

文章编号: 2096-1618(2020)02-0146-05

# 基于 HPSO-BP 神经网络的个人信用评估

石丽红, 陶宏才

(西南交通大学信息科学与技术学院, 四川 成都 611756)

**摘要:**为了解决 BP 神经网络和标准 PSO-BP 神经网络模型收敛慢、易陷入局部最优值等问题,引入改进的粒子群算法 HPSO,提出了基于 HPSO-BP 神经网络的信用评估模型。在 PyCharm 环境下,利用德国个人信用数据集,分别比较了 BP 神经网络模型、标准 PSO-BP 神经网络模型和文中的 HPSO-BP 神经网络模型。实验结果表明,基于 HPSO-BP 神经网络的评估模型在收敛速度和准确度上都优于另外两个模型。

**关键词:**BP 神经网络;标准 PSO-BP;HPSO-BP;信用评估

**中图分类号:**TP389.1

**文献标志码:**A

**doi:**10.16836/j.cnki.jcuit.2020.02.004

## 0 引言

目前,中国正处于市场经济全面发展的时期,面临较多问题,个人信用问题就是其中的一个。市场经济本质是信用经济,信用问题解决不好,将直接影响经济的正常运转<sup>[1]</sup>。然而,现今中国个人信用体系的建立还不完善,也没有建立科学的评估标准和评估方法<sup>[2]</sup>。另外,随着互联网和大数据的发展,产生了海量的信用相关数据,如何利用这些数据对个人信用进行科学评估已经成为亟待解决的问题。

信用评估方法按时间先后顺序可以分为三类:专家打分法、数学统计法和人工智能法。随着互联网和大数据的发展,人工智能法得到越来越多学者的重视,基于人工智能的信用评估研究层出不穷。常见的应用于信用评估的人工智能模型有人工神经网络<sup>[3]</sup>、支持向量机<sup>[4]</sup>、决策树<sup>[5]</sup>等。其中,人工神经网络尤其是 BP 神经网络在信用评估领域得到了广泛的应用,并取得了很好的效果。

BP 神经网络具有很强的非线性映射能力和泛化能力,但是其基于梯度下降的学习方法导致网络收敛速度过慢,而且容易陷入局部极小值。针对 BP 神经网络这些问题,很多学者通过混合不同的算法以提高 BP 神经网络的收敛速度和精度,一个常见的混合模型就是基于粒子群优化的 BP 神经网络模型<sup>[6]</sup>。粒子群优化算法是一种智能优化算法,其算法思想来源于鸟类觅食行为,该算法通过群体中个体之间的协作和信息共享寻找最优解。但是,标准的粒子群算法存在早熟、精度不高、收敛慢等问题。故文中引入改进的粒子

群算法——HPSO<sup>[7]</sup>,提出基于 HPSO-BP 神经网络的个人信用评估模型,并将该模型应用于德国开源个人信用数据集中。实验结果表明,本文提出的模型在收敛速度和准确度上得到了一定的提高。

## 1 相关技术

### 1.1 BP 神经网络

BP 神经网络是最具代表性、使用最广泛的一种神经网络模型,它是一种多层前馈神经网络。在应用 BP 神经网络求解问题时,常采用如图 1 所示的三层网络结构。




图1 三层 BP 神经网络结构图

BP 神经网络的学习过程由信号正向传播和误差反向传播两个过程组成。在正向传播中,输入信号从输入层经过隐含层学习处理后到达输出层。在反向传播中,按照误差梯度下降的方向,从输出层到隐含层最后到输入层,依次迭代调整网络的权值和阈值,使得最终的神经网络达到最小误差。详细的数学表述如下。

信号正向传播。隐含层、输出层的输出满足

$$H_j = f\left(\sum_{i=1}^m x_i \cdot u_{ij} - \theta_j\right) \quad (1)$$

$$O_k = \text{sigmoid}(\sum_{j=1}^h H_j \cdot v_{jk} - \theta_k) \quad (2)$$

式(1)中,  $x_i (i=1, 2, \dots, m)$  为 BP 神经网络的输入值;  $u_{ij} (j=1, 2, \dots, h)$  为输入层第  $i$  个结点到隐含层第  $j$  个结点的连接权值;  $\theta_j$  为隐含层第  $j$  个结点的阈值;  $H_j$  为隐含层第  $j$  个结点的输出值。式(2)中,  $H_j$  为输出层的输入值;  $v_{jk} (k=1, 2, \dots, n)$  为隐含层第  $j$  个结点到输出层第  $k$  个结点的连接权值;  $\theta_k$  为输出层第  $k$  个结点的阈值;  $O_k$  为 BP 神经网络的输出值。

误差反向传播。误差函数  $E$ 、隐含层到输出层的权值调整公式、输入层到隐含层的权值调整公式为

$$E_p = \frac{1}{2} \sum_{k=1}^n (y_k - O_k)^2 \quad (3)$$

$$v_{jk}(t+1) = v_{jk}(t) + \Delta v_{jk} \quad (4)$$

$$\Delta v_{jk} = -\eta \frac{\partial E(t)}{\partial v_{jk}(t)} \quad (5)$$

$$u_{ij}(t+1) = u_{ij}(t) + \Delta u_{ij} \quad (6)$$

$$\Delta u_{ij} = -\eta \frac{\partial E(t)}{\partial u_{ij}(t)} \quad (7)$$

式(3)中,  $E_p (p=1, 2, \dots, P)$  为第  $p$  个样本的均方差;  $y_k$  为期望输出值;  $O_k$  为网络实际输出值。式(5)和式(7)中,  $\eta$  表示学习率, 它决定了网络的学习速率;  $\Delta v_{jk}$  为隐含层第  $j$  个结点到输出层第  $k$  个结点的连接权值调整量;  $\Delta u_{ij}$  为输入层第  $i$  个结点到隐含层第  $j$  个结点的连接权值的调整量。

## 1.2 PSO 算法

粒子群算法是受鸟类觅食行为启发而提出的一种优化算法, 通过群体间的信息共享和个体自身经验修正个体的勘探和开发能力, 最终求取优化问题的解<sup>[8]</sup>。标准的粒子群算法的数学描述如下:

设在一个  $d$  维搜索空间中, 一个群体有  $m$  个粒子, 每个粒子  $i$  有速度  $v$  和位置  $x$  两个属性, 速度和位置的维度都为  $d$ , 即  $v_i = (v_{i1}, v_{i2}, \dots, v_{id})$ ,  $x_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 。每个粒子都由适应度函数  $\text{fitness}$  计算其当前位置的好坏, 每个粒子  $i$  都在  $d$  维空间中单独搜索最优位置, 并记忆自己搜索到的历史最优位置  $p_i = (p_{i1}, p_{i2}, \dots, p_{id})$ 。然后, 将自己的最优位置和其他粒子共享, 所有粒子中的最优位置作为整个群体的当前最优位置  $p_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ , 每个粒子  $i$  利用个体最优位置  $p_i$  和群体最优位置  $p_g$ , 通过式(8)和式(9)不断调整自己的速度  $v_i$  和位置  $x_i$ 。

$$v_i^{t+1} = \omega v_i^t + c_1 r_1 (p_i^t - x_i^t) + c_2 r_2 (p_g^t - x_i^t) \quad (8)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (9)$$

$$\omega = \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{T} \times t \quad (10)$$

其中,  $T$  为最大迭代次数,  $t$  为当前迭代次数;  $\omega$  为惯性权重, 它是影响算法性能的关键参数, 一般按照式(10)更新。其中,  $\omega_{\max}$  一般取值为 0.9,  $\omega_{\min}$  一般取值为 0.4;  $c_1$ 、 $c_2$  表示学习因子, 分别调节粒子向个体最优位置和群体最优位置靠近的步长, 一般取值为 2;  $r_1$ 、 $r_2$  为介于  $[0, 1]$  的随机数。

## 1.3 HPSO 算法

对于由式(8)~(10)确定的标准粒子群算法, 群体的多样性会随着迭代次数增加而急速降低, 导致粒子的探测开发能力减弱, 最终无法跳出局部最优解。针对标准粒子群算法的这些问题, Wang 等<sup>[7]</sup>提出改进的粒子群算法——HPSO, 该算法的灵感来源于人类行为特征, 借鉴人类将坏习惯作为警示以纠正自身行为举止的活动。HPSO 算法据此想法在对粒子的速度进行更新时加入了群体最差位置项  $p_w$ ,  $p_w$  也是一个  $d$  维向量, 即  $p_w = (p_{w1}, p_{w2}, \dots, p_{wd})$ 。另外, 为了降低标准粒子群算法的参数敏感性, HPSO 还去除了学习因子系数  $c_1$ 、 $c_2$ 。HPSO 算法的具体公式为

$$v_i^{t+1} = \omega v_i^t + r_1 (p_i^t - x_i^t) + r_2 (p_g^t - x_i^t) + r_3 (p_w^t - x_i^t) \quad (11)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (12)$$

$$p_w = \text{argmax}(\text{fit}(p_1), \text{fit}(p_2), \dots, \text{fit}(p_m)) \quad (13)$$

其中,  $p_w$  表示整个群体当前最差位置;  $\text{fit}$  为适应度函数;  $\omega$  为惯性权重, 按照式(8)更新;  $r_1$ 、 $r_2$  为介于  $[0, 1]$  的随机数,  $r_1 + r_2 = 1$ ,  $r_3$  为服从标准正态分布的随机数。

HPSO 算法不仅参数简单、计算成本低, 而且在增加种群多样性上起到了很大的作用。对比标准 PSO 算法, HPSO 算法在提高粒子脱离局部最优解概率和加快算法收敛速度方面具有明显的优势。

## 2 基于 HPSO-BP 神经网络的新模型

### 2.1 问题提出

BP 神经网络存在收敛慢、局部最优等不足。为了弥补这些不足, 很多研究中利用粒子群算法对 BP 神经网络进行优化。

尽管在大部分情况下, 利用粒子群算法优化后的 BP 神经网络增加了跳出局部最优值的概率和加快了收敛速度。但是标准的粒子群算法本身存在早熟、收敛慢、参数敏感等缺陷, 有时优化效果并不明显, 甚至在某些情况下, 基于标准粒子群优化的 BP 神经网络的精度还不及 BP 神经网络自身的精度。为了提高粒子群算法优化 BP 神经网络的效率, 可以对粒子群算法进行改进, 故引入了 HPSO 算法, 提出了基于 HPSO-

BP神经网络的新模型。

## 2.2 新模型算法处理流程

描述新模型算法前,需要对 HPSO 算法做些许调整。式(11)中,HPSO 算法的参数  $r_1$  和  $r_2$  为介于  $[0,1]$  的随机数,且  $r_1+r_2=1$ , $r_3$  为服从标准正态分布的随机数。考虑到当  $r_1$  较大时,粒子将会更快地飞向历史最优位置  $p_i$ 。而由于存在  $r_1+r_2=1$  的限制,粒子向全局最优位置  $p_g$  飞行的概率就相对减小了。当  $r_1$  较小时情况则相反,这会降低粒子飞行的随机性。其次,由于  $r_3$  服从标准正态分布,因此当  $r_3<0$  时,会降低粒子的整体飞行速度,这在算法迭代初期会降低粒子的开发能力。鉴于上述考虑,对 HPSO 算法中的  $r_1$ 、 $r_2$  和  $r_3$  做这样一些调整,即:不限制  $r_1+r_2=1$ ;取消  $r_3$  服从标准正态分布的设定,而让其取值为介于  $[0,1]$  的随机数。后续的实验结果表明,这样的调整是必要的和有效的。

新模型中,须用经上述调整后的 HPSO 算法去优化 BP 神经网络,并使每个粒子的位置向量代表一个 BP 神经网络的所有连接权值和阈值。即,首先用式(14)作为适应度计算函数,然后将 HPSO 搜索到的全局最优的位置向量映射为 BP 神经网络的连接权值和阈值。

$$fit = \frac{1}{P} \sum_{p=1}^P \sum_{k=1}^n (y_{pk} - O_{pk})^2 \quad (14)$$

式中, $P$  为样本数量; $k$  为神经网络的第  $k$  个输出结点; $y_{pk}$  为期望输出值; $O_{pk}$  为神经网络实际输出值。

HPSO-BP 神经网络模型的算法具体步骤如下,流程如图 2 所示。

**步骤 1** 确定网络的拓扑结构,准备训练数据。

**步骤 2** 初始化粒子群:种群大小  $N$ ;搜索空间维度  $d$ ;最大迭代次数  $T$ ;惯性权重  $\omega$  取值范围;粒子位置  $x_i$  和粒子速度  $v_i$ 。

**步骤 3** 用式(14)计算每个粒子的适应度,初始化每个粒子的历史最优位置  $p_i$ 、群体最优位置  $p_g$  和群体最差位置  $p_w$ 。

**步骤 4** 排除粒子速度和位置越界的粒子,并用式(11)和式(12)更新粒子速度和粒子位置。

若  $v_i > v_{\max}$ ,则  $v_i = v_{\max}$ ;若  $v_i < v_{\min}$ ,则  $v_i = v_{\min}$ 。

若  $x_i > x_{\max}$ ,则  $x_i = x_{\max}$ ;若  $x_i < x_{\min}$ ,则  $x_i = x_{\min}$ 。

$v_{\max}$ 、 $v_{\min}$ 、 $x_{\max}$ 、 $x_{\min}$  均为自定义的常数。

**步骤 5** 计算每个粒子的当前适应值:如果粒子适应值小于其历史最优位置  $p_i$  对应的适应值,则更新粒子的最优位置  $p_i$ ;如果存在适应值小于群体最优位置  $p_g$  对应的适应值的粒子,则更新群体最优位置  $p_g$ ;如果存在适应值大于群体最差位置  $p_w$  对应的适应值的粒子,则更新群体最差位置  $p_w$ 。

**步骤 6** 判断迭代是否已经达到最大次数,或者是否满足算法误差精度。如果满足任一条件,则迭代结束,跳转到步骤 7;否则,跳转到步骤 4。

**步骤 7** 将群体最优位置  $p_g$  映射为 BP 神经网络的权值和阈值,输入测试数据,测试网络的泛化能力。

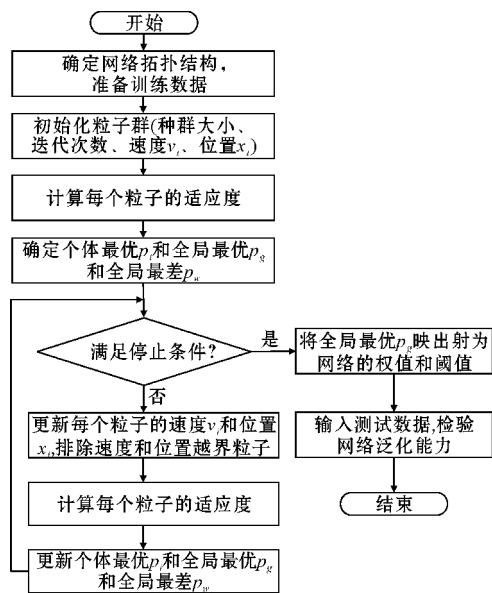


图2 HPSO-BP 算法流程

## 3 模型在个人信用评估上的实验及分析

### 3.1 数据集

数据来源于 UCI 数据库中的德国开源个人信用数据集。每条数据包含 20 个个人信用指标,其中 13 个指标是类别属性,7 个是数值属性。每条数据对应 1 个表示个人信用状况的标签,信用标签分“信用好”和“信用差”两种,分别用数值 1 和 2 表示。数据集总共有 1000 条数据,其中有 700 条是“信用好”的,300 条是“信用差”的。

### 3.2 实验环境和评价指标

实验环境如表 1 所示,针对本文的实验,采用了收敛速度和准确率两个评价指标,其中收敛速度用算法收敛时的迭代次数表示。

表1 实验环境及配置

实验环境	环境配置
操作系统	Windows8
CPU	Intel Core i5-3337U 1.80GHz
内存	4.00G
编程语言	Python3.7.3
开发环境	PyCharm2018



3.3 模型对比实验与分析

采用德国开源个人信用数据集,对 BP 神经网络模型(BPNN)、标准 PSO-BP 神经网络模型(标准 PSO-BPNN)、调整前 HPSO-BP 神经网络模型(调整前 HP-SO-BPNN)和本文模型进行对比实验。在实验中,采用三层神经网络结构,取 600 个“信用好”样本和 200 个“信用差”样本作为训练集,剩余 100 个“信用好”样本和 100 个“信用差”样本作为测试集,对每个模型进行了五折交叉实验,实验结果如表 2 所示。

表 2 模型实验数据对比

模型	收敛时迭代次数	适应度	准确率/%
BPNN	8500	0.0268	58
标准 PSO-BPNN	250	0.143	61
调整前 HPSO-BPNN	780	0.105	63
本文模型	220	0.164	69

由表 2 可知,BP 神经网络模型的收敛速度和精度最差。经过粒子群优化后的 BP 神经网络的收敛速度和精度都得到了提高。在本文的应用场景下,用调整前的 HPSO 优化 BP 神经网络,其收敛速度不如标准 PSO 优化后的神经网络快,而调整后的 HPSO-BP 神经网络模型的收敛速度和精度得到了进一步提高。

3.3.1 BP 神经网络模型

因为每条数据有 20 个信用指标,所以 BP 神经网络的输入层为 20 个结点,通过试凑法,最后确定隐含层为 10 个结点,输出层为 2 个结点,分别对应“信用好”和“信用差”两个标签,学习率为0.01。BP 神经网络模型在 20-10-2 的网络结构下的迭代误差曲线如图 3 所示。




图 3 BP 神经网络迭代误差曲线

3.3.2 标准 PSO-BP 神经网络模型

根据 BP 神经网络模型的实验结果,网络的拓扑结构为 20-10-2;群体大小为 10;惯性权重取值范围取值

$\omega_{\max}=0.9,\omega_{\min}=0.4$ ;学习因子取值为  $c_1=c_2=2$ 。标准 PSO-BP 神经网络模型的迭代误差曲线如图 4 所示。




图 4 标准 PSO-BP 神经网络迭代误差曲线

3.3.3 调整前 HPSO-BP 神经网络模型

该模型的网络拓扑结构也为 20-10-2;群体大小为 10;惯性权重取值范围  $\omega_{\max}=0.9,\omega_{\min}=0.4$ ;  $r_1、r_2$  为  $[0,1]$  的随机数,且  $r_1+r_2=1$ ,  $r_3$  为服从标准正态分布的随机数。调整前 HPSO-BP 神经网络模型的迭代误差曲线如图 5 所示。




图 5 调整前 HPSO-BP 神经网络迭代误差曲线

3.3.4 本文模型

本文模型的网络拓扑结构也为 20-10-2;群体大小为 10;惯性权重取值范围  $\omega_{\max}=0.9,\omega_{\min}=0.4$ ;使用调整之后的  $r_1、r_2、r_3$ ,均取值为  $[0,1]$  的随机数。本文模型的迭代误差曲线如图 6 所示。




图 6 本文模型迭代误差曲线

## 4 结束语

针对 BP 神经网络和标准 PSO-BP 神经网络存在收敛速度慢、局部最优等问题,提出基于 HPSO-BP 的神经网络评估模型,并利用德国开源个人信用数据集对 BP 神经网络模型、标准 PSO-BP 神经网络模型和本文模型进行对比实验。实验结果表明,本文模型的收敛速度和准确度都高于另外两个模型。

## 参考文献:

- [1] 姜金明.我国个人信用评估研究[D].广州:广东工业大学,2006.
- [2] 尤晓明.个人信用评分系统应用现状与展望[J].中国信用卡,2009(3):59-61.
- [3] Khashman A. A Neural Network Model for Credit Risk Evaluation[J]. International Journal of Neural Systems,2009,19(4):285-294.
- [4] Harikrishna S, Farquad M A H, Shabana. Credit Scoring Using Support Vector Machine: A Comparative Analysis[J]. Advanced Materials Research, 2012:6527-6533.
- [5] Jiang W L. Research and Application of Credit Score Based on Decision Tree Model[C]. 2010 The 3rd International Conference on Computational Intelligence and Industrial Application (PACIIA-2010),2010:279-283.
- [6] Liu N, Xia E J, Yang L. Research and Application of PSO-BP Neural Networks in Credit Risk Assessment[C]. Computational Intelligence and Design (ISCID),2010 International Symposium on IEEE, 2010:103-106.
- [7] Yue Wang, Hao Liu, ZhongXin Yu, et al. An improved artificial neural network based on human-behaviour particle swarm optimization and cellular automata[J]. Expert System with Applications, 2019, DOI:10.1016/j.eswa.2019.1862.
- [8] 周俊,陈璟华,刘国祥.粒子群优化算法中惯性权重综述[J].广东电力,2013(7):13-16.
- [9] 蒋维.基于改进 PSO-BP 神经网络的个人信用评级模型及算法研究[D].成都:电子科技大学,2018.
- [10] 凌晓,徐鲁帅,梁瑞,等.基于改进 PSO-BPNN 的输油管道内腐蚀速率研究[J].中国安全生产技术,2019,15(10):63-68.
- [11] 蔡荣辉,崔雨轩,薛培静.三层 BP 神经网络隐层节点数确定方法探究[J].电脑与信息技术,2017,25(5):29-33.
- [12] 陈云,石松.基于 PSO-BP 集成的国内外企业信用风险评估[J].计算机应用研究,2014,31(9):2705-2710.
- [13] 全秋娟,李萌,赵岂.基于分类思想的改进粒子群优化算法[J].现代电子技术,2019,42(19):11-14.
- [14] Zhan Z H, Zhang J, Li Y. Adaptive Particle Swarm Optimization[J]. IEEE Transactions on Cybernetics. 2010,39(6):1362-1381.
- [15] 张德慧,张德育,刘清云,等.基于粒子群算法的 BP 神经网络优化技术[J].计算机工程与设计,2015,36(5):1321-1326.

## Personal Credit Evaluation based on HPSO-BP Neural Network

SHI Lihong, TAO Hongcai

(School of Information Science & Technology, Southwest Jiaotong University, Chengdu 611756, China)

**Abstract:** To solve the problems such as slow convergence, local optimal of BP neural network and standard PSO-BP neural network credit evaluation models, this paper introduces an improved particle swarm algorithm HPSO, and proposes a credit evaluation model based on HPSO-BP neural network. Under PyCharm, by using the German personal credit data set, a comparing experiment is done on the BP neural network, the standard PSO-BP neural network and the HPSO-BP neural network. The results show that the credit evaluation model based on HPSO-BP neural network has better convergence speed and higher accuracy than the other two models.

**Keywords:** BP neural network; standard PSO-BP; HPSO-BP; credit evaluation