Оглавление

Предисловие

Эта книга подробно рассказывает о современных методах построения и анализа алгоритмов. В ней подробно разобрано много конкретных алгоритмов; мы старались рассказать о них понятно, но не опуская деталей и не жертвуя строгостью изложения.

Алгоритмы записаны с виде *"псевдокода"* и прокомментированы в тексте; мы старались сделать описание алгоритма понятным людям с минимальным программистским опытом. Книга содержит более 260 рисунков, поясняющих работу различных алгоритмов. Мы обращаем особое внимание на эффективность рассматриваемых алгоритмов и приводим оценки времени их работы.

Мы старались написать учебник по построению алгоритмов и структур данных, который могли бы использовать преподаватели и студенты — от первокурсников до аспирантов. Книга может быть использована и для самообразования профессиональных программистов.

Преподавателям:

Мы старались сделать возможным использование книги на разных уровнях — от начального курса по программированию и структурам данных до аспирантского курса по эффективным алгоритмам. В ней гораздо больше материала, чем можно включить в семестровый курс, так что вы можете выбрать главы по вкусу.

Мы старались сделать главы достаточно независимыми. Каждая глава начинается с более простого материала; более трудные темы отнесены в разделы, помеченные звёздочкой и помещённые в конец главы. В лекциях для начинающих можно ограничиться несколькими первыми разделами выбранных вами глав, оставив подробное изучение остальных для более продвинутого курса.

Каждый раздел снабжён упражнениями (всего их более 900): каждая глава заканчивается задачами (всего более 120). Как правило, упражнения проверяют понимание изложенного материала (часть из них — устные вопросы, часть подходят для письменного домашнего задания). Задачи более развёрнуты; многие из них дополняют теоретический материал соответствующей главы и разбиты на части, соответствующие этапам доказательства или построения.

Звёздочкой отмечены более трудные упражнения и разделы; они предназначены скорее для старшекурсников и аспирантов. Разделы со звёздочкой часто требуют лучшей математической подготовки; упражнение со звёздочкой может также требовать дополнительных знаний или просто быть более трудным.

Студентам:

Мы надеемся, что книга доставит вам удовольствие и познакомит с методами построения алгоритмов. Мы старались писать подробно, понятно и интересно, напоминая по ходу дела необходимые сведения из математики. Подготовительные сведения обычно собраны в начальных разделах главы, которые можно бегло просмотреть, если вы уже знакомы с темой.

Книга эта велика, и на лекциях, скорее всего, будет разобрана лишь часть материала. Мы надеемся, что оставшаяся часть будет вам полезна если не сейчас, так в будущем, так что вы сохраните книгу в качестве справочника.

Что нужно знать, приступая к чтению? Мы рассчитываем, что вы

- имеете некоторый программистский опыт, и рекурсивные процедуры, массивы и списки вас не пугают;
- простые математические рассуждения (скажем, доказательства по индукции) вам также знакомы (кое-где понадобятся отдельные факты из курса математического анализа; в первой части больше ничего из математики не потребуется).

Программистам:

В книгу включены алгоритмы для самых разных задач и её можно использовать как справочник. Главы почти независимы, так что можно сразу выбрать интересующий вас материал.

Большинство обсуждаемых алгоритмов вполне могут быть использованы на практике, и мы уделяем должное внимание деталям реализации. Если алгоритм представляет скорее теоретический интерес, мы отмечаем это и обсуждаем альтернативные подходы.

Наш псевдокод легко перевести на любой язык программирования, если это понадобится. Надо только иметь в виду, что мы не включаем в алгоритмы системно-зависимые фрагменты (обработку ошибок и т. п.), чтобы не затемнять сути дела.

Ошибки

Книга такого объёма не может не содержать ошибок. Если вы обнаружили ошибку в английском оригинале книги, или у вас есть предложения по её исправлению, мы будем рады узнать об этом. Мы будем особенно рады новым упражнениям и задачам (но, пожалуйста, присылайте их с решениями). Почтовый адрес:

Introduction to Algorithms
MIT Labratory for Computer Science
545 Technology Square
Cambridge, Massachusetts 02139

Можно также получить список известных опечаток и сообщить о найденных ошибках с помощью электронной почты; чтобы получить инструкции, пошлите по адресу `algorithms@theory.lcs.mit.edu` письмо, содержащее `Subject: help` в заголовке. Извините, что мы не можем лично ответить на все письма.

[При переводе были учтены все исправления, имевшиеся на момент издания перевода (декабрь 1997), кроме того, исправлено несколько обнаруженных при переводе опечаток, но, возможно, возникли новые (в чём виноват научный редактор книги, А. Шень). Поэтому, обнаружив ошибку в русском тексте, не посылайте её сразу авторам: может быть, она возникла при переводе! Сообщите о ней сначала переводчикам, по адресу `algor@mccme.ru` или по почте (Москва, 121002, Большой Власьевский пер., 11, Московский центр непрерывного математического образования, издательство).]

Благодарности

Многие друзья и коллеги немало сделали для улучшения этой книги. Мы благодарим всех их за помощь и конструктивную критику.

Лаборатория информатики Массачусетского технологического института (Massachusetts Institute of Technology, Laboratory for Computer Science) была идеальным местом для работы над книгой. Наши коллеги по теоретической группе этой лаборатории были особенно терпимы и любезно соглашались просматривать главы книги. Мы хотели бы особенно поблагодарить следующих из них: Baruch Awerbuch, Shafi Goldwasser, Leo Guibas, Tom Leighton, Albert Meyer, David Shmoys, Eva Tardos. Компьютеры, на которых готовилась книга (трёх типов: Microvax, Apple Macintosh, Sun Sparcstation) поддерживали William Ang, Sally Bemus, Ray Hirschfeld и Mark Reinhold; они же перекомпилировали TEX, когда наши файлы перестали помещаться в его стандартную версию. Компания Thinking Machines поддерживала Чарльза Лейзерсона в

период его работы в этой компании.

Многие наши коллеги использовали предварительные варианты этой книги в своих лекционных курсах, и предложили различные улучшения. Мы хотели бы особенно поблагодарить следующих наших коллег: Richard Beigel (Yale), Andrew Goldberg (Stanford), Joan Lucas (Rutgers), Mark Overmars (Utrecht), Alan Sherman (Tufts, Maryland), Diane Souvaine (Rutgers).

При чтении лекций по материалам этой книги нам помогали наши коллеги, которые внесли много улучшений. Мы особенно признательны: Alan Baratz, Bonnie Berger, Aditi Dhagat, Burt Kaliski, Arthur Lent, Andrew Moulton, Marios Papaefthymiou, Cindy Phillips, Mark Reinhold, Phil Rogaway, Flavio Rose, Arie Rudich, Alan Sherman, Cliff Stein, Susmita Sur, Gregory Troxel, Margaret Tuttle.

Многие люди помогли нам в работе над книгой в разных отношениях: работа в библиотеке (Denise Sergent), гостеприимство в читальном зале (Maria Sensale), доступ к личной библиотеке (Albert Meyer), проверка упражнений и придумывание новых (Shlomo Kipnis, Bill Niehaus, David Wilson), составление индекса (Marios Papaefthymiou, Gregory Troxel), техническая помощь (Inna Radzihovsky, Denise Sergent, Gayle Sherman, и особенно Be Hubbard).

Многие ошибки обнаружили наши студенты, особенно Bobby Blumofe, Bonnie Eisenberg, Raymond Johnson, John Keen, Richard Lethin, Mark Lillibridge, John Pesaris, Steve Ponzio, Margaret Tuttle.

Многие наши коллеги сообщили нам полезную информацию о конкретных алгоритмах, а также критически прочитали отдельные главы книги; в их числе Bill Aiello, Alok Aggrawal, Eric Bach, Vašek Chvátal, Richard Cole, Johan Hastad, Alex Ishii, David Johnson, Joe Kilian, Dina Kravets, Bruce Maggs, Jim Orlin, James Park, Thane Plambeck, Herschel Safer, Jeff Shallit, Cliff Stein, Gil Strang, Bob Tarjan, Paul Wang. Многие из них предложили нам задачи для нашей книги, среди них Andrew Goldberg, Danny Sleator, Umesh Vazirani.

Английский оригинал книги был подготовлен с помощью LaTeX (макропакет для системы TeX). Рисунки делались на компьютере Apple Macintosh с помощью программы Mac Draw II; мы благодарны за оперативную техническую поддержку в этой области (Joanna Terry, Claris Corporation; Michael Mahoney, Advanced Computer Graphics). Индекс был подготовлен с помощью программы Windex, написанной авторами. Список литературы готовился с помощью программы BibTeX. Оригинал-макет английского издания был подготовлен в Американском математическом обществе с помощью фотонаборной машины фирмы Autologic; мы признательны за помощь в этом (Ralph Youngen, Американское математическое общество). Макет разработали: Rebecca Daw, Amy Henderson (реализация макета для системы LaTeX), Jeannet

Leendertse (обложка).

Авторы получили большое удовольствие от сотрудничества с издательствами MIT Press (Frank Sallow, Terry Ehling, Larry Cohen, Lorrie Lejeune) и McGraw-Hill (David Shapiro) и благодарны им за поддержку и терпение, а также замечательное редактирование (Larry Cohen).

Наконец, авторы благодарят своих жён (Nicole Cormen, Lina Lue Leicerson, Gail Rivest) и детей (Ricky, William и Debby Leicerson; Alex и Christopher Rivest) за любовь и поддержку при работе над книгой (Alex Rivest также помог нам с *"парадоксом дней рождения на Марсе"* (раздел 6.6.1). Любовь, терпение и поддержка наших семей сделали эту книгу возможной; им она и посвящается.

Кембридж, Томас Кормен (Thomas H. Cormen)
Массачусетс Чарльз Лейзерсон (Charles E. Leiserson)
март 1990 года Рональд Ривест (Ronald L. Rivest)

От переводчиков:

Мы признательны издательству MIT и авторам за разрешение перевести книгу, и за помощь при подготовке перевода (в том числе за предоставление английского текста книги и иллюстраций в электронной форме). Издание перевода стало возможно благодаря финансовой поддержке Российского фонда фундаментальных исследований (руководитель проекта В.А. Успенский).

В работе над переводом книги участвовала большая группа студентов, аспирантов и сотрудников Московского центра непрерывного математического образования, Независимого Московского университета и МГУ:

К. Белов, Ю. Боравлёв, Д. Ботин, В. Горелик, Д. Дерягин Ю. Калнишкан, А. Катанова, С. Львовский, А. Ромащенко, К. Сонин, К. Трушкин, М. Ушаков, А. Шень, В. Шувалов, М. Юдашкин (перевод)

А. Акимов, М. Вьюгин, Д. Дерягин, А. Евфимьевский, Ю. Калнишкан, А. Ромащенко, А. Чернов М. Ушаков, А. Шень (редактирование)

В. Радионов (вёрстка)

В.В. Ященко (редактор)

1 Введение

В этой главе мы разбираем основные понятия и методы, связанные с построением и анализом алгоритмов, на примере двух алгоритмов сортировки — простейшего алгоритма сортировки вставками и более эффективного алгоритма сортировки слиянием.

На этих примерах мы познакомимся с псевдокодом, на котором мы будем записывать алгоритмы, обозначениями для скорости роста функций, методом *"разделяй и властвуй"* построения алгоритмов, а также с другими понятиями, которые будут встречаться нам на протяжении всей книги.

1.1 Алгоритмы

Алгоритм (algorithm) — это формально описанная вычислительная процедура, получающая **исходные данные** (input), называемые также входом алгоритма или его аргументом, и выдающая **результат** вычислений на выход (output).

Алгоритмы строятся для решения тех или иных **вычислительных задач** (computational problems). Формулировка задачи описывает, каким требованиям должно удовлетворять решение задачи, а алгоритм, решающий эту задачу, находит объект, этим требованиям удовлетворяющий.

В этой главе мы рассматриваем **задачу сортировки** (sorting problem); помимо своей практической важности эта задача служит удобным примером для иллюстрации различных понятий и методов. Она описывается так:

Вход: Последовательность n чисел $(a_1, a_2, \ldots, a_n)$.

Выход: Перестановка $(a'_1, a'_2, \ldots, a'_n)$ исходной последовательности, для которой $a'_1 \leqslant a'_2 \leqslant \ldots \leqslant a'_n$.

Например, получив на вход $\langle 31, 41, 59, 26, 41, 58 \rangle$, алгоритм сортировки должен выдать на выход $\langle 26, 31, 41, 41, 58, 59 \rangle$.

Подлежащая сортировке последовательность называется **входом** (instance) задачи сортировки.

Многие алгоритмы используют сортировку в качестве промежуточного шага. Имеется много разных алгоритмов сортировки; выбор в конкретной ситуации зависит от длины сортируемой последовательности, от того, в какой степени она уже отсортирована, а также от типа имеющейся памяти (оперативная память, диски, магнитные ленты).

Алгоритм считают **правильным** (correct), если на любом допустимом (для данной задачи) входе он он заканчивает работу и выдает результат, удовлетворяющий требованиям задачи. В этом случае говорят, что алгоритм **решает** (solves) данную вычислительную задачу. Неправильный алгоритм может (для некоторого входа) вовсе не остановиться или дать неправильный результат. (Впрочем, это не делает алгоритм заведомо бесполезным — если ошибки достаточно редки. Подобная ситуация встретится нам в главе 33 при поиске больших простых чисел. Но это всё же скорее исключение, чем правило.)

Алгоритм может быть записан на русском или английском языке, в виде компьютерной программы или даже в машинных кодах — важно только, чтобы процедура вычислений была чётко описана.

Мы будем записывать алгоритмы с помощью **псевдокода** (pseudocode), который напомнит вам знакомые языки программирования (Си, Паскаль, Алгол). Разница в том, что иногда мы позволяем себе описать действия алгоритма *"своими словами"*, если так получается яснее. Кроме того, мы опускаем технологические подробности (обработку ошибок, скажем), которые необходимы в реальной программе, но могут заслонить существо дела.

Сортировка вставками

Сортировка вставками (insertion sort) удобна для сортировки коротких последовательностей. Именно таким способом обычно сортируют карты: держа в левой руке уже упорядоченные карты и взяв правой рукой очередную карту, мы вставляем её в нужное место, сравнивая с имеющимися и идя справа налево (см. рис. 1.1)

Запишем этот алгоритм в виде процедуры Insertion-Sort, параметром которой является массив $A[1\,..\,n]$ (последовательность длины n, подлежащая сортировке). Мы обозначаем число элементов в массиве A через $length[A]$. Последовательность сортируется *"на месте"* (in place), без дополнительной памяти (помимо массива мы используем лишь фиксированное число ячеек памяти). После выполнения процедуры Insertion-Sort массив A упорядочен по возрастанию.

Рисунок 1.1 Сортировка карт вставками

```
Insertion-Sort(A)
for j ← 2 to length[A]
     do key ← A[j]
        ▷ добавить A[j] к отсортированной части A[1 . . j − 1].
        i ← j − 1
        while i > 0 and A[i] > key
            do A[i + 1] ← A[i]
               i ← i − 1
        A[i + 1] ← key
```

Рисунок 1.2 Работа процедуры Insertion-Sort для входа $A = \langle 5, 2, 4, 6, 1, 3 \rangle$. Позиция j показана кружком.

На рис. 1.2 показана работа алгоритма при $A = \langle 5, 2, 4, 6, 1, 3 \rangle$. Индекс j указывает *"очередную карту"* (только что взятую со стола). Участок $A[1\,..\,j-1]$ составляют уже отсортированные карты (левая рука), а $A[j+1\,..\,n]$ — ещё не просмотренные. В цикле **for** индекс j пробегает массив слева направо. Мы берём элемент

$A[j]$ (строка 2 алгоритма) и сдвигаем идущие перед ним и большие его по величине элементы (начиная с $j-1$-го) вправо, освобождая место для взятого элемента. (строки 4–7). В строке 8 элемент $A[j]$ помещается в освобождённое место.

Псевдокод

Вот основные соглашения, которые мы будем использовать:

1. Отступ от левого поля указывает на уровень вложенности. Например, тело цикла **for** (строка 1) состоит из строк 2–8, а тело цикла **while** (строка 5) содержит строки 6–7, но не 8. Это же правило применяется и для **if-then-else**. Это делает излишним специальные команды типа **begin** и **end** для начала и конца блока. (В реальных языках программирования такое соглашение применяется редко, поскольку затрудняет чтение программ, переходящих со страницы на страницу.)

2. Циклы **while**, **for**, **repeat** и условные конструкции **if**, **then**, **else** имеют тот же смысл, что в Паскале.

3. Символ $\triangleright$ начинает комментарий (идущий до конца строки).

4. Одновременное присваивание $i \leftarrow j \leftarrow e$ (переменные i и j получают значение e) заменяет два присваивания $j \leftarrow e$ и $i \leftarrow j$ (в этом порядке).

5. Переменные (в данном случае i, j, key) локальны внутри процедуры (если не оговорено противное).

6. Индекс массива пишется в квадратных скобках: $A[i]$ есть i-й элемент в массиве A. Знак ".." выделяет часть массива: $A[1\,..\,j]$ обозначает участок массива A, включающий $A[1], A[2], \ldots, A[j]$.

7. Часто используются **объекты** (objects), состоящие из нескольких **полей** (fields), или, как говорят, имеющие несколько **атрибутов** (attributes). Значение поля записывается как *имя_поля*[*имя_объекта*]. Например, длина массива считается его атрибутом и обозначается *length*, так что длина массива A запишется как *length*[A]. Что обозначают квадратные скобки (элемент массива или поле объекта), будет ясно из контекста.

Переменная, обозначающая массив или объект, считается указателем на составляющие его данные. После присваивания $y \leftarrow x$ для любого поля f выполнено $f[y] = f[x]$. Более того, если мы теперь выполним оператор $f[x] \leftarrow 3$, то будет не только $f[x] = 3$, но и $f[y] = 3$, поскольку после $y \leftarrow x$ переменные x и y указывают на один и тот же объект.

Указатель может иметь специальное значение NIL, не указывающее ни на один объект.

8. Параметры передаются **по значению** (by value): вызванная процедура получает собственную копию параметров; изменение параметра внутри процедуры снаружи невидимо. При передаче объек-

тов копируется указатель на данные, составляющие этот объект, а сами поля объекта — нет. Например, если x — параметр процедуры, то присваивание $x \leftarrow y$, выполненное внутри процедуры, снаружи заметить нельзя, а присваивание $f[x] \leftarrow 3$ — можно.

Упражнения

1.1-1 Следуя образцу рис. 1.2, покажите, как работает Insertion-Sort на входе $A = \langle 31, 41, 59, 26, 41, 58 \rangle$.

1.1-2 Измените процедуру Insertion-Sort так, чтобы она сортировала числа в невозрастающем порядке (вместо неубывающего).

1.1-3 Рассмотрим следующую **задачу поиска**:

Вход: Последовательность n чисел $A = \langle a_1, a_2, \ldots, a_n \rangle$ и число v.

Выход: Индекс i, для которого $v = A[i]$, или специальное значение NIL, если v не встречается в A.

Напишите программу **линейного поиска** (linear search), который последовательно просматривает A в поисках v.

1.1-4 Даны два n-значных двоичных числа, записанных в виде n-элементных массивов A и B. Требуется поместить их сумму (в двоичной записи) в $(n+1)$-элементный массив C. Уточните постановку задачи и запишите соответствующую программу на псевдокоде.

1.2 Анализ алгоритмов

Рассматривая различные алгоритмы решения одной и той же задачи, полезно проанализировать, сколько вычислительных ресурсов они требуют (время выполнения, память), и выбрать наиболее эффективный. Конечно, надо договориться о том, какая модель вычислений используется. В этой книге в качестве модели по большей части используется обычная однопроцессорная **машина с произвольным доступом** (random-access machine, RAM), не предусматривающая параллельного выполнения операций. (Мы рассмотрим некоторые модели параллельных вычислений в последней части книги.)

Сортировка вставками: анализ

Время сортировки вставками зависит от размера сортируемого массива: чем больше массив, тем больше может потребоваться времени. Обычно изучают зависимости времени работы от размера входа. (Впрочем, для алгоритма сортировки вставками важен не только размер массива, но и порядок его элементов: если массив почти упорядочен, то времени требуется меньше.)

Как измерять **размер входа** (input size)? Это зависит от конкретной задачи. В одних случаях разумно считать число элементов на входе (сортировка, преобразование Фурье). В других более естественно считать общее число битов, необходимое для представления всех входных данных. Иногда размер входа измеряется не одним числом, а несколькими (например, число вершин и число рёбер графа).

Временем работы (running time) алгоритма мы называем число элементарных шагов, которые он выполняет — вопрос только в том, что считать элементарным шагом. Мы будем полагать, что одна строка псевдокода требует не более чем фиксированного числа операций (если только это не словесное описание какой-то сложной операции — типа *"отсортировать все точки по x-координате"*). Мы будем различать также **вызов** (call) процедуры (на который уходит фиксированное число операций) и её **исполнение** (execution), которое может быть долгим.

Итак, вернёмся к процедуре Insertion-Sort и отметим около каждой строки её стоимость (число операций) и число раз, которое эта строка исполняется. Для каждого j от 2 до n (здесь $n = length[A]$ — размер массива) подсчитаем, сколько раз будет исполнена строка 5, и обозначим это число через t_j. (Заметим, что строки внутри цикла выполняются на один раз меньше, чем проверка, поскольку последняя проверка выводит из цикла.)

	Insertion-Sort(A)	*стоимость*	*число раз*
1	**for** $j \leftarrow 2$ **to** $length[A]$	c_1	n
2	**do** $key \leftarrow A[j]$	c_2	$n-1$
3	▷ добавить $A[j]$ к отсортиро- ▷ ванной части $A[1\,..\,j-1]$.	0	$n-1$
4	$i \leftarrow j-1$	c_4	$n-1$
5	**while** $i > 0$ and $A[i] > key$	c_5	$\sum_{j=2}^{n} t_j$
6	**do** $A[i+1] \leftarrow A[i]$	c_6	$\sum_{j=2}^{n}(t_j-1)$
7	$i \leftarrow i-1$	c_7	$\sum_{j=2}^{n}(t_j-1)$
8	$A[i+1] \leftarrow key$	c_8	$n-1$

Строка стоимости c, повторённая m раз, даёт вклад cm в общее число операций. (Для количества использованной памяти этого сказать нельзя!) Сложив вклады всех строк, получим

$$T(n) = c_1 n + c_2(n-1) + c_4(n-1) + c_5 \sum_{j=2}^{n} t_j + \\ + c_6 \sum_{j=2}^{n} (t_j - 1) + c_7 \sum_{j=2}^{n} (t_j - 1) + c_8(n-1).$$

Как мы уже говорили, время работы процедуры зависит не только от n, но и от того, какой именно массив размера n подан ей на вход. Для процедуры Insertion-Sort наиболее благоприятен случай, когда массив уже отсортирован. Тогда цикл в строке 5 завершается после первой же проверки (поскольку $A[i] \leqslant key$ при $i = j - 1$), так что все t_j равны 1, и общее время есть

$$T(n) = c_1 n + c_2(n-1) + c_4(n-1) + c_5(n-1) + c_8(n-1) = \\ = (c_1 + c_2 + c_4 + c_5 + c_8)n - (c_2 + c_4 + c_5 + c_8).$$

Таким образом, в наиболее благоприятном случае время $T(n)$, необходимое для обработки массива размера n, является **линейной функцией** (linear function) от n, т.е. имеет вид $T(n) = an + b$ для некоторых констант a и b. (Эти константы определяются выбранными значениями $c_1, \ldots, c_8$.)

Если же массив расположен в обратном (убывающем) порядке, время работы процедуры будет максимальным: каждый элемент $A[j]$ придётся сравнить со всеми элементами $A[1] \ldots A[j-1]$. При этом $t_j = j$. Вспоминая, что

$$\sum_{j=2}^{n} j = \frac{n(n+1)}{2} - 1, \qquad \sum_{j=2}^{n} (j-1) = \frac{n(n-1)}{2}$$

(см. гл. 3), получаем, что в худшем случае время работы процедуры равно

$$T(n) = c_1 n + c_2(n-1) + c_4(n-1) + c_5 \left(\frac{n(n+1)}{2} - 1 \right) + \\ + c_6 \left(\frac{n(n-1)}{2} \right) + c_7 \left(\frac{n(n-1)}{2} \right) + c_8(n-1) = \\ = \left(\frac{c_5}{2} + \frac{c_6}{2} + \frac{c_7}{2} \right) n^2 + \left(c_1 + c_2 + c_4 + \frac{c_5}{2} - \frac{c_6}{2} - \frac{c_7}{2} + c_8 \right) n - \\ - (c_2 + c_4 + c_5 + c_8).$$

Теперь функция $T(n)$ — **квадратичная** (quadratic function), т.е. имеет вид $T(n) = an^2 + bn + c$. (Константы a, b и c снова определяются значениями c_1–c_8.)

Время работы в худшем случае и в среднем

Итак, мы видим, что время работы в худшем случае и в лучшем случае могут сильно различаться. Большей частью нас будет интересовать **время работы в худшем случае** (worst-case running time), которое определяется как максимальное время работы для входов данного размера. Почему? Вот несколько причин.

- Зная время работы в худшем случае, мы можем гарантировать, что выполнение алгоритма закончится за некоторое время, даже не зная, какой именно вход (данного размера) попадётся.
- На практике *"плохие"* входы (для которых время работы близко к максимуму) могут часто попадаться. Например, для базы данных плохим запросом может быть поиск отсутствующего элемента (довольно частая ситуация).
- Время работы в среднем может быть довольно близко к времени работы в худшем случае. Пусть, например, мы сортируем случайно расположенные n чисел в помощью процедуры Insertion-Sort. Сколько раз придётся выполнить цикл в строках 5–8? В среднем около половины элементов массива $A[1\,..\,j-1]$ больье $A[j]$, так что t_j в среднем можно считать равным $j/2$, и время $T(n)$ квадратично зависит от n.

В некоторых случаях нас будет интересовать также **среднее время работы** (average-case running time, expexted running time) алгоритма на входах данной длины. Конечно, эта величина зависит от выбранного распределения вероятностей (обычно рассматривается равномерное распределение), и на практике реальное распределение входов может оказаться совсем другим. (Иногда его можно преобразовать в равномерное, используя датчик случайных чисел.)

Порядок роста

Наш анализ времени работы процедуры Insertion-Sort был основан на нескольких упрощающих предположениях. Сначала мы предположили, что время выполнения i-й строки постоянно и равно c_i. Затем мы огрубили оценку до $an^2 + bn + c$. Сейчас мы пойдём ещё дальше и скажем, что время работы в худшем случае имеет **порядок роста** (rate of growth, order of growth) n^2, отбрасывая члены меньших порядков (линейные) и не интересуясь коэффициентом при n^2. Это записывают так: $T(n) = \Theta(n^2)$ (подробное объяснение обозначений мы отложим до следующей главы).

Алгоритм с меньшим порядком роста времени работы обычно предпочтителен: если, скажем, один алгоритм имеет время работы $\Theta(n^2)$, а другой — $\Theta(n^3)$, то первый более эффективен (по крайней мере для достаточно длинных входов; будут ли реальные входы таковыми — другой вопрос).

Упражнения

1.2-1 Будем сортировать массив из n элементов так: просмотрим его и найдём минимальный элемент, который скопируем в первую ячейку другого массива. Затем просмотрим его снова и найдём следующий элемент, и так далее. Такой способ сортировки можно назвать **сортировкой выбором** (selection sort). Запишите этот алгоритм с помощью псевдокода. Укажите время его работы в лучшем и худшем случаях, используя Θ-обозначения.

1.2-2 Вернёмся к алгоритму линейного поиска (упр. 1.1-3). Сколько сравнений потребуется в среднем этому алгоритму, если искомым элементом может быть любой элемент массива (с одинаковой вероятностью)? Каково время работы в худшем случае и в среднем? Как записать эти времена с помощью Θ-обозначений?

1.2-3 Дана последовательность чисел $x_1, x_2, \ldots, x_n$. Покажите, что за время $\Theta(n \log n)$ можно определить, есть ли в этой последовательности два одинаковых числа.

1.2-4 Даны коэффициенты $a_0, a_1, \ldots, a_{n-1}$ многочлена; требуется найти его значение в заданной точке x. Опишите естественный алгоритм, требующий времени $\Theta(n^2)$. Как выполнить вычисления за время $\Theta(n)$, не используя дополнительного массива? Используйте *"схему Горнера"*:

$$\sum_{i=0}^{n-1} a_i x^i = (\ldots(a_{n-1}x + a_{n-2})x + \ldots + a_1)x + a_0.$$

1.2-5 Как записать выражение $n^3/1000 - 100n^2 - 100n + 3$ с помощью Θ-обозначений?

1.2-6 Почти любой алгоритм можно немного изменить, радикально уменьшив время его работы в лучшем случае. Как?

1.3 Построение алгоритмов

Есть много стандартных приёмов, используемых при построении алгоритмов. Сортировка вставками является примером алгоритма, действующего **по шагам** (incremental approach): мы добавляем элементы один за другим к отсортированной части массива.

В этом разделе мы покажем в действии другой подход, который называют *"разделяй и властвуй"* (divide-and-conquer approach), и построим с его помощью значительно более быстрый алгоритм сортировки.

1.3.1 Принцип *"разделяй и властвуй"*

Многие алгоритмы по природе **рекурсивны** (recursive algorithms): решая некоторую задачу, они вызывают самих себя для решения её подзадач. Идея метода *"разделяй и властвуй"* состоит как раз в этом. Сначала задача разбивается на несколько подзадач меньшего размера. Затем эти задачи решаются (с помощью рекурсивного вызова — или непосредственно, если размер достаточно мал). Наконец, их решения комбинируются и получается решение исходной задачи.

Для задачи сортировки эти три этапа выглядят так. Сначала мы разбиваем массив на две половины меньшего размера. Затем мы сортируем каждую из половин отдельно. После этого нам остаётся соединить два упорядоченных массива половинного размера в один. Рекурсивное разбиение задачи на меньшие происходит до тех пор, пока размер массива не дойдёт до единицы (любой массив длины 1 можно считать упорядоченным).

Нетривиальной частью является соединение двух упорядоченных массивов в один. Оно выполняется с помощью вспомогательной процедуры $\textsc{Merge}(A, p, q, r)$. Параметрами этой процедуры являются массив A и числа p, q, r, указывающие границы сливаемых участков. Процедура предполагает, что $p \leqslant q < r$ и что участки $A[p \,..\, q]$ и $A[q+1 \,..\, r]$ уже отсортированы, и **сливает** (merges) их в один участок $A[p \,..\, r]$.

Мы оставляем подробную разработку этой процедуры читателю (упр. 1.3-2), но довольно ясно, что время работы процедуры $\textsc{Merge}$ есть $\Theta(n)$, где n — общая длина сливаемых участков ($n = r - p + 1$). Это легко объяснить на картах. Пусть мы имеем две стопки карт, и в каждой карты идут сверху вниз в возрастающем порядке. Как сделать из них одну? На каждом шаге мы берём меньшую из двух верхних карт и кладём её (рубашкой вверх) в результирующую стопку. Когда одна из исходных стопок становится пустой, мы добавляем все оставшиеся карты второй стопки к результирующей стопке. Ясно, что каждый шаг требует ограниченного числа действий, и общее число действий есть $\Theta(n)$.

Теперь напишем процедуру сортировки слиянием $\textsc{Merge-Sort}(A, p, r)$, которая сортирует участок $A[p \,..\, r]$ массива A, не меняя остальную часть массива. При $p \geqslant r$ участок содержит максимум один элемент, и тем самым уже отсортирован. В противном случае мы отыскиваем число q, которое делит участок на две примерно равные части $A[p \,..\, q]$ (содержит $\lceil n/2 \rceil$ элементов) и $A[q+1 \,..\, r]$ (содержит $\lfloor n/2 \rfloor$ элементов). Здесь через $\lfloor x \rfloor$ мы обозначаем целую часть x (наибольшее целое число, меньшее или равное x), а через $\lceil x \rceil$ — наименьшее целое число, большее или равное x.

sorted sequence — отсортированная последовательность
merge — слияние
initial sequence — начальная последовательность

Рисунок 1.3 Сортировка слиянием для массива $A = \langle 5, 2, 4, 6, 1, 3, 2, 6 \rangle$.

Merge-Sort(A, p, r)

if $p < r$
  then $q \leftarrow \lfloor (p + r)/2 \rfloor$
    Merge-Sort(A, p, q)
    Merge-Sort$(A, q + 1, r)$
    Merge(A, p, q, r)

Весь массив теперь можно отсортировать с помощью вызова Merge-Sort$(A, 1, \mathit{length}[A])$. Если длина массива $n = \mathit{length}[A]$ есть степень двойки, то в процессе сортировки произойдёт слияние пар элементов в отсортированные участки длины 2, затем слияние пар таких участков в отсортированные участки длины 4 и так далее до n (на последнем шаге соединяются два отсортированных участка длины $n/2$). Этот процесс показан на рис. 1.3.

1.3.2 Анализ алгоритмов типа *"разделяй и властвуй"*

Как оценить время работы рекурсивного алгоритма? При подсчёте мы должны учесть время, затрачиваемое на рекурсивные вызовы, так что получается некоторое **рекуррентное соотношение** (recurrence equation). Далее следует оценить время работы, исходя из этого соотношения.

Вот примерно как это делается. Предположим, что алгоритм разбивает задачу размера n на a подзадач, каждая из которых имеет в b раз меньший размер. Будем считать, что разбиение требует времени $D(n)$, а соединение полученных решений — времени $C(n)$.

Тогда получаем соотношение для времени работы $T(n)$ на задачах размера n (в худшем случае): $T(n) = aT(n/b) + D(n) + C(n)$. Это соотношение выполнено для достаточно больших n, когда задачу имеет смысл разбивать на подзадачи. Для малых n, когда такое разбиение невозможно или не нужно, применяется какой-то прямой метод решения задачи. Поскольку n ограничено, время работы тоже не превосходит некоторой константы.

Анализ сортировки слиянием

Для простоты будем предполагать, что размер массива (n) есть степень двойки. (Как мы увидим в главе 4, это не очень существенно.) Тогда на каждом шаге сортируемый участок делится на две равные половины. Разбиение на части (вычисление границы) требует времени $\Theta(1)$, а слияние — времени $\Theta(n)$. Получаем соотношение

$$T(n) = \begin{cases} \Theta(1), & \text{если } n = 1, \\ 2T(n/2) + \Theta(n/2), & \text{если } n > 1. \end{cases}$$

Как мы увидим в главе 4, это соотношение влечёт $T(n) = \Theta(n \log n)$, где через $\log$ мы обозначаем двоичный логарифм (основание логарифмов, впрочем, не играет роли, так как приводит лишь к изменению константы). Поэтому для больших n сортировка слиянием эффективнее сортировки вставками, требующей времени $\Theta(n^2)$.

Упражнения

1.3-1 Следуя образцу рис. 1.3, показать работу сортировки слиянием для массива $A = \langle 3, 41, 52, 26, 38, 57, 9, 49 \rangle$.

1.3-2 Написать текст процедуры $\textsc{Merge}(A, p, q, r)$.

1.3-3 Докажите по индукции, что если

$$T(n) = \begin{cases} 2, & \text{если } n = 2, \\ 2T(n/2) + n, & \text{если } n = 2^k \text{ и } k > 1, \end{cases}$$

то $T(n) = n \log n$ (при всех n, являющихся степенями двойки).

1.3-4 Сортировку вставками можно оформить как рекурсивную процедуру: желая отсортировать $A[1\,..\,n]$, мы (рекурсивно) сортируем $A[1\,..\,n-1]$, а затем ставим $A[n]$ на правильное место в отсортированном массиве $A[1\,..\,n-1]$. Напишите рекуррентное соотношение для времени работы такой процедуры.

1.3-5 Возвращаясь к задаче поиска (упр. 1.1-3), заметим, что при поиске в отсортированном массиве мы можем сначала сравнить искомый элемент со средним элементом массива, узнать, в какой половине его следует искать, а затем применить ту же идею рекурсивно. Такой способ называется **двоичным поиском** (binary search). Напишите соответствующую программу, используя цикл или рекурсию. Объясните, почему время её работы есть $\Theta(\log n)$.

1.3-6 Заметим, что цикл **while** в строках 5–7 процедуры Insertion-Sort (разд. 1.1) просматривает элементы отсортированного участка $A[1\,..\,j-1]$ подряд. Вместо этого можно было бы использовать двоичный поиск (упр. 1.3-5), чтобы найти место вставки за время $\Theta(\log n)$. Удастся ли таким образом сделать общее время работы равным $\Theta(n \log n)$?

1.3-7* Дан массив S из n действительных чисел, а также число x. Как за время $\Theta(n \log n)$ определить, можно ли представить x в виде суммы двух элементов массива S?

Замечания

Как мог бы сказать Козьма Прутков, хороший алгоритм подобен острому ножу — тот и другой достигают цели легко и просто. Другое сравнение: человек, пользующийся плохим алгоритмом, подобен повару, отбивающему мясо отвёрткой: едва съедобный и малопривлекательный результат достигается ценой больших усилий.

Часто разница между плохим и хорошим алгоритмом более существенна, чем между быстрым и медленным компьютером. Пусть мы хотим отсортировать массив из миллиона чисел. Что быстрее — сортировать его вставками на суперкомпьютере (100 миллионов операций в секунду) или слиянием на домашнем компьютере (1 миллион операций)? Пусть к тому же сортировка вставками написана на ассемблере чрезвычайно экономно, и для сортировки n чисел нужно, скажем, лишь $2n^2$ операций. В то же время алгоритм слиянием написан без особой заботы об эффективности и число операций есть $50n \log n$. Для сортировки миллиона чисел получаем

$$\frac{2 \cdot (10^6)^2 \text{ операций}}{10^8 \text{ операций в секунду}} = 20\,000 \text{ секунд} \approx 5{,}56 \text{ часов}$$

для суперкомпьютера и всего

$$\frac{50 \cdot (10^6) \log(10^6) \text{ операций}}{10^6 \text{ операций в секунду}} \approx 1\,000 \text{ секунд} \approx 17 \text{ минут}$$

для домашнего компьютера.

Мы видим, что разработка эффективных алгоритмов — не менее важная компьютерная технология, чем разработка быстрой электроники. В этой области также происходит заметный прогресс.

Упражнения

1.3-1 Пусть сортировки вставками и слиянием исполняются на одной и той же машине и требуют $8n^2$ и $64n \log n$ соответственно. Для каких значений n сортировка вставками является более эффективной? Как можно улучшить алгоритм сортировки слиянием?

1.3-2 При каком наименьшем значении n алгоритм, делающий $100n^2$ операций, эффективнее алгоритма, делающего 2^n операций?

Задачи

1-1 Сравнение времени работы

Пусть имеется алгоритм, решающий задачу размера n за $f(n)$ микросекунд. Каков максимальный размер задачи, которую он сможет решить за время t? Найти его для функций и времён, перечисленных в таблице.

	1 сек	1 мин	1 час	1 день	1 месяц	1 год	1 век
$\log n$							
$\sqrt{n}$							
n							
$n \log n$							
n^2							
n^3							
2^n							
$n!$							

1-2 Сортировка вставками для коротких кусков

Асимптотически сортировка слиянием быстрее сортировки вставками, но для малых n соотношение обратное. Поэтому имеет смысл достаточно короткие куски не разбивать дальше, а применять к ним сортировку вставками. Вопрос в том, где следует провести границу.

а. Пусть массив длины n разбит на k частей размера n/k. Покажите, что можно отсортировать все части по отдельности (с помощью сортировки вставками) за время $\Theta(nk)$.

б. Покажите, что после этого можно слить все части в один упорядоченный массив за время $\Theta(n \log(n/k))$.

в. Тем самым общее время работы такого смешанного алгоритма есть $\Theta(nk + n \log(n/k))$. Какова максимальная скорость роста k как функции от n, при котором это время по-прежнему есть $\Theta(n \log n)$?

г. Как бы вы стали выбирать оптимальное значение k на практике?

1-3 Число инверсий

Пусть $A[1\,..\,n]$ — массив из n различных чисел. Нас будет интересовать количество **инверсий** (inversions) в этом массиве, т.е. число пар $i < j$, для которых $A[i] > A[j]$.

а. Укажите пять инверсий в массиве $\langle 2, 3, 8, 6, 1 \rangle$.

б. Каково максимально возможное число инверсий в массиве длины n?

в. Как связано время работы алгоритма сортировки вставками и число инверсий? Объясните свой ответ.

г. Постройте алгоритм, который считает число инверсий в массиве длины n за время $\Theta(n \log n)$. (Указание: Модифицируйте алгоритм сортировки слиянием.)

Замечания

Есть множество хороших книг о построении алгоритмов. Вот некоторые из них: Ахо, Хопкрофт и Ульман [4,5], Баас [14], Брассар и Бретли [14], Хоровиц и Сахни [105], Кнут [121, 122, 123], Манбер [142], Мельхорн [144, 145, 146], Пурдом и Браун [164], Рейнгольд, Нивергельт и Део [167], Седжвик [175], Уилф [201]. Практические аспекты разработки эффективных алгоритмов: Бентли [24,25], Гоннет [90].

В 1968 году Кнут опубликовал первый из трёх томов серии *Искусство программирования для ЭВМ* [121, 122, 123], который стал началом новой эпохи в науке об эффективных алгоритмах. Все три тома до сих пор остаются незаменимым справочником. Как пишет Кнут, слово *"алгоритм"* происходит от имени арабского математика девятого века Ал-Хорезми (al-Khowârizmî, или al-Khwârizmî).

Ахо, Хопкрофт и Ульман [4] указали на важность асимптотического анализа времени работы как средства сравнения эффективности алгоритмов. Они широко использовали рекуррентные соотношения для получения оценок времени работы.

Книга Кнута [123] содержит исчерпывающее изложение множества алгоритмов сортировки. Он сравнивает различные алгоритмы, точно подсчитывая число различных шагов (мы делали это для сортировки сравнением). Рассматриваются различные варианты сортировки вставками, включая сортировку Шелла (D. L. Shell), которая использует сортировку подпоследовательностей с постоянным шагом для уменьшения числа операций.

Сортировка слиянием также описана в книге Кнута, который указывает, что механическое устройство для слияния двух стопок перфокарт за один проход было изобретено в 1938 году. Повидимому, Джон фон Нейман (J. von Neumann), один из основателей информатики, написал программу сортировки слиянием для компьютера EDVAC в 1945 году.

I Математические основы анализа алгоритмов

Введение

В этой части собраны сведения из математики, которые используются при анализе алгоритмов. Мы советуем бегло просмотреть её и перейти к следующим главам, возвращаясь к просмотренному по мере надобности.

В главе 2 мы вводим понятия и обозначения, связанные с асимптотикой функций (Θ и др.), а также некоторые другие. Наша цель здесь не рассказать о чём-то новом, а просто согласовать обозначения и терминологию.

В главе 3 приводятся различные методы вычисления и оценки сумм (подробное изложение можно найти в любом учебнике математического анализа).

Глава 4 посвящена преобразованию рекуррентных соотношений в явные оценки. Мы формулируем и доказываем общее утверждение такого рода (теорема 4.1), которого в большинстве случаев оказывается достаточно. Его доказательство довольно длинно, но в дальнейшем не используется, так что при первом чтении его можно пропустить.

В главе 5 мы даём определения различных понятий, связанных с множествами, отношениями, функциями, графами и деревьями, и вводим соответствующие обозначения.

Глава 6 посвящена основным понятиям комбинаторики и теории вероятностей. Большая часть книги не использует этого материала, так что при первом чтении эту главу (особенно последние разделы) можно смело пропустить, возвращаясь к пропущенному по мере надобности.

2 Скорость роста функций

Сравнивая два алгоритма сортировки в главе 1, мы установили, что время работы одного (сортировка слиянием) примерно пропорционально n^2, а другого (сортировка вставками) — $n \lg n$. Каковы бы ни были коэффициенты пропорциональности, для достаточно больших n первый алгоритм работает быстрее.

Анализируя алгоритм, можно стараться найти точное число выполняемых им действий. Но в большинстве случаев игра не стоит свеч, и достаточно оценить **асимптотику** роста времени работы алгоритма при стремлении размера входа к бесконечности (asymptotic efficiency). Если у одного алгоритма скорость роста меньше, чем у другого, то в большинстве случаев он будет эффективнее для всех входов, кроме совсем коротких. (Хотя бывают и исключения.)

2.1 Асимптотические обозначения

Хотя во многих случаях эти обозначения используются неформально, полезно начать с точных определений.

Θ-обозначение

В главе 2 мы говорили, что время $T(n)$ работы алгоритма сортировки вставками на входах длины n есть $\Theta(n^2)$. Точный смысл этого утверждения такой: найдутся такие константы $c_1, c_2 > 0$ и такое число n_0, что $c_1 n^2 \leqslant T(n) \leqslant c_2 n^2$ при всех $n \geqslant n_0$. Вообще, если $g(n)$ — некоторая функция, то запись $f(n) = \Theta(g(n))$ означает, что найдутся такие $c_1, c_2 > 0$ и такое n_0, что $0 \leqslant c_1 g(n) \leqslant f(n) \leqslant c_2 g(n)$ для всех $n \geqslant n_0$ (см. рис. 2.1). (Запись $f(n) = \Theta(g(n))$ читается так: *"эф от эн есть тэта от же от эн"*.)

[!!!!!!!!! Рисунок 2.1 - подпись к нему:]

Иллюстрации к определениям $f(n) = \Theta(g(n))$, $f(n) = O(g(n))$ и $f(n) = \Omega(g(n))$.

Разумеется, это обозначение следует употреблять с осторожностью: установив, что $f_1(n) = \Theta(g(n))$ и $f_2(n) = \Theta(g(n))$, не следует заключать, что $f_1(n) = f_2(n)$!

Определение $\Theta(g(n))$ предполагает, что функции $f(n)$ и $g(n)$ **асимптотически неотрицательны**, т.е. неотрицательны для достаточно больших значений n. Заметим, что если функции f и g строго положительны, то можно исключить n_0 из определения (изменив константы c_1 и c_2 так, чтобы для малых n неравенство также выполнялось).

Если $f(n) = \Theta(g(n))$, то говорят, что $g(n)$ является **асимптотически точной** оценкой для $f(n)$. На самом деле это отношение симметрично: если $f(n) = \Theta(g(n))$, то $g(n) = \Theta(f(n))$.

Вернёмся к примеру из главы 1 и проверим, что $(1/2)n^2 - 3n = \Theta(n^2)$. Согласно определению, надо указать положительные константы c_1, c_2 и число n_0 так, чтобы неравенства

$$c_1 n^2 \leqslant \frac{1}{2}n^2 - 3n \leqslant c_2 n^2$$

выполнялись для всех $n \geqslant n_0$. Разделим на n^2:

$$c_1 \leqslant \frac{1}{2} - \frac{3}{n} \leqslant c_2$$

Видно, что выполнения второго неравенства достаточно положить $c_2 = 1/2$. Первое будет выполнено, если (например) $n_0 = 7$ и $c_1 = 1/14$.

Другой пример использования формального определения: покажем, что $6n^3 \neq \Theta(n^2)$. В самом деле, пусть найдутся такие c_2 и n_0, что $6n^3 \leqslant c_2 n^2$ для всех $n \geqslant n_0$. Но тогда $n \leqslant c_2/6$ для всех $n \geqslant n_0$ — что явно не так.

Отыскивая асимптотически точную оценку для суммы, мы можем отбрасывать члены меньшего порядка, которые при больших n становятся малыми по сравнению с основным слагаемым. Заметим также, что коэффициент при старшем члене роли не играет (он может повлиять только на выбор констант c_1 и c_2). Например, рассмотрим квадратичную функцию $f(n) = an^2 + bn + c$, где a, b, c — некоторые константы и $a > 0$. Отбрасывая члены младших порядков и коэффициент при старшем члене, находим, что $f(n) = \Theta(n^2)$. Чтобы убедиться в этом формально, можно положить $c_1 = a/4$, $c_2 = 7a/4$ и $n_0 = 2 \cdot \max((|b|/a), \sqrt{|c|/a})$ (проверьте, что требования действительно выполнены). Вообще, для любого полинома $p(n)$ степени d с положительным старшим коэффициентом имеем $p(n) = \Theta(n^d)$ (задача 2-1).

Упомянем важный частный случай использования Θ-обозначений: $\Theta(1)$ обозначает ограниченную функцию, отделённую от нуля некоторый положительной константой при достаточно больших значениях аргумента. (Из контекста обычно ясно, что именно считается аргументом функции.)

O- и Ω-обозначения

Запись $f(n) = \Theta(g(n))$ включает в себя две оценки: верхнюю и нижнюю. Их можно разделить. Говорят, что $f(n) = O(g(n))$, если найдётся такая константа $c > 0$ и такое число n_0, что $0 \leqslant f(n) \leqslant cg(n)$ для всех $n \geqslant n_0$ Говорят, что $f(n) = \Omega(g(n))$, если найдется такая константа $c > 0$ и такое число n_0, что $0 \leqslant cg(n) \leqslant f(n)$ для всех $n \geqslant n_0$. Эти записи читаются так: *"эф от эн есть о большое от же от эн"*, *"эф от эн есть оме́га большая от же от эн"*.

По-прежнему мы предполагаем, что функции f и g неотрицательны для достаточно больших значений аргумента. Легко видеть (упр. 2.1-5), что выполнены следующие свойства:

Теорема 2.1. *Для любых двух функций $f(n)$ и $g(n)$ свойство $f(n) = \Theta(g(n))$ выполнено тогда и только тогда, когда $f(n) = O(g(n))$ и $f(n) = \Omega(g(n))$.*

Для любых двух функций свойства $f(n) = O(g(n))$ и $g(n) = \Omega(f(n))$ равносильны.

Как мы видели, $an^2 + bn + c = \Theta(n^2)$ (при положительных a). Поэтому $an^2 + bn + c = O(n^2)$. Другой пример: при $a > 0$ можно написать $an + b = O(n^2)$ (положим $c = a + |b|$ и $n_0 = 1$). Заметим, что в этом случае $an + b \neq \Omega(n^2$ и $an + b \neq \Theta(n^2)$.

Асимптотические обозначения (Θ, O и Ω) часто употребляются внутри формул. Например, в главе 1 мы получили рекуррентное соотношение

$$T(n) = 2T(n/2) + \Theta(n)$$

для времени работы сортировки слиянием. Здесь $\Theta(n)$ обозначает некоторую функцию, про которую нам важно знать лишь, что она не меньше $c_1 n$ и не больше $c_2 n$ для некоторых положительных c_1 и c_2 и для всех достаточно больших n.

Часто асимптотические обозначения употребляются не вполне формально, хотя их подразумеваемый смысл обычно ясен из контекста. Например, мы можем написать выражение

$$\sum_{i=1}^{n} O(i)$$

имея в виду сумму $h(1) + h(2) + \ldots + h(n)$, где $h(i)$ — некоторая функция, для которой $h(i) = O(i)$. Легко видеть, что сама эта сумма как функция от n есть $O(n^2)$.

Типичный пример использования асимптотических обозначений — цепочка равенств наподобие $2n^2+3n+1 = 2n^2+\Theta(n) = \Theta(n^2)$. Второе из этих равенств ($2n^2+\Theta(n) = \Theta(n^2)$) понимается при этом так: какова бы ни была функция $h(n) = \Theta(n)$ в левой части, сумма $2n^2 + h(n)$ есть $\Theta(n^2)$.

o- и ω-обозначения

Запись $f(n) = O(g(n))$ означает, что с ростом n отношение $f(n)/g(n)$ остаётся ограниченным. Если к тому же

$$\lim_{n\to\infty} \frac{f(n)}{g(n)} = 0, \tag{2.1}$$

то мы пишем $f(n) = o(g(n))$ (читается *"эф от эн есть о малое от же от эн"*). Формально говоря, $f(n) = o(g(n))$, если для всякого положительного $\varepsilon > 0$ найдётся такое n_0, что $0 \leqslant f(n) \leqslant \varepsilon g(n)$ при всех $n \geqslant n_0$. (Тем самым запись $f(n) = o(g(n))$ предполагает, что $f(n)$ и $g(n)$ неотрицательны для достаточно больши́х n.)

Пример: $2n = o(n^2)$, но $2n^2 \neq o(n^2)$.

Аналогичным образом вводится ω-обозначение: говорят, что $f(n)$ есть $\omega(g(n))$ (*"эф от эн есть оме́га малая от же от эн"*), если для любого положительного c существует такое n_0, что $0 \leqslant cg(n) \leqslant f(n)$ при всех $n \geqslant n_0$. Другими словами, $f(n) = \omega(g(n))$ означает, что $g(n) = o(f(n))$.

Пример: $n^2/2 = \omega(n)$, но $n^2/2 \neq \omega(n^2)$.

Сравнение функций

Введённые нами определения обладают некоторыми свойствами транзитивности, рефлексивности и симметричности:

Транзитивность:

$f(n) = \Theta(g(n))$ и $g(n) = \Theta(h(n))$ влечёт $f(n) = \Theta(h(n))$,
$f(n) = O(g(n))$ и $g(n) = O(h(n))$ влечёт $f(n) = O(h(n))$,
$f(n) = \Omega(g(n))$ и $g(n) = \Omega(h(n))$ влечёт $f(n) = \Omega(h(n))$,
$f(n) = o(g(n))$ и $g(n) = o(h(n))$ влечёт $f(n) = o(h(n))$,
$f(n) = \omega(g(n))$ и $g(n) = \omega(h(n))$ влечёт $f(n) = \omega(h(n))$.

Рефлексивность:

$f(n) = \Theta(f(n))$, $\quad f(n) = O(f(n))$, $\quad f(n) = \Omega(f(n))$.

Симметричность:

$f(n) = \Theta(g(n))$ если и только если $g(n) = \Theta(f(n))$.

Обращение:

$f(n) = O(g(n))$ если и только если $g(n) = \Omega(f(n))$,
$f(n) = o(g(n))$ если и только если $g(n) = \omega(f(n))$.

Можно провести такую параллель: отношения между функциями f и g подобны отношениям между числами a и b:

$$\begin{array}{lcl} f(n) = O(g(n)) & \approx & a \leqslant b \\ f(n) = \Omega(g(n)) & \approx & a \geqslant b \\ f(n) = \Theta(g(n)) & \approx & a = b \\ f(n) = o(g(n)) & \approx & a < b \\ f(n) = \omega(g(n)) & \approx & a > b \end{array}$$

Параллель эта, впрочем, весьма условна: свойства числовых неравенств не переносятся на функции. Например, для любых двух чисел a и b всегда или $a \leqslant b$, или $a \geqslant b$, однако нельзя утверждать, что для любых двух (положительных) функций $f(n)$ и $g(n)$ или $f(n) = O(g(n))$, или $f(n) = \Omega(g(n))$. В самом деле, можно проверить, что ни одно из этих двух соотношений не выполнено для $f(n) = n$ и $g(n) = n^{1+\sin n}$ (показатель степени в выражении для $g(n)$ меняется в интервале от 0 до 2). Заметим ещё, что для чисел $a \leqslant b$ влечёт $a < b$ или $a = b$, в то время как для функций $f(n) = O(g(n))$ не влечёт $f(n) = o(g(n))$ или $f(n) = \Theta(g(n))$.

Упражнения

2.1-1 Пусть $f(n)$ и $g(n)$ неотрицательны для достаточно больших n. Покажите, что $\max(f(n), g(n)) = \Theta(f(n) + g(n))$.

2.1-2 Покажите, что

$$(n+a)^b = \Theta(n^b) \tag{2.2}$$

для любого вещественного a и для любого $b > 0$.

2.1-3 Почему утверждение *"время работы алгоритма A не меньше $O(n^2)$"* не имеет смысла?

2.1-4 Можно ли утверждать, что $2^{n+1} = O(2^n)$? Что $2^{2n} = O(2^n)$?

2.1-5 Докажите теорему 2.1.

2.1-6 Приведите пример функций $f(n)$ и $g(n)$, для которых $f(n) = O(g(n))$, но $f(n) \neq o(g(n))$ и $f(n) \neq \Theta(g(n))$.

2.1-7 Покажите, что свойства $f(n) = o(g(n))$ и $f(n) = \omega(g(n))$ не могут быть выполнены одновременно.

2.1-8 Асимптотические обозначения могут быть введены и для функций, зависящих от нескольких параметров. Говорят, что $f(m,n) = O(g(m,n))$, если найдутся n_0, m_0 и положительное c, для которых $0 \leqslant f(m,n) \leqslant cg(m,n)$ для всех $n \geqslant n_0$ и $m \geqslant m_0$. Дайте аналогичные определения для $\Theta(g(m,n))$ и $\Omega(g(m,n))$.

2.2 Стандартные функции и обозначения

Монотонность

Говорят, что функция $f(n)$ **монотонно возрастает** (is monotonically increasing), если $f(m) \leqslant f(n)$ при $m \leqslant n$. Говорят, что функция $f(n)$

монотонно убывает (is monotonically decreasing), если $f(m) \geqslant f(n)$ при $m \leqslant n$. Говорят, что функция $f(n)$ **строго возрастает** (is strictly increasing), если $f(m) < f(n)$ при $m < n$. Говорят, что функция $f(n)$ **строго убывает** (is strictly decreasing), если $f(m) > f(n)$ при $m < n$.

Целые приближения снизу и сверху

Для любого вещественного числа x через $\lfloor x \rfloor$ (the floor of x) мы обозначаем его целую часть, т.е. наибольшее целое число, не превосходящее x. Симметричным образом $\lceil x \rceil$ (the ceiling of x) обозначает наименьшее целое число, не меньшее x. Очевидно,

$$x - 1 < \lfloor x \rfloor \leqslant x \leqslant \lceil x \rceil < x + 1$$

для любого x. Кроме того,

$$\lceil n/2 \rceil + \lfloor n/2 \rfloor = n$$

для любого целого n. Наконец, для любого x и для любых целых положительных a и b имеем

$$\lceil \lceil x/a \rceil / b \rceil = \lceil x/ab \rceil \tag{2.3}$$

и

$$\lfloor \lfloor x/a \rfloor / b \rfloor = \lfloor x/ab \rfloor \tag{2.4}$$

(чтобы убедиться в этом, полезно заметить, что для любого z и для целого n свойства $n \leqslant z$ и $n \leqslant \lfloor z \rfloor$ равносильны).

Функции $x \mapsto \lfloor x \rfloor$ и $x \mapsto \lceil x \rceil$ монотонно возрастают.

Многочлены

Многочленом (полиномом) степени d от переменной n (polynomial in n of degree d) называют функцию

$$p(n) = \sum_{i=0}^{d} a_i n_i$$

(d — неотрицательное целое число). Числа $a_0, a_1, \ldots, a_d$ называют **коэффициентами** (coefficients) многочлена. Мы считаем, что **старший коэффициент** a_d не равен нулю (если это не так, уменьшим d — это можно сделать, если только многочлен не равен нулю тождественно).

Для больших значений n знак многочлена $p(n)$ определяется старшим коэффициентом (остальные члены малы по сравнению с ним), так что при $a_d > 0$ многочлен $p(n)$ асимптотически положителен (положителен при больши́х n) и можно написать $p(n) = \Theta(n^d)$.

При $a \geqslant 0$ функция $n \mapsto n^a$ монотонно возрастает, при $a \leqslant 0$ — монотонно убывает. Говорят, что функция $f(n)$ **полиномиально ограничена**, если $f(n) = n^{O(1)}$, или, другими словами, если $f(n) = O(n^k)$ для некоторой константы k (см. упр. 2.2-2).

Экспоненты

Для любых вещественных m, n и $a \neq 0$ имеем

$$\begin{aligned} a^0 &= 1, & (a^m)^n &= a^{mn}, \\ a^1 &= a, & (a^m)^n &= (a^n)^m, \\ a^{-1} &= 1/a, & a^m a^n &= a^{m+n}. \end{aligned}$$

При $a \geqslant 1$ функция $n \mapsto a^n$ монотонно возрастает.

Мы будем иногда условно полагать $0^0 = 1$.

Функция $n \mapsto a^n$ называется показательной функцией, или экспонентой (exponential). При $a > 1$ показательная функция растёт быстрее любого полинома: каково бы ни было b,

$$\lim_{n\to\infty} \frac{n^b}{a^n} = 0 \tag{2.5}$$

или, другими словами, $n^b = o(a^n)$. Если в качестве основания степени взять число $e = 2{,}71828\ldots$, то экспоненту можно записать в виде ряда

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \ldots = \sum_{k=0}^{\infty} \frac{x^k}{k!} \tag{2.6}$$

где $k! = 1 \cdot 2 \cdot 3 \cdot \ldots \cdot k$ (см. ниже о факториалах).

Для всех вещественных x выполнено неравенство

$$e^x \geqslant 1 + x \tag{2.7}$$

которое обращается в равенство лишь при $x = 0$. При $|x| \leqslant 1$ можно оценить e^x сверху и снизу так:

$$1 + x \leqslant e^x \leqslant 1 + x + x^2 \tag{2.8}$$

Можно сказать, что $e^x = 1 + x + \Theta(x^2)$ при $x \to 0$, имея в виду соответствующее истолкование обозначения Θ (в котором $n \to \infty$ заменено на $x \to 0$).

При всех x выполнено равенство $\lim_{n\to\infty} \left(1 + \frac{x}{n}\right)^n = e^x$.

Логарифмы

Мы будем использовать такие обозначения:

$$\begin{aligned} \lg n &= \log_2 n && \text{(двоичный логарифм)},\\ \ln n &= \log_e n && \text{(натуральный логарифм)},\\ \lg^k n &= (\lg n)^k, &&\\ \lg\lg n &= \lg(\lg n) && \text{(повторный логарифм)}. \end{aligned}$$

Мы будем считать, что в формулах знак логарифма относится лишь к непосредственно следующему за ним выражению, так что $\lg n + k$ есть $\lg(n)+k$ (а не $\lg(n+k)$). При $b>1$ функция $n \mapsto \log_b n$ (определённая при положительных n) строго возрастает.

Следующие тождества верны при всех $a>0$, $b>0$, $c>0$ и при всех n (если только основания логарифмов не равны 1):

$$\begin{aligned} a &= b^{\log_b a}, & \log_b(1/a) &= -\log_b a\\ \log_c(ab) &= \log_c a + \log_c b, & \log_b a &= \frac{1}{\log_a b}\\ \log_b a^n &= n\log_b a, & a^{\log_b c} &= c^{\log_b a}\\ \log_b a &= \frac{\log_c a}{\log_c b} \end{aligned} \tag{2.9}$$

Изменение основания у логарифма умножает его на константу, поэтому в записи типа $O(\log n)$ можно не уточнять, каково основание логарифма. Мы будем чаще всего иметь дело с двоичными логарифмами (они появляются, когда задача делится на две части) и потому оставляем за ними обозначение lg.

Для натурального логарифма есть ряд (который сходится при $|x|<1$):

$$\ln(1+x) = x - \frac{x^2}{2} + \frac{x^3}{3} - \frac{x^4}{4} + \frac{x^5}{5} - \ldots$$

При $x>-1$ справедливы неравенства

$$\frac{x}{1+x} \leqslant \ln(1+x) \leqslant x \tag{2.10}$$

которые обращаются в равенства лишь при $x=0$.

Говорят, что функция $f(n)$ **ограничена полилогарифмом** (is polylogaritmically bounded), если $f(n) = \lg^{O(1)} n$. Предел (2.5) после подстановок $n=\lg m$ и $a=2^c$ даёт

$$\lim_{m\to\infty} \frac{\lg^b m}{(2^c)^{\lg m}} = \lim_{m\to\infty} \frac{\lg^b m}{m^c} = 0$$

и, таким образом, $\lg^b n = o(n^c)$ для любой константы $c>0$. Другими словами, любой полином растёт быстрее любого полилогарифма.

Факториалы

Запись $n!$ (читается *"эн факториал"*, "n factorial") обозначает произведение всех чисел от 1 до n. Полагают $0! = 1$, так что $n! = n \cdot (n-1)!$ при всех $n = 1, 2, 3, \ldots$.

Сразу же видно, что $n! \leqslant n^n$ (каждый из сомножителей не больше n). Более точная оценка даётся **формулой Стирлинга** (Stirling's approximation), которая гласит, что

$$n! = \sqrt{2\pi n}\left(\frac{n}{e}\right)^n (1 + \Theta(1/n)) \qquad (2.11)$$

Из формулы Стирлинга следует, что

$$n! = o(n^n),$$
$$n! = \omega(2^n),$$
$$\lg(n!) = \Theta(n \lg n).$$

Справедлива также следующая оценка:

$$\sqrt{2\pi n}\left(\frac{n}{e}\right)^n \leqslant n! \leqslant \sqrt{2\pi n}\left(\frac{n}{e}\right)^n e^{1/12n}. \qquad (2.12)$$

Итерации логарифма

Мы используем обозначение $\log^* n$ (*"логарифм со звёздочкой от эн"*) для функции: называемой **итерированным логарифмом** (iterated logarithm). Эта функция определяется так. Вначале рассмотрим i-ую итерацию логарифма, функцию $\lg^{(i)}$, определённую так: $\lg^{(0)} n = n$ и $\lg^{(i)}(n) = \lg(\lg^{(i-1)} n)$ при $i > 0$. (Последнее выражение определено, если $\lg^{(i-1)} n$ определено и положительно.) Будьте внимательны: обозначения $\lg^i n$ и $\lg^{(i)} n$ внешне похожи, но означают совершенно разные функции.

Теперь $\lg^* n$ определяется как минимальное число $i \geqslant 0$, при котором $\lg^{(i)} n \leqslant 1$. Другими словами, $\lg^* n$ — это число раз, которое нужно применить функцию lg, чтобы из n получить число, не превосходящее 1.

Функция $\lg *n$ растёт исключительно медленно:

$$\lg^* 2 = 1,$$
$$\lg^* 4 = 2,$$
$$\lg^* 16 = 3,$$
$$\lg^* 65536 = 4,$$
$$\lg^* 2^{65536} = 5.$$

Поскольку число атомов в наблюдаемой части Вселенной оценивается как 10^{80}, что много меньше 2^{65536}, то значения n, для которых $\lg^* n > 5$, вряд ли могут встретиться.

Числа Фибоначчи

Последовательность **чисел Фибоначчи** (Fibonacci numbers) определяется рекуррентным соотношением:

$$F_0 = 0, \quad F_1 = 1, \quad F_i = F_{i-1} + F_{i-2} \text{ при } i \geqslant 2 \tag{2.13}$$

Другими словами, в последовательности Фибоначчи

$$0,\ 1,\ 1,\ 2,\ 3,\ 5,\ 8,\ 13,\ 21,\ 34,\ 55\ \ldots$$

каждое число равно сумме двух предыдущих. Числа Фибоначчи связаны с так называемым отношением **золотого сечения** (golden ratio) φ и с сопряжённым с ним числом $\hat{\varphi}$:

$$\begin{aligned} \varphi &= \frac{1+\sqrt{5}}{2} = 1{,}61803\ldots, \\ \hat{\varphi} &= \frac{1-\sqrt{5}}{2} = -0{,}61803\ldots \end{aligned} \tag{2.14}$$

Именно, имеет место формула

$$F_i = \frac{\varphi^i - \hat{\varphi}^i}{\sqrt{5}} \tag{2.15}$$

которую можно доказать по индукции (упр. 2.2-7). Поскольку $|\hat{\varphi}| < 1$, слагаемое $|\hat{\varphi}^i/\sqrt{5}|$ меньше $1/\sqrt{5} < 1/2$, так что F_i равно числу $\varphi^i/\sqrt{5}$, округлённому до ближайшего целого.

Число F_i быстро (экспоненциально) растёт с ростом i.

Упражнения

2.2-1 Покажите, что для монотонно возрастающих функций $f(n)$ и $g(n)$ функции $f(n) + g(n)$ и $f(g(n))$ будут также монотонно возрастать. Если к тому же $f(n)$ и $g(n)$ неотрицательны при всех n, то и функция $f(n)g(n)$ будет монотонно возрастать.

2.2-2 Покажите, что $T(n) = n^{O(1)}$ тогда и только тогда, когда существует положительное k, при котором $T(n) = O(n^k)$ (считаем, что $T(n) > 1$).

2.2-3 Докажите равенства (2.9).

2.2-4 Докажите, что $\lg(n!) = \Theta(n \lg n)$ и что $n! = o(n^n)$.

2.2-5* Будет ли функция $\lceil \lg n \rceil!$ полиномиально ограниченной? Будет ли функция $\lceil \lg \lg n \rceil!$ полиномиально ограниченной?

2.2-6* Что больше (при больших n): $\lg(\lg^* n)$ или $\lg^*(\lg n)$?

2.2-7 Докажите по индукции формулу (2.15).

2.2-8 Докажите такую оценку для чисел Фибоначчи: $F_{i+2} \geqslant \varphi^i$ при $i \geqslant 0$ (здесь φ — отношение золотого сечения).

Задачи

2-1 Асимптотика многочленов

Пусть $p(n) = a_0 + a_1 n + \ldots + a_d n^d$ — многочлен степени d, причём $a_d > 0$. Докажите, что

а. $p(n) = O(n^k)$ при $k \geqslant d$.
б. $p(n) = \Omega(n^k)$ при $k \leqslant d$.
в. $p(n) = \Theta(n^k)$ при $k = d$.
г. $p(n) = o(n^k)$ при $k > d$.
д. $p(n) = \omega(n^k)$ при $k < d$.

2-2 Сравнение асимптотик

Для всех клеток следующей таблицы ответьте *"да"* или *"нет"* на вопрос о том, можно ли записать A как O, o, Ω, ω или Θ от B ($k \geqslant 1$, $\varepsilon > 0$, $c > 1$ — некоторые константы).

	A	B	O	o	Ω	ω	Θ
а.	$\lg^k n$	n^ε					
б.	n^k	c^n					
в.	$\sqrt{n}$	$n^{\sin n}$					
г.	2^n	$2^{n/2}$					
д.	$n^{\lg m}$	$m^{\lg n}$					
е.	$\lg(n!)$	$\lg(n^n)$					

2-3 Сравнение скорости роста

а. Расположите следующие 30 функций в порядке увеличения скорости роста (каждая функция есть O(следующая)) и отметьте, какие из этих функций на самом деле имеют одинаковую скорость роста (одна есть Θ от другой):

$\lg(\lg^* n)$	$2^{\lg^* n}$	$(\sqrt{2})^{\lg n}$	n^2	$n!$	$(\lg n)!$
$(3/2)^n$	n^3	$\lg^2 n$	$\lg(n!)$	2^{2^n}	$n^{1/\lg n}$
$\ln \ln n$	$\lg^* n$	$n \cdot 2^n$	$n^{\lg \lg n}$	$\ln n$	1
$2^{\lg n}$	$(\lg n)^{\lg n}$	e^n	$4^{\lg n}$	$(n+1)!$	$\sqrt{\lg n}$
$\lg^* \lg n$	$2^{\sqrt{2 \lg n}}$	n	2^n	$n \lg n$	$2^{2^{n+1}}$

б. Укажите неотрицательную функцию $f(n)$, которая не сравнима ни с одной из функций g_i этой таблицы ($f(n)$ не есть $O(g_i(n))$ и $g_i(n)$ не есть $O(f(n))$).

2-4 Свойства асимптотических обозначений

Пусть функции $f(n)$ и $g(n)$ положительны при достаточно больших n. Можно ли утверждать, что

а. если $f(n) = O(g(n))$, то $g(n) = O(f(n))$?

б. $f(n) + g(n) = \Theta(\min(f(n), g(n)))$?

в. $f(n) = O(g(n))$ влечёт $\lg(f(n)) = O(\lg(g(n)))$, если $\lg(g(n)) > 0$ и $f(n) \geqslant 1$ для достаточно больших n?

г. $f(n) = O(g(n))$ влечёт $2^{f(n)} = O(2^{g(n)})$?

д. $f(n) = O((f(n))^2)$?

е. $f(n) = O(g(n))$ влечёт $g(n) = \Omega(f(n))$?

ж. $f(n) = \Theta(f(n/2))$?

з. $f(n) + o(f(n)) = \Theta(f(n))$?

2-5 Варианты асимптотических обозначений

В некоторых книгах Ω-обозначение используется в ином смысле. Мы будем использовать обозначение Ω^∞ для этого варианта, чтобы избежать путаницы. Пусть $f(n)$ и $g(n)$ — функции натурального аргумента. Говорят, что $f(n) = \Omega^\infty(g(n))$, если найдётся положительное число c, при котором $f(n) \geqslant cg(n) \geqslant 0$ для бесконечно многих натуральных n.

а. Покажите, что для любых двух функций $f(n)$ и $g(n)$, положительных при больших значениях n, выполнено либо $f(n) = O(g(n))$, либо $f(n) = \Omega^\infty(g(n))$, и что для нашего прежнего определения $\Omega(g(n))$ этого утверждать нельзя.

б. Каковы возможные достоинства и недостатки применения оценок вида Ω^∞ при исследовании времени работы алгоритмов?

Некоторые авторы в записи $f(n) = O(g(n))$ не требуют, чтобы функция $f(n)$ была асимптотически положительной. Будем использовать обозначение O' и скажем, что $f(n) = O'(g(n))$, если $|f(n)| = O(g(n))$.

в. Что происходит при таком определении с утверждениями теоремы 2.1?

Некоторые авторы используют ещё один вариант определения: будем говорить, что $f(n) = \tilde{O}(g(n))$, если найдутся положительные числа c и k, для которых $0 \leqslant f(n) \leqslant cg(n)\lg^k n$ для всех достаточно больших n.

г. Определите $\tilde{\Omega}$ и $\tilde{\Theta}$ аналогичным образом и докажите аналог теоремы 2.1.

2-6 Итерации

Мы итерировали логарифмическую функцию, но аналогичная операция возможна и для других функций. Пусть $f(n)$ — некоторая функция, причём $f(n) < n$. Определим $f^{(i)}(n)$, положив $f^{(0)}(n) = n$ и $f(i)(n) = f(f^{(i-1)}(n))$ при $i > 0$.

Для фиксированного числа c определим функцию $f_c^*(n)$ как минимальное $i \geqslant 0$, для которого $f^{(i)}(n) \leqslant c$. (Другими словами, f_c^* — это сколько раз нужно применять функцию f, чтобы из n получить число, не превосходящее c.) Заметим, что $f_c^*(n)$ определено далеко не всегда.

Для каждой из следующих функций $f(n)$ и значений c оцените f_c^* возможно точнее:

	$f(n)$	c	$f_c^*(n)$
а.	$\lg n$	1	
б.	$n-1$	0	
в.	$n/2$	1	
г.	$n/2$	2	
д.	$\sqrt{n}$	2	
е.	$\sqrt{n}$	1	
ж.	$n^{1/3}$	2	
з.	$n/\lg n$	2	

Замечания

Как считает Кнут [121], использование O-обозначений восходит к учебнику по теории чисел (P. Bachmann, 1892). Обозначение $o(g(n))$ было использовано Ландау (E. Landau) в 1909 году при обсуждении распределения простых чисел. Использование Ω- и Θ-обозначений рекомендовано Кнутом [124]: эти обозначения позволяют избежать технически некорректного употребления O-обозначений для нижних оценок (хотя многие люди продолжают так делать). Подробнее об асимптотических обозначениях см. Кнут [121, 124] и Брассар и Бретли [33].

Одни и те же обозначения порой используются в различных смыслах, хотя разница, как правило, оказывается несущественной. В частности, иногда сравниваемые функции не предполагаются неотрицательными при больших n (и сравниваются модули).

Существует много справочников, содержащих сведения об элементарных функциях: Абрамович и Стегун [1], Бейер [27]. Можно также взять любой учебник по анализу (см., например, Апостол [12] или Томас и Финни [192]). Книга Кнута [121] содержит много полезных математических сведений, используемых при анализе алгоритмов.

3 Суммирование

Если алгоритм содержит цикл (for, while), то время его работы является суммой времён отдельных шагов. Например, как мы знаем из раздела 1.2, выполнение j-го шага алгоритма сортировки вставками требует времени, пропорционального j. Поэтому общее время будет определяться суммой

$$\sum_{j=1}^{n} j,$$

которая есть $\Theta(n^2)$. Подобного рода суммы нам не раз встретятся (в частности, в главе 4 при анализе рекуррентных соотношений).

В разделе 3.1 перечислены основные свойства сумм. Некоторые из этих свойств доказываются в разделе 3.2; большинство пропущенных доказательств можно найти в учебниках по математическому анализу.

3.1 Суммы и их свойства

Для суммы $a_1 + a_2 + \ldots + a_n$ используют обозначение

$$\sum_{k=1}^{n} a_k.$$

При $n = 0$ значение суммы считается равным 0.

Как правило, нижний и верхний пределы суммирования — целые числа. (Если это не так, обычно подразумеваются целые части.)

В конечных суммах слагаемые можно произвольно переставлять.

В курсах анализа определяют сумму бесконечного **ряда** (series) $a_1 + a_2 + a_3 + \ldots$ или

$$\sum_{k=1}^{\infty} a_k$$

как предел последовательности частичных сумм

$$\lim_{n\to\infty}\sum_{k=1}^{n} a_k.$$

Если предела не существует, говорят, что ряд **расходится** (diverges); в противном случае он **сходится**. Если ряд $\sum_{k=1}^{\infty}|a_k|$ сходится, то ряд $\sum_{k=1}^{\infty}a_k$ называют **абсолютно сходящимся** (absolutely convergent series); всякий абсолютно сходящийся ряд сходится, но не наоборот. При перестановке членов абсолютно сходящегося ряда он остаётся абсолютно сходящимся и его сумма не меняется.

Линейность

Свойство линейности гласит, что

$$\sum_{k=1}^{n}(ca_k+b_k)=c\sum_{k=1}^{n}a_k+\sum_{k=1}^{n}b_k$$

для любого числа c и для любых конечных последовательностей $a_1,\ldots,a_n$ и $b_1,\ldots,b_n$. Почленно складывать и умножать на числа можно не только конечные суммы, но и сходящиеся бесконечные ряды.

Арифметические прогрессии

Сумма

$$\sum_{k=1}^{n}k=1+2+\ldots+n,$$

которая возникла при анализе алгоритма сортировки вставками, является **арифметической прогрессией** (arithmetic series). Её значение равно

$$\sum_{k=1}^{n}k=\frac{1}{2}n(n+1)= \tag{3.1}$$

$$=\Theta(n^2). \tag{3.2}$$

Геометрические прогрессии

При $x\neq 1$ сумму **геометрической прогрессии** (geometric или exponential series)

$$\sum_{k=0}^{n}x^k=1+x+x^2+\ldots+x^n$$

можно найти по формуле

$$\sum_{k=0}^{n} x^k = \frac{x^{n+1}-1}{x-1}. \tag{3.3}$$

Сумма бесконечно убывающей геометрической прогрессии (при $|x| < 1$) даётся формулой

$$\sum_{k=0}^{\infty} x^k = \frac{1}{1-x}. \tag{3.4}$$

Гармонический ряд

имеет вид $1+1/2+1/3+\ldots+1/n+\ldots$; его n-ая частичная сумма (nth harmonic number) равна

$$H_n = 1+\frac{1}{2}+\frac{1}{3}+\ldots+\frac{1}{n} = \sum_{k=1}^{n}\frac{1}{k} = \ln n + O(1). \tag{3.5}$$

Почленное интегрирование и дифференцирование

Дифференцируя или интегрируя обе части известного тождества, можно получить новое. Например, дифференцируя тождество (3.4) и умножая результат на x, получаем

$$\sum_{k=0}^{\infty} kx^k = \frac{x}{(1-x)^2}. \tag{3.6}$$

Суммы разностей

Для любой последовательности $a_0, a_1, \ldots, a_n$ можно записать тождество

$$\sum_{k=1}^{n}(a_k - a_{k-1}) = a_n - a_0 \tag{3.7}$$

(все промежуточные члены сокращаются). Такие суммы по-английски называют telescoping series. Аналогично,

$$\sum_{k=0}^{n-1}(a_k - a_{k+1}) = a_0 - a_n.$$

Этот приём позволяет просуммировать ряд $\sum_{k=1}^{n-1}\frac{1}{k(k+1)}$. Поскольку $\frac{1}{k(k+1)} = \frac{1}{k} - \frac{1}{k+1}$, получаем, что

$$\sum_{k=1}^{n-1}\frac{1}{k(k+1)} = \sum_{k=1}^{n-1}\left(\frac{1}{k}-\frac{1}{k+1}\right) = 1-\frac{1}{n}.$$

Произведения

Произведение чисел $a_1, \ldots, a_n$ записывают как

$$\prod_{k=1}^{n} a_k.$$

При $n = 0$ значение defnпроизведения (product) считается равным 1. Логарифмирование превращает произведение в сумму:

$$\lg \prod_{k=1}^{n} a_k = \sum_{k=1}^{n} \lg a_k.$$

Упражнения

3.1-1 Вычислите $\sum_{k=1}^{n}(2k-1)$.

3.1-2* Покажите, используя формулу для частичных сумм гармонического ряда, что $\sum_{k=1}^{n} 1/(2k-1) = \ln(\sqrt{n}) + O(1)$.

3.1-3* Покажите, что $\sum_{k=0}^{\infty}(k-1)/2^k = 0$.

3.1-4* Вычислите сумму $\sum_{k=1}^{\infty}(2k+1)x^{2k}$.

3.1-5 Используя линейность суммы, сформулируйте и докажите утверждение о возможности перестановки асимптотического O-обозначения и суммирования.

3.1-6 Используя линейность суммы, сформулируйте и докажите утверждение о возможности перестановки асимптотического Ω-обозначения и суммирования.

3.1-7 Вычислите произведение $\prod_{k=1}^{n} 2 \cdot 4^k$.

3.1-8* Вычислите произведение $\prod_{k=2}^{n}(1-1/k^2)$.

3.2 Оценки сумм

Рассмотрим несколько приёмов, которые позволяют найти значение суммы (или хотя бы оценить эту сумму сверху или снизу).

Индукция

Если удалось угадать формулу для суммы, её легко проверить с помощью математической индукции. Пример: докажем, что сумма арифметической прогрессии $S_n = \sum_{k=1}^{n} k$ равна $n(n+1)/2$. При $n = 1$ это верно. Теперь предположим, что равенство $S_n = n(n+1)/2$ верно при некотором n и проверим его для $n+1$. В самом деле,

$$\sum_{k=1}^{n+1} k = \sum_{k=1}^{n} k + (n+1) = n(n+1)/2 + (n+1) = (n+1)(n+2)/2.$$

Индукцию можно использовать и для неравенств. Например, покажем, что сумма геометрической прогрессии $\sum_{k=0}^{n} 3^k$ есть $O(3^n)$. Точнее, мы покажем, что $\sum_{k=0}^{n} 3^k \leqslant c \cdot 3^n$ для некоторой константы c (которую мы выберем позднее). При $n = 0$ имеем $\sum_{k=0}^{0} 3^k = 1 \leqslant c \cdot 1$; это верно при $c \geqslant 1$. Предполагая справедливость оценки при некотором n, докажем её для $n+1$. Имеем:

$$\sum_{k=0}^{n+1} 3^k = \sum_{k=0}^{n} 3^k + 3^{n+1} \leqslant c3^n + 3^{n+1} = \left(\frac{1}{3} + \frac{1}{c}\right) c3^{n+1} \leqslant c3^{n+1}.$$

Последний переход законен, если $(1/3 + 1/c) \leqslant 1$, т.е. если $c \geqslant 3/2$. Поэтому $\sum_{k=0}^{n} 3^k = O(3^n)$, что и требовалось доказать.

Индукцией следует пользоваться аккуратно, особенно при доказательстве асимптотических оценок, поскольку тут легко ошибиться. Для примера *"докажем"*, что $\sum_{k=1}^{n} k = O(n)$. Очевидно, $\sum_{k=1}^{1} k = O(1)$. Предполагая справедливость оценки при некотором n, докажем её для следующего значения n. В самом деле,

$$\sum_{k=1}^{n+1} k = \sum_{k=1}^{n} k + (n+1) = O(n) + (n+1) \overset{\text{[неверно!]}}{=} O(n+1).$$

Ошибка в том, что константа, подразумеваемая в обозначении $O(n)$, растёт вместе с n.

Почленные сравнения

Иногда можно получить верхнюю оценку для суммы, заменив каждый её член на больший (например, на наибольший из членов суммы). Так, простейшей оценкой сверху для суммы арифметической прогрессии $\sum_{k=1}^{n} k$ будет

$$\sum_{k=1}^{n} k \leqslant \sum_{k=1}^{n} n = n^2.$$

В общем случае

$$\sum_{k=1}^{n} a_k \leqslant n a_{\max},$$

где $a_{\max}$ — наибольшее из $a_1, \ldots, a_n$.

В некоторых случаях можно применить более точный метод — сравнение с геометрической прогрессией. Допустим, дан ряд $\sum_{k=0}^{n} a_k$ с положительными членами, для которого $a_{k+1}/a_k \leqslant r$ при всех $k \geqslant 0$ и некотором $r < 1$. Тогда $a_k \leqslant a_0 r^k$, и сумма может быть ограничена сверху бесконечной убывающей геометрической прогрессией:

$$\sum_{k=0}^{n} a_k \leqslant \sum_{k=0}^{\infty} a_0 r^k = a_0 \sum_{k=0}^{\infty} r^k = a_0 \frac{1}{1-r}.$$

Применим этот метод для суммы $\sum_{k=1}^{\infty} k3^{-k}$. Первый член равен $1/3$, отношение соседних членов равно

$$\frac{(k+1)3^{-(k+1)}}{k3^{-k}} = \frac{1}{3} \cdot \frac{k+1}{k} \leqslant \frac{2}{3}$$

для всех $k \geqslant 1$. Следовательно, каждый член суммы оценивается сверху величиной $(1/3)(2/3)^k$, так что

$$\sum_{k=1}^{\infty} k3^{-k} \leqslant \sum_{k=1}^{\infty} \frac{1}{3} \cdot \left(\frac{2}{3}\right)^k = \frac{1}{3} \cdot \frac{1}{1-\frac{2}{3}} = 1.$$

Важно, что отношение соседних членов не просто меньше 1, а ограничено некоторой константой $r < 1$, общей для всех членов ряда. Например, для гармонического ряда отношение $(k+1)$-го и k-го членов равно $\frac{k}{k+1} < 1$. Тем не менее

$$\sum_{k=1}^{\infty} \frac{1}{k} = \lim_{n\to\infty} \sum_{k=1}^{n} \frac{1}{k} = \lim_{n\to\infty} \Theta(\lg n) = \infty.$$

Здесь не существует константы r, отделяющей отношения соседних членов от единицы.

Разбиение на части

Можно разбить сумму на части и оценивать каждую часть по отдельности. В качестве примера получим нижнюю оценку для суммы арифметической прогрессии $\sum_{k=1}^{n} k$. Если мы оценим снизу каждый член единицей, то получим оценку $\sum_{k=1}^{n} k \geqslant n$. Разница с верхней оценкой $O(n^2)$ слишком велика, поэтому поступим по-другому:

$$\sum_{k=1}^{n} k = \sum_{k=1}^{n/2} k + \sum_{k=n/2+1}^{n} k \geqslant \sum_{k=1}^{n/2} 0 + \sum_{k=n/2+1}^{n} \frac{n}{2} = \left(\frac{n}{2}\right)^2.$$

Эта оценка уже асимптотически точна (отличается от верхней оценки, и тем самым от истинного значения, не более чем в константу раз).

Иногда полезно отбросить несколько первых членов последовательности, записав (для фиксированного k_0)

$$\sum_{k=0}^{n} a_k = \sum_{k=0}^{k_0} a_k + \sum_{k=k_0+1}^{n} a_k = \Theta(1) + \sum_{k=k_0+1}^{n} a_k.$$

Например, для ряда

$$\sum_{k=0}^{\infty} \frac{k^2}{2^k}$$

отношение последовательных членов

$$\frac{(k+1)^2/2^{k+1}}{k^2/2^k} = \frac{(k+1)^2}{2k^2}$$

не всегда меньше 1. Поэтому, чтобы применить метод сравнения с геометрической прогрессией, выделим три первых члена ряда. Для всех следующих членов ($k \geqslant 3$) отношение не превосходит $8/9$, поэтому

$$\sum_{k=0}^{\infty} \frac{k^2}{2^k} = \sum_{k=0}^{2} \frac{k^2}{2^k} + \sum_{k=3}^{\infty} \frac{k^2}{2^k} \leqslant O(1) + \frac{9}{8} \sum_{k=0}^{\infty} \left(\frac{8}{9}\right)^k = O(1),$$

поскольку вторая сумма — бесконечно убывающая геометрическая прогрессия.

Разбиение ряда на части бывает полезно и в более сложных ситуациях. Оценим, например, частичные суммы гармонического ряда $H_n = \sum_{k=1}^{n} \frac{1}{k}$. Для этого разобьем отрезок от 1 до n на $\lfloor \lg n \rfloor$ частей $1 + (1/2 + 1/3) + (1/4 + 1/5 + 1/6 + 1/7) + \ldots$. Каждая часть не превосходит 1 (заменим все слагаемые в ней на первое из них), всего частей $\lfloor \lg n \rfloor + 1$ (последняя может быть неполной). Получаем, что

$$1 + 1/2 + 1/3 + \ldots + 1/n \leqslant \lg n + 1. \tag{3.8}$$

Сравнение с интегралами

Для монотонно возрастающей функции f мы можем заключить сумму $\sum_{k=m}^{n} f(k)$ между двумя интегралами:

$$\int\limits_{m-1}^{n} f(x)\,dx \leqslant \sum_{k=m}^{n} f(k) \leqslant \int\limits_{m}^{n+1} f(x)\,dx. \tag{3.9}$$

Рисунок 3.1 Сравнение суммы $\sum_{k=m}^{n} f(k)$ с интегралами. Внутри каждого прямоугольника записана его площадь. Общая площадь всех прямоугольников равна значению суммы. Значение интеграла равно площади закрашенной фигуры под кривой. (а) Сравнивая площади, получаем $\int_{m-1}^{n} f(x)\,dx \leqslant \sum_{k=m}^{n} f(k)$. (б) Сдвигая прямоугольники на единицу вправо, видим, что $\sum_{k=m}^{n} f(k) \leqslant \int_{m}^{n+1} f(x)\,dx$.

В самом деле, как видно из рис. 3.1, сумма (площадь всех прямоугольников) содержит одну закрашенную область (верхний рисунок) и содержится в другой (нижний рисунок). Аналогичное неравенство можно написать для монотонно убывающей функции f:

$$\int_{m}^{n+1} f(x)\,dx \leqslant \sum_{k=m}^{n} f(k) \leqslant \int_{m-1}^{n} f(x)\,dx. \tag{3.10}$$

Этим методом можно получить хорошие оценки для частичных сумм гармонического ряда: нижнюю оценку

$$\sum_{k=1}^{n} \frac{1}{k} \geqslant \int_{1}^{n+1} \frac{dx}{x} = \ln(n+1) \tag{3.11}$$

и верхнюю оценку (для ряда без первого члена)

$$\sum_{k=2}^{n} \frac{1}{k} \leqslant \int_{1}^{n} \frac{dx}{x} = \ln n,$$

откуда

$$\sum_{k=1}^{n} \frac{1}{k} \leqslant \ln n + 1. \tag{3.12}$$

Упражнения

3.2-1 Покажите, что сумма $\sum_{k=1}^{n} \frac{1}{k^2}$ ограничена сверху константой (не зависящей от n).

3.2-2 Найдите асимптотическую верхнюю оценку для суммы

$$\sum_{k=0}^{\lfloor \lg n \rfloor} \lceil n/2^k \rceil.$$

3.2-3 Разбивая сумму на части, покажите, что n-я частичная сумма гармонического ряда есть $\Omega(\lg n)$.

3.2-4 Заключите сумму $\sum_{k=1}^{n} k^3$ между двумя интегралами.

3.2-5 Почему при получении верхней оценки для частичной суммы гармонического ряда мы отбросили первый член и только потом применили оценку (3.10)?

Задачи

3-1 Оценки для сумм

Найдите асимптотически точные оценки для следующих сумм (считая $r \geqslant 0$ и $s \geqslant 0$ константами):

а. $\sum_{k=1}^{n} k^r$.

б. $\sum_{k=1}^{n} \lg^s k$.

в. $\sum_{k=1}^{n} k^r \lg^s k$.

Замечания

Книга Кнута [121] — прекрасный справочник по материалу этой главы. Основные свойства рядов можно найти в любом учебнике по математическому анализу (авторы отсылают англоязычного читателя к книгам [12] и [192]).

4 Рекуррентные соотношения

Оценивая время работы рекурсивной процедуры, мы часто приходим к соотношению, которое оценивает это время через время работы той же процедуры на входных данных меньшего размера. Такого рода соотношения называются **рекуррентными** (recurrences). Например, как мы видели в главе 1, время работы процедуры Merge-Sort описывается соотношением

$$T(n) = \begin{cases} \Theta(1), & \text{если } n = 1, \\ 2T(n/2) + \Theta(n), & \text{если } n > 1. \end{cases} \tag{4.1}$$

из которого вытекает (как мы увидим), что $T(n) = \Theta(n \lg n)$.

В этой главе предлагаются три способа, позволяющие решить рекуррентное соотношение, т.е. найти асимптотическую ("Θ" или "O") оценку для его решений. Во-первых, можно угадать оценку, а затем доказать её по индукции, подставляя угаданную формулу в правую часть соотношения (**метод подстановки**, substitution method). Во-вторых, можно *"развернуть"* рекуррентную формулу, получив при этом сумму, которую можно затем оценивать (**метод итераций**, iteration method). Наконец, мы приводим общий результат о рекуррентных соотношениях вида

$$T(n) = aT(n/b) + f(n),$$

где $a \geqslant 1$, $b > 1$ — некоторые константы, а $f(n)$ — заданная функция. Соответствующий результат мы будет называть **основной теоремой о рекуррентных соотношениях** (master theorem). Формулировка этой теоремы довольно длинна, зато во многих случаях она сразу приводит к ответу.

Технические детали

Формулируя и доказывая утверждения про рекуррентные соотношения, мы будем опускать некоторые технические подробности. Например, в приведённой выше формуле для процедуры Merge-Sort должны стоять целые части ($T(n)$ определено лишь при целых n):

$$T(n) = \begin{cases} \Theta(1), & \text{если } n = 1, \\ T(\lceil n/2 \rceil) + T(\lfloor n/2 \rfloor) + \Theta(n), & \text{если } n > 1. \end{cases} \tag{4.2}$$

Кроме того, обычно мы будем опускать начальные условия, имея в виду, что $T(n) = \Theta(1)$ для небольших n. Таким образом, соотношение (4.1) запишется в виде

$$T(n) = 2T(n/2) + \Theta(n). \tag{4.3}$$

Это позволительно, так как начальное условие (значение $T(1)$) влияет только на постоянный множитель, но не на порядок роста функции $T(n)$.

Такое небрежное обращение с деталями, конечно, требует осторожности, чтобы не упустить (пусть редких) случаев, в которых подобные детали влияют на результат. В этой главе мы разберём несколько примеров, показывающих, как восполнить пропущенные детали (см. доказательство теоремы 4.1 и задачу 4.5).

4.1 Метод подстановки

Идея проста: отгадать ответ и доказать его по индукции. Часто ответ содержит коэффициенты, которые надо выбрать так, чтобы рассуждение по индукции проходило.

Индуктивный метод применим и к нижним, и к верхним оценкам. В качестве примера найдём верхнюю оценку для функции, заданной соотношением

$$T(n) = 2T(\lfloor n/2 \rfloor) + n, \tag{4.4}$$

которое аналогично (4.2) и (4.3). Можно предположить, что $T(n) = O(n \lg n)$, т.е. что $T(n) \leqslant cn \lg n$ для подходящего $c > 0$. Будем доказывать это по индукции. Пусть эта оценка верна для $\lfloor n/2 \rfloor$, т.е. $T(\lfloor n/2 \rfloor) \leqslant c \lfloor n/2 \rfloor \lg(\lfloor n/2 \rfloor)$. Подставив её в соотношение, получим

$$\begin{aligned} T(n) &\leqslant 2(c\lfloor n/2 \rfloor \lg(\lfloor n/2 \rfloor)) + n \leqslant \\ &\leqslant cn \lg(n/2) + n = cn \lg n - cn \lg 2 + n = cn \lg n - cn + n \leqslant \\ &\leqslant cn \lg n. \end{aligned}$$

Последний переход законен при $c \geqslant 1$.

Для завершения рассуждения остаётся проверить базис индукции, т.е. доказать оценку для начального значения n. Тут мы сталкиваемся с тем, что при $n = 1$ правая часть неравенства обращается в нуль, каким бы ни взять c (поскольку $\lg 1 = 0$). Приходится вспомнить, что асимптотическую оценку достаточно доказать для всех n, начиная с некоторого. Подберём c так, чтобы оценка $T(n) \leqslant cn \lg n$ была верна при $n = 2$ и $n = 3$. Тогда для больших n можно рассуждать по индукции, и опасный случай $n = 1$ нам не встретится (поскольку $\lfloor n/2 \rfloor \geqslant 2$ при $n > 3$).

Как отгадать оценку?

Для этого нужен навык и немного везения. Вот несколько наводящих соображений.

Аналогия. Рассмотрим для примера соотношение

$$T(n) = 2T(\lfloor n/2 \rfloor + 17) + n.$$

которое отличается от (4.4) добавочным слагаемым 17 в правой части. Можно ожидать, однако, что эта добавка не может существенно изменить характер решения: при больших n разница между $\lfloor n/2 \rfloor + 17$ и $\lfloor n/2 \rfloor$ вряд ли так уж существенна. Можно предположить, что оценка $T(n) = O(n \lg n)$ остаётся в силе, а затем и доказать это по индукции (см. упр. 4.1-5).

Последовательные приближения. Можно начать с простых и грубых оценок, а затем уточнять их. Например, для соотношения (4.1) есть очевидная нижняя оценка $T(n) = \Omega(n)$ (поскольку справа есть член n), и верхняя оценка $T(n) = O(n^2)$ (которую легко доказать по индукции). Далее можно постепенно сближать их, стремясь получить асимптотически точные нижнюю и верхнюю оценки, отличающиеся не более чем в константу раз.

Тонкости

Иногда рассуждение по индукции сталкивается с трудностями, хотя ответ угадан правильно. Обычно это происходит потому, что доказываемое по индукции утверждение недостаточно сильно. В этом случае может помочь вычитание члена меньшего порядка.

Рассмотрим соотношение

$$T(n) = T(\lfloor n/2 \rfloor) + T(\lceil n/2 \rceil) + 1.$$

Можно надеяться, что в этом случае $T(n) = O(n)$. Это действительно так. Попробуем, однако, доказать, что $T(n) \leqslant cn$ при подходящем выборе константы c. Индуктивное предположение даёт

$$T(n) \leqslant c\lfloor n/2 \rfloor + c\lceil n/2 \rceil + 1 = cn + 1,$$

а отсюда ни для какого c не вытекает неравенства $T(n) \leqslant cn$. В такой ситуации можно попытаться доказать более слабую оценку, например $O(n^2)$, но на самом деле в этом нет необходимости: наша догадка верна, надо только не ослабить, а усилить предположение индукции.

Новая гипотеза выглядит так: $T(n) \leqslant cn - b$ для некоторых констант b и c. Подстановка в правую часть даёт

$$T(n) \leqslant (c\lfloor n/2\rfloor - b) + (c\lceil n/2\rceil - b) + 1 = cn - 2b + 1 \leqslant cn - b$$

Последний переход законен при $b \geqslant 1$. Остаётся лишь выбрать константу c с учётом начальных условий.

Это рассуждение вызывает недоумение: если доказательство не проходит, не следует ли ослабить (увеличить) оценку, а не усиливать её? Но на самом деле ничего странного здесь нет — усилив оценку, мы получаем возможность воспользоваться более сильным индуктивным предположением.

Как делать не надо

Асимптотическая запись опасна при неумелом применении: вот пример неправильного *"доказательства"* оценки $T(n) = O(n)$ для соотношения (4.4). Предположим, что $T(n) \leqslant cn$, тогда можно записать

$$T(n) \leqslant 2(c\lfloor n/2\rfloor) + n \leqslant cn + n = O(n).$$

Это рассуждение, однако, ничего не доказывает, так как индуктивный переход требует, чтобы в правой части было cn с той же самой константой c, а не абстрактное $O(n)$.

Замена переменных

Часто несложная замена переменных позволяет преобразовать рекуррентное соотношение к привычному виду. Например, соотношение

$$T(n) = 2T(\lfloor\sqrt{n}\rfloor) + \ln n$$

кажется довольно сложным, однако заменой переменных его легко упростить. Сделав замену $m = \lg n$, получим

$$T(2^m) = 2T(2^{m/2}) + m.$$

Обозначив $T(2^m)$ через $S(m)$, приходим к соотношению

$$S(m) = 2S(m/2) + m,$$

которое уже встречалось (4.4). Его решение: $S(m) = O(m \lg m)$. Возвращаясь к $T(n)$ вместо $S(m)$, получим

$$T(n) = T(2^m) = S(m) = O(m \lg m) = O(\lg n \lg\lg n).$$

Приведённое рассуждение требует, конечно, уточнений, поскольку пока что мы доказали оценку на $T(n)$ лишь для n, являющихся степенями двойки. Чтобы выйти из положения, можно определить $S(m)$ как максимум $T(n)$ по всем n, не превосходящим 2^m.

Упражнения

4.1-1 Покажите, что из $T(n) = T(\lceil n/2 \rceil) + 1$ следует, что $T(n) = O(\lg n)$.

4.1-2 Покажите, что из $T(n) = 2T(\lfloor n/2 \rfloor) + n$ вытекает $T(n) = \Omega(n \lg n)$, и тем самым $T(n) = \Theta(n \lg n)$.

4.1-3 Как обойти трудность с начальным значением $n = 1$ при исследовании соотношения (4.4), изменив доказываемое по индукции утверждение, но не меняя начального значения?

4.1-4 Покажите, что соотношение (4.2) для сортировки слиянием имеет решением $\Theta(n \lg n)$.

4.1-5 Покажите, что $T(n) = 2T(\lfloor n/2 \rfloor + 17) + n$ влечёт $T(n) = O(n \lg n)$.

4.1-6 Решите с помощью замены переменных соотношение $T(n) = 2T(\sqrt{n}) + 1$, (опуская подробности, связанные с тем, что значения переменных — не целые).

4.2 Преобразование в сумму

Как быть, если не удается угадать решение? Тогда можно, итерируя это соотношение (подставляя его само в себя), получить ряд, который можно оценивать тем или иным способом.

Для примера рассмотрим соотношение

$$T(n) = 3T(\lfloor n/4 \rfloor) + n.$$

Подставляя его в себя, получим:

$$\begin{aligned} T(n) &= n + 3T(\lfloor n/4 \rfloor) = n + 3(\lfloor n/4 \rfloor + 3T(\lfloor n/16 \rfloor)) \\ &= n + 3(\lfloor n/4 \rfloor + 3(\lfloor n/16 \rfloor + 3T(\lfloor n/64 \rfloor))) \\ &= n + 3\lfloor n/4 \rfloor + 9\lfloor n/16 \rfloor + 27T(\lfloor n/64 \rfloor), \end{aligned}$$

Мы воспользовались тем, что, согласно (2.4), $\lfloor \lfloor n/4 \rfloor /4 \rfloor = \lfloor n/16 \rfloor$ и $\lfloor \lfloor n/16 \rfloor /4 \rfloor = \lfloor n/64 \rfloor$. Сколько шагов надо сделать, чтобы дойти до начального условия? Поскольку после i-ой итерации справа окажется $T(\lfloor n/4^i \rfloor)$, мы дойдём до $T(1)$, когда $\lfloor n/4^i \rfloor = 1$, т.е. когда $i \geqslant \log_4 n$. Заметив, что $\lfloor n/4^i \rfloor \leqslant n/4^i$, мы можем оценить наш ряд убывающей геометрической прогрессией (плюс последний член, соответствующий $3^{\log_4 n}$ задачам ограниченного размера):

$$\begin{aligned} T(n) &\leqslant n + 3n/4 + 9n/16 + 27n/64 + \ldots + 3^{\log_4 n}\Theta(1) \\ &\leqslant n \sum_{i=0}^{\infty} \left(\frac{3}{4}\right)^i + \Theta(n^{\log_4 3}) \\ &= 4n + o(n) = O(n) \end{aligned}$$

(Мы заменили конечную сумму из не более чем $\log_4 n + 1$ членов на сумму бесконечного ряда, а также переписали $3^{\log_4 n}$ как $n^{\log_4 3}$, что есть $o(n)$, так как $\log_4 3 < 1$.)

Часто преобразование рекуррентного соотношения в сумму приводит к довольно сложным выкладкам. При этом важно следить за двумя вещами: сколько шагов подстановки требуется и какова сумма членов, получающихся на данном шаге. Иногда несколько первых шагов позволяют отгадать ответ, который затем удаётся доказать по индукции (с меньшим количеством вычислений).

Особенно много хлопот доставляют округления (переход к целой части). Для начала стоит предположить, что значения параметра таковы, что округления не требуются (в нашем примере при $n = 4^k$ ничего округлять не придётся). Вообще говоря, такое предположение не вполне законно, так как оценку надо доказать для всех достаточно больших целых чисел, а не только для степеней четвёрки. Мы увидим в разделе 4.3, как можно обойти эту трудность (см. также задачу 4-5).

Деревья рекурсии

Процесс подстановки соотношения в себя можно изобразить в виде **дерева рекурсии** (recursion tree). Как это делается, показано на рис. 4.1 на примере соотношения

$$T(n) = 2T(n/2) + n^2.$$

Для удобства предположим, что n — степень двойки. Двигаясь от (а) к (г), мы постепенно разворачиваем выражение для $T(n)$, используя выражения для $T(n)$, $T(n/2)$, $T(n/4)$ и т.д. Теперь мы можем вычислить $T(n)$, складывая значения вершин на каждом уровне. На верхнем уровне получаем n^2, на втором — $(n/2)^2 + (n/2)^2 = n^2/2$, на третьем — $(n/4)^2+(n/4)^2+(n/4)^2+(n/4)^2 = n^2/4$. Получается убывающая геометрическая прогрессия, сумма которой отличается от её первого члена не более чем на постоянный множитель. Итак, $T(n) = \Theta(n^2)$.

На рис. 4.2 показан более сложный пример — дерево для соотношения

$$T(n) = T(n/3) + T(2n/3) + n$$

Total=всего

Рисунок 4.1 Дерево рекурсии для соотношения $T(n) = 2T(n/2) + n^2$. Высота полностью развернутого дерева (г) равна $\lg n$ (дерево имеет $\lg n + 1$ уровней).

Рисунок 4.2 Дерево рекурсии для соотношения $T(n) = T(n/3) + T(2n/3) + n$.

(для простоты мы вновь игнорируем округления). Здесь сумма значений на каждом уровне равна n. Дерево обрывается, когда значения аргумента становятся сравнимыми с 1. Для разных ветвей это происходит на разной глубине, и самый длинный путь $n \to (2/3)n \to (2/3)^2 n \to \cdots \to 1$ требует около $k = \log_{3/2} n$ шагов (при таком k мы имеем $(2/3)^k n = 1$). Поэтому $T(n)$ можно оценить как $O(n \lg n)$.

Упражнения

4.2-1 Итерируя (подставляя в себя) соотношение $T(n) = 3T(\lfloor n/2 \rfloor) + n$, найдите хорошую верхнюю асимптотическую оценку для $T(n)$.

4.2-2 Анализируя дерево рекурсии, покажите, что $T(n) = T(n/3) + T(2n/3) + n$ влечёт $T(n) = \Omega(n \lg n)$.

4.2-3 Нарисуйте дерево рекурсии для $T(n) = 4T(\lfloor n/2 \rfloor) + n$ и получите асимптотически точные оценки для $T(n)$.

4.2-4 С помощью итераций решите соотношение $T(n) = T(n - a) + T(a) + n$, где $a \geqslant 1$ — некоторая константа.

4.2-5 С помощью дерева рекурсии решите соотношение $T(n) = T(\alpha n) + T((1-\alpha)n) + n$, где α — константа в интервале $0 < \alpha < 1$.

4.3 Общий рецепт

Этот метод годится для рекуррентных соотношений вида

$$T(n) = aT(n/b) + f(n), \tag{4.5}$$

где $a \geqslant 1$ и $b > 1$ — некоторые константы, а f — положительная (по крайней мере для больших значений аргумента) функция. Он даёт общую формулу; запомнив её, можно решать в уме различные рекуррентные соотношения.

Соотношение (4.5) возникает, если алгоритм разбивает задачу размера n на a подзадач размера n/b, эти подзадачи решаются рекурсивно (каждая за время $T(n/b)$) и результаты объединяются. При этом затраты на разбиение и объединение описываются функцией $f(n)$ (в обозначениях раздела 1.3.2 $f(n) = C(n) + D(n)$). Например, для процедуры Merge-Sort мы имеем $a = 2$, $b = 2$, $f(n) = \Theta(n)$.

Как всегда, в формуле (4.5) возникает проблема с округлением: n/b может не быть целым. Формально следовало бы заменить

$T(n/b)$ на $T(\lfloor n/b \rfloor)$ или $T(\lceil n/b \rceil)$. Оба варианта, как мы увидим в следующем разделе, приводят к одному и тому же ответу, и для простоты мы будем опускать округление в наших формулах.

Основная теорема о рекуррентных оценках

Теорема 4.1. *Пусть $a \geqslant 1$ и $b > 1$ — константы, $f(n)$ — функция, $T(n)$ определено при неотрицательных n формулой*

$$T(n) = aT(n/b) + f(n),$$

где под n/b понимается либо $\lceil n/b \rceil$, либо $\lfloor n/b \rfloor$. Тогда:

1. Если $f(n) = O(n^{\log_b a - \varepsilon})$ для некоторого $\varepsilon > 0$, то $T(n) = \Theta(n^{\log_b a})$.

2. Если $f(n) = \Theta(n^{\log_b a})$, то $T(n) = \Theta(n^{\log_b a} \lg n)$.

3. Если $f(n) = \Omega(n^{\log_b a + \varepsilon})$ для некоторого $\varepsilon > 0$ и если $af(n/b) \leqslant cf(n)$ для некоторой константы $c < 1$ и достаточно больших n, то $T(n) = \Theta(f(n))$.

В чём суть этой теоремы? В каждом из трёх случаев мы сравниваем $f(n)$ с $n^{\log_b a}$; если одна из этих функций растёт быстрее другой, то она и определяет порядок роста $T(n)$ (случаи 1 и 3). Если обе функции одного порядка (случай 2), то появляется дополнительный логарифмический множитель и ответом служит формула $\Theta(n^{\log_b a} \lg n) = \Theta(f(n) \lg n)$.

Отметим важные технические детали. В первом случае недостаточно, чтобы $f(n)$ была просто меньше, чем $n^{\log_b a}$: нам нужен *"зазор"* размера n^{ε} для некоторого $\varepsilon > 0$. Точно так же в третьем случае $f(n)$ должна быть больше $n^{\log_b a}$ с запасом, и к тому же удовлетворять условию *"регулярности"* $af(n/b) \leqslant cf(n)$; проверка последнего условия, как правило, не составляет труда.

Заметим, что три указанных случая не исчерпывают всех возможностей: может оказаться, например, что функция $f(n)$ меньше, чем $n^{\log_b a}$, но зазор недостаточно велик для того, чтобы воспользоваться первым утверждением теоремы. Аналогичная *"щель"* есть и между случаями 2 и 3. Наконец, функция может не обладать свойством регулярности.

Применения основной теоремы

Рассмотрим несколько примеров, где применение теоремы позволяет сразу же выписать ответ.

Для начала рассмотрим соотношение

$$T(n) = 9T(n/3) + n.$$

В этом случае $a = 9$, $b = 3$, $f(n) = n$, а $n^{\log_b a} = n^{\log_3 9} = \Theta(n^2)$.

Поскольку $f(n) = O(n^{\log_3 9-\varepsilon})$ для $\varepsilon = 1$, мы применяем первое утверждение теоремы и заключаем, что $T(n) = \Theta(n^2)$.

Теперь рассмотрим соотношение

$$T(n) = T(2n/3) + 1.$$

Здесь $a = 1$, $b = 3/2$, $f(n) = 1$ и $n^{\log_b a} = n^{\log_{3/2} 1} = n^0 = 1$. Подходит случай 2, поскольку $f(n) = \Theta(n^{\log_b a}) = \Theta(1)$, и мы получаем, что $T(n) = \Theta(\lg n)$.

Для соотношения

$$T(n) = 3T(n/4) + n\lg n$$

мы имеем $a = 3$, $b = 4$, $f(n) = n\lg n$; при этом $n^{\log_b a} = n^{\log_4 3} = O(n^{0{,}793})$. Зазор (с $\varepsilon \approx 0{,}2$) есть, остаётся проверить условие регулярности. Для достаточно большого n имеем $af(n/b) = 3(n/4)\lg(n/4) \leqslant (3/4)n\lg n = cf(n)$ для $c = 3/4$. Тем самым по третьему утверждению теоремы $T(n) = \Theta(n\lg n)$.

Вот пример, когда теорему применить не удаётся: пусть $T(n) = 2T(n/2) + n\lg n$. Здесь $a = 2$, $b = 2$, $f(n) = n\lg n$, $n^{\log_b a} = n$. Видно, что $f(n) = n\lg n$ асимптотически больше, чем $n^{\log_b a}$, но зазор недостаточен: отношение $f(n)/n^{\log_b a} = (n\lg n)/n = \lg n$ не оценивается снизу величиной n^ε ни для какого $\varepsilon > 0$. Это соотношение попадает в промежуток между случаями 2 и 3; для него можно получить ответ по формуле из упр. 4.4-2.

Упражнения

4.3-1 Используя основную теорему, найдите асимптотически точные оценки для соотношения

а. $T(n) = 4T(n/2) + n$;
б. $T(n) = 4T(n/2) + n^2$;
в. $T(n) = 4T(n/2) + n^3$.

4.3-2 Время работы алгоритма A описывается соотношением $T(n) = 7T(n/2)+n^2$, а время работы алгоритма A' — соотношением $T'(n) = aT'(n/4)+n^2$. При каком наибольшем целом значении a алгоритм A' асимптотически быстрее, чем A?

4.3-3 Используя основную теорему, покажите, что соотношение $T(n) = T(n/2) + \Theta(1)$ (для двоичного поиска, см. упр. 1.3-5) влечёт $T(n) = \Theta(\lg n)$.

4.3-4 Покажите, что условия регулярности (случай 3) не вытекает из других условий: приведите пример функции f, для которой существует требуемая константа ε, но условие регулярности не выполнено.

⋆ 4.4 Доказательство Теоремы 4.1

Мы приведём доказательство теоремы 4.1 для дотошных читателей; в дальнейшем оно не понадобится, так что при первом чтении его вполне можно пропустить.

Доказательство состоит из двух частей. Сначала мы рассматриваем только те n, которые являются степенями числа b; все основные идеи видны уже для этого случая. Затем полученный результат распространяется на все натуральные числа, при этом мы аккуратно следим за округлениями и т. п.

В этом разделе мы позволим себе не совсем корректно обращаться с асимптотической записью: будем использовать её для функций, определённых только на степенях числа b, хотя определение требует, чтобы оценки доказывались для всех достаточно больших натуральных чисел.

Из контекста будет понятно, что имеется в виду, но нужно быть внимательным, чтобы не запутаться: если о функции $T(n)$ ничего не известно, то оценка $T(n) = O(n)$ для n, являющихся степенями двойки, ничего не гарантирует для произвольных n. (Возможно, что $T(n) = n$ при $n = 1, 2, 4, 8, \ldots$ и $T(n) = n^2$ при остальных n.)

4.4.1 Случай натуральных степеней

Пусть $T(n)$ определено для чисел, являющихся (натуральными) степенями числа $b > 1$ (не обязательно целого) и удовлетворяет соотношению (4.5), т.е.

$$T(n) = aT(n/b) + f(n).$$

Мы получим оценку для T так: перейдём от этого соотношения к суммированию (лемма 4.2), затем оценим полученную сумму (лемма 4.3) и подведём итоги (лемма 4.4).

Лемма 4.2. *Пусть $a \geqslant 1$, $b > 1$ — константы, и пусть $f(n)$ — неотрицательная функция, определённая на степенях b. Пусть $T(n)$ — функция, определённая на степенях b соотношением $T(n) = aT(n/b) + f(n)$ при $n > 1$, причём $T(1) > 0$. Тогда*

$$T(n) = \Theta(n^{\log_b a}) + \sum_{j=0}^{\log_b n-1} a^j f(n/b^j). \qquad (4.6)$$

Рисунок 4.3 Дерево рекурсии для соотношения $T(n) = aT(n/b) + f(n)$ является полным a-ичным деревом высоты $\log_b n$ с $n^{\log_b a}$. Сумма весов по уровням показана справа, а общая сумма даётся формулой (4.6).

Доказательство. Последовательно подставляя соотношение само в себя, получаем

$$\begin{aligned} T(n) &= f(n) + aT(n/b) \\ &= f(n) + af(n/b) + a^2T(n/b^2) \\ &= f(n) + af(n/b) + a^2f(n/b^2) + \ldots \\ &\quad + a^{\log_b n-1}f(n/b^{\log_b n-1}) + a^{\log_b n}T(1). \end{aligned}$$

Поскольку $a^{\log_b n} = n^{\log_b a}$, последний член может быть записан как $\Theta(n^{\log_b a})$. Оставшиеся члены образуют сумму, фигурирующую в утверждении леммы. □

Дерево рекурсии

Доказательство леммы 4.2 можно пояснить в терминах дерева рекурсии (рис. 4.3), если число a целое (хотя само доказательство этого не требует). В корне стоит число $f(n)$, в каждом из a его детей стоит число $f(n/b)$, в каждом из a^2 внуков стоит $f(n/b^2)$ и т. д. На уровне j имеется a^j вершин; вес каждой — $f(n/b^j)$. Листья находятся на расстоянии $\log_b n$ от корня, и имеют положительный вес $T(1)$; всего на дереве $a^{\log_b n} = n^{\log_b a}$ листьев.

Равенство (4.6) получается, если сложить веса на всех уровнях: общий вес на j-м уровне есть $a^j f(n/b^j)$, а общий вес внутренней части дерева есть

$$\sum_{j=0}^{\log_b n-1} a^j f(n/b^j).$$

Если рекуррентное соотношение произошло из алгоритма типа *"разделяй и властвуй"*, эта сумма отражает стоимость разбиения задачи на подзадачи и объединения решений. Суммарный вес всех листьев есть стоимость решения всех $n^{\log_b a}$ задач размера 1, которая составляет $\Theta(n^{\log_b a})$.

В терминах дерева рекурсии легко объяснить, чему соответствуют три случая в формулировке основной теоремы. В первом случае основная часть веса сосредоточена в листьях, в третьем — в корне, во втором вес равномерно распределён по уровням дерева.

Теперь оценим величину суммы в формуле (4.6).

Лемма 4.3. *Пусть $a \geqslant 1$, $b > 1$ — константы, $f(n)$ — неотрицательная функция, определённая на натуральных степенях b. Рассмотрим функцию $g(n)$, определённую формулой*

$$g(n) = \sum_{j=0}^{\log_b n-1} a^j f(n/b^j) \tag{4.7}$$

(для n, являющихся степенями b). Тогда

1. Если $f(n) = O(n^{\log_b a-\varepsilon})$ для некоторой константы $\varepsilon > 0$, то $g(n) = O(n^{\log_b a})$.

2. Если $f(n) = \Theta(n^{\log_b a})$, то $g(n) = \Theta(n^{\log_b a} \lg n)$.

3. Если $af(n/b) \leqslant cf(n)$ для некоторой константы $c < 1$ и для всех $n \geqslant b$, то $g(n) = \Theta(f(n))$.

Доказательство. 1. В первом случае достаточно доказать утверждение леммы для функции $f(n) = n^\alpha$, где $\alpha = \log_b a - \varepsilon$ Для такой функции f равенство (4.7) может быть переписано так: (теперь $\alpha = \log_b a$)

$$\begin{aligned} g(n) &= f(n) + af(n/b) + a^2 f(n/b^2) + \ldots + a^{k-1} f(n/b^{k-1}) \\ &= n^\alpha + a(n/b)^\alpha + a^2(n/b^2)^\alpha + \ldots + a^{k-1}(n/b^{k-1})^\alpha; \end{aligned} \tag{4.8}$$

правая часть представляет собой геометрическую прогрессию длины $k = \log_b n$ со знаменателем a/b^α; этот знаменатель больше 1, так как $\alpha < \log_b a$ и $b^\alpha < a$. Для такой прогресии сумма по порядку равна последнему члену (отличается от него не более чем на константу раз). Этот последний член есть $O(a^k) = O(n^{\log_b a})$.

Для первого случая утверждение леммы доказано.

2. Во втором случае аналогичное рассуждение даёт сумму того же вида:

$$\begin{aligned} g(n) &= f(n) + af(n/b) + a^2 f(n/b^2) + \ldots \\ &= n^\alpha + a(n/b)^\alpha + a^2(n/b^2)^\alpha + \ldots, \end{aligned} \tag{4.9}$$

но теперь $\alpha = \log_b a$ и потому знаменатель геометрической прогрессии равен 1 и все её члены равны. Их число есть $\log_b n$, и потому сумма равна

$$n^{\log_b a} \log_b n = \Theta(n^{\log_b a} \lg n).$$

Случай 2 разобран.

3. В этом случае условие регулярности функции f гарантирует, что в нашей сумме каждый следующий член не превосходит предыдущего, умноженного на $c < 1$. Тем самым её можно оценить сверху убывающей геометрической прогрессией со знаменателем c, и сумма такой прогрессии не более чем в константу (равную $1/(1-c)$) раз превосходит первый член (но и не меньше его, так как все слагаемые неотрицательны). Таким образом, $g(n) = \Theta(f(n))$ для n, являющихся степенями b. Доказательство леммы завершено. □

Теперь мы можем доказать основную теорему о рекуррентных оценках для случая, когда n есть натуральная степень b.

Лемма 4.4. *Пусть $a \geqslant 1$, $b > 1$ — константы, и пусть $f(n)$ — неотрицательная функция, определённая на степенях b. Пусть $T(n)$ — функция, определённая на степенях b соотношением $T(n) = aT(n/b) + f(n)$ при $n > 1$ и $T(1) > 0$. Тогда:*

1. Если $f(n) = O(n^{\log_b a - \varepsilon})$ для некоторого $\varepsilon > 0$, то $T(n) = \Theta(n^{\log_b a})$.

2. Если $f(n) = \Theta(n^{\log_b a})$, то $T(n) = \Theta(n^{\log_b a}) \lg n$.

3. Если $f(n) = \Omega(n^{\log_b a + \varepsilon})$ для некоторого $\varepsilon > 0$ и если $af(n/b) \leqslant cf(n)$ для некоторой константы $c < 1$ и для достаточно больших n, то $T(n) = \Theta(f(n))$.

??????? Как убрать точку в конце слова Доказательство?

Доказательство. состоит в комбинации лемм 4.2 и 4.3. В первом случае получаем

$$T(n) = \Theta(n^{\log_b a}) + O(n^{\log_b a}) = \Theta(n^{\log_b a}).$$

Во втором случае имеем

$$T(n) = \Theta(n^{\log_b a}) + \Theta(n^{\log_b a} \lg n) = \Theta(n^{\log_b a} \lg n).$$

В третьем случае

$$T(n) = \Theta(n^{\log_b a}) + \Theta(f(n)) = \Theta(f(n)).$$

Заметим, что в последнем случае условие "$f(n) = \Omega(n^{\log_b a+\varepsilon})$ *для некоторого* $\varepsilon > 0$" можно было бы опустить, так как оно вытекает из условия регулярности (см. упр. 4.4-3). □

Лемма 4.4 доказана.

4.4.2 Целые приближения сверху и снизу

Нам осталось разобраться подробно с произвольными n, не являющимися степенями числа b. В этом случае n/b подлежит округлению и соотношение имеет вид

$$T(n) = aT(\lceil n/b \rceil) + f(n) \tag{4.10}$$

или

$$T(n) = aT(\lfloor n/b \rfloor) + f(n). \tag{4.11}$$

Надо убедиться, что оценка остаётся в силе и для этого случая.

Посмотрим, какие изменения надо внести в наши рассуждения. Вместо последовательности $n, n/b, n/b^2, \ldots$ теперь надо рассматривать последовательность n_i, определённую так:

$$n_i = \begin{cases} n, & \text{если } i = 0, \\ \lceil n_{i-1}/b \rceil, & \text{если } i > 0. \end{cases} \tag{4.12}$$

(мы рассматриваем случай округления с избытком). Эта последовательность — убывающая, но не обязательно стремится к единице. Однако мы можем утверждать, что после $\log_b n$ итераций получится число, ограниченное не зависящей от n (хотя зависящей от b) константой.

В самом деле, из неравенства $\lceil x \rceil \leqslant x + 1$ следует, что

$$\begin{aligned} &n_0 \leqslant n, \\ &n_1 \leqslant \frac{n}{b} + 1, \\ &n_2 \leqslant \frac{n}{b^2} + \frac{1}{b} + 1, \\ &n_3 \leqslant \frac{n}{b^3} + \frac{1}{b^2} + \frac{1}{b} + 1, \\ &\ldots\ldots\ldots\ldots\ldots\ldots\ldots \end{aligned}$$

Поскольку $1 + 1/b + 1/b^2 + \ldots \leqslant 1/(b-1)$, для $i = \lfloor \log_b n \rfloor$ мы получаем $n_i \leqslant n/b^i + b/(b-1) \leqslant b + b/(b-1) = O(1)$.

Итерируя соотношение (4.10), мы получаем

$$\begin{aligned}
T(n) &= f(n_0) + aT(n_1) \\
&= f(n_0) + af(n_1) + a^2 T(n_2) \\
&\leqslant f(n_0) + af(n_1) + a^2 f(n_2) + \ldots + \\
&\quad + a^{\lfloor \log_b n \rfloor - 1} f(n_{\lfloor \log_b n \rfloor - 1}) + a^{\lfloor \log_b n \rfloor} T(n_{\lfloor \log_b n \rfloor}) \\
&= \Theta(n^{\log_b a}) + \sum_{j=0}^{\lfloor \log_b n \rfloor - 1} a^j f(n_j). \qquad (4.13)
\end{aligned}$$

Это выражение очень похоже на (4.6), только здесь n не обязано быть степенью числа b.

[Строго говоря, сказанное требует некоторых уточнений. Дело в том, что величина $T(n_{\lceil \log bn \rceil})$ может оказаться равной нулю. Но мы знаем, что $f(n)$ асимптотически положительна, т.е. положительна для всех n, начиная с некоторого n_0. Поэтому в развёртывании суммы нужно остановиться, немного не дойдя до этого n_0. Мы опускаем подробности.]

Теперь надо разобраться с соотношениями между слагаемыми в сумме

$$g(n) = \sum_{j=0}^{\lfloor \log_b n \rfloor - 1} a^j f(n_j). \qquad (4.14)$$

Раньше мы сравнивали эту сумму с геометрической прогрессией, в которой знаменатель был больше единицы (первый случай), равен единице (второй случай) или меньше единицы (третий случай). Третий случай не вызывает дополнительных проблем, так как в условии регулярности также предусматривается округление (причём в ту же сторону, что и в рекуррентном соотношении). Во втором случае мы должны оценить, насколько велики изменения вследствие замены n/b^i на n_i. Как мы видели, разница не превосходит $b/(b-1)$, но надо ещё от абсолютной ошибки перейти к относительной. Нам надо проверить, что $f(n_j) = O(n^{\log_b a}/a^j) = O((n/b^j)^{\log_b a})$, тогда проходит доказательство леммы 4.3 (случай 2). Заметим, что $b^j/n \leqslant 1$ при $j \leqslant \lfloor \log_b n \rfloor$. Из оценки $f(n) = O(n^{\log_b a})$ вытекает, что для подходящего c и достаточно больших n_j

$$\begin{aligned}
f(n_j) &\leqslant c\left(\frac{n}{b^j}+\frac{b}{b-1}\right)^{\log_b a}\\
&= c\left(\frac{n^{\log_b a}}{a^j}\right)\left(1+\left(\frac{b^j}{n}\cdot\frac{b}{b-1}\right)\right)^{\log_b a}\\
&\leqslant c\left(\frac{n^{\log_b a}}{a^j}\right)\left(1+\frac{b}{b-1}\right)^{\log_b a}\\
&= O\left(\frac{n^{\log_b a}}{a^j}\right).
\end{aligned}$$

Последний переход использует то, что $c(1+b/(b-1))^{\log_b a}$ — константа. Итак, случай 2 разобран.

Рассуждение для случая 1 почти такое же. Там нужно доказать оценку $f(n_j) = O(n^{\log_b a-\varepsilon})$; а это делается примерно так же, как и в случае 2, хотя преобразования будут несколько сложнее.

Итак, мы рассмотрели случай произвольного n для округления с избытком. Аналогично можно рассмотреть случай округления с недостатком, при этом нужно будет доказывать, что n_j не может быть сильно меньше n/b^j.

Упражнения

4.4-1* Укажите простую явную формулу для n_i из (4.12), если b — положительное целое число.

4.4-2* Покажите, что если $f(n) = \Theta(n^{\log_b a}\lg^k n)$, где $k \geqslant 0$, то соотношение (4.5) влечёт $T(n) = \Theta(n^{\log_b a}\lg^{k+1} n)$. Для простоты рассмотрите лишь случай целых степеней b.

4.4-3* Покажите, что в случае 3 основной теоремы одно из условий лишнее: условие регулярности ($af(n/b) \leqslant cf(n)$ для некоторого $c < 1$) гарантирует, что существует $\varepsilon > 0$, для которого $f(n) = \Omega(n^{\log_b a+\varepsilon})$.

Задачи

4-1 Примеры рекуррентных соотношений

Дайте как можно более точные асимптотические верхние и нижние оценки для следующих соотношений (считаем, что $T(n)$ — константа при $n \leqslant 2$):

а. $T(n) = 2T(n/2) + n^3$.

б. $T(n) = T(9n/10) + n$.

в. $T(n) = 16T(n/4) + n^2$.
г. $T(n) = 7T(n/3) + n^2$.
д. $T(n) = 7T(n/2) + n^2$.
е. $T(n) = 2T(n/4) + \sqrt{n}$.
ж. $T(n) = T(n-1) + n$.
з. $T(n) = T(\sqrt{n}) + 1$.

4-2 Недостающее число

Массив $A[1\,..\,n]$ содержит все целые числа от 0 до n, кроме одного. Чтобы найти пропущенное число, можно отмечать во вспомогательном массиве $B[0\,..\,n]$ все числа, встречающиеся в A, и затем посмотреть, какое число не отмечено (всё вместе требует времени $O(n)$). При этом использование элемента массива A в качестве индекса считается элементарной операцией.

Наложим такое дополнительное ограничение на доступ к массиву A: за одно действие мы можем посмотреть заданный бит заданного элемента массива A.

Покажите, что и при таких ограничениях мы можем найти пропущенное число за время $O(n)$.

4-3 Время передачи параметров

В этой книге мы предполагаем, что передача параметров занимает постоянное время, даже если передаваемый параметр — массив. В большинстве языков программирования это так и есть, поскольку передаётся не сам массив, а указатель на него. Но возможны и другие варианты. Сравним три способа передачи массивов в качестве параметров:

1. Массив передается как указатель за время $\Theta(1)$.

2. Массив копируется за время $\Theta(N)$, где N — размер массива.

3. В процедуру передаётся только та часть массива, которая будет в ней использоваться. При этом требуется время $\Theta(q-p+1)$, если передаётся участок $A[p\,..\,q]$.

а. Рассмотрим рекурсивный алгоритм двоичного поиска числа в упорядоченном массиве (упр. 1.3-5). Каково будет время его работы при каждом из указанных способов передачи параметра? (Аргументами рекурсивной процедуры являются искомый элемент и массив, в котором осуществляется поиск.)

б. Проведите такой анализ для алгоритма Merge-Sort из раздела 1.3.1.

4-4 Ещё несколько рекуррентных соотношений

Укажите возможно более точные асимптотические верхние и нижние оценки для $T(n)$ в каждом из указанных ниже примеров. Предполагается, что $T(n)$ — константа при $n \leqslant 8$.

а. $T(n) = 3T(n/2) + n \lg n$.

б. $T(n) = 3T(n/3 + 5) + n/2$.
в. $T(n) = 2T(n/2) + n/\lg n$.
г. $T(n) = T(n-1) + 1/n$.
д. $T(n) = T(n-1) + \lg n$.
е. $T(n) = \sqrt{n}T(\sqrt{n}) + n$.

4-5 Переход от степеней к произвольным аргументам

Пусть мы получили оценку для $T(n)$ при всех n, являющихся степенями некоторого целого b. Как распространить её на произвольные n?

а. Пусть $T(n)$ и $h(n)$ — монотонно возрастающие функции, определённые для произвольных положительных аргументов (не обязательно целых), причём $T(n) \leqslant h(n)$ для всех n, являющихся степенями целого числа $b > 1$. Пусть известно, кроме того, что h *"растёт достаточно медленно"*: $h(n) = O(h(n/b))$. Докажите, что $T(n) = O(h(n))$.

б. Пусть для функции T выполнено соотношение $T(n) = aT(n/b) + f(n)$ при $n > n_0$; пусть $a \geqslant 1$, $b > 1$ и $f(n)$ монотонно возрастает. Пусть $T(n)$ монотонно возрастает при $n \leqslant n_0$, и при этом $T(n_0) \leqslant aT(n_0/b) + f(n_0)$. Докажите, что $T(n)$ монотонно возрастает.

в. Упростите доказательство теоремы 4.1 для случая монотонной и *"достаточно медленно растущей"* функции $f(n)$. Воспользуйтесь леммой 4.4.

4-6 Числа Фибоначчи

Числа Фибоначчи определяются соотношением (2.13). Здесь мы рассмотрим некоторые их свойства. Для этого определим **производящую функцию** (generating function), определяемую как **формальный степенной ряд** (formal power series)

$$\mathcal{F} = \sum_{i=0}^{\infty} F_i z^i = 0 + z + z^2 + 2z^3 + 3z^4 + 5z^5 + 8z^6 + 13z^7 + \ldots$$

а. Покажите, что $\mathcal{F}(z) = z + z\mathcal{F}(z) + z^2\mathcal{F}(z)$.

б. Покажите, что

$$\mathcal{F}(z) = \frac{z}{1 - z - z^2} = \frac{z}{(1-\varphi z)(1-\widehat{\varphi} z)} = \frac{1}{\sqrt{5}}\left(\frac{1}{1-\varphi z} - \frac{1}{1-\widehat{\varphi} z}\right)$$

где

$$\varphi = \frac{1+\sqrt{5}}{2} = 1{,}61803\ldots$$

и

$$\widehat{\varphi} = \frac{1-\sqrt{5}}{2} = -0{,}61803\ldots$$

в. Покажите, что

$$\mathcal{F}(z) = \sum_{i=0}^{\infty} \frac{1}{\sqrt{5}}(\varphi^i - \widehat{\varphi}^i)z^i.$$

г. Докажите, что F_i при $i > 0$ равно ближайшему к $\varphi^i/\sqrt{5}$ целому числу. (Указание: $|\widehat{\varphi}| < 1$.)

д. Докажите, что $F_{i+2} \geqslant \varphi^i$ для всех $i \geqslant 0$.

4-7 Тестирование микросхем

Имеется n одинаковых микросхем, способных проверять друг друга; некоторые из них исправны, некоторые — нет. Для проверки пара микросхем вставляется в специальную плату, после чего каждая из них сообщает о состоянии соседа. Исправная микросхема при этом никогда не ошибается, а неисправная может дать любой ответ.

Ответ A	Ответ B	Результат
B исправна	A исправна	обе хорошие или обе плохие
B исправна	A неисправна	хотя бы одна неисправна
B неисправна	A исправна	хотя бы одна неисправна
B неисправна	A неисправна	хотя бы одна неисправна

а. Покажите, что если больше половины микросхем плохие, то попарное тестирование не позволит узнать наверняка, какие именно микросхемы плохи (они смогут нас обмануть).

б. Пусть нужно найти хотя бы одну хорошую микросхему из n штук, из которых больше половины исправных. Покажите, что достаточно $\lfloor n/2 \rfloor$ попарных тестов, чтобы свести задачу к аналогичной задаче половинного размера.

в. Пусть исправно больше половины микросхем. Покажите, что можно найти все хорошие микросхемы за $\Theta(n)$ попарных тестов. (Воспользуйтесь рекуррентным соотношением.)

[Эту задачу можно переформулировать в иных терминах: имеется n одинаковых на вид предметов, но на самом деле они относятся к нескольким категориям. Есть прибор, который по двум предметам проверяет, одинаковы ли они. Известно, что предметы некоторой категории составляют большинство. Надо найти представитель этого большинства за $O(n)$ сравнений. Помимо рекуррентного решения, эта задача имеет простое итеративное решение. Заведём коробку, в которой будем накапливать одинаковые предметы, а также урну, куда можно выкидывать предметы. Перекладываем непросмотренные элементы в коробку или урну, поддерживая такое свойство: среди невыкинутых искомые составляют большинство.]

Замечания

Числа Фибоначчи рассматривались Фибоначчи (L. Fibonacci) в 1202 году. Муавр (A. De Moivre) применил производящие функции для решения рекуррентных соотношений (см. задачу 4-6). Основная теорема о рекуррентных соотношениях заимствована из работы Бентли, Хакен и Сакса [26], где приводится более сильный результат (включающий результат упр. 4.4-2). Кнут [121] и Лю [140] показывают, как решать линейные рекуррентные соотношения с помощью производящих функций. Дополнительные сведения о решении рекуррентных соотношений приводят Пурдом и Браун [164].

1257

5 Множества

В этой главе мы напоминаем определения, терминологию, обозначения и основные свойства множеств, отношений, функций, графов и деревьев. Читатели, знакомые с ними, могут пропустить эту главу (обращаясь к ней по мере необходимости).

5.1 Множества

Множество (set) состоит из **элементов** (members, elements). Если объект x является элементом множества S, мы пишем $x \in S$ (читается *"x принадлежит S"*). Если x не принадлежит S, пишем $x \notin S$. Можно задать множество перечислением его элементов через запятые в фигурных скобках. Например, множество $S = \{1, 2, 3\}$ содержит элементы $1, 2, 3$ и только их. Число 2 является элементом этого множества, а число 4 — нет, так что $2 \in S$, $4 \notin S$. Множество не может содержать двух одинаковых элементов, и порядок элементов не фиксирован. Два множества A и B **равны** (are equal), если они состоят из одних и тех же элементов. В этом случае пишут $A = B$. Например, $\{1, 2, 3, 1\} = \{1, 2, 3\} = \{3, 2, 1\}$.

Для часто используемых множеств имеются специальные обозначения:

- $\varnothing$ обозначает **пустое множество** (empty set), не содержащее ни одного элемента.
- $\mathbb{Z}$ обозначает множество **целых чисел** (integers); $\mathbb{Z} = \{\ldots, -2, -1, 0, 1, 2, \ldots\}$;
- $\mathbb{R}$ обозначает множество **вещественных (действительных) чисел** (real numbers);
- $\mathbb{N}$ обозначает множество **натуральных чисел** (natural numbers); $\mathbb{N} = \{0, 1, 2, \ldots\}$[1]

Если все элементы множества A являются элементами множе-

[1] Иногда нумерацию натуральных чисел начинают с 1 — раньше так было принято.

ства B, (из $x \in A$ следует $x \in B$), говорят, что A является **подмножеством** (subset) множества B и пишут $A \subseteq B$. Если при этом A не совпадает с B, то A называется **собственным подмножеством** (proper subset) множества B; в этом случае пишут $A \subset B$. (Многие авторы используют обозначение $A \subset B$ для подмножеств, а не для собственных подмножества.) Для любого множества A выполнено соотношение $A \subseteq A$. Множества A и B равны тогда и только тогда, когда $A \subseteq B$ и $B \subseteq A$. Для любых трёх множеств A, B и C из $A \subseteq B$ и $B \subseteq C$ следует $A \subseteq C$. Для любого множества A имеет место соотношение $\varnothing \subseteq A$.

Иногда множество определяется как часть другого множества: мы можем выделить из множества A все элементы, обладающие некоторым свойством, и образовать из них новое множество B. Например, множество чётных чисел можно определить как $\{x : x \in \mathbb{Z}$ и $x/2$ — целое число$\}$. Это обычно читают *"множество x из $\mathbb{Z}$, для которых..."* Иногда вместо двоеточия используется вертикальная черта.

Для любых множеств A и B можно построить следующие множества, получаемые с помощью **теоретико-множественных операций** (set operations):

- **Пересечение** (intersection) множеств A и B определяется как множество
$$A \cap B = \{x : x \in A \text{ и } x \in B\}.$$
- **Объединение** (union) множеств A и B определяется как множество
$$A \cup B = \{x : x \in A \text{ или } x \in B\}.$$
- **Разность** (difference) множеств A и B определяется как множество
$$A \setminus B = \{x : x \in A \text{ и } x \notin B\}.$$

Теоретико-множественные операции обладают следующими свойствами:

Свойства пустого множества (empty set laws):

$$A \cap \varnothing = \varnothing, \qquad A \cup \varnothing = A.$$

Идемпотентность (idempotency laws):

$$A \cap A = A, \qquad A \cup A = A.$$

Коммутативность (commutative laws):

$$A \cap B = B \cap A, \qquad A \cup B = B \cup A.$$

??? На картинке следует заменить минус на \

Рисунок 5.1 Диаграмма Венна, иллюстрирующая первый из законов де Моргана (5.2). Множества A, B, C изображены кругами на плоскости.

Ассоциативность (associative laws):

$$A \cap (B \cap C) = (A \cap B) \cap C, \qquad A \cup (B \cup C) = (A \cup B) \cup C.$$

Дистрибутивность (distributive laws):

$$\begin{aligned} A \cap (B \cup C) = (A \cap B) \cup (A \cap C), \\ A \cup (B \cap C) = (A \cup B) \cap (A \cup C) \end{aligned} \tag{5.1}$$

Законы поглощения (absorption laws):

$$A \cap (A \cup B) = A, \qquad A \cup (A \cap B) = A$$

Законы де Моргана (DeMorgan's laws):

$$\begin{aligned} A \setminus (B \cap C) = (A \setminus B) \cup (A \setminus C), \\ A \setminus (B \cup C) = (A \setminus B) \cap (A \setminus C) \end{aligned} \tag{5.2}$$

Рис. 5.1 иллюстрирует первый из законов де Моргана (5.1); множества A, B и C изображены в виде кругов на плоскости.

Часто все рассматриваемые множества являются подмножества некоторого фиксированного множества, называемого **универсумом** (universe). Например, если нас интересуют множества, элементами которых являются целые числа, то в качестве универсума можно взять множество $\mathbb{Z}$ целых чисел. Если универсум U фиксирован, можно определить **дополнение** (complement) множества A как $\overline{A} = U \setminus A$. Для любого $A \subseteq U$ верны такие утверждения:

$$\overline{\overline{A}} = A, \qquad A \cap \overline{A} = \varnothing, \qquad A \cup \overline{A} = U.$$

Из законов де Моргана (5.2) следует, что для любых множеств $A, B \subseteq U$ имеют место равенства

$$\overline{A \cap B} = \overline{A} \cup \overline{B}, \qquad \overline{A \cup B} = \overline{A} \cap \overline{B}.$$

Два множества A и B называются **непересекающимися** (disjoint), если они не имеют общих элементов, т.е. если $A \cap B = \varnothing$. Говорят, что семейство $\mathcal{S} = \{S_i\}$ непустых множеств образует **разбиение** (partition) множества S, если

- множества S_i **попарно не пересекаются** (are pairwise disjoint), т. е. $S_i \cap S_j = \varnothing$ при $i \neq j$,
- их объединение есть S, т. е.

$$S = \bigcup_{S_i \in \mathcal{S}} S_i$$

Другими словами, семейство $\mathcal{S}$ образует разбиение множества S, если любой элемент $s \in S$ принадлежит ровно одному из множеств S_i семейства.

Число элементов в множестве S называется его **мощностью** (cardinality), или **размером** (size), и обозначается $|S|$. Два множества имеют одну и ту же мощность, если между их элементами можно установить взаимно однозначное соответствие. Мощность пустого множества равна нулю: $|\varnothing| = 0$. Мощность **конечного** (finite) множества — натуральное число; для **бесконечных** (infinite) множеств понятие мощности требует аккуратного определения. Оно нам не понадобится; упомянем лишь, что множества, элементы которых можно поставить во взаимно однозначное соответствие с натуральными числами, называются **счётными** (countably infinite); бесконечные множества, не являющиеся счётными, называют **несчётными** (uncountable). Множество целых чисел $\mathbb{Z}$ счётно, в то время как множество вещественных чисел $\mathbb{R}$ несчётно.

Для любых двух конечных множеств A и B выполнено равенство

$$|A \cup B| = |A| + |B| - |A \cap B| \tag{5.3}$$

из этого равенства вытекает, что

$$|A \cup B| \leqslant |A| + |B|$$

Если множества A и B не пересекаются, то $|A \cap B| = 0$ и это неравенство обращается в равенство: $|A \cup B| = |A| + |B|$. Если $A \subseteq B$, то $|A| \leqslant |B|$.

Конечное множество из n элементов называют **n-элементным** (n-set); одноэлементное множество именуют иногда **синглетоном** (singleton). В английской литературе употребляется также термин k-subset, означающий k-элементное подмножество (какого-либо множества).

Для данного множества S можно рассмотреть множество всех его подмножеств, включая пустое множество и само S; его обозначают 2^S и называют **множеством-степенью** (power set). Например, $2^{\{a,b\}} = \{\varnothing, \{a\}, \{b\}, \{a,b\}\}$. Для конечного S множество 2^S содержит $2^{|S|}$ элементов.

Упорядоченная пара из двух элементов a и b обозначается (a, b) и формально может быть определена как $(a, b) = \{a, \{a, b\}\}$, так что (a, b) отличается от (b, a). [Это определение упорядоченной пары предложено Куратовским. Можно было бы использовать и другое определение, важно только, чтобы $(a, b) = (c, d)$ было равносильно $(a = c)$ и $(b = d)$.]

Декартово произведение (cartesian product) двух множеств A и B определяется как множество всех упорядоченных пар, у которых первый элемент принадлежит A, а второй — B. Обозначение: $A \times B$. Формально можно записать

$$A \times B = \{(a, b) : a \in A \text{ и } b \in B\}$$

Например, $\{a, b\} \times \{a, b, c\} = \{(a, a), (a, b), (a, c), (b, a), (b, b), (b, c)\}$. Для конечных множеств A и B мощность их произведения равна произведению мощностей:

$$|A \times B| = |A| \cdot |B|. \tag{5.4}$$

Декартово произведение n множеств $A_1, A_2, \ldots, A_n$ определяется как множество n**-ок** (n-tuples)

$$A_1 \times A_2 \times \ldots \times A_n = \{(a_1, a_2, \ldots, a_n) : a_i \in A_i \text{ при всех } i = 1, 2, \ldots, n\}$$

(формально можно определить тройку (a, b, c) как $((a, b), c)$, чётверку (a, b, c, d) как $((a, b, c), d)$ и так далее).

Число элементов в декартовом произведение равно произведению мощностей сомножителей:

$$|A_1 \times A_2 \times \ldots \times A_n| = |A_1| \cdot |A_2| \cdot \ldots \cdot |A_n|$$

Можно определить также **декартову степень**

$$A^n = A \times A \times \ldots \times A$$

как произведение n одинаковых сомножителей; для конечного A мощность A^n равна $|A|^n$. Отметим, что n-ки можно рассматривать как конечные последовательности длины n (см. с. ??).

Упражнения

5.1-1 Нарисуйте диаграмму Венна для первого из свойств дистрибутивности (5.1).

5.1-2 Докажите обобщение законов де Моргана на случай большего числа множеств:

$$\overline{A_1 \cap A_2 \cap \ldots \cap A_n} = \overline{A_1} \cup \overline{A_2} \cup \ldots \cup \overline{A_n},$$
$$\overline{A_1 \cup A_2 \cup \ldots \cup A_n} = \overline{A_1} \cap \overline{A_2} \cap \ldots \cap \overline{A_n}.$$

5.1-3 Докажите обобщение равенства (5.3), называемое **формулой включений и исключений** (principle of inclusion and exclusion):

$$\begin{aligned}|A_1 \cup A_2 \cup \ldots \cup A_n| = {} & |A_1| + |A_2| + \ldots + |A_n| \\ & - |A_1 \cap A_2| - |A_1 \cap A_3| - \ldots \\ & + |A_1 \cap A_2 \cap A_3| + \ldots \\ & + (-1)^{n-1}|A_1 \cap A_2 \cap \ldots \cap A_n|\end{aligned}$$

5.1-4 Доказать, что множество нечётных натуральных чисел счётно.

5.1-5 Доказать, что если множество S конечно и содержит n элементов, то множество-степень 2^S содержит 2^n элементов. (Другими словами, множество S имеет 2^n различных подмножеств.)

5.1-6 Дайте формально индуктивное определение n-ки, используя понятие упорядоченной пары.

5.2 Отношения

Бинарным отношением (binary relation) R между элементами множеств A и B называется подмножество декартова произведения $A \times B$. Если $(a, b) \in R$, пишут aRb и говорят, что элемент a находится в отношении R с элементом b. Бинарным отношением на множестве A называют подмножество декартова квадрата $A \times A$. Например, отношение *"быть меньше"* на множестве натуральных чисел есть множество $\{(a, b) : a, b \in \mathbb{N}$ и $a < b\}$. Под **n-местным отношением** (n-ary relation) на множествах $A_1, A_2, \ldots, A_n$ понимают подмножество декартова произведения $A_1 \times A_2 \times \ldots \times A_n$.

Бинарное отношение $R \subseteq A \times A$ называют **рефлексивным** (reflexive), если

$$aRa$$

для всех $a \in A$. Например, отношения "$=$" и "$\leqslant$" являются рефлексивными отношениями на множестве $\mathbb{N}$, но отношение "$<$" таковым не является. Отношение R называется **симметричным** (symmetric), если

$$aRb \text{ влечёт } bRa$$

для всех $a, b \in A$. Отношение равенства является симметричным, а отношения "$<$" и "$\leqslant$" — нет. Отношение R называют **транзитивным** (transitive), если

$$aRb \text{ и } bRc \text{ влечёт } aRc$$

для всех $a, b, c \in A$. Например, отношения "$<$", "$\leqslant$" и "$=$" являются транзитивными, а отношение $R = \{(a,b) : a, b \in \mathbb{N}$ и $a = b - 1\}$ — нет, так как $3R4$ и $4R5$, но не $3R5$.

Отношение, являющееся одновременно рефлексивным, симметричным и транзитивным, называют **отношением эквивалентности** (equivalence relation). Если R — отношение эквивалентности на множестве A, то можно определить **класс эквивалентности** (equivalence class) элемента $a \in A$ как множество $[a] = \{b \in A : aRb\}$ всех элементов, эквивалентных a. Например, на множестве натуральных чисел можно определить отношение эквивалентности, считая числа a и b эквивалентными, если их сумма $a + b$ чётна. Это отношение (назовём его R) действительно будет отношением эквивалентности. В самом деле, сумма $a + a$ всегда чётна, так что оно рефлексивно; $a + b = b + a$, так что R симметрично; наконец, если $a+b$ и $b+c$ — чётные числа, то $a+c = (a+b)+(b+c)-2b$ также чётно, так что R транзитивно. Класс эквивалентности числа 4 есть $[4] = \{0, 2, 4, 6, \ldots\}$, а класс эквивалентности числа 3 есть $[3] = \{1, 3, 5, 7, \ldots\}$. Основное свойство классов эквивалентности состоит в следующем:

Теорема 5.1 (Отношения эквивалентности соответствуют разбиениям). *Для любого отношения эквивалентности на множестве A классы эквивалентности образуют разбиение A. Напротив, для любого разбиения множества A отношение "быть в одном классе" является отношением эквивалентности.*

Доказательство. Чтобы доказать первое утверждение, надо показать, что классы эквивалентности непусты, попарно не пересекаются и в объединении дают всё множество A. По свойству рефлексивности $a \in [a]$, поэтому классы непусты и покрывают всё a. Докажем, что если классы $[a]$ и $[b]$ пересекаются, то они совпадают. Пусть c — их общий элемент, тогда aRc, bRc, cRb (симметричность) и aRb (транзитивность). Теперь видно, что $[b] \subseteq [a]$: если x — произвольный элемент b, то bRx и по транзитивности aRx. Аналогично, $[a] \subseteq [b]$ и потому $[a] = [b]$.

Второе утверждение теоремы совсем очевидно. □

Бинарное отношение R на множестве A называется **антисимметричным**, если

$$aRb \text{ и } bRa \text{ влечёт } a = b.$$

Например, отношение "$\leqslant$" на натуральных числах является антисимметричным, поскольку из $a \leqslant b$ и $b \leqslant a$ следует $a = b$. Рефлексивное, антисимметричное и транзитивное отношение называется отношением **частичного порядка** (partial order), и множество вместе с таким отношением на нём называется **частично упорядоченным множеством** (partially ordered set). Например, отношение *"быть потом-*

ком" на множестве людей является частичным порядком, если мы считаем человека своим потомком.

Частично упорядоченное множество, даже конечное, может не иметь наибольшего элемента — такого элемента x, что yRx для любого элемента y. Следует различать понятия наибольшего и максимального элементов: элемент x называется **максимальным** (maximal), если не существует большего элемента, т.е. если из xRy следует $x = y$. Например, среди нескольких картонных коробок может не быть наибольшей (в которую помещается любая другая), но заведомо есть одна или несколько максимальных (которые не влезают ни в одну другую).

Частичный порядок называется **линейным** (total order, linear order), если для любых элементов a и b выполнено либо aRb, либо bRa (или оба — тогда они равны по свойству антисимметричности). Например, отношение "$\leqslant$" на множестве натуральных чисел является линейным порядком, а отношение *"быть потомком"* на множестве людей — нет (можно найти двух человек, не являющихся потомками друг друга).

Упражнения

5.2-1 Доказать, что отношение "$\subseteq$" на множестве всех подмножеств множества $\mathbb{Z}$ является отношением частичного, но не линейного порядка.

5.2-2 Показать, что для любого положительного n отношение $a \equiv b \pmod{n}$ является отношением эквивалентности на множестве $\mathbb{Z}$. (Говорят, что $a \equiv b \pmod{n}$, если существует целое q, для которого $a - b = qn$.) Сколько классов эквивалентности есть у этого отношения?

5.2-3 Приведите пример отношения, которое

а. рефлексивно и симметрично, но не транзитивно;

б. рефлексивно и транзитивно, но не симметрично;

в. симметрично и транзитивно, но не рефлексивно.

5.2-4 Пусть S — конечное множество, R — отношение эквивалентности на S. Докажите, что если R антисимметрично, что все классы эквивалентности содержат по одному элементу.

5.2-5 Профессор думает, что всякое симметричное и транзитивное отношение рефлексивно, и предлагает такое доказательство: из aRb следует bRa по симметричности, откуда следует aRa по транзитивности. Правильно ли это доказательство?

5.3 Функции

Пусть даны два множества A и B. **Функцией** (function), отображающей A в B, называется бинарное отношение $f \subseteq A \times B$, обладающее таким свойством: для каждого $a \in A$ существует ровно одно $b \in B$, для которого $(a, b) \in f$. Множество A называется **областью определения** (domain) функции; для множества B в русском языке нет общепринятого названия, а по-английски оно называется codomain.

Можно сказать, что функция f сопоставляет с каждым элементом множества A некоторый элемент множества B. Одному элементу множества A может соответствовать только один элемент множества B, хотя один и тот же элемент B может соответствовать нескольким различным элементам A. Например, бинарное отношение

$$f = \{(a, b) : a \in \mathbb{N} \text{ и } b = a \bmod 2\}$$

можно рассматривать как функцию $f \colon \mathbb{N} \to \{0, 1\}$, поскольку для каждого натурального числа a существует единственное $b \in \{0, 1\}$, равное $a \bmod 2$. Можно записать $f(0) = 0$, $f(1) = 1$, $f(2) = 0$ и так далее. С другой стороны, отношение

$$g = \{(a, b) : a, b \in \mathbb{N} \text{ и } a + b \text{ чётно}\}$$

не является функцией, поскольку (например) пары $(1, 3)$ и $(1, 5)$, принадлежащие этому отношению, имеют равные первые члены, но разные вторые.

Если пара (a, b) принадлежит отношению f, являющемуся функцией, то говорят, что b является **значением** (value) функции для **аргумента** (argument) a, и пишут $b = f(a)$. Чтобы задать функцию, надо указать её значение для каждого аргумента, принадлежащего её области определения. Например, можно задать функцию $f \colon \mathbb{N} \to \mathbb{N}$ формулой $f(n) = 2n$, которая означает, что $f = \{(n, 2n) : n \in \mathbb{N}\}$. Две функции $f, g \colon A \to B$ считаются **равными** (equal), если $f(a) = g(a)$ для всех $a \in A$. (Обратите внимание, что с формальной точки зрения мы считаем функции $f \colon A \to B_1$ и $g \colon A \to B_2$ различными при $B_1 \neq B_2$, даже если $f(a) = g(a)$ при всех a!)

Конечной последовательностью (finite sequence) длины n называют функцию f, область определения которой есть множество $\{0, 1, 2, \ldots, n-1\}$. Конечную последовательность часто записывают как список её значений, т. е. как $\langle f(0), f(1), \ldots, f(n-1)\rangle$. **Бесконечной последовательностью** (infinite sequence) называется функция, областью определения которой является множество $\mathbb{N}$ натуральных чисел. Например, последовательность Фибоначчи, заданная уравнением (2.13), может быть записана как $\langle 0, 1, 1, 2, 3, 5, 8, 13, 21, \ldots\rangle$.

Если область определения функции является декартовым произведением нескольких множества, мы обычно опускаем дополнительные скобки вокруг аргументов. Например, если $f\colon A_1 \times A_2 \times \ldots \times A_n \to B$, мы пишем $f(a_1, a_2, \ldots, a_n)$ вместо более формального $f((a_1, a_2, \ldots, a_n))$. Каждое из a_i также называется **аргументом** (argument) функции f, хотя формально её аргументов следовало бы считать n-ку $(a_1, a_2, \ldots, a_n)$.

Если $b = f(a)$ для некоторой функции $f\colon A \to B$ и некоторых $a \in A$, $b \in B$, то элемент b называют **образом** (image) элемента a. Для произвольного подмножества A' множества A его образ $f(A')$ определяют формулой

$$f(A') = \{b \in B : b = f(a) \text{для некоторого } a \in A'\}.$$

Множество значений (range) функции f определяется как образ области её определения, т.е. как $f(A)$. Например, множество значений функции $f\colon \mathbb{N} \to \mathbb{N}$, определённой формулой $f(n) = 2n$, есть множество всех чётных натуральных чисел, которое можно записать как $f(\mathbb{N}) = \{m : m = 2n \text{ для некоторого } n \in \mathbb{N}\}$.

Функция $f\colon A \to B$ называется **сюръекцией** (surjection), или **наложением**, если её образ совпадает с множеством B, т.е. всякий элемент $b \in B$ является образом некоторого элемента $a \in A$. Например, функция $f\colon \mathbb{N} \to \mathbb{N}$, заданная формулой $f(n) = \lfloor n/2 \rfloor$, является сюръекцией. Функция $f(n) = 2n$ не будет сюръекцией, если считать, что $f\colon \mathbb{N} \to \mathbb{N}$, но будет таковой, если считать её отображающей множество натуральных чисел в множество чётных натуральных чисел. Функцию $f\colon A \to B$, являющуюся сюръекцией, называют также отображением A **на** B (onto B).

Функция $f\colon A \to B$ называется **инъекцией** (injection), или **вложением**, если различным аргументам соответствуют различные значения, т.е. если $f(a) \neq f(a')$ при $a \neq a'$. Например, функция $f(n) = 2n$ является инъекцией множества $\mathbb{N}$ в множество $\mathbb{N}$, поскольку любое число n является образом самое большее одного элемента ($n/2$, если n чётно; нечётные числа не являются образами никаких элементов). Функция $f(n) = \lfloor n/2 \rfloor$ не является инъекцией, так как (например) $f(2) = f(3) = 1$. В английской литературе для инъекций употребляется также термин *"one-to-one function"*.

Функция $f\colon A \to B$ называется **биекцией** (bijection), если она одновременно является инъекцией и сюръекцией. Например, функция $f(n) = (-1)^n \lceil n/2 \rceil$, рассматриваемая как функция, отображающая

$\mathbb{N}$ в $\mathbb{Z}$, является биекцией:

$$\begin{array}{r@{\,\to\,}r} 0 & 0 \\ 1 & -1 \\ 2 & 1 \\ 3 & -2 \\ 4 & 2 \\ \multicolumn{2}{c}{\vdots} \end{array}$$

Инъективность означает, что никакой элемент множества $\mathbb{Z}$ не является образом двух разных элементов множества $\mathbb{N}$. Сюръективность означает, что всякий элемент множества $\mathbb{Z}$ является образом хотя бы одного элемента множества $\mathbb{N}$. Биекции называют также **взаимно однозначными соответствиями** (one-to-one correspondence), поскольку они устанавливают соответствия между элементами множеств A и B. Биективная функция, отображающая множество A в себя, называется **перестановкой** (permutation) множества A.

Если функция f биективна, можно определить **обратную** (inverse) функцию f^{-1} соотношением

$$f^{-1}(b) = a \text{ тогда и только тогда, когда } f(a) = b.$$

Например, для рассмотренной выше функции $f(n) = (-1)^n \lceil n/2 \rceil$ обратная функция вычисляется по формуле

$$f^{-1}(m) = \begin{cases} 2m, & \text{если } m \geqslant 0, \\ -2m - 1, & \text{если } m < 0. \end{cases}$$

Упражнения

5.3-1 Пусть A и B — конечные множества, и $f\colon A \to B$ — некоторая функция. Покажите, что
а. если f — инъекция, то $|A| \leqslant |B|$;
б. если f — сюръекция, то $|A| \geqslant |B|$.

5.3-2 Будет ли биекцией функция $f\colon \mathbb{N} \to \mathbb{N}$, заданная формулой $f(x) = x + 1$? Тот же вопрос для функции $\mathbb{Z} \to \mathbb{Z}$, заданной той же формулой.

5.3-3 Дайте определение обратного к бинарному отношению. (Если отношение является биекцией, то определение должно давать обратную биекцию в описанном выше смысле.)

5.3-4* Постройте биекцию $f\colon \mathbb{Z} \to \mathbb{Z} \times \mathbb{Z}$.

Рисунок 5.2 Ориентированные и неориентированные графы. (а) Ориентированный граф (V, E), где $V = \{1,2,3,4,5,6\}$ и $E = \{(1,2),(2,2),(2,4),(2,5),(4,1),(4,5),(5,4),(6,3)\}$. Ребро $(2,2)$ является ребром-циклом. (б) Неориентированный граф $G = (V, E)$, где $V = \{1,2,3,4,5,6\}$ и $E = \{(1,2),(1,5),(2,5),(3,6)\}$. Вершина 4 является изолированной (не имеет смежных вершин). (в) Подграф графа (а), получающийся его ограничением на множество вершин $\{1,2,3,6\}$.

5.4 Графы

В этом разделе мы рассмотрим основные понятия, связанные с ориентированными и неориентированными графами. Следует иметь в виду, что терминология здесь не вполне устоялась и в разных книгах можно встретить разные определения, но по большей части различия невелики. Мы вернёмся к графам в главе 23, где рассматриваются различные алгоритмы на графах.

Ориентированный граф (directed graph) определяется как пара (V, E), где V — конечное множество, а E — бинарное отношение на V, т.е. подмножество множества $V \times V$. Ориентированный граф иногда для краткости называют **орграфом** (digraph). Множество V называют **множеством вершин** графа (vertex set); его элемент называют **вершиной** графа (vertex; множественное число vertices). Множество E называют **множеством рёбер** (edge set) графа; его элементы называют **рёбрами** (edges). На рисунке 5.2 (а) показан ориентированный граф с множеством вершин $\{1,2,3,4,5,6\}$. Вершины изображены кружками, а рёбра — стрелками. Заметим, что граф может содержать **рёбра-циклы** (self-loops), соединяющие вершину с собой.

В **неориентированном** (undirected) графе $G = (V, E)$ множество рёбер (V) состоит из **неупорядоченных** (unordered) пар вершин: парами являются множества $\{u, v\}$, где $u, v \in V$ и $u \neq v$. Мы будем обозначать неориентированное ребро как (u, v) вместо $\{u, v\}$; при этом для неориентированного графа (u, v) и (v, u) обозначают одно и то же ребро. Неориентированный граф не может содержать рёбер-циклов, и каждое ребро состоит из двух различных вершин (*"соединяя"* их). На рис. 5.2 (б) изображён неориентированный граф с множеством вершин $\{1,2,3,4,5,6\}$.

Многие понятия параллельно определяются для ориентированных и неориентированных графов (с соответствующими изменениями). Про ребро (u, v) ориентированного графа говорят, что оно **выходит из** (incident from, leaves) вершины u и **входит** (incident to, enters) в вершину v. Например, на рис. 5.2 (а) имеется три ребра, выходящих из вершины 2 $((2,2),(2,4),(2,5))$ и два ребра, в неё входящих $((1,2),(2,2))$. Про ребро (u, v) неориентированного графа говорят, что оно **инцидентно** вершинам (incident on vertices) u и v. Например, на рис. 2.5 (б) есть два ребра, инцидентные вершине 2 (рёбра $(1,2)$ и $(2,5)$).

Если в графе G имеется ребро (u, v), говорят, что вершина v **смежна** с вершиной u (is adjacent to u). Для неориентированных графов отношение смежности является симметричным, но для ориентированных графов это не обязательно. Если вершина v смежна с вершиной u в ориентированном графе, пишут $u \to v$. Для обоих рисунков 5.2 (а) и 5.2 (б) вершина 2 является смежной с вершиной 1, но лишь во втором из них вершина 1 смежна с вершиной 2 (в первом случае ребро $(2,1)$ отсутствует в графе).

Степенью (degree) вершины в неориентированном графе называется число инцидентных ей рёбер. Например, для графа рис. 5.2 (б) степень вершины 2 равна 2. Для ориентированного графа различают **исходящую степень** (out-degree), определяемую как число выходящих из неё рёбер, и **входящую степень** (in-degree), определяемую как число входящих в неё рёбер. Сумма исходящей и входящей степеней называется **степенью** (degree) вершины. Например, вершина 2 в графе рис. 5.2 (а) имеет входящую степень 2, исходящую степень 3 и степень 5.

Путь длины k (path of length k) из вершины u в вершину v определяется как последовательность вершин $\langle v_0, v_1, v_2, \ldots, v_k \rangle$, в которой $v_0 = u$, $v_k = v$ и $(v_{i-1}, v_i) \in E$ для всех $i = 1, 2, \ldots, k$. Таким образом, путь длины k состоит из k рёбер. Этот путь **содержит** (contains) вершины $v_0, v_1, \ldots, v_k$ и рёбра $(v_0, v_1), (v_1, v_2), \ldots, (v_{k-1}, v_k)$. Вершину v_0 называют **началом** пути, вершину v_k — его **концом**; говорят, что путь ведёт **из** v_0 **в** v_k. Если для данных вершин u и u' существует путь p из u в u', то говорят, что вершина u' **достижима из** u **по пути** p (u' is reachable from u via p). В этом случае мы пишем (для ориентированных графов) $u \overset{p}{\leadsto} u'$.

Путь называется **простым** (simple), если все вершины в нём различны. Например, на рис. 5.2 (а) есть простой путь $\langle 1, 2, 5, 4 \rangle$ длины 3, а также путь $\langle 2, 5, 4, 5 \rangle$ той же длины, не являющийся простым.

Подпуть (subpath) пути $p = \langle v_0, v_1, \ldots, v_k \rangle$ получится, если мы возьмём некоторое число идущих подряд вершин этого пути, т. е. последовательность $\langle v_i, v_{i+1}, \ldots, v_j \rangle$ при некоторых i, j, для которых $0 \leqslant i \leqslant j \leqslant k$.

Циклом (cycle) в ориентированном графе называется путь, в котором начальная вершина совпадает с конечной и который содержит хотя бы одно ребро. Цикл $\langle v_0, v_1, \ldots, v_k\rangle$ называется **простым**, если в нём нет одинаковых вершин (кроме первой и последней), т.е. если все вершины $v_1, v_2, \ldots, v_k$ различны. Ребро-цикл является циклом длины 1. Мы отождествляем циклы, отличающиеся сдвигом вдоль цикла: один и тот же цикл длины k может быть представлен k различными путями (в качестве начала и конца можно взять любую из k вершин). Например, на рис. 5.2 (а) пути $\langle 1,2,4,1\rangle$, $\langle 2,4,1,2\rangle$ и $\langle 4,1,2,4\rangle$ представляют один и тот же цикл. Этот цикл является простым, в то время как цикл $\langle 1,2,4,5,4,1\rangle$ таковым не является. На том же рисунке есть цикл $\langle 2,2\rangle$, образованный единственным ребром-циклом $(2,2)$. Ориентированный граф, не содержащий рёбер-циклов, называется **простым** (simple).

В неориентированном графе путь $\langle v_0, v_1, \ldots, v_k\rangle$ называется (простым) **циклом**, если $k \geqslant 3$, $v_0 = v_k$ и все вершины $v_1, v_2, \ldots, v_k$ различны. Например, на рис. 5.2 (б) имеется простой цикл $\langle 1,2,5,1\rangle$.

Граф, в котором нет циклов, называется **ациклическим** (acyclic).

Неориентированный граф называется **связным** (connected), если для любой пары вершин существует путь из одной в другую. Для неориентированного графа отношение *"быть достижимым из"* является отношением эквивалентности на множестве вершин. Классы эквивалентности называются **связными компонентами** (connected components) графа. Например, на рис. 5.2 (б) имеются три связные компоненты: $\{1,2,5\}$, $\{3,6\}$ и $\{4\}$. Неориентированный граф связен тогда и только тогда, когда он состоит из единственной связной компоненты.

Ориентированный граф называется **сильно связным** (strongly connected), если из любой его вершины достижима (по ориентированным путям) любая другая. Любой ориентированный граф можно разбить на **сильно связные компоненты** (strongly connected components), которые определяются как классы эквивалентности отношения *"u достижимо из v и v достижимо из u"*. Ориентированный граф сильно связен тогда и только тогда, когда состоит из единственной сильно связной компоненты. Граф рис. 5.2 (а) имеет три таких компоненты: $\{1,2,4,5\}$, $\{3\}$ и $\{6\}$. Заметим, что вершины $\{3,6\}$ не входят в одну сильно связную компоненту, так как 3 достижима из 6, но не наоборот.

Два графа $G = (V, E)$ и $G' = (V', E')$ называются **изоморфными** (isomorphic), если существует взаимно однозначное соответствие $f\colon V \to V'$ между множествами их вершин, при котором рёбрам одного графа соответствуют рёбра другого: $(u, v) \in E$ тогда и только тогда, когда $(f(u), f(v)) \in E'$. Можно сказать, что изоморфные графы — это один и тот же граф, в котором вершины названы по-разному. На рис. 5.3 (а) приведён пример двух изоморфных графов G и G' с множествами вершин $V = \{1,2,3,4,5,6\}$ и

Рисунок 5.3 (а) Пара изоморфных графов. (б) Неизоморфные графы: верхний имеет вершину степени 4, а нижний — нет.

$V' = \{u, v, w, x, y, z\}$. Функция $f\colon V \to V'$, для которой $f(1) = u$, $f(2) = v$, $f(3) = w$, $f(4) = x$, $f(5) = y$, $f(6) = z$, является изоморфизмом. Напротив, графы на рис. 5.3 (б) не изоморфны, хотя оба имеют по 5 вершин и по 7 рёбер. Чтобы убедиться, что они не изоморфны, достаточно отметить, что в верхнем графе есть вершина степени 4, а в нижнем — нет.

Граф $G' = (E', V')$ называют **подграфом** (subgraph) графа $G = (E, V)$, если $E' \subseteq E$ и $V' \subseteq V$. Если в графе $G = (E, V)$ выбрать произвольное множество вершин V', то можно рассмотреть его подграф, состоящий из этих вершин и всех соединяющих их рёбер, т. е. граф $G' = (E', V')$, для которого

$$E' = \{(u, v) \in E : u, v \in V'\}$$

Этот подграф можно назвать **ограничением** графа G на множество вершин V' (subgraph of G induced by V'). Ограничение графа рис. 5.2 (а) на множество вершин $\{1, 2, 3, 6\}$ показано на рис. 5.2 (в) и имеет три ребра $(1, 2)$, $(2, 2)$, $(6, 3)$.

Для любого неориентированного графа G можно рассмотреть его **ориентированный вариант** (directed version), заменив каждое неориентированное ребро $\{u, v\}$ на пару ориентированных рёбер (u, v) и (v, u), идущих в противоположных направлениях. С другой стороны, для каждого ориентированного графа можно рассмотреть его **неориентированный вариант** (undirected version), забыв про ориентацию рёбер, удалив рёбра-циклы и соединив рёбра (u, v) и (v, u) в одно неориентированное ребро $\{u, v\}$. В ориентированном графе **соседом** (neighbor) вершины u называют любую вершину, соединённую с ней ребром (в ту или другую сторону); таким образом, v является соседом u тогда и только тогда, когда v смежно u или u смежно v. Для неориентированного графа выражения *"v — сосед u"* и *"v смежна с u"* являются синонимами.

Некоторые виды графов имеют специальные названия. **Полным** (complete) графом называют неориентированный граф, содержащий все возможные рёбра для данного множества вершин (любая вершина смежна любой другой). Неориентированный граф (V, E) называют **двудольным** (bipartite), если множество вершин V можно разбить на две часть V_1 и V_2 таким образом, что концы любого ребра оказываются в разных частях. Ациклический неориентированный граф называют **лесом** (forest), а связный ациклический неориентированный граф называют **деревом** (без выделенного корня; подробно деревья рассматриваются в следующем разделе). По-английски дерево без выделенного корня называется free tree. Ориентированный ациклический граф (directed acyclic graph) по-английски часто сокращают до *"dag"* (по первым буквам).

Иногда рассматривают обобщения понятия графа. Например, можно рассматривать **мультиграф** (multigraph), который похож на неориентированный граф, но может содержать много рёбер, соединяющих одну и ту же пару вершин, а также рёбра-циклы. **Гиперграф** (hypergraph) отличается от неориентированного графа тем, что он содержит **гиперрёбра** (hyperedges), соединяющие не две вершины, а произвольное множество вершин. Многие алгоритмы обработки обычных графов могут быть обобщены на такие графоподобные структуры.

Упражнения

5.4-1 На вечеринке каждый гость считает, сколько рукопожатий он сделал. Потом все числа складываются. Покажите, что получится чётное число, доказав следующую **лемму о рукопожатиях** (handshaking lemma): для неориентированного графа сумма степеней всех его вершин равна удвоенному числу рёбер.

5.4-2 Покажите, что требование $k \geqslant 3$ в определении цикла в неориентированном графе существенно (если его отменить, в любом графе, где есть хоть одно ребро, будет цикл).

5.4-3 Докажите, что если в графе (ориентированном или неориентированном) есть путь из вершины u в вершину v, то в нём есть простой путь из u в v. Докажите, что если в ориентированном графе есть цикл, то в нём есть простой цикл.

5.4-4 Покажите, что в связном неориентированном графе (V, E) число вершин превосходит число рёбер не более чем на 1: $|E| \geqslant |V| - 1$

5.4-5 Проверьте, что отношение *"быть достижимым из"* является (для неориентированного графа) отношением эквивалентности. Какие из трёх свойств, входящих в определение отношения эквивалентности, справедливы для отношения достижимости в ориентированном графе?

5.4-6 Нарисуйте неориентированную версию графа рис. 5.2 (а) и ориентированную версию графа рис. 5.2 (б).

5.4-7* Как можно представить гиперграф с помощью двудольного графа, изображая отношение инцидентности в гиперграфе отношением смежности в двудольном графе? (Указание: вершинами двудольного графа должны быть вершины гиперграфа, а также гиперрёбра гиперграфа.)

5.5 Деревья

Как и слово *"граф"*, слово *"дерево"* также употребляется в нескольких родственных смыслах. В этом разделе мы даём определения и рассматриваем свойства нескольких видов деревьев. В разделах 11.4 и 23.1 мы вернёмся к деревьям и рассмотрим способы их представления в программах.

5.5.1 Деревья без выделенного корня

Как мы говорили в разделе 5.4, **дерево** (без выделенного корня, free tree) определяется как связный ациклический неориентированный граф. Если неориентированный граф является ациклическим, но (возможно) несвязным, его называют **лесом** (forest); как и положено, лес состоит из деревьев (являющихся его связными компонентами). Многие алгоритмы обработки деревьев применимы и к лесам. На рис. 5.4 (а) изображено дерево; на рис. 5.4 (б) изображён лес. Лес рисунка 5.4 (б) не является деревом, так как не связен. Граф на рисунке 5.4 (в) не является ни деревом, ни даже лесом, так как в нём есть цикл.

В следующей теореме указано несколько важных свойств дере-

Рисунок 5.4 (а) Дерево без выделенного корня. (б) Лес. (в) Граф, содержащий цикл, не является ни деревом, ни лесом.

Рисунок 5.5 Два простых пути из u в v

вьев.

Теорема 5.2 (Свойства деревьев). *Пусть $G = (V, E)$ — неориентированный граф. Тогда следующие свойства равносильны:*

1. G является деревом (без выделенного корня).

2. Для любых двух вершин G существует единственный соединяющий их простой путь.

3. Граф G связен, но перестаёт быть связным, если удалить любое его ребро.

4. Граф G связен и $|E| = |V| - 1$.

5. Граф G ациклический и $|E| = |V| - 1$.

6. Граф G ациклический, но добавление любого ребра к нему порождает цикл.

Доказательство. (1) $\Rightarrow$ (2): Поскольку дерево связно, для любых двух вершин существует соединяющий их путь; выкинув из него лишнее, можем считать, что этот путь простой. Пусть есть два разных простых пути p_1 и p_2 из некоторый вершины u в другую вершину v (рис. 5.5). Посмотрим, где эти пути расходятся; пусть w — последняя общая вершина перед разветвлением, а x и y — различные вершины, следующие за w в путях p_1 и p_2. Двигаясь по первому пути, дождёмся момента, когда путь вновь пересекается со вторым в некоторой вершине z. Рассмотрим участок p' первого пути от w до z (через x) и участок второго пути p'' от w до z (через y). Пути p' и p'' не имеют общих вершин (не считая концов), поскольку z было первой вершиной на пути p_1 после w, попавшей в p_2. Поэтому мы получаем цикл (состоящий из p' и обращения пути p'').

(2) $\Rightarrow$ (3) Граф, очевидно, связен. Пусть (u, v) — любое его ребро. Если после его удаления граф останется связным, то в нём будет путь, соединяющий u и v — второй путь, что противоречит предположению.

(3) $\Rightarrow$ (4) По условию, граф связен, поэтому $|E| \geqslant |V| - 1$ (упр. 5.4-4). Докажем, что $|E| \leqslant |V| - 1$, рассуждая по индукции. Связный граф с $n = 1, 2$ вершинами имеет $n - 1$ рёбер. Пусть граф G имеет $n \geqslant 3$ рёбер и для графов с меньшим числом рёбер наше неравенство уже доказано. Удаление ребра разбивает граф G на $k \geqslant 2$ связных компонент (на самом деле на две, но это нам не важно). Для

каждой из компонент выполнено условие (3). Индуктивное предположение гарантирует, что общее число рёбер в них не больше $|V| - k \leqslant |V| - 2$. Значит, до удаления ребра было не более $|V| - 1$ рёбер.

(4) $\Rightarrow$ (5) Пусть граф связен и $|E| = |V| - 1$. Покажем, что граф не имеет циклов. Если цикл есть, удаление любого ребра из цикла не нарушает связности (можно пройти по остающейся части цикла). Будем повторять это до тех пор, пока не останется связный граф без циклов (дерево). Как мы уже знаем, для дерева число рёбер на единицу меньше числа вершин — но по предположению то же соотношение было и до удаления рёбер, так что удалить мы ничего не могли и с самого начала не было циклов.

(5) $\Rightarrow$ (6) Пусть граф G не имеет циклов и $|E| = |V| - 1$. Пусть G имеет k связных компонент; они по определению являются деревьями. Мы знаем, что в каждой из них число рёбер на единицу меньше числа вершин, поэтому общее число рёбер на k меньше числа вершин. Значит, $k = 1$ и граф представляет собой дерево. В нём любые две вершины могут быть соединены простым путём (мы уже знаем, что (1) $\Rightarrow$ (2)), и потому добавление любого ребра порождает цикл.

(6) $\Rightarrow$ (1) Пусть граф является ациклическим, но добавление любого ребра порождает цикл. Надо показать, что он связен. В самом деле, рассмотрим две произвольные вершины u и v. Мы знаем, что добавление ребра (u, v) порождает цикл. В этом цикле должно встречаться ребро (u, v), поскольку до его добавления цикла не было — но только один раз, и остальная часть цикла соединяет u и v, что и требовалось. $\square$

5.5.2 Деревья с корнем. Ориентированные деревья

Дерево с корнем, или **корневое дерево** (rooted tree), получается, если в дереве (связном ациклическом неориентированном графе) выделить одну из вершин выделена, назвав её **корнем** (root). Вершины корневого дерева по-английски называются также *"nodes"*. На рисунке 5.6 (a) показано корневое дерево с 12 вершинами и корнем 7.

Пусть x — произвольная вершина корневого дерева с корнем в r. Существует единственный путь из r в x; все вершины, находящиеся на этом пути, мы называем **предками** (ancestors) вершины x. Если y является предком x, то x называется **потомком** (descendant) y. Каждую вершину мы считаем своим предком и потомком. Предки и потомки вершины x, не совпадающие с x, называются **собственными предками** (proper ancestors) и **собственными потомками** (proper descendants) вершины x. [Эта терминология не вполне удачна: фразу *"вершина является своим собственным потомком"* можно толковать по разному, и при одном толковании она высота = 4, глубина 0, глубина 1 и т.п.

Рисунок 5.6 (а) Корневое дерево высоты 4. Дерево нарисовано обычным образом: корень (вершина 7) нарисована сверху, соседние с ним вершины (дети корня, вершины глубины 1) нарисованы под ней, вершины следующего уровня (дети детей корня, вершины глубины 2) под ними и т. д. Для деревьев с порядком на детях для каждой вершины фиксирован порядок на множестве её детей. (б) То же самое корневое дерево, но с другим порядком (среди детей вершины 3), будет другим деревом с порядком на детях.

верна, а при другом нет.]

Для каждой вершины x можно рассмотреть дерево, состоящее из всех потомков x, в котором x считается корнем. Оно называется **поддеревом с корнем в** x (subtree rooted at x). Например, на рис. 5.6 (а) поддерево с корнем в 8 содержит вершины 8, 6, 5 и 9.

Если (y, x) — последнее ребро на пути из корня в x, то y называется **родителем** (parent) x, а x называется **ребёнком** y. [Раньше вместо *"родитель"* и *"ребёнок"* говорили *"отец"* (father) и *"сын"* (son), что было более логично, так как вообще-то у человека двое родителей, а у вершины дерева — не более одного. Зато принятая теперь в американской литературе терминология *"политически корректна"*.]

Корень является единственной вершиной, у которой нет родителя. Вершины, имеющие общего родителя, называют в американской литературе siblings; к сожалению, русского перевода у этого слова нет, и мы будем (как это делалось раньше) называть такие вершины **братьями**. Вершина корневого дерева, не имеющая детей, называется **листом** (leaf, external node). Вершины, имеющие детей, называются **внутренними** (internal).

Число детей у вершины корневого дерева называется её **степенью** (degree). Отметим, что для всех вершин, кроме корня, степень на единицу меньше степени той же вершины в том же дереве, если рассматривать дерево как неориентированный граф (поскольку тогда надо учитывать и ребро, идущее вверх). Длина пути от корня до произвольной вершины x называется **глубиной** (depth) вершины x. Максимальная глубина вершин дерева называется **высотой** (height) дерева.

Деревом с порядком на детях (ordered tree) называется корневое

Рисунок 5.7 Двоичные деревья. (а) Двоичное дерево, изображённое традиционным образом. Левый ребёнок вершины нарисован слева-снизу от неё, правый — справа-снизу. (б) Другое двоичное дерево (отличие в том, что теперь у вершины 7 есть правый ребёнок 5 и нет левого, а не наоборот). Такое различие возможно в двоичном дереве, но не в дереве с порядком на детях. (в) Добавляя дополнительные листья к дереву (а), мы получаем дерево, у которого каждая старая вершина имеет двух детей. Добавленные листья изображены квадратиками.

дерево с дополнительной структурой: для каждой вершины множество её детей упорядочено (известно, какой её потомок первый, какой второй и т. д.). Два дерева на рис. 5.6 одинаковы как корневые деревья, но различны как деревья с порядком на детях.

5.5.3 Двоичные деревья. Позиционные деревья

Двоичное дерево (binary tree) проще всего определить рекурсивно как конечный набор вершин, который

- либо пуст (не содержит вершин),
- либо разбит на три непересекающиеся части: вершину, называемую **корнем** (root), двоичное дерево, называемое **левым поддеревом** (left subtree) корня, и двоичное дерево, называемое **правым поддеревом** (right subtree) корня.

Двоичное дерево, не содержащее вершин, называется **пустым** (empty). Оно иногда обозначается NIL. Если левое поддерево непусто, то его корень называется **левым ребёнком** (left child) корня всего дерева; **правый ребёнок** (right child) определяется аналогично. Если левое или правое поддерево корня пусто, то говорят, что у корня нет левого или правого ребёнка (child is absent). Пример двоичного дерева показан на рис. 5.7 (а).

Было бы ошибкой определить двоичное дерево просто как дерево с порядком на детях, в котором степень каждой вершины не превосходит 2. Дело в том, что в двоичном дереве важно, каким является единственный ребёнок вершины степени 1 — левым или правым, а для дерева с порядком на детях такого различия не существует. На рис. 5.7 (а,б) показаны два различных двоичных дерева, которые высота=3, глубина 0, глубина 1 и т.п.

Рисунок 5.8 Полное двоичное дерево высоты 3 имеет 8 листьев и 7 внутренних вершин.

одинаковы как деревья с порядком на детях.

Пустующие места в двоичном дереве часто заполняют фиктивными листьями. После этого у каждой старой вершины будет двое детей (либо прежних, либо добавленных). Это преобразование показано на рис. 5.7 (в).

Можно определить аналоги двоичных деревьев для деревьев большей степени: двоичные деревья являются частным случаем **k-ичных** (k-ary) деревьев при $k = 2$. Более подробно, **позиционное дерево** (positional tree) определяется как корневое дерево, в котором дети любой вершины помечены различными целыми положительными числами, которые считаются их номерами. При этом у каждой вершины есть вакансии для детей номер 1, 2, 3 и так далее, из которых некоторые (конечное число) заполнены, а остальные свободны (ith child is absent). При этом k-ичным деревом называется позиционное дерево, не имеющее вершин с номерами больше k.

Полным k-ичным деревом (complete k-ary tree) называется k-ичное дерево, в котором все листья имеют одинаковую глубину и все внутренние вершины имеют степень k. (Тем самым структура такого дерева полностью определяется его высотой.) На рис. 5.8 показано полное двоичное дерево высоты 3. Подсчитаем, сколько листьев имеет полное k-ичное дерево высоты h. Корень является единственной вершиной глубины 0, его k детей являются вершинами глубины 1, их детьми являются k^2 вершин глубины k и так далее вплоть до k^h листьев глубины h. Можно добавить, что высота k-ичного дерева с n листьями равна $\log_k n$ (такое дерево существует, только если этот логарифм целый). Число внутренних вершин полного k-ичного дерева высоты h равно

$$1 + k + k^2 + \ldots + k^{h-1} = \frac{k^h - 1}{k - 1}$$

(см. (3.3)). В частности, для полного двоичного дерева число внутренних вершин на единицу меньше числа листьев.

Упражнения

5.5-1 Нарисуйте все деревья (без выделенного корня), содержащие три вершины A, B и C. Нарисуйте все корневые деревья с вершинами A, B и C и корнем A. Нарисуйте все (корневые) деревья с порядком на детях с вершинами A, B и C и корнем A. Нарисуйте все двоичные деревья с вершинами A, B и C и корнем A.

5.5-2 Покажите, что для любого $n \geqslant 7$ существует дерево с n вершинами, из которого можно получить n различных корневых деревьев, объявив корнем одну из n вершин.

5.5-3 Пусть $G = (V, E)$ — ориентированный ациклический граф, в котором существует вершина v_0, из которой в каждую другую $v \in V$ ведёт единственный путь. Покажите, что неориентированный вариант графа G является деревом.

5.5-4 Докажите по индукции, что в любом двоичном дереве число вершин степени 2 на единицу меньше числа листьев.

5.5-5 Покажите, что двоичное дерево с n вершинами имеет высоту не меньше $\lfloor \lg n \rfloor$.

5.5-6* Определим **внутреннюю сумму длин** (internal path length) для двоичного дерева, в котором каждая вершина имеет степень 0 или 2, как сумму глубин всех внутренних вершин. Определим **внешнюю сумму длин** для этого же дерева как сумму глубин всех его листьев. Пусть n — число внутренних вершин такого дерева, i и e — внутренняя и внешняя суммы длин. Докажите, что $e = i + 2n$.

5.5-7* Определим *"вес"* листа в двоичном дереве как 2^{-d}, где d — его глубина. Докажите, что сумма весов всех листьев в двоичном дереве не превосходит 1 (**неравенство Крафта**, Kraft inequality)

5.5-8* Покажите, что в любом двоичном дереве с L листьями можно найти поддерево, число листьев в котором находится на отрезке $[L/3, 2L/3]$.

Задачи

5-1 Раскраска графа

Назовём k-раскраской неориентированного графа (V, E) функцию $c\colon V \to \{0, 1, \ldots, k-1\}$, для которого $c(u) \neq c(v)$ для любых двух смежных вершин u и v. (Концы любого ребра должны иметь разные цвета.)

а. Покажите, что любое дерево имеет 2-раскраску.

б. Покажите, что следующие свойства неориентированного графа G равносильны:

1. Граф G двудольный.
2. Граф G имеет 2-раскраску.
3. Граф G не имеет циклов нечётной длины.

в. Пусть d — максимальная степень вершин неориентированного графа G. Покажите, что G имеет $(d+1)$-раскраску.

г. Покажите, что если граф G имеет $O(|V|)$ рёбер, то G имеет $O(\sqrt{|V|})$-раскраску.

5-2 Графы и люди

Переведите на язык неориентированных графов следующие утверждения и докажите их. (Предполагается, что отношение *"быть другом"* симметрично, и человек не включается в число своих друзей.)

а. В любой компании из $n \geqslant 2$ человек найдутся два человека с одинаковым числом друзей (среди присутствующих).

б. В любой группе из 6 человек можно найти либо трёх человек, являющихся друзьями друг друга, либо трёх человек, никакие двое из которых не являются друзьями.

в. Любую компанию людей можно развести по двум комнатам так, что для каждого человека как минимум половина его друзей окажутся в другой комнате.

г. Если в компании из n человек у каждого не менее $n/2$ друзей, то эту компанию можно рассадить за круглым столом так, чтобы каждый сидел между двумя своими друзьями.

5-3 Разбиение деревьев на части

Многие алгоритмы на графах, действующие по принципу *"разделяй и властвуй"*, делят граф на две части, при этом желательно удалять как можно меньше рёбер и получить две части по возможности близкого размера.

а. Покажите, что в любом двоичном дереве с n вершинами можно найти ребро, после удаления которого получатся две части размера не больше $3n/4$ каждая.

б. Покажите, что константу $3/4$ в пункте (а) нельзя улучшить, приведя пример двоичного дерева, для которого после удаления любого ребра в одной из частей остаётся не менее $3n/4$ вершин.

в. Покажите, что множество вершин любого двоичного дерева с n вершинами можно разбить на две части A и B таким образом, что $|A| = \lfloor n/2 \rfloor$, $|B| = \lceil n/2 \rceil$, а число рёбер, соединяющих вершины из разных частей, есть $O(\lg n)$.

Замечания

Основатель символической логики Буль (G. Boole) ввёл многие из нынешних теоретико-множественных обозначений в книге, опубликованной в 1854 году. Современная теория множеств (прежде всего теория мощностей бесконечных множеств) была создана Кантором (G. Cantor) в 1874–1895 годах. Термин *"функция"* использовал Лейбниц (G.W. Leibnitz) в применении к некоторым математическим формулам. Определение функции впоследствии многократно обобщалось. Теория графов восходит к 1736 году, когда Эйлер (L. Euler) показал, что невозможно пройти по всем семи мостам города Кёнигсберга по одному разу и вернуться в исходную точку.

Полезным справочником по определениям и результатам теории графов является книга Харари [94].

6 Комбинаторика и вероятность

В этой главе излагаются начала комбинаторики и теории вероятностей. Если вы знакомы с ними, советуем просмотреть начало главы и внимательно прочесть последние разделы. Многие главы этой книги не используют теорию вероятностей, но кое-где она необходима.

Раздел 6.1 напоминает основные факты комбинаторики (в том числе формулы для перестановок и сочетаний). Раздел 6.2 содержит аксиомы вероятности и основные факты о распределениях вероятностей. В разделе 6.3 определяются понятия случайной величины, ее математического ожидания и дисперсии. Раздел 6.4 посвящен геометрическому и биномиальному распределениям. Исследование биномиального распределения продолжается в разделе 6.5 (оценка *"хвостов"*). В последнем разделе 6.6 применение теории вероятностей иллюстрируется на примере трёх задач: парадокса дня рождения, случайного распределения шаров по урнам и оценки длины выигрышных участков при бросании монеты.

6.1 Подсчёт количеств

Иногда можно найти число предметов определённого вида, не перечисляя их все. Например, легко найти число всех n-битовых строк или всех перестановок n объектов. В этом разделе мы рассмотрим основные методы такого подсчёта. Предполагается, что читатель знаком с понятиями теории множеств (см. разд. 5.1).

Правила суммы и произведения

Множество, количество элементов которого мы хотим подсчитать, часто может быть представлено в виде объединения непересекающихся множеств или декартова произведения множеств.

Правило суммы (rule of sum) гласит, что $|A \cup B| = |A| + |B|$ для непересекающихся конечных множеств A и B (частный случай формулы (5.3)). Если символ на номере машины должен быть либо латинской буквой, либо цифрой, то всего есть $26+10=36$ возможностей, так как букв 26, а цифр 10.

Правило произведения (rule of product) утверждает, что $|A \times B| = |A| \cdot |B|$ для конечных множеств A и B, см. (5.4). Например, имея 28 сортов мороженого и 4 вида сиропа, можно изготовить $28 \cdot 4 = 112$ вариантов мороженого с сиропом (не смешивая разные сорта мороженого и сиропа).

Строки

Строкой (string; по-русски говорят также о **словах**) называют конечную последовательность элементов некоторого конечного множества S (называемого **алфавитом**). Например, существует 8 двоичных (составленных из нулей и единиц) строк длины 3:

$$000, 001, 010, 011, 100, 101, 110, 111.$$

Иногда строку длины k называют **k-строкой** (k-string). **Подстрокой** (substring) s' строки s называется произвольная последовательность идущих подряд элементов строки s. Говоря о **k-подстроке** (k-substring), имеют в виду подстроку длины k. Так, 010 является 3-подстрокой строки 01101001 (она начинается с позиции 4), а 111 — нет.

Строка длины k из элементов множества S является элементом прямого произведения S^k, так что всего существует $|S|^k$ строк длины k. В частности, имеется 2^k двоичных строк длины k. Это можно объяснить ещё и так: первый элемент строки можно выбрать $|S|$ способами; для каждого из них есть $|S|$ вариантов продолжения, и так далее — всего k выборов, получается $|S| \times |S| \times \ldots \times |S|$ (k множителей) вариантов.

Перестановки

Перестановкой (permutation) конечного множества S называется упорядоченная последовательность всех его элементов, в которой каждый элемент встречается ровно один раз. Так, существует 6 перестановок множества $S = \{a, b, c\}$:

$$abc, acb, bac, bca, cab, cba.$$

Всего имеется $n!$ перестановок множества из n элементов, так как первый элемент перестановки можно выбрать n способами, второй $n-1$ способами, третий $n-2$ способами, и т.д.

Размещения без повторений

Если каждый элемент можно использовать только один раз, но не требуется использовать все элементы, говорят о **размещениях без повторений**. Пусть фиксировано множество S из n элементов и некоторое k, не превосходящее n. Размещением без повторений из n по k называют последовательность длины k, составленную из различных элементов S. (Английский термин — k-permutation.) Число таких размещений равно

$$n(n-1)(n-2)\cdots(n-k+1)=\frac{n!}{(n-k)!} \tag{6.1}$$

так как существует n способов выбора первого элемента, $n-1$ способов выбора второго элемента, и так далее до k-го элемента, который можно выбрать $n-k+1$ способами.

Например, существует $12 = 4 \cdot 3$ последовательностей из двух различных элементов множества $\{a, b, c, d\}$:

$$ab, ac, ad, ba, bc, bd, ca, cb, cd, da, db, dc.$$

Частным случаем этой формулы является формула для числа перестановок (поскольку перестановки являются частным случаем размещений при $n = k$).

Сочетания

Сочетаниями (k-combinations) из n элементов по k называются k-элементные подмножества какого-либо n-элементного множества. Например, у множества $\{a, b, c, d\}$ из 4 элементов имеется 6 двухэлементных подмножеств

$$\{a, b\}, \{a, c\}, \{a, d\}, \{b, c\}, \{b, d\}, \{c, d\}.$$

Число сочетаний из n по k в $k!$ раз меньше числа размещений без повторений (для тех же n и k), так как из каждого k-сочетания можно сделать $k!$ размещений без повторений, переставляя его элементы. Поэтому из формулы (6.1) следует, что число сочетаний из n по k равно

$$\frac{n!}{k!(n-k)!}. \tag{6.2}$$

Для $k = 0$ эта формула даёт 1, как и должно быть (есть ровно одно пустое подмножество; напомним, что $0! = 1$).

Биномиальные коэффициенты

Для числа сочетаний из n по k используется обозначение C_n^k или (в английской литературе) $\binom{n}{k}$:

$$C_n^k = \binom{n}{k} = \frac{n!}{k!(n-k)!}. \tag{6.3}$$

Эта формула симметрична относительно замены k на $n-k$:

$$C_n^k = C_n^{n-k}. \tag{6.4}$$

Числа C_n^k известны также как **биномиальные коэффициенты** (binomial coefficients), появляющиеся в **биноме Ньютона** (binomial expansion):

$$(x+y)^n = \sum_{k=0}^{n} C_n^k x^k y^{n-k} \tag{6.5}$$

(если раскрыть скобки в $(x+y)^n$, то количество членов, содержащих k множителей x и $n-k$ множителей y, равно количеству способов выбрать k мест из n, т.е. C_n^k).

При $x = y = 1$ бином Ньютона даёт

$$2^n = \sum_{k=0}^{n} C_n^k. \tag{6.6}$$

(Комбинаторный смысл: 2^n двоичных строк длины n сгруппированы по числу единиц: имеется как раз C_n^k строк с k единицами.)

Существует много тождеств с биномиальными коэффициентами (некоторые из них предлагаются в качестве упражнений в конце этого раздела).

Оценки биномиальных коэффициентов

В некоторых случаях нам понадобится оценить величину биномиальных коэффициентов. Для $1 \leqslant k \leqslant n$ имеем оценку снизу

$$\begin{aligned} C_n^k &= \frac{n(n-1)\cdots(n-k+1)}{k(k-1)\cdots 1} \\ &= \left(\frac{n}{k}\right)\left(\frac{n-1}{k-1}\right)\cdots\left(\frac{n-k+1}{1}\right) \\ &\geqslant \left(\frac{n}{k}\right)^k. \end{aligned} \tag{6.7}$$

Используя неравенство $k! \geqslant (\frac{k}{e})^k$, являющееся следствием формулы Стирлинга (2.12), получаем оценку сверху

$$C_n^k = \frac{n(n-1)\cdots(n-k+1)}{k(k-1)\cdots 1}$$

$$\leqslant \frac{n^k}{k!} \tag{6.8}$$

$$\leqslant \left(\frac{en}{k}\right)^k. \tag{6.9}$$

Для всех $0 \leqslant k \leqslant n$ можно по индукции (см. упр. 6.1-12) доказать оценку

$$C_n^k \leqslant \frac{n^n}{k^k(n-k)^{n-k}}, \tag{6.10}$$

где ради удобства записи полагаем $0^0 = 1$. Для $k = \lambda n$, где $0 \leqslant \lambda \leqslant 1$, эта оценка может быть записана как

$$C_n^{\lambda n} \leqslant \frac{n^n}{(\lambda n)^{\lambda n}((1-\lambda)n)^{(1-\lambda)n}}$$

$$= \left(\left(\frac{1}{\lambda}\right)^{\lambda}\left(\frac{1}{1-\lambda}\right)^{1-\lambda}\right)^n \tag{6.11}$$

$$= 2^{nH(\lambda)}, \tag{6.12}$$

где величина

$$H(\lambda) = -\lambda \lg \lambda - (1-\lambda)\lg(1-\lambda) \tag{6.13}$$

называется **(двоичной) шенноновской энтропией**, по-английски (binary) entropy function. В этой записи мы полагаем $0 \lg 0 = 0$, так что $H(0) = H(1) = 0$.

Упражнения

6.1-1 Сколько существует k-подстрок строки длины n? (Подстроки, начинающиеся с различных позиций строки, считаются разными.) каково общее число подстрок строки длины n?

6.1-2 **Булева функция** (boolean function) с n входами и m выходами — это функция, определенная на множестве $\{\text{TRUE}, \text{FALSE}\}^n$ со значениями в множестве $\{\text{TRUE}, \text{FALSE}\}^m$. Сколько существует различных булевых функций с n входами и одним выходом? А булевых функций с n входами и m выходами?

6.1-3 Сколькими способами n (различных) профессоров могут расположиться за круглым столом? Способы, отличающиеся поворотом, считаются одинаковыми.

6.1-4 Сколькими способами можно выбрать три различных числа из множества $\{1, 2, \ldots, 100\}$ так, чтобы их сумма была четной? (Порядок выбора существен.)

6.1-5 Докажите тождество

$$C_n^k = \frac{n}{k} C_{n-1}^{k-1} \tag{6.14}$$

для $0 < k \leqslant n$.

6.1-6 Докажите тождество

$$C_n^k = \frac{n}{n-k} C_{n-1}^k$$

для $0 \leqslant k < n$.

6.1-7 Выбирая k предметов из n, можно отметить один из предметов и следить, выбран он или нет. Используя это обстоятельство, докажите, что

$$C_n^k = C_{n-1}^k + C_{n-1}^{k-1}.$$

6.1-8 Используя результат упражнения 6.1-7, составьте таблицу для C_n^k при $n = 0, 1, 2, \ldots, 6$ и при k от 0 до n в виде равнобедренного треугольника (C_0^0 сверху, C_1^0 и C_1^1 в следующей строке, и так далее). Этот треугольник называют **треугольником Паскаля** (Pascal's triangle).

6.1-9 Докажите равенство

$$\sum_{i=1}^{n} i = C_{n+1}^2.$$

6.1-10 Покажите, что для фиксированного $n \geqslant 0$ величина C_n^k достигает наибольшего (среди всех k от 0 до n) значения при $k = \lfloor n/2 \rfloor$ и при $k = \lceil n/2 \rceil$ (так что для чётного n максимум один, а для нечётного — два стоящих рядом).

6.1-11* Покажите, что для любых $n \geqslant 0$, $j \geqslant 0$, $k \geqslant 0$, $j + k \leqslant n$ выполнено неравенство

$$C_n^{j+k} \leqslant C_n^j C_{n-j}^k$$

с помощью комбинаторных рассуждений, а также с использованием формулы (6.3). В каких случаях это неравенство обращается в равенство?

6.1-12* Докажите по индукции неравенство (6.10) для $k \leqslant n/2$; затем, используя (6.4), докажите его для всех $k \leqslant n$.

6.1-13* Используя формулу Стирлинга, докажите, что

$$C_{2n}^n = \frac{2^{2n}}{\sqrt{\pi n}}(1 + O(1/n)). \tag{6.16}$$

6.1-14* Дифференцируя $H(\lambda)$, покажите, что максимум достигается при $\lambda = 1/2$. Чему равно $H(1/2)$?

6.2 Вероятность

В этом разделе мы напомним основные понятия теории вероятностей.

Пусть задано некоторое множество S, которое мы называем **вероятностным пространством** (sample space), а его элементы — **элементарными событиями** (elementary events). Каждый из элементов может рассматриваться как возможный исход испытания. Например, бросанию двух различных монет соответствует вероятностное пространство, содержащее четыре строки длины 2, составленные из символов О (орёл) и Р (решка):

$$S = \{\text{ОО}, \text{ОР}, \text{РО}, \text{РР}\}$$

Событием (event) называется подмножество пространства S. Например, в нашем примере можно рассмотреть событие *"выпал один орёл и одна решка"*, т.е. множество $\{\text{ОР}, \text{РО}\}$.

Событие S (всё вероятностное пространство) называется **достоверным событием** (certain event), а событие $\varnothing$ называется **невозможным событием** (null event). События A и B называются **несовместными** (mutually exclusive), если $A \cap B = \varnothing$. Каждое элементарное событие $s \in S$ мы будем считать событием $\{s\} \subseteq S$. Различные элементарные события несовместны.

Сказанное относится без оговорок к случаю конечного или счётного множества S. В общем случае определение сложнее, и событиями считаются не все подмножества множества S, а только некоторые. Они должны образовывать σ-алгебру (пересечение и объединение счётного числа событий есть событие; дополнение события есть событие). Мы не будем говорить об этом подробно, хотя некоторые примеры такого рода (равномерное распределение на отрезке) нам встретятся.

Аксиомы вероятности

Распределением вероятностей (probability distribution) на вероятностном пространстве S называется функция P, ставящая в соответствие каждому событию некоторое неотрицательное число и удовлетворяющая следующим требованиям (**аксиомам вероятности**, по-английски probability axioms):

1. $\mathsf{P}A \geqslant 0$ для любого события A.

2. $\mathsf{P}\{S\} = 1$.

3. $\mathsf{P}\{A \cup B\} = \mathsf{P}\{A\} + \mathsf{P}\{B\}$ для любых двух несовместных событий A и B, и, более того,

$$\mathsf{P}\{\cup_i A_i\} = \sum_i \mathsf{P}\{A_i\}.$$

для любой (конечной или счетной) последовательности попарно несовместных событий $A_1, A_2, \ldots$

Число $\mathsf{P}\{A\}$ называется **вероятностью события** A (probability of the event A). Заметим, что аксиома 2 фиксирует *"единицу измерения"* вероятностей, принимая за 1 вероятность достоверного события.

Вот несколько простых следствий из этих аксиом. Невозможное событие имеет нулевую вероятность $\mathsf{P}\{\varnothing\} = 0$. Если $A \subseteq B$, то $\mathsf{P}\{A\} \leqslant \mathsf{P}\{B\}$. Используя обозначение $\overline{A}$ для события $S - A$ (дополнение к A), имеем $\mathsf{P}\{\overline{A}\} = 1 - \mathsf{P}\{A\}$. Для любых двух событий A и B имеет место

$$\begin{aligned} \mathsf{P}\{A \cup B\} &= \mathsf{P}\{A\} + \mathsf{P}\{B\} - \mathsf{P}\{A \cap B\} && (6.17) \\ &\leqslant \mathsf{P}\{A\} + \mathsf{P}\{B\}. && (6.18) \end{aligned}$$

В нашем примере с бросанием двух монет, положим вероятность каждого элементарного исхода равной $1/4$. Тогда вероятность выпадения по крайней мере одного орла будет

$$\begin{aligned} \mathsf{P}\{\text{оо}, \text{ор}, \text{ро}\} &= \mathsf{P}\{\text{оо}\} + \mathsf{P}\{\text{ор}\} + \mathsf{P}\{\text{ро}\} \\ &= 3/4. \end{aligned}$$

Иначе: вероятность того, что не будет ни одного орла, равна $\mathsf{P}\{\text{рр}\} = 1/4$, поэтому вероятность появления по меньшей мере одного орла есть $1 - 1/4 = 3/4$.

6.2.1 Дискретное распределение вероятностей

Распределение вероятностей на конечном или счётном вероятностном пространстве называется **дискретным** (discrete). Для таких распределений можно написать

$$\mathsf{P}\{A\} = \sum_{s \in A} \mathsf{P}\{s\},$$

для любого события A, поскольку оно является объединением не более чем счётного множества несовместных элементарных событий. Если множество S конечно и все элементы его равновероятны, то получается **равномерное распределение вероятностей** (uniform probability distribution) на конечном множестве S. При этом вероятность любого события, включающего в себя k элементарных исходов из $|S|$, равна $k/|S|$. В таких случаях говорят *"выберем случайно элемент $s \in S$"*.

В качестве примера рассмотрим **бросание симметричной монеты** (flipping a fair coin), для которой вероятности орла и решки одинаковы и равны $1/2$. Бросая её n раз, мы приходим к равномерному распределению на пространстве $S = \{\text{О}, \text{Р}\}^n$, состоящем из 2^n элементов. Каждое элементарное событие из S можно рассматривать как строку длины n элементов множества $\{\text{О}, \text{Р}\}$, и все такие строки имеют вероятность $1/2^n$. Событие

$$A = \{\text{выпало } k \text{ орлов и } n-k \text{ решек}\}$$

есть подмножество S и состоит из $|A| = C_n^k$ элементов, так как существует C_n^k строк, содержащих ровно k орлов. Тем самым, вероятность события A равна $\mathsf{P}\{A\} = C_n^k/2^n$.

Непрерывное равномерное распределение вероятностей

Будем считать элементарными исходами точки некоторого отрезка $[a, b]$. Определим вероятность события $[c, d] \subseteq [a, b]$ формулой

$$\mathsf{P}\{[c, d]\} = \frac{d-c}{b-a}.$$

В этом случае, как мы говорили, надо считать событиями не все подмножества отрезка, а только некоторые, которые называют измеримыми. Мы не приводим соответствующих определений, отсылая читателя к любому учебнику по теории вероятностей или по теории меры.

Заметим, что вероятность каждой точки равна 0, и потому вероятность полуинтервала $(c, d]$ и интервала (c, d) могут быть определены той же формулой.

Такое распределение вероятностей называют **непрерывным равномерным распределением** (continuous uniform probability distribution).

Условная вероятность и независимость

Иногда мы располагаем частичной информацией о результате эксперимента. Например, пусть нам известно, что в результате бросания двух симметричных монет по крайней мере одна из них выпала орлом. Какова вероятность того, что обе монеты выпали орлом? Известная нам информация позволяет исключить случай выпадения двух решек. Три оставшихся исхода будут равновероятны, поэтому вероятность каждого (в том числе и интересующего нас) есть $1/3$.

Эта идея формализуется в определении **условной вероятности** (conditional probability) события A при условии события B; она обозначается $\mathsf{P}\{A|B\}$ и определяется формулой

$$\mathsf{P}\{A|B\} = \frac{\mathsf{P}\{A \cap B\}}{\mathsf{P}\{B\}}, \tag{6.19}$$

(мы предполагаем, что $\mathsf{P}\{B\} \neq 0$). Интуитивный смысл понятен: событие B происходит в некоторой доле экспериментов; мы смотрим, какую часть среди них составляют те, когда произошло ещё и событие A.

Два события называются **независимыми** (independent), если

$$\mathsf{P}\{A \cap B\} = \mathsf{P}\{A\}\mathsf{P}\{B\},$$

В случае $\mathsf{P}\{B\} \neq 0$ это условие можно переписать как

$$\mathsf{P}\{A|B\} = \mathsf{P}\{A\}.$$

В нашем примере с двукратным бросанием монеты появления орла при первом и втором бросании будут независимыми, так как каждое событие имеет вероятность $1/2$, а их пересечение (два орла) — $1/4$. В том же примере события *"первая монета выпала орлом"* и *"выпал один орёл и одна решка"* также независимы, хотя это сразу и не так ясно. Но в этом легко убедиться по определению: вероятность каждого события равна $1/2$, вероятность их пересечения равна $1/4$. А вот события *"первая монета выпала орлом"* и *"выпала хоть одна решка"* не будут независимыми.

События *"первая монета выпала орлом"* и *"вторая монета выпала орлом"* перестанут быть независимыми, если изменить распределение вероятностей и считать, что монеты склеены и одновременно выпадают либо орлом, либо решкой (т.е. что комбинации ОО и РР имеют вероятность $1/2$).

События $A_1, A_2, \ldots, A_n$ называются **попарно независимыми** (pairwise independent), если

$$\mathsf{P}\{A_i \cap A_j\} = \mathsf{P}\{A_i\}\mathsf{P}\{A_j\}$$

для всех $1 \leqslant i < j \leqslant n$.

События $A_1, A_2, \cdots, A_n$ называются **независимыми в совокупности** (mutually independent), если для любого набора $A_{i_1}, A_{i_2}, \ldots, A_{i_k}$ этих событий (здесь $2 \leqslant k \leqslant n$ и $1 \leqslant i_1 < i_2 < \cdots < i_k \leqslant n$) имеет место равенство

$$\mathsf{P}\{A_{i_1} \cap A_{i_2} \cap \ldots \cap A_{i_k}\} = \mathsf{P}\{A_{i_1}\}\mathsf{P}\{A_{i_2}\}\cdots\mathsf{P}\{A_{i_k}\}.$$

Это требование — более сильное: например, в нашем примере события *"первая монета выпала орлом"*, *"вторая монета выпала орлом"* и *"две монеты выпали одинаково"* попарно независимы, но не являются независимыми в совокупности.

Формула Байеса

Из определения условной вероятности (6.19) следует, что для двух событий A и B, вероятности которых положительны, выполнено равенство

$$\begin{aligned} \mathrm{P}\{A \cap B\} &= \mathrm{P}\{B\}\mathrm{P}\{A|B\} \\ &= \mathrm{P}\{A\}\mathrm{P}\{B|A\}. \end{aligned} \tag{6.20}$$

Выражая отсюда $\mathrm{P}\{A|B\}$, получаем формулу

$$\mathrm{P}\{A|B\} = \frac{\mathrm{P}\{A\}\mathrm{P}\{B|A\}}{\mathrm{P}\{B\}}, \tag{6.21}$$

известную как **формула Байеса** (Bayes's theorem). Эту формулу можно переписать так: поскольку $B = (B \cap A) \cup (B \cap \overline{A})$, а $B \cap A$ и $B \cap \overline{A}$ — несовместные события, то

$$\begin{aligned} \mathrm{P}\{B\} &= \mathrm{P}\{B \cap A\} + \mathrm{P}\{B \cap \overline{A}\} \\ &= \mathrm{P}\{A\}\mathrm{P}\{B|A\} + \mathrm{P}\{\overline{A}\}\mathrm{P}\{B|\overline{A}\}. \end{aligned}$$

Подставляя данное выражение в формулу (6.21), получаем другой вариант формулы Байеса:

$$\mathrm{P}\{A|B\} = \frac{\mathrm{P}\{A\}\mathrm{P}\{B|A\}}{\mathrm{P}\{A\}\mathrm{P}\{B|A\} + \mathrm{P}\{\overline{A}\}\mathrm{P}\{B|\overline{A}\}}.$$

Формула Байеса помогает вычислять условные вероятности. Пусть у нас есть две монеты: одна симметричная, а другая всегда выпадает орлом. Мы случайным образом выбираем одну из двух монет, после чего её дважды подбрасываем. Предположим, что оба раза выпали орлы. Какова вероятность того, что была выбрана несимметричная монета?

Решим эту задачу при помощи формулы Байеса. Пусть событие A — выбор несимметричной монеты, событие B — выпадение выбранной монеты орлами дважды. Нам нужно вычислить $\mathrm{P}\{A|B\}$. Имеем: $\mathrm{P}\{A\} = 1/2$, $\mathrm{P}\{B|A\} = 1$, $\mathrm{P}\{\overline{A}\} = 1/2$ и $\mathrm{P}\{B|\overline{A}\} = 1/4$, следовательно,

$$\mathrm{P}\{B|A\} = \frac{(1/2) \cdot 1}{(1/2) \cdot 1 + (1/2) \cdot (1/4)} = 4/5.$$

Упражнения

6.2-1 Докажите **неравенство Буля** (Boole's inequality):

$$\mathrm{P}\{A_1 \cup A_2 \cup \ldots\} \leqslant \mathrm{P}\{A_1\} + \mathrm{P}\{A_2\} + \ldots \tag{6.22}$$

для любой конечной или счётной последовательности событий $A_1, A_2, \ldots$.

6.2-2 Профессор бросает симметричную монету, а студент бросает бросает две симметричные монеты. Какова вероятность того, что у профессора выпадет больше орлов, чем у студента? (Все три бросания независимы.)

6.2-3 Колоду карт (с числами от 1 до 10) тасуют и вынимают три карты. Какова вероятность того, что числа на этих картах будут идти в возрастающем порядке?

6.2-4* Имеется несимметричная монета, для которой вероятность выпадения орла есть неизвестное нам число p ($0 < p < 1$). Покажите, как с её помощью можно имитировать симметричную монету, сделав несколько бросаний. (Указание: бросьте монету дважды; если результаты разные, дайте ответ; если одинаковые, повторяйте испытание.)

6.2-5* Как имитировать бросание монеты с вероятностью появления орла a/b, имея симметричную монету, которую можно подбрасывать несколько раз? (Числа a и b целые, $0 < a < b$, математическое ожидание числа бросаний должно быть ограничено сверху полиномом от $\lg b$.)

6.2-6 Докажите, что

$$\mathsf{P}\{A|B\} + \mathsf{P}\{\overline{A}|B\} = 1.$$

6.2-7 Докажите, что для любого набора событий $A_1, A_2, \ldots, A_n$,

$$\mathsf{P}\{A_1 \cap A_2 \cap \ldots \cap A_n\} = \\ = \mathsf{P}\{A_1\} \cdot \mathsf{P}\{A_2|A_1\} \cdot \mathsf{P}\{A_3|A_1 \cap A_2\} \cdots \mathsf{P}\{A_n|A_1 \cap A_2 \cap \cdots \cap A_{n-1}\}.$$

6.2-8* Придумайте множество из n попарно независимых событий, для которого любое подмножество из $k > 2$ событий не будет независимым в совокупности.

6.2-9* События A и B являются **условно независимыми** (conditionally independent) при условии события C, если

$$\mathsf{P}\{A \cap B|C\} = \mathsf{P}\{A|C\} \cdot \mathsf{P}\{B|C\}.$$

Придумайте простой (но не тривиальный) пример двух событий, которые не являются независимыми, но условно независимы при условии некоторого третьего события.

6.2-10* Вы участвуете в игре, в которой приз скрыт за одной из трёх ширм (и выиграете приз, если отгадаете, где). После того как вы выбрали одну из ширм, ведущий игры открыл одну из двух оставшихся ширм, и оказалось, что там приза нет. В этот момент можно поменять свой выбор, указав на третью ширму. Как изменятся шансы на выигрыш, если вы сделаете это?

6.2-11* Начальник тюрьмы выбрал одного из трёх заключённых X, Y и Z, чтобы отпустить его на волю. Остальные двое будут казнены. Страж знает, кто из троих выйдет на свободу, но не имеет права сообщать никакому из узников информацию о его судьбе. Заключенный X просит стража назвать ему имя одного из заключенных Y или Z, который будет казнён, объясняя, что ему и так известно, что один из них точно будет казнён, а, значит, он не получит никакой информации о своей судьбе. Страж сообщает X, что Y будет казнен. Заключённый X радуется, считая, что его шансы остаться в живых возросли до 1/2 (освобождён будет или он, или Z). Прав ли он?

6.3 Дискретные случайные величины

Дискретная случайная величина (discrete random variable) X — это функция, отображающая конечное или счётное вероятностное пространство S в множество действительных чисел. Каждому возможному исходу испытания она ставит в соответствие действительное число. (Тем самым на множестве значений функции X возникает распределение вероятностей.)

В теории вероятностей рассматривают и случайные величины на несчётных вероятностных пространствах, но это сложнее, и мы обойдёмся без них.

Для случайной величины X и действительного числа x определяем событие $X = x$ как $\{s \in S : X(s) = x\}$; вероятность этого события равна

$$\mathsf{P}\{X = x\} = \sum_{\{s \in S : X(s) = x\}} \mathsf{P}\{s\}.$$

Функция

$$f(x) = \mathsf{P}\{X = x\}$$

называется **функцией распределения вероятностей** (probability density function) случайной величины X. Из аксиом вероятности следует, что $\mathsf{P}\{X = x\} \geqslant 0$ и $\sum_x \mathsf{P}\{X = x\} = 1$.

Для примера рассмотрим бросание пары обычных шестигранных костей. Имеется 36 элементарных событий, составляющих вероятностное пространство. Будем предполагать, что все они равновероятны: $\mathsf{P}\{s\} = 1/36$. Определим случайную величину X, как *максимальное число*, выпавшее на одной из двух костей. Тогда

$\mathsf{P}\{X = 3\} = 5/36$, так как X принимает значение 3 при 5 элементарных исходах (а именно, $(1,3)$, $(2,3)$, $(3,3)$, $(3,2)$ и $(3,1)$).

Как правило, на одном и том же вероятностном пространстве рассматривают несколько случайных величин. Если X и Y — случайные величины, то функция

$$f(x, y) = \mathsf{P}\{X = x, Y = y\}$$

называется **функцией совместного распределения вероятностей** (joint probability density function) величин X и Y. Для фиксированного значения y

$$\mathsf{P}\{Y = y\} = \sum_x \mathsf{P}\{X = x,\ Y = y\}.$$

Аналогично, для фиксированного значения x,

$$\mathsf{P}\{X = x\} = \sum_y \mathsf{P}\{X = x,\ Y = y\}.$$

Используя определение условной вероятности (6.19), можно записать

$$\mathsf{P}\{X = x | Y = y\} = \frac{\mathsf{P}\{X = x,\ Y = y\}}{\mathsf{P}\{Y = y\}}.$$

Две случайные величины называются **независимыми** (independent), если события $X = x$ и $Y = y$ являются независимыми для любых значений x и y, другими словами, если если $\mathsf{P}\{X = x,\ Y = y\} = \mathsf{P}\{X = x\}\mathsf{P}\{Y = y\}$ для всех x и y.

Складывая и умножая случайные величины, определённые на одном и том же вероятностном пространстве, мы получаем новые случайные величины, определённые на том же пространстве.

Математическое ожидание случайной величины

Простейшая и наиболее часто используемая характеристика случайной величины — это её **среднее** (mean), называемое также **математическим ожиданием** (expected value, expectation). Для дискретной случайной величины X оно определяется формулой

$$\mathsf{M}[X] = \sum_x x\mathsf{P}\{X = x\}, \tag{6.23}$$

и существует, когда этот ряд имеет конечное число членов или абсолютно сходится. Иногда математическое ожидание обозначается μ_X или просто μ, если из контекста ясно, о какой случайной величине идет речь.

Пусть в игре дважды бросают симметричную монету; вы получаете 3 рубля за каждого выпавшего орла и отдаёте 2 рубля за каждую выпавшую решку. Выигрыш X будет случайной величиной, и её математическое ожидание будет равно

$$\begin{aligned}\mathsf{M}[X] &= 6 \cdot \mathsf{P}\{2 \text{ орла}\} + 1 \cdot \mathsf{P}\{1 \text{ орёл и } 1 \text{ решка}\} - 4 \cdot \mathsf{P}\{2 \text{ решки}\} \\ &= 6(1/4) + 1(1/2) - 4(1/4) \\ &= 1.\end{aligned}$$

Математическое ожидание суммы случайных величин равно сумме их ожиданий:

$$\mathsf{M}[X+Y] = \mathsf{M}[X] + \mathsf{M}[Y], \tag{6.24}$$

если $\mathsf{M}[X]$ и $\mathsf{M}[Y]$ определены. Это правило можно распространить на любые конечные и абсолютно сходящиеся бесконечные суммы.

Пусть X — случайная величина, а $g(x)$ — произвольная функция. Тогда можно рассмотреть случайную величину $g(X)$ (на том же вероятностном пространстве). Её математическое ожидание (если оно определено) можно найти по формуле

$$\mathsf{M}[g(X)] = \sum_x g(x)\mathsf{P}\{X = x\}.$$

Для функции $g(x) = ax$, где a — некоторая константа, имеем

$$\mathsf{M}[aX] = a\mathsf{M}[X]. \tag{6.25}$$

Два последних свойства можно скомбинировать в одной формуле (свойство линейности): для любых двух случайных величин X и Y и любой константы a

$$\mathsf{M}[aX+Y] = a\mathsf{M}[X] + \mathsf{M}[Y]. \tag{6.26}$$

Если две случайные величины X и Y независимы и их математические ожидания определены, то

$$\begin{aligned}\mathsf{M}[XY] &= \sum_x \sum_y xy\mathsf{P}\{X = x, Y = y\} \\ &= \sum_x \sum_y xy\mathsf{P}\{X = x\}\mathsf{P}\{Y = y\} \\ &= (\sum_x x\mathsf{P}\{X = x\})(\sum_y y\mathsf{P}\{Y = y\}) \\ &= \mathsf{M}[X]\mathsf{M}[Y].\end{aligned}$$

Более общо, если имеется n независимых в совокупности случайных величин $X_1, X_2, \ldots, X_n$, имеющих математические ожидания, то

$$\mathsf{M}[X_1 X_2 \cdots X_n] = \mathsf{M}[X_1]\mathsf{M}[X_2] \cdots \mathsf{M}[X_n]. \tag{6.27}$$

Если случайная величина X может принимать только натуральные значения $(0, 1, 2, \ldots)$, то имеется красивая формула для её математического ожидания:

$$\begin{aligned}\mathsf{M}[X] &= \sum_{i=0}^{\infty} i\mathsf{P}\{X = i\} \\ &= \sum_{i=0}^{\infty} i(\mathsf{P}\{X \geqslant i\} - \mathsf{P}\{X \geqslant i+1\}) \\ &= \sum_{i=1}^{\infty} \mathsf{P}\{X \geqslant i\}. \qquad (6.28)\end{aligned}$$

В самом деле, каждый член $\mathsf{P}\{X \geqslant i\}$ присутствует в сумме i раз со знаком плюс и $i-1$ раз со знаком минус (исключение составляет член $\mathsf{P}\{X \geqslant 0\}$, вовсе отсутствующий в сумме).

Дисперсия и стандартное отклонение

Дисперсия (variance) случайной величины X с математическим ожиданием $\mathsf{M}[X]$ определяется как

$$\begin{aligned}\mathsf{D}[X] &= \mathsf{M}[(X - \mathsf{M}[X])^2] \\ &= \mathsf{M}[X^2 - 2X\mathsf{M}[X] + \mathsf{M}^2[X]] \\ &= \mathsf{M}[X^2] - 2\mathsf{M}[X\mathsf{M}[X]] + \mathsf{M}^2[X] \\ &= \mathsf{M}[X^2] - 2\mathsf{M}^2[X] + \mathsf{M}^2[X] \\ &= \mathsf{M}[X^2] - \mathsf{M}^2[X]. \qquad (6.29)\end{aligned}$$

Переходы $\mathsf{M}[\mathsf{M}^2[X]] = \mathsf{M}^2[X]$ и $\mathsf{M}[X\mathsf{M}[X]] = \mathsf{M}^2[X]$ законны, так как $\mathsf{M}[X]$ — это число (а не случайная величина) и можно сослаться на (6.25), полагая $a = \mathsf{M}[X]$. Формулу (6.29) можно переписать так:

$$\mathsf{M}[X^2] = \mathsf{D}[X] + \mathsf{M}^2[X] \qquad (6.30)$$

При увеличении случайной величины в a раз её дисперсия растёт в a^2 раз:

$$\mathsf{D}[aX] = a^2\mathsf{D}[X].$$

Если X и Y независимы, то

$$\mathsf{D}[X + Y] = \mathsf{D}[X] + \mathsf{D}[Y].$$

Более общо, дисперсия суммы n попарно независимых случайных величин $X_1, \ldots, X_n$ равна сумме их дисперсий:

$$\mathsf{D}\left[\sum_{i=1}^{n} X_i\right] = \sum_{i=1}^{n} \mathsf{D}[X_i]. \qquad (6.31)$$

Стандартным отклонением (standard deviation) случайной величины X называется квадратный корень из её дисперсии. Часто стандартное отклонение случайной величины обозначается σ_X или просто σ, если из контекста ясно, о какой случайной величине идет речь. В этой записи дисперсия обозначается σ^2.

Упражнения

6.3-1 Подбрасываются две обычные шестигранные кости. Чему равно математическое ожидание суммы выпавших чисел? Чему равно математическое ожидание максимума из двух выпавших чисел?

6.3-2 В массиве $A[1\,..\,n]$ имеется n расположенных в случайном порядке различных чисел; все возможные расположения чисел равновероятны. Чему равно математическое ожидание номера места, на котором находится максимальный элемент? Номера места, на котором находится минимальный элемент?

6.3-3 В коробочке лежат три игральные кости. Игрок ставит доллар на одно из чисел от 1 до 6. Коробочка встряхивается и открывается. Если названное игроком число не выпало вовсе, то он проигрывает свой доллар. В противном случае он сохраняет его и получает дополнительно столько долларов, сколько выпало костей с названным им числом. Сколько в среднем выигрывает игрок в одной партии?

6.3-4* Пусть X и Y — независимые случайные величины. Покажите, что $f(X)$ и $g(Y)$ также независимы для любых функций f и g.

6.3-5* Пусть X — неотрицательная случайная величина с математическим ожиданием $\mathsf{M}[X]$. Докажите **неравенство Маркова** (Markov's inequality)

$$\mathsf{P}\{X \geqslant t\} \leqslant \mathsf{M}[X]/t \tag{6.32}$$

для всех $t > 0$. [Это неравенство называют также **неравенством Чебышёва**.]

6.3-6* Пусть S — вероятностное пространство, на котором определены случайные величины X и X', причём $X(s) \geqslant X'(s)$ для всех $s \in S$. Докажите, что для любого действительного числа t,

$$\mathsf{P}\{X \geqslant t\} \geqslant \mathsf{P}\{X' \geqslant t\}.$$

6.3-7 Что больше: математическое ожидание квадрата случайной величины или квадрат её математического ожидания?

6.3-8 Покажите, что для случайной величины, принимающей только значения 0 и 1, выполнено равенство $D[X] = \mathsf{M}[X]\mathsf{M}[1-X]$.

6.3-9 Выведите из определения дисперсии (6.29), что $\mathsf{D}[aX] = a^2\mathsf{D}[X]$.

6.4 Геометрическое и биномиальное распределения

Бросание симметричной монеты — частный случай **испытаний по схеме Бернулли** (Bernouilli trials) в которой рассматривается n независимых в совокупности испытаний, каждое из которых имеет два возможных исхода: **успех** (success), происходящий с вероятностью p, и **неудачу** (failure), имеющую вероятность $1-p$. Два важных распределения вероятностей — геометрическое и биномиальное — связаны со схемой Бернулли.

Геометрическое распределение

Рассмотрим серию испытаний Бернулли, в каждом из которых успех имеет вероятность p (а неудача имеет вероятность $q = 1 - p$). Какое испытание будет первым успешным? Пусть случайная величина X — его номер; эта величина принимает значения $1, 2, \ldots$, причём

$$\mathsf{P}\{X = k\} = q^{k-1}p \tag{6.33}$$

(первый успех будет иметь номер k, если $k-1$ испытаний до него были неудачными, а k-е оказалось удачным). Распределение вероятностей, заданное формулой (6.33), называется **геометрическим распределением** (geometric distribution). Оно показано на рис. 6.1.

Предполагая, что $p < 1$, найдём математическое ожидание геометрического распределения, используя формулу (3.6):

$$\mathsf{M}[X] = \sum_{k=1}^{\infty} kq^{k-1}p = \frac{p}{q}\sum_{k=0}^{\infty} kq^k = \frac{p}{q}\cdot\frac{q}{(1-q)^2} = 1/p. \tag{6.34}$$

Другими словами, нужно в среднем $1/p$ раз провести испытание, чтобы добиться успеха, что естественно ожидать, поскольку вероятность успеха равна p. Дисперсию можно вычислить аналогичным образом; получится, что

$$\mathsf{D}[X] = q/p^2. \tag{6.35}$$

Пример: будем бросать пару костей, пока в сумме не выпадет или семь или одиннадцать. Для одного эксперимента есть 36 возможных

Рисунок 6.1 Геометрическое распределение с вероятностью успеха $p = 1/3$ и вероятностью неудачи $q = 1 - p$. Математическое ожидание равно $1/p = 3$.

исходов, в 6 из них получается семь и в 2 получается одиннадцать. Поэтому вероятность успеха p равна $8/36 = 2/9$, и нам в среднем придётся $1/p = 9/2 = 4{,}5$ раза бросить кости, чтобы выпало семь или одиннадцать.

Биномиальное распределение

Рассмотрим n испытаний по схеме Бернулли с вероятностью успеха p и вероятностью неудачи $q = 1 - p$. Пусть случайная величина X — количество успехов в n испытаниях. Её значение может быть равно $0, 1, \ldots, n$, и

$$\mathsf{P}\{X = k\} = C_n^k p^k (1-p)^{n-k}, \tag{6.36}$$

для любого $k = 0, 1, \ldots, n$ так как имеется C_n^k способов выбрать из n испытаний k удачных, и вероятность каждого такого случая будет $p^k q^{n-k}$. Распределение (6.36) называют **биномиальным** (binomial distribution). Для биномиальных распределений мы используем обозначение

$$b(k; n, p) = C_n^k p^k (1-p)^{n-k}. \tag{6.37}$$

Пример биномиального распределения показан на рисунке 6.2. Название "биномиальное" связано с тем, что правая часть фор-

Рисунок 6.2 Биномиальное распределение $b(k; 15; 1/3)$, порождаемое $n = 15$ испытаниями по схеме Бернулли, каждое из которых имеет вероятность успеха $p = 1/3$. Математическое ожидание равно $np = 5$.

мулы (6.37) — это k-й член бинома Ньютона $(p+q)^n$. Вспоминая, что $p + q = 1$, получаем

$$\sum_{k=0}^{n} b(k; n, p) = 1, \tag{6.38}$$

как и должно быть (аксиома 2).

Математическое ожидание для случайной величины, имеющей биномиальное распределение, можно вычислить с помощью (6.14) и (6.38). Пусть X — случайная величина, имеющая биномиальное распределение $b(k; n, p)$. Положим $q = 1 - p$. По определению математического ожидания, имеем

$$\begin{aligned} \mathsf{M}[X] &= \sum_{k=0}^{n} k b(k; n, p) \\ &= \sum_{k=1}^{n} k C_n^k p^k q^{n-k} \\ &= np \sum_{k=1}^{n} C_{n-1}^{k-1} p^{k-1} q^{n-k} \\ &= np \sum_{k=0}^{n-1} C_{n-1}^{k} p^k q^{(n-1)-k} \\ &= np \sum_{k=0}^{n-1} b(k; n-1, p) \\ &= np. \end{aligned} \tag{6.39}$$

Тот же самый результат почти без вычислений можно получить так: пусть X_i — количество успехов в i-м испытании (которое равно 0 с вероятностью q и равно 1 с вероятностью p). Тогда $\mathsf{M}[X_i] = p \cdot 1 + q \cdot 0 = p$. Остаётся заметить, что $X = X_1 + \ldots + X_n$, и потому по свойству линейности (6.26)

$$\mathsf{M}[X] = \mathsf{M}\left[\sum_{i=1}^{n} X_i\right] = \sum_{i=1}^{n} \mathsf{M}[X_i] = \sum_{i=1}^{n} p = np.$$

Подобным образом можно вычислить и дисперсию. Из (6.29) следует, что $\mathsf{D}[X_i] = \mathsf{M}[X_i^2] - \mathsf{M}^2[X_i]$. Поскольку X_i принимает лишь значения 0 и 1, то $\mathsf{M}[X_i^2] = \mathsf{M}[X_i] = p$, и, значит,

$$\mathsf{D}[X_i] = p - p^2 = pq. \tag{6.40}$$

Теперь воспользуемся независимостью испытаний и формулой (6.31):

$$\mathsf{D}[X] = \mathsf{D}\left[\sum_{i=1}^{n} X_i\right] = \sum_{i=1}^{n} \mathsf{D}[X_i] = \sum_{i=1}^{n} pq = npq. \tag{6.41}$$

На рисунке 6.2 видно, что $b(k; n, p)$ как функция от k сначала увеличивается, пока k не достигнет значения np, а затем уменьшается. Это можно проверить, вычислив отношение двух последовательных членов:

$$\begin{aligned}
\frac{b(k;n,p)}{b(k-1;n,p)} &= \frac{C_n^k p^k q^{n-k}}{C_n^{k-1} p^{k-1} q^{n-k+1}} \\
&= \frac{n!(k-1)!(n-k+1)!p}{k!(n-k)!n!q} \\
&= \frac{(n-k+1)p}{kq} \\
&= 1 + \frac{(n+1)p-k}{kq}.
\end{aligned} \tag{6.42}$$

Это отношение больше 1, когда $(n+1)p - k$ положительно, так что $b(k;n,p) > b(k-1;n,p)$ при $k < (n+1)p$ (функция растёт), и $b(k;n,p) < b(k-1;n,p)$ при $k > (n+1)p$ (функция убывает). Если число $(n+1)p$ — целое, то функция имеет двойной максимум: в точках $(n+1)p$ и $(n+1)p-1 = np-q$. В противном случае максимум один, и достигается он в целой точке k, лежащей в диапазоне $np - q < k < (n+1)p$.

Следующая лемма даёт верхнюю оценку для биномиального распределения.

Лемма 6.1. *Пусть* $n \geqslant 0$, $0 < p < 1$, $q = 1 - p$, $0 \leqslant k \leqslant n$. *Тогда*

$$b(k; n, p) \leqslant \left(\frac{np}{k}\right)^k \left(\frac{nq}{n-k}\right)^{n-k}.$$

Доказательство. Согласно неравенству (6.10), имеем

$$\begin{aligned} b(k; n, p) &= C_n^k p^k q^{n-k} \\ &\leqslant \left(\frac{n}{k}\right)^k \left(\frac{n}{n-k}\right)^{n-k} p^k q^{n-k} \\ &= \left(\frac{np}{k}\right)^k \left(\frac{nq}{n-k}\right)^{n-k}. \end{aligned}$$

□

Упражнения

6.4-1 Проверьте аксиому 2 для геометрического распределения.

6.4-2 Сколько раз в среднем нужно бросать 6 симметричных монет до выпадения 3 орлов и 3 решек (в одном испытании)?

6.4-3 Покажите, что $b(k; n, p) = b(n - k; n, q)$, где $q = 1 - p$.

6.4-4 Покажите, что максимум биномиального распределения $b(k; n, p)$ примерно равен $1/\sqrt{2\pi npq}$, где $q = 1 - p$.

6.4-5* Покажите, что вероятность не получить ни одного успеха в n независимых испытаниях с вероятностью успеха $1/n$ примерно равна $1/e$. Затем покажите, что вероятность получить ровно один успешный исход также приблизительно равна $1/e$.

6.4-6* Профессор бросает симметричную монету n раз, студент делает то же самое. Покажите, что вероятность того, что число орлов у них будет одинаково, равна $C_{2n}^n/4^n$. (Указание. Если считать орла успехом профессора и неудачей студента, то искомое событие есть появление n успехов среди $2n$ испытаний.) Выведите отсюда тождество

$$\sum_{k=0}^{n} (C_n^k)^2 = C_{2n}^n.$$

6.4-7* Покажите, что для $0 \leqslant k \leqslant n$,

$$b(k; n, 1/2) \leqslant 2^{nH(k/n)-n},$$

где $H(x)$ — функция энтропии (6.13).

6.4-8* Рассмотрим n независимых испытаний. Пусть p_i — вероятность успеха в i-м испытании, а случайная величина X есть количество успехов во всех этих испытаниях. Пусть $p \geqslant p_i$ для всех $i = 1, 2, \ldots, n$. Докажите, что

$$\mathsf{P}\{X < k\} \leqslant \sum_{i=0}^{k-1} b(i; n, p)$$

при любом $k = 1, 2, \ldots, n$.

6.4-9* Рассмотрим случайную величину X, равную числу успехов в n испытаниях с вероятностями успеха $p_1, \ldots, p_n$. Пусть X' — аналогичная случайная величина, для которой вероятности успеха равны $p'_1, \ldots, p'_n$. Пусть $p'_i \geqslant p_i$ при всех i. Докажите, что

$$\mathsf{P}\{X' \geqslant k\} \geqslant \mathsf{P}\{X \geqslant k\}.$$

при любом $k = 0, \ldots, n$

(Указание: можно считать, что результаты второй серии испытаний получаются так: сначала делается первая серия, а потом её результаты корректируются случайным образом в сторону увеличения. Используйте результат упражнения 3.3-6.)

6.5 Хвосты биномиального распределения

В оригинале со звездой!

Во многих задачах важна вероятность не в точности k успехов при биномиальном распределении, а *не менее* k успехов (или не более k успехов). В этом разделе мы исследуем этот вопрос, оценив **хвосты** (tails) биномиального распределения. Такие оценки показывают, что большие отклонения числа успехов от математического ожидания (np) маловероятны.

Сначала получим оценку для правого хвоста распределения $b(k; n, p)$. Оценки для левого хвоста симметричны (успехи меняются местами с неудачами).

Теорема 6.2. *Пусть X — число успехов в серии из n независимых испытаний с вероятностью успеха p. Тогда*

$$\mathsf{P}\{X \geqslant k\} = \sum_{i=k}^{n} b(i; n, p) \leqslant C_n^k p^k.$$

Доказательство. Воспользуемся неравенством (6.15):

$$C_n^{k+i} \leqslant C_n^k C_{n-k}^i.$$

Заметим, что

$$\begin{aligned}
\mathsf{P}\{X \geqslant k\} &= \sum_{i=k}^{n} b(i;n,p) \\
&= \sum_{i=0}^{n-k} b(k+i;n,p) \\
&= \sum_{i=0}^{n-k} C_n^{k+i} p^{k+i}(1-p)^{n-(k+i)} \\
&\leqslant \sum_{i=0}^{n-k} C_n^k C_{n-k}^i p^{k+i}(1-p)^{n-(k+i)} \\
&= C_n^k p^k \sum_{i=0}^{n-k} C_{n-k}^i p^i (1-p)^{(n-k)-i} \\
&= C_n^k p^k \sum_{i=0}^{n-k} b(i;n-k,p) \\
&= C_n^k p^k,
\end{aligned}$$

так как $\sum_{i=0}^{n-k} b(i;n-k,p) = 1$ по формуле (6.38). □

Переписывая это утверждение для левого хвоста, получаем такое

Следствие 6.3. Пусть X — число успехов в серии из n независимых испытаний с вероятностью успеха p. Тогда

$$\mathsf{P}\{X \leqslant k\} = \sum_{i=0}^{k} b(i;n,p) \leqslant C_n^{n-k}(1-p)^{n-k} = C_n^k(1-p)^{n-k}.$$

Наша следующая оценка будет для левого хвоста биномиального распределения: с удалением границы от точки максимума вероятность, приходящаяся на хвост, экспоненциально уменьшается.

Теорема 6.4. *Пусть X — число успехов в серии из n независимых испытаний с вероятностью успеха p и вероятностью неудачи $q = 1-p$. Тогда*

$$\mathsf{P}\{X < k\} = \sum_{i=0}^{k-1} b(i;n,p) < \frac{kq}{np-k} b(k;n,p)$$

при $0 < k < np$.

Доказательство. Мы сравниваем $\sum_{i=0}^{k-1} b(i;n,p)$ с суммой геометрической прогрессии (см. разд. 3.2). Для $i = 1,2,\ldots,k$ формула (6.42) даёт

$$\frac{b(i-1;n,p)}{b(i;n,p)} = \frac{iq}{(n-i+1)p} < \left(\frac{i}{n-i}\right)\left(\frac{q}{p}\right) \leqslant \left(\frac{k}{n-k}\right)\left(\frac{q}{p}\right).$$

Положив
$$x = \left(\frac{k}{n-k}\right)\left(\frac{q}{p}\right) < 1,$$
видим, что в последовательности $b(i;n,p)$ при $0 \leqslant i \leqslant k$ каждый член меньше следующего, умноженного на x. Поэтому интересующая нас сумма (от $i=0$ до $i=k-1$) меньше значения $b(k;n,p)$, умноженного на $x+x^2+x^3+\ldots = x/(1-x)$:
$$\sum_{i=0}^{k-1} b(i;n,p) < \frac{x}{1-x} b(k;n,p) = \frac{kq}{np-k} b(k;n,p).$$
$\square$

При $k \leqslant np/2$ коэффициент $kq/(np-k)$ не превосходит 1, так что $b(k;n,p)$ является оценкой сверху для суммы всех предыдущих членов. Для примера рассмотрим n бросаний симметричной монеты. Положим $p=1/2$ и $k=n/4$. Теорема 6.4 гарантирует, что вероятность появления менее чем $n/4$ орлов меньше вероятности выпадения в точности $n/4$ орлов. (Более того, для любого положительного $r \leqslant n/4$ вероятность появления менее r орлов меньше вероятности появления в точности r орлов.) Теорема 6.4 может быть использована вместе с оценками биномиального распределения сверху, например с леммой 6.1.

Симметричная оценка для правого хвоста выглядит так:

Следствие 6.5. Пусть X — число успехов в серии из n независимых испытаний с вероятностью успеха p и вероятностью неудачи $q = 1-p$. Тогда
$$\mathsf{P}\{X > k\} = \sum_{i=k+1}^{n} b(i;n,p) < \frac{(n-k)p}{k-np} b(k;n,p)$$
при $np < k < n$.

В следующей теореме рассматривается более общий случай: каждое из испытаний имеет свою вероятность успеха.

Теорема 6.6. *Рассмотрим серию из n независимых испытаний; вероятность успеха в i-м из них обозначим p_i (вероятность неудачи q_i равна $1-p_i$). Пусть случайная величина X есть число успехов в серии, и пусть $\mu = \mathsf{M}[X]$. Тогда для $r > \mu$ выполнено неравенство*
$$\mathsf{P}\{X - \mu \geqslant r\} \leqslant \left(\frac{\mu e}{r}\right)^r.$$

Доказательство. Для любого $\alpha > 0$ функция $e^{\alpha x}$ строго возрастает по x, поэтому
$$\mathsf{P}\{X-\mu \geqslant r\} = \mathsf{P}\{e^{\alpha(X-\mu)} \geqslant e^{\alpha r}\},$$

Для оценки правой части мы используем неравенство Маркова (6.32) (а наиболее выгодное значение α подберём позднее):

$$\mathsf{P}\{X-\mu \geqslant r\} \leqslant \mathsf{M}[e^{\alpha(X-\mu)}]e^{-\alpha r}. \tag{6.43}$$

Остаётся оценить $\mathsf{M}[e^{\alpha(X-\mu)}]$ и выбрать значение для α. Рассмотрим случайную величину X_i, равную 1 в случае успеха i-го испытания и 0 в случае его неудачи. Тогда

$$X = \sum_{i=1}^{n} X_i$$

и

$$X-\mu = \sum_{i=1}^{n}(X_i - p_i).$$

Поскольку испытания независимы, то величины X_i независимы. Поэтому величины $e^{\alpha(X_i-p_i)}]$ независимы (упр. 6.3-4), и по формуле (6.27) можно переставить произведение и математическое ожидание:

$$\mathsf{M}[e^{\alpha(X-\mu)}] = \mathsf{M}\left[\prod_{i=1}^{n} e^{\alpha(X_i-p_i)}\right] = \prod_{i=1}^{n}\mathsf{M}[e^{\alpha(X_i-p_i)}].$$

Каждый множитель можно оценить так:

$$\begin{aligned} \mathsf{M}[e^{\alpha(X_i-p_i)}] &= e^{\alpha(1-p_i)}p_i + e^{\alpha(0-p_i)}q_i \\ &= p_i e^{\alpha q_i} + q_i e^{-\alpha p_i} \\ &\leqslant p_i e^{\alpha} + 1 \\ &\leqslant \exp(p_i e^{\alpha}), \end{aligned} \tag{6.44}$$

где $\exp(x)$ обозначает экспоненциальную функцию: $\exp(x) = e^x$. (Мы воспользовались тем, что $\alpha > 0$, $q_i \leqslant 1$, $e^{\alpha q_i} \leqslant e^{\alpha}$ и $e^{-\alpha p_i} \leqslant 1$, а также неравенством (2.7).) Следовательно,

$$\mathsf{M}[e^{\alpha(X-\mu)}] \leqslant \prod_{i=1}^{n}\exp(p_i e^{\alpha}) = \exp(\mu e^{\alpha}),$$

так как $\mu = \sum_{i=1}^{n} p_i$. Таким образом, из неравенства (6.43) следует оценка

$$\mathsf{P}\{X-\mu \geqslant r\} \leqslant \exp(\mu e^{\alpha} - \alpha r). \tag{6.45}$$

Выбирая $\alpha = \ln(r/\mu)$ (см. упр. 6.5-6), получаем

$$\begin{aligned} \mathsf{P}\{X-\mu \geqslant r\} &\leqslant \exp(\mu e^{\ln(r/\mu)} - r\ln(r/\mu)) \\ &= \exp(r - r\ln(r/\mu)) = \frac{e^r}{(r/\mu)^r} = \left(\frac{\mu e}{r}\right)^r. \end{aligned}$$

□

[Формально эта оценка применима при любом $r > \mu$, но её имеет смысл применять только если r больше μ более чем в e раз, иначе правая часть будет больше единицы.]

Теорему 6.6 можно применять и для случая равных вероятностей. При этом $\mu = \mathsf{M}[X] = np$, и получается такое

Следствие 6.7. Пусть X — число успехов в серии из n независимых испытаний по схеме Бернулли с вероятностью успеха p. Тогда

$$\mathsf{P}\{X - np \geqslant r\} = \sum_{k=\lceil np+r\rceil}^{n} b(k; n, p) \leqslant \left(\frac{npe}{r}\right)^r .$$

Упражнения

6.5-1* Что менее вероятно: не получить ни одного орла при n бросаниях симметричной монеты, или получить менее n орлов при $4n$ бросаниях симметричной монеты?

6.5-2* Покажите, что

$$\sum_{i=0}^{k-1} C_n^i a^i < (a+1)^n \frac{k}{na - k(a+1)} b(k; n, a/(a+1))$$

при $a > 0$ и $0 < k < n$.

6.5-3* Докажите, что при $0 < k < np$, где $0 < p < 1$ и $q = 1 - p$, выполнено неравенство

$$\sum_{i=0}^{k-1} p^i q^{n-i} < \frac{kq}{np - k} \left(\frac{np}{k}\right)^k \left(\frac{nq}{n-k}\right)^{n-k} .$$

6.5-4* Покажите, что в условиях теоремы 6.6 выполнено неравенство

$$\mathsf{P}\{\mu - X \geqslant r\} \leqslant \left(\frac{(n-\mu)e}{r}\right)^r ,$$

а в условиях следствия 6.7 выполнено неравенство

$$\mathsf{P}\{np - X \geqslant r\} \leqslant \left(\frac{nqe}{r}\right)^r .$$

6.5-5* Рассмотрим серию из n независимых испытаний; вероятность успеха в i-м из них обозначим p_i (вероятность неудачи q_i равна $1 - p_i$). Пусть случайная величина X есть число успехов в серии, и пусть $\mu = \mathsf{M}[X]$. Докажите, что при $r \geqslant 0$ выполнено неравенство

$$\mathsf{P}\{X - \mu \geqslant r\} \leqslant e^{-r^2/2n}.$$

6.5-6* Покажите, что при выбранном значении $\alpha = \ln(r/\mu)$ правая часть неравенства (6.45) достигает минимума.

6.6 Вероятностный анализ

В этом разделе мы приведём три примера применения разобранных методов оценки вероятностей. Примеры эти таковы: совпадение дней рождений у двух человек среди данных k человек, распределение шаров по урнам и участки повторяющихся исходов при бросании монеты.

6.6.1 Парадокс дня рождения

Парадокс дня рождения (birthday paradox) связан с таким вопросом: сколько человек должно быть в комнате, чтобы с большой вероятностью среди них оказались двое родившихся в один день? Парадокс состоит в том, что ответ значительно меньше числа дней в году, что кажется странным.

Мы считаем, что в году 365 дней и что дни рождения k человек выбираются случайно и независимо друг от друга. Оценим вероятность того, что все дни рождения окажутся различными. Пусть день рождения первого уже выбран; ясно, что день рождения второго совпадёт с ним с вероятностью 1/365. При выбранных (и различных) днях рождения первого и второго вероятность, что у третьего день рождения совпадёт с одним из уже имеющихся, будет 2/365 и так далее. В итоге вероятность того, что у k человек будут различные дни рождения, есть

$$\left(1-\frac{1}{365}\right)\left(1-\frac{2}{365}\right)\ldots\left(1-\frac{k-1}{365}\right).$$

Более формально, пусть n — число дней в году, и пусть A_i — событие *"день рождения $(i+1)$-го человека не совпадает с днями рождения предыдущих i человек"*. Тогда пересечение $B_i = A_1 \cap A_2 \cap \ldots \cap A_{i-1}$ будет событием *"у первых i человек дни рождения различны"*.

Поскольку $B_k = A_{k-1} \cap B_{k-1}$, то из формулы (6.20) получаем соотношение

$$\mathsf{P}\{B_k\} = \mathsf{P}\{B_{k-1}\}\mathsf{P}\{A_{k-1}|B_{k-1}\}. \tag{6.46}$$

Начальное условие: $\mathsf{P}\{B_1\} = 1$.

Условная вероятность $\mathsf{P}\{A_{k-1}|B_{k-1}\}$ равна $(n-k+1)/n$, так как среди n дней имеется $n-(k-1)$ свободных (по условию все предыдущие дни рождения различны). Поэтому

$$
\begin{aligned}
\mathsf{P}\{B_k\} &= \mathsf{P}\{B_1\}\mathsf{P}\{A_1|B_1\}\mathsf{P}\{A_2|B_2\}\cdots\mathsf{P}\{A_{k-1}|B_{k-1}\} \\
&= 1\cdot\left(\frac{n-1}{n}\right)\left(\frac{n-2}{n}\right)\ldots\left(\frac{n-k+1}{n}\right) \\
&= 1\cdot\left(1-\frac{1}{n}\right)\left(1-\frac{2}{n}\right)t\ldots\left(1-\frac{k-1}{n}\right)
\end{aligned}
$$

Теперь из неравенства $1+x \leqslant e^x$ (2.7) следует, что

$$
\begin{aligned}
\mathsf{P}\{B_k\} &\leqslant e^{-1/n}e^{-2/n}e^{-(k-1)/n} \\
&= e^{-(1+2+3+\ldots+(k-1))/n} \\
&= e^{-k(k-1)/2n} \\
&\leqslant 1/2,
\end{aligned}
$$

если $-k(k-1)/2n \leqslant ln(1/2)$. Вероятность того, что все k дней рождений различны, не превосходит $1/2$ при $k(k-1) \geqslant 2n\ln 2$. Решая это квадратное неравенство, получаем $k \geqslant (1+\sqrt{1+(8\ln 2)n})/2$. Для $n = 365$, имеем $k \geqslant 23$. Итак, если в комнате находится не менее 23 человек, то с вероятностью не менее $1/2$ какие-то двое из них родились в один и тот же день. На Марсе, где год состоит из 669 марсианских суток, в комнате должно быть не менее 31 марсианина.

Другой метод анализа

Есть другой, более простой способ получить оценку для родственной задачи. Для каждой пары людей (i,j), находящихся в комнате, рассмотрим случайную величину X_{ij}

$$
X_{ij} = \begin{cases} 1, & \text{если } i \text{ и } j \text{ родились в один день,} \\ 0, & \text{в противном случае.} \end{cases}
$$

Вероятность того, что дни рождения двух данных людей совпадают, равна $1/n$, поэтому по определению математического ожидания (6.23)

$$
\mathsf{M}[X_{ij}] = 1\cdot(1/n) + 0\cdot(1-1/n) = 1/n
$$

при $i \neq k$.

Сумма всех X_{ij} по всем парам $1 \leqslant i < j \leqslant k$ имеет математическое ожидание, равное сумме ожиданий для каждой пары; всего пар $C_k^2 = k(k-1)/2$, так что эта сумма равна $k(k-1)/2n$. Поэтому нужно примерно $\sqrt{2n}$ человек, чтобы математическое ожидание числа пар людей с совпадающими днями рождения сравнялось с 1.

Например, при $n = 365$ и $k = 28$ ожидаемое число пар людей, родившихся в один день, равно $(28 \cdot 27)/(2 \cdot 365) \approx 1{,}0356$. На Марсе для этого требуется 38 марсиан.

Заметим, что мы оценивали две разные вещи: (1) при каком k вероятность события $X = \sum X_{ij} > 0$ больше $1/2$, и (2) при каком k математическое ожидание X больше 1. Формально это разные вопросы (можно заметить лишь, что если вероятность $\mathsf{P}\{X > 0\} > 1/2$, то $\mathsf{M}[X] > 1/2$, так как величина X принимает целые значения). Однако и в том, и в другом случае ответ имеет асимптотику $\Theta(\sqrt{n})$.

6.6.2 Шары и урны

Пусть имеется b урн, пронумерованных от 1 до b. Мы опускаем в них шары: каждый шар с равной вероятностью помещается в одну из урн независимо от предыдущих. Таким образом, с точки зрения любой из урн происходит последовательность испытаний по схеме Бернулли с вероятностью успеха $1/b$ (успех — попадание шара в эту урну). Мы рассмотрим несколько задач, связанных с таким процессом.

Сколько шаров попадёт в данную урну? Количество шаров, попавших в данную урну, описывается биномиальным распределением $b(k; n, 1/b)$. Если всего бросается n шаров, то математическое ожидание числа попавших в урну шаров равно n/b.

Сколько в среднем шаров нужно бросить, пока в данную урну не попадёт шар? Количество бросков до первого попадания в заданную урну имеет геометрическое распределение с вероятностью $1/b$, поэтому ожидаемое число бросков есть $1/(1/b) = b$.

Сколько шаров нужно бросить, чтобы каждая урна содержала по меньшей мере один шар? Будем следить за числом заполненных урн. Вначале оно равно нулю, а затем увеличивается, пока не достигнет b. Обозначим через n_i случайную величину, равную числу попыток, потребовавшихся, чтобы это число возросло от $i-1$ до i. (Таким образом, если вторая и третья попытки пришлись на ту же урну, что первая, а четвёртая — на другую, то $n_1 = 1$, $n_2 = 3$.) Общее число попыток до заполнения всех урн равно $n_1 + n_2 + \ldots + n_b$. Мы вычислим математическое ожидание этой суммы как сумму математических ожиданий. Когда мы ждём заполнения i-й урны, заполнено $i-1$ урн из b и вероятность попасть в незаполненную равна $(b-i+1)/b$. По свойству геометрического распределения математическое ожидание величины n_i обратно этой вероятности и равно $b/(b-i+1)$. Сумма этих величин по всем i равна $b(1/b + 1/(b-1) + \ldots + 1/2 + 1) = b(\ln b + O(1))$. (См. формулу (3.5) для суммы гармонического ряда.)

Итак, требуется сделать в среднем примерно $b \ln b$ бросков, прежде чем в каждой урне появится по шару.

6.6.3 Участки повторяющихся исходов

Пусть мы бросаем симметричную монету n раз. Какое максимальное число идущих подряд орлов мы ожидаем увидеть? Оказывается, ответ на этот вопрос — $\Theta(\lg n)$.

Сначала докажем, что ожидаемая длина наибольшего участка есть $O(\lg n)$. Пусть событие A_{ik} состоит в том, что имеется участок из k или более орлов, начинающийся с i-го бросания. Очевидно,

$$\mathsf{P}\{A_{ik}\} = 1/2^k. \tag{6.47}$$

При $k = 2\lceil \lg n \rceil$ вероятность появления k орлов в данных позициях не превосходит $1/n^2$, а возможных мест (значений i) меньше чем n, так что вероятность появления k орлов подряд (где-нибудь) не больше $1/n$. Теперь математическое ожидание максимального числа идущих подряд орлов оценивается так: это число никогда не превосходит n и почти всегда (с вероятностью $1-1/n$) не превосходит $2\lceil \lg n \rceil$, поэтому ожидание не больше $\lceil 2\lg n \rceil + n\cdot(1/n) = O(\lg n)$.

Вероятность образования участка орлов длины не менее $r\lceil \lg n \rceil$ быстро уменьшается с ростом r (для фиксированной позиции она не больше $2^{-r\lg n} = n^{-r}$, а для всех позиций в сумме она не превосходит $n\cdot n^{-r} = n^{-(r-1)}$.) Например, для $n = 1000$ вероятность появления участка из по меньшей мере $2\lceil \lg n \rceil = 20$ орлов не превосходит $1/n = 1/1000$, а вероятность появления участка $3\lceil \lg n \rceil = 30$ орлов не больше $1/n^2 = 10^{-6}$.

Теперь докажем оценку снизу: ожидаемая длина наибольшего участка есть $\Omega(\lg n)$. Для этого рассмотрим участки длины $\lfloor (\lg n)/2 \rfloor$. Согласно (6.47) вероятность появления такого участка в данной позиции не меньше $1/2^{\lfloor (\lg n)/2 \rfloor} \geqslant 1/\sqrt{n}$, а вероятность его непоявления не больше $1-1/\sqrt{n}$. Разобьём всю последовательность бросаний на непересекающиеся группы, состоящие из $\lfloor (\lg n)/2 \rfloor$ бросаний каждая. (Несколько членов окажутся вне групп, если при делении будет остаток.) Число групп не меньше $2n/\lg n - 1$.

События в разных группах независимы, поэтому вероятность того, что ни одна из этих групп не состоит из одних орлов, не больше

$$\begin{aligned}(1-1/\sqrt{n})^{2n/\lg n - 1} &\leqslant e^{-(2n/\lg n - 1)/\sqrt{n}} \\ &= O(e^{-\lg n}) = O(1/n)\end{aligned}$$

Мы использовали тот факт, что $1 + x \leqslant e^x$ (2.7), а также то, что $(2n/\lg n - 1)/\sqrt{n} \geqslant \lg n - O(1)$.

Итак, с вероятностью не менее $1 - O(1/n)$ длина наибольшего участка подряд идущих орлов не меньше $\lfloor \lg n/2 \rfloor = \Omega(\lg n)$, поэтому математическое ожидание никак не меньше $(1-1/n)\Omega(\lg n) = \Omega(\lg n)$.

Упражнения

6.6-1 Шары бросают в b урн; все бросания независимы друг от друга, и каждый шар равновероятно попадает в любую из урн. Чему равно ожидаемое количество бросаний до момента, когда в одной из урн окажется два шара?

6.6-2* Существенно ли для приведённого нами анализа парадокса дня рождения то, что дни рождения независимы в совокупности, или было бы достаточно их попарной независимости? Объясните свой ответ.

6.6-3* Скольких гостей надо пригласить на вечеринку, чтобы скорее всего оказалось, что по меньшей мере *трое* из них родились в один день?

6.6-4* Какую долю составляют инъекции среди всех отображений k-элементного множества в n-элементное? Как связан этот вопрос с парадоксом дня рождения?

6.6-5* Пусть n шаров бросают в n урн, все бросания независимы, попадания каждого шара во все урны равновероятны. Чему равно ожидаемое количество пустых урн? А ожидаемое количество урн, в которые попало в точности по одному шару?

6.6-6* Улучшите нижнюю оценку для длин участков из одних орлов, показав, что при n бросаниях симметричной монеты участок длины $\lg n - 2\lg\lg n$ найдётся с вероятностью не меньше $1 - 1/n$.

Задачи

6-1 Шары и урны

В этой задаче мы считаем число способов разложить n шаров в b различных урн.

а. Предположим, что все шары разные, их порядок внутри урны не учитывается. Докажите, что существует b^n способов поместить шары в урны.

б. Предположим, что все шары разные и их порядок в урне существен. Докажите, что шары можно разложить по урнам $(b+n-1)!/(b-1)!$ способами. (Указание: подсчитайте число способов расставить n различных шаров и $b-1$ одинаковых чёрточек в ряд.)

в. Предположим, что все шары одинаковы, и их порядок в урне не имеет значения. Покажите, что число способов раскладки шаров по урнам равняется C^n_{b+n-1}. (Указание: используйте ту же идею, что в пункте (б).)

г. Покажите, что если шары одинаковые и в любую урну помещается не больше одного шара, то число способов равно C^n_b.

д. Покажите, что если шары одинаковые и в любой урне должен оказаться по меньшей мере один шар, то число способов раскладки шаров равно C^{b-1}_{n-1}.

6-2 Программа вычисления максимума

Рассмотрим такую программу поиска максимума в неупорядоченном массиве $A[1\,..\,n]$.

```
1 max ← −∞
2 for i ← 1 to n
3     do ▷ Сравнить A[i] с max.
4        if A[i] > max
5           then max ← A[i]
```

Мы хотим определить, сколько раз в среднем выполняется присваивание в строке 5. Предполагается, что числа в массиве A различны и расположены в случайном порядке (все перестановки равновероятны).

а. Если число x случайно выбрано из i различных чисел, то с какой вероятностью оно окажется максимальным числом среди них?

б. Как соотносится $A[i]$ с предыдущими элементами массива для тех i, при которых выполняется строка 5?

в. Чему равна вероятность выполнения строки 5 программы для данного значения i?

г. Пусть s_i — случайная величина, равная 1 или 0 в зависимости от того, выполнялась строка 5 на i-м шаге цикла или нет. Чему равно $\mathsf{M}[s_i]$?

д. Пусть $s = s_1+s_2+\dots+s_n$ — общее число присваиваний в строке 5 при исполнении всей программы. Покажите, что $\mathsf{M}[s] = \Theta(\lg n)$.

6-3 Проблема выбора

Заведующая кафедрой принимает на работу нового сотрудника. Она назначила собеседования n претендентам и хочет выбрать наиболее квалифицированного из них. Однако университетские правила требуют, чтобы после беседы претенденту сразу сообщалось, принят он или нет.

Для этого она применяет такое правило. Сначала она говорит с первыми k претендентами, отказывая им независимо от их квалификации. Если среди оставшихся есть более квалифицированный, чем первые k, то первый из таковых принимается. Если нет, принимается последний из претендентов. Покажите, что вероятность выбрать таким способом лучшего из претендентов будет максимальна (и равна примерно $1/e$), если k примерно равно n/e.

6-4 Вероятностный счётчик

С помощью t-битного счётчика мы можем считать до $2^t - 1$. Следующий приём **вероятностного подсчёта** (probabilistic counting, R. Morris) даёт возможность вести счёт до куда больших значений, правда ценою некоторой потери точности.

Выберем возрастающую последовательность целых неотрицательных чисел n_i (где i меняется от 0 до 2^t-1). Её смысл таков: если значение t-битного регистра равно i, то это означает, что подсчитываемое количество (число выполненных операций Increment) примерно равно n_i. Мы считаем, что $n_0 = 0$.

Операция Increment увеличивает значение счетчика, содержащего i, с некоторой вероятностью. Именно, число i увеличивается на 1 с вероятностью $1/(n_{i+1} - n_i)$, и остается неизменным в остальных случаях. (Если $i = 2^t - 1$, то происходит переполнение.) Идея проста: в среднем для увеличения i на единицу потребуется как раз $n_{i+1} - n_i$ операций.

Если $n_i = i$ для всех $i \geqslant 0$, то получаем обычный счётчик. Более интересные ситуации возникают, если выбрать, например, $n_i = 2^{i-1}$ для $i > 0$ или $n_i = F_i$ (i-е число Фибоначчи, см. разд. 2.2).

Мы будем предполагать, что n_{2^t-1} достаточно велико, и пренебрегать возможностью переполнения.

а. Покажите, что математическое ожидание содержимого счётчика после выполнения n операций Increment, в точности равно n.

б. Дисперсия случайной величины, равной содержимому счётчика после n операций Increment, зависит от выбора последовательности $n_0, n_1, \ldots$. Найдите эту дисперсию для случая $n_i = 100i$.

Замечания

Общие методы решения вероятностных задач обсуждались в знаменитой переписке Паскаля (B. Pascal) и Ферма (P. de Fermat), начавшейся в 1654 году, и в книге Гюйгенса (C. Huygens, 1657). Более строгое изложение теории вероятностей было дано в работах Бернулли (J. Bernoulli, 1713) и Муавра (A. De Moivre, 1730). Дальнейшее развитие теории вероятностей связано с именами Лапласа (P. S. de Laplace), Пуассона (S.-D. Poisson) и Гаусса (C. F. Gauss).

Суммы случайных величин исследовались П. Л. Чебышёвым и А. А. Марковым (старшим). В 1933 году А. Н. Колмогоров сформулировал аксиомы теории вероятностей. Оценки хвостов распределений приводят Чернов [40] и Хофдинг [99]. Важные результаты о случайных комбинаторных структурах принадлежат Эрдёшу (P. Erdös).

Литература по теме главы: Кнут [121], Лю [140] (хорошие пособия по элементарной комбинаторике и подсчету); Биллингсли [28], Чанг [41], Дрейк [57], Феллер [66], Розанов [171] (стандартные учебники по теории вероятностей); Боллобас [30], Хофри [100], Спенсер [179] (техника вероятностного анализа).

II Сортировка и порядковые статистики

Введение

В этой части мы рассмотрим несколько алгоритмов, решающих **задачу сортировки** (sorting problem). Исходным данным для этой задачи является последовательность чисел $\langle a_1, a_2, \ldots, a_n \rangle$. Результатом должна быть последовательность $\langle a'_1, a'_2, \ldots, a'_n \rangle$, состоящая из тех же чисел, идущих в неубывающем порядке: $a'_1 \leqslant a'_2 \leqslant \cdots \leqslant a'_n$. Обычно исходная последовательность задана как массив, хотя возможны и другие варианты (например, связанный список).

Структура сортируемых объектов

На практике редко требуется упорядочивать числа как таковые. Обычно надо сортировать **записи** (records), содержащие несколько полей, и располагать их в порядке, определяемым одним из полей. [Например, в архиве отдела кадров для каждого сотрудника фирмы может храниться запись, содержащая различные поля (фамилия, имя, отчество, год рождения, адрес и т. п.), и в какой-то момент может понадобиться упорядочить все записи по годам рождения.] Поле, по которому проводится сортировка (год рождения в нашем примере), называется **ключом** (key), а остальные поля — дополнительными данными (satellite data). Можно представлять себе дело так: алгоритм сортирует ключи, но вместе с каждым ключом перемещаются (без изменения) дополнительные данные, с ним связанные. (Если этих данных много, разумно перемещать не сами данные, а лишь указатель на них.)

Все эти подробности мы не рассматриваем, ограничиваясь задачей сортировки ключей. Приводимые нами алгоритмы являются, таким образом, лишь *"скелетом"* реальной программы, к которому нужно добавить обработку дополнительных данных (что обычно не сложно, хотя и хлопотно).

Алгоритмы сортировки

Мы уже встречались в главе 1 с двумя алгоритма, сортирующими n чисел за время $\Theta(n^2)$ в худшем случае. Их простота, однако, делает их эффективными для сортировки небольшого массива без дополнительной памяти (in place). (Имеется в виду, что мы не имеем права заводить ещё одного массива, но переменные для чисел использовать можно). Алгоритм сортировки слиянием имеет лучшую асимптотическую оценку времени работы, но он требует дополнительного массива.

В этой части книги мы рассмотрим ещё два алгоритма сортировки вещественных чисел. Первый из них называется *"сортировкой с помощью кучи"* (heapsort). Здесь *"куча"* — некоторая структура данных, имеющая много приложений (одно из них, очереди с приоритетами, мы также рассмотрим в главе 7). Этот алгоритм не требует дополнительного массива и работает за время $\Theta(n \lg n)$ в худшем случае.

В главе 8 строится другой алгоритм, называемый *"быстрой сортировкой"* (quicksort). В худшем случае он требует времени $\Theta(n^2)$, но в среднем — лишь $\Theta(n \lg n)$, и на практике он обычно быстрее сортировки с помощью кучи (его внутренний цикл прост, поэтому константа в асимптотической оценке меньше).

Все эти алгоритмы (сортировки вставками, слиянием, с помощью кучи и быстрая сортировка) используют только попарные сравнения объектов, но не их внутреннюю структуру. В главе 9 мы показываем, что любая сортировка такого вида в худшем случае требует времени $\Omega(n \lg n)$, введя подходящую формальную модель (разрешающие деревья). Тем самым становится ясным, что сортировки слиянием и с помощью кучи асимптотически оптимальны.

Однако эта нижняя оценка не распространяется на алгоритмы, использующие внутреннюю структуру данных. В главе 9 рассматривается несколько примеров такого рода. Сортировка подсчётом (counting sort) позволяет отсортировать n целых чисел в диапазоне от 1 до k за время $O(n+k)$, используя сортируемые числа как индексы в массиве размера k. Если $k = O(n)$, время сортировки становится пропорциональным размеру массива. Родственный алгоритм, называемый *"цифровой сортировкой"*, применяет сходный приём поразрядно, и позволяет отсортировать n целых чисел, каждое из которых имеет d разрядов в k-ичной системе счисления, за время $O(d(n+k))$. Если считать, что d постоянно, а k есть $O(n)$, то общее время есть $O(n)$. Третий алгоритм такого рода, сортировка вычёрпыванием, предполагает, что сортируемые числа равномерно распределены на отрезке и независимы, и в среднем требует $O(n)$ действий для n чисел.

Порядковые статистики

Если нам надо найти i-й по величине элемент массива, можно сначала отсортировать массив, что требует времени $\Omega(n \lg n)$, если не пользоваться внутренней структурой элементов (глава 9). Но при этом выполняется лишняя работа (сортировка остальных элементов), и можно построить более эффективные алгоритмы для задачи отыскания i-го по величине элемента (которую называют также задачей о порядковых статистиках). В главе 10 приводятся два таких алгоритма: один требует времени $O(n^2)$ в худшем случае и $O(n)$ в среднем; другой, более сложный, обходится временем $O(n)$ в худшем случае.

Используемые сведения из математики

Большая часть материала глав 7–10 доступна читателю с минимальной математической подготовкой. Однако вероятностный анализ алгоритмов (быстрой сортировки, сортировки вычёрпыванием и отыскания i-го по величине элемента) требует знакомства с теорией вероятностей (глава 6). Добавим, что алгоритм отыскания i-го элемента за линейное время (в худшем случае) более сложен, чем другие алгоритмы этой главы.

7 Сортировка с помощью кучи

В этой главе рассмотрен алгоритм **сортировки с помощью кучи** (heapsort). Как и алгоритм сортировки слиянием, он требует времени $O(n \lg n)$ для сортировки n объектов, но обходится дополнительной памятью размера $O(1)$ (вместо $O(n)$ для сортировки слиянием). Таким образом, этот алгоритм сочетает преимущества двух ранее рассмотренных алгоритмов — сортировки слиянием и сортировки вставками.

Структура данных, которую использует алгоритм (она называется *"двоичной кучей"*) оказывается полезной и в других ситуациях. В частности, на её базе можно эффективно организовать очередь с приоритетами (см. разд. 7.5). В следующих главах нам встретятся алгоритмы, использующие сходные структуры данных (биномиальные кучи, фибоначчиевы кучи).

Термин *"куча"* иногда используют в другом смысле (область памяти, где данные размещаются с применением автоматической *" сборки мусора"* — например, в языке Lisp), но мы этого делать не будем.

7.1 Кучи

Двоичной кучей (binary heap) называют массив с определёнными свойствами упорядоченности, Чтобы сформулировать эти свойства, будем рассматривать массив как двоичное дерево (рис. 7.1). Каждая вершина дерева соответствует элементу массива. Если вершина имеет индекс i, то её родитель имеет индекс $\lfloor i/2 \rfloor$ (вершина с индексом 1 является корнем), а её дети — индексы $2i$ и $2i+1$. Будем считать, что куча может не занимать всего массива и хранить массив A, его длину $length[A]$ и специальный параметр $heap\text{-}size[A]$ (размер кучи), причём $heap\text{-}size[A] \leqslant length[A]$. Куча состоит из элементов $A[1], \ldots, A[heap\text{-}size[A]]$. Движение по дереву осуществляется процедурами

Рисунок 7.1 Кучу можно рассматривать как дерево (а) или как массив (б). Внутри вершины показано её значение. Около вершины показан её индекс в массиве.

Parent(i)
    return $\lfloor i/2 \rfloor$

Left(i)
    return $2i$

Right(i)
    return $2i + 1$

Элемент $A[1]$ является корнем дерева.

В большинстве компьютеров для выполнения процедур Left и Parent можно использовать команды левого и правого сдвига (Left, Parent); Right требует левого сдвига, после которого в младший разряд помещается единица.

Элементы, хранящиеся в куче, должны обладать **основным свойством кучи** (heap property): для каждой вершины i, кроме корня (т.е. при $2 \leqslant i \leqslant \textit{heap-size}[A]$),

$$A[\textsc{Parent}(i)] \geqslant A[i]. \tag{7.1}$$

Отсюда следует, что значение потомка не превосходит значения предка. Таким образом, наибольший элемент дерева (или любого поддерева) находится в корневой вершине дерева (этого поддерева).

Высотой (height) вершины дерева называется высота поддерева с корнем в этой вершине (число рёбер в самом длинном пути с началом в этой вершине вниз по дереву к листу). Высота дерева, таким образом, совпадает с высотой его корня. В дереве, составляющем кучу, все уровни (кроме, быть может, последнего), заполнены полностью. Поэтому высота этого дерева равна $\Theta(\lg n)$, где n — число элементов в куче (см. упр. 7.1-2). Как мы увидим ниже, время работы основных операций над кучей пропорционально высоте дерева и, следовательно, составляет $O(\lg n)$. Оставшаяся часть главы посвящена анализу этих операций и применению кучи в задачах сортировки и моделирования очереди с приоритетами. Перечислим основные операции над кучей:

- Процедура Heapify позволяет поддерживать основное свойство (7.1). Время работы составляет $O(\lg n)$.
- Процедура Build-Heap строит кучу из исходного (неотсортированного) массива. Время работы $O(n)$.
- Процедура Heapsort сортирует массив, не используя дополнительной памяти. Время работы $O(n \lg n)$.
- Процедуры Extract-Max (взятие наибольшего) и Insert (добавление элемента) используются при моделировании очереди с приоритетами на базе кучи. Время работы обеих процедур составляет $O(\lg n)$.

Упражнения

7.1-1 Пусть куча имеет высоту h. Сколько элементов может в ней быть? (Укажите максимальное и минимальное значения.)

7.1-2 Докажите, что куча из n элементов имеет высоту $\lfloor \lg n \rfloor$.

7.1-3 Докажите, что при выполнении основного свойства кучи корневая вершина любого поддерева является наибольшей в этом поддереве.

7.1-4 Где может находиться наименьший элемент кучи, если все её элементы различны?

7.1-5 Пусть массив отсортирован в обратном порядке (первый элемент — наибольший). Является ли такой массив кучей?

7.1-6 Является ли кучей массив $\langle 23, 17, 14, 6, 13, 10, 1, 5, 7, 12 \rangle$?

7.2 Сохранение основного свойства кучи

Процедура Heapify — важное средство работы с кучей. Её параметрами являются массив A и индекс i. Предполагается, что поддеревья с корнями $\text{Left}(i)$ и $\text{Right}(i)$ уже обладают основным свойством. Процедура переставляет элементы поддерева с вершиной i, после чего оно обладает основным свойством. Идея проста: если это свойство не выполнено для вершины i, то её следует поменять с бо́льшим из её детей и т. д., пока элемент $A[i]$ не *"подгрузится"* до нужного места.

Рисунок 7.2 Работа процедуры HEAPIFY$(A, 2)$ при *heap-size*$[A] = 10$. (а) Начальное состояние кучи. В вершине $i = 2$ основное свойство нарушено. Чтобы восстановить его, необходимо поменять $A[2]$ и $A[4]$. После этого (б) основное свойство нарушается в вершине с индексом 4. Рекурсивный вызов процедуры HEAPIFY$(A, 4)$ восстанавливает основное свойство в вершине с индексом 4 путём перестановки $A[4] \leftrightarrow A[9]$ (в). После этого основное свойство выполнено для всех вершин, так что процедура HEAPIFY$(A, 9)$ уже ничего не делает.

```
HEAPIFY(A, i)
 1  l ← LEFT(i)
 2  r ← RIGHT(i)
 3  if l ⩽ heap-size[A] и A[l] > A[i]
 4     then largest ← l
 5     else  largest ← i
 6  if r ⩽ heap-size[A] и A[r] > A[largest]
 7     then largest ← r
 8  if largest ≠ i
 9     then обменять A[i] ↔ A[largest]
10          HEAPIFY(A, largest)
```

Работа процедуры HEAPIFY показана на рис. 7.2. В строках 3–7 в переменную *largest* помещается индекс наибольшего из элементов $A[i]$, $A[\text{LEFT}(i)]$ и $A[\text{RIGHT}(i)]$. Если $largest = i$, то элемент $A[i]$ уже *"погрузился"* до нужного места, и работа процедуры закончена. Иначе процедура меняет местами $A[i]$ и $A[largest]$ (что обеспечивает выполнение свойства (7.1) в вершине i, но возможно, нарушает это свойство в вершине *largest*) и рекурсивно вызывает себя для вершины *largest*, чтобы исправить возможные нарушения.

Оценим время работы процедуры Heapify. На каждом шаге требуется произвести $\Theta(1)$ действий, не считая рекурсивного вызова. Пусть $T(n)$ — время работы для поддерева, содержащего n элементов. Если поддерево с корнем i состоит из n элементов, то поддеревья с корнями $\text{Left}(i)$ и $\text{Right}(i)$ содержат не более чем по $2n/3$ элементов каждое (наихудший случай — когда последний уровень в поддереве заполнен наполовину). Таким образом,

$$T(n) \leqslant T(2n/3) + \Theta(1)$$

Из теоремы 4.1 (случай 2) получаем, что $T(n) = O(\lg n)$. Эту же оценку можно получить так: на каждом шаге мы спускаемся по дереву на один уровень, а высота дерева есть $O(\lg n)$.

Упражнения

7.2-1 Покажите, следуя образцу рис. 7.2, как работает процедура $\text{Heapify}(A, 3)$ для массива $\langle 27, 17, 3, 16, 13, 10, 1, 5, 7, 12, 4, 8, 9, 0\rangle$.

7.2-2 Пусть элемент $A[i]$ больше, чем его дети. Каков будет результат вызова процедуры $\text{Heapify}(A, i)$?

7.2-3 Пусть $i > \textit{heap-size}[A]/2$. Каков будет результат вызова процедуры $\text{Heapify}(A, i)$?

7.2-4 Измените процедуру Heapify, заменив рекурсию циклом. (Некоторые компиляторы при этом порождают более эффективный код.)

7.2-5 Докажите, что наибольшее время работы процедуры Heapify для кучи из n элементов равно $\Omega(\lg n)$. (Указание: приведите пример, когда процедура вызывается для каждой вершины на пути от корня к листу).

7.3 Построение кучи

Пусть дан массив $A[1\,..\,n]$, который мы хотим превратить в кучу, переставив его элементы. Для этого можно использовать процедуру Heapify, применяя её по очереди ко всем вершинам, начиная с нижних. Поскольку вершины с номерами $\lfloor n/2\rfloor + 1, \ldots, n$ являются листьями, поддеревья с этими вершинами удовлетворяют основному свойству. Для каждой из оставшихся вершин, в порядке убывания индексов, мы применяем процедуру Heapify. Порядок обработки вершин гарантирует, что каждый раз условия вызова процедуры (выполнение основного свойства для поддеревьев) будут выполнены.

```
Build-Heap(A)
heap-size[A] ← length[A]
for i ← ⌊length[A]/2⌋ downto 1
     do Heapify(A, i)
```

Пример работы процедуры Build-Heap показан на рис. 7.3.

Ясно, что время работы процедуры Build-Heap не превышает $O(n \lg n)$. Действительно, процедура Heapify вызывается $O(n)$ раз, а каждое её выполнение требует времени $O(\lg n)$. Однако эту оценку можно улучшить, чем мы сейчас и займёмся.

Дело в том, что время работы процедуры Heapify зависит от высоты вершины, для которой она вызывается (и пропорционально этой высоте). Поскольку число вершин высоты h в куче из n элементов не превышает $\lceil n/2^{h+1} \rceil$ (см. упр. 7.3-3), а высота все кучи не превышает $\lfloor \lg n \rfloor$ (упр. 7.1-2), время работы процедуры Build-Heap не превышает

$$\sum_{h=0}^{\lfloor \lg n \rfloor} \left\lceil \frac{n}{2^{h+1}} \right\rceil O(h) = O\left(n \sum_{h=0}^{\lfloor \lg n \rfloor} \frac{h}{2^h} \right) \tag{7.2}$$

Полагая $x = 1/2$ в формуле (3.6), получаем верхнюю оценку для суммы в правой части:

$$\sum_{h=0}^{\infty} \frac{h}{2^h} = \frac{1/2}{(1-1/2)^2} = 2.$$

Таким образом, время работы процедуры Build-Heap составляет

$$O\left(n \sum_{h=0}^{\infty} \frac{h}{2^h} \right) = O(n).$$

Упражнения

7.3-1 Покажите, следуя образцу рис. 7.3, как работает процедура Build-Heap для массива $A = \langle 5, 3, 17, 10, 84, 19, 6, 22, 9 \rangle$.

7.3-2 Почему в процедуре Build-Heap существенно, что параметр i пробегает значения от $\lfloor length[A]/2 \rfloor$ до 1 (а не наоборот)?

7.3-3 Докажите, что куча из n элементов содержит не более $\lceil n/2^{h+1} \rceil$ вершин высоты h.

Рисунок 7.3 Работа процедуры Build-Heap. Показано состояние данных перед каждым вызовом процедуры Heapify в строке 3.

7.4 Алгоритм сортировки с помощью кучи

Алгоритм сортировки с помощью кучи состоит из двух частей. Сначала вызывается процедура BUILD-HEAP, после выполнения которой массив является кучей. Идея второй части проста: максимальный элемент массива теперь находится в корне дерева ($A[1]$). Его следует поменять с $A[n]$, уменьшить размер кучи на 1 и восстановить основное свойство в корневой вершине (поскольку поддеревья с корнями LEFT(1) и RIGHT(1) не утратили основного свойства кучи, это можно сделать с помощью процедуры HEAPIFY). После этого в корне будет находиться максимальный из оставшихся элементов. Так делается до тех пор, пока в куче не останется всего один элемент.

```
HEAPSORT(A)
1  BUILD-HEAP(A)
2  for i ← length[A] downto 2
3       do поменять A[1] ↔ A[i]
4          heap-size[A] ← heap-size[A] − 1
5          HEAPIFY(A, 1)
```

Работа второй части алгоритма показана на рис. 7.4. Изображены состояния кучи перед каждым выполнением цикла **for** (строка 2).

Время работы процедуры HEAPSORT составляет $O(n \lg n)$. Действительно, первая часть (построение кучи) требует времени $O(n)$, а каждое из $n-1$ выполнений цикла **for** занимает время $O(\lg n)$.

Упражнения

7.4-1 Покажите, следуя образцу рис. 7.4, как работает процедура HEAPSORT для массива $A = \langle 5, 13, 2, 25, 7, 17, 20, 8, 4 \rangle$.

7.4-2 Пусть исходный массив A уже отсортирован в порядке возрастания. Каково будет время сортировки с помощью кучи? А если массив был отсортирован в порядке убывания?

7.4-3 Докажите, что время работы процедуры HEAPSORT составляет $\Omega(n \lg n)$.

7.5 Очереди с приоритетами

На практике алгоритм сортировки с помощью кучи не является самым быстрым — как правило, быстрая сортировка (гл. 8) работает быстрее. Однако сама куча как структура данных часто ока-

Рисунок 7.4 Работа процедуры Heapsort. Показано состояние массива перед каждым вызовом процедуры Heapify. Зачернённые элементы уже не входят в кучу.

зывается полезной. В этом разделе мы рассмотрим моделирование очереди с приоритетами на базе кучи — один из самых известных примеров использования кучи.

Очередь с приоритетами (priority queue) — это множество S, элементы которого мы будем считать числами. На практике элементами множества S являются пары $\langle key, \alpha \rangle$, где key — число, определяющее приоритет элемента и называемое **ключом** (key). а α — связанная с ним информация; эта информация хранится рядом с элементом и перемещается вместе с ним, не влияя на его обработку.

Возможны следующие операции над очередью с приоритетами:

Insert(S, x): добавление элемента x к множеству S;

Maximum(S): наибольший элемент множества;

EXTRACT-MAX(S): изъятие из множества наибольшего элемента.

Очередь с приоритетами может, например, использоваться в операционной системе с разделением времени. При этом хранится список заданий с приоритетами; как только выполнение очередного задания заканчивается, из очереди выбирается задание с наибольшим приоритетом (операция EXTRACT-MAX). Новые задания добавляются в очередь с помощью операции INSERT.

Другое применение той же структуры — управляемое событиями моделирование (event-driven simulation). В очереди находятся события, а приоритет определяется временем, когда событие должно произойти. Разумеется, события должны моделироваться в том порядке, в котором они происходят. Выбор очередного события производится с помощью операции EXTRACT-MIN (порядок здесь обратный), добавление событий — с помощью операции INSERT.

Опишем теперь реализацию очереди с приоритетами. Будем хранить элементы множества в виде кучи. При этом максимальный элемент находится в корне, так что операция MAXIMUM требует времени $\Theta(1)$. Чтобы изъять максимальный элемент из очереди, нужно действовать так же, как и при сортировке:

HEAP-EXTRACT-MAX(A)

if $\textit{heap-size}[A] < 1$
    then ошибка: *"очередь пуста"*
$\textit{max} \leftarrow A[1]$
$A[1] \leftarrow A[\textit{heap-size}[A]]$
$\textit{heap-size}[A] \leftarrow \textit{heap-size}[A] - 1$
HEAPIFY($A, 1$)
return $\textit{max}$

Время работы составляет $O(\lg n)$ (процедура HEAPIFY вызывается один раз).

Чтобы добавить элемент к очереди, его следует добавить в конец кучи (как лист), а затем дать ему *"всплыть"* до нужного места:

HEAP-INSERT(A, $\textit{key}$)

$\textit{heap-size}[A] \leftarrow \textit{heap-size}[A] + 1$
$i \leftarrow \textit{heap-size}[A]$
while $i > 1$ и $A[\text{PARENT}(i)] < \textit{key}$
    do $A[i] \leftarrow A[\text{PARENT}(i)]$
        $i \leftarrow \text{PARENT}(i)$
$A[i] \leftarrow \textit{key}$

Пример работы процедуры HEAP-INSERT показан на рис. 7.5. Время работы составляет $O(\lg n)$, поскольку *"подъём"* нового листа занимает не более $\lg n$ шагов (индекс i после каждой итерации цикла **while** уменьшается по крайней мере вдвое).

Итак, все операции над очередью с приоритетами из n элементов

Рисунок 7.5 Работа процедуры Heap-Insert. Добавляется элемент с ключевым значением 15 (темный кружок означает место для этого элемента).

требуют времени $O(\lg n)$.

Упражнения

7.5-1 Покажите, следуя образцу рис. 7.5, как работает процедура Heap-Insert$(A, 3)$ для кучи $A = \langle 15, 13, 9, 5, 12, 8, 7, 4, 0, 6, 2, 1 \rangle$.

7.5-2 Покажите на рисунках, как работает процедура Heap-Extract-Max для кучи из предыдущего упражнения.

7.5-3 Объясните, как реализовать обычную очередь (first-in, first-out) и стек на базе очереди с приоритетами. (Определения см. в разд. 11.1).

7.5-4 Реализуйте процедуру Heap-Increase-Key(A, i, k) (увеличение элемента), которая увеличивает элемент $A[i]$ до k, если он был меньше k ($A[i] \leftarrow \max(A[i], k)$) и восстанавливает основное свойство кучи. Время работы — $O(\lg n)$.

7.5-5 Реализуйте операцию Heap-Delete(A, i) — удаление элемента с индексом i из кучи. Время работы $O(\lg n)$.

7.5-6 Придумайте алгоритм, который позволяет за время $O(n \lg k)$ слить k отсортированных списков в один отсортированный список (здесь n — общее число элементов в списках). (Указание: используйте кучу.)

Задачи

7-1 Построение кучи с помощью вставок

Можно построить кучу, последовательно добавляя элементы с помощью процедуры Heap-Insert. Рассмотрим следующий алгоритм:

```
Build-Heap′(A)
heap-size[A] ← 1
for i ← 2 to length[A]
     do Heap-Insert(A, A[i])
```

а. Запустим процедуры Build-Heap и Build-Heap′ для одного и того же массива. Всегда ли они создадут одинаковые кучи? (Докажите или приведите контрпример.)

б. Докажите, что время работы процедуры Build-Heap′ в худшем случае составляет $\Theta(n \lg n)$ (где n — количество элементов).

7-2 Работа с d-ичными кучами

Рассмотрим **d-ичную кучу** (d-ary heap), в которой вершины имеют d детей вместо двух.

а. Как выглядят для такой кучи процедуры, аналогичные Parent, Left и Right?

б. Как высота d-ичной кучи из n элементов выражается через n и d?

в. Реализуйте процедуру Extract-Max. Каково время её работы (выразите его через n и d)?

г. Реализуйте процедуру Insert. Каково время её работы?

д. Реализуйте процедуру Heap-Increase-Key (упр. 7.5-4). Каково время её работы?

Замечания

Алгоритм сортировки с помощью кучи предложил Уильямс [202]; там же описана реализация очереди с приоритетами на базе кучи. Процедура Build-Heap предложена Флойдом [69].

8 Быстрая сортировка

В этой главе рассмотрен так называемый алгоритм *"быстрой сортировки"*. Хотя время его работы для массива из n чисел в худшем случае составляет $\Theta(n^2)$, на практике этот алгоритм является одним из самых быстрых: математическое ожидание времени работы составляет $\Theta(n \lg n)$, причём множитель при $n \lg n$ довольно мал. Кроме того, быстрая сортировка не требует дополнительной памяти и сохраняет эффективность для систем с виртуальной памятью.

В разделе 8.1 описывается алгоритм в целом и процедура разделения массива на части. Оценка эффективности алгоритма довольно сложна; в разделе 8.2 приводятся интуитивные доводы, а строгий анализ отложен до раздела 8.4. В разделе 8.3 описаны варианты быстрой сортировки, использующие генератор случайных чисел. При этом время работы в худшем случае (при неудачном случайном выборе) составляет $O(n^2)$, но среднее время работы составляет лишь $O(n \lg n)$. (Говоря о среднем времени, мы имеем в виду не усреднение по всем входам, а математическое ожидание времени работы, которое *для любого входа* не превосходит $O(n \log n)$.) Один из вариантов вероятностного алгоритма быстрой сортировки подробно анализируется в разделе 8.4, где доказаны оценки для среднего и наибольшего времени работы.

8.1 Описание быстрой сортировки

Быстрая сортировка (quicksort), как и сортировка слиянием, основана на принципе *"разделяй и властвуй"* (см. разд. 1.3.1). Сортировка участка $A[p\,..\,r]$ происходит так:

- Элементы массива A переставляются так, чтобы любой из элементов $A[p], \ldots, A[q]$ был не больше любого из элементов $A[q+1], \ldots, A[r]$, где q — некоторое число в интервале $p \leqslant q < r$. Эту операцию мы будем называть разделением (partition).
- Процедура сортировки рекурсивно вызывается для массивов $A[p\,..\,q]$ и $A[q+1\,..\,r]$.

После этого массив $A[p\,..\,r]$ отсортирован.

Итак, процедура сортировки Quicksort выглядит следующим образом:

```
Quicksort(A, p, r)
if p < r
   then q ← Partition(A, p, r)
        Quicksort(A, p, q)
        Quicksort(A, q + 1, r)
```

Для сортировки всего массива необходимо выполнить процедуру Quicksort$(A, 1, \mathit{length}[A])$.

Разбиение массива

Основной шаг алгоритма — процедура Partition, которая переставляет элементы массива $A[p\,..\,r]$ нужным образом:

```
Partition(A, p, r)
 1  x ← A[p]
 2  i ← p − 1
 3  j ← r + 1
 4  while TRUE
 5      do repeat j ← j − 1
 6            until A[j] ⩽ x
 7         repeat i ← i + 1
 8            until A[i] ⩾ x
 9         if i < j
10            then поменять A[i] ↔ A[j]
11            else return j
```

Работа процедуры Partition показана на рис. 8.1. Элемент $x = A[p]$ выбирается в качестве *"граничного"*; массив $A[p\,..\,q]$ будет содержать элементы, не большие x, а массив $A[q+1\,..\,r]$ — элементы, не меньшие x. Идея состоит в том, чтобы накапливать элементы, не большие x, в начальном отрезке массива ($A[p\,..\,i]$), а элементы, не меньшие x — в конце ($A[j\,..\,r]$). В начале оба *"накопителя"* пусты: $i = p - 1$, $j = r + 1$.

Внутри цикла **while** (в строках 5–8) к начальному и конечному участкам присоединяются элементы (как минимум по одному). После выполнения этих строк $A[i] \geqslant x \geqslant A[j]$. Если мы поменяем $A[i]$ и $A[j]$ местами, то их можно будет присоединить к начальному и конечному участкам.

В момент выхода из цикла выполнено неравенство $i \geqslant j$. При этом массив разбит на части $A[p], \ldots, A[j]$ и $A[j+1], \ldots, A[r]$; любой элемент первой части не превосходит любого элемента второй

Рисунок 8.1 Работа процедуры PARTITION. Незакрашенные элементы относятся к уже сформированным кускам, закрашенные ещё не распределены. (а) Начальное состояние массива, начальный и конечный куски пусты. Элемент $x = A[p] = 5$ используется в качестве граничного. (б) Результат первого прохода цикла **while** (строки 4–8). (в) Элементы $A[i]$ и $A[j]$ меняются местами (строка 10). (г) Результат второго прохода цикла **while**. (д) Результат третьего (последнего) прохода цикла **while**. Поскольку $i \geqslant j$, процедура останавливается и возвращает значение $q = j$. Элементы слева от $A[j]$ (включая сам этот элемент) не больше, чем $x = 5$, а элементы справа от $A[j]$ не меньше, чем $x = 5$.

части. Процедура возвращает значение j.

Хотя идея процедуры очень проста, сам алгоритм содержит ряд тонких моментов. Например, не очевидно, что индексы i и j не выходят за границы промежутка $[p\,..\,r]$ в процессе работы. Другой пример: важно, что в качестве граничного значения выбирается $A[p]$, а не, скажем, $A[r]$. В последнем случае может оказаться, что $A[r]$ — самый большой элемент массива, и в конце выполнения процедуры будет $i = j = r$, так что возвращать $q = j$ будет нельзя — нарушится требование $q < r$, и процедура QUICKSORT зациклится. Правильность процедуры PARTITION составляет предмет задачи 8-1.

Время работы процедуры PARTITION составляет $\Theta(n)$, где $n = r - p + 1$ (см. упр. 8.1-3).

Упражнения

8.1-1 Покажите, следуя образцу рис. 8.1, как работает процедура PARTITION для массива $A = \langle 13, 19, 9, 5, 12, 8, 7, 4, 11, 2, 6, 21 \rangle$.

8.1-2 Пусть все элементы массива $A[p\,..\,r]$ равны. Какое значение вернёт процедура PARTITION?

8.1-3 Приведите простое соображение, объясняющее, почему время работы процедуры PARTITION составляет $\Theta(n)$.

8.1-4 Как отсортировать массив в порядке убывания (а не возрастания), используя те же методы?

8.2 Работа быстрой сортировки

Время работы алгоритма быстрой сортировки зависит от того, как разбивается массив на каждом шаге. Если разбиение происходит на примерно равные части, время работы составляет $O(n \lg n)$, как и для сортировки слиянием. Если же размеры частей сильно отличаются, сортировка может занимать время $O(n^2)$, как при сортировке вставками.

Наихудшее разбиение

"*Наиболее неравные части*" получатся, если одна часть содержит $n-1$ элемент, а вторая — всего 1. (Как мы увидим в разделе 8.4.1, это наихудший случай с точки зрения времени работы.) Предположим, что на каждом шаге происходит именно так. Поскольку процедура разбиения занимает время $\Theta(n)$, для времени работы $T(n)$ получаем соотношение

$$T(n) = T(n-1) + \Theta(n)$$

Поскольку $T(1) = \Theta(1)$, имеем

$$T(n) = T(n-1) + \Theta(n) = \sum_{k=1}^{n} \Theta(k) = \Theta\left(\sum_{k=1}^{n} k\right) = \Theta(n^2)$$

(последняя сумма — арифметическая прогрессия, см. формулу (3.2)). Дерево рекурсии для этого случая показано на рис. 8.2. (По поводу деревьев рекурсии см. разд. 4.2.)

Мы видим, что при максимально несбалансированном разбиении время работы составляет $\Theta(n^2)$, как и для сортировки вставками. В частности, это происходит, если массив изначально отсортирован (заметим, что в этом случае сортировка вставками производится за время $\Theta(n)$).

Наилучшее разбиение

Если на каждом шаге массив разбивается ровно пополам, быстрая сортировка требует значительно меньше времени. Действительно, в этом случае рекуррентное соотношение имеет вид

$$T(n) = 2T(n/2) + \Theta(n)$$

и, согласно теореме 4.1 (случай 2), $T(n) = \Theta(n \lg n)$. Дерево рекурсии для этого случая показано на рисунке 8.3.

Рисунок 8.2 Дерево рекурсии процедуры Quicksort для наихудшего случая (процедура Partition каждый раз производит разбиение, в котором одна из частей содержит один элемент). Время работы равно $\Theta(n^2)$.

Рисунок 8.3 Дерево рекурсии процедуры Quicksort для наилучшего случая (массив каждый раз разбивается пополам). Время работы равно $\Theta(n \lg n)$.

Промежуточный случай

Как будет показано в разделе 8.4, среднее время работы (с точностью до множителя) совпадает с временем работы в наилучшем случае. Чтобы объяснить это, посмотрим, как меняется рекуррентное соотношение в зависимости от степени сбалансированности разбиения.

Пусть, например, на каждом шаге массив разбивается на две части с отношением размеров $9:1$. Тогда

$$T(n) = T(9n/10) + T(n/10) + n$$

(для удобства мы заменили $\Theta(n)$ на n). Дерево рекурсии показано на рисунке 8.4. На каждом уровне мы производим не более n действий, так что время работы определяется глубиной рекурсии.

Рисунок 8.4 Дерево рекурсии для случая, когда разбиение каждый раз производится в отношении 9 : 1. Время работы равно $\Theta(n \lg n)$.

В данном случае эта глубина равна $\log_{10/9} n = \Theta(\lg n)$, так что время работы по-прежнему составляет $\Theta(n \lg n)$, хотя константа и больше. Ясно, что для любого фиксированного отношения размеров частей (сколь бы велико оно ни было) глубина дерева рекурсии по-прежнему будет логарифмической, а время работы будет равно $\Theta(n \lg n)$.

Среднее время: интуитивные соображения

Чтобы вопрос о среднем времени работы имел смысл, нужно уточнить, с какой частотой появляются различные входные значения. Как правило, предполагается, что все перестановки входных значений равновероятны. (Мы вернёмся к этому в следующем разделе.)

Для наугад взятого массива разбиения вряд ли будут всё время происходить в одном и том же отношении — скорее всего, часть разбиений будет хорошо сбалансирована, а часть нет. Как показывает упр. 8.2-5, примерно 80 процентов разбиений производятся в отношении не более 9 : 1.

Будем предполагать для простоты, что на каждом втором уровне все разбиения наихудшие, а на оставшейся половине уровней наилучшие (пример показан на рис. 8.5(a)). Поскольку после каждого *”хорошего”* разбиения размер частей уменьшается вдвое, число *”хороших”* уровней равно $\Theta(\lg n)$, а поскольку каждый второй уровень *”хороший”*, общее число уровней равно $\Theta(\lg n)$, а время работы — $\Theta(n \lg n)$. Таким образом, плохие уровни не испортили асимптотику времени работы (а лишь увеличили константу, скрытую в асимпто-

Рисунок 8.5 (а) Два уровня: плохой (n разбивается на $n-1$ и 1) и хороший ($n-1$ разбивается на две равные части). (б) Если эти два уровня заменить одним, получится разбиение на почти равные по величине части.

тическом обозначении).

Упражнения

8.2-1 Докажите, что если массив состоит из одинаковых элементов, то время работы процедуры Quicksort равно $\Theta(n \lg n)$.

8.2-2 Пусть массив отсортирован в порядке убывания. Докажите, что время работы процедуры Quicksort составляет $\Theta(n^2)$.

8.2-3 Как правило, в банках обрабатывают чеки в порядке их поступления; клиенты же предпочитают, чтобы в отчёте платежи были указаны в порядке номеров чеков. Владелец чековой книжки обычно выписывает чеки подряд, а получатели чеков предъявляют их в банк вскоре после выписывания. Таким образом, порядок номеров нарушается незначительно. Следовательно, банку требуется отсортировать почти отсортированный массив. Объясните, почему сортировка вставками в таких случаях работает быстрее, чем быстрая сортировка.

8.2-4 Пусть разбиения на каждом шаге производятся в отношении $\alpha : 1-\alpha$, где $0 < \alpha \leqslant 1/2$. Докажите, что минимальная глубина листа на дереве рекурсии примерно равна $-\lg n / \lg \alpha$, а максимальная примерно равна $-\lg n / \lg(1-\alpha)$. (Не заботьтесь об округлении.)

8.2-5* Докажите, что для любого числа α в интервале $0 < \alpha \leqslant 1/2$ вероятность того, что разбиение случайного массива будет сбалансировано не хуже, чем $\alpha : 1-\alpha$, примерно равна $1-2\alpha$. При каком значении α вероятность этого события равна $1/2$?

8.3 Вероятностные алгоритмы быстрой сортировки

Ранее мы предположили, что все перестановки входных значений равновероятны. Если это так, а размер массива достаточно велик, быстрая сортировка — один из наиболее эффективных алгоритмов. На практике, однако, это предположение (равной вероятности всех перестановок на входе) не всегда оправдано (см. упр. 8.2-3). В этом разделе мы введём понятие вероятностного алгоритма и рассмотрим два вероятностных алгоритма быстрой сортировки, которые позволяют отказаться от предположения о равной вероятности всех перестановок.

Идея состоит в привнесении случайности, обеспечивающем нужное распределение. Например, перед началом сортировки можно случайно переставить элементы, после чего уже все перестановки станут равновероятными (это можно сделать за время $O(n)$ — см. упр. 8.3-4). Такая модификация не увеличивает существенно время работы, но теперь математическое ожидание времени работы не зависит от порядка элементов во входном массиве (они всё равно случайно переставляются).

Алгоритм называется **вероятностным** (randomized), если он использует **генератор случайных чисел** (random-number generator). Мы будем считать, что генератор случайных чисел Random работает так: Random(a, b) возвращает с равной вероятностью любое целое число в интервале от a до b. Например, Random$(0, 1)$ возвращает 0 или 1 с вероятностью $1/2$. При этом разные вызовы процедуры независимы в смысле теории вероятностей. Можно считать, что мы каждый раз бросаем кость с $(b-a+1)$ гранями и сообщаем номер выпавшей грани. (На практике обычно используют **генератор псевдослучайных чисел** (pseudorandom-number generator) — детерминированный алгоритм, который выдаёт числа, *"похожие"* на случайные.)

Для такого вероятностного варианта алгоритма варианта быстрой сортировки нет *"неудобных входов"*: упражнение 13.4-4 показывает, что перестановок, при которых время работы велико, совсем мало — поэтому вероятность того, что алгоритм будет работать долго (для любого конкретного входа) невелика.

Аналогичный подход применим и в других ситуациях, когда в ходе выполнения алгоритма мы должны выбрать один из многих вариантов его продолжения, причём мы не знаем, какие из них хорошие, а какие плохие, но знаем, что хороших вариантов достаточно много. Нужно только, чтобы плохие выборы не разрушали достигнутого при предыдущих хороших (как мы видели в разделе 8.2, для алгоритма быстрой сортировки это так).

Вместо того, чтобы предварительно переставлять элементы массива, мы можем внести элемент случайности в процедуру Partition. Именно, перед разбиением массива $A[p\,..\,r]$ будем менять элемент $A[p]$ со случайно выбранным элементом массива. Тогда каждый элемент с равной вероятностью может оказаться граничным, и в среднем разбиения будут получаться достаточно сбалансированными.

Этот подход заменяет разовую случайную перестановку входов в начале использованием случайных выборов на всём протяжении работы алгоритма. В сущности это то же самое, и оба алгоритма имеют математическое ожидание времени работы $O(n \lg n)$, но небольшие технические различия делают анализ нового варианта проще, и именно он будет рассматриваться в разделе 8.4.

Изменения, которые нужно внести в процедуры, совсем невелики:

```
Randomized-Partition(A, p, r)
i ← Random(p, r)
поменять A[p] ↔ A[i]
return Partition(A, p, r)
```

В основной процедуре теперь будет использоваться Randomized-Partition вместо Partition:

```
Randomized-Quicksort(A, p, r)
if p < r
   then q ← Randomized-Partition(A, p, r)
        Randomized-Quicksort(A, p, q)
        Randomized-Quicksort(A, q + 1, r)
```

Анализом этого алгоритма мы займёмся в следующем разделе.

Упражнения

8.3-1 Почему для вероятностного алгоритма важно не максимальное время работы (для данного входа), а математическое ожидание этого времени?

8.3-2 Сколько раз при выполнении процедуры Randomized-Quicksort может происходить обращение к генератору случайных чисел Random в худшем случае? Изменится ли ответ для наилучшего случая?

8.3-3* Реализуйте процедуру Random(a, b), используя бросания монеты, т.е. датчик, с равной вероятностью выдающий 0 или 1. Каково математическое ожидание времени работы вашей процедуры?

8.3-4* Придумайте вероятностную процедуру, которая за время $\Theta(n)$ случайным образом переставляет элементы входного массива $A[1\,..\,n]$.

8.4 Анализ быстрой сортировки

В этом разделе мы превратим *"интуитивные"* соображения раздела 8.2 в строгое рассуждение. Сначала мы рассмотрим наихудший случай (рассуждения будут одинаковы и для алгоритма Quicksort, и для алгоритма Randomized-Quicksort), а затем найдём среднее время работы алгоритма Randomized-Quicksort.

8.4.1 Анализ наихудшего случая

В разделе 8.2 мы видели, что если разбиение на каждом шаге наиболее несбалансировано, то время работы составляет $\Theta(n^2)$. Интуитивно ясно, что это наихудший (в смысле времени работы) случай. Сейчас мы строго докажем это.

Для доказательства того, что время работы составляет $O(n^2)$, мы используем метод подстановки (см. разд. 4.1). Пусть $T(n)$ — наибольшее время работы алгоритма для массива длины n. Тогда, очевидно,

$$T(n) = \max_{1\leqslant q\leqslant n-1}(T(q) + T(n-q)) + \Theta(n) \tag{8.1}$$

(мы рассматриваем все возможные разбиения на первом шаге). Предположим, что $T(q) \leqslant cq^2$ для некоторой константы c и для всех q, меньших некоторого n. Тогда

$$T(n) \leqslant \max_{1\leqslant q\leqslant n-1}(cq^2+c(n-q)^2)+\Theta(n) = c\cdot\max_{1\leqslant q\leqslant n-1}(q^2+(n-q)^2)+\Theta(n).$$

Квадратный трёхчлен $q^2 + (n-q)^2$ достигает максимума на отрезке $1 \leqslant q \leqslant n-1$ в его концах (вторая производная по q положительна, поэтому функция выпукла вниз, см. упр. 8.4-2). Этот максимум равен $1^2 + (n-1)^2 = n^2 - 2(n-1)$. Отсюда получаем

$$T(n) \leqslant cn^2 - 2c(n-1) + \Theta(n) \leqslant cn^2,$$

если константа c выбрана так, чтобы последнее слагаемое было меньше предпоследнего. Итак, время работы в худшем случае составляет $\Theta(n^2)$.

8.4.2 Анализ среднего времени работы

Как мы уже видели в разделе 8.2, если разбиения производятся так, что отношение размеров частей ограничено, то глубина дерева рекурсии равна $\Theta(\lg n)$, а время работы — $\Theta(n \lg n)$. Чтобы получить оценку среднего времени работы алгоритма Randomized-Quicksort, мы сначала проанализируем работу процедуры Partition, затем получим рекуррентное соотношение на среднее время работы и решим его (попутно получив одну полезную оценку).

Анализ разбиений

Напомним, что перед тем как в строке 3 процедуры Randomized-Partition вызывается процедура Partition, элемент $A[p]$ переставляется со случайно выбранным элементом массива $A[p\,..\,r]$. Для простоты мы будем предполагать, что все числа в массиве различны. Хотя оценка среднего времени сохраняется и в том случае, когда в массиве есть одинаковые элементы, получить её сложнее, и мы этого делать не будем.

Прежде всего, заметим, что значение q, которое возвратит процедура Partition, зависит только от того, сколько в массиве элементов, не больших $x = A[p]$ (число таких элементов мы будем называть **рангом** (rank) элемента x и обозначать $\mathrm{rank}(x)$). Если $n = r - p + 1$ — число элементов в массиве, то, поскольку все элементы имеют равные шансы попасть на место $A[p]$, все значения $\mathrm{rank}(x)$, от 1 до n, равновероятны (имеют вероятность $1/n$).

Если $\mathrm{rank}(x) > 1$, то, как легко видеть, при разбиении левая часть будет содержать $\mathrm{rank}(x) - 1$ элементов — в ней окажутся все элементы, меньшие x. Если же $\mathrm{rank}(x) = 1$, то левая часть будет содержать один элемент (после первого же выполнения цикла будет $i = j = p$). Отсюда следует, что с вероятностью $1/n$ левая часть будет содержать $2, 3, \ldots, n-1$ элементов, а с вероятностью $2/n$ — один элемент.

Рекуррентное соотношение для среднего времени работы

Обозначим среднее время работы алгоритма Randomized-Quicksort для массива из n элементов через $T(n)$. Ясно, что $T(1) = \Theta(1)$. Время работы состоит из времени работы процедуры Partition, которое составляет $\Theta(n)$, и времени работы для двух массивов размера q и $n-q$, причём q с вероятностью $2/n$ принимает значение 1 и с вероятностью $1/n$ — значения $2, \ldots, n-1$. Поэтому

$$T(n) = \frac{1}{n}\left(T(1) + T(n-1) + \sum_{q=1}^{n-1}(T(q) + T(n-q))\right) + \Theta(n) \quad (8.2)$$

(слагаемое, соответствующее $q = 1$, входит дважды). Поскольку $T(1) = \Theta(1)$ и $T(n) = O(n^2)$, имеем

$$\frac{1}{n}(T(1) + T(n-1)) = \frac{1}{n}(\Theta(1) + O(n^2)) = O(n).$$

Поэтому слагаемые $T(1)$ и $T(n-1)$ в первой скобке (8.2) можно включить в $\Theta(n)$. С учётом этого получаем

$$T(n) = \frac{1}{n}\sum_{q=1}^{n-1}(T(q) + T(n-q)) + \Theta(n). \quad (8.3)$$

Поскольку каждое слагаемое $T(k)$, где $k = 1, \ldots, n-1$, встречается в сумме дважды, её можно переписать так:

$$T(n) = \frac{2}{n}\sum_{k=1}^{n-1}T(k) + \Theta(n). \quad (8.4)$$

Решение рекуррентного соотношения

Соотношение (8.4) можно решить, используя метод подстановки. Предположим, что $T(n) \leqslant an\lg n + b$, где константы $a > 0$ и $b > 0$ пока неизвестны, и попытаемся доказать это по индукции. При $n = 1$ это верно, если взять достаточно большие a и b. При $n > 1$ имеем

$$\begin{aligned} T(n) &= \frac{2}{n}\sum_{k=1}^{n-1}T(k) + \Theta(n) \\ &\leqslant \frac{2}{n}\sum_{k=1}^{n-1}(ak\lg k + b) + \Theta(n) \\ &= \frac{2a}{n}\sum_{k=1}^{n-1}k\lg k + \frac{2b}{n}(n-1) + \Theta(n). \end{aligned}$$

Ниже мы покажем, что первую сумму можно оценить так:

$$\sum_{k=1}^{n-1}k\lg k \leqslant \frac{1}{2}n^2\lg n - \frac{1}{8}n^2. \quad (8.5)$$

Используя это, получим

$$\begin{aligned}T(n) &\leqslant \frac{2a}{n}\left(\frac{1}{2}n^2\lg n - \frac{1}{8}n^2\right) + \frac{2b}{n}(n-1) + \Theta(n)\\ &\leqslant an\lg n - \frac{a}{4}n + 2b + \Theta(n)\\ &= an\lg n + b + \left(\Theta(n) + b - \frac{a}{4}n\right) \leqslant an\lg n + b,\end{aligned}$$

если выбрать a так, чтобы $\frac{a}{4}n$ было больше $\Theta(n)+b$. Следовательно, среднее время работы есть $O(n\lg n)$.

Доказательство оценки для суммы

Осталось доказать оценку (8.5). Поскольку каждое слагаемое не превышает $n\lg n$, получаем оценку

$$\sum_{k=1}^{n-1} k\lg k \leqslant n^2\lg n.$$

Для наших целей она не подходит — нам необходима более точная оценка $\frac{1}{2}n^2\lg n - \Omega(n^2)$.

Если в предыдущей оценке заменять лишь $\lg k$ на $\lg n$, оставив k в неприкосновенности, получим оценку

$$\sum_{k=1}^{n-1} k\lg k \leqslant \lg n\sum_{k=1}^{n-1} k = \frac{n(n-1)}{2}\lg n \leqslant \frac{1}{2}n^2\lg n.$$

Осталось лишь заметить, что заменяя $\lg k$ на $\lg n$, мы прибавили по крайней мере по $k \cdot 1$ к каждому слагаемом первой половины суммы (где $k \leqslant n/2$), всего примерно $(n/2)^2/2 = n^2/8$.

Более формально,

$$\sum_{k=1}^{n-1} k\lg k = \sum_{k=1}^{\lceil n/2\rceil-1} k\lg k + \sum_{k=\lceil n/2\rceil}^{n-1} k\lg k$$

При $k < \lceil n/2\rceil$ имеем $\lg k \leqslant \lg(n/2) = \lg n - 1$. Поэтому

$$\begin{aligned}\sum_{k=1}^{n-1} k\lg k &\leqslant (\lg n - 1)\sum_{k=1}^{\lceil n/2\rceil-1} k + \lg n\sum_{k=\lceil n/2\rceil}^{n-1} k\\ &= \lg n\sum_{k=1}^{n-1} k - \sum_{k=1}^{\lceil n/2\rceil-1} k \leqslant \frac{1}{2}n(n-1)\lg n - \frac{1}{2}\left(\frac{n}{2}-1\right)\frac{n}{2}\\ &\leqslant \frac{1}{2}n^2\lg n - \frac{1}{8}n^2\end{aligned}$$

при $n \geqslant 2$. Оценка (8.5) доказана.

[Следующий простой вывод оценки для среднего времени работы вероятностного алгоритма быстрой сортировки (для несколько другого варианта алгоритма) предложил Л.А. Левин.

(1) Будем представлять себе сортировку так: есть N камней разного веса и чашечные весы для их сравнения. Мы берём случайный камень и делим всю кучу на три части: легче его, тяжелее его и он сам, после чего (рекурсивный вызов) сортируем первую и вторую части.

(2) Как выбрать случайный камень? Можно считать, что сначала всем камням случайно присваиваются различные ранги (будем считать их числами от 1 до N), и в качестве границы берётся камень минимального ранга (из подлежащих сортировке в данный момент). (Можно проверить, что это равносильно независимым выборам камней на каждом шаге: на первом шаге каждый из камней может быть выбран с равной вероятностью, после такого выбора в каждой из групп все камни также равновероятны и т. д.)

(3) Таким образом, каждый камень характеризуется двумя числами от 1 до N — порядковым *номером* (в порядке возрастания весов) и *рангом*. Соответствие между номерами и рангами определяет число операций в процессе сортировки.

(4) Для каждых двух номеров i, j из $\{1, \ldots, N\}$ через $p(i, j)$ обозначим вероятность того, что камни с этими номерами будут сравниваться друг с другом. Например, $p(i, i+1) = 1$, поскольку соседние по весу камни должны быть сравнены обязательно (сравнения с другими камнями их не различают).

(5) Заметим, что $p(i, i+2) = 2/3$. В самом деле, сравнения не произойдёт в том и только том случае, когда из трёх камней с номерами i, $i+1$ и $i+2$ камень $i+1$ имеет наименьший ранг. Аналогично, $p(i, i+k) = 2/(k+1)$ (камни с номерами i и $i+k$ сравниваются, если среди $k+1$ камней $i, i+1, \ldots, i+k$ один из двух крайних имеет наименьший ранг).

(6) Математическое ожидание числа сравнений можно разбить в сумму $\sum m(i, j)$ ожиданий числа сравнений между камнями с номерами i и j. Но поскольку два данных камня сравниваются не более одного раза, $m(i, j) = p(i, j)$. Таким образом, получаем точное выражение для математического ожидания числа сравнений:

$$\sum_{1 \leqslant i < j \leqslant n} \frac{2}{j - i + 1}.$$

(7) Группируя в этой сумме равные члены и вспоминая, что $1 + 1/2 + 1/3 + \ldots + 1/k = O(\lg k)$, получаем оценку $O(N \lg N)$ для математического ожидания времени работы быстрой сортировки.

Анализ облегчается тем, что алгоритм разбиения (на три части) более симметричен. Реализация такого способа разбиения также проста: массив делится на четыре участка (перечисляем их слева направо): меньшие границы, равные границе, непросмотренные и бóльшие границы.]

Упражнения

8.4-1 Докажите, что наименьшее время работы быстрой сортировки составляет $\Omega(n \lg n)$.

8.4-2 Докажите, что функция $q^2 + (n-q)^2$ на отрезке $[1, n-1]$ принимает наибольшее значение в концах отрезка.

8.4-3 Докажите, что математическое ожидание времени работы процедуры RANDOMIZED-QUICKSORT на любом входе есть $\Omega(n \lg n)$.

8.4-4 На практике время работы быстрой сортировки можно уменьшить, если на завершающем этапе (когда массив почти отсортирован) использовать сортировку вставками. Сделать это можно, например, так: пусть процедура RANDOMIZED-QUICKSORT(A, p, r) ничего не делает, если $r-p+1 < k$ (т.е. сортируемый массив содержит меньше k элементов). После окончания рекурсивных вызовов получившийся массив сортируется с помощью сортировки вставками. Докажите, что математическое ожидание времени работы такого алгоритма составляет $O(nk + n\lg(n/k))$. Как бы вы стали выбирать число k?

8.4-5* Докажите равенство

$$\int x \ln x \, dx = \frac{1}{2}x^2 \ln x - \frac{1}{4}x^2$$

Выведите отсюда (используя метод сравнения с интегралом) более сильную (в сравнении с (8.5)) оценку для суммы $\sum_{k=1}^{n-1} k \lg k$.

8.4-6* Рассмотрим следующую модификацию процедуры RANDOMIZED-PARTITION: случайным образом выбираются три элемента массива и в качестве граничного элемента берётся средний по величине из выбранных трёх камней. Оцените вероятность того, что при этом разбиение будет сбалансировано не хуже, чем $\alpha : 1-\alpha$.

Задачи

8-1 Правильность процедуры разбиения

Покажите, что процедура PARTITION работает правильно. Для этого докажите следующее:

а. В процессе работы процедуры индексы i и j не выходят за пределы отрезка $[p\,..\,r]$.

б. В момент окончания работы процедуры индекс j не может быть равен r (т.е. обе части разбиения непусты).

в. В момент окончания работы процедуры любой элемент массива $A[p\,..\,j]$ не больше любого элемента массива $A[j+1\,..\,r]$.

8-2 Алгоритм Ломуто для разбиения

Вариант процедуры Partition, который мы сейчас рассмотрим, принадлежит Н. Ломуто (N. Lomuto). В процессе работы строятся куски $A[p\,..\,i]$ и $A[i+1\,..\,j]$, причём элементы первого куска не больше $x = A[r]$, а элементы второго куска — больше x.

```
Lomuto-Partition(A, p, r)
x ← A[r]
i ← p − 1
for j ← p to r
      do if A[j] ⩽ x
            then i ← i + 1
                  поменять A[i] ↔ A[j]
if i < r
   then return i
   else  return i − 1
```

а. Докажите, что процедура Lomuto-Partition работает правильно.

б. Сколько раз процедуры Partition и Lomuto-Partition могут перемещать один и тот же элемент? (Укажите наибольшие значения.)

в. Докажите, что процедура Lomuto-Partition, как и процедура Partition, требует времени $\Theta(n)$, где n — число элементов в массиве.

г. Заменим в тексте процедуры Quicksort процедуру Partition на Lomuto-Partition. Как изменится время быстрой сортировки для массива, все элементы которого равны?

д. Рассмотрим процедуру Randomized-Lomuto-Partition, которая меняет $A[r]$ со случайно выбранным элементом массива и затем вызывает процедуру Lomuto-Partition. Докажите, что вероятность того, что процедура Randomized-Lomuto-Partition вернёт значение q, равна вероятности того, что процедура Randomized-Partition вернёт значение $p+r-q$.

8-3 Сортировка по частям

Профессор предложил следующий *"продвинутый"* алгоритм сортировки:

```
Stooge-Sort(A, i, j)
if A[i] > A[j]
    then поменять A[i] ↔ A[j]
if i + 1 ⩾ j
    then return
k ← ⌊(j − i + 1)/3⌋           ▷ Округление с недостатком.
Stooge-Sort(A, i, j − k)      ▷ Первые две трети.
Stooge-Sort(A, i + k, j)      ▷ Последние две трети.
Stooge-Sort(A, i, j − k)      ▷ Опять первые две трети.
```

а. Докажите, что процедура Stooge-Sort действительно сортирует массив.

б. Найдите рекуррентное соотношение для наибольшего времени работы процедуры Stooge-Sort и получите из него оценку этого времени.

в. Сравните наибольшее время работы процедуры Stooge-Sort с наибольшим временем для других вариантов сортировки (вставками, слиянием, с помощью кучи и быстрой сортировки). Стоит ли продлевать контракт с профессором?

8-4 Размер стека при быстрой сортировке

Процедура Quicksort два раза рекурсивно вызывает себя (для левой и для правой части). В действительности без второго рекурсивного вызова можно обойтись, заменив его циклом (именно так хорошие компиляторы обрабатывают ситуацию, когда последним оператором процедуры является рекурсивный вызов; для такой ситуации есть термин **tail recursion**):

```
Quicksort′(A, p, r)
while p < r
    do ▷ Разбить и отсортировать левую часть.
        q ← Partition(A, p, r)
        Quicksort′(A, p, q)
        p ← q + 1
```

а. Докажите, что процедура Quicksort′ действительно сортирует массив.

Как правило, компиляторы реализуют рекурсию с помощью стека, где хранятся копии локальных переменных для каждого рекурсивного вызова. Вершина стека содержит информацию, относящуюся к текущему вызову; когда он завершается, информация удаляется из стека. В нашем случае для каждого рекурсивного вызова локальные переменные занимают объём $O(1)$, так что необходимый **размер стека** (stack depth) пропорционален глубине рекурсии.

б. Покажите, что в некоторых случаях процедура Quicksort′ требует стека размера $\Theta(n)$.

в. Измените процедуру Quicksort$'$ так, чтобы объём стека не превышал $\Theta(\lg n)$ (сохраняя оценку $\Theta(n \lg n)$ для среднего времени работы).

8-5 Разбиение с помощью медианы трёх элементов

Работу процедуры Randomized-Quicksort можно ускорить, выбирая граничный элемент для разбиения более тщательно. Один из распространённых подходов — это **метод медианы трёх** (median-of-3 method): в качестве граничного элемента используется средний из трёх случайно выбранных элементов массива. Мы будем предполагать, что все элементы входного массива $A[1\,..\,n]$ различны и $n \geqslant 3$. Через $A'[1\,..\,n]$ будем обозначать отсортированный массив (который мы и хотим получить). Пусть $p_i = \mathsf{P}\{x = A'[i]\}$, где x — граничный элемент, выбранный описанным выше способом.

а. Выразите вероятность p_i (для $i = 2, 3, \ldots, n-1$) через i и n (заметьте, что $p_1 = p_n = 0$).

б. Насколько вероятность выбрать средний элемент ($A'[\lfloor (n+1)/2 \rfloor]$) больше, чем при обычном случайном выборе? К чему стремится отношение этих вероятностей при $n \to \infty$?

в. Будем называть разбиение с граничным элементом x *"хорошим"*, если $x = A'[i]$, где $n/3 \leqslant i \leqslant 2n/3$. Насколько вероятность *"хорошего"* разбиения больше, чем при обычном случайном выборе? (Указание: при вычислениях оцените сумму интегралом.)

г. Докажите, что использование метода медианы трёх сохраняет оценку $\Omega(n \lg n)$ для времени работы быстрой сортировки (и влияет лишь на константу перед $n \lg n$).

Замечания

Алгоритм быстрой сортировки принадлежит Хоару [98]. В статье Седжвика [174] обсуждаются детали реализации быстрой сортировки и их влияние на время работы. Вероятностные алгоритмы для разных задач рассматриваются в статье Рабина [165].

9 Сортировка за линейное время

Мы познакомились с различными алгоритмами, которые могут отсортировать n чисел за время $O(n \lg n)$. Алгоритмы сортировки слиянием (merge sort) и сортировки с помощью кучи (heap sort) работают за такое время в худшем случае, а у алгоритма быстрой сортировки таковым является среднее время работы. Оценка $O(n \lg n)$ точна: для каждого из этих алгоритмов можно предъявить последовательность из n чисел, время обработки которой будет $\Omega(n \lg n)$.

Все упомянутые алгоритмы проводят сортировку, основываясь исключительно на попарных сравнениях элементов, поэтому их иногда называют **сортировками сравнением** (comparison sort). В разделе 9.1 мы покажем, что всякий алгоритм такого типа сортирует n элементов за время не меньше $\Omega(n \lg n)$ в худшем случае. Тем самым алгоритмы сортировки слиянием и с помощью кучи асимптотически оптимальны: не существует алгоритма сортировки сравнением, который превосходил бы указанные алгоритмы более, чем в конечное число раз.

В разделах 9.2, 9.3 и 9.4 мы рассматриваем три алгоритма сортировки (сортировка подсчётом, цифровая сортировка и сортировка вычёрпыванием), работающих за линейное время. Разумеется, они улучшают оценку $\Omega(n \lg n)$ за счёт того, что используют не только попарные сравнения, но и внутреннюю структуру сортируемых объектов.

9.1 Нижние оценки для сортировки

Говорят, что алгоритм сортировки основан на сравнениях, если он никак не использует внутреннюю структуру сортируемых элементов, а лишь сравнивает их и после некоторого числа сравнений выдаёт ответ (указывающий истинный порядок элементов). Так мы приходим к модели алгоритмов сортировки, называемой разрешающими деревьями.

Рисунок 9.1 Разрешающее дерево для алгоритма сортировки вставками, обрабатывающего последовательность из трёх элементов. Поскольку число перестановок из трёх элементов равно $3! = 6$, у дерева должно быть не менее 6 листьев.

Разрешающие деревья

Начнём с примера: на рис. 9.1 изображено **разрешающее дерево** (decision tree), соответствующее сортировке последовательности из трёх элементов с помощью алгоритма сортировки вставками из раздела 1.1.

Пусть теперь мы сортируем n элементов $a_1, \ldots, a_n$. Каждая внутренняя вершина разрешающего дерева соответствует операции сравнения и снабжена пометкой вида $a_i : a_j$, указывающей, какие элементы надо сравнить ($1 \leqslant i, j \leqslant n$). Каждый лист разрешающего дерева снабжен пометкой $\langle \pi(1), \pi(2), \ldots, \pi(n) \rangle$, где π — перестановка n элементов (см. разд. 6.1 по поводу перестановок). Для получения нижних оценок мы можем ограничиться случаем различных элементов, тогда результатом сортировки будет перестановка элементов в порядке возрастания.

Опишем, какой алгоритм сортировки соответствует данному разрешающему дереву. Надо пройти по дереву от корня до листа. Выбор направления (налево или направо) происходит так. Пусть в вершине написано $a_i : a_j$. Тогда надо идти налево, если $a_i \leqslant a_j$, и направо в противном случае. Если в листе, в который мы в итоге приходим, записана перестановка π, то результатом сортировки считаем последовательность $a_{\pi(1)}, a_{\pi(2)}, \ldots, a_{\pi(n)}$, которая должна быть неубывающей, если алгоритм правилен.

Каждая из $n!$ перестановок должна появиться хотя бы на одном листе разрешающего дерева (поскольку правильный алгоритм должен предусматривать все возможные порядки).

Нижняя оценка для худшего случая

Число сравнений в худшем случае для такого алгоритма равно высоте разрешающего дерева — максимальной длине пути в этом дереве от корня до листа. Следующая теорема дает нижнюю оценку на эту высоту.

Теорема 9.1. *Высота любого разрешающего дерева, сортирующего n элементов, есть $\Omega(n \lg n)$.*

Доказательство. Поскольку среди листьев разрешающего дерева должны быть представлены все перестановки n элементов, число этих листьев не менее $n!$. Поскольку двоичное дерево высоты h имеет не более 2^h листьев, имеем $n! \leqslant 2^h$. Логарифмируя это неравенство по основанию 2 и пользуясь неравенством $n! > (n/e)^n$, вытекающим из формулы Стирлинга (2.11), получаем, что

$$h \geqslant n \lg n - n \lg e = \Omega(n \lg n),$$

что и утверждалось. □

Следствие 9.2. Алгоритмы сортировки слиянием и с помощью кучи асимптотически оптимальны.

Доказательство. Они работают за время $O(n \lg n)$; в силу доказанной теоремы, эта оценка асимптотически неулучшаема. □

Упражнения

9.1-1 Какова наименьшая возможная глубина листа в разрешающем дереве алгоритма сортировки?

9.1-2 Докажите асимптотически точную оценку для $\lg(n!) = \sum_{k=1}^{n} \lg k$ без формулы Стирлинга, используя методы разд. 3.2.

9.1-3 Покажите, что не существует алгоритма сортировки, основанного на сравнениях, который работал бы за линейное время для половины из $n!$ возможных входных последовательностей длины n. Как изменится ответ, если в этой задаче заменить $1/2$ на $1/n$? На $1/2^n$?

9.1-4 Профессор разработал компьютер, который поддерживает *"тройные ветвления"*: после одного-единственного сравнения $a_i : a_j$ управление может быть передано в одно из трёх мест программы, в зависимости от того, какое из соотношений выполнено: $a_i < a_j$, $a_i = a_j$ или $a_i > a_j$. Он надеется, что благодаря таким сравнениям сортировку n элементов можно провести асимптотически быстрее, чем за время $\Omega(n \lg n)$. Покажите, что профессор заблуждается.

9.1-5 Покажите, что для слияния двух отсортированных последовательностей из n элементов достаточно $2n-1$ сравнений в худшем случае.

9.1-6 Последовательность из n элементов, которую необходимо отсортировать, разбита на участки длины k. При этом любой элемент первого участка меньше любого элемента второго и т. д. (так что остаётся лишь отсортировать элементы внутри участков). Покажите, что такая сортировка потребует не менее $\Omega(n \lg k)$ сравнений в худшем случае. (Указание: недостаточно сослаться на необходимость n/k раз сортировать участок длиной k.)

9.2 Сортировка подсчётом

Алгоритм **сортировки подсчётом** (counting sort) применим, если каждый из n элементов сортируемой последовательности — целое положительное число в известном диапазоне (не превосходящее заранее известного k). Если $k = O(n)$, то алгоритм сортировки подсчётом работает за время $O(n)$.

Идея этого алгоритма в том, чтобы для каждого элемента x предварительно подсчитать, сколько элементов входной последовательности меньше x, после чего записать x напрямую в выходной массив в соответствии с этим числом (если, скажем, 17 элементов входного массива меньше x, то в выходном массиве x должен быть записан на место номер 18). Если в сортируемой последовательности могут присутствовать равные числа, эту схему надо слегка модифицировать, чтобы не записать несколько чисел на одно место.

В приводимом ниже псевдокоде используется вспомогательный массив $C[1\,..\,k]$ из k элементов. Входная последовательность записана в массиве $A[1\,..\,n]$, отсортированная последовательность записывается в массив $B[1\,..\,n]$.

Counting-Sort(A, B, k)

1 **for** $i \leftarrow 1$ **to** k
2   **do** $C[i] \leftarrow 0$
3 **for** $j \leftarrow 1$ **to** $\mathit{length}[A]$
4   **do** $C[A[j]] \leftarrow C[A[j]] + 1$
5 $\triangleright$ $C[i]$ равно количеству элементов, равных i.
6 **for** $i \leftarrow 2$ **to** k
7   **do** $C[i] \leftarrow C[i] + C[i-1]$
8 $\triangleright$ $C[i]$ равно количеству элементов, не превосходящих i
9 **for** $j \leftarrow \mathit{length}[A]$ **downto** 1
10   **do** $B[C[A[j]]] \leftarrow A[j]$
11         $C[A[j]] \leftarrow C[A[j]] - 1$

Работа алгоритма сортировки подсчётом проиллюстрирована на рис. 9.2. После инициализации (строки 1–2) мы сначала помещаем в $C[i]$ количество элементов массива A, равных i (строки 3–4), а затем, находя частичные суммы последовательности $C[1], C[2], \ldots, C[k]$, — количество элементов, не превосходящих i (строки 6–7). Наконец, в строках 9–11 каждый из элементов

Рисунок 9.2 Работа алгоритма Counting-Sort, применённого к массиву $A[1\,..\,8]$, состоящему из натуральных чисел, не превосходящих $k = 6$. (а) Массив A и вспомогательный массив C после выполнения цикла в строках 3–4. (б) Массив C после выполнения цикла в строках 6–7. (в–д) Выходной массив B и вспомогательный массив C после одного, двух и трёх повторений цикла в строках 9–11. Зачернённые клетки соответствуют элементам массива, значения которым ещё не присвоены. (е) Массив B после окончания работы алгоритма.

массива A помещается на нужное место в массиве B. В самом деле, если все n элементов различны, то в отсортированном массиве число $A[j]$ должно стоять на месте номер $C[A[j]]$, ибо именно столько элементов массива A не превосходят $A[j]$; если в массиве A встречаются повторения, то после каждой записи числа $A[j]$ в массив B число $C[A[j]]$ уменьшается на единицу (строка 11), так что при следующей встрече с числом, равным $A[j]$, оно будет записано на одну позицию левее.

Оценим время работы алгоритма сортировки подсчётом. Циклы в строках 1–2 и 6–7 работают за время $O(k)$, циклы в строках 3–4 и 10–11 — за время $O(n)$, а весь алгоритм, стало быть, работает за время $O(k+n)$. Если $k = O(n)$, то время работы есть $O(n)$.

Для алгоритма сортировки подсчётом нижняя оценка разд. 9.1 — не препятствие, поскольку он не сравнивает сортируемые числа между собой, а использует их в качестве индексов массива.

Алгоритм сортировки подсчётом обладает важным свойством, называемым **устойчивостью** (it is stable). Именно, если во входном массиве присутствует несколько равных чисел, то в выходном массиве они стоят в том же порядке, что и во входном. Это свойство не имеет смысла, если в массиве записаны только числа сами по себе, но если вместе с числами записаны дополнительные данные, это оказывается важным. Более точно, представим себе, что мы сортируем не просто числа, а пары $\langle t, x\rangle$, где t — число от 1 до k, а x — произвольный объект, и хотим переставить их так, чтобы первые компоненты пар шли в неубывающем порядке. Описанный нами алгоритм позволяет это сделать, причём относительное расположение пар с равными первыми компонентами не меняется. Это свойство и называется устойчивостью. Мы увидим в следующем разделе, как оно применяется.

Упражнения

9.2-1 Следуя образцу рис. 9.2., покажите работу алгоритма Counting-Sort для случая $k = 7$ и $A = \langle 7, 1, 3, 1, 2, 4, 5, 7, 2, 4, 3 \rangle$.

9.2-2 Докажите, что алгоритм Counting-Sort является устойчивым.

9.2-3 Заменим строку 9 алгоритма Counting-Sort на такую:

9 **for** $j \leftarrow 1$ **to** $length[A]$

Покажите, что алгоритм остаётся правильным. Будет ли он устойчив?

9.2-4 Пусть на выходе алгоритма сортировки надо напечатать элементы входной последовательности в отсортированном порядке. Модифицируйте алгоритм Counting-Sort таким образом, чтобы он делал это, не используя массива B или иных массивов (помимо A и C). (Указание: свяжите в списки элементы массива A с одинаковым значением; где взять место для хранения указателей?).

9.2-5 Дано n целых чисел от 1 до k. Разработайте алгоритм, который подвергает эти данные предварительной обработке, а затем за время $O(1)$ отвечает на любой вопрос типа *"сколько чисел из данного набора лежит между a и b?"*. Время на предварительную обработку должно быть $O(n + k)$.

9.3 Цифровая сортировка

Алгоритм **цифровой сортировки** (radix sort) использовался в машинах для сортировки перфокарт (сейчас такие машины можно найти разве что в музеях). В картонных перфокартах специальный перфоратор пробивал дырки. В каждой из 80 колонок были места для 12 прямоугольных дырок. Вообще-то в одной колонке можно было пробить несколько дырок, их комбинация соответствовала символу (так что на карте было место для 80 символов), но цифры 0–9 кодировались одиночными дырками в строках 0–9 соответствующей колонки.

Сортировочной машине указывали столбец, по которому нужно произвести сортировку, и она раскладывала колоду перфокарт на

$$
\begin{array}{ccccccc}
329 & & 720 & & 720 & & 329 \\
457 & & 355 & & 329 & & 355 \\
657 & & 436 & & 436 & & 436 \\
839 & \Rightarrow & 457 & \Rightarrow & 839 & \Rightarrow & 457 \\
436 & & 657 & & 355 & & 657 \\
720 & & 329 & & 457 & & 720 \\
355 & & 839 & & 657 & & 839 \\
 & & \uparrow & & \uparrow & & \uparrow
\end{array}
$$

Рисунок 9.3 Цифровая сортировка последовательности из семи трёхзначных чисел. На вход подаются числа первого столбца. Далее показан порядок чисел после сортировки по третьей, второй и первой цифрам (вертикальные стрелки указывают, по какой цифре производилась сортировка).

10 стопок в зависимости от того, какая из дырок 0–9 была пробита в указанном столбце.

Как отсортировать колоду перфокарт с многозначными числами (разряд единиц в одном столбце, десятков — в предыдущем и т. д.)? Первое, что приходит в голову, — начать сортировку со старшего разряда. При этом получится 10 стопок, каждую из которых на следующем шаге придётся разбивать на 10 стопок, и так далее — получится много стопок перфокарт, в которых легко запутаться (см. упражнение 9.3-5).

Как ни странно, оказывается удобнее начать *с младшего разряда*, разложив колоду на 10 стопок в зависимости от того, где пробито отверстие в *"младшем"* столбце. Полученные 10 стопок надо после этого сложить в одну в таком порядке: сначала карты с 0, затем карты с 1, и т. д. Получившуюся колоду вновь рассортируем на 10 стопок, но уже в соответствии с разрядом десятков, сложим полученные стопки в одну колоду, и т. д.; если на перфокартах были записаны d-значные числа, то понадобится d раз воспользоваться сортировочной машиной. На рис. 9.3 изображено, как действует этот алгоритм, примененный к семи трёхзначным числам.

Важно, чтобы алгоритм, с помощью которого происходит сортировка по данному разряду, был устойчивым: карточки, у которых в данной колонке стоит одна и та же цифра, должны выйти из сортировочной машины в той же последовательности, в которой они туда подавались (само собой, при складывании 10 стопок в одну менять порядок карт в стопках тоже не следует).

В компьютерах цифровая сортировка иногда используется для упорядочения данных, содержащих несколько полей. Пусть, например, нам надо отсортировать последовательность дат. Это можно сделать с помощью любого алгоритма сортировки, сравнивая даты следующим образом: сравнить годы, если годы совпадают — сравнить месяцы, если совпадают и месяцы — сравнить числа. Вместо этого, однако, можно просто трижды отсортировать массив дат с помощью устойчивого алгоритма: сначала по дням, потом по месяцам, потом по годам.

Программу для цифровой сортировки написать легко. Мы предполагаем, что каждый элемент n-элементного массива A состоит из d цифр, причем цифра номер 1 — младший разряд, а цифра номер d — старший.

Radix-Sort(A, d)

```
1  for i ← 1 to d
2       do отсортировать массив A устойчивым
           алгоритмом по значению цифры номер i
```

Правильность алгоритма цифровой сортировки доказывается индукцией по номеру разряда (см. упр. 9.3-3). Время работы зависит от времени работы выбранного устойчивого алгоритма. Если цифры могут принимать значения от 1 до k, где k не слишком велико, то очевидный выбор — сортировка подсчётом. Для n чисел с d знаками от 0 до $k-1$ каждый проход занимает время $\Theta(n+k)$; поскольку мы делаем d проходов, время работы цифровой сортировки равно $\Theta(dn+kd)$. Если d постоянно и $k = O(n)$, то цифровая сортировка работает за линейное время.

При цифровой сортировке важно правильно выбрать основание системы счисления, поскольку от него зависит размер требуемой дополнительной памяти и время работы. Конкретный пример: пусть надо отсортировать миллион 64-битных чисел. Если рассматривать их как четырёхзначные числа в системе счисления с основанием 2^{16}, то при цифровой сортировке мы справимся с ними за четыре прохода, используя в процедуре Counting-Sort массив B размером 2^{16} (что немного по сравнению с размером сортируемого массива) Это выгодно отличается от сортировки сравнением, когда на каждое число приходится по $\lg n \approx 20$ операций. К сожалению, цифровая сортировка, опирающаяся на сортировку подсчётом, требует ещё одного массива (того же размера, что и сортируемый) для хранения промежуточных результатов, в то время как многие алгоритмы сортировки сравнением обходятся без этого. Поэтому, если надо экономить память, алгоритм быстрой сортировки может оказаться предпочтительнее.

Упражнения

9.3-1 Следуя образцу рис. 9.3, покажите, как происходит цифровая сортировка (по алфавиту) английских слов COW, DOG, SEA, RUG, ROW, MOB, BOX, TAB, BAR, EAR, TAR, DIG, BIG, TEA, NOW, FOX.

9.3-2 Какие из следующих алгоритмов сортировки являются устойчивыми: сортировка вставками, сортировка слиянием, сортировка с помощью кучи, быстрая сортировка? Объясните, каким способом можно любой алгоритм сортировки превратить в устойчивый. Сколько при этом потребуется дополнительного времени и памяти?

9.3-3 Докажите по индукции, что алгоритм цифровой сортировки правилен. Где в вашем доказательстве используется устойчивость алгоритма сортировки цифр?

9.3-4 Объясните, как рассортировать n целых положительных чисел, не превосходящих n^2, за время $O(n)$.

9.3-5* Пусть мы сортируем перфокарты с помощью сортировочной машины, начиная со старшего разряда. Сколько раз придётся запустить машину (в худшем случае) для сортировки d-значных чисел? Какое максимальное количество стопок карт придётся одновременно хранить по ходу дела?

9.4 Сортировка вычёрпыванием

Алгоритм **сортировки вычёрпыванием** (bucket sort) работает за линейное (среднее) время. Как и сортировка подсчётом, сортировка вычёрпыванием годится не для любых исходных данных: говоря о линейном среднем времени, мы предполагаем, что на вход подаётся последовательность независимых случайных чисел, равномерно распределённых на промежутке $[0;1)$ (определение равномерного распределения дано в разд. 6.2).

[Заметим, что этот алгоритм — детерминированный (не использует генератора случайных чисел); понятие случайности возникает лишь при анализе времени его работы.]

Идея алгоритма состоит в том, что промежуток $[0;1)$ делится на n равных частей, после чего для чисел из каждой части выделяется свой ящик-**черпак** (bucket), и n подлежащих сортировке чисел раскладываются по этим ящикам. Поскольку числа равномерно распределены на отрезке $[0;1)$, следует ожидать, что в каждом ящике их будет немного. Теперь отсортируем числа в каждом ящике по отдельности и пройдёмся по ящикам в порядке возрастания, выписывая попавшие в каждый из них числа также в порядке возрастания.

Будем считать, что на вход подается n-элементный массив A, причем $0 \leqslant A[i] < 1$ для всех i. Используется также вспомогательный массив $B[0\,..\,n-1]$, состоящий из списков, соответствующих ящикам. Алгоритм использует операции со списками, которые опи-

Рисунок 9.4 Работа алгоритма Bucket-Sort. (а) На вход подан массив $A[1\,..\,10]$. (б) Массив списков $B[0\,..\,9]$ после выполнения строки 5. Список с индексом i содержит числа, у которых первый знак после запятой есть i. Отсортированный массив получится, если последовательно выписать списки $B[0], \ldots, B[9]$.

саны в разд. 11.2.

Bucket-Sort(A)

1 $n \leftarrow \mathit{length}[A]$
2 **for** $i \leftarrow 1$ **to** n
3   **do** добавить $A[i]$ к списку $B[\lfloor nA[i] \rfloor]$
4 **for** $i \leftarrow 0$ **to** $n - 1$
5   **do** отсортировать список $B[i]$ (сортировка вставками)
6 соединить списки $B[0], B[1], \ldots, B[n-1]$ (в указанном порядке)

На рис. 9.4 показана работа этого алгоритма на примере массива из 10 чисел.

Чтобы показать, что алгоритм сортировки вычёрпыванием правилен, рассмотрим два числа $A[i]$ и $A[j]$. Если они попали в разные ящики, то меньшее из них попало в ящик с меньшим номером, и в выходной последовательности оно окажется раньше; если они попали в один ящик, то после сортировки содержимого ящика меньшее число будет также предшествовать большему.

Проанализируем время работы алгоритма. Операции во всех строках, кроме пятой, требуют (общего) времени $O(n)$. Просмотр всех ящиков также занимает время $O(n)$. Таким образом, нам остаётся только оценить время сортировки вставками внутри ящиков.

Пусть в ящик $B[i]$ попало n_i чисел (n_i — случайная величина). Поскольку сортировка вставками работает за квадратичное время, математическое ожидание длительности сортировки чисел в ящике номер i есть $O(\mathsf{M}[n_i^2])$, а математическое ожидание суммарного времени сортировки во всех ящиках есть

$$\sum_{i=0}^{n-1} O(\mathsf{M}[n_i^2]) = O\left(\sum_{i=0}^{n-1} \mathsf{M}[n_i^2]\right). \tag{9.1}$$

Найдём функцию распределения случайных величин n_i. Поскольку числа распределены равномерно, а величины всех отрезков равны, вероятность того, что данное число попадет в ящик номер i, равна $1/n$. Стало быть, мы находимся в ситуации примера из разд. 6.6.2 с шарами и урнами: у нас n шаров-чисел, n урн-ящиков, и вероятность попадания данного шара в данную урну равна $p = 1/n$. Поэтому числа n_i распределены биномально: вероятность того, что $n_i = k$, равна $C_n^k p^k (1-p)^{n-k}$, математическое ожидание равно $\mathsf{M}[n_i] = np = 1$, и дисперсия равна $\mathsf{D}[n_i] = np(1-p) = 1 - 1/n$. Из формулы (6.30) имеем:

$$\mathsf{M}[n_i^2] = \mathsf{D}[n_i] + \mathsf{M}^2[n_i] = 2 - \frac{1}{n} = \Theta(1).$$

Подставляя эту оценку в (9.1), получаем, что математическое ожидание суммарного времени сортировки всех ящиков есть $O(n)$, так что математическое ожидание времени работы алгоритма сортировки вычёрпыванием в самом деле линейно зависит от количества чисел.

Упражнения

9.4-1 Следуя образцу рис. 9.4, покажите, как работает алгоритм Bucket-Sort для массива $A = \langle 0.79, 0.13, 0.16, 0.64, 0.39, 0.20, 0.89, 0.53, 0.71, 0.42\rangle$.

9.4-2 Каково время работы алгоритма сортировки вычёрпыванием в худшем случае? Придумайте его простую модификацию, сохраняющую линейное среднее время работы и снижающую время работы в худшем случае до $O(n \lg n)$.

9.4-3* Дано n независимых случайных точек с координатами $(x_i; y_i)$, равномерно распределённых в круге радиуса 1 с центром в начале координат (это означает, что вероятность найти точку в какой-то области пропорциональна площади этой области). Разработайте алгоритм, располагающий точки в порядке возрастания расстояния от центра и имеющий среднее время работы $\Theta(n)$. (Указание: воспользуйтесь сортировкой вычёрпыванием, но позаботьтесь о том, чтобы площади ящиков были равны).

9.4-4* Пусть X — случайная величина. Ее **функция распределения** (probability distribution function) определяется формулой $P(x) =$

$\mathsf{P}\{X \leqslant x\}$. Предположим, что на вход алгоритма поступает последовательность из n чисел, которые являются независимыми случайными величинами с функцией распределения P. Функция P непрерывна и может быть вычислена за время $O(1)$. Как отсортировать такую последовательность, чтобы среднее время сортировки линейно зависело от n?

Задачи

9-1 Нижние оценки для среднего числа сравнений

В этой задаче мы докажем, что среднее время работы любого детерминированного или вероятностного алгоритма сортировки n чисел, основанного на сравнениях, есть $\Omega(n \lg n)$. Начнем с того, что рассмотрим детерминированный алгоритм A, основанный на сравнениях; пусть T_A — его разрешающее дерево. Мы предполагаем, что все перестановки входной последовательности равновероятны.

а. Напишем на каждом листе дерева T_A вероятность того, что алгоритм завершится в этом листе. Покажите, что в $n!$ листах написано $1/n!$, а в остальных листах написан нуль.

б. Обозначим через $D(T)$ сумму глубин всех листьев в двоичном дереве T (мы предполагаем, что каждая вершина либо является листом, либо имеет двух детей — так устроены разрешающие деревья). Пусть T — дерево с $k > 1$ листьями, и пусть через LT и RT обозначены левое и правое поддеревья. Покажите, что $D(T) = D(LT) + D(RT) + k$.

в. Пусть $d(m)$ — наименьшее значение числа $D(T)$ среди всех деревьев T с m листьями. Покажите, что $d(k) = \min_{1 \leqslant i \leqslant k-1}\{d(i) + d(k-i) + k\}$. (Указание: дерево LT может содержать от 1 до $k-1$ листьев.)

г. Покажите, что для фиксированного k выражение $i \lg i + (k - i)\lg(k-i)$ достигает минимума на отрезке от 1 до $k-1$ в точке $i = k/2$. Выведите отсюда, что $d(k) = \Omega(k \lg k)$.

д. Покажите, что $D(T_A) = \Omega(n! \lg(n!))$, и выведите отсюда, что время сортировки n чисел с помощью разрешающего дерева T_A, усреднённое по всем перестановкам на входе, есть $\Omega(n \lg n)$.

Теперь рассмотрим вероятностный алгоритм B, основанный на сравнениях. Его можно описать с помощью разрешающего дерева, в котором бывают узлы двух типов: соответствующие сравнениям и случайным выборам. В узлах второго типа происходит вызов процедуры $\textsc{Random}(1, r)$; у такого узла r детей, каждый из которых выбирается с равной вероятностью. (Для разных узлов число r может быть разным.)

е. Пусть имеется вероятностный алгоритм сортировки B. Для каждой перестановки на входе найдём математическое ожидание числа сравнений. Усредним эти ожидания по всем входам; получится некоторое число T. Покажите, что существует детерминированный алгоритм A, у которого среднее (по всем перестановкам на входе) число сравнений не превосходит T. Выведите отсюда, что для любого вероятностного алгоритма максимальное (по всем входам) математическое ожидание числа сравнений есть $\Omega(n \lg n)$.

(Указание. Если среднее по всем входам и всем вариантам случайных чисел равно T, то существует такой набор случайных чисел, при котором среднее по всем входам не больше T.)

9-2 Сортировка без дополнительной памяти за линейное время

а. Пусть нам дан массив записей, который необходимо отсортировать по ключу, принимающему значение 0 или 1. Придумайте простой алгоритм, осуществляющий такую сортировку за линейное время и использующий дополнительную память $O(1)$ (иными словами, объем дополнительной памяти не зависит от размеров сортируемого массива).

б. Можно ли воспользоваться алгоритмом из пункта (а) для цифровой сортировки по b-битному ключу за время $O(bn)$? Объясните свой ответ.

в. Пусть n записей надо отсортировать по ключу, принимающему целые значения от 1 до k. Как модифицировать сортировку подсчётом, чтобы можно было отсортировать эти записи за время $O(n+k)$, и при этом объем используемой памяти (помимо сортируемого массива) был $O(k)$? (Указание. Начните со случая $k=3$.)

Замечания

Анализ алгоритмов сортировки с помощью разрешающих деревьев был предложен Фордом и Джонсоном [72]. В фундаментальной книге Кнута [123], посвященной сортировке, рассматриваются многочисленные варианты этой задачи и доказывается нижняя оценка числа сравнений (приведённая в этой главе). Нижние оценки для задачи сортировки и различных обобщений разрешающих деревьев подробно изучались Бен-Ором [23].

Согласно Кнуту, заслуга изобретения сортировки подсчётом (1954 год) и её комбинации с цифровой сортировкой принадлежит Сьюарду (H. H. Seward). Сама же цифровая сортировка, видимо, давно применялась для сортировки перфокарт. Кнут утверждает, что первое печатное описание этого метода появилось в 1929 году в качестве составной части руководства по оборудованию для работы с перфокартами, написанного Комри (L. J. Comrie). Сортировка вычёрпыванием используется с 1956 года, когда Айзек (E. J. Isaac) и Синглетон (R. C. Singleton) предложили основную идею.

10 Медианы и порядковые статистики

В этой главе мы рассматриваем такую задачу: дано множество из n чисел; найти тот его элемент, который будет i-м по счёту, если расположить элементы множества в порядке возрастания. В англоязычной литературе такой элемент называется i-й **порядковой статистикой** (order statistic). Например, **минимум** (minimum) — это порядковая статистика номер 1, а **максимум** (maximum) — порядковая статистика номер n. **Медианой** (median) называется элемент множества, находящийся (по счёту) посередине между минимумом и максимумом. Точнее говоря, если n нечётно, то медиана — это порядковая статистика номер $i = (n+1)/2$, а если n чётно, то медиан даже две: с номерами $i = n/2$ и $i = n/2+1$. Можно ещё сказать, что, независимо от чётности n, медианы имеют номер $i = \lfloor (n+1)/2 \rfloor$ и $i = \lceil (n+1)/2 \rceil$. В дальнейшем мы будем называть медианой меньшую из двух (если их две).

Для удобства мы будем считать, что множество, в котором мы ищем порядковые статистики, состоит из различных элементов, хотя практически всё, что мы делаем, переносится на ситуацию, когда во множестве есть повторяющиеся элементы. **Задача выбора элемента с данным номером** (selection problem) состоит в следующем:

Дано: Множество A из n различных элементов и целое число i, $1 \leqslant i \leqslant n$.

Найти: Элемент $x \in A$, для которого ровно $i-1$ элементов множества A меньше x.

Эту задачу можно решить за время $O(n \lg n)$: отсортировать числа, после чего взять i-й элемент в полученном массиве. Есть, однако, и более быстрые алгоритмы.

В разделе 10.1 мы рассмотрим простейший случай: нахождение максимального и минимального элементов. Общая задача более интересна; ей посвящены два следующих раздела. В разделе 10.2 мы рассматриваем удобный на практике вероятностный алгоритм, который ищет порядковую статистику за время $O(n)$ в среднем (имеется в виду математическое ожидание времени его работы на любом входе). В разделе 10.3 мы рассматриваем (представляющий скорее теоретический интерес) детерминированный алгоритм, требующий времени $O(n)$ в худшем случае.

10.1 Минимум и максимум

Сколько сравнений необходимо, чтобы во множестве из n чисел найти наименьшее? За $n-1$ сравнений это сделать легко: надо последовательно перебирать все числа, храня значение наименьшего числа из уже просмотренных. Запишем этот алгоритм, считая, что числа заданы в виде массива A длины n.

```
MINIMUM(A)
1  min ← A[1]
2  for i ← 2 to length[A]
3       do if min > A[i]
4             then min ← A[i]
5  return min
```

Разумеется, аналогичным образом можно найти и максимум.

Можно ли найти минимум еще быстрее? Нет, и вот почему. Рассмотрим алгоритм нахождения наименьшего числа как турнир среди n чисел, а каждое сравнение — как матч, в котором меньшее число побеждает. Чтобы победитель был найден, каждое из остальных чисел должно проиграть по крайней мере один матч, так что меньше $n-1$ сравнений быть не может, и алгоритм MINIMUM оптимален по числу сравнений.

Интересный вопрос, связанный с этим алгоритмом — нахождение математического ожидания числа исполнений строки 4. В задаче 6-2 требуется показать, что эта величина есть $\Theta(\lg n)$.

Одновременный поиск минимума и максимума

Иногда бывает нужно найти одновременно минимальный и максимальный элементы множества. Представим себе программу, которая должна уменьшить рисунок (набор точек, заданных своими координатами) так, чтобы он уместился на экране. Для этого нужно найти максимум и минимум по каждой координате.

Если мы попросту найдем сначала минимум, а потом максимум, затратив на каждый из них по $n-1$ сравнений, то всего будет $2n-2$ сравнения, что асимптотически оптимально. Можно, однако, решить эту задачу всего за $3\lceil n/2\rceil - 2$ сравнений. Именно, будем хранить значения максимума и минимума уже просмотренных чисел, а очередные числа будем обрабатывать по два таким образом: сначала сравним два очередных числа друг с другом, а затем большее из них сравним с максимумом, а меньшее — с минимумом.

При этом на обработку двух элементов мы затратим три сравнения вместо четырёх (кроме первой пары, где понадобится всего одно сравнение).

Упражнения

10.1-1 Покажите, что второе по величине число из n данных можно найти в худшем случае за $n + \lceil \lg n \rceil - 2$ сравнения. (Указание. Ищите это число вместе с наименьшим.)

10.1-2* Покажите, что для одновременного нахождения наибольшего и наименьшего из n чисел в худшем случае необходимо не менее $\lceil 3n/2 \rceil - 2$ сравнений. (Указание. В каждый момент элементы делятся на четыре группы: (1) непросмотренные (которые могут оказаться и минимальными, и максимальными); (2) те, что ещё могут оказаться минимальными, но заведомо не максимальны; (3) те, что ещё могут оказаться максимальными, но не минимальными; (4) отброшенные (которые заведомо не минимальны и не максимальны). Пусть a_1, a_2, a_3, a_4 — количество элементов каждой группы. Как меняются эти числа при сравнениях?)

10.2 Выбор за линейное в среднем время

Хотя общая задача выбора выглядит более сложной, чем задача о минимуме или максимуме, её, как ни странно, тоже можно решить за время $\Theta(n)$. В этом разделе мы рассмотрим вероятностный алгоритм Randomized-Select для решения этой задачи, действующий по схеме *"разделяй и властвуй"*. Он аналогичен алгоритму быстрой сортировки из главы 8: массив разбивается на меньшие части. Однако алгоритм быстрой сортировки, разбив массив на два куска, обрабатывает оба, а алгоритм Randomized-Select — только один из этих кусков. Поэтому он быстрее: среднее время быстрой сортировки есть $\Theta(n \lg n)$, в то время как алгоритм Randomized-Select работает в среднем за время $\Theta(n)$.

Алгоритм Randomized-Select использует процедуру Randomized-Partition, описанную в разделе 8.3, поведение которой (и, стало быть, всего алгоритма) зависит от датчика случайных чисел. Вызов Randomized-Select(A, p, r, i) возвращает i-й по счёту в порядке возрастания элемент массива $A[p\,..\,r]$.

```
Randomized-Select(A, p, r, i)
1  if p = r
2     then return A[p]
3  q ← Randomized-Partition(A, p, r)
4  k ← q − p + 1
5  if i ⩽ k
6     then return Randomized-Select(A, p, q, i)
7     else  return Randomized-Select(A, q + 1, r, i − k)
```

После исполнения процедуры Randomized-Partition в строке 3 массив $A[p\,..\,r]$ состоит из двух непустых частей $A[p\,..\,q]$ и $A[q+1\,..\,r]$, причём всякий элемент $A[p\,..\,q]$ меньше всякого элемента $A[q+1\,..\,r]$. В строке 4 вычисляется количество элементов в массиве $A[p\,..\,q]$. Дальнейшее зависит от того, в каком из этих двух массивов лежит i-й по величине элемент массива $A[p\,..\,r]$. Если $i \leqslant k$, то нужный нам элемент лежит в левой части (массиве $A[p\,..\,q]$), откуда и извлекается в результате (рекурсивного) вызова Randomized-Select в строке 6. Если же $i > k$, то все k элементов левой части ($A[p\,..\,q]$) заведомо меньше искомого, который можно найти как $(i-k)$-й по счёту элемент массива $A[q+1\,..\,r]$ (строка 7).

Время работы алгоритма Randomized-Select (с учётом времени работы процедуры Randomized-Partition) в худшем случае есть $\Theta(n^2)$, даже если мы ищем всего лишь минимум: в самом деле, при особом невезении может оказаться, что мы все время разбиваем массив возле наибольшего оставшегося элемента. Однако случайный выбор гарантирует, что для любого входа среднее время работы алгоритма будет невелико.

Докажем это. Рассмотрим для каждой из возможных перестановок n элементов математическое ожидание времени работы алгоритма (среднее по всем случайным выборам). Пусть $T(n)$ — максимальное из этих ожиданий. Как мы отмечали в разделе 8.4, после вызова Randomized-Partition левая часть разбиения содержит 1 элемент с вероятностью $2/n$, и содержит $i > 1$ элементов с вероятностью $1/n$ для любого i от 2 до $n-1$. Можно считать, что $T(n)$ монотонно возрастает с ростом n (если это не так, заменим $T(n)$ на $T'(n) = \max_{1 \leqslant i \leqslant n} T(i)$ и повторим все рассуждения для T'). Заметим, что худшим случаем будет тот, когда i-й по счёту элемент попадает в бóльшую из двух половин, на которые разбивается массив. Отсюда имеем:

$$\begin{aligned} T(n) &\leqslant \frac{1}{n}\left(T(\max(1,n-1)) + \sum_{k=1}^{n-1} T(\max(k,n-k))\right) + O(n) \\ &\leqslant \frac{1}{n}\left(T(n-1) + 2\sum_{k=\lceil n/2\rceil}^{n-1} T(k)\right) + O(n) \\ &= \frac{2}{n}\sum_{k=\lceil n/2\rceil}^{n-1} T(k) + O(n) \end{aligned}$$

(мы сгруппировали одинаковые слагаемые при переходе от первой строки ко второй и отбросили $T(n-1)/n$ при переходе от второй строки к третьей, так как в худшем случае $T(n-1) = O(n^2)$, и тем самым слагаемое $T(n-1)/n$ можно включить в $O(n)$).

Теперь докажем, что $T(n) \leqslant cn$, рассуждая по индукции (как выбрать c, мы скажем после). В самом деле, пусть неравенство $T(j) \leqslant cj$ верно для всех $j < n$. Тогда, используя формулу для суммы арифметической прогрессии, получаем, что

$$\begin{aligned} T(n) &\leqslant \frac{2}{n}\sum_{k=\lceil n/2\rceil}^{n-1} ck + O(n) \\ &\leqslant \frac{2c}{n}\cdot\frac{n}{2}\cdot\frac{n/2+1+n-1}{2} + O(n) \\ &= \frac{3cn}{4} + O(n) \leqslant cn, \end{aligned}$$

если выбрать c столь большим, чтобы $c/4$ превосходило константу, подразумеваемую в слагаемом $O(n)$.

Стало быть, любая порядковая статистика, и медиана в том числе, может быть найдена за линейное в среднем время.

Упражнения

10.2-1 Напишите версию процедуры RANDOMIZED-SELECT, не использующую рекурсии.

10.2-2 Предположим, что мы используем алгоритм RANDOMIZED-SELECT для выбора наименьшего элемента из массива $A = \langle 3,2,9,0,7,5,4,8,6,1\rangle$. Опишите последовательность разбиений, соответствующую худшему случаю.

10.2-3 Будет ли алгоритм RANDOMIZED-SELECT правильно работать, если в массиве A есть равные элементы (как мы помним, в этом случае процедура RANDOMIZED-PARTITION разбивает $A[p\,..\,r]$

на части $A[p\,..\,q]$ и $A[q+1\,..\,r]$ таким образом, что всякий элемент $A[p\,..\,q]$ не превосходит всякого элемента $A[q+1\,..\,r]$)?

10.3 Выбор за линейное в худшем случае время

Теперь рассмотрим (детерминированный) алгоритм Select, решающий задачу о порядковых статистиках за время $O(n)$ в худшем случае. Как и Randomized-Select, этот алгоритм основан на последовательном разбиении массива на меньшие части; в данном случае, однако, мы гарантируем, что выбранное разбиение не является неудачным. Алгоритм Select использует (детерминированную) процедуру Partition (см. описание алгоритма быстрой сортировки в разд. 8.1), модифицированную таким образом, чтобы элемент, с которым сравнивают, задавался как параметр.

Алгоритм Select находит i-й по порядку элемент в массиве размера $n > 1$ следующим образом:

1. Разбить n элементов массива на $\lfloor n/5 \rfloor$ групп по 5 элементов и (возможно) одну группу, в которой менее пяти элементов.
2. Найти медиану каждой из $\lceil n/5 \rceil$ групп (для чего отсортировать группу вставками).
3. Вызвав (рекурсивно) процедуру Select, найти число x, являющееся медианой найденных $\lceil n/5 \rceil$ медиан.
4. Вызвав модифицированную процедуру Partition, разбить массив относительно найденной *"медианы медиан"*. Пусть k — количество элементов в нижней части этого разбиения (в верхней части, стало быть, $n-k$).
5. Вызвав (рекурсивно) процедуру Select, найти i-ую порядковую статистику нижней части разбиения, если $i \leqslant k$, или $(i-k)$-ю порядковую статистику верхней части разбиения, если $i > k$.

Оценим время работы алгоритма Select. Для начала выясним, сколько чисел заведомо будут больше *"медианы медиан"* x (см. рис. 10.1). Не менее половины медиан, найденных на втором шаге, будут больше или равны x. Стало быть, по крайней мере половина из $\lceil n/5 \rceil$ групп даст по три числа, бо́льших x, за двумя возможными исключениями: группа, содержащая x, и последняя неполная группа. Тем самым имеется не менее

$$3\left(\left\lceil \frac{1}{2}\left\lceil \frac{n}{5} \right\rceil \right\rceil - 2\right) \geqslant \frac{3n}{10} - 6.$$

элементов, заведомо больших x, и точно так же получаем, что имеется не менее $3n/10 - 6$ элементов, заведомо меньших x. Значит, алгоритм Select, рекурсивно вызываемый на пятом шаге, будет обрабатывать массив длиной не более $7n/10 + 6$.

Рисунок 10.1 Анализ алгоритма Select. Элементы массива (их n) изображены кружками, каждый столбец — группа из 5 или меньше элементов, белые кружки — медианы групп. *"Медиана медиан"* обозначена буквой x. Стрелки идут от бо́льших чисел к меньшим. Видно, что в каждом из полных столбцов правее x имеется три числа, бо́льших x, и что в каждом из столбцов левее x имеется три числа, меньших x. Множество чисел, заведомо бо́льших x, выделено серым.

Пусть теперь $T(n)$ — время работы алгоритма Select на массиве из n элементов в худшем случае. Первый, второй и четвертый шаги выполняются за время $O(n)$ (на втором шаге мы $O(n)$ раз сортируем массивы размером $O(1)$), третий шаг выполняется за время не более $T(\lceil n/5 \rceil)$, а пятый шаг, по доказанному, — за время, не превосходящее $T(\lfloor 7n/10+6 \rfloor)$ (как и раньше, можно предполагать, что $T(n)$ монотонно возрастает с ростом n). Стало быть,

$$T(n) \leqslant T(\lceil n/5 \rceil) + T(\lfloor 7n/10 + 6 \rfloor) + O(n).$$

Поскольку сумма коэффициентов при n в правой части ($1/5+7/10 = 9/10$) меньше единицы, из этого рекуррентного соотношения вытекает, что $T(n) \leqslant cn$ для некоторой константы c. Это можно доказать по индукции. В самом деле, предполагая, что $T(m) \leqslant cm$ для всех $m < n$, имеем

$$\begin{aligned} T(n) &\leqslant c(\lceil n/5 \rceil) + c(\lfloor 7n/10 + 6 \rfloor) + O(n) \\ &\leqslant c(n/5 + 1) + c(7n/10 + 6) + O(n) \\ &\leqslant 9cn/10 + 7c + O(n) = \\ &= cn - c(n/10 - 7) + O(n). \end{aligned}$$

При подходящем выборе c это выражение будет не больше cn при всех $n > 70$ (надо, чтобы $c(n/10 - 6)$ превосходило коэффициент, подразумеваемый в $O(n)$). Таким образом, индуктивный переход возможен при $n > 70$ (заметим ещё, что при таких n выражения $\lceil n/5 \rceil$ и $\lfloor 7n/10 + 6 \rfloor$ меньше n).

Увеличив c ещё (если надо), можно добиться того, чтобы $T(n)$ не превосходило cn и при всех $n \leqslant 70$, что завершает рассуждение по индукции. Стало быть, алгоритм Select работает за линейное время (в худшем случае).

Отметим, что алгоритмы Select и Randomized-Select, в отличие от описанных в главе 9 алгоритмов сортировки за линейное время, используют только попарные сравнения элементов массива и применимы для произвольного упорядоченного множества. Эти алгоритмы асимптотически эффективнее очевидного подхода *"упорядочи множество и выбери нужный элемент"*, поскольку всякий алгоритм сортировки, использующий только попарные сравнения, требует времени $\Omega(n \lg n)$ не только в худшем случае (раздел 9.1), но и в среднем (задача 9-1).

Упражнения

10.3-1 Будет ли алгоритм Select работать за линейное время, если разбивать массив на группы не из пяти, а из семи элементов? Покажите, что для групп из трёх элементов рассуждение не проходит.

10.3-2 Пусть x — *"медиана медиан"* в алгоритме Select (массив содержит n элементов). Покажите, что при $n \geqslant 38$ количество элементов, бóльших x (так же как и количество элементов, меньших x) не меньше $\lceil n/4 \rceil$.

10.3-3 Модифицируйте алгоритм быстрой сортировки так, чтобы он работал за время $O(n \lg n)$ в худшем случае.

10.3-4* Пусть алгоритм выбора i-го по счёту элемента использует только попарные сравнения. Покажите, что с помощью тех же сравнений можно в качестве побочного результата получить списки элементов, меньших искомого, а также бóльших искомого.

10.3-5 Пусть у нас есть какой-то алгоритм, находящий медиану за линейное в худшем случае время. Используя его в качестве подпрограммы, разработайте простой алгоритм, решающий задачу нахождения произвольной порядковой статистики за линейное время.

10.3-6 Под k-**квантилями** (k-th quantiles) множества из n чисел мы понимаем $k-1$ его элементов, обладающих следующим свойством: если расположить элементы множества в порядке возрастания, то квантили будут разбивать множество на k равных (точнее, отличающихся не более чем на один элемент) частей. Разработайте алгоритм, который за время $O(n \lg k)$ находит k-квантили данного множества.

10.3-7 Разработайте алгоритм, который по заданному k находит в данном множестве S его k элементов, менее всего отстоящих от медианы. Число операций должно быть $O(|S|)$.

Рисунок 10.2 Как провести с востока на запад магистраль, чтобы суммарная длина подводящих трубопроводов была минимальна?

10.3-8 Пусть $X[1\,..\,n]$ и $Y[1\,..\,n]$ — два возрастающих массива. Разработайте алгоритм, находящий за время $O(\lg n)$ медиану множества, полученного объединением элементов этих массивов.

10.3-9 Профессор консультирует нефтяную компанию, которой требуется провести магистральный нефтепровод в направлении строго с запада на восток через нефтеносное поле, на котором расположены n нефтяных скважин. От каждой скважины необходимо подвести к магистрали трубопровод по кратчайшему пути (строго на север или на юг, рис. 10.2). Координаты всех скважин профессору известны; необходимо выбрать местоположение магистрали, чтобы сумма длин всех трубопроводов, ведущих от скважин к магистрали, была минимальна. Покажите, что оптимальное место для магистрали можно найти за линейное время.

Задачи

10-1 Сортировка i наибольших элементов

Дано множество из n чисел; требуется выбрать из них i наибольших и отсортировать (пользуясь только попарными сравнениями). Для каждого из приведенных ниже подходов разработайте соответствующий алгоритм и выясните, как зависит от n и i время работы этих алгоритмов в худшем случае.

а Отсортировать все числа и выписать i наибольших.

б Поместить числа в очередь с приоритетами и вызвать i раз процедуру Extract-Max.

в Найти с помощью алгоритма раздела 10.3 i-е по величине число (считая от наибольшего), разбить массив относительно него и отсортировать i наибольших чисел.

10-2 Взвешенная медиана

Пусть дано n различных чисел $x_1, \ldots, x_n$, и пусть каждому x_i сопоставлено положительное число (*"вес"*) w_i, причём сумма всех весов равна 1. **Взвешенной медианой** (weighted median) называется такое число x_k, что

$$\sum_{x_i < x_k} w_i \leqslant \frac{1}{2} \qquad \text{и} \qquad \sum_{x_i > x_k} w_i \leqslant \frac{1}{2}.$$

а Покажите, что если все веса равны $1/n$, то взвешенная медиана совпадает с обычной.

б Как найти взвешенную медиану n чисел с помощью сортировки за время $O(n \lg n)$ в худшем случае?

в Как модифицировать алгоритм Select (раздел 10.3), чтобы он искал взвешенную медиану за время $\Theta(n)$ в худшем случае?

Задача о выборе места для почты (post-office location problem) состоит в следующем. Дано n точек $p_1, \ldots, p_n$ и n положительных весов $w_1, \ldots, w_n$; требуется найти точку p (не обязательно совпадающую с одной из p_i), для которой выражение $\sum_{i=1}^{n} w_i d(p, p_i)$ будет минимально (через $d(a,b)$ обозначается расстояние между точками a и b).

д Покажите, что в одномерном случае (точки — вещественные числа, $d(a,b) = |a-b|$) взвешенная медиана будет решением этой задачи.

е Найдите оптимальное решение в двумерном случае (точки — пары вещественных чисел), если расстояние между точками $a = (x_1, y_1)$ и $b = (x_2, y_2)$ задается *"в L_1-метрике"*: $d(a,b) = |x_1 - x_2| + |y_1 - y_2|$ (американцы называют такую метрику Manhattan distance, по названию района Нью-Йорка, разбитого улицами на прямоугольные кварталы)

10-3 Нахождение i-го по величине элемента при малых i

Пусть $T(n)$ — время работы процедуры Select, примененной к массиву из n чисел; в худшем случае $T(n) = \Theta(n)$, но коэффициент при n, подразумеваемый в этом обозначении, довольно велик. Если i мало по сравнению с n, то отобрать i-ый по величине элемент можно быстрее.

а Опишите алгоритм, который находит i-й по величине элемент в множестве из n чисел, делая $U_i(n)$ сравнений, причём

$$U_i(n) = \begin{cases} T(n) & \text{если } n \leqslant 2i, \\ n/2 + U_i(\lfloor n/2 \rfloor) + T(2i+1) & \text{иначе.} \end{cases}$$

(Указание: сделайте $\lfloor n/2 \rfloor$ попарных сравнений и отберите i наименьших среди меньших элементов пар.)

б Покажите, что $U_i(n) = n + O(T(2i)\log(n/i))$.

в Покажите, что, при постоянном i, имеем $U_i(n) = n + O(\lg n)$. [Та же оценка получится, если построить кучу из главы 7, а затем i раз выбрать из неё минимальный элемент.]

г Пусть $i = n/k$, причём $k \geqslant 2$; покажите, что $U_i(n) = n + O(T(2n/k)\lg k)$.

Замечания

Алгоритм для нахождения медианы за линейное в худшем случае время предложили Блюм, Флойд, Пратт, Ривест и Тарьян [29]. Вероятностный алгоритм с линейным средним временем работы принадлежит Хоару [97]. Флойд и Ривест [70] разработали усовершенствованную версию этого алгоритма, в которой граница разбиения определяется по небольшой случайной выборке.

III Структуры данных

Введение

В программировании часто приходится иметь дело с множествами, меняющимися в процессе выполнения алгоритма. В следующих пяти главах мы рассмотрим структуры данных, предназначенные для хранения изменяющихся (**динамических**, по-английски dynamic) множеств.

Разные алгоритмы используют разные операции. Нередко, например, требуется лишь добавлять и удалять элементы в множество, а также проверять, принадлежит ли множеству данный элемент. Структура данных, поддерживающая такие операции, называется **словарём** (dictionary). В других ситуациях могут понадобиться более сложные операции. Например, очереди с приоритетами, о которых шла речь в главе 7 в связи с кучами, разрешают выбирать и удалять *наименьший* элемент (помимо добавления элементов). Понятно, что выбор реализации динамического множества зависит от того, какие операции с ним нам потребуются.

Элементы множеств

Обычно элемент динамического множества — это запись, содержащая различные поля. Часто одно из полей рассматривается как **ключ** (key), предназначенный для идентификации элемента, а остальные поля — как **дополнительная информация** (satellite data), хранящаяся вместе с ключом. Элемент множества ищется по ключу; когда элемент, мы можем прочесть или изменить дополнительную информацию, имеющуюся в этом элементе. Во многих случаях все ключи различны, и тогда множество можно рассматривать как функцию, которая с каждым (существующим) ключом сопоставляет некоторую дополнительную информацию.

Многие способы реализации множеств требуют, чтобы вместе с каждым ключом хранились не только дополнительные данные, но и некоторая служебная информация (например, указатели на другие элементы множества)

Часто на множестве ключей имеется естественный линейный порядок (например, ключи могут быть действительными числами или словами, на которых есть лексикографический порядок). В этом случае можно говорить, например, о наименьшем элементе множества или об элементе, непосредственно следующем за данным.

Мы предполагаем, что элементы множества хранятся в некоторой общей области памяти и для каждого имеется указатель, который позволяет получить доступ к этому элементу. Обычно в качестве указателя выступает просто адрес в памяти; если язык программирования этого не предусматривает, указателем может быть индекс в массиве.

Операции над множествами

Операции над множествами делятся на **запросы** (queries), которые не меняют множества, и **операции, меняющие множество** (modifying operations). Типичные операции с множествами таковы:

SEARCH(S,k) (поиск). Запрос, который по данному множеству S и ключу k возвращает указатель на элемент множества S с ключом k. Если такого элемента в множестве S нет, возвращается NIL.

INSERT(S,x) добавляет к множеству S элемент, на который указывает указатель x (подразумевается, что к этому моменту все поля в записи, на которую указывает x, уже заполнены).

DELETE(S,x) удаляет из множества S элемент, на который указывает указатель x (обратите внимание, что x — указатель, а не ключ).

MINIMUM(S) выдаёт указатель на элемент множества S с наименьшим ключом (считаем, что ключи линейно упорядочены).

MAXIMUM(S) выдаёт указатель на элемент множества S с наибольшим ключом.

SUCCESSOR(S,x) (следующий) возвращает указатель на элемент множества S, непосредственно следующий за элементом x (в смысле линейного порядка на ключах). Если x — наибольший элемент, возвращается NIL.

PREDECESSOR(S,x) (предыдущий) возвращает указатель на элемент, непосредственно предшествующий элементу x (если x — наименьший элемент, возвращается NIL).

Запросы SUCCESSOR и PREDECESSOR часто используются и при работе с множествами, в которых ключи различных элементов могут совпадать. При этом разумная реализация гарантирует, что функции SUCCESSOR и PREDECESSOR обратны, что начав с MINUMUM(S)

и применяя функцию Successor, мы перечислим все элементы множества в неубывающем порядке и т. п.

Стоимость операций над множествами обычно оценивается через размер множеств, к которым они применяются. Например, в главе 14 мы описываем структуру данных, которая позволяет выполнить каждую из перечисленных операций за время $O(\lg n)$, где n — число элементов множества.

Обзор части III

В главах 11–15 мы описываем различные структуры данных, предназначенные для работы с динамическими множествами. С помощью этих структур данных можно разработать эффективные алгоритмы для решения многих различных задач. Кстати, с одной важной структурой данных (кучей) мы уже познакомились в главе 7.

В главе 11 мы разбираем принципы работы с простейшими структурами данных: стеками, очередями, связанными списками и корневыми деревьями. В этой же главе рассказывается, как реализовать записи и указатели с помощью языков программирования, в которых нет соответствующих типов данных. Бóльшая часть материала этой главы составляет стандартный материал начального курса программирования.

В главе 12 мы познакомимся с хеш-таблицами, поддерживающими операции Insert, Delete и Search. В худшем случае поиск в хеш-таблице требует времени $\Theta(n)$, но среднее время, необходимое для выполнения любой из словарных операций с хеш-таблицей, составляет (при некоторых предположениях) лишь $O(1)$. Анализ хеширования использует теорию вероятностей, но для понимания большей части главы знакомство с этой теорией не обязательно.

В главе 13 мы занимаемся деревьями двоичного поиска. Эти деревья поддерживают все перечисленные операции с множествами. В худшем случае стоимость каждой из операций есть $\Theta(n)$, но для случайно построенного дерева математическое ожидание этой стоимости есть $O(\lg n)$. На базе деревьев двоичного поиска строятся многие другие структуры данных.

Глава 14 посвящена красно-чёрным деревьям. Эта разновидность деревьев двоичного поиска гарантированно работает быстро: время выполнения каждой операции в худшем случае есть $O(\lg n)$. Красно-чёрные деревья представляют собой один из вариантов *"сбалансированных"* деревьев поиска; другой вариант (Б-деревья) обсуждается в главе 19. Алгоритмы для работы с красно-чёрными деревьями устроены довольно хитро. Хотя детали можно опустить при первом чтении, интересно в них разобраться.

В главе 15 мы рассматриваем дополнительные структуры на красно-чёрных деревьях, позволяющие выполнять ещё несколько операций (порядковые статистики, операции с деревьями промежутков).

11 Элементарные структуры данных

В этой главе мы рассматриваем несколько простых структур данных для хранения множеств: стеки, очереди, списки, корневые деревья. Мы покажем, как можно реализовать их с помощью указателей или массивов.

11.1 Стеки и очереди

Стеки и очереди — это динамические множества, в которых элемент, удаляемый из множества операцией Delete, не задаётся произвольно, а определяется структурой множества. Именно, из **стека** (stack) можно удалить только тот элемент, который был в него добавлен последним: стек работает по принципу *"последним пришёл — первым ушёл"* (last-in, first-out — сокращенно LIFO). Из **очереди** (queue), напротив, можно удалить только тот элемент, который находился в очереди дольше всего: работает принцип *"первым пришёл — первым ушёл"* (first-in, first-out, сокращенно FIFO). Существует несколько способов эффективно реализовать стеки и очереди. В этом разделе мы расскажем, как реализовать их на базе массива.

Стеки

Операция добавления элемента в стек часто обозначается Push, а операция удаления верхнего элемента из стека часто обозначается Pop (push в данном контексте означает *"запихивать"*, а pop — *"вынимать"*). Стек можно уподобить стопке тарелок, из которой можно взять верхнюю и на которую можно положить новую тарелку. [Другое название стека в русской литературе — *"магазин"* — понятно всякому, кто разбирал автомат Калашникова.]

На рис. 11.1 показано, как можно реализовать стек ёмкостью не более n элементов на базе массива $S[1\,..\,n]$. Наряду с массивом мы храним число $top[S]$, являющееся индексом последнего добавленного в стек элемента. Стек состоит из элементов $S[1\,..\,top[S]]$, где $S[1]$ —

Рисунок 11.1 Реализация стека на базе массива S. Светло-серые клетки заняты элементами стека. (а) Стек S содержит 4 элемента, верхний элемент — число 9. (б) Тот же стек после выполнения операций Push(S, 17) и Push(S, 3). (в) Стек после того, как операция Pop(S) вернула значение 3 (последний добавленный в стек элемент). Хотя число 3 по-прежнему присутствует в массиве S, в стеке его уже нет; на вершине стека — число 17.

нижний элемент стека (*"дно"*) а $S[top[S]]$ — верхний элемент, или вершина стека.

Если $top[S] = 0$, то стек **пуст** (is empty). Если $top[S] = n$, то при попытке добавить элемент происходит **переполнение** (overflow), поскольку размер стека в нашей реализации ограничен числом n. Симметричная ситуация — попытка удалить элемент из пустого стека — по-русски никак не называется (*"недо-полнение"*?), а по-английски называется underflow. В этой главе для простоты мы не будем обращать внимание на возможность переполнения стека.

Операции со стеком (проверка пустоты, добавление элемента, удаление элемента) записываются так:

```
Stack-Empty(S)
if top[S] = 0
   then return TRUE
   else return FALSE
```

```
Push(S, x)
top[S] ← top[S] + 1
S[top[S]] ← x
```

```
Pop(S)
if Stack-Empty(S)
   then error "underflow"
   else top[S] ← top[S] − 1
        return S[top[S] + 1]
```

Выполнение операций Push и Pop показано на рис. 11.1. Каждая из трёх операций со стеком выполняется за время $O(1)$.

Очереди

Операцию добавления элемента к очереди мы будем обозначать Enqueue, а операцию удаления элемента из очереди будем обозначать Dequeue. (Как и для стеков, удаляемый из очереди элемент определен однозначно и поэтому является не передаётся процедуре процедуре Dequeue, а возвращается этой процедурой.) Правило здесь такое же, как в живой очереди: первым пришёл — первым обслужен. (И если наши программы правильны, можно не опасаться, что кто-то пройдёт без очереди.)

Другими словами, у очереди есть **голова** (head) и **хвост** (tail). Элемент, добавляемый в очередь, оказывается в её хвосте, как только что подошедший покупатель; элемент, удаляемый из очереди, находится в её голове, как тот покупатель, что отстоял дольше всех.

На рис. 11.2 показано, как можно реализовать очередь, вмещающую не более чем $n-1$ элемент, на базе массива $Q[1\,..\,n]$. Мы храним числа $head[Q]$ — индекс головы очереди, и $tail[Q]$ — индекс свободной ячейки, в которую будет помещён следующий добавляемый к очереди элемент. Очередь состоит из элементов массива, стоящих на местах с номерами $head[Q]$, $head[Q]+1$, $\ldots$, $tail[Q]-1$ (подразумевается, что массив свёрнут в кольцо: за n следует 1). Если $head[Q] = tail[Q]$, то очередь пуста. Первоначально имеем $head[Q] = tail[Q] = 1$. Если очередь пуста, попытка удалить элемент из неё ведёт к ошибке (underflow); если $head[Q] = tail[Q]+1$, то очередь полностью заполнена, и попытка добавить к ней элемент вызовет переполнение (overflow).

В наших реализациях процедур Enqueue и Dequeue мы игнорируем возможность переполнения или попытки изъятия элемента из пустой очереди (в упражнении 11.1-4 мы попросим вас внести в код соответствующие проверки).

Enqueue(Q, x)

$Q[tail[Q]] \leftarrow x$
if $tail[Q] = length[Q]$
  then $tail[Q] \leftarrow 1$
  else $tail[Q] \leftarrow tail[Q] + 1$

Dequeue(Q)

$x \leftarrow Q[head[Q]]$
if $head[Q] = length[Q]$
  then $head[Q] \leftarrow 1$
  else $head[Q] \leftarrow head[Q] + 1$
return x

Работа процедур Enqueue и Dequeue показана на рис. 11.2. Каждая из этих процедур работает за время $O(1)$.

Рисунок 11.2 Очередь, реализованная на базе массива $Q[1\,..\,n]$. Светло-серые клетки заняты элементами очереди. (а) В очереди находятся 5 элементов (позиции $Q[7\,..\,11]$). (б) Очередь после выполнения процедур Enqueue(Q, 17), Enqueue(Q, 3) и Enqueue(Q, 5). (в) Очередь после выполнения процедуры Dequeue(Q) (которая возвращает значение 15). Новой головой очереди стало число 6.

Упражнения

11.1-1 Следуя образцу рис. 11.1, покажите работу операций Push(S, 4), Push(S, 1), Push(S, 3), Pop(S), Push(S, 8) и Pop(S) на стеке, реализованном с помощью массива $S[1\,..\,6]$. Первоначально стек пуст.

11.1-2 Как на базе одного массива $A[1\,..\,n]$ реализовать два стека суммарной длины не больше n? Операции Push и Pop должны выполняться за время $O(1)$.

11.1-3 Следуя образцу рис. 11.2, покажите работу операций Enqueue(Q, 4), Enqueue(Q, 1), Enqueue(Q, 3), Dequeue(Q), Enqueue(Q, 8) и Dequeue(Q) на очереди, реализованной с помощью массива $Q[1\,..\,5]$. Первоначально очередь пуста.

11.1-4 Перепишите процедуры Enqueue и Dequeue, предусмотрев проверки на случай переполнения или underflow.

11.1-5 Стек позволяет добавлять и удалять элементы только с одного конца. В очередь добавлять элементы можно только с одного конца, а удалять — только с другого. Структура данных, называемая **деком** (deque, от double-ended queue — *"очередь с двумя концами"*), позволяет добавлять и удалять элементы с обоих концов. Реализуйте дек на базе массива таким образом, чтобы операции добавления и удаления элемента с каждого из концов занимали время $O(1)$.

11.1-6 Объясните, как можно реализовать очередь на базе двух стеков. Каково время работы операций ENQUEUE и DEQUEUE при такой реализации?

11.1-7 Объясните, как реализовать стек на базе двух очередей. Каково время работы стековых операций?

11.2 Связанные списки

В **связанном списке** (или просто списке; по-английски linked list) элементы линейно упорядочены, но порядок определяется не номерами, как в массиве, а указателями, входящими в состав элементов списка. Списки являются удобным способом реализации динамических множеств, позволяющим реализовать все операции, перечисленные во введении к этой части (хотя и не всегда эффективно).

Если каждый стоящий в очереди запомнит, кто за ним стоит, после чего все в беспорядке рассядутся на лавочке, получится односторонне связанный список; если он запомнит ещё и впереди стоящего, будет двусторонне связанный список.

Другими словами, как показано на рис. 11.3, элемент **двусторонне связанного списка** (doubly linked list) — это запись, содержащая три поля: *key* (ключ) и два указателя *next* (следующий) и *prev* (от previous — предыдущий). Помимо этого, элементы списка могут содержать дополнительные данные. Если x — элемент списка, то $next[x]$ указывает на следующий элемент списка, а $prev[x]$ — на предшествующий. Если $prev[x] = \text{NIL}$, то у элемента x нет предшествующего: это **голова** (head) списка. Если $next[x] = \text{NIL}$, то x — последний элемент списка или, как говорят, его **хвост** (tail).

Прежде чем двигаться по указателям, надо знать хотя бы один элемент списка; мы предполагаем, что для списка L известен указатель $head[L]$ на его голову. Если $head[L] = \text{NIL}$, то список пуст.

В различных ситуациях используются разные виды списков. В **односторонне связанном** (singly linked) списке отсутствуют поля *prev*. В **упорядоченном** (sorted) списке элементы расположены в порядке возрастания ключей, так что у головы списка ключ наименьший, а у хвоста списка — наибольший, в отличие от **неупорядоченного** (unsorted) списка. В **кольцевом списке** (circular list) поле *prev* головы списка указывает на хвост списка, а поле *next* хвоста списка указывает на голову списка.

Если иное не оговорено особо, под списком мы будем понимать неупорядоченный двусторонне связанный список.

Рисунок 11.3 (а) Двусторонне связанный список L содержит числа $1, 4, 9, 16$. Каждый элемент списка — это запись с полями для ключа и указателей на предыдущий и последующий элементы (эти указатели изображены стрелками). В поле *next* у хвоста списка и в поле *prev* у головы списка находится указатель NIL (косая черта на рисунке); *head*[L] указывает на голову списка. (б) В результате выполнения операции List-Insert(L, x), где $key[x] = 25$, в списке появился новый элемент с ключом 25; он стал новой головой списка, а его поле *next* указывает на бывшую голову — элемент с ключом 9. (в) Вслед за этим была выполнена операция List-Delete(L, x), где x — указатель на элемент с ключом 4.

Поиск в списке

Процедура List-Search(L, k) находит в списке L (с помощью простого линейного поиска) первый элемент, имеющий ключ k. Точнее говоря, она возвращает указатель на этот элемент, или NIL, если элемента с таким ключом в списке нет. Если, например, L — список рис. 11.3а, то вызов List-Search$(L, 4)$ вернёт указатель на третий элемент списка, а вызов List-Search$(L, 7)$ вернёт NIL.

```
List-Search(L, k)
x ← head[L]
while x ≠ NIL and key[x] ≠ k
      do x ← next[x]
return x
```

Поиск в списке из n элементов требует в худшем случае (когда приходится просматривать весь список) $\Theta(n)$ операций.

Добавление элемента в список

Процедура List-Insert добавляет элемент x к списку L, помещая его в голову списка (рис. 11.3б).

```
LIST-INSERT(L, x)
next[x] ← head[L]
if head[L] ≠ NIL
   then prev[head[L]] ← x
head[L] ← x
prev[x] ← NIL
```

Процедура LIST-INSERT выполняется за время $O(1)$ (не зависящее от длины списка).

Удаление элемента из списка

Процедура LIST-DELETE удаляет элемент x из списка L, направляя указатели ***"в обход"*** этого элемента. При этом в качестве аргумента ей передаётся указатель на x. Если задан ключ элемента x, то перед удалением надо найти его указатель с помощью процедуры LIST-SEARCH.

```
LIST-DELETE(L, x)
if prev[x] ≠ NIL
   then next[prev[x]] ← next[x]
   else head[L] ← next[x]
if next[x] ≠ NIL
   then prev[next[x]] ← prev[x]
```

Удаление элемента из списка проиллюстрировано на рис. 11.3в. Процедура LIST-DELETE работает за время $O(1)$; однако для удаления элемента с заданным ключом его надо сначала найти, что потребует времени $\Theta(n)$.

Фиктивные элементы

Если забыть об особых ситуациях на концах списка, процедуру LIST-DELETE можно записать совсем просто:

```
LIST-DELETE'(L, x)
next[prev[x]] ← next[x]
prev[next[x]] ← prev[x]
```

Такие упрощения станут законными, если добавить к списку L фиктивный элемент $nil[L]$, который будет иметь поля *next* и *prev* наравне с прочими элементами списка. Этот элемент (называемый **sentinel** — часовой) не позволит нам выйти за пределы списка. Указатель на него играет роль значения NIL. Замкнём список в кольцо: в поля $next[nil[L]]$ и $prev[nil[L]]$ запишем указатели на голову и хвост списка соответственно, а в поля *prev* у головы списка и *next* у

Рисунок 11.4 Список L, использующий фиктивный элемент $nil[L]$ (тёмно-серый прямоугольник). Вместо $head[L]$ используем $next[nil[L]]$. (а) Пустой список. (б) Список рис. 11.3а (элемент с ключом 9 — голова, 1 — хвост). (в) Тот же список после процедуры List-Insert$'(L, x)$, если $key[x] = 25$. (г) После удаления элемента с ключом 1. Новый хвост имеет ключ 4.

хвоста списка занесём указатели на $nil[L]$ (рис. 11.4). При этом $next[nil[L]]$ — указатель на голову списка, так что атрибут $head[L]$ становится лишним. Пустой список L теперь будет кольцом, в котором $nil[L]$ — единственный элемент.

В процедуре List-Search нужно лишь заменить NIL на $nil[L]$ и $head[L]$ на $next[nil[L]]$:

List-Search$'(L, k)$

$x \leftarrow next[nil[L]]$
while $x \neq nil[L]$ and $key[x] \neq k$
  do $x \leftarrow next[x]$
return x

Для удаления элемента годится процедура List-Delete$'$, приведённая выше. Наконец, добавлять элемент к списку можно так:

List-Insert$'(L, x)$

$next[x] \leftarrow next[nil[L]]$
$prev[next[nil[L]]] \leftarrow x$
$next[nil[L]] \leftarrow x$
$prev[x] \leftarrow nil[L]$

Пример работы процедур List-Insert$'$ и List-Delete$'$ показан на рис. 11.4.

Использование фиктивных элементов едва ли может улучшить асимптотику времени работы алгоритма, но упрощает программу. Иногда (если использование фиктивных элементов позволяет сократить фрагмент кода, находящийся глубоко внутри цикла), можно ускорить исполнение программы в несколько раз.

Не следует применять фиктивные элементы без нужды. Если алгоритм использует много коротких списков, использование фиктивных элементов может обернуться серьезной дополнительной тратой памяти. В этой книге фиктивные элементы используются только тогда, когда это существенно упрощает программу.

Упражнения

11.2-1 Можно ли добавить элемент в множество, представленное односторонне связанным списком, за время $O(1)$? Тот же вопрос для удаления элемента.

11.2-2 Реализуйте стек на базе односторонне связанного списка. Операции PUSH и POP должны выполняться за время $O(1)$.

11.2-3 Реализуйте очередь на базе односторонне связанного списка. Операции ENQUEUE и DEQUEUE должны выполняться за время $O(1)$.

11.2-4 Реализуйте словарные операции INSERT, DELETE и SEARCH для свёрнутого в кольцо односторонне связанного списка. Каково время работы ваших процедур?

11.2-5 Операция UNION (объединение) получает на входе два непересекающихся множества и возвращает их объединение (сами исходные множества при этом пропадают). Реализуйте эту операцию так, чтобы она работала за время $O(1)$, представляя множества списками подходящего типа.

11.2-6 Напишите процедуру, которая сливает два односторонне связанных упорядоченных списка в один (также упорядоченный), не используя фиктивных элементов. Затем сделайте это, используя фиктивный элемент с ключом ∞ (добавляемый в конец списков). Какая из двух программ проще?

11.2-7 Напишите нерекурсивную процедуру, которая за время $\Theta(n)$ переставляет элементы односторонне связанного списка в обратном порядке. Объём дополнительной (помимо необходимой для хранения исходного списка) памяти должен быть $O(1)$.

11.2-8* Есть способ сэкономить место при реализации двусторонне связанного списка, сжав два указателя *next* и *prev* в одно значение $np[x]$. Будем считать, что все указатели суть k-битные числа и указателю NIL соответствует число нуль. Определим $np[x]$ по формуле $np[x] = next[x] \,\mathrm{XOR}\, prev[x]$, где XOR — побитовое сложение по модулю 2 (исключающее ИЛИ). Не забудьте указать, каким образом хранится информация о голове списка. Как реализовать операции SEARCH, INSERT и DELETE? Объясните, как переставить такой список в обратном порядке за время $O(1)$.

Рисунок 11.5 Список рис. 11.3а, представленный с помощью тройки массивов ($key, next, prev$). Каждому элементу списка соответствует светло-серый столбик. В верхней строчке выписаны порядковые номера, играющие роль указателей; действие указателей показано стрелками. Значение переменной L — указатель на голову списка.

11.3 Реализация указателей и записей с несколькими полями

В языках вроде фортрана не предусмотрено ни указателей, ни элементов, имеющих несколько полей. В таком случае приходится обходиться массивами, используя индекс в массиве как указатель и заменяя массив записей несколькими массивами.

Представление с помощью нескольких массивов

Массив, составленный из записей, можно заменить несколькими массивами (по одному на каждое поле записи). Например, на рис. 11.5 показано, как представить в виде трёх массивов тот же список, что и на рис. 11.3а: в массиве key хранятся ключи, а в массивах $next$ и $prev$ — указатели. Каждому элементу списка соответствует тройка $(key[x], next[x], prev[x])$ для некоторого индекса x. Роль указателя на этот элемент играет число x. В качестве NIL можно использовать число, не являющееся индексом никакого элемента массивов (например, 0 или -1). На рис. 11.3а запись с ключом 4 стоит в списке сразу после записи с ключом 16; и действительно, число 16 стоит в массиве key на месте с номером 5, число 4 — на месте номер 2, и имеем $next[5] = 2$, а также $prev[2] = 5$.

В наших программах обозначение типа $key[x]$ может пониматься двояко: и как элемент массива key с индексом x, и как поле key записи с адресом x (в зависимости от возможностей языка программирования полезно то или другое понимание).

Представление с помощью одного массива

Вместо нескольких массивов можно использовать один, размещая в нём различные поля одного объекта рядом. Так обычно поступает компилятор: если в программе используется массив элементов, ка-

Рисунок 11.6 Тот же список, что на рис. 11.3а и 11.5, реализованный на базе единственного массива A. Каждой записи соответствует тройка идущих подряд элементов массива. Полям *key*, *next* и *prev* соответствуют сдвиги 0, 1 и 2. Указатель на запись — индекс первого из отведённых для неё элементов. Светло-серые записи входят в список; стрелками изображено действие указателей.

ждый из которых имеет несколько полей, то на каждый элемент отводится непрерывный участок памяти, в котором друг за другом размещаются значения полей. Указателем на элемент обычно считают адрес первой ячейки этого участка; адреса полей получаются сдвигом на определённые константы.

При реализации записей на базе массива можно воспользоваться той же стратегией. Рассмотрим один-единственный массив A. Каждая запись будет занимать в нём непрерывный участок $A[j\,..\,k]$. Указатель на запись — это индекс j; каждому полю записи соответствует число из интервала $[0\,..\,k-j]$ — сдвиг. Например, при представлении всё того же списка, что и на рис. 11.3а и 11.5, можно решить, что полям *key*, *next* и *prev* соответствуют сдвиги 0, 1 и 2. Тогда значение $prev[i]$, где i — указатель (= индекс в массиве A), есть не что иное, как $A[i+2]$ (см. рис. 11.6).

Такое представление позволяет хранить в одном массиве записи разных типов (отводя под них участки разной длины), но для наших целей будет достаточно представления в виде нескольких массивов, поскольку большинство структур данных, с которыми мы будем иметь дело, состоят из однотипных записей.

Выделение и освобождение памяти

При добавлении нового элемента в список надо отвести под него место в памяти. Стало быть, необходимо вести учёт использования адресов. В некоторых системах этим ведает специальная подпрограмма — **сборщик мусора** (garbage collector), которая определяет, какие участки памяти более не используются, и возвращает их для повторного использования. Во многих случаях, однако, можно возложить обязанности по выделению и освобождению памяти на саму структуру данных. В этом разделе мы покажем, как это делается; в качестве примера рассмотрим двусторонне связанный список, представленный с помощью нескольких массивов.

Пусть массивы, с помощью которых мы представляем наш спи-

Рисунок 11.7 Работа процедур Allocate-Object и Free-Object. (а) Тот же список, что на рис. 11.5 (светло-серый) и список свободных позиций (тёмно-серый). Структура списка свободных позиций изображена с помощью стрелок. (б) Вот что получится после вызова Allocate-Object() (возвращает значение 4), присваивания $key[4] \leftarrow 25$ и вызова List-Insert$(L, 4)$. Новый список свободных позиций начинается с 8 (таково было значение $next[4]$). (в) Теперь мы вызвали List-Delete$(L, 5)$, а затем Free-Object(5). Позиция 5 — голова нового списка свободных позиций, за ней следует 8.

сок, имеют длину m, и пусть в данный момент в списке содержится $n \leqslant m$ элементов. Остальные $n - m$ мест (позиций) в массиве **свободны** (free).

Мы будем хранить свободные позиции в односторонне связанном списке, называемом **списком свободных позиций** (free list). Этот список использует только массив *next*: именно, $next[i]$ содержит индекс свободной позиции, следующей за свободной позицией i. Голова списка хранится в переменной *free*. Список свободных позиций хранится вперемежку со списком L (рис. 11.7). Обратите внимание, что каждому числу из отрезка $[1; m]$ отвечает элемент либо списка L, либо списка свободных мест.

Список свободных позиций ведёт себя как стек: из всех свободных участков памяти под новую запись выделяется тот, который был освобождён последним. Поэтому для выделения и освобождения памяти можно воспользоваться реализацией стековых операций Push и Pop на базе списка. В приводимых ниже процедурах Allocate-Object (выделить место) и Free-Object (освободить место) подразумевается, что в глобальной переменной $free$ записан индекс первой (в списке) свободной позиции.

Рисунок 11.8 Списки L_1 (светло-серый) и L_2 (тёмно-серый), а также список свободных мест (черный) хранятся в одной тройке массивов.

```
Allocate-Object()
if free = NIL
   then error "Свободного места нет"
   else x ← free
        free ← next[x]
        return x
```

```
Free-Object(x)
next[x] ← free
free ← x
```

Первоначально список свободных позиций содержит n элементов. Если свободного места не осталось, процедура Allocate-Object сообщает об ошибке.

Часто один список свободных позиций обслуживает сразу несколько динамических множеств (рис. 11.8).

Описанные процедуры выделения и освобождения памяти просты и удобны (работают за время $O(1)$). Их можно приспособить для хранения однотипных записей любого вида, отведя одно из полей записи под хранение индекса *next* (в свободных позициях).

Упражнения

11.3-1 Следуя образцу рис. 11.5, изобразите представление последовательности $\langle 13, 4, 8, 19, 5, 11 \rangle$ в виде двусторонне связанного списка, реализованного с помощью трех массивов; по образцу рис. 11.6 изобразите тот же список, реализованный с помощью одного массива.

11.3-2 Напишите процедуры Allocate-Object и Free-Object для случая однотипных записей, хранящихся в одном массиве.

11.3-3 Почему в процедурах Allocate-Object и Free-Object никак не фигурирует поле *prev*?

11.3-4 Часто (например, при страничной организации виртуальной памяти) бывает полезно хранить элементы списка в непрерывном участке памяти. Рассмотрим реализацию списка с помощью нескольких массивов. Перепишите процедуры Allocate-Object и Free-Object таким образом, чтобы элементы списка занимали позиции $1..m$, где m — число элементов списка. (Указание: воспользуйтесь реализацией стека на базе массива.)

11.3-5 Пусть двусторонне связанный список L длины m представлен с помощью трех массивов *key*, *prev* и *next* длины n, а процедуры выделения и освобождения места поддерживают *двусторонне* связанный список свободных позиций.

Напишите процедуру Compactify-List (сжатие списка), которая переписывает список L длины m в первые m позиций массивов, сохраняя его структуру (и изменяя список свободных позиций нужным образом). Время работы алгоритма должно быть $\Theta(m)$, размер используемой памяти (сверх занятой массивами) должен быть $O(1)$. Не забудьте доказать правильность своего алгоритма.

11.4 Представление корневых деревьев

Описанные в предыдущем разделе способы представления списков применимы и к другим структурам данных, составленным из однотипных элементов. В этом разделе мы научимся использовать указатели для представления деревьев. Начнём мы с двоичных деревьев, а затем объясним, как представлять деревья с произвольным ветвлением.

Каждая вершина дерева будет записью с несколькими полями. Одно из этих полей содержит ключ, как и в случае со списками. Остальные поля предназначены для хранения дополнительных данных и, главное, указателей на другие вершины. Как конкретно устроены эти поля, зависит от типа дерева.

Двоичные деревья

Как показано на рис. 11.9, при представлении двоичного дерева T мы используем поля p, *left* и *right*, в которых хранятся указатели на родителя, левого и правого ребёнка вершины x соответственно. Если $p[x] =$ NIL, то x — корень; если у x нет левого или правого ребёнка, то *left*$[x]$ или *right*$[x]$ есть NIL. С деревом T связан атрибут *root*$[T]$ — указатель на его корень. Если *root*$[T] =$ NIL, то дерево T пусто.

Рисунок 11.9 Представление двоичного дерева T. Каждая вершина x включает поля $p[x]$ (сверху), $left[x]$ (внизу слева) и $right[x]$ (внизу справа). Ключи на схеме не показаны.

Корневые деревья с произвольным ветвлением

Если известно, что число детей каждой вершины ограничено сверху константой k, то такое дерево можно реализовать аналогично двоичному дереву, помещая указатели на детей в поля $child_1, child_2, \ldots, child_k$, заменяющие поля *left* и *right*. Если количество детей может быть любым, так делать нельзя: заранее неизвестно, сколько полей (или массивов — при представлении с помощью нескольких массивов) надо выделить.

Проблема может возникнуть и в том случае, если количество детей ограничено заранее известным числом k, но у большинства вершин число детей много меньше k: описанная реализация тратит много памяти зря.

Как же быть? Заметим, что любое дерево можно преобразовать в двоичное. При этом у каждой вершины будет не более двух детей: левый ребёнок останется тем же, но правым ребёнком станет вершина, которая была правым соседом (непосредственно следующим ребёнком того же родителя). Теперь это двоичное дерево можно хранить описанным выше способом.

Опишем схему хранения деревьев с произвольным ветвлением, основанную на этой идее, более подробно. Она называется *"левый ребёнок — правый сосед"* (left-child, right-sibling representation) и показана на рис. 11.10. По-прежнему в каждой вершине хранится указатель p на родителя и атрибут $root[T]$ является указателем на корень дерева. Кроме p, в каждой вершине хранятся ещё два указателя:

1. $left\text{-}child[x]$ указывает на самого левого ребёнка вершины x;

Рисунок 11.10 Представление дерева T по схеме *"левый ребёнок — правый сосед"*. В каждой записи x присутствуют поля $p[x]$ (сверху), *left-child*$[x]$ (внизу слева) и *right-sibling*$[x]$ (внизу справа). Ключи не показаны.

2. *right-sibling*$[x]$ указывает на ближайшего справа соседа вершины x (*"следующего по старшинству брата"*)

Вершина x не имеет детей тогда и только тогда, когда *left-child*$[x]$ = NIL. Если вершина x — крайний правый ребенок своего родителя, то *right-sibling*$[x]$ = NIL.

Другие способы представления деревьев

Иногда встречаются другие способы представления деревьев. Например, в главе 7 при реализации кучи не надо было хранить указателей на родителя и детей, поскольку их номера получались умножением и делением на 2. В главе 22 нам встретятся деревья, по которым двигаются от листьев к корню (и потому указатели на детей или соседей не нужны). Конкретный выбор представления дерева определяется спецификой задачи.

Упражнения

11.4-1 Нарисуйте двоичное дерево, представленное следующим образом:

индекс	*key*	*left*	*right*
1	12	7	3
2	15	8	NIL
3	4	10	NIL
4	10	5	9
5	2	NIL	NIL
6	18	1	4
7	7	NIL	NIL
8	14	6	2
9	21	NIL	NIL
10	5	NIL	NIL

Корень дерева — в вершине с индексом 6.

11.4-2 Напишите работающую за линейное время рекурсивную процедуру, которая печатает ключи всех вершин данного двоичного дерева.

11.4-3 Как сделать то же самое (что и в предыдущем упражнении), используя нерекурсивную процедуру? (При устранении рекурсии полезен стек.)

11.4-4 Напишите работающую за линейное время процедуру, печатающую ключи всех вершин дерева, представленного по схеме *"левый ребёнок — правый сосед"*.

11.4-5* Напишите работающую за линейное время нерекурсивную процедуру, печатающую ключи всех вершин двоичного дерева, для которой объём используемой памяти (сверх памяти, в которой хранится дерево) есть $O(1)$, и во время работы процедуры дерево не меняется (даже временно).

11.4-6* Придумайте способ хранения дерева с произвольным ветвлением, при котором в каждой вершине хранятся всего два (а не три, как в схеме *"левый ребенок — правый сосед"*) указателя плюс одна булева переменная.

Задачи

11-1 Сравнение разных типов списков

Найдите асимптотику времени работы (в худшем случае) для каждой из перечисленных в начале части III (с. ??) операций, применённой к каждому из указанных типов списков.

	неупорядоченный, односторонне связанный	упорядоченный, односторонне связанный	неупорядоченный, двусторонне связанный	упорядоченный, двусторонне связанный
SEARCH(L, k)				
INSERT(L, x)				
DELETE(L, x)				
SUCCESSOR(L, x)				
PREDECESSOR(L, x)				
MINIMUM(L)				
MAXIMUM(L)				

11-2 Реализация сливаемых куч на базе списков

Структура данных под названием **сливаемые кучи** (mergeable heaps) хранит набор динамических множеств (куч), и поддерживает следующие операции: MAKE-HEAP (создание пустой кучи), INSERT, MINIMUM, EXTRACT-MIN и, наконец, UNION (объединение двух куч в одну; две старые кучи пропадают). Для каждого из перечисленных ниже случаев реализуйте (по возможности эффективно) сливаемые кучи на базе списков. Оцените время работы операций через размеры участвующих множеств.

а Списки упорядочены.

б Списки неупорядочены.

в Списки неупорядочены, объединяемые множества не пересекаются друг с другом.

11-3 Поиск в отсортированном сжатом списке

В упражнении 11.3-4 требовалось хранить списки *"компактно"*: n-элементный список должен был занимать первые n позиций массива. Предположим ещё, что все ключи различны и что список упорядочен (иными словами, $key[i] < key[next[i]]$ при $next[i] \neq$ NIL). Оказывается, что в этих предположениях следующий вероятностный алгоритм выполняет поиск в списке за время $o(n)$:

```
COMPACT-LIST-SEARCH(L, k)
i ← head[L]
n ← length[L]
while i ≠ NIL and key[i] ⩽ k
     do j ← RANDOM(1, n)
        if key[i] < key[j] and key[j] < k
          then i ← j
        i ← next[i]
        if key[i] = k
          then return i
return NIL
```

Без строк 4–6 это был бы обычный алгоритм с последовательным перебором элементов списка. В строках 4–6 мы пытаемся перескочить на случайно выбранную позицию j. Если $key[i] < key[j] < k$, то при этом мы экономим время, так как не проверяем элементы, лежащие в позициях между i и j. (Благодаря тому, что список занимает непрерывный участок массива, мы можем выбрать в нём случайный элемент.)

а Зачем нужно предполагать, что все ключи различны? Покажите, что для неубывающего списка с (возможно) совпадающими ключами случайные скачки могут не улучшить асимптотику времени поиска.

Как оценить время работы? Представим себе, что на нескольких первых шагах мы выполняем только случайные скачки, а на остальных выполняем линейный поиск. Можно оценить ожидаемое расстояние до искомого элемента после первой фазы — и тем самым длительность второй фазы. Наш алгоритм будет работать не хуже такого усечённого, и остаётся только правильно выбрать длительность первой фазы, чтобы получить оценку получше.

Сделаем это аккуратно. Для каждого $t \geqslant 0$ обозначим через X_t случайную величину, равную расстоянию (измеренному вдоль списка) от позиции i до искомого ключа k после t случайных скачков.

б Покажите, что для каждого $t \geqslant 0$ математическое ожидание времени работы алгоритма Compact-List-Search есть $O(t+E[X_t])$.

в Покажите, что $E(X_t) \leqslant \sum_{r=1}^{n}(1-r/n)^t$. (Указание: воспользуйтесь формулой (6.28)).

г Покажите, что $\sum_{r=0}^{n-1} 5 \leqslant n^{t+1}/(t+1)$.

д Покажите, что $E(X_t) \leqslant n/(t+1)$, и объясните *"на пальцах"*, почему это неравенство должно быть верно.

е Покажите, что математическое ожидание времени работы алгоритма Compact-List-Search есть $O(\sqrt{n})$.

Замечания

Прекрасные справочники по структурам данных — книги Ахо, Хопкрофта и Ульмана [5] и Кнута [121]. Результаты экспериментов по сравнению эффективности различных операций на структурах данных можно найти в Гоннет [90]

Стеки и очереди использовались в математике и делопроизводстве в докомпьютерную эру. Кнут [121] отмечает, что в 1947 году Тьюринг (A. M. Turing) использовал стеки для связи подпрограмм.

Структуры данных, основанные на указателях, также, видимо, относятся к *"фольклору"*. Согласно Кнуту, указатели использовались еще в первых компьютерах с магнитными барабанами. В 1951 году Хоппер (G. M. Hopper) разработал язык A-1, в котором алгебраические формулы представлялись в виде двоичных деревьев. Тот же Кнут указывает, что систематическое использование указателей началось с языка IPL-II, который разработали в 1956 году Ньюэлл, Шоу и Саймон (A. Newell, J. C. Shaw, H. A. Simon). В разработанном теми же авторами в 1957 году языке IPL-III появились в явном виде операции со стеками.

12 Хеш-таблицы

Часто бывают нужны динамические множества, поддерживающие только *"словарные операции"* добавления, поиска и удаления элемента. В этом случае часто применяют так называемое хеширование; соответствующая структура данных называется *"хеш-таблица"* (или *"таблица расстановки"*). В худшем случае поиск в хеш-таблице может занимать столько же времени, сколько поиск в списке ($\Theta(n)$), но на практике хеширование весьма эффективно. При выполнении некоторых естественных условий математическое ожидание времени поиска элемента в хеш-таблице есть $O(1)$.

Хеш-таблицу можно рассматривать как обобщение обычного массива. Если у нас достаточно памяти для массива, число элементов которого равно числу всех возможных ключей, для каждого возможного ключа можно отвести ячейку в этом массиве и тем самым иметь возможность добраться до любой записи за время $O(1)$ (*"прямая адресация"*, см. разд. 12.1). Однако если реальное количество записей значительно меньше, чем количество возможных ключей, то эффективнее применить хеширование: вычислять позицию записи в массиве, исходя из ключа. В разделе 12.2 обсуждаются основные идеи, а в разделе 12.3 — конкретные способы такого вычисления. В этой главе представлено несколько вариантов хеширования.

Мы увидим, что хеширование — эффективный и удобный способ выполнять основные словарные операции (среднее время $O(1)$ при некоторых предположениях).

12.1 Прямая адресация

Прямая адресация применима, если количество возможных ключей невелико. Пусть возможными ключами являются числа из множества $U = \{0, 1, \ldots, m-1\}$ (число m не очень велико). Предположим также, что ключи всех элементов различны.

Для хранения множества мы пользуемся массивом $T[0\,..\,m-1]$, называемым **таблицей с прямой адресацией** (direct-address table). Ка-

Переводы надписей на самой картинке: universe of keys — всевозможные ключи, actual keys — используемые ключи, key — ключ, satellite data — дополнительные данные.

Рисунок 12.1 Реализация динамического множества с помощью таблицы T с прямой адресацией. Множество возможных ключей есть $U = \{0, 1, \ldots, 9\}$. Каждому из этих ключей соответствует своё место в таблице. В позициях таблицы с номерами 2, 3, 5 и 8 (фактически используемые ключи) записаны указатели на элементы множества, а в неиспользуемых позициях таблицы (тёмно-серые) записан NIL.

ждая **позиция**, или **ячейка**, (по-английски slot или position) соответствует определённому ключу из множества U (рис. 12.1: $T[k]$ — место, предназначенное для записи указателя на элемент с ключом k; если элемента с ключом k в таблице нет, то $T[k] = $ NIL).

Реализация словарных операций тривиальна:

Direct-Address-Search(T, k)
  return $T[k]$

Direct-Address-Insert(T, x)
  $T[key[x]] \leftarrow x$

Direct-Address-Delete(T, x)
  $T[key[x]] \leftarrow$ NIL

Каждая из этих операций требует времени $O(1)$.

Иногда можно сэкономить место, записывая в таблицу T не указатели на элементы множества, а сами эти элементы. Можно обойтись и без отдельного поля *"ключ"*: ключом служит индекс в массиве. Впрочем, если мы обходимся без ключей и указателей, то надо иметь способ указать, что данная позиция свободна.

Упражнения

12.1-1 Опишите процедуру для нахождения наибольшего элемента динамического множества, представленного в виде таблицы с прямой адресацией. Каково время работы этой процедуры в худшем случае?

12.1-2 **Битовый вектор** (bit vector) — это массив битов (нулей и единиц). Битовый вектор длины m занимает значительно меньше места, чем массив из m указателей. Как, пользуясь битовым вектором, реализовать динамическое множество, состоящее из различных элементов и не содержащее дополнительных данных? Словарные операции должны выполняться за время $O(1)$.

12.1-3 Как реализовать таблицу с прямой адресацией, в которой ключи различных элементов могут совпадать, а сами элементы могут содержать дополнительные данные? Операции добавления, удаления и поиска должны выполняться за время $O(1)$ (не забудьте, что аргументом процедуры удаления DELETE является указатель на удаляемый элемент, а не ключ).

12.1-4* Предположим, что нам надо реализовать динамическое множество, поддерживающее словарные операции, на базе очень большого массива. Первоначально в массиве может быть записано что-то, не имеющее отношение к нашей задаче, но массив такой большой, что предварительно очищать его непрактично. Как в таких условиях реализовать таблицу с прямой адресацией? Каждая запись должна занимать место размером $O(1)$, операции добавления, удаления и поиска должны выполняться за время $O(1)$, время на инициализацию структуры данных также должно быть равно $O(1)$. (Указание: чтобы иметь возможность узнать, имеет ли данный элемент массива отношение к нашей структуре данных, заведите стек, размер которого равен количеству записей в таблице).

12.2 Хеш-таблицы

Прямая адресация обладает очевидным недостатком: если множество U всевозможных ключей велико, то хранить в памяти массив T размером $|U|$ непрактично, а то и невозможно. Кроме того, если число реально присутствующих в таблице записей мало по сравнению с $|U|$, то много памяти тратится зря.

Если количество записей в таблице существенно меньше, чем количество всевозможных ключей, то хеш-таблица занимает гораздо меньше места, чем таблица с прямой адресацией. Именно, хеш-таблица требует памяти объёмом $\Theta(|K|)$, где K — множество записей, при этом время поиска в хеш-таблице по-прежнему есть $O(1)$ (единственное *"но"* в том, что на сей раз это — оценка в среднем, а не в худшем случае, да и то только при определённых предположениях).

В то время как при прямой адресации элементу с ключом k от-

Переводы надписей на самой картинке: universe of keys — всевозможные ключи, actual keys — используемые ключи

Рисунок 12.2 Использование хеш-функции для отображения ключей в позиции хеш-таблицы. Хеш-значения ключей k_2 и k_5 совпадают — имеет место коллизия.

водится позиция номер k, при хешировании этот элемент записывается в позицию номер $h(k)$ в **хеш-таблице** (hash table) $T[0\,..\,m-1]$, где

$$h\colon U \to \{0, 1, \ldots, m-1\}$$

— некоторая функция, называемая **хеш-функцией** (hash function). Число $h(k)$ называют **хеш-значением** (hash value) ключа k. Идея хеширования показана на рис. 12.2: пользуясь массивом длины m, а не $|U|$, мы экономим память.

Проблема, однако, в том, что хеш-значения двух разных ключей могут совпасть. В таких случаях говорят, что случилась **коллизия**, или **столкновение** (collision). К счастью, эта проблема разрешима: хеш-функциями можно пользоваться и при наличии столкновений.

Хотелось бы выбрать хеш-функцию так, чтобы коллизии были невозможны. Но при $|U| > m$ неизбежно существуют разные ключи, имеющие одно и то же хеш-значение. Так что можно лишь надеяться, что для фактически присутствующих в множестве ключей коллизий будет немного, и быть готовыми обрабатывать те коллизии, которые всё-таки произойдут.

Выбирая хеш-функцию, мы обычно не знаем заранее, какие именно ключи будут храниться. Но на всякий случай разумно сделать сделать хеш-функцию в каком-то смысле *"случайной"*, хорошо перемешивающей ключи по ячейкам (английский глагол “to hash” означает *"мелко порубить, помешивая"*). Разумеется, *"случайная"* хеш-функция должна всё же быть детерминированной в том смысле, что при ее повторных вызовах с одним и тем же аргументом она должна возвращать одно и то же хеш-значение.

В этом разделе мы рассмотрим простейший способ обработки (как говорят, *"разрешения"*) коллизий с помощью цепочек. Другой способ — открытая адресация — рассматривается в разделе 12.4.

Переводы надписей на самой картинке: universe of keys — всевозможные ключи, actual keys — используемые ключи

Рисунок 12.3 Разрешение коллизий с помощью цепочек. В позиции $T[j]$ хранится указатель на список элементов с хеш-значением j. Например, $h(k_1) = h(k_4)$ и $h(k_5) = h(k_2) = h(k_7)$.

Разрешение коллизий с помощью цепочек

Технология **сцепления элементов** (chaining) состоит в том, что элементы множества, которым соответствует одно и то же хеш-значение, связываются в цепочку-список (рис. 12.3). В позиции номер j хранится указатель на голову списка тех элементов, у которых хеш-значение ключа равно j; если таких элементов в множестве нет, в позиции j записан NIL.

Операции добавления, поиска и удаления реализуются легко:

Chained-Hash-Insert(T, x)

добавить x в голову списка $T[h(key[x])]$

Chained-Hash-Search(T, k)

найти элемент с ключом k в списке $T[h(k)]$

Chained-Hash-Delete(T, x)

удалить x из списка $T[h(key[x])]$

Операция добавления работает в худшем случае за время $O(1)$. Максимальное время работы операции поиска пропорционально длине списка (ниже мы рассмотрим этот вопрос подробнее). Наконец, удаление элемента можно провести за время $O(1)$ — при условии, что списки двусторонне связаны (если списки связаны односторонне, то для удаления элемента x надо предварительно найти его предшественника, для чего необходим поиск по списку; в таком случае стоимость удаления и поиска примерно одинаковы).

Анализ хеширования с цепочками

В этом разделе мы оценим время работы операций для хеширования с цепочками.

Пусть T — хеш-таблица с m позициями, в которую занесено n элементов. **Коэффициентом заполнения** (load factor) таблицы называется число $\alpha = n/m$ (это число может быть и меньше, и больше единицы). Мы будем оценивать стоимость операций в терминах α.

В худшем случае хеширование с цепочками ведет себя отвратительно: если хеш-значения всех n ключей совпадают, то таблица сводится к одному списку длины n, и на поиск будет тратиться то же время $\Theta(n)$, что и на поиск в списке, плюс ещё время на вычисление хеш-функции. Конечно, в такой ситуации хеширование бессмысленно.

Средняя стоимость поиска зависит от того, насколько равномерно хеш-функция распределяет хеш-значения по позициям таблицы. Вопросу о том, как добиваться этой равномерности, посвящён раздел 12.3; пока же будем условно предполагать, что каждый данный элемент может попасть в любую из m позиций таблицы с равной вероятностью и независимо от того, куда попал другой элемент. Мы будем называть это предположение гипотезой *"равномерного хеширования"* (simple uniform hashing).

Будем считать, что для данного ключа k вычисление хеш-значения $h(k)$, шаг по списку и сравнение ключей требует фиксированного времени, так что время поиска элемента с ключом k линейно зависит от количества элементов в списке $T[h(k)]$, которые мы просматриваем в процессе поиска. Будем различать два случая: в первом случае поиск оканчивается неудачей (элемента с ключом k в списке нет), во втором поиск успешен — элемент с требуемым ключом обнаруживается.

Теорема 12.1. *Пусть T — хеш-таблица с цепочками, имеющая коэффициент заполнения α. Предположим, что хеширование равномерно. Тогда при поиске элемента, отсутствующего в таблице, будет просмотрено в среднем α элементов таблицы, а среднее время такого поиска (включая время на вычисление хеш-функции) будет равно $\Theta(1+\alpha)$.*

Доказательство. Поскольку в предположении равномерного хеширования все позиции таблицы для данного ключа равновероятны, среднее время поиска отсутствующего элемента совпадает со средним временем полного просмотра одного из m списков, то есть пропорционально средней длине наших m списков. Эта средняя длина есть $n/m = \alpha$, откуда получаем первое утверждение теоремы; второе утверждение получится, если добавить время $\Theta(1)$ на вычисление хеш-значения. □

Теорема 12.2. *При равномерном хешировании среднее время успешного поиска в хеш-таблице с цепочками есть* $\Theta(1+\alpha)$, *где* α *— коэффициент заполнения.*

Доказательство. Хотя формулировка этой теоремы похожа на предыдущую, смысл утверждения несколько иной. В предыдущей теореме мы рассматривали произвольную таблицу с коэффициентом заполнения α и оценивали среднее число действий, необходимых для поиска случайного элемента, равновероятно попадающего во все ячейки таблицы.

В этой теореме так делать нельзя: если мы возьмём произвольную таблицу и, считая все её элементы равновероятными, будем искать среднее время поиска случайно выбранного из них, то оценки вида $\Theta(1+\alpha)$ не получится (контрпример: таблица, в которой все элементы попали в один список)

Формулировка подразумевает двойное усреднение: сначала мы рассматриваем случайно выбранную последовательность элементов, добавляемых в таблицу, причём на каждом шаге все значения ключа равновероятны и шаги независимы, а затем в полученной таблице выбираем элемент для поиска, считая все её элементы равновероятными.

Посмотрим на ситуацию в тот момент, когда таблица уже построена, но случайный элемент для поиска ещё не выбран. Чему равно среднее время поиска, усреднённое по всем n элементам таблицы? Надо сложить позиции всех элементов в своих списках и поделить сумму на n (общее число элементов).

Если представить себе, что при заполнении таблицы элементы дописывались в конец соответствующих списков (см. упр. 12.2-3), то упомянутая сумма по порядку величины равна общему число операций, выполненных при заполнении таблицы (поскольку при добавлении в конец и при поиске выполняется одно и то же количество действий).

Теперь вспомним об усреднении по различным возможностям в процессе построения таблицы. При добавлении в неё i-го элемента математическое ожидание числа действий равно $\Theta(1+(i-1)/m)$ (см. доказательство предыдущей теоремы), и потому математическое ожидание общего числа действий при заполнении таблицы, делённое на n, есть

$$\begin{aligned}\Theta\left(\frac{1}{n}\sum_{i=1}^{n}\left(1+\frac{i-1}{m}\right)\right) &= \Theta\left(1+\frac{1}{nm}\sum_{i=1}^{n}(i-1)\right) = \\ &= \Theta\left(1+\frac{1}{nm}\cdot\frac{(n-1)n}{2}\right) = \\ &= \Theta\left(1+\frac{\alpha}{2}-\frac{1}{2m}\right) = \Theta(1+\alpha).\end{aligned}$$

□

Если количество позиций в хеш-таблице считать пропорциональным числу элементов в таблице, то из доказанных теорем вытекает, что среднее время на поиск (в оптимистических предположениях о распределении вероятностей) есть $O(1)$. В самом деле, если $n = O(m)$, то $\alpha = n/m = O(1)$ и $O(1 + \alpha) = O(1)$. Поскольку стоимость добавления в хеш-таблицу с цепочками есть $O(1)$ (даже при добавлении в конец, см. упр. 12.2-3), а стоимость удаления элемента есть $O(1)$ (мы считаем, что списки двусторонне связаны), среднее время выполнения любой словарной операции (в предположении равномерного хеширования) есть $O(1)$.

Упражнения

12.2-1 Пусть h — случайная хеш-функция, сопоставляющая с каждым из n различных ключей $\{k_1, k_2, \ldots, k_n\}$ одну из m позиций в таблице. Каково математическое ожидание числа коллизий (точнее, числа пар (i, j), для которых что $h(k_i) = h(k_j)$)?

12.2-2 Как будет выглядеть хеш-таблица с цепочками после того, как в неё последовательно поместили элементы с ключами $5, 28, 19, 15, 20, 33, 12, 17, 10$ (в указанном порядке)? Число позиций в таблице равно 9, хеш-функция имеет вид $h(k) = k \bmod 9$.

12.2-3 Покажите, что математическое ожидание времени добавления нового элемента (в предположении равномерного хеширования) есть $O(1 + \alpha)$, если мы добавляем новый элемент в конец соответствующей цепочки.

12.2-4 Профессор предполагает, что хеширование с цепочками будет гораздо эффективнее, если списки элементов с данным хеш-значением будут упорядоченными. Как этот подход повлияет на стоимость успешного поиска, поиска отсутствующего элемента, добавления, удаления?

12.2-5 Разработайте реализацию хеш-таблицы с цепочками, в которой записи хранятся внутри самой хеш-таблицы (неиспользуемые позиции связываются в список свободных мест). Считайте, что в каждой позиции могут храниться либо флаг и два указателя, либо флаг, указатель и элемент. Все словарные операции, а также операции по выделению и освобождению места, должны выполняться за время $O(1)$. Обязательно ли делать список свободных мест двусторонне связанным?

12.2-6 Пусть общее число возможных ключей (размер множества U) превосходит mn, где m — количество хеш-значений. Покажите, что существует не менее n ключей с одним и тем же хеш-значением, так что в худшем случае поиск в хеш-таблице с цепочками займет время $\Theta(n)$.

12.3 Хеш-функции

В этом разделе мы обсудим, чего мы ждём от хорошей хеш-функции, а затем разберём три способа построения хеш-функций: деление с остатком, умножение и универсальное хеширование.

Какой должна быть хорошая хеш-функция?

Хорошая хеш-функция должна (приближенно) удовлетворять предположениям равномерного хеширования: для очередного ключа все m хеш-значений должны быть равновероятны. Чтобы это предположение имело смысл, фиксируем распределение вероятностей P на множестве U; будем предполагать, что ключи выбираются из U независимо друг от друга, и каждый распределён в соответствии с P. Тогда равномерное хеширование означает, что

$$\sum_{k:\ h(k)=j} P(k) = \frac{1}{m} \quad \text{для } j = 0, 1, \ldots, m-1. \tag{12.1}$$

К сожалению, распределение P обычно неизвестно, так что проверить это невозможно (да и ключи не всегда разумно считать независимыми).

Изредка распределение P бывает известно. Пусть, например, ключи — случайные действительные числа, независимо и равномерно распределённые на интервале $[0;1)$. В этом случае легко видеть, что хеш-функция $h(k) = \lfloor km \rfloor$ удовлетворяет условию (12.1).

На практике при выборе хеш-функций пользуются различными эвристиками, основанными на специфике задачи. Например, компилятор языка программирования хранит таблицу символов, в которой ключами являются идентификаторы программы. Часто в программе используется несколько похожих идентификаторов (например, `pt` и `pts`). Хорошая хеш-функция будет стараться, чтобы хеш-значения у таких похожих идентификаторов были различны.

Обычно стараются подобрать хеш-функцию таким образом, чтобы её поведение не коррелировало с различными закономерностями, которые могут встретиться в хешируемых данных. Например, описываемый ниже метод деления с остатком состоит в том, что в качестве хеш-значения берётся остаток от деления ключа на некоторое простое число. Если это простое число никак не связано с функцией распределения P, то такой метод даёт хорошие результаты.

Заметим в заключение, что иногда желательно, чтобы хеш-функция удовлетворяла условиям, выходящим за пределы требования равномерного хеширования. Например, можно стараться, чтобы *"близким"* в каком-либо смысле ключам соответствовали *"далёкие"* хеш-значения (это особенно желательно при пользовании описанной в разделе 12.4 линейной последовательностью проб).

Ключи как натуральные числа

Обычно предполагают, что область определения хеш-функции — множество целых неотрицательных чисел. Если ключи не являются натуральными числами, их обычно можно преобразовать к такому виду (хотя числа могут получиться большими). Например, последовательности символов можно интерпретировать как числа, записанные в системе счисления с подходящим основанием: идентификатор `pt` — это пара чисел $(112, 116)$ (таковы ASCII-коды букв `p` и `t`), или же число $(112 \cdot 128) + 116 = 14452$ (в системе счисления по основанию 128). Далее мы всегда будем считать, что ключи — целые неотрицательные числа.

12.3.1 Деление с остатком

Построение хеш-функции методом **деления с остатком** (division method) состоит в том, что ключу k ставится в соответствие остаток от деления k на m, где m — число возможных хеш-значений:

$$h(k) = k \bmod m.$$

Например, если размер хеш-таблицы равен $m = 12$ и ключ равен 100, то хеш-значение равно 4.

При этом некоторых значений m стоит избегать. Например, если $m = 2^p$, то $h(k)$ — это просто p младших битов числа k. Если нет уверенности, что все комбинации младших битов ключа будут встречаться с одинаковой частотой, то степень двойки в качестве числа m не выбирают. Нехорошо также выбирать в качестве m степень десятки, если ключи естественно возникают как десятичные числа: ведь в этом случае окажется, что уже часть цифр ключа полностью определяет хеш-значение. Если ключи естественно возникают как числа в системе счисления с основанием 2^p, то нехорошо брать $m = 2^p - 1$, поскольку при этом одинаковое хеш-значение имеют ключи, отличающиеся лишь перестановкой *"2^p-ичных цифр"*.

Хорошие результаты обычно получаются, если выбрать в качестве m простое число, далеко отстоящее от степеней двойки. Пусть, например, нам надо поместить примерно 2000 записей в хеш-таблицу с цепочками, причем нас не пугает возможный перебор

Переводы надписей: w bits — w битов; extract p bits — выделить p битов. ВНИМАНИЕ: на рисунке надо УБРАТЬ знаки целой части, заменив $\lfloor A \cdot 2^w \rfloor$ на $A \cdot 2^w$!!!!!!!

Рисунок 12.4 Хеширование методом умножения. Ключ k, представленный в виде w-битного числа, умножается на w-битное число $A \cdot 2^w$, где A — константа из интервала $(0;1)$. У произведения берут младшие w битов, а из этих w битов выделяют p старших. Это и есть хеш-значение $h(k)$.

трёх вариантов при поиске отсутствующего в таблице элемента. Что ж, воспользуемся методом деления с остатком при длине хеш-таблицы $m = 701$. Число 701 простое, $701 \approx 2000/3$, и до степеней двойки от числа 701 тоже далеко. Стало быть, можно выбрать хеш-функцию вида

$$h(k) = k \bmod 701.$$

На всякий случай можно ещё поэкспериментировать с реальными данными на предмет того, насколько равномерно будут распределены их хеш-значения.

12.3.2 Умножение

Построение хеш-функции методом **умножения** (multiplication method) состоит в следующем. Пусть количество хеш-значений равно m. Зафиксируем константу A в интервале $0 < A < 1$, и положим

$$h(k) = \lfloor m(kA \bmod 1) \rfloor,$$

где $kA \bmod 1$ — дробная часть kA.

Достоинство метода умножения в том, что качество хеш-функции мало зависит от выбора m. Обычно в качестве m выбирают степень двойки, поскольку в большинстве компьютеров умножение на такое m реализуется как сдвиг слова. Пусть, например, длина слова в нашем компьютере равна w битам и ключ k помещается в одно слово. Тогда, если $m = 2^p$, то вычисление хеш-функции можно провести так: умножим k на w-битное целое число $A \cdot 2^w$ (мы предполагаем, что это число является целым); получится $2w$-битное число

Метод умножения работает при любом выборе константы A, но некоторые значения A могут быть лучше других. Оптимальный выбор зависит от того, какого рода данные подвергаются хешированию. В книге [123] Кнут обсуждает выбор константы A и приходит к выводу, что значение

$$A \approx (\sqrt{5} - 1)/2 = 0{,}6180339887\ldots \tag{12.2}$$

является довольно удачным.

В заключение приведём пример: если $k = 123456$, $m = 10000$ и A определено формулой (12.2), то

$$\begin{aligned} h(k) &= \lfloor 10000 \cdot (123456 \cdot 0{,}61803\ldots \bmod 1) \rfloor = \\ &= \lfloor 10000 \cdot (76300{,}0041151\ldots \bmod 1) \rfloor = \\ &= \lfloor 10000 \cdot 0{,}0041151\ldots \rfloor = \\ &= \lfloor 41{,}151\ldots \rfloor = 41. \end{aligned}$$

12.3.3 Универсальное хеширование

Если недоброжелатель будет специально подбирать данные для хеширования, то (зная функцию h) он может устроить так, что все n ключей будут соответствовать одной позиции в таблице, в результате чего время поиска будет равно $\Theta(n)$. Любая фиксированная хеш-функция может быть дискредитирована таким образом. Единственный выход из положения — выбирать хеш-функцию случайным образом, не зависящим от того, какие именно данные вы хешируете. Такой подход называется **универсальным хешированием** (universal hashing). Что бы ни предпринимал ваш недоброжелатель, если он не имеет информации о выбранной хеш-функции, среднее время поиска останется хорошим.

Основная идея универсального хеширования — выбирать хеш-функцию во время исполнения программы случайным образом из некоторого множества. Стало быть, при повторном вызове с теми же входными данными алгоритм будет работать уже по-другому. Как и в случае с алгоритмом быстрой сортировки, рандомизация гарантирует, что нельзя придумать входных данных, на которых алгоритм всегда бы работал медленно (в примере с компилятором и таблицей символов не сможет получиться, что какой-то определённый стиль выбора идентификаторов приводит к замедлению компиляции: вероятность, что компиляция замедлится из-за неудачного хеширования, во-первых, мала, и во-вторых, зависит только от количества идентификаторов, но не от их выбора).

Пусть $\mathcal{H}$ — конечное семейство функций, отображающих данное множество U (множество всевозможных ключей) во множество $\{0, 1, \ldots, m-1\}$ (множество хеш-значений). Это семейство называется **универсальным** (universal), если для любых двух ключей $x, y \in U$ число функций $h \in \mathcal{H}$, для которых $h(x) = h(y)$, равно $|\mathcal{H}|/m$. Иными словами, при случайном выборе хеш-функции вероятность коллизии между двумя данными ключами должна равняться вероятности совпадения двух случайно выбранных хеш-значений (которая равна $1/m$).

Следующая теорема показывает, что универсальное семейство хеш-функций обеспечивает хорошую производительность в среднем.

Теорема 12.3. *Пусть нам необходимо поместить n фиксированных ключей в таблицу размера m, где $m \geqslant n$, и хеш-функция выбирается случайным образом из универсального семейства. Тогда математическое ожидание числа коллизий, в которых участвует данный ключ x, меньше единицы.*

Доказательство. Математическое ожидание числа коллизий данного ключа x с данным ключом y равно $1/m$ по определению универсального семейства. Поскольку всего имеется $n-1$ ключей, отличных от x, математическое ожидание числа коллизий с каким-нибудь из этих ключей равно $(n-1)/m$, что меньше единицы, поскольку $n \leqslant m$. □

Как же построить универсальное семейство? Нам поможет в этом элементарная теория чисел. Число m (количество хеш-значений) выберем простым. Будем считать, что каждый ключ представляет собой последовательность $r+1$ *"байтов"* (байт, или символ,— это просто двоичное число с ограниченным числом разрядов; мы будем считать, что максимальное значение байта меньше m). Для каждой последовательности $a = \langle a_0, a_1, \ldots, a_r \rangle$, элементы которой являются вычетами по модулю m (то есть принадлежат множеству $\{0, 1, \ldots, m-1\}$), рассмотрим функцию h_a, заданную формулой

$$h_a(x) = \sum_{i=0}^{r} a_i x_i \bmod m, \qquad (12.3)$$

где ключ x есть последовательность байтов $\langle x_0, x_1, \ldots, x_r \rangle$. Положим

$$\mathcal{H} = \bigcup_a \{h_a\}, \qquad (12.4)$$

Очевидно, множество $\mathcal{H}$ содержит m^{r+1} элементов.

Теорема 12.4. *Семейство функций $\mathcal{H}$, определённое по формулам* (12.3) *и* (12.4), *является универсальным семейством хеш-функций.*

Доказательство. Пусть $x = \langle x_0, x_1, \ldots, x_r \rangle$ и $y = \langle y_0, y_1, \ldots, y_r \rangle$ — два различных ключа; не ограничивая общности, можно считать, что $x_0 \neq y_0$. Если $a = \langle a_0, a_1, \ldots, a_r \rangle$, то $h_a(x) = h_a(y)$ тогда и только тогда, когда

$$a_0(x_0 - y_0) \equiv -\sum_{j=1}^{r} a_i(x_i - y_i) \pmod{m}.$$

Поскольку $x_0 - y_0 \not\equiv 0 \pmod{m}$, для каждой последовательности $\langle a_1, \ldots, a_r \rangle$ существует и единственно значение a_0, при котором это равенство выполнено (раздел 33.4). Количество таких последовательностей равно m^r, и таково же, стало быть, количество функций из $\mathcal{H}$, не различающих ключи x и y. Поскольку $m^r = |\mathcal{H}|/m$, всё доказано.

[Короче можно сказать так: ненулевой линейный функционал $h \mapsto h(x-y)$ с равной вероятностью принимает любое из m своих значений, в том числе 0.] $\square$

Упражнения

12.3-1 Пусть в связанном списке каждый элемент хранится вместе с его ключом k и соответствующим хеш-значением $h(k)$. Ключ представляет собой длинную последовательность символов. Как можно упростить поиск в этом списке элемента с данным ключом?

12.3-2 Предположим, что ключами являются последовательности символов, которые мы рассматриваем как числа, записанные в системе счисления с основанием 128. Число m помещается в 32-битном слове с запасом, но числа, соответствующие ключам, уже не помещаются, поскольку ключи содержат много десятков символов. Как вычислить хеш-функцию, построенную методом деления? (Нет необходимости реализовывать арифметические операции с длинными числами — достаточно дополнительной памяти постоянного объёма.)

12.3-3 Пусть ключи представляют собой последовательности p-битных символов, рассматриваемые как числа в 2^p-ичной системе счисления, а в качестве хеш-функции выбран остаток при делении на $m = 2^p - 1$. Покажите, что двум ключам, отличающимся только порядком символов, соответствует одно и то же хеш-значение. Приведите пример приложения, в котором применение такой хеш-функции было бы нежелательно.

12.3-4 Пусть размер хеш-таблицы равен $m = 1000$, а хеш-функция имеет вид $h(k) = \lfloor m(kA \bmod 1) \rfloor$, где $A = (\sqrt{5} - 1)/2$. В какие позиции попадут ключи 61, 62, 63, 64 и 65?

12.3-5 Удалим из семейства $\mathcal{H}$, определённого по формулам (12.3) и (12.4), те функции h_a, в которых хотя бы одно из a_i равна нулю. Покажите, что получившееся семейство хеш-функций универсальным не будет.

12.4 Открытая адресация

В отличие от хеширования с цепочками, при **открытой адресации** (open addressing) никаких списков нет, а все записи хранятся в самой хеш-таблице: каждая ячейка таблицы содержит либо элемент динамического множества, либо NIL. Поиск заключается в том, что мы определённым образом просматриваем элементы таблицы, пока не найдём то, что ищем, или не удостоверимся, что элемента с таким ключом в таблице нет. Тем самым число хранимых элементов не может быть больше размера таблицы: коэффициент заполнения не больше 1.

Конечно, и при хешировании с цепочками можно использовать свободные места в хеш-таблице для хранения списков (упражнение 12.2-5), но при открытой адресации указатели вообще не используются: последовательность просматриваемых ячеек *вычисляется*. За счет экономии памяти на указателях можно увеличить количество позиций в таблице, что уменьшает число коллизий и сокращает поиск.

Чтобы добавить новый элемент в таблицу с открытой адресацией, ячейки которой занумерованы целыми числами от 0 до $m-1$, мы просматриваем её, пока не найдем свободное место. Если всякий раз просматривать ячейки подряд $(0, 1, \ldots, m-1)$, потребуется время $\Theta(n)$, но суть в том, что порядок просмотра таблицы зависит от ключа! Иными словами, мы добавляем к хеш-функции второй аргумент — номер попытки (нумерацию начинаем с нуля), так что хеш-функция имеет вид

$$h\colon U \times \{0, 1, \ldots, m-1\} \to \{0, 1, \ldots, m-1\}$$

(U — множество ключей). **Последовательность испробованных мест** (probe sequence), или (короче) **последовательность проб** для данного ключа k имеет вид

$$\langle h(k,0), h(k,1), \ldots, h(k,m-1) \rangle;$$

функция h должна быть такой, чтобы каждое из чисел от 0 до $m-1$ встретилось в этой последовательности ровно один раз (для каждого ключа все позиции таблицы должны быть доступны). Ниже приводится текст процедуры добавления в таблицу T с открытой адресацией; в нем подразумевается, что записи не содержат дополнительной информации, кроме ключа. Если ячейка таблицы пуста, в ней записан NIL (фиксированное значение, отличное от всех ключей).

```
Hash-Insert(T, k)
i ← 0
repeat j ← h(k, i)
        if T[j] = NIL
          then T[j] ← k
                return j
          else i ← i + 1
  until i = m
error "переполнение хеш-таблицы"
```

При поиске элемента с ключом k в таблице с открытой адресацией ячейки таблицы просматриваются в том же порядке, что и при добавлении в нее элемента с ключом k. Если при этом мы натыкаемся на ячейку, в которой записан NIL, то можно быть уверенным, что искомого элемента в таблице нет (иначе он был бы занесён в эту ячейку). (Внимание: мы предполагаем, что никакие элементы из таблицы не удаляются!)

Вот текст процедуры поиска Hash-Search (если элемент с ключом k содержится в таблице T в позиции j, процедура возвращает j, в противном случае она возвращает NIL).

```
Hash-Search(T, k)
i ← 0
repeat j ← h(k, i)
        if T[j] = k
          then return j
        i ← i + 1
  until T[j] = NIL или i = m
return NIL
```

Удалить элемент из таблицы с открытой адресацией не так просто. Если просто записать на его место NIL, то в дальнейшем мы не сможем найти те элементы, в момент добавления которых в таблицу это место было занято (и из-за этого был выбран более далёкий элемент в последовательности испробованных мест). Возможное решение — записывать на место удалённого элемента не NIL, а специальное значение DELETED (*"удалён"*), и при добавлении рассматривать ячейку с записью DELETED как свободную, а при поиске — как занятую (и продолжать поиск). Недостаток этого подхода в том, что время поиска может оказаться большим даже при низком коэффициенте заполнения. Поэтому, если требуется удалять записи из хеш-таблицы, предпочтение обычно отдают хешированию с цепочками.

В нашем анализе открытой адресации мы будем исходить из предположения, что хеширование **равномерно** (uniform) в том смысле, что все $m!$ перестановок множества $\{0, 1, \ldots, m-1\}$ равновероятны. На практике это вряд ли так, хотя бы по той причине, что для этого необходимо, чтобы число возможных ключей было как минимум $\leqslant m!$, где m — число хеш-значений. Поэтому обычно пользуются более или менее удачными суррогатами, вроде описываемого ниже двойного хеширования.

Обычно применяют такие три способа вычисления последовательности испробованных мест: линейный, квадратичный и двойное хеширование. В каждом из этих способов последовательность $\langle h(k,0), h(k,1), \ldots, h(k, m-1)\rangle$ будет перестановкой множества $\{0, 1, \ldots, m-1\}$ при любом значении ключа k, но ни один из этих способов не является равномерным по той причине, что они дают не более m^2 перестановок из $m!$ возможных. Больше всего разных перестановок получается при двойном хешировании; не удивительно, что и на практике этот способ дает лучшие результаты.

Линейная последовательность проб

Пусть $h' \colon U \to \{0, 1, \ldots, m-1\}$ — *"обычная"* хеш-функция. Функция, определяющая **линейную последовательность проб** (linear probing), задаётся формулой

$$h(k, i) = (h'(k) + i) \bmod m.$$

Иными словами, при работе с ключом k начинают с ячейки $T[h'(k)]$, а затем перебирают ячейки таблицы подряд: $T[h'(k)+1], T[h'(k)+2], \ldots$ (после $T[m-1]$ переходят к $T[0]$). Поскольку последовательность проб полностью определяется первой ячейкой, реально используется всего лишь m различных последовательностей.

Открытую адресацию с линейной последовательностью проб легко реализовать, но у этого метода есть один недостаток: он может привести к образованию **кластеров**, то есть длинных последовательностей занятых ячеек, идущих подряд (по-английски это явление называется primary clustering). Это удлиняет поиск; в самом деле, если в таблице из m ячеек все ячейки с чётными номерами заняты, а ячейки с нечётными номерами свободны, то среднее число проб при поиске элемента, отсутствующего в таблице, есть 1,5; Если, однако, те же $m/2$ занятых ячеек идут подряд, то среднее число проб примерно равно $m/8 = n/4$ (n — число занятых мест в таблице). Тенденция к образованию кластеров объясняется просто: если i заполненных ячеек идут подряд, вероятность того, что при очередной вставке в таблицу будет использована ячейка, следующая непосредственно за ними, есть $(i+1)/m$, в то время как для свободной ячейки, предшественница которой также свободна, вероятность быть использованной равна всего лишь $1/m$. Всё вышеизложенное показывает, что линейная последовательность проб довольно далека от равномерного хеширования.

Квадратичная последовательность проб

Функция, определяющая **квадратичную последовательность проб** (quadratic probing), задаётся формулой

$$h(k, i) = (h'(k) + c_1 i + c_2 i^2) \bmod m, \tag{12.5}$$

где по-прежнему h' — обычная хеш-функция, а c_1 и $c_2 \neq 0$ — некоторые константы. Пробы начинаются с ячейки номер $T[h'(k)]$, как и при линейном методе, но дальше ячейки просматриваются не подряд: номер пробуемой ячейки квадратично зависит от номера попытки. Этот метод работает значительно лучше, чем линейный, но если мы хотим, чтобы при просмотре хеш-таблицы использовались все ячейки, значения m, c_1 и c_2 нельзя выбирать как попало; один из способов выбора описан в задаче 12-4. Как и при линейном методе, вся последовательность проб определяется своим первым членом, так что опять получается всего m различных перестановок. Тенденции к образованию кластеров больше нет, но аналогичный эффект проявляется в (более мягкой) форме **образования вторичных кластеров** (secondary clustering).

Двойное хеширование

Двойное хеширование (double hashing) — один из лучших методов открытой адресации. Перестановки индексов, возникающие при двойном хешировании, обладают многими свойствами, присущими равномерному хешированию. При двойном хешировании функция h имеет вид

$$h(k, i) = (h_1(k) + i h_2(k)) \bmod m,$$

где h_1 и h_2 — обычные хеш-функции. Иными словами, последовательность проб при работе с ключом k представляет собой арифметическую прогрессию (по модулю m) с первым членом $h_1(k)$ и шагом $h_2(k)$. Пример двойного хеширования приведен на рис. 12.5.

Чтобы последовательность испробованных мест покрыла всю таблицу, значение $h_2(k)$ должно быть взаимно простым с m (если наибольший общий делитель $h_2(k)$ и m есть d, то арифметическая прогрессия по модулю m с разностью $h_2(k)$ займёт долю $1/d$ в таблице; см. главу 33). Простой способ добиться выполнения этого условия — выбрать в качестве m степень двойки, а функцию h_2 взять такую, чтобы она принимала только нечётные значения. Другой вариант: m — простое число, значения h_2 — целые положительные числа, меньшие m. Например, для простого m можно положить

$$h_1(k) = k \bmod m,$$
$$h_2(k) = 1 + (k \bmod m'),$$

Рисунок 12.5 Добавление элемента в таблицу с открытой адресацией при двойном хешировании. В нашем случае $m = 13$, $h_1(k) = k \bmod 13$, $h_2(k) = 1 + (k \bmod 11)$. Если $k = 14$, то последовательность проб будет такая: 1 и 5 заняты, 9 свободно, помещаем туда.

где m' чуть меньше, чем m (например, $m' = m - 1$ или $m - 2$). Если, например, $m = 701$, $m' = 700$ и $k = 123456$, то $h_1(k) = 80$ и $h_2(k) = 257$. Стало быть, последовательность проб начинается с позиции номер 80 и идёт далее с шагом 257, пока вся таблица не будет просмотрена (или не будет найдено нужное место).

В отличие от линейного и квадратичного методов, при двойном хешировании можно получить (при правильном выборе h_1 и h_2) не m, а $\Theta(m^2)$ различных перестановок, поскольку каждой паре $(h_1(k), h_2(k))$ соответствует своя последовательность проб. Благодаря этому производительность двойного хеширования близка к той, что получилась бы при настоящем равномерном хешировании.

Анализ хеширования с открытой адресацией

Так же, как и при анализе хеширования с цепочками, при анализе открытой адресации мы будем оценивать стоимость операций в терминах коэффициента заполнения $\alpha = n/m$ (n — число записей, m — размер таблицы). Поскольку при открытой адресации каждой ячейке соответствует не более одной записи, $\alpha \leqslant 1$.

Мы будем исходить из предположения о равномерности хеширования. В этой идеализированной схеме предполагается следующее: мы выбираем ключи случайным образом, причём все $m!$ возможных последовательностей проб равновероятны. Поскольку эта идеализированная схема далека от реальности, доказываемые ниже результаты следует рассматривать не как математические теоремы, описывающие работу реальных алгоритмов открытой адресации, а как эвристические оценки.

Начнём с того, что оценим время на поиск элемента, отсутствующего в таблице.

Теорема 12.5. *Математическое ожидание числа проб при поиске в таблице с открытой адресацией отсутствующего в ней элемента не превосходит* $1/(1-\alpha)$ *(хеширование предполагается равномерным, через* $\alpha < 1$ *обозначен коэффициент заполнения).*

Доказательство. Мы предполагаем, что таблица фиксирована, а искомый элемент выбирается случайно, причём все возможные последовательности проб равновероятны. Нас интересует математическое ожидание числа попыток, необходимых для обнаружения свободной ячейки, то есть сумма

$$1 + \sum_{i=0}^{\infty} i p_i. \tag{12.6}$$

где p_i — вероятность того, что мы встретим ровно i занятых ячеек.

Каждая новая проба выбирается равномерно среди оставшихся не испробованными ячеек; если разрешить пробовать повторно уже испробованные ячейки, то часть проб пропадёт зря и математическое ожидание только увеличится. Но для этого нового варианта мы уже вычисляли математическое ожидание (раздел 6.4, геометрическое распределение), и оно равно

$$1/(1-\alpha) \tag{12.7}$$

поскольку вероятность успеха для каждой пробы равна $1-\alpha$. □

Если коэффициент заполнения отделён от единицы, теорема 12.5 предсказывает, что поиск отсутствующего элемента будет в среднем проходить за время $O(1)$. Например, если таблица заполнена наполовину, то среднее число проб будет не больше $1/(1-0{,}5) = 2$, а если на 90%, то не больше $1/(1-0{,}9) = 10$.

Из теоремы 12.5 немедленно получается и оценка на стоимость операции добавления к таблице:

Следствие 12.6. В предположении равномерного хеширования математическое ожидание числа проб при добавлении нового элемента в таблицу с открытой адресацией не превосходит $1/(1-\alpha)$, где $\alpha < 1$ — коэффициент заполнения.

Доказательство. При добавлении в таблицу отсутствующего в ней элемента происходят те же пробы, что при поиске отсутствующего в в ней элемента. □

Оценить среднее время успешного поиска немногим сложнее.

Теорема 12.7. *Рассмотрим таблицу с открытой адресацией, коэффициент заполнения которой равен $\alpha < 1$. Пусть хеширование равномерно. Тогда математическое ожидание числа проб при успешном поиске элемента в таблице не превосходит*

$$\frac{1}{\alpha}\ln\frac{1}{1-\alpha},$$

если считать, что ключ для успешного поиска в таблице выбирается случайным образом и все такие выборы равновероятны.

Доказательство. Уточним, как производится усреднение: сначала мы заполняем таблицу независимо выбираемыми ключами, причём для каждого из них выполняется предположение равномерного хеширования. Затем мы усредняем по всем элементам таблицы время их поиска.

Заметим, что при успешном поиске ключа k мы делаем те же самые пробы, которые производились при помещении ключа k в таблицу. Тем самым среднее число проб при поиске (усреднение по элементам) равно общему числу проб при добавлении, делённому на число элементов в таблице, которое мы обозначаем n. Математическое ожидание общего числа проб при добавлении равно сумме математических ожиданий для каждого отдельного шага. К моменту добавления $(i+1)$-го элемента в таблице заполнено i позиций, коэффициент заполнения равен i/m (m — число мест в таблице), и математическое ожидание не больше $1/(1-i/m) = m/(m-i)$. Поэтому сумма математических ожиданий не превосходит

$$\frac{m}{m}+\frac{m}{m-1}+\frac{m}{m-2}+\ldots+\frac{m}{m-n+1}.$$

Эта сумма равна $m\cdot(1/(m-n+1)+\ldots+1/(m-1)+1/m)$ и оценивается сверху с помощью интеграла (3.10):

$$m\cdot\int\limits_{m-n}^{m}\frac{1}{t}\,dt = m\ln(m/(m-n)).$$

Вспоминая, что общее число операций надо поделить на n, получаем оценку $(m/n)\ln(m/(m-n)) = (1/\alpha)\ln(1/(1-\alpha))$. $\square$

Если, например, таблица заполнена наполовину, то среднее число проб для успешного поиска не превосходит 1,387, а если на 90%, то 2,559.

Упражнения

12.4-1 Выполните добавление ключей $10, 22, 31, 4, 15, 28, 17, 88, 59$ (в указанном порядке) в хеш-таблицу с открытой адресацией размера $m = 11$. Для вычисления последовательности проб используется линейный метод с $h'(k) = k \bmod m$. Выполните то же задание, если используется квадратичный метод с той же h', $c_1 = 1$, $c_2 = 3$, а также для двойного хеширования с $h_1 = h'$ и $h_2(k) = 1 + (k \bmod (m-1))$.

12.4-2 Напишите процедуру Hash-Delete для удаления элемента из таблицы с открытой адресацией, реализующую описанную схему (со значением DELETED), и перепишите соответствующим образом процедуры Hash-Insert и Hash-Search.

12.4-3* Покажите, что при двойном хешировании ($h(k,i) = (h_1(k) + ih_2(k)) \bmod m$) последовательность проб, соответствующая ключу k, является перестановкой множества $\{0, 1, \ldots, m-1\}$ тогда и только тогда, когда $h_2(k)$ взаимно просто с m. (Указание: см. главу 33.)

12.4-4 Найдите численные значения верхних оценок теорем 12.5 и 12.7 для поиске присутствующего и отсутствующего элементов для коэффициентов заполнения 1/2, 3/4 и 7/8.

12.4-5* Предположим, что мы помещаем n записей в таблицу с открытой адресацией; размер таблицы равен m, хеширование равномерно, ключи записей выбираются случайным образом. Обозначим через $p(n,m)$ вероятность того, что при этом не произойдет коллизий. Покажите, что $p(n,m) \leqslant e^{-n(n-1)/2m}$. (Указание: см. неравенство (2.7).) Эта величина очень мала, когда n заметно больше $\sqrt{n}$.

12.4-6* Частичные суммы гармонического ряда можно оценить так:

$$H_n = \ln n + \gamma + \frac{\varepsilon}{2n}, \tag{12.8}$$

где $\gamma = 0{,}5772156649\ldots$ — так называемая **постоянная Эйлера** (Euler's constant) и $0 < \varepsilon < 1$ (доказательство см. в книге Кнута [121]). Как использовать это для оценки куска гармонического ряда в доказательстве теоремы 12.7?

12.4-7* Найдите ненулевое значение коэффициента заполнения α, при котором оценка среднего числа проб при поиске отсутствующего элемента (теорема 12.5) вдвое превосходит оценку среднего числа проб при успешном поиске (теорема 12.7).

Задачи

12-1 Наибольшее число проб при добавлении элемента

Рассмотрим хеш-таблицу с открытой адресацией размера m, в которую один за другим помещаются n ключей, причём $n \leqslant m/2$. Предположим, что хеширование равномерно.

а. Покажите, что для любого $i = 1, 2, \ldots, n$ вероятность того, что при добавлении i-го ключа в таблицу произошло более k проб, не превосходит 2^{-k}.

б. Покажите, что для любого $i = 1, 2, \ldots, n$ вероятность того, что при добавлении i-го ключа в таблицу произошло более $2 \lg n$ проб, не превосходит $1/n^2$.

Пусть X — случайная величина, равная максимальному числу проб при добавлении элементов с номерами $1, 2, \ldots, n$.

в. Покажите, что $\mathsf{P}\{X > 2 \lg n\} \leqslant 1/n$.

г. Покажите, что математическое ожидание величины X (наибольшего числа проб) есть $O(\lg n)$.

12-2 Поиск в неизменяющемся множестве

Пусть мы работаем с множеством из n элементов, в котором ключи являются числами, а единственная операция, которую надо поддерживать, — это поиск (элементы не добавляются и не удаляются). Требуется реализовать поиск максимально эффективно (до того, как начнут поступать запросы на поиск, множество можно предварительно обработать, и время на такую обработку не ограничено).

а. Покажите, что поиск можно реализовать таким образом, чтобы в худшем случае он занимал время $O(\lg n)$, а дополнительная память (сверх той, в которой хранится само множество) не использовалась.

б. Пусть мы решили записать элементы нашего множества в хеш-таблицу с открытой адресацией, состоящую из m ячеек. Предположим, что хеширование равномерно. При каком минимальном объёме $m - n$ дополнительной памяти средняя стоимость операции поиска элемента, отсутствующего в множестве, будет не хуже, чем в пункте (а)? В качестве ответа приведите асимптотическую оценку $m - n$ через n.

12-3 Длины цепочек при хешировании

Рассмотрим хеш-таблицу с n ячейками, в которой коллизии разрешаются с помощью цепочек. Хеширование равномерно: каждый новый ключ имеет равные шансы попасть во все ячейки независимо от предыдущих. Пусть M — максимальная длина цепочек после добавления n ключей. Ваша задача — доказать, что математическое ожидание M есть $O(\lg n/\lg\lg n)$.

а. Фиксируем некоторое хеш-значение. Пусть Q_k — вероятность того, ему соответствует k различных ключей. Покажите, что
$$Q_k = C_n^k\left(\frac{1}{n}\right)^k\left(1-\frac{1}{n}\right)^{n-k}.$$

б. Пусть P_k — вероятность того, что максимальная длина цепочки равна k. Покажите, что $P_k \leqslant nQ_k$.

в. Выведите из формулы Стирлинга (2.11), что $Q_k < e^k/k^k$.

г. Покажите, что существует такая константа $c > 1$, что $Q_k < 1/n^3$ при $k \geqslant c\lg n/\lg\lg n$. Заключите отсюда, что $P_k < 1/n^2$ при таких k.

д. Покажите, что математическое ожидание величины M не превосходит
$$\mathsf{P}\left\{M > \frac{c\lg n}{\lg\lg n}\right\}\cdot n + \mathsf{P}\left\{M \leqslant \frac{c\lg n}{\lg\lg n}\right\}\cdot\frac{c\lg n}{\lg\lg n},$$
и выведите отсюда, что это математическое ожидание есть $O(\lg n/\lg\lg n)$.

12-4 Пример квадратичной последовательности проб

Пусть нам надо поместить запись с ключом k в хеш-таблицу, ячейки которой пронумерованы числами $0, 1, \ldots, m-1$. У нас есть хеш-функция h, отображающая множество ключей в множество $\{0, 1, \ldots, m-1\}$. Будем действовать так:

1. Находим $i \leftarrow h(k)$ и полагаем $j \leftarrow 0$.
2. Проверяем позицию номер i. Если она свободна, заносим туда запись и на этом останавливаемся.
3. Полагаем $j \leftarrow (j+1) \bmod m$ и $i \leftarrow (i+j) \bmod m$ и возвращаемся к шагу 2.

а. Покажите, что описанный алгоритм — частный случай *"квадратичного метода"* для подходящих значений c_1 и c_2.

Предположим, что m является степенью двойки.

б. Покажите, что в худшем случае будет просмотрена вся таблица.

12-5 k-универсальное хеширование

Пусть $\mathcal{H}$ — семейство хеш-функций, отображающих множество возможных ключей U в $\{0, 1, \ldots, m-1\}$. Будем говорить, что $\mathcal{H}$ является **k-универсальным**, если для любой последовательности k различных ключей $\langle x_1, \ldots, x_k\rangle$ случайная величина $\langle h(x_1), \ldots, h(x_k)\rangle$ (где h — случайный элемент $\mathcal{H}$) принимает все m^k своих возможных значений с равными вероятностями.

а. Покажите, что всякое 2-универсальное семейство универсально.

б. Покажите, что семейство $\mathcal{H}$, описанное в разделе 12.3.3, не является 2-универсальным.

в. Расширим семейство $\mathcal{H}$ из разд. 12.3.3 и рассмотрим всевозможные функции вида

$$h_{a,b}(x) = h_a(x) + b \bmod m,$$

где b — некоторый вычет по модулю m. Покажите, что полученное семейство будет 2-универсальным.

Замечания

Алгоритмы хеширования прекрасно изложены у Кнута [123] и Гоннета [90]. Согласно Кнуту, хеш-таблицы и метод цепочек были изобретены Луном (H. P. Luhn) в 1953 году. Примерно в то же время Амдаль (G. M. Amdahl) изобрёл открытую адресацию.

13 Двоичные деревья поиска

Деревья поиска (search trees) позволяют выполнять следующие операции с динамическими множествами: Search (поиск), Minimum (минимум), Maximum (максимум), Predecessor (предыдущий), Successor (следующий), Insert (вставить) и Delete (удалить). Таким образом, дерево поиска может быть использовано и как словарь, и как очередь с приоритетами.

Время выполнения основных операций пропорционально высоте дерева. Если двоичное дерево *"плотно заполнено"* (все его уровни имеют максимально возможное число вершин), то его высота (и время выполнения операций) пропорциональны логарифму числа вершин. Напротив, если дерево представляет собой линейную цепочку из n вершин, это время вырастает до $\Theta(n)$. В разделе 13.4 мы увидим, что высота случайного двоичного дерева поиска есть $O(\lg n)$, так что в этом случае время выполнения основных операций есть $\Theta(\lg n)$.

Конечно, возникающие на практике двоичные деревья поиска могут быть далеки от случайных. Однако, приняв специальные меры по балансировке деревьев, мы можем гарантировать, что высота деревьев с n вершинами будет $O(\log n)$. В главе 14 рассмотрен один из подходов такого рода (красно-чёрные деревья). В главе 19 рассматриваются Б-деревья, которые особенно удобны для данных, хранящихся во вторичной памяти с произвольным доступом (на диске).

В этой главе мы рассмотрим основные операции с двоичными деревьями поиска и покажем, как напечатать элементы дерева в неубывающем порядке, как искать заданный элемент, как найти максимальный или минимальный элемент, как найти элемент, следующий за данным и предшествующий данному, и, наконец, как добавить или удалить элемент. Напомним, что определение дерева и основные свойства деревьев приводятся в главе 5.

Рисунок 13.1 Двоичные деревья поиска. Левое поддерево произвольной вершины x содержит ключи, не превосходящие $key[x]$, правое — не меньшие $key[x]$. Разные двоичные деревья поиска могут представлять одно и то же множество. Время выполнения (в худшем случае) большинства операций пропорционально высоте дерева. (а) Двоичное дерево поиска высоты 2 с 6 вершинами. (б) Менее эффективное дерево высоты 4, содержащее те же ключи.

13.1 Что такое двоичное дерево поиска?

В **двоичном дереве поиска** (binary search tree; пример приведён на рис. 13.1) каждая вершина может иметь (или не иметь) левого и правого ребёнка; каждая вершина, кроме корня, имеет родителя. При представлении с использованием указателей мы храним для каждой вершины дерева, помимо значения ключа *key* и дополнительных данных, также и указатели *left*, *right* и p (левый ребёнок, правый ребёнок, родитель). Если ребёнка (или родителя — для корня) нет, соответствующее поле содержит NIL.

Ключи в двоичном дереве поиска хранятся с соблюдением **свойства упорядоченности** (binary-search-tree property):

> Пусть x — произвольная вершина двоичного дерева поиска. Если вершина y находится в левом поддереве вершины x, то $key[y] \leqslant key[x]$. Если y находится в правом поддереве x, то $key[y] \geqslant key[x]$.

Так, на рис. 13.1(а) в корне дерева хранится ключ 5, ключи 2, 3 и 5 левом поддереве корня не превосходят 5, а ключи 7 и 8 в правом — не меньше 5. То же самое верно для всех вершин дерева. Например, ключ 3 на рис. 13.1(а) не меньше ключа 2 в левом поддереве и не больше ключа 5 в правом.

Свойство упорядоченности позволяет напечатать все ключи в неубывающем порядке с помощью простого рекурсивного алгоритма (называемого по-английски **inorder tree walk**). Этот алгоритм печатает ключ корня поддерева после всех ключей его левого поддерева, но перед ключами правого поддерева. (Заметим в скобках, что порядок, при котором корень предшествует обоим поддеревьям, называется **preorder**; порядок, в котором корень следует за ними, называется **postorder**.)

Вызов INORDER-TREE-WALK(*root*[T]) печатает (в указанном порядке) все ключи, входящие в дерево T с корнем *root*[T].

```
INORDER-TREE-WALK(x)
if x ≠ NIL
   then INORDER-TREE-WALK(left[x])
        напечатать key[x]
        INORDER-TREE-WALK(right[x])
```

К примеру, для обоих деревьев рис. 13.1 будет напечатано $2, 3, 5, 5, 7, 8$. Свойство упорядоченности гарантирует правильность алгоритма (индукция по высоте поддерева). Время работы на дереве с n вершинами есть $\Theta(n)$: на каждую вершину тратится ограниченное время (помимо рекурсивных вызовов) и каждая вершина обрабатывается один раз.

Упражнения

13.1-1 Нарисуйте двоичные деревья поиска высоты 2, 3, 4, 5 и 6 для одного и того же множества ключей $\{1, 4, 5, 10, 16, 17, 21\}$.

13.1-2 Кучи из раздела 7.1 также были двоичными деревьями, и требование упорядоченности там тоже было. В чём разница между тем требованием и теперешним? Как вы думаете, можно ли напечатать элементы двоичной кучи в неубывающем порядке за время $O(n)$? Объясните ваш ответ.

13.1-3 Напишите нерекурсивный алгоритм, печатающий ключи в двоичном дереве поиска в неубывающем порядке. (Указание: Простое решение использует в качестве дополнительной структуры стек; более изящное решение не требует стека, но предполагает, что можно проверять равенство указателей.)

13.1-4 Напишите рекурсивные алгоритмы для обхода деревьев в различных порядках (preorder, postorder). Как и раньше, время работы должно быть $O(n)$ (где n — число вершин).

13.1-5 Покажите, что любой алгоритм построения двоичного дерева поиска, содержащего заданные n элементов, требует (в худшем случае) времени $\Omega(n \lg n)$. Воспользуйтесь тем, что сортировка n чисел требует $\Omega(n \lg n)$ действий.

Рисунок 13.2 Поиск в двоичном дереве. Ища ключ 13, мы идём от корня по пути $15 \to 6 \to 7 \to 13$. Чтобы найти минимальный ключ 2, мы всё время идём налево; чтобы найти максимальный ключ 20 — направо. Для вершины с ключом 15 следующей будет вершина с ключом 17 (это минимальный ключ в правом поддереве вершины с ключом 15). У вершины с ключом 13 нет правого поддерева; поэтому, чтобы найти следующую за ней вершину, мы поднимаемся вверх, пока не пройдём по ребру, ведущему вправо-вверх; в данном случае следующая вершина имеет ключ 15.

13.2 Поиск в двоичном дереве

В этом разделе мы покажем, что двоичные деревья поиска позволяют выполнять операции Search, Minimum, Maximum, Successor и Predecessor за время $O(h)$, где h — высота дерева.

Поиск

Процедура поиска получает на вход искомый ключ k и указатель x на корень поддерева, в котором производится поиск. Она возвращает указатель на вершину с ключом k (если такая есть) или специальное значение NIL (если такой вершины нет).

```
Tree-Search(x, k)
if x = NIL или k = key[x]
    then return x
if k < key[x]
    then return Tree-Search(left[x], k)
    else return Tree-Search(right[x], k)
```

В процессе поиска мы двигаемся от корня, сравнивая ключ k с ключом, хранящимся в текущей вершине x. Если они равны, поиск завершается. Если $k < key[x]$, то поиск продолжается в левом поддереве x (ключ k может быть только там, согласно свойству упорядоченности). Если $k > key[x]$, то поиск продолжается в правом поддереве. Длина пути поиска не превосходит высоты дерева, поэтому время поиска есть $O(h)$ (где h — высота дерева).

Вот итеративная версия той же процедуры (которая, как правило, более эффективна):

```
Iterative-Tree-Search(x, k)
while x ≠ NIL и k ≠ key[x]
     do if k < key[x]
           then x ← left[x]
           else  x ← right[x]
return x
```

Минимум и максимум

Минимальный ключ в дереве поиска можно найти, пройдя по указателям *left* от корня (пока не упрёмся в NIL), см. рис. 13.2. Процедура возвращает указатель на минимальный элемент поддерева с корнем x.

```
Tree-Minimum(x)
while left[x] ≠ NIL
     do  x ← left[x]
return x
```

Свойство упорядоченности гарантирует правильность процедуры Tree-Minimum. Если у вершины x нет левого ребёнка, то минимальный элемент поддерева с корнем x есть x, так как любой ключ в правом поддереве не меньше $key[x]$. Если же левое поддерево вершины x не пусто, то минимальный элемент поддерева с корнем x находится в этом левом поддереве (поскольку сам x и все элементы правого поддерева больше).

Алгоритм Tree-Maximum симметричен:

```
Tree-Maximum(x)
while right[x] ≠ NIL
     do  x ← right[x]
return x
```

Оба алгоритма требуют времени $O(h)$, где h — высота дерева (поскольку двигаются по дереву только вниз).

Следующий и предыдущий элементы

Как найти в двоичном дереве элемент, следующий за данным? Свойство упорядоченности позволяет сделать это, двигаясь по дереву. Вот процедура, которая возвращает указатель на следующий за x элемент (если все ключи различны, он содержит следующий по величине ключ) или NIL, если элемент x — последний в дереве.

```
TREE-SUCCESSOR(x)
1  if right[x] ≠ NIL
2     then return TREE-MINIMUM(right[x])
3  y ← p[x]
4  while y ≠ NIL and x = right[y]
5      do  x ← y
6          y ← p[y]
7  return y
```

Процедура TREE-SUCCESSOR отдельно рассматривает два случая. Если правое поддерево вершины x непусто, то следующий за x элемент — минимальный элемент в этом поддереве и равен TREE-MINIMUM($right[x]$). Например, на рис. 13.2 за вершиной с ключом 15 следует вершина с ключом 17.

Пусть теперь правое поддерево вершины x пусто. Тогда мы идём от x вверх, пока не найдём вершину, являющуюся левым сыном своего родителя (строки 3–7). Этот родитель (если он есть) и будет искомым элементом. [Формально говоря, цикл в строках 4–6 сохраняет такое свойство: $y = p[x]$; искомый элемент непосредственно следует за элементами поддерева с корнем в x.]

Время работы процедуры TREE-SUCCESSOR на дереве высоты h есть $O(h)$, так как мы двигаемся либо только вверх, либо только вниз.

Процедура TREE-PREDECESSOR симметрична.

Таким образом, мы доказали следующую теорему.

Теорема 13.1. *Операции* SEARCH, MINIMUM, MAXIMUM, SUCCESSOR *и* PREDECESSOR *на дереве высоты h выполняются за время $O(h)$.*

Упражнения

13.2-1 Предположим, что в двоичном дереве поиска хранятся числа от 1 до 1000 и мы хотим найти число 363. Какие из следующих последовательностей *не* могут быть последовательностями просматриваемых при этом ключей?

а. $2, 252, 401, 398, 330, 344, 397, 363$;

б. $924, 220, 911, 244, 898, 258, 362, 363$;

в. $925, 202, 911, 240, 912, 245, 363$;

г. $2, 399, 387, 219, 266, 382, 381, 278, 363$;

д. $935, 278, 347, 621, 299, 392, 358, 363$.

13.2-2 Пусть поиск ключа в двоичном дереве завершается в листе. Рассмотрим три множества: A (элементы слева от пути поиска),

B (элементы на пути) и C (справа от пути). Профессор утверждает, что для любых трёх ключей $a \in A$, $b \in B$ и $c \in C$ верно $a \leqslant b \leqslant c$. Покажите, что он неправ, и приведите контрпример минимально возможного размера.

13.2-3 Докажите формально правильность процедуры Tree-Successor.

13.2-4 В разделе 13.1 был построен алгоритм, печатающий все ключи в неубывающем порядке. Теперь это можно сделать иначе: найти минимальный элемент, а потом $n-1$ раз искать следующий элемент. Докажите, что время работы такого алгоритма есть $O(n)$.

13.2-5 Докажите, что k последовательных вызовов Tree-Successor выполняются за $O(k+h)$ шагов (h — высота дерева) независимо от того, с какой вершины мы начинаем.

13.2-6 Пусть T — двоичное дерево поиска, все ключи в котором различны, x — его лист, а y — родитель x. Покажите, что $key[y]$ является соседним с $key[x]$ ключом (следующим или предыдущим в смысле порядка на ключах).

13.3 Добавление и удаление элемента

Эти операции меняют дерево, сохраняя свойство упорядоченности. Как мы увидим, добавление сравнительно просто; удаление чуть сложнее.

Добавление

Процедура Tree-Insert добавляет заданный элемент в подходящее место дерева T (сохраняя свойство упорядоченности). Параметром процедуры является указатель z на новую вершину, в которую помещены значения $key[z]$ (добавляемое значение ключа), $left[z] = \text{NIL}$ и $right[z] = \text{NIL}$. В ходе работы процедура меняет дерево T и (возможно) некоторые поля вершины z, после чего новая вершина с данным значением ключа оказывается вставленной в подходящее место дерева.

Рисунок 13.3 Добавление элемента с ключом 13. Светло-серые вершины находятся на пути от корня до позиции нового элемента. Пунктир связывает новый элемент со старыми.

```
TREE-INSERT(T, z)
 1  y ← NIL
 2  x ← root[T]
 3  while x ≠ NIL
 4       do y ← x
 5          if key[z] < key[x]
 6             then x ← left[x]
 7             else x ← right[x]
 8  p[z] ← y
 9  if y = NIL
10     then root[T] ← z
11     else if key[z] < key[y]
12             then left[y] ← z
13             else right[y] ← z
```

На рисунке 13.3 показано, как работает процедура TREE-INSERT. Подобно процедурам TREE-SEARCH и ITERATIVE-TREE-SEARCH, она двигается вниз по дереву, начав с его корня. При этом в вершине y сохраняется указатель на родителя вершины x (цикл в строках 3–7). Сравнивая $key[z]$ с $key[x]$, процедура решает, куда идти — налево или направо. Процесс завершается, когда x становится равным NIL. Этот NIL стоит как раз там, куда надо поместить z, что и делается в строках 8–13.

Как и остальные операции, добавление требует времени $O(h)$ для дерева высоты h.

Удаление

Параметром процедуры удаления является указатель на удаляемую вершину. При удалении возможны три случая, показанные на рисунке 13.4. Если у z нет детей, для удаления z достаточно поместить NIL в соответствующее поле его родителя (вместо z). Если у z есть один ребёнок, можно *"вырезать"* z, соединив его родителя

Рисунок 13.4 Удаление вершины z из двоичного дерева поиска. (а) Если вершина z не имеет детей, её можно удалить без проблем. (б) Если вершина z имеет одного ребёнка, помещаем его на место вершины z. (в) Если у вершины z двое детей, мы сводим дело к предыдущему случаю, удаляя вместо неё вершину y с непосредственно следующим значением ключа (у этой вершины ребёнок один) и помещая ключ $key[y]$ (и связанные с ним дополнительные данные) на место вершины z.

напрямую с его ребёнком. Если же детей двое, требуются некоторые приготовления: мы находим следующий (в смысле порядка на ключах) за z элемент y; у него нет левого ребёнка (упр. 13.3-4). Теперь можно скопировать ключ и дополнительные данные из вершины y в вершину z, а саму вершину y удалить описанным выше способом.

Примерно так и действует процедура Tree-Delete (хотя рассматривает эти три случая в несколько другом порядке).

```
Tree-Delete(T, z)
 1  if left[z] = nil или right[z] = nil
 2     then y ← z
 3     else  y ← Tree-Successor(z)
 4  if left[y] ≠ nil
 5     then x ← left[y]
 6     else  x ← right[y]
 7  if x ≠ nil
 8     then p[x] ← p[y]
 9  if p[y] = nil
10     then root[T] ← x
11     else  if y = left[p[y]]
12              then left[p[y]] ← x
13              else  right[p[y]] ← x
14  if y ≠ z
15     then key[z] ← key[y]
16          ▷ копируем дополнительные данные, связанные с y
17  return y
```

В строках 1–3 определяется вершина y, которую мы потом вырежем из дерева. Это либо сама вершина z (если у z не более одного ребёнка), либо следующий за z элемент (если у z двое детей). Затем в строках 4–6 переменная x становится указателем на существующего ребёнка вершины y, или равной NIL, если у y нет детей. Вершина y вырезается из дерева в строках 7–13 (меняются указатели в вершинах $p[y]$ и x). При этом отдельно рассматриваются граничные случаи, когда $x = \text{NIL}$ и когда y является корнем дерева. Наконец, в строках 14–16, если вырезанная вершина y отлична от z, ключ (и дополнительные данные) вершины y перемещаются в z (ведь нам надо было удалить z, а не y). Наконец, процедура возвращает указатель y (это позволит вызывающей процедуре впоследствии освободить память, занятую вершиной y). Время выполнения есть $O(h)$ на дереве высоты h.

Итак, мы доказали следующую теорему.

Теорема 13.2. *Операции* INSERT *и* DELETE *могут быть выполнены за время $O(h)$, где h — высота дерева.*

Упражнения

13.3-1 Напишите рекурсивный вариант процедуры TREE-INSERT.

13.3-2 Начиная с пустого дерева, будем добавлять элементы с различными ключами один за другим. Если после этого мы проводим поиск элемента с ключом x, то число сравнений на единицу больше числа сравнений, выполненных при добавлении этого элемента. Почему?

13.3-3 Набор из n чисел можно отсортировать, сначала добавив их один за другим в двоичное дерево поиска (с помощью процедуры Tree-Insert), а потом обойти дерево с помощью процедуры Inorder-Tree-Walk. Найдите время работы такого алгоритма в худшем и в лучшем случае.

13.3-4 Покажите, что, если вершина двоичного дерева поиска имеет двоих детей, то следующая за ней вершина не имеет левого ребёнка, а предшествующая ей вершина — правого.

13.3-5 Предположим, что указатель на вершину y хранится в какой-то внешней структуре данных и что предшествующая y вершина дерева удаляется с помощью процедуры Tree-Delete. Какие при этом могут возникнуть проблемы? Как можно изменить Tree-Delete, чтобы этих проблем избежать?

13.3-6 Коммутируют ли операции удаления двух вершин? Другими словами, получим ли мы одинаковые деревья, если в одном случае удалим сначала x, а потом y, а в другом — наоборот? Объясните свой ответ.

13.3-7 Если у z двое детей, мы можем использовать в Tree-Delete не следующий за z элемент, а предыдущий. Можно надеяться, что справедливый подход, который в половине случаев выбирает предыдущий, а в половине — следующий элемент, будет приводить к лучше сбалансированному дереву. Как изменить текст процедуры, чтобы реализовать такой подход?

⋆ 13.4 Случайные двоичные деревья поиска

Как мы видели, основные операции с двоичными деревьями поиска требуют времени $O(h)$, где h — высота дерева. Поэтому важно понять, какова высота *"типичного"* дерева. Для этого необходимо принять какие-то статистические предположения о распределении ключей и последовательности выполняемых операций.

К сожалению, в общем случае ситуация трудна для анализа, и мы будем рассматривать лишь деревья, полученные добавлением вершин (без удалений). Определим **случайное двоичное дерево** (randomly built search tree) из n различных ключей как дерево, получающееся из пустого дерева добавлением этих ключей в случайном порядке (все $n!$ перестановок считаем равновероятными). (Как видно из упр. 13.4-2, это не означает, что все двоичные деревья равновероятны, поскольку разные порядки добавления могут приводить к одному и тому же дереву.) В этом разделе мы докажем, что математическое ожидание высоты случайного дерева из n ключей есть $O(\lg n)$.

Посмотрим, как связана структура дерева с порядком добавления ключей.

Лемма 13.3. *Пусть T — дерево, получающееся после добавления n различных ключей $k_1, k_2, \ldots, k_n$ (в указанном порядке) к изначально пустому дереву. Тогда k_i является предком k_j в T тогда и только тогда, когда $i < j$, и при этом*

$$k_i = \min\{k_l : 1 \leqslant l \leqslant i \text{ и } k_l > k_j\}$$

(ключ k_i больше k_j и их не разделяет ни один ключ среди $k_1, \ldots, k_i$) или

$$k_i = \max\{k_l : 1 \leqslant l \leqslant i \text{ и } k_l < k_j\}$$

(ключ k_i меньше k_j и их не разделяет ни один ключ среди $k_1, \ldots, k_i$)

Доказательство. $\Rightarrow$: Предположим, что k_i является предком k_j. Очевидно, $i < j$ (потомок появляется в дереве позже предка). Рассмотрим дерево T_i, которое получается после добавления ключей $k_1, k_2, \ldots, k_i$. Путь в T_i от корня до k_i тот же, что и путь в T от корня до k_i. Таким образом, если бы ключ k_j был добавлен в T_i, он стал бы правым или левым ребёнком k_i. Следовательно (см. упр. 13.2-6), k_i является либо наименьшим среди тех ключей из $k_1, k_2, \ldots, k_i$, которые больше k_j, либо наибольшим среди ключей из того же набора, меньших k_j.

$\Leftarrow$: Предположим, что k_i является наименьшим среди тех ключей $k_1, k_2, \ldots, k_i$, которые больше k_j. (Другой случай симметричен.) Что будет происходить при помещении ключа k_j в дерево? Сравнение k_j с ключами на пути от корня к k_i даст те же результаты, что и для k_i. Следовательно, мы пройдём путь от корня до k_i, так что k_j станет потомком k_i.

Лемма доказана. □

Теперь можно понять, как зависит глубина каждого ключа от перестановки на входе.

Следствие 13.4. Пусть T — дерево, полученное из пустого добавлением n различных ключей $k_1, k_2, \ldots, k_n$ (в указанном порядке). Для каждого ключа k_j (при всех $1 \leqslant j \leqslant n$) рассмотрим множества

$$G_j = \{k_i : 1 \leqslant i < j \text{ и } k_l > k_i > k_j \text{ при всех } l < i, \text{ для которых } k_l > k_j\}$$

и

$$L_j = \{k_i : 1 \leqslant i < j \text{ и } k_l < k_i < k_j \text{ при всех } l < i, \text{ для которых } k_l < k_j\}.$$

Тогда ключи на пути из корня в k_j — в точности $G_j \cup L_j$, а глубина k_j в дереве T равна

$$d(k_j, T) = |G_j| + |L_j|.$$

На рисунке 13.5 изображены множества G_j и L_j. Их построение можно объяснить так. Считая для наглядности ключи числами, будем отмечать их на числовой оси: сначала k_1, потом k_2 и так далее вплоть до k_j. В каждый момент на оси отмечено несколько точек $k_1, \ldots, k_t$ (где $1 \leqslant t \leqslant j-1$). Посмотрим, какая из этих точек будет ближайшей справа к будущему положению ключа k_j. Множество всех таких ближайших точек (для всех моментов времени $t = 1, 2, \ldots, j-1$) и есть G_j. Ближайшие слева точки образуют множество L_j.

Наша цель — оценить сверху количество элементов в G_j и L_j, поскольку сумма этих количеств равна глубине ключа k_j. Фиксируем некоторое j. Число элементов в G_j будет случайной величиной, зависящей от порядка ключей на входе (имеет значение лишь порядок на ключах $k_1, \ldots, k_j$). Мы хотим оценить это число сверху (доказать, что вероятность события *"это число велико"* мала).

Следующий факт из теории вероятностей играет центральную роль при этой оценке.

Лемма 13.5. *Пусть $k_1, k_2, \ldots, k_n$ есть случайная перестановка n различных чисел. Для каждого i от 1 до n рассмотрим минимальный элемент в множестве $\{k_1, k_2, \ldots, k_i\}$. Множество всех таких элементов назовём S:*

$$S = \{k_i : 1 \leqslant i \leqslant n \text{ и } k_l > k_i \text{ для всех } l < i\}. \qquad (13.1)$$

Тогда $\mathsf{P}\{|S| \geqslant (\beta+1)H_n\} \leqslant 1/n^2$, где H_n — n-я частичная сумма гармонического ряда, а $\beta \approx 4{,}32$ — корень уравнения $(\ln\beta - 1)\beta = 2$.

Доказательство. Будем следить за тем, как меняется множество $\{k_1, \ldots, k_i\}$ с ростом i. На i-м шаге к нему добавляется элемент k_i, причём он с равными вероятностями может оказаться первым, вторым,..., i-м по величине (каждой из этих возможностей соответствует равная доля входных перестановок). Таким образом, вероятность увеличения множества S на i-м шаге равна $1/i$ при любом порядке среди ключей $k_1, \ldots, k_{i-1}$, так что для разных i эти события независимы.

Мы приходим к ситуации, описанной в теореме 6.6: имеется последовательность независимых испытаний, вероятность успеха в i-м испытании равна $1/i$. Нам надо оценить число успехов.

Математическое ожидание этого числа равно $1 + 1/2 + \ldots + 1/i = H_i = \ln i + O(1)$, см. формулу (3.5) и задачу 6-2. Нам надо оценить вероятность того, что число успехов больше своего математического ожидания в $\beta + 1$ раз.

Это делается с помощью теоремы 6.6. Напомним, что математическое ожидание $|S|$ есть $\mu = H_n \geqslant \ln n$, и по теореме 6.6 мы имеем

$$\begin{aligned}
\mathsf{P}\{|S| \geqslant (\beta+1)H_n\} &= P\{|S| - \mu \geqslant \beta H_n\} \leqslant \\
&\leqslant \left(\frac{eH_n}{\beta H_n}\right)^{\beta H_n} = \\
&= e^{(1-\ln\beta)\beta H_n} \leqslant \\
&\leqslant e^{-(\ln\beta - 1)\beta \ln n} = \\
&= n^{-(\ln\beta-1)\beta} = \\
&= 1/n^2
\end{aligned}$$

согласно определению числа β. □

После такой подготовки вернёмся к деревьям поиска.

Теорема 13.6. *Средняя высота случайного двоичного дерева поиска, построенного по n различным ключам, есть $O(\lg n)$.*

Доказательство. Пусть $k_1, k_2, \ldots, k_n$ — случайная перестановка данных n ключей, T — дерево, полученное последовательным добавлением этих ключей к пустому. Для фиксированного номера j и для произвольного числа t рассмотрим вероятность того, что глубина $d(k_j, T)$ ключа k_j не меньше t. Согласно следствию 13.4, в этом случае хотя бы одно из множеств G_j и L_j должно иметь размер не менее $t/2$. Таким образом,

$$\mathsf{P}\{d(k_j, T) \geqslant t\} \leqslant \mathsf{P}\{|G_j| \geqslant t/2\} + \mathsf{P}\{|L_j| \geqslant t/2\}. \qquad (13.2)$$

Вначале рассмотрим $\mathsf{P}\{|G_j| \geqslant t/2\}$. Оценим условную вероятность этого события при фиксированном множестве $U = \{t : 1 \leqslant t \leqslant j - 1 \text{ и } k_t > k_j\}$ (то есть когда известно, какие из элементов $k_1, \ldots, k_{j-1}$ больше k_j). Мы находимся в ситуации леммы 13.5 (все перестановки элементов с индексами из U равновероятны), и поэтому условная вероятность события $|G_j| \geqslant t/2$ при данном U равна вероятности того, что в случайной перестановке из $u = |U|$ элементов есть по крайней мере $t/2$ элементов, меньших всех предыдущих. С ростом u эта вероятность только растёт, так что все условные вероятности не превосходят $\mathsf{P}\{|S| \geqslant t/2\}$, где S определено как в лемме 13.5. Поэтому и полная вероятность события $\{|G_j| \geqslant t/2\}$ не превосходит $\mathsf{P}\{|S| \geqslant t/2\}$.

Аналогичным образом

$$\mathsf{P}\{|L_j| \geqslant t/2\} \leqslant \mathsf{P}\{|S| \geqslant t/2\}$$

и, согласно неравенству (13.2),

$$\mathsf{P}\{d(k_j, T) \geqslant t\} \leqslant 2\mathsf{P}\{|S| \geqslant t/2\}.$$

Взяв теперь $t = 2(\beta+1)H_n$, где $H_n = 1+1/2+\ldots+1/n$ (а $\beta \approx 4{,}32$ — корень уравнения $(\ln\beta - 1)\beta = 2$) и применив лемму 13.5, мы заключаем, что

$$\mathsf{P}\{d(k_j,T) \geqslant 2(\beta+1)H_n\} \leqslant 2\mathsf{P}\{|S| \geqslant (\beta+1)H_n\} \leqslant 2/n^2.$$

Всего вершин в дереве не более n, поэтому вероятность того, что какая-то вершина будет иметь глубину $2(\beta+1)H_n$ или больше, не более чем в n раз превосходит такую же вероятность для одной вершины, и потому не превосходит $2/n$. Итак, с вероятностью по меньшей мере $1-2/n$ высота случайного дерева не превосходит $2(\beta+1)H_n$, и в любом случае она не больше n. Таким образом, математическое ожидание не превосходит $(2(\beta+1)H_n)(1-2/n) + n(2/n) = O(\lg n)$. □

Упражнения

13.4-1 Приведите пример дерева поиска, в котором средняя (по всем вершинам) глубина вершины есть $\Theta(\lg n)$, но высота дерева есть $\omega(\lg n)$. Насколько велика может быть высота дерева, если средняя глубина вершины есть $\Theta(\lg n)$?

13.4-2 Покажите, что при нашем понимании случайного двоичного дерева поиска не все упорядоченные деревья с данными n ключами равновероятны. (Указание: Рассмотрите случай $n = 3$.)

13.4-3* Для данной константы $r \geqslant 1$ укажите константу t, для которой вероятность события *"высота случайного двоичного дерева поиска не меньше tH_n"* меньше $1/n^r$.

13.4-4* Рассмотрим алгоритм Randomized-Quicksort, применённый к последовательности из n чисел. Докажите, что для любой константы $k > 0$ существует такая константа c, что с вероятностью не менее $1 - c/n^k$ алгоритм завершает работу за время $cn\lg n$.

Задачи

13-1 Двоичные деревья поиска и равные ключи

Равные ключи — источник проблем при работе с деревьями поиска.

а Какова асимптотика времени работы процедуры Tree-Insert при добавлении n одинаковых ключей в изначально пустое дерево?

Причина тут в том, что при выборе в строках 5–7 и 11–13 мы в случае равенства всегда двигаемся направо по дереву. Будем рассматривать случай равенства отдельно. Оцените асимптотику времени добавления n равных ключей в пустое дерево при использовании трёх различных подходов:

б Храним в вершине x флаг $b[x]$, и выбираем левого или правого ребёнка в зависимости от значения $b[x]$. При этом флаг меняется при каждом посещении вершины, так что направления чередуются.

в Храним элементы с равными ключами в одной вершине (с помощью списка) и добавляем элемент с уже встречавшимся ключом в этот список.

г Направление движения выбираем случайно. (Каково будет время в худшем случае? Что вы можете сказать о математическом ожидании?)

13-2 Цифровые деревья

Рассмотрим две строки $a = a_0a_1 \ldots a_p$ и $b = b_0b_1 \ldots b_q$, составленные из символов некоторого (упорядоченного) алфавита. Говорят, что строка a **лексикографически меньше** строки b (a is lexicographically less than b), если выполняется одно из двух условий:

1. Существует число j из $0..\min(p,q)$, при котором $a_i = b_i$ для всех $i = 0, 1, \ldots, j-1$ и $a_j < b_j$.
2. $p < q$ и $a_i = b_i$ для всех $i = 0, 1, \ldots, p$.

Например, $10100 < 10110$ согласно правилу 1 (при $j = 3$), а $10100 < 101000$ согласно правилу 2. Такой порядок применяется в словарях.

Строение **цифрового дерева** (radix tree) видно из примера на рис. 13.6, где показано дерево, хранящее битовые строки 1011, 10, 011, 100 и 0. При поиске строки $a = a_0a_1 \ldots a_p$ мы на i-м шаге идём налево при $a_i = 0$ и направо при $a_i = 1$. Пусть элементами множества S являются попарно различные битовые строки суммарной длины n. Покажите, как с помощью цифрового дерева отсортировать S в лексикографическом порядке за $\Theta(n)$ действий. (Например, для множества рис. 13.6 результатом сортировки будет последовательность $0, 011, 10, 100, 1011$.)

13-3 Средняя глубина вершины в случайном двоичном дереве

В этой задаче мы докажем, что математическое ожидание средней глубины вершины в случайном двоичном дереве с n вершинами есть $O(\lg n)$. Хотя этот результат слабее, чем результат теоремы 13.6, доказательство устанавливает интересные аналогии между двоичными деревьями поиска и процедурой Randomized-Quicksort из раздела 8.3.

Рассмотрим (ср. главу 5, упр. 5.5-6) сумму глубин $d(x,T)$ всех вершин x дерева T, которую мы будем обозначать $P(T)$.

а Средняя глубина вершины в дереве T есть

$$\frac{1}{n}\sum_{x\in T} d(x,T) = \frac{1}{n}P(T).$$

Таким образом, надо показать, что математическое ожидание $P(T)$ есть $O(n\lg n)$.

б Обозначим через T_L и T_R левое и правое поддеревья дерева T. Убедитесь, что если T содержит n вершин, то

$$P(T) = P(T_L) + P(T_R) + n - 1.$$

в Обозначим через $P(n)$ математическое ожидание внутренней суммы длин для случайного двоичного дерева поиска с n вершинами. Покажите, что

$$P(n) = \frac{1}{n}\sum_{i=0}^{n-1}(P(i) + P(n-i-1) + n - 1).$$

г Покажите, что

$$P(n) = \frac{2}{n}\sum_{k=1}^{n-1} P(k) + \Theta(n).$$

д Вспоминая рассуждение из раздела 8.4.2 (оценка математического ожидания времени быстрой сортировки), покажите, что $P(n) = O(n\lg n)$.

В каждом рекурсивном вызове быстрой сортировки мы случайным образом выбираем граничный элемент. Подобно этому, каждая вершина дерева поиска является границей между левым и правым своим поддеревом.

е Опишите реализацию алгоритма быстрой сортировки, при котором в процессе сортировки элементов $k_1, \ldots, k_n$ выполняются в точности те же сравнения, что и при добавлении их в (изначально пустое) дерево. (Порядок сравнений может быть другим.)

13-4 Количество разных двоичных деревьев

Обозначим через b_n количество различных двоичных деревьев с n вершинами. В этой задаче требуется вывести формулу для b_n и оценить скорость роста числа b_n.

а Покажите, что $b_0 = 1$ и что

$$b_n = \sum_{k=0}^{n-1} b_k b_{n-1-k}$$

при $n \geqslant 1$.

б Пусть $B(x)$ — производящая функция

$$B(x) = \sum_{n=0}^{\infty} b_n x^n$$

(определение производящих функций дано в задаче 4-6). Покажите, что $B(x) = xB(x)^2 + 1$ и, таким образом,

$$B(x) = \frac{1}{2x}(1 - \sqrt{1-4x}).$$

Ряд Тейлора (Taylor expansion) функции $f(x)$ в точке $x = a$ определяется формулой

$$f(x) = \sum_{k=0}^{\infty} \frac{f^{(k)}(a)}{k!}(x-a)^k$$

где $f^{(k)}(a)$ — k-я производная f в точке a.

в Покажите, что

$$b_n = \frac{1}{n+1} C_{2n}^n$$

разложив в ряд Тейлора функцию $\sqrt{1-4x}$ в точке 0. (Ряд для $\sqrt{1+h} = (1+h)^{1/2}$ можно получить также как обобщение бинома Ньютона, если для нецелых n и целых неотрицательных k положить $C_n^k = n(n-1)\ldots(n-k+1)/k!$.)

Число b_n называется n-м **числом Каталана** (Catalan number).

г Покажите, что

$$b_n = \frac{4^n}{\sqrt{\pi} n^{3/2}}(1 + O(1/n)).$$

Замечания

Подробное обсуждение двоичных деревьев поиска и многих аналогичных структур данных можно найти у Кнута [123]. Видимо, двоичные деревья поиска были независимо придуманы многими людьми незадолго до 1960 года.

ключи	21	9	4	25	7	12	3	10	19	29	17	6	26	18
G'_j	21			25					19	29				
G_j	21								19					
L'_j		9	4		7	12	3	10						
L_j		9				12								

(б)

Рисунок 13.5 Множества G_j и L_j, составляющие множество ключей на пути к ключу $k_j = 17$. (а) Черные вершины содержат ключи из G_j, белые из L_j, остальные вершины — серые. Выделен путь к ключу k_j. Ключи левее пунктирной линии меньше k_j, ключи правее — больше. (б) Множество $G'_j = \{21, 25, 19, 29\}$ состоит из ключей, добавленных раньше ключа 17 и больших 17. Множество $G_j = \{21, 19\}$ содержит ключи, бывшие ближайшими справа к ключу 17, то есть бывшие минимальными в уже появившейся части G'_j. Ключ 21 был добавлен первым к G'_j и попал в G_j; ключ 25 не попал (он больше текущего минимума, равного 21). Ключ 19 попадает в G_j, потому что он меньше 21, а 29 — нет, так как $29 > 19$. Множества L'_j и L_j строятся аналогичным образом.

Рисунок 13.6 Цифровое дерево хранит строки 1011, 10, 011, 100 и 0. Каждой вершине соответствует ключ — строка, которую можно прочесть, идя из корня в эту вершину, поэтому эти ключи не надо хранить специально (на рисунке они показаны для наглядности). Тёмные вершины не соответствуют ключам, а являются промежуточными для других вершин.

14 Красно-чёрные деревья

В главе 13 мы показали, что основные операции с двоичным деревом поиска высоты h могут быть выполнены за $O(h)$ действий. Деревья эффективны, если их высота мала — но малая высота не гарантируется, и в худшем случае деревья не более эффективны, чем списки. Красно-чёрные деревья — один из типов *"сбалансированных"* деревьев поиска, в которых предусмотрены операции балансировки, гарантирующие, что высота дерева не превзойдёт $O(\lg n)$.

14.1 Свойства красно-чёрных деревьев

Красно-чёрное дерево (red-black tree) — это двоичное дерево поиска, вершины которого разделены на красные (red) и чёрные (black). Таким образом, каждая вершина хранит один дополнительный бит — её цвет.

При этом должны выполняться определённые требования, которые гарантируют, что глубины любых двух листьев отличаются не более чем в два раза, поэтому дерево можно назвать **сбалансированным** (balanced).

Каждая вершина красно-чёрного дерева имеет поля *color* (цвет), *key* (ключ), *left* (левый ребёнок), *right* (правый ребёнок) и p (родитель). Если у вершины отсутствует ребёнок или родитель, соответствующее поле содержит NIL. Для удобства мы будем считать, что значения NIL, хранящиеся в полях *left* и *right*, являются ссылками на дополнительные (фиктивные) листья дерева. В таком пополненном дереве каждая старая вершина (содержащая ключ) имеет двух детей.

Двоичное дерево поиска называется красно-чёрным деревом, если оно обладает следующими свойствами (будем называть их **RB-свойствами**, по-английски red-black properties):

1. Каждая вершина — либо красная, либо чёрная.
2. Каждый лист (NIL) — чёрный.

Рисунок 14.1 Красно-чёрное дерево. Чёрные вершины показаны как тёмные, красные — как серые. Каждая вершина либо красная, либо черная. Все NIL-листья чёрные. Дети красной вершины — чёрные. Для каждой вершины все пути от неё вниз к листьям содержит одинаковое количество чёрных вершин. Около каждой вершины (кроме листьев) записана её чёрная высота. Чёрная высота листьев равна 0.

3. Если вершина красная, оба её ребёнка чёрные.
4. Все пути, идущие вниз от корня к листьям, содержат одинаковое количество чёрных вершин.

Пример красно-чёрного дерева показан на рисунке 14.1.

Рассмотрим произвольную вершину x красно-чёрного дерева и пути, ведущие вниз от неё к листьям. Все они содержат одно и то же число чёрных вершин (добавим к ним путь из корня в x и применим свойство 4). Число чёрных вершин в любом из них (саму вершину x мы не считаем) будем называть **чёрной высотой** (black-height) вершины x и обозначать $\mathrm{bh}(x)$. Чёрной высотой дерева будем считать чёрную высоту его корня.

Следующая лемма показывает, что красно-чёрные деревья хороши как деревья поиска.

Лемма 14.1. *Красно-чёрное дерево с n внутренними вершинами (т. е. не считая NIL-листьев) имеет высоту не больше* $2\lg(n+1)$.

Доказательство. Сначала покажем, что поддерево с корнем в x содержит по меньшей мере $2^{\mathrm{bh}(x)}-1$ внутренних вершин. Доказательство проведём индукцией от листьев к корню. Для листьев чёрная высота равна 0, и поддерево в самом деле содержит не менее $2^{\mathrm{bh}(x)}-1=2^0-1=0$ внутренних вершин. Пусть теперь вершина x не является листом и имеет чёрную высоту k. Тогда оба её ребёнка имеют чёрную высоту не меньше $k-1$ (красный ребёнок будет иметь высоту k, чёрный — $k-1$). По предположению индукции левое и правое поддеревья вершины x содержат не менее $2^{k-1}-1$ вершин, и потому поддерево с корнем в x содержит по меньшей мере $2^{k-1}-1+2^{k-1}-1+1=2^k-1$ внутренних вершин.

Чтобы завершить доказательство леммы, обозначим высоту дерева через h. Согласно свойству 3, по меньшей мере половину всех вершин на пути от корня к листу, не считая корень, составляют чёрные вершины. Следовательно, чёрная высота дерева не меньше $h/2$. Тогда

$$n \geqslant 2^{h/2} - 1.$$

Перенося 1 налево и перейдя к логарифмам, получаем $\lg(n+1) \geqslant h/2$, или $h \leqslant 2\lg(n+1)$. Лемма доказана. $\square$

Тем самым для красно-чёрных деревьев операции SEARCH, MINIMUM, MAXIMUM, SUCCESSOR и PREDECESSOR выполняются за время $O(\lg n)$, так как время их выполнения есть $O(h)$ для дерева высоты h, а красно-чёрное дерево с n вершинами имеет высоту $O(\lg n)$.

Сложнее обстоит дело с процедурами TREE-INSERT и TREE-DELETE из главы 13: проблема в том, что они могут испортить структуру красно-чёрного дерева, нарушив RB-свойства. Поэтому эти процедуры придётся модифицировать. Мы увидим в разделах 14.3 и 14.4, как можно реализовать добавление и удаление элементов за время $O(\lg n)$ с сохранением RB-свойств.

Упражнения

14.1-1 Нарисуйте полное двоичное дерево поиска высоты 3 с ключами $\{1, 2, \ldots, 15\}$. Добавьте NIL-листья и покрасьте вершины тремя способами так, чтобы получившиеся красно-чёрные деревья имели чёрную высоту 2, 3 и 4.

14.1-2 Предположим, что корень красно-чёрного дерева красный. Если мы покрасим его в чёрный цвет, останется ли дерево красно-чёрным?

14.1-3 Покажите, что самый длинный путь вниз от вершины x к листу не более чем вдвое длиннее самого короткого такого пути.

14.1-4 Какое наибольшее и наименьшее количество внутренних вершин может быть в красно-чёрном дереве чёрной высоты k?

14.1-5 Опишите красно-чёрное дерево, содержащее n ключей, с наибольшим возможным отношением числа красных внутренних вершин к числу чёрных внутренних вершин. Чему равно это отношение? Для какого дерева это отношение будет наименьшим, и чему равно это отношение?

Рисунок 14.2 Операции вращения на двоичном дереве поиска. Операция RIGHT-ROTATE преобразует левое дерево в правое, меняя несколько указателей. Правое дерево можно перевести в левое обратной операцией LEFT-ROTATE. Вершины x и y могут находиться в любом месте дерева. Буквы α, β и γ обозначают поддеревья. В обоих деревьях выполнено одно и то же свойство упорядоченности: ключи из α предшествуют $key[x]$, который предшествует ключам из β, которые предшествуют $key[y]$, который предшествует ключам из γ.

14.2 Вращения

Операции TREE-INSERT и TREE-DELETE выполняются на красно-чёрном дереве за время $O(\lg n)$, но они изменяют дерево, и результат может не обладать RB-свойствами, описанными в разделе 14.1. Чтобы восстановить эти свойства, надо перекрасить некоторые вершины и изменить структуру дерева.

Мы будем менять структуру с помощью **вращений** (rotations). Вращение представляет собой локальную операцию (меняется несколько указателей) и сохраняет свойство упорядоченности. На рисунке 14.2 показаны два взаимно обратных вращения: левое и правое. Левое вращение возможно в любой вершине x, правый ребёнок которой (назовём его y) не является листом (NIL). После вращения y оказывается корнем поддерева, x — левым ребёнком y, а бывший левый ребёнок y — правым ребёнком x.

В процедуре LEFT-ROTATE предполагается, что $right[x] \neq$ NIL.

```
LEFT-ROTATE(T, x)
y ← right[x]                ▷ Находим y.
right[x] ← left[y]          ▷ Левое поддерево y становится
                                  правым поддеревом x.
if left[y] ≠ NIL
   then p[left[y]] ← x
p[y] ← p[x]                 ▷ Делаем родителя x родителем y.
if p[x] = NIL
   then root[T] ← y
   else if x = left[p[x]]
           then left[p[x]] ← y
           else right[p[x]] ← y
left[y] ← x                 ▷ Делаем x левым ребёнком y.
p[x] ← y
```

На рисунке 14.3 показано действие процедуры LEFT-ROTATE. Про-

Рисунок 14.3 Пример действия процедуры Left-Rotate. Дополнительные nil-листья не показаны. Порядок ключей в начальном и конечном деревьях один и тот же.

цедура Right-Rotate аналогична. Обе они работают за время $O(1)$ и меняют только указатели. Остальные поля вершин остаются неизменными.

Упражнения

14.2-1 Нарисуйте дерево, которое получится, если с помощью процедуры Tree-Insert добавить ключ 36 к дереву рис. 14.1. Если сделать добавленную вершину красной, будет ли полученное дерево обладать RB-свойствами? А если сделать её чёрной?

14.2-2 Напишите процедуру Right-Rotate.

14.2-3 Убедитесь, что вращения сохраняют свойство упорядоченности.

14.2-4 Пусть a, b и c — произвольные вершины в поддеревьях α, β и γ на рис. 14.2 (справа). Как изменится глубина a, b и c при выполнении левого вращения?

14.2-5 Покажите, что произвольное двоичное дерево поиска с n вершинами может быть преобразовано в любое другое дерево с тем же числом вершин (и теми же ключами) с помощью $O(n)$ вращений. (Указание: Сначала покажите, что $n-1$ правых вращений достаточно, чтобы преобразовать любое дерево в идущую вправо цепочку.)

14.3 Добавление вершины

Добавление вершины в красно-чёрное дерево проводится за время $O(\lg n)$. Сначала мы применяем процедуру Tree-Insert, как делалось для двоичных деревьев поиска, и красим новую вершину в красный цвет. После этого надо восстановить RB-свойства, для чего приходится перекрасить некоторые вершины и произвести вращения. При этом возможны различные ситуации, с которыми надо аккуратно разобраться.

```
RB-Insert(T, x)
 1  Tree-Insert(T, x)
 2  color[x] ← RED
 3  while x ≠ root[T] и color[p[x]] = RED
 4      do if p[x] = left[p[p[x]]]
 5            then y ← right[p[p[x]]]
 6                 if color[y] = RED
 7                    then color[p[x]] ← BLACK          ▷ Случай 1
 8                         color[y] ← BLACK             ▷ Случай 1
 9                         color[p[p[x]]] ← RED         ▷ Случай 1
10                         x ← p[p[x]]                  ▷ Случай 1
11                    else if x = right[p[x]]
12                            then x ← p[x]             ▷ Случай 2
13                                 Left-Rotate(T, x)    ▷ Случай 2
14                         color[p[x]] ← BLACK          ▷ Случай 3
15                         color[p[p[x]]] ← RED         ▷ Случай 3
16                         Right-Rotate(T, p[p[x]])     ▷ Случай 3
17            else (аналогичный текст с
                   заменой left ↔ right)
18  color[root[T]] ← BLACK
```

На рисунке 14.4 показан пример применения процедуры RB-Insert.

Процедура RB-Insert проще, чем кажется на первый взгляд. После выполнения строк 1–2 выполняются все RB-свойства, кроме одного: красная вершина x может иметь красного родителя. (см. рис. 14.4a). В остальном всё в порядке — другие свойства *"не замечают"* добавления красной вершины (отметим, что новая красная вершина имеет двух чёрных NIL-детей).

Такая ситуация (выполнены все RB-свойства, за исключением того, что красная вершина x может иметь красного родителя) будет сохраняться после любого числа итераций цикла. На каждом шаге вершина x поднимается вверх по дереву (если только не удалось устранить нарушения полностью; в этом случае мы выходим из цикла).

Рисунок 14.4 Работа процедуры RB-Insert. (а) Добавлена вершина x; при этом нарушилось свойство 3: x и его родитель красные. Вершина y (которую можно назвать *"дядей"* вершины x) красная, поэтому имеет место случай 1. После перекрашивания вершин получается дерево (б). Новая вершина x и её родитель красные, но дядя y чёрный. Так как x — правый ребёнок, имеет место случай 2. Производится левое вращение, которое дает дерево (в). Теперь уже x является левым ребёнком, и это — случай 3. После правого вращения получаем корректное красно-чёрное дерево (г).

Рисунок 14.5 Случай 1. Нарушено свойство 3: x и его родитель — красные. Наши действия не зависят от того, является ли x правым (а) или левым (б) сыном. Все поддеревья α, β, γ, δ и ε имеют чёрный корень и одинаковую чёрную высоту. Процедура меняет цвет вершины $p[p[x]]$ и её детей. Цикл продолжается после присваивания $x \leftarrow p[p[x]]$; свойство 3 может быть нарушено только между красной вершиной $p[p[x]]$ и её родителем (если он тоже красный).

Внутри цикла рассматриваются шесть случаев, но три из них симметричны трём другим, различия лишь в том, является ли родитель вершины x левым или правым ребёнком своего родителя. Эти случаи разделяются в строке 4. Мы выписали фрагмент процедуры для случая, когда $p[x]$ — левый ребёнок своего родителя. (Симметричные случаи относятся к строке 17.)

Мы будем предполагать, что во всех рассматриваемых нами красно-чёрных деревьях корень чёрный (и поддерживать это свойство — для этого используется строка 18). Поэтому в строке 4 красная вершина $p[x]$ не может быть корнем ($p[p[x]]$ существует).

Операции внутри цикла начинаются с нахождения вершины y, которая является *"дядей"* вершины x (имеет того же родителя, что и вершина $p[x]$). Если вершина y красная, имеет место случай 1, если чёрная — то один из случаев 2 и 3. Во всех случаях вершина $p[p[x]]$ чёрная, так как пара x–$p[x]$ была единственным нарушением RB-свойств.

Случай 1 (строки 7–10) показан на рис. 14.5. Эта часть текста исполняется, если и $p[x]$, и y красные. При этом вершина $p[p[x]]$ — чёрная. Перекрасим $p[x]$ и y в чёрный цвет, а $p[p[x]]$ — в красный. При этом число чёрных вершин на любом пути из корня к листьям останется прежним. Нарушение RB-свойства возможно в единственном месте нового дерева: у $p[p[x]]$ может быть красный родитель. Поэтому надо продолжить выполнение цикла, присвоив x значение $p[p[x]]$.

В случаях 2 и 3 вершина y чёрная. Эти два случая различаются тем, каким ребёнком x приходится своему родителю — левым или

Рисунок 14.6 Случаи 2 и 3 в процедуре RB-Insert. Как и для случая 1, нарушено свойство 3 красно-чёрных деревьев, так как вершина x и её родитель $p[x]$ — красные. Корни деревьев α, β, γ и δ — чёрные; эти деревья имеют одинаковую чёрную высоту. Оба вращения, показанные на рисунке, не меняют число чёрных вершин на пути от корня к листьям. После этого мы выходим из цикла: RB-свойства выполнены всюду.

правым. Если правым, исполняются строки 12–13 (случай 2). В этом случае выполняется левое вращение, которое сводит случай 2 к случаю 3. когда x является левым ребёнком (рис. 14.6), Так как и x, и $p[x]$ красные, после вращения количества чёрных вершин на путях остаются прежними.

Итак, осталось рассмотреть случай 3: красная вершина x является левым ребёнком красной вершины $p[x]$, которая является левым ребёнком чёрной вершины $p[p[x]]$, правым ребёнком которой является чёрная вершина y. В этом случае достаточно произвести правое вращение и перекрасить две вершины, чтобы устранить нарушение RB-свойств. Цикл больше не выполняется, так как вершина $p[x]$ теперь чёрная.

Каково время выполнения процедуры RB-Insert? Высота красно-чёрного дерева есть $O(\lg n)$, если в дереве n вершин, поэтому вызов Tree-Insert требует времени $O(\lg n)$. Цикл повторяется, только если мы встречаем случай 1, и при этом x сдвигается вверх по дереву. Таким образом, цикл повторяется $O(\lg n)$ раз, и общее время работы есть $O(\lg n)$. Интересно, что при этом выполняется не более двух вращений (после которых мы выходим из цикла).

Упражнения

14.3-1 В строке 2 процедуры RB-Insert мы красим новую вершину x в красный цвет. Если бы мы покрасили её в черный цвет, свойство 3 не было бы нарушено. Почему же мы этого не сделали?

14.3-2 В строке 18 мы красим корень дерева в чёрный цвет. Зачем это делается?

14.3-3 Нарисуйте красно-чёрные деревья, которое получаются при последовательном добавлении к пустому дереву ключей

$41, 38, 31, 12, 19, 8$.

14.3-4 Пусть чёрная высота каждого из поддеревьев $\alpha, \beta, \gamma, \delta, \varepsilon$ на рисунках 14.5 и 14.6 равна k. Найдите чёрные высоты всех вершин на этих рисунках и проверьте, что свойство 4 действительно не нарушается.

14.3-5 Рассмотрим красно-чёрное дерево, полученное добавлением n вершин к пустому дереву. Убедитесь, что при $n > 1$ в дереве есть хотя бы одна красная вершина.

14.3-6 Как эффективно реализовать процедуру RB-Insert, если в вершинах не хранятся указатели на родителей?

14.4 Удаление

Как и другие операции, удаление вершины из красно-чёрного дерева требует времени $O(\lg n)$. Удаление вершины несколько сложнее вставки.

Чтобы упростить обработку граничных условий, мы используем фиктивный элемент (по-английски называемый sentinel) вместо NIL (см. с. ??). Для красно-чёрного дерева T фиктивный элемент $nil[T]$ имеет те же поля, что и обычная вершина дерева. Его цвет чёрный, а остальным полям (p, $left$, $right$ и key) могут быть присвоены любые значения. Мы считаем, что в красно-чёрном дереве все указатели NIL заменены указателями на $nil[T]$.

Благодаря фиктивным элементам мы можем считать NIL-лист, являющийся ребёнком вершины x, обычной вершиной, родитель которой есть x. В принципе можно было бы завести по одной фиктивной вершине для каждого листа, но это было бы напрасной потерей памяти. Чтобы избежать этого, мы используем один элемент $nil[T]$, представляющий все листы. Однако, когда мы хотим работать с листом — ребёнком вершины x, надо не забыть выполнить присваивание $p[nil[T]] \leftarrow x$.

Процедура RB-Delete следует схеме процедуры Tree-Delete из раздела 13.3. Вырезав вершину, она вызывает вспомогательную процедуру RB-Delete-Fixup, которая меняет цвета и производит вращения, чтобы восстановить RB-свойства.

```
RB-Delete(T, z)
 1  if left[z] = nil[T] или right[z] = nil[T]
 2     then y ← z
 3     else y ← Tree-Successor(z)
 4  if left[y] ≠ nil[T]
 5     then x ← left[y]
 6     else x ← right[y]
 7  p[x] ← p[y]
 8  if p[y] = nil[T]
 9     then root[T] ← x
10     else if y = left[p[y]]
11             then left[p[y]] ← x
12             else right[p[y]] ← x
13  if y ≠ z
14     then key[z] ← key[y]
15          ▷ Копируем дополнительные данные из вершины y.
16  if color[y] = BLACK
17     then RB-Delete-Fixup(T, x)
18  return y
```

Есть три различия между процедурами RB-Delete и Tree-Delete. Во-первых, вместо NIL всюду стоит указатель на фиктивный элемент $nil[T]$. Во-вторых, проверка $x \neq$ NIL в строке 7 процедуры Tree-Delete удалена, и присваивание $p[x] \leftarrow p[y]$ выполняется в любом случае. Если x есть фиктивный элемент $nil[T]$, то его указатель на родителя становится равным родителю удаляемого элемента y. В-третьих, в строках 16–17 вызывается процедура RB-Delete-Fixup, если удаляемая вершина y — чёрная. При удалении красной вершины RB-свойства не нарушаются (чёрные высоты не меняются, и красные вершины не могут стать соседними). Передаваемая процедуре RB-Delete-Fixup вершина x являлась единственным ребёнком вершины y, если у y был ребёнок (не являющийся листом), или фиктивным элементом $nil[T]$, если вершина y не имела детей. В последнем случае присваивание в строке 7 гарантирует, что $p[x]$ указывает на бывшего родителя y — вне зависимости от того, является ли x настоящей вершиной или фиктивным элементом.

Посмотрим, как процедура RB-Delete-Fixup восстанавливает RB-свойства дерева.

RB-DELETE-FIXUP(T, x)

```
 1  while x ≠ root[T] и color[x] = BLACK
 2      do if x = left[p[x]]
 3           then w ← right[p[x]]
 4                if color[w] = RED
 5                  then color[w] ← BLACK                   ▷ Случай 1
 6                       color[p[x]] ← RED                  ▷ Случай 1
 7                       LEFT-ROTATE(T, p[x])               ▷ Случай 1
 8                       w ← right[p[x]]                    ▷ Случай 1
 9                if color[left[w]] = BLACK и
                         color[right[w]] = BLACK
10                  then color[w] ← RED                     ▷ Случай 2
11                       x ← p[x]                           ▷ Случай 2
12                  else if color[right[w]] = BLACK
13                         then color[left[w]] ← BLACK      ▷ Случай 3
14                              color[w] ← RED              ▷ Случай 3
15                              RIGHT-ROTATE(T, w)          ▷ Случай 3
16                              w ← right[p[x]]             ▷ Случай 3
17                       color[w] ← color[p[x]]             ▷ Случай 4
18                       color[p[x]] ← BLACK                ▷ Случай 4
19                       color[right[w]] ← BLACK            ▷ Случай 4
20                       LEFT-ROTATE(T, p[x])               ▷ Случай 4
21                       x ← root[T]                        ▷ Случай 4
22           else (симметричный фрагмент с
                  заменой left ↔ right)
23  color[x] ← BLACK
```

Если удалённая процедурой RB-DELETE вершина y была чёрной, то любой путь, через неё проходивший, теперь содержит на одну чёрную вершину меньше. Таким образом, свойство 4 нарушилось. Мы можем компенсировать это за счёт вершины x (занявшей место вершины y). Если x — красная, сделаем её чёрной (заодно мы избегаем опасности получить красную вершину с красным родителем). Если x — чёрная, объявим её *"дважды чёрной"* и будем считать за две при подсчёте числа чёрных вершин на пути от корня к листьям. Конечно, такой выход может быть лишь временным, поскольку определение красно-чёрных деревьев не предусматривает дважды чёрных вершин, и мы должны постепенно от такой вершины избавиться.

Процедура RB-DELETE-FIXUP(T, x) применяется к дереву, которое *обладает свойствами красно-чёрного дерева, если учесть дополнительную единицу черноты в вершине* x, и превращает его в настоящее красно-чёрное дерево. В цикле (строки 1–22) дерево меняется, и значение переменной x тоже меняется (выделенная вершина может сдвигаться вверх по дереву), но сформулированное свойство остаётся верным.

Цикл завершается, если (1) x указывает на красную вершину (тогда мы в строке 23 красим её в чёрный цвет) или если (2) x указывает на корень (тогда лишняя чернота может быть просто удалена из дерева). Может оказаться также, что (3) внутри тела цикла удаётся выполнить несколько вращений и перекрасить несколько вершин, после чего дважды чёрная вершина исчезнет. В этом случае присваивание $x \leftarrow root[T]$ позволяет выйти из цикла.

Внутри цикла x указывает на дважды чёрную вершину, не являющуюся корнем. В строке 2 мы определяем, каким ребёнком является x — левым или правым. (Подробно выписана часть процедуры для первого случая, второй случай симметричен и скрыт в строке 22.) Переменная w (строка 3) указывает на второго ребёнка вершины $p[x]$ (*"брата"* вершины x). Так как вершина x — дважды чёрная, w не может быть равно $nil[T]$, поскольку в этом случае вдоль одного пути от $p[x]$ вниз (через w) было бы меньше черных вершин, чем вдоль другого (через x).

Четыре возможных случая показаны на рис. 14.7. Прежде чем разбираться с ними детально, посмотрим, как проверить, что преобразования не нарушают свойство 4. Достаточно убедиться, что количество чёрных вершин от корня показанного поддерева до каждого из поддеревьев $\alpha, \beta, \ldots, \zeta$ не изменилось. Например, на рис. 14.7а, иллюстрирующем случай 1, количество чёрных вершин от корня до каждого из поддеревьев α и β равно 3 как до, так и после преобразования. (Напомним, что вершина x считается за две.) Аналогично, количество чёрных вершин от корня до γ, δ, ε и ζ, равно 2 до и после преобразования. На рис. 14.7б вершина B может быть и чёрной, и красной. Если она красная, то число чёрных вершин от корня до α (до и после преобразования) равно 2, если чёрная — то 3. Остальные случаи проверяются аналогично (упр. 14.4-5).

Итак, рассмотрим все случаи по порядку. Случай 1 (строки 5–8 процедуры RB-Delete-Fixup, рис. 14.7а) имеет место, когда вершина w, брат x, красная (в этом случае их родитель, $p[x]$, чёрный). Так как оба ребёнка вершины w чёрные, мы можем поменять цвета w и $p[x]$ и произвести левое вращение вокруг $p[x]$, не нарушая RB-свойств. Вершина x остаётся дважды чёрной, а её новый брат — чёрный, так что мы свели дело к одному из случаев 2, 3 или 4.

Если вершина w чёрная, имеет место один из случаев 2–4. Они различаются между собой цветом детей вершины w. В случае 2 (строки 10–11, рис. 14.7б) оба ребёнка вершины w чёрные. Так как вершина w тоже чёрная, мы можем снять чёрную окраску с x (лишнюю) и с w (сделав её красной), и добавить черноту родителю, $p[x]$. После этого продолжим выполнение цикла. Заметим, что если мы попали в случай 2 из случая 1, то вершина $p[x]$ — красная, поэтому цикл сразу же завершится (добавив чёрного к красной вершине, мы красим её в обычный чёрный цвет).

В случае 3 (строки 13–16, рис. 14.7в) вершина w чёрная, её левый ребёнок — красный, а правый — чёрный. Мы можем поменять цвета w и её левого ребёнка и потом применить правое вращение так, что RB-свойства будут сохранены. Новым братом вершины x теперь будет чёрная вершина с красным правым ребёнком, и мы свели случай 3 к случаю 4.

Наконец, в случае 4 (строки 17–21, рис. 17.4г) вершина w (брат вершины x) является чёрной, а её правый ребёнок — красный. Меняя некоторые цвета и производя левое вращение вокруг $p[x]$, мы можем удалить излишнюю черноту у x, не нарушая RB-свойств. Присваивание $x \leftarrow root[T]$ выводит нас из цикла.

Каково время выполнения процедуры RB-DELETE? Высота красно-чёрного дерева с n вершинами есть $O(\lg n)$, поэтому время исполнения RB-DELETE без учёта RB-DELETE-FIXUP есть $O(\lg n)$. Сколько времени требует цикл в процедуре RB-DELETE-FIXUP? Как только обнаруживается случай 1, 3 или 4, мы выходим из цикла (при этом выполняется $O(1)$ операций и самое большее три вращения). До этого возможно несколько повторений случая 2, но при каждом повторении указатель x перемещается вверх по дереву и никакие вращения не производятся, так что число таких шагов есть $O(\lg n)$. Таким образом, процедура RB-DELETE-FIXUP требует времени $O(\lg n)$, и общее время работы процедуры RB-DELETE также есть $O(\lg n)$ (отметим ещё раз, что при этом производится не более трёх вращений).

Упражнения

14.4-1 Убедитесь, что после выполнения процедуры RB-DELETE корень дерева остаётся чёрным, если он таковым был.

14.4-2 В упр. 14.3-3 построено красно-чёрное дерево, которое получается добавлением ключей $41, 38, 31, 12, 19, 8$ в пустое дерево. Нарисуйте деревья, которые получатся из него при последовательном удалении ключей $8, 12, 19, 31, 38, 41$.

14.4-3 В каких строках процедуры RB-DELETE-FIXUP мы можем читать или изменять фиктивный элемент $nil[T]$?

14.4-4 Упростите процедуру LEFT-ROTATE, используя фиктивный элемент для представления NIL и ещё один фиктивный элемент, содержащий указатель на корень дерева.

14.4-5 Для каждого из случаев на рисунке 14.7 подсчитайте количество чёрных вершин от корня поддерева на рисунке до каждого из поддеревьев $\alpha, \beta, \ldots, \zeta$ и убедитесь, что оно не меняется при преобразованиях. Используйте обозначение $count(c)$ для *"степени чер-*

Рисунок 14.7 Четыре случая, возможных в основном цикле процедуры RB-Delete-Fixup. Чёрные вершины показаны как чёрные, красные показаны тёмно-серыми. Светло-серые вершины на рисунке могут быть и красными, и чёрными. (Их цвета обозначаются c и c'.) Буквы $\alpha, \beta, \ldots, \zeta$ обозначают произвольные поддеревья. В каждом случае конфигурация слева преобразуется в конфигурацию справа перекрашиванием вершин и/или вращениями. Вершина, на которую указывает x, дважды чёрная. Единственный случай, когда выполнение цикла продолжается — случай 2. (а) Случай 1 сводится к случаю 2, 3 или 4, если поменять местами цвета вершин B и D и произвести левое вращение. (б) В случае 2 *"избыток черноты"* в вершине x перемещается вверх по дереву, когда мы делаем D красной и устанавливаем указатель x в B. Если мы попали в случай 2 из случая 1, то цикл завершается, так как вершина B была красной. (в) Случай 3 сводится к случаю 4, если поменять местами цвета вершин C и D и выполнить правое вращение. (г) В случае 4 можно перекрасить некоторые вершины и выполнить левое вращение (не нарушив RB-свойства) так, что лишний чёрный цвет исчезает, и цикл можно завершить.

ноты” вершины цвета c, считая $count(c)$ равным 0 для красной вершины и 1 для чёрной.

14.4-6 Предположим, что вершина вставлена в красно-чёрное дерево, а потом сразу же удалена. Будет ли получившееся дерево совпадать с исходным? Почему?

Задачи

14-1 Динамические множества с сохранением предыдущих версий

Иногда полезно сохранять предыдущие версии меняющегося множества. (Такие структуры данных называются по-английски persistent data structures.) Можно, конечно, копировать множество каждый раз, когда оно изменяется. Но такой подход требует много памяти и времени — и есть способы, позволяющие сделать это более эффективно.

Мы хотим предусмотреть возможность хранения предыдущих версий для множества S с операциями Insert, Delete и Search. Мы считаем, что множество S реализовано с помощью двоичных деревьев поиска, как показано на рис. 14.8а. Для каждой версии множества мы храним свой отдельный корень. Чтобы добавить ключ 5, мы создаём новую вершину с этим ключом. Эта вершина становится левым ребёнком новой вершины с ключом 7, так как существующую вершину менять нельзя. Подобным образом новая вершина с ключом 7 становится левым ребёнком новой вершины с ключом 8, правый ребёнок которой — существующая вершина с ключом 10. В свою очередь, новая вершина с ключом 8 становится правым ребёнком нового корня r' с ключом 4, левый ребёнок которого — существующая вершина с ключом 3. Таким образом, мы копируем лишь часть дерева, а в остальном используем старое, как это показано на рис. 14.8б.

Мы предполагаем, что вершины дерева содержат поля *key*, *left* и *right*, но не содержат поля p, указывающего на родителя. (См. также упр. 14.3-6.)

а Покажите, какие вершины хранимого таким образом дерева должны быть изменены (созданы) в общем случае при добавлении или удалении элемента.

б Напишите процедуру Persistent-Tree-Insert, которая добавляет ключ k в дерево T.

в Если высота дерева равна h, сколько времени и памяти требует написанная вами процедура? (Количество памяти можно измерять количеством новых вершин.)

г Пусть мы используем и поля p в вершинах дерева. В этом случае процедура Persistent-Tree-Insert должна будет выполнить

Рисунок 14.8 (а) Двоичное дерево поиска с ключами $2, 3, 4, 7, 8, 10$. (б) Дерево с сохранением предыдущих версий после добавления ключа 5. Текущая версия состоит из вершин, доступных из текущего корня r', а предыдущая версия содержит вершины, доступные из старого корня r. Тёмно-серые вершины добавлены при добавлении ключа 5.

дополнительные действия. Покажите, что в этом случае время работы и объём необходимой памяти будут $\Omega(n)$, где n — количество вершин в дереве.

д Покажите, как можно использовать красно-чёрные деревья, чтобы гарантировать, что добавление и удаление элемента для множества с хранением предыдущих версий будут требовать времени $O(\lg n)$ в худшем случае.

14-2 Операция объединения красно-чёрных деревьев

Операция **объединения** (join) применяется к двум динамическим множествам S_1 и S_2 и элементу x, причём заранее известно, что $key[x_1] \leqslant key[x] \leqslant key[x_2]$ для любых $x_1 \in S_1$ и $x_2 \in S_2$. Её результатом является множество $S = S_1 \cup \{x\} \cup S_2$. В этой задаче мы покажем, как реализовать операцию объединения для красно-чёрных деревьев.

а Мы будем хранить чёрную высоту красно-чёрного дерева T в специальной переменной $bh[T]$. Убедитесь, что это значение можно поддерживать, не размещая никакой дополнительной информации в вершинах дерева и не ухудшая асимптотику времени работы процедур RB-Insert и RB-Delete. Покажите, что, спускаясь по дереву, можно вычислить чёрную высоту каждой вершины за время $O(1)$ в расчёте на каждую просмотренную вершину.

Мы хотим реализовать операцию RB-Join(T_1, x, T_2), которая из двух деревьев T_1 и T_2 формирует новое красно-чёрное дерево $T = T_1 \cup \{x\} \cup T_2$ (старые деревья при этом разрушаются). Пусть n — общее количество вершин в T_1 и T_2.

б Считая, что $bh[T_1] \geqslant bh[T_2]$, опишите алгоритм со временем работы $O(\lg n)$, находящий среди чёрных вершин дерева T_1, имеющих чёрную высоту $bh[T_2]$, вершину y с наибольшим ключом.

в Пусть T_y — поддерево с корнем y. Покажите, как заменить T_y на $T_y \cup \{x\} \cup T_2$ за время $O(1)$ без потери свойства упорядоченности.

г В какой цвет надо покрасить x, чтобы сохранить RB-свойства 1, 2 и 4? Объясните, как восстановить свойство 3 за время $O(\lg n)$.

д Убедитесь, что время выполнения процедуры RB-JOIN есть $O(\lg n)$.

Замечания

Идея балансировки двоичных деревьев поиска принадлежит Г. М. Адельсону-Вельскому и Е. М. Ландису [2], предложившим в 1962 году класс сбалансированных деревьев, называемых теперь АВЛ-деревьями. Баланс поддерживается с помощью вращений; для его восстановления после добавления или удаления вершины может потребоваться $\Theta(\lg n)$ вращений (для дерева с n вершинами). Ещё один класс деревьев поиска, называемых 2-3-деревьями, был предложен Хопкрофтом (J. E. Hopcroft, не опубликовано) в 1970 году. Здесь баланс поддерживается за счёт изменения степеней вершин. Обобщение 2-3-деревьев, называемое Б-деревьями, предложили Байер и МакКрейт [18]; Б-деревья обсуждаются в главе 19.

Красно-чёрные деревья предложил Байер [17], назвав их *"симметричными двоичными Б-деревьями"*. Гибас и Седжвик [93] подробно изучили их свойства и предложили использовать для наглядности красный и чёрный цвета.

Из многих других вариаций на тему сбалансированных деревьев наиболее любопытны, видимо, *"расширяющиеся деревья"* (splay trees), которые придумали Слеатор и Тарьян [177]. Эти деревья являются *" саморегулирующимися"*. (Хорошее описание расширяющихся деревьев дал Тарьян [188].) Расширяющиеся деревья поддерживают баланс без использования дополнительных полей (типа цвета). Вместо этого *"расширяющие операции"* (splay operations), включающие вращения, выполняются при каждом обращении к дереву. Учётная стоимость (amortized cost, гл. 18) в расчёте на одну операцию с деревом для расширяющихся деревьев составляет $O(\lg n)$.

15 Пополнение структур данных

Далеко не во всех ситуациях можно обойтись лишь классическими структурами данных (двоичными деревьями поиска, двусторонне связанными списками, хеш-таблицами и т. п.) Однако редко требуется придумать что-то совсем новое: в большинстве случаев достаточно расширить какую-либо из классических структур данных, храня вместе с её объектами дополнительную информацию. Эффективное обновление этой информации при выполнении операций иногда требует немалой изобретательности.

В качестве примера в этом разделе рассматриваются красно-чёрные деревья. Храня в вершинах дополнительную информацию, мы сможем быстро находить i-й по порядку элемент, а также выполнять обратное действие: находить порядковый номер данного элемента множества (разд. 15.1). В разделе 15.2 обсуждается общая схема работы с дополнительной информацией и доказывается теорема, которая облегчает пополнение для красно-чёрных деревьев. В разделе 15.3 эта же теорема используется для построения структуры данных, хранящей динамическое множество промежутков (на числовой прямой) и позволяющей быстро находить элемент множества, перекрывающийся с заданным промежутком.

15.1 Динамические порядковые статистики

Порядковые статистики уже обсуждались в главе 10, где мы искали i-й по порядку элемент множества из n элементов, что требовало $O(n)$ операций (если множество предварительно не упорядочено). В данном разделе мы покажем, как с помощью пополненных красно-чёрных деревьев найти i-й элемент за $O(\log n)$ операций. Кроме того, за то же время можно будет найти порядковый номер заданного элемента.

Подходящая структура данных показана на рис. 15.1. **Порядковым деревом** (order-statistic tree) мы называем красно-чёрное дерево T, каждая вершина x которого, помимо обычных полей $key[x]$, $color[x]$, $p[x]$, $left[x]$ и $right[x]$ имеет поле $size[x]$. В нём хранится размер (количество вершин, не считая NIL-листьев) поддерева с корнем в x (считая и саму вершину x). Считая, что в поле $size$[NIL] записан 0, можно написать такое соотношение:

$$size[x] = size[left[x]] + size[right[x]] + 1.$$

(При реализации можно использовать фиктивный элемент $nil[T]$, как в разделе 14.4, а можно каждый раз проверять, не равен ли указатель значению NIL, и подставлять 0 вместо значения поля $size$.)

Поиск i-го по величине элемента

Мы должны уметь обновлять дополнительную информацию (поля $size$) при добавлении и удалении элементов. Но сначала объясним, как ею пользоваться. Начнём с поиска i-го элемента. Рекурсивная процедура OS-Select(x, i) возвращает указатель на i-й элемент поддерева с корнем x. Найти i-й элемент во всём дереве T можно с помощью вызова OS-Select$(root[T], i)$.

```
OS-Select(x, i)
1  r ← size[left[x]]+1
2  if i = r
3     then return x
4  elseif i < r
5     then return OS-Select(left[x], i)
6  else return OS-Select(right[x], i − r)
```

Этот алгоритм использует ту же идею, что и алгоритмы поиска главы 10. В поддереве с корнем x сначала идут $size[left[x]]$ вершин левого поддерева, меньших x, затем сама вершина x (которая является $(size[left[x]] + 1)$-й по счёту), и затем вершины правого поддерева x.

Процедура начинает с вычисления порядкового номера r вершины x (строка 1). Если $i = r$ (строка 2), то x и есть i-й элемент, и мы возвращаем его (строка 3). Если $i < r$, то искомый элемент находится в левом поддереве вершины x, и программа рекурсивно вызывает себя (строка 5). Если же $i > r$, то искомый элемент находится в правом поддереве вершины x, но его порядковый номер внутри этого поддерева будет уже не i, а $i - r$. Этот элемент выдаётся при рекурсивном вызове в строке 6.

Покажем, как процедура OS-Select ищет 17-й элемент дерева, изображённого на рис. 15.1. Мы начинаем с корня (с ключом 26), при этом $i = 17$. Размер левого поддерева корня равен 12, поэтому порядковый номер корня равен 13, и искомая вершина находится в правом поддереве, имея там порядковый номер $17 - 13 = 4$. Ищем 4-й элемент поддерева с корнем 41. Левое поддерево вершины 41 имеет размер 5, т. е. порядковый номер вершины 41 равен 6. Ищем

Рисунок 15.1 Порядковое дерево. Красные вершины изображены как светло-серые, чёрные — как тёмные. Помимо обычных полей красно-чёрного дерева, у каждой вершины x есть поле $size[x]$, где хранится размер поддерева с корнем в x.

4-й элемент поддерева с корнем 30. В этом дереве корень имеет порядковый номер 2, поэтому ищем $(4 - 2) = 2$-й элемент правого поддерева. В этом дереве корень 38 оказался вторым по порядку (размер левого поддерева равен 1), поэтому мы возвращаем указатель на вершину 38.

При каждом рекурсивном вызове процедуры мы спускаемся по дереву на один уровень, поэтому время работы в худшем случае пропорционально высоте. Высота красно-чёрного дерева с n вершинами равна $O(\log n)$, так что время работы процедуры OS-Select на n-элементном множестве есть $O(\log n)$.

Определение порядкового номера элемента

Процедура OS-Rank получает указатель на элемент x порядкового дерева T и находит порядковый номер (rank) элемента в дереве.

```
OS-Rank(T, x)
1  r ← size[left[x]] + 1
2  y ← x
3  while y ≠ root[T]
4       do if y = right[p[y]]
5             then r ← r + size[left[p[y]]] + 1
6           y ← p[y]
7  return r
```

Порядковый номер элемента x на единицу больше количества элементов, меньших x. Цикл в строках 3–6 имеет такой инвариант: r есть порядковый номер вершины x в поддереве с корнем y. Перед первым выполнением цикла это так: r есть порядковый номер x в дереве с корнем в x (строка 1), а $y = x$ (строка 2). Как надо изменить r при переходе от вершины y к её родителю $p[y]$? Если y — левый ребёнок вершины $p[y]$, то вершина x имеет один и тот же порядковый номер в поддеревьях с корнями в y и $p[y]$. Если же y — правый ребёнок, при переходе от y к $p[y]$ к порядковому номеру вершины x прибавится $size[left[p[y]]]$ элементов левого поддерева и сама вершина $p[y]$. В строке 5 мы учли эту добавку.

При выходе из цикла $y = root[T]$, а r — порядковый номер x во всём дереве.

Для примера посмотрим, как эта процедура определит порядковый номер вершины с ключом 38 в дереве, изображённом на рис. 15.1. В таблице показан ключ вершины y и число r в начале каждого цикла.

Шаг	$key[x]$	r
1	38	2
2	30	4
3	41	4
4	26	17

Возвращается значение 17.

С каждым шагом глубина вершины y уменьшается на единицу, и каждый шаг требует времени $O(1)$, поэтому время работы процедуры OS-Rank на n-элементном множестве есть $O(\log n)$.

Обновление информации о размерах поддеревьев

С помощью полей *size* мы научились быстро вычислять порядковый номер элемента, а также находить i-й элемент дерева. Теперь надо понять, как обновлять это поле при добавлении и удалении элемента из красно-чёрного дерева. Оказывается, это можно сделать, не ухудшив асимптотическую оценку времени работы процедур добавления и удаления элемента.

Как мы видели в разделе 14.3, добавление элемента в красно-чёрное дерево состоит из двух частей: сначала мы добавляем новую вершину, делая её ребёнком уже существующей, а затем производим некоторые вращения и перекрашивания (если это необходимо)

На первом этапе мы для каждой пройденной вершины x (на пути от корня до места добавления вершины) увеличим на единицу значение $size[x]$. В поле *size* добавленной вершины запишем число 1. При этом мы проходим путь длиной $O(\log n)$ и дополнительно тратим время $O(\log n)$, после чего все поля *size* правильны.

При вращении изменяются размеры только двух поддеревьев: их вершинами являются концы ребра, вокруг которого происходило вращение. Поэтому к тексту процедуры Left-Rotate(T, x) (раздел 14.2) достаточно добавить строки

```
13  size[y] ← size[x]
14  size[x] ← size[left[x]] + size[right[x]] + 1
```

Рисунок 15.2 Обновление поля *size* при вращениях вокруг ребра (x, y). Это поле необходимо обновить только у вершин x и y. Для того, чтобы узнать новое значение, достаточно обладать информацией, хранящейся в x, y и в корнях поддеревьев, изображенных в виде треугольников.

На рис. 15.2 показано, как меняется поле *size*. Аналогичные изменения внесём и в процедуру Right-Rotate.

Так как при добавлении элемента в красно-чёрное дерево выполняется не больше двух вращений, то коррекция поля *size* после вращений требует $O(1)$ операций (а перекрашивание вообще не влияет на размеры). Таким образом, добавление элемента в порядковое дерево из n вершин требует времени $O(\log n)$, как и для обычного красно-чёрного дерева.

Удаление элемента из красно-чёрного дерева также состоит из двух частей — сначала мы удаляем вершину y, а затем делаем (самое большее) три вращения (см. разд. 14.4). После выполнения первой части, мы уменьшим на единицу поля *size* у всех вершин на пути из y к корню. Длина этого пути $O(\log n)$, поэтому дополнительно нам потребуется время $O(\log n)$. Что происходит с вращениями, мы уже видели. Таким образом, обновление поля *size*, не ухудшает (асимптотически) время, необходимое для удаления и добавления элемента.

Упражнения

15.1-1 Пусть T — дерево на рис. 15.1. Покажите, как работает процедура OS-Select$(T, 10)$.

15.1-2 Пусть T — дерево на рис. 15.1. Покажите, как работает процедура OS-Rank(T, x), где x — вершина с ключом 35.

15.1-3 Перепишите процедуру OS-Select, не используя рекурсии.

15.1-4 Реализуйте рекурсивную процедуру OS-Key-Rank(T, k), которая получает на входе порядковое дерево T с попарно различными ключами, а также ключ k, и возвращает порядковый номер ключа k в этом дереве.

15.1-5 Дана вершина x порядкового дерева из n вершин и натуральное число i. Как найти i-й по порядку элемент, считая от вершины x, за время $O(\log n)$?

15.1-6 Заметим, что процедуры OS-Select и OS-Rank используют поле *size* только для того, чтобы узнать порядковый номер вершины x в поддереве с корнем x. Предположим, что мы храним в вершине вместо поля *size* этот порядковый номер. Как обновлять эту информацию при добавлении и удалении элемента? (Напомним, что добавление и удаление сопровождаются вращениями.)

15.1-7 Как, используя порядковые деревья, посчитать число инверсий (см. задачу 1-3) в массиве размера n за время $O(n \log n)$?

15.1-8* Рассмотрим n хорд окружности, заданных своими концами (считаем, что все $2n$ концевых точек различны). Придумайте алгоритм, который за время $O(n \lg n)$ определяет, сколько пар хорд пересекаются внутри круга. (Например, если все хорды — диаметры, то ответом будет C_n^2.)

15.2 Общая схема работы с дополнительной информацией

Ситуация, когда требуется пополнить какую-либо стандартную структуру данных дополнительной информацией, довольно типична. Мы встретимся с ней снова в следующем разделе. А в этом разделе мы докажем общую теорему, облегчающую этот процесс в случае красно-чёрных деревьев.

Пополнение структуры данных делится на четыре шага:

1. выбираем базовую структуру данных;
2. решаем, какую дополнительную информацию мы будем хранить (и обновлять);
3. проверяем, что эту информацию удаётся обновлять при выполнении операций, допустимых для выбранной структуры данных;
4. реализуем новые операции.

Конечно, эти правила — всего лишь общая схема, и в конкретной ситуации надо проявлять разумную гибкость, но схема эта может быть полезной.

Давайте посмотрим на конструкции раздела 15.1 с точки зрения этих правил.

На шаге 1 мы выбрали красно-чёрные деревья в качестве базовой структуры.

На шаге 2 мы решили добавить к каждой вершине поле *size*. Смысл хранения дополнительной информации состоит в том, что она позволяет выполнять некоторые операции быстрее. Без поля *size* мы не смогли бы выполнить операции OS-Select и OS-Rank за время $O(\log n)$. (Несколько иной вариант выбора дополнительной информации дан в упр. 15.2-1.)

На шаге 3 мы убедились, что обновление полей *size* при добавлении и удалении элементов можно выполнить без ухудшения асимптотики для времени добавления и удаления. В этом смысле наш выбор удачен: если бы, скажем, мы решили хранить для каждой вершины её порядковый номер, то процедуры OS-Select и OS-Rank работали бы быстро, но добавление нового элемента повлекло бы за собой изменение дополнительной информации во многих вершинах дерева (во всех, если добавленный элемент минимален). Наш выбор (поле *size*) даёт удачный компромисс между лёгкостью использования и обновления.

На шаге 4 мы реализовали процедуры OS-Select и OS-Rank, из-за которых мы, собственно, и затевали всё это дело.

Впрочем, в других ситуациях (упр. 15.2-1) дополнительная информация используется не для реализации новых операций, а для ускорения уже имеющихся.

Дополнительная информация для красно-чёрных деревьев

Следующая теорема показывает, что для красно-чёрных деревьев информацию определённого вида можно обновлять, не замедляя (асимптотически) операции добавления и удаления. Её доказательство во многом повторяет рассуждения из раздела 15.1.

Теорема 15.1 (Пополнение красно-чёрного дерева). *Рассмотрим дополнительный атрибут f, определённый для вершин красно-чёрных деревьев. Предположим, что для всякой вершины x значение $f[x]$ полностью задаётся остальной информацией, хранящейся в вершинах x, $left[x]$ и $right[x]$ (в том числе значениями $f[left[x]]$ и $f[right[x]]$), и его вычисление по этим данным требует времени $O(1)$. Тогда поля f можно обновлять при добавлении и удалении элемента из дерева, не ухудшая (асимптотически) время выполнения добавления и удаления.*

Доказательство. Идея доказательства состоит в том, что изменение поля f в некоторой вершине x повлечёт за собой изменения поля f только в вершинах, расположенных на пути из корня в x. В самом деле, изменение $f[x]$ повлечёт за собой изменение $f[p[x]]$, что в свою очередь изменит $f[p[p[x]]]$ и т.д., но другие вершины останутся нетронутыми. От $f[root[T]]$ не зависит значение поля f в других вершинах, и процесс изменений остановится. Так как высота дерева равна $O(\log n)$, то после изменения поля $f[x]$ для какой-то одной вершины x мы сможем обновить все необходимые поля за время $O(\log n)$.

Добавление элемента x в дерево T делается в два этапа (см. разд. 14.3). На первом этапе вершину x добавляют в качестве ребёнка уже существующей вершины $p[x]$. Значение $f[x]$ вычисляется за время $O(1)$, так как новая вершина — лист (точнее, её дети — NIL-листья). Далее происходит $O(\lg n)$ изменений полей на пути к корню. Итак, первый этап занимает время $O(\log n)$. На втором этапе мы выполняем вращения (самое большее два); после каждого потребуется $O(\lg n)$ операций для распространения изменений вверх по дереву.

Удаление также проводится в два этапа (см. разд. 14.4). На первом этапе изменения возникают, если удаляемая вершина заменяется её последователем, а также когда мы выбрасываем удаляемую вершину или её последователя. И в том и в другом случае мы изменяем поле f у одной вершины, поэтому обновление всех полей займет время $O(\log n)$. На втором этапе мы делаем самое большее три вращения, каждое из которых требует времени $O(\log n)$ для обновления полей на пути к корню. □

Во многих случаях (в частности, для поля *size*) при вращениях все поля можно обновить за время $O(1)$, а не $O(\log n)$. Такая ситуация возникает в упр. 15.2-4.

Упражнения

15.2-1 Пополнить порядковое дерево (не ухудшив асимптотически время операций) так, чтобы минимальный и максимальный элементы, а также предшественник и последователь данного элемента отыскивались бы за время $O(1)$.

15.2-2 Будем хранить в каждой вершине красно-чёрного дерева её чёрную высоту. Возможно ли обновлять это поле при добавлении и удалении элемента из дерева, не ухудшив (асимптотически) время работы этих операций?

15.2-3 Будем хранить в вершине её глубину. Возможно ли обновлять это поле при добавлении и удалении элемента из дерева, не ухудшив (асимптотически) время работы этих операций?

15.2-4* Пусть $\otimes$ — ассоциативная бинарная операция на некотором множестве M, и пусть в каждой вершине красно-чёрного дерева хранится некоторый элемент a множества M (свой в каждой вершине). Пусть теперь мы хотим хранить в каждой вершине x поле $f[x] = a[x_1] \otimes a[x_2] \otimes \ldots \otimes a[x_m]$, где $x_1, x_2, \ldots, x_m$ — все вершины поддерева с корнем x (в порядке возрастания ключей). Показать, что поле f при вращениях можно обновлять за время $O(1)$. Провести аналогичное рассуждение для поля *size*.

15.2-5* Мы хотим реализовать для красно-чёрных деревьев операцию RB-ENUMERATE(x, a, b), которая выдаёт список всех вершин в поддереве с корнем x, для которых ключ k находится в промежутке $a \leqslant k \leqslant b$. Как сделать это за время $\Theta(m + \log n)$, где n — количество вершин в дереве, а m — число выдаваемых ключей? (Указание. Достаточно полей, имеющихся в красно-чёрных деревьях; новые поля не нужны.)

15.3 Деревья промежутков

В этом разделе мы используем красно-чёрные деревья для хранения меняющегося множества промежутков. **Отрезком** (closed interval) $[t_1, t_2]$ называется множество вещественных чисел t, для которых $t_1 \leqslant t \leqslant t_2$. (Предполагается, что $t_1 \leqslant t_2$.) **Полуинтервал** (half-open interval) и **интервал** (open interval) получаются из отрезка выкидыванием одного или двух концов соответственно. В этом разделе мы имеем дело только с отрезками, но все результаты легко распространяются на интервалы и полуинтервалы.

Представим себе базу данных, в которой хранится информация о протяжённых по времени событиях: для каждого события хранится промежуток времени, которое оно занимает. Рассматриваемая в этом разделе структура данных позволяет по любому промежутку найти все события, которые пересекаются с этим промежутком, причём делает это достаточно быстро.

Мы считаем, что отрезок $[t_1, t_2]$ представляет собой запись i, состоящую из двух полей: $low[i] = t_1$ (**левый конец** (low endpoint)) и $high[i] = t_2$ (**правый конец** (high endpoint)). Будем говорить, что отрезки i и i' **перекрываются** (overlap), если $low[i] \leqslant high[i']$ и $low[i'] \leqslant high[i]$; иными словами, если $i \cap i' \neq \emptyset$. (Обратите внимание, что отрезки, имеющие общий конец, считаются перекрывающимися.)

Всего возможно три варианта взаимного расположения отрезков i и i' (рис. 15.3):

1. отрезки i и i' перекрываются,
2. $high[i] < low[i']$,
3. $high[i'] < low[i]$.

Деревом промежутков (interval tree) назовём красно-чёрное дерево, каждая вершина x которого хранит отрезок $int[x]$. Дерево промежутков позволяет реализовать следующие операции:

Interval-Insert(T, x) добавляет к дереву T элемент x (содержащий некоторый отрезок $int[x]$);

Interval-Delete(T, x) удаляет из дерева T элемент x;

Interval-Search(T, i) возвращает указатель на элемент x дерева T, для которого отрезки i и $int[x]$ перекрываются (и возвращает nil, если такого элемента в дереве нет).

Пример дерева промежутков показан на рис.15.4. Следуя схеме раздела 15.2, мы реализуем такую структуру данных и операции на

Рисунок 15.3 Три варианта взаимного расположения отрезков i и i'. (а) Отрезки i и i' перекрываются. Возможно четыре варианта; во всех четырёх $low[i] \leqslant high[i']$ и $low[i'] \leqslant high[i]$. (б) $high[i] < low[i']$. (в) $high[i'] < low[i]$.

ней.

Шаг 1: Базовая структура данных

Мы уже выбрали базовую структуру: красно-чёрное дерево, каждая вершина x которого содержит отрезок $int[x]$. Ключом вершины является левый конец отрезка $low[int[x]]$; обход дерева в порядке *"левое поддерево — корень — правое поддерево"* перечисляет вершины в порядке возрастания ключей.

Шаг 2: Дополнительная информация

Каждая вершина, помимо отрезка, содержит поле $max[x]$, в котором хранится максимальный из правых концов отрезков, содержащихся в поддереве с корнем x.

Шаг 3: Обновление дополнительной информации

Проверим, что дополнительную информацию можно обновлять при добавлении и удалении элемента без (асимптотического) ухудшения времени работы этих операций. В самом деле,

$$max[x] = \max(high[int[x]], max[left[x]], max[right[x]]),$$

и остаётся лишь сослаться на теорему 15.1. Можно отметить также, что при вращениях поле max можно обновлять за время $O(1)$ (упр. 15.2-4 и 15.3-1).

Шаг 4: Новые операции

Процедура Interval-Search(T, i) находит в дереве T отрезок, перекрывающийся с i. Если такого отрезка нет, она возвращает

Рисунок 15.4 Дерево промежутков. (а) Набор из 10 отрезков (выше тот, у которого левый конец больше). (б) Дерево промежутков, хранящее эти отрезки. При этом свойство упорядоченности дерева выполняется для левых концов.

значение NIL.

```
Interval-Search(T, i)
x ← root[T]
while x ≠ NIL и int[x] не перекрывается с i
     do if left[x] ≠ NIL и max[left[x]] ⩾ low[i]
           then x ← left[x]
           else  x ← right[x]
return x
```

Мы ищем отрезок, проходя дерево от корня к листу. Процедура останавливается, если отрезок найден или если значение переменной x стало равным NIL. Каждая итерация цикла требует $O(1)$ шагов, поэтому время работы процедуры пропорционально высоте дерева (и равно $O(\log n)$ для дерева из n вершин).

Для примера посмотрим, как процедура ищет в дереве на рис. 15.4 отрезок, перекрывающийся с отрезком $i = [22, 25]$. Мы начинаем с корня ($x = root[T]$), который хранит отрезок $[16, 21]$, не перекрывающийся с i. Так как $max[left[x]] = 23$, что больше, чем

$low[i] = 22$, то мы переходим к левому ребёнку корня ($x \leftarrow left[x]$). Этот ребёнок хранит отрезок $[8, 9]$, также не перекрывающийся с i. На этот раз $max[left[x]] = 10$ меньше $low[i] = 22$, поэтому мы переходим к правому ребёнку вершины x. Там находится отрезок $[15, 23]$, перекрывающийся с i, и поиск завершается.

Рассмотрим пример безрезультатного поиска в том же дереве — будем искать отрезок, перекрывающийся с $i = [11, 14]$. Снова начинаем с корня. Корень хранит отрезок $[16, 21]$, не перекрывающийся с i. Так как $max[left[x]] = 23$ больше $low[i] = 11$, переходим к левому ребёнку. Теперь в x хранится отрезок $[8, 9]$. Он не перекрывается с i, и $max[left[x]] = 10$ меньше $low[i] = 11$, поэтому идём направо. (Слева искомого отрезка быть не может). В x теперь хранится $[15, 23]$, с i этот отрезок не перекрывается, $left[x] =$ NIL, поэтому идём направо и возвращаем значение NIL.

Корректность процедуры Interval-Search устанавливает теорема 15.2, которая утверждает, что если отрезки $int[x]$ и i не перекрываются, то дальнейший поиск идёт в правильном направлении (если нужные отрезки вообще есть в дереве, то они есть и в выбираемой части дерева). Поэтому нам достаточно просмотреть всего один путь. (Обратите внимание, что слова *"правильное направление"* не означают, что в другом направлении искомых отрезков нет: мы утверждаем лишь, что если они есть вообще, то есть и в *"правильном"* направлении!)

Теорема 15.2. *Пусть x — произвольная вершина дерева, i — отрезок, не перекрывающийся с $int[x]$, и мы выполняем строки 3–5 процедуры* Interval-Search(T, i). *Тогда:*

1. *Если выполняется строка 4, то либо поддерево с корнем $left[x]$ (левое поддерево) содержит отрезок, перекрывающийся с i, либо поддерево с корнем $right[x]$ (правое поддерево) не содержит отрезка, перекрывающегося с i.*
2. *Если выполняется строка 5, то левое поддерево не содержит отрезка, перекрывающегося с i.*

Доказательство. Начнём с более простого случая 2. Строка 5 выполняется, если не выполнено условие в строке 3, то есть если $left[x] =$ NIL или $max[left[x]] < low[i]$. В первом случае левое поддерево пусто, поэтому не содержит отрезка, перекрывающегося с i. Предположим, что $left[x] \neq$ NIL и $max[left[x]] < low[i]$. Рассмотрим произвольный отрезок i' из левого поддерева (см. рис. 15.5а). Так как $max[left[x]]$ — наибольший правый конец таких отрезков, то

$$high[i'] \leqslant max[left[i]] < low[i],$$

поэтому отрезок i' целиком лежит левее отрезка i. Случай 2 рассмотрен.

Рисунок 15.5 Отрезки в доказательстве теоремы 15.2. Пунктиром показано значение $max[left[x]]$. (а) Случай 2: мы идем направо. Никакой интервал i' не перекрывается с i. (б) Случай 1: мы идем налево. Выберем в левом поддереве отрезок i', для которого $high[i'] = max[left[x]] \geqslant low[i]$. Тогда либо i' перекрывается с i, либо i' лежит целиком справа от i, и i не перекрывается ни с каким отрезком i'' из правого поддерева, потому что $low[i'] \leqslant low[i'']$.

Рассмотрим теперь случай 1. Предположим, что в левом поддереве нет отрезков, перекрывающихся с i. Тогда нужно доказать, что таких отрезков нет и в правом. Так как выполняется строка 4, то условие в строке 3 выполнено, и $max[left[x]] \geqslant low[i]$. Поэтому в левом поддереве найдётся отрезок i', для которого

$$high[i'] = max[left[i']] \geqslant low[i]$$

(см. рис. 15.5б). Но отрезки i и i' не перекрываются (по предположению — мы считаем, что в левом поддереве нет отрезков, перекрывающихся с i). Это означает, что отрезок i' лежит целиком справа от i (целиком слева он лежать не может), то есть $high[i] < low[i']$. В дереве T выполнено свойство упорядоченности левых концов, поэтому и все отрезки правого поддерева лежат целиком справа от i: для произвольного отрезка i'' из правого поддерева выполнено

$$high[i] < low[i'] \leqslant low[i''].$$

$\square$

Упражнения

15.3-1 Напишите процедуру Left-Rotate для дерева промежутков, которая обновляет поля max за время $O(1)$.

15.3-2 Перепишите процедуру Interval-Search для случая, когда в дереве промежутков хранятся не отрезки, а интервалы (то есть нас интересуют перекрытия ненулевой длины).

15.3-3 Постройте алгоритм, который по заданному отрезку возвращает перекрывающийся с ним отрезок с минимальным левым концом (или константу nil, если таких отрезков нет).

15.3-4 Напишите программу, которая по заданному отрезку i и дереву промежутков T возвращает список всех отрезков дерева T, перекрывающихся с i. Время работы должно быть $O(\min(n, k \log n))$, где k — число элементов возвращаемого списка. (Дополнительный вопрос: как сделать это, не меняя дерева?)

15.3-5 Какие надо внести изменения в определение дерева промежутков, чтобы дополнительно реализовать процедуру INTERVAL-SEARCH-EXACTLY(T, i), которая либо возвращает вершину x дерева T, для которой $low[int[x]] = low[i]$ и $high[int[x]] = high[i]$, либо выдаёт константу NIL, если таких вершин нет (ищет отрезок, равный i, а не просто перекрывающийся с i.) Время работы процедуры INTERVAL-SEARCH-EXACTLY, а также всех прежних процедур промежутков должно оставаться равным $O(\log n)$.

15.3-6 Рассмотрим множество Q натуральных чисел. Определим MIN-GAP как расстояние между двумя ближайшими числами в Q. Например, если $Q = \{1, 5, 9, 15, 18, 22\}$, то MIN-GAP$(Q)$ равно $18 - 15 = 3$. Реализуйте структуру данных, эффективно реализующую добавление, удаление и поиск элемента, а также операцию MIN-GAP. Каково время работы этих операций?

15.3-7* При разработке интегральных схем информация часто представляется в виде списка прямоугольников. Пусть даны n прямоугольников со сторонами, параллельными осям координат. Каждый прямоугольник задаётся четырьмя числами: координатами левого нижнего и правого верхнего углов. Написать программу, которая за время $O(n \log n)$ выясняет, есть ли среди этих прямоугольников два перекрывающихся (но не требуется найти все перекрывающиеся прямоугольники). Обратите внимание, что границы перекрывающихся прямоугольников могут не пересекаться, если один лежит внутри другого. (Указание. Двигаем горизонтальную прямую снизу вверх и смотрим, как меняется её пересечение с прямоугольниками.)

Задачи

15-1 Точка максимальной кратности

Мы хотим следить за **точкой максимальной кратности** (point of maximum overlap) множества промежутков — точкой, которая принадлежит максимальному числу промежутков из этого множества. Как нам обновлять информацию об этой точке при добавлении и удалении элемента?

15-2 Детская считалка

Задача о детской считалке (Josephus problem) состоит в следующем. Фиксируем два числа m и n ($m \leqslant n$). Вначале n детей стоят по кругу. Начав с кого-то, мы считаем *"первый, второй, третий..."*Как только доходим до m-го, он выходит из круга, и счёт продолжается дальше по кругу уже без него (начиная с единицы). Так продолжается, пока не останется ровно один человек. Нас будет интересовать зависящая от n и m последовательность ((n, m)-Josephus permutation), в которой дети выходят из круга. Например, при $n = 7$ и $m = 3$ искомая последовательность выглядит так: $\langle 3, 6, 2, 7, 5, 1, 4 \rangle$.

а Зафиксируем m. Напишите программу, которая по данному n даёт эту последовательность за время $O(n)$.

б Напишите программу, которая по произвольным n и m даёт искомую последовательность за время $O(n \log n)$.

Замечания

Описания некоторых видов деревьев промежутков можно найти в Препарата и Шамос [160]. Наибольший теоретический интерес представляет здесь результат, к которому независимо пришли Эдельсбруннер (H. Edelsbrunner, 1980) и МакКрейт (E. M. McCreight, 1981). Разработанная ими структура данных хранит n отрезков и позволяет перечислить те из них, которые перекрываются с заданным отрезком, за время $O(k + \log n)$, где k — количество таких отрезков.

IV Методы построения и анализа алгоритмов

Введение

Эта часть посвящена трём важным методам построения и анализа эффективных алгоритмов: динамическому программированию (глава 16), жадным алгоритмам (глава 17) и амортизационному анализу (глава 18). Эти методы, возможно, чуть сложнее разобранных ранее (*"разделяй и властвуй"*, использование случайных чисел, решение рекуррентных соотношений), но не менее важны.

Динамическое программирование обычно применяется к задачам, в которых искомый ответ состоит из частей, каждая из которых в свою очередь даёт оптимальное решение некоторой подзадачи. Динамическое программирование полезно, если на разных путях многократно встречаются одни и те же подзадачи; основной технический приём — запоминать решения встречающихся подзадач на случай, если та же подзадача встретится вновь.

Жадные алгоритмы, как и динамическое программирование, применяются в тех случаях, когда искомый объект строится по частям. Жадный алгоритм делает на каждом шаге *"локально оптимальный"* выбор. Простой пример: стараясь набрать данную сумму денег минимальным числом монет, можно последовательно брать монеты наибольшего возможного достоинства (не превосходящего той суммы, которую осталось набрать).

Жадный алгоритм обычно работает гораздо быстрее, чем алгоритм, основанный на динамическом программировании. Однако жадный алгоритм вовсе не всегда даёт оптимальное решение. Во многих задачах применимость жадных алгоритмов удаётся доказать с помощью так называемых матроидов, о которых рассказано в главе 17.

Амортизационный анализ — это средство анализа алгоритмов, производящих последовательность однотипных операций. Вместо того, чтобы оценивать время работы для каждой из этих операций по отдельности, амортизационный анализ оценивает среднее время работы в расчёте на одну операцию. Разница может оказаться существенной, если долго выполняемые операции не могут идти подряд. На самом деле амортизационный анализ — не только средство анализа алгоритмов, но еще и подход к разработке алгоритмов: ведь разработка алгоритма и анализ скорости его работы тесно связаны. В главе 18 мы рассказываем о трёх методах амортизационного анализа алгоритмов.

16 Динамическое программирование

Подобно методу *"разделяй и властвуй"*, динамическое программирование решает задачу, разбивая её на подзадачи и объединяя их решения. Как мы видели в главе 1, алгоритмы типа *"разделяй и властвуй"* делят задачу на независимые подзадачи, эти подзадачи — на более мелкие подзадачи и так далее, а затем собирают решение основной задачи *"снизу вверх"*. Динамическое программирование применимо тогда, когда подзадачи не являются независимыми, иными словами, когда у подзадач есть общие *"подподзадачи"*. В этом случае алгоритм типа *"разделяй и властвуй"* будет делать лишнюю работу, решая одни и те же подподзадачи по нескольку раз. Алгоритм, основанный на динамическом программировании, решает каждую из подзадач единожды и запоминает ответы в специальной таблице. Это позволяет не вычислять заново ответ к уже встречавшейся подзадаче.

В типичном случае динамическое программирование применяется к **задачам оптимизации** (optimization problems). У такой задачи может быть много возможных решений; их *"качество"* определяется значением какого-то параметра, и требуется выбрать оптимальное решение, при котором значение параметра будет минимальным или максимальным (в зависимости от постановки задачи). Вообще говоря, оптимум может достигаться для нескольких разных решений.

Как строится алгоритм, основанный на динамическом программировании? Надо:

1. описать структуру оптимальных решений,
2. выписать рекуррентное соотношение, связывающее оптимальные значения параметра для подзадач,
3. двигаясь снизу вверх, вычислить оптимальное значение параметра,
4. пользуясь полученной информацией, построить оптимальное решение.

Основную часть работы составляют шаги 1–3. Если нас интересует только оптимальное значение параметра, шаг 4 не нужен. Если же шаг 4 необходим, для построения оптимального решения иногда приходится получать и хранить дополнительную информацию в процессе выполнения шага 3.

В этой главе мы решим несколько оптимизационных задач с помощью динамического программирования. В разделе 16.1 мы выясним, как найти произведение нескольких матриц, сделав как можно меньше умножений. В разделе 16.2 мы обсудим, какие свойства задачи делают возможным применение динамического программирования. После этого мы расскажем (в разделе 16.3), как найти наибольшую общую подпоследовательность двух последовательностей. Наконец, в разделе 16.4 мы воспользуемся динамическим программированием для нахождения оптимальной триангуляции выпуклого многоугольника. (Удивительным образом эта задача оказывается похожей на задачу о перемножении нескольких матриц.)

16.1 Перемножение нескольких матриц

Мы хотим найти произведение

$$A_1 A_2 \ldots A_n \tag{16.1}$$

последовательности n матриц $\langle A_1, A_2, \ldots, A_n \rangle$. Мы будем пользоваться стандартным алгоритмом перемножения двух матриц в качестве подпрограммы. Но прежде надо расставить скобки в (16.1), чтобы указать порядок умножений. Будем говорить, что в произведении матриц **полностью расставлены скобки** (product is fully parenthesized), если это произведение либо состоит из одной-единственной матрицы, либо является заключенным в скобки произведением двух произведений с полностью расставленными скобками. Поскольку умножение матриц ассоциативно, конечный результат вычислений не зависит от расстановки скобок. Например, в произведении $A_1 A_2 A_3 A_4$ можно полностью расставить скобки пятью разными способами:

$$(A_1(A_2(A_3A_4))); \quad (A_1((A_2A_3)A_4)); \quad ((A_1A_2)(A_3A_4));$$
$$((A_1(A_2A_3))A_4); \quad (((A_1A_2)A_3)A_4);$$

во всех случаях ответ будет один и тот же.

Не влияя на ответ, способ расстановки скобок может сильно повлиять на стоимость перемножения матриц. Посмотрим сначала, сколько операций требует перемножение двух матриц. Вот стандартный алгоритм (*rows* и *columns* обозначают количество строк и столбцов матрицы соответственно):

```
Matrix-Multiply(A, B)
1  if columns[A] ≠ rows[B]
2    then error "умножить нельзя"
3    else  for i ← 1 to rows[A]
4            do  for j ← 1 to columns[B]
5                  do C[i, j] ← 0
6                     for k ← 1 to columns[A]
7                        do C[i, j] ← C[i, j] + A[i, k] · B[k, j]
8          return C
```

Матрицы A и B можно перемножать, только если число столбцов у A равно числу строк у B. Если A — это $p \times q$-матрица, а B — это $q \times r$-матрица, то их произведение C является $p \times r$-матрицей. При выполнении этого алгоритма делается pqr умножений (строка 7) и примерно столько же сложений. Для простоты мы будем учитывать только умножения. [В главе 31 приведён алгоритм Штрассена, требующий меньшего числа умножений. В этой главе мы принимаем как данность простейший способ умножения матриц и ищем оптимум за счёт расстановки скобок.]

Чтобы увидеть, как расстановка скобок может влиять на стоимость, рассмотрим последовательность из трех матриц $\langle A_1, A_2, A_3 \rangle$ размеров 10×100, 100×5 и 5×50 соответственно. При вычислении $((A_1 A_2) A_3)$ нужно $10 \cdot 100 \cdot 5 = 5000$ умножений, чтобы найти 10×5-матрицу $A_1 A_2$, а затем $10 \cdot 5 \cdot 50 = 2500$ умножений, чтобы умножить эту матрицу на A_3. Всего 7500 умножений. При расстановке скобок $(A_1(A_2 A_3))$ мы делаем $100 \times 5 \times 50 = 25\,000$ умножений для нахождения 100×50-матрицы $A_2 A_3$, плюс ещё $10 \times 100 \times 50 = 50\,000$ умножений (умножение A_1 на $A_2 A_3$), итого 75 000 умножений. Тем самым, первый способ расстановки скобок в 10 раз выгоднее.

Задача об умножении последовательности матриц (matrix-chain multiplication problem) может быть сформулирована следующим образом: дана последовательность из n матриц $\langle A_1, A_2, \ldots, A_n \rangle$ заданных размеров (матрица A_i имеет размер $p_{i-1} \times p_i$); требуется найти такую (полную) расстановку скобок в произведении $A_1 A_2 \ldots A_n$, чтобы вычисление произведения требовало наименьшего числа умножений.

Количество расстановок скобок

Прежде чем применять динамическое программирование к задаче об умножении последовательности матриц, стоит убедиться, что простой перебор всех возможных расстановок скобок не даст эффективного алгоритма. Обозначим символом $P(n)$ количество полных расстановок скобок в произведении n матриц. Последнее умножение может происходить на границе между k-й и $(k+1)$-й матрицами. До этого мы отдельно вычисляем произведение первых k и остальных $n-k$ матриц. Поэтому

$$P(n) = \begin{cases} 1, & \text{если } n = 1, \\ \sum\limits_{k=1}^{n-1} P(k)P(n-k), & \text{если } n \geqslant 2. \end{cases}$$

В задаче 13-4 мы просили вас доказать, что это соотношение задаёт последовательность **чисел Каталана**

$$P(n) = C(n-1),$$

где

$$C(n) = \frac{1}{n+1} C_{2n}^{n} = \Omega(4^n / n^{3/2}).$$

Стало быть, число решений экспоненциально зависит от n, так что полный перебор неэффективен. [Другой способ понять, что число вариантов экспоненциально: разобьём матрицы на группы по три; произведение для каждой группы можно вычислить двумя способами, так что для $3n$ матриц есть не менее 2^n вариантов.]

Шаг 1: строение оптимальной расстановки скобок

Если мы собираемся воспользоваться динамическим программированием, то для начала должны описать строение оптимальных решений. Для задачи об умножении последовательности матриц это выглядит следующим образом. Обозначим для удобства через $A_{i..j}$ матрицу, являющуюся произведением $A_i A_{i+1} \ldots A_j$. Оптимальная расстановка скобок в произведении $A_1 A_2 \ldots A_n$ разрывает последовательность между A_k и A_{k+1} для некоторого k, удовлетворяющего неравенству $1 \leqslant k < n$. Иными словами, при вычислении произведения, диктуемом этой расстановкой скобок, мы сначала вычисляем произведения $A_{1..k}$ и $A_{k+1..n}$, а затем перемножаем их и получаем окончательный ответ $A_{1..n}$. Стало быть, стоимость этой оптимальной расстановки равна стоимости вычисления матрицы $A_{1..k}$, плюс стоимость вычисления матрицы $A_{k+1..n}$, плюс стоимость перемножения этих двух матриц.

Чем меньше умножений нам потребуется для вычисления $A_{1..k}$ и $A_{k+1..n}$, тем меньше будет общее число умножений. Стало быть, оптимальное решение задачи о перемножении последовательности матриц содержит оптимальные решения задач о перемножении её частей. Как мы увидим в разделе 16.2, это и позволяет применить динамическое программирование.

Шаг 2: рекуррентное соотношение

Теперь надо выразить стоимость оптимального решения задачи через стоимости оптимальных решений её подзадач. Такими подзадачами будут задачи об оптимальной расстановке скобок в произведениях $A_{i..j} = A_i A_{i+1} \dots A_j$ для $1 \leqslant i \leqslant j \leqslant n$. Обозначим через $m[i,j]$ минимальное количество умножений, необходимое для вычисления матрицы $A_{i..j}$; в частности, стоимость вычисления всего произведения $A_{1..n}$ есть $m[1,n]$.

Числа $m[i,j]$ можно вычислить так. Если $i = j$, то последовательность состоит из одной матрицы $A_{i..i} = A_i$ и умножения вообще не нужны. Стало быть, $m[i,i] = 0$ для $i = 1, 2, \dots, n$. Чтобы посчитать $m[i,j]$ для $i < j$, мы воспользуемся информацией о строении оптимального решения, полученной на шаге 1. Пусть при оптимальной расстановке скобок в произведении $A_i A_{i+1} \dots A_j$ последним идет умножение $A_i \dots A_k$ на $A_{k+1} \dots A_j$, где $i \leqslant k < j$. Тогда $m[i,j]$ равно сумме минимальных стоимостей вычисления произведений $A_{i..k}$ и $A_{k+1..j}$ плюс стоимость перемножения этих двух матриц. Поскольку для вычисления произведения $A_{i..k} A_{k+1..j}$ требуется $p_{i-1} p_k p_j$ умножений,

$$m[i,j] = m[i,k] + m[k+1,j] + p_{i-1} p_k p_j.$$

В этом соотношении подразумевается, что оптимальное значение k нам известно; на деле это не так. Однако число k может принимать всего лишь $j - i$ различных значений: $i, i+1, \dots, j-1$. Поскольку одно из них оптимально, достаточно перебрать эти значения k и выбрать наилучшее. Получаем рекуррентную формулу:

$$m[i,j] = \begin{cases} 0 & \text{при } i = j, \\ \min\limits_{i \leqslant k < j} \{m[i,k] + m[k+1,j] + p_{i-1} p_k p_j\} & \text{при } i < j. \end{cases} \tag{16.2}$$

Числа $m[i,j]$ — стоимости оптимальных решений подзадач. Чтобы проследить за тем, как получается оптимальное решение, обозначим через $s[i,j]$ оптимальное место последнего умножения, то есть такое k, что при оптимальном вычислении произведения $A_i A_{i+1} \dots A_j$ последним идет умножение $A_i \dots A_k$ на $A_{k+1} \dots A_j$. Иными словами, $s[i,j]$ равно числу k, для которого $m[i,j] = m[i,k] + m[k+1,j] + p_{i-1} p_k p_j$.

Шаг 3: вычисление оптимальной стоимости

Пользуясь соотношениями (16.2), теперь легко написать рекурсивный алгоритм, определяющий минимальную стоимость вычисления произведения $A_1 A_2 \dots A_n$ (т.е. число $m[1,n]$). Однако время работы такого алгоритма экспоненциально зависит от n, так что этот алгоритм не лучше полного перебора. Настоящий выигрыш во времени мы получим, если воспользуемся тем, что подзадач относительно немного: по одной задаче для каждой пары (i, j), для которой $1 \leqslant i \leqslant j \leqslant n$, а всего $C_n^2 + n = \Theta(n^2)$. Экспоненциальное время работы возникает потому, что рекурсивный алгоритм решает каждую из подзадач по многу раз, на разных ветвях дерева рекурсии. Такое *"перекрытие подзадач"* — характерный признак задач, решаемых методом динамического программирования.

Вместо рекурсии мы вычислим оптимальную стоимость *"снизу вверх"*. В нижеследующей программе предполагается, что матрица A_i имеет размер $p_{i-1} \times p_i$ при $i = 1, 2, \ldots, n$. На вход подаётся последовательность $p = \langle p_0, p_1, \ldots, p_n \rangle$, где $length[p] = n + 1$. Программа использует вспомогательные таблицы $m[1 \,..\, n, 1 \,..\, n]$ (для хранения стоимостей $m[i, j]$) и $s[1 \,..\, n, 1 \,..\, n]$ (в ней отмечается, при каком k достигается оптимальная стоимость при вычислении $m[i, j]$).

```
Matrix-Chain-Order(p)
 1  n ← length[p] − 1
 2  for i ← 1 to n
 3       do m[i, i] ← 0
 4  for l ← 2 to n
 5       do for i ← 1 to n − l + 1
 6               do j ← i + l − 1
 7                  m[i, j] ← ∞
 8                  for k ← i to j − 1
 9                       do q ← m[i, k] + m[k + 1, j] + p_{i−1} p_k p_j
10                          if q < m[i, j]
11                            then m[i, j] ← q
12                                 s[i, j] ← k
13  return m, s
```

Заполняя таблицу m, этот алгоритм последовательно решает задачи об оптимальной расстановке скобок для одного, двух, ..., n сомножителей. В самом деле, соотношение (16.2) показывает, что число $m[i, j]$ — стоимость перемножения $j - i + 1$ матриц — зависит только от стоимостей меньшего (чем $j - i + 1$) числа матриц. Именно, для $k = i, i + 1, \ldots, j - 1$ получается, что $A_{i..k}$ — произведение $k - i + 1 < j - i + 1$ матриц, а $A_{k+1..j}$ — произведение $j - k < j - i + 1$ матриц.

Сначала (в строках 2–3) алгоритм выполняет присваивания $m[i, i] \leftarrow 0$ для $i = 1, 2, \ldots, n$: стоимость перемножения последовательности из одной матрицы равна нулю. При первом исполнении цикла (строки 4–12) вычисляются (с помощью соотношений (16.2)) значения $m[i, i+1]$ для $i = 1, 2, \ldots, n-1$ — это минимальные стоимости для последовательностей длины 2. При втором проходе вычи-

Рисунок 16.1 Таблицы m и s, вычисляемые процедурой MATRIX-CHAIN-ORDER для $n = 6$ и матриц следующего размера:

матрица	размер
A_1	30×35
A_2	35×15
A_3	15×5
A_4	5×10
A_5	10×20
A_6	20×25

Таблицы повёрнуты так, что главная диагональ горизонтальна. В таблице m используются только клетки, лежащие не ниже главной диагонали, в таблице s — только клетки, лежащие строго выше. Минимальное количество умножений, необходимое для перемножения всех шести матриц, равно $m[1,6] = 15\,125$. Пары клеточек, заштрихованных одинаковой светлой штриховкой, совместно входят в правую часть формулы в процессе вычисления $m[2,5]$ (строка 9 процедуры MATRIX-CHAIN-ORDER):

$$m[2,5] = \min \begin{cases} m[2,2] + m[3,5] + p_1 p_2 p_5 = 0 + 2500 + 35 \cdot 15 \cdot 20 = 13000, \\ m[2,3] + m[4,5] + p_1 p_3 p_5 = 2625 + 1000 + 35 \cdot 5 \cdot 20 = 7125, \\ m[2,4] + m[5,5] + p_1 p_4 p_5 = 4375 + 0 + 35 \cdot 10 \cdot 20 = 11375. \end{cases}$$

сляются $m[i, i+2]$ для $i = 1, 2, \ldots, n-2$ — минимальные стоимости перемножения последовательностей длины 3, и так далее. На каждом шаге значение $m[i,j]$, вычисляемое в строках 9–12, зависит только от вычисленных ранее значений $m[i,k]$ и $m[k+1,j]$.

На рис. 16.1 показано, как это происходит при $n = 6$. Поскольку мы определяем $m[i,j]$ только для $i \leqslant j$, используется часть таблицы, лежащая над главной диагональю. На рисунке таблицы повёрнуты (главная диагональ горизонтальна). Внизу выписана последовательность матриц. Число $m[i,j]$ — минимальная стоимость перемножения подпоследовательности $A_i A_{i+1} \ldots A_j$ — находится на пересечении диагоналей, идущих вправо-вверх от матрицы A_i и влево-вверх от матрицы A_j. В каждом горизонтальном ряду собраны стоимости перемножения подпоследовательностей фиксированной длины. Для заполнения клетки $m[i,j]$ нужно знать произведения $p_{i-1} p_k p_j$ для $k = i, i+1, \ldots, j-1$ и содержимое клеток, лежащих слева-внизу и справа-внизу от $m[i,j]$.

Простая оценка показывает, что время работы алгоритма Matrix-Chain-Order есть $O(n^3)$. В самом деле, число вложенных циклов равно трём, и каждый из индексов l, i и k принимает не более n значений. В упражнении 16.1-3 мы предложим вам показать, что время работы этого алгоритма есть $\Theta(n^3)$. Объём памяти, необходимый для хранения таблиц m и s, есть $\Theta(n^2)$. Тем самым этот алгоритм значительно эффективнее, чем требующий экспоненциального времени перебор всех расстановок.

Шаг 4: построение оптимального решения

Алгоритм Matrix-Chain-Order находит минимальное число умножений, необходимое для перемножения последовательности матриц. Осталось найти расстановку скобок, приводящую к такому числу умножений.

Для этого мы используем таблицу $s[1\,..\,n, 1\,..\,n]$. В клетке $s[i,j]$ записано место последнего умножения при оптимальной расстановке скобок; другими словами, при оптимальном способе вычисления $A_{1..n}$ последним идёт умножение $A_{1..s[1,n]}$ на $A_{s[1,n]+1..n}$. Предшествующие умножения можно найти рекурсивно: значение $s[1, s[1,n]]$ определяет последнее умножение при нахождении $A_{1..s[1,n]}$, а $s[s[1,n]+1, n]$ определяет последнее умножение при вычислении $A_{s[1,n]+1..n}$. Приведённая ниже рекурсивная процедура вычисляет произведение $A_{i..j}$, имея следующие данные: последовательность матриц $A = \langle A_1, A_2, \ldots, A_n\rangle$, таблицу s, найденную процедурой Matrix-Chain-Order, а также индексы i и j. Произведение $A_1 A_2 \ldots A_n$ равно Matrix-Chain-Multiply$(A, s, 1, n)$.

```
Matrix-Chain-Multiply(A, s, i, j)
if j > i
   then X ← Matrix-Chain-Multiply(A, s, i, s[i, j])
        Y ← Matrix-Chain-Multiply(A, s, s[i, j] + 1, j)
        return Matrix-Multiply(X, Y)
   else return A_i
```

В примере на рис. 16.1 вызов Matrix-Chain-Multiply$(A, s, 1, 6)$ вычислит произведение шести матриц в соответствии с расстановкой скобок

$$((A_1(A_2A_3))((A_4A_5)A_6)). \tag{16.3}$$

[Техническое замечание: следует позаботиться, чтобы при передаче массива s в процедуру не происходило копирования.]

Упражнения

16.1-1 Найдите оптимальную расстановку в задаче о перемножении матриц, если $p = \langle 5, 10, 3, 12, 5, 50, 6 \rangle$.

16.1-2 Разработайте алгоритм PRINT-OPTIMAL-PARENS, печатающий оптимальную расстановку скобок. (Таблица s уже вычислена алгоритмом MATRIX-CHAIN-ORDER.)

16.1-3 Пусть $R(i, j)$ обозначает количество обращений алгоритма MATRIX-CHAIN-ORDER к элементу $m[i, j]$ таблицы m с целью вычисления других элементов таблицы [строка 9]. Покажите, что общее количество таких обращений равно

$$\sum_{i=1}^{n} \sum_{j=1}^{n} R(i, j) = \frac{n^3 - n}{3}.$$

(Указание. Вам может пригодиться формула $\sum_{i=1}^{n} i^2 = n(n+1)(2n+1)/6$.)

16.1-4 Покажите, что полная расстановка скобок в произведении n множителей использует ровно $n - 1$ пар скобок.

16.2 Когда применимо динамическое программирование

В этом разделе мы укажем два признака, характерных для задач, решаемых методом динамического программирования.

Оптимальность для подзадач

При решении оптимизационной задачи с помощью динамического программирования необходимо сначала описать структуру оптимального решения. Будем говорить, что задача **обладает свойством оптимальности для задач** (has optimal substructure), если оптимальное решение задачи содержит оптимальные решения её подзадач. Если задача обладает этим свойством, то динамическое программирование может оказаться полезным для её решения (а возможно, применим и жадный алгоритм — см. главу 17).

В разделе 16.1 мы видели, что задача перемножения матриц обладает свойством оптимальности для подзадач: каждая скобка в оптимальном произведении указывает оптимальный способ перемножения входящих в неё матриц. Чтобы убедиться, что задача обладает этим свойством, надо (как в разделе 16.1) показать, что, улучшая решение подзадачи, мы улучшим и решение исходной задачи.

Как только свойство оптимальности для подзадач установлено, обычно становится ясно, с каким именно множеством подзадач будет иметь дело алгоритм. Например, для задачи о перемножении последовательности матриц подзадачами будут задачи о перемножении кусков этой последовательности.

Перекрывающиеся подзадачи

Второй свойство задач, необходимое для использования динамического программирования, — малость множества подзадач. Благодаря этому при рекурсивном решении задачи мы всё время выходим на одни и те же подзадачи. В таком случае говорят, что у оптимизационной задачи имеются **перекрывающиеся подзадачи** (overlapping subproblems). В типичных случаях количество подзадач полиномиально зависит от размера исходных данных.

В задачах, решаемых методом *"разделяй и властвуй"*, так не бывает: для них рекурсивный алгоритм, как правило, на каждом шаге порождает совершенно новые подзадачи. Алгоритмы, основанные на динамическом программировании, используют перекрытие подзадач следующим образом: каждая из подзадач решается только один раз, и ответ заносится в специальную таблицу; когда эта же подзадача встречается снова, программа не тратит время на её решение, а берёт готовый ответ из таблицы.

Вернёмся для примера к задаче о перемножении последовательности матриц. Из рисунка 16.1 видно, что решение каждой из подзадач, записанное в данной клеточке таблицы, многократно используется процедурой Matrix-Chain-Order при решении подзадач из расположенных выше клеточек. Например, $m[3,4]$ используется четырежды: при вычислении $m[2,4]$, $m[1,4]$, $m[3,5]$ и $m[3,6]$. Было бы крайне неэффективно вычислять $m[3,4]$ всякий раз заново. В самом деле, рассмотрим следующий (неэффективный) рекурсивный алгоритм, основанный непосредственно на соотношениях (16.2) и вычисляющий $m[i,j]$ — минимальное количество умножений, необходимое для вычисления $A_{i..j} = A_i A_{i+1} \ldots A_j$:

Recursive-Matrix-Chain(p, i, j)

if $i = j$
    then return 0
$m[i,j] \leftarrow \infty$
for $k \leftarrow i$ **to** $j - 1$
    do $q \leftarrow$ Recursive-Matrix-Chain$(p, i, k) +$
        $+$ Recursive-Matrix-Chain$(p, k+1, j) + p_{i-1} p_k p_j$
        if $q < m[i,j]$
            then $m[i,j] \leftarrow q$
return $m[i,j]$

Рисунок 16.2 Дерево рекурсии для Recursive-Matrix-Chain$(p, 1, 4)$. В каждой вершине записаны значения i и j. Заштрихованы *"лишние"* вершины (вычисления в которых повторяют уже проделанные).

На рис. 16.2 изображено дерево рекурсии для Recursive-Matrix-Chain$(p, 1, 4)$. В каждой вершине записаны значения i и j. Обратите внимание, что некоторые пары (i, j) встречаются многократно.

Легко видеть, что время работы Recursive-Matrix-Chain$(p, 1, n)$ зависит от n по меньшей мере экспоненциально. В самом деле, обозначим его $T(n)$ и примем, что время исполнения строк 1–2, а также 6–7, равно единице. Тогда:

$$T(1) \geqslant 1,$$

$$T(n) \geqslant 1 + \sum_{k=1}^{n-1} (T(k) + T(n-k) + 1), \qquad \text{если } n > 1.$$

В сумме по k каждое $T(i)$ (при $i = 1, 2, \ldots, n-1$) встречается дважды, и ещё есть $n-1$ единиц. Стало быть,

$$T(n) \geqslant 2 \sum_{i=1}^{n-1} T(i) + n. \tag{16.4}$$

Докажем по индукции, что $T(n) \geqslant 2^{n-1}$ для всех $n \geqslant 1$. При $n = 1$ неравенство выполнено, так как $T(1) \geqslant 1 = 2^0$. Шаг индукции:

$$\begin{aligned} T(n) \geqslant 2 \sum_{i=1}^{n-1} 2^{i-1} + n = 2 \sum_{i=0}^{n-2} 2^i + n = \\ = 2(2^{n-1} - 1) + n = 2^n - 2 + n \geqslant 2^{n-1}. \end{aligned}$$

Мы видим, что алгоритм Recursive-Matrix-Chain требует экспоненциального времени. Причина в том, что этот алгоритм многократно встречает одинаковые подзадачи и каждый раз решает их заново. Различных подзадач всего лишь $\Theta(n^2)$, и масса времени теряется на лишнюю работу. Метод динамического программирования позволяет этой лишней работы избежать.

Динамическое программирование *"сверху вниз"*

Алгоритм раздела 16.1 действовал *"снизу вверх"*. Но тот же приём (исключение повторного решения подзадач) можно реализовать и для алгоритмов, работающих *"сверху вниз"*. Для этого нужно запоминать ответы к уже решённым подзадачам в специальной таблице. Сначала вся таблица пуста (т.е. заполнена специальными записями, указывающими на то, что соответствующее значение еще не вычислено). Когда в процессе выполнения алгоритма подзадача встречается в первый раз, её решение заносится в таблицу. В дальнейшем решение этой подзадачи берётся прямо из таблицы. (В нашем примере таблицу ответов завести легко, так как подзадачи нумеруются парами (i, j). В более сложных случаях можно использовать хеширование.) По-английски этот прием улучшения рекурсивных алгоритмов называется **memoization**.

Применим это усовершенствование к алгоритму Recursive-Matrix-Chain:

```
Memoized-Matrix-Chain(p)
n ← length[p] − 1
for i ← 1 to n
     do for j ← i to n
            do m[i, j] ← ∞
return Lookup-Chain(p, 1, n)
```

```
Lookup-Chain(p, i, j)
if m[i, j] < ∞
   then return m[i, j]
if i = j
   then m[i, j] ← 0
   else for k ← i to j − 1
            do q ← Lookup-Chain(p, i, k) +
                      + Lookup-Chain(p, k + 1, j) + p_{i−1} p_k p_j
               if q < m[i, j]
                  then m[i, j] ← q
return m[i, j]
```

Процедура Memoized-Matrix-Chain, подобно Matrix-Chain-Order, заполняет таблицу $m[1..n, 1..n]$, где $m[i, j]$ — минимальное количество умножений, необходимое для вычисления $A_{i..j}$. Первоначально $m[i, j] = \infty$ в знак того, что соответствующее место в таблице не заполнено. Если при исполнении Lookup-Chain(p, i, j) оказывается, что $m[i, j] < \infty$, то процедура сразу выдает это значение $m[i, j]$. В противном случае $m[i, j]$ вычисляется как в процедуре Recursive-Matrix-Chain, записывается в таблицу и выдаётся в качестве ответа. Тем самым вызов Lookup-Chain(p, i, j) всегда возвращает $m[i, j]$, но вычисления проводятся только при первом таком вызове.

Рис. 16.2 иллюстрирует экономию, достигаемую заменой Recursive-Matrix-Chain на Memoized-Matrix-Chain. Заштрихованные вершины дерева рекурсии соответствуют тем случаям, когда значение $m[i, j]$ не вычисляется, а берётся прямо из таблицы.

Алгоритм Memoized-Matrix-Chain требует времени $O(n^3)$, как и алгоритм Matrix-Chain-Order. В самом деле, каждая из $\Theta(n^2)$ позиций таблицы один раз инициализируется (строка 4 процедуры Memoized-Matrix-Chain) и один-единственный раз заполняется — при первом вызове Lookup-Chain(p, i, j) для данных i и j. Все вызовы Lookup-Chain(p, i, j) делятся на первые и повторные. Каждый из $\Theta(n^2)$ первых вызовов требует времени $O(n)$ (не включая времени работы рекурсивных вызовов Lookup-Chain для меньших участков); общее время работы есть $O(n^3)$. Каждый из повторных вызовов требует времени $O(1)$; их число есть $O(n^3)$ (вычисления для каждой из $O(n^2)$ клеток таблицы порождают $O(n)$ вызовов). Тем самым рекурсивный алгоритм, требующий времени $\Omega(2^n)$, превратился в полиномиальный, требующий времени $O(n^3)$.

Подведём итоги: задача об оптимальном порядке умножения n матриц может быть решена за время $O(n^3)$ либо *"сверху вниз"* (рекурсивный алгоритм с запоминанием ответов), либо *"снизу вверх"* (динамическое программирование). Оба алгоритма основаны на перекрытии подзадач; число подзадач есть $\Theta(n^2)$, и оба алгоритма решают каждую из подзадач лишь единожды.

Вообще говоря, если каждая из подзадач должна быть решена хоть раз, метод динамического программирования (*"снизу вверх"*) обычно эффективнее, чем рекурсия с запоминанием ответов, поскольку реализация рекурсии (а также проверка, есть ответ в таблице или ещё нет) требует дополнительного времени. Но если для нахождения оптимума не обязательно решать все подзадачи, подход *"сверху вниз"* имеет то преимущество, что решаются лишь те подзадачи, которые действительно нужны.

Упражнения

16.2-1 Сравните неравенство (16.4) с формулой (8.4), использованной при оценке времени работы алгоритма быстрой сортировки. В чём причина того, что оценки, получающиеся из этих двух рекуррентных соотношений, столь различны?

16.2-2 Как лучше искать оптимальный порядок перемножения матриц: перебирая все расстановки скобок и вычисляя количество умножений для каждой из них, или же с помощью алгоритма

Recursive-Matrix-Chain?

16.2-3 Нарисуйте дерево рекурсии для алгоритма Merge-Sort (сортировка слиянием) из раздела 1.3.1, применённого к массиву из 16 элементов. Почему здесь нет смысла запоминать ответы к уже решённым подзадачам?

16.3 Наибольшая общая подпоследовательность

Подпоследовательность получается из данной последовательности, если удалить некоторые её элементы (сама последовательность также считается своей подпоследовательностью). Формально: последовательность $Z = \langle z_1, z_2, \ldots, z_k \rangle$ называется **подпоследовательностью** (subsequence) последовательности $X = \langle x_1, x_2, \ldots, x_n \rangle$, если существует строго возрастающая последовательность индексов $\langle i_1, i_2, \ldots, i_k \rangle$, для которой $z_j = x_{i_j}$ при всех $j = 1, 2, \ldots, k$. Например, $Z = \langle B, C, D, B \rangle$ является подпоследовательностью последовательности $X = \langle A, B, C, B, D, A, B \rangle$; соответствующая последовательность индексов есть $\langle 2, 3, 5, 7 \rangle$. (Отметим, что говоря о последовательностях, мы — в отличие от курсов математического анализа — имеем в виду конечные последовательности.)

Будем говорить, что последовательность Z является **общей подпоследовательностью** (common subsequence) последовательностей X и Y, если Z является подпоследовательностью как X, так и Y. Пример: $X = \langle A, B, C, B, D, A, B \rangle$, $Y = \langle B, D, C, A, B, A \rangle$, $Z = \langle B, C, A \rangle$. Последовательность Z в этом примере — не самая длинная из общих подпоследовательностей X и Y (последовательность $\langle B, C, B, A \rangle$ длиннее). Последовательность $\langle B, C, B, A \rangle$ будет наибольшей общей подпоследовательностью для X и Y, поскольку общих подпоследовательностей длины 5 у них нет. Наибольших общих подпоследовательностей может быть несколько. Например, $\langle B, D, A, B \rangle$ — другая наибольшая общая подпоследовательность X и Y.

Задача о наибольшей общей подпоследовательности (сокращенно НОП; по-английски LCS = longest-common-subsequence) состоит в том, чтобы найти общую подпоследовательность наибольшей длины для двух данных последовательностей X и Y. В этом разделе мы покажем, как решить эту задачу с помощью динамического программирования.

Строение наибольшей общей подпоследовательности

Если решать задачу о НОП *"в лоб"*, перебирая все подпоследовательности последовательности X и проверяя для каждой из них, не будет ли она подпоследовательностью последовательности Y, то алгоритм будет работать экспоненциальное время, поскольку последовательность длины m имеет 2^m подпоследовательностей (столько же, сколько подмножеств у множества $\{1, 2, \ldots, m\}$).

Однако задача о НОП обладает свойством оптимальности для подзадач, как показывает теорема 16.1 (см. ниже). Подходящее множество подзадач — множество пар префиксов двух данных последовательностей. Пусть $X = \langle x_1, x_2, \ldots, x_m \rangle$ — некоторая последовательность. Её **префикс** (prefix) длины i — это последовательность $X_i = \langle x_1, x_2, \ldots, x_i \rangle$ (при i от 0 до m). Например, если $X = \langle A, B, C, B, D, A, B \rangle$, то $X_4 = \langle A, B, C, B \rangle$, а X_0 — пустая последовательность.

Теорема 16.1 (о строении НОП). *Пусть $Z = \langle z_1, z_2, \ldots, z_k \rangle$ — одна из наибольших общих подпоследовательностей для $X = \langle x_1, x_2, \ldots, x_m \rangle$ и $Y = \langle y_1, y_2, \ldots, y_n \rangle$. Тогда:*

1. *если $x_m = y_n$, то $z_k = x_m = y_n$ и Z_{k-1} является НОП для X_{m-1} и Y_{n-1};*
2. *если $x_m \neq y_n$ и $z_k \neq x_m$, то Z является НОП для X_{m-1} и Y;*
3. *если $x_m \neq y_n$ и $z_k \neq y_n$, то Z является НОП для X_m и Y_{n-1}.*

Доказательство. (1) Если $z_k \neq x_m$, то мы можем дописать $x_m = y_n$ в конец последовательности Z и получить общую подпоследовательность длины $k + 1$, что противоречит условию. Стало быть, $z_k = x_m = y_n$. Если у последовательностей X_{m-1} и Y_{n-1} есть более длинная (чем Z_{k-1}) общая подпоследовательность, то мы можем дописать к ней $x_m = y_n$ и получить общую подпоследовательность для X и Y, более длинную, чем Z — противоречие.

(2) Коль скоро $z_k \neq x_m$, последовательность Z является общей подпоследовательностью для X_{m-1} и Y. Так как Z — НОП для X и Y, то она тем более является НОП для X_{m-1} и Y.

(3) Аналогично (2). □

Мы видим, что НОП двух последовательностей содержит в себе наибольшую общую подпоследовательность их префиксов. Стало быть, задача о НОП обладает свойством оптимальности для подзадач. Сейчас мы убедимся, что перекрытие подзадач также имеет место.

Рекуррентная формула

Теорема 16.1 показывает, что нахождение НОП последовательностей $X = \langle x_1, x_2, \ldots, x_m \rangle$ и $Y = \langle y_1, y_2, \ldots, y_n \rangle$ сводится к решению либо одной, либо двух подзадач. Если $x_m = y_n$, то достаточно найти НОП последовательностей X_{m-1} и Y_{n-1} и дописать к ней в конце $x_m = y_n$. Если же $x_m \neq y_n$, то надо решить две подзадачи: найти

НОП для X_{m-1} и Y, а затем найти НОП для X и Y_{n-1}. Более длинная из них и будет служить НОП для X и Y.

Теперь сразу видно, что возникает перекрытие подзадач. Действительно, чтобы найти НОП X и Y, нам может понадобиться найти НОП X_{m-1} и Y, а также НОП X и Y_{n-1}; каждая из этих задач содержит подзадачу нахождения НОП для X_{m-1} и Y_{n-1}. Аналогичные перекрытия будут встречаться и далее.

Как и в задаче перемножения последовательности матриц, мы начнём с рекуррентного соотношения для стоимости оптимального решения. Пусть $c[i,j]$ обозначает длину НОП для последовательностей X_i и Y_j. Если i или j равно нулю, то одна из двух последовательностей пуста, так что $c[i,j]=0$. Сказанное выше можно записать так:

$$c[i,j] = \begin{cases} 0 & \text{если } i=0 \text{ или } j=0, \\ c[i-1,j-1]+1 & \text{если } i,j>0 \text{ и } x_i=y_j, \\ \max(c[i,j-1],c[i-1,j]), & \text{если } i,j>0 \text{ и } x_i \neq y_j. \end{cases} \tag{16.5}$$

Вычисление длины НОП

Исходя из соотношения (16.5), легко написать рекурсивный алгоритм, работающий экспоненциальное время и вычисляющий длину НОП двух данных последовательностей. Но поскольку различных подзадач всего $\Theta(mn)$, лучше воспользоваться динамическим программированием.

Исходными данными для алгоритма LCS-Length служат последовательности $X=\langle x_1,x_2,\ldots,x_m\rangle$ и $Y=\langle y_1,y_2,\ldots,y_n\rangle$. Числа $c[i,j]$ записываются в таблицу $c[0\,..\,m,0\,..\,n]$ в таком порядке: сначала заполняется слева направо первая строка, затем вторая, и т. д. Кроме того, алгоритм запоминает в таблице $b[1\,..\,m,1\,..\,n]$ *"происхождение"* $c[i,j]$: в клетку $b[i,j]$ заносится стрелка, указывающая на клетку с координатами $(i-1,j-1)$, $(i-1,j)$ или $(i,j-1)$, в зависимости от того, равно ли $c[i,j]$ числу $c[i-1,j-1]+1$, $c[i-1,j]$ или $c[i,j-1]$ (см. (16.5)). Результатами работы алгоритма являются таблицы c и b.

Рисунок 16.3 Таблицы c и b, созданные алгоритмом LCS-Length при $X = \langle A, B, C, B, D, A, B \rangle$ и $Y = \langle B, D, C, A, B, A \rangle$. В клетке с координатами (i, j) записаны число $c[i, j]$ и стрелка $b[i, j]$. Число 4 в правой нижней клетке есть длина НОП. При $i, j > 0$ значение $c[i, j]$ определяется тем, равны ли x_i и y_j, и вычисленными ранее значениями $c[i-1, j]$, $c[i, j-1]$ и $c[i-1, j-1]$. Путь по стрелкам, ведущий из $c[7, 6]$, заштрихован. Каждая косая стрелка на этом пути соответствует элементу НОП (эти элементы выделены).

```
LCS-Length(X, Y)
m ← length[X]
n ← length[Y]
for i ← 1 to m
     do c[i, 0] ← 0
for j ← 0 to n
     do c[0, j] ← 0
for i ← 1 to m
     do for j ← 1 to n
            do if x_i = y_j
                  then c[i, j] ← c[i − 1, j − 1] + 1
                       b[i, j] ← "↖"
                  else if c[i − 1, j] ⩾ c[i, j − 1]
                          then c[i, j] ← c[i − 1, j]
                               b[i, j] ← "↑"
                          else c[i, j] ← c[i, j − 1]
                               b[i, j] ← "←"
return c, b
```

На рис. 16.3 показана работа LCS-Length для $X = \langle A, B, C, B, D, A, B \rangle$ и $Y = \langle B, D, C, A, B, A \rangle$.

Алгоритм LCS-Length требует времени $O(mn)$: на каждую клетку требуется $O(1)$ шагов.

Построение НОП

Таблица b, созданная процедурой LCS-LENGTH, позволяет быстро найти НОП последовательностей $X = \langle x_1, x_2, \ldots, x_m \rangle$ и $Y = \langle y_1, y_2, \ldots, y_n \rangle$. Для этого надо пройти по пути, указанному стрелками, начиная с $b[m, n]$. Пройденная стрелка $\nwarrow$ в клетке (i, j) означает, что $x_i = y_j$ входит в наибольшую общую подпоследовательность. Вот как это реализовано в рекурсивной процедуре PRINT-LCS (НОП для X и Y печатается при вызове PRINT-LCS$(b, X, \mathit{length}[X], \mathit{length}[Y])$):

```
PRINT-LCS(b, X, i, j)
if i = 0 или j = 0
   then return
if b[i, j] = "↖"
   then PRINT-LCS(b, X, i − 1, j − 1)
        напечатать x_i
elseif b[i, j] = "↑"
   then PRINT-LCS(b, X, i − 1, j)
else PRINT-LCS(b, X, i, j − 1)
```

Будучи применённой к таблице рис. 16.3, эта процедура напечатает $BCBA$. Время работы процедуры есть $O(m + n)$, поскольку на каждом шаге хотя бы одно из чисел m и n уменьшается.

Улучшение алгоритма

После того, как алгоритм разработан, нередко удаётся сделать его более экономным. В нашем примере можно обойтись без таблицы b. В самом деле, каждое из чисел $c[i, j]$ зависит от $c[i - 1, j]$, $c[i, j - 1]$ и $c[i - 1, j - 1]$. Зная $c[i, j]$, мы можем за время $O(1)$ выяснить, какая из этих трёх записей использовалась. Тем самым можно найти НОП за время $O(m+n)$ с помощью одной только таблицы c (в упражнении 16.3-2 мы попросим вас это сделать). При этом мы экономим $\Theta(mn)$ памяти. (Впрочем, асимптотика не меняется: объём таблицы c есть также $\Theta(mn)$.)

Если нас интересует только длина наибольшей общей подпоследовательности, то столько памяти не нужно: вычисление $c[i, j]$ затрагивает только две строки с номерами i и $i - 1$ (это не предел экономии: можно обойтись памятью на одну строку таблицы c плюс ещё чуть-чуть, см. упражнение 16.3-4). При этом, однако, саму подпоследовательность найти (за время $O(m + n)$) не удаётся.

Упражнения

16.3-1 Найдите НОП последовательностей $\langle 1,0,0,1,0,1,0,1\rangle$ и $\langle 0,1,0,1,1,0,1,1,0\rangle$.

16.3-2 Разработайте алгоритм, строящий НОП для $X = \langle x_1, x_2, \ldots, x_m\rangle$ и $Y = \langle y_1, y_2, \ldots, y_n\rangle$ за время $O(m+n)$, исходя только из таблицы c.

16.3-3 Разработайте рекурсивный вариант алгоритма LCS-Length с запоминанием ответов, требующий времени $O(mn)$.

16.3-4 Покажите, как можно вычислить длину НОП, используя память размера $2\min(m,n)+O(1)$ и храня лишь часть таблицы c. А как это сделать, используя память $\min(m,n)+O(1)$?

16.3-5 Разработайте алгоритм, находящий наибольшую возрастающую подпоследовательность данной последовательности из n чисел и работающий за время $O(n^2)$.

16.3-6* Разработайте алгоритм, решающий предыдущую задачу за время $O(n \log n)$. (Указание. Храним для каждого i наименьший из последних элементов возрастающих подпоследовательностей длины i. Как меняются эти числа при добавлении нового элемента?)

16.4 Оптимальная триангуляция многоугольника

Несмотря на свою геометрическую формулировку, эта задача очень близка к задаче о перемножении матриц.

Многоугольник (polygon) — это замкнутая кривая на плоскости, составленная из отрезков, называемых **сторонами** (sides) многоугольника. Точка, в которой сходятся две соседние стороны, называется **вершиной** (vertex). Несамопересекающийся многоугольник (только такие мы и будем, как правило, рассматривать) называется **простым** (simple). Множество точек плоскости, лежащих внутри простого многоугольника, называется **внутренностью** (interior) многоугольника, объединение его сторон называется его **границей** (boundary), а множество всех остальных точек плоскости называется его **внешностью** (exterior). Простой многоугольник называется **выпуклым** (convex), если для любых двух точек, лежащих внутри или на границе многоугольника, соединяющий их отрезок целиком лежит внутри или на границе многоугольника.

Выпуклый многоугольник можно задать, перечислив его вершины против часовой стрелки: многоугольник $P = \langle v_0, v_1, \ldots, v_{n-1}\rangle$

Рисунок 16.4 Две триангуляции выпуклого семиугольника. Каждая делит семиугольник на $7-2=5$ треугольников с помощью $7-3=4$ диагоналей.

имеет n сторон $\overline{v_0v_1}, \overline{v_1v_2}, \ldots, \overline{v_{n-1}v_n}$. Здесь v_n — то же самое, что v_0 (удобно нумеровать вершины n-угольника вычетами по модулю n).

Если v_i и v_j — две вершины, не являющиеся соседними, отрезок $\overline{v_iv_j}$ называется **диагональю** (chord) многоугольника. Диагональ $\overline{v_iv_j}$ разбивает многоугольник на два: $\langle v_i, v_{i+1}, \ldots, v_j\rangle$ и $\langle v_j, v_{j+1}, \ldots, v_i\rangle$. **Триангуляция** (triangulation) многоугольника — это набор диагоналей, разрезающих многоугольник на треугольники; сторонами этих треугольников являются стороны исходного многоугольника и диагонали триангуляции.

На рис. 16.4 изображены две триангуляции семиугольника. (Триангуляцию можно также определить как максимальное множество диагоналей, не пересекающих друг друга.)

Во всех триангуляциях n-угольника одно и то же число треугольников (сумма всех углов многоугольника равна произведению $180°$ и числа треугольников в триангуляции), а именно $n-2$. При этом используются $n-3$ диагонали (проводя диагональ, мы увеличиваем число частей на 1).

Задача об оптимальной триангуляции (optimal triangulation problem) состоит в следующем. Дан выпуклый многоугольник $P = \langle v_0, v_1, \ldots, v_{n-1}\rangle$ и весовая функция w, определённая на множестве треугольников с вершинами в вершинах P. Требуется найти триангуляцию, для которой сумма весов треугольников будет наименьшей.

Естественный пример весовой функции — функция

$$w(\triangle v_iv_jv_k) = |v_iv_j| + |v_jv_k| + |v_kv_i|,$$

где $|v_iv_j|$ обозначает (евклидово) расстояние между v_i и v_j. Мы построим алгоритм решения этой задачи, который применим для любой весовой функции.

Триангуляции и расстановки скобок

Существует удивительная связь между триангуляциями многоугольника и расстановками скобок (скажем, в произведении последовательности матриц). Проще всего объяснить эту связь с помощью деревьев.

Полной расстановке скобок соответствует так называемое **дерево разбора** (parse tree) выражения. На рис. 16.5а изображено дерево разбора для

$$((A_1(A_2A_3))(A_4(A_5A_6))). \tag{16.6}$$

В его листьях стоят матрицы-сомножители, а в вершинах — их произведения: в каждой вершине стоит произведение двух выражений, стоящих в её детях.

Триангуляцию выпуклого многоугольника $\langle v_0, v_1, \ldots, v_{n-1}\rangle$ также можно изобразить в виде дерева. Листьями его будут стороны многоугольника (кроме $\overline{v_0v_{n-1}}$). Остальные вершины — это диагонали триангуляции плюс сторона $\overline{v_0v_{n-1}}$; эту последнюю объявим корнем.

Построение дерева (на примере триангуляции рис. 16.5а) показано на рис. 16.5б. Для начала мы смотрим, в какой треугольник попал корень $\overline{v_0v_{n-1}}$. В нашем случае это $\triangle v_0v_3v_6$. Детьми корня будем считать две другие стороны этого треугольника. Триангуляция состоит из этого треугольника и двух триангуляций оставшихся частей ($\langle v_0, v_1, v_2, v_3\rangle$ и $\langle v_3, v_4, v_5, v_6\rangle$, рис. 16.5б), причём диагонали, являющиеся детьми корня, являются сторонами этих многоугольников ($\overline{v_0v_3}$ и $\overline{v_3v_6}$ на рис. 16.5б). Повторим для каждой из них ту же конструкцию: рассмотрим треугольник триангуляции нового многоугольника, содержащий выделенную сторону, две другие стороны этого треугольника объявим её детьми и т.д. В конце концов мы придём к бинарному дереву с $n-1$ листом. Действуя в обратном порядке, можно по бинарному дереву построить триангуляцию. Построенное соответствие между триангуляциями и бинарными деревьями является взаимно однозначным.

Вспоминая, что полные расстановки скобок в произведении n сомножителей находятся во взаимно однозначном соответствии с бинарными деревьями с n листьями, получаем взаимно однозначное соответствие между полными расстановками скобок в произведении n матриц и триангуляциями $(n+1)$-угольника. При этом матрица A_i в произведении $A_1A_2\ldots A_n$ соответствует стороне $\overline{v_{i-1}v_i}$, а диагональ $\overline{v_{i-1}v_j}$ $(1 \leqslant i < j \leqslant n)$ соответствует произведению $A_{i..j}$.

Это соответствие можно понять и без деревьев. Напишем на всех сторонах триангулированного многоугольника, кроме одной, по сомножителю. Далее поступаем так: если в треугольнике две стороны уже помечены, то на третьей мы пишем их произведение. На