



格致方法·定量研究系列 吴晓刚 主编

定序因变量的logistic 回归模型

[美] 安·A. 奥康奈尔(Ann A.O'Connell) 著
赵亮员 译



- 革新研究理念
- 丰富研究工具
- 最权威、最前沿的定量研究方法指南

15

格致出版社 上海人民出版社

吴晓刚 主编

定序因变量的 logistic 回归模型

[美] 安·A. 奥康奈尔(Ann A.O'Connell) 著
赵亮员 译



SAGE Publications, Inc.

格致出版社 上海人民出版社

图书在版编目(CIP)数据

定序因变量的 logistic 回归模型 / (美)安·A. 奥康奈尔著;赵亮员译.—上海:格致出版社;上海人民出版社,2018. 7

(格致方法·定量研究系列)

ISBN 978 - 7 - 5432 - 2878 - 8

I. ①定… II. ①安… ②赵… III. ①回归分析-统计模型-研究 IV. ①0212. 1

中国版本图书馆 CIP 数据核字(2018)第 110831 号

责任编辑 贺俊逸

格致方法·定量研究系列

定序因变量的 logistic 回归模型

[美]安·A. 奥康奈尔 著

赵亮员 译

出 版 格致出版社

上海人民出版社

(200001 上海福建中路 193 号)

发 行 上海人民出版社发行中心

印 刷 浙江临安曙光印务有限公司

开 本 920×1168 1/32

印 张 5.75

字 数 118,000

版 次 2018 年 7 月第 1 版

印 次 2018 年 7 月第 1 次印刷

ISBN 978 - 7 - 5432 - 2878 - 8/C · 204

定 价 35.00 元

出版说明

由香港科技大学社会科学部吴晓刚教授主编的“格致方法·定量研究系列”丛书，精选了世界著名的 SAGE 出版社定量社会科学研究丛书，翻译成中文，起初集结成八册，于 2011 年出版。这套丛书自出版以来，受到广大读者特别是年轻一代社会科学工作者的热烈欢迎。为了给广大读者提供更多的方便和选择，该丛书经过修订和校正，于 2012 年以单行本的形式再次出版发行，共 37 本。我们衷心感谢广大读者的支持和建议。

随着与 SAGE 出版社合作的进一步深化，我们又从丛书中精选了三十多个品种，译成中文，以飨读者。丛书新增品种涵盖了更多的定量研究方法。我们希望本丛书单行本的继续出版能为推动国内社会科学定量研究的教学和研究作出一点贡献。

总序

2003年,我赴港工作,在香港科技大学社会科学部教授研究生的两门核心定量方法课程。香港科技大学社会科学部自创建以来,非常重视社会科学研究方法论的训练。我开设的第一门课“社会科学里的统计学”(Statistics for Social Science)为所有研究型硕士生和博士生的必修课,而第二门课“社会科学中的定量分析”为博士生的必修课(事实上,大部分硕士生在修完第一门课后都会继续选修第二门课)。我在讲授这两门课的时候,根据社会科学研究的数理基础比较薄弱的特点,尽量避免复杂的数学公式推导,而用具体的例子,结合语言和图形,帮助学生理解统计的基本概念和模型。课程的重点放在如何应用定量分析模型研究社会实际问题上,即社会研究者主要为定量统计方法的“消费者”而非“生产者”。作为“消费者”,学完这些课程后,我们一方面能够读懂、欣赏和评价别人在同行评议的刊物上发表的定量研究的文章;另一方面,也能在自己的研究中运用这些成熟的方法论技术。

上述两门课的内容,尽管在线性回归模型的内容上有少

量重复,但各有侧重。“社会科学里的统计学”从介绍最基本的社会研究方法论和统计学原理开始,到多元线性回归模型结束,内容涵盖了描述性统计的基本方法、统计推论的原理、假设检验、列联表分析、方差和协方差分析、简单线性回归模型、多元线性回归模型,以及线性回归模型的假设和模型诊断。“社会科学中的定量分析”则介绍在经典线性回归模型的假设不成立的情况下的一些模型和方法,将重点放在因变量为定类数据的分析模型上,包括两分类的 logistic 回归模型、多分类 logistic 回归模型、定序 logistic 回归模型、条件 logistic 回归模型、多维列联表的对数线性和对数乘积模型、有关删节数据的模型、纵贯数据的分析模型,包括追踪研究和事件史的分析方法。这些模型在社会科学研究中有着更加广泛的应用。

修读过这些课程的香港科技大学的研究生,一直鼓励和支持我将两门课的讲稿结集出版,并帮助我将原来的英文课程讲稿译成了中文。但是,由于种种原因,这两本书拖了多年还没有完成。世界著名的出版社 SAGE 的“定量社会科学研究”丛书闻名遐迩,每本书都写得通俗易懂,与我的教学理念是相通的。当格致出版社向我提出从这套丛书中精选一批翻译,以飨中文读者时,我非常支持这个想法,因为这从某种程度上弥补了我的教科书未能出版的遗憾。

翻译是一件吃力不讨好的事。不但要有对中英文两种语言的精准把握能力,还要有对实质内容有较深的理解能力,而这套丛书涵盖的又恰恰是社会科学中技术性非常强的内容,只有语言能力是远远不能胜任的。在短短的一年时间里,我们组织了来自中国内地及香港、台湾地区的二十几位

研究生参与了这项工程,他们当时大部分是香港科技大学的硕士和博士研究生,受过严格的社会科学统计方法的训练,也有来自美国等地对定量研究感兴趣的博士研究生。他们是香港科技大学社会科学部博士研究生蒋勤、李骏、盛智明、叶华、张卓妮、郑冰岛,硕士研究生贺光烨、李兰、林毓玲、肖东亮、辛济云、於嘉、余珊珊,应用社会经济研究中心研究员李俊秀;香港大学教育学院博士研究生洪岩璧;北京大学社会学系博士研究生李丁、赵亮员;中国人民大学人口学系讲师巫锡炜;中国台湾“中央”研究院社会学所助理研究员林宗弘;南京师范大学心理学系副教授陈陈;美国北卡罗来纳大学教堂山分校社会学系博士候选人姜念涛;美国加州大学洛杉矶分校社会学系博士研究生宋曦;哈佛大学社会学系博士研究生郭茂灿和周韵。

参与这项工作的许多译者目前都已经毕业,大多成为中国内地以及香港、台湾等地区高校和研究机构定量社会科学方法教学和研究的骨干。不少译者反映,翻译工作本身也是他们学习相关定量方法的有效途径。鉴于此,当格致出版社和 SAGE 出版社决定在“格致方法·定量研究系列”丛书中推出另外一批新品种时,香港科技大学社会科学部的研究生仍然是主要力量。特别值得一提的是,香港科技大学应用社会经济研究中心与上海大学社会学院自 2012 年夏季开始,在上海(夏季)和广州南沙(冬季)联合举办《应用社会科学研究方法研修班》,至今已经成功举办三届。研修课程设计体现“化整为零、循序渐进、中文教学、学以致用”的方针,吸引了一大批有志于从事定量社会科学研究的博士生和青年学者。他们中的不少人也参与了翻译和校对的工作。他们在

繁忙的学习和研究之余,历经近两年的时间,完成了三十多本新书的翻译任务,使得“格致方法·定量研究系列”丛书更加丰富和完善。他们是:东南大学社会学系副教授洪岩璧,香港科技大学社会科学部博士研究生贺光烨、李忠路、王佳、王彦蓉、许多多,硕士研究生范新光、缪佳、武玲蔚、臧晓露、曾东林,原硕士研究生李兰,密歇根大学社会学系博士研究生王骁,纽约大学社会学系博士研究生温芳琪,牛津大学社会学系研究生周穆之,上海大学社会学院博士研究生陈伟等。

陈伟、范新光、贺光烨、洪岩璧、李忠路、缪佳、王佳、武玲蔚、许多多、曾东林、周穆之,以及香港科技大学社会科学部硕士研究生陈佳莹,上海大学社会学院硕士研究生梁海祥还协助主编做了大量的审校工作。格致出版社编辑高璇不遗余力地推动本丛书的继续出版,并且在这个过程中表现出极大的耐心和高度的专业精神。对他们付出的劳动,我在此致以诚挚的谢意。当然,每本书因本身内容和译者的行文风格有所差异,校对未免挂一漏万,术语的标准译法方面还有很大的改进空间。我们欢迎广大读者提出建设性的批评和建议,以便再版时修订。

我们希望本丛书的持续出版,能为进一步提升国内社会科学定量教学和研究水平作出一点贡献。

吴晓刚

于香港九龙清水湾

序

在过去 60 年中, logit 模型已经成为社会科学中最流行的统计方法。自从伦西斯·李克特(Rensis Likert)1932 年出版《态度测量的方法》(*A Technique for the Measurement of Attitudes*)以来,人们对人类态度的测量方法一直都在变化着。实际上,今天的任何社会调查都已将李克特类型的量表作为一种主要的方法。一个典型的李克特量表有五个类别(例如,非常不同意、同意、不知道、同意、非常同意),用以测量个体对问题的响应,尽管它在别的地方也许还有三到七个或更多的响应类别。如果我们将五个类别编码为从 1 到 5,那么我们可以用线性回归模型来估计李克特量表,这也是早些时候分析这样的数据时所采用的方法。然而,这种方法也存在诸多明显的问题。首先,经典线性回归假设连续因变量是距离相等的定序因变量类别(ordered response categories)。一个李克特类型的量表,或者任何其他的定序量表,虽然是定序的,但并不一定在类别间等距。其次,也许是更重要的,这样的量表所得出的分布不是经典线性回归所假定的数据呈现的正态分布。

为了分析定序数据的这种属性,也有其他的方法,经常

使用的是列联表和对数线性模型的形式,具体可以参见:《定序数据分析》(*Analysis of Ordinal Data*),作者海德普兰德、莱恩和罗森塔尔(Hiderbrand, Laing, Rosenthal);《对数线性模型》(*Log-linear Models*),作者诺克和伯克(Knoke & Burke);《潜变量的对数线性模型》(*Loglinear Models With Latent Variables*),作者哈根纳斯(Hagenaars);《定序对数线性模型》(*Ordinal Log-Linear Models*),作者石井坤茨(Ishii-Kuntz);《列联表分析中的比数比》(*Odds Ratios in the Analysis of Contingency Tables*),作者鲁达斯(Rudas)。然而,这些方法都不在回归的框架下,而回归方法正是社会科学中广为人知且被广泛应用的量化方法。

安·A. 奥康奈尔的这本书填补了空白。即使有的著作也将定序因变量变量在 logit 模型中加以处理,但本书则完全通过呈现三种形式的因变量来集中关注该类 logit 模型,这些因变量抓住了响应的定序本质。本书以展示来自儿童早期追踪研究的实例开始,其中的主要因变量虽然不是李克特量表,但其对早期读写和算术熟练度的测量还是定序的。作者进而回顾了 logistic 回归,并接着呈现三个核心主题章节:累积或比例比数模型(cumulative or proportional odds model),连续比例模型(continuation ratio model)以及相邻类别模型(adjacent categories model)。与此同时,书中给出了 SAS® 和 SPSS® 的案例。尽管比例比数模型也许是三种方法中最常用的,但在结论部分,读者可以领会到关于替代方法尤其是什么时候使用替代方法的提示。

廖福挺

目 录

序	1
第 1 章 概述	1
第 1 节 本书的目的	5
第 2 节 软件和句法	7
第 3 节 本书结构	8
第 2 章 背景介绍：儿童早期追踪研究	11
第 1 节 儿童早期追踪研究概述	12
第 2 节 定序结果的实际重要性	15
第 3 节 模型中的变量	16
第 3 章 背景：logistic 回归	19
第 1 节 logistic 回归概述	20
第 2 节 模型拟合的评估	25
第 3 节 模型的解释	27
第 4 节 关联的测量	30
第 5 节 logistic 回归	31
第 6 节 比较统计软件间的结果	40

试读结束：需要全本请在线购买：www.ertongbook.com

第 4 章 定序结果的累积（比例）比数模型	45
第 1 节 累积比数模型概述	46
第 2 节 单个解释变量的累积比数模型	50
第 3 节 累积比数的全模型分析	64
第 4 节 logit 中的比例比数和线性假设	68
第 5 节 累积比数模型的替代方法	73
第 6 节 偏比例比数	76
第 5 章 连续比例模型	83
第 1 节 连续比例模型概述	84
第 2 节 关联函数	88
第 3 节 相关的概率	90
第 4 节 因变量的向性和连续比例的形成	92
第 5 节 使用 logit 关联和重构数据的连续比例模型	94
第 6 节 使用互补双对数关联的连续比例模型	103
第 7 节 关联的选择和两个互补双对数模型的等价	109
第 8 节 连续比例模型的方法选择	112
第 9 节 ECLS-K 数据的全模型连续比例分析	114
第 6 章 相邻类别模型	119
第 1 节 相邻类别模型概述	120
第 2 节 仅有性别的模型	123
第 3 节 两个解释变量的相邻类别模型	129

第 4 节 全相邻类别模型分析	131
第 7 章 结论	133
第 1 节 本书内容总结	134
第 2 节 进一步研究的考虑	138
附录	141
注释	152
参考文献	154
译名对照表	161

第 1 章

概 述

对于很多在教育和社会科学中的因变量,定序尺度提供了一种将可能的结果区分开来的简单且便捷的方法,而这些可能结果最好被看成是等级定序的(rank-orderd)。定序数据的主要特点,是指定给所测量变量的相继类别的数字代表的量级上的差异,或者“大于”或者“小于”的性质(Stevens, 1946, 1951)。一些定序数据的例子包括:对开放式答案或文字进行编码的一类题目,以及解决以能力改善为基础的答案的计算方案(例如,0 = 差,1 = 可以接受,2 = 优秀)。对比之下,名义水平的数据发生在数值用于通过认定类别之间简单的质的差别来测量一个变量的情况(例如,1 = 男性,或者2 = 女性;所在学校的地理位置描述:1 = 乡村,2 = 城市,3 = 郊区,等等);名义变量没有定序数据的方向特征。另一方面,在定距或者定比水平尺度上测量的变量的确使用了表明定序数据“大于”或者“小于”属性的尺度值,但还保持了在尺度间相邻值距离均等或者间隔均等长度的属性。以摄氏尺度测量的温度是我们熟知的定距水平变量的例子。然而,定距水平的变量的零点相对主观,而非绝对。拥有所有定距尺度属性但也有真实零点的变量,被称为定比水平。例如,对一项任务的反应时间、重量以及距离等是熟悉的定比水平的变量。^[1]

定序类别在将数字指派为代表贡献、建构或者行为的相继类别且有方向意义上的差异的研究情境下很常见。纳普(Knapp, 1999)使用定序评级法,通过划分轻微的(1)、适中的(2)、严重的(3)尺度类别来评估疾病的严重程度。在纳普的研究中,归于疾病严重度类别的数字代表了逐渐增加的严重度,在这个意义上,“适中”比“轻微”更严重,而“严重”比“适中”更严重。赋予“严重”案例的数值并不是说“严重”是“轻微”的三倍严重程度,而是说“严重”的疾病严重度比“轻微”类别的疾病严重度要大,也比“适中”类别的那些要大。

用来代表进度上更严重的类别的数字选择很方便地保留了定义类别本身的“大于”或者“小于”的隐含属性。数字是对研究的属性进行建模,例如疾病的严重程度,并被用来保留类别的传递性;如果值(3)代表着比值(2)严重得多的状态,而值(2)又代表着比值(1)严重得多的状态,那么传递性的特征意味着值(3)代表的状态比值(1)代表的状态要严重得多(Cliff & Keats, 2003; Krantz, Luce, Suppes & Tversky, 1971)。

对定序尺度变量的测量是类似的。定序尺度在咨询服务和精神疗法中已经用于主观的概率或者可能性的判断中(例如,对从1=“非常不可能”到5=“非常可能”进行评分)(Ness, 1995)。一个客户在经过治疗后的临床表现可以归类为:恶化(1)、没有变化(2)、改善(3)(Grissom, 1994)。健康研究者经常使用五级尺度来描述健康相关行为的“改变阶段”,例如,戒烟、使用避孕套、运动行为、减肥努力(Hedeker & Mermelstein, 1998; Plotnikoff, Blanchard, Hotz & Rhodes, 2001; Prochaska & DiClemente, 1983, 1986; Prochaska, DiClemente & Norcross, 1992)。在改变阶段模型中,朝着行

为改变的意向或者行为通常通过以下阶段来测量:(1)意图前期(precontemplation);(2)意图期(contemplation);(3)准备期(preparation);(4)行动期(action)和(5)维持期(maintenance)。教师对在他们的教室里所实施的教育改革的关注体验也通过定序尺度来测量,它代表了关注的焦点从1(自身)到7(他人)(Hall & Hordes, 1984; van den Berg, Slegers, Geijsel & Vandeberghe, 2000)。在童年早期教育中,早期读写能力的层次体的掌握指标会影响青少年儿童的读写熟练度,本质上可以通过定序来归类:(1)语音语韵觉识(phonemic awareness);(2)发音(phonics);(3)流利阅读(fluency);(4)词汇(vocabulary);(5)文本理解(text comprehensive)(早期阅读能力改善中心,Center for the Improvement of Early Reading Achievement, CIERA, 2000)。

尽管定序结果可以是简单且有意义的,但对它们进行理想的统计处理对很多实证研究者而言仍然是一项挑战(Cliff, 1996a; Clogg & Shihadeh, 1994; Ishii-Kuntz, 1994)。历史上,研究者对定序结果的分析依赖于两种非常不同的方法。一些研究者选择使用定序结果的参数模型,例如通过将定序结果作为至少定距水平的变量的多元线性回归,假设这些方法的稳健性克服了任何可能的解释问题。其他的研究者选择将定序变量严格地当做类别变量对待,并运用对数线性或非参数方法来理解数据。尽管两种策略在研究问题的基础上都能够说明问题,但它们都不是发展出定序结果的解释模型的最佳方法(Agresti, 1989; Cliff, 1996a; Clogg & Shihadeh, 1994; O'Connell, 2000),尤其是当分析的焦点是在这些定序分数的区分方面时。