

DOI: 10.19666/j.rlfed.202305076

基于改进灰狼算法优化双向长短时记忆神经网络的水冷壁壁温预测

詹毅¹, 冯磊华¹, 杨锋², 钟信¹
(1.长沙理工大学能源与动力工程学院, 湖南 长沙 410114;
2.华自科技股份有限公司, 湖南 长沙 410006)

[摘要] 提出一种基于改进灰狼 (MGWO) 算法优化双向长短时记忆 (BiLSTM) 神经网络的水冷壁壁温预测模型, 灰狼算法采用非线性因子调整策略、自适应位置更新策略和动态权重修改策略进行改进以提升算法的全局寻优能力, 利用改进灰狼算法优化 BiLSTM 模型的隐藏层数量、学习率和正则化参数以提高模型的预测精度, 采用新疆某电厂的数据进行预测仿真, 结果表明: 改进后的算法预测精度更高, 在机组升、降负荷时, 均可以预测到壁温的变化趋势, 模型的平均均方根误差相比于长短时记忆 (LSTM) 神经网络、BiLSTM 模型分别降低了 9.86% 和 3.69%, 且可以提前预测到水冷壁壁温的超温情况, 对于预防水冷壁超温有重要意义。

[关键词] 水冷壁; 壁温预测; 双向长短时记忆神经网络; 改进灰狼算法; 自适应位置更新

[引用本文格式] 詹毅, 冯磊华, 杨锋, 等. 基于改进灰狼算法优化双向长短时记忆神经网络的水冷壁壁温预测[J]. 热力发电, 2024, 53(1): 188-196. ZHAN Yi, FENG Leihua, YANG Feng, et al. Prediction of water wall temperature based on improved grey wolf optimizer and bidirectional long and short term memory network[J]. Thermal Power Generation, 2024, 53(1): 188-196.

Prediction of water wall temperature based on improved grey wolf optimizer and bidirectional long and short term memory network

ZHAN Yi¹, FENG Leihua¹, YANG Feng², ZHONG Xin¹
(1.School of Energy and Power Engineering, Changsha University of Science and Technology, Changsha 410114, China;
2.HNAC Technology Co., Ltd., Changsha 410006, China)

Abstract: An improved grey wolf optimizer (MGWO) is used to optimize BiLSTM to predict water wall temperature. The improved algorithm adopts nonlinear factor adjustment strategy, adaptive position update strategy and dynamic weight modification strategy to improve the global optimization ability of the GWO. The improved grey wolf optimizer is used to optimize the number of hidden layers, learning rate and regularization parameters of the BiLSTM model to improve the prediction accuracy of the model. The data of a power plant in Xinjiang are used for prediction simulation. The results show that, the improved optimizer has higher prediction accuracy, and can predict the change trend of wall temperature when the unit is lifting and lowering load. Compared with the LSTM and BiLSTM models, the average root mean square error of the model reduces by 9.86% and 3.69%, respectively, and the overtemperature of water wall temperature can be predicted in advance, which is of great significance for the prevention of overtemperature of water wall.

Key words: water wall; prediction of wall temperature; bidirectional long and short term memory neural network; improved grey wolf optimizer; adaptive location updates

近年来我国超(超)临界机组发展迅速, 但锅炉水冷壁管、过热器管、再热器管和省煤器管四管爆管

问题仍时有发生^[1]。特别是随着新能源发电的大规模并网, 火力发电机组负荷快速、频繁、大幅波动已成

收稿日期: 2023-05-08

基金项目: 湖南省自然科学基金项目 (2018JJ3552)

Supported by: Natural Science Foundation of Hunan Province (2018JJ3552)

第一作者简介: 詹毅 (1999), 男, 硕士研究生, 主要研究方向为热工过程控制建模与优化控制, zy15675451590@163.com。

通信作者简介: 冯磊华 (1980), 女, 博士, 副教授, 主要研究方向为热工过程建模与优化控制, fengleihua80@126.com。

为新常态^[2],更进一步加剧了(四管)爆管问题,对机组安全造成了严重的影响^[3]。研究表明,引起受热面爆管的原因为受热面长时间超温运行^[4-5]、高温腐蚀^[6-7]、垢下腐蚀^[8]及锅炉水处理不当^[9]等,其中水冷壁管超温是造成水冷壁爆管的主要原因。因此,建立准确、快速预测水冷壁壁温的模型,对于保障机组的运行安全尤为重要。

目前对于水冷壁壁温的控制与预防,主要分为 3 个方面:1)通过实际测量技术及壁温测点直接得到壁温数据^[10],此类方法可以快速、精准测算出壁温温度,但是炉膛内燃烧情况多变,容易出现仪器损毁或者测量数据丢失等情况;2)通过数值模拟或依据测量数据,计算炉膛内负荷和工质水动力的变化,建立炉膛数值模型,计算水冷壁壁温^[11-12],此类方法对于受热面的传热计算模型大都经过简化处理,或者是在稳态工况下进行计算的,很难准确得到锅炉负荷发生变化时的受热面壁温;3)基于人工智能、模糊识别、机器学习等方法得到水冷壁壁温的预测模型^[13-14]。传统的以人工智能算法和机器学习为核心的壁温预测方法(如 ANN、ELM、SVM、BP 神经网络),在处理非线性问题方面表现较大优势,但面对水冷壁壁温这类与机组蓄热相关的强时序问题时,预测效果不佳。

近年来,卷积神经网络(CNN)和长短时记忆(LSTM)神经网络被广泛用于处理时间序列的问题,前者更适用于图像分类的工作,而后者在时间序列预测方面具有更广泛的运用^[15]。水冷壁壁温受水、煤、风多种因素影响同时锅炉蓄热也对壁温影响较大,要想准确预测水冷壁壁温,需要充分挖掘数据中存在的信息。其中,双向长短时记忆(BiLSTM)神经网络对数据挖掘更加充分,可以从前向和后向同时传递信息,在处理多维输入数据和长时间序列面前更具优势。同样地,神经网络在超参数的选取方面也很重要,隐藏层数量、学习率和正则化参数等超参数对模型的预测结果具有较大的影响,现有选取方法以手动调节为主且主要依靠经验进行选取,因此较容易错过最优参数组合。将各种元启发式算法结合神经网络自动寻优最佳超参数组合是一种解决途径。灰狼算法是一种新型优化算法,灰狼算法在最优解方面比遗传算法、粒子蚁群等元启发式算法具有更高的收敛速度和精度^[16],但灰狼算法在进化后期容易出现早熟和局部收敛的问题,因此需要对其进行改进,再用来寻找 BiLSTM 神经网络的最优超参数组合。

综上,本文利用 BiLSTM 神经网络预测水冷壁管壁温度(壁温),并通过改进灰狼优化(MGWO)算法对模型参数进行寻优,以提升其预测精度和泛化能力。该方法通过灰色关联度分析影响水冷壁壁温的相关因素,选取高相关度因素作为输入变量,并利用 MGWO 算法优化 BiLSTM 模型隐藏层、学习率、正则化参数,最终输出壁温预测结果。

1 双向长短时记忆神经网络

LSTM 神经网络是递归神经网络的改进版本,适合处理时间序列中间隔和延迟非常长的重要事件^[17],解决了传统 RNN 中的梯度消失或者爆炸问题。但是传统 LSTM 神经网络总是对数据从前到后进行训练,即水冷壁壁温参数在 LSTM 模型中是按照时间序列从前到后进行训练,这种训练方式对数据的利用率不高,不能充分挖掘数据内在特征。

BiLSTM 神经网络由 2 个 LSTM 神经网络组成,其可以利用过去和未来的状态来提高预测的准确性^[18]。因此 BiLSTM 模型能将当前壁温数据同过去和未来的数据产生联系,对当前壁温模型进行修正以提高预测精度。BiLSTM 模型如图 1 所示。与传统 LSTM 神经网络相比,其构建了一个前向和后向传播的双向递归神经网络,有效克服了 LSTM 神经网络数据信息不足的缺点。

对于 BiLSTM 神经网络,前向传播层和后向传播层分别从 $1 \sim t$ 和 $t \sim 1$ 进行计算,并在每个时刻保持各自的状态,最终由前向层和后向层各时刻对应的输出值叠加得到相应的壁温值。具体数学表达式为:

$$h_t = f(W_1 \cdot x_t + W_2 \cdot h_{t-1}) \quad (1)$$

$$h'_t = f(W_3 \cdot x_t + W_5 \cdot h_{t-1}) \quad (2)$$

$$o_t = g(W_4 \cdot x_t + W_6 \cdot h'_t) \quad (3)$$

式中: h_t 、 h'_t 分别为前向、后向隐藏层状态; W_1 — W_6 为共享权重。




图 1 BiLSTM 模型结构
Fig.1 Bidirectional LSTM model structure

2 改进灰狼优化算法

2.1 算法简介

灰狼优化 (grey wolf optimization, GWO) 算法是澳大利亚学者 Mirjalili^[19-20]受狼群猎食行为的启发所提出来的, 该算法具有控制参数较少、搜索效率高、收敛速度快等特点。对于标准 GWO 算法, 它的位置更新方程仅凭 α 狼引导, 因此其局部寻优能力强而全局探索能力弱; 此外收敛因子 α 会在一定程度影响到算法的全局寻优能力和局部寻优能力之间的平衡性, 且标准 GWO 算法设置的是随迭代次数从 2 线性递减到 0。然而在针对水冷壁壁温预测分析上, 由于算法的搜索过程较为复杂, 线性收敛因子很难适应实际搜索情况, 容易使算法陷入局部最优解, 因此, 本文对标准 GWO 算法提出以下改进措施:

1) 非线性收敛因子调整策略 收敛因子 α 的不同更新策略会对算法性能产生极大的影响^[21-22], 而且线性策略往往不是最有效的^[23], 因此本文提出一种非线性收敛因子更新方式为:

$$\alpha = 1 - \tanh((t - K_1 \cdot T) / (K_2 \cdot T)) \quad (4)$$

式中: K_1 、 K_2 为调节系数, 其取值范围为(0,1); t 为当前迭代次数; T 为最大迭代次数。

式(4)所示的非线性收敛因子更新策略, 调整 K_1 和 K_2 取值即可改变收敛因子 α 的非线性特征。若发现训练后的水冷壁壁温数据出现过拟合现象或者模型出现局部最优解, 可增大 K_1 及降低 K_2 值, 降低收敛因子 α 的前期递减速率, 使算法的全局寻优能力得到加强; 后期递减速率加快, 加强算法的收敛速度。反之, 则降低 K_1 及增大 K_2 值。经过仿真模拟最终确定 K_1 的值为 0.6, K_2 的值为 0.1。

2) 自适应位置更新策略 在实际的寻优过程中, α 狼更可能为最优解。为突出最优狼对种群的全局领导能力及强化算法的全局搜索能力, 在位置更新过程中逐步增加 α 狼的权重, 其数学表达式如下:

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \left(1 - \frac{t}{T}\right) + W \vec{X}_1 \frac{t}{T} \quad (5)$$

$$W = \sin\left(\frac{\pi t}{2T}\right) \quad (6)$$

3) 修改动态权重策略 文献[24]指出, 传统 GWO 算法中 \vec{X}_1 、 \vec{X}_2 、 \vec{X}_3 求平均值的方式不能体现 α 、 β 、 δ 三者间的重要程度, 因此采用一种基于改进步长欧氏距离的比例权重为:

$$W_1 = \frac{|\vec{X}_1|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3|} \quad (7)$$

$$W_2 = \frac{|\vec{X}_2|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3|} \quad (8)$$

$$W_3 = \frac{|\vec{X}_3|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3|} \quad (9)$$

结合式(5)的自适应位置更新策略, 改进后的灰狼位置更新方式可表示为:

$$\vec{X}(t+1) = \frac{W_1 \vec{X}_1 + W_2 \vec{X}_2 + W_3 \vec{X}_3}{3} \left(1 - \frac{t}{T}\right) + W \cdot \vec{X}_1 \frac{t}{T} \quad (10)$$

本文主要对灰狼算法的收敛因子、位置更新及动态权重 3 个方面进行改进, 理论上改进后 MGWO 算法的寻优效率会极大增强, 收敛值会更加精确, 算法更容易跳出局部最优解。为检验改进后的灰狼优化 (MGWO) 算法的有效性, 需要对 MGWO 算法进行性能测试。

2.2 MGWO 算法性能测试

本文采用 6 种不同的基准测试函数对 MGWO 算法的性能进行检验, 其中 f_1 、 f_2 为单峰基准函数, f_3 、 f_4 为多峰基准函数, f_5 、 f_6 为固定维多峰函数^[25]。基准函数的具体信息见表 1, 函数优化收敛曲线如图 2 所示。由图 2 可知, MGWO 算法在初期可以快速收敛, 且收敛效率均高于 GWO 算法, 表明改进的非线性收敛因子提升了寻优效率。 f_1 、 f_2 单峰基准函数中, MGWO 算法的收敛精度远高于 GWO 算法; f_3 、 f_4 多峰基准函数中, MGWO 算法可以求得最优解 0; f_5 、 f_6 固定维多峰函数中, MGWO 算法可以很快跳出局部最优, 而 GWO 算法陷入局部最优解, 表明改进策略可以使算法有效跳出局部最优解。对比 GWO 算法, MGWO 算法的收敛值更接近理论最优值, 表明改进后的函数有效地提高了寻优精度, 且减少了算法进入局部最优解的概率。

因此, MGWO 算法可以有效提升 BiLSTM 神经网络的性能, 能进一步增强水冷壁壁温的预测精度。

3 算例分析

3.1 数据归一化处理

为保证不同变量对水冷壁壁温的影响相同, 且保证收敛速度及提升模型精度, 需要对水冷壁壁温及相关影响因素进行归一化处理, 将数据归算到[0, 1]。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

表 1 基准函数
Tab.1 Baseline functions

函数	维数	范围	最优解
$f_1(x) = \sum_{i=1}^n x_i^2$	30	[-100, 100]	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	[-10, 10]	0
$f_3(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	[-5.12, 5.12]	0
$f_4(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	[-600, 600]	0
$f_5(x) = \left(\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1}$	2	[-65, 65]	1
$f_6(x) = \sum_{i=1}^{11} \left[a_i - \frac{x_i(b_i^2 + b_j x^2)}{b_i^2 + b_j x_3 + x_4} \right]^2$	4	[-5, 5]	0.000 30

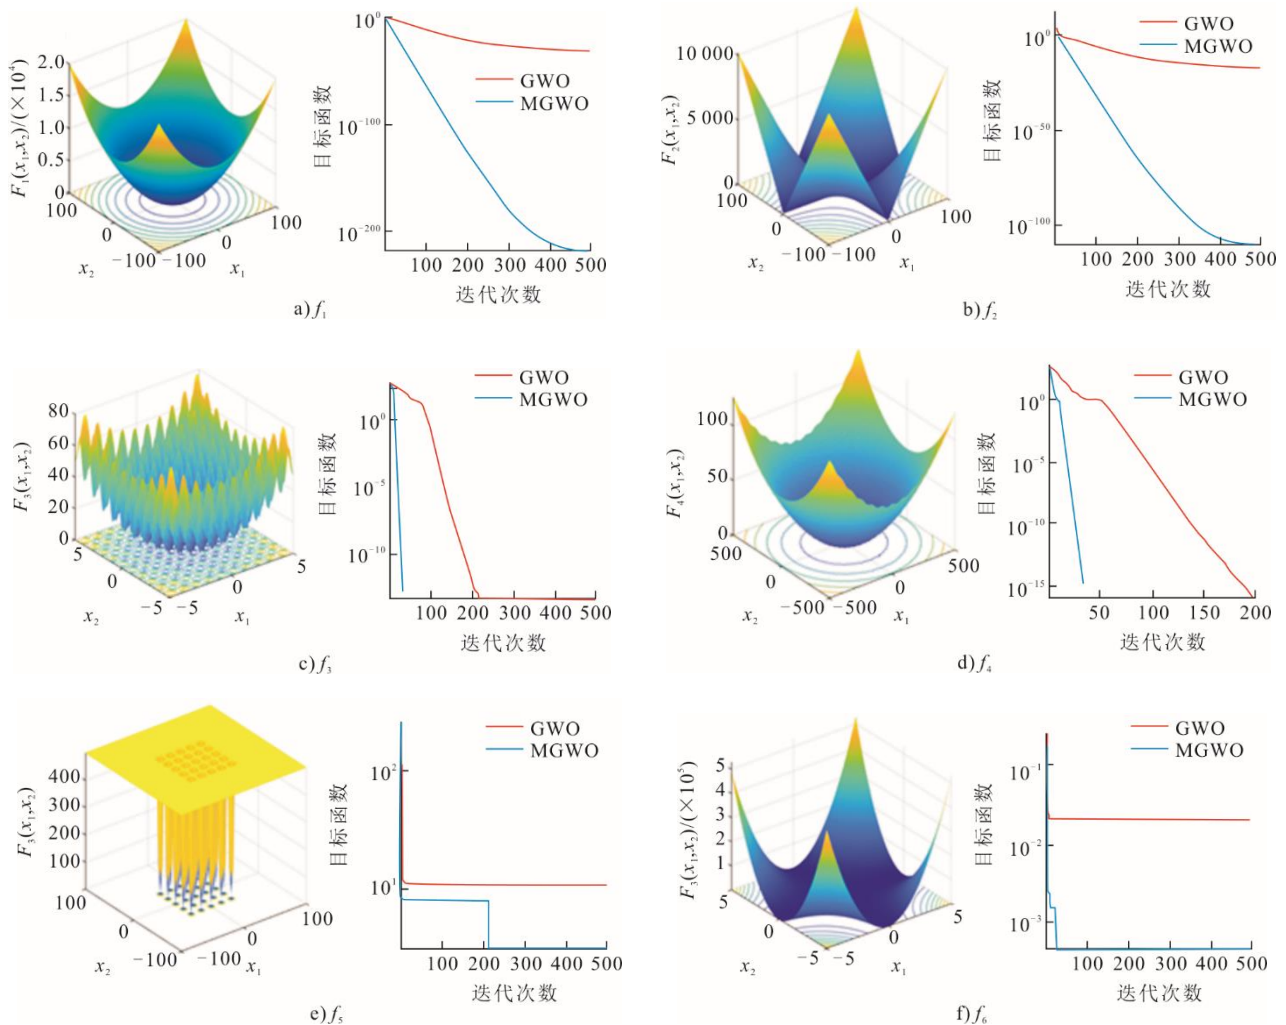


图 2 函数优化收敛曲线
Fig.2 Function optimization convergence curves

式中： x' 为归一化后的值； x 为实际值； x_{\max} 、 x_{\min} 分别为变量的极大值和极小值。

3.2 评价指标选取

本文采取在壁温预测中常被使用的评价指标

平均绝对误差 δ_{MAE} 、平均绝对百分比误差 δ_{MAPE} 和均方根误差 δ_{RMSE} 对水冷壁壁温预测模型性能进行评估, 其计算如式(12)~式(14):

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (12)$$

$$\delta_{MAPE} = \frac{100\%}{n} \sum_{i=1}^n |(y_i - y'_i) / y_i| \quad (13)$$

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (14)$$

式中: n 为预测数; y_i 为水冷壁温真实值; y'_i 为水冷壁温预测值。

3.3 灰色关联度分析

灰色关联度分析^[26]是一种多因素统计分析方法, 它可以有效地处理非线性和不确定问题, 比较适合分析锅炉壁温与其他因素相关性之类的非线性问题。灰色关联分析的主要任务是根据水冷壁壁温的几何曲线变化趋势, 分析确定各因素的影响, 研究壁温与其他影响因素之间的相似性。其关联系数 ζ_i 可表示为:

$$\zeta_i(k) = \frac{\min_i \min_k \Delta r + \rho \cdot \max_i \max_k \Delta r}{\Delta r + \rho \cdot \max_i \max_k \Delta r} \quad (15)$$

式中: $\Delta r = |x_0(k) - x_i(k)|$; ρ 为分辨系数, 通常取 0.5。

为了反映比较序列与水冷壁壁温序列之间的关联关系, 求出比较序列所有关联系数的均值, 称为关联序列 r_{0i} , 关联序列 r_{0i} 越大, 相关性越强^[27], 具体计算公式如下:

$$r_{0i} = \frac{1}{m} \sum_{k=1}^m \zeta_i(k) \quad (16)$$

式中: m 为元素个数; 下标“0”表示水冷壁壁温序列; i 表示比较序列。

3.4 模型数据集及输入变量的选取

本文研究对象为新疆准东地区某电厂超超临界 660 MW 锅炉, 该锅炉为一次中间再热、超超临界压力变压运行、单炉膛、平衡通风、固态排渣、全钢架、全悬吊结构、紧身封闭布置的 II 型锅炉, 采用四角切圆燃烧方式, 主燃烧器布置在水冷壁的四角。选取该电厂 2021 年 8 月 18 日至 2021 年 8 月 24 日的实测数据作为数据集。因水冷壁壁温数据时效性较强, 故每 30 s 进行一次采样, 剔除异常数据后共包含 18 000 组数据。预测模型中应用的训练集、测试集选取见表 2。

引起壁温超温的因素很多, 其中最直接的影响因素分为烟气侧和工质侧 2 个方面。烟气侧主要与

炉膛热负荷和配风有关, 工质侧主要与给水有关。经查阅相关文献后, 初步确定机组功率、总燃料量、锅炉出口烟气含氧量、主蒸汽压力、主蒸汽温度、给水流量、给水温度、给水压力、分离器出口壁温、分离器出口蒸汽压力、一次风风量、一次风风温、一次风风压、二次风风量、二次风风压、中间点过热度等 16 个变量作为影响水冷壁壁温的初选变量, 并将其设置为比较序列, 取一测点水冷壁壁温作为参考序列。根据式(15)及式(16), 将灰色关联度计算结果按从大到小汇总, 计算结果见表 3。

表 2 数据集

Tab.2 Data set

数据类型	选取时段	数据组数
数据集	8 月 18 日—8 月 24 日	18 000
训练集	8 月 18 日—8 月 22 日	14 112
测试集	8 月 23 日—8 月 24 日	3 888

表 3 灰色关联度计算结果

Tab.3 The grey correlation degree calculation result

因素	灰色关联度	因素	灰色关联度
主蒸汽温度	0.973	机组功率	0.825
分离器壁温	0.971	给水流量	0.810
一次风温	0.961	一次风压	0.785
给水温度	0.950	二次风总量	0.777
一次风总量	0.941	给水压力	0.760
主蒸汽压力	0.869	出口烟气含氧量	0.753
分离器出口蒸汽压力	0.865	中间点过热度	0.716
总燃料量	0.835	二次风压	0.694

为确定水冷壁温预测模型最优输入参数的个数, 需要对模型的输入变量个数进行试验, 以确定最佳输入参数个数。试验模型为 MGWO-BiLSTM, 试验结果见表 4。

表 4 输入参数个数对预测模型的影响

Tab.4 The effect of the number of input parameters on the predictive model

输入参数个数	δ_{RMSE}
6	8.681 4
8	8.524 9
9	8.299 5
10	7.771 4
11	8.450 6
12	8.764 0

由表 4 可见, 当输入参数个数为 10 时模型的 δ_{RMSE} 最小, 即输入变量选择 10 个可以提高模型的预测精度。最终确定 MGWO-BiLSTM 模型的输入变量为主蒸汽温度、分离器壁温、一次风温、给水

温度、一次风总量、主蒸汽压力、分离器出口蒸汽压力、总燃料量、机组功率、给水流量；输出变量为水冷壁壁温。

3.5 MGWO-BiLSTM 模型求解

运用灰色关联度对影响水冷壁温的相关因素进行筛选，将相关度高的因素作为输入变量输入神经网络，然后让改进灰狼算法对 BiLSTM 神经网络的隐藏层数量、学习率和正则化参数进行全局寻优，其约束条件见表 5，最后输出预测变量为水冷壁壁温，MGWO-BiLSTM 预测模型求解的流程图如图 3 所示。

表 5 改进灰狼算法优化参数
Tab.5 Optimization parameters of the improved grey wolf algorithm

改进灰狼算法优化参数	约束范围
隐藏层节点数	[10, 80]
学习率	[0.001, 0.01]
正则化参数 L_2	[0.000 1, 0.001]

3.6 预测结果

为验证本文提出的 MGWO-BiLSTM 预测模型的准确性，现将 LSTM 模型、BiLSTM 模型、MGWO-

BiLSTM 模型分别对水冷壁壁温进行预测分析。图 4 为所有数据集上的预测曲线，包含 8 月 18 日—8 月 22 日的训练集预测曲线和 8 月 23 日—8 月 24 日的测试集预测曲线，表 6 为不同模型间的预测性能比较。

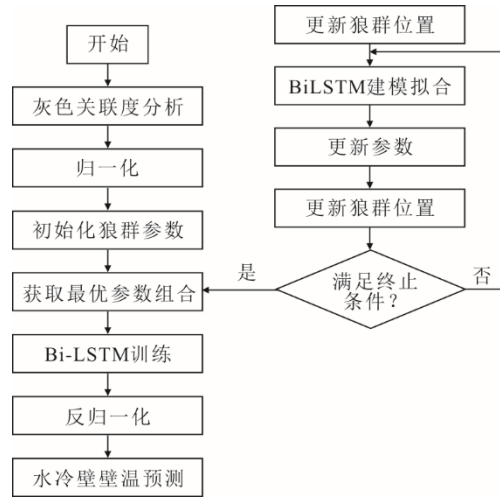


图 3 MGWO-BiLSTM 预测水冷壁壁温流程
Fig.3 MGWO-BiLSTM predicts the wall temperature process of the water wall




图 4 所有数据集的预测性能曲线
Fig.4 Prediction performance curves of all datasets

表 6 不同预测模型的预测性能比较
Tab.6 Comparison of prediction performance of different predictive models

模型	$\delta_{RMSE}/^{\circ}C$		$\delta_{MAE}/^{\circ}C$		$\delta_{MAPE}/\%$	
	训练集	测试集	训练集	测试集	训练集	测试集
LSTM	8.851 1	9.836 1	5.598 9	7.744 6	1.43	2.05
BiLSTM	8.861 5	9.205 3	5.505 6	6.635 4	1.41	1.76
MGWO-BiLSTM	6.422 2	8.865 9	4.017 6	6.197 2	1.02	1.62

由图4可以看出：在训练集（8月18日—8月22日的数据）中3种模型的预测值与实际值相比整体趋于一致，但当机组降负荷时（如断面1所示），LSTM模型和BiLSTM模型并不能精确地预测到壁温的变化趋势；预测集中LSTM模型和BiLSTM模型没有预测到水冷壁超温的情况，而MGWO-BiLSTM模型有效预测到了水冷壁壁温超温。且由表6可知，MGWO-BiLSTM模型的 δ_{RMSE} 、 δ_{MAE} 、 δ_{MAPE} 均低于前2个模型，其模型的 δ_{RMSE} （测试集）相比于LSTM、BiLSTM模型分别降低了9.86%和3.69%。为了更清楚地观测其预测效果，分别选取图4中的3个断面进行放大分析，断面1为机组降负荷时的预测曲线，断面2为机组稳定负荷时的预测曲线，断面3为机组升负荷时的预测曲线，其结果分别如图5—图7所示，对应的模型预测性能见表7—表9。

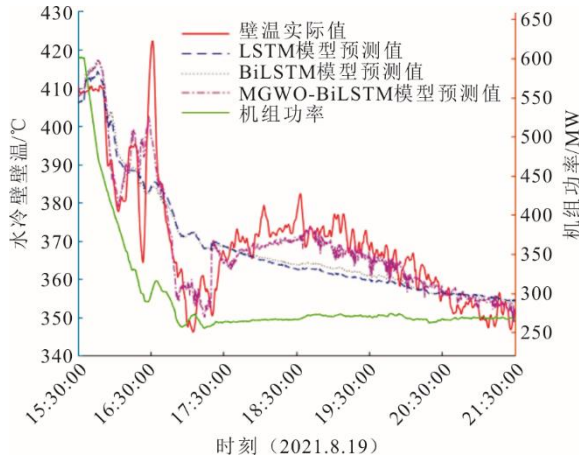


图5 降负荷壁温预测曲线
Fig.5 The predicted wall temperature curves during load reduction

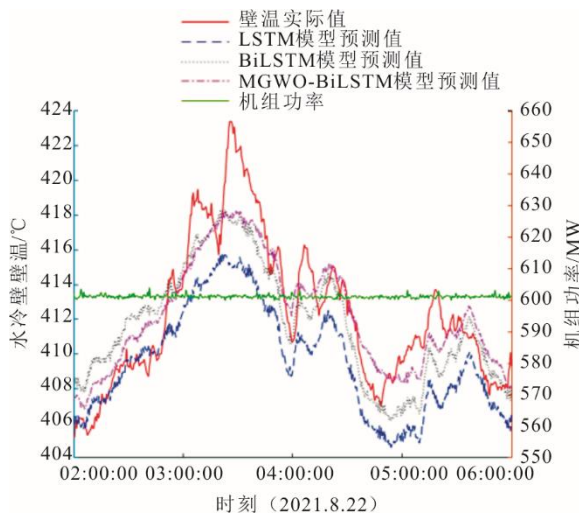


图6 稳定负荷壁温预测曲线
Fig.6 The predicted wall temperature curves at stable load

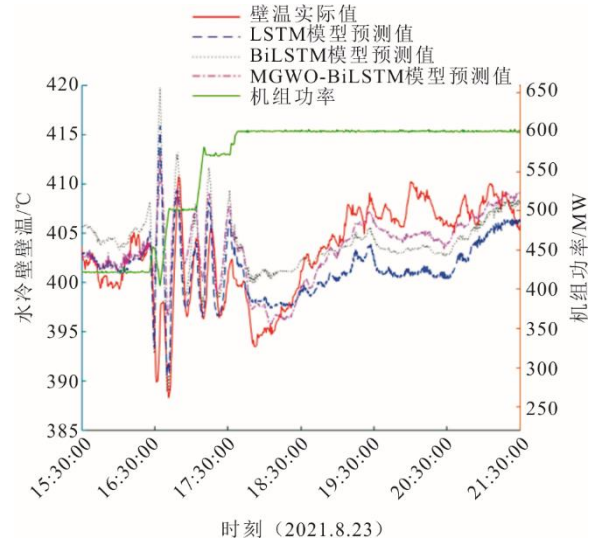


图7 升负荷壁温预测曲线
Fig.7 The predicted wall temperature curves during load ascending

表7 降负荷时模型预测性能
Tab.7 The model prediction performance when load is down

模型	$\delta_{RMSE}/^{\circ}C$	$\delta_{MAE}/^{\circ}C$	$\delta_{MAPE}/\%$
LSTM	9.892 8	7.885 4	2.13
BiLSTM	9.602 8	7.535 4	2.03
MGWO-BiLSTM	6.206 2	4.379 7	1.18

表8 稳定负荷时模型预测性能
Tab.8 The model prediction performance when the load is stable

模型	$\delta_{RMSE}/^{\circ}C$	$\delta_{MAE}/^{\circ}C$	$\delta_{MAPE}/\%$
LSTM	3.415 6	2.841 0	0.69
BiLSTM	2.263 5	1.910 9	0.46
MGWO-BiLSTM	1.713 0	1.404 8	0.34

表9 升负荷时模型预测性能
Tab.9 The model prediction performance when load raises

模型	$\delta_{RMSE}/^{\circ}C$	$\delta_{MAE}/^{\circ}C$	$\delta_{MAPE}/\%$
LSTM	4.439 2	3.498 4	0.87
BiLSTM	4.352 0	3.343 2	0.83
MGWO-BiLSTM	3.456 0	2.404 3	0.60

由图5可知，机组在降负荷时，前2种模型的预测效果不太理想，预测精度较差，而MGWO-BiLSTM模型可以稳定地预测到降负荷时壁温的变化趋势。同时，由表7可见，MGWO-BiLSTM模型的 δ_{RMSE} 为6.2062℃， δ_{MAE} 为4.3797℃， δ_{MAPE} 为1.18%。相比于LSTM模型和BiLSTM模型，其 δ_{RMSE} 分别降低了37.26%、35.37%； δ_{MAE} 分别降低了44.46%、41.88%； δ_{MAPE} 分别降低了44.6%、41.87%。结果表明，MGWO-BiLSTM模型对机组降负荷下的预测适应性较好，在机组进行调峰而频繁升降负荷

的环境下有较大的优势。

由图6可得,机组在稳定负荷或负荷保持不变时,LSTM模型、BiLSTM模型、MGWO-BiLSTM模型对壁温的预测效果都较好。观察表8发现MGWO-BiLSTM模型的误差更小,其 δ_{RMSE} 仅为1.713 0 °C,同时 δ_{MAE} 和 δ_{MAPE} 分别为1.404 8 °C和0.34%。

由图7可得,机组在升负荷时,3个模型对壁温的预测值均比较好。同时,由表9可见,MGWO-BiLSTM模型的 δ_{RMSE} 、 δ_{MAE} 、 δ_{MAPE} 均最小,分别为3.456 0 °C、2.404 3 °C、0.60%。结果表明,MGWO-BiLSTM模型无论是在机组升、降负荷,还是在机组保持稳定负荷时,均对水冷壁壁温的预测效果较好。

4 结 论

本文采用新疆某电厂历史运行数据作为训练数据,并将预测结果与LSTM和BiLSTM神经网络等常用时间序列壁温预测方法进行对比。以 δ_{RMSE} 、 δ_{MAE} 和 δ_{MAPE} 为评价指标,验证本文所提出的MGWO-BiLSTM神经网络模型的预测精度和准确度,并得出以下结论。

1) 相对于传统预测模型,MGWO-BiLSTM模型可以充分发掘水冷壁壁温的时序特征,且MGWO算法可以避免模型陷于局部最优,因此模型的 δ_{RMSE} 相比于LSTM、BiLSTM模型分别降低了9.86%和3.69%,提高了模型的预测精度。

2) 机组负荷变化在50%~100%范围内,无论机组升、降负荷,MGWO-BiLSTM模型均可以很好预测水冷壁壁温的变化趋势。同时,该模型可以有效预测到机组在降负荷时可能出现的超温情况。研究成果可为研究人员改进水冷壁壁温控制系统提供了思路与参考。

[参 考 文 献]

- [1] 王春昌. 水冷壁流量偏差及其超温爆管[J]. 热力发电, 2007, 36(10): 30-32.
WANG Chunchang. Flow rate deviation in the water-wall and overtemperature tube-burst thereof[J]. Thermal Power Generation, 2007, 36(10): 30-32.
- [2] 高林, 王林, 刘畅, 等. 火电机组深度调峰热工控制系统改造[J]. 热力发电, 2018, 47(5): 95-100.
GAO Lin, WANG Lin, LIU Chang, et al. Thermal control system retrofit for deep peak load regulation of thermal power unit[J]. Thermal Power Generation, 2018, 47(5): 95-100.
- [3] 朱亚清, 张曦. 超超临界1000MW机组锅炉水冷壁管

- 超温控制策略[J]. 热力发电, 2015, 44(8): 99-103.
ZHU Yaqing, ZHANG Xi. Control strategy for water wall overheat in a 1 000 MW ultra supercritical unit[J]. Thermal Power Generation, 2015, 44(8): 99-103.
- [4] 周凌宇, 刘辉, 周平, 等. 300 MW 墙式切圆锅炉水冷壁超温的数值模拟与燃烧优化[J]. 热能动力工程, 2022, 37(3): 129-135.
ZHOU Lingyu, LIU Hui, ZHOU Ping, et al. Numerical simulation and combustion optimization on the water wall overtemperature in 300 MW wall-tangentially fired boiler[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(3):129-135.
- [5] 蔡晖, 史志刚, 秦承鹏, 等. 深度调峰机组水冷壁管开裂原因分析[J]. 热力发电, 2020, 49(11): 176-181.
CAI Hui, SHI Zhigang, QIN Chengpeng, et al. Cause analysis for cracking of water-wall tubes in steam depth peaking unit[J]. Thermal Power Generation, 2020, 49(11): 176-181.
- [6] 王毅斌, 张思聪, 谭厚章, 等. 劣质烟煤低氮燃烧模式下水冷壁高温腐蚀与硫化物沉积形成分析[J]. 中国电机工程学报, 2020, 40(24): 8058-8066.
WANG Yibin, ZHANG Sicong, TAN Houzhang, et al. Analysis of high-temperature corrosion and sulfide deposits formed on water-wall tubes under low-NO_x combustion mode for low-qualities bituminous coal[J]. Proceedings of the CSEE, 2020, 40(24): 8058-8066.
- [7] 程超, 韩建伟, 任建辉. 300 MW 电站锅炉水冷壁高温腐蚀现象产生原因的探讨[J]. 电站系统工程, 2023, 39(2): 22-24.
CHENG Chao, HAN Jianwei, REN Jianhui. Discussion on high temperature corrosion of 300 MW utility boiler water wall[J]. Power System Engineering, 2023, 39(2): 22-24.
- [8] 宋兆华. 电站锅炉水冷壁垢下腐蚀分析及防护[J]. 设备管理与维修, 2022(10): 45-48.
SONG Zhaohua. Corrosion analysis and protection under water wall scale of power station boiler[J]. Plant Maintenance Engineering, 2022(10): 45-48.
- [9] 王悦, 谢小娟, 郭佳鑫, 等. 锅炉水冷壁爆管原因分析及措施探讨[J]. 广东化工, 2022, 49(4): 175-177.
WANG Yue, XIE Xiaojuan, GUO Jiaxin, et al. Cause analysis and measures discussion on tube explosion of boiler water wall[J]. Guangdong Chemical Industry, 2022, 49(4): 175-177.
- [10] CALISTO H. Transient transpiration radiometer-development of a heat flux sensor for high aggressivity environments thesis submitted in partial fulfilment for the degree of doctor of philosophy in mechanical engineering[D]. Portugal: University of Aveko, 2013: 1.
- [11] 蒋晓锋. 1 000 MW 双切圆锅炉热力计算及模拟分析[D]. 上海: 上海交通大学, 2014: 1.
JIANG Xiaofeng. Thermodynamic calculation and simulation analysis in a 1 000 MW double tangential boiler[D]. Shanghai: Shanghai Jiao Tong University, 2014: 1.
- [12] CHEN T, ZHANG Y J, LIAO M R, et al. Coupled modeling of combustion and hydrodynamics for a coal-fired supercritical boiler[J]. Fuel, 2019, 240: 49-56.
- [13] DHANUSKODIA R, KALIAPPANA R, SURESHA S, et al. Artificial neural networks model for predicting wall temperature of supercritical boilers[J]. Applied Thermal Engineering, 2015, 90: 749-753.
- [14] 苏学能, 刘天琪, 曹鸿谦, 等. 基于 Hadoop 架构的多

- 重分布式 BP 神经网络的短期负荷预测方法[J]. 中国电机工程学报, 2017, 37(17): 4966-4973.
- SU Xueneng, LIU Tianqi, CAO Hongqian, et al. A multiple distributed BP neural networks approach for short-term load forecasting based on hadoop framework[J]. Proceedings of the CSEE, 2017, 37(17): 4966-4973.
- [15] 张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述[J]. 计算机工程与应用, 2021, 57(11): 57-69.
- ZHANG Chi, GUO Yuan, LI Ming. Review of development and application of artificial neural network models[J]. Computer Engineering and Applications, 2021, 57(11): 57-69.
- [16] MIRJALILI S. How effective is the grey wolf optimizer in training multi-layer perceptrons[J]. Applied Intelligence, 2015, 43(1): 150-161.
- [17] 刘建伟, 王园方, 罗雄麟. 深度记忆网络研究进展[J]. 计算机学报, 2021, 44(8): 1549-1589.
- LIU Jianwei, WANG Yuanfang, LUO Xionglin. Research and development on deep memory network[J]. Chinese Journal of Computers, 2021, 44(8): 1549-1589.
- [18] LIN Y, CHEN K C, ZHANG X, et al. Forecasting crude oil futures prices using BiLSTM-Attention-CNN model with wavelet transform[J]. Applied Soft Computing, 2022, 130: 109723.
- [19] MIRJALIL SI, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [20] SAREMI Z. Evolutionary population dynamics and grey wolf optimizer[J]. Neural Computing and Applications, 2015, 26(5): 1257-1263.
- [21] 左剑, 张程稳, 肖逸, 等. 基于灰狼优化算法的多机电力系统稳定器参数最优设计[J]. 电网技术, 2017, 41(9): 2987-2995.
- ZUO Jian, ZHANG Chengwen, XIAO Yi, et al. Multi-machine PSS parameter optimal tuning based on grey wolf optimizer algorithm[J]. Power System Technology, 2017, 41(9): 2987-2995.
- [22] YU C C, SHIH P C, LI X C. A dynamic adjusting novel global harmony search for continuous optimization problems[J]. Symmetry, 2018, 10(8): 337.
- [23] 张阳, 周溪召. 求解全局优化问题的改进灰狼算法[J]. 上海理工大学学报, 2021, 43(1): 73-82.
- ZHANG Yang, ZHOU Xizhao. Modified grey wolf optimization algorithm for global optimization problems[J]. Journal of University of Shanghai for Science and Technology, 2021, 43(1): 73-82.
- [24] RODRÍGUEZ L, CASTILLO O, SORIA J, et al. A fuzzy hierarchical operator in the grey wolf optimizer algorithm[J]. Applied Soft Computing, 2017, 57: 315-328.
- [25] 龙文, 蔡绍洪, 焦建军, 等. 一种改进的灰狼优化算法[J]. 电子学报, 2019, 47(1): 169-175.
- LONG Wen, CAI Shaohong, JIAO Jianjun, et al. An improved grey wolf optimization algorithm[J]. Acta Electronica Sinica, 2019, 47(1): 169-175.
- [26] 刘文颖, 门德月, 梁纪峰, 等. 基于灰色关联度与LSSVM 组合的月度负荷预测[J]. 电网技术, 2012, 36(8): 228-232.
- LIU Wenyong, MEN Deyue, LIANG Jifeng, et al. Monthly load forecasting based on grey relational degree and least squares support vector machine[J]. Power System Technology, 2012, 36(8): 228-232.
- [27] 吉兴全, 曾若梅, 张玉敏, 等. 基于注意力机制的CNN-LSTM 短期电价预测[J]. 电力系统保护与控制, 2022, 50(17): 125-132.
- JI Xingquan, ZENG Ruomei, ZHANG Yumin, et al. CNN-LSTM short-term electricity price prediction based on an attention mechanism[J]. Power System Protection and Control, 2022, 50(17): 125-132.

(责任编辑 邓玲惠)

广告目次

《热力发电》.....	封三
浙江顺豪新材料有限公司.....	后彩插 1
西安热工研究院有限公司.....	后彩插 2—5
上海冠龙阀门节能设备股份有限公司.....	后彩插 6