂度。

【解答】

`reverse()` 算法的递归跟踪过程，如图 x1.7 所示。



图x1.7 `reverse()` 算法的递归跟踪



图x1.8 `power2()` 算法的递归跟踪

从中可以清楚地看出，每递归深入一层，入口参数 `lo` 和 `hi` 之间的差距必然缩小 2，因此递归深度（亦即时间复杂度）为：

$$(hi - lo) / 2 = n/2 = o(n)$$

`power2()` 算法的递归跟踪过程，如图 x1.8 所示。

类似地也可看出，每递归深入一层，入口参数 `n` 即缩小一半，因此递归深度（亦即时间复杂度）应为：

$$\log_2 n = o(\log n)$$

若按教材中的定义，将参数 `n` 所对应二进制展开的宽度记作 $r = \log n$ ，则由图 x1.8 看出，每递归深入一层， r 都会减一，因此递归深度（亦即时间复杂度）应为：

$$o(r) = o(\log n)$$

这与上述分析殊途同归。

[1-32] 若假定机器字长无限，移位操作只需单位时间，递归不会溢出，且 `rand()` 为理想的随机数发生器。试分析以下函数 $F(n)$ ，并以大 o 记号的形式确定其渐进复杂度的紧上界。

```

1 void F(int n) {
    for (int i = 0; i < n; i++)
        for (int j = 0; j < n; j++);
}

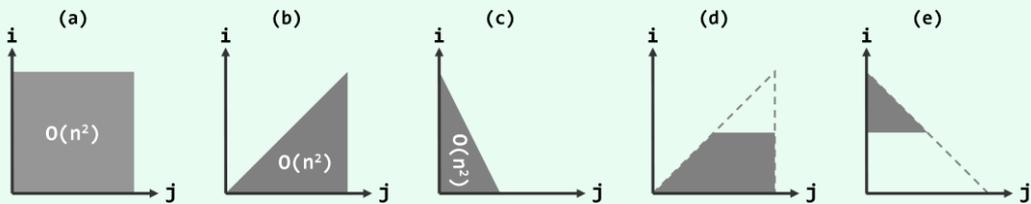
```

【解答】

这是最基本的二重循环模式，其特点是循环控制变量均按算术级数变化。内循环的每次迭代只需 $\mathcal{O}(1)$ 时间，故执行时间取决于总体的迭代次数。因外、内循环的范围分别是 $i \in [0, n)$ 和 $j \in [0, n)$ ，故累计迭代次数为：

$$\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} 1 = \sum_{i=0}^{n-1} n = n \times n = \mathcal{O}(n^2)$$

实际上在如图x1.9(a)所示的 (i, j) 坐标平面上，此二重循环的执行过程对应于匀速地自下而上、由左到右逐行扫过矩形 $[0, n) \times [0, n)$ 。因此，这一过程所需的时间也就对应于该矩形的面积，就渐进意义而言即是 $\mathcal{O}(n^2)$ 。



图x1.9 二重循环执行时间的对应图形

相对于以上严格的计算，基于这一图形式理解的估算不仅更加简捷，而且可以更好地体现通过大 \mathcal{O} 记号刻画渐进复杂度总体趋势的要义。而对于接下来更为复杂的情况，这种方法的上述优势则尤为突出。

```

2 void F(int n) {
    for (int i = 0; i < n; i++)
        for (int j = i; j < n; j++);
}

```

【解答】

这也是一种典型的二重循环模式，循环控制变量仍然按算术级数变化。与上例相比，外循环的范围依然是 $i \in [0, n)$ ，但内循环的范围则变成 $j \in [i, n)$ ，故累计迭代次数为：

$$\sum_{i=0}^{n-1} \sum_{j=i}^{n-1} 1 = \sum_{i=0}^{n-1} (n-i) = \sum_{(k=n-i)=1}^n k = n(n+1)/2 = \mathcal{O}(n^2)$$

也可套用以上基于图形的估算方法，在如图x1.9(b)所示的 (i, j) 坐标平面上，此二重循环的执行过程对应于匀速地自下而上、由左到右逐行扫过三角形 $[0, n) \times [i, n)$ 。该三角形的面积大致为原矩形的一半——就渐进意义而言，时间复杂度依然是 $\mathcal{O}(n^2)$ 。

```

3 void F(int n) {
    for (int i = 0; i < n; i++)
        for (int j = 0; j < i; j += 2013);
}

```

【解答】

这里，外循环的范围依然是 $i \in [0, n)$ ，但内循环控制变量 j 递增的步长改为 2013，对应的范围变成 $j * 2013 \in [0, i)$ 。

套用以上基于图形的估算方法，在如图 x1.9(c) 所示的 (i, j) 坐标平面上，此二重循环的执行过程对应于匀速地自下而上、由左到右逐行扫过一个三角形。该三角形的高仍保持为 n ，底边压缩了 2013 倍，故其面积大致为原矩形的 $1/2/2013 = 1/4026$ 倍——就渐进意义而言，时间复杂度依然是 $O(n^2)$ 。

```

4 void F(int n) {
    for (int i = 0; i < n/2; i++)
        for (int j = i; j < n; j++);
}

```

【解答】

这里，外循环和内循环的范围分别改为 $i \in [0, n/2)$ 和 $j \in [i, n)$ 。

依然沿用以上基于图形的估算方法，在如图 x1.9(d) 所示的 (i, j) 坐标平面上，此二重循环的执行过程对应于匀速地自下而上、由左到右逐行扫过一个梯形。该梯形的上底和下底分别长为 $n/2$ 和 n ，高度为 $n/2$ ，故其面积大致为原矩形的 $3/8$ 倍——就渐进意义而言，其时间复杂度依然是 $O(n^2)$ 。

```

5 void F(int n) {
    for (int i = n/2; i < n; i++)
        for (int j = 0; j < n - i; j++);
}

```

【解答】

这里，外循环的范围改为 $i \in [n/2, n)$ ，内循环的范围是 $j \in [0, i)$ 。

依然沿用以上基于图形的估算方法，在如图 x1.9(e) 所示的 (i, j) 坐标平面上，此二重循环的执行过程对应于匀速地自下而上、由左到右逐行扫过一个小三角形。该三角形的底和高均为 $n/2$ ，故其面积大致为原矩形的 $1/8$ 倍——就渐进意义而言，其时间复杂度依然是 $O(n^2)$ 。

```

6 void F(int n) {
    for (int i = 0; i < n; i++)
        for (int j = 1; j < n; j <= 1);
}

```

【解答】

请注意，在此二重循环模式中，尽管外循环的控制变量*i*仍在 $[0, n)$ 内按算术级数变化，但内循环的控制变量*j*在 $[1, n)$ 内却是按（以2为倍数的）几何级数变化，故累计迭代次数为：

$$\sum_{i=0}^{n-1} \sum_{(k=\log j)=0}^{\log n-1} 1 = \sum_{i=0}^{n-1} (\log n - 1) = n \log n - n = O(n \log n)$$

这里所采用的左移操作，不仅因为可以便捷地实现控制变量*j*的倍增，同时更为重要的是，这也为复杂度的快速估算提供了线索和依据。我们知道，任意正整数的二进制展开的宽度，与其数值呈对数关系。具体地，数值的加倍对应于其展开宽度加一，反之亦然。

从这一角度考查此处的内循环可见，随着*j*以2为倍数不断递增，*j*的二进制展开宽度将以1为步长不断递增。每一轮内循环的迭代次数既然等于*j*从1至*n*的倍增次数，也应该就是*n*的二进制展开宽度，即 $\log n$ 。因此，*n*轮内循环共计耗时 $O(n \log n)$ 。

```
7 void F(int n) {
    for (int i = 0; i < n; i++)
        for (int j = 1; j < 2013; j <<= 1);
}
```

【解答】

此处内循环的控制变量*j*尽管也是按几何级数递增，但其变化范围固定在 $[1, 2013)$ 内。因此每一轮内循环只做常数（ $\log 2013$ ）次的迭代。故总体时间复杂度仅取决于外循环，为 $O(n)$ 。

```
8 void F(int n) {
    for (int i = 1; i < n; i++)
        for (int j = 0; j < n; j += i);
}
```

【解答】

此处内循环的控制变量*j*尽管是在 $[0, n)$ 内按算术级数递增，但步长并不固定。具体地，第*i*轮内循环采用的步长即为*i*，故需做*n/i*次迭代。于是，所有循环的累计迭代次数为：

$$\sum_{i=1}^{n-1} \sum_{(k=\frac{j}{i})=0}^{\frac{n}{i}-1} 1 = \sum_{i=1}^{n-1} \frac{n}{i} = n \sum_{i=1}^{n-1} \frac{1}{i} = O(n \log n)$$

这里需要借助关于调和级数的以下性质：

$$\sum_{i=1}^n \frac{1}{i} = 1 + \frac{1}{2} + \frac{1}{3} + \cdots + \frac{1}{n} = \ln n + \gamma + O\left(\frac{1}{2n}\right)$$

其中， $\gamma \approx 0.577216$ 为欧拉常数。

```
9 void F(int n) { for (int i = 0, j = 0; i < n; i += j, j ++); }
```

【解答】

这里的变量*i*和*j*均从0开始不断递增，每经过一步迭代，*i*递增*j*，*j*递增1。

表x1.1 函数F(n)中变量*i*和*j*随迭代不断递增的过程

迭代次序 <i>t</i>	0	1	2	3	4	...
变量 <i>i</i>	0	0 + 0	0 + 0 + 1	0 + 0 + 1 + 2	0 + 0 + 1 + 2 + 3	...
变量 <i>j</i>	0	1	2	3	4	...

具体地，这一过程可以归纳如表x1.1所示。故经过*k*次迭代后，必有：

$$i = \sum_{t=0}^{k-1} t = k(k-1)/2$$

在循环退出之前，必有：

$$i = k(k-1)/2 < n, \text{ 或等价地, } k < \frac{1 + \sqrt{1 + 8n}}{2}$$

故该函数的时间复杂度为 $O(\sqrt{n})$ 。

```
10 void F(int n) { for (int i = 1, r = 1; i < n; i <= r, r <= 1); }
```

【解答】

这里的变量*i*和*r*均从1开始不断递增，每经过一步迭代，*i*递增为*i*·2^r，*r*递增为2·*r*。

表x1.2 函数F(n)中变量*i*和*r*随迭代不断递增的过程

迭代次序 <i>t</i>	0	1	2	3	4	...
变量 <i>i</i>	2 ⁰	2 ⁰⁺¹	2 ⁰⁺¹⁺²	2 ⁰⁺¹⁺²⁺⁴	2 ⁰⁺¹⁺²⁺⁴⁺⁸	...
变量 <i>r</i>	2 ⁰ = 1	2 ¹ = 2	2 ² = 4	2 ³ = 8	2 ⁴ = 16	...

具体地，这一过程可以归纳如表x1.2所示。故经过*k*次迭代后，必有

$$i = \prod_{t=0}^{k-1} 2^{2^t} = 2^{\sum_{t=0}^{k-1} 2^t} = 2^{(2^k-1)}$$

在循环退出之前，必有

$$i = 2^{(2^k-1)} < n$$

亦即

$$2^k - 1 < \log n$$

$$2^k \leq \log n$$

$$k \leq \log \log n$$

故该函数的时间复杂度为 $\mathcal{O}(\log \log n)$ 。

同样地，这里通过左移操作实现变量递增的方式，也为我们快捷地估算时间复杂度提供了新的视角和线索。从二进制展开的角度来看，变量 r 的展开宽度每次增加一位，而变量 i 则每次增加 r 位。也就是说，变量 i 的宽度将以（大致）加倍的指数速度膨胀，直至刚好超过 $\log n$ 。因此，总体的迭代次数应不超过 $\log n$ 的对数，亦即 $\mathcal{O}(\log \log n)$ 。

```
11 void F(int n) { for (int i = 1; i < n; i = 1 << i); }
```

【解答】

每经一次迭代， i 即增长至 2^i 。设经过 k 次迭代之后，因 $i \geq n$ 而退出迭代。

现颠倒原迭代的方向，其过程应等效于反复令 $n = \log_2 n$ ，并经 k 次迭代之后有 $n \leq 1$ 。由此可知，若对 n 反复取对数直至其不大于1，则 k 等于其间所做对数运算的次数，记作 $k = \log^* n$ ，读作“log-星-n”。

我们知道，指数函数增长的速度本来就很快，而按照 $i = 2^i$ 规律增长的速度更是极其地快。因此不难理解，作为反函数的 $T(n) = \mathcal{O}(\log^* n)$ 尽管依然是递增的，但增长的速度应极其地慢。

另一方面，既然此前习题[1-12]介绍的 $\mathcal{O}(\log \log n)$ 通常可以视作常数，则 $\mathcal{O}(\log^* n)$ 更应该可以。

不妨仍以人类目前所能感知的宇宙范围内，所有基本粒子的总数 $N = 10^{81} = 2^{270}$ 为例，不难验证有：

$$\log^* N < 5$$

```
12 int F(int n) { return (n > 0) ? G(G(n - 1)) : 0; }
   int G(int n) { return (n > 0) ? G(n - 1) + 2*n - 1 : 0; }
```

【解答】

首先，需要分析这两个函数的功能语义。不难验证， $G(n) = n^2$ 实现了整数的平方运算功能；相应地， $F(n) = ((n - 1)^2)^2 = (n - 1)^4$ 。

接下来为分析时间复杂度，这里及以下将 $F(n)$ 和 $G(n)$ 的时间复杂度分别记作 $f(n)$ 和 $g(n)$ 。

$G(n)$ 属于线性递归（linear recursion），其原理及计算过程实质上可以表示为：

$$n^2 = (2n - 1) + (2n - 3) + \dots + 5 + 3 + 1$$

也就是说，经递归 n 层计算前 n 个奇数的总和。因此，其运行时间为 $g(n) = \mathcal{O}(n)$ 。

请注意，这里的 $F()$ 并非递归函数，其本身只消耗 $\mathcal{O}(1)$ 时间。不过， $F(n)$ 会启动 $G()$ 的两次递归，入口参数分别为 $n - 1$ 和 $(n - 1)^2$ 。故综合而言，总体运行时间应为：

$$\begin{aligned} f(n) &= \mathcal{O}(1) + g(n - 1) + g((n - 1)^2) \\ &= \mathcal{O}(1) + \mathcal{O}(n - 1) + \mathcal{O}((n - 1)^2) \\ &= \mathcal{O}(n^2) \end{aligned}$$

需要强调的是，既然 $G((n - 1)^2)$ 的递归深度为 $(n - 1)^2$ ，故在实际运行时此类代码比较容易因递归过深而导致存储空间的溢出。

```
13 void F(int n) { for (int i = 1; i < n/G(i, 0); i ++); }
    int G(int n, int k) { return (n < 1) ? k : G(n - 2*k - 1, k + 1); }
```

【解答】

同样地，首先需要分析这两个函数的功能语义。不难验证， $G(n, 0) = \lceil \sqrt{n} \rceil$ 实现了整数的开方运算功能；相应地， $F(n)$ 只不过是以前一题的步长为1，令变量*i*从1递增到 $n/\lceil \sqrt{n} \rceil$ 。

$G(n)$ 属于线性递归（linear recursion），其原理实质上与前一题相同，只不过计算过程相反——从1开始，依次从*n*中扣除各个奇数，直至*n*不再是正数。因此与前一题同理，共需递归 $\lceil \sqrt{n} \rceil$ 层，其运行时间亦为：

$$g(n) = o(\lceil \sqrt{n} \rceil)$$

这里的 $F()$ 本身只是一个基本的迭代，递增的控制变量*i*初始值为1。在迭代终止时，应有：

$$i \geq n/\lceil \sqrt{i} \rceil$$

亦即：

$$i = \Theta(n^{2/3})$$

需要特别留意的是，函数 $F()$ 中的循环每做一步迭代，都需要调用一次 $G(i, 0)$ 以核对终止条件。故综合而言，总体运行时间应为：

$$\begin{aligned} f(n) &= o(\sqrt{1}) + o(\sqrt{2}) + o(\sqrt{3}) + \dots + o(\sqrt{n^{2/3}}) \\ &= o\left(\int_0^n \sqrt{x}\right) \\ &= o(n) \end{aligned}$$

即便计入 $f()$ 自身所需的 $o(n^{1/3})$ 时间，已不足以影响这一结论。

在以上分析的基础上稍加体会即不难理解，对于函数 $F()$ 而言，循环的终止条件实际上完全取决于输入参数*n*——迭代过程等效于变量*i*从1逐步递增至 $n^{1/3}$ 。故就此问题而言，为提高算法的整体效率，应该直接估算出 $n^{1/3}$ ，然后将其作为越界点。为此，只需改写函数 $G(n)$ 并使之返回 $G(n) = n^{1/3}$ ，即可使得 $F()$ 仅需调用一次 $G()$ 。

实际上只要实现得法，具有以上新的操作语义的函数 $G(n)$ 只需运行 $o(n^{1/3})$ 时间。请读者根据提示，独立完成此项任务。

```
14 int F(int n) { return (n > 0) ? G(2, F(n - 1)) : 1; }
    int G(int n, int m) { return (m > 0) ? n + G(n, m - 1) : 0; }
```

【解答】

同样地，首先需要分析这两个函数的功能语义。不难验证有：

$$G(n, m) = n * m, \text{ 实现了整数的乘法运算功能}$$

$$F(n) = 2^n, \text{ 实现了2的整数次幂运算功能}$$

接下来，分析这两个函数的时间复杂度。

$G(n, m)$ 的计算过程，实质上就是将*n*累加*m*次，故其运行时间为：

$$g(n, m) = o(m)$$


```
15 int F(int n) { return (n > 3) ? F(n >> 1) + F(n >> 2) : n; }
```

【解答】

该 $F(n)$ 函数属于典型的二分递归，以下采用递推方程法，对其做一分析。

根据该函数的定义，可以得出如下边界条件和递推关系：

$$f(0) = f(1) = f(2) = f(3) = 1$$

$$f(4) = 3$$

$$f(n) = f(n/2) + f(n/4) + 1$$

若令

$$s(m) = f(2^m)$$

则以上方程可等价地转换为：

$$s(0) = 1$$

$$s(1) = 1$$

$$s(2) = 3$$

$$s(m) = s(m-1) + s(m-2) + 1$$

再令

$$t(m) = (s(m) + 1)/2$$

则可进一步转换为：

$$t(0) = 1$$

$$t(1) = 1$$

$$t(2) = 2$$

$$t(m) = t(m-1) + t(m-2)$$

与Fibonacci数列做一对比，即可知有：

$$t(m) = \text{fib}(m+1) = \mathcal{O}(\Phi^m)$$

其中， $\Phi = (1 + \sqrt{5})/2 = 1.618$

于是有：

$$f(n) = 2 \cdot t(\log n) - 1$$

$$= 2 \cdot \mathcal{O}(\Phi^{\log n}) - 1$$

$$= \mathcal{O}(\Phi^{\log n})$$

$$= \mathcal{O}(n^{\log \Phi})$$

$$= \mathcal{O}(n^{0.694})$$

饶有趣味的是，尽管该函数的形式属于二分递归，但经以上分析可见，其计算过程中出现的递归实例却远不足 $\mathcal{O}(n)$ 个，其复杂度亦远低于线性。

从分治策略的角度看，该算法模式意味着，每个规模为 n 的问题，均可在 $\mathcal{O}(1)$ 时间内分解为规模分别为 $n/2$ 和 $n/4$ 的两个子问题。实际上其复杂度之所以仅为 $\mathcal{O}(n^a)$ ，关键在于两个子问题的规模总和 $(3n/4)$ 已经严格地小于原问题的规模 (n) 。

```

16 void F(int n) {
    for (int i = n; 0 < i; i --)
        if (!(rand() % i))
            for (int j = 0; j < n; j ++);
}

```

【解答】

这是一种典型的随机算法（**randomized algorithm**）模式，其中通过随机数`rand()`决定程序执行的去向，因此通常需要从概率期望的角度来界定其运行时间。

以下不妨基于随机均匀分布的假定条件（即`rand()`在整数范围内取任意值的概率均等），来分析该程序的平均运行时间。

这里的外循环共迭代 n 步。在每一步中，只有当随机数`rand()`整除外循环的控制变量 i 时，方可执行内循环。内循环的长度与变量 i 无关，共执行 n 步。若内循环执行，则其对总体时间复杂度的贡献即为 n ；否则，贡献为 0 。

既然假定属于均匀随机分布，故`rand()`能够整除变量 i 的概率应为 $1/i$ 。这就意味着，与每个变量 i 相对应的内循环被执行的概率为：

$$1/i$$

反过来，内循环不予执行的概率即为：

$$(i - 1)/i$$

故就概率期望的角度而言，对应于变量 i 的内循环平均迭代 n/i 步。

于是根据期望值的线性律（**linearity of expectation**），整个程序执行过程中内循环迭代步数的期望值，应该等于在每一步外循环中内循环迭代步数期望值的总和，亦即：

$$\begin{aligned}
 f(n) &= (1/n + 1/(n - 1) + \dots + 1/3 + 1/2 + 1) \times n \\
 &= \text{expected-}\mathcal{O}(n \log n)
 \end{aligned}$$

这里同样需要借助关于调和级数的以下性质：

$$\sum_{i=1}^n \frac{1}{i} = 1 + \frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{n} = \ln n + \gamma + \Theta\left(\frac{1}{2n}\right)$$

其中， $\gamma \approx 0.577216$ 为欧拉常数。

即便再计入 n 步外循环本身所需的 $\mathcal{O}(n)$ 时间，总体的渐进复杂度亦是如此。

第2章

向量

[2-1] 关于某个算法，甲证明“其平均时间复杂度为 $O(n)$ ”，乙证明“其分摊时间复杂度为 $O(n)$ ”。若他们的结论均正确无误，则是甲的结论蕴含乙的结论，乙的结论蕴含甲的结论，还是互不蕴含？

【解答】

两个结论之间不存在蕴含关系，但相对而言，后一结论更为可靠和可信。

所谓平均复杂度，是指在假定各种输入实例的出现符合某种概率分布之后，进而估算出的加权复杂度均值。比如在教材的第12.1.5节中，将基于“待排序的元素服从独立均匀随机分布”这一假设，估算出快速排序算法在各种情况下的加权平均复杂度。

所谓分摊复杂度，则是纵观连续的足够多次操作，并将其间总体所需的运行时间分摊至各次操作。与平均复杂度的本质不同在于，这里强调，操作序列必须是的确能够真实发生的，其中各次操作之间应存在前后连贯的时序关系。比如在参考文献[41]中，Tarjan采用势能分析法对伸展树所有可能的插入、删除操作序列进行分析，并估算出在此意义下单次操作的分摊执行时间。

由此可见，前者不必考查加权平均的各种情况出现的次序，甚至其针对概率分布所做的假设未必符合真实情况；后者不再割裂同一算法或数据结构的各次操作之间的因果关系，更加关注其整体的性能。综合而言，基于后一尺度得出的分析结论，应该更符合于真实情况，也更为可信。

以教材2.4节中基于容量加倍策略的可扩充向量为例。若采用平均分析，则很可能因为所做的概率分布假定与实际不符，而导致不准确的结论。比如若采用通常的均匀分布假设，认为扩容与不扩容事件的概率各半，则会得出该策略效率极低的错误结论。实际上，只要假定这两类事件出现的概率各为常数，就必然导致这种误判。而实际情况是，采用加倍扩容策略后，在其生命期内随着该数据结构的容量不断增加，扩容事件出现的概率将以几何级数的速度迅速趋近于零。对于此类算法和数据结构，唯有借助分摊分析，方能对其性能做出综合的客观评价。

[2-2] 教材 32 页代码 2.2 的 `copyFrom()` 算法中，目标数组 `_elem[]` 是通过 `new` 操作由系统另行分配的，故可保证在物理上与来源数组 `A[]` 相互独立。若不能保证这种独立性，该算法需要做哪些调整？

【解答】

若不能保证目标数组与来源数组之间的独立性，则二者可能在空间上有所重叠，出现所谓的“搭接”现象。此时，需要区分两种情况分别处理。若目标数组的某一后缀与来源数组的某一前缀重叠搭接，则需要按“从前到后”的次序逐一转移各元素；反之，若目标数组的某一前缀与来源数组的某一后缀重叠搭接，则应改用“从后到前”的次序。

[2-3] 假设将教材 34 页代码 2.4 中 `expand()` 算法的扩容策略改为“每次追加固定数目的单元”。

a) 试证明，在最坏情况下，单次操作中消耗于扩容的分摊时间为 $\Theta(n)$ ，其中 n 为向量规模；

【解答】

假定每次追加 d 个单元。于是，只要每隔固定的常数 k 次操作就发生一次扩容，则初始容量为 n_0 的向量在经过连续的 $N \gg k$ 次操作之后，容量将增加至：

$$n = n_0 + d \cdot (N/k)$$

在此过程中，消耗于扩容操作的时间合计为：

$$\begin{aligned} T(N) &= (n_0 + d) + (n_0 + 2d) + (n_0 + 3d) + \dots + (n_0 + d \cdot (N/k)) \\ &= n_0 \cdot (N/k) + d \cdot (N/k)(N/k - 1) \end{aligned}$$

均摊至单次操作，所需时间为：

$$\begin{aligned} T(N)/N &= n_0/k + (d/k)(N/k - 1) \\ &= [n_0 + d \cdot (N/k)]/k - d/k \\ &= n/k - d/k \\ &= \Theta(n) \end{aligned}$$

b) 试举例说明，这种最坏情况的确可能发生。

【解答】

考查初始为空 ($n_0 = 0$) 的向量，假定持续地对其执行插入操作。于是，每经过 d 次操作，都需要花费线性时间进行扩容。于是就分摊意义而言，单次操作需花费 $\Theta(n)$ 时间用于扩容。

[2-4] 试证明，教材 36 页代码 2.5 中 shrink() 算法具有分摊的常数时间复杂度。

【解答】

与教材 2.4.4 节对 expand() 算法的分析方法完全一致。

[2-5] 设某算法中设有一个无符号 32 位整型变量 $count = b_{31}b_{30}\dots b_1b_0$ ，其功能是作为计数器，不断地递增 ($count++$ ，溢出后循环)。每经一次递增， $count$ 的某些比特位都会在 0 和 1 之间翻转。

比如，若当前有： $count = 43_{(10)} = 0\dots 0101011_{(2)}$

则下次递增之后将有： $count = 44_{(10)} = 0\dots 0101100_{(2)}$

在此过程中，共有 (最末尾的) 三个比特发生翻转。

现在，考查对 c 连续的足够多次递增操作。纵观这一系列的操作，试证明：

a) 每经过 2^k 次递增， b_k 恰好翻转一次；

【解答】

每经过 2^k 次递增，计数器的数值恰好增加 2^k 。体现在其二进制展开中，对应于数位 b_k 的 (由 0 到 1 或由 1 到 0) 翻转。

b) 对于每次递增操作，就分摊的意义而言， $count$ 只有 $\mathcal{O}(1)$ 个比特位发生翻转。

【解答】

不妨从 0 开始，考查该计数器的连续 $N \gg 2$ 次递增操作。我们将在此期间的所有数位翻转，分别“记账”至对应的数位。于是根据以上 a) 所证的性质，所有数位的翻转次数总和为：

$$\begin{aligned} &N/2^{31} + N/2^{30} + \dots + N/4 + N/2 + N \\ &= N \cdot (1/2^{31} + 1/2^{30} + \dots + 1/4 + 1/2 + 1) \\ &< 2N \end{aligned}$$

因此就分摊意义而言，单次递增操作仅引发 $\mathcal{O}(1)$ 次数位翻转。

与基于加倍策略的可扩充向量同理，这里的关键在于参与累计的各项构成（以1/2为倍数的）几何级数，正如我们已知的，就渐进意义而言其总和同阶于其中的最大项。因此无论这里的计数器有多少个二进制数位组成，上述性质与结论均可成立。实际上，即便假设计数器拥有无穷个数位（故永不溢出），亦是如此。

[2-6] 考查教材 37 页代码 2.7 中的 permute() 算法，假设 rand() 为理想的随机数发生器，试证明：

a) 通过反复调用 permute() 算法，可以生成向量 $V[0, n]$ 的所有 $n!$ 种排列；

【解答】

可以通过对向量规模 n 的数学归纳予以证明。假定该命题对于规模不足 n 的任意向量均成立。作为归纳的基础，规模 $n = 1$ 的情况不证自明。以下考查规模为 n 的任意向量 $V[]$ ：

$$V[0], V[1], V[2], \dots, V[n - 1]$$

任取该向量的一个排列：

$$V[a_0], V[a_1], V[a_2], \dots, V[a_{n-1}]$$

只需证明，该排列有可能被 permute() 算法生成。

实际上，在该算法的第一次迭代中，有可能取 $\text{rand}() \% n = a_{n-1}$ 。于是，首次参与交换的将是 $V[n - 1]$ 和 $V[\text{rand}() \% i] = V[a_{n-1}]$ ，且如此交换之后的向量成为：

$$V[0], V[1], \dots, V[a_{n-1} - 1], V[n - 1], V[a_{n-1} + 1], \dots, V[n - 2], V[a_{n-1}]$$

不难看出，自此之后的计算过程完全等效于，对于其中前 $n - 1$ 个元素组成的子向量置乱。也就是说，可等效于将向量：

$$V[0], V[1], \dots, V[a_{n-1} - 1], V[n - 1], V[a_{n-1} + 1], \dots, V[n - 2]$$

置乱为：

$$V[a_0], V[a_1], V[a_2], \dots, V[a_{n-2}]$$

由归纳假设，permute() 算法可以生成长度为 $n - 1$ 的该排列（以及长度为 n 的整个排列）。

b) 由该算法生成的排列中，各元素处于任一位置的概率均为 $1/n$ ；

【解答】

可以按照各元素在 permute() 算法中（自后向前）就位的次序，归纳证明这一命题。

首先，鉴于 rand() 的随机均匀性，最早就位的元素 $V[a_{n-1}]$ 必以相等的概率选自整个向量，故原向量中每个元素最终出现在该位置的概率为 $1/n$ 。

不妨假定该命题对前 k 个 ($0 \leq k < n$) 就位的元素均成立，即它们均是以 $1/n$ 的等概率取自原向量中各元素。以下，考查下一个就位的元素 $X = V[a_{n-k-1}]$ 。

如图 x2.1 所示，按照算法流程，元素 X 应随机地选自当时的前 $n - k$ 个元素（包含其自身），且其中各元素被选中的概率均为 $1/(n - k)$ 。

请注意，当时的这前 $n - k$ 个元素均有可能参与过此前的 k 次随机交换。这些元素都是截至当前尚未就位者，原向量中的任何一个元素，都有 $(n - k)/n$ 的概率成为它们中的一员。因此，原向量中每个元素接下来被随机选中且随即交换成为 $V[a_{n-1}]$ 的概率应是：

$$(n - k)/n \times 1/(n - k) = 1/n$$



图x2.1 permute()算法中第k + 1个就位元素，应等概率地随机选自当时的前n - k个元素

c) 该算法生成各排列的概率均为 $1/n!$ 。

【解答】

既然以上已经证明，原向量中各元素最终就位于各位置的概率均等，permute()算法就应以相等的概率，随机地生成所有可能的排列。

对于规模为n的向量，可能的排列共计n!种，故概率分别为 $1/n!$ 。

[2-7] 在C语言标准库中，Brian W. Kernighan和Dennis M. Ritchie设计的随机数发生器如下：

```

unsigned long int next = 1;

/* rand: return pseudo-random integer on 0..32767 */
int rand(void)
{
    next = next * 1103515245 + 12345;
    return (unsigned int)(next/65536) % 32768;
}

/* srand: set seed for rand() */
void srand(unsigned int seed)
{
    next = seed;
}

```

a) 阅读这段代码，并理解其原理；

【解答】

该算法维护一个32位的无符号长整数next，随着next的“随意”变化，不断输出伪随机数。通过srand(seed)，可以设置next的初始值（随机种子）。

此后rand()的每一次执行过程，均如图x2.2所示。



图x2.2 Brian W. Kernighan和Dennis M. Ritchie所设计随机数发生器的原理

首先，在next当前值的基础上乘以 $1103515245 = 3^5 \times 5 \times 7 \times 129749$ ，并加上12345。然后，通过整除运算在该长整数的二进制展开中截取高16位，进而通过模余运算抹除最高比特位。经如此的“混沌化”处理之后，即可作为“随机数”返回。

- b) 试说明, 若采用 rand() 的这个版本实现 permute() 算法, 则上题的结论 a) 和 b) 并不能兑现;**
(提示: 绝大多数的排列实际上根本无法由该算法生成)

【解答】

不难注意到, 以上rand()算法的返回值尽管具有一定的随机性, 但远非理想的随机。实际上更严格地讲, 其返回值是确定的: 只要知道当前的next值, 即可确定地得出下一next值。

反观如教材37页代码2.7所示的permute算法, 其对每一个向量的置乱结果, 应完全取决于其间对rand()函数 $n = V.size()$ 次调用所返回的 n 个“随机数”。但使用如上实现的rand(), 这些返回值完全取决于所设定的起始种子seed。

permute()算法如需兑现上题中结论a)和b)所述的性质, 本应保证能够(通过rand())获得 n 个彼此独立的随机数。然而不幸的是, 由以上分析可见这一条件并不成立。

实际上我们甚至可以确定, 如此可能获得的长度为 n 的“随机数”序列有多少个——其总数不超过seed的取值范围, 就此例而言即为:

$$2^{16} = 65,536 < 9! = 362,880$$

这就意味着, 即便是长度 $n = 9$ 的向量, 借助该版本的rand()也无法枚举出所有可能的置乱排列; 而对于更长的向量, 这个算法就更是无能为力了。

- c) 试说明, 采用此类伪随机数发生器实现 permute() 算法, 上题的结论 a) 和 b) 必然无法兑现;**

【解答】

由以上分析可知, 只要继续沿用这种“种子 + 迭代”的模式, 增加rand()输出整数的位宽亦是徒然——这种“改进”并不能有效地克服上述缺陷。比如, 不难验证有:

$$2^{64} = 2^{60+4} < 20 \times 10^{18} < 21! = 51,090,942,171,709,440,000$$

也就是说, 即便使用64位的无符号整数, 在向量的规模超过20之后, 借助这种模式的随机数发生器就无法覆盖所有可能的置乱排列。进一步地, 随着向量规模 n 的进一步扩大, 如此可枚举出来的排列, 在所有 $n!$ 种排列中所占的比例将迅速下降, 并很快趋近于零。

- d) 针对 b) 和 c) 所指出的不足, 应如何改进 rand() 和 permute() 算法?**

【解答】

以上所介绍基于“种子 + 迭代”模式的随机数发生器, 在permute()之类的算法中之所以显得力不从心, 关键在于它们无法保证所生成随机数之间的独立性(independence)。反过来, 这也给我们指出了改进的大方向。

当然, 要在独立性与高效性之间达到足够令人满意的平衡绝非易事, 有待于我们的持续探索。

[2-8] 考查教材 39 页代码 2.10 中的无序向量查找算法 find(e, lo, hi)。

- a) 在最好情况下, 该算法需要运行多少时间? 为什么?**

【解答】

若首次接受比对的元素(即向量区间的末元素`_elem[hi - 1]`)恰好就是目标元素, 则算法可以随即因查找成功而终止。这自然地属于最好情况——此种情况下, 累计仅需常数时间。

b) 若仅考查成功的查找, 则平均需要运行多少时间? 为什么?**【解答】**

这种顺序式的查找算法, 可能成功地终止于向量区间内的任意位置。此外, 各元素对应的查找长度, 自后向前构成一个递增的等差数列:

$$1, 2, 3, \dots, n = h_i - l_o$$

于是若按照默认惯例, 假定所有元素作为目标元素的概率均等, 则其查找长度的均值(数学期望)应渐进地与其中的最高项同阶, 为 $O(n)$ 。详细(但嫌复杂)的分析, 亦是殊途同归:

$$(1 + 2 + 3 + \dots + n)/n = (n + 1)/2 = O(n)$$

[2-9] 考查教材 40 页代码 2.11 中的无序向量插入算法 insert(r, e)。

试证明, 若插入位置 r 等概率分布, 则该算法的平均时间复杂度为 $O(n)$, n 为向量的规模。

【解答】

这里, 运行时间主要来自于后继元素顺次后移的操作。因此对于每个插入位置而言, 对应的移动操作次数恰好等于其后继元素(包含自身)的数目。不难看出它们也构成一个等差数列, 故在等概率的假设条件下, 其均值(数学期望)应渐进地与其中的最高项同阶, 为 $O(n)$ 。

详细(但嫌复杂)的分析, 亦是殊途同归。

[2-10] 考查教材 41 页代码 2.12 中的无序向量删除算法 remove(lo, hi)。**a) 若以自后向前的次序逐个前移后继元素, 可能出现什么问题?****【解答】**

位置靠前的元素, 可能被位置靠后(优先移动)的元素覆盖, 从而造成数据的丢失。

b) 何时出现这类问题? 试举一例。(提示: 后继元素多于待删除元素时, 部分单元会相互覆盖)**【解答】**

如图x2.3(a)所示, 考查规模为5的向量:

$$V[0, 5) = \{ 0, 1, 2, 3, 4 \}$$

假设我们试图通过调用`V.remove(0, 2)`以删除其中的前两个元素。若采用题中所述不当的次序, 则数据元素的移动过程应如该图(b~d)所示。可见, 原数据元素 $V[2] = 2$ 并未顺利转移至输出向量中的 $V[0]$, 即出现数据的丢失现象。



图x2.3 无序向量删除算法remove(lo, hi)中, 采用自后向前的次序移动可能造成数据丢失

不难验证, 只要按照教材的建议颠倒移动的次序, 即可便捷地避免这类错误。

[2-11] Vector::deduplicate()算法的如下实现是否正确？为什么？

```

template <typename T> int Vector<T>::deduplicate() { //删除无序向量中重复元素（错误版）
    int oldSize = _size; //记录原规模
    for (Rank i = 1; i < _size; i++) { //逐一考查_elem[i]
        Rank j = find(_elem[i], 0, i); //在_elem[i]的前驱中寻找与之雷同者（至多一个）
        if (0 <= j) remove(j); //若存在，则删除之（但在此种情况，下一迭代不必做i++）
    }
    return oldSize - _size; //向量规模变化量，即被删除元素总数
}

```

【解答】

按照这一“算法”，若果真发现雷同的前驱`_elem[j]`，虽然的确可以剔除之，但由此产生的副作用是，秩为`i`的单元所对应的将不再是原先的`_elem[i]`（而是其直接后继`_elem[i + 1]`）。

这里即便假设，如教材代码2.14所实现的同名算法那样，仍能保证接受检查的每个`_elem[i]`至多只有一个雷同的前驱，但因如上所述的副作用，原`_elem[i + 1]`也将被跳过，从而导致遗漏与之雷同的元素。实际上，该“算法”每发现一次雷同，都有可能如此遗漏另一个雷同。

[2-12] 考查教材 42 页代码 2.14 中的无序向量唯一化算法 deduplicate()。

a) 试证明，即便在最好情况下，该算法也需要运行 $\Omega(n^2)$ 时间；

【解答】

该算法由 $\mathcal{O}(n)$ 次迭代构成，每次迭代都需要做一次查找操作，以及可能的一次删除操作。对于元素`_elem[k]`，若需做删除操作，则为此需花费 $\mathcal{O}(n - k)$ 时间移动所有的后继元素；反之，若不需要做删除操作，则意味着此前的查找操作以失败告终，其间已经花费了 $\mathcal{O}(k)$ 时间。总而言之，无论如何，各轮迭代至少需要 $\Omega(\min(n - k, k))$ 时间，累计 $\Omega(n^2)$ 。

b) 试参照教材 46 页代码 2.19 中有序向量唯一化算法 uniquify()的技巧，改进该算法，并分析其时间复杂度；

【解答】

比如，在发现重复元素后不必立即剔除，而是借助位图Bitmap结构（习题[2-34]）将其标注为“待删除”。待所有雷同元素均已筛选完毕，再经一趟遍历在 $\mathcal{O}(n)$ 时间内统一删除。

经如此改进之后，尽管渐进的时间复杂度依然为 $\mathcal{O}(n^2)$ ，但因为时间消耗主要来源于静态的查找操作，故实际的运行速度仍将大幅提高。

c) 试继续改进该算法，使其时间复杂度降至 $\mathcal{O}(n \log n)$ ；

【解答】

最为直接的方法，就是先调用`sort()`接口对向量做整体排序，然后调用`uniquify()`接口做唯一化处理。只要实现得当（比如采用教材所介绍的优化算法），这两步均只需 $\mathcal{O}(n \log n)$ 时间。

当然，由此将产生的一个副作用——保留下来的元素，未必延续此前的相对排列次序。实际上，完全可以在不增加渐进时间复杂度的前提下，消除这一副作用。请读者独立完成这一任务。

d) 这一效率是否还有改进的余地? 为什么?

【解答】

如果没有其它的附加条件,那么在图灵机等通常的计算模型下,可以证明“无序向量唯一化”问题的复杂度下界(难度)为 $\Omega(n \log n)$ 。为此,我们可以借助归约的技巧。

一般地,考查难度待界定的问题B。若另一问题A满足以下性质:

- 1) 问题A的任一输入,都可以在线性时间内转换为问题B的输入
- 2) 问题B的任一输出,都可以在线性时间内转换为问题A的输出

则称“问题A可在线性时间内归约为问题B”,或简称作“问题A可线性归约为问题B”,或者称“从问题A到问题B,存在一个线性(时间)归约(linear-time reduction)关系”,记作:

$$A \leq_N B$$

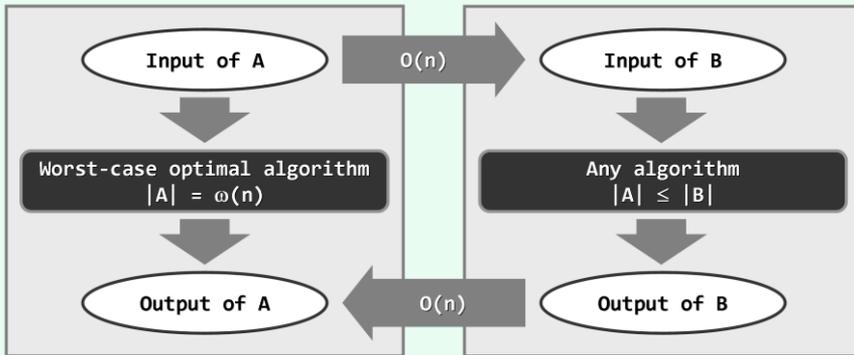
此时,若问题A的难度(记作 $|A|$)已界定为严格地高于 $\Omega(n)$,亦即:

$$|A| = \Omega(f(n)) = \omega(n)^{\textcircled{1}}$$

则问题B的难度(记作 $|B|$)也不会低于这个复杂度下界,亦即:

$$|B| \geq |A| = \Omega(f(n))$$

实际上,若问题A果真可以线性归约为问题B,则由后者的任一算法,必然同时也可以导出前者的一个算法。这一结论,可由图x2.4直接看出:为求解问题A,可将其输入转化为问题B的输入,再调用后者的算法,最后将输出转化为前者的输出。



图x2.4 从问题A到问题B的线性归约

因此,假若问题B具有一个更低的下界,则至少存在一个 $\omega(f(n))$ 的算法,于是由上可知,问题A也存在一个 $\omega(f(n))$ 的算法——这与问题A已知的 $\omega(n)$ 下界相悖。

^① 这里的“小 ω 记号”(small-omega notation),也是界定复杂度的尺度。

准确地,若存在函数 $f(n)$,使得对于任何正的常数 c ,当 n 足够大之后都有 $T(n) > c \cdot f(n)$,则可认为 $f(n)$ 给出了 $T(n)$ 增长速度的一个严格非紧的渐进下界,记作 $T(n) = \omega(f(n))$ 。请注意小 ω 记号与大 Ω 记号的微妙区别。

比如, $2n(n+1) = \Omega(n \log n)$ 而且 $2n(n+1) = \omega(n \log n)$, $2n \log n = \Omega(n \log n)$ 但 $2n \log n \neq \omega(n \log n)$

^② 这里的“小 ω 记号”(small-0 notation),也是界定复杂度的尺度。

准确地,若存在函数 $f(n)$,使得对于任何正的常数 c ,当 n 足够大之后都有 $T(n) < c \cdot f(n)$,则可认为 $f(n)$ 给出了 $T(n)$ 增长速度的一个严格非紧的渐进上界,记作 $T(n) = \omega(f(n))$ 。请注意小 ω 记号与大 ω 记号的微妙区别。

比如, $2n = \omega(n \log n)$ 而且 $2n = \omega(n \log n)$, $2n \log n = \omega(n \log n)$ 但 $2n \log n \neq \omega(n \log n)$

归纳起来，为运用线性归约界定问题B的难度下界，须经以下步骤：

- 1) 找到难度已知为 $\omega(n)$ 的问题A
- 2) 证明问题A可线性归约为问题B——其输入、输出可在线性时间内完成转换

就本题而言，“无序向量唯一化”即是难度待界定的问题B，将其简记作UNIQ。作为参照，考查所谓的元素唯一性（Element Uniqueness，简称EU）问题A：

对于任意n个实数，判定其中是否有重复者

作为EU问题的输入，任意n个实数都可在线性时间内组织为一个无序向量，从而转换为UNIQ问题的输入；另一方面，一旦得到UNIQ问题的输出（即去重之后的向量），只需花费线性时间，核对向量的规模是否依然为n，即可判定原实数中是否含有重复者（亦即，得到EU问题的输出）。因此，EU问题可以线性归约为UNIQ问题，亦即：

$$A \leq_N B$$

实际上，算法复杂度理论业已证明，EU问题具有 $\Omega(n \log n)$ 的复杂度下界，故这也是UNIQ问题的一个下界。反过来，以上所给的 $\mathcal{O}(n \log n)$ 算法，已属最优。

[2-13] 试参照函数对象 Increase (教材 44 页代码 2.16) 重载运算符 “()” 的方式，基于无序向量的遍历接口 traverse()，实现以下操作（假定向量元素类型支持算术运算）：

a) decrease()：所有元素数值减一；

【解答】

一种可行的实现方式，如代码x2.1所示。

```
1 template <typename T> struct Decrease //函数对象：递减一个T类对象
2   { virtual void operator()(T& e) { e--; } }; //假设T可直接递减或已重载--
3
4 template <typename T> void decrease(Vector<T> & V) //统一递减向量中的各元素
5 { V.traverse(Decrease<T>()); } //以Decrease<T>()为基本操作进行遍历
```

代码x2.1 基于遍历实现向量的decrease()功能

与教材代码2.16中increase()接口的实现方式同理，这里首先定义一个名为Decrease的函数对象，然后以此为基本操作，通过遍历接口对向量的所有元素逐一处理。

b) double()：所有元素数值加倍。

【解答】

一种可行的实现方式，如代码x2.2所示。

```
1 template <typename T> struct Double //函数对象：倍增一个T类对象
2   { virtual void operator()(T& e) { e *= 2; } }; //假设T可直接倍增
3
4 template <typename T> void double(Vector<T> & V) //统一加倍向量中的各元素
```

```
5 { V.traverse(Double<T>()); } //以Double<T>()为基本操作进行遍历
```

代码x2.2 基于遍历实现向量的double()功能

与以上Decrease的实现方式相仿，这里的关键依然在于定义一个名为Double的函数对象。

[2-14] 字符串、复数、矢量等类型没有提供自然的比较规则，但仍能人为地对其强制定义某种大小关系(即次序关系)。试分别为这三种类型的对象定义“人工的”次序。

【解答】

比如，可以采用字典序来确定字符串之间的次序。

复数与复平面上的点一一对应，故可以按照“先实部、后虚部”的原则定义复数之间的次序；复数也与极坐标平面上的点一一对应，故也可以按照“先幅值、后极角”的原则定义其次序。

二维矢量与复数彼此对应，故定义于复数之间任何一种次序，也应适用于矢量。反之亦然。读者可参照以上方式，结合具体应用的特点及需求，定义不同的次序。

[2-15] 考查采用CBA式算法对4个整数的排序。

a) 试证明，最坏情况下不可能少于5次比较；

【解答】

既然是考查最坏情况，不妨假定所有整数互异，此时的CBA式算法经每次比较之后，在对应的比较树(comparison tree)中只有两个有效的分支。

此时共有4!种可能的输出，故算法对应的比较树至少拥有24个叶节点，因此树高至少是：

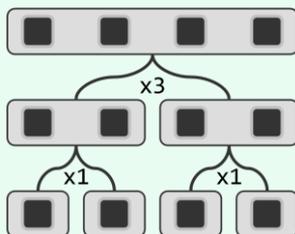
$$\lceil \log_2 24 \rceil = 5$$

b) 试设计这样的—个CBA式算法，即便在最坏情况下，至多只需5次比较。

【解答】

比如，可以采用教材61页2.8.3节介绍的归并排序(mergesort)算法。

如图x2.5所示，当输入规模为4时，归并排序算法的递归深度为2。



图x2.5 输入规模为4时的归并排序过程

底层的两次二路归并，各自仅需1次比较；顶层的一次二路归并，最坏情况下只需3次比较。总体合计，不过5次比较。

[2-16] `search(e, lo, hi)`算法版本 C (教材 56 页代码 2.24) 所返回的秩, 均符合接口规范。试针对以下情况, 分别验证这一结论:

- [`lo, hi`]中的元素均小于 e ;
- [`lo, hi`]中的元素均等于 e ;
- [`lo, hi`]中的元素均大于 e ;
- [`lo, hi`]中既包含小于 e 的元素, 也包含大于 e 的元素, 但不含等于 e 的元素。

【解答】

请读者对照该算法对应的代码, 独立完成分析和验证任务。

[2-17] 考虑用向量存放一组字符串。

为在其中进行二分查找, 可依据字典序确定字符串之间的次序:

设字符串 $a = a_1a_2\dots a_n$ 和 $b = b_1b_2\dots b_m$

则 $a < b$ 当且仅当 $n = 0 < m$, 或者 $a_1 < b_1$, 或者 $a_1 = b_1$ 且 $a_2\dots a_n < b_2\dots b_m$

也就是说, 两个字符串之间的大小关系, 取决于它们 (按首字符对齐后) 第一对互异的字符。

- 试实现一个字符串类, 并提供相应的比较器, 或者重载对应的操作符;

【解答】

请读者仿照教材代码 2.9, 独立完成编码与调试任务。

- 若共有 n 个字符串, 二分查找的复杂度是否仍为 $O(\log n)$?

【解答】

总体而言, 此时的二分查找, 未必可以保证在 $O(\log n)$ 时间内完成。

尽管二分查找算法的流程、迭代次数均保持不变, 但与整数、字符之类的基本数据类型不同, 字符串的长度并不确定, 且无上限。因此, “每次比较仅需 $O(1)$ 时间” 的假设条件不再成立, 换言之, 此时字符串之间的比较已经不能继续视作基本操作。

[2-18] 设采用实现如教材 48 页代码 2.21 所示的二分查找 `binSearch()` 算法版本 A, 针对独立均匀分布于 $[0, 2n]$ 内的整数目标, 在固定的有序向量 $\{1, 3, 5, \dots, 2n-1\}$ 中查找。

- 若将平均的成功和失败查找长度分别记作 S 和 F , 试证明: $(S+1) \cdot n = F \cdot (n+1)$;

【解答】

对向量规模 n 做数学归纳。

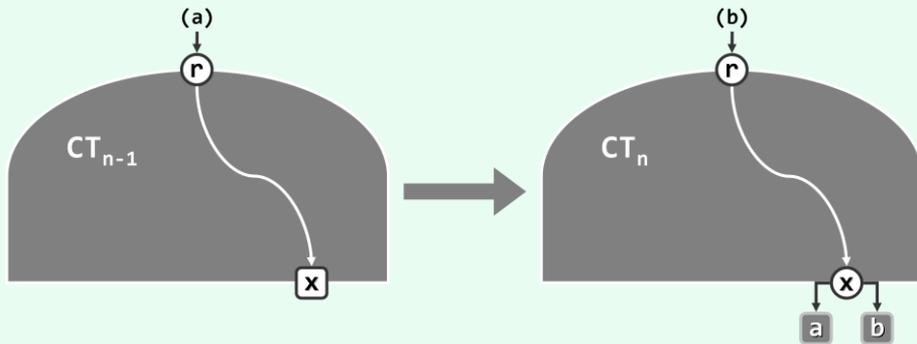
假定对于规模小于 n 的所有向量, 以上命题均成立。以下考查规模为 n 的向量。

实际上, 我们可以考查 `binSearch()` 算法对应的比较树。一般地, 若向量的规模为 n , 则对应的比较树应由 n 个内部节点 (成功的返回) 以及 $n+1$ 个叶节点 (失败的返回)。

特别地, 规模为 $n-1$ 和 n 的向量所对应的比较树 (CT_{n-1} 和 CT_n) 应该分别如图 x2.6(a) 和 (b) 所示。二者之间的差异仅在于, 前者的某一外部节点 x , 被替换为由一个内部节点 x 和两个外部节点 a 与 b 组成的子树。也就是说, 原先的某一查找失败情况, 现在对应于一种成功情况, 另加两种失败情况。综合而言, 成功情况及失败情况各自增加一种。

比如, 对于向量 $\{1, 3\}$, 共计有 2 种成功情况 $\{1, 3\}$ 以及 3 种失败情况 $\{0, 2, 4\}$;

而对于向量{ 1, 3, 5 }，则共计有3种成功情况{ 1, 3, 5 }以及4种失败情况{ 0, 2, 4, 6 }。



图x2.6 二分查找binSearch()算法版本A所对应的比较树，在向量规模递增后的结构变化

设在 CT_{n-1} 中，失败情况 x 所对应的查找长度为 d 。于是根据算法流程，在 CT_n 中成功情况 x 对应的查找长度应为 $d + 2$ ，而新的两种失败情况对应的查找长度为 $d + 1$ 和 $d + 2$ 。

若在 CT_{n-1} 中，内部节点、外部节点所对应的成功查找总长度、失败查找总长度应分别为：

$$S \cdot (n - 1)$$

$$F \cdot n$$

则在 CT_n 中，内部节点、外部节点所对应的成功查找总长度、失败查找总长度应分别为：

$$S \cdot (n - 1) + (d + 2)$$

$$F \cdot n + (d + 1) + (d + 2) - d = F \cdot n + (d + 3)$$

于是在 CT_n 中，成功查找、失败查找的平均长度应分别为：

$$S' = [S \cdot (n - 1) + (d + 2)]/n$$

$$F' = [F \cdot n + (d + 3)]/(n + 1)$$

故有：

$$(S' + 1) \cdot n = (S + 1) \cdot (n - 1) + (d + 3)$$

$$F' \cdot (n + 1) = F \cdot n + (d + 3)$$

根据归纳假设，应有：

$$(S + 1) \cdot (n - 1) = F \cdot n$$

故有：

$$(S' + 1) \cdot n = F' \cdot (n + 1)$$

至于以上证明的归纳基础，该命题的平凡情况不难验证。我们将此留给读者完成。

b) 上述结论，是否适用于 binSearch() 算法的其它版本？为什么？

【解答】

仍然适用。

证明方法完全类似，只不过在从 CT_{n-1} 转换至 CT_n 时，内部节点、叶节点所对应的成功、失败查找长度的计算口径不同。

c) 上述结论, 是否适用于 fibSearch() 算法的各个版本? 为什么?

【解答】

依然适用。

考查在从 CT_{n-1} 转换至 CT_n 后, (二者有所差异的) 局部子树对成功、失败查找总长度的贡献。实际上在命题中恒等式的两端, 只要这两方面的贡献相互抵消, 恒等式即可继续成立。

不难验证, fibSearch() 依然具有这种特性。我们也将此留给读者完成。

d) 若待查找的整数按照其它的随机规律分布, 以上结论又应如何调整?

【解答】

命题中的恒等式需加入各种情况对应的概率权重。具体的调整形式, 留给读者完成。

实际上, 原命题中的恒等式, 也可视作一种特殊情况——在等概率分布下, 所有权重均等。

[2-19] 为做 Fibonacci 查找, 未必非要严格地将向量整理为 fib(n) - 1 形式的长度。

比如, 可考虑以下策略:

- a) 按照黄金分割比, 取 $m_i = \lfloor 0.382 * l_o + 0.618 * h_i \rfloor$
- b) 按照近似的黄金分割比, 取 $m_i = \lfloor (l_o + 2 * h_i) / 3 \rfloor$
- c) 按照近似的黄金分割比, 取 $m_i = (l_o + (l_o \ll 1) + h_i + (h_i \ll 2)) \gg 3$

这几种替代策略, 综合性能各有什么优劣? 为什么?

【解答】

在如代码 2.22 (教材 53 页) 所示的 fibSearch() 算法中, 首先需要调用 Fib 类的初始化接口, 找到一个尽可能小, 却亦足够覆盖整个向量 $V[0, n)$ 的 Fibonacci 数, 作为初始查找范围的宽度:

$$N \geq h_i - l_o$$

如代码 x1.12 所示, Fib 类对象的初始化只需 $\mathcal{O}(\log_{\phi}(n))$ 时间 (分摊至后续的查找过程, 每次递归仅增加 $\mathcal{O}(1)$ 时间)。接下来在迭代式逐层深入地查找过程中, 还需通过一个内循环确定合适的黄金分割点——实际上每个分割点只需不超过两次迭代。

尽管以上足以说明 fibSearch() 算法的高效性, 但就算法流程的简洁性而言, 却远不如标准的二分查找 binSearch() 算法。

究其原因在于, 目前实现的版本对 Fibonacci 查找思想的理解和贯彻过于机械。实际上, 本题所建议的几种方式都能在保持渐进效率的前提下适当地灵活变通, 使算法的流程得以简化和清晰。建议的三种改进方案中, 方案 a) 采用近似值快速地估算出切分点, 方案 b) 可更好地发挥整数运算的优势, 而方案 c) 则通过移位操作替代更为耗时的乘、除法运算。

[2-20] 试分别针对二分查找算法版本 A (代码 2.21) 及 Fibonacci 算法 (代码 2.22), 推导其失败查找长度的显式公式, 并就此方面的性能对二者做一对比。

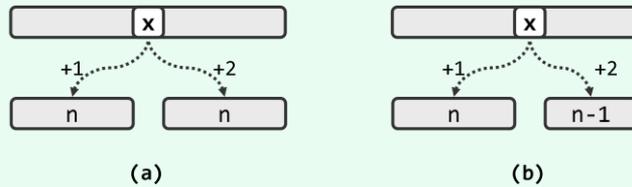
【解答】

可以证明: 对于规模为 n 的有序向量, 二分查找在失败情况下的平均比较次数不超过:

$$1.5 \cdot \log_2(n + 1) = \mathcal{O}(1.5 \cdot \log n)$$

为此, 我们采用数学归纳法。作为归纳基, 这一命题对长度为 1 的向量显然。

以下考查二分查找的第一步迭代，如图x2.7所示无非两种情况。



图x2.7 二分查找失败情况的递归分类

首先，考查左、右子向量规模均为 n 的情况。此时如图(a)所示，左侧子向量总共包含 $n + 1$ 种失败情况，由归纳假设，其平均比较长度不超过：

$$1 + 1.5 \cdot \log_2(n + 1)$$

右侧子向量也总共包含 $n + 1$ 种失败情况，由归纳假设，其平均比较长度不超过：

$$2 + 1.5 \cdot \log_2(n + 1)$$

综合所有失败情况，总体的平均查找长度不超过：

$$\begin{aligned} & [(n + 1) \cdot (1 + 1.5 \cdot \log_2(n+1)) + (n + 1) \cdot (2 + 1.5 \cdot \log_2(n+1))] / (2n + 2) \\ & = 1.5 \cdot \log_2(2n + 2) = \mathcal{O}(1.5 \cdot \log(2n + 1)) \end{aligned}$$

再考查左、右子向量规模分别为 n 和 $n - 1$ 的情况。此时如图(b)所示，左侧子向量总共包含 $n + 1$ 种失败情况，由归纳假设，其平均比较长度不超过：

$$1 + 1.5 \cdot \log_2(n + 1)$$

右侧子向量总共包含 n 种失败情况，由归纳假设，其平均比较长度不超过：

$$2 + 1.5 \cdot \log^2 n$$

综合所有失败情况，总体的平均查找长度不超过：

$$\begin{aligned} & [(n + 1) \cdot (1 + 1.5 \cdot \log_2(n + 1)) + n \cdot (2 + 1.5 \cdot \log_2 n)] / (2n + 1) \\ & = [(3n + 1) + 1.5 \cdot ((n + 1) \cdot \log_2(n + 1) + n \cdot \log_2 n)] / (2n + 1) \\ & \sim^{\textcircled{*}} [(3n + 1) + 1.5 \cdot 2 \cdot (n + 1/2) \cdot \log_2(n + 1/2)] / (2n + 1) \\ & = (3n + 1) / (2n + 1) + 1.5 \cdot \log_2(n + 1/2) \\ & \sim 1.5 \cdot [1 + \log_2(n + 1/2)] \\ & = 1.5 \cdot \log_2(2n + 1) = \mathcal{O}(1.5 \cdot \log(2n)) \end{aligned}$$

类似地还可以证明：Fibonacci查找在失败情况下的平均比较次数不超过：

$$\lambda \cdot \log_2(n + 1) = \mathcal{O}(\lambda \cdot \log n)$$

其中

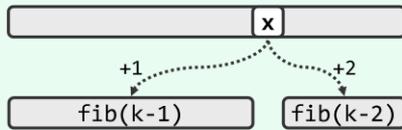
$$\lambda = 1 + 1/\Phi^2 = (2 + \Phi)/(1 + \Phi) = 3 - \Phi = 1.382$$

$$\Phi = (\sqrt{5} + 1) / 2 = 1.618$$

我们依然采用数学归纳法。作为归纳基，这一命题对长度为1的向量显然。

^① 本书约定，使用符号“ \sim ”表示渐进同阶

以下如图x2.8所示, 设向量长度为 $n = \text{fib}(k) - 1$, 考查Fibonacci查找的第一步迭代。



图x2.8 Fibonacci查找失败情况的递归分类

此时, 左侧子向量共计 $\text{fib}(k - 1)$ 种失败情况, 由归纳假设, 其平均比较长度不超过:

$$1 + \lambda \cdot \log_2 \text{fib}(k - 1)$$

右侧子向量共计 $\text{fib}(k - 2)$ 种失败情况, 其平均比较长度不超过:

$$2 + \lambda \cdot \log_2 \text{fib}(k - 2)$$

综合所有失败情况, 平均查找长度不超过:

$$\begin{aligned} & [\text{fib}(k-1) \cdot (1 + \lambda \cdot \log_2 \text{fib}(k-1)) + \text{fib}(k-2) \cdot (2 + \lambda \cdot \log_2 \text{fib}(k-2))] / \text{fib}(k) \\ &= [(\text{fib}(k) + \text{fib}(k-2)) + \lambda \cdot (\text{fib}(k-1) \cdot \log_2 \text{fib}(k-1) \\ &\quad + \text{fib}(k-2) \cdot \log_2 \text{fib}(k-2))] / \text{fib}(k) \\ &\sim [\lambda \cdot \text{fib}(k) + \lambda \cdot \text{fib}(k) \cdot (\log_2 \text{fib}(k) - 1)] / \text{fib}(k) \\ &= \lambda \cdot \log_2 \text{fib}(k) \end{aligned}$$

由上可见, 就失败情况而言, 尽管两种查找算法的渐进时间复杂度均为 $\mathcal{O}(\log n)$, 但常系数却又一定的差异——Fibonacci查找的 $\lambda = 1.382$, 较之二分查找的1.5更小。

[2-21] 设 $A[0, n)$ 为一个非降的正整数向量。

试设计并实现算法 `expSearch(int x)`, 对于任意给定的正整数 $x \leq A[n - 1]$, 从该向量中找出一个元素 $A[k]$, 使得 $A[k] \leq x \leq A[\min(n - 1, k^2)]$ 。

若有多个满足这一条件的 k , 只需返回其中任何一个, 但查找时间不得超过 $\mathcal{O}(\log(\log k))$ 。

(提示: 指数查找 (exponential search))

【解答】

我们令 k 从1开始不断递增 ($A[k]$ 亦相应地非降变化), 直至 $A[k]$ 首次超过查找目标 x 。

当然, 这里不能采用顺序的逐一递增 ($k = k + 1$) 模式:

$$k = 1, 2, 3, 4, 5, 6 \dots$$

显然, 在抵达 $A[k] \leq x \leq A[k + 1]$ 之前, 必然已经花费了 $\mathcal{O}(k)$ 时间。可见, 为尽快抵达目标位置, 必须加大各试探位置的间距。

然而类似地, 采用一般的递增模式仍不足够, 比如加倍的递增 ($k = 2 * k$) 模式:

$$k = 1, 2, 4, 8, 16, 32, \dots$$

因为在抵达 $A[k] \leq x \leq A[2k]$ 之前, 如此必然已经花费了 $\mathcal{O}(\log k)$ 时间。

为进一步加大各次试探位置的间距, 可以采用指数递增 ($k = k * k$) 模式:

$$k = 1, 2, 4, 16, 256, 65536, \dots$$

如此, 在抵达 $A[k] \leq x \leq A[k^2]$ 之前, 仅需试探的步数为:

$$\mathcal{O}(\log(\log k)) = \mathcal{O}(\log \log k)$$

[2-22] 设 $A[0, n][0, n]$ 为整数矩阵（即二维向量）， $A[0][0] = 0$ 且任何一行（列）都严格递增。

- a) 试设计一个算法，对于任一整数 $x \geq 0$ ，在 $O(r + s + \log n)$ 时间内，从该矩阵中找出并报告所有值为 x 的元素（的位置），其中 $A[0][r]$ ($A[s][0]$) 为第 0 行（列）中不大于 x 的最大者；（提示：马鞍查找 (saddleback search)）

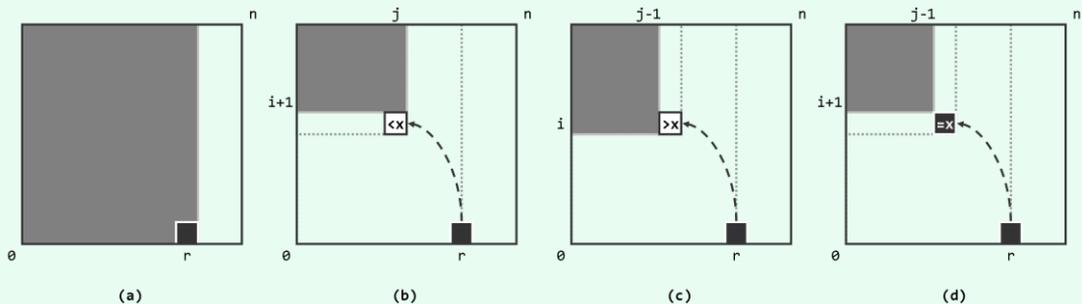
【解答】

一种可行的算法，过程大致如算法x2.1所示。

```
saddleback(int A[n][n], int x) {
    int i = 0; //不变性：有效查找范围始终为左上角的子矩形A[i, n][0, j]
    int j = binSearch(A[0][], x); //借助二分查找，在O(logn)时间内，从A的第0行中找到不大于x的最大者
    while ((i < n) && (-1 < j)) { //以下，反复根据A[i][j]与x的比较结果，不断收缩查找范围A[i, n][0, j]
        if (A[i][j] < x) i++; //矩形区域的底边上移
        else if (x < A[i][j]) j--; //矩形区域的右边左移
        else { report(A[i][j]); i++; j--; } //报告当前命中元素，矩形区域的底边上移、右边左移
    }
}
```

算法x2.1 马鞍查找

该算法的原理及过程，如图x2.9所示。若将待查找矩阵A视作二维矩形区域，则在算法的每一次迭代中，搜索的范围始终可精简为该矩形左上角的某一子矩形（以阴影示意）。当然，该子矩形在初始情况下即为矩阵对应的整个区域。



图x2.9 马鞍查找算法的原理及过程

算法首先通过二分查找，花费 $O(\log n)$ 的时间在首行 $A[0][j]$ 中确定起始元素 $A[0][j = r]$ 。于是如图(a)所示，根据该矩阵的单调性，查找范围即可收缩至 $A[i = 0, n][0, j = r]$ 。

接下来，反复地根据子矩形右下角元素 $A[i][j]$ 与目标元素 x 的大小关系，不断收缩子矩形。既然该矩阵在两个维度均具有单调性，故若 $A[i][j] < x$ ，则如图(b)所示，意味着当前子矩形的底边可以向上收缩一行；若 $x < A[i][j]$ ，则如图(c)所示，意味着当前子矩形的右边可以向左收缩一列；而倘若 $A[i][j] = x$ ，则如图(d)所示，不仅意味着找到了一个新的命中元素，而且当前子矩形的底边和右边可以同时收缩。

总而言之无论如何，每经过一次迭代，搜索的范围都可有效地收缩。由此可见，该算法也采用了减而治之 (decrease-and-conquer) 的策略。

为估计这一过程所需进行的迭代次数，我们不妨考查观察量： $k = j - i$ 。

开始迭代之前，设二分查找返回值为 $j = r < n$ ，则当时应有：

$$k = j - i = r - 0 < n$$

此后每经过一次迭代，或者 j 减一，或者 i 加一，或者二者同时如此变化。总而言之，无论如何观察量 k 都至少减一。另一方面根据循环条件，最后一次迭代中必然有 $i = s$ 和 $0 \leq j$ ，即：

$$k = j - i \geq 0 - s > -n$$

由此可见，这个过程迭代次数不超过：

$$r + s < 2n$$

请注意，单调性在此扮演了重要的角色。实际上，如果将矩阵理解为某一地区，将其中各单元的数值视作对应位置的高度，则该地区的地形将类似于马鞍的形状，该算法也因此得名。

从这一视角来看，所有命中的元素应该就是输入指定高度 x 所对应的一条等高线。于是，上述查找过程，则等效于从某一端的起点出发，逐点遍历该等高线。因为元素数值的严格单调性，该等高线与每一行、每一列至多相交于一个单元。这些单元也就是算法需要遍历并检查的单元，若等高线的起点和终点分别为 $A[0][r]$ 和 $A[s][0]$ ，则其包含的单元应不超过 $r + s$ 个。这一结论，与前面的分析殊途同归。

b) 若 A 的各行(列)只是非减(而不是严格递增)，你的算法需做何调整？复杂度有何变化？

【解答】

如果带查询矩阵的严格单调性不能保证，则在 $A[i][j] = x$ 的情况下不能继续有效地收缩查找范围。实际上在此种条件下，命中的元素可能多达 $\Omega(n^2)$ 个，故仅在上述算法的基础上做修补，已很难保证整体的效率。

为此，不妨改用其它策略，比如采用第8章将要介绍的 kd -树结构或四叉树等数据结构及相应的算法。

[2-23] 教材 2.6 节针对有序向量介绍的各种查找算法，落实减而治之策略的形式均大同小异：反复地“猜测”某一元素 $S[mi]$ ，并通过将目标元素与之比较的结果，确定查找范围收缩的方向。然而在某些特殊的场合，沿前、后两个方向深入的代价并不对称，甚至其中之一只允许常数次。

比如，在仅能使用直尺的情况下，可通过反复实验，用鸡蛋刚能摔碎的下落高度(比如精确到毫米)来度量蛋壳的硬度。尽管可以假定在破裂之前蛋壳的硬度保持不变，但毕竟破裂是不可逆的。故若仅有一枚鸡蛋，则我们不得不从 0 开始，以 1 毫米为单位逐步增加下落的高度。若蛋壳的硬度不超过 n 毫米，则需要进行 $o(n)$ 次实验。就效率而言，这等价于退化到无序向量的顺序查找。

a) 若你拥有两枚鸡蛋(假定它们硬度完全相同)，所需实验可减少到多少次？试给出对应的算法；

【解答】

不妨以 \sqrt{n} 为间距，将区间 $[1, n]$ 均匀地划分为 \sqrt{n} 个区间。于是，借助第一枚鸡蛋，即可在 $o(\sqrt{n})$ 时间内确定其硬度值所属的区间。接下来，再利用第二枚鸡蛋，花费 $o(\sqrt{n})$ 时间在此区间之内精确地确定其硬度值。

两步合计，共需花费 $o(2 \cdot \sqrt{n}) = o(\sqrt{n})$ 时间。

b) 进一步地, 如果你拥有三枚鸡蛋呢?**【解答】**

仿照上述思路, 以 $n^{1/3}$ 为间距, 将区间 $[1, n]$ 均匀地划分为 $n^{1/3}$ 个区间(宽度各为 $n^{2/3}$); 然后, 再将每个区间继续均匀地细分为 $n^{1/3}$ 个子区间(宽度各为 $n^{1/3}$)。

类似地, 借助第一枚鸡蛋, 在 $O(n^{1/3})$ 时间内将查找范围缩减至 $n^{2/3}$; 接下来, 再利用第二枚鸡蛋, 在 $O(n^{1/3})$ 时间内将查找范围缩减至 $n^{1/3}$; 最后, 利用第三枚鸡蛋, 花费 $O(n^{1/3})$ 时间在此区间之内精确地确定硬度值。

综合以上三步, 总共耗时不过:

$$O(3 \cdot n^{1/3}) = O(n^{1/3})$$

c) 一般地, 如果共有 d 枚鸡蛋可用呢?**【解答】**

将以上方法推广, 也就是对区间 $[1, n]$ 逐层细分。每深入一层, 都将当前层的每个子区间均匀地细分为 $n^{1/d}$ 个更小的子区间。累计共分为 d 层。

查找也是逐层进行, 不断深入: 每花费 $O(n^{1/d})$ 时间, 查找范围的宽度都收缩至此前的 $n^{-1/d}$ 。

纵观整个查找过程, 共计 d 次复杂度为 $O(n^{1/d})$ 顺序查找, 累计耗时不过:

$$O(d \cdot n^{1/d}) = O(n^{1/d})$$

需特别留意的是, 为实现子区间的分层细分, 只需根据输入参数 d 确定规则, 并不需要进行实质性的计算, 因此这部分时间无需考虑。

[2-24] 在实际应用中, 有序向量内的元素不仅单调排列, 而且往往还服从某种概率分布。若能利用这一性质, 则可以更快地完成查询。

以查阅英文字典为例, 单词"Data"应大致位于前 1/5 和 1/4 之间, 而"Structure"则应大致位于后 1/5 和 1/4 之间。对元素的分布规律掌握得越准确, 这种加速效果也就越加可观。

此类方法的原理大同小异, 无非是利用向量元素的分布规律, 根据目标数值, 通过插值估计出其大致所对应的秩, 从而迅速缩小搜索范围, 故称作插值查找 (interpolation search)。

a) 若有序向量中的元素均独立且等概率地取自某一数值区间, 试证明它们应大致按线性规律分布;**【解答】**

既然是均匀且独立的分布, 样本数量(向量区间内元素的数量)自然应线性正比于取值范围(向量区间两端点的数值之差)。

b) 针对此类有序向量, 如何通过插值来估计待查找元素的秩? 试给出具体的计算公式;**【解答】**

若查找区间为 $[lo, hi]$, 且查找目标为 Y ($A[lo] \leq Y < A[hi]$), 则 Y 的秩可以近似地估计为:

$$mi = lo + (hi - lo) * (Y - A[lo]) / (A[hi] - A[lo])$$

c) 试证明：对于此类向量，每经一次插值和比较，待搜索区间的宽度大致以平方根的速度递减^[25]；

【解答】

设查找的目标为Y。

该算法通过不断迭代逐步逼近最终位置，故不妨考查其中第j步迭代 S_j , $j = 1, 2, \dots$ 。

若此步迭代对应于子区间 $V_j = [L_j, H_j)$ ，区间宽度 $N_j = H_j - L_j$ ，则按照上述估计公式，接受比较的元素的秩为：

$$K_j = L_j + N_j \cdot P_j$$

其中，

$$P_j = (Y - A[L_j]) / (A[H_j] - A[L_j])$$

这里的 P_j ，既可看作Y在区间 V_j 内的相对位置，同时也是均匀分布于 V_j 之内的每一随机变量取值不大于Y的概率。

我们将 V_j 中不大于Y的元素数目记作 I_j 。既然该区间内的 N_j 个元素相互独立，故 I_j 应该就是它们取值不大于Y的概率总和。更准确地， I_j 可视作一个符合二项式分布的随机变量，于是 I_j 的期望值为 $N_j \cdot P_j$ ，方差为 $N_j \cdot P_j \cdot (1 - P_j)$ 。

再来考查查找目标Y，将其在整个区间中的秩记作 K^* ——亦即，总共恰有 K^* 个元素不大于Y。

于是，在查找范围业已收缩至 V_j 时， $K^* - L_j$ 就是上述符合二项式分布的随机变量。因此若如上将第j个接受比较的元素的秩记作 K_j ，则按照该算法的原理， K_j 即是在经过此前各步迭代而进入状态 S_j 的情况下，取 K^* 的条件期望，亦即：

$$K_j = E(K^* \mid S_1, S_2, \dots, S_j) \dots \dots \dots (1)$$

以下考查前后相邻的两次试探位置的间距，令：

$$D_j = |K_{j+1} - K_j|$$

实际上，根据该算法的原理不难看出，以下两个等式中，总是必有其一成立：

$$K_j = L_{j+1}$$

$$K_j = H_{j+1}$$

相应地，以下两式之一也必然成立：

$$D_j = N_{j+1} \cdot P_{j+1}$$

$$D_j = N_{j+1} \cdot (1 - P_{j+1})$$

因此无论如何，总是有：

$$\text{var}(K^* \mid S_1, S_2, \dots, S_j) = N_j \cdot P_j \cdot (1 - P_j) \leq D_{j-1} \dots \dots \dots (2)$$

由以上的定义，还可以导出：

$$\begin{aligned} D_j &= |K_{j+1} - K_j| \\ &= |E(K^* \mid S_1, S_2, \dots, S_j, S_{j+1}) - K_j| \\ &= |E(K^* - K_j \mid S_1, S_2, \dots, S_j, S_{j+1})| \end{aligned}$$

由柯西不等式可知：

$$\begin{aligned} D_j^2 &= [E(K^* - K_j \mid S_1, S_2, \dots, S_j, S_{j+1})]^2 \\ &\leq [E[(K^* - K_j)^2 \mid S_1, S_2, \dots, S_j, S_{j+1}]] \end{aligned}$$

根据条件期望值的性质，进一步地有：

$$E(D_j^2 \mid S_1, S_2, \dots, S_j)$$

$$\begin{aligned} &\leq E([E([K^* - K_j]^2 \mid S_1, S_2, \dots, S_j, S_{j+1})] \mid S_1, S_2, \dots, S_j) \\ &= E([K^* - K_j]^2 \mid S_1, S_2, \dots, S_j) \end{aligned}$$

由(1)式, 在依次转入 S_1, S_2, \dots, S_j 状态后, 随机变量 K^* 的期望值为 K_j , 故上式也就是 K^* 在此时的条件方差。于是由(2)式, 继续有:

$$E(D_j^2 \mid S_1, S_2, \dots, S_j) \leq D_{j-1} \dots \dots \dots (3)$$

最后, 再次根据柯西不等式, 并利用条件期望值的性质, 由(3)式有:

$$\begin{aligned} [E(D_j \mid S_1)]^2 &\leq E(D_j^2 \mid S_1) \\ &= E(E(D_j^2 \mid S_1, S_2, \dots, S_j) \mid S_1) \\ &\leq E(D_{j-1} \mid S_1) \end{aligned}$$

亦即:

$$E(D_j \mid S_1) \leq \sqrt{E(D_{j-1} \mid S_1)}$$

这就意味着, 从进入第一步迭代之后, 随后各步迭代所对应查找自区间的宽度, 将以平方根的速度逐次递减。

实际上, 第一步迭代所对应的子区间也具有这一性质。请读者参照以上方法, 独立补充证明。

d) 试证明: 对于长度为 n 的此类向量, 插值查找的期望运行时间为 $O(\log \log n)$;

【解答】

针对宽度为 n 的向量做插值查找时, 记所需的时间为 $T(n)$ 。于是有以下边界条件及递推方程:

$$\begin{aligned} T(1) &= O(1) \\ T(n) &= T(\sqrt{n}) + O(1) \end{aligned}$$

令:

$$S(n) = T(2^n)$$

则有:

$$\begin{aligned} S(1) &= O(1) \\ S(n) &= S(n/2) + O(1) \end{aligned}$$

解之可得:

$$S(n) = O(\log n)$$

对应地:

$$T(n) = S(\log n) = O(\log \log n)$$

e) 按照以上思路实现对应的插值查找算法, 并通过实际测量, 与二分查找等算法做一效率对比 ;

【解答】

请读者独立完成算法的编码与调试任务。

f) 你的实测对比结果, 与理论分析是否吻合? 若不吻合, 原因何在?

【解答】

请读者独立完成实验, 依据统计结果加以验证, 并作出分析与解释。

[2-25] 对于几乎有序的向量，如教材代码 2.26 (60 页) 和代码 2.27 (60 页) 所示的起泡排序算法，都显得效率不足。

比如，即便乱序元素仅限于 $A[\theta, \sqrt{n}]$ 区间，最坏情况下仍需调用 `bubble()` 做 $\Omega(\sqrt{n})$ 次调用，共做 $\Omega(n)$ 次交换操作和 $\Omega(n^{3/2})$ 次比较操作，因此累计运行 $\Omega(n^{3/2})$ 时间。

a) 试改进原算法，使之在上述情况下仅需 $\mathcal{O}(n)$ 时间；

【解答】

可改进如代码x2.3和代码x2.4所示：

```
1 template <typename T> //向量的起泡排序
2 void Vector<T>::bubbleSort(Rank lo, Rank hi) //assert: 0 <= lo < hi <= size
3 { while (lo < (hi = bubble(lo, hi))); } //逐趟做扫描交换，直至全序
```

代码x2.3 向量的起泡排序 (改进版)

```
1 template <typename T> Rank Vector<T>::bubble(Rank lo, Rank hi) { //一趟扫描交换
2     Rank last = lo; //最右侧的逆序对初始化为[lo - 1, lo]
3     while (++lo < hi) //自左向右，逐一检查各对相邻元素
4         if (_elem[lo - 1] > _elem[lo]) { //若逆序，则
5             last = lo; //更新最右侧逆序对位置记录，并
6             swap(_elem[lo - 1], _elem[lo]); //通过交换使局部有序
7         }
8     return last; //返回最右侧的逆序对位置
9 }
```

代码x2.4 单趟扫描交换 (改进版)

较之教材中的代码2.26和2.27，这里将逻辑型标志 `sorted` 改为秩 `last`，以记录各趟扫描交换所遇到的最后（最右）逆序元素。如此，在乱序元素仅限于 $A[\theta, \sqrt{n}]$ 区间时，仅需一趟扫描交换，即可将问题范围缩减至这一区间。累计耗时：

$$\mathcal{O}(n + (\sqrt{n})^2) = \mathcal{O}(n)$$

b) 继续改进，使之在如下情况下仅需 $\mathcal{O}(n)$ 时间：乱序元素仅限于 $A[n - \sqrt{n}, n)$ 区间；

【解答】

仿照a)的思路与技巧，将扫描交换的方向调换为自后（右）向前（左），记录最前（最左）逆序元素。请读者独立完成这一改进。

c) 综合以上改进，使之在如下情况下仅需 $\mathcal{O}(n)$ 时间：乱序元素仅限于任意的 $A[m, m + \sqrt{n})$ 区间。

【解答】

综合以上a)和b)的思路与技巧，方向交替地执行扫描交换，同时动态地记录和更新最左和最右的逆序元素。请读者独立完成这一改进。

[2-26] 根据教材 2.8.3 节所给递推关系以及边界条件试证明,如教材 62 页代码 2.28 所示 mergeSort() 算法的运行时间 $T(n) = O(n \log n)$ 。

【解答】

教材中已针对该算法,给出了如下边界条件及递推方程:

$$T(1) = O(1)$$

$$T(n) = 2 \times T(n/2) + O(n)$$

或等价地

$$T(n)/n = T(n/2)/(n/2) + O(1)$$

以下若令:

$$S(n) = T(n)/n$$

则有:

$$S(1) = O(1)$$

$$S(n) = S(n/2) + O(1)$$

$$= S(n/4) + O(2)$$

$$= \dots$$

$$= S(n/2^k) + O(k)$$

$$= O(\log n)$$

于是有:

$$T(n) = n \cdot S(n)$$

$$= O(n \log n)$$

归并排序的边界条件及递推方程,在算法复杂度分析中非常典型,以上解法也极具有代表性。因此,读者不妨记住这一递推模式,并在今后作为基本结论直接应用。

[2-27] 如教材 62 页代码 2.28 所示 mergeSort() 算法,即便在最好情况下依然需要 $\Omega(n \log n)$ 时间。

实际上略微修改这段代码,即可使之在(子)序列业已有序时仅需线性时间。为此,mergeSort() 的每个递归实例仅需增加常数的时间,且其它情况下的总体计算时间仍然保持 $O(n \log n)$ 。

试给出你的改进方法,并说明其原理。

【解答】

只需将原算法中的

```
merge(lo, mi, hi);
```

一句改为:

```
if (_elem[mi - 1] > _elem[mi]) merge(lo, mi, hi);
```

实际上按照原算法的流程,在即将调用merge()接口对业已各自有序的向量区间[lo, mi)和[mi, hi)做二路归并之前,_elem[mi - 1]即是前一(左侧)区间的末(最靠右)元素,而_elem[mi]则是后一(右侧)区间的首(最靠左)元素。

于是,若属于本题所指(业已整体有序)的情况,则必有 $_elem[mi - 1] \leq _elem[mi]$;反之亦然。因此只需加入如上的比较判断,即可在这种情况下省略对 $merge()$ 的调用。

不难看出,如此并不会增加该算法的渐进时间复杂度。

[2-28] 教材 63 页代码 2.29 中的二路归并算法 $merge()$, 反复地通过 new 和 $delete$ 操作申请和释放辅助空间。然而实验统计表明, 这类操作的实际时间成本, 大约是常规运算的 100 倍, 故往往成为制约效率提高的瓶颈。

a) 试改写该算法, 通过尽量减少此类操作, 进一步优化整体效率;

【解答】

可以在算法启动时, 统一申请一个足够大的缓冲区作为辅助向量 $B[]$, 并作为全局变量为所有递归实例公用; 归并算法完成之后, 再统一释放。

如此可以将动态空间申请的次数降至 $O(1)$, 而不再与递归实例的总数 $O(n)$ 相关。当然, 这样会在一定程度上降低代码的规范性和简洁性, 代码调试的难度也会有所增加。

b) 试通过实测, 对比并验证你的改进效果。

【解答】

请读者独立完成实验测试, 并给出验证结论。

[2-29] 二路归并算法 $merge()$ (教材 63 页代码 2.29) 中的循环体内, 两条并列语句的判断逻辑, 并非完全对称。

a) 若将后一句中的 “ $C[k] < B[j]$ ” 改为 “ $C[k] \leq B[j]$ ”, 对算法将有何影响?

【解答】

经如此调整之后, 虽不致影响算法的正确性(仍可排序), 但不再能够保证各趟二路归并的稳定性, 整个归并排序算法的稳定性也因此不能保证。

原算法的控制逻辑可以保证稳定性。实际上, 若两个子区间当前接受比较的元素分别为 $B[j]$ 和 $C[k]$, 则唯有在前者严格大于后者时, 才会将后者转移至 $A[i++]$; 反之, 只要前者不大于后者(包含二者相等的情况), 都会优先转移前者。由此可见, 无论是子区间内部(相邻)的重复元素, 还是子区间之间的重复元素, 在归并之后依然能够保持其在原向量中的相对次序。

b) 若将前一句中的 “ $B[j] \leq C[k]$ ” 改为 “ $B[j] < C[k]$ ”, 对算法将有何影响?

【解答】

当待归并的子向量之间有重复元素时, 循环体内的两条处理语句均会失效, 两个子向量的首元素都不会被转移, 算法将在此处进入死循环。

c) 若同时做以上修改, 对算法又将有何影响?

【解答】

不影响算法的正确性, 仍可排序。然而每经过一趟归并, 子向量之间的重复元素都会颠倒前后的次序, 从而进一步地破坏整个归并排序算法的稳定性。

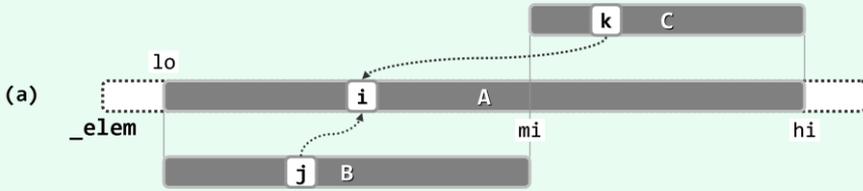
[2-30] 二路归并算法 merge() (教材 63 页代码 2.29) 中的循环体, 虽然形式上简洁, 但流程控制逻辑却较为复杂。

a) 试分情况验证并解释该算法的正确性;

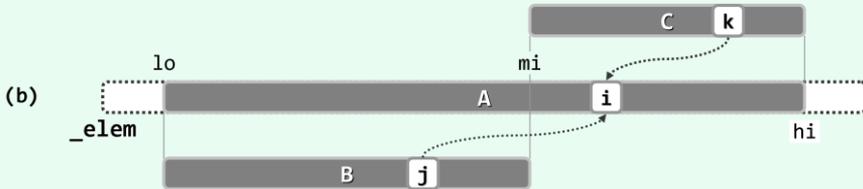
【解答】

这里之所以引入了较为复杂的控制逻辑, 目的是为了统一对不同情况的处理。尽管如此可使代码在形式上更为简洁, 但同时也会在一定程度上造成运行效率的下降。

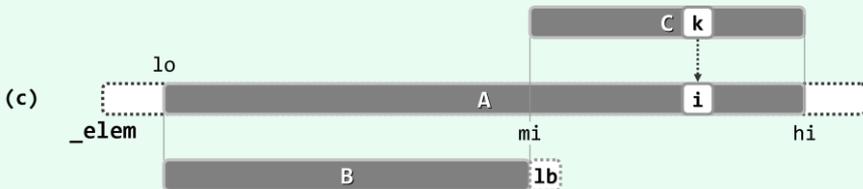
实际上, 二路归并算法过程中可能出现的情况, 如图x2.10至图x2.13所示无非四种。



图x2.10 B[]和C[]中的元素均未耗尽, 且已转入A[]的元素总数 $i \leq lb$



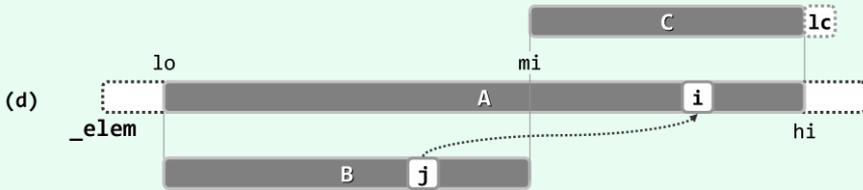
图x2.11 B[]和C[]中的元素均未耗尽, 且已转入A[]的元素总数 $i > lb$



图x2.12 B[]中的元素先于C[]耗尽

就本章特定的二路归并而言, 在情况(c)下C[]中剩余元素已不必移动。

此时, 为更好地理解循环体内的控制逻辑 “ $lb \leq j \mid\mid (C[k] < B[j])$ ”, 不妨假想地设置一个哨兵 $B[lb] = +\infty$ 。如此, “ $lb \leq j$ ” 即可作为特殊情况归入 “ $C[k] < B[j]$ ”。



图x2.13 C[]中的元素先于B[]耗尽

类似地, 此时为更好地理解循环体内的控制逻辑 “ $lc \leq k \mid\mid (B[j] \leq C[k])$ ”, 不妨假想地设置一个哨兵 $C[lc] = +\infty$, 即可将 “ $lc \leq k$ ” 作为特殊情况归入 “ $B[j] < C[k]$ ”。

b) 基于以上理解, 该循环体可以如何简化?**【解答】**

可以考虑精简为如下形式 (为便于对比, 这里插入了一些空格):

```
for (Rank i = 0, j = 0, k = 0; j < 1b; ) { //将B[j]和C[k]中的小者续至A末尾
    if ( (k < 1c) &&                (C[k] < B[j]) ) A[i++] = C[k++];
    if (                (1c <= k) || (B[j] <= C[k]) ) A[i++] = B[j++];
}
```

代码x2.5 有序向量二路归并算法的简化

请读者对照以上所列各种情况独立验证, 尽管这里交换了循环体内两句的次序, 同时删除了一些判断条件, 却并不影响该算法的正确性和稳定性。

c) 如果从代码可维护性及运行效率的角度出发, 该算法应该如何实现?**【解答】**

不难看出, 上述四种情况的发生次序, 必然首先是(a), 然后(可能会)经过(b), 最后以(c)或(d)结束。因此从代码可维护性及运行效率的角度出发, 不妨将(a和b)与(c或d)分为两个阶段, 分别处理。如此虽然会增加代码量, 但因判断逻辑可以进一步精简, 反而会在一定程度上提高运行效率。

[2-31] 找到 (v2.4 之前版本) Python 的 bisect 模块, 阅读其中 bisect_right() 接口的实现代码。

a) 试以增加注释的形式, 说明该接口的输入输出、功能语义、实现策略和算法实现;**【解答】**

bisect模块增加注释之后的源代码, 如代码x2.6所示:

```
def bisect_right(a, x, lo=0, hi=None): # 在有序向量区间a[lo, hi)中, 采用二分策略查找x
    if hi is None: # hi未予明确指定时, 默认值取作
        hi = len(a) # a的长度——因lo默认取作0, 故默认时等效于对整个向量做查找
    while lo < hi: # 每步迭代仅需做一次比较判断, 有两个分支
        mid = (lo+hi)//2 # 以中点为轴点
        if x < a[mid]: hi = mid # 经一比较后, 若x小于轴点, 则向左深入[lo, mi)
        else: lo = mid + 1 # 否则向右深入(mi, hi)
    return lo # lo为x在a[lo, hi)中适当的插入位置
```

代码x2.6 增加注释后, Python的bisect模块中bisect_right接口的源代码

需说明的是, 出于效率的考虑, 在Python v2.4之后版本中, 该接口已改用C语言实现。

b) 就以上方面而言, 该接口与本章向量的哪个接口基本类似? 同时, 又有什么区别?**【解答】**

bisect_right()的功能语义、算法原理及流程, 与Vector::binsearch()的版本C(教材56页代码2.24)几乎如出一辙。二者之间的差异无非在于, 前者返回的秩比后者大一。

[2-32] 自学 C++ STL 中 vector 容器的使用方法，阅读对应的源代码。

【解答】

请读者独立完成相关代码的阅读和分析。

[2-33] 自学 Java 语言中的 Java.util.ArrayList 和 java.util.Vector 类，并阅读对应的源代码。

【解答】

请读者独立完成相关代码的阅读和分析任务。

[2-34] 位图 (Bitmap) 是一种特殊的序列结构，可用以动态地表示由一组 (无符号) 整数构成的集合。其长度无限，且其中每个元素的取值均为布尔型 (初始均为 false)，支持的操作接口主要包括：

```
void set(int i); //将第i位置为true (将整数i加入当前集合)
void clear(int i); //将第i位置为false (从当前集合中删除整数i)
bool test(int i); //测试第i位是否为true (判断整数i是否属于当前集合)
```

a) 试给出 Bitmap 类的定义，并具体实现以上接口；

【解答】

一种可行的实现方式，如代码x2.7所示。

```
1 class Bitmap { //位图Bitmap类
2 private:
3     char* M; int N; //比特图所存放的空间M[], 容量为N*sizeof(char)*8比特
4 protected:
5     void init(int n) { M = new char[N = (n + 7) / 8]; memset(M, 0, N); }
6 public:
7     Bitmap(int n = 8) { init(n); } //按指定 (或默认) 规模创建比特图 (为测试暂时选用较小的默认值)
8     Bitmap(char* file, int n = 8) //按指定 (或默认) 规模, 从指定文件中读取比特图
9     { init(n); FILE* fp = fopen(file, "r"); fread(M, sizeof(char), N, fp); fclose(fp); }
10    ~Bitmap() { delete [] M; M = NULL; } //析构时释放比特图空间
11
12    void set (int k) { expand(k); M[k >> 3] |= (0x80 >> (k & 0x07)); } //插入
13    void clear(int k) { expand(k); M[k >> 3] &= ~(0x80 >> (k & 0x07)); } //删除
14    bool test (int k) { expand(k); return M[k >> 3] & (0x80 >> (k & 0x07)); } //测试
15
16    void dump (char* file) //将位图整体导出至指定的文件, 以便对此后的新位图批量初始化
17    { FILE* fp = fopen(file, "w"); fwrite(M, sizeof(char), N, fp); fclose(fp); }
18    char* bits2string(int n) { //将前n位转换为字符串——
19        expand(n - 1); //此时可能被访问的最高位为bitmap[n - 1]
20        char* s = new char[n + 1]; s[n] = '\0'; //字符串所占空间, 由上层调用者负责释放
21        for (int i = 0; i < n; i++) s[i] = test(i) ? '1' : '0';
22        return s; //返回字符串位置
23    }
```

```

24 void expand(int k) { //若被访问的Bitmap[k]已出界,则需扩容
25     if (k < 8 * N) return; //仍在界内,无需扩容
26     int oldN = N; char* oldM = M;
27     init(2 * k); //与向量类似,加倍策略
28     memcpy_s(M, N, oldM, oldN); delete [] oldM; //原数据转移至新空间
29 }
30 };

```

代码x2.7 位图Bitmap类

这里使用了一段动态申请的连续空间M[],并依次将其中的各比特位与位图集合中的各整数一一对应:若集合中包含整数k,则该段空间中的第k个比特位为1;否则该比特位为0。

在实现上述一一对应关系时,这里借助了高效的整数移位和位运算。鉴于每个字节通常包含8个比特,故通过移位运算:

$$k \gg 3$$

即可确定对应的比特位所属字节的秩;通过逻辑位与运算:

$$k \& 0x07$$

即可确定该比特位在此字节中的位置;通过移位操作:

$$0x80 \gg (k \& 0x07)$$

即可得到该比特位在此字节中对应的数值掩码(mask)。

得益于这种简明的对应关系,只需在局部将此字节与上述掩码做逻辑或运算,即可将整数k所对应的比特位设置为1;将此字节与上述掩码做逻辑与运算,即可测试该比特位的状态;将此字节与上述掩码的反码做逻辑位与运算,即可将该比特位设置为0。

这里还提供了一个dump()接口,可以将位图整体导出至指定的文件,以便对此后的新位图批量初始化。例如在后面9.3节实现高效的散列表结构时,经常需要快速地找出不小于某一整数的最小素数。为此,可以借助Eratosthenes算法,事先以位图形式筛选出足够多个候选素数,并通过dump()接口将此集合保存至文件。此后在使用散列表时,可一次性地读入该文件,即可按照需要反复地快速确定合适的素数。

与可扩充向量一样,一旦即将发生溢出,这里将调用expand()接口扩容。可见,这里采用的也是“加倍”的扩容策略。

b) 试针对你的实现,分析各接口的时间和空间复杂度;

【解答】

根据以上分析,set()、clear()和test()等接口仅涉及常数次基本运算,故其时间复杂度均为 $O(1)$ 。可见,这种实现方式巧妙地发挥了向量之“循秩访问”方式的优势。

此外,相对于四则运算等常规运算,这里所涉及的整数移位和位运算更为高效,因此该数据结构实际的运行效率非常高,该结构也是一种典型的实用数据结构。

这里，位图向量所占的空间线性正比于集合的取值范围——在很多应用中，这一范围就是问题本身的规模，故通常不会导致渐进空间复杂度的增加。

c) 创建 Bitmap 对象时，如何节省下为初始化所有元素所需的时间？（提示：参考文献[4][9]）

【解答】

首先考查简单的情况：位图结构只需提供 `test()` 和 `set()` 接口，暂且不需要 `clear()` 接口。针对此类需求，一种可行的方法大致如代码 x2.8 所示。

```

1 class Bitmap { //位图Bitmap类：以空间作为补偿，节省初始化时间（仅允许插入，不支持删除）
2 private:
3     Rank* F; Rank N; //规模为N的向量F，记录[k]被标记的次序（即其在栈T[]中的秩）
4     Rank* T; Rank top; //容量为N的栈T，记录被标记各位秩的栈，以及栈顶指针
5
6 protected:
7     inline bool valid(Rank r) { return (0 <= r) && (r < top); }
8
9 public:
10    Bitmap(Rank n = 8) //按指定（或默认）规模创建比特图（为测试暂时选用较小的默认值）
11    { N = n; F = new Rank[N]; T = new Rank[N]; top = 0; } //在O(1)时间内隐式地初始化
12    ~Bitmap() { delete [] F; delete [] T; } //析构时释放空间
13
14 // 接口
15    inline void set(Rank k) { //插入
16        if (test(k)) return; //忽略已带标记的位
17        F[k] = top++; T[ F[k] ] = k; //建立校验环
18    }
19    inline bool test(Rank k) //测试
20    { return valid(F[k]) && (k == T[ F[k] ]); }
21 };

```

代码x2.8 可快速初始化的Bitmap对象（仅支持set()操作）

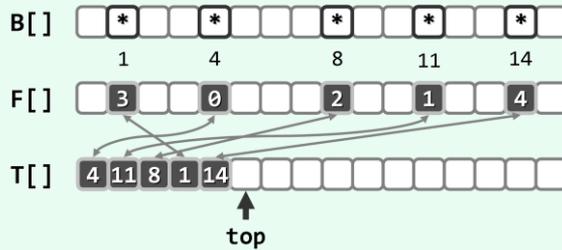
首先，将代码x2.7中Bitmap类的内部空间M[]，代替换为一对向量F[]和T[]，其中元素均为Rank类型，其规模N均与（逻辑上的）位图结构B[]相同。实际上，T[]的工作方式将等效于栈，栈顶由top指示，初始top = 0。

请注意，与代码x2.7的版本相比，这里对两个向量均未做显式的初始化。

此后，每当需要调用 `set(k)` 标记新的B[k]位时，即可将k压入栈T[]中，并将该元素（当前的顶元素）在栈中的秩存入F[k]。

如此产生的效果是，在k与T[F[k]]之间建立了一个校验环路。也就是说，当F[k]指向栈T[]中的某个有效元素（`valid(F[k])`），而且该元素T[F[k]]恰好就等于k时，在逻辑上必然等效于B[k] = true；更重要的是，反之亦然。因此如代码x2.8所示，`test(k)`接口只需判断以上两个条件是否同时成立。

经如此改造之后，位图结构的一个运转实例如图x2.14所示。



图x2.14 通过引入两个等长的向量，在 $O(1)$ 时间内初始化Bitmap对象

按以上方法，首先在 $O(1)$ 时间内对该位图结构做初始化。接下来，依次标记：

$B[4]$ ， $B[11]$ ， $B[8]$ ， $B[1]$ ， $B[14]$ ， ...

相应地依次压入栈T[]中的分别是：

$T[0] = 4$ ， $T[1] = 11$ ， $T[2] = 8$ ， $T[3] = 1$ ， $T[4] = 14$ ， ...

向量F[]中依次存入的秩为：

$F[4] = 0$ ， $F[11] = 1$ ， $F[8] = 2$ ， $F[1] = 3$ ， $F[14] = 4$ ， ...

不难看出，整个过程中，凡可通过test(k)逻辑的任何比特位k，均被标记过；反之亦然。

由上同时可见，经如上改造之后的test()和set()接口，各自仍然仅需 $O(1)$ 时间。

当然，以上方法仅限于标记操作set()，尚不支持清除操作clear()。如需兼顾这两个接口，就必须有效地辨别两种无标记的位：从未标记过的，以及曾经一度被标记后来又清除的。否则，每次为无标记的位增加标记时，若简单地套用目前的set()接口为其增加一个校验环，则栈T[]的规模将线性正比于累积的操作次数，从而无法限制在N以内（尽管向量F[]仍可以），整个结构的复杂度也将随着操作次数的增加严格单调的增加。

能够有效区分以上两种无标记位的一种Bitmap类，可实现如代码x2.9所示。

```

1 class Bitmap { //位图Bitmap类：以空间作为补偿，节省初始化时间（既允许插入，亦支持删除）
2 private:
3     Rank* F; Rank N; //规模为N的向量F，记录[k]被标记的次序（即其在栈T[]中的秩）
4     Rank* T; Rank top; //容量为N的栈T，记录被标记各位秩的栈，以及栈顶指针
5
6 protected:
7     inline bool valid(Rank r) { return (0 <= r) && (r < top); }
8     inline bool erased(Rank k) //判断[k]是否曾被标记过，且后来又被清除
9     { return valid(F[k]) && !(T[ F[k] ] + 1 + k); } //这里约定，此类[k]满足：T[ F[k] ] = - 1 - k
10
11 public:
12     Bitmap(Rank n = 8) //按指定（或默认）规模创建比特图（为测试暂时选用较小的默认值）
13     { N = n; F = new Rank[N]; T = new Rank[N]; top = 0; } //在O(1)时间内隐式地初始化
14     ~Bitmap() { delete [] F; delete [] T; } //析构时释放空间

```

```

15
16 // 接口
17 inline void set(Rank k) { //插入
18     if (test(k)) return; //忽略已带标记的位
19     if (!erased(k)) F[k] = top++; //若系初次标记, 则创建新校验环
20     T[ F[k] ] = k; //若系曾经标记后被清除, 则恢复原校验环
21 }
22 inline void clear(Rank k) //删除
23 { if (test(k)) T[ F[k] ] = - 1 - k; } //忽略不带标记的位
24 inline bool test(Rank k) //测试
25 { return valid(F[k]) && (k == T[ F[k] ]); }
26 };

```

代码x2.9 可快速初始化的Bitmap对象 (兼顾set()和clear()操作)

这里的clear()接口并非简单地破坏原校验环, 而是将T[F[k]]取负之后再减一。也就是说, 可以在与正常校验环不相冲突的前提下, 就地继续保留原校验环的信息。

基于这一约定, set(k)接口只需调用erase(k), 即可简明地判定[k]究竟属于哪种类型。若系从未标记过的, 则按此前的方法新建一个校验环; 否则可以直接恢复原先的校验环。

不难再次确认, 在扩充后的版本中, 各接口依然保持常数的时间复杂度。

最后, 考查经改进之后Bitmap结构的空間复杂度。尽管表面上看, F[]和T[]的规模均不超过N, 但这并不意味着整个结构所占空间的总量渐进不变。关键在于, 两个向量的元素类型已不再是比特位或逻辑位, 而是秩。二者的本质区别在于, 前一类元素自身所占空间与整体规模无关, 而后者有关。具体来说, 这里Rank类型的取值必须足以涵盖Bitmap的规模; 反之, 可用Bitmap的最大规模也不能超越Rank类型的取值范围。比如, 若Rank为四个字节的整数, 则Bitmap的规模无法超过 $2^{31} - 1 = \mathcal{O}(10^9)$, 否则Rank自身的字宽必须相应加大。所幸, 目前的多数应用尚不致超越这个规模, 因此仍可近似地认为以上改进版Bitmap具有线性的空间复杂度。

与之相关的另一问题是, 目前的版本仍不支持动态扩容。我们将这一任务留给读者, 并请读者对可扩容版Bitmap结构的空間、时间复杂度做一分析。

[2-35] 利用 Bitmap 类设计算法, 在 $\mathcal{O}(n)$ 时间内剔除 n 个 ASCII 字符中的重复字符, 各字符仅保留一份。

【解答】

将非重复的ASCII字符视作一个集合, 并将其组织为一个Bitmap结构——ASCII编码为k的字符, 对应于其中第k个比特位。

初始时, 该集合为空, Bitmap结构中的所有比特位均处于0状态。以下, 只需在 $\mathcal{O}(n)$ 时间内遍历所有的输入字符, 并对ASCII编码为k的字符, 通过set(k)接口将其加入集合。

请注意, 这里使用的Bitmap结构只需128个比特位。因此, 最后只需再花费 $\mathcal{O}(128) = \mathcal{O}(1)$ 时间遍历一趟所有的比特位, 并输出所有通过test()测试的比特位, 即可完成字符集的去重。

[2-36] 利用 Bitmap 类设计算法，快速地计算不大于 10^8 的所有素数。（提示：Eratosthenes 筛法）

【解答】

比如，可以采用Eratosthenes^④筛法。该算法一种可行的实现方式如代码x2.10所示。

```

1 #include "../Bitmap/Bitmap.h" //引入Bitmap结构
2
3 /*****
4  * 筛法求素数
5  * 计算出不大于n的所有素数
6  * 不计内循环，外循环自身每次仅一次加法、两次判断，累计O(n)
7  * 内循环每趟迭代O(n/i)步，由素数定理至多n/ln(n)趟，累计耗时不过
8  *     n/2 + n/3 + n/5 + n/7 + n/11 + ...
9  *     < n/2 + n/3 + n/4 + n/6 + n/7 + ... + n/(n/ln(n))
10 *     = O(n(ln(n/ln(n)) - 1))
11 *     = O(nln(n) - nln(ln(n)) - 1)
12 *     = O(nlog(n))
13 * 如下实现做了进一步优化，内循环从i * i而非i + i开始，迭代步数由O(n / i)降至O(max(1, n / i - i))
14 *****/
15 void Eratosthenes(int n, char* file) {
16     Bitmap B(n); B.set(0); B.set(1); //0和1都不是素数
17     for (int i = 2; i < n; i++) //反复地，从下一
18         if (!B.test(i)) //可认定的素数i起
19             for (int j = __min(i, 46340) * __min(i, 46340); j < n; j += i) //以i为间隔
20                 B.set(j); //将下一个数标记为合数
21     B.dump(file); //将所有整数的筛选标记统一存入指定文件，以便日后直接导入
22 }

```

代码x2.10 Eratosthenes素数筛选算法

这里的Bitmap结构B，相当于Eratosthenes的羊皮纸。初始时，（除0和1之外的）所有整数都有可能是素数，正如羊皮纸在开始前是完好无损的。

算法的主循环启动之后，将逐一检测各整数*i*（即与之对应的比特位[*i*]）。若当前的整数*i*已可被判定为合数（即B.test(*i*) = true，亦相当于羊皮纸上对应的方格已穿洞），则忽略之。否则，整数*i*应为素数，故须从2*i*开始以*i*为间隔，将后续所有形如*j* = *ki*（*k* ≥ 2）的整数*j*逐一标记为合数（即B.set(*j*)，亦相当于在羊皮纸上对应方格中穿孔）。

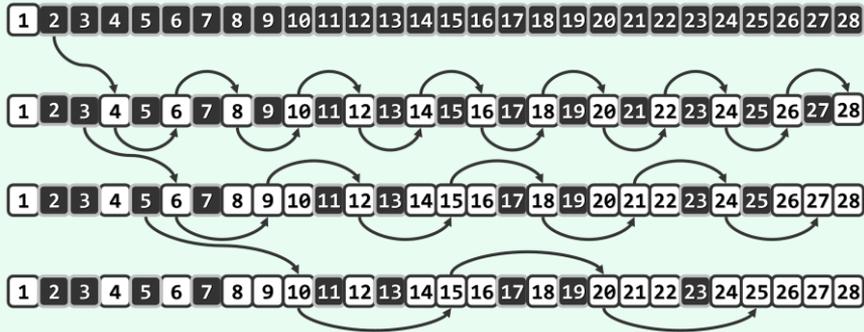
图x2.15逐行地依次给出了该算法在初始状态以及前三次迭代之后，Bitmap位图结构（Eratosthenes筛子）所对应的内部组成和状态。其中，白色的比特位（有穿孔的方格）所对应的整数已确认为合数；跨行的箭头联线，表示在确认了一个新的素数*i*之后，开始从2*i*开始筛

^④ Eratosthenes (276-194 B.C.)，埃拉托斯特尼，古希腊先哲。经纬坐标系的发明者。

其对地球半径简捷而精准地计算，也是封底估算方法的经典实例。

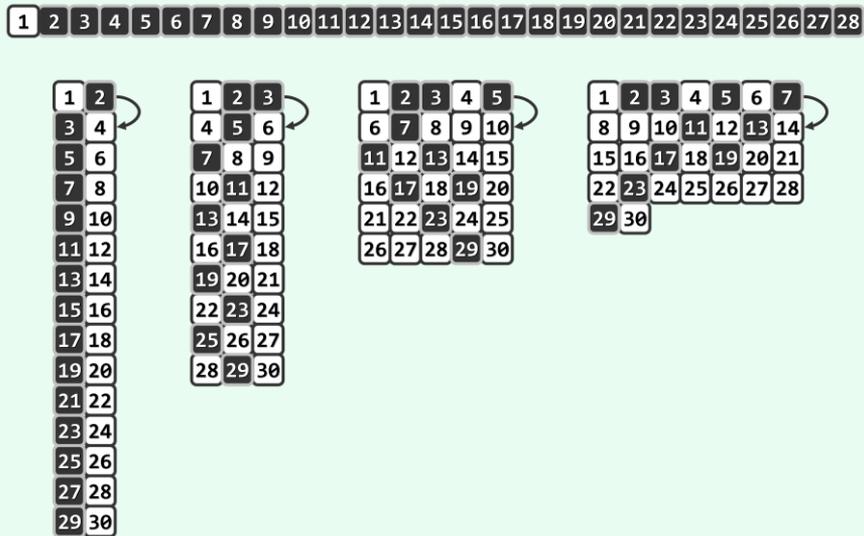
此处实现的算法也源自于他，并被形象地称作埃拉托斯特尼的筛子（the sieve of Eratosthenes）。

除其所有的整倍数；而同行内的箭头，则对应于逐个筛除其整倍数的过程。



图x2.15 Eratosthenes算法的实例

通过不断重排所有整数，我们可以更好地理解该算法的原理及过程。在算法确认了一个新的素数*i*之后，不妨将所有整数以*i*为单位顺次排成*i*列的矩阵（当然，应有无穷行）。如此，各次迭代所对应的重排结果应如图x2.16所示，依次为2列、3列、5列、7列、...

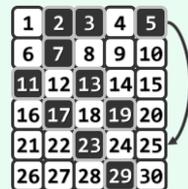


图x2.16 Eratosthenes算法：每次迭代中所筛除的整数，恰好就是重排矩形的最右侧一列

该算法可在 $O(n \log n)$ 时间内计算出不超过*n*的所有素数，具体分析可参见代码所附注释。

实际上，这里所实现的版本已在以上思路的基础上做了改进（尽管不是渐进意义上的改进）。

不难发现，在从对应于素数*i*的重排矩阵中，筛除其最右侧一列时，完全可以直接从*i*²（而不是2*i*）出发。以*i* = 5为例，如图x2.17所示完全可以从25（而不是10）出发。实际上，该列中介于[2*i*, *i*²）之间的整数，均应该已经在此前的某次迭代中被筛除了。



图x2.17 Eratosthenes算法的改进

[2-37] 教材 12 页算法 1.3 中, 在选出三个数之后还需对它们做排序。试证明:

a) 至多只需比对元素的大小三次, 即可完成排序;

【解答】

首先, 任取两个数并比较大小, 记作 $a < b$ 。如此, 整个数轴被分为三个区间:

$$(-\infty, a) \quad (a, b) \quad (b, +\infty)$$

此后, 至多再做两次比较, 即可确定第三个数落在其中哪个区间。

b) 在最坏情况下, 的确至少需要比对元素的大小三次, 才能完成排序。

【解答】

3 个数的排序结果, 共有 $3! = 6$ 种。也就是说, 该问题的任何一个算法所对应的比较树 (comparison tree) 中, 至少应有 6 个叶节点, 故树高不致低于:

$$\lceil \log_2 6 \rceil = 3$$

[2-38] 代数判定树 (algebraic decision tree, ADT) 是比较树的推广, 其中的节点分别对应于根据某一代数表达式做出的判断。例如, 比较树中各节点所对应的 “ $a == b$ ” 式判等以及 “ $a < b$ ” 式比较, 均可统一为根据一次代数表达式 “ $a - b$ ” 取值符号的判断。

a) 对应于教材 2.7.4 节所列比较树的性质, 代数判定树有哪些相仿的性质?

【解答】

与比较树类似地, 代数判定树也具有如下性质:

- ① 每一内部节点各对应于一次 (基于代数计算数值正负符号的) 判定操作
- ② 内部节点的左、右分支, 分别对应于在不同的数值符号下的执行方向
- ③ 叶节点 (亦即, 根到叶节点的路径) 对应于算法某次执行的完整过程及输出
- ④ 反过来, 算法的每一运行过程都对应于从根到某一叶节点的路径

b) 2.7.5 节中基于比较树模型的下界估计方法^{[27][28]}, 可否推广至代数判定树? 如何推广?

【解答】

完全可以推广。

需要特别注意的是, 对一般代数式的求值本身未必仍然属于基本操作, 故不见得可以在常数时间内完成。例如在高维空间中, 为计算两个点之间的欧氏距离所需的时间应线性正比于空间的维度 d , 若不将 d 视作常数, 则此时欧氏距离的计算即不属于基本操作。

因此在代数判定树中, 应根据各节点所对应代数计算操作的复杂度, 以根节点到叶节点通路的加权长度, 来度量各种输出所对应的计算成本。

[2-39] 任给 12 个互异的整数, 其中 10 个已组织为一个有序序列, 现需要插入剩余的两个以完成整体排序。若采用 CBA 式算法, 最坏情况下至少需做几次比较? 为什么?

【解答】

对于该问题的任一算法, 都可以将其中所有的分支描述为一棵代数判定树。根据排列组合中

基本知识，可能的输出数目应为：

$$\text{前一整数可能的插入位置数} \times \text{后一整数可能的插入位置数} = 11 \times 12 = 132$$

这也是该判定树应含叶节点数目的下限。

于是对应地，判定树的高度应至少是：

$$\lceil \log_2 132 \rceil = 8$$

这也是此类算法在最坏情况下需做比较操作次数的下限。

[2-40] 经过至多 $(n - 1) + (n - 2) = 2n - 3$ 次比较，不难从任何存有 n 个整数的向量中找出最大者和次大者。试改进这一算法，使所需的比较次数（即便在最坏情况下）也不超过 $\lceil 3n/2 \rceil - 2$ 。

【解答】

可以采用分治策略，通过二分递归解决该问题。

算法的具体过程为：将原问题划分为两个子问题，分别对应于向量的前半部分和后半部分。以下，在递归地求解两个子问题（即找出两个子向量各自的最大和次大元素）后，只需两次比较操作，即可得到原问题的解（即确定整个向量中的最大和次大元素）。

实际上，若前一子向量中的最大、次大元素分别为 a_1 和 a_2 ，后一子向量中的最大、次大元素分别为 b_1 和 b_2 ，则全局的最大元素必然选自 a_1 和 b_1 之间。不失一般性地，设：

$$a_1 = \max(a_1, b_1)$$

于是全局的次大元素必然选自 a_2 和 b_1 ，亦即：

$$\max(a_2, b_1)$$

若将该算法的运行时间记作 $T(n)$ ，则根据以上分析，可得边界条件及递推方程如下：

$$T(2) = 1$$

$$T(n) = 2 * T(n/2) + \boxed{2}$$

若令：

$$S(n) = [T(n) + 2]/n$$

则有：

$$S(n) = S(n/2) = S(n/4) = \dots = S(2) = 3/2$$

故有：

$$T(n) = \lceil 3n/2 \rceil - 2$$

比如，若利用以上算法从任意8个整数中找出最大、次大元素，则即便是在最坏情况下，也只需 $T(8) = 10$ 次比较操作。

请注意，这里的关键性技巧在于，为合并子问题的解，可以仅需2次而不是3次比较操作。否则，对应的递推关系应是：

$$T(n) = 2 * T(n/2) + \boxed{3}$$

解之即得：

$$T(n) = 2n - 3$$

仍以8个整数为例，在最坏情况下可能需要进行13次比较操作。

[2-41] 试证明，对于任一 $n \times m$ 的整数矩阵 M ，若首先对每一列分别排序，则继续对每一行分别排序后，其中的各列将依然有序（一个实例如图 x2.18 所示）。（提示：只需考查 $n = 2$ 的情况）

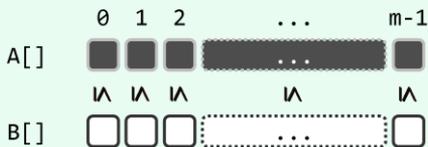
5	8	7	3	5	0	3	1	3	2	— 0 —	— 1 —	— 2 —	— 3 —	— 3 —
1	5	2	8	8	1	5	2	4	5	— 1 —	— 2 —	— 4 —	— 5 —	— 5 —
0	9	4	6	2	5	8	4	6	7	— 4 —	— 5 —	— 6 —	— 7 —	— 8 —
6	3	1	4	7	6	9	7	8	8	— 6 —	— 7 —	— 8 —	— 8 —	— 9 —

图x2.18 4×5的矩阵实例：经逐列排序再逐行排序后，每行、每列均各自有序

【解答】

因各行的排序独立进行，故只需证明以上命题对任意两行成立。

在已逐列排序的矩阵中，任取两行 $A[0, m)$ 和 $B[0, m)$ 。如图x2.19所示，不妨设 $A[]$ 位于 $B[]$ 之上方，于是在经逐列排序之后，对所有的 $0 \leq k < m$ 均有 $A[k] \leq B[k]$ 成立。

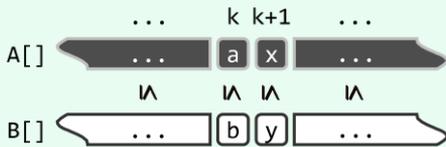


图x2.19 只需考查沿纵向捉对有序中的任意两行

以下将通过两种方法证明，在继而再做逐行排序之后，两行的元素沿纵向依然捉对有序。

【证法 A】

不妨假想地采用起泡排序算法，同步地对各行实施排序。如此只需证明，该算法每向前迭代一步， A 和 B 中的元素沿纵向依次捉对的有序性，依然继续保持。



图x2.20 起泡排序的每一步，都是考查一对相邻元素

实际上如图x2.20所示，在每一步迭代中，该算法都仅逐行考查同一对相邻元素，比如：

$$A[k] = a \text{ 和 } A[k + 1] = x$$

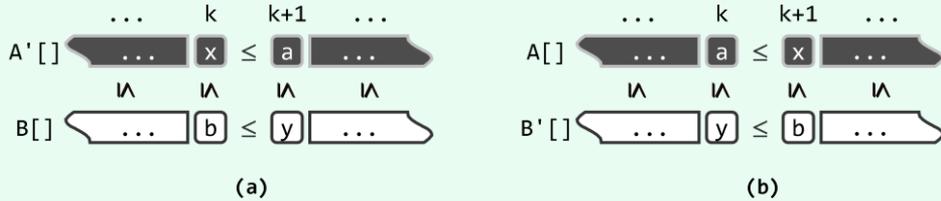
$$B[k] = b \text{ 和 } B[k + 1] = y$$

不妨假设，在此之前已有：

$$a \leq b \text{ 和 } x \leq y$$

经过此步迭代之后，尽管 a 和 x 可能互换位置， b 和 y 也可能互换位置，但总体而言无非四种情况。其中，对于两行均无交换和同时交换的情况，命题显然成立。

故以下如图x2.21所示，只需考查其中只有一行交换的两种情况。



图x2.21 只需考查仅有一行进行交换的两种情况：(a) a和x交换；(b) b和y交换

首先，设仅交换a和x。于是如图x2.21(a)所示，必有：

$$A'[k] = x \leq A'[k+1] = a \leq b = B[k] = B'[k]$$

$$A'[k+1] = a \leq b \leq y = B[k+1] = B'[k+1]$$

反之，设仅交换b和y。于是如图x2.21(b)所示，必有：

$$A'[k] = A[k] = a \leq A[k+1] = x \leq y = B'[k]$$

$$A'[k+1] = A[k+1] = x \leq y = B'[k] \leq b = B'[k+1]$$

原命题故此得证。

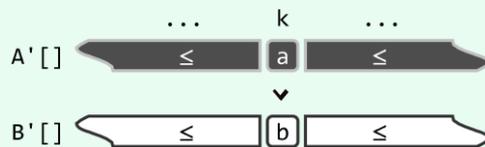
需特别强调的是，这里不能采用插入排序或选择排序等其它算法——它们与起泡排序不同，不能保证在排序过程中，各行之间能够严格同步地进行比较，故不能直接支持以上推导过程。

【证法B】

反证。假设如图x2.22所示，在经逐行排序之后有：

$$A'[k] = a > b = B'[k]$$

自然地，A[] (A'[]) 中的元素必然可以划分为两类：小于a的，以及不小于a的（含a本身）。而且，这两类元素互不重复，其总数应恰好为m。



图x2.22 假设逐行排序之后，沿纵向出现一对逆序元素a和b

然而根据以上假设条件，以下可以导出，这两类元素的总数不少于m + 1，从而导致悖论。

首先考查并统计小于a的元素。为此可以注意到以下事实：

$$B'[0, k] \leq B'[k] = b < a = A'[k]$$

这就意味着，对于B'[0, k]（亦来自于原B[]）中的每一元素，在原A[]中都应有一个不大于b（亦即小于a）的元素与之对应——也就是说，在A[]中至少有k + 1个元素小于a。

再来统计不小于a的元素。既然a ≤ A[k, m)，故A[]中至少有m - k个元素不小于a。

因此，两类元素合计总数至少应为：

$$(k + 1) + (m - k) = m + 1 > m$$

第3章

列表

[3-1] 考查列表结构的查找操作。

- a) 试针对教材 72 页代码 3.5 中的 `List::find()` ,以及 78 页代码 3.17 中的 `List::search()` ,就其在最好、最坏和平均情况下的效率做一分析对比 ;

【解答】

二者的效率完全一致:在最好情况下,均只需 $O(1)$ 时间;在最坏情况下,均需要 $O(n)$ 时间;平均而言,二者均需 $O(n)$ 时间。

- b) 有序性对于列表查找操作效率的提高有多大作用 ?

【解答】

由上可见,即便附加了有序性的条件,列表的查找效率也不能有实质的提高。究其原因在于,列表结构是通过位置来访问其中的元素——即“循位置访问”(call-by-position),这与向量的“循秩访问”(call-by-rank)迥然不同。

[3-2] 考查如教材 73 页代码 3.7 和 74 页代码 3.8 所示的列表节点插入算法 `ListNode::insertAsPred()` 和 `ListNode::insertAsSucc()`。

- a) 在什么情况下,新插入的节点既是首节点也是末节点 ?

【解答】

若将某元素插入当时为空的列表,则插入之后列表仅含单个节点(列表规模为1),该节点将同时扮演首节点和末节点的角色。

- b) 此时,这两种算法是否依然适用?为什么?试通过实测验证你的结论。

【解答】

教材所给的算法实现,在以上特殊情况下依然可行,能够顺利地完成插入操作。

之所以能够如此,是得益于这里在内部统一设置的哨兵节点(sentinel node)。如此插入的新节点,在列表内部居于头节点和尾节点之间。

[3-3] 考查如教材 75 页代码 3.11 所示的 `List::remove()` 算法。

当待删除的节点既是首节点也是末节点(即列表仅含单个节点)时,该算法是否依然适用?为什么?

【解答】

教材所给的算法实现,在以上特殊情况下依然可行,能够顺利地完成删除操作。

之所以能够如此,也是得益于内部的哨兵节点。当最后一个节点被删除之后,头节点和尾节点在列表内部彼此相邻,互为前驱和后继。

[3-4] 考查如教材 76 页代码 3.14 所示的 `List::deduplicate()` 算法。

a) 给出其中循环体所具有的不变性，并通过数学归纳予以证明；

【解答】

这里的不变性是：在迭代过程中的任意时刻，当前节点 `p` 的所有前驱互不相同。

算法启动之初，`p` 没有前驱，以上命题自然成立。

以下假定在当前迭代之后，不变性依然成立，考查随后的下一步迭代。

在此步迭代过程中，首先转至下一节点 `p`，并通过 `find()` 接口，在其前驱中查找与之雷同者。既然此前不变性是满足的，则与 `p` 雷同的元素至多仅有一个。这个雷同元素 `q` 若果真存在，则必然会被找到，并随即通过 `remove(q)` 接口被剔除。于是无论如何，以上不变性必然再次成立。

因此根据数学归纳原理，这一不变性将始终保持，直至算法结束。那时，`p` 即是列表的尾哨兵元素，其余元素均为它的前驱，由不变性可知它们必然互异。由此可见，该算法是正确的。

b) 试举例说明，该算法在最好情况下仅需 $O(n)$ 时间；

【解答】

当所有元素均彼此雷同时，即属于该算法的最好情况。此时，`deduplicate()` 算法依然需要执行 $O(n)$ 步迭代，但可以证明每一步只需 $O(1)$ 时间。

实际上，根据以上所指出的不变性，当前节点 `p` 始终只有 1 个前驱（并且与之雷同）。因此，每步迭代中的 `find()` 操作仅需常数时间。

由此也可顺便得出最坏情况——所有元素彼此互异。在此种情况下，当前节点 `p` 的前驱数目（亦即各次 `find()` 操作所对应的时间）将随着迭代的推进线性地递增，平均为 $O(n)$ ，算法总体的时间复杂度为 $O(n^2)$ 。

c) 试改进该算法，使其时间复杂度降至 $O(n \log n)$ ；

【解答】

最简明的一种改进方法是：首先调用 `sort()` 接口，借助高效的算法在 $O(n \log n)$ 时间内将其转换为有序列表；进而调用 `uniquify()` 接口，在 $O(n)$ 时间内剔除所有雷同元素。

d) $O(n \log n)$ 的效率是否还有改进的余地？为什么？

【解答】

就最坏情况下复杂度的意义而言，以上方法已属最优。

为证明这一结论，只需构造一个从元素唯一性（Element Uniqueness）问题，到列表排序问题的线性归约。请读者仿照此前第 2 章习题 [2-12]，自行给出具体的构造方法。

[3-5] 试基于列表的遍历接口 `traverse()` 实现以下操作（假定数据对象类型支持算术运算）：

a) `increase()`：所有元素数值加一；

【解答】

一种可行的实现方式，如代码 x3.1 所示。

```

1 template <typename T> struct Increase //函数对象：递增一个T类对象
2   { virtual void operator()(T& e) { e++; } }; //假设T可直接递增或已重载++
3
4 template <typename T> void increase(List<T> & L) //统一递增列表中的各元素
5 { L.traverse(Increase<T>()); } //以Increase<T>()为基本操作进行遍历

```

代码x3.1 基于遍历实现列表的increase()功能

与教材代码2.16中向量increase()接口的实现方式同理，这里也是将同一名为Increase()的函数对象作为基本操作，并通过遍历接口对列表的所有元素逐一处理。

b) half()：所有元素数值减半。

【解答】

一种可行的实现方式，如代码x3.2所示。

```

1 template <typename T> struct Half //函数对象：减半一个T类对象
2   { virtual void operator()(T& e) { e /= 2; } }; //假设T可直接减半
3
4 template <typename T> void half(List<T> & L) //统一减半列表中的各元素
5 { L.traverse(Half<T>()); } //以Half<T>()为基本操作进行遍历

```

代码x3.2 基于遍历实现列表的half()功能

与以上Increase的实现方式相仿，这里的关键依然在于定义一个名为Half的函数对象。

[3-6] 对数据结构的操作，往往都集中于数据元素的一个较小子集。因此对列表而言，若能将每次被访问的节点及时转移至查找长度更短的前端，则整体效率必将大为提高。这种能够自适应调整的列表，即所谓的自调整列表（self-adjusting list）。

试通过改造本章的List模板类，实现自适应列表结构。

【解答】

读者可以按照以下操作准则，独立完成改进：

- 1) 新元素总是作为首节点被插入；
- 2) 已有的元素一旦接受访问，也随即将其转移至最前端（作为首元素）。

通常的应用环境都具有较强甚至极强的数据局部性（data locality）——在其生命期的某一区间内，对列表结构的访问往往集中甚至限定于某一特定的元素子集。引入以上策略之后，子集中元素所对应的节点，很快会“自适应地”集中至列表的前端。在此后相当长的一段时间内，其余的元素几乎可以忽略。于是，在此期间此类列表的访问效率，将主要取决于该子集（而非整个全集）的规模，因此上述改进的实际效果非常好（参见教材8.1.1节）。

[3-7] 自学 C++ STL 中 list 容器的使用方法，阅读对应的源代码。

【解答】

请读者独立完成阅读任务。

[3-8] 考查插入排序算法。

a) 仿照教材 80 页代码 3.19, 针对向量实现插入排序算法 `Vector::insertionSort()`;

【解答】

请读者独立完成算法的设计与实现任务。

b) 你实现的插入排序算法是稳定的吗?为什么?

【解答】

请读者根据具体的实现方法, 给出分析及结论。

[3-9] 考查选择排序算法。

a) 仿照教材 81 页代码 3.20, 试针对向量结构实现选择排序算法 `Vector::selectionSort()`;

【解答】

一种可行的实现方式, 如代码x3.3所示。

```
1 template <typename T> //向量选择排序
2 void Vector<T>::selectionSort(Rank lo, Rank hi) { //assert: 0 < lo <= hi <= size
3     while (lo < --hi)
4         swap(_elem[max(lo, hi)], _elem[hi]); //将[hi]与[lo, hi]中的最大者交换
5 }
6
7 template <typename T>
8 Rank Vector<T>::max(Rank lo, Rank hi) { //在[lo, hi]内找出最大者
9     Rank mx = hi;
10    while (lo < hi--) //逆向扫描
11        if (_elem[hi] > _elem[mx]) //且严格比较
12            mx = hi; //故能在max有多个时保证后者优先, 进而保证selectionSort稳定
13    return mx;
14 }
```

代码x3.3 向量的选择排序算法

b) 你实现的选择排序算法是稳定的吗?为什么?

【解答】

是稳定的。

这里在未排序子向量中查找最大元素时, 总是自后向前地逆向扫描; 相应地, 唯有遇到严格更大的元素时, 才更新最大元素的记录。如此, 即便最大元素有重复的多个, 每次都必定会选中其中最靠后者(并进而将其转移至已排序子向量)。于是, 每一组重复的元素, 都将按照其在原向量中的相对位置依次转移, 从而最终保持它们之间的相对位置。

[3-10] 假定序列中 n 个元素的数值为独立均匀地随机分布，试证明：

a) 列表的插入排序算法平均需做约 $n^2/4 = \Theta(n^2)$ 次元素比较操作；

【解答】

首先，平均意义下的比较操作次数，也就是概率意义下比较操作的期望次数。

该算法共需执行 $\Theta(n)$ 步迭代，故根据期望值的线性律（linearity of expectation），比较操作总次数的期望值，应该等于各步迭代中比较操作次数的期望值之和。

该算法中的比较操作，主要消耗于对有序子列表的 `search()` 查找过程。

由 3.4.2 节的分析结论，`search()` 接口具有线性的平均复杂度。这就意味着，各步迭代内的 `search()` 过程所涉及的比较操作次数，应从 Θ 到 $n - 1$ 按算术级数线性递增，故其总和应为：

$$\sum_{k=\Theta}^{n-1} (k/2) = n \cdot (n - 1) / 4 = \Theta(n^2)$$

b) 向量的插入排序算法平均需做约 $n^2/4 = \Theta(n^2)$ 次元素移动操作；

【解答】

与列表不同，向量的插入排序中 `search()` 查找接口可以采用二分查找之类的算法，从而使其复杂度从线性降低至 $\Theta(\log n)$ 。

然而另一方面，在确定适当位置之后为将新元素插入已排序的子序列，尽管列表只需 $\Theta(1)$ 时间，但向量在最坏情况下我们不得移动 $\Theta(n)$ 个节点，而且平均而言亦是如此。故与 a) 同理，总体而言，平均共需执行 $\Theta(n^2)$ 次元素移动操作。

由这个例子，可清楚地看出两种数据访问方式各自的长处：循秩访问的方式更适宜于静态的查找操作，但在频繁动态修改的场合却显得效率低下；循位置访问的方式更适宜于动态修改，却不能高效地支持静态查找。

向量结构与列表结构所呈现的这种对称性，既非常有趣，更耐人寻味。

c) 序列的插入排序算法过程中平均有 $\text{expected-}\Theta(\log n)$ 个元素无需移动。

【解答】

同样地，既然该算法由多步迭代构成，故其间无需移动的元素期望数目，就应该等于各步迭代中，待插入元素无需移动的概率总和。

根据该算法的原理，对于任意 $k \in [\Theta, n)$ ，在第 k 步迭代启动之初，当前元素 $A[k]$ 的 k 个前驱应该业已构成一个有序的子序列 $A[\Theta, k)$ 。不难看出，若 $A[k]$ 无需移动即使得 $A[\Theta, k]$ 仍为有序子序列，则其充要条件是， $A[k]$ 在 $A[\Theta, k]$ 中为最大元素。

既然假定所有元素都符合独立且均匀的随机分布，故作为前 $k + 1$ 个输入元素中的普通一员， $A[k]$ 在其中为最大元素的概率应与其它元素均等，都是 $1/(k + 1)$ 。于是，这一概率的总和即为：

$$\sum_{k=\Theta}^{n-1} 1/(k + 1) = \sum_{k=1}^n 1/k = \Theta(\log n)$$

[3-11] 序列中元素 $A[i]$ 和 $A[j]$ 若满足 $i < j$ 且 $A[i] > A[j]$, 则称之为一个逆序对 (inversion)。

考查如教材 80 页代码 3.19 所示的插入排序算法 `List::insertionSort()`, 试证明:

a) 若所有逆序对的间距均不超过 k , 则运行时间为 $O(kn)$;

【解答】

算法进入到 $A[j]$ 所对应的那步迭代时, 该元素 (在输入序列中) 的所有前驱应该业已构成一个有序子序列 $A[0, j)$ 。既然其中至多只有 k 个元素与 $A[j]$ 构成逆序对, 故查找过程 `search()` 至多扫描其中的 k 个元素, 即可确定适当的插入位置, 对应的时间不超过 $O(k)$ 。

实际上, 每一步迭代均具有如上性质, 故累计运行时间不超过 $O(kn)$ 。

在教材 12.3 节对希尔排序高效性的论证中, 这一结论将至关重要。

b) 特别地, 当 k 为常数时, 插入排序可在线性时间内完成;

【解答】

这也就是 a) 中结论的一个自然推论。

c) 若共有 I 个逆序对, 则关键码比较的次数不超过 $O(I)$;

【解答】

这里定义的每一逆序对, 均涉及两个元素。为便于分析, 这里约定将其计入后者的“账”上。因此, 所有元素的逆序前驱的数目总和, 应恰好等于 I 。

将 a) 中的分析方法作一般化推广, 即不难看出: 每个元素所涉及比较操作的次数, 应恰好等于其逆序前驱的数目; 整个算法过程中所执行的比较操作的总数, 应恰好等于所有元素的逆序前驱的数目总和, 亦即 I 。

d) 若共有 I 个逆序对, 则运行时间为 $O(n + I)$ 。

【解答】

由以上分析, 算法过程中消耗于比较操作的时间可由 $O(I)$ 界定, 而消耗于移动操作的时间可由 $O(n)$ 界定, 二者累计即为 $O(n + I)$ 。

既然此处实际的运行时间更多地取决于逆序对的数目, 而不仅仅是输入序列的长度, 故插入排序亦属于所谓输入敏感的 (input sensitive) 算法。

实际上更为精确地, 每步迭代中的查找都是以失败告终——或者找到不大于当前元素者, 或者抵达 $A[-1]$ 越界。若将这两类操作也归入比较操作的范畴, 则还有一个 $O(n)$ 项。好在就渐进意义而言, 这一因素可以忽略。

[3-12] 如教材 80 页代码 3.19 所示, 考查插入排序算法 `List::insertionSort()`。

a) 若输入列表为 $\{ 61, 60, 59, \dots, 5, 4, 3, 2, 0, 1, 2 \}$, 则共需要做多少次关键码比较?

【解答】

这里的关键在于, 如何统计出查找过程 `search()` (教材 78 页代码 3.17) 在该算法各步迭代中所执行的比较操作次数。

具体如表x3.1所示，列表结构中的头、尾哨兵，分别等效于元素 $-\infty$ 和 $+\infty$ ；已排序的子序列，用阴影表示；在当前迭代步经查找并归入排序子序列的元素，用方框注明。

就此例而言，共计63个元素，故对应于63步迭代，依次从0至62编号，各对应于一行。

表x3.1 列表{ 61, 60, 59, ..., 5, 4, 3, 2, 0, 1, 2 }的插入排序过程

迭代编号	列表元素														比较次数
0	$-\infty$	61	60	59	58	...	5	4	3	2	0	1	2	$+\infty$	1
1	$-\infty$	60	61	59	58	...	5	4	3	2	0	1	2	$+\infty$	2
2	$-\infty$	59	60	61	58	...	5	4	3	2	0	1	2	$+\infty$	3
3	$-\infty$	58	59	60	61	...	5	4	3	2	0	1	2	$+\infty$	4
...	$-\infty$								$+\infty$...
56	$-\infty$	5	6	7	8	...	61	4	3	2	0	1	2	$+\infty$	57
57	$-\infty$	4	5	6	7	...	60	61	3	2	0	1	2	$+\infty$	58
58	$-\infty$	3	4	5	6	...	59	60	61	2	0	1	2	$+\infty$	59
59	$-\infty$	2	3	4	5	...	58	59	60	61	0	1	2	$+\infty$	60
60	$-\infty$	0	2	3	4	...	57	58	59	60	61	1	2	$+\infty$	61
61	$-\infty$	0	1	2	3	...	56	57	58	59	60	61	2	$+\infty$	61
62	$-\infty$	0	1	2	2	...	55	56	57	58	59	60	61	$+\infty$	60

由该表可以看出，第0步迭代经过一次（当前元素61与头哨兵 $-\infty$ 的）比较，即可确定其适当的插入位置——当然，此步的插入操作其实可以省略，但为简化控制逻辑，算法中不妨统一处理。实际上，从第0步至第60步迭代所插入的元素，在当时都是最小的，故每一查找过程search()都会终止于头哨兵 $-\infty$ ，而新元素都会被转移至最前端作为首元素。由此可见，这些迭代步所对应的比较次数，应从1至61逐步递增。

最后两步迭代原理一样，但过程与结果略有区别。第61步迭代中的查找过程search()需做61次比较，最后终止于节点0。第62步迭代中的查找过程search()需做60次比较，最后终止于节点2。请特别留意，最后一步迭代对两个雷同元素2的处理方式——既然search()算法是稳定的，故后一元素2应被插入于前一元素2之后。

累计以上各步迭代，比较操作的总次数应为：

$$(1 + 2 + 3 + \dots + 60 + 61) + 61 + 60 = 2012$$

利用此前“插入排序算法复杂度主要取决于逆序对总数”的结论，也可得到同一结果。诚如前言，我们不难验证：以上各步迭代中所做比较操作的次数，恰好就是（在输入序列中）与当前元素构成逆序对的前驱总数。具体地，对于前61个元素：

$$\{ 61, 60, 59, \dots, 3, 2, 0 \}$$

而言，逆序前驱数依次为：

$$\{ 0, 1, 2, \dots, 58, 59, 60 \}$$

而对于最后两个元素：

{ 1, 2 }

而言，逆序前驱数分别为：

{ 60, 59 }

因此，原输入序列所含逆序对的总数应为：

$$I = (0 + 1 + 2 + \dots + 59 + 60) + 60 + 59 = 1949$$

再计入每个元素所对应的最后一次失败的比较，该算法累计执行的比较操作次数应为：

$$I + n = 1949 + 63 = 2012$$

可见，两种方法殊途同归。

b) 试通过实实验证你的结论。

【解答】

只需在查找过程 `search()` 中，在执行比较操作的同时计数，查找返回时打印所记次数即可。

[3-13] 教材 81 页代码 3.20 中的 `List::selectionSort()` 算法，通过 `selectMax()` 在前端子序列中定位最大元素 `max` 之后，将其对应的节点整体取出，再后移并归至后端子序列之首。

这一过程中的 `remove()` 和 `insertBefore()` 接口涉及节点存储空间的动态释放 (`delete`) 与申请 (`new`)，二者虽均属于 $O(1)$ 复杂度的基本操作，但根据实验统计，此类操作实际所需的时间较之一般的基本操作多出两个数量级。其实，教材 80 页的图 3.6 已暗示了一个更好的实现方式：只需令 `max` 与前端子序列的末元素互换数据项即可。

a) 试按照这一思路，在代码 3.20 的基础上完成改进；

【解答】

题中对改进方法已做了足够清楚的描述，请读者照此思路独立完成。

b) 通过实际测试统计验证，新的版本的确比代码 3.20 更加高效。

【解答】

请读者根据自己的改进方法，独立完成。

[3-14] 教材 81 页代码 3.20 中的 `List::selectionSort()` 算法，通过 `selectMax()` 在前端子序列中定位的最大元素 `max`，有可能恰好就是 `tail` 的前驱——自然，此时“二者”无需交换。针对这一“问题”，你可能会考虑做些“优化”，以期避免上述不必要的交换，比如将

```
insertBefore(tail, remove(max));
```

一句改为

```
if (tail->pred != max) insertBefore(tail, remove(max));
```

a) 以序列{ 1980, 1981, 1982, ..., 2011, 2012; 0, 1, 2, ..., 1978, 1979 }为例, 这种情况共发生多少次?

【解答】

我们首先引入循环节 (cycle) 的概念。

考查序列 $A[0, n)$ 以及与之对应的排序序列 $S[0, n)$ 。若存在

$$0 \leq \{ k_0, k_1, k_2, \dots, k_{d-1} \} < n$$

使得对于任意 $0 \leq i < d$, 都有

$$A[k_i] = S[k_{(i+1) \bmod d}]$$

则称对于序列 $A[0, n)$ 而言, $\{ k_0, k_1, k_2, \dots, k_{d-1} \}$ 构成 $[0, n)$ 的一个循环节。

以本题所给的序列为例, 不难验证有:

$$A[1980] = 1947 = S[1947]$$

$$A[1947] = 1914 = S[1914]$$

$$A[1914] = 1881 = S[1881]$$

...

$$A[66] = 33 = S[33]$$

$$A[33] = 0 = S[0]$$

$$A[0] = 1980 = S[1980]$$

因此相对于该序列, 以下即为一个循环节:

$$\{ 1980, 1947, 1914, \dots, 66, 33, 0 \}$$

这是一个等差数列, 公差为33, 总计的项数 (即该循环节的长度) 为:

$$d = (1980 - 0) / 33 + 1 = 61$$

不难理解, 每个元素都应属于某个循环节 (长度可能为1), 但不可能同时属于两个循环节。这就意味着, 按照上述定义, 任何序列都可以唯一地分解为若干个彼此独立的循环节。

接下来, 我们重新审视选择排序算法`List::selectionSort()`的每一步迭代, 假设被选出的最大元为 $A[m]$ 。不难看出, 将 m 转移至`tail`之前的效果, 等同于该元素所属的循环节长度减一; 而其它元素所属循环节的长度不变。当然, 若该循环节的长度减至0, 则意味着该循环节消失。

特别地, 若题中所建议的“优化”能够生效, 则此时的 $A[m]$ 就是排序序列中的 $S[m]$; 这就意味着, $A[m]$ 必然自成一个 (长度为1的) 循环节。反之, 一旦 $A[m]$ 所属循环节的长度缩减至1, 则“优化”也必然生效。由此可见, 该“优化”措施恰好对每个循环节生效一次; 而在整个算法过程中生效的总次数, 应恰好等于输入序列所含循环节的数目。

现在, 我们再回到本题。根据上述分析结论, 我们只需统计出题中所给序列中的循环节总数。

实际上就这一序列而言, $[0, 2012]$ 范围内每一个公差为33的等差数列, 均构成一个循环节。而且, 因为有:

$$2013 = 33 \times 61$$

所以与上面所指出的那个循环节一样, 每个循环节的长度均为61, 共计33个循环节。

更精细地考查代码可以发现, 在处理到最后一个循环节的最后一个元素 (当时的 $A[0] = 0$)

时，该算法会直接退出而不会继续选取最大元并做移动，故上述“优化”生效的实际次数为：

$$33 - 1 = 32$$

b) 试证明，在各元素等概率独立分布的情况下，这种情况发生的概率仅为 $1/n \rightarrow 0$ ——也就是说，就渐进意义而言，上述“优化”得不偿失。

【解答】

继续考查列表的选择排序算法后不难发现，在A[m]所属循环节消失之前的瞬间，A[m]应为A[0, m]中的最大元。鉴于此前的A[0, m]一直符合独立且均匀的随机分布，故发生这一事件的概率应与区间[0, m]的长度成反比。

进一步地，再次根据期望值的线性律（linearity of expectation），在n次循环中发生这种情况的期望次数，应等于各步迭代中发生这一事件的概率总和，亦即：

$$1/n + 1/(n - 1) + 1/(n - 2) + \dots + 1/3 + 1/2 + 1/1 = \Theta(\ln n)$$

[3-15] 在如教材 82 页代码 3.21 所示的 List::selectMax() 算法中，若将判断条件由

```
!lt((cur = cur->succ)->data, max->data)
```

改为

```
lt(max->data, (cur = cur->succ)->data)
```

则如代码 3.20 所示的 selectionSort() 算法的输出有何变化？试举一例。

【解答】

教材所给的算法，是按从前（左）向后（右）的次序扫描各元素，再将选出来的当前最大元后移，并归入已排序的后缀子序列。就其语义而言，题中的两个逻辑表达式都旨在指示“当前的最大元记录需要更新”，故都能保证正确地挑选出最大元。然而在有多个雷同的最大元时，二者之间却又存在着细微而本质的差异。

按照前一逻辑表达式，在同时存在多个最大元时，算法总是会选出其中的最靠后（右）者。因此，原序列中雷同元素之间的相对次序，将在排序后的序列中得以延续。反之，若调整为后一逻辑表达式，则在同时存在多个最大元时，算法总是会选出其中的最靠前（左）者。如此，雷同元素在最终输出序列中的次序，将会完全颠倒。

比如，对于如下输入序列：

```
{ 5, 3a, 9, 3b, 3c, 2 }
```

若采用后一逻辑表达式，则对应的输出序列将是：

```
{ 2, 3c, 3b, 3a, 5, 9 }
```

而若采用前一逻辑表达式，则对应的输出序列将是：

```
{ 2, 3a, 3b, 3c, 5, 9 }
```

由上可见，就对雷同元素的处理方式而言，教材所给的算法实现更为精细和恰当，可以保证以selectMax()为基础的选择排序算法selectionSort()是稳定的。

[3-16] 考查如教材 83 页代码 3.23 所示的 `List::mergeSort()` 算法，试证明：

- a) 若为节省每次子列表的划分时间，而直接令 $m = \min(c, n/2)$ ，其中 c 为较小的常数（比如 5），则总体复杂度反而会上升至 $O(n^2)$ ；

【解答】

做如此调整之后，在切分出来的两个子列表中，必有其一的长度不超过 c ，而另一个的长度不小于 $n - c$ 。尽管如此可以在 $O(c)$ 时间内完成子任务的划分，但二路归并仍需 $O(n)$ 时间，因此其对应的递推方程应为：

$$T(n) = T(c) + T(n - c) + O(n)$$

解之可得：

$$T(n) = O(n^2)$$

- b) 特别地，当取 $c = 1$ 时，该算法等效地退化为插入排序。

【解答】

此时，参与二路归并的每一对子列表中，总有一个长度为 1。故就实际效果而言，原算法的二路递归将退化为单分支的线性递归，“归并”操作将等同于将单个元素插入至另一子列表中。因此，整个计算过程及效果均完全等同于插入排序。

[3-17] 考查基于 `List::merge()` 算法（教材 82 页代码 3.22）实现的 `List::mergeSort()` 算法（教材 83 页代码 3.23）。

该算法是稳定的吗？若是，请给出证明；否则，试举一实例。

【解答】

是稳定的。为证明这一点，只需证明雷同元素之间的相对次序在输出序列中依然保持。

不妨采用数学归纳法。假定在每一次二路归并过程中，上述命题对任何长度短于 L 的列表都成立。以下考查长度为 L 的列表。

考查 `List::merge()` 算法中两个子列表的当前节点 p （左）和 q （右）。根据这里的逻辑条件，只要 p 不大于 q ，都会将 p 取出并归入输出列表；即便 p 和 q 相等， p 也会先于 q 转入输出列表。也就是说，与 p 和 q 雷同的所有元素之间的相对次序将会得以延续。

[3-18] 试仿照教材 22 页代码 1.10 中向量的倒置算法，实现 `List::reverse()` 接口，将列表中元素的次序前后倒置。

【解答】

这里，由繁至简给出该算法的三种实现方式。

第一种实现方式如代码 x3.4 所示。

```
1 template <typename T> void List<T>::reverse() { //前后倒置
2     if (_size < 2) return; //平凡情况
3     ListNodePosi(T) p; ListNodePosi(T) q;
```

```

4   for (p = header, q = p->succ; p != trailer; p = q, q = p->succ)
5       p->pred = q; //自前向后,依次颠倒各节点的前驱指针
6   trailer->pred = NULL; //单独设置尾节点的前驱指针
7   for (p = header, q = p->pred; p != trailer; p = q, q = p->pred)
8       q->succ = p; //自前向后,依次颠倒各节点的后继指针
9   header->succ = NULL; //单独设置头节点的后继指针
10  swap(header, trailer); //头、尾节点互换
11 }

```

代码x3.4 列表倒置算法的第一种实现

这里,借助两个指针逐一处理相邻的各对节点。首先通过一趟遍历,自前向后地依次颠倒各节点的前驱指针(使之指向当前的后继)。接下来再通过一趟遍历,自前向后地依次颠倒各节点的后继指针(使之指向此前的前驱)。当然,在两趟遍历之后,还需要单独地设置尾节点的前驱指针、头节点的后继指针。至此,所有节点的排列次序均已完全颠倒,故最后只需交换头、尾节点的指针,即可实现整体倒置的效果。

第二种实现方式如代码x3.5所示。

```

1  template <typename T> void List<T>::reverse() { //前后倒置
2      if (_size < 2) return; //平凡情况
3      for (ListNodePosi(T) p = header; p; p = p->pred) //自前向后,依次
4          swap(p->pred, p->succ); //交换各节点的前驱、后继指针
5      swap(header, trailer); //头、尾节点互换
6  }

```

代码x3.5 列表倒置算法的第二种实现

这里仅需使用一个指针p。借助该指针,自前向后地对整个列表做一趟遍历,并令每个节点的前驱、后继指针互换。同样地,最后还需令头、尾节点的指针互换。

第三种实现方式如代码x3.6所示。

```

1  template <typename T> void List<T>::reverse() { //前后倒置
2      ListNodePosi(T) p = header; ListNodePosi(T) q = trailer; //头、尾节点
3      for (int i = 1; i < _size; i += 2) // (从首、末节点开始)由外而内,捉对地
4          swap((p = p->succ)->data, (q = q->pred)->data); //交换对称节点的数据项
5  }

```

代码x3.6 列表倒置算法的第三种实现

这一实现方式的思路与策略,与教材代码1.10中的倒置算法如出一辙。具体地,这里通过一轮迭代,从首、末节点开始由外而内,捉对地交换各对称节点的数据项。

指针p和q始终指向一对位置对称的节点。请注意,尽管其初值分别为头、尾哨兵节点,但进入迭代之后,它们所指向的都是对外可见的有效节点。

无论以上何种实现，计算过程无非都是一或两趟遍历迭代，每一步迭代都只涉及常数次基本操作，因此整体的时间复杂度均为 $O(n)$ 。另外，除了列表本身，这些实现方式均只需常数的辅助空间，故也都属于就地算法。

综合而言，最后一种实现方式的形式更为简明，但若基础数据类型T本身较为复杂，则节点data项的直接交换可能导致耗时的构造、析构运算。而前两种实现方式虽形式略嫌复杂，但因为仅涉及指针赋值，故在基础类型T较为复杂的场合将更为高效。

[3-19] Josephus 环游戏的规则如下：

一个刚出锅的山芋，在围成一圈的 n 个孩子间传递。大家一起数数，每数一次，当前拿着山芋的孩子就把山芋转交给紧邻其右的孩子。一旦数到事先约定的某个数 k ，拿着山芋的孩子即退出，并从该位置起重新数数。如此反复，最后剩下的那个孩子就是幸运者。

a) 试实现算法 `josephus(int n, int k)`，输出孩子们出列的次序，并确定最终的幸运者；

【解答】

在本章所实现列表结构的基础上做扩展，使之成为所谓的循环列表（Circular list）。也就是说，首节点的前驱取作末节点，末节点的后继取作首节点。于是，无论是通过前驱还是后继引用，都可以反复地遍历整个列表。

初始时，将 n 个孩子组织为一个循环列表。此后借助后继引用，不难找到下一出列的孩子；其出列的动作，及对应于删除与之对应的节点。如此不断反复。

b) 该算法的时间、空间复杂度各是多少？

【解答】

整个算法所需的空间主要消耗于循环列表，其最大规模不过 $O(n)$ 。因为这里无需使用前驱引用，故实际上空间消耗还可进一步减少，但渐进地依然是 $O(n)$ 。

算法的执行时间，主要消耗于对游戏过程的模拟。每个孩子出列之前，都需沿着后继引用前进 k 步，故累计需要 $O(n \cdot k)$ 时间。

当然，在 $n < k$ 时，可以通过取“ $k \% n$ ”，进一步加快模拟过程。如此，时间复杂度应为：

$$O(n \cdot \text{mod}(k, n)) = O(n^2)。$$

第4章

栈与队列

[4-1] a) 试基于 3.2.2 节的列表模板类 List, 实现栈结构;**【解答】**

仿照教材中由Vector类派生Stack类的方法, 也可如代码x4.1所示由List类派生Stack类。

```

1 #include "../List/List.h" //以列表为基类, 派生出栈模板类
2 template <typename T> class Stack: public List<T> { //将列表的首/末端作为栈顶/底
3 public: //size()、empty()以及其它开放接口, 均可直接沿用
4     void push(T const& e) { insertAsLast(e); } //入栈: 等效于将新元素作为列表的首元素插入
5     T pop() { return remove(last()); } //出栈: 等效于删除列表的首元素
6     T& top() { return last()->data; } //取顶: 直接返回列表的首元素
7 };

```

代码x4.1 由List类派生Stack类

这里直接将列表结构视作栈结构, 并借助List类已有的操作接口, 实现Stack类所需的操作接口。具体地, 列表的头部对应于栈底, 尾部对应于栈顶。于是, 栈顶元素总是与列表的末节点相对应; 为将某个元素压入栈中, 只需将其作为末节点加至列表尾部; 反之, 为弹出栈顶元素, 只需删除末节点, 并返回其中存放的元素。

请注意, 这里还同时默认地继承了List类的其它开放接口, 但它们的语义与Vector类所提供的同名操作接口可能不尽相同。比如查找操作, List::find()通过返回值(位置)为NULL来表示查找失败, 而Vector()则是通过返回值(秩)小于零来表示查找失败。因此在同时还使用了这些接口的算法中, 需要相应地就此调整代码实现。

比如, 在基于栈结构实现的八皇后算法placeQueens() (教材101页代码4.9)中, (局部)解存放于栈solu中, 一旦经过solu.find(q)操作确认没有冲突, 即加入一个皇后。教材中所实现版本中的栈结构派生自Vector类, 故可通过检查find()所返回的秩是否非负来判定查找是否成功。若改由List类派生出栈结构, 则需相应地调整此句——我们将此留给读者独立完成。

另外, 将列表节点与栈元素之间的对应次序颠倒过来, 从原理上讲也是可行的。但是, 同样出于以上考虑, 我们还是更加倾向于采用以上的对应次序。如此, 栈中元素的逻辑次序与它们在向量或列表中的逻辑次序一致, 从而使得栈的标准接口之外的接口具有更好的兼容性。

以hanoi()算法(17页代码x1.13)为例, 为了显示盘子移动的过程, 必须反复地遍历栈中的元素(盘子)。若采用与代码x4.1相反的对对应次序, 则针对栈基于Vector和List的两种实现, 需要分别更改显示部分的代码; 反之, 则可以共享同一份代码。

b) 按照你的实现方式, 栈 ADT 各接口的效率如何?**【解答】**

对于如代码x4.1所示实现的栈结构, 各操作接口均转换为常数次列表的基本操作, 故与基于向量派生的栈结构一样, 所有接口各自仅需 $O(1)$ 时间。

[4-2] a) 试基于 2.2.3 节的向量模板类 Vector, 实现队列结构;

【解答】

仿照以上基于 List 实现栈结构的方法与技巧, 请读者独立完成。

b) 在实现过程中你遇到了哪些困难? 你是如何解决的?

【解答】

请读者结合自己的实现过程, 独立给出解答。

[4-3] 设 B 为 $A = \{ 1, 2, 3, \dots, n \}$ 的任一排列。

a) 试证明, B 是 A 的一个栈混洗, 当且仅当对于任意 $1 \leq i < j < k \leq n$, P 中都不含如下模式:

$$\{ \dots, k, \dots, i, \dots, j, \dots \}$$

【解答】

先证明“仅当”。为此可以采用反证法。

首先请注意, 对于输入序列中的任意三个元素, 其在输出序列中是否存在一个可行的相对排列次序, 与其它元素无关。因此不妨只关注这三个元素 $\{ i, j, k \}$ 。

接下来可注意到, 无论如何, 元素 i 和 j 必然先于 k (弹出栈 A 并随即) 压入中转栈 S 。若输出序列 $\{ k, i, j \}$ 存在, 则意味着在此三个元素中, k 必然首先从栈 S 中弹出。而在 k 即将弹出之前的瞬间, i 和 j 必然已经转入栈 S ; 而且根据“后进先出”的规律, 三者栈 S 中 (自顶向下) 的次序必然是 $\{ k, j, i \}$ 。这就意味着, 若要 k 率先从栈 S 中弹出, 则三者压入输出栈 B 的次序必然是 $\{ k, j, i \}$, 而不可能是 $\{ k, i, j \}$ 。

既然以上规律与其余元素无关, $\{ k, i, j \}$ 即可视作判定整体输出序列不可行的一个特征, 我们不妨称之为“禁形” (forbidden pattern)。

再证明“当”。

实际上只要按照算法 x4.1, 则对于不含任何禁形的输出序列, 都可给出其对应的混洗过程。

```
stackPermutation(B[1, n]) { //B[]为待甄别的输出序列, 其中不含任何禁形
    Stack S; //辅助中转栈
    int i = 1; //模拟输入栈A (的栈顶元素)
    for k = 1 to n { //通过迭代, 依次输出每一项B[k]
        while (S.empty() || B[k] != S.top()) //只要B[k]仍未出现在S栈顶
            S.push(i++); //就反复地从栈A中取出顶元素, 并随即压入栈S
        //assert: 只要B[]的确不含任何禁形, 则以上迭代就不可能导致栈A的溢出
        //assert: 以上迭代退出时, S栈必然非空, 且S的栈顶元素就是B[k]
        S.pop(); //因此, 至此只需弹出S的栈顶元素, 即为我们所希望输出的B[k]
    }
}
```

算法x4.1 确认不含任何禁形的序列都是栈混洗

该算法尽管包含两重循环，但其中实质的push()和pop()操作均不超过 $O(n)$ 次，故其总体时间复杂度应线性正比于输入序列的长度。

算法x4.1只需略作修改，即可实现对栈混洗的甄别：对于 $\{1, 2, 3, \dots, n\}$ 的任一排列，判定其是否为栈混洗。请读者参照以上分析以及注释，独立完成此项工作。当然，你所改进的算法，必须依然具有 $O(n)$ 的时间复杂度。

b) 若对任意 $1 \leq i < j < n$, B 中都不含模式：

$\{ \dots, j + 1, \dots, i, \dots, j, \dots \}$

则 B 是否必为 A 的一个栈混洗？若是，试给出证明；否则，试举一反例。

【解答】

可以证明此类序列B必为A的一个栈混洗，故亦可将：

$\{ j + 1, i, j \}$

视作新的一类禁形。为此，不妨将：

$\{ k, i, j \}$

$\{ j + 1, i, j \}$

分别称作“915”式禁形、“615”式禁形。

显然，此类禁形是a)中禁形的特例，故只需证明“当”：只要B中含有“915”式禁形，则必然也含有“615”式禁形——当然，两类禁形中的i和j未必一致。

以下做数学归纳。假定对于任何的 $k - i < d$ ，以上命题均成立，考查 $k - i = d$ 的情况。

不妨设 $i < j < k - 1$ ，于是元素 $k - 1$ 在B中相对于i的位置无非两种可能：

1) $k - 1$ 居于i的左侧（前方）

此时， $\{ k - 1, i, j \}$ 即为“915”式禁形，由归纳假设，必然亦含有“615”式禁形。

2) $k - 1$ 居于i的右侧（后方）

此时， $\{ k, i, k - 1 \}$ 即构成一个“615”式禁形。

c) 若对任意 $1 < j < k \leq n$, B 中都不含模式

$\{ \dots, k, \dots, j - 1, \dots, j, \dots \}$

则 B 是否必为 A 的一个栈混洗？若是，试给出证明；否则，试举一反例。

【解答】

此类序列B未必是A的一个栈混洗，故不能将“945”式特征：

$\{ k, j - 1, j \}$

称作禁形。作为反例，不妨考查序列：

$B[] = \{ 2, 4, 1, 3 \}$

不难验证，其中不含任何的“945”式模式（ $\{ 3, 1, 2 \}$ 、 $\{ 4, 1, 2 \}$ 、 $\{ 4, 2, 3 \}$ ）。但反过来，若对序列B[]应用算法x4.1，却将导致错误（请读者独立验证这一点，并指出错误的位置及原因），这说明该序列并非A的栈混洗。

当然，作为对b)中结论的又一次验证，不难看出该序列的确包含“615”式禁形：

{ 4, 1, 3 }

[4-4] 设 $S = \{ 1, 2, 3, \dots, n \}$ ，试证明：

a) S 的每个栈混洗都分别对应于由 n 对括号组成的一个合法表达式，且反之亦然；

【解答】

采用数学归纳法。

假设以上命题对少于 n 对括号的表达式（以及长度短于 n 的序列）均成立，现考查 n 的情况。

我们令混洗操作序列中的push/pop操作，与表达式中的左/右括号彼此对应。于是，在任意合法的表达式中，必然存在一对紧邻的左、右括号；相应地，在栈混洗对应的栈操作序列中，也必然存在一对紧邻的push和pop操作。进一步地，将这对括号从表达式中删除后，依然得到一个表达式——只不过长度减二；将这对push和pop操作删除后，也依然得到一个栈混洗所对应的栈操作序列——其长度亦减二。由归纳假设，缩短后的表达式与栈混洗彼此对应。

b) S 共有 $Catalan(n) = (2n)!/(n+1)!/n!$ 个栈混洗。

【解答】

根据以上结论，只需统计 n 对括号所能组成的合法表达式数目 $T(n)$ 。

由 n 对括号组成的任一合法表达式 S_n ，都可唯一地分解和表示为如下形式：

$$S_n = (S_k)S_{n-k-1}$$

其中， S_k 和 S_{n-k-1} 均为合法表达式，且分别由 k 和 $n - k - 1$ 对括号组成。

鉴于 k 的取值范围为 $[0, n)$ ，故有如下边界条件和递推式：

$$\begin{aligned} T(0) &= T(1) = 1 \\ T(n) &= \sum_{k=0}^{n-1} T(k) \cdot T(n-k-1) \end{aligned}$$

这是典型的Catalan数式递推关系，解之即得题中结论。

[4-5] Internet 超文本 HTML 文档，由成对出现的标志 (tag) 划分为不同的部分与层次。

类似于括号，与起始标志 $\langle myTag \rangle$ 相对应地，结束标志为 $\langle /myTag \rangle$ 。

常用的 HTML 标志有：文档体 ($\langle body \rangle$ 和 $\langle /body \rangle$)、节的头部 ($\langle h1 \rangle$ 和 $\langle /h1 \rangle$)、左对齐 ($\langle left \rangle$ 和 $\langle /left \rangle$)、段落 ($\langle p \rangle$ 和 $\langle /p \rangle$)、字体 ($\langle font \rangle$ 和 $\langle /font \rangle$) 等。

a) 试拓展 paren() 算法 (教材 93 页代码 4.5)，以支持对以上 HTML 标志的嵌套匹配检查；

【解答】

增加switch结构的分支，对每一种HTML标志，都相应地增加一条case语句，且处理方式与paren()算法已给出的分支完全一致。具体的实现请读者独立完成。

b) 继续扩展，以支持对任意“ $\langle myTag \rangle \dots \langle /myTag \rangle$ ”形式标志的嵌套匹配检查。

【解答】

此时，实际上需要处理的匹配括号有无数种，故显然不能简单地逐个增加一条语句。

一种可行的方法需要借助栈结构。具体地，每当遇到一个<myTag>标记，即令其入栈（相当于左括号）。每当遇到一个</myTag>标记，即与当前栈顶处的标记比对。倘若二者匹配，则弹出栈顶标记，然后继续读入并处理下一标记；否则，即可断定该文本（至少）在此处出现失配。

当然，待整个HTML文本扫描完毕，还需再次检查辅助栈。此时唯有栈为空，方可判定整个文本中的标记完全匹配。

[4-6] 教材 95 页代码 4.7 中的 evaluate() 算法，需借助 readNumber() 函数，根据当前字符及其后续的若干字符，解析出当前的操作数。试实现该函数。

【解答】

一种可行的实现方式，如代码x4.2所示。

```

1 void readNumber(char*& p, Stack<float>& stk) { //将起始于p的子串解析为数值，并存入操作数栈
2     stk.push((float)(*p - '0')); //当前数位对应的数值进栈
3     while (isdigit(*(++p))) //只要后续还有紧邻的数字（即多位整数的情况），则
4         stk.push(stk.pop() * 10 + (*p - '0')); //弹出原操作数并追加新数位后，新数值重新入栈
5     if ('.' != *p) return; //此后非小数点，则意味着当前操作数解析完成
6     float fraction = 1; //否则，意味着还有小数部分
7     while (isdigit(*(++p))) //逐位加入
8         stk.push(stk.pop() + (*p - '0')*(fraction /= 10)); //小数部分
9 }

```

代码x4.2 操作数的解析

[4-7] 教材 95 页代码 4.7 中的 evaluate() 算法，需借助 orderBetween(op1, op2) 函数，判定操作符 op1 和 op2 之间的优先级关系。试利用如代码 4.6（教材 94 页）所示的优先级表，实现该函数。

【解答】

一种可行的实现方式，如代码x4.3所示。

```

1 Operator optr2rank(char op) { //由运算符转译出编号
2     switch (op) {
3         case '+': return ADD; //加
4         case '-': return SUB; //减
5         case '*': return MUL; //乘
6         case '/': return DIV; //除
7         case '^': return POW; //乘方
8         case '!': return FAC; //阶乘
9         case '(': return L_P; //左括号
10        case ')': return R_P; //右括号
11        case '\0': return EOE; //起始符与终止符
12        default : exit(-1); //未知运算符
13    }
14 }

```

```

15
16 char orderBetween(char op1, char op2) //比较两个运算符之间的优先级
17 { return pri[optr2rank(op1)][optr2rank(op2)]; }

```

代码x4.3 运算符优先级关系的判定

[4-8] 教材 95 页代码 4.7 中的 evaluate() 算法, 为将常规表达式转换为 RPN 表达式, 需借助 append() 函数将操作数或运算符追加至字符串 rpn 的末尾。

试实现该函数。(提示: 需针对浮点数和字符, 分别重载一个接口)

【解答】

一种可行的实现方式, 如代码x4.4所示。

```

1 void append(char*& rpn, float opnd) { //将操作数接至RPN末尾
2     int n = strlen(rpn); //RPN当前长度(以'\0'结尾, 长度n + 1)
3     char buf[64];
4     if (opnd != (float)(int)opnd) sprintf(buf, "%.2f \0", opnd); //浮点格式, 或
5     else                          sprintf(buf, "%d \0", (int)opnd); //整数格式
6     rpn = (char*) realloc(rpn, sizeof(char) * (n + strlen(buf) + 1)); //扩展空间
7     strcat(rpn, buf); //RPN加长
8 }
9
10 void append(char*& rpn, char optr) { //将运算符接至RPN末尾
11     int n = strlen(rpn); //RPN当前长度(以'\0'结尾, 长度n + 1)
12     rpn = (char*) realloc(rpn, sizeof(char) * (n + 3)); //扩展空间
13     sprintf(rpn + n, "%c ", optr); rpn[n + 2] = '\0'; //接入指定的运算符
14 }

```

代码x4.4 将操作数或操作符统一接至RPN表达式末尾

这里, 在接入每一个新的操作数或操作符之前, 都要调用realloc()函数以动态地扩充RPN表达式的容量, 因此会在一定程度上影响时间效率。

在十分注重这方面性能的场所, 读者可以做适当的改进——比如, 仿照教材2.4.2节中可扩充向量的策略, 凡有必要扩容时即令容量加倍。

[4-9] 试以表达式“(0!+1)*2^(3!+4)-(5!-67-(8+9))”为例, 给出 evaluate() 算法的完整执行过程。

【解答】

该表达式的求值过程, 如表x4.1所示。其中每一步所对应的当前字符, 均以方框注明; 表达式的结束标识'\0', 则统一用\$示意; 各行左侧为栈底, 右侧为栈顶。

请参考对应的注解, 体会运算符栈和操作数栈随算法执行的演变过程及规律。

表x4.1 表达式求值算法实例

表达式	运算符栈	操作数栈	注解
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$		表达式起始标识入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (左括号入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (0	操作数0入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (!	0	运算符'!'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (1	运算符'!'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (+	1	运算符'+'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (+	1 1	操作数1入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ (2	运算符'+'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$	2	左括号出栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ *	2	运算符'*'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ *	2 2	操作数2入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^	2 2	运算符'^'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (2 2	左括号入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (2 2 3	操作数3入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (!	2 2 3	运算符'!'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (2 2 6	运算符'!'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (+	2 2 6	运算符'+'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (+	2 2 6 4	操作数4入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^ (2 2 10	运算符'+'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ * ^	2 2 10	左括号出栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ *	2 1024	运算符'^'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$	2048	运算符'*'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ -	2048	运算符'-'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (2048	左括号入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (2048 5	操作数5入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (!	2048 5	运算符'!'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (2048 120	运算符'!'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (-	2048 120	运算符'-'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (-	2048 120 67	操作数67入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (2048 53	运算符'-'出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (-	2048 53	运算符'-'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (- (2048 53	左括号入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (- (2048 53 8	操作数8入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (- (+	2048 53 8	运算符'+'入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (- (+	2048 53 8 9	操作数9入栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))\$$	\$ - (- (2048 53 17	运算符'+'出栈执行

表达式	运算符栈	操作数栈	注解
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))$	\$ - (-	2048 53 17	左括号出栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))$	\$ - (2048 36	运算符 '-' 出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))$	\$ -	2048 36	左括号出栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))$	\$	2012	运算符 '-' 出栈执行
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))$		2012	表达式起始标识出栈
$(0!+1)*2^{(3!+4)}-(5!-67-(8+9))$			返回唯一的元素 2012

[4-10] 教材 95 页代码 4.7 中的 `evaluate()` 算法, 对乘方运算符“^”的求值采用了向左优先结合律, 比如表达式“ 2^3^5 ”将被理解为“ $(2^3)^5$ ”。

试按照通常习惯, 将该运算符调整为满足向右优先结合律, 如上例应被理解为“ $2^(3^5)$ ”。

要求对该算法的修改尽可能小。

【解答】

就此类问题而言, 与其去修改代码 4.7 中的 `evaluate()` 算法, 不如直接调整代码 4.6 中的优先级表。实际上, 只需将其中的 `pri['^']['^']` 由 '>' 改作 '<'。

经过如此调整之后, 当表达式当前扫描至操作符 '^', 且此时的操作符栈顶元素亦为 '^' 时, 后者不会随即执行计算, 而是令前者入栈。从优先级的角度来看, 如此可保证靠后 (而非靠前) 的 '^' 运算符优先执行计算。

[4-11] 教材 95 页代码 4.7 中 `evaluate()` 算法执行过程中的某一时刻, 设操作符栈共存有 502 个括号。

a) 此时栈的规模 (含栈底的 '\0') 至多可能多大? 为什么?

b) 请示意性地画出当时栈中的内容。

【解答】

由该算法的原理不难看出, 在其执行过程中的任何时刻, 操作符栈中所存每一操作符相对于其直接后继 (若存在) 的优先级都要 (严格地) 更高。

当然, 这一性质只对相邻操作符成立, 故并不意味着其中所有的操作符都按优先级构成一个单调序列。在该算法中, (左) 括号扮演了重要的角色——无论它是栈顶操作符, 或者是表达式中的当前操作符, 都会 (因对应的 `pri[][]` 表项为 '<' 而) 执行压栈操作。就效果而言, 如此等价于将递增的优先级复位, 从而可以开始新一轮递增。对照如代码 4.6 所示的优先级表即不难验证, 其它操作符均无这一特性。

因此, 在 (左) 括号数固定的条件下, 为使操作符栈中容纳更多的操作符, 必须使每个 (左) 括号的上述特性得以充分发挥。具体地, 在每个 (左) 括号入栈之前, 应使每个优先级别的操作符都出现一次 (当然, 也至多各出现一次)。这里, '+' 和 '-' 同处一级, '*' 和 '/' 同处一级, '^' 自成一级, '!' 也自成一级。

需特别注意的是, 根据代码 4.6 中的优先级表, 任何时刻操作符 '!' 在操作符栈中只可能存有一个, 而且必定是栈顶。对于合法的表达式, 此后出现的下一操作符不可能是 '('。而无论接下来出现的是何种操作符 (即便是 '!' 本身), 该操作符都会随即出栈并执行对应的计算。

综合以上分析，为使操作符栈的规模最大，其中所存的操作符应大致排列表x4.2所示。

表x4.2 (左) 括号数固定时，运算符栈的最大规模

θ	1	2	3	4	5	6	7	8	9	10	11	12	...	2008	2009	2010	2011	2012
$\setminus \theta$	+	*	^	(+	*	^	(+	*	^	(...	(+	*	^	!
θ				1				2				3		502				503

不难看出，此时操作符栈的规模为：

$$(502 + 1) \times 4 + 1 = 2013$$

[4-12] 对异常输入的处置能力是衡量算法性能的重要方面，即教材 1.1.4 节所谓的鲁棒性。为考查教材 95 页代码 4.7 中 evaluate() 算法的这一性能，现以非正常的表达式“(12)3+!4*+5”作为其输入。

a) 试给出在算法退出之前，操作数栈和操作符栈的演化过程；

【解答】

evaluate() 算法对该“表达式”的求值过程，如表x4.3所示。其中，运算符栈和操作数栈的栈底/栈顶都在左侧/右侧。

表x4.3 非法表达式“(12)3+!4*+5”的“求值”过程

表达式	运算符栈	操作数栈	注解
(1 2) 3 + ! 4 * + 5 \$	\$		表达式起始标识入栈
((1 2) 3 + ! 4 * + 5 \$	\$ (左括号入栈
((1 2) 3 + ! 4 * + 5 \$	\$ (12	操作数12入栈
((1 2) 3 + ! 4 * + 5 \$	\$	12	左括号出栈
((1 2) 3 + ! 4 * + 5 \$	\$	12 3	操作数3入栈
((1 2) 3 + ! 4 * + 5 \$	\$ +	12 3	运算符 '+' 入栈
((1 2) 3 + ! 4 * + 5 \$	\$ + !	12 3	运算符 '!' 入栈
((1 2) 3 + ! 4 * + 5 \$	\$ + !	12 3 4	操作数4入栈
((1 2) 3 + ! 4 * + 5 \$	\$ +	12 3 24	运算符 '!' 出栈执行
((1 2) 3 + ! 4 * + 5 \$	\$ + *	12 3 24	运算符 '*' 入栈
((1 2) 3 + ! 4 * + 5 \$	\$ +	12 72	运算符 '*' 出栈执行
((1 2) 3 + ! 4 * + 5 \$	\$	84	运算符 '+' 出栈执行
((1 2) 3 + ! 4 * + 5 \$	\$ +	84	运算符 '+' 入栈
((1 2) 3 + ! 4 * + 5 \$	\$	84 5	操作数5入栈
((1 2) 3 + ! 4 * + 5 \$	\$	89	运算符 '+' 出栈执行
((1 2) 3 + ! 4 * + 5 \$		89	表达式起始标识出栈
((1 2) 3 + ! 4 * + 5 \$			返回唯一的元素89

b) 该算法是否能够正常终止? 若异常退出, 试解释原因; 否则, 试给出算法的输出;

【解答】

由表x4.3可见, 尽管上述表达式明显不合语法, 但`evaluate()`算法却依然能够顺利求值, 并正常退出。实际上此类实例纯属巧合, 更多时候该算法在处理非法表达式时都会异常退出。

反观上例也可看出, 巧合的原因在于, 在该“表达式”的求值过程中, 每当需要执行某一运算时, 在操作数栈中至少存有足够多操作数可供弹出并参与运算。

c) 试改进该 `evaluate()` 算法, 使之能够判别表达式的语法是否正确。

【解答】

就最低的标准而言, 改进后的算法应该能够判定表达式是否合法。为此, 除了需要检查括号的匹配, 以及在每次试图执行运算时核对操作数栈的规模足够大, 还需要确认每个操作符与其所对应操作数之间的相对位置关系符合中缀表达式 (`infix`) 的语法。最后一项检查的准则并不复杂: 在每个操作符即将入栈时, 操作数栈的规模应比操作符栈的规模恰好大一。

请读者根据以上提示, 独立完成对原算法的改进工作。当然, 就此问题的进一步要求是, 在判定表达式非法后, 还应能够及时报告问题的类型及其所在的位置, 甚至给出修正的建议。

[4-13] RPN 表达式无需括号即可确定运算优先级, 这是否意味着其所占空间必少于常规表达式? 为什么?

【解答】

未必。实际上, 尽管RPN表达式可以省去括号, 但必须在相邻的操作数、操作符之间插入特定的分隔符 (通常为空格)。这种分隔符必须事先约定, 且不能用以表示操作数或操作符, 故亦称做元字符 (`meta-character`)。

不难看出, RPN表达式所引入元字符的数量, 与操作数和操作符的总数相当, 故其所占空间总量未必少于原表达式。

[4-14] PostScript 是一种典型的栈式语言, 请学习该语言的基本语法, 并编写简单的绘图程序。

【解答】

如代码x4.5所示, 即为PostScript语言绘图程序的一个实例。

```

1 %!PS-Adobe-2.0
2 %
3 % Smiling faces drawing
4 %
5 % Written by: Junhui DENG
6 % Last update: Mar. 2009
7 %
8 /Times-Roman findfont
9 24 scalefont
10 setfont
11 %

```

```
12 /red      {1 0 0 setrgbcolor} def
13 /green    {0 1 0 setrgbcolor} def
14 /blue     {0 0 1 setrgbcolor} def
15 /yellow   {1 1 0 setrgbcolor} def
16 /black    {0 0 0 setrgbcolor} def
17 /white    {1 1 1 setrgbcolor} def
18 %
19 /dottedline {0 setlinewidth} def
20 /fatline   {16 setlinewidth} def
21 /thinline  {4 setlinewidth} def
22 %
23 /smile {
24   newpath
25   gsave
26   rotate
27   0 translate
28   180 div dup scale
29   yellow  0 0 180 0 360 arc fill
30   red     -55 45 27 0 360 arc fill
31   blue    55 45 27 0 360 arc fill
32   fatline white 0 -18 90 210 330 arc stroke
33   thinline black 0 0 180 0 360 arc stroke
34   grestore
35 } def
36 %
37 gsave
38 300 400 translate
39 180 0 0 smile
40 360 -15 0 {
41   dup 6 div
42   180
43   2 index
44   smile
45   pop
46 } for
47 %
48 -65 -30 moveto
49 black (Hello, world!) show
50 grestore
51 %
```

代码x4.5 PostScript语言的绘图程序

请读者阅读和运行该段代码，并通过添加注释，完成对其功能的分析。

[4-15] 为判断包含多种括号的表达式是否匹配，可否采用如下策略：

分别检查各种括号是否匹配；若它们分别匹配，则整体匹配

试证明你的结论，或者给出一个反例。

【解答】

在仅有一种括号时，括号匹配的判断准则，可以概括并精简为两条：

- a) 在表达式任意前缀中，左括号的数量都不少于右括号；
- b) 整个表达式中，左括号与右括号数量相等。

然而在有多种括号并存时，还需追加一条，以检查不同括号之间的相对位置：

- x) 在相互匹配的任何一对括号之间，则各种括号都是匹配的。

否则，即便每种括号均各自匹配，但不同括号之间仍可能存在相互“交错”的现象。比如，以下即是一个反例：

([{ }]) }

[4-16] 在 N 皇后搜索算法（教材 101 页代码 4.9）中，“忒修斯的线绳”与“粉笔”各是通过什么机制实现的？

【解答】

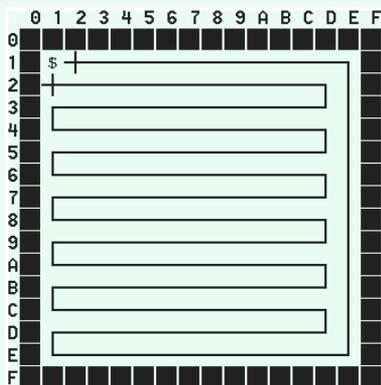
该算法所使用的栈 `solu` 就相当于“忒修斯的线绳”：压栈操作等效于前进一步并延长线绳；出栈操作等效于顺着线绳后退一步，同时收缩线绳。

这里通过循环按单调次序逐一检查每个格点，故不致于重复访问——这一机制，即等效于在迷宫中藉以作标记的“粉笔”。

[4-17] 考查如教材 103 页代码 4.13 所示的迷宫寻径算法。

- a) 试举例说明，即便 $n \times n$ 迷宫内部没有任何障碍格点，且起始与目标格点紧邻，也可能须在搜索过所有共 $(n - 2)^2$ 个可用格点之后，才能找出一条长度为 $(n - 2)^2$ 的通路；

【解答】



图x4.1 迷宫算法低效的实例

符合上述条件的一个具体实例，如图x4.1所示。

根据该算法的控制流程，在每个格点都是固定地按照东、南、西、北的次序，逐个地试探相邻的格点。因此，尽管在此例中目标终点就紧邻于起始点的西侧，也只有在按照如图所示的路线，遍历过所有的 $(n - 2)^2$ 个格点之后，才能抵达终点。

b) 尝试改进该算法, 使之访问的格点尽可能少, 找出的路径尽可能短。

【解答】

一种简便而行之有效的策略是, 每次都是按随机次序试探相邻格点。

为此, 需要改写nextESWN()函数(教材102页代码4.10)以及相关的数据结构。

请读者照此提示, 独立完成设计、编码和调试任务。

[4-18] Fermat-Lagrange 定理指出, 任何一个自然数都可以表示为 4 个整数的平方和, 这种表示形式称作费马-拉格朗日分解, 比如: $30 = 1^2 + 2^2 + 3^2 + 4^2$ 。

试采用试探回溯策略, 实现以下算法:

- 对任一自然数 n , 找出一个费马-拉格朗日分解;
- 对任一自然数 n , 找出所有费马-拉格朗日分解(同一组数的不同排列视作等同);
- 对于不超过 n 的每一自然数, 给出其费马-拉格朗日分解的总数。

【解答】

在枚举并检查各候选解的过程中, 需充分利用费马-拉格朗日分解的性质进行剪枝。

请读者按照这一总体思路, 独立完成具体的算法设计, 以及编码和调试任务。

[4-19] 暂且约定按照自然优先级, 并且不使用括号, 考查在数字'0'~'9'间加入加号'+', 乘号'*'后所构成的合法算术表达式。

a) 试编写一个程序, 对于任一给定的整数 s , 给出所有值为 s 的表达式。比如:

```
100    =  0 + 12 + 34 + 5 * 6 + 7 + 8 + 9
        0 + 12 + 3 * 4 + 5 + 6 + 7 * 8 + 9
        0 + 1 * 2 * 3 + 4 + 5 + 6 + 7 + 8 * 9
        0 * 1 + 2 * 3 + 4 + 5 + 6 + 7 + 8 * 9
        0 + 1 + 2 + 3 + 4 + 5 + 6 + 7 + 8 * 9
        0 + 1 * 2 * 3 * 4 + 5 + 6 + 7 * 8 + 9
        0 * 1 + 2 * 3 * 4 + 5 + 6 + 7 * 8 + 9
        ...
2012   =  0 + 12 + 34 * 56 + 7 + 89
        ...
```

b) 拓展你的程序, 使之同时还支持阶乘'!'。比如

```
2012   =  0! + 12 + 3!! + 4 * 5! + 6! + 7 + 8 * 9
        ...
```

c) 继续拓展, 引入乘方'^'、减法 '-'、除法 '/' 等更多运算;

d) 再做拓展, 引入括号。

【解答】

在枚举并检查各候选解的过程中, 需充分利用各种运算符(以及括号)的性质进行剪枝。

请读者按照这一总体思路, 独立完成算法设计, 以及编码和调试任务。

[4-20] 试从以下方面改进 4.6.2 节的银行服务模拟程序，使之更加符合真实情况：

- a) 顾客按更复杂的随机规律抵达；
- b) 新顾客选择队列时不以人数，而以其服务时长总和为依据。

【解答】

请读者独立完成编码和调试任务。

[4-21] 自学 C++ STL 中 stack 容器和 queue 容器的使用方法，阅读对应的源代码。

【解答】

请读者独立完成阅读任务。

[4-22] 双端队列 (deque^①) 是常规队列的扩展。顾名思义，该结构允许在其逻辑上的两端实施数据操作。具体地，与队头 (front) 端和队尾 (rear) 端相对应地，插入和删除操作各设有两个接口：

```
template <typename T> class Deque {
public:
    T& front(); //读取首元素
    T& rear(); //读取末元素
    void insertFront(T const& e); //将元素e插至队列前端
    void insertRear(T const& e); //将元素e插至队列末端
    T removeFront(); //删除队列的首元素
    T removeRear(); //删除队列的末元素
};
```

a) 实现如上定义的双向队列结构；

【解答】

比如，可以仿照代码x4.1中基于List结构派生出Stack结构，以及代码4.14（教材106页）中基于List结构派生出Queue结构的技巧。

具体地，将List结构的两端与Deque结构的两端相对应，相应的操作即可自然地转化为List结构在头、尾的插入和删除操作。

b) 你所实现的这些接口，时间复杂度各为多少？

【解答】

采用以上策略实现的Deque结构，各操作接口分别对应于List结构在首、末两端的插入或删除操作接口。根据3.3节对List结构性能的分析结论，得益于其内部的头、尾哨兵节点，这些操作均可在 $O(1)$ 时间内完成。

^① deque原本的读音与队列ADT的dequeue接口雷同，都是[di:kju]，为示区别，通常将deque改读作[dek]

[4-23] 从队列的角度回顾二路归并算法的两个版本，不难发现，无论 `Vector::merge()`（教材 63 页代码 2.29）还是 `List::merge()`（教材 82 页代码 3.22），所用到的操作无非两类：

从两个输入序列的前端删除元素

将元素插入至输出序列的后端

因此，若使用队列 ADT 接口来描述和实现该算法的过程，必将既简洁且深刻。

试按照这一理解，编写二路归并算法的另一版本，实现任意一对有序队列的归并。

【解答】

可以将 `Vector` 或 `List` 结构的首、末两端，与 `Queue` 结构的首、末两端相对应，并约定队列中的各元素从队首至队末，按单调非降次序排列。于是，对待归并序列（队列）的操作，仅限于调用 `front()` 接口（取各序列的首元素并比较大小）和 `dequeue()` 接口（摘出首元素中的小者）；而对合成序列（队列）的操作，仅限于调用 `enqueue()` 接口（将摘出的元素归入序列）。

请读者按照以上介绍和提示，独立完成编码和调试任务。

实际上，使用栈的 ADT 接口，也可简洁地描述和实现归并排序算法。当然，每次归并之后，还需随即对合成的序列（栈）做一次倒置操作 `reverse()`（参见习题 [4-25]）。

[4-24] 基于向量模板类 `Vector` 实现栈结构时，为了进一步提高空间的利用率，可以考虑在一个向量内同时维护两个栈。它们分别以向量的首、末元素为栈底，并相向生长。

为此，对外的入栈和出栈操作接口都需要增加一个标志位，用一个比特来区分实施操作的栈。

具体地，入栈接口形式为 `push(0, e)` 和 `push(1, e)`，出栈接口形式为 `pop(0)` 和 `pop(1)`。

a) 试按照上述思路，实现这种孪生栈结构；

【解答】

请读者参照以上提示，独立完成。

b) 当孪生栈的规模之和已达到向量当前的容量时，为保证后续的入栈操作可行，应采取什么措施？

【解答】

扩容。仿照 2.4.3 节的策略和方法，同样可以实现分摊意义上的高效。

[4-25] 试设计并实现 `Stack::reverse()` 接口，将栈中元素的次序前后倒置。

【解答】

一种可行的方法是：先将栈中的元素逐一取出并依次插入某一辅助队列，然后再逐一取出队列中的元素并依次插回原栈。请读者根据以上介绍和提示，独立完成编码和调试任务。

[4-26] 试设计并实现 `Queue::reverse()` 接口，将队列中元素的次序前后倒置。

【解答】

仿照上题的方法：先将队列中的元素逐一取出并依次插入某一辅助栈，然后再逐一取出栈中的元素并依次插回原队列。请读者根据以上介绍和提示，独立完成编码和调试任务。

第5章

二叉树

[5-1] 考查任何一棵二叉树 T 。

a) 试证明, 对于其中任一节点 $v \in T$, 总有 $\text{depth}(v) + \text{height}(v) \leq \text{height}(T)$;

【解答】

对于子树 v 中的任一节点 x , 我们将 x 在该子树中的深度记作 $\text{depth}_v(x)$ 。

若将树根节点记作 r , 则根据定义有:

$$\text{height}(v) = \max\{ \text{depth}_v(x) \mid x \in \text{subtree}(v) \}$$

于是,

$$\begin{aligned} & \text{depth}(v) + \text{height}(v) \\ &= \text{depth}(v) + \max\{ \text{depth}_v(x) \mid x \in \text{subtree}(v) \} \\ &= \max\{ \text{depth}(v) + \text{depth}_v(x) \mid x \in \text{subtree}(v) \} \\ &= \max\{ \text{depth}(x) \mid x \in \text{subtree}(v) \} \dots\dots\dots (1) \end{aligned}$$

另一方面,

$$\begin{aligned} & \text{height}(T) = \text{height}(r) \\ &= \max\{ \text{depth}_r(x) \mid x \in \text{subtree}(r) = T \} \\ &= \max\{ \text{depth}(x) \mid x \in \text{subtree}(r) = T \} \dots\dots\dots (2) \end{aligned}$$

对比(1)、(2)两式, 二者都是取 $\text{depth}(x)$ 的最大值, 但前者所覆盖的范围 (子树 v) 是后者所覆盖范围 (全树) 的子集, 因此前者必然不大于后者。

b) 以上取等号的充要条件是什么?

【解答】

由以上分析可见, 唯有在全树最深节点属于子树 v 时, a) 中不等式方可取等号; 反之亦然。实际上, 此时对应的充要条件是: 全树最深 (叶) 节点 (之一) 是节点 v 的后代, 或者等价地, 节点 v 是全树 (某一) 最深 (叶) 节点的祖先。

[5-2] 考查任何一棵高度为 h 的二叉树 T , 设其中深度为 k 的叶节点有 n_k 个, $0 \leq k \leq h$ 。

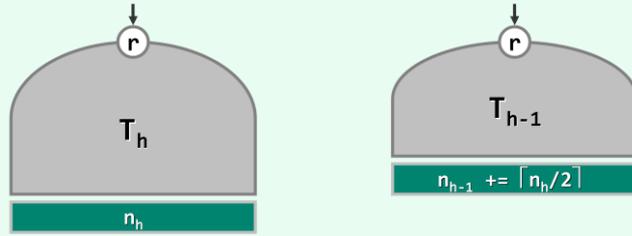
a) 试证明: $\sum_{k=0}^h (n_k/2^k) \leq 1$;

【解答】

采用数学归纳法, 对树高 h 做归纳。

在 $h = 0$ 时, 该不等式对单节点的二叉树显然成立。故假定对于高度小于 h 的二叉树, 该不等式均成立, 以下考查高度为 h 的二叉树。

该树在最底层拥有恰好 n_h 个 (叶) 节点。如图 x5.1 所示, 若将它们统一删除, 则只可能在原次底层 (现最底层) 增加叶节点, 其余更高层的叶节点不增不减。准确地说, 若原次底层新增叶节点共计 m 个, 则必有 $m \geq \lceil n_h/2 \rceil$; 或者反过来等价地, $n_h \leq 2m$ ——取等号当且仅当 n_h 为偶数。



图x5.1 n_h 个底层（叶）节点删除后，（次底层叶）节点至少增加 $\lfloor n_h/2 \rfloor$ 个

经如此统一删除底层（叶）节点之后，所得二叉树的高度为 $h - 1$ ，故由归纳假设应当满足：

$$\sum_{k=0}^{h-2} (n_k/2^k) + (n_{h-1} + m)/2^{h-1} = \sum_{k=0}^{h-1} (n_k/2^k) + m/2^{h-1} \leq 1$$

相应地，对于原树而言应有：

$$\begin{aligned} \sum_{k=0}^h (n_k/2^k) &= \sum_{k=0}^{h-1} (n_k/2^k) + n_h/2^h \\ &\leq \sum_{k=0}^{h-1} (n_k/2^k) + 2m/2^h \dots\dots\dots (*) \\ &= \sum_{k=0}^{h-1} (n_k/2^k) + m/2^{h-1} \\ &\leq 1 \end{aligned}$$

b) 以上不等式取等号的充要条件是什么？

【解答】

由以上证明过程可见，题中不等式若欲取等号，则在（沿数学归纳反向）每一步递推中，以上不等式(*)都应取等号，而其充要条件是 $n_h = 2m$ 。换言之，二叉树每次增加一层，最底层的新叶节点都应该是成对引入的。递推地应用这一规则即不难看出，在如此生成的二叉树中，所有节点的度数必为偶数——亦即所谓的真二叉树（proper binary tree）。

[5-3] 试证明，在二叉树中接入 (attachAsLC()或 attachAsRC()) 或摘除 (remove()或 secede()) 一棵非空子树之后

a) 该子树所有祖先的后代数目 (size) 必然变化；

【解答】

“祖先-后代”关系是相对的，故这一结论显然成立。

b) 该子树所有祖先的高度 (height) 可能变化；

【解答】

同样显然成立。

一般地，若在接入/摘除某棵子树之后，某个祖先节点的高度的确因此而增加/降低，则在此时/此前，该祖先节点的最深后代必然都来自于该子树。

c) 对于非该子树祖先的任何节点, 高度与后代数目均保持不变。

【解答】

同样地, 由“祖先-后代”关系的相对性, 后代集合及其总数显然不变。对于这样的节点而言, 通往其(包括最深后代在内的)所有后代的通路既然不变, 故高度亦保持不变。

[5-4] 考查如教材 121 页代码 5.6 所示的 `BinTree::updateHeightAbove(x)` 算法。

a) 试证明, 在逆行向上依次更新 x 各祖先高度的过程中, 一旦发现某一祖先的高度没有发生变化, 算法即可提前终止;

【解答】

在高度更新过程中, 将首个高度不变的节点记作 C 。

考查任一更高的祖先节点 A 。若从 A 通往其最深后代的通路不经过 C , 则 A 的高度自然不变。否则, 该通路自上而下经过 C 之后, 必然会继续通往 C 的最深后代。这种情况下, 既然 C 的高度保持不变, 则该后代的深度必然也不变——尽管这种后代节点可能不止一个。

b) 试按此思路改进这一算法;

【解答】

在自底而上逐层更新的过程中, 一旦当前祖先节点的高度未变, 即可立即终止。

c) 如此改进之后, 算法的渐进复杂度是否会相应地降低? 为什么?

【解答】

在最坏情况下我们仍需一直更新到树根节点, 因此就渐进意义而言算法的复杂度并未降低。当然, 如此改进之后毕竟可以自适应地减少不必要的更新计算, 因此这种改进依然是值得的。

[5-5] 教材 123 页代码 5.9 中的 `removeAt()` 算法, 时间复杂度是多少? 空间呢?

【解答】

对于待删除子树中的每一节点, 该算法都有一个对应的递归实例; 反之, 算法运行期间出现过的每一递归实例, 也唯一对应于某一节点。再注意到, 每个递归实例均只需常数时间, 故知整体的运行时间应线性正比于待删除子树的规模。

在算法运行过程中的任何时刻, 递归调用栈中各帧所对应的节点, 自底而上两两构成“父亲-孩子”关系——比如特别地, 最底部的一帧对应于(子树的)根节点。而当递归调用栈达到最高时, 栈顶一帧必然对应于(子树中的)最深节点。由此可见, 该算法的空间复杂度应线性正比于待删除子树的高度。

[5-6] 试证明, 若采用 PFC 编码, 则无论二进制编码串的长度与内容如何, 解码过程总能持续进行——只有最后一个字符的解码可能无法完成。

【解答】

按照教材 5.2.2 节介绍的 PFC 解码算法, 整个解码过程就是在 PFC 编码树上的“漫游”过程: 最初从根节点出发; 此后, 根据编码串的当前编码位相应地向左(比特 0)或向右(比特 1)深入;

一旦抵达叶节点，则输出其对应的字符，并随即复位至根节点。

可见，算法无法继续的唯一可能情况时，在准备向下深入时发现没有对应的分支。然而根据其定义和约束条件，PFC编码树必然是真二叉树（proper binary tree）。也就是说，该算法运行过程中所抵达的每一内部节点，必然同时拥有左、右分支。因此上述情况实际上不可能发生。

[5-7] 因其解码过程不必回溯，PFC 编码算法十分高效。然而反过来，这一优点并非没有代价。

试举例说明，如果因为信道干扰等影响致使某个比特位翻转错误，尽管解码依然可进行下去，但后续所有字符的解码都会出现错误。

【解答】

以如教材142页图5.35所示的编码树为例，考查与信息串"AI"相对应的编码串" 00^{011} "。

若因传输过程中所受干扰，导致接收到的编码串误作" $1^{00}1^1$ "，则仍可正常解码，只不过得到的是错误的信息串"MAMM"。

请注意，依靠该算法本身，并不能检测出此类错误。

当然，这类例子还有很多。读者若有兴趣，不妨自行尝试其它的可能。

[5-8] 在 2.7.5 节我们已经看到，CBA 式排序算法在最坏情况下均至少需要 $\Omega(n \log n)$ 时间，但这并不足以衡量此类算法的总体性能。比如，我们尚不确定，是否在很多甚至绝大多数其它情况下有可能做到运行时间足够少，从而能够使得平均复杂度更低。试证明：若不同序列作为输入的概率均等，则任何 CBA 式排序算法的平均运行时间依然为 $\Omega(n \log n)$ 。（提示：PFC 编码）

【解答】

针对CBA式算法复杂度下界的估计，教材2.7.5节建议的统一方法是：先确定算法所对应的比较树（comparison tree），然后通过输入规模与可能的输出结果（叶节点）数目，推算出最小树高——即算法在最坏情况下所需的运行时间。

此处所需进一步考查的，是在各种输出结果符合某种概率分布的前提下，算法的平均性能。不难理解，实际上这等效于考查比较树中各叶节点的加权平均深度，其中各叶节点的权重取作出现对应输出的概率。

若将比较树与5.5.2节中的最优编码树（optimal encoding tree）做一对照即可看出，这也就是所谓的叶节点平均深度（average leaf depth）。特别地，在各种输出结果概率均等的前提下，对于任一固定的输入规模 n ，完全二叉树的叶节点平均深度可达到最小——然而即便如此，也至少有 $\Omega(n \log n)$ 。

[5-9] 考查 5.4.1 节所介绍的各种递归式二叉树遍历算法。若将其渐进时间复杂度记作 $T(n)$ ，试证明：

$$T(n) = T(a) + T(n - a - 1) + \theta(1) = \theta(n)$$

【解答】

这些算法都属于二分递归（binary recursion），但无论如何，每当递归深入一层，都等效于将当前问题（遍历规模为 n 的二叉树）分解为两个子问题（分别遍历规模为 a 和 $n - a - 1$ 的两棵子树）。因此，递归过程总是可以描述为题中的递推关系。在考虑到边界条件（递归基仅需常数时间），即可导出这些算法的运行时间均为 $\theta(n)$ 的结论。

[5-10] 试按照消除尾递归的一般性方法，将二叉树先序遍历算法的递归版（教材 124 页代码 5.11）改写为迭代形式。

【解答】

在引入辅助栈之后，可以实现如代码x5.1所示的迭代版先序遍历算法。

```

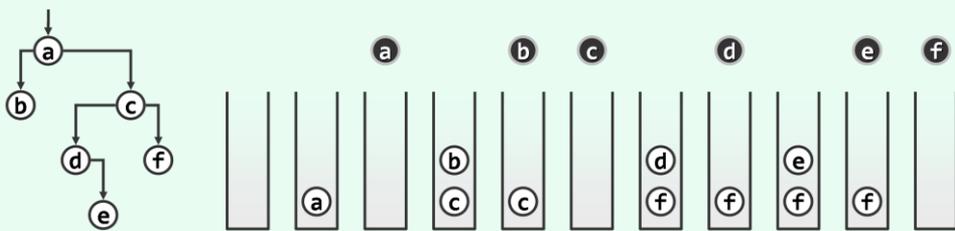
1 template <typename T, typename VST> //元素类型、操作器
2 void travPre_I1(BinNodePosi(T) x, VST& visit) { //二叉树先序遍历算法 (迭代版#1)
3     Stack<BinNodePosi(T)> S; //辅助栈
4     if (x) S.push(x); //根节点入栈
5     while (!S.empty()) { //在栈变空之前反复循环
6         x = S.pop(); visit(x->data); //弹出并访问当前节点，其非空孩子的入栈次序为
7         if (HasRChild(*x)) S.push(x->rChild); if (HasLChild(*x)) S.push(x->lChild); //先右后左
8     }
9 }

```

代码x5.1 二叉树先序遍历算法 (迭代版#1)

请特别留意这里的入栈次序：根据“后进先出”原理，右孩子应先于左孩子入栈。

图x5.2以其左侧的二叉树为例，给出了先序遍历辅助栈从初始化到再次变空的演变过程。



图x5.2 迭代式先序遍历实例 (出栈节点以深色示意)

[5-11] 考查教材 5.4.2、5.4.3、5.4.4 和 5.4.5 节所介绍的各种迭代式二叉树遍历算法。

a) 试证明，这些算法都是正确的——亦即，的确会访问每个节点一次且仅一次；

【解答】

纵观这些遍历算法，不难发现以下事实：

只要某个节点能被访问到，则其孩子节点必然也能

由此进一步地可知：只要某个节点能被访问到，则其每个后代节点必然也能。于是特别地，作为根节点的后代，树中的所有节点都能被（起始于根节点的）遍历访问到。

由此可见，这些遍历算法绝不致于遗漏任何节点。

另一方面，我们还需证明，这些算法也不致于重复访问任何节点，它们各自仅被访问一次。

实际上，纵观travPre_I1()算法（教材108页代码x5.1）、travPre_I2()算法（教材128页代码5.14）、travIn_I1()算法（教材129页代码5.15）、travIn_I2()算法（教材130页代码5.17）和travPost_I()算法（教材133页代码5.19），不难看出它们的一项共同点：

每个节点都在且仅在刚刚出栈之后，随即（通过调用visit()）被访问

因此只要进一步注意到，每个节点各自只入栈一次，即可确定每个节点的确至多被访问一次。

迭代式中序遍历算法travIn_I3()（教材131页代码5.18）虽然没有使用栈结构，但也具有类似性质。请读者自行找出规律，并证明同样的结论。

层次遍历算法travLevel()（教材134页代码5.20）采用了队列结构，类似地也不难看出：

每个节点都在且仅在刚刚出队之后，随即（通过调用visit()）被访问

再考虑到每个节点各自只入队一次，即可确定每个节点也至多被访问一次。

b) 试证明，无论递归式或迭代式，这些算法都具有线性时间复杂度；

【解答】

这些算法的运行时间主要消耗于两部分：栈（或队列）操作，以及对节点的访问操作。

根据以上分析，以上操作对每个节点而言各有不过常数次数，因此总体而言，这些算法的运行时间都线性正比于二叉树自身的规模。

c) 这些算法的空间复杂度呢？

【解答】

这些算法所占用的空间，主要地无非是用于对辅助结构（栈或队列）的维护。

在travPre_I1()算法（代码x5.1）、travPre_I2()算法（代码5.14）、travIn_I1()算法（代码5.15）和travIn_I2()算法（代码5.17）的运行过程中，树中每一层至多只有一个节点存在栈中，因此栈结构的最大规模不超过二叉树的深度，最坏情况下为 $O(n)$ 。

在travPost_I()算法（代码5.19）的运行过程中，树中每一层至多只有两个节点存在栈中，故栈结构的最大规模不超过二叉树深度的两倍，最坏情况下亦不过 $O(n)$ 。

在travLevel()算法（代码5.20）的运行过程中，队列结构中所存节点的深度相差不超过一，故该结构的最大规模不超过二叉树中任意的相邻两层规模之和，最坏情况下也是 $O(n)$ 。

迭代式中序遍历travIn_I3()算法（代码5.18），需要特别地做一深入讨论。正如教材中所指出的，这里并未（显式地）使用复杂的辅助结构，故表面上看仅需 $O(1)$ 辅助空间。然而相对于功能相同的其它算法，这里却要求每个节点都必须配有parent指针。实际上，借助辅助结构的其它算法，则完全可以不必如此——即便是travPost_I()算法（代码5.19），也可以通过对入栈节点附加标记，以避免使用parent指针）。因此就这一意义严格而言，travIn_I3()算法仍需要 $O(n)$ 的辅助空间。

[5-12] 对比教材中图 5.15 与图 5.16 不难发现，先序遍历与后序遍历在宏观次序上具有极强的对称性。

利用这种对称性，试仿照 5.4.2 节所给先序遍历算法的迭代版，实现后序遍历算法更多的迭代版。

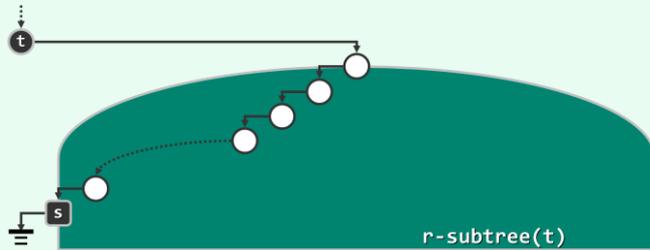
【解答】

请读者参照以上提示，独立完成编码和调试任务。

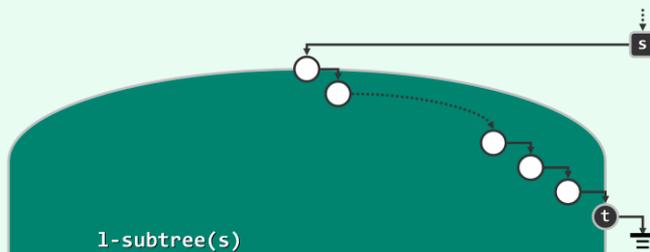
[5-13] 试针对代码 5.16 中 `BinNode::succ()` 算法的两种情况，分别绘出一幅插图以说明其原理及过程。

【解答】

两种可能的情况，分别如图x5.3和图x5.4所示。



图x5.3 `BinNode::succ()` 的情况一：t拥有右后代，其直接后继为右子树中左分支的末端节点s



图x5.4 `BinNode::succ()` 的情况二：t没有右后代，其直接后继为以其为直接前驱的祖先s

需要强调的是，第二种情况涵盖了一种特殊情况：当s并不存在时，t即为全树的最大节点。

请对照教材119页代码5.2，体会宏`IsRChild()`的定义方式，尤其是如此定义如何能够简化130页代码5.16，同时确保`BinNode<T>::succ()`接口在上述特殊情况下能够正确地返回NULL。

[5-14] 仿照 `BinNode::succ()` (教材 130 页代码 5.16)，实现二叉树节点直接前驱的定位接口 `BinNode::pred()`。

【解答】

请读者比照接口`BinNode::succ()`的实现方式，独立完成。

[5-15] 按照本章实现的迭代式算法(代码 x5.1、代码 5.14、代码 5.15、代码 5.17 和代码 5.19)对规模为 n 的二叉树做遍历，辅助栈的容量各应取作多大，才不致出现中途溢出？

【解答】

根据习题[5-11]的分析结论，最坏情况下(二叉树深度为 $\Omega(n)$ 时)辅助栈必须足以容纳 $\Omega(n)$ 个节点，这也是这些算法空间规模的安全下限。

[5-16] 中序遍历迭代式算法的第三个版本(教材 131 页代码 5.18)，需反复地调用 `succ()` 接口以定位直接后继，从而会相应地增加计算成本。

试问，该算法的渐进时间复杂度是否依然保持为 $\mathcal{O}(n)$ ？若是，请给出证明；否则试举一例。

【解答】

该算法的时间复杂度依然还是 $\mathcal{O}(n)$ 。

为得出这一结论，只需证明：

无论二叉树规模与结构如何，对succ()接口所有调用所需时间总和不超过 $O(n)$

反观教材130页代码5.16不难看出，实际上在这一场合下对succ()算法的调用，其中的if判断语句必然取else分支。因此，算法所消耗的时间应线性正比于其中while循环的步数，亦即其中对parent引用的访问次数。考查该次数，并将规模为n的二叉树所需的最大次数记作P(n)。可以证明，必有 $P(n) \leq n$ 。

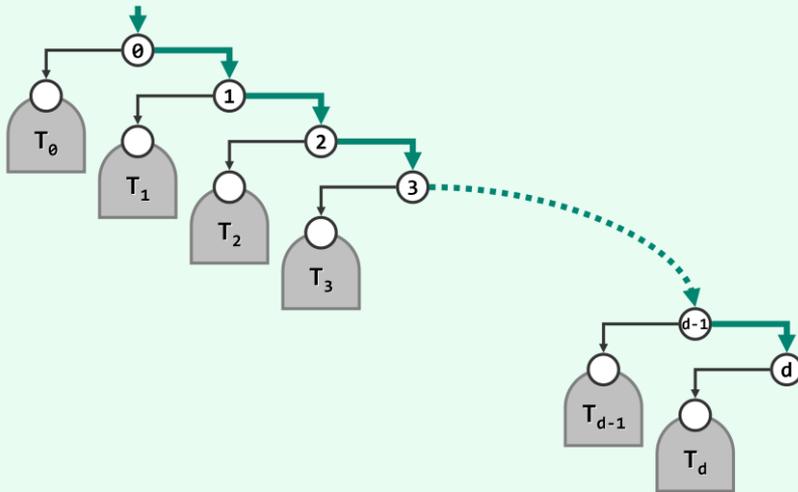
为此，我们对二叉树的高度做数学归纳。作为归纳基，不难验证：对于高度为-1（规模 $n = 0$ ）的空树而言，根本无需访问parent引用，即 $P(0) = 0$ ；对于高度为0（规模 $n = 1$ ）的二叉树而言，只需访问（根节点数值为NULL的）parent引用一次，故有 $P(1) = 1$ 。

因此，以下假设 $P(n) \leq n$ 对于高度小于h的所有二叉树均成立，并考查高度为h的二叉树T。

如图x5.5所示，若T的最右侧通路长度为d（ $d \leq h$ ），必然可以将T分解为d + 1棵子树：

$\{ T_0, T_1, T_2, T_3, \dots, T_{d-1}, T_d \}$

当然，其中的某些子树可能是空树。另外，尽管各子树的高度未必相同，但必然都小于h。因此根据归纳假设，其各自内部的遍历过程中对parent引用的访问次数，应线性正比于其各自的规模。特别地，其中最后一个节点（若子树非空）对应的succ()调用中，最后一个访问的是从子树根节点，联接到全树最右侧通路的parent指针（图中以细线条示意）。请注意，尽管相对于孤立的子树而言，这个parent引用不再是NULL，但并不影响访问次数的统计。



图x5.5 二叉树中序遍历过程中对succ()接口的调用

因此，在所有子树内部的遍历过程中对parent引用的访问，累计不会超过：

$$|T_0| + |T_1| + |T_2| + |T_3| + \dots + |T_{d-1}| + |T_d| = n - d - 1$$

就全树而言，除此之外尚未统计的，只有在最右侧通路末节点处对succ()的调用。该次调用过程中对parent引用的访问，也就是在图中以粗线条示意者（实际方向应颠倒，向上），不难看出其总数为d + 1。与各子树合并统计，总次数不超过：

$$(n - d - 1) + (d + 1) = n$$

**[5-17] 考查中序遍历迭代式算法的第三个版本（教材 131 页代码 5.18）。
试继续改进该算法，使之不仅无需辅助栈，而且也无需辅助标志位。**

【解答】

一种可行的改进方式，如代码x5.2所示。

```

1 template <typename T, typename VST> //元素类型、操作器
2 void travIn_I4(BinNodePosi(T) x, VST& visit) { //二叉树中序遍历算法（迭代版#4，无需栈或标志位）
3     while (true)
4         if (HasLChild(*x)) //若有左子树，则
5             x = x->lChild; //深入遍历左子树
6         else { //否则
7             visit(x->data); //访问当前节点，并
8             while (!HasRChild(*x)) //不断地在无右分支处
9                 if (!(x = x->succ())) return; //回溯至直接后继节点（在没有后继的末节点处，直接退出）
10                else visit(x->data); //访问新的当前节点
11            x = x->rChild; //（直至有右分支处）转向非空的右子树
12        }
13 }

```

代码x5.2 二叉树中序遍历算法（迭代版#4）

可以看到，这里同样需要调用succ()接口确定回溯的位置。

请读者参照注释，验证该算法的正确性，并就其时、空效率做一分析。

[5-18] 考查实现如 134 页代码 5.20 所示的层次遍历算法，设二叉树共含 n 个节点。

a) 试证明，只要辅助队列 Q 的容量不低于 $\lceil n/2 \rceil$ ，就不致于出现中途溢出的问题；

【解答】

可以证明：在该算法执行过程中的每一步迭代之后，若当前已经有 n 个节点入过队，则仍在队中的至多有 $\lceil n/2 \rceil$ 个——当然，相应地，至少已有 $\lfloor n/2 \rfloor$ 个已经出队。

实际上，对该算法稍加观察即不难发现：每次迭代都恰有一个节点出队；若该节点的度数为 d ($0 \leq d \leq 2$)，则随即会有 d 个节点入队。通过对已出队节点的数目做数学归纳，即不难证明以上事实。我们将此项工作留给读者。

b) 在规模为 n 的所有二叉树中，哪些的确会需要如此大容量的辅助队列？

【解答】

在算法过程中的任一时刻，辅助队列的规模均不致小于仍应在队列中节点的数目。考查这些节点在目前已入过队的节点中所占的比重。由以上观察结果，可以进一步推知：为使这一比重保持为尽可能大的 $\lceil n/2 \rceil/n$ ，此前所有出队节点的度数都必须取作最大的 2；且中途一旦某个节点只有 1 度甚至 0 度，则不可能恢复到这一比重。

由此可见，若果真需要如此大容量的辅助队列，则在最后一个节点入队之前，所有出队节点都必须是 2 度的。由此可见，其对应的充要条件是，这是一棵规模为 n 的完全二叉树。

c) 在层次遍历过程中, 若 Q 中节点的总数的确会达到这么多, 则至多可能达到多少次?

【解答】

按照层次遍历的次序, 若将树中各节点依次记作:

$$x_1, x_2, \dots, x_{\lfloor n/2 \rfloor}; x_{\lfloor n/2 \rfloor + 1}, \dots, x_n$$

则其中 $x_1 \sim x_{\lfloor n/2 \rfloor}$ 为内部节点, 共计 $\lfloor n/2 \rfloor$ 个; $x_{\lfloor n/2 \rfloor + 1} \sim x_n$ 为叶节点, 共计 $\lceil n/2 \rceil$ 个。

根据以上分析, 若 n 为奇数, 则必然是一棵真完全二叉树, 此时的最大规模 $\lceil n/2 \rceil = (n+1)/2$ 仅在 $x_{\lfloor n/2 \rfloor + 1}$ 处于队首时出现一次。若 n 为偶数, 则只有最后一个内部节点 $x_{\lfloor n/2 \rfloor}$ 的度数为 1, 此时的最大规模 $\lceil n/2 \rceil = n/2$ 在 $x_{\lfloor n/2 \rfloor}$ 和 $x_{\lfloor n/2 \rfloor + 1}$ 处于队首时各出现一次。

[5-19] 参考图 5.26 (教材 135 页) 和图 5.27 (教材 135 页) 中的实例, 考查对规模为 n 的完全二叉树 (含满二叉树) 的层次遍历。

a) 试证明: 在整个遍历过程中, 辅助队列的规模变化是单峰对称的, 即

$$\{0, 1, 2, \dots, (n+1)/2, \dots, 2, 1, 0\} \quad (n \text{ 为奇数时}) \text{ 或}$$

$$\{0, 1, 2, \dots, n/2, n/2, \dots, 2, 1, 0\} \quad (n \text{ 为偶数时})$$

【解答】

根据上题的分析结论, 显然成立。

b) 非完全二叉树的层次遍历过程, 是否也可能具有这种性质? 为什么?

【解答】

仍由上题的分析结论, 在对非完全二叉树的遍历过程中, 辅助队列的规模不可能达到 $\lceil n/2 \rceil$ 。

[5-20] 在完全二叉树的层次遍历过程中, 按入队 (亦即出队) 次序从 0 起将各节点 x 编号为 $r(x)$ 。

a) 试证明: 对于任一节点 x 及其左、右孩子 L 和 R (如果存在), 必然有

$$\begin{aligned} r(L) &= 2*r(x) + 1 \\ r(x) &= \lfloor (r(L) - 1)/2 \rfloor = (r(L) - 1)/2 \\ r(R) &= 2*r(x) + 2 \\ r(x) &= \lfloor (r(R) - 1)/2 \rfloor = r(R)/2 - 1 \end{aligned}$$

【解答】

由图 10.2 (教材 287 页) 中的实例, 直接易见。

b) 试证明: 任一编号 $r \in [0, n)$ 都唯一对应于某个节点;

【解答】

由图 10.2 (教材 287 页) 中的实例, 直接易见。

c) 很多应用往往只涉及完全二叉树, 此时, 如何利用上述性质提高对树的存储和处理效率?

【解答】

将所有节点存入向量结构, 各节点 x 的秩 $\text{rank}(x)$ 即为其编号 $r(x)$ 。

d) 根据以上编号规则, 如何判断任何一对节点之间是否存在“祖先-后代”关系?

【解答】

令 $s(X) = r(X) + 1$, $S(X)$ 为 $s(X)$ 的二进制展开, 于是有:

- (1) 节点A是D的祖先, 当且仅当 $S(A)$ 是 $S(D)$ 的前缀。其中特别地,
- (2) 节点A是D的父亲, 当且仅当 $S(A)$ 是 $S(D)$ 的前缀且 $|S(A)| + 1 = |S(D)|$

以图10.2 (教材287页) 中的节点1、8和18为例, 即可验证上述结论:

$$\begin{aligned} s(1) &= r(1) + 1 = 2 = 10_{(2)} \\ s(8) &= r(8) + 1 = 9 = 1001_{(2)} \\ s(18) &= r(18) + 1 = 19 = 10011_{(2)} \end{aligned}$$

[5-21] 采用“父节点 + 孩子节点”方式表示和实现有根的有序多叉树, 隶属于同一节点的孩子节点互为兄弟, 且此处的有序性可以理解为“左幼右长”——位置偏左者为弟, 偏右者为兄。实际上, 这只是现代意义上对“弟”和“兄”的理解, 具体到学源上师生关系, 可对应于师弟、师兄。

但按中国传统文化, 就此的理解与约定却有所不同: 凡同辈之间, 无论长幼均统一互称为“兄”; 而所谓“弟”, 则用以指称后辈, 大抵相当于“弟子”或“徒弟”。

试问: 若照此传统惯例, 将“子”改称作“弟”, 将“兄弟”统一作“兄”, 则多叉树的“父节点 + 孩子节点”表示法, 将恰好对应于二叉树的哪种表示法?

【解答】

“长子-兄弟”表示法。

[5-22] 考查借助二叉树, 表示 (有根有序) 多叉树的长子-兄弟表示法: 分别以左/右孩子作为长子/兄弟。

- a) 试基于 `BinTree` 模板类 (教材 121 页代码 5.5), 派生出 `Tree` 模板类;
- b) 试结合应用, 测试你的 `Tree` 模板类。

【解答】

请读者参照教材第5.1.3节关于“长子-兄弟”表示法之原理的讲解, 以及这里所给的提示, 独立完成设计、编码及测试工作。

[5-23] 试在 `BinTree` 模板类 (教材 121 页代码 5.5) 的基础上, 扩展 `BinTree::swap()` 接口, 在 $O(n)$ 时间将二叉树中每一个节点的左、右孩子 (其中之一可能为空) 互换, 其中 n 为树中的节点总数。

【解答】

在教材所给的递归版先序、中序或后序遍历算法的基础上, 在每个递归实例中, 交换当前节点的左、右孩子 (子树)。

请读者照此思路, 独立完成算法的编码和调试。

虽经如上扩充, 但每个递归实例渐进地仍然仅需常数时间, 故总体时间复杂度依然为 $O(n)$ 。当然, 为了提高实际的运行效率, 可以进一步改为迭代形式。此项任务, 由读者独立完成。

[5-24] 设二叉树共含 n 个节点,且各节点数据项的类型支持大小比较和线性累加(类似于整数或浮点数)。

- a) 试设计并实现一个递归算法,在 $O(n)$ 时间内判断是否该树中所有节点的数值均不小于其真祖先的数值总和。对于没有真祖先的树根节点,可认为“真祖先”的数值总和为 θ ;

【解答】

仍以教材所给的递归版先序、中序或后序遍历算法,作为基础框架。

引入一个辅助栈,用以记录从根节点到当前节点的(唯一)通路,当然,沿途节点亦即当前节点的所有祖先。另设一个累加器,动态记录辅助栈中所有节点数据项的总和。

为此,递归每深入一层,即将当前节点压入辅助栈中,同时累计其数据项;反之,递归每返回一层,即弹出辅助栈的顶部节点,并从累加器中扣除其数据项。对于每个当前节点,都将其数据项与累加器做一比较。一旦确认前者小于后者,即可立刻报告“NO”并退出。若直到辅助栈重新变空,都未发生上述情况,即最终可报告“YES”并退出。

请读者照此思路,独立完成算法的编码和调试。

同样地,以上扩充既不致增加递归实例的数量,亦不会增加各递归实例的渐进执行时间,故总体的时间复杂度依然为 $O(n)$ 。

- b) 试将以上算法改写为等价的迭代形式,且运行时间依然为 $O(n)$;

【解答】

请读者参照教材中各种迭代版遍历算法的实现方式和技巧,独立完成这一改进。

- c) 迭代版需要多少空间?

【解答】

因为省去了由系统隐式维护的递归调用栈,故迭代版只要实现得当,实际占用的空间将大为减少——尽管渐进的空间复杂度依然是线性的。

[5-25] 设二叉树共含 n 个节点,且各节点数据项的类型支持大小比较(类似于整数或浮点数)。

- a) 试设计并实现一个递归算法,在 $O(n)$ 时间内将每个节点的数值替换为其后代中的最大数值。

【解答】

以教材所给的递归版后序遍历算法为基础框架,做必要的扩充。

首先,需要调整接口约定,使每个递归实例都有返回值——亦即,当前节点更新后的数据项。

作为递归基,空树可返回可能的最小值(比如对于整数,可取 `INT_MIN`)。这样,按照后序遍历的次序,只要当前节点的左、右子树均已遍历(左、右孩子的数据项均已更新),即可从二者当中取其更大者,并相应地更新当前节点的数据项,最后再返回更新后的数据项。

请读者照此思路,独立完成算法的编码和调试任务。

同样地,以上扩充既不致增加递归实例的数量,亦不会增加各递归实例的渐进执行时间,故总体的时间复杂度依然为 $O(n)$ 。

b) 试将以上算法改写为等价的迭代形式, 且运行时间依然为 $O(n)$;

【解答】

请读者参照教材中各种迭代版后序遍历算法的实现方式和技巧, 独立完成这一改进。

c) 迭代版需要多少空间?

【解答】

因为省去了由系统隐式维护的递归调用栈, 故迭代版只要实现得当, 实际占用的空间将大为减少——尽管渐进的空间复杂度依然是线性的。

[5-26] 设二叉树共含 n 个节点, 且各节点数据项的类型支持线性累加 (类似于整数或浮点数)。

试设计并实现一个递归算法, 按照如下规则, 在 $O(n)$ 时间内为每个节点设置适当的数值:

树根为 θ

对于数值为 k 的节点, 其左孩子数值为 $2k + 1$, 右孩子数值为 $2k + 2$

【解答】

不难看出, 对于完全二叉树, 题中的要求实际上等效于, 按照层次遍历的次序, 为树中的各节点顺序编号。而一般的二叉树作为其子树, 各节点的编号也与完全二叉树完全吻合。因此可以教材所给的层次遍历算法为基础框架, 并做必要的扩充。

具体地, 在根节点首先入队之前, 将其数据项置为 θ 。此后的每一步迭代中, 若出队节点的编号为 k , 则入队的左、右孩子节点 (若存在) 的数值, 可分别取作 $2k + 1$ 、 $2k + 2$ 。

请读者照此思路, 独立完成编码和调试任务。

以上扩充并不会增加各步迭代的渐进执行时间, 故总体时间复杂度依然为 $O(n)$ 。

[5-27] 试证明, 在考虑字符的出现频率之后, 最优编码树依然具有双子性。

【解答】

与不考虑出现频率时的情况相仿, 依然可以反证。

假若某棵最优编码树不是真二叉树, 则通过收缩变换消除其中的单分支节点, 同时平均编码长度亦必然缩短。矛盾。

[5-28] 试证明, 5.5.4 节所述 Huffman 编码算法的原理, 对任意字符集均成立。

【解答】

可以证明:

由 Huffman 算法所生成的编码树, 的确是最优编码树

为此, 可以对字符集的规模 $|\Sigma|$ 做归纳。作为归纳基, 对单字符集 ($|\Sigma| = 1$) 而言显然。故不妨在 $|\Sigma| < n$ 时以上命题均成立, 现考查 $|\Sigma| = n$ 的情况。

按照 Huffman 算法的流程, 首先从 Σ 中取出频率最低的两个字符 x 和 y , 并将其合并为一个新的超字符 z 。而在算法此后的执行过程中, 可以等效地认为 x 和 y 已被删除, 并被代以 z ——亦即,

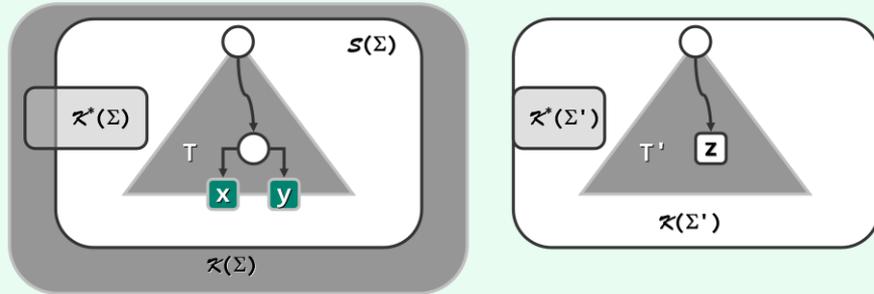
字符集相当于被替换为:

$$\Sigma' = (\Sigma \setminus \{x, y\}) \cup \{z\}$$

其中

$$w(z) = w(x) + w(y)$$

考查字符集 Σ 和 Σ' 各自的所有编码树,如图x5.6所示,令其分别构成集合 $\mathcal{S}(\Sigma)$ 与 $\mathcal{Z}(\Sigma')$,其中的最优编码树分别为其中的子集 $\mathcal{Z}^*(\Sigma)$ 与集合 $\mathcal{Z}^*(\Sigma')$ 。



图x5.6 频率最低的兄弟节点合并之后,最优编码树必对应于合并之前的最优编码树

鉴于最优编码树必然具有层次性,故在 $\mathcal{Z}^*(\Sigma)$ 中只需考虑 x 和 y 在底层互为兄弟的那些编码树,不妨令其构成集合 $\mathcal{S}(\Sigma)$ 。于是如图x5.6所示,在按照以上方法统一合并 x 和 y 之后,即在 $\mathcal{S}(\Sigma)$ 与 $\mathcal{Z}(\Sigma')$ 之间建立起了一一对应的关系。

考查如此对应的任意两棵树 $T \in \mathcal{S}(\Sigma)$ 和 $T' \in \mathcal{Z}(\Sigma')$,二者的编码总长之差为:

$$n \cdot \text{ald}(T) - (n - 1) \cdot \text{ald}(T') = w(x) + w(y) = w(z)$$

对于固定的字符集 Σ 而言,这个差异 $w(z)$ 即是一个常数。因此, $\mathcal{Z}^*(\Sigma')$ 中的最优编码树,亦必然对应于 $\mathcal{S}(\Sigma) \cap \mathcal{Z}^*(\Sigma')$ 中的最优编码树。故归纳假设可以推广至 $|\Sigma| = n$ 的情况。

[5-29] 5.5.4 节针对 Huffman 树构造算法的讲解中,暂时忽略了歧义情况。比如,有些字符的出现频率可能恰好相等;或者虽然最初的字符权重互异,但经过若干次合并之后,森林 F 也可能出现权重相等的子树。另外,每次选出一对(超)字符在合并时的左右次序也没有明确说明。

a) 试证明,以上歧义并不影响所生成编码树的最优性,即它仍是 Huffman 编码树之一;

【解答】

上题所给的证明,并未排除字符 x 和 y 权重相同的情况,故其结论足以覆盖本题。

b) 参照教材所给代码,了解并总结在实现过程中处理这类歧义的一般性方法。

【解答】

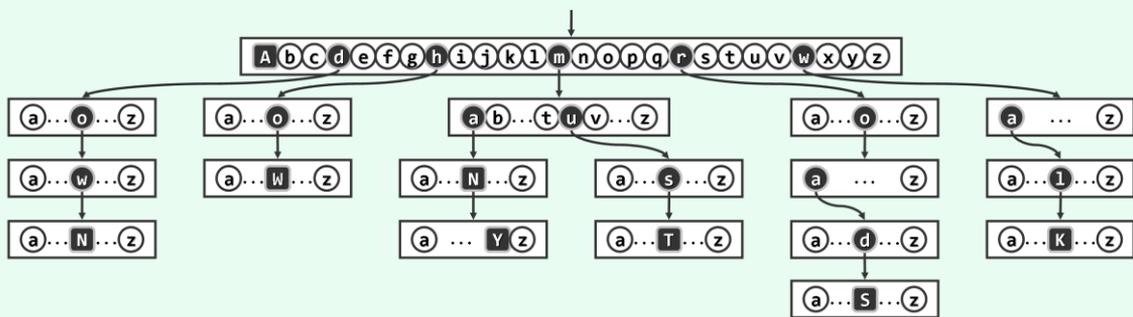
这里实际上是将此类歧义情况的处理,转交给具体实现 Huffman 森林的数据结构,比如采用列表结构(教材138页代码5.24),或者采用优先级队列结构(教材285页代码10.2)。

目前这些结构对歧义情况均未强制地处理,而多是依照其在逻辑序列中的次序,确定等权重(超)字符的合并次序。反之,若需要显示地消除此类歧义,亦可从这些方面入手。

[5-30] 设字符表为 Σ ($|\Sigma| = r$)。任一字符串集 S 都可如图 x5.7 所示, 表示为一棵键树 (trie) ^①。

键树是有根有序树, 其中的每个节点均包含 r 个分支。深度为 d 的节点分别对应于长度为 d 的字符串, 且祖先所对应字符串必为后代所对应字符串的前缀。键树只保留与 S 中字符串 (及其前缀) 相对应的节点 (黑色), 其余的分支均标记为 NULL (白色)。

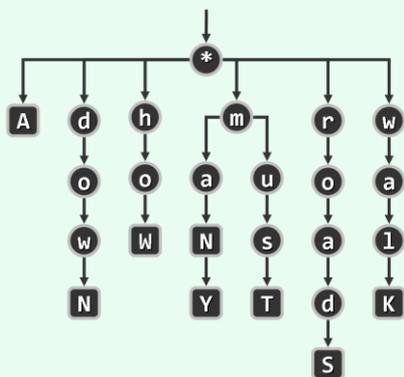
注意, 因为不能保证字符串相互不为前缀 (如 "man" 与 "many"), 故对应于完整字符串的节点 (黑色方形、大写字母) 未必都是叶子。



图x5.7 字符串集{ "how", "many", "roads", "must", "a", "man", "walk", "down" }对应的键树

试按照如图 x5.7 所示的构思, 实现对应的 Trie 模板类。同时要求提供一个接口 $find(w)$, 在 $O(|w|) = O(h)$ 的时间内判断 S 是否包含字符串 w , 其中 $|w|$ 为该字符串的长度, h 为树高。

(提示: 每个节点都实现为包含 r 个指针的一个向量, 各指针依次对应于 Σ 中的字符: S 包含对应的字符串 (前缀), 当且仅当对应的指针非空。此外, 每个非空指针都还需配有一个 $bool$ 类型的标志位, 以指示其是否对应于 S 中的某个完整的字符串。于是, 键树的整体逻辑结构可以抽象为如图 x5.8 所示的形式。其中, 黑色方形元素的标志位为 $true$, 其余均为 $false$ 。)



图x5.8 键树的紧凑表示与实现

【解答】

请读者根据以上介绍和提示, 独立完成编码和调试任务。

^① 由 R. de la Briandais 于 1959 年发明^[53]。名字源自单词 reTRIEval, 发音上为区别于 tree, 改读作 [trai]

第6章



[6-1] 关联矩阵 (incidence matrix) 是描述和实现图算法的另一重要方式。对于含有 n 个顶点、 e 条边的图，对应的关联矩阵 $I[] []$ 共有 n 行 e 列。在无向图中，对于任意的 $0 \leq i < n$ 和 $0 \leq j < e$ ，若第 i 个顶点与第 j 条边彼此关联，则定义 $I[i][j] = 1$ ；否则，定义 $I[i][j] = 0$ 。

a) 关联矩阵与邻接矩阵有何联系？

【解答】

就无向图而言（不考虑自环等情况），既然每一条边均恰好与两个顶点关联，故该矩阵中的每一列都应恰好包含两个1，总和均为2。

考查关联矩阵与其转置的乘积 $B = I \cdot I^T$ 。该矩阵对角线上的任意元素 $B[i][i]$ ，都应满足：

$$B[i][i] = I[i] \cdot I[i]^T = \text{顶点 } i \text{ 的度数}$$

而对于对角线以外的任意元素 $B[i][j]$ ， $i \neq j$ ，都有

$$B[i][j] = I[i] \cdot I[j]^T = \text{顶点 } i \text{ 与顶点 } j \text{ 之间公共的关联边数}$$

也就是说， $B[i][j]$ 等于1/0当且仅当顶点 i 与顶点 j 是/否彼此邻接。

b) 有向图的关联矩阵应如何定义？

通常的定义方式为，对于任意的 $0 \leq i < n$ 和 $0 \leq j < e$ ，若第 j 条边从第 i 个顶点发出（即顶点 i 为边 j 之尾），则定义 $I[i][j] = -1$ ；若第 j 条边进入第 i 个顶点（即顶点 i 为边 j 之头），则定义 $I[i][j] = +1$ ；否则，定义 $I[i][j] = 0$ 。

c) 有向图的关联矩阵，与邻接矩阵又有何联系？

与无向图类似地，有向图关联矩阵中的每一列应包含+1和-1各一个，总和应均为0。

为发现此时两种矩阵之间的联系，不妨依然考查关联矩阵与其转置的乘积 $B = I \cdot I^T$ 。

对于该矩阵对角线上的任意元素 $B[i][i]$ ，都有

$$B[i][i] = I[i] \cdot I[i]^T = \text{顶点 } i \text{ 的（出、入总）度数}$$

而对于对角线以外的任意元素 $B[i][j]$ ， $i \neq j$ ，都有

$$- B[i][j] = - I[i] \cdot I[j]^T = \text{顶点 } i \text{ 与顶点 } j \text{ 之间公共的关联（有向）边数}$$

也就是说， $B[i][j]$ 等于0当且仅当顶点 i 与顶点 j 互不邻接； $B[i][j]$ 等于-1或-2，当且仅当在顶点 i 与顶点 j 之间，联接有1或2条有向边。

d) 基于关联矩阵，可以解决哪些问题？试举一例。

【解答】

以参考文献[20]为例，其中的24.4节针对线性规划（linear programming）问题的一种特例——差分约束系统（system of difference constraints）——介绍了一个高效算法。该算法中最为重要的一个步骤，就是将差分约束系统转化为有向带权图：将差分约束变量视作顶点，将差分约束矩阵视作关联矩阵。如此，原问题即可转化为有向带权图的最短路径问题。

[6-2] 试说明，即便计入向量扩容所需的时间，就分摊意义而言，GraphMatrix::insert(v)算法的时间复杂度依然不超过 $O(n)$ 。

【解答】

首先请注意，GraphMatrix类（教材157页代码6.2）在底层，是基于可扩充向量，以二维Vector结构的形式来实现邻接矩阵。

按照第2.4节的实现方法及其分析结论，每一向量（即邻接矩阵的每一行）的单次插入操作，在分摊意义上只需 $O(1)$ 时间。这里，在每一节点的插入过程中， n 个向量的操作（含扩容操作）完全同步，故总体的运行时间不超过分摊的 $O(n)$ 。

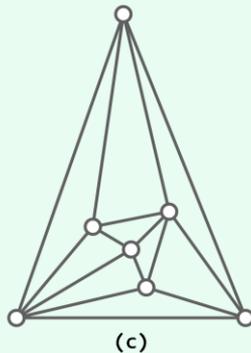
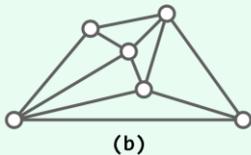
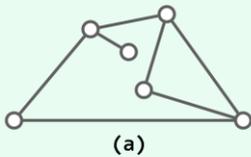
当然，为插入一个顶点，在最坏情况下可能需要访问和修改整个邻接矩阵，共需 $O(n^2)$ 时间。

[6-3] 所谓平面图，即可以将 n 个顶点映射为平面上的 n 个点，并且顶点之间的所有联边只相交于其公共端点，而不相交于边的内部。

试证明，平面图必满足 $e = O(n)$ ，亦即，边数与顶点数同阶。（提示：平面图必然遵守欧拉公式 $n - e + f - c = 1$ ，其中 n 、 e 、 f 和 c 分别为平面图的顶点、边、面和连通域的数目）

【解答】

不妨设这里所讨论的平面图，如图x6.1(a)所示，至少包含3个顶点；自然地，同时也包含 $c \geq 1$ 个连通域。考查其中各边与各面之间的关联关系，将其总数记作 I 。



图x6.1 (a)平面图、(b)三角剖分以及 (c)外面亦为三角形的三角剖分

首先不难看出，悬边仅与一张面关联，其余各条边均与两张面相关联。因此，每条边对 I 的贡献至多为2，故有：

$$I \leq 2e \dots \dots \dots (1)$$

另一方面，平面图中仅有一张无界的面——即所谓的外面（outer face）——它对 I 的贡献至少为3。此外其余的各张面，均由至少三条边围成，对 I 的贡献也至少为3，故有：

$$3f \leq I \dots \dots \dots (2)$$

联立不等式(1)和(2)，即有：

$$3f \leq 2e$$

$$f \leq 2e/3 \dots \dots \dots (3)$$

将不等式(3)代入欧拉公式，则有：

$$1 = n - e + f - c \leq n - e + 2e/3 - 1$$

稍作整理，即得：

$$e \leq 3n - 6 = O(n) \dots \dots \dots (4)$$

由以上证明也可进一步推知，不等式(4)取等号，当且仅当不等式(1~3)均取等号。

此时，每张面（包括外面）应恰好由三条边围成。也就是说，该平面图不仅如图x6.1(b)所示，是习题[6-32]中定义的三角剖分（triangulation），而且更如图x6.1(c)所示，外面也必须是一个三角形。

[6-4] a) 试通过将无向图的二维邻接矩阵映射至一维向量,提高空间利用率。

【解答】

无向图的邻接矩阵必然对称,亦即, $A[i][j] = A[j][i]$ 对合法的任意 i 和 j 均成立。因此,邻接矩阵的上或下半角完全可以不必记录,并将剩余部分转化并压缩为一维向量 A' 。

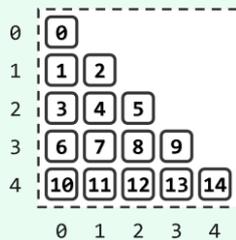
这里,不妨仅保存其中的下半三角区域(含对角线),即所有满足 $0 \leq j \leq i < n$ 的元素 $A[i][j]$ 。于是如图x6.2所示不难验证,可以在这些元素与向量 A' 之间建立如下——对应关系:

$$A[i][j] \leftrightarrow A'[i(i+1)/2 + j]$$

或者等价地:

$$A'[k] \leftrightarrow A[i][k - i(i+1)/2], \text{ 其中 } i = \lfloor (\sqrt{8k+1} - 1)/2 \rfloor$$

如此所得一维向量 A' 的长度为 $n(n+1)/2$, 大致为未压缩之前的一半。但就渐进意义而言,空间复杂度依然为 $O(n^2)$ 。



图x6.2 将5×5的对称矩阵压缩至长度为15的一维向量

b) 采用你所提出的方法,需额外增加多少处理时间?

【解答】

就从 A 中元素到 A' 中元素的映射而言,以上转换均属于基本操作,各自仅需 $O(1)$ 时间。

c) 采用你所提出的方法,是否会影响图 ADT 各接口的效率?

【解答】

既然以上转换均属于基本操作,故在顶点集保持不变的情况下,各接口所需时间将保持不变。然而在图的规模可能发生改变场合,无论是新顶点的引入还是原顶点的删除,都有可能需要移动 A' 中的所有元素,从而造成巨大的额外时间开销,因此得不偿失。

[6-5] a) 试按照 158 页 6.4 节的思路,以邻接表的形式实现图 ADT 的各操作接口;

【解答】

一种可行的实现方式大致如下。首先,将原定义的整体框架:

```
#include "../Vector/Vector.h" //引入向量
/* ... */
template <typename Tv, typename Te> //顶点类型、边类型
class GraphMatrix : public Graph<Tv, Te> { //基于向量,以邻接矩阵形式实现的图
private:
    Vector<Vertex<Tv>> V; //顶点集(向量)
    Vector<Vector<Edge<Te>*>> E; //边集(邻接矩阵)
    /* ... */
}
```

调整为

```

#include "../Vector/Vector.h" //引入向量
#include "../List/List.h" //引入列表
/* ... */
template <typename Tv, typename Te> //顶点类型、边类型
class GraphList : public Graph<Tv, Te> { //基于向量和列表,以邻接表形式实现的图
private:
    Vector<Vertex<Tv>> V; //顶点集(向量)
    Vector<List<Edge<Te>*>> E; //边集(邻接表)
    /* ... */
}

```

可见,所有顶点依然构成一个向量,且分别将各自的关联边组织为一个列表(即所谓边表)。既然同一边表内的边都关联于同一顶点,故为了便于查找另一关联顶点,接下来还需相应地在原Edge边结构的基础上,再增加一个域v:

```

template <typename Te> struct Edge { //边对象
    Te data; int weight; EStatus status; //数据、权重、状态
    int v; //关联顶点
    Edge(Te const& d, int w) : data(d), weight(w), status(UNDETERMINED) {} //构造新边
};

```

对于有向图,可以统一约定各边分别归属于其尾顶点所对应的边表(出边表),或统一归属于其头顶点(入边表)。而为了提高查找效率,甚至可以同时为各顶点设置出边表和入边表。

Graph各标准接口的具体实现,也要做相应的调整,凡涉及边表的操作都要将此前Vector结构的操作替换为List结构的操作。请读者独立完成这些工作。

b) 分析这一实现方式的时间、空间效率,并与基于邻接矩阵的实现做一对比。

【解答】

在空间复杂度方面,邻接表可以动态地与图结构的实际规模相匹配,而不再是固定的 $\Theta(n^2)$ 。具体地,若当时的图结构共含 n 个顶点、 e 条边,则实际的空间消耗应不超过 $\mathcal{O}(n + e)$ 。

与邻接矩阵相比,多数针对顶点的操作的时间复杂度几乎不变,但涉及边的操作则不尽相同。

在这里,边确认操作 $\text{exists}(i, j)$ 的作用至关重要。改为邻接表之后,我们需要遍历顶点 i 所对应的边表,方可判定其中是否存在与顶点 j 相关联者,因此其所需时间由 $\mathcal{O}(1)$ 增加至 $\mathcal{O}(\text{deg}(i)) = \mathcal{O}(n)$ 。相应地,涉及 $\text{exists}()$ 操作的顶点删除操作 $\text{remove}(i)$ 也需要更多的时间。此外,在改用邻接表之后,边删除操作 $\text{remove}(i, j)$ 也需要以类似的方式确认边 (i, j) 的确实存在,并在存在时确定该边记录的存放位置,因此该操作也将不能在 $\mathcal{O}(1)$ 时间内完成。

请读者根据自己的具体实现方式,对其它操作接口时间效率的变化补充分析。

[6-6] 试基于 BFS 搜索设计并实现一个算法，在 $O(n + e)$ 时间内将任一无向图分解为一组极大连通域。

【解答】

反观如教材160页代码6.3所示的广度优先搜索算法，其子算法BFS(v)只有在访遍顶点 v 所属的极大连通域之后，方可返回；此后，若还有其它尚未访问的连通域，则算法主入口bfs()中的循环必然会继续检查其余的所有顶点，而一旦发现尚处于UNDISCOVERED状态的顶点，即会再次调用子算法BFS()并遍历该顶点所属的极大连通域。

由此可见，只需按照BFS()的各次调用顺序，分批输出所访问的顶点以及边，即可实现无向图的极大连通域分解。

相对于基本的广度遍历算法，除了顶点和边的输出，该算法并未引入更多操作，因此其时间复杂度依然是 $O(n + e)$ 。

实际上，上述分析以及结论，同样适用于如教材162页代码6.4所示的深度优先遍历算法。

[6-7] 若在图 G 中存在从顶点 s 通往顶点 v 的道路，则其中最短道路的长度称作 s 到 v 的 (最小) 距离，记作 $\pi(v)$ ；不存在通路时，取 $\pi(v) = +\infty$ 。试证明，在起始于 s 的广度优先搜索过程中：

a) 波峰集中的各顶点，始终按其在 BFS 树中的深度，在辅助队列中单调排列，且彼此相差不超过一；

【解答】

采用数学归纳法，证明该不变性在每一顶点入队后都成立。初始时队列为空，自然成立。

考查下一入队顶点 u ，其在BFS树中的深度 $\text{depth}(u)$ ，是在其入队的同时确定的。就在 u 入队的那一步迭代中，此前必有某一顶点 v 刚刚出队，且在BFS树中 u 是 v 的孩子，故有：

$$\text{depth}(u) = \text{depth}(v) + 1$$

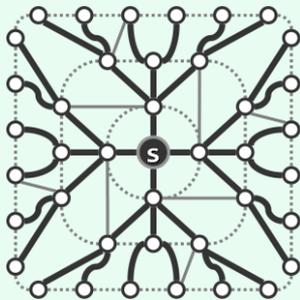
因此，倘若题中所述不变性在该步迭代之前成立，则在 v 出队、 u 入队后应该继续成立。

b) 所有顶点按其在 BFS 树中的深度，以非降次序接受访问。

【解答】

根据以上分析，如图x6.3所示，BFS树是在广度优先搜索的过程中自上而下逐层生成的，各顶点也是以其在树中的深度为序逐个被发现的；反过来，对原图的广度优先搜索过程，完全等同于对BFS树的层次遍历过程。

原图的各边所联接的顶点，在BFS中的深度之差不超过1；由树边联接的顶点，在BFS树中的深度之差恰好为1。



图x6.3 图的BFS搜索，等效于BFS树的层次遍历

c) 所有顶点按其到 s 的距离，以非降次序接受访问。

【解答】

由上，只需证明每一顶点 u 都满足 $\pi(u) = \text{depth}(u)$ 。

反证，假设至少有一个顶点不满足这一性质。以下，考查此类顶点中 $\pi()$ 值最小者 u 。

既然在BFS树（原图的子图）中已有一条长度为 $\text{depth}(u)$ 的通路联接于 s 和 u 之间，故必有：

$$\pi(u) \leq \text{depth}(u)$$

因此，不妨假定：

$$\pi(u) < \text{depth}(u) \dots\dots\dots (1)$$

在原图中，考查 s 到 u 的（任何一条）最短路径，其长度即为 $\pi(u)$ 。显然 $u \neq s$ ，故 u 在该路上的直接前驱顶点存在。将次前驱顶点记作 v ，则 v 应满足：

$$\pi(v) = \pi(u) - 1 < \pi(u) \dots\dots\dots (2)$$

根据 u 之 $\pi()$ 值的最小性，这就意味着 v 必然满足：

$$\pi(v) = \text{depth}(v) \dots\dots\dots (3)$$

综合(1)、(2)和(3)，即得：

$$\text{depth}(v) + 1 < \text{depth}(u)$$

然而，这一不等式不可能成立。实际上，在顶点 v 出队时，作为 v 的邻接顶点之一， u 必然会在同一步迭代中入队，并且同时确定其在BFS树中的深度为：

$$\text{depth}(u) = \text{depth}(v) + 1$$

需要强调的是，以上分析过程及结论，对于有向图同样适用。

[6-8] 若无向图中所有边的权重均相等，试基于广度优先搜索的框架设计并实现一个算法，在 $O(n + e)$ 时间内计算出某一起始顶点到其余顶点的（最小）距离和一条（最短）通路。

【解答】

根据上题的结论，经过广度优先搜索之后，各顶点在BFS树中的深度值，即是在原图中从起始顶点到它们的（最小）距离。因此，只需套用该算法，在每个顶点入队时随即输出其所确定的深度值；而在最终生成的BFS树中，从树根到各顶点的（唯一）通路，即是对应的（最短）通路。

需要强调的是，在原图中，任意两个顶点之间的（最短）通路可能不止一条，但它们的长度必然相同。

[6-9] 在无向连通图中，最长的通路称作其直径（diameter）。试基于广度优先搜索的框架，设计并实现一个查找直径的算法，要求时间复杂度为 $O(n + e)$ 。

【解答】

算法的主题流程如下：首先从任一顶点 v 出发，经过一趟广度优先搜索，找到与之距离最远的顶点 a ；然后从 a 出发，再经过一趟广度优先搜索，找到与之距离最远的顶点 b 。不难证明，在后一棵BFS树中， ab 之间的通路即是原图的直径。

请读者根据以上介绍，在教材所提供代码的基础上，独立完成该算法的编码和调试任务。

当然，按照题中所给定义，同一无向连通图的直径可能不止一条。有兴趣的读者不妨进一步拓展以上算法，从任一无向连通图中找出所有的直径。

[6-10] 试基于深度优先搜索的框架设计并实现一个算法，在 $O(n + e)$ 时间判定任一无向图是否存在欧拉环路；并且在存在时，构造出一条欧拉环路。

【解答】

根据图论的基本结论，只需遍历全图确定其连通性，再核对各顶点的度数。若连通且没有奇度数的顶点，则必然存在欧拉环路；否则，不存在欧拉环路。其中特别地，若奇度数的顶点恰有两个，则必然存在以这两个顶点为起点、终点的欧拉通路。

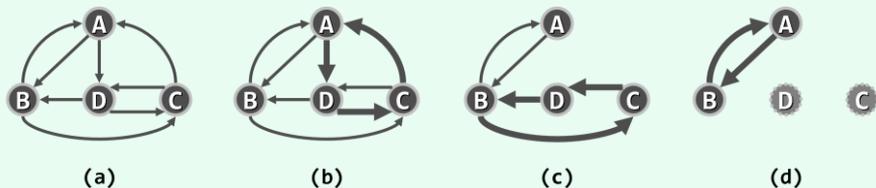
构造欧拉环路的一种算法，过程大致如下。从任一顶点出发做一趟深度优先搜索，依次记录沿途经过的各边并随即将其从图中删除；一旦有顶点度数归零，也随即将此顶点删除。一旦回到起点，即得到一条欧拉子环路。此时若还存在已访问但尚未被删除的顶点，则任选其一并从它出发，再做一趟深度优先搜索，过程相同。每次所得新的子环路，都需要在搜索的起始点处与此前的子环路合并为一条更大的子环路。当不剩任何顶点时，算法结束，当前的子环路即为原图的一条欧拉环路。

如果采用邻接表实现图结构，则以上算法中的每一基本操作（访问或删除当前顶点的一条关联边、访问度数非零的顶点、删除度数为零的顶点、将两条子环路在公共顶点处合并等）都可以在常数时间内完成，故总体运行时间线性正比于原图自身的规模。

上述关于欧拉环路存在性的判定依据以及环路的构造算法不仅适用于无向图，实际上也不难推广至有向图。

考查如图x6.4(a)所示的有向图实例——也就是教材152页图6.4(a)中的实例。

首先，经核对确认各顶点的出、入度数分别相等，故可判定该有向图存在欧拉环路。



图x6.4 构造有向图的欧拉环路：各子环路加粗示意，删除的边不再画出，删除的顶点以灰色示意

接下来，从任一顶点出发做深度优先搜索。比如，若从顶点C出发，可能如图(b)所示得到一条子环路：

{ C A D }

删除已访问过的边，并继续从顶点C出发做深度优先搜索，即可能如图(c)所示得到子环路：

{ C D B }

并与上一子环路在顶点C处合并为：

{ C D B C A D }

删除已访问过的边，并删除度数为零的顶点C和D之后，继续从已经访问但尚未删除的任一顶点出发做深度优先搜索。实际上此时只能从顶点B出发，得到子环路{ B, A }，并与上一子环路在顶点B处合并为：

{ C D B A B C A D }

[6-11] BFS 算法 (教材 160 页代码 6.3) 的边分类, 采用了简化的策略:

树边 (TREE) 之外, 统一归为跨边 (CROSS)

试分别针对无向图和有向图, 讨论跨边的可能情况。

【解答】

根据此前的分析, 无向图中任意一对邻接顶点在BFS树中的深度之差至多为1。因此在经过广度优先搜索之后, 无向图的各边无非两类: 树边, 亦即被BFS树采用的边; 跨边, 亦即联接于来自不同分支、深度相同或相差一层的两个顶点之间的边。

类似地, 有向图中的每一条边(v, u)均必然满足:

$$\text{depth}(u) \leq \text{depth}(v) + 1$$

这一不等式取等号时, (v, u)即是(由 v 指向 u 的)一条树边。

若满足:

$$\text{depth}(u) = \text{depth}(v)$$

则 v 和 u 在BFS树中分别属于不同的分支, (v, u)跨越于二者之间。

若满足:

$$\text{depth}(u) < \text{depth}(v)$$

则在BFS树中, u 既可能与 v 属于不同的分支, 也可能就是 v 的祖先。

[6-12] 考查采用 DFS 算法 (教材 162 页代码 6.4) 遍历而生成的 DFS 树。试证明:

a) 顶点 v 是 u 的祖先, 当且仅当

$$[\text{dTime}(v), \text{fTime}(v)] \supseteq [\text{dTime}(u), \text{fTime}(u)]$$

【解答】

先证明“仅当”。若 v 是 u 的祖先, 则遍历过程的次序应该是“ v 被发现... u 被发现... u 被访问完毕... v 被访问完毕”。也就是说, u 的活跃期包含于 v 的活跃期中。由此也可得出一条推论: 在任一顶点 v 刚被发现的时刻, 其每个后代顶点 u 都应处于UNDISCOVERED状态。

反之, 若 u 的活跃期包含于 v 的活跃期中, 则意味着当 u 被发现(由UNDISCOVERED状态转入DISCOVERED状态)时, v 应该正处于DISCOVERED状态。因此, v 既不可能与 u 处于不同的分支, 也不可能是 u 的后代。故“当”亦成立。

实际上由以上分析可进一步看出, 此类顶点活跃期之间是严格的包含关系。

b) v 与 u 无承袭关系, 当且仅当

$$[\text{dTime}(v), \text{fTime}(v)] \cap [\text{dTime}(u), \text{fTime}(u)] = \emptyset$$

【解答】

作为a)的推论, “当”显然成立, 故只需证明“仅当”。考查没有承袭关系的顶点 v 与 u , 且不妨设 $\text{dTime}(v) < \text{dTime}(u)$ 。于是根据a), 只需证明 $\text{fTime}(v) < \text{dTime}(u)$ 。

否则, 若 $\text{dTime}(u) < \text{fTime}(v)$, 则意味着当 u 被发现时, v 应该仍处于DISCOVERED状态。此时, 必然有一条从 v 通往 u 的路径, 且沿途的顶点都处于DISCOVERED状态。此时在DFS()算法的函数调用栈中, 沿途各顶点依次分别存有一帧。在DFS树中, 该路径上的每一条边都对应于一对父子顶点, 故说明 u 是 v 的后代——这与假设矛盾。

[6-13] 在起始于顶点 s 的 DFS 搜索过程中的某时刻, 设当前顶点为 v 。试证明, 任一顶点 u 处于 DISCOVERED 状态, 当且仅当 u 来自 s 通往 v 的路径沿途——或者等效地, 在 DFS 树中 u 必为 v 的祖先。

【解答】

由题所述条件, 可知必有:

$$dTime(u) < dTime(v) < fTime(u)$$

于是由以上根据顶点活跃期之间相互包含关系的结论, 必有:

$$dTime(u) < dTime(v) < fTime(v) < fTime(u)$$

亦即:

$$[dTime(v), fTime(v)] \subseteq [dTime(u), fTime(u)]$$

故知 u 必为 v 的祖先。

由以上规律亦可进一步推知: 起始顶点 s 既是第一个转入 DISCOVERED 状态的, 也是最后一个转入 VISITED 状态的, 其活跃期纵贯整个 DFS() 算法过程的始末; 在此期间的任一时刻, 任何顶点处于 DISCOVERED 状态, 当且仅当它属于从起始顶点 s 到当前顶点 v 的通路上——这一通路的作用, 也就相当于第 4.4.1 节所介绍的忒修斯的线绳。

[6-14] 通过显式地维护一个栈结构, 将 DFS 算法 (教材 162 页代码 6.4) 改写为迭代版本。

【解答】

实际上, 这里引入的栈结构, 只需动态记录从起始顶点 s 到当前顶点之间通路上的各个顶点, 其中栈顶对应于当前顶点。每当遇到处于 UNDISCOVERED 状态的顶点, 则将其转为 DISCOVERED 状态, 并令其入栈; 一旦当前顶点的所有邻居都不再处于 UNDISCOVERED 状态, 则将其转为 VISITED 状态, 并令其出栈。

[6-15] 为将顶点及边的状态标志复位, 本章所给的 Graph::reset() 需要耗费 $O(v + e)$ 时间。

试设计一种方法, 将这部分时间降低至 $O(v)$ 。

【解答】

仿照习题 [2-34] 之 c) 中介绍的技巧, 在不增加渐进空间复杂度的前提下, 在常数时间内完成各顶点所对应边向量的初始化, 从而使这方面总体所需的时间仅线性正比于顶点总数。

特别地, 若顶点总数保持不变, 则只需为所有顶点的边向量设置一个总体的 Bitmap 结构, 该结构的初始化仅需常数时间。

[6-16] a) 试说明, 对于整数权重的网络, 可通过足够小的扰动, 在不影响 Prim 算法正确性、计算过程及复杂度的前提下, 消除由 (同为某一割的极短跨越边的) 重复边引起的歧义。

【解答】

设原图共含 v 个顶点、 e 条边, 且不妨假定 $v - 1 \leq e$ 。若各边权重 (按输入次序) 依次为:

$$W = \{ w_1, w_2, w_3, \dots, w_e \}$$

且不妨设其中各边权重不致完全相等, 则可将其替换为:

$$W' = \{ w_1 + 1/e^2, w_2 + 2/e^2, w_3 + 3/e^2, \dots, w_e + e/e^2 = w_e + 1/e \}$$

也就是说, 各边的权重均有所增加, 且增量为以 $1/e^2$ 为公差的算术级数。

请注意，所有各边权重的扰动量总和不过：

$$(1 + 2 + 3 + \dots + e)/e^2 = (1 + e)/2e < 1$$

更重要的是，即便W中可能存在等权的边，在如此构造的W'中各边的权重也必然互异。于是，对其采用Prim（以及稍后介绍的Kruskal）算法将不致出现歧义情况，其最小支撑树T_m'亦必然唯一确定。也就是说，W'的任何一棵支撑树T'都应满足：

$$|T_m'| \leq |T'| \dots\dots\dots (1)$$

这里的|T_m'|和|T'|分别表示T_m'和T'的总权重。特别地，等号仅在T' = T_m'时成立。

不等式(1)的左、右同时向下取整后，应该依然成立，亦即：

$$\lfloor |T_m'| \rfloor \leq \lfloor |T'| \rfloor \dots\dots\dots (1')$$

既然|W| = |W'| = e，故二者的所有支撑树之间必然存在一一对应的关系。

考查如此对应的每一对支撑树T和T'。既然它们各自都恰好包含v - 1条边，故应有：

$$0 < |T'| - |T| < (v - 1) \cdot (1/e) \leq 1$$

也就是说，必有：

$$\lfloor |T'| \rfloor = |T| \dots\dots\dots (2)$$

特别地，若设与T_m'对应的（W的）支撑树为T_m，则也应有

$$\lfloor |T_m'| \rfloor = |T_m| \dots\dots\dots (3)$$

综合(3)、(1')和(2)可知，对于W的任何一棵支撑树T，都有：

$$|T_m| = \lfloor |T_m'| \rfloor \leq \lfloor |T'| \rfloor = |T|$$

由此可见，T_m必然是W的（一棵）最小支撑树。

另一种“方法”似乎更加巧妙，但实际上并不可行，故在此特作说明。

仿照以上技巧，将原图各边的权重依次替换为：

$$W' = \{ w_1 + 1/2, w_2 + 1/2^2, w_3 + 1/2^3, \dots, w_e + 1/2^e \}$$

也就是说，各边权重均有所增加，且增量构成以1/2为公比的几何级数，其总和不过：

$$1/2 + 1/2^2 + 1/2^3 + \dots + 1/2^e < 1$$

同时，即便W中可能存在等权的边，在如此构造的W'中各边的权重同样必然互异。因此与上一方法同理，亦可以消除最小支撑树构造过程中的歧义。

然而不幸的是，这种“方法”要求计算机的数值精度达到1/2^e——与边数e呈负指数相关，或者说数位与e呈线性相关。也就是说，随着e的增加，计算机的字长很快就会溢出。而反观上一方法，数值精度为1/e²，相对而言不致轻易就溢出。

b) 这种方法可否推广至实数权重的网络？

【解答】

以上方法之所以行之有效，是因为事先能够在不等权的边之间，确定边权重的最小差值(1)，从而既能够保证W'中的各权重彼此互异，同时又能保证通过向下取整运算，可以从|T'|确定对应的|T|。若权重可以取自任意实数，则这两个性质不能直接兼顾。

当然，若各边权重均取自浮点数（正如实际计算环境中的情况），则仍可以套用上述方法，只不过需要做必要的预处理——通过统一的放缩，将各边的权重转换为整数。

[6-17] 在教材 176 页图 6.20 中，出于简洁的考虑，将通路 us 和 vt 分别画在构成割的两个子图中。然而这样有可能造成误解，比如读者或许会认为，组成这两条通路的边也必然分别归属于这两个子图。

试举一实例说明， us 或 vt 均可能在两个子图之间穿越多（偶数）次——亦即，除了该割的最短跨越边 uv ，最小支撑树还可能采用同一割的其它跨越边，其长度甚至可能严格大于 $|uv|$ 。

【解答】

一个（组）通用的实例如图 x6.5 所示。

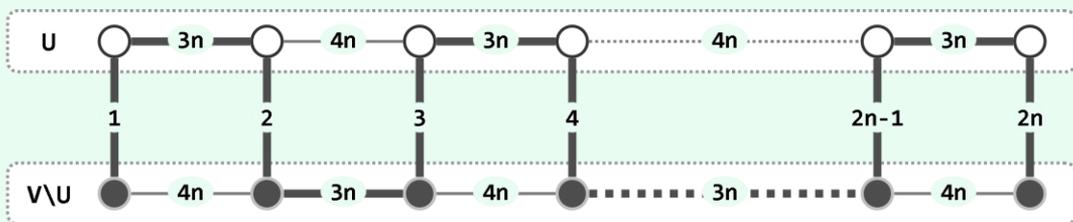


图 x6.5 最小支撑树（粗线条）可能反复地穿越于割的两侧

这里的子集 U 包含 $2n$ 个顶点（白色），其中 $2n - 1$ 条非跨越边的权重依次为：

$$W_U = \{ 3n, 4n, 3n, 4n, \dots, 3n \}$$

补集 $V \setminus U$ 也包含 $2n$ 个顶点（黑色），其中 $2n - 1$ 条非跨越边的权重依次为：

$$W_{V \setminus U} = \{ 4n, 3n, 4n, 3n, \dots, 4n \}$$

在这两个子集之间，共有 $2n$ 条跨越边，其权重依次为：

$$X = \{ 1, 2, 3, 4, \dots, 2n - 1, 2n \}$$

不难验证，该图的最小支撑树唯一确定，由权重不超过 $3n$ 的所有 $4n - 1$ 条边组成，亦即图 x6.5 中所有的粗边。由图易见，该支撑树就是一条通路，它在割的两侧总共穿越 $2n$ 次——（权重为 1 的）最短跨越边只是其中之一。

实际上， X 中各跨越边的权重未必需要按次序排列。

另外，基于二部图，完全可以构造出更为精简的实例。读者不妨照此思路，独立尝试。

[6-18] 利用“有向无环图中极大顶点入度必为零”的性质，实现一个拓扑排序算法，若输入为有向无环图则给出拓扑排序，否则报告“非有向无环图”。该算法时间、空间复杂度各是多少？

【解答】

基于这一策略的拓扑排序算法，过程大致如算法 x6.1 所示。

```

1  将所有入度为零的顶点存入栈 S //O(n)
2  取空队列 Q //记录拓扑排序序列, O(1)
3  while (!S.empty()) { //O(n)
4    Q.enqueue(v = S.pop()); //栈顶顶点 v 转入队列 Q
5    for each edge(v, u) //考查 v 的所有邻接顶点 u
6      if (inDegree(u) < 2) S.push(u); //凡入度仅为 1 者, 均压入栈 S 中
7    G = G \ {v}; //删除顶点 v 及其关联边 (邻接顶点入度相应地递减)

```

```

8 } //总体 $O(n + e)$ 
9 return |G| ? Q : "NOT_DAG"; //残留的G空 ( Q覆盖所有顶点 ), 当且仅当原图可拓扑排序 ( Q即是排序序列 )

```

算法x6.1 基于“反复删除零入度节点”策略的拓扑排序算法

这里，栈S和队列Q的初始化共需 $O(n)$ 时间。主体循环共计迭代 $O(n)$ 步，其中涉及的操作无非以下五类：出、入栈，共计 $O(n)$ 次；入队，共计 $O(n)$ 次；递减邻接顶点的入度，共计 $O(e)$ 次；删除（零入度）顶点，共计 $O(n)$ 个；（删除顶点时一并）删除关联边，共计 $O(e)$ 条。以上各类操作均属于基本操作，故总体运行时间为 $O(n + e)$ ，线性正比于原图的规模。

空间方面，除了原图本身，这里引入了辅助栈S和辅助队列Q，分别用以存放零入度顶点和排序序列。不难看出，无论是S或Q，每个顶点从始至终至多在其中存放一份，故二者的规模始终不超过 $O(n)$ 。实际上，通过更进一步地观察还可以发现，S和Q之间在任何时刻都不可能拥有公共顶点，因此二者总体所占的空间亦不过 $O(n)$ 。

请注意，既然不是基于深度优先搜索，故亦无需维护各顶点的时间标签及状态、各边的分类。因此相对于基于深度优先搜索的拓扑排序算法而言，这一实现方式所需的附加空间更少——尤其是对于稠密图而言。

[6-19] a) 试从教材 167 页代码 6.5 中，删除与拓扑排序无关的操作，以精简其实现；

【解答】

就拓扑排序这一问题而言，这里并不需要对各边进行分类，也不需要记录各顶点的时间标签，相关的数据项及操作均可删除。顶点的状态虽然仍需区分，却已不必过细，只要足以判定是否已经访问过即可。相应地，循环体内的三个switch分支也只需保留一个。

请读者按照以上思路，独立完成精简工作。

b) 精简之后，整体的渐进复杂度有何变化？

【解答】

经以上精简之后，运行时间虽有所减少，但渐进的复杂度依然保持为 $O(n + e)$ 。

空间方面，因为不必维护各边的分类标签，故除原图本身外仅需使用 $O(n)$ 辅助空间。

[6-20] a) 试从教材 170 页代码 6.6 中，删除与双连通分量分解无关的操作，以精简其实现；

【解答】

就双连通分量分解这一问题而言，这里并不需要对各边进行分类，相关的数据项及操作均可删除。各顶点的时间标签（其中的fTime用作hca）和状态，都仍然需要记录。

请读者按照以上思路，独立完成精简工作。

b) 精简之后，整体的渐进复杂度有何变化？

【解答】

经以上精简之后，运行时间虽有所减少，但渐进的复杂度依然保持为 $O(n + e)$ 。

空间方面，因为不必维护各边的分类标签，故除原图本身外仅需使用 $O(n)$ 辅助空间。

[6-21] 试按照 PFS 搜索的统一框架（教材 173 页代码 6.7），通过设计并实现对应的 prioUpdater 函数对象，分别实现 BFS 和 DFS 算法。

【解答】

BFS算法对应的优先级更新器，可实现如代码x6.1所示。

```

1 template <typename Tv, typename Te> struct BfsPU { //针对BFS算法的顶点优先级更新器
2     virtual void operator()(Graph<Tv, Te>* g, int uk, int v) {
3         if (g->status(v) == UNDISCOVERED) //对于uk每一尚未被发现的邻接顶点v
4             if (g->priority(v) > g->priority(uk) + 1) { //将其到起点的距离作为优先级数
5                 g->priority(v) = g->priority(uk) + 1; //更新优先级（数）
6                 g->parent(v) = uk; //更新父节点
7             } //如此效果等同于，先被发现者优先
8     }
9 };

```

代码x6.1 基于PFS框架的BFS优先级更新器

比如，对于任何一个图结构 g ，若顶点为 char 类型，边为 int 类型，则可以通过如下形式的调用，基于PFS框架完成对 g 的广度优先搜索。

```
g->pfs(0, BfsPU<char, int>());
```

与Dijkstra算法的顶点优先级更新器DijkstraPU()（教材179页代码6.9）做一对比，即可看出，这里的BfsPU()只不过将 u_k 到邻接顶点 v 的距离 $g\text{->weight}(u_k, v)$ 统一替换为1——也就是说，所谓的广度优先搜索实际上完全等效于，在所有边权重均为1的图中应用Dijkstra算法构造最短路径树。就此意义而言，广度优先搜索也可以视作Dijkstra算法的一个特例。

DFS算法对应的优先级更新器，可实现如代码x6.2所示。

```

1 template <typename Tv, typename Te> struct DfsPU { //针对DFS算法的顶点优先级更新器
2     virtual void operator()(Graph<Tv, Te>* g, int uk, int v) {
3         if (g->status(v) == UNDISCOVERED) //对于uk每一尚未被发现的邻接顶点v
4             if (g->priority(v) > g->priority(uk) - 1) { //将其到起点距离的负数作为优先级数
5                 g->priority(v) = g->priority(uk) - 1; //更新优先级（数）
6                 g->parent(v) = uk; //更新父节点
7                 return; //注意：与BfsPU()不同，这里只要有一个邻接顶点可更新，即可立即返回
8             } //如此效果等同于，后被发现者优先
9     }
10 };

```

代码x6.2 基于PFS框架的DFS优先级更新器

同样地，对于任何一个图结构 g ，若顶点为 $char$ 类型，边为 int 类型，则可以通过如下形式的调用，基于PFS框架完成对 g 的深度优先搜索。

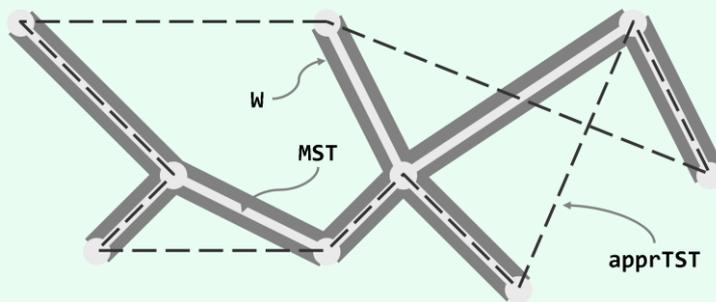
```
g->pfs(0, DfsPU<char, int>());
```

[6-22] 所谓旅行商问题，要求在任意 n 个城市的所有哈密尔顿环路中，找出总交通成本最低者。该问题属于经典的 NPC 问题，多数学者相信不存在多项式算法。

试证明：若城市及其之间的交通成本可描述为遵守三角不等式的带权网络，且已构造出对应的最小支撑树，则可在 $O(n)$ 时间内找出一条哈密尔顿环路，其交通成本不超过最优成本的两倍。

【解答】

借助最小支撑树构造近似的旅行商环路的过程及原理，如图x6.6所示。



图x6.6 借助最小支撑树，构造近似的旅行商环路

对于遵守三角不等式的任一带权网络 G ，若其最小支撑树 MST （由图中灰色各边组成）已知，则只需将其中的每一条边，替换为方向互逆的一对边（黑色），即可相应地可以得到一条环路 W 。于是，若将 MST 和 W 的总权重分别记作 $|MST|$ 和 $|W|$ ，则显然有：

$$|W| = 2 \cdot |MST| \dots\dots\dots (1)$$

将理想的旅行商环路（traveling salesman tour）记作 TST 。作为一条环路，从 TST 中删除任何一条边 e 之后，都应得到一条纵贯所有顶点的通路 $TST(e)$ ，这条通路也可视作原图的一棵支撑树。因此，其长度（沿途各边的权重总和）应不小于最小支撑树的总长，亦即：

$$|MST| \leq |TST(e)| < |TST| \dots\dots\dots (2)$$

综合(1)、(2)两式，即有：

$$|W| < 2 \cdot |TST|$$

也就是说，环路 W 的总长度不超过旅行商环路的两倍。

当然，严格地说至此 W 还不是一条旅行商环路——它经过每个顶点至少两次，而不是恰好一次。为此，只需对其遍历一趟，沿途所遇的顶点一旦在此前业已经过，则一概忽略并跳过，而改为一条直接联接的“捷径”。当最终重新回到遍历起点时，即得到了一条严格意义上的环路 $apprTST$ （图中以虚线示意）。

因为这里的带权网络遵守三角不等式，故在上述遍历过程中被跳过各边的总长，不致超过各段捷径的总长，这意味着 $apprTST$ 的总长相对于 W ，只能进一步地缩短。

[6-23] 合成数 (composite number) 法, 是消除图算法歧义性的一种通用方法。

首先, 在顶点的标识之间约定某一次序。比如, 顶点标识为整数或字符时, 可直接以整数或字符为序; 对于字符串等标识, 不妨按字典序排列。于是, 若边 (v, u) 权重为 w , 则对应的合成数取作向量:

$$(w, \min(v, u), \max(v, u))$$

如此, 任何两条边总能明确地依照字典序比较出大小。

试在 6.11.5 节 Prim 算法和 6.12.2 节 Dijkstra 算法中引入这一方法, 以消除其中的歧义性。

【解答】

采用这一方法, 实质的调整无非只是比较器的重新定义, 算法的整体框架及流程均保持不变。具体地, 也就是将原先各边的权重, 替换为其对应的合成数, 并按照字典序判定各边的优先级。

反观 Prim 算法。在最短跨越边同时存在多条时, 该算法可以任取其中之一。虽然如此必然能够构造出一棵最小支撑树, 但却不能保证其唯一确定性。

对于所有边的权重为整数或浮点数的情况, 此前介绍过通过扰动使之唯一确定化的技巧。按照这一方法, 输入序列中各边的扰动量严格单调递增, 故在扰动之后, 原先权重相等的边必然可以按照“前小后大”的准则判定相对的优先级。从这个角度来看, 其效果完全等同于将各边的权重依次替换为如下合成数:

$$W' = \{ (w_1, 1), (w_2, 2), (w_3, 3), \dots, (w_e, e) \}$$

请注意, 这一方法不再局限于整数或浮点数的权重, 因此适用范围更广。

[6-24] 考查某些边的权重不是正数的带权网络。试证明:

a) 对此类网络仍可以定义最小支撑树——此时, Prim 算法是否依然可行?

【解答】

不妨设带权网络 G 中各边权重的最小值为 $-\delta < 0$, 此类网络的最小支撑树同样亦必然存在, 且可以套用 Prim 算法构造出来。

为更清楚地看出这一点, 可以令 G 所有边的权重统一地增加 2δ , 即可得到另一带权网络 G' , 且 G' 中各边权重均为正数, 故 G' 的最小支撑树必然存在。既然 G 和 G' 的顶点与边一一对应, 故其支撑树亦必一一对应。

实际上, 无论各边的权重如何取值, 支撑树所采用边的总数必然固定为 $v - 1$, 其中 v 为顶点总数。因此就总权重而言, G 的每一棵支撑树与 G' 所对应支撑树的差异均为:

$$2\delta \cdot (v - 1)$$

因此, 原网络 G 的最小支撑树必然存在, 而且必与 G' 的最小支撑树对应。

b) 若不含负权重环路, 则仍可以定义最短路径树——此时, Dijkstra 算法是否依然可行?

【解答】

依然可行。

[6-25] 各边权重未必互异时，带权网络的“最小生成树”未必唯一，故应相应地，将其改称作“极小支撑树”更为妥当。对于任一此类的带权网络 G ，试证明：

a) 每一割的极短跨越边都会被 G 的某棵极小支撑树采用；

【解答】

教材176页图6.20已在“各边权重互异”的前提下，证明了Prim算法的正确性。在废除这一前提之后，证明的技巧依然类似。

反证。如该图所示，假设 uv 是割 $(U : V/U)$ 的极短跨越边（之一），但 uv 却未被任何极小支撑树采用。任取一棵极小支撑树 T ，则 T 至少会采用该割的一条跨越边 st 。于是同理，将 st 替换为 uv ，将得到另一棵支撑树 T' ，而且其总权重不致增加。这与假设相悖。

b) G 的每棵极小支撑树中的每一条边，都是某一割的极短跨越边。

【解答】

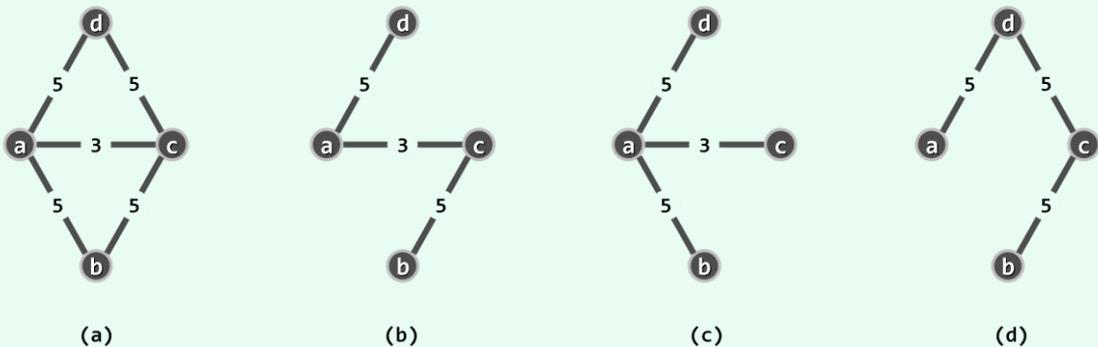
任取 G 的一棵极小支撑树 T ，考查其中的任何一条树边 uv 。将该边删除之后， T 应恰好被分成两棵子树，它们对应的两个顶点子集也构成 G 的一个割 $(U : V \setminus U)$ 。

实际上， uv 必然是该割的极短跨越边（之一）。否则，与 a) 同理，只需将其替换为一条极短跨越边 st ，即可得到一棵总权重更小的支撑树 T' ——这与 T 的极小性矛盾。

[6-26] 试举例说明，在允许多边等权的图 G 中，即便某棵支撑树 T 的每一条边都是 G 某一割的极短跨越边， T 也未必是 G 的极小支撑树。

【解答】

考查如图x6.7(a)所示的带权网络 G 。



图x6.7 完全由极短跨越边构成的支撑树，未必是极小的

首先不难验证，每一条边都是 G 某一割的极短跨越边： ac 为全图的最短边； ad 则为割：

$$(\{ a, b, c \} : \{ d \})$$

的极短跨越边（之一）——根据对称性，其余权重同为5的各边亦是如此。

既然该网络的支撑树都由三条边组成，故如图(b)和(c)所示，总权重为 $3 + 5 + 5 = 13$ 的支撑树必然是极小的。然而如图(d)所示，同样亦由三条极短跨越边构成的支撑树，总权重却为15，显然并非极小支撑树。

[6-27] 试证明，尽管在允许多边等权时，同一割可能同时拥有多条最短跨越边，6.11.5 节中 Prim 算法所采用的贪心迭代策略依然行之有效。（提示：只需证明，只要 T_k 是某棵极小支撑树的子树，则 T_{k+1} 也必是（尽管可能与前一棵不同的）某棵极小支撑树的子树）

【解答】

任取一棵极小支撑树 $T^* = (V, E^*)$ ，以下采用数学归纳法证明：

对于Prim算法过程中所生成的每一棵（子）树 T_k ，都可以在总权重不致增加的前提下，将 T^* 转换为其一棵超树

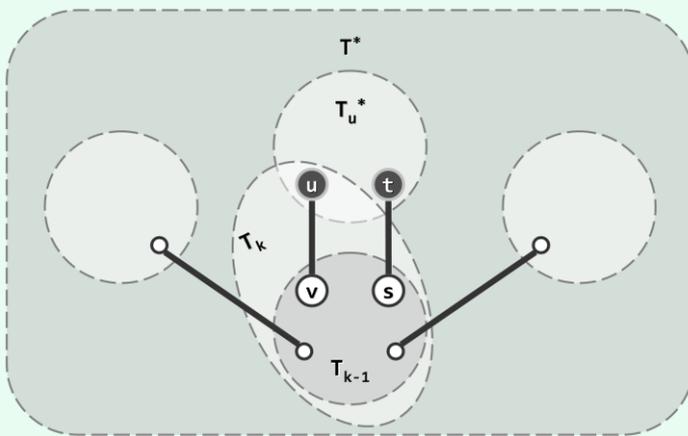
如果这是事实，则意味着Prim算法最终生成的 T_n 也是一棵极小支撑树。

作为归纳基，以上命题对于 T_1 显然成立。

以下，假定上述命题对于 T_1, \dots, T_{k-1} ($2 \leq k$) 均成立。如图x6.8所示，考查：

$$T_k = (V_{k-1} \cup \{u\}, E_{k-1} \cup \{vu\})$$

且不妨设边 $vu \notin E^*$ 。



图x6.8 在各边权重未必互异时，Prim算法依然正确

既然 T^* 是 T_{k-1} 的超树，故在将后者从前者中删除之后， $T^* \setminus T_{k-1}$ 应该是个非空的森林。将顶点 u 在其中所属的子树记作 T_u^* 。在 T^* 中，子树 T_{k-1} 与子树 T_u^* 之间必然有且仅有一条边相联，设为 st （有可能 $s = v$ 或 $t = u$ ，但是不能同时成立）。

现在，在 T^* 中将 st 替换为 vu 。经如此转换之后， T^* 的连通性和无环性依然满足，故仍是原图的一棵支撑树。就权重而言， T^* 新、旧两个版本之间的差异为 $|vu| - |st|$ 。鉴于Prim算法挑选的 vu 必然是极短跨越边，故新版本的权重不致增加（当然，也不可能下降）。由此可见，归纳假设对 T_k 也依然成立。

[6-28] Joseph Kruskal 于 1956 年^[31]提出了构造极小支撑树的另一算法：

将每个顶点视作一棵树，并将所有边按权重非降排序；
 依次考查各边，只要其端点分属不同的树，则引入该边，并将端点所分别归属的树合二为一；
 如此迭代，直至累计已引入 $n - 1$ 条边时，即得到一棵极小支撑树。

试证明：

a) 算法过程中所引入的每一条边，都是某一割的极短跨越边（因此亦必属于某棵极小支撑树）；

【解答】

考查Kruskal算法每一步迭代中所引入的边 vu 。在此步迭代即将执行之前， v 必属于当时森林中的某棵子树，将其记作 T_v 。 T_v 及其补集，构成原图的一个割。不难看出， vu 既然（作为当时不致造成环路的极短边）被选用，则它必然也是该割的极短跨越边。

b) 算法过程中的任一时刻，由已引入的边所构成的森林，必是某棵极小支撑树的子图；

（请注意，这一结论方足以确立 Kruskal 算法的正确性，但前一结论并不充分）

【解答】

任取一棵极小支撑树 $T^* = (V, E^*)$ ，以下采用数学归纳法证明：

对于Kruskal算法过程中的每一个森林 F_k

都可以在总权重不致增加的前提下，将 T^* 转换为其一棵超树

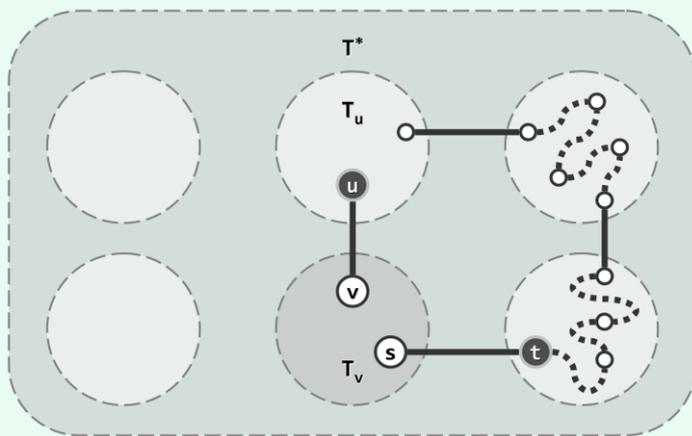
如果这是事实，则意味着Kruskal算法最终生成的 $T_n = F_n$ 也是一棵极小支撑树。

作为归纳基，以上命题对于 F_0 显然成立。

以下，假定上述命题对于 F_0, \dots, T_{k-1} ($1 \leq k$) 均成立。如图x6.9所示，考查：

$$F_k = (V, E_{k-1} \cup \{vu\})$$

且不妨设边 $vu \notin E^*$ 。



图x6.9 Kruskal算法的正确性

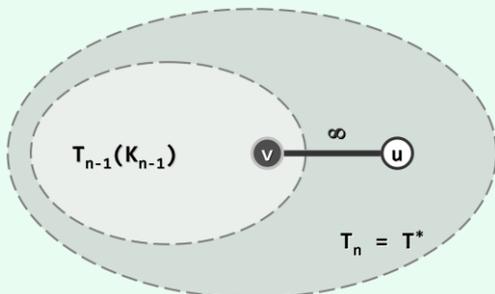
将 v 和 u 所属的子树分别记作 T_v 和 T_u 。既然 T^* 是 F_{k-1} 的超树，故 T^* 中必然在 T_v 和 T_u 之间存在（唯一的）一条通路。该通路可能就是 vu 之外的另一跨越边，也可能是转辗穿过其它子树的一条迂回通路。无论如何，如图所示将该通路的起始边设为 st 。

现在，在 T^* 中将 st 替换为 vu 。经如此转换之后， T^* 的连通性和无环性依然满足，故仍是原图的一棵支撑树。就权重而言， T^* 新、旧两个版本之间的差异为 $|vu| - |st|$ 。鉴于Kruskal算法挑选的 vu 必然是极短跨越边，故新版本的权重不致增加（当然，也不可能下降）。由此可见，归纳假设对 F_k 也依然成立。

[6-29] 试举例说明, 在最坏情况下, Kruskal 算法的确可能需要检查 $\Omega(n^2)$ 条边。

【解答】

一类最坏的情况, 如图x6.10所示。



图x6.10 Kruskal算法的最坏情况

该实例中, 原网络中的 $n - 1$ 个顶点构成完全图 K_{n-1} , 其中各边的权重相对不大; 最后一个顶点 u , 则仅通过一条权重足够大的边 vu 与完全图相联。

若将 $(\{u\} : K_{n-1})$ 视作割, 则 vu 是唯一的跨越边。因此, 尽管该边的权重在全局最大, 但该带权网络的任何一棵极小支撑树 T^* , 都必会采用该边。

而按照Kruskal算法的策略, vu 必然是作为最后一条边接受检查; 在此前, 该算法也必然已经遍历过 K_{n-1} 中所有的边, 累计耗时总量为:

$$n(n - 1)/2 + 1 = \Omega(n^2)$$

[6-30] 若将森林中的每棵树视作一个等价类, 则 Kruskal 算法迭代过程所涉及的计算不外乎两类:

```
T = find(x) //查询元素(顶点)x所属的等价类(子树)T
union(x, y) //将元素(顶点)y所属的等价类(子树), 合并至元素(顶点)x所属的等价类(子树)
```

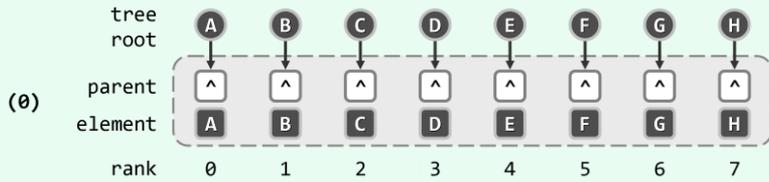
支持以上操作接口的数据结构, 即所谓的独立集(disjoint set), 亦称作并查集(union-find set) [32][33][34][35]。

a) 试基于此前介绍过的基本数据结构实现并查集, 并用以组织 Kruskal 算法中的森林;

【解答】

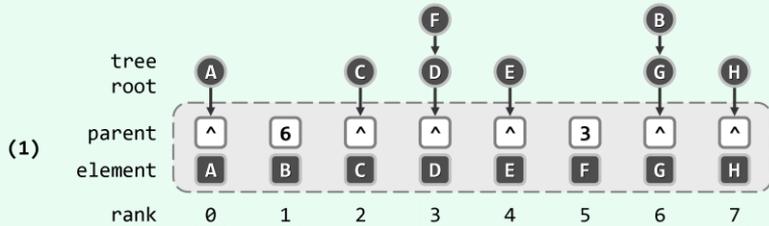
并查集中的等价类, 可以视作某一全集经划分之后得到的若干互不相交的子集。最初状态下, 全集中的每个元素自成一个子集, 并以该元素作为其标识。此后, 每经过一次 $union(x, y)$ 操作, 都将元素 y 所属的子集归入元素 x 所属的子集, 并继续沿用元素 x 此前的标识。

一种可行的方法是, 将并查集中的所有元素组织为一个向量, 其中的子集则以多叉树的形式实现。以由8个元素组成的并查集 $\{\{A\}, \{B\}, \{C\}, \{D\}, \{E\}, \{F\}, \{G\}, \{H\}\}$ 为例, 其初始状态如图x6.11所示。如以上约定, 各元素自成一棵树, 故parent值统一取作-1。



图x6.11 并查集：初始状态

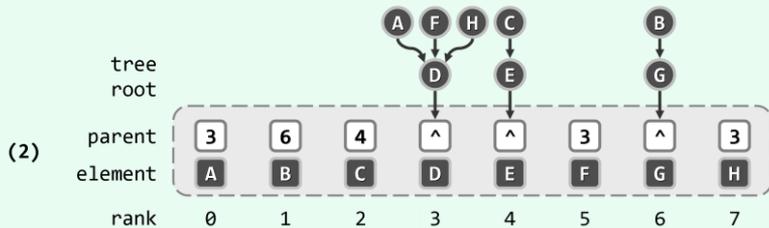
如此，子集的合并操作可对应于树的合并操作。既然元素所属的子集就是其所属的树，故对二者亦不必刻意区分。比如，在经过union(D, F)和union(G, B)操作之后，以上并查集的内部结构及逻辑结构如图x6.12所示。其效果等同于，将F所属的树归入D所属的树，并继续沿用原标识D；将B所属的树归入G所属的树，并继续沿用原标识G。



图x6.12 并查集：经union(D, F)和union(G, B)操作之后

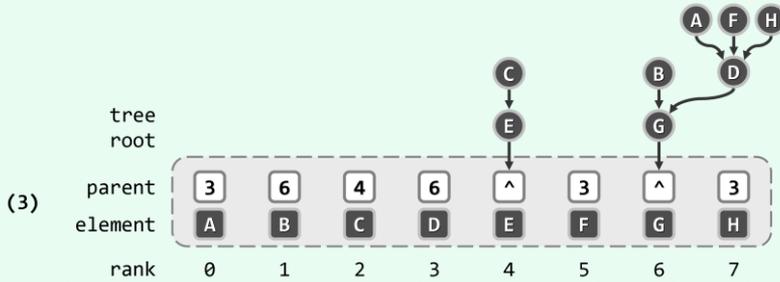
这里约定，每个子集的标识就是其所对应的树根元素。于是为了实现find(x)操作，只需从元素x出发找到其对应的树根。为此，只需要记录每个元素的父节点——亦即其在向量中的秩。比如，元素F对应的parent值从初始的-1修改为3，指向元素D；元素B对应的parent值从初始的-1修改为6，指向元素G。

以下如图x6.13所示，经union(D, A)和union(F, H)之后，元素A和H都被归入以元素D为根（标识）的树（子集）中；经union(E, C)之后，元素C被归入元素E所属的树中。请留意这里对有关元素parent值的设置，以及逻辑上树形结构的对应变化。



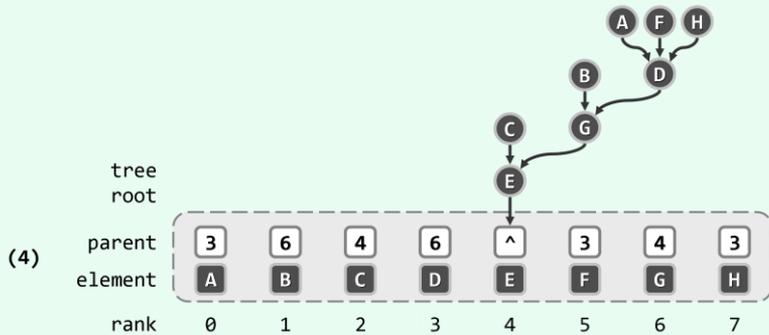
图x6.13 并查集：经union(D, A)、union(F, H)和union(E, C)操作之后

以下，假设继续执行union(B, A)操作。为此可如图x6.14所示，首先顺着parent的指示找到元素B和元素A各自所属的树根（子集标识）G和D；再通过将元素D的parent值从-1修改为6（指向元素G），从而将树D（对应的子集）整体归入树G（对应的子集）。



图x6.14 并查集：经union(B, A)操作之后

以下，假设继续执行union(C, F)操作。为此可如图x6.15所示，首先顺着parent的指示找到元素C和元素F各自所属的树根（子集标识）E和G；再通过将元素G的parent值从-1修改为4（指向元素E），从而将树G（对应的子集）整体归入树E（对应的子集）。



图x6.15 并查集：经union(C, F)操作之后（树高未能有效控制）

由于并查集的union()操作并不可逆，故至此以后该结构将不会再实质性的调整。

b) 按你的实现，find()和 union()接口的复杂度各是多少？相应地，Kruskal 算法的复杂度呢？

【解答】

无论find()或union()，都需要首先确定相关元素所属子集的标识（树根）。为此，需要沿着parent的指示不断上行，因此执行时间主要取决于元素在树中所处的深度；就最坏情况而言，取决于树的高度。然而按照目前的策略，我们并不能有效地控制树高。

仍以如图x6.11所示的初始并查集为例，假若接下来依次执行：

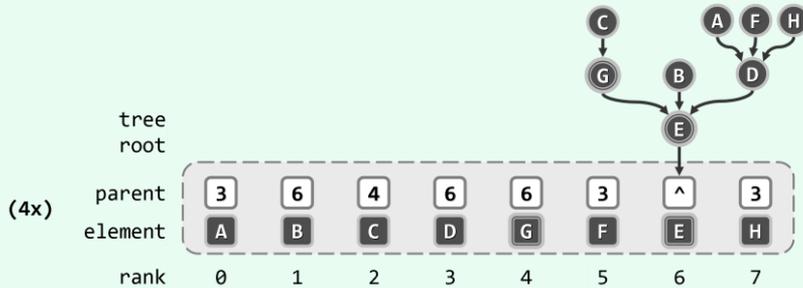
union(A, B), union(B, C), union(C, D), ..., union(G, H)

则不难验证，各次union()操作所需的时间将按算术级数递增。

一般地在最坏情况下，对于包含n个元素的并查集，以上过程共需 $O(n^2)$ 时间，单次操作平均需要 $O(n)$ 时间——退化到蛮力算法。相应地，基于该版本并查集的Kruskal算法，可能平均而言每步迭代都需要线性时间，累计共需 $O(n \cdot e)$ 时间。

为有效控制树的高度，还可采用其它的策略。比如在合并树时，可以采取“低者归入高者”的策略。也就是说，比较待合并的树的高度，并倾向于将更低者归入更高者。

仍以如图x6.14所示的并查集为例，以下同样执行union(C, F)。在找出对应的树G和E之后，经比较发现前者更高。故与如图x6.15所示的合并方向相反，只要改为将树E归入树G，则如图x6.16所示，合并之后的树高即可由3降至2。



图x6.16 并查集：经union(C, F)操作之后（“低者归入高者”以控制树高）

当然，为此还需要给每个元素增添一个域，以动态记录其高度：初始统一取作0；合并时若两树高度相等，则合并后树根的高度值相应地递增；若高度不等，则无调整。

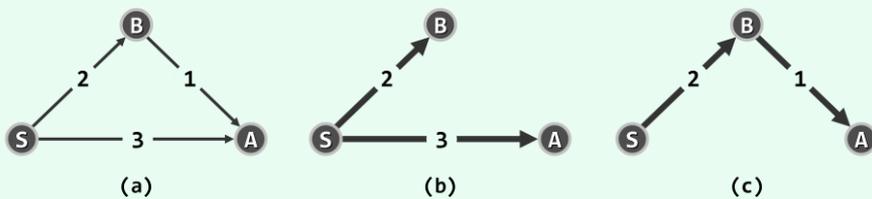
最后，为了遵守此前关于子集标识的沿用约定，还有可能需要交换原先的两个树根——比如此例中的元素E和G——包括它们各自的标识以及parent值。

有效控制树高的另一策略是路径压缩（path compression），它源自如下观察事实：就此问题而言，树中元素之间的拓扑联接关系并不重要；另外，因为仅涉及（沿parent指示的）上行查找而无需下行查找，故孩子的数目并不影响查找效率。因此，在对每个元素做查找的同时，可以将上行通路上的所有元素取出，再统一作为树根的孩子重新接入。如此，树可以尽可能地平坦化，从而进一步地控制树高。

[6-31] 试举例说明，即便带权网络中不含权重相等的边，其最短路径树依然可能不唯一。

【解答】

最简单的一个实例如图x6.17所示。



图x6.17 各边权重互异时，最短路径树依然可能不唯一

对照图(a)不难确认：该带权网络中各边的权重互异；相对于起始顶点S，顶点A和B的最短距离分别为3和2。然而对于A而言，最短路径有两条（{ S, A }和{ S, B, A }），相应地如图(b)和(c)所示有两棵最短路径树。

[6-32] 若图 G 的顶点取自平面上的点, 各顶点间均有联边且权重就是其间的欧氏距离, 则 G 的最小支撑树亦称作欧氏最小支撑树 (Euclidean Minimum Spanning Tree, EMST), 记作 $EMST(G)$ 。

a) 若套用 Kruskal 或 Prim 算法构造 $EMST(G)$, 各需多少时间?

【解答】

带权网络 G 是由平面点集隐式定义的完全图, 故若 G 由 n 个顶点构成, 则所含边数应为:

$$e = n(n - 1)/2 = O(n^2)$$

因此若直接调用 (借助优先级队列结构改进之后的) Prim 算法, 渐进的时间复杂度应为:

$$O((n + e) \cdot \log n) = O(n^2 \log n)$$

因此若直接调用 Kruskal 算法, 渐进的时间复杂度应为:

$$O(e \log n) = O(n^2 \log n)$$

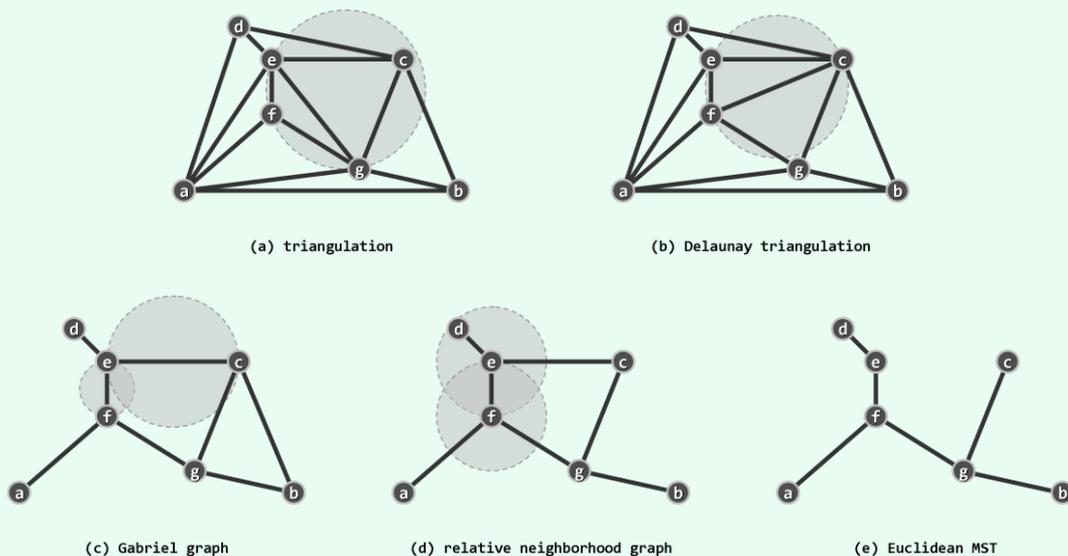
b) 试设计一个算法, 在 $O(n \log n)$ 时间内构造出 $EMST(G)$;

(提示: Delaunay 三角剖分 (Delaunay triangulation))

【解答】

由上可见, 为了能够高效地构造欧氏最小支撑树, 必须回避对多达 $O(n^2)$ 条边的处理。

为此, 可以首先通过预处理, 将由欧式距离隐式定义的完全图, 转化为如图 x6.18 所示的某种邻近图 (proximity graph); 然后, 再针对邻近图调用 Prim 之类的常规算法。



图x6.18 由平面点集依照欧氏距离隐式定义的若干典型的邻近图

其中图(a)为三角剖分 (triangulation), 也就是原隐式完全图的任意极大平面子图。因每个子区域都是三角形, 故此得名。不难发现, 同一点集的三角剖分往往并不唯一确定——但其所保留的边总数固定, 所分出的三角形总数已固定。

任一点集都有一个特殊的三角剖分, 称作Delaunay三角剖分 (Delaunay triangulation)。如图(b)所示, 在这种三角剖分中, 任意三角形的外接圆都不包含第四个点——亦即所谓的空圆

性质 (empty-circle property)。反观图(a)，其中三角形efg的外接圆内还有c点，故而不属于Delaunay三角剖分。

可以按照以下准则，从Delaunay三角剖分中剔除若干条边：一条边被剔除，当且仅当以其为直径的圆中（除了该边的两个端点）还包含第三个点。如此保留下来的子图如图(c)所示，即是所谓的Gabriel图 (Gabriel graph)。读者不妨对照图(b)和图(c)，核对各边确实都是按照以上准则被保留或剔除。

进一步地，可以按照以下原则，从Gabriel图中再剔除若干条边：一条边被剔除，当且仅当以其为半径、分别以其端点为圆心的两个圆，不会同时包含第三个点。如此保留下来的子图如图(d)所示，即是所谓的RNG图 (relative neighborhood graph)。读者不妨对照图(c)和图(d)，核对各边确实都是按照以上准则被保留或剔除。

由上可见，Delaunay三角剖分、Gabriel图、RNG图依次构成“超图-子图”的关系。

实际上进一步地还可以证明，如图(d)和图(e)所示，欧氏最小支撑树必是RNG图的子图。这一事实的证明方法和技巧，与教材第6.11.5节“最小支撑树必然采用极短跨越边”的证明极其相似，我们将此留给读者独立完成。

既然三角剖分是平面图，故以上介绍的所有邻近图亦是。根据习题[6-3]的结论，其所含边的总数必然与顶点数渐进地相当，从 $O(n^2)$ 降低到 $O(n)$ 。

另一好消息是，以上邻近图均可在 $O(n \log n)$ 的时间内构造出来。因此这里的预处理通常并不会增加整体的渐进时间复杂度。

c) 试证明你的算法已是最优的 (亦即，在最坏情况下，任何此类算法都需要 $\Omega(n \log n)$ 时间)。

【解答】

对于任意平面点集 G ，可以定义最近邻图 (nearest neighbor graph, NNG) 如下：

边 pq 属于该图，当且仅当点 q 在 $G \setminus \{p\}$ 中距离 p 最近

请注意，最近邻图是有向图。也就是说， q 是 p 的最近邻，未必反之亦然。

考查经典的 ε -间距问题 (ε -closeness)：

设 P 为由任意 n 个实数构成的集合，对于任意的 $\varepsilon > 0$ ，判定 P 中是否存在两个实数的差距不大于 ε

该问题的难度，已经证明为 $\Omega(n \log n)$ 。

实际上可以证明，最近邻图必然是欧氏最小支撑树的子图。特别地，该图中的最短边，即是所谓点集 G 中的最近点对 (nearest pair)。

不难看出， ε -间距问题可在线性时间内归约至最近点对问题，而最近点对问题又可以进一步地在线性时间内归约至欧氏最小支撑树问题。根据线性归约的传递性， ε -间距问题可在线性时间内归约至欧氏最小支撑树问题。

于是自然地， $\Omega(n \log n)$ 的复杂度下界，亦适用于欧氏最小支撑树问题。这意味着，在没有其它附加条件的前提下，以上所设计的 $O(n \log n)$ 算法，应该已经属于最坏情况下最优的。

第7章

搜索树

[7-1] 试证明，一棵二叉树是二叉搜索树，当且仅当其中序遍历序列单调非降。

【解答】

考查二叉搜索树中的任一节点 r 。按照中序遍历的约定， r 左（右）子树中的节点（若存在）均应先于（后于） r 接受访问。

按照二叉搜索树的定义， r 左（右）子树中的节点（若存在）均不大于（不小于） r ，故中序遍历序列必然在 r 处单调非降；反之亦然。

鉴于以上所取 r 的任意性，题中命题应在二叉搜索树中处处成立。

由此题亦可看出，二叉搜索树的定义不能更改为“任意节点 r 的左（右）孩子（若存在）均不大于（不小于） r ”——相当于将原定义中的“左（右）后代”，替换为“左（右）孩子”。为强化印象，读者不妨构造一个符合这一“定义”，但却不是二叉搜索树的具体实例。

[7-2] 试证明，由一组共 n 个互异节点组成的二叉搜索树，总共有 $(2n)!/n!/(n+1)!$ 棵。

【解答】

我们将 n 个互异节点所能组成二叉搜索树的总数，记作 $T(n)$ 。

由上题结论，尽管由同一组节点组成的二叉搜索树不尽相同，但它们的中序遍历序列却必然相同，不妨记作：

$$\boxed{x_0 \ x_1 \ x_2 \ \dots \ x_{k-1}} \quad x_k \quad \boxed{x_{k+1} \ x_{k+2} \ \dots \ x_{n-1}}$$

根据所取树根节点的不同，所有搜索树可以分为 n 类。如上所示，对于其中以 x_k 为根者而言，左、右子树必然分别由 $\{x_0, x_1, x_2, \dots, x_{k-1}\}$ 和 $\{x_{k+1}, x_{k+2}, \dots, x_{n-1}\}$ 组成。

如此，可得边界条件和递推式如下：

$$T(0) = T(1) = 1$$

$$T(n) = \sum_{k=0}^{n-1} T(k) \cdot T(n-k-1)$$

这是典型的Catalan数式递推关系，解之即得题中结论。

[7-3] 试证明，含 n 个节点的二叉树的最小高度为 $\lfloor \log_2 n \rfloor$ ——这也是由 n 个节点组成的完全二叉树高。

【解答】

实际上不难证明，若高度为 h 的二叉树共含 n 个节点，则必有：

$$n \leq 2^{h+1} - 1$$

这里的等号成立，当且仅当是满树。于是有：

$$h \geq \log_2(n+1) - 1$$

$$h \geq \lceil \log_2(n+1) \rceil - 1 = \lfloor \log_2 n \rfloor$$

[7-4] 与其它算法类似，searchIn()算法的递归版（教材 186 页代码 7.3）也存在效率低下的问题。试将该算法改写为迭代形式。请注意保持出口时返回值和 hot 的语义。

【解答】

只要注意到该算法的递归形式接近于尾递归，即可实现其迭代版如代码x7.1所示。

```
#define EQUAL(e, v) (! (v) || (e) == (v)->data) //节点v (或假想的通配哨兵) 的关键码等于e
template <typename T> //在以v为根的 (AVL、SPLAY、rbTree等) BST子树中查找关键码e
static BinNodePosi(T)& searchIn (BinNodePosi(T)& v, const T& e, BinNodePosi(T)& hot) {
    if (EQUAL(e, v)) return v; hot = v; //退化情况：在子树根节点v处命中
    while (1) { //一般地，反复不断地
        BinNodePosi(T)& c = (e < hot->data) ? hot->lChild : hot->rChild; //确定深入方向
        if (EQUAL(e, c)) return c; hot = c; //命中返回，或者深入一层
    } //hot始终指向最后一个失败节点
} //返回时，返回值指向命中节点 (或假想的通配哨兵)，hot指向其父亲 (退化时为初始值NULL)
```

代码x7.1 二叉搜索树searchIn()算法的迭代实现

不难验证，该迭代版出口时返回值和hot的语义，与递归版完全一致。

[7-5] 试证明，采用BST::insert()算法（教材 188 页代码 7.5），在二叉搜索树中插入节点v之后
a) 除v的历代祖先以外，其余节点的高度无需更新；

【解答】

我们知道，节点的高度仅取决于其后代——更确切地，等于该节点与其最深后代之间的距离。因此在插入节点v之后，节点a的高度可能发生变化（增加），当且仅当v是a的后代，或反过来等价地，a是v的祖先。

b) 祖先高度不会降低，但至多加一；

【解答】

插入节点v之后，所有节点的后代集不致缩小。而正如前述，高度取决于后代深度的最大值，故不致下降。

另一方面，假定节点a的高度由h增加至h'。若将v的父节点记作p，则a到p的距离不大于a在此之前的高度h，于是必有：

$$h' \leq |ap| + 1 \leq h + 1$$

c) 一旦某个祖先高度不变，更高的祖先也必然高度不变。

【解答】

对于任意节点p，若将其左、右孩子分别记作l和r（可能是空），则必有：

$$\text{height}(p) = 1 + \max(\text{height}(l), \text{height}(r))$$

在插入节点v之后，在l和r之间，至多其一可能会（作为v的祖先而）有所变化。一旦该节点的高度不变，p以及更高层祖先（如果存在的话）的高度亦保持不变。

[7-6] 试证明，采用 `BST::remove()` 算法（教材 190 页代码 7.6）从二叉搜索树中删除节点，若实际被删除的节点为 x ，则此后：

a) 除 x 的历代祖先以外，其余节点的高度无需更新；

【解答】

同样地，节点的高度仅取决于其后代——更确切地，等于该节点与其最深后代之间的距离。因此在删除节点 x 之后，节点 a 的高度可能发生变化（下降），当且仅当 x 是 a 的后代，或反过来等价地， a 是 x 的祖先。

b) 祖先高度不会增加，但至多减一；

【解答】

假设在删除节点 x 之后，祖先节点 a 的高度由 h 变化为 h' 。现在，我们假想式地将 x 重新插回树中，于是自然地， a 的高度应该从 h' 恢复至 h 。由 [7-5] 题的结论 b)，必有：

$$h \leq h' + 1$$

亦即：

$$h' \geq h - 1$$

c) 一旦某个祖先高度不变，更高的祖先也必然高度不变。

【解答】

反证，假设在删除节点 x 之后，祖先节点的高度会间隔地下降和不变。

仿照上一问的思路，假想着将 x 重新插回树中。于是，所有节点的高度均应复原，而祖先节点的高度则必然会间隔地上升和不变。这与 [7-5] 题的结论 c) 相悖。

[7-7] 利用以上事实，进一步改进 `updateHeightAbove()` 方法，提高效率。

【解答】

在逐层上行依次更新祖先高度的过程中，一旦某一祖先的高度不变，便可随即终止。

当然，就最坏情况而言，依然必须更新至树根节点。

[7-8] a) 试按照随机生成和随机组成两种方式，分别进行实际测试，并统计出二叉搜索树的平均高度；

b) 你得到的统计结果，与 7.3.1 节所给的结论是否相符？

【解答】

请读者按照教材中对这两种方式的定义，以及相关的介绍，独立完成编码、调试和实测任务，并根据统计结果给出结论和分析。

[7-9] `BinTree::removeAt()` 算法（教材 190 页代码 7.7）的执行过程中，当目标节点同时拥有左、右孩子时，总是固定地选取直接后继与之交换。于是，从二叉搜索树的整个生命期来看，左子树将越来越倾向于高于右子树，从而加剧整体的不平衡性。

一种简捷且行之有效的改进策略是，除直接后继外还同时考虑直接前驱，并在二者之间随机选取。

a) 试基于习题[5-14]扩展的 `pred()` 接口, 实现这一策略;

【解答】

针对这一问题, 实现随机选取的一种简明方法是:

调用 `rand()` 取 (伪) 随机数, 根据其奇偶, 相应地调用 `succ()` 或 `pred()` 接口

从理论上讲, 如此可以保证各有 50% 的概率使用直接后继或直接前驱, 从而在很大程度上消除题中指出的“天然”不均衡性。

`BinTree::removeAt()` 算法的其余部分, 无需任何修改。

b) 通过实测统计采用新策略之后的平均树高, 并与原策略做一对比。

【解答】

请读者按照以上介绍, 独立完成编码、调试和实测任务, 并根据统计结果给出结论和分析。

[7-10] 为使二叉搜索树结构支持多个相等数据项的并存, 需要增加一个 `BST::searchAll(e)` 接口, 以查找出与指定目标 `e` 相等的所有节点 (如果的确存在)。

a) 试在 `BST` 模板类 (教材 185 页代码 7.2) 的基础上, 扩充接口 `BST::searchAll(e)`。

要求该接口的时间复杂度不超过 $O(k + h)$, 其中 h 为二叉搜索树的高度, k 为命中节点的总数;

【解答】

从后面第 8.4.1 节所介绍范围查询的角度来看, 从二叉搜索树中找出所有数值等于 `e` 的节点, 完全等效于针对区间 $(e - \epsilon, e + \epsilon)$ 的范围查找, 其中 ϵ 为某一足够小的正数。

因此, 自然可以套用第 8.4.1 节所给的算法框架: 针对 `e - ϵ` 和 `e + ϵ` 各做一次查找, 并确定查找路径终点的最低公共祖先; 在从公共祖先通往这两个终点的路径上, 自上而下地根据各层的分支方向, 相应地忽略整个分支, 或者将整个分支悉数报告出来。

整个算法所拣出的分支, 在每一层不超过两个, 故总共不会超过 $O(h)$ 个。借助 (任何一种常规的) 遍历算法, 都可在线性时间内枚举出每个分支中的所有节点; 而对所有分支的遍历, 累计耗时亦不过 $O(k)$ 。

需要特别说明的是, 这里既不利于也不需要显式地确定 ϵ 的具体数值。实际上, 我们只需要对比较器做适当的调整: 针对 `e - ϵ` (`e + ϵ`) 的查找过程, 与针对 `e` 的查找过程基本相同, 只是在遇到数值为 `e` 的节点时, 统一约定向左 (右) 侧深入。

b) 同时, 改进原有的 `BST::search(e)` 接口, 使之总是返回最早插入的节点 `e`——即先进先出。

【解答】

在中序遍历序列中, 所有数值为 `e` 的雷同节点, 必然依次紧邻地构成一个区间。为实现“先进先出”的规范, 需要进一步地要求它们在此区间内按插入次序排列。

为此可以统一约定: 在 `BST::insert(e)` 内的查找定位过程中, 凡遇到数值相同的节点, 均优先向右侧深入; 而在 `BST::search(e)` 的查找过程中, 凡遇到数值相同的节点, 均向左侧深入。当然, 将以上约定的左、右次序颠倒过来, 亦同样可行。

[7-11] 考查包含 n 个互异节点的二叉搜索树。

试证明，无论树的具体形态如何， $BST::search()$ 必然恰有 n 种成功情况和 $n + 1$ 种失败情况。

【解答】

通过对树高做数学归纳，不难证明。请读者独立完成这一任务。

[7-12] 试证明，在高度为 h 的 AVL 树中，任一叶节点的深度均不小于 $\lceil h/2 \rceil$ 。

【解答】

对树高 h 做数学归纳。作为归纳基， $h = 1$ 时的情况显然。假设以上命题对高度小于 h 的 AVL 树均成立，以下考查高度为 h 的 AVL 树。

根据 AVL 树的性质，如图 x7.1 所示，此时左、右子树的高度至多为 $h - 1$ ，至少为 $h - 2$ 。

由归纳假设，在高度为 $h - 1$ 的子树内部，叶节点深度不小于：

$$\lceil (h - 1)/2 \rceil \geq \lceil h/2 \rceil - 1$$

而在高度为 $h - 2$ 的子树内部，叶节点深度也不小于：

$$\lceil h/2 \rceil - 1$$

因此在全树中，任何叶节点深度都不致小于：

$$1 + (\lceil h/2 \rceil - 1) = \lceil h/2 \rceil$$

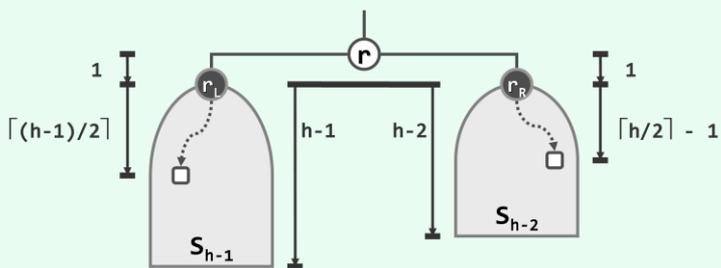


图 x7.1 AVL 树中最浅的叶节点

[7-13] 试证明：

a) 按照二叉搜索树的基本算法在 AVL 树中引入一个节点后，失衡的节点可能多达 $\Omega(\log n)$ 个；

【解答】

首先，引入一类特殊的 AVL 树，它们符合以下条件：其中每个内部节点的左子树，都比右子树在高度上少一。这也就是所谓的 Fib-AVL 树 (Fibonacci AVL tree)。

如图 x7.2 (a~d) 所示，即为高度分别为 1、2、3 和 4 的 Fib-AVL 树。通过数学归纳法不难证明，此类 AVL 树的高度若为 h ，则其规模必然是 $\text{fib}(h + 3) - 1$ ，故此得名。实际上，Fib-AVL 树也是在高度固定的前提下，节点总数最少的 AVL 树。

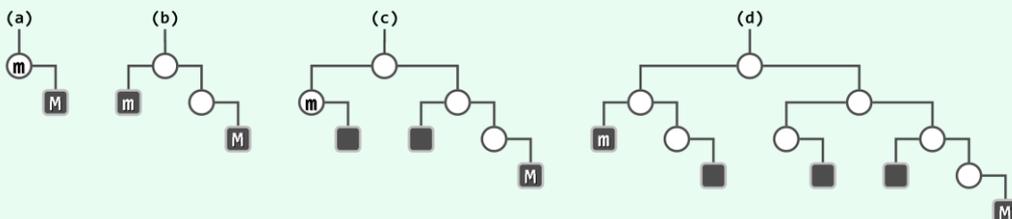


图 x7.2 Fib-AVL 树

考查其中数值最大 (中序遍历序列中最靠后) 的节点 M 。该节点共计 h 个祖先，而且它们的平衡因子均为 -1 。现在，假设需要将一个词条插入其中，而且该词条大于节点 M 。

按照二叉搜索树的插入算法，必然会相应地在节点M之下，新建一个右孩子x。此时，节点M所有祖先的平衡因子都会更新为-2，从而出现失衡现象。失衡节点的总数为：

$$h = \text{fib}^{-1}(n + 1) - 3 = \log_{\phi} n = \mathcal{O}(\log n)$$

其中，

$$\Phi = (\sqrt{5} + 1) / 2 = 1.618$$

b) 按照二叉搜索树的基本算法从 AVL 树中摘除一个节点后，失衡的节点至多 1 个。

【解答】

请注意，节点的失衡与否，取决于其左、右子树高度之差。因此反过来，只要子树的高度不变，则节点不可能失衡。

在删除节点之后自底而上逐层核对平衡因子的过程中，一旦遇到一个失衡节点v，则被删除节点必然来自v原本更低的一棵子树，而v的高度必然由其另一更高的子树确定，故v的高度必然保持不变。由以上分析结论，除了v本身，其祖先节点必然不可能失衡。

[7-14] 按照教材第 7.3.4 节的定义和描述，实现节点旋转调整算法 zig() 和 zag()。

【解答】

请读者对照教材193页图7.11，以及193页图7.12，独立完成编码和调试任务。

[7-15] 试证明：

a) 规模为 n 的任何二叉搜索树，经过不超过 n - 1 次旋转调整，都可等价变换为仅含左分支的二叉搜索树，即最左侧通路 (leftmost path)；

【解答】

可以设计一个具体的算法，以完成这一等价变换。为此，需要回顾迭代式先序遍历算法的版本#2（教材128页代码5.14），并对该算法的流程略作改动。

具体地如教材127页图5.18所示，考查二叉搜索树的最左侧通路。从该通路的末端节点 L_d 开始，我们将逐步迭代地延长该路径，直至不能继续延长。每次迭代，无非两种情况：

其一，若 L_k 的右子树为空，则可令 L_k 上移一层，转至其父节点。

其二，若 L_k 的右孩子 R_k 存在，则可以 L_k 为轴，做一次zag旋转调整。如此， R_k 将（作为 L_k 的父亲）纳入最左侧通路中。

不难看出，整个迭代过程的不变性为：

- 1) 当前节点 L_k 来自最左侧通路
- 2) L_k 的左子树（由不大于 L_k 的所有节点组成）已不含任何右向分支

另外，整个迭代过程也满足如下单调性：

最左侧通路的长度，严格单调地增加

故该算法必然终止，且最终所得的二叉搜索树不再含有任何右向分支。

以上思路，可具体实现如代码x7.2所示。

```

1 //通过zag旋转调整，将子树x拉伸成最左侧通路
2 template <typename T> void stretchByZag(BinNodePosi(T)& x) {
3     int h = 0;
4     BinNodePosi(T) p = x; while (p->rChild) p = p->rChild; //最大节点，必是子树最终的根
5     while (x->lChild) x = x->lChild; x->height = h++; //转至初始最左侧通路的末端
6     for ( ; x != p; x = x->parent, x->height = h++) { //若x右子树已空，则上升一层
7         while (x->rChild) //否则，反复地
8             x->zag(); //以x为轴做zag旋转
9     } //直到抵达子树的根
10 }

```

代码x7.2 power2BF_I()算法的递归版

可见，每做一次zag旋转调整，总有一个节点归入最左侧通路中，后者的长度也同时加一。最坏情况下，除原根节点外，其余节点均各自对应于一次旋转，累计不过 $n - 1$ 次。

通过进一步的观察不难看出：

任一节点需要通过一次旋转归入最左侧通路，当且仅当它最初不在最左侧通路上

故若原最左侧通路的长度为 s ，则上述算法所做的旋转调整，恰好共计 $n - s - 1$ 次。

其中特别地， $s = 0$ （根节点的左子树为空），当且仅当需做 $n - 1$ 次旋转——这也是最坏情况的充要条件。

b) 规模为 n 的任何两棵等价二叉搜索树，至多经过 $2n - 2$ 次旋转调整，即可彼此转换。

【解答】

既然每棵二叉搜索树经过至多 $n - 1$ 次旋转调整，总能等价变换为最左侧通路，故反之亦然。因此，对于任何两棵二叉搜索树，都可按照上述方法，经至多 $n - 1$ 次旋转调整，先将其一等价变换为最左侧通路；然后同理，可再经至多 $n - 1$ 次旋转调整，从最左侧通路等价变换至另一棵二叉搜索树。

[7-16] 为使 AVL 树结构支持多个相等数据项的并存，需要增加一个 `AVL::searchAll(e)` 接口，以查找出与指定目标 e 相等的所有节点（如果的确存在）。

a) 试在如 194 页代码 7.8 所示 AVL 模板类的基础上扩充接口 `AVL::searchAll(e)`，要求其时间复杂度不得超过 $O(k + \log n)$ ，其中 n 为 AVL 树的规模， k 为命中节点的总数；

【解答】

原理及方法均与习题[7-10]完全相同。

性能方面，通过遍历枚举所有命中子树中的节点，仍可以在线性的 $O(k)$ 时间内完成；因为AVL树可以保持适度平衡，故所涉及的查找可以更快完成，累计耗时不超过 $O(\log n)$ 。

b) 同时,改进原有的 $AVL::search(e)$ 接口,使之总是返回最早插入的节点 e ——即先进先出。

【解答】

原理及方法均与习题[7-10]基本相同。

需要强调的是,尽管在插入或删除操作的过程中,可能会做旋转以重新平衡,但因这些都属于等价变换,(包括雷同节点在内的)所有节点的中序遍历序列始终保持不变,每一组雷同节点都始终依照插入次序排列。

[7-17] 试证明,对于任意大的正整数 n ,都存在一棵规模为 n 的 AVL 树,从中删除某一特定节点之后,的确需要做 $\Omega(\log n)$ 次旋转,方能使全树恢复平衡。

【解答】

首先,考查习题[7-13]所引入的Fib-AVL树。

如150页的图x7.2(a~d)所示,若从该树中删除最小的节点(亦即中序遍历序列中的首节点) m ,则首先会导致 m 的父节点 p 失衡。在树高 h 为奇数时, m 虽不是叶节点,但按照二叉搜索树的删除算法,在实际摘除 m 之前,必然已经将 m 与其直接后继(此时亦即其右孩子)交换,从而等效于删除其右孩子。

不难验证,在父节点 p 恢复平衡之后,其高度必然减一,从而造成 m 祖父节点 g 的失衡。同样地,尽管节点 g 可以恢复平衡,但其高度必然减一,从而造成更高层祖先的失衡。这种现象,可以一直传播至树根。

仿照习题[7-12]的分析方法不难证明,在高度为 h 的Fib-AVL树中,节点 m 的深度为 $\lfloor h/2 \rfloor$ 。因此,上述重平衡过程所涉及的节点旋转次数应不少于:

$$\begin{aligned} \lfloor h/2 \rfloor &= \lfloor (\text{fib}^{-1}(n+1) - 3)/2 \rfloor \\ &= \log_{\phi} n / 2 \\ &= \Omega(\log n) \end{aligned}$$

其中,

$$\phi = (\sqrt{5} + 1) / 2 = 1.618$$

实际上,只需对以上Fib-AVL树的结构做进一步的调整,完全可以使得每个节点的重平衡都属于双旋形式,从而使得总体的旋转次数加倍至:

$$\lfloor h/2 \rfloor \cdot 2 \approx h$$

当然,从渐进的角度看,以上结论并未有实质的改进。

请读者参照以上思路,独立给出具体的调整方法。

尽管以上方法仅适用于规模为 $n = \text{fib}(h+3) - 1$ 的AVL树,但其原理及方法并不难推广至一般性的 n 。

[7-18] D. E. Knuth^[3]曾指出, `AVL::remove()`操作尽管在最坏情况下需做 $\Omega(\log n)$ 次旋转, 但平均而言仅需做 $\theta.21$ 次。试通过实验统计, 验证这一结论。

【解答】

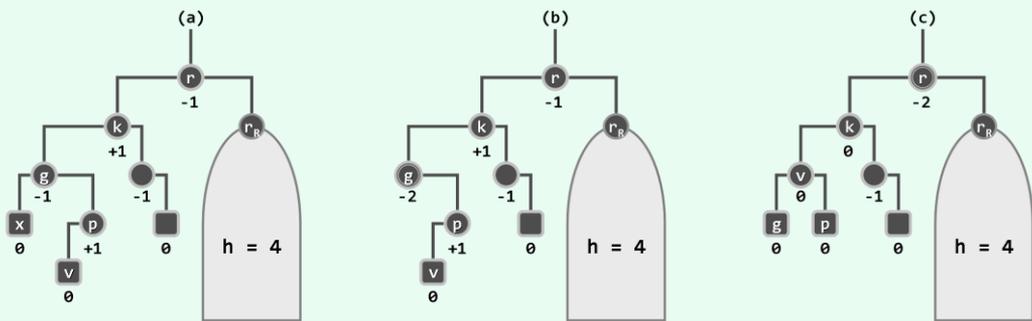
请读者独立完成测试和统计, 并结合实测结果给出结论及分析。

[7-19] 设在从AVL树中摘除一个节点之后, 刚刚通过调整使 $g(x)$ 重新恢复了平衡。此时, 若发现 $g(x)$ 原先的父节点依然平衡, 则是否可以不必继续检查其更高层的祖先, 并随即停止上溯? 也就是说, 此时在更高层是否依然可能有失衡的祖先? 若是, 请说明理由; 否则, 试举一反例。

【解答】

实际上, 此时若停止上溯, 则有可能会遗漏更高层的失衡祖先节点——AVL树节点删除操作的这一性质, 与节点插入操作完全不同。

考查如图x7.3(a)所示的实例, 只需注意逐一核对各节点的平衡因子, 不难验证这的确是一棵AVL树, 且高度为5。其中, 左子树高度为3, 右子树高度为4, 但鉴于其具体结构组成无所谓, 故未予详细绘出。



图x7.3 从AVL-树中删除节点之后, 需要重平衡的祖先未必相邻

现在, 若从中删除节点 x , 则首先按照二叉搜索树的算法, 将其直接摘除。此时应如图(b)所示, 全树唯一的失衡节点只有 g 。于是接下来按照AVL-树的重平衡算法, 经双旋调整即可恢复这一局部的平衡。

此时, 考查 g 原先的父节点 k 。如图(c)所示, 尽管节点 k 的平衡因子由 $+1$ 降至 0 , 却依然不失平衡。然而, 自底而上的调整过程不能就此终止。我们注意到, 此时节点 k 的高度已由3降至2, 于是对于更高层的祖先节点 r 而言, 平衡因子由 -1 进一步降至 -2 , 从而导致失衡。

由上可见, 仅仅通过平衡性, 并不足以确定可否及时终止自底而上的重平衡过程。然而, 并非没有办法实现这种优化。实际上, 只要转而通过核对重平衡后节点的高度, 即可及时判定是否可以立即终止上溯过程。请读者按照这一提示和思路, 独立给出改进的方法。

由此反观AVL-树的插入操作, 之所以能够在首次重平衡之后随即终止上溯, 原因在于此时不仅局部子树的平衡性能够恢复, 而且局部子树的高度亦必然同时恢复。

[7-20] 试证明, 按递增次序将 $2^{h+1} - 1$ 个关键字插入初始为空的 AVL 树中, 必然得到高度为 h 的满树。

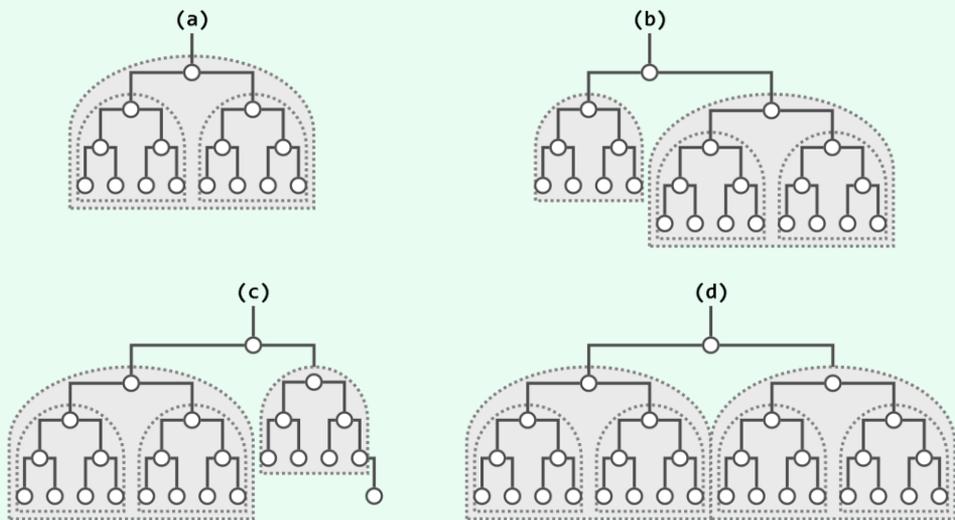
【解答】

首先, 考察AVL的右侧分支。对照AVL树的重平衡算法不难发现, 在这样的插入过程中, 该分支上沿途上各节点 v 始终满足以下不变性:

- 1) v 的左子树必为满树;
- 2) $\text{height}(\text{rc}(v)) - 1 \leq \text{height}(\text{lc}(v)) \leq \text{height}(\text{rc}(v))$

实际上, 在这一系列的插入操作过程中出现的每一次失衡, 都可以通过zag单旋予以修复。如教材196页图7.15(a)所示, 若 T_0 、 T_1 和 T_2 都是满树, 则旋转之后应如图(b)所示, 节点 g 与 T_0 和 T_1 必然也构成一棵(增高一层的)满树。

为更加细致地展示这一演变过程并证明以上结论, 以下不妨对树高做数学归纳。作为归纳基, 以上命题自然对高度为 θ (单节点)的AVL树成立。假设以上命题对高度不超过 h 的AVL树均成立, 现考查高度为 $h + 1$ 的情况。



图x7.4 将31个关键字按单调次序插入, 必然得到一棵高度为4的满树

如图x7.4所示, 我们不妨将关键字 $[0, 2^{h+2} - 1)$ 的插入过程, 分为四个阶段:

a) 首先插入关键字 $[0, 2^{h+1} - 1)$

由归纳假设, 应得到一棵高度为 h 的满树。

以 $h = 3$ 为例, 在将关键字 $[0, 15)$ 依次插入初始为空的AVL树后, 应如图(a)所示, 得到一棵高度为3、规模为15的满树。

b) 继续插入关键字 $[2^{h+1} - 1, 3 \cdot 2^h - 1)$

这一阶段的插入对树根的左子树没有影响, 其效果等同于将这些关键字单调地插入右子树。因此亦由归纳假设, 右子树必然成为一棵高度为 h 的满树。

继续以上实例。在接下来依次插入关键字 $[15, 22)$ 之后, 该AVL树应如图(b)所示, 根节点的左子树与右子树分别是一棵高度为2和3的满树。

c) 再插入关键码[$3 \cdot 2^h - 1$]

如此,必将引起树根节点的失衡,并在以根为轴做zag单旋之后恢复平衡。此后,根节点的左子树是高度为 h 的满树;右子树高度亦为 h ,但最底层只有一个关键码——新插入的[$3 \cdot 2^h - 1$]。

仍然继续上例。在接下来再插入关键码[23]之后,该AVL树应如图(c)所示,根节点的左子树是一棵高度为3的满树;右子树高度亦为3,但最底层仅有一个关键码[23]。

d) 最后,插入关键码[$3 \cdot 2^h, 2^{h+2} - 1$]

同样地,这些关键码的插入并不影响树根的左子树,其效果等同于将这些关键码单调地插入右子树。故由归纳假设,右子树必然成为一棵高度为 h 的满树。至此,整体得到一棵高度为 $h + 1$ 的满树。

仍然继续上例。在接下来再插入关键码[24, 32]之后,该AVL树应如图(d)所示,根节点的左子树和右子树都是高度为3的满树,整体构成一棵高度为4的满树。

第8章

高級搜索树

[8-1] 试扩充 Splay 模板类 (教材 208 页代码 8.1), 使之支持多个相等数据项的并存。

为此, 需要增加 searchAll(e) 和 removeAll(e) 接口, 以查找或删除等于指定目标 e 的所有节点。同时, 原先的 search(e) 和 remove(e) 接口, 将转而负责查找或删除等于指定目标 e 的任一节点。

【解答】

原理及方法, 均与习题[7-10] (149页) 和习题[7-16] (152页) 完全相同。

请读者独立完成编码和调试任务。

[8-2] 试证明, 伸展树所有基本操作接口的分摊时间复杂度, 均为 $O(\log n)$ 。

【解答】

关于伸展树可在任意情况下均保持良好的操作效率, 教材208页图8.7的实例还不足以作为严格的证明。事实上, 伸展树单次操作所需的时间量 T 起伏极大, 并不能始终保证控制在 $O(\log n)$ 以内。故需沿用教材2.4.4节的方法, 从分摊的角度做一分析和评判。具体地, 可将实际可能连续发生的一系列操作视作一个整体过程, 将总体所需计算时间分摊至其间的每一操作, 如此即可得到其单次操作的分摊复杂度 A , 并依此评判伸展树的整体性能。

当然, 就具体的某次操作而言, 实际执行时间 T 与分摊执行时间 A 往往并不一致, 如何弥合二者之间的差异呢?

实际上, 分摊分析法在教材中已经而且将会多次出现, 比如此前第2.4.4节的可扩充向量、第5.4节的各种迭代式遍历算法以及后面第11.3.7节的KMP串匹配算法等。相对而言, 伸展树的性能分析更为复杂, 以下将采用势能分析法 (potential analysis)。

仿照物理学的思想和概念, 这里可假想式地认为, 每棵伸展树 S 都具有一定量 (非负) 的势能 (potential), 记作 $\Phi(S)$ 。于是, 若经过某一操作并相应地通过旋转完成伸展之后 S 演化为另一伸展树 S' , 则对应的势能变化为:

$$\Delta\Phi = \Phi(S') - \Phi(S)$$

推而广之, 考查对某伸展树 S_0 连续实施 $m \gg n$ 次操作的过程。将第 i 次操作后的伸展树记作 S_i , 则有:

$$\Delta\Phi_i = \Phi(S_i) - \Phi(S_{i-1}), \quad 1 \leq i \leq m$$

而从该过程的整体来看, 应有

$$\Delta\Phi = \sum_{i=1}^m [\Phi(S_i) - \Phi(S_{i-1})] = \Phi(S_m) - \Phi(S_0)$$

也就是说, 整体的势能变化量仅取决于最初和最终状态——这与物理学中势能场的规律吻合。势能函数与物理学中势能的另一相似之处在于, 它也可以被看作是能量 (计算成本) 的一种存在形式。比如, 当某一步计算实际所需的时间小于分摊复杂度时, 则可理解为通过势能的增加

将提前支出的计算成本存储起来；反之，在前者大于后者时，则可从此前积累的势能中支取相应量用于支付超出的计算成本。

以下，若将第*i*次操作的分摊复杂度取作实际复杂度与势能变化量之和，即

$$A_i = T_i + \Delta\Phi_i$$

则有

$$\sum_{i=1}^m A_i = \sum_{i=1}^m T_i + [\Phi(S_m) - \Phi(S_0)]$$

如此，总体的实际运行时间 $\sum_{i=1}^m T_i$ ，将不会超过总体的分摊运行时间 $\sum_{i=1}^m A_i$ ，故后者可以视作前者的一个上界。

比如，R. E. Tarjan^[42]使用如下势能函数：

$$\Phi(S) = \sum_{v \in S} \log |v|, \quad \text{其中 } |v| = \text{节点 } v \text{ 的后代数目}$$

证明了伸展树单次操作的分摊时间复杂度为 $\mathcal{O}(\log n)$ 。为此，以下将分三种情况（其余情况不过是它们的对称形式）证明：

在对节点*v*的伸展过程中，每一步调整所需时间均不超过*v*的势能变化的3倍，即：
 $3 \cdot [\Phi'(v) - \Phi(v)]$

情况A) zig

如教材第8.1.3节所述，这种情况在伸展树的每次操作中至多发生一次，而且只能是伸展调整过程的最后一步。作为单旋，这一步调整实际所需时间为 $T = \mathcal{O}(1)$ 。同时由教材207页图8.5，这步调整过程中只有节点*v*和*p*的势能有所变化，且*v* (*p*) 后代增加（减少）势能必上升（下降），故对应的分摊复杂度为：

$$A = T + \Delta\Phi = 1 + \Delta\Phi(p) + \Delta\Phi(v) \leq 1 + [\Phi'(v) - \Phi(v)]$$

情况B) zig-zag

作为双旋的组合，这一调整实际所需时间为 $T = \mathcal{O}(2)$ 。于是由教材206页图8.4可知：

$$\begin{aligned} A &= T + \Delta\Phi \\ &= 2 + \Delta\Phi(v) + \Delta\Phi(p) + \Delta\Phi(g) \\ &= 2 + \Phi'(g) - \Phi(g) + \Phi'(p) - \Phi(p) + \Phi'(v) - \Phi(v) \\ &= 2 + \Phi'(g) + \Phi'(p) - \Phi(p) - \Phi(v) \dots\dots\dots (\because \Phi'(v) = \Phi(g)) \\ &\leq 2 + \Phi'(g) + \Phi'(p) - 2 \cdot \Phi(v) \dots\dots\dots (\because \Phi(v) < \Phi(p)) \\ &\leq 2 + 2 \cdot \Phi'(v) - 2 - 2 \cdot \Phi(v) \dots (\because \Phi'(g) + \Phi'(p) \leq 2 \cdot \Phi'(v) - 2) \\ &= 2 \cdot [\Phi'(v) - \Phi(v)] \end{aligned}$$

这里的最后一步放大，需利用对数函数 $f(x) = \log_2 x$ 的性质，即该函数属于凹函数（concave function），因此必有：

$$\frac{\log_2 a + \log_2 b}{2} \leq \log_2 \frac{a+b}{2}$$

亦即:

$$\log_2 a + \log_2 b \leq 2 \cdot \log_2 \frac{a+b}{2} = 2 \cdot [\log_2(a+b) - 1] < 2 \cdot (\log_2 c - 1)$$

情况C) zig-zig

作为双旋的组合,这一调整实际所需时间也为 $T = \mathcal{O}(2)$ 。于是由教材206页图8.3可知

$$\begin{aligned} A &= T + \Delta\Phi \\ &= 2 + \Delta\Phi(v) + \Delta\Phi(p) + \Delta\Phi(g) \\ &= 2 + \Phi'(g) - \Phi(g) + \Phi'(p) - \Phi(p) + \Phi'(v) - \Phi(v) \\ &= 2 + \Phi'(g) + \Phi'(p) - \Phi(p) - \Phi(v) \dots \dots \dots (\because \Phi'(v) = \Phi(g)) \\ &\leq 2 + \Phi'(g) + \Phi'(p) - 2 \cdot \Phi(v) \dots \dots \dots (\because \Phi(v) < \Phi(p)) \\ &\leq 2 + \Phi'(g) + \Phi'(v) - 2 \cdot \Phi(v) \dots \dots \dots (\because \Phi'(p) < \Phi'(v)) \\ &\leq 3 \cdot [\Phi'(v) - \Phi(v)] \dots \dots \dots (\because \Phi'(g) + \Phi(v) \leq 2 \cdot \Phi'(v) - 2) \end{aligned}$$

同样地,其中最后一步放大也需利用对数函数的凹性。

综合以上各种情况可知,无论具体过程如何,伸展操作的每一步至多需要 $3 \cdot [\Phi'(v) - \Phi(v)]$ 时间。因此,若在对伸展树的某次操作中,节点 v 经过一连串这样的调整上升成为根节点 r ,则趟伸展操作总体所需的分摊时间为:

$$\begin{aligned} A &\leq 1 + 3 \cdot [\Phi(r) - \Phi(v)] \leq 1 + 3 \cdot \Phi(r) \\ &= \mathcal{O}(1 + \log n) = \mathcal{O}(\log n) \end{aligned}$$

[8-3] 试扩充 RedBlack 模板类 (教材 230 页代码 8.13), 使之支持多个相等数据项的并存。

为此,需要增加 searchAll(e)和 removeAll(e)接口,以查找或删除等于指定目标 e 的所有节点。

同时,原先的 search(e)和 remove(e)接口,将转而负责查找或删除等于指定目标 e 的任一节点。

【解答】

原理及方法,均与习题[7-10](149页)和习题[7-16](152页)完全相同。

请读者独立完成编码和调试任务。

[8-4] 试对于任何指定的 m 和 N, 构造一棵存有 N 个关键码的 m 阶 B 树, 使得在其中插入某个特定关键码之后, 需要进行 $\Omega(\log_m N)$ 次分裂。

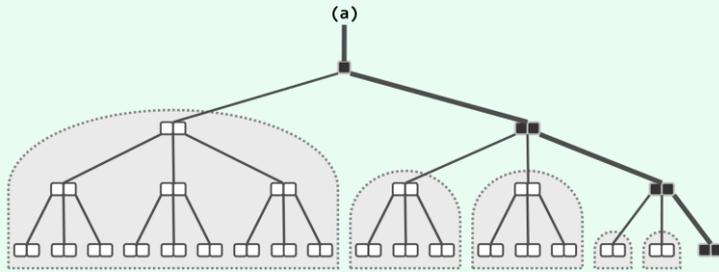
【解答】

不妨设 m 为奇数(偶数的情况方法类似,请读者独立补充)。

首先,考查由尽可能少的关键码组成的高度为 h 的 m 阶B-树。

例如,如图x8.1所示即是一棵高度 $h = 4$ 的 $m = 5$ 阶B-树,其使用的关键码总数为:

$$2 \cdot \lceil m/2 \rceil^{h-1} - 1 = 53$$



图x8.1 高度 $h = 4$ 、由53个节点组成的一棵5阶B-树

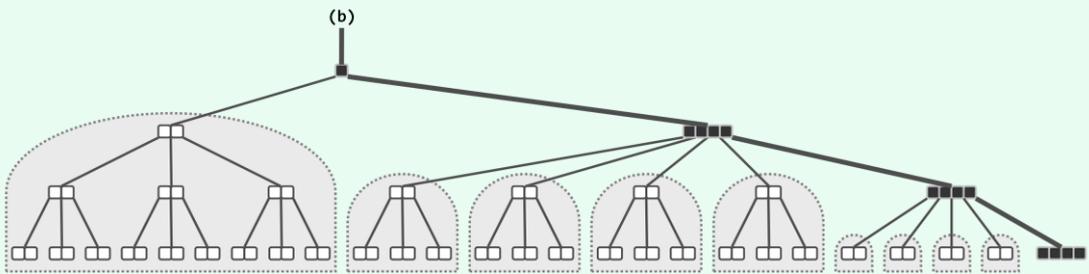
考查该树的最右侧通路。因该通路在图中以粗线条和黑色方格示意，故不妨将沿途的关键码称作黑关键码，其余称作白关键码。于是，如阴影虚框所示，可以将整棵树分割为一系列的子树。

进一步地，如此划分出来的子树，可与最右侧通路上的关键码建立起一一对应的关系：每棵子树的直接后继都是一个黑关键码——亦即不小于该子树的最小关键码。当然特别地，最右侧通路末端节点中的关键码可视为空树的直接后继。

不妨设此树所存的关键码为：

$$\{ 1, 2, \dots, n \}$$

以下，若从 $n + 1$ 起，按递增次序继续插入关键码，则只能沿最右侧通路发生分裂。而且，在根节点保持只有单个关键码的前提下，全树的高度必然保持不变。考查如此所能得到的规模最大的B-树，除根节点外，其最右侧通路上各节点都应含有 $m - 1$ 个关键码（处于饱和状态）。这样的一个实例，如图x8.2所示。



图x8.2 高度 $h = 4$ 、由79个节点组成的一棵5阶B-树

若将黑、白关键码所属的节点，亦分别称作黑节点、白节点，则此时它们应分别处于上溢和下溢的临界状态。接下来若再插入一个关键码，而且大于目前已有的所有关键码，则必然会沿着最右侧通路（持续）发生 $h - 1$ 次分裂。

为统计该树的规模，依然如图中阴影虚框所示，沿着最右侧通路将所有节点分组。进一步地，如此划分出来的子树，同样与最右侧通路上的黑关键码一一对应。

以下，我们将每棵子树与对应的黑关键码归为一组。如此划分之后，考查其中高度为 k 的任一子树所属的分组，不难发现其规模应为：

$$\lceil m/2 \rceil^k$$

因此，全树的总规模应为：

$$\hat{N} = \lceil m/2 \rceil^{h-1} + (m - 1) \cdot [\lceil m/2 \rceil^{h-2} + \lceil m/2 \rceil^{h-3} + \dots + \lceil m/2 \rceil^0]$$

$$= [\lceil m/2 \rceil^{h-1} \cdot (m + \lceil m/2 \rceil - 2) - m + 1] / (\lceil m/2 \rceil - 1) \dots \dots \dots (*)$$

反之，便有：

$$h = 1 + \log_{\lceil m/2 \rceil} [((\lceil m/2 \rceil - 1) \cdot \hat{N} + m - 1) / (m + \lceil m/2 \rceil - 2)]$$

$$= \Theta(\log_{\lceil m/2 \rceil} \hat{N}) = \Theta(\log_m \hat{N})$$

因此，对于任意指定的规模N，若令：

$$h = 1 + \lfloor \log_{\lceil m/2 \rceil} [((\lceil m/2 \rceil - 1) \cdot N + m - 1) / (m + \lceil m/2 \rceil - 2)] \rfloor$$

并按(*)式估算出 $\hat{N} \leq N$ ，则可按上述方法构造一棵高度为h、规模为 \hat{N} 的m阶B-树，且接下来只要再插入一个全局最大关键码，就会沿最右侧通路发生 $h - 1 = \Omega(\log_m \hat{N})$ 次分裂。而其余 $N - \hat{N}$ 个关键码，可在不影响最右侧通路的前提下，作为白关键码适当地插入并散布到各棵子树当中。

[8-5] 现拟将一组共 n 个互异的关键码，插入至一棵初始为空的 m 阶 B-树中，设 $m \ll n$ 。

a) 按照何种次序插入这批关键码，可使所得到的 B-树高度最大？

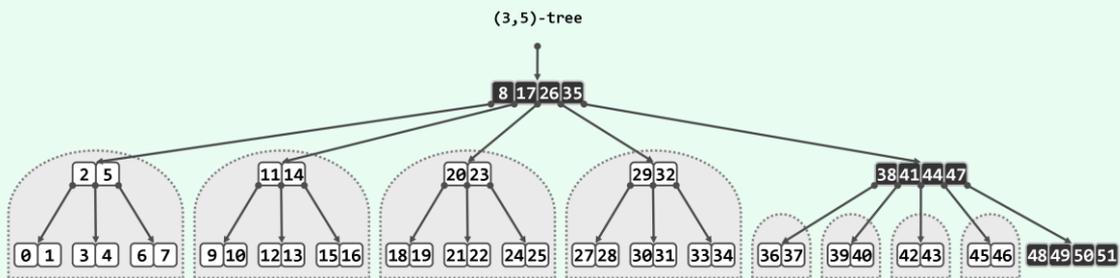
【解答】

保证B-树达到最大高度的一种简明方法，就是按单调次序插入所有关键码。

不妨设m为奇数（偶数的情况方法类似，请读者补充）。比如，按单调递增次序将：

{ 0, 1, 2, ..., 51 }

插入初始为空的5阶B-树，所生成B-树的结构应如图x8.3所示。



图x8.3 按递增插入[0, 52)而生成的5阶B-树

一般地，不难验证：在按递增次序插入各关键码的过程中，最右侧通路（沿途节点在图中以黑色示意）以下的所有子树（以虚框包围的各组白色节点），始终都属于“稀疏临界”状态。在处于这种状态的子树中，任一节点的删除，都将引起持续的合并操作，并导致高度的下降。

因此,若阶次为 m ,则此类子树中的每个节点均有 $\lceil m/2 \rceil$ 分支;若其高度为 h ,则其下所含的外部节点总数应为 $\lceil m/2 \rceil^h$,内部节点总数应为 $\lceil m/2 \rceil^h - 1$ 。在上例中 $m = 5$,于是高度为 $h = 1$ 的(4棵)此类子树必然包含3个外部节点和2个内部节点,高度为 $h = 2$ 的(4棵)此类子树必然包含9个外部节点和8个内部节点。

实际上若采用单调递增的次序,则每次插入的关键码在当前都属最大。因此,插入算法必然沿着最右侧通路做查找并确定其插入位置;而一旦出现上溢现象,也只能沿最右侧通路实施分裂操作。如此,尽管最右侧通路下属的子树可能会增加,但它们始终保持稀疏临界状态。

一般地,仿照教材8.2.4节的分析方法可知:如此插入 $[0, n)$ 而生成的 m 阶B-树,高度应为:

$$h = h_{\max} = \log_{\lceil m/2 \rceil} \lfloor (n + 1)/2 \rfloor + 1$$

仍以上述B-树为例, $m = 5$, $n = 52$,故树高应为:

$$h = \log_{\lceil 5/2 \rceil} \lfloor (52 + 1)/2 \rfloor + 1 = 3$$

若继续插入下一关键码52,则在持续分裂3次之后,树高将增至:

$$h = \log_{\lceil 5/2 \rceil} \lfloor (53 + 1)/2 \rfloor + 1 = 4$$

依然是此时所能达到的最大树高。

b) 按照何种次序插入这批关键码,可使所得到的B-树高度最小?

【解答】

请读者参照a)中思路,独立给出解答。

[8-6] 考查任意阶的B-树T。

a) 若T的初始高度为1,而在经过连续的若干次插入操作之后,高度增加至 h 且共有 n 个内部节点,则在此过程中T总共分裂过多少次?

【解答】

考查因新关键码的插入而引起的任何一次分裂操作。

被分裂的节点,无非两种类型。若它不是根节点,则树中的节点增加一个,同时树高保持不变,故有:

$$n += 1 \quad \text{和} \quad h += 0$$

否则若是根节点,则除了原节点一分为二,还会新生出一个(仅含单关键码的)树根,同时树的高度也将相应地增加一层,故有:

$$n += 2 \quad \text{和} \quad h += 1$$

可见,无论如何, n 与 h 的差值均会恰好地增加一个单位——因此, $n - h$ 可以视作为分裂操作的一个计数器。该计数器的初始值为 $1 - 1 = 0$,故最终的 $n - h$ 即是从初始状态之最后,整个过程中所做分裂操作的总次数。

请注意,以上结论与各关键码的数值大小以及具体的插入过程均无关,仅取决于B-树最初和最终的状态——高度和内部节点数。

b) 在如上过程中, 每一关键码的插入, 平均引发了多少次分裂操作?

【解答】

由上可见, 累计发生的分裂操作次数, 不仅取决于连续插入操作的次数, 同时也取决于最终的树高。前者亦即树中最终所含关键码的总数 N , 后者即是 h 。

若关键码总数固定为 N , 则为使节点尽可能地多, 内部节点各自所含的关键码应尽可能地少。注意到根节点至少包含1个关键码, 其余内部节点至少包含 $\lceil m/2 \rceil - 1$ 个关键码, 故必有:

$$n \leq 1 + (N - 1) / (\lceil m/2 \rceil - 1)$$

因此, 在如上连续的 N 次插入操作中, 分裂操作的平均次数必然不超过:

$$(n - h) / N < n / N < 1 / (\lceil m/2 \rceil - 1)$$

可见, 平均而言, 大致每经过 $\lceil m/2 \rceil - 1$ 次插入, 才会发生一次分裂。

根据习题[8-4]的结论, 某一关键码的插入, 在最坏情况下可能引发多达 $\Omega(\log_m N)$ 次的分裂。对照本题的结论可知, 这类最坏情况发生的概率实际上极低。

c) 若 T 的初始高度为 h 且含有 n 个内部节点, 而在经过连续的若干次删除操作之后高度下降至1, 则在此过程中 T 总共合并过多少次?

【解答】

与a)同理, 若合并后的节点不是树根, 则有

$$n -- 1 \quad \text{和} \quad h -- 0$$

否则若是根节点, 则有:

$$n -- 2 \quad \text{和} \quad h -- 1$$

可见, 无论如何, n 与 h 的差值 $n - h$ 均会恰好地减少一个单位。既然最终有:

$$n = h = 1 \quad \text{或等价地} \quad n - h = 0$$

故其间所发生合并操作的次数, 应恰好等于 $n - h$ 的初值。

同样请注意, 以上结论与各关键码的数值大小以及具体的删除过程均无关, 仅取决于 B -树最初和最终的状态——高度和内部节点数。

d) 设 T 的初始高度为1, 而且在随后经过若干次插入和删除操作——次序任意, 且可能彼此相间。

试证明: 若在此期间总共做过 S 次分裂和 M 次合并, 且最终共有 n 个内部节点, 高度为 h , 则必有:

$$S - M = n - h$$

【解答】

综合a)和c)的结论可知: 在 B -树的整个生命期内, $n - h$ 始终忠实反映了分裂操作次数与合并操作次数之差。

需要特别说明的是, 以上前三问只讨论了连续插入和连续删除的情况, 其结论并不适用于本问的情况——两种操作可以任意次序执行。下题将要考查的, 即是其中的极端情况。

[8-7] 设 $m \geq 3$ 为奇数。试对任意的 $h > 0$ ，构造一棵高度为 h 的 m 节 B-树，使得若反复地对该树交替地执行插入、删除操作，则每次插入或删除操作都会引发 h 次分裂或合并。

【解答】

若从一棵空的 m 节 B-树开始，按单调顺序依次插入以下关键字：

$$\{ 1, 2, 3, 4, 5, \dots, N \}, \quad \text{其中, } N = 2 \cdot \left[\left(\frac{m+1}{2} \right)^h - 1 \right]$$

则易见，树高恰好为 h ，而且最右侧通路上的节点均有 m 个分支，其余节点各有 $(m+1)/2$ 个分支。

于是，接下来若继续插入关键字 $N+1$ ，则会沿最右侧通路发生 h 次分裂，全树增高一层；接下来若再删除关键字 $N+1$ ，则会沿着最右侧通路发生 h 次合并，全树降低一层。

更重要的是，如此经过一轮插入和删除，该树宏观的结构以及各节点的组成，都将完全复原。这就意味着，若反复地如此交替地插入和删除，则每一次操作都会在该树中引发 h 处结构性改变。

当然，此类最坏情况在实际应用中出现的概率同样极低，平均而言，B-树节点分裂与合并的次数依然极少。

[8-8] 对比本章所介绍的 B-树插入与删除算法后不难发现，二者并不完全对称。

比如，删除关键字时若发生下溢，则可能采用旋转（通过父亲间接地向兄弟借得一个关键字）或者合并两种手段进行修复；然而，插入关键字时若发生上溢，却只是统一通过分裂进行修复。

实际上从理论上讲，也可优先通过旋转来修复上溢：

只要某个兄弟仍处于非饱和状态，即可通过父亲，间接地向该兄弟借得一个关键字

a) 仿照代码 8.12（教材 226 页），在代码 8.10（教材 221 页）的基础上做扩充，按上述思路优先通过旋转来修复上溢；

【解答】

这种修复上溢的方法，原理与教材的图 8.17（223 页）或图 8.18（223 页）相同，过程恰好相反。请读者根据以上介绍和提示，独立完成编码和调试任务。

b) 在实际应用中，为何不倾向于采用这种手段，而是更多地直接通过分裂来修复上溢？

【解答】

表面上看，B-树的插入操作与删除操作方向相反、过程互逆，但二者并非简单的对称关系。在删除操作的过程中若当前节点发生下溢，未必能够通过合并予以修复——除非其兄弟节点亦处于下溢的临界状态。而在插入操作的过程中若当前节点发生上溢，则无论其兄弟节点的状态和规模如何，总是可以立即对其实施分裂操作。

实际上就算法的控制逻辑而言，优先进行分裂更为简明。而根据习题[8-6]的分析结论，在 B-树的生命期内，分裂操作通常都不致过于频繁地发生。因此，不妨直接采用优先进行分裂的策略来修复上溢节点。

另外，优先进行分裂也不致于导致空间利用率的显著下降。实际上无论分裂多少次，无论分裂出多少个节点，根据 B-树的定义，其空间利用率最差也不致低于 50%。

最后，优先分裂策略也不致于导致树高——决定 I/O 负担以及访问效率的主要因素——的明显增加。实际上根据教材 8.2.4 节的分析结论，B-树的高度主要取决于所存关键字的总数，而与其中节点的数目几乎没有关系。

[8-9] 极端情况下，B-树中根以外所有节点只有 $\lceil m/2 \rceil$ 个分支，空间使用率大致仅有50%。而若按照教材8.2节介绍的方法，简单地将上溢节点一分为二，则有较大的概率会出现或接近这种极端情况。

为提高空间利用率，可将内部节点的分支数下限从 $\lceil m/2 \rceil$ 提高至 $\lceil 2m/3 \rceil$ 。于是，一旦节点 v 发生上溢且无法通过旋转完成修复，即可将 v 与其（已经饱和的某一）兄弟合并，再将合并节点等分为三个节点。采用这一策略之后，即得到了B-树的一个变种，称作 B^* -树（ B^* -tree）^{[39][40]}。

当然，实际上不必真地先合二为一，再一分为三。可通过更为快捷的方式，达到同样的效果：从来自原先两个节点及其父节点的共计 $m + (m - 1) + 1 = 2m$ 个关键码中，取出两个上交给父节点，其余 $2m - 2$ 个则尽可能均衡地分摊给三个新节点。

a) 按照上述思路，实现 B^* -树的关键码插入算法；

【解答】

如题中所述，若对空间利用率和树的高度十分在意，也不妨采用优先旋转的策略：一旦发生上溢，首先尝试从上溢节点将部分关键码转移至（尚未饱和的）兄弟节点。

请读者参照以上介绍和提示，独立完成编码和调试任务。

b) 与B-树相比， B^* -树的关键码删除算法又有何不同？

【解答】

与插入过程对称地，从节点 v 中删除关键码后若发生下溢，且其左、右兄弟均无法借出关键码，则先将 v 与左、右兄弟合并，再将合并节点等分为两个节点。同样地，实际上不必真地先合三为一，再一分为二。可通过更为快捷的方式，达到同样的效果：从来自原先三个节点及其父节点的共计：

$$(\lceil m/2 \rceil - 1) + 1 + (\lceil m/2 \rceil - 2) + 1 + (\lceil m/2 \rceil - 1) = 3 \cdot \lceil m/2 \rceil - 2$$

个关键码中，取一个上交给父节点，其余 $3 \cdot \lceil m/2 \rceil - 3$ 个则尽可能均衡地分摊给两个新节点。

注意，以上所建议的方法，不再是每次仅转移单个关键码，而是一次性地转移多个——等效于上溢或下溢节点与其兄弟分摊所有的关键码。采用这一策略，可以充分地利用实际应用中普遍存在的高度数据局部性，大大减少读出或写入节点的I/O操作。

不难看出，单关键码的转移尽管也可以修复上溢或下溢的节点，但经如此修复之后的节点将依然处于上溢或下溢的临界状态。接下来一旦继续插入或删除近似甚至重复的关键码（在局部性较强的场合，这种情况往往会反复出现），该节点必将再次发生上溢或下溢。由此可见，就修复效果而言，多关键码的成批转移，相对单关键码的转移更为彻底——尽管还不是一劳永逸。

针对数据局部性的另一改进策略，是使用所谓的页面缓冲池（buffer pool of pages）。这是在内存中设置的一个缓冲区，用以保存近期所使用过节点（页面）的副本。

只要拟访问的节点仍在其中（同样地，在局部性较强的场合，这种情况也往往会反复出现），即可省略I/O操作并直接访问；否则，才照常规方法处理，通过I/O操作从外存取出对应的节点（页面）。缓冲池的规模确定后，一旦需要读入新的节点，只需将其中最不常用的节点删除即可腾出空间。

实际上，不大的页面缓冲池即可极大地提高效率。请读者通过实验统计，独立作出验证。

c) 按照你的构想, 实现 B*-树的关键码删除算法。

【解答】

请读者参照以上介绍和提示, 独立完成编码和调试任务。

[8-10] Java 语言所提供的 `java.util.TreeMap` 类是用红黑树实现的。

试阅读相关的 Java 源代码, 并就其实现方式与本章的 C++ 实现做一比较。

【解答】

请读者对照教材中实现的红黑树, 独立完成代码阅读和比较任务。

[8-11] H. Olivie 于 1982 年提出的半平衡二叉搜索树 (half-balanced binary search trees)^[47],

非常类似于红黑树。这里所谓的半平衡 (half-balanced), 是指此树的什么性质?

试阅读参考文献, 并给出你的理解。

【解答】

按照定义, 在半平衡二叉搜索树中, 每个节点 v 都应满足以下条件: v 到其最后代 (叶) 节点的距离, 不得超过到其最浅后代叶节点距离的两倍。

若半平衡二叉搜索树所含内部节点的总数记作 n , 高度记作 h , 则可以证明必有:

$$h \leq 2 \cdot \log_2(n + 2) - 2$$

请读者在阅读相关文献之后, 独立给出自己的理解。

[8-12] 人类所拥有的数字化数据的总量, 在 2010 年已经达到 2^B ($2^{70} = 10^{21}$) 量级。

假定其中每个字节自成一个关键码, 若用一棵 $m = 256$ 阶的 B-树来存放它们, 则

a) 该树的最大高度是多少?

【解答】

首先需要指出的是, 鉴于目前常规的字节仅含 8 个比特位, 可能的关键码只有 $2^8 = 256$ 种, 故数据集中必然含有大量重复, 因此若果真需要使用 B-树来存放该数据集, 可参照习题 [7-10] (149 页) 和习题 [7-16] (152 页) 的方法和技巧, 扩展 B-树结构的功能, 使之支持重复关键码。

根据教材 8.2.4 节的分析结论, 存放 $N < 10^{21}$ 个关键码的 $m = 256$ 阶 B-树, 高度不会超过

$$\begin{aligned} \log_{\lceil m/2 \rceil} \lfloor (N + 1)/2 \rfloor + 1 &= \log_{128} \lfloor (1 + 10^{21})/2 \rfloor + 1 \\ &\sim \log_2 10^{21} / \log_2 128 + 1 \sim 70 / 7 + 1 = 11 \end{aligned}$$

b) 最小呢?

【解答】

同样根据教材 8.2.4 节的分析结论, 该 B-树的高度不会低于

$$\log_m(N + 1) = \log_{256}(10^{21} + 1) \sim \log_2 10^{21} / \log_2 256 \sim \lceil 70 / 8 \rceil = 9$$

实际应用中, 多采用 128~256 阶的 B-树。综合以上分析结论, 可以明确地看到, 此类 B-树的高度并不大, 而且起伏变化的范围也不大。这也是在多层次存储系统中, 该结构可以成功用以处理大规模数据的原因。

[8-13] 考查含有 2012 个内部节点的红黑树。

a) 该树可能的最小黑高度 d_{\min} 是多少？

【解答】

将红黑树中内部节点的总数记作 N ，将其黑高度记作 d 。

若考查与之相对应的4阶B-树，则该B-树中存放的关键码恰有 N 个，且其高度亦为 d 。于是，再次根据教材8.2.4节的分析结论，最小黑高度应为：

$$d_{\min} = \lceil \log_4(N + 1) \rceil = \lceil \log_4 2013 \rceil = 6$$

b) 该树可能的最大黑高度 d_{\max} 是多少？

【解答】

与上同理，最大黑高度应为：

$$\begin{aligned} d_{\max} &= 1 + \lfloor \log_{4/2} \lfloor (N + 1) / 2 \rfloor \rfloor \\ &= 1 + \lfloor \log_2 \lfloor 2013 / 2 \rfloor \rfloor = 1 + \lfloor \log_2 1006 \rfloor = 10 \end{aligned}$$

c) 该树可能的最小高度 h_{\min} 是多少？

【解答】

根据习题[7-3]，从常规二叉搜索树的角度看，树高不低于：

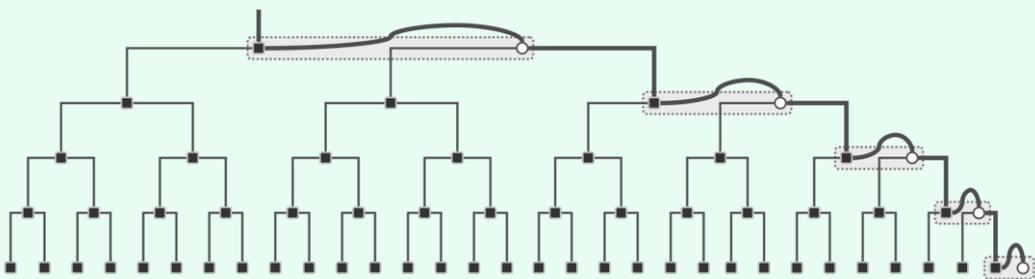
$$h_{\min} = \lfloor \log_2 N \rfloor = \lfloor \log_2 2012 \rfloor = 10$$

当然，还需具体地构造出这样的一棵红黑树——这项任务请读者独立完成。

d) 该树可能的最大高度 h_{\max} 是多少？

【解答】

我们来考查与原问题等价的逆问题：若高度固定为 h ，红黑树中至少包含多少个节点。不妨仍然考查与红黑树的对应的4阶B-树。



图x8.4 高度（计入扩充的外部节点）为10的红黑树，至少包含62个节点

先考查 h 为偶数的情况。如图x8.4所示，该B-树的高度应为 $h/2$ ；其中几乎所有节点均只含单关键码；只有 $h/2$ 个节点包含两个关键码（分别对应于原红黑树中的一个红、黑节点），它们在每一高度上各有一个，且依次互为父子，整体构成一条路径（这里不妨以最右侧通路为例）。于是，该B-树所含关键码（亦即原红黑树节点）的总数为：

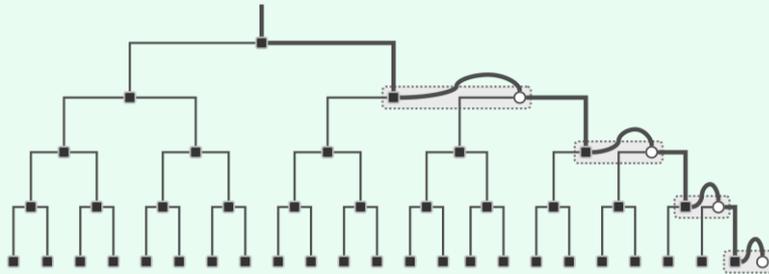
$$N_{\min} = 2 \times (1 + 2 + 4 + 8 + 16 + \dots + 2^{h/2 - 1}) = 2^{h/2 + 1} - 2$$

例如，如图x8.4所示的红黑树高度为10，对应B-树高度为5，所含关键码（节点）总数为：

$$N_{\min} = 2^{10/2 + 1} - 2 = 2^{5 + 1} - 2 = 62$$

因此反过来，当节点总数固定为N时，最大高度不过

$$h_{\max} = 2 \cdot (\lfloor \log_2(N + 2) \rfloor - 1) \dots \dots \dots (1)$$



图x8.5 高度（计入扩充的外部节点）为9的红黑树，至少包含46个节点

再考查h为奇数的情况。如图x8.5所示，该B-树的高度应为 $(h + 1)/2$ ；其中几乎所有节点均只含单关键码；只有 $(h - 1)/2$ 个节点包含两个关键码（分别对应于原红黑树中的一个红、黑节点），除了根节点，它们在每一高度上各有一个，且依次互为父子，整体构成一条路径（同样地，以最右侧通路为例）。于是，该B-树所含关键码（亦即原红黑树节点）的总数为：

$$\begin{aligned} N_{\min} &= 2 \times (1 + 2 + 4 + 8 + 16 + \dots + 2^{(h-1)/2 - 1}) + 2^{(h+1)/2 - 1} \\ &= 3 \cdot 2^{(h-1)/2} - 2 \end{aligned}$$

例如，如图x8.5所示的红黑树高度为9，对应B-树高度为5，所含关键码（节点）总数为：

$$N_{\min} = 3 \cdot 2^{(9-1)/2} - 2 = 3 \cdot 2^4 - 2 = 46$$

因此反过来，当节点总数固定为N时，最大高度不过

$$h_{\max} = 2 \cdot \lfloor \log_2(\frac{N + 2}{3}) \rfloor + 1 \dots \dots \dots (2)$$

综合(1)和(2)两式可知，在 $N = 2012$ 是，应有：

$$\begin{aligned} h_{\max} &= \max(2 \cdot (\lfloor \log_2(2012 + 2) \rfloor - 1), 2 \cdot \lfloor \log_2(\frac{N + 2}{3}) \rfloor + 1) \\ &= \max(18, 19) \\ &= 19 \end{aligned}$$

读者不妨按照以上分析，示意性地绘出该红黑树（及其对应B-树）的结构。

[8-14] 就最坏情况而言，红黑树在其重平衡过程中可能需要对多达 $\Omega(\log n)$ 个节点做重染色。然而，这并不足以代表红黑树在一般情况下的性能。

试证明，就分摊意义而言，红黑树重平衡过程中需重染色的节点不超过 $o(1)$ 个。

【解答】

不妨从初始为空开始，考查对红黑树的一系列插入和删除操作，将操作总数记作 $m \gg 2$ 。可以证明：存在常数 $c > 0$ ，使得在此过程中所做的重染色操作不超过 cm 次。

为此，可以使用习题[8-2]的方法，定义势能函数如下：

$$\Phi(S) = 2 \cdot \text{BRR}(S) + \text{BBB}(S)$$

其中, $\text{BRR}(S)$ 为当前状态 S 下, 拥有两个红孩子的黑节点总数; $\text{BBB}(S)$ 则为当前状态 S 下, 拥有两个黑孩子的黑节点总数。

不难验证, 以上势能函数始终非负, 且初始值为零。

为得出题中所述结论, 只需进一步验证: 每做一次重染色, 无论属于何种情况, 该势能函数都会至少减少1个单位; 另外, 每经过一次插入或删除操作, 该势能函数至多会增加常数 c 个单位。请读者对照教材第8.3.3节和第8.3.4节中所列的各种情况, 独立完成对以上性质的验证。

[8-15] 试证明, 若中位点能够在线性时间内确定, 则 kd-树构造算法 `buildKdTree()` (242 页算法 8.1) 的总体执行时间可改进至 $\mathcal{O}(n \log n)$, 其中 $n = |P|$ 为输入点集的规模。

【解答】

如此, 在该分治式算法中, 每个问题 (kd-树的构造) 都能在线性时间内均衡地划分为两个子问题 (子树的构造); 而且子问题的解 (子树) 都能在常数时间内合并为原问题的解 (kd-树)。于是, 其时间复杂度 $T(n)$ 所对应的递推式为:

$$T(n) = 2 \cdot T(n/2) + \mathcal{O}(n)$$

解之即得:

$$T(n) = \mathcal{O}(n \log n)$$

[8-16] 关于 kd-树查找算法 `kdSearch()` (教材 244 页算法 8.2), 试证明以下结论:

a) 在树中某一节点发生递归, 当且仅当与该节点对应的子区域, 与查询区域的边界相交;

【解答】

按照该算法的控制逻辑, 只要当前子区域与查询区域 R 的边界相交时, 即会发生递归; 反之, 无论当前子区域是完全处于 R 之外 (当前递归实例直接返回), 还是完全处于 R 之内 (直接遍历当前子树并枚举其中所有的点), 都不会发生递归。

b) 若令 $Q(n)$ = 规模为 n 的子树中与查询区域边界相交的子区域 (节点) 总数, 则有:

$$Q(n) = 2 + 2Q(n/4) = \mathcal{O}(\sqrt{n})$$

【解答】

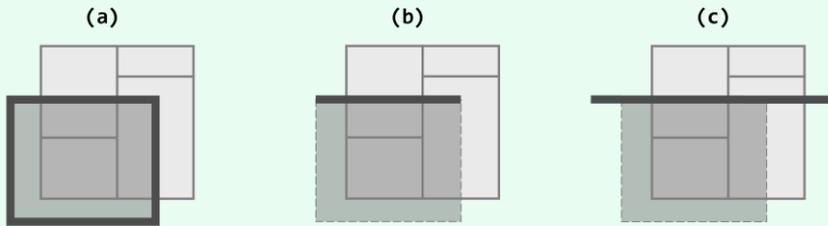
设 R 为任一查询区域。

根据其所对应子区域与 R 边界的相交情况, kd-树中的所有节点可以划分以下几类:

- (0) 与 R 的边界不相交
- (1) 只与 R 的一条边相交
- (2) 同时与 R 的多条边相交

根据 a), 其中第 (0) 类节点对 $Q(n)$ 没有贡献。

如图 x8.6(a) 所示, 第 (1) 类节点又可以细分为四种, 分别对应于 R 的上、下、左、右四边。既然是估计渐进复杂度, 不妨只考虑其中一种——比如, 如图 (b) 所示, 只考查水平的上边。



图x8.6 统计与查询区域边界相交的子区域（节点）总数

根据定义，kd-树自顶而下地每经过k层，切分的维度方向即循环一轮。因此，不妨考查与R边界相交的任一节点，以及自该节点起向下的k代子孙节点。对于2d-树而言，也就是考查与R边界相交的任一节点，以及它的2个子辈节点（各自大致包含n/2个点）和4个孙辈节点（各自大致包含n/4个点）。

为简化分析，我们不妨如图(c)所示，进一步地将R的上边延长为其所在的整条直线。于是，不难发现，无论这4个孙辈节点（子区域）的相对位置和大小如何，该直线至多与其中的2个相交；反过来，至少有两个节点（子区域）不再发生递归。于是，即可得到如下递推关系：

$$Q(n) \leq 2 + 2 \cdot Q(n/4) \dots\dots\dots (*)$$

再结合边界条件：

$$Q(1) = 1$$

解之即得：

$$Q(n) = o(\sqrt{n})$$

请注意，以上并未统计第(2)类节点（子区域），但好在这类节点只占少数，就渐进的意义而言，并不影响总体的上界。

比如在图x8.6(a)中，包含R四个角点的那些节点（子区域）即属此列。以其中包含R左上角者为例，这类节点在kd-树的每一层至多一个，故其总数不超过树高 $o(\log n)$ 。相对于第一类节点的 $o(\sqrt{n})$ ，完全可以忽略。

当然，第(2)类节点（子区域）还有其它可能的情况，比如同时包含R的多个角点。但不难说明，其总数依然不超过 $o(\log n)$ 。

c) kdSearch()的运行时间为：

$$o(r + \sqrt{n})$$

其中 r 为实际命中并被报告的点数。

【解答】

从递归的角度看，若忽略对reportSubtree()的调用，kd-树范围查询算法的每一递归实例本身均仅需 $o(1)$ 时间。故由以上b)所得结论，查询共需 $o(\sqrt{n})$ 时间。

reportSubtree(v)是通过遍历子树v，在线性时间内枚举其中的命中点。整个算法对该例程所有调用的累计时间，应线性正比于输出规模r。

两项合计，即得题中所述结论。

d) 进一步地, 试举例说明, 单次查询中的确可能有多达 $\Omega(\sqrt{n})$ 个节点发生递归, 故以上估计是紧的。

【解答】

为确切地达到这一紧界, 以上b) 中所得递推式(*)必须始终取等号; 反之, 只有该递推式始终取等号, 则必然可以实现紧界。请读者按照这一思路, 独立给出具体实例。

需要指出的是, 由此结论也可看出, c) 中所做的简化与放大, 在渐进意义上都是紧的。

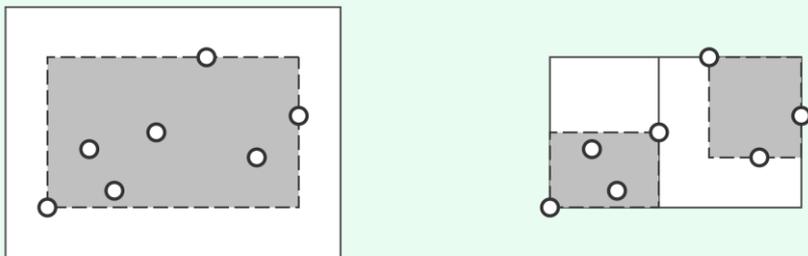
e) 若矩形区域不保证与坐标轴平行, 甚至不是矩形(比如圆), 则上述结论是否依然成立?

【解答】

依然成立。具体的分析方法及过程, 可以参见[46]。

[8-17] 不难理解, kd-树中节点 v 所对应的矩形区域即便与查询范围 R 相交, 其中所含的输入点也不见得会落在 R 之内。比如在极端的情况下, v 中可能包含大量的输入点, 但却没有一个落在 R 之内。当然, $\text{kdSearch}()$ (教材 244 页算法 8.2) 在这类情况下所做的递归, 都是不必进行的。

克服这一缺陷的一种简明方法, 如图 x8.7 所示: 在依然保持各边平行于坐标轴, 同时所包含输入点子集不变的前提下, 尽可能地收缩各矩形区域。其效果等同于, 将原矩形替换为依然覆盖其中所有输入点的最小矩形——即所谓的包围盒 (bounding-box)。其实, 在如教材图 8.41 所示的实例中, 正因为采用了这一技巧, 才得以在节点 $\{F, H\}$ 处, 有效地避免了一次无意义的递归。



图x8.7 每次切分之后, 都随即将子区域 (实线) 替换为包围盒 (虚线), 以加速此后的查找

试按照以上构思, 在教材 242 页算法 8.1 的基础上, 改进 kd-树的构造算法。

【解答】

请读者参照以上介绍和提示, 独立完成编码和调试任务。

[8-18] 若仅需报告落在指定范围内点的数目, 而不必给出它们的具体信息, 则借助 kd-树需要多少时间?

【解答】

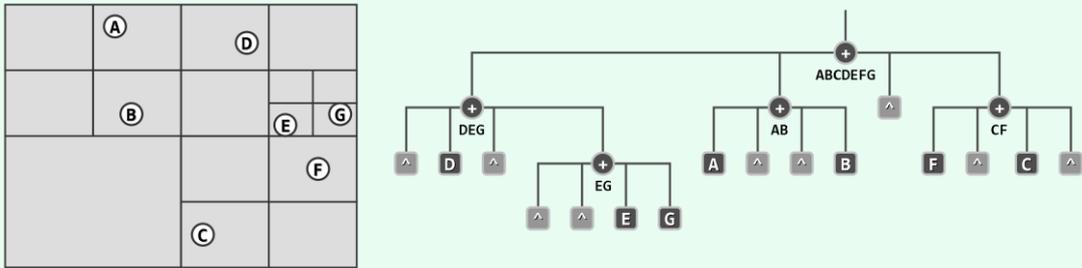
只需 $\mathcal{O}(\sqrt{n})$ 时间。

既然无需具体地枚举所命中的点, 故可令kd-树的每一节点分别记录其对应子树中所存放的点数。这样, 对于经查找而被筛选出来的每一棵子树, 都可以直接累计其对应的点数, 而不必对其进行遍历。如此, 原先消耗于遍历枚举的 $\mathcal{O}(r)$ 时间即可节省; 同时, 对各子树所含点数的累加, 耗时不超过被筛选出来的子集 (子树) 总数——亦即 $\mathcal{O}(\sqrt{n})$ 。

[8-19] 四叉树^[51] (quadtree) 是 2d-树的简化形式, 其简化策略包括:

- ① 直接沿区域的 (水平或垂直) 平分线切分, 从而省略了中位点的计算
- ② 沿垂直方向切出的每一对节点 (各自再沿水平方向切分) 都经合并后归入其父节点
- ③ 被合并的节点即便原先 (因所含输入点不足两个) 而未继续切分, 在此也需要强行 (沿水平方向) 切分一次

于是如图 x8.8 所示, 每个叶节点各含 0 至 1 个输入点; 每个内部节点则都统一地拥有四个孩子, 分别对应于父节点所对应矩形区域经平均划分之后所得的四个象限, 该树也由此得名。

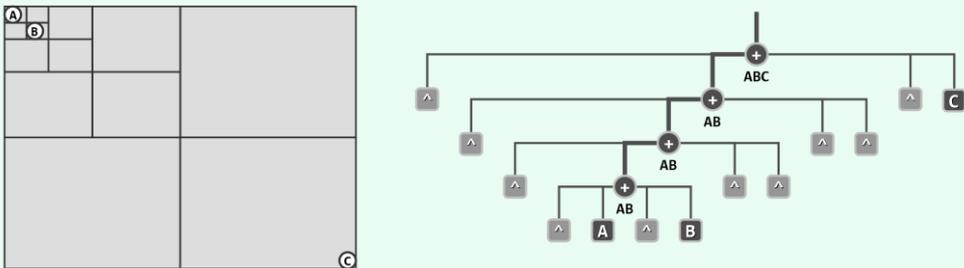


图x8.8 通过递归地将平面子区域均分为四个象限 (左), 构造对应的四叉树 (右)

a) 与 kd-树不同, 四叉树可能包含大量的空 (即不含任何输入点的) 节点。更糟糕的是, 此类节点的数目无法仅由输入规模 n 界定。对于任意的 $N > 0$, 试构造一个仅含 $n = 3$ 个点的输入点集, 使得在其对应的四叉树中, 空节点的数目超过 N 个。

【解答】

这样的实例, 如图x8.9所示。实际上, 以此为基础, 可以导出一系列的此类实例。



图x8.9 四叉树的空间利用率可能极低

这里只有A、B和C三个点, 但A和B之间的距离非常接近, 以至于必须持续划分4次, 它们才不再属于同一子区域。在如此构造出来的四叉树中, 每一层都有1个内部节点和3个叶节点; 而除了最高的两层和最低的一层, 其余各层的3个叶节点都对应于空的子区域。

限于篇幅, 这里所给实例的深度仅为4。实际上仿照此例的构思, 不难扩展并得出层数更多的例子, 其中存放的依然只有三个点, 但其空间利用率却可以无限地接近于0。为此, 只需不断地令点A和点B相互靠近。当然, 最为极端的情况也就是这两个点彼此重合。

作为对照, 读者不妨绘出同样存放这三个点的kd-树, 并体会二者在空间效率方面的差异, 以及导致这种差异的根本原因。

为消除这一缺陷，可以仿照kd-树，将点集的划分策略由“按空间平分”改为“按点数平分”。尽管如此需要额外地记录各节点所对应的划分位置，但却可以严格地保证划分的均衡性，从而有效地提高整体的空间效率。

b) 对于任一输入点集 P ，若将其中所有点对的最长、最小距离分别记作 D 和 d ，则 $\lambda = D/d$ 称作 P 的散布度 (spread)。试证明， P 所对应的二叉树高度为 $O(\log \lambda)$ 。

【解答】

与kd-树一样，二叉树中的每个节点也唯一地对应于某个矩形子区域；同一深度上各节点所对应的子区域面积相等（或渐进地同阶），彼此无交，且它们的并覆盖整个空间。

其中，根节点对应的子区域，边长为 D ；其下4个子节点所对应的子区域，边长为 $D/2$ ；再下一层的16个孙辈节点所对应的子区域，边长为 $D/4$ ；...；最底层（叶）节点所对应的子区域，边长为 d （或者更严格地， $d/2$ ）。

由此可见，整个二叉树的高度不超过 $O(\log \lambda)$ 。

由此反观以上a)中实例，导致其中空节点过多的直接原因，也可以认为在于 d 相对于 D 过小，以致于散布度 λ 以及树高过大。

c) 按照以上描述，试用 C/C++语言实现二叉树结构。

【解答】

请读者参照以上介绍和提示，独立完成编码和调试任务。

d) 试基于二叉树结构设计相应的范围查询算法，并利用你的二叉树结构实现该算法。

【解答】

与基于kd-树的查询算法基本相同。

从递归的角度来看，对于任一节点（子区域）的查询任务，都可以分解为对4个子节点（细分子区域）的查询子任务。其中，有些子任务需要继续递归（子区域与查询区域的边界相交），有些子任务则可立即以失败返回（子区域完全落在查询区域以外），有些子任务则可立即以成功返回（子区域完全落在查询区域以内）。

请读者参照以上介绍和提示，独立完成编码和调试任务。

e) 针对范围查询这一应用, 试分别从时间、空间效率的角度, 将四叉树与 2d-树做一比较。

【解答】

以上d) 所给算法的原理与过程, 尽管与采用kd-树的算法基本相同, 但却有着本质的区别, 从而导致其时间、空间性能均远不如kd-树。主要的原因, 具体体现在以下方面。

首先由a) 可见, 四叉树中存在大量的空节点(子区域), 因此在查找过程中即便能够确定某一节点(子区域)完全落在查询区域内部, 也不能在线性时间内枚举出其中有效的各点。整体而言, 不可能在 $\mathcal{O}(r)$ 时间内枚举出所有的命中点——而且, 通常情况会远远超过 $\mathcal{O}(r)$ 。

另外由b) 可见, (若不做改进) 四叉树的高度取决于点集的散布度 λ , 而不是点集的规模。因此树高没有明确的上限, 递归深度及查找长度也难以有效控制。在各点分布极其不均匀的场合, 树高往往会远远超过kd-树的 $\mathcal{O}(\log n)$ 。

以下对其平均情况做一估计。

不妨假定所有点均取自单位正方形 $[0, 1] \times [0, 1]$, 对应的四叉树高度为 h 。查询矩形区域 R 的长度和宽度分别为 x 和 y 。

在深度为 k 的任一层($0 \leq k \leq h$), 共有 4^k 个节点, 分别对应于 4^k 个互不相交的子正方形(有些不含任何点), 面积统一为 4^{-k} 。故节点总数为:

$$N = \sum_{k=0}^h 4^k = (4^{h+1} - 1) / 3 \sim 4^{h+1} / 3$$

在深度为 k 的一层, 与查询区域 R 相交(并因此需要耗费时间)的节点总数大致为:

$$(x \cdot 2^k + 1) \cdot (y \cdot 2^k + 1) = xy \cdot 4^k + (x + y) \cdot 2^k + 1$$

故所有各层与 R 相交者的总数大致为:

$$\begin{aligned} & \sum_{k=0}^h [xy \cdot 4^k + (x + y) \cdot 2^k + 1] \\ & \sim xy \cdot 4^{h+1} / 3 + (x + y) \cdot 2^{h+1} + (h + 1) \\ & = xy \cdot N + (x + y) \cdot \sqrt{3N} + \log_4(3N) \\ & = \mathcal{O}(xy \cdot N) \end{aligned}$$

主要取决于查询区域 R 的面积 xy , 以及四叉树的划分粒度 N (如上分析, 取决于散布度 λ)。

f) 试将上述思路推广至三维的情况, 以三层为间隔对 3d-树的节点做类似的合并, 从而实现所谓的八叉树(octree)结构。

【解答】

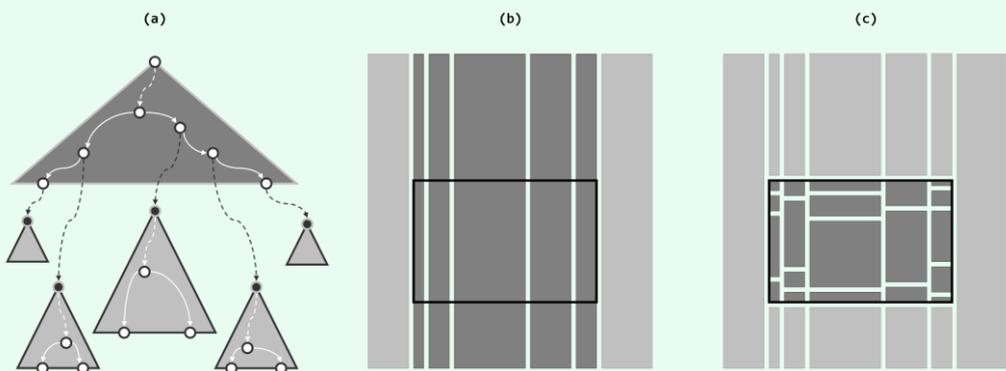
基本原理、方法与技巧, 与四叉树完全一致。

请读者参照以上介绍和提示, 独立完成编码和调试任务。

[8-20] 范围查询的另一解法需要借助范围树 (range tree)^[48]。

为此, 首先仿照如图 8.37 (教材 240 页) 和图 8.38 (教材 241 页) 所示的策略, 按 x 坐标将平面上所有输入点组织为一棵平衡二叉搜索树, 称为主树 (main tree)。

于是如图 x8.10(a)和(b)所示, 该树中每个节点各自对应于一个竖直的条带区域; 左、右孩子所对应的条带互不重叠, 均由父节点所对应的条带垂直平分而得; 同一深度上所有节点所对应的条带也互不重叠, 而且它们合并后恰好覆盖整个平面。



图x8.10 利用范围树, 可以实现更加高效的范围查询

接下来, 分别对于主树中每一节点, 将落在其所对应条带区域中的输入点视作一个输入子集, 并同样采用以上方法, 按照 y 坐标将各个子集组织为一棵平衡二叉搜索树, 它们称作关联树 (associative tree)^①。于是如图 x8.10(a)和(c)所示, 每棵关联树所对应的竖直条带, 都会进而逐层细分为多个矩形区域, 且这些矩形区域也同样具有以上所列主树中各节点所对应条带区域的性质。至此, 主树与这 $O(n)$ 棵关联树构成了一个两层的嵌套结构, 即所谓的范围树。

利用范围树, 可按如下思路实现高效的范围查询。对于任一查询范围 $R = [x_1, x_2] \times [y_1, y_2]$, 首先按照 $[x_1, x_2]$ 对主树做一次 x 方向的范围查询。根据 8.4.1 节的分析结论, 如此可以得到 $O(\log n)$ 个节点, 而且如图 x8.10(b)所示, 它们所对应的竖直条带互不重叠, 它们合并后恰好覆盖了 x 坐标落在 $[x_1, x_2]$ 范围内的所有输入点。

接下来, 深入这些节点各自对应的关联树, 分别按照 $[y_1, y_2]$ 做一次 y 方向的范围查询。如此从每棵关联树中取出的一系列节点, 也具有与以上取自主树的节点的类似性质。具体地如图 x8.10(c)所示, 这些节点所对应的矩形区域互不重叠, 且它们合并之后恰好覆盖了当前竖直条带内 y 坐标落在 $[y_1, y_2]$ 范围内的所有输入点。换言之, 这些点合并之后将给出落在 R 中的所有点, 既无重也不漏。

a) 按照以上描述, 试用 C/C++ 语言实现二维的范围树结构;

【解答】

请读者参照以上介绍和提示, 独立完成编码和调试任务。

^① 关联树的引入, 只是为了便于将此结构推广至更高维度; 就此特定的二维情况而言, 完全可以代之以简单的有序向量

b) 试证明, 如此实现的范围树, 空间复杂度为 $\mathcal{O}(n \log n)$;

【解答】

显然, 主树自身仅需 $\mathcal{O}(n)$ 空间。

这里的关联树共计有 n 棵, 表面上看, 每一棵的规模都可能达到 $\Omega(n)$ 。然而以下将证明, 总体空间 $\mathcal{O}(n^2)$ 的上界远远不紧, 更紧的上界应为 $\mathcal{O}(n \log n)$ 。

以上之所以得出 $\mathcal{O}(n^2)$ 这一不紧的上界, 是因为我们采用的统计方法是:

对每一棵关联树, 统计有多少个点可能出现在其中

为得出更紧的上界, 我们不妨颠倒思路, 采用如下统计方法:

对于每一个点, 统计它可能出现在多少棵关联树中

稍作观察即不难发现, 任一点 p 出现在某一关联树中, 当且仅当在主树中, 该关联树对应的节点是 p 所对应叶节点的祖先。而在平衡二叉搜索树中, 每个节点的祖先均不超过 $\mathcal{O}(\log n)$ 个。

c) 按照以上描述, 试利用你的范围树实现新的范围查询算法 ;

【解答】

与 kd -树的查询算法类似。

首先沿 x 方向做一次 (一维的) 范围查找, 并在主树中挑选出不超过 $\mathcal{O}(\log n)$ 个节点。

然后, 对于其中的每个节点, 在与之对应的关联树中, 沿 y 方向各做一次 (一维的) 范围查找。关联树中每一棵命中的子树, 都可通过遍历在线性时间内枚举其中节点。

d) 试证明, 以上范围查询算法的时间复杂度为 $\mathcal{O}(r + \log^2 n)$, 其中 r 为实际命中并被报告的点数 ;

【解答】

按照如上算法, 可知如下性质:

- 1) 对主树的查找耗时 $\mathcal{O}(\log n)$
- 2) 对 $\mathcal{O}(\log n)$ 棵关联树的查找分别耗时 $\mathcal{O}(\log n)$, 累计耗时 $\mathcal{O}(\log^2 n)$

再计入遍历枚举所需的 $\mathcal{O}(r)$ 时间, 即得题中待证的结论。

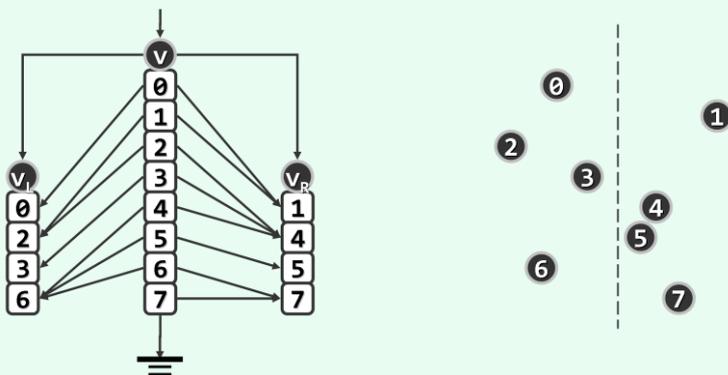
e) 继续改进^⑨以上范围树，在不增加空间复杂度的前提下，将查询时间减至 $O(r + \log n)^{[49][50]}$ 。
 (提示：尽管每次查询均涉及 $O(\log n)$ 次 y 坐标的范围查询，但其查找区间都同为 $[y_1, y_2]$)

【解答】

正如以上提示所指出的：

在每一次范围查询中，在所涉及关联树的查找之间，具有极强的相关性——它们的入口参数同为 $[y_1, y_2]$

因此可如图x8.11所示，借助分散层叠 (fractional cascading) 的技巧加以改进。为此，需要在主树中每一对父子节点所对应的关联树之间，增加一系列的索引。



图x8.11 通过分散层叠，进一步提高范围树的查找性能

具体地如图x8.11所示，设主树中的节点 v_L 和 v_R 是 v 的左、右孩子；它们各自对应的关联树，则简化地表示为有序向量（等效于关联树的中序遍历序列）。于是，在 v 关联树中查找结果，可以直接为其孩子节点的关联树直接利用，相应地查找成本由 $O(\log n)$ 降至 $O(1)$ 。当然，对于最低公共祖先节点所对应的关联树，还是需要做一次 $O(\log n)$ 的查找。

综上所述，改进之后的范围树可在：

$$O(\log n + \log n) = O(\log n)$$

时间完成查找，并在：

$$O(r)$$

时间内报告查询结果。

^⑨ 严格地说，只有在经过如此改进之后方可称作范围树，否则只是一般的多层搜索树 (multi-level search tree)

第9章

词典

第10章

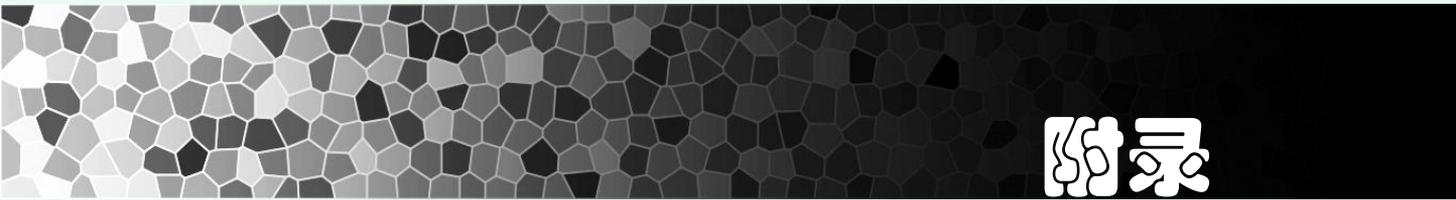
优先级队列

第11章

串

第12章

排序



附录

参考文献

- [1] D. E. Knuth. The Art of Computer Programming, Volume 1: Fundamental Algorithms (3rd edn.). Addison-Wesley (1997), ISBN:0-201-89683-1
- [2] D. E. Knuth. The Art of Computer Programming, Volume 2: Seminumerical Algorithms (3rd edn.). Addison-Wesley (1997), ISBN:0-201-89684-8
- [3] D. E. Knuth. The Art of Computer Programming, Volume 3: Sorting and Searching (2nd edn.). Addison-Wesley (1998), ISBN:0-201-89685-0
- [4] A. V. Aho, J. E. Hopcroft, J. D. Ullman. The Design and Analysis of Computer Algorithms (1st edn.). Addison-Wesley (1974), ISBN:0-201-00029-0
- [5] J. Bentley. Writing Efficient Programs. Prentice-Hall (1982), ISBN:0-139-70251-2
- [6] J. Bentley. More Programming Pearls: Confessions of a Coder. Addison Wesley (1988), ISBN:0-201-11889-0
- [7] R. L. Graham, D. E. Knuth, O. Patashnik. Concrete Mathematics: A Foundation for Computer Science (2nd edn.). Addison-Wesley (1994), ISBN:0-201-55802-5
- [8] 严蔚敏 等. 数据结构 (C语言版). 北京: 清华大学出版社, 1997年4月第1版, ISBN:7-302-02368-9
- [9] J. Bentley. Programming Pearls (2nd edn.). Addison-Wesley (2000), ISBN:0-201-65788-0
- [10] T. Budd. Classic Data Structures in Java. Addison-Wesley (2000), ISBN:0-201-70002-6
- [11] J. Hromkovic. Design And Analysis Of Randomized Algorithms: Introduction to Design Paradigms. Springer-Verlag (2005), ISBN:3-540-23949-9
- [12] H. Samet. Foundations of Multidimensional and Metric Data Structures. Morgan Kaufmann (2006), ISBN:0-123-69446-9
- [13] M. A. Weiss. Data Structures and Algorithm Analysis in C++ (3rd edn.). Addison Wesley (2006), ISBN:0-321-44146-1
- [14] E. Horowitz, S. Sahni, D. Mehta. Fundamentals of Data Structures in C++ (2nd edn.). Silicon Press (2006), ISBN:0-929-30637-6
- [15] A. Drozdek. Data Structures and Algorithms in C++ (2nd edn.). Thomson Press (2006), ISBN:8-131-50115-9
- [16] 殷人昆 等. 数据结构 (C++语言描述). 北京: 清华大学出版社, 2007年6月第2版, ISBN:7-302-14811-1
- [17] P. Brass. Advanced Data Structures. Cambridge University Press, ISBN:0-521-88037-8
- [18] J. Edmonds. How to Think about Algorithms. Cambridge University Press (2008), ISBN:0-521-61410-8
- [19] K. Mehlhorn & P. Sanders. Algorithms and Data Structures: The Basic Tools. Springer (2008), ISBN:3-540-77977-9
- [20] T. H. Cormen, C. E. Leiserson, R. L. Rivest, C. Stein. Introduction to Algorithms (3rd edn.). MIT Press (2009), ISBN:0-262-03384-4

- [21] R. Bird. *Pearls of Functional Algorithm Design*. Cambridge University Press (2010), ISBN:0-521-51338-8
- [22] M. L. Hetland. *Python Algorithms: Mastering Basic Algorithms in the Python Language*. Apress (2010), ISBN:1-430-23237-4
- [23] M. T. Goodrich, R. Tamassia, D. M. Mount. *Data Structures and Algorithms in C++ (2nd edn.)*. John Wiley & Sons (2011), ISBN:0-470-38327-5
- [24] R. Sedgewick & K. Wayne. *Algorithms (4th edn.)*. Addison-Wesley (2011), ISBN:0-321-57351-X
- [25] Y. Perl, A. Itai and H. Avni, Interpolation Search: A $\log(\log(n))$ Search, *Commun. ACM*, 21 (1978), pp. 550-553
- [26] A. C. Yao & F. F. Yao. The Complexity of Searching an Ordered Random Table. 17th Annual Symposium on Foundations of Computer Science (1976), 173-177
- [27] A. C. Yao & J. M. Steele. Lower Bounds to Algebraic Decision Trees. *Journal of Algorithms* (1982), 3:1-8
- [28] A. C. Yao. Lower Bounds for Algebraic Computation Trees with Integer Inputs. *SIAM J. On Computing* (1991), 20:655-668
- [29] L. Devroye. A Note on the Height of Binary Search Trees. *J. of ACM* (1986), 33(3):489-498
- [30] P. Flajolet & A. Odlyzko. The Average Height of Binary Trees and Other Simple Trees. *Journal of Computer and System Sciences* (1982), 25(2):171-213
- [31] J. B. Kruskal. On the Shortest Spanning Subtree of a Graph and the Traveling Salesman Problem. *Proc. of the American Mathematical Society*, 7(1):48-50
- [32] B. W. Arden, B. A. Galler, R. M. Graham. An Algorithm for Equivalence Declarations. *Communications ACM* (1961), 4:310-314
- [33] B. A. Galler, M. J. Fisher. An Improved Equivalence Algorithm. *Communications ACM* (1964), 7:301-303
- [34] R. E. Tarjan. Efficiency of a Good but not Linear Set Union Algorithm. *Journal of the ACM* (1975), 22:215-225
- [35] R. Seidel & M. Sharir. Top-Down Analysis of Path Compression. *SIAM Journal Computing* (2005), 34:515-525
- [36] G. Adelson-Velskii & E. M. Landis. An Algorithm for the Organization of Information. *Proc. of the USSR Academy of Sciences* (1962), 146:263-266
- [37] D. S. Hirschberg. An Insertion Technique for One-Sided Heightbalanced Trees. *Comm. ACM* (1976), 19(8):471-473
- [38] S. H. Zweben & M. A. McDonald. An Optimal Method for Deletion in One-Sided Height-Balanced Trees. *Commun. ACM* (1978), 21(6):441-445
- [39] K. Culik, T. Ottman, D. Wood. Dense Multiway Trees. *ACM Transactions on Database Systems* (1981), 6:486-512
- [40] E. Gudes & S. Tsur. Experiments with B-tree Reorganization. *SIGMOD* (1980), 200-206
- [41] D. D. Sleator & R. E. Tarjan. Self-Adjusting Binary Trees. *JACM* (1985), 32:652-686

- [42] R. E. Tarjan. Amortized Computational Complexity. *SIAM. J. on Algebraic and Discrete Methods* 6(2):306-318
- [43] R. Bayer & E. McCreight. Organization and Maintenance of Large Ordered Indexes. *Acta Informatica* (1972), 1(3):173-189
- [44] R. Bayer. Symmetric Binary B-Trees: Data Structure and Maintenance Algorithms. *Acta Informatica* (1972), 1(4):290-306
- [45] L. J. Guibas & R. Sedgwick. A Dichromatic Framework for Balanced Trees. *Proc. of the 19th Annual Symposium on Foundations of Computer Science* (1978), 8-21
- [46] J. L. Bentley. Multidimensional Binary Search Trees Used for Associative Searching. *Communications of the ACM* (1975), 18(9):509-517
- [47] H. J. Olivie. A New Class of Balanced Search Trees: Half Balanced Binary Search Trees. *ITA* (1982), 16(1):51-71
- [48] J. L. Bentley. Decomposable Searching Problems. *Information Processing Letters* (1979), 8:244-251
- [49] J. H. Hart. Optimal Two-Dimensional Range Queries Using Binary Range Lists. Technical Report 76-81, Department of Computer Science, University of Kentucky (1981)
- [50] D. E. Willard. New Data Structures for Orthogonal Range Queries. *SIAM Journal on Computing* (1985), 14:232-253
- [51] H. Samet, An Overview of Quadtrees, Octrees, and Related Hierarchical Data Structures, in R. Earnshaw, ed., *Theoretical Foundations of Computer Graphics and Cad*, Springer Berlin Heidelberg, 1988, pp. 51-68
- [52] W. Pugh. Skip Lists: a Probabilistic Alternative to Balanced Trees. *Lecture Notes in Computer Science* (1989), 382:437-449
- [53] R. de la Briandais. File Searching Using Variable Length Keys. *Proc. of the Western Joint Computer Conference 1959*, 295-298
- [54] E. H. Sussenguth. Use of Tree Structures for Processing Files. *Communications of the ACM* (1963), 6:272-279
- [55] D. R. Morrison. PATRICIA - Practical Algorithm to Retrieve Information Coded in Alphanumeric. *Journal of the ACM* (1968), 15:514-534
- [56] J. L. Bentley & R. Sedgwick. Fast Algorithms for Sorting and Searching Strings. *Proc. of 8th ACM-SIAM Symposium on Discrete Algorithms* (1997), 360-369
- [57] R. W. Floyd. Algorithm 113: Treesort. *Communications of the ACM* (1962), 5:434
- [58] C. A. Crane. Linear Lists and Priority Queues as Balanced Binary Trees. PhD thesis, Stanford University (1972)
- [59] E. M. McCreight. Priority Search Trees. *SIAM J. Comput.* (1985), 14(2):257-276
- [60] D. E. Knuth, J. H. Morris, V. R. Pratt. Fast Pattern Matching in Strings. *SIAM Journal of Computing* (1977), 6(2):323-350

-
- [61] R. S. Boyer & J. S. Moore. A Fast String Searching Algorithm. *Communications of the ACM* (1977), 20:762-772
 - [62] L. J. Guibas & A. M. Odlyzko. A New Proof of the Linearity of the Boyer-Moore String Search Algorithm. *SIAM Journal on Computing* (1980), 9(4):672-682
 - [63] R. Cole. Tight Bounds on the Complexity of the Boyer-Moore Pattern Matching Algorithm. *SIAM Journal on Computing* 23(5):1075-1091
 - [64] C. A. R. Hoare. Quicksort. *Computer Journal* (1962), 5(1):10-15
 - [65] D. L. Shell. A High-Speed Sorting Procedure. *Communications of the ACM* (1959), 2(7):30-32
 - [66] R. Sedgwick, A New Upper Bound for Shellsort, *J. Algorithms*, 7 (1986), pp. 159-173

插图索引

图x1.1 过直线外一点作其平行线	2
图x1.2 《海岛算经》算法原理	3
图x1.3 fib()算法中递归实例fib(k)的两种出现可能	13
图x1.4 使用85块L形积木,可以恰好覆盖缺失一角的16×16棋盘	18
图x1.5 采用分治策略,将大棋盘的覆盖问题转化为四个小棋盘的覆盖问题	18
图x1.6 借助reverse()算法在O(n)时间内就地移位的过程及原理	21
图x1.7 reverse()算法的递归跟踪	24
图x1.8 power2()算法的递归跟踪	24
图x1.9 二重循环执行时间的对应图形	25
图x1.10 联合递归函数F(n)和G(n)的递归跟踪图	31
图x2.1 permute()算法中第k + 1个就位元素,应等概率地随机选自当时的前n - k个元素	39
图x2.2 Brian W. Kernighan和Dennis M. Ritchie所设计随机数发生器的原理	39
图x2.3 无序向量删除算法remove(lo, hi)中,采用自后向前的次序移动可能造成数据丢失	41
图x2.4 从问题A到问题B的线性归约	43
图x2.5 输入规模为4时的归并排序过程	45
图x2.6 二分查找binSearch()算法版本A所对应的比较树,在向量规模递增后的结构变化	47
图x2.7 二分查找失败情况的递归分类	49
图x2.8 Fibonacci查找失败情况的递归分类	50
图x2.9 马鞍查找算法的原理及过程	51
图x2.10 B[]和C[]中的元素均未耗尽,且已转入A[]的元素总数 $i \leq lb$	59
图x2.11 B[]和C[]中的元素均未耗尽,且已转入A[]的元素总数 $i > lb$	59
图x2.12 B[]中的元素先于C[]耗尽	59
图x2.13 C[]中的元素先于B[]耗尽	59
图x2.14 通过引入两个等长的向量,在 $O(1)$ 时间内初始化Bitmap对象	64
图x2.15 Eratosthenes算法的实例	67
图x2.16 Eratosthenes算法:每次迭代中所筛除的整数,恰好就是重排矩形的最右侧一列	67
图x2.17 Eratosthenes算法的改进	67
图x2.18 4×5的矩阵实例:经逐列排序再逐行排序后,每行、每列均各自有序	70
图x2.19 只需考查沿纵向捉对有序中的任意两行	70
图x2.20 起泡排序的每一步,都是考查一对相邻元素	70
图x2.21 只需考查仅有一行进行交换的两种情况:(a) a和x交换;(b) b和y交换	71
图x2.22 假设逐行排序之后,沿纵向出现一对逆序元素a和b	71
图x4.1 迷宫算法低效的实例	99
图x5.1 n_h 个底层(叶)节点删除后,(次底层叶)节点至少增加 $\lceil n_h/2 \rceil$ 个	105
图x5.2 迭代式先序遍历实例(出栈节点以深色示意)	108

图x5.3 BinNode::succ()的情况一：t拥有右后代，其直接后继为右子树中左分支的末端节点s	110
图x5.4 BinNode::succ()的情况二：t没有右后代，其直接后继为以其为直接前驱的祖先s	110
图x5.5 二叉树中序遍历过程中对succ()接口的调用	111
图x5.6 频率最低的兄弟节点合并之后，最优编码树必对应于合并之前的最优编码树	117
图x5.7 字符串集{ "how", "many", "roads", "must", "a", "man", "walk", "down" }对应的键树	118
图x5.8 键树的紧凑表示与实现	118
图x6.1 (a)平面图、(b)三角剖分以及(c)外面亦为三角形的三角剖分	121
图x6.2 将5×5的对称矩阵压缩至长度为15的一维向量	122
图x6.3 图BFS搜索，等效于BFS树的层次遍历	124
图x6.4 构造有向图的欧拉环路：各子环路加粗示意，删除的边不再画出，删除的顶点以灰色示意	126
图x6.5 最小支撑树（粗线条）可能反复地穿越于割的两侧	130
图x6.6 借助最小支撑树，构造近似的旅行商环路	133
图x6.7 完全由极短跨越边构成的支撑树，未必是极小的	135
图x6.8 在各边权重未必互异时，Prim算法依然正确	136
图x6.9 Krusal算法的正确性	137
图x6.10 Krusal算法的最坏情况	138
图x6.11 并查集：初始状态	139
图x6.12 并查集：经union(D, F)和union(G, B)操作之后	139
图x6.13 并查集：经union(D, A)、union(F, H)和union(E, C)操作之后	139
图x6.14 并查集：经union(B, A)操作之后	140
图x6.15 并查集：经union(C, F)操作之后（树高未能有效控制）	140
图x6.16 并查集：经union(C, F)操作之后（“低者归入高者”以控制树高）	141
图x6.17 各边权重互异时，最短路径树依然可能不唯一	141
图x6.18 由平面点集依照欧氏距离隐式定义的若干典型的邻近图	142
图x7.1 AVL树中最浅的叶节点	150
图x7.2 Fib-AVL树	150
图x7.3 从AVL-树中删除节点之后，需要重平衡的祖先未必相邻	154
图x7.4 将31个关键字按单调次序插入，必然得到一棵高度为4的满树	155
图x8.1 高度h = 4、由53个节点组成的一棵5阶B-树	161
图x8.2 高度h = 4、由79个节点组成的一棵5阶B-树	161
图x8.3 按递增插入[0, 52)而生成的5阶B-树	162
图x8.4 高度（计入扩充的外部节点）为10的红黑树，至少包含62个节点	168
图x8.5 高度（计入扩充的外部节点）为9的红黑树，至少包含46个节点	169
图x8.6 统计与查询区域边界相交的子区域（节点）总数	171
图x8.7 每次切分之后，都即将子区域（实线）替换为包围盒（虚线），以加速此后的查找	172
图x8.8 通过递归地将平面子区域均分为四个象限（左），构造对应的二叉树（右）	173
图x8.9 二叉树的空间利用率可能极低	173
图x8.10 利用范围树，可以实现更加高效的范围查询	176

图x8.11 通过分散层叠, 进一步提高范围树的查找性能	178
图x9.1 表长与公差有非平凡公因子时, 会出现大量的冲突	182
图x9.2 双向平方试探法	186
图x9.3 将密钥码{ 2012, 10, 120, 175, 190, 230 }, 依次插入长度为11的散列表	188
图x9.4 删除密钥码2012, 并做懒惰删除标记	188
图x9.5 PATRICIA树 (PATRICIA tree)	194
图x9.6 三叉键树 (ternary trie)	194
图x10.1 字符权重已排序时, 可在线性时间内构造出Huffman编码树	200
图x10.2 三叉堆: (a)逻辑结构及(b)物理结构	202
图x10.3 优先级搜索树	204
图x10.4 基于优先级搜索树的半无穷范围查询算法	205
图x10.5 高效支持getMax()接口的栈	206
图x10.6 高效支持getMax()接口的队列	208
图x10.7 合并AVL树S和T: 不妨假定 $g \geq h$	208
图x10.8 合并AVL树S和T: 删除T中的最小节点m, 在S的最右侧通路上找到与树T'高度接近的节点u	209
图x10.9 合并AVL树S和T: 以m为结合点合并S'和T', 在整体接入至S	209
图x10.10 以任意键为界, 分裂AVL树 (这里只是示意性地绘出了各子树, 并未严格地反映其高度)	210
图x11.1 BM算法的最坏情况	216
图x12.1 轴点构造算法 (版本C)	220
图x12.2 在向量X和Y各自排序后, 对齐元素之间的次序依然保持	226
图x12.3 (a)排序前有 $Y[0, 3) \leq X[4, 7)$, (b)排序后仍有 $Y'[0, 3) \leq X'[4, 7)$	226
图x12.4 g-有序的向量A[]再经h-排序后, $A[i + g]$ 必然来自阴影区域	227
图x12.5 g-有序的向量A[]按照h列重排之后, $A[i]$ 所属列的前缀, 必然与 $A[i + g]$ 所属列的后缀, 逐个元素地对应有序	227

表格索引

表x1.1 函数 $F(n)$ 中变量 i 和 j 随迭代不断递增的过程	28
表x1.2 函数 $F(n)$ 中变量 i 和 r 随迭代不断递增的过程	28
表x3.1 列表{ 61, 60, 59, ..., 5, 4, 3, 2, 0, 1, 2 }的插入排序过程	80
表x4.1 表达式求值算法实例	94
表x4.2 (左) 括号数固定时, 运算符栈的最大规模	96
表x4.3 非法表达式“(12)3+!4*+5”的“求值”过程	96
表x9.1 n 个人中存在生日巧合的概率	183
表x9.2 对序列{ 5a, 2a, 3, 2b, 9a, 5b, 9b, 8, 2c }的直接计数排序	190
表x9.3 借助散列表对{ 5a, 2a, 3, 2b, 9a, 5b, 9b, 8, 2c }的计数排序(凡“-”项均与其上方项相等) .	192

算法索引

算法x1.1 过直线外一点作其平行线	2
算法x1.2 缺角棋盘的覆盖算法	18
算法x2.1 马鞍查找	51
算法x4.1 确认不含任何禁形的序列都是栈混洗	89
算法x6.1 基于“反复删除零入度节点”策略的拓扑排序算法	131
算法x9.1 整数向量的计数排序算法	191
算法x10.1 基于优先级搜索树的半无穷范围查询算法	205

代码索引

代码x1.1 《海岛算经》中计算海岛高度的算法	3
代码x1.2 《海岛算经》中计算海岛距离的算法	3
代码x1.3 包含循环、分支、子函数调用甚至递归结构，但具有常数时间复杂度的算法	6
代码x1.4 countOnes()算法的改进版	8
代码x1.5 countOnes()算法的再改进版	9
代码x1.6 power2BF_I()算法的递归版	10
代码x1.7 power2()算法的迭代版	10
代码x1.8 通用的迭代版幂函数算法	11
代码x1.9 数组最大值算法（迭代版）	11
代码x1.10 数组最大值算法（线性递归版）	11
代码x1.11 数组最大值算法（二分递归版）	12
代码x1.12 Fib类的实现	16
代码x1.13 Hanoi塔算法	17
代码x1.14 运用“中华更相减损术”的最大公约数算法	20
代码x1.15 借助reverse()算法在O(n)时间内就地移位	21
代码x1.16 计算Hailstone(n)序列长度的“算法”	23
代码x2.1 基于遍历实现向量的decrease()功能	44
代码x2.2 基于遍历实现向量的double()功能	45
代码x2.3 向量的起泡排序（改进版）	56
代码x2.4 单趟扫描交换（改进版）	56
代码x2.5 有序向量二路归并算法的简化	60
代码x2.6 增加注释后，Python的bisect模块中bisect_right接口的源代码	60
代码x2.7 位图Bitmap类	62
代码x2.8 可快速初始化的Bitmap对象（仅支持set()操作）	63
代码x2.9 可快速初始化的Bitmap对象（兼顾set()和clear()操作）	65
代码x2.10 Eratosthenes素数筛选算法	66
代码x3.1 基于遍历实现列表的increase()功能	76
代码x3.2 基于遍历实现列表的half()功能	76
代码x3.3 向量的选择排序算法	77
代码x3.4 列表倒置算法的第一种实现	85
代码x3.5 列表倒置算法的第二种实现	85
代码x3.6 列表倒置算法的第三种实现	85
代码x4.1 由List类派生Stack类	88
代码x4.2 操作数的解析	92
代码x4.3 运算符优先级关系的判定	93

代码x4.4 将操作数或操作符统一接至RPN表达式末尾	93
代码x4.5 PostScript语言的绘图程序	98
代码x5.1 二叉树先序遍历算法(迭代版#1)	108
代码x5.2 二叉树中序遍历算法(迭代版#4)	112
代码x6.1 基于PFS框架的BFS优先级更新器	132
代码x6.2 基于PFS框架的DFS优先级更新器	132
代码x7.1 二叉搜索树searchIn()算法的迭代实现	147
代码x7.2 power2BF_I()算法的递归版	152
代码x12.1 轴点构造算法(版本C)	221

关键词索引

(按关键词中各汉字的声母及各英文单词的首字母排序, 比如“大O记号”对应于“DOJH”)

A

- 凹函数 (concave function) 7, 159
埃拉托斯特尼的筛子 (the sieve of Eratosthenes) 66

B

- 并查集 (union-find set) 138
八叉树 (octree) 175
波峰集 (frontier) 124
比较树 (comparison tree) 45, 46, 47, 68, 107
伯努利实验 (Bernoulli trial) 217
半平衡二叉搜索树 (half-balanced binary search trees) 167
包围盒 (bounding-box) 172
半无穷范围查询 (semi-infinite range query) 204
 B^* -树 (B^* -tree) 166
标志 (tag) 91

C

- 差分约束系统 (system of difference constraints) 120
常数代价准则 (uniform cost criterion) 15
超限数学归纳法 (transfinite induction) 22
插值查找 (interpolation search) 53

D

- 多层搜索树 (multi-level search tree) 178
队堆 (queap) 207
递归跟踪 (recursion trace) 12, 24, 31
独立集 (disjoint set) 138
独立性 (independence) 40
对数代价准则 (logarithmic cost criterion) 15

Dijkstra算法 (Dijkstra Algorithm)	134, 202
Delaunay三角剖分 (Delaunay triangulation)	142
代数判定树 (algebraic decision tree, ADT)	68
队头 (front)	101
递推方程 (recurrence equation)	13, 23, 31, 55, 69, 84
队尾 (rear)	101

E

二分查找 (binary search)	46, 47, 48
二分递归 (binary recursion)	32, 107
ε -间距问题 (ε -closeness)	143

F

Fib-AVL树 (Fibonacci AVL tree)	150, 153
封底估算 (back-of-the-envelope calculation)	5, 66
分而治之 (divide-and-conquer)	32, 225
费马平方和定理 (Two-Square Theorem of Fermat)	187
分散层叠 (fractional cascading)	178
Floyd算法 (Floyd Algorithm)	201
分摊分析 (amortized analysis)	36, 37, 158, 201
范围树 (range tree)	176, 204

G

割 (cut)	128, 130, 135, 136, 137, 138
归并排序 (mergesort)	45
高度 (height)	105
关联树 (associative tree)	176
关联矩阵 (incidence matrix)	120
Gabriel图 (Gabriel graph)	143

H

合成数 (composite number)	134, 201
多叉堆 (d-heap)	202
好后缀 (good suffix)	214

后进先出 (last-in-first-out, LIFO)	108
活跃期 (active duration)	127

J

减而治之 (decrease-and-conquer)	51, 225
几何分布 (geometric distribution)	199, 217
键树 (trie)	118, 193, 194
计数排序 (counting sort)	190
禁形 (forbidden pattern)	89
基于比较式算法 (comparison-based algorithm, CBA)	68, 107, 199

K

kd-树 (kd-tree)	52
咖啡罐游戏 (Coffee Can Game)	22
Kruskal算法 (Kruskal Algorithm)	137, 138, 140, 142
快速排序 (quicksort)	36
k-选取 (k-selection)	222
空圆性质 (empty-circle property)	143

L

鲁棒性 (robustness)	96
路径压缩 (path compression)	141
邻接表 (adjacency list)	122, 189
邻接矩阵 (adjacency matrix)	120
邻近图 (proximity graph)	142
良序 (well order)	22
旅行商环路 (traveling salesman tour)	133

M

马鞍查找 (saddleback search)	51
末节点 (last node)	74, 86, 111
模式枚举 (pattern enumeration)	215

N

- NP完全的 (NP-complete) 12
 逆序对 (inversion) 4, 79

O

- 欧拉环路 (Eulerian tour) 126
 欧拉通路 (Eulerian path) 126
 欧氏最小支撑树 (Euclidean Minimum Spanning Tree, EMST) 142

P

- PATRICIA树 (PATRICIA tree) 194
 Prim算法 (Prim Algorithm) 128, 134, 136, 142, 202

Q

- 起泡排序 (bubblesort) 5
 期望值的线性律 (linearity of expectation) 33, 78, 83

R

- RNG图 (relative neighborhood graph) 143

S

- 哨兵节点 (sentinel node) 74, 196
 三叉键树 (ternary trie) 194
 四叉树 (quadtree) 52, 173, 194
 树堆 (treap) 204
 双端队列 (deque) 101
 随机存储器 (Random Access Machine, RAM) 20
 首节点 (first node) 74, 86, 153
 数据局部性 (data locality) 76, 166
 三角剖分 (triangulation) 121, 142
 随机生成 (randomly generated by) 148

随机算法 (randomized algorithm)	33
随机组成 (randomly composed of)	148
散列表 (hashtable)	62, 182, 183, 184, 185, 188, 189
势能 (potential)	158
势能分析法 (potential analysis)	36, 158
输入敏感的 (input sensitive)	79
伸展树 (splay tree)	36

T

凸函数 (convex function)	7
图灵机 (Turing Machine, TM)	20
跳转表 (skip list)	180

W

尾递归 (tail recursion)	223
稳定性 (stability)	191
外面 (outer face)	121
完全二叉堆 (complete binary heap)	196
完全二叉树 (complete binary tree)	146

X

斜堆 (skew heap)	200
循环节 (cycle)	82
循环列表 (Circular list)	86
先进先出 (first-in-first-out, FIFO)	149, 153, 180
小 ω 记号 (small-omega notation)	43
小 O 记号 (small-O notation)	43
循位置访问 (call-by-position)	74, 78
线性递归 (linear recursion)	29, 30, 31
线性规划 (linear programming)	120
线性时间归约 (linear-time reduction)	43, 75, 199
循秩访问 (call-by-rank)	62, 74

Y

叶节点平均深度 (average leaf depth)	107
掩码 (mask)	62
页面缓冲池 (buffer pool of pages)	166
元素唯一性 (Element Uniqueness)	44, 75
优先级搜索 (Priority-First Search, PFS)	202, 203
优先级搜索树 (priority search tree, PST)	204
元字符 (meta-character)	97

Z

最短路径树 (shortest-path tree)	132, 134, 141
字典序 (lexicographical order)	45, 46, 134
真二叉树 (proper binary tree)	105, 107, 116
直径 (diameter)	125
最近点对 (nearest pair)	143
最近邻图 (nearest neighbor graph)	143
主树 (main tree)	176
众数 (majority)	222
指数查找 (exponential search)	50
自调整列表 (self-adjusting list)	76
中位点 (median point)	170, 173
中位数 (median)	222
中缀表达式 (infix)	97
最左侧通路 (leftmost path)	151
最左最低点 (leftmost-then-lowest point)	22

习题汇总

第1章	第2章	第3章	第4章	第5章	第6章	第7章	第8章	第9章	第10章	第11章	第12章
[1-1]	[2-1]	[3-1]	[4-1]	[5-1]	[6-1]	[7-1]	[8-1]	[9-1]	[10-1]	[11-1]	[12-1]
[1-2]	[2-2]	[3-2]	[4-2]	[5-2]	[6-2]	[7-2]	[8-2]	[9-2]	[10-2]	[11-2]	[12-2]
[1-3]	[2-3]	[3-3]	[4-3]	[5-3]	[6-3]	[7-3]	[8-3]	[9-3]	[10-3]	[11-3]	[12-3]
[1-4]	[2-4]	[3-4]	[4-4]	[5-4]	[6-4]	[7-4]	[8-4]	[9-4]	[10-4]	[11-4]	[12-4]
[1-5]	[2-5]	[3-5]	[4-5]	[5-5]	[6-5]	[7-5]	[8-5]	[9-5]	[10-5]	[11-5]	[12-5]
[1-6]	[2-6]	[3-6]	[4-6]	[5-6]	[6-6]	[7-6]	[8-6]	[9-6]	[10-6]	[11-6]	[12-6]
[1-7]	[2-7]	[3-7]	[4-7]	[5-7]	[6-7]	[7-7]	[8-7]	[9-7]	[10-7]	[11-7]	[12-7]
[1-8]	[2-8]	[3-8]	[4-8]	[5-8]	[6-8]	[7-8]	[8-8]	[9-8]	[10-8]	[11-8]	[12-8]
[1-9]	[2-9]	[3-9]	[4-9]	[5-9]	[6-9]	[7-9]	[8-9]	[9-9]	[10-9]	[11-9]	[12-9]
[1-10]	[2-10]	[3-10]	[4-10]	[5-10]	[6-10]	[7-10]	[8-10]	[9-10]	[10-10]	[11-10]	[12-10]
[1-11]	[2-11]	[3-11]	[4-11]	[5-11]	[6-11]	[7-11]	[8-11]	[9-11]	[10-11]		[12-11]
[1-12]	[2-12]	[3-12]	[4-12]	[5-12]	[6-12]	[7-12]	[8-12]	[9-12]	[10-12]		[12-12]
[1-13]	[2-13]	[3-13]	[4-13]	[5-13]	[6-13]	[7-13]	[8-13]	[9-13]	[10-13]		[12-13]
[1-14]	[2-14]	[3-14]	[4-14]	[5-14]	[6-14]	[7-14]	[8-14]	[9-14]	[10-14]		[12-14]
[1-15]	[2-15]	[3-15]	[4-15]	[5-15]	[6-15]	[7-15]	[8-15]	[9-15]	[10-15]		
[1-16]	[2-16]	[3-16]	[4-16]	[5-16]	[6-16]	[7-16]	[8-16]	[9-16]	[10-16]		
[1-17]	[2-17]	[3-17]	[4-17]	[5-17]	[6-17]	[7-17]	[8-17]	[9-17]	[10-17]		
[1-18]	[2-18]	[3-18]	[4-18]	[5-18]	[6-18]	[7-18]	[8-18]	[9-18]	[10-18]		
[1-19]	[2-19]	[3-19]	[4-19]	[5-19]	[6-19]	[7-19]	[8-19]	[9-19]	[10-19]		
[1-20]	[2-20]		[4-20]	[5-20]	[6-20]	[7-20]	[8-20]	[9-20]	[10-20]		
[1-21]	[2-21]		[4-21]	[5-21]	[6-21]			[9-21]	[10-21]		
[1-22]	[2-22]		[4-22]	[5-22]	[6-22]			[9-22]	[10-22]		
[1-23]	[2-23]		[4-23]	[5-23]	[6-23]			[9-23]			
[1-24]	[2-24]		[4-24]	[5-24]	[6-24]			[9-24]			
[1-25]	[2-25]		[4-25]	[5-25]	[6-25]			[9-25]			
[1-26]	[2-26]		[4-26]	[5-26]	[6-26]			[9-26]			
[1-27]	[2-27]			[5-27]	[6-27]						
[1-28]	[2-28]			[5-28]	[6-28]						
[1-29]	[2-29]			[5-29]	[6-29]						
[1-30]	[2-30]			[5-30]	[6-30]						
[1-31]	[2-31]				[6-31]						
[1-32]	[2-32]				[6-32]						
	[2-33]										
	[2-34]										
	[2-35]										
	[2-36]										
	[2-37]										
	[2-38]										
	[2-39]										
	[2-40]										
	[2-41]										