

SHUJU FENXI JICHU JI MOXING

数据分析

基础及模型

管 涛◎编著

>>>>>>>>



合肥工业大学出版社
HEFEI UNIVERSITY OF TECHNOLOGY PRESS

管
涛
著

数据分析基础及模型



合肥工业大学出版社

内容提要

全书共分7章,主要包括:第1章介绍了相关的算子理论基本定义和概念;第2章介绍了数据分析的数理统计基础,包括常用统计分布、分布函数的变换、收敛性、MCMC采样、随机逼近;第3章引入了数据分析中常见的矩阵计算和分解的相关理论和方法;第4章阐述了一些数据分类模型;第5章介绍了流行的降维理论和方法;第6章论述了聚类分析相关理论和算法;第7章讨论了在线学习的理论和方法。本书亦注重算法的Matlab实现,书中包含了一些算法的Matlab程序。

本书可作为高等院校计算机科学与技术、电子商务、云计算、数据挖掘和分析、信息检索等专业的教学参考书,也可作为大数据领域工程人员的参考用书。

图书在版编目(CIP)数据

数据分析基础及模型/管涛著. —合肥:合肥工业大学出版社,2015.7
ISBN 978-7-5650-2317-0

I. ①数… II. ①管… III. ①统计数据—统计分析 IV. ①0212.1

中国版本图书馆CIP数据核字(2015)第161754号

数据分析基础及模型

管涛著

责任编辑 马成勋

出版	合肥工业大学出版社	版次	2015年7月第1版
地址	合肥市屯溪路193号	印次	2015年7月第1次印刷
邮编	230009	开本	710毫米×1000毫米 1/16
电话	理工编辑部:0551—62903200 市场营销中心:0551—62903198	印张	13.75
网址	www.hfutpress.com.cn	字数	200千字
E-mail	hfutpress@163.com	印刷	安徽联众印刷有限公司
		发行	全国新华书店

ISBN 978-7-5650-2317-0

定价:28.00元

如果有影响阅读的印装质量问题,请与出版社发行部联系调换。




大数据是随着信息技术的发展而诞生的一个科学领域,在学术界和工程界中得到了广泛的研究和应用,为社会的发展带来了收益、人们的生活带来了便利。大数据的研究得到了世界各国政府的重视,投入了不少的物力和财力。目前,不少企业开展着许多大数据的应用,例如,百度、google 的文本、图像搜索,淘宝、京东等电商的推荐系统,facebook、linkedin 等社交网站的用户连接模型,电子政务专家决策和咨询系统。大数据应用的本质在于面向用户的已知的或潜在的需求,建立恰当的数据分析和处理模型,得到结论并提供有效的服务或者参考,增加企业的利润。然而,在大数据上构建有效的数据分析模型并非易事。通常情况下,有效信息是隐藏在大量错误、冗余、异质、多源、高维、多尺度的复杂数据之中,数据之间也存在着众多的联系,那么,在这种情况下,我们该如何应对呢?围绕着这种需求,本书重点阐述了与复杂数据处理紧密相关的数学领域和原理,包括算子理论、统计分析方法、矩阵分析和计算方面的内容,同时,也介绍了当今流行的一些数据推断、分类、聚类模型和方法,包括贝叶斯推断、高斯混合模型、数据降维方法、自组织映射、竞争学习、在线学习。

本书与数据挖掘、机器学习、数学理论领域在分析问题的角度上有一定的区别。从内容上看,数据挖掘和机器学习书籍更侧重工程上的实践和应用,很少揭示算法蕴含的数学原理。而数学专业书籍多从理论上定义和证明,较少结合实际问题进行讲解,与应用脱节较大,计算机专业的研究人员入门较难。本书不探讨深刻的数学理论本身,而是结合数据分析需求和作者的工作,对相关的数学领域加以阐述和介绍,是对计算机领域的数据分析研究的一个有效的补充。

本书的撰写和出版得到了国家自然科学基金(No. 41171341)、河南省教育厅科学技术研究重点项目科技攻关计划(No. 14A520060)、郑州市普通科技攻关计划项目(No. 20130783)的支持,在此表示感谢,同时感谢家人的支持。

作 者

2015年3月于郑州



第 1 章 算子理论基础	(1)
1.1 基本概念和定义	(1)
1.2 常用不等式	(7)
小结及深入的主题	(12)
第 2 章 统计分析基础	(15)
2.1 基本概念	(16)
2.2 常见分布及 Matlab 实现	(22)
2.5 收敛性	(42)
2.6 随机逼近	(45)
小结及深入的主题	(48)
第 3 章 矩阵分解与计算	(53)
3.1 基本概念	(53)
3.2 矩阵分解与降维	(58)
小结及深入的主题	(70)
第 4 章 分类模型	(75)
4.1 贝叶斯推断	(75)
4.2 高斯混合模型(GMM)	(80)
4.3 Logistic 回归	(94)
4.4 判别分析	(96)

4.5 集成学习(Ensemble Learning)	(98)
小结及深入的主题	(100)
第5章 数据降维方法	(113)
5.1 主成分分析(PCA)	(113)
5.2 扩展的 PCA 模型	(115)
5.3 流形学习	(118)
5.4 谱聚类	(119)
5.5 典型谱聚类算法及其性能分析	(127)
小结及深入的主题	(136)
第6章 聚类分析	(143)
6.1 经典聚类模型	(143)
6.2 核聚类模型	(147)
6.3 常见算法性能的分析与比较	(150)
小结及深入的主题	(151)
第7章 在线学习	(155)
7.1 引言	(155)
7.2 模型和算法	(157)
7.3 模型复杂性及选择	(176)
7.4 算法收敛性、收敛速度和误差界	(179)
7.5 典型应用	(183)
小结及深入的主题	(186)
附录 A 常用参数和指标	(201)
A.1 期望和方差	(201)
A.2 偏度(Skewness)	(201)
A.3 峰度(Peakness/Kurtosis)	(201)
附录 B 度量	(202)
B.1 相关性度量	(202)
B.2 距离度量	(203)
附录 C Cramer-Rao 不等式	(206)
附录 D 中英文对照表	(208)

符号表

符号	含义
Ω	概率空间
$\mathbb{R}^n$	n 维欧氏空间
H	Hilbert 空间
$\emptyset$	空集
ρ	测度
Θ	参数空间
X	随机变量或样本或矩阵
$A, B, C, \dots$	集合或矩阵
$\text{tr}(A)$	矩阵 A 的迹
A^*	矩阵 A 的共轭转置
σ	矩阵奇异值
λ	矩阵特征值
$ \cdot $	集合的基或元素的数目
$\in$	属于
$\subset$	包含于
$\ll$	远小于
$\propto$	正比于
∂	求偏导或微分

df	对函数 f 求微分
∇	求梯度
Δ	Laplace 算子
$N(0,1)$	标准正态分布
Γ	Gamma 分布, 伽玛分布
χ^2	卡方分布
μ	均值
θ	参数
Σ	方差
$K(\cdot, \cdot)$	核函数
$\wedge$	逻辑合取运算
$\vee$	逻辑析取运算
$\neg$	逻辑非
$\forall$	任意
$\exists$	存在
∞	无穷大
$\sim$	服从(分布)
$\rightarrow$	收敛于或映射
$\xrightarrow{F}$	依分布收敛于
$\xrightarrow{a.s.}$	几乎必然收敛于
ϕ	非线性映射
Φ	正交函数集

第1章 算子理论基础

函数定义为数集到数集的映射,算子推广了函数的概念,实现空间到空间的映射。一类特殊的算子称为泛函,从空间映射到数集。在人工智能和机器学习领域,许多方法使用样本学习和构造泛化的(非)线性逼近函数,如神经网络、支撑向量机、高斯混合模型、集成学习、回归和主成分分析等,完成数据的分类、判别、降维、回归和因子分析等。在模型结构或者模型复杂度确定的条件下,学习一个函数其实是根据样本确定最优的参数值。通常的做法为首先定义误差或者目标泛函,通过样本学习最小化该泛函,求得最优参数。

算子理论扩展了泛函的概念,在学习理论中占据了重要的地位,但目前的应用基础领域很少有这方面的文献。对数据的操作实际上就是对矩阵的运算,变换矩阵作为算子可以对矩阵进行旋转、投影、对角化。变换的结果由算子的性质决定,因此,研究算子的连续性、可微性、有界性、紧性、正定性、象空间、零空间等具有普遍意义。

1.1 基本概念和定义

1.1.1 空间

在数学分析中,空间是一种抽象的概念,定义为具有某种特殊属性的对象的集合。空间的种类很多,如欧式空间、概率空间、内积空间、拓扑空间、仿射空间等等。空间可以具有度量,由范数定义的度量空间称为赋范空间。空间在度量的定义下可以是完备的或者不完备的,如 Hilbert 空间在内积度量的定义下是完备的。完备的赋范空间称为 Banach 空间,

Hilbert 空间属于 Banach 空间。Hilbert 空间中的度量通过内积定义,其中包含了许多光滑与非光滑函数。它的一个光滑子空间为再生核 Hilbert 空间(Reproduce Kernel Hilbert Space, RKHS),可以通过一个正定核函数生成。在工程中,通常考虑的空间具有三个基本要素,包括对象、结构和测度。对象指要研究的实体,可以是向量、矩阵、函数、子空间、算子等,结构指空间的构成方式,测度确定空间集合的大小。依据不同的研究对象,数据分析中的空间包括向量空间(如欧式空间)、泛函空间(如再生核 Hilbert 空间)。向量空间可以通过正交化的有限或无限个基向量张成,正交性通过向量内积定义。泛函空间可以通过正交基函数构造,如多项式基函数、正交三角函数基。函数的正交性定义为指定区域内两个函数乘积的积分。拓扑空间是一个集合 X 和其上定义的拓扑结构 τ 组成的二元组 (X, τ) 。依不同的作用,测度有多种定义方式,如勒贝格测度、概率测度等。概率测度定义了概率空间,用来度量空间中事件集的发生概率。

范数是定义在空间中对象上的一种度量,有向量范数、矩阵范数、算子范数等。给定实数域 $\mathbb{R}$, 空间 $\mathbb{R}^n$ 中的向量 x 有如下形式的范数:

$$1 \text{ 范数: } \|x\|_1 = \sum_{i=1}^n |x_i|;$$

$$2 \text{ 范数: } \|x\|_2 = \sqrt{\sum_{i=1}^n x_i^2};$$

$$\infty \text{ 范数: } \|x\|_\infty = \max\{|x_1|, |x_2|, \dots, |x_n|\};$$

更一般地,可以定义 p 范数,

$$p \text{ 范数: } \|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}.$$

空间 $\mathbb{R}^{m \times n}$ 的元素为 $m \times n$ 阶的矩阵。若 $A \in \mathbb{R}^{m \times n}$, 则 A 的范数有以下几种形式:

$$1 \text{ 范数: } \|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^m |a_{ij}|, \text{ 即列和最大为范数};$$

$$\infty \text{ 范数: } \|A\|_\infty = \max_{1 \leq i \leq m} \sum_{j=1}^n |a_{ij}|, \text{ 即行和最大为范数};$$

p 范数: $\|A\|_p = (\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^p)^{1/p}, p \in \mathbb{N}, p > 2$;

F 范数: $\|A\|_F = (\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2)^{1/2} = \sqrt{\text{trace}(A^* A)}$, 其中 A^* 为 A

的共轭矩阵。

矩阵范数具有如下一些性质: 对于 $A, B \in \mathbb{R}^{m \times n}, C, D \in \mathbb{R}^{m \times n}, \alpha \in \mathbb{R}$, 有

$\|A\| \geq 0$, 仅当 $A=0$ 时等号成立;

$\|\alpha A\| = |\alpha| \|A\|$;

$\|A+B\| \leq \|A\| + \|B\|$;

$\|CD\| \leq \|C\| \|D\|$;

$\|C\| = \|C^*\|$, C^* 为 C 的共轭矩阵。

例 1.1 L_p 空间及范数

$L^p (1 \leq p < \infty)$ 空间是泛函分析中一类特殊的 Banach 空间, 要求可测函数 $f: \Omega \rightarrow \mathbb{R}$ 在测度空间 $(\Omega, \sum, \mu)$ 中具有有限 p -可积性。 L^p 范数定义为:

$$\|f\|_p = \left(\int_{\Omega} |f|^p d\mu \right)^{1/p} < \infty,$$

特别地, L^2 空间(或记为 L_2) 在数据分析模型中经常用到。 p -范数扩展到有限长度离散向量产生了 l^p 空间, 对于向量 x 具有如下的定义:

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} < \infty$$

1.1.2 紧集与算子

紧集是空间中一类特殊的集合, 如欧式空间 $\mathbb{R}^n$ 中的有界闭集。为什么需要考虑紧集? 在无限维空间中, 许多良好的数学性质未必成立, 从而难以研究点列的极限行为、空间的性质。如果能通过有限的结构来探讨无限情况下的性质, 那么问题就容易解决, 而具有这样有限结构的集合即为紧集。紧集提供了一种利用有限结构研究无限结构的方法。紧集的定义

义可以从不同的角度描述,如序列、拓扑结构。

拓扑空间定义方法:紧集是拓扑空间内的一类特殊点集,它们的任何开覆盖都有有限子覆盖。

序列定义方法:紧集的任意序列有收敛子列,且子列的极限点属于该集合。下面是紧集所具有的一些常用性质:

- (1)在有限维空间紧集即为有界闭集;
- (2)实数空间中的紧集具有最大和最小元素;
- (3)紧集在连续函数下的像仍是紧集;
- (4)定义在紧集上的连续实值函数有界,且有最大和最小值。

紧集是一种良好的结构,而紧算子如何定义,有何用途呢?算子表示了数学物理中的一种功能,是一种作用于对象之上的运算。算子可以表现为函数、矩阵或者其他数学、物理变换。不同的矩阵,产生的作用不同,如投影、旋转、平移等。算子有不同的种类,如线性算子、共轭算子、拉普拉斯算子、积分算子等。下面介绍一些可能用到的算子概念。

紧算子通过集合定义,将有界集映射为相对紧集(relatively compact set)[Conway,1990]。给定算子 $T: X \rightarrow Y$, X, Y 为赋范向量空间,如果对于 X 的任意有界序列 $\{x_n\}_{n=1}^{\infty}$,都存在子序列 $\{x_{n_k}\}_{k=1}^{\infty}$ 使得 $\{T(x_{n_k})\}_{k=1}^{\infty}$ 在 Y 中有界,称 T 为紧的。

拉普拉斯算子(Laplacian) L 是一种微分算子,记为 Δ 或 ∇^2 。在 n 维欧氏空间, L 定义为如下的二阶微分算子:

$$Lf = \Delta f = \nabla^2 f = \nabla \cdot \nabla f,$$

其中: f 为二阶可微函数。拉普拉斯算子在谱聚类算法中多有应用。

在物理学中, $f = f(x, y, z, t)$ 表示关于空间和时间的温度函数,空间的热传导方程表示为:

$$\frac{\partial f}{\partial t} = k \left(\frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} + \frac{\partial^2 f}{\partial z^2} \right) = k \nabla^2 f,$$

或者

$$\frac{\partial f}{\partial t} = k \Delta f$$

式中 ∇^2 或 Δ 表示 Laplace 算子, f 表示热量在空间的分布, k 为常数。该方程也称为扩散方程, 是 Fokker-Plank 方程的原型, 描述了粒子或者热量在空间随时间变化的分布。该方程的解析解表达为热核函数 $G(x, t)$ (即高斯分布) 与 f 的卷积的形式, 即对 $x \in \mathbb{R}^3$,

$$H(f)(x) = G(t, x) * f = \int G(t, x, \tau) f(\tau) d\tau.$$

积分算子 T . 在再生核 Hilbert 空间 (RKHS), 积分算子定义如下:

$$T(f)(x) = \int_{\Omega} K(x, y) f(y) d\mu(y)$$

式中: Ω 表示积分域; $K(\cdot, \cdot)$ 核函数; μ 表示测度, 如概率分布 P 。

在 RKHS 中, 积分算子特征系统与谱聚类、核函数具有紧密的联系。

迹类算子. Hilbert 空间中的紧对称算子 T 称为迹类的 [Weidman, 1990], 如果它的特征值 $\{\lambda_n\}$ 满足 $\sum_{n=1}^{\infty} |\lambda_n| < \infty$ 。

算子范数. 如果 X 和 Y 是 Banach 空间, T 是 $X \rightarrow Y$ 的线性算子, $\|T\|$ 定义为: $\|T\| = \sup\{\|Tx\| : \|x\| \leq 1\}$ 。

算子的迹定义为:

$$\text{tr}(T) = \sum_{n=1}^{\infty} (Te_n, e_n),$$

其中: $\{e_n\}$ 是 H 中标准正交集。

算子的迹范数

$$\|T\|_{\text{tr}} = \sum_{n=1}^{\infty} |\lambda_n|.$$

1.1.3 正交函数基

在泛函空间中, 两个函数之间的正交性通过内积来定义。在离散空间中, 函数在某范围内的离散值构成了向量, 正交性通过内积表示。因此, 一个定义域内函数之间的正交性也可以通过内积来定义, 即两个函数在指定域内的乘积的积分。当该积分为零时, 表示两个函数正交, 否则, 相关。给定一组函数, 若对于任意两个不同的函数, 内积为零; 而对于相

同的函数,内积为常数,则称该函数集满足正交性。进而,若在该集合之外不存在函数与集合内的所有函数正交,则该集合构成了完备正交函数基。完备正交函数基可能具有有限或者无限个元素。就有限情况而言,形式化定义可以描述如下,给定定义域 Ω 、测度 μ ,函数集 $\{f_i \mid i \leq N\}$ 在 Ω 上的正交性定义为:

$$\int_{\Omega} f_i \circ f_j d\mu = \begin{cases} 0, & i \neq j \\ k, & i = j \end{cases}, k \neq 0$$

无限情况下具有类似的定义形式。下面介绍一些常见的正交函数基。

例 1.2 复指数函数基

$\Phi = \{e^{jn\omega_0 t} \mid n=0, \pm 1, \pm 2, \dots\}$ 为闭区间 $[0, T]$ 上完备正交集,其中: $\omega_0 = 2\pi/T$ 为基频。

复指数函数基已经应用于周期信号的傅利叶级数展开,分析信号的频率成分。

例 1.3 勒让德(Legendre) 多项式

$$\Phi = \{p_n(x) \mid n \geq 0\}, \text{ 其中 } P_n(x) = \frac{1}{n!} \left(\frac{d}{dx}\right)^n (x^2 - 1)^n,$$

构成了区间 $[-1, 1]$ 上的正交多项式函数集。函数 $f(x)$ 的勒让德多项式级数形式为:

$$f(x) = \sum_{n=0}^{\infty} c_n P_n(x),$$

其中: $c_n = \frac{2n+1}{2} \int_{-1}^1 f(x) p_n(x) dx$ 。

例 1.4 切比雪夫多项式

n 阶切比雪夫多项式 $T_n(x)$ 定义为:

$$T_n(x) = \begin{cases} \cos(n \arccos x) & |x| \leq 1 \\ \operatorname{ch}(n \operatorname{arcch} x) & |x| > 1 \end{cases}$$

特殊情况下,

$$T_0(x) = 1,$$

$$T_1(x) = x,$$

$$T_2(x) = 2x^2 - 1,$$

.....

$$T_n(x) = 2xT_{n-1}(x) - T_{n-2}(x),$$

在信号处理中,切比雪夫多项式广泛应用于滤波器设计。

1.2 常用不等式

不等式是算法理论的基础,在概率论、矩阵分析、泛函分析、数值优化领域应用广泛。在机器学习领域,不等式发挥着重要的作用。具体来讲,不等式在算法领域的作用体现在两个方面:第一、算法的理论验证。不论是经典算法,还是新构造的算法,人们都需要证实算法的可靠性,保证算法在数学上不存在原理性错误。同时,还要通过推导,论证算法的收敛性、误差分析,计算算法的收敛速度,以保证算法的有效性。第二、算法往往具有一些重要的性质,推导和衍生这些性质需要利用不等式简化。比如,采用不等式估算算法的计算复杂性、空间复杂性。在不同个数学分支中,不等式有很多种类。常见不等式在不同的空间(如欧式空间、概率空间、函数空间)表述形式有一定的差异,但是有些公式在本质上是是一致的。下面介绍五个常用的不等式,前三个是关于概率的不等式,后两者为关于期望的不等式。

1.2.1 Markov 不等式

Markov 不等式是由俄国数学家马尔可夫提出的,描述了非负随机变量大于某一正数的概率的上界[Stein & Shakarchi, 2005]。假设 X 为一非负随机变量, $E(X)$ 存在,则对于任意的 $\epsilon > 0$,

$$P(X > \epsilon) \leq \frac{E(X)}{\epsilon} \quad (1-1)$$

证明: 由于 X 为非负随机变量,则

$$\begin{aligned}
 E(X) &= \int_0^{\infty} xf(x)dx = \int_0^{\epsilon} xf(x)dx + \int_{\epsilon}^{+\infty} xf(x)dx \\
 &\geq \epsilon \int_{\epsilon}^{+\infty} f(x)dx = \epsilon P(X > \epsilon)
 \end{aligned}$$

$$\text{因此, } P(X > \epsilon) \leq \frac{E(X)}{\epsilon}$$

1.2.2 Chebyshev 不等式

Chebyshev 不等式适用于所有的分布形式,描述了随机变量的取值超出某一值的比例。假设随机变量 X 的均值和方差均存在,令 $\mu = E(X)$, $\sigma^2 = V(X)$,则对于任意的 $\epsilon > 0$,Chebyshev 不等式定义为[现代应用数学手册编委会,2000]:

$$P(|X - \mu| \geq \epsilon) \leq \frac{\sigma^2}{\epsilon^2}, \quad (1-2)$$

或者

$$P(|Z| \geq \epsilon) \leq \frac{1}{\epsilon^2},$$

$$\text{其中: } Z = \frac{X - \mu}{\sigma}.$$

证明: 仅考虑连续密度函数情况。设 $P(x)$ 的密度函数为 $f(x)$,则

$$\begin{aligned}
 P(|X - \mu| \geq \epsilon) &= \int_{|x - \mu| \geq \epsilon} p(x)dx = \int_{\mu + \epsilon}^{\infty} p(x)dx + \int_{-\infty}^{\mu - \epsilon} p(x)dx \\
 &= \int_{x - \mu \leq -\epsilon} \frac{|x - \mu|^2}{\epsilon^2} p(x)dx + \int_{x - \mu \geq \epsilon} \frac{|x - \mu|^2}{\epsilon^2} p(x)dx \\
 &\leq \int_{-\infty}^{\mu - \epsilon} \frac{|x - \mu|^2}{\epsilon^2} p(x)dx + \int_{\mu + \epsilon}^{\infty} \frac{|x - \mu|^2}{\epsilon^2} p(x)dx \\
 &\quad + \int_{\mu - \epsilon}^{\mu + \epsilon} \frac{|x - \mu|^2}{\epsilon^2} p(x)dx \\
 &= \int_{-\infty}^{\infty} \frac{|x - \mu|^2}{\epsilon^2} p(x)dx = \frac{\sigma^2}{\epsilon^2}
 \end{aligned}$$

1.2.3 Hoeffding 不等式

Hoeffding 不等式描述了一组随机变量的均值偏离它的期望的程度