

P163  
1648

高等数学第二部分

# 数 理 统 计

高等数学教研组编

西安交通大学

1962.4

绪 论 .....	1
<b>第一章 基本概念</b> .....	3
§ 1. 总体, 个体, 样本·数理统计的目的与方法 .....	3
§ 2. 数据分布——频数分布与频率分布 .....	5
§ 3. 数据频率分布的数字特征 .....	11
§ 4. 随机抽样 .....	17
§ 5. 用大样本估计总体的平均数, 均方差, 频率分布 .....	20
<b>第二章 大样本参数估计和统计假设检验</b> .....	22
§ 1. 无偏估计量 .....	22
§ 2. 大样本对于总体平均数和均方差的区间估计 .....	24
§ 3. 检验一个大样本是否来自平均数已知的总体 .....	29
§ 4. 两个样本是否来自平均数相同的两总体的检验 .....	31
附表 I 正态分布数值表 .....	34
习题 .....	35
<b>第三章 小样本参数区间估计和统计假设检验</b> .....	39
§ 1. 正态总体平均数的区间估计 .....	37
§ 2. 检验小样本是否来自平均数为已知的正态总体 .....	40
§ 3. 检验两个样本是否来自平均数相同的两个正态总体 .....	41
§ 4. 检验两个样本是否来自均方差相同的两个正态总体 .....	43
§ 5. 检验样本是否来自已知的正态总体 .....	48
习题 .....	51
附表 I $\chi^2$ 分布的临界限值 .....	55
附表 II $t$ 分布的临界限值 .....	57
附表 III $F$ 分布的临界限值 .....	58

第四章 生产过程中产品的质量控制的.....	59
§ 1. 計量控制.....	59
§ 2. 計件控制.....	66
第五章 方差分析.....	70
§ 1. 一元方差分析.....	70
§ 2. 二元方差分析.....	76
习题.....	79
第六章 相关分析.....	82
§ 1. 引言.....	82
§ 2. 直綫相关簡述.....	83
§ 3. 曲綫相关.....	85
§ 4. 多元綫性相关.....	88
习题.....	96

# 数 理 统 计

## 绪 论

数理统计学和概率论一样是研究大量现象在数量上的规律性的科学，但是它却使用着不同的方法。较明确地说：数理统计是从实际资料出发来研究大量现象的规律性。

显然，如果我们进行了大量的观察，那就能看出这些大量现象所呈现的规律性，但是客观上又只允许我们对大量现象进行局部的观测。从表面看来这是矛盾的，然而我们只要能充分利用观察资料和局部与整体之间的内在联系来进行分析与推断，仍然能够认识这些规律性。因为这种从局部观测去推断整体的方法有着普遍的意义，因而数理统计的应用非常广泛。

数理统计方法在工业生产及科学研究中有着广泛的应用。下面举几个例子来说明数理统计所能解决的某些问题。

1. 在现代大批生产的情况下，特别是工业自动化发展，使产量不断提高。在这种情况下如何检查生产出来的大量产品的质量成为严重问题。比如说一台自动机床日产1500个零件，出于对工作和经济的考虑，我们不能把零件每一个都进行检查，而是从中抽取一部分出来进行检查，从而断定一天产品的质量情况。尤其是有很多试验具有破坏性的，不允许我们对产品进行全面检查。比如说检查电灯泡的能点时数，要把电灯泡一直点到不亮为止。要检查炮弹的射程必需发射一下，那末炮弹就炸掉了。诸如此类的例子在工业生产中很多。此外，还要由抽查的一部分产品质量情况，应决定整批产品合格与否，这就是产品验收问题。

2. 上面讲的产品质量检查与产品验收是在一批产品已经生产出来，然后进行质量检查，决定产品合格与否。这还是消极的。积极的方法是在生产过程中随时地进行一些检查，来判断生产的进行是否正常，亦就是说生产出来的产品是否合于规格要求。这可启示我们随时调整机器使生产经常保持正常状态，这是所谓生产中的质量控制问题。

3. 在生产中常要作这样的试验：比较运用好几种原料（或者不同方法）生产出来的产品质量是否相同，进而判断那些原料（或生产方法）生产出来的产品质量较高。这时我们只能用各种原料（或各种生产方法）做

不多几次試驗，从試驗資料来作出决定。在科学研究中，常要在各种不同条件下做不多几次試驗，从試驗資料判断由于条件的不同对于試驗結果是否有显著影响。若不同，进而可以断定在怎样的条件下試驗得到的結果最好。这是所謂試驗分析問題。

4. 在生产中常需要找出所用原料与生产出来产品的質量之間的关系。在科学研究中要寻找各种因素与試驗結果之間的关系。比如說，在紡織厂中要找出原棉的物理性能（有纖維強力，纖維支數等）与成紗的質量之間的关系，以便如何合理地利用原料紡出高質量的紗。

在上面一些例子中都是从做一些試驗或作一些观察得到的一些数据来判断总的情况。这正是数理統計的任务，亦是数理統計所用的方法。

在数理統計中要解决二个問題：1. 如何来設置观察或試驗。2. 如何通过观察或試驗得到的数据进行分析，科学地判断总的情况，更具体地說揭示大量現象中事物的本質（如1、2、3）及存在于一些事物之間本質的联系（如4）。总之，数理統計是通过对某些观察或試驗結果的分析来揭示存在大量現象中事物本質和事物間的本質联系的科学。

数理統計是一門数学，它与各門具体学科有着密切联系。把它的方法与原理运用去研究各門科学，得到各种密切联系这門学科实际的数理統計学。如：工业应用数理統計，紡織工业数理統計，水文学中数理統計，統計物理、測量誤差理論等等。数理統計这門数学的理論与方法由于生产实践和自然科学研究的刺激得到不断发展，反过来利用新的数理統計的方法能更广泛地去解决生产实践和自然科学研究中提出的一些問題。

在运用数理統計方法时，首先要从观察与試驗得到的数据具有高度正确性，对这样資料进行統計分析得到的結論才有效。再則統計分析所得結論是否正确，还要在实践中进行檢查。

数理統計与概率論有什么联系呢？可以这样說，数理統計是以概率論作为工具的。更明确地說，在讲解統計原理与导出統計方法时要用到概率論中的一些概念（如：概率，随机变数等）和一些結論（如：大数定律，中心极限定理）。

在本讲义中将介紹一般的統計原理和方法，至于有些断言和式子的导出相当复杂，本讲义只列出結論而不作推导。我們热忱期望工业高等学校学生在掌握了数理統計原理与方法之后能够运用去解决生产和科学研究中所提出的实际問題。

# 第一章 基本概念

在开始这一章中我们将介绍数理统计中的一些术语，讨论概率论中的一些概念（如：随机变数，分布函数，分布密度）与数理统计的概念如何结合起来，并运用概率论理论去解决统计中提出的某些最基本的問題。

## §1. 总体，个体，样本。数理统计的目的和方法

所欲研究对象的全体称为总体（或母体），这些研究对象具有通性，总体中包含的基本元素称为个体。

例 1. 检查某天一机床出的产品的质量，那末这天这机床所产生出产品构成一个总体；而每一个产品是一个个体。总体中元素的通性是同一天同一机器同一工人生产出来的。

例 2. 检查一包棉花纤维的强力与支数，这包棉花所有的棉纤维就构成总体，而每根棉纤维是一个个体。总体中元素的通性是同一包棉花中的纤维。

但是通常总体中的个体是指物体某种性质数量特征，并非指物体本身。比如說在例 1 中生产出的是圆柱形零件，那末所有零件的直径构成一总体，所有零件的长度亦构成一总体，所有零件数重量亦构成一总体（如果需要考虑重量的話）。在例 2 中所有纤维的强力构成一总体，所有纤维的长度亦构成一总体。也有些物体的性质不可度量，这时可以任意給物体的性质一种数量标志。如：若考察一批产品的质量，每一个产品仅有废品和正品之分，我們可以假设（完全是人为的）废品是“1”，正品是“0”。这批产品质量的总体可以看成由很多个“1”和“0”組成。

总体中所含个体的个数，称为总体容量，用  $N$  表示。总体容量可大可小。比如說我們考察一机器某天生产出 50 个产品的长度，那末总体容量是 50。又如一大包棉花中所包含纤维达 5000 亿根以上，这时纤维强度构成的总体的容量可以看成是无限大。而无限大总体亦是存在的，比如說一条河流的年流量，从它形成的一天起每年都有，这河流所有年流量构成的总体在理論上可以认为是无限的。在数理统计中不妨把容量相当大的总体看成是容量为无限的总体。这样对我們在数学上討論很有好处，在下面 § 4 中将加以說明。

个体既是指物体的某种性质的数量特征，在数学上只是考虑这一性质

的变量，今后一个个体用一个数来表示，那末总体就成为一些数的集合，用  $x_1, x_2, \dots, x_N$  或  $x_1, x_2, \dots$  表示。

我們再进一步分析通常所见的总体是怎样一些数的集合。我們发现，这一般可以分为离散和連續二种，如果我們一批 ( $n$  个) 另件的直径，各为  $x_1, x_2, \dots, x_N$ ，则  $(x_1, x_2, \dots, x_N)$  是一个离散数集。如果我們测量一物体的长度，由于各种偶然因素影响，会引起誤差，每一次测量可能取得的数值可以充滿某一区間，这一区間是一个連續数集。应该特別注意，不管是总体是离散数集或連續数集，其中的数据都是按比例分布的。这点下节要詳細分析討論。

由于总体的容量一般來說都很大；因而要得到总体的性質經常是从总体中取出一部分加以研究。总体的一部分个体组成的集合称为样本（或子样）。比如从某天一机床生产出的另件中取出 50 个，这 50 个另件就是一个样本。从一个总体中可以取出很多种个体集合，因而有很多种样本。特別地，总体是一个特殊的样本。样本中所包含个体的数目称样本容量用  $n$  表示。那末样本可以用  $x_1, x_2, \dots, x_n$  来表示。（注意： $x_1, x_2, \dots, x_n$  不了解为总体  $x_1, x_2, \dots, x_N$  的前  $n$  个数）抽取样本如过程称为抽样。从某天一机床生产出的另件中取出一个样本，亦可以說从另件中抽样。

总体，样本都是相对的。同一事物由于研究的問題不同，有时可以作为总体，有时亦可以作为样本。举例來說，某天一車床生产出来的产品全体，我們若檢查此日这車床产品长度的質量，那末这些产品长度就組成一个总体。若檢查整个車間在这天产品长度的質量，那末这些产品长度就是一个样本。

数理統計的目的就是利用抽样的方法得到总体的一个样本，从而依据样本的情况来判断总体的情况。例如說从 1000 个产品中取出 50 个产品进行檢查，从而判断 1000 个产品中廢品率是多少。从总体中取的样本愈大則样本的情况愈能反映总体的情况。但很大的样本要考查它的性質很困难。若取的样本太小，則不能反映总体的情况。在数理統計中将要解决二个問題：1. 如何抽样，抽多少；2. 从样本的情况如何来判断总体的情况。

数理統計另一目的是利用抽样方法从几个总体中任一个总体得到几个样本，从几个样本的情况判断几个总体的某种性質有否差異，或者判断几个总体之間的联系。

在本节中我們說总体和样本都是一些数的集合，这些数字的分布的情

况如何描繪呢？來下节中将給出描繪数据的方法。

## §2. 数据分布——類数分布与頻率分布

我們假定：在 §2, §3 的討論中数据  $x_1, x_2, \dots, x_n$  可以表示总体的一个样本，亦可以表示总体本身（当  $n=N$  时，实际上总体是一个特殊样本）。

一般地说实验观察得到的数据常常是分散的，沒有系統的，我們必須按性質分類，并加以整理，把同类性質的数据归納在一起，并且按大小排列起来。按大小順序排起来的数据称为統計序列，还是用  $x_1, x_2, \dots, x_n$  表示，此时  $x_1 \leq x_2 \leq \dots \leq x_n$ 。

表示数据分布情况有两种方法：一种是列表的形式，一种是繪图的形式。从表和图中我們能看出数据的分布情况，并且能粗淺的看出，数据集集中在什么地方，集中程度如何。

上节已談到，实验观察得到的数据按性質分有二种：一种是离散的，亦就是数据从离散分布的总体中取得的。比如只能取非負整数值。另一种是連續的，亦就是数据从連續分布的总体中取得的。比如說产品的长度。

下面分二种情况进行討論：

1. 在数据不多特别是离散的情况下，通常把按大小排列的数中相同的归在一起。設  $x_1, x_2, \dots, x_n$  中有  $s$  个不相同的数， $x_1^*, x_2^*, \dots, x_s^*$ ，其中  $x_i^*$  有  $m_i$  个 ( $i=1, 2, \dots, s$ )。我們称  $m_i$  为  $x_i^*$  出現的頻数。所有頻数加起来称为总頻数（即是  $n$ ）。頻数  $m_i$  比上总頻数  $n$  称为  $x_i^*$  出現的頻率。列成表：

	$x_1^*$	$x_2^*$	.....	$x_s^*$
頻 数	$m_1$	$m_2$	.....	$m_s$
頻 率	$\frac{m_1}{n}$	$\frac{m_2}{n}$	.....	$\frac{m_s}{n}$

第一二行称頻数分布，第一三行称頻率分布。

表中  $\sum_{i=1}^s m_i = n, \sum_{i=1}^s \frac{m_i}{n} = 1$ 。

（讀者可以把数据頻率分布表与概率論中的离散随机变量的分布列作



比較)。

数据的頻数分布和頻率分布都描繪了数据的分布情况。更明确地說頻数分布給出了各个数值个数的分布，頻率分布給出了各个数值佔全体数据的百分比的分布。

若用图表示更能直观地显示出数据的分布情况。

作图时，只要把数据作为横坐标，頻数(頻率)作为纵坐标作出点子，连接各点就得到頻数(頻率)分布图，这种分布图称为多角形頻数(頻率)分布图。有的书上只画出表示頻数(頻率)高点的点子，而不作联接各点的直綫。(見图 1)




图 1

作多角形頻数分布图如右:

若把图中頻数  $m_i$  分别换成頻率  $\frac{m_i}{n}$  ( $i=1, 2, \dots, n$ ) 亦即把多角形的頂点的高度压缩  $n$  倍，則得到多角形頻率分布图。




图 2

实用上还有一种所謂累积頻数(頻率)分布图。对于横坐标上何一值  $x$  取纵坐标为小于  $x$  的数据的頻数(頻率)就得到累积頻数(頻率)分布图(見图 2)。

累积頻数(頻率)分布图是阶梯形曲綫。在間断点  $x_1^*, x_2^*, \dots, x_n^*$  上的跳跃分别为  $m_1, m_2, \dots, m_n$ 。

若把图中頻数  $m_i$  分别换成頻率  $\frac{m_i}{n}$  ( $i=1, 2, \dots, m_n$ )，亦即把图形的高度压缩  $n$  倍，則得到累积頻率分布图。

(讀者可以把累积頻率分布与概率論中的高数随机变数的分布两数作比較)。

2. 若数据的个数超过 100 特别是数据連續的情况下，用上法处理起来是繁复的。可以用分組法来处理，下一节可以看到用分組法处理在計算上可以带来很大方便。所謂分組法即是把数据划分成一些組，划分成一些組后把每一个組作为一个基本单元，在同一組内的数据都看成是相同的，

2. 若数据的个数超过 100 特别是数据連續的情况下，用上法处理起来是繁复的。可以用分組法来处理，下一节可以看到用分組法处理在計算上可以带来很大方便。所謂分組法即是把数据划分成一些組，划分成一些組后把每一个組作为一个基本单元，在同一組内的数据都看成是相同的，

它們都等于組的兩端的不均數，亦可以說等于組中值，組中值就作為一組中數據的代表。因而組的個數比之于不同的數據的個數要少得多，這樣處理起來就方便多了。現把  $n$  個數據劃分成  $e$  個組（為以後方便起見，亦用  $e$  表示組的個數）。

$$\begin{array}{c} | x_1, x_2, | \dots, x_e | \\ \cdot a_0 \qquad a_1 \qquad \qquad \qquad a_e \end{array}$$

兩相鄰分點間距離  $a_1 - a_0, a_2 - a_1, \dots, a_e - a_{e-1}$  稱組長（或組距）。在实际工作中分組的原則如下（這些原則完全由实际工作經驗所得）：

分組的原則：

(1) 數據需要在一百個以上。

(2) 在一般情況下把數據分成 15 組到 25 組為宜，但至少不能少于 10 組。若組分得太多，就不方便。若組分得太少，就太粗糙，不能很好反映实际情况。

(3) 在一般情況下分組分得每組長都相同。在數據分布極不均勻時，在分組時要求每個組內所包含的數據的個數不宜相差太懸殊。亦就是在劃分，組的長度時在數據較密的地方可以取短一些，在數據較疏的地方可以取長一些。

(4) 在兩組的交界上的數據約定歸于右邊一邊組。

同樣地每組內的數據的個數稱為頻數。所有頻數的和稱為總頻數即是  $n$ 。各組的頻數比上總頻數稱為頻率。列成表：

組	$(a_0 a_1)$	$(a_1 a_2)$	.....	$(a_{e-1}, a_e)$
頻 數	$m_1$	$m_2$	.....	$m_e$
頻 率	$\frac{m_1}{n}$	$\frac{m_2}{n}$	.....	$\frac{m_e}{n}$

第一二行稱頻數分布，第一三行稱頻率分布。

對於分組情形，可用直方頻數（頻率）分布圖描繪分組的頻數（頻率）分布情況。直方圖有二種：

(1) 在橫坐標上劃出點  $a_0, a_1, a_2, \dots, a_e$ ，以每一組為底邊，相應組上的頻數（頻率）為高作矩形，得到高直方頻數（頻率）分布圖。

作直方頻數分布圖如下（圖 3）；




图 3

若把图中频数  $m_i$  分别换成频率  $\frac{m_i}{n}$  ( $i=1, 2, \dots, n$ ) 亦即把各矩形的高度压缩  $n$  倍, 则得到直方频数 (频率) 分布图。

这种直方图的缺点在于假如一个组分得长一些, 那末在这组上的频数 (频率) 就要大一些, 结果势必相应的矩形要高一些。这样不能很好看出频数 (频率) 分布情况, 把各组的频数 (频率) 加以比较, 为了避免这一点, 可以作另一种直方图。

(ii) 在横坐标上画点  $a_0, a_1, a_2, \dots, a_n$ , 以每一组就底边, 矩形高取为相对应组上的频数 (频率) 被组的长度除得的数值, 这数值等于组内平均分布, 在单位长度区间的频数 (频率) 的大小。这样表示频数 (频率) 分布情况要可避免掉因组的长度大, 而相应组上的频数 (频率) 亦大这一点。因为各个矩形高 =  $\frac{\text{频数 (频率)}}{\text{底长}}$ , 可见矩形面积就等于相应组上的频数 (频率) 了。

作直方频数分布图如下 (见图 4)。图中所有矩形面积之和等于总频数  $n$ 。

特别要提出的是直方频率分布图 (图 5) :



图 4




图 5

它只是把直方频数分布图的高压缩  $n$  倍。图中所有矩形的总面积等于 1。在数据连续的情况下, 从理论上讲, 当  $n$  不断增大, 每一组的长度分得愈来愈小时, 表示频率分布的阶梯形曲线就趋近于一条光滑的曲线, 曲线记为  $f(x)$ , 曲线  $f(x)$  称为频率分布曲线, 函数  $f(x)$  称为频率分布密度函数, 简称频率分布密度。

频率分布密度理论上描绘了连续数据的分布情况。

(读者可以把数据的频率分布密度与概率论中的连续随机变数的分布密度作比较)。

频率分布密度有如下性质:

(1)  $f(x) \geq 0$ 。

(2) 数据分布在区间  $[x, x+dx]$  中的频率等于区间  $[x, x+dx]$  之上曲线  $f(x)$  之下梯形的面积  $f(x)dx$  (见图 6)。




图 6

由(2)可得

(3) 数据分布在区间  $[a, b]$  中的频率等于区间  $[a, b]$  之上曲线  $f(x)$  之下曲边梯形的面积  $\int_a^b f(x)dx$  (见图 6)。

(4) 曲线  $f(x)$  下的总面积  $\int_{-\infty}^{+\infty} f(x)dx = 1$  等于 1。

在分组的情况同样可作出累积频率(频率)分布图。把在组内的频率(频率)看成均匀地分布着,因而在组内  $x$  增加时累积频率(频率)就均匀地增加,故在组内的图形是直线,累积频率分布如下(见图 7):




图 7

特别值得提出的是累积频率分布图。图形如下:



图 8

它是把累积频率分布图高度压缩  $n$  倍。在数据连续情况,当  $n$  不断增

大，分的組的长度愈来愈小时，在理論上累积頻率曲綫趋近于一条光滑的曲綫，記为  $F(x)$ 。曲綫  $F(x)$  称为累积頻率分布曲綫（見圖8）。函数  $F(x)$  称为累积頻率分布函数。（讀者可与概率論中的連續随机变数的分布函数作比較）。累积頻率分布函数描繪了数据的分布情况。

頻率分布密度和累积頻率分布函数者描繪了数据的分布情况，那么它們之間又有怎样的关系呢？在数据連續分布时，有一满意的回答。

現在來說明頻率分布函数  $f(x)$  和累积頻率分布函数  $F(x)$  之間的关系：

在数据連續分布时，数据落在区間  $[x, x+dx]$  內的概率为  $F(x+dx) - F(x)$ ，另一方面它又等于  $f(x)dx$ 。

$$F(x+dx) - F(x) = f(x)dx$$

$$\frac{F(x+dx) - F(x)}{dx} = f(x)$$

因而得到  $F'(x) = f(x)$ 。

此式說明累积頻率分布函数的导数等于頻率分布密度。那么利用牛顿—萊布尼茲公式，反过来就有

$$F(b) - F(a) = \int_a^b f(x)dx$$

引进了頻率分布函数与累积頻率分布函数后，我們把处理一批数据問題变成处理已經用几何图形表示出来的一个函数的問題。从此以后我們就可以用代数和微积分的工具了。

“ $n \rightarrow \infty$ ”时数据的頻率分布密度或累积頻率分布函数，在实际問題中反映了无限大总体或近似无限大总体的数据的頻率分布。实际工作中，我們总是通过总体的一个样本的数据分布去推判总体的数据分布，当所取的样本愈大，样本的数据分布愈接近总体的数据分布。由于人們受到時間、精力、經濟等各方面的限制，我們得到的样本容量不可能太大。因而“ $n \rightarrow \infty$ ”只是数学上的假想，我們假想“ $n \rightarrow \infty$ ”时的極限情形样本的頻率分布就变成总体的頻率分布了。由此得出結論：頻率分布密度或累积頻率分布函数从理論上察見地反映了无限大或近似无限大总体的数据的頻率分布情况。有的书上把頻率分布密度和累积頻率分布函数称之为数据的理論分布。

数据的頻率分布和概率論中随机变数的概率分布相类似。从意义上讲

是不同的，数据的频率分布是表示数据的分布情况，那里多一些那里少一些，而随机变量的概率分布表示随机变量取值的概率分布情况，但是，它们之间有着紧密的联系，这一点我们在第4节中将详细地阐述。

类似于随机变量的数字特征，在下一节中我们要讲数据的频率分布的数字特征。

### §3. 数据频率分布的数字特征

数据频率分布的数字特征是指频率分布的特点的数值，大致地来说可以分为二种：一种是数据集中在什么位置，即数据围绕什么位置分布的，另一种是数据对于集中位置的集中程度如何，它们的定义完全类似于随机变量的数学特征。

#### 1. 平均数。

把所有数据相加取平均得到的数值称为平均数，记为  $\bar{x}$ ，用式子表示成

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

在不分组的情况：

$$\begin{aligned} \bar{x} &= \frac{m_1 x_1^* + m_2 x_2^* + \dots + m_n x_n^*}{n} \\ &= \frac{m_1}{n} x_1^* + \frac{m_2}{n} x_2^* + \dots + \frac{m_n}{n} x_n^* \end{aligned}$$

在分组的情况：设第  $i$  组组中值为  $x_i^*$ ，设  $x_i^*$  为第  $i$  组的代表 ( $i = 1, 2, \dots, a$ )，则

$$\begin{aligned} \bar{x} &= \frac{m_1 x_1^* + m_2 x_2^* + \dots + m_a x_a^*}{n} \\ &= \frac{m_1}{n} x_1^* + \frac{m_2}{n} x_2^* + \dots + \frac{m_a}{n} x_a^* \end{aligned}$$

当然这样算得的平均数与真正的平均数是有误差的，但是当组分得不太大时，这误差是相当小的。

平均数是数据分布的很重要的一个特征，它把数据之间的差异平均掉了，数据以平均数为集中中心，围绕它分布，在产品检查和测量理论中是一个重要指标。

例题：

$x_i^*$	$m_i$	$m_i x_i^*$
19	1	19
20	5	60
21	5	105
22	7	154
23	6	138
24	2	48
25	1	25

$$\sum m_i = 25 \quad \sum m_i x_i^* = 549$$

$$\bar{x} = \frac{549}{25} = 21.96$$

在组长相等的情况，有时用下面的公式计算平均数是相当麻烦的。下面介绍一个计算平均数的简单方法。

平均数简算法：先找出一个在数据分布中佔比较中间的位置的中值  $x_0$ ，每个组中值  $x_i^*$  减去  $x_0$ ，再除以组的长度  $c$ ，则得到

$$u_i^* = \frac{x_i^* - x_0}{c}$$

对  $u_i^*$  取平均得到  $\bar{u}$  与  $\bar{x}$  的关系如下：

$$\begin{aligned} \bar{x} &= \sum_{i=1}^n \frac{m_i}{n} x_i^* = \sum_{i=1}^n \frac{m_i}{n} (c u_i^* + x_0) \\ &= c \sum_{i=1}^n \frac{m_i}{n} u_i^* + x_0 \sum_{i=1}^n \frac{m_i}{n} = c \bar{u} + x_0 \end{aligned}$$

故由  $\bar{u}$  很简单地能算出  $\bar{x}$ 。

例題：	組	$x_i^*$	$m_i$	$u_i^*$	$m_i u_i^*$
	189.5~193.5	191.5	2	-7	-14
	193.5~197.5	195.5	4	-6	-24
	197.5~201.5	199.5	7	-5	-35
	201.5~205.5	203.5	12	-4	-48
	205.5~209.5	207.5	19	-3	-57
	209.5~213.5	211.5	24	-2	-48
	213.5~217.5	215.5	27	-1	-27
	217.5~221.5	219.5	35	0	0

221.5~225.5	223.5	26	1	26
225.5~229.5	227.5	21	2	42
229.5~233.5	231.5	18	3	54
233.5~237.5	235.5	13	4	42
237.5~241.5	239.5	6	5	30
241.5~245.5	243.5	5	6	30
245.5~249.5	247.5	2	7	14
249.5~253.5	251.5	1	8	8

$$\sum m_i = 222$$

$$\sum m_i x_i = 3$$

表中取中间值 219.5 为  $x_0$ ,  $c$  的值为 4.

$$\bar{u} = \frac{3}{222} = 0.0135.$$

$$\bar{x} = 4 \times 0.0135 + 219.5 = 219.554.$$

在数据连续分布时, 当数据无限增多, 分组分得愈来愈小时, 平均数可表成积分

$$\bar{x} = \int_{-\infty}^{+\infty} xf(x)dx$$

其中  $f(x)$  为数据的频率分布.

### 2. 中位数.

把数据按大小次序排列起来, 最中间的一个数称为中位数. 记为  $M_0$ .

数据有奇数个, 那末中位数取中间的一个数. 例: 数据 60、80、90、95、98,  $M_0 = 90$ .

数据有偶数个, 那末中位数取中间二个数的平均值. 例: 数据 60、80、90、95、98、100,  $M_0 = \frac{90+95}{2} = 92.5$ .

中位数亦描写数据的集中位置, 数据围绕中位数分布着. 中位数计算很方便, 比之于平均数的计算简单得多. 它在产品质量控制中要应用到.

### 3. 均方差.

数据与平均数之差的平方的平均值开根称为均方差, 记为  $\sigma$ . 用式表示为

$$\sigma = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}}$$

在不分组的情况:



$$\begin{aligned}\sigma &= \sqrt{\frac{m_1(x_1^* - \bar{x})^2 + m_2(x_2^* - \bar{x})^2 + \cdots + m_c(x_c^* - \bar{x})^2}{n}} \\ &= \sqrt{\frac{m_1}{n}(x_1^* - \bar{x})^2 + \frac{m_2}{n}(x_2^* - \bar{x})^2 + \cdots + \frac{m_c}{n}(x_c^* - \bar{x})^2}\end{aligned}$$

在分组的情况：第  $i$  组内的数据以组的中間值  $x_i^*$  为代表 ( $i=1, 2, \dots, c$ )，则

$$\begin{aligned}\sigma &= \sqrt{\frac{m_1(x_1^* - \bar{x})^2 + m_2(x_2^* - \bar{x})^2 + \cdots + m_c(x_c^* - \bar{x})^2}{n}} \\ &= \sqrt{\frac{m_1}{n}(x_1^* - \bar{x})^2 + \frac{m_2}{n}(x_2^* - \bar{x})^2 + \cdots + \frac{m_c}{n}(x_c^* - \bar{x})^2}\end{aligned}$$

若均方差愈小，则数据对于平均数之差的平方的平均值愈小。因而数据对平均数之差的绝对数值都很小，说明数据对于平均数的差异都很小，数据对于平均数  $\bar{x}$  愈集中。由此可见，均方差是描述数据对于平均数差异程度或者集中性程度的数。

均方差在产品检查与测量理论中是一个很重要的量。

在计算均方差时常采用公式：

$$\sigma = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n} - \bar{x}^2} = \sqrt{\frac{\sum_{i=1}^n m_i x_i^{*2}}{n} - \bar{x}^2}$$

公式推导：

$$\begin{aligned}\sigma &= \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} = \sqrt{\frac{\sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2)}{n}} \\ &= \sqrt{\frac{\sum_{i=1}^n x_i^2}{n} - 2\bar{x} \frac{\sum_{i=1}^n x_i}{n} + \bar{x}^2} = \sqrt{\frac{\sum_{i=1}^n m_i x_i^{*2}}{n} - \bar{x}^2} \\ &= \sqrt{\frac{\sum_{i=1}^n m_i x_i^{*2}}{n} - \bar{x}^2}\end{aligned}$$

利用这公式计算可减少一道减  $\bar{x}$  的手续，所以计算时有方便之处。

例证：