

李晓林 编著

精算学原理

JINGSUANXUE YUANLI

(第二卷)

风险 统计



经济科学出版社

精 算 学 原 理
(第二卷)

风 险 统 计

李晓林 编著

经济科学出版社

1999 年·北京

责任编辑:柳 敏
责任校对:徐领弟
版式设计:周国强
技术编辑:潘泽新 李长建

精算学原理 (第二卷) 风险统计

李晓林 编著

网址: www.esp.com.cn

电子邮件: esp@public2.east.net.cn

(版权所有 翻印必究)

社址:北京海淀区万泉河路 66 号 邮编:100086

出版部电话:62630591 发行部电话:62568485

经济科学出版社出版、发行 新华书店经销

北京新华印刷厂印刷

河北省三佳装订厂装订

850×1168 毫米 32 开 15.5 印张 380000 字

1999 年 11 月第一版 1999 年 11 月第一次印刷

印数:0001—3000 册

ISBN 7-5058-1793-0/F·1273 定价:26.00 元

(图书出现印装问题,本社负责调换)

目 录

第一章 数据的整理	1
第一节 数据的描述	1
第二节 数据分布位置的度量	9
第三节 数据分布密集与分散程度的度量	13
第四节 对称与偏斜度	19
第二章 随机变量及其分布和数字特征	22
第一节 随机事件与概率	22
第二节 随机变量的分布和数字特征	39
第三章 概率母函数和矩母函数	81
第一节 母函数	81
第二节 概率母函数	82
第三节 矩母函数	89
第四章 随机向量	99
第一节 二维随机向量的分布	100
第二节 随机向量的数字特征	106
第三节 n 维随机向量	112
第五章 卷积和随机变量的线性组合的分布	117
第一节 独立随机变量的和	117
第二节 独立随机变量的线性组合的分布	119
第六章 条件分布与条件期望	131
第一节 随机变量的条件分布	131
第二节 条件数学期望	137
第七章 大数定律和中心极限定理	146
第一节 切比雪夫不等式	146

第二节 中心极限定理	148
第三节 大数定律	152
第八章 抽样分布	155
第一节 统计量	155
第二节 抽样分布	159
第九章 参数估计	171
第一节 点估计	171
第二节 估计量的评选标准	177
第三节 区间估计	179
第四节 正态总体均值与方差的区间估计	184
第五节 $(0 \sim 1)$ 分布参数的区间估计	188
第六节 单侧置信区间	189
第十章 假设检验	192
第一节 假设检验	192
第二节 正态总体均值的假设检验	198
第三节 正态总体方差的假设检验	204
第四节 分布拟合检验	206
第十一章 一元线性回归	215
第一节 一元线性回归	215
第二节 a, b 的估计	218
第三节 σ^2 的估计	222
第十二章 风险模型	224
第一节 概述	224
第二节 集合风险模型	229
第三节 复合风险模型 $G(x)$ 的计算	250
第四节 个体风险模型	266
第五节 参数变动——不确定性	278
第十三章 破产分析理论	289
第一节 基本概念	289
第二节 泊松分布和复合泊松分布	294
第三节 调节系数和兰德伯格不等式	302

第四节	变化的参数值对有限和无限时间破产 概率的影响	311
第五节	再保险与破产	321
第十四章	贝叶斯统计推断	331
第一节	先验分布和后验分布	331
第二节	简单情况下后验分布的推导	334
第三节	误差函数	336
第四节	特殊情况下的贝叶斯估计	339
第十五章	置信度理论	347
第一节	基本思想	348
第二节	贝叶斯置信度	351
第三节	经验贝叶斯置信理论：模型 1	363
第四节	经验贝叶斯置信度理论：模型 2	383
第十六章	无赔款优待	398
第一节	背景介绍	398
第二节	无赔款优待法的定义	400
第三节	稳定状态分析	403
第四节	无赔款优待制对索赔倾向的影响	409
第十七章	递推三角形	415
第一节	背景	415
第二节	运用递推因子进行预测	418
第三节	针对通货膨胀的调整	431
附录 I	几种常见分布	443
附录 II	常用概率统计表	447
主要参考文献		483

第一章

数据的整理

在实际中，一个完整的统计调查一般包括以下几个步骤：

1. 收集数据
2. 数据的描述
3. 正式的统计推断
4. 结果报告

本章将从数据的描述开始，探讨数据的整理方法。

第一节 数据的描述

我们先来明确几个概念：

批数据 (batch data)，是一组相关的观察数据，例如：

当前世界各国的通货膨胀率；

我国各省的年度预算；

中央财经大学各班级的学生数。

样本数据 (sample data)，是一组从总体中抽出的，同时代表那个总体的数据，例如：

从某保险公司人身意外伤害险保单中抽出的 100 份保单，其保额组成的样本；

从某保险公司汽车险索赔案中抽出的 300 个案例组成的样本；

某养老金计划中 180 个被保险人的年龄组成的样本。

涉及到批数据的分析是为了按数据的重要特征为指标来进行分类整理。涉及到样本数据的分析,除了是为按数据的重要特征进行分类整理之外,还有一个重要的目的就是要作出关于样本总体的推断。本书的主要内容将与样本数据和推断有关。

数据涉及到有关变量的值,我们把变量分为如下几种类型:

(1) 数值性 (numerical) 数据:

① 离散型数据,产生于计数(如精算师的人数,索赔的件数);

② 连续型数据,产生于测量(如比率、数额、年龄)。

(2) 范畴性 (categorical) 数据:

① 属性数据,只有两个类型(如是与否,男与女,索赔与不索赔);

② 名义性数据,有好几种不规则的类型(如保单的类型,索赔的性质);

③ 序列性数据,有多种不同程度的类型(如调查表显示诸如大力支持,……,强烈反对)。

下面将通过例子来做说明,大部分例子涉及数值性数据。

一、频数分布和条形图

例 1.1 假设某保险公司的 80 份家庭储蓄保单组成的样本,其家庭中 16 岁以下儿童的人数如下:

2	1	3	1	1	4	5	2	2	1	4	5	4	2	2	0
3	2	2	2	2	2	2	1	2	3	3	1	1	4	3	2
1	3	0	3	0	0	3	2	3	2	2	2	2	3	4	3
3	1	6	2	2	1	3	0	2	3	1	7	4	0	0	5
2	2	4	3	1	3	3	2	0	3	2	2	2	5	2	2

试用简明的方式描述这些数据,并用恰当的图表表示出来。

解：这是一个典型的离散型变量，其可能值为 0, 1, 2, 3, ……。很明显，通过计算出 0, 1, 2 等的个数可以很好地描述这些数据的特征。通常，我们把这些数字的个数或者说出现的次数称为频数，把这种描述方式称为频数分布。本书中的频数用 m 来表示，即：

16 岁以下的儿童人数, x	样本中的家庭数, m
0	8
1	12
2	28
3	19
4	7
5	4
6	1
7	1
8 或 8 以上	0

显然，对于这些数据在其可能值上的分布，我们可以通过上述列表的方法得到清晰的认识。

条形图可能比表格表达的更为恰当，它能更好地表明数据的离散属性。如图1-1。

现在，对于这些数据是如何分布在其可能值上，我们已经有了一个清晰的视觉印象，从而有了该保险公司家庭储蓄保单中 16 岁以下儿童个数分布情况的概念。

二、群频数和直方图

群频数又称分组频数或组频数，我们通过实例来说明群频数和直方图的概念。实例中的数据是用最接近 100 元的方式分类的。现金额如用角或分的方式给出将是真正离散的，但在这里鉴于数额如此之大，我们可以认为它们是连续的。实际中，由于数




图 1-1

据都只能以特定的精确度近似测量，而没有数据能以无限小的精度测量，所以所有数据都是离散的。

例 1.2 保险公司家庭财产保单中某 100 件由于管道渗漏引起的索赔组成的样本，索赔金额如下（单位 100 元）：

243	306	271	396	287	399	466	269	295	330
425	324	228	113	226	176	320	230	404	487
127	74	523	164	366	343	330	436	141	388
293	464	200	392	265	403	372	259	426	262
221	355	324	374	347	261	278	113	135	291
176	342	443	239	302	483	231	292	373	346
293	236	223	371	287	400	314	468	337	308
359	352	273	267	277	184	286	214	351	270
330	238	248	419	330	319	440	427	314	414
291	299	265	318	415	372	238	323	411	494

试用简明的方式描述这些数据，并用恰当的图表表示出来。

解：如果考虑频数分布，可能值太多了，因此我们将它们分组，并计算每组中的件数。数值从 74 到 523，所以一个合理的分组是 50~99，100~149，150~199，…，500~549 等等，这将得到 10 组数据：

组别	频数
50~99	1
100~149	5
150~199	4
200~249	14
250~299	22
300~349	20
350~399	14
400~449	13
450~499	6
500~549	1

这就是有相同间距的群频数分布，我们称之为组容相同，由此可以对数据分布在各组上的情况有一个清晰的印象。

直方图的表达更恰当，它能更好地表明现金额的几乎所有连续属性。如图1-2：

我们已经对这些数据的分布情况有了清晰的印象，进而了解了公司此类业务的索赔额分布的概念。

在例 1.2 中我们把数据分成了 10 组，这是舍弃细枝末节和获得清晰的概括之间的妥协。如果分 5 组，会失去太多的细节，而分 20 组将不会有一个如此清晰的概括。

上述的群频数分布和直方图的组容相等。在某些情况下，在两端分一个或两个更宽的组可能会更方便。在这些情况下必须注明长方形的面积而不是高度与频数成比例。原因在于直觉上的比




图 1-2

较用的是面积。例如两个边长之比为 1:2 的正方形，它们的面积之比为 1:4，眼睛很自然地判断它们之比为 1:4。

三、枝叶图

当今常用的另一种直方图为枝叶图。它的视觉印象与直方图相似，但是没有丢失组中数据的变化细节。这里是例 1.2 中数据的枝叶图（图1-3）。

图中左边的枝单位是 100，右边的叶单位是 10。由此单位数据能被表达出来，虽然是以最接近 10 的数额近似表述出来。

构造一个枝叶图可以用于直方图相同的组容。上面的枝叶图中的枝我们称为半枝图，因为 100、200、300 等数据的两个半部分是分别描述的。如下面全枝图（图1-4）没有给出半枝图这样清晰的描述。




图1-3




图1-4

四、点图

对于更小的数据组我们用点图 (dotplot) 来描述。其做法是把数据沿着一条有刻度的直线用点或叉号表示出来。

五、其他描述方式

1. 相对频数，即发生的频数或群频数与观察的次数的比值。它给出了数额为某值或属于某组的数据所占的比例。

例如，例 1.1 中的儿童人数的相对频数分布为：

16 岁以下的儿童人数	相对频数
0	0.1
1	0.15
2	0.35
3	0.2375
4	0.0875

5	0.05
6	0.0125
7	0.0125

在第二章你将看到，这是一个等价于随机变量概率的数据，它将被看作是从数据中得到的经验概率。

2. 累积频数，即把数据小于和等于某值或某数据组的频数累加后的和（包括取其自身和比其更小值的频数或群频数）。

对分组的数据来说，我们很自然把累积频数与各组的上界联系起来。例如，例 1.2 中的索赔额分布，其累积频数为：

各组上限	累积频数
100	1
150	6
200	10
250	24
300	46
350	66
400	80
450	93
500	99
550	100

累积频数也能用图形表示出来。

我们也可以用相对形式来研究累积频数，在第二章将会看到数据的相对累积频数分布相似于随机变量的分布函数。

还有其他描述数据的方式，如饼分图、象形图等等，本书不一一叙说了。但是必须指出的是，一种图示中的误导倾向：一种特定的图能引起误导。我们可能在传媒上看过这样的图片，如瓶的图形被用来表示不同时期某种酒的销量并进行比较，视觉上的比较是由其体积引起的，但是这类图片往往错误地用高度来代表频数。这与前面讲的正方形面积与长度的问题是类似的。

六、精确度

在描述数据时，我们不得不始终考虑它的精确度。例如，在例 1.2 的索赔额中，用角和分来记录数据是没有价值的。如果不考虑其他因素，知道索赔额是 796.33 元，总比仅仅知道是 796 元好。

读者可能对“4 位小数”或“3 位有效数字”的概念已经非常熟悉。在风险统计中，我们更需要“重要数字”的概念。

例如，一个数集可能牵涉到计算的比率问题，该数集由以下数据组成：

1.0581 1.0366 1.0120 1.0404 1.0321
1.0156 1.0632 1.0026 1.0589 1.0333

由于所有数据都以 1.0…开头，出于比较的目的，主要考察第三和第四两位数字。实际上，把它们表示成超过 1 的百分数更好比较。于是，我们往往考察下列数据：

5.8 3.7 1.2 4.0 3.2 1.6 6.3 0.2 5.9 3.3

在另一个有如下数据的例子里：

33 232 元 7 677 元 65 652 元 86 675 元 98 329 元
40 020 元 65 526 元 4 484 元 85 113 元 52 886 元
用 1 000 元为单位进行比较会更清晰，即考察数据：

33 8 66 87 98 40 66 4 85 53

在报告中表达数据时，应避免过于精确，数字越简单，读者越容易理解和享用从数据中得到的信息。在实际中，一般用 2 或 3 个重要数字足够了。

第二节 数据分布位置的度量

通常，人们对数据分布情况关心的主要是数据分布的位置、密集或分散程度、偏斜情况等等。本节将探讨数据分布位置情况的各种度量。例如，看到例 1.2 的直方图，我们能发现索赔额集

中在 300 元附近。第三节、第四节将探讨数据分布的密集或分散程度、偏斜情况。

一、均值

描述数据分布的最普通的度量是均值 (mean)。严格来说应叫作算术平均值, 因为还有其他“均值”, 如调和均值和几何均值。但通常, 我们还是把它简单地称为均值。

对一个有 n 个数据的数列,

$$x_1, x_2, \dots, x_n$$

或

$$x_i, i = 1, 2, \dots, n$$

其均值是

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

读作“ x -bar (巴)”。

实际上均值与大多数人常常称用的平均数是相同的概念。

对一个有可能值 $x_1, x_2, \dots, x_k$ 的频数分布, 其对应频数为 $m_1, m_2, \dots, m_k$, 其中 $\sum m_i = n$, 其均值为

$$\bar{x} = \frac{1}{n} \sum_{i=1}^K m_i x_i$$

对一个群频数分布来说, 其均值计算如上, 不过这里的数值是各组的中点 (中间值)。^①

例 1.3 计算例 1.1 中的均值。

$$\text{解: } \bar{x} = \frac{1}{80} \sum m_i x_i = \frac{186}{80} = 2.325$$

由于三位小数太多了, 我们取 $\bar{x} = 2.3$ 。

① 在一般的统计著作中把它定义为样本均值, 而且把它当作总体均值的估计值。如果这些是样本数据, 则这是很明显的。如果这些是批数据, 那么将没有相应的总体均值。然而, 由于大部分是样本数据, 本书将一般地将其称为样本均值。

例 1.4 以全部的数据和分组数据两种形式计算例 1.2 的均值。

解：用全部的数据计算：

$$\bar{x} = \frac{1}{100} \sum x_i = \frac{31\,353}{100} = 313.53$$

我们取 $\bar{x} = 313.5$ 。

用分组数据计算：我们取各组中间值 75 125,

$$\bar{x} = \frac{1}{100} \sum m_i x_i = \frac{31\,750}{100} = 317.5$$

严格来说，组中值应是 74.5, 124.5..., 得出均值为 312.0, 但注意到分组的误差，简单的选择是足够的。

由于分组的误差为 $313.53 - 312.0 = 1.53$ ，其相对误差为 0.5%。这个误差是由于分成群频数分布时丢失的细节造成的。

注意：上例中涉及了“过于精确”的概念。考虑到由于分组的误差或丢失的细节，用更高的精确度没有什么意义。

一般地，我们取比原始数据多一位小数作为均值。如果是一个较大的数列，我们可以考虑再多取二位小数，但一定不要多于此。

二、中位数

另一个有用的度量是中位数 (median)。把 n 个数据按大小排列，中位数是把这个数列分成两半的那个数，一半小于它，一半大于它，如果 n 是奇数，中位数就是中间的那个，如果 n 是偶数，中位数则是中间两数的中点（或平均值），可以表示成是第 $(n+1)/2$ 个数。^①

中位数与均值是两个不同的概念。例如，有 5 个观测值：

1.1 1.5 1.6 1.8 2.2

均值为 1.64，中位数是 1.6，相当接近。然而，对于另外 5

① 没有一个标准的符号表示中位数，一些书用 M ，另一些书用 $\bar{x}$ 。