

基于 Finsler 几何的 k -means 算法

许 晴, 李凡长, 邹 鹏

(苏州大学计算机科学与技术学院, 江苏苏州 215006)

摘要:针对 k -means 算法存在的相似性度量、准则函数优化效果不理想及多维流形数据分析性能效果不好等问题, 引入 Finsler 几何中的 Finsler 度量, 提出了一种基于 Finsler 几何的 k -means 算法, 并在 UCI 数据集和 ORL 人脸数据库上与传统 k -means 算法及 SBKM 算法进行了比较, 实验结果验证了该算法的可行性和有效性.

关键词: Finsler 几何; Finsler 度量; k -means 算法; 相似性度量; 准则函数

中图分类号: TP311 **文献标识码:** A doi:10.3969/j.issn.0253-2778.2014.07.005

引用格式: Xu Qing, Li Fanzhang, Zou Peng. The k -means algorithm based on Finsler geometry[J]. Journal of University of Science and Technology of China, 2014, 44(7): 570-575.

许晴, 李凡长, 邹鹏. 基于 Finsler 几何的 k -means 算法[J]. 中国科学技术大学学报, 2014, 44(7): 570-575.

The k -means algorithm based on Finsler geometry

XU Qing, LI Fanzhang, ZOU Peng

(School of Computer Science and Technology, Soochow University, Suzhou 215006, China)

Abstract: The problems with the k -means algorithm that the optimization effect of similarity measure and criterion function is not ideal and the analysis performance of multi-dimensional manifold data is ineffective, a modified version based on Finsler geometry was proposed, which introduces Finsler metric. Experimental results in comparison with traditional k -means algorithm and SBKM algorithm on UCI data sets and ORL face image sets show the feasibility and effectiveness of the algorithm.

Key words: Finsler geometry; Finsler metric; k -means algorithm; similarity measure; criterion function

0 引言

k -means 算法是 MacQueen^[1]提出的一种无监督聚类算法, 该算法已在机器学习、数据分析等领域得到广泛关注. 它的核心思想是把 n 个数据对象划分为 k 个聚类, 使得每个聚类中的数据点到该聚类中心的平方和最小. 该算法原理简单且便于处理大

批量数据, 具有收敛速度快、聚类效果好的优势. 同时 k -means 算法也存在不足之处, 如 k -means 算法多采用欧式距离度量数据对象之间的相似度, 通常只能发现数据对象分布较均匀的球状簇, 而无法发现任意簇; 另外欧式距离在现实的二维及三维空间中有明确的几何意义, 但在高维空间情况易会失去几何直观意义. 针对 k -means 算法的不足, 许多学者

收稿日期: 2014-03-21; 修回日期: 2014-06-15

基金项目: 国家自然科学基金(61033013, 60775045), 东吴学者计划, 苏州大学敬文书院“3I 工程”重点项目资助.

作者简介: 许晴, 女, 1990 年生, 硕士生. 研究方向: 机器学习. E-mail: 20124227022@suda.edu.cn

通讯作者: 李凡长, 教授. E-mail: lfzh@suda.edu.cn

做了许多改进^[2-10]. 如文献[5]考虑了类结构中的多种对称性质, 提出了一种改进的基于类对称的距离度量, 可以有效发现超球面以外的具有较对称形状的簇; 文献[9]用马氏距离取代传统 k -means 算法中的欧式距离度量, 可检测超椭球集群; 文献[10]提出了一种新的相似性度量函数, 较好地克服了传统距离函数在高维空间的缺点.

这些成果虽然对单流形结构有较好的效果, 但对多流形问题就显得不是很有用了, 因此, 本文尝试利用 Finsler 几何来研究多流形结构上的 k -means 问题. Finsler 几何是研究具有 Finsler 度量的空间几何性质的学科. 在数学定义中, 度量是用来测量空间中两点之间的“距离”, 从一点到另一点的距离函数称为度量. 常见的度量有: 欧氏度量、黎曼度量等. 欧氏度量是目前最常见的度量, 衡量的是多维空间中两点之间的绝对距离, 但是不能直接地用在流形上. 黎曼度量正是为了在微分流形上建立曲线的长度等概念而产生的, 它的度量形式是一个正定的(至少是非退化的)二次微分式. 相比于这些度量, Finsler 几何中的 Finsler 度量更具有一般性, 它不受二次式度量形式的限制, 且度量本身受高维空间的影响很小, 这正好弥补了上述 k -means 算法中相似性度量、准则函数优化效果不理想及多维流形数据分析性能效果不好的缺陷.

1 k -means 算法回顾

k -means 算法的基本思想是: 首先指定需要划分的簇的个数值 k , 然后随机地选择 k 个初始数据对象作为初始的聚类中心; 计算其余的各数据对象到这 k 个初始聚类中心的距离(这里一般采用欧式距离作为相似性度量), 把数据对象划归到距离它最近的那个中心所处的簇类中; 最后, 调整新类并且重新计算出新类的中心, 如果两次计算出来的聚类中心未曾发生任何的变化, 那么就可以说明数据对象的调整已经结束, 也就是说聚类采用的准则函数(这里一般采用的是误差平方和准则函数)是收敛的, 表示算法结束.

k -means 算法中假定所有数据对应于 n 维空间 R^n 中的点, 数据对象与聚类中心间的距离一般是根据欧式距离定义的. 数据对象 x 表示为特征向量 $x = (x^1, x^2, \dots, x^p)$, x^p 表示样本 x 的第 p 个特征的值.

那么数据对象 x_i 与聚类中心 q_j 间距离表

示为:

$$d(x_i, q_j) = \sqrt{\sum_{l=1}^p (x_i^l - q_j^l)^2} \quad (1)$$

误差平方和准则函数则表示为:

$$J = \sum_{j=1}^k \sum_{i=1}^{n_j} \|x_i - q_j\|^2 \quad (2)$$

式中, q_j 是 k 个集合的中心, 可以用来代表 k 个类型,

q_j 的值即类 j 中样本的均值: $q_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_i, j = 1, 2, \dots, k$.

2 Finsler 几何的基本概念

Finsler 几何是较黎曼几何学更具一般性的一种度量几何学, 下面先对 Finsler 几何的基本概念进行介绍.

定义 2.1 Finsler 函数

我们知道黎曼几何学是基于正定的(至少是非退化的)二次微分式 $ds^2 = g_{ij}(u) du^i \otimes du^j$ 的度量几何学, 其中 u^i 是局部坐标, $g_{ij} = g_{ji}$ 是该流形上的光滑函数. 而 Finsler 几何则考虑更一般的情形, 不受度量形式是二次式的限制. 为此假定 $ds = F(u^1, \dots, u^m; du^1, \dots, du^m)$. 其中, $F(x; y)$ 是有 $2m$ 个自变量的非负光滑函数, 并且仅当 $y = 0$ 时为零, 称为 Finsler 函数. 同时还要求 $F(x; y)$ 关于自变量 y 是一阶齐次函数, 即

$$F(x^1, \dots, x^m; \lambda y^1, \dots, \lambda y^m) = |\lambda| F(x^1, \dots, x^m; y^1, \dots, y^m), \forall \lambda \in R \quad (3)$$

定义 2.2 Finsler 度量

设 M 是一个 n 维光滑流形, $F: TM \rightarrow [0, +\infty)$ 是其切丛上的非负函数. 如果 F 满足如下条件:

- (I) 正齐性: $F(x, \lambda y) = \lambda F(x, y), \forall \lambda > 0$;
- (II) 光滑性: 在带孔切丛 $TM \setminus \{0\}$ 上 $F(x; y)$ 是 C^∞ 函数;
- (III) 正则性: 对于任意非零向量 $y \neq 0$,

$$g_{ij}(x, y) = \frac{1}{2} \frac{\partial^2 F^2}{\partial y^i \partial y^j}(x, y) = \frac{1}{2} [F^2]_{y^i y^j}$$

构成正定的矩阵, 则称 F 为 M 上的一个 Finsler 度量.

3 基于 Finsler 几何的 k -means 算法设计

Finsler 度量是较黎曼度量更一般的一种度量, 由于其定义的一般性, 我们可以构造出很多 Finsler

度量. 国内外很多学者对 Finsler 几何进行了研究, 并给出了一些具有良好性质或易于计算的 Finsler 度量^[11-17]. (α, β) 度量便是其中一类丰富的可计算的 Finsler 度量, 它们在 Finsler 几何中扮演着非常重要的角色.

令 $F = \alpha\phi(s)$, $s = \frac{\beta}{\alpha}$. 其中, $\alpha = \sqrt{a_{ij}(x)y^i y^j}$ 是黎曼度量, $\beta = b_i(x)y^i$ 为非零的 1 形式, $\phi = \phi(s)$ 定义在开区间 $(-b_0, b_0)$ 且满足 $\phi(0) = 1$, $\phi(s) > 0$, $\phi(s) - s\phi'(s) + (b^2 - s^2)\phi''(s) > 0$, $|s| \leq b \leq b_0$, 则对任意 $x \in M$, F 是流形 M 上正定的 Finsler 度量, 称作 (α, β) 度量. 可以很容易验证 (α, β) 度量是满足 Finsler 度量的定义的. 证明如下:

令

$$\begin{aligned} \alpha_\lambda &= \alpha(x^1, \dots, x^m; \lambda y^1, \dots, \lambda y^m), \\ \beta_\lambda &= \beta(x^1, \dots, x^m; \lambda y^1, \dots, \lambda y^m); \\ \therefore \alpha_\lambda &= \alpha(x^1, \dots, x^m; \lambda y^1, \dots, \lambda y^m) = \\ & \sqrt{a_{ij}(x)\lambda y^i \lambda y^j} = |\lambda| \sqrt{a_{ij}(x)y^i y^j}, \\ \beta_\lambda &= \beta(x^1, \dots, x^m; \lambda y^1, \dots, \lambda y^m) = \\ & b_i(x)\lambda y^i = \lambda(b_i(x)y^i); \\ \therefore F(x^1, \dots, x^m; \lambda y^1, \dots, \lambda y^m) &= \alpha_\lambda \phi(\beta_\lambda / \alpha_\lambda) = \\ & |\lambda| \sqrt{a_{ij}(x)y^i y^j} \phi\left[\frac{\lambda}{|\lambda|} \frac{\beta}{\alpha}\right]. \end{aligned}$$

所以只需满足函数 ϕ 为偶函数且恒大于 0, 即 $\phi(-s) = \phi(s)$ 且 $\phi(s) \geq 0$, 就可以保证 (α, β) 度量为 Finsler 度量.

我们取 (α, β) 度量的简洁形式, 即令 $\phi(s) = 1 + \frac{\beta}{\alpha}$, 则有 $F = \alpha + \beta$, α, β 分别取:

$$\begin{aligned} \alpha &= \frac{\sqrt{|y|^2 + \mu(|x|^2 |y|^2 - \langle x, y \rangle^2)}}{1 + \mu |x|^2}, \\ \beta &= \frac{\sqrt{-\mu} \langle x, y \rangle}{1 + \mu |x|^2}. \end{aligned}$$

其中,

$$\begin{aligned} u < 0, \langle x, y \rangle &= \sum_{i=1}^n x^i y^i, \\ |x| &= \sqrt{\sum_{i=1}^n (x^i)^2}, \quad |y| = \sqrt{\sum_{i=1}^n (y^i)^2}. \end{aligned}$$

至此, Finsler 度量公式可写为:

$$F = \frac{\sqrt{|y|^2 + \mu(|x|^2 |y|^2 - \langle x, y \rangle^2)}}{1 + \mu |x|^2} + \frac{\sqrt{-\mu} \langle x, y \rangle}{1 + \mu |x|^2} \quad (4)$$

k -means 算法中数据对象 x_i 到聚类中心 q_j 的相似性度量可定义为:

$$d_{\text{Finsler}}(x_i, q_j) = \frac{\sqrt{|q_j|^2 + \mu(|x_i|^2 |q_j|^2 - \langle x_i, q_j \rangle^2)}}{1 + \mu |x_i|^2} + \frac{\sqrt{-\mu} \langle x_i, q_j \rangle}{1 + \mu |x_i|^2} \quad (5)$$

其中,

$$\begin{aligned} u < 0, \langle x_i, q_j \rangle &= \sum_{l=1}^p x_i^l q_j^l, \\ |x_i| &= \sqrt{\sum_{l=1}^p (x_i^l)^2}, \quad |q_j| = \sqrt{\sum_{l=1}^p (q_j^l)^2}. \end{aligned}$$

相应地, k -means 算法中的准则函数可以定义为:

$$J = \sum_{j=1}^k \sum_{i=1}^{n_j} (d_{\text{Finsler}}(x_i, q_j))^2 \quad (6)$$

基于 Finsler 几何的 k -means 算法的基本流程见算法 3.1.

算法 3.1 (FGK-means) 基于 Finsler 几何的 k -means 算法 (Finsler geometric k -means, FGK-means)

输入: 聚类数 k ; 包含 n 个数据对象的数据集 X
输出: k 个聚类

Step 1 从数据集 X 中任意选取 k 个对象作为初始聚类中心 $(q_1^{(1)}, q_2^{(1)}, \dots, q_k^{(1)})$;

Step 2 第 r 次迭代时, 根据式 (5) 分别计算每个对象 $x_i, i = 1, 2, \dots, n$ 到各个聚类中心的 Finsler 距离;

Step 3 找出每个数据对象关于聚类中心的最小距离, 并将其归入与其距离最小的聚类中心所在的簇中;

Step 4 更新各簇的聚类中心 $q_i^{(r)} = \frac{1}{n_j} \sum_{i=1}^{n_j} x_{ji}$;

Step 5 根据式 (6), 计算准则函数 J_r , 并与前一次 J_{r-1} 相比, 若 $|J_{r+1} - J_r| < \delta$, 则算法结束; 否则转入 Step 2 进行再一次迭代.

4 实验结果与分析

为了验证本文算法的有效性, 我们进行了两组实验. 其中, 第一组实验采用二维仿真数据集, 以便对算法的聚类效果进行直观分析; 第二组采用实物图像, 分别在 UCI 数据库^[18] 以及 ORL 人脸数据库^[19] 上进行实验, 并与传统 k -means 算法及文献

[5]中提出的 SBKM 算法进行比较. 本文实验均在 matlab 平台上实现.

4.1 实验一的结果比较与分析

实验 1: 为了直观分析本文算法的聚类效果以及与传统 k -means 算法和 SBKM 算法进行比较, 我们设计了一组人工数据作为输入数据集 X . 该人工数据是随机生成的三类二维连通图集数据, 每次生成数据时每类样本是 100 个, 我们给出了一次随机生成的数据, 将其可视化如图 1(a) 所示. 其中符号 “*”, “○” 和 “▽” 分别表示不同的类别, 图中每个点的坐标表示的是每个二维数据所在的位置.

利用本文提出的 FGK-means 算法对数据集 X 进行聚类, 我们输入聚类类别数 k 为 3, 并任意选取初始聚类中心点 $((-0.0023, -0.4913), (0.0198, 0.1235), (-0.0412, 0.1520))$, 经过多次迭代, 结果如图 1(b) 所示. 传统 k -means 算法和 SBKM 算法对数据集 X 聚类后的结果分别如图 1(c) 和 1(d) 所示.

图 1(a) 是原始生成数据的可视化图, 其中随机生成的三类数据有较多重叠部分. 图 1(b), (c), (d)

分别是用本文提出的 FGK-means 算法, 传统 k -means 算法及 SBKM 算法对原始生成数据进行聚类得到的结果. 由图可以发现, 本文算法相对另外两种算法可以较好地将三类数据分开.

4.2 实验二的结果比较与分析

实验 2: 我们采用 UCI 数据库上的 Iris 及 Statlog (vehicle silhouettes) 数据集作为待聚类样本, 分别采用传统 k -means 算法、SBKM 算法及本文提出的 FGK-means 算法进行聚类, 且为了消除样本选择的随机独立性, 独立重复进行 100 次实验, 取平均识别率作为最终识别率.

UCI 数据库是一个专门用于测试机器学习、数据挖掘算法的数据库, 库中的数据都有确定的分类, 可以直观表示聚类结果的质量. 其中, Iris 数据集取自 3 类鸢尾属植物的花朵样本, 共含 150 个数据, 每个数据有 4 维属性. Statlog 数据集取自 4 类交通工具轮廓样本, 共含 946 个数据, 每个数据有 18 维属性. UCI 数据集上的聚类识别率分别如图 2(a) 和图 2(b) 所示.

从图 2(a) 和 2(b) 可以看出, FGK-means 算法




图 1 随机数据和可视化结果

Fig. 1 Random data and the result of visualization




图 2 UCI 数据集上的聚类性能

Fig. 2 Clustering performance on the UCI dataset

的聚类性能明显优于传统 k -means 算法,且随着数据样本的增多,FGK-means 算法也比 SBKM 算法具有更好的识别精度.以上结果表明,引入 Finsler 度量后,能够提高算法的聚类性能.

4.3 实验三的结果比较与分析

实验 3:我们验证 FGK-means 算法在 ORL 人脸数据库上的实验效果. ORL 人脸数据库由剑桥大学 AT&T 实验室创建,包含 40 个不同的人,每个人有 10 幅人脸面部图像,分别在不同时间,不同光照条件,不同姿势表情的情况下拍摄得到的,每幅图像灰度级为 256,分辨率为 112×92 ,部分图像如图 3 所示.



图 3 ORL 人脸数据库部分图像

Fig. 3 Part of the images in ORL

实验中,我们从 ORL 人脸库中随机选取一定数量的样本作为输入数据集,大小从 120 变化到 320,且为了消除样本选择的随机独立性,我们独立重复进行 100 次实验,并取平均识别率作为最终识别率.图 4 给出了传统 k -means 算法,SBKM 算法以及本文提出的 FGK-means 算法在 ORL 人脸数据库上不同训练样本个数情况下的实验结果.

从图 4 可以看出,随着样本数据量的增加,3 个算法的识别率整体呈上升趋势,虽然本文提出的 FGK-means 算法未能保持稳定的聚类能力,但与传统 k -means 算法和 SBKM 算法相比较,本文提出的




图 4 ORL 人脸库上的聚类性能

Fig. 4 Clustering performance on the ORL face image sets

FGK-means 算法的聚类性能更优.

5 结论

本文针对 k -means 算法相似性度量、准则函数优化效果不理想及多维流形数据分析性能效果不好等不足,引入 Finsler 几何中度量形式不受二次式限制的 Finsler 度量,优化了 k -means 算法的相似性度量、准则函数及多维流形结构上分析数据的性能,提出了基于 Finsler 几何的 k -means 算法 (FGK-means),并在 UCI 数据集和 ORL 人脸数据库上与传统 k -means 算法及文献[5]中提出的 SBKM 算法进行了对比实验.实验结果表明,FGK-means 算法相较传统 k -means 算法及 SBKM 算法在 UCI 数据集和 ORL 人脸数据库上的聚类效果得到了有效的改进,但随着样本数据量的增加,FGK-means 算法未能保持稳定的聚类性能.因此如何选取更一般的 Finsler 度量函数,且充分运用 Finsler 几何的其他知识,将是我们下一步工作的重点.

参考文献(References)

- [1] MacQueen J B. Some methods for classification and analysis of multivariate observations[C]//Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability. London, UK: Cambridge University Press, 1967: 281-297.
- [2] Jain A K. Data clustering: 50 years beyond k -means [J]. Pattern Recognition Letters, 2010, 31(8): 651-666.
- [3] Kashima H, Hu J Y, Ray B, et al. k -means clustering of proportional data using L_1 distance[C]//Proceedings of the 19th International Conference on Pattern Recognition. Tampa, USA: IEEE Press, 2008: 1-4.
- [4] Banerjee A, Merugu S, Dhillon I S, et al. Clustering with Bregman divergences [J]. The Journal of Machine Learning Research, 2005, 6: 1 705-1 749.
- [5] Su M C, Chou C H. A modified version of the k -means algorithm with a distance based on cluster symmetry [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(6): 674-680.
- [6] Wang L, Bo L F, Jiao L C. A modified k -means clustering with a density-sensitive distance metric[C]//Proceedings of the First International Conference on Rough Sets and Knowledge Technology. Berlin Heidelberg: Springer, 2006: 544-551.
- [7] Liu C R, Hu T M, Ge Y, et al. Which distance metric is right: An evolutionary k -Means view [C]//Proceedings of the SIAM International Conference on Data Mining. Anaheim, USA: SIAM Press, 2012: 907-918.
- [8] Linde Y, Buzo A, Gray R M. An algorithm for vector quantizer design [J]. IEEE Transactions on Communications, 1980, 28(1): 84-95.
- [9] Mao J C, Jain A K. A self-organizing network for hyperellipsoidal clustering (HEC) [J]. IEEE Transactions on Neural Networks, 1996, 7(1): 16-29.
- [10] Yang F Z, Zhu Y Y. An efficient method for similarity search on quantitative transactions data [J]. Journal of Computer Research and Development, 2004, 41(2): 361-368.
杨凤召,朱扬勇.一种有效的量化交易数据相似性搜索方法[J].计算机研究与发展,2004,41(2):361-368.
- [11] Chen G Z, Cheng X Y, Yuan M G. On a class of projectively flat Finsler metrics with weakly isotropic flag curvature [J]. Periodica Mathematica Hungarica, 2013, 67(2): 155-166.
- [12] Matsumoto M. On Finsler spaces with Randers' metric and special forms of important tensors [J]. Journal of Mathematics of Kyoto University, 1974, 14(3): 477-498.
- [13] Cui N W, Shen Y B. Projective change between two classes of (α, β) -metrics [J]. Differential Geometry and its Applications, 2009, 27(4): 566-573.
- [14] Chern S S, Shen Z M. Riemann-Finsler Geometry [M]. Singapore: World Scientific, 2005.
- [15] 沈一兵,沈忠民.现代芬斯勒几何初步[M].北京:高等教育出版社,2013.
- [16] 陈省身,陈维桓.微分几何讲义[M].二版,北京:北京大学出版社,2001.
- [17] 李凡长,张莉,杨季文,等.李群机器学习[M].合肥:中国科学技术大学出版社,2013.
- [18] Machine Learning Repository [EB/OL]. <http://archive.ics.uci.edu/ml/datasets.html>.
- [19] <http://cs.nyu.edu/~roweis/data/olivettifaces.mat>.