

基于物理信息神经网络的冷却塔水温自适应分解组合预测^①



孙通¹, 吴萌¹, 杨生虎², 张耀明²

¹(西安建筑科技大学 信息与控制工程学院, 西安 710055)

²(国能平罗发电有限公司 生产技术部, 石嘴山 753400)

通信作者: 吴萌, E-mail: wumeng@xauat.edu.cn

摘要: 国有大型火力发电厂冷却塔的水温预测对“双碳”减排有重要意义, 为提高电厂运行能效, 解决监测数据非实时预测方法中的原始数据波动大、预测精度低等问题, 本文提出一种基于 PINN-CEEMDAN-GA-BiLSTM 分解组合模型的预测方法. 首先, 使用自适应噪声完全集合经验模态分解 (CEEMDAN) 模型在快速提取非线性和非光滑信号的时频特征方面的优势, 对分解得到的 13 个固有模态函数 (IMF) 进行重构. 其次, 使用遗传算法 (GA) 对 CEEMDAN 的参数进行优化调整. 最后, 引入物理信息神经网络 (PINN) 来引导物理规律和约束条件, 将物理信息纳入损失函数中, 利用双向长短期记忆神经网络 (BiLSTM) 模型在物理信息神经网络下对在每个重构的 IMF 分量进行建模和预测. 这种组合利用 BiLSTM 在物理信息神经网络下对数据进行更准确的建模, 有助于提高预测精度和模型的稳定性. 通过将该模型与其他混合模型进行对比分析, 结果证明, 所提出模型具有较高的预测精度, 决定系数、均方根误差、平均绝对误差和平均绝对百分比误差分别为 0.998 7、0.129 5、0.100 1、0.454 1, 验证了该模型在水温预测方面的有效性.

关键词: 水温预测; 物理信息神经网络; 自适应噪声完全集合经验模态分解; 双向长短期记忆网络

引用格式: 孙通, 吴萌, 杨生虎, 张耀明. 基于物理信息神经网络的冷却塔水温自适应分解组合预测. 计算机系统应用, 2025, 34(9): 180-191. <http://www.c-s-a.org.cn/1003-3254/9934.html>

Adaptive Decomposition Combinatorial Prediction for Condensation Tower Water Temperature Based on Physical Information Neural Network

SUN Tong¹, WU Meng¹, YANG Sheng-Hu², ZHANG Yao-Ming²

¹(College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

²(Production Technology Department, Guoneng Pingluo Power Generation Co. Ltd., Shizuishan 753400, China)

Abstract: The water temperature prediction of condensation towers in large state-owned thermal power plants is of great significance for “dual-carbon” emission reduction. To improve power plant operational efficiency and address issues in non-real-time monitoring methods, such as large fluctuations in raw data and low prediction accuracy, this study proposes a predictive method based on the PINN-CEEMDAN-GA-BiLSTM decomposition-combination model. Firstly, by leveraging the advantages of the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) model in quickly extracting time-frequency characteristics of nonlinear and non-smooth signals, the 13 intrinsic mode functions (IMFs) obtained from decomposition are reconstructed. Secondly, the genetic algorithm (GA) is used to optimize and adjust the parameters of CEEMDAN. Finally, the physics-informed neural network (PINN) is introduced to incorporate physical laws and constraints by integrating physical information into the loss function, and the bidirectional

① 基金项目: 国家重点研发计划 (2023YFC3803900)

收稿时间: 2025-01-16; 修改时间: 2025-02-12; 采用时间: 2025-03-06; csa 在线出版时间: 2025-07-14

CNKI 网络首发时间: 2025-07-15

long short-term memory (BiLSTM) neural network model is used to model and predict each reconstructed IMF component under the PINN. This combination uses BiLSTM to achieve more accurate data modeling under the PINN, contributing to enhanced prediction precision and model stability. Through comparative analysis with other hybrid models, the results show that the proposed model has high prediction accuracy, with determination coefficient, root mean square error, mean absolute error, and mean absolute percentage error reaching 0.998 7, 0.129 5, 0.100 1, and 0.454 1, respectively, which verify the effectiveness of the model in water temperature prediction.

Key words: water temperature prediction; physical information neural network (PINN); complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN); bidirectional long short-term memory (BiLSTM)

近年来,全球能源结构转型加速推进,“双碳”目标对电力行业提出严峻挑战^[1].作为我国主要的发电方式,火力发电在能源转型中扮演着至关重要的角色.以国能平罗电厂为例,该电厂建设有两台660 MW高效超临界空冷机组,总装机1320 MW,机组采用两机一塔,在额定工况下,冷却塔出塔水温每降低1℃可使真空度提升0.8–1.2 kPa,相应降低发电煤耗1.2–1.8 g/kWh.对于660 MW间接空冷机组,这一温控优化意味着单台机组年运行可减少标煤消耗约5000吨,同时削减二氧化碳排放量超1.3万吨,具有显著的经济效益和环保价值^[2].然而,冷却塔水温受机组参数和环境温度等因素影响,在调控过程中难以精准把握其非线性变化规律,导致部分工况下冷却系统偏离最优运行区间.因此,建立基于数据驱动的冷却塔水温预测模型对于实现冷却系统的动态优化调控以及提高电厂整体效率具有重要意义.

目前,针对温度的序列预测的研究,多个学者给出了不同的预测模型.其中有代表性的传统方法如Ahmadi-Nedushan等^[3]提出用统计方法以及Di Nunno等^[4]使用的堆叠多层感知器和随机森林方法,主要对日水温以及不同周期的水温变化进行研究,实验结果表明,堆叠模型远远优于浅层多层感知器.陈英义等^[5]使用优化后的BP神经网络预测养殖池塘的水温,优化后的BP神经网络解决了传统的水温小样本非实时预测方法预测精度低、鲁棒性的问题.杨豪等^[6]同样使用优化后的BP神经网络预测冷却塔的出塔水温,使用优化后的BP神经网络加入了影响冷却塔出塔水温的进塔水温、循环水流量等因素,比传统神经网络预测结果更加准确.Yu等^[7]提出 ε -SVR-AHP-BPANN的混合预测模型,分析了人类活动特征的人为因素和湖泊固有特性的物理因素,在预测日湖泊水温变化方面取得了良

好效果.Zhang等^[8]提出CNN和LSTM的混合模型,通过CNN提取数据集中的时空特征,LSTM捕获数据中的时间依赖关系和序列信息,从而提高模型的预测准确性.张锦荣等^[9]与李祥铜等^[10]分别提出EMD-LSTM和WTD-LSTM混合模型,分别通过对原始数据进行多尺度分解和小波变换处理,对原始数据进行分解,从而提高模型的预测精度.为了进一步提升模型的预测精度,Stajkowski等^[11]使用遗传算法^[12]优化的长短期记忆神经网络,对模型参数进行优化,解决了LSTM网络的时间窗大小和架构等问题;Ikram等^[13]使用爬行动物搜索算法应用于混合模型中获取超参数,实验结果表明,加入优化算法后的模型预测精度高于单一模型的预测精度.

为了使模型在具有更好的效果的同时具有更好的解释性,物理信息神经网络被广泛应用.PINN将物理方程知识和神经网络结合,有助于维持物理信息的一致性,提高模型的解释性和可靠性.Zanetta等^[14]通过将气象专业知识以解析方程的形式集成到深度学习后处理模型中,以实现深度学习模型的物理一致性,通过约束神经网络以强制执行热力学状态方程,可以得到在性能不受损的情况下具有物理一致性的温度预测和湿度预测,该方法在数据稀缺的情况下也尤有优势.Yuan等^[15]利用基于时空偏微分方程的物理引导神经网络来预测海面温度,通过将偏微分方程中的每一项作为可调参数,优化预测值与观测值之间的距离,提高了海面温度预测的精度.任少君等^[16]针对基于机器学习的 NO_x 排放浓度预测过度依赖训练样本等问题,提出一种基于物理信息神经网络的燃煤锅炉 NO_x 排放浓度预测方法,考虑煤量、氧量与 NO_x 排放浓度之间的单调关系,结果表明,加入物理信息神经网络后模型预测能力得到明显提升.

针对电厂工业控制对冷却塔水温预测精度和模型可解释性的高要求,特别是在夏季高温和冬季低温条件下,水温预测精度需达到95%以上,且绝对误差控制在1°C以内,以确保冷却塔的高效运行和机组安全性.本文提出的基于PINN-CEEMDAN-GA-BiLSTM的混合模型,在大温度序列预测中,利用了CEEMDAN模型在时频特征提取方面的优势,并结合遗传算法对参数的优化调整,结合物理信息神经网络、双向长短期记忆神经网络和深度学习技术,提高水温预测准确性和物理可解释性.在本文的预测过程中,针对数据量过大,直接对其进行预测可能会面临计算复杂度、模型训练困难等问题.因此,首先采用经验模态分解方法对数据进行分解,将原始数据分解成多个固有模态函数,从而降低数据的复杂性.其次,通过遗传算法优化模型参数,进一步提高预测模型的准确性和泛化能力.最后,通过物理信息神经网络下的BiLSTM网络,结合时间序列数据的长期依赖性和物理方程的约束,实现了对复杂数据的高效预测.综上所述,本文设计了一种混合预测网络,旨在准确预测电厂冷却塔水温的同时增强模型的可解释性.

1 理论基础

1.1 物理信息神经网络和BiLSTM

物理信息神经网络(physical information neural network, PINN)^[17]是一种结合了神经网络和物理方程的方法,用于解决物理问题和模拟物理系统. PINN的目标是通过学习数据和物理信息来预测物理系统的行为和属性.传统的数值模拟方法通常基于离散化的物理方程和数值求解技术.然而,对于复杂的物理系统和边界条件,这些方法可能面临计算复杂性和数值不稳定性的挑战. PINN通过将神经网络嵌入物理方程中,以端到端的方式学习物理系统的行为,可以在不需要显式离散化和网格的情况下进行模拟和预测.

在本文中,物理信息神经网络引入基本的物理原则,以确保网络的预测不仅符合历史数据的模式,而且符合电厂系统的物理规律.这种物理信息神经网络的构建理念,提供了对时间序列的深层次物理解,从而在非线性和非平稳数据预测方面,显著提高了模型的准确性和可靠性.具体来说,本文通过将傅里叶传热方程纳入损失函数中,模型不仅可以学习数据的模式,还能够遵循电厂系统的物理原理,从而提高模型的预测

准确性和可靠性.

双向长短期记忆网络(bidirectional long short-term memory, BiLSTM),通过结合一个正向的LSTM层和一个反向的LSTM层来提高温度预测的精度.这种结构允许模型同时考虑过去的温度数据和未来的温度数据,以做出更准确的预测.具体来说,正向LSTM层捕获并利用过去时间点的温度信息,辅助预测未来的温度;而反向LSTM层则从未来的时间点开始,逆向处理数据,以改进对过去温度的理解和适应.通过这种双向处理,BiLSTM可以全面捕捉时间序列数据中的时序依赖关系,从而提高预测性能. BiLSTM神经网络架构图如图1所示.

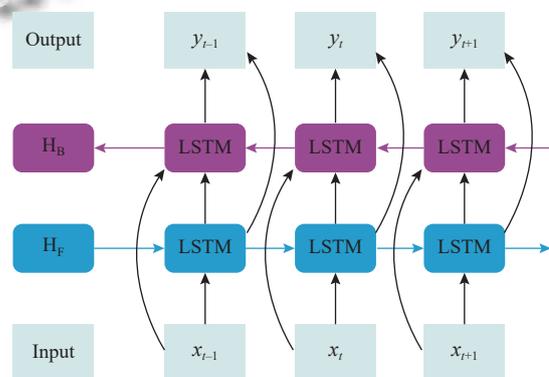


图1 BiLSTM框图

LSTM单元包括遗忘门、输入门、输出门和一个维持状态的单元.下面是一个标准的LSTM单元公式,这些相同的计算被应用于BiLSTM网络的前向和反向LSTM.对于时间步 t 的输入 x_t 和先前的隐藏状态 h_{t-1} ,还有先前的单元状态 c_{t-1} ,LSTM单元的公式如下:

遗忘门:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门:

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

单元状态更新:

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (4)$$

输出门:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

其中, σ 表示 Sigmoid 激活函数, \tanh 表示双曲正切激活函数, W 和 b 代表权重矩阵和偏置项, 各门的 f_i 、 i_i 和 o_i 分别代表遗忘门、输入门和输出门的激活值, \tilde{c}_i 代表候选单元状态, c_i 和 h_i 分别代表当前单元状态和隐藏状态, * 表示逐元素乘法. BiLSTM 网络通过结合前向和后向两个 LSTM 单元的隐藏状态来形成最终的输出 y_i .

在电厂应用背景下, BiLSTM 通过结合正向和反向的 LSTM 层, 能够更好地理解冷却系统中温度的变化规律. 这种双向结构使得模型能够综合考虑过去和未来的温度数据, 提高对未来温度趋势的预测准确性. 同时, BiLSTM 作为一种强大的深度学习模型, 通过与物理信息神经网络相结合, BiLSTM 可以更好地融合物理方程和时间序列数据, 提高对冷却系统温度变化的理解和预测能力.

1.2 完全集合经验模态自适应噪声分解

完全集合经验模态分解自适应噪声 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN) 技术是基于原始的经验模态分解 (EMD) 技术^[18], 这种基于 EMD 通过集成的方式加入了自适应噪声, 以克服 EMD 在实际应用中遇到的问题, 特别是模态混叠问题. 该方法不仅减少了所需的筛选迭代次数, 且最小化了计算成本, 从而比传统的 EEMD 方法更有效. 原始序列 $x(t)$ 的 CEEMDAN 分解具体步骤如下所示.

(1) 向温度时间序列 $x_i(t)$ 中添加一系列不同的白噪声序列, 生成新的噪声干扰信号.

$$x_i(t) = x(t) + w_i(t) \quad (7)$$

(2) 对每个添加了不同白噪声序列的信号 $x_i(t)$, 使用经验模态分解算法分解它们, 提取出一系列固有模态函数 $IMF_{ij}(t)$, 其中 i 表示不同的白噪声序列, j 表示对应的 IMF 序号.

(3) 对于每个 IMF 的序号 j , 将从所有加噪信号 $x_i(t)$ 分解得到的 $IMF_{ij}(t)$ 进行集成, 即对所有 i 求平均, 得到最终的 IMF 分量.

$$IMF_j(t) = \frac{1}{N} \sum_{i=1}^N IMF_{ij}(t) \quad (8)$$

其中, N 是加入的不同白噪声序列的总数.

(4) 从原始信号 $x(t)$ 中减去所有集成后的 IMF, 得到残差信号 $r(t)$.

$$r(t) = x(t) - \sum_j IMF_j(t) \quad (9)$$

(5) 重复上述过程, 直到残差信号 $r(t)$ 符合停止标准, 即它不能再被分解成更多的 IMF 信号或者达到了预先设定的 IMF 个数. 最终, 原始信号 $x(t)$ 被分解为一系列 IMF 信号.

$$x(t) = \sum_j IMF_j(t) + r(t) \quad (10)$$

在 PINN-CEEMDAN-GA-BiLSTM 模型中, 通过对温度时间序列进行分解, CEEMDAN 技术可以提取出不同的模态函数, 为模型提供更多关于温度变化规律的信息. 这种分解方法能够帮助模型更好地理解温度数据的特征和模式, 从而提高预测的准确性和可靠性. 对于电厂冷却塔温度数据, CEEMDAN 技术的引入有助于更好地处理温度时间序列数据, 提高温度预测的准确性. CEEMDAN 技术通过对温度数据进行分解和去噪处理, 能够有效地去除噪声干扰, 揭示出温度变化的真实模式, 为电厂冷却系统的温度预测提供更可靠的支持.

1.3 遗传算法

遗传算法是一种受自然遗传学启发的搜索优化算法, 其目标是在有限的迭代次数内找到问题的最优解. 遗传算法通过模拟生物进化的过程, 使用交叉、变异和选择等操作, 在超参数空间中搜索最佳解. 该算法使用适应度函数的概念和自然选择原则来确定实现优化的下一个样本点. 遗传算法的步骤如下.

(1) 初始化种群.

(2) 计算适应度. 适应度是衡量每个个体对问题解决程度的量化指标. 对于每个个体 i , 其适应度 $F(i)$ 可以根据问题特定的适应度函数计算得出:

$$F(i) = f(x_i) \quad (11)$$

其中, f 代表适应度函数, x_i 代表第 i 个个体的解.

(3) 选择. 根据个体适应度与总体适应度的比例来选取下一代. 个体 i 被选中的概率 $p(i)$ 为:

$$p(i) = \frac{F(i)}{\sum_{j=1}^N F(j)} \quad (12)$$

其中, N 是种群的总个体数.

(4) 遗传操作. 对选择后的解执行遗传操作, 包括交叉和变异, 生成下一代种群. 其中交叉操作和变异操

作分别如下。

交叉操作: 在简单的一点交叉中, 假设父代个体 A 和 B , 交叉点为 c , 则新生成的后代可以表示为:

$$Child_1 = [A[1 : c], B[(c + 1) : end]] \quad (13)$$

$$Child_2 = [B[1 : c], A[(c + 1) : end]] \quad (14)$$

变异操作: 假设每个基因位在变异时的变化概率为 p_m , 对于某个个体的基因位 g_i , 变异操作可以描述为:

$$g'_i = \begin{cases} mutate(g_i), & \text{with probability } p_m \\ g_i, & \text{otherwise} \end{cases} \quad (15)$$

其中, $mutate(g_i)$ 代表对基因位 g_i 进行改变的操作, g'_i 为变异后的基因位。

(5) 替换. 用新一代种群替换掉原始种群。

(6) 检查终止条件. 如果达到最大迭代数, 则算法停止, 输出当前最优解; 否则, 回到步骤 (2), 继续迭代. GA-BiLSTM 对应的逻辑框图如图 2 所示。

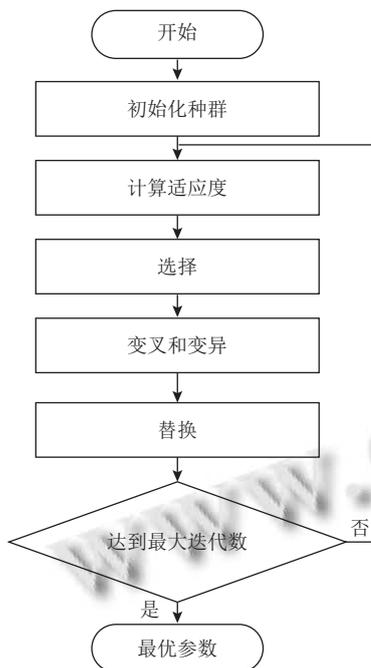


图 2 遗传算法流程图

2 基于 PINN-CEEMDAN-GA-BiLSTM 的水温预测方法

2.1 评价指标

为了全面评估引入物理信息神经网络后的预测模型性能, 采用了决定系数 (R^2)、均方根误差 ($RMSE$)、

平均绝对误差 (MAE) 和平均绝对百分比误差 ($MAPE$), 其对应公式如下。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (19)$$

其中, y_i 是第 i 个观测值, \hat{y}_i 是第 i 个预测值, \bar{y} 是观测值的平均值, n 是观测值的数量. 当决定系数 R^2 接近 1 时, 则表示模型预测与实际温度之间的吻合度高, 从而反映出模型具有较高的精度. 为负数则意味着模型预测与实际温度之间几乎没有相关性, 模型表现不佳. 至于均方根误差和平均绝对误差, 它们的值越接近 0, 就越能说明模型在预测温度方面的误差较小, 预测结果较为精确. 平均绝对百分比误差越小则代表模型能够完美预测温度。

2.2 CEEMDAN 分解

本文选取国能平罗电厂每日机组循环水温作为数据来源, 时间跨度为 2021 年 2 月 8 日-2022 年 3 月 31 日, 每隔 30 min 采样一次, 共 20 000 个时间点. 在数据划分上, 将训练集与测试集的比例定为 9:1, 其原始数据如图 3 所示。

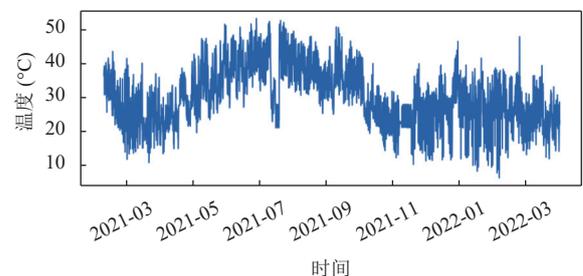


图 3 原始数据图

通过观察原始数据图, 可以看出原始温度数据呈现出非线性并具有一定的不稳定性. 直接对原始数据进行预测存在难以捕捉数据的复杂模式和变化趋势的问题, 因为原始数据可能包含多个频率和振荡模式, 以

及不同尺度上的波动. 这种复杂性和不稳定性使得直接预测原始数据变得困难, 容易导致模型性能不佳和预测结果不准确. 因此, 使用 CEEMDAN 方法对原始数据进行分解能够有效地将数据分解成多个固有模

式函数, 使得数据的结构更清晰, 有助于提取数据中的隐藏模式和趋势, 从而提高预测的准确性和可靠性. CEEMDAN 方法分解结果如图 4 所示, 共生成 13 个 IMF 分量.

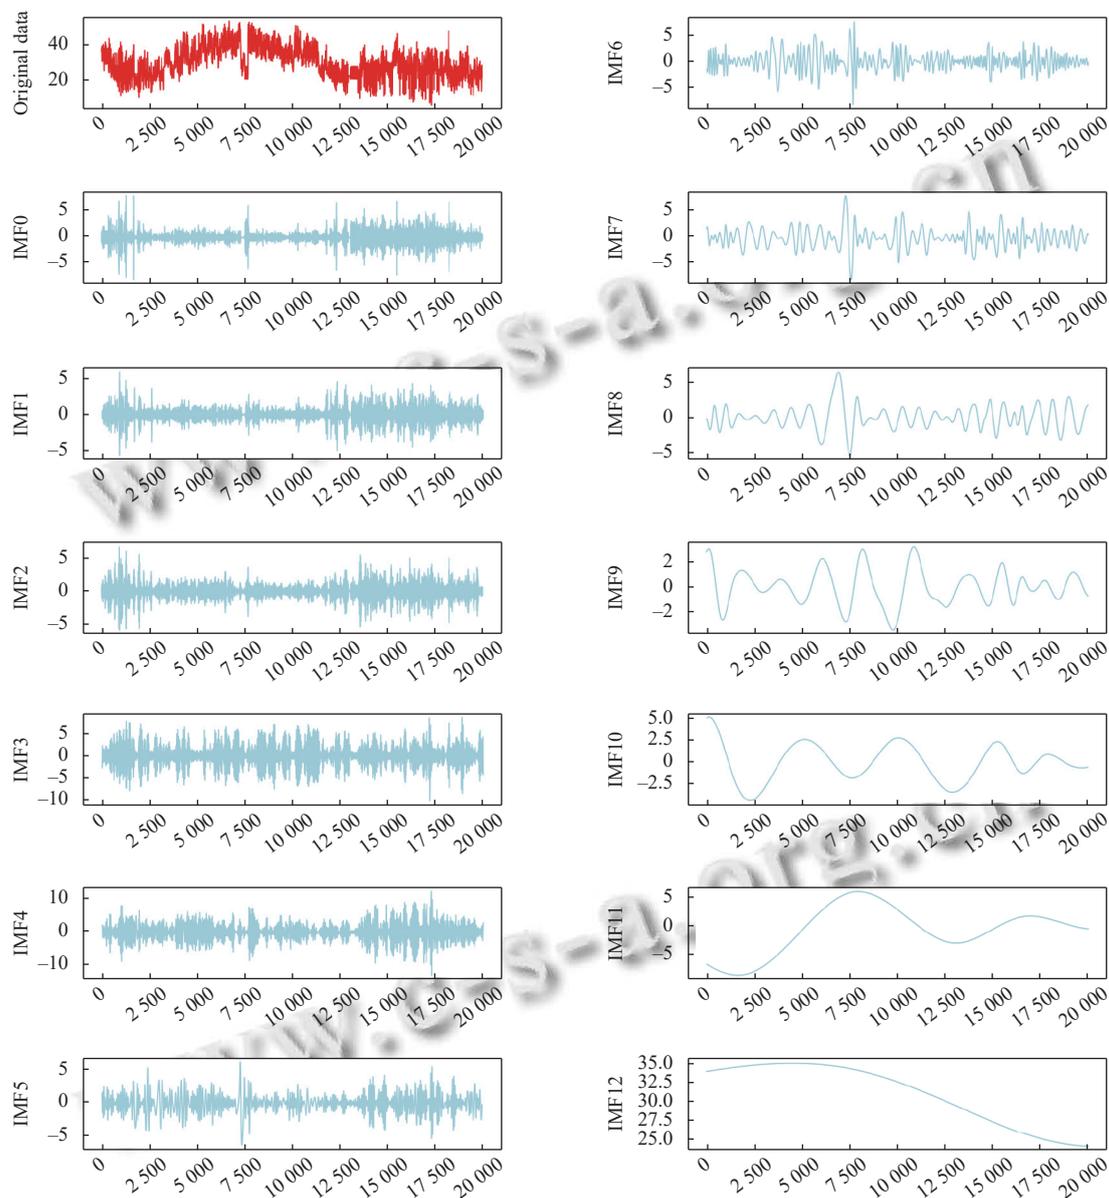


图 4 CEEMDAN 分解图

独立的对每个 IMF 分量进行预测会存在以下问题. 首先, 独立预测会忽略各 IMF 之间的相互作用和依赖关系. 其次, 鉴于一些 IMF 分量可能仅包含噪声或较为次要的信息, 而其他分量则承载着关键的信号特征, 此种预测方式可能会对不够关键的分量过度关注, 从而忽略了对核心特征的精准预测. 最后, 独立预测每个

IMF 分量的做法不仅会提高预测流程的复杂性, 还会导致计算成本上升, 对于 13 个 IMF 分量的单独预测可能会造成资源与时间上的不必要浪费.

因此, 样本熵作为一种衡量时间序列数据复杂度和不规则性的有效统计量, 它能够帮助分析数据的随机性与确定性. 通过结合具有相似样本熵的 IMF 分量

进行预测,不仅可以提高预测精度,同时也降低了计算负担.利用样本熵作为衡量时间序列数据复杂度和不规则性的统计量,评估各个IMF分量之间的相似性.IMF分量的样本熵值越接近,表示它们在时间序列上的随机性和确定性程度越相似.对所得13个IMF分量进行样本熵计算结果如图5所示,其中IMF14后面的点为残差信号的样本熵.其中参数 m 是样本熵算法中的一个关键参数,用于定义模板的长度.模板是样本序列中的连续子序列,用于比较样本序列中不同部分之间的相似性.较大的 m 值会导致更长的模板,随着 m 值的增加,算法对于相似性的要求也会增加.通常情况下,常用的 m 值为1或2.参数 r 是样本熵算法中的另一个重要参数,用于定义两个模板之间的相似性阈值. r 表示两个模板值之间的最大差值,即在计算样本熵时,如果两个模板之间的差值小于 r ,则认为它们是相似的.

根据计算结果,将IMF0和IMF1进行集成处理,

同理,IMF2和IMF3合并为CO-IMF1;IMF4、IMF5和IMF6合并为CO-IMF2;IMF7、IMF8和IMF9合并为CO-IMF3;IMF10、IMF11和IMF12合并为CO-IMF4.集成后的CO-IMF以及各CO-IMF预测结果如图6所示.

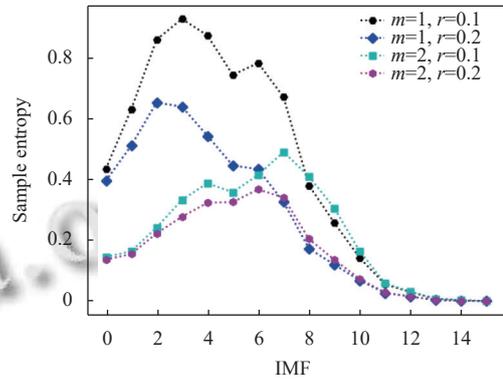


图5 样本熵计算结果图

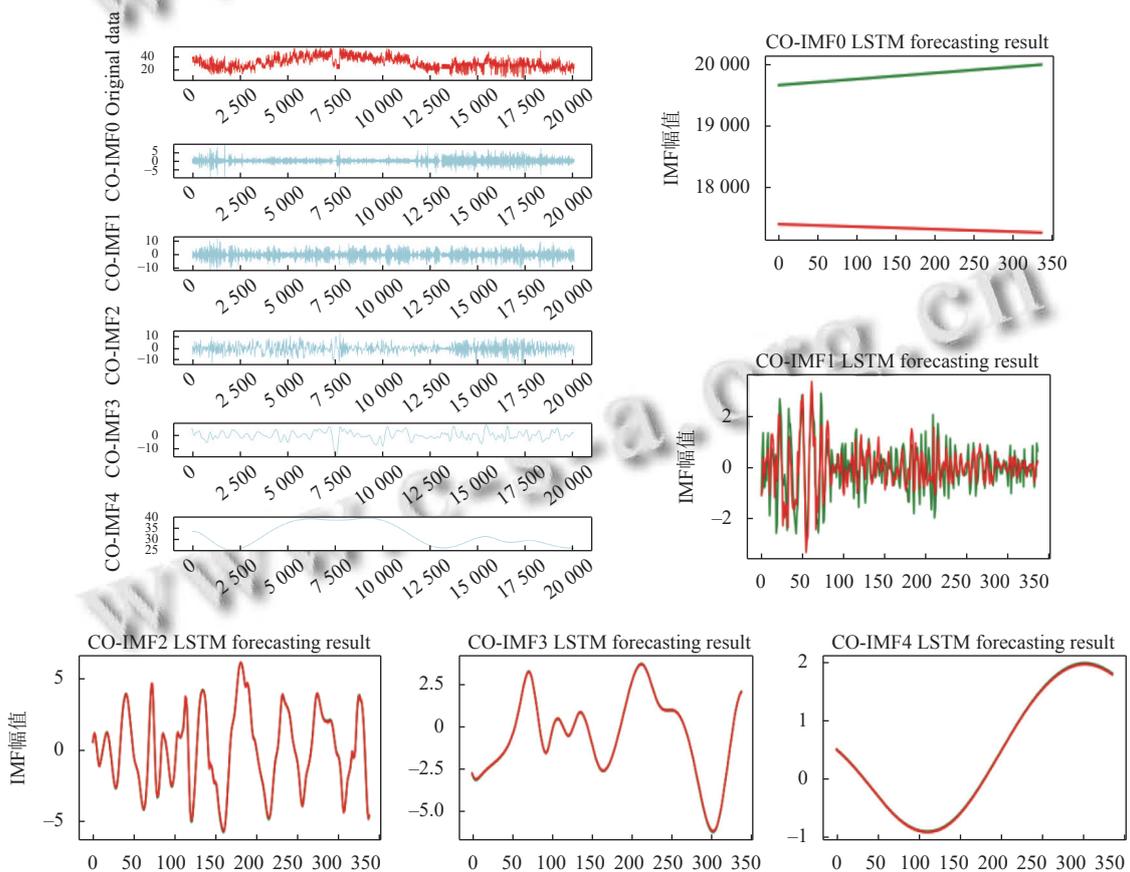


图6 集成IMF和各CO-IMF预测图

2.3 遗传算法优化的BiLSTM

由于BiLSTM网络的预测精度对模型参数设定的

要求,因此使用遗传算法对BiLSTM模型参数进行寻优处理.本文通过GA遗传算法得到最优参数.在遗传

算法中设置初始种群大小为 50, 并进行总共 10 轮的迭代过程. 在本文中, 设定隐藏单元数量 CELL 时, 考虑了 32、64、128 这 3 种可能选项. 对于 batch_size, 尝试了 32、64 两种设定, 而在设置 epochs 时, 模拟了 1000、1500、2000、2500 这 4 种可能的取值. 为了避免模型过拟合的情况, 还设定了 dropout 参数, 并尝试了 0.1、0.2、0.3、0.4 这 4 种不同的值, 以及自适应学习率和提前停止的耐心值分别为 100、200. 在整个优化过程中, 使用 Adam 优化器. 经过 10 轮迭代后, 确定了最优的超参数组合, 分别为: 单元数量 64, batch_size 为 64, epochs 为 2000, 两个 dropout 参数分别为 0.2, 自适应学习率和提前停止的耐心值为 100. 最终 GA-BiLSTM 模型参数优化选择结果如表 1 所示.

表 1 超参数取值结果

参数	可选值	最优值
CELL	32, 64, 128	64
batch_size	32, 64	64
epochs	1000, 1500, 2000, 2500	2000
dropout	0.1, 0.2, 0.3, 0.4	0.2
提前停止耐心值	100, 200	100

遗传算法通过模拟生物进化中的自然选择和遗传机制, 在超参数优化过程中实现了全局最优解的搜索. 其得到最优参数的主要步骤如下.

(1) 首先, 将待优化的超参数 (如隐藏单元数、批量大小等) 编码为染色体形式的参数组合, 构建包含 50 组随机参数配置的初始种群.

(2) 每个个体代表一组特定的 BiLSTM 模型参数设置, 通过适应度函数评估其性能优劣.

(3) 在迭代过程中, 算法优先选择适应度排名前 20% 的优异个体作为亲本, 采用单点交叉法对选定个体的参数编码进行重组, 例如将两个亲本的隐藏单元数和批量大小参数进行交换, 同时以 5% 的概率对个别参数实施变异操作 (如将 dropout 值从 0.2 突变为 0.3).

(4) 经过 10 代进化后, 种群逐步收敛至最优参数区域, 最终筛选出验证集损失最小的参数组合.

这种进化策略有效克服了传统网格搜索的计算效率瓶颈, 通过定向保留优质基因、动态探索参数空间, 在有限迭代次数内实现了复杂高维参数空间的智能寻优, 通过遗传算法优化得到的最佳参数组合将极大地提升 BiLSTM 模型在水温预测中的性能表现, 并为模型的可解释性提供更多支持. 这一优化方法在提高预

测精度的同时, 也为深度学习模型参数优化提供了一种有效的手段.

从表 2 中可以看出, 采用所得超参数在预测天数为 7 天时, 评价指标 MAPE 明显优于其他天数, 模型 R^2 、RMSE、MAE 也在 7 天时比其他天数更低, 超过 7 天时, 模型的预测能力逐渐下降, 出现过拟合现象, 表明该模型在预测 7 天温度时, 预测效果达到最佳, 因此本研究使用 PINN-CEEMDAN-GA-BiLSTM 预测一周的温度变换.

表 2 模型性能对比不同时长评价指标

天数	R^2	RMSE	MAE	MAPE
5	0.9965	0.2259	0.1814	0.8024
6	0.9968	0.2103	0.1737	0.7711
7	0.9984	0.1411	0.1070	0.4808
8	0.9980	0.1619	0.1184	0.5129
9	0.9964	0.1486	0.1169	0.5341

2.4 物理信息神经网络下的 BiLSTM

在 PINN-BiLSTM 模型中, 针对通过 CEEMDAN 分解后的数据, 采用物理信息神经网络的双向长短期记忆神经网络进行训练, 以精确捕捉温度时间序列的动态变化并进行有效的预测. BiLSTM 的双向结构允许网络同步处理过去和未来的信息, 这对于理解温度序列的复杂模式尤其有效. 由于温度序列可能受到多种物理因素的影响, 这种包含时间前后文的学习方式, 增强了模型对温度波动的预测能力. 在本文中, 应用 PINN 进行温度预测, 其中损失函数设计为两个互补部分的组合: 数据驱动损失和物理驱动损失. 数据驱动损失主要由均方误差构成. 均方误差是评价神经网络预测温度与实际观察温度间差异的指标. 其表示为:

$$L_d = \frac{1}{N} \sum_{i=1}^N (T_p(t_i, x_i) - T_{\text{obs}}(t_i, x_i))^2 \quad (20)$$

其中, L_d 表示数据驱动损失. N 是数据点的总数量. $T_p(t_i, x_i)$ 是神经网络在时间 t_i 和空间位置 x_i 预测的温度值.

物理驱动损失部分引入了傅里叶热传导方程, 捕捉温度如何依据物理定律随时间和空间分布演化的复杂规律, 以确保预测不仅基于数据也基于物理理解. 具体而言, 傅里叶热传导方程阐释了温度随时间 t 以及空间位置 x 的分布演变. 在此框架中, 温度 T 是唯一的输入变量, 并且热扩散率 α 被视为已知常数. 通过将传热

方程构建到神经网络的损失函数中, 定义出物理驱动损失项, 该损失项通过量化网络预测与物理定律预期期间的偏差来指导训练过程. 傅里叶传热方程描述了温度随时间和空间变化的物理规律, 它的一维稳态形式是:

$$\frac{\partial T}{\partial t} = \alpha \frac{\partial^2 y}{\partial x^2} \quad (21)$$

通过将该方程整合到 PINN 的损失函数中, 可以构造一个物理驱动损失项, 该损失项能够衡量神经网络预测的温度变化与傅里叶定律预测之间的差异. 物理驱动损失 L_p 通过数值微分来获得, 计算方法如下:

$$L_p = \frac{1}{M} \sum_{j=1}^M \left(\frac{\partial T_p}{\partial t}(t_j, x_j) - \alpha \frac{\partial^2 T_p}{\partial x_j^2} \right)^2 \quad (22)$$

其中, T_p 是 PINN 预测的温度值, M 是用于计算物理损失项的样本点数.

总损失函数 L_t 将物理驱动损失和数据驱动损失结合起来, 以确保模型的预测不仅与实际观测数据吻合, 还遵守了热传递的物理定律. 总损失函数形式为:

$$L_t = L_d + \lambda L_p \quad (23)$$

其中, L_d 是基于数据的均方误差损失, 用于衡量模型预测温度与实际观测温度之间的差异. λ 是一个超参数, 用于平衡数据驱动损失和物理驱动损失的相对重要性. 通过调整 λ , 可以在模型的准确性与物理合理性之间做

出权衡. 神经网络的训练过程包括对损失函数的最小化, 使得模型在符合傅里叶定律的同时, 也尽量贴近观测数据.

2.5 PINN-CEEMDAN-GA-BiLSTM 模型

本文设计的 PINN-CEEMDAN-GA-BiLSTM 温度序列预测模型架构主要包括: CEEMDAN 模块, 负责对序列数据进行预处理; 遗传算法模块, 用于优化模型参数以提高预测的准确性; 最后为 PINN 和 BiLSTM 模块联合构建的预测器, 利用物理信息神经网络与双向长短时记忆网络的综合优势, 来执行最终的序列预测. 模型构架首先采用 CEEMDAN 模块负责对原始序列数据进行预处理, 将其分解为 13 个具有不同频率特征的本征模态函数 (IMF). 这种分解有助于更好地捕获数据中的时频特征, 为后续预测提供了更丰富的信息. 接下来, 遗传算法模块发挥着优化模型参数的作用, 通过对 BiLSTM 模型的隐藏单元数量、batch size、epochs、dropout 参数等超参数进行调整, 提高了预测模型的准确性和泛化能力. 最后, 使用 PINN 和 BiLSTM 模块的联合构建预测器, 利用了物理信息神经网络和双向长短时记忆网络的综合优势. 通过将 PINN 引入预测过程中, 通过在损失函数中对模型进行约束, 模型可以受益于物理约束条件的加强, 从而提高了模型的可解释性和泛化能力. BiLSTM 网络结合遗传算法得到的最优超参数进行序列预测, 进一步提高了预测的准确性和稳定性. 其整体框架图如图 7 所示.

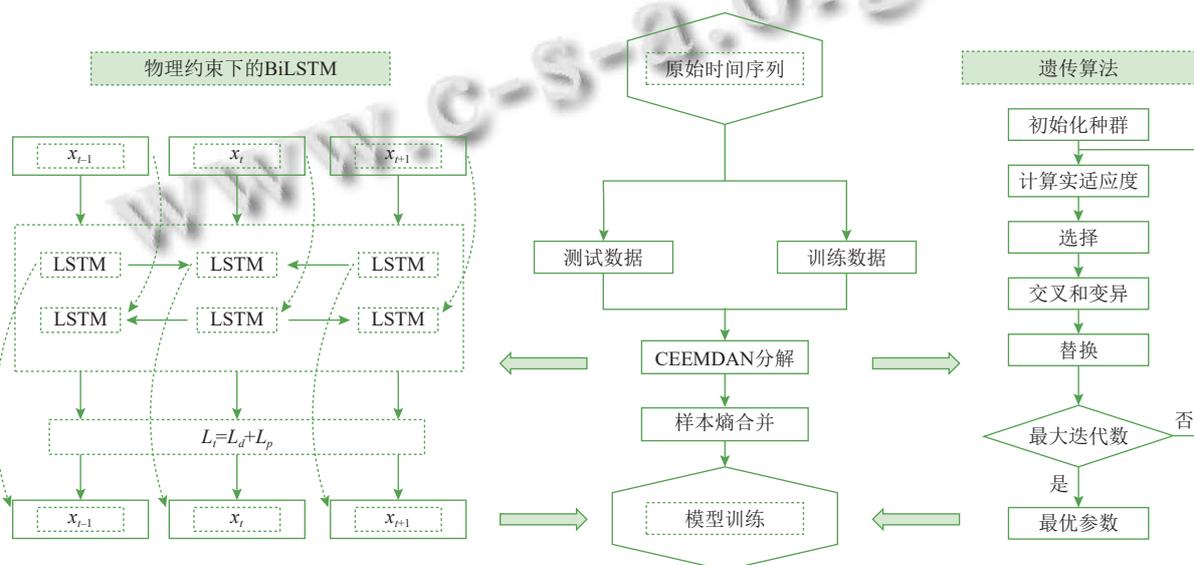


图 7 模型整体框架图

3 实验分析

3.1 预测结果分析

PINN-CEEMDAN-GA-BiLSTM 模型温度预测结果如图 8 所示。由图 8 可以看出,模型预测得到的数据与实际观测值的吻合度极高,几乎完美预测了真实数据的变化趋势,表明该模型在温度预测任务上取得良好表现。结合后文,本文所提出预测模型的评价指标 R^2 为 0.9984,非常接近 1,表示该模型获得的预测温度与实际温度高度吻合,证明该模型具有较高的精度, $RMSE$ 和 MAE 仅为 0.1411 和 0.1070,模型最大误差仅为 0.4808,误差在 5% 以内,该结果表明该模型在温度预测方面具有较高的性能。

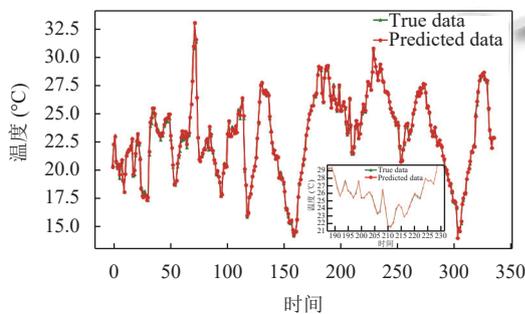


图 8 PINN-CEEMDAN-GA-BiLSTM 预测结果图

3.2 对比实验

为了进一步验证 PINN-CEEMDAN-GA-BiLSTM 预测模型的有效性,本文将该模型与其他模型进行对比分析。涉及的预测模型包括 GRU^[19]、DNN^[20],以及混合模型 CEEMDAN-BPNN^[21]和 CEEMDAN-LSTM。其中 GRU 是一种循环神经网络的变体,专门设计用于处理序列数据,GRU 主要通过更新门和重置门来控制信息的更新和忘记,从而有效地捕捉序列中的关键信息。DNN 是一种深度神经网络模型,由多个隐藏层组成,DNN 的每个隐藏层都由多个神经元组成,每个神经元都通过非线性激活函数将输入转换为输出。通过多个隐藏层的组合,DNN 可以学习到更高层次的抽象特征,提高预测的准确性。CEEMDAN-BPNN 混合模型通过反向传播算法训练网络以适应输入和输出之间的关系。为保证实验的一致性,在所有的对比实验中,均采用遗传算法得到的超参数。

其各个模型的评价指标结果如表 3 所示。从表中可以看出,PINN-CEEMDAN-GA-BiLSTM 模型在各项评价指标上表现优异其各项评价指标均比其他模型优

秀。分别来看,与单一模型的 GRU 和 DNN 相比,所提出的混合模型明显优于 GRU 和 DNN 模型,该模型对于复杂数据的处理能力和预测准确性有显著提升。CEEMDAN-BPNN 模型预测精度相对较差,其原因主要在于,尽管 CEEMDAN 方法有效地将时间序列数据分解为多个本征模态函数,并有助于提取数据中的时频特征,但 BPNN 作为传统的前馈神经网络,相较于更为先进的 LSTM 或 BiLSTM 模型,在处理长时序数据和复杂模式时存在一定的局限性。BPNN 的结构简单,缺乏记忆和时序信息的处理能力,因此在面对复杂的动态变化时,无法像 BiLSTM 那样保持长期依赖关系,导致其预测精度较低。

表 3 对比实验评价指标

Model	R^2	$RMSE$	MAE	$MAPE$
GRU	0.9228	1.0077	0.7211	3.2629
DNN	0.9033	1.1279	0.8145	3.6999
CEEMDAN-BPNN	0.8341	0.1430	0.1244	0.4739
CEEMDAN-LSTM	0.9973	0.1883	0.1393	0.6274
PINN-CEEMDAN-GA-BiLSTM	0.9987	0.1295	0.1001	0.4541

对于混合模型,可以观察到,加入物理信息神经网络后的模型表现更加良好,这表明加入物理信息神经网络的有效性。PINN-CEEMDAN-GA-BiLSTM 模型与 CEEMDAN-LSTM 模型相比,虽然 R^2 仅上涨了 0.001,但在 $RMSE$ 、 MAE 、 $MAPE$ 这 3 个评价指标中,分别下降 0.0116、0.0069 和 0.0267,PINN-CEEMDAN-GA-BiLSTM 表现得更为良好,其所呈现出的性能差异,主要来源于 BiLSTM 组件对时间序列依赖性和长期记忆能力的高效捕捉,这使得模型在处理和预测具有时间动态性质数据时,具备更加强大的能力。

各个模型预测结果如图 9 所示。通过上述多种模型的对比图,以及评价指标对比图(图 10),表明 PINN-CEEMDAN-GA-BiLSTM 在温度预测方面具有良好的性能。可以看出,本文所提出的混合预测模型 PINN-CEEMDAN-GA-BiLSTM 与其他预测模型相比预测性能更精确。相较于单一模型没有足够的复杂性来捕捉温度数据中的复杂模式和非线性关系,CEEMDAN 改进后的信号处理方法能够自适应地分解信号,并对各残差分量进行噪声自适应处理,BiLSTM 网络在加入 CEEMDAN 模块对数据进行处理后, R^2 提升 0.0723,并且 $RMSE$ 、 MAE 和 $MAPE$ 分别下降 0.8111、0.5748 和 2.6131,模型的预测性能得到明显提升。相比于单向 LSTM 网络模型,双向 LSTM 网络模型在处理时序数

据时能够更全面地捕捉上下文信息和时序关系,提供更丰富的表示能力,并且在训练过程中具有更好的梯度传播性质.与单向 LSTM 模型相比,使用双向 LSTM 模型后, R^2 虽然变化不大,仅提升 0.001,但 $RMSE$ 、 MAE 和 $MAPE$ 这 3 项指标分别下降 0.0406、0.0281 和 0.1278,表明使双向 LSTM 模型在预测方面的有效性. PINN 提供了一种将物理定律和先验知识以约束形式融入神经网络训练过程的方法,能够指导网络学习过程,提高模型的泛化能力和物理可解释性,通过表 4 可以明显看出,加入 PINN 模块后,模型的 $RMSE$ 、 MAE 和 $MAPE$ 都有所下降,分别下降 0.0182、0.0111 和 0.0455,其中 $MAPE$ 指标下降明显,表明该 PINN 模块在水温预测方面的有效性.

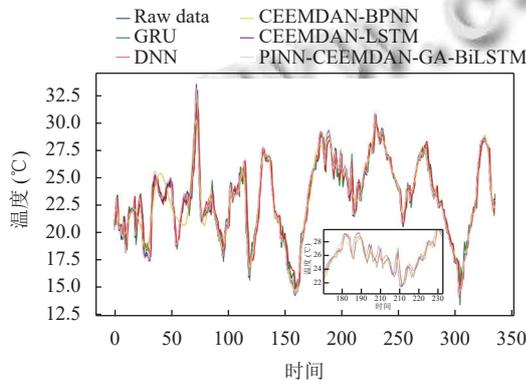


图 9 各模型预测结果对比图

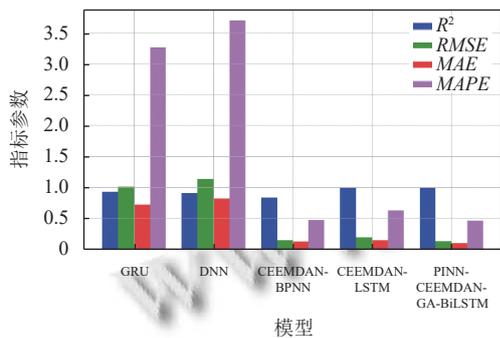


图 10 评价指标对比图

表 4 消融实验评价指标

Model	R^2	$RMSE$	MAE	$MAPE$
BiLSTM	0.9241	0.9994	0.7141	3.2405
CEEMDAN-BiLSTM	0.9983	0.1477	0.1112	0.4996
PINN-CEEMDAN-GA-BiLSTM	0.9987	0.1295	0.1001	0.4541

3.3 消融实验分析

在对该混合模型进行消融实验时,为确保实验结果的有效性,各模块均采用经过遗传算法优化得出的

超参数进行实验.采用 BiLSTM 作为基础模型, BiLSTM 作为一种强大的循环神经网络结构,能够有效地捕捉时间序列数据中的长期依赖关系,具有良好的记忆性和顺序性.消融实验评价指标如表 4 所示.在 CEEMDAN-BiLSTM 消融实验中去除物理约束条件的情况下,通过完全集成经验模态分解自适应噪声分解的预测准确度明显提升,各项评价指标均有显著提高, R^2 从 0.9241 提升至 0.9983, $RMSE$ 从 0.9994 降低至 0.1477, MAE 从 0.7141 下降至 0.1112, $MAPE$ 从 3.2405 减少至 0.4996.进一步观察加入物理约束条件后的混合模型,尽管在 R^2 评价指标上提升略微,但在 $RMSE$ 、 MAE 和 $MAPE$ 评价指标中均有所下降,显示出约束条件对网络模型的优化效果.具体而言,加入物理约束条件后,模型在 $RMSE$ 、 MAE 和 $MAPE$ 方面的表现有所改善,分别降至 0.1295、0.1001 和 0.4541,进一步提高了模型的预测准确性,验证该物理约束条件的有效性.

相较于传统的 BiLSTM 模型, CEEMDAN-BiLSTM 模型通过对复杂数据进行数据分解展现出更好的预测效果.而 PINN-CEEMDAN-GA-BiLSTM 模型引入物理约束条件后,在预测准确度上得到进一步提升,特别在降低 $RMSE$ 、 MAE 和 $MAPE$ 指标方面取得显著成效.这表明,结合物理约束条件和数据分解技术可以有效地提高混合模型的预测性能,为复杂数据的预测和分析提供更为准确的结果.

4 结论

本文针对大型火力发电厂冷却塔出水口的实时水温预测,存在数据量过多以及多因素扰动影响的问题,设计了 PINN-CEEMDAN-GA-BiLSTM 分解组合模型,使用完全集成经验模态分解自适应噪声对原始数据进行分解,通过遗传算法对参数进行优化,得到最优参数,并将分解后的数据在物理信息神经网络下使用双向长短期记忆神经网络进行温度预测.实验结果表明,该模型可有效处理复杂大数据,实验评价指标 R^2 、 $RMSE$ 、 MAE 和 $MAPE$ 分别为 0.9987、0.1295、0.1001 和 0.4541,预测结果可精准表达冷却塔水温未来变化趋势,预测未来一周时间内温度变化,为企业动态优化冷却塔功效的决策提供依据.其中, CEEMDAN 负责对复杂温度数据进行分解,提取关键时频特征,减少数据噪声;遗传算法用于优化模型参数,提高预测精度; PINN 结合物理约束增强模型的可解释性,确保预测结果符合热

力学规律; BiLSTM 充分利用时间序列数据的长期依赖性, 实现高效精准的温度预测. 通过准确预测冷却塔水温, 电厂运营人员可以提前做出关键决策, 确保电厂运行的高效性和可靠性. 这种混合模型预测方法为实时水温预测问题提供了一种有效且可靠的解决方案, 对于电厂的决策制定和运营管理具有重要意义.

参考文献

- 1 国家市场监督管理总局, 中国国家标准化管理委员会. GB/T 32127-2024 电力需求响应监测与评价导则. 北京: 中国标准出版社, 2024.
- 2 国家电网发布碳达峰碳中和行动方案. 中国经济时报, 2021-03-24(04). [doi: 10.28427/n.cnki.njjsb.2021.00055]
- 3 Ahmadi-Nedushan B, St-hilaire A, Ouarda TBMJ, *et al.* Predicting river water temperatures using stochastic models: Case study of the Moisie River (Québec, Canada). *Hydrological Processes*, 2007, 21(1): 21–34. [doi: 10.1002/hyp.6353]
- 4 Di Nunno F, Zhu SL, Ptak M, *et al.* A stacked machine learning model for multi-step ahead prediction of lake surface water temperature. *Science of the Total Environment*, 2023, 890: 164323. [doi: 10.1016/j.scitotenv.2023.164323]
- 5 陈英义, 程倩倩, 成艳君, 等. 基于 GA-BP 神经网络的池塘养殖水温短期预测系统. *农业机械学报*, 2017, 48(8): 172–178. [doi: 10.6041/j.issn.1000-1298.2017.08.019]
- 6 杨豪, 章立新, 尹证, 等. 冷却塔出塔水温预测方法的对比分析及应用. *暖通空调*, 2021, 51(4): 112–117.
- 7 Yu ZY, Yang K, Luo Y, *et al.* Lake surface water temperature prediction and changing characteristics analysis-A case study of 11 natural lakes in Yunnan-Guizhou Plateau. *Journal of Cleaner Production*, 2020, 276: 122689.
- 8 Zhang WY, Zhou HY, Bao XH, *et al.* Outlet water temperature prediction of energy pile based on spatial-temporal feature extraction through CNN-LSTM hybrid model. *Energy*, 2023, 264: 126190. [doi: 10.1016/j.energy.2022.126190]
- 9 张锦荣, 王康谊. 基于 EMD-LSTM 的水产养殖水温预测模型. *计算机与数字工程*, 2023, 51(9): 2189–2194. [doi: 10.3969/j.issn.1672-9722.2023.09.045]
- 10 李祥铜, 曹亮, 李湘丽, 等. 基于 WTD-LSTM 的对虾养殖水温组合预测模型. *广东农业科学*, 2021, 48(2): 153–160. [doi: 10.16768/j.issn.1004-874X.2021.02.020]
- 11 Stajkowski S, Kumar D, Samui P, *et al.* Genetic-algorithm-optimized sequential model for water temperature prediction. *Sustainability*, 2020, 12(13): 5374. [doi: 10.3390/su12135374]
- 12 余维, 李阳, 钟李红, 等. 基于改进实数编码遗传算法的神经网络超参数优化. *计算机应用*, 2024, 44(3): 671–676.
- 13 Ikram RMA, Mostafa RR, Chen ZH, *et al.* Water temperature prediction using improved deep learning methods through reptile search algorithm and weighted mean of vectors optimizer. *Journal of Marine Science and Engineering*, 2023, 11(2): 259. [doi: 10.3390/jmse11020259]
- 14 Zanetta F, Nerini D, Beucler T, *et al.* Physics-constrained deep learning postprocessing of temperature and humidity. *Artificial Intelligence for the Earth Systems*, 2023, 2(4): e220089.
- 15 Yuan TK, Zhu JX, Wang WX, *et al.* A space-time partial differential equation based physics-guided neural network for sea surface temperature prediction. *Remote Sensing* 2023, 15(14): 3498.
- 16 任少君, 朱保宇, 翁琪航, 等. 基于物理信息神经网络的燃煤锅炉 NO_x 排放浓度预测方法. *中国电机工程学报*, 2024, 44(20): 8157–8165. [doi: 10.13334/j.0258-8013.pcsee.231661]
- 17 Nilpueng K, Kaseethong P, Mesgarpour M, *et al.* A novel temperature prediction method without using energy equation based on physics-informed neural network (PINN): A case study on plate-circular/square pin-fin heat sinks. *Engineering Analysis with Boundary Elements*, 2022, 145: 404–417.
- 18 Torres ME, Colominas MA, Schlotthauer G, *et al.* A complete ensemble empirical mode decomposition with adaptive noise. *Proceedings of the 2011 IEEE International Conference on Acoustics, Speech and Signal Processing*. Prague: IEEE, 2011. 4144–4147.
- 19 Mahjoub S, Chrifi-Alaoui L, Marhic B, *et al.* Predicting energy consumption using LSTM, multi-layer GRU and drop-GRU neural networks. *Sensors*, 2022, 22(11): 4062.
- 20 Mahmoud A, Mohammed A. A survey on deep learning for time-series forecasting. In: Hassanien AE, Darwish A, eds. *Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges*. Cham: Springer, 2021. 365–392.
- 21 张盼盼, 权磊, 李思李, 等. 基于 LSTM-BPNN 神经网络的沥青路面性能预测模型研究. *公路交通科技*, 2023, 40(S2): 54–60.

(校对责编: 张重毅)