

doi: 10.7690/bgzd.2025.05.014

## 基于粒子群算法优化 BP 神经网络的森林降水量预测

于万荣, 田淙海, 刘奎军, 邱旭梅, 郭文昕  
(山西省气象局山西省气象服务中心, 太原 030002)

**摘要:** 针对森林降水量预测传统方法的缺点, 提出粒子群算法优化 BP 神经网络森林降水量预测方法。将 2020—2022 年森林降水量作为数据集进行对比实验, 实验证明 PSO-BP 神经网络算法相较于 LSTM 模型和传统的 BP 神经网络, 误差明显降低, 预测精度更高, 同时训练集和测试集提升了 5%~11%, 降低了泛化误差, 适用于数据量较大的森林降水量预测。结果表明, 该方法为后续森林降水量预测提供新的思路和方法。

**关键词:** 粒子群; BP 算法; 森林降水量; 预测模型

**中图分类号:** TP183 **文献标志码:** A

## Forest Precipitation Prediction Based on BP Neural Network Optimized by Particle Swarm Optimization Algorithm

Yu Wanrong, Tian Zonghai, Liu Kuijun, Qiu Xumei, Guo Wenxin

(Shanxi Provincial Meteorological Bureau Shanxi Meteorological Service Center, Taiyuan 030002, China)

**Abstract:** In view of the shortcomings of the traditional forest precipitation prediction method, a forest precipitation prediction method based on BP neural network optimized by particle swarm algorithm is proposed. Taking the forest precipitation from 2020 to 2022 as a data set for comparative experiments, the experimental results show that compared with the LSTM model and the traditional BP neural network, the PSO-BP neural network algorithm has a significant degree of error reduction and higher prediction accuracy. At the same time, the training set and test set are improved by 5%~11%, which reduces the generalization error and is suitable for forest precipitation prediction with large amount of data. The results show that this method provides a new idea and method for the subsequent forest precipitation prediction.

**Keywords:** particle swarm optimization; BP algorithm; forest precipitation; prediction model

### 0 引言

森林是陆地水循环的主体。森林具有蒸腾作用。蒸腾作用起到水的调控和循环, 同时涵养水源减缓了水土流失的灾害。准确地预测森林降水量方法, 对合理使用水资源, 维持正常的水循环及环境友好的人类生产活动等具有重要意义<sup>[1]</sup>。目前, 预测森林降水量方法主要有偏最小二乘回归法、AR 模型等传统统计分析及人工神经网络模型等方法<sup>[2-5]</sup>。

随着技术进步, 人工智能 (artificial intelligence, AI) 已然成为各个领域可持续发展的重要推动力。深度学习可以提高处理复杂问题的能力, 帮助提高对影响降雨的变量和来源的理解。目前关于降水预测的大量现有研究中, 传统的经典预测方法是回归分析法和时间序列预测法。基于回归分析的预测方法有偏最小二乘回归法、自回归移动平均模型等<sup>[6]</sup>。而例如灰色系统<sup>[7]</sup>、马尔可夫模型<sup>[8]</sup>和集对分析<sup>[9]</sup>等是基于时间序列的预测方法。这些方法简单且应用广泛, 但降水预测的精度较低无法准确描述降水

发展和变化的趋势<sup>[10]</sup>。而深度学习<sup>[11]</sup>非常适合处理多维和复杂数据, 不需要数据的物理建模<sup>[12]</sup>; 另一方面, 深度学习有多个层次, 其中低层次的特征被结合起来形成更多抽象高级特征, 非线性网络结构可以实现复杂功能近似, 显示了强大的数据集表示能力; 因此, 使用预测降水量的深度学习技术已经成为一种非常实用的技术。

在众多的深度学习技术中, BP 和 LSTM 是 2 种广泛使用的深度学习神经网络<sup>[13-14]</sup>。神经网络已在许多领域投入使用, 包括拟合、分类和模式识别<sup>[15]</sup>。例如, Ferreira 等<sup>[16]</sup>对比了深度学习和传统机器学习模型。结果表明, 深度学习模型的性能稍好于传统机器学习模型。Granata 等<sup>[17]</sup>基于定量降水预测 (recursive neural network, RNN) 预测短期未来实际蒸散量。该结果表明, 基于深度学习的模型准确预测实际蒸散量, 但模型的性能受当地气候条件影响。改变 BP 神经网络的激励函数是 BP 神经网络改进研究之一。Zhang 等<sup>[18]</sup>将正弦函数作为 BP

收稿日期: 2024-08-10; 修回日期: 2024-09-11

第一作者: 于万荣 (1978—), 男, 山西人, 硕士。

神经网络的激励函数网络 CP 是一组正交多项式,通常用于函数逼近。研究表明,正交多项式在拟合中表现出更好函数,与普通多项式<sup>[19-21]</sup>相比,正交多项式的拟合稳定性更好。Zhang 等<sup>[22-23]</sup>提出了多种神经网络结构,用于分类,通过在前馈神经网络中应用 CP 并结合直接重量测定法以及交叉验证法。基于 Zhang 的研究, Jin 等<sup>[24-25]</sup>进一步改进了应用于葡萄酒地区的研究分类和乳腺癌分类。因为原始 RNN 存在序列数据的存储容量有限的缺点,所以递归神经网络处理能力较差。LSTM<sup>[26]</sup>是 RNN 的能变体能有效缓解 RNN 缺点的能力,如梯度消失和弱记忆能力,使 RNN 应用于各种领域。Kratzert 等<sup>[27]</sup>用 LSTM 模拟气象观测径流,并经实践验证,其预测精度可高。Xiang 等<sup>[28]</sup>使用了基于 LSTM 的预测模型和 seq2seq 结构来预测每小时降雨径流,结果表明 LSTM-seq2seq 模型的精度高于其他模型,但是操作复杂调参较难,该方法用于提高短期洪水预报的精度,但还不具备长期预测优势。

目前,研究人员已将上述 2 种神经网络应用于降水预测,神经网络预测方法可以有效地提取非线性序列的随机特征,实现高预测具有良好的研究和应用价值。例如,根据景德镇 2008—2018 年的气象数据, Kang 等<sup>[29]</sup>将 LSTM 模型用于预测降水,得到 LSTM 模型可以很好地应用于降水预测。Zhou 等<sup>[30]</sup>使用改进的 BP 神经网络模型预测台风降水量和台风降水事件,通过分析正常年份和预测误差较大的年份,提出了一种新的预测方法对于每次迭代中的 BP 模型,降水预测精度优于原始 BP 神经网络。除了预测深层降水学习方法,也可以通过卫星云图和雷达探测。Zahraei 等<sup>[31]</sup>引入了一种短期像素算法使用雷达降雨数据进行定量降水预测(short-term quantitative precipitation forecasting, SQPF),并提出使用分层网格跟踪算法。结果表明该算法能够有效地跟踪和预测接下来几小时的强风暴事件。Bowler 等<sup>[32]</sup>提出了一种新的甘道夫系统降水基于平流的预测方案,该方法不需要划分雷达分析连续降雨区域(continuous rainfall areas, CRA),使用平滑约束诊断降雨分析中的块平流速度,本方案与基于 CRA 的旧 Gandolf 平流方案进行了比较。Pham 等<sup>[33]</sup>比较了几种先进的 AI 模型预测日降水量,结果表明支持向量机是预测降水量的最佳、最稳健和最可靠的方法。Banadooki 等<sup>[34]</sup>提出基于流型优化将算法(flow regime optimization algorithm, FRA)

优化多层感知器神经网络(multilayer perceptron, MLP)模型和基于流型优化将算法优化 SVR 模型,对降水进行预测研究。结果得出所提出的 MLP-FRA 模型具有更强的降雨预测能力。Wang 等<sup>[35]</sup>通过适当的正交分解和数据同化,提高了降水预报的效果。对于这些方法的良好使用效果,为森林地区的降水量预测提供了非常好的解决思路,深度学习技术 BP 神经网络具有较好的非线性问题解决能力,但缺点是过度依赖数据样本、过度学习以及模型效率低下<sup>[36-38]</sup>,影响了模型降水量预测的有效性和精确性<sup>[5]</sup>。BP 神经网络需要进一步优化和改良,笔者提出基于粒子群算法优化 BP 神经网络模型,用于森林降水量预测研究,提供精度更高和操作更简单的森林降水量预测问题解决方法。

## 1 森林降水量预测原理

森林降水量预测主要分为 4 个环节:变量选择、数据的预处理、模型建立和修正、模型评价。变量选择挑选了 3 个主要参数(压力  $P$ 、温度  $T$ 、气体热力学温度  $K$ ),数据的预处理采用归一化进行预处理,确定辅助变量和主导变量,结合粒子群算法的全局搜索优点以及 BP 神经网络的非线性问题解决能力建立 PSO-BP 神经网络模型,将单隐层神经网络与 PSO-BP 神经网络模型进行对比试验,将输出的测试结果对比评价分析。

### 1.1 变量选择及数据预处理

森林降水量主要受以下因素影响:1) 大气:主要包括大气环流、锋面、气旋等因素对降水的影响。2) 温湿度、经纬度位置、云层厚度、洋流:暖流流经对气候有增温增湿的作用。3) 森林绿化率,森林面积、人类活动:人类活动多形成上升气流易成云致雨。

森林降水量预测的最基本理论是降水量观测和降水强度观测紧密结合。针对无法计量或暂且不能用电子信息技术计量的主要自变量,挑选另一个便于计量的自变量,产生数学关系来推断。软测量建模方法最重要的步骤就是通过对相关机理知识和操作规程的了解,结合现场数据测量标准选择辅助变量,通过数学理论知识建立软测量模型,经过对模型的训练和学习得到一定精度的预测。故挑选 3 个主要参数(压力  $P$ 、温度  $T$ 、气体热力学温度  $K$ )进行森林降水量预测。

由于网络收敛速度很可能会因数据单位或规模

的不相同而减缓，因而必须对输入数据开展如下式所示的归一化预处理：

$$X = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

式中：X 为无量纲化后的值；x 为任意数值； $x_{\min}$  为最小值； $x_{\max}$  为最大值。

### 1.2 BP 和 PSO-BP 神经网络模型建立

#### 1.2.1 BP 神经网络结构

如图 1 所示，3 层 BP 神经网络结构分别是输入层、隐含层和输出层<sup>[39-40]</sup>。各层神经元的联接方式依照相对应的权重值。BP 神经网络的训练步骤：1) 训练顶层互联网；2) 固定其权值和阈值；3) 将隐模块输出训练为下层大数据的输入向量。全部完成后，依据反向传播优化计算方法优化权值和阈值，直至达到目标后，测算终止。

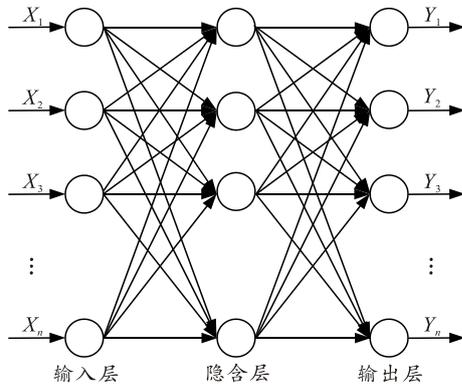


图 1 3 层 BP 神经网络结构

#### 1.2.2 PSO 优化 BP 神经网络模型

粒子群算法具有普遍全球随机搜索能力。实验操作中选用线性降低权系数法和引入变异算子的方法去提升粒子群的全局寻优能力：

1) 线性降低权系数：目的在于优化算法早期有较强的全局寻优能力，中后期有较强的部分开发能力。计算公式为：

$$\omega(t) = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \times t / G \quad (2)$$

式中： $\omega_{\max}$  为惯性系数上限； $\omega_{\min}$  为惯性系数下线；t 为训练的数量；G 为训练数量的极值。

2) 变异算子：在迭代优化环节中，引进变异算子，其完成步骤如下：

Step 1: 依据各层节点数测算 BP 神经网络的权重和阈值数量(即粒子长短)；

Step 2: 根据二进制编码将 BP 神经网络的权重和阈值序号成相对应的粒子；

Step 3: 重置粒子群的预定设置参数，创建粒子群算法的常数，如各粒子的种群模 N 等；

Step 4: 测算初始粒子群内每个粒子的适应能力；

Step 5: 各自记录粒子群的个人极值和全局性极值；

Step 6: 参照式(1)和(2)迭代粒子表征的速度  $v_i$  和坐标  $x_i$ ；

Step 7: 测算新粒子群内每个粒子的适应能力；

Step 8: 更新每个粒子的个人极值；

Step 9: 更新粒子群的全局性极值；

Step 10: 倘若达到要求或迭代频次做到最多循环迭代次数，则退出循环，否则回到 Step 6 继续迭代；

Step 11: BP 神经网络使用得到的最佳值进行预测分析。

基于粒子群算法优化 BP 神经网络模型流程图 2 所示。

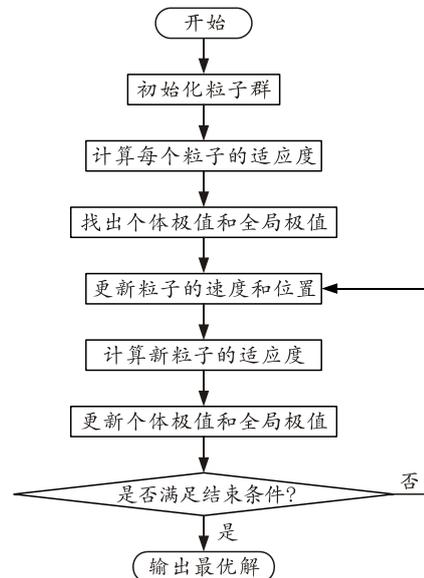


图 2 基于粒子群算法优化 BP 神经网络模型流程

#### 1.2.3 模型评价

均方根误差 (root mean square error, RMSE) 和决定系数 ( $R^2$ ) 作为评价体系模型拟合的性能加以分析和比较。

在实验操作中，RMSE 能够体现模型预测分析自变量与目标变量间的离散程度。 $R^2$  可以评价线性拟合水平； $R^2$  值越接近 1，拟合水平越高，RMSE 和  $R^2$  计算公式如下：

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{x}_i - x_i)^2}{n}} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (4)$$

式中： $\hat{x}_i$  为估计值； $x_i$  为真实值； $\bar{x}$  为均值； $n$  为数量。

## 2 仿真结果与分析

### 2.1 数据来源

本试验数据来源于某森林 2020—2022 年月度降水量数据，将 3 个主要参数 2020—2022 年月度(压力  $P$ 、温度  $T$ 、气体热力学温度  $K$ )作为模型输入变量训练模型，以开展森林降水量预测分析。

### 2.2 实验参数设置

#### 2.2.1 BP 模型参数设置

本实验 BP 模型训练参数设定如表 1 所示。

表 1 BP 模型参数

S 形函数	线性函数	最大评估次数	学习率	训练目标系数
tansig	purelin	1 000	0.01	$1e-5$

#### 2.2.2 PSO-BP 模型参数设置

PSO-BP 神经网络参数设置如表 2 所示。

表 2 PSO-BP 模型参数

最大优化迭代次数	种群规模	最大惯性权重	最小惯性权重
100	40	0.9	0.1
隐含层传递函数	学习率	输出层传递函数	训练目标系数
tansig	0.01	purelin	$1e-5$

其适应性函数以 BP 神经网络总误差的绝对值为 PSO 的适应性参数，公式如下：

$$\text{fitness}=\text{sum}(\text{abs}(a-o))。 \quad (5)$$

式中： $a$  为预测值； $o$  为真实值。

### 2.3 实验结果

#### 2.3.1 PSO-BP 模型预测结果

本次实验随机选择某区域森林 2020—2022 年月度降水量数据作为预测对象，主要进行以下实验：在相同的环境条件下，使用不同的神经网络算法对月度降水量进行数据预测。将 2.1 节中的数据进行预处理之后，在确定辅助变量和主导变量后，选择构建单隐层的 BP 网络和 LSTM 模型作为对比实验模型。以单隐层的 BP 网络为基础搭建 PSO-BP 网络模型，将本文中的数据导入 BP 网络和 PSO-BP 网络模型中进行测量，通过观察不同算法条件下森林降雨量预测值与实际值的线性拟合是否收敛，对 PSO-BP 网络模型的优化性进行验证，如图 3 所示。

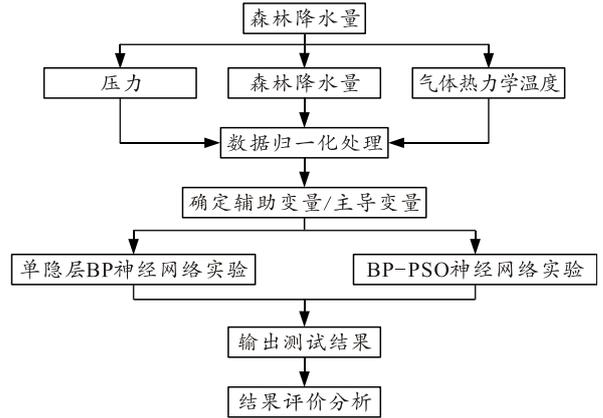


图 3 PSO-BP 降水量预测算法模型

经过实验比较 BP、LSTM、PSO-BP 等森林实际降水量预测效果，线性拟合后 BP 神经网络的预测结果及 PSO-BP 神经网络预测结果以及加入 LSTM 进行对比预测如图 4 所示。

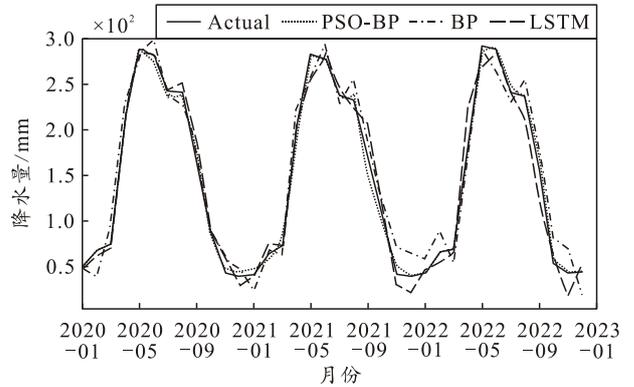


图 4 森林降水量神经网络多种预测对比结果

#### 2.3.2 仿真比较结果分析

笔者对比 PSO-BP 神经网络、原始 BP 神经网络以及 LSTM 模型可知：所得随机初始化权重阈值对原始的 BP 神经网络模型影响很大，需要调整确定的超参数较多，学习记忆不稳定；改进的 PSO 算法优化 BP 神经网络在具有较好的拟合效果，同时具有好的泛化兼容性能，不易出错。不同模型的性能比较如表 3 所示。

表 3 模型仿真的参数对比

模型	RMSE	训练集 $R^2$	测试集 $R^2$
改进的 PSO-BP 网络	0.26	0.90	0.89
BP 网络	0.32	0.83	0.84
LSTM	0.34	0.80	0.81

由表 3 可知：笔者所提改进的 PSO-BP 网络在森林降水量测量中，其模型的 RMSE 更小，算法的误差相较于 LSTM 模型和传统的 BP 神经网络有明显的降低，可能 PSO 网络增强了 BP 神经网络的特征提取性能，提升了其稳定性，其改进网络的训练

集和测试集  $R^2$  相较于 LSTM 模型和传统的 BP 神经网络提升了 5%~11%, 改进网络的泛化性能得到了明显提升。

### 3 结论

森林降水量的预测能减少降水量的随机性对森林生态和生产科研的影响。笔者主要研究了森林降水量的基本方法, 强调了森林降水量在生活中的重要性。由于神经网络具有诸多预测训练的优点, 同时根据粒子群的优化特点, 将改进的 PSO-BP 网络、没有调整优化的原始 BP 网络以及 LSTM 模型在相同的试验条件下进行对比实验。实验结果表明: 改进的 PSO-BP 网络较于 LSTM 模型和原始 BP 网络测量森林降水量准确率较高, 泛化更好, 误差较小。

### 参考文献:

- [1] 胡建华, 黄宇龙, 张坚, 等. 基于麻雀搜索算法优化双隐层 BP 神经网络的张力减径钢管壁厚预测[J]. 塑性工程学报, 2022, 29(8): 145-151.
- [2] 谢永成, 李光升, 魏宁, 等. 基于 GA-BP 神经网络的装甲车辆电路板故障诊断[J]. 自动化与仪表, 2022, 37(8): 97-101.
- [3] 刘阳, 曹学禹. 基于 BP 神经网络的再生混凝土力学性能预估研究[J]. 混凝土世界, 2022(8): 19-24.
- [4] 李婵娟, 焦有权, 温江丽, 等. BP 神经网络在密云水库入库水量预测中的应用[J]. 北京水务, 2022(4): 14-20.
- [5] 范喜林. 一种基于 BP 神经网络的堆煤检测方法[J]. 煤, 2022, 31(8): 56-58.
- [6] ZHAO J, LIU X J. A hybrid method of dynamic cooling and heating load forecasting for office buildings based on artificial intelligence and regression analysis[J]. Energy Build, 2018, 174: 293-308.
- [7] TIEN T L. A research on the grey prediction model GM(1, n)[J]. Appl Math Comput, 2012, 218: 4903-4916.
- [8] FU G B, CHARLES S P, KIRSHNER S. Daily rainfall projections from general circulation models with a downscaling nonhomogeneous hidden Markov model (NHMM) for south-eastern Australia[J]. Hydrol Process, 2013, 27: 3663-3673.
- [9] WANG D, BORTHWICK A G, HE H D, et al. A hybrid wavelet de-noising and Rank-Set Pair Analysis approach for forecasting hydro-meteorological time series[J]. Environ Res, 2018, 160: 269-281.
- [10] CHEN M, MAO S W, LIU Y H. Big data: A survey[J]. Mob Netw Appl, 2014, 19: 171-209.
- [11] WONG T Y, BRESSLER N M. Artificial Intelligence with Deep Learning Technology Looks Into Diabetic Retinopathy Screening[J]. JAMA J Am Med Assoc, 2016, 316: 2366-2367.
- [12] LEE J Y. Physical modeling of charge transport in conjugated polymer field-effect transistors[J]. J Phys D Appl Phys, 2021, 54: 143002.
- [13] NANDA T, SAHOO B, BERIA H, et al. A wavelet-based non-linear autoregressive with exogenous inputs (WNARX) dynamic neural network model for real-time flood forecasting using satellite-based rainfall products[J]. J Hydrol, 2016, 539: 57-73.
- [14] KASHIWAO T, NAKAYAMA K, ANDO S, et al. A neural network-based local rainfall prediction system using meteorological data on the Internet: A case study using data from the Japan Meteorological Agency[J]. Appl Soft Comput, 2017, 56: 317-330.
- [15] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning Representations by Back Propagating Errors[J]. Nature, 1986, 323: 533-536.
- [16] FERREIRA L B, CUNHADO F F. Multi-step ahead forecasting of daily reference evapotranspiration using deep learning. Comput[J]. Electron. Agric, 2020, 178: 105728.
- [17] GRANATA F, NUNNOF D. Forecasting evapotranspiration in different climates using ensembles of recurrent neural networks[J]. Agric Water Manag, 2021, 255: 107040.
- [18] ZHANG Y, QU L, LIU J, et al. Sine neural network (SNN) with double-stage weights and structure determination (DS-WASD)[J]. Soft Comput, 2016, 20: 211-221.
- [19] TIAN C, LIU S C. Demodulation of two-shot fringe patterns with random phase shifts by use of orthogonal polynomials and global optimization[J]. Opt Express 2016, 24: 3202-3215.
- [20] MAHMMOD B M, RAMLI A R, BAKER T. Speech Enhancement Algorithm Based on Super-Gaussian Modeling and Orthogonal Polynomials[J]. IEEE Access 2019, 7: 103485-103504.
- [21] LIN H G, CAO D Q, SHAO C H. An admissible function for vibration and flutter studies of FG cylindrical shells with arbitrary edge conditions using characteristic orthogonal polynomials[J]. Compos Struct, 2018, 185: 748-763.
- [22] ZHANG Y N, YIN Y H, GUO D S, et al. Cross-validation based weights and structure determination of Chebyshev-polynomial neural networks for pattern classification[J]. Pattern Recognit, 2014, 47: 3414-3428.
- [23] ZHANG Y N, YU X T, GUO D S. Weights and structure determination of multiple-input feed-forward neural network activated by Chebyshev polynomials of Class 2 via cross-validation[J]. Neural Comput & Appl, 2014, 25: 1761-1770.
- [24] JIN L, HUANG Z G, LI Y H, et al. On Modified Multi-Output Chebyshev-Polynomial Feed-Forward Neural Network for Pattern Classification of Wine Regions[J]. IEEE Access, 2019, 7: 1973-1980.