

文章编号: 2095-2163(2023)05-0023-09

中图分类号: TP181

文献标志码: A

基于 GA-DBN 模型的分类方法研究

师 展, 安艾芝, 樊重俊, 秦小晖

(上海理工大学 管理学院, 上海 200093)

摘要: 本文采用多层受限玻尔兹曼机和 BP 神经网络构成的深度置信网络作为分类模型, 并采用遗传算法对深度置信网络中的受限玻尔兹曼机的参数进行逐层寻优, 从而构建了 GA-DBN 分类模型。通过与随机森林、人工神经网络、支持向量机和 XGBoost 分类模型进行对比实验发现, 构建的 GA-DBN 模型在分类准确度和 F_1 值上均有较好的表现。为验证遗传算法对 DBN 模型的优化效果, 将人工蜂群算法优化的 DBN 模型即 ABC-DBN 模型与 GA-DBN 模型进行对比实验发现, GA-DBN 模型在准确率、 F_1 值和运行时间上均表现出良好的效果, 说明遗传算法对 DBN 模型的优化效果更突出。

关键词: 遗传算法; 多层受限玻尔兹曼机; BP 神经网络; 深度置信网络

Research on classification method based on GA-DBN model

SHI Zhan, AN Aizhi, FAN Chongjun, QIN Xiaohui

(School of Business, University of Shanghai for Science and Technology, Shanghai 200093, China)

[Abstract] In this paper, Deep Belief Networks (DBN) composed of Restricted Boltzmann Machine (RBM) and BP neural network were adopted as classification model. The GA-DBN classification model is constructed by using Genetic Algorithm (GA) to optimize the parameters of constrained Boltzmann machine in deep confidence network layer by layer. By comparing with random forest, artificial neural network, support vector machine and XGBoost classification model, it is found that the classification accuracy and F_1 value of GA-DBN model are better. In order to verify the optimization effect of genetic algorithm on DBN model, the DBN model optimized by Artificial Bee Colony algorithm (ABC), namely ABC-DBN model and GA-DBN model, was compared and tested. GA-DBN model shows good results in accuracy, F_1 value and running time, which verifies that genetic algorithm is more effective in optimizing DBN model.

[Key words] genetic algorithms; multilayer restricted boltzmann machine; BP neural networks; deep confidence

0 引言

分类问题属于数据挖掘的重要任务之一, 即通过对数据进行学习, 建立合理的分类预测模型, 得到目标函数, 实现将新的样本数据属性集对应到目标属性分类。分类是一个监督学习的过程, 其处理“带标签”的数据, 即分类结果的类别标签均为已知的^[1]。已知数据集的特征以及这些特征对应的标签, 算法会遍历每一笔数据, 尽可能正确地划分数据的类别。

分类问题可分为二分类问题与多分类问题。二分类问题处理包含两种类别标签的数据, 将每一个样本尽可能正确地划分到这两个类别之一中, 给定一个样本作为输入, 输出的答案只能有两个, 诸如: “是否”、“有无”问题即为二分类问题。多分类问题

又可以区分为多类别问题和多标签问题, 前者对含有多个类别的数据进行处理, 把每个样本归入一个类别, 这样每个样本所归属的类别就是唯一的, 不能同时归入多个类别; 后者是指一个样本可以分到多个类别中, 每个样本所划分的类别不是单一的, 一个样本可能同时有多个标签来描述, 是一个样本可以属于多个类别的问题^[2-3]。本文只对分类问题中的二分类问题进行研究。

如何对所接触的事物进行合理分类是人类认识世界、了解世界的重要途径, 同时也是机器学习领域的重点内容^[4]。获得最佳的分类精度是各种分类器的最终目标, 主要通过以下步骤来实现: 首先, 通过对训练集数据进行学习, 构建分类模型, 明确分类的特定规则; 其次, 用已知的分类规则和分类模型在测试集上进行检测, 达到一定的准确度后, 对新数据

作者简介: 师 展(1989-), 女, 博士研究生, 主要研究方向: 数据挖掘、机器学习。

通讯作者: 樊重俊 Email: fan.chongjun@163.com

收稿日期: 2022-06-12

集进行分类预测。为解决分类问题,学者们陆续提出了众多分类算法,常用的分类算法包括K-近邻、朴素贝叶斯分类算法、决策树算法、支持向量机算法、人工神经网络算法等。

数据挖掘的主要工作包括数据描述和数据预测。数据描述是对数据之间存在的相关性、发展的趋势、是否异常等潜在的联系进行归纳,预测是基于一部分数据的属性值,对另一部分数据特定属性的值做出判断。当对象为离散数据,预测的属性值是离散且无序时,该任务即为分类任务。在分类任务方面,本文提出了遗传算法优化的DBN模型,构建基于遗传算法改进的GA-DBN模型,并利用多个数据集进行实验,验证GA-DBN模型在准确率、 F_1 值等方面优于其他分类器。

1 模型构建

1.1 遗传算法

遗传算法(Genetic Algorithms, GA)是经典的群智能优化算法之一。20世纪60年代遗传算法这一名词便开始初露头角,但缺乏实践研究;1975年,遗传算法在J. Holland等学者出版的《自然系统和人工系统的适配》中有了系统的论述^[5];20世纪80年代后,GA算法理论研究和应用研究都成为专家学者们关注的重点,在组合优化、机器学习等方面均占有一席之地。

群智能优化算法受自然界和生物界规律的启发,根据其原理模仿设计出计算机求解问题的算法。达尔文的生物进化论与孟德尔的基因理论是遗传算法的两个重要理论基础。生物进化的基本过程如图1所示,种群中生物的生存与淘汰遵循“物竞天择,适者生存”的规律,群体中的个体经过婚配产生子群体,进化过程中生物机体的某些特性也会传递到后代身上,但也会产生新的个体特性。后代逐渐成长为新的群体淘汰旧群体。但为了保证多样性,淘汰的可能性并不是由适应度唯一决定,只是适应度高的个体被淘汰的可能性低,适应度低的个体也同样可能进入群体,只是进入群体的可能低于适应度高的个体。

遗传算法中通过遗传操作寻找问题最优解,基本流程如图2所示。算法涉及到参数编码、初始群体设定、适应度函数计算、遗传操作和终止条件等基本要素。

遗传操作包括选择、交叉、变异,是算法的关键步骤。选择就是从群体中淘汰部分个体,选择出一

部分优良个体去繁殖子代。选择需要遵循一个既能实现较快收敛又要维持种群多样性方法,因此不能总挑选最好的个体也不能随机选择。常用的选择方法有适应度比例法、锦标赛选择策略及最佳个体保存方法。




图1 生物进化的基本过程

Fig. 1 The basic process of biological evolution

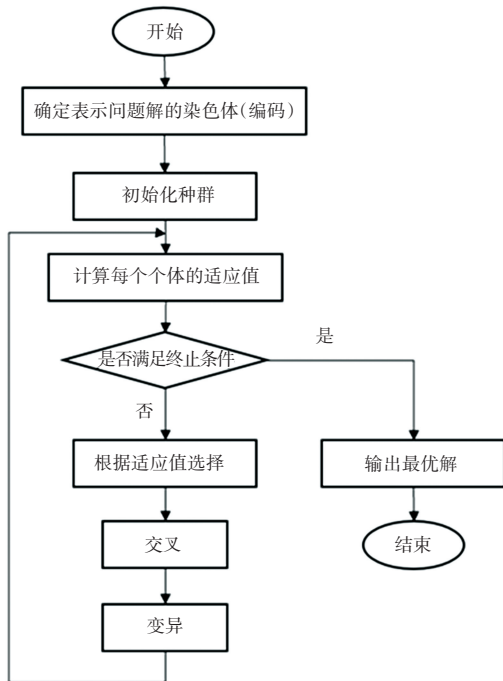


图2 遗传算法的基本流程

Fig. 2 The basic process of genetic algorithm

交叉就是两个生物机体彼此的染色体相互混合后产生新的染色体,即基因重组。父代的优良基因和不良基因都有可能被后代继承,但随着种群进化,后代总会比上一代生存和复制得更好。常用的交叉方法有实数重组法和二进制交叉法。

变异就是个体基因在传递给后代的过程中发生改变,使其成为新的个体。变异可以对选择及交叉过程进行修复,避免算法出现早熟现象。常用的变异方法有实数变异法和二进制变异法。

遗传算法步骤如下:

(1) 初始化种群。随机生成一个有 N 个个体的初始群体 $pop(t)$, 并对个体 $pop_i(t)$ 进行编码, 设定群体规模、迭代次数、终止条件等参数;

(2) 计算适应度。明确目标函数, 计算群体中各个个体的适应度函数值, 如式(1):

$$f_i = fitness(pop_i(t)) \quad (1)$$

(3) 判断是否满足终止条件: 满足, 算法终止; 反之执行下一步;

(4) 选择操作。在群体中, 根据一定的概率, 从中随机选出一批个体形成一个新的群体;

(5) 交叉操作。随机指定两个个体中染色体的一点进行交换;

(6) 变异操作。对某个个体染色体的部分基因进行变异, 得到新的个体;

(7) 返回第(2)步, 重复执行直到找到最优解。

1.2 深度置信网络

深度置信网络模型 (Deep Belief Networks, DBN) 将 BP 算法 (Back Propagation, BP) 与多层受限玻尔兹曼机 RBM (Restricted Boltzmann Machine, RBM) 进行组合, RBM 模型完成 DBN 模型中无监督的学习过程, 有监督学习则是由 BP 算法来完成^[6]。DBN 模型的组成结构如图 3 所示。

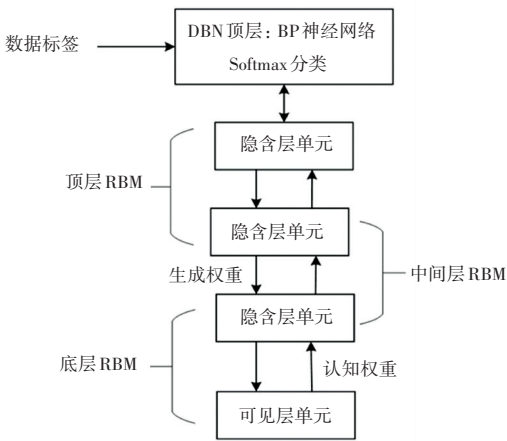


图 3 DBN 模型的组成结构

Fig. 3 Composition structure of DBN model

BP 算法在 DBN 模型顶层逐层微调 RBM 模型相关参数, 尽量使模型的输出与实际标签一致, 以提高模型分类的准确率, 同时使 DBM 模型达到整体最优。在 DBN 模型中, 除了顶层的受限玻尔兹曼机, 其它层之间的权重可以被分为向上的认知权重和向下的生成权重。认知权重向上逐层传递, 与当前层的输入数据结合生成高一层的神经元状态, 传递过

程中采用梯度下降法寻找最优状态, 生成权重向下与 BP 神经网络结合生成低一层次的神经元状态, 与实际神经元状态作对比求误差。

DBN 训练过程如图 4 所示, 主要分为两步:

(1) 分别单独无监督训练每一层 RBM 网络, 确保特征向量映射到不同特征空间时都尽可能多的保留特征信息;

(2) 在 DBN 的最后一层设置 BP 神经网络, 接收 RBM 的输出特征向量作为其输入特征向量, 有监督的训练实体关系分类器。每一层 RBM 网络只能确保自身层内的权值对该层特征向量映射达到最优, 并不是对整个 DBN 的特征向量映射达到最优, 因此 BP 神经网络还将错误信息自顶向下传播至每一层 RBM, 微调整个 DBN 模型, 避免陷入局部最优。




图 4 DBN 模型的训练过程

Fig. 4 Training process of DBN model

1.3 GA-DBN 模型的构建

本文采用遗传算法对深度置信网络中的受限玻尔兹曼机的参数进行逐层寻优, 从而构建了 GA-DBN 分类模型。遗传算法从 DBN 模型中最底层的 RBM 模型开始权重寻优, 底层 RBM 模型将遗传算法训练后的权重矩阵进行正向计算和反向传播后得到隐含层, 作为上层的 RBM 模型的输入层, 上层 RBM 重复这一过程, 最终输入到 BP 神经网络中。

GA-DBN 模型的训练流程如图 5 所示。训练关键步骤如下:

(1) 数据预处理, 划分数据集并输入训练集和测试集;

(2) 各层 RBM 模型中连接可见单元和隐藏单

元之间的权重作为遗传算法种群,对各个权值进行实数编码;

(3) 构造适应度函数。本文以重构误差作为适应度函数,重构误差即经吉布斯采样重构后的数据与原始数据之间的平方差,如式(2):

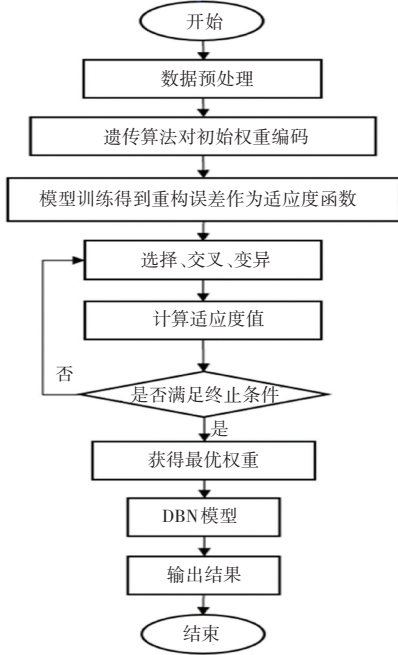


图5 GA-DBN模型训练流程

Fig. 5 GA-DBN model training process

$$f = \sum_{i=1}^M \sum_{j=1}^N (v_{ij} - v'_{ij})^2 \quad (2)$$

其中, M 为样本个数; N 为数据维度; v_{ij} 为第 i 个样本的第 j 个维度的值; v'_{ij} 为 v_{ij} 重构后的值。

(4) 根据适应度值选择出优良个体遗传到子代,如式(3):

$$p_i = \frac{f_i}{\sum_{i=1}^N f_i} \quad (3)$$

(5) 两个个体交叉匹配后产生新个体并遗传给子代,如式(4):

$$\begin{cases} g_{k_1j} = g_{k_1,j}r + g_{k_2,j}(1-r) \\ g_{k_2j} = g_{k_2,j}r + g_{k_1,j}(1-r) \end{cases} \quad (4)$$

其中, $g_{k_1,j}$ 为个体 k_1 第 j 位的基因; $g_{k_2,j}$ 为个体 k_2 第 j 位的基因; $r \in [0, 1]$ 为随机数。

(6) 个体部分基因变异成为新个体,如式(5):

$$g'_{ij} = \begin{cases} g_{ij}r_2 + (g_{ij} - g_{\max})r_1(1 - s/s_{\max}), & r_2 \geq 0.5 \\ g_{ij}r_2 + (g_{\min} - g_{ij})r_1(1 - s/s_{\max}), & r_2 < 0.5 \end{cases} \quad (5)$$

其中, g_{ij} 表示个体的基因,基因的上界为

g_{\max} , 下界为 g_{\min} , r_1, r_2 为随机数,当前遗传算法进化次数为 s , 最大为 s_{\max} 。

(7) 计算适应度函数,满足算法结束条件则更新 RBM 模型的权重和偏置量,反之执行(3);

(8) 对 DBN 模型中的 RBM 模型逐层训练。

遗传算法结束条件为:算法到达最大进化次数或算法得到的重构误差逼近程度在某个范围内,且遗传算法多次进化后发现优化结果几乎不变。

在预训练阶段完成后, RBM 达到了局部最优。为了实现整体最优, RBM 模型训练好后正向输入到 BP 神经网络进行反向计算, BP 神经网络自上而下对整个 DBN 模型参数进行微调,并且结合预训练得到的权重和 DBN 参数, soft-max 模型对训练数据进行分类。

2 模型评估方法

本文选用 Acc (Accuracy, Acc)、 F_1 度量、受试者工作特征曲线 (Receiver Operating Characteristic Curve, ROC) 对分类模型性能进行综合评价。

Acc 为准确率指标,表示在分类中模型对测试集进行分类,分类正确的个数占测试集总个数的比例,如式(6):

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (6)$$

F_1 度量的一般形式是 F_β , 是查准率 (precision) 和查全率 (recall) 的加权调和平均数,查准率代表分类器分类正确的正类数据占分类器中分类为正的的全部数据的比例,查全率表示分类器分类正确的正类数据占整个数据集正类数据的比例,如式(7) ~ 式(9):

$$precision = \frac{TP}{TP + FP} \quad (7)$$

$$recall = \frac{TP}{TP + FN} \quad (8)$$

$$F_\beta = \frac{(1 + \beta^2) \times precision \times recall}{\beta^2 \times (precision + recall)} \quad (9)$$

其中, TP 表示预测值和真实值均为正类; FN 表示预测值为负类,真实值为正类; FP 表示预测值为正类,真实值为负类; TN 表示预测值和真实值均为负类; β 表示对精准率与召回率赋予的权重,本文中 β 取值为 1。

受试者工作特征曲线 (Receiver Operating Characteristic Curve, ROC) 是评价模型的常用图示方法, ROC 曲线示意图如图 6 所示,横坐标为 FPR ,

纵坐标为 TPR , (Area Under Curve, AUC) 为 ROC 曲线下的面积, 其值越大代表分类器的性能越好。

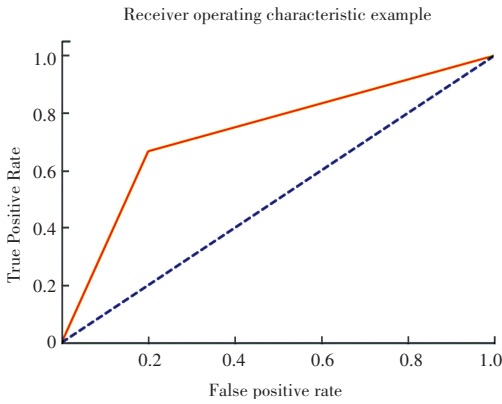


图 6 ROC 曲线示意图

Fig. 6 ROC curve diagram

3 实验与结果分析

3.1 数据集选取与描述

UCI 数据库是由美国加州大学 Owen 分校提供的开放数据库, 其中包含了许多可供机器学习使用的标准数据集, 可用于验证本文分类模型的性能。本文实验选取 UCI 数据库中样本数不一、属性不一的 7 组数据用于分类器性能对比。

选取的 7 组数据集的名称、样本数、属性数等信息, 见表 1。

表 1 实验数据集

Tab. 1 Experimental data sets

编号	数据集名	样本数	属性数
1	Breast Cancer	286	9
2	Wholesale customers	440	8
3	Transfusion	748	4
4	Shill Bidding	6 321	13
5	Mushroom	8 124	22
6	Bank Marketing	41 188	17
7	Adult	48 842	14

3.2 不同分类算法实验结果与分析

按照 4: 1 的比例对 Breast Cancer、Wholesale customers、Transfusion、Shill Bidding、Mushroom、Bank Marketing、Adult 数据集进行划分, 并选取随机森林 (Random Forests, RF)、人工神经网络 (Artificial Neural Network, ANN)、支持向量机 (Support Vector Machine, SVM) 和 XGBoost (eXtreme Gradient Boosting) 分类模型这 4 个分类器在训练集上对数据进行训练, 并与本文所提出的 GA-DBN 分类模型进行比较。

本实验中, DBN 模型中的 RBM 层数均为 3 层, 迭代次数为 100 为止, 其中学习速率为 0.10, 动量学习率为 0.5, 迭代过程中模型的重构误差逐渐降低, 当趋于某个固定值时, 动量学习率变为 0.9。依据不同数据集划分的 DBN 结构见表 2。

表 2 DBM 结构

Tab. 2 DBM structure

数据集	首层 RBM 可见元	中间层 RBM 可见元	顶层 RBM 可见元	DBN 网络节点数
1	286	150	150	286-100-50-2
2	440	200	200	440-200-200-2
3	748	370	250	748-370-250-2
4	6 321	3 500	1 000	6 321-3 500-1 000-2
5	8 124	4 500	3 000	8 124-4 500-3 000-2
6	41 188	20 000	10 000	41 188-20 000-10 000-2
7	48 842	25 000	12 000	48 842-25 000-12 000-2

GA-DBN 模型将重构误差作为适应度函数, 通过 GA 算法找到误差最小时对应的参数, 最终可以得到权重的学习速率以及可见层和隐藏层的偏置量学习速率。本文实验针对不同数据集建立了相对应的 DBN 模型, 对 DBN 模型中的每层 RBM 模型进行 GA 算法优化迭代可得到该层的重构误差, 多次迭代后每层 RBM 的重构误差都在 0.03 左右, 数据集 7 中的底层 RBM 重构误差的实验结果如图 7 所示。


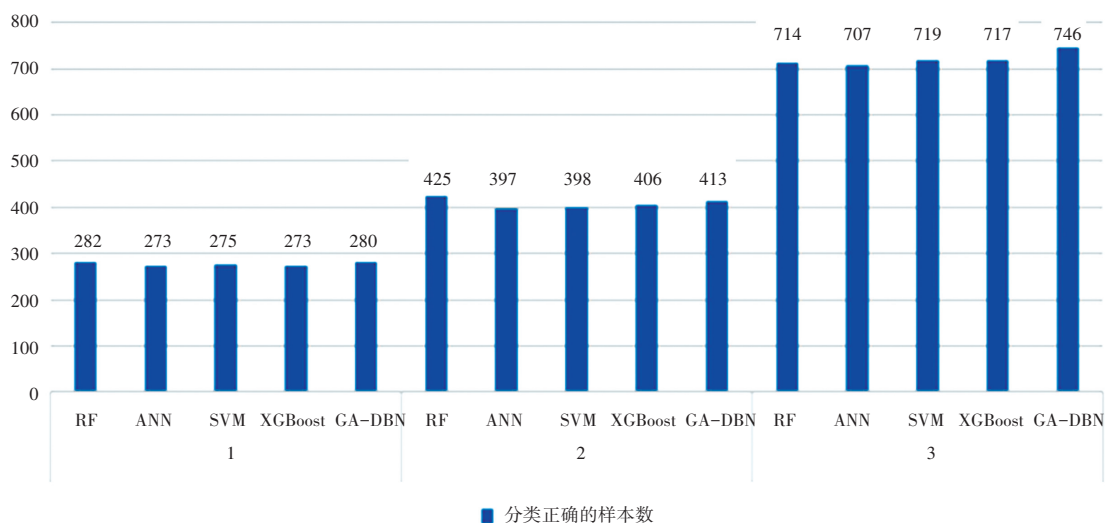


图 7 重构误差


Fig. 7 Reconstruction errors

各个数据集被正确分类样本数的实验结果如图8所示,表明基于GA-DBN分类模型对多分类问题表现出较好的分类效果,正确分类的样本数最高。不同分类器的实验结果见表3,与其他分类模型相比,GA-DBN模型在分类效果上有不同程度的提升,误判率较低。与人工神经网络(ANN)模型相比,GA-DBN模型准确率提升了2.33%~14.91%, F_1 度量提升2.75%~145.92%;与SVM模型相比,GA-DBN模型准确率提升了1.23%~4.93%, F_1 度量提升0.14%~44.99%;与XGBoost模型相比,GA-DBN模型准确率提升了0.14%~4.03%, F_1 度量提升0.77%~8.69%。

根据表3,在数据集1上,GA-DBN的准确率略低于随机森林,但GA-DBN模型在运行时间上更短,效率明显提升;在数据集2上,GA-DBN在准确率和运行时间上不及随机森林,但 F_1 值高于随机森林;在数据集5上,GA-DBN模型表现一般,结合数据集中数据的分布特点发现该数据集为不平衡数据集,因而分类效果较差;在数据集7上,GA-DBN模型的 F_1 值略低于XGBoost,但准确率高于XGBoost;在其余数据集上,GA-DBN模型的准确率 Acc 与 F_1 值均较为理想。同分类器在7个数据集上的ROC曲线如图9所示。



(a) 数据集 1, 2, 3 正确分类样本数



(b) 数据集 4, 5, 6, 7 正确分类样本数

图8 正确分类样本数

Fig. 8 Number of correctly classified samples

表 3 不同分类器的实验结果

Tab. 3 Experimental results of different classifiers


数据集	分类器	Acc / %	Precision / %	Recall / %	F_1 - score / %	Time / s
1	RF	99.12	100.00	98.61	99.30	6.86
	ANN	95.61	94.31	95.25	94.77	3.46
	SVM	96.49	95.88	98.64	97.24	0.32
	XGBoost	95.61	94.73	98.63	96.64	0.95
	GA-DBN	98.24	97.32	97.45	97.38	0.18
2	RF	96.71	92.01	91.74	91.87	0.13
	ANN	90.23	90.78	88.16	88.45	0.15
	SVM	90.67	90.16	88.79	89.46	0.24
	XGBoost	92.49	92.14	90.31	91.21	0.56
	GA-DBN	94.87	93.14	92.95	94.04	0.21
3	RF	95.57	94.43	90.52	92.43	0.63
	ANN	94.63	91.39	90.17	90.77	0.71
	SVM	96.21	94.27	91.69	92.96	0.67
	XGBoost	95.89	92.58	90.31	91.43	0.97
	GA-DBN	99.75	97.36	95.93	96.63	0.59
4	RF	95.17	81.63	65.28	72.54	1.39
	ANN	94.79	78.21	63.97	70.37	1.24
	SVM	96.21	80.58	68.13	73.83	0.79
	XGBoost	95.89	83.59	74.37	78.71	0.88
	GA-DBN	97.39	89.23	82.17	85.55	0.97
5	RF	77.21	75.38	50.36	60.38	102.24
	ANN	75.65	74.29	53.18	61.98	90.86
	SVM	83.02	75.59	56.49	64.66	100.48
	XGBoost	86.74	74.32	63.79	68.65	7.00
	GA-DBN	87.11	78.90	63.96	70.65	8.49
6	RF	89.38	91.30	23.41	37.16	62.54
	ANN	89.26	65.31	23.18	34.21	60.15
	SVM	90.34	66.77	22.85	34.05	57.68
	XGBoost	91.65	65.79	51.36	57.69	17.62
	GA-DBN	91.78	66.25	58.16	61.94	30.95
7	RF	76.33	74.15	55.77	63.65	102.24
	ANN	80.27	74.83	54.37	62.96	105.71
	SVM	85.02	75.59	56.49	64.66	100.48
	XGBoost	87.11	77.40	66.18	71.35	48.15
	GA-DBN	87.71	78.90	63.96	70.65	63.55

3.3 不同优化算法实验结果与分析
 采用人工蜂群算法(Artificial Bee Colony, ABC)


对 DBN 模型中的权重寻优,以验证遗传算法对 DBN 模型的优化效果。在实验中,ABC 算法的各种参数

设定与 GA-DBN 模型一致,选取准确率、 F_1 度量和运行时间对 ABC-DBN 模型和 GA-DBN 模型进行评价,实验结果见表 4。


通过表 4 实验结果可知,与 ABC-DBN 模型相比,GA-DBN 模型在准确率和 F_1 度量上表现良好,但 ABC-DBN 模型运行时间较短;在数据集 1、2、3 上,ABC-DBN 模型与 GA-DBN 模型的表现相差无几,但是随着数据量增大,样本特征变多,遗传算法的优化效果更加突出,ABC-DBN 模型与 GA-DBN 模型的差距拉大,遗传算法中的交叉和变异操作有助于寻找 DBN 模型实现全局最优。




(a) Breast cancer 数据集




(b) Wholesale customers 数据集




(c) Transfusion 数据集




(d) Skill bidding 数据集



(e) Mushroom 数据集



(f) Bank marketing 数据集



(g) Adult 数据集

图 9 ROC 图

Fig. 9 ROC diagram

表 4 不同优化算法的实验结果

Tab. 4 Experimental results of different optimization algorithms

数据集	分类器	Acc /%	F_1 - score /%	Time/s
1	ABC-DBN	98.07	96.51	0.23
	GA-DBN	98.24	97.38	0.18
2	ABC-DBN	94.60	94.11	0.20
	GA-DBN	94.87	94.04	0.21
3	ABC-DBN	97.31	95.76	0.74
	GA-DBN	99.75	96.63	0.59
4	ABC-DBN	92.10	85.48	1.02
	GA-DBN	97.39	85.55	0.79
5	ABC-DBN	80.59	60.13	8.10
	GA-DBN	87.11	70.65	8.49
6	ABC-DBN	85.23	60.74	30.79
	GA-DBN	91.78	61.94	30.95
7	ABC-DBN	82.39	59.72	60.07
	GA-DBN	87.71	70.65	63.55

4 结束语

在训练过程中, DBN 模型参数具有不稳定性, 从而影响模型性能。本文选用遗传算法 (GA) 对 DBN 模型的权重参数进行寻优, 构建了 GA-DBN 模型; 从 UCI 数据库选取了 7 个样本数和属性不同的二分类数据集作为实验数据, 验证 GA-DBM 模型的

分类效果; 同时选择随机森林、人工神经网络、支持向量机和 XGBoost 4 个常用的分类模型作为对比模型, 实验结果表明 GA-DBN 模型在不同数据集上的表现至少有一个指标是最优的, 整体来讲其在准确率 Acc 、 F_1 值及运行效率上均较为理想。为了验证 GA-DBN 模型的优化效果, 选择人工蜂群算法 (ABC) 优化后的 DBN 模型即 ABC-DBN 模型与 GA-DBN 模型进行对比实验, 结果表明遗传算法对 DBN 模型的优化更稳定。

参考文献

(上接第 22 页)

型, 尝试将一种新的多步学习方法 EnDQN 应用于该模型中, 并在 carEnv 停车场仿真环境中评估了该方法的性能。实验结果表明, 该模型非常高效且 EnDQN 大幅优于现有的进化策略和神经网络结合的方法。在未来, 计划设计一种更合理的奖励函数来进一步优化 EnDQN 算法在停车场车位自动化排布设计上的性能。

参考文献

[1] 贾志欣. 排样问题的研究现状与趋势[J]. 计算机辅助设计与图形学学报, 2004(7): 890-897.
 [2] HUANG J, LIAO T, KANG H, et al. A general algorithm for rectangular parking optimization design[J]. Journal of Physics: Conference Series. IOP Publishing, 2020, 1486(3): 032029.
 [3] 利润. 地下停车场车位自动化排布方法研究[D]. 广州: 华南理工大学, 2020.

[1] 杨杏丽. 分类学习算法的性能度量指标综述[J]. 计算机科学, 2021, 48(8): 209-219.
 [2] WANG Xun, LIU Huan, YANG Zeqing, et al. Research and implementation of a multi-label learning algorithm for chinese text classification[C]// 2017 3rd International Conference on Big Data Computing and Communications (BIGCOM). USA: IEEE, 2017: 68-76.
 [3] TAREKEGN A N, GIACOBINI M, MICHALAK K. A review of methods for imbalanced multi-label classification[J]. Pattern Recognition, 2021, 118: 107965.
 [4] 张工学. 模式识别[M]. 北京: 清华大学出版社, 2010: 1-25.
 [5] 陈国良, 王熙法, 庄镇泉, 等. 遗传算法及其应用[M]. 北京: 人民邮电出版社, 1999: 1-10.
 [6] HINTON G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002; págs. 1771-1800.

[4] 徐涵喆, 黄逸彬, 杨赫, 等. 基于规则的城市地下车库外圈车位排布启发式算法[J]. 北京邮电大学学报, 2019, 42(4): 102-108.
 [5] 余光鑫. 基于强化学习的地下车库生成式设计研究[J]. 广州: 华南理工大学, 2020. DOI: 10.27151/d.cnki.ghnl.2020.001609.
 [6] 刘国庆. 深度强化学习中样本效率提升方法研究[D]. 合肥: 中国科学技术大学, 2021.
 [7] Pablo Escandell-Montero, Delia Lorente, José M, et al. Online fitted policy iteration based on extreme learning machines[J]. Knowledge-Based Systems, 2016, 100: 200-211.
 [8] YUAN Y, YU Z L, GU Z, et al. A novel multi-step Q-learning method to improve data efficiency for deep reinforcement learning[J]. Knowledge-Based Systems, 2019, 175: 107-117.
 [9] WANG J X, KURTH-NELSON Z, TIRUMALA D, et al. Learning to reinforcement learn[J]. arXiv preprint arXiv: 1611.05763, 2016.
 [10] SUTTON R S, BARTO A G. Reinforcement learning: An introduction[M]. MIT press, 2018.