

国外计算机科学教材系列

统计学习基础

——数据挖掘、推理与预测

The Elements of Statistical Learning

Data Mining, Inference, and Prediction

Springer Series in Statistics

Trevor Hastie
Robert Tibshirani
Jerome Friedman

The Elements of
Statistical Learning

Data Mining, Inference,
and Prediction

Trevor Hastie

[美] Robert Tibshirani 著

Jerome Friedman

范明 柴玉梅 咎红英 等译



电子工业出版社

Publishing House of Electronics Industry
<http://www.phei.com.cn>



统计学习基础

——数据挖掘、推理与预测

The Elements of Statistical Learning

Data Mining, Inference, and Prediction

随着计算机和信息时代的到来,统计问题的规模和复杂性都有了急剧增加。数据存储、组织和检索领域的挑战导致一个新领域“数据挖掘”的产生。数据挖掘是一个多学科交叉领域,涉及数据库技术、机器学习、统计学、神经网络、模式识别、知识库、信息提取、高性能计算等诸多领域,并在工业、商务、财经、通信、医疗卫生、生物工程、科学等众多行业得到了广泛的应用。

本书试图将学习领域中许多重要的新思想汇集在一起,并且在统计学的框架下解释它们。尽管有些数学细节是必要的,但本书强调的是方法和它们的概念基础,而不是理论性质。本书内容广泛,从有指导的学习(预测)到无指导的学习,应有尽有。包括神经网络、支持向量机、分类树和提升等主题,是同类书籍中介绍得最全面的,适合从事数据挖掘和机器学习研究的读者阅读。

作者简介

Trevor Hastie, Robert Tibshirani 和 Jerome Friedman 都是斯坦福大学统计学教授,并在这个领域做出了杰出的贡献。Hastie 和 Tibshirani 提出了广义加法模型,并出版了专著“Generalized Additive Models”。Hastie 的主要研究领域为:非参数回归和分类、统计计算以及生物信息学、医学和工业的特殊数据挖掘问题。他提出了主曲线和主曲面的概念,并用 S-PLUS 编写了大量统计建模软件。Tibshirani 的主要研究领域为:应用统计学、生物统计学和机器学习。他提出了套索的概念,还是“An Introduction to the Bootstrap”一书的作者之一。Friedman 是 CART、MARS 和投影寻踪等数据挖掘工具的发明人之一。他不仅是位统计学家,而且是物理学家和计算机科学家,并先后在物理学、计算机科学和统计学的一流杂志上发表了论文 80 余篇。

ISBN 7-5053-9331-6



9 787505 393318 >



责任编辑:杜阎燕
封面设计:毛惠庚

本书贴有激光防伪标志,凡没有防伪标志者,属盗版图书

ISBN 7-5053-9331-6 定价:45.00 元



国外计算机科学教材系列

统计学习基础

——数据挖掘、推理与预测

The Elements of Statistical Learning
Data Mining, Inference, and Prediction

Trevor Hastie
[美] Robert Tibshirani 著
Jerome Friedman

范明 柴玉梅 咎红英 等译

电子工业出版社
Publishing House of Electronics Industry
北京·BEIJING

内 容 简 介

计算和信息技术的飞速发展带来了医学、生物学、财经和营销等诸多领域的海量数据。理解这些数据是一种挑战,这导致了统计学领域新工具的发展,并延伸到诸如数据挖掘、机器学习和生物信息学等新领域。许多工具都具有共同的基础,但常常用不同的术语来表达。本书介绍了这些领域的一些重要概念。尽管应用的是统计学方法,但强调的是概念,而不是数学。许多例子附以彩图。本书内容广泛,从有指导的学习(预测)到无指导的学习,应有尽有。包括神经网络、支持向量机、分类树和提升等主题,是同类书籍中介绍得最全面的。

本书可作为高等院校相关专业本科生和研究生的教材,对于统计学相关人员、科学界和业界关注数据挖掘的人,本书值得一读。

Translation from the English language edition:

The Elements of Statistical Learning by Trevor Hastie, Robert Tibshirani, and Jerome Friedman.

Copyright © 2001 Trevor Hastie, Robert Tibshirani, Jerome Friedman.

Springer-Verlag is a company in the BertelsmannSpringer publishing group.

All Rights Reserved.

Authorized Simplified Chinese language edition by Publishing House of Electronics Industry. Copyright © 2004.

本书中文简体字翻译版由斯普林格出版公司授予电子工业出版社。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。

版权贸易合同登记号 图字: 01-2002-4937

图书在版编目(CIP)数据

统计学习基础——数据挖掘、推理与预测/(美)黑斯蒂(Hastie, T.)等著;范明等译.

-北京:电子工业出版社,2004.1

(国外计算机科学教材系列)

书名原文: The Elements of Statistical Learning: Data Mining, Inference, and Prediction

ISBN 7-5053-9331-6

I. 统... II. ①黑... ②范... III. 统计学-教材 IV. C8

中国版本图书馆CIP数据核字(2003)第124311号

责任编辑: 杜闽燕

印 刷: 北京兴华印刷厂

出版发行: 电子工业出版社

北京市海淀区万寿路173信箱 邮编: 100036

经 销: 各地新华书店

开 本: 787 × 1092 1/16 印张: 24.75 字数: 634千字 彩插: 22

印 次: 2004年1月第1次印刷

定 价: 45.00元

凡购买电子工业出版社的图书,如有缺损问题,请向购买书店调换;若书店售缺,请与本社发行部联系。联系电话:(010) 68279077。质量投诉请发邮件至 zltts@phei.com.cn, 盗版侵权举报请发邮件至 dbqq@phei.com.cn。



图 1.3

DNA 微阵列数据：人体瘤数据 6830 个基因（行）和 64 个样本（列）的表达水平矩阵。只显示 100 行的随机选样。显示的是热度图，从鲜绿（负，低显性）到鲜红（正，高显性）。遗漏的值为灰色。行和列以随机次序显示

0/1 响应的线性回归




图 2.1

一个二维空间上的分类例子。类用二元变量编码 (GREEN = 0, RED = 1), 并且用线性回归拟合。直线是 $x^T \hat{\beta} = 0.5$ 定义的判定边界。红色区域表示输入空间被分类为 RED 的部分, 而绿色区域被分类为 GREEN

15- 最近邻分类




图 2.2

与图 2.1 相同的二维分类例子。类用二元变量编码 (GREEN = 0, RED = 1), 并用式 (2.8) 的 15- 最近邻平均拟合。因此, 预测类用 15- 最近邻的多数表决确定

1- 最近邻分类




图 2.3

与图 2.1 相同的二维分类例子。类用二元变量编码 (GREEN = 0, RED = 1), 并用 1- 最近邻分类预测


 k - 最近邻数

图 2.4

图 2.1、图 2.2 和图 2.3 使用的模拟例子的误分类曲线。使用一个规模为 200 的训练样本和一个规模为 10 000 的检验样本。红色曲线是 k - 最近邻分类的检验误差, 绿色曲线是训练误差。线性回归的结果是三自由度上较大的红色和绿色方块。紫色直线是最优的贝叶斯误差率




图 2.7

一个模拟例子，表明维灾难及其对MSE、偏倚和方差的影响。对于 $p = 1, \dots, 10$ ，输入特征值在 $[-1, 1]^p$ 上均匀分布。左上角的图显示IR上的(无噪声)目标函数: $f(X) = e^{-8\|X\|^2}$ ，并图示1-最近邻对 $f(0)$ 估计所产生的误差。训练点用蓝色粗体标记。右上角的图展示1-最近邻域的半径随维数 p 增加的原因。左下角的图展示1-最近邻域的平均半径。右下角的图显示作为维数 p 的函数，MSE、平方偏倚和方差的曲线




图 2.8


一个与图 2.7 具有相同设置的模拟例子。这里，除一个维为 $f(X) = \frac{1}{2}(X_1 + 1)^3$ 外，函数为常数。方差占支配地位

图 2.9

显示1-最近邻相对于最小二乘方关于模型 $Y = f(X) + \varepsilon$ 的期望预测误差的曲线(在 $x_0 = 0$)。对于红色曲线, $f(x) = x_1$; 而对于绿色曲线, $f(x) = \frac{1}{2}(x_1 + 1)^3$



➡ 图 3.5

前列腺癌例子所有可能的子集模型。对每个子集容量，显示该容量的每个模型的残差平方和



➡ 图 3.11

对于一个简单例子，不同方法的系数曲线图：两个具有相关度 ± 0.5 的输入，而实际的回归系数是 $\beta = (4, 2)$






图 4.1

左图显示取自三个类的一些数据点, 以及由线性判别分析找出的线性判定边界。右图显示二次判定边界。这些边界通过找出 5 维空间 $X_1, X_2, X_1X_2, X_1^2, X_2^2$ 中的线性边界得到。在该空间上的线性不等式是原空间中的二次不等式




图 4.2

数据取自 IR^2 中的三个类, 并容易被线性判定边界分开。右图显示被线性判别分析找到的边界。左图显示被指示响应变量的线性回归找出的边界。中间类完全被屏蔽 (不占支配地位)




图 4.3

对于一个 3- 类问题, IR 上的线性回归的屏蔽作用。底部的底线图 (rug plot) 指示每个观测的位置和类隶属关系。每幅图上的三条曲线是 3- 类指示变量的拟合回归; 例如, 对于红色类, 红色观测的 y_{red} 为 1, 而绿色和蓝色观测的 y_{red} 为 0。每幅图的上方是训练误差率。对于该问题, 贝叶斯误差率为 0.025, 与 LDA 误差率一样




图 4.4

元音训练数据的二维图。有 11 个类， $X \in \mathbb{R}^{10}$ 。这是 LDA 模型（见第 4.3.3 节）下的最佳视图。加重的圆是每个类的投影均值向量。类的重叠相当多

图 4.5

左图显示三个高斯分布，它们具有相同的协方差和不同的均值。图中包含的是每种情况围绕概率 95% 的常量密度围线。图中显示了每两个类之间的贝叶斯判定边界（虚线），而分离所有三个类的贝叶斯判定边界是粗实线（前者的子集）。在右图中，我们看到取自每个高斯分布的容量为 30 的样本，以及拟合的 LDA 判定边界





图 4.6

拟合二次边界的两种方法。对于图 4.1 的数据，左图显示二次判定边界（使用 5 维空间 $X_1, X_2, X_1X_2, X_1^2, X_2^2$ 上的 LDA 得到）。右图显示 QDA 发现的二次判定边界。差别很小，通常也是如此



线性判别分析




图 4.8

到标准变量对上的 4 个投影。注意，随标准变量的秩增加，形心变得集中。在右下图，它们似乎被叠加，并且类变得最乱




图 4.11

在前两个标准变量生成的二维子空间中元音训练数据的判定边界。注意，在任意较高维的子空间中，判定边界是较高维的仿射平面，不能用线表示




图 4.12

南非心脏病数据的散点图。每幅图显示一对风险因素，并且病例和控制用颜色编码（红色是病例）。心脏病家族史变量（famhist）是二元的（yes 或 no）




图 4.13

一个小例子，包含两个可被超平面分隔的类。橙色线是最小二乘方解，它将一个训练数据误分类。图中还显示了两个蓝色分隔超平面，它们被以不同的随机初始化的感知器学习算法找出




图 4.15

与图4.13相同的数据。阴影区域描述分离两个类的最大边缘。有三个支撑点，它们在边缘的边界上，而最佳分离超平面（蓝线）将隔离带一分为二。图中还显示了逻辑斯谛回归找出的边界（红线），它非常接近最佳分离超平面（见第12.3.3节）





图 5.3

4个不同模型的逐点方差曲线。 X 包含50个点，随机地取自 $U[0, 1]$ ，一个假定的误差模型具有常数方差。线性 and 三次多项式拟合分别具有2个和4个自由度，而三次样条和自然三次样条具有6个自由度。三次样条在0.33和0.66有两个纽结，而自然样条在0.1和0.9具有边界纽结，并且有4个内部纽结均匀地散布在它们中间

音素例子



音素分类：原始的和受限逻辑斯缔回归




图 5.5

上图显示对数周期图；对于15个例子，每个音素“aa”和“ao”从695个“aa”和1022个“ao”中选样，对数周期图作为频率的函数显示。每个对数周期在256个均匀分布的频率点上测量。下面的图显示逻辑斯缔回归系数（作为频率的函数），使用256个对数周期图作为输入值，通过极大似然拟合数据。在红色曲线上，限制系数是光滑的，而在锯齿状灰色曲线上没有限制

m354310




图 5.7

[上图]臭氧浓度作为Daggot气压梯度的函数的光滑样条拟合。两个拟合对应于光滑参数的不同值。光滑参数的选取是为了得到5个和15个由 $df_\lambda = \text{trace}(\mathbf{S}_\lambda)$ 定义的有效自由度。[左下图]两个光滑样条矩阵的前25个本征值。前两个本征值恰为1，并且所有的本征值都大于或等于零。[右下图]样条光滑子矩阵的第三个和第六个本征向量。在每条曲线中， $\mathbf{u}_k$ 都对照 $\mathbf{x}$ 绘制，并因此视为 x 的函数。图底部的底线指示数据点的出现。阻尼函数表示这些函数的光滑版本（使用5df光滑子）





图 5.9

非线性加法误差模型 (5.22) 的实现，左上图显示其 $EPE(\lambda)$ 和 $CV(\lambda)$ 曲线。其他图对于不同的 df_λ ，显示数据、真实函数（紫色）和拟合曲线（绿色），其中黄色阴影是拟合曲线 ± 2 倍标准误差频带

加法自然三次样条



自然三次样条——张量积




图 5.11

图 2.1 的模拟例子。左图显示加法逻辑斯缔回归模型的判定边界，在两个坐标上都使用自然样条（全部 $df = 1 + (4 - 1) + (4 - 1) = 7$ ）。右图显示在每个坐标上使用自然样条基张量积的结果（全部 $df = 4 \times 4 = 16$ ）。紫色虚线边界是该问题的贝叶斯判定边界




图 5.12

用围线图显示薄板样条拟合心脏病数据。响应是收缩血压（sbp），它作为年龄（age）和肥胖（obesity）的函数建模。图中标定有数据点以及用做纽结的点的格。谨慎使用来自数据凸包之内（红色）格的纽结，并忽略数据凸包之外（绿色）格的纽结




图 5.14

上图显示一个NMR信号，小波收缩版本以绿色叠加。左下图表示原信号的小波变换，使用symmlet-8基函数，取到 V_4 。每个系数用垂直条的高度（正的或负的）表示。右下图表示使用S-PLUS中的wvshrink函数收缩后的小波系数。wvshrink函数实现了Donoho和Johnstone的小波自适应SureShrink方法