

基于多预测模型与非线性组合的神经网络风速预测

王家君¹, 曹薇², 张贵龙², 张淮智¹, 凌子兴¹, 赵小强¹

(1. 西安邮电大学, 陕西 西安 710121; 2. 雅砻江流域水电开发有限公司, 四川 成都 610051)

摘要: 针对复杂山地风速在时空特性上存在强随机性的问题, 为了提高风速数据预测的准确性, 提出一种基于多预测模型与非线性组合的神经网络风速预测算法。在算法第一层, 利用灰狼优化器(GWO)并引入动态收敛因子改进鲸鱼优化算法(WOA), 将改进后的WOA应用于反向传播神经网络(BPNN)权值及偏置项的更新过程。同时, 基于改进后的鲸鱼优化算法的反向传播神经网络(IWOABP)、极限学习机(ELM)和长短期记忆(LSTM)3种优势互补的方法构建组合预测方法, 并在此基础上利用算法第二层的ELM混合机制, 以非线性方式学习第一层与最终结果的关系。仿真结果表明, 所提算法相较于BPNN、小波神经网络(WNN)及灰狼优化器导向的BPNN(GWOBP), 预测误差均有所降低。

关键词: 复杂山地; 风速预测; 鲸鱼优化算法; 神经网络

中图分类号: TP183

文献标识码: A

doi: 10.11959/j.issn.2096-3750.2021.00221

Neural network wind speed prediction based on multiple prediction model and nonlinear combination

WANG Jiajun¹, CAO Wei², ZHANG Guilong², ZHANG Huaizhi¹, LING Zixing¹, ZHAO Xiaoqiang¹

1. Xi'an University of Posts and Telecommunications, Xi'an 710121, China

2. Yalong River Basin Hydropower Development Co., Ltd., Chengdu 610051, China

Abstract: For the problem of strong randomness in space-time characteristics of wind speed in complex mountains, in order to improve the accuracy of wind speed data prediction, a neural network wind speed prediction algorithm based on multiple prediction model and nonlinear combination was proposed. In the first layer of the algorithm, the grey wolf optimizer (GWO) and the dynamic convergence factor were used to improve the whale optimization algorithm (WOA), and the improved WOA was applied to the updating process of BPNN weights and bias items. At the same time, the improved whale optimization algorithm of back propagation neural network (IWOABP), ELM and LSTM three complementary single methods were constructed to build a combination prediction method, and on this basis, the ELM mixing mechanism of the second layer of the algorithm was utilized to learn the relationship between the first layer and the final result in a non-linear way. Simulation results show that compared with BPNN, WNN and GWOBP, the proposed algorithm has lower prediction errors.

Key words: complex mountain areas, wind speed prediction, whale optimization algorithm, neural network

1 引言

风能作为一种清洁、环保、储量丰富的可再生

能源在现代社会发展的应用逐渐增多, 对于缓解全球能源危机具有不容忽视的作用^[1]。作为风能资源开发和利用的首要环节, 风能评估不仅是风

收稿日期: 2020-12-28; 修回日期: 2021-11-08

通信作者: 张淮智, 1019771588@qq.com

基金项目: 国家自然科学基金-雅砻江联合基金资助项目(No.U1965102); 陕西省创新人才推进计划-物联网科技创新团队(No.2019TD-028)

Foundation Items: The Yalong River Joint Funds of the National Natural Science Foundation of China (No.U1965102), The IoT Innovation Team for Talent Promotion Plan of Shanxi Province (No.2019TD-028)

电项目投资的核心,也是风能图谱绘制的重要步骤之一。风速作为风能监测的重要指标,需要对风电场的风速进行在线监测以确保数据的完整性和可靠性。

除沿海地区及部分内陆平原外,我国大多数风电场都建设在地形复杂的山区^[2]。例如,位于凉山州山区的雅砻江风光水互补清洁能源示范基地的平均风速在 7 m/s 以上,但其地貌特征的特殊性导致风速频繁变化^[3],使得风速资源预测的挑战更加艰巨。因此,常用预测模型来预测未来的风速情况。Bizrah 等^[4]研究了季节性自回归滑动平均 (ARMA, autoregressive moving average) 风速预测模型,采用每日和每小时的数据进行测试以验证模型的准确度,该模型具有一定的可靠性,但未考虑风的高度随机性,仅考虑风的季节性变化,因此,该预测模型不具有很强的可移植能力。张亚刚等^[5]研究了基于变模态分解 (VMD, variational mode decomposition)、主成分分析径向基函数 (PCA-RBF, principal components analysis- radial basis function)、ARMA 及由 VMD 分解风速的误差序列,基于风速的线性和非线性特性,分别采用贝叶斯方法的理论体系中马尔可夫链蒙特卡洛框架下的 ARMA 模型以及 PCA-RBF 模型对风速进行分析,该方法针对线性模型有相当出色的性能结果,但对非线性模型仍旧存在易陷入局部最优的缺点。刘光标等^[6]将时间序列分解、自相关分析、优化算法和基本预测模型组合到一个优化框架中,其预测误差统计量小于其他模型,但更适用于预测平滑序列,在相对不平滑序列中的预测准确度不高。Ahadi 等^[7]提出一种基于神经网络的风速时间序列预测方法,将神经网络方法获得的结果与 ARMA 模型获得的结果进行比较,尽管验证了神经网络方法相较于时间序列模型提供了更准确的风速时间序列预测,但仍存在误差大、精度低及实用性较差的问题。张亚刚等^[8]研究了基于洛伦兹扰动的反向传播神经网络风速预测,利用洛伦兹扰动明显减弱了风速的随机波动性,更适用于复杂山地的风速变化环境,但其未能解决反向传播神经网络 (BPNN, back propagation neural network) 存在的局部最优解问题,导致其收敛结果不稳定。魏昱洲等^[9]提出基于长短期记忆 (LSTM, long short-term memory) 网络的超短期风速预测算法,利用双层 LSTM 神经网络结构对北京市海淀区的风速进行了 1 min、5 min、10 min 的超前预测,

由于 LSTM 网络考虑风速数据的历史关联性,相较于大部分算法,其预测精度高且误差较小,然而 LSTM 网络属于深度神经网络,其时间复杂度较高,尽管可以达到较高的准确率,但双层网络的设置会加倍增加网络开销。

综上,现有的高空风能预测方式包括基于时间序列模型以及非线性拟合模型的风速预测方法。基于时间序列模型的预测方法主要依靠风速的时间特性,结合物理及推理演算的方式进行预测,尽管该方法在预测线性或平滑序列时的性能显著,但在非线性或不平滑的风速序列预测过程中仍存在模型复杂且精确度不高的问题。基于神经网络的非线性拟合方法虽比时间序列模型更精确,但神经网络存在易陷入局部最优解的缺陷。此外,以上算法仅使用单一的神经网络算法进行预测,导致算法误差较大,预测精度不高^[10]。所以,针对风速多变的环境,本文采用群智能优化算法对传统的神经网络算法进行改进,克服神经网络易陷入局部最优解的缺陷,探索输入数据与输出数据之间的非线性关系;并采用非线性组合的风速预测方法,可充分利用各种单一模型的信息,有利于提高风速预测的精度,改变现有神经网络难以预测复杂风场风速的窘境。

综上所述,本文围绕基于神经网络的预测算法与群智能优化算法展开复杂山地风能资源数据预测算法的研究,提出了基于改进鲸鱼优化算法的反向传播神经网络 (IWOABP, improved whale optimization algorithm backpropagation neural) 预测算法,可增强原算法的全局寻优能力,显著降低预测误差,提出了基于多预测模型与非线性组合的神经网络 (MPM-NC-NN, multi prediction model and nonlinear combination neural network) 风速预测算法,通过组合预测代替单一预测的方式,可提高现有预测算法的预测精度。

2 基于 IWOABP 的风速预测算法

针对 BPNN 在训练过程中易陷入局部最优的问题,采用全局寻优能力强的鲸鱼优化算法 (WOA, whale optimization algorithm)^[11],提出一种基于 IWOABP 的风速预测算法,利用改进后的算法替代原有梯度下降法更新权值与偏置项,进而改善了 BPNN 易陷入局部最优的缺陷。

2.1 鲸鱼优化算法

座头鲸通常成群生活,其捕食过程主要分为包

围猎物 and 气泡网饲养两个阶段^[12]。WOA 算法对螺旋“气泡网饲养”的狩猎过程进行了数学建模，以达到优化适应度函数的目的。

1) 包围猎物阶段

座头鲸在感知到猎物位置后将其包围。但由于在目标函数寻优的过程中，最优解不是先验已知的，因而假设当前的最优候选解为近似最优解。在每轮迭代的过程中，当最优候选解被确定后，其他搜索代理（鲸鱼种群）将朝着最优候选解的位置逼近，这一行为由式(1)和式(2)表示。

$$D = |C \cdot X^*(t) - X(t)| \quad (1)$$

$$X(t+1) = X^*(t) - A \cdot D \quad (2)$$

其中， t 代表当前迭代次数， A 和 C 是控制不同搜索方法的系数， X^* 是目前获得的最优解的位置向量， X 是鲸鱼个体的位置向量。其中， X^* 的值会在每次迭代过程中通过寻找搜索代理的最佳适应度值的方式进行更新， A 和 C 的计算式为

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

$$C = 2 \cdot r \quad (4)$$

其中， a 在随着算法执行过程从 2 到 0 线性递减， r 为 $[0,1]$ 的随机数，鲸鱼优化算法图解如图 1 所示。




图 1 鲸鱼优化算法图解

2) “气泡网饲养”攻击方法

鲸鱼“气泡网饲养”的攻击过程主要分为以下两个步骤。

收缩包围机制：如图 2 所示，这种行为是通过降低式(3)中 a 的值实现的。 A 的波动范围也随着 a 的减小而减小，即 a 在迭代过程中从 2 减小到 0， A 为 $[-2,2]$ 中的随机值。




图 2 收缩包围机制

螺旋位置更新：根据鲸鱼螺旋上升捕食猎物的行为，搜索代理也并非直接奔向猎物，而是以螺旋的方式逐步逼近猎物的。该方法首先根据 (X, Y) 处的鲸鱼和 (X^*, Y^*) 处的猎物之间的距离，在鲸鱼和猎物之间建立一个方程，模拟“气泡网”，如式(5)和式(6)所示。

$$X(t+1) = \begin{cases} X^*(t) - A \cdot D, & p < 0.5 \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t), & p \geq 0.5 \end{cases} \quad (5)$$

$$D = |X^*(t) - X(t)| \quad (6)$$

其中， p 是 $[0,1]$ 的随机数， D 代表第 i 条鲸鱼与猎物之间的距离， b 表示对数螺旋线常数， l 为 $[-1,1]$ 的随机数。螺旋位置更新如图 3 所示。




图 3 螺旋位置更新

3) 搜索猎物

向量 A 的递减同样可用于搜索猎物阶段。通过 A 的设定，迫使下一步搜索代理的位置由当前最佳搜索代理和原始搜索代理的位置确定。其数学模型如式(7)和式(8)所示。

$$D = |C \cdot \bar{X}_{rand} - X| \quad (7)$$

$$X(t+1) = \bar{X}_{rand} - A \cdot D \quad (8)$$

其中, \mathbf{X}_{rand} 是从当前搜索代理中选择的随机位置向量。

2.2 基于灰狼优化器改进的鲸鱼优化算法

为了改善 BPNN 在更新权值与偏置项的过程中存在易陷入局部最优的问题, 本文结合灰狼优化器 (GWO, grey wolf optimizer) [13] 狼群分级的思想对 WOA 进行了改进, 旨在进一步提升算法全局寻优的能力。此外, 对原始算法收敛因子的计算方法进行改进, 增加了算法全局及局部搜索的能力。

1) 改进当前最优鲸鱼位置更新策略

灰狼作为一种常见的群居动物, 其捕食行为通常为集体行动, 群体内有严格的等级制度。灰狼种群等级制度示意图如图 4 所示 [14]。头狼作为指挥狼位于金字塔的顶端, 称为 α 狼。 α 狼主要负责制定种群的管理制度, 在狩猎过程中起主导作用。灰狼种群的特殊等级制度使得它们在捕杀猎物时协调默契。捕食时由头狼 α 带领, β 狼、 δ 狼和 ω 狼一起猎杀。在捕猎的初始阶段, 狼群中各成员群体出动, 共同搜寻并跟踪猎物, 当发现猎物时立即将其包围, 随着包围圈的缩小, α 狼起指挥作用, 由 β 狼和 δ 狼发起攻击, 其他狼准备在猎物逃窜时追捕, 在猎物和狼群的位置变化时, 通过攻击和追捕相互配合, 完成对猎物捕杀 [15]。




图 4 灰狼种群等级制度示意图

基于此生物习性, 将 WOA 在 $0.3 < |A| < 1$ 时 (A 为收敛因子, 用来控制不同搜索方法的系数) 的搜索代理 (鲸鱼个体) 位置更新方向修改为向次狼方向, 在 $|A| < 0.3$ 时朝着头狼方向更新。在收缩包围过程的前期, 搜索代理向次优搜索代理的位置更新; 在收缩包围过程的后期, 搜索代理朝着最优搜索代理的位置更新。

2) 改进动态收敛因子

在保证算法收敛性能的前提下, 进一步提高算法的寻优能力。分析算法执行过程发现, 当 $|A| < 1$

时, 算法处于执行“气泡网饲养”攻击方法阶段, 在此阶段, 由于包围猎物阶段搜索到的解为局部最优解, 所以算法执行后期所有的搜索代理均朝着更差的方向更新, 进而对其最终结果有很大程度的影响。因此, 可对收敛因子 A 进行调整。本文对 WOA 中收敛因子 A 进行了调整, 利用改进的动态收敛因子, 进一步加强算法的全局及局部搜索能力, 进而使算法最终可以收敛到全局最优。动态收敛因子 A 的计算公式如式(9)所示。

$$A = \frac{2}{1 + e^{\left(\frac{5t}{\text{max_iteration}} - 3\right)}} \quad (9)$$

其中, t 为当前迭代次数, max_iteration 为最大迭代次数。

2.3 IWOABP 预测算法

改进的鲸鱼优化算法 (IWOA, improved whale optimization algorithm) 在原始 WOA 的基础上, 将误差作为适应度函数, 同时将鲸鱼个体比作权值与偏置项, 结合次优解及动态收敛因子, 进一步提升了 WOA 的寻优能力, 从而提高了算法的预测性能。利用 IWOA 在搜索寻优方面全局寻优能力强、精度高且易跳出局部最优的优势替代经典梯度下降法, 解决了 BPNN 易陷入局部最优而导致的预测结果不精确的问题, 实现步骤如下。

1) 初始化参数

初始化神经网络的学习率。选用 sigmoid 函数作为激活函数, 如式(10)所示。神经网络输入层与隐含层的权值 $\omega_{i,j}^{[m]}$, 输入层与隐含层的偏置项 $b_i^{[m]}$, 隐含层与输出层的权值 $\omega_{j,k}^{[m]}$, 隐含层与输出层的偏置项 $b_j^{[m]}$, 如式(11)~式(14)所示。IWOA 收敛因子 \bar{a} 如式(15)所示。

$$f_{\text{sigmoid}}(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

$$\omega_{i,j}^{[m]} = 0.5 \times \text{rand}j, i - 0.1 \quad (11)$$

$$b_i^{[m]} = 0.5 \times \text{rand}j, 1 - 0.1 \quad (12)$$

$$b_j^{[m]} = 0.5 \times \text{rand}k, j - 0.1 \quad (13)$$

$$\omega_{j,k}^{[m]} = 0.5 \times \text{rand}k, 1 - 0.1 \quad (14)$$

$$\bar{a} = \frac{2}{1 + e^{\left(\frac{5t}{\text{max_iteration}} - 3\right)}} \quad (15)$$

其中, i 、 j 、 k 分别为输入层、隐含层和输出层节

点个数。

2) 计算适应度函数及当前最佳搜索代理

为了更好地改善神经网络的反向传播过程，进一步提升网络的预测准确度，将神经网络误差函数视为 IWOA 的适应度函数，其计算方法如式(16)~式(19)所示。

$$O_j = \text{sigmoid}(\omega_{i,j}^{[m]} \times i + \text{repmat}(B_1, 1, n)) \quad (16)$$

$$Y^{(n)} = \omega_{j,k}^{[m]} \times O_j + \text{repmat}(B_2, 1, n) \quad (17)$$

$$\text{Error} = Y^{(n)} - Y^{(n)} \quad (18)$$

$$\text{MSE} = \text{mse}(\text{Error}) \quad (19)$$

其中， O_j 为隐含层节点的输出， $Y^{(n)}$ 为输出层节点输出，Error 为神经网络输出值与真实数据之间的误差， $Y^{(n)}$ 为期望误差，MSE 为均方误差。

3) IWOA 更新权值及偏置项

基于 IWOA 的权值偏置项更新方法主要分为寻优过程和更新过程。寻优过程将神经网络中的一组权值和偏置项视为一个搜索代理，同时将上述均方误差 MSE (MSE, mean-square error) 作为适应度函数 (待优化的目标函数)。将每一个搜索代理与当前最优搜索代理比较，得到下一次迭代的最优搜索代理。根据收缩环绕机制及螺旋位置更新机制更新全部搜索代理位置，该过程在每轮迭代选取当前最优搜索代理后执行，并将当前最优搜索代理的权值偏置项作为更新后的权值偏置项，迭代直到算法目标误差达到预设值或迭代次数达到指定上限，算法结束，输出模型参数。

IWOABP 算法流程如图 5 所示。

3 基于 MPM-NC-NN 的风速预测算法

高效低误差是风速数据预测的最终目标，上文所提 IWOABP 算法，在长期风速数据预测中，仍存在无法解决长期历史数据相互依赖的问题。如文献[16]所述，使用大量单一方法进行组合通常具有更好的预测性能，并通过实验证实可通过组合的单个预测模型提高预测准确性。因此提出了一种基于多预测模型与非线性组合的神经网络风速预测算法，该算法相较于任意一种单一预测方法，避免了算法陷入局部最优解，考虑了长短期历史数据，提高了算法预测精度。

3.1 基于 IWOABP、ELM 和 LSTM 的多预测模型

考虑到单一预测方法的过程不严谨、结果不确定的缺陷，采用组合预测方法进行预测。极限学习机 (ELM, extreme learning machine) 具有比传统人工神经网络 (ANN, artificial neural network) 更出色的泛化性能；LSTM 具备解决长期依赖问题的能力；IWOABP 具有全局寻优能力强的特点。因此将 3 种优势互补的算法进行组合，以期获取更低误差的风速预测结果。MPM-NC-NN 算法第一层的预测步骤如下。

步骤 1 将所选数据集按照式(20)和式(21)分为输入数据 x_1 和输出数据 y_1 。

$$X = \begin{bmatrix} X_1(1) & \cdots & X_A(1) \\ \vdots & \ddots & \vdots \\ X_1(N) & \cdots & X_A(N) \end{bmatrix} \quad (20)$$

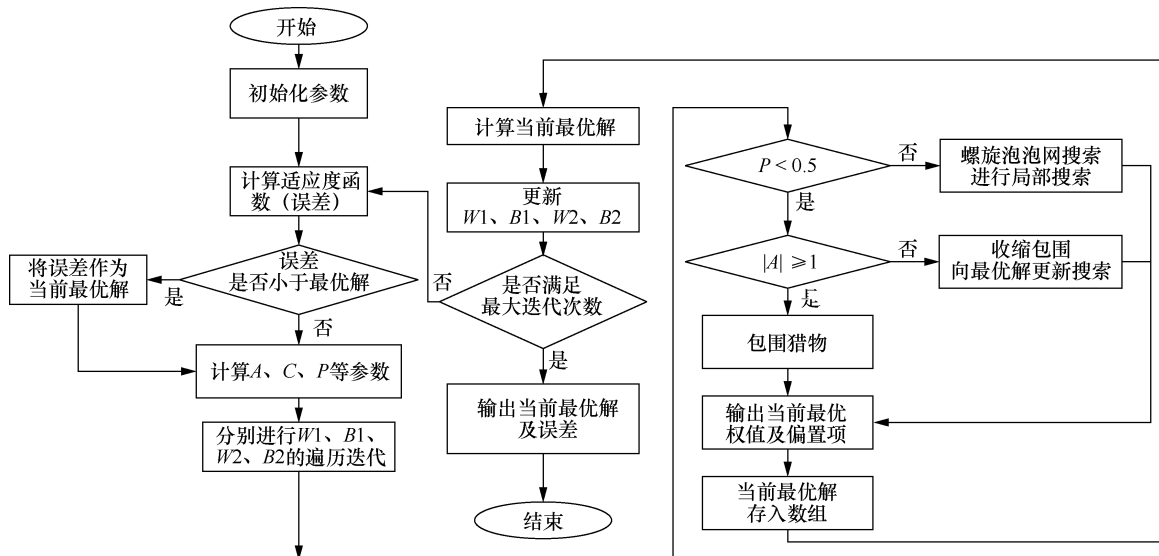


图 5 IWOABP 算法流程

$$y_1 = [X(1) \ \cdots \ X(N)]^T \quad (21)$$

其中, A 为数据个数 (500 组), $X_A(N)$ 为不同的输入量, N 表示不同维度的输入参数 (如 $X_A(1)$ 表示温度、 $X_A(2)$ 表示气压等), A 表示数据点的个数。即输入数据 x_1 的列代表不同类型的参数, 行代表数据点的个数, 输出数据 y_1 表示真实的风速数据。

步骤 2 基于所选数据集, 分别采用 IWOABP、ELM 和 LSTM 方法进行预测。

步骤 3 确定初始可调整参数, 如每种单一预测方法的每一层中隐藏层和神经元的数量。然后, 通过最小化训练过程中的 MSE, 获得 x_1 和 y_1 之间的关系 f 。式(22)和式(23)给出了相应的计算方法。

$$Y_i = f_i(x_1) \quad (22)$$

$$MSE = \frac{1}{N} \sum_{k=1}^A (Y_i(k) - y_1)^2 \quad (23)$$

其中, f_i 表示数据映射的非线性关系, Y_i ($i=1, 2, 3$) 表示在 IWOABP、ELM 和 LSTM 的训练过程期间的预测值。

步骤 4: 通过训练得到 IWOABP、ELM 和 LSTM 网络的预测值, 并将相关数据 (即训练的预测数据 x_1 、 y_1 和单一预测结果 P_i) 发送到第二层以进行非线性组合。

3.2 基于 ELM 的非线性混和机制

ELM 由于其高计算效率和出色泛化性能的优点, 被用作第二层非线性混合机制。第二层网络的预测步骤如下。

步骤 1 将第一层的预测结果分为训练样本和测试数据, 并从 IWOABP、ELM 和 LSTM 的训练过程中获取预测值, 如式(24)和式(25)所示。

$$x_2 = \begin{bmatrix} X_1(1) & X_2(1) & X_3(1) \\ X_1(2) & X_2(2) & X_3(2) \\ \vdots & \vdots & \vdots \\ X_1(N) & X_2(N) & X_3(N) \end{bmatrix} \quad (24)$$

$$y_2 = y_1 \quad (25)$$

其中, $X_i(j)$ 表示完成训练过程后, 第 i 种预测方法的第 j 组数据的预测值。

步骤 2 确定初始可调参数, 如 ELM 方法每一层中的隐藏层数和神经元数。然后, 通过最小化均方根误差 (RMSE, root mean square error), 获得 3

种单一预测方法与最终预测结果之间的关系 f_4 , 如式(26)和式(27)所示。

$$P_4 = f_4 x_2 \quad (26)$$

$$MSE = \frac{1}{N} \sum_{k=1}^N (P_4(k) - y_2)^2 \quad (27)$$

步骤 3 将第一层收集到的 3 个预测结果, 通过非线性关系 f_4 获得最终预测结果, 如式(28)所示。

$$F_s = f_4(F_1, F_2, F_3) \quad (28)$$

其中, F_1 、 F_2 和 F_3 为 IWOABP、ELM 和 LSTM 获得的预测结果, F_s 表示最终的预测结果。

4 仿真分析

4.1 算法分析

IWOA 在原始 WOA 基础上, 将误差作为适应度函数, 同时将鲸鱼个体比作权值与偏置项, 结合次优解及动态收敛因子, 进一步提升了 WOA 的寻优能力。IWOA 与 BPNN、WOA 的算法性能对比如图 6 所示。IWOA 算法在 100 次迭代后寻求的均方误差小于 BPNN 算法的均方差, 收敛效果较好。但算法在前 50 次迭代时波动较大, 这是因为引入次优搜索代理避免在包围猎物阶段当前最佳搜索代理搜索到局部最优解导致其他搜索代理均朝着局部最优方向移动, 这使得算法收敛于局部最优而非全局最优。而次优解是为了避免陷入局部最优而选择的较差解, 且该过程仅在 $|A| > 1$ 时执行, 因此算法在前半段寻优过程中均方误差波动较大, 但在算法后半段, 由于最优搜索代理的正确引导, 收敛结果较改动前更佳。




图 6 IWOA 与 BPNN、WOA 的算法性能对比

MPM-NC-NN 与 ELM、LSTM、IWOABP 算法均方根误差对比如图 7 所示, MPM-NC-NN 算法均方根误差相较于各独立算法均有所下降。不论其他 3 种独立的算法误差多大, MPM-NC-NN

算法都能结合 3 种算法的优势，进而预测到较为精确的数据。仿真实验参数见表 1。

表 1 仿真实验的主要参数

名称	参数	参数值
通用参数	噪声强度	0.01 dB
	最大迭代次数	1 000
	误差精度	0.65×10^{-4}
MPM-NC-NN	鲸鱼种群数量	20 只
	学习率	0.05
	输入层	6 层
	输出层	1 层
	隐含层	3 层
LSTM	学习率	0.04
	输入层	6 层
	输出层	1 层
	隐含层	5 层
ELM	灰狼种群数量	20 只
	学习率	0.03
	输入层	6 层
	输出层	1 层
	隐含层	7 层
IWOABP	学习率	0.03
	输入层	6 层
	输出层	1 层
	隐含层	3 层

2019 年 5 月 23 日每小时的气压、平均风向、最高气温、最低气温、相对湿度、水气压及风速数据。实验参数见表 2。

表 2 仿真实验的主要参数

名称	参数	参数值
通用参数	噪声强度	0.01 dB
	最大迭代次数	1 000
	误差精度	0.64×10^{-4}
MPM-NC-NN	鲸鱼种群数量	20 只
	学习率	0.05
	输入层	6 层
	输出层	1 层
	隐含层	3 层
BPNN	学习率	0.03
	输入层	6 层
	输出层	1 层
	隐含层	3 层
灰狼优化器导向的 BPNN (GWOBP, grey wolf optimizer backpropagation neural)	灰狼种群数量	20 只
	学习率	0.07
	输入层	6 层
	输出层	1 层
	隐含层	3 层
小波神经网络 (WNN, wavelet neural network)	学习率	0.04
	输入层	6 层
	输出层	1 层
	隐含层	2 层




图 7 MPM-NC-NN 与 ELM、LSTM、IWOABP 算法均方根误差对比

4.2 对比分析

使用 MATLAB 2018b 仿真软件对提出的 MPM-NC-NN 风速预测算法进行仿真。所采用的数据为西昌市牦牛山片区测风塔 2019 年 4 月 28 日~

不同算法风速训练绝对误差对比如图 8 所示。4 种算法风速训练绝对误差分析见表 3，WNN 比所提 WEL-ELM 在训练阶段更接近真实值，其原因在于 WNN 的训练过程太贴近于训练数据的特征，在训练集上预测性能较好，但在新的测试集上预测性能一般，此现象称为过拟合。BPNN 由于复杂环境风速数据波动较大，且 BPNN 易陷入局部最优，没有准确学到测试样本的特性，进而导致网络欠拟合。综上，MPM-NC-NN 预测性能优于其他 3 种算法。

不同算法风速预测值对比如图 9 所示，所提算法预测结果相较于 BPNN、GWOBP、WNN 更接近真实值。

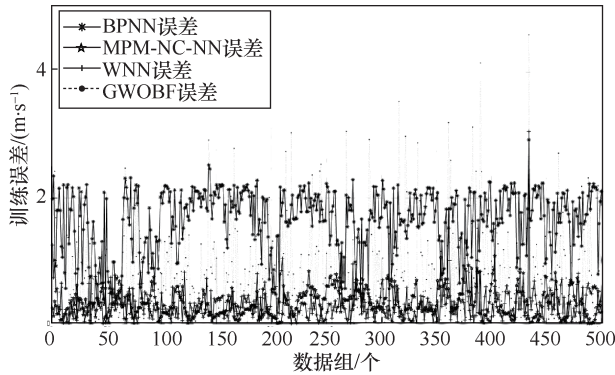


图8 不同算法风速训练绝对误差对比

表3 4种算法风速训练绝对误差分析

算法	BPNN	GWOBP	WNN	MPM-NC-NN
绝对误差	1.635	0.817	0.316	0.322

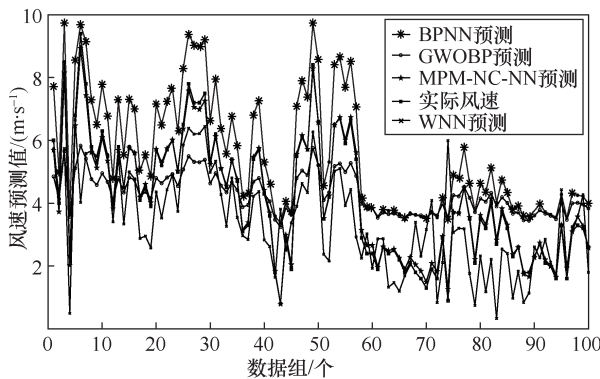


图9 不同算法风速预测值对比

4.3 预测结果对比

平均绝对误差 (MAE, mean absolute error) 可以更好地反映预测值误差的实际情况, MAE 越接近于 0, 说明预测结果越准确。MSE 为均方误差, 一般用于衡量全部预测值与真实值之间的偏差情况, MSE 越小说明预测模型具有良好的稳定性和预测结果, MSE 常被称为损失函数, 是评价神经网络性能指标的重要因素。RMSE 为均方根误差, 反映的是系统误差的分散程度, 表示预测值与真实值的偏差范围, 与 MSE 不同, 它对预测数据中的极值点具有很强的灵敏度, RMSE 的值越大, 说明数据波动性越强。

4 种算法性能见表 4, 通过对 100 组数据的各类误差求均值, 以反映 4 种算法性能, 所提算法的 MAE、MSE、RMSE 分别为 0.118、0.015、0.154, 均优于其他 3 种算法。

4.4 算法稳定性

为了评估本文所提算法的模型稳定性, 将 MPM-NC-NN 与 BPNN、GWOBP、WNN 进行了

100 次重复性实验。100 次实验均方根误差对比如图 10 所示, 所提算法的均方根误差相较于 BPNN、GWOBP、WNN 算法明显较低。

表4 4种算法性能

算法	MAE	RMSE	MSE
BPNN	1.447	1.492	0.149
GWOBP	1.155	1.341	0.134
WNN	1.122	1.426	0.142
MPM-NC-NN	0.118	0.154	0.015

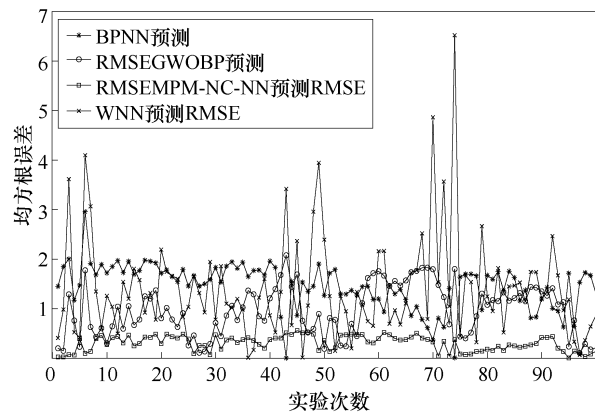


图10 100次实验均方根误差对比

5 结束语

本文主要研究如何提升非线性神经网络预测算法的准确性, 提出了一种基于多预测模型与非线性组合的神经网络风速预测算法。该算法利用 IWOABP 与 ELM、LSTM 结合组成算法的第一层多预测模型, 再经过第二层非线性混合机制预测, 提高了算法的全局寻优能力和数据预测精准度。仿真结果表明, 与 BPNN、WNN、GWOBP 对比, 所提算法在预测性能方面均优于其他算法。

参考文献:

- [1] 王雪芹. 风电项目运营期生态影响分析探讨[J]. 环境与发展, 2018, 30(5): 10-11, 25.
WANG X Q. Analysis and discussion on the ecological impact of wind power project in operation period[J]. Environment and Development, 2018, 30(5): 10-11, 25.
- [2] 杜云, 黎发贵, 胡荣, 等. 测风塔在风电场风能资源评估中的重要性和代表性[J]. 水力发电, 2018, 44(7): 97-99.
DU Y, LI F G, HU R, et al. The importance and representation of wind measuring tower in wind energy resources assessment[J]. Water Power, 2018, 44(7): 97-99.
- [3] DAI J C, TAN Y Y, YANG W X, et al. Investigation of wind resource

characteristics in mountain wind farm using multiple-unit SCADA data in Chenzhou: a case study[J]. Energy Conversion and Management, 2017, 148: 378-393.

- [4] BIZRAH A, AL-MUHAINI M. The impact of seasonal ARMA wind speed modeling on the reliability of power distribution systems[C]//2017 IEEE Power & Energy Society General Meeting. Piscataway: IEEE Press, 2017: 1-5.
- [5] ZHANG Y G, ZHAO Y, KONG C H, et al. A new prediction method based on VMD-PRBF-ARMA-E model considering wind speed characteristic[J]. Energy Conversion and Management, 2020, 203: 112254.
- [6] LIU G B, ZHOU J Z, JIA B J, et al. Advance short-term wind energy quality assessment based on instantaneous standard deviation and variogram of wind speed by a hybrid method[J]. Applied Energy, 2019, 238: 643-667.
- [7] AHADI A, LIANG X D. Wind speed time series predicted by neural network[C]//2018 IEEE Canadian Conference on Electrical & Computer Engineering (CCECE). Piscataway: IEEE Press, 2018: 1-4.
- [8] ZHANG Y G, CHEN B, ZHAO Y, et al. Wind speed prediction of IPSO-BP neural network based on Lorenz disturbance[J]. IEEE Access, 2018, 6: 53168-53179.
- [9] 魏昱洲, 许西宁. 基于LSTM长短期记忆网络的超短期风速预测[J]. 电子测量与仪器学报, 2019, 33(2): 64-71.
WEI Y Z, XU X N. Ultra-short-term wind speed prediction model using LSTM networks[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 64-71.
- [10] 张露, 卢继平, 梅亦蕾, 等. 基于不同优化准则的风电功率预测[J]. 电力自动化设备, 2015, 35(5): 139-145.
ZHANG L, LU J P, MEI Y L, et al. Wind power forecasting based on different optimization criteria[J]. Electric Power Automation Equipment, 2015, 35(5): 139-145.
- [11] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [12] BURKARD M, WHITWORTH D, SCHIRMER K, et al. Establishment of the first humpback whale fibroblast cell lines and their application in chemical risk assessment[J]. Aquatic Toxicology, 2015, 167: 240-247.
- [13] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [14] AL-ABOODY N A, AL-RAWESHIDY H S. Grey wolf optimization-based energy-efficient routing protocol for heterogeneous wireless sensor networks[C]//2016 4th International Symposium on Computational and Business Intelligence (ISCBI). Piscataway: IEEE Press, 2016: 101-107.
- [15] 王海峰, 李萍, 王博, 等. 灰狼算法优化BP神经网络的图像去模糊复原[J]. 液晶与显示, 2019, 34(10): 992-999.
WANG H F, LI P, WANG B, et al. Image deblurring restoration of BP neural network based on grey wolf algorithm[J]. Chinese Journal of Liquid Crystals and Displays, 2019, 34(10): 992-999.
- [16] 喻华, 卢继平, 曾燕婷, 等. 基于不同优化准则和广义回归神经网络的风电功率非线性组合预测[J]. 高电压技术, 2019, 45(3): 1002-1008.
YU H, LU J P, ZENG Y T, et al. Nonlinear combined model for wind power forecasting based on different optimization criteria and generalized regression neural network[J]. High Voltage Engineering, 2019, 45(3): 1002-1008.

[作者简介]



王家君(1997-), 男, 西安邮电大学通信与信息工程学院硕士生, 主要研究方向为物联网技术及应用、风能资源在线测量等。



曹薇(1982-), 女, 雅砻江流域水电开发有限公司高级工程师、主任工程师, 主要研究方向为战略规划、新能源管理等。



张贵龙(1985-), 男, 雅砻江流域水电开发有限公司高级工程师, 主要研究方向为电气工程与自动化、太阳能和风力发电等。



张淮智(1996-), 男, 西安邮电大学通信与信息工程学院硕士生, 主要研究方向为物联网技术及应用、风能资源在线测量等。



凌子兴(1998-), 男, 西安邮电大学通信与信息工程学院硕士生, 主要研究方向为物联网技术及应用、神经网络等。



赵小强(1977-2021), 男, 博士, 西安邮电大学教授, 主要研究方向为物联网技术及应用、智慧农业、环境监测及风能资源在线测量等。