

基于 GWO-DBSCAN 算法的 电商用户价值分类模型设计与实现

赵煜¹ 卢胜男¹

ZHAO Yu LU Shengnan

摘要

基于对电商平台用户画像中用户价值标签的现状了解,分析了以往电商平台常用的 K-means 聚类方法的不足之处,并在此基础上选取多个聚类方法进行横向对比,确定了 GWO-DBSCAN 聚类方法来处理电商用户行为数据。采用基于密度划分的 DBSCAN 聚类算法,针对 DBSCAN 算法聚类效果受扫描半径 ϵ 和最小包含点 $\minpts$ 影响较大的问题,利用灰狼优化算法的全局寻优特性对最佳扫描半径 ϵ 和最小包含点 $\minpts$ 求解,实现对电商用户群体更合理的聚类。通过实践检验发现,采取 GWO-DBSCAN 算法聚类的结果与使用其他聚类方法得到的结果相比,在用户分类的合理性方面有较明显的提升。

关键词

用户价值分析; 聚类算法; RFM 模型; 灰狼优化算法; DBSCAN 算法

doi: 10.3969/j.issn.1672-9528.2024.07.014

0 引言

伴随电商平台的繁荣发展,行业竞争也日趋白热化,为了在激烈的市场竞争中脱颖而出,科学评价客户价值并精准划分客户群体,进而指导制定营销策略,是赢得客户获取利润的重要手段。RFM 客户价值模型作为一种定量分析模型,在电商用户价值领域得到广泛应用,从业者通过对电商用户价值进行深入的研究,做了不同的改进。N. Manjushree 等人通过改进的 K-means,基于在线分析对产品的动态价格进行预测^[1];袁绮蕊^[2]通过 RFM 模型筛选典型的用户,从事实、模型和预测三个维度构建用户画像模型,并使用 K-means 对用户数据进行聚类分析;施文幸等人^[3]基于萤火虫 K-means 聚类的电力用户画像构建和应用;陈东清等人^[4]基于熵权法改进 RFM 模型,通过权重计算得分评价电商用户价值;徐翔斌等人^[5]基于电子商务行业,将总利润 P 引入 RFM 模型,得到了 RFP 模型,并使用 K-means 聚类算法对其顾客进行聚类,为电子商务行业提出了针对性营销策略;谢鹏寿等人^[6]根据汽车 4S 店客户的消费特征,提出了适用于汽车销售行业的 TFM 模型,并采用 K-means 算法对客户进行细分。

可以看出,原先的研究大多使用 K-means 聚类方法对模型进行聚类,但 K-means 存在对初始聚类中心选择敏感,不同初始选择会导致不同的聚类结果、需要预先确定簇数 K ,且 K 值的选取不易把握、对非凸形状类簇识别效果差、易受噪声、边缘点、孤立点影响等缺点,导致算法聚类效率不高。

目前许多研究都基于密度峰值的聚类基础上进行改进^[7],基于密度划分的 DBSCAN 算法可以解决上述的部分问题,但 DBSCAN 需要根据给出的数据集选择合适的参数:扫描半径 (ϵ) 和最小包含点 ($\minpts$),只有选择合适的参数,才能得到更好的聚类效果。灰狼优化算法作为一种新型的智能优化算法,受到灰狼捕食行为的启发,这类算法在优化问题中具有较高的求解精度和寻优能力,已被广泛应用在聚类算法中。孟涛等人^[8]将改进遗传算法和 DBSCAN 聚类相结合,刘成汉等人^[9]使用改进交叉算子后的自适应人工蜂群黏菌算法做研究。

针对以上问题,本文提出一种基于灰狼算法优化的 DBSCAN 聚类算法对用户价值分类。通过引入灰狼算法,优化 DBSCAN 聚类算法中的两个参数,并通过电商用户数据集来验证算法分类的有效性。

1 理论基础

1.1 DBSCAN 算法

DBSCAN (density-based special clustering of application with noise) 是一种基于密度的聚类算法,该算法不需要预先定义簇的个数,而是将高密度的区域划分为簇,并将其他区域视为噪声,这样就可以在有噪声的数据中发现任意形状的簇,对于有噪声(即孤立点或异常值)的数据集有很好的鲁棒性。DBSCAN 的基本概念包括两个算法参数,即扫描半径 (ϵ) 和最小包含点 ($\minpts$);三种类别的点,即核心点、边界点与噪声点;四种点的关系,即密度直达、密度可达、密

1. 西安石油大学 陕西西安 710065

度相连与非密度相连。

1.2 灰狼优化算法 (GWO)

灰狼算法 (grey wolf optimizer) 是 Seyedali Mirjalili 等人^[10]在 2014 年提出的一种基于自然界灰狼行为的启发式优化算法, 算法模拟了灰狼群体中不同等级灰狼间的社会等级制度和捕食行为, 通过不断搜索最优解来解决复杂问题。在算法中每一个灰狼个体的位置代表了解向量中的一个解, 种群中适应度最优的解、次优的解和第三优的解分别对应 α 狼、 β 狼和 δ 狼, 而其余的解被看作 ω 狼: α 狼具有最高领导地位; β 狼服从 α 狼的领导并引导其他的狼; δ 狼服从 α 狼和 β 狼的领导并负责保卫和侦察; ω 狼服从其他狼的领导。灰狼算法主要分为三个步骤: 包围猎物、狩猎和攻击猎物。

(1) 包围猎物, 狼群在搜索猎物时逐渐接近并包围, 具体数学模型为:

$$\bar{D} = |\bar{C} \cdot \bar{X}_p(t) - \bar{X}(t)| \quad (1)$$

$$\bar{X}(t+1) = \bar{X}_p(t) - \bar{A} \cdot \bar{D} \quad (2)$$

式中: $\bar{X}_p$ 为猎物的位置向量, $\bar{X}$ 为狼群的位置向量, $\bar{D}$ 为狼群距离猎物的长度, t 为当前算法迭代次数, 协同系数向量 $\bar{A}$ 、 $\bar{C}$ 定义如下:

$$\bar{A} = 2\bar{a} \cdot \bar{r}_1 - \bar{a} \quad (3)$$

$$\bar{C} = 2 \cdot \bar{r}_2 \quad (4)$$

$\bar{A}$ 用来模拟灰狼的攻击行为, 受收敛因子 $\bar{a}$ 的影响。 $\bar{a}$ 在整个迭代过程中, 由 2 减小到 0。

(2) 狩猎行为:

$$\begin{cases} \bar{D}_\alpha = |\bar{C}_1 \square \bar{X}_\alpha - \bar{X}| \\ \bar{D}_\beta = |\bar{C}_2 \square \bar{X}_\beta - \bar{X}| \\ \bar{D}_\delta = |\bar{C}_3 \square \bar{X}_\delta - \bar{X}| \end{cases} \quad (5)$$

上述是灰狼个体跟踪猎物位置的数学模型, $\bar{D}_\alpha$ 、 $\bar{D}_\beta$ 和 $\bar{D}_\delta$ 分别为 α 狼、 β 狼和 δ 狼与其他个体之间的距离; $\bar{X}_\alpha$ 、 $\bar{X}_\beta$ 和 $\bar{X}_\delta$ 分别是 α 狼、 β 狼和 δ 狼的当前最优位置。当 $|\bar{A}| < 1$ 时, 狼群集体更新位置:

$$\begin{cases} \bar{X}_1 = \bar{X}_\alpha - \bar{A}_1 \cdot \bar{D}_\alpha \\ \bar{X}_2 = \bar{X}_\beta - \bar{A}_2 \cdot \bar{D}_\beta \\ \bar{X}_3 = \bar{X}_\delta - \bar{A}_3 \cdot \bar{D}_\delta \end{cases} \quad (6)$$

$$\bar{X}(t+1) = \frac{\bar{X}_1 + \bar{X}_2 + \bar{X}_3}{3} \quad (7)$$

式 (6) 为 ω 狼在 α 狼、 β 狼和 δ 狼的分别领导下更新后的位置, 其中的 $\bar{A}_1$ 、 $\bar{A}_2$ 和 $\bar{A}_3$ 是根据式 (3) 计算得到的系数向量, 式 (7) 为 ω 狼最后确定的位置。

(3) 攻击猎物

$$a = 2 \left(1 - \frac{t}{T} \right) \quad (8)$$

式中: t 表示当前迭代次数, T 为人为设定的最大迭代次数, 在迭代过程中, a 值线性逐渐减小, 其对应 $\bar{A}$ 的值也会在区间 $[-a, a]$ 变化; a 值越小表示灰狼越靠近猎物, 当 $|\bar{A}| < 1$ 算法完成收敛, 获取猎物位置。本文选用灰狼算法来选取最佳的扫描半径 eps 与最小包含点 minpts 。

1.3 GWO-DBSCAN 聚类算法

本文结合 GWO 灰狼优化算法对 DBSCAN 算法进行改进, 以 silhouette 指标为目标函数, 通过 GWO 算法对 DBSCAN 中的扫描半径与最小包含点进行优化, 通过多次迭代寻优, 找到使 silhouette 取值最大时的 eps 和 minpts 。改进后算法具体流程如下。




图 1 GWO-DBSCAN 聚类算法流程

步骤 1: 计算用户数据样本之间的欧氏距离, 对比每个样本与其最近 / 最近邻居之间的平均距离 d , 选取合适的 eps 和 minpts 的取值范围: $[\text{eps_min}, \text{minpts_min}]$ 和 $[\text{eps_max}, \text{minpts_max}]$ 。

步骤 2: 设计 GWO 算法的最大迭代次数 T , 种群规模 M , 初始向量值, 即 eps 与 minpts 组成的集合。

步骤 3: 根据种群规模 M 和 eps 、 minpts 的取值范围, 随机生成初始解集合 $\{[\text{eps}_1, \text{minpts}_1], [\text{eps}_2, \text{minpts}_2] \dots\}$ 。

步骤4: 将初始解集合中的元素依次代入 DBSCAN 算法中, 对原始用户数据集进行聚类, 计算并存储每次聚类结果的 silhouette 指标。

步骤5: 对初始解集合与对应的 silhouette 值按照升序排序, 得到初始解集合中的最优的前三个解和最优的前三个 silhouette 值。

步骤6: 计算系数向量的参数 a , 利用式 (6) 对初始解集合中的每个元素进行位置更新, 并重新代入 DBSCAN 算法中对数据集进行聚类, 计算 silhouette 值。

步骤7: 判断是否到达 GWO 算法的最大迭代次数 T , 若满足, 结束迭代并执行步骤8; 若不满足, 执行步骤5继续寻优过程。

步骤8: 将得到的最优解 eps 和 minpts 代入 DBSCAN 算法中, 得到最终聚类结果。

2 实验结果与分析

2.1 数据集选取及数据预处理

为验证改进算法在聚类电商用户价值的合理、可靠性, 本课题采用 RFM 模型中的三个指标作为实验输入数据。RFM 模型是常用于衡量客户价值的数学模型。该模型主要是通过分析最近一次购买时间 (recency)、消费频率 (frequency) 和消费金额 (monetary) 3 个角度, 对客户进行细分, 进而来确定客户价值的。因此, RFM 模型在电商平台得到了比较广泛的应用。

选取的数据集为 kaggle 上的某电商脱敏后的用户行为数据集。该数据集包括用户 ID、性别、住址、订单日期、购买商品品类、购买商品数量等信息, 通过对数据集预处理, 得到 RFM 模型中近一次购买时间、消费频率和消费金额这三个数据。

2.2 评价指标

本文的实验结果评价指标为: 轮廓系数 (silhouette coefficient)、Calinski-Harabasz index (CH)、戴维森堡丁指数 (Davies-bouldin index, DBI)。轮廓系数和 CH 指标的计算方法为:

$$s = \frac{b - a}{\text{Max}(a, b)} \quad (9)$$

$$\text{SC} = \frac{\sum_{i=1}^N s_i}{N} \quad (10)$$

$$\text{CH} = \frac{\text{tr}(B_k)(N - K)}{\text{tr}(W_k)(K - 1)} \quad (11)$$

$$\begin{cases} B_k = \sum_{q=1}^k n_q (c_q - c_e)(c_q - c_e)^T \\ W_k = \sum_{q=1}^k \sum_{x \in C_q} (x - c_q)(x - c_q)^T \end{cases} \quad (12)$$

式 (9) 中, s 表示某个样本的轮廓系数, a 表示某个样本与其所在簇内其他样本的平均距离, b 表示某个样本与其他簇样本的平均距离; 式 (10) 中 SC 为聚类总的轮廓系数; 式 (12) 中 B_k 为类间的协方差矩阵, W_k 为类内数据的协方差矩阵, c_q 表示类 q 的中心点, c_e 表示数据集的中心点, n_q 表示类 q 中数据的数目, C_q 表示类 q 的数据集合。

2.3 实验结果分析

为验证改进后算法的有效性, 分别使用 K-means 算法、FCM 算法、OPTICS 算法、DBSCAN 算法和 GWO-DBSCAN 算法对给出的电商用户行为数据集进行聚类, 并对结果作对比。

表 1 是通过 3 种内部聚类指标, 对 5 种不同聚类算法的结果作比较。可以看出, GWO-DBSCAN 算法在轮廓系数上对比其他的聚类算法, 分别提高了 0.014 5、0.096、0.075 8、0.014 5; 在 DBI 值上对比其他聚类算法, 分别降低了 0.024 6、0.026 5、0.121 7、0.024 6; 在 CH 值上对比其他的聚类算法最高。这说明本文提出的改进后的算法聚类更合理, 簇间距离更大, 簇内样本更紧密, 更少出现交叉重叠现象。

表 1 对比实验结果

	Kmeans	FCM	OPTICS	DBSCAN	GWO-DBSCAN
聚类中心数	4	3	4	4	4
轮廓系数	0.816 0	0.734 5	0.754 6	0.816 0	0.830 5
CH 值	7 223.637 0	1 376.943 1	2 261.449 3	7 223.637 0	12 844.375 2
DBI 值	0.257 9	0.259 8	0.355 0	0.257 9	0.233 3

表 2 为采用 GWO-DBSCAN 聚类算法得到的聚类结果, 并展示了每个类别中各自的 RFM 指标均值和该类别的用户质量; 根据聚类结果来看, 该数据集的用户分为 4 类。

表 2 GWO-DBSCAN 聚类结果

	R 均值	F 均值	M 均值	占比	用户质量
类别 1	31.6	3	473.4	0.33	低
类别 2	45.5	4	690.0	0.17	中
类别 3	24.6	5	1 165.2	0.17	高
类别 4	15.3	4	805.4	0.17	中高

类别 3 为高价值用户群体, 这类用户的特点是消费金额最多, 购物频率最高, 最后一次上线的时间也较短, 这类用户是电商用户中需要维持和发展的客户。

类别 4 的用户为中高价值用户群体, 消费金额仅次于高质量用户群体, 最后一次购买时间最近, 消费频率也很高,

此类用户是企业重点保持但不必大力发展的用户。

类别 2 为中等质量用户群体,潜在价值高,此类用户的特点是最后一次购买时间久,但消费金额和消费频率不算太低,是企业大力发展且需要不断维护防止流失的用户。

类别 1 是低价值客户群体,其购买频率和消费金额都是最低的,总的来说是电商用户中具有一定价值但需企业取舍的客户。

图 2 为采用 GWO-DBSCAN 聚类算法聚类,并排除异常用户数据后各类别用户所占比重,图 3 为各类用户总花费占比,其中高质量的用户占比最少,但消费金额最多,分别为 19.9% 和 32.5%;中等价值的用户和中高价值用户占比接近,且花费相当,差不多为 20%,低价值用户虽然消费金额不是最低的,但人数上占比最多,多达 39.7%。可以看出,改进后聚类算法的聚类结果很符合帕累托法则(Pareto's principle):高价值的用户占总人数的 20%。这表明改进后算法在聚类电商用户的合理性表现优异。




图 2 各用户价值人数占比图




图 3 各类用户总花费占比

3 结语

针对传统 K-means 方法根据 RFM 模型对电商用户进行聚类时需要提前确定用户类别数、容易受到异常点影响等问题,本文提出一种基于灰狼算法优化的 GWO-DBSCAN

聚类算法。针对 DBSCAN 聚类算法的两个重要参数进行优化,使用聚类内部评价指标 silhouette 作为目标函数,利用灰狼优化算法寻找两个参数的全局最优解。通过在数据集上进行实验,验证了改进算法有效提高了聚类结果的质量,可以为后续开发人员制定电商用户画像标签提供可靠的依据和参考。

参考文献:

- [1]MANJUSHREE N, BHAVANA N.Predicting dynamic product price by online analysis:modified k-means cluster[J].Advances in intelligent systems and computing,2020,1120:1-15.
- [2]袁绮蕊.基于 K-MEANS 的在线健康社区用户画像模型构建[J].科技情报研究,2021,3(4):95-106.
- [3]施文幸,曹诗韵.基于萤火虫 K-means 聚类的电力用户画像构建和应用[J].计算机系统应用,2021,30(8):281-287.
- [4]陈东清,叶翀,黄章树.基于熵权法改进 RFM 模型的电商客户价值细分研究[J].西安电子科技大学学报(社会科学版),2020,30(2):39-45.
- [5]徐翔斌,王佳强,涂欢,等.基于改进 RFM 模型的电子商务客户细分[J].计算机应用,2012,32(5):1439-1442.
- [6]谢鹏寿,张宽,范宏进,等.汽车 4S 店 TFM 客户细分模型及其方法研究[J].小型微型计算机系统,2019,40(10):2165-2169.
- [7]DU M, DING S, JIA H.Study on density peaks clustering based on k-nearest neighbors and principal component analysis[J].Knowledge-based systems,2016,99(May 1):135-145.
- [8]孟涛,王晓勇,胡胜利.基于改进遗传算法和 DBSCAN 聚类的学习数据深度挖掘方法[J].齐齐哈尔大学学报(自然科学版),2024(1):1-7.
- [9]刘成汉,何庆.改进交叉算子的自适应人工蜂群黏菌算法[J].小型微型计算机系统,2023,44(2):263-268.
- [10]MIRJALILI S, MIRJALILI S M, LEWIS A.Grey wolf optimizer[J].Advances in engineering software, 2014, 69: 46-61.

【作者简介】

赵煜(1997—),男,陕西西安人,硕士研究生,研究方向:机器学习、大数据技术与应用。

卢胜男(1982—),女,江苏徐州人,博士,副教授,硕士生导师,研究方向:图像处理及机器学习、大数据技术应用。

(收稿日期:2024-05-11)