



普通高等教育“十一五”国家级规划教材

21世纪
统计学
系列教材

Statistics

21世纪统计学系列教材

Applied Regression Analysis

应用回归分析 (第四版)

何晓群 刘文卿 编著



中国人民大学出版社

普通高等教育“十一五”国家级规划教材



Statistics 21世纪统计学系列教材

Applied Regression Analysis

应用回归分析

(第四版)

何晓群 刘文卿 编著

中国人民大学出版社

· 北京 ·

图书在版编目 (CIP) 数据

应用回归分析/何晓群, 刘文卿编著. —4 版. —北京: 中国人民大学出版社, 2015.3
21 世纪统计学系列教材
ISBN 978-7-300-20980-7

I. ①应… II. ①何… ②刘… III. ①回归分析-高等学校-教材 IV. ①O212.1

中国版本图书馆 CIP 数据核字 (2015) 第 053941 号

普通高等教育“十一五”国家级规划教材
21 世纪统计学系列教材

应用回归分析 (第四版)

何晓群 刘文卿 编著

Yingyong Huigui Fenxi

出版发行 中国人民大学出版社

社址 北京中关村大街 31 号

电话 010-62511242 (总编室)

010-82501766 (邮购部)

010-62515195 (发行公司)

网址 <http://www.crup.com.cn>

<http://www.ttrnet.com> (人大教研网)

经 销 新华书店

印 刷 三河市汇鑫印务有限公司

规 格 185 mm×260 mm 16 开本

印 张 18.75 插页 1

字 数 403 000

邮政编码 100080

010-62511770 (质管部)

010-62514148 (门市部)

010-62515275 (盗版举报)

版 次 2001 年 6 月第 1 版

2015 年 4 月第 4 版

印 次 2015 年 4 月第 1 次印刷

定 价 34.00 元

总序

贾丹桂

改革开放以来，高等统计教育有了很大的发展。随着课程设置的不断调整，有不少教材出版，同时也翻译引进了一些国外优秀教材。作为培养我国统计专门人才的摇篮，中国人民大学统计学系自1952年创建以来，走过了风风雨雨，一直坚持着理论与应用相结合的办学方向，培养能够理论联系实际、解决实际问题的高层次人才。随着新知识经济和网络时代的到来，我们在教学科研的实践中，深切地感受到，无论是自然科学领域、社会科学领域的研究，还是国家宏观管理和企业生产经营管理，甚至在人们的日常生活中，信息需求量日益增多，信息处理技术更加复杂，作为信息技术支柱的统计方法，越来越广泛地应用于各个领域。

面对新的形势，我们一直在思索，课程设置、教材选择、教学方式等怎样才能使学生适应社会经济发展的客观需要。在反复酝酿、不断尝试的基础上，我们决定与统计学界的同仁，共同编写、出版一套面向21世纪的统计学系列教材。

这套系列教材聘请了中国科学院院士、中国科技大学陈希孺教授，上海财经大学数量经济研究院张尧庭教授，中国科学院数学与系统科学研究所冯士雍研究员等作为编委。他们长期任中国人民大学的兼职教授，一直关心、支持着统计学的学科建设和应用统计的发展。中国人民大学应用统计科学研究中心2000年已成为国家级研究基地，这些专家是首批专职或兼职研究人员。这一开放性研究基地的运作，将有利于提升我国应用统计科学的研究水平，也必将进一步促进高等统计教育的发展。

这套教材是我们奉献给新世纪的，希望它能够为促进应用统计教育水平的提高增添一份力量。这套教材力求体现以下特点：

第一，在教材选择上，主要面向经济类统计学专业。选材既包括统计教材也包括风险管理与精算方面的教材。尽管名为统计学系列教材，但并不求大、求全，而是力求精选。对于目前已有的内容较为成熟、适合教学需要、公认的较好的教材，并未列入本次出版计划。

第二，每部教材的内容和写作，注意广泛吸收国内外优秀教材的成果。教材力求简明



易懂、内容系统和实用，注重对统计方法思想的阐述，并结合大量实际数据和实例说明统计方法的特点及应用条件。

第三，强调与计算机的结合。为着力提高学生运用统计方法分析解决问题的能力，教材所涉及的统计计算，要求运用目前已有的统计软件。根据教材内容，选择使用 SAS, SPSS, TSP, STATISTICA, EViews, MINITAB, Excel 等。

感谢中国人民大学出版社的同志们，他们怀着发展我国应用统计科学的热情和提高统计教育水平的愿望，经过反复论证，使这套教材得以出版。感谢参与教材编写的同行专家、统计学系的教师。愿大家的辛勤劳动能够结出丰硕的果实。我们期待着与统计学界的同仁，共同创造应用统计辉煌的明天。

易丹辉



前 言

本书是根据多年的教学经验与实践，结合统计学专业的特点，针对社会经济、自然科学和管理科学等领域中常见的回归分析问题，对传统的线性回归分析方法进行了系统的整理和归纳，并在此基础上，结合现代统计学的新进展，提出了许多新的方法。本书在编写过程中充分考虑了读者的需要，力求做到深入浅出，通俗易懂，便于自学。同时，书中还提供了大量的例题和习题，以便读者能够更好地掌握和应用所学的知识。

回归分析是统计学中一个非常重要的分支，在自然科学、管理科学和社会经济等领域有着非常广泛的应用。本书是针对统计学专业和财经管理类专业教学的需要而编写的。

本书写作的指导思想是在不失严谨的前提下，明显不同于纯数理类教材，努力突出实际案例的应用和统计思想的渗透，结合统计软件全面系统地介绍回归分析的实用方法，尽量结合中国社会经济、自然科学等领域的研究实例，把回归分析的方法与实际应用结合起来，注意定性分析与定量分析的紧密结合，努力把同行以及我们在实践中应用回归分析的经验和体会融入其中。

本书 2001 年出版以来，得到了读者的广泛认可，第四版是继续作为普通高等教育“十一五”国家级规划教材出版的。在这期间，SPSS 社会科学统计软件包 (Statistical Package for the Social Science) 已经从 13.0 版本提高到 22.0 版本，使我们可以在第四版中为读者提供更多的实用方法。本书的案例主要运用目前国内最流行的统计软件 SPSS 22.0 完成，部分内容用 Excel 和 SAS 软件完成，所讲述的方法都结合实例介绍软件的实施过程。几乎每章后面给出本章小结与评注和思考与练习题。

全书共分 10 章。第 1 章对回归分析的研究内容和建模过程给出综述性介绍；第 2 章和第 3 章详细介绍了一元和多元线性回归的参数估计、显著性检验及其应用；第 4 章对违背回归模型基本假设的异方差、自相关和异常值等问题给出了诊断和处理方法，在这一章增加了 BOX-COX 变换；第 5 章介绍了回归变量选择与逐步回归方法；第 6 章就多重共线性的产生背景、诊断方法、处理方法等方面结合实际经济问题给予讨论；第 7 章岭回归估计是解决共线性问题的一种非常实用的方法；第 8 章介绍了主成分回归与偏最小二乘；第 9 章介绍了可化为线性回归的曲线回归、多项式回归，以及不能线性化的非线性回归模型的计算；第 10 章分别介绍了自变量中含定性变量和因变量是定性变量的回归问题，以及因变量是多类别和有序变量的回归问题。

本书作为回归分析的应用教材，重点是结合 SPSS 软件使用回归分析中的各种方法，比较各种方法的适用条件，并正确解释分析结果。为了保持教材的完整性，对一些基本的

公式和定理给出了推导和证明，对一些基本的理论性质也做了必要的说明。对统计学专业的本科生可以全面系统地讲述教材的内容；对非统计学专业的本科生应该舍弃其中理论性质的内容；对非统计学专业的研究生可以根据具体情况选择讲授其中的内容。根据我们的教学实践，本书讲授 54 课时较为合适，若有计算机和投影设备的配合，教学将会更为方便和有效。

在本书的写作过程中得到了中国人民大学 21 世纪统计学系列教材编审委员会和中国人民大学出版社的支持。编写大纲经过教材编写委员会的认真讨论，教材第一版得到 **张尧庭**、**吴喜之**两位教授的认真审阅，他们提出了不少中肯的意见。我们的博士生胡小宁，硕士研究生赵云静、唐菁穗为第四版的编写作了大量上机计算。本书的大部分案例是我们多年教学和科研工作的积累，部分案例为体现其典型性引用他人著作。在此谨向对本书出版提供帮助的师长和朋友表示衷心的感谢。

本书的完成是我们两位作者多年友好合作的结果，我们期望它的出版能为回归分析在中国的应用做出积极的贡献。由于水平所限，书中难免有不足之处，尤其是在一些应用研究的体会性讨论中，恐有偏颇之处，恳切希望读者批评指正。

何晓群 刘文卿

2015 年 3 月

于中国农业大学明德楼

目 录

第1章 回归分析概述	1
1.1 变量间的统计关系	1
1.2 回归方程与回归名称的由来	4
1.3 回归分析的主要内容及其一般模型	5
1.4 建立实际问题回归模型的过程	8
1.5 回归分析应用与发展述评	13
思考与练习	15
第2章 一元线性回归	16
2.1 一元线性回归模型	16
2.2 参数 β_0 , β_1 的估计	21
2.3 最小二乘估计的性质	26
2.4 回归方程的显著性检验	28
2.5 残差分析	39
2.6 回归系数的区间估计	42
2.7 预测和控制	43
2.8 本章小结与评注	47
思考与练习	53
第3章 多元线性回归	57
3.1 多元线性回归模型	57
3.2 回归参数的估计	61
3.3 参数估计量的性质	67
3.4 回归方程的显著性检验	70
3.5 中心化和标准化	75
3.6 相关阵与偏相关系数	78



3.7 本章小结与评注	82
思考与练习	88
第4章 违背基本假设的情况	91
4.1 异方差性产生的背景和原因	91
4.2 一元加权最小二乘估计	93
4.3 多元加权最小二乘估计	102
4.4 自相关性问题及其处理	104
4.5 BOX-COX 变换	116
4.6 异常值与强影响点	122
4.7 本章小结与评注	126
思考与练习	129
第5章 自变量选择与逐步回归	132
5.1 自变量选择对估计和预测的影响	132
5.2 所有子集回归	134
5.3 逐步回归	143
5.4 本章小结与评注	152
思考与练习	157
第6章 多重共线性的情形及其处理	160
6.1 多重共线性产生的背景和原因	160
6.2 多重共线性对回归模型的影响	161
6.3 多重共线性的诊断	164
6.4 消除多重共线性的方法	168
6.5 本章小结与评注	170
思考与练习	172
第7章 岭回归	173
7.1 岭回归估计的定义	173
7.2 岭回归估计的性质	175
7.3 岭迹分析	176
7.4 岭参数 k 的选择	178
7.5 用岭回归选择变量	179
7.6 本章小结与评注	186
思考与练习	187
第8章 主成分回归与偏最小二乘	190
8.1 主成分回归	190
8.2 偏最小二乘	196
8.3 本章小结与评注	203
思考与练习	205



第 9 章 非线性回归	206
9.1 可化为线性回归的曲线回归	206
9.2 多项式回归	213
9.3 非线性模型	219
9.4 本章小结与评注	232
思考与练习	234
第 10 章 含定性变量的回归模型	237
10.1 自变量含定性变量的回归模型	237
10.2 自变量含定性变量的回归模型的应用	240
10.3 因变量是定性变量的回归模型	245
10.4 Logistic 回归模型	247
10.5 多类别 Logistic 回归	254
10.6 因变量顺序数据的回归	259
10.7 本章小结与评注	261
思考与练习	263
部分练习题参考答案	269
附 录	279
表 1 简单相关系数临界值表	279
表 2 t 分布表	280
表 3 F 分布表	281
表 4 DW 检验上下界表	287
参考文献	289



C 第1章

Chapter 1 回归分析概述

为了在系统学习回归分析之前对该课程的思想方法、主要内容、发展现状等有个概括的了解，本章将由变量间的统计关系引申出社会经济与自然科学等现象中的相关与回归问题，并扼要介绍“回归”名称的由来及近代回归分析的发展、回归分析研究的主要内容，以及建立回归模型的步骤与建模过程中应注意的问题。

1.1 变量间的统计关系

社会经济与自然科学等现象之间的相互联系和制约是一个普遍规律。例如社会经济的发展总是与一定的经济变量的数量变化紧密联系的。社会经济现象不仅同和它有关的现象构成一个普遍联系的整体，而且在它的内部存在着许多彼此关联的因素，在一定的社会环境、地理条件、政府决策影响下，一些因素推动或制约另外一些与之联系的因素发生变化。这种状况表明，在经济现象的内部和外部联系中存在着一定的相关性，人们往往利用这种相关关系来制定有关的经济政策，以指导、控制社会经济活动的发展。要认识和掌握客观经济规律就必须探求经济现象间经济变量的变化规律，变量间的统计关系是经济变量变化规律的重要特征。

互有联系的经济现象及经济变量间关系的紧密程度各不一样。一种极端的情况是一个变量的变化能完全决定另一个变量的变化。例如，一家保险公司承保汽车 5 万辆，每辆保费收入为 1 000 元，则该保险公司汽车承保总收入为 5 000 万元。如果把承保总收入记为 y ，承保汽车辆数记为 x ，则 $y=1000x$ 。 x 与 y 两个变量间完全表现为一种确定性关系，即函数关系，如图 1—1 所示。

又如，银行的一年期存款利率为 2.55%，存入的本金用 x 表示，到期的本息用 y 表示，则 $y=x+2.55\%x$ 。这里 y 与 x 仍表现为一种线性函数关系。对于任意两个变量间的函数关系，可以表述为下面的数学形式

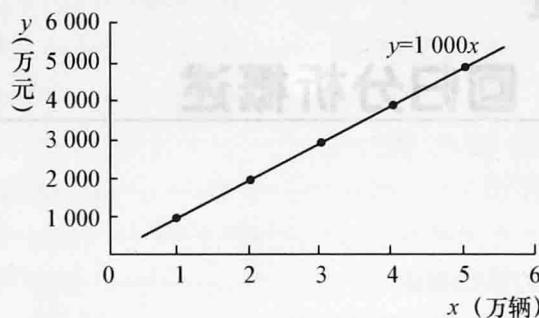


图 1—1 函数关系图

$$y=f(x)$$

再如，工业企业的原材料消耗总额用 y 表示，生产量用 x_1 表示，单位产量消耗用 x_2 表示，原材料价格用 x_3 表示，则

$$y=x_1x_2x_3$$

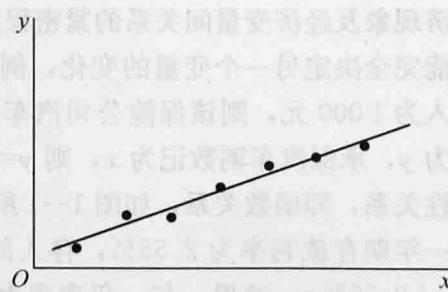
这里的 y 与 x_1 , x_2 , x_3 仍是一种确定性的函数关系，但它们显然不是线性函数关系。我们可以将变量 y 与 p 个变量 x_1 , x_2 , ..., x_p 之间存在的某种函数关系用下面的形式表示

$$y=f(x_1, x_2, \dots, x_p)$$

经济问题中还有很多函数关系的例子。物理学中的自由落体距离公式、初等数学中的许多计算公式等表示的都是变量间的函数关系。

然而，现实世界中还有不少情况是两事物之间有着密切的联系，但它们密切的程度并没有到由一个可以完全确定另一个。下面举几个例子。

(1) 我们都知道某种高档消费品的销售量与城镇居民的收入密切相关，居民收入高，这种消费品的销售量就大。但是由居民收入 x 并不能完全确定某种高档消费品的销售量 y ，因为这种高档消费品的销售量还受人们的消费习惯、心理因素、其他商品的吸引程度及价格的高低等诸多因素的影响。这样变量 y 与变量 x 就是一种非确定性的关系，如图 1—2 所示。

图 1—2 y 与 x 非确定性关系图

(2) 粮食产量 y 与施肥量 x 之间有密切的关系，在一定的范围内，施肥量越多，粮食产量就越高。但是，施肥量并不能完全确定粮食产量，因为粮食产量还与其他因素有关，如降雨量、田间管理水平等。因此粮食产量 y 与施肥量 x 之间不存在确定的函数关系。

(3) 储蓄额与居民的收入密切相关，但是由居民收入并不能完全确定储蓄额。因为影响储蓄额的因素很多，如通货膨胀、股票价格指数、利率、消费观念、投资意识等。因此尽管储蓄额与居民收入有密切的关系，但它们之间并不存在一种确定性关系。

再如广告费支出与商品销售额、保险利润与保费收入、工业产值与用电量等。这方面的例子不胜枚举。

以上变量间关系的一个共同特征是尽管密切，但却是一种非确定性关系。由于经济问题的复杂性，有许多因素因为我们的认识以及其他客观原因的局限，并没有包含在内，或者由于试验误差、测量误差以及其他种种偶然因素的影响，使得另外一个或一些变量的取值带有一定的随机性。因此当一个或一些变量取定值后，不能以确定值与之对应。

从图 1—1 看到确定性的函数关系，各对应点完全落在一条直线上。而由图 1—2 看到，各对应点并不完全落在一条直线上，即有的点在直线上，有的点在直线的两侧。这种对应点不能分布在一条直线上的变量间的关系，也就是变量 x 与 y 之间有一定的关系，但是又没有密切到可以通过 x 唯一确定 y 的程度，这种关系正是统计学中研究的重要内容。在推断统计中，我们把上述变量间具有密切关联而又不能由某一个或某一些变量唯一确定另外一个变量的关系称为变量间的统计关系或相关关系。这种统计关系的规律性是统计学中研究的主要对象，现代统计学中关于统计关系的研究已形成两个重要的分支，它们叫回归分析和相关分析。

回归分析和相关分析都是研究变量间关系的统计学课题。在应用中，两种分析方法经常相互结合和渗透，但它们研究的侧重点和应用面不同。它们的差别主要有以下几点：一是在回归分析中，变量 y 称为因变量，处在被解释的特殊地位。在相关分析中，变量 y 与变量 x 处于平等的地位，即研究变量 y 与变量 x 的密切程度与研究变量 x 与变量 y 的密切程度是一回事。二是相关分析中所涉及的变量 y 与 x 全是随机变量。而回归分析中，因变量 y 是随机变量，自变量 x 可以是随机变量，也可以是非随机的确定变量。通常的回归模型中，我们总是假定 x 是非随机的确定变量。三是相关分析的研究主要是为刻画两类变量间线性相关的密切程度。而回归分析不仅可以揭示变量 x 对变量 y 的影响大小，还可以由回归方程进行预测和控制。

由于回归分析与相关分析研究的侧重点不同，它们的研究方法也大不相同。回归分析已成为现代统计学中应用最广泛、研究最活跃的一个独立分支。

1.2 回归方程与回归名称的由来

回归分析是处理变量 x 与 y 之间的关系的一种统计方法和技术。这里所研究的变量之间的关系就是上述的统计关系，即当给定 x 的值， y 的值不能确定，只能通过一定的概率分布来描述。于是，我们称给定 x 时 y 的条件数学期望

$$f(x) = E(y|x) \quad (1.1)$$

为随机变量 y 对 x 的回归函数，或称为随机变量 y 对 x 的均值回归函数。式 (1.1) 从平均意义上刻画了变量 x 与 y 之间的统计规律。

在实际问题中，我们把 x 称为自变量， y 称为因变量。如果要由 x 预测 y ，就是要利用 x , y 的观察值，即样本观测值

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) \quad (1.2)$$

来建立一个函数，当给定 x 值后，代入此函数中算出一个 y 值，这个值就称为 y 的预测值。如何建立这个函数？这就要从样本观测值 (x_i, y_i) 出发，观察 (x_i, y_i) 在平面直角坐标系上的分布情况，图 1—2 就是居民收入与商品销售量的散点图。由这个图可看出样本点基本上分布在一条直线的周围，因而要确定商品销售量 y 与居民收入 x 的关系，可考虑用一个线性函数来描述。图 1—2 中的直线即线性方程

$$E(y|x) = \alpha + \beta x \quad (1.3)$$

方程式 (1.3) 中的参数 α , β 尚不知道，这就需要由样本数据式 (1.2) 去进行估计。具体如何估计参数 α , β ，我们在第 2 章中将详细介绍。

当我们由样本数据式 (1.2) 估计出 α , β 的值后，以估计值 $\hat{\alpha}$, $\hat{\beta}$ 分别代替式 (1.3) 中的 α , β ，得方程

$$\hat{y} = \hat{\alpha} + \hat{\beta} x \quad (1.4)$$

方程式 (1.4) 就称为回归方程。这里因为因变量 y 与自变量 x 呈线性关系，故称式 (1.4) 为 y 对 x 的线性回归方程。又因式 (1.4) 的建立依赖于观察或试验积累的数据式 (1.2)，所以又称式 (1.4) 为经验回归方程。相对这种叫法，我们把式 (1.3) 称为理论回归方程。理论回归方程是设想把所研究问题的总体中每一个体的 (x, y) 值都测量了，利用其全部结果而建立的回归方程，这在实际中是做不到的。理论回归方程中的 α 是方程式 (1.3) 所画出的直线在 y 轴上的截距， β 为直线的斜率，它们分别称为回归常数和回归系数。而方程式 (1.4) 中的参数 $\hat{\alpha}$, $\hat{\beta}$ 称为经验回归常数和经验回归系数。

回归分析的基本思想和方法以及“回归”(regression)名称的由来归功于英国统计学家 F. 高尔顿 (F. Galton, 1822—1911)。高尔顿和他的学生、现代统计学的

奠基者之一 K. 皮尔逊 (K. Pearson, 1856—1936) 在研究父母身高与其子女身高的遗传问题时, 观察了 1 078 对夫妇, 以每对夫妇的平均身高作为 x , 而取他们的一个成年儿子的身高作为 y , 将结果在平面直角坐标系上绘成散点图, 发现趋势近乎一条直线。计算出的回归直线方程为:

$$\hat{y} = 33.73 + 0.516x \quad (1.5)$$

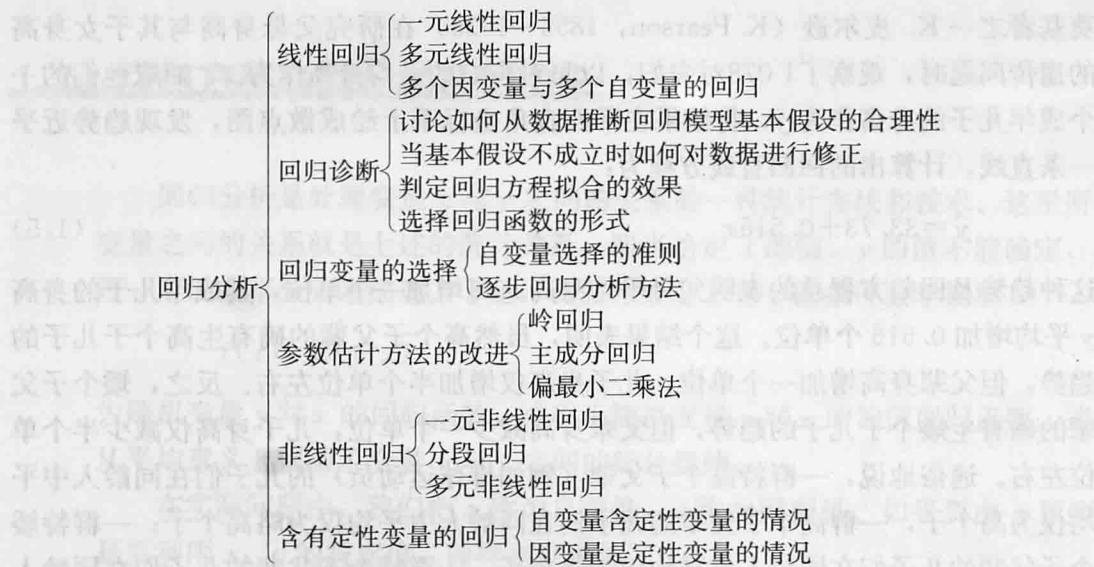
这种趋势及回归方程总的表明父母平均身高 x 每增加一个单位, 其成年儿子的身高 y 平均增加 0.516 个单位。这个结果表明, 虽然高个子父辈的确有生高个子儿子的趋势, 但父辈身高增加一个单位, 儿子身高仅增加半个单位左右。反之, 矮个子父辈的确有生矮个子儿子的趋势, 但父辈身高减少一个单位, 儿子身高仅减少半个单位左右。通俗地说, 一群特高个子父辈 (例如排球运动员) 的儿子们在同龄人中平均仅为高个子, 一群高个子父辈的儿子们在同龄人中平均仅为略高个子; 一群特矮个子父辈的儿子们在同龄人中平均仅为矮个子, 一群矮个子父辈的儿子们在同龄人中平均仅为略矮个子, 即子代的平均高度向中心回归了。正是因为子代的身高有回到同龄人平均身高的这种趋势, 才使人类的身高在一定时间内相对稳定, 没有出现父辈个子高其子女更高, 父辈个子矮其子女更矮的两极分化现象。这个例子生动地说明了生物学中“种”的概念的稳定性。正是为了描述这种有趣的现象, 高尔顿引进了“回归”这个名词来描述父辈身高 x 与子辈身高 y 的关系。尽管“回归”这个名称的由来具有其特定的含义, 而人们在研究大量的问题中, 其变量 x 与 y 之间的关系并不总是具有这种“回归”的含义, 但仍借用这个名词把研究变量 x 与 y 间统计关系的量化方法称为“回归”分析, 也算是对高尔顿这位伟大的统计学家的纪念。

1.3 回归分析的主要内容及其一般模型

一、回归分析研究的主要内容

回归分析研究的主要对象是客观事物变量间的统计关系, 它是建立在对客观事物进行大量试验和观察的基础上, 用来寻找隐藏在那些看上去是不确定的现象中的统计规律性的统计方法。回归分析方法是通过建立统计模型研究变量间相互关系的密切程度、结构状态及进行模型预测的一种有效的工具。

回归分析方法在生产实践中的广泛应用是其发展和完善的根本动力。如果从 19 世纪初 (1809 年) 高斯 (Gauss) 提出最小二乘法算起, 回归分析的历史已有 200 多年。从经典的回归分析方法到近代的回归分析方法, 它们所研究的内容已非常丰富。如果按研究的方法来划分, 回归分析研究的范围大致如下:



二、回归模型的一般形式

如果变量 x_1, x_2, \dots, x_p 与随机变量 y 之间存在着相关关系，通常就意味着每当 x_1, x_2, \dots, x_p 取定值后， y 便有相应的概率分布与之对应。随机变量 y 与相关变量 x_1, x_2, \dots, x_p 之间的概率模型为：

$$y = f(x_1, x_2, \dots, x_p) + \epsilon \quad (1.6)$$

式中，随机变量 y 称为被解释变量（因变量）； x_1, x_2, \dots, x_p 称为解释变量（自变量）。在计量经济学中，也称因变量为内生变量，自变量为外生变量。 $f(x_1, x_2, \dots, x_p)$ 为一般变量 x_1, x_2, \dots, x_p 的确定性关系； ϵ 为随机误差。正是因为随机误差项 ϵ 的引入，才将变量之间的关系描述为一个随机方程，使得我们可以借助随机数学方法研究 y 与 x_1, x_2, \dots, x_p 的关系。由于客观经济现象是错综复杂的，一种经济现象很难用有限个因素来准确说明，随机误差项可以概括表示由于人们的认识以及其他客观原因的局限而没有考虑的种种偶然因素。随机误差项主要包括下列因素的影响：

- (1) 由于人们认识的局限或时间、费用、数据质量等的制约未引入回归模型但又对回归被解释变量 y 有影响的因素。
- (2) 样本数据的采集过程中变量观测值的观测误差。
- (3) 理论模型设定的误差。
- (4) 其他随机因素。

模型式 (1.6) 清楚地表达了变量 x_1, x_2, \dots, x_p 与随机变量 y 的相关关系，它由两部分组成：一部分是确定性函数关系，由回归函数 $f(x_1, x_2, \dots, x_p)$ 给出；另一部分是随机误差项 ϵ 。由此可见模型式 (1.6) 准确地表达了相关关系既有联系又不确定的特点。

当概率模型式(1.6)中回归函数为线性函数时,即有

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_p x_p + \epsilon \quad (1.7)$$

式中, $\beta_0, \beta_1, \beta_2, \dots, \beta_p$ 为未知参数, 常称为回归系数。线性回归模型的“线性”是针对未知参数 $\beta_i (i=0, 1, 2, \dots, p)$ 而言的。回归解释变量的线性是非本质的,因为解释变量是非线性的时,常可以通过变量的替换把它转化成线性的。

如果 $(x_{i1}, x_{i2}, \dots, x_{ip}; y_i) (i=1, 2, \dots, n)$ 是式(1.7)中变量 $(x_1, x_2, \dots, x_p; y)$ 的一组观测值,则线性回归模型可表示为:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \epsilon_i, \quad i=1, 2, \dots, n \quad (1.8)$$

为了估计模型参数的需要,古典线性回归模型通常应满足以下几个基本假设。

(1) 解释变量 x_1, x_2, \dots, x_p 是非随机变量,观测值 $x_{i1}, x_{i2}, \dots, x_{ip}$ 是常数。

(2) 等方差及不相关的假定条件为:

$$\begin{cases} E(\epsilon_i) = 0, & i=1, 2, \dots, n \\ \text{cov}(\epsilon_i, \epsilon_j) = \begin{cases} \sigma^2, & i=j \\ 0, & i \neq j \end{cases} & i, j = 1, 2, \dots, n \end{cases}$$

这个条件称为高斯-马尔柯夫(Gauss-Markov)条件,简称G-M条件。在此条件下,便可以得到关于回归系数的最小二乘估计及误差项方差 σ^2 估计的一些重要性质,如回归系数的最小二乘估计是回归系数的最小方差线性无偏估计等。

(3) 正态分布的假定条件为:

$$\begin{cases} \epsilon_i \sim N(0, \sigma^2), & i=1, 2, \dots, n \\ \epsilon_1, \epsilon_2, \dots, \epsilon_n \text{ 相互独立} \end{cases}$$

在此条件下便可得到关于回归系数的最小二乘估计及 σ^2 估计的进一步结果,如它们分别是回归系数及 σ^2 的最小方差无偏估计等,并且可以进行回归的显著性检验及区间估计。

(4) 通常为了便于数学上的处理,还要求 $n > p$,即样本量的个数要多于解释变量的个数。

在整个回归分析中,线性回归的统计模型最为重要。一方面是因为线性回归的应用最广泛;另一方面是只有在回归模型为线性的假定下,才能得到比较深入和一般的结果;此外,有许多非线性的回归模型可以通过适当的变换转化为线性回归问题处理。因此,线性回归模型的理论和应用是本书研究的重点。

对线性回归模型通常要研究的问题有:

- (1) 如何根据样本 $(x_{i1}, x_{i2}, \dots, x_{ip}; y_i) (i=1, 2, \dots, n)$ 求出 $\beta_0, \beta_1, \beta_2, \dots, \beta_p$ 及方差 σ^2 的估计。
- (2) 对回归方程及回归系数的种种假设进行检验。
- (3) 如何根据回归方程进行预测和控制,以及如何进行实际问题的结构分析。