

Probability and Computing

Randomized Algorithms and
Probabilistic Analysis

概率与计算

(美) Michael Mitzenmacher Eli Upfal 著
哈佛大学 布朗大学

史道济 等译



机械工业出版社
China Machine Press

概率与计算

概率是现代计算机科学核心理论不可或缺的一部分。基础的概率分析、随机化算法以及概率组合构造已经成为计算机科学和应用数学的基本工具。本书全面讲述了离散概率及其在计算中的应用，适于计算机科学、数学、工程学等专业高年级本科生阅读。

—Richard M. Karp, 加州大学伯克利分校

这是一本有关随机化算法的新书。它很好地涵盖了所有基本主题，并包括许多有用的现代应用。

—Alan Frieze, 卡内基-梅隆大学

随机化与概率技术在现代计算科学中起着重要的作用，其应用遍及组合优化、机器学习、通信网络以及安全协议等诸多领域。

本书详细地介绍了概率技术以及在概率算法与分析发展中使用过的范例。本书分两部分，第一部分介绍了随机抽样、期望、马尔可夫不等式、切比雪夫不等式、切尔诺夫界、球和箱子模型、概率技术和马尔可夫链等核心内容。第二部分主要研究连续概率、有限独立性的应用、熵、马尔可夫链蒙特卡罗方法、耦合、鞅和平衡配置等比较高深的课题。

作者简介

Michael Mitzenmacher 1996年于加州大学伯克利分校获得博士学位，现为哈佛大学计算机科学教授。在1999年进入哈佛大学之前，他是Palo Alto数字系统研究实验室的研究人员。他曾获美国科学基金（NSF）CAAREER奖和Alfred P. Sloan研究基金。2002年，由于在纠错码方面的出色工作，他获得了IEEE信息论学会的“最佳论文”奖。



Eli Upfal 于以色列耶路撒冷希伯来大学获得博士学位，现为布朗大学计算机科学教授、系主任。在1997年进入布朗大学之前，他是IBM研究部的研究人员、以色列Weizmann科学院的教授。他的主要研究兴趣包括随机化计算和算法的概率分析及其在最优算法、通信网络、并行计算和分布式计算、计算生物学中的应用。



Probability and Computing

Randomized Algorithms and
Probabilistic Analysis



ISBN 978-7-111-20805-1



9 787111 208051



华章图书

华章网站 <http://www.hzbook.com>

网上购书: www.china-pub.com

投稿热线: (010) 88379604

购书热线: (010) 68995259, 68995264

读者信箱: hzsj@hzbook.com

ISBN 978-7-111-20805-1

定价: 39.00 元

2007

33

Probability and Computing

0211

47

2007

Randomized Algorithms and
Probabilistic Analysis

概率与计算

(美) Michael Mitzenmacher Eli Upfal 著
哈佛大学 布朗大学

史道济 等译

(*) 机械工业出版社
China Machine Press



本书详细介绍了概率技术以及在概率算法与分析发展中使用过的范例。本书分两部分，第一部分介绍了随机抽样、期望、马尔可夫不等式、切比雪夫不等式、切尔诺夫界、球和箱子模型、概率技术和马尔可夫链等核心内容。第二部分主要研究连续概率、有限独立性的应用、熵、马尔可夫链蒙特卡罗方法、耦合、鞅和平衡配置等比较高深的课题。

本书适合作为高等院校计算机科学和应用数学专业高年级本科生与低年级研究生的教材，也适合作为数学工作者和科技人员的参考书。

Michael Mitzenmacher and Eli Upfal: Probability and Computing: Randomized Algorithms and Probabilistic Analysis (ISBN 0-521-83540-2).

Originally published by Cambridge University Press in 2005.

This Chinese edition is published with the permission of the Syndicate of the Press of the University of Cambridge, Cambridge, England.

Copyright © 2005 by Michael Mitzenmacher and Eli Upfal.

This edition is licensed for distribution and sale in the People's Republic of China only, excluding Hong Kong, Taiwan and Macao and may not be distributed and sold elsewhere.

本书原版由剑桥大学出版社出版。

本书简体字中文版由英国剑桥大学出版社授权机械工业出版社独家出版。未经出版者预先书面许可，不得以任何方式复制或抄袭本书的任何部分。

此版本仅限在中华人民共和国境内(不包括中国香港、台湾、澳门地区)销售发行，未经授权的本书出口将被视为违反版权法的行为。

版权所有，侵权必究。

本书法律顾问 北京市展达律师事务所

本书版权登记号：图字：01-2005-5838

图书在版编目(CIP)数据

概率与计算/(美)米曾马克(Mitzenmacher, M.)等著；史道济等译。—北京：机械工业出版社，2007.4

(华章数学译丛)

书名原文：Probability and Computing: Randomized Algorithms and Probabilistic Analysis
ISBN 978-7-111-20805-1

I. 概… II. ①米… ②史… III. 概率论 IV. O211

中国版本图书馆CIP数据核字(2007)第011786号

机械工业出版社(北京市西城区百万庄大街22号 邮政编码 100037)

责任编辑：方敏 迟振春

北京牛山世兴印刷厂印刷·新华书店北京发行所发行

2007年4月第1版第1次印刷

186mm×240mm·19印张

定价：39.00元

凡购本书，如有倒页、脱页、缺页，由本社发行部调换

本社购书热线：(010)68326294



教师服务登记表

尊敬的老师:

您好!感谢您购买我们出版的_____教材。

机械工业出版社华章公司本着为服务高等教育的出版原则,为进一步加强与高校教师的联系与沟通,更好地为高校教师服务,特制此表,请您填妥后发回给我们,我们将定期向您寄送华章公司最新的图书出版信息,为您的教材、论著或译著的出版提供可能的帮助。欢迎您对我们的教材和服务提出宝贵的意见,感谢您的大力支持与帮助!

个人资料(请用正楷完整填写)

教师姓名	<input type="checkbox"/> 先生 <input type="checkbox"/> 女士	出生年月	职务	职称: <input type="checkbox"/> 教授 <input type="checkbox"/> 副教授 <input type="checkbox"/> 讲师 <input type="checkbox"/> 助教 <input type="checkbox"/> 其他	
学校		学院		系别	
联系电话	办公:	联系地址及邮编			
	宅电:				
	移动:	E-mail			
学历	毕业院校	国外进修及讲学经历			
研究领域					
主讲课程		现用教材名	作者及出版社	共同授课教师	教材满意度
课程: <input type="checkbox"/> 专 <input type="checkbox"/> 本 <input type="checkbox"/> 研 <input type="checkbox"/> MBA 人数: 学期: <input type="checkbox"/> 春 <input type="checkbox"/> 秋					<input type="checkbox"/> 满意 <input type="checkbox"/> 一般 <input type="checkbox"/> 不满意 <input type="checkbox"/> 希望更换
课程: <input type="checkbox"/> 专 <input type="checkbox"/> 本 <input type="checkbox"/> 研 <input type="checkbox"/> MBA 人数: 学期: <input type="checkbox"/> 春 <input type="checkbox"/> 秋					<input type="checkbox"/> 满意 <input type="checkbox"/> 一般 <input type="checkbox"/> 不满意 <input type="checkbox"/> 希望更换
课程: <input type="checkbox"/> 专 <input type="checkbox"/> 本 <input type="checkbox"/> 研 <input type="checkbox"/> MBA 人数: 学期: <input type="checkbox"/> 春 <input type="checkbox"/> 秋					<input type="checkbox"/> 满意 <input type="checkbox"/> 一般 <input type="checkbox"/> 不满意 <input type="checkbox"/> 希望更换
备注	已出版著作		译著		
	著书	方向一			
	计划	方向二			
	是否愿意从事翻译工作		<input type="checkbox"/> 是 <input type="checkbox"/> 否	翻译方向	
意见和建议					

填妥后请选择以下任何一种方式将此表返回:(如方便请附名片)

地址:北京市西城区百万庄南街1号 华章公司营销中心 邮编:100037

电话:(010) 68353079 88378995 传真:(010) 68995260

E-mail: hzedu@hzbook.com marketing@hzbook.com 图书详情可登录<http://www.hzbook.com>网站查询

译者序

随着人类对客观世界认识的不加深，现在人们普遍认为实际中一切可观测对象几乎都具有随机性。计算机科学领域也不例外，许多比较高深的概率方法在计算机科学中获得了越来越广泛的应用，其中最主要的问题就是随机化算法及算法的概率分析。

随机化算法就是在运行到某一步时需要在诸多可能中随机选择其中之一作为下一步的算法。在某些问题中，这种算法比最好的确定性算法还有效，而且常常比较简单，易于编写程序。算法的概率分析则是研究对具有某种分布的随机输入，即使是一个理论上的 NP 难题，也有很大可能成为一个容易解决的实例。这些内容已成为计算机科学与应用数学的基本工具，本书正是为这些学科以及某些工科的高年级本科生与研究生而写的，具有以下几个特点：

1. 内容安排与传统做法不一样。各章次序是以文献中的相对重要性排序的，前一部分（第 1~7 章）是核心内容，后一部分（第 8~14 章）是相对高深的内容。因此教师在讲授时，可根据需要进行适当调整。

2. 理论与实际相结合。每章介绍一种方法，并给出利用随机化算法或对算法的概率分析的例子，但这并不说明本书仅强调实际应用，事实上，除了一些特殊情况，书中对所有的定理都给出了严格的证明。

3. 大量的练习与例子。全书共有 300 多道练习，其中有些练习要求读者自己编写程序，并在计算机上运行，检查与相关理论是否一致。这些例子与练习有助于培养学生的实际编程能力，不仅对理解书中的内容有帮助，更是计算机科学与应用数学及某些工科学生的自主创新所不可缺少的环节。

本书由史道济、李璠、刘晶、郭慧、贺广婷、吴新荣、李秀敏、蔡霞、辛凌雯、徐付霞、王秀林、刘娟和张春英共同翻译完成，史道济翻译了第 8、11 两章，并进行了全书的审查和统稿工作。对原书中出现的某些印刷错误，我们已作了改正，不再一一指出。

限于译者的水平，译文难免有不妥之处，欢迎专家和读者批评指正。



前 言

为什么要研究随机性

计算机科学家为什么要研究和使用随机性？因为计算机出现了太多不可预见的性态！随机性似乎是一种缺点，它使得有效地使用计算机这种已经具有挑战性的工作更加复杂。

20 世纪，科学研究已经将随机性视为建模和分析中的基本组成部分。例如，在物理方面，牛顿定律使人们相信宇宙的位置是确定的：如果有一个足够大的计算工具和合适的初始条件，人们可以确定若干年后行星的位置。而量子论的发展却提出了非常不同的观点：宇宙仍旧按照自然法则运转，但是这些自然法则的核心是随机性。“上帝不会同宇宙玩骰子。”这是爱因斯坦用来反驳现代量子力学的一句名言。然而，当代亚微粒子物理学的主要理论仍然建立在随机现象和统计规律的基础上，并且在从生物学的遗传和进化到自由市场经济的价格波动模型等几乎所有其他科学领域中，随机性都起着重要的作用。

计算机科学也不例外。从一些概率定理证明的高深的理论性概念到个人计算机以太网卡的实用性设计，随机性和概率方法在现代计算机科学中都扮演了关键角色。过去 20 年来，概率论在计算中的应用得到了巨大的发展，越来越高级、越来越复杂的概率技术已用于更加广泛和更富挑战性的计算机科学应用中。在本书中，我们主要研究随机性影响计算机科学的基本方法：随机化算法和算法的概率分析。

随机化算法：随机化算法是执行过程中要求作出随机选择的算法。实际上，随机化程序会使用由随机数发生器产生的数值，从若干执行分支中决定下一步执行哪个分支。例如，以太网卡协议用随机数决定何时试图访问共享的以太网通信介质。随机性在破除对称性、阻止不同的以太网卡同时重复访问介质方面是很有用的。随机化算法的其他常见应用还包括蒙特卡罗模拟和密码学中的初始检验。在这些以及其他重要应用中，随机化算法比最著名的确定性方法更有效，并且在大多数情况下更简单，更容易编程。

这些获益是需要付出一定代价的，问题的答案可以有某个不正确的概率，或者只以某个概率保证有效。虽然设计一个有可能不正确的算法似乎有点奇怪，但是如果错误的概率很小，那么提高运行速度和减少占用的内存是有价值的。

算法的概率分析：复杂性理论根据计算的复杂性对问题进行分类，尤其是区分简单问题和困难问题。例如，复杂性理论认为流动推销员问题是一个 NP 难题。如果城市数量以次指数增长的话，那么不可能存在一个可以解决流动推销员问题的任何一个实例的算法。对于经典的最好情况复杂性理论，一个令人困惑的现象是，在分类上属于困难的计算问题，实际上却很容易解决。概率分析对这种现象给出了理论上的解释。虽然对某些不合理的输入集合，问题难以解决，但对大多数输入（尤其是在日常的应用中），这些问题实际上却容易解决。更确切地说，如果我们认为输入是随机选择的结果，而随机选择是根据所有可能输入集合上的某个概率分布

作出的,就很有可能得到一个易于解答的问题实例,而这些实例以相对较小的概率是难解的.算法的概率分析是研究当输入来自恰当定义的概率空间时,算法如何运行的一种方法.正如我们将要看到的,即使是NP难题,也会有对于几乎所有输入都极其有效的算法.

关于本书

本教材供计算机科学和应用数学专业高年级本科生或低年级研究生一至两个学期的课程使用.在众多优秀的大学中,随机化和概率技术已经从高年级研究生讨论班的主题变为高年级本科生和低年级研究生的正式课程.在这方面有大量相当高深的、研究性的书籍,但仍然需要一本介绍性的教科书,我们希望本书能满足这方面的要求.

本书的内容是从最近几年布朗大学(CS 155)和哈佛大学(CS 223)讲授计算机科学中的概率方法课程发展而来的.这些课程和本书强调的是概率技术以及范例,而非特定的应用领域.每章介绍一种方法或者技术,通过一些随机化算法分析或基于随机输入算法的概率分析例子来阐述.其中许多例子来自网络中的问题,反映了网络领域的主要趋势(和作者的兴趣).

本书共14章,可分成两部分,第一部分(第1~7章)是核心内容.本书只要求读者具备基本的概率论知识,相当于计算机科学专业离散数学标准课程包含的内容.第1~3章复习初等概率论,并介绍一些有意义的应用,内容包括随机抽样、期望、马尔可夫不等式、方差和切比雪夫不等式.如果教学班有充分的概率背景,那么这几章可以很快地讲过去,但是建议读者不要跳过这些章节,因为这里介绍了随机化算法和算法的概率分析概念,并且还有一些贯穿全书的例子.

第4~7章介绍高级课题,包括切尔诺夫界、球和箱子模型、概率方法和马尔可夫链.同前面几章相比,这几章介绍的内容更加具有挑战性.难度特别大的部分章节(教师可以根据需要考虑跳过这部分内容)标上了星号.根据教学进度,前七章介绍的核心内容可以作为四分之一学年或半学年的课程.

本书第二部分(第8~14章)介绍其他一些高级内容,这些内容既可以作为基本课程的必要补充,也可以作为另一门更高级的课程.这些章节是各自独立的,所以教师可以选择最适合学生的内容来讲授.将关于连续概率和熵的两章纳入基本课程中可能是最适合的.对连续概率(第8章)的介绍主要集中在均匀分布和指数分布,其中还包括一些排队论的例子.对于熵(第9章)的介绍包括如何度量随机性,以及在随机提取、压缩和编码中熵是如何自然地产生的.

第10章和第11章分别介绍了蒙特卡罗方法和耦合.这两章密切相关,最好在一起学习.第12章是关于鞅的,涵盖了如何处理相关随机变量的各种重要问题,而第13章则从不同的思路继续研究两两独立和消去随机性的进展.最后一章(第14章)讨论平衡配置问题,介绍了作者的一些想法,与第5章的球和箱子问题密切相关.

本书各个章节的顺序,尤其是第一部分的顺序,是根据它们在算法文献中的相对重要性安排的.例如,我们先介绍切尔诺夫界,而其他一些基本的概率知识(如马尔可夫链),则放在后面.但是,教师可以按照不同顺序授课.在更强调一般随机过程的课程中,可以在第1~3

章后直接讲授马尔可夫链(第7章),随后讲授球和箱子及随机图(第5章,略去哈密顿圈例子),接下来可以跳过第6章关于概率方法的内容,而讲授连续概率和泊松过程(第8章)。本书其余大部分内容都会用到第4章中切尔诺夫界的知识。

书中的大部分练习是理论性的,但我们也选取了一些编程练习——包括两个需要编程的探索性作业。我们发现偶尔的编程练习,对于加强本书的思想和增添课程的多样性很有帮助。

我们决定将本书的内容限制在基于严格数学分析的方法和技术之内,除去一些特殊情况,本书的所有定理都给出了完整的证明。很明显,许多相当有用的概率方法并不在这种严格的限制之内。例如,在蒙特卡罗方法的重要领域中,大多数实际解具有启发性,从而证实了试验估计比严格数学分析更有效。我们认为,为了很好地应用和理解启发性方法的优缺点,扎实地掌握基础概率理论和本书给出的严格技术是十分必要的。我们希望读者在学完本书之后能够喜欢这种讲述方式。

致谢

首先感谢许多曾经研究本书讲述的极好题材的概率论专家和计算机科学家。我们没有把大量原始论文作为参考文献放入书中,只是提供一些优秀的参考书目,它们给出了本书各章的背景材料和更进一步的讨论。

书中许多内容来自布朗大学 CS 155 课程和哈佛大学 CS 223 课程的学生和老师的建议和反馈。我们特别要感谢 Aris Anagnostopoulos、Eden Hochbaum、Rob Hunter 和 Adam Kirsch,他们阅读了本书的草稿,并提出了意见。

我们尤其要感谢 Dick Karp, 2003 年秋季,他在伯克利大学授课(CS 174)期间,使用了本教材的草稿,他的早期建议和修正意见对改进稿件是非常有价值的。Peter Bartlett 在 2004 年春季于伯克利大学授课(CS 174)期间,也提出了很多有用的建议和修正意见。

感谢在本书编写过程中认真读过部分初稿的同事,他们在内容及表达方面指出许多错误,提出重要的改进意见,他们是: Artur Czumaj、Alan Frieze、Claire Kenyon、Joe Marks、Salil Vadhan、Eric Vigoda。另外,感谢为出版社审稿的一些不知道姓名的评审者。

感谢 Rajeev Matwani 和 Prabhakar Raghavan 同意我们引用他们优秀的著作《Randomized Algorithms》中的某些练习。

最后感谢剑桥大学出版社的 Lauren Cowles,她在本书的准备和组织中提供了很多编辑方面的帮助和意见。

本书的写作得到了美国国家科学基金会信息技术研究基金(授权号 CCR-0121154)的部分资助。

目 录

译者序

前言

第 1 章 事件与概率	1
1.1 应用: 验证多项式恒等式	1
1.2 概率论公理	2
1.3 应用: 验证矩阵乘法	6
1.4 应用: 最小割随机化算法	10
练习	12
第 2 章 离散随机变量与期望	17
2.1 随机变量与期望	17
2.1.1 期望的线性性	18
2.1.2 詹森不等式	19
2.2 伯努利随机变量和二项随机变量	20
2.3 条件期望	22
2.4 几何分布	24
2.4.1 例: 赠券收集问题	26
2.5 应用: 快速排序的期望运行时间	28
练习	31
第 3 章 矩与高差	36
3.1 马尔可夫不等式	36
3.2 随机变量的方差和矩	37
3.2.1 例: 二项随机变量的方差	39
3.3 切比雪夫不等式	39
3.3.1 例: 赠券收集问题	40
3.4 应用: 计算中位数的随机化算法	43
3.4.1 算法	43
3.4.2 算法分析	44
练习	47
第 4 章 切尔诺夫界	50
4.1 矩母函数	50
4.2 切尔诺夫界的导出和应用	51
4.2.1 泊松试验和的切尔诺夫界	52
4.2.2 例: 投掷硬币	55

4.2.3 应用: 估计参数	55
4.3 某些特殊情况下更好的界	56
4.4 应用: 集合的均衡	58
* 4.5 应用: 稀疏网络中的数据包路由 选择	59
4.5.1 超立方体网络上排列的路由选择	59
4.5.2 蝶形网络上排列的路由选择	64
练习	68
第 5 章 球、箱子和随机图	74
5.1 例: 生日悖论	74
5.2 球和箱子模型	76
5.2.1 球和箱子模型	76
5.2.2 应用: 桶排序	77
5.3 泊松分布	78
5.3.1 二项分布的极限	80
5.4 泊松近似	82
* 5.4.1 例: 赠券收集问题再讨论	85
5.5 应用: 散列法	88
5.5.1 链散列	88
5.5.2 散列: 二进制数字串	88
5.5.3 Bloom 过滤器	89
5.5.4 放弃对称性	91
5.6 随机图	92
5.6.1 随机图模型	92
5.6.2 应用: 随机图中的 哈密顿圈	93
练习	98
探索性作业	102
第 6 章 概率方法	104
6.1 基本计数论证	104
6.2 期望论证	106
6.2.1 应用: 求最大割	106
6.2.2 应用: 最大可满足性	108
6.3 利用条件期望消除随机化	108

6.4 抽样和修改	109	8.4.3 条件到达时间分布	170
6.4.1 应用: 独立集合	110	8.5 连续时间马尔可夫过程	172
6.4.2 应用: 有较大围长的图	110	8.6 例: 马尔可夫排队论	175
6.5 二阶矩方法	111	8.6.1 均衡的 $M/M/1$ 排队	175
6.5.1 应用: 随机图的阈性质	111	8.6.2 均衡的 $M/M/1/K$ 排队	178
6.6 条件期望不等式	113	8.6.3 $M/M/\infty$ 排队中的顾客数	178
6.7 洛瓦兹局部引理	114	练习	180
6.7.1 应用: 边不相交的路径	117	第9章 熵、随机性和信息	185
6.7.2 应用: 可满足性	118	9.1 熵函数	185
*6.8 利用洛瓦兹局部引理的显式构造	118	9.2 熵和二项式系数	187
6.8.1 应用: 可满足性算法	118	9.3 熵: 随机性的测度	189
6.9 洛瓦兹局部引理: 一般情况	121	9.4 压缩	193
练习	123	*9.5 编码: 香农定理	195
第7章 马尔可夫链及随机游动	127	练习	202
7.1 马尔可夫链: 定义及表示	127	第10章 蒙特卡罗方法	208
7.1.1 应用: 2-可满足性的 随机化算法	129	10.1 蒙特卡罗方法	208
7.1.2 应用: 3-可满足性的 随机化算法	132	10.2 应用: DNF 计数问题	210
7.2 状态分类	135	10.2.1 朴素算法	210
7.2.1 例: 赌徒的破产	137	10.2.2 DNF 计数问题的完全 多项式随机方案	211
7.3 平稳分布	138	10.3 从近似抽样到近似计数	213
7.3.1 例: 简单的队列	143	10.4 马尔可夫链蒙特卡罗方法	217
7.4 无向图上的随机游动	144	10.4.1 Metropolis 算法	218
7.4.1 应用: $s-t$ 连通性算法	146	练习	220
7.5 Parrondo 悖论	146	最小支撑树的探索性作业	222
练习	150	*第11章 马尔可夫链的耦合	224
第8章 连续分布与泊松过程	155	11.1 变异距离和混合时间	224
8.1 连续随机变量	155	11.2 耦合	226
8.1.1 \mathbb{R} 中的概率分布	155	11.2.1 例: 洗牌	227
8.1.2 联合分布与条件概率	157	11.2.2 例: 超立方体上的随机 游动	228
8.2 均匀分布	159	11.2.3 例: 固定大小的独立 集合	228
8.2.1 均匀分布的其他性质	160	11.3 应用: 变异距离是不增的	230
8.3 指数分布	161	11.4 几何收敛	232
8.3.1 指数分布的其他性质	162	11.5 应用: 正常着色法的近似抽样	232
*8.3.2 例: 有反馈的球和箱子	163	11.6 路径耦合	236
8.4 泊松过程	166	练习	239
8.4.1 到达间隔分布	168		
8.4.2 组合与分解泊松过程	169		

第 12 章 鞅	244
12.1 鞅	244
12.2 停时	245
12.2.1 例: 选举定理	247
12.3 瓦尔德方程	248
12.4 鞅的尾部不等式	250
12.5 Azuma-Hoeffding 不等式的应用	252
12.5.1 一般形式	252
12.5.2 应用: 模式匹配	254
12.5.3 应用: 球和箱子	254
12.5.4 应用: 色数	255
练习	255
第 13 章 两两独立及通用散列函数	260
13.1 两两独立	260
13.1.1 例: 两两独立的二进制数字的构造	261
13.1.2 应用: 消去最大割算法的随机性	261
13.1.3 例: 构造关于一个素数模的两两独立的值	262
13.2 两两独立变量的切比雪夫不等式	263
13.2.1 应用: 利用少量随机二进制数字的抽样	264
13.3 通用散列函数族	266
13.3.1 例: 一个 2 维通用散列函数族	267
13.3.2 例: 一个 2 维强通用散列函数族	268
13.3.3 应用: 完美散列	270
13.4 应用: 在数据流中寻找重量级的源-终点	272
练习	275
第 14 章 平衡配置	278
14.1 两种选择的影响力	278
14.1.1 上界	278
14.2 两种选择: 下界	282
14.3 两种选择影响力的应用	285
14.3.1 散列	285
14.3.2 动态资源配置	285
练习	286
进一步阅读材料	289
索引	290



第1章 事件与概率

本章介绍随机化算法的思想并复习某些概率论基本概念，这些概念是分析简单随机化算法在验证代数恒等式及在图中寻找最小割集的算法性能时要涉及的。

1.1 应用：验证多项式恒等式

计算机有时也会出现错误，例如由于不正确的程序或者计算机硬件故障而引起的问题。因此，用简单方法双重检查计算结果是有用的。对于某些问题，我们可以用随机化方法有效地验证输出的正确性。

假定有一个计算单项式乘法的程序。考虑验证下面的恒等式，程序可能输出：

$$(x+1)(x-2)(x+3)(x-4)(x+5)(x-6) \stackrel{?}{=} x^6 - 7x^3 + 25.$$

有一个简单的方法验证这个恒等式是否成立：将式子左边的每一项相乘，观察得到的多项式是否与式子右边相同。在这个例子中，当我们把式子左边的所有常数项相乘以后，发现所得结果与式子右边的常数项不一样，所以上面的等式是不可能成立的。更一般地，给定两个多项式

$F(x)$ 和 $G(x)$ ，可以通过将它们变换成规范形式 $\left(\sum_{i=0}^d c_i x^i\right)$ 来验证它们是否恒等：

$$F(x) \stackrel{?}{=} G(x);$$

两个多项式等价，当且仅当它们的规范形式中的所有系数都相等。基于此，我们假定 $F(x)$ 为

乘积形式 $F(x) = \prod_{i=1}^d (x - a_i)$ ，而 $G(x)$ 为规范形式。连续地将 $F(x)$ 的第 i 个单项式与前面 $i-1$

个单项式的乘积相乘，如此把 $F(x)$ 变换成规范形式，需要做 $\Theta(d^2)$ 次系数相乘。虽然随着系数的不断增多，执行加法和乘法的时间不可避免地增加，但我们仍然假定每一次相乘需要的时间相同。

到目前为止，我们并没有涉及任何特别有意义的内容。为了检查计算程序所做的单项式乘法是否正确，我们假定重新进行单项式的乘法，并检查其结果。检查程序的方法是编写另一个程序，以解决本质上与我们希望第一个程序所做的是同样的问题。这当然是一种双重检查程序的方法：编写做同样事情的另外一个程序，并确认结果完全一致。但是由于在检查一个已知答案和重新计算原来问题之间存在着差别，这种方法至少存在两个问题。首先，如果在计算单项式乘法的程序中存在错误，那么在检测程序中可能也存在同样的错误。（假定检测程序和原始程序都是由同一个人编写的！）其次，我们更愿意花较少的时间去检验答案是否正确，而不想花时间去重新解决最初的问题，这是合乎情理的。

我们代之以随机化方法来获得一种更快的验证恒等式的方法。首先非形式地解释这种算

法, 然后建立形式的数学框架来分析算法.

设 $F(x)$ 和 $G(x)$ 的最高阶或 x 的最高次数为 d . 随机化算法首先是从 $\{1, \dots, 100d\}$ 中均匀随机地选取一个整数 r , 这里“均匀随机”是指取到每个整数是等可能的, 然后计算 $F(r)$ 和 $G(r)$ 的值. 如果 $F(r) \neq G(r)$, 则算法判定两个多项式不等价; 如果 $F(r) = G(r)$, 则算法判定两个多项式等价.

假设在一个计算步骤中, 算法可以产生一个从 $\{1, \dots, 100d\}$ 中均匀随机地选取的整数 r , 计算 $F(r)$ 和 $G(r)$ 的值需要 $O(d)$ 时间, 要快于计算 $F(r)$ 的规范形式. 但是, 这种随机化算法有可能给出错误的结果.

为什么随机化算法会给出错误的结果呢?

如果 $F(x) = G(x)$, 由于对任意的 r , 都有 $F(r) = G(r)$, 那么算法将给出正确的结论.

如果 $F(x) \neq G(x)$ 并且 $F(r) \neq G(r)$, 算法发现 $F(x)$ 和 $G(x)$ 不一致的情形, 于是给出正确的答案. 因此, 当算法判定两个多项式不相同, 答案总是正确的.

如果 $F(x) \neq G(x)$ 但 $F(r) = G(r)$, 那么算法给出错误的结论. 换句话说, 当两个多项式不相等的时候, 算法可能会给出它们相等的结论. 当 r 是方程 $F(x) - G(x) = 0$ 的根时, 必然会出现上述错误. 如果多项式 $F(x) - G(x)$ 的最高次数不大于 d , 根据代数基本定理, 最高次数为 d 的多项式不可能有多于 d 个根. 于是, 当 $F(x) \neq G(x)$ 时, 在 $\{1, \dots, 100d\}$ 范围内, 不可能有多于 d 个值, 使得 $F(r) = G(r)$. 因为在 $\{1, \dots, 100d\}$ 范围内只有 $100d$ 个值, 所以算法选取一个值并给出错误答案的机会不会大于 $1/100$.

1.2 概率论公理

现在我们回到正式的数学背景来分析随机化算法. 任何一个概率命题必然涉及基本概率空间.

定义 1.1 概率空间的三要素:

1. 样本空间 Ω , 一个以概率空间作为模型的随机过程所有可能结果的集合.
2. 表示可容许事件的集族 \mathcal{F} , 其中 \mathcal{F} 中的每个集合都是样本空间 Ω 的子集.
3. 满足定义 1.2 的概率函数 $\text{Pr}: \mathcal{F} \rightarrow \mathbb{R}$.

Ω 中的每一个元素称为简单事件或基本事件.

在验证多项式恒等式的随机化算法中, 样本空间是整数集合 $\{1, \dots, 100d\}$, 在这个范围内的每个整数 r 的选取为一个简单事件.

定义 1.2 概率函数是任意一个满足下列条件的函数 $\text{Pr}: \mathcal{F} \rightarrow \mathbb{R}$:

1. 对于任意的事件 E , $0 \leq \text{Pr}(E) \leq 1$.
2. $\text{Pr}(\Omega) = 1$.
3. 对任意两两互不相交事件的有限或可数无穷序列 E_1, E_2, E_3, \dots , 有

$$\text{Pr}\left(\bigcup_{i \geq 1} E_i\right) = \sum_{i \geq 1} \text{Pr}(E_i).$$

本书中的大部分内容都将用到离散概率空间. 在离散概率空间中, 样本空间 Ω 是有限集或可数无穷集, 而可容许事件族 \mathcal{F} 由样本空间 Ω 中的所有子集构成. 在离散概率空间中, 概率函数由简单事件的概率唯一确定.

在验证多项式恒等式的随机化算法中, 整数 r 的每次选取为一个简单事件. 因为算法是均匀随机地选取整数 r , 所以所有简单事件是等概率的. 样本空间有 $100d$ 个简单事件, 所有简单事件的概率之和必须为 1, 所以每一个简单事件的概率为 $1/100d$.

由于事件是集合, 我们用标准的集合论记号来表示事件组合. 用 $E_1 \cap E_2$ 表示事件 E_1 和 E_2 同时发生, $E_1 \cup E_2$ 表示事件 E_1 或 E_2 (或两者) 发生. 例如, 投掷两粒骰子, E_1 代表第一粒骰子点数为 1 事件, E_2 代表第二粒骰子点数为 1 事件, 则 $E_1 \cap E_2$ 表示两粒骰子点数都为 1 事件, 而 $E_1 \cup E_2$ 表示至少有一粒骰子点数为 1 事件. 类似地, $E_1 - E_2$ 表示事件 E_1 发生, 而事件 E_2 没有发生. 在上面的例子中, $E_1 - E_2$ 表示第一粒骰子点数为 1, 而第二粒骰子点数不为 1 事件. \bar{E} 表示 $\Omega - E$; 例如, 如果 E 代表投掷骰子得到偶数点事件, 那么 \bar{E} 表示得到奇数点事件.

由定义 1.2 引出如下显然的引理.

引理 1.1 对于任意两个事件 E_1 和 E_2 ,

$$\Pr(E_1 \cup E_2) = \Pr(E_1) + \Pr(E_2) - \Pr(E_1 \cap E_2).$$

证明 由定义,

$$\Pr(E_1) = \Pr(E_1 - (E_1 \cap E_2)) + \Pr(E_1 \cap E_2),$$

$$\Pr(E_2) = \Pr(E_2 - (E_1 \cap E_2)) + \Pr(E_1 \cap E_2),$$

$$\Pr(E_1 \cup E_2) = \Pr(E_1 - (E_1 \cap E_2)) + \Pr(E_2 - (E_1 \cap E_2)) + \Pr(E_1 \cap E_2).$$

因此引理得证. ■

定义 1.2 的一个推论称为并的界. 它虽然十分简单, 但是极其有用.

引理 1.2 对任意有限或可数无穷的事件序列 E_1, E_2, \dots , 总有

$$\Pr\left(\bigcup_{i=1}^{\infty} E_i\right) \leq \sum_{i=1}^{\infty} \Pr(E_i).$$

注意引理 1.2 与定义 1.2 中的第三个条件的区别, 定义 1.2 中是等式, 并且要求事件两两互不相交.

推广引理 1.1 可以得到如下等式, 通常称为容斥原理.

引理 1.3 设 E_1, \dots, E_n 为任意 n 个事件, 则

$$\begin{aligned} \Pr\left(\bigcup_{i=1}^n E_i\right) &= \sum_{i=1}^n \Pr(E_i) - \sum_{i < j} \Pr(E_i \cap E_j) + \sum_{i < j < k} \Pr(E_i \cap E_j \cap E_k) - \dots \\ &\quad + (-1)^{r+1} \sum_{i_1 < i_2 < \dots < i_r} \Pr\left(\bigcap_{s=1}^r E_{i_s}\right) + \dots \end{aligned}$$

容斥原理的证明留作练习 1.7.

我们在前面已经指出, 只有当输入的两个多项式 $F(x)$ 和 $G(x)$ 不等价时, 随机化算法可能会给出不正确的答案; 如果选择的随机数是多项式 $F(x) - G(x)$ 的根, 随机化算法就给出不正确的答案. 设 E 表示算法不能给出正确答案事件, 相应于事件 E 的集合中的元素是多项式 $F(x) - G(x)$ 的根, 且在整数集合 $\{1, \dots, 100d\}$ 中. 因为多项式不会有多于 d 个根, 所以事

件 E 不会有多于 d 个简单事件, 所以

$$\Pr(\text{算法失败}) = \Pr(E) \leq \frac{d}{100d} = \frac{1}{100}.$$

一个算法可能返回错误的答案, 这看上去或许是不正常的. 把算法的正确性当作一个目标, 并试图与其他目标一起优化, 这是有帮助的. 在设计一个算法时, 一般希望能极小化计算步骤和占用的内存. 但有时需要进行一下权衡: 是需要占用较多内存的较快算法, 还是占用较少内存的较慢算法. 前面介绍的随机化算法就给出了在正确性与速度之间的一种权衡. 允许算法可以给出不正确的答案(在系统意义上), 在设计算法时就增加了权衡的余地. 但是请放心, 正如我们将要提到的, 并不是所有的随机化算法都会给出不正确的答案.

对于前面刚刚讨论过的算法, 即使当两个多项式不等价时, 算法仍会给出 99% 的正确答案. 能否改进这个概率呢? 一种方法是从一个更大的整数范围内选取随机数 r . 如果样本空间为整数集合 $\{1, \dots, 1000d\}$, 则错误答案的概率至多为 $1/1000$. 但在某些时候, 我们可用的取值范围受限于运行算法的计算机的精度.

另一种方法是用不同的随机数多次重复地运行算法来检验恒等式. 这里我们利用算法具有单边错误的性质. 只有在输出为两个多项式等价时, 算法才有可能出错. 如果某次运行产生一个数 r , 使得 $F(r) \neq G(r)$, 则多项式不等价. 于是, 如果多次重复运行算法, 至少有一轮运行中出现 $F(r) \neq G(r)$, 我们就可以知道 $F(r)$ 和 $G(r)$ 不等价, 而只有当所有运行都相等时, 算法的输出才为两个多项式等价.

在重复运行算法时, 我们也要多次从范围 $\{1, \dots, 100d\}$ 中选取随机数. 按一个已知分布重复地抽取随机数一般称为抽样. 这样, 我们有两种方法从 $\{1, \dots, 100d\}$ 中重复地抽取随机数: 即有放回抽样和无放回抽样. 有放回抽样指不必记住哪些数已经在以前的检验中用过; 不管以前的抽样情况, 每次运行算法都从 $\{1, \dots, 100d\}$ 中均匀随机地选取一个数, 所以存在某种机会, 抽到一个在以前运行时曾经抽到过的 r . 无放回抽样是指一旦选取了一个数 r , 就不容许在以后的运行中再选这个数. 在一次迭代中选取的数是在以前没有被选取的整数范围内均匀地遍取的.

首先考虑有放回的抽样. 假设重复算法 k 次, 并且输入的两个多项式不等价. 那么在 k 次迭代中, 从集合 $\{1, \dots, 100d\}$ 中随机抽取的数是多项式 $F(x) - G(x)$ 的根, 而使算法给出错误输出的概率是多少? 如果 $k=1$, 这个概率至多为 $d/100d = 1/100$. 如果 $k=2$, 第一次迭代抽到一个根的概率为 $1/100$, 第二次迭代抽到根的概率也是 $1/100$, 从而两次迭代都抽到根的概率至多为 $(1/100)^2$. 一般地, 对任意的 k , k 次迭代都抽到根的概率至多为 $(1/100)^k$.

为了用一个式子来表示上述结果, 我们介绍独立的概念.

定义 1.3 两个事件 E 和 F 是独立的, 当且仅当

$$\Pr(E \cap F) = \Pr(E) \cdot \Pr(F).$$

更一般地, 事件 E_1, E_2, \dots, E_k 两两独立, 当且仅当对任意的子集 $J \subseteq \{1, k\}$,

$$\Pr\left(\bigcap_{i \in J} E_i\right) = \prod_{i \in J} \Pr(E_i).$$

如果采用有放回抽样, 则在每次迭代过程中, 算法都是从集合 $\{1, \dots, 100d\}$ 中均匀随机地选取一个随机数, 于是每次迭代中的选取都与以前迭代中的选取无关. 当多项式不等价时,

设 E_i 为算法在第 i 次运行时抽到一个使 $F(r_i) - G(r_i) = 0$ 的根 r_i 这一事件, 则算法返回错误答案的概率为

$$\Pr(E_1 \cap E_2 \cap \cdots \cap E_k).$$

因为 $\Pr(E_i)$ 至多为 $d/100d$, 且因为事件 E_1, E_2, \dots, E_k 是独立的, 所以经 k 次迭代后, 算法给出错误答案的概率为

$$\Pr(E_1 \cap E_2 \cap \cdots \cap E_k) = \prod_{i=1}^k \Pr(E_i) \leq \prod_{i=1}^k \frac{d}{100d} = \left(\frac{1}{100}\right)^k.$$

因此, 算法出错的概率随着试验次数的增大而以指数级减小.

下面考虑无放回抽样的情况. 此时选取一个给定数的概率是关于以前迭代事件的条件概率.

定义 1.4 在已知事件 F 发生的条件下, 事件 E 也发生的条件概率为

$$\Pr(E|F) = \frac{\Pr(E \cap F)}{\Pr(F)}.$$

仅当 $\Pr(F) > 0$ 时, 条件概率有定义.

直观上, 我们需要在由事件 F 定义的事件集中求事件 $E \cap F$ 的概率. 因为 F 定义了受限的样本空间, 我们通过除以 $\Pr(F)$ 来归一化概率, 使得所有事件的概率和为 1. 当 $\Pr(F) > 0$ 时, 上述定义可以写成有用的形式

$$\Pr(E|F)\Pr(F) = \Pr(E \cap F).$$

注意当 E 和 F 独立, 并且 $\Pr(F) \neq 0$ 时, 我们有

$$\Pr(E|F) = \frac{\Pr(E \cap F)}{\Pr(F)} = \frac{\Pr(E)\Pr(F)}{\Pr(F)} = \Pr(E).$$

这是条件概率应当具有的一个性质; 直观上, 如果两个事件独立, 则一个事件的信息不会影响另一个事件的概率.

再次假定重复 k 次算法, 并且输入的两个多项式不等价, 那么在所有 k 次从集合 $\{1, \dots, 100d\}$ 中随机抽样的迭代中得到多项式 $F(x) - G(x)$ 的根, 从而导致算法给出错误输出的概率是多少?

如同关于有放回抽样的分析, 设 E_i 为算法第 i 次迭代中抽到的随机数 r_i 是多项式 $F(x) - G(x)$ 的根这一事件; 则算法返回错误答案的概率仍然为

$$\Pr(E_1 \cap E_2 \cap \cdots \cap E_k).$$

由条件概率的定义, 我们得到

$$\Pr(E_1 \cap E_2 \cap \cdots \cap E_k) = \Pr(E_k | E_1 \cap E_2 \cap \cdots \cap E_{k-1}) \cdot \Pr(E_1 \cap E_2 \cap \cdots \cap E_{k-1}),$$

重复这个推导可得

$$\begin{aligned} & \Pr(E_1 \cap E_2 \cap \cdots \cap E_k) \\ &= \Pr(E_1) \cdot \Pr(E_2 | E_1) \cdot \Pr(E_3 | E_1 \cap E_2) \cdots \Pr(E_k | E_1 \cap E_2 \cap \cdots \cap E_{k-1}). \end{aligned}$$

我们能得到 $\Pr(E_j | E_1 \cap E_2 \cap \cdots \cap E_{j-1})$ 的界吗? 注意至多有 d 个 r 值, 使得 $F(r) - G(r) = 0$ 成立; 如果从第 1 次到第 $j-1$ 次 ($j-1 < d$) 迭代中找到了其中的 $j-1$ 个根, 那么对无放回抽样, 在其余的 $100d - (j-1)$ 次选取中, 只有 $d - (j-1)$ 个值 r , 使得 $F(r) - G(r) = 0$ 成立. 于是

$$\Pr(E_j | E_1 \cap E_2 \cap \cdots \cap E_{j-1}) \leq \frac{d - (j-1)}{100d - (j-1)},$$

因此在 $k \leq d$ 次迭代后, 算法给出错误答案的概率以

$$\Pr(E_1 \cap E_2 \cap \cdots \cap E_k) \leq \prod_{j=1}^k \frac{d - (j-1)}{100d - (j-1)} \leq \left(\frac{1}{100}\right)^k$$

为界。因为当 $j > 1$ 时, $(d - (j-1))/(100d - (j-1)) < d/100d$, 所以犯错误的概率比有放回抽样时稍微有些改善。你可能已经注意到如果无放回地进行 $d+1$ 次抽样, 且两个多项式不等价, 我们保证能抽到一个 r , 使得 $F(r) - G(r) \neq 0$ 。于是经 $d+1$ 次迭代, 可以保证输出正确的答案。但是在 $d+1$ 点上计算多项式的值, 用标准算法需要 $\Theta(d^2)$ 次运算, 并不比确定性算法计算规范形式快。

7

既然无放回抽样算法出错的概率有较好的界, 为什么我们仍然使用有放回抽样呢? 从理论方面考虑, 在有些情况下, 有放回抽样明显地易于分析。实际上, 有放回抽样在编写算法的程序方面比较简单, 对出错概率的影响也是几乎可以忽略的, 因此是一个值得考虑的选择。

1.3 应用: 验证矩阵乘法

现在考虑另外一个例子, 其中随机性可以用来验证等式, 而且比已知的确定性算法更快。假设有三个 $n \times n$ 矩阵 A , B 和 C 。为了方便起见, 假定对模为 2 的整数计算。我们要验证下式是否成立:

$$AB = C.$$

一种方法是, 直接计算 A 与 B 的乘法, 然后将所得结果与矩阵 C 比较。简单的矩阵相乘法需要 $\Theta(n^3)$ 次运算。而一个比较复杂的算法, 仍然需要大约 $\Theta(n^{2.37})$ 次运算。

我们再次运用随机化算法, 它能较快地验证——但可能要付出以较小概率返回错误答案的代价。此算法与验证多项式恒等式的随机化算法在思想上是类似的。算法抽取一个随机向量 $\bar{r} = (r_1, r_2, \dots, r_n) \in \{0, 1\}^n$ 。然后计算 $AB\bar{r}$, 即先计算 $B\bar{r}$, 再计算 $A(B\bar{r})$, 也计算 $C\bar{r}$ 。如果 $A(B\bar{r}) \neq C\bar{r}$, 则 $AB \neq C$ 。否则返回 $AB = C$ 。

算法要求做三次矩阵-向量的乘法, 需要 $\Theta(n^2)$ 次计算。下面的定理给出了当它们实际上不相等时算法却返回 $AB = C$ 的概率的界。

定理 1.4 如果 $AB \neq C$, 且 \bar{r} 是均匀随机地从 $\{0, 1\}^n$ 中选取的, 则

$$\Pr(AB\bar{r} = C\bar{r}) \leq \frac{1}{2}.$$

证明 在证明之前, 我们指出向量 \bar{r} 的样本空间为集合 $\{0, 1\}^n$, 考虑的事件是 $AB\bar{r} = C\bar{r}$ 。首先介绍下面简单而有用的引理。■

引理 1.5 均匀随机地选取 $\bar{r} = (r_1, r_2, \dots, r_n) \in \{0, 1\}^n$ 等价于从 $\{0, 1\}$ 中独立均匀地选取每一个 r_i 。■

证明 如果每一个 r_i 都是独立且均匀随机地选取的, 那么 2^n 种可能向量 \bar{r} 中的每一个都以 2^{-n} 的概率被抽到。这就给出了引理的证明。■

设 $D = AB - C \neq 0$ 。那么 $AB\bar{r} = C\bar{r}$ 意味着 $D\bar{r} = 0$ 。由于 $D \neq 0$, 必有某个非零元素; 不

失一般性, 设非零元素为 d_{11} .

因为 $D\bar{r} = 0$, 必然有

$$\sum_{j=1}^n d_{1j} r_j = 0,$$

或等价地,

$$r_1 = -\frac{\sum_{j=2}^n d_{1j} r_j}{d_{11}}. \quad (1.1)$$

现在介绍一种有用的思想. 不考虑向量 \bar{r} , 假定我们是由 r_n 到 r_1 依次从 $\{0, 1\}$ 中独立且均匀随机地选取 r_i . 引理 1.5 指出, 按这种方法选取 r_i 与均匀随机地选取向量 \bar{r} 是等价的. 现在只考虑恰在选取 r_1 之前的情况, 此时式 (1.1) 右边是确定的, 所以能使等式成立的 r_1 至多只有一个. 由于 r_1 可以有两种选择, 所以等式成立的概率至多为 $1/2$, 于是 $AB\bar{r} = C\bar{r}$ 成立的概率至多也为 $1/2$. 现在除了 r_1 以外, 将所有变量都固定, 我们将样本空间缩减为只有 r_1 的两个值 $\{0, 1\}$ 的集合, 而问题也转化为考虑等式 (1.1) 是否成立这样一个事件.

这种思想称为延迟决策原理. 当存在多个随机变量时, 如向量 \bar{r} 中的 r_i , 则在算法中把它们中的一部分固定在某一点, 其余部分看作随机的——或延迟的——直到分析下一个点. 正式说来, 这种思想依赖于先前确定的值; 当某些随机变量取值被确定后, 必须将这些值作为条件去进行下面的分析. 我们将在本书稍后给出延迟决策原理的其他例子.

为用公式表示这种论证, 我们首先介绍一个称为全概率定律的简单事实.

定理 1.6 [全概率定律] 设 E_1, E_2, \dots, E_n 是样本空间 Ω 中互不相交事件, 且 $\bigcup_{i=1}^n E_i = \Omega$. 则

$$\Pr(B) = \sum_{i=1}^n \Pr(B \cap E_i) = \sum_{i=1}^n \Pr(B | E_i) \Pr(E_i).$$

证明 由于事件 $B \cap E_i (i=1, \dots, n)$ 互不相交且覆盖整个样本空间 Ω , 从而有

$$\Pr(B) = \sum_{i=1}^n \Pr(B \cap E_i).$$

进一步, 由条件概率的定义,

$$\sum_{i=1}^n \Pr(B \cap E_i) = \sum_{i=1}^n \Pr(B | E_i) \Pr(E_i).$$

现在由全概率定律, 对 $(x_2, x_3, x_4, \dots, x_n) \in \{0, 1\}^{n-1}$ 的所有取值求得

$$\begin{aligned} & \Pr(AB\bar{r} = C\bar{r}) \\ &= \sum_{(x_2, \dots, x_n) \in \{0, 1\}^{n-1}} \Pr((AB\bar{r} = C\bar{r}) \cap ((r_2, \dots, r_n) = (x_2, \dots, x_n))) \end{aligned}$$

$$\begin{aligned}
&\leq \sum_{(x_2, \dots, x_n) \in \{0,1\}^{n-1}} \Pr \left(\left(r_1 = -\frac{\sum_{j=2}^n d_{1j} r_j}{d_{11}} \right) \cap ((r_2, \dots, r_n) = (x_2, \dots, x_n)) \right) \\
&= \sum_{(x_2, \dots, x_n) \in \{0,1\}^{n-1}} \Pr \left(r_1 = -\frac{\sum_{j=2}^n d_{1j} r_j}{d_{11}} \right) \cdot \Pr((r_2, \dots, r_n) = (x_2, \dots, x_n)) \\
&\leq \sum_{(x_2, \dots, x_n) \in \{0,1\}^{n-1}} \frac{1}{2} \Pr((r_2, \dots, r_n) = (x_2, \dots, x_n)) \\
&= \frac{1}{2}.
\end{aligned}$$

这里第 4 行用到了 r_1 和 (r_2, \dots, r_n) 的独立性. ■

为了改善定理 1.4 给出的错误概率, 我们仍然利用算法具有单边错误的性质, 并且多次运行算法. 如果找到了某个 \bar{r} 使得 $AB\bar{r} \neq C\bar{r}$, 则算法将正确地返回 $AB \neq C$. 如果总是发现 $AB\bar{r} = C\bar{r}$, 则算法将返回 $AB = C$, 但存在一个犯错误的概率. 对每次试验从 $\{0, 1\}^n$ 中重复选取 \bar{r} , 在 k 次试验后, 我们发现出错的概率至多为 2^{-k} . 多次重复试验将运行时间增加到 $\Theta(kn^2)$.

假定我们用上述方法进行 100 次验证. 对于充分大的 n , 随机检查算法的运行时间仍为 $\Theta(n^2)$, 快于已知的矩阵乘法的确定性算法. 一个不正确的算法能通过 100 次验证检查的概率仅为 2^{-100} , 这是一个极小的数. 实际上, 在算法执行中计算机更有可能崩溃, 而不是返回一个错误的答案.

随着随机试验的重复进行, 一个感兴趣的相关问题是评估对矩阵乘法正确性信任程度的增加. 在本节的最后, 我们介绍贝叶斯定律.

定理 1.7 [贝叶斯定律] 设 E_1, E_2, \dots, E_n 是互不相交集, 且 $\bigcup_{i=1}^n E_i = E$. 则

$$\Pr(E_j | B) = \frac{\Pr(E_j \cap B)}{\Pr(B)} = \frac{\Pr(B | E_j) \Pr(E_j)}{\sum_{i=1}^n \Pr(B | E_i) \Pr(E_i)}.$$

下面的问题作为贝叶斯定律的一个简单应用. 我们得到 3 枚硬币, 已知其中两枚硬币是均匀的, 而另一枚硬币不均匀, 出现正面的概率为 $2/3$. 我们不清楚 3 枚硬币中究竟哪枚硬币是不均匀的. 将 3 枚硬币随机排列, 然后依次投掷 3 枚硬币. 前两枚硬币出现正面, 第 3 枚硬币出现反面. 那么第 1 枚硬币是不均匀的概率是多少?

硬币是随机投掷的, 所以在观测投掷硬币结果之前, 每一枚硬币都有相同的可能性是不均匀的. 设 E_i 表示第 i 次投掷的那枚硬币是不均匀的事件, B 表示投掷 3 枚硬币的结果为正面、正面、反面这一事件.

在投掷硬币之前, 对每一个 i , 我们有 $\Pr(E_i) = 1/3$. 也可以算出事件 E_i 的条件下事件 B 的概率:

$$\Pr(B | E_1) = \Pr(B | E_2) = \frac{2}{3} \cdot \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{6},$$

及

$$\Pr(B | E_3) = \frac{1}{2} \cdot \frac{1}{2} \cdot \frac{1}{3} = \frac{1}{12}.$$

由贝叶斯定律, 有

$$\Pr(E_1 | B) = \frac{\Pr(B | E_1) \Pr(E_1)}{\sum_{i=1}^3 \Pr(B | E_i) \Pr(E_i)} = \frac{2}{5}.$$

于是, 当知道 3 枚硬币的投掷结果时, 第 1 枚硬币不均匀的可能性从 $1/3$ 增大到 $2/5$.

现在回到随机矩阵乘法检验, 我们希望评估由重复检验得到的对矩阵相等信任程度的增加. 贝叶斯方法从先验模型出发, 并对模型参数赋予初值, 然后通过新的观测值来修正模型, 从而得到包含新信息的后验模型.

在矩阵乘法中, 如果没有关于生成恒等式过程的信息, 那么一个合理的先验假定是等式成立的概率为 $1/2$. 如果运行随机化检验一次, 并且返回矩阵等式成立, 那么这将如何改变我们对等式成立的信任呢?

设 E 表示等式成立事件, B 表示检验返回等式成立事件. 我们从 $\Pr(E) = \Pr(\bar{E}) = 1/2$ 开始, 又因为检验有 $1/2$ 的单边错误的界, 因此有 $\Pr(B | E) = 1$ 及 $\Pr(B | \bar{E}) \leq 1/2$. 由贝叶斯定律, 得

$$\Pr(E | B) = \frac{\Pr(B | E) \Pr(E)}{\Pr(B | E) \Pr(E) + \Pr(B | \bar{E}) \Pr(\bar{E})} \geq \frac{1/2}{1/2 + 1/2 \cdot 1/2} = \frac{2}{3}.$$

假设再次运行随机化检验, 而返回的结论仍然是等式成立. 在第一次检验之后, 我们自然会修改先验模型, 使得我们相信 $\Pr(E) \geq 2/3$, 而 $\Pr(\bar{E}) \leq 1/3$. 现在设 B 表示一次新的检验返回等式成立这一事件; 因为每次检验都是独立的, 如前面的分析, 我们有 $\Pr(B | E) = 1$ 和 $\Pr(B | \bar{E}) \leq 1/2$. 由贝叶斯定律可知

$$\Pr(E | B) \geq \frac{2/3}{2/3 + 1/3 \cdot 1/2} = \frac{4}{5}.$$

一般地, 如果先验模型 (在做检验之前) 是 $\Pr(E) \geq 2^i / (2^i + 1)$, 并且如果检验返回等式成立 (事件 B), 则有

$$\Pr(E | B) \geq \frac{\frac{2^i}{2^i + 1}}{\frac{2^i}{2^i + 1} + \frac{1}{2} \frac{1}{2^i + 1}} = \frac{2^{i+1}}{2^{i+1} + 1} = 1 - \frac{1}{2^i + 1}.$$

于是, 如果全部 100 次调用矩阵相等检验都返回等式成立, 那么我们对这个等式正确性的信任至少为 $1 - 1/(2^{100} + 1)$.

1.4 应用：最小割随机化算法

图的割集是一个边的集合，当去掉这些边时将图分成两个或多个连通部分。给定一个有 n 个顶点的图 $G=(V, E)$ ，最小割问题就是在图 G 中寻找一个基数最小的割集。许多领域，包括网络可靠性的研究，都有最小割问题。这里的顶点相当于网络中的机器，边相当于机器之间的连接。最小割就是使某对机器之间能互相通信的最少边数。最小割还来自聚类问题。例如，如果顶点代表网页（或者一个超文本系统中的任一文件），如果对应顶点之间有超文本链接，两个顶点之间就有一条连接它们的边，那么最小割将图分成相互之间链接很少的文档簇，不同簇中的文档是不相关的。

我们将利用已给出的定义和技术来分析最小割问题的简单的随机化算法。算法的主要运算是边的缩减。在缩减边 $|u, v|$ 时，将两个顶点 u 和 v 合并成一个顶点，删除所有连接 u 和 v 的边，保留图中所有其他的边。新图可能有并行的边，但没有自圈。例如图 1.1 所示的每一步中，黑色的粗线即是被缩减的边。

算法包括 $n-2$ 次迭代。在每次迭代中，算法从图的现有边中选出一条边并将它缩减掉。每一步都有多种可能的方法选择边，我们的随机化算法是从剩下的边中均匀随机地选择一条边。

每一次迭代都会使图中的顶点个数减少一个，经 $n-2$ 次迭代后，图只剩下两个顶点。算法输出连接这两个保留顶点的边的集合。

容易验证，在算法的中间迭代过程中，新图的任一割集也是原始图的割集。而另一方面，原始图的每一个割集并不一定是中间迭代过程中新图的割集，因为割集中的有些边可能已经在以前的迭代中被缩减了。所以，算法的输出总是原始图的割集，但不一定是最小基数割集（见图 1.1）。

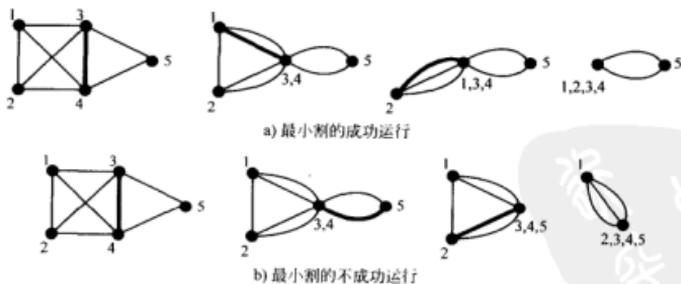


图 1.1 在长度为 2 的最小割集的图中，两种最小割执行的例子

现在我们建立算法返回正确输出概率的下界。

定理 1.8 算法至少以 $2/n(n-1)$ 的概率输出最小割集。

证明 设 k 是 G 的最小割集长度。图可能会有几个最小长度的割集。我们来计算找到某个

指定的最小割集 C 的概率.

因为 C 是图的割集, 除去集合 C 将顶点集合分成两个集合 S 和 $V-S$, 使得不存在连接 S 中的顶点到 $V-S$ 中顶点的边. 假设在整个算法运行中, 我们只缩减连接 S 中的两个顶点或 $V-S$ 中两个顶点的边, 而不是 C 中的边. 这样, 所有由算法缩减的边是连接 S 中顶点或 $V-S$ 中顶点的边, 经 $n-2$ 次迭代后, 算法返回的是由 C 中边连接的两个顶点的图. 所以, 我们可以得到结论: 如果算法在 $n-2$ 次迭代中根本不选择 C 中的边, 那么算法返回的 C 就是最小割集.

上面的讨论直观上解释了为什么要在每次迭代中均匀随机地在剩下的边中选取边. 如果割集 C 的长度较小, 并且如果算法在每一步都是均匀地选择边, 那么算法选取 C 中边的概率是很小的——至少当剩下的边数与 C 比较相对较大时.

设 E_i 表示第 i 次迭代时缩减的边不在 C 中这一事件, $F_i = \bigcap_{j=1}^i E_j$ 表示在前 i 次迭代中没有缩减 C 中的边. 我们需要计算 $\Pr(F_{n-2})$.

我们从计算 $\Pr(E_1) = \Pr(F_1)$ 开始. 因为最小割集有 k 条边, 所以图中所有顶点的次数必至少为 k 或更大. 如果每个顶点至少连接 k 条边, 则图中至少有 $nk/2$ 条边. 第一条缩减边是从所有边中均匀随机地选取的. 因为图中至少有 $nk/2$ 条边, 且 C 有 k 条边, 所以第一次迭代没有选取 C 中边的概率为

$$\Pr(E_1) = \Pr(F_1) \geq 1 - \frac{2k}{nk} = 1 - \frac{2}{n}. \quad [13]$$

假设第一次缩减没有消去 C 中的边. 换句话说, 我们给出事件 F_1 成立的条件. 第一次迭代后, 我们得到一个有 $n-1$ 个顶点和最小割集长度为 k 的新图. 仍然假定图中每一个顶点的次数必至少为 k , 图必至少有 $k(n-1)/2$ 条边. 于是,

$$\Pr(E_2 | F_1) \geq 1 - \frac{k}{k(n-1)/2} = 1 - \frac{2}{n-1}.$$

类似地,

$$\Pr(E_i | F_{i-1}) \geq 1 - \frac{k}{k(n-i+1)/2} = 1 - \frac{2}{n-i+1}.$$

为了计算 $\Pr(F_{n-2})$, 我们利用

$$\begin{aligned} \Pr(F_{n-2}) &= \Pr(E_{n-2} \cap F_{n-3}) = \Pr(E_{n-2} | F_{n-3}) \cdot \Pr(F_{n-3}) \\ &= \Pr(E_{n-2} | F_{n-3}) \cdot \Pr(E_{n-3} | F_{n-4}) \cdots \Pr(E_2 | F_1) \cdot \Pr(F_1) \\ &\geq \prod_{i=1}^{n-2} \left(1 - \frac{2}{n-i+1}\right) = \prod_{i=1}^{n-2} \left(\frac{n-i-1}{n-i+1}\right) \\ &= \left(\frac{n-2}{n}\right) \left(\frac{n-3}{n-1}\right) \left(\frac{n-4}{n-2}\right) \cdots \left(\frac{4}{6}\right) \left(\frac{3}{5}\right) \left(\frac{2}{4}\right) \left(\frac{1}{3}\right) \\ &= \frac{2}{n(n-1)}. \quad \blacksquare \end{aligned}$$

因为算法具有单边错误的性质，我们可以重复运行算法来减小出错概率。假设运行最小割随机化算法 $n(n-1)\ln n$ 次，并输出在所有次迭代中找到的最小长度割集。输出不是一个最小割集的概率界为

$$\left(1 - \frac{2}{n(n-1)}\right)^{n(n-1)\ln n} \leq e^{-2\ln n} = \frac{1}{n^2}.$$

在第一个不等式中，我们用到了 $1-x \leq e^{-x}$ 。

练习

- 1.1 投掷均匀的硬币 10 次，计算下列事件的概率：
- 出现正面的次数和出现反面的次数相同。
 - 出现正面的次数大于出现反面的次数。
 - 第 i 次出现的情况与第 $(11-i)$ 次出现的情况相同，其中 $i=1, \dots, 5$ 。
 - 至少连续出现 4 次正面。
- 1.2 投掷两粒标准的正六面体骰子。设两粒骰子的投掷结果是相互独立的，计算下列事件的概率：
- 两粒骰子出现相同的点数。
 - 第一粒骰子出现的点数大于第二粒骰子出现的点数。
 - 两粒骰子点数之和为偶数。
 - 两粒骰子点数乘积是完全平方数。
- 1.3 我们洗一副标准扑克牌，得到的一种组合在 $52!$ 种可能的组合中是均匀分布的。计算下列事件的概率：
- 前两张牌中至少有一张 A。
 - 前五张牌中至少有一张 A。
 - 前两张牌是一对同样大小的牌。
 - 前五张牌的花色都为方片。
 - 前五张牌形成满堂红（三张是同样大小的牌，另外两张是另一种同样大小的牌）。
- 1.4 我们正在参加一场比赛，只要我们中间有一人赢得了 n 局，比赛立即结束。假定比赛在两人间公平进行，即每人赢得一局比赛的概率都为 $1/2$ ，与其他不同局的结果无关。那么比赛结束时，失败一方已经赢得 k 局的概率是多少？
- 1.5 一天吃完饭后，Alice 向 Bob 提出建议，用下面的方法决定由谁付账。Alice 从她的口袋里拿出 3 颗六面体骰子，但是这些骰子不是标准的，各个面上的点数如下：
- 骰子 A: 1, 1, 6, 6, 8, 8。
 - 骰子 B: 2, 2, 4, 4, 9, 9。
 - 骰子 C: 3, 3, 5, 5, 7, 7。
- 每一粒骰子都是均匀的，即每个点数出现的概率相同。Alice 解释游戏规则：她和 Bob 都

选一粒骰子，然后投掷，点数低的人输，负责付账。为了表示自己并不占有优势，Alice 让 Bob 先选择骰子。

- (a) 假定 Bob 选择骰子 A，Alice 选择骰子 B。写出所有可能事件以及它们发生的概率，证明 Alice 赢的概率大于 $1/2$ 。
- (b) 假定 Bob 选择骰子 B，Alice 选择骰子 C。写出所有可能事件以及它们发生的概率，证明 Alice 赢的概率大于 $1/2$ 。
- (c) 因为选择骰子 A 和 B 都对 Alice 有利，所以 Bob 似乎应该选择骰子 C。假定 Bob 确实选择骰子 C，而 Alice 选择骰子 A。写出所有可能事件以及它们发生的概率，证明 Alice 赢的概率仍然大于 $1/2$ 。

1.6 考虑下面的球和箱子游戏。从一个箱子中有 1 个黑球和 1 个白球开始，然后反复地按以下方式进行：从箱子里均匀随机地取出一球，然后把它与另一个同色球一起放回箱子。这样重复下去，直到箱子中有 n 个球为止。证明白球数可以等可能地为 1 到 $n-1$ 中的任何数。

- 1.7 (a) 证明引理 1.3，即容斥原理。
 (b) 当 ℓ 为奇数时，证明

$$\Pr\left(\bigcup_{i=1}^n E_i\right) \leq \sum_{i=1}^n \Pr(E_i) - \sum_{i < j} \Pr(E_i \cap E_j) + \sum_{i < j < k} \Pr(E_i \cap E_j \cap E_k) - \cdots + (-1)^{\ell+1} \sum_{i_1 < i_2 < \cdots < i_\ell} \Pr(E_{i_1} \cap \cdots \cap E_{i_\ell}).$$

- (c) 当 ℓ 为偶数时，证明

$$\Pr\left(\bigcup_{i=1}^n E_i\right) \geq \sum_{i=1}^n \Pr(E_i) - \sum_{i < j} \Pr(E_i \cap E_j) + \sum_{i < j < k} \Pr(E_i \cap E_j \cap E_k) - \cdots + (-1)^{\ell+1} \sum_{i_1 < i_2 < \cdots < i_\ell} \Pr(E_{i_1} \cap \cdots \cap E_{i_\ell}).$$

- 1.8 从 $[1, 1\,000\,000]$ 范围内均匀随机地抽取一个数。运用容斥原理计算这个数能被 4, 6, 9 中之一或更多个整除的概率。
- 1.9 投掷一枚均匀硬币 n 次。对 $k > 0$ ，计算连续出现 $\log_2 n + k$ 次正面的概率的上界。
- 1.10 有一枚均匀的硬币和一枚两面都是头像（正面）的硬币，以相同概率从这两枚硬币中随机选择一枚并投掷。已知投掷结果是出现正面，那么投掷的是两面头像硬币的概率是多少？
- 1.11 我正准备向你发一个要么是 0 要么是 1 的位信号，当发送这个位信号后，经 n 个中继站你才能收到。每一个中继站独立地以概率 p 翻转位信号。
 (a) 证明你收到正确位信号的概率为

$$\sum_{k=0}^{\lfloor n/2 \rfloor} \binom{n}{2k} p^{2k} (1-p)^{2k}.$$

- (b) 考虑用另外一种方法来计算这个概率. 如果中继站以概率 $(1-q)/2$ 翻转位信号, 我们称这个中继站有偏差 q , 所以 q 是 $[-1, 1]$ 之间的一个实数. 证明位信号通过两个偏差分别为 q_1 和 q_2 的中继站发送等价于通过一个偏差为 q_1, q_2 的中继站发送.
- (c) 证明: 当位信号通过如前面(a)所述的 n 个中继站传送, 你能收到正确位信号的概率为

$$\frac{1 + (2p - 1)^n}{2}.$$

- 1.12 依照游戏节目“让我们做一次交易”的主持人的名字, 下面的问题称为 Monty Hall 问题. 有三块幕布, 一块幕布的后面有一辆新汽车, 其余两块幕布后边是山羊. 游戏是这样进行的: 参赛者选择一块他认为后面有汽车的幕布, 然后主持人 Monty 拉开其余两块幕布中的一块, 看到的是一只山羊. (Monty 可能有不止一只山羊的选择, 这时假定他均匀随机地选择展示哪一只羊.) 这时, 参赛者可以停在他原来选的幕布那儿, 或者换到另一块未拉开的幕布那儿. 在展现了汽车的位置后, 参赛者赢得汽车或是另一只山羊. 参赛者应不应该换幕布, 或者换不换没有任何区别吗?
- 1.13 对某种遗传性疾病, 医药公司兜售一种新的检测技术. 假阴性率很小: 如果你有这种遗传病, 检测结果呈阳性的概率为 0.999; 假阳性率也很小: 如果你没有这种遗传病, 检测结果呈阳性的概率仅为 0.005. 假定人口的 2% 患有这种遗传疾病, 如果从均匀地选取一人进行检测, 结果呈阳性, 那么此人患有这种遗传疾病的概率为多少?
- 1.14 我准备参加一次壁球比赛, 面临的是一个只看过这个人打球、但从未交过手的参赛者. 考虑三种可能的先验模型: 我们有相同的能力, 因此每人获胜每盘的机会均等; 我的能力稍强些, 能以 0.6 的概率独立地获胜每盘; 或者他的能力稍强些, 能以 0.6 的概率独立地获胜每盘. 在我们进行比赛之前, 认为上述三种情况的可能性相同.

我们的比赛在其中一人赢得三盘时停止, 我赢了第二盘比赛, 对手赢得第一、二和四盘. 在这场比赛之后, 在后验模型中, 我应相信对手的能力稍比我强的概率是多少?

- 1.15 投掷 10 粒标准六面体骰子. 假定投掷是独立的, 它们的点数之和能被 6 整除的概率是多少? (提示: 用延迟决策原理, 考虑投掷除一粒之外所有骰子后情形.)
- 1.16 考虑下面的投掷三粒标准六面体骰子的游戏. 如果游戏者最后能使得三粒骰子的点数相同, 则获胜. 游戏者首先同时投掷所有三粒骰子; 经第一次投掷后, 游戏者可以选择三粒骰子中的任一个、两个或全部并再投掷一次; 经第二次投掷, 游戏者还可选择三粒骰子中的任一粒再投掷最后一次. 对问题(a)~(d), 假定游戏者运用下述最优化策略: 如果所有三粒骰子点数都一致, 则游戏者停止投掷并获胜; 如果两粒骰子点数一样, 则游戏者选择那个点数不一样的骰子再投掷一次; 如果三粒骰子点数全都不同, 则重新投掷全部骰子.

(a) 计算第一次投掷时, 三粒骰子点数都相同的概率.

(b) 计算第一次投掷时, 三粒骰子中恰有两粒骰子点数相同的概率.

(c) 计算在第一次投掷时三粒骰子中恰有两粒点数相同的条件下, 游戏者获胜的概率.

(d) 考虑所有可能的投掷情况, 计算游戏者获胜的概率.

1.17 在我们的矩阵乘法算法中, 整数模取为 2. 如果整数模取为 k , $k > 2$, 说明分析将会发生怎样的变化.

1.18 有一个函数 $F: \{0, \dots, n-1\} \rightarrow \{0, \dots, m-1\}$, 并且知道对于 $0 \leq x, y \leq n-1$, 有 $F((x+y) \bmod n) = (F(x) + F(y)) \bmod m$. 计算 F 值的唯一方法是查找存储有 F 值的表. 可是在我们没有注意时, 恶魔篡改了表格中 $1/5$ 的数据.

设计一种简单的随机化算法: 给定一个输入 z , 输出一个至少以 $1/2$ 概率等于 $F(z)$ 的值. 无论恶魔改了什么样的数值, 算法都会对每个 z 值进行运算. 要求算法查找尽可能少的表以及使用尽可能少的计算.

假定允许重复你的初始算法三次. 那么此时你应该做什么? 用改进算法得到正确答案的概率是多少?

1.19 给出事件的例子, 使得 $\Pr(A|B) < \Pr(A)$, $\Pr(A|B) = \Pr(A)$ 和 $\Pr(A|B) > \Pr(A)$.

1.20 如果 E_1, E_2, \dots, E_n 相互独立, 证明 $\bar{E}_1, \bar{E}_2, \dots, \bar{E}_n$ 也相互独立.

1.21 给出三个随机事件 X, Y, Z 的例子, 其中任意两个独立, 但是三个事件不相互独立.

1.22 (a) 考虑集合 $\{1, \dots, n\}$, 按照下面的方法得到该集合的子集 X : 对应于集合中的每个元素独立地投掷一次均匀硬币; 如果硬币正面朝上, 那么这个元素属于集合 X , 否则不属于. 证明这样确定的子集 X 等可能地为全部 2^n 个可能子集中的任一个.

(b) 假定从 $\{1, \dots, n\}$ 的全部 2^n 个子集中独立且均匀随机地选取两个子集 X 和 Y . 确定 $\Pr(X \subseteq Y)$ 和 $\Pr(X \cup Y = \{1, \dots, n\})$. (提示: 用本题(a)中的结论.)

1.23 在一个图中可能有几个不同的最小割集. 利用最小割随机化算法的分析, 证明至多有 $n(n-1)/2$ 个不同的最小割集.

1.24 推广割集的概念, 将图中一个 r 路割集定义为某些边的集合, 如果除去这个边的集合, 将使图分成 r 个或更多个连通部分. 说明如何将最小割随机化算法用于求最小 r 路割集, 并给出经一次迭代即可成功的概率界.

1.25 为了改进最小割随机化算法的成功概率, 可以多次运行算法.

(a) 考虑运行算法两次, 计算缩减的边数并求出找到最小割的概率界.

(b) 考虑如下变化: 从有 n 个顶点的图开始, 利用最小割随机化算法, 首先将图缩减为 k 个顶点; 复制此 k 个顶点的新图, 对它独立地运行随机化算法 ℓ 次, 计算缩减的边数, 并求出找到最小割的概率界.

(c) 对于(b)中的变化, 求最优的(或至少是接近最优的) k 和 ℓ 值, 使找到与运行原算法两次有相同缩减边数的最小割的概率达到最大.

1.26 如果游戏双方都知道井字棋游戏最优策略, 那么双方最终以打成平手结束井字棋游戏. 所以我们对井字棋游戏作一些随机改动.

(a) 第一种改动: 根据一次独立的均匀硬币的投掷来决定九个方格中每一格是标上 X 还

是 O 。如果只有一个选手得到了一个获胜的井字棋组合(相同字母组成一条或多条线——译者注), 则此选手获胜; 否则比赛为平局。计算 X 获胜的概率。(可以用计算机程序帮助运行。)

- (b) 第二种改动: X 和 O 轮流, 并且 X 先手。在轮到 X 游戏者时, 从剩余的空格中独立且均匀随机地选取一个空格, 并放入 X ; 轮到 O 时, 类似地进行。第一个得到获胜的井字棋组合的选手赢得比赛; 如果没有选手能完成获胜组合, 比赛为平局。计算每位选手获胜的概率。(可以编写一个程序来帮助运行。)



第2章 离散随机变量与期望

本章我们介绍离散随机变量与期望的概念，然后给出分析算法的期望特性的基本方法，并应用这些方法计算众所周知的快速排序法的期望运行时间。在分析两种形式的快速排序法中，我们演示随机化算法分析（由算法的随机选择来定义其概率空间）与确定性算法的概率分析（由输入的某个概率分布来定义其概率空间）之间的区别。

首先定义伯努利随机变量、二项随机变量和几何随机变量，然后研究简单分支过程的期望大小，最后分析一个本书中多次出现的概率范例——赠券收集问题的期望值。

2.1 随机变量与期望

在研究一个随机事件时，我们感兴趣的常常是与随机事件有关的某些值，而不是事件本身。例如投掷两粒骰子，我们通常对两粒骰子点数之和感兴趣，而不关心每粒骰子的点数是多少。投掷两粒骰子的样本空间由 36 个等概率事件组成，由数字的有序对 $\{(1, 1), (1, 2), \dots, (6, 5), (6, 6)\}$ 给出。如果我们关心的量是两粒骰子的点数之和，那么会关注 11 个（具有不等概率的）随机事件：11 种可能的点数之和。任何一个这种从样本空间到实数的函数都称为随机变量。

定义 2.1 在样本空间 Ω 上的一个随机变量 X 是 Ω 上的一个实值函数，即 $X: \Omega \rightarrow \mathbb{R}$ 。只取有限个值或者可数无穷个值的随机变量称为离散随机变量。

由于随机变量是函数，常常用像 X 或 Y 那样的大写字母表示，而实数通常用小写字母表示。

对于一个离散随机变量 X 和一个实数 a ，事件“ $X=a$ ”包含样本空间中随机变量 X 取值为 a 的所有基本事件。即“ $X=a$ ”表示集合 $\{s \in \Omega \mid X(s) = a\}$ ， $\#$

$$\Pr(X = a) = \sum_{s \in \Omega: X(s) = a} \Pr(s)$$

表示这个事件的概率。如果 X 是表示两粒骰子点数之和的随机变量，那么事件 $X=4$ 相应于基本事件 $\{(1, 3), (2, 2), (3, 1)\}$ 的集合。因此

$$\Pr(X = 4) = \frac{3}{36} = \frac{1}{12}.$$

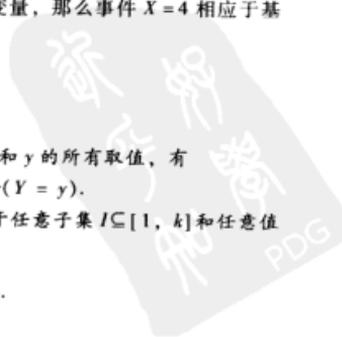
我们把事件独立性的定义推广到随机变量。

定义 2.2 两个随机变量 X 和 Y 是独立的，当且仅当对于 x 和 y 的所有取值，有

$$\Pr((X = x) \cap (Y = y)) = \Pr(X = x) \cdot \Pr(Y = y).$$

类似地，随机变量 X_1, X_2, \dots, X_k 是相互独立的，当且仅当对于任意子集 $I \subseteq [1, k]$ 和任意值 $x_i, i \in I$ ，有

$$\Pr\left(\bigcap_{i \in I} X_i = x_i\right) = \prod_{i \in I} \Pr(X_i = x_i).$$



随机变量的一个基本特征是它的期望. 随机变量的期望是它可能取值的加权平均, 每个值的权为变量取该值的概率.

定义 2.3 离散随机变量 X 的期望, 用 $E[X]$ 表示, 由

$$E[X] = \sum_i i \Pr(X = i)$$

给出, 其中求和是对 X 值域内所有值进行的. 如果 $\sum_i |i| \Pr(X=i)$ 收敛, 则期望有限; 否则, 期望无界.

例如, 表示两粒骰子点数之和的随机变量 X 的期望为

$$E[X] = \frac{1}{36} \cdot 2 + \frac{2}{36} \cdot 3 + \frac{3}{36} \cdot 4 + \cdots + \frac{1}{36} \cdot 12 = 7.$$

可以尝试用对称性简单地说明为什么 $E[X] = 7$.

举一个离散随机变量的期望无界的例子. 考虑随机变量 X , 其取值为 2^i 的概率是 $1/2^i$, 其中 $i=1, 2, \dots$, 则 X 的期望是

$$E[X] = \sum_{i=1}^{\infty} \frac{1}{2^i} 2^i = \sum_{i=1}^{\infty} 1 = \infty.$$

这里使用了一个不太正式的记号 $E[X] = \infty$ 来表示 $E[X]$ 无界.

2.1.1 期望的线性性

期望的一个重要性质是期望的线性性, 这可以显著简化期望的计算. 根据这个性质, 多个随机变量之和的期望等于各个随机变量的期望之和. 对于正规的表述, 我们有如下定理.

定理 2.1 [期望的线性性] 对于任意一组有限个具有有限期望的离散随机变量 X_1, X_2, \dots, X_n ,

$$E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i].$$

证明 对两个随机变量 X 和 Y 证明这个命题, 由归纳法可知一般情况下成立. 下面的求和理解是在相应随机变量的值域上进行:

$$\begin{aligned} E[X+Y] &= \sum_i \sum_j (i+j) \Pr((X=i) \cap (Y=j)) \\ &= \sum_i \sum_j i \Pr((X=i) \cap (Y=j)) + \sum_i \sum_j j \Pr((X=i) \cap (Y=j)) \\ &= \sum_i i \sum_j \Pr((X=i) \cap (Y=j)) + \sum_j j \sum_i \Pr((X=i) \cap (Y=j)) \\ &= \sum_i i \Pr(X=i) + \sum_j j \Pr(Y=j) \\ &= E[X] + E[Y]. \end{aligned}$$

由定义 1.2 得到第一个等式, 由定理 1.6 全概率定律得到倒数第二个等式. ■

我们现在应用这个性质来计算两粒标准骰子点数之和的期望. 记 $X = X_1 + X_2$, 其中 X_i 表示骰子 i 的点数, 其中 $i=1, 2$. 则

$$E[X_i] = \frac{1}{6} \sum_{j=1}^6 j = \frac{7}{2}.$$

由期望的线性性，我们有

$$E[X] = E[X_1] + E[X_2] = 7. \quad [22]$$

值得强调的是，期望的线性性对任意随机变量集都成立，即使它们不是独立的。例如，仍然考虑前面的例题，记 $Y = X_1 + X_1^2$ ，即使 X_1 和 X_1^2 显然相关，我们仍然有

$$E[Y] = E[X_1 + X_1^2] = E[X_1] + E[X_1^2].$$

考虑 X_1 的六种可能的点数，作为练习，读者可以验证上述等式。

在某些情况下，期望的线性性对于可数无穷个随机变量之和仍然成立，特别是只要

$\sum_{i=1}^{\infty} E[|X_i|]$ 收敛，便可证明

$$E\left[\sum_{i=1}^{\infty} X_i\right] = \sum_{i=1}^{\infty} E[X_i].$$

关于可数无穷和期望的线性性，在练习 2.29 中将有进一步的深入讨论。

本章中的几个例子说明期望的线性性可以显著简化期望的计算。下面的简单引理是一个与期望的线性性有关的结果。

引理 2.2 对于任意的常数 c 和离散随机变量 X ,

$$E[cX] = cE[X].$$

证明 对于 $c=0$ 引理显然成立。当 $c \neq 0$ 时，

$$\begin{aligned} E[cX] &= \sum_j j \Pr(cX = j) \\ &= c \sum_j (j/c) \Pr(X = j/c) \\ &= c \sum_k k \Pr(X = k) \\ &= cE[X]. \end{aligned} \quad \blacksquare$$

2.1.2 詹森不等式

假设我们均匀随机地从 $[1, 99]$ 范围内选取一个正方形的边长 X ，那么面积的期望值是多少？可以将此记为 $E[X^2]$ ，认为它等于 $E[X]^2$ 是有诱惑力的，但是通过简单的计算就可以看出这是错误的。实际上， $E[X]^2 = 2500$ ，而 $E[X^2] = 9950/3 > 2500$ 。

更一般地，我们可以证明 $E[X^2] \geq (E[X])^2$ 。考虑 $Y = (X - E[X])^2$ ，随机变量 Y 是非负的，因此它的期望也必定是非负的，所以

$$\begin{aligned} 0 \leq E[Y] &= E[(X - E[X])^2] \\ &= E[X^2 - 2XE[X] + (E[X])^2] \\ &= E[X^2] - 2E[XE[X]] + (E[X])^2 \\ &= E[X^2] - (E[X])^2. \end{aligned} \quad [23]$$

由期望的线性性，得到倒数第二行等式，而根据引理 2.2 化简 $E[XE[X]] = E[X] \cdot E[X]$ ，得

到最后一行.

实际上, 不等式 $E[X^2] \geq (E[X])^2$ 是称为詹森不等式的更一般定理的一个例子. 詹森不等式指出, 对于任意的凸函数 f , 有 $E[f(X)] \geq f(E[X])$.

定义 2.4 函数 $f: \mathbb{R} \rightarrow \mathbb{R}$ 称为凸的, 如果对于任意的 x_1, x_2 及 $0 \leq \lambda \leq 1$,

$$f(\lambda x_1 + (1 - \lambda)x_2) \leq \lambda f(x_1) + (1 - \lambda)f(x_2).$$

直观上, 一个凸函数 f 具有这样的性质, 如果用直线连接凸函数图上的任意两点, 这条直线或落在图上或在图的上方. 下面的事实是定义 2.4 另一个有用的表述形式, 但我们不给出证明.

引理 2.3 如果 f 是二次可微函数, 那么 f 是凸的, 当且仅当 $f''(x) \geq 0$.

定理 2.4 [詹森不等式] 如果 f 是一个凸函数, 那么

$$E[f(X)] \geq f(E[X]).$$

证明 我们在假定 f 有一个泰勒展开式的情况下证明这个定理, 令 $\mu = E[X]$. 依据泰勒定理, 存在一个值 c , 使得

$$\begin{aligned} f(x) &= f(\mu) + f'(\mu)(x - \mu) + \frac{f''(c)(x - \mu)^2}{2} \\ &\geq f(\mu) + f'(\mu)(x - \mu), \end{aligned}$$

由凸性, $f''(x) \geq 0$. 两边同时取期望, 并且根据期望的线性性和引理 2.2, 得到如下结果:

$$\begin{aligned} E[f(X)] &\geq E[f(\mu) + f'(\mu)(X - \mu)] \\ &= E[f(\mu)] + f'(\mu)(E[X] - \mu) \\ &= f(\mu) = f(E[X]). \end{aligned}$$

[24]

练习 2.10 给出了詹森不等式的另一种证明, 它对只取有限多个值的任意随机变量 X 成立.

2.2 伯努利随机变量和二项随机变量

假定我们做一项成功概率是 p , 失败概率是 $1 - p$ 的试验. 令 Y 是一个这样随机变量, 满足

$$Y = \begin{cases} 1 & \text{如果实验成功,} \\ 0 & \text{否则.} \end{cases}$$

变量 Y 称为伯努利或示性随机变量. 注意, 对伯努利随机变量,

$$E[Y] = p \cdot 1 + (1 - p) \cdot 0 = p = \Pr(Y = 1).$$

例如, 投掷一枚均匀的硬币, 并认为出现“正面”表示成功, 那么对应的示性随机变量的期望值是 $1/2$.

现在考虑 n 次独立地抛掷硬币试验序列, 在这一系列试验中出现正面的次数是什么分布? 更一般地, 考虑 n 次独立试验序列, 每次试验成功的概率都为 p . 如果用 X 表示这 n 次独立试验中成功的次数, 那么 X 服从二项分布.

定义 2.5 一个参数为 n 和 p 的二项随机变量 X , 记为 $B(n, p)$, 由下面的概率分布定义, 其中 $j = 0, 1, 2, \dots, n$:

$$\Pr(X = j) = \binom{n}{j} p^j (1 - p)^{n-j}.$$

也就是说, 在每次试验成功概率为 p 的 n 次独立试验中, 恰有 j 次成功和 $n-j$ 次失败时, 二项随机变量 X 等于 j .

作为练习, 需要证明定义 2.5 保证 $\sum_{j=0}^n \Pr(X=j) = 1$. 根据定义 1.2, 对于二项随机变量是一个有效的概率函数, 这一点是必要的.

在许多情况下, 尤其是在抽样中, 常常出现二项随机变量. 举一个实际的例子, 假如打算收集有关通过路由器被后处理的数据包数据. 我们可能想知道来自某个源或者某种数据类型的数据包的大致比例. 我们没有足够的内存来存储所有的数据包, 所以只能选择数据包的一个随机子集(或样本)做后期分析. 如果每一个数据包以概率 p 被存储起来, 而且每天有 n 个数据包通过路由器, 那么每天被抽到的数据包个数是参数为 n 和 p 的二项随机变量 X . 如果想知道对于这样的一个样本需要多大的内存, 一个很自然的出发点就是确定随机变量 X 的期望.

这种方式的抽样也出现在其他情形中. 例如, 在程序运行时, 通过对程序计数器的抽样, 可以确定程序的哪部分耗时最长. 这种知识可用于动态程序优化技术, 如二进制重写, 在程序执行时修改这个程序的可执行二进制形式. 由于在程序运行时, 重写可执行代码的代价高昂, 因此抽样可以帮助优化器确定何时值得去做.

二项随机变量 X 的期望是什么? 我们可以由定义直接计算:

$$\begin{aligned} E[X] &= \sum_{j=0}^n j \binom{n}{j} p^j (1-p)^{n-j} \\ &= \sum_{j=0}^n j \frac{n!}{j!(n-j)!} p^j (1-p)^{n-j} \\ &= \sum_{j=1}^n \frac{n!}{(j-1)!(n-j)!} p^j (1-p)^{n-j} \\ &= np \sum_{j=1}^n \frac{(n-1)!}{(j-1)!((n-1)-(j-1))!} p^{j-1} (1-p)^{(n-1)-(j-1)} \\ &= np \sum_{k=0}^{n-1} \frac{(n-1)!}{k!((n-1)-k)!} p^k (1-p)^{(n-1)-k} \\ &= np \sum_{k=0}^{n-1} \binom{n-1}{k} p^k (1-p)^{(n-1)-k} \\ &= np, \end{aligned}$$

其中最后的等式利用了二项式恒等式

$$(x+y)^n = \sum_{k=0}^n \binom{n}{k} x^k y^{n-k}.$$

期望的线性性可以明显简化证明. 如果 X 是参数为 n 和 p 的二项随机变量, 那么 X 表示 n 次试验中成功的次数, 其中每次试验成功的概率为 p . 定义 n 个个性随机变量 X_1, \dots, X_n 的集合, 其中当第 i 次试验成功时 $X_i = 1$, 否则 $X_i = 0$. 显然, $E[X_i] = p$, 并且 $X = \sum_{i=1}^n X_i$, 故由期

望的线性性,

$$E[X] = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] = np.$$

期望的线性性使得用更简单的随机变量(例如示性随机变量)之和表示一个随机变量的方法极其有用.

2.3 条件期望

如同定义条件概率一样, 定义一个随机变量的条件期望也是非常有用的. 下面的定义是相当自然的.

定义 2.6

$$E[Y | Z = z] = \sum_y y \Pr(Y = y | Z = z),$$

其中求和是对 Y 值域中的所有 y 进行的.

这个定义表明, 和期望的定义一样, 随机变量的条件期望也是其可能取值的加权和, 不同之处在于现在每个值的权是变量取这个值的条件概率.

例如, 假定我们独立地投掷两粒标准的六面体骰子. 令 X_1 表示第一粒骰子出现的点数, X_2 表示第二粒骰子出现的点数, X 表示两粒骰子的点数之和, 则

$$E[X | X_1 = 2] = \sum_x x \Pr(X = x | X_1 = 2) = \sum_{x=1}^6 x \cdot \frac{1}{6} = \frac{11}{2}.$$

再举另一个例子, 计算 $E[X_1 | X = 5]$:

$$\begin{aligned} E[X_1 | X = 5] &= \sum_{x=1}^4 x \Pr(X_1 = x | X = 5) \\ &= \sum_{x=1}^4 x \frac{\Pr(X_1 = x \cap X = 5)}{\Pr(X = 5)} \\ &= \sum_{x=1}^4 x \frac{1/36}{4/36} = \frac{5}{2}. \end{aligned}$$

由定义 2.6, 自然得到下面的等式.

引理 2.5 对于任意的随机变量 X 和 Y , 有

$$E[X] = \sum_y \Pr(Y = y) E[X | Y = y],$$

其中求和是对于 Y 值域中的所有使期望存在的 y 进行的.

证明

$$\begin{aligned} &\sum_y \Pr(Y = y) E[X | Y = y] \\ &= \sum_y \Pr(Y = y) \sum_x x \Pr(X = x | Y = y) \\ &= \sum_x \sum_y x \Pr(X = x | Y = y) \Pr(Y = y) \end{aligned}$$



$$\begin{aligned}
 &= \sum_y \sum_x x \Pr(X = x \cap Y = y) \\
 &= \sum_x x \Pr(X = x) \\
 &= E[X].
 \end{aligned}$$

[27]

期望的线性性也可以推广到条件期望. 引理 2.6 给出了明确的表述, 其证明留作练习 2.11.

引理 2.6 对于任意一组具有有限期望的有限个离散随机变量 X_1, X_2, \dots, X_n , 以及任意的随机变量 Y ,

$$E\left[\sum_{i=1}^n X_i \mid Y = y\right] = \sum_{i=1}^n E[X_i \mid Y = y].$$

常常把条件期望作为如下的随机变量, 这一点似乎不好理解.

定义 2.7 表达式 $E[Y \mid Z]$ 是一个当 $Z = z$ 时取值为 $E[Y \mid Z = z]$ 的随机变量 $f(Z)$.

我们强调 $E[Y \mid Z]$ 不是一个实数值, 实际上它是随机变量 Z 的一个函数. 因此 $E[Y \mid Z]$ 本身是一个从样本空间到实数的函数, 所以可以把它当作一个随机变量.

在前面投掷两粒骰子的例子中,

$$E[X \mid X_1] = \sum_x x \Pr(X = x \mid X_1) = \sum_{x=X_1+1}^{X_1+6} x \cdot \frac{1}{6} = X_1 + \frac{7}{2}.$$

我们看到 $E[X \mid X_1]$ 是一个取值依赖于 X_1 的随机变量.

如果 $E[Y \mid Z]$ 是一个随机变量, 那么考虑它的期望 $E[E[Y \mid Z]]$ 是有意义的. 在上面的例子中, 我们得到 $E[X \mid X_1] = X_1 + 7/2$. 因此,

$$E[E[X \mid X_1]] = E\left[X_1 + \frac{7}{2}\right] = \frac{7}{2} + \frac{7}{2} = 7 = E[X].$$

更一般地, 我们有下面的定理.

定理 2.7

$$E[Y] = E[E[Y \mid Z]].$$

证明 由定义 2.7, 我们有 $E[Y \mid Z] = f(Z)$, 其中当 $Z = z$ 时, $f(Z)$ 取值为 $E[Y \mid Z = z]$. 于是

$$E[E[Y \mid Z]] = \sum_z E[Y \mid Z = z] \Pr(Z = z).$$

由引理 2.5, 右边等于 $E[Y]$. ■

现在我们给出条件期望一个有意义的应用. 考虑一个含有调用过程 S 的程序. 假定每次调用过程 S 都会递归地复制产生过程 S 新的副本, 其中新副本个数是一个参数为 n 和 p 的二项随机变量. 还假定这些随机变量对于每一次调用 S 都是独立的. 由此程序产生的过程 S 的副本的期望个数是多少? [28]

为了分析这个递归复制过程, 我们引入“代”的概念. 初始过程 S 为第 0 代. 其他情况下, 如果一个过程 S 是由另一个 $i-1$ 代过程 S 复制的, 就称为第 i 代. 令 Y_i 表示第 i 代 S 过程的个数. 因为我们知道 $Y_0 = 1$, 第 1 代过程的个数服从二项分布, 所以

$$E[Y_i] = np.$$

类似地, 假定我们知道第 $i-1$ 代过程的个数为 y_{i-1} , 那么 $Y_{i-1} = y_{i-1}$. 令 Z_k 表示第 $i-1$ 代的第 $k(1 \leq k \leq y_{i-1})$ 个过程所复制的副本个数, 每个 Z_k 都是参数为 n 和 p 的二项随机变量. 那么,

$$\begin{aligned} E[Y_i | Y_{i-1} = y_{i-1}] &= E\left[\sum_{k=1}^{y_{i-1}} Z_k | Y_{i-1} = y_{i-1}\right] \\ &= \sum_{j \geq 0} j \Pr\left(\sum_{k=1}^{y_{i-1}} Z_k = j | Y_{i-1} = y_{i-1}\right) \\ &= \sum_{j \geq 0} j \Pr\left(\sum_{k=1}^{y_{i-1}} Z_k = j\right) \\ &= E\left[\sum_{k=1}^{y_{i-1}} Z_k\right] \\ &= \sum_{k=1}^{y_{i-1}} E[Z_k] \\ &= y_{i-1} np. \end{aligned}$$

第三行中, 我们用到了所有的 Z_k 都是独立的二项随机变量, 特别是每个 Z_k 值与 Y_{i-1} 无关, 使得可以消去条件. 在第五行, 我们利用了期望的线性性.

根据定理 2.7, 可以归纳地计算第 i 代的期望大小, 我们有

$$E[Y_i] = E[E[Y_i | Y_{i-1}]] = E[Y_{i-1} np] = np E[Y_{i-1}].$$

由对 i 的归纳, 并利用 $Y_0 = 1$ 的事实, 我们得到

$$E[Y_i] = (np)^i.$$

由这个程序产生的过程 S 副本的期望总数为

$$E\left[\sum_{i \geq 0} Y_i\right] = \sum_{i \geq 0} E[Y_i] = \sum_{i \geq 0} (np)^i.$$

如果 $np \geq 1$, 则期望无界; 如果 $np < 1$, 则期望等于 $1/(1 - np)$. 因此, 该程序产生的过程的期望个数有界, 当且仅当每一个过程复制的过程期望个数都小于 1.

这里分析的过程是分支过程的一个简单例子, 它是概率论中被广泛研究的一个概率范例.

2.4 几何分布

假设我们投掷一枚硬币, 直到出现正面才停止, 那么投掷的次数是什么分布? 这是一个几何分布的例子, 它来自下面场合: 我们进行一系列独立试验, 直到第一次成功, 每次试验成功的概率为 p .

定义 2.8 一个参数为 p 的几何随机变量 X 由以下的概率分布给出, 其中 $n = 1, 2, \dots$:

$$\Pr(X = n) = (1 - p)^{n-1} p.$$

也就是说几何随机变量 X 等于 n , 必定是经历 $n-1$ 次失败后接着一次成功.

作为练习, 证明几何随机变量 X 满足

$$\sum_{n \geq 1} \Pr(X = n) = 1.$$

由定义 1.2, 几何随机变量成为一个有效的概率函数, 这也是必需的.

在 2.2 节对一个路由器的数据包抽样的例子中, 如果数据包以概率 p 被抽到, 那么在最近一次抽到包后, 直到包括下一次抽到包之间通过的包数, 由参数为 p 的几何随机变量给出.

几何随机变量称为无记忆的, 因为从现在开始的 n 次试验, 取得第一次成功的概率与以前经历过的失败次数无关. 非正式地说, 我们可以不考虑过去的失败, 因为它们不能改变未来的直到第一次成功的试验次数的分布. 正式地说, 我们有以下的命题.

引理 2.8 对一个参数为 p 的几何随机变量 X , 当 $n > 0$ 时,

$$\Pr(X = n + k \mid X > k) = \Pr(X = n).$$

证明

$$\begin{aligned} \Pr(X = n + k \mid X > k) &= \frac{\Pr((X = n + k) \cap (X > k))}{\Pr(X > k)} \\ &= \frac{\Pr(X = n + k)}{\Pr(X > k)} \\ &= \frac{(1-p)^{n+k-1}p}{\sum_{i=k}^{\infty} (1-p)^i p} \\ &= \frac{(1-p)^{n+k-1}p}{(1-p)^k} \\ &= (1-p)^{n-1}p \\ &= \Pr(X = n). \end{aligned}$$

第四个等式用到对 $0 < x < 1$, $\sum_{i=k}^{\infty} x^i = x^k / (1-x)$ 的事实. ■

现在计算几何随机变量的期望. 当一个随机变量在自然数集合 $\mathcal{N} = \{0, 1, 2, 3, \dots\}$ 取值时, 可利用另一个公式来计算其期望.

引理 2.9 设 X 为一离散随机变量, 只取非负整数值, 则

$$E[X] = \sum_{i=1}^{\infty} \Pr(X \geq i).$$

证明

$$\begin{aligned} \sum_{i=1}^{\infty} \Pr(X \geq i) &= \sum_{i=1}^{\infty} \sum_{j=i}^{\infty} \Pr(X = j) \\ &= \sum_{j=1}^{\infty} \sum_{i=1}^j \Pr(X = j) \\ &= \sum_{j=1}^{\infty} j \Pr(X = j) \\ &= E[X]. \end{aligned}$$



由于求和项都是非负的, 因此交换无限项求和(可能)是合理的. ■

对于参数为 p 的几何随机变量 X ,

$$\Pr(X \geq i) = \sum_{n=i}^{\infty} (1-p)^{n-1} p = (1-p)^{i-1}.$$

所以

$$\begin{aligned} E[X] &= \sum_{i=1}^{\infty} \Pr(X \geq i) \\ &= \sum_{i=1}^{\infty} (1-p)^{i-1} \\ &= \frac{1}{1-(1-p)} \\ &= \frac{1}{p}. \end{aligned}$$

因此对于一枚 $p=1/2$ 的均匀硬币, 看到第一次正面平均需要抛掷两次.

还有另外一种方法求参数为 p 的几何随机变量 X 的期望——利用条件期望和几何随机变量的无记忆性. 回忆一下, X 对应于抛掷硬币直到第一次出现正面的次数, 已知每次出现正面的概率为 p . 令 $Y=0$ 表示第一次抛掷硬币出现反面, $Y=1$ 表示第一次抛掷硬币出现正面. 由引理 2.5 中的等式,

$$\begin{aligned} E[X] &= \Pr(Y=0)E[X|Y=0] + \Pr(Y=1)E[X|Y=1] \\ &= (1-p)E[X|Y=0] + pE[X|Y=1]. \end{aligned}$$

如果 $Y=1$, 那么 $X=1$, 所以 $E[X|Y=1]=1$. 如果 $Y=0$, 那么 $X>1$. 在这种情况下, 令剩下的(第一次投掷后到第一次出现正面)投掷次数为 Z . 那么由期望的线性性,

$$E[X] = (1-p)E[Z+1] + p \cdot 1 = (1-p)E[Z] + 1.$$

由几何随机变量的无记忆性, Z 也是参数为 p 的几何随机变量. 由于 X 和 Z 具有相同的分布, 因此 $E[Z]=E[X]$. 所以我们有

$$E[X] = (1-p)E[X] + 1 = (1-p)E[X] + 1,$$

由此 $E[X]=1/p$.

这种利用条件期望计算期望的方法是非常有用的, 特别是连同几何随机变量的无记忆性.

2.4.1 例: 赠券收集问题

赠券收集问题产生于下面场合. 假设有 n 种不同的赠券, 每盒麦片内附有其中的一张赠券. 当收集到每种赠券中的一张时, 便可以得到奖品. 假定每盒麦片中的赠券是从 n 种可能中独立且均匀地随机选取的, 还假定在收集赠券时不与其他人合作. 在拥有每种赠券至少一张之前, 需要购买多少盒麦片? 这个简单问题产生于许多不同场合, 在本书的几个地方还会再次出现.

令 X 表示收集到每种赠券至少一张所需要购买的麦片盒数. 我们现在求 $E[X]$. 如果 X_i 表示恰有 $i-1$ 种不同赠券时为得到一张新的赠券购买的盒数, 那么显然 $X = \sum_{i=1}^n X_i$.

31

32

把随机变量 X 分成 n 个随机变量 $X_i (i=1, \dots, n)$ 之和的优点是, 每个 X_i 都为几何随机变量. 当已经得到恰好 $i-1$ 种赠券时, 再得到一种新赠券的概率是

$$p_i = 1 - \frac{i-1}{n}.$$

因此, X_i 是参数为 p_i 的几何随机变量, 且

$$E[X_i] = \frac{1}{p_i} = \frac{n}{n-i+1}.$$

由期望的线性性, 我们有

$$\begin{aligned} E[X] &= E\left[\sum_{i=1}^n X_i\right] \\ &= \sum_{i=1}^n E[X_i] \\ &= \sum_{i=1}^n \frac{n}{n-i+1} \\ &= n \sum_{i=1}^n \frac{1}{i}. \end{aligned}$$

和式 $\sum_{i=1}^n 1/i$ 称为调和数 $H(n)$, 下面证明 $H(n) = \ln(n) + \Theta(1)$. 这样, 对于赠券收集问题, 为了收集齐所有 n 种赠券, 需要随机赠券的期望张数为 $n \ln(n) + \Theta(n)$.

引理 2.10 调和数 $H(n) = \sum_{i=1}^n 1/i$ 满足 $H(n) = \ln(n) + \Theta(1)$.

证明 由于 $1/x$ 是单调递减的, 我们可以记

$$\ln n = \int_{k=1}^n \frac{1}{x} dx \leq \sum_{k=1}^n \frac{1}{k}$$

及

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

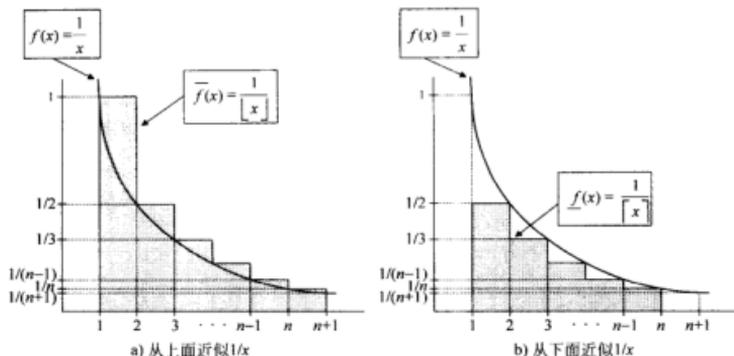
由图 2.1 易知, 曲线 $f(x) = 1/x$ 下方的面积相应于积分, 阴影部分的面积相应于求和

$$\sum_{k=1}^n 1/k \quad \text{及} \quad \sum_{k=2}^n 1/k.$$

因此, $\ln(n) \leq H(n) \leq \ln n + 1$, 证毕. ■

作为赠券收集问题的一个简单应用, 假设数据包从源主机经固定的路由器路径不断地传送到目标主机. 目标主机想知道数据包流经过了哪些路由器传送, 便于以后查找是哪个路由器处理时破坏了数据包. 如果数据包头部有足够空间, 每一个路由器可以在头部添加它的标识码, 给出传输路径. 不幸的是, 数据包头部不可能有那么多可用的空间.

假如每个包的头部恰好有存放一个路由器标识码的空间, 并且这个空间用于存放从这条路

图 2.1 $f(x) = 1/x$ 下面面积的近似表示

径上所有路由器中均匀随机选取的一个路由器的标识码。实际上这是容易做到的，我们将在练习 2.18 中考虑这个问题。这样，从目标主机来看，确定路径中的所有路由器问题与赠券收集问题是类似的。如果路径中有 n 个路由器，那么在目标主机知道路径中的所有路由器之前必须到达的数据流中的数据包的期望数是 $nH(n) = n \ln(n) + \Theta(n)$ 。

2.5 应用：快速排序的期望运行时间

快速排序是一种简单且实际上非常有效的排序算法。输入是 n 个数 x_1, x_2, \dots, x_n 的列表。为简便起见，我们假定数是各不相同的。快速排序函数首先在此列表中选择一基准元素，假定基准元素为 x 。运行算法就是每个其他元素与 x 的比较，将元素列表分成两个子表：小于 x 的元素和大于 x 的元素。注意如果比较是按自然次序从左到右进行的，那么每个子表中元素的排列次序与原始表的一样。快速排序法就是对这些子表的递归排序。如算法 2.1 所示。

算法 2.1 快速排序算法

输入：全序总体中 n 个不同元素的列表 $S = \{x_1, \dots, x_n\}$ 。

输出：排序后的 S 的元素。

1. 如果 S 只有一个或零个元素，返回 S ；否则继续。
2. 选择 S 中一个元素作为基准元素，称为 x 。
3. 为了将其其他元素分成两个子列表， S 中的每个其他元素与 x 作比较：
 - (a) S_1 是 S 中所有比 x 小的元素。
 - (b) S_2 是 S 中所有比 x 大的元素。
4. 对 S_1 和 S_2 快速排序。
5. 返回列表 S_1, x, S_2 。



最坏情况下,快速排序需要进行 $\Omega(n^2)$ 次比较运算. 例如,假定输入形如 $x_1 = n, x_2 = n-1, \dots, x_{n-1} = 2, x_n = 1$, 还假定采用以列表的第一个元素作为基准的规则. 那么第一个基准应该选为 n , 因此快速排序执行 $n-1$ 次比较, 产生一个大小为 0 的空表(不需要再进行其他工作)及另一个大小为 $n-1$ 的子表, 次序为 $n-1, n-2, \dots, 2, 1$. 下一个选取的基准为 $n-1$, 快速排序执行 $n-2$ 次比较, 得到一个次序为 $n-2, n-3, \dots, 2, 1$, 大小为 $n-2$ 的子表. 继续做下去, 快速算法需要进行

$$(n-1) + (n-2) + \dots + 2 + 1 = \frac{n(n-1)}{2} \text{ 次比较.}$$

这并不是导致 $\Omega(n^2)$ 比较的唯一的最好情况. 如果基准元素每次都是从最小几个元素或者最大几个元素中选取, 那么会出现类似的最坏情况.

对给定的输入, 我们显然选择了最坏的基准. 基准的合理选择只要求为数不多的几次比较. 例如, 如果我们选择的基准将列表分为大小至多是 $\lceil n/2 \rceil$ 的两个子表, 那么比较次数 $C(n)$ 将遵循下面的循环关系:

$$C(n) \leq 2C(\lceil n/2 \rceil) + \Theta(n).$$

这个方程的解是 $C(n) = O(n \log n)$, 这是比较排序法的最好的可能结果. 事实上, 把输入表分为两个大小至少为 cn (c 为一常数) 的子表的任意基准元素序列都需要运行 $O(n \log n)$ 次.

[35]

这个讨论提供了应该如何选取基准的某些直观知识. 在算法的每一步迭代中, 都有一个好的基准元素集合, 它们将输入表分成两个大小几乎相等的子表, 而这只需两个子表的大小相互是一个常数因子即可. 也有不好的基准元素集合, 它不能把原表有效地分成两个子表. 如果能足够经常地选择好的基准, 快速排序将很快结束. 那么如何保证算法总能经常有效地选择好的基准元素呢? 我们有以下两种方法解决这个问题.

首先, 把算法改成随机选取基准, 这使快速排序成为一种随机化算法, 随机化就不大可能让我们重复选择不好的基准. 可以证明简单的随机化快速排序法执行比较的期望次数为 $2n \ln(n) + O(n)$, 这要比比较排序法的界 $\Omega(n \log n)$ (至多常数因子) 好. 这里, 期望是关于基准的随机选取.

第二种可能性是保持原有的确定性算法, 用列表的第一个元素为基准, 但是考虑输入的概率模型. n 个不同元素集合的一种排列只是这些元素的 $n!$ 种次序中的一个, 代替最糟的可能输入, 假定我们已经知道输入项是依随机次序的. 对于某些应用, 这个假定是合理的. 换句话说, 在运行确定性快速排序算法之前, 将输入表按照随机选择次序排列. 这样, 我们得到了基于输入模型概率分析的确定性算法. 用这种方法比较的期望数也是 $2n \ln(n) + O(n)$, 但是此处的期望是关于输入的随机选取.

随机化算法分析和确定性算法的概率分析一般都用相同的技术. 事实上, 在这种应用中, 随机化快速排序法分析与随机输入下的确定性快速排序法的概率分析本质上是一样的.

我们首先分析随机快速排序法, 它是快速排序的随机化算法形式.

定理 2.11 假设在随机快速排序法中, 每一次都是从所有可能中独立且均匀随机地选取基准的, 那么对于任意的输入, 随机快速排序法所做比较的期望次数为 $2n \ln n + O(n)$.

证明 设 y_1, y_2, \dots, y_n 与输入值 x_1, x_2, \dots, x_n 有相同的值, 但是按照升序排列. 对于

$i < j$, 记 X_{ij} 为一随机变量, 如果在算法执行过程的任何时候 y_i 和 y_j 进行了比较, 则 X_{ij} 取值为 1; 否则取 0. 那么比较的总次数 X 满足

$$X = \sum_{i=1}^{n-1} \sum_{j=i+1}^n X_{ij},$$

且根据期望的线性性得

$$\begin{aligned} E[X] &= E\left[\sum_{i=1}^{n-1} \sum_{j=i+1}^n X_{ij}\right] \\ &= \sum_{i=1}^{n-1} \sum_{j=i+1}^n E[X_{ij}]. \end{aligned}$$

由于 X_{ij} 是只取 0 和 1 的示性随机变量, $E[X_{ij}]$ 等于 X_{ij} 为 1 的概率. 因此我们只需计算两个元素 y_i 和 y_j 相比较的概率. 现在, y_i 和 y_j 进行比较, 当且仅当 y_i 或者 y_j 是从集合 $Y^{ij} = \{y_i, y_{i+1}, \dots, y_{j-1}, y_j\}$ 中由随机快速排序法选作第一个基准. 这是因为如果 y_i (或者 y_j) 是从这个集合选取的第一个基准, y_i 和 y_j 必仍在同一个子列表中, 因此它们将会进行比较. 类似地, 如果二者都不是从这个集合中选取的第一个基准, 那么 y_i 和 y_j 将被分在不同的子列表中, 所以不会进行比较.

因为我们的基准都是从每个子列表中独立且均匀随机地选取的, 也就是第一次从 Y^{ij} 中选取的一个基准等可能地是这个集合中的任一元素. 因此 y_i 或者 y_j 是从 Y^{ij} 中选取的第一个基准的概率, 即 X_{ij} 取 1 的概率, 它是 $2/(j-i+1)$. 利用替换 $k=j-i+1$, 得

$$\begin{aligned} E[X] &= \sum_{i=1}^{n-1} \sum_{j=i+1}^n \frac{2}{j-i+1} \\ &= \sum_{i=1}^{n-1} \sum_{k=2}^{n-i+1} \frac{2}{k} \\ &= \sum_{k=2}^n \sum_{i=1}^{n+1-k} \frac{2}{k} \\ &= \sum_{k=2}^n (n+1-k) \frac{2}{k} \\ &= \left((n+1) \sum_{k=2}^n \frac{2}{k} \right) - 2(n-1) \\ &= (2n+2) \sum_{k=1}^n \frac{1}{k} - 4n. \end{aligned}$$

注意我们交换了双重和号的次序, 得到了期望的简洁形式.

回顾和式 $H(n) = \sum_{k=1}^n 1/k$ 满足 $H(n) = \ln n + \Theta(1)$, 因此我们有 $E[X] = 2n \ln n + \Theta(n)$. ■

下面, 我们讨论随机输入下的快速排序法的确定性形式. 假定每一次递归构造的子列表中元素的次序与原列表相同.

定理 2.12 假设在快速排序法中，每次选取子列表中第一个元素作为基准。如果输入是在其所有可能排列中均匀随机选取的，那么确定性快速排序法所做比较的期望次数为 $2n \ln n + O(n)$ 。

证明 证明与随机快速排序法本质上是相同的。仍然是 y_i 和 y_j 比较，当且仅当 y_i 或者 y_j 是由快速排序法从集合 Y^i 中选取的第一个基准。因为每个子列表中元素次序与原列表相同，所以从集合 Y^i 中选取的第一个基准恰好是输入列表中来自 Y^i 的第一个元素，因为输入值的所有可能排列是等可能的， Y^i 中每个元素作为第一个基准也是等可能的。由此，同随机快速排序法分析中所做的一样，再次利用期望的线性性，得到 $E[X]$ 的同样表达式。 ■

练习

- 2.1 假设投掷一粒均匀的 k 面骰子，在骰子的面上标有数字 1 到 k ，如果 X 是出现的点数， $E[X]$ 等于多少？
- 2.2 猴子在一个只有 26 个小写字母的键盘上打字，每个字母都是从字母表中独立均匀随机地选取的。如果猴子打了 1 000 000 个字母，出现序列“proof”的期望次数是多少？
- 2.3 给出随机变量 X 和函数 f 的例子，满足 $E[f(X)] \leq f(E[X])$ ， $E[f(X)] = f(E[X])$ 和 $E[f(X)] \geq f(E[X])$ 。
- 2.4 对于任意 $k \geq 1$ 的偶数，证明 $E[X^k] \geq E[X]^k$ 。
- 2.5 若 X 为一个 $B(n, 1/2)$ 随机变量， $n \geq 1$ ，证明 X 为偶数的概率是 $1/2$ 。
- 2.6 假设我们独立地投掷两粒标准的六面体骰子，设 X_1 是第一粒骰子的点数， X_2 是第二个骰子的点数， X 是两个骰子点数之和。
- (a) $E[X | X_1 \text{ 为偶数}]$ 等于多少？
- (b) $E[X | X_1 = X_2]$ 等于多少？
- (c) $E[X_1 | X = 9]$ 等于多少？
- (d) 对 $[2, 12]$ 中的 k ， $E[X_1 - X_2 | X = k]$ 等于多少？
- 2.7 设 X 和 Y 为独立的几何随机变量，其中 X 的参数为 p ， Y 的参数为 q 。
- (a) $X = Y$ 的概率是多少？
- (b) $E[\max(X, Y)]$ 等于多少？
- (c) $\Pr(\min(X, Y) = k)$ 是多少？
- (d) $E[X | X \leq Y]$ 等于多少？
- 可以发现记住几何随机变量的无记忆性对此有帮助。
- 2.8 (a) Alice 和 Bob 决定生小孩，直到他们拥有第一个女儿或者有 $k \geq 1$ 个孩子为止。假定婴儿为男孩或者女孩是独立的，概率都为 $1/2$ ，并且没有多胞胎情况。那么他们的女孩的期望个数是多少？他们的男孩的期望个数是多少？
- (b) 假定 Alice 和 Bob 只是简单地决定继续不断地生孩子，直到他们拥有第一个女儿。如果这是可能的，那么他们的男孩的期望个数是多少？
- 2.9 (a) 假设将一粒均匀的 k 面骰子投掷两次，骰子的面上标有数字 $1 \sim k$ ，得到两个值 X_i 和

X_2 , $E[\max(X_1, X_2)]$ 等于多少? $E[\min(X_1, X_2)]$ 等于多少?

(b) 利用(a)中的计算, 证明

$$E[\max(X_1, X_2)] + E[\min(X_1, X_2)] = E[X_1] + E[X_2]. \quad (2.1)$$

(c) 利用期望的线性性而不是直接计算, 解释等式(2.1)为什么一定成立.

2.10 (a) 用归纳法证明, 如果 $f: \mathbb{R} \rightarrow \mathbb{R}$ 是凸函数, 那么对于任意的 x_1, x_2, \dots, x_n 和 $\lambda_1,$

$$\lambda_2, \dots, \lambda_n, \sum_{i=1}^n \lambda_i = 1, \text{ 有}$$

$$f\left(\sum_{i=1}^n \lambda_i x_i\right) \leq \sum_{i=1}^n \lambda_i f(x_i). \quad (2.2)$$

(b) 利用不等式(2.2)证明, 如果 $f: \mathbb{R} \rightarrow \mathbb{R}$ 是凸的, 那么对于任意只取有限多个值的随机变量 X , 有

$$E[f(X)] \geq f(E[X])$$

2.11 证明引理 2.6.

2.12 从一副 n 张纸牌中, 有放回地且均匀随机地取牌, 直到看到了这副纸牌的所有 n 张为止, 我们必需抽取纸牌的期望次数是多少? 如果抽取了 $2n$ 张纸牌, 那么根本没有被抽到过的纸牌的期望张数是多少? 恰被抽到一次的呢?

2.13 (a) 考虑下列稍作变化的赠券收集问题. 每包麦片内装有 $2n$ 种不同赠券中的一张. 赠券可以配成 n 对, 赠券 1 和赠券 2 是一对, 赠券 3 和赠券 4 是一对, 等等. 一旦收集齐每对中的一张, 便可得到奖品. 假定每包中的赠券是从 $2n$ 种可能中独立地、均匀随机地选取的. 在得到奖品之前, 必须购买的期望包数是多少?

(b) 将问题(a)的结果推广到下面情况: 假设有 kn 种不同赠券, 分为 n 个分离的 k 张赠券集合, 从而需要每个集合中的一张赠券.

2.14 几何分布作为我们投掷一枚硬币直到出现正面的投掷次数的分布. 现在考虑投掷一枚硬币直到第 k 次出现正面的投掷次数 X 的分布, 其中每次投掷硬币出现正面是独立的, 概率为 p . 证明对于 $n \geq k$ 时, 这个分布由

$$\Pr(X = n) = \binom{n-1}{k-1} p^k (1-p)^{n-k}$$

给出(这称为负二项分布).

2.15 对一枚每次投掷出现正面是独立的且概率为 p 的硬币, 直到第 k 次出现正面的投掷期望次数是多少?

2.16 假设我们投掷一枚硬币 n 次, 得到一个投掷序列 X_1, X_2, \dots, X_n . 一个投掷串是有相同结果的相继投掷子列, 例如, 如果 X_3, X_4 和 X_5 都是正面, 那么存在一个从第三次投掷开始的长度为 3 的串(如果 X_6 也是正面, 那么存在一个从第三次投掷开始的长度为 4 的串).

(a) 如果 n 是 2 的幂, 证明长度为 $\log_2 n + 1$ 的串的预期数是 $1 - o(1)$.

(b) 证明对于足够大的 n , 不存在长度至少为 $\lfloor \log_2 n - 2\log_2 \log_2 n \rfloor$ 的串的概率小于 $1/n$.

(提示: 将投掷序列分为 $\lfloor \log_2 n - 2\log_2 \log_2 n \rfloor$ 次相继投掷的不相交区组, 利用某个区组是一个串的事件与任何其他区组是一个串的事件的独立性.)

- 2.17 回忆在 2.3 节中描述的递归复制过程. 假设每次调用过程 S 都会递归地复制过程 S 的新副本, 其中新副本的个数以概率 p 为 2, 以概率 $1-p$ 为 0. 如果 Y_i 表示第 i 代 S 的副本个数, 确定 $E[Y_i]$. 对什么样的 p 值, 副本总数的期望有界?

- 2.18 下面的方法通常称为贮存抽样法. 假设有一个数据项序列, 每次只能传递一个项目. 我们希望保持一个单项目的样本, 这个项目均匀地分布在我们每一步所看到的全部数据项中, 而且希望在预先不知道项目总数或者保存我们所看到的全部数据项的情况下完成. [40]

考虑下面的算法, 任何时候内存中只贮存一个项目. 当第一个项目出现时, 它贮存在内存中; 当第 k 个项目出现时, 它以概率 $1/k$ 替换内存中的项目. 解释为什么这种算法可以解决问题.

- 2.19 假定我们修改练习 2.18 中的贮存抽样算法, 使得当第 k 个项目出现时, 它以概率 $1/2$ 替换内存中的项目. 描述内存中项目的分布.
- 2.20 数 $[1, n]$ 的一个排列可以用函数 $\pi: [1, n] \rightarrow [1, n]$ 来表示, 其中 $\pi(i)$ 是 i 在该排列中的次序. 排列 $\pi: [1, n] \rightarrow [1, n]$ 的固定点是使 $\pi(x) = x$ 成立的值. 求从所有排列中均匀随机选取的一个排列的固定点个数的期望.
- 2.21 设 a_1, a_2, \dots, a_n 是 $\{1, 2, \dots, n\}$ 的一个随机排列, 等可能地为 $n!$ 种可能排列中的任意一个. 当对列表 a_1, a_2, \dots, a_n 排序时, 元素 a_i 从它当前位置到达排序位置必须移动 $|a_i - i|$ 的距离. 求元素必须移动的期望总距离

$$E \left[\sum_{i=1}^n |a_i - i| \right].$$

- 2.22 设 a_1, a_2, \dots, a_n 为 n 个不同数的列表. 我们称 a_i 和 a_j 是倒置的, 如果 $i < j$ 但 $a_i > a_j$. 冒泡排序算法交换列表中两个相邻倒置数的次序, 直到没有倒置数为止, 从而使列表排序. 假设冒泡排序算法的输入是一个随机排列, 等可能地为 n 个不同数的 $n!$ 种排列中任意一个. 确定用冒泡排序算法需要纠正的倒置数的期望次数.
- 2.23 线性插入排序法可以对一个数组适当地排序. 比较第一和第二个数, 如果它们次序颠倒了, 将它们交换, 使得符合排列次序. 然后将第三个数放在合适的排序位置, 首先跟第二个数比较, 如果不是在合适的次序上, 则与第二个数交换, 并跟第一个数比较. 反复进行下去, 对于第 k 个数, 经过不断的向前交换, 直到前 k 个数是依次排列为止. 当输入是 n 个不同数的随机排列时, 确定线性插入排序法需要进行交换的期望次数.
- 2.24 反复掷一粒公正的骰子, 直到出现第一对相继的两个六点, 投掷次数的期望是多少? (提示: 答案不是 36.)
- 2.25 对 n 个人进行血液化验. 每个人可以单独化验, 但是费用过高. 合并化验可以减少化验费用. 把 k 个人的血样合起来同时分析, 如果化验呈阴性, 对这 k 个人的组, 这一次化验就够了. 如果化验呈阳性, 则这 k 个人需要再进行单独化验, 因此这 k 个人需要进行 $k+1$ 次化验. [41]

假定我们产生了 n/k 个不同的组, 每组 k 个人 (n 能被 k 整除), 并用合并法进行化验. 假设对于独立化验, 每个人呈阳性的概率为 p .

(a) 对 k 个人的合并样本, 化验呈阳性的概率是多少?

(b) 需要化验的期望次数是多少?

(c) 描述如何求最优的 k 值.

(d) 给出一个不等式, 说明对什么样的 p 值, 合并化验比每个人单独化验好.

- 2.26 按下面的方法可以将一个置换 $\pi: [1, n] \rightarrow [1, n]$ 表示为环的集合. 设每个数 $i (i = 1, \dots, n)$ 对应一个顶点, 如果置换将数 i 映射到数 $\pi(i)$, 那么从顶点 i 到顶点 $\pi(i)$ 画一条有向弧, 由此导出一张图, 它是不相交环的集合. 注意某些环可以是自圈. 在 n 个数的随机排列中, 环的期望个数是多少?

- 2.27 考虑在整数 $x \geq 1$ 上的分布: $\Pr(X = x) = (6/\pi^2)x^{-2}$. 由于 $\sum_{k=1}^{\infty} k^{-2} = \pi^2/6$, 所以这是有效分布. 它的期望是多少?

- 2.28 考虑一种简化的轮盘赌游戏. 设在红色或者黑色处下了 x 美元的赌注, 轮子转动后, 如果小球停在了下注的颜色处, 那么可得到原来的赌注, 再加上另外的 x 美元, 如果球不是停在下注的颜色处, 就输掉所下的赌注. 每种颜色以 $1/2$ 的概率独立地出现. (这是一种简化了的情况. 因为实际轮盘上有一个或者两个既不是红色也不是黑色的位置, 因此猜中正确颜色的概率实际上小于 $1/2$.)

下面是一个比较流行的赌博策略. 第一次旋转下赌注 1 美元. 如果输了, 在下次旋转中下 2 美元赌注. 一般地, 如果在前 $k-1$ 次旋转中都输了, 那么在第 k 次旋转中下 2^{k-1} 美元赌注. 按照这种策略最终能够赢 1 美元. 现在设 X 是一随机变量, 度量在赢得游戏前所输掉的最大值 (即在赢得赌博的那次旋转前输掉的总钱数). 证明 $E[X]$ 是无界的. 这种策略的实际意义蕴涵什么?

- 2.29 如果 X_0, X_1, \dots 是随机变量序列, 使得级数

$$\sum_{j=0}^{\infty} E[|X_j|]$$

收敛, 证明期望的线性性成立:

$$E\left[\sum_{j=0}^{\infty} X_j\right] = \sum_{j=0}^{\infty} E[X_j].$$

- 2.30 在练习 2.28 的轮盘赌游戏中, 我们发现最终将以概率 1 赢得 1 美元. 记 X_j 为第 j 轮赌博中赢得的钱数. (如果已经赢得了前一轮赌博, 这可以是 0.) 确定 $E[X_j]$, 并根据期望的线性性证明赢得钱数的期望是 0. 此时期望的线性性还成立吗? (与练习 2.29 作比较.)
- 2.31 对练习 2.28 的轮盘赌问题变形如下. 反复投掷一枚均匀硬币. 你需要付 j 美元去进行游戏. 如果直到第 k 次投掷时才第一次出现正面, 则赢得 $2^k/k$ 美元. 你的期望赢钱是多少? 为了玩这样的游戏, 你愿意付多少钱?
- 2.32 你需要聘用一名新的助理, 有 n 个人来面试. 你希望为这个职位录用最好的人选. 当你

面试完一个应聘者后，给他们打分，最高分是最出色的，并且不存在分数相同的情况。你一个接一个地面试应聘者，由于你公司的招聘惯例，当面试了第 k 个应聘者后，你要么在下一个面试之前，将工作给这位应聘者；要么失去录用此应聘者的机会。假定应聘者是依随机次序进行面试的，是从所有 $n!$ 种可能次序中均匀随机地选取的。

考虑下面的策略。首先，面试 m 个应聘者，并将他们全部淘汰。这些应聘者给你留下了他们的实力有多强的印象。在第 m 个应聘者后，你录用第一个面试的应聘者，如果他比以前已经面试过的 m 个应聘者都出色。

(a) 设 E 为我们录用了最好的助理这一事件， E_i 为第 i 个应聘者是最出色的且被录用的事件。确定 $\Pr(E_i)$ ，并证明

$$\Pr(E) = \frac{m}{n} \sum_{j=m+1}^n \frac{1}{j-1}.$$

(b) 确定 $\sum_{j=m+1}^n \frac{1}{j-1}$ 的界，从而得到

$$\frac{m}{n} (\ln n - \ln m) \leq \Pr(E) \leq \frac{m}{n} (\ln(n-1) - \ln(m-1)).$$

(c) 证明当 $m = n/e$ 时， $m(\ln n - \ln m)/n$ 达到最大值，并说明为什么对这个 m 值有 $\Pr(E) \geq 1/e$.



第3章 矩与方差

本章与下一章我们讨论界定尾分布，即随机变量取值远离其期望的概率的方法。在算法分析中，这些界是估计算法失败的概率并以大概率确定它们运行时间界的主要工具。本章我们研究马尔可夫不等式和切比雪夫不等式，并演示它们在随机化中位数算法分析中的应用。下一章讨论切比雪夫界及其应用。

3.1 马尔可夫不等式

下面定理中给出的马尔可夫不等式通常不足以产生有用的结果，但在求比较复杂的界时却是一种基本工具。

定理 3.1 [马尔可夫不等式] 设 X 是只取非负值的随机变量，那么对所有 $a > 0$,

$$\Pr(X \geq a) \leq \frac{E[X]}{a}.$$

证明 对 $a > 0$, 记

$$I = \begin{cases} 1 & \text{如果 } X \geq a, \\ 0 & \text{其他,} \end{cases}$$

注意，因为 $X \geq 0$,

$$I \leq \frac{X}{a}. \quad (3.1)$$

因为 I 是一个 0-1 随机变量， $E[I] = \Pr(I=1) = \Pr(X \geq a)$ 。

对 (3.1) 式求期望得到

$$\Pr(X \geq a) = E[I] \leq E\left[\frac{X}{a}\right] = \frac{E[X]}{a}. \quad \blacksquare$$

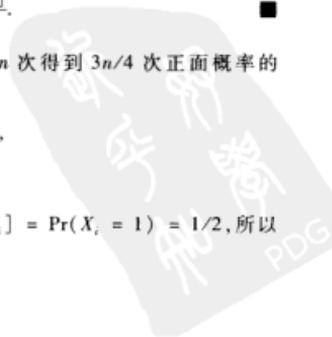
例如，假定我们用马尔可夫不等式求一枚均匀硬币投掷 n 次得到 $3n/4$ 次正面概率的界。记

$$X_i = \begin{cases} 1 & \text{第 } i \text{ 次投掷硬币出现正面,} \\ 0 & \text{其他,} \end{cases}$$

且设 $X = \sum_{i=1}^n X_i$ 表示 n 次硬币投掷中出现正面的次数。因为 $E[X_i] = \Pr(X_i = 1) = 1/2$ ，所以

$E[X] = \sum_{i=1}^n E[X_i] = n/2$ 。由马尔可夫不等式，我们得到

$$\Pr(X \geq 3n/4) \leq \frac{E[X]}{3n/4} = \frac{n/2}{3n/4} = \frac{2}{3}.$$



3.2 随机变量的方差和矩

当我们知道随机变量的期望及变量是非负时, 马尔可夫不等式给出了最好的可能的尾部界 (见练习 3.16). 如果有关于随机变量分布的更多信息可以利用, 其尾部界还可以改进.

关于随机变量的附加信息经常用它的矩来表达. 期望也称作随机变量的一阶矩. 更一般地, 我们定义随机变量的矩如下.

定义 3.1 一个随机变量 X 的 k 阶矩为 $E[X^k]$.

当二阶矩 ($E[X^2]$) 也可利用时, 能得到显著加强的尾部界. 已知一阶矩和二阶矩, 就可以计算随机变量的方差和标准差. 直观上, 方差和标准差提供了随机变量离它的期望可能有多远的一种度量.

定义 3.2 一个随机变量 X 的方差定义为

$$\text{Var}[X] = E[(X - E[X])^2] = E[X^2] - (E[X])^2.$$

随机变量 X 的标准差为

$$\sigma[X] = \sqrt{\text{Var}[X]}.$$

由期望的线性性容易看出, 定义中方差的两种形式是等价的. 记住 $E[X]$ 是一个常数, 我们有

$$\begin{aligned} E[(X - E[X])^2] &= E[X^2 - 2XE[X] + E[X]^2] \\ &= E[X^2] - 2E[XE[X]] + E[X]^2 \\ &= E[X^2] - 2E[X]E[X] + E[X]^2 \\ &= E[X^2] - (E[X])^2. \end{aligned}$$

[45]

如果随机变量 X 是常数 (即它总取相同的值) 那么它的方差和标准差为 0. 更一般地, 如果随机变量 X 以概率 $1/k$ 取值 $kE[X]$, 以概率 $1-1/k$ 取值 0, 那么它的方差为 $(k-1)(E[X])^2$, 它的标准差为 $\sqrt{k-1}E[X]$. 这些情形有助于证实直觉, 即当随机变量的取值接近它的期望时, 方差 (及标准差) 比较小, 而当取值远离其期望时, 方差 (及标准差) 比较大.

我们早就知道两个随机变量和的期望等于它们各自期望的和. 自然要问, 同样的结论对于方差是否成立. 我们发现两个随机变量和的方差还有一个称为协方差的额外项.

定义 3.3 两个随机变量 X 和 Y 的协方差为

$$\text{Cov}(X, Y) = E[(X - E[X])(Y - E[Y])].$$

定理 3.2 对任意两个随机变量 X 和 Y , 有

$$\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y] + 2\text{Cov}(X, Y).$$

证明

$$\begin{aligned} \text{Var}[X + Y] &= E[(X + Y - E[X + Y])^2] \\ &= E[(X + Y - E[X] - E[Y])^2] \\ &= E[(X - E[X])^2 + (Y - E[Y])^2 + 2(X - E[X])(Y - E[Y])] \\ &= E[(X - E[X])^2] + E[(Y - E[Y])^2] + 2E[(X - E[X])(Y - E[Y])] \\ &= \text{Var}[X] + \text{Var}[Y] + 2\text{Cov}(X, Y). \end{aligned}$$

■

练习 3.14 表明这个定理可以推广到任意有限个随机变量和。

当随机变量独立时，两个(或任意有限个)随机变量和的方差等于它们各自方差的和。等价地，如果 X 和 Y 是独立的随机变量，那么它们的协方差为 0。为证明这个结果，我们首先需要关于独立随机变量乘积的期望的结果。

定理 3.3 如果 X 和 Y 是两个独立的随机变量，那么

$$E[X \cdot Y] = E[X] \cdot E[Y].$$

证明 在下面的和式中，令 i 取遍 X 值域内所有的值， j 取遍 Y 值域内所有的值：

$$\begin{aligned} E[X \cdot Y] &= \sum_i \sum_j (i \cdot j) \cdot \Pr((X = i) \cap (Y = j)) \\ &= \sum_i \sum_j (i \cdot j) \cdot \Pr(X = i) \cdot \Pr(Y = j) \\ &= \left(\sum_i i \cdot \Pr(X = i) \right) \left(\sum_j j \cdot \Pr(Y = j) \right) \\ &= E[X] \cdot E[Y], \end{aligned}$$

其中第二行用到了 X 与 Y 的独立性。 ■

与期望的线性性不同，不管随机变量是否独立，期望的线性性对它们之和都是成立的，而两个(或多个)随机变量乘积的期望等于它们期望的乘积却未必成立，如果随机变量是相关的。为说明这一点，设 Y 和 Z 都对应于均匀硬币的投掷。如果出现正面， Y 和 Z 取值为 0；如果出现反面，取值为 1。这样 $E[Y] = E[Z] = 1/2$ 。如果两次投掷是独立的，那么 $Y \cdot Z$ 以概率 $1/4$ 取值为 1，其他为 0。所以实际上有 $E[Y \cdot Z] = E[Y] \cdot E[Z]$ 。假定代之以下面的方式，投掷硬币是相关的：将硬币捆在一起，所以 Y 和 Z 或者同时出现正面，或同时出现反面。单独考虑每个硬币仍是一枚均匀硬币。但现在 $Y \cdot Z$ 以概率 $1/2$ 取 1，所以 $E[Y \cdot Z] \neq E[Y] \cdot E[Z]$ 。

推论 3.4 如果 X 和 Y 是独立的随机变量，那么

$$\text{Cov}(X, Y) = 0$$

且

$$\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y].$$

证明

$$\begin{aligned} \text{Cov}(X, Y) &= E[(X - E[X])(Y - E[Y])] \\ &= E[X - E[X]] \cdot E[Y - E[Y]] \\ &= 0. \end{aligned}$$

第二个等式用到了这样的事实，因为 X 和 Y 是独立的，所以 $X - E[X]$ 和 $Y - E[Y]$ 也独立，因此可用定理 3.3。最后一个等式用到这样的事实，对任意随机变量 Z ，有

$$E[(Z - E[Z])] = E[Z] - E[E[Z]] = 0.$$

因为 $\text{Cov}(X, Y) = 0$ ，我们有 $\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y]$ 。 ■

由归纳法，我们可以推广推论 3.4 的结果去证明任意有限个独立随机变量和的方差等于它们方差的和。

[47]

定理 3.5 设 X_1, X_2, \dots, X_n 是独立的随机变量, 那么

$$\text{Var} \left[\sum_{i=1}^n X_i \right] = \sum_{i=1}^n \text{Var}[X_i].$$

3.2.1 例: 二项随机变量的方差

参数为 n 和 p 的二项随机变量 X 的方差可以通过计算 $E[X^2]$ 直接确定:

$$\begin{aligned} E[X^2] &= \sum_{j=0}^n \binom{n}{j} p^j (1-p)^{n-j} j^2 \\ &= \sum_{j=0}^n \frac{n!}{(n-j)! j!} p^j (1-p)^{n-j} (j^2 - j) + j \\ &= \sum_{j=0}^n \frac{n!(j^2 - j)}{(n-j)! j!} p^j (1-p)^{n-j} + \sum_{j=0}^n \frac{n! j}{(n-j)! j!} p^j (1-p)^{n-j} \\ &= n(n-1)p^2 \sum_{j=2}^n \frac{(n-2)!}{(n-j)!(j-2)!} p^{j-2} (1-p)^{n-j} \\ &\quad + np \sum_{j=1}^n \frac{(n-1)!}{(n-j)!(j-1)!} p^{j-1} (1-p)^{n-j} \\ &= n(n-1)p^2 + np. \end{aligned}$$

这里我们应用二项式定理化简了和式. 于是

$$\begin{aligned} \text{Var}[X] &= E[X^2] - (E[X])^2 \\ &= n(n-1)p^2 + np - n^2 p^2 \\ &= np - np^2 \\ &= np(1-p). \end{aligned}$$

另一种推导要求利用独立性. 回忆 2.2 节中一个二项随机变量 X 可表示成 n 个独立的伯努利试验的和, 每次试验的成功概率为 p . 这样的伯努利试验 Y 有方差

$$E[(Y - E[Y])^2] = p(1-p)^2 + (1-p)(-p)^2 = p - p^2 = p(1-p).$$

由推论 3.4, X 的方差为 $np(1-p)$.

3.3 切比雪夫不等式

利用随机变量的期望和方差, 可以推导出称为切比雪夫不等式的显著加强的尾部界.

定理 3.6 [切比雪夫不等式] 对任意的 $a > 0$, 有

$$\Pr(|X - E[X]| \geq a) \leq \frac{\text{Var}[X]}{a^2}.$$

证明 首先注意到

$$\Pr(|X - E[X]| \geq a) = \Pr((X - E[X])^2 \geq a^2).$$

因为 $(X - E[X])^2$ 是非负随机变量, 我们可以应用马尔可夫不等式证得

$$\Pr((X - E[X])^2 \geq a^2) \leq \frac{E[(X - E[X])^2]}{a^2} = \frac{\text{Var}[X]}{a^2}. \quad \blacksquare$$

下面的切比雪夫不等式的有用变形, 给出了用随机变量的标准差或期望的一个常数因子来表示随机变量与它的期望的离差的界.

推论 3.7 对任意 $t > 1$, 有

$$\Pr(|X - E[X]| \geq t \cdot \sigma[X]) \leq \frac{1}{t^2} \quad \text{及} \quad \Pr(|X - E[X]| \geq t \cdot E[X]) \leq \frac{\text{Var}[X]}{t^2(E[X])^2}.$$

我们再次考虑投掷硬币的例子, 这次应用切比雪夫不等式给出在一系列 n 次投掷均匀硬币时, 得到多于 $3n/4$ 次正面概率的界. 回忆如果第 i 次投掷出现正面, $X_i = 1$, 否则 $X_i = 0$, 且 $X = \sum_{i=1}^n X_i$ 表示 n 次硬币投掷中出现正面的次数. 为利用切比雪夫不等式, 我们需要计算 X 的方差. 首先注意到因为 X_i 是一个 0-1 随机变量,

$$E[(X_i)^2] = E[X_i] = \frac{1}{2}.$$

所以

$$\text{Var}[X_i] = E[(X_i)^2] - (E[X_i])^2 = \frac{1}{2} - \frac{1}{4} = \frac{1}{4}.$$

现在因为 $X = \sum_{i=1}^n X_i$, 且 X_i 是独立的, 我们可以利用定理 3.5 去计算

$$\text{Var}[X] = \text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i] = \frac{n}{4}.$$

再由切比雪夫不等式得

$$\begin{aligned} \Pr(X \geq 3n/4) &\leq \Pr(|X - E[X]| \geq n/4) \\ &\leq \frac{\text{Var}[X]}{(n/4)^2} \\ &= \frac{n/4}{(n/4)^2} \\ &= \frac{4}{n}. \end{aligned}$$

49

事实上我们可以做得更好一些. 切比雪夫不等式给出的 $4/n$, 实际上是 X 小于 $n/4$ 或大于 $3n/4$ 的概率界, 因此, 由对称性可知 X 大于 $3n/4$ 的概率实际上为 $2/n$. 对较大的 n , 切比雪夫不等式给出了比马尔可夫不等式显著更好的界.

3.3.1 例: 赠券收集问题

我们将马尔可夫不等式与切比雪夫不等式应用于赠券收集问题. 回忆收集 n 张赠券的时间 X 的期望为 nH_n , 其中 $H_n = \sum_{i=1}^n 1/i = \ln n + O(1)$. 因此由马尔可夫不等式得

$$\Pr(X \geq 2nH_n) \leq \frac{1}{2}.$$

为了利用切比雪夫不等式, 我们需要求出 X 的方差. 再次回忆 2.4.1 节中 $X = \sum_{i=1}^n X_i$, 其

中 X_i 是参数为 $(n-i+1)/n$ 的几何随机变量. 在这种情形下, 因为收集到第 i 张赠券的时间不依赖于收集前 $i-1$ 张赠券花了多长时间, 所以 X_i 是独立的. 因此

$$\text{Var}[X] = \text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i],$$

所以我们需要求出几何随机变量的方差.

设 Y 是参数为 p 的几何随机变量. 我们已在 2.4 节中看到, $E[X] = 1/p$. 为计算 $E[Y^2]$, 下面的诀窍是有用的. 我们知道, 对 $0 < x < 1$,

$$\frac{1}{1-x} = \sum_{i=0}^{\infty} x^i.$$

取导数, 得

$$\begin{aligned} \frac{1}{(1-x)^2} &= \sum_{i=0}^{\infty} ix^{i-1} \\ &= \sum_{i=0}^{\infty} (i+1)x^i; \\ \frac{2}{(1-x)^3} &= \sum_{i=0}^{\infty} i(i-1)x^{i-2} \\ &= \sum_{i=0}^{\infty} (i+1)(i+2)x^i. \end{aligned}$$

[50]

可以推出

$$\begin{aligned} \sum_{i=1}^{\infty} i^2 x^i &= \sum_{i=0}^{\infty} i^2 x^i \\ &= \sum_{i=0}^{\infty} (i+1)(i+2)x^i - 3 \sum_{i=0}^{\infty} (i+1)x^i + \sum_{i=0}^{\infty} x^i \\ &= \frac{2}{(1-x)^3} - 3 \frac{1}{(1-x)^2} + \frac{1}{(1-x)} \\ &= \frac{x^2 + x}{(1-x)^3}. \end{aligned}$$

由此可得

$$\begin{aligned} E[Y^2] &= \sum_{i=1}^{\infty} p(1-p)^{i-1} i^2 \\ &= \frac{p}{1-p} \sum_{i=1}^{\infty} (1-p)^{i-1} i^2 \\ &= \frac{p}{1-p} \frac{(1-p)^2 + (1-p)}{p^3} \\ &= \frac{2-p}{p^2}. \end{aligned}$$



最后, 我们得到

$$\begin{aligned}\operatorname{Var}[Y] &= E[Y^2] - E[Y]^2 \\ &= \frac{2-p}{p^2} - \frac{1}{p^2} \\ &= \frac{1-p}{p^2}.\end{aligned}$$

我们已经证明了下面有用的引理.

引理 3.8 参数为 p 的几何随机变量的方差是 $(1-p)/p^2$.

对一个几何随机变量 Y , $E[Y^2]$ 也可由条件期望导出. 我们利用 Y 对应于直到出现第一次正面所需的投掷次数, 其中每一次投掷出现正面的概率为 p . 令 $X=0$, 若第一次出现反面; $X=1$, 若第一次出现正面. 由引理 2.5,

$$\begin{aligned}E[Y^2] &= \Pr(X=0)E[Y^2 | X=0] + \Pr(X=1)E[Y^2 | X=1] \\ &= (1-p)E[Y^2 | X=0] + pE[Y^2 | X=1].\end{aligned}$$

如果 $X=1$, 那么 $Y=1$ 从而 $E[Y^2 | X=1]=1$. 如果 $X=0$, 那么 $Y>1$. 此时, 记第一次投掷后直到第一次出现正面所需的其余投掷次数为 Z . 那么由期望的线性性得到

$$\begin{aligned}E[Y^2] &= (1-p)E[(Z+1)^2] + p \cdot 1 \\ &= (1-p)E[Z^2] + 2(1-p)E[Z] + 1.\end{aligned}\quad (3.2)$$

由几何随机变量的无记忆性, Z 仍是参数为 p 的几何随机变量. 因此 $E[Z]=1/p$ 且 $E[Z^2]=E[Y^2]$. 将这些值代入(3.2)式, 我们有

$$E[Y^2] = (1-p)E[Y^2] + \frac{2(1-p)}{p} + 1 = (1-p)E[Y^2] + \frac{2-p}{p},$$

由此可得 $E[Y^2] = (2-p)/p^2$, 与其他方法计算得到的结果相符.

现在我们回到赠券收集问题中方差的讨论. 利用几何随机变量的上界 $\operatorname{Var}[Y] \leq 1/p^2$ 代替引理 3.8 中的精确结果, 可以简化讨论. 于是

$$\operatorname{Var}[X] = \sum_{i=1}^n \operatorname{Var}[X_i] \leq \sum_{i=1}^n \left(\frac{n}{n-i+1}\right)^2 = n^2 \sum_{i=1}^n \left(\frac{1}{i}\right)^2 \leq \frac{\pi^2 n^2}{6}.$$

这里我们应用了恒等式

$$\sum_{i=1}^n \left(\frac{1}{i}\right)^2 = \frac{\pi^2}{6}.$$

现在, 由切比雪夫不等式,

$$\Pr(|X - nH_n| \geq nH_n) \leq \frac{n^2 \pi^2 / 6}{(nH_n)^2} = \frac{\pi^2}{6(H_n)^2} = O\left(\frac{1}{\ln^2 n}\right).$$

此时, 切比雪夫不等式再次给出比马尔可夫不等式更好的界. 但只要用相当简单的并的界, 就可以看出这仍是一个相当弱的界.

考虑经 $n \ln n + cn$ 步后还没有得到第 i 张赠券的概率. 这个概率为

$$\left(1 - \frac{1}{n}\right)^{n(\ln n + c)} < e^{-(\ln n + c)} = \frac{1}{e^n n}.$$

由并的界, 某张赠券在 $n \ln n + cn$ 步后还没有被收集到的概率仅为 e^{-c} . 特别地, 经 $2n \ln n$ 步后, 仍没有收集齐所有赠券的概率至多为 $1/n$, 这是一个比切比雪夫不等式能达到的结果有明显改进的界.

3.4 应用: 计算中位数的随机化算法

考虑取自全序总体的 n 个元素集合 S , S 的中位数为 S 中一个元素 m , 使得在 S 中至少有 $\lfloor n/2 \rfloor$ 个元素小于等于 m , 且 S 中至少有 $\lfloor n/2 \rfloor + 1$ 个元素大于等于 m . 如果 S 中元素是互异的, 那么 m 是依 S 的排列次序的第 $(\lceil n/2 \rceil)$ 个元素. [52]

中位数容易用排序法经 $O(n \log n)$ 步确定地求得, 还有一种相对复杂的确定性算法, 经 $O(n)$ 时间计算中位数. 这里, 我们分析一种随机化线性时间算法, 它比确定性算法明显简单, 而且在线性运行时间中得到一个较小的常数因子. 为简化表示, 我们假定 n 为奇数, 且输入集合 S 中的元素是相异的. 这种算法和分析容易修改为包括多重集合 S (见练习 3.23) 和偶数个元素集合的情况.

3.4.1 算法

算法的主要思想涉及在 1.2 节讨论过的抽样, 目的是找到两个元素, 它们依 S 的排序是彼此接近的, 而且中位数位于它们之间. 特别地, 我们寻找两个元素 $d, u \in S$ 使得:

1. $d \leq m \leq u$ (中位数 m 在 d 和 u 之间); 及
2. 对 $C = \{s \in S; d \leq s \leq u\}$, $|C| = o(n/\log n)$ (在 d 和 u 之间的元素总数是少的).

为寻找两个这样的元素, 抽样给我们提供了一种简单有效的方法.

我们要求一旦验明了这样两个元素, 中位数便可以按以下步骤经线性时间容易地找到. 算法数出 (在线性时间) S 中小于 d 的元素个数 ℓ_d , 然后对集合 C 排序 (次线性时间, 或 $o(n)$ 时间). 注意到, 因为 $|C| = o(n/\log n)$, 利用任一个对 m 个元素要求 $o(m \log m)$ 时间的标准排序算法, 集合 C 可经 $o(n)$ 时间排好序. 依 C 的排序, 第 $(\lfloor n/2 \rfloor - \ell_d + 1)$ 个元素即为 m , 因为 S 中恰有 $\lfloor n/2 \rfloor$ 个元素小于那个值 ($\lfloor n/2 \rfloor - \ell_d$) 个元素在 C 中, ℓ_d 个元素在 $S - C$ 中.

为了找到元素 d 和 u , 我们从 S 中有放回抽样得到一个含 $\lceil n^{3/4} \rceil$ 个元素的多重集合 R . 有放回抽样意味着 R 中每个元素都是从集合 S 中均匀随机选取的, 与以前的选取无关. 因此, S 中同一元素可能在多重集合 R 中出现多于一次. 无放回抽样可能会给出勉强较好的界, 但执行和分析它都相当困难. 值得注意的是我们假定以不变的时间从 S 中抽出一个元素.

因为 R 是 S 的一个随机样本, 我们希望 S 的中位数元素接近于 R 的中位数元素. 因此选择 d 和 u 必须是 R 中围绕 R 的中位数的元素.

我们要求算法的所有步骤都以大的概率, 即对某个常数 $c > 0$, 至少以 $1 - O(1/n^c)$ 的概率工作. 为了以大的概率保证集合 C 包含中位数 m , 我们固定 d 和 u 分别为按 R 的排序的第 $\lfloor n^{3/4}/2 - \sqrt{n} \rfloor$ 个和第 $\lfloor n^{3/4}/2 + \sqrt{n} \rfloor$ 个元素. 有了这种选择, 集合 C 就包含了 R 的中位数附近 $2\sqrt{n}$ 个样本点之间的所有 S 的元素. 分析将阐明 R 的大小的选择以及 d 和 u 的选择都是为了保证 (a) 集合 C 足够大, 使它以大概率包含 m , (b) 集合 C 充分小, 使它能以大的概率用次线性时间排序. [53]

算法 3.1 给出了过程的正式描述. 以后, 为方便起见, 我们把 \sqrt{n} 和 $n^{3/4}$ 都当作整数.

算法 3.1 随机化中位数算法

输入: 一个全序总体上 n 个元素的集合 S .

输出: S 的中位数元素, 用 m 表示.

1. 独立地、均匀随机地、有放回地从 S 中取出 $\lceil n^{3/4} \rceil$ 个元素组成一个(多重)集合 R .
2. 对集合 R 排序.
3. 设 d 为排序集合 R 中第 $(\lfloor n^{3/4}/2 - \sqrt{n} \rfloor)$ 个最小元素.
4. 设 u 为排序集合 R 中第 $(\lceil n^{3/4}/2 + \sqrt{n} \rceil)$ 个最小元素.
5. 将集合 S 中每个元素与 d 和 u 比较, 计算集合 $C = \{x \in S: d \leq x \leq u\}$ 及数 $\ell_d = |\{x \in S: x < d\}|$ 和 $\ell_u = |\{x \in S: x > u\}|$.
6. 如果 $\ell_d > n/2$ 或 $\ell_u > n/2$, 则输出 FAIL.
7. 如果 $|C| \leq 4n^{3/4}$, 则对集合 C 排序; 否则, 输出 FAIL.
8. 输出排序集合 C 中的第 $(\lfloor n/2 \rfloor - \ell_d + 1)$ 个元素.

3.4.2 算法分析

基于前面的讨论, 我们首先证明——不管整个过程中的随机选取——算法(a)总是按线性时间结束, 而(b)输出或者是正确结果或是 FAIL.

定理 3.9 随机化中位数算法以线性时间结束, 而且如果它输出的不是 FAIL, 则它输出的是输入集合 S 的正确中位数元素.

证明 因为仅当中位数不在集合 C 中时, 算法将给出不正确的结果, 所以正确性成立. 但 $\ell_d > n/2$ 或 $\ell_u > n/2$, 从而由算法的第 6 步保证此时算法输出 FAIL. 类似地, 只要 C 充分小, 总的工作量只关于 S 的大小是线性的, 所以算法第 7 步保证了算法不会花费比线性时间更多的时间; 如果排序消耗太长时间, 则算法输出 FAIL, 且不再排序. ■

对定理 3.9 以后余留问题的分析, 其中有兴趣的是算法输出 FAIL 的概率的界. 我们通过识别三个“坏”事件给出这个概率的界, 如果这三个坏事件都不发生, 算法就不会失败. 在下一系列的引理中, 我们给出每个坏事件的概率的界, 并证明这些概率的和仅为 $O(n^{-1/4})$.

考虑下面三个事件:

$$\mathcal{E}_1: Y_1 = |\{r \in R \mid r \leq m\}| < \frac{1}{2}n^{3/4} - \sqrt{n};$$

$$\mathcal{E}_2: Y_2 = |\{r \in R \mid r \geq m\}| < \frac{1}{2}n^{3/4} - \sqrt{n};$$

$$\mathcal{E}_3: |C| > 4n^{3/4}.$$

引理 3.10 随机化中位数算法失败, 当且仅当 \mathcal{E}_1 , \mathcal{E}_2 或 \mathcal{E}_3 中至少有一个发生.

证明 在算法的第 7 步失败等价于事件 \mathcal{E}_3 . 在算法的第 6 步失败, 当且仅当 $\ell_d > n/2$ 或 $\ell_u > n/2$. 但对 $\ell_d > n/2$, R 中第 $(n^{3/4}/2 - \sqrt{n})$ 个最小元素必大于 m ; 这等价于事件 \mathcal{E}_1 . 类似地, $\ell_u > n/2$ 等价于事件 \mathcal{E}_2 . ■

引理 3.11

$$\Pr(\mathcal{E}_1) \leq \frac{1}{4}n^{-1/4}.$$

证明 定义一个随机变量 X_i 为

$$X_i = \begin{cases} 1 & \text{如果第 } i \text{ 次抽样小于等于中位数,} \\ 0 & \text{其他.} \end{cases}$$

因为抽样有放回, X_i 独立. 又因为 S 中有 $(n-1)/2+1$ 个元素小于等于中位数, 所以从 S 中随机选取一个元素小于等于中位数的概率可以写为

$$\Pr(X_i = 1) = \frac{(n-1)/2+1}{n} = \frac{1}{2} + \frac{1}{2n}.$$

事件 \mathcal{E}_1 等价于

$$Y_1 = \sum_{i=1}^{n^{3/4}} X_i < \frac{1}{2}n^{3/4} - \sqrt{n}.$$

因为 Y_1 是伯努利试验的和, 它是参数为 $n^{3/4}$ 和 $1/2+1/(2n)$ 的二项随机变量. 因此, 利用 3.2.1 节的结果得到

$$\begin{aligned} \text{Var}[Y_1] &= n^{3/4} \left(\frac{1}{2} + \frac{1}{2n} \right) \left(\frac{1}{2} - \frac{1}{2n} \right) \\ &= \frac{1}{4}n^{3/4} - \frac{1}{4n^{5/4}} \\ &< \frac{1}{4}n^{3/4}. \end{aligned}$$

55

然后由切比雪夫不等式可得

$$\begin{aligned} \Pr(\mathcal{E}_1) &= \Pr\left(Y_1 < \frac{1}{2}n^{3/4} - \sqrt{n}\right) \\ &\leq \Pr(|Y_1 - E[Y_1]| > \sqrt{n}) \\ &\leq \frac{\text{Var}[Y_1]}{n} \\ &< \frac{\frac{1}{4}n^{3/4}}{n} = \frac{1}{4}n^{-1/4}. \end{aligned}$$

类似地可得到事件 \mathcal{E}_2 的概率的同样的界. 现在我们给出第三个坏事件 \mathcal{E}_3 的概率的界.

引理 3.12

$$\Pr(\mathcal{E}_3) \leq \frac{1}{2}n^{-1/4}.$$

证明 如果 \mathcal{E}_3 发生, $|C| > 4n^{3/4}$, 那么下列两事件至少一个发生:

$\mathcal{E}_{3,1}$: C 中至少 $2n^{3/4}$ 个元素大于中位数;

$\mathcal{E}_{3,2}$: C 中至少 $2n^{3/4}$ 个元素小于中位数.

我们给出第一个事件发生的概率的界; 由对称性知第二个事件有相同的界. 如果 C 中至少

有 $2n^{3/4}$ 个元素大于中位数, 那么依 S 的排序, u 的次序至少为 $\frac{1}{2}n + 2n^{3/4}$, 这样集合 R 中至少有 $\frac{1}{2}n^{3/4} - \sqrt{n}$ 次抽样是在 S 的 $\frac{1}{2}n - 2n^{3/4}$ 个最大元素中进行的.

设 X 为在 S 的 $\frac{1}{2}n - 2n^{3/4}$ 个最大元素中的抽样次数. 记 $X = \sum_{i=1}^{n^{3/4}} X_i$, 其中

$$X_i = \begin{cases} 1 & \text{如果第 } i \text{ 次抽样是在 } S \text{ 的 } \frac{1}{2}n - 2n^{3/4} \text{ 个最大元素中进行的,} \\ 0 & \text{其他.} \end{cases}$$

X 仍为二项随机变量, 我们得到

$$E[X] = \frac{1}{2}n^{3/4} - 2\sqrt{n}$$

及

$$\text{Var}[X] = n^{3/4} \left(\frac{1}{2} - 2n^{-1/4} \right) \left(\frac{1}{2} + 2n^{-1/4} \right) = \frac{1}{4}n^{3/4} - 4n^{1/4} < \frac{1}{4}n^{3/4}.$$

由切比雪夫不等式得

$$\Pr(\mathcal{E}_{3,1}) = \Pr\left(X \geq \frac{1}{2}n^{3/4} - \sqrt{n}\right) \quad (3.3)$$

$$\leq \Pr(|X - E[X]| \geq \sqrt{n}) \leq \frac{\text{Var}[X]}{n} < \frac{\frac{1}{4}n^{3/4}}{n} = \frac{1}{4}n^{-1/4}. \quad (3.4)$$

56 类似地, 有

$$\Pr(\mathcal{E}_{3,2}) \leq \frac{1}{4}n^{-1/4}$$

及

$$\Pr(\mathcal{E}_3) \leq \Pr(\mathcal{E}_{3,1}) + \Pr(\mathcal{E}_{3,2}) \leq \frac{1}{2}n^{-1/4}. \quad \blacksquare$$

结合刚刚得到的界, 我们可以推断出算法输出 FAIL 的概率的界为

$$\Pr(\mathcal{E}_1) + \Pr(\mathcal{E}_2) + \Pr(\mathcal{E}_3) \leq n^{-1/4}.$$

由此得到下面的定理.

定理 3.13 随机化中位数算法失败的概率的界为 $n^{-1/4}$.

重复算法 3.1 直到成功地找到中位数, 我们可以得到一个永远不会失败的迭代算法, 但它有一个随机运行时间. 在算法逐次运行中所得的样本是独立的, 所以每次运行的成功跟其他运行是无关的, 因此直达到成功的运行次数是一个几何随机变量. 作为练习, 希望证明算法的这种变化(一直运行到找到一个解)仍然有线性期望运行时间.

失败或返回不正确结果的随机化算法称为蒙特卡罗 (Monte Carlo) 算法. 一个蒙特卡罗算法的运行时间通常不依赖于随机选取的方法. 例如, 在定理 3.9 中我们已经证明了: 不管它的随机选择, 随机化中位数算法总是在线性时间结束.

总是返回正确结果的随机化算法称为 Las Vegas 算法. 我们已经看到中位数的蒙特卡罗随机化算法可以通过重复运行直到成功为止而转化为 Las Vegas 算法. 把它转化为 Las Vegas 算法意味着运行时间是可变的, 尽管期望运行时间仍是线性的.

练习

- 3.1 设 X 是从 $[1, n]$ 上均匀随机选取的一个数, 求 $\text{Var}[X]$.
- 3.2 设 X 为从 $[-k, k]$ 上均匀随机选取的一个数, 求 $\text{Var}[X]$.
- 3.3 假定我们投掷一粒标准的均匀骰子 100 次. 设 X 是这 100 次投掷出现的点数之和. 利用切比雪夫不等式给出 $\Pr(|X - 350| \geq 50)$ 的界.
- 3.4 证明: 对任意的实数 c 及任意的离散随机变量 X , $\text{Var}[cX] = c^2 \text{Var}[X]$.
- 3.5 给定任意两个随机变量 X 和 Y , 由期望的线性性, 我们有 $E[X - Y] = E[X] - E[Y]$. 证明: 当 X 和 Y 独立时, $\text{Var}[X - Y] = \text{Var}[X] + \text{Var}[Y]$.
- 3.6 对于每次投掷都是以概率 p 独立地出现正面的硬币, 直到第 k 次出现正面的投掷次数的方差是什么?
- 3.7 股票市场的一个简单模型指出, 每天一支价格为 q 的股票会以概率 p 按一个 $r > 1$ 的因子增加到 qr , 以概率 $(1-p)$ 跌落到 q/r . 假定我们开始有一支价格为 1 的股票, 求 d 天后这支股票价格的期望值和方差的公式.
- 3.8 假设我们有一个算法, 以一串 n 个二进制数字作为输入, 还告知如果输入的二进制数字是独立且均匀随机选取的, 期望运行时间为 $O(n^2)$. 对大小为 n 的输入, 关于这个算法的最坏情况运行时间, 马尔可夫不等式能告诉我们什么?
- 3.9 (a) 设 X 为伯努利随机变量的和, $X = \sum_{i=1}^n X_i$, X_i 不必独立, 证明:

$$E[X^2] = \sum_{i=1}^n \Pr(X_i = 1) E[X | X_i = 1]. \quad (3.5)$$

提示: 首先证明

$$E[X^2] = \sum_{i=1}^n E[X_i X],$$

然后利用条件期望.

(b) 用 (3.5) 式给出参数为 n 和 p 的二项随机变量的方差的另一种推导.

- 3.10 对几何随机变量 X , 求出 $E[X^3]$ 和 $E[X^4]$. (提示: 利用引理 2.5.)
- 3.11 回忆练习 2.22 中的冒泡排序算法, 求用冒泡排序算法需要纠正的倒置次数的方差.
- 3.12 找一个具有有限期望和无限方差的随机变量的例子. 给出清晰的论证, 证明你的选择具有这些性质.
- 3.13 找一个具有有限 j 阶矩 ($1 \leq j \leq k$), 但 $(k+1)$ 阶矩无界的随机变量的例子. 给出清晰的论证, 证明你的选择具有这些性质.
- 3.14 证明: 对任意有限个随机变量集合 X_1, X_2, \dots, X_n , 有

$$\text{Var} \left[\sum_{i=1}^n X_i \right] = \sum_{i=1}^n \text{Var}[X_i] + 2 \sum_{i=1}^n \sum_{j>i}^n \text{Cov}(X_i, X_j).$$

3.15 设随机变量 X 表示随机变量的和 $X = \sum_{i=1}^n X_i$. 证明: 如果对每一对 i 和 $j, 1 \leq i < j \leq n$, 有

$$E[X_i X_j] = E[X_i]E[X_j], \text{ 那么 } \text{Var}[X] = \sum_{i=1}^n \text{Var}[X_i].$$

3.16 本题说明马尔可夫不等式已经紧到有可能达到等式. 给定正整数 k , 描述一个只取非负值的随机变量 X , 满足

$$\Pr(X \geq kE[X]) = \frac{1}{k}.$$

3.17 你可以举一个说明切比雪夫不等式是紧的例子吗(类似于练习 3.16 中的马尔可夫不等式)? 如果不能, 说明为什么.

3.18 证明: 对标准差为 $\sigma[X]$ 的随机变量 X 及任意正实数 t , 有:

$$(a) \quad \Pr(X - E[X] \geq t\sigma[X]) \leq \frac{1}{1+t^2};$$

$$(b) \quad \Pr(|X - E[X]| \geq t\sigma[X]) \leq \frac{2}{1+t^2}.$$

3.19 设 Y 为取非负整值的随机变量, 且有正的期望. 证明:

$$\frac{E[Y]^2}{E[Y^2]} \leq \Pr[Y \neq 0] \leq E[Y].$$

3.20 (a) 切比雪夫不等式用随机变量的方差界定它与期望的偏离, 也可以用更高阶矩. 假设有一个随机变量 X 及偶数 k , 使 $E[(X - E[X])^k]$ 有限. 证明:

$$\Pr(|X - E[X]| > t \sqrt[k]{E[(X - E[X])^k]}) \leq \frac{1}{t^k}.$$

(b) 为什么当 k 为奇数时, 导出类似的不等式是困难的?

3.21 置换 $\pi: [1, n] \rightarrow [1, n]$ 的不变点是使 $\pi(x) = x$ 的值. 求从所有置换中均匀随机选取一个置换的不变点个数的方差. (提示: 当 $\pi(i) = i$ 时, 令 X_i 为 1, 所以 $\sum_{i=1}^n X_i$ 即为不变点个数. 不能利用线性性去求 $\text{Var} \left[\sum_{i=1}^n X_i \right]$, 但可以直接计算.)

3.22 假设我们投掷一枚均匀硬币 n 次, 得到 n 个随机二进制数字. 按某个次序考虑所有 $m = \binom{n}{2}$ 个二进制数字对. 令 Y_i 为第 i 对二进制数字的异或, 并令 $Y = \sum_{i=1}^m Y_i$ 为 Y_i 等于 1 的个数.

- (a) 证明每个 Y_i 以概率 $1/2$ 为 0, 以概率 $1/2$ 为 1.
 (b) 证明 Y_i 不是独立的.
 (c) 证明 Y_i 满足性质 $E[Y_i Y_j] = E[Y_i]E[Y_j]$.

(d) 利用练习 3.15 求 $\text{Var}[Y]$.

(e) 利用切比雪夫不等式, 证明关于 $\Pr(|Y - E[Y]| \geq n)$ 的界.

- 3.23 将求中位数算法推广到输入 S 为多重集合的情况. 证明所得到的算法是正确的, 并给出其运行时间的界.
- 3.24 将求中位数算法推广到求 n 个项目集合中第 k 个最大项目, 其中 k 是任意给定值. 证明所得到的算法是正确的, 并给出其运行时间的界.
- 3.25 弱大数定律表明, 若 X_1, X_2, \dots 为独立同分布的随机变量, 其均值为 μ , 标准差为 σ , 那么对任意常数 $\varepsilon > 0$, 我们有

$$\lim_{n \rightarrow \infty} \Pr\left(\left|\frac{X_1 + X_2 + \dots + X_n}{n} - \mu\right| > \varepsilon\right) = 0.$$

利用切比雪夫不等式证明这个弱大数定律.



第4章 切尔诺夫界

本章介绍一般称为切尔诺夫界的内容。切尔诺夫界极其有用，它给出了尾部分布的指数递减的界。这些界是利用随机变量的矩母函数的马尔可夫不等式而得的。在本章我们首先定义并讨论矩母函数的性质。然后导出二项分布和其他有关分布的切尔诺夫界，并用一个集合均衡问题作为例子。为了说明切尔诺夫界的功能，我们将它们用于超立方及蝶状网络的随机化数据包传送方案的分析。

4.1 矩母函数

在提出切尔诺夫界之前，我们先讨论矩母函数 $E[e^{tX}]$ 的特殊作用。

定义 4.1 随机变量 X 的矩母函数是

$$M_X(t) = E[e^{tX}].$$

我们的主要兴趣是这个函数在零的邻域内的存在性和各种性质。

由函数 $M_X(t)$ 可以给出 X 的所有阶矩。

定理 4.1 设 X 是一个矩母函数为 $M_X(t)$ 的随机变量，在期望和微分运算交换是合理的假设下，对于所有 $n > 1$ ，我们有

$$E[X^n] = M_X^{(n)}(0),$$

其中 $M_X^{(n)}(0)$ 是 $M_X(t)$ 的 n 阶导数在 $t=0$ 处的取值。

证明 假设可以交换期望和微分运算，那么有

$$M_X^{(n)}(t) = E[X^n e^{tX}].$$

计算 $t=0$ 时的值，由上面的表达式得

$$M_X^{(n)}(0) = E[X^n]. \quad \blacksquare$$

只要矩母函数在零的邻域内存在，期望和微分运算可以交换的假设成立，本书考虑的所有分布便都是这种情况。

作为一个特殊的例子，考虑定义 2.8 中参数为 p 的几何随机变量 X 。那么，对于 $t < -\ln(1-p)$ ，

$$\begin{aligned} M_X(t) &= E[e^{tX}] \\ &= \sum_{k=1}^{\infty} (1-p)^{k-1} p e^{tk} \\ &= \frac{p}{1-p} \sum_{k=1}^{\infty} (1-p)^k e^{tk} \\ &= \frac{p}{1-p} ((1-(1-p)e^t)^{-1} - 1). \end{aligned}$$

由此



$$M_1^{(1)}(t) = p(1 - (1-p)e^t)^{-2}e^t \quad \text{及}$$

$$M_1^{(2)}(t) = 2p(1-p)(1 - (1-p)e^t)^{-3}e^{2t} + p(1 - (1-p)e^t)^{-2}e^t.$$

計算這些導數在 $t=0$ 時取值，並由定理 4.1 得到 $E[X] = 1/p$ 和 $E[X^2] = (2-p)/p^2$ ，這與之前在第 2.4 節和 3.3.1 節的計算一致。

另一個有用的性質是隨機變量的矩母函數（或者等价地，變量的所有階矩）唯一地定義它的分布。但是，下面定理的證明已經超出了本書的範圍。

定理 4.2 令 X 和 Y 是兩個隨機變量。如果對某個 $\delta > 0$ ，對於所有的 $t \in (-\delta, \delta)$ 有

$$M_{X+Y}(t) = M_X(t)M_Y(t),$$

那麼 X 和 Y 有相同分布。

定理 4.2 的一個應用是確定獨立隨機變量和的分布。

定理 4.3 如果 X 和 Y 是獨立隨機變量，那麼

$$M_{X+Y}(t) = M_X(t)M_Y(t).$$

證明

$$M_{X+Y}(t) = E[e^{t(X+Y)}] = E[e^{tX}e^{tY}] = E[e^{tX}]E[e^{tY}] = M_X(t)M_Y(t).$$

這裡我們用到了 X 和 Y 是獨立的，因此 e^{tX} 和 e^{tY} 是獨立的，從而得出 $E[e^{tX}e^{tY}] = E[e^{tX}]E[e^{tY}]$ 。 ■

因此，如果知道 $M_X(t)$ 和 $M_Y(t)$ ，並且如果將函數 $M_X(t)M_Y(t)$ 看成是一個已知分布的矩母函數，那麼由定理 4.2，這個函數必然是 $X+Y$ 的分布。我們將在隨後的章節以及練習里看到一些例子。

4.2 切爾諾夫界的導出和應用

對於某恰當選擇的 t 值，將馬爾可夫不等式用於 e^{tX} 即得到隨機變量 X 的切爾諾夫界。我們從馬爾可夫不等式導出下面有用的不等式：對任意的 $t > 0$ ，

$$\Pr(X \geq a) = \Pr(e^{tX} \geq e^{ta}) \leq \frac{E[e^{tX}]}{e^{ta}}.$$

特別地，

$$\Pr(X \geq a) \leq \min_{t>0} \frac{E[e^{tX}]}{e^{ta}}.$$

類似地，對於任意 $t < 0$ ，

$$\Pr(X \leq a) = \Pr(e^{tX} \geq e^{ta}) \leq \frac{E[e^{tX}]}{e^{ta}}.$$

因此

$$\Pr(X \leq a) \leq \min_{t<0} \frac{E[e^{tX}]}{e^{ta}}.$$

通過選取合適的 t 值而得具體分布的界。使 $E[e^{tX}]/e^{ta}$ 達到最小的 t 值給出了最好可能的界，人們常選取能給出方便形式的 t 值。由這種方法導出的界一般通稱為切爾諾夫界。當我們提到一個隨機變量的切爾諾夫界時，實際上就是用這種方式導出的很多界中的一個。

4.2.1 泊松试验和的切尔诺夫界

现在我们讨论切尔诺夫界最常用的形式：对于独立的 0-1 随机变量（也称作泊松试验）的和的尾分布。（泊松试验不同于将在 5.3 节中讨论的泊松随机变量）。在泊松试验中，随机变量的分布不必相等。伯努利试验是泊松试验的一种特殊情形，其中独立的 0-1 随机变量有相同的分布；换言之，所有试验都是以同样的概率取值为 1 的泊松随机变量。回忆二项分布给出在 n 次独立的伯努利试验中成功的次数。我们的切尔诺夫界对于二项分布是成立的，对更一般情况的泊松试验之和也成立。

设 X_1, \dots, X_n 是独立的泊松试验序列，满足 $\Pr(X_i = 1) = p_i$ ，设 $X = \sum_{i=1}^n X_i$ ，并记

$$\mu = E[X] = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] = \sum_{i=1}^n p_i.$$

对于给定的 $\delta > 0$ ，我们感兴趣的是 $\Pr(X \geq (1 + \delta)\mu)$ 及 $\Pr(X \leq (1 - \delta)\mu)$ 的界——即 X 偏离它的期望 μ 为 $\delta\mu$ 或者更多的概率。为讨论切尔诺夫界，需要计算 X 的矩母函数。我们从每个 X_i 的矩母函数开始：

$$\begin{aligned} M_{X_i}(t) &= E[e^{tX_i}] \\ &= p_i e^t + (1 - p_i) \\ &= 1 + p_i(e^t - 1) \\ &\leq e^{p_i(e^t - 1)}, \end{aligned}$$

其中在最后一个不等式中，我们用到了这样的事实：对任何 y ， $1 + y \leq e^y$ 。由定理 4.3，取 n 个矩母函数的乘积而得

$$\begin{aligned} M_X(t) &= \prod_{i=1}^n M_{X_i}(t) \\ &\leq \prod_{i=1}^n e^{p_i(e^t - 1)} \\ &= \exp\left\{\sum_{i=1}^n p_i(e^t - 1)\right\} \\ &= e^{(e^t - 1)\mu}. \end{aligned}$$

既然我们已经确定了矩母函数的界，接下来准备给出泊松试验之和的切尔诺夫界的具体形式。首先考虑超过均值的偏差。

定理 4.4 设 X_1, \dots, X_n 是独立的泊松试验，满足 $\Pr(X_i) = p_i$ ，设 $X = \sum_{i=1}^n X_i$ ， $\mu = E[X]$ 。

那么下面的切尔诺夫界成立：

1. 对任意 $\delta > 0$,

$$\Pr(X \geq (1 + \delta)\mu) \leq \left(\frac{e^\delta}{(1 + \delta)^{(1 + \delta)}}\right)^\mu; \quad (4.1)$$

2. 对任意 $0 < \delta \leq 1$,

$$\Pr(X \geq (1 + \delta)\mu) \leq e^{-\mu\delta^2/3}; \quad (4.2)$$

3. 对任意 $R \geq 6\mu$,

$$\Pr(X \geq R) \leq 2^{-R}. \quad (4.3) \quad [64]$$

定理的第一个界是最强的, 由这个界可以导出其余两个界, 而后者在许多场合具有容易叙述、便于计算的优点.

证明 由马尔可夫不等式, 对任意 $t > 0$, 我们有

$$\begin{aligned} \Pr(X \geq (1 + \delta)\mu) &= \Pr(e^{tX} \geq e^{t(1+\delta)\mu}) \\ &\leq \frac{E[e^{tX}]}{e^{t(1+\delta)\mu}} \\ &\leq \frac{e^{(e^t-1)\mu}}{e^{t(1+\delta)\mu}}. \end{aligned}$$

对任意 $\delta > 0$, 可令 $t = \ln(1 + \delta) > 0$, 从而得到(4.1):

$$\Pr(X \geq (1 + \delta)\mu) \leq \left(\frac{e^\delta}{(1 + \delta)^{(1+\delta)}} \right)^\mu.$$

为得到(4.2), 我们需要证明对于 $0 < \delta \leq 1$, 有

$$\frac{e^\delta}{(1 + \delta)^{(1+\delta)}} \leq e^{-\delta^2/3}.$$

两边取对数, 得到等价的条件

$$f(\delta) = \delta - (1 + \delta)\ln(1 + \delta) + \frac{\delta^2}{3} \leq 0.$$

计算 $f(\delta)$ 的导数, 我们有

$$f'(\delta) = 1 - \frac{1 + \delta}{1 + \delta} - \ln(1 + \delta) + \frac{2}{3}\delta$$

$$= -\ln(1 + \delta) + \frac{2}{3}\delta;$$

$$f''(\delta) = -\frac{1}{1 + \delta} + \frac{2}{3}.$$

我们看到, 对 $0 \leq \delta < 1/2$, $f''(\delta) < 0$, 而当 $\delta > 1/2$ 时, $f''(\delta) > 0$, 因此 $f'(\delta)$ 在区间 $[0, 1]$ 上先减后增. 因为 $f'(0) = 0$, 且 $f'(1) < 0$, 我们可以断定, 在区间 $[0, 1]$ 上, $f'(\delta) \leq 0$. 因为 $f(0) = 0$, 在此区间上也有 $f(\delta) \leq 0$, 这就证明了(4.2).

为证明(4.3), 设 $R = (1 + \delta)\mu$. 那么对 $R \geq 6\mu$, $\delta = R/\mu - 1 \geq 5$. 因此, 由(4.1),

$$\begin{aligned} \Pr(X \geq (1 + \delta)\mu) &\leq \left(\frac{e^\delta}{(1 + \delta)^{(1+\delta)}} \right)^\mu \\ &\leq \left(\frac{e}{1 + \delta} \right)^{(1+\delta)\mu} \end{aligned}$$

$$\leq \left(\frac{e}{6}\right)^n$$

$$\leq 2^{-n}.$$

65

对均值下方的离差的界有类似的结果。

定理 4.5 设 X_1, \dots, X_n 是独立的泊松试验, 满足 $\Pr(X_i) = p_i$, 设 $X = \sum_{i=1}^n X_i$, $\mu = E[X]$, 那么对 $0 < \delta < 1$, 有

$$1. \quad \Pr(X \leq (1 - \delta)\mu) \leq \left(\frac{e^{-\delta}}{(1 - \delta)^{(1 - \delta)}}\right)^\mu; \quad (4.4)$$

$$2. \quad \Pr(X \leq (1 - \delta)\mu) \leq e^{-\mu\delta^2/2}. \quad (4.5)$$

式(4.4)中的界仍然比(4.5)强, 但后者一般便于使用, 且足以满足大多数应用。

证明 由马尔可夫不等式, 对任意 $t < 0$, 我们有

$$\begin{aligned} \Pr(X \leq (1 - \delta)\mu) &= \Pr(e^{tX} \geq e^{t(1 - \delta)\mu}) \\ &\leq \frac{E[e^{tX}]}{e^{t(1 - \delta)\mu}} \\ &\leq \frac{e^{(e^t - 1)\mu}}{e^{t(1 - \delta)\mu}}. \end{aligned}$$

对 $0 < \delta < 1$, 令 $t = \ln(1 - \delta) < 0$ 即得(4.4):

$$\Pr(X \leq (1 - \delta)\mu) \leq \left(\frac{e^{-\delta}}{(1 - \delta)^{(1 - \delta)}}\right)^\mu.$$

为证明(4.5), 我们必须证明, 对 $0 < \delta < 1$, 有

$$\frac{e^{-\delta}}{(1 - \delta)^{(1 - \delta)}} \leq e^{-\delta^2/2}.$$

对 $0 < \delta < 1$, 两边取对数可得到等价的条件

$$f(\delta) = -\delta - (1 - \delta)\ln(1 - \delta) + \frac{\delta^2}{2} \leq 0,$$

对 $f(\delta)$ 求导得

$$f'(\delta) = \ln(1 - \delta) + \delta,$$

$$f''(\delta) = -\frac{1}{1 - \delta} + 1.$$

因为在 $(0, 1)$ 内, $f''(\delta) < 0$, 且因为 $f'(\delta) = 0$, 因此在 $[0, 1)$ 内, 我们有 $f'(\delta) \leq 0$. 所以, 在此区间内 $f(\delta)$ 非增. 因为 $f(0) = 0$, 当 $0 < \delta < 1$ 时, $f(\delta) \leq 0$, 此即所证。 ■

66

由式(4.2)及式(4.4)直接导出的下述形式的切尔诺夫界是经常使用的。

推论 4.6 设 X_1, \dots, X_n 是独立的泊松试验, 满足 $\Pr(X_i) = p_i$. 设 $X = \sum_{i=1}^n X_i$, $\mu = E[X]$, 对 $0 < \delta < 1$,

$$\Pr(|X - \mu| \geq \delta\mu) \leq 2e^{-\mu\delta^2/3}. \quad (4.6)$$

實際上，我們常常沒有 $E[X]$ 的精確值。但我們可以在定理 4.4 中用 $\mu \geq E[X]$ ，在定理 4.5 中用 $\mu \leq E[X]$ 來代替（參看練習 4.7）。

4.2.2 例：投擲硬幣

設 X 是 n 次獨立地投擲一枚均勻硬幣的序列中出現正面的次數。由式 (4.6) 的切爾諾夫界，我們有

$$\begin{aligned} \Pr\left(\left|X - \frac{n}{2}\right| \geq \frac{1}{2}\sqrt{6n \ln n}\right) &\leq 2\exp\left\{-\frac{1}{3}\frac{n}{2}\frac{6 \ln n}{n}\right\} \\ &= \frac{2}{n}. \end{aligned}$$

這說明出現正面的次數非常緊密地集中在均值 $n/2$ 周圍，在大多數時間中，與均值的偏差是 $O(\sqrt{n \ln n})$ 階的。

為了比較這個界與切比雪夫界的能力，考慮在 n 次獨立地投擲一枚均勻硬幣的序列中，出現不多於 $n/4$ 次正面或不少於 $3n/4$ 次正面的概率。我們在上一章利用切比雪夫不等式證明了

$$\Pr\left(\left|X - \frac{n}{2}\right| \geq \frac{n}{4}\right) \leq \frac{4}{n}.$$

只需計算一個顯著大事件的概率，就可看出這個界不如切爾諾夫界。在這種情況下，由切爾諾夫界，我們得到

$$\begin{aligned} \Pr\left(\left|X - \frac{n}{2}\right| \geq \frac{n}{4}\right) &\leq 2\exp\left\{-\frac{1}{3}\frac{n}{2}\frac{1}{4}\right\} \\ &\leq 2e^{-n/24}. \end{aligned}$$

即切爾諾夫方法給出的界比由切比雪夫不等式得到的界為指數級小。

4.2.3 應用：估計參數

假定我們的興趣在於計算人群中出現某種特殊基因突變的概率。給定一個 DNA 樣本，實驗室檢測可以確定是否發生了突變。但是，檢測是昂貴的，我們想要從少數幾個樣品中得到相對可靠的估計。

設 p 是我們試圖估計的未知值，假定有 n 個樣品，其中的 $X = \hat{p}n$ 個有突變。給定足夠多的樣品，希望 p 值接近於樣本值 \hat{p} ，我們利用置信區間的概念來表示這種直觀性。

定義 4.2 參數 p 的 $1-\gamma$ 置信區間是使

$$\Pr(p \in [\hat{p} - \delta, \hat{p} + \delta]) \geq 1 - \gamma$$

成立的區間 $[\hat{p} - \delta, \hat{p} + \delta]$ 。

注意，我們不是預測參數的某個值，而是給出一個可能包含參數的區間。如果 p 可取任意實值，則試圖由一有限樣本去圍住它的精確值可能是沒有意義的，但如果估計它在一個較小範圍內卻是有意義的。

自然希望區間大小 2δ 及錯誤概率 γ 都尽可能地小。我們給出這兩個參數與樣本數 n 之間的交換。特別地，已知在 n 個樣品中（從所有人羣中均勻隨機選取的）發現恰在 $X = \hat{p}n$ 個樣品中有突變，需要求 δ 及 γ 的值，使得

$$\Pr(p \in [\bar{p} - \delta, \bar{p} + \delta]) = \Pr(np \in [n(\bar{p} - \delta), n(\bar{p} + \delta)]) \geq 1 - \gamma.$$

现在 $X = n\bar{p}$ 是参数为 n 及 p 的二项分布, 从而 $E[X] = np$. 如果 $p \notin [\bar{p} - \delta, \bar{p} + \delta]$, 那么我们有以下两个事件之一:

1. 如果 $p < \bar{p} - \delta$, 那么 $X = n\bar{p} > n(p + \delta) = E[X](1 + \delta/p)$;
2. 如果 $p > \bar{p} + \delta$, 那么 $n\bar{p} < n(p - \delta) = E[X](1 - \delta/p)$.

可以用切尔诺夫界(4.2)及(4.5)计算

$$\Pr(p \notin [\bar{p} - \delta, \bar{p} + \delta]) = \Pr\left(X < np\left(1 - \frac{\delta}{p}\right)\right) + \Pr\left(X > np\left(1 + \frac{\delta}{p}\right)\right) \quad (4.7)$$

$$< e^{-np(\delta/p)^2/2} + e^{-np(\delta/p)^2/3} \quad (4.8)$$

$$= e^{-n\delta^2/2p} + e^{-n\delta^2/3p}. \quad (4.9)$$

式(4.9)给出的界是没有用处的, 因为 p 值未知. 由 $p \leq 1$ 可得一个简单的解,

$$\Pr(p \notin [\bar{p} - \delta, \bar{p} + \delta]) < e^{-n\delta^2/2} + e^{-n\delta^2/3}.$$

令 $\gamma = e^{-n\delta^2/2} + e^{-n\delta^2/3}$, 我们得到了在 δ , n 与错误概率 γ 之间的一个交换.

还可通过其他切尔诺夫界(如练习 4.13 及 4.16 那样)得到更好的界. 在第 10 章讨论蒙特卡罗方法时, 我们再回到参数估计问题上来.

4.3 某些特殊情况下更好的界

在对称随机变量的某些特殊情况下, 利用比较简单的证明方法可以得到更强的界.

首先考虑每个变量以等概率取值为 1 或者 -1 时, 独立随机变量之和.

定理 4.7 设 X_1, \dots, X_n 是独立随机变量, 满足

$$\Pr(X_i = 1) = \Pr(X_i = -1) = \frac{1}{2}.$$

记 $X = \sum_{i=1}^n X_i$, 对任意 $a > 0$, 有

$$\Pr(X \geq a) \leq e^{-a^2/2n}.$$

证明 对任意 $t > 0$,

$$E[e^{tX_i}] = \frac{1}{2}e^t + \frac{1}{2}e^{-t}.$$

为估计 $E[e^{tX}]$, 将 e^t 作泰勒级数展开,

$$e^t = 1 + t + \frac{t^2}{2!} + \dots + \frac{t^i}{i!} + \dots$$

及

$$e^{-t} = 1 - t + \frac{t^2}{2!} + \dots + (-1)^i \frac{t^i}{i!} + \dots,$$

所以

$$E[e^{tX_i}] = \frac{1}{2}e^t + \frac{1}{2}e^{-t}$$



$$\begin{aligned}
 &= \sum_{i>0} \frac{t^{2i}}{(2i)!} \\
 &\leq \sum_{i>0} \frac{(t^2/2)^i}{i!} \\
 &= e^{t^2/2}.
 \end{aligned}$$

利用这个估计得

$$E[e^{tX}] = \prod_{i=1}^n E[e^{tX_i}] \leq e^{t^2n/2}$$

及

$$\Pr(X \geq a) = \Pr(e^{tX} \geq e^{ta}) \leq \frac{E[e^{tX}]}{e^{ta}} \leq e^{t^2n/2 - ta}. \quad [69]$$

令 $t = a/n$, 我们得到

$$\Pr(X \geq a) \leq e^{-a^2/2n}.$$

由对称性, 也有

$$\Pr(X \leq -a) \leq e^{-a^2/2n}.$$

综合上述两个结果得到下面的推论.

推论 4.8 设 X_1, \dots, X_n 是独立的随机变量, 满足

$$\Pr(X_i = 1) = \Pr(X_i = -1) = \frac{1}{2}.$$

记 $X = \sum_{i=1}^n X_i$, 那么对任意 $a > 0$,

$$\Pr(|X| \geq a) \leq 2e^{-a^2/2n}.$$

作变换 $Y_i = (X_i + 1)/2$, 我们可以证明下面的推论.

推论 4.9 设 Y_1, \dots, Y_n 是独立的随机变量, 满足

$$\Pr(Y_i = 1) = \Pr(Y_i = 0) = \frac{1}{2}.$$

令 $Y = \sum_{i=1}^n Y_i, \mu = E[Y] = n/2$.

1. 对任意 $a > 0$,

$$\Pr(Y \geq \mu + a) \leq e^{-2a^2/n}.$$

2. 对任意 $\delta > 0$,

$$\Pr(Y \geq (1 + \delta)\mu) \leq e^{-\delta^2\mu}. \quad (4.10)$$

证明 利用定理 4.7 的记号, 我们有

$$Y = \sum_{i=1}^n Y_i = \frac{1}{2} \left(\sum_{i=1}^n X_i \right) + \frac{n}{2} = \frac{1}{2}X + \mu.$$



应用定理 4.7 可得

$$\Pr(Y \geq \mu + a) = \Pr(X \geq 2a) \leq e^{-4a^2/2n},$$

这就证明了推论的第 1 部分. 令 $a = \delta\mu = \delta n/2$ 可得第 2 部分的证明. 仍由定理 4.7, 我们有

$$\Pr(Y \geq (1 + \delta)\mu) = \Pr(X \geq 2\delta\mu) \leq e^{-2\delta^2\mu^2/n} = e^{-\delta^2 n}.$$

注意在界(4.10)的指数部分中的常数是 1, 而在界(4.2)中的常数是 1/3.

类似地, 我们有以下结论.

推论 4.10 设 Y_1, \dots, Y_n 是独立随机变量, 满足

$$\Pr(Y_i = 1) = \Pr(Y_i = 0) = \frac{1}{2}.$$

记 $Y = \sum_{i=1}^n Y_i, \mu = E[Y] = n/2$.

1. 对任意 $0 < a < \mu$,

$$\Pr(Y \leq \mu - a) \leq e^{-2a^2/n}.$$

2. 对任意 $0 < \delta < 1$,

$$\Pr(Y \leq (1 - \delta)\mu) \leq e^{-\delta^2 n}. \quad (4.11)$$

4.4 应用: 集合的均衡

给定一个 $n \times m$ 矩阵 A , 其元素在 $\{0, 1\}$ 中, 设

$$\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nm} \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix} = \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_n \end{bmatrix}.$$

假定寻找一个元素在 $\{-1, 1\}$ 中的向量 \bar{b} , 它极小化

$$\|A\bar{b}\|_\infty = \max_{i=1, \dots, n} |c_i|.$$

这个问题产生于统计试验设计中, 矩阵 A 的每一列表示一个试验对象, 每一行表示一个特征. 向量 \bar{b} 将试验对象分成两个分离的组, 使得每个特征在两组之间尽可能大致上均衡. 其中的一组作为在另一组上所进行的试验的控制组.

计算向量 \bar{b} 的随机化算法非常简单. 我们以 $\Pr(b_i = 1) = \Pr(b_i = -1) = 1/2$ 随机地选取 \bar{b} 的元素, 不同元素的选取是独立的. 令人惊讶的是虽然这个算法忽略了矩阵 A 的元素, 但下面的定理说明 $\|A\bar{b}\|_\infty$ 可能只是 $O(\sqrt{m \ln n})$. 这个界是相当紧的. 练习 4.15 要求证明当 $m = n$ 时, 存在一个矩阵 A , 使得对任意选择的 \bar{b} , $\|A\bar{b}\|_\infty$ 都是 $\Omega(\sqrt{n})$.

定理 4.11 对随机向量 \bar{b} , 它的元素是从集合 $\{-1, 1\}$ 中独立地且等概率地选取的, 那么

$$\Pr(\|A\bar{b}\|_\infty \geq \sqrt{4m \ln n}) \leq \frac{2}{n}.$$

证明 考虑第 i 行 $\bar{a}_i = a_{i,1}, \dots, a_{i,n}$, 设 k 是此行中 1 的个数. 如果 $k \leq \sqrt{4m \ln n}$, 那么显然有 $|\bar{a}_i \cdot \bar{b}| = |c_i| \leq \sqrt{4m \ln n}$. 另一方面, 如果 $k > \sqrt{4m \ln n}$, 我们注意到和

$$Z_i = \sum_{j=1}^n a_{i,j} b_j$$

中 k 个非零项是独立的随机变量, 每项以概率 $1/2$ 取 $+1$ 或 -1 .

现在利用推论 4.8 的切尔诺夫界及 $m \geq k$ 的事实,

$$\Pr(|Z_i| > \sqrt{4m \ln n}) \leq 2e^{-4n \ln n / 2k} \leq \frac{2}{n}.$$

由并的界, 对任一行, 这个界不成立的概率至多为 $2/n$. ■

4.5 应用: 稀疏网络中的数据包路由选择

并行计算中的一个基本问题是如何在整个稀疏通信网络中有效地通信. 我们用一个 N 个结点的有向图作为通信网络的模型, 每个结点是一个选路开关. 一条有向边模拟一个通信通道, 它连接两个相邻的选路开关. 考虑一个同步计算模型, 其中: (a) 在每一时间步, 一条边运送一个数据包; (b) 每一步, 一个数据包可以在不多于一条边上移动. 我们假定开关有缓冲器, 或者能对等待每个开关输出边传送的储存数据包进行排队.

给定一个网络拓扑, 一个路由选择算法为每对结点指定一条网络中连接这对结点的路由或边的序列. 算法还指定开关队列中有序数据包的排队策略. 例如, 按照数据包到达次序排序的先到先出策略 (FIFO); 按照数据包在网络中必须通过的边数的递减次序排列的最远者先出 (FTG) 策略.

对一给定的网络拓扑, 衡量路由选择算法性能的标准是传送任意排列的路由选择问题所要求的最大时间——以并行步数为度量, 其中每个结点恰好传送一个数据包, 且每个结点恰好是一个数据包的地址.

当然, 如果网络是所有结点都相互连接的完全图, 则只需一个并行步就可以选定一个排列. 但从实际考虑, 一个大规模的并行机网络必定是稀疏的. 每个结点只能直接连接少数几个邻点, 大部分数据包沿途必须经过中间结点才能到达他们的最终目的地. 因为一条边可能在多于一个数据包的路径上, 又因为每条边在每步只能通过一个数据包, 因而稀疏网络上并行的数据包路由选择可能导致拥挤和阻塞. 为并行计算机设计一个有效的通信方案的实际问题引出了一个有意义的组合与算法问题: 设计一个连接任意多个处理器的稀疏网络族, 并且要求以少量并行步传送任一排列的路由选择算法.

这里我们讨论一个简单却是一流的随机化路由选择技术, 然后利用切尔诺夫界分析它在超立方网络及螺旋网络上的性能. 我们首先分析在有 N 个处理器及 $O(N \log N)$ 条边的超立方网络上选择排列路由的情况, 然后对有 N 个结点和只有 $O(N)$ 条边的螺旋网络给出一个更详细的讨论.

4.5.1 超立方体网络上排列的路由选择

设 $\mathcal{N} = \{0 \leq i < N - 1\}$ 是并行机中的处理器集合, 对某个整数 n 满足 $N = 2^n$. 设 $\bar{x} = (x_1, \dots, x_n)$ 是数 $0 \leq x \leq N - 1$ 的二进制表示.

定义 4.3 n 维超立方体(或 n -立方体)是一个有 $N=2^n$ 个结点的网络, 结点 x 有到结点 y 的有向连接, 当且仅当 \bar{x} 与 \bar{y} 恰有一个二进制数字(也称为“位”——译者注)上的差别。

如图 4.1 所示, 注意 n -立方体中有向边的总数为 $2nN$, 这是因为每个结点邻接着 n 条输出边和 n 条输入边。而且网络的直径也是 n , 即存在连接网络中任意两个结点的长度直到 n 的有向路径, 也存在用任一较短路径不能连接的结点对。

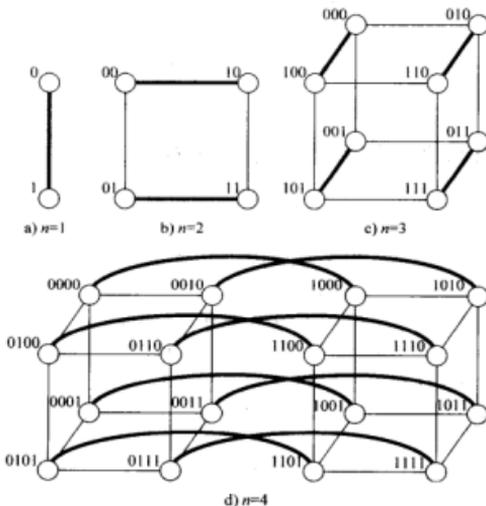


图 4.1 1, 2, 3 及 4 维超立方体

超立方体拓扑允许一个简单的位固定的路由选择机制, 如算法 4.1 所示。在确定下一次应通过哪条边时, 算法只要简单地依次考虑每个位, 如果有必要便通过这条边。

算法 4.1 n 维立方体位固定路由选择算法

1. 令 \bar{a} , \bar{b} 分别是数据包的出发地和目的地。
2. 对 $i=1$ 到 n ,

如果 $a_i \neq b_i$, 那么通过边 $(b_1, \dots, b_{i-1}, a_i, \dots, a_n) \rightarrow (b_1, \dots, b_{i-1}, b_i, a_{i+1}, \dots, a_n)$ 。

虽然这个算法看起来相当自然, 但是只利用位固定路由可能导致高度拥挤和不良的性能, 如练习 4.20 所示。存在某些位固定路由表现不佳的排列。我们将要证明, 如果从某个源发出去的每一个数据包到达均匀随机选择的目的地, 这些路由的表现是好的。由此形成下面的方法: 首先将每个数据包传送到随机选择的中间点, 然后从这个中间点传送到最终的目的地。

先将数据包传送到一个随机的中间点, 似乎有点奇怪。从某种意义上说, 这类似于 2.5 节中对快速排序法的分析。我们发现对一个已按逆序排列的列表, 快速排序法需要 $\Omega(n^2)$ 次比

较, 而对随机选择的排列, 比较的期望次数只是 $O(n \log n)$. 对于快速排序法, 将数据随机化能导致较少的运行时间. 这里也如此, 随机化数据包经过的路径——通过一个随机中间点传送——避免了不好的初始排列, 从而导致较好的期望性能.

对所有数据包并行地执行两阶段路由选择算法(算法 4.2). 对每个数据包的随机选择是独立地进行的. 我们的分析对任何遵守以下自然要求的排队策略都成立: 如果在时间步开始时队列不空, 某个数据包在该时间步内沿着与此队列有关联的边传送. 我们证明这个路由选择策略渐近地达到最优并行时间.

算法 4.2 两阶段路由选择算法

阶段 I: 用位固定路由选择, 将数据包传送到网络中随机选取的一个结点.

阶段 II: 用位固定路由选择, 将数据包从它的随机位置传送到目的地.

定理 4.12 给出一个任意排列的路由选择问题, 算法 4.2 的两阶段路由选择方案对所有数据包以 $1 - O(N^{-1})$ 的概率, 用 $O(n) = O(\log N)$ 并行步传送到它们在 n 维立方体上的目的地.

证明 我们首先分析阶段 I 的运行时间. 为简化分析, 假定在所有数据包结束阶段 I 的执行之前, 没有数据包开始执行阶段 II. 后面将证明可以去掉这一假设.

我们强调用到一个始终是不言自明的事实: 如果一个数据包传送到网络中随机选择的结点 \bar{x} , 我们可以认为 $\bar{x} = (x_1, \dots, x_n)$ 是通过令每个 x_i 独立地以 $1/2$ 概率为 0, 以 $1/2$ 概率为 1 而生成的.

对一给定的数据包 M , 令 $T_1(M)$ 表示 M 完成阶段 I 的步数, 对一个给定边 e , 令 $X_1(e)$ 表示在阶段 I 中经由边 e 传送的数据包的总数.

在执行阶段 I 的每一步中, 数据包 M 或者正经过一条边, 或者在 M 经由的一条边上排队, 等待其他数据包经过. 这个简单的观察使 M 的路由选择次数与通过 M 路径上的边来传送的数据包总数有了如下联系. [74]

引理 4.13 设 e_1, \dots, e_m 是数据包 M 在阶段 I 经过的 $m \leq n$ 条边, 那么

$$T_1(M) \leq \sum_{i=1}^m X_1(e_i).$$

我们把遵循位固定算法的 $m \leq n$ 条边组成的路径 $P = (e_1, e_2, \dots, e_m)$ 称做一个可能的数据包路径. 用 v_0, v_1, \dots, v_m 表示相应的结点, 满足 $e_i = (v_{i-1}, v_i)$. 按 $T_1(M)$ 的定义, 对任意可能的数据包路径 P , 设

$$T_1(P) = \sum_{i=1}^m X_1(e_i).$$

由引理 4.13, 在阶段 I 多于 T 步的概率不会超过对某个可能的数据包路径 P 发生 $T_1(P) \geq T$ 的概率. 注意, 因为存在 2^n 个可能的起点和 2^n 个可能的目的点, 至多存在 $2^n \cdot 2^n = 2^{2n}$ 个可能的数据包路径.

为了证明这个定理, 我们要求以大的概率来界定 $T_1(P)$. 因为 $T_1(P)$ 等于和 $\sum_{i=1}^m X_1(e_i)$, 自然想到用切尔诺夫界. 这里的困难在于 $X_1(e_i)$ 不是独立的随机变量, 这是因为经过一条边的

数据包很可能还要经过其中一条相邻边。为了防止这一困难的发生，我们先用切尔诺夫界证明，以大的概率不会有大于 $6n$ 个不同的数据包通过 P 的任一边。然后在这个事件的条件下，仍利用切尔诺夫界，导出通过路径 P 的边传送这些数据包总数的大概率界。^①

现在固定某个有 m 条边的可能的数据包路径 P 。为得到经过 P 的一条边上的数据包个数的大概率界，我们称一个数据包在路径 P 的结点 v_{i-1} 处是活动的，如果它到达 v_{i-1} 且有通过边 e_i 到达 v_i 的可能。也就是如果 v_{i-1} 与 v_i 在第 j 位上不同，那么——为了一个数据包在 v_{i-1} 处是活动的——当它到达 v_{i-1} 时，它的第 j 位不能被位固定算法固定。我们也称一个数据包是活动的，如果它在路径 P 的某个顶点处是活动的。下面我们界定活动数据包的总数。

对 $k=1, \dots, N$ ，令 H_k 是 0-1 随机变量，如果在结点 k 发出的数据包是活动的，则 $H_k=1$ ；否则， $H_k=0$ 。注意 $H_k (k=1, \dots, N)$ 是独立的，因为 (a) 每个 H_k 仅依赖于在结点 k 发出的数据包的中间目的地的选择；(b) 对所有数据包，这些选择是独立的。设 $H = \sum_{k=1}^N H_k$ 表示活动数据包的总个数。

我们首先讨论 $E[H]$ 的界。考虑所有在 v_{i-1} 处活动的数据包，假定 $v_{i-1} = (b_1, \dots, b_{j-1}, a_j, a_{j+1}, \dots, a_n)$ ， $v_i = (b_1, \dots, b_{j-1}, b_j, a_{j+1}, \dots, a_n)$ 。那么只有在地址 $(*, \dots, *, a_j, \dots, a_n)$ 之一发出的数据包在第 j 位固定之前，可能到达 v_{i-1} ，其中 $*$ 表示 0 或 1。类似地，每个这样的数据包实际上只是当其随机目的地是地址 $(b_1, \dots, b_{j-1}, *, \dots, *)$ 中之时到达 v_{i-1} 。所以，在 v_{i-1} 处存在不多于 2^{i-1} 个可能的活动数据包，每个这样的数据包在 v_{i-1} 处实际上是活动的概率为 $2^{-(i-1)}$ 。因此，在每个顶点处，活动数据包的期望个数为 1，因为我们只考虑 m 个顶点 v_0, v_1, \dots, v_{n-1} ，由期望的线性性，

$$E[H] \leq m \cdot 1 \leq n.$$

因为 H 为独立的 0-1 随机变量之和，因此可以由切尔诺夫界(用(4.3))证明

$$\Pr(H \geq 6n) \leq 6E[H] \leq 2^{-6n}.$$

关于 H 的大概率界可以帮助我们得到 $T_i(P)$ 的界如下。利用

$$\begin{aligned} \Pr(A) &= \Pr(A|B)\Pr(B) + \Pr(A|\bar{B})\Pr(\bar{B}) \\ &\leq \Pr(B) + \Pr(A|\bar{B}), \end{aligned}$$

对一个给定的可能的数据包路径 P ，我们有

$$\begin{aligned} \Pr(T_i(P) \geq 30n) &\leq \Pr(H \geq 6n) + \Pr(T_i(P) \geq 30n | H < 6n) \\ &\leq 2^{-6n} + \Pr(T_i(P) \geq 30n | H < 6n). \end{aligned}$$

因此，如果证明了

① 这种方法过度估计了完成一个阶段的时间。事实上，有一种确定性方法可以证明，在这样的设置下，数据包在路径上的延迟受到经过这条路径边的不同数据包的个数的限制，因此不需要限制在路径上传送的这些数据包的总数。但依本书之意，我们愿意介绍概率证明。

$$\Pr(T_1(P) \geq 30n \mid H < 6n) \leq 2^{-3n-1},$$

那么便有

$$\Pr(T_1(P) \geq 30n) \leq 2^{-3n},$$

这已足以证明我们的结论.

所以, 我们需要得出条件概率 $\Pr(T_1(P) \geq 30n \mid H \leq 6n)$ 的界. 换言之, 在可能使用 P 的边的活动数据包不多于 $6n$ 的条件下, 需要通过 P 的边传送这些数据包总数的界. [76]

首先我们观察到, 如果一个数据包离开路径, 在路由选择算法的这个阶段, 它不可能返回那条路径. 实际上, 假定活动数据包在 v_i , 且移动到 $w \neq v_{i+1}$, 在 v_{i+1} 与 w 中不相同的最小指标位在这个阶段的后期不可能固定, 所以数据包的路由与路径 P 在这个阶段不可能再次相交.

现在假定在路径 P 上有一个在结点 v_i 处的活动数据包, 这个数据包通过 e_i 的概率是多少? 我们把数据包作为以其目的地的二进制表示的固定位, 用每次独立随机地投掷一枚硬币给出其二进制表示. 在这种表示中, 边 e_i 的结点只有一个位 (譬如说, 在第 j 位上) 的差别. 所以, 数据包通过边 e_i 的概率至多为 $1/2$, 这是因为为了通过这条边, 对第 j 位必须选择适当值. (事实上, 概率可能小于 $1/2$; 在选择第 j 位值之前, 数据包可能经过其他的边).

为了得到我们的界, 将算法中的每一点看作一个试验, 其中在路径 P 上一个结点 v_i 处的活动数据包可能通过边 e_i . 如果数据包离开了路径, 试验成功; 如果数据包仍留在路径上, 试验失败. 因为在一次成功的试验中, 数据包离开了路径, 如果存在至多 $6n$ 个活动数据包, 那么至多可以有 $6n$ 次成功. 每次试验独立地、至少以 $1/2$ 的概率成功. 试验次数本身是一个在关于 $T_1(P)$ 的界中用到的随机变量.

我们认为活动数据包通过 P 上的边多于 $30n$ 次的概率小于投掷一枚均匀硬币 $36n$ 次出现正面少于 $6n$ 次的概率. 为验证这一点, 把每次试验当作投掷一枚硬币, 出现正面相当于成功. 每次试验硬币以适当的概率偏向于出现正面, 但这个概率总是至少为 $1/2$, 且对每次试验硬币是独立的. 每次失败 (反面) 对应于活动数据包通过一条边, 一旦有 $6n$ 次成功, 我们便知道不会有更多的数据包离开可能通过的路径边. 用一枚均匀硬币代替一枚可能偏向于成功的硬币只能减少活动数据包通过 P 的边数多于 $30n$ 次的概率, 由归纳法 (关于有偏硬币个数) 容易证明这一点.

设 Z 是在 $36n$ 次均匀硬币投掷中出现正面的次数, 现在利用切爾諾夫界 (4.5) 来证明:

$$\Pr(T_1(P) \geq 30n \mid H \leq 6n) \leq \Pr(Z \leq 6n) \leq e^{-18n(2/3)^{1/2}} = e^{-6n} \leq 2^{-3n-1}.$$

由此

$$\Pr(T_1(P) \geq 30n) \leq \Pr(H \geq 6n) + \Pr(T_1(P) \geq 30n \mid H \leq 6n) \leq 2^{-3n},$$

这正是我们所希望证明的. 因为在超立方体中至多存在 2^{2n} 个可能的数据包路径, 所以存在任意满足 $T_1(P) \geq 30n$ 的可能的数据包路径的概率的界为

$$2^{2n} 2^{-3n} = 2^{-n} = O(N^{-1}).$$

这就完成了阶段 I 的分析. 现在假定所有数据包完成了它们在阶段 I 的传送, 考虑阶段 II 的执行. 此时, 阶段 II 可以看作倒回去再执行阶段 I: 代替在一个已知起点开始到随机目的点 [77]

的数据包, 阶段 II 的数据包是在随机起点开始到达已知目的地. 所以, 在阶段 II 以概率 $1 - O(N^{-1})$ 没有数据包会多于 $30n$ 步.

事实上, 我们可以去掉只在阶段 I 完成后数据包才进入阶段 II 的假定. 由前面的讨论可以得出这样的结论: 在阶段 I 和阶段 II 期间, 通过任一数据包路径上边的数据包总数以 $1 - O(N^{-1})$ 的概率不超过 $60n$. 因为一个数据包只有当另一数据包正在通过那条边时才会被耽搁. 由此可得: 经 $60n$ 步后, 每个数据包完成阶段 I 和阶段 II 的概率为 $1 - O(N^{-1})$, 而不管两个阶段是如何相互影响的. 这就完成了定理 4.12 的证明. ■

注意, 路由选择算法的运行时间优化直到一个常数因子, 这是因为超立方体的直径是 n . 但是因为 $2nN$ 条有向边只用于传送 N 个数据包, 因而网络没有被完全利用. 在任意已知时间, 至多有边的 $1/2n$ 是实际使用的. 这个问题在下节讨论.

4.5.2 蝶形网络上排列的路由选择

这一节我们将使超立方体网络上排列的路由选择结果适合于蝶形网络上的路由选择, 从而给出网络利用上的一个显著的改进. 特别地, 本节的目的是以 $O(\log N)$ 并行时间步. 对一个有 N 个结点及 $O(N)$ 条边的网络选择一个排列. 回忆超立方体网络有 N 个结点, 但有 $\Omega(N \log N)$ 条边. 尽管在实质上与超立方体网络类似, 对蝶形网络的论证还是存在某种另外的复杂性.

我们研究如下定义的缠绕蝶形网络.

定义 4.4 缠绕蝶形网络有 $N = n2^n$ 个结点. 这些结点排列成 n 列, 2^n 行. 一个结点的地址是数对 (x, r) , 其中 $1 \leq x \leq 2^n$ 是结点的行数, $0 \leq r \leq n-1$ 是结点的列数. 结点 (x, r) 连接到结点 (y, s) , 当且仅当 $s = r + 1 \pmod n$ 且下面两个条件之一成立:

1. $x = y$, (“直接”边).
2. 在二进制表示中, x 和 y 恰好只在第 s 位上不同 (“翻转”边).

参看图 4.2. 为看出缠绕蝶形网络和超立方体网络之间的关系, 将缠绕蝶形网络每一行内的 n 个结点折迭成一个“超结点”, 我们得到一个 n 维立方网络. 利用这个对应, 容易验证存在唯一的长为 n 的有向路径将结点 (x, r) 与同一列中任意其他结点 (w, r) 连结. 这条路径由位固定得到: 首先固定 $r+1$ 到 n 的位, 然后固定 1 到 r 的位. 参见算法 4.3. 蝶形网络的随机化排列的路由选择算法由三个阶段组成, 如算法 4.4 所示.

算法 4.3 缠绕蝶形网络的位固定路由选择算法

1. 设 (x, r) 和 (y, r) 分别表示数据包的起点和目的点.
2. 对 $i=0$ 到 $n-1$, 计算

$$(a) j = ((i+r) \bmod n) + 1.$$

(b) 如果 $a_i = b_j$, 则经过直接边到模 n 的 j 列; 否则, 经过翻转边到模 n 的 j 列.

算法 4.4 三阶段路由选择算法

对于一个由结点 (x, r) 发送到结点 (y, s) 的数据包:

阶段 I: 选择一个随机的 $w \in [1, \dots, 2^n]$. 利用位固定路由选择算法, 从结点 (x, r) 将数据包发送到结点 (w, r) .

阶段 II：利用直接边，将数据包发送到结点 (u, s) 。

阶段 III：利用位固定路由选择算法，将数据包从结点 (u, s) 发送到结点 (y, s) 。

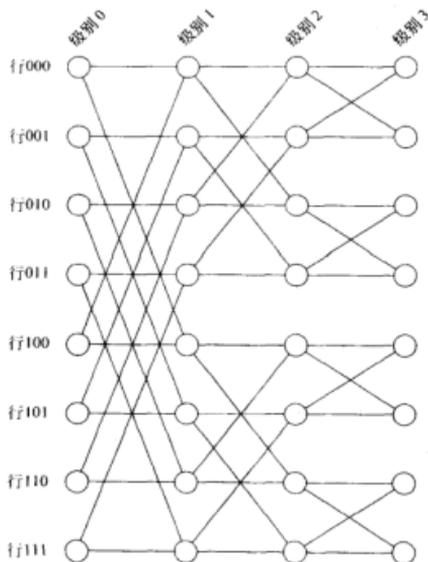


图 4.2 蝶形网络。缠绕蝶形网络包含从级别 3 倒回到级别 0 的附加边

与超立方体网络的分析不同，这里的分析不可能简单地得出可能通过路径边的活动数据包个数的界。给定一个数据包的路径，当在蝶形网络上选择一个随机排列时，与这条路径有共享边的其他数据包的期望个数为 $\Omega(n^2)$ ，而不是 n 立方中的 $O(n)$ 。为得到 $O(n)$ 路由选择次数，我们需要更精确的分析技巧，即考虑数据包通过边的次序。

为此，我们需要考虑当有几个数据包等待使用边时队列使用的优先策略。这里会用到各种优先策略；我们假定有下面的规则。

1. 数据包通过一条边的优先权是 $(i-1)n+t$ ，其中 i 是数据包的当前阶段， t 是数据包在此阶段已经通过的边数。

2. 如果在任一步，有多于一个的数据包要通过一条边，则有最小优先权的数据包先传送。

定理 4.14 在有 $N = n2^n$ 个结点的缠绕蝶形网络上，给定任意排列的路由选择问题，算法 4.4 的三阶段路由选择方案以 $1 - O(N^{-1})$ 的概率，用 $O(n) = O(\log N)$ 并行步，将所有数据包传送到它们的目的地。

证明 边队列中的优先规则保证处于某阶段的数据包不可能延迟较早阶段的数据包。由此，在我们即将进行的分析中，可以分别考虑完成每个阶段的时间，然后将这些时间相加，作

为完成三阶段路由选择方案的总时间的界。

我们从第二阶段开始考虑。首先讨论以大的概率每一行在第二阶段至多通过 $4n$ 个数据包。为此, 设 X_w 表示在三阶段路由选择算法中选择中间行是 w 的数据包的个数, 那么 X_w 是独立的 0-1 随机变量之和, 每个数据包是一个 0-1 随机变量, 且 $E[X_w] = n$ 。因此可以直接利用切尔诺夫界(4.3)得到

$$\Pr(X_w \geq 4n) \leq \left(\frac{e^3}{4^3}\right)^n \leq 3^{-2n}.$$

存在 2^n 个可能行 w , 由并的界, 任一行有多于 $4n$ 个数据包的概率只有 $2^n \cdot 3^{-2n} = O(N^{-1})$ 。

现在我们证明, 如果每一行至多有 $4n$ 个第二阶段的数据包, 那么完成第二阶段至多需要 $5n$ 步。结合前面的结论, 这就意味着以概率 $1 - O(N^{-1})$, 第二阶段至多需要 $5n$ 步。为此, 注意在第二阶段, 路由选择具有一个特殊的结构: 每个数据包沿着它的行从一条边移向另一条边。由于优先规则, 每个数据包只能在它到达时, 队列中已经有数据包等待的情况下才被延迟。所以设置延迟一个数据包 p 的数据包个数的上界, 我们就可以得到当 p 到达每个队列时, 已在这个队列中的数据包的总数的界。但在阶段 II, 一个到达的数据包发现队列中其他数据包的个数不会随时间而增加, 因为在每一步, 队列都要发送一个数据包, 而至多接收一个数据包。(一个值得考虑的特殊情况是, 在阶段 II 的某点, 当队列成为空队列时的情况, 这个队列在以后的某步可以收到其他数据包, 但在这一点以后到达的数据包在队列中找到的数据包个数永远为零。)因为在开始行至多总共有 $4n$ 个数据包, 所以当 p 从一个队列移动到另一个队列时, 它至多找到 $4n$ 个数据包会延迟它。因为每个数据包在第二阶段至多移动 n 次, 所以这一阶段的总时间至多为 $5n$ 步。

现在考虑其他阶段。由于对称性, 第一阶段与第三阶段仍是相同的, 所以只考虑第一阶段, 我们的分析将用到延迟序列。

定义 4.5 执行阶段 I 的延迟序列是一个 n 条边 e_1, \dots, e_n 的序列, 满足或者 $e_i = e_{i+1}$, 或者 e_{i+1} 是由 e_i 的终点出发的边。序列 e_1, \dots, e_n 具有进一步的性质, 即 e_i 是在 e_{i+1} 和 e_{i-1} 的两条输入边中, 以直到 i 的优先权输送数据包的最后边(之一)。

延迟序列与完成阶段 I 的时间之间的关系由下面的引理给出。

引理 4.15 对阶段 I 的一个已知执行及延迟序列 e_1, \dots, e_n , 设 t_i 是以优先权 i 通过边 e_i 发送的数据包个数, T_i 是边 e_i 完成发送优先权直到 i 的所有数据包所需要的时间, 因此 T_n 是阶段 I 期间所有要经过 e_n 的数据包已经通过 e_n 的最早时间。那么

$$1. T_n \leq \sum_{i=1}^n t_i.$$

$$2. \text{如果阶段 I 的执行需要 } T \text{ 步, 那么对这个执行, 存在一个延迟序列满足 } \sum_{i=1}^n t_i \geq T.$$

证明 由延迟序列的设计, 在时刻 T_i , e_{i+1} 的队列已经持有优先权为 $i+1$ 的需要随后传送的所有数据包, 而且在此时, 已经完成了优先权直到 i 的所有数据包的传送, 所以

$$T_{i+1} \leq T_i + t_{i+1}.$$

因为 $T_1 = t_1$, 我们有

$$\begin{aligned} T_n &\leq T_{n-1} + t_n \\ &\leq T_{n-2} + t_{n-1} + t_n \\ &\leq \sum_{i=1}^n t_i, \end{aligned}$$

这就证明了引理的第一部分.

对第二部分, 假定阶段 I 需要 T 步, 且设 e 是在时间 T 传送一个数据包的某条边. 我们可以如下构造一个满足 $e_n = e$ 的延迟序列, 即选择 e_{n-1} 为从 e 及其两条最后输送的优先权为 $n-1$ 的数据包的输入边中的一条边, 类似地选择 e_{n-2} , 一直到 e_1 . 由引理的第一部分, $\sum_{i=1}^n t_i \geq T$. [81]

回到定理 4.14 的证明, 现在我们证明一个 $T \geq 40n$ 的延迟序列的概率只有 $O(N^{-1})$. 对任意一个边的序列 e_1, \dots, e_n , 满足 $e_i = e_{i+1}$ 或 e_{i+1} 是由 e_i 的终点出发的边, 我们称这样一个序列为一个可能的延迟序列. 对一个给定的执行及一个可能的延迟序列, 记 t_i 是通过 e_i 传送的、优先权为 i 的数据包个数, $T = \sum_{i=1}^n t_i$. 我们首先界定 $E[T]$. 考虑边 $e_i = v \rightarrow v'$. 优先权为 i 的数据包通过这条边, 仅当它们的源点与 v 的距离为 $i-1$. 恰好存在 2^{i-1} 个用一条长为 $i-1$ 的有向路径连接到 v 的结点. 因为在阶段 I, 数据包传送到随机的目的点, 每一个这样的结点发送一个经由边 e_i 的数据包的概率为 2^{-i} , 从而给出

$$E[t_i] = 2^{i-1} 2^{-i} = \frac{1}{2} \quad \text{及} \quad E[T] = \frac{n}{2}.$$

现在利用延迟序列的动机清楚了, 每个可能的延迟序列定义了一个随机变量 T , 其中 $E[T] = n/2$, 所有延迟序列的最大的 T 是这一阶段运行时间的界. 所以我们需要关于 T 的界, 它以足够大的概率对所有可能的延迟序列都成立. 用类似于定理 4.12 的证明中用过的理由, 可以得到关于 T 的一个大率的界. 我们首先界定传送的边被计入 T 的不同数据包的个数.

对 $j=1, \dots, N$, 如果由结点 j 发送的数据包的任意一次传送计入 T 中, 则 $H_j = 1$; 否则, $H_j = 0$. 显然, $H = \sum_{j=1}^N H_j \leq T$, 且 $E[H] \leq E[T] = n/2$, 其中 H_j 是独立随机变量. 所以由切尔夫诺夫界(4.3)可得

$$\Pr(H \geq 5n) \leq 2^{-5n}.$$

在事件 $H \leq 5n$ 的条件下, 我们按与定理 4.12 的证明中同样的方法继续证明 T 的界. 给定一个数据包 u , 至少有一次传送计入 T , 我们考虑还有多少次 u 的传送是计入 T 的. 特别是如果 u 计入 t_i , 则考虑它计入 t_{i+1} 的概率. 我们要区别如下两种情况.

1. 如果 $e_{i+1} = e_i$, 那么 u 不计入 t_{i+1} , 因为它的优先权为 $i+1$ 的传送是在下一列. 类似地, 也不能计入任意 t_j 中, $j > i$.

2. 如果 $e_{i+1} \neq e_i$, 那么 u 继续通过 e_{i+1} (且计入 t_{i+1}) 的概率至多为 $1/2$. 如果它不继续通过 e_{i+1} , 那么在这个阶段的任何进一步的传送中, 它不能与延迟序列相交.

如定理 4.12 的证明那样, $T \geq 40n$ 的概率小于投掷一枚均匀硬币 40n 次出现正面少于 5n 次的概率。(记住在这种情况下, H 中每个数据包的第一次传送必定计入 T 中.) 设 Z 是 40n 次均匀硬币投掷中出现正面的次数, 现在用切尔诺夫界(4.5)证明

$$\Pr(T \geq 40n \mid H \leq 5n) \leq \Pr(Z \leq 5n) \leq e^{-20n(3/4)^{3/2}} \leq 2^{-5n}.$$

我们得到

$$\Pr(T \geq 40n) \leq \Pr(T \geq 40n \mid H \leq 5n) + \Pr(H \geq 5n) \leq 2^{-5n+1}.$$

存在不多于 $2N3^{n-1} \leq n2^*3^n$ 个可能的延迟序列. 所以, 在阶段 I 的执行中, 存在一个 $T \geq 40n$ 的延迟序列的概率(利用并的界)的上界为

$$n2^*3^n 2^{-5n+1} \leq O(N^{-1}).$$

因为阶段 III 完全类似于阶段 I, 且因为阶段 II 以概率 $1 - O(N^{-1})$ 也在 $O(n)$ 步内完成, 我们得到三阶段路由选择算法以 $1 - O(N^{-1})$ 的概率在 $O(n)$ 步内完成. ■

练习

- 4.1 Alice 和 Bob 经常下棋. Alice 棋艺更高, 因此她赢得任何一次给定比赛的概率是 0.6, 且与其他所有的比赛独立. 他们决定进行一场由 n 场比赛组成的联赛. 用切尔诺夫界给出 Alice 输掉这场联赛的概率的界.
- 4.2 我们有一粒标准的六面体骰子. 令 X 表示投掷 n 次骰子中出现 6 的次数. 令 p 是事件 $X \geq n/4$ 的概率. 对利用马尔可夫不等式、切比雪夫不等式以及切尔诺夫界可能得到的 p 的最好上界进行比较.
- 4.3 (a) 确定二项随机变量 $B(n, p)$ 的矩母函数.
 (b) 令 X 是一个 $B(n, p)$ 随机变量, Y 是一个 $B(m, p)$ 随机变量, 其中 X 和 Y 是独立的. 利用 (a) 来确定 $X + Y$ 的矩母函数.
 (c) 从函数 $X + Y$ 的矩母函数形式可以总结出什么?
- 4.4 通过一个直接清楚的计算确定抛掷一枚均匀硬币 100 次得到 55 次或者更多次正面的概率, 并且把这个概率与切尔诺夫界比较. 对于抛掷 1000 次得到 550 次或者更多次正面做同样的分析.
- 4.5 我们计划进行一次民意测验以了解某团体内希望弹劾他们总统的人的百分比. 假设每一个人回答是或者不是, 如果实际希望弹劾总统的人的比例是 p , 我们想得到 p 的一个估计 X , 使得对已知的 ε 和 δ , $0 < \varepsilon, \delta < 1$, 满足

$$\Pr(|X - p| \leq \varepsilon p) > 1 - \delta.$$

我们询问了从这个团体中独立地、均匀随机地选出的 N 个人, 并给出其中希望弹劾总统的比例. 为了使我们的结果是 p 的一个适当的估计, N 应取多大? 利用切尔诺夫界, 并用 p, ε 及 δ 来表示 N . 如果 $\varepsilon = 0.1, \delta = 0.05$, 并且如果知道 p 在 0.2 到 0.8 之间, 用你的界计算 N 值.

- 4.6 (a) 在一次用选票对两位候选人的选举中, 每张选票会以概率 $p = 0.02$ 被独立地登记错.

利用切尔诺夫界给出在一次有 1 000 000 张选票的选举中, 有多于 4% 的选票登记错了的概率界.

- (b) 假定登记错了的选票总作为另一位候选人的选票. 假定候选人 A 收到了 510 000 张选票, 候选人 B 收到了 490 000 张选票. 利用切尔诺夫界给出候选人 B 由于登记错了的选票而赢得这次选举的概率的界. 特别地, 设 X 是候选人 A 的登记错了的选票的张数, Y 是候选人 B 登记错了的选票的张数, 对适当选择的 k 和 ℓ , 给出 $\Pr((X > k) \cap (Y < \ell))$ 的界.

4.7 我们在本章始终不言而喻地假定切尔诺夫界的以下推广, 证明这是正确的.

设 $X = \sum_{i=1}^n X_i$, 其中 X_i 是独立的 0-1 随机变量, $\mu = E[X]$. 选择任意满足 $\mu_L \leq \mu \leq \mu_U$ 的 μ_L, μ_U . 那么, 对任意 $\delta > 0$,

$$\Pr(X \geq (1 + \delta)\mu_U) \leq \left(\frac{e^\delta}{(1 + \delta)^{(1+\delta)}} \right)^{\mu_U}.$$

类似地, 对任意 $0 < \delta < 1$,

$$\Pr(X \leq (1 - \delta)\mu_L) \leq \left(\frac{e^{-\delta}}{(1 - \delta)^{(1-\delta)}} \right)^{\mu_L}.$$

- 4.8 我们说明如何构造 $[0, 1]$ 上的随机排列 π , 给定一个独立地且均匀随机地输出来自 $[1, k]$ 中的数的黑盒子, 其中 $k \geq n$. 计算一个函数: $f: [1, n] \rightarrow [1, k]$, 对 $i \neq j$, $f(i) \neq f(j)$, 这样就产生了一个排列: 按 $f(i)$ 值的次序, 简单地输出数 $[1, n]$. 为构造这样一个函数 f , 对 $j = 1, \dots, n$, 如下进行: 重复地从黑盒子得到数, 并令 $f(j)$ 是第一个满足 $f(i) \neq f(j)$ ($i < j$) 的数, 以此来选取 $f(j)$.

证明这个方法给出了一个从所有排列中均匀随机选择的一个排列. 求 $k = n$ 及 $k = 2n$ 时需要调用黑盒子的期望次数. 对 $k = 2n$ 的情况, 证明每次调用黑盒子将 $f(j)$ 的值指派给某个 j 的概率至少为 $1/2$. 基于此, 利用切尔诺夫界给出调用黑盒子的次数至少为 $4n$ 次的概率的界.

- 4.9 假定可以得到随机变量 X 的独立样品 X_1, X_2, \dots , 还假定希望用这些样品估计 $E[X]$.

84

利用 t 个样品, 用 $\left(\sum_{i=1}^t X_i \right) / t$ 作为 $E[X]$ 的估计值. 我们希望至少以 $1 - \delta$ 的概率使估计值在来自 $E[X]$ 真值的 $\varepsilon E[X]$ 的范围内. 如果 X 不是 0-1 随机变量, 便不能利用切尔诺夫界直接界定我们的估计值有多好, 而且也不知道它的矩母函数. 我们给出另一种只要求 X 的方差有界的途径, 记 $r = \sqrt{\text{Var}[X]}/E[X]$.

(a) 利用切比雪夫不等式, 证明 $O(r^2/\varepsilon^2\delta)$ 个样品足以解决问题.

(b) 假定只需要一个较弱的估计, 即至少以 $3/4$ 的概率使估计在 $E[X]$ 的 $\varepsilon E[X]$ 内. 证明对这个较弱的估计 $O(r^2/\varepsilon^2)$ 个样品足够了.

(c) 证明: 通过取 $O(\log(1/\delta))$ 个弱估计的中位数, 可以至少以 $1 - \delta$ 的概率得到一个在 $E[X]$ 的 $\varepsilon E[X]$ 之内的估计值. 推导出只需要 $O((r^2 \log(1/\delta))/\varepsilon^2)$ 个样品.

- 4.10 娱乐场正在测试一种新型的简单的吃角子老虎机. 每次游戏, 投币人放入 1 美元, 吃角子老虎机或以 $4/25$ 的概率返还给投币人 3 美元, 或以 $1/200$ 的概率返回 100 美元, 或者以余下的概率什么也不返回. 假定每次游戏与其他次游戏独立.

这个娱乐场在测试中惊讶地发现, 在前一百万次游戏中机器损失了 10 000 美元. 导出这个事件概率的切尔诺夫界. 在导出这一界时, 可以用计算器或程序来帮助选择合适的值.

- 4.11 考虑从集合 $\{0, 1, 2\}$ 中均匀地选择的 n 个独立整数的集合 X_1, \dots, X_n . 令 $X = \sum_{i=1}^n X_i$, $0 < \delta < 1$, 导出 $\Pr(X \geq (1 + \delta)n)$ 及 $\Pr(X \leq (1 - \delta)n)$ 的切尔诺夫界.
- 4.12 考虑 n 个均值为 2 的独立的几何分布随机变量集合 X_1, \dots, X_n . 令 $X = \sum_{i=1}^n X_i, \delta > 0$.
- (a) 将切尔诺夫界用于 $(1 + \delta)(2n)$ 次投掷的均匀硬币序列, 导出 $\Pr(X \geq (1 + \delta)(2n))$ 的界.
- (b) 利用几何随机变量的矩母函数, 直接导出 $\Pr(X \geq (1 + \delta)(2n))$ 的切尔诺夫界.
- (c) 哪一个界更好?
- 4.13 设 X_1, \dots, X_n 是独立的泊松试验, 满足 $\Pr(X_i = 1) = p$. 令 $X = \sum_{i=1}^n X_i$, 那么有 $E[X] = pn$. 令

$$F(x, p) = x \ln(x/p) + (1 - x) \ln((1 - x)/(1 - p)).$$

- (a) 对 $1 \geq x > p$, 证明

$$\Pr(X \geq xn) \leq e^{-nF(x, p)}.$$

- (b) 当 $0 < x, p < 1$ 时, 证明 $F(x, p) - 2(x - p)^2 \geq 0$. (提示: 取 $F(x, p) - 2(x - p)^2$ 关于 x 的二阶导数).

- (c) 利用(a)和(b), 证明

$$\Pr(X \geq (p + \varepsilon)n) \leq e^{-2n\varepsilon^2}.$$

- (d) 利用对称性证明

$$\Pr(X \leq (p - \varepsilon)n) \leq e^{-2n\varepsilon^2},$$

并推断出

$$\Pr(|X - pn| \geq \varepsilon n) \leq 2e^{-2n\varepsilon^2}.$$

- 4.14 修改定理 4.4 的证明, 给出泊松试验加权和的下列界. 设 X_1, \dots, X_n 是独立的泊松试验, $\Pr(X_i) = p_i$, $a_1 \cdots a_n$ 是 $[0, 1]$ 中的实数. 令 $X = \sum_{i=1}^n a_i X_i, \mu = E[X]$. 那么下面的切尔诺夫界成立: 对任一 $\delta > 0$,

$$\Pr(X \geq (1 + \delta)\mu) \leq \left(\frac{e^\delta}{(1 + \delta)^{(1 + \delta)}} \right)^\mu.$$

对任意 $0 < \delta < 1$, 证明 $X \leq (1 - \delta)\mu$ 的概率有类似的界.

- 4.15 设 X_1, \dots, X_n 是独立随机变量, 满足

$$\Pr(X_i = 1 - p_i) = p_i \quad \text{及} \quad \Pr(X_i = -p_i) = 1 - p_i.$$

设 $X = \sum_{i=1}^n X_i$. 证明

$$\Pr(|X| \geq a) \leq 2e^{-2a^2/n}.$$

提示: 可能需要不等式

$$p_i e^{X_i(1-p_i)} + (1-p_i)e^{-X_i} \leq e^{X_i^2/8}.$$

直接证明这个不等式是困难的.

- 4.16 设 X_1, \dots, X_n 是独立的泊松试验, $\Pr(X_i) = p_i$. 令 $X = \sum_{i=1}^n a_i X_i, \mu = E[X]$. 利用练习 4.15 的结果证明: 对任 $0 < \delta < 1$,

$$\Pr(|X - \mu| \geq \delta\mu) \leq 2e^{-2\delta^2\mu^2/n}.$$

- 4.17 假定有 n 项任务分配给 m 台处理器. 为简单起见, 假定 m 整除 n . 一项任务以概率 p 一步完成, 以概率 $1-p$ 需 $k > 1$ 步完成. 如果我们为每台处理器随机地指派恰好 n/m 项任务, 利用切爾諾夫界确定所有任务全部完成所需时间的上界和下界 (以大的概率成立).

- 4.18 在许多无线电通信系统中, 每台接收机以某个特殊频率收听. 在时间 t 发出的位信号 $b(t)$ 分别是 1 或 -1, 不幸的是, 来自附近的其他通信噪声可能影响接收机信号. 这种噪声的简单模型如下: 有 n 台其他发报机. 第 i 台的强度为 $p_i \leq 1$. 在任一时刻 t , 第 i 台发报机也要发送表示为 1 或 -1 的位信号 $b_i(t)$, 接收机得到的信号 $s(t)$ 为

$$s(t) = b(t) + \sum_{i=1}^n p_i b_i(t).$$

如果 $s(t)$ 接近于 1 而不是 -1, 接收机假定这个在 t 时刻发出的位信号是 1; 否则, 接收机假定它为 -1.

假定所有位信号 $b_i(t)$ 都可当作独立的均匀随机变量. 给出切爾諾夫界以估计接收机在确定 $b(t)$ 时的出错概率.

- 4.19 一个函数 f 称为凸的, 如果对任意 x_1, x_2 , 及 $0 \leq \lambda \leq 1$,

$$f(\lambda x_1 + (1-\lambda)x_2) \leq \lambda f(x_1) + (1-\lambda)f(x_2).$$

(a) 设 Z 是在区间 $[0, 1]$ 中一个 (有限) 值集合上取值的随机变量, $p = E[Z]$. 由 $\Pr(X=1) = p$ 和 $\Pr(X=0) = 1-p$ 定义一个伯努利随机变量. 证明对任意的凸函数 f , $E[f(Z)] \leq E[f(X)]$.

(b) 利用对任意 $t \geq 0$, $f(x) = e^{tx}$ 是凸函数的事实, 基于 X 的切爾諾夫界, 给出 Z 的切爾諾夫型界.

- 4.20 我们证明, 随机化快速排序算法以大的概率用 $O(n \log n)$ 时间将一个 n 个数的集合排序.

考虑随机化快速排序法的以下见解。算法中决定基准元素的每一点称为一个结点。假定在某个特殊结点排序的集合大小为 s 。结点称为好的，如果基准元素将集合分成两部分，每一部分的大小不超过 $2s/3$ ；否则，称结点是坏的。可以认为这些结点形成一棵树，其中根结点拥有整个待排序的集合，子结点拥有第一个基准步后形成的两个集合，等等。

(a) 证明在这棵树上任一从根到叶的路径中，好结点的个数不会大于 $c \log_2 n$ ，其中 c 是某个正的常数。

(b) 证明：以大的概率（大于 $1 - 1/n^2$ ），这棵树上一条给定的从根到叶的路径中，结点的个数不大于 $c' \log_2 n$ ，其中 c' 是另一常数。

(c) 证明：以大的概率（大于 $1 - 1/n$ ），从根到叶的最长的路径中，结点的个数不大于 $c' \log_2 n$ 。（提示：在这棵树上有多少个结点？）

(d) 利用你的答案证明至少以 $O(n \log n)$ 的概率，快速排序法的运行时间是 $1 - 1/n$ 。

87

4.21 考虑在 n 维立方体上选择一个排列的位固定路由选择算法。假定 n 是偶数。将每个源结点 s 写作每个长为 $n/2$ 的两个二进制数字串 a_i 和 b_i 的串联。令 s 的数据包终点是 b_i 和 a_i 的串联。证明这个排列要求位固定路由选择算法 $\Omega(\sqrt{N})$ 步。

4.22 为在 n 维立方体中选择一个排列，考虑位固定路由选择算法的以下修改。假定每个数据包选择一个随机次序（与其他数据包的选择无关）且以那个次序固定位，而不是按从 1 到 n 的次序固定位。证明存在一个排列，使得这个算法以大的概率只需要 $2^{O(n)}$ 步。

4.23 假定我们用 n 维立方体网络的随机化路由选择算法（算法 4.2）传送总数直到 $p2^n$ 个数据包，其中每个结点是不多于 p 个数据包的源点，且每个结点是不多于 p 个数据包的终点。

(a) 以大的概率给出这个算法运行时间的界；

(b) 以大的概率给出在路由选择算法执行的任一步的任一结点处，数据包最大个数的界。

4.24 证明在 $N = n2^n$ 个结点的缠绕蝶形网络上选择一个随机排列时，经过一个给定数据包路径上的任一边的数据包的期望个数为 $\Omega(n^2)$ 。

4.25 在这个练习中，我们为以下的数据包路由选择问题设计一种随机化算法。给定一个网络，它是无向连通图 G ，其中的结点表示处理器，结点之间的边表示导线。还给出了 N 个要传送的数据包的集合。我们为每个数据包给出一个源结点，一个终结点以及这个数据包从源点到它的终点会经过的精确路由（图中的路径）。（可以假定路径中没有圈。）在每一时间步，至多有一个数据包能通过一条边。任一时间步内，数据包在任一结点处可以等待，还假定在每一结点处 unlimited 队列长。

数据包集合的程序表为每个数据包安排沿着它们各自的路由移动的时间，也就是在每个时间步中指定了哪一个数据包移动，哪一个数据包等待。我们的目的是制作一张数据包程序表，希望极小化传送所有数据包到达它们的终点所需要的总时间和最大的队列长。

(a) 扩张 d 是任一数据包经过的最大距离，拥塞 c 是在整个传送期间，一条边必须经过

的数据包的最大个数. 证明任一程序表要求的时间至少为 $\Omega(c+d)$.

- (b) 考虑下面的无约束程序表. 其中在单个时间步期间, 可能有多个数据包经过一条边. 为每个数据包指定一个从区间 $[1, \lceil \alpha c / \log(Nd) \rceil]$ 上独立地、均匀随机选取的整数延迟, 其中 α 是常数. 一个被指派了延迟 x 的数据包在它的源结点等待 x 时间步; 然后按照它的特殊路由不停地移动到其最终的目的点. 给出在某个特殊的时间步 t 有多于 $O(\log(Nd))$ 个数据包通过任一边 e 的概率的上界. [88]
- (c) 仍用(b)中的无约束程序表, 证明对充分大的 α , 在任一时间步有多于 $O(\log(Nd))$ 个数据包通过任一边的概率至多为 $1/(Nd)$.
- (d) 利用无约束程序表导出一个简单的随机化算法, 即以大的概率, 利用长为 $O(\log(Nd))$ 的队列且服从每一时间步至多有一个数据包经过一条边的约束, 制作一个长度为 $O(c+d\log(Nd))$ 的程序表. [89]



第5章 球、箱子和随机图

这一章，我们关注最基本的随机过程之一： m 个球随机地投入 n 个箱子，投入一个箱子里的每个球是独立且均匀随机地选取的。我们用前面提出的方法来分析这一过程，并提出了一种新的基于泊松近似的方法，我们说明这个模型的一些应用，包括赠券收集问题的更深入分析及 Bloom 过滤器数据结构的分析。在介绍与随机图密切相关的模型后，我们证明在一个有充分多条边的随机图上寻找哈密顿圈的有效算法。尽管在一般情况下寻找哈密顿圈是 NP 难题，但对一个随机选取的图，我们的结果表明，以大的概率在多项式时间内，这个问题是可解的。

5.1 例：生日悖论

参加一次讲座，注意到教室里有 30 人，是坐在教室里的某两人有相同的生日更可能呢？还是教室里没有两人会有相同的生日更可能呢？

假定每个人的生日是一年 365 天中随机的一天，每人都是独立地且均匀随机地选取的，在这个假定下，可以建立这个问题的模型。假定显然是简化的，例如，假定每个人的生日在一年内的任一天是等可能的，我们回避了闰年，也忽略了双胞胎的可能！但作为一个模型，这样的假定有容易理解和分析的优点。

计算这个概率的一个方法是直接对两个人不是同一生日的结构进行计数。考虑每个人有各不相同的生日的结构比考虑某两个人不是同一生日的结构更容易。需要从 365 天中选取 30 天，有 $\binom{365}{30}$ 种情况，可以用 30! 种可能次序中的任何一种将这 30 天指派给这些人。所以在 365^{30}

90 种可能出现的生日中，存在 $\binom{365}{30} 30!$ 种结构，使没有两人具有相同的生日。因此概率是

$$\frac{\binom{365}{30} 30!}{365^{30}}. \quad (5.1)$$

也可以用每次考虑一个人的方法来计算这个概率。教室中的第一个人有一个生日，第二个人有不同生日的概率是 $\left(1 - \frac{1}{365}\right)$ ，在已知前两人有不同生日的情况下，教室里第三个人与前面两位有不同生日的概率为 $\left(1 - \frac{2}{365}\right)$ 。继续下去，在假定前 $k-1$ 人有不同生日的条件下，教室里面的第 k 人与前面 $k-1$ 人有不同生日的概率为 $\left(1 - \frac{k-1}{365}\right)$ 。所以 30 个人全都有不同生日的概率是这些项的乘积，或

$$\left(1 - \frac{1}{365}\right) \cdot \left(1 - \frac{2}{365}\right) \cdot \left(1 - \frac{3}{365}\right) \cdots \left(1 - \frac{29}{365}\right).$$

可以验证, 它和式(5.1)是完全一样的.

计算表明(到四个小数位)这个乘积是 0.293 7, 所以当 30 人在教室中时, 有多于 70% 的机会两个人有相同的生日. 类似的计算说明, 教室里只需有 23 人, 有两人有相同生日就比设有两人有相同生日的可能性大.

更一般地, 如果有 m 个人, 有 n 个可能的生日, 那么所有 m 人有不同生日的概率为

$$\left(1 - \frac{1}{n}\right) \cdot \left(1 - \frac{2}{n}\right) \cdot \left(1 - \frac{3}{n}\right) \cdots \left(1 - \frac{m-1}{n}\right) = \prod_{j=1}^{m-1} \left(1 - \frac{j}{n}\right).$$

利用当 k 与 n 相比较小时, $1 - k/n \approx e^{-k/n}$, 可以得到, 如果 m 相对于 n 较小, 则

$$\begin{aligned} \prod_{j=1}^{m-1} \left(1 - \frac{j}{n}\right) &= \prod_{j=1}^{m-1} e^{-j/n} \\ &= \exp\left\{-\sum_{j=1}^{m-1} \frac{j}{n}\right\} \\ &= e^{-m(m-1)/2n} \\ &\approx e^{-m^2/2n}. \end{aligned}$$

因此, 能使所有 m 人有不同生日的概率为 $1/2$ 的 m 值, 近似地由等式

$$\frac{m^2}{2n} = \ln 2$$

给出, 或者 $m = \sqrt{2n \ln 2}$. 对 $n = 365$ 的情况, 这个近似到两位小数的近似值为 $m = 22.49$, 与精确计算有相当好的一致性.

不用刚导出的近似式, 而是考虑练习 5.3 中的方法, 可以给出更紧的、更正式的界. 但以下简单的说明给出了宽松的界, 它有很好的直观性. 我们每次考虑一个人, 令 E_k 表示第 k 人生日与前面 $k-1$ 人中的每一个人的生日都不相同的事件. 那么前 k 人不会有不同生日的概率为

[9]

$$\begin{aligned} \Pr(\bar{E}_1 \cup \bar{E}_2 \cup \cdots \cup \bar{E}_k) &\leq \sum_{i=1}^k \Pr(\bar{E}_i) \\ &\leq \sum_{i=1}^k \frac{i-1}{n} \\ &= \frac{k(k-1)}{2n}. \end{aligned}$$

如果 $k \leq \sqrt{n}$, 这个概率小于 $1/2$, 所以对 $\lfloor \sqrt{n} \rfloor$ 个人, 所有生日都不相同的概率至少为 $1/2$.

现在假定前 $\lfloor \sqrt{n} \rfloor$ 人都有不同的生日, 以后的每个人与前 $\lfloor \sqrt{n} \rfloor$ 人之一有相同生日的概率至少为 $\sqrt{n}/n = 1/\sqrt{n}$. 因此后 $\lfloor \sqrt{n} \rfloor$ 人与前 $\lfloor \sqrt{n} \rfloor$ 人有不同生日的概率至多为

$$\left(1 - \frac{1}{\sqrt{n}}\right)^{\lfloor \sqrt{n} \rfloor} < \frac{1}{e} < \frac{1}{2}.$$

因此, 只要有 $2\lfloor \sqrt{n} \rfloor$ 人, 所有生日全不相同的概率便至多为 $1/e$.

5.2 球和箱子模型

5.2.1 球和箱子模型

生日悖论是一个常用球和箱子来模拟的更一般数学框架的一个例子. 我们有 m 个球, 要放入 n 个箱子中, 每个球的位置是从 n 种可能中独立地且均匀随机地选取的. 箱子中球的分布看起来像是什么? 在生日悖论中出现的问题为是否存在有两个球的箱子.

关于这个随机过程, 我们可以提出一些有意义的问题. 例如, 多少个箱子是空的? 在最满的箱子中有多少个球? 其中的许多问题在算法的设计与分析中得到了应用.

我们对生日悖论的分析表明, 如果将 m 个球随机地放入 n 个箱子, 那么对某个 $m = \Omega(\sqrt{n})$, 至少有一个箱子中可能会有多于一个的球. 另一个有意义的问题是关心一个箱子里球的最大个数, 或最大负荷. 考虑 $m = n$, 即球的个数等于箱子数且平均负荷为 1 的情况. 当然, 最大的可能负荷为 n , 但所有 n 个球落到同一箱子的可能性是非常小的. 我们寻找随着 n 增大, 以趋于 1 的概率成立的一个上界. 通过直接计算并利用并的界可以证明, 对充分大的 n , 至多以 $1/n$ 的概率, 最大负荷不大于 $3 \ln n / \ln \ln n$. 这是一个非常宽松的界, 虽然实际上最大负荷以接近于 1 的概率 (如以后我们所证明的那样) 为 $\Omega(\ln n / \ln \ln n)$, 这里我们选用常数因子 3 是为了简化证明, 如果比较较的话, 该因子还可减小.

引理 5.1 将 n 个球独立地且均匀随机地放入 n 个箱子里, 对充分大的 n , 最大负荷大于 $3 \ln n / \ln \ln n$ 的概率至多为 $1/n$.

证明 箱子 1 至少得到 M 个球的概率至多为

$$\binom{n}{M} \left(\frac{1}{n}\right)^M.$$

由并的界这是成立的; 存在 M 个球的 $\binom{n}{M}$ 个不同集合, 对任一 M 个球的集合, 全都落入箱子 1 的概率为 $(1/n)^M$. 现在, 我们利用不等式

$$\binom{n}{M} \left(\frac{1}{n}\right)^M \leq \frac{1}{M!} \leq \left(\frac{e}{M}\right)^M.$$

这里第二个不等式是下面的关于阶乘的更一般界的一个推论: 因为

$$\frac{k^i}{k!} < \sum_{i=0}^{\infty} \frac{k^i}{i!} = e^i,$$

我们有

$$k! > \left(\frac{k}{e}\right)^k.$$

再次由并的界, 对 $M \geq 3 \ln n / \ln \ln n$, 可得对充分大的 n , 任一箱子至少得到 M 个球的概率有上界

$$\begin{aligned}
 n \left(\frac{e}{M} \right)^M &\leq n \left(\frac{e \ln \ln n}{3 \ln n} \right)^{3 \ln n / \ln \ln n} \\
 &\leq n \left(\frac{\ln \ln n}{\ln n} \right)^{3 \ln n / \ln \ln n} \\
 &= e^{\ln n \cdot (e^{-\ln \ln \ln n - \ln \ln n})^{3 \ln n / \ln \ln n}} \\
 &= e^{-2 \ln n + 3(\ln n)(\ln \ln \ln n) / \ln \ln n} \\
 &\leq \frac{1}{n}.
 \end{aligned}$$

5.2.2 应用：桶排序

桶排序是排序算法的一个例子. 在对输入的一定假定下, 它突破了标准的比较排序法的下界 $\Omega(n \log n)$. 例如, 假定有一个 $n = 2^k$ 个元素的集合需要排序, 每个元素是从 $[0, 2^k)$ ($k \geq m$) 范围内独立地且均匀随机地选取的一个整数. 利用桶排序, 我们可以在期望时间 $O(n)$ 内排好这些数, 这里的期望是关于随机输入的选取来计算的, 因为桶排序是一种完全确定算法.

桶排序分两个阶段: 第一阶段, 将元素放入 n 个桶中, 第 j 桶存放所有前 m 个二进制数字对应于数 j 的元素. 例如, 如果 $n = 2^{10}$, 那么第 3 桶应含有所有前 10 个二进制数字为 0000000011 的元素. 当 $j < \ell$ 时, 在这个排序中所有第 j 桶元素应在第 ℓ 桶元素之前. 假定每个元素经 $O(1)$ 时间就可以放入适当的桶内, 这一阶段只要求 $O(n)$ 时间. 因为假定待排序的元素是均匀选取的, 所以放入某个特定桶中的元素个数服从二项分布 $B(n, 1/n)$. 可以用链表实现桶排序.

第二阶段, 利用任一标准的二次时间算法 (例如冒泡排序法或插入排序法) 对每个桶排序. 依次连接每个桶的排序表, 就给出了元素的排序. 剩下的问题是证明在第二阶段所用的期望时间只是 $O(n)$.

这个结果依赖于有关输入分布的假定. 在均匀分布下, 桶排序自然属于球和箱子模型: 元素是球, 桶是箱子, 每个球均匀随机地落入一个箱子.

设 X_j 是落入第 j 桶的元素个数, 那么对第 j 桶排序的时间至多为 $c(X_j)^2$, 其中 c 是某个常数. 用在第二阶段排序的期望时间至多为

$$E \left[\sum_{j=1}^n c(X_j)^2 \right] = c \sum_{j=1}^n E[X_j^2] = cnE[X_1^2],$$

其中第一个等式成立是由于期望的线性性, 第二个等式是由于对称性, 因为对所有桶, $E[X_j^2]$ 是相同的.

因为 X_1 是一个二项随机变量 $B(n, 1/n)$, 由 3.2.1 节的结果得到

$$E[X_1^2] = \frac{n(n-1)}{n^2} + 1 = 2 - \frac{1}{n} < 2.$$

因此用在第二阶段的总的期望时间至多为 $2cn$, 所以桶排序法需要以期望的线性时间运行.

5.3 泊松分布

现在我们考虑有 m 个球、 n 个箱子的球和箱子模型中，一个给定箱子是空的概率以及空箱子的期望个数。为了第 1 个箱子是空的，必定是所有 m 个球都没有落入，因为每个球以 $1/n$ 的概率落入第 1 个箱子，所以第 1 个箱子一直是空的概率为

$$\left(1 - \frac{1}{n}\right)^m \approx e^{-m/n};$$

当然，由对称性，这个概率对所有箱子是一样的。如果 X_j 是一个随机变量，当第 j 个箱子是空时，它是 1；否则，它是 0，那么 $E[X_j] = (1 - 1/n)^m$ 。设 X 是表示空箱子个数的随机变量，那么由期望的线性性，

$$E[X] = E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] = n\left(1 - \frac{1}{n}\right)^m \approx ne^{-m/n}.$$

所以，空箱子的期望比例近似为 $e^{-m/n}$ 。即使对中等大小的 m 和 n ，这个近似值也是非常好的，我们将在本章内经常用到它。

可以推广前面的证明来求有 r 个球的箱子的期望比例，其中 r 是任意常数。一个给定箱子有 r 个球的概率为

$$\binom{m}{r} \left(\frac{1}{n}\right)^r \left(1 - \frac{1}{n}\right)^{m-r} = \frac{1}{r!} \frac{m(m-1)\cdots(m-r+1)}{n^r} \left(1 - \frac{1}{n}\right)^{m-r}.$$

当 m 和 n 相对于 r 比较大时，右边的第二个因子近似为 $(m/n)^r$ ，第三个因子近似为 $e^{-m/n}$ 。因此一个给定的箱子有 r 个球的概率 p_r 近似为

$$p_r \approx \frac{e^{-m/n} (m/n)^r}{r!}, \quad (5.2)$$

并且恰有 r 个球的箱子的期望个数近似为 np_r 。我们将在 5.3.1 节中用公式表示这个关系。

前面的计算自然让我们考虑下面的分布。

定义 5.1 一个参数为 μ 的离散泊松随机变量 X 由以下在 $j=0, 1, 2, \dots$ 上的概率分布给出：

$$\Pr(X = j) = \frac{e^{-\mu} \mu^j}{j!}.$$

(注意泊松随机变量与在 4.2.1 节讨论的泊松试验不一样。)

我们用概率之和为 1 来验证这个定义给出了一个恰当的概率分布。

$$\begin{aligned} \sum_{j=0}^{\infty} \Pr(X = j) &= \sum_{j=0}^{\infty} \frac{e^{-\mu} \mu^j}{j!} \\ &= e^{-\mu} \sum_{j=0}^{\infty} \frac{\mu^j}{j!} \\ &= 1, \end{aligned}$$



其中用到了泰勒展开式 $e^x = \sum_{j=0}^{\infty} (x^j/j!)$.

下面证明这个随机变量的期望为 μ :

$$\begin{aligned} E[X] &= \sum_{j=0}^{\infty} j \Pr(X = j) \\ &= \sum_{j=1}^{\infty} j \frac{e^{-\mu} \mu^j}{j!} \\ &= \mu \sum_{j=1}^{\infty} \frac{e^{-\mu} \mu^{j-1}}{(j-1)!} \\ &= \mu \sum_{j=0}^{\infty} \frac{e^{-\mu} \mu^j}{j!} \\ &= \mu. \end{aligned}$$

在将 m 个球放入 n 个箱子的问题中, 一个箱子内球的个数的分布近似地是 $\mu = m/n$ 的泊松分布, 如人们可以预料的那样, $\mu = m/n$ 恰是每个箱子中球的平均个数.

泊松分布的一个重要性质由下面的引理给出.

引理 5.2 有限个独立泊松随机变量的和是泊松随机变量.

证明 考虑两个均值为 μ_1 和 μ_2 的独立泊松随机变量 X 和 Y , 更多随机变量的情况用归纳法简单处理. 现在

$$\begin{aligned} \Pr(X + Y = j) &= \sum_{k=0}^j \Pr((X = k) \cap (Y = j - k)) \\ &= \sum_{k=0}^j \frac{e^{-\mu_1} \mu_1^k}{k!} \frac{e^{-\mu_2} \mu_2^{(j-k)}}{(j-k)!} \\ &= \frac{e^{-(\mu_1 + \mu_2)}}{j!} \sum_{k=0}^j \frac{j!}{k!(j-k)!} \mu_1^k \mu_2^{(j-k)} \\ &= \frac{e^{-(\mu_1 + \mu_2)}}{j!} \sum_{k=0}^j \binom{j}{k} \mu_1^k \mu_2^{(j-k)} \\ &= \frac{e^{-(\mu_1 + \mu_2)} (\mu_1 + \mu_2)^j}{j!}. \end{aligned}$$

在最后一个等式中用二项式定理简化了和式.

我们也可用矩母函数来证明引理 5.2.

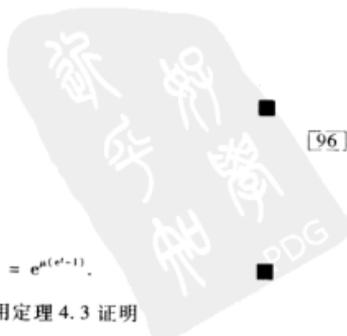
引理 5.3 参数为 μ 的泊松随机变量的矩母函数是

$$M_x(t) = e^{\mu(e^t - 1)}.$$

证明 对任意的 t ,

$$E[e^{tX}] = \sum_{k=0}^{\infty} \frac{e^{-\mu} \mu^k}{k!} e^{tk} = e^{\mu(e^t - 1)} \sum_{k=0}^{\infty} \frac{e^{-\mu e^t} (\mu e^t)^k}{k!} = e^{\mu(e^t - 1)}.$$

已知两个均值为 μ_1 和 μ_2 的独立泊松随机变量 X 和 Y , 我们用定理 4.3 证明



$$M_{Y+Z}(t) = M_Y(t) \cdot M_Z(t) = e^{(\mu_1 + \mu_2)(e^t - 1)},$$

这是均值为 $\mu_1 + \mu_2$ 的泊松随机变量的矩母函数. 由定理 4.2, 矩母函数唯一确定分布, 因此和 $X + Y$ 是均值为 $\mu_1 + \mu_2$ 的泊松随机变量.

下面我们给出泊松随机变量的切尔诺夫界, 在本章稍后将要用到它.

定理 5.4 设 X 是参数为 μ 的泊松随机变量.

1. 如果 $x > \mu$, 则

$$\Pr(X \geq x) \leq \frac{e^{-\mu} (\mu)^x}{x^x};$$

2. 如果 $x < \mu$, 则

$$\Pr(X \leq x) \leq \frac{e^{-\mu} (\mu)^x}{x^x}.$$

证明 对任意的 $t > 0$ 及 $x > \mu$,

$$\Pr(X \geq x) = \Pr(e^{tX} \geq e^{tx}) \leq \frac{E[e^{tX}]}{e^{tx}}.$$

代入泊松分布矩母函数的表达式, 我们有

$$\Pr(X \geq x) \leq e^{\mu(e^t - 1) - tx}.$$

选取 $t = \ln(x/\mu) > 0$, 得到

$$\begin{aligned} \Pr(X \geq x) &\leq e^{x - \mu - x \ln(x/\mu)} \\ &= \frac{e^{-\mu} (\mu)^x}{x^x}. \end{aligned}$$

对任意的 $t < 0$ 及 $x < \mu$,

$$\Pr(X \leq x) = \Pr(e^{tX} \geq e^{tx}) \leq \frac{E[e^{tX}]}{e^{tx}}.$$

因此

$$\Pr(X \leq x) \leq e^{\mu(e^t - 1) - tx}.$$

选取 $t = \ln(x/\mu) < 0$, 可得

$$\begin{aligned} \Pr(X \leq x) &\leq e^{x - \mu - x \ln(x/\mu)} \\ &= \frac{e^{-\mu} (\mu)^x}{x^x}. \end{aligned}$$

5.3.1 二项分布的极限

我们已经证明, 将 m 个球随机地放入 b 个箱子中, 一个箱子有 r 个球的概率 p_r 近似地为均值是 m/b 的泊松分布. 一般地, 当 n 比较大而 p 比较小时, 泊松分布是参数为 n 和 p 的二项分布的极限分布. 更确切地, 我们有下面的极限结果.

定理 5.5 设 X_n 是参数为 n 和 p 的二项随机变量, 其中 p 是 n 的函数, 且 $\lim_{n \rightarrow \infty} np = \lambda$ 是一个与 n 无关的常数. 那么, 对任意固定的 k ,

$$\lim_{n \rightarrow \infty} \Pr(X_n = k) = \frac{e^{-\lambda} \lambda^k}{k!}.$$

将这个定理直接用于球和箱子情景. 考虑有 m 个球和 b 个箱子的情况, 其中 m 是 b 的函数, 并且 $\lim_{b \rightarrow \infty} m/b = \lambda$. 设 X_n 是某个指定箱子内球的个数, 那么 X_n 是参数为 m 和 $1/b$ 的二项随机变量. 应用定理 5.5 表明

$$\lim_{b \rightarrow \infty} \Pr(X_n = r) = \frac{e^{-\lambda} (\lambda/n)^r}{r!},$$

这与式(5.2)的近似是一致的.

在证明定理 5.5 之前, 先介绍它的某些应用. 这种类型的分布是常常出现的, 且通常用泊松分布作为模型. 例如, 考虑一本书(包括本书)内拼写或语法错误的个数. 一个这种错误的模型是每个单词以某个非常小的概率 p 出现一个错误, 所以错误个数是一个有很大 n 和很小 p 的二项随机变量, 因而可以作为泊松随机变量来处理. 另一个例子, 考虑一块巧克力馅小甜饼中巧克力碎片的个数, 一个可能的模型是将小甜饼分成大量互相分开的小块, 每一小片巧克力以某个概率 p 落入小块甜饼中. 用这个模型, 在一块甜饼中的巧克力片数大致服从泊松分布. 我们将在第 8 章看到在连续情况下泊松分布的类似应用.

定理 5.5 的证明 可以记

$$\Pr(X_n = k) = \binom{n}{k} p^k (1-p)^{n-k}.$$

下面, 对 $|x| \leq 1$, 利用

$$e^x (1-x^2) \leq 1+x \leq e^x, \quad (5.3)$$

这由 e^x 的泰勒级数展开可得(留作练习 5.6), 所以

$$\begin{aligned} \Pr(X_n = k) &\leq \frac{n^k p^k (1-p)^n}{k! (1-p)^k} \\ &\leq \frac{(np)^k e^{-np}}{k! (1-pk)} \\ &= \frac{e^{-np} (np)^k}{k! (1-pk)}. \end{aligned}$$

由式(5.3)的前一部分及 $k \geq 0$ 时, $(1-p) \geq 1-pk$ 的事实, 可知第二行成立. 并且

$$\begin{aligned} \Pr(X_n = k) &\geq \frac{(n-k+1)^k p^k (1-p)^n}{k!} \\ &\geq \frac{((n-k+1)p)^k e^{-np} (1-p^2)^n}{k!} \\ &\geq \frac{e^{-np} ((n-k+1)p)^k (1-p^2)^n}{k!}, \end{aligned}$$

在第二个不等式中, 我们用了式(5.3), 其中 $x = -p$.

综上所述, 我们有

$$\frac{e^{-np} (np)^k}{k! (1-pk)} \leq \Pr(X_n = k) \leq \frac{e^{-np} ((n-k+1)p)^k}{k!} (1-p^2)^n.$$

在 n 趋于无穷的极限中, 由于 pn 的极限值是常数 λ , 所以 p 趋于零. 因此 $1/(1-pk)$ 趋于 1,

$1 - p^2 n$ 趋于 1, 且 $(n - k + 1)p$ 与 np 之间的差趋于 0. 因此

$$\lim_{n \rightarrow \infty} \frac{e^{-np} (np)^k}{k!} \frac{1}{1 - pk} = \frac{e^{-\lambda} \lambda^k}{k!}$$

及

$$\lim_{n \rightarrow \infty} \frac{e^{-np} ((n - k + 1)p)^k}{k!} (1 - p^2 n) = \frac{e^{-\lambda} \lambda^k}{k!}.$$

因为 $\lim_{n \rightarrow \infty} \Pr(X_n = k)$ 在这两个值之间, 故定理成立. ■

5.4 泊松近似

分析球和箱子问题的主要困难在于处理这个系统中自然产生的相关性. 例如, 如果将 m 个球放入 n 个箱子里, 且发现箱子 1 是空的, 那么箱子 2 是空的就有较小的可能, 因为我们知道现在 m 个球必须分布在 $n - 1$ 个箱子中. 更具体地: 如果知道前 $n - 1$ 个箱子中球的个数, 那么最后一个箱子中球的个数是完全确定的. 各个箱子的负荷不独立, 而分析独立的随机变量一般要容易得多, 因为我们可以运用切尔诺夫界. 因此防止出现相关性排序的一般方法是有用的.

我们已经证明, 将 m 个球独立地且均匀随机地放入 n 个箱子后, 在某个给定箱子里球的个数的分布近似地为均值是 m/n 的泊松分布. 我们也愿意说, 在假定每个箱子的负荷是独立的均值为 m/n 的泊松随机变量时, 所有箱子里球的个数的联合分布有一个很好的近似. 这就允许将箱子的负荷作为独立的随机变量. 这里证明当我们关心充分稀有事件时可以这样做. 特别地, 我们将在推论 5.9 中证明, 当将 m 个球放入 n 个箱子时, 对所有的箱子用泊松近似作为一个事件的概率, 并与 $e^{\sqrt{m}}$ 相乘给出了事件概率的一个上界. 对稀有事件, 这个额外的因子 $e^{\sqrt{m}}$ 并不重要. 为了得到这个结果, 现在我们介绍某些专门的方法.

假定将 m 个球独立地且均匀随机地放入 n 个箱子中, $X_i^{(n)}$ 是第 i 个箱子内球的个数, $1 \leq i \leq n$. 令 $Y_1^{(n)}, \dots, Y_n^{(n)}$ 是均值为 m/n 的独立泊松随机变量. 我们导出这两个随机变量集合之间一种有用的关系. 在进行了更详细的分析后, 常常能得到特定问题更紧的界, 但这种方法相当一般, 且易于应用.

随机地放入 m 个球与为每个箱子指定一个按均值为 m/n 泊松分布的球数, 二者之间存在不同. 在第一种情况下, 我们知道一共有 m 个球, 但在第二种情况下, 我们只知道 m 是在所有箱子中球的期望个数. 但假定在用泊松分布时以 m 个球结束. 此时的分布实际上与将 m 个球随机地放入 n 个箱子内是相同的.

定理 5.6 无论 m 取什么值, 在条件 $\sum_i Y_i^{(n)} = k$ 下, $(Y_1^{(n)}, \dots, Y_n^{(n)})$ 的分布与 $(X_1^{(k)}, \dots, X_n^{(k)})$ 的分布相同.

证明 将 k 个球放入 n 个箱子, 对任意满足 $\sum_i k_i = k$ 的 k_1, \dots, k_n , $(X_1^{(k)}, \dots, X_n^{(k)}) = (k_1, \dots, k_n)$ 的概率为

$$\frac{\binom{k}{k_1; k_2; \dots; k_s}}{n^k} = \frac{k!}{(k_1!)(k_2!) \cdots (k_s!) n^k}$$

现在, 对任意的 k_1, \dots, k_s , $\sum_i k_i = k$, 在满足 $\sum_i Y_i^{(n)} = k$ 的 $(Y_1^{(n)}, \dots, Y_s^{(n)})$ 条件下, 考虑

$$(Y_1^{(n)}, \dots, Y_s^{(n)}) = (k_1, \dots, k_s)$$

的概率

$$\begin{aligned} & \Pr\left((Y_1^{(n)}, \dots, Y_s^{(n)}) = (k_1, \dots, k_s) \mid \sum_{i=1}^s Y_i^{(n)} = k\right) \\ &= \frac{\Pr((Y_1^{(n)} = k_1) \cap (Y_2^{(n)} = k_2) \cap \dots \cap (Y_s^{(n)} = k_s))}{\Pr\left(\sum_{i=1}^s Y_i^{(n)} = k\right)}. \end{aligned}$$

$Y_i^{(n)} = k_i$ 的概率是 $e^{-m/n} (m/n)^{k_i} / k_i!$, 这是因为 $Y_i^{(n)}$ 是均值为 m/n 的独立泊松随机变量. 由引理 5.2, $Y_i^{(n)}$ 的和本身也是泊松随机变量, 其均值为 m . 因此

$$\begin{aligned} \frac{\Pr((Y_1^{(n)} = k_1) \cap (Y_2^{(n)} = k_2) \cap \dots \cap (Y_s^{(n)} = k_s))}{\Pr\left(\sum_{i=1}^s Y_i^{(n)} = k\right)} &= \frac{\prod_{i=1}^s e^{-m/n} (m/n)^{k_i} / k_i!}{e^{-m} m^k / k!} \\ &= \frac{k!}{(k_1!)(k_2!) \cdots (k_s!) n^k}. \end{aligned}$$

这就证明了定理. ■

由于两个分布之间的这个关系, 我们可以证明关于箱子负荷任一函数的更强结论.

定理 5.7 设 $f(x_1, \dots, x_s)$ 是一非负函数. 那么

$$E[f(X_1^{(n)}, \dots, X_s^{(n)})] \leq e \sqrt{m} E[f(Y_1^{(n)}, \dots, Y_s^{(n)})]. \quad (5.4)$$

证明 我们有

$$\begin{aligned} E[f(Y_1^{(n)}, \dots, Y_s^{(n)})] &= \sum_{k=0}^{\infty} E\left[f(Y_1^{(n)}, \dots, Y_s^{(n)}) \mid \sum_{i=1}^s Y_i^{(n)} = k\right] \Pr\left(\sum_{i=1}^s Y_i^{(n)} = k\right) \\ &\geq E\left[f(Y_1^{(n)}, \dots, Y_s^{(n)}) \mid \sum_{i=1}^s Y_i^{(n)} = m\right] \Pr\left(\sum_{i=1}^s Y_i^{(n)} = m\right) \\ &= E[f(X_1^{(n)}, \dots, X_s^{(n)})] \Pr\left(\sum_{i=1}^s Y_i^{(n)} = m\right), \end{aligned}$$

其中最后一个等号成立是如定理 5.6 所证明的, 在给定 $\sum_{i=1}^s Y_i^{(n)} = m$ 时, $Y_i^{(n)}$ 的联合分布恰好是

$X_i^{(n)}$ 的联合分布. 因为 $\sum_{i=1}^s Y_i^{(n)}$ 是均值为 m 的泊松分布, 现在我们有

$$E[f(Y_1^{(n)}, \dots, Y_s^{(n)})] \geq E[f(X_1^{(n)}, \dots, X_s^{(n)})] \frac{m^m e^{-m}}{m!}.$$

我们利用如引理 5.8 所证明的下列关于 $m!$ 的宽松的上界:

$$m! < e \sqrt{m} \left(\frac{m}{e}\right)^m.$$

[101] 这样就有

$$E[f(Y_1^{(n)}, \dots, Y_s^{(n)})] \geq E[f(X_1^{(n)}, \dots, X_s^{(n)})] \frac{1}{e \sqrt{m}}$$

定理得证. ■

下面证明所用阶乘的上界, 它与引理 5.1 的证明中所用到的宽松下界有非常密切的配合.

引理 5.8

$$n! \leq e \sqrt{n} \left(\frac{n}{e}\right)^n. \quad (5.5)$$

证明 利用

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

的事实. 首先声明对 $i \geq 2$,

$$\int_{i-1}^i \ln x dx \geq \frac{\ln(i-1) + \ln i}{2}.$$

这是由于 $\ln x$ 的二阶导数为 $-1/x^2$, 总是负的, 因此它是凹函数. 所以

$$\int_1^n \ln x dx \geq \sum_{i=1}^n \ln i - \frac{\ln n}{2}$$

或等价地,

$$n \ln n - n + 1 \geq \ln(n!) - \frac{\ln n}{2}.$$

现在两边取指数, 即得所要的结论. ■

定理 5.7 对箱子中球的个数的任意非负函数都成立. 特别地, 如果函数是示性函数(即如果某个事件出现, 函数取为 1; 否则, 取为 0), 那么定理就给出了事件概率的界. 我们称箱子中球的个数是均值为 m/n 的独立泊松随机变量的场合为泊松情况, 而称 m 个球独立地且均匀随机地放入 n 个箱子的场合为精确情况.

推论 5.9 在泊松情况发生概率为 p 的任一事件, 在精确情况的发生概率至多为 $pe \sqrt{m}$.

证明 设 f 是事件的示性函数. 此时, $E[f]$ 恰好是事件发生的概率, 故由定理 5.7 立即可知结果成立. ■

这是一个相当强的结论, 它表明在泊松情况下以小概率发生的事件在精确情况下也以小概率发生, 这里的事件是球放入箱子. 因为在算法分析中, 我们常常希望说明某个事件以小概率发生, 这个结果表明可以用一个对泊松近似的分析来得到精确情况的界. 由于每个箱子中球的个数是独立随机变量, 因此泊松近似容易分析^⑤.

[102]

⑤ 存在其他方法处理球和箱子模型中的相关性. 我们在第 12 章给出适用于这里的更一般的处理相关性的方法(利用鞅). 还存在用于球和箱子问题的负相关性理论, 它也能将相关性处理得很好.

在许多自然情况下，我们实际上可以做得稍微好一点。下面定理的证明留作练习 5.14。

定理 5.10 设 $f(x_1, \dots, x_n)$ 是一非负函数，使得 $E[f(X_1^{(n)}, \dots, X_n^{(n)})]$ 关于 m 单调递增或者单调递减。那么

$$E[f(X_1^{(n)}, \dots, X_n^{(n)})] \leq 2E[f(Y_1^{(n)}, \dots, Y_n^{(n)})]. \quad (5.6)$$

直接可以得到下面的推论。

推论 5.11 设 \mathcal{E} 是这样一个事件，它的概率是球个数的单调递增或者单调递减函数。如果在泊松情况下， \mathcal{E} 有概率 p ，那么在精确情况下， \mathcal{E} 的概率至多为 $2p$ 。

为了说明这个推论的用处，再次考虑 $m=n$ 情况的最大负荷问题。通过并的界已经证明了以大的概率最大负荷至多为 $3 \ln n / \ln \ln n$ 。用泊松近似，我们证明关于最大负荷几乎完全一样的下界。

引理 5.12 当 n 个球独立地且均匀随机地放入 n 个箱子时，对充分大的 n ，最大负荷至少以 $1 - 1/n$ 的概率至少为 $\ln n / \ln \ln n$ 。

证明 在泊松情况下，箱子 1 至少有负荷 $M = \ln n / \ln \ln n$ 的概率至少为 $1/(eM!)$ ，这是恰有负荷 M 的概率。在泊松情况下，所有箱子是独立的，所以，没有箱子负荷至少为 M 的概率至多为

$$\left(1 - \frac{1}{eM!}\right)^n \leq e^{-n/(eM!)}.$$

现在需要选择 M ，使得 $e^{-n/(eM!)} \leq n^{-2}$ ，对此(由定理 5.7)，我们有精确情况下最大负荷不是至少为 M 的概率至多是 $e\sqrt{n}/n^2 < 1/n$ 。这就证明了引理。因为最大负荷显然是关于球个数的单调递增函数，我们还可以利用稍微更好的定理 5.10，但本质上不影响证明。

所以只需证明 $M! \leq n/(2e \ln n)$ ，或等价地， $\ln M! \leq \ln n - \ln \ln n - \ln(2e)$ 。由(6.5)的界，当 n (因此 $M = \ln n / \ln \ln n$)适当大时，得到

$$M! \leq e\sqrt{M}\left(\frac{M}{e}\right)^M \leq M\left(\frac{M}{e}\right)^M.$$

所以对适当大的 n ，

$$\begin{aligned} \ln M! &\leq M \ln M - M + \ln M \\ &= \frac{\ln n}{\ln \ln n} (\ln \ln n - \ln \ln \ln n) - \frac{\ln n}{\ln \ln n} + (\ln \ln n - \ln \ln \ln n) \\ &\leq \ln n - \frac{\ln n}{\ln \ln n} \\ &\leq \ln n - \ln \ln n - \ln(2e), \end{aligned}$$

在最后两个不等式中，我们用到了 $\ln \ln n = o(\ln n / \ln \ln n)$ 。

5.4.1 例：赠券收集问题再讨论

在 2.4.1 节介绍的赠券收集问题可以看作一个球和箱子问题。回忆一下，在这个问题中有 n 种不同类型的赠券，每盒麦片有一张从这 n 种类型中独立地且均匀随机地选取的赠券，你需要购买麦片，直到收集齐每种赠券的一张。如果把赠券当作箱子，麦片盒当作球，问题成为：

如果球是独立地且均匀随机地放入箱子中的,直到所有箱子里都至少有一个球,那么需要多少个球?我们在2.4.1节已经证明,需要的期望麦片盒数为 $nH(n) \approx n \ln n$; 在3.3.1节,我们证明了如果有 $n \ln n + cn$ 盒麦片,那么所有赠券还没有都收集齐的概率至多为 e^{-c} 。可以用这些结果直接去解释球和箱子问题。在每个箱子中至少有一个球之前所需要投入球的期望数为 $nH(n)$ 。当投放了 $n \ln n + cn$ 个球时,所有箱子里还不能都至少有一个球的概率为 e^{-c} 。

我们在第4章中已经看到,切尔诺夫界给出了独立的0-1随机变量之和聚集的结果。这里利用泊松分布的切尔诺夫界得到赠券收集问题的更强的结论。

定理 5.13 设 X 是得到 n 种赠券的每一种之前观测到的赠券数,那么,对任意常数 c ,

$$\lim_{n \rightarrow \infty} \Pr[X > n \ln n + cn] = 1 - e^{-c}.$$

这个定理说明,对大的 n ,所要求的赠券数非常接近于 $n \ln n$ 。例如,超过98%的时间要求的赠券数在 $n \ln n - 4n$ 与 $n \ln n + 4n$ 之间。这是一个苛刻的阈值的例子,其中随机变量紧密地集中在其均值的周围。

证明 将这个问题作为球和箱子问题来考虑。我们从考虑泊松近似开始,然后说明泊松近似给出极限意义上的正确答案。对于泊松近似,假定每个箱子中球的个数是均值为 $\ln n + c$ 的泊松随机变量,所以球的总数的期望是 $m = n \ln n + cn$ 。那么某个指定箱子是空的概率为

$$e^{-(\ln n + c)} = \frac{e^{-c}}{n}.$$

因为在泊松近似中,所有箱子是独立的,所以没有箱子是空的概率为

$$\left(1 - \frac{e^{-c}}{n}\right)^n \approx e^{-e^{-c}}.$$

当 n 变得很大时,在极限意义下,最后一个近似是合适的,所以在这里用它。

为证明泊松近似是精确的,我们着手以下步骤。考虑这样的试验,每个箱子内有泊松个数个球,均值为 $\ln n + c$ 。设 \mathcal{E} 表示没有箱子是空的事件, X 是放入的球数。我们已经知道

$$\lim_{n \rightarrow \infty} \Pr(\mathcal{E}) = e^{-e^{-c}}.$$

将 $\Pr(\mathcal{E})$ 作如下分解:

$$\begin{aligned} \Pr(\mathcal{E}) &= \Pr(\mathcal{E} \cap (|X - m| \leq \sqrt{2m \ln m})) + \Pr(\mathcal{E} \cap (|X - m| > \sqrt{2m \ln m})) \\ &= \Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) \cdot \Pr(|X - m| \leq \sqrt{2m \ln m}) \\ &\quad + \Pr(\mathcal{E} \mid |X - m| > \sqrt{2m \ln m}) \cdot \Pr(|X - m| > \sqrt{2m \ln m}). \end{aligned} \quad (5.7)$$

只要确认两个事实,则这个表达式表明是有用的。首先证明 $\Pr(|X - m| > \sqrt{2m \ln m})$ 是 $o(1)$, 即泊松情况下,放入的球数明显地偏离其均值的概率是 $o(1)$ 。这就保证式(5.7)右边和式中的第二项是 $o(1)$ 。其次,证明

$$|\Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) - \Pr(\mathcal{E} \mid X = m)| = o(1).$$

即在恰有 m 个球的实验与只是几乎有 m 个球的实验之间的差别,使得每个箱子有球的概率之差可以渐近地忽略。由于这两个事实,式(5.7)成为

$$\Pr(\mathcal{E}) = \Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) \cdot \Pr(|X - m| \leq \sqrt{2m \ln m})$$

$$\begin{aligned}
 & + \Pr(\mathcal{E} \mid |X - m| > \sqrt{2m \ln m}) \cdot \Pr(|X - m| > \sqrt{2m \ln m}) \\
 = & \Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) \cdot (1 - o(1)) + o(1) \\
 = & \Pr(\mathcal{E} \mid X = m)(1 - o(1)) + o(1),
 \end{aligned}$$

因此

$$\lim_{n \rightarrow \infty} \Pr(\mathcal{E}) = \lim_{n \rightarrow \infty} \Pr(\mathcal{E} \mid X = m).$$

但由定理 5.6, 右边的量等于随机放入 m 个球时每个箱子里至少有一个球的概率, 这是因为在泊松近似中, 总数为 m 个球的条件等价于将 m 个球随机地放入 n 个箱子中. 所以只要证明了这两个事实, 定理就成立.

为了证明 $\Pr(|X - m| > \sqrt{2m \ln m})$ 是 $o(1)$, 考虑 X 是均值为 m 的泊松随机变量, 这是因为它是独立泊松随机变量之和. 我们利用泊松分布的切尔诺夫界(定理 5.4)来界定这个概率, 将这个界记为

$$\Pr(X \geq x) \leq e^{x - m - x \ln(x/m)}.$$

对 $x = m + \sqrt{2m \ln m}$, 利用当 $z \geq 0$ 时, $\ln(1+z) \geq z - z^2/2$ 来证明

$$\begin{aligned}
 \Pr(X > m + \sqrt{2m \ln m}) & \leq e^{\sqrt{2m \ln m} - (m + \sqrt{2m \ln m}) \ln(1 + \sqrt{2 \ln m}/m)} \\
 & \leq e^{\sqrt{2m \ln m} - (m + \sqrt{2m \ln m})(\sqrt{2 \ln m}/m - \ln m/m)} \\
 & = e^{-\ln m + \sqrt{2m \ln m}(\ln m/m)} = o(1).
 \end{aligned}$$

如果 $x < m$, 也有类似的证明. 所以 $\Pr(|X - m| > \sqrt{2m \ln m}) = o(1)$.

现在证明第二个事实, 即

$$|\Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) - \Pr(\mathcal{E} \mid X = m)| = o(1).$$

注意 $\Pr(\mathcal{E} \mid X = k)$ 关于 k 是递增的, 因为这个概率相应于 k 个球独立地且均匀随机地放入时所有箱子不空的概率. 放入的球越多, 所有箱子越可能不空. 由此

$$\begin{aligned}
 \Pr(\mathcal{E} \mid X = m - \sqrt{2m \ln m}) & \leq \Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) \\
 & \leq \Pr(\mathcal{E} \mid X = m + \sqrt{2m \ln m}).
 \end{aligned}$$

因此我们得到界

$$\begin{aligned}
 |\Pr(\mathcal{E} \mid |X - m| \leq \sqrt{2m \ln m}) - \Pr(\mathcal{E} \mid X = m)| \\
 \leq \Pr(\mathcal{E} \mid X = m + \sqrt{2m \ln m}) - \Pr(\mathcal{E} \mid X = m - \sqrt{2m \ln m}),
 \end{aligned}$$

也即证明了右边为 $o(1)$. 在放入 $m - \sqrt{2m \ln m}$ 个球与放入 $m + \sqrt{2m \ln m}$ 个球时, 所有箱子都至少有一个球的概率之间是不同的. 这个差别等价于下面实验的概率: 我们放入 $m - \sqrt{2m \ln m}$ 个球时, 仍至少有一个空箱子, 但再放入另外 $2\sqrt{2m \ln m}$ 个球后, 所有箱子都非空了. 为了使这个事件发生, 在放入 $m - \sqrt{2m \ln m}$ 个球以后, 必须至少有一个空箱子; 在后面的 $2\sqrt{2m \ln m}$ 个球中, 由并的界, 有一个球放入这个箱子的概率至多为 $(2\sqrt{2m \ln m})/n = o(1)$. 因此这个差别也是 $o(1)$. ■

5.5 应用：散列法

5.5.1 链散列

球和箱子模型对散列法建模也是有用的。例如，考虑口令检验程序的应用，它通过保存一个不能接受的口令字典来阻止人们使用那些常用的、容易破译的口令。当用户试图建立一个口令时，程序将会核查请求的口令是否为不能接受集合的部分。口令检验程序的一个可能的途径是依字母顺序存储不能接受的口令，并对字典进行二元搜索，以检查推荐的口令是否是能接受的。对 m 个单词，二元搜索要求 $\Theta(\log m)$ 时间。

另一种可能是将单词放入接收器中，然后搜索被单词占用的接收器。在一个接收器里，单词用一个链表来表示。用散列函数完成单词在接收器中的放置。从全域 U 到值域 $[0, n-1]$ 的散列函数 f 可以看成将全域中的项目放入 n 个接收器里的一种方法。这里全域 U 由可能的口令串组成，接收器集合称为散列表。因为放入同一接收器里的项目是用一个链表连接在一起的，所以这种散列方法称为链散列。

利用散列表将字典问题转换成球和箱子问题。如果不能接受的口令字典由 m 个单词组成，散列表的值域为 $[0, n-1]$ ，那么可以用与 m 个球随机地放置于 n 个箱子同样的分布作为接收器中单词分布的模型。还要作一个更强的假定：用散列函数将单词以随机形式映射到接收器中，使得每个单词的位置是独立同分布的。在设计体现随机性的散列函数背后有大量的理论，我们不在这里探究这些理论。散列函数是随机函数的假定简化了问题的模型，换言之，假定：(a) 对每个 $x \in U$ ， $f(x) = j$ 的概率为 $1/n$ (对 $0 \leq j \leq n-1$)；(b) 对每个 x ， $f(x)$ 的值是相互独立的。注意，这并不意味着 $f(x)$ 的每次求值给出不同的随机答案。 $f(i)$ 的值始终是固定的，它只是以同样的可能性取值域中的任一值。

考虑有 n 个接收器和 m 个单词时的搜索时间。为了搜索一个项目，我们首先将它散列以找到它所在的接收器，然后通过链表顺序地寻找。如果搜索一个不在字典中的单词，那么在这个词散列到的接收器中，词的期望个数为 m/n 。如果搜索的词在字典中，那么在这个词的接收器中，其他词的期望个数为 $(m-1)/n$ ，所以接收器中词的期望个数为 $1 + (m-1)/n$ 。如果是散列表选取 $n = m$ 个接收器，那么我们在一个接收器中必须搜索的词的期望个数是一个常数。如果散列需要常数时间，那么搜索的总期望时间是常数。

但是搜索一个词的最大时间与接收器中词的最大个数成比例。我们已经证明 $n = m$ 时，这个最大负荷以接近于 1 的概率为 $\Theta(\ln n / \ln \ln n)$ ，因此以大的概率，这就是在这样一个散列表中的最大搜索时间。虽然这比标准二元搜索所要求的时间少，但比平均时间慢了许多，这可能成为许多应用的障碍。

链散列的另一个缺点是浪费空间。如果对 n 个项目用 n 个接收器，某些接收器将会是空的，潜在地导致浪费空间。浪费的空间可以抵消使每个接收器平均单词个数大于 1 的搜索时间。

5.5.2 散列：二进制数字串

如果想节省空间而不是节省时间，可以通过另外一种方法运用散列。仍考虑保存不合适的口令的字典问题。假定口令限制为八个 ASCII 字符，它要求 64 个二进制数字 (8 个字节) 来表

示. 假设用散列函数将每个单词映射为一个 32 个二进制数字的串. 这个串将作为单词的简短指纹, 就像指纹是识别人的简洁方法一样, 指纹串是识别单词的简洁方法. 我们将指纹保存在一个排序表中. 为了检查提议的口令是否为不能接受的, 我们计算它的指纹, 并在此排序表上寻找它. 譬如用二元搜索^①, 如果指纹在排序表上, 则判定该口令为不能接受的.

这种情况下, 我们的口令检验程序可能没有给出正确答案! 下面的情况是可能发生的: 对输入了一个可接受口令的用户, 因为他的指纹与不可接受口令的指纹匹配, 只能被拒绝. 因此存在某种散列产生假阳性的机会: 将并不是真实的匹配错误地宣称是匹配. 问题在于——与人类具有的指纹不一样——我们的指纹并不唯一地识别关联的词. 这只是此类算法可能犯的一种错误类型, 不允许在不能接受口令的字典中的口令. 在口令应用中, 允许假阳性意味着我们的算法过于保守, 这也许是可以接受的. 但设置容易被破译的口令也许是不能接受的.

将问题放在更一般的范围中, 我们将它描述为一个近似的集合元素资格问题. 假定有一个来自大的全域 U 的 m 个元素的集合 $S = \{s_1, s_2, \dots, s_m\}$, 我们愿意将元素用这样一种方法表示, 使得能很快回答“ x 是 S 的元素吗?”形式的问题, 也愿意使用占用尽可能小的空间的表示法. 为了节省空间, 我们愿意允许假阳性形式的偶然错误. 这里不允许的口令对应于集合 S .

用于生成指纹的散列函数的值域应多大? 特别地, 如果使用二进制数字, 为了生成一个指纹需要多少个二进制数字? 显然, 我们希望选取的二进制数字个数对假阳性匹配能够给出一个可接受的概率. 一个可接受的口令与 S 中任一特定的不可容许口令具有不同指纹的概率是 $(1 - 1/2^b)$. 由此, 如果集合 S 的大小为 m , 且如果用 b 个二进制数字表示指纹, 那么对一个可接受的口令, 假阳性概率是 $1 - (1 - 1/2^b)^m \approx 1 - e^{-m/2^b}$. 如果希望这个假阳性的概率小于常数 c , 即要求

$$e^{-m/2^b} \geq 1 - c,$$

上式蕴涵

$$b \geq \log_2 \frac{m}{\ln(1/(1-c))}.$$

即我们需要 $b = \Omega(\log_2 m)$ 个二进制数字. 另一方面, 如果用 $b = 2 \log_2 m$ 个二进制数字, 那么假阳性的概率下降到

$$1 - \left(1 - \frac{1}{m^2}\right)^m < \frac{1}{m}.$$

在我们的例子中, 如果字典有 $2^{16} = 65\,536$ 个词, 则当散列给出恰好小于 $1/65\,536$ 的假阳性概率时, 会用 32 个二进制数字.

5.5.3 Bloom 过滤器

我们可以推广 5.5.1 节及 5.5.2 节的散列思想, 以取得所需空间与假阳性概率之间更有意义的权衡. 称得到的近似集合成员问题的数据结构为一个 Bloom 过滤器.

① 此时指纹均匀分布在所有 32 个二进制数字的串上. 对这个分布的随机数集合, 存在较快的搜索算法. 如在待排序的元素来自均匀分布时, 桶排序法比标准的比较排序法更快, 但此处我们不关心这一点.

Bloom 过滤器由一个 n 个二进制数字的数组组成, 从 $A[0]$ 到 $A[n-1]$, 开始时全都设置为 0. 一个 Bloom 过滤器利用 k 个值为 $\{0, \dots, n-1\}$ 的独立的随机散列函数 h_1, \dots, h_k . 便于分析, 我们作通常的假定: 这些散列函数将全域中的每个元素都映射为值域 $\{0, \dots, n-1\}$ 上的均匀随机数. 假定用一个 Bloom 过滤器来表示一个来自大全域 U 的 m 个元素的集合 $S = \{s_1, s_2, \dots, s_m\}$. 对每个元素 $s \in S$, 二进制数字 $A[h_i(s)]$ 设置为 1, 其中 $1 \leq i \leq k$. 一个二进制数字的位置可以多次设置为 1, 但只有第一次改变有作用. 为了检查一个元素 x 是否在 S 中, 我们检查所有数组位置 $A[h_i(x)]$ ($1 \leq i \leq k$) 是否设置为 1. 如果不是, 那么 x 显然不是 S 的成员, 因为如果 x 在 S 中, 那么由构造法, 所有位置 $A[h_i(x)]$ ($1 \leq i \leq k$) 都应设置为 1. 如果所有 $A[h_i(x)]$ 都设置为 1, 我们就假定 x 在 S 中, 虽然这可能是错误的. 如果 x 不在 S 中, 但所有位置 $A[h_i(x)]$ 都被 S 的元素设置为 1, 就会出错. 因此 Bloom 过滤器可能产生假阳性. 图 5.1 展示了一个例子.

109

一个不在集合中的元素的假阳性概率, 在散列函数是随机的假定下, 可以直接计算. 在 S 中所有元素都散列为 Bloom 过滤器后, 某一个二进制数字仍然是 0 的概率为

$$\left(1 - \frac{1}{n}\right)^{km} \approx e^{-km/n}.$$

记 $p = e^{-km/n}$. 为简化分析, 我们暂且假定将 S 的所有元素都散列为 Bloom 过滤器后, 二进制数字仍然是 0 的比例是 p , 那么假阳性概率为

$$\left(1 - \left(1 - \frac{1}{n}\right)^{km}\right)^k \approx (1 - e^{-km/n})^k = (1 - p)^k.$$

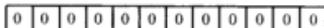
记 $f = (1 - e^{-km/n})^k = (1 - p)^k$. 从现在起, 为方便起见, 我们用渐近近似的 p 和 f (分别) 表示在 Bloom 过滤器中二进制数字是 0 的概率和假阳性的概率.

假定已知 m 和 n , 希望优化散列函数的个数 k , 从而极小化假阳性概率 f . 存在两种对抗的力量: 利用较多的散列函数可以给我们较多的机会, 对一个不是 S 成员的元素找到二进制数字 0; 但利用较少的散列函数能增加数组中二进制数字 0 的比例. 最优的散列函数个数是作为 k 的函数, 极小化 f . 这用求导数的方法容易得到. 记 $g = k \ln(1 - e^{-km/n})$, 从而 $f = e^g$, 而极小化假阳性概率 f 等价于关于 k 极小化 g . 我们得到

$$\frac{dg}{dk} = \ln(1 - e^{-km/n}) + \frac{km}{n} \frac{e^{-km/n}}{1 - e^{-km/n}}.$$

容易验证, 当 $k = (\ln 2) \cdot (n/m)$ 时, 导数为零, 且这是全局最小点. 此时假阳性概率 f 为 $(1/2)^k \approx (0.6185)^{n/m}$. 假阳性概率的指数为 n/m , 即每个项目所用的二进制数字的个数. 当然, 实际上 k 必须是整数, 所以 k 的最好可能选择会导致一个稍高的假阳性比例.

从一个 0 的数组开始



将 S 的每个元素散列 k 次, 每次散列给出设置为 1 的数组位置



检查 y 是否在 S 中, 检查 k 个散列位置. 如果出现 0, 则 y 不在 S 中



如果只出现 1, 则断定 y 在 S 中, 这可能产生假阳性



图 5.1 如何构造 Bloom 过滤器函数的例子

Bloom 过滤器类似于一个散列表, 但其中没有存储集中的项目, 而是简单地用一个二进制数字来记录一个项目是否散列到那个位置. 如果 $k=1$, 则恰有一个散列函数, 而 Bloom 过滤器等价于基于散列的指纹系统, 其中指纹表存储在一个 0-1 二进制数字数组中, 所以可把 Bloom 过滤器看成基于散列的指纹这一思想的推广. 正如我们已经看到的, 在用指纹时, 为了得到假阳性的小的不变概率, 每个项目要求 $\Omega(\log m)$ 个指纹二进制数字. 在许多实际应用中, 每个项目要求 $\Omega(\log m)$ 个二进制数字可能太多了. 在保持 n/m , 即每个项目要求的存储二进制数字个数为常数时, Bloom 过滤器允许不变的假阳性概率. 对许多应用, 小空间的要求使可接受的错误具有不变的概率. 例如, 在口令应用中, 我们可能愿意接受 1% 或 2% 的假阳性比例. [110]

即使对小的常数(比如 $c=8$) 有 $n=cm$, Bloom 过滤器也是高效的. 在这种情况下, 当 $k=5$ 或 $k=6$ 时, 假阳性概率只比 0.02 多一点. 将与每个元素散列到 $\Theta(\log m)$ 个二进制数字的方法相比, Bloom 过滤器明显地要求较少的二进制数字而仍能达到非常好的假阳性概率.

构造另一种最优化方法也是有意义的. 考虑假阳性概率 f 作为 p 的函数. 我们得到

$$\begin{aligned} f &= (1-p)^k \\ &= (1-p)^{\lfloor -\ln p \rfloor (n/c)} \\ &= (e^{-\ln(p) \lfloor -\ln p \rfloor})^{n/c}. \end{aligned} \quad (5.8)$$

由这个表达式的对称性, 容易验证 $p=1/2$ 极小化假阳性概率 f . 因此当 Bloom 过滤器的每个二进制数字以 $1/2$ 概率为 0 时, 达到最优结果. 一个优化的 Bloom 过滤器看起来有点像一个随机的二进制数字串.

最后, 再次考虑我们的假定, 即 S 的所有元素都散列为 Bloom 过滤器后, 仍然为 0 的二进制数字的比例是 p . 将数组中的每一个二进制数字当作一个箱子, 散列一个项目好像放入一个球. 所以 S 中所有元素都散列后, 仍然为 0 的元素的个数的比例等价于将 mk 个球投到 n 个箱子后空箱子的比例. 令 X 表示放入 mk 个球时空箱子的个数, 这种箱子的期望比例为

$$p' = \left(1 - \frac{1}{n}\right)^{km}.$$

不同箱子为空的事件并不独立, 但可以由推论 5.9 以及式(4.6)的切尔诺夫界得到

$$\Pr(|X - np'| \geq \epsilon n) \leq 2e^{-\sqrt{\epsilon} n^{3/4}}.$$

事实上, 也可用推论 5.11, 因为 0 元素的个数——相应于空箱子的个数——关于投入的球数是单调递减的. 这个界告诉我们空箱子的比例接近于 p' (当 n 适当大时), 而 p' 非常接近于 p . 所以对于实际性能的预测, 在 Bloom 过滤器中 0 元素的比例为 p 的假定已经是相当精确了.

5.5.4 放弃对称性

作为散列的最后应用, 我们考虑散列如何给出放弃对称性的简单方法. 假定有 n 个用户希望共用一种资源, 比如超级计算机的时间, 他们必须依次使用资源, 每次一人. 当然, 每个用户都希望尽可能安排得早一点. 我们如何能很快地、公平地确定一个用户的排列?

如果每个用户都有一个识别名或识别码, 散列就能提供一种可能解. 将每个用户的标识符散列为 2^k 个二进制数字, 然后利用所得数字的排序顺序给出一种排列, 也就是散列后的标识 [111]

符给出最小的数的那个用户先用,等等.用这种方法,我们不希望两个用户被散列为相同的值,因为那样的话必须再次决定如何对这些用户排序.

如果 b 充分大,那么以大的概率,用户将得到全不相同的散列值.利用 5.1 节关于生日悖论的分析,可以分析两个散列值冲突的概率;散列值对应于生日.这里我们用类似于 5.5.2 节分析指纹所用到的简单方法.考虑一个用户的观点.某个其他用户得到相同散列值的概率为

$$1 - \left(1 - \frac{1}{2^b}\right)^{n-1} \leq \frac{n-1}{2^b}.$$

由并的界,任一用户有与其他用户相同散列值的概率至多为 $n(n-1)/2^b$. 所以,选取 $b = 3 \log_2 n$ 可以至少以 $1 - 1/n$ 的概率保证成功.

这个解是极具适应性的,它对分布式计算的许多场合都有用.例如,新用户可以方便地在任何时刻加入到这个时间表中,只要他们不散列为与时间表中其他用户相同的数字.

一个相关的问题是领导者选举.不是试图对所有用户进行排序,而是假定简单地希望从公正地选举一个领导者.同样地,如果有一个合适的随机散列函数,那么可以简单地取散列值最小的用户.对这个方案的分析留作练习 5.25.

5.6 随机图

5.6.1 随机图模型

有许多定义在图上的 NP 计算难题:哈密顿圈,独立集合,顶点覆盖,等等.一个值得提出的问题是,这些问题对所有图中的大多数输入是困难的,还是只对相对小的一部分是困难的.随机图模型对这些问题的研究提供了一种概率环境.

随机图的大部分工作集中在两个紧密相关的模型 $G_{n,p}$ 和 $G_{n,N}$ 中.在 $G_{n,p}$ 中,考虑 n 个不同顶点 v_1, v_2, \dots, v_n 上的所有无向图.一个图具有已知的 m 条边集合的概率为

$$p^m (1-p)^{\binom{n}{2}-m}.$$

在 $G_{n,p}$ 中生成一个随机图的一种方法是按某个次序考虑 $\binom{n}{2}$ 条可能边中的每一条,然后以概率 p 独立地往图上添加每条边,所以图中边的期望数为 $\binom{n}{2}p$,且每个顶点有期望次数 $(n-1)p$.

在 $G_{n,N}$ 模型中,我们考虑恰有 N 条边的 n 个顶点上的所有无向图.有 $\binom{n}{2}$ 个可能的图,

每个图以相等的概率选取.生成一个均匀地来自 $G_{n,N}$ 中的图的一种方法是从没有边的图开始.

[12]

均匀随机地选取 $\binom{n}{2}$ 条可能边中的一条,并将它添加为图中的边.现在独立地且均匀随机地选取剩余的 $\binom{n}{2} - 1$ 条可能边中的一条,并将它添加到图中.类似地,继续在剩下的未被选取的边中独立地且均匀随机地取一条边,直到有 N 条边为止.

$G_{n,p}$ 模型和 $G_{n,n}$ 模型是有关系的；当 $p = N / \binom{n}{2}$ 时， $G_{n,p}$ 中一个随机图的边数集中在 N 附近，且在来自 $G_{n,p}$ 中的一个图有 N 条边的条件下，那个图关于所有来自 $G_{n,n}$ 的图是均匀的。这个关系类似于将 m 个球投入 n 个箱子中与使每个箱子内球的个数是均值为 m/n 的泊松分布之间的关系。

确实，在随机图与球和箱子模型之间存在许多类似之处。在 $G_{n,n}$ 模型中，将边放到图中就好像将球放入箱子里，但是因为每条边有两个端点，每条边就好像将两个球同时放入两个不同的箱子里。由边定义的配对添加了一个丰富的结构，这是在球和箱子模型中不存在的。我们也常常利用两个模型之间的关系来简化随机图模型的分析。例如，在赠券收集问题中，我们发现，当放入了 $n \ln n + cn$ 个球时，随 n 增加到无穷，存在空箱子的概率收敛于 e^{-c} 。类似地，对随机图，我们有以下定理，其证明留作练习 5.19。

定理 5.14 设 $N = \frac{1}{2}(n \ln n + cn)$ ，那么在 $G_{n,n}$ 中存在任一孤立点(次数为 0 的顶点)的概率随 n 趋于无穷而收敛到 e^{-c} 。

5.6.2 应用：随机图中的哈密顿圈

在图中，一条哈密顿路是通过每个顶点且恰好一次的路，一个哈密顿圈是通过每个顶点恰好一次的圈。通过分析在随机图中寻找哈密顿圈的简单而有效的算法，我们说明随机图与球和箱子问题之间的有意义的联系。算法是随机化的，且它的概率分析涉及输入分布及算法的随机选择。在图上找一个哈密顿圈是 NP 难题。但对这种算法的分析说明，对适当随机选择的图，找哈密顿圈并不困难，虽然一般情况下求解可能是困难的。

我们的算法将利用一种称为旋转的简单运算。设 G 是一无向图。假定

$$P = v_1, v_2, \dots, v_k$$

是 G 中的一个简单路， (v_k, v_1) 是 G 的一条边，那么

$$P' = v_1, v_2, \dots, v_k, v_1, v_{k-1}, \dots, v_2, v_1$$

也是简单路，称为旋转边为 (v_k, v_1) 的 P 的旋转；如图 5.2 所示。

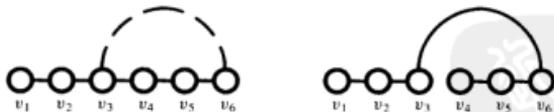


图 5.2 旋转边为 (v_k, v_1) 的路 $v_1, v_2, v_3, v_4, v_5, v_6$ 的旋转产生一个新的路 $v_1, v_2, v_3, v_6, v_5, v_4, v_1$

我们首先考虑一个简单、自然的算法以提供分析的需要。假定将输入表示为图中每个顶点的邻接边的列表，每个列表的边按独立且均匀随机排列的随机次序给出。最初，算法选取任一顶点作为路的开始，是路的初始始点，始点始终是路的一个端点，从这点开始算法或者确定性地从这个始点“长”出一条路；或者旋转路——只要在始点的列表中还有剩余邻接边。见算法 5.1。

分析这个算法的困难在于只要算法查验了边列表中的某些边，剩余边的分布便是在算法已

经看到的那些边的条件下的分布。考虑一个修正的算法以克服这个困难，虽然效率较低，但避免了这个条件问题，所以容易分析所考虑的随机图。见算法 5.2。每个顶点 v 保持两个列表：用过边(v)列表由算法过程中 v 为始点时用到的 v 的邻接边组成，这个列表的初始值为空表；未用过边(v)列表由其他未被使用过的 v 的邻接边组成。

算法 5.1 哈密顿圈算法

输入：有 n 个顶点的图 $G=(V, E)$ 。

输出：哈密顿圈，或失败。

1. 从一个随机顶点出发作为路的始点。
2. 重复以下步骤，直到旋转边封闭成一个哈密顿圈，或者路的始点的未用过边列表为空：
 - (a) 设当前路为 $P=v_1, v_2, \dots, v_k$ ，其中 v_k 是始点，并设 (v_k, u) 是始点列表中第一条边。
 - (b) 从始点的列表及 u 的列表中消去 (v_k, u) 。
 - (c) 如果 $u \neq v_1$ ， $1 \leq i \leq k$ ，在路的终点添加 $u=v_{k+1}$ ，并使它成为始点。
 - (d) 否则，如果 $u=v_1$ ，用 (v_k, v_1) 旋转当前路，且令 v_{k+1} 为始点。（如果 $k=n$ ，这一步封闭为哈密顿路，且选择边为 (v_n, v_1) 。）
3. 如果找到圈，返回哈密顿圈；如果没有找到圈，失败。

算法 5.2 修正的哈密顿圈算法

输入：有 n 个顶点及关联边列表的图 $G=(V, E)$ 。

输出：哈密顿圈，或失败。

1. 从一个随机顶点出发作为路的始点。
2. 重复以下步骤，直到旋转边封闭成一个哈密顿圈，或者路的始点的未用过边的列表为空：
 - (a) 设当前路为 $P=v_1, v_2, \dots, v_k$ ，且 v_k 是始点。
 - (b) 分别以概率 $1/n$ ， $|用过边(v_k)|/n$ ， $1-1/n-|用过边(v_k)|/n$ 执行 i, ii 或 iii：
 - i. 将路反向，使 v_1 成为始点。
 - ii. 从用过边 (v_k) 中均匀随机地选一条边；如果边是 (v_k, v_i) ，用 (v_k, v_i) 旋转当前路，并令 v_{k+1} 为始点。（如果边是 (v_k, v_{k-1}) ，则不作改变。）
 - iii. 从未用过边 (v_k) 中选第一条边，称它为 (v_k, u) 。如果 $u \neq v_1$ ， $1 \leq i \leq k$ ，在路的终点添加 $u=v_{k+1}$ ，并使它成为始点。否则，如果 $u=v_1$ ，用 (v_k, v_1) 旋转当前路，令 v_{k+1} 为始点。（如果 $k=n$ ，该步封闭为哈密顿路，且选取边为 (v_n, v_1) 。）
 - (c) 适当地更新用过边及未用过边列表。
3. 如果找到了圈，返回哈密顿圈；如果没有找到圈，失败。

我们在初始未用过边列表的特殊模型假定下，开始分析算法。然后，将这个模型与随机图的 $G_{n,p}$ 模型联系起来。假定与顶点 v 连接的 $n-1$ 条可能边中的每一条初始时都以某个概率 q 独立地在顶点 v 的未用过边列表上，还假定这些边是依随机次序的。思考这个问题的一种方法

是, 在算法开始之前, 通过以概率 q 插入每条可能边 (v, u) 的方法为每个顶点 v 创建一个未用过边列表. 将相应的图 G 当作包括了所有被插入到某个未用过边列表中的边的图. 注意, 这意味着一条边 (v, u) 开始时可以在 v 的未用过边列表中, 而不是在 u 的未用过边列表中. 还要注意, 当边 (v, u) 被算法第一次使用时, 如果 v 是始点, 那么它只从 v 的未用过边列表中消去; 如果边在 u 的未用过边列表上, 则它保留在此列表上.

以适当的概率从用过边列表或未用过边列表中选取旋转边, 然后每一步以某个小概率将路反向, 从而修正旋转过程, 使得列表的下一个始点是从图的所有顶点中均匀随机地选取的. 只要具备这个性质, 就可以直接应用赠券收集问题的分析方法来分析算法的进展.

修正算法似乎有些浪费, 将路反向或以一条用过边来旋转不可能增加路的长度. 另外, 我们也没有在每一步利用 G 的所有可能边. 由于下面的引理, 容易分析修正算法的优点.

引理 5.15 假定在用上述模型选取的图上运行修正的哈密顿图算法, 设 V_t 是 t 步后的起始顶点, 那么对任一点 u , 只要 t 步时在起始顶点至少存在一条未用过边可供使用, 便有

$$\Pr(V_{t+1} = u \mid V_t = u_t, V_{t-1} = u_{t-1}, \dots, V_0 = u_0) = \frac{1}{n}.$$

即不考虑过程的历史, 每一步的起始顶点都可认为是从所有顶点中均匀随机选取的.

证明 考虑路为 $P = v_1, v_2, \dots, v_k$ 时的可能情况.

使 v_1 成为始点的唯一方法是将路反向, 故以概率 $1/n$ 有 $V_{t+1} = v_1$.

如果 $u = v_{i+1}$ 是位于路上的顶点, 且 (v_i, v_{i+1}) 是用过边 (v_i) , 那么 $V_{t+1} = u$ 的概率为

$$\frac{|\text{用过边}(v_i)|}{n} \cdot \frac{1}{|\text{用过边}(v_i)|} = \frac{1}{n}.$$

如果 u 没有包含在前两种情况之一中, 那么利用以下的事实: 当从未用过边 (v_k) 中选取一条边时, 邻接的顶点在所有 $n - |\text{用过边}(v_k)| - 1$ 个剩余顶点上是均匀的. 由延迟决策原理, 这是成立的. 我们的初始设置要求 v_k 的未用过边列表的构造应该以概率 q 包括每条可能边, 且随机化列表的次序. 这等价于选取 X 个 v_k 的邻点, 其中 X 是一个 $B(n-1, q)$ 随机变量, X 个顶点是均匀随机无放回选取的. 因为 v_k 的列表的确定与其他顶点的列表无关, 所以算法的历史并不能告诉我们任何有关未用过边 (v_k) 列表中剩余边的情况, 并且延迟决策原理适用. 因此在没有看到的 v_k 的未用过边列表中的任一边, 都是等可能地连接到 $n - |\text{用过边}(v_k)| - 1$ 个剩余可能邻接顶点中的任一点.

如果 $u = v_{i+1}$ 是路上的顶点, 但 (v_i, v_{i+1}) 不在用过边 (v_k) 中, 那么 $V_{t+1} = u$ 的概率就是从未用过边 (v_k) 中选取边 (v_i, v_{i+1}) 作为下一旋转边的概率, 为

$$\left(1 - \frac{1}{n} - \frac{|\text{用过边}(v_k)|}{n}\right) \left(\frac{1}{n - |\text{用过边}(v_k)| - 1}\right) = \frac{1}{n}. \quad (5.9)$$

最后, 如果 u 不在路上, 那么 $V_{t+1} = u$ 的概率就是从未用过边 (v_k) 中选取边 (v_{k+1}, u) 的概率, 但这与式 (5.9) 给出的概率相同. ■

对算法 5.2, 求哈密顿图问题似乎与赠券收集问题极为相似: 当还剩余 k 个顶点要被添加时, 寻找一个新的顶点添加到路的概率为 k/n . 只要所有顶点都在路上, 在每次旋转时封闭成为一个圈的概率便是 $1/n$. 因此, 如果未用过边的列表不会耗尽, 那么可以期望经大约

$O(n \ln n)$ 次旋转形成哈密顿路, 用大约另外 $O(n \ln n)$ 次旋转封闭路, 并形成哈密顿圈. 更具体地, 我们可以证明以下定理.

定理 5.16 假定修正的哈密顿圈算法的初始输入有未用过边列表, 其中每条边 (v, u) ($u \neq v$) 以 $q \geq 20 \ln n/n$ 的概率独立地放置在 v 的列表中, 那么算法能以 $1 - O(n^{-1})$ 的概率经 $O(n \ln n)$ 次重复图(第2步)的迭代, 成功地找到哈密顿圈.

注意我们并没有假定输入的随机图有哈密顿圈. 定理的一个推论是用这种方法选取的随机图以大的概率有哈密顿圈.

定理 5.16 的证明 考虑下列两个事件:

\mathcal{E}_1 : 算法运行了 $3n \ln n$ 步, 没有未用过边列表成为空表, 但不能构成哈密顿圈.

\mathcal{E}_2 : 在前 $3n \ln n$ 圈的迭代期间, 至少有一个未用过边列表成为空表.

对于算法失败, 事件 \mathcal{E}_1 或 \mathcal{E}_2 必须发生. 我们首先界定 \mathcal{E}_1 的概率. 引理 5.15 表明, 只要在算法 5.2 第 2 步的前 $3n \ln n$ 次迭代中没有出现空的未用过边列表, 则在每次迭代中, 路的一个始点关于图的 n 个顶点是均匀的. 为了界定 \mathcal{E}_1 , 考虑每次迭代中始点是均匀随机地选取时, 为找到哈密顿圈需要多于 $3n \ln n$ 次迭代的概率.

为找到哈密顿路, 算法需要多于 $2n \ln n$ 次迭代的概率, 恰好是 n 种类型的赠券收集问题要求多于 $2n \ln n$ 张赠券的概率. 在 $2n \ln n$ 张随机赠券中, 找不到任一特定类型赠券的概率为

$$\left(1 - \frac{1}{n}\right)^{2n \ln n} \leq e^{-2 \ln n} = \frac{1}{n^2}.$$

由并的界, 找不到任一类型赠券的概率至多为 $1/n$.

为了使哈密顿路成为圈, 路必须是封闭的, 每一步都有 $1/n$ 的概率使其成为圈. 因此在接着的 $n \ln n$ 次迭代中, 路不能成为圈的概率是

$$\left(1 - \frac{1}{n}\right)^{n \ln n} \leq e^{-\ln n} = \frac{1}{n}.$$

这就证明了

$$\Pr(\mathcal{E}_1) \leq \frac{2}{n}.$$

下面界定 $\Pr(\mathcal{E}_2)$, 即讨论在前 $3n \ln n$ 次迭代中, 一个未用过边列表成为空表的概率的界. 考虑如下两个子事件.

\mathcal{E}_{2a} : 在前 $3n \ln n$ 次圈的迭代中, 至少有 $9 \ln n$ 条边从至少一个顶点的未用过边列表中消去.

\mathcal{E}_{2b} : 至少有一个顶点在它的未用过边列表中少于 $10 \ln n$ 条边.

为使 \mathcal{E}_2 发生, \mathcal{E}_{2a} 或 \mathcal{E}_{2b} 必须发生. 因此

$$\Pr(\mathcal{E}_2) \leq \Pr(\mathcal{E}_{2a}) + \Pr(\mathcal{E}_{2b}).$$

首先考虑 $\Pr(\mathcal{E}_{2a})$ 的界. 在圈的每一次迭代中, 恰好用一条边. 由引理 5.15 的证明可知, 在每一次迭代中, 一个给定顶点 v 是路的始点的概率为 $1/n$, 且每一步是独立的. 因此在前 $3n \ln n$ 步, v 是始点的次数 X 为二项随机变量 $B(3n \ln n, 1/n)$, 这控制了取自 v 的未用过边列表中的边数.

对二项随机变量 $B(3n \ln n, 1/n)$, 利用式 (4.1) 的切尔诺夫界, 取 $\delta = 2$, $\mu = 3 \ln n$, 我

们有

$$\Pr(X \geq 9 \ln n) \leq \left(\frac{e^2}{27}\right)^{3 \ln n} \leq \frac{1}{n^2}.$$

对所有顶点取并的界, 可得 $\Pr(\mathcal{E}_{2a}) \leq 1/n$.

其次, 考虑 $\Pr(\mathcal{E}_{2b})$ 的界. 对充分大的 n , 在一个顶点的未用过边的初始列表中, 边的期望数 Y 至少为 $(n-1)q \geq 20(n-1) \ln n/n \geq 19 \ln n$. 仍利用切尔诺夫界(式(4.5)), 任一顶点在它的初始列表上有 $10 \ln n$ 条边或更少边的概率至多为

$$\Pr(Y \leq 10 \ln n) \leq e^{-19 \ln n (9/19)^{2/2}} \leq \frac{1}{n^2},$$

由并的界, 任一顶点有非常少量邻接边的概率至多为 $1/n$. 所以

$$\Pr(\mathcal{E}_{2b}) \leq \frac{1}{n},$$

因此

$$\Pr(\mathcal{E}_2) \leq \frac{2}{n}.$$

总之, 在 $3n \ln n$ 次迭代中, 算法不能找到哈密顿圈的概率的界为

$$\Pr(\mathcal{E}_1) + \Pr(\mathcal{E}_2) \leq \frac{4}{n}. \quad \blacksquare$$

我们并没有努力去优化证明中的常数. 但明显存在一种折衷, 即用更多边换取更低的失败概率.

剩下的事情是说明如何将我们的算法用于 $G_{n,p}$ 中的图. 可以证明, 只要 p 已知, 就可以将图的边分成满足定理 5.16 要求的边的列表.

推论 5.17 通过适当地初始化未用过边列表中的边, 算法 5.2 可以以概率 $1 - O(1/n)$ 从 $G_{n,p}$ 随机选取的图上找到哈密顿圈, 其中 $p \geq 40 \ln n/n$.

证明 我们将来自 $G_{n,p}$ 的输入图的边作如下划分. 设 $q \in [0, 1]$ 满足 $p = 2q - q^2$. 考虑输入图中的任一边 (u, v) . 我们精确地执行以下三个可能性之一: 以概率 $q(1-q)/(2q-q^2)$ 将这条边放在 u 的(而不是 v)的未用过边列表中; 以概率 $q(1-q)/(2q-q^2)$ 将边初始放在 v 的(而不是 u)的未用过边列表中; 以剩余的的概率 $q^2/(2q-q^2)$ 将边放在这两个未用过边列表中.

现在, 对任一可能边 (u, v) , 它被初始放在 v 的未用过边列表中的概率为

$$p \left(\frac{q(1-q)}{2q-q^2} + \frac{q^2}{2q-q^2} \right) = q.$$

而且, 边 (u, v) 初始放在 u 和 v 的未用过边列表中的概率为 $pq^2/(2q-q^2) = q^2$, 所以这两种放置是独立事件. 因为每条边 (u, v) 是独立地处理的, 假如结果 q 至少为 $20 \ln n/n$, 这种划分就满足定理 5.16 的要求. 当 $p \geq 40 \ln n/n$ 时, 我们有 $q \geq p/2 \geq 20 \ln n/n$, 结论成立. \blacksquare

在练习 5.26 中, 我们考虑即使 p 不是事先已知时, 如何利用算法 5.2 使得没有对 p 的了解就必须初始化边的列表.

练习

- 5.1 对什么样的 n 值, $(1+1/n)^n$ 在 e 的 1% 范围内? 在 e 的 0.0001% 范围内呢? 类似地, 对什么样的 n 值, $(1-1/n)^n$ 在 $1/e$ 的 1% 范围内? 在 $1/e$ 的 0.0001% 范围内呢?
- 5.2 假定社会安全号是均匀随机地有重复地配给的, 即每个社会安全号由 9 个随机产生的数字组成, 而且不检查同一号码会不会配给两次. 有时, 将社会安全号的后四位数字作为口令. 在一个房间里, 需要多少个人会使得存在两个人有相同的后四位数字比不存在更可能? 多少个号码能够使得存在一对重号比不存在更可能? 如果社会安全号由 13 个数字组成, 将如何回答这两个问题? 试着给出精确的数值答案.
- 5.3 假定将球随机地放入 n 个箱子. 对某个常数 c_1 , 证明如果有 $c_1\sqrt{n}$ 个球, 那么没有两个球落入同一箱子的概率至多为 $1/e$. 类似地, 对某个常数 c_2 (以及充分大的 n), 证明如果有 $c_2\sqrt{n}$ 个球, 那么没有两个球落入同一箱子的概率至少为 $1/2$. 使这些常数尽可能接近于最优. 提示: 可以利用以下事实:

$$e^{-x} \geq 1 - x$$

及

$$e^{-x^2} \leq 1 - x, \quad \text{当 } x \leq \frac{1}{2}.$$

- 5.4 在一个可容纳 100 人的演讲厅里, 考虑其中是否有三人是同一个生日. 利用与以前分析中相同的假定, 解释如何精确地计算这个概率.
- 119 5.5 设 X 是均值为 μ 的泊松随机变量, 用以表示本书中某页上的错误个数. 每个错误独立地以概率 p 是语法错误, 以概率 $1-p$ 为拼写错误. 如果 Y 和 Z (分别) 表示这本书某页上的语法和拼写错误个数的随机变量, 证明 Y 和 Z 分别是均值为 μp 和 $\mu(1-p)$ 的泊松随机变量, 并证明 Y 和 Z 是独立的.
- 5.6 利用泰勒展开式

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

证明对任意 x , $|x| \leq 1$, 有

$$e^x(1-x^2) \leq 1+x \leq e^x.$$

- 5.7 假定 n 个球独立地且均匀随机地放入 n 个箱子中.
- (a) 在已知恰有一个球落入前三个箱子的条件下, 求箱子 1 有一个球的条件概率.
- (b) 在箱子 2 没有得到球的条件下, 求箱子 1 中球的条件期望个数.
- (c) 写出箱子 1 得到的球多于箱子 2 的概率表达式.
- 5.8 在 5.2.2 节的桶排序法分析中, 假定 n 个元素是从 $[0, 2^k]$ 中独立地且均匀随机地选取的. 现在代之以假定: n 个元素是从 $[0, 2^k]$ 中独立选取的, 服从具有如下性质的分布: 对某个固定常数 $a > 0$, 以至多 $a/2^k$ 的概率选取任一数 $x \in [0, 2^k]$. 证明在这些条件下,

桶排序法仍然要求线性期望时间.

5.9 考虑 n 个球随机投入 n 个箱子时, 每个箱子恰好有一个球的概率.

(a) 利用泊松近似, 给出这个概率的上界.

(b) 确定这个事件的精确概率.

(c) 证明这两个概率相差一个乘法因子, 它等于参数为 n 的泊松随机变量取值 n 的概率, 解释为什么这可由定理 5.6 得出.

5.10 考虑 m 个球投入 n 个箱子, 为方便起见, 对箱子从 0 到 $n-1$ 编号. 如果箱子 $i, i+1, \dots, i+k-1$ 都是空的, 我们称在箱子 i 处存在一个 k 间断.

(a) 确定 k 间断的期望个数.

(b) 证明 k 间断个数的切尔诺夫型界. (提示: 如果在箱子 i 处存在一个 k 间断, 令 $X_i = 1$, 那么在 X_i 与 X_{i+1} 间存在相关性, 为避免这种相关性, 可以考虑 X_i 和 X_{i+k} .)

5.11 下面的问题作为一个简单的分布系统模型, 其中代理人为资源而竞争, 但有争议时放弃. 球表示代理人, 箱子表示资源. 系统通过各轮投球逐渐演进. 每一轮, 球都是独立且均匀随机地放入 n 个箱子. 独自落在一个箱子中的球得到供给, 不再考虑. 在下一轮, 再次放入剩下的球. 从第一轮有 n 个球开始, 直到每个球得到供给结束.

(a) 如果在某轮开始时有 b 个球, 那么在下一轮开始时, 球的期望个数是多少?

(b) 假定每一轮中得到供给的球数恰好是得到供给球的期望个数. 证明经 $O(\log \log n)$ 轮后, 所有球都将得到供给. (提示: 如果 x_j 是经 j 轮后剩下的球的期望个数, 证明并利用 $x_{j+1} \leq x_j^2/n$.)

5.12 假定我们改变球和箱子过程如下: 为方便起见, 将箱子从 0 到 $n-1$ 编号. 有 $\log_2 n$ 个选手, 每个选手从 $[0, n-1]$ 中均匀随机地选取一个初始位置 ℓ , 然后在编号为 $\ell \bmod n, \ell+1 \bmod n, \dots, \ell+n/\log_2 n-1 \bmod n$ 的每个箱子中放入一球. 证明这种情况下, 当 $n \rightarrow \infty$ 时, 最大负荷以趋近于 1 的概率仅为 $O(\log \log n / \log \log \log n)$.

5.13 我们证明如果 Z 是均值为 μ 的泊松随机变量, 其中 $\mu \geq 1$ 是整数, 那么 $\Pr(Z \geq \mu) \geq 1/2$, $\Pr(Z \leq \mu) \geq 1/2$.

(a) 证明: 对 $0 \leq h \leq \mu-1$, $\Pr(Z = \mu+h) \geq \Pr(Z = \mu-h-1)$.

(b) 利用 (a), 证明 $\Pr(Z \geq \mu) \geq 1/2$.

(c) 证明: 对 $0 \leq h \leq \mu$, $\Pr(Z = \mu-h) \geq \Pr(Z = \mu+h+1)$.

(d) 确定 $\Pr(Z = \mu-h) - \Pr(Z = \mu+h+1)$ 的一个下界.

(e) 确定 $\Pr(Z \geq 2\mu+2)$ 的一个上界.

(f) 利用 (c) ~ (e), 证明 $\Pr(Z \leq \mu) \geq 1/2$.

5.14 (a) 在定理 5.7 中, 我们证明了对任一非负函数 f ,

$$E[f(Y_1^{(n)}, \dots, Y_n^{(n)})] \geq E[f(X_1^{(n)}, \dots, X_n^{(n)})] \Pr(\sum Y_i^{(n)} = m).$$

证明: 仍在 f 是非负条件下, 如果 $E[f(X_1^{(n)}, \dots, X_n^{(n)})]$ 是关于 m 单调递增的, 那么

$$E[f(Y_1^{(m)}, \dots, Y_n^{(m)})] \geq E[f(X_1^{(m)}, \dots, X_n^{(m)})] \Pr(\sum Y_i^{(m)} \geq m).$$

当 $E[f(X_1^{(m)}, \dots, X_n^{(m)})]$ 关于 m 单调递减时, 给出一个类似的结论.

(b) 利用 (a) 及练习 5.13, 证明定理 5.10.

5.15 我们考虑在球和箱子背景下, 不用定理 5.7 给出切尔诺夫型界的另一种方法. 考虑将 n

121 个球随机放入 n 个箱子中. 如果第 i 个箱子为空, 则 $X_i = 1$; 否则为 0. 令 $X = \sum_{i=1}^n X_i$, 并设 $Y_i (i=1, \dots, n)$ 表示独立的伯努利随机变量, 以概率 $p = (1-1/n)^n$ 为 1. 令 $Y = \sum_{i=1}^n Y_i$.

(a) 证明: 对任意 $k \geq 1$, $E[X_1 X_2 \cdots X_k] \leq E[Y_1 Y_2 \cdots Y_k]$.

(b) 证明: 对所有 $t \geq 0$, $E[e^{tX}] \leq E[e^{tY}]$. (提示: 利用 e^x 的展开式, 并比较 $E[X^k]$ 与 $E[Y^k]$.)

(c) 导出 $\Pr(X \geq (1+\delta)E[X])$ 的切尔诺夫界.

5.16 设 G 是用 $G_{n,p}$ 模型生成的随机图.

(a) 一个图的 k 个顶点的团是 k 个顶点的子集, 使得这些顶点之间的所有 $\binom{k}{2}$ 条边全在图中. p 作为 n 的函数, 它取何值时, G 中 5 个顶点的团的期望个数等于 1?

(b) 一个 $K_{3,3}$ 图是每条边上有 3 个顶点的完全二部图. 换言之, 它是有 6 个顶点和 9 条边的图; 6 个顶点分成两组, 每组 3 个, 9 条边连接各组间的 9 对顶点. 作为 n 的函数, p 取何值时, G 的子图 $K_{3,3}$ 的期望个数等于 1?

(c) 作为 n 的函数, p 取何值时, 图中的哈密顿圈的期望个数等于 1?

5.17 定理 5.7 证明了在球和箱子问题中(其中每个箱子中球的个数是独立的泊松随机变量), 任何以小概率出现的事件在标准的球和箱子模型中, 也以小概率出现. 对随机图证明类似的结论: 在 $G_{n,p}$ 模型中以小概率发生的事件, 在 $G_{n,N}$ 模型中, 当 $N = \binom{n}{2}p$ 时, 也以小概率发生.

5.18 一个 n 个顶点的无向图是不连通的, 如果存在 $k < n$ 个顶点集合, 使得这个集合与图的其余顶点之间没有边. 否则, 便称为连通的. 证明存在常数 c , 使得如果 $N \geq cn \log n$, 那么以概率 $O(c^{-n})$ 从 $G_{n,N}$ 随机选取的图是连通的.

5.19 证明定理 5.14.

5.20 (a) 设 $f(n)$ 是一个具有 n 个顶点的空无向图成为连通图时必须添加的随机边的期望个数. (连通性已在练习 5.18 中定义.) 也就是假定从一个 n 个顶点和零条边的图开始, 然后反复地从所有不在当前图的边中均匀随机地选取一条并添加之, 直到图成为连通的. 如果 X_n 表示添加的边数, 那么 $f(n) = E[X_n]$.

对已知的 n 值, 编写一个估计 $f(n)$ 的程序. 程序应当按照所添加的边追踪图的连通部分, 直到图成为连通的. 或许希望利用分离集数据结构, 即一个在标准的大

学算法教材中包含的课题。可以试验 $n = 100, 200, 300, 400, 500, 600, 700, 800, 900$ 及 1000 。每个试验重复 100 次, 对每个 n 值, 计算所需边的平均数。基于这样的试验, 推荐一个认为是 $f(n)$ 的好的估计函数 $h(n)$ 。

(b) 修改关于问题(a)的程序, 使得也能跟踪孤立点。设 $g(n)$ 是在不存在更多孤立点前添加的期望边数。在 $f(n)$ 和 $g(n)$ 之间有一个什么样的关系?

- 5.21 在开放寻址的散列法中, 散列表是作为一个数组执行的, 且没有链表或链。数组中的每个条目或者包含一个散列项, 或者是空的。对每个线索 k , 散列函数定义了一个表位置的探索序列 $h(k, 0), h(k, 1), \dots$ 。为插入线索 k , 我们首先按线索的探索序列所定义的次序检查表位置序列, 直到发现空位置, 然后在那个位置插入项目。在散列表中搜索项目时, 我们按线索的探索序列定义的次序检查表位置序列, 直到发现那个项目或者在序列中发现一个空位置。如果发现空位置, 这意味着项目不在表中。

一个有 $2n$ 个条目的开放寻址散列表用于存放 n 个项目。假定表位置 $h(k, j)$ 均匀地散布在 $2n$ 个可能的表位置上, 且所有 $h(k, j)$ 是独立的。

(a) 在这些条件下, 证明一个要求多于 k 次探索的插入概率至多为 2^{-k} 。

(b) 对 $i = 1, 2, \dots, n$, 证明要求多于 $2 \log n$ 次探索的第 i 次插入概率至多为 $1/n^2$ 。

设随机变量 X_i 表示第 i 次插入所要求的探索次数, 在(b)中已证明了 $\Pr(X_i > 2 \log n) \leq 1/n^2$ 。设随机变量 $X = \max_{1 \leq i \leq n} X_i$ 表示 n 次插入中任一次所要求的最大探索次数。

(c) 证明 $\Pr(X > 2 \log n) \leq 1/n$ 。

(d) 证明最长探索序列的期望长度为 $E[X] = O(\log n)$ 。

- 5.22 Bloom 过滤器可用于估计集合的差别。假定你有一个集合 X , 我有一个集合 Y , 二者都有 n 个元素。例如, 集合可能表示我们特别喜欢的 100 首歌曲。利用相同的二进制数字个数 m 以及相同的 k 个散列函数, 我们两人建立集合的 Bloom 过滤器。确定二进制数字的期望个数, 其中我们的 Bloom 过滤器的差别是一个 m, n, k 及 $|X \cap Y|$ 的函数。说明为什么将它用作寻找在音乐方面有相同口味的人比直接比较歌曲列表更容易。

- 5.23 假定希望将 Bloom 过滤器推广为允许在基础集合中删除及插入项目。可以将 Bloom 过滤器修改成为计数器数组, 以代替二进制数字数组。每次将一个项目插入 Bloom 过滤器, 由项目的散列给出的计数器增加 1。删去一个项目, 可以简单地减少计数器。为了保持小的空间, 计数器应是固定长度的, 如 4 个二进制数字的。

说明使用固定长度的计数器时误差是如何产生的。假定一个设置为任何时候集合中至多有 n 个元素, m 个计数器, k 个散列函数, 且计数器是 b 个二进制数字的, 说明如何界定在 t 个插入或删除过程中出现一个错误的概率。

- 5.24 假定你为有 $m = 2^t$ 个二进制数字的词的字典构造了一个 Bloom 过滤器。构造应用的某个合作者希望利用你的 Bloom 过滤器, 但只能用 2^{t-1} 个二进制数字的。说明你的同事如何利用你的 Bloom 过滤器, 使得能利用原来的词典以避免重新构造一个新的 Bloom 过滤器。

- 5.25 对于 5.5.4 节提到的领导者选举问题, 我们有 n 个用户, 每个用户都有一个识别码。散

列函数将识别码作为输入, 输出一个 b 位散列值. 假定这些值是独立且均匀分布的. 每个用户散列他的识别码, 领导者是有最小散列值的用户. 给出以概率 p 保证能成功选取唯一领导者所必需的二进制数字个数 b 的上界和下界. 使你的界尽可能地紧.

- 5.26 考虑算法 5.2, 即寻找哈密顿圈的修正算法. 我们已经证明, 通过将边适当地初始放置在边列表中, 算法能以大的概率从 $G_{n,p}$ 随机选取的图中找到一个哈密顿圈, 其中 p 已知且充分大. 证明也能类似地应用此算法以大的概率从 $G_{n,N}$ 随机选取的图中寻找哈密顿圈, 其中 $N = c_1 n \ln n$, c_1 是适当大的常数. 再证明即使在 p 不是事先已知的情况下, 只要 p 至少为 $c_2 \ln n/n$, 修正算法仍可使用, 其中 c_2 是适当大的常数.

探索性作业

随机过程的研究中有一部分是首先在高层次上理解发生了什么, 然后将这个理解用于提出正式的数学证明. 在这个作业中, 将给出一个基本随机过程的几种变形. 为此需要在编写代码来模拟过程的基础上进行试验(代码应该非常短, 最多几页). 试验之后, 应该利用模拟结果指导来作出猜测, 并证明关于过程的论述. 可以应用学过的知识(包括球和箱子模型的概率界及分析)来做这件事情.

考虑有 $N = 2^n - 1$ 个结点的完全二叉树, 这里 n 是树的深度. 开始时, 所有结点是未标号的. 随着时间的流逝, 通过我们将要描述的过程, 结点成为已标号的.

所有过程都有相同的基本形式. 我们将结点看成在范围 $[1, N]$ 内有唯一标识的数字. 每个时间单位, 我向你发送结点的标识码. 当你收到发送的结点时, 便标出它, 而且执行以下的标号规则, 它在我发送下一个结点以前有效.

- 如果一个结点及其兄弟结点是已标号的, 那么它的父结点是已标号的.
- 如果一个结点及其父结点是已标号的, 那么其他兄弟结点是已标号的.

在发送下一结点以前, 尽可能多地递归使用标号规则. 例如, 图 5.3 中已标号结点已经填入. 标有 X 的结点的到来, 在自上而下地用标号规则标记树时, 只许你对剩余结点标号. 记住, 总是尽可能多地应用标号规则.

现在考虑我以不同的方法向你发送结点.

方法 1: 每个时间单位, 我发送一个从所有 N 个结点中独立且均匀随机地选取的结点的标识码. 注意, 我可能向你发送一个已经标号的结点, 事实上, 我可能发送一个我已经发送过的无用结点.

方法 2: 每个时间单位, 我发送一个从我还没有发送过的结点中均匀随机地选取的结点的标识码. 仍有可能到达一个已经标号的结点, 但每个结点至多发送一次.

方法 3: 每个时间单位, 我发送一个从你还没有标号的结点中均匀随机地选取的结点的标识码.

我们对每种方法确定在所有结点标号以前需要多少时间步. 首先编写一个程序模拟发

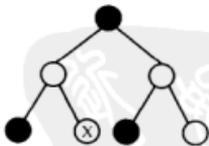


图 5.3 X 的到达引起所有其他结点成为已标号的

送过程及标号规则. 对 $[10, 20]$ 中的每个 n 值, 运行每种方法10次, 以清楚易读的形式给出来自你的实验数据, 并适当地解释你的数据. 一个提示: 你可能发现让你的程序打印出在树成为完全标号的之前发送的最后一个结点是有用的.

1. 对第一种方法, 证明发送结点的期望数是 $\Omega(N \log N)$. 这与你的模拟能很好地相配吗?
2. 对第二种方法, 你可能发现在树被标号以前, 几乎必须发送所有的 N 个结点. 证明以一个不变的概率, 至少需要发送 $N - 2\sqrt{N}$ 个结点.
3. 第三种方法的表现可能有点不正常, 用证明来解释它.

在回答了这些问题以后, 你可能希望考虑有关这些方法的可以证明的其他事实.



第6章 概率方法

概率方法是一种证明对象存在的方式。其基本原理是比较简单的：为了证明具有某种性质的对象的存在，我们展示一个对象的样本空间，其中一个随机选择的对象具有所要求性质的概率是正的。如果选取一个具有所要求性质对象的概率是正的，那么样本空间必定含有这种对象，所以这样的对象是存在的。比如，在一次摸彩活动中，如果存在赢得100万美元奖金的正概率，那么必须至少有一张彩票会赢得这个奖金。

尽管概率方法的基本原理是简单的，但它在一些特殊问题中的应用常牵涉到复杂的组合论证。在这一章里，我们学习几种基于概率方法的构造性证明技术。首先从简单的计数及平均量开始，然后介绍两个较高级的工具——洛瓦兹(Lovasz)局部引理和二阶矩方法。

在算法方面，一般来讲我们不仅关心存在性的证明，也对对象的显式结构感兴趣。在许多情况下，用概率方法得到的存在性的证明可以转换为有效的随机化构造算法，在有些情况下，这些证明可以转换为有效的确定性构造算法；因为这样一个过程把一个概率方法转换成了一个确定性方法，所以称为消除随机化。我们给出来自概率方法的随机化构造算法以及确定性构造算法的例子。

6.1 基本计数论证

为了证明具有某种性质的对象的存在性，我们构造一个对象的适当概率空间 S ，然后证明从 S 中选取一个具有所要求性质对象的概率严格地大于0。

第一个例子，我们考虑用两种颜色给一个图的边着色的问题，要求不能出现一个所有边颜色都相同的大团。设 K_n 是有 n 个顶点（有所有 $\binom{n}{2}$ 条边）的完备图， K_n 中 k 个顶点的团是一个完备的子图 K_k 。

定理 6.1 如果 $\left(\frac{n}{2}\right)2^{-(\binom{n}{2}-1)} < 1$ ，那么有可能用两种颜色给 K_n 的边着色，使得不会有单色 K_k 子图。

证明 定义一个用两种颜色对 K_n 的边的所有可能着色组成的样本空间。存在 $2^{\binom{n}{2}}$ 种可能的着色法，所以如果均匀随机地选取其中之一，那么在我们的概率空间中选取每种着色法的概率就是 $2^{-\binom{n}{2}}$ 。理解这个概率空间的一种很好的方法是：如果我们独立地为图中的每条边着色，每一条边以 $\frac{1}{2}$ 的概率取两种颜色中的一种，那么便得到了从这一样本空间中均匀选取的一种随机着色。也就是我们独立地投掷一枚均匀硬币来确定每条边的颜色。

对 K_n 中所有 $\binom{n}{k}$ 个不同的 k 顶点团，固定任意一个次序，令 A_i 是团 i 为单色这一事件，

$i = 1, \dots, \binom{n}{k}$. 一旦团的第一条边着色了, 那么所有其余 $\binom{k}{2} - 1$ 条边必须有相同的颜色. 这样

$$\Pr(A_i) = 2^{-\binom{k}{2}+1}.$$

利用并的界可得

$$\Pr\left(\bigcup_{i=1}^{\binom{n}{k}} A_i\right) \leq \sum_{i=1}^{\binom{n}{k}} \Pr(A_i) = \binom{n}{k} 2^{-\binom{k}{2}+1} < 1,$$

其中最后一个不等式由定理的假设得出. 因此有

$$\Pr\left(\bigcap_{i=1}^{\binom{n}{k}} \bar{A}_i\right) = 1 - \Pr\left(\bigcup_{i=1}^{\binom{n}{k}} A_i\right) > 0.$$

由于从我们的样本空间选取一种没有单色 k 顶点团的着色法的概率严格地大于 0, 因此必定存在一种没有单色 k 顶点团的着色. ■

作为一个例子, 考虑 K_{1000} 的边是否可以用这种方法着两种颜色, 使得没有单色的 K_{20} . 计算是简单的, 如果我们注意到对 $n \leq 2^{k/2}$ 且 $k \geq 3$ 时,

$$\begin{aligned} \binom{n}{k} 2^{-\binom{k}{2}+1} &\leq \frac{n^k}{k!} 2^{-(k(k-1)/2)+1} \\ &\leq \frac{2^{k/2+1}}{k!} \\ &< 1. \end{aligned}$$

本例中显然有 $n = 1000 \leq 2^{10} = 2^{k/2}$, 由定理 6.1 可知, 存在一种对 K_{1000} 边的 2 着色法, 使得没有单色的 K_{20} .

能利用这个证明设计一个有效算法来构造这样一种着色吗? 考虑给出随机化构造算法的一般方法. 首先要求可以从样本空间有效地抽取一种着色. 在这种情况下, 因为我们可以对每条边以随机选取的颜色独立着色, 所以抽样是容易的, 但一般来说这不是一个有效的抽样算法.

如果有一个有效的抽样算法, 下一个问题是: 在得到能满足我们要求的样品之前, 必需产生多少个样品? 如果得到一个具有所要求性质的样品的概率是 p , 且在每次试验中抽样是独立的, 那么在找到具有所要求性质的样品之前需要的样品个数是一个期望为 $1/p$ 的几何随机变量. 因此, 为了有一个能在多项式期望时间内找到合适样本的算法, 我们要求 $1/p$ 是关于问题大小的多项式.

如果 $p = 1 - o(1)$, 那么抽样一次给出一种不正确的概率为 $o(1)$ 的蒙特卡罗构造算法. 在希望找到一种在 1000 个顶点的图上没有单色 K_{20} 的着色法的例子中, 我们知道一种随机着色有一个单色 K_{20} 的概率至多为

$$\frac{2^{20 \cdot 2+1}}{20!} < 8.5 \cdot 10^{-16}.$$

因此我们有一种以小概率失败的蒙特卡罗算法。

如果希望一种 Las Vegas 算法——即总是给出正确构造的算法，那么我们需要第三种成分。为证实抽样对象满足要求，我们要求一个多项式时间方法，然后可以验证样本，直到找到那样的样品。对这种构造法的期望时间的上界，可以将期望的样品个数 $1/p$ ，即产生每个样品的时间的上界与检验每个样品的时间的上界一起相乘。对着色问题，当 k 是常数时，存在一个多项式时间的验证算法：简单地检查所有 $\binom{n}{k}$ 团，并保证它们不是单色的。然而，当 k 随着 n 增加时，这种方法似乎不能推广以得到多项式时间算法。

6.2 期望论证

正如我们已经看到的，为了证实具有某种性质的对象的存在，可以设计一个概率空间，在这个概率空间中随机选取的元素，以正的概率是一个具有指定性质的对象。为证明这样的对象存在，一个类似的且有时更容易的方法是用平均量。支持这种方法的直觉是，在离散概率空间中，一个随机变量必须以正概率至少取一个不大于其期望的值，也至少有一个取值不小于期望的值。比如，如果一张彩票的期望值至少是 3 美元，那么必须至少有一张彩票的价值不大于 3 美元，且至少也有一张彩票的价值不小于 3 美元。

更正式地，我们有下面的引理。

引理 6.2 假定有一个概率空间 S 以及定义在 S 上的随机变量 X ，满足 $E[X] = \mu$ ，那么 $\Pr(X \geq \mu) > 0$ 且 $\Pr(X \leq \mu) > 0$ 。

证明 我们有

$$\mu = E[X] = \sum_x x \Pr(X = x),$$

其中求和范围遍及 X 值域中的所有值，如果 $\Pr(X \geq \mu) = 0$ ，那么

$$\mu = \sum_x x \Pr(X = x) = \sum_{x < \mu} x \Pr(X = x) < \sum_{x < \mu} \mu \Pr(X = x) = \mu,$$

得到矛盾。类似地，如果 $\Pr(X \leq \mu) = 0$ ，那么

$$\mu = \sum_x x \Pr(X = x) = \sum_{x > \mu} x \Pr(X = x) > \sum_{x > \mu} \mu \Pr(X = x) = \mu,$$

仍得出矛盾。

这样，在 S 的样本空间中，必至少存在一种情况，使 X 的值至少为 μ ，且至少存在一种 X 值不大于 μ 的情况。

6.2.1 应用：求最大割

我们考虑在一个无向图中求最大割的问题。一个割是将顶点划分成两个不相交的集合，割的值是从划分的一侧到另一侧的所有边的权。这里我们考虑图中所有边有相同权 1 的情况。求最大割问题是 NP 难题。利用概率方法，我们证明最大割的值必须至少是图中边数的 $\frac{1}{2}$ 。

⊙ 有时产生或检验一个样本的时间本身可能是一个随机变量，此时，可以用瓦尔德方程（在第 12 章讨论）。

定理 6.3 给定一个有 n 个顶点和 m 条边的无向图 G , 存在一个将 V 分成两个互不相交集 A 和 B 的划分, 使得至少有 $\frac{m}{2}$ 条联接 A 中顶点与 B 中顶点的边, 即存在一个值至少为 $\frac{m}{2}$ 的割.

证明 用随机、独立指派每个顶点到两个集合之一的方法构造集合 A 和 B . 设 e_1, \dots, e_m 是图 G 的边的任意列举, 对 $i=1, \dots, m$, 定义 X_i 满足

$$X_i = \begin{cases} 1, & \text{如果边 } e_i \text{ 联接 } A \text{ 和 } B, \\ 0, & \text{其他} \end{cases}$$

边 e_i 联接 A 中顶点与 B 中顶点的概率是 $\frac{1}{2}$, 所以,

$$E[X_i] = \frac{1}{2}.$$

设 $C(A, B)$ 是表示对应于集合 A 和 B 的割值的随机变量, 那么

$$E[C(A, B)] = E\left[\sum_{i=1}^m X_i\right] = \sum_{i=1}^m E[X_i] = m \cdot \frac{1}{2} = \frac{m}{2}.$$

因为随机变量 $C(A, B)$ 的期望是 $\frac{m}{2}$, 存在一个划分 A 和 B , 使得至少有 $\frac{m}{2}$ 条联接集合 A 和集合 B 的边. ■

可以将这个证明转换成寻找一个值至少为 $\frac{m}{2}$ 的割的有效算法. 我们首先说明如何得到一个 Las Vegas 算法. 在后面的 6.3 节, 说明构造一个确定性的多项式时间算法.

如证明中所描述的那样, 随机选取一个划分是容易的. 期望论证并没有给出随机划分是值至少为 $\frac{m}{2}$ 的割的概率下界. 为导出这样一个下界, 设

$$p = \Pr\left(C(A, B) \geq \frac{m}{2}\right),$$

注意到 $C(A, B) \leq m$, 那么

$$\begin{aligned} \frac{m}{2} &= E[C(A, B)] \\ &= \sum_{i \leq m/2-1} i \Pr(C(A, B) = i) + \sum_{i \geq m/2} i \Pr(C(A, B) = i) \\ &\leq (1-p) \left(\frac{m}{2} - 1\right) + pm, \end{aligned}$$

这蕴涵

$$p \geq \frac{1}{m/2 + 1}.$$

所以, 在找到值至少为 $\frac{m}{2}$ 的割之前的抽样期望数正是 $\frac{m}{2} + 1$. 检验由样本确定的割值是否至少为 $\frac{m}{2}$, 可以通过简单地数出横跨割的边数, 用多项式时间完成. 所以我们有一个求割的 Las Vegas 算法.

6.2.2 应用：最大可满足性

我们将类似的方法用于最大可满足性(MAXSAT)问题。在逻辑公式中，一个文字或者是布尔变量或者是布尔变量的否定。我们用 \bar{x} 表示变量 x 的否定。可满足性(SAT)问题或 SAT 公式是子句集合合取(AND)的逻辑表示，其中每个子句是文字的析取(OR)。例如，下面的表达式就是 SAT 的一个实例：

$$(x_1 \vee \bar{x}_2 \vee \bar{x}_3) \wedge (\bar{x}_1 \vee \bar{x}_3) \wedge (x_1 \vee x_2 \vee x_3) \wedge (x_4 \vee \bar{x}_3) \wedge (x_4 \vee \bar{x}_1).$$

一个 SAT 公式实例的解是变量赋值为 True 或 False，使得所有的子句都是满足的。即在每个子句中，至少存在一个真文字。例如， x_1 赋值为 True， x_2 为 False， x_3 为 False， x_4 为 True 满足前面的 SAT 公式。一般地，确定一个 SAT 公式是否有解是 NP 难题。

给定一个 SAT 公式，一个有关的目标是满足尽可能多的子句。以后，假定没有子句包含一个变量及它的余，因为此时子句总是满足的。

定理 6.4 给定 m 个子句的集合，设 k_i 是第 i 个子句中的文字个数， $i=1, 2, \dots, m$ 。令 $k = \min_{i=1}^m k_i$ ，那么存在一个至少满足

$$\sum_{i=1}^m (1 - 2^{-k_i}) \geq m(1 - 2^{-k})$$

个子句的真赋值。

证明 对变量独立、均匀随机地赋值。有 k_i 个文字的第 i 个子句是满足的概率至少为 $(1 - 2^{-k_i})$ 。所以满足的子句的期望数至少为

$$\sum_{i=1}^m (1 - 2^{-k_i}) \geq m(1 - 2^{-k}),$$

所以必有一个至少满足那么多子句的赋值。 ■

前面的证明也容易转换为一个有效的随机化算法，当所有 $k_i = k$ 时的情况留作练习 6.1。

6.3 利用条件期望消除随机化

概率方法可以了解如何构造确定性算法。作为一个例子，我们用条件期望的方法来消除 6.2.1 节求最大割算法的随机性。

回忆我们将图的 n 个顶点 V 划分成集合 A 和 B 的方法，是将每个顶点独立且均匀随机地放入两个集合之一。这给出了期望值 $E[C(A, B)] \geq m/2$ 的割。现在设想确定地放置顶点，每次放一个，依任意次序 v_1, v_2, \dots, v_n 。设 x_i 是 v_i 放入的集合（所以 x_i 或者是 A ，或者是 B ），假定已经放置了前 k 个顶点，如果其余顶点是独立且均匀地放入两个集合之一时，考虑割的期望值。将这个量记为 $E[C(A, B) | x_1, x_2, \dots, x_k]$ ，这是已知前 k 个顶点的位置 x_1, x_2, \dots, x_k 时割值的条件期望。我们用归纳法证明如何放置下一个顶点，使得

$$E[C(A, B) | x_1, x_2, \dots, x_k] \leq E[C(A, B) | x_1, x_2, \dots, x_{k+1}].$$

由此可知

$$E[C(A, B)] \leq E[C(A, B) | x_1, x_2, \dots, x_n].$$

右边是由我们的放置算法确定的割值, 这是因为如果 x_1, x_2, \dots, x_k 全都确定, 便有一个图的割. 因此我们的算法返回一个其值至少为 $E[C(A, B)] \geq m/2$ 的割.

归纳的基本情况是

$$E[C(A, B) | x_1] = E[C(A, B)],$$

因为我们将第一个顶点放在哪个集合中并不重要, 所以由对称性, 这是成立的.

现在证明归纳步, 即

$$E[C(A, B) | x_1, x_2, \dots, x_k] \leq E[C(A, B) | x_1, x_2, \dots, x_{k+1}]. \quad (6.1)$$

考虑随机放置 v_{k+1} , 使得以概率 $\frac{1}{2}$ 放入 A 或 B , 设 Y_{k+1} 是表示它放入集合的随机变量, 那么

$$\begin{aligned} E[C(A, B) | x_1, x_2, \dots, x_k] &= \frac{1}{2} E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = A] \\ &\quad + \frac{1}{2} E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = B]. \end{aligned}$$

因此

$$\begin{aligned} \max\{E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = A], E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = B]\} \\ \geq E[C(A, B) | x_1, x_2, \dots, x_k]. \end{aligned}$$

所以, 我们必须做的是计算两个量 $E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = A]$ 与 $E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = B]$, 然后将 v_{k+1} 放入能产生较大期望的集合中. 只要这样做, 我们就有一个满足

$$E[C(A, B) | x_1, x_2, \dots, x_k] \leq E[C(A, B) | x_1, x_2, \dots, x_{k+1}].$$

的放置.

为计算 $E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = A]$, 注意已知前 $k+1$ 个顶点的放置的条件, 所以可以计算对割值有贡献的顶点中边的个数. 对所有其余的边, 以后将对割有贡献的概率为 $\frac{1}{2}$, 这是因为这是其两个端点在割的不同侧的概率. 由期望的线性性, $E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = A]$ 是横跨割的边数(其两个端点都在前 $k+1$ 个顶点中)加上其余边的一半, 这在线性时间内容易计算. 对 $E[C(A, B) | x_1, x_2, \dots, x_k, Y_{k+1} = B]$ 同样为真.

事实上, 从这个证明中我们看到, 两个量中的较大者正是由 v_{k+1} 在 A 中或是 B 中有更多邻点所确定的. 不以 v_{k+1} 作为一个端点的所有边对两个期望有同样大小的贡献, 所以我们的消除随机化算法有以下简单形式: 依某种次序取顶点, 将第一个顶点任意地放入 A 中, 放置每个相继顶点使横跨割的边数最大化. 等价地, 将每个顶点放入有较少邻点的那侧, 有结时任意放置. 这是一个简单的贪婪算法, 我们的分析说明, 它总能保证割至少有 $\frac{m}{2}$ 条边.

6.4 抽样和修改

至此, 我们直接用概率方法构造了具有所要求性质的随机结构. 在某些情况下, 不是直接地而是将问题分成两个阶段会更容易工作. 在第一阶段, 构造一个并不具有所要求性质的随机

结构, 然后在第二步, 修改这个随机结构, 使其具有所要求的性质. 我们给出这种抽样和修改方法的两个例子.

6.4.1 应用: 独立集合

图 G 中的独立集合是相互之间没有边的顶点集合. 寻找一个图中的最大独立集合是一个 NP 难题. 下面的定理说明概率方法可以给出一个图的最大独立集合的大小的界.

定理 6.5 设 $G = (V, E)$ 是有 n 个顶点和 m 条边的图, 那么 G 有一个至少有 $\frac{n^2}{4m}$ 个顶点的独立集合.

证明 设 $d = \frac{2m}{n}$ 是 G 中顶点的平均次, 考虑下面的随机化算法.

1. 以 $1 - \frac{1}{d}$ 的概率独立地删除图 G 中的每个顶点(连同它的关联边一起删除).

2. 对每条剩余边, 消去它及它的一个相邻顶点.

因为所有边都已消去, 剩余顶点形成了一个独立集合. 这是抽样和修改方法的一个例子. 首先对顶点抽样, 然后修改剩余的图.

设 X 是算法第一步后生存的顶点个数. 因为图有 n 个顶点且每个顶点以 $\frac{1}{d}$ 的概率生存, 因此

$$E[X] = \frac{n}{d}.$$

设 Y 是算法第一步后生存的边数. 图中有 $\frac{nd}{2}$ 条边, 一条边生存当且仅当它的两个相邻点生存. 这样

$$E[Y] = \frac{nd}{2} \left(\frac{1}{d}\right)^2 = \frac{n}{2d}.$$

算法的第二步消去了所有剩余边及至多 Y 个顶点. 当算法结束时, 输出一个大小至少为 $X - Y$ 的独立集合, 且

$$E[X - Y] = \frac{n}{d} - \frac{n}{2d} = \frac{n}{2d}$$

由算法产生的独立集合的期望大小为 $\frac{n}{2d}$, 所以, 图有一个至少有 $\frac{n}{2d} = \frac{n^2}{4m}$ 个顶点的独立集合. ■

6.4.2 应用: 有较大围长的图

作为另一个例子, 我们考虑图的围长, 即它的最小圈的长度. 直观上, 我们期望稠密的图有较小的围长, 但可以证明存在有相对较大围长的稠密图.

定理 6.6 对任意整数 $k \geq 3$, 存在一个有 n 个结点且至少有 $\frac{1}{4}n^{1+1/k}$ 条边及围长至少为 k 的图.

证明 首先对一个随机图 $G \in G_{n,p}$ 抽样, $p = n^{1/k-1}$. 设 X 是图的边数, 那么

$$E[X] = p \binom{n}{2} = \frac{1}{2} \left(1 - \frac{1}{n}\right) n^{1+1/k}.$$

设 Y 是长至多为 $k-1$ 的图中圈个数. 任一长为 i ($3 \leq i \leq k-1$) 的指定的可能圈以概率 p^i 出现, 而且存在 $\binom{n}{i} \frac{(i-1)!}{2}$ 个长度为 i 的可能圈; 为此, 首先考虑选取 i 个顶点, 然后考虑可能的次序, 最后记住相反的次序产生相同的圈. 因此

$$E[Y] = \sum_{i=3}^{k-1} \binom{n}{i} \frac{(i-1)!}{2} p^i \leq \sum_{i=3}^{k-1} n^i p^i = \sum_{i=3}^{k-1} n^{i/k} < kn^{(k-1)/k}.$$

通过从每个长度直到 $k-1$ 的圈中消去一条边来修改原来随机选取的图 G , 所以修改后的图的围长至少为 k . 当 n 足够大时, 所得图中的期望边数为

$$E[X - Y] \geq \frac{1}{2} \left(1 - \frac{1}{n} \right) n^{1/4+1} - kn^{(k-1)/4} \geq \frac{1}{4} n^{1/4+1}.$$

因此存在至少有 $\frac{1}{4} n^{1/4+1}$ 条边且围长至少为 k 的一个图. ■

6.5 二阶矩方法

二阶矩方法是另一种用于概率方法的有用方法. 标准的途径是利用以下容易由切比雪夫不等式导出的不等式.

定理 6.7 如果 X 是非负整值随机变量, 那么

$$\Pr(X = 0) \leq \frac{\text{Var}[X]}{(E[X])^2}. \quad (6.2) \quad \boxed{134}$$

证明

$$\Pr(X = 0) \leq \Pr(|X - E[X]| \geq E[X]) \leq \frac{\text{Var}[X]}{(E[X])^2}. \quad \blacksquare$$

6.5.1 应用: 随机图的阈性质

二阶矩方法可以用于证明某些随机图的阈性质, 即在 $G_{n,p}$ 模型中, 常常有这样的情况, 存在一个阈函数 f 使得: (a) 当 p 恰好小于 $f(n)$ 时, 几乎没有图具有所要求的性质; 而 (b) 当 p 恰好大于 $f(n)$ 时, 几乎每个图具有所要求的性质. 这里我们给出一个相对简单的例子.

定理 6.8 在图 $G_{n,p}$ 中, 假定 $p = f(n)$, 其中 $f(n) = o(n^{-2/3})$, 那么对任意 $\varepsilon > 0$ 及充分大的 n , 一个选自 $G_{n,p}$ 的随机图具有 4 个或更多顶点的团的概率小于 ε . 类似地, 如果 $f(n) = \omega(n^{-2/3})$, 那么对充分大的 n , 一个选自 $G_{n,p}$ 的随机图不具有 4 个或更多顶点的团的概率小于 ε .

证明 首先考虑 $p = f(n)$ 和 $f(n) = o(n^{-2/3})$ 的情况. 设 $C_1, \dots, C_{\binom{n}{4}}$ 是图 G 中所有 4 个顶点的子集的列举. 设

$$X_i = \begin{cases} 1, & \text{如果 } C_i \text{ 是 4 团} \\ 0, & \text{其他} \end{cases}$$

又设

$$X = \sum_{i=1}^{\binom{n}{4}} X_i,$$

所以

$$E[X] = \binom{n}{4} p^6.$$

在这种情况下, $E[X] = o(1)$, 这表示对于充分大的 n , $E[X] < \varepsilon$. 因为 X 是非负整值的随机变量, 因此 $\Pr(X \geq 1) \leq E[X] < \varepsilon$. 所以一个选自 $G_{n,p}$ 的随机图有 4 个或更多顶点的团的概率小于 ε .

现在考虑 $p = f(n)$ 而 $f(n) = \omega(n^{-2/3})$ 的情况. 此时随 n 增大, $E[X] \rightarrow \infty$. 这本身不足以给出结论: 以大的概率, 一个选自 $G_{n,p}$ 的图有至少是 4 个顶点的团. 但可以利用定理 6.7 证明, 这种情况下 $\Pr(X=0) = o(1)$. 为此必须证明 $\text{Var}[X] = o((E[X])^2)$. 这里我们直接计算方差, 另一方法如练习 6.11 给出.

首先有以下有用的公式.

引理 6.9 设 $Y_i (i=1, \dots, m)$ 是 0-1 随机变量, $Y = \sum_{i=1}^m Y_i$, 那么

$$\text{Var}[Y] \leq E[Y] + \sum_{1 \leq i, j \leq m, i \neq j} \text{Cov}(Y_i, Y_j).$$

证明 对于任意的随机变量序列 Y_1, \dots, Y_m ,

$$\text{Var}\left[\sum_{i=1}^m Y_i\right] = \sum_{i=1}^m \text{Var}[Y_i] + \sum_{1 \leq i, j \leq m, i \neq j} \text{Cov}(Y_i, Y_j).$$

这是定理 3.2 推广到 m 个变量的情况.

当 Y_i 是 0-1 随机变量时, $E[Y_i^2] = E[Y_i]$, 所以

$$\text{Var}[Y_i] = E[Y_i^2] - (E[Y_i])^2 \leq E[Y_i],$$

引理得证.

我们希望计算

$$\text{Var}[X] = \text{Var}\left[\sum_{i=1}^{\binom{n}{4}} X_i\right].$$

应用引理 6.9 可知, 需要考虑随机变量 X_i 的协方差. 如果 $|C_i \cap C_j| = 0$, 那么相应的团是不相交的, 因此 X_i 与 X_j 是独立的. 所以此时 $E[X_i X_j] - E[X_i]E[X_j] = 0$. 如果 $|C_i \cap C_j| = 1$, 同样为真.

如果 $|C_i \cap C_j| = 2$, 那么相应的团共享一条边. 对处在同一个图中的两个团, 图中必须出现 11 条相应边. 因此, 这种情况下有 $E[X_i X_j] - E[X_i]E[X_j] \leq E[X_i X_j] \leq p^{11}$. 共有 $\binom{n}{6}$ 种方法选取 6 个顶点, 有 $\binom{6}{2; 2; 2}$ 种方法将它们分到 C_i 和 C_j 中 (因为为 $C_i \cap C_j$ 选取两个顶点, 单独为 C_i 取两个, 单独为 C_j 取两个).

如果 $|C_i \cap C_j| = 3$, 那么相应的团共享 3 条边. 对处于同一个图中的两个团, 图中必须出现 9 条相应边. 因此, 这种情况下有 $E[X_i X_j] - E[X_i]E[X_j] \leq E[X_i X_j] \leq p^9$. 共有 $\binom{n}{5}$ 种方法

选取 5 个顶点；有 $\binom{5}{3; 1; 1}$ 种方法将它们分到 C_1 和 C_2 中。

最后再次回忆 $E[X] = \binom{n}{4} p^6$, $p = f(n) = \omega(n^{-2/3})$, 因此,

$$\text{Var}[X] \leq \binom{n}{4} p^6 + \binom{n}{6} \binom{6}{2; 2; 2} p^{11} + \binom{n}{5} \binom{5}{3; 1; 1} p^9 = o(n^8 p^{12}) = o((E[X])^2),$$

这是因为

$$(E[X])^2 = \left(\binom{n}{4} p^6 \right)^2 = \Theta(n^8 p^{12}).$$

现在由定理 6.7 证明了 $\Pr(X=0) = o(1)$, 这样就证明了定理的第二部分. ■

6.6 条件期望不等式

对于伯努利随机变量的和, 我们可以导出另一种常常易于应用的二阶矩方法. [136]

定理 6.10 设 $X = \sum_{i=1}^n X_i$, 其中每个 X_i 是 0-1 随机变量, 那么

$$\Pr(X > 0) \geq \sum_{i=1}^n \frac{\Pr(X_i = 1)}{E[X | X_i = 1]}. \quad (6.3)$$

注意式 (6.3) 成立并不需要 X_i 独立.

证明 记 $Y = 1/X$, 如果 $X > 0$; 否则, $Y = 0$, 那么

$$\Pr(X > 0) = E[XY].$$

但

$$\begin{aligned} E[XY] &= E\left[\sum_{i=1}^n X_i Y\right] \\ &= \sum_{i=1}^n E[X_i Y] \\ &= \sum_{i=1}^n (E[X_i Y | X_i = 1] \Pr(X_i = 1) + E[X_i Y | X_i = 0] \Pr(X_i = 0)) \\ &= \sum_{i=1}^n E[Y | X_i = 1] \Pr(X_i = 1) \\ &= \sum_{i=1}^n E[1/X | X_i = 1] \Pr(X_i = 1) \\ &\geq \sum_{i=1}^n \frac{\Pr(X_i = 1)}{E[X | X_i = 1]}. \end{aligned}$$

关键一步是从第 3 行到第 4 行, 其中通过利用 $E[X_i Y | X_i = 0] = 0$ 的事实, 以更有利的方法运用了条件期望. 最后一行利用了对凸函数 $f(x) = \frac{1}{x}$ 的詹森不等式. ■

可以用定理 6.10 给出定理 6.8 的另一个证明. 特别地, 如果 $p=f(n)=\omega(n^{-2/3})$, 则用定理 6.10 证明对任意实常数 $\varepsilon>0$ 及充分大的 n , 取自 $G_{n,p}$ 的一个随机图没有 4 个或更多顶点的团的概率小于 ε .

如定理 6.8 证明的那样, 令 $X = \sum_{i=1}^{\binom{n}{4}} X_i$, 其中如果 4 个顶点的子集 C_i 是一个 4 团, 则 X_i 是

1, 否则为 0. 对某个特殊的 X_j , 我们有 $\Pr(X_j=1)=p^6$. 利用期望的线性性, 计算

$$E[X | X_j = 1] = E\left[\sum_{i=1}^{\binom{n}{4}} X_i | X_j = 1\right] = \sum_{i=1}^{\binom{n}{4}} E[X_i | X_j = 1].$$

在 $X_j=1$ 的条件下, 对 0-1 随机变量, 我们现在利用下式计算 $E[X_i | X_j=1]$,

$$E[X_i | X_j = 1] = \Pr(X_i = 1 | X_j = 1).$$

存在 $\binom{n-4}{4}$ 个与 C_j 不相交的顶点集合 C_i , 每个相应的 X_i 以概率 p^6 为 1. 类似地, 对 $4\binom{n-4}{3}$ 个与 C_j 有一个公共顶点的集合 C_i , 以概率 p^6 有 $X_i=1$.

在其余情况, 对与 C_j 有两个公共顶点的 $6\binom{n-4}{2}$ 个集合 C_i , 有 $\Pr(X_i=1 | X_j=1)=p^5$, 对与 C_j 有三个公共顶点的 $4\binom{n-4}{1}$ 个集合 C_i , 有 $\Pr(X_i=1 | X_j=1)=p^3$. 总之, 我们有

$$\begin{aligned} E[X | X_j = 1] &= \sum_{i=1}^{\binom{n}{4}} E[X_i | X_j = 1] \\ &= 1 + \binom{n-4}{4} p^6 + 4\binom{n-4}{3} p^6 + 6\binom{n-4}{2} p^5 + 4\binom{n-4}{1} p^3. \end{aligned}$$

由定理 6.10 得

$$\Pr(X > 0) \geq \frac{\binom{n}{4} p^6}{1 + \binom{n-4}{4} p^6 + 4\binom{n-4}{3} p^6 + 6\binom{n-4}{2} p^5 + 4\binom{n-4}{1} p^3}.$$

当 $p=f(n)=\omega(n^{-2/3})$ 时, 随 n 增大, 上式趋于 1.

6.7 洛瓦兹局部引理

在应用概率方法时, 最漂亮且最有用的工具之一是洛瓦兹局部引理. 设 E_1, \dots, E_n 是某个概率空间中的坏事件集合, 我们希望证明在样本空间中, 存在一个不包含在任意坏事件中的元素.

如果事件相互独立, 证明是容易的. 回忆事件 E_1, \dots, E_n 相互独立, 当且仅当对任意的子集 $J \subseteq [1, n]$,

$$\Pr\left(\bigcap_{i \in I} E_i\right) = \prod_{i \in I} \Pr(E_i).$$

而且, 如果 E_1, \dots, E_n 相互独立, 那么 $\bar{E}_1, \dots, \bar{E}_n$ 也相互独立. (这已留作练习 1.20.) 如果对所有的 i , $\Pr(E_i) < 1$, 那么

$$\Pr\left(\bigcap_{i=1}^n \bar{E}_i\right) = \prod_{i=1}^n \Pr(\bar{E}_i) > 0,$$

因此存在样本空间的一个元素, 它不包含在任意坏事件中.

在许多问题中, 要求相互独立太苛刻了, 洛瓦兹局部引理将前面的证明推广到 n 个事件不是相互独立而是有限相关的情况. 特别地, 由相互独立的定义, 我们称事件 E 与事件 E_1, \dots, E_n 相互独立, 如果对任意子集 $I \subseteq [1, n]$,

$$\Pr\left(E \mid \bigcap_{j \in I} E_j\right) = \Pr(E).$$

事件间的相关性可以用一个相关图来表示.

定义 6.1 事件 E_1, \dots, E_n 的集合的相关图是图 $G = (V, E)$, 满足 $V = \{1, \dots, n\}$, 且对 $i = 1, \dots, n$, 事件 E_i 与事件 $\{E_j \mid (i, j) \notin E\}$ 相互独立.

我们首先讨论一个特殊情况, 即对称形式的洛瓦兹局部引理, 这是比较直观且对大多数算法应用也已足够了.

定理 6.11 [洛瓦兹局部引理] 设 E_1, \dots, E_n 是一个事件集合, 假定以下条件成立:

1. 对于所有 i , $\Pr(E_i) \leq p$.
2. 由 E_1, \dots, E_n 给出的相关图的次不超过 d .
3. $4dp \leq 1$.

那么

$$\Pr\left(\bigcap_{i=1}^n \bar{E}_i\right) > 0.$$

证明 记 $S \subseteq [1, \dots, n]$, 我们对 $s = 0, \dots, n-1$ 用归纳法证明, 如果 $|S| \leq s$, 那么对于所有的 $k \notin S$, 有

$$\Pr(E_k \mid \bigcap_{j \in S} \bar{E}_j) \leq 2p.$$

为了当 S 非空时这个表达式有意义, 我们需要 $\Pr\left(\bigcap_{j \in S} \bar{E}_j\right) > 0$.

由假定 $\Pr(E_k) \leq p$ 可知, 基础情况 $s = 0$ 成立. 为执行归纳步骤, 我们首先证明 $\Pr\left(\bigcap_{j \in S} \bar{E}_j\right) > 0$. 由于 $\Pr(\bar{E}_j) \geq 1 - p > 0$, 所以当 $s = 1$ 时, 这是成立的. 对 $s > 1$, 不失一般性, 设 $S = \{1, \dots, s\}$, 那么

$$\begin{aligned} \Pr\left(\bigcap_{i=1}^s \bar{E}_i\right) &= \prod_{i=1}^s \Pr(\bar{E}_i \mid \bigcap_{j=1}^{i-1} \bar{E}_j) \\ &= \prod_{i=1}^s (1 - \Pr(E_i \mid \bigcap_{j=1}^{i-1} \bar{E}_j)) \end{aligned}$$



$$\geq \prod_{i=1}^s (1 - 2p) > 0.$$

在得到最后一行时，我们用到了归纳假设。

对于归纳法的其余部分，令 $S_1 = \{j \in S \mid (k, j) \in E\}$ ， $S_2 = S - S_1$ 。如果 $S_2 = S$ ，那么 E_k 与 $\bar{E}_i (i \in S)$ 是相互独立的，且

$$\Pr(E_k \mid \bigcap_{j \in S} \bar{E}_j) = \Pr(E_k) \leq p.$$

继续考虑 $|S_2| < s$ 的情况，引进下面的记号是有用的。设 F_s 是由

[139]

$$F_s = \bigcap_{j \in S} \bar{E}_j$$

定义的，类似地定义 F_{s_1} 和 F_{s_2} ，注意 $F_s = F_{s_1} \cap F_{s_2}$ 。

由条件概率的定义可知

$$\Pr(E_k \mid F_s) = \frac{\Pr(E_k \cap F_s)}{\Pr(F_s)}. \quad (6.4)$$

将条件概率的定义应用于(6.4)的分子，得到

$$\begin{aligned} \Pr(E_k \cap F_s) &= \Pr(E_k \cap F_{s_1} \cap F_{s_2}) \\ &= \Pr(E_k \cap F_{s_1} \mid F_{s_2}) \Pr(F_{s_2}). \end{aligned}$$

分母可以写成

$$\begin{aligned} \Pr(F_s) &= \Pr(F_{s_1} \cap F_{s_2}) \\ &= \Pr(F_{s_1} \mid F_{s_2}) \Pr(F_{s_2}). \end{aligned}$$

消去公因子，我们已经证明公因子不为零。得到

$$\Pr(E_k \mid F_s) = \frac{\Pr(E_k \cap F_{s_1} \mid F_{s_2})}{\Pr(F_{s_1} \mid F_{s_2})}. \quad (6.5)$$

注意即使在 $S_2 = \emptyset$ 时，(6.5)式也成立。

因为事件交的概率不超过其中任一事件的概率，且 E_k 与 S_2 中的事件独立，所以可以给出(6.5)中分子的界为

$$\Pr(E_k \cap F_{s_1} \mid F_{s_2}) \leq \Pr(E_k \mid F_{s_2}) = \Pr(E_k) \leq p.$$

因为 $|S_2| < |S| = s$ ，将归纳假设用于

$$\Pr(E_i \mid F_{s_2}) = \Pr(E_i \mid \bigcap_{j \in S_2} \bar{E}_j).$$

再利用 $|S_1| \leq d$ 的事实，我们给出(6.5)的分母的下界如下：

$$\begin{aligned} \Pr(F_{s_1} \mid F_{s_2}) &= \Pr\left(\bigcap_{i \in S_1} \bar{E}_i \mid \bigcap_{j \in S_2} \bar{E}_j\right) \\ &\geq 1 - \sum_{i \in S_1} \Pr(E_i \mid \bigcap_{j \in S_2} \bar{E}_j) \\ &\geq 1 - \sum_{i \in S_1} 2p \end{aligned}$$



$$\begin{aligned} &\geq 1 - 2pd \\ &\geq \frac{1}{2}. \end{aligned}$$

[140]

利用分子的上界及分母的下界, 我们证明了归纳:

$$\begin{aligned} \Pr(E_k | F_s) &= \frac{\Pr(E_k \cap F_{s_1} | F_{s_2})}{\Pr(F_{s_1} | F_{s_2})} \\ &\leq \frac{p}{1/2} = 2p. \end{aligned}$$

由于

$$\begin{aligned} \Pr\left(\bigcap_{i=1}^n \bar{E}_i\right) &= \prod_{i=1}^n \Pr\left(\bar{E}_i \mid \bigcap_{j=1}^{i-1} \bar{E}_j\right) \\ &= \prod_{i=1}^n \left(1 - \Pr\left(E_i \mid \bigcap_{j=1}^{i-1} \bar{E}_j\right)\right) \\ &\geq \prod_{i=1}^n (1 - 2p) > 0, \end{aligned}$$

定理成立. ■

6.7.1 应用: 边不相交的路径

假设 n 对用户需要利用一个给定网络上的边不相交的路径通信, 每对 $i=1, \dots, n$ 可以从 m 条路径集合 F_i 中选择一条路径. 我们利用洛瓦兹局部引理证明, 如果可能的路径不具有太多的共同边, 那么存在一种选取联结 n 对用户的 n 条边不相交路径的方法.

定理 6.12 如果 F_i 中任一路径与 F_j 中不多于 k 条的路径具有共同边, 其中 $i \neq j$, 且 $\frac{8nk}{m} \leq 1$, 那么存在一种选取联结 n 对子的 n 条边不相交路径的方法.

证明 考虑由从 m 条路径集合中独立、均匀随机选取一条路径的每一个对子所定义的概率空间. 定义 $E_{i,j}$ 表示对子 i 和 j 选取的路径至少具有一条共同边的事件. 因为 F_i 中的一条路径与 F_j 中不多于 k 条的路径具有共同边, 所以

$$p = \Pr(E_{i,j}) \leq \frac{k}{m}.$$

设 d 是相关图的次. 因为当 $i' \notin \{i, j\}$, $j' \notin \{i, j\}$ 时, 事件 $E_{i,j}$ 与所有事件 $E_{i',j'}$ 独立, 我们有 $d < 2n$. 因为

$$4dp < \frac{8nk}{m} \leq 1,$$

洛瓦兹局部引理的所有条件都满足, 证明了

$$\Pr\left(\bigcap_{i \neq j} \bar{E}_{i,j}\right) > 0.$$

因此, 存在路径的选择使得 n 条路径是边不相交的. ■

[141]

6.7.2 应用：可满足性

作为第二个例子，我们回到可满足性问题。对于 k 可满足性 (k -SAT) 问题，公式限制为每个子句恰有 k 个文字，仍然假定没有子句包含一个文字及其否定，因为这些子句是平凡的。我们证明任意一个 k -SAT 公式（其中没有变量出现在太多的子句中）有一个满足的赋值。

定理 6.13 如果在 k -SAT 公式中没有变量出现在多于 $T = \frac{2^k}{4k}$ 个子句中，那么公式有一个满足的赋值。

证明 考虑由给定的对变量的一个随机赋值所定义的概率空间。对 $i=1, \dots, m$ ，设 E_i 表示由于随机赋值第 i 子句不满足事件。因为每个子句有 k 个文字，

$$\Pr(E_i) = 2^{-k}.$$

事件 E_i 与所有与子句 i 不具有共同变量的子句有关的事件相互独立。因为子句 i 中 k 个变量中每一个都可能出现在不多于 $T = \frac{2^k}{4k}$ 个子句中，相关图的次的界为 $d \leq kT \leq 2^{k-2}$ 。

在这种情况下，

$$4dp \leq 4 \cdot 2^{k-2} 2^{-k} \leq 1.$$

所以，我们可以利用洛瓦兹局部引理得到结论

$$\Pr\left(\bigcap_{i=1}^m \bar{E}_i\right) > 0;$$

因此存在公式的一个满足的赋值。 ■

6.8 利用洛瓦兹局部引理的显式构造

洛瓦兹局部引理证明了一个适当定义的样本空间中，随机元素有满足我们要求的非零概率。但是，这个概率对基于简单抽样的算法可能太小了。在找到一个满足我们要求的元素之前所需的抽样对象的个数可能是关于问题大小的指数级的。

在一些有意义的应用中，洛瓦兹局部引理的现有结果可用于导出有效的构造算法。虽然在具体应用中细节有所不同，但所有已知算法都是基于一般的两阶段方案。在第一阶段，问题的变量子集赋予随机值，剩下的变量推迟到第二阶段。在第一阶段赋值的随机变量的子集是这样选取的：

[142]

1. 利用局部引理，可以证明在第一阶段固定的随机部分解可推广为问题的全部解，而无需修改第一阶段固定的任意变量。

2. 由推迟到第二阶段的变量定义的事件间的相关图 H 以大的概率只有少量的连通分支。

当相关图由连通分支组成时，得到一个分支变量的解与其他分支无关。所以两阶段算法的第一阶段将原问题分成较小的子问题，然后每个较小的子问题可以在第二阶段用穷举搜索法独立地解决。

6.8.1 应用：可满足性算法

我们通过寻找 k -SAT 公式的满足赋值的算法来演示这种技术。显式构造结果显著地弱于上节所证明的现有结果。特别是在 k 是常数的情况，我们得到了多项式时间算法。这个结果

仍然是有意义的, 这是因为 $k \geq 3$ 时, k -可满足性问题是 NP 完全的. 为记号方便起见, 这里我们只处理 k 是偶数常数的情况; k 为奇数常数的情况是类似的.

考虑一个 k -SAT 公式 \mathcal{F} , k 是偶数常数, 使得对在证明中确定的某个常数 $\alpha > 0$, 每个变量出现在不多于 $T = 2^{\alpha k}$ 个子句中. 设 x_1, \dots, x_ℓ 是 ℓ 个变量, C_1, \dots, C_m 是 \mathcal{F} 的 m 个子句.

按照 6.8 节中提出的步骤, 求关于 \mathcal{F} 的满足赋值的算法有两个阶段. 在第一阶段, 固定某些变量, 剩余变量延迟到第二阶段. 在执行第一阶段时, 如果下面两个条件成立, 我们称子句 C_i 是危险的.

1. 子句 C_i 中的 $\frac{k}{2}$ 个文字被固定.
2. C_i 还不是满足的.

可以如下描述阶段 I. 依次考虑变量 x_1, \dots, x_ℓ , 如果 x_i 不在危险的子句中, 则独立且均匀随机地将其赋予一个 $\{0, 1\}$ 中的值.

一个子句是生存子句, 如果对阶段 I 中固定的变量不是满足的. 注意生存子句有不多于在第一阶段固定的 $\frac{k}{2}$ 个变量. 一个延迟变量是第一阶段没有赋值的变量. 在阶段 II, 我们用穷举搜索方法给延迟变量赋值, 并完成对公式的满足赋值.

在下面的两个引理中, 我们展示了

1. 在阶段 I 计算的部分解可以推广为 \mathcal{F} 的完全满足的赋值.
2. 以大的概率, 用关于 m 的多项式时间完成阶段 II 的穷举搜索.

引理 6.14 存在一个延迟变量的赋值, 使得所有生存子句是满足的.

证明 设 $H = (V, E)$ 是 m 个结点的图, 其中 $V = \{1, \dots, m\}$, 设 $(i, j) \in E$ 当且仅当 $C_i \cap C_j \neq \emptyset$, 即 H 是原问题的相关图. 设 $H' = (V', E')$ 是一个图, 其中 $V' \subseteq V, E' \subseteq E$, 使得 (a) $i \in V'$ 当且仅当 C_i 是生存子句; (b) $(i, j) \in E'$ 当且仅当 C_i 和 C_j 共享一个延迟变量. 在下面的讨论中, 我们不区分结点 i 与子句 i .

考虑对每个延迟变量独立地赋以 $\{0, 1\}$ 中的随机值所定义的概率空间. 在阶段 I 对非延迟变量的赋值与对延迟变量的随机赋值一起, 定义了对所有 ℓ 个变量的一个赋值. 对 $i = 1, \dots, m$, 设 E_i 是生存子句 C_i 不满足这个赋值的事件. 将事件 E_i 与 V' 中的结点 i 相关联, 那么图 H' 是这个事件集合的相关图.

一个生存子句至少有 $\frac{k}{2}$ 个延迟变量, 所以

$$p = \Pr(E_i) \leq 2^{-k/2}.$$

一个变量出现在不多于 T 个子句中, 所以, 相关图的次不超过

$$d = kT \leq k2^{\alpha k}.$$

对一个充分小的常数 $\alpha > 0$,

$$4dp = 4k2^{\alpha k}2^{-k/2} \leq 1,$$

故由洛瓦兹局部引理, 存在对延迟变量的赋值——与阶段 I 对变量的赋值一起——满足公式.



对阶段 I 中变量子集的赋值将问题划分成与 m 个独立子公式一样多, 使得每个延迟变量只出现在一个子公式中. 子公式由 H' 的连通分支给出. 如果可以证明 H' 的每个连通分支的大小为 $O(\log m)$, 那么每个子公式将有多于 $O(k \log m)$ 个延迟变量. 对在每个子公式中所有变量的所有可能赋值的穷举搜索就可以以多项式时间进行. 因此, 我们关注下面的引理.

引理 6.15 以概率 $1 - o(1)$, H' 中的所有连通分支的大小为 $O(\log m)$.

证明 考虑 H 中 r 个顶点的连通分支 R . 如果 R 是一个 H' 中的连通分支, 那么它的所有 r 个结点是生存子句. 一个生存子句或者是危险子句, 或者与危险子句至少共享一个延迟变量 (即它有一个 H' 中的邻点是危险子句). 一个已给子句是危险的概率至多为 $2^{-\frac{1}{2}}$, 这是因为在阶段 I 恰好有 $\frac{k}{2}$ 个变量给定了随机值, 而这些值都不满足子句. 一个给定子句生存的概率是这个子句或者它的直接邻点中至少有一个是危险的概率, 这不超过

$$(d+1)2^{-k/2},$$

其中仍是 $d = KT > 1$.

如果单个子句的生存是独立事件, 那么我们将处于极好的状态. 但是, 从这里的叙述中, 这样的事件明显地不是独立的. 我们识别 R 中的顶点子集, 使得由这个子集的顶点表示的子句的生存是独立事件. H 中连通分支 R 的 4-树 S 定义如下:

1. S 是有根树.
2. S 中任两个结点在 H 中的距离至少为 4.
3. 只在 H 中距离恰好为 4 的两个结点之间, 在 S 中有一条边.
4. R 中的任意结点或者在 S 中, 或者与 S 中的一个结点距离为 3, 或者更小.

考虑 4-树中的结点是有用的, 这是因为一个 4-树中的结点 u 生存的事件与 4-树中其他结点 v 生存的事件实际上是独立的. 任何可以使子句 u 生存的子句与任何可以使子句 v 生存的子句的距离至少为 2. 距离为 2 的子句不共享变量, 因此, 它们是危险的事件是独立的. 我们可以利用这种独立性得出结论, 对任意的 4-树 S , 在 4-树中结点生存的概率至多是

$$((d+1)2^{-k/2})^{|S|}.$$

连通分支 R 的最大 4-树 S 是有最大可能顶点个数的 4-树. 因为相关图的次不超过 d , 存在不多于

$$d + d(d-1) + d(d-1)(d-1) \leq d^3 - 1$$

个与任一已知顶点距离为 3 或更小的结点. 所以我们断定 R 的最大 4-树必至少有 $\frac{r}{d^3}$ 个顶点. 否则, 当考虑最大 4-树 S 的顶点及所有与这些顶点距离为 3 或更小的邻点时, 我们得到少于 r 个顶点. 因此, 必存在一个与 S 中所有顶点距离至少为 4 的顶点. 如果这个顶点与 S 中某个顶点距离恰好为 4, 那么可以将它加到 S 中, 即 S 不是最大的, 产生矛盾. 如果它与 S 中所有顶点的距离大于 4, 考虑任意使它接近 S 的路径, 这样的路径最后必经过与 S 中所有顶点距离至少为 4 且与 S 中某个顶点距离为 4 的一个顶点, 仍与 S 的最大性矛盾.

为证明对某个常数 c , 以概率 $1 - o(1)$ 在 H' 中不存在大小为 $r \geq c \log_2 m$ 的连通分支 R , 我

们证明不存在以概率 $1 - o(1)$ 生存的大小为 $\frac{r}{d}$ 的 H 的 4-树. 因为一个生存的连通分支 R 有一个大小为 $\frac{r}{d}$ 的最大 4-树, 缺少这样一个 4-树意味着缺少这样一个分支. [145]

我们需要数出 H 中大小为 $s = \frac{r}{d}$ 的 4-树的个数. 可以用 m 种方法选取 4-树的根. 一个根为 v 的树由欧拉旅行唯一确定, 即始点和终点在 v , 通过树的每条边两次, 每个方向一次. 因为 S 的边表示 H 中长度为 4 的路径, 在 4-树的每个顶点, 欧拉路能以 d^4 种不同方法继续, 所以 H 中大小为 $s = \frac{r}{d}$ 的 4-树的个数不超过

$$m(d^4)^{2s} = md^{8r/d^4}.$$

在 H' 中每个这种 4-树的结点生存的概率至多为

$$((d+1)2^{-k/2})^s = ((d+1)2^{-k/2})^{r/d^4}.$$

因此 H' 有一个大小为 r 的连通分支的概率不超过

$$md^{8r/d^4} ((d+1)2^{-k/2})^{r/d^4} \leq m2^{(k-d^4)(8\alpha+2\alpha-1/2)} = o(1),$$

其中 $r \geq c \log_2 m$, c 是适当的常数, $\alpha > 0$ 是充分小的常数. ■

这样, 我们有以下定理.

定理 6.16 考虑有 m 个子句的 k -SAT 公式, 其中 k 为偶数常数, 且每个变量出现在直到 2^{k-1} 个子句中, $\alpha > 0$ 是充分小的常数. 那么存在一个算法, 以关于 m 的多项式期望时间找到公式的满足赋值.

证明 如我们已经描述的那样, 如果第一阶段将问题分成只涉及 $O(k \log m)$ 个变量的子公式, 那么可以用穷举法求解每个子公式, 以关于 m 的多项式时间求得一个解. 第一阶段将问题适当地划分的概率为 $1 - o(1)$, 所以在得到一个好的划分以前, 需要平均地运行阶段 I 一个不变的常数时间, 定理成立. ■

6.9 洛瓦兹局部引理: 一般情况

为完全起见, 我们给出洛瓦兹局部引理的一般情况的叙述和证明.

定理 6.17 设 E_1, \dots, E_n 是任意概率空间中的一个事件集, $G = (E, V)$ 是这些事件的相关图, 假设存在 $x_1, \dots, x_n \in [0, 1]$, 使得对所有的 $1 \leq i \leq n$, 有

$$\Pr(E_i) \leq x_i \prod_{(i,j) \in E} (1 - x_j).$$

那么

$$\Pr\left(\bigcap_{i=1}^n \bar{E}_i\right) \geq \prod_{i=1}^n (1 - x_i).$$

证明 设 $S \subseteq \{1, \dots, n\}$, 我们用关于 $s = 0, \dots, n$ 的归纳法证明, 如果 $|S| \leq s$, 那么对所有的 k , 有

$$\Pr\left(E_k \mid \bigcap_{j \in S} \bar{E}_j\right) \leq x_k.$$

如局部引理的对称情况那样, 必须当心条件概率应是恰当定义的. 利用与对称情况相同的方

法, 这是成立的, 所以只需集中考虑归纳法的其余部分.

由假设

$$\Pr(E_k) \leq x_k \prod_{(k,j) \in E} (1 - x_j) \leq x_k,$$

$s=0$ 的基本情况是成立的.

对归纳步骤, 设 $S_1 = \{j \in S \mid (k, j) \in E\}$, $S_2 = S - S_1$. 如果 $S_2 = S$, 那么 E_k 与事件 $\bar{E}_i (i \in S)$ 相互独立, 且

$$\Pr(E_k \mid \bigcap_{j \in S} \bar{E}_j) = \Pr(E_k) \leq x_k.$$

继续考虑 $|S_2| < s$ 的情况, 仍利用记号

$$F_s = \bigcap_{j \in S} \bar{E}_j$$

并类似地定义 F_{S_1} 及 F_{S_2} , 使得 $F_s = F_{S_1} \cap F_{S_2}$.

由条件概率的定义可知

$$\Pr(E_k \mid F_s) = \frac{\Pr(E_k \cap F_s)}{\Pr(F_s)}. \quad (6.6)$$

再次由条件概率的定义, (6.6) 的分子可写成

$$\Pr(E_k \cap F_s) = \Pr(E_k \cap F_{S_1} \mid F_{S_2}) \Pr(F_{S_2}),$$

分母可写成

$$\Pr(F_s) = \Pr(F_{S_1} \mid F_{S_2}) \Pr(F_{S_2}).$$

消去公因子得

$$\Pr(E_k \mid F_s) = \frac{\Pr(E_k \cap F_{S_1} \mid F_{S_2})}{\Pr(F_{S_1} \mid F_{S_2})}. \quad (6.7)$$

因为事件交的概率不超过每个事件的概率, 还因为 E_k 与 S_2 中的事件独立, 我们可以用

147

$$\Pr(E_k \cap F_{S_1} \mid F_{S_2}) \leq \Pr(E_k \mid F_{S_2}) = \Pr(E_k) \leq x_k \prod_{(k,j) \in E} (1 - x_j)$$

界定(6.7)的分子.

为了界定(6.7)的分母, 记 $S_1 = \{j_1, \dots, j_r\}$, 由归纳假设, 我们有

$$\begin{aligned} \Pr(F_{S_1} \mid F_{S_2}) &= \Pr\left(\bigcap_{j \in S_1} \bar{E}_j \mid \bigcap_{j \in S_2} \bar{E}_j\right) \\ &= \prod_{i=1}^r \left(1 - \Pr\left(E_{j_i} \mid \left(\bigcap_{\mu=1}^{i-1} \bar{E}_{j_\mu}\right) \cap \left(\bigcap_{j \in S_2} \bar{E}_j\right)\right)\right) \\ &\geq \prod_{i=1}^r (1 - x_{j_i}) \\ &\geq \prod_{(k,j) \in E} (1 - x_j). \end{aligned}$$

利用分子的上界及分母的下界, 可以证明归纳假设:

$$\begin{aligned}
 \Pr(E_k \mid \bigcap_{j \in S} \bar{E}_j) &= \Pr(E_k \mid F_S) \\
 &= \frac{\Pr(E_k \cap F_{S_1} \mid F_{S_2})}{\Pr(F_{S_1} \mid F_{S_2})} \\
 &\leq \frac{x_k \prod_{(i,j) \in E} (1-x_j)}{\prod_{(i,j) \in E} (1-x_j)} \\
 &= x_k.
 \end{aligned}$$

现在由

$$\begin{aligned}
 \Pr(\bar{E}_1, \dots, \bar{E}_n) &= \prod_{i=1}^n \Pr(\bar{E}_i \mid \bar{E}_1, \dots, \bar{E}_{i-1}) \\
 &= \prod_{i=1}^n (1 - \Pr(E_i \mid \bar{E}_1, \dots, \bar{E}_{i-1})) \\
 &\geq \prod_{i=1}^n (1 - x_i) > 0
 \end{aligned}$$

可知定理成立. ■

练习

- 6.1 考虑一个有 m 个子句的 SAT 实例, 其中每个子句恰有 k 个文字.
- 给出寻找至少有 $m(1-2^{-k})$ 个子句满足赋值的 Las Vegas 算法, 并分析它的期望运行时间.
 - 利用条件期望方法, 给出随机化算法的消除随机性.
- 6.2 (a) 对每个整数 n , 证明存在用两种颜色对完全图 K_n 的边的一种着色法, 使得 K_n 的单色副本总数至多为 $\binom{n}{4} 2^{-5}$ 个.
- (b) 给出一个寻找 K_n 的至多有 $\binom{n}{4} 2^{-5}$ 个单色副本的着色法的随机化算法, 以关于 n 的多项式的期望时间运行.
- (c) 说明如何利用条件期望的方法构造一种用多项式时间的确定性着色法.
- 6.3 给定有 n 个顶点的无向图 $G = (V, E)$, 考虑以下生成独立集的方法. 已知顶点的一个排列 σ , 定义顶点的一个子集 $S(\sigma)$ 如下: 对每个顶点 i , $i \in S(\sigma)$ 当且仅当没有 i 的邻点 j 依排列 σ 的次序在 i 的前面.
- 证明每个 $S(\sigma)$ 是 G 中的独立集.
 - 提出一个自然的随机化算法来产生 σ , 对此可以证明 $S(\sigma)$ 的期望基为

$$\sum_{i=1}^n \frac{1}{d_i + 1},$$

其中 d_i 表示顶点 i 的次.

(c) 证明 G 有一个大小至少为 $\sum_{i=1}^n \frac{1}{d_i + 1}$ 的独立集.

- 6.4 考虑下面的两人游戏. 开始时将 k 个代价券放置在整数直线 $[0, n]$ 的数 0 处. 每一轮, 由称为挑选者的一人选择代价券的两个不相交的非空集合 A 和 B (集合 A 及 B 不必包括所有其余的代价券, 只需要是不相交的即可). 另一人称为移动者, 将一个集合中的所有代价券从台板上取走. 另一集合中的代价券全都从它们当前的位置沿着整数直线向上移动一个间隔. 如果有任意代价券到达 n , 挑选者获胜. 如果挑选者以一张没有到达 n 的代价券而结束游戏, 移动者获胜.

(a) 当 $k \geq 2^n$ 时, 给出一个挑选者的获胜策略.

(b) 利用概率方法证明, 当 $k < 2^n$ 时, 必存在一个移动者的获胜策略.

(c) 解释如何利用条件期望的方法消去 $k < 2^n$ 时移动者获胜策略的随机性.

- 6.5 我们已经用概率方法证明了, 如果图 G 有 n 个结点和 m 条边, 那么存在将 n 个结点分成集合 A 和 B 的划分, 使得至少有 $\frac{m}{2}$ 条边横跨划分. 稍微改善这个结果: 证明存在一种划分, 使得至少有 $\frac{mn}{2n-1}$ 条边横跨划分.

- 6.6 我们可以将求最大割问题推广到求最大 k -割. 一个 k -割是将顶点分成 k 个不相交集的划分, 割值是从 k 个集合中的某个到另一个的所有横跨边的权. 在 6.2.1 节, 我们考虑了所有边有相同权 1 的 2-割, 用概率方法证明了任意有 m 条边的图 G 有一个值至少为 $\frac{m}{2}$ 的割. 推广这种方法证明任意有 m 条边的图 G 有一个值至少为 $\frac{(k-1)m}{k}$ 的 k -割. 说明如何利用消去随机性方法 (由 6.3 节的论证) 给出寻找这样一个割的确定性算法.

- 6.7 超图 H 是一个集合对 (V, E) , 其中 V 是顶点集合, E 是超边集合. E 中的每一条超边是 V 的子集. 特别地, r -一致超图是每条边大小都为 r 的超图. 例如, 2-一致超图就是一个标准图. 超图 H 中的控制集是一个顶点集合 $S \subset V$, 对每条边 $e \in E$, 满足 $e \cap S \neq \emptyset$, 即 S 抵达超图中的每条边.

设 $H = (V, E)$ 是有 n 个顶点和 m 条边的 r -一致超图. 证明对每个实数 $0 \leq p \leq 1$, 存在大小至多为 $np + (1-p)^r m$ 的控制集. 并证明存在一个大小至多为 $(m + n \ln r)/r$ 的控制集.

- 6.8 对每个整数 n , 证明存在用两种颜色为 K_n 边着色的方法, 使得当

$$x = n - \binom{n}{k} 2^{-\binom{n}{k}}$$

时, 不存在大小为 k 的单色团 (提示: 先用两种颜色为 K_n 边着色, 然后再修补).

- 6.9 竞赛图是一个 n 个顶点的图, 在每对顶点之间恰有一条有向边. 如果顶点代表选手, 那么每条边可以作为两个选手之间的比赛结果: 边指向获胜者. 一个排名是 n 个选手从好

到坏(不容许出现结)的次序. 给定一个竞赛图的结果, 人们可能希望确定选手的排名. 排名称为与 y 到 x 的有向边不一致的. 如果按此排名, y 在 x 的前面(因为在竞赛图中, x 战胜了 y).

(a) 证明对每个竞赛图, 存在至多与 50% 的边不一致的排名.

(b) 证明对充分大的 n , 存在一个竞赛图, 使得每个排名与这个竞赛图中至少 49% 的边不一致.

6.10 $\{1, 2, \dots, n\}$ 的一个子集族 \mathcal{F} 称为反链, 如果不存在 \mathcal{F} 中的一对集合 A 和 B 满足 $A \subset B$.

(a) 给出一个 \mathcal{F} 的例子, 其中 $|\mathcal{F}| = \binom{n}{\lfloor n/2 \rfloor}$.

(b) 设 f_k 是 \mathcal{F} 中大小为 k 的集合个数, 证明

$$\sum_{k=0}^n \frac{f_k}{\binom{n}{k}} \leq 1.$$

(提示: 选取一个从数字 1 到 n 的随机排列, 令 $X_i = 1$, 如果在你的排列中, 前 k 个数产生一个 \mathcal{F} 中的集合. 如果 $X = \sum_{k=0}^n X_k$, 关于 X , 你能够说些什么吗?)

(c) 证明对任意反链 \mathcal{F} , $|\mathcal{F}| \leq \binom{n}{n/2}$.

6.11 在 6.5.1 节为了演示二阶矩方法, 我们给出了随机图中 4-团个数的方差的界. 说明如何利用练习 3.9 中的等式直接计算方差: 对伯努利随机变量之和 $X = \sum_{i=0}^n X_i$,

$$E[X^2] = \sum_{i=1}^n \Pr(X_i = 1) E[X | X_i = 1].$$

6.12 考虑 $G_{n,p}$ 中的图是否有不变大小 k 的团的问题. 对这个性质, 建立一个合适的阈函数, 推广用于大小为 k 的团的方法, 或用二阶矩方法, 或用条件期望不等式, 证明你的阈函数对大小为 5 的团是正确的.

6.13 考虑 $G_{n,p}$ 中的图, $p = c \ln n/n$. 利用二阶矩方法或条件期望不等式证明, 如果 $c < 1$, 那么对任意常数 $\varepsilon > 0$ 及充分大的 n , 图至少以 $1 - \varepsilon$ 的概率有孤立顶点.

6.14 考虑 $G_{n,p}$ 中的图, $p = \frac{1}{n}$. 设 X 是图中三角形的个数, 其中三角形是有三条边的团. 证明

$$\Pr(X \geq 1) \leq 1/6$$

及

$$\lim_{n \rightarrow \infty} \Pr(X \geq 1) \geq 1/7.$$

(提示: 利用条件期望不等式.)

6.15 考虑 4.4 节的集合平衡问题. 我们断言, 对 \bar{b} 的任意选取, 存在 $n \times n$ 矩阵 A , 对此 $\|A \bar{b}\|_{\infty}$ 为 $\Omega(\sqrt{n})$. 为方便起见, 假定 n 是偶数.

(a) 我们已在 (5.5) 式证明了

$$n! \leq e\sqrt{n} \left(\frac{n}{e}\right)^n.$$

利用类似的思想, 对某个正常数 a , 证明

$$n! \geq a\sqrt{n} \left(\frac{n}{e}\right)^n.$$

(b) 设 $b_1, b_2, \dots, b_{m/2}$ 全都等于 1, 而 $b_{\frac{m}{2}+1}, b_{\frac{m}{2}+2}, \dots, b_m$ 全都等于 -1. 设 Y_1, Y_2, \dots, Y_m 每个都是从 $\{0, 1\}$ 中独立地且均匀随机地选取的. 证明存在一个正常数 c , 使得对充分大的 m ,

$$\Pr\left(\left|\sum_{i=1}^m b_i Y_i\right| > c\sqrt{m}\right) > \frac{1}{2}.$$

(提示: 考虑等于 1 的 Y_i 个数的条件.)

(c) 设 b_1, b_2, \dots, b_m 每个可以等于 1 或 -1, Y_1, Y_2, \dots, Y_m 每个是从 $\{0, 1\}$ 中独立地且均匀随机地选取的. 证明存在一个正常数 c , 使得对充分大的 m ,

$$\Pr\left(\left|\sum_{i=1}^m b_i Y_i\right| > c\sqrt{m}\right) > \frac{1}{2}.$$

(d) 证明存在一个矩阵 A , 使得对任意选取的 \bar{b} , $\|A \bar{b}\|_{\infty}$ 为 $\Omega(\sqrt{n})$.

6.16 利用洛瓦兹局部引理证明: 如果

$$4 \binom{k}{2} \binom{n}{k-2} 2^{1-\binom{k}{2}} \leq 1,$$

那么有可能用两种颜色对 K_n 的边着色, 使得没有单色 K_k 子图.

6.17 利用一般形式的洛瓦兹局部引理证明, 可以用较弱的条件 $ep(d+1) \leq 1$ 代替条件 $4dp \leq 1$ 来改善定理 6.11 的对称形式.

6.18 设 $G = (V, E)$ 是无向图, 假定每个 $v \in V$ 与一个 $8r$ 种颜色的集合 $S(v)$ 相关联, 其中 $r \geq 1$. 另外还假定对每个 $v \in V$ 及 $c \in S(v)$, 存在 v 的至多 r 个邻点 u , 使得 c 在 $S(u)$ 中. 证明存在 G 的适当着色, 对每个顶点 v 指派一种来自它的类 $S(v)$ 中的颜色, 使得对任意边 $(u, v) \in E$, 指派给 u 和 v 的颜色是不同的. 可以令 $A_{u,v}$ 是 u 和 v 都用颜色 c 来着色的事件, 然后考虑这样的事件族.

[151]

[152]

乎
能
PDG

第7章 马尔可夫链及随机游动

马尔可夫链为随机过程建模提供了一个简单但有效的框架。我们从关于马尔可夫链的基本定义来开始这一章，然后说明马尔可夫链如何用于分析 2-SAT 及 3-SAT 问题的简单随机化算法，接着研究马尔可夫链的长期性能，阐明状态的分类及收敛于平稳分布的条件。我们用这些技术分析简单的赌博方案及离散形式的马尔可夫队列。对图上的随机游动的极限性态有特殊的兴趣。我们证明图的覆盖时间的界，并利用这个界对 $s-t$ 连通性问题提供一种简单的随机化算法。最后用马尔可夫链技术解决一个称为 Parrondo 悖论的微妙的问题。

7.1 马尔可夫链：定义及表示

随机过程 $X = \{X(t); t \in T\}$ 是随机变量的集合。指标 t 通常表示时间，此时，过程 X 是随时间而变化的随机变量 X 的取值模型。

我们称 $X(t)$ 是过程在时刻 t 的状态。以后，用 X_t 代替 $X(t)$ 。如果对所有 t ， X_t 从一个可数无穷集中取值，那么称 X 是一个离散空间过程。如果 X_t 是从一个有限集中取值，那么称过程是有限的。如果 T 是可数无穷集合，称 X 是一个离散时间过程。

本章我们着重于特殊类型的离散时间、离散空间随机过程 X_0, X_1, X_2, \dots ，其中 X_t 的值依赖于 X_{t-1} 的值，但不依赖于导致系统取那个值的状态序列。

定义 7.1 一个离散时间随机过程 X_0, X_1, X_2, \dots 是马尔可夫链，如果[⊖]

$$\Pr(X_t = a_t | X_{t-1} = a_{t-1}, X_{t-2} = a_{t-2}, \dots, X_0 = a_0) = \Pr(X_t = a_t | X_{t-1} = a_{t-1}) \\ = P_{a_{t-1}, a_t}$$

[153]

这个定义表示状态 X_t 依赖于前一状态 X_{t-1} ，但与过程如何到达状态 X_{t-1} 的特殊历史无关。这称为马尔可夫性或无记忆性。当我们说链是马尔可夫的，就意味着这个意思。注意马尔可夫性并不蕴涵 X_t 与随机变量 X_0, X_1, \dots, X_{t-2} 独立，它只蕴涵 X_t 与过去的任意相关性表现在 X_{t-1} 的取值中。

不失一般性，我们可以假定马尔可夫链的离散状态空间为 $\{0, 1, 2, \dots, n\}$ （或 $\{0, 1, 2, \dots\}$ ，如果可数无穷）。转移概率

$$P_{i,j} = \Pr(X_t = j | X_{t-1} = i)$$

是过程从 i 经一步移动到 j 的概率。马尔可夫性蕴涵马尔可夫链由一步转移矩阵

$$P = \begin{bmatrix} P_{0,0} & P_{0,1} & \cdots & P_{0,j} & \cdots \\ P_{1,0} & P_{1,1} & \cdots & P_{1,j} & \cdots \\ \vdots & \vdots & \ddots & \vdots & \ddots \\ P_{i,0} & P_{i,1} & \cdots & P_{i,j} & \cdots \\ \vdots & \vdots & \ddots & \vdots & \ddots \end{bmatrix}$$

[⊖] 严格说来，这是时间齐次的马尔可夫链，这将是我们在本书中研究的唯一类型。

唯一确定. 也就是位于第 i 行第 j 列的元素是转移概率 $P_{i,j}$, 因此对所有 i , $\sum_{j=0} P_{i,j} = 1$.

马尔可夫链转移矩阵的这种表示对计算过程的未来状态的分布是方便的. 设 $p_i(t)$ 表示过程在 t 时刻处于状态 i 的概率, $\bar{p}(t) = (p_0(t), p_1(t), p_2(t), \dots)$ 是在 t 时刻给出链的状态分布的向量. 对在 $t-1$ 时刻的所有可能状态求和, 我们有

$$p_i(t) = \sum_{j=0} p_j(t-1)P_{j,i}$$

或[⊖]

$$\bar{p}(t) = \bar{p}(t-1)P.$$

我们将概率分布表示成一个行向量, 做乘法 $\bar{p}P$ 而不是 $P\bar{p}$, 这就与从分布 $\bar{p}(t-1)$ 出发并应用运算对象 P 到达分布 $\bar{p}(t)$ 的解释一致了.

对任意 $m \geq 0$, 我们将 m 步转移概率

$$P_{i,j}^m = \Pr(X_{t+m} = j | X_t = i)$$

定义为链从状态 i 经恰好 m 步到达状态 j 的概率.

在从 i 出发经 1 次转移的条件下, 我们有

$$P_{i,j}^m = \sum_{k=0} P_{i,k} P_{k,j}^{m-1}. \quad (7.1)$$

设 $P^{(m)}$ 是一个矩阵, 其元素为 m 步转移概率, 使得第 i 行第 j 列元素为 $P_{i,j}^m$. 那么, 由 (7.1) 式可得

$$P^{(m)} = P \cdot P^{(m-1)};$$

经关于 m 的归纳,

$$P^{(m)} = P^m.$$

所以, 对任意 $t \geq 0$ 及 $m \geq 1$,

$$\bar{p}(t+m) = \bar{p}(t)P^m.$$

马尔可夫链的另一种有用的表示是用一个有向的加权图 $D = (V, E, w)$. 图的顶点集合是链的状态集. 存在一条有向边 $(i, j) \in E$, 当且仅当 $P_{i,j} > 0$, 此时边 (i, j) 的权 $w(i, j)$ 由 $w(i, j) = P_{i,j}$ 给出. 自圈 (一条边开始和结束在同一顶点) 是允许的. 对每个 i , 我们仍要求 $\sum_{j:(i,j) \in E} w(i, j) = 1$. 一个由过程逗留过的状态序列表示为图上的一条有向路径. 过程沿着这条路径的概率是路径边的权的乘积.

图 7.1 给出了一个马尔可夫链的例子以及两种表示之间的对应. 我们考虑如何用每种表示法计算恰好经三步从状态 0 到状态 3 的概率. 在图上, 考虑所有恰好经三步从状态 0 到状态 3 的路径. 这样的路径只有 4 条: $0-1-0-3$, $0-1-3-3$, $0-3-1-3$, 及 $0-3-3-3$. 过程经过每一条这样路径的概率分别为 $3/32$, $1/96$, $1/16$ 及 $3/64$. 将这些概率相加, 求出总概率为 $41/192$. 另外, 可以简单地计算

⊖ 向量运算以自然的方式推广到可数个元素的情况.

$$P^3 = \begin{bmatrix} 3/16 & 7/48 & 29/64 & 41/192 \\ 5/48 & 5/24 & 79/144 & 5/36 \\ 0 & 0 & 1 & 0 \\ 1/16 & 13/96 & 107/192 & 47/192 \end{bmatrix}$$

元素 $P_{0,3}^3 = 41/192$ 给出正确答案. 如果希望知道从 4 个状态中均匀随机地选取一个状态开始, 经 3 步后在状态 3 结束的概率, 也会用到这个矩阵. 只要计算

$$(1/4, 1/4, 1/4, 1/4)P^3 = (17/192, 47/384, 737/1152, 43/288)$$

即可得到, 这里, 最后一个元素 $43/288$ 是要求的答案.

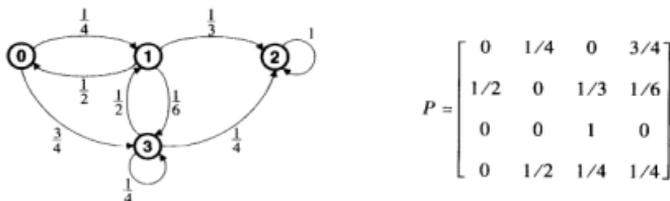


图 7.1 马尔可夫链(左)及相应的转移矩阵(右)

7.1.1 应用: 2-可满足性的随机化算法

回忆由 6.2.2 节, 一般可满足性(SAT)问题的输入是由子句集合的合取(AND)给出的布尔公式, 其中每个子句是文字的析取(OR), 而文字是一个布尔变量或一个布尔变量的否定. 解 SAT 公式的一个实例是变量赋值为 True(T)及 False(F), 使得所有子句是满足的. 一般 SAT 问题是 NP 难题. 这里我们分析 2-SAT 的简单随机化算法, 将问题限制为以多项式时间可解的情况.

对 k 可满足性(k -SAT)问题, 可满足性公式受到每个子句恰有 k 个文字的限制. 因此, 对 2-SAT 问题的一个输入, 每个子句恰有两个文字. 以下表达式是 2-SAT 的一个实例:

$$(x_1 \vee x_2) \wedge (\bar{x}_1 \vee \bar{x}_3) \wedge (x_1 \vee x_2) \wedge (x_4 \vee \bar{x}_3) \wedge (x_4 \vee \bar{x}_1). \quad (7.2)$$

寻找 2-SAT 公式解的一种自然的途径是从一个赋值开始, 寻找不满足的子句, 并改变赋值, 使子句成为满足的. 如果子句中有两个文字, 那么存在对赋值的两种可能的改变, 使得子句满足. 我们的 2-SAT 算法(算法 7.1)随机地确定尝试这些改变中的哪一个. 在算法中, n 表示公式中变量的个数, m 是确定算法以一个正确答案结束的概率的整参数.

算法 7.1 2-SAT 算法

1. 以一个任意的真值赋值开始.
2. 重复到 $2mn^2$ 次, 如果所有子句满足, 结束:
 - (a) 选取任一不满足的子句.
 - (b) 在子句中均匀随机地选取一个文字, 改变它的变量值.
3. 如果找到了一个有效的真值赋值, 返回它.
4. 否则, 返回公式是不可满足的.

在式(7.2)给出的实例中, 如果以所有变量设置为 False 开始, 那么子句 $(x_1 \vee x_2)$ 是不满足的, 所以算法可能选取这个子句, 然后选取 x_1 设置为 True, 此时子句 $(x_1 \vee \bar{x}_1)$ 不满足, 算法可能改变那个子句中的变量值, 等等.

如果算法以真值赋值结束, 显然返回一个正确答案. 在算法不能找到真值赋值的情况时需要小心, 后面我们将会回到这个问题. 现在假定公式是满足的, 算法实际运行直到找到一个满足的真值赋值为止.

我们的主要兴趣在于算法执行当型循环的迭代次数, 称算法每次改变一个真值赋值为一步. 因为 2-SAT 公式有 $O(n^2)$ 个不同的子句, 每步执行 $O(n^2)$ 时间. 较快的完成是可能的, 但我们不在此考虑. 设 S 表示 n 个变量的满足的赋值, A_i 表示经第 i 步算法后的变量赋值, X_i 表示当前赋值 A_i 中, 与满足的赋值 S 有相同值的变量个数. 当 $X_i = n$ 时, 算法以满足的赋值结束. 事实上, 如果算法找到了另外的满足赋值, 算法可能在 X_i 到达 n 之前结束. 但对我们的分析, 最糟糕的情况是算法只在当 $X_i = n$ 时停止. 从 $X_i < n$ 开始, 我们考虑算法是如何随时间而进展的, 特别地, 在 X_i 达到 n 之前, 这还需要多久.

首先如果 $X_i = 0$, 那么对下一步变量值的任何变化, 我们都有 $X_{i+1} = 1$, 因此

$$\Pr(X_{i+1} = 1 \mid X_i = 0) = 1.$$

现在假定 $1 \leq X_i \leq n-1$, 每一步选取一个不满足的子句. 因为 S 满足子句, 这表示 A_i 与 S 在这个子句中至少有一个变量值不一致. 因为子句有不多于两个的变量, 所以增加匹配个数的概率至少为 $1/2$, 如果处于这个子句中的两个变量值 A_i 和 S 都不一致的情况, 匹配个数增加的概率为 1 . 因此减少匹配个数的概率至多为 $1/2$. 故对 $1 \leq j \leq n-1$,

$$\Pr(X_{i+1} = j+1 \mid X_i = j) \geq 1/2;$$

$$\Pr(X_{i+1} = j-1 \mid X_i = j) \leq 1/2.$$

随机过程 X_0, X_1, X_2, \dots 不一定是马尔可夫链, 因为 X_i 增加的概率可能依赖于算法在那一步选取的不满足子句中, A_i 与 S 是一个变量还是两个变量不一致. 同样这也可能依赖于过去已经考虑过的子句. 但是考虑下列马尔可夫链 Y_0, Y_1, Y_2, \dots :

$$Y_0 = X_0;$$

$$\Pr(Y_{i+1} = 1 \mid Y_i = 0) = 1;$$

$$\Pr(Y_{i+1} = j+1 \mid Y_i = j) = 1/2;$$

$$\Pr(Y_{i+1} = j-1 \mid Y_i = j) = 1/2.$$

马尔可夫链 Y_0, Y_1, Y_2, \dots 是随机过程 X_0, X_1, X_2, \dots 的悲观形式, 因为 X_i 在下一步至少以 $1/2$ 的概率增加, Y_i 恰好以 $1/2$ 的概率增加. 因此, 显然从任一点开始的到达 n 的期望时间对马尔可夫链 Y 要多于对随机过程 X , 以后我们要用到这个事实. (第 11 章将提出这种思路的更强的形式框架.)

这种马尔可夫链是无向图 G 上随机游动的模型. (我们将在 7.4 节进一步详细说明随机游动.) G 的顶点是整数 $0, \dots, n$, 且对 $1 \leq i \leq n-1$, 结点 i 与结点 $i-1$ 和结点 $i+1$ 连接. 设 h_j 是从 j 开始的到达 n 的期望步数. 对 2-SAT 算法, h_j 是从在位置 j 与 S 匹配的真值赋值开始, 到完全匹配 S 的期望步数的上界.

显然, $h_n = 0$, $h_0 = h_1 + 1$, 这是因为从 h_0 开始, 总是一步移动到 h_1 . 我们利用期望的线性性来寻找其他 h_j 值的表达式. 设 Z_j 表示从状态 j 到达 n 的步数的随机变量. 现在考虑从状态 j 出发, 其中 $1 \leq j \leq n-1$. 以 $1/2$ 的概率, 下一状态为 $j-1$, 此时 $Z_j = 1 + Z_{j-1}$; 以 $1/2$ 的概率, 下一步是 $j+1$, 此时 $Z_j = 1 + Z_{j+1}$. 因此

$$E[Z_j] = E\left[\frac{1}{2}(1 + Z_{j-1}) + \frac{1}{2}(1 + Z_{j+1})\right].$$

但 $E[Z_j] = h_j$, 故由期望的线性性, 我们得到

$$h_j = \frac{h_{j-1} + 1}{2} + \frac{h_{j+1} + 1}{2} = \frac{h_{j-1}}{2} + \frac{h_{j+1}}{2} + 1.$$

所以, 我们有以下方程组:

$$h_n = 0;$$

$$h_j = \frac{h_{j-1}}{2} + \frac{h_{j+1}}{2} + 1, \quad 1 \leq j \leq n-1;$$

$$h_0 = h_1 + 1.$$

可以用归纳法证明, 对 $0 \leq j \leq n-1$,

$$h_j = h_{j+1} + 2j + 1.$$

当 $j=0$ 时, 上式成立, 因为 $h_1 = h_0 - 1$. 对 j 的其他值, 利用等式

$$h_j = \frac{h_{j-1}}{2} + \frac{h_{j+1}}{2} + 1$$

得到

$$\begin{aligned} h_{j+1} &= 2h_j - h_{j-1} - 2 \\ &= 2h_j - (h_j + 2(j-1) + 1) - 2 \\ &= h_j - 2j - 1, \end{aligned}$$

第二行用到了归纳假设. 我们可以断言

$$h_0 = h_1 + 1 = h_2 + 1 + 3 = \cdots = \sum_{i=0}^{n-1} 2i + 1 = n^2.$$

解关于 h_j 的方程组的另一种方法是猜测并验证解 $h_j = n^2 - j^2$. 方程组有 $n+1$ 个线性无关的方程, $n+1$ 个未知量, 因此对每个 n 值, 存在唯一解. 所以, 如果这个解满足前述等式, 它必是正确的. 我们有 $h_n = 0$. 对 $1 \leq j \leq n-1$, 检查

$$\begin{aligned} h_j &= \frac{n^2 - (j-1)^2}{2} + \frac{n^2 - (j+1)^2}{2} + 1 \\ &= n^2 - j^2 \end{aligned}$$

及

$$\begin{aligned} h_0 &= (n^2 - 1) + 1 \\ &= n^2. \end{aligned}$$

这样, 我们已经证明了下面的事实.



引理 7.1 假定 n 个变量的 2-SAT 公式有满足的赋值, 且 2-SAT 算法允许运行直到找到一个满足的赋值. 那么, 直到算法找到一个赋值所需的期望步数为 n^2 .

现在我们回到不满足公式的处理, 经固定步数, 算法被迫停止.

定理 7.2 如果公式是不可满足的, 2-SAT 算法总能返回一个正确的答案. 如果公式是可满足的, 那么算法至少以 $1 - 2^{-n}$ 的概率返回一个满足的赋值; 否则, 它不正确地返回公式是不可满足的.

证明 如果不存在满足的赋值, 显然算法正确地返回公式是不可满足的. 假定公式是可满足的, 将算法的执行分成以每 $2n^2$ 步为一段. 已知在前 $i-1$ 段没有找到满足的赋值, 算法在第 i 段没有找到满足的赋值的条件概率是多少? 由引理 7.1, 不考虑开始位置, 找到一个满足赋值的期望时间不超过 n^2 . 设 Z 是从第 i 段开始直到算法找到满足赋值的步数. 由马尔可夫不等式,

$$\Pr(Z > 2n^2) \leq \frac{n^2}{2n^2} = \frac{1}{2}.$$

所以, 经 m 段, 算法不能找到满足赋值的概率的上界为 $(1/2)^m$. ■

7.1.2 应用: 3-可满足性的随机化算法

现在我们将用于给出 2-SAT 算法的技术推广, 以得到 3-SAT 的随机化算法. 这个问题是 NP 完全的, 所以如果一种随机化算法在关于 n 的多项式期望时间中解决了问题, 这是相当令人惊异的^①. 我们提出一个用关于 n 的指数级的期望时间解决 3-SAT 的随机化 3-SAT 算法, 但比尝试对变量的所有可能真值赋值的平凡方法有效得多.

首先考虑当用于 3-SAT 问题时随机化 2-SAT 算法变形的执行. 基本途径与上一节中相同, 见算法 7.2. 在这个算法中, m 是控制算法成功概率的参数. 我们关注得到满足赋值(假定存在)期望时间的界, 因为一旦找到这样的界, 定理 7.2 的证明便可以推广.

算法 7.2 3-SAT 算法

1. 以一个任意的真值赋值开始.
2. 重复直到 m 次, 如果所有子句满足, 结束:
 - (a) 选取任一不满足的子句.
 - (b) 均匀随机地选取一个文字, 改变当前真值赋值中变量的值.
3. 如果找到了一个有效的真值赋值, 返回它.
4. 否则, 返回公式是不可满足的.

如 2-SAT 算法分析的那样, 假定公式是可满足的, S 是一满足的赋值. 设 i 步过程后, 赋值为 A_i , 并设 X_i 是当前赋值 A_i 与 S 匹配的变量个数. 与 2-SAT 算法同样的理由, 对 $1 \leq j \leq n-1$, 有

① 技术上, 这不解决 $P = NP$ 问题, 因为我们利用随机化算法而不是确定性算法解决 NP 难题. 但是, 这对解决所有 NP 完全的问题具有相似的影响深远的意义.

$$\Pr(X_{i+1} = j + 1 | X_i = j) \geq 1/3;$$

$$\Pr(X_{i+1} = j - 1 | X_i = j) \leq 2/3.$$

由于在每一步我们选取一个不满足子句，所以 A_i 与 S 在这个子句中必至少有一个变量不匹配。至少以 $1/3$ 的概率增加当前真值赋值与 S 之间的配合个数。用分析马尔可夫链 Y_0, Y_1, \dots ，(其中 $Y_0 = X_0$)，及等式

$$\Pr(Y_{i+1} = 1 | Y_i = 0) = 1,$$

$$\Pr(Y_{i+1} = j + 1 | Y_i = j) = 1/3,$$

$$\Pr(Y_{i+1} = j - 1 | Y_i = j) = 2/3,$$

我们仍然可以得到直至 $X_i = n$ 所需的期望步数的上界。

[160]

在这种情况下，链更可能向下而不是向上移动。如果用 h_j 表示从 j 开始到达 n 的期望步数，那么下面等式对 h_j 是成立的：

$$h_n = 0;$$

$$h_j = \frac{2h_{j-1}}{3} + \frac{h_{j+1}}{3} + 1, \quad 1 \leq j \leq n-1;$$

$$h_0 = h_1 + 1.$$

这些方程仍有唯一解，由下式给出：

$$h_j = 2^{n-j} - 2^{j-2} - 3(n-j).$$

另外，也可用归纳法证明关系式

$$h_j = h_{j+1} + 2^{j-2} - 3$$

而得到解。验证这个解确实满足前述方程，我们将它留作练习。

刚刚描述的算法平均地经 $\Theta(2^n)$ 步找到一个满足的赋值。这个结果并不非常令人高兴，因为只有 2^n 个真值赋值要尝试。但我们可以显著地改进这个方法，有两个关键的意见：

1. 如果均匀随机地选取一个初始真值赋值，那么与 S 匹配的变量个数是期望为 $n/2$ 的二项分布。以一个指数级小但不可忽略的概率，从初始赋值开始的过程有显著地多于 $n/2$ 个变量与 S 匹配。

2. 一旦算法开始，它似乎更愿意向 0 移动，而不是向 n 移动。过程运行得越长，便更可能往 0 移动。所以，我们以多个随机选取的初始赋值重新开始过程，每次运行过程少量步数，这比以相同的初始赋值运行过程许多步要来得好。

基于这些思想，我们考虑修正的算法 7.3。修正算法从一个随机赋值开始，最多经 $3n$ 步达到满足的赋值。如果它不能在 $3n$ 步内找到一个满足的赋值，便以一个新的随机选取的赋值重新开始搜索。现在我们确定在找到满足的赋值以前，过程需要多少次重新开始。

算法 7.3 修正的 3-SAT 算法

1. 重复到 m 次，如果所有子句满足，结束：

(a) 从一个均匀随机选取的真值赋值开始。

(b) 重复以下步骤直到 $3n$ 次, 如果找到一个满足的赋值, 结束:

i: 选取任一不满足的子句;

ii: 均匀随机地选取一个文字, 且改变当前真值赋值中的变量值.

2. 如果找到一个有效的真值赋值, 返回它.

3. 否则, 返回公式是不可满足的.

设 q 表示以均匀随机选取的真值赋值开始, 在 $3n$ 步内修正的过程达到 S (或某个其他满足的赋值) 的概率. 设 q_j 是从一个恰好有 j 个变量与 S 不一致的真值赋值开始修正算法达到 S (或某个其他满足的赋值) 的概率的下界. 考虑在整数直线上移动的一个质点, 以 $1/3$ 的概率向上移动 1, 以 $2/3$ 的概率向下移动 1. 注意

[161]

$$\binom{j+2k}{k} \left(\frac{2}{3}\right)^k \left(\frac{1}{3}\right)^{j+k}.$$

是在一个 $j+2k$ 个移动的序列中恰有 k 个向下移动、 $k+j$ 个向上移动的概率. 所以这是算法以恰有 j 个变量与 S 不一致的赋值开始, 在 $j+2k \leq 3n$ 步中找到一个满足赋值的概率的下界, 即

$$q_j \geq \max_{k=0, \dots, j} \binom{j+2k}{k} \left(\frac{2}{3}\right)^k \left(\frac{1}{3}\right)^{j+k}.$$

特别地, 考虑 $k=j$ 的情况, 此时, 我们有

$$q_j \geq \binom{3j}{j} \left(\frac{2}{3}\right)^j \left(\frac{1}{3}\right)^{2j}.$$

为了近似 $\binom{3j}{j}$, 利用斯特林公式, 这类似于已经证明的关于阶乘的界 (5.2) 和 (5.5). 斯特林公式是紧的, 对这个应用是有用的. 我们用下面的宽松形式.

引理 7.3 [斯特林公式] 对 $m > 0$,

$$\sqrt{2\pi m} \left(\frac{m}{e}\right)^m \leq m! \leq 2\sqrt{2\pi m} \left(\frac{m}{e}\right)^m.$$

因此, 当 $j > 0$ 时,

$$\begin{aligned} \binom{3j}{j} &= \frac{(3j)!}{j!(2j)!} \\ &\geq \frac{\sqrt{2\pi(3j)}}{4\sqrt{2\pi j}\sqrt{2\pi(2j)}} \left(\frac{3j}{e}\right)^{3j} \left(\frac{e}{2j}\right)^{2j} \left(\frac{e}{j}\right)^j \\ &= \frac{\sqrt{3}}{8\sqrt{\pi j}} \left(\frac{27}{4}\right)^j \\ &= \frac{c}{\sqrt{j}} \left(\frac{27}{4}\right)^j, \end{aligned}$$

[162]

其中常数 $c = \sqrt{3}/8\sqrt{\pi}$. 所以当 $j > 0$ 时,

$$q_j \geq \binom{3j}{j} \left(\frac{2}{3}\right)^j \left(\frac{1}{3}\right)^{2j}$$

$$\begin{aligned} &\geq \frac{c}{\sqrt{j}} \left(\frac{27}{4}\right)^j \left(\frac{2}{3}\right)^j \left(\frac{1}{3}\right)^{2j} \\ &\geq \frac{c}{\sqrt{j}} \frac{1}{2^j}. \end{aligned}$$

并且, $q_0 = 1$.

建立了 q_j 的下界后, 现在可以导出 q 的下界, 即从随机赋值开始, 经 $3n$ 步过程搜索到一个满足赋值的概率的下界:

$$\begin{aligned} q &\geq \sum_{j=0}^n \Pr(\text{随机赋值与 } S \text{ 有 } j \text{ 个不匹配}) \cdot q_j \\ &\geq \frac{1}{2^n} + \sum_{j=1}^n \binom{n}{j} \left(\frac{1}{2}\right)^n \frac{c}{\sqrt{j}} \frac{1}{2^j} \\ &\geq \frac{c}{\sqrt{n}} \left(\frac{1}{2}\right)^n \sum_{j=0}^n \binom{n}{j} \left(\frac{1}{2}\right)^j (1)^{n-j} \quad (7.3) \\ &= \frac{c}{\sqrt{n}} \left(\frac{1}{2}\right)^n \left(\frac{3}{2}\right)^n \\ &= \frac{c}{\sqrt{n}} \left(\frac{3}{4}\right)^n, \end{aligned}$$

其中在 (7.3) 中用到了 $\sum_{j=0}^n \binom{n}{j} \left(\frac{1}{2}\right)^j (1)^{n-j} = \left(1 + \frac{1}{2}\right)^n$.

假定满足的赋值存在, 在找到一个满足赋值以前, 过程尝试过的随机赋值的次数是参数为 q 的几何随机变量. 尝试过的赋值的期望次数是 $1/q$, 且对每个赋值, 算法至多利用 $3n$ 步. 所以, 找到一个解的期望步数界定为 $O(n^{3/2}(4/3)^n)$. 如 2-SAT 的情况 (定理 7.2) 一样, 修正的 3-SAT 算法 (算法 7.3) 产生 3-SAT 问题的蒙特卡罗算法. 如果找到满足解的期望步数有上界 a , 且如果设 m 为 $2ab$, 那么当公式是可满足的时, 没有找到赋值的概率有上界 2^{-a} .

7.2 状态分类

分析马尔可夫链长期性态的第一步是对它的状态进行分类. 在有限马尔可夫链情况, 这相当于分析表示马尔可夫链的有向图的连通结构.

定义 7.2 状态 i 是由状态 j 可达的, 如果对某个整数 $n \geq 0$, $P_{ij}^n > 0$. 如果两个状态 i 和 j 是相互可达的, 我们说它们是相通的, 且记为 $i \leftrightarrow j$.

在链的图表示中, $i \leftrightarrow j$, 当且仅当存在连结 i 到 j 及 j 到 i 的有向路径.

相通关系定义了一个等价关系, 即相通关系是

1. 自反的——对任意状态 i , $i \leftrightarrow i$;
2. 对称的——如果 $i \leftrightarrow j$, 那么 $j \leftrightarrow i$;
3. 传递的——如果 $i \leftrightarrow j$ 且 $j \leftrightarrow k$, 那么 $i \leftrightarrow k$.

对此的证明留作练习 7.4. 所以, 相通关系将状态分成不相交的等价类, 我们称之为相通

类. 从一个类移向另一个类是可能的, 但此时不可能返回第一个类.

定义 7.3 马尔可夫链是不可约的, 如果所有状态属于一个相通类.

换言之, 马尔可夫链是不可约的, 如果对每一对状态都存在由第一状态可以到达第二状态的非零概率. 这样, 我们有下面的引理.

引理 7.4 一个有限马尔可夫链是不可约的, 当且仅当它的图表示是一个强连通图.

下面我们区别瞬时与常返状态之间的不同. 设 r'_{ij} 表示从状态 i 出发, 在时刻 t 第一次转移到状态 j 的概率, 即

$$r'_{ij} = \Pr(X_t = j; \text{如果 } 1 \leq s \leq t-1, X_s \neq j | X_0 = i).$$

定义 7.4 状态是常返的, 如果 $\sum_{i=1}^n r'_{ii} = 1$; 状态是瞬时的(也称非常返——译者注), 如果 $\sum_{i=1}^n r'_{ii} < 1$. 马尔可夫链是常返的, 如果链中每个状态是常返的.

如果状态 i 是常返的, 那么只要链访问过那个状态, 它将(以概率 1)最终返回那个状态. 因此链将反复地、无限经常地访问状态 i . 另一方面, 如果状态 i 是瞬时的, 那么从 i 出发, 链将以某个固定的概率 $p = \sum_{i=1}^n r'_{ii}$ 返回 i . 此时, 从 i 出发, 链访问 i 的次数由几何随机变量给出. 如果相通类中一个状态是瞬时的(分别为常返的), 那么这个类中的所有状态是瞬时的(分别为常返的). 对此的证明留作练习 7.5.

我们用 $h_{i,i} = \sum_{t=1}^{\infty} t \cdot r'_{ii}$ 表示从状态 i 出发返回状态 i 的期望时间. 类似地, 对任一对象

164 i, j , 用 $h_{i,j} = \sum_{t=1}^{\infty} t \cdot r'_{ij}$ 表示从状态 i 首次达状态 j 的期望时间. 如果链是常返的, 即无限经常地访问状态 i , 那么 $h_{i,i}$ 应是有限的. 这不是导出下面定义的情况.

定义 7.5 如果 $h_{i,i} < \infty$, 常返状态 i 是正常返的; 否则, 是零常返的.

为了给出马尔可夫链有零常返状态的例子, 考虑一个状态为正整数的链. 从状态 i 出发, 到达状态 $i+1$ 的概率是 $i/(i+1)$; 以概率 $1/(i+1)$, 链返回状态 1. 从状态 1 出发, 在前 t 步中没有返回状态 1 的概率因此是

$$\prod_{j=1}^t \frac{j}{j+1} = \frac{1}{t+1}.$$

所以从状态 1 不返回状态 1 的概率为 0, 且状态 1 是常返的, 因此

$$r'_{1,1} = \frac{1}{t(t+1)}.$$

它从状态 1 首次返回状态 1 的期望步数为

$$h_{1,1} = \sum_{t=1}^{\infty} t \cdot r'_{1,1} = \sum_{t=1}^{\infty} \frac{1}{t+1},$$

它是无界的.

在前面的例子中, 马尔可夫链有无穷多个状态, 这是零常返状态存在的必要条件. 下面重要引理的证明留作练习 7.9.

引理 7.5 在一个有限的马尔可夫链中:

1. 至少有一个状态是常返的;
2. 所有常返状态是正常返的.

最后, 为了以后对马尔可夫链的极限分布进行研究, 我们需要定义状态是非周期的意义. 作为非周期的例子, 考虑状态是正整数的一个随机游动. 在状态 i , 链以 $1/2$ 的概率移动到 $i+1$ 且以 $1/2$ 的概率移动到 $i-1$. 如果链从状态 0 出发, 那么它只能经偶数次移动才可能处于一个偶数状态, 只能经奇数次移动才可能处于一个奇数状态. 这是一个周期性的例子.

定义 7.6 在离散时间马尔可夫链中的状态 j 是周期的, 如果存在一个整数 $\Delta > 1$, 使得 $\Pr(X_{t+\Delta} = j | X_t = j) = 0$, 除非 s 被 Δ 整除. 一个离散时间马尔可夫链是周期的, 如果链的任一状态是周期的. 一个状态或链不是周期的, 称为非周期的.

[165]

在我们的例子中, 马尔可夫链的每个状态是周期的, 这是因为对每个状态 j , $\Pr(X_{t+s} = j | X_t = j) = 0$, 除非 s 可以被 2 整除.

我们以关于有限马尔可夫链的性态的一个重要推论结束这一节.

定义 7.7 一个非周期的正常返状态是遍历状态. 马尔可夫链是遍历的, 如果它的所有状态是遍历的.

推论 7.6 任一有限的、不可约的、非周期的马尔可夫链是遍历的.

证明 由引理 7.5, 有限链至少有一个常返状态, 并且如果链是不可约的, 那么它的所有状态是常返的. 由引理 7.5, 在有限链中, 所有常返状态是正常返的, 因此链的所有状态是正常返的且是非周期的, 所以链是遍历的. ■

7.2.1 例: 赌徒的破产

当马尔可夫链有多于一个常返状态的类时, 通常对过程将要进入并被某个给定的相通类吸收的概率感兴趣.

例如, 考虑两个选手之间一系列独立、公平的赌博. 每一轮选手以 $1/2$ 的概率赢一元或以 $1/2$ 的概率输一元. 系统在时刻 t 的状态是选手 1 赢的钱数. 如果选手 1 输钱, 这个数是负的. 初始状态是 0.

假定存在两个数 ℓ_1 和 ℓ_2 , 使得选手 i 不会输掉多于 ℓ_1 元, 且当达到了两个状态 $-\ell_1$ 或 ℓ_2 之一时, 游戏结束, 这样的假定是合理的. 此时赌徒之一破产, 即他输掉了所有的钱. 为与马尔可夫链的形式一致, 我们假定对两个结束状态的每一个只存在一个转移离开, 且假定它返回相同状态. 这给出有两个吸收的常返状态的马尔可夫链.

选手 1 在输掉 ℓ_1 元之前赢 ℓ_2 元的概率是多少? 如果 $\ell_2 = \ell_1$, 则由对称性, 这个概率必为 $1/2$. 对一般情况, 利用状态的分类, 我们提供一种简单的证明.

显然 $-\ell_1$ 和 ℓ_2 是常返状态, 所有余下的状态是瞬时的, 这是因为存在由这些状态的每一个移向状态 $-\ell_1$ 或状态 ℓ_2 的非零概率.

设 P_t^i 是经 t 步链处于状态 i 的概率. 对 $-\ell_1 < i < \ell_2$ 来说, 状态 i 是瞬时的, 所以 $\lim_{t \rightarrow \infty} P_t^i = 0$.

设 q 是游戏以选手 1 赢得 ℓ_2 元而结束, 使得链被吸收到状态 ℓ_2 的概率, 那么 $1-q$ 是链吸收到状态 $-\ell_1$ 的概率. 由定义,

$$\lim_{t \rightarrow \infty} P_{\ell_2}^t = q.$$

因为每轮赌博是公平的, 选手 1 在每一步的期望得益为 0. 设 W^t 是 t 步后选手 1 的得益, 则由归纳法, 对任意 t , $E[W^t] = 0$. 所以

[166]

$$E[W^t] = \sum_{i=-\ell_1}^{\ell_2} iP_i^t = 0$$

及

$$\begin{aligned} \lim_{t \rightarrow \infty} E[W^t] &= \ell_2 q - \ell_1(1 - q) \\ &= 0. \end{aligned}$$

这样,

$$q = \frac{\ell_1}{\ell_1 + \ell_2}.$$

即赢(或输)的概率与选手愿意输(或赢)的钱数成比例.

产生同样答案的另一种方法是令 q_j 表示选手 1 在已赢得 j 元时, $(-\ell_1 \leq j \leq \ell_2)$ 在输掉 ℓ_1 元之前赢得 ℓ_2 元的概率. 显然 $q_{-\ell_1} = 0$, $q_{\ell_2} = 1$. 对 $-\ell_1 < j < \ell_2$, 考虑第一次游戏的结果来计算:

$$q_j = \frac{q_{j-1}}{2} + \frac{q_{j+1}}{2}.$$

我们有 $\ell_2 + \ell_1 - 2$ 个线性无关的方程和 $\ell_2 + \ell_1 - 2$ 个未知数, 所以这个方程组存在唯一解. 容易验证 $q_j = (\ell_1 + j)/(\ell_1 + \ell_2)$ 满足所给的方程.

在练习 7.20 中, 我们考虑如现实生活中的—般情况那样, 如果一位选手处于不利地位; 从而更有可能输而不是赢得任何—次游戏会发生什么样的情况.

7.3 平稳分布

回忆如果 P 是马尔可夫链的一步转移矩阵, $\tilde{p}(t)$ 是链在时刻 t 状态的概率分布, 那么

$$\tilde{p}(t+1) = \tilde{p}(t)P.$$

特别有趣的是经—次转移后状态概率分布不改变的情况.

定义 7.8 马尔可夫链的平稳分布(也称平衡分布)是满足

$$\tilde{\pi} = \tilde{\pi}P$$

的概率分布 $\tilde{\pi}$.

如果一个链到达了平稳分布, 那么它在所有未来时间都保持这个分布. 这样, 一个平稳分布表示链的性态中—种不变的状态或平衡. 平稳分布在分析马尔可夫链中起着关键作用. 马尔可夫链的基本定理刻划了收敛于平稳分布的链的特征.

[167]

我们首先讨论有限链的情况, 然后将结果推广到离散空间链. 不失—般性, 假定马尔可夫链的有限状态集为 $\{0, 1, \dots, n\}$.

定理 7.7 任意有限、不可约且遍历的马尔可夫链有下列性质:

1. 链有唯一的平稳分布 $\bar{\pi} = (\pi_0, \pi_1, \dots, \pi_n)$;
2. 对所有 j 和 i , 极限 $\lim_{t \rightarrow \infty} P_{j,i}^t$ 存在且与 j 无关;
3. $\pi_i = \lim_{t \rightarrow \infty} P_{j,i}^t = 1/h_{i,i}$.

在这个定理的条件下, 平稳分布 $\bar{\pi}$ 有两种解释. 首先, π_i 是马尔可夫链在无穷远的未来将处于状态 i 的概率, 而且这个概率与初始状态无关. 换言之, 如果运行链以足够长时间, 链的初始状态几乎被忘记, 且处于状态 i 的概率收敛于 π_i . 其次, π_i 是 $h_{i,i} = \sum_{r=1}^{\infty} t \cdot r_{i,i}^t$, 即从状态 i 出发的链又返回状态 i 的期望步数的倒数. 这是因为: 如果从状态 i 返回状态 i 的平均时间是 $h_{i,i}$, 那么我们期望处于状态 i 的时间为 $1/h_{i,i}$, 所以依极限, 必有 $\pi_i = 1/h_{i,i}$.

定理 7.7 的证明 利用下面不加证明的陈述来证明定理.

引理 7.8 对任意不可约、遍历的马尔可夫链及任意状态 i , 极限 $\lim_{t \rightarrow \infty} P_{i,i}^t$ 存在, 且

$$\lim_{t \rightarrow \infty} P_{i,i}^t = \frac{1}{h_{i,i}}.$$

这个引理是更新理论中一个基本结果的推论. 我们给出引理 7.8 的非正式的证明: 两次访问 i 之间的期望时间为 $h_{i,i}$, 所以状态 i 被访问的时间为 $1/h_{i,i}$. 因此 $\lim_{t \rightarrow \infty} P_{i,i}^t$ (表示当链从状态 i 出发, 在遥远的将来选择一个状态为状态 i 的概率) 必为 $1/h_{i,i}$.

利用 $\lim_{t \rightarrow \infty} P_{i,i}^t$ 存在的事实, 现在证明对任意的 j 和 i ,

$$\lim_{t \rightarrow \infty} P_{j,i}^t = \lim_{t \rightarrow \infty} P_{i,i}^t = \frac{1}{h_{i,i}};$$

即这些极限存在, 且与起始状态 j 无关.

回忆 $r_{j,i}^t$ 是从 j 出发, 链在 t 时刻首次达 i 的概率. 因为链是不可约的, 所以有 $\sum_{k=1}^{\infty} r_{j,i}^k = 1$, 且

对于任意 $\varepsilon > 0$, 存在 (一个有限) $t_1 = t_1(\varepsilon)$, 使得 $\sum_{k=1}^{t_1} r_{j,i}^k \geq 1 - \varepsilon$.

对 $j \neq i$, 有

$$P_{j,i}^t = \sum_{k=1}^t r_{j,i}^k P_{i,i}^{t-k}.$$

对 $t \geq t_1$,

$$\sum_{k=1}^{t_1} r_{j,i}^k P_{i,i}^{t-k} \leq \sum_{k=1}^t r_{j,i}^k P_{i,i}^{t-k} = P_{j,i}^t.$$

利用 $\lim_{t \rightarrow \infty} P_{i,i}^t$ 存在且 t_1 有限的事实, 有

$$\begin{aligned} \lim_{t \rightarrow \infty} P_{j,i}^t &\geq \lim_{t \rightarrow \infty} \sum_{k=1}^{t_1} r_{j,i}^k P_{i,i}^{t-k} \\ &= \sum_{k=1}^{t_1} r_{j,i}^k \lim_{t \rightarrow \infty} P_{i,i}^t. \end{aligned}$$



$$\begin{aligned}
 &= \lim_{t \rightarrow \infty} P'_{j,i} \sum_{k=1}^{i_1} r'_{j,i}{}^k \\
 &\geq (1 - \varepsilon) \lim_{t \rightarrow \infty} P'_{j,i}.
 \end{aligned}$$

类似地,

$$\begin{aligned}
 P'_{j,i} &= \sum_{k=1}^i r'_{j,i}{}^k P'_{j,i}{}^k \\
 &\leq \sum_{k=1}^{i_1} r'_{j,i}{}^k P'_{j,i}{}^k + \varepsilon,
 \end{aligned}$$

由此可以推断

$$\begin{aligned}
 \lim_{t \rightarrow \infty} P'_{j,i} &\leq \lim_{t \rightarrow \infty} \left(\sum_{k=1}^{i_1} r'_{j,i}{}^k P'_{j,i}{}^k + \varepsilon \right) \\
 &= \sum_{k=1}^{i_1} r'_{j,i}{}^k \lim_{t \rightarrow \infty} P'_{j,i}{}^k + \varepsilon \\
 &\leq \lim_{t \rightarrow \infty} P'_{j,i} + \varepsilon.
 \end{aligned}$$

令 ε 趋于 0, 我们已经证明, 对任意一对 i 和 j ,

$$\lim_{t \rightarrow \infty} P'_{j,i} = \lim_{t \rightarrow \infty} P'_{i,i} = \frac{1}{h_{i,i}}.$$

现在令

$$\pi_i = \lim_{t \rightarrow \infty} P'_{j,i} = \frac{1}{h_{i,i}}.$$

我们证明 $\bar{\pi} = (\pi_0, \pi_1, \dots)$ 形成一个平稳分布.

对每个 $t \geq 0$, 有 $P'_{i,i} > 0$, 因此 $\pi_i \geq 0$. 对任意 $t \geq 0$, $\sum_{i=0}^n P'_{j,i} = 1$, 所以

$$\lim_{t \rightarrow \infty} \sum_{i=0}^n P'_{j,i} = \sum_{i=0}^n \lim_{t \rightarrow \infty} P'_{j,i} = \sum_{i=0}^n \pi_i = 1,$$

且 $\bar{\pi}$ 是一个严格意义上的分布. 现在,

$$P'_{j,i}{}^{t+1} = \sum_{k=0}^n P'_{j,i}{}^t P_{k,i}{}^t.$$

令 $t \rightarrow \infty$, 有

$$\pi_i = \sum_{k=0}^n \pi_i P_{k,i}.$$

这证得 $\bar{\pi}$ 是平稳分布.

假定存在另一平稳分布 $\bar{\phi}$, 那么由同样的理由, 我们有

$$\phi_i = \sum_{k=0}^n \phi_k P'_{k,i}.$$



取 $t \rightarrow \infty$ 的极限得到

$$\phi_i = \sum_{k=0}^n \phi_k \pi_i = \pi_i \sum_{k=0}^n \phi_k.$$

因为 $\sum_{k=0}^n \phi_k = 1$, 由此对所有 i , $\phi_i = \pi_i$, 或 $\bar{\phi} = \bar{\pi}$. ■

对于定理 7.7 做些评论是值得的. 首先, 对平稳分布的存在, 不必要要求马尔可夫链是非周期的. 事实上, 任何有限的马尔可夫链都有一个平稳分布, 但在周期性状态 i 的情况下, 平稳概率 π_i 不是处于 i 的极限概率, 而正是访问状态 i 的长期频率. 其次, 任意有限链至少有一个分支是常返态的. 只要链到达常返分支, 它就不可能离开那个分支. 所以, 相应于那个分支的子链是不可约且常返的, 并且极限定理用于链的任一非周期常返分支.

计算有限马尔可夫链平稳分布的一种方法是解线性方程组

$$\bar{\pi}P = \bar{\pi}.$$

如果已知一个特定的链, 这是特别有用的. 例如, 已知转移矩阵

$$P = \begin{bmatrix} 0 & 1/4 & 0 & 3/4 \\ 1/2 & 0 & 1/3 & 1/6 \\ 1/4 & 1/4 & 1/2 & 0 \\ 0 & 1/2 & 1/4 & 1/4 \end{bmatrix},$$

由 $\bar{\pi}P = \bar{\pi}$ 及 $\sum_{i=0}^3 \pi_i = 1$, 可知有 5 个方程, 4 个未知量 $\pi_0, \pi_1, \pi_2, \pi_3$, 方程有唯一解.

另一种有用的技术是研究马尔可夫链的割集. 对链的任一状态 i ,

$$\sum_{j=0}^n \pi_j P_{j,i} = \pi_i = \pi_i \sum_{j=0}^n P_{i,j}$$

或

$$\sum_{j=1}^n \pi_j P_{j,i} = \sum_{j=1}^n \pi_i P_{i,j}.$$

即在平稳分布中, 链离开一个状态的概率等于进入这个状态的概率, 这可推广到如下的状态集合.

定理 7.9 设 S 是一个有限、不可约且非周期的马尔可夫链的状态集合, 在平稳分布中, 链离开集合 S 的概率等于进入 S 的概率.

换言之, 如果 C 是链的图表示中的一个割集, 那么, 在平稳分布下, 依一个方向通过割集的概率等于依另一方向通过割集的概率.

图 7.2 给出了基本的但是有用的马尔可夫链, 它作为割集的一个例子. 链只有两个状态. 从状态 0, 以概率 p 移动到状态 1, 且以概率 $1-p$ 停留在状态 0. 类似地, 从状态 1, 以概率 q 移动到状态 0, 且以概率 $1-q$ 保持在状态 1. 这个马尔可夫链常用于表示突发行为. 例如, 当位信号在传送中有错误



图 7.2 用于描述突发行为的一个简单的马尔可夫链

时, 则常常错一大批, 因为错误常是由某段时间的外部现象引起的. 在这种背景下, 经 t 步后处于状态 0 表示第 t 个位信号成功发送, 而状态 1 表示这一个位信号传送有误. 成功发送与错误发送位信号的长度都服从几何分布. 当 p 和 q 都较小时, 状态变化不常发生, 此即突发行为的模型.

转移矩阵是

$$P = \begin{bmatrix} 1-p & p \\ q & 1-q \end{bmatrix}.$$

解 $\bar{\pi}P = \bar{\pi}$ 相当于解下列有三个方程的方程组:

$$\pi_0(1-p) + \pi_1q = \pi_0;$$

$$\pi_0p + \pi_1(1-q) = \pi_1;$$

$$\pi_0 + \pi_1 = 1.$$

第 2 个方程是多余的, 解为 $\pi_0 = q/(p+q)$, $\pi_1 = p/(p+q)$. 例如, 当自然参数 $p=0.005$, $q=0.1$ 时, 在平稳分布中, 有多于 95% 的位信号是被无错误地接收的.

利用割集公式, 我们得到在平稳分布中离开状态 0 的概率必等于进入状态 0 的概率, 或

$$\pi_0p = \pi_1q.$$

现在利用 $\pi_0 + \pi_1 = 1$, 仍然得到 $\pi_0 = q/(p+q)$, $\pi_1 = p/(p+q)$.

最后, 对于马尔可夫链, 由下面的定理容易计算平稳分布.

定理 7.10 考虑一个有限、不可约且遍历的马尔可夫链, 转移矩阵为 P . 如果存在非负实数 $\bar{\pi} = (\pi_0, \dots, \pi_n)$ 使得 $\sum_{i=0}^n \pi_i = 1$, 且如果对任一对状态 i, j ,

$$\pi_i P_{i,j} = \pi_j P_{j,i},$$

那么 $\bar{\pi}$ 是相应于 P 的平稳分布.

证明 考虑 $\bar{\pi}P$ 的第 j 个元素. 由定理的假设, 我们发现它等于

$$\sum_{i=0}^n \pi_i P_{i,j} = \sum_{i=0}^n \pi_j P_{j,i} = \pi_j.$$

所以 $\bar{\pi}$ 满足 $\bar{\pi} = \bar{\pi}P$. 因为 $\sum_{i=0}^n \pi_i = 1$, 由定理 7.7 可知 $\bar{\pi}$ 必是马尔可夫链唯一的平稳分布. ■

满足条件

$$\pi_i P_{i,j} = \pi_j P_{j,i}$$

的链称为时间可逆的, 练习 7.13 可以帮助说明为什么. 可以验证图 7.2 是时间可逆的.

现在我们转向有可数无穷状态空间的马尔可夫链的收敛性. 利用与定理 7.7 的证明中基本相同的方法可以证明下面的结果.

定理 7.11 任一不可约非周期的马尔可夫链属于下列两种类型之一:

1. 链是遍历的——对任一对状态 i, j , 极限 $\lim_{t \rightarrow \infty} P_{j,i}^t$ 存在, 且与 j 无关, 链有唯一的平稳分

布 $\pi_i = \lim_{t \rightarrow \infty} P'_{j,i} > 0$.

2. 没有状态是正常返的——对所有 i, j , 有 $\lim_{t \rightarrow \infty} P'_{j,i} = 0$, 且链没有平稳分布.

测集与时间可逆性还可用于求可数无穷状态空间的马尔可夫链的平稳分布.

7.3.1 例: 简单的队列

队列是一条顾客等待服务的直线. 考虑一个有界队列模型, 其中时间被分成等长的步. 在每一时间步, 恰有下列之一发生:

- 如果队列中有少于 n 位顾客, 以概率 λ , 有一位新顾客加入队列.
- 如果队列非空, 以概率 μ , 队列中的首位顾客接受服务并离开队列.
- 以剩余的概率, 队列不变.

如果 X_i 是 i 时刻队列中的顾客数, 那么在前述规则下, X_i 产生一个有限状态的马尔可夫链, 它的转移矩阵有下列非零元素:

$$\begin{aligned} P_{i,i+1} &= \lambda && \text{如果 } i < n; \\ P_{i,i-1} &= \mu && \text{如果 } i > 0; \\ P_{i,i} &= \begin{cases} 1 - \lambda & \text{如果 } i = 0, \\ 1 - \lambda - \mu & \text{如果 } 1 \leq i \leq n-1, \\ 1 - \mu & \text{如果 } i = n. \end{cases} \end{aligned}$$

马尔可夫链是不可约、有限且非周期的, 所以有唯一的平稳分布 $\bar{\pi}$. 我们利用 $\bar{\pi} = \bar{\pi}P$ 得到

$$\begin{aligned} \pi_0 &= (1 - \lambda)\pi_0 + \mu\pi_1, \\ \pi_i &= \lambda\pi_{i-1} + (1 - \lambda - \mu)\pi_i + \mu\pi_{i+1}, \quad 1 \leq i \leq n-1, \\ \pi_n &= \lambda\pi_{n-1} + (1 - \mu)\pi_n. \end{aligned}$$

容易验证

$$\pi_i = \pi_0 \left(\frac{\lambda}{\mu} \right)^i$$

是上述方程组的解. 加上要求 $\sum_{i=0}^n \pi_i = 1$, 有

$$\sum_{i=0}^n \pi_i = \sum_{i=0}^n \pi_0 \left(\frac{\lambda}{\mu} \right)^i = 1$$

或

$$\pi_0 = \frac{1}{\sum_{i=0}^n (\lambda/\mu)^i}$$

对所有 $0 \leq i \leq n$,

$$\pi_i = \frac{(\lambda/\mu)^i}{\sum_{i=0}^n (\lambda/\mu)^i} \quad (7.4) \quad [172]$$

在这种情况下计算平稳概率的另一种方法是利用割集. 对任意 i , 转移 $i \rightarrow i+1$ 及 $i+1 \rightarrow i$ 组成表示马尔可夫链的图的一个割集. 所以, 在平稳分布中, 从状态 i 移动到状态 $i+1$ 的概率必等于从状态 $i+1$ 移动到状态 i 的概率, 或

$$\lambda \pi_i = \mu \pi_{i+1}.$$

现在由简单的归纳可得

$$\pi_i = \pi_0 \left(\frac{\lambda}{\mu} \right)^i.$$

在队列中顾客数没有上限 n 的情况下, 马尔可夫链不再是有限的, 而有一个可数无穷的状態空间. 应用定理 7.11, 马尔可夫链有平稳分布, 当且仅当下面的线性方程组对所有 $\pi_i \geq 0$ 有解:

$$\begin{aligned} \pi_0 &= (1 - \lambda) \pi_0 + \mu \pi_1; \\ \pi_i &= \lambda \pi_{i-1} + (1 - \lambda - \mu) \pi_i + \mu \pi_{i+1}, \quad i \geq 1. \end{aligned} \quad (7.5)$$

容易验证

$$\pi_i = \frac{(\lambda/\mu)^i}{\sum_{i=0}^{\infty} (\lambda/\mu)^i} = \left(\frac{\lambda}{\mu} \right)^i \left(1 - \frac{\lambda}{\mu} \right)$$

是方程组(7.5)的解. 这自然地推广了式(7.4)给出的方程组中顾客数有上界 n 的情况的解. 所有 π_i 大于 0, 当且仅当 $\lambda < \mu$, 这相应于顾客到达的速度慢于他们接受服务的速度. 如果 $\lambda > \mu$, 那么顾客到达的速度快于他们离开的速度. 因此, 不存在平稳分布, 队列长度将成为任意长. 这时候, 马尔可夫链中的每个状态是瞬时的. $\lambda = \mu$ 的情况更微妙, 仍然不存在平稳分布, 队列将成为任意长, 但现在状态是零常返. (见有关的练习 7.17.)

7.4 无向图上的随机游动

无向图上的随机游动是一种常用于分析算法的特殊类型的马尔可夫链. 设 $G = (V, E)$ 是有限且无向的连通图.

定义 7.9 G 上的随机游动是由一个质点在 G 的顶点间移动的序列定义的马尔可夫链. 在这个过程中, 质点在已知时间步的位置是系统的状态. 如果质点在顶点 i , 且如果 i 有 $d(i)$ 条出发边, 那么质点沿着边 (i, j) 移动到邻点 j 的概率为 $1/d(i)$.

在分析随机化 2-SAT 算法时, 我们已经见过这种游动的一个例子.

对无向图上的随机游动问题, 有一个关于非周期性的如下的简单准则.

引理 7.12 无向图 G 上的随机游动是非周期的, 当且仅当 G 不是二部图.

证明 图是二部的, 当且仅当它没有奇数条边的圈. 在无向图中, 总存在一条从一个顶点到它自身的长为 2 的路. 如果图是二部图, 那么随机游动是周期的, 周期 $d=2$. 如果图不是二部的, 那么它有奇圈, 由经过那个圈, 我们有从任一顶点到它自身的奇数长度的路. 由此马尔可夫链是非周期的. ■

在这一节的其余部分, 我们假定 G 不是二部图. 在有限、无向、连通的非二部图 G 上的随机游动满足定理 7.7 的条件, 因此随机游动收敛于平稳分布. 我们证明这个分布只依赖于图

的次序列.

定理 7.13 G 上的随机游动收敛于平稳分布 $\bar{\pi}$, 其中

$$\pi_v = \frac{d(v)}{2|E|}.$$

证明 因为 $\sum_{v \in V} d(v) = 2|E|$, 由此

$$\sum_{v \in V} \pi_v = \sum_{v \in V} \frac{d(v)}{2|E|} = 1,$$

即 $\bar{\pi}$ 是 $v \in V$ 上严格意义的分布.

令 P 是马尔可夫链的转移概率矩阵, $N(v)$ 表示 v 的邻点. 关系式 $\bar{\pi} = \bar{\pi}P$ 等价于

$$\pi_v = \sum_{u \in N(v)} \frac{d(u)}{2|E|} \frac{1}{d(u)} = \frac{d(v)}{2|E|},$$

定理成立. ■

回忆 $h_{u,v}$ 表示从 v 到达 u 的期望步数, 我们有下面的推论.

推论 7.14 对 G 中任意顶点 u ,

$$h_{u,v} = \frac{2|E|}{d(u)}.$$

对任意一对顶点 u 和 v , 我们证明下列简单的界.

引理 7.15 如果 $(u, v) \in E$, 那么 $h_{u,v} < 2|E|$.

证明 设 $N(u)$ 是 G 中顶点 u 的邻点集合. 我们用两种不同方法计算 $h_{u,v}$:

$$\frac{2|E|}{d(u)} = h_{u,v} = \frac{1}{d(u)} \sum_{w \in N(u)} (1 + h_{w,v}).$$

所以,

$$2|E| = \sum_{w \in N(u)} (1 + h_{w,v}),$$

于是得到结论 $h_{u,v} < 2|E|$. ■

定义 7.10 图 $G = (V, E)$ 的覆盖时间是对所有的顶点 $v \in V$, 从 v 出发的随机游动访问图中所有结点的期望时间的最大值.

引理 7.16 $G = (V, E)$ 的覆盖时间有上界 $4|V| \cdot |E|$.

证明 选择 G 的一棵支撑树, 即选择一个边的子集, 它给出联结 G 的所有顶点的无圈图. 在这棵支撑树上存在一个循环(欧拉)旅行, 其中每条边在每个方向只经过一次; 例如, 进行深度优先搜索时, 由考虑通过的顶点序列可以找到这样一个旅行. 设 $v_0, v_1, \dots, v_{2|V|-2} = v_0$ 是从顶点 v_0 出发的旅行中的顶点序列, 显然, 通过旅行中顶点的期望时间是覆盖时间的上界. 因此覆盖时间的上界为

$$\sum_{i=0}^{2|V|-3} h_{v_0, v_{i+1}} < (2|V| - 2)(2|E|) < 4|V| \cdot |E|,$$

其中第一个不等式来自引理 7.15. ■

7.4.1 应用： $s-t$ 连通性算法

假设有一个无向图 $G=(V, E)$ 及 G 中的两个顶点 s 和 t . 令 $n = |V|$, $m = |E|$. 我们希望确定是否存在一条联结 s 和 t 的路. 利用标准的宽度优先搜索或深度优先搜索, 在线性时间内容易做到这一点, 但这些算法要求 $\Omega(n)$ 空间.

这里, 我们提出一种随机化算法(算法 7.4), 只要求 $O(\log n)$ 位内存, 即使小于所要求的位数, 也能写出 s 与 t 之间的路. 算法是简单的: 执行 G 上的随机游动足够多步, 使得从 s 到 t 的路似乎已经找到. 我们将覆盖时间的结果(引理 7.16)用于界定随机游动必须运行的步数. 为方便起见, 假定图 G 没有二部连通分支, 使得定理 7.13 的结果用于 G 的任一连通分支(用一些附加的技术性的工作可以将这个结果用于二部图).

算法 7.4 $s-t$ 连通性算法

1. 从 s 开始随机游动.
2. 如果游动在 $4n^3$ 步之内到达 t , 则返回存在一条路; 否则, 返回不存在路.

定理 7.17 $s-t$ 连通性算法(算法 7.4)以 $1/2$ 的概率返回正确答案, 当存在从 s 到 t 的路时, 它只会犯返回不存在这样的路的错误.

证明 如果不存在路, 那么算法返回正确答案. 如果存在路, 如果算法在 $4n^3$ 步游动内没有找到路, 则算法出错. 从 s 到达 t (如果存在一条路)的期望时间由它们的共享分支的覆盖时间给出上界, 由引理 7.16, 至多为 $4nm < 2n^3$. 由马尔可夫不等式, 游动需多于 $4n^3$ 步从 t 到达 s 的概率至多为 $1/2$. ■

算法必须保留它当前位置的踪迹, 取 $O(\log n)$ 位, 随机游动中取的步数也只取 $O(\log n)$ 位(因为只计数到 $4n^3$). 只要存在某种从每个顶点选取一个随机邻点的方法, 这便是要求的所有内存.

7.5 Parrondo 悖论

Parrondo 悖论提供了马尔可夫链分析的有意义的例子, 也演示了在涉及概率时的微妙性. 这个悖论与“两个错误不能产生一个正确”的古老谚语矛盾, 证明了两个输的游戏可以组合产生一个赢的游戏. 因为 Parrondo 悖论可以用各种不同的方法分析, 我们将仔细检查一些研究问题的方法.

首先考虑游戏 A , 我们反复投掷一枚有偏的硬币(称它为硬币 a), 以 $p_a < 1/2$ 的概率出现正面, 以 $1-p_a$ 的概率出现反面. 如果硬币出现正面, 你赢得一元; 如果出现反面, 则输掉一元. 显然对你来说这是一种输的游戏. 例如, 如果 $p_a = 0.49$, 每次游戏, 你的期望损失是两分.

在游戏 B 中, 我们仍是反复投掷硬币, 但投掷的硬币依赖于你在迄今为止的游戏中的表现如何. 设 w 是你到目前为止赢的次数, ℓ 是你输的次数. 每一轮赌一元, 所以 $w - \ell$ 表示你的输赢; 如果是负的, 你就是输钱. 游戏 B 使用两个有偏的硬币: 硬币 b 和硬币 c . 如果你赢的钱数是 3 的倍数, 那么你投掷硬币 b , 它以概率 p_b 出现正面, 以概率 $1-p_b$ 出现反面. 否则,

你掷硬币 c ，它以概率 p_c 出现正面，以概率 $1 - p_c$ 出现反面。如果硬币出现正面，你还是赢一元，如果出现反面，则输一元。

这个游戏比较复杂，所以我们考虑一个特殊的例子。假定硬币 b 以概率 $p_b = 0.09$ 出现正面，以概率 0.91 出现反面，而硬币 c 以概率 $p_c = 0.74$ 出现正面，以概率 0.26 出现反面。初一看，似乎游戏 B 对你有利。如果有 $1/3$ 时间你赢的是 3 的倍数，因此用硬币 b ，其余 $2/3$ 的时间用硬币 c ，那么你赢的概率 w 是

$$w = \frac{1}{3} \frac{9}{100} + \frac{2}{3} \frac{74}{100} = \frac{157}{300} > \frac{1}{2}.$$

按照这种路线推理的问题是硬币 b 不一定使用 $1/3$ 时间！为直观地理解这一点，考虑第一次开始游戏时，当你获利是 0 时会发生什么。你用硬币 b ，更可能输。此后，你用硬币 c ，更可能赢。在赢得一元或输掉两元之前，你可能花费大量时间来回于输一元与打破平局之间，所以你用硬币 b 可能多于 $1/3$ 的时间。

事实上，游戏 B 的特殊例子对你来说是一场输的游戏。证明这一点的一种方法是假定在你获利为 0 时开始玩游戏 B ，一直持续到你或者输掉三元或者赢得三元为止。如果在这种情况下，你输比赢更有可能，由对称性，每当你的获利是 3 的倍数时，你总是更可能输 3 元而不是赢 3 元。所以平均来讲，你显然在这种游戏中是输钱。

确定你是否输比赢更有可能的一种方法是分析吸收状态。考虑由整数 $\{-3, \dots, 3\}$ 组成的状态空间上的马尔可夫链，其中状态表示你的获利。我们希望知道，当你从 0 开始，在到达 3 之前你是否更可能到达 -3 。可以建立一个方程组来确定这个问题。设 z_i 表示你的当前获利是 i 元时，在你赢得 3 元以前输掉了 3 元而结束的概率。计算所有的概率 $z_{-3}, z_{-2}, z_{-1}, z_0, z_1, z_2$ 及 z_3 ，虽然我们实际上只对 z_0 有兴趣。如果 $z_0 > 1/2$ ，那么从 0 开始，我们更可能输 3 元而不是赢 3 元。这里 $z_{-3} = 1, z_3 = 0$ ，这些是边界条件。我们还有以下等式：

$$z_{-2} = (1 - p_c)z_{-3} + p_c z_{-1},$$

$$z_{-1} = (1 - p_c)z_{-2} + p_c z_0,$$

$$z_0 = (1 - p_b)z_{-1} + p_b z_1,$$

$$z_1 = (1 - p_c)z_0 + p_c z_2,$$

$$z_2 = (1 - p_c)z_1 + p_c z_3.$$

这是有 5 个未知量和 5 个方程的方程组，因此容易求解。 z_0 的一般解为

$$z_0 = \frac{(1 - p_b)(1 - p_c)^2}{(1 - p_b)(1 - p_c)^2 + p_b p_c}.$$

对这里的特殊例子，解为 $z_0 = 15\,379/27\,700 = 0.555$ ，说明长时间地玩这种游戏，输比赢有更

大可能。

代替直接解这些方程，还存在一种简单的方法来确定首先到达 -3 还是 3 的相对概率。考虑任一从 0 出发，在到达 -3 以前到达 3 而结束的移动序列。例如，一个可能的序列是

$$s = 0, 1, 2, 1, 2, 1, 0, -1, -2, -1, 0, 1, 2, 1, 2, 3.$$

我们用从序列中最后一个 0 开始的每个数取相反数的方法，对这样的序列与从 0 出发，在到达 3 之前于 -3 结束的序列之间建立一个一对一的自身映射。在这个例子中， s 映射成 $f(s)$ ，其中

$$f(s) = 0, 1, 2, 1, 2, 1, 0, -1, -2, -1, 0, -1, -2, -1, -2, -3.$$

容易验证这是相关序列的一对一映射.

下面的引理提供了 s 与 $f(s)$ 之间的一个有用的关系.

引理 7.18 对任一从 0 出发, 在到达 -3 之前于 3 结束的移动序列, 我们有

$$\frac{\Pr(s \text{ 出现})}{\Pr(f(s) \text{ 出现})} = \frac{p_b p_c^2}{(1-p_b)(1-p_c)^2}.$$

证明 对任一满足引理性质的已知序列 s , 令 t_1 为从 0 到 1 的转移次数; t_2 是从 0 到 -1 的转移次数; t_3 是从 -2 到 -1, -1 到 0, 1 到 2 及 2 到 3 的转移次数之和; t_4 是从 2 到 1, 1 到 0, -1 到 -2 及 -2 到 -3 的转移次数之和, 那么序列 s 出现的概率是 $p_b^{t_1}(1-p_b)^{t_2}p_c^{t_3}(1-p_c)^{t_4}$.

现在考虑将 s 变换为 $f(s)$ 时会发生什么. 我们将一个从 0 到 1 的转移变为从 0 到 -1 的转移. 由此, s 中上升 1 的转移总数比下降 1 的转移总数多 2, 这是因为序列在 3 结束. 那么在 $f(s)$ 中下降 1 的转移总数比上升 1 的转移总数多 2. 因此序列 $f(s)$ 出现的概率为 $p_b^{t_1-1}(1-p_b)^{t_2+1}p_c^{t_3-2}(1-p_c)^{t_4+2}$, 引理成立. ■

令 S 是所有从 0 出发且在到达 -3 之前于 3 结束的移动序列集合, 立即可得

$$\frac{\Pr(\text{在 } -3 \text{ 以前到达 } 3)}{\Pr(\text{在 } 3 \text{ 以前到达 } -3)} = \frac{\sum_{s \in S} \Pr(s \text{ 出现})}{\sum_{s \in S} \Pr(f(s) \text{ 出现})} = \frac{p_b p_c^2}{(1-p_b)(1-p_c)^2}.$$

如果这个比小于 1, 那么输比赢更有可能. 在我们的特殊例子中, 这个比是 $12\,321/15\,379 < 1$.

最后, 分析问题的另一种方法是利用平稳分布. 考虑状态 $\{0, 1, 2\}$ 上的马尔可夫链, 这里状态表示我们的获利被 3 除时的余数 (即状态记录了 $w - \ell \pmod{3}$ 的踪迹). 设 π_i 是这个链的平稳分布. 在平稳分布中, 我们赢一元钱的概率, 即如果玩足够长时间赢一元钱的极限概率为

$$\begin{aligned} p_b \pi_0 + p_c \pi_1 + p_c \pi_2 &= p_b \pi_0 + p_c (1 - \pi_0) \\ &= p_c - (p_c - p_b) \pi_0. \end{aligned}$$

我们同样想知道, 这是否大于或小于 $1/2$.

容易将平稳分布的等式写成

$$\begin{aligned} \pi_0 + \pi_1 + \pi_2 &= 1, \\ p_b \pi_0 + (1-p_c) \pi_2 &= \pi_1, \\ p_c \pi_1 + (1-p_b) \pi_0 &= \pi_2, \\ p_c \pi_2 + (1-p_c) \pi_1 &= \pi_0. \end{aligned}$$

实际上, 因为有 4 个等式而只有 3 个未知量, 这些等式中的一个实际上是多余的. 容易解此方程组而得

$$\begin{aligned} \pi_0 &= \frac{1-p_c+p_c^2}{3-2p_c-p_b+2p_b p_c+p_c^2}, \\ \pi_1 &= \frac{p_b p_c-p_c+1}{3-2p_c-p_b+2p_b p_c+p_c^2} \end{aligned}$$

$$\pi_2 = \frac{p_b p_c - p_b + 1}{3 - 2p_c - p_b + 2p_b p_c + p_c^2}.$$

回忆如果平稳分布中赢的概率小于 $1/2$, 或等价地, 如果 $p_c - (p_c - p_b)\pi_0 < 1/2$, 就会输. 在我们的特殊例子中, $\pi_0 = 673/1759 \approx 0.3826\cdots$, 且

$$p_c - (p_c - p_b)\pi_0 = \frac{86421}{175900} < \frac{1}{2}.$$

我们再次发现游戏 B 在长期运行中是一个输的游戏.

现在我们已经完全分析了游戏 A 和游戏 B . 下面考虑如果将这两个游戏结合起来会发生什么. 在游戏 C 中, 反复执行下面的赌博. 我们开始投掷一枚均匀的硬币, 称它为 d . 如果 d 是正面, 进行游戏 A ; 投掷硬币 a , 如果硬币是正面, 你赢. 如果 d 是反面, 那么进行游戏 B : 如果你当前获利是 3 的倍数, 投掷硬币 b , 否则投掷硬币 c , 且如果硬币是正面, 你赢. 对你来说, 这似乎必定是一场输的游戏. 毕竟游戏 A 和游戏 B 都是输的游戏, 这种游戏只是投掷一枚硬币来决定玩两种游戏中的哪一个.

事实上, 除了概率稍有不同以外, 游戏 C 精确地类似于 B . 如果你的获利是 3 的倍数, 那么你赢的概率是 $p'_b = \frac{1}{2}p_a + \frac{1}{2}p_b$. 否则, 你赢的概率是 $p'_c = \frac{1}{2}p_a + \frac{1}{2}p_c$. 用 p'_b, p'_c 代替 p_b, p_c , 我们可以重复前面用于对游戏 B 的分析. (180)

例如, 如果比

$$\frac{p'_b (p'_c)^2}{(1 - p'_b)(1 - p'_c)^2} < 1,$$

那么对你这是一场输的游戏; 如果比大于 1, 则是一场赢的游戏. 在我们的特殊例子中, 比为 $438741/420959 > 1$, 所以游戏 C 显然是一场赢的游戏.

这似乎有些奇怪, 所以利用考虑平稳分布的其他方法重新检查. 如果 $p'_c - (p'_c - p'_b)\pi_0 < 1/2$, 这是一场输的游戏, 而如果 $p'_c - (p'_c - p'_b)\pi_0 > 1/2$, 则是一场赢的游戏, 其中 π_0 现在是相应于游戏 C 的链的平稳分布. 在我们的特殊例子中, $\pi_0 = 30529/88597$, 且

$$p'_c - (p'_c - p'_b)\pi_0 = \frac{4456523}{8859700} > \frac{1}{2}.$$

所以游戏 C 仍是赢的游戏.

如何将两个输的游戏随机地结合产生一个赢的游戏? 关键是因为游戏 B 有一个非常特殊的构造, 所以才是一场输的游戏. 如果你的赢利被 3 整除, 在下一轮就可能输, 但如果你设法克服了那个初始障碍, 便可能赢得下面几次游戏. 凭借障碍使游戏 B 成为输的游戏. 用组合游戏的方法削弱障碍, 因为现在当你的赢利被 3 整除时, 有时你玩游戏 A , 这是接近于公平的游戏. 虽然游戏 A 偏向于对你不利, 但偏得很小, 所以它比初始障碍更容易克服, 组合游戏不再使它成为一场输的游戏所要求的特殊构造.

你可能担心这似乎违反了期望的线性律. 如果从一场游戏 A, B 及 C 的赢利(分别)为 X_a, X_b 及 X_c , 那么似乎有

$$E[X_c] = E\left[\frac{1}{2}X_a + \frac{1}{2}X_b\right] = \frac{1}{2}E[X_a] + \frac{1}{2}E[X_b],$$

所以, 如果 $E[X_A]$ 和 $E[X_B]$ 是负的, 那么 $E[X_C]$ 也应是负的. 问题是这个等式没有意义. 这是因为不涉及当前的赢利, 我们不可能谈论关于游戏 B 及 C 的期望赢利. 对游戏 B 和 C , 用状态 $\{0, 1, 2\}$ 上的马尔可夫链来描述. 设 s 表示当前状态, 我们有

$$\begin{aligned} E[X_C | s] &= E\left[\frac{1}{2}(X_A + X_B) | s\right] \\ &= \frac{1}{2}E[X_A | s] + \frac{1}{2}E[X_B | s]. \end{aligned}$$

对任一已知步, 期望的线性性成立, 但必须有当前状态的条件. 通过对游戏的组合, 我们改变了链在每个状态度过多久, 从而可以将两个输的游戏变成一个赢的游戏.

练习

7.1 考虑一个状态空间 $\{0, 1, 2, 3\}$ 及转移矩阵

$$P = \begin{bmatrix} 0 & 3/10 & 1/10 & 3/5 \\ 1/10 & 1/10 & 7/10 & 1/10 \\ 1/10 & 7/10 & 1/10 & 1/10 \\ 9/10 & 1/10 & 0 & 0 \end{bmatrix}$$

的马尔可夫链, 所以 $P_{0,3} = 3/5$ 是从状态 0 移动到状态 3 的概率.

(a) 求此马尔可夫链的平稳分布.

(b) 如果链从状态 0 出发, 求经 32 步后处于状态 3 的概率.

(c) 如果链是从 4 个状态中均匀随机选取的一个状态开始, 求经 128 步后处于状态 3 的概率.

(d) 假定链从状态 0 开始, 使 $\max_s |P'_{0,s} - \pi_s| \leq 0.01$ 成立的最小 t 值是什么? 这里 π 是平稳分布. 使 $\max_s |P'_{0,s} - \pi_s| \leq 0.001$ 成立的最小 t 值是什么?

7.2 考虑有下列转移矩阵

$$P = \begin{bmatrix} p & 1-p \\ 1-p & p \end{bmatrix}$$

的两状态马尔可夫链, 求 $P'_{0,0}$ 的一个简单表达式.

7.3 考虑有两个状态 0 和 1 的一个过程 X_0, X_1, X_2, \dots . 过程由两个矩阵 P 和 Q 控制. 如果 k 是偶数, 值 $P_{i,j}$ 给出在 X_k 到 X_{k+1} 的一步上从状态 i 到状态 j 的概率. 类似地, 如果 k 是奇数, 那么 $Q_{i,j}$ 给出由 X_k 到 X_{k+1} 的一步上从状态 i 到状态 j 的概率. 解释为什么这个过程不满足(时间齐次)马尔可夫链的定义 7.1, 然后给出一个有较大状态空间的过程, 它等价于这个过程, 且满足定义 7.1.

7.4 证明相通关系定义一个等价关系.

7.5 证明: 如果在相通类中一个状态是瞬时的(分别为常返的), 那么这个类中的所有状态是瞬时的(分别是常返的).

7.6 在研究 2-SAT 算法时, 我们考虑了一个在 0 处有一个完全反射边界的一维随机游动, 即

每当到达位置 0 时, 游动便以概率 1 在下一步移向位置 1. 现在考虑在 0 处有一个部分反射边界的随机游动. 每当到达位置 0 时, 游动便以 $1/2$ 的概率移向位置 1, 以 $1/2$ 的概率停留在 0 处. 随机游动处处都以 $1/2$ 的概率向上或向下移动 1. 从位置 i 出发, 利用部分反射边界的随机游动, 求到达 n 的期望移动次数.

[182]

- 7.7 假定 2-SAT 算法 7.1 以一个均匀随机选取的赋值开始, 这如何影响直到找到一个满足赋值的期望时间?
- 7.8 将 3-SAT 的随机化算法推广到 k -SAT, 作为 k 的函数, 算法的期望时间是什么?
- 7.9 在分析 3-SAT 随机化算法时, 我们作了悲观的假设, 即在每一步选取的子句中, 当前赋值 A_i 与真值赋值 S 只有一个变量的不同. 假定代之以每步是独立的, 两个赋值在子句中有一个变量不一致的概率为 p , 至少有两个变量不一致的概率为 $1-p$. p 的最大值是什么? 对此可以证明在算法 7.2 结束之前, 期望步数是 p 的多项式吗? 对这个 p 值给出证明, 并在这种情况下, 给出期望步数的一个上界.
- 7.10 图的着色是对其每个顶点的颜色的一种赋值. 一个图是 k -可着色的, 如果存在用 k 种颜色对图的着色, 使得没有两个相邻顶点有相同的颜色. 设 G 是 3-可着色图.
- (a) 证明存在用两种颜色的图的着色法, 使得没有三角形是单色的. (图 G 的三角形是 G 的有三个顶点的子图, 这些顶点全都相互毗邻.)
- (b) 考虑下列用两种颜色对 G 的顶点着色的算法, 使得没有三角形是单色的. 算法以对 G 的任意 2-着色法开始, 当 G 中有任意单色的三角形时, 算法选取一个这样的三角形, 并改变那个三角形中随机选取的一个顶点的颜色. 导出在算法找到具有所要求性质的 2-着色法之前, 这种着色的期望步数的一个上界.
- 7.11 一个元素为 $p_{i,j}$ 的 $n \times n$ 矩阵 P 称为随机的, 如果所有元素都是非负的, 且每行元素之和是 1. 称它为二重随机的, 如果每列元素之和也是 1. 证明对任一用二重随机矩阵表示的马尔可夫链, 均匀分布是平稳分布.
- 7.12 设 X_n 是一粒均匀骰子 n 次独立投掷的和. 证明, 对任意 $k \geq 2$,

$$\lim_{n \rightarrow \infty} \Pr(X_n \text{ 被 } k \text{ 整除}) = \frac{1}{k}.$$

- 7.13 考虑一个在 n 个状态上有平稳分布 $\bar{\pi}$ 及转移概率 $P_{i,j}$ 的有限马尔可夫链. 设想在时刻 0 开始的一个链, 运行 m 步后得到状态序列 X_0, X_1, \dots, X_m . 考虑相反次序的状态 X_m, X_{m-1}, \dots, X_0 .
- (a) 证明: 已知 X_{k+1} , 状态 X_k 与 $X_{k+2}, X_{k+3}, \dots, X_m$ 无关. 所以反向序列是马尔可夫的.
- (b) 证明: 对反向序列, 转移概率 $Q_{i,j}$ 由下式给出:
- $$Q_{i,j} = \frac{\pi_j P_{j,i}}{\pi_i}.$$
- (c) 证明: 如果原马尔可夫链是时间可逆的, 使得 $\pi_i P_{i,j} = \pi_j P_{j,i}$, 那么 $Q_{i,j} = P_{i,j}$. 即不

[183]

管从向前次序还是从向后次序考虑, 状态服从相同的转移概率.

- 7.14 证明: 相应于在无向、由一个分支组成的非二部图上的随机游动的马尔可夫链是时间可逆的.
- 7.15 设 $P_{i,i}^{(t)}$ 是一个马尔可夫链从状态 i 出发, 经 t 步后返回状态 i 的概率. 证明

$$\sum_{i=1}^n P_{i,i}^{(t)}$$

无界, 当且仅当状态 i 是常返的.

- 7.16 证明引理 7.5.
- 7.17 考虑下面的马尔可夫链, 它类似于在 0 处有完全反射边界的 1 维随机游动. 无论何时到达位置 0, 游动以概率 1 在下一步移动到位置 1. 否则, 游动以概率 p 从 i 移动到 $i+1$, 以概率 $1-p$ 从 i 移动到 $i-1$. 证明:
- (a) 若 $p < 1/2$, 每个状态是正常返的.
- (b) 若 $p = 1/2$, 每个状态是零常返的.
- (c) 若 $p > 1/2$, 每个状态是瞬时的.
- 7.18 (a) 考虑在 2 维整数格上的随机游动, 其中每点有 4 个邻点(上, 下, 左, 右). 每个状态是瞬时零常返的, 还是正常返的? 给出一个理由.
- (b) 对 3 维整数格, 回答(a)中的问题.
- 7.19 考虑赌徒破产问题, 其中一个选手一直玩到输了 ℓ_1 元或赢了 ℓ_2 元为止. 证明所玩游戏期望次数是 $\ell_1 \ell_2$.
- 7.20 我们已经考虑过游戏是公平情况下的赌徒破产问题. 现在考虑游戏是不公平的情况: 每次游戏输 1 元的概率是 $2/3$, 每次游戏赢 1 元的概率是 $1/3$. 假设开始时有 i 元, 当到达 n 元或全部输光时结束. 记 W_i 是 t 轮游戏后赢得的钱数.
- (a) 证明 $E[2^{W_{i+1}}] = E[2^{W_i}]$;
- (b) 利用(a)确定当从位置 i 开始时, 以 0 元结束的概率以及以 n 元结束的概率?
- (c) 将前面的证明推广到输的概率是 $p > 1/2$ 的情况(提示: 对某常数 c , 试考虑 $E[c^{W_i}]$).
- 7.21 考虑状态 $\{0, 1, \dots, n\}$ 上的马尔可夫链, 其中对 $i < n$, 有 $P_{i,i+1} = 1/2$, $P_{i,i-1} = 1/2$, 并且 $P_{n,n} = 1/2$, $P_{n,n-1} = 1/2$. 这个过程可以看作在顶点为 $\{0, 1, \dots, n\}$ 的有向图上的随机游动, 其中每个顶点有两条有向边: 一条返回 0, 一条移向下一个更大数的顶点(在顶点 n 处有一个自圈). 求这个链的平稳分布.(这个例子说明有向图上的随机游动与无向图上的随机游动有很大的不同.)
- 7.22 一只猫和一只老鼠在连通的、无向的、非二部图 G 上独立地随机游动. 他们在同一时间不同结点出发, 在每一时间步, 每个作一次转移. 如果它们在某个时间步处于相同结点, 猫吃掉老鼠. 设 n 和 m 分别表示 G 的顶点数和边数. 证明在猫吃掉老鼠以前, 期望时间的上界为 $O(m^2 n)$. (提示: 考虑一个马尔可夫链, 其状态为有序对 (a, b) , 其中 a 是猫的位置, b 是老鼠的位置.)
- 7.23 在网络上散布信息的一种方法是用传闻散布范例. 假定在网络上当前有 n 台主机. 最

初, 从一台主机一条信息开始, 每一轮有信息的每台主机从其余 $n-1$ 台主机中独立地且均匀随机地选取另一台主机进行联系, 并向那台主机发送信息. 我们想知道以 0.99 的概率, 在所有主机都收到信息之前需要多少轮.

(a) 解释如何将这个问题看成马尔可夫链.

(b) 在已知 $k-1$ 轮后有 i 台主机收到了信息的条件下, 确定计算在 k 轮后有 j 台主机收到信息的概率的方法. (提示: 有各种方法来进行, 一种方法是设 $P(i, j, c)$ 是在某轮中, 在 i 台主机的前 c 台已经做出了它们的选择之后, j 台主机收到信息的概率, 然后对 P 求一个递归式.)

(c) 作为一个计算练习, 写一段程序来确定 $n=128$ 时, 以 0.9999 的概率从一台主机开始的一条信息送到其余所有主机所需要的轮数.

- 7.24 n 个顶点的棒棒糖图是一个在 $n/2$ 个顶点上的团与 $n/2$ 个顶点上的路相连接的图, 如图 7.3 所示. 结点 u 是团与路的一部分, 令 v 表示路的另一端点.

185

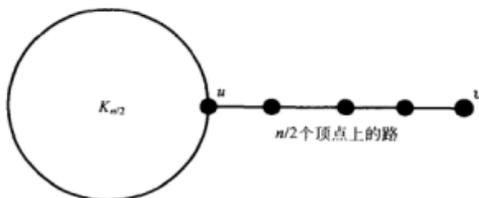


图 7.3 棒棒糖图

(a) 证明从 v 出发的随机游动的期望覆盖时间是 $\Theta(n^2)$.

(b) 证明从 u 出发的随机游动的期望覆盖时间为 $\Theta(n^3)$.

- 7.25 以下是简单的儿童棋类游戏的变形. 选手从位置 0 开始, 在一次选手的轮换中, 她投掷一粒标准的六面体骰子. 如果她的旧位置是正整数 x , 她掷出的是 y , 那么她的新位置是 $x+y$, 有两种情况除外:

- 如果 $x+y$ 可被 6 整除且小于 36, 她的新位置是 $x+y-6$.
- 如果 $x+y$ 大于 36, 选手仍停留在 x .

当一个选手抵达目的位置 36 时, 游戏结束.

(a) 设 X_i 是表示从位置 i ($0 \leq i \leq 35$) 到达 36 所需要的投掷次数的随机变量, 给出刻画 $E[X_i]$ 的方程组.

(b) 利用可以解线性方程组的程序, 对 $0 \leq i \leq 35$, 求 $E[X_i]$.

- 7.26 设在一个圆上标出了 n 个等距点, 不失一般性, 我们认为点是按顺时针方向从 0 到 $n-1$ 标记的. 初始, 一只狼从 0 处开始, 在其余 $n-1$ 个点的每处有一只羊. 狼在圆上随机游动, 每一步狼以 $1/2$ 的概率移动到一个邻点, 以 $1/2$ 的概率移动到另一个邻点. 在第一次到达一个点时, 如果在那里有一只羊, 狼就吃掉它. 哪只羊最可能是被最后吃掉的?

- 7.27 假定给出 n 个记录 R_1, R_2, \dots, R_n , 记录是以某种次序保存着的. 以这种次序的第 j 个记录的存取费用是 j . 这样, 如果有 4 个记录, 依次为 R_2, R_4, R_3, R_1 , 那么存取 R_4 的费用为 2, 存取 R_1 的费用为 4.

进一步假定, 在每一步, 记录 R_j 存取的概率为 p_j , 且每一步与其他各步独立. 如果预先知道 p_j 的值, 将依 p_j 的递减次序来保存 R_j . 但如果事先不知道 p_j , 我们可能利用启发式的“向前移动”: 每一步将要存取的记录放在列表的前头. 假定移动记录可以不需费用, 且其他记录保留相同次序. 例如, 如果在存取 R_3 之前的次序是 R_2, R_4, R_1, R_1 , 那么下一步的次序将是 R_3, R_2, R_4, R_1 .

在这种设置下, 记录的次序可以看作一个马尔可夫链的状态, 给出这个链的平稳分布. 令 X_k 是存取第 k 个请求的记录的费用, 确定 $\lim_{k \rightarrow \infty} E[X_k]$ 的表达式. 该表达式在已知 p_j 时, 应在关于 n 的多项式时间内容易计算.

- 7.28 考虑下面的离散时间队列的变形. 时间被分成固定长度的步, 每一时间步开始时, 一位顾客以概率 λ 到达. 在每一时间步结束时, 如果队列非空, 那么在队列前面的顾客以概率 μ 完成服务.
- 说明在每一时间步开始时队列中的顾客数如何形成一个马尔可夫链, 并确定相应的转移概率.
 - 说明在什么条件下, 可以期望存在一个平稳分布 $\bar{\pi}$.
 - 如果平稳分布存在, 那么 π_0 的值应是什么, 在时间步开始时, 队列中没有顾客的概率是什么? (提示: 考虑在长时间的运行中, 顾客进入队列的速度和顾客离开队列的速度必须相等.)
 - 确定平稳分布, 并说明这是如何对应于 (b) 中的条件?
 - 现在考虑变化的情况, 我们改变新的到达及服务的次序, 即在每个时间步开始时, 如果队列非空, 那么一位顾客以概率 μ 接受服务; 在每一时间步结束时, 一位顾客以概率 λ 到达. 如何改变对 (a) ~ (d) 的回答?



第8章 连续分布与泊松过程

本章介绍连续随机变量的一般概念，焦点是二个连续分布的例子：均匀分布与指数分布。然后研究泊松过程，它是一个与均匀分布及指数分布都有关的连续时间的计数过程。最后，以泊松过程在排队论中的基本应用结束本章。

8.1 连续随机变量

8.1.1 Ω 中的概率分布

图 8.1 中连续轮盘赌的转轮的圆周为 1，我们转动轮盘，当它停止时，得到从标有箭头的“0”开始的钟表式距离 x (以无限精度计算)。

这个试验的样本空间由 $[0, 1)$ 中所有实数组成。假定当圆盘停止时，盘的圆周上的任意一点都等可能地朝向箭头。一个已知结果 x 的概率 p 是多少？

为回答这个问题，我们回忆第 1 章定义的概率函数是任意满足以下三个要求的函数：

1. $\Pr(\Omega) = 1$.
2. 对任一事件 E ,
$$0 \leq \Pr(E) \leq 1$$
.
3. 对任意(有限或可数)不相交事件集合 B ,

$$\Pr\left(\bigcup_{E \in B} E\right) = \sum_{E \in B} \Pr(E).$$

记 $S(k)$ 是 $[0, 1)$ 中 k 个不同点的集合， p 是 $[0, 1)$ 内任一给定点为轮盘赌试验结果的概率。因为任一事件的概率都不会超过 1，

$$\Pr(x \in S(k)) = kp \leq 1.$$

我们可以在 $[0, 1)$ 内选取任意 k 个不同点，所以对任意整数 k 都必须有 $kp \leq 1$ ，这蕴涵 $p = 0$ 。这样，在无穷样本空间中，我们观测到了存在概率为 0 的可能事件。取这个事件的补，在无穷样本空间中，我们观测到了可能存在概率为 1 的事件，但并不对应于所有可能的试验结果，在某种意义上，也即可能存在概率为 1 的事件不是必然事件。

如果我们试验的每个可能结果的概率都是 0，那么该如何定义有非零概率的较大事件的概率？对 \mathbb{R} 上的概率分布，概率是赋予区间的，而不是赋予个别值^①。

一个随机变量 X 的概率分布由它的分布函数 $F(x)$ 给出，对任意 $x \in \mathbb{R}$ ，定义

$$F(x) = \Pr(X \leq x).$$

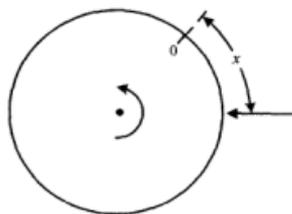


图 8.1 一个连续轮盘赌的转轮

① 不可数无穷概率空间的严格论述依赖于测度论，已超出本书范围。这里，我们只是注意概率函数需要事件集合的可测性。一般情况下，样本空间中的所有子集族不一定可测，但区间的博雷尔集合总是可测的。

我们说随机变量 X 是连续的, 如果它的分布函数 $F(x)$ 是 x 的连续函数. 我们将假定本章中的随机变量是连续的. 此时对任意特殊的 x 值, 必有 $\Pr(X=x)=0$. 而这进一步意味着 $\Pr(X \leq x) = \Pr(X < x)$, 这是一个本章中随意使用的事实.

如果存在函数 $f(x)$, 使得对一切 $-\infty < a < \infty$, 总有

$$F(a) = \int_{-\infty}^a f(t) dt,$$

则称 $f(x)$ 是 $F(x)$ 的密度函数, 且

$$f(x) = F'(x),$$

[189] 其中导数是合理定义的.

因为

$$\Pr(x < X \leq x + dx) = F(x + dx) - F(x) \approx f(x) dx,$$

所以可以不严格地将 $f(x) dx$ 作为无穷小区间 $[x, x + dx)$ 的“概率”. 以后与此类似地考虑, 在离散空间, 事件 E 的概率是包含在 E 中简单事件的概率之和. 对 \mathbb{R} 中的事件, 平行的概念是概率密度函数在 E 中基本事件上的积分.

例如区间 $[a, b)$ 的概率由积分

$$\Pr(a \leq X < b) = \int_a^b f(x) dx$$

给出, 密度函数为 $f(x)$ 的随机变量 X 的期望及高阶矩由积分

$$E[X^i] = \int_{-\infty}^{\infty} x^i f(x) dx$$

定义. 更一般地, 对任意的函数 g , 如果下面的积分存在, 则

$$E[g(X)] = \int_{-\infty}^{\infty} g(x) f(x) dx.$$

X 的方差为

$$\text{Var}[X] = E[(X - E[X])^2] = \int_{-\infty}^{\infty} (x - E[X])^2 f(x) dx = E[X^2] - (E[X])^2.$$

下面的引理给出了引理 2.9 在连续随机变量时的类似结果.

引理 8.1 设 X 是只取非负值的连续随机变量, 那么

$$E[X] = \int_0^{\infty} \Pr(X \geq x) dx.$$

证明 设 $f(x)$ 是 X 的密度函数, 那么

$$\begin{aligned} \int_{x=0}^{\infty} \Pr(X \geq x) dx &= \int_{x=0}^{\infty} \int_{y=x}^{\infty} f(y) dy dx \\ &= \int_{y=0}^{\infty} \int_{x=0}^y f(y) dx dy \\ &= \int_{y=0}^{\infty} y f(y) dy \\ &= E[X]. \end{aligned}$$

[190] 因为被积表达式是非负的, 所以可以交换积分的次序. ■

8.1.2 联合分布与条件概率

一个实值随机变量的分布函数的概念容易推广到多个随机变量的情况.

定义 8.1 X 和 Y 的联合分布函数是

$$F(x, y) = \Pr(X \leq x, Y \leq y).$$

变量 X 和 Y 有联合密度函数 f , 如果对所有 x, y ,

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) du dv.$$

当导数存在时, 我们仍然有

$$f(x, y) = \frac{\partial^2}{\partial x \partial y} F(x, y).$$

这些定义显然可以推广到多于两个变量的联合分布函数.

已知 X 和 Y 的联合分布函数, 可以考虑边缘分布函数

$$F_X(x) = \Pr(X \leq x), \quad F_Y(y) = \Pr(Y \leq y),$$

及相应的边缘密度函数 $f_X(x)$ 和 $f_Y(y)$.

定义 8.2 随机变量 X 和 Y 是独立的, 如果对所有 x, y ,

$$\Pr((X \leq x) \cap (Y \leq y)) = \Pr(X \leq x) \Pr(Y \leq y).$$

由这个定义, 两个随机变量是独立的, 当且仅当它们的联合分布函数是它们的边缘分布函数的乘积:

$$F(x, y) = F_X(x) F_Y(y).$$

关于 x 和 y 求导数可知, 如果 X 和 Y 独立, 那么

$$f(x, y) = f_X(x) f_Y(y),$$

这个条件也是充分的.

作为例子, 设 a, b 是正的常数, 考虑在 $x, y \geq 0$ 上, 由

$$F(x, y) = 1 - e^{-ax} - e^{-by} + e^{-(ax+by)}$$

给出的两个随机变量 X 和 Y 的联合分布函数. 可以求得

$$F_X(x) = F(x, \infty) = 1 - e^{-ax},$$

类似地, $F_Y(y) = 1 - e^{-by}$. 另外, 可以计算

$$f(x, y) = abe^{-(ax+by)},$$

由此可知

$$F_X(z) = \int_{x=0}^z \int_{y=0}^{\infty} abe^{-(ax+by)} dy dx = \int_{x=0}^z -ae^{-ax} = 1 - e^{-az}.$$

我们得到

$$F(x, y) = 1 - e^{-ax} - e^{-by} + e^{-(ax+by)} = (1 - e^{-ax})(1 - e^{-by}) = F_X(x) F_Y(y),$$

所以 X, Y 独立. 也可以用密度函数验证它们的独立性

$$f_X(x) = ae^{-ax}, \quad f_Y(y) = be^{-by}, \quad f(x, y) = f_X(x) f_Y(y).$$

连续随机变量的条件概率提出了一个重要而敏感的问题. 当 $\Pr(F) \neq 0$ 时, 自然的定义

$$\Pr(E|F) = \frac{\Pr(E \cap F)}{\Pr(F)}$$

是合适的. 例如, 当 $\Pr(Y \leq 6)$ 不为零时,

$$\Pr(X \leq 3 | Y \leq 6) = \frac{\Pr((X \leq 3) \cap (Y \leq 6))}{\Pr(Y \leq 6)}.$$

在离散情况, 如果 $\Pr(F) = 0$, 很简单, $\Pr(E|F) = 0$ 是没有定义的. 但在连续情况, 在以概率 0 发生的事件的条件下, 条件概率有明确的表示式. 例如, 对前面讨论过的联合分布函数 $F(x, y) = 1 - e^{-ax} - e^{-by} + e^{-(ax+by)}$, 考虑

$$\Pr(X \leq 3 | Y = 4)$$

似乎是合理的, 但由于 $\Pr(Y = 4)$ 是概率为 0 的事件, 定义不适用.

如果应用定义, 应有

$$\Pr(X \leq 3 | Y = 4) = \frac{\Pr((X \leq 3) \cap (Y = 4))}{\Pr(Y = 4)}.$$

分子和分母都为零, 启发我们考虑它们都趋于零时的极限. 自然的选择是

$$\Pr(X \leq 3 | Y = 4) = \lim_{\delta \rightarrow 0} \Pr(X \leq 3 | 4 \leq Y \leq 4 + \delta).$$

这个选择导出如下的定义:

$$\Pr(X \leq x | Y = y) = \int_{a--}^x \frac{f(u, y)}{f_y(y)} du.$$

192 要非正式地理解为什么这是一个合理的选择, 考虑

$$\begin{aligned} & \lim_{\delta \rightarrow 0} \Pr(X \leq x | y \leq Y \leq y + \delta) \\ &= \lim_{\delta \rightarrow 0} \frac{\Pr((X \leq x) \cap (y \leq Y \leq y + \delta))}{\Pr(y \leq Y \leq y + \delta)} \\ &= \lim_{\delta \rightarrow 0} \frac{F(x, y + \delta) - F(x, y)}{F_y(y + \delta) - F_y(y)} \\ &= \lim_{\delta \rightarrow 0} \int_{a--}^x \frac{\partial F(u, y + \delta) / \partial x - \partial F(u, y) / \partial x}{F_y(y + \delta) - F_y(y)} du \\ &= \int_{a--}^x \lim_{\delta \rightarrow 0} \frac{(\partial F(u, y + \delta) / \partial x - \partial F(u, y) / \partial x) / \delta}{(F_y(y + \delta) - F_y(y)) / \delta} du \\ &= \int_{a--}^x \frac{f(u, y)}{f_y(y)} du. \end{aligned}$$

这里, 我们假定了可以交换积分与极限的次序, 且 $f_y(y) \neq 0$.

值

$$f_{x|y}(x, y) = \frac{f(x, y)}{f_y(y)}$$

也称为条件密度函数. 类似地, 有

$$f_{y|x}(x, y) = \frac{f(x, y)}{f_x(x)}.$$

我们的定义有一个自然的解释, 即为了计算 $\Pr(X \leq x | Y = y)$, 在适当的范围内对相应的

条件密度函数求积分. 可以检查, 通过适当的积分, 这个定义给出了 $\Pr(X \leq x | Y \leq y)$ 的标准定义. 类似地, 可以利用条件密度函数计算条件期望

$$E[X | Y = y] = \int_{x=-\infty}^{\infty} xf_{X|Y}(x, y) dx.$$

例如, 当 $F(x, y) = 1 - e^{-ax} - e^{-by} + e^{-(ax+by)}$ 时,

$$\Pr(X \leq 3 | Y = 4) = \int_{x=0}^3 \frac{abe^{-ax+4b}}{be^{-4b}} du = 1 - e^{-3a},$$

这也是一个可以利用独立性直接得到的结果.

8.2 均匀分布

当一个随机变量 X 假定在区间 $[a, b]$ 上取值, 使得所有等长的小区间有相等的概率, 我们称 X 是在区间 $[a, b]$ 上的均匀分布, 或称它在区间 $[a, b]$ 上是均匀的. 用 $U[a, b]$ 来表示这样的随机变量. 我们也可以讨论在区间 $[a, b)$, $(a, b]$ 或 (a, b) 上的均匀分布. 事实上, 因为当 $b > a$ 时取任一特殊值的概率为 0, 这些分布本质上是相同的. [193]

这样一个 X 的概率分布函数为

$$F(x) = \begin{cases} 0 & \text{如果 } x \leq a, \\ \frac{x-a}{b-a} & \text{如果 } a \leq x \leq b, \\ 1 & \text{如果 } x \geq b, \end{cases}$$

它的密度函数是

$$f(x) = \begin{cases} 0 & \text{如果 } x < a, \\ \frac{1}{b-a} & \text{如果 } a \leq x \leq b, \\ 0 & \text{如果 } x > b. \end{cases}$$

它们如图 8.2 所示.

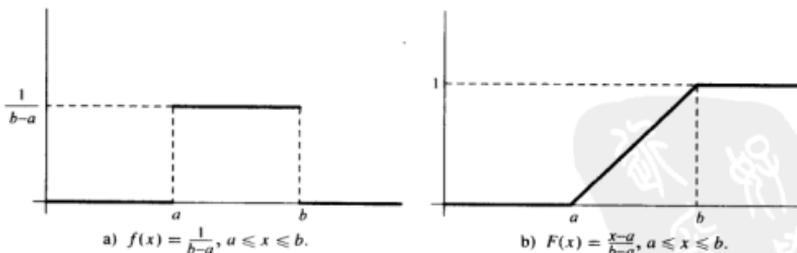


图 8.2 均匀分布

X 的期望是

$$E[X] = \int_a^b \frac{x}{b-a} dx = \frac{b^2 - a^2}{2(b-a)} = \frac{b+a}{2},$$

二阶矩为

$$E[X^2] = \int_a^b \frac{x^2}{b-a} dx = \frac{b^3 - a^3}{3(b-a)} = \frac{b^2 + ab + a^2}{3}.$$

方差如下计算:

$$\text{Var}[X] = E[X^2] - (E[X])^2 = \frac{b^2 + ab + a^2}{3} - \frac{(b+a)^2}{4} = \frac{(b-a)^2}{12}.$$

在连续的轮盘赌例子中, 试验的结果 X 为 $[0, 1)$ 上的均匀分布, 所以 X 的期望为 $1/2$, 方差为 $1/12$.

8.2.1 均匀分布的其他性质

假设有一个从譬如 $[0, 1]$ 上的均匀分布中选取的随机变量 X , 而且还知道 X 小于等于 $1/2$. 由这个信息, X 的条件分布在一个较小区间 $[0, 1/2]$ 上仍是均匀的.

引理 8.2 设 X 是 $[a, b]$ 上的均匀随机变量, 那么, 对 $c \leq d$,

$$\Pr(X \leq c | X \leq d) = \frac{c-a}{d-a}.$$

也就是说, 在 $X \leq d$ 的条件下, X 在 $[a, d]$ 上是均匀的.

证明

$$\begin{aligned} \Pr(X \leq c | X \leq d) &= \frac{\Pr((X \leq c) \cap (X \leq d))}{\Pr(X \leq d)} \\ &= \frac{\Pr(X \leq c)}{\Pr(X \leq d)} \\ &= \frac{c-a}{d-a}. \end{aligned}$$

由此可知, 在 X 小于等于 d 的条件下, X 精确地有在 $[a, d]$ 上均匀随机变量的分布函数. ■

当然, 如果考虑 $\Pr(X \leq c | X \geq d)$, 也有类似的结论成立; 在 $X \geq d$ 的条件下, 所得的分布是 $[d, b]$ 上的均匀分布.

均匀分布的另一个事实来自这样的直觉: 如果 n 个点均匀地分布在一个区间上, 我们期望它们有大致相等的间距. 将这一思想整理成如下的引理.

引理 8.3 设 X_1, X_2, \dots, X_n 是 $[0, 1]$ 上独立的均匀随机变量, Y_1, Y_2, \dots, Y_n 与 X_1, X_2, \dots, X_n 有相同的值, 且以增序排列, 那么 $E[Y_k] = k/(n+1)$.

证明 我们首先用显式计算证明关于 Y_1 的结果. 由定义, $Y_1 = \min(X_1, X_2, \dots, X_n)$, 现在

$$\begin{aligned} \Pr(Y_1 \geq y) &= \Pr(\min(X_1, X_2, \dots, X_n) \geq y) \\ &= \Pr((X_1 \geq y) \cap (X_2 \geq y) \cap \dots \cap (X_n \geq y)) \\ &= \prod_{i=1}^n \Pr(X_i \geq y) \\ &= (1-y)^n. \end{aligned}$$

由引理 8.1 可知

$$E[Y_1] = \int_{y=0}^1 (1-y)^n dy = \frac{1}{n+1}.$$

另外, 也可利用 $F(y) = 1 - (1-y)^n$, 得到 Y_1 的密度函数为 $f(y) = n(1-y)^{n-1}$, 并由分部积分得

$$E[Y_1] = \int_{y=0}^1 ny(1-y)^{n-1} dy = -y(1-y)^n \Big|_{y=0}^{y=1} + \int_{y=0}^1 (1-y)^n dy = \frac{1}{n+1}.$$

[195]

经某种计算, 这个分析可以推广到求 $E[Y_k]$, 我们留作练习 8.5. 但是, 一个简单的方法是利用对称性. 考虑圆周长为 1 的圆, 并独立地且均匀随机地在圆上放 $n+1$ 个点 P_0, P_1, \dots, P_n . 这等价于 8.1.1 节用连续轮盘赌的一次旋转来选择每个点. 将 P_0 点标为 0, 令 X_i 是从 P_0 到 P_i 的按顺时针方向的钟表式距离, 那么 X_i 是来自 $[0, 1]$ 的独立、均匀的随机变量, 值 Y_k 恰好是从 P_0 开始沿顺时针方向到第 k 点所经过的钟表式距离, 见图 8.3.

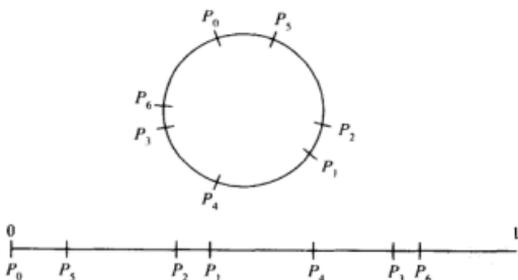


图 8.3 圆上的随机点与直线上的随机点之间的对应

Y_k 与 Y_{k+1} 之间的距离是两个相应邻点之间的弧长. 但由对称性, 所有相邻点之间的弧长必有相同的期望长度. 因为 n 个点产生了 $n+1$ 条弧, 而且它们的总长度为 1, 所以每个弧的期望长度为 $1/(n+1)$. 由期望的线性性, $E[Y_k]$ 是前 k 段弧的期望长度之和, 因此 $E[Y_k] = k/(n+1)$. ■

这个证明利用了从 $[0, 1]$ 中独立且均匀随机地选取 n 个点与在周长为 1 的圆上独立且均匀随机地选取 $n+1$ 个点之间的一一对应. 当这种关系可以利用时常能极大地简化冗长的证明. 本章中我们还将给出更多的类似的关系.

8.3 指数分布

另一个重要的连续分布是指数分布.

定义 8.3 一个参数为 θ 的指数分布由下面的概率分布函数给出:

$$F(x) = \begin{cases} 1 - e^{-\theta x} & \text{如果 } x \geq 0, \\ 0 & \text{其他.} \end{cases}$$

[196]

指数分布的密度函数是

$$f(x) = \theta e^{-\theta x}, \quad x \geq 0.$$

见图 8.4.

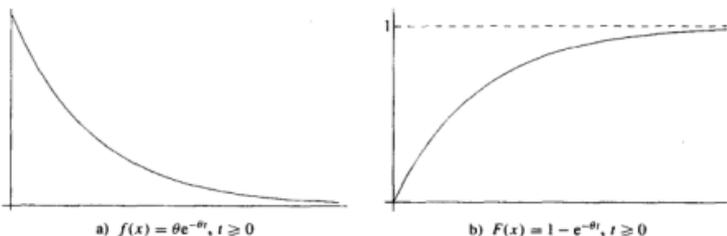


图 8.4 指数分布

它的一、二阶矩是

$$E[X] = \int_0^{\infty} t \theta e^{-\theta t} dt = \frac{1}{\theta},$$

$$E[X^2] = \int_0^{\infty} t^2 \theta e^{-\theta t} dt = \frac{2}{\theta^2}.$$

因此

$$\text{Var}[X] = E[X^2] - (E[X])^2 = \frac{1}{\theta^2}.$$

8.3.1 指数分布的其他性质

类似于离散的几何分布，指数分布的最重要性质也许是它的无记忆性。

引理 8.4 对参数为 θ 的指数随机变量，

$$\Pr(X > s + t | X > t) = \Pr(X > s).$$

证明

$$\begin{aligned} \Pr(X > s + t | X > t) &= \frac{\Pr(X > s + t)}{\Pr(X > t)} \\ &= \frac{1 - \Pr(X \leq s + t)}{1 - \Pr(X \leq t)} \\ &= \frac{e^{-\theta(s+t)}}{e^{-\theta t}} \\ &= e^{-\theta s} \\ &= \Pr(X > s). \end{aligned}$$

指数分布是唯一的无记忆性的连续分布。几何分布是唯一的无记忆性的离散分布，因此可以将指数分布看作离散几何分布的连续形式。几何分布是在一系列独立相同的伯努利试验中直到首次成功的次数模型，而指数分布是在一个无记忆的连续时间随机过程中直到首事件出现的时间模型。

几个指数随机变量的最小值也具有某些有意义的性质。

引理 8.5 如果 X_1, X_2, \dots, X_n 是独立的指数分布随机变量，参数分别为 $\theta_1, \theta_2, \dots$,

θ_n , 那么 $\min(X_1, X_2, \dots, X_n)$ 是参数为 $\sum_{i=1}^n \theta_i$ 的指数分布, 且

$$\Pr(\min(X_1, X_2, \dots, X_n) = X_i) = \frac{\theta_i}{\sum_{i=1}^n \theta_i}.$$

证明 只需证明两个指数随机变量的情况即可, 由归纳法可得一般情况. 设 X_1, X_2 是参数为 θ_1, θ_2 的独立指数随机变量, 那么

$$\begin{aligned}\Pr(\min(X_1, X_2) > x) &= \Pr((X_1 > x) \cap (X_2 > x)) \\ &= \Pr(X_1 > x) \Pr(X_2 > x) \\ &= e^{-\theta_1 x} e^{-\theta_2 x} \\ &= e^{-(\theta_1 + \theta_2)x}.\end{aligned}$$

因此, 最小值是参数 $\theta_1 + \theta_2$ 的指数分布.

进一步, 设 $f(x_1, x_2)$ 是 (X_1, X_2) 的联合分布密度函数. 因为变量是独立的, 我们有 $f(x_1, x_2) = \theta_1 e^{-\theta_1 x_1} \theta_2 e^{-\theta_2 x_2}$. 因此

$$\begin{aligned}\Pr(X_1 < X_2) &= \int_{x_2=0}^{\infty} \int_{x_1=0}^{x_2} f(x_1, x_2) dx_1 dx_2 \\ &= \int_{x_2=0}^{\infty} \theta_2 e^{-\theta_2 x_2} \left(\int_{x_1=0}^{x_2} \theta_1 e^{-\theta_1 x_1} dx_1 \right) dx_2 \\ &= \int_{x_2=0}^{\infty} \theta_2 e^{-\theta_2 x_2} (1 - e^{-\theta_1 x_2}) dx_2 \\ &= \int_{x_2=0}^{\infty} (\theta_2 e^{-\theta_2 x_2} - \theta_2 e^{-(\theta_1 + \theta_2)x_2}) dx_2 \\ &= 1 - \frac{\theta_2}{\theta_1 + \theta_2} \\ &= \frac{\theta_1}{\theta_1 + \theta_2}.\end{aligned}$$

例如, 假设一条航线的售票柜台有 n 个服务代理人, 其中第 i 个代理人为每个顾客服务所需的时间是参数为 θ_i 的指数分布, 你在时刻 T_0 站在队伍的最前面, 所有 n 个代理人都忙着, 你为等到一个代理人的平均时间是多少?

因为服务时间是指数分布的, 在时刻 T_0 前, 每个代理人已经帮助另一顾客多长时间并不重要, 对每个顾客的剩余时间仍然服从指数分布, 这是指数分布无记忆性的特征. 由引理 8.5, 直到首个代理人空闲的时间是参数为 $\sum_{i=1}^n \theta_i$ 的指数分布, 所以期望等待时间是 $1 / \sum_{i=1}^n \theta_i$. 实际上,

你甚至可以确定每个代理人成为首个有空闲的概率, 第 j 个代理人首先有空闲的概率为 $\theta_j / \sum_{i=1}^n \theta_i$.

8.3.2 例: 有反馈的球和箱子

作为指数分布的一个应用, 我们考虑标准的球和箱子模型的一种有意义的变形. 在这个问题中, 只有两个箱子, 球一个接一个地来到. 最初, 两个箱子里都至少有一个球. 假定当箱子

1 有 x 个球, 箱子 2 有 y 个球时, 箱子 1 得到下一个球的概率是 $x/(x+y)$, 而箱子 2 得到下一个球的概率是 $y/(x+y)$. 这个系统具有反馈: 一个箱子里的球越多, 以后就有可能得到更多的球. 一个等价的问题是练习 1.6 给出的. 你可能希望检查(用归纳法)如果两个箱子开始时都只有一个球且总共有 n 个球, 那么箱子 1 中的球的个数是 $[1, n-1]$ 上的均匀分布.

假定以下列方式加强反馈. 如果箱子 1 有 x 个球, 箱子 2 有 y 个球, 那么箱子 1 得到下一个球的概率为 $x^p/(x^p+y^p)$, 箱子 2 得到下一个球的概率为 $y^p/(x^p+y^p)$, $p > 1$. 例如, 当 $p=2$ 时, 如果箱子 1 有三个球, 箱子 2 有四个球, 那么下一个球进入箱子 1 的概率只有 $9/25 < 3/7$. 设置 $p > 1$ 加强了有较多球的那个箱子的优势.

这个模型被提议用于描述垄断造成的经济形势. 例如, 假定有两个操作系统: Lindows 和 Winux. 为了保持兼容性, 用户倾向于购买与别用户相同操作系统的机器. 这种效应关于每个操作系统的用户数量可以是非线性的, 用参数 p 对此建模.

现在给出一个值得注意的结果: 只要 $p > 1$, 必存在某个点, 此时一个箱子得到掷出的所有余下的球. 在经济学中, 这是一个非常强的垄断形式, 其他竞争者无条件地中止得到新的顾客.

定理 8.6 在任意初始条件下, 如果 $p > 1$, 那么以概率 1 存在一个数 c , 使得两个箱子中有一个不会得到多于 c 个球.

注意定理的措辞. 我们并没有说存在某个固定的 c (也许依赖于初始条件), 使得一个箱子不会有多于 c 个球. (如果有这个意思, 就会说存在一个数 c , 使得一个箱子以概率 1 不会有多于 c 个球.) 而是说是以概率 1 在某点(我们并不知道前面的时间)一个箱子停止得到球.

证明 为方便起见, 假定两个箱开始时都有一个球, 这并不影响结果.

先考虑一个密切相关的过程. 设两个箱子开始时在时刻 0 都有一个球. 球到达每个箱子, 如果箱子 1 在时刻 t 得到了第 z 个球, 那么它在时刻 $t+T_z$ 得到下一个球, 其中 T_z 是参数为 z^p 的指数分布的随机变量. 类似地, 如果箱子 2 在时刻 t 得到了第 z 个球, 那么它在时刻 $t+U_z$ 得到下一个球, 其中 U_z 也是参数为 z^p 的指数分布的随机变量. 所有 T_z 和 U_z 的值都是独立的, 在这个方案中, 每个箱子可独立地考虑, 一个箱子发生的事情并不影响另一个箱子.

虽然这个过程似乎与原问题没有关系, 但我们认为这是精确的模仿. 考虑一个球到达的那个时刻, 箱子 1 有 x 个球, 箱子 2 有 y 个球. 由指数分布的无记忆性, 最近到达的球落入哪个箱子并不重要, 下一个球落入箱子 1 的时间服从均值为 x^p 的指数分布, 下一个球落入箱子 2 的时间服从均值为 y^p 的指数分布, 而且由引理 8.5, 下一个球落入箱子 1 的概率为 $x^p/(x^p+y^p)$, 落入箱子 2 的概率为 $y^p/(x^p+y^p)$. 所以, 这个方案精确地模仿了原问题中所发生的事情, 见图 8.5.

我们用 $F_1 = \sum_{j=1}^{\infty} T_j$ 定义箱子 1 的饱和时间, 类似地, $F_2 = \sum_{j=1}^{\infty} U_j$ 是箱子 2 的饱和时间.

饱和时间表示一个箱子收到球的总数为无界的第一时间. 饱和时间并不显然是有明确定义的随机变量: 如果和不收敛, 因而它的值为无穷时, 将会怎样呢? 这里利用 $p > 1$ 的事实, 我们有

$$E[F_1] = E\left[\sum_{j=1}^{\infty} T_j\right] = \sum_{j=1}^{\infty} E[T_j] = \sum_{j=1}^{\infty} \frac{1}{j^p}.$$

这里利用了可数无穷随机变量和的期望的线性性, 如果 $\sum_{j=1}^{\infty} E[|T_j|]$ 收敛, 期望的线性性是成立的. (第 2 章讨论了可数无穷和期望线性性的应用, 特别见练习 2.29.) 只需证明当 $p > 1$ 时 $\sum_{j=1}^{\infty} 1/j^p$ 收敛于一个有限数即可. 经适当的积分可知, 和的有界性成立:

$$\sum_{j=1}^{\infty} \frac{1}{j^p} \leq 1 + \int_{n=1}^{\infty} \frac{1}{u^p} du = 1 + \frac{1}{p-1}.$$

实际上所有整数阶矩都收敛于一个有限数. 由此, F_1 和 F_2 都以概率 1 有限, 故有定义.

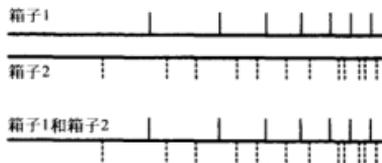


图 8.5 在这个方案中, 球到达之间的时间间隔是指数分布的, 每个箱子可以分别考虑, 只要简单地将两个箱子的时间轴合在一起, 就可得到原过程的结果

进一步, F_1 和 F_2 以概率 1 是不同的. 为证明这一点, 假定除了 T_1 , 随机变量 T_j 和 U_j 的所有值都已知, 那么对 F_1 等于 F_2 情况, 必然有

$$T_1 = \sum_{j=1}^{\infty} U_j - \sum_{j=2}^{\infty} T_j.$$

但 T_1 取任一特定值的概率为 0, 就像轮盘赌的转轮取某个特定值的概率为 0 一样. 因此以概率 1, $F_1 \neq F_2$.

假设 $F_1 < F_2$, 那么对某个 n , 必有

$$\sum_{j=1}^n U_j < F_1 < \sum_{j=1}^{n+1} U_j.$$

这蕴涵对任意充分大的数 m ,

$$\sum_{j=1}^n U_j < \sum_{i=1}^m T_i < \sum_{j=1}^{n+1} U_j,$$

即在箱子 2 得到它的 $(n+1)$ 个球之前, 箱子 1 已得到了 m 个球. 因为我们的新过程精确地对应于球与箱子原过程, 也即精确地对应于原过程所发生的一切. 但这意味着一旦箱子 2 有 n 个球后就不能再得到任何别的球了, 它们全到箱子 1 中去了. 如果 $F_2 < F_1$, 证明是类似的. 因此以概率 1 存在某个 n , 使得一个箱子不能有多于 n 个球. ■

当 p 接近于 1 或两个箱子里开始时大量的且几乎相等个数的球时, 在一个箱子足以得到

这样一个垄断的控制之前,可能需要一个很长的时间. 另一方面, 当 p 比 1 大得多(譬如 $p=2$) 且每个箱子开始时都只有一个球时, 垄断很快发生. 在练习 8.24 中会要求你模拟这个过程.

8.4 泊松过程

泊松过程是一个与均匀分布和指数分布都有关的重要的计数过程. 考虑一个随机事件序列, 如一个队列中顾客的到达或从放射性物质中 α 粒子的发射. 设 $N(t)$ 表示在时间间隔 $[0, t]$ 内的事件数, 过程 $\{N(t), t \geq 0\}$ 是一个随机计数过程.

定义 8.4 参数(或速度)为 λ 的泊松过程是使以下陈述成立的随机计数过程 $\{N(t), t \geq 0\}$:

1. $N(0) = 0$.
2. 过程有独立平稳增量, 也即对任意的 $t, s > 0$, $N(t+s) - N(s)$ 的分布与 $N(t)$ 的分布相同, 且对任意两个不相交的区间 $[t_1, t_2]$ 和 $[t_3, t_4]$, $N(t_2) - N(t_1)$ 的分布与 $N(t_4) - N(t_3)$ 的分布独立.
3. $\lim_{t \rightarrow 0} \Pr(N(t) = 1)/t = \lambda$, 即在短的时间间隔 t 内的单个事件的概率趋于 λt .
4. $\lim_{t \rightarrow 0} \Pr(N(t) \geq 2)/t = 0$, 即在短的时间间隔 t 内, 多于一个事件的概率趋于 0.

令人惊讶的是这个广泛而相对自然的条件定义了唯一的过程. 特别是在一个给定的时间间隔内的事件个数服从 5.3 节定义的泊松分布.

定理 8.7 设 $\{N(t) | t \geq 0\}$ 是参数为 λ 的泊松过程, 对任意的 $t, s \geq 0$ 及任意的整数 $n \geq 0$,

$$P_n(t) = \Pr(N(t+s) - N(s) = n) = e^{-\lambda t} \frac{(\lambda t)^n}{n!}.$$

证明 我们首先看到由定义 8.4 的第 2 个性质, $P_n(t)$ 是合理定义的, $N(t+s) - N(s)$ 的分布只依赖于 t 而与 s 无关.

为计算 $P_0(t)$, 我们注意到区间 $[0, t]$ 和 $[t, t+h]$ 中事件个数是独立的随机变量, 所以

$$P_0(t+h) = P_0(t)P_0(h).$$

现在记

$$\begin{aligned} \frac{P_0(t+h) - P_0(t)}{h} &= P_0(t) \frac{P_0(h) - 1}{h} \\ &= P_0(t) \frac{1 - \Pr(N(h) = 1) - \Pr(N(h) \geq 2) - 1}{h} \\ &= P_0(t) \frac{-\Pr(N(h) = 1) - \Pr(N(h) \geq 2)}{h}. \end{aligned}$$

取 $h \rightarrow 0$ 时的极限, 由定义 8.4 的性质 2-4, 我们得到

$$\begin{aligned} P'_0(t) &= \lim_{h \rightarrow 0} \frac{P_0(t+h) - P_0(t)}{h} \\ &= \lim_{h \rightarrow 0} P_0(t) \frac{-\Pr(N(h) = 1) - \Pr(N(h) \geq 2)}{h} \\ &= -\lambda P_0(t). \end{aligned}$$

为解

$$P_0'(t) = -\lambda P_0(t),$$

我们将它改写为

$$\frac{P_0'(t)}{P_0(t)} = -\lambda.$$

关于 t 积分得

$$\ln P_0(t) = -\lambda t + C,$$

或

$$P_0(t) = e^{-\lambda t + C}.$$

因为 $P_0(0) = 1$, 我们得到

$$P_0(t) = e^{-\lambda t}. \quad (8.1)$$

对 $n \geq 1$, 记

$$\begin{aligned} P_n(t+h) &= \sum_{k=0}^n P_{n-k}(t) P_k(h) \\ &= P_n(t) P_0(h) + P_{n-1}(t) P_1(h) + \sum_{k=2}^n P_{n-k}(t) \Pr(N(h) = k). \end{aligned}$$

计算 $P_n(t)$ 的一阶导数得

$$\begin{aligned} P_n'(t) &= \lim_{h \rightarrow 0} \frac{P_n(t+h) - P_n(t)}{h} \\ &= \lim_{h \rightarrow 0} \frac{1}{h} \left(P_n(t) (P_0(h) - 1) + P_{n-1}(t) P_1(h) + \sum_{k=2}^n P_{n-k}(t) \Pr(N(h) = k) \right) \\ &= -\lambda P_n(t) + \lambda P_{n-1}(t), \end{aligned}$$

其中用到了事实

$$\lim_{h \rightarrow 0} \frac{P_1(h)}{h} = \lambda$$

(由性质 2 及 3) 及

$$0 \leq \lim_{h \rightarrow 0} \frac{1}{h} \sum_{k=2}^n P_{n-k}(t) \Pr(N(h) = k) \leq \lim_{h \rightarrow 0} \frac{\Pr(N(h) \geq 2)}{h} = 0$$

(由性质 4), 所以

$$\lim_{h \rightarrow 0} \frac{1}{h} \sum_{k=2}^n P_{n-k}(t) \Pr(N(h) = k) = 0.$$

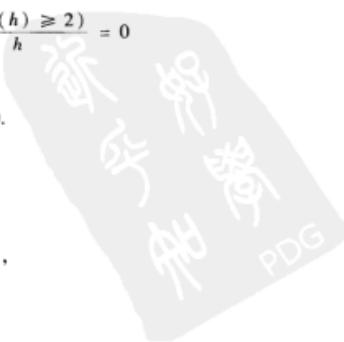
为解

$$P_n'(t) = -\lambda P_n(t) + \lambda P_{n-1}(t),$$

记

$$e^{\lambda t} (P_n'(t) + \lambda P_n(t)) = e^{\lambda t} \lambda P_{n-1}(t),$$

这给出



203

$$\frac{d}{dt}(e^{\lambda t} P_n(t)) = \lambda e^{\lambda t} P_{n-1}(t). \quad (8.2)$$

然后由 (8.1) 得到

$$\frac{d}{dt}(e^{\lambda t} P_1(t)) = \lambda e^{\lambda t} P_0(t) = \lambda,$$

这蕴涵

$$P_1(t) = (\lambda t + c)e^{-\lambda t}.$$

因为 $P_1(0) = 0$, 我们得到

$$P_1(t) = \lambda t e^{-\lambda t}. \quad (8.3)$$

继续对 n 用归纳法证明对所有 $n \geq 0$,

$$P_n(t) = e^{-\lambda t} \frac{(\lambda t)^n}{n!}.$$

由式 (8.2) 及归纳假设, 我们有

$$\frac{d}{dt}(e^{\lambda t} P_n(t)) = \lambda e^{\lambda t} P_{n-1}(t) = \frac{\lambda^n t^{n-1}}{(n-1)!}.$$

积分并由 $P_n(0) = 0$ 的事实便给出了结果. ■

参数 λ 也称为泊松过程的速度, 因为 (如我们已经证明的) 在任一长度为 t 的时间段内的事件个数是一个期望为 λt 的泊松随机变量.

反过来也成立, 即我们可以等价地定义泊松过程作为一个有泊松到达的过程, 如下面的定理所述.

定理 8.8 设 $\{N(t) \mid t \geq 0\}$ 是一随机过程, 使得:

1. $N(t) = 0$;
2. 过程有独立增量 (即在不相交时间间隔内的事件个数是独立事件);
3. 在任一长度为 t 的区间内, 事件个数服从均值为 λt 的泊松分布.

那么 $\{N(t) \mid t \geq 0\}$ 是速度为 λ 的泊松过程.

证明 过程显然满足定义 8.4 的条件 1 和 2. 为证明条件 3, 我们有

$$\lim_{t \rightarrow 0} \frac{\Pr(N(t) = 1)}{t} = \lim_{t \rightarrow 0} \frac{e^{-\lambda t} \lambda t}{t} = \lambda.$$

条件 4 由下式可知成立:

$$\lim_{t \rightarrow 0} \frac{\Pr(N(t) \geq 2)}{t} = \frac{e^{-\lambda t} (\lambda t)^2}{2t} = 0. \quad \blacksquare$$

8.4.1 到达间隔分布

设 X_1 是泊松过程首个事件的时间, X_n 是第 $(n-1)$ 个事件与第 n 个事件之间的时间间隔. 一般称 X_n 为到达间隔时间, 因为它们表示事件到达之间的时间. 这里, 我们证明所有 X_n 有相同的分布, 且这个分布是指数分布.

我们从导出 X_1 的分布开始.

定理 8.9 X_1 是参数为 λ 的指数分布.

204



证明

$$\Pr(X_1 > t) = \Pr(N(t) = 0) = e^{-\lambda t}.$$

所以

$$F(X_1) = 1 - \Pr(X_1 > t) = 1 - e^{-\lambda t}.$$

利用泊松过程有独立平稳增量的事实, 我们可以证明下面更强的结果.

定理 8.10 随机变量 $X_i (i=1, 2, \dots)$ 是独立同分布的参数为 λ 的指数随机变量.

证明 X_i 的分布由

$$\begin{aligned} & \Pr(X_i > t_i \mid (X_0 = t_0) \cap (X_1 = t_1) \cap \dots \cap (X_{i-1} = t_{i-1})) \\ &= \Pr\left(N\left(\sum_{k=0}^i t_k\right) - N\left(\sum_{k=0}^{i-1} t_k\right) = 0\right) \\ &= e^{-\lambda t_i} \end{aligned}$$

给出, 所以 X_i 的分布是参数为 λ 的指数分布, 它与其他到达间隔值无关.

定理 8.10 表明, 如果有一泊松到达过程, 那么到达间隔时间是同分布的指数随机变量. 事实上, 容易验证反之亦真(这留作练习 8.17).

定理 8.11 设 $\{N(t) \mid t \geq 0\}$ 是一随机过程, 使得:

1. $N(t) = 0$; 且
2. 到达间隔时间是独立同分布的参数为 λ 的指数随机变量.

那么 $\{N(t) \mid t \geq 0\}$ 是速度为 λ 的泊松过程.

8.4.2 组合与分解泊松过程

泊松过程与指数分布的到达间隔时间之间的对应, 在证明泊松过程的性质时是相当有用的. 一个直接的事实是泊松过程以一种自然的方法结合. 我们说两个泊松过程 $N_1(t)$ 和 $N_2(t)$ 是独立的, 当且仅当对任意的 t 和 u , $N_1(t)$ 和 $N_2(u)$ 是独立的. 设 $N_1(t) + N_2(t)$ 表示对应于两个过程 $N_1(t)$ 和 $N_2(t)$ 的事件个数的计数过程, 我们证明, 如果 $N_1(t)$ 和 $N_2(t)$ 是独立的泊松过程, 那么它们结合形成一个泊松过程 $N_1(t) + N_2(t)$.

定理 8.12 设 $N_1(t)$ 和 $N_2(t)$ 分别是参数为 λ_1 和 λ_2 的独立泊松过程, 那么 $N_1(t) + N_2(t)$ 是参数为 $\lambda_1 + \lambda_2$ 的泊松过程, 且过程 $N_1(t) + N_2(t)$ 的每个事件以概率 $\lambda_1 / (\lambda_1 + \lambda_2)$ 来自过程 $N_1(t)$.

证明 显然 $N_1(0) + N_2(0) = 0$, 且因为两个过程是独立的, 每个都有独立增量, 所以两个过程的和也有独立增量. 到达数 $N_1(t) + N_2(t)$ 是两个独立的泊松随机变量之和, 它(如我们在引理 5.2 所见到的)服从参数为 $\lambda_1 + \lambda_2$ 的泊松分布. 所以由定理 8.8, $N_1(t) + N_2(t)$ 是速度为 $\lambda_1 + \lambda_2$ 的泊松过程.

由定理 8.9, $N_1(t) + N_2(t)$ 的到达间隔时间是参数为 $\lambda_1 + \lambda_2$ 的指数分布, 由引理 8.5, $N_1(t) + N_2(t)$ 中的事件来自过程 $N_1(t)$ 的概率为 $\lambda_1 / (\lambda_1 + \lambda_2)$.

用归纳法, 定理可推广到多于两个过程的情况.

注意像结合一样, 泊松过程还可以分解. 如果把一个速度为 λ 的泊松过程作如下分解, 即对每个事件或以概率 p 标为类型 1, 或以概率 $1-p$ 标为类型 2, 那么看起来应得到两个速度为

λp 和 $\lambda(1-p)$ 的泊松过程. 事实上, 有时候我们可以有一个更强的结果: 两个过程是独立的.

定理 8.13 假定有一个速度为 λ 的泊松过程 $N(t)$, 每个事件独立地以概率 p 标为类型 1 或以概率 $1-p$ 标为类型 2, 那么类型 1 事件形成一个速度为 λp 的泊松过程 $N_1(t)$, 类型 2 事件形成速度为 $\lambda(1-p)$ 的泊松过程 $N_2(t)$, 且两个泊松过程是独立的.

证明 首先证明类型 1 事件实际上形成一个泊松过程. 显然 $N_1(t) = 0$, 而且因为过程 $N(t)$ 有独立增量, 所以过程 $N_1(t)$ 也有独立增量. 其次证明 $N_1(t)$ 有泊松分布:

$$\begin{aligned} \Pr(N_1(t) = k) &= \sum_{j=k}^{\infty} \Pr(N_1(t) = k \mid N(t) = j) \Pr(N(t) = j) \\ &= \sum_{j=k}^{\infty} \binom{j}{k} p^k (1-p)^{j-k} \frac{e^{-\lambda t} (\lambda t)^j}{j!} \\ &= \frac{e^{-\lambda p t} (\lambda p t)^k}{k!} \sum_{j=k}^{\infty} \frac{e^{-\lambda(1-p)t} (\lambda t(1-p))^{j-k}}{(j-k)!} \\ &= \frac{e^{-\lambda p t} (\lambda p t)^k}{k!}. \end{aligned}$$

所以, 由定理 8.8, $N_1(t)$ 是速度为 λp 的泊松过程.

为了证明独立性, 我们需要证明对任意的 t 和 u , $N_1(t)$ 和 $N_2(u)$ 是独立的. 事实上, 只需证明对任意 t , $N_1(t)$ 和 $N_2(t)$ 是独立的; 然后利用泊松过程具有独立平稳增量的事实, 可以证明对任意的 t 和 u , $N_1(t)$ 和 $N_2(u)$ 是独立的 (见练习 8.18). 我们有

$$\begin{aligned} \Pr((N_1(t) = m) \cap (N_2(t) = n)) &= \Pr((N(t) = m+n) \cap (N_2(t) = n)) \\ &= \frac{e^{-\lambda t} (\lambda t)^{m+n}}{(m+n)!} \binom{m+n}{n} p^m (1-p)^n \\ &= \frac{e^{-\lambda t} (\lambda t)^{m+n}}{m! n!} p^m (1-p)^n \\ &= \frac{e^{-\lambda p t} (\lambda p t)^m}{m!} \frac{e^{-\lambda(1-p)t} (\lambda t(1-p))^n}{n!} \\ &= \Pr(N_1(t) = m) \Pr(N_2(t) = n). \quad \blacksquare \end{aligned}$$

8.4.3 条件到达时间分布

我们已经利用泊松过程有独立增量的事实证明了到达间隔时间的分布是指数分布. 这个假定的另一应用如下: 在一个区间内恰有一个事件出现的条件下, 事件出现的实际时间是这个区间上的均匀分布. 为此考虑一个已知 $N(t) = 1$ 的泊松过程, 并考虑落在时间区间 $(0, t]$ 中的单个事件的时间 X_1 :

$$\begin{aligned} \Pr(X_1 < s \mid N(t) = 1) &= \frac{\Pr((X_1 < s) \cap (N(t) = 1))}{\Pr(N(t) = 1)} \\ &= \frac{\Pr((N(s) = 1) \cap (N(t) - N(s) = 0))}{\Pr(N(t) = 1)} \end{aligned}$$

$$\begin{aligned}
 &= \frac{(\lambda s e^{-\lambda s}) e^{-\lambda(t-s)}}{\lambda t e^{-\lambda t}} \\
 &= \frac{s}{t}.
 \end{aligned}$$

这里我们用到了 $N(s)$ 和 $N(t) - N(s)$ 的独立性.

将此推广到 $N(t) = n$ 的情况, 我们利用顺序统计量的概念. 设 X_1, \dots, X_n 是一个随机变量的 n 次独立观测, X_1, \dots, X_n 的顺序统计量由按(增)序排列的 n 个观测组成. 例如, 如果 X_1, X_2, X_3, X_4 是由在 $[0, 1]$ 上均匀地选取一个数而产生的独立随机变量, 取整到二位小数. 我们可能有 $X_1 = 0.47, X_2 = 0.33, X_3 = 0.93, X_4 = 0.26$. 相应的顺序统计量是 $Y_{(1)} = 0.26, Y_{(2)} = 0.33, Y_{(3)} = 0.47, Y_{(4)} = 0.93$, 其中 $Y_{(i)}$ 称为第 i 个最小顺序统计量. [207]

定理 8.14 给定 $N(t) = n$, 那么 n 个到达时间与 $[0, t]$ 上均匀分布的 n 个独立随机变量的顺序统计量有相同的分布.

证明 首先计算取自 $[0, t]$ 上的均匀分布的 n 个独立观测 X_1, X_2, \dots, X_n 的顺序统计量的分布. 记 $Y_{(1)}, \dots, Y_{(n)}$ 表示顺序统计量.

我们希望有一个关于

$$\Pr(Y_{(1)} \leq s_1, Y_{(2)} \leq s_2, \dots, Y_{(n)} \leq s_n)$$

的表达式.

设 \mathcal{E} 是事件

$$Y_{(1)} \leq s_1, Y_{(2)} \leq s_2, \dots, Y_{(n)} \leq s_n.$$

对从 1 到 n 的数的任意排列 i_1, i_2, \dots, i_n , 记 $\mathcal{E}_{i_1, i_2, \dots, i_n}$ 是事件

$$X_{i_1} \leq s_1, X_{i_2} \leq s_2, \dots, X_{i_n} \leq s_n.$$

除非对某个 j , $X_j = X_{j+1}$, 事件 $\mathcal{E}_{i_1, i_2, \dots, i_n}$ 是不相交的. 因为两个均匀随机变量相等的概率为 0, 所以这种事件的总概率也是 0, 可以忽略. 由对称性, 所有事件 $\mathcal{E}_{i_1, i_2, \dots, i_n}$ 有相同的概率. 又

$$\mathcal{E} = \cup \mathcal{E}_{i_1, i_2, \dots, i_n},$$

其中并是关于所有排列的. 由此

$$\begin{aligned}
 \Pr(Y_{(1)} \leq s_1, Y_{(2)} \leq s_2, \dots, Y_{(n)} \leq s_n) \\
 &= \sum \Pr(X_{i_1} \leq s_1, X_{i_2} \leq s_2, \dots, X_{i_n} \leq s_n) \\
 &= n! \Pr(X_1 \leq s_1, X_2 \leq s_2, \dots, X_n \leq s_n),
 \end{aligned}$$

其中第 2 行中的和是关于所有 $n!$ 个排列的. 如果现在用 u_i 表示 X_i 的取值, 那么

$$\begin{aligned}
 \Pr(X_1 \leq s_1, X_2 \leq s_2, \dots, X_n \leq s_n) \\
 &= \int_{u_1=0}^{s_1} \int_{u_2=0}^{s_2} \dots \int_{u_n=0}^{s_n} \left(\frac{1}{t}\right)^n du_n \dots du_1,
 \end{aligned}$$

其中我们利用了 $[0, t]$ 上均匀随机变量的密度函数为 $f(t) = 1/t$ 的事实. 这给出

$$\Pr(Y_{(1)} \leq s_1, Y_{(2)} \leq s_2, \dots, Y_{(n)} \leq s_n) = \frac{n!}{t^n} \int_{u_1=0}^{s_1} \int_{u_2=0}^{s_2} \dots \int_{u_n=0}^{s_n} du_n \dots du_1.$$

现在我们考虑在条件 $N(t) = n$ 下泊松过程的到达时间分布. 设 S_1, \dots, S_{n+1} 是前 $n+1$ 个到达时间, 还设 $T_1 = S_1, T_i = S_i - S_{i-1}$ 是到达间隔的区间长度. 由定理 8.10 可知 (a) 在没有条件 $N(t) = n$ 时, 随机变量 T_1, \dots, T_n 的分布是独立的; (b) 对每个 i, T_i 是参数为 λ 的指数分布. 回忆指数分布的密度函数为 $\lambda e^{-\lambda t}$, 我们有

$$\begin{aligned} & \Pr(S_1 \leq s_1, S_2 \leq s_2, \dots, S_n \leq s_n, N(t) = n) \\ &= \Pr\left(T_1 \leq s_1, T_2 \leq s_2 - T_1, \dots, T_n \leq s_n - \sum_{i=1}^{n-1} T_i, T_{n+1} > t - \sum_{i=1}^n T_i\right) \\ &= \int_{t_1=0}^1 \int_{t_2=0}^{t_2-t_1} \dots \int_{t_n=0}^{t_n-\sum_{i=1}^{n-1} t_i} \int_{t_{n+1}=t-\sum_{i=1}^n t_i}^{\infty} \lambda^{n+1} e^{-\lambda\left(\sum_{i=1}^{n+1} t_i\right)} dt_{n+1} \dots dt_1. \end{aligned}$$

关于 t_{n+1} 积分而得

$$\begin{aligned} \int_{t_{n+1}=t-\sum_{i=1}^n t_i}^{\infty} \lambda^{n+1} e^{-\lambda\left(\sum_{i=1}^{n+1} t_i\right)} dt_{n+1} &= -\lambda^n \left[e^{-\lambda\sum_{i=1}^{n+1} t_i} \right]_{t_{n+1}=t-\sum_{i=1}^n t_i}^{\infty} \\ &= \lambda^n e^{-\lambda t}. \end{aligned}$$

所以,

$$\begin{aligned} & \Pr(S_1 \leq s_1, S_2 \leq s_2, \dots, S_n \leq s_n, N(t) = n) \\ &= \lambda^n e^{-\lambda t} \int_{t_1=0}^{t_1} \int_{t_2=0}^{t_2-t_1} \dots \int_{t_n=0}^{t_n-\sum_{i=1}^{n-1} t_i} dt_n \dots dt_1 \\ &= \lambda^n e^{-\lambda t} \int_{u_1=0}^{t_1} \int_{u_2=u_1}^{t_2} \dots \int_{u_n=u_{n-1}}^{t_n} du_n \dots du_1, \end{aligned}$$

其中最后一个等式由变换 $u_i = \sum_{j=1}^i t_j$ 可得.

因为

$$\Pr(N(t) = n) = e^{-\lambda t} \frac{(\lambda t)^n}{n!}$$

及在长度为 t 的区间中事件个数有参数为 λt 的泊松分布, 条件概率计算给出

$$\begin{aligned} & \Pr(S_1 \leq s_1, S_2 \leq s_2, \dots, S_n \leq s_n \mid N(t) = n) \\ &= \frac{\Pr(S_1 \leq s_1, S_2 \leq s_2, \dots, S_n \leq s_n, N(t) = n)}{\Pr(N(t) = n)} \\ &= \frac{n!}{t^n} \int_{u_1=0}^{t_1} \int_{u_2=u_1}^{t_2} \dots \int_{u_n=u_{n-1}}^{t_n} du_n \dots du_1. \end{aligned}$$

[209] 这正是顺序统计量的分布函数. 定理得证. ■

8.5 连续时间马尔可夫过程

第 7 章我们研究了离散时间和离散空间的马尔可夫链. 连同连续随机变量的引入, 现在我们可以研究马尔可夫链的连续时间类似情况, 其中过程在转移到下一状态之前, 在某个状态中

停留了一个随机的时间间隔。为区别离散过程的和连续过程，当处理连续时间时，我们称为马尔可夫过程。

定义 8.5 一个连续时间随机过程 $\{X_t | t \geq 0\}$ 是马尔可夫的 (或称为马尔可夫过程)，如果对所有的 $s, t \geq 0$ ：

$$\Pr(X(s+t) = x | X(u), 0 \leq u \leq t) = \Pr(X(s+t) = x | X(t)),$$

而且这个概率与时间 t 无关[⊖]。

这个定义说明，在直到时刻 t 的历史条件下，系统在时刻 $s+t$ 的状态 $X(s+t)$ 的分布只依赖于状态 $X(t)$ ，而与使过程处于状态 $X(t)$ 的特定历史无关。

将我们的讨论限制在离散空间、连续时间的马尔可夫过程，存在另一个表述这种过程的等价方法，它更便于分析。回忆离散时间马尔可夫链由转移矩阵 $P = (P_{i,j})$ 确定，其中 $P_{i,j}$ 是从状态 i 一步转移到状态 j 的概率。一个连续时间马尔可夫过程可以用如下方法表示为两个随机过程的组合。

1. 一个转移矩阵 $P = (p_{i,j})$ ，其中 $p_{i,j}$ 是已知当前状态是 i 时，下一个状态为 j 的概率。(这里我们用小写字母表示转移概率，为了将它们与相应的离散时间过程的转移概率相区别。) 矩阵 P 是称之为相应的马尔可夫过程的嵌入或骨架马尔可夫链的转移矩阵。

2. 一个参数向量 $(\theta_1, \theta_2, \dots)$ ，即在移动到下一步之前，过程在状态 i 的停留时间的分布是参数为 θ_i 的指数分布。为了满足马尔可夫过程所要求的无记忆性，停留在某个给定状态的时间分布必定是指数分布。

连续时间马尔可夫过程的正式论述比它们在离散时间场合涉及更多内容，其完全讨论已超出本书范围。我们将讨论限制在计算离散空间、连续时间过程且平稳分布存在情况的平稳分布 (也称均衡分布) 问题。如离散时间情况一样，平稳分布 $\bar{\pi}$ 中的值 π_i 给出在无穷远的未来马尔可夫过程处于状态 i 的极限概率，而不管初始状态如何。即如果设 $P_{j,i}(t)$ 表示在时刻 0 从状态 j 开始而在时刻 t 处于状态 i 的概率，那么

$$\lim_{t \rightarrow \infty} P_{j,i}(t) = \pi_i.$$

类似地， π_i 给出过程处于状态 i 的长时间的长期的比例。而且，如果初始状态 j 是从平稳分布中选取的，那么在时刻 t 处于状态 i 的概率对所有 t 都是 π_i 。

为了确定平稳分布，考虑导数 $P'_{j,i}(t)$ ：

$$\begin{aligned} P'_{j,i}(t) &= \lim_{h \rightarrow 0} \frac{P_{j,i}(t+h) - P_{j,i}(t)}{h} \\ &= \lim_{h \rightarrow 0} \frac{\sum_k P_{j,k}(t) P_{k,i}(h) - P_{j,i}(t)}{h} \\ &= \lim_{h \rightarrow 0} \left(\sum_{k \neq i} \frac{P_{k,i}(h)}{h} P_{j,k}(t) - \frac{1 - P_{i,i}(h)}{h} P_{j,i}(t) \right). \end{aligned}$$

因为停留在状态 k 的时间分布是参数为 θ_k 的指数分布，所以可以利用泊松过程的性质，

⊖ 与处理离散时间马尔可夫链一样，这是一个时间齐次马尔可夫过程，我们在本书中只研究这种类型。

当 h 趋于零时, 在长度为 h 的区间内离开状态 k 的极限概率是 $h\theta_k$, 且多于一步转移的极限概率是 0. 所以

$$\lim_{h \rightarrow 0} \frac{P_{k,i}(h)}{h} = \theta_k p_{k,i}.$$

类似地, $1 - P_{i,i}(h)$ 是在时间区间 h 内转移出现且转移不是从状态 i 返回其自身的概率, 所以

$$\lim_{h \rightarrow 0} \frac{1 - P_{i,i}(h)}{h} = \theta_i (1 - p_{i,i}).$$

现在假定可以交换极限与和式, 我们强调这种交换对可数无穷空间并不总是满足的. 在这个假定下,

$$\begin{aligned} & \lim_{t \rightarrow \infty} \left(\sum_{j \neq i} \frac{P_{k,i}(h)}{h} P_{j,k}(t) - \frac{1 - P_{i,i}(h)}{h} P_{j,i}(t) \right) \\ &= \sum_{j \neq i} \theta_k p_{k,i} P_{j,k}(t) - P_{j,i}(t) (\theta_i - \theta_i p_{i,i}) \\ &= \sum_i \theta_k p_{k,i} P_{j,k}(t) - \theta_i P_{j,i}(t). \end{aligned}$$

取 $t \rightarrow \infty$ 的极限, 有

$$\lim_{t \rightarrow \infty} P'_{j,i}(t) = \lim_{t \rightarrow \infty} \sum_k \theta_k p_{k,i} P_{j,k}(t) - \theta_i P_{j,i}(t) = \sum_k \theta_k p_{k,i} \pi_k - \theta_i \pi_i.$$

如果过程有平稳分布, 必须有

$$\lim_{t \rightarrow \infty} P'_{j,i}(t) = 0.$$

否则, $P_{j,i}(t)$ 不收敛于平稳值. 因此在平稳分布 $\bar{\pi}$ 中, 我们有以下的速度方程:

$$\pi_i \theta_i = \sum_k \pi_k \theta_k p_{k,i}. \quad (8.4)$$

这个方程组有一个很好的解释. 左边的表达式 $\pi_i \theta_i$ 是转移出现离开状态 i 的速度. 右边的表达式 $\sum_k \pi_k \theta_k p_{k,i}$ 是转移出现进入状态 i 的速度. (一个从状态 i 返回状态 i 的转移看作是一个离开状态 i 的转移和一个进入状态 i 的转移.) 在平稳分布中, 这些速度必须相等, 所以离开状态和进入状态的转移的长期速度是相等的. 这种进入和离开每个状态的速度的相等性提供了一个求连续马尔可夫过程平稳分布的简单直观的方法. 这种论述可以推广到状态集, 说明类似于定理 7.9 的关于离散时间马尔可夫链的割集方程的结果对连续时间马尔可夫过程也成立.

如果所有状态停留时间的指数分布有相同的参数, 即所有的 θ_i 都相等, 那么方程 (8.4) 成为

$$\pi_i = \sum_k \pi_k p_{k,i}.$$

这对应于

$$\bar{\pi} = \bar{\pi} P,$$

其中 P 是嵌入马尔可夫链的转移矩阵. 我们可以有如下的结论: 在这种情况下, 连续时间过程的平稳分布与嵌入马尔可夫链的平稳分布是相同的.

8.6 例：马尔可夫排队论

在计算机科学的许多基本应用中都会出现排队。操作系统中的调度程序可以控制队列中的任务，直到有处理器或其他所需要的资源可以利用。在平行式或分布式程序设计时，线程可以对每次只允许访问一个线程的关键部分进行排队。在网络方面，在等待通过一个路由器时，数据包是排队的。即使在计算机系统盛行之前，排队论已有广泛的研究以掌握电话网络的工作情况，其中也有类似的调度程序问题。本节我们将分析某些最基本的排队模型，即用泊松过程作为顾客到达一个队列的随机过程模型，并用指数分布的随机变量作为要求服务时间的模型。

以后，用标准记号 $Y/Z/n$ 表示排队模型，其中 Y 表示来到的顾客流分布， Z 表示服务时间分布， n 表示服务员人数。马尔可夫或无记忆分布的标准记号是 M ，所以 $M/M/n$ 表示一个排队模型，其中顾客到达按照泊松过程，有 n 个服务员，他们的服务时间是独立的相同的指数分布。其他排队模型包括有无穷多个服务人员的 $M/M/\infty$ 模型及 $M/G/1$ 模型，其中 G 表示服务时间可以是任意的分布。[2]2

一个队列还必须有一个确定顾客服务次序的规则。除非有其他特殊的说明，我们假定是先到先出 (First In First Out, FIFO) 规则，即按顾客到达的次序为他们服务。

8.6.1 均衡的 $M/M/1$ 排队

假定顾客到达是按照参数为 λ 的泊松过程，还假定由一个服务员为他们服务。为顾客服务的时间是独立的且参数为 μ 的指数分布。

设 $M(t)$ 是 t 时刻队列中的顾客人数。因为到达过程和服务时间都是无记忆分布，过程 $\{M(t) \mid t \geq 0\}$ 定义了一个连续时间的马尔可夫过程，我们考虑这个过程的平稳分布。

令

$$P_k(t) = \Pr(M(t) = k)$$

表示 t 时刻在队伍中有 k 个顾客的概率。我们利用当 h 趋于 0 时在时间区间内到达 (或离开) 的概率是 λh (或 μh) 的事实，所以

$$\begin{aligned} \frac{dP_0(t)}{dt} &= \lim_{h \rightarrow 0} \frac{P_0(t+h) - P_0(t)}{h} \\ &= \lim_{h \rightarrow 0} \frac{P_0(t)(1 - \lambda h) + P_1(t)\mu h - P_0(t)}{h} \\ &= -\lambda P_0(t) + \mu P_1(t), \end{aligned} \quad (8.5)$$

且对 $k \geq 1$,

$$\begin{aligned} \frac{dP_k(t)}{dt} &= \lim_{h \rightarrow 0} \frac{P_k(t+h) - P_k(t)}{h} \\ &= \lim_{h \rightarrow 0} \frac{P_k(t)(1 - \lambda h - \mu h) + P_{k-1}(t)\lambda h + P_{k+1}(t)\mu h - P_k(t)}{h} \\ &= -(\lambda + \mu)P_k(t) + \lambda P_{k-1}(t) + \mu P_{k+1}(t). \end{aligned} \quad (8.6)$$

按均衡性，

$$\frac{dP_k(t)}{dt} = 0, \quad k = 0, 1, 2, \dots$$

如果系统收敛于一个平稳分布[⊖] $\bar{\pi}$, 那么由方程(8.5)可得

$$\mu\pi_1 = \lambda\pi_0.$$

用速度的语言, 这个等式有一个简单的解释: 按均衡性, 对队列中没有顾客的状态, 进入的速度为 $\mu\pi_1$, 离开的速度为 $\lambda\pi_0$, 这两个速度必须相等. 如果将上式写成 $\pi_1 = \pi_0(\lambda/\mu)$, 那么式(8.6)及简单的归纳给出

$$\pi_k = \pi_{k-1} \left(\frac{\lambda}{\mu} \right) = \pi_0 \left(\frac{\lambda}{\mu} \right)^k.$$

因为 $\sum_{k=0}^{\infty} \pi_k = 1$, 我们必须有

$$\pi_0 \sum_{k=0}^{\infty} \left(\frac{\lambda}{\mu} \right)^k = 1. \quad (8.7)$$

假定 $\lambda < \mu$, 由此得

$$\pi_0 = 1 - \frac{\lambda}{\mu}, \quad \pi_k = \left(1 - \frac{\lambda}{\mu} \right) \left(\frac{\lambda}{\mu} \right)^k.$$

如果 $\lambda > \mu$, 那么式(8.7)中的和式不收敛, 实际上, 系统没有达到平稳分布. 直观上, 这是显然的: 如果新顾客到达的速度大于服务完成的速度, 那么系统不可能达到平稳分布. 如果 $\lambda = \mu$, 系统也不可能达到均衡分布, 如练习 8.22 所讨论的.

为了计算处于均衡状态的系统中的顾客的期望数(用 L 表示), 记

$$\begin{aligned} L &= \sum_{k=0}^{\infty} k\pi_k \\ &= \frac{\lambda}{\mu} \sum_{k=1}^{\infty} k \left(1 - \frac{\lambda}{\mu} \right) \left(\frac{\lambda}{\mu} \right)^{k-1} \\ &= \frac{\lambda}{\mu} \frac{1}{1 - \lambda/\mu} \\ &= \frac{\lambda}{\mu - \lambda}, \end{aligned}$$

其中在第三个等式中, 我们用到了和是参数为 $1 - \lambda/\mu$ 的几何随机变量的期望的事实.

有趣的是, 我们还没有利用的事实是这样的服务规则, 即得到服务的顾客是已经等待了最长时间的顾客. 事实上, 因为所有服务时间服从指数分布, 而指数分布是无记忆的, 因此所有顾客似乎等价于依据直到他们离开所需要的服务时间的分布的队列, 而不考虑已经为他们服务了多长时间. 这样, 每当队列中至少有一个顾客时, 对于为某个顾客服务的任何服务规则, 我们的均衡分布等式以及系统中顾客的期望个数都成立.

下面计算在假定 FIFO 排队下, 当系统处于均衡时, 顾客停留在系统中的期望时间, 用 W 表示. 设 $L(k)$ 表示一位新顾客发现队列中有 k 个顾客的事件, 可以记

⊖ 系统收敛的证明依赖于更新理论, 这已超出本书的范围.

213

214

$$W = \sum_{k=0}^{\infty} E[W | L(k)] \Pr(L(k)).$$

因为服务时间是独立的和无记忆的, 期望为 $1/\mu$, 由此

$$E[W | L(k)] = (k+1) \frac{1}{\mu}.$$

为计算 $\Pr(L(k))$, 我们注意到如果系统处于均衡中, 那么离开状态 k 的转移速度是 $\pi_k \theta_k$, 其中 $\theta_0 = \lambda$, $\theta_k = \lambda + \mu$, $k \geq 1$. 应用引理 8.5, 由于一位新顾客到来而引起下一个离开状态 k 的转移概率为 λ/θ_k . 所以, 顾客到达并发现在队列中已经有 k 个顾客的速度为

$$\pi_k \theta_k \frac{\lambda}{\theta_k} = \pi_k \lambda.$$

因为新顾客来到系统的总速度是 λ , 我们断言一个新顾客发现系统中有 k 个顾客的概率为

$$\Pr(L(k)) = \frac{\pi_k \lambda}{\lambda} = \pi_k.$$

这是一个 PASTA 原则的例子, 它描述了泊松到达看时间平均 (Poisson Arrivals See Time Average). 即如果有一个泊松到达的马尔可夫过程有平稳分布, 且系统处于状态 k 的时间比例为 π_k , 那么 π_k 也是他们到达时发现系统处于状态 k 的到达者的比例. 由于泊松过程的独立性与无记忆性, PASTA 原则经常是简化分析的有用工具. 对更一般性情况下的 PASTA 原则的证明已超出本书范围.

现在计算

$$\begin{aligned} W &= \sum_{k=0}^{\infty} E[W | L(k)] \Pr(L(k)) \\ &= \sum_{k=0}^{\infty} \frac{k+1}{\mu} \pi_k \\ &= \frac{1}{\mu} \left(1 + \sum_{k=0}^{\infty} k \pi_k \right) \\ &= \frac{1}{\mu} (1 + L) \\ &= \frac{1}{\mu} \left(1 + \frac{\lambda}{\mu - \lambda} \right) \\ &= \frac{1}{\mu - \lambda} \\ &= \frac{L}{\lambda}. \end{aligned}$$

关系 $L = \lambda W$ 称为 Little 结果. 它不仅对 $M/M/1$ 排队成立, 也对任意稳定的排队系统成立. 这个基本结果的证明也超出了本书的范围.

虽然 $M/M/1$ 排队表示一个非常简单的过程, 但它对研究更复杂的过程是有用的. 例如假定有 n 种类型的顾客进入队列, 每个类型都是按泊松过程到达的, 而且所有顾客都有均值为 μ

的指数分布服务时间。因为泊松过程的组合，队列的到达过程是泊松过程，这可以用 $M/M/1$ 排队建模。类似地，假定只有一个泊松到达过程，对每种顾客类型分开排队。如果每个到达顾客以某个固定概率 p_i 是类型 i 的，那么泊松过程对每个顾客类型分成独立的泊松过程，因此每个类型的排队是 $M/M/1$ 排队。例如，在一个计算机网络中如果对不同类型用不同的处理器，就可能出现这种类型的分解。

8.6.2 均衡的 $M/M/1/K$ 排队

一个 $M/M/1/K$ 排队是一个具有有界队列长度的 $M/M/1$ 排队。如果一个顾客到达时队列已经有 K 个顾客，那么这位顾客就离开系统而不排队了。有界队列长度的模型在诸如网络路由器的应用中有用，一旦数据包缓冲区满了，到达的数据包就会被删除。

系统完全类似于前一个例子。由均衡性，我们有

$$\pi_k = \begin{cases} \pi_0 (\lambda/\mu)^k, & k \leq K, \\ 0, & k > K, \end{cases}$$

和

$$\pi_0 = \frac{1}{\sum_{k=0}^K (\lambda/\mu)^k}.$$

对任意 $\lambda, \mu > 0$ ，这些等式定义了一个适当的概率分布，而且我们不再要求 $\lambda < \mu$ 。

8.6.3 $M/M/\infty$ 排队中的顾客数

假定新用户按速度为 λ 的泊松过程连接到一个对等网络。用户连接网络的时间长度服从参数为 μ 的指数分布。假定在时刻 0，没有用户连接网络，设 $M(t)$ 为 t 时刻连接的用户数， $M(t)$ 的分布是什么？

我们可以将这个过程看作有无限用户个数的马尔可夫排队，一位顾客在她接入系统时刻开始接受服务，当服务结束时离开。我们用两种方式分析这个过程。第一种是用速度方程(8.4)计算过程的平稳分布。第二种方法比较复杂，但给出更多的信息：直接计算 t 时刻系统中顾客个数的分布，然后考虑 t 趋于无穷时的极限。

为了导出过程的速度方程，我们注意到如果(在某给定时刻)系统中有 $k \geq 0$ 个顾客，那么下一个事件可能是 k 位现有顾客中的一位结束服务或是一位新顾客到达。所以前一个事件的时间是 $k+1$ 个独立指数分布的随机变量的最小值，这些变量中有 k 个参数是 μ ，一个参数是 λ 。由引理 8.5，当系统中有 k 位顾客时，首个事件的时间服从参数为 $\theta = k\mu + \lambda$ 的指数分布。而且引理表明，已知一个事件发生，那个事件是一位新顾客到达的概率是

$$p_{\lambda, k+1} = \frac{\lambda}{\lambda + k\mu},$$

当 $k \geq 1$ 时，事件是一位顾客离开的概率是

$$p_{\mu, k-1} = \frac{k\mu}{\lambda + k\mu}.$$

将这些值代入(8.4)，得到了满足

$$\pi_0 \lambda = \pi_1 \mu$$

的平稳分布 $\bar{\pi}$, 且对 $k \geq 1$,

$$\pi_k(\lambda + k\mu) = \pi_{k-1}\lambda + \pi_{k+1}(k+1)\mu. \quad (8.8)$$

我们将(8.8)改写为

$$\begin{aligned} \pi_{k+1}(k+1)\mu &= \pi_k(\lambda + k\mu) - \pi_{k-1}\lambda \\ &= \pi_k\lambda + \pi_k k\mu - \pi_{k-1}\lambda. \end{aligned}$$

由简单的归纳得

$$\pi_k k\mu = \pi_{k-1}\lambda,$$

所以

$$\pi_{k+1} = \frac{\lambda}{\mu(k+1)}\pi_k.$$

现在再次由简单的归纳得

$$\pi_k = \pi_0 \left(\frac{\lambda}{\mu}\right)^k \frac{1}{k!},$$

所以

$$1 = \sum_{k=0}^{\infty} \pi_0 \left(\frac{\lambda}{\mu}\right)^k \frac{1}{k!} = \pi_0 e^{\lambda/\mu}.$$

我们得出 $\pi_0 = e^{-\lambda/\mu}$, 更一般地,

$$\pi_k = \frac{e^{-\lambda/\mu} (\lambda/\mu)^k}{k!},$$

所以, 均衡分布是参数为 λ/μ 的离散泊松分布.

现在我们继续第二种方法: 计算 t 时刻系统中顾客人数的分布, 用 $M(t)$ 表示, 然后考虑 t 趋于无穷时 $M(t)$ 的极限. 记 $N(t)$ 是在区间 $[0, t]$ 内连接到网络上的用户总数. 因为 $N(t)$ 服从泊松分布, 在这个值的条件下, 我们可以记作

$$\Pr(M(t) = j) = \sum_{n=0}^{\infty} \Pr(M(t) = j | N(t) = n) e^{-\lambda t} \frac{(\lambda t)^n}{n!}. \quad (8.9)$$

如果一个用户在时刻 x 连接到网络, 那么她在时刻 t 仍然连接的概率是 $e^{-\mu(t-x)}$. 由 8.4.3 节, 我们知道任一用户到达时间在 $[0, t]$ 上是均匀的, 所以任一用户在时刻 t 仍然连接的概率为

$$p = \int_0^t e^{-\mu(t-x)} \frac{dx}{t} = \frac{1}{\mu t} (1 - e^{-\mu t}).$$

因为事件对不同用户是独立的, 对 $j \leq n$, 我们有

$$\Pr(M(t) = j | N(t) = n) = \binom{n}{j} p^j (1-p)^{n-j}.$$

将此值代入等式(8.9)可得

$$\begin{aligned} \Pr(M(t) = j) &= \sum_{n=j}^{\infty} \binom{n}{j} p^j (1-p)^{n-j} e^{-\lambda t} \frac{(\lambda t)^n}{n!} \\ &= e^{-\lambda t} \frac{(\lambda t p)^j}{j!} \sum_{n=j}^{\infty} \frac{(\lambda t (1-p))^{n-j}}{(n-j)!} \end{aligned}$$



$$\begin{aligned}
 &= e^{-\lambda t} \frac{(\lambda t)^j}{j!} \sum_{m=0}^{\infty} \frac{(\lambda t(1-p))^m}{m!} \\
 &= e^{-\lambda t} \frac{(\lambda t)^j}{j!} e^{-\lambda t(1-p)} \\
 &= e^{-\lambda p} \frac{(\lambda t p)^j}{j!}.
 \end{aligned}$$

所以在时刻 t 的用户数服从参数为 $\lambda t p$ 的泊松分布.

因为

$$\lim_{t \rightarrow \infty} \lambda t p = \lim_{t \rightarrow \infty} \lambda t \frac{1}{\mu t} (1 - e^{-\mu t}) = \frac{\lambda}{\mu},$$

[218] 由此可知, 在极限情况下, 顾客人数有参数为 λ/μ 的泊松分布, 这与以前的计算是相称的.

练习

- 8.1 设 X 和 Y 是 $[0, 1]$ 上独立的均匀随机变量, 求 $X+Y$ 的密度函数和分布函数.
- 8.2 设 X 和 Y 是独立的、参数为 1 的指数分布的随机变量. 求 $X+Y$ 的密度函数和分布函数.
- 8.3 设 X 是 $[0, 1]$ 上的均匀随机变量, 确定 $\Pr(X \leq 1/2 \mid 1/4 \leq X \leq 3/4)$ 及 $\Pr(X \leq 1/4 \mid (X \leq 1/3) \cup (X \geq 2/3))$.
- 8.4 我们同意在 12 点到 1 点之间到我们特别喜爱的三明治商店一起午餐, 因为我们都很忙, 谁都不能保证大家在什么时候都能到达, 假定每个人到达时间是这个小时上的均匀分布. 为使谁也别等太长时间, 我们同意每个人只等另一个人恰好 15 分钟, 然后离开. 我们在午餐时彼此见面的概率是多少?
- 8.5 我们在引理 8.3 中求出了 n 个独立的 $[0, 1]$ 上均匀随机变量的最小值的期望, 通过直接计算它大于 y ($0 \leq y \leq 1$) 的概率而得到. 请用类似的计算求 n 个随机变量中第 k 小的变量大于 y 的概率, 并由此证明它的期望值是 $k/(n+1)$.
- 8.6 设 X_1, X_2, \dots, X_n 是参数为 1 的独立的指数随机变量. 求 n 个随机变量中的第 k 大变量的期望值.
- 8.7 考虑 n 个顶点的完全图. 每条边赋予的一个权是从实数区间 $[0, 1]$ 独立地且均匀随机地选取的. 证明这个图的最小支撑树的期望权至少为 $1 - 1/\left(1 + \binom{n}{2}\right)$. 当每条边被独立地赋予一个来自参数为 1 的指数分布的权时, 求类似的界.
- 8.8 考虑 n 个顶点的完全图, 每条边赋予一个独立地且均匀随机地选自实数区间 $[0, 1]$ 的权. 我们提出以下求图中最小权哈密顿圈的贪婪方法. 每一步存在一个主顶点. 开始时, 顶点 1 为主顶点, 每一步在当前主顶点与从未成为主顶点的新顶点之间的边中, 找一个最小权的边. 将这条边添加到圈中, 并将新的顶点设置为主顶点. 经 $n-1$ 步后, 我们得到了哈密顿路, 并添加一条从最后一个主顶点返回顶点 1 的边构成一个哈密顿圈. 用这种贪婪方法求得的哈密顿圈的期望权是多少? 并求当每条边独立地赋予一个来自参数为 1 的指数分布的权时的期望.

[219]

- 8.9 你可能喜欢写一个模拟指数分布随机变量的程序, 你的系统有一个随机数发生器, 它产生来自实数区间 $(0, 1)$ 上的独立的均匀分布的随机数. 给出一个程序, 它将已知的均匀随机数变换成参数为 λ 的指数分布随机变量.
- 8.10 将 n 个点均匀随机地放置在周长为1的圆周上, 这 n 个点把圆分成 n 个弧, 设 $Z_i (1 \leq i \leq n)$ 是按某种任意次序给出的这些弧的长度.
- (a) 证明所有 Z_i 以至少 $1 - 1/n^{c-1}$ 的概率至多为 $c \ln n / (n-1)$.
- (b) 证明对充分大的 n , 存在一个常数 c' , 使得至少有一个 Z_i 以至少 $1/2$ 的概率至少为 $c' \ln n$. (提示: 利用二阶矩方法.)
- (c) 证明所有 Z_i 至少以 $1/2$ 的概率至少为 $1/2n^2$.
- (d) 证明对充分大的 n , 存在一个常数 c' , 使得至少有一个 Z_i 以至少 $1/2$ 的概率至多为 c'/n^2 . (提示: 利用二阶矩方法.)
- (e) 解释有关下列问题的结果: X_1, X_2, \dots, X_{n-1} 是从实数区间 $[0, 1]$ 独立且均匀随机选取的值, 设 Y_1, \dots, Y_{n-1} 表示以升序排列的这些值, 还定义 $Y_0 = 0, Y_n = 1$. 点 Y_i 将单位区间分成 n 段, 如何理解这些段中最短的和最长的段?
- 8.11 桶排序是5.2.2节讨论过的一种简单的排序算法.
- (a) 当 n 个待排序元素是从 $[0, 1]$ 中独立、均匀选取的随机数时, 如何执行桶排序法, 使得期望运行时间为 $O(n)$?
- (b) 现在考虑当待排序元素不一定是在一个区间上的均匀随机数时, 如何执行桶排序法. 特别地, 假定待排序元素是形如 $X+Y$ 的数时, 其中(对每个元素) X 和 Y 都是 $[0, 1]$ 上独立、均匀选取的随机数. 如何修改桶, 使得桶排序法能具有期望运行时间 $O(n)$? 如果待排序元素不是 $X+Y$ 形式, 而是 $\max(X, Y)$ 形式的数呢?
- 8.12 设 n 个点均匀随机地放置在周长为1的圆周上, 这 n 个点将圆周分成 n 个弧. $Z_i (1 \leq i \leq n)$ 是按任意次序排列的这些弧的长度, X 是至少为 $1/n$ 的 Z_i 的个数, 求 $E[X]$ 和 $\text{Var}[X]$.
- 8.13 一台数码相机需要两节电池, 你买了一包标号为1到 n 的 n 节电池. 在开始时, 你装上电池1和2. 每当有一节电池没电时, 立即用最小标号的没有用过的电池代替没电的电池. 假定每节电池用完之前使用的时间量服从均值为 μ 的指数分布, 所有电池是独立的. 最后, 除了一节以外, 所有电池都没电了. [220]
- (a) 求标号为 i 的那节电池最后还有电的概率.
- (b) 求你的照相机用这包电池能够运行的期望时间.
- 8.14 设 X_1, X_2, \dots 是参数为1的指数随机变量.
- (a) 说明 $X_1 + X_2$ 不是指数随机变量.
- (b) 设 N 是参数为 p 的几何随机变量, 证明 $\sum_{i=1}^N X_i$ 服从参数为 p 的指数分布.
- 8.15 (a) 设 X_1, X_2, \dots 是独立的指数随机变量序列, 每个均值都为1. 已知正的实数 k , 设 N 由

$$N = \min \left\{ n; \sum_{i=1}^n X_i > k \right\}$$

定义, 即 N 是使前 n 个 X_i 之和大于 k 的最小的数, 确定 $E[N]$.

- (b) 设 X_1, X_2, \dots 是区间 $(0, 1)$ 上的独立的均匀随机变量序列, 已知正的实数 $k, 0 < k < 1$, N 由

$$N = \min \left\{ n; \prod_{i=1}^n X_i < k \right\}$$

定义, 即 N 是使前 n 个 X_i 之积小于 k 的最小的数. 确定 $E[N]$. (提示: 可以利用练习 8.9.)

- 8.16 有 n 个任务交给 n 个处理器. 每个任务有两个阶段, 每个阶段的时间由参数为 1 的指数随机变量给出. 所有任务及所有阶段的时间是独立的, 我们称任务完成了一半, 如果完成了两阶段之一.

(a) 导出当一个任务恰好全部完成时, 有 k 个任务完成了一半的概率的表达式.

(b) 导出直到有一个任务恰好全部完成的期望时间的表达式.

(c) 解释这个问题如何同生日悖论有关.

- 8.17 证明定理 8.11.

- 8.18 用正规形式完成定理 8.13 的证明: 如果 $N_1(t)$ 和 $N_2(t)$ 独立, 那么对任意 $t, \mu > 0$, $N_1(t)$ 和 $N_2(\mu)$ 也独立.

221

- 8.19 你正在一个公共汽车站等开往市区的汽车. 实际上, 你可以乘坐 n 条不同的线路, 每一条线路都有不同的行车路线. 你决定坐哪辆汽车取决于哪辆汽车先到车站. 只要你正在等车, 你等第 i 路汽车的时间服从均值为 μ_i 分钟的指数分布. 一旦你坐上了第 i 路汽车, 你要花 t_i 分钟到达市区.

设计一个决策算法——当一辆汽车到达时——你是坐还是不坐这辆汽车, 假定你的目的是极小化到达市区的期望时间. (提示: 你希望确定这样的汽车集合, 只要它们到达你就上车. 共有 2^n 个可能的集合, 这对一个有效算法太大了, 证明你只需考虑这些集合中的一小部分.)

- 8.20 给定一个离散空间、连续时间的马尔可夫过程 $X(t)$, 通过考虑过程访问的状态, 可以导出一个离散时间的马尔可夫链 $Z(t)$. 即令 $Z(0) = X(0)$, $Z(1)$ 是时刻 $t=0$ 后, 过程 $X(t)$ 第一次移动到的状态, $Z(2)$ 是过程 $X(t)$ 移动到的下一个状态, 等等. (如果马尔可夫过程 $X(t)$ 进行了一次从状态 i 到状态 i 的转移, 这在关联的转移矩阵中当 $p_{ii} \neq 0$ 时是可以发生的, 那么马尔可夫链 $Z(t)$ 也应该进行从状态 i 到状态 i 的转移.)

(a) 假定过程 $X(t)$ 停留在状态 i 的时间是参数为 $\theta_i = \theta$ (对所有的 i 都相同) 的指数分布, 进一步假定过程 $X(t)$ 有平稳分布, 证明马尔可夫链 $Z(t)$ 有相同的平稳分布.

(b) 给出一个例子说明, 如果 θ_i 不全相等, 那么 $X(t)$ 和 $Z(t)$ 的平稳分布可以不同.

- 8.21 Ehrenfest 模型是物理学中的一个基本模型. 在一个容器中有 n 个质点随机移动. 我们考虑容器的左一半和右一半内的质点数. 经过参数为 1 的指数分布的时间后, 容器某一半中的一个质点移动到另一半, 且所有质点是独立的, 见图 8.6.



图 8.6 Ehrenfest 模型

- (a) 求这个过程的平稳分布.
- (b) 在平稳分布中, 什么样的状态有最大的概率? 对此你有什么样的解释.
- 8.22 按照练习 8.20 所描述的方法, 我们可以从 $M/M/1$ 排队过程得到一个离散时间马尔可夫链. 离散时间链记录了队列中的顾客人数. 即使队列是空的, 也允许离开事件以速度 λ 出现. 这不影响排队状态, 但在相应的马尔可夫链中给出了从状态 0 到状态 0 的转移.
- (a) 描述这个离散时间链的可能转移, 并给出它们的概率. [2.2]
- (b) 证明当 $\lambda < \mu$ 时, 这个链的平稳分布与 $M/M/1$ 过程的平稳分布相同.
- (c) 证明在 $\lambda = \mu$ 的情况下对马尔可夫链不存在有效的平稳分布.
- 8.23 串联排队中, 顾客是按速度为 λ 的泊松过程到达一个 $M/M/1$ 队列, 服务时间是独立的, 且服从参数为 μ_1 的指数分布. 在第一个队列完成了服务后, 顾客立即到也是由一个服务员服务的第二个队列, 而服务时间是独立的, 服从参数为 μ_2 的指数分布. 求这个系统的平稳分布. (提示: 推广一个队列的平稳分布形式.)
- 8.24 编写一个模拟有反馈的球和箱子模型的程序.
- (a) 在箱子 1 中有 51 个球, 箱子 2 中有 49 个球, 用 $p=2$ 开始你的模拟. 运行你的程序 100 次, 每次都是当一个箱子有 60% 的球时停止. 平均来讲, 当程序停止时, 箱子里有多少个球? 箱子 1 多久得到半数以上的球?
- (b) 进行与 (a) 相同的试验, 但从箱子 1 有 52 个球而箱子 2 中有 48 个球开始. 这会改变你的答案多少?
- (c) 进行与 (a) 相同的试验, 但从箱子 1 有 102 个球而箱子 2 有 98 个球开始, 这会改变你的答案多少?
- (d) 进行与 (a) 相同的试验, 但现在用 $p=1.5$, 这会改变你的答案多少?
- 8.25 这里我们考虑研究 FIFO 排队的一种方法, 采用一个不变的服务时间长度 1 及参数 $\lambda < 1$ 的泊松到达. 用 k 个指数分布的服务阶段代替固定的服务时间, 每个阶段平均时间为 $1/k$. 顾客在离开队列之前必须经过所有 k 个阶段的服务, 且只要有一位顾客正在接受这 k 个阶段的服务, 直到服务结束, 别的顾客不能接受服务.
- (a) 导出花在 k 个指数分布阶段上 (每阶段的均值为 $1/k$) 的总时间明显偏离 1 的概率的切尔诺夫界.
- (b) 导出这种情况下定义平稳分布的方程组 (提示: 设 π_j 是停留在队列中接受 j 个阶段服务的极限概率. 每个等待的顾客要求 k 个阶段, 即要求接受在第 1 阶段和第 k 阶

段之间的服务), 并不要求解这个方程组得到 π_i 的闭形式.

(c) 由这些方程用数值方法确定均衡排队中顾客的平均人数, 比如 $\lambda = 0.8$, $k = 10, 20, 30, 40$ 及 50 . 讨论当 k 增加时, 你的结果是否收敛, 并比较到达速度为 $\lambda < 1$ 且期望服务时间为 $\mu = 1$ 的 $M/M/1$ 排队中顾客的期望人数.

- 8.26 编写一个模拟 n 个 $M/M/1$ FIFO 排队的数据库程序, 每个队列有速度为每秒 $\lambda < 1$ 的泊松到达, 每个服务时间服从均值为 1 秒的指数分布. 你的模拟运行 t 秒, 并返回完成服务的每位顾客停留在系统中的平均时间. 对 $n = 100$, $t = 10\,000$ 秒, $\lambda = 0.5, 0.8, 0.9$ 及 0.99 给出你的模拟结果.

编写我们现在描述的模拟的一个自然方法是保持事件的优先权队列. 这样的队列贮存了所有即将发生事件的时间, 如下一顾客到达时间或下一顾客完成队列中服务的时间. 例如, 一个优先权队列可以回答如“下一个事件是什么?”这样的问题, 优先权队列常常执行得更好.

当一个顾客准备去队列 k 时, 就需要计算下一顾客到达队列 k 的时间, 并按优先权队列进入. 如果队列 k 是空的, 到达顾客完成服务的时间应按优先权排队. 如果队列 k 不是空的, 这位顾客排在队伍的末尾. 如果完成了一个顾客的服务后队列不是空的, 那么应计算(在队伍最前面的)下一位顾客完成服务的时间, 并放入优先权队列. 你应该记录每位顾客的到达时间和完成服务的时间.

你可以找到简化这种一般方案的方法, 例如, 不去考虑每个队列分别的到达过程, 而是基于 8.4.2 节我们所知道的将它们组合成一个到达过程. 解释你的简化.

你可能希望利用练习 8.9 来帮助为你的模拟构造指数分布的随机变量.

修改你的模拟, 将均值为 1 秒的指数分布的服务时间修改为服务时间总是恰好为 1 秒. 仍旧对 $n = 100$, $t = 10\,000$ 秒及 $\lambda = 0.5, 0.8, 0.9$ 及 0.99 , 给出你的模拟结果. 以指数分布的服务时间还是不变的服务时间能更快地完成任务?



第9章 熵、随机性和信息

假定我们有两枚有偏的硬币，一枚出现正面的概率是 $3/4$ ，另一枚出现正面的概率是 $7/8$ 。每次投掷，哪枚硬币具有更大的随机性？在本章中，我们将引入熵函数作为随机性的一般度量。特别地，我们证明从一系列投掷有偏的硬币可以提取独立的、无偏的随机比特的个数对应于这个硬币的熵。熵在信息和通信方面也有重要的作用。为了阐释这个作用，我们检查压缩和编码中的某些基本结果，看看它们是如何与熵有关系的。我们证明的主要结果是关于二进制对称信道的香农编码定理，它是信息论领域的一个基本结果。对香农定理的证明用到了在前几章中已经提出的几种思想，包括切尔诺夫界、马尔可夫不等式和概率方法。

9.1 熵函数

一个随机变量的熵是它的分布的函数，正如我们将要看到的，它给出了一个关于分布的随机性的度量。

定义 9.1

1. 对于一个离散随机变量 X ，二进制的熵由

$$H(X) = - \sum_x \Pr(X = x) \log_2 \Pr(X = x)$$

给出，其中求和取遍 X 值域中的所有 x 值。等价地，可以写为

$$H(X) = E \left[\log_2 \frac{1}{\Pr(X)} \right].$$

2.25

2. 如果一个随机变量只取两个可能结果，其中一个以概率 p 出现，那么这个随机变量的二进制熵函数为

$$H(p) = -p \log_2 p - (1-p) \log_2 (1-p).$$

我们定义 $H(0) = H(1) = 0$ ，所以二进制熵函数在区间 $[0, 1]$ 上是连续的。函数图像如图 9.1 所示。

对于两枚有偏的硬币，以 $3/4$ 的概率出现正面的那枚硬币的熵是

$$H\left(\frac{3}{4}\right) = -\frac{3}{4} \log_2 \frac{3}{4} - \frac{1}{4} \log_2 \frac{1}{4} = 2 - \frac{3}{4} \log_2 3 \approx 0.8113,$$

而以 $7/8$ 的概率出现正面的那枚硬币的熵是

$$H\left(\frac{7}{8}\right) = -\frac{7}{8} \log_2 \frac{7}{8} - \frac{1}{8} \log_2 \frac{1}{8} = 3 - \frac{7}{8} \log_2 7 \approx 0.5436.$$

因此，以 $3/4$ 的概率出现正面的硬币有一个较大熵。

对 $H(p)$ 求导数，得

$$\frac{dH(p)}{dp} = -\log_2 p + \log_2 (1-p) = \log_2 \frac{1-p}{p},$$

我们看到，当 $p = 1/2$ 时， $H(p)$ 达到最大，且 $H(1/2) = 1$ 个比特。解释这个表述的一种方法是

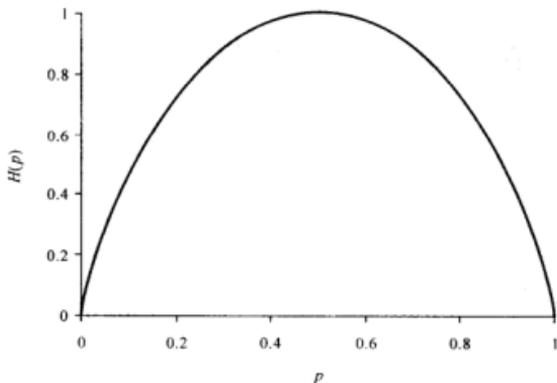


图 9.1 二进制熵函数

说：每次投掷一枚两面的硬币，得到至多 1 个比特的随机性，当硬币均匀时，可恰好得到 1 个比特的随机性。虽然这样说看起来相当清楚，但并不清楚每次投掷一枚出现正面概率是 $3/4$ 的硬币时，得到 $H(3/4)$ 个随机比特在 $H(3/4) = 2 - \frac{3}{4} \log_2 3$ 意义下是什么意思。我们将在本章较

[226]

后部分阐明这个问题。

作为另一个例子，考虑一粒标准六面体骰子，每面朝上的概率都为 $1/6$ ，熵是 $\log_2 6$ 。一般地，一个有 n 个等可能结果的随机变量的熵为

$$-\sum_{i=1}^n \frac{1}{n} \log_2 \frac{1}{n} = \log_2 n.$$

因此一个八面体骰子的熵为 3 个比特。这个结果看上去很自然；如果将骰子的各面采用二进制标上 $0 \sim 7$ ，则骰子滚动的结果将给出在集合 $\{0, 1\}^3$ 上均匀的 3 个比特的序列，这等价于独立且均匀随机生成的 3 个比特。

值得强调的是，随机变量 X 的熵不依赖于 X 可能的取值，只依赖于 X 在这些值上的概率分布。八面体骰子的熵不依赖于骰子每面上的数是什么；只与所有八面都是等可能出现有关。 X 的期望或方差不具有这种性质，但对一个随机性度量是有意义的。为了度量骰子的随机性，我们将不关心每个面的数是多少，只关心每个面多久朝上一次。

在这章中，我们考虑独立随机变量序列的熵，比如独立投掷的硬币序列的熵。对于这种情况，下面的引理允许我们由每个随机变量的熵求序列的熵。

引理 9.1 设 X_1 和 X_2 为独立随机变量， $Y = (X_1, X_2)$ ，那么

$$H(Y) = H(X_1) + H(X_2).$$

当然，引理可以毫无困难地用归纳法推广到 Y 是独立随机变量的任意有限序列情况。

证明 下面的和式是关于 X_1 和 X_2 所有可能的取值求出的. 利用 X_1 和 X_2 的独立性, 可简化表达式, 从而得到下面的结果:

$$\begin{aligned}
 H(Y) &= - \sum_{x_1, x_2} \Pr((X_1, X_2) = (x_1, x_2)) \log_2 \Pr((X_1, X_2) = (x_1, x_2)) \\
 &= - \sum_{x_1, x_2} \Pr(X_1 = x_1) \Pr(X_2 = x_2) \log_2 (\Pr(X_1 = x_1) \Pr(X_2 = x_2)) \\
 &= - \sum_{x_1, x_2} \Pr(X_1 = x_1) \Pr(X_2 = x_2) (\log_2 \Pr(X_1 = x_1) + \log_2 \Pr(X_2 = x_2)) \\
 &= - \sum_{x_1} \sum_{x_2} \Pr(X_2 = x_2) \Pr(X_1 = x_1) \log_2 \Pr(X_1 = x_1) \\
 &\quad - \sum_{x_2} \sum_{x_1} \Pr(X_1 = x_1) \Pr(X_2 = x_2) \log_2 \Pr(X_2 = x_2) \\
 &= - \left(\sum_{x_1} \Pr(X_1 = x_1) \log_2 \Pr(X_1 = x_1) \right) \left(\sum_{x_2} \Pr(X_2 = x_2) \right) \\
 &\quad - \left(\sum_{x_2} \Pr(X_2 = x_2) \log_2 \Pr(X_2 = x_2) \right) \left(\sum_{x_1} \Pr(X_1 = x_1) \right) \\
 &= - \sum_{x_1} \Pr(X_1 = x_1) \log_2 \Pr(X_1 = x_1) - \sum_{x_2} \Pr(X_2 = x_2) \log_2 \Pr(X_2 = x_2) \\
 &= H(X) + H(Y).
 \end{aligned}$$

[227]

9.2 熵和二项式系数

在说明熵的各种应用之前, 我们首先介绍在纯组合理论中, 熵是如何自然产生的.

引理 9.2 设 nq 是 $[0, n]$ 中的一个整数, 那么

$$\frac{2^{nH(q)}}{n+1} \leq \binom{n}{nq} \leq 2^{nH(q)}.$$

证明 当 $q=0$ 或 $q=1$ 时, 结论显然成立, 所以假定 $0 < q < 1$. 为了证明它的上界, 注意到由二项式定理, 我们有

$$\binom{n}{nq} q^{nq} (1-q)^{(1-q)n} \leq \sum_{k=0}^n \binom{n}{k} q^k (1-q)^{n-k} \leq (q + (1-q))^n = 1.$$

因此,

$$\binom{n}{nq} \leq q^{-nq} (1-q)^{-(1-q)n} = 2^{-nq \log_2 q} 2^{-(1-q)n \log_2 (1-q)} = 2^{nH(q)}.$$

对于下界, 我们知道 $\binom{n}{nq} q^{nq} (1-q)^{(1-q)n}$ 是表达式 $\sum_{k=0}^n \binom{n}{k} q^k (1-q)^{n-k}$ 中的一项. 我们证明它是最大的一项. 考虑两个相继项之间的差如下:

$$\begin{aligned} & \binom{n}{k} q^k (1-q)^{n-k} - \binom{n}{k+1} q^{k+1} (1-q)^{n-k-1} \\ &= \binom{n}{k} q^k (1-q)^{n-k} \left(1 - \frac{n-k}{k+1} \frac{q}{1-q}\right). \end{aligned}$$

每当

$$1 - \frac{n-k}{k+1} \frac{q}{1-q} \geq 0$$

或(等价地, 通过一些计算)

$$k \geq qn - 1 + q$$

时, 这个差是非负的. 因此, 项在 $k=qn$ 之前是递增的, 而在这一点之后是递减的, 因此 $k=qn$ 是和式中的最大项.

因为和式有 $n+1$ 项, 且 $\binom{n}{nq} q^{nq} (1-q)^{(1-q)n}$ 为最大项, 我们有

$$\binom{n}{nq} q^{nq} (1-q)^{(1-q)n} \geq \frac{1}{n+1}$$

或

$$\binom{n}{nq} \geq \frac{q^{-nq} (1-q)^{-(1-q)n}}{n+1} = \frac{2^{nH(q)}}{n+1}. \quad \blacksquare$$

我们经常用到下面稍为特殊一点的推论.

推论 9.3 当 $0 \leq q \leq 1/2$ 时,

$$\binom{n}{\lfloor nq \rfloor} \leq 2^{nH(q)}; \quad (9.1)$$

类似地, 当 $1/2 \leq q \leq 1$ 时,

$$\binom{n}{\lceil nq \rceil} \leq 2^{nH(q)}. \quad (9.2)$$

当 $1/2 \leq q \leq 1$ 时,

$$\frac{2^{nH(q)}}{n+1} \leq \binom{n}{\lfloor nq \rfloor}; \quad (9.3)$$

类似地, 当 $0 \leq q \leq 1/2$ 时,

$$\frac{2^{nH(q)}}{n+1} \leq \binom{n}{\lceil nq \rceil}. \quad (9.4)$$

证明 首先证明(9.1)式; (9.2)式的证明完全类似. 当 $0 \leq q \leq 1/2$ 时,

$$\binom{n}{\lfloor nq \rfloor} q^{nq} (1-q)^{(1-q)n} \leq \binom{n}{\lfloor nq \rfloor} q^{\lfloor nq \rfloor} (1-q)^{n-\lfloor nq \rfloor} \leq \sum_{k=0}^n \binom{n}{k} q^k (1-q)^{n-k} = 1.$$

由此, 我们可以如引理 9.2 那样继续下去.

(9.3)式成立是因为当 $q \geq 1/2$ 时, 引理 9.2 给出

$$\binom{n}{\lfloor nq \rfloor} \geq \frac{2^{nH(Lq \downarrow/n)}}{n+1} \geq \frac{2^{nH(q)}}{n+1};$$

类似推出(9.4)式成立。 ■

尽管这些界是松的,但对我们来说已经足够了。当考虑投掷一系列有偏的硬币时,其中硬币正面向上的概率为 $p > 1/2$,组合系数与熵函数之间的关系将会在本章的证明中反复出现。利用切尔诺夫界,我们知道对于足够大的 n ,正面向上的次数几乎总是接近于 np 。因此,这个序列几乎总是 $\binom{n}{np} \approx 2^{nH(p)}$ 个序列中的一个,其中的近似关系由引理 9.2 得到的。更进一步地说,每个这样的序列都大约以如下的概率出现:

$$p^{np} (1-p)^{n(1-p)} \approx 2^{-nH(p)}.$$

因此,当考虑 n 次投掷有偏的硬币的结果时,基本上可以限制在以大致相等概率出现的约 $2^{nH(p)}$ 个结果中。

9.3 熵:随机性的测度

解释随机变量的熵的一种方法就是将它作为从随机变量的一个例证中,可以平均地提取出多少个无偏的独立比特的一个测度。我们对有偏的硬币考虑这个问题,证明对足够大的 n ,可以从 n 次投掷出现正面概率为 $p > 1/2$ 的硬币中,提取的期望比特数基本上是 $nH(p)$ 。换言之,对熵为 $H(p)$ 的硬币的每次投掷,平均地可以产生约 $H(p)$ 个独立的比特。可以将这个结果推广到其他随机变量,但这里(且贯穿本章)我们主要关注有偏的硬币的特殊情况,以使得结论更清楚。

我们从定义开始,阐述提取随机比特的意义。

定义 9.2 令 $|y|$ 是比特序列 y 的比特个数,一个提取函数 Ext 是指以随机变量 X 的值为输入,以比特序列 y 作为输出,满足

$$\Pr(\text{Ext}(X) = y \mid |y| = k) = 1/2^k,$$

其中 $\Pr(|y| = k) > 0$ 。

在有偏的硬币的情况,输入 X 是投掷 n 次有偏的硬币的结果。输出中的比特数不固定,而是依赖于输入。如果提取函数输出 k 个比特,可以认为这些比特是独立地且均匀随机产生的,这是因为每个 k 个比特的序列都是等可能出现的。而且,定义中也没有要求提取函数的有效计算。尽管在这里不考虑有效性,但在练习 9.12 中我们还是给出了一个有效的提取算法。

作为证明从有偏的硬币中提取无偏比特结论的第一步,我们考虑从一个服从均匀分布的整数随机变量中提取随机比特的的问题。例如,设 X 为均匀随机地从 $\{0, 1, \dots, 7\}$ 中选取的一个整数, Y 为将 X 写成二进制数时得到的 3 个比特的序列。若 $X=0$,则 $Y=000$;若 $X=7$,则 $Y=111$ 。容易验证每个 3 个比特的序列是等可能出现的,所以将任意输入 X 与相应的输出 Y 相关联,就得到一个平凡的提取函数 Ext 。

当 X 是均匀地取自 $\{0, 1, \dots, 11\}$ 时,可能要稍微困难一些。如果 $X \leq 7$, 仍可以令 Y 是将 X 写成二进制数字时得到的 3 个比特的序列。还剩下 $X \in \{8, 9, 10, 11\}$ 的情况,可以将这

230

四个可能中的每一个与不同的 2 个比特序列相关联. 例如, 令 Y 为将 $X-8$ 表示为二进制数字时得到的 2 个比特序列. 这样, 若 $X=8$, 则 $Y=00$; 若 $X=11$, 则 $Y=11$. 完整的提取函数见图 9.2. 每个 3 比特序列都以相同的概率 $1/12$ 出现, 每个 2 比特序列也以相同的概率 $1/12$ 出现, 所以满足定义 9.2.

输入	0	1	2	3	4	5	6	7
输出	000	001	010	011	100	101	110	111

输入	0	1	2	3	4	5	6	7	8	9	10	11
输出	000	001	010	011	100	101	110	111	00	01	10	11

图 9.2 从 $\{0, 1, \dots, 7\}$ 及 $\{0, 1, \dots, 11\}$ 中均匀随机地选取的一个数的提取函数

我们将这些例子推广为下面的定理.

定理 9.4 假设一个随机变量 X 的值均匀随机地取自整数集 $\{0, 1, \dots, m-1\}$, 使得 $H(X) = \log_2 m$. 那么存在 X 的一个提取函数, 平均至少输出 $\lfloor \log_2 m \rfloor - 1 = \lfloor H(X) \rfloor - 1$ 个独立无偏的比特.

证明 如果 $m > 1$ 为 2 的幂, 那么提取函数可以利用 $\log_2 m$ 个比特简单地输出表示输入 X 的二进制数字. (如果 $m=1$, 则什么也不输出, 或等价地, 输出一个空序列.) 所有的输出序列都有 $\log_2 m$ 个比特, 且所有的 $\log_2 m$ 个比特序列都是等可能出现的, 所以满足定义 9.2. 如果 m 不是 2 的幂, 情况将较为复杂. 我们递归地描述提取函数. (非递归的描述在练习 9.8 中给出.) 令 $\alpha = \lfloor \log_2 m \rfloor$, 如果 $X \leq 2^\alpha - 1$, 那么函数输出 X 的 α 位的二进制表示; 在这种情况下, 所有 α 个比特的序列作为输出是等可能的. 如果 $X \geq 2^\alpha$, 那么 $X - 2^\alpha$ 是集合 $\{0, \dots, m - 2^\alpha - 1\}$ 上的均匀分布, 这个集合比集合 $\{0, \dots, m\}$ 小. 提取函数可依据变量 $X - 2^\alpha$ 的提取函数递归地产生输出.

递归提取函数保持了以下性质: 对每个 k , 2^k 个 k 个比特的序列中的每一个以相等的概率作为输出. 由归纳法可知, 由这种提取函数产生的无偏、独立的比特的期望个数至少为 $\lfloor \log_2 m \rfloor - 1$. 当 m 为 2 的幂时的情况是平凡的. 否则, 由归纳法可得, 输出中 Y 的比特个数满足

$$\begin{aligned} E[Y] &\geq \frac{2^\alpha}{m} + \frac{m - 2^\alpha}{m} (\lfloor \log_2 (m - 2^\alpha) \rfloor - 1) \\ &= \alpha + \frac{m - 2^\alpha}{m} (\lfloor \log_2 (m - 2^\alpha) \rfloor - \alpha - 1). \end{aligned}$$

231

假设 $\lfloor \log_2 (m - 2^\alpha) \rfloor = \beta$, 其中 $0 \leq \beta \leq \alpha - 1$, 那么当 $m = 2^\alpha + 2^\beta$ 时, $(m - 2^\alpha)/m$ 达到最小. 因此,

$$\begin{aligned} E[Y] &\geq \alpha + \frac{2^\beta}{2^\alpha + 2^\beta} (\beta - \alpha - 1) \\ &\geq \alpha - \frac{1}{2^{\alpha-\beta}} (\alpha - \beta + 1) \\ &\geq \alpha - 1. \end{aligned}$$

这就完成了归纳. ■

我们将在本节主要结论的证明中用到定理 9.4.

定理 9.5 考虑一个正面出现概率为 $p > 1/2$ 的硬币, 对任意的常数 $\delta > 0$ 及充分大的 n :

1. 存在一个提取函数 Ext, 对一个 n 次独立投掷硬币的输入序列, 平均至少有 $(1 - \delta)nH(p)$ 个独立随机比特输出.
2. 对一个 n 次独立投掷硬币的输入序列, 任意一个提取函数 Ext 输出的比特平均数至多为 $nH(p)$.

证明 我们从描述一个提取函数开始, 从投掷 n 次有偏硬币中, 提取函数平均至少产生 $(1 - \delta)nH(p)$ 个随机比特. 在此之前我们已经看到, 对有偏硬币情况, n 次投掷硬币的输出很可能是大约 $2^{nH(p)}$ 个序列中的一个, 每个的出现概率约为 $2^{-nH(p)}$. 如果我们实际上有这种类型的均匀分布, 对均匀随机选取的数便可以用刚给出的那个提取函数, 平均地得到几乎 $nH(p)$ 个均匀随机比特. 但由于分布并非恰好是均匀分布, 下面我们处理由此所产生的技术细节.

存在恰好 j 次正面的 $\binom{n}{j}$ 个可能的序列, 且其中的每一个都以相同的概率 $p^j(1-p)^{n-j}$ 出现.

对每一个 j 值, $0 \leq j \leq n$, 我们将有 j 个正面的 $\binom{n}{j}$ 个序列中的每一个序列映射为集合

$\{0, \dots, \binom{n}{j} - 1\}$ 中唯一的整数. 当出现 j 个正面时, 我们将这个序列映射为相应的整数. 在

存在 j 个正面的条件下, 这个数在整数集合 $\{0, \dots, \binom{n}{j} - 1\}$ 上是均匀的, 因此可以应用定理

9.4 为这种情况而设计的提取函数. 令 Z 为一个表示投掷出现正面次数的随机变量, B 为表示由提取函数产生的比特个数的随机变量, 那么

$$E[B] = \sum_{k=0}^n \Pr(Z = k) E[B | Z = k],$$

且由定理 9.4,

$$E[B | Z = k] \geq \left\lfloor \log_2 \binom{n}{k} \right\rfloor - 1.$$

令 $\varepsilon < p - 1/2$ 为一待定的常数, 只考虑满足 $n(p - \varepsilon) \leq k \leq n(p + \varepsilon)$ 的 k 值, 我们计算 $E[B]$ 的下界. 对每一个这样的 k , 有

$$\binom{n}{k} \geq \binom{n}{\lfloor n(p + \varepsilon) \rfloor} \geq \frac{2^{nH(p + \varepsilon)}}{n + 1}.$$

其中最后一个不等式由推论 9.3 得到. 因此

$$\begin{aligned} E[B] &\geq \sum_{k = \lfloor n(p - \varepsilon) \rfloor}^{\lfloor n(p + \varepsilon) \rfloor} \Pr(Z = k) E[B | Z = k] \\ &\geq \sum_{k = \lfloor n(p - \varepsilon) \rfloor}^{\lfloor n(p + \varepsilon) \rfloor} \Pr(Z = k) \left(\left\lfloor \log_2 \binom{n}{k} \right\rfloor - 1 \right) \end{aligned}$$

$$\begin{aligned} &\geq \left(\log_2 \frac{2^{nH(p+\varepsilon)}}{n+1} - 2 \right) \sum_{k=\lfloor n(p-\varepsilon) \rfloor}^{\lceil n(p+\varepsilon) \rceil} \Pr(Z = k) \\ &\geq (nH(p+\varepsilon) - \log_2(n+1) - 1) \Pr(|Z - nP| \leq \varepsilon n). \end{aligned}$$

现在 $E[Z] = np$ ，且由(4.6)式的切尔诺夫界，可以给出 $\Pr(|Z - np| > \varepsilon n)$ 的界，即

$$\Pr(|Z - np| > \varepsilon n) \leq 2e^{-\varepsilon^2/3p}.$$

因此

$$E[B] \geq (nH(p+\varepsilon) - \log_2(n+1) - 1)(1 - 2e^{-\varepsilon^2/3p}).$$

我们断言，对任意常数 $\delta > 0$ ，通过选择足够小的 ε 及足够大的 n ，有

$$E[B] \geq (1 - \delta)nH(p).$$

例如，对足够小的 ε ，

$$nH(p+\varepsilon) \geq (1 - \delta/3)nH(p),$$

当 $n > (3p/\varepsilon^2) \ln(6/\delta)$ 时，有

$$1 - 2e^{-\varepsilon^2/3p} \geq 1 - \delta/3.$$

因此利用这些选择，

$$E[B] \geq ((1 - \delta/3)nH(p) - \log_2(n+1) - 1)(1 - \delta/3).$$

现在只要选取足够大的 n ，使得 $(\delta/3)nH(p)$ 大于 $\log_2(n+1) + 1$ ，就有

$$E[B] \geq ((1 - 2\delta/3)nH(p))(1 - \delta/3) \geq (1 - \delta)nH(p),$$

这证明了存在一个提取函数，使得由投掷 n 次有偏硬币可以平均地提取 $(1 - \delta)nH(p)$ 个独立均匀的比特。

下面证明不存在提取函数可以得到平均意义上比 $nH(p)$ 个比特大的结果。这个证明依据下面的基本事实：如果一个输入序列 x 以概率 q 出现，那么相应的输出序列 $\text{Ext}(x)$ 至多可以有 $|\text{Ext}(x)| \leq \log_2(1/q)$ 个比特。这是因为所有具有 $|\text{Ext}(x)|$ 个比特的序列都至少有概率 q ，所以

$$2^{|\text{Ext}(x)|} q \leq 1,$$

这给出了 $\text{Ext}(x)$ 所需要的界。给定任意提取函数，如果 B 为表示由提取函数对输入 X 产生的比特个数的随机变量，那么

$$\begin{aligned} E[B] &= \sum_x \Pr(X = x) |\text{Ext}(x)| \\ &\leq \sum_x \Pr(X = x) \log_2 \frac{1}{\Pr(X = x)} \\ &= E\left[\log_2 \frac{1}{\Pr(X)} \right] \\ &= H(X). \end{aligned}$$

另外一个自然的问题就是如何从由无偏的硬币产生有偏的比特，这个问题在练习 9.11 中给出了部分的解答。



9.4 压缩

解释熵值的第二种方法来自压缩. 仍然假定有一枚正面出现概率为 $p > 1/2$ 的硬币, 投掷 n 次, 记录哪一次出现正面和哪一次出现反面的轨迹. 可以用一个比特表示每次投掷出的结果, 0 表示出现正面, 1 表示出现反面, 总共利用 n 个比特. 如果利用硬币是有偏的事实, 平均地会比较好. 例如, 假定 $p = 3/4$, 对于一对相继的投掷, 用 0 表示两次都出现正面, 10 表示第一次出现正面, 第二次出现反面, 110 表示第一次出现反面第二次出现正面, 111 表示两次出现的都是反面. 那么每一对投掷使用比特的平均个数为

$$1 \cdot \frac{9}{16} + 2 \cdot \frac{3}{16} + 3 \cdot \frac{3}{16} + 3 \cdot \frac{1}{16} = \frac{27}{16} < 2.$$

因此, 将 n 次投掷序列分成两两一对, 并用所述方法表示每一对, 平均来说可以利用少于标准方案的每次投掷用 1 个比特. 这就是一个压缩的例子.

值得强调的是在这里所用的表示法有一个特别的性质: 如果写出投掷硬币序列的表示, 就可以简单地通过按由左至右的分析唯一地进行解码. 例如, 序列

011110

对应的是两次正面、接着两次反面、再接着一次正面及一次反面. 由于没有其他投掷序列可以产生这样的输出, 所以不会产生歧义. 我们的表示法具有这样的性质是因为, 用于表示一对投掷的比特序列不会是该表示中运用的其他比特序列的前缀. 具有这种性质的表示法称为前缀码, 在练习 9.15 中会有深入的讨论.

压缩仍然是一个值得考虑研究的课题. 在存储或传输信息时, 节省比特相当于节省资源, 所以利用数据结构找到一种能减少使用比特个数的方法是值得的.

这里考虑一个压缩一系列有偏硬币投掷结果的特殊情况. 对熵为 $H(p)$ 的有偏硬币, 我们证明 (a) 投掷 n 次有偏硬币的结果可以近似地平均用 $nH(p)$ 个比特表示; (b) 近似地平均 $nH(p)$ 个比特是必需的. 特别地, 对投掷 n 次均匀硬币结果的任何一种表示, 基本上都需要 n 个比特. 所以熵就是经压缩后每次投掷硬币产生的比特平均个数的一种度量. 这一论证可以推广到任意离散随机变量 X , 使得对 n 个独立的、与 X 有相同分布的随机变量 X_1, X_2, \dots, X_n , 可以平均地用约为 $nH(X)$ 个比特表示. 在压缩的设置中, 熵可以看作输入序列中信息量的度量. 序列的熵越大, 为了表示它所需要的比特的个数越多.

下面我们用一个定义来说明这种意义下压缩的含义.

定义 9.3 压缩函数 Com 以一个 $\{H, T\}^n$ 中的元素给出的投掷 n 次硬币的序列作为输入, 输出一个比特序列, 使得对每一个投掷 n 次的输入序列都会产生不同的输出序列.

定义 9.3 相当弱, 但是对于我们的目的已经足够了. 通常, 压缩函数必须满足更强的要求; 例如, 我们可能需要一个前缀码来简化译码. 用这个较弱的定义更有利于下界的证明. 还有, 尽管在这里不关心压缩和解压缩过程的效率, 但是存在非常有效的压缩方案, 在很多情况下都是几乎最优的. 在练习 9.17 中我们将考虑一个有效的压缩方案.

下面的定理阐述了有偏硬币的熵和压缩之间的关系.

定理 9.6 考虑一个出现正面概率 $p > 1/2$ 的硬币. 对于任意常数 $\delta > 0$, 当 n 足够大时:

1. 存在一个压缩函数 Com, 使得对于独立投掷 n 次硬币的输入序列, Com 输出比特的期望个数至多为 $(1 + \delta)nH(p)$;

2. 对一个独立投掷 n 次硬币的输入序列, 任一压缩函数输出的比特的期望个数至少为 $(1 - \delta)nH(p)$.

定理 9.6 与定理 9.5 相当类似. 任一压缩函数输出的比特的期望个数的下界稍微较弱. 事实上, 可以将这个下界提高到 $nH(p)$, 如果我们坚持码是一个前缀码——使得没有输出是其他任意序列的前缀——但是不在这里证明. 为证明输出比特期望个数的上界而设计的压缩函数产生一个前缀码. 这个压缩函数的构造直观上大致与定理 9.5 相同. 我们知道, 以大的概率, 来自 n 次投掷的结果是在大致有 np 次正面的约 $2^{nH(p)}$ 个序列中的一个. 可以用大约 $nH(p)$ 个比特表示每个这样的序列, 给出一个适当的压缩函数的存在性.

235

定理 9.6 的证明 首先证明存在如定理所保证的压缩函数. 令 $\varepsilon > 0$ 为一个适当小的常数, 满足 $p - \varepsilon > 1/2$. 令 X 为在 n 次投掷硬币中出现正面的次数. 我们以压缩函数输出的第一个比特作为标志, 如果序列中至少有 $n(p - \varepsilon)$ 个正面, 就令其为 0; 否则为 1. 当第一个比特是 1 时, 压缩函数就采用花费大的缺省方案, 即对 n 次投掷中的每一次都用 1 个比特. 这样总共需要 $(n + 1)$ 个比特作为输出; 但是由 (4.5) 式的切尔诺夫界, 发生这种情况的概率不超过

$$\Pr(X < n(p - \varepsilon)) \leq e^{-n\varepsilon^2/2p}.$$

现在我们考虑至少出现 $n(p - \varepsilon)$ 次正面的情况. 这种形式的硬币投掷序列的个数为

$$\sum_{j=n(p-\varepsilon)}^n \binom{n}{j} \leq \sum_{j=n(p-\varepsilon)}^n \binom{n}{\lceil n(p-\varepsilon) \rceil} \leq \frac{n}{2} 2^{nH(p-\varepsilon)}.$$

第一个不等式成立是因为, 只要 $j > n/2$, 二项式的项是递减的; 第二个不等式是推论 9.3 的一个结果. 对每一个这样的投掷硬币序列, 压缩函数都可以指派唯一的恰有 $\lfloor nH(p - \varepsilon) + \log_2 n \rfloor$ 个比特的序列去表示它, 这是因为

$$2^{nH(p-\varepsilon) + \log_2 n} \geq \frac{n}{2} 2^{nH(p-\varepsilon)}.$$

包括标志比特, 至多占用 $nH(p - \varepsilon) + \log_2 n + 1$ 个比特去表示出现这么多正面的投掷硬币序列.

综合这些结果, 我们得到了压缩函数所需要的期望比特的个数至多为

$$e^{-n\varepsilon^2/2p}(n+1) + (1 - e^{-n\varepsilon^2/2p})(nH(p-\varepsilon) + \log_2 n + 1) \leq (1 + \delta)nH(p),$$

其中通过首先选取一个足够小的 ε , 再取足够大的 n , 在类似于定理 9.5 的意义上, 不等号成立.

现在证明下界. 首先, 回忆投掷硬币出现 k 次正面的特殊序列的概率是 $p^k(1-p)^{n-k}$. 因为 $p > 1/2$, 如果序列 S_1 比另一序列 S_2 有更多的正面, 则 S_1 比 S_2 更可能出现. 我们有下面的引理.

引理 9.7 如果序列 S_1 比 S_2 更可能出现, 那么使得输出的比特的期望个数最小化的压缩函数将指派给 S_2 一个至少像 S_1 一样长的比特序列.

236

证明 假定一个压缩函数指派给 S_2 的比特序列要比指派给 S_1 的比特序列短. 我们可以通

过转换与 S_1 和 S_2 关联的输出序列, 改善这个压缩函数输出的比特的期望个数, 所以这个压缩函数不是最优的。

因此, 对于一个最优的压缩函数, 正面越多的序列给出的字符串就越短。

还可以利用下面简单的事实。如果对 s 个硬币投掷序列中的每一个, 压缩函数指派不同的比特序列来表示, 那么对于 s 个输入序列, 其中一个的输出比特的序列长度必至少有 $\log_2 s - 1$ 个比特。这是因为至多存在 $1 + 2 + 4 + \dots + 2^b = 2^{b+1} - 1$ 个不同的直到 b 个比特的序列, 所以如果 s 个投掷硬币序列中的每一个都指派一个至多 b 个比特的序列, 那么必有 $2^{b+1} > s$, 因此 $b > \log_2 s - 1$ 。

固定一个适当小的 $\varepsilon > 0$, 数出有 $\lfloor (p + \varepsilon)n \rfloor$ 次正面的输入序列的个数。存在

$$\binom{n}{\lfloor (p + \varepsilon)n \rfloor} \text{ 个有 } \lfloor (p + \varepsilon)n \rfloor \text{ 次正面的序列, 由推论 9.3,}$$

$$\binom{n}{\lfloor (p + \varepsilon)n \rfloor} \geq \frac{2^{nH(p+\varepsilon)}}{n+1}.$$

因此对至少一个有 $\lfloor (p + \varepsilon)n \rfloor$ 次正面的投掷硬币序列, 任何一个压缩函数都必须输出至少 $\log_2(2^{nH(p+\varepsilon)}/(n+1)) - 1 = nH(p+\varepsilon) - \log_2(n+1) - 1$ 个比特。所以由引理 9.7, 使期望输出长度最小的压缩函数必须使用至少这么多多个比特去表示任一有较少正面的序列。

由(4.2)式的切尔诺夫界, 只要 n 足够大(特别地, $n > 2/\varepsilon$), 正面次数 X 满足

$$\Pr(X \geq \lfloor n(p + \varepsilon) \rfloor) \leq \Pr(X \geq n(p + \varepsilon - 1/n)) \leq e^{-n(\varepsilon - 1/n)^2/2p} \leq e^{-n\varepsilon^2/12p}.$$

这样, 以至少 $1 - e^{-n\varepsilon^2/12p}$ 的概率, 我们可以得到一个正面少于 $\lfloor n(p + \varepsilon) \rfloor$ 次的输入序列, 且由前面的理由可知, 使期望输出长度极小化的压缩函数在这种情况下仍然必定至少输出 $nH(p + \varepsilon) - \log_2(n+1) - 1$ 个比特。因此输出的比特的期望个数至少为

$$(1 - e^{-n\varepsilon^2/12p})(nH(p + \varepsilon) - \log_2(n+1) - 1).$$

通过首先取足够小的 ε , 然后取足够大的 n , 这可以至少是 $(1 - \delta)nH(p)$ 。 ■

9.5 编码: 香农定理

我们已经看到通过改变数据的表示法, 压缩可以减少表示数据所要求的比特的期望个数。编码也可以改变数据的表示。编码增加冗余码以避免数据丢失或出错, 而不是减少表示数据所要求的比特的个数。

在编码理论中, 我们建立由发送器发出的信息通过一个信道传送到接收器的模型。信道可能产生噪声, 使位信号的某些值在传输过程中失真。信道可以有线连接、无线连接或一个存储网络。例如, 如果我将数据保存在可记录的介质上并希望以后读取, 那么我既是发送器也是接收器, 而存储介质扮演信道的角色。在本节中, 我们关注一种特殊类型的信道。

定义 9.4 一个参数为 p 的二元对称信道的输入是一个位信号序列 x_1, x_2, \dots , 输出是一个位信号序列 y_1, y_2, \dots , 使得对每个 i , 独立地有 $\Pr(x_i = y_i) = 1 - p$ 。通俗地说, 发送的每个位信号以概率 p 独立地被改变为错误值。

为获得信道之外的信息，可以引入冗余以帮助避免错误的引入。作为一个极端的例子，假设发送器希望通过二元对称信道发送单个位信号信息给接收器。为减少出错的可能性，发送器和接收器同意重复位信号 n 次。如果 $p < 1/2$ ，接收器的一个自然解码方案是查看接收到的 n 个位信号，并确定接收的较频繁的值就是发送器意指的位信号值。 n 越大，接收器越可能确定正确的位信号；当位信号重复的次数足够多时，出错的概率可以任意地小。在练习 9.18 中对这个例子有更深入的讨论。

编码理论研究要求的冗余量和各种类型信道上解码错误概率之间的权衡。对二元对称信道，简单的重复位信号可能不是冗余位信号的最好用法，我们考虑更一般的编码函数。

定义 9.5 一个 (k, n) 编码函数 $\text{Enc}: \{0, 1\}^k \rightarrow \{0, 1\}^n$ 以 k 个位信号的序列作为输入，以 n 个位信号的序列作为输出。一个 (k, n) 解码函数 $\text{Dec}: \{0, 1\}^n \rightarrow \{0, 1\}^k$ 以 n 个位信号的序列作为输入，以 k 个位信号的序列作为输出。

在编码理论中，发送器采用一条 k -位消息，并经由编码函数将它编为一组 $n \geq k$ 个的位信号，然后通过信道发送这些位信号。接收器检测接收到的 n 个位信号，并用解码函数试图确定原始的 k -位消息。

给定一个参数为 p 、目标编码长度为 n 的二元信道，我们希望能确定 k 的最大值，使得存在具有以下性质的 (k, n) 编码和解码函数：对任意的 k 个位信号的输入序列，在发生信道失真后，接收器都能以适当大的概率从相应的 n -位编码序列中解码出正确的输入。

令 $m \in (0, 1)^k$ 是将要发送的消息， $\text{Enc}(m)$ 是经信道传送的位信号序列。令随机变量 X 表示收到的位信号序列。我们要求对所有可能的消息 m 及一个事先选择的常数 γ ，至少以概率 $1 - \gamma$ 有 $\text{Dec}(X) = m$ 。如果没有噪声，则可以通过信道传送原始的 k 个位信号。噪声减少了接收器从发送的每个位信号中提取的信息，所以在每组的 n 个位信号中，发送器能可靠地发送只有大约 $k = n(1 - H(p))$ 个位信号的消息。这个结果称为香农定理，我们将用下面的形式证明。

[238]

定理 9.8 对一个参数为 $p < 1/2$ 的二元对称信道以及任意的常数 $\delta, \gamma > 0$ ，当 n 足够大时：

1. 对任意的 $k \leq n(1 - H(p) - \delta)$ ，存在 (k, n) 编码和解码函数，使得对每一个可能的 k -位输入消息，接收器不能得到正确消息的概率至多为 γ 。
2. 当 $k \geq n(1 - H(p) + \delta)$ 时，对一个均匀随机选择的 k -位输入消息，不存在正确解码概率至少为 γ 的 (k, n) 编码和解码函数。

证明 当 $k \leq n(1 - H(p) - \delta)$ 时，首先用概率的方法证明适当的 (k, n) 编码和解码函数的存在性。最后，希望对每一个可能的输入，我们的编码和解码函数出错的概率至多为 γ 。从一个较弱的结果开始，当输入是从所有的 k -位输入中均匀随机地选择时，证明存在适当的编码函数。

编码函数为 2^k 个串中的每一个指派一个从所有 n -位序列空间中独立地且均匀随机地选择的 n -位的码字。将这些码字标为 $X_0, X_1, \dots, X_{2^k-1}$ 。利用一个包含了每个 k -位串的大的查询表，编码函数简单地输出指派给 k -位消息的码字。（你可能关心两个码字会出现相同的情况；

这种概率是非常小的，并且在下面的分析中进行处理。）

为了描述解码函数，我们提供一种基于编码函数的查询表的解码算法，可以假定为接收器所拥有。解码算法利用接收器预计信道产生约 pn 个错误的事实。因此接收器寻找与接收到的 n 位信号在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间不同的码字，其中 $\varepsilon > 0$ 为某个适当小的常数。如果恰有一个码字具有这种性质，那么接收器将假定这是发送的码字，并将复原相应的消息。如果具有这种性质的码字多余一个，那么解码算法失败。这里描述的了解码算法需要指数时间和空间。在本章余下的部分，我们不再如此关心效率问题。

通过所有可能的 n -位序列的简单运行，可以由算法得到相应的 (k, n) 解码函数。每当一个序列用前述的算法适当解码时，解码函数关于那个序列的输出是设置与相应码字关联的 k -位序列。当算法失效时，对这个序列的输出可能是一个任意的 k 个位信号的序列。对失效的解码函数，以下两个事件中至少一件必然发生：

- 信道产生的错误个数不是在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间。
- 当发送一个码字时，接收到的序列与某个其他码字的不同在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间。

239

现在证明的途径是清晰的。可以用切尔诺夫界证明，以大的概率，信道不会出现太多或太少的错误。在不会产生太多或太少的错误个数的条件下，问题成为以所要求的概率，多大的 k 可以保证接收到的序列在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间不会与多码字有差别。

既然已经描述了编码和解码函数，下面确定分析中使用的记号。令 R 为接收到的位信号序列。对 n -位信号序列 s_1 和 s_2 ，记 $\Delta(s_1, s_2)$ 表示序列 s_1 和 s_2 之间不同位置的个数。称 $\Delta(s_1, s_2)$ 为这两个串之间的汉明距离，我们说序列对 (s_1, s_2) 有权

$$w(s_1, s_2) = p^{\Delta(s_1, s_2)} (1-p)^{n-\Delta(s_1, s_2)}.$$

这个权对应于通过信道发送 s_1 时接收到 s_2 的概率。我们引进随机变量 $S_0, S_1, S_2, \dots, S_{2^k-1}$ 和 $W_0, W_1, W_2, \dots, W_{2^k-1}$ ，其定义如下：集合 S_i 是所有接收到的解码为 X_i 的序列集合。值 W_i 由

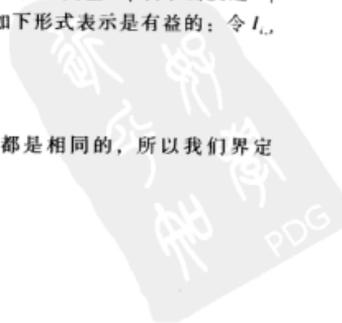
$$W_i = \sum_{r \in S_i} w(X_i, r)$$

给出。 S_i 和 W_i 为只依赖于 $X_1, X_2, \dots, X_{2^k-1}$ 的随机选择的随机变量。变量 W_i 表示当发送 X_i 时，接收到的序列 R 不在 S_i 中因此解码不正确的概率。将 W_i 用如下形式表示是有益的：令 $I_{i,r}$ 为一示性随机变量，若 $r \notin S_i$ ，则为 1；其他情况为 0，可以记

$$W_i = \sum_r I_{i,r} w(X_i, r).$$

我们从界定 $E[W_i]$ 开始。由对称性，对所有的 i ， $E[W_i]$ 都是相同的，所以我们界定 $E[W_0]$ 。现在

$$\begin{aligned} E[W_0] &= E \left[\sum_r I_{0,r} w(X_0, r) \right] \\ &= \sum_r E[w(X_0, r) I_{0,r}]. \end{aligned}$$



将和式分成两部分. 令 $T_1 = \{s: |\Delta(X_0, s) - pn| > \varepsilon n\}$, $T_2 = \{s: |\Delta(X_0, s) - pn| \leq \varepsilon n\}$, 其中 $\varepsilon > 0$ 为某个待定的常数. 那么有

$$\sum_r E[w(X_0, r)I_{0,r}] = \sum_{r \in T_1} E[w(X_0, r)I_{0,r}] + \sum_{r \in T_2} E[w(X_0, r)I_{0,r}],$$

我们界定其中的每一项.

首先界定

$$\begin{aligned} \sum_{r \in T_1} E[w(X_0, r)I_{0,r}] &\leq \sum_{r \in T_1} w(X_0, r) \\ &= \sum_{r: |\Delta(X_0, r) - pn| > \varepsilon n} p^{\Delta(X_0, r)} (1-p)^{n-\Delta(X_0, r)} \\ &= \Pr(|\Delta(X_0, R) - np| > \varepsilon n). \end{aligned}$$

240

即为了界定第一项, 我们只需简单地界定由于错误个数不在 $[(p-\varepsilon)n, (p+\varepsilon)n]$ 范围内的概率使得接收器没有正确解码的概率, 以及错误个数不在这个范围内的概率. 等价地, 我们得到了由于假定信道引入太多或太少的错误而不能正确解码的界. 这个概率是非常小的, 因为由切尔诺夫界的(4.6)式, 我们可以看出:

$$\Pr(|\Delta(X_0, R) - np| > \varepsilon n) \leq 2e^{-\varepsilon^2 n / 3p}.$$

对任意的 $\varepsilon > 0$, 可以选取足够大的 n , 使这个概率并因此 $\sum_{r \in T_1} E[w(X_0, r)I_{0,r}]$ 小于 $\gamma/2$.

现在求 $\sum_{r \in T_2} E[w(X_0, r)I_{0,r}]$ 的上界. 对每个 $r \in T_2$, 当接收到 r 时, 解码算法将是成功的, 除非 r 与某个其他码字 X_i 在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间不同. 因此只有当存在这样的 X_i 时, $I_{0,r}$ 为 1, 所以对任意 X_0 值和 $r \in T_2$, 我们有

$$E[w(X_0, r)I_{0,r}] = w(X_0, r) \Pr(\text{对某个 } X_i, 1 \leq i \leq 2^k - 1, |\Delta(X_i, r) - pn| \leq \varepsilon n).$$

由此, 如果对任意 X_0 值和 $r \in T_2$, 我们得到一个上界

$$\Pr(\text{对某个 } X_i, 1 \leq i \leq 2^k - 1, |\Delta(X_i, r) - pn| \leq \varepsilon n) \leq \gamma/2,$$

那么

$$\sum_{r \in T_2} E[w(X_0, r)I_{0,r}] \leq \sum_{r \in T_2} w(X_0, r) \frac{\gamma}{2} \leq \frac{\gamma}{2}.$$

为得到这个上界, 我们回忆其他码字 $X_1, X_2, \dots, X_{2^k-1}$ 是独立地且均匀随机选取的. 因此, 任何其他特殊的码字 $X_i (i > 0)$ 与任意给定的长为 n 的串 r 在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 范围内不同的概率至多为

$$\sum_{j=\lfloor n(p-\varepsilon) \rfloor}^{\lfloor n(p+\varepsilon) \rfloor} \binom{n}{j} \frac{1}{2^n} \leq n \frac{\binom{n}{\lfloor n(p+\varepsilon) \rfloor}}{2^n}$$

这里我们用 n 乘以它的最大项作为和的上界; 当 $j = \lfloor n(p+\varepsilon) \rfloor$ 取遍和式中所有的 j 时, 只要所选的 ε 满足 $p+\varepsilon < 1/2$, $\binom{n}{j}$ 便达到最大.

利用推论 9.3,

$$\frac{\binom{n}{\lfloor n(p+\varepsilon) \rfloor}}{2^n} \leq \frac{2^{H(p+\varepsilon)n}}{2^n} \\ = 2^{-n(1-H(p+\varepsilon))}.$$

因此任意特定的 X_i 在位数上与串 r 匹配, 从而引起一个解码失败的概率至多为 $n2^{-n(1-H(p+\varepsilon))}$. 由并的界, 当发送 X_0 时, 其他 $2^k - 1$ 个码字中的任意一个导致解码失败的概率至多为

$$n2^{-n(1-H(p+\varepsilon))} (2^k - 1) \leq n2^{n(H(p+\varepsilon) - H(p) - \delta)},$$

其中用到了 $k \leq n(1 - H(p) - \delta)$ 的事实. 通过选取足够小的 ε 使 $H(p + \varepsilon) - H(p) - \delta$ 为负, 再选取充分大的 n , 可以使该项如所要求的那样小, 特别地可使它小于 $\gamma/2$.

集合 T_1 和 T_2 对应于解码算法中两种错误类型, 通过对这两个集合 T_1 和 T_2 的界求和, 可以得到 $E[W_0] \leq \gamma$.

可以对这个结果进行自助, 以证明存在一个特殊的码, 使得如果发送的 k -位消息是均匀随机选取的, 那么这个码以概率 γ 失败. 利用期望的线性和概率方法, 有

$$\sum_{j=0}^{2^k-1} E[W_j] = E\left[\sum_{j=0}^{2^k-1} W_j\right] \leq 2^k \gamma,$$

其中, 期望是关于码字 $X_0, X_1, \dots, X_{2^k-1}$ 的随机选择而取的. 根据概率方法, 必存在一个特殊的码字集合 $x_0, x_1, \dots, x_{2^k-1}$, 使得

$$\sum_{j=0}^{2^k-1} W_j \leq 2^k \gamma.$$

当发送的 k -位消息是均匀随机地选取时, 这个码字集合错误的概率为

$$\frac{1}{2^k} \sum_{j=0}^{2^k-1} W_j \leq \gamma.$$

这就证明了论断.

我们现在证明定理中一个更强的结论: 可以选取码字, 使得对每一单个码字失败的概率的上界为 γ . 注意这不能由前面的分析得到, 以前只是简单地证明了码字失败的平均概率的上界为 γ .

我们已经证明存在一组码字 $x_0, x_1, \dots, x_{2^k-1}$, 满足

$$\sum_{j=0}^{2^k-1} W_j \leq 2^k \gamma.$$

不失一般性, 假定 x_i 是以 W_i 的升序排序的. 假设消去具有最大值 W_i 的码字的一半; 即消去的是在发送时发生错误有最大概率的那些码字. 我们断言对每个 x_i ($i < 2^{k-1}$) 必满足 $W_i \leq 2\gamma$; 否则得到一个矛盾

$$\sum_{j=2^{k-1}}^{2^k-1} W_j > 2^{k-1} (2\gamma) = 2^k \gamma.$$

(利用与在 3.1 节中证明马尔可夫不等式类似的理由.)

我们可以仅用这 2^{k-1} 个码字对所有的 $(k-1)$ -位串建立新的编码和解码函数, 现在对每个码字的错误概率同时至多为 2γ . 因此, 必须证明当 $k-1 \leq n(1-H(p)-\delta)$ 时, 存在一个代码使得对任何发送的消息, 接收器没有得到正确消息的概率至多为 2γ . 因为 δ 和 γ 是任意的常数, 令 $\gamma' = \gamma/2$, $\delta' = \delta/2$. 那么有 $k-1 \leq n(1-H(p)-2\delta')$, 这蕴涵 $k \leq n(1-H(p)-\delta')$, 所以对任意单个码字编码失败的概率的界为 γ' . 用 γ' 和 δ' 代替 γ 和 δ , 这恰好是定理前半部分的陈述, 因此定理的这一部分已经得证.

完成了定理前半部分的证明后, 现在转向后半部分的证明: 对任意的常数 $\delta, \gamma > 0$ 及充分大的 n , 不存在满足 $k \geq n(1-H(p)-\delta')$ 的 (k, n) 编码和解码函数, 使得对一个均匀随机选取的 k -位输入消息, 正确解码的概率至少是 γ .

在给出证明之前, 先考虑一些有用的直觉. 我们知道由信道产生的错误个数以大的概率在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间, 其中 $\varepsilon > 0$ 为适当的常数. 假设我们试图构造解码函数, 使得当错误个数在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间时, 每个码字都能正确地解码. 那么由这个解码函数, 每个码字与

$$\sum_{k=\lfloor (p-\varepsilon)n \rfloor}^{\lfloor (p+\varepsilon)n \rfloor} \binom{n}{k} \geq \binom{n}{\lfloor np \rfloor} \geq \frac{2^{nH(p)}}{n+1}$$

个位的序列关联; 最后一个不等号由推论 9.3 得到. 但存在 2^k 个相异的码字, 且当 n 充分大时,

$$2^k \frac{2^{nH(p)}}{n+1} \geq 2^{n(1-H(p)+\delta)} \frac{2^{nH(p)}}{n+1} > 2^n.$$

因为只有 2^n 个可能的位序列可以被接收到, 所以不可能构造一个解码函数, 使得当错误个数在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间时总能正确地解码.

我们现在需要将这个证明推广到任意的编码和解码函数. 这个证明比较复杂, 因为不能假定当错误个数在 $(p-\varepsilon)n$ 和 $(p+\varepsilon)n$ 之间时, 解码函数必须试图正确地解码, 尽管这看起来是可以追求的最好方法.

已知码字为 $x_0, x_1, \dots, x_{2^k-1}$ 的任一固定的编码函数和任一固定的解码函数, 令 z 为成功解码的概率. 定义 S_i 为所有解码为 x_i 的接收到的序列集合. 那么

$$\begin{aligned} z &= \sum_{i=0}^{2^k-1} \sum_{s \in S_i} \Pr((x_i \text{ 被发送}) \cap (R = s)) \\ &= \sum_{i=0}^{2^k-1} \sum_{s \in S_i} \Pr(x_i \text{ 被发送}) \Pr(R = s | x_i \text{ 被发送}) \\ &= \frac{1}{2^k} \sum_{i=0}^{2^k-1} \sum_{s \in S_i} \Pr(R = s | x_i \text{ 被发送}) \\ &= \frac{1}{2^k} \sum_{i=0}^{2^k-1} \sum_{s \in S_i} w(x_i, s) \end{aligned}$$

第二行由条件概率的定义得到. 第三行利用了这样的事实, 即发送的消息(因此发送的码字)是从所有码字中均匀随机选取的. 第四行恰好是权函数的定义.

为了界定最后一行, 再次将和式 $\sum_{i=0}^{2^k-1} \sum_{s \in S_i} w(x_i, s)$ 分成两部分. 令 $S_{i,1} = \{s \in S_i : |\Delta(x_i, s) - pn| > \varepsilon n\}$, $S_{i,2} = \{s \in S_i : |\Delta(x_i, s) - pn| \leq \varepsilon n\}$, 其中 $\varepsilon > 0$ 仍为某一特定的常数. 那么

$$\sum_{s \in S_i} w(x_i, s) = \sum_{s \in S_{i,1}} w(x_i, s) + \sum_{s \in S_{i,2}} w(x_i, s).$$

现在

$$\sum_{s \in S_{i,1}} w(x_i, s) \leq \sum_{s: |\Delta(x_i, s) - pn| > \varepsilon n} w(x_i, s),$$

这可由切尔诺夫界定. 右边的和简单地表示由信道产生的错误个数不在 $(p - \varepsilon)n$ 和 $(p + \varepsilon)n$ 之间的概率, 在前面的讨论中我们知道这个概率至多为 $2e^{-\varepsilon^2 n/2}$. 这个界等价于假设即使信道产生太多或太少的错误个数, 解码是成功的; 因为错误过多或过少的概率都是小的, 所以由这个假设仍然产生一个好的界.

为给出 $\sum_{s \in S_{i,2}} w(x_i, s)$ 的界, 我们注意 $w(x_i, s)$ 关于 $\Delta(x_i, s)$ 是递减的. 因此, 对 $s \in S_{i,2}$,

$$\begin{aligned} w(x_i, s) &\leq p^{(p-\varepsilon)n} (1-p)^{(1-p+\varepsilon)n} \\ &= p^{pn} (1-p)^{(1-p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n} \\ &= 2^{-H(p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n}. \end{aligned}$$

所以,

$$\begin{aligned} \sum_{s \in S_{i,2}} w(x_i, s) &\leq \sum_{s \in S_{i,2}} 2^{-H(p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n} \\ &= 2^{-H(p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n} |S_{i,2}|. \end{aligned}$$

继续可以得到

$$\begin{aligned} z &= \frac{1}{2^k} \sum_{i=0}^{2^k-1} \sum_{s \in S_i} w(x_i, s) \\ &= \frac{1}{2^k} \sum_{i=0}^{2^k-1} \left(\sum_{s \in S_{i,1}} w(x_i, s) + \sum_{s \in S_{i,2}} w(x_i, s) \right) \\ &\leq \frac{1}{2^k} \sum_{i=0}^{2^k-1} \left(2e^{-\varepsilon^2 n/2} + 2^{-H(p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n} |S_{i,2}| \right) \\ &= 2e^{-\varepsilon^2 n/2} + \frac{1}{2^k} 2^{-H(p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n} \sum_{i=0}^{2^k-1} |S_{i,2}| \\ &\leq 2e^{-\varepsilon^2 n/2} + \frac{1}{2^k} 2^{-H(p)n} \left(\frac{1-p}{p}\right)^{\varepsilon n} 2^n. \end{aligned}$$

在最后一行中, 我们用到了一个重要的事实, 即位序列 S_i 的集合 (因此所有 $S_{i,2}$) 都是不相交的, 所以它们总数的大小至多为 2^n . 这是我们使用解码函数发挥了作用, 允许建立一个有用

的界.

结论为

$$\begin{aligned} z &\leq 2e^{-\varepsilon^2 n/3p} + 2^{\varepsilon - (1-H(p)+\delta)n - H(p)n} \left(\frac{1-p}{p} \right)^{\varepsilon n} \\ &= 2e^{-\varepsilon^2 n/3p} + \left(\left(\frac{1-p}{p} \right)^{\varepsilon} 2^{-\delta} \right)^n. \end{aligned}$$

只要选择充分小的 ε , 使

$$\left(\frac{1-p}{p} \right)^{\varepsilon} 2^{-\delta} < 1,$$

那么当 n 充分大时, 就有 $z < \gamma$, 这就证明了定理 9.8. ■

香农定理证明了在足够长的区段传输任意接近二进制对称信道容量的代码的存在性. 但是定理既没有给出明确的代码, 也没有说明这样的代码可以有效地编码和解码. 在香农完成最初的工作之后, 花费了几十年的时间才找到具有几乎最优性能的实际代码.

练习

9.1 (a) 令 $S = \sum_{k=1}^{10} 1/k^2$. 考虑一个随机变量 X , 对任意整数 $k=1, 2, \dots, 10$, 有 $\Pr(X=k) = 1/Sk^2$. 求 $H(X)$.

(b) 令 $S = \sum_{k=1}^{10} 1/k^3$. 考虑一个随机变量 X , 对任意整数 $k=1, 2, \dots, 10$, 有 $\Pr(X=k) = 1/Sk^3$. 求 $H(X)$.

(c) 考虑 $S_{\alpha} = \sum_{k=1}^{10} 1/k^{\alpha}$, 其中 $\alpha > 1$ 是常数. 考虑随机变量 X_{α} , 对任意整数 $k=1, 2, \dots, 10$, 有 $\Pr(X_{\alpha}=k) = 1/S_{\alpha}k^{\alpha}$. 给出直观的说明来解释 $H(X_{\alpha})$ 是否是关于 α 的递增或递减函数, 并且说明为什么.

9.2 考虑一粒 n 面的骰子, 其中第 i 面向上的概率为 p_i . 证明当每面都以相同的概率 $1/n$ 向上时, 投掷骰子的熵达到最大.

9.3 (a) 反复投掷一枚均匀硬币直到出现第一次正面. 令 X 为所需的投掷次数, 求 $H(X)$.

(b) 你的朋友反复投掷一枚均匀硬币, 直到出现第一次正面. 你想要确定需要投掷多少次. 你可以提问一系列只回答是或否的下面形式的问题: 给你的朋友一个整数集合, 如果所投掷的次数在这个集合中, 你的朋友回答“是”; 否则回答“不是”. 给出一个策略, 使得在确定所投掷的次数之前, 你必须问的问题的期望个数是 $H(X)$.

(c) 给出直观的解释: 为什么你不能提出一个允许你的问题平均地少于 $H(X)$ 个的策略.

9.4 (a) 证明

$$S = \sum_{k=2}^{\infty} \frac{1}{k \ln^2 k}$$

是有限的.

(b) 考虑由下式给出的整值离散随机变量 X ,

$$\Pr(X = k) = \frac{1}{Sk \ln^2 k}, \quad k \geq 2.$$

证明 $H(X)$ 是无界的.

9.5 假定 p 是在实区间 $[0, 1]$ 上均匀随机选取的. 计算 $E[H(p)]$.

9.6 条件熵 $H(Y|X)$ 定义为

$$H(Y|X) = \sum_{x,y} \Pr((X=x) \cap (Y=y)) \log_2 \Pr(Y=y|X=x).$$

如果 $Z = (X, Y)$, 证明

$$H(Z) = H(X) + H(Y|X).$$

9.7 斯特林公式的一种形式为

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

利用这个公式, 证明

$$\binom{n}{qn} \geq \frac{2^{nH(q)}}{2\sqrt{n}},$$

这是一个比引理 9.2 更紧的界.

9.8 在定理 9.5 中已经证明了可以用递归的程序, 平均地从一个均匀随机地取自 $S = \{0, \dots, m-1\}$ 的数 X 中, 提取至少 $\lfloor \log_2 m \rfloor - 1$ 个独立无偏的比特. 考虑下面的提取函数: 令 $\alpha = \lfloor \log_2 m \rfloor$, 并记

$$m = \beta_\alpha 2^\alpha + \beta_{\alpha-1} 2^{\alpha-1} + \dots + \beta_0 2^0,$$

其中每个 β_i 是 1 或 0.

令 k 为使 β_i 等于 1 的 i 值的个数. 用下面的方法将 S 分为 k 个互不相交的子集: 存在一个使每个 β_i 值等于 1 的集合, 且对这个 i , 集合有 2^i 个元素. S 对集合的指派可以是任意的, 只要得到的集合是互不相交的. 为了得到一个提取函数, 我们将有 2^i 个元素的子集中的元素按照一对一的方式映射为长度为 i 的 2^i 个二进制字符串.

证明这个映射等价于定理 9.5 中给出的递归提取程序, 这两种方法对所有的 i 都以相同的概率产生 i 个比特.

9.9 我们已经证明, 可以从一个均匀随机地取自 $\{0, \dots, m-1\}$ 的数中, 平均提取至少 $\lfloor \log_2 m \rfloor - 1$ 个独立无偏的比特. 因此, 如果有 k 个均匀随机地取自 $\{0, \dots, m-1\}$ 的数, 那么可以从中平均提取至少 $k \lfloor \log_2 m \rfloor - k$ 个独立无偏的比特. 给出一个较好的程序, 使得可以从这些数中平均地提取至少 $k \lfloor \log_2 m \rfloor - 1$ 个独立无偏的比特.

9.10 假定有产生独立地投掷均匀硬币的方法.

(a) 给出一个利用恰好投掷 $\log_2 n$ 次硬币产生一个均匀地取自 $\{0, 1, \dots, n-1\}$ 中的数的算法, 其中 n 是 2 的幂.

(b) 如果 n 不是 2 的幂, 证明对任意固定的 k , 没有算法可以利用恰好投掷 k 次硬币产

生一个均匀地取自 $\{0, 1, \dots, n-1\}$ 的数.

(c) 如果 n 不是 2 的幂, 证明对任意固定的 k , 没有算法可以利用至多 k 次投掷产生一个均匀地取自 $\{0, 1, \dots, n-1\}$ 的数.

(d) 给出一个即使当 n 不是 2 的幂时, 利用至多 $2\lceil \log_2 n \rceil$ 次期望投掷, 产生一个均匀地取自 $\{0, 1, \dots, n-1\}$ 的数的算法.

9.11 假定有产生独立地投掷均匀硬币的方法.

(a) 利用均匀硬币给出一个模拟以概率 p 出现正面的有偏硬币投掷的算法. 你的算法所用的期望投掷次数必须至多为 2. (提示: 将 p 写成用二进制表示的小数, 并用均匀硬币产生二进制的小数数字.)

(b) 给出一个利用硬币产生一个均匀地取自 $\{0, 1, \dots, n-1\}$ 的数的算法, 算法所用的期望投掷次数必须至多为 $\lceil \log_2 n \rceil + 2$.

9.12 有一个提取算法 A , 它的输入是 n 次独立投掷一枚出现正面概率为 $p > 1/2$ 的硬币序列 $X = x_1, x_2, \dots, x_n$. 将序列分为 $\lfloor n/2 \rfloor$ 对, 对 $i = 1, \dots, \lfloor n/2 \rfloor$, 有 $a_i = (x_{2i-1}, x_{2i})$. 依次考虑这些对, 如果 $a_i = (\text{正}, \text{反})$, 那么输出一个 0; 如果 $a_i = (\text{反}, \text{正})$, 那么输出一个 1; 其他情况, 移向下一对.

(a) 证明提取出的比特是独立无偏的.

(b) 证明提取比特的期望个数是 $\lfloor n/2 \rfloor 2p(1-p) \approx np(1-p)$.

(c) 可以从序列 X 导出另一个投掷硬币的集合 $Y = y_1, y_2, \dots$ 如下. 从 $j, k = 1$ 开始, 重复以下的运算直到 $j = \lfloor n/2 \rfloor$: 如果 $a_j = (\text{正}, \text{正})$, 令 y_k 为正面, 并增加 j, k ; 如果 $a_j = (\text{反}, \text{反})$, 令 y_k 为反面, 并增加 j, k ; 否则增加 j . 图 9.3 给出了一个例子.

X	H	H	T	T	H	T	H	H	H	T	H	H	T	T	T	T	T
Y	H	T	H	H	T	T	T	T	T	T	T	T	T	T	T	T	T
Z	H	H	T	H	T	H	T	H	T	H	T	H	T	H	T	H	T
Y	H	T	H	H	T	T	Z	H	H	T	H	T	H	T	H	T	H
	H	T	H	H	T	T	H	H	T	H	T	H	T	H	T	H	T
	T	H	H	H	T	T	H	H	T	H	T	H	T	H	T	H	T

图 9.3 在对输入序列 X 运行 A 后, 可以得到进一步的序列 Y 和 Z ; 再对 Y 和 Z 的每一个运行 A , 可以由此得到更进一步的序列; 等等

这里直观上产生了某些随机性, 即 A 不能有效地利用, 也不能重复利用. 证明关于 Y 运行 A 得到的比特是独立无偏的, 进一步证明它们与由关于 X 运行 A 得到的比特独立.

(d) 可以由序列 X 导出第二个投掷硬币的集合 $Z = z_1, z_2, \dots, z_{\lfloor n/2 \rfloor}$ 如下: 令 z_i 为正面, 如果 $a_i = (\text{正}, \text{正})$ 或 $(\text{反}, \text{反})$; 其他情况令 z_i 为反面. 见图 9.3 的一个例子. 证明关于 X 运行 A 产生的比特是独立无偏的, 进一步证明它们与关于 X 和 Y 运行 A 产生的比特独立.

(e) 在导出 Y 和 Z , 并关于 Y 和 Z 运行 A 之后, 可以用相同的方法关于这些序列运行 A .

从而递归地从这些序列中的每一个导出两个进一步的序列,等等.图 9.3 给出了一个例子.当序列 X 的长度趋于无穷时,令 $A(p)$ 表示序列 X 中每次投掷硬币(出现正面的概率为 p)所提取的平均比特数.证明 $A(p)$ 满足递归式

$$A(p) = p(1-p) + \frac{1}{2}(p^2 + q^2)A\left(\frac{p^2}{p^2 + q^2}\right) + \frac{1}{2}A(p^2 + (1-p)^2).$$

(f) 证明熵函数 $H(p)$ 满足上面的关于 $A(p)$ 的递归式.

(g) 执行(e)中说明的递归提取过程.对于由出现正面概率为 $p = 0.7$ 的硬币产生 1 024 个比特的序列运行 1 000 次.给出对所有 1 000 次运行所提取的投掷次数的分布,并讨论你的结果如何接近 $1024 \cdot H(0.7)$.

- 9.13 假定不用有偏的硬币,而是用一粒熵为 $h > 0$ 的有偏的六面体骰子.修改有偏硬币的提取函数,使得对投掷骰子序列中的每次投掷平均提取几乎 h 个随机比特.形式地证明你的提取函数是通过恰当地修改定理 9.5 而工作的.
- 9.14 假定代替有偏的硬币,我们有一粒熵为 $h > 0$ 的有偏的六面体骰子.修改有偏硬币的压缩函数,使得将 n 次投掷骰子序列平均地压缩为几乎 nh 个比特.形式地证明你的压缩函数是通过恰当地修改定理 9.6 而工作的.
- 9.15 我们希望压缩一个独立同分布的随机变量序列 X_1, X_2, \dots , 每个 X_i 取 n 个值中的一个.将第 i 个值映射为一个 ℓ_i 比特序列的码字.我们希望这些码字有这样的性质:没有码字是任意其他码字的前缀.

(a) 说明当依次读取比特时,上述性质如何用于简单地解压由这个压缩算法建立的串.

(b) 证明 ℓ_i 必须满足

$$\sum_{i=1}^n 2^{-\ell_i} \leq 1.$$

这称为 Kraft 不等式.

- 9.16 我们希望压缩一个独立同分布的随机变量序列 X_1, X_2, \dots , 每个 X_i 取 n 个值中的一个.第 i 个值以概率 p_i 出现,其中 $p_1 \geq p_2 \geq \dots \geq p_n$. 结果被压缩为如下:令

$$T_i = \sum_{j=1}^{i-1} p_j,$$

第 i 个码字为 T_i 的前 $\log_2(1/p_i)$ 个比特.从一个空串开始,依次考虑 X_i .如果 X_i 取第 i 个值,则将第 i 个码字加到串的最后.

(a) 证明没有码字是任意其他码字的前缀.

(b) 令 z 是每个随机变量 X_i 附加比特的平均数.证明

$$H(X) \leq z \leq H(X) + 1.$$

- 9.17 算术编码是一种标准的压缩方法.当被压缩的串是一个投掷有偏硬币的序列时,可以描述为如下:假定有一个比特序列 $X = (X_1, X_2, \dots, X_n)$, 其中每个 X_i 独立地以概率 p 为 0, 以概率 $1-p$ 为 1. 序列是按词典顺序排序的,所以对 $x = (x_1, x_2, \dots, x_n)$ 和 $y = (y_1, y_2, \dots, y_n)$, 若第一个使得 $x_i \neq y_i$ 的坐标 i 中有 $x_i = 0$ 且 $y_i = 1$, 则说 $x < y$. 如果

z_x 是串 x 中 0 的个数, 那么定义 $p(x) = p^{z_x}(1-p)^{n-z_x}$ 及 $q(x) = \sum_{y < x} p(y)$.

- (a) 假定顺序地给出 $X = (X_1, X_2, \dots, X_n)$. 说明如何在 $O(n)$ 时间内计算 $q(x)$. (可以假定对实数的每种运算需要不变的时间.)
- (b) 证明区间 $[q(x), q(x) + p(x)]$ 是 $[0, 1]$ 上的不相交子区间;
- (c) 已知 (a) 和 (b), 序列 X 可表示为区间 $[q(X), q(X) + p(X)]$ 中任意一点. 证明可在 $[q(X), q(X) + p(X)]$ 中选取一个有 $\lceil \log_2(1/p(X)) \rceil + 1$ 个二进制位的十进制小数的码字来表示 X , 且用这种方法没有码字是任意其他码字的前缀.
- (d) 给定一个选自 (c) 中的码字, 说明如何对它解压以确定对应的序列 (X_1, X_2, \dots, X_n) .
- (e) 利用切尔诺夫界, 证明 $\log_2(1/p(X))$ 以大的概率接近 $H(p)$. 因此这种方法给出一个有效的压缩方案.
- 9.18 Alice 要通过二元对称信道把一次投掷均匀硬币的结果发送给 Bob, 每个位信号被翻转的概率为 $p < 1/2$. 为避免在传输中出错, 她将正面编码为 $2k+1$ 个 0 的序列, 将反面编码为 $2k+1$ 个 1 的序列.
- (a) 考虑 $k=1$ 的情况, 则正面编码为 000, 反面编码为 111. 对可以收到的 8 种可能的 3 个位序列中的每一个, 在 Bob 接收到那个序列的条件下, 确定 Alice 投掷出一个正面的概率.
- (b) Bob 通过检查 3 个位进行解码. 如果有 2 个或 3 个位是 0, Bob 决定对应的硬币投掷是一次正面. 证明对每次投掷, 这种规则使错误概率极小.
- (c) 对一般的 k , 如果至少有 $k+1$ 个位是 0, Bob 决定投掷是一次正面, 证明这种规则使错误概率极小.
- (d) 给出一个 Bob 出错的概率公式, 使之对一般的 k 成立. 计算当 $p=0.1$ 且 k 取 1 到 6 时这个概率公式的值.
- (e) 利用切尔诺夫界, 给出 (d) 中计算的概率的界.
- 9.19 考虑下面的信道. 发送者发送集合 $\{0, 1, 2, 3, 4\}$ 中的一个符号. 信道会产生错误: 在发送符号 k 时, 接收器以 $1/2$ 的概率接收到 $k+1 \pmod 5$, 并以 $1/2$ 的概率接收到 $k-1 \pmod 5$. 当发送多个符号时, 错误是相互独立的.

对这样的信道我们定义编码和解码函数. 一个 (j, n) 编码函数 Enc 将 $\{0, 1, \dots, j-1\}$ 中的一个数映射为 $\{0, 1, 2, 3, 4\}^n$ 中的一个序列, 一个 (j, n) 解码函数 Dec 将 $\{0, 1, 2, 3, 4\}^n$ 中的序列映射回 $\{0, 1, \dots, j-1\}$ 中. 注意这个定义与我们用于二元对称信道的位序列有些许的不同.

存在错误概率为 0 的 $(1, 1)$ 编码和解码函数. 编码函数将 0 映射为 0, 1 映射为 1. 当发送 0 时, 接收器接收到的是 1 或 4, 所以解码函数将 1 和 4 映射回为 0; 当发送 1 时, 接收器接收到的是 2 或 0, 所以解码函数将 2 和 0 映射回为 1. 这样保证不产生错误. 因此对每次信道使用, 至少有一个位是可以无错误地发送的.

- (a) 证明存在错误概率为 0 的 $(5, 2)$ 编码和解码函数. 证明这意味着信道的每一次使用可发送多于一个位的信息.

(b) 证明如果存在错误概率为 0 的 (j, n) 编码和解码函数, 那么 $n \geq \log_2 j / (\log_2 5 - 1)$.

- 9.20 一个二元删除信道传输一个 n 位的序列. 每一个位或者没有错误地成功到达, 或者不能成功地到达, 而以一个“?”符号替代, 表示不知道那个位是 1 或 0. 失败以概率 p 独立地发生. 可以用类似于二元对称信道的方法, 对二元删除信道定义 (k, n) 编码函数和解码函数, 除非这里的解码函数 $\text{Dec}: \{0, 1, ?\}^n \rightarrow \{0, 1\}^k$ 必须能处理有“?”符号的序列.

证明对任意 $p > 0$ 及任意的常数 $\delta, \gamma > 0$, 如果 n 足够大, 那么存在 (k, n) 编码函数和解码函数, 其中 $k \leq n(1 - p - \delta)$, 使得对每一个可能的 k -位输入消息, 接收器不能获得正确消息的概率至多 γ .

- 9.21 在证明香农定理时, 我们利用了下面的解码方法: 对适当选择的 ε , 寻找一个与接收到的位序列有 $(p - \varepsilon)n$ 与 $(p + \varepsilon)n$ 之间不同的码字; 如果只存在一个这样的码字, 解码器认为那个码字就是发送的码字. 假定代之以解码器寻找与接收到的序列有最少位数不同的码字(随意地处理), 并认为那个码字就是发送的码字. 说明对这种解码技术如何修改香农定理的证明以得到类似的结果.



第 10 章 蒙特卡罗方法

蒙特卡罗方法是有关通过抽样和模拟来估计值的工具集成。蒙特卡罗技术广泛应用于物理学和工程的几乎所有领域。在这一章，我们首先用给出常数 π 值的一个估计的简单试验，提出通过抽样估计一个值的基本思想。用抽样进行估计经常会比这个简单例子复杂得多。通过考虑如何适当地抽样以估计析取范式 (DNF) 布尔公式的满足的赋值个数，来说明在设计一个有效的抽样过程中可能产生的潜在的困难。

然后我们转向一般的研究，演示从几乎均匀的抽样到组合对象的近似计数的一般的简化方法。这致使我们考虑如何得到几乎均匀的样本，一种方法是在本章最后一节介绍的马尔可夫链蒙特卡罗方法 (MCMC)。

10.1 蒙特卡罗方法

考虑估计常数 π 值的以下方法。设 (X, Y) 是在平面上以原点 $(0, 0)$ 为中心的一个 2×2 的正方形内均匀选取的一点，这等价于在 $[-1, 1]$ 的均匀分布中独立地选取 X 和 Y 。圆心在 $(0, 0)$ 且半径为 1 的圆在这个正方形的内部，面积为 π 。如果令

$$Z = \begin{cases} 1 & \text{如果 } \sqrt{X^2 + Y^2} \leq 1, \\ 0 & \text{其他,} \end{cases}$$

那么，因为点是从 2×2 正方形内均匀选取的，所以 $Z = 1$ 的概率恰好是圆的面积与正方形面积的比，见图 10.1。因此

252

$$\Pr(Z = 1) = \frac{\pi}{4}.$$

假设进行这个试验 m 次 (运行过程中 X 和 Y 是独立选取的)， Z_i 表示第 i 次试验的 Z 值。如果

$W = \sum_{i=1}^m Z_i$ ，那么

$$E[W] = E\left[\sum_{i=1}^m Z_i\right] = \sum_{i=1}^m E[Z_i] = \frac{m\pi}{4},$$

因此 $W' = (4/m)W$ 是 π 的一个自然估计。利用 (4.6) 式的切尔诺夫界，我们计算

$$\begin{aligned} \Pr(|W' - \pi| \geq \varepsilon\pi) &= \Pr\left(\left|W - \frac{m\pi}{4}\right| \geq \frac{\varepsilon m\pi}{4}\right) \\ &= \Pr(|W - E[W]| \geq \varepsilon E[W]) \\ &\leq 2e^{-m\varepsilon^2/12}. \end{aligned}$$

因此，利用足够大的样本，以大的概率可以得到如我们希望那样紧的一个 π 的近似。

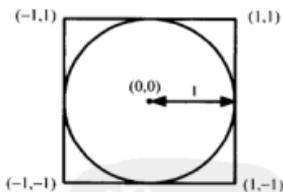


图 10.1 在正方形内均匀随机选取的一点以 $\pi/4$ 的概率落在圆内

这种近似 π 的方法是我们现在描述的更一般的近似算法类中的一个例子。

定义 10.1 一个随机化算法给出 V 值的 (ε, δ) 近似, 如果算法的输出 X 满足

$$\Pr(|X - V| \leq \varepsilon V) \geq 1 - \delta.$$

我们估计 π 的方法给出了一个 (ε, δ) 近似, 只要 $\varepsilon < 1$, 并取 m 足够大, 使得

$$2e^{-m\varepsilon^2/12} \leq \delta.$$

经代数计算可知, 只需选取

$$m \geq \frac{12 \ln(2/\delta)}{\pi \varepsilon^2}.$$

可以推广估计 π 的方法的思想, 得到抽样次数与近似质量之间的关系. 这一章将始终利用下面的切尔诺夫界的简单应用.

[253]

定理 10.1 设 X_1, \dots, X_n 是独立同分布示性随机变量, $\mu = E[X_i]$. 若 $m \geq (3 \ln(2/\delta))/\varepsilon^2 \mu$, 那么

$$\Pr\left(\left|\frac{1}{m} \sum_{i=1}^m X_i - \mu\right| \geq \varepsilon \mu\right) \leq \delta.$$

即 m 个样品提供 μ 的一个 (ε, δ) 近似.

证明留作练习 10.1.

更一般地, 我们希望有一种算法, 它不只是近似单个值, 而是以问题的实例作为输入, 给出问题的近似解的值. 这里我们考虑将输入 x 映射为值 $V(x)$ 的问题. 例如, 给定一个输入图, 希望知道图中独立集合的个数.

你可能要问我们为什么会满足于一个近似呢? 也许我们的目的应是一个精确的答案. 就拿 π 来说, 我们不可能得到精确的答案, 因为 π 是个无理数. 正像马上要看到的, 求近似的另一个理由是, 存在这样的问题, 给出精确答案的算法的存在性就意味着 $P = NP$, 所以不可能找到这样的算法. 但这并不排除有效的近似算法的可能性.

定义 10.2 一个问题的完全多项式随机化近似方案 (FPRAS) 是一个这样的随机化算法: 给定一个输入 x 及任意的参数 ε, δ 满足 $0 < \varepsilon, \delta < 1$, 算法在关于 $1/\varepsilon, \ln \delta^{-1}$ 和输入 x 大小的多项式时间内, 输出 $V(x)$ 的一个 (ε, δ) 近似.

练习 10.3 考虑了一个似乎较弱但实际上是等价的 FPRAS 定义, 这里回避了参数 δ .

蒙特卡罗方法本质上包括这里给出的得到 V 值的有效近似的方法. 我们要求一个有效的过程产生独立同分布的随机样本 X_1, X_2, \dots, X_n , 其中 $E[X_i] = V$, 然后取足够的抽样给出 V 的 (ε, δ) 近似. 产生一个好的抽样序列常常是一个不平常的任务, 也是蒙特卡罗方法主要的焦点.

蒙特卡罗方法有时也称为蒙特卡罗模拟. 作为一个例子, 假定要估计未来某个时间一支股票的期望价格, 我们可以提出一个在那时的依赖于随机变量 Y_1, Y_2, \dots, Y_k 的股票价格 $p(Y_1, Y_2, \dots, Y_k)$ 的模型. 如果能够从 Y_i 的联合分布中重复产生独立的随机向量 (y_1, y_2, \dots, y_k) , 那么就可以重复产生独立的随机变量 X_1, X_2, \dots , 其中

$$X_i = p(Y_1, \dots, Y_k).$$

然后可以利用蒙特卡罗方法由 X_i 去估计未来的期望价格 $E[p(Y_1, Y_2, \dots, Y_k)]$, 即通过多次模拟 Y_i 的可能未来输出, 可以估计股票价格的期望值.

254

10.2 应用: DNF 计数问题

作为一个要求非平凡抽样技术估计问题的例子, 我们考虑析取范式(DNF)中布尔公式的满足赋值个数的计数问题. 一个 DNF 公式是子句的析取(OR) $C_1 \vee C_2 \vee \dots \vee C_l$, 其中每个子句 C_i 是文字的合取(AND). 例如, 以下是一个 DNF 公式:

$$(x_1 \wedge \bar{x}_2 \wedge x_3) \vee (x_2 \wedge x_4) \vee (\bar{x}_1 \wedge x_3 \wedge x_4).$$

回忆 6.2.2 节的标准可满足性问题中, 输入公式是一个子句集合的合取(AND), 而每个子句又是文字的析取(OR), 这通常称作合取范式(CNF). 尽管确定一个 CNF 公式的可满足性是困难的, 但确定一个 DNF 公式的可满足性却是简单的. 因为对 DNF 公式的满足赋值只需满足一个子句, 所以寻找一个满足赋值或证明它不是可满足的比较容易.

精确地计数一个 DNF 公式满足赋值的个数有多难呢? 任给一个 CNF 公式 H , 可以由德·摩根律得到公式 H 的否定 \bar{H} 的 DNF 公式, 与原 CNF 公式有相同个数的变量和子句. 公式 H 有满足的赋值, 当且仅当存在某个不满足 \bar{H} 的变量赋值. 所以, H 有一个满足的赋值, 当且仅当 \bar{H} 的满足赋值个数严格地小于 2^n , 即 n 个布尔变量可能赋值的总数. 我们断言, 对一个 DNF 公式满足赋值个数的计数至少像解决一个 NP 完全问题 SAT 一样困难.

存在与计数 NP 问题的解有关联的一个复杂性类, 记作 #P, 读作“sharp-P”. 形式地, 一个问题是在 #P 类中的, 如果存在一个多项式时间的不确定的图灵机, 使得对任意一个输入 I , 接受的计算数等于与输入 I 关联的不同解的个数. 计数一个 DNF 公式满足赋值的个数实际上是一个 #P 完全问题; 即这个问题与这个类中的任何其他问题一样难. #P 类的其他完全问题包括计数一个图中不同的哈密顿圈的个数以及计数一个二部图中的完美匹配个数.

不可能存在一个计算 #P 完全问题的解的精确个数的多项式时间算法, 因为这样一种算法至少意味着 $P = NP$. 因此, 对 DNF 公式满足赋值的个数, 寻找一个 FPRAS 是有意义的.

10.2.1 朴素算法

我们首先试着推广曾用来近似 π 的方法, 阐明为什么这种方法一般情况下是不合适的, 然后说明为了解决这个问题, 如何改进抽样技术.

255

设 $c(F)$ 是 DNF 公式 F 的满足赋值的个数, 这里假定 $c(F) > 0$, 因为在运行抽样算法之前, 容易检查是否有 $c(F) = 0$. 在 10.1 节, 我们通过下面的方法来近似 π : 生成均匀随机地来自 2×2 正方形中的点, 并检查是否在目标(半径为 1 的圆)内. 在算法 10.1 中, 我们尝试一种类似的方法: 产生 n 个变量的均匀随机赋值, 然后检查得到的赋值是否在公式 F 的满足赋值的目标中.

算法 10.1 DNF 计数算法 I

输入: 一个有 n 个变量的 DNF 公式 F .

输出: $Y = c(F)$ 的一个近似.

1. $X \leftarrow 0$;
2. 对 $k=1$ 到 m :
 - (a) 产生一个从所有 2^n 个可能赋值中均匀随机地选取的 n 个变量的随机赋值;
 - (b) 如果随机赋值满足 F , 则 $X \leftarrow X + 1$;
3. 返回 $Y \leftarrow (X/m)2^n$.

如果算法的第 k 次迭代产生一个满足赋值, 令 X_i 为 1; 否则为 0. 那么 $X = \sum_{k=1}^m X_i$, 其中 X_i 是独立的 0-1 随机变量, 每个以 $c(F)/2^n$ 的概率取值为 1. 因此, 由期望的线性性,

$$E[Y] = \frac{E[X]2^n}{m} = c(F).$$

利用定理 10.1 可知, X/m 给出了 $c(F)/2^n$ 的一个 (ε, δ) 近似, 因此当

$$m \geq \frac{3 \cdot 2^n \ln(2/\delta)}{\varepsilon^2 c(F)}$$

时, Y 给出了 $c(F)$ 的 (ε, δ) 近似.

如果对某个多项式 α , $c(F) \geq 2^n/\alpha(n)$, 那么由前面的分析可知, 只需抽样 m 次, 其中 m 是关于 n , $1/\varepsilon$ 和 $\ln(1/\delta)$ 的多项式. 但不能排除 $c(F)$ 比 2^n 小得多的可能性, 特别是 $c(F)$ 可能是 n 的多项式. 因为我们的分析要求抽样次数 m 与 $2^n/c(F)$ 成比例, 所以并不认为算法的运行时间总是关于问题大小的多项式.

这不是对分析的人为简化, 在练习 10.4 中给出了证明的粗略梗概. 如果满足赋值的个数是 n 的多项式, 并且在每一步都是从所有 2^n 种可能赋值中均匀随机地抽样, 那么以大的概率, 在找到第一次满足赋值之前, 必须抽样一个指数级次的赋值. 例如, 可以断定, 不考虑指数级多的随机赋值, 我们不可能分辨 n , n^2 及 n^3 个满足赋值的场合, 因为在所有三种情况下, 都以大的概率得到零个满足赋值. [256]

这种抽样方法的问题在于满足赋值集合在所有赋值集合中不是足够稠密的, 这是对我们抽样技术追加的以前没有明确提出的要求. 用定理 10.1 的话来说, 我们试图近似的 μ 值需要足够多的抽样次数才有效.

为了得到这个问题的 FPRAS, 需要设计一个更好的抽样方案, 以避免浪费那么多步在不满足公式的赋值上. 我们需要构建一个包含所有 F 的满足赋值的样本空间, 而且具有下面的性质: 这些赋值在样本空间中是足够稠密的, 从而可以有效地抽样.

10.2.2 DNF 计数问题的完全多项式随机方案

现在我们修改抽样过程以得到一个 FPRAS. 令 $F = C_1 \vee C_2 \vee \dots \vee C_r$, 不失一般性, 假定没有子句包含一个变量及其否定 (如果存在这样的子句, 它不是满足的, 我们可以从公式中消去它). F 的一个满足赋值至少要满足子句 C_1, \dots, C_r 中的一个. 每个子句是文字的合取, 所以对出现在子句中的变量只有唯一的赋值是满足子句的, 所有其他变量可以取任意值. 例如, 为了满足子句 $(x_1 \wedge \bar{x}_2 \wedge x_3)$, x_1 和 x_3 必须取 True, 而 x_2 必须取 False.

如果子句 C_i 含有 ℓ_i 个文字, 那么对 C_i 恰好存在 2^{ℓ_i} 个满足赋值. 令 SC_i 表示满足子句 C_i 的赋值集合, 令

$$U = \{(i, a) \mid 1 \leq i \leq t, a \in SC_i\}.$$

注意到我们知道 U 的大小, 这是因为

$$\sum_{i=1}^t |SC_i| = |U|,$$

并且可以计算 $|SC_i|$.

我们希望估计的值由下式给出:

$$c(F) = \left| \bigcup_{i=1}^t SC_i \right|.$$

因为一个赋值可以满足不只一个子句, 所以出现在 U 中的多于一个对中, 因而 $c(F) \leq |U|$.

为了估计 $c(F)$, 定义一个 U 的大小为 $c(F)$ 的子集 S . 我们用以下方法构造这个集合: 对 F 的每一个满足赋值, 在 U 中恰好选取具有这个赋值的一对; 特别地, 可以选取具有最小的子句指标数的那一对元素, 即

$$S = \{(i, a) \mid 1 \leq i \leq t, a \in SC_i, a \notin SC_j, j < i\}.$$

因为 U 的大小已知, 所以由估计比 $|S|/|U|$ 可以估计 S 的大小. 如果利用前面的方法均匀随机地从 U 中抽样, 从 U 中均匀随机地选取一个对, 并记录它们隔多久处于 S 中, 则可以有效地估计这个比值. 因为 S 在 U 中是相对稠密的, 所以可以避免在简单随机地抽样赋值时遇到的问题. 特别地, 因为每一个赋值至多可以满足 t 个不同的子句, 所以 $|S|/|U| \geq 1/t$.

现在剩下的唯一问题是如何从 U 中均匀抽样. 假定首先选取第一个坐标 i , 因为第 i 个子句有 $|SC_i|$ 个满足赋值, 我们以 $|SC_i|$ 成比例的概率选择 i . 特别地, 以概率

$$\frac{|SC_i|}{\sum_{i=1}^t |SC_i|} = \frac{|SC_i|}{|U|}$$

选取 i . 然后可以从 SC_i 中均匀随机地抽取一个满足赋值. 这是容易做到的; 对于每个不在子句 i 中的文字, 独立地且均匀随机地选取一个值 True 或 False. 这样, 我们选择对子 (i, a) 的概率为

$$\begin{aligned} \Pr(\text{选择}(i, a)) &= \Pr(\text{选择 } i) \cdot \Pr(\text{选择 } a / \text{选择 } i) \\ &= \frac{|SC_i|}{|U|} \frac{1}{|SC_i|} \\ &= \frac{1}{|U|}, \end{aligned}$$

即为一个均匀分布.

算法 10.2 执行这些步骤.

算法 10.2 DNF 计数算法 II

输入: 一个有 n 个变量的 DNF 公式 F .

输出: $Y = c(F)$ 的一个近似.

1. $X \leftarrow 0$;
2. 对 $k = 1$ 到 m :

(a) 以概率 $|SC_i| / \sum_{i=1}^l |SC_i|$ 均匀随机地选取一个赋值 $a \in SC_i$;

(b) 如果 a 不在任一 $SC_j (j < i)$ 中, 则 $X \leftarrow X + 1$;

3. 返回 $Y \leftarrow (X/m) \sum_{i=1}^l |SC_i|$.

定理 10.2 当 $m = \lceil (3t/\varepsilon^2) \ln(2/\delta) \rceil$ 时, DNF 计数算法 II 是 DNF 计数问题的一个完全多项式随机化近似方案 (FPRAS).

证明 算法的第 2(a) 步均匀随机地抽取 U 中的一个元素, 这个元素属于 S 的概率至少是 $1/t$. 固定任意的 $\varepsilon > 0$ 和 $\delta > 0$, 令

$$m = \left\lceil \frac{3t}{\varepsilon^2} \ln \frac{2}{\delta} \right\rceil.$$

那么 m 是 t , ε 和 $\ln(1/\delta)$ 的多项式, 每一次抽样的处理时间是 t 的多项式. 由定理 10.1, 对这样的抽样次数, X/m 给出了 $c(F)/|U|$ 的 (ε, δ) 近似, 因此 Y 给出了 $c(F)$ 的 (ε, δ) 近似. ■

258

10.3 从近似抽样到近似计数

DNF 公式的例子表明, 在可以从一个合适的空间进行抽样与可以对那个空间中具有某个性质的目标进行计数之间存在着一种基本的联系. 在这一节, 我们将介绍一般简化方法的概要来说明, 如果可以对一个“自可约”组合问题进行几乎均匀地抽样得到一个解, 那么就能够构造一个近似地计数那个问题解的个数的随机化算法. 我们为一个图中独立集合个数的计数问题来演示这种方法. 在下一章, 还要考虑用这个方法对一个图的正规着色法个数进行计数的问题.

首先需要将近似均匀抽样概念用公式表示, 这里, 我们以一个输入 x 及存在与这个输入关联的基础有限样本空间 $\Omega(x)$ 的形式给出问题的例子.

定义 10.3 设 ω 是对有限样本空间 Ω 的一种抽样算法的(随机)输出, 抽样算法生成 Ω 的一个 ε -均匀样本, 如果对 Ω 的任意子集 S 有

$$\left| \Pr(\omega \in S) - \frac{|S|}{|\Omega|} \right| \leq \varepsilon.$$

抽样算法是一个问题的完全多项式几乎均匀抽样 (FPAUS), 如果对已知的输入 x 和参数 $\varepsilon > 0$, 算法生成 $\Omega(x)$ 的一个 ε -均匀样本, 并且以关于 $\ln \varepsilon^{-1}$ 和输入 x 大小的多项式时间运行.

下一章, 我们介绍总变异距离的概念, 它容许关于 ε -均匀样本的一个等价定义.

举一个例子, 独立集合的 FPAUS 以一个图 $G = (V, E)$ 及参数 ε 作为输入. 样本空间是图的所有独立集合, 输出是独立集合的一个 ε -均匀样本, 产生这样一个样本的时间是关于图的大小和 $\ln \varepsilon^{-1}$ 的多项式. 事实上, 可以减少到只需要关于 $\ln \varepsilon^{-1}$ 的多项式的运行时间, 但是我们利

用定义 10.3 给出的标准定义.

我们的目的是要证明, 给定一个独立集合的 FPAUS, 可以构造一个计数独立集合个数的 FPRAS. 假定输入 G 有 m 条边, 令 e_1, e_2, \dots, e_m 表示这些边的一个任意次序, 令 E_i 是 E 中前 i 条边的集合, $G_i = (V, E_i)$. 注意到 $G = G_m$, 而且 G_{i-1} 就是从 G_i 中除去一条边后得到的.

令 $\Omega(G_i)$ 表示 G_i 中独立集合的集合, 那么图 G 中独立集合的个数可以表示为

$$|\Omega(G)| = \frac{|\Omega(G_m)|}{|\Omega(G_{m-1})|} \times \frac{|\Omega(G_{m-1})|}{|\Omega(G_{m-2})|} \times \frac{|\Omega(G_{m-2})|}{|\Omega(G_{m-3})|} \times \cdots \times \frac{|\Omega(G_1)|}{|\Omega(G_0)|} \times |\Omega(G_0)|.$$

由于图 G_0 没有边, V 的每一个子集都是独立集合, 并且 $|\Omega(G_0)| = 2^V$. 为了估计 $|\Omega(G)|$, 我们需要关于比

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|}, \quad i = 1, \dots, m$$

的一个好的估计量. 更严格地, 我们提出比 r_i 的估计 \bar{r}_i , 那么 G 中独立集合个数的估计将是

$$2^V \prod_{i=1}^m \bar{r}_i,$$

而真值是

$$|\Omega(G)| = 2^V \prod_{i=1}^m r_i.$$

为了计算估计量的误差, 我们需要界定比

$$R = \prod_{i=1}^m \frac{\bar{r}_i}{r_i}.$$

特别地, 为了得到一个 (ε, δ) 近似, 我们希望 $\Pr(|R-1| \leq \varepsilon) \geq 1 - \delta$. 需要利用下面的引理.

引理 10.3 假设对所有的 i , $1 \leq i \leq m$, \bar{r}_i 是 r_i 的一个 $(\varepsilon/2m, \delta/m)$ 近似, 那么

$$\Pr(|R-1| \leq \varepsilon) \geq 1 - \delta.$$

证明 对每个 $1 \leq i \leq m$, 有

$$\Pr\left(\left|\frac{\bar{r}_i}{r_i} - 1\right| \leq \frac{\varepsilon}{2m}\right) \geq 1 - \frac{\delta}{m}.$$

等价地,

$$\Pr\left(\left|\frac{\bar{r}_i}{r_i} - 1\right| > \frac{\varepsilon}{2m}\right) < \frac{\delta}{m}.$$

由并的界, 对任意 i , $\left|\frac{\bar{r}_i}{r_i} - 1\right| > (\varepsilon/2m)r_i$ 的概率至多是 δ ; 因此, 对所有 i , $\left|\frac{\bar{r}_i}{r_i} - 1\right| \leq (\varepsilon/2m)r_i$ 的概率至少是 $1 - \delta$. 等价地, 对所有的 i ,

$$1 - \frac{\varepsilon}{2m} \leq \frac{\bar{r}_i}{r_i} \leq 1 + \frac{\varepsilon}{2m}$$

[260] 成立的概率至少为 $1 - \delta$. 当这些界对所有 i 都成立时, 综合它们而得到

$$1 - \varepsilon \leq \left(1 - \frac{\varepsilon}{2m}\right)^m \leq \prod_{i=1}^m \frac{\bar{r}_i}{r_i} \leq \left(1 + \frac{\varepsilon}{2m}\right)^m \leq 1 + \varepsilon,$$

证毕. ■

因此, 我们需要一个得到 r_i 的 $(\varepsilon/2m, \delta/m)$ 近似的方法. 由对抽样独立集所用 FPAUS 的蒙特卡罗算法估计这些比中的每一个, 为了估计 r_i , 我们在 G_{i-1} 中抽样独立集合, 并且如算法 10.3 所描述的那样计算这些独立集合也是 G_i 中独立集合的比例. 选取程序中的常数以便于引理 10.4 的证明.

算法 10.3 估计 r_i

输入: 图 $G_{i-1} = (V, E_{i-1})$ 和图 $G_i = (V, E_i)$.

输出: $\bar{r}_i = r_i$ 的一个近似.

1. $X \leftarrow 0$;
2. 重复 $M = \lceil 1296m^2 \varepsilon^{-2} \ln(2m/\delta) \rceil$ 次独立试验:
 - (a) 从 $\Omega(G_{i-1})$ 中产生一个 $(\varepsilon/6m)$ -均匀样本;
 - (b) 如果这个样本也是 G_i 中的一个独立集合, 令 $X \leftarrow X + 1$;
3. 返回 $\bar{r}_i \leftarrow X/M$.

引理 10.4 当 $m \geq 1$ 且 $0 < \varepsilon \leq 1$ 时, 估计 r_i 的程序产生 r_i 的一个 $(\varepsilon/2m, \delta/m)$ 近似.

证明 我们首先证明 r_i 不会太小, 以避免 10.2.1 节中出现过的问题. 假定 G_{i-1} 和 G_i 的不同在于边 u, v 在 G_i 中, 但不在 G_{i-1} 中. G_i 中的一个独立集合也是 G_{i-1} 中的独立集合, 所以

$$\Omega(G_i) \subseteq \Omega(G_{i-1}).$$

$\Omega(G_{i-1}) \setminus \Omega(G_i)$ 中的独立集合包含 u 和 v . 为了界定集合 $\Omega(G_{i-1}) \setminus \Omega(G_i)$ 的大小, 我们将每个 $I \in \Omega(G_{i-1}) \setminus \Omega(G_i)$ 与一个独立集合 $I \setminus \{v\} \in \Omega(G_i)$ 相关联. 在这个映射中, 一个独立集合 $I' \in \Omega(G_i)$ 与不多于一个独立集合 $I' \cup \{v\} \in \Omega(G_{i-1}) \setminus \Omega(G_i)$ 关联, 因此 $|\Omega(G_{i-1}) \setminus \Omega(G_i)| \leq |\Omega(G_i)|$, 所以有

$$r_i = \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|} = \frac{|\Omega(G_i)|}{|\Omega(G_i)| + |\Omega(G_{i-1}) \setminus \Omega(G_i)|} \geq \frac{1}{2}.$$

现在考虑 M 个样品, 如果第 k 个样品在 $\Omega(G_i)$ 中, 令 $X_k = 1$; 否则, $X_k = 0$. 因为我们的样品是由 $(\varepsilon/6m)$ 均匀抽样器生成的, 由定义 10.3, 每一个 X_k 必须满足

$$\left| \Pr(X_k = 1) - \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|} \right| \leq \frac{\varepsilon}{6m}. \quad [261]$$

因为 X_k 是示性随机变量, 有

$$\left| E[X_k] - \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|} \right| \leq \frac{\varepsilon}{6m},$$

进一步, 由期望的线性性,

$$\left| E\left[\frac{\sum_{k=1}^M X_k}{M}\right] - \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|} \right| \leq \frac{\varepsilon}{6m}.$$

因此, 我们有

$$\begin{aligned} |E[\bar{r}_i] - r_i| &= \left| E\left[\frac{\sum_{i=1}^M X_i}{M} \right] - \frac{|\Omega(G_i)|}{|\Omega(G_{i-1})|} \right| \\ &\leq \frac{\varepsilon}{6m}. \end{aligned}$$

现在综合(a)刚刚证明的 $E[\bar{r}_i]$ 接近 r_i 的事实和(b)当样品数量足够大时, \bar{r}_i 接近 $E[\bar{r}_i]$ 的事实, 我们来完成引理的证明. 由于 $r_i \geq 1/2$, 有

$$E[\bar{r}_i] \geq r_i - \frac{\varepsilon}{6m} \geq \frac{1}{2} - \frac{\varepsilon}{6m} \geq \frac{1}{3}.$$

由定理 10.1 可知, 如果样品个数 M 满足

$$M \geq \frac{3 \ln(2m/\delta)}{(\varepsilon/12m)^2 (1/3)} = 1296m^2 \varepsilon^{-2} \ln \frac{2m}{\delta},$$

那么

$$\Pr\left(\left|\frac{\bar{r}_i}{E[\bar{r}_i]} - 1\right| \geq \frac{\varepsilon}{12m}\right) = \Pr\left(|\bar{r}_i - E[\bar{r}_i]| \geq \frac{\varepsilon}{12m} E[\bar{r}_i]\right) \leq \frac{\delta}{m}.$$

等价地, 以概率 $1 - \delta/m$, 有

$$1 - \frac{\varepsilon}{12m} \leq \frac{\bar{r}_i}{E[\bar{r}_i]} \leq 1 + \frac{\varepsilon}{12m}. \quad (10.1)$$

当 $|E[\bar{r}_i] - r_i| \leq \varepsilon/6m$ 时, 有

$$1 - \frac{\varepsilon}{6mr_i} \leq \frac{E[\bar{r}_i]}{r_i} \leq 1 + \frac{\varepsilon}{6mr_i}.$$

由 $r_i \geq 1/2$ 得到

$$1 - \frac{\varepsilon}{3m} \leq \frac{E[\bar{r}_i]}{r_i} \leq 1 + \frac{\varepsilon}{3m}. \quad (10.2)$$

综合(10.1)和(10.2)式, 以概率 $1 - \delta/m$, 有

$$1 - \frac{\varepsilon}{2m} \leq \left(1 - \frac{\varepsilon}{3m}\right) \left(1 - \frac{\varepsilon}{12m}\right) \leq \frac{\bar{r}_i}{r_i} \leq \left(1 + \frac{\varepsilon}{3m}\right) \left(1 + \frac{\varepsilon}{12m}\right) \leq 1 + \frac{\varepsilon}{2m}.$$

262 这样就给出了要求的 $(\varepsilon/2m, \delta/m)$ 近似. ■

样品个数 M 是 m , ε 和 $\ln \delta^{-1}$ 的多项式, 每次抽样时间是图的大小和 $\ln \varepsilon^{-1}$ 的多项式, 因此我们有下面定理.

定理 10.5 给定任意一个图中的独立集合的完全多项式几乎均匀抽样器 (FPAUS), 我们可以构造一个关于这个图 G 的独立集合个数的完全多项式随机化近似方案 (FPRAS).

事实上, 这个定理更常用到的是下面的形式.

定理 10.6 给定任意一个最大次至多为 Δ 的图的独立集合的完全多项式几乎均匀抽样器 (FPAUS), 我们可以构造一个关于最大次至多为 Δ 的图 G 中的独立集合个数的完全多项式随机化近似方案 (FPRAS).

定理的这种形式源于我们前面的讨论. 因为图 G_i 是初始图 G 的子图. 因此, 如果从最大次至多为 Δ 的一个图开始, 那么我们的 FPAUS 只需在最大次至多为 Δ 的图上工作. 在下一章, 我们将看到如何对最大次为 4 的图建立一个 FPAUS.

这种技术可以用于组合计数问题的广泛领域, 例如, 在第 11 章, 我们考虑它在求图 G 的正规着色法中的应用. 唯一的要求是可以构造问题的改进序列, 从一个容易计数(在我们的例子中, 一个没有边的图中独立集合个数)的场合开始到实际计数问题结束, 使得相继场合计数之间的比至多是关于问题大小的多项式.

10.4 马尔可夫链蒙特卡罗方法

蒙特卡罗方法是基于抽样的方法. 产生一个具有要求的概率分布的随机样本经常是困难的, 例如, 在前一节我们看到, 如果能够产生一个来自独立集合的几乎均匀样本, 就能计数一个图中独立集合的个数. 但是怎样产生一个几乎均匀样本呢?

马尔可夫链蒙特卡罗方法(MCMC)对从要求的概率分布中抽样提供了一个非常一般的方法. 其基本思想是定义一个遍历马尔可夫链, 这个链的状态集合是样本空间, 它的平稳分布是所要求的抽样分布. 令 X_0, X_1, \dots, X_r 是链的一段, 马尔可夫链可以从任意一个初始状态 X_0 收敛到平稳分布, 所以经过足够多的 r 步后, 状态 X_r 的分布将接近于平稳分布, 所以可以作为一个抽样. 类似地, 重复这个过程, 以 X_r 作为初始点, 可以用 X_{2r} 作为一个抽样, 等等. 因此, 可以把状态序列 $X_1, X_{2r}, X_{4r}, \dots$ 作为来自马尔可夫链平稳分布的几乎独立的样本. 这种方法的效率依赖于: (a) 为了保证一个适当好的样本, r 必须有多大; (b) 马尔可夫链的每一步需要多少计算. 在本节, 我们着重寻找具有合适的平稳分布的有效马尔可夫链, 而不考虑 r 需要多大的问题. 耦合是一种确定 r 值与样本质量之间关系的方法, 将在下章介绍.

在最简单情况, 目标是构造一个平稳分布为状态空间 Ω 上的均匀分布的马尔可夫链. 第一步是设计一个移动集合, 保证这个马尔可夫链下的状态空间是不可约的. 我们称从状态 x (但排除 x) 经过一步到达的状态集合为 x 的邻域, 记作 $N(x)$. 采用如下的限制: 如果 $y \in N(x)$, 那么 $x \in N(y)$. 一般地, $N(x)$ 是一个小的集合, 使得执行每一次移动只是简单的计算.

我们仍然用图 $G = (V, E)$ 中的独立集合作为例子, 状态空间是 G 的所有独立集合全体. 一种自然的邻域结构譬如说是状态 x 和 y (它们都是独立集合) 为相邻的, 如果它们只有一个顶点的不同, 即由 y 只需增加或去掉一个顶点就可得到 x . 因为所有的独立集合都能通过去除一系列顶点(或增加顶点)达到(或可被达到)空的独立集合, 所以这种相邻关系保证状态空间是不可约的.

一旦建立了相邻关系, 我们还需要建立转移概率. 一种自然的方法是尝试执行状态空间图上的随机游动, 但这可能不一定导出一个均匀分布. 由定理 7.13 可知, 在随机游动的平稳分布中, 一个顶点的概率与这个顶点的次成比例. 在以前的讨论中, 没有要求所有状态有相同个数的邻点, 这等价于状态空间图中的所有顶点都有相同的次.

下面的引理表明, 如果对每一个顶点给出一个适当的自圈概率来修改随机游动, 那么可以得到一个均匀的平稳分布.

引理 10.7 对一个有限的状态空间 Ω 和邻域结构 $|N(x) \mid x \in \Omega|$, 令 $N = \max_{x \in \Omega} |N(x)|$, $M \geq N$ 是任意的数. 考虑一个马尔可夫链, 其中

$$P_{x,y} = \begin{cases} 1/M & \text{若 } x \neq y \text{ 且 } y \in N(x), \\ 0 & \text{若 } x \neq y \text{ 且 } y \notin N(x), \\ 1 - N(x)/M & \text{若 } x = y. \end{cases}$$

如果这个链是不可约的且是非周期的, 那么平稳分布是均匀分布.

证明 我们证明这个链是时间可逆的, 然后应用定理 7.10. 对任意的 $x \neq y$, 如果 $\pi_x = \pi_y$, 那么

$$\pi_x P_{x,y} = \pi_y P_{y,x}.$$

这是因为 $P_{x,y} = P_{y,x} = 1/M$. 所以均匀分布 $\pi_x = 1/|\Omega|$ 是平稳分布. ■

现在考虑下面简单的马尔可夫链, 其状态是图 $G = (V, E)$ 中的独立集合.

1. X_0 是 G 中的任意一个独立集合.

2. 计算 X_{i+1} :

(a) 从 V 中均匀随机地选取一个顶点 v .

(b) 如果 $v \in X_i$, 那么 $X_{i+1} = X_i \setminus \{v\}$.

(c) 如果 $v \notin X_i$, 并且如果 X_i 中增加 v 后仍是独立集合, 那么 $X_{i+1} = X_i \cup \{v\}$.

(d) 其他, 令 $X_{i+1} = X_i$.

这个链具有这样的性质, 即状态 X_i 的邻域都是独立集合, 它们与 X_i 只相差一个顶点. 因为每一个状态都可以到达空集, 并且都可以由空集到达, 所以这个链是不可约的. 假设 G 至少有一条边 (u, v) , 那么状态 $\{v\}$ 有一个自圈 ($P_{v,v} > 0$), 且这个链是非周期的. 进一步, 当 $y \neq x$ 时, 得到 $P_{x,y} = 1/|V|$ 或 0. 所以由引理 10.7, 平稳分布是均匀分布.

10.4.1 Metropolis 算法

我们已经研究了怎样构造一个具有均匀平稳分布的链, 但是在某些情况下, 我们可能希望从一个非均匀平稳分布的链进行抽样. Metropolis 算法提供了一种将状态空间 Ω 上任意不可约马尔可夫链变换为一个具有所要求的平稳分布的时间可逆的马尔可夫链的一般构造方法. 这个方法推广了以前用于产生均匀平稳分布链的思想: 向状态增加自圈概率以得到所要求的平稳分布.

再次假定对马尔可夫链已经设计了一个不可约状态空间, 现在希望在这个状态空间上构造具有平稳分布 $\pi_x = b(x)/B$ 的马尔可夫链, 其中对所有的 $x \in \Omega$, 有 $b(x) > 0$, 使得 $B = \sum_{x \in \Omega} b(x)$ 是有限的. 正如我们将在下面引理(它推广了引理 10.7)中看到的, 只需知道所求概率之间的比; 和 B 可以是未知的.

引理 10.8 对一个有限的状态空间 Ω 和邻域结构 $|N(x) \mid x \in \Omega|$, 令 $N = \max_{x \in \Omega} |N(x)|$, $M \geq N$ 是任意数. 对任意的 $x \in \Omega$, 令 $\pi_x > 0$ 是平稳分布中状态 x 的所要求概率, 考虑一个马尔可夫链, 其中

$$P_{x,y} = \begin{cases} (1/M) \min(1, \pi_y/\pi_x) & \text{如果 } x \neq y \text{ 且 } y \in N(x), \\ 0 & \text{如果 } x \neq y \text{ 且 } y \notin N(x), \\ 1 - \sum_{y \neq x} P_{x,y} & \text{如果 } x = y. \end{cases}$$

265

如果这个链是不可约的且是非周期的, 那么平稳分布由概率 π_x 给出.

证明 如引理 10.7 的证明, 我们证明这个链是时间可逆的, 并应用定理 7.10. 对任意的 $x \neq y$, 如果 $\pi_x \leq \pi_y$, 那么 $P_{x,y} = 1$ 且 $P_{y,x} = \pi_x/\pi_y$, 由此得到 $\pi_x P_{x,y} = \pi_y P_{y,x}$. 类似地, 如果 $\pi_x > \pi_y$, 那么 $P_{x,y} = \pi_y/\pi_x$ 且 $P_{y,x} = 1$, 由此得到 $\pi_x P_{x,y} = \pi_y P_{y,x}$. 由定理 7.10, 平稳分布由 π_x 值给出. ■

作为一个如何应用引理 10.8 的例子, 我们考虑如何修改独立集合上的前述的马尔可夫链. 假定现在要建立一个马尔可夫链, 其中在平稳分布中, 对某个常数参数 $\lambda > 0$, 每一个独立集合 I 有与 $\lambda^{|I|}$ 成比例的概率, 即 $\pi_x = \lambda^{|I_x|}/B$, 其中 I_x 是与状态 x 对应的独立集合, $B = \sum_x \lambda^{|I_x|}$. 当 $\lambda = 1$ 时, 这是均匀分布; 当 $\lambda > 1$ 时, 较大的独立集合有比较小的独立集合更大的概率; 当 $\lambda < 1$ 时, 较大的独立集合有比较小的独立集合更小的概率.

现在考虑关于图 $G = (V, E)$ 中独立集合的前述马尔可夫链的下列变化:

1. X_0 是 G 中任意一个独立集合,
2. 计算 X_{i+1} :
 - (a) 从 V 中均匀随机地选取一个顶点 v ;
 - (b) 如果 $v \in X_i$, 则以概率 $\min(1, 1/\lambda)$ 令 $X_{i+1} = X_i \setminus \{v\}$;
 - (c) 如果 $v \notin X_i$, 且如果将 v 加入 X_i 后仍是一个独立集合, 则以概率 $\min(1, \lambda)$ 令 $X_{i+1} = X_i \cup \{v\}$;
 - (d) 其他, 令 $X_{i+1} = X_i$.

现在我们依据两步法. 首先建议通过选取一个增加或删除的顶点 v 作一次移动, 其中每个顶点以 $1/M$ 的概率被选到, $M = |V|$. 然后以概率 $\min(1, \pi_y/\pi_x)$ 接受这个建议, 其中 x 是当前状态, y 是马尔可夫链将要移动的建议状态. 如果链试图增加一个顶点, 则 π_y/π_x 是 λ ; 如果链试图去掉一个顶点, 则 π_y/π_x 是 $1/\lambda$. 这种两步方法是 Metropolis 算法的特点: 以概率 $1/M$ 选择每一个邻点, 再以概率 $\min(1, \pi_y/\pi_x)$ 接受这个点. 利用这种两步方法, 我们自然地得到转移概率 $P_{x,y}$ 为

$$P_{x,y} = \frac{1}{M} \min\left(1, \frac{\pi_y}{\pi_x}\right),$$

所以可以应用引理 10.8.

重要的是, 在设计这个马尔可夫链时, 我们不必知道 $B = \sum_x \lambda^{|I_x|}$. 一个有 n 个顶点的图可以有指数级多个独立集合, 直接计算这个和对很多图来说都是过分的, 我们的马尔可夫链利用 π_y/π_x 给出了正确的平稳分布, 这是相当容易处理的.

266

练习

- 10.1 正式地证明定理 10.1.
- 10.2 利用蒙特卡罗技术近似 π 的另一个方法是蒲丰投针试验. 研究并解释蒲丰投针试验, 进一步解释该方法如何用于得到 π 的近似值.
- 10.3 证明下面的变更定义与本章给出的 FPRAS 定义等价: 一个问题的完全多项式随机化近似方案 (FPRAS) 是一种随机化算法, 对给定的一个输入 x 和任意参数 $\varepsilon (0 < \varepsilon < 1)$, 算法以关于 $1/\varepsilon$ 和输入 x 大小的多项式时间输出一个 $(\varepsilon, 1/4)$ 近似. (提示: 为了将成功概率从 $3/4$ 逐渐提高到 $1 - \delta$, 考虑算法的几次独立运行的中位数. 为什么中位数比平均数好?)
- 10.4 假设有一类 DNF 可满足性问题的实例, 对某个多项式 α , 每个有 $\alpha(n)$ 满足真赋值, 再假定用朴素抽样赋值方法, 并检查它们是否满足公式. 证明, 经过 $2^{n/2}$ 次抽样赋值后, 对给定的实例找到一个满足赋值的概率是关于 n 的指数级小.
- 10.5 (a) 令 S_1, S_2, \dots, S_m 是有限总体 U 的子集, 已知 $|S_i|, 1 \leq i \leq m$, 我们希望得到集合

$$S = \bigcup_{i=1}^m S_i$$

大小的一个 (ε, δ) 近似. 一种通用的方法是, 用一步从集合 S_i 中均匀随机地选取一个元素, 对给定的元素 $x \in U$, 还可以确定这个 x 所属集合 S_i 的个数, 称这个数为 $c(x)$.

定义 p_i 为

$$p_i = \frac{|S_i|}{\sum_{j=1}^m |S_j|}.$$

第 j 次试验由下列步骤组成: 选取一个集合 S_j , 其中每个集合 S_i 被选到的概率为 p_i , 然后从 S_j 中均匀随机地选取一个元素 x_j . 在每次试验中的随机选取与所有其他试验是独立的. 经 t 次试验后, 用

$$\left(\frac{1}{t} \sum_{j=1}^t \frac{1}{c(x_j)} \right) \left(\sum_{i=1}^m |S_i| \right)$$

估计 $|S|$. 作为 m, ε 和 δ 的一个函数, 确定为得到 $|S|$ 的一个 (ε, δ) 近似所需要的试验次数.

(b) 解释如何利用 (a) 中所得的结果得到计数 DNF 公式解的个数的另一种近似算法.

- 10.6 计数一个背包实例解的个数问题可以如下定义: 已知体积为 $a_1, a_2, \dots, a_n > 0$ 的物品和一个整数 $b > 0$, 求向量 $(x_1, x_2, \dots, x_n) \in \{0, 1\}^n$ 的个数, 使得 $\sum_{i=1}^n a_i x_i \leq b$. 这里数 b 可以看作背包容量, x_i 表示每个物品是否放进背包内. 计数解对应于计数可以放在背包中且不超过背包容量的不同物品集合的个数.
- (a) 计数这个问题解的个数的朴素方法是均匀随机地重复选取向量 $(x_1, x_2, \dots, x_n) \in \{0, 1\}^n$, 并且返回产生有效解的抽样比例的 2^n 倍. 讨论为什么一般来说这不是一

一个好的策略，特别是讨论当每个 a_i 均为 1 且 $b = \sqrt{n}$ 时，此方法将是不好的。

- (b) 考虑向量 $(x_1, x_2, \dots, x_n) \in \{0, 1\}^n$ 上的马尔可夫链 X_0, X_1, \dots ，假设 X_j 是 (x_1, x_2, \dots, x_n) 。在每一步，马尔可夫链均匀随机地选取 $i \in [1, n]$ 。如果 $x_i = 1$ ，那么在 X_j 中令 $x_i = 0$ 得到 X_{j+1} ；如果 $x_i = 0$ ，那么在 X_j 中令 $x_i = 1$ 得到 X_{j+1} ，如果这样能满足约束条件 $\sum_{i=1}^n a_i x_i \leq b$ ；否则， $X_{j+1} = X_j$ 。

证明只要 $\sum_{i=1}^n a_i x_i > b$ ，这个马尔可夫链就有一个均匀平稳分布。证明这个链是不可约的和非周期的。

- (c) 证明：如果我们有一个关于背包问题的 FPAUS，那么可以导出这个问题的一个 FPRAS。为使问题提得更恰当，不失一般性，假定 $a_1 \leq a_2 \leq \dots \leq a_n$ ，令 $b_0 = 0$ ， $b_i = \sum_{j=1}^i a_j$ ， $\Omega(b_i)$ 表示满足 $\sum_{j=1}^n a_j x_j \leq b_i$ 的向量集合 $(x_1, x_2, \dots, x_n) \in \{0, 1\}^n$ ，令 k 是满足 $b_k \geq b$ 的最小整数。考虑等式

$$|\Omega(b)| = \frac{|\Omega(b)|}{|\Omega(b_{k-1})|} \times \frac{|\Omega(b_{k-1})|}{|\Omega(b_{k-2})|} \times \dots \times \frac{|\Omega(b_1)|}{|\Omega(b_0)|} \times |\Omega(b_0)|.$$

你需要证明 $|\Omega(b_{i-1})| / |\Omega(b_i)|$ 不会太小，特别地，证明 $|\Omega(b_i)| \leq (n+1) |\Omega(b_{i-1})|$ 。

- 10.7 Ω 的 ε -均匀样本的另一种定义如下：一个抽样算法生成一个 ε -均匀样本 ω ，如果对所有 $x \in \Omega$ ，

$$\frac{|\Pr(w = x) - 1/|\Omega||}{1/|\Omega|} \leq \varepsilon.$$

证明在这种定义下的 ε -均匀样本产生如定义 10.3 中所给出的一个 ε -均匀样本。

- 10.8 令 $S = \sum_{i=1}^{\infty} i^{-2} = \pi^2/6$ ，基于正整数上的 Metropolis 算法设计一个马尔可夫链，使得在平稳分布中， $\pi_i = 1/Si^2$ 。链中任意一个整数 $i > 1$ 的邻域应当只是 $i-1$ 和 $i+1$ ，而 1 的邻域只是整数 2。
- 10.9 回忆练习 2.22 的冒泡排序算法：假定有标号为 1 到 n 的 n 张卡片，卡片 X 的顺序可以是一个马尔可夫链的状态。令 $f(X)$ 是将卡片按递增顺序排列所需的冒泡排列移动次数。基于 Metropolis 算法设计一个马尔可夫链，使得在平稳分布中，对已知常数 $\lambda > 0$ ，一个次序 X 的概率与 $\lambda^{f(X)}$ 成比例。链中的状态对是连通的，如果它们对应于至多互换两张卡片即可得到的次序对。
- 10.10 无向图 $G = (V, E)$ 的一个 Δ -着色法 C 是从集合 $\{1, 2, \dots, \Delta\}$ 中为每一个顶点指派一个代表颜色的数字作为标号。边 (u, v) 是反常的，如果 u, v 都被指派相同的颜色。令 $I(C)$ 表示着色法 C 中反常边的个数，基于 Metropolis 算法设计一个马尔可夫链，使得在平稳分布中，对已知常数 $\lambda > 0$ ，着色法 C 的概率与 $\lambda^{I(C)}$ 成比例。链中的状态对是连通的，如果它们对应的着色对只在—一个顶点处不同。

- 10.11 在“Metropolis 算法”一节，我们在图的独立集合上构造了一个马尔可夫链，其中在平稳分布中， $\pi_x = \lambda^{|I_x|}/B$ 。这里 I_x 是对应于状态 x 的独立集合， $B = \sum_x \lambda^{|I_x|}$ 。用类似的方法，在排除了空集的图的独立集合上构造一个马尔可夫链，其中的 $\pi_x = |I_x|/B$ ， B 是一个常数。由于这个链不含空集，所以首先应设计一个邻域结构，以保证状态空间是连通的。
- 10.12 Metropolis 算法的下面的推广是由 Hastings 提出的。假设有一个由转移矩阵 Q 给出的状态空间 Ω 上的马尔可夫链，要在这个状态空间上构造一个平稳分布为 $\pi_x = b(x)/B$ 的马尔可夫链，其中对所有的 $x \in \Omega$ ， $b(x) > 0$ 且 $B = \sum_{x \in \Omega} b(x)$ 是有限的。按如下方法定义一个新的马尔可夫链：当 $X_n = x$ 时，产生一个随机变量 Y ，使得 $\Pr(Y=y) = Q_{x,y}$ 。注意 Y 可以通过模拟原马尔可夫链一步生成。令 X_{n+1} 以概率

$$\min\left(\frac{\pi_y Q_{y,x}}{\pi_x Q_{x,y}}, 1\right)$$

到达 Y ；否则，令 X_{n+1} 到达 X_n 。证明，如果这个链是非周期的和不可约的，那么它也是时间可逆的，并且有由 π_x 给出的平稳分布。

- 10.13 假设有一个程序，以实区间 $[0, 1]$ 上的数 x 作为输入，输出 $f(x)$ 是在范围 $[1, b]$ 中取值的某个有界函数 f ，我们希望估计

$$\int_{x=0}^1 f(x) dx.$$

假定有一个随机数发生器，可以产生独立均匀的随机变量 X_1, X_2, \dots ，对一个适当的 m 值，证明

$$\sum_{i=1}^m \frac{f(X_i)}{m}$$

给出积分的 (ε, δ) 近似。

最小支撑树的探索性作业

考虑一个有 $\binom{n}{2}$ 条边的完全无向图，每一条边有一个均匀随机地取自 $[0, 1]$ 中的实数权。

你的目的是估计这种图的最小支撑树的期望权如何作为 n 的函数成长的，这需要执行最小支撑树算法以及生成合适的随机图程序。（你应该检查在你的系统上使用的是哪种随机数发生器，并确定如何给它们初值，比如说用计算机时钟上的值）

依赖于你所用的算法和你的运行，你可能发现当 n 较大时，你的程序占用了过多的内存。为了减少 n 较大时的内存，我们建议用下面的方法。在这个设置中，最小支撑树极不可能利用权大于 $k(n)$ 的每条边，其中 $k(n)$ 是某个函数。首先通过对小的 n 值反复运行程序来估计 $k(n)$ ，然后当 n 较大时，去掉权大于 $k(n)$ 的边。如果你使用这种方法，必须阐明为什么用这种方法去掉边不会导致程序找到的支撑树实际上不是最小的。

对 $n = 16, 32, 64, 128, 256, 512, 1024, 2048, 4096, 8192$ 以及更大的值运行你的程

序, 如果你的程序运行得足够快, 对每一个 n 值至少重复运行你的程序 5 次, 并取平均(要保证你再次设置的随机数生成器的初值是合适的). 对成功运行了你的程序的 n 值, 列出一张树的平均大小的表. 随着 n 的增大, 最小支撑树的平均大小发生了什么变化?

另外, 你应该写一页或两页纸来更深入地讨论你的试验, 这个讨论应该反映出你从这种赋值中学到了什么, 可以按如下题目来写.

- 你用的是什么样的最小支撑树算法? 为什么?
- 你的算法的运行时间是多少?
- 如果选择去除一些边, 你是如何确定 $k(n)$ 的, 你的方法如何有效?
- 对你的结果, 你可以给出一个粗略的解释吗? (随 n 增大时的极限性质可以严格地证明, 但这是非常困难的; 你不必试图证明任何精确的结果.)
- 关于随机数发生器, 你有过什么有意义的试验吗? 你相信它吗?



*第 11 章 马尔可夫链的耦合

在第 7 章研究离散时间马尔可夫链时, 我们发现遍历马尔可夫链收敛于一个平稳分布, 但并没有确定它们的收敛有多快, 而这在一些算法应用(如用马尔可夫链蒙特卡罗方法抽样)中是很重要的. 本章介绍耦合的概念, 这是界定马尔可夫链收敛速度的有用的方法. 我们说明在某些应用中的耦合方法, 包括洗牌问题、随机游动及独立集合和顶点着色法的马尔可夫链蒙特卡罗抽样.

11.1 变异距离和混合时间

考虑下列洗 n 张牌的方法. 每一步, 独立地且均匀随机地选取一张牌, 并将它放在这副牌的最上面. 可以将洗牌过程当作一个马尔可夫链, 其中的状态即是牌的当前次序. 可以检查这个马尔可夫链是有限、不可约和非周期的, 因此它有一个平稳分布.

设 x 是链的一个状态, $N(x)$ 是可以一步到达 x 的状态集合. 这里 $|N(x)| = n$, 因为前一步的 n 个不同位置都可以是 x 中的最上面一张牌. 如果 π_i 是与平稳分布中的状态 y 关联的概率, 那么对任意的状态 x , 有

$$\pi_x = \frac{1}{n} \sum_{y \in N(x)} \pi_y.$$

均匀分布满足这些等式, 因此唯一的平稳分布是所有可能排列上的均匀分布.

我们知道当步数无限增加时, 平稳分布是马尔可夫链的极限分布. 如果可以“永远”地运行链, 那么在极限意义上将得到一个具有均匀分布的状态. 实际上我们只能运行链有限步. 如果希望用这种马尔可夫链去洗这副牌, 在得到一副接近均匀分布的牌之前需要多少步?

为量化“接近于均匀”的意义, 我们必须介绍一种距离度量.

定义 11.1 在可数状态空间 S 上的两个分布 D_1 和 D_2 之间的变异距离由下式给出:

$$\|D_1 - D_2\| = \frac{1}{2} \sum_{x \in S} |D_1(x) - D_2(x)|.$$

图 11.1 给出了一个变异距离的图例.

变异距离定义中的因子 $1/2$ 保证变异距离在 0 和 1 之间, 还有以下另一种有用的特征.

引理 11.1 对任意 $A \subseteq S$, 令 $D_i(A) = \sum_{x \in A} D_i(x)$, $i = 1, 2$, 那么

$$\|D_1 - D_2\| = \max_{A \subseteq S} |D_1(A) - D_2(A)|.$$

仔细审视图 11.1 可以使这个引理的证明比较清楚.

证明 设 $S^+ \subseteq S$ 是使 $D_1(x) \geq D_2(x)$ 的状态集合, $S^- \subseteq S$ 是使 $D_2(x) > D_1(x)$ 的状态集合. 显然,

$$\max_{A \subseteq S} \{D_1(A) - D_2(A)\} = D_1(S^+) - D_2(S^+)$$

及

$$\max_{A \subseteq S} \{ D_2(A) - D_1(A) \} = D_2(S^-) - D_1(S^-).$$

但因为 $D_1(S) = D_2(S) = 1$, 我们有

$$D_1(S^+) + D_1(S^-) = D_2(S^+) + D_2(S^-) = 1, \quad [272]$$

这蕴涵

$$D_1(S^+) - D_2(S^+) = D_2(S^-) - D_1(S^-).$$

因此

$$\max_{A \subseteq S} |D_1(A) - D_2(A)| = |D_1(S^+) - D_2(S^+)| = |D_1(S^-) - D_2(S^-)|.$$

最后, 因为

$$|D_1(S^+) - D_2(S^+)| + |D_1(S^-) - D_2(S^-)| = \sum_{x \in S} |D_1(x) - D_2(x)| = 2 \|D_1 - D_2\|,$$

我们有

$$\max_{A \subseteq S} |D_1(A) - D_2(A)| = \|D_1 - D_2\|,$$

这就完成了证明.

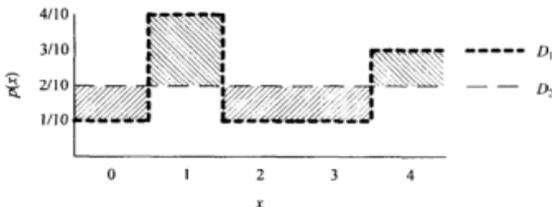


图 11.1 变异距离的例子. 按向上对角线画出的阴影面积对应于使 $D_1(x) < D_2(x)$ 的 x 值, 按向下对角线画出的阴影面积对应于使 $D_1(x) > D_2(x)$ 的 x 值. 向上对角线阴影的总面积必定等于向下对角线阴影的总面积, 而变异距离等于这两个面积之一

作为引理 11.1 的一个应用, 假定运行洗牌马尔可夫链, 直到链的分布与均匀分布之间的变异距离小于 ε . 接近均匀分布是个很强的概念, 因为牌的每种排列必至多有 $1/n! + \varepsilon$ 的概率. 实际上, 变异距离的界给出了一个较强的陈述: 对任意子集 $A \subseteq S$, 最后排列来自集合 A 的概率至多为 $\pi(A) + \varepsilon$. 例如, 假定某人尝试将一张 A 放在一副牌的最上面, 如果从这个分布到均匀分布的变异距离小于 ε , 我们可以有把握地说 A 是一副牌的第一张牌的概率比有一副理想洗牌的概率至多大 ε .

另一个例子, 假定取一副 52 张的扑克牌, 并洗所有的牌, 但将黑桃 A 留在最上面. 此时得到的分布 D_1 与均匀分布 D_2 之间的变异距离可由考虑黑桃 A 在最上面的状态集合 B 来界定:

$$\|D_1 - D_2\| = \max_{A \subseteq S} |D_1(A) - D_2(A)| \geq |D_1(B) - D_2(B)| = 1 - \frac{1}{52} = \frac{51}{52}.$$

变异距离的定义与 ε -均匀样本(由定义 10.3 给出)的定义是一致的. 一个抽样算法返回 Ω 上的 ε -均匀样本, 当且仅当它的输出分布 D 与均匀分布 U 之间的变异距离满足

$$\|D - U\| \leq \varepsilon.$$

因此, 界定均匀分布与若干步后马尔可夫链的状态分布之间变异距离, 可能是证明有效的 ε -均匀抽样器存在性的有用的方法, 这(如在第 10 章所证明的)可能给出一个有效的近似计数算法.

现在考虑如何给出 t 步后变异距离的界. 以后假定所考虑的马尔可夫链是有合理定义的平稳分布的遍历离散空间和离散时间链, 将用到下面的定义.

273

定义 11.2 设 $\bar{\pi}$ 是状态空间为 S 的马尔可夫链的平稳分布, p_t^x 表示从状态 x 出发经 t 步后链的状态分布, 定义

$$\Delta_t(x) = \|p_t^x - \bar{\pi}\|; \quad \Delta(t) = \max_{x \in S} \Delta_t(x).$$

即 $\Delta_t(x)$ 是平稳分布与 p_t^x 之间的变异距离, $\Delta(t)$ 是对所有的状态 x 这种变异距离的最大值.

还定义

$$\tau_t(\varepsilon) = \min \{t; \Delta_t(x) \leq \varepsilon\}; \quad \tau(\varepsilon) = \max_{x \in S} \tau_t(\varepsilon).$$

即 $\tau_t(\varepsilon)$ 是使得 p_t^x 与平稳分布之间的变异距离小于 ε 的第一个 t 步, $\tau(\varepsilon)$ 是对所有的状态 x , $\tau_t(\varepsilon)$ 的最大值.

将 $\tau(\varepsilon)$ 作为 ε 的函数时, 一般称为马尔可夫链的混合时间. 一个链称为快速混合的, 如果 $\tau(\varepsilon)$ 是关于 $\log(1/\varepsilon)$ 及问题大小的多项式. 问题的大小与具体情况有关, 在洗牌的例子中, 大小就是牌的张数.

11.2 耦合

马尔可夫链的耦合是一种界定马尔可夫链混合时间的一般技术.

定义 11.3 状态空间为 S 的马尔可夫链 M_t 的耦合是一个在状态空间 $S \times S$ 上的马尔可夫链 $Z_t = (X_t, Y_t)$, 使得

$$\Pr(X_{t+1} = x' \mid Z_t = (x, y)) = \Pr(M_{t+1} = x' \mid M_t = x);$$

$$\Pr(Y_{t+1} = y' \mid Z_t = (x, y)) = \Pr(M_{t+1} = y' \mid M_t = y).$$

即一个耦合由同时运行的马尔可夫链 M 的两个副本组成, 这两个副本不是刻板的复制, 两个链不必处于相同的状态, 也不必作同样的移动. 我们的意思是每个副本的表现通过它的转移概率与原马尔可夫链精确地相似. 得到耦合的一种显然方法是取马尔可夫链两次独立的运行. 如我们将要看到的, 这种耦合对我们的目的并不是很有用的.

实际上, 我们感兴趣的耦合是 (a) 能使链的两个副本有相同的状态; (b) 一旦两个链处于相同的状态, 两个链就需作完全一样的移动, 以保持它们处于相同状态中. 当链的两个副本达到相同状态时, 就称它们为耦合了. 下面的引理激发我们为什么要寻找耦合的一对.

274

引理 11.2 [耦合引理] 设 $Z_t = (X_t, Y_t)$ 是状态空间 S 上马尔可夫链 M 的一个耦合. 假定存在一个 T , 使得对每个 $x, y \in S$,

$$\Pr(X_T \neq Y_T | X_0 = x, Y_0 = y) \leq \varepsilon.$$

那么

$$\tau(\varepsilon) \leq T.$$

即对任意初始状态, 经 T 步后链的状态分布与平稳分布之间的变异距离至多为 ε .

证明 考虑当 Y_0 是按平稳分布选取且 X_0 取任意值时的耦合. 对给定的 T 和 ε 及任意的 $A \subseteq S$,

$$\begin{aligned} \Pr(X_T \in A) &\geq \Pr((X_T = Y_T) \cap (Y_T \in A)) \\ &= 1 - \Pr((X_T \neq Y_T) \cup (Y_T \notin A)) \\ &\geq (1 - \Pr(Y_T \notin A)) - \Pr(X_T \neq Y_T) \\ &\geq \Pr(Y_T \in A) - \varepsilon \\ &= \pi(A) - \varepsilon. \end{aligned}$$

这里, 由并的界, 第二行成立. 在第三行, 用了对任意的初始状态 X_0 和 Y_0 都有 $\Pr(X_T \neq Y_T) \leq \varepsilon$ 的事实, 特别当 Y_0 是按平稳分布选取时也成立. 最后一行, 利用了 $\Pr(Y_T \in A) = \pi(A)$, 因为 Y_T 也是按平稳分布分布的. 对集合 $S-A$ 同样可以证明 $\Pr(X_T \notin A) \geq \pi(S-A) - \varepsilon$ 或 $\Pr(X_T \in A) \leq \pi(A) + \varepsilon$.

由此,

$$\max_{i,A} |p_i^T(A) - \pi(A)| \leq \varepsilon,$$

故由引理 11.1, 经 T 步运行后的链与平稳分布的变异距离的上界为 ε . ■

11.2.1 例: 洗牌

为将耦合引理有效地用于洗牌马尔可夫链, 需要选取一个合适的耦合. 给定在不同状态下链的两个副本 X_i 和 Y_i , 耦合的一种可能是从 1 到 n 均匀随机地选择一个位置 j , 并同时两个链中的从上面数起的第 j 张牌移动到顶端. 这是一个合适的耦合, 因为每个链都可以与原洗牌的马尔可夫链一样单独行动. 尽管这个耦合是自然的, 但显然不能直接应用. 因为链从不同状态出发, 两个链的从最上面数起的第 j 张牌通常是不一样的, 将这两张不同的牌移动到顶端并不能产生处于相同状态的链的两个副本.

一个更有用的耦合是从 1 到 n 均匀随机地选择一个位置 j , 然后通过移动从最上面数起的第 j 张牌到顶端由 X_i 得到 X_{i+1} , 并用 C 表示这张牌的牌面. 为了从 Y_i 得到 Y_{i+1} , 将牌面为 C 的牌移动到顶端. 这样的耦合仍是合适的, 因为在这两个链中, 一张特殊的牌移动到顶端的概率对每步都是 $1/n$. 用这种耦合, 由归纳法容易看到, 一旦牌 C 移动到顶端, 它在链的两个副本中就永远处于相同位置. 因此只要每张牌至少有一次机会移动到了顶端, 这两个副本必然成为耦合的.

现在洗牌马尔可夫链的耦合问题看来与赠券收集问题相似了; 为了得到直至链耦合所需的步数的界, 我们简单地界定在每张牌至少被选取一次以前所必须均匀随机地选取牌的次数. 我们知道当马尔可夫链运行 $n \ln n + cn$ 步后, 一张特定的牌从未被移动到顶端的概率至多为

$$\left(1 - \frac{1}{n}\right)^{n \ln n + cn} \leq e^{-(\ln n + c)} = \frac{e^{-c}}{n},$$

所以(由并的界)任一张牌从未移动到顶端的概率至多为 e^{-1} . 因此只要经 $n \ln n + n \ln(1/\varepsilon) = n \ln(n/\varepsilon)$ 步, 链没有耦合的概率至多为 ε . 耦合引理使得可以断定, 均匀分布与 $n \ln(n/\varepsilon)$ 步后链的状态分布之间的变异距离有上界 ε .

11.2.2 例: 超立方体上的随机游动

回忆 4.5.1 节中的 n 维超立方体(或 n -立方体)由 $N=2^n$ 个编号为 0 到 $N-1$ 个结点组成. 设 $\bar{x} = (x_1, \dots, x_n)$ 是 x 的二进制表示. 结点 x 与 y 由一条边连接, 当且仅当 \bar{x} 与 \bar{y} 恰有一个位上的差异.

我们考虑定义在 n -立方体上的以下马尔可夫链. 每一步都从 $\{1, \dots, n\}$ 均匀随机地选取一个坐标 i , 新的状态 x' 是从当前状态 x 中(可能除了 x_i 以外)通过保持 \bar{x} 的所有坐标相同得到的. 坐标 x_i 以 $1/2$ 的概率设置为 0, 以 $1/2$ 的概率设置为 1. 除了链以 $1/2$ 的概率停留在同一顶点而不是移动到一个新顶点, 从而消除了潜在的周期性问题以外, 这个马尔可夫链恰好是超立方体上的随机游动. 由此容易得到这个链的平稳分布是超立方体顶点上的均匀分布.

利用马尔可夫链的两个副本 X_t 与 Y_t 之间的显然耦合得到这个马尔可夫链的混合时间 $\tau(\varepsilon)$ 的界: 每一步都对两个链作同样的移动. 只要选取了第 i 坐标作为马尔可夫链的一个移动, 这种耦合便保证链的两个副本在第 i 个坐标上是一致的. 因此当所有 n 个坐标中的每一个都被至少选取一次以后, 链将是耦合的.

所以可以由直到每个坐标都至少被马尔可夫链选取一次的步数的界作为混合时间的界. 同洗牌链的情况一样, 这又归结为赠券收集问题. 由同样的论证, 经 $n \ln(n\varepsilon^{-1})$ 步后, 链没有耦合的概率小于 ε , 故由耦合引理, 混合时间满足

$$\tau(\varepsilon) \leq n \ln(n\varepsilon^{-1}).$$

11.2.3 例: 固定大小的独立集合

考虑这样一个马尔可夫链, 其状态是图 $G=(V, E)$ 中大小恰为 k 的所有独立集合. 因为我们限制在固定大小的独立集合, 所以需要与 10.4 节讨论的所有独立集合的链不同的马尔可夫链. 从独立集合 X_t 均匀随机地选取一个顶点 $v \in X_t$ 及均匀随机地选取的一个顶点 $w \in V$ 形成一次移动. 移动 $m(v, w, X_t)$ 可以如下描述: 如果 $w \notin X_t$ 且 $(X_t - \{v\}) \cup \{w\}$ 是一个独立集合, 那么 $X_{t+1} = (X_t - \{v\}) \cup \{w\}$; 否则 $X_{t+1} = X_t$. 设 n 是图中顶点个数, Δ 是任一顶点的最大次. 这里我们证明当 $k \leq n/(3\Delta + 3)$ 时, 这个链迅速混合. 我们把证明这个马尔可夫链是遍历的且有均匀的平稳分布的任务留作练习 11.11, 并在以后论证中假定这是成立的.

考虑 $Z_t = (X_t, Y_t)$ 上的一个耦合. 我们的耦合要求每一步在 $X_t - Y_t$ 及 $Y_t - X_t$ 的顶点之间有任意完美的匹配 M , 例如, 可以将顶点标上 1 到 n , 并按排列后的次序将 $Y_t - X_t$ 的元素通过一一映射按排列后的次序与 $X_t - Y_t$ 的元素匹配. 对我们的耦合, 首先通过均匀随机地选取 $v \in X_t$, $w \in V$ 选取链 X_t 的一个转移, 然后执行移动 $m(v, w, X_t)$. 显然链 X_t 的副本确实如定义 11.3 所要求的服从原马尔可夫链. 对 Y_t 的转移, 如果 $v \in Y_t$, 那么用同一对顶点 v 和 w 并执行移动 $m(v, w, Y_t)$; 如果 $v \notin Y_t$, 则执行移动 $m(M(v), w, Y_t)$ (其中 $M(v)$ 表示与 v 匹配的顶点). 链 Y_t 的副本也确实服从原马尔可夫链, 因为每对顶点 $v \in Y_t$, $w \in V$ 都是以概率 $1/kn$ 选取的.

建立耦合的另一种方法如下. 我们仍然均匀随机地选取 $v \in X_t$ 及 $w \in Y_t$, 然后在链 X_t 中执行移动 $m(v, w, X_t)$. 如果 $v \in Y_t$, 在链 Y_t 中执行移动 $m(v, w, Y_t)$; 否则均匀随机地选取一个顶点 $v' \in Y_t - X_t$, 且在链 Y_t 中执行移动 $m(v', w, Y_t)$. 在练习 11.10 将看到这满足定义 11.3.

设 $d_t = |X_t - Y_t|$ 度量 t 步后两个独立集合之间的差异. 显然 d_t 在每一步至多可以改变 1. 我们证明 d_t 更可能是递减而不是递增, 利用这个事实, 对充分大的 t 建立 $d_t > 0$ 的概率的上界.

假设 $d_t > 0$, 为使 $d_{t+1} = d_t + 1$, 必须在 t 时刻从 $X_t \cap Y_t$ 中选取顶点 v , 且选取 w 使得恰好在其中一个链存在转移. 所以 w 必是集合 $(X_t - Y_t) \cup (Y_t - X_t)$ 中的一个顶点或顶点的邻点, 由此

$$\Pr(d_{t+1} = d_t + 1 | d_t > 0) \leq \frac{k - d_t}{k} \frac{2d_t(\Delta + 1)}{n}.$$

类似地, 为使 $d_{t+1} = d_t - 1$, 只需在 t 时刻有 $v \notin Y_t$, 且 w 不是集合 $X_t \cup Y_t - \{v, v'\}$ 中的顶点, 也不是顶点的邻点. 注意 $|X_t \cup Y_t| = k + d_t$. 所以,

$$\Pr(d_{t+1} = d_t - 1 | d_t > 0) \geq \frac{d_t}{k} \frac{n - (k + d_t - 2)(\Delta + 1)}{n}.$$

这样, 对 $d_t > 0$, 我们有

$$\begin{aligned} E[d_{t+1} | d_t] &= d_t + \Pr(d_{t+1} = d_t + 1) - \Pr(d_{t+1} = d_t - 1) \\ &\leq d_t + \frac{k - d_t}{k} \frac{2d_t(\Delta + 1)}{n} - \frac{d_t}{k} \frac{n - (k + d_t - 2)(\Delta + 1)}{n} \\ &= d_t \left(1 - \frac{n - (3k - d_t - 2)(\Delta + 1)}{kn} \right) \\ &\leq d_t \left(1 - \frac{n - (3k - 3)(\Delta + 1)}{kn} \right). \end{aligned}$$

只要 $d_t = 0$, 两个链便有相同的路径, 所以 $E[d_{t+1} | d_t = 0] = 0$.

利用条件期望等式, 我们有

$$E[d_{t+1}] = E[E[d_{t+1} | d_t]] \leq E[d_t] \left(1 - \frac{(n - 3k + 3)(\Delta + 1)}{kn} \right).$$

经归纳得到

$$E[d_t] \leq d_0 \left(1 - \frac{(n - (3k - 3)(\Delta + 1))}{kn} \right)^t.$$

因为 $d_0 \leq k$, 且因为 d_t 是非负整数, 所以

$$\Pr(d_t \geq 1) \leq E[d_t] \leq k \left(1 - \frac{(n - (3k - 3)(\Delta + 1))}{kn} \right)^t \leq e^{-\frac{(n - (3k - 3)(\Delta + 1))}{kn} t}.$$

这个结果的一个推论是每当 $k \leq n/(3\Delta + 3)$ 时, 变异距离便收敛于零, 此时

$$\tau(\varepsilon) \leq \frac{kn \ln \varepsilon^{-1}}{n - (3k - 3)(\Delta + 1)}.$$

这样我们发现 $\tau(\varepsilon)$ 是 n 和 $\ln(1/\varepsilon)$ 的多项式, 这蕴涵只要 $k \leq n/(3\Delta + 3)$, 链就迅速混合.

实际上, 我们可以改进这个结果. 在练习 11.12 中, 利用一个稍微复杂的耦合得到了对任

意 $k \leq n/2(\Delta + 1)$ 成立的界.

11.3 应用: 变异距离是不增的

我们知道一个遍历的马尔可夫链最终收敛于它的平稳分布. 事实上, 在马尔可夫链的状态与它的平稳分布之间的变异距离关于时间是不增的. 为证明这一点, 我们从一个有意义的引理开始, 它给出了变异距离的另一个有用的性质.

引理 11.3 给定状态空间 S 上的分布 σ_x 和 σ_y , 令 $Z = (X, Y)$ 是 $S \times S$ 上的随机变量, 其中 X 服从 σ_x 分布, Y 服从 σ_y 分布, 那么

$$\Pr(X \neq Y) \geq \| \sigma_x - \sigma_y \|. \quad (11.1)$$

此外, 存在 $Z = (X, Y)$ 的一个联合分布, 其中 X 服从 σ_x 分布, Y 服从 σ_y 分布, 且此时等号成立.

仍考察一个特殊的例子(如图 11.1 所示)有助于理解下面的证明.

证明 对每个 $x \in S$, 我们有

$$\Pr(X = Y = x) \leq \min(\Pr(X = x), \Pr(Y = x)).$$

因此

$$\Pr(X = Y) \leq \sum_{x \in S} \min(\Pr(X = x), \Pr(Y = x)).$$

所以

$$\begin{aligned} \Pr(X \neq Y) &\geq 1 - \sum_{x \in S} \min(\Pr(X = x), \Pr(Y = x)) \\ &= \sum_{x \in S} (\Pr(X = x) - \min(\Pr(X = x), \Pr(Y = x))). \end{aligned}$$

因此如果能够证明

$$\| \sigma_x - \sigma_y \| = \sum_{x \in S} (\Pr(X = x) - \min(\Pr(X = x), \Pr(Y = x))) \quad (11.2)$$

就可以了. 但当 $\sigma_x(x) < \sigma_y(x)$ 时, $\Pr(X = x) - \min(\Pr(X = x), \Pr(Y = x)) = 0$, 而当 $\sigma_x(x) \geq \sigma_y(x)$ 时,

$$\Pr(X = x) - \min(\Pr(X = x), \Pr(Y = x)) = \sigma_x(x) - \sigma_y(x).$$

如果用 S' 表示所有使 $\sigma_x(x) \geq \sigma_y(x)$ 的状态集合, 那么(11.2)式右边等于 $\sigma_x(S') - \sigma_y(S')$, 由引理 11.1 中的证明可知, 这等于 $\| \sigma_x - \sigma_y \|$, 这给出了引理第一部分的证明.

如果取一个联合分布, 其中尽可能地有 $X = Y$, 那么(11.1)式中等号成立. 特别地, 记 $m(x) = \min(\Pr(X = x), \Pr(Y = x))$. 如果 $\sum_x m(x) = 1$, 那么 X, Y 有相同分布, 证明已经完成. 否则, 令 $Z = (X, Y)$ 由

$$\Pr(X = x, Y = y) = \begin{cases} m(x) & \text{如果 } x = y; \\ \frac{(\sigma_x(x) - m(x))(\sigma_y(y) - m(y))}{1 - \sum_z m(z)} & \text{其他} \end{cases}$$

定义. 这样选择 Z 的意思是首先尽可能地使 X, Y 匹配, 其次, 如果它们不能匹配, 则迫使 X 和 Y 有独立的表现.

对 Z 的这种选择,

$$\Pr(X = Y) = \sum_x m(x) = 1 - \|\sigma_x - \sigma_y\|.$$

[279]

剩下的只需证明对 Z 的这种选择, $\Pr(X = x) = \sigma_x(x)$; 对 $\Pr(Y = y)$ 也有同样式子成立. 如果 $m(x) = \sigma_x(x)$, 那么 $\Pr(X = x, Y = x) = m(x)$. 且当 $x \neq y$ 时, $\Pr(X = x, Y = y) = 0$, 所以 $\Pr(X = x) = \sigma_x(x)$. 如果 $m(x) = \sigma_y(x)$, 那么

$$\begin{aligned} \Pr(X = x) &= \sum_y \Pr(X = x, Y = y) \\ &= m(x) + \sum_{y \neq x} \frac{(\sigma_x(x) - m(x))(\sigma_y(y) - m(y))}{1 - \sum_z m(z)} \\ &= m(x) + \frac{(\sigma_x(x) - m(x)) \sum_{y \neq x} (\sigma_y(y) - m(y))}{1 - \sum_z m(z)} \\ &= m(x) + \frac{(\sigma_x(x) - m(x))(1 - \sigma_y(x) - (\sum_z m(z) - m(x)))}{1 - \sum_z m(z)} \\ &= m(x) + (\sigma_x(x) - m(x)) \\ &= \sigma_x(x). \end{aligned}$$

这就完成了证明. ■

回忆 $\Delta(t) = \text{Max}_x \Delta_x(t)$, 其中 $\Delta_x(t)$ 是从状态 x 出发经 t 步后的马尔可夫链的状态分布与平稳分布之间的变异距离. 利用引理 11.3, 可以证明 $\Delta(t)$ 关于时间是非增的.

定理 11.4 对任一遍历的马尔可夫链 M_t , $\Delta(T+1) \leq \Delta(T)$.

证明 设 x 是任一给定的状态, y 是从平稳分布中选取的一个状态, 那么

$$\Delta_x(T) = \|p_x^T - p_y^T\|.$$

实际上, 如果 X_T 服从 p_x^T 分布, Y_T 服从 p_y^T 分布, 那么由引理 11.3, 存在一个随机变量 $Z_T = (X_T, Y_T)$, 使得 $\Pr(X_T \neq Y_T) = \Delta_x(T)$. 从这个状态 $Z_T = (X_T, Y_T)$, 考虑马尔可夫链的任意一步耦合: 只要 $X_T = Y_T$, 耦合就作同样的移动, 使得 $X_{T+1} = Y_{T+1}$. 链是按这样的方法从 $Z_T = (X_T, Y_T)$ 到 $Z_{T+1} = (X_{T+1}, Y_{T+1})$ 的. 现在 X_{T+1} 服从 p_x^{T+1} 分布, Y_{T+1} 服从 p_y^{T+1} 分布, 这是平稳分布. 故由引理 11.3,

$$\begin{aligned} \Delta_x(T) &= \Pr(X_T \neq Y_T) \\ &\geq \Pr(X_{T+1} \neq Y_{T+1}) \\ &\geq \|p_x^{T+1} - p_y^{T+1}\| \\ &= \Delta_x(T+1). \end{aligned}$$

由第一行得第二行成立是因为当 $X_T = Y_T$ 时, 一步耦合保证 $X_{T+1} = Y_{T+1}$. 由于对每个状态 x , 前

述关系都成立, 所以结果成立. ■

11.4 几何收敛

以下的一般结果来自一个普通的耦合, 可用于界定某些马尔可夫链的混合时间.

定理 11.5 设 P 是一个有限、不可约、非周期的马尔可夫链的转移矩阵, m_j 是矩阵第 j 列的最小元素, $m = \sum_j m_j$, 那么对所有 x 和 t ,

$$\|p_x^t - \pi\| \leq (1-m)^t.$$

证明 如果第 j 列的最小元素为 m_j , 那么链从每一个状态出发经一步到达状态 j 的概率至少为 m_j . 因此可以设计一个耦合, 其中在每一步, 链的两个副本至少以 m_j 的概率一起移动到状态 j . 因为这对所有 j 成立, 在每一步两个链都至少以概率 m 形成耦合. 因此经 t 步后它们不能耦合的概率至多为 $(1-m)^t$, 由耦合引理可知定理成立. ■

如果每列都有一个零元素, 此时 $m=0$, 则定理 11.5 不能直接利用. 在练习 11.6 中考虑如何使它任一有限、不可约、非周期的马尔可夫链成为有用的. 定理 11.5 说明在非常一般的条件下, 随着变异距离关于步数几何地收敛, 马尔可夫链很快地收敛于它们的平稳分布.

以下是一个更一般的有关结果. 假定对某个常数 $c < 1/2$, 可以得到关于 $\tau(c)$ 的一个上界. 例如, 由耦合可能得到这样的界. 对任意的 $\varepsilon > 0$, 这对于用自助法求 $\tau(\varepsilon)$ 的界足够了.

定理 11.6 设 P 是一个有限、不可约、非周期马尔可夫链 M_1 的转移矩阵, 对某个 $c < 1/2$, 有 $\tau(c) \leq T$, 那么对这个马尔可夫链, $\tau(\varepsilon) \leq \lceil \ln \varepsilon / \ln(2c) \rceil T$.

证明 考虑任意两个初始状态 $X_0 = x, Y_0 = y$. 由 $\tau(c)$ 的定义, 我们有 $\|p_x^T - \pi\| \leq c$ 及 $\|p_y^T - \pi\| \leq c$. 由此 $\|p_x^T - p_y^T\| \leq 2c$, 因此由引理 11.3, 存在一个随机变量 $Z_{T,x,y} = (X_T, Y_T)$, 其中 X_T 服从 p_x^T 分布, Y_T 服从 p_y^T 分布, 使得 $\Pr(X_T \neq Y_T) \leq 2c$.

现在考虑由转移矩阵 P^T 给定的马尔可夫链 M'_1 , 这对应于一个它的每一步都是 M_1 的 T 步的链. 对这个新链, $Z_{T,x,y}$ 给出了一个耦合. 即已知成对的状态 (x, y) 中链 M'_1 的两个副本, 可以由分布 $Z_{T,x,y}$ 给出下一对状态, 它保证两个状态不能用一步耦合的概率至多为 $2c$. 由归纳法, 链 M'_1 的这个耦合经 k 步不能耦合的概率至多为 $(2c)^k$. 由耦合引理, 如果

$$(2c)^k \leq \varepsilon,$$

M'_1 经 k 步后在其平稳分布的变异距离 ε 之内. 由此至多经 $\lceil \ln \varepsilon / \ln(2c) \rceil$ 步, M'_1 在其平稳分布的变异距离 ε 之内. 但 M'_1 与 M_1 有相同的平稳分布, M'_1 的每一步对应于 M_1 的 T 步, 所以对马尔可夫链 M_1 ,

$$\tau(\varepsilon) \leq \left\lceil \frac{\ln \varepsilon}{\ln(2c)} \right\rceil T. \quad \blacksquare$$

11.5 应用: 正常着色法的近似抽样

一个图的顶点着色法是对每个顶点 v 给出取自集合 C 的一种颜色, 不失一般性, 可以假定这个集合为 $\{1, 2, \dots, c\}$. 在正常着色法中, 每条边的两个端点用两种不同的颜色着色. 对最大次为 Δ 的任一图可按下面的程序用 $\Delta + 1$ 种颜色适当地着色: 选择任意的顶点次序, 每次

用一种颜色给顶点着色, 用其任何一个邻点都没有用到的一种颜色为每个顶点着色.

这里我们感兴趣的是几乎均匀随机地抽样一个图的正常着色法. 我们提出马尔可夫链蒙特卡罗 (MCMC) 方法产生这样一个样本, 然后用耦合技术证明它能迅速混合. 用第 10 章的术语, 这给出了正常着色法的一个 FPAUS. 应用从近似计数到几乎均匀抽样的一般简化方法, 如定理 10.5 所示, 可以利用对抽样正常着色法的 FPAUS 得到正常着色法次数的一个 FPRAS. 这种简化的细节作为练习 11.15 的一部分.

首先提出一个直接的耦合, 当存在 $c > 4\Delta + 1$ 种颜色时, 允许我们有效地近似抽样着色法, 然后说明如何改进这个耦合, 从而将必须的颜色种数减少到 $2\Delta + 1$.

正常着色法的马尔可夫链是最简单的一种可能. 每一步都均匀随机地选取一个顶点 v , 并均匀随机地选取一种颜色 ℓ . 如果新的着色是恰当的 (即 v 没有一个着色为 ℓ 的邻点), 那么给顶点 v 重新着色 ℓ , 否则不改变链的状态. 这个有限马尔可夫链是非周期的, 因为它停留在同一状态的概率非零. 当 $c \geq \Delta + 2$ 时, 它还是不可约的. 为了说明如何从任一状态 X 可以到达任意其他一个状态 Y , 考虑任意的顶点次序. 对 X 中的顶点重新着色, 使得按这个次序与 Y 匹配. 如果在任一步发生冲突, 这是必然要出现的, 因为需要着色的顶点 v 受到另一个按这种次序排在后面的顶点 v' 的限制. 但 v' 可以重新着色上某种别的不冲突的颜色, 因为 $c \geq \Delta + 2$, 容许这个过程继续下去. 因此, 当 $c \geq \Delta + 2$ 时, 马尔可夫链有平稳分布. 这个平稳分布是在所有正规着色法上的均匀分布, 由引理 10.7 可以验证这个事实.

当有 $4\Delta + 1$ 种颜色时, 我们用一对链 (X_t, Y_t) 上的平凡耦合: 对两个链的每一步都选取相同的顶点和相同的颜色.

定理 11.7 对任一 n 个顶点且最大次为 Δ 的图, 如果 $c \geq 4\Delta + 1$, 图着色法的马尔可夫链的混合时间满足

$$\tau(\varepsilon) \leq \left\lceil \frac{nc}{c - 4\Delta} \ln \left(\frac{n}{\varepsilon} \right) \right\rceil.$$

证明 设 D_t 表示时刻 t 两个链中有不同颜色的顶点集合, 且记 $d_t = |D_t|$. 在使 $d_t > 0$ 的每一步, 或者 d_t 保持相同值, 或者 d_t 至多增加或减少 1. 我们证明 d_t 实际上更可能是减而不是增; 然后利用这个事实, 对充分大的 t 界定 d_t 为非零的概率.

考虑在两个链中有不同颜色的任一顶点 v . 因为 v 的次至多为 Δ , 所以至少有 $c - 2\Delta$ 种颜色不会出现在两个链之一的 v 的邻点中. 如果顶点用这 $c - 2\Delta$ 种颜色之一重新着色, 这将使两个链会有相同的颜色, 所以

$$\Pr(d_{t+1} = d_t - 1 \mid d_t > 0) \geq \frac{d_t}{n} \frac{c - 2\Delta}{c}.$$

现在考虑在两个链中有相同颜色的任一顶点 v . 对下一步要着不同颜色的 v , 必有某个邻点 w 在两个链中着有不同颜色, 此时可以尝试给 v 重新着色上邻点 w 在这两个链之一所具有的颜色, 这样只要求一个链中的顶点 v 重新着色, 但另一个链不必. 按这样的方法, 两个链中着有不同颜色的每个顶点至多影响 Δ 个邻点. 因此, 当 $d_t > 0$ 时,

$$\Pr(d_{t+1} = d_t + 1 \mid d_t > 0) \leq \frac{\Delta d_t}{n} \frac{2}{c}.$$

我们得到

$$\begin{aligned} E[d_{i+1} | d_i] &= d_i + \Pr(d_{i+1} = d_i + 1) - \Pr(d_{i+1} = d_i - 1) \\ &\leq d_i + \frac{\Delta d_i}{n} \frac{2}{c} - \frac{d_i}{n} \frac{c - 2\Delta}{c} \\ &\leq d_i \left(1 - \frac{c - 4\Delta}{nc} \right), \end{aligned}$$

如果 $d_i = 0$, 上式也成立.

利用条件期望等式, 有

$$E[d_{i+1}] = E[E[d_{i+1} | d_i]] \leq E[d_i] \left(1 - \frac{c - 4\Delta}{nc} \right).$$

由归纳法可得

$$E[d_i] \leq d_0 \left(1 - \frac{c - 4\Delta}{nc} \right)^i.$$

[283] 因为 $d_0 \leq n$, 且因为 d_i 是非负整数, 可知

$$\Pr(d_i \geq 1) \leq E[d_i] \leq n \left(1 - \frac{c - 4\Delta}{nc} \right)^i \leq ne^{-i(c-4\Delta)/nc}.$$

因此经

$$t = \left\lceil \frac{nc}{c - 4\Delta} \ln \left(\frac{n}{\varepsilon} \right) \right\rceil$$

步后, 变异距离至多为 ε . ■

假设马尔可夫链的每一步可以在关于 n 的多项式时间内有效地完成, 定理 11.7 给出了正常着色法的一个 FPAUS.

定理 11.7 有较大的改进余地. 例如, 对 d_i 减小的概率的界定, 我们用到了宽松的界 $c - 2\Delta$. 如果 v 周围的某些顶点在两个链中有相同的颜色, 那么减少 d_i 的颜色种数可以很大. 用稍微小心、精巧的耦合, 可以改进定理 11.7 使对任意 $c \geq 2\Delta + 1$ 成立.

定理 11.8 给定一个最大次为 Δ 的 n 个顶点的图, 如果 $c \geq 2\Delta + 1$, 图着色法马尔可夫链的混合时间满足

$$\tau(\varepsilon) \leq \left\lceil \frac{n(c - \Delta)}{c - 2\Delta} \ln \left(\frac{n}{\varepsilon} \right) \right\rceil$$

证明 如前, 用 D_t 表示 t 时刻两个链中有不同颜色的顶点集合, $|D_t| = d_t$. 设 A_t 是 t 时刻两个链有相同颜色的顶点集合. 对 A_t 中的顶点 v , $d'(v)$ 是 D_t 中与 v 邻接的顶点数, 类似地, 对 D_t 中的顶点 w , $d'(w)$ 是 A_t 中与 w 邻接的顶点数. 注意

$$\sum_{v \in A_t} d'(v) = \sum_{w \in D_t} d'(w),$$

这是因为两个和都是连接 A_t 中顶点与 D_t 中顶点的边数. 用 m' 表示此和.

考虑以下耦合: 如果选取顶点 $v \in D_t$, 重新着色, 我们简单地在两个链中选取相同的颜色. 即当 v 在 D_t 中时, 利用以前用过的相同耦合. 不管所选颜色与在链的两个副本中 v 的任一邻点上的任意颜色是否不同, 顶点 v 都有相同颜色, 这样的颜色有 $c - 2\Delta + d'(v)$ 种. 注意这比我们

在证明定理 11.7 时用过的界要紧凑. 因此当 $d_i > 0$ 时, $d_{i+1} = d_i - 1$ 的概率至少为

$$\frac{1}{n} \sum_{v \in A_i} \frac{c - 2\Delta + d'(v)}{c} = \frac{1}{cn} ((c - 2\Delta)d_i + m').$$

现在假定重新着色的顶点是 $v \in A_i$, 在这种情况下, 我们稍稍改变耦合. 回忆在前面的耦合中, 如果随机选取的颜色只出现在 v 在一个链的邻点上而不在另一个链的邻点, 那么重新着色顶点 $v \in A_i$ 使得 v 在两个链中有不同颜色. 例如: 当 v 着绿色时, 在一个链中的一个邻点 w 着红色, 在另一个链中的邻点着蓝色, 且在任一链中没有 v 的其他邻点着红色或蓝色, 那么无论将 v 着红色还是蓝色的尝试必将使 v 在一个链中要重新着色, 但在另一个链中不必重新着色. 因此对增加 d_i , v 的颜色存在两种可能的选择.

在两个链中只有与 v 相邻的一个顶点 w 有不同颜色的特殊情况下, 可以如下改进耦合: 当试着为第一个链中的 v 重新着上蓝色时, 试着为第二个链中的 v 重新着上红色; 而当试着为第一个链中的 v 重新着上红色时, 试着为第二个链中的 v 重新着上蓝色. 现在 v 或者改变在两个链中的颜色, 或者在两个链中保持相同. 由改变耦合, 可以把两个可能增加 d_i 的坏的移动缩减为只有一个坏的移动. 图 11.2 给出了一个例子.

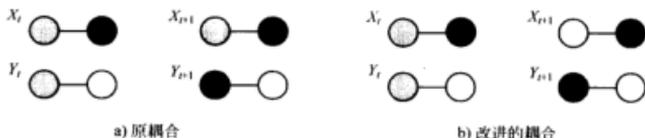


图 11.2 在原耦合 a) 中, 灰色顶点在两个链中有相同颜色, 且在两个链中有一个不同颜色的邻点, 一个是黑的, 一个是白的. 如果试图把灰色顶点重新着上黑色, 那么, 一个链能成功移动, 但另一个链不能, 增加了 d_i . 类似地, 如果试图把灰色顶点重新着上白色, 那么一个链能成功移动, 但另一个不能, 给出了增加 d_i 的第二次移动. 在改进的耦合 b) 中, 如果 X_i 中的灰色顶点重新着上白色, 则在 Y_i 中的灰色顶点重新着上黑色, 反之亦然, 恰好给出一次增加 d_i 的移动

更一般地, 如果在 v 的周围存在 $d'(v)$ 个不同颜色的顶点, 那么可以将颜色配对, 使得至多有 $d'(v)$ 种颜色的选择会引起 d_i 的增加, 而在原耦合中则有多达 $2d'(v)$ 种选择. 具体来讲, 设 $S_1(v)$ 是 v 在第一个链中但不在第二个链中的邻点的颜色集合, 类似地, $S_2(v)$ 是 v 在第二个链中而不在第一个链中的邻点的颜色集合. 尽可能多地将颜色 $c_1 \in S_1(v)$ 与 $c_2 \in S_2(v)$ 配成对, 使得当在一个链中选取 c_1 时, 在另一个链中选取 c_2 . 这样使增加 d_i 的 v 的着色法的总数至多为 $\max(S_1(v), S_2(v)) \leq d'(v)$.

作为结果, 当 $d_i > 0$ 时, $d_{i+1} = d_i + 1$ 的概率至多为

$$\frac{1}{n} \sum_{v \in A_i} \frac{d'(v)}{c} = \frac{m'}{cn}.$$

所以我们得到

$$E[d_{i+1} | d_i] \leq d_i \left(1 - \frac{c - 2\Delta}{nc} \right).$$

按与证明定理 11.7 中相同的理由, 有

$$Pr(d_i \geq 1) \leq E[d_i] \leq n \left(1 - \frac{c-2\Delta}{nc}\right)^t \leq ne^{-t(c-2\Delta)/nc},$$

经

$$t = \left\lceil \frac{nc}{c-2\Delta} \ln\left(\frac{n}{\epsilon}\right) \right\rceil$$

步后变异距离至多为 ϵ .

因此当 $c > 2\Delta$ 时, 可以用正常着色法的马尔可夫链给出一个 FPAUS.

11.6 路径耦合

在 10.3 节证明了如果可以得到次至多为 Δ 的图的独立集合的一个 FPAUS, 那么就可以近似地计数这种图的独立集合个数. 这里我们提出独立集合的马尔可夫链, 与耦合方法一起, 来证明在 $\Delta \leq 4$ 时, 这个链给出这样一个 FPAUS. 耦合方法利用了一种称为路径耦合的进一步的技术. 我们特别对图中抽样独立集合的马尔可夫链演示这种技术, 虽然用一个适当的定义这种方法也可推广到其他问题中去.

有意思的是要证明 10.4 节给出的抽样独立集合的简单的马尔可夫链(即每一步对当前的独立集合消去或试图增加一个随机顶点, 并很快混合)可能是非常困难的. 这里, 我们代之以考虑一个不同的能简化分析的马尔可夫链. 不失一般性, 假定图由单连分支组成. 每一步, 马尔可夫链均匀随机地选取图中一条边 (u, v) . 如果 X_t 是 t 时刻的独立集合, 那么移动过程如下.

- 以 $1/3$ 的概率, 令 $X_{t+1} = X_t - \{u, v\}$ (这个移动消去了 u 和 v , 如果它们在集合中).
- 以 $1/3$ 的概率, 令 $Y = (X_t - \{u\}) \cup \{v\}$. 如果 Y 是独立集合, 那么 $X_{t+1} = Y$; 否则, $X_{t+1} = X_t$ (这个移动试图消去 u , 如果它在独立集合中, 然后增加 v).
- 以 $1/3$ 的概率, 令 $Y = (X_t - \{v\}) \cup \{u\}$. 如果 Y 是独立集合, 那么 $X_{t+1} = Y$; 否则, $X_{t+1} = X_t$ (这个移动试图消去 v , 如果它在集合中, 然后增加 u).

容易验证, 这个链有一个在所有独立集合上均匀的平稳分布. 现在用路径耦合方法给出链的混合时间的界.

路径耦合的思想是从恰在一个顶点不同的状态对 (X_t, Y_t) 的耦合开始的, 然后将这个耦合扩展到所有状态对上的一般耦合. 在应用时, 因为分析两个状态只有一点儿不同(这里, 只是一个顶点不同)的情况要比分析所有可能的状态对常常容易得多, 所以路径耦合是非常有效的.

考虑图 $G = (V, E)$. 我们称一个顶点是坏的, 如果它是 X_t 或 Y_t 的一个元素, 但不是两者的; 否则, 称这个顶点是好的. 记 $d_t = |X_t - Y_t| + |Y_t - X_t|$, 所以 d_t 是坏顶点的个数. 假设 X_t 和 Y_t 恰有一个顶点的不同(即 $d_t = 1$), 我们用在两个状态中作相同移动的简单耦合, 证明在这个耦合下, 当 $d_t = 1$ 时, $E[d_{t+1} | d_t] \leq d_t$ 或等价地, $E[d_{t+1} - d_t | d_t = 1] \leq 0$.

不失一般性, 设 $X_t = I$ 且 $Y_t = I \cup \{x\}$. 只有当移动涉及 x 的邻点时, d_t 才可能出现变化. 所以在分析这种耦合时, 我们把讨论限制在选取的随机边邻接 x 的邻点的移动. 如果顶点 $z \neq x$ 在 t 步与 $t+1$ 步之间从好的变成坏的, 令 $\delta_t = 1$; 类似地, 如果顶点 x 在 t 步与 $t+1$ 步之间从

坏的变成好的, 令 $\delta_i = -1$. 由期望的线性性,

$$E[d_{i+1} - d_i | d_i = 1] = E\left[\sum \delta_w | d_i = 1\right] = \sum_w E[\delta_w | d_i = 1].$$

如我们将要看到的, 在和式中只需考虑这样一些 w , 它们等于 x 、 x 的邻点或 x 邻点的邻点, 因为只有这些顶点是在链的一步中可能从好顶点变为坏顶点, 或可能从坏顶点变为好顶点. 我们将以这种方式, 即只要 $\Delta \leq 4$, $E[d_{i+1} - d_i | d_i = 1] \leq 0$ 就成为显然, 来说明如何平衡移动.

设 x 有 k 个邻点, y 是这些邻点之一. 对每个是 x 邻点的顶点 y , 考虑所有选取一条与 y 相邻的移动. 以后的分析要用到限制 $\Delta \leq 4$, 这里有如图 11.3 所示的三种情况.

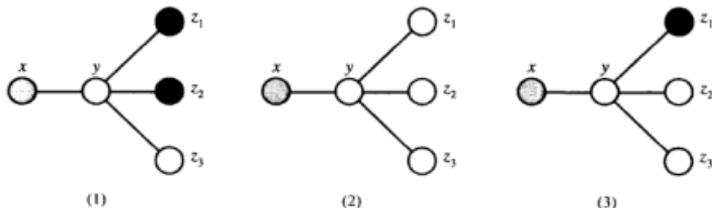


图 11.3 独立集合马尔可夫链的三种情况. 黑色顶点在耦合的两个独立集合中, 顶点 x 着灰色, 表示它是耦合中一条链的独立集合的元素, 但不是其他链的独立集合的元素

1. 假设在独立集合 $I = X_i$ 中 y 有两个或更多个邻点, 那么没有涉及 y 的移动可以增加坏顶点的个数, 因此作为任一这种移动的结果, d_{i+1} 不可能大于 d_i .

2. 假设在 I 中 y 没有邻点, 如果选取边 (y, z_i) (其中 $1 \leq i \leq 3$), 且试图增加 y 而消去 z_i , 则 d_i 可以增加 1. 这些移动在 X_i 上成功, 但在 Y_i 上不成功, 所以至多以 $3 \cdot 1/3 |E| = 1|E|$ 的概率有 $\delta_y = 1$, 没有其他涉及 y 的移动增加 d_i .

来自 δ_y 的可能增加通过减少 δ_x 的移动相抵了. 在边 (x, y) 上的三个可能移动中的任何一个都与顶点 x 匹配, 使得 $\delta_x = -1$, 并且没有增加其他坏顶点. 因此至多以 $1/|E|$ 的概率, $\delta_x = -1$. 我们看到的 $\sum_w E[\delta_w | d_i = 1]$ 上的所有这些移动的总影响为

$$1 \cdot \frac{1}{|E|} - 1 \cdot \frac{1}{|E|} = 0,$$

所以来自这种情况的移动不增加 $E[d_{i+1} - d_i | d_i = 1]$.

3. 假设在 I 中 y 有一个邻点. 如果选取边 (x, y) , 那么两个移动可以给出 $\delta_x = -1$: 消去 x 及 y 的移动, 或消去 y 但增加 x 的移动. 第三种试图增加 y 而消去 x 的移动在两个链中都不行, 因为 y 有一个 I 中的邻点. 所以至少以 $\frac{2}{3}(1/|E|)$ 的概率有 $\delta_x = -1$.

设 z 是 y 在 I 中的邻点, 如果选取边 (x, y) 且试图增加 y 而消去 z , 那么经一步 y 和 z 都可以成为坏顶点. 这种移动在 X_i 上成功, 但在 Y_i 上失败, 因为 δ_y 和 δ_z 都等于 1, 所以使得 d_i 增加 2. 没有其他移动增加 d_i . 因此在这种情况下, 坏顶点个数增加的概率为 $1/3|E|$, 且增加

2. 并且, 所有这些在 $\sum_{\delta} E[\delta_{\nu} | d_i = 1]$ 上的移动的总的的影响为

$$2 \cdot \frac{1}{3|E|} - 1 \cdot \frac{2}{3} \frac{1}{|E|} = 0,$$

所以来自这种情况的移动不增加 $E[d_{i+1} - d_i | d_i = 1]$.

情况分析说明如果考虑涉及一个指定邻点 y 的移动, 它们是平衡的, 从而每个增加 $d_{i+1} - d_i$ 的移动必与相应的减小 $d_{i+1} - d_i$ 的移动匹配. 关于所有顶点求和, 计算得到

$$E[d_{i+1} - d_i | d_i = 1] = E\left[\sum_{\delta} \delta_{\nu} | d_i = 1\right] = \sum_{\delta} E[\delta_{\nu} | d_i = 1] \leq 0.$$

现在用一个适当的耦合来证明对任何状态对 (X_i, Y_i) , $E[d_{i+1} | d_i] \leq d_i$. 如果 $d_i = 0$, 陈述是平凡的, 所以只需证明 $d_i = 1$ 时, 陈述成立即可. 如果 $d_i > 1$, 则产生一个状态链 Z_0, Z_1, \dots, Z_{d_i} 如下: $Z_0 = X_i$, 而每个相继的 Z_i 由 Z_{i-1} 通过从 $X_i - Y_i$ 中消去一个顶点或者对 $Y_i - X_i$ 增加一个顶点得到. 这是能够做到的, 例如, 首先逐个地消去 $X_i - Y_i$ 中所有顶点, 然后再逐个地增加 $Y_i - X_i$ 的顶点. 现在产生的耦合如下. 当在 $X_i = Z_0$ 中进行一次移动时, 关于 $d_i = 1$ 情况的耦合给出了一个关于状态 Z_1 的相应移动. 这个在 Z_1 中的移动可以类似地与状态 Z_2 中的移动耦合, 等等, 直到在 Z_{d_i-1} 中的移动产生 $Z_{d_i} = Y_i$ 的一个移动. 设 Z'_i 是从状态 Z_i 进行移动后的状态, 且令

$$\Delta(Z'_{i-1}, Z'_i) = |Z'_{i-1} - Z'_i| + |Z'_i - Z'_{i-1}|.$$

注意 $Z'_0 = X_{i+1}$, $Z'_{d_i} = Y_{i+1}$, 我们已经证明了 $E[d_{i+1} - d_i | d_i = 1] \leq 0$, 故可以得到

$$E[\Delta(Z'_{i-1}, Z'_i)] \leq 1;$$

即因为两个状态 Z_{i-1} 和 Z_i 恰有一个顶点的不同, 所以经一步后它们之间不同的顶点的期望数至多为 1. 利用集合的三角不等式

$$|A - B| \leq |A - C| + |C - B|,$$

我们得到

$$|X_{i+1} - Y_{i+1}| + |Y_{i+1} - X_{i+1}| \leq \sum_{i=1}^{d_i} (|Z'_{i-1} - Z'_i| + |Z'_i - Z'_{i-1}|)$$

或

$$d_{i+1} = |X_{i+1} - Y_{i+1}| + |Y_{i+1} - X_{i+1}| \leq \sum_{i=1}^{d_i} \Delta(Z'_{i-1}, Z'_i).$$

因此

$$\begin{aligned} E[d_{i+1} | d_i] &\leq E\left[\sum_{i=1}^{d_i} \Delta(Z'_{i-1}, Z'_i)\right] \\ &= \sum_{i=1}^{d_i} E[\Delta(Z'_{i-1}, Z'_i)] \\ &\leq d_i. \end{aligned}$$



在前面的例子中，可以证明形如

$$E[d_{t+1} | d_t] \leq \beta d_t,$$

的严格的不等式，其中 $\beta < 1$ ，我们利用这个严格的不等式给出混合时间的界。然而对快速混合，只需一个更弱的条件 $E[d_{t+1} | d_t] \leq d_t$ ，如将在练习 11.7 中所看到的。所以当最大次至多为 4 时，马尔可夫链给出了图中独立集合的 FPAUS。如在 10.3 节已经证明的那样，这可以用于得到这个问题的 FPARS。

练习

- 11.1 编写一个程序，以两个正整数 n_1, n_2 及两个实数 p_1, p_2 ($0 \leq p_1, p_2 \leq 1$) 作为输入，程序的输出应该是二项随机变量 $B(n_1, p_1)$ 和 $B(n_2, p_2)$ 之间的变异距离，舍入到千分之一。利用程序计算以下几对分布之间的变异距离： $B(20, 0.5)$ ； $B(20, 0.49)$ ； $B(20, 0.5)$ ； $B(21, 0.5)$ ； $B(21, 0.5)$ 与 $B(21, 0.49)$ 。
- 11.2 考虑洗牌的马尔可夫链，其中每一步都是均匀随机地选取一张牌，并将它放在最上面。假设现在不是运行这个链固定的步数，而是直到使每张牌至少有一次被移到最上面的第一步才停止。证明在这个停止时刻，链的状态是关于牌的 $n!$ 种可能排列上的均匀分布。
- 11.3 考虑洗牌的马尔可夫链，其中每一步都是均匀随机地选取一张牌，并将它放在最上面。证明对某个常数 $\varepsilon > 0$ ，如果链只运行 $(1 - \varepsilon)n \ln n$ 步，那么变异距离为 $1 - o(1)$ 。
- 11.4 (a) 考虑由转移矩阵

$$P = \begin{bmatrix} 1/2 & 0 & 1/2 & 0 & 0 \\ 0 & 1/2 & 1/2 & 0 & 0 \\ 1/4 & 1/4 & 0 & 1/4 & 1/4 \\ 0 & 0 & 1/2 & 1/2 & 0 \\ 0 & 0 & 1/2 & 0 & 1/2 \end{bmatrix}$$

给出的马尔可夫链，说明为什么当直接用于 P 时，定理 11.5 没有用。然后将定理 11.5 用于转移矩阵为 P^2 的马尔可夫链，并说明原马尔可夫链收敛于它的平稳分布的含义。

- (b) 考虑由转移矩阵

$$P = \begin{bmatrix} 1/2 & 0 & 1/2 & 0 & 0 \\ 0 & 1/2 & 1/2 & 0 & 0 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 0 & 0 & 1/2 & 1/2 & 0 \\ 0 & 0 & 1/2 & 0 & 1/2 \end{bmatrix}$$

给出的马尔可夫链，将定理 11.5 用于 P ，然后将定理 11.5 用于转移矩阵为 P^2 的马尔可夫链，说明原马尔可夫链收敛于它的平稳分布的含义。哪种应用给出变异距离更好的界？

- 11.5 假设反复投掷一粒标准的六面体骰子, 得到一个独立的随机变量序列 X_1, X_2, \dots , 其中 X_i 是第 i 次投掷的结果. 设

$$Y_j = \sum_{i=1}^j X_i \bmod 10$$

是前 j 次投掷之和关于模 10 的同余. 序列 Y_j 形成一个马尔可夫链. 确定它的平稳分布, 并确定这个链关于 $\tau(\varepsilon)$ 的界. (提示: 一种途径是利用练习 11.4 的方法.)

[290]

- 11.6 定理 11.5 只在马尔可夫链的转移矩阵 P 中至少有一列存在一个非零元素时有用. 证明对任一有限、非周期、不可约的马尔可夫链, 存在一个时刻 T , 使得 P^T 的每个元素都非零. 说明如何将它同定理 11.5 一起使用.
- 11.7 在这一章反复使用的一种方法是定义一个距离函数 d_t , 表示经 t 步后耦合的两个状态之间的距离, 然后证明当 $d_t > 0$ 时, 存在 $\beta < 1$, 使得

$$E[d_{t+1} | d_t] \leq \beta d_t.$$

(a) 在这个条件下, 给出用 β 和 d^* 表示的 $\tau(\varepsilon)$ 的上界, 其中 d^* 是耦合的所有可能初始状态对的最大距离.

(b) 假定

$$E[d_{t+1} | d_t] \leq d_t.$$

假定有附加条件: d_{t+1} 是 $d_t, d_t - 1$ 或 $d_t + 1$ 之一, 且 $\Pr(d_t \neq d_{t+1}) \geq \gamma$. 给出用 ε, d^* 及 γ 表示的 $\tau(\varepsilon)$ 的上界. 你的答案应该是关于 d^* 及 $1/\gamma$ 的多项式 (提示: 将 d_t 看作类似于直线上的随机游动).

(c) 利用 (a) 和 (b), 证明 11.5 节着色链的混合时间即使在颜色种数只为 2Δ 时, 也是图中顶点数及 $\ln(1/\varepsilon)$ 的多项式.

(d) 推广 (b) 中的论证, 证明 11.6 节给出的独立集合的马尔可夫链上的混合时间是图中顶点个数及 $\ln(1/\varepsilon)$ 的多项式.

- 11.8 考虑 n 个顶点的非二部连通图上的随机游动, 其中每个顶点有相同的次 $d > n/2$. 证明

$$\tau(\varepsilon) \leq \frac{\ln \varepsilon}{\ln(1 - (2d - n)/d)}.$$

- 11.9 考虑在圆上依次放置的 n 个点 $[0, n-1]$ 的马尔可夫链. 每一步, 链以 $1/2$ 的概率停留在当前点, 或以 $1/2$ 的概率依顺时针方向移动到下一点. 求平稳分布, 并证明对任意 $\varepsilon > 0$, 混合时间 $\tau(\varepsilon)$ 为 $O(n^2 \ln(1/\varepsilon))$.

- 11.10 在 11.2.3 节, 我们提出了下面的耦合 $Z_t = (X_t, Y_t)$. 首先为链 X_t 以及 $v \in X_t, w \in V$ 选取一个转移, 如果 $v \in Y_t$, 对链 Y_t 的转移用相同的顶点 v 和 w ; 否则, 均匀随机地选取一个顶点 $v' \in Y_t - X_t$, 然后在链 Y_t 中用 v' 和 w 执行转移. 证明这是满足定义 11.3 的有效耦合.

- 11.11 如 11.2.3 节定义的一个有 n 个节点、最大次为 Δ 的图中, 对大小恰好为 $k \leq n/3(\Delta + 1)$ 的所有独立集合抽样的马尔可夫链, 证明这个链是遍历的, 且有一个均匀的平稳分布.

[291]

- 11.12 我们希望改进 11.2.3 节的耦合技术以得到一个更好的界. 这里的改进与用于证明定理 11.8 的方法有关. 如 11.2.3 节的耦合, 如果试图使 $v \in X_i - Y_i$ 移动到顶点 w , 那么在另一个链用匹配的顶点作相同的移动, 但如果试图移动在两个链中的顶点 $v \in X_i \cap Y_i$, 我们不再作相同的移动.

(a) 假定存在一个恰有 $d_i(\Delta + 1)$ 个不同顶点的集合 S_1 , 这些顶点是 $X_i - Y_i$ 中的顶点或顶点的邻点. 类似地, 假定存在一个恰有 $d_i(\Delta + 1)$ 个不同顶点的集合 S_2 , 这些顶点是 $Y_i - X_i$ 中的顶点或顶点的邻点; 进一步假定 S_2 与 S_1 不相交. 还假定 S_1 中的顶点以一对一的方式与 S_2 中的顶点匹配. 证明这样的移动可以耦合, 使得当一个链试图但不能将 v 移动到一个链的 S_1 中的顶点时, 它也试图但不能将 v 移动到另一链的 S_2 中匹配的顶点. 类似地, 证明移动可以耦合, 使得当一个链试图且成功地 将 v 移动到一个链的 S_1 中的顶点时, 它也试图且成功地将 v 移动到另一个链的 S_2 中匹配的顶点. 证明这个耦合给出

$$\Pr(d_{i+1} = d_i + 1) \leq \frac{k - d_i d_i(\Delta + 1)}{k n}$$

(b) 一般情况下, S_2 和 S_1 不必不相交或大小相等. 证明此时通过将失败的移动尽可能多地配对, 可以增加 d_i 的 w 的选择个数为 $\max(|S_1|, |S_2|) \leq d_i(\Delta + 1)$. 然后证明

$$\Pr(d_{i+1} = d_i + 1) \leq \frac{k - d_i d_i(\Delta + 1)}{k n}$$

对所有情况都成立.

(c) 利用这个耦合得到对任意 $k \leq n/2(\Delta + 1)$ 都成立的 $\tau(\varepsilon)$ 的一个多项式界.

- 11.13 对状态空间为 S 的马尔可夫链, t 为任意的非负整数, 设

$$\bar{\Delta}(t) = \max_{s, r \in S} \|p'_s - p'_r\|.$$

还假定马尔可夫链有一个平稳分布.

(a) 证明对任意正整数 s 和 t , $\bar{\Delta}(s+t) \leq \bar{\Delta}(s)\bar{\Delta}(t)$.

(b) 证明对任意正整数 s 和 t , $\Delta(s+t) \leq \Delta(s)\Delta(t)$.

(c) 证明对任意正整数 t ,

$$\Delta(t) \leq \bar{\Delta}(t) \leq 2\Delta(t).$$

- 11.14 考虑一副 n 张扑克牌洗牌问题的下列变化. 每一步从这副牌中均匀随机地选取两张牌, 然后交换它们的位置. (有可能两次取牌得到同一张牌, 此时出现不交换的情况.)

(a) 证明以下是一个等价的过程: 每一步从这副牌中均匀随机地选取一张牌, 且从 $[1, n]$ 均匀随机地选取一个位置, 然后将位置 i 上的牌与取到的那张牌交换位置.

(b) 考虑对牌和位置的两种选取对链的两个副本来说是同时的耦合. 用 X_i 表示在链

的两个副本中具有不同位置的牌的张数. 证明 X_i 关于时间是非增的.

(c) 证明

$$\Pr(X_{i+1} \leq X_i - 1 | X_i > 0) \geq \left(\frac{X_i}{n}\right)^2.$$

(d) 不管两个链的初始状态, 证明直到 X_i 为 0 的期望时间是 $O(n^2)$.

11.15 修改引理 10.3 及引理 10.4 的论证来证明, 如果对任意 $c \geq \Delta + 2$, 有一个正常着色法的 FPAUS, 那么对这个 c 值, 也有一个 FPRAS.

11.16 考虑下列简单的马尔可夫链, 其状态是图 $G = (V, E)$ 中的独立集合. 由 X_i 计算 X_{i+1} :

- 从 V 中均匀随机地选取一个顶点 v , 并投掷一枚均匀的硬币.
- 如果正面朝上且 $v \in X_i$, 那么 $X_{i+1} = X_i \setminus \{v\}$.
- 如果正面朝上且 $v \notin X_i$, 那么 $X_{i+1} = X_i$.
- 如果反面朝上, $v \notin X_i$, 且将 v 添入 X_i 仍然给出一个独立集合, 那么 $X_{i+1} = X_i \cup \{v\}$.
- 如果反面朝上且 $v \in X_i$, 那么 $X_{i+1} = X_i$.

(a) 证明这个链的平稳分布是所有独立集合上的均匀分布.

(b) 我们特别地在圆形图和直线图上考虑这个马尔可夫链. 对有 n 个顶点的直线图, 顶点标以 1 到 n 的标号, 存在从 1 到 2, 2 到 3, \dots , $n-1$ 到 n 的一条边. 对 n 个顶点的圆形图也一样, 但增加一条从 n 到 1 的边.

对这个马尔可夫链, 设计一个直线图和圆形图的耦合 (X_i, Y_i) , 如果 $d_i = |X_i - Y_i| + |Y_i - X_i|$ 是两个独立集合不一致的顶点个数, 那么在每一步耦合至少增加 d_i , 那样尽可能地减小 d_i .

(c) 用 (b) 中的耦合, 证明可以用这个链得到圆形图或直线图上独立集合的一个 FPAUS. 可能要练习 11.7.

(d) 对直线图及圆形图的特殊情况, 可以导出独立集合个数的精确公式. 导出这些情况下的精确公式, 且证明该公式是正确的 (提示: 可以将结果表示成斐波那契数).

293

11.17 对整数 a, b , 一个 $a \times b$ 网格是一个图, 其顶点是所有有序的整数对 (x, y) , 其中 $0 \leq x < a, 0 \leq y < b$. 图的边连接所有不同的顶点 (x, y) 和 (x', y') , 使得 $|x - x'| + |y - y'| = 1$. 即每个顶点与它的上、下、左、右的邻点相连接, 其中在边界上的顶点只与有关的点连接. 考虑由 10×10 网格给出的图上的下列问题.

- (a) 执行一个 FPAUS 以产生一个图的 ϵ -均匀的正规 10 着色法, 其中 ϵ 是作为输入给出的. 讨论该马尔可夫链运行多少步, 其初始状态是什么, 以及其他有关的细节.
- (b) 将 FPAUS 作为一个子程序, 执行 FPRAS 产生图的正规 10 着色法个数的 (ϵ, δ) 近似. 运行它得到 $(0.1, 0.001)$ 近似以检验程序代码. (注意: 这可能需要相当长的运行时间.) 讨论对边的选择次序, 每步要求多少个样本, 在整个过程中执行马尔可夫链多少步, 以及其他有关细节.

- 11.18 在 11.2.3 节中考虑过独立集合上的下列马尔可夫链：一次移动是由独立集合 X_i 经均匀随机地选取一个顶点 $v \in X_i$ ，且从图中均匀随机地挑出一个顶点 w 形成的。如果 $X_i - |v| + |w|$ 是独立集合，那么 $X_{i+1} = X_i - |v| + |w|$ ；否则， $X_{i+1} = X_i$ 。我们已经证明了当 $k \leq n/2(\Delta + 1)$ 时，通过关于 n 和 $\ln(1/\epsilon)$ 的多项式表示 $\tau(\epsilon)$ 的界，这个链快速收敛于它的平稳分布。利用路径耦合思路简化这个证明。
- 11.19 我们在 11.5 节考虑过着色问题的简单的马尔可夫链。假定可以用路径耦合技术。（不必去证明这一点。）在这种情况下，可以只考虑 $d_i = 1$ 的情况。当 $d_i = 1$ 且 $c > 2\Delta$ 时，对某个 $\beta < 1$ ， $E[d_{i+1} | d_i] \leq \beta d_i$ ，给出一个比较简单的证明。并证明当 $d_i = 1$ ， $c = 2\Delta$ 时， $E[d_{i+1} | d_i] \leq d_i$ 。



第12章 鞅

鞅是满足某些条件的随机变量序列, 这些条件产生于诸如随机游动和赌博问题等众多应用中. 本章重点介绍三种有用的与鞅有关的分析工具: 鞅停止定理、瓦尔德不等式和 Azuma-Hoeffding 不等式. 鞅停止定理和瓦尔德方程是计算复合随机过程期望的重要工具. 在导出与相关随机变量的函数值的切尔诺夫型尾部界时, Azuma-Hoeffding 不等式是非常有效的方法. 本章主要讨论 Azuma-Hoeffding 不等式在模式匹配、球和箱子、随机图等问题中的应用.

12.1 鞅

定义 12.1 随机变量序列 Z_0, Z_1, \dots 是关于序列 X_0, X_1, \dots 的一个鞅, 如果对所有的 $n \geq 0$, 满足以下条件:

- Z_n 是 X_0, X_1, \dots, X_n 的函数.
- $E[|Z_n|] < \infty$.
- $E[Z_{n+1} | X_0, \dots, X_n] = Z_n$.

随机变量序列 Z_0, Z_1, \dots 称为一个鞅, 当它是关于自身的一个鞅. 即 $E[|Z_n|] < \infty$, 且 $E[Z_{n+1} | Z_0, \dots, Z_n] = Z_n$.

鞅可以含有有限个或可数无穷个元素. 鞅序列的指标不必从 0 开始, 实际上, 在许多应用中, 从 1 开始更加方便. 当我们说 Z_0, Z_1, \dots 是关于 X_1, X_2, \dots 的鞅时, 可以认为 X_0 是一个可被忽略的常数.

例如, 考虑一个赌徒参加一系列公平的赌博. 令 X_i 为赌徒在第 i 次赌博赢得的钱数 (若赌徒输了, 则 X_i 是负的), Z_i 为他在第 i 次赌博结束时总的赢利. 因为每次赌博都是公平的, 故 $E[X_i] = 0$, 且

$$E[Z_{i+1} | X_1, X_2, \dots, X_i] = Z_i + E[X_{i+1}] = Z_i.$$

从而, Z_1, Z_2, \dots, Z_n 是一个关于序列 X_1, X_2, \dots, X_n 的鞅. 有意思的是, 不管每次赌博的赌注是多少, 即使这些赌注是依赖于前面结果的, 这个序列都是一个鞅.

杜布鞅是利用以下一般方法构造的鞅. 设 X_0, X_1, \dots, X_n 为一个随机变量序列, Y 是随机变量, 满足 $E[|Y|] < \infty$. (一般地, Y 将依赖于 X_0, \dots, X_n .) 那么

$$Z_i = E[Y | X_0, \dots, X_i], \quad i = 0, 1, \dots, n,$$

它是一个关于 X_0, X_1, \dots, X_n 的鞅, 因为

$$\begin{aligned} E[Z_{i+1} | X_0, \dots, X_i] &= E[E[Y | X_0, \dots, X_{i+1}] | X_0, \dots, X_i] \\ &= E[Y | X_0, \dots, X_i] \\ &= Z_i. \end{aligned}$$

这里用到了 $E[Y | X_0, \dots, X_{i+1}]$ 自身是随机变量的事实, 且由条件期望的定义 2.7 可得

$$E[V | W] = E[E[V | U, W] | W].$$



在大多数应用中, 我们是从满足 $Z_0 = E[Y]$ 的杜布鞅开始的, 这对应于 X_0 是一个与 Y 独立的平凡的随机变量. 为理解杜布鞅的概念, 假设希望预测随机变量 Y 的值, 而 Y 的值是随机变量 X_1, \dots, X_n 的值的函数. 序列 Z_0, Z_1, \dots, Z_n 表示一个逐渐利用越来越多有关随机变量 X_1, X_2, \dots, X_n 的的信息得到的 Y 值的精细估计的序列. 第一个元素 Z_0 正是 Y 的期望. 元素 Z_i 是已知 X_1, \dots, X_i 的值时 Y 的期望值, 而且如果 Y 完全由 X_1, \dots, X_n 确定, 那么 $Z_n = Y$.

现在考虑杜布鞅的两个例子, 它们产生于对随机图性质的评估. 设 G 是来自 $G_{n,p}$ 的随机图, 以某个任意的次序标出 $m = \binom{n}{2}$ 条可能边的位置, 且令

$$X_j = \begin{cases} 1 & \text{如果第 } j \text{ 边位置上存在一条边,} \\ 0 & \text{其他情况.} \end{cases}$$

考虑定义在图上的任意有限值函数 F , 例如, 设 $F(G)$ 是 G 中最大独立集的大小. 现在令 $Z_0 = E[F(G)]$ 及

$$Z_i = E[F(G) | X_1, \dots, X_i], \quad i = 1, \dots, m.$$

序列 Z_0, Z_1, \dots, Z_m 是表示 $F(G)$ 的条件期望的杜布鞅, 每次一条边地逐渐揭示了每条边是否在图中. 这种揭示边的过程给出的一个鞅通常称为边暴露鞅.

类似地, 代替每次揭示一条边, 可以每次一个顶点地揭示与一个给定顶点相连的边的集合. 固定任意一个从 1 到 n 的顶点的编号, 设 G_i 是由前 i 个顶点导出的 G 的子图, 那么令 $Z_0 = E[F(G)]$ 及

$$Z_i = E[F(G) | G_1, \dots, G_i], \quad i = 1, \dots, n,$$

给出了一个通常称为顶点暴露鞅的杜布鞅.

12.2 停时

回到参加了一系列公平赌博的那个赌徒, 在上节我们看到 Z_1, Z_2, \dots 是一个鞅, 其中 Z_i 表示赌徒在第 i 次赌博后的赢利. 如果赌徒(在开始游戏前)决定在赌完恰好 k 次后离去, 那么赌徒的期望获利是多少?

引理 12.1 如果序列 Z_0, Z_1, \dots, Z_n 是关于 X_0, X_1, \dots, X_n 的鞅, 那么有

$$E[Z_n] = E[Z_0].$$

证明 因为 Z_0, Z_1, \dots, Z_n 是关于 X_0, X_1, \dots, X_n 的鞅, 所以有

$$Z_i = E[Z_{i+1} | X_0, \dots, X_i].$$

两边求期望且利用条件期望的定义, 我们有

$$E[Z_i] = E[E[Z_{i+1} | X_0, \dots, X_i]] = E[Z_{i+1}].$$

重复这个论证, 得到

$$E[Z_n] = E[Z_0].$$

这样, 如果游戏次数在开始时是固定的, 那么从这些次赌博中获利的期望为零. 现在假设赌博次数不固定, 比如赌徒可以选择进行随机次数的赌博. 当赌徒的停止赌博决策是基于已经

进行过的赌博结果时,会出现一种更加复杂(而且现实)的情况.比如,赌徒可能决定一直玩到他的赢钱总数至少为一百美元.下面的概念是相当有用的.

定义 12.2 称非负整值随机变量 T 是序列 $\{Z_n, n \geq 0\}$ 的停时,如果事件 $T = n$ 只依赖于随机变量 Z_0, Z_1, \dots, Z_n 的值.

一个停时对应于只基于到目前为止的结果决定何时停止序列的一种策略.例如,赌徒首次连续赢得五次赌博是一个停时,因为这可由已进行过的赌博结果而定.类似地,赌徒首次赢得至少一百元也可以是一个停时.令 T 为赌徒连续赢得五次赌博的最后时间,但这不是一个停时,因为若不知道 Z_{n+1}, Z_{n+2}, \dots 就不可能决定是否有 $T = n$.

为了充分利用鞅的性质,我们需要刻画关于保持性质 $E[Z_T] = E[Z_0] = 0$ 的停时 T 的条件.就好像是如果赌博是公平的,总有 $E[Z_T] = 0$ 成立.但是考虑赌徒的停时是使 $Z_T > B$ 的第一个 T 的情况,其中 B 是一个大于 0 的固定常数.在这种情况下,赌徒退出赌博时的期望收益是大于 0 的.具有这种停时的微妙问题在于停时可能不是有限的,因此赌徒可能永远也不能结束赌博.鞅停止定理表明,在一定条件下,特别是在停时是有界的或具有有界的期望,则鞅在停时的期望值等于 $E[Z_0]$.在此我们描述某种形式的鞅停止定理(有时称为最优停止定理)而不证明.

定理 12.2 [鞅停止定理] 如果 Z_0, Z_1, \dots 是关于 X_1, X_2, \dots 的鞅, T 是 X_1, X_2, \dots 的停时,那么有

$$E[Z_T] = E[Z_0],$$

只要满足以下条件之一:

- Z_i 有界, 所以存在一个常数 c , 使得对任意 i 有 $|Z_i| \leq c$;
- T 是有界的;
- $E[T] < \infty$, 而且存在一个常数 c , 使得 $E[|Z_{i+1} - Z_i| | X_1, \dots, X_i] < c$.

我们利用鞅停止定理导出 7.2.1 节介绍的赌徒破产问题的一个简单的解.考虑一系列独立的公平赌博,在每一轮赌徒以 1/2 的概率赢得 1 元,或者以 1/2 的概率输掉 1 元.令 $Z_0 = 0$, X_i 表示第 i 次赌博赢的钱数, Z_i 为第 i 次赌博后总的赢钱数.(同样,如果赌徒输了钱,那么 X_i 和 Z_i 是负的.)假设当赌徒输掉 ℓ_1 元或赢得 ℓ_2 元时就退出赌博.那么在输掉 ℓ_1 元之前,赌徒赢得 ℓ_2 元的概率是多少?

设 T 为首次赢得 ℓ_2 元或输掉 ℓ_1 元的时间,那么 T 是 X_1, X_2, \dots 的停时.序列 Z_0, Z_1, \dots 是一个鞅,因为 Z_i 的值显然有界,我们可以应用鞅停止定理.因此,有

$$E[Z_T] = 0.$$

设 q 为赌徒在赢得 ℓ_2 元后退出赌博的概率,那么由

$$E[Z_T] = \ell_2 q - \ell_1 (1 - q) = 0$$

得到

$$q = \frac{\ell_1}{\ell_1 + \ell_2},$$

与 7.2.1 节求得的结果一致.

12.2.1 例：选举定理

下面的选举定理是鞅停止定理的另一个应用. 假定两个候选人参加一次选举, 候选人 A 获得 a 票, 候选人 B 获得 $b (< a)$ 票. 计票顺序是随机的, 是从 $a + b$ 张选票的所有排列中均匀随机选择的. 我们证明候选人 A 在计票中始终领先的概率为 $(a - b)/(a + b)$. 虽然这可由组合法确定, 但我们用鞅给出一个漂亮的论证.

令 $n = a + b$ 为总选票数, S_k 为在计了 k 张选票之后, 候选人 A 领先的选票数 (S_k 可以为负), 那么 $S_n = a - b$. 对 $0 \leq k \leq n - 1$, 定义

$$X_k = \frac{S_{n-k}}{n-k}.$$

首先证明序列 X_0, X_1, \dots, X_{n-1} 构成一个鞅. 注意到序列 X_0, X_1, \dots, X_n 与倒序的计数过程有关, X_0 是 S_n 的函数, X_{k-1} 是 S_1 的函数, 等等. 考虑

$$E[X_k | X_0, \dots, X_{k-1}].$$

关于 X_0, \dots, X_{k-1} 的条件等价于关于 $S_n, S_{n-1}, \dots, S_{n-k+1}$ 的条件, 依次等价于计票到最后 $k - 1$ 张选票时计数值的条件.

在条件 S_{n-k+1} 下, 计票前 $n - k + 1$ 张票后, 候选人 A 获得的票数是

$$\frac{n - k + 1 + S_{n-k+1}}{2},$$

候选人 B 获得的票数是

$$\frac{n - k + 1 - S_{n-k+1}}{2}.$$

计票中的第 $(n - k + 1)$ 张选票是来自这前 $n - k + 1$ 张票中的一张随机选票. 如果第 $(n - k + 1)$ 张选票是给候选人 B 的, 则 S_{n-k} 等于 $S_{n-k+1} + 1$; 如果那张选票是给候选人 A 的, 则 S_{n-k} 等于 $S_{n-k+1} - 1$. 这样, 对 $k \geq 1$,

$$\begin{aligned} E[S_{n-k} | S_{n-k+1}] &= (S_{n-k+1} + 1) \frac{n - k + 1 - S_{n-k+1}}{2(n - k + 1)} + (S_{n-k+1} - 1) \frac{n - k + 1 + S_{n-k+1}}{2(n - k + 1)} \\ &= S_{n-k+1} \frac{n - k}{n - k + 1}. \end{aligned}$$

因此,

$$\begin{aligned} E[X_k | X_0, \dots, X_{k-1}] &= E\left[\frac{S_{n-k}}{n-k} \mid S_n, \dots, S_{n-k+1}\right] \\ &= \frac{S_{n-k+1}}{n - k + 1} \\ &= X_{k-1}, \end{aligned}$$

证明了序列 X_0, X_1, \dots, X_{n-1} 是一个鞅.

定义 T 是使 $X_k = 0$ 的最小的 k , 如果这样的 k 存在, 否则 $T = n - 1$. 那么 T 是一个有界的停时, 满足鞅停止定理的要求, 且

$$E[X_T] = E[X_0] = \frac{E[S_n]}{n} = \frac{a-b}{a+b}.$$

现在考虑两种情况:

情况 1 在整个计票过程中候选人 A 始终领先. 在这种情况下, 对 $0 \leq k \leq n-1$, 所有 S_{n-k} (因此所有的 X_k) 都是正数, $T=n-1$, 且

$$X_T = X_{n-1} = S_1 = 1.$$

即 $S_1=1$ 成立, 因为候选人 A 在计票过程中必须获得第一张选票, 才能在整个计票过程中始终领先.

情况 2 候选人 A 在计票过程中不是始终领先. 在这种情况下, 我们断言, 对某个 $k < n-1$, 有 $X_k=0$. 候选人 A 最后显然获得更多选票. 如果候选人 B 处于领先, 那么一定有某个中间点 k , 使 S_k (因此 X_k) 等于 0. 此时, $T=k < n-1$ 且 $X_T=0$.

显然有

$$E[X_T] = \frac{a-b}{a+b} = 1 \cdot \Pr(\text{情况 1}) + 0 \cdot \Pr(\text{情况 2}),$$

这样情况 1, 即候选人在计票过程中始终领先的概率为 $(a-b)/(a+b)$.

12.3 瓦尔德方程

鞅停止定理的一个重要推论是著名的瓦尔德方程. 瓦尔德方程处理独立随机变量和的期望, 其中求和的随机变量的个数本身是一个随机变量.

定理 12.3 [瓦尔德方程] 设 X_1, X_2, \dots 是非负、独立且与 X 的分布有相同分布的随机变量, T 是这个序列的一个停时. 如果 T 和 X 存在有界的期望, 那么

$$E\left[\sum_{i=1}^T X_i\right] = E[T] \cdot E[X].$$

事实上, 瓦尔德方程在更一般的情况下也成立. 当不要求随机变量 X_1, X_2, \dots 是非负时, 有多种不同方法证明等式也是成立的.

证明 对 $i \geq 1$, 设

$$Z_i = \sum_{j=1}^i (X_j - E[X]).$$

[300] 序列 Z_1, Z_2, \dots 是关于 X_1, X_2, \dots 的鞅, 且 $E[Z_i] = 0$.

现在 $E[T] < \infty$, 且

$$E[|Z_{i+1} - Z_i| | X_1, \dots, X_i] = E[|X_{i+1} - E[X]|] \leq 2E[X].$$

因此可以利用鞅停止定理计算

$$E[Z_T] = E[Z_1] = 0.$$

现在得到

$$E[Z_T] = E\left[\sum_{j=1}^T (X_j - E[X])\right]$$



$$\begin{aligned}
 &= E \left[\left(\sum_{j=1}^T X_j \right) - TE[X] \right] \\
 &= E \left[\sum_{j=1}^T X_j \right] - E[T] \cdot E[X] \\
 &= 0,
 \end{aligned}$$

这给出结果. ■

在独立随机变量序列的情况下, 我们有一个等价的、更简单的便于应用的停时定义.

定义 12.3 设 Z_0, Z_1, \dots, Z_n 为独立的随机变量序列, 一个非负的整值随机变量 T 是这个序列的一个停时, 如果事件 $T=n$ 与 Z_{n+1}, Z_{n+2}, \dots 独立.

举一个简单例子, 考虑一种赌徒首先掷一粒标准骰子的赌博. 如果掷的结果是 X , 那么接着再掷 X 粒新的标准骰子, 她的获利 Z 是 X 粒骰子的和. 这种赌博获利的期望是多少?

对 $1 \leq i \leq X$, 设 Y_i 为第二轮中第 i 粒骰子的点数, 那么

$$E[Z] = E \left[\sum_{i=1}^X Y_i \right].$$

由定义 12.3 知 X 是一个停时, 因此由瓦尔德方程可得

$$E[Z] = E[X] \cdot E[Y_i] = \left(\frac{7}{2} \right)^2 = \frac{49}{4}.$$

瓦尔德方程可以由 Las Vegas 算法的分析而得, 如我们看到的在 3.4 节描述的求中位数的随机化算法, 这个算法总是给出正确答案, 但是有可变的运行时间. 在 Las Vegas 算法中, 我们常常反复执行某个可能返回或可能不返回正确答案的随机化子程序. 然后用某个确定性的检查子程序来确定答案是否正确. 如果正确, 那么 Las Vegas 算法以正确答案结束; 否则, 再次运行随机化子程序. 如果 N 是直到找到正确答案的试验次数, X_i 是第 i 次试验中两个子程序的运行时间——只要 X_i 是独立且与 X 相同的分布——瓦尔德方程给出此算法的期望运行时间为

$$E \left[\sum_{i=1}^N X_i \right] = E[N] \cdot E[X].$$

这种方法的一个例子在练习 12.12 中给出.

作为另一个例子, 考虑通过一个共享通道联结的 n 个服务器的集合. 时间被分成离散的时间段, 在每一时间段, 任一个需要发送数据包的服务器可以由通道进行传送. 如果在那个时间恰好只有一个数据包发送, 那么传送就会成功完成. 如果有多于一个数据包发送, 那么没有一个会成功 (并且发送者会发现失败). 数据包保存在服务器的缓冲器中, 直到它们被成功传送. 服务器服从以下简单协议: 在每一时间段, 如果服务器的缓冲器不是空的, 那么它就以 $1/n$ 的概率试图发送缓冲器中的第一个数据包. 假设服务器的缓冲器中有一个数据包的无穷序列. 那么直到每个服务器都至少成功发送一个数据包所用的时间段的期望个数是多少?

设 N 是直到每个服务器都至少成功发送一个数据包时成功发送的数据包个数, t_i 为第 i 个成功发送的数据包的时段, 从 $t_0 = 0$ 开始, 且设 $r_i = t_i - t_{i-1}$. 那么直到每个服务器都至少成功发送一个数据包的时段个数 T 由下式给出:

$$T = \sum_{i=1}^N r_i.$$

可以验证 N 和 r_i 是独立的, 且 N 的期望是有界的; 从而 N 是序列 $\{r_i\}$ 的停时.

在一个给定的时间段中成功发送一个数据包的概率为

$$p = \binom{n}{1} \left(\frac{1}{n}\right) \left(1 - \frac{1}{n}\right)^{n-1} \approx e^{-1}.$$

每个 r_i 都服从参数为 p 的几何分布, 因此 $E[r_i] = 1/p \approx e$.

已知一个数据包在给定的时间段中成功发送, 那个数据包的发送者在 n 个服务器中均匀分布, 且与以前的过程无关. 利用第 2 章对赠券收集问题期望的分析, 我们得到 $E[N] = nH(n) = n \ln n + O(n)$. 现在用瓦尔德方程计算

$$\begin{aligned} E[T] &= E\left[\sum_{i=1}^N r_i\right] \\ &= E[N] \cdot E[r_i] \\ &= \frac{nH(n)}{p}, \end{aligned}$$

它约为 $en \ln n$.

12.4 鞅的尾部不等式

算法分析中鞅的最有用的性质也许是可以用切尔诺夫型的尾部不等式, 即使在随机变量不是独立的情况下. 这个领域中的主要结果是 Azuma 不等式和 Hoeffding 不等式. 它们十分相似, 因此它们常常被合在一起而称为 Azuma-Hoeffding 不等式.

定理 12.4 [Azuma-Hoeffding 不等式] 设 X_0, \dots, X_n 是一个鞅, 满足

$$|X_i - X_{i-1}| \leq c_i.$$

那么对所有 $t \geq 0$ 和任意 $\lambda > 0$, 有

$$\Pr(|X_t - X_0| \geq \lambda) \leq 2e^{-\lambda^2 / \left(2 \sum_{i=1}^t c_i^2\right)}.$$

证明 证明按照与切尔诺夫界(4.2节)相同的形式进行. 首先导出 $E[e^{\alpha(X_t - X_0)}]$ 的上界. 为此, 定义

$$Y_i = X_i - X_{i-1}, \quad i = 1, \dots, t.$$

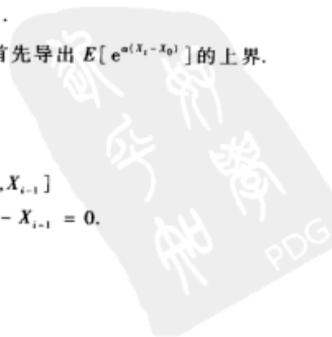
注意到 $|Y_i| \leq c_i$, 且因为 X_0, X_1, \dots 是一个鞅, 所以

$$\begin{aligned} E[Y_i | X_0, X_1, \dots, X_{i-1}] &= E[X_i - X_{i-1} | X_0, X_1, \dots, X_{i-1}] \\ &= E[X_i | X_0, X_1, \dots, X_{i-1}] - X_{i-1} = 0. \end{aligned}$$

现在考虑

$$E[e^{\alpha Y_i} | X_0, X_1, \dots, X_{i-1}].$$

记



$$Y_i = -c_i \frac{1 - Y_i/c_i}{2} + c_i \frac{1 + Y_i/c_i}{2}.$$

由 e^{ax} 的凸性, 有

$$\begin{aligned} e^{aY_i} &\leq \frac{1 - Y_i/c_i}{2} e^{-ac_i} + \frac{1 + Y_i/c_i}{2} e^{ac_i} \\ &= \frac{e^{ac_i} + e^{-ac_i}}{2} + \frac{Y_i}{2c_i} (e^{ac_i} - e^{-ac_i}). \end{aligned}$$

因为 $E[Y_i | X_0, X_1, \dots, X_{i-1}] = 0$, 我们有

$$\begin{aligned} E[e^{aY_i} | X_0, X_1, \dots, X_{i-1}] &\leq E\left[\frac{e^{ac_i} + e^{-ac_i}}{2} + \frac{Y_i}{2c_i} (e^{ac_i} - e^{-ac_i}) \mid X_0, X_1, \dots, X_{i-1}\right] \\ &= \frac{e^{ac_i} + e^{-ac_i}}{2} \\ &\leq e^{(ac_i)^2/2}. \end{aligned}$$

这里利用与证明定理 4.7 相似的方法, 为了得到

$$\frac{e^{ac_i} + e^{-ac_i}}{2} \leq e^{(ac_i)^2/2},$$

我们利用了 e^x 的泰勒级数展开式, 由此,

$$\begin{aligned} E[e^{a(X_i - X_0)}] &= E\left[\prod_{i=1}^{i-1} e^{aY_i}\right] \\ &= E\left[\prod_{i=1}^{i-2} e^{aY_i}\right] E[e^{aY_{i-1}} | X_0, X_1, \dots, X_{i-2}] \\ &\leq E\left[\prod_{i=1}^{i-2} e^{aY_i}\right] e^{(ac_{i-1})^2/2} \\ &\leq e^{\alpha^2 \sum_{k=1}^i c_k^2/2}. \end{aligned}$$

从而

$$\begin{aligned} \Pr(X_i - X_0 \geq \lambda) &= \Pr(e^{a(X_i - X_0)} \geq e^{a\lambda}) \\ &\leq \frac{E[e^{a(X_i - X_0)}]}{e^{a\lambda}} \\ &\leq e^{\alpha^2 \sum_{k=1}^i c_k^2/2 - a\lambda} \\ &\leq e^{-\lambda^2 / \left(2 \sum_{k=1}^i c_k^2\right)}, \end{aligned}$$

其中最后一个不等式是由选取 $\alpha = \lambda / \sum_{k=1}^i c_k^2$ 而得到的. 类似的证明给出 $\Pr(X_i - X_0 \leq -\lambda)$ 的界, 这通过将每一处的 X_i 都换成 $-X_i$ 即可看出, 从而定理得证. ■

下面的推论常常更便于应用.



推论 12.5 设 X_0, X_1, \dots 是一个鞅, 使得对所有 $k \geq 1$,

$$|X_k - X_{k-1}| \leq c.$$

那么, 对所有 $t \geq 1$ 和 $\lambda > 0$ 有

$$\Pr(|X_t - X_0| \geq \lambda c \sqrt{t}) \leq 2e^{-\lambda^2/2}.$$

现在给出 Azuma-Hoeffding 不等式的更一般的形式, 在我们的应用中可以得到稍紧一些的界.

定理 12.6 [Azuma-Hoeffding 不等式] 设 X_0, \dots, X_n 是一个鞅, 对某些常数 d_k 和某些可能是 X_0, X_1, \dots, X_{k-1} 的函数的随机变量 B_k , 满足

$$B_k \leq X_k - X_{k-1} \leq B_k + d_k,$$

那么, 对所有 $t \geq 0$ 和任意 $\lambda > 0$, 有

$$\Pr(|X_t - X_0| \geq \lambda) \leq 2e^{-2\lambda^2 / \left(\sum_{k=1}^t d_k^2\right)}.$$

这个形式的不等式对 $|X_k - X_{k-1}|$ 的界作了一般化的要求, 关键是 $X_k - X_{k-1}$ 的下界和上界之间的间隙 d_k . 注意当有界 $|X_k - X_{k-1}| \leq c$ 时, 这个结果与定理 12.4 是等价的, 其中 $B_k = -c_k$, 间隙 $d_k = 2c_k$. 这个定理的证明与定理 12.4 的证明类似并留作练习 12.6.

12.5 Azuma-Hoeffding 不等式的应用

12.5.1 一般形式

在给出 Azuma-Hoeffding 不等式的某些应用之前, 先介绍一种有用的技巧. 我们说一个函数

$$f(\bar{X}) = f(X_1, X_2, \dots, X_n)$$

满足界为 c 的利普希茨条件, 如果对任意 i 和值 x_1, \dots, x_n 与 y_i 的任意集合, 有

$$|f(x_1, x_2, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) - f(x_1, x_2, \dots, x_{i-1}, y_i, x_{i+1}, \dots, x_n)| \leq c.$$

就是说, 任何单独一个坐标值的改变可能改变函数值至多为 c .

令

$$Z_0 = E[f(X_1, X_2, \dots, X_n)]$$

及

$$Z_k = E[f(X_1, X_2, \dots, X_n) | X_1, X_2, \dots, X_k].$$

序列 Z_0, Z_1, \dots 是一个杜布鞅, 而且如果 X_i 是独立的随机变量, 那么我们断言存在只依赖于 Z_0, \dots, Z_{k-1} 的随机变量 B_k , 满足 $B_k \leq Z_k - Z_{k-1} \leq B_k + c$. 那么 $Z_k - Z_{k-1}$ 的上下界之间的间隙至多是 c , 所以可以应用定理 12.6 的 Azuma-Hoeffding 不等式.

我们对离散随机变量的情况(虽然结论在更一般的情况下成立)证明结论. 为简化记号, 将 X_1, X_2, \dots, X_n 简记为 S_n , 因此将

$$E[f(\bar{X}) | X_1, X_2, \dots, X_k]$$

记为

$$E[f(\bar{X}) | S_k].$$

也借用这个记号定义

$$f_k(\bar{X}, x) = f(X_1, \dots, X_{k-1}, x, X_{k+1}, \dots, X_n).$$

即 $f_k(\bar{X}, x)$ 表示第 k 个坐标取值为 x 的 $f(\bar{X})$. 类似地, 记

$$f_k(\bar{z}, x) = f(z_1, \dots, z_{k-1}, x, z_{k+1}, \dots, z_n).$$

利用这些记号, 有

$$Z_k - Z_{k-1} = E[f(\bar{X}) | S_k] - E[f(\bar{X}) | S_{k-1}].$$

从而 $Z_k - Z_{k-1}$ 的上界为

$$\sup_x E[f(\bar{X}) | S_{k-1}, X_k = x] - E[f(\bar{X}) | S_{k-1}],$$

下界为

$$\inf_y E[f(\bar{X}) | S_{k-1}, X_k = y] - E[f(\bar{X}) | S_{k-1}].$$

(如果处理的随机变量只能取有限个数的值, 可以用 \max 和 \min 替代 \sup 和 \inf) 因此, 令

$$B_k = \inf_y E[f(\bar{X}) | S_{k-1}, X_k = y] - E[f(\bar{X}) | S_{k-1}],$$

如果可以界定

$$\sup_x E[f(\bar{X}) | S_{k-1}, X_k = x] - \inf_y E[f(\bar{X}) | S_{k-1}, X_k = y] \leq c,$$

那么我们将适当地界定间隙 $Z_k - Z_{k-1}$. 现在

$$\begin{aligned} & \sup_x E[f(\bar{X}) | S_{k-1}, X_k = x] - \inf_y E[f(\bar{X}) | S_{k-1}, X_k = y] \\ &= \sup_{x,y} (E[f(\bar{X}) | S_{k-1}, X_k = x] - E[f(\bar{X}) | S_{k-1}, X_k = y]) \\ &= \sup_{x,y} E[f_k(\bar{X}, x) - f_k(\bar{X}, y) | S_{k-1}]. \end{aligned}$$

因为 X_i 是独立的, 所以从 X_{k+1} 到 X_n 值的任何一个特殊集合的概率不依赖于 X_1, \dots, X_k 的值. 因此对任何值 $x, y, z_1, \dots, z_{k-1}$,

$$E[f_k(\bar{X}, x) - f_k(\bar{X}, y) | X_1 = z_1, \dots, X_{k-1} = z_{k-1}]$$

等于

$$\sum_{z_{k+1}, \dots, z_n} \Pr((X_{k+1} = z_{k+1}) \cap \dots \cap (X_n = z_n)) \cdot (f_k(\bar{z}, x) - f_k(\bar{z}, y)).$$

但

$$f_k(\bar{z}, x) - f_k(\bar{z}, y) \leq c,$$

因此

$$E[f_k(\bar{X}, x) - f_k(\bar{X}, y) | S_{k-1}] \leq c,$$

得到要求的界.

X_i 是独立随机变量的要求是应用这个一般构架的基本要求. 找一个 X_i 不独立时的反例留作练习 12.20.

12.5.2 应用：模式匹配

在许多情景中，包括检查 DNA 结构，一个目标是在一个字符序列中找到有意义的模式。在这里，如果字符是简单地随机生成的，短语“有意义的模式”常常是指比人们预期的更频繁地出现的串。如果一个串出现的次数集中在随机模型的期望周围，那么“有意义的”的概念是合理的。我们将用 Azuma-Hoeffding 不等式对一个简单随机模型说明集中的意思。

设 $X = (X_1, \dots, X_n)$ 是从字母表 Σ 中独立地且均匀随机地选择的一列字符，其中 $s = |\Sigma|$ 。令 $B = (b_1, \dots, b_k)$ 是 Σ 中固定的 k 个字符的串。设 F 是在随机串 X 中的固定串 B 出现的次数。显然，

$$E[F] = (n - k + 1) \left(\frac{1}{s}\right)^k.$$

我们利用杜布鞅和 Azuma-Hoeffding 不等式证明，如果 k 相对于 n 是较小的，那么 B 在 X 中出现的次数是高度集中在它的均值周围的。

设

$$Z_0 = E[F],$$

且对 $1 \leq i \leq n$ ，令

$$Z_i = E[F | X_1, \dots, X_i].$$

那么序列 Z_0, \dots, Z_n 是一个杜布鞅，而且

$$Z_n = F.$$

因为串 X 中的每个字符可以包含在不多于 k 个可能的匹配中，对任意 $0 \leq i \leq n$ ，有

$$|Z_{i+1} - Z_i| \leq k.$$

换句话说， X_{i+1} 的值在任一方向对 F 值的影响至多为 k ，这里因为 X_{i+1} 包含在不多于 k 个可能的匹配中。因此，差

$$|E[F | X_1, \dots, X_{i+1}] - E[F | X_1, \dots, X_i]| = |Z_{i+1} - Z_i|$$

必至多为 k 。由定理 12.4 得到

$$\Pr(|F - E[F]| \geq \varepsilon) \leq 2e^{-\varepsilon^2/2nk^2},$$

或者(由推论 12.5)

$$\Pr(|F - E[F]| \geq \lambda k \sqrt{n}) \leq 2e^{-\lambda^2/2}.$$

应用定理 12.6 的一般构架，可以得到稍好一点的界。设 $F = f(X_1, X_2, \dots, X_n)$ ，那么由以前的论证，任何单一的 X_i 值的改变可能改变 F 的值至多为 k ，从而这个函数满足界为 k 的利普希茨条件。那么由定理 12.6 得到

$$\Pr(|F - E[F]| \geq \varepsilon) \leq 2e^{-2\varepsilon^2/nk^2},$$

将指数中的值改进了一个因子 4。

12.5.3 应用：球和箱子

假定独立地且均匀随机地将 m 个球投掷到 n 个箱子中，设 X_i 是一个表示第 i 个球所落入的箱子的随机变量。

设 F 是投掷 m 个球后空箱子的个数，那么序列

$$Z_i = E[F | X_1, \dots, X_i]$$

是一个杜布鞅. 我们断言 $F = f(X_1, X_2, \dots, X_n)$ 满足界为 1 的利普希茨条件. 考虑 F 是如何随着第 i 个球的放置而变化的. 如果第 i 个球落入一个只有它自己的箱子, 那么改变 X_i 使得第 i 个球落入一个已经有某个其他球的箱子中将使 F 增加 1. 类似地, 如果第 i 个球落入一个已有其他球的箱子中, 那么改变 X_i 使得第 i 个球落入另外一个空箱子将使 F 减少 1. 在所有其他情况下, 改变 X_i 使 F 处于相同的状态. 因此, 由定理 12.6 的 Azuma-Hoeffding 不等式可得

$$\Pr(|F - E[F]| \geq \varepsilon) \leq 2e^{-\varepsilon^2/2n}.$$

也可以应用 $|Z_{i+1} - Z_i| \leq 1$ 时的定理 12.4, 但得到一个稍弱一点的结果, 这里

$$E[F] = n \left(1 - \frac{1}{n}\right)^n,$$

但是可以在不知 $E[F]$ 的情况下得到集中的结果.

这个结果可以通过更细心地界定 $Z_i - Z_{i-1}$ 的界之间的间隙得到改善. 这个问题的考虑留作练习 12.19.

12.5.4 应用: 色数

给定 $G_{n,p}$ 中的一个随机图 G , 色数 $\chi(G)$ 是为了给这个图中所有顶点着色, 使得没有相邻顶点有同一种颜色, 所需要的颜色种数的最小值. 我们用 12.1 节定义的顶点暴露鞅来得到 $\chi(G)$ 的集中结果.

设 G_i 是由顶点集合 $\{1, \dots, i\}$ 导出的 G 的随机子图, $Z_0 = E[\chi(G)]$, 并设

$$Z_i = E[\chi(G) | G_1, \dots, G_i].$$

因为一个顶点不能用多于一种新的颜色, 所以 Z_i 与 Z_{i-1} 之间的间隙至多是 1, 因此可以应用定理 12.6 中的 Azuma-Hoeffding 不等式的一般框架. 我们有

$$\Pr(|\chi(G) - E[\chi(G)]| \geq \lambda \sqrt{n}) \leq 2e^{-\lambda^2}.$$

这个结论即使在不知道 $E[\chi(G)]$ 的情况下也成立.

308

练习

- 12.1 如果 Z_0, Z_1, \dots, Z_n 是关于 X_0, X_1, \dots, X_n 的一个鞅, 证明它也是关于自身的鞅.
 12.2 设 $Z_0 = 0$, 对 $j \geq 0$, X_{j+1} 是在实区间 $[X_j, 1]$ 上均匀选取的, 证明对 $k \geq 0$, 序列

$$Y_k = 2^k(1 - X_k)$$

是一个鞅.

- 12.3 设 X_1, X_2, \dots 是期望为 0、方差为 $\sigma^2 < \infty$ 的独立同分布的随机变量, 令

$$Z_n = \left(\sum_{i=1}^n X_i\right)^2 - n\sigma^2.$$

证明 Z_1, Z_2, \dots 是一个鞅.

- 12.4 考虑赌徒破产问题, 其中一个赌徒进行了一系列独立的赌博, 或者以概率 1/2 赢一元,

或者以概率 $1/2$ 输一元. 赌博一直持续到或者输了 ℓ_1 元, 或者赢了 ℓ_2 元. 如果赌徒赢

了第 n 次赌博, 则 X_n 为 1, 否则为 -1 . 记 $Z_n = \left(\sum_{i=1}^n X_i \right)^2 - n$.

(a) 证明 Z_1, Z_2, \dots 是鞅.

(b) 设 T 是赌徒结束赌博时的停时, 确定 $E[Z_T]$.

(c) 计算 $E[T]$. (提示: 可以利用已经知道的有关赌徒赢的概率.)

- 12.5 考虑赌徒破产问题, 现在独立的赌博是这样的, 赌徒或者以概率 $p < 1/2$ 赢一元, 或者以概率 $1-p$ 输一元. 如练习 12.4, 赌博一直持续到或者输了 ℓ_1 元, 或者赢了 ℓ_2 元. 如果赌徒赢了第 n 次赌博, 则 X_n 为 1, 否则为 -1 , 令 Z_n 是 n 次赌博后赌徒赢得的总钱数.

(a) 证明

$$A_n = \left(\frac{1-p}{p} \right)^{Z_n}$$

是均值为 1 的鞅.

(b) 确定赌徒在输掉 ℓ_2 元之前赢 ℓ_1 元的概率.

(c) 证明

$$B_n = Z_n - (2p-1)n$$

是均值为 0 的鞅.

(d) 设 T 是赌徒结束赌博时的停时, 确定 $E[Z_T]$, 并利用它确定 $E[T]$. (提示: 可以利用已经知道的有关赌徒赢的概率.)

- 12.6 证明定理 12.6.

- 12.7 在装箱问题中, 给定体积为 a_1, a_2, \dots, a_n 的货物, 对 $1 \leq i \leq n$, $0 \leq a_i \leq 1$. 目的是将它们装入最少个数的箱子, 每个箱子能容纳任意多个体积之和不超过 1 的货物. 假定每个 a_i 是依某个(对每个 i 可以不同的)分布独立选取的. 设 P 是按货物的最好装箱方式所要求的箱子数, 证明

$$\Pr(|P - E[P]| \geq \lambda) \leq e^{-2\lambda^2/n}.$$

- 12.8 考虑有 $N = 2^n$ 个结点的 n 维立方体, 设 S 是立方体上顶点的非空集合, x 是从立方体的所有顶点中均匀随机选取的一个顶点, $D(x, S)$ 是对所有点 $y \in S$, x 和 y 不同的坐标的最小个数, 给出关于

$$\Pr(|D(x, S) - E[D(x, S)]| > \lambda)$$

的一个界.

- 12.9 我们在第 4 章提出了 $|0, 1|$ 随机变量之和的尾部界, 我们可以利用鞅将这个结果推广到值域在 $[0, 1]$ 中的任意随机变量之和. 设 X_1, X_2, \dots, X_n 是独立的随机变量, 满足

$\Pr[0 \leq X_i \leq 1] = 1$. 如果 $S_n = \sum_{i=1}^n X_i$, 证明

$$\Pr(|S_n - E[S_n]| \geq \lambda) \leq 2e^{-2\lambda^2}.$$

- 12.10 一位停车场的服务员将 n 辆汽车的 n 把钥匙搞乱了. n 辆汽车主人同时到达, 服务员按照从所有排列中均匀随机地选取的一个排列给每个车主一把钥匙. 如果车主得到了他自己的汽车钥匙, 就收下钥匙并离开; 否则, 他将钥匙退回给服务员. 现在, 服务员对剩下的钥匙和汽车主人重复这个过程, 直到所有车主得到他们自己的汽车钥匙.

设 R 是直到所有汽车主人得到了他们自己的汽车钥匙的回合数. 我们希望计算 $E[R]$. 设 X_i 是第 i 个回合中得到了自己汽车钥匙的车主个数, 证明

$$Y_i = \sum_{j=1}^i (X_j - E[X_j | X_1, \dots, X_{j-1}])$$

是一个鞅, 利用鞅停止定理, 计算 $E[R]$.

- 12.11 Alice 和 Bob 在一次跳棋赛中相互比赛, 其中第一个赢得 4 局的选手赢得比赛. 选手是公平地比赛的, 所以每个选手赢得每局游戏的概率是 $1/2$, 且与其他局游戏独立. 每局时间是在 $[30, 60]$ 分钟上均匀分布的整数, 也与其他局独立. 他们进行比赛所花费时间的期望是多少? [310]

- 12.12 为将 n 个数依递增顺序排列; 考虑下面极其无效的算法. 首先从 n 个数中均匀随机地选取一个数, 将它放在第 1 位; 然后从剩下的 $n-1$ 个数中均匀随机地选取一个数, 将它放在第 2 位; 如果第二个数小于第一个数, 重新从头开始; 否则, 再从剩下的 $n-2$ 个数中均匀随机地选取一个数, 将它放在第 3 位; 等等. 只要算法发现放置的第 k 项小于第 $k-1$ 项, 算法便从头开始. 假定输入是 n 个不同的数, 确定算法放置一个数的期望步数.

- 12.13 假定要将 n 张多米诺骨牌排成一串, 一旦完成, 便可以用一种令人愉快的方式击倒领头的多米诺骨牌, 使它们全部倒下. 在每次放置一张多米诺骨牌时, 存在某种可能使得它倒下从而引起所有其他已经小心放置的多米诺骨牌全部倒下. 此时, 必须从第一张多米诺骨牌开始重新放置.

(a) 将每次尝试放置一张多米诺骨牌称为一次试验, 每次试验成功的概率为 p . 利用瓦尔德方程, 求在放置准备好了以前, 需要试验的期望次数, 对 $n=100$ 及 $p=0.1$ 计算试验的次数.

(b) 假定代之以可以将放置分成 k 个部分, 每部分大小为 n/k , 用这种方式, 只要完成了一部分, 在进一步放置时, 它就不会倒下. 例如: 如果有 10 个大小为 10 的部分, 那么只要第一部分的 10 张多米诺骨牌成功放置, 它们就不会倒下, 以后一张多米诺骨牌失误会使其他部分倒, 但第一部分保持准备好的状态. 在这种情况下, 求放置准备好了之前所需要试验的期望次数. 对 $n=100$, $k=10$ 和 $p=0.1$, 计算试验次数, 并与 (a) 中的答案比较.

- 12.14 (a) 设 X_1, X_2, \dots 是独立的指数随机变量序列, 每个均值为 1. 给定一个正实数 k , 令 N 由

$$N = \min \left\{ n : \sum_{i=1}^n X_i > k \right\}$$

定义, 即 N 是前 n 个 X_i 之和大于 k 的最小整数. 利用瓦尔德不等式确定 $E[N]$.

- (b) 设 X_1, X_2, \dots 是区间 $(0, 1)$ 上独立均匀的随机变量序列. 给定一个正实数 k , 令 N 由

$$N = \min \left\{ n: \prod_{i=1}^n X_i < k \right\}$$

定义, 即 N 是前 n 个 X_i 之积小于 k 的最小整数. 确定 $E[N]$. (提示: 可以借助于练习 8.9.)

- 12.15 串 s 的子序列是任意由 s 删去字符而得的串. 考虑两个长度为 n 的串 x 和 y , 其中每个字符在每个串中是独立地以 $1/2$ 的概率为 0, 以 $1/2$ 的概率为 1. 考虑这两个串的最长公共子序列.

- (a) 对充分大的 n , 证明最长公共子序列的期望长度大于 $c_1 n$ 而小于 $c_2 n$, 其中常数 $c_1 > 1/2$, $c_2 < 1$. (任意常数 c_1, c_2 都可以. 作为一次挑战, 可以努力去找可能找到的最好的常数 c_1, c_2 .)

- (b) 利用鞅不等式证明最长公共子序列的长度高度集中在它的均值附近.

- 12.16 已知一个装有 r 个红球和 g 个绿球的箱子, 假定无放回地从箱子中均匀抽样 n 个球. 提出一个合适的鞅, 并用它证明样本中的红球数紧紧地集中在 $nr/(r+g)$ 周围.

- 12.17 在第 5 章证明了在一个 Bloom 过滤器中元素为 0 的比例集中在

$$p' = \left(1 - \frac{1}{n}\right)^{km}$$

附近, 其中 m 是数据项个数, k 是散列函数个数, 而 n 是 Bloom 过滤器中二进制数字的个数. 利用鞅不等式导出一个类似的集中结论.

- 12.18 考虑来自 $G_{n,n}$ 的一个随机图, 其中 $N = cn$, $c > 0$ 是某个常数, 令 X 是孤立顶点 (即次为 0 的顶点) 的期望个数.

- (a) 确定 $E[X]$.

- (b) 证明

$$\Pr(|X - E[X]| \geq 2\lambda \sqrt{cn}) \leq 2e^{-\lambda^2/2}.$$

(提示: 利用以每次一条边揭示的图中边位置的鞅.)

- 12.19 对 m 个球投入 n 个箱子的问题, 由 Azuma-Hoeffding 不等式改进我们的界. 设 F 是投入 m 个球后的空箱个数, X_i 是第 i 个球落入的箱子, 定义 $Z_0 = E[F]$, $Z_i = E[F | X_1, \dots, X_i]$.

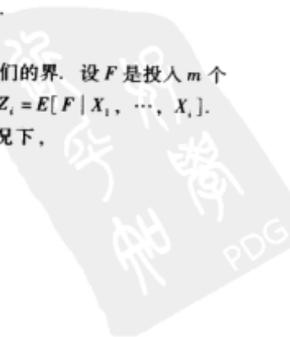
- (a) 令 A_i 表示投放第 i 个球后的空箱子的个数, 证明在这种情况下,

$$Z_{i-1} = A_{i-1} \left(1 - \frac{1}{n}\right)^{m-i+1}.$$

- (b) 如果在投放第 i 个球时, 它落入的箱子是空箱, 证明

$$Z_i = (A_{i-1} - 1) \left(1 - \frac{1}{n}\right)^{m-i}.$$

- (c) 如果在投放第 i 个球时, 它落入的箱子不是空箱, 证明



$$Z_i = A_{i-1} \left(1 - \frac{1}{n}\right)^{n-i}.$$

(d) 说明定理 12.6 的 Azuma-Hoeffding 不等式适用于 $d_i = (1 - 1/n)^{n-i}$ 的情况.

(e) 利用 (d), 证明

$$\Pr(|F - E[F]| \geq \lambda) \leq 2e^{-\lambda^2(2n-1)/(n^2 - (E[F])^2)}.$$

12.20 设 $f(X_1, X_2, \dots, X_n)$ 满足利普希茨条件, 即对任意 i 及任意值 x_1, x_2, \dots, x_n 和 y_i ,

$$|f(x_1, x_2, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) - f(x_1, x_2, \dots, x_{i-1}, y_i, x_{i+1}, \dots, x_n)| \leq c.$$

令

$$Z_0 = E[f(X_1, X_2, \dots, X_n)]$$

及

$$Z_i = E[f(X_1, X_2, \dots, X_n) \mid X_1, X_2, \dots, X_i],$$

给出一个例子以说明如果 X_i 不是独立的, 那么有可能有 $|Z_i - Z_{i-1}| > c$.



第 13 章 两两独立及通用散列函数

这一章将介绍并应用一种受到限制的独立性的概念(称为每 k 个独立), 特别关注于两两独立的重要情况. 应用有限相关性能使我们减少随机化算法用到的随机性量, 在某些情况下, 我们能将一个随机化算法转化为一种有效的确定性算法. 有限相关性也用于通用及强通用散列函数族的设计中, 给出空间——和时间——有效的数据结构. 我们考虑为什么通用散列函数在实际中是有效的, 并说明它们是如何导出简单完美的散列方案. 最后, 将这些思想用于在数据流中找到频繁出现的对象的有效且实用的近似算法的设计, 推广第 5 章介绍的 Bloom 过滤器数据结构.

13.1 两两独立

回忆第 2 章中定义的一个事件集合 E_1, E_2, \dots, E_n 是相互独立的, 如果对任意子集 $I \subseteq [1, n]$,

$$\Pr\left(\bigcap_{i \in I} E_i\right) = \prod_{i \in I} \Pr(E_i).$$

类似地, 我们定义随机变量集合 X_1, X_2, \dots, X_n 是相互独立的, 如果对任意子集 $I \subseteq [1, n]$ 及任意值 $x_i, i \in I$,

$$\Pr\left(\bigcap_{i \in I} X_i = x_i\right) = \prod_{i \in I} \Pr(X_i = x_i).$$

相互独立常常是太强的要求而无法满足. 这里, 我们考察一种在许多情况下是有用的、受到更多限制的独立性概念: 每 k 个独立.

定义 13.1

1. 事件集合 E_1, E_2, \dots, E_n 是每 k 个独立的, 如果对任意子集 $I \subseteq [1, n], |I| \leq k$, 有

$$\Pr\left(\bigcap_{i \in I} E_i\right) = \prod_{i \in I} \Pr(E_i).$$

2. 随机变量集合 X_1, X_2, \dots, X_n 是每 k 个独立的, 如果对任意子集 $I \subseteq [1, n] (|I| \leq k)$ 及任意值 $x_i, i \in I$,

$$\Pr\left(\bigcap_{i \in I} X_i = x_i\right) = \prod_{i \in I} \Pr(X_i = x_i).$$

3. 随机变量 X_1, X_2, \dots, X_n 称为两两独立的, 如果它们是每 2 个独立的, 即对任意一对 i, j 及任意值 a, b ,

$$\Pr((X_i = a) \cap (X_j = b)) = \Pr(X_i = a)\Pr(X_j = b).$$

13.1.1 例：两两独立的二进制数字的构造

随机二进制数字是均匀的，如果它以相同的概率取值 0 和 1。这里，我们说明如何从 b 个独立的均匀随机的二进制数字 X_1, \dots, X_b 中导出 $m = 2^b - 1$ 个均匀的两两独立的二进制数字。

依某种次序列举 $\{1, 2, \dots, b\}$ 的 $2^b - 1$ 个非空子集，记 S_j 为依这种次序的第 j 个子集，令

$$Y_j = \bigoplus_{i \in S_j} X_i,$$

其中 \oplus 是不可兼或运算。等价地，可以将这写成

$$Y_j = \sum_{i \in S_j} X_i \pmod{2}.$$

引理 13.1 Y_j 是两两独立的均匀二进制数字。

证明 首先证明对任意非空集合 S_j ，随机二进制数字

$$Y_j = \bigoplus_{i \in S_j} X_i$$

是均匀的。利用延迟决策原理(见 1.3 节)容易证明这一点。设 z 是 S 中最大元素，那么

$$Y_j = \left(\bigoplus_{i \in S_j - \{z\}} X_i \right) \oplus X_z.$$

假定我们对所有 $i \in S_j - \{z\}$ 揭示 X_i 的值，那么显然， X_z 的值决定了 Y_j 的值，且 Y_j 将以相同的概率取值 0 和 1。

现在考虑任意两个变量 Y_k 和 Y_ℓ ，它们对应于集合 S_k 和 S_ℓ 。设 z 是 S_ℓ 的元素，它不在 S_k 中，对任意值 $c, d \in \{0, 1\}$ ，考虑

$$\Pr(Y_\ell = d \mid Y_k = c).$$

再次由延迟决策原理，我们断言这个概率为 $1/2$ 。假定对所有在 $(S_k \cup S_\ell) - \{z\}$ 中的 i 揭示 X_i 值，即使这确定了 Y_k 的值， X_z 的值也将确定 Y_ℓ ，所以关于 Y_k 值的条件不会改变 Y_ℓ 等可能地为 0 或 1。因此，

$$\begin{aligned} \Pr((Y_k = c) \cap (Y_\ell = d)) &= \Pr(Y_\ell = d \mid Y_k = c) \Pr(Y_k = c) \\ &= 1/4. \end{aligned}$$

因为这对任意的值 $c, d \in \{0, 1\}$ 成立，所以我们已经证明了两两独立性。 ■

13.1.2 应用：消去最大割算法的随机性

在第 6 章，我们考察了在无向图 $G = (V, E)$ 中寻找一个最大割的简单随机化算法：算法以 $1/2$ 的概率将每个顶点独立地放置在割的一侧。用这个方法生成的割的期望值为 $m/2$ ，其中 m 是图中边的条数。我们还证明了(在 6.3 节)利用条件期望可以有效地消去这个算法的随机性。

这里我们提出消去这个算法随机性的另一种方法：利用两两独立性。这为利用每 k 个独立性消去随机性的方法给出了一个例证。

假定有一个两两独立的二进制数字集 Y_1, Y_2, \dots, Y_n ，其中 $n = |V|$ 是图中顶点个数。通过将所有 $Y_i = 0$ 的顶点 i 放在割的一侧，将所有 $Y_i = 1$ 的顶点 i 放在割的另一侧的方法来定义

割. 我们证明此时横跨割的期望边数依然是 $m/2$, 即在分析期望时不要求完全独立, 两两独立足够了.

回忆 6.2.1 节的论证: 将边从 1 到 m 编号, 如果第 i 条边横跨割, 令 $Z_i = 1$; 否则, 令 $Z_i = 0$. 那么 $Z = \sum_{i=1}^m Z_i$ 是横跨割的边数, 且

$$E[Z] = E\left[\sum_{i=1}^m Z_i\right] = \sum_{i=1}^m E[Z_i].$$

设 a 和 b 是与第 i 条边邻接的两个顶点, 那么

$$\Pr(Z_i = 1) = \Pr(Y_a \neq Y_b) = 1/2,$$

其中用到了 Y_a 和 Y_b 的两两独立性. 因此 $E[Z_i] = 1/2$, 且由此 $E[Z] = m/2$.

现在设 n 个两两独立的二进制数字 Y_1, \dots, Y_n 是按引理 13.1 (这里 $b = \lceil \log_2(n+1) \rceil$) 中的方法, 由 b 个独立的且均匀随机的二进制数字 X_1, \dots, X_b 生成的. 那么对所得的割有 $E[Z] = m/2$, 其中样本空间恰是最初的 b 个随机二进制数字的所有可能选择. 由概率方法 (特别地由引理 6.2), 存在 b 个二进制数字的某种设置给出一个值至少为 $m/2$ 的割. 为了找到这样一个割, 可以尝试二进制数字所有可能的 2^b 种设置. 因为 2^b 是 $O(n)$, 且因为对每个割, 横跨边的条数容易以 $O(m)$ 时间计算, 因此可以用 $O(mn)$ 时间确定地找到一个至少有 $m/2$ 条横跨边的割.

虽然这种方法并没有显得如 6.3 节的消除随机性那样有效, 但此方案的一个可取之处是平行化是平凡的. 如果有足够多的处理器可以利用, 那么可以对随机二进制数字 X_1, X_2, \dots, X_b 的 $\Omega(n)$ 种可能性的每一个指派给一个处理器, 而每种可能性给出一个割. 利用 $O(n)$ 个处理器, 平行化减少一个 $\Omega(n)$ 因子的运行时间. 事实上, 利用 $O(mn)$ 个处理器, 可以为一个有特定的随机二进制数字序列的特定边组合指派一个处理器, 然后, 对随机二进制数字的那种设置以不变时间确定边是否横跨割. 这样为了收集结果并找到较大的割, 只需要 $O(\log n)$ 时间.

13.1.3 例: 构造关于一个素数模的两两独立的值

考虑给出两两独立值 Y_0, Y_1, \dots, Y_{p-1} 的另一种构造法, 这些值在 $\{0, 1, \dots, p-1\}$ 上是均匀的, 其中 p 是素数. 我们的构造法只要求两个在 $\{0, 1, \dots, p-1\}$ 上独立均匀的值 X_1 和 X_2 , 由此导出

$$Y_i = X_1 + iX_2 \pmod{p}, \quad i = 0, \dots, p-1.$$

引理 13.2 变量 Y_0, Y_1, \dots, Y_{p-1} 在 $\{0, 1, \dots, p-1\}$ 上是两两独立的均匀的随机变量.

证明 仍由延迟决策原理, 显然每个 Y_i 在 $\{0, 1, \dots, p-1\}$ 上是均匀的. 给定 X_2 , 对 X_1 的 p 个各不相同的可能值给出 Y_i 关于模 p 的 p 个各不相同的可能值, 其中的每一个是等可能的.

现在考虑任意两个变量 Y_i 和 Y_j , 我们希望证明, 对任意的 $a, b \in \{0, 1, \dots, p-1\}$,

$$\Pr((Y_i = a) \cap (Y_j = b)) = \frac{1}{p^2},$$

这表示是两两独立的. 事件 $Y_i = a$ 和 $Y_j = b$ 等价于

$$X_1 + iX_2 = a \pmod{p} \quad \text{和} \quad X_1 + jX_2 = b \pmod{p}.$$

这是两个方程和两个未知数的方法组, 恰有一个解

$$X_2 = \frac{b-a}{j-i} \pmod{p} \quad \text{和} \quad X_1 = a - \frac{i(b-a)}{j-i} \pmod{p}.$$

因为 X_1 和 X_2 在 $\{0, 1, \dots, p-1\}$ 上是独立的和均匀的, 结果成立. ■

可以推广这个证明得到下面有用的结果: 给定 $2n$ 个独立的均匀随机的二进制数字, 可以构造直到 2^n 个两两独立且均匀的 n 个二进制数字串. 推广要求有限域的知识, 所以我们只在这里概述结果. 设置和证明完全与引理 13.2 的相同, 除了代替模 p , 我们在有 2^n 个元素的一个固定有限域上(比如按某个不可约的 n 次多项式取模. 系数在 $GF(2)$ 中的所有多项式域 $GF(2^n)$) 执行所有的计算. 即假定一个从 n 个二进制数字的串(也可以将它作为 $\{0, 1, \dots, 2^n - 1\}$ 中的数)到域元素的一个固定的一对一映射 f . 令

$$Y_i = f^{-1}(f(X_1) + f(i) \cdot f(X_2)),$$

其中 X_1 和 X_2 是在 $\{0, 1, \dots, 2^n - 1\}$ 上独立且均匀选取的, i 取遍值 $\{0, 1, \dots, 2^n - 1\}$, 且加法和乘法是在域上执行的, 所以 Y_i 是两两独立的.

13.2 两两独立变量的切比雪夫不等式

两两独立性比相互独立性要弱得多, 例如, 可以用切尔诺夫界估计独立随机变量和的尾部分布, 但如果 X_i 只是两两独立, 就不能直接应用切尔诺夫界. 然而, 对于和的方差的方便计算, 两两独立已经足够了, 它允许切比雪夫不等式的有益应用.

定理 13.3 设 $X = \sum_{i=1}^n X_i$, 其中 X_i 是两两独立的随机变量, 那么

$$\text{Var}[X] = \sum_{i=1}^n \text{Var}[X_i].$$

证明 我们在第 3 章看到

$$\text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i] + 2 \sum_{i < j} \text{Cov}(X_i, X_j),$$

其中

$$\text{Cov}(X_i, X_j) = E[(X_i - E[X_i])(X_j - E[X_j])] = E[X_i X_j] - E[X_i]E[X_j].$$

因为 X_1, X_2, \dots, X_n 两两独立, 显然(与定理 3.3 相同的理由)对任意的 $i \neq j$, 我们有

$$E[X_i X_j] - E[X_i]E[X_j] = 0.$$

所以,

$$\text{Var}[X] = \sum_{i=1}^n \text{Var}[X_i]. \quad \blacksquare$$

将切比雪夫不等式用于两两独立变量的和得到下面的推论.

推论 13.4 设 $X = \sum_{i=1}^n X_i$, 其中 X_i 是两两独立的随机变量, 那么

$$\Pr(|X - E[X]| \geq a) \leq \frac{\text{Var}[X]}{a^2} = \frac{\sum_{i=1}^n \text{Var}[X_i]}{a^2}.$$

13.2.1 应用：利用少量随机二进制数字的抽样

我们通过抽样将两两独立随机变量的切比雪夫不等式用于得到一个好的近似，这比基于切尔诺夫界的自然方法使用了较少的随机性。

假定有一个将 n -位向量映射到实数的函数 $f: \{0, 1\}^n \rightarrow [0, 1]$ 。记 $\bar{f} = \left(\sum_{x \in \{0, 1\}^n} f(x) \right) / 2^n$

是 f 的平均值，我们希望计算 \bar{f} 的一个 $1 - \delta$ 置信区间，即希望找到一个区间 $[\bar{f} - \varepsilon, \bar{f} + \varepsilon]$ ，使得

$$\Pr(\bar{f} \in [\bar{f} - \varepsilon, \bar{f} + \varepsilon]) \geq 1 - \delta.$$

作为一个具体的例子，假定有一个可积函数 $g: [0, 1] \rightarrow [0, 1]$ ，且 g 的导数存在，对某个固定的常数 C ，在整个区间 $(0, 1)$ 上有 $|g'(x)| \leq C$ 。我们感兴趣的是 $\int_{x=0}^1 g(x) dx$ 。可能没有直接的方法精确地计算这个积分，但通过抽样，可以得到一个好的估计。如果 X 是 $[0, 1]$ 上的均匀随机变量，那么由连续随机变量期望的定义， $E[g(X)] = \int_{x=0}^1 g(x) dx$ 。通过对多次独立抽样取平均，我们可以近似积分。如果随机性的来源只是产生随机二进制数字而不是随机实数，那么可以用下面的方法来近似积分。对一个二进制数字串 $x \in \{0, 1\}^n$ ，将它看作是用二进制表示的十进制小数，就可以将 x 理解为一个实数 $\hat{x} \in [0, 1]$ ；例如，11001 对应于 $0.11001 = 25/32$ 。设 $f(x)$ 表示函数 g 在十进制小数 \hat{x} 处的值。这样，对任意整数 i ， $0 \leq i \leq 2^n - 1$ ，对 $y \in [i/2^n, (i+1)/2^n]$ ，我们有

$$f\left(\frac{i}{2^n}\right) - \frac{C}{2^n} \leq g(y) \leq f\left(\frac{i}{2^n}\right) + \frac{C}{2^n}.$$

因此

$$\frac{1}{2^n} \sum_{x \in \{0, 1\}^n} \left(f(x) - \frac{C}{2^n} \right) \leq \int_{x=0}^1 g(x) dx \leq \frac{1}{2^n} \sum_{x \in \{0, 1\}^n} \left(f(x) + \frac{C}{2^n} \right).$$

取充分大的 n ，可以保证 $\bar{f} = \left(\sum_{x \in \{0, 1\}^n} f(x) \right) / 2^n$ 与 g 的积分相差至多一个常数 γ 。此时， \bar{f} 的置

信区间 $[\bar{f} - \varepsilon, \bar{f} + \varepsilon]$ 产生一个 g 的积分的置信区间 $[\bar{g} - \varepsilon - \gamma, \bar{g} + \varepsilon + \gamma]$ 。

可以用独立样本及切尔诺夫界求平均值 \bar{f} 的置信区间问题。即假定在 $\{0, 1\}^n$ 中均匀地有放回地抽样随机点，计算在所有这些点处的 f 值，并取样本的平均值，这类似于 4.2.3 节的参数估计。定理 13.5 是下面切尔诺夫界的直接推论，利用练习 4.13 及 4.19 可以导出。如果 Z_1, Z_2, \dots, Z_n 是独立同分布的实值随机变量（均值为 μ ），取 $[0, 1]$ 中值的一个有限可能的集合之一，那么

$$\Pr\left(\left|\sum_{i=1}^n Z_i - m\mu\right| \geq \varepsilon m\right) \leq 2e^{-2\varepsilon^2}.$$

定理 13.5 设 $f: \{0, 1\}^n \rightarrow [0, 1]$, $\bar{f} = \left(\sum_{x \in \{0, 1\}^n} f(x)\right) / 2^n$, 令 X_1, \dots, X_n 是从 $\{0, 1\}^n$ 中独立地且均匀随机地选取的. 如果 $m > \ln(2/\delta) / 2\varepsilon^2$, 那么

$$\Pr\left(\left|\frac{1}{m} \sum_{i=1}^m f(X_i) - \bar{f}\right| \geq \varepsilon\right) \leq \delta.$$

虽然 m 的精确选取依赖于所用的切尔诺夫界, 但一般地, 为了达到要求的界, 这种直接方法要求 $\Omega(\ln(1/\delta)/\varepsilon^2)$ 次抽样.

用这种方法可能产生的问题是要求使用大量的随机二进制数字. f 的每次抽样要求 n 个独立的二进制数字, 所以应用定理 13.5 意味着, 为了至少以 $1-\delta$ 的概率得到一个加性误差至多为 ε 的近似, 至少需要 $\Omega(n \ln(1/\delta)/\varepsilon^2)$ 个独立的、均匀随机的二进制数字.

当需要记录样本是如何得到时产生了一个有关的问题, 即工作可能是重复的, 且在以后是要查验的. 在这种情况下, 也需要存储用作档案的二进制数字. 此时使用的随机二进制数字越少, 存储量要求也越少.

利用较少随机性, 可以用两两独立的样本得到类似的近似. 设 X_1, \dots, X_n 是取自 $\{0, 1\}^n$ 的两两独立的点, 令 $Y = \left(\sum_{i=1}^m f(X_i)\right) / m$. 那么 $E[Y] = \bar{f}$, 且由切比雪夫不等式得到

$$\begin{aligned} \Pr(|Y - \bar{f}| \geq \varepsilon) &\leq \frac{\text{Var}[Y]}{\varepsilon^2} \\ &= \frac{\text{Var}\left[\left(\sum_{i=1}^m f(X_i)\right) / m\right]}{\varepsilon^2} \\ &= \frac{\sum_{i=1}^m \text{Var}[f(X_i)]}{m^2 \varepsilon^2} \\ &\leq \frac{m}{m^2 \varepsilon^2} = \frac{1}{m \varepsilon^2}, \end{aligned}$$

这是因为 $\text{Var}[f(X_i)] \leq E[(f(X_i))^2] \leq 1$. 故当 $m = 1/\delta\varepsilon^2$ 时, 我们得到 $\Pr(|Y - \bar{f}| \geq \varepsilon) \leq \delta$. (事实上, 可以证明 $\text{Var}[f(X_i)] \leq 1/4$, 从而给出一个稍好一点的界, 这留作练习 13.4.)

利用两两独立的样本要求更多次抽样: $\Theta(1/\delta\varepsilon^2)$, 当它们独立时为 $\Theta(\ln(1/\delta)/\varepsilon^2)$ 次抽样. 但是回忆 13.1.3 节, 只需以 $2n$ 个均匀独立的二进制数字就可以得到 2^n 个两两独立的样品. 因此只要 $1/\delta\varepsilon^2 < 2^n$, $2n$ 个随机二进制数字即够, 这比用完全独立样本要求的个数少了许多. 通常 ε 和 δ 是与 n 无关的固定常数, 从使用的随机二进制数字的个数及计算花费两个方面考虑, 这种类型的估计是相当有效的.

13.3 通用散列函数族

在此之前, 当研究散列函数时, 我们是将它们作为具有下列意义下的完全随机性来建立模型的: 对任意一个项目集合 x_1, x_2, \dots, x_k , 散列值 $h(x_1), h(x_2), \dots, h(x_k)$ 被认为在散列函数的值域上是均匀、独立的. 这是我们用于分析在第 5 章中球与箱子问题的散列框架. 完全随机散列函数的假定简化了对散列理论研究的分析. 但实际上, 完全随机散列函数对计算和存储都过于昂贵, 所以模型并没有完全反映现实.

有两条途径常用于提供实际的散列函数. 在许多情况下, 使用启发式的或为体现随机性而专门设计的函数. 虽然这些函数对某些应用可能是合适的, 但一般并没有任何相关的可证实的保证, 对它们的使用具有潜在的风险. 另一条途径是使用具有某些可证实的保证的散列函数. 我们放弃关于完全随机散列函数的较强的叙述, 而以有效存储及计算的散列函数的较弱叙述来代替.

考虑计算上最简单的、提供了有用且可证实的保证的散列函数类之一: 通用散列函数族. 这些函数在实际中有广泛应用.

定义 13.2 设 U 是一个全集, $|U| \geq n$, 令 $V = \{0, 1, \dots, n-1\}$. 一个从 U 到 V 的散列函数族 \mathcal{H} 称为是 k 维通用的, 如果对任意元素 x_1, x_2, \dots, x_k 以及从 \mathcal{H} 中均匀随机选取的一个散列函数 h , 有

$$\Pr(h(x_1) = h(x_2) = \dots = h(x_k)) \leq \frac{1}{n^{k-1}}.$$

一个从 U 到 V 的散列函数族 \mathcal{H} 称为是 k 维强通用的, 如果对任意元素 x_1, x_2, \dots, x_k , 任意值 $y_1, y_2, \dots, y_k \in \{0, 1, \dots, n-1\}$ 和一个均匀随机地取自 \mathcal{H} 的散列函数 h , 有

$$\Pr((h(x_1) = y_1) \cap (h(x_2) = y_2) \cap \dots \cap (h(x_k) = y_k)) = \frac{1}{n^k}.$$

我们主要对 2 维通用及 2 维强通用散列函数族感兴趣. 当从一个 2 维通用散列函数族中选取一个散列函数时, 任意两个元素 x_1, x_2 具有相同的散列值的概率至多为 $1/n$. 在这方面, 一个取自 2 维通用散列函数族的散列函数的表现如同随机散列函数一样, 但对 2 维通用散列函数族, 任意三个值 x_1, x_2, x_3 有相同散列值的概率如同 x_1, x_2, x_3 的散列值相互独立的情形一样至多为 $1/n^2$, 这是不成立的.

当族是 2 维强通用散列函数族, 且从那个族中选取一个散列函数时, 值 $h(x_1)$ 和 $h(x_2)$ 是两两独立的, 这是因为它们取任意一对特殊值的概率为 $1/n^2$. 由此, 取自 2 维强通用散列函数族的散列函数也称为两两独立的散列函数. 更一般地, 如果族是 k 维强通用散列函数族, 且从那个族中选取一个散列函数, 那么值 $h(x_1), h(x_2), \dots, h(x_k)$ 是每 k 个独立的. 值得注意的是, 一个 k 维强通用散列函数也是 k 维通用的.

为了对通用散列函数族的性质有某些了解, 我们重新回到第 5 章在球与箱子框架中考虑过的问题. 在 5.2 节, 当 n 个项目用完全随机散列函数被散列到 n 个箱子时, 以大的概率最大负荷是 $\Theta(\log n / \log \log n)$, 现在考虑当用一个取自 2 维通用族的散列函数将 n 个项目散列到 n 个箱子时, 关于最大负荷可以得到什么样的界.

首先考虑比较一般的情况, 我们有标为 x_1, x_2, \dots, x_m 的 m 个项目. 对 $1 \leq i < j \leq m$, 如果项目 x_i 和 x_j 落入同一个箱子, 令 $X_{ij} = 1$. 设 $X = \sum_{1 \leq i < j \leq m} X_{ij}$ 是项目对之间的冲突个数, 由期望的线性性,

$$E[X] = E\left[\sum_{1 \leq i < j \leq m} X_{ij}\right] = \sum_{1 \leq i < j \leq m} E[X_{ij}].$$

因为散列函数取自 2 维通用散列函数族, 因此

$$E[X_{ij}] = \Pr(h(x_i) = h(x_j)) \leq \frac{1}{n},$$

所以

$$E[X] \leq \binom{m}{2} \frac{1}{n} < \frac{m^2}{2n}. \quad (13.1)$$

由马尔可夫不等式得

$$\Pr\left(X \geq \frac{m^2}{n}\right) \leq \Pr(X \geq 2E[X]) \leq \frac{1}{2}.$$

如果现在假定一个箱子中的最多项目个数是 Y , 那么冲突数 X 必至少为 $\binom{Y}{2}$. 所以,

$$\Pr\left(\binom{Y}{2} \geq \frac{m^2}{n}\right) \leq \Pr\left(X \geq \frac{m^2}{n}\right) \leq \frac{1}{2},$$

这蕴涵

$$\Pr(Y \geq m\sqrt{2/n}) \leq \frac{1}{2}.$$

特别在 $m = n$ 的情况下, 以至少 $1/2$ 的概率最大负荷最多是 $\sqrt{2n}$.

这个结果比完美随机散列函数的弱, 但它对任意一个 2 维通用散列函数族成立, 这是极其一般的结论. 如我们将在 13.3.3 节描述的那样, 这个结果对设计完美散列函数是有用的.

13.3.1 例: 一个 2 维通用散列函数族

设全域 U 是集合 $\{0, 1, 2, \dots, m-1\}$, 散列函数的值域是 $V = \{0, 1, 2, \dots, n-1\}$, $m \geq n$. 考虑由选取一个素数 $p \geq m$ 得到的散列函数族, 记

$$h_{a,b}(x) = ((ax + b) \bmod p) \bmod n,$$

然后取族

$$\mathcal{H} = \{h_{a,b} \mid 1 \leq a \leq p-1, 0 \leq b \leq p-1\}.$$

注意这里的 a 不能取值 0.

引理 13.6 \mathcal{H} 是 2 维通用的.

证明 我们对 \mathcal{H} 中使来自 U 的两个不同元素 x_1 和 x_2 冲突的函数个数进行计数.

首先注意到, 对任意 $x_1 \neq x_2$,

$$ax_1 + b \neq ax_2 + b \pmod{p}$$

是成立的, 因为 $ax_1 + b = ax_2 + b \pmod{p}$ 蕴涵 $a(x_1 - x_2) = 0 \pmod{p}$, 而这里的 a 和 $(x_1 - x_2)$ 关于

模 p 都是非零的。

事实上, 对于每一对值 (u, v) , 满足 $u \neq v$, $0 \leq u, v \leq p-1$, 恰好存在一对值 (a, b) , 使得 $ax_1 + b = u \pmod p$, 且 $ax_2 + b = v \pmod p$. 这对方程有两个未知数, 它的唯一解为:

$$a = \frac{v-u}{x_2-x_1} \pmod p,$$

$$b = u - ax_1 \pmod p.$$

因为对于每对 (a, b) , 恰好存在一个散列函数, 因此 \mathcal{H} 中恰好存在一个散列函数, 使得

$$ax_1 + b = u \pmod p, \quad ax_2 + b = v \pmod p.$$

所以当 $h_{a,b}$ 是从 \mathcal{H} 中均匀随机地选取时, 为了界定 $h_{a,b}(x_1) = h_{a,b}(x_2)$ 的概率, 只需求出 (u, v) 的对数, 其中 $0 \leq u, v \leq p-1$, $u \neq v$ 但 $u = v \pmod n$. 对 u 的每一选择, 至多有 $\lceil p/n \rceil - 1$ 个对 v 是可能合适的值, 即至多给出 $p(\lceil p/n \rceil - 1) \leq p(p-1)/n$ 对. 每一对相应于 $p(p-1)$ 个散列函数之一, 所以

$$\Pr(h_{a,b}(x_1) = h_{a,b}(x_2)) \leq \frac{p(p-1)/n}{p(p-1)} = \frac{1}{n}.$$

证明了 \mathcal{H} 是 2 维通用的. ■

13.3.2 例: 一个 2 维强通用散列函数族

我们可以应用类似于引理 13.6 中构造 2 维通用散列函数族的思想来构造一个 2 维强通用散列函数族. 首先, 假定全域 U 及散列函数的值域 V 是 $\{0, 1, 2, \dots, p-1\}$, 其中 p 是某个素数. 现在令

$$h_{a,b}(x) = (ax + b) \pmod p,$$

考虑族

$$\mathcal{H} = \{h_{a,b} \mid 0 \leq a, b \leq p-1\}.$$

注意这里的 a 可以取值 0, 这与引理 13.6 中所用的散列函数不同.

引理 13.7 \mathcal{H} 是 2 维强通用的.

证明 完全类似于引理 13.2 的证明. 对 U 的任意两个不同元素 x_1 和 x_2 及 V 中任意两个值 y_1 和 y_2 , 我们需要证明

$$\Pr((h_{a,b}(x_1) = y_1) \cap (h_{a,b}(x_2) = y_2)) = \frac{1}{p^2}.$$

条件 $h_{a,b}(x_1) = y_1$ 和 $h_{a,b}(x_2) = y_2$ 产生两个含有未知值 a, b 的两个关于模 p 的等式: $ax_1 + b = y_1 \pmod p$ 及 $ax_2 + b = y_2 \pmod p$. 两个等式和两个未知数的方程组只有一个解:

$$a = \frac{y_2 - y_1}{x_2 - x_1} \pmod p,$$

$$b = y_1 - ax_1 \pmod p.$$

因此在 p^2 个可能中, 只有一对 (a, b) 的选择将 x_1 和 x_2 散列为 y_1 和 y_2 , 证得

$$\Pr((h_{a,b}(x_1) = y_1) \cap (h_{a,b}(x_2) = y_2)) = \frac{1}{p^2}.$$

正如所求. ■

虽然这给出了2维通用散列族,但要求全域 U 和值域 V 是相同的限制使结果几乎没有用处;通常我们希望将一个大的全域散列为一个比较小的值域.可以用一种容许较大全域的自然方式来推广这种构造法.设 $V = \{0, 1, 2, \dots, p-1\}$,但现在令 $U = \{0, 1, 2, \dots, p^k-1\}$,其中 k 是某个整数, p 是素数.可以将全域 U 的元素解释为一个向量 $\vec{u} = (u_0, u_1, \dots, u_{k-1})$,其中 $0 \leq u_i \leq p-1, 0 \leq i \leq k-1$,且 $\sum_{i=0}^{k-1} u_i p^i = u$.事实上,这给出了此种形式的向量与 U 中元素之间的一个一对一的映射.

对任意向量 $\vec{a} = (a_0, a_1, \dots, a_{k-1})$,其中 $0 \leq a_i \leq p-1, 0 \leq i \leq k-1$ 及任意值 $b, 0 \leq b \leq p-1$,记

$$h_{\vec{a},b}(u) = \left(\sum_{i=0}^{k-1} a_i u_i + b \right) \bmod p,$$

考虑族

$$\mathcal{H} = \{h_{\vec{a},b} \mid 0 \leq a_i, b \leq p-1, \text{对所有 } 0 \leq i \leq k-1\}.$$

引理 13.8 \mathcal{H} 是2维强通用的.

证明 按照引理13.7的证明,对任意两个元素 u_1 和 u_2 (它们相应的向量 $\vec{u}_i = (u_{i,0}, u_{i,1}, \dots, u_{i,k-1})$)及 V 中任意两个值 y_1 和 y_2 ,需要证明

$$\Pr((h_{\vec{a},b}(u_1) = y_1) \cap (h_{\vec{a},b}(u_2) = y_2)) = \frac{1}{p^2}.$$

因为 u_1, u_2 是不同的,它们必须至少有一个坐标不同.不失一般性,设 $u_{1,0} \neq u_{2,0}$.对任意给定的 a_1, a_2, \dots, a_{k-1} 的值,条件 $h_{\vec{a},b}(u_1) = y_1$ 及 $h_{\vec{a},b}(u_2) = y_2$ 等价于

$$a_0 u_{1,0} + b = \left(y_1 - \sum_{j=1}^{k-1} a_j u_{1,j} \right) \bmod p$$

$$a_0 u_{2,0} + b = \left(y_2 - \sum_{j=1}^{k-1} a_j u_{2,j} \right) \bmod p.$$

对任意已知的 a_1, a_2, \dots, a_{k-1} 的值,这给出了两个方程和两个未知值(a_0, b)的方程组,与引理13.7一样,恰有一个解.因此对每个 a_1, a_2, \dots, a_{k-1} ,在 p^2 个可能中,只有一对(a_0, b)的选择将 u_1 和 u_2 散列为 y_1 和 y_2 ,证得

$$\Pr((h_{\vec{a},b}(u_1) = y_1) \cap (h_{\vec{a},b}(u_2) = y_2)) = \frac{1}{p^2},$$

正如所求. ■

虽然用一个素数的算术模描述了2维通用及2维强通用散列函数族,但可以将这些技术推广到一般的有限域上,特别是用 n 个二进制数字序列表示的 2^n 个元素的域上.推广要求有限域的知识,所以在这里只是概略地叙述结果.条件及证明与引理13.8完全一样,除了代替模 p 的在有 2^n 个元素的固定有限域上进行所有的计算.假定有一个从 n 个二进制数字的串(这也可以认为是 $\{0, 1, \dots, 2^n-1\}$ 中的数)到域元素的一个固定的一对一映射 f ,令

$$h_{x,S}(u) = f^{-1} \left(\sum_{i=0}^{k-1} f(a_i) \cdot f(u_i) + f(b) \right),$$

其中 a_i 和 b 是在 $\{0, 1, \dots, 2^n - 1\}$ 中独立且均匀随机地选取的, 且加法与乘法是在域上执行的, 这就给出一个值域大小为 2^n 的 2 维通用散列函数.

13.3.3 应用: 完美散列

完美散列是存储一种静态程序库的有效数据结构. 在静态程序库中, 项目永久地存储在一个表中. 一旦项目被存储, 表就只用于搜索运算: 对一个项目的搜索给出项目在表中的位置, 或返回项目不在此表中.

假定 m 个项目的集合 S 利用来自 2 维通用族且是链散列的散列函数散列到一个有 n 个接收器的表中. 在链散列中(见 5.5.1 节), 散列到相同接收器中的项目保存在一个链表中, 为查寻一个项目 x 的运算次数与 x 的接收器中的项目数成比例. 我们有下面简单的界.

引理 13.9 假定 m 个元素通过利用一个均匀随机地取自 2 维通用族的散列函数 h 散列到 n 个接收器的链散列表中. 对任意元素 x , 设 X 是接收器 $h(x)$ 中的项目数, 那么

$$E[X] \leq \begin{cases} m/n & \text{如果 } x \notin S, \\ 1 + (m-1)/n & \text{如果 } x \in S. \end{cases}$$

证明 如果 S 的第 i 个元素(在某个任意次序下)与 x 在同一个接收器中, 令 $X_i = 1$; 否则为 0. 因为散列函数取自 2 维通用族, 因此

$$\Pr(X_i = 1) = 1/n.$$

所以由

$$E[X] = E \left[\sum_{i=1}^m X_i \right] = \sum_{i=1}^m E[X_i] \leq \frac{m}{n},$$

第一个结果成立, 其中为了得出 $E[X_i] \leq 1/n$, 用到了散列函数的通用性. 类似地, 如果 x 是 S 的元素, 那么(不失一般性)令它是 S 的第一个元素, 因此 $X_1 = 1$, 当 $i \neq 1$ 时, 仍有

$$\Pr(X_i = 1) = 1/n.$$

所以

$$E[X] = E \left[\sum_{i=1}^m X_i \right] = 1 + \sum_{i=2}^m E[X_i] \leq 1 + \frac{m-1}{n}. \quad \blacksquare$$

引理 13.9 说明, 在利用来自 2 维通用族的散列函数时, 散列的平均性能是好的, 因为仔细查看任意项目的接收器的时间被一个较小的数界定. 例如, 如果 $m = n$, 那么当搜索 x 的散列表时, 必须检查的不同于 x 的项目的期望数至多为 1. 然而, 这没有给出对最坏情况的搜索时间的界. 某些接收器可能有 \sqrt{n} 个或更多的元素, 而搜索这些元素中的一个要求长得多的查寻时间.

这激发了完美散列的思想. 给定一个集合 S , 我们将构造一个散列表, 以给出非常好的最坏情况的执行, 特别地, 完美散列要求以一个不变的运算次数去寻找散列表中的一个项目(或确定它不在表中).

首先证明完美散列是容易的, 如果对散列表及一个合适的 2 维通用散列函数族有足够

空间.

引理 13.10 如果 $h \in \mathcal{H}$ 是从将全域 U 映射到 $[0, n-1]$ 的 2 维通用散列函数族中均匀随机地选取的, 那么对任意大小为 m 的集合 $S \subset U$, 当 $n \geq m^2$ 时, h 是完美的概率至少为 $1/2$.

证明 设 s_1, s_2, \dots, s_m 是 S 的 m 个项目, 如果 $h(s_i) = h(s_j)$, 令 $X_{i,j} = 1$ 为 1; 否则为 0. 令 $X = \sum_{1 \leq i < j \leq m} X_{i,j}$, 那么如我们在 (13.1) 式所见到的那样, 当使用 2 维通用散列函数时, 冲突的期望个数是

$$E[X] = E\left[\sum_{1 \leq i < j \leq m} X_{i,j}\right] = \sum_{1 \leq i < j \leq m} E[X_{i,j}] \leq \binom{m}{2} \frac{1}{n} < \frac{m^2}{2n}.$$

由马尔可夫不等式可知

$$\Pr\left(X \geq \frac{m^2}{n}\right) \leq \Pr(X \geq 2E[X]) \leq \frac{1}{2}.$$

因此, 当 $n \geq m^2$ 时, 我们以至少 $1/2$ 的概率发现 $X < 1$. 这蕴涵以至少 $1/2$ 的概率, 一个随机选取的散列函数是完美的. \blacksquare

为在 $n \geq m^2$ 时找到一个完美散列函数, 可以简单地尝试从 2 维通用族中均匀随机地选取的散列函数, 直至找到一个无冲突的为止. 这给出 Las Vegas 算法, 平均至多需要两个散列函数.

我们想到不要求 $\Omega(m^2)$ 个接收器空间的完美散列来存储 m 个项目的集合, 用两水平方案完成完美散列只需 $O(m)$ 个接收器. 首先利用一个来自 2 维通用族的散列函数将集合散列到有 m 个接收器的散列表, 其中某些接收器有冲突. 对每一个这样的接收器, 从合适的 2 维通用族中提供第二个散列函数及完全分离的第二张散列表. 如果在接收器中有 $k > 1$ 个项目, 那么第二张散列表用 k^2 个接收器. 在引理 13.10 中已经证明, 以 k^2 个接收器可以从 2 维通用族中找到一个没有冲突的散列函数. 剩下的只需证明, 利用谨慎选择的第一个散列函数, 可以保证算法用到的总空间只是 $O(m)$. [327]

定理 13.11 两水平方法给出一个利用 $O(m)$ 个接收器的 m 个项目的完美散列方案.

证明 如在引理 13.10 中证明的那样, 第一阶段的冲突数 X 满足

$$\Pr\left(X \geq \frac{m^2}{n}\right) \leq \Pr(X \geq 2E[X]) \leq \frac{1}{2}.$$

当 $n = m$ 时, 这表示有多于 m 个冲突的概率至多为 $1/2$. 利用概率方法, 存在从 2 维通用散列函数族的一个选取在第一阶段给出至多 m 个冲突. 事实上, 通过尝试从 2 维通用族中均匀随机地选取的散列函数的 Las Vegas 算法, 可以有效地找到这样的散列函数. 所以可以假定在第一阶段已经找到了至多有 m 个冲突的散列函数.

设 c_i 是第 i 个接收器中的项目个数, 那么在第 i 个接收器中的项目之间存在 $\binom{c_i}{2}$ 个冲突, 所以

$$\sum_{i=1}^m \binom{c_i}{2} \leq m.$$

对每个有 $c_i > 1$ 个项目的接收器, 我们寻找第二个利用空间 c_i^2 而没有冲突的散列函数. 对每个

接收器, 仍可利用 Las Vegas 算法找到这个散列函数. 所用的接收器总数有上界

$$m + \sum_{i=1}^m c_i^2 \leq m + 2 \sum_{i=1}^m \binom{c_i}{2} + \sum_{i=1}^m c_i \leq m + 2m + m = 4m.$$

因此所用的接收器总数只是 $O(m)$. ■

13.4 应用: 在数据流中寻找重量级的源-终点

路由器通过网络发送数据包. 在一天结束时, 向网络管理员提出的一个自然的问题是: 从源点 s 到终点 d 通过路由器发送的字节数是否大于预先确定的阈值. 我们称这样一对源-终点为重量级的源-终点.

在设计寻找重量级的源-终点算法时, 必须记住对路由器的限制. 路由器只能有很少的内存, 所以不可能保存每一可能对子 s 和 d 的记录, 因为有太多这样的对子. 路由器还必须很快地发送数据包, 所以路由器对每个数据包必须只执行少量的几个计算操作. 我们提出即使对这些限制也适用的随机化数据结构. 这样的数据结构要求一个阈值 q , 所有负责至少 q 个总字节数的源-终点对认为是重量级的. q 通常是每日总期望流量的某个固定的百分数, 比如 1%. 在一天结束时, 数据结构给出一张可能的重量级源-终点列表. 所有真的重量级源-终点 (至少负责 q 个字节) 被列出, 但某些其他对也可能出现在此列表中. 另外两个输入常数 ε 和 δ 用于控制什么样的无直接关联的对可能被列入重量级源-终点列表中. 假定 Q 表示一天时间中总的字节数, 我们的数据结构保证包含少于 $q - \varepsilon Q$ 个字节流量的任意一个源-终点对至多以 δ 的概率在列表中. 换言之, 所有重量级源-终点在列表中, 所有与重量级源-终点充分远的对至多以 δ 的概率在列表中; 接近于重量级源-终点的对可能在也可能不在列表中.

这个路由器的例子是许多希望保持一个大数流简单扼要情况的典型. 在大部分数据流模型中, 大量数据依次到达小块, 每个块必须在下一个块到达之前进行处理. 在网络路由器设置中, 每个块一般是一个数据包. 要处理的数据量通常是相当大的, 到达之间的时间是相当短的, 要求算法和数据结构对每个块只能用少量的内存及计算.

可以利用在 5.5.3 节讨论过的一种变化的 Bloom 过滤器来解决这个问题. 与那里假定用完全随机散列函数的解不同, 这里只用 2 维通用散列函数族得到更强的可证实的界. 这是重要的, 因为路由器设置的效率要求只用容易计算的非常简单的散列函数, 同时也想得到可证实的执行保证.

我们的数据结构称为最小计数过滤器, 最小计数过滤器处理一系列形如 $X_i = (i, c_i)$ 的对子流 X_1, X_2, \dots , 其中 i 是一个项目, $c_i > 0$ 是整数计数增量. 在路由器设置中, i 是一个包的源点-终点地址对, c_i 是包中的字节数, 记

$$\text{Count}(i, T) = \sum_{1 \leq j \leq i, 1 \leq k \leq T} c_k,$$

即 $\text{Count}(i, T)$ 是与项目 i 关联的直到时间 T 的总的计数. 在路由器设置中, $\text{Count}(i, T)$ 是与地址对 i 的数据包关联的直到时间 T 的字节总数. 最小计数过滤器对所有项目 i 及所有时间 T , 以可以跟踪重量级源-终点的方式保持 $\text{Count}(i, T)$ 的一个运行近似.

一个最小计数过滤器由 m 个计数器组成, 以后假定我们的计数器有足够多的位, 使得不

必为溢出担心。在许多实际情况中，32 位计数器已经足够了，且执行也是方便的。一个最小计数过滤器利用 k 个散列函数，我们将计数器分成 k 个大小为 m/k 的相互分离的组 G_1, G_2, \dots, G_k 。为方便起见，以后假定 m 可被 k 整除。用 $C_{a,j}(1 \leq a \leq k, 0 \leq j \leq m/k - 1)$ 为计数器标号，使得 $C_{a,j}$ 对应于第 a 组的第 j 个计数器，即可以将计数器看成具有 2 维数组的形式，每行有 m/k 个计数器，共有 k 列散列函数将项目从全域映射到计数器，所以有散列函数 H_a ，其中 $1 \leq a \leq k, H_a: U \rightarrow [0, m/k - 1]$ 。即 k 个散列函数的每一个取一个来自全域的项目，并将它映射为一个数 $[0, m/k - 1]$ 。等价地，可以将每个散列函数看作取一个项目 i 并将它映射到计数器 $C_{a,H_a(i)}$ ， H_a 应是从 2 维通用散列族独立且均匀随机地选取的。

3.29

利用我们的计数器保持 $\text{Count}(i, T)$ 的近似踪迹。开始时，所有计数器都设置为 0。为处理一对 (i, c_i) ，对每个 $a(1 \leq a \leq k)$ 计算 $H_a(i)$ 及相差 c_i 的增量 $C_{a,H_a(i)}$ 。设 $C_{a,j}(T)$ 是处理从 X_1 直到 X_T 后计数器 $C_{a,j}$ 的值。我们断言：对任一项目，与那个项目关联的最小计数器是其计数的一个上界，且与那个项目关联的最小计数器以有界的概率离开不多于直到那个点处理过的所有对 (i, c_i) 的总计数的 ε 倍。特别有下面的定理。

定理 13.12 对全域 U 中的任意 i 及任意序列 $(i_1, c_1), \dots, (i_T, c_T)$,

$$\min_{j=H_a(i), 1 \leq a \leq k} C_{a,j}(T) \geq \text{Count}(i, T).$$

进一步，以 $1 - (k/m\varepsilon)^k$ 的概率对散列函数的选择，有

$$\min_{j=H_a(i), 1 \leq a \leq k} C_{a,j}(T) \leq \text{Count}(i, T) + \varepsilon \sum_{t=1}^T c_t.$$

证明 第一个界

$$\min_{j=H_a(i), 1 \leq a \leq k} C_{a,j}(T) \geq \text{Count}(i, T)$$

是平凡的。当在流中看到对 (i, c_i) 时，每个满足 $j = H_a(i)$ 的计数器 $C_{a,j}$ 有增量 c_i 。由此，每个这样的计数器的值在任何时间 T 至少为 $\text{Count}(i, T)$ 。

对第二个界，考虑任意特殊的 i 和 T 。首先考虑特殊的计数器 $C_{1,H_1(i)}$ ，然后利用对称性。我们知道经前 T 对之后，这个计数器的值至少为 $\text{Count}(i, T)$ 。设随机变量 Z_i 是由于不同于 i 的项目引起的计数器的增量，设 X_i 是这样一个随机变量：当 $i_t \neq i$ 但 $H_1(i_t) = H_1(i)$ 时， X_i 取值为 1；否则取值为 0。那么

$$Z_i = \sum_{\substack{t: 1 \leq t \leq T, i_t \neq i \\ H_1(i_t) = H_1(i)}} c_t = \sum_{t=1}^T X_i c_t.$$

由于 H_1 是从 2 维通用族中选取的，对任 $i_t \neq i$ ，有

$$\Pr(H_1(i_t) = H_1(i)) \leq \frac{k}{m}.$$

因此

$$E[X_i] \leq \frac{k}{m}.$$

由此



330

$$E[Z_1] = E\left[\sum_{i=1}^r X_i c_i\right] = \sum_{i=1}^r c_i E[X_i] \leq \frac{k}{m} \sum_{i=1}^r c_i.$$

由马尔可夫不等式,

$$\Pr(Z_1 \geq \varepsilon \sum_{i=1}^r c_i) \leq \frac{k/m}{\varepsilon} = \frac{k}{m\varepsilon}. \quad (13.2)$$

设 Z_2, Z_3, \dots, Z_l 是对应于每一个其他散列函数的随机变量, 由对称性, 所有 Z_i 满足 (13.2) 式的概率界. 此外, Z_i 是独立的, 这是因为散列函数是从散列函数族中独立选取的, 因此

$$\Pr(\min_{j=1}^l Z_j \geq \varepsilon \sum_{i=1}^r c_i) = \prod_{j=1}^l \Pr(Z_j \geq \varepsilon \sum_{i=1}^r c_i) \quad (13.3)$$

$$\leq \left(\frac{k}{m\varepsilon}\right)^l. \quad (13.4)$$

由计算容易查验, 当 $k = m\varepsilon/e$ 时, $(k/m\varepsilon)^l$ 达到极小, 此时

$$\left(\frac{k}{m\varepsilon}\right)^l = e^{-m\varepsilon^l/e}.$$

当然, k 是需要选择的, 使 k 和 m/k 都是整数, 但这不会从本质上影响概率界.

可以利用最小计数过滤器按下面的方式跟踪路由设置中的重量级源-终点. 当一对 (i_r, c_r) 到达时, 更新最小计数过滤器. 如果与 i_r 关联的最小散列值至少是重量级源-终点的阈值 q , 那么将此项目放入可能的重量级源-终点列表中. 我们不关心执行此列表的运算细节, 但注意它可以编组, 使得容许利用标准的平衡搜索树数据结构以它本身大小的对数时间进行更新及搜索; 另外它也可以编组成更大的数组或一个散列表.

回忆用 Q 表示一天结束时的总流量.

推论 13.13 假定利用一个有 $k = \left\lceil \ln \frac{1}{\delta} \right\rceil$ 个散列函数、 $m = \left\lceil \ln \frac{1}{\delta} \right\rceil \cdot \left\lceil \frac{e}{\varepsilon} \right\rceil$ 个计数器及阈值 q 的最小计数过滤器. 那么所有重量级源-终点放入列表中, 而且任意对应于少于 $q - \varepsilon Q$ 个字节的源-终点对以至多 δ 的概率放入列表中.

证明 因为计数关于时间是递增的, 所以可简单地考虑一天结束时的情况. 由定理 13.12, 最小计数过滤器将保证所有真的重量级源-终点放入列表中, 这是因为一个真的重量级源-终点的计数器值至少为 q . 而且由定理 13.12, 对任意一对源-终点, 对应于小于 $q - \varepsilon Q$ 字节的最小计数器值达到 q 的概率至多为

$$\left(\frac{k}{m\varepsilon}\right)^k \leq e^{-\ln(1/\delta)} = \delta.$$

331

最小计数过滤器在只利用它的散列函数中的有限随机性、 $O\left(\frac{1}{\varepsilon} \ln \frac{1}{\delta}\right)$ 个计数器以及 $O(\ln 18)$ 次计算来处理每个项目方面是非常有效的. (处理依赖于其表示的可能的重量级源-终点列表可能要求额外的计算及空间.)

在结束最小计数过滤器的讨论之前, 我们描述一个简单的改进, 称为保守的更新, 虽然难以分析, 但在实际中常能很好地运用. 当一个对子 (i, c_i) 到达时, 原最小计数过滤器对项目 i

散列到的每个计数器 $C_{a,j}$ 增加 c_i , 以保证

$$\min_{j=H_a(i), 1 \leq a \leq k} C_{a,j}(T) \geq \text{Count}(i, T)$$

对所有的 i 和 T 成立. 事实上, 不对每个计数器都增加 c_i 通常也能保证上式成立. 考虑处理第 $(t-1)$ 对以后的状态. 归纳地假定对所有 i , 直到我们进行的那一点, 有

$$\min_{j=H_a(i), 1 \leq a \leq k} C_{a,j}(t-1) \geq \text{Count}(i, t-1).$$

那么当 (i, c_i) 到达时, 我们需要对所有计数器保证

$$C_{a,j}(t) \geq \text{Count}(i, t),$$

其中 $j = H_a(i)$, $1 \leq a \leq k$, 但

$$\text{Count}(i, t) = \text{Count}(i, t-1) + c_i \leq \min_{j=H_a(i), 1 \leq a \leq k} C_{a,j}(t-1) + c_i.$$

因此, 可以考虑从 i 散列到的 k 个计数器得到的最小计数器值 v , 将 c_i 加到那个值上, 并将任意小于 $v+c_i$ 的计数器增加到 $v+c_i$. 图 13.1 给出了一个例子. 一个计数为 3 的项目到达; 在到达时刻, 与此项目关联的最小计数器值为 4. 由此, 对这个项目的计数至多为 7, 所以可以更新所有关联的计数器以保证它们全都至少为 7. 一般地, 如果所有 i 散列的计数器是相等的, 则保守的更新等价于每个计数器只增加 c_i . 当 i 不全相等时, 保守的更新改进对某些计数器增加较少, 这将趋于减少过滤器产生的误差.

(i, 3)

3	8	5	1
4	8	3	2
3	0	5	9

3	8	5	1
7	8	3	2
3	0	7	9

图 13.1 一个项目到达, 计数增加 3. 左边是初始状态, 阴影部分的计数器需要更新. 利用保守的更新, 最小计数器值 4 确定所有相应的计数器需要至少增加到 $4+3=7$. 经更新后所得的状态如右图所示

332

练习

- 13.1 一枚均匀的硬币抛掷 n 次, 如果第 i 次和第 j 次抛掷出现同一面, 那么令 X_{ij} 为 1, 其中 $1 \leq i < j \leq n$; 否则为 0. 证明 X_{ij} 两两独立, 但不独立.
- 13.2 (a) 设 X, Y 是从 $\{0, 1, \dots, n\}$ 中独立地且均匀随机地选取的数, 令 Z 是它们关于模 $n+1$ 的和. 证明 X, Y 及 Z 两两独立, 但不是独立的.
- (b) 推广这个例子给出一个随机变量的集合, 它们是每 k 个独立, 但不是每 $(k+1)$ 个独立的.
- 13.3 对任意一个从有限集合 U 到有限集合 V 的散列函数族, 证明当 h 是从那个散列函数族中随机选取时, 存在一对元素 x, y , 使

$$\Pr(h(x) = h(y)) \geq \frac{1}{|V|} - \frac{1}{|U|}.$$

这个结果应不依赖于函数 h 是如何从族中选取的。

- 13.4 证明对任意在值域 $[0, 1]$ 上取值的离散随机变量 X , $\text{Var}[X] \leq 1/4$.
- 13.5 假定有一个随机化算法 Test , 按如下步骤检验一个串是否出现在一种语言 L 中. 给定一个输入 x , 算法 Test 从集合 $S = \{0, 1, \dots, p-1\}$ (其中 p 是某个素数) 中均匀地选取一个随机整数 r . 如果 x 在这种语言中, 那么对 r 的至少一半的可能值, $\text{Test}(x, r) = 1$. 一个使 $\text{Test}(x, r) = 1$ 的 r 值称为 x 的证据. 如果 x 不在此语言中, 那么总有 $\text{Test}(x, r) = 0$.

如果对一个输入 $x \in L$, 通过独立地且均匀地从 S 选取两个数 r_1 和 r_2 来运行算法 Test 两次, 得到 $\text{Test}(x, r_1)$ 和 $\text{Test}(x, r_2)$, 那么我们至少以 $3/4$ 的概率找到证据. 证明: 令 $s_i = r_1 i + r_2 \pmod p$, 计算 $\text{Test}(x, r_i)$, $0 \leq i \leq t < p$, 利用相同的随机性量, 可以以至少 $1 - 1/t$ 的概率得到一个证据.

- 13.6 在 5.2.2 节的桶排序分析中假定 n 个元素是从值域 $[0, 2^t)$ 中独立地且均匀随机地选取的, 假如代之以 n 个元素是从 $[0, 2^t)$ 中只是两两独立地均匀选取的. 证明在这些条件下, 桶排序仍然要求线性期望时间.

333

- 13.7 (a) 我们已经证明当利用从 2 维通用散列函数族中选取的散列函数将 n 个项目散列到 n 个接收器时, 极大负荷以至少 $1/2$ 的概率至多为 $\sqrt{2n}$. 推广这一论证到 k 维通用散列函数族, 即求一个值使极大负荷大于此值的概率至多为 $1/2$;

(b) 在引理 5.1 中已经证明在标准的球和箱子模型下, 当 n 个球独立地且均匀随机地投入 n 个箱子时, 最大负荷以 $1 - 1/n$ 的概率至多为 $3 \ln n / \ln \ln n$. 求最小的 k 值, 使得当从 k 维通用族中选取散列函数时, 极大负荷至少以 $1/2$ 的概率至多为 $3 \ln n / \ln \ln n$.

- 13.8 可以将求最大割问题推广到求最大 k -割. 一个 k -割是将顶点分成 k 个相互分离集合的一种划分, 一个割的值是从 k 个集合之一横跨另一个集合的所有边的权. 在 13.1.2 节, 我们考虑了所有权为 1 的 2-割, 证明了如何利用 n 个两两独立的二进制数字集合消去标准随机化算法的随机性. 解释如何推广这种消去随机性方法以得到 3-割的多项式时间算法, 并给出你的算法的运行时间. (提示: 可能要利用在 13.3.2 节找到的那种类型的散列函数.)

- 13.9 假定已知 m 个向量 $\vec{v}_1, \vec{v}_2, \dots, \vec{v}_m \in \{0, 1\}^\ell$, 使得 m 个向量中的任意 k 个是关于模 2 线性独立的. 令 $\vec{v}_i = (v_{i,1}, v_{i,2}, \dots, v_{i,\ell})$, \vec{u} 是从 $\{0, 1\}^\ell$ 中均匀随机地选取的, $X_i = \sum_{j=1}^{\ell} v_{i,j} u_j \pmod 2$. 证明 X_i 是均匀的每 k 个独立的二进制数字.

- 13.10 我们检查 2 维通用散列函数不同于完全随机散列函数的一种特殊方法. 令 $S = \{0, 1, 2, \dots, k\}$, 考虑一个值域为 $\{0, 1, 2, \dots, p-1\}$ 的散列函数, 其中 p 是比 k 大得多的某个素数. 考虑值 $h(0), h(1), \dots, h(k)$. 如果 h 是完全随机散列函数, 那么 $h(0)$ 小于任一其他值的概率约为 $1/(k+1)$. (最小值可能有结, 所以任意 $h(i)$ 有唯一最小值的概率稍小于 $1/(k+1)$.) 现在考虑从 13.3.2 节的族

$$\mathcal{H} = \{h_{a,b} \mid 0 \leq a, b \leq p-1\}$$

中均匀选取的散列函数 h . 通过从 \mathcal{H} 中随机选取 10 000 个散列函数并对所有 $x \in S$ 计算

$h(x)$ 的方法估计 $h(0)$ 小于 $h(1), \dots, h(k)$ 的概率. 对 $k=32$ 及 $k=128$, 利用素数 $p=5\,023\,309$ 及 $p=10\,570\,849$ 运行这个试验, 你的估计是否接近 $1/(k+1)$?

- 13.11 在一个多重集合中, 每个元素可以出现多次. 假定有两个由正整数组成的多重集合 S_1 和 S_2 , 我们希望检验这两个集合是否“相同”, 即如果每个项在每个集合中出现相同的次数. 一种检验方法是对两个集合排序, 然后按所排次序进行比较. 如果每个多重集合包含 n 个元素, 这需花费 $O(n \log n)$ 的时间.

(a) 考虑下面的算法. 将 S_1 的每个元素散列到一个有 cn 个计数器的散列表, 计数器的初值为 0, 第 i 个计数器每次增加一个元素的散列值为 i . 利用另一个同样大小的表及同一个散列函数, 对 S_2 进行同样的运算. 如果对所有的 i , 第一张表中的第 i 个计数器与第二张表中的第 i 个计数器是匹配的, 则报告集合是相同的; 否则, 报告集合是不同的.

[334]

分析这种算法的运行时间及错误概率, 假定散列函数是从 2 维通用族中选取的. 解释这种算法如何可以推广为蒙特卡罗算法, 并分析其运行时间与错误概率之间的权衡.

- (b) 对此问题也可以设计一种 Las Vegas 算法. 现在散列表中的每个元素对应于计数器的链表. 每个元素占有一个散列到那个位置的每个元素出现次数的列表, 这个列表可以依排序次序保存. 仍对 S_1 创建一个散列表, 对 S_2 创建一个散列表, 我们检验经散列后所得到的表是否相等.

证明这种算法只利用线性空间只要求线性期望时间.

- 13.12 在 13.3.1 节证明了当 $p \geq n$ 时, 族

$$\mathcal{H} = \{h_{a,b} \mid 1 \leq a \leq p-1, 0 \leq b \leq p\}$$

是 2 维通用的, 其中

$$h_{a,b}(x) = ((ax + b) \bmod p) \bmod n.$$

现在考虑散列函数

$$h_a(x) = (ax \bmod p) \bmod n$$

及族

$$\mathcal{H}' = \{h_a \mid 1 \leq a \leq p-1\}.$$

给出一个例子说明 \mathcal{H}' 不是 2 维通用的. 然后证明 \mathcal{H}' 在下列意义下几乎是通用的: 对任意 $x, y \in \{0, 1, 2, \dots, p-1\}$, 如果 h 是从 \mathcal{H}' 均匀随机选取的, 那么

$$\Pr(h(x) = h(y)) \leq \frac{2}{n}.$$

- 13.13 在描述最小计数过滤器时, 假设数据流由形如 (i_i, c_i) 的对组成, 其中 i_i 是一个项目, $c_i > 0$ 是整数计数增量. 假定容许减少项目的计数, 使得流可以包括形如 (i_i, c_i) ($c_i < 0$) 的对. 可以要求一个项目 i 的总计数

$$\text{Count}(i, T) = \sum_{c_i = -1, 1 \leq i \leq T} c_i$$

总是正的.

在这种情况下, 解释如何修改或者利用最小计数过滤器寻找重量级源-终点.

[335]

*第14章 平衡配置

在这一章中，我们分析经典的球和箱子范例的一个简单而有用的变形及其在散列与动态资源配置中的应用。

14.1 两种选择的影响力

假定通过将每个球放入一个独立、均匀随机选取的箱子的方法将 n 个球依次放入 n 个箱子里。我们在第5章已经研究过这个经典的球和箱子问题了。当时已经证明在过程结束时，任一箱子中的最多球数——最大负荷——以大的概率为 $\Theta(\ln n / \ln \ln n)$ 。

在另一种放置过程中，每个球放入 d 个可能的目的箱子，每个箱子都是独立、均匀随机地选取的，将球放入 d 种可能位置中在放置时最不满的那个箱子中。那么原先的球和箱子问题相应于 $d=1$ 的情况。令人吃惊的是即使当 $d=2$ 时，其性质也完全不同：在过程结束时，以大的概率最大负荷是 $\ln \ln n / \ln 2 + O(1)$ 。因此，在这个随机放置过程中，一个明显是微小的改变导致最大负荷按指数级减少。那么我们可能会问：如果每个球有 3 种选择将会怎样；也许所得的负荷会是 $O(\ln \ln \ln n)$ 。我们将考虑每个球有 d 种选择的一般情况，并证明当 $d \geq 2$ 时，以大的概率最大负荷是 $\ln \ln n / \ln d + \Theta(1)$ 。虽然有多于两种的选择会减少最大负荷，但是减少量对它只改变一个常数因子，所以最大负荷仍是 $\Theta(\ln \ln n)$ 。

14.1.1 上界

定理 14.1 假定按下列方式将 n 个球依次放入 n 个箱子中。对每个球，独立、均匀随机地（有放回）选取 $d \geq 2$ 个箱子。每个球放入 d 个箱子中在放置时最不满的那个箱子中，并随机地打破结。将所有球都放完后，以 $1 - o(1/n)$ 的概率，任意一个箱子的最大负荷至多是 $\ln \ln n / \ln d + O(1)$ 。

336

证明是相当麻烦的，因此在开始之前，我们先非正式地列出几个要点。为了找到最大负荷的界，我们需要对所有的 i 值近似地给出有 i 个球的箱子个数的界。事实上，对于任意给定的 i ，不试图给出负荷恰为 i 的箱子数的界，而给出负荷至少为 i 的箱子数的界会容易一些。大部分证明过程是通过直接的归纳法。我们希望找到一系列 β_i 值，使得以大的概率负荷至少为 i 的箱子数的上界是 β_i 。

假定已知在整个放置过程中，负荷至少是 i 的箱子数的上界是 β_i 。我们考虑怎样确定一个适当的以大的概率成立的 β_{i+1} 的归纳界。定义一个球的高度是放置该球的箱子中已有的球的个数加 1。也就是说，如果把球看作是按照到达次序堆放在箱子里的，那么一个球的高度就是它在堆放中的位置。高度至少为 $i+1$ 的球的个数给出至少有 $i+1$ 个球的箱子的个数的上界。

一个球的高度至少是 $i+1$ ，仅当它选择的 d 个箱子中的每一个的负荷至少是 i 。如果确实有至多 β_i 个箱子的负荷总是至少为 i ，那么每次选取得到一个负荷至少是 i 的箱子的概率至多是 β_i/n 。因此一个球的高度至少是 $i+1$ 的概率至多是 $(\beta_i/n)^d$ 。可以利用切尔诺夫界得出如下

结论: 以大的概率, 高度至少为 $i+1$ 的球的个数至多是 $2n(\beta_i/n)^d$. 也就是说, 如果按照上述方法进行, 那么

$$\frac{\beta_{i+1}}{n} \leq 2 \left(\frac{\beta_i}{n} \right)^d.$$

我们要在分析中认真考察这个递归过程, 并证明当 $j = \ln \ln n / \ln d + O(1)$ 时, β_j 成为 $O(\ln n)$. 在分析中必须要稍微仔细一点, 因为切尔诺夫界不再非常有用, 但由它很容易得到上述结论.

证明是相当复杂的, 这主要是因为必须近似地处理条件. 在界定 β_{j+1} 时, 我们假定已经有了一个关于 β_j 的界. 这个假定在正式的证明中必须看作是一个需要注意的条件.

我们将使用下面的记号: t 时刻的状态是指系统在刚刚放置完第 t 个球时的状态. 变量 $h(t)$ 指第 t 个球的高度, $\nu_i(t)$ 和 $\mu_i(t)$ (分别) 表示 t 时刻负荷至少为 i 的箱子的个数和高度至少是 i 的球的个数. 当上述意义明确时, 我们用 ν_i 和 μ_i 表示 $\nu_i(n)$ 和 $\mu_i(n)$. 在证明中经常要用到的一个明显而重要的事实是 $\nu_i(t) \leq \mu_i(t)$, 这是因为负荷至少是 i 的每个箱子必须至少包含一个高度至少是 i 的球.

在开始之前, 我们注意两个简单的引理. 第一个引理, 利用关于二项随机变量的特殊的切尔诺夫界, 容易由在 (4.2) 式中令 $\delta=1$ 导出.

引理 14.2

$$\Pr(B(n, p) \geq 2np) \leq e^{-np/3}. \quad (14.1)$$

下面的引理将有助于我们在主要证明中处理相关的随机变量.

引理 14.3 令 X_1, X_2, \dots, X_n 是任意域上的随机变量序列, Y_1, Y_2, \dots, Y_n 是二项随机变量序列, 满足 $Y_i = Y_i(X_1, \dots, X_i)$. 如果

$$\Pr(Y_i = 1 \mid X_1, \dots, X_{i-1}) \leq p,$$

那么

$$\Pr\left(\sum_{i=1}^n Y_i > k\right) \leq \Pr(B(n, p) > k).$$

证明 如果每次只考虑一个变量 Y_i , 那么不管 X_i 取什么值, 每个 Y_i 比成功概率是 p 的独立伯努利试验更不可能取值 1. 然后经过简单推导就可知上面的结论成立. ■

现在开始主要证明.

定理 14.1 的证明 按照前面的概要, 我们要构造 β_i 值, 使得以大的概率, 对所有 i 有 $\nu_i(n) \leq \beta_i$. 令 $\beta_4 = n/4$, 对 $4 \leq i < i^*$, 令 $\beta_{i+1} = 2\beta_i^d/n^{d-1}$, 其中 i^* 待定. 令 \mathcal{E}_i 表示事件 $\nu_i(n) \leq \beta_i$. 注意 \mathcal{E}_4 以概率 1 成立. 当只有 n 个球时, 至少有 4 个球的箱子不可能多于 $n/4$ 个. 现在证明以大的概率, 当 $4 \leq i < i^*$ 时, 如果 \mathcal{E}_i 成立, 那么 \mathcal{E}_{i+1} 也成立.

在给定的范围内固定一个 i 值. 令 Y_i 是一个二项随机变量, 满足

$$Y_i = 1, \quad \text{当且仅当} \quad h(t) \geq i+1 \text{ 且 } \nu_i(t-1) \leq \beta_i.$$

即如果第 t 个球的高度至少是 $i+1$, 并且在 $t-1$ 时负荷至少是 i 的箱子至多有 β_i 个时, Y_i 是 1. 只有当负荷至少为 i 的箱子至多有 β_i 个时, $Y_i = 1$. 这个要求好像有点奇怪, 但它可以使对条件的处理变得比较容易.

特别地, 令 ω_j 表示第 j 个球所选择的箱子. 那么

$$\Pr(Y_i = 1 \mid \omega_1, \dots, \omega_{i-1}) \leq \frac{\beta_i^d}{n^d}.$$

也就是说, 在给定由前 $i-1$ 个球所做的选择时, Y_i 为 1 的概率不超过 $(\beta_i/n)^d$. 这是因为要使 Y_i 为 1, 必须有至多 β_i 个负荷至少是 i 的箱子, 而当这个条件成立时, 对第 i 个球选择的 d 个箱子负荷全都至少为 i 的概率是 $(\beta_i/n)^d$. 如果不强迫 Y_i 是零, 如果存在多于 β_i 个负荷至少是 i 的箱子, 那么不能用这种方式给出这个条件概率的界.

记 $p_i = \beta_i^d/n^d$, 则由引理 14.3, 可以得到结论

338

$$\Pr\left(\sum_{i=1}^n Y_i > k\right) \leq \Pr(B(n, p_i) > k).$$

由于对 Y_i 的谨慎定义, 上式成立与任一事件 \mathcal{E}_i 是独立的 (没有包含如果只有 $\nu_i(i-1) \leq \beta_i$, 则 $Y_i = 1$ 条件, 不等式不一定成立.)

在条件 \mathcal{E}_i 下, 有 $\sum_{i=1}^n Y_i = \mu_{i+1}$. 因为 $\nu_{i+1} \leq \mu_{i+1}$, 有

$$\begin{aligned} \Pr(\nu_{i+1} > k \mid \mathcal{E}_i) &\leq \Pr(\mu_{i+1} > k \mid \mathcal{E}_i) \\ &= \Pr\left(\sum_{i=1}^n Y_i > k \mid \mathcal{E}_i\right) \\ &\leq \frac{\Pr\left(\sum_{i=1}^n Y_i > k\right)}{\Pr(\mathcal{E}_i)} \\ &\leq \frac{\Pr(B(n, p_i) > k)}{\Pr(\mathcal{E}_i)} \end{aligned}$$

利用引理 14.2 的切尔诺夫界给出二项分布的尾部的界. 在前面的等式中, 令 $k = \beta_{i+1} = 2np_i$, 得到

$$\Pr(\nu_{i+1} > \beta_{i+1} \mid \mathcal{E}_i) \leq \frac{\Pr(B(n, p_i) > 2np_i)}{\Pr(\mathcal{E}_i)} \leq \frac{1}{e^{p_i n/3} \Pr(\mathcal{E}_i)},$$

只要 $p_i n \geq 6 \ln n$, 上式便给出

$$\Pr(\neg \mathcal{E}_{i+1} \mid \mathcal{E}_i) \leq \frac{1}{n^2 \Pr(\mathcal{E}_i)}. \quad (14.2)$$

我们现在用

$$\begin{aligned} \Pr(\neg \mathcal{E}_{i+1}) &= \Pr(\neg \mathcal{E}_{i+1} \mid \mathcal{E}_i) \Pr(\mathcal{E}_i) + \Pr(\neg \mathcal{E}_{i+1} \mid \neg \mathcal{E}_i) \Pr(\neg \mathcal{E}_i) \\ &\leq \Pr(\neg \mathcal{E}_{i+1} \mid \mathcal{E}_i) \Pr(\mathcal{E}_i) + \Pr(\neg \mathcal{E}_i) \end{aligned} \quad (14.3)$$

的事实去掉这个条件, 只要 $p_i n \geq 6 \ln n$, 由 (14.2) 和 (14.3) 式就有

$$\Pr(\neg \mathcal{E}_{i+1}) \leq \Pr(\neg \mathcal{E}_i) + \frac{1}{n^2}. \quad (14.4)$$

因此, 只要 $p_i n \geq 6 \ln n$ 且 \mathcal{E}_i 以大的概率成立, 则 \mathcal{E}_{i+1} 也以大的概率成立. 为了得出结论, 我们还需要另外两步. 首先, 需要证明当 i 近似为 $\ln \ln n / \ln d$ 时, $p_i n < 6 \ln n$, 因为这是我们要要求的最大负荷的界. 其次, 必须分别仔细处理 $p_i n < 6 \ln n$ 的情况, 因为一旦 p_i 这么小, 切尔诺夫界就不足以给出适当的界.

令 i^* 是使得 $p_i = \beta_i^d / n^d < 6 \ln n / n$ 成立的最小 i 值. 我们证明 i^* 是 $\ln \ln n / \ln d + O(1)$. 为此, 归纳地证明界

$$\beta_{i+1} = \frac{n}{2^{2^{d^i} - \sum_{j=0}^{i-1} d^j}}$$

当 $i=0$ 时, 上式成立, 归纳证明如下:

$$\begin{aligned} \beta_{(i+1)+1} &= \frac{2\beta_{i+1}^d}{n^{d-1}} \\ &= \frac{2 \left(\frac{n}{2^{2^{d^i} - \sum_{j=0}^{i-1} d^j}} \right)^d}{n^{d-1}} \\ &= \frac{n}{2^{2^{d^{i+1}} - \sum_{j=0}^i d^j}} \end{aligned}$$

第一行是 β_i 的定义, 第二行是由于归纳假设. 由此 $\beta_{i+1} \leq n/2^{d^i}$, 且因此 i^* 是 $\ln \ln n / \ln d + O(1)$. 归纳地利用(14.4)式, 我们得到

$$\Pr(\neg \mathcal{E}_{i^*}) \leq \frac{i^*}{n^2}.$$

现在处理 $p_i n < 6 \ln n$ 的情况. 我们有

$$\begin{aligned} \Pr(\nu_{i^*+1} > 18 \ln n \mid \mathcal{E}_{i^*}) &\leq \Pr(\mu_{i^*+1} > 18 \ln n \mid \mathcal{E}_{i^*}) \\ &\leq \frac{\Pr(B(n, 6 \ln n/n) \geq 18 \ln n)}{\Pr(\mathcal{E}_{i^*})} \\ &\leq \frac{1}{n^2 \Pr(\mathcal{E}_{i^*})}, \end{aligned}$$

其中最后一个不等式还是由于切尔诺夫界. 像前面那样去掉条件而得

$$\Pr(\nu_{i^*+1} > 18 \ln n) \leq \Pr(\neg \mathcal{E}_{i^*}) + \frac{1}{n^2} \leq \frac{i^* + 1}{n^2}. \quad (14.5)$$

为了整理, 注意到

$$\Pr(\nu_{i^*+3} \geq 1) \leq \Pr(\mu_{i^*+3} \geq 1) \leq \Pr(\mu_{i^*+2} \geq 2),$$

界定后一个量如下:

$$\Pr(\mu_{i^*+2} \geq 2 \mid \nu_{i^*+1} \leq 18 \ln n) \leq \frac{\Pr(B(n, (18 \ln n/n)^d) \geq 2)}{\Pr(\nu_{i^*+1} \leq 18 \ln n)} \leq \frac{\binom{n}{2} (18 \ln n/n)^{2d}}{\Pr(\nu_{i^*+1} \leq 18 \ln n)}.$$

这里最后一个不等式是由应用粗略的并的界得到；有 $\binom{n}{2}$ 种方式选择两个球，每一对球有高度至少是 $i^* + 2$ 的概率是 $(18 \ln n/n)^{2d}$ 。

像前面那样去掉条件，然后利用 (14.5) 式得到

$$\begin{aligned} \Pr(\nu_{i^*, i^*} \geq 1) &\leq \Pr(\mu_{i^*, i^*} \geq 2) \\ &\leq \Pr(\mu_{i^*, i^*} \geq 2 \mid \nu_{i^*, i^*} \leq 18 \ln n) \Pr(\nu_{i^*, i^*} \leq 18 \ln n) \\ &\quad + \Pr(\nu_{i^*, i^*} > 18 \ln n) \\ &\leq \frac{(18 \ln n)^{2d}}{n^{2d-2}} + \frac{i^* + 1}{n^2}, \end{aligned}$$

这就证明了 $d \geq 2$ 时， $\Pr(\nu_{i^*, i^*} \geq 1)$ 是 $o(1/n)$ ，故最大的箱子负荷大于 $i^* + 3 = \ln \ln n / \ln d + O(1)$ 的概率是 $o(1/n)$ 。 ■

随机地打破结便于证明，但在实践中，可以用任何自然的方式打破结。例如在练习 14.1 中，我们证明如果箱子是从 1 到 n 编号的，那么只需利用有利于较小编号箱子的打破结的方法。

作为一个有趣的变化，假定将 n 个箱子分成两个大小相等的组。一半箱子当作左边，另一半当作右边。现在每个球独立地且均匀随机地从每一半箱子中选择一个箱子。每个球仍放入两个箱子中有最小负荷的那个箱子——但现在如果有结，则球放在左边一半的那个箱子中。令人吃惊的是由于箱子分组，并用这种方式打破结，我们可以得到关于最大负荷的一个稍好一点的界： $\ln \ln n / 2 \ln((1 + \sqrt{5})/2) + O(1)$ 。可以将这种方法推广到把箱子分成 d 个有序的同大小的组，如果最小负荷箱子有结，把球放在编号最小的那个箱子里。这种变化是练习 14.13 的课题。

14.2 两种选择：下界

本节将通过证明一个相应的下界来演示说明定理 14.1 的结果是非常严密的。

定理 14.4 假定按下列方式将 n 个球依次放入 n 个箱子中。对每个球，可以独立、均匀随机地选取（有放回） $d \geq 2$ 个箱子。每个球放入 d 个箱子中在放置时最不满的那个箱子中，随机地打破结。将所有球都放完后，任意一个箱子的最大负荷以 $1 - o(1/n)$ 的概率至少是 $\ln \ln n / \ln d - O(1)$ 。

证明的思路与上界相似，但有几个关键的不同之处。如上界那样，我们希望找到一个值 γ_i 的序列，使得负荷至少是 i 的箱子数 γ_i 以大的概率有下界 γ_i 。在推导上界时，利用高度至少为 i 的球的个数作为高度至少为 i 的箱子个数的一个上界。但在证明下界时却不能这么做。取而代之的是应该找到高度恰为 i 的球的个数的下界，然后把它作为高度至少为 i 的箱子数的一个下界。

类似的情况，为证明上界，我们利用了 n 时刻至少有 i 个球的箱子数在任意 $t \leq n$ 时都至少为 $\nu_i(t)$ 。现在这不能帮助我们证明下界；为了确定第 t 个球有高度 $i+1$ 的概率，需要的是 $\nu_i(t)$ 的下界而不是上界。为了解决这个问题，我们确定在 $n(1 - 1/2^t)$ 时刻负荷至少为 i 的箱子数的一个下界 γ_i ，然后界定在整个区间 $(n(1 - 1/2^t), n(1 - 1/2^{t+1}))$ 上出现的高度为 $i+1$ 的

球的个数. 当在推导中需要它们时, 这保证了适当的下界成立, 在证明中将会澄清这一点.

我们叙述需要的引理, 它们类似于上界中的引理.

引理 14.5

$$\Pr(B(n, p) \leq np/2) \leq e^{-np/8}. \quad (14.6)$$

引理 14.6 令 X_1, X_2, \dots, X_n 是在任意域中的随机变量序列, Y_1, Y_2, \dots, Y_n 是具有性质 $Y_i = Y_i(X_1, \dots, X_i)$ 的二项随机变量序列. 如果

$$\Pr(Y_i = 1 \mid X_1, \dots, X_{i-1}) \geq p,$$

那么

$$\Pr\left(\sum_{i=1}^n Y_i > k\right) \geq \Pr(B(n, p) > k).$$

定理 14.4 的证明 令 \mathcal{F}_i 表示事件 $\nu_i(n(1-1/2^i)) \geq \gamma_i$, 其中 γ_i 由

$$\gamma_0 = n;$$

$$\gamma_{i+1} = \frac{n}{2^{i+1}} \left(\frac{\gamma_i}{n}\right)^d$$

给出. 显然, \mathcal{F}_0 以概率 1 成立. 现在要归纳地证明相继的 \mathcal{F}_i 以充分大的概率成立, 从而可以得到要求的下界.

我们希望计算

$$\Pr(\neg \mathcal{F}_{i+1} \mid \mathcal{F}_i).$$

对于区间 $R = (n(1-1/2^i), n(1-1/2^{i+1})]$ 中的 t , 定义二项随机变量:

$$Z_i = 1, \text{ 当且仅当 } h(t) = i+1 \text{ 或 } \nu_{i+1}(t-1) \geq \gamma_{i+1}.$$

因此, 如果 $\nu_{i+1}(t-1) \geq \gamma_{i+1}$, 则 Z_i 总是 1.

第 t 个球恰有高度 $i+1$ 的概率为

$$\left(\frac{\nu_i(t-1)}{n}\right)^d - \left(\frac{\nu_{i+1}(t-1)}{n}\right)^d.$$

第一项是第 t 个球所选择的所有 d 个箱子的负荷至少是 i 的概率. 这对第 t 个球的高度恰为 $i+1$ 是必须的. 但必须减去所有 d 种选择至少有 $i+1$ 个球的概率, 因为在这种情况下, 球的高度将大于 $i+1$.

仍然令 ω_j 表示第 j 个球所选择的箱子, 我们得到

$$\Pr(Z_i = 1 \mid \omega_1, \dots, \omega_{i-1}, \mathcal{F}_i) \leq \left(\frac{\gamma_i}{n}\right)^d - \left(\frac{\gamma_{i+1}}{n}\right)^d.$$

这是因为如果 $\nu_{i+1}(t-1) \geq \gamma_{i+1}$, 则 Z_i 必然是 1; 因此可以考虑在 $\nu_{i+1}(t-1) \leq \gamma_{i+1}$ 的情况下的概率. 在条件 \mathcal{F}_i 下, 仍有 $\nu_i(t-1) \geq \gamma_i$.

由 γ_i 的定义可以进一步得到

$$\Pr(Z_i = 1 \mid \omega_1, \dots, \omega_{i-1}, \mathcal{F}_i) \geq \left(\frac{\gamma_i}{n}\right)^d - \left(\frac{\gamma_{i+1}}{n}\right)^d \geq \frac{1}{2} \left(\frac{\gamma_i}{n}\right)^d.$$

$$\text{令 } p_i = \frac{1}{2} (\gamma_i/n)^d.$$

应用引理 14.6 可以得到

$$\Pr\left(\sum_{i \in R} Z_i < k \mid \mathcal{F}_i\right) \leq \Pr\left(B\left(\frac{n}{2^{i+1}}, p_i\right) < k\right).$$

现在选择的 γ_i 很好地满足

$$\gamma_{i+1} = \frac{1}{2} \frac{n}{2^{i+1}} p_i.$$

由切尔诺夫界,

$$\Pr\left(B\left(\frac{n}{2^{i+1}}, p_i\right) < \gamma_{i+1}\right) \leq e^{-\gamma_{i+1}/(8 \cdot 2^{i+1})},$$

如果 $p_i n/2^{i+1} \geq 17 \ln n$, 这个界是 $o(1/n^2)$. 令 i^* 是使得此式成立的最大整数的下界. 以后将证明 i^* 可以选择为 $\ln \ln n / \ln d - O(1)$. 现在假设是这种情况, 则当 $i \leq i^*$ 时, 已经证明

$$\Pr\left(\sum_{i \in R} Z_i < \gamma_{i+1} \mid \mathcal{F}_i\right) \leq \Pr\left(B\left(\frac{n}{2^{i+1}}, p_i\right) < \gamma_{i+1}\right) = o\left(\frac{1}{n^2}\right).$$

进一步, 由定义可知 $\sum_{i \in R} Z_i < \gamma_{i+1}$ 蕴涵 $\neg \mathcal{F}_{i+1}$. 因此, 当 $i \leq i^*$ 时,

$$\Pr(\neg \mathcal{F}_{i+1} \mid \mathcal{F}_i) \leq \Pr\left(\sum_{i \in R} Z_i < \gamma_{i+1} \mid \mathcal{F}_i\right) = o\left(\frac{1}{n^2}\right).$$

所以, 对充分大的 n ,

$$\begin{aligned} \Pr(\mathcal{F}_{i^*}) &\geq \Pr(\mathcal{F}_{i^*} \mid \mathcal{F}_{i^*-1}) \cdot \Pr(\mathcal{F}_{i^*-1} \mid \mathcal{F}_{i^*-2}) \cdots \Pr(\mathcal{F}_1 \mid \mathcal{F}_0) \cdot \Pr(\mathcal{F}_0) \\ &\geq (1 - 1/n^2)^{i^*} \\ &= 1 - o(1/n). \end{aligned}$$

剩下的只要证明 $\ln \ln n / \ln d - O(1)$ 实际上是 i^* 的一个适当选择. 这只需证明当 i 是 $\ln \ln n / \ln d - O(1)$ 时, $\gamma_i \geq 17 \ln n$ 即可. 由迭代公式 $\gamma_{i+1} = \gamma_i^d / (2^{i+3} n^{d-1})$, 通过简单归纳可以发现

$$\gamma_i = \frac{n}{2^{\sum_{t=0}^{i-1} (i+2-4)^d t}}.$$

一个非常粗略的界是

$$\gamma_i > \frac{n}{2^{10d^{i-1}}}.$$

因此我们寻找最大的 i , 使得

$$\frac{n}{2^{10d^{i-1}}} \geq 17 \ln n.$$

[343] 对充分大的 n , 利用下列不等式链, 可以取与 $\ln \ln n / \ln d - O(1)$ 一样大的 i :

$$\frac{n}{2^{10d^{i-1}}} \geq 17 \ln n,$$

$$2^{10d^{i-1}} \leq \frac{n}{17 \ln n},$$



$$10d^{i-1} \leq \log_2 n - \log_2(17 \ln n),$$

$$d^{i-1} \leq \frac{1}{20} \ln n,$$

$$i \leq \frac{\ln \ln n}{\ln d} - O(1). \quad \blacksquare$$

14.3 两种选择影响力的应用

平衡配置范例在计算问题方面有许多有意义的应用。这里，我们详细地给出两个简单的应用。在考虑这些问题时，切记得到的平衡配置范例的界是 $\ln \ln n / \ln d + O(1)$ ，在实践中这一般相应于至多为 5 的最大负荷。

14.3.1 散列

在第 5 章考虑散列时，通过假定散列函数将被散列项目映射到散列表中的随机元素，我们将它与球和箱子范例联系起来。在这种假定下，我们证明了：(a) 当 $O(n)$ 个项目被散列到有 n 个元素的表时，散列到表中的每个元素的项目的期望个数是 $O(1)$ ；(b) 以大的概率，散列到表中任意一个元素的最大项目个数是 $\Theta(\ln n / \ln \ln n)$ 。

这些结果对于大多数应用是令人满意的，但对其中的某些应用并不满意，因为在所有项目中最糟糕情况的查找时间的期望值是 $\Theta(\ln n / \ln \ln n)$ 。例如，将一个路由表存入路由器时，为查找散列表中最差情况的时间可能是一个重要的性能标准， $\Theta(\ln n / \ln \ln n)$ 的结果太大了。另一个潜在的问题是内存的浪费。例如，假定设计一个散列表，其中每个接收器应该配置一个固定大小的高速缓冲存储器的存储线路。因为最大负荷要比平均值大很多，我们不得不使用大量的高速缓冲存储器线路，而它们当中的很多个将完全是空的。对于一些应用，像路由器，这种内存的浪费是不合要求的。

应用平衡配置范例，我们得到一个期望为 $O(1)$ 且最大存取时间是 $O(\ln \ln n)$ 的散列方案。两链技术利用两个随机散列函数。这两个散列函数对每个项目定义散列表中的两个可能元素。项目插入到在插入时最不满的那个位置。表上每个元素中的项目保存在一个链表中。如果 n 个项目依次插入到大小为 n 的一个表中，期望插入和查找时间仍是 $O(1)$ 。(见练习 14.3.) 定理 14.1 表明，以大的概率寻找一个项目的最长时间是 $O(\ln \ln n)$ ，而只用一个随机散列函数时的最长时间是 $\Theta(\ln n / \ln \ln n)$ 。这种改进不是不必付出代价的。因为现在搜索一个项目是要在两个接收器中而不是一个接收器中搜索，在期望最长搜索时间上的改进大约是平均搜索时间加倍的代价。如果两个接收器可以平行地搜索，则可以减少这种代价。

14.3.2 动态资源配置

假定一个用户或一个进程必须在大量同样的资源中进行在线选择。(在网络的服务器中选择服务器使用；选择一张磁盘存储目录；选择一个打印机，等等。)为了寻找一个最小负荷的资源，用户在发送他们的请求之前，可能检查所有资源的负荷。这个过程是昂贵的，因为它要求向每个资发放送中断信号。另一种方法是向随机资源发送任务。这种方法的费用最小，但是如果所有的用户都这么做，那么服务器的负荷将会有显著的变化。平衡配置范例提出一个

更有效的解决方案。如果每个用户抽样两个资源的负荷，并将他的请求发送给最小负荷的资源，那么就能保持小的总费用，而 n 个资源的负荷变化也小得多。

练习

- 14.1 (a) 定理 14.1 和定理 14.4 的证明是对随机地打破结的情况而言的。非正式地说明，如果箱子是从 1 到 n 编号的且以有利于最小编号的箱子打破结，则定理依然成立。
 (b) 非正式地说明，定理适用于任意的破结机构，这里不包含尚未被放置的球所选择的箱子信息。
- 14.2 考虑下面平衡配置范例的变形：将 n 个球依次放到 n 个箱子中，箱子从 0 到 $n-1$ 标号。每个球均匀随机地选择一个箱子 i ，并将这个球放在箱子 $i, i+1 \bmod n, i+2 \bmod n, \dots, i+d-1 \bmod n$ 中有最小负荷的那个箱子中。证明：当 d 是常数时，最大负荷随 $\Theta(\ln n / \ln \ln n)$ 增加。即在这种情况下，平衡配置范例不会得到一个 $O(\ln \ln n)$ 的结果。
- 14.3 解释为什么在用两链方法时，对具有 n 个项目的一张大小为 n 的散列表中插入一个项目和搜索一个项目的期望时间是 $O(1)$ 。考虑两种情况：搜索一个在表中的项目；搜索一个不在表中的项目。
- 14.4 考虑下面平衡配置范例的变形：将 n 个球依次放入 n 个箱子中。每个球有 d 个选择，从 n 个箱子中独立地且均匀随机地选择 d 个箱子。放置一个球时，也允许在这 d 个箱子中移动球，使得它们的负荷尽可能地相等。证明在这种情况下，以 $1 - o(1/n)$ 的概率，最大负荷仍至少为 $\ln \ln n / \ln d - O(1)$ 。
- 14.5 假定在平衡配置设置时有 n 个箱子，但箱子不是均匀随机地选择的。代之以将箱子分为两种类型：箱子的 $1/3$ 是 A 型，箱子的 $2/3$ 是 B 型。在随机地选择一个箱子时，选择每个 A 型箱子的概率是 $2/n$ ，选择每个 B 型箱子的概率是 $1/2n$ 。证明：当每个球有 d 个箱子选择时，任意一个箱子的最大负荷依然是 $\ln \ln n / \ln d + O(1)$ 。
- 14.6 考虑一个与平衡配置范例平行的情况：现在有 n/k 轮，每一轮有 k 个新球到达。每个球放在它的 d 个选择中有最小负荷的那个箱子中，在这种设置下，每个箱子的负荷是上一轮结束时的负荷。随机地打破结。注意 k 个新球不能影响彼此的放置。给出一个关于 n 、 d 和 k 的函数作为最大负荷的上界。
- 14.7 我们已经证明，依次将 n 个球随机放入 n 个箱子，（每个球可以选择两个箱子）以大的概率，最大负荷是 $\ln \ln n / \ln 2 + O(1)$ 。假定不是依次地放球，而是访问 n 个球的所有 $2n$ 种选择，假定希望将每个球都放入它所选择的箱子中最大负荷为最小的那个箱子。在这种设置下，以大的概率，可以得到一个常数的最大负荷。

编写一个程序研究这种情况。程序应该输入一个参数 k ，然后运行下面的贪婪算法。在每一步，球的某个子集是活跃的；开始时，所有球都是活跃的。重复地寻找一个箱子，此箱子中至少有一个但不多于 k 个已经选择该箱子的活跃球，将这些活跃球指派给这个箱子，然后从活跃球集合中去掉这些球。直到没有剩下活跃球或是没有合适的箱子时停止该过程。若算法以没有剩下的活跃球结束，那么指派给每个箱子的球不会多于

k 个.

尝试用 10 000 个球和 10 000 个箱子运行该程序. 在 5 次中至少有 4 次因为没有剩余的活跃球而中止程序的最小的 k 值是多少? 如果程序足够快, 尝试更多的试验. 如果程序足够快, 还可以尝试对 100 000 个球和 100 000 个箱子回答同样的问题.

- 14.8 下面的问题是对一个简单的分布系统建模, 其中代理商为资源而竞争, 在有争议时放弃. 像练习 5.11 那样, 球代表代理商, 箱子代表资源.

系统是在各轮中逐渐形成的. 在每轮的第一部分, 球是独立地、均匀随机地放入 n 个箱子中的. 在每轮的第二部分, 在那轮中至少有一个球的每个箱子从那轮中恰好供给一个球. 剩余的球在下一轮中再发放. 从第一轮有 n 个球开始, 当每个球都供给时停止.

(a) 证明: 以 $1 - o(1/n)$ 的概率, 这种方法至多需 $\log_2 \log_2 n + O(1)$ 轮. (提示: 令 b_i 是 k 轮后剩余的球数, 证明只要 b_{i+1} 充分大, 对于适当的常数 c , 以大的概率有 $b_{i+1} \leq c(b_i)^2/n$.)

(b) 假定我们修改了此系统, 使得一个箱子在一轮中接收一个球, 当且仅当那个球是那个箱子在那轮中要求的唯一一个球. 证明: 仍以 $1 - o(1/n)$ 的概率, 这种方法至多需 $\log_2 \log_2 n + O(1)$ 轮.

- 14.9 模拟球与箱子试验的一种自然方法是生成一个存储每个箱子负荷的数组. 为了模拟 1 000 000 个球放入 1 000 000 个箱子, 需要一个有 1 000 000 个计数器的数组. 另一种方法是保存一个数组, 其第 j 个元素记录的是负荷为 j 的箱子个数. 利用标准的球与箱子范例及平衡配置范例解释怎样用这种方法以小得多的空间模拟将 1 000 000 个球放入 1 000 000 个箱子的试验.

- 14.10 写一个程序比较标准的球与箱子范例与平衡配置范例的性能. 模拟将 n 个球放入 n 个箱子中, 每个球有 $d = 1, 2, 3$ 及 4 种随机选择的情形. 可以尝试 $n = 10\,000$, $n = 100\,000$ 及 $n = 1\,000\,000$ 的情形. 每个试验至少重复 100 次, 根据试验, 为每个 d 值计算最大负荷的均值和方差. 可以利用练习 14.9 的思路.

- 14.11 编写一个模拟程序说明平衡配置范例如何改进分布排队系统的性能. 考虑一个有 n 个 FIFO 队列的银行, 进入银行的顾客数是以每秒 λn 速度的泊松到达流, 其中 $\lambda < 1$. 顾客在入口处选择一个服务队列, 为每个顾客的服务时间服从均值为 1 秒的指数分布. 要比较两种情况: (i) 每个顾客从 n 个队列中独立地且均匀随机地选择一个队列等待服务; (ii) 每个顾客从 n 个队列中独立、均匀随机地选择两个队列, 然后在较少顾客的队列中等待服务, 随机地解开结. 注意, 第一种情况等价于一个有 n 个 $M/M/1$ FIFO 队列的银行, 每个队列是速度为每秒 $\lambda < 1$ 的泊松到达. 可以在练习 8.26 中找到有助于构造该模拟的讨论.

模拟要运行 t 秒, 然后返回在这个系统中花费时间的平均值 (对于完成服务的所有顾客) 及他们在所选队列中发现等待服务的顾客人数的平均值 (对于已经到达的所有顾客). 要给出 $n = 100$, $t = 10\,000$ 秒, $\lambda = 0.5, 0.8, 0.9$ 和 0.99 时的模拟结果.

- 14.12 编写一个程序比较标准的球与箱子范例与平衡配置范例的下面变化的性能. 开始时 n 个点均匀随机地放在周长为 1 的圆周上. 这 n 个点将圆周分成 n 段圆弧, 圆弧对应于箱子. 现在将 n 个球按下列方式放入箱子中: 每个球均匀随机地选择圆周上 d 个点. 这 d 个点对应于它们所在的圆弧(或等价地, 箱子). 将球放在这 d 个箱子中最小负荷的那个箱子, 以有利于最短圆弧的方式打破结.

对 $d=1$ 和 $d=2$ 的情况, 模拟将 n 个球放入 n 个箱子的试验. 可以尝试 $n=1\,000$, $n=10\,000$ 及 $n=100\,000$. 每个试验至少重复 100 次, 对每次运行, n 个初始点都要重新选择. 根据该试验, 对于每个 d 值列出一个表格, 标出最大负荷为 k 的次数.

应该注意, 某些圆弧要比其他圆弧长很多, 因此当 $d=1$ 时, 最大负荷可能会相当大. 要找到每个球被放置在哪个箱子中可能要求执行二元搜索或某些其他附加的数据结构, 从而快速地将圆周上的点映射到适当的箱子中.

- 14.13 可以对我们描述过的平衡配置方案进行一个虽小但有意义的改进. 仍然将 n 个球放入 n 个箱子中. 这里假定 n 是偶数. 假定将 n 个箱子分成大小为 $n/2$ 的两个组, 称这两个组为左组和右组. 对于每个球, 独立地从左组均匀随机地选择一个箱子, 从右组均匀随机地选择一个箱子. 将球放入有最小负荷的箱子中, 但如果有的话, 则总是将球放入左组的箱子. 用这种方案, 最大负荷减小为 $\ln \ln n/2 \ln \phi + O(1)$, 其中 $\phi = (1 + \sqrt{5})/2$ 为黄金比例. 这样以一个常数因子改进了定理 14.1 的结果. (注意对原来方案的两个改变: 将箱子分成两个组, 用一致的方式打破结. 这两种改变对得到想要的改进是必要的.)

- (a) 写一个程序比较原平衡配置方案与这种变形的性能. 运行将 n 个球放入 n 个箱子而每个球有 $d=2$ 种选择的模拟试验. 可以尝试 $n=10\,000$, $n=100\,000$ 和 $n=1\,000\,000$ 的情况. 每次试验至少重复 100 次, 根据该试验, 计算最大负荷的期望和方差, 描述新的变形的改善程度.
- (b) 改写定理 14.1 证明这个结果. 在定理证明中必须如何改变的关键思想是现在要求两个序列 β_i 和 γ_i . 类似于定理 14.1, β_i 表示左组中负荷至少为 i 的箱子个数的设计 upper, γ_i 表示右组中负荷至少为 i 的箱子个数的设计 upper. 证明选择

$$\beta_{i+1} = \frac{c_1 \beta_i \gamma_i}{n^2} \quad \text{及} \quad \gamma_{i+1} = \frac{c_2 \beta_{i+1} \gamma_i}{n^2}$$

是合适的, 其中 c_1 和 c_2 是某个常数(只要 β_i 和 γ_i 足够大, 可以用切尔诺夫界).

现在令 F_k 是第 k 个费波那契数. 用归纳法证明, 对充分大的 i , 对某常数 c_3 和 c_4 , $\beta_i \leq nc_3 c_4^{F_i}$, $\gamma_i \leq nc_3 c_4^{F_{i+1}}$ 成立. 根据定理 14.1, 用这个结论证明 upper $\ln \ln n/2 \ln \phi + O(1)$.

- (c) 将 n 个箱子分成 d 个有序组容易将这种变形推广到有 $d > 2$ 个选择的情况, 从每组均匀随机地选择一个箱子, 以有利于排序在先的组的方式打破结. 对这种情况建最大负荷的适当 upper 是多少, 给出支持你的建议的论据. (不需要给出完整而正式证明.)

进一步阅读材料

- N. Alon and J. Spencer, *The Probabilistic Method*, 2nd ed. Wiley, New York, 2000.
- B. Bollobás, *Random Graphs*, 2nd ed. Academic Press, Orlando, FL, 1999.
- T. H. Corman, C. E. Leiserson, R. L. Rivest, and C. Stein, *Introduction to Algorithms*, 2nd ed. MIT Press/McGraw-Hill, Cambridge/New York, 2001.
- T. M. Cover and J. A. Thomas, *Elements of Information Theory*, Wiley, New York, 1991.
- W. Feller, *An Introduction to the Probability Theory, Vol. 1*, 3rd ed. Wiley, New York, 1968.
- W. Feller, *An Introduction to the Probability Theory, Vol. 2*, Wiley, New York, 1966.
- S. Karlin and H. M. Taylor, *A First Course in Stochastic Processes*, 2nd ed. Academic Press, New York, 1975.
- S. Karlin and H. M. Taylor, *A Second Course in Stochastic Processes*. Academic Press, New York, 1981.
- F. Leighton, *Parallel Algorithms and Architectures*. Morgan Kaufmann, San Mateo, CA, 1992.
- R. Motwani and P. Raghavan, *Randomized Algorithms*. Cambridge University Press, 1995.
- J. H. Spencer, *Ten Lectures on the Probabilistic Method*, 2nd ed. SIAM, Philadelphia, 1994.
- S. Ross, *Stochastic Processes*. Wiley, New York, 1996.
- S. Ross, *A First Course in Probability*, 6th ed. , Prentice-Hall, Englewood Cliffs, NJ, 2002.
- S. Ross, *Probability Models for Computer Science*. Academic Press, Orlando, FL, 2002.
- R. W. Wolff, *Stochastic Modeling and the Theory of Queues*. Prentice-Hall, Englewood Cliffs, NJ, 1989.



索引

索引中的页码为英文原书页码, 与书中页边标注的页码一致。

#P(复杂性类), 255

A

arithmetic coding(算术编码), 250

Azuma-Hoeffding inequality (Azuma-Hoeffding 不等式), 303

B

balanced allocation(平衡配置), 336-345

ballot theorem(选举定理), 299

balls and bins model(球和箱子模型), 92-104

balls and bins with feedback(有反馈的球和箱子模型), 199-201

Bayes' law(贝叶斯定律), 10

Bernoulli random variable(伯努利随机变量), 25
expectation(期望), 25
variance(方差), 48

Bernoulli trials(伯努利试验), 63

binary erasure channel(二元删除信道), 251

binary symmetric channel(二元对称信道), 238

binomial coefficients, bounds(二项式系数的界), 228-229

binomial distribution(二项分布), 25, 161

binomial identity(二项式恒等式), 26

binomial random variable(二项随机变量), 25, 29
expectation(期望), 26
variance(方差), 48

binomial theorem(二项式定理), 48, 228

birthday paradox(生日悖论), 90-92

bit-fixing routing algorithm(位固定路由算法), 74, 79, 80, 88

Bloom filter(Bloom 过滤器), 109-111, 329

branching process(分支过程), 30

Bubblesort(冒泡排序法), 41, 58, 94

Bucket sort(桶排序法), 93-94

Buffon's needle(蒲丰投针), 267

burst errors(突发错误), 171

butterfly, wrapped(缠绕蝶形), 78
routing algorithm(路由算法), 80

C

chain hashing(链散列), 106-107

channel(信道), 238

binary symmetric(二元对称), 238

Chebyshev's inequality(切比雪夫不等式), 48-49, 56, 134

pairwise independent variables(两两独立变量), 318-319

Chernoff bound(切尔诺夫界), 63, 61-83

geometric random variables(几何随机变量), 85

Poisson random variable(泊松随机变量), 97

Poisson trials(泊松试验), 63-67, 85

sum of $\{-1, +1\}$ random variables($\{-1, +1\}$ 随机变量的和), 69-71

weighted sum of Poisson trials(泊松试验的加权), 86

compression(压缩), 234-237

compression function(压缩函数), 235

conditional density function(条件密度函数), 193

conditional entropy(条件熵), 246

conditional expectation(条件期望), 26, 26-30, 131-133, 181
random variable(随机变量), 28

conditional expectation inequality(条件期望不等式), 136-138

conditional probability(条件概率), 6, 27, 140, 159, 192

confidence interval(置信区间), 68, 319

- connectivity algorithm(连通性算法), 176
- convex function(凸函数), 24
- count-min filter(最小计数过滤器), 329-332
 - conservative update(保守的更新), 332
- coupling(耦合), 274, 271-289
- coupon collector's problem(赠券收集问题), 32-34, 50, 104-106, 117
 - expectation(期望), 33
 - variance(方差), 52.
- covariance(协方差), 46, 135, 318
- cuts(割), 316-317
- D**
- data stream model(数据流模型), 329
- decoding function(解码函数), 238
- delay sequence(延迟序列), 81
- density function(密度函数), 189
 - conditional(条件), 193
- dependency graph(相关图), 139
- derandomization(消除随机性), 126
 - conditional expectations(条件期望), 131-133
 - pairwise independence(两两独立), 316-317
- discrete probability space(离散概率空间, 见 probability space, discrete)
- discrete random variable(离散随机变量, 见 random variable, discrete)
- distribution function(分布函数), 189
 - joint distribution(联合分布), 191
- DNF formula(析取范式, DNF 公式), 255
 - approximating the number of satisfying assignment(近似满足赋值个数), 255-259
- Doob martingale(杜布鞅), 296
- dynamic resource allocation(动态资源分配), 345
- E**
- edge-disjoint paths(边不相交的路径), 141
- edge exposure martingale(边暴露鞅), 296
- embedded Markov chain(嵌入马尔可夫链), 210
- encoding function(解码函数), 238
- entropy(熵), 225, 225-245
- entropy function, binary(二进制熵函数), 226
- (ε, δ) -approximation((ε, δ) -近似), 253, 254
- ε -uniform sample(ε -均匀样本), 259
- event(事件), 3
 - set notation(集合符号), 3
 - simple(简单), 3
- expectation(期望), 21, 20-26, 128-131
 - Bernoulli random variable(伯努利随机变量), 25
 - binomial random variable(二项随机变量), 26
 - conditional(条件, 见 conditional expectation)
 - continuous random variable(连续随机变量), 190
 - coupon collector's problem(赠券收集问题), 33
 - exponential random variable(指数随机变量), 197
 - geometric random variable(几何随机变量), 31
 - linearity of(的线性性), 见 linearity of expectations
 - Poisson random variable(泊松随机变量), 96
 - product of random variables(随机变量的乘积), 46
 - uniform random variable(均匀随机变量), 194
- exponential distribution(指数分布), 196, 205
 - density(密度), 197
 - distribution function(分布函数), 196
 - memoryless property(无记忆性), 197
 - minimum(最小值), 198
- exponential random variable(指数随机变量), 196
 - expectation(期望), 197
 - variance(方差), 197
- extracting random bits(提取随机比特), 230-234
- extraction function(提取函数), 230, 248
- F**
- factorial bounds(阶乘界), 93, 102, 151
- fully polynomial almost uniform sampler(FPAUS)(完全多项式几乎均匀抽样器), 259, 259-263
- fully polynomial randomized approximation scheme(FPRAS)(完全多项式随机近似方案), 254, 257-263, 267
- G**
- gambler's ruin(赌徒的破产), 166-167, 298
- geometric distribution(几何分布), 30, 62
- geometric random variable(几何随机变量), 30, 62

expectation(期望), 31
 memoryless property(无记忆性), 30
 variance(方差), 50
 girth(围长), 134

H

Hamiltonian cycle(哈密顿圈), 113
 algorithm(算法), 115
 harmonic number(调和数), 33
 hashing(散列), 106-112, 344-345
 fingerprint(指纹), 108
 perfect hashing(完全散列), 326-328
 universal hash functions(通用散列函数), 321-328
 heavy hitters(重量级的源-终点), 332
 algorithm(算法), 328
 hypercube(超立方), 73
 routing algorithm(路由选择算法), 75

I

inclusion-exclusion principle(容斥原理), 4, 16
 independence(独立性), 6, 21, 191
 k -wise(每 k 个独立), 315
 mutual(相互), 6, 21, 138, 314
 pairwise(两两), 315
 independent set(独立集合), 133-134
 approximate counting(近似计数), 259
 sampling(抽样), 277-278, 286-289
 indicator random variable(示性随机变量), 25, 26

J

Jensen's inequality(詹森不等式), 23-24

K

Kraft inequality(Kraft 不等式), 249
 k -SAT(k -可满足性), 142-146, 156

L

large cuts(最大割), 129-130
 Las Vegas algorithm(Las Vegas 算法), 57, 128, 130
 law of total probability(全概率定律), 9
 leader election(领导者选举), 112
 linear insertion sort(线性插入排序), 41, 94
 linearity of expectations(期望的线性性), 22, 26

Little's result(Little 结果), 216
 Lovasz local lemma(洛瓦兹局部引理), 138-148
 explicit constructions(显式构造), 142
 general case(一般情况), 146, 148
 symmetric version(对称形式), 139-141

M

marginal distribution function(边缘分布函数), 191
 Markov chain(马尔可夫链), 153, 153-210
 aperiodic(非周期), 165
 communicating states(相通状态), 164
 coupling(耦合), 274, 271-289
 directed graph representation(有向图表示), 155
 embedded(嵌入), 210
 equilibrium distribution(均衡分布), 167
 ergodic(遍历), 166
 irreducible(不可约), 164
 Markov property(马尔可夫性质), 154
 memoryless property(无记忆性), 154
 mixing time(混合时间), 274
 null recurrent(零常返), 165
 path coupling(路径耦合), 286-289
 periodic(周期), 165
 positive recurrent(正常返), 165
 rapidly mixing(快速混合), 274
 recurrent(常返), 164
 skeleton(骨架), 210
 state(状态), 153
 stationary distribution(平稳分布), 167, 167-172
 time-reversible(时间可逆), 172, 183, 264, 266
 transient(瞬时), 164
 transition matrix(转移矩阵), 154
 transition probability(转移概率), 154; n -step(n -步), 154
 Markov chain Monte Carlo method(马尔可夫链蒙特卡罗方法), 263-265
 Markov processes(马尔可夫过程), 210
 Markov's inequality(马尔可夫不等式), 44-45
 martingale(鞅), 295, 295-308
 Azuma-Hoeffding inequality(Azuma-Hoeffding 不等式), 303

edge exposure(边暴露), 296
 stopping theorem(停止定理), 298
 vertex exposure(顶点暴露), 297
 maximum cut(最大割), 131-133
 maximum satisfiability(最大可满足性), 130-131
 median algorithm(中位数算法), 52-57
 memoryless property(无记忆性), 30, 197
 Metropolis scheme(Metropolis 方案), 265
 min-cut algorithm(最小割算法), 12-14
 minimum cut-set(最小割集), 12
 moment generating function(矩母函数), 61, 61-63
 Poisson distribution(泊松分布), 97
 moments(矩), 45
 Monte Carlo algorithm(蒙特卡罗算法), 57, 128, 335
 Monte Carlo method(蒙特卡罗方法), 252-266

N

negative binomial random variable(负二项随机变量), 40

O

order statistics(顺序统计量), 207
 uniform random variables(均匀随机变量), 208

P

packet routing(数据包路由选择), 72-83
 hypercube(超立方体), 75
 wrapped butterfly(缠绕蝶形), 80
 pairwise independence(两两独立), 315
 constructions(构造), 315-318
 sampling(抽样), 319-321
 Parrondo's paradox(Parrondo 悖论), 177
 PASTA principle(PASTA 原则), 215
 perfect hashing(完美散列), 326-328
 permutation(排列), 41
 Poisson approximation(泊松近似), 99-105, 111
 Poisson distribution(泊松分布), 95, 202
 moment generating function(矩母函数), 97
 Poisson process(泊松过程), 202, 201-209
 combining(组合), 205-207
 interarrival distribution(到达间隔分布), 204
 splitting(分裂), 205-207

Poisson random variable(泊松随机变量), 63, 95
 Chernoff bound(切尔诺夫界), 97
 expectation(期望), 96
 sums(和), 96
 Poisson trial(泊松试验), 63
 prefix code(前缀码), 234, 249
 principle of deferred decisions(延迟决策原理), 9, 116
 priority queue(优先权排队), 224
 probabilistic method(概率方法), 126-148, 242
 counting argument(计数论证), 126-128
 expectation argument(期望论证), 128-131
 Lovasz local lemma(洛瓦兹局部引理), 138-148
 sample and modify(抽样与修改), 133-134
 second moment method(二阶矩方法), 134-136
 probability function(概率函数), 3
 probability space(概率空间), 3
 discrete(离散), 3

Q

queues(队列, 排队), 173-174, 212-218
 $M/M/1$, 213-216
 $M/M/1/K$, 216
 $M/M/\infty$, 216-218
 notation(记号), 212
 Quicksort(快速排序), 34-38
 pivot(基准), 34

R

random graphs(随机图), 112-113, 296
 threshold function(阈函数), 135, 135-138
 random variable(随机变量), 20, 20-26
 continuous(连续), 189, 188-193
 discrete(离散), 20
 random walk(随机游动), 174, 174-177
 cover time(覆盖时间), 176
 stationary distribution(平稳分布), 175
 randomized routing(随机化路由选择), 72-83
 hypercube(超立方体), 75
 wrapped butterfly(缠绕蝶形), 80
 reservoir sampling(贮存抽样法), 40

S

- sample space(样本空间), 3
- sampling(抽样), 5
 - pairwise independence(两两独立), 319-321
 - with replacement(有放回), 5
 - without replacement(无放回), 5
- satisfiability(可满足性), 130, 142-146
- second moment method(二阶矩方法), 134-136
- set balancing(集合的均衡), 71
- set membership problem(集合成员问题), 108
- Shannon's theorem(香农定理), 237-245
- skeleton Markov chain(骨架马尔可夫链), 210
- standard deviation(标准差), 45
- stationary distribution(平稳分布), 179, 210
 - continuous time Markov processes(连续时间马尔可夫过程), 210-212
- $s-t$ connectivity algorithm($s-t$ 连通性算法), 176
- Stirling's formula(斯特林公式), 162, 246
- stochastic counting process(随机计数过程), 201
- stochastic process(随机过程), 153
- stopping time(停时), 297, 297-300
- symmetry breaking(放弃对称性), 111-112
- 2-SAT, 156
 - algorithm(算法), 156-159
- 3-SAT, 159
 - algorithm(算法), 161

U

- uniform distribution(均匀分布), 193, 208
 - conditional probability(条件概率), 194

- density function(密度函数), 194
- distribution function(分布函数), 194
- uniform random variable(均匀随机变量), 193
 - expectation(期望), 194
 - variance(方差), 194
- union bound(并的界), 4, 52, 127
- universal hash functions(通用散列函数), 321, 321-328

V

- variance(方差), 45
 - Bernoulli random variable(伯努利随机变量), 48
 - binomial random variable(二项随机变量), 48
 - continuous random variable(连续随机变量), 190
 - exponential random variable(指数随机变量), 197
 - geometric random variable(几何随机变量), 50
 - sum(和), 46
 - sum of pairwise independent variables(两两独立随机变量的和), 318
 - uniform random variable(均匀随机变量), 194
- variation distance(变异距离), 272, 278
- verifying(验证)
 - matrix multiplication(矩阵乘法), 8-12
 - polynomial identities(多项式恒等式), 1-8
- vertex coloring, sampling(顶点着色, 抽样), 282-286
- vertex exposure martingale(顶点暴露鞅), 297

W

- Wald's equation(瓦尔德方程), 300-302
- weak law of large numbers(弱大数律), 60

