

基于改进鲸鱼算法的BP神经网络水资源需求预测方法

马 创 周代棋 张 业

重庆邮电大学软件工程学院 重庆 400065

摘 要 随着现代居民居住地愈发集中,供水管网规模不断扩大,水资源供给面临着新的困难和挑战。其中包括水资源调度时的动态变化、管网的突发故障、水资源的不可控流失以及多目标和计算量庞大等问题。BP神经网络因拥有较强的自学习能力和泛化能力而被广泛应用于水资源预测问题中,但其也存在收敛速度慢、容易陷入局部极值的问题。群智能算法作为一种寻优算法,具有操作简单、收敛速度快、全局寻优能力强等优点。为提高BP神经网络在水资源预测方面的收敛速度和预测精度,提出一种基于改进鲸鱼算法优化的BP神经网络水资源需求预测模型,通过改变鲸鱼优化算法收敛因子的计算方式以及增加惯性权重来加强算法的寻优广度和精度,再通过BP神经网络采用改进的WOA算法输出的最优权值、阈值作为初始参数值训练模型。实验验证,改进的WOA-BP神经网络方法相比传统WOA-BP方法在收敛速度和预测精度方面都有更优的表现。

关键词: 鲸鱼优化算法;BP神经网络;水资源需求预测

中图分类号 TP181

BP Neural Network Water Resource Demand Prediction Method Based on Improved Whale Algorithm

MA Chuang, ZHOU Dai-qi and ZHANG Ye

School of Software Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract With the increasing concentration of modern residential areas and the continuous expansion of water supply network, water supply is facing new difficulties and challenges. It includes the dynamic change of water resource scheduling, the sudden breakdown of pipe network, the uncontrollable loss of water resources, multi-objective and huge calculation. BP neural network has been widely used in water resources prediction because of its strong self-learning ability and generalization ability, but it also has the problems of slow convergence and easy to fall into local extremes. As a kind of optimization algorithm, swarm intelligence algorithm has simple operation, fast convergence speed and strong global optimization ability. In order to improve the convergence speed and prediction accuracy of BP neural network in water resources prediction, a BP neural network water resource demand prediction model based on the optimization of improved whale algorithm is proposed. The optimization breadth and accuracy of the algorithm are strengthened, and then the optimal weights and thresholds output by the improved WOA algorithm are used as initial parameter values to train the model through BP neural network. Through experimental verification, the improved WOA-BP neural network method has better performance in terms of convergence speed and prediction accuracy than the traditional WOA-BP method.

Keywords Whale optimization algorithm, BP neural network, Water resources demand prediction

1 引言

水资源量偏低,严重影响了我国经济和社会的可持续发展^[1]。

水资源优化配置是实现水资源可持续发展和提高水资源利用率的重要途径^[2-3]。城市区域水资源调度问题,需要考虑

我国水资源分布不均衡,各地区水资源供需不平衡,人均

基金项目:国家自然科学基金面上项目(6172099);重庆市高校创新团队建设项目(CXTDG201602010);重庆市“三百”科技创新领军人才支持计划(CSTCCXLJRC201917);重庆市高校优秀成果转化资助项目(KJZH17116);重庆市人工智能技术创新重大主题专项(CSTC2017rgzn-zdyf0140);重庆市创新创业示范团队培育计划(CSTC2017kjrc-excytd0063);重庆市技术创新与应用示范重大主题专项项目(CSTC2018JSZX-CYZZX0178, CSTC2018JSZX-CYZZX0185);重庆市基础科学与前沿技术研究项目(CSTC2017jcyjAX0270, CSTC2018jcyjA0672, CSTC2017jcyjAX0071)

This work was supported by the Surface Project of National Natural Science Foundation of China (6172099), Program for Innovation Team Building at Institutions of Higher Education in Chongqing (CXTDG201602010), Science and Technology Innovation Leadership Support Program of Chongqing (CSTCCXLJRC201917), University Outstanding Achievements Transformation Funding Project of Chongqing (KJZH17116), Artificial Intelligence Technology Innovation Important Subject Projects of Chongqing (CSTC2017rgzn-zdyf0140), Innovation and Entrepreneurship Demonstration Team Cultivation Plan of Chongqing (CSTC2017kjrc-excytd0063), Industry Important Subject Projects of Chongqing (CSTC2018JSZX-CYZZX0178, CSTC2018JSZX-CYZZX0185) and Chongqing Research Program of Basic Research and Frontier Technology (CSTC2017jcyjAX0270, CSTC2018jcyjA0672, CSY2017jcyjAX0071).

通信作者:马创(machuang@cqupt.edu.cn)

地区用水量、地区降水量、非常规用水等诸多问题。城市供水网建设的完善以及数据采集技术的进步,积累了大量的地区不同类型用水及供水数据。这些数据为水资源需求预测提供了可靠的依据,使得有效规划供水量成为可能,提高了城市整体用水效率。

大规模的水资源调度实验研究最早源于 20 世纪 40 年代 Mass 提出的水库优化调度问题,其在 50 年代中期创立的系统工程在水库(群)优化调度中得到了广泛应用^[4]。随着时间的推移,不断有学者提出新的相关解决方法,较常用的动态规划方法、大系统协调分解方法、传统统计方法和人工智能方法。其中,传统统计方法和人工智能方法主要用于水资源预测。传统统计方法以自回归积分移动平均模型(ARIMA)为代表,实现了短期的水资源消耗预测。人工智能方法包括人工神经网络(ANNs)、随机森林(RF)、支持向量机(SVMs)和群智能优化算法等,被广泛应用于水资源需求预测中。人工神经网络因为对非线性数据预测有较好的拟合效果而得到了广泛应用。文献[5]提出的改进组合神经网络引入模糊反馈法来改进嫡值法,使模型可以根据历史数据自动推演水资源需求的变化趋势,并引入反馈和演化机制使得可以调整模型的求解精度和收敛速度。文献[6]提出的基于粗糙集和 BP 神经网络的流域水资源脆弱性预测方法,利用 BP 神经网络对河流指标数据与脆弱度之间的映射关系进行拟合。但传统 BP 神经网络模型通常存在易陷入局部最小,初始阈值和权值随机赋予以及网络训练震荡等现象^[6]。因此,网络参数的选取在预测模型中至关重要,参数选取不当会造成网络收敛速度慢、预测精度低等一系列问题。为了解决这一问题,当前普遍采用群智能算法优化神经网络结构,以此来找到最佳的权值和阈值,确定最优的模型结构和参数。典型的群智能算法包括粒子群算法^[7]、蚁群优化算法^[8]、人工鱼群算法^[9]、萤火虫算法^[10]、果蝇优化算法^[11]和白蚁算法^[12]。文献[13]对粒子群算法进行改进,使之对最佳位置的搜索从全局范围逐渐向局部范围转变,并将其应用到 BP 神经网络的权值阈值筛选中,实现了对天气的精准预测。文献[14]采用人工鱼群算法对小波神经网络输入和输出权值及伸缩和平移系数进行了寻优修正,实现了更快、更准确的变压器故障诊断。

2016 年澳大利亚学者 Mirjalili 提出一种新的群智能算法:鲸鱼优化算法(WOA)^[15]。该算法操作简单,跳出局部最优的能力较强,调整参数较少。该算法经常与其他算法相结合来解决计算问题中的寻优问题。文献[16]提出了一种鲸鱼算法优化的最小二乘支持向量机预测模型,用于模型中的残差修正。尽管寻优能力较强,但 WOA 算法在面对复杂的优化问题时依然无法避免易陷入局部最优解和收敛速度慢等问题。为了克服这些问题,本文在预测模型中提出一种改进收敛因子和增加自适应权重的鲸鱼优化算法,避免 WOA 提前进入早熟现象,并且加快收敛速度。因此,本文提出一种基于改进鲸鱼算法的 BP 神经网络的水资源需求预测模型。

2 改进的鲸鱼优化算法

2.1 鲸鱼优化算法

鲸鱼优化算法是一种元启发式群智优化算法,具有调整

参数少、操作简单、易于理解等特点。该算法模仿了座头鲸“螺旋气泡网”策略,主要包括随机找寻猎物、包围选定猎物和捕食选定猎物 3 种行为。

(1) 随机找寻猎物

寻找某个问题的解可以理解成鲸鱼群寻找猎物的过程,其随机找寻猎物的过程可转化为如下数学模型:

$$D = |X(t) - C X_{\text{rand}}(t)| \quad (1)$$

$$X(t+1) = X_{\text{rand}} - A D \quad (2)$$

其中, X_{rand} 为从当前鲸群中随机选择的位置向量,其中包含了可行解。 X 为个体所在的位置向量; t 表示当前迭代次数; A 和 C 是系数,其计算方法如下:

$$A = 2a \cdot r_1 - a \quad (3)$$

$$C = 2r_2 \quad (4)$$

$$a = 2 - 2t/T_{\text{max}} \quad (5)$$

其中, r_1 和 r_2 属于区间 $[0,1]$ 之间的随机数; a 在迭代过程中线性减小; T_{max} 表示迭代次数的最大值。

(2) 包围目标猎物

靠近可行解的计算过程可以模拟为座头鲸靠近选定猎物的活动^[17]。如果认定此猎物是当前的最佳猎物,则更新位置,数学模型如下:

$$D = |X(t) - C X_{\text{best}}(t)| \quad (6)$$

$$X(t+1) = X_{\text{best}}(t) - A \cdot D \quad (7)$$

其中, t 为当前迭代次数; A 和 C 为系数; $X_{\text{best}}(t)$ 为当前最佳位置; $X(t)$ 为当前所在位置。

(3) 捕食目标猎物

座头鲸通过螺旋上升的方式来更新位置,进而捕猎选定的猎物。数学模型如下:

$$X(t+1) = D' \cdot e^{bl} \cdot \cos(2\pi l) + X^* \quad (8)$$

$$D' = |X^*(t) - X(t)| \quad (9)$$

其中, b 为对数螺旋线状常数, l 为在区间 $[-1,1]$ 的随机数。式(9)表示第 i 头鲸群个体当前最佳位置与猎物之间的距离。

在模型中,通过减小式(3)中 a 的值来实现收缩环绕机制, A 的波动范围会随着 a 的减小而不断减小。 A 是在区间 $[-a,a]$ 内的随机值,设置 A 为区间 $[-1,1]$ 的随机值,则搜索代理新的位置会随机出现在之前的位置与当前最优解位置之间的某一处。座头鲸收缩环绕的同时沿着螺旋路径向选定猎物移动,两者行为是同时发生的,数学模型如下:

$$X(t+1) = \begin{cases} X^*(t) - A \cdot D, & p < 0.5 \\ X^*(t) + D' \cdot e^{bl} \cdot \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (10)$$

其中, p 为 $[0,1]$ 区间内的随机数。

2.2 非线性收敛因子

从 WOA 算法式(2)可知,算法的全局搜索和局部探索能力主要依赖于参数 A ,由式(3)、式(5)可知参数 A 的取值主要依赖于收敛因子 a 。较大的收敛因子能够提供强有力的全局搜索能力,避免算法过早进入局部最优解,形成早熟;较小的收敛因子使算法具有较强的局部探索能力,能加快算法的收敛速度,提升算法效率^[15]。在传统的 WOA 算法中,收敛因子是随着迭代次数而递归减少的,这种方法容易导致算法收敛速度过慢。为了解决这一问题,在不改变收敛因子变化趋势的前提下,采用非线性调整策略,一方面能保证算法全局

搜索能力及局部探索能力,另一方面能加快算法的收敛速度。公式如下:

$$a = (2 - 2t/T_{\max})(1 - t^3/T_{\max}^3) \quad (11)$$

其中, t 代表当前迭代次数; T_{\max} 为最大迭代次数。此方法能保证在算法迭代早期生成较大的参数 A , 以保证全局搜索能力, 同时加快算法收敛速度; 在迭代后期, 则生成较小的参数 A , 以提升算法的局部探索能力。

2.3 自适应权重

惯性权重对算法收敛速度和全局寻优能力都有较大的影响^[18]。但由于 WOA 算法在优化过程中是非线性变化的, 惯性权重的线性下降策略无法体现在实际的优化过程中, 同时考虑到各搜索代理状态的差异性, 本文利用一种基于搜索代理当前状态的非线性自适应权重策略, 其数学模型如下:

$$\omega(t)_i = \begin{cases} \omega_1 - \frac{\omega_2 - \omega_1}{T_{\max}} \cdot \frac{f(t)_i - f(t)_{\min}}{f(t)_{\max} - f(t)_{\min}}, & f(t)_i < f(t)_{\text{avg}} \\ \omega_2 + \frac{(\omega_2 - \omega_1)}{T_{\max}} \cdot \frac{f(t)_i - f(t)_{\text{avg}}}{f(t)_{\max} - f(t)_{\min}}, & f(t)_i \geq f(t)_{\text{avg}} \end{cases} \quad (12)$$

其中, $\omega(t)_i$ 为第 i 个搜索代理在第 t 次迭代的权重, T_{\max} 表示最大的迭代次数, ω_1 为初始最小权重, ω_2 为初始最大权重, $f(t)_{\text{avg}}$ 表示当前第 t 次迭代后种群的平均适应度值, $f(t)_{\min}$ 和 $f(t)_{\max}$ 则分别代表第 t 次迭代后的最小适应度值和最大适应度值。

从式(12)中可以看出, 当搜索代理的适应度值小于平均适应度值时, 权重 ω 较小, 这保证了在最优解附近空间中的精细搜索; 当适应度值大于平均适应度值时, 权重 ω 较大, 这使得搜索代理可以在更大范围空间寻优。 ω 会随着当前种群平均适应度值和个体搜索代理适应度值进行自适应变化, 以此来有效提高 WOA 算法的收敛速度和精度。将式(12)代入式(10)后形成改进后的捕食猎物时的位置更新策略, 数学模型如下:

$$X(t+1) = \begin{cases} \omega(t) \cdot X^*(t) - A \cdot D, & p < 0.5 \\ \omega(t) \cdot X^*(t) + D' e^{bl} \cdot \cos(2\pi l), & p \geq 0.5 \end{cases} \quad (13)$$

2.4 算法步骤

改进后的鲸鱼优化算法的具体步骤如下:

- 1) 初始化参数: 种群数量 N 、最大迭代次数 T_{\max} 、初始最小权重 ω_1 、初始最大权重 ω_2 、当前迭代次数 $t=0$ 。
- 2) 计算每个个体的适应度值, 记录当前最优的适应度值和其对应的位置向量。
- 3) 计算并更新每个个体的 a, A, C, l, p 和 ω 值, 其中使用式(11)来计算 a 的值。
- 4) 如果 $|A| \geq 1$, 按式(2)更新下一代的位置。
- 5) 如果 $|A| < 1$, 按式(13)更新下一代的位置。
- 6) 判断是否达到了循环结束条件, 若是, 则结束算法, 输出最优解; 否则, 返回步骤 2)。

3 基于改进鲸鱼 WOA 优化 BP 神经网络预测模型

3.1 BP 神经网络

BP 神经网络是一种多层的前馈神经网络, 其主要的特点是: 信号是前向传播的, 而误差是反向传播的。BP 神经网络

的过程主要分为两个阶段, 第一阶段是信号的前向传播, 即从输入层经过隐藏层, 最后再到达输出层; 第二阶段是误差的反向传播, 将输出层的结果与预期结果做对比, 从输出层到隐含层, 最后到输入层, 依次调节隐含层到输出层的权重和偏置、输入层到隐含层的权重和偏置。BP 神经网络具有自学习能力、非线性函数映射能力, 且鲁棒性强。三层 BP 神经网络的结构如图 1 所示。




图 1 单隐含层 BP 神经网络拓扑结构

Fig. 1 Single hidden layer BP neural network topology

有监督的 BP 神经网络算法的过程如下:

- 1) 网络初始化, 给各连接权值分别赋一个 $(-1, 1)$ 区间内的随机数, 设定误差函数 e , 给定计算精度值 ϵ 和最大学习次数 M 。
- 2) 随机选取第 k 个输入样本及对应期望输出。
- 3) 计算隐藏层各神经元的输入和输出。
- 4) 利用网络期望输出和实际输出, 计算误差函数对输出层的各神经元的偏导数 $\delta_o(k)$ 。
- 5) 利用输出层各神经元的 $\delta_o(k)$ 和隐含层各神经元的输出来修正连接权值 $\omega_{ho}(k)$ 。
- 6) 利用隐藏层各神经元的 $\delta_h(k)$ 和输入层各神经元的输入修正连接权值。
- 7) 计算全局误差。
- 8) 判断网络误差是否在可接受范围内, 当误差达到预设精度或学习次数大于设定的最大次数时, 结束算法; 否则, 选取下一个学习样本及对应的期望输出, 返回到第 3) 步, 进入下一轮学习。

3.2 改进的 WOA 算法优化 BP 神经网络

改进的 WOA 算法优化 BP 神经网络的基本思想是: 利用改进后的 WOA 算法优化 BP 神经网络的初始权值和阈值, 将 BP 神经网络的训练误差作为个体的适应度值, 选择最优的 BP 神经网络初始权值和阈值。具体的流程如下:

- 1) BP 神经网络初始化。确定网络的输入和输出结构、初始的连接权值和阈值。
- 2) 改进后的 WOA 初始化。将步骤 1) 中的初始权值和阈值转化为改进后的 WOA 的位置向量; 并且初始化算法的其他基本参数, 设置种群规模 N 、最大迭代次数 T_{\max} 、初始最小权重 ω_1 、初始最大权重 ω_2 和收敛因子 a 。同时, 将改进的 WOA 的适应度函数 $F(x)$ 作为模型预测输出值与实测值之间的均方误差。
- 3) 计算个体适应度值。找出最优适应度值的位置, 记录下位置向量并将其作为当前最优个体位置 $x_{\text{best}}(t)$ 。
- 4) 根据 A 的值来采取不同的位置更新策略。如果 $|A| \geq 1$, 按式(2)更新下一代的位置; 如果 $|A| < 1$, 按式(13)更新下一代的位置。
- 5) 满足最大迭代次数或达到误差精度要求后终止寻优算

法,将当前的最优参数赋值给 BP 神经网络。

改进后的预测模型的流程图如图 2 所示。

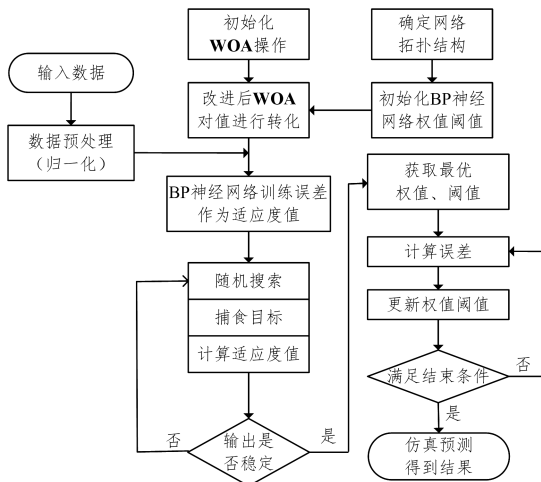


图 2 改进的预测模型流程图

Fig. 2 Optimized predictive model flow chart

4 实验结果及分析

4.1 实验数据集

本节将采用美国地质勘探局(USGS)的两份数据集。其中,数据集 A 记录了某地区从 2012 年 1 月到 2018 年 9 月的用水分类及对应用水量。数据集 B 记录了该地区对应水站的供水量及入库量。数据示例如表 1、表 2 所列。

表 1 数据集 A 示例

Table 1 Example of data set A

Time	Type	Assumption	Region code
201809	Irrigation-Multi-Family	22 830	78 613
201809	Multi-Family	338 430	78 613

表 2 数据集 B 示例

Table 2 Example of data set B

Time	Supply	Receipt
201809	41 843. 4	41 753. 3
201807	45 429. 2	65 432. 3

4.2 基于改进 WOA 的 BP 神经网络方法的实验分析

为验证模型的有效性,将改进后的预测模型对供水量的预测结果与传统的 BP 神经网络、传统 WOA 优化的 BP 神经网络进行对比实验。将上述数据集作为 3 种对比实验的输入,以验证模型在获得历史数据情况下对未来水资源供水量的预测效果。

神经网络模型的参数设置为:迭代次数 $epo=100$,学习率 $lr=0.1$,目标误差 $goal=0.00001$ 。WOA 的模型参数设置为:种群规模 $N=50$,最大迭代次数 $T_{max}=50$,最小权重 $w_1=0.5$,最大权重 $w_2=0.9$ 。利用每月用水分类对应的用水量及当月的水站入库量作为输入,输出该地区当月的用水量预测值。3 个模型的预测结果与真实值的对比如图 3 所示。从图 3 中可以看到,只使用 BP 神经网络进行预测时得到的值和真实值差距较大,而使用 WOA-BP 神经网络进行预测时得到的值比 BP 神经网络更为接近真实值。但相比上述两种模型,改进的 WOA-BP 模型得到的值的变化趋势和准确性都明显与真实值更接近。




图 3 几种模型的预测值与真实值的对比

Fig. 3 Comparison of improved models

图 4 为传统 WOA-BP 神经网络与改进的 WOA-BP 神经网络模型的预测误差率对比,图 5 为传统 WOA-BP 神经网络与改进的 WOA-BP 神经网络模型的适应度值变化实验对比。




图 4 模型预测误差的对比

Fig. 4 Comparison of prediction errors




图 5 模型适应度值的对比

Fig. 5 Comparison of fitness values

从图 4 中可以看到,改进的 WOA-BP 神经网络模型比传统 WOA-BP 神经网络模型的预测误差率小,改进的模型正确率为 92%~98%,传统的模型正确率为 88%~92%。图 5 中,改进 WOA-BP 神经网络模型在 20 代左右时趋于稳定,而传统的 WOA-BP 神经网络模型在 25 代后才趋于稳定。由图 5 可知,改进的 WOA 方法加快了模型的收敛速度。

综合上述实验,我们可以清晰地看到改进后的 WOA-BP 神经网络模型无论在预测值、误差率还是收敛速度方面都明显优于传统方法。

结束语 本文介绍了一种基于改进 WOA 的 BP 神经网络水资源需求预测方法,该方法主要利用改进的 WOA 克服传统 BP 神经网络容易达到局部极小值的问题,提高了模型的收敛速度和预测精度。本文首先对本模型提出的背景进行阐述;然后介绍了模型中所涉及到的相关算法,并对算法进行阐释;之后具体阐述了本文所提算法的主要思想和步骤;最后采用 USGS 提供的某地区用水量及水站数据集进行了实验验证,并将所提算法与传统 BP 神经网络、传统 WOA-BP 神经网络进行了对比分析。实验结果表明,该方法在各方面都优于传统方法。

下一步研究,仍需要进一步分析 WOA 的收敛因子、初始权重对算法性能的影响,尽力提高其寻优的效率。而且,本文

分析的情况较少,下一步需要针对用水量因天气、突发事件等其他因素影响发生不规则变化时的水资源需求进行分析,考虑更多的因素来保证模型的实用性和可行性。

参 考 文 献

- [1] CHEN Z K. Sustainable development and utilization of water resources in China in the 21st century [J]. *Engineering Science*, 2000, 2(3): 7-11.
- [2] WANG H, YOU J J. Research progress and progress in rational allocation of water resources [J]. *Journal of Hydraulic Engineering*, 2008, 39(10): 1168-1175.
- [3] WEI J, MEI Y D, YANG N, et al. Research Status and Development Trend of Modern Water Resources Allocation [J]. *Advances in Science and Technology of Water Resources*, 2009, 29(4): 73-77.
- [4] HE B F. Regional Water Resources Optimization Model Based on Genetic Algorithm [J]. *International Journal Hydroelectric Energy*, 2002(9): 10-12.
- [5] WANG J. Research on water resources prediction based on improved combined neural network [J]. *Computer Science*, 2016, 43(S1): 516-517, 532.
- [6] LIU Q Q, CHEN Y. Water Resources Vulnerability Prediction Based on Rough Set and BP Neural Network; A Case Study of Huaihe River [J]. *Resources and Environment in The Yangtze Basin*, 2016, 25(9): 1317-1327.
- [7] KENNEDY J, EBERHART R. Particle swarm optimization [C] // *Proceedings of the 1995 IEEE international Conference on Neural Networks*. Perth, WA, Australia; IEEE, 1995: 1942-1948.
- [8] DORIGO M, BIRATTARI M, STUTZLE T. Ant colony optimization [J]. *Computational Intelligence Magazine*, 2007, 1(4): 28-39.
- [9] LI X L, SHAO Z J, QIAN J X. An Optimization Model Based on Animal Autonomy; Fish School Algorithm [J]. *System Engineering Theory and Practice*, 2002, 22(11): 32-38.
- [10] YANG X S. Firefly algorithm, stochastic test functions and design optimization [J]. *International Journal of Bio-inspired Com-*

putation, 2010, 2(2): 78-84.

- [11] PAN W T. A new fruit fly optimization algorithm: taking the financial distress model as an example [J]. *Knowledge-based Systems*, 2012, 26(2): 69-74.
- [12] MARTIN R, STEPHEN W. Termite: A swarm intelligent routing algorithm for mobile wireless Ad-Hoc networks [M]. New York: Stigmergic optimization, 2005.
- [13] SHEN Y G. Application of Improved Particle Swarm BP Neural Network Algorithm in Weather Forecast [J]. *Computer Ear*, 2019(8): 18-20, 36.
- [14] JIA Y M, SHI M P, YAN X. Improved artificial fish swarm algorithm to optimize wavelet neural network for transformer fault diagnosis [J]. *Editorial Board of Journal of HPU (Nature Science)*, 2019, 38(2): 103-109.
- [15] IMIRJALILI S, LEWIS A. The whale optimization algorithm [J]. *Advances in Engineering Software*, 2016(95): 51-67.
- [16] FENG C, YU C G, SUN L, et al. Track irregularity prediction based on improved GM(1, 1) and WOA-LSSVM combined prediction model [J]. *Railway Standard Design*, 2019, 63(4): 34-39, 46.
- [17] ZHANG H L, LV J Y, CHENG L. Parameter Tuning of Controller of Electric Vehicle Induction Drive System Based on WOA [J]. *Journal of Shandong Agricultural university (Nature Science)*, 2019, 50(1): 163-166.
- [18] SHI Y, EBERHART R. A Modified Particle Swarm Optimizer [C] // *Proceedings of 1998 IEEE World Congress on Computational Intelligence*. Washington D. C. , USA; IEEE Press, 1998: 69-73.



MA Chuang, born in 1984, Ph.D, associate professor. His main research interests include complex network and machine learning.

(上接第 478 页)

- [19] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500): 2323-2326.
- [20] CHENG B, YANG J, YAN S, et al. Learning With l1-Graph for Image Analysis [J]. *IEEE Transactions on Image Processing*, 2009, 19(4): 858-866.
- [21] LIU G, LIN Z, YAN S, et al. Robust recovery of subspace structures by low-rank representation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(1): 171-184.
- [22] LU C Y, MIN H, ZHAO Z Q, et al. Robust and efficient subspace segmentation via least squares regression [C] // *European Conference on Computer Vision*. Springer, 2012: 347-360.
- [23] LYONS M, AKAMATSU S, KAMACHI M, et al. Coding facial expressions with gabor wavelets [C] // *Proceedings Third IEEE International Conference on Automatic Face and Gesture Recognition*. IEEE, 1998: 200-205.
- [24] SAMARIA F S, HARTER A C. Parameterisation of a stochastic model for human face identification [C] // *Proceedings of 1994*

IEEE Workshop on Applications of Computer Vision. 1994: 138-142.

- [25] NENE S A, NAYAR S K, MURASE H. Columbia object image library (COIL-20): CUCS-005-96 [R]. 1996.
- [26] FANG X, XU Y, LI X, et al. Orthogonal self-guided similarity preserving projection for classification and clustering [J]. *Neural Networks*, 2017, 88: 1-8.



YI Yu-gen, born in 1986, Ph.D, lecturer. His research interests include artificial intelligence, computer vision, and machine learning.



DAI Jiang-yan, born in 1985, postdoctor, associate professor. Her main research interests include image inpainting and computer vision.