



本课件仅用于教学使用。未经许可，任何单位、组织和个人不得将课件用于该课程教学之外的用途(包括但不限于盈利等)，也不得上传至可公开访问的网络环境

1

数据科学导论

Introduction to Data Science

第四章 数据挖掘基础

陈恩红，黄振亚

Email: huangzhy@ustc.edu.cn, cheneh@ustc.edu.cn

课程主页：

<http://staff.ustc.edu.cn/~huangzhy/Course/DS2024.html>




数据挖掘基础

2

□ 数据挖掘——四个任务有哪些常用方法？

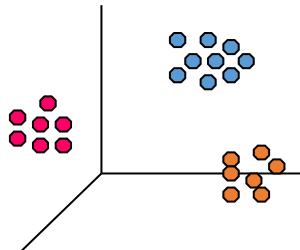
分类与预测



关联分析




聚类



数据

	T		H		P	
	L	H	L	H	L	H
J	-6.0	8.8	60	100	986	1044
F	-2.8	10.9	48	100	973	1025
M	-5.6	17.7	34	100	976	1037
A	-1.2	22.2	27	100	996	1036
M	-0.8	27.8	25	100	1003	1034
J	5.2	29.1	26	100	998	1030
J	9.8	30.6	23	99	997	1027
A	5.6	26.1	31	100	992	1029
S	5.2	24.8	35	100	998	1028
O	-0.4	21.3	42	100	990	1031
N	-7.6	17.3	55	100	963	1023
D	-10.4	9.2	53	100	987	1039

table 17a
2010 monthly weather variation, Cambridge (UK)




聚类分析: 应用实例

3

案例一：分子与药物分析

- 输入: 生物医药分子
- 结构相似度更高的分子被分配到一个聚簇



- 第7簇中含有芳香族羧酸酯
- 第35簇中含有芳基卤化物
- 第44簇中含有磺胺

➤ Hadipour, H., Liu, C., Davis, R., Cardona, S.T., & Hu, P. (2022). Deep clustering of small molecules at large-scale via variational autoencoder embedding and K-means. *BMC Bioinformatics*, 23.



聚类分析: 应用实例

4

□ 案例二：疫情溯源

- 输入：纽约市病例人群的信息：地理位置等
- 对纽约市的冠状病毒病(COVID-19)爆发场所聚类，定位的感染源




FIGURE 5. K-means clustering ($k = 15$) in New York state.

按病例的位置聚类，得到K个聚簇区域




FIGURE 7. Hot spots H_k for each cluster in New York state (orange circles).

聚簇区域中心被视为感染源

- Guevara C, Peñas M S. Surveillance Routing of COVID-19 Infection Spread Using an Intelligent Infectious Diseases Algorithm[J]. Ieee Access, 2020, 8: 201925-201936.




聚类分析: 应用实例

5

□ 案例三：网络舆情分析-话题挖掘

- 输入：社交媒体中的评论与话题
- 话题聚类，同一话题簇中出现的关键词相似





- Cai Y, Wu X, Xie X, et al. A topic mining method for multi-source network public opinion based on improved hierarchical clustering[C]//2019 IEEE DSC. IEEE, 2019: 439-444.

聚类分析: 应用实例

6

案例四：安防与维稳-犯罪团伙识别

- 输入：人员轨迹时空数据：如网吧、酒店、车站等，
- 对嫌疑人的轨迹信息进行聚类，找出犯罪团伙。



聚类分析: 应用实例

7

□ 案例五：教育问题的聚类

- 输入：数学应用题
- 题目聚类，同类题目的解答模板一样


数学应用题

Prob. A: Norma has 88 cards. She loses 70. How many cards will Norma have ?

Eq: $88 - 70$

Prob. B: Joyce starts with 75 apples. She gives 52 to Larry. How many apples does Joyce end with?

Eq: $75 - 52$



基础运算的
模式不同

- $n_1 + n_2$
- n_1 / n_2
- $n_1 - n_2$
- $(n_1 + n_2) * n_3$
- $n_1 * n_2$
- $(n_1 + n_2) / n_3$

- Li, Z., Zhang, W., Yan, C., Zhou, Q., Li, C., Liu, H., & Cao, Y. (2022). Seeking Patterns, Not just Memorizing Procedures: Contrastive Learning for Solving Math Word Problems. ArXiv, abs/2110.08464.
- Huang, Z., Lin, X., Wang, H., Liu, Q., Chen, E., Ma, J., Su, Y., & Tong, W. (2021). DisenQNet: Disentangled Representation Learning for Educational Questions. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining.



聚类分析: 应用实例


8

□ 案例六：学业数据分析——优化教师教学

- 输入：试验学校的学生考试数据
- 聚类发现教师教学模式的规律



根据考试数据对班级进行简单聚类，根据聚类结果，发现70%的类里，两个班级是同位授课教师






聚类分析

9

□ 数据挖掘任务 —— 聚类(Clustering)

- 目标：对数据进行 “群体性” 分析，将样本分为若干个簇 (Clusters)
 - 其中，每个簇都由相似的样本所组成
- 簇的特点：簇内相似 (距离近)，簇间相异 (距离远)





聚类分析

10


□ 聚类分析要解决三个问题

□ 1. 如何定义簇？：即，思考我们的目标（但具有主观性）

- “群体性”的依据：不同的“群体性”立场，可以得到不同的簇
- 例如，学生分组应该考虑 **技能互补？** 还是 **能力相近？**

□ 2. 如何定义相关性？即，度量数据之间的相似性

- 相似性度量往往存在一定局限性，未必反映聚类的真实意图
- 例如，常用向量表征数据(人的爱好)，但是否绝对相似？



技能互补？ 能力相近？



图片本身相似，但代表的类别完全不同？




聚类分析

11

□ 聚类分析要解决三个问题

□ 3. 如何决定簇的数量？即，选择合适数量的簇

- 数据没有天然标签，簇的数量往往是个开放性问题
- 避免过大或过小的簇，会导致失去代表性，但这未必可通过簇数调节





聚类分析

13

- 聚类方法：最常见的无监督学习算法
- 常用方法
 - K均值聚类(K-means)
 - 密度聚类(Density-based Clustering)
 - 聚类效果验证
 - 前沿聚类方法



聚类分析：K-means

14

□ K-means的基本概念

- **数据**：视作高维空间中的一个点，表示为向量
- **中心点**：簇的中心，反应簇的共有属性
- **簇的数量**：人为设定
- **数据的关系度量**：用“平均”的方式簇中心与簇中数据





聚类分析：K-means

15

□ K-means算法：设定K个中心，形成K个数据簇

- 根据问题目标，预先指定簇的个数K
- 每一个簇存在一个中心点
- 每一个数据属于最近中心点对应的簇
- 簇中心的更新：依赖簇中数据的算术平均
- 簇中心更新后：根据度量，数据将重新分配至不同的簇
- 算法是迭代过程：簇中心与簇数据迭代更新，直至稳定

1: Select K points as the initial centroids.

2: **repeat**

3: Form K clusters by assigning all points to the closest centroid.

4: Recompute the centroid of each cluster.

5: **until** The centroids don't change



聚类分析：K-means


16

- 一个例子展示：K-means过程
- 3个簇中心
- 数据：二维空间的点
- “+”：表示簇中心
- 颜色：不同的簇



聚类分析：K-means

17











聚类分析：K-means

18

□ K-means示例





聚类分析：K-means

19

□ 如何评估K-means的效果

- 指标：平方误差和 (Sum of Squared Error , SSE)
- 算法目标：优化数据与簇中心的距离
 - 定义每个数据的聚类误差：样本数据与最近簇的距离
- SSE定义为

$$SSE = \sum_{i=1}^K \sum_{x \in C_i} dist^2(m_i, x)$$

- x 是簇 C_i 的样本, m_i 是簇 C_i 的质心, 可证明 m_i 是簇 C_i 平均 (mean)
- 注：面对多个聚类结果时, 倾向于SSE更小的方式
 - 当簇数量K增加时, SSE一般趋于下降, 因此尽量在相同K下比较SSE
 - K和SSE较小的聚类, 优于 K和SSE较大的聚类



聚类分析：K-means

20

□ K-means的特点

□ 关于中心点

- 中心点一般采用随机初始化，因此重复K-means得到的结果可能不同
- 中心点一般设置为簇内数据的平均向量（算术平均）

□ 关于相关性度量

- 可用欧几里得距离、余弦相似度、相关系数等度量

□ 关于算法运行


- K均值算法常常几轮就收敛
- 算法停止条件为：Until relatively few points change clusters
 - 低于一定数量的数据更新簇的归属，即，每个簇中只有很少的数据发生变化
- 算法复杂度 $O(n \times K \times I \times d)$
 - n = 样本总数, K = 簇的个数数, I = 迭代轮数, d = 特征维度



聚类分析: K-means

21

- K-means的特点: 初始中心如何选择?
 - 中心点初始化较好时 (回顾19页的例子)











数据挖掘基础

22

□ K-means的特点: 初始中心如何选择?




聚类结果好



聚类分析：K-means

23

- K-means的特点: 初始中心如何选择?
 - 中心点初始化较差时










聚类分析: K-means

24

□ K-means的特点: 初始中心如何选择?



聚类结果差



聚类分析：K-means

25

- K-means的特点: 如何解决初始中心选择的问题?
 - 最简单的方法: 多次运行
 - 但效率较低 (能否得到好的结果 [看你的运气](#))
 - 采少数样本, 借助其他聚类 (如层次聚类) 先确定出初始中心
 - 然而层次聚类开支较大, 同时此方法仅适用于K较小的情况
 - 初始选择大于K的数量, 然后从中挑选聚类分隔较为明显的中心
 - 后处理 “修补” 聚类的结果
 - 二分K均值方案 (Bisecting K-means)



聚类分析：K-means

26

□ K-means的特点: 如何解决初始中心选择的问题?

□ 二分K均值方案 (Bisection K-means)

- 不容易受到初始化问题的影响
- K-means的变体，类似于一种层次聚类的思想
- 基本思想：为了得到K个簇，先分为2个簇，然后不断选择其中一个分裂

-
- 1: Initialize the list of clusters to contain the cluster containing all points.
 - 2: **repeat**
 - 3: Select a cluster from the list of clusters
 - 4: **for** $i = 1$ to *number_of_iterations* **do**
 - 5: Bisect the selected cluster using basic K-means
 - 6: **end for**
 - 7: Add the two clusters from the bisection with the lowest SSE to the list of clusters.
 - 8: **until** Until the list of clusters contains K clusters
-




聚类分析：K-means

27

□ K-means的特点: 如何解决初始中心选择的问题?

- 实例: 二分K均值方案 (Bisecting K-means)
- 从这个实例可以看出, 二分K均值受初始中心的影响不大
- 究其原因, 二分K均值 可视作一个“逐步求精”的过程






数据挖掘基础

28

□ K-means的特点: 可能返回空簇

- 例如, 所有的点在分配时都未被分配到某个簇
 - 解决方法: 以样本作为初始中心, 则不会出现, 即簇内至少一个点
- 处理空簇: 一般而言, 新生成一个簇来替代空簇(思路类似后处理)
 - 解决方法1: 选择一个最远样本点新生成一个簇
 - 解决方法2: 将最大SSE的簇进行拆分





聚类分析：K-means

29

□ K-means的局限性

□ 簇的特点会影响K-means聚类的结果

- 1. 簇的规模
- 2. 簇的（数据）密度
- 3. 簇的（不规则）形状




聚类分析：K-means


30

□ K-means的局限性

- 1. 簇的规模：当出现规模不同的簇时，往往结果会受到一定干扰



Original Points



K-means (3 Clusters)




聚类分析：K-means


31

□ K-means的局限性

- 2. 簇的(数据)密度：当出现密度不同的簇时，往往结果会受到一定干扰



Original Points



K-means (3 Clusters)




聚类分析：K-means


32

□ K-means的局限性

- 3. 簇的形状：当出现不规则形状的簇时（非球状），往往很难有效聚类



Original Points



K-means (2 Clusters)




聚类分析：K-means


33

□ 如何解决K-means的局限性


□ 一种解决方法：初始时增加簇的个数，然后将多个小簇合并为大簇





不同规模



不同形状



不同密度





聚类分析

49

□ 聚类方法：最常见的无监督学习算法

□ 常用方法

- K均值聚类(K-means)
- 密度聚类(Density-based Clustering)
- 聚类效果验证
- 前沿聚类方法



聚类分析：密度聚类

50

□ 密度聚类

- 基本假设：只有达到一定密度，才足以成为一个簇
- 密度：指定样本一定半径的样本数量
 - 半径，记为Eps
 - 半径内样本数阈值，记为MinPts

□ 典型算法：DBSCAN


- 核心要素：三类不同的数据点
- 1. 核心点(Core point): 稠密部分内部的点
 - 其Eps的范围内的样本个数不少于MinPts，这些核心点位于簇的中心
- 2. 边界点(Border point): 非核心点，但是处于稠密区域边界内/上的点
 - 其Eps的范围内的样本个数少于MinPts，但它是某个核心点的邻居
- 3. 噪音点(Noise point): 处于稀疏区域的点
 - 除核心点和边界点之外的样本

聚类分析：密度聚类

51

DBSCAN

三类点：核心点、边界点和噪音点 示意图





聚类分析：密度聚类

52

□ DBSCAN的基本流程可归纳如下

- 1. 将所有节点区分为核心点、边界点或噪声点
- 2. 删除噪声点
- 3. 将所有距离在预定半径内的核心点之间连一条边
- 4. 连通的核心点形成一个簇
- 5. 将所有的边界点指派到一个与之关联的核心点所在的簇中




聚类分析：密度聚类


53

□ DBSCAN实例

- 半径Eps = 10, 阈值MinPts = 4



Original Points



Point types:

绿色core, 蓝色border, 红色noise




聚类分析：密度聚类

54


□ DBSCAN的优势

- 对噪声鲁棒
- 能够处理不同形状和大小的簇

周边的噪声除去，内部的数据很好的聚类



Original Points



Clusters


聚类分析：密度聚类

55


DBSCAN的局限性

- 簇的密度变化使得DBSCAN的效果可能会受到影响
- 参数难以设置：半径Eps、阈值MinPts的选取需与数据维度匹配

例子：两种方式参数相近，但簇的密度完全不同，DBSCAN的结果差距很大



Original Points





聚类分析：密度聚类

56

□ DBSCAN算法作者获得ICDM2013 Research Contributions Award

TITEL

ZITIERT VON

JAHR

A density-based algorithm for discovering clusters in large spatial databases with noise.

22965

1996

M Ester, HP Kriegel, J Sander, X Xu

kdd 96 (34), 226-231





聚类分析

57

□ 聚类方法：最常见的无监督学习算法

□ 常用方法

- K均值聚类(K-means)
- 层次聚类(Hierarchical Clustering)
- 密度聚类(Density-based Clustering)
- 聚类效果验证
- 前沿聚类方法



聚类分析

58

□ 聚类效果验证

- 作为无监督学习，聚类问题并没有天然标签，如何评估聚类结果？
- 首先，我们需要了解，为什么需要评估聚类结果的“好”与“坏”
 - 确定数据集的聚类趋势，**确定是否真的有群体性**
 - 确定**合理的簇的个数**
 - 比较两个簇，或者比较两种方法的聚类，看**哪种结果更合适**
 - 将聚类的簇与已知的客观信息进行比较
 - 例如，外部提供的标签、Query等



聚类分析

59

□ 聚类效果验证

- 一般而言，聚类问题的评估标准可以分为以下三类
 - **非监督评估** (或内部评估) :仅使用数据本身的特性，而不考虑任何外部标签信息
 - 例如：距离矩阵，SSB(分离度：簇质心 m_i 到数据点均值 m 的距离平方和
$$SSB = \sum_{i=1}^K |C_i|(m - m_i)^2, |C_i| \text{是簇} i \text{的大小, } m \text{是所有数据点的总均值}$$
 - **有监督评估** (或外部评估) :引入外部信息，衡量聚类结构与外部结果的匹配程度
 - 例如：Entropy, Jaccard系数, 准确 (Precision) 、召回 (Recall) 、F值等
 - **相对评估**：主要用于比较两个簇或者两个聚类结果
 - 常常需要外部或内部指标结合, e.g., SSE or entropy



聚类分析

60

□ 方式1：非监督评估：—基于邻近度矩阵

- 理想的聚类结果是：簇内的点邻近度全为1，簇之间的邻近度全为0
- 通过邻近度矩阵，可以可视化地评估聚类结果的好坏
 - 通过观察相似度矩阵是否体现出对角模式，可以大致判断结果好坏

簇内相似，簇间相异





聚类分析

61

□ 方式2：有监督评估—基于Jaccard系数


- 理想的聚类结果是：在邻近度矩阵中
 - 同一个类中的样本，对应的矩阵元素为1
 - 不同类中的样本，对应的矩阵元素为0
- 通过比较两个“理想”矩阵之间的相关性，可以近似估计聚类结果

f_{00} = 具有不同的类和不同的簇的对象对的个数

f_{01} = 具有不同的类和相同的簇的对象对的个数

f_{10} = 具有相同的类和不同的簇的对象对的个数

f_{11} = 具有相同的类和相同的簇的对象对的个数



$$\text{Jaccard 系数} = \frac{f_{11}}{f_{01} + f_{10} + f_{11}}$$


(回顾第2章：数据集成)

聚类分析


62

□ 方式3：相对评估—基于SSE

- 对同一样本集合， SSE较小的聚类结果更好



簇数K小





聚类分析

63

- Y Liu, Z Li, H Xiong, X Gao, J Wu, “**Understanding of internal clustering validation measures**” . ICDM 2010.
- Yanchi Liu, Zhongmou Li, Hui Xiong, Xuedong Gao, Junjie Wu, Sen Wu, “ **Understanding and Enhancement of Internal Clustering Validation Measures**” , IEEE Transactions on Cybernetics (TC), Vol. 43, No. 3, pp. 982-994, 2013.
- J Wu, H Xiong, J Chen, “**Adapting the right measures for k-means clustering**” . KDD 2009.

“The validation of clustering structures is the most difficult and frustrating part of cluster analysis. Without a strong effort in this direction, cluster analysis will remain a black art accessible only to those true believers who have experience and great courage.”

-----*Algorithms for Clustering Data*, Jain and Dubes



聚类分析

64

□ 聚类方法：最常见的无监督学习算法

□ 常用方法

- K均值聚类(K-means)
- 层次聚类(Hierarchical Clustering)
- 密度聚类(Density-based Clustering)
- 聚类效果验证
- 前沿聚类方法



聚类分析

65

□ 前沿聚类方法 — 课外学习

- Prototype-based(基于原型的聚类)
 - Fuzzy K-means
 - Mixture Model Clustering
 - Self-Organizing Maps
- Density-based(基于密度的聚类)
 - Grid-based clustering
 - Subspace clustering
- Graph-based (基于图的聚类)
 - Chameleon
 - Jarvis-Patrick
 - Shared Nearest Neighbor (SNN)



总结：聚类分析

66

- 聚类方法：最常见的无监督学习算法
- 常用方法
 - K均值聚类(K-means)
 - 层次聚类(Hierarchical Clustering)
 - 密度聚类(Density-based Clustering)
 - 聚类效果验证
 - 前沿聚类方法