

网上聚类分析的可视化设计与开发^①

Design and Development on Visualizing Internet – Based Cluster Analysis

石彤菊 马新顺 (华北电力大学 数理系 河北 保定 071003)

摘要: 利用 Microsoft Visual J++ 6.0 作为实验开发平台,采用 Java 语言及 Applet 嵌入网页技术,实现了互联网环境下的聚类分析可视化。所设计的可视化窗口上,能够通过范例演示聚类分析全过程,并可通过选择快速聚类法、最短距离法、最长距离法对录入数据进行聚类分析,具有数据的录入、修改、输出分类结果及显示分类谱系图等功能。

关键词: 数学实验 聚类分析 Microsoft visual J++ 6.0 Applet 小程序

1 引言

数学实验是大学数学课程的一种新的教学模式。该课程将数学知识、数学建模与计算机应用相结合,让同学们自己做实验,体验解决问题的过程,从实验中去学习,从成功和失败中去获得真知。本文的主要内容是我校基于 Visual J++ 6.0 开发的数学实验的一部分,实现聚类分析可视化设计与编程。

聚类分析是对被评价对象进行定量分类的一种多元统计分析方法。聚类的目的是挖掘数据潜在的自然分组结构和关系。聚类分析方法已经在众多的不同领域中得到应用,有效地解决了科学研究所中多因素、多指标的分类问题。在本设计实现分类的过程中,主要是把原始资料列为一个矩阵,通过对矩阵进行求最大最小值、去掉相关性最小的行或列等运算来实现。通过本实验,能使同学们更好的了解聚类分析的原理、应用,并能够用它解决实际中的聚类问题。

2 聚类分析理论

2.1 原始资料矩阵

设有 n 个样品,每个样品测得 m 项指标,原始资料可用 $n * m$ 的矩阵表示为:

$$X = \begin{pmatrix} x_{11} & \dots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nm} \end{pmatrix}$$

其中 x_{ij} ($i=1, \dots, n$; $j=1, \dots, m$) 为第 i 个样品的第 j 个指标的观测数据。第 i 个样品 X_i 为矩阵 X 的

第 i 行所描述,所以任何两个样品 X_k 与 X_l 之间的相似性,可以通过矩阵 X 中的第 K 行和第 L 行的相似程度来刻划,任何两个变量 x_k 与 x_l 之间的相似性,可以通过第 K 列和第 L 列的相似程度来刻划。

2.2 距离

如果把 n 个样品(X 中的 n 行)看成 m 维空间(m 个变量描述)中 n 个点,则两个样品间相似程度可用 m 维空间中两点的距离来度量。令 d_{ij} 表示样品 X_i 和 X_j 的距离。我们取明氏距离 $d_{ij}(q) = (\sum_{\alpha=1}^m |x_{i\alpha} - x_{j\alpha}|^q)^{1/q}$ 中的 $q=2$ 也就是用欧氏距离来定义样本间的距离^[1]。

2.3 聚类方法

2.3.1 最短距离法

定义类 G_i 和 G_j 之间的距离为两类最近样品的距离 $D_{ij} = \min_{X_i \in G_i, X_j \in G_j} d_{ij}$ 。设类 G_p 与 G_q 合并为一个新类记为 G_r ,则任一类 G_k 与 G_r 的距离:

$$D_{kj} = \min \left\{ \min_{X_i \in G_k, X_j \in G_p} d_{ij}, \min_{X_i \in G_k, X_j \in G_q} d_{ij} \right\} = \min \{D_{kp}, D_{kq}\}$$

2.3.2 最长距离法

定义类 G_i 和 G_j 之间的距离为两类最远样品的距离

$$D_{pq} = \max_{X_i \in G_p, X_j \in G_q} d_{ij}$$

最长距离法与最短距离法的并类步骤完全一样,将各样品先自成一类,然后将非对角线上最小元素对应的两类合并。设某一步将类 G_p 与 G_q 合并为 G_r ,则任一类 G_k 与 G_r 的距离用最长距离公式为:

^① 基金项目: 华北电力大学博士学位教师科研基金资助项目(200612005); 河北省高等教育教学教改研究资助项目(2006–2009)

$$D_{ij} = \max \left\{ \max_{X_i \in G_k, X_j \in G_p} d_{ij}, \max_{X_i \in G_k, X_j \in G_q} d_{ij} \right\} = \max \{D_{kp}, D_{kq}\}$$

再找非对角线最小元素的两类合并,直至所有的样品全归为一类为止。

2.3.3 快速聚类法

快速聚类法又称为动态聚类法,首先将样品根据实际问题的意义粗略地分类,然后再按照某种原则进行修正,直至分类比较合理为止。快速聚类的过程大致可由下图 1 所示[2]:




图 1 快速聚类法的过程

3 程序设计

3.1 编程语言的选择

选择 Visual J++ 6.0 作为开发工具。

3.2 程序的界面设计

3.2.1 Applet 界面的设计

该界面用 Java Applet 编程实现,使用 this.setLayout(null) 进行控件布局非常灵活,可以自由设定各个控件的位置,还可以通过 reshape 自由设定各个控件的大小。程序主界面如下图 2 所示:




图 2 聚类分析的主界面

3.2.2 网页界面的设计

首先将 Applet 小程序嵌入到网页中,再在网页中写明实验题目、实验原理、方法说明、使用说明、结论及问题等。页面的设计用 Microsoft Office FrontPage 2003 作为开发环境^[3]。

3.3 程序中使用的主要控件

Label(标签); Button(按钮); TextField(文本框); TextArea(文本域); CheckboxGroup(单选按钮组),在此单选按钮组中定义了三个单选按钮 radio1、radio2、radio3。此外,在此程序中还定义了一块画布 mycanvas,两个弹出式窗口 MyFrame1、MyFrame2。并且画布和弹出式窗口都是通过新建自己的类来实现的^[4]。

4 算法设计

4.1 对原始资料的标准化

设

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{pmatrix}$$

为原始资料矩阵,为消除数据量纲的影响,对原始数据进行标准化,即取

$$\bar{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j} \quad i=1,2,\dots,n; j=1,2,\dots,m$$

其中, $\bar{x}_j = (\sum_{i=1}^n x_{ij}) / n$, $s_j = [\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2 / (n-1)]^{1/2}$, 将标准化后的数据存入数组 $x1[][]$ 中。

4.2 最短(长)距离法聚类过程算法

利用欧氏距离求得距离矩阵 D,找出距离矩阵中非对角线最小元素 x_{pq} ,比较距离矩阵中的第 p 行和第 q 列,将相对应的元素的较大值用较小的值代替,然后再删掉矩阵中的第 q 行和第 q 列,将矩阵的行的维数和列的维数分别减 1,继续重复执行,直至矩阵中只剩下一个元素为止,就完成了样本类的合并。此算法的流程图如下图 3 所示:




图 3 最短距离法流程图

4.3 快速聚类过程算法

找出距离矩阵 D 中非对角线最大元素,即可设定初始分类的聚点为 x_p 和 x_q ,再通过比较各样本与 x_p 和 x_q 之间的距离来确定将样品放入哪一个类,在 n 个样品中,比较 $d[i][p]$ 、 $d[i][q]$ 将样品 i 加入距离较小的类。

根据新分好的类中的样本计算新的聚点:

$$d1 = \frac{1}{\text{count1}} \sum_{x_i \in G_1} d[i][p], \quad d2 = \frac{1}{\text{count2}} \sum_{x_i \in G_2} d[i][p]$$

其中 count1、count2 分别是类 1 和类 2 中已有的样品的个数,重复进行直到划分出一个较合理的类为止【2】。其流程图见图 4



图 4 快速聚类法流程图

5 画图程序算法

5.1 最短、最长距离法的谱系图

在 MyCanvas 中定义数组 lei1[]、lei2[] 通过在 Applet1 中用 MyCanvas.lei1[]、MyCanvas.lei2[] 进行赋值来存放并类过程中每次所合并的样本的序号。用标志变量 flag1 = true 来确定选择的方法是最短距离法。

谱系图的画出是通过画直线来完成的,由于求出的类间距离是根据标准化后的矩阵求出的,所以距离比较小,为了画图的清晰性,将距离扩大 100 倍画出。

5.2 快速聚类法的谱系图

为了直观地显示快速聚类法的结果,首先画出两

个方框来存放每一类中的样本。再通过在 Applet1 中赋好值的数组 fenlei1[]、fenlei2[] 来将分好类的样本存放在相应的方框内。

6 程序的输入和输出

6.1 程序的输入

所设计的内容包括自动分析和手动分析两部分内容。在自动分析中,为方便用户学习,系统内已经输入好的一组数据进行分析,这组数据可以通过点击自动分析旁边的显示原始资料按钮显示出来。数据来源为世界各国森林资源的分布数据^[1]。

在手动分析中,用户需要输入样本个数 n、变量数 m 及原始数据矩阵 x,系统将自动生成一个 n * m 的矩阵。数据输入格式为: 数据 + 空格 + 数据 + 空格 +。最后按“读入”按钮就可将数据读入了。

6.2 程序的输出

程序的输出分为文本框输出和画图直观显示。文本框将输出合并的类号和类间距离等,为了更直观的让用户了解聚类分析的过程,还特意加入了谱系图显示。

为了方便用户的使用,进行了网页设计,包括一些必要的文字说明,如实验目的、实验原理、方法步骤、使用说明等,与 Applet 可视化程序一起构成了一个完整的聚类分析实验。

参考文献

- 夏绍伟,杨家本,杨振斌. 系统工程概论. 北京: 清华大学出版社,1995. 88 - 97.
- 范金城,梅长林. 数据分析. 北京: 高等教育出版社,2006. 176 - 197.
- 王凯,张家才. 网页制作技巧与实例. 北京: 冶金工业出版社,1999.
- 杨昭,孙友编. Java 语言程序设计. 北京: 中国水利水电出版社,2004.