

王聪, 杨海根. 面向连续-离散混合数据分类的强化学习表征方法[J]. 智能计算机与应用, 2025, 15(1): 117-122. DOI: 10.20169/j. issn. 2095-2163. 250118

面向连续-离散混合数据分类的强化学习表征方法

王聪, 杨海根

(南京邮电大学 通信与信息工程学院, 南京 210000)

摘要: 人工智能技术的快速发展引爆了大数据时代, 由此而产生了各类型数据, 数据驱动着机器学习的发展, 机器学习的性能也依赖表征模型对这类数据的表征结果, 而传统的数据表征算法并不能使这类数据获得最佳区分性。为解决上述问题, 本文在表征算法的基础上引入强化学习, 以聚类评价指标作为奖励, 获得最佳区分性的表征数据, 并将其用于分类任务中。实验结果表明本文提出的强化学习表征方法相较于传统表征方法在机器学习分类任务上能取得更好的效果。

关键词: 机器学习; 数据表征; 强化学习

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)01-0117-06

Reinforcement learning representation method for continuous-categorical mixed data classification

WANG Cong, YANG Haigen

(School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210000, China)

Abstract: The rapid development of artificial intelligence technology has detonated the era of big data, resulting in various types of data, data drives the development of machine learning, and the performance of machine learning also depends on the representation of such data by the representation model, while the traditional representation algorithm can not make the best distinction of such data. In order to solve the above problems, this paper introduces reinforcement learning on the basis of the representation algorithm, takes the clustering evaluation index as the reward, obtains the best distinguishing representation data, and applies it to the classification task. Experimental results show that the proposed reinforcement learning representation method can achieve better results in machine learning classification tasks than traditional representation methods.

Key words: machine learning; data representation; reinforcement learning

0 引言

人工智能的发展日新月异, 带来了数据爆发式的增长, 也催生了智能时代的到来。作为推动发展和变革的基础, 数据不仅仅驱动着机器学习的发展, 也考验着现存机器学习算法的学习能力^[1]。传统的机器学习算法大多数是针对结构化数据, 如监督学习中的决策树, 朴素贝叶斯, 无监督学习的 k-means 聚类等, 而现有的数据大都是复杂异构的, 需要对这类数据进行表征处理, 转化为传统机器学习算法能够处理的数据类型^[2]。数据表征是指将数据对象中抽象的特征数据化的过程, 是数据处理的

优先步骤, 也是机器学习与数据之间的桥梁。通过对数据进行表征学习, 使得复杂异构的原始数据化繁为简, 将原始数据的表达提炼的更好, 让机器学习算法在数据表征的基础上进行分类、回归、优化、预测等操作事半功倍。

数据表征结果的好坏很大程度上会影响机器学习的学习性能, 在复杂异构的数据上通过表征处理的方法来消除数据之间的特征耦合关系表现出了数据表征的必要性和优势^[3]。对于结构化的属性数据, 通常将其分为连续数据、离散数据和由连续数据与离散数据组成的混合数据。连续数据本身属于表征处理过的数据, 不再需要进行表征处理, 但是可以

基金项目: 国家重点研发计划(2021YFB3300300)。

通信作者: 杨海根(1983—), 男, 博士, 教授, 博士生导师, 主要研究方向: 人工智能, 数据智能, 工业软件。Email: yhg@njupt.edu.cn。

收稿日期: 2023-07-23

对这类数据进行特征维度优化。针对具有离散特征的离散数据,数据编码是较为常见的一种表征方式,其中最常见的是将离散数据的离散特征编码成矩阵的独热编码,但是使用这种编码方式会使表征后数据的维度有一定的增加,可能会引起维度灾难^[4]。另外一种常见的编码方式是 IDF (Inverse Document Frequency) 编码,这种编码方式从频率的角度捕获数据的特性,表征数据对象中每个特征值频率倒数的 Log 值^[5]。上述数据编码方式操作较为简单,但不能获得数据对象特征值耦合关系。针对离散数据的表征方法还可以利用数据对象的相似度矩阵,如 AHMAD A 等^[6]提出在特征值的条件概率中通过学习其相似度来表征数据特征值的耦合关系;WANG C 等^[7]在此基础上还考虑了数据特征内外的耦合关系;而 JIAN S 等^[8]提出的无监督耦合类别数据表示 CURE 框架则是通过捕获特征之间不同层次的特征值耦合关系来表征数据。对于由连续数据和离散数据组合而成的混合数据来说,目前都是通过数据转化来构建表征处理模型,例如 DAVID G 等^[9]提出的数值和名义数据的分类谱聚类方法 (spectralCAT), 通过对其连续特征使用聚类等手段进行离散化来构造新的离散特征,但不能考虑不同类型的数据;WANG C^[7]使用了与 spectralCAT 相同的方法来离散化数据的连续特征,通过使用离散变量的相似度来表示离散特征,然后通过计算数据特征之间的人

数相关系数来断定特征之间的相关性,但是转化过程中存在一定的信息丢失,所以这种处理方式也存在着瑕疵。JIAN S^[10]提出的 Metric-based Auto-Instructor 模型 (MAI) 为两个交互式的编码模块构建混合数据表征模型,通过两个编码结构块相互学习,进而得到区分性更强的混合数据的表征,但是这类方法参数学习时间长,且不容易获得最优效果。机器学习领域中的强化学习是近些年来一个热点研究方向,其基本思想是通过最大化决策实体从环境中获得的奖励,以学习到完成目标的最优策略,应用于数据表征模型时可实现对表征的优化^[11]。

针对上述研究,本文结合了强化学习和编码方式数据表征方法,提出了一种基于强化学习的混合数据表征方法,将强化学习中的学习能力与决策能力应用于数据表征的过程中,通过训练学习,得到最具有区分性的表征数据。

1 本文算法

本文提出一种基于强化学习的混合数据表征算法,算法的总体框架图如图 1 所示。先将目标数据划分为离散数据与连续数据;建立数据的编码层与表征层,并将其视作强化学习中的决策实体,应用聚类评价指标作为奖励,当奖励最大化时,获得最佳区分性的表征数据。

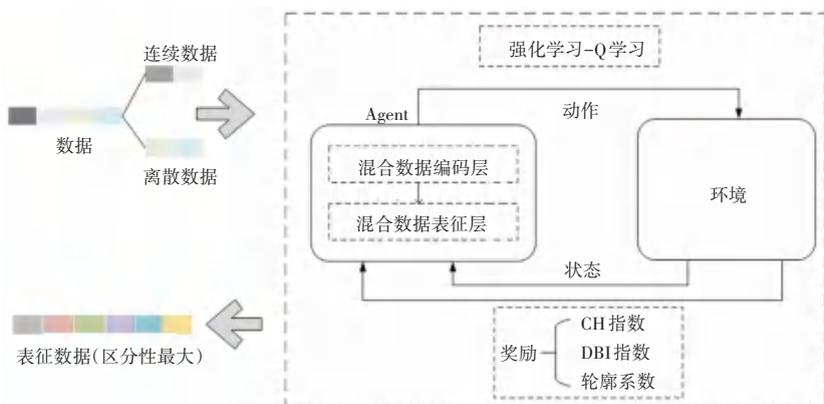


图 1 表征算法框架图

Fig. 1 Representation algorithm framework diagram

1.1 混合数据编码层

将目标数据划分为连续数据与离散数据,通过计算数据的联合概率密度来量化离散特征与连续特征之间的交互关系。连续数据变量 A_i 的连续特征值记为 a_i^x , 离散数据变量 V_j 的离散特征值记为 v_j ,

计算数据的联合密度:

$$p(a_i^x, v_j) = \frac{1}{n} \sum_{k=1}^n \left\{ L_\lambda(v_j^k, v_j) W\left(\frac{a_i^k - a_i^x}{h_i}\right) \right\} \quad (1)$$

其中, n 为数据对象个数; $W\left(\frac{a_i^k - a_i^x}{h_i}\right)$ 为连

续数据特征的核函数; h_i 为带宽参数,属于连续变量。

通常使用高斯核函数作为连续变量的核函数,表示如下:

$$K_h(z) = \frac{1}{\sqrt{2\pi}h} \exp\left(-\frac{z^2}{2}\right) \quad (2)$$

带宽根据标准非参统计估计^[12]。

$L_\lambda(v_j^k, v_j)$ 是离散变量核函数,设定如下^[13]:

$$L_\lambda(v_j^k, v_j) = \begin{cases} 1, & \text{if } v_j^k = v_j \\ \lambda, & \text{other} \end{cases} \quad (3)$$

其中, $\lambda \ll 1$ 是离散变量的带宽。

当计算出数据的离散变量与数据的连续变量的密度估计,此时可以根据密度估计定义数据对象 x 的耦合编码矩阵 \mathbf{M}_x , 其表达式如下:

$$\mathbf{M}_x = \begin{vmatrix} r(a_1^x, v_1) & \cdots & r(a_1^x, v_L) \\ \vdots & \ddots & \vdots \\ r(a_n^x, v_1) & \cdots & r(a_n^x, v_L) \end{vmatrix} \quad (4)$$

其中, $r(a_i^x, v_j)$ 由数据对象的联合概率密度推导得到,表明数据的连续变量和数据的离散变量之间的交互关系,定义如下:

$$r(a_i^x, v_j) = \begin{cases} a_i^x, & \text{if } p(a_i^x, v_j) \geq \tau \\ \lambda a_i^x, & \text{other} \end{cases} \quad (5)$$

其中, τ 为阈值参数, $0 < \lambda < 1$ 为比例系数。

式(4)中的耦合编码矩阵体现出数据的离散特征与数据的连续特征之间的异构耦合关系,其中每个数据由一个耦合编码矩阵 \mathbf{M}_x 表示,所以可将数据量化为向量 \mathbf{f} 。

1.2 混合数据表征层

数据经过编码层后获得的特征相互独立,互不相关。为了捕获数据特征之间的耦合关系,可将编码后的向量 \mathbf{f} 通过一个全连接网络转换为表征向量 \mathbf{h} , 公式如下:

$$\mathbf{h} = \sigma(\mathbf{f}, \mathbf{W}) \quad (6)$$

其中,权重矩阵 $\mathbf{W} \in R$ 包含所有特征之间的交互强度, σ 为 logistic 函数,定义如下:

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (7)$$

通过全连接网络,特征向量映射成了新的表征向量,但是此时的表征向量仅仅捕获了特征层面的耦合关系,为了增强表征向量的区分性,引入强化学习实现对表征的优化。

1.3 Q 学习

Q 学习是强化学习算法的一种,其学习方法与

Markov 决策过程一致^[14-15]。在这一过程中,Agent 依照策略执行动作列表中的任一动作。 t 时刻,将环境状态记为 s_t , Agent 执行动作 a_t , 环境状态则由 s_t 变为 s_{t+1} , 同时反馈奖励 $R(s_t, a_t)$ 给 Agent, 反复以上步骤直到训练学习完成。Q 学习算法中,用估计函数 $Q(s_t, a_t)$ 来表示 Agent 在状态 s_t 下选择动作 a_t 后所得到的最大累计奖励, $Q(s_t, a_t)$ 公式如下:

$$Q(s_t, a_t) = R(s_t, a_t) + \gamma \max Q(s_{t+1}, a_{t+1}) \quad (8)$$

其中, a 为动作列表中任一动作, $\gamma (0 \leq \gamma \leq 1)$ 为折扣系数。

为了使 Q 学习在适当时刻收敛,引入学习率,更新后的 $Q(s_t, a_t)$ 表示如下:

$$Q(s_t, a_t) = (1 - \alpha)Q(s_t, a_t) + \alpha R(s_t, a_t) + \gamma \max Q(s_{t+1}, a_{t+1}) \quad (9)$$

其中, $\alpha (0 \leq \alpha \leq 1)$ 为算法收敛的学习率。

1.4 动态奖励

根据不同场景的需要,将不同维度的聚类评价指标通过权重系数来调节并进行加权作为动态奖励,动态奖励信息 R :

$$R = \sum_{i=1}^n \alpha_i r_i \quad (10)$$

其中, $\alpha_i (0 \leq \alpha_i \leq 1)$ 为参数, r_i 为不同维度的聚类评价指标。

1.4.1 CH 指数

CH (Calinski-Harabasz) 指数的实质是以聚类间的平方和聚类内平均值为基础来评估聚类的有效性^[16], 指标公式如下:

$$CH = \frac{\sum_i n_i d^2(c_i, c)}{(NC - 1)} \quad (11)$$

$$\sum_i \sum_{x \in c_i} \frac{d^2(x, c_i)}{(NC - 1)}$$

其中, c_i 指第 i 个类别; n_i 指 c_i 中数据的个数; $d(x, y)$ 指数据对象 x 和 y 之间的距离。

CH 指数越大,其聚类效果越好。

1.4.2 DBI 指数

DBI (Davies-Boulding) 指数是对每一个簇类 i 计算与其他类的最大相似度,取所有类的最大相似度的均值^[17], 指标公式如下:

$$DBI = \frac{1}{n} \sum_{i=1}^n \max_{j \neq i} \left(\frac{\bar{S}_i - \bar{S}_j}{\|w_i - w_j\|_2} \right) \quad (12)$$

其中, \bar{S}_i 为第 i 类数据到其类中心的平均欧氏距离, $\|w_i - w_j\|_2$ 为第 i 类和第 j 类的类中心欧氏距

离。

DBI 指数越小,其类内距离越小,同时类间距离越大。

1.4.3 轮廓系数

轮廓系数(Silhouette Coefficient)是聚类效果的一种评价方式^[18]。最佳值为1,最差值为-1,接近0的值表示重叠的群集,指标公式如下:

$$S(i) = \frac{b(j) - a(i)}{\max[a(i), b(j)]} \quad (13)$$

其中, i 和 j 表示不同的类内样本点, $a(i)$ 表示样本点与同一簇中其他点的相似度,公式如下式, $b(j)$ 表示样本与下一个最近簇中其他点的相似度,计算方式与 $a(i)$ 相似, $distance$ 代表 i 与 j 的距离。

$$a(i) = \frac{1}{n-1} \sum_{i \neq j} distance(i, j) \quad (14)$$

本文算法如下:

算法1 基于 Q 学习的混合数据表征学习算法
输入 混合数据集 X ,

输出 最佳区分性的表征数据集 M

1 初始化表征数据集为 ϕ , 初始化 Q 表, 初始化当前状态 s , 初始化重放缓冲区 D

2 构建混合数据编码层与表征层, 记为动作 a

3 for 每次迭代 do

4 for $t = 1$, 最大时间步数 do

5 观察环境状态 s_t , 根据策略选定动作 a_t , 观察执行后的环境状态 s_{t+1}

6 $Q(s_t, a_t) = (1 - \alpha)Q(s_t, a_t) + \alpha R(s_t, a_t) + \gamma \max_{a'} Q(s_{t+1}, a')$

7 根据公式(8)计算奖励值 $R(s_t, a_t)$

8 更新重放缓冲区 $D = (s_t, a_t, R(s_t, a_t), s_{t+1})$

9 结束 for 循环

10 结束 for 循环

2 实验数据集描述

UCI Machine Learning Repository 公开数据集是机器学习算法领域的权威数据集之一。本文选用了其中3个数据集用于完成分类任务实验,其中包含全离散特征的 Soybean (Large) 数据集,全连续特征的 Glass Identification 数据集和离散与连续特征都包含的 Steel Plates Faults 数据集,数据集的具体信息见表1。

表1 实验数据集描述

数据集	样本数量	特征数量	离散特征	连续特征
Glass Identification	214	9	0	9
Soybean(Large)	307	35	35	0
Steel Plates Faults	1 941	27	15	12

2.1 对照试验设置

为了验证本文提出的基于强化学习的混合数据表征算法的有效性,对原始数据,MAI 模型表征数据与本文算法表征后的数据进行机器学习分类,选择支持向量机(SVM),随机森林(RF),径向基函数(RBF)这3个经典分类器进行对比,通过比较分类准确率来判定。为了更好的说明实验结果的客观性,对照实验的分类器参数设置不变。

2.2 评估方法

对于分类任务,通常以准确率(Accuracy)来衡量任务性能。准确率是评估算法正确检测能力的一个重要指标,公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FN + FP} \quad (15)$$

其中, TP 为正确预测的样本数; FN 为被预测成其他类别的样本数; TN 为正确预测其他样本为其它类别的样本数; FP 为被错误预测的样本数。

2.3 实验结果与分析

在设定的基础上,分别在 Glass Identification, Soybean(Large), Steel Plates Faults 数据集上进行10次实验,最终实验结果取平均值,3个数据集在不同条件下的分类准确率见表2~表4。

表2 原始数据准确率

分类器	数据集		
	SVM	RF	RBF
Glass Identification	70.2	82.4	73.6
Soybean(Large)	88.1	76.4	80.3
Steel Plates Faults	67.4	74.8	80.6

表3 MAI 模型表征数据准确率

分类器	数据集		
	SVM	RF	RBF
Glass Identification	72.3	83.5	73.9
Soybean(Large)	89.5	78.1	81.3
Steel Plates Faults	71.2	78.8	82.6

表 4 本文算法表征数据准确率

Table 4 Our method representation data accuracy %

分类器	数据集		
	SVM	RF	RBF
Class Identification	73.2	84.3	75.1
Soybean(Large)	90.1	78.3	81.8
Steel Plates Faults	86.3	85.5	86.6

Class Identification 对照实验结果如图 2 所示, Class Identification 数据集经过表征处理后, 分类准确率得到小幅度提升, 本文提出的基于强化学习的混合数据表征方法相较于 MAI 表征模型处理这类数据具有微弱的优势。

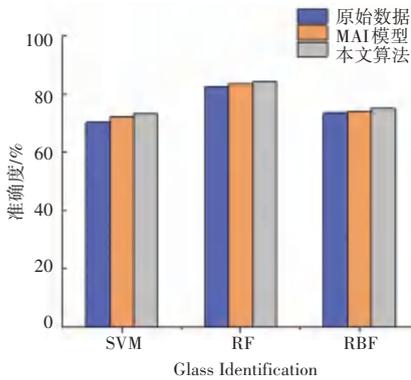


图 2 Class Identification 对照实验图

Fig. 2 Class Identification control test diagram

Soybean (Large) 对照实验结果如图 3 所示, Soybean(Large) 数据集经过表征处理后, 分类准确率得到小幅度提升, 本文提出的基于强化学习的混合数据表征方法相较于 MAI 表征模型处理这类数据具有一定的优势。

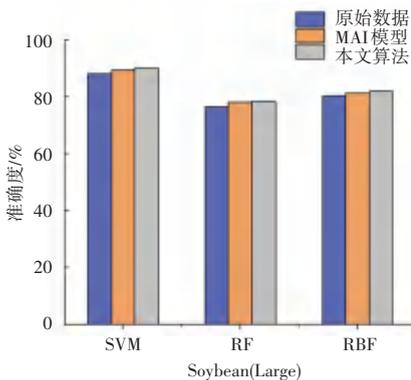


图 3 Soybean(Large) 对照实验图

Fig. 3 Soybean(Large) control test diagram

Steel Plates Faults 对照实验结果如图 4 所示。针对 Steel Plates Faults 这类包含连续特征与离散特

征的混合数据集, 经过表征处理后分类准确率有着较大的提升, 本文提出的表征算法相较于 MAI 表征模型有着明显的优势, 能显著改善对表征的优化。

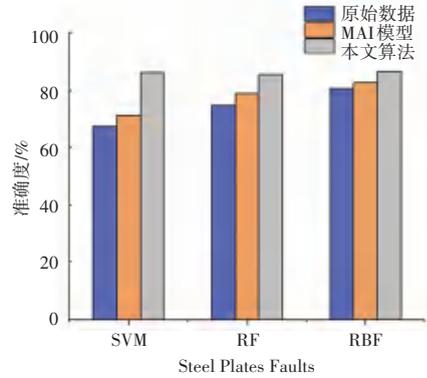


图 4 Steel Plates Faults 对照实验图

Fig. 4 Steel Plates Faults control test diagram

3 结束语

现有的机器学习算法过于依赖数据的表征处理, 且目前现存的数据表征模型无法获得最佳的特征区分度, 为此本文提出一种基于强化学习的混合数据表征算法。该方法在混合数据编码层与表征层的基础上引入了强化学习, 通过 Agent 训练学习, 自主决策获得最具有区分度的表征数据集, 并且将不同维度的聚类评价指标的加权作为动态奖励, 自主决策出不同场景下最具有区分度的表征数据。本文提出的表征算法处理后的数据应用于分类任务时能明显提升任务效果。本算法在公开的 3 个 UCI 数据集上进行实验, 通过对照试验可知使用本文的算法均能得到较好的实验结果。后期考虑将算法应用超大规模的数据集, 丰富其实用背景。

参考文献

- [1] 蹇松雷, 卢凯. 复杂异构数据的表征学习综述[J]. 计算机科学, 2020, 47(2): 1-9.
- [2] SUN S, SHI H, WU Y. A survey of multi-source domain adaptation[J]. Information Fusion, 2015, 24: 84-92.
- [3] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: A review and new perspectives[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8): 1798-1828.
- [4] BENGIO Y, LECUN Y. Scaling learning algorithms towards AI[J]. Large-scale Kernel Machines, 2007, 34(5): 1-41.
- [5] AIZAWA A. An information-theoretic perspective of TF-IDF measure[J]. Information Processing & Management, 2003, 39(1): 46-65.
- [6] AHMAD A, DEY L. A method to compute distance between two categorical values of same attribute in unsupervised learning for

- categorical data set [J]. *Pattern Recognition Letters*, 2007, 28(1):110-118.
- [7] WANG C, CHI C H, ZHOU W, et al. Coupled interdependent attribute analysis on mixed data[C] // *Proceedings of 29th AAAI Conference on Artificial Intelligence*. AAAI, 2015:1861-1967
- [8] JIAN S, PANG G, CAO L, et al. CURE: Flexible categorical data representation by hierarchical coupling learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 31(5):853-866.
- [9] DAVID G, AVERBUCH A. SpectralCAT: Categorical spectral clustering of numerical and nominal data[J]. *Pattern Recognition*, 2012, 45(1):416-433.
- [10] JIAN S, HU L, CAO L, et al. Metric-based auto-instructor for learning mixed data representation[C] // *Proceedings of Thirty-Second AAAI Conference on Artificial Intelligence*. AAAI, 2018:3318-3325.
- [11] 于飞, 郝建国, 张中杰. 基于动作概率的强化学习动作探索策略[J]. *计算机应用与软件*, 2023, 40(5):184-189.
- [12] LI Q, RACINE J S. Nonparametric estimation of conditional CDF and quantile functions with mixed categorical and continuous data [J]. *Journal of Business & Economic Statistics*, 2008, 26(4):423-434.
- [13] AITCHISON J, AITKEN C G. Multivariate binary discrimination by the kernel method[J]. *Biometrika*, 1976, 63(3):413-420.
- [14] WATKINS P, DAYAN. Q-learning [J]. *Machine Learning*, 1992, 8(3):279-292.
- [15] TSITSIKLIS, JOHN N. Asynchronous stochastic approximation and Q-learning[J]. *Machine Learning*, 1994, 16(3):185-202.
- [16] CALINSKI T, HARABASZ J. A dendrite method for cluster analysis[J]. *Communications in Statistics-theory and Methods*, 1974, 3(1):1-27.
- [17] DAVIES D L, BOULDIN D W. Cluster separation measure[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1979, 1(2):224-227.
- [18] 孙林, 刘梦含, 徐久成. 基于优化初始聚类中心和轮廓系数的K-means 聚类算法[J]. *模糊系统与数学*, 2022, 36(1):47-65.