

文章编号:1001-9081(2013)11-3107-04

doi:10.11772/j.issn.1001-9081.2013.11.3107

小波神经网络模型的改进方法

张炎亮¹, 陈 鑫^{1*}, 李亚东²

(1. 郑州大学 管理工程学院, 郑州 450001; 2. 河南投资集团有限公司 总经办, 郑州 450001)

(* 通信作者电子邮箱 chenxin_zzu@126.com)

摘要:为了改善小波神经网络(WNN)在处理复杂非线性问题的性能,针对量子粒子群优化(QPSO)算法易早熟、后期多样性差、搜索精度不高的缺点,提出一种同时引入加权系数、引入Cauchy随机数、改进收缩-扩张系数和引入自然选择的改进量子粒子群优化算法,将其代替梯度下降法,训练小波基系数和网络权值,再将优化后的参数组合输入小波神经网络,以实现算法的耦合。通过对3个UCI标准数据集的仿真实验表明,与WNN、PSO-WNN、QPSO-WNN算法相比,改进的量子粒子群-小波神经网络(MQPSO-WNN)算法的运行时间减少了11%~43%,而计算相对误差较之降低了8%~57%。因此,改进的量子粒子群-小波神经网络模型能够更迅速、更精确地逼近最优值。

关键词:小波神经网络;改进的量子粒子群;参数组合优化

中图分类号: TP301 文献标志码:A

Modified method for wavelet neural network model

ZHANG Yanliang¹, CHEN Xin^{1*}, LI Yadong²

(1. School of Management Engineering, Zhengzhou University, Zhengzhou Henan 450001, China;

2. Department of Executive, Henan Investment Group Company Limited, Zhengzhou Henan 450001, China)

Abstract: To improve the performance of Wavelet Neural Network (WNN) model in dealing with complex nonlinear problems, concerning the shortcomings of premature convergence, poor late diversity, poor search accuracy of Quantum-behaved Particle Swarm Optimization (QPSO) algorithm, a modified quantum-behaved particle swarm algorithm was proposed for WNN training by introducing weighting coefficients, introducing Cauchy random number, improving contraction-expansion coefficient and introducing natural selection at the same time. And then it replaced the gradient descent method with the modified quantum-behaved particle swarm algorithm, trained the wavelet coefficients and network weights, and then input the optimized combination of parameters into wavelet neural network to achieve the algorithm coupling. The simulation results on three UCI standard datasets show that the running time of the Modified Quantum-behaved Particle Swarm Optimization-Wavelet Neural Network (MQPSO-WNN) was reduced by 11%~43%, while the calculation error was decreased by 8%~57%, compared with wavelet neural network, PSO-WNN and QPSO-WNN. Therefore, the MQPSO-WNN model can approximate the optimal value more quickly and more accurately.

Key words: Wavelet Neural Network (WNN); modified Quantum-behaved Particle Swarm Optimization (QPSO); parameters combination optimization

0 引言

小波神经网络(Wavelet Neural Network, WNN)自提出以来得到了广泛应用,然而,传统WNN模型存在精度差、不稳定、易早熟等缺点。与此同时,量子粒子群优化(Quantum-behaved Particle Swarm Optimization, QPSO)算法虽然对传统粒子群优化(Particle Swarm Optimization, PSO)算法进行一定的改进,但仍然没有完全摆脱PSO容易陷入局部最优的缺点,并存在着易早熟、后期多样性差、搜索精度不高等缺陷。

基于此,本文将在前人的研究基础上,提出一套QPSO算法的改进方案,并用改进后的QPSO算法代替梯度下降法,以均方差(Mean Squared Error, MSE)误差为目标函数,优化WNN的小波基系数和网络权值,再将优化后的参数组合输入WNN模型进一步精确优化,从而实现两种算法的耦合。通过实验分析可以证明,改进后的WNN具备更高的收敛精度和更快的收敛速度,对于解决复杂非线性问题拥有更好的泛化

能力、容错能力以及学习能力。

1 量子粒子群算法及其改进

1.1 量子粒子群算法

为了克服传统PSO算法的缺陷,Sun等^[1]提出QPSO算法,提高了粒子群的全局收敛能力。由于算法在迭代过程中,仅存在粒子位置的变化,因此计算大大简化,主要迭代方程归纳为:

$$\begin{cases} mbest(t) = \frac{1}{M} \sum_{i=1}^M p_i(t) = \\ \left(\frac{1}{M} \sum_{i=1}^M p_{i,1}(t), \frac{1}{M} \sum_{i=1}^M p_{i,2}(t), \dots, \frac{1}{M} \sum_{i=1}^M p_{i,n}(t) \right) \quad (1) \\ p(t) = (r_1 p_i(t) + r_2 p_g(t)) / (r_1 + r_2) \\ X(t+1) = p(t) \pm \beta |mbest(t) - X(t)| \ln(1/u) \end{cases}$$

其中: $i = 1, 2, \dots, M; n = 1, 2, \dots, N; M$ 为粒子的种群规模; N 为粒子的维数; t 为当前迭代次数; r_1, r_2 和 u 均为[0,1]的随

收稿日期:2013-05-10;修回日期:2013-07-17。 基金项目:教育部人文社会科学研究青年基金资助项目(11YJC630291)。

作者简介:张炎亮(1979-),女,安徽亳州人,副教授,博士,主要研究方向:工业工程;陈鑫(1989-),男,江苏盐城人,硕士研究生,主要研究方向:工业工程;李亚东(1976-),男,河南焦作人,高级工程师,博士,主要研究方向:企业风险管理。

机数; $p_i(t)$ 为粒子的个体最优位置; $p_g(t)$ 为粒子的全局最优位置; $p(t)$ 为 $p_i(t)$ 和 $p_g(t)$ 之间的随机点。 β 为收缩-扩张系数, 是量子粒子群算法唯一的初始参数, 通常情况下, β 的值随着迭代次数增加而线性减小^[2], 即:

$$\beta = 0.5 + (1 - 0.5)(T - t)/T \quad (2)$$

其中 T 为最大迭代次数。当 $u \leq 0.5$ 时, β 取正号; 当 $u > 0.5$ 时, β 取负号。与其他智能算法不同, 量子粒子群只有收缩-扩张系数 β 作为唯一的初始参数, 因此它具有易控制、收敛快以及全局搜索能力强等特点, 但也存在以下几点问题:

1) 量子粒子群算法没有从根本上改变标准粒子群在后期容易陷入早熟的问题, 相关研究^[3] 表明, 随着迭代次数的增加, 种群的多样性逐步减弱, 粒子的全局搜索能力也会随之降低。

2) 在量子空间里, 单个粒子没有速度向量的指引, 后期搜索能力较弱, 并且随着 β 参数的递减, 粒子的搜索空间也逐步压缩, 容易陷入早熟, 导致搜索精度不高。

1.2 改进的量子粒子群算法

为了改善 QPSO 算法性能, Sun 等做了许多工作, 比如提出了概率分布机制, 维持种群的多样性^[4]; 与模拟退火算法相结合, 提高全局搜索能力^[5]; 利用免疫记忆来提高粒子的收敛速度^[6]等。此外, Coelho^[7] 提出了基于 Gaussian 分布的 QPSO 算法, 通过引入变异算子改善后期搜索能力; 林星等^[8] 提出混沌 QPSO 优化算法, 具有较好的搜索精度和较强的克服早熟的能力; 许少华等^[9] 引入量子 Hadamard 门操作和全局自适应因子, 改善了 QPSO 算法的搜索能力等。

上述改进方法都能在一定程度上改善了 QPSO 算法的性能, 但算法的改进应是一个系统工作, 仅靠一两个方面的改善, 效果非常有限, 甚至可能会带来一些负面效果, 比如提高粒子搜索精度可能降低收敛速度, 加快搜索可能陷入早熟, 所以, 本文针对 QPSO 算法固有缺陷, 提出从收敛精度、搜索速度以及克服早熟能力的三个方面综合考虑, 全面系统地设计改进方案, 主要包括以下 4 点。

1) 加权系数。

式(1)中平均最优位置 m_{best} 仅仅是由处于每个维度上最优粒子的简单求和平均得出, 这就等同于假定了每个粒子在空间搜索中所做贡献是一样的, 而在实际情况中这显然是不合理的。虽然在多数情况下, 传统的处理方式是可行的, 但是为了降低算法的随机性, 提高粒子搜索精度, 本文引入加权系数^[10] 对原算法进行改进。

在每次迭代时, 通过计算出适应值 $p_i(t)$, 筛选出每一个维度处于最优位置的粒子。若是求最大值问题, 则 $p_i(t)$ 越大, 粒子越重要; 反之, 若是求最小值问题, 则 $p_i(t)$ 越小, 粒子越重要。因此, 根据适应值的大小, 首先将粒子按降序排列, 然后为每个粒子确定其加权系数 $\alpha_{i,n}$, 离预期的最优结果越近, $\alpha_{i,n}$ 的值越大, 所以, 将 m_{best} 改进为:

$$m_{best} = \frac{1}{M} \sum_{i=1}^M p_i(t) = \left(\frac{1}{M} \sum_{i=1}^M \alpha_{i,1} p_{i,1}(t), \frac{1}{M} \sum_{i=1}^M \alpha_{i,2} p_{i,2}(t), \dots, \frac{1}{M} \sum_{i=1}^M \alpha_{i,n} p_{i,n}(t) \right) \quad (3)$$

$\alpha_{i,n}$ 的值在一定范围内呈线性递减排列, 即:

$$\alpha_{i,n} = 1.5 - \frac{1.5 - 0.5}{M} \times m \quad (4)$$

其中 m 为排序后的粒子所处的位置编号数。

2) Cauchy 随机数。

一般情况下, QPSO 算法的随机因子都是使用均匀分布产生, 但随着迭代次数的增加, 量子空间逐渐被压缩, 一旦陷入局部最优, 大多数粒子会不断趋同, 整个粒子群就会失去多样性, 如此便很难避免早熟的产生。对此, 有文献提出使用 Gaussian 分布代替均匀分布, 增加粒子后期的活力, 但由于 Cauchy 分布具有较高的两翼概率, 更易得到一个离原点较远的随机数, 比 Gaussian 分布的区域范围更广, 因此, 本文采用 Cauchy 分布^[11] 代替均匀分布生成随机因子。

本文采用标准的 Cauchy 分布 $C(0,1)$ 分布, 首先将随机因子 u 由原来的 $u \sim U(0,1)$ 改为 u 服从 $u \sim C(0,1)$, 其次, 将随机因子 r_1 和 r_2 也改为服从 Cauchy 分布, 即 $r_1, r_2 \sim C(0, 1)$, 则式(1)改进为:

$$\begin{cases} m_{best}(t) = \frac{1}{M} \sum_{i=1}^M p_i(t) = \\ \left(\frac{1}{M} \sum_{i=1}^M \alpha_{i,1} p_{i,1}(t), \frac{1}{M} \sum_{i=1}^M \alpha_{i,2} p_{i,2}(t), \dots, \frac{1}{M} \sum_{i=1}^M \alpha_{i,n} p_{i,n}(t) \right) \\ p(t) = C_1 p_i(t) + C_2 p_g(t) / (C_1 + C_2) \\ x(t+1) = p(t) \pm \beta |m_{best}(t) - x(t)| \ln(1/C) \end{cases} \quad (5)$$

3) 随机收缩-扩张系数。

收缩-扩张系数 β 是 QPSO 算法中唯一重要的初始参数, 较大的 β 有利于粒子的快速收敛, 提高算法的全局搜索能力; 而较小的 β 有利于对当前的搜索区域进行精确局部搜索, 增强算法的局部搜索能力。文献[2] 中详细验证了当 β 为线性递减或者非线性递减时, 对于多数情况下能取得较好的结果, 但这种参数处理方法需要反复的实验才能确定最优值, 并且, 若在搜索的开始阶段未能接近最优值, 则随着 β 的减小和粒子多样性的减弱, 算法易陷入局部最优。

对此, 本文在白俊强等^[12] 的启发下, 将收缩-扩张系数 β 服从某种随机分布, 如果在搜索的开始阶段未能接近最优值, 则 β 的随机生成能使部分粒子跳出局部最优, 重新在可行域中搜索, 进而尽量避免 β 线性或非线性递减所引起的早熟, 因此将式(2)改进为:

$$\begin{cases} \varepsilon = \varepsilon_{\min} + (\varepsilon_{\max} - \varepsilon_{\min}) \times \text{rand}(0,1) \\ \beta = \varepsilon + \sigma \times N(0,1) \end{cases} \quad (6)$$

其中: ε_{\max} 为随机系数的最大值; ε_{\min} 为随机系数的最小值; σ 为随机系数的方差; $N(0,1)$ 为标准正态分布的随机数; $\text{rand}(0,1)$ 为 0 到 1 之间的随机数。

4) 自然选择。

为了在不影响收敛精度的前提下, 尽可能提高粒子在可行域空间的搜索速度, 本文在前人研究^[13] 的基础上, 将自然选择的思想引入到 QPSO 算法的改进方案中, 通过保留优等粒子, 加快淘汰迭代过程中偏离最优解的劣等粒子来实现对算法的改进。

具体的做法是在每次迭代过程中将每一个种群的粒子按适应值 $p_i(t)$ 排序, 通过比较, 用粒子群中最优的 20% 部分的粒子替换最差 20% 部分的粒子, 同时保留每次迭代过程中产生的全局最优值, 以提高粒子群中优等粒子的比重, 以保证 QPSO 算法的收敛速度加快, 并持续保持良好的性能。

综上所述, 本文提出了旨在提高 QPSO 算法收敛精度、搜索速度和克服早熟能力的 3 种性能, 以引入加权系数、Cauchy 随机数、随机收缩-扩张系数和自然选择的 4 种改进方法为基础的一套改进方案, 以此提升 QPSO 算法的综合性能, 如图 1

所示。其中: 引入加权系数是为了提高收敛精度, 引入自然选择是为了提高搜索速度, 引入 Cauchy 随机数和随机收缩-扩张系数是为了防止早熟的产生。

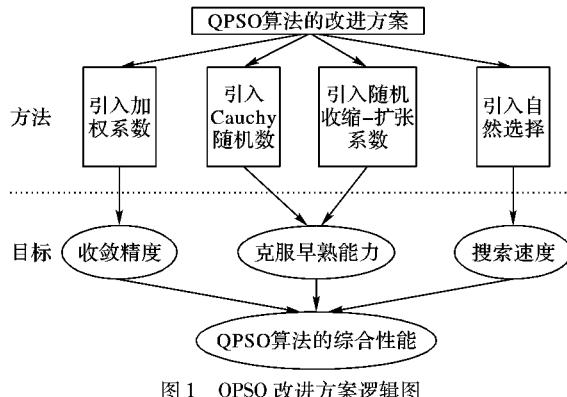


图 1 QPSO 改进方案逻辑图

2 基于改进的 QPSO 的小波神经网络模型

2.1 小波神经网络

WNN 与传统 BP 神经网络的主要区别在于将神经元中的 Sigmoid 激励函数换成小波基函数, 使其具备小波变换的局部化特点和神经网络的自学习性质, 具备较强的非线性逼近能力。

隐含层函数 $\psi_{a,b}(x)$ 采用国内外较多使用的 Morlet 小波基函数^[14], 即:

$$\psi(x) = \cos(1.75x) e^{-\frac{x^2}{2}} \quad (7)$$

网络输出的误差函数采用均方差计算, 即:

$$MSE = \sqrt{\frac{1}{M} \sum_{m=1}^M \sum_{j=1}^J (y_m^j - R_m^j)^2} \quad (8)$$

根据预测误差值, 采用梯度下降法调整连接层权重和小波基系数, 即:

$$\begin{cases} \Delta w = -\eta_1 \frac{\partial MSE}{\partial w} \\ \Delta a = -\eta_2 \frac{\partial MSE}{\partial a} \\ \Delta b = -\eta_2 \frac{\partial MSE}{\partial b} \end{cases} \quad (9)$$

其中: M 为输入样本的规模, J 为输出层节点个数, x_m^i 为输入层样本元素, y_m^j 为对应的实际输出值, $\psi_{a,b}(x)$ 为小波基函数, a_k 和 b_k 分别为第 k 个隐含层节点的伸缩系数和平移系数, η_1 和 η_2 分别为连接层权重和小波基系数的学习概率。

2.2 改进的量子粒子群-小波神经网络的实现

使用基于改进的量子粒子群算法训练小波神经网络 (Modified Quantum Particle Swarm Optimization-Wavelet Neural Network, MQPSO-WNN) 实际上就是将每个维度的粒子向量分别代表 WNN 模型的初始连接层权重 (w_{ik}, w_{kj}) 和小波基系数 (a_k, b_k), 并以均方差误差函数, 即式 (8) 作为 MQPSO 优化的目标函数, 通过反复迭代计算, 一直到适应值趋于稳定为止。在此基础上, 将优化后的参数组合应用到预先设置好的 WNN 模型中进一步训练, 直至搜索到最优网络参数。由于在 MQPSO-WNN 的初始阶段, MQPSO 算法代替了梯度下降法调整 WNN 模型参数, 使得整个网络能够更稳定地在更接近最优解位置进行参数寻优, 从而有效提高了 WNN 寻优速度和精度。

MQPSO-WNN 算法的步骤如图 2 所示。

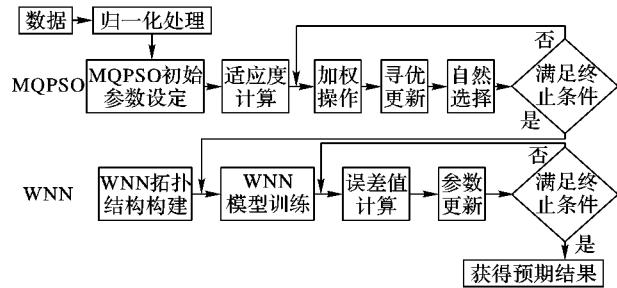


图 2 MQPSO-WNN 算法的步骤

2.3 改进的量子粒子群-小波神经网络的分析

与 BP 神经网络相比, WNN 采用小波基函数取代 Sigmoid 函数作为激励函数, 并引入伸缩、平移因子, 因此具备了更强的容错、识别和预测能力, 但在实际应用中 WNN 存在着初始参数的选取不合适可能导致整个学习过程不收敛的缺点。而 MQPSO 算法拥有精度高、收敛快等良好性能, 因此, 尝试将二者相互耦合, 采用 MQPSO 算法对网络参数进行优化, 得到更适应 WNN 模型的参数组合, 再通过 WNN 进一步精确优化, 能够提高 WNN 模型的稳定性、容错能力及学习能力, 增强其对于实际问题的解决能力。

3 仿真实验

3.1 实验条件

为了验证 MQPSO-WNN 算法的有效性及优越性, 本实验在 CPU 主频 2.20 GHz、内存 2.0 GB 的运行环境下, 使用 Matlab 7.0 软件, 选取 UCI 机器学习数据库中的 3 个标准数据集作为原始数据集(都是典型的复杂非线性预测问题), 分别采用 WNN、PSO-WNN、QPSO-WNN 和 MQPSO-WNN 算法进行预测仿真实验, 进而对比研究。

根据实验的需要, 择优选取了 3 个 UCI 标准数据集进行预测, 相关信息如表 1 所示。

表 1 UCI 标准数据集的相关信息

数据集	样本数	训练集样本数	预测集样本数	属性数	隐节点数
Wine	178	153	25	12	25
Seeds	210	180	30	7	15
Housing	506	426	80	13	27

将每个标准数据集随机分为训练集和预测集的两部分。相关参数设置如下: WNN 的学习概率 η_1, η_2 分别为 0.055 和 0.0055, 最大迭代次数为 500; PSO、QPSO 及 MQPSO 的种群规模 M 为 30, 粒子位置范围为 $[-5, 5]$, 最大迭代次数为 300, 其中, PSO 的加速系数 c_1, c_2 均为 1.49445, 惯性权重为 0.729, 速度范围为 $[-0.8, 0.8]$ 。

实验中的输入输出数据均采用式(10)进行归一化处理, 并对处理好的数据进行相空间重构:

$$X_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (10)$$

其中: $\{x_i\}$ 为原始数据集, $\{X_i\}$ 为归一化处理后的数据集。

实验中采用的误差评价体系包括相对误差值 (Error) 和均方差误差值 (MSE), 即:

$$Error = \frac{|x_i - \hat{x}_i|}{\hat{x}_i} \quad (11)$$

$$MSE = \sqrt{\frac{1}{N_{y_{true}}} \sum_{i=1}^{N_{y_{true}}} (x_i - \hat{x}_i)^2} \quad (12)$$

其中: x_i 为原始数据, \hat{x}_i 为预测数据, $N_{y_{true}}$ 为预测样本的规模。

3.2 实验结果及分析

1) PSO、QPSO 及 MQPSO 的对比分析。

首先, 经过多次反复的实验, 将 PSO、QPSO 和 MQPSO 的 3 种进化算法优化 WNN 模型的收敛情况归类总结, 并进行对比分析, 如图 3~5 所示。

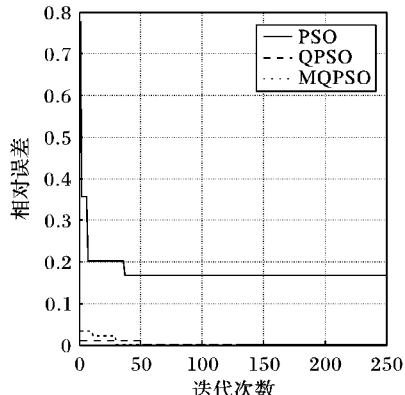


图 3 算法在 Wine 中的收敛情况

比较可以看出: 图 3 中的 PSO 在迭代后期出现了局部最优的情况, 收敛效果和误差精度明显不如 QPSO 和 MQPSO; 图 4、5 中的 MQPSO 较之 QPSO 和 PSO, 收敛曲线更加平稳, 而且能够更加快速地逼近预期误差精度, 具备更好的优化性能, 验证了 MQPSO 优化 WNN 的有效性和优越性。

2) WNN、PSO-WNN、QPSO-WNN 及 MQPSO-WNN 的性能分析。

本文主要通过分析误差和运行时间来评价 WNN、PSO-WNN、QPSO-WNN 和 MQPSO-WNN 的性能。表 2 的实验结果

为对每个数据集反复训练预测 100 次的平均结果。

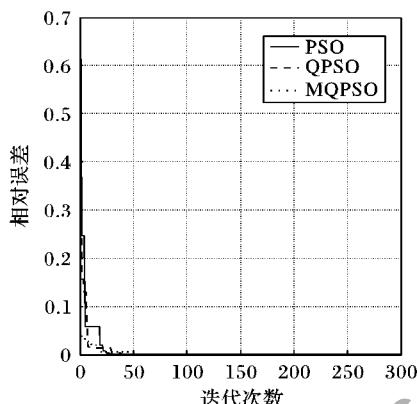


图 4 算法在 Seeds 中的收敛情况

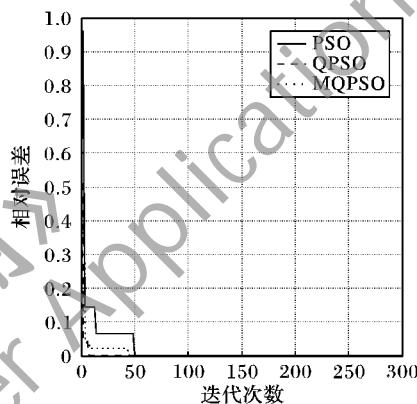


图 5 算法在 Housing 中的收敛情况

表 2 4 种算法实验结果对比

算法	Wine			Seeds			Housing		
	时间/s	相对误差	均方差误差	时间/s	相对误差	均方差误差	时间/s	相对误差	均方差误差
WNN 算法	379	0.0917	7.6808	416	0.0128	0.0277	662	0.094	0.2303
PSO-WNN 算法	316	0.0666	5.8995	383	0.0112	0.0202	671	0.075	0.1869
QPSO-WNN 算法	271	0.0575	5.8926	387	0.0087	0.0186	640	0.066	0.1542
MQPSO-WNN 算法	215	0.0119	4.9163	373	0.0090	0.0173	634	0.059	0.1533

从表 2 的实验结果汇总可以看出, MQPSO-WNN 算法的运行时间较之前三种方法减少了 11%~43%, 而计算相对误差较之降低了 8%~57%。由此可以看出, 在迭代次数相同的情况下, MQPSO-WNN 算法的计算速度更快、误差波动更小, 具备更强的适应能力和更优的预测精度。

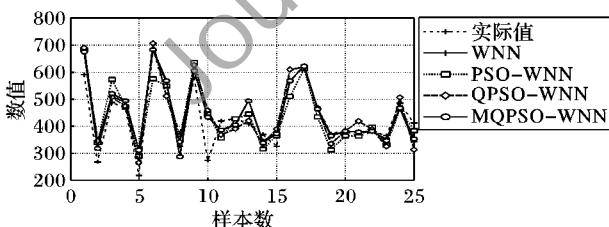


图 6 Wine 的预测效果

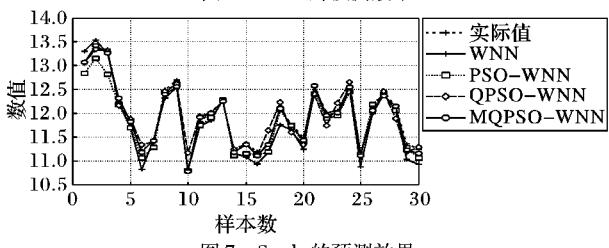


图 7 Seeds 的预测效果

由图 6~8 可以直观地看出 MQPSO-WNN 的预测精度更

高、预测效果更优, 进一步验证了 MQPSO-WNN 算法的有效性和优越性, 表现出良好的计算性能。

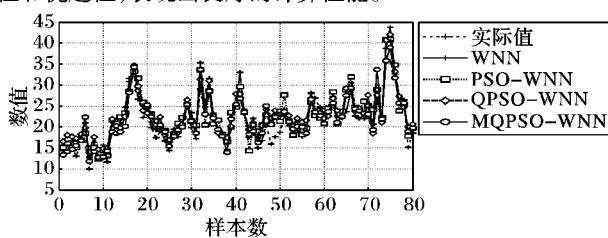


图 8 Housing 的预测效果

4 结语

本文主要做了两个方面的工作: 一方面针对 QPSO 算法易早熟、后期多样性差以及搜索精度不高等缺点, 提出了一套包括引入加权系数、引入 Cauchy 随机数、改进收缩-扩张系数和引入自然选择的改进方案; 另一方面, 针对 WNN 的初始参数选取不合适可能导致整个学习过程不收敛的缺点, 将改进后的 QPSO 算法优化 WNN 的参数组合, 实现两种算法的耦合。仿真实验表明: 改进后的 QPSO 算法提高了 WNN 的学习能力和泛化能力, 使得 MQPSO-WNN 拥有稳定性好、收敛速度快、预测精度高等优点, 值得进一步深入研究与实践应用。

(下转第 3143 页)

中 T 的取值范围为 {20, 40, 60, 80, 100} , 而 ML-LVQ 在集合 {1, 3, 5, 7, 9} 上优化超参数 S 。

表 2 中测量运行时间; $S = 9$, $T = 100$ 。从中可知, ML-LVQ 算法在 4 个评价准则上都取得了比 AdaBoost. LRMH 更好的性能, 尤其在 $mac\text{-}F1$ 上(从 90.97% 到 94.57%), 这表明 ML-LVQ 无论是在判别食用油(纯油或混合油)的组成成分方面还是在判别组成成分的比重方面都表现更优。

表 2 两种算法在 4 个评价准则上的比较

算法	评价准则/%				运行 时间/s
	one-error	avg-prec	mac-F1	mic-F1	
ML-LVQ	1.05	98.66	94.57	97.22	58.47
AdaBoost. LRMH	3.24	97.03	90.97	96.03	113.82

AdaBoost. RMH 算法的训练时间复杂度和测试时间复杂度分别为 $O(T(dN \log N + NL))$ 和 $O(TL)$, 而 ML-LVQ 的训练时间复杂度为 $O(NTLSD)$, 测试时间复杂度为 $O(LSd)$ 。表 2 的最后一栏显示了 ML-LVQ 取参数 $S = 9$ 和 AdaBoost. LRMH 取参数 $T = 100$ 时的运行时间比较。显然, ML-LVQ 在数据集上运行得更快一些, 近似地比后者快一倍。

4 结语

本文提出了一个多标号学习矢量量化算法(ML-LVQ)应用于食用油的掺伪检测, 它通过最小化排序损失的上界来优化多标号的排序(ranking)准则函数, 利用元标号分类器提高二分(bipartition)准则函数。前者能将混合油中的各成分按比重大小正确排序, 而后者能有效地区分混合油或纯油的组成成分。在 9 类食用油以及它们的混合所组成的样本上测试的结果显示, ML-LVQ 在 4 种准则函数上均取得了比改进的多标号 AdaBoost. RMH 算法更优的性能。

参考文献:

- [1] 宋玉峰, 王微山, 杨学军, 等. 食用油掺假检测方法研究进展[J]. 中国食物与营养, 2012, 18(3): 9–12.
- [2] 方伟, 孙俊, 谢振平, 等. 量子粒子群优化算法的收敛性分析及控制参数研究[J]. 物理学报, 2010, 59(6): 3686–3694.
- [3] 龙海侠, 须文波, 王小根, 等. 基于选择操作的量子粒子群算法[J]. 控制与决策, 2010, 25(10): 1499–1506.
- [4] SUN J, XU W B, FANG W. Quantum-behaved particle swarm optimization with a hybrid probability distribution [C]// Proceedings of the 9th Pacific Rim International Conference on Artificial Intelligence, LNCS 4099. Berlin: Springer-Verlag, 2006: 737–746.
- [5] LIU J, SUN J, XU W B. Improving quantum-behaved particle swarm optimization by simulated annealing [C]// Proceedings of the 2006 International Conference on Computational Intelligence and Bioinformatics, LNCS 4115. Berlin: Springer-Verlag, 2006: 130–136.
- [6] LIU J, SUN J, XU W B. Quantum-behaved particle swarm optimization with immune memory and vaccination [C]// Proceedings of the 2006 IEEE International Conference on Granular Computing. Piscataway: IEEE Press, 2006: 453–456.

- [2] CHRISTOPHER M. Pattern recognition and machine learning [M]. Berlin: Springer, 2006: 561–569.
- [3] HAI Z, WANG J. Detection of adulteration in camellia seed oil and sesame oil using an electronic nose [J]. European Journal of Lipid Science and Technology, 2006, 108(2): 116–124.
- [4] PATRICIA C M, JANSEN H G, IRENE B M, et al. The use of multivariate modelling of near infrared spectra to predict the butter fat content of spreads [J]. Analytica Chimica Acta, 2007, 595(1/2): 176–181.
- [5] HUO Q G, JIN X B, ZHANG H M. Multi-label classification for oil authentication [C]// FSKD 2012: Proceedings of the 2012 International Conference on Fuzzy Systems and Knowledge Discovery. Piscataway: IEEE Press, 2012: 711–714.
- [6] SCHAPIRE R E, SINGER Y. Improved boosting algorithms using confidence-rated predictions [J]. Machine Learning, 1999, 37(3): 297–336.
- [7] SCHAPIRE R E, SINGER Y. Boostexter: a boosting-based system for text categorization [J]. Machine Learning, 2000, 39(2/3): 135–168.
- [8] JIN X B, HOU X W, LIU C L. Prototype learning with margin-based conditional log-likelihood loss [C]// ICPR 2008: Proceedings of the 2008 International Conference of Pattern Recognition. Piscataway: IEEE Press, 2008: 1–4.
- [9] JIN X B, LIU C L, HOU X W. Regularized margin-based conditional log-likelihood loss for prototype learning [J]. Pattern Recognition, 2010, 43(7): 2428–2438.
- [10] TANG L, RAJAN S, NARAYANAN V K. Large scale multi-label classification via metalabeler [C]// WWW'09: Proceedings of the 18th International Conference on World Wide Web. Piscataway: IEEE Press, 2009: 211–220.
- [11] 郭涛, 杜蕾蕾, 万辉, 等. 高效液相色谱法测胆固醇含量鉴别地沟油[J]. 食品科学, 2009, 30(22): 286–289.
- [12] TSOUmakas G, Katakis I, Vlahavas I. Mining multi-label data [M]. Berlin: Springer, 2010: 667–685.

(上接第 3110 页)

参考文献:

- [7] COELHO L S. Novel Gaussian quantum-behaved particle swarm optimizer applied to electromagnetic design [J]. IET Science, Measurement and Technology, 2007, 11(2): 290–294.
- [8] 林星, 冯斌, 孙俊, 混沌量子粒子群优化算法[J]. 计算机工程与设计, 2008, 29(10): 2610–2612.
- [9] 许少华, 王皓, 王颖, 等. 一种改进的量子粒子群优化算法及其应用[J]. 计算机工程与应用, 2011, 47(20): 34–37.
- [10] XI M L, SUN J, XU W B. An improved quantum-behaved particle swarm optimization algorithm with weighted mean best position [J]. Applied Mathematics and Computation, 2008, 205(5): 751–759.
- [11] 许磊. 电力系统经济调度的放置研究[J]. 计算机仿真, 2012, 29(9): 324–327.
- [12] 白俊强, 尹戈玲, 孙智伟. 基于二阶振荡及自然选择的随机权重混合粒子群算法[J]. 控制与决策, 2012, 27(10): 1459–1464.
- [13] 刘耀年, 尹洪全, 张伟, 等. 基于改进粒子群算法的配电网状态估计[J]. 电测与仪表, 2012, 49(9): 24–27.
- [14] JIAN C L, ZHI H G, HUI Q W. Research on the application of the wavelet neural network model in peak load forecasting considering of the climate factors [C]// Proceedings of the 4th International Conference on Machine Learning and Cybernetics. Piscataway: IEEE Press, 2005: 538–543.