

引用格式:徐楚琦,孙辰昊,詹明宇,等.基于IGWO-Seq2Seq的风电故障预测方法[J].电力科学与技术学报,2024,39(6):203-211.

Citation: XU Chuqi, SUN Chenhao, ZHAN Mingyu, et al. Wind power fault prediction method based on IGWO-Seq2Seq[J]. Journal of Electric Power Science and Technology, 2024, 39(6): 203-211.

基于 IGWO-Seq2Seq 的风电故障预测方法

徐楚琦¹, 孙辰昊², 詹明宇², 周刚韬², 李梓维²

(1. 天合石油集团股份有限公司, 黑龙江 牡丹江 157011; 2. 长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

摘要:风电机组在运行过程中面临各种故障风险,如何精准地诊断和预测故障,对于提升风电场的运行效率和保障系统安全具有重要意义。传统的故障诊断方法主要依赖于基于规则的模型或浅层机器学习算法,这些方法在处理复杂、非线性、时序性强的数据时常常表现出较低的精度和较差的泛化能力。为此,提出一种基于改进灰狼优化(improved grey wolf optimizer, IGWO)算法的编解码器(Seq2Seq)模型,用于风电机组故障诊断预测。模型通过注意力机制增强关键输入时刻的特征表达能力,并利用 IGWO 算法对超参数进行全局优化以提升模型的预测精度和泛化能力。与传统模型相比,该模型风电机组故障预测中具备高效性和可靠性,为风电场的智能化运行与维护提供技术支持。

关键词:风电故障预测;灰狼优化算法;编解码器;注意力机制;深度学习技术

DOI: 10.19781/j.issn.1673-9140.2024.06.021 中图分类号: TM614 文章编号: 1673-9140(2024)06-0203-09

Wind power fault prediction method based on IGWO-Seq2Seq

XU Chuqi¹, SUN Chenhao², ZHAN Mingyu², ZHOU Gangtao², LI Ziwei²

(1. Trisun Petroleum Group Co., Ltd., Mudanjiang 157011, China; 2. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: Wind turbines face various fault risks during operation, making precise fault diagnosis and prediction crucial for improving wind farm operation efficiency and ensuring system safety. Traditional fault diagnosis methods primarily rely on rule-based models or shallow machine learning algorithms, which often exhibit low accuracy and poor generalization ability when dealing with complex, nonlinear, and strongly time-dependent data. To address these challenges, this paper proposes an encoder-decoder (Seq2Seq) model based on an improved grey wolf optimizer (IGWO) for fault diagnosis and prediction of wind turbines. The model enhances the feature expression of key input moments through an attention mechanism and leverages IGWO to perform global optimization of hyperparameters, improving both prediction accuracy and generalization ability. Compared with traditional models, this approach demonstrates high efficiency and reliability in wind turbine fault prediction, providing technical support for the intelligent operation and maintenance of wind farms.

Key words: wind power fault prediction; grey wolf optimizer; encoder-decoder; attention mechanism; deep learning technology

“十四五”规划提出“双碳”目标以来,以风电为典型代表的新能源体系更加注重清洁低碳、安全高效的能源消纳和电力储备^[1-4]。风电机组作为风电场的核心设备,其稳定性和可靠性直接关系到整个

电网的安全运行。近年来,随着风电装机容量的持续增长,风电机组的故障问题逐渐成为制约其经济性和可靠性的关键因素。风电机组的故障不仅影响其发电效率,延长修复周期,还可能导致较高的

收稿日期: 2024-07-01; 修回日期: 2024-10-15

基金项目: 湖南省自然科学基金联合基金(2024JJ9175)

通信作者: 孙辰昊(1991—),男,博士,讲师,主要从事电力数据挖掘及应用、人工智能等方面的研究; E-mail: chenhaosun@csust.edu.cn

运维成本和不必要的停机时间^[5]。因此,如何对风电机组进行有效的故障诊断与预测,已成为风电行业亟待解决的重要问题。

风电机组作为复杂的能源转换设备,其可靠性和运行效率直接影响到风电场的经济性和发电效益^[6]。风电机组故障通常表现为机组停运、设备损坏以及发电效率下降等,及时有效的故障判断与预测对于减少风电机组的停运时间、降低运维成本、提高系统运行效率具有重要意义。风电故障判断与预测方法可以分为传统方法、基于模型的方法和基于数据驱动的方法三大类。

传统方法主要依赖经验公式和统计学分析,如通过时间域和频域分析识别设备异常特征^[7]。这类方法在早期应用广泛,然而,随着风电场规模的扩大和运行环境的复杂化,这些方法的局限性日益凸显。面对现代风电场多源、多维、动态的数据特点,传统方法在处理复杂非线性关系和多因素耦合特性时显得力不从心,难以有效捕捉系统运行中的细微变化,尤其在应对突发性故障和隐蔽性风险时,诊断能力明显不足。

基于模型的方法则主要依赖于物理模型,通过理论假设分析和机理建模描述故障特征^[8-9]。这些方法能够深入挖掘设备运行的内在机制,对故障诊断具有较强的物理解释性。然而,随着风电设备和系统结构的日益复杂,精确建模变得困难,模型的精度受到较大限制。此外,由于基于模型的方法通常假设运行条件的理想化,其对复杂工况的适应性较弱,限制了在实际场景中的广泛应用。

数据驱动的方法近年来得到广泛关注,通过深度学习、集成学习等技术,从海量数据中提取潜在影响特征,实现未来故障风险预测,无须依赖具体的物理模型。其中,文献[10]提出了一种基于关联分析的生成式对抗神经网络的风电机组故障判断方法。文献[11]针对极端天气导致风电机组频繁故障,提出了基于改进贝叶斯网络的风电机组故障判断与风险预测模型。文献[12]针对风电机组齿轮箱故障判断,采用数字信号处理与机器学习相结合的方法,实现了故障自动诊断。在进一步的研究中,数据驱动方法逐渐融入了更多先进技术,以增强其对复杂问题的处理能力。文献[13]基于数据驱动的风电机组桨变系统,证明了添加注意力机制对于神经网络带来的提升。文献[14]引入线性解码器结构构建Transformer模型,具备长期使用稳定性,可以消除误预测现象。文献[15]

构建具有记忆时序信息的循环神经网络的输入特征,设置故障预警阈值,实现对风电机组故障状态预警。然而,尽管数据驱动方法在风电故障判断中表现出强大的适应性和灵活性,但其发展仍面临一定挑战。受限于预测模型结构,当考虑现实场景下多维复杂、非线性时序特征时,计算复杂度会明显上升,难以直接提取。此外,模型性能对超参数(如神经元数量和学习率)的高度依赖^[16],参数选择的合理性直接影响模型的预测精度与收敛速度。复杂模型的超参数调优过程通常依赖经验,难以保证全局最优解的获得,影响了模型全局性能和泛化能力^[17]。

因此,本文搭建了编解码器(Seq2Seq)模型^[18],进行风电故障判断及预测。该模型以门控循环单元(gate recurrent unit, GRU)为基本预测单元,在保证信息提取能力的同时简化网络结构^[19]。2组GRU单元分别构成编解码器结构强化对历史序列联系的深入提取,解码过程中引入注意力机制^[20]进一步提升长时间多步预测的精度和鲁棒性,使得模型在捕捉复杂时序特征方面具有显著优势。此外,考虑到深度学习模型超参数难以确定,且受限于对超参数的高度依赖,仅依靠经验确定超参数易使模型陷入局部最优。因此,本文利用改进灰狼优化算法(improved grey wolf optimizer, IGWO)^[21]对Seq2Seq模型的超参数进行全局优化。通过优化选取编解码器模型神经元个数以及学习率,加强模型参数选取的自适应性,以提高搜索效率。

灰狼优化(grey wolf optimizer, GWO)算法在全局搜索能力方面具有良好的适应性,但在高维参数空间中易出现收敛速度减缓的现象。通过将IGWO算法与Seq2Seq模型相结合,充分发挥了IGWO算法在参数优化中的全局探索能力和Seq2Seq模型在复杂时序建模中的精细化能力,有效提高了模型的预测精度和泛化能力。

1 编解码器模型

编解码器模型的主体为由2组GRU单元所组成的编码器-解码器结构。其基本结构如图1所示。编码器GRU对输入的时间序列进行编码操作,提取深层依赖并将特征语义向量传递给解码GRU组,依次输出解码结果。每一时刻,解码单元根据3组输入信息进行解码计算:语义向量 c 、上一时刻解码GRU输出 y_{t-1} 、上一时刻解码GRU隐层

状态 h_{t-1} 。具体计算如下:

$$\begin{cases} c = d(Uh_t) \\ h_t = f(W[h_{t-1}, y_{t-1}, c] + b_1) \\ y_t = g(Vh_t + b_2) \end{cases} \quad (1)$$

式中, U 、 W 、 V 分别为权重矩阵; b_1 和 b_2 为偏置向量; d 、 f 、 g 为激活函数, 本文取 \tanh 为激活函数。特别地, 在解码开始时, 解码 GRU 接收 $\langle \text{start} \rangle$ 所示的输入编码作为开始标识符, 结束解码则输出 $\langle \text{stop} \rangle$ 所示的输出编码作为终止标识符。

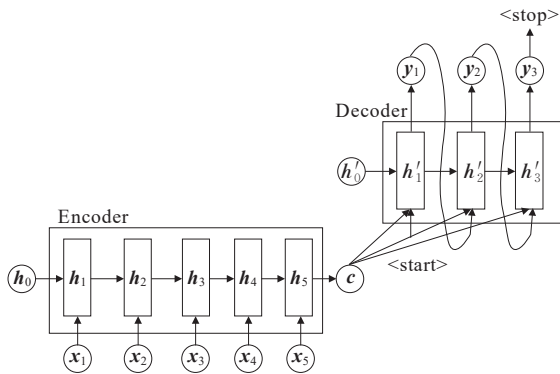


图 1 Seq2Seq 模型示意
Figure 1 Seq2Seq model

注意力机制源于对人类视觉的研究, 人脑在认知事物时会选择性地关注其主体特征, 集中精力于更有用的信息。注意力机制使得 Seq2Seq 模型更关注重要输入节点信息, 在预测时根据相关性大小分配不同权重, 用于当前时刻预测值的解码计算。

在解码第 i 时刻, 将上一时刻解码 GRU 最顶层隐层状态 S_{i-1} 与输入时序经编码器的编译结果 $\{h_j\}_{j=1}^{T_x}$ (T_x 为编码器时间步长) 按下式计算得到编码器第 j 时刻输出、在解码第 i 时刻的相关度:

$$e_{ij} = V_a^T \tanh(W_a S_{i-1} + U_a h_j) \quad (2)$$

式中, h_j 为编码器第 j 时刻的编译输出; V_a^T 、 W_a 、 U_a 均为全连接层权重矩阵。

以 softmax 函数对编码不同时刻所对应的的相关度进行归一化处理, 得到编码器各时刻对应于解码第 i 时刻输出预测的重要性权重^[22]为

$$a_{ij} = \exp(e_{ij}) / \sum_{k=1}^{T_x} \exp(e_{ik}) \quad (3)$$

综合所求得的注意力权重与编码器各时刻输入 $\{a_{ij}\}$ 进行加权求和, 即可得到在解码第 i 时刻所对应的特征语义向量为

$$c_i = \sum_{j=1}^{T_x} a_{ij} h_j \quad (4)$$

根据注意力机制求得的特征语义向量 c , 既包含全部编码器时序信息的输出状态, 又包含当前时刻解码器输出的特征注意力关联信息, 可以提取对当前时刻预测输出更为重要的输入时序信息并赋予更大权重, 从而提高编解码器模型长期预测的精度和稳定性。

2 改进灰狼优化算法

GWO 算法由 Mirjalili 团队于 2014 年提出, 是一种通过模拟灰狼群体追捕猎物, 迭代寻求最优解的智能优化算法^[23]。GWO 算法可以同时兼顾局部寻优和全局最优搜索, 收敛性能强, 收敛因子和信息反馈机制可以自适应调整。IGWO 算法调整了收敛因子以及灰狼最终位置更新公式, 进一步提高了灰狼算法全局搜索的稳定性和寻优性能, 收敛速度更快。

狼群内部有严格的等级制度^[24], 小部分头狼带领着狼群 β 搜捕猎物, 头狼等级由上而下可分为 α 、 β 、 δ 3 级, 剩下的灰狼记为 ω 狼。每次位置更新后根据距离猎物适应度高低筛选出 3 个级别的头狼, 即 α 狼为适应度最优的灰狼, β 狼次之。狩猎过程中, 狼在头狼 α 、 β 和 δ 的带领下进行包括搜索、靠近、包围、猎捕和攻击等一系列狩猎行为。其中包围和猎捕是主要的优化过程。

2.1 包围行动

灰狼狩猎行为中, 猎物的最终位置即为其全局最优解, 灰狼群体的包围行为即不断接近猎物的过程。灰狼个体与猎物的距离、狼群根据与猎物距离而更新自身位置分别为

$$D = |C \cdot X_p(t) - X(t)| \quad (5)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (6)$$

式中, t 为迭代次数; $X_p(t)$ 为第 t 次迭代时猎物的位置向量; $X(t)$ 为第 t 次迭代时灰狼个体的位置向量。系数向量 A 、 C 以及收敛因子 a 分别为

$$A = 2a \cdot r_1 - a \quad (7)$$

$$C = 2 \cdot r_2 \quad (8)$$

$$a = \cos\left(\frac{t}{t_{\max}} \pi\right) + 1 \quad (9)$$

式(7)~(9)中, $r_1, r_2 \in [0, 1]$, 为随机变量; t 为当前迭代次数; t_{\max} 为最大迭代次数。

系数向量 A 决定了灰狼位置更新的移动步长, $|A| > 1$ 时, 狼群搜索范围将扩大, 体现为 IGWO 算

法的全局搜索能力;当 $|A| < 1$ 时,狼群缩小搜索范围,表明逐步包围猎物并发起进攻,精确找寻最优解。系数向量 C 则与移动方向有关,有助于在陷入局部最优时,增强全局搜索程度,提高算法全局搜索的稳定性。

经典灰狼算法中收敛因子 a 随迭代次数由2到0线性变化,而研究表明^[25],对收敛因子 a 进行非线性变化可以提升算法的寻优性能。于是式(9)中IGWO算法运用余弦函数对 a 进行非线性变换,同样保证数值上 $a \in [0, 2]$ 。

2.2 猎捕行动

在灰狼识别出猎物的位置并将其包围后,狼群即在头狼 α 、 β 和 δ 的带领下进行猎捕^[26]。头狼的位置更新^[27]分别为

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X| \\ D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta = |C_3 \cdot X_\delta - X| \end{cases} \quad (10)$$

$$\begin{cases} X_1 = X_\alpha - A_1 \cdot D_\alpha \\ X_2 = X_\beta - A_2 \cdot D_\beta \\ X_3 = X_\delta - A_3 \cdot D_\delta \end{cases} \quad (11)$$

式(10)、(11)中, X_α 、 X_β 、 X_δ 为3匹头狼的位置; X 为该灰狼个体位置。每次迭代后,根据适应度大小选出最优的3匹头狼记为新的 α 、 β 和 δ 狼,剩余的 ω 狼将根据新的头狼位置更新自己的位置,即

$$X_{(t+1)} = \frac{X_1 + X_2 + X_3}{3} \quad (12)$$

在IGWO算法中^[28],根据 α 、 β 和 δ 狼的不同适应度值设置不同的权重,在狼群位置更新中更突出 α 狼的主导作用,提高算法模型的收敛精度和速度,即

$$X_{(t+1)} = \frac{1}{\frac{1}{f_\alpha} + \frac{1}{f_\beta} + \frac{1}{f_\delta}} \left(\frac{X_1}{f_\alpha} + \frac{X_2}{f_\beta} + \frac{X_3}{f_\delta} \right) \quad (13)$$

式中, t 为迭代次数; $\frac{1}{f_\alpha}$ 、 $\frac{1}{f_\beta}$ 、 $\frac{1}{f_\delta}$ 分别为 α 、 β 、 δ 狼的对应权重。

3 模型的整体流程及框架

为了提升编解码器模型在风电故障预测中的建模能力和预测精度,本文首先利用IGWO算法对模型关键超参数进行优化选取。优化的超参数包括学习率、两层编码器神经元数量以及两层解码器神经元数量。优化目标为以编解码器模型在训练

集数据上经过100次迭代后的平均相对误差作为适应度值,旨在通过全局搜索策略实现参数组合的最优选择,从而提升模型的收敛效率和鲁棒性。具体的优化流程如下。

1) 初始化解算参数,包括:狼群规模 N 、最大迭代次数 t_{\max} 、系数向量 A 和 C 以及收敛因子。

2) 根据待优化超参数的取值范围,随机生成狼群中每只灰狼的初始位置向量。位置向量中的每个分量分别对应一个超参数的具体取值,形成初始参数组合。

3) 将每只灰狼的位置向量代入编解码器模型进行训练,计算其适应度值。根据适应度值的大小,对灰狼进行排序,并选取适应度值最小的3只灰狼分别作为 α 、 β 和 δ 狼,作为当前搜索方向的指导个体。

4) 根据算法的位置更新公式,更新每只灰狼的当前位置 X 。位置更新依赖于 α 、 β 和 δ 狼的位置,并结合动态调整的参数,更新过程通过动态收缩搜索区域实现算法的收敛性。

5) 重复步骤3)和步骤4),逐步更新灰狼群的位置向量。在每次迭代中,通过重新计算适应度值动态调整 α 、 β 和 δ 狼的位置,确保全局最优解的搜索效率。

6) 当迭代到最大迭代次数或满足提前终止条件时,选取 α 狼的位置向量 X 作为超参数的最优取值组合。将该组合用于编解码器模型训练,以保证模型的全局最优性能。

4 算例分析

4.1 数据准备

为验证所提基于IGWO算法和编解码器的风电故障诊断与预测模型的有效性,选择了美国堪萨斯州某风电场的实际数据进行实验。该数据集来自于风电场的SCADA系统,记录了风电机组的实时运行状态、故障发生时间以及环境因素。通过这些数据,模型能够进行风电机组故障的诊断并预测故障发生的时间。

对美国堪萨斯州某风电场的实际运行数据进行算例分析,观察在测试集上模型预测结果。其电力信息和环境检测信息分别从SCADA系统和风塔直接导出。原始数据集记录了该风场2012年全年信息,如表1所示,在本文中设置数据采集频率为12 h。

表 1 风电机组特征参量

Table 1 Characteristic parameters of wind turbines

特征参量	单位	备注
功率	MW	最大容量 16 MW
风向	(°)	100 m 处
风速	m/s	100 m 处
气温	K	2 m 处
大气压	Pa	叶片表面
空气密度	kg/m ³	中心处
振动数据	m/s ²	传感器处
故障记录		
风机状态		系统健康状况

各特征参量监测数据如图 2 所示,将前 11 个月的数据作为训练集,后 1 个月数据为测试集。

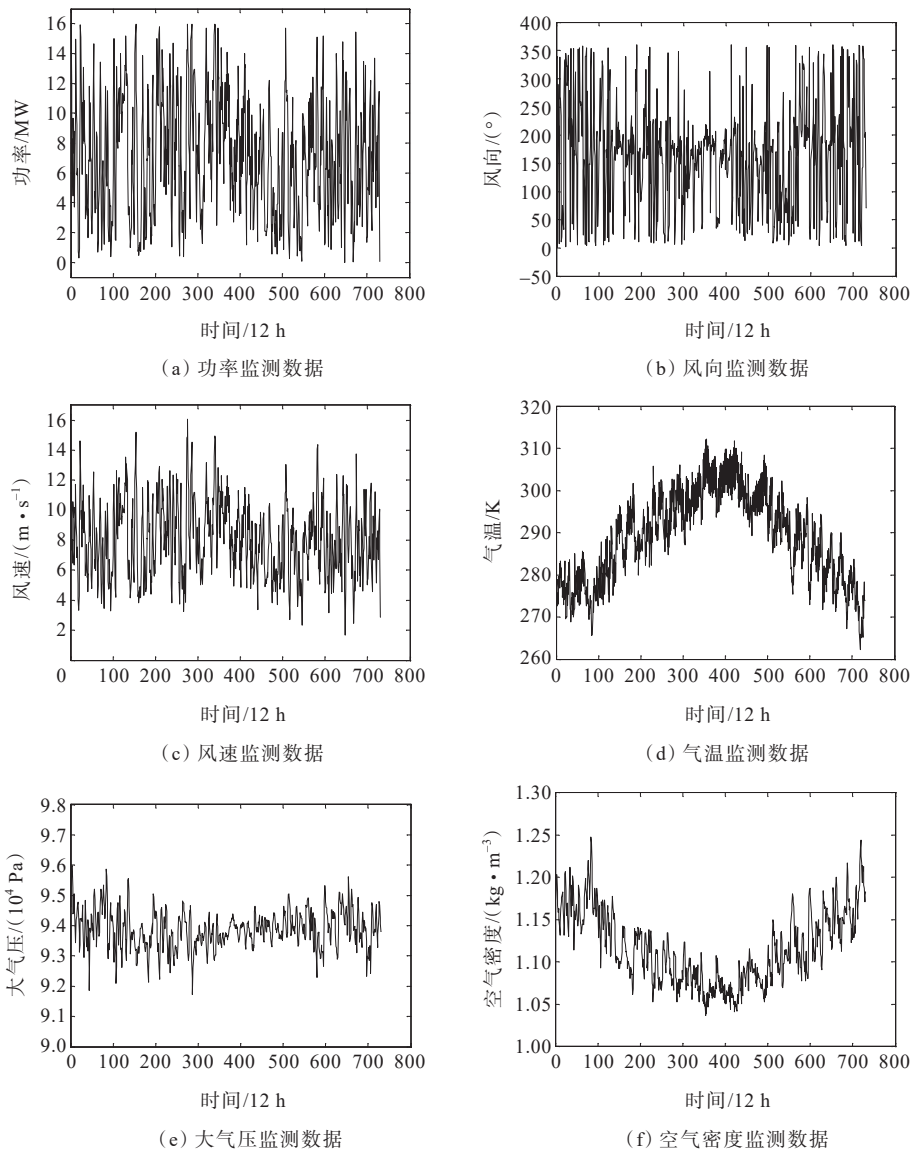


图 2 风电场特征参量监测数据

Figure 2 Monitoring data of characteristic parameters of wind farms

本文结合注意力机制构建编解码器预测模型,并引入 IGWO 算法对 Seq2Seq 网络隐层神经元个数及学习率等超参数进行优化选取。编码器、解码器模块均选用 2 层 GRU 网络,编码器时间步长设置为 100,解码器时间步长为 62,即训练模型利用前 50 d 的历史数据信息预测后 31 d 的风电输出功率。

预测结果评价指标选用平均相对误差(mean relative percentage error, MRE)和均方根误差(root mean squared percentage error, RMSE)。上述误差指标通过评估预测值整体误差,衡量整体预测稳定性,有效刻画预测精度:

$$M_{RE} = \frac{1}{T_y} \sum_{i=1}^{T_y} \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (14)$$

$$R_{MSE} = \sqrt{\frac{1}{T_y} \sum_{i=1}^{T_y} \left(\frac{\hat{y}_i - y_i}{y_i} \right)^2} \times 100\% \quad (15)$$

式(14)、(15)中, T_y 为每例预测样本标签总数; \hat{y} 为预测值; y 为样本真实标签。

根据算例设置, 狼群规模 N 取 30, 最大迭代次数 t_{max} 取 200, α 、 β 、 δ 狼的对应权重分别为 1/2、1/3、1/6, 猎物位置为五维向量, 分别代表五类待优化的超参数。经过 200 次迭代, 各超参数取值情况如表 2 所示。

表 2 风电机组特征参量

Table 2 Characteristic parameters of wind turbines

超参数	取值范围	最优值
学习率	0.001~0.010	0.003
Enc_layer1	5~50	37
Enc_layer2	5~50	8
Dec_layer1	5~50	48
Dec_layer2	5~50	6

4.2 算例数据分析

应用文 4.1 所得的编解码器模型最优超参数构建相应的 Seq2Seq 模型, 并对该风电场 12 月风电故障诊断进行预测, 从而优化算法和预测算法两方面比较分析模型在测试集上的预测性能。

1) 优化算法对比方面, 将本文 IGWO 算法与简单 GWO 算法、飞蛾扑火优化 (moth-flame optimization, MFO) 算法以及粒子群优化 (particle swarm optimization, PSO) 算法分别对 Seq2Seq 模型进行超参数调优, 记录每次优化迭代后的最优适应度值, 如图 3 所示。其中 GWO 算法的狼群数目设置为 30, MFO 算法的种群数设置为 15, PSO 算法的粒子群数量设置为 50, 均优化迭代 200 次。

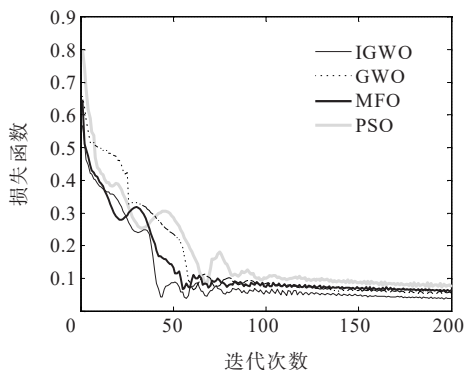


图 3 各算法优化性能对比

Figure 3 Comparison of optimization performance of each algorithm

由图 3 可知, 本文 IGWO 算法在 200 次迭代后使得 Seq2Seq 模型的最优适应度值为 0.038, 低于 GWO 算法 (0.054)、MFO 算法 (0.064) 和 PSO (0.073) 算法, 且所需迭代次数更少, 收敛速度更快。验证了 IGWO 算法由于同时兼顾局部最优和全局调优而具有更强的收敛性, 随着收敛因子和位置更新公式的优化, 进一步提高了全局寻优的稳定性。

2) 预测算法对比方面, 将 GRU 神经网络模型和 SVR 预测模型分别经 IGWO 算法进行 100 次迭代超参数调优后, 与本文方法的预测结果进行比较。各模型预测结果在第 10、20、31 d 内的误差指标如表 3 所示。其中 GRU 网络迭代 100 次, 优化超参数为学习率和两层隐藏层神经元个数; SVR 模型使用径向基核函数 (radial basis function kernel, RBF), 优化超参数为惩罚系数 C 和核函数参数 g 。

表 3 各模型预测结果误差

Table 3 Errors of prediction results of each model

时间/ d	本文方法		IGWO+GRU		IGWO+SVR	
	$M_{AE}/$ %	$R_{MSE}/$ %	$M_{AE}/$ %	$R_{MSE}/$ %	$M_{AE}/$ %	$R_{MSE}/$ %
10	7.17	10.11	16.98	27.96	21.13	31.89
20	11.26	14.66	20.42	28.71	25.67	34.24
31	11.94	15.73	22.46	30.45	29.66	39.63

风电机组运行过程中信号幅值的变化情况如图 4 所示, 实线代表实际测量的信号变化趋势, 虚线表示基于预测模型计算的信号结果。通过两者的对比, 可以评估模型的预测能力。灰色区域标识了信号幅值超过故障阈值的时间段, 这些区域对应设备发生故障的状态。




图 4 故障信号预测及状态诊断

Figure 4 Fault signal prediction and state diagnosis

在故障预测领域,相似度是一项重要的指标,用于衡量实时传感器数据与历史参考数据之间的差异。为了及时预警并采取应对措施,当相似度值低于某个设定的阈值时,系统会触发报警,提醒运维人员检查设备状态,从而降低故障带来的损失和安全隐患。运用相似度的方法,在故障预警测试中,曲线最先下降到阈值以下的模型故障预警性能最好。根据运行人员经验,设定阈值为0.7。

3个模型的故障预警相似度变化如图5所示,各模型预测结果误差如表3所示。由图5可知,相比于IGWO-SVR模型和IGWO-GRU模型,IGWO-Seq2seq模型的相似度计算结果最先低于设定的阈值,也就是最先发出故障警报。实验结果证明,IGWO-Seq2seq模型相比于对比模型,拥有最好的故障预警性能。

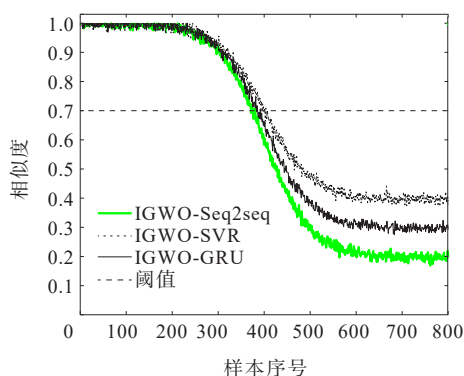


图5 各模型的故障预警测试结果

Figure 5 Fault warning test results of each model

由表3可知,本文模型在3个时间节点上的各项误差指标均为最低水平,经过一个月的预测,本文方法的MAE指标为11.94%,相比GRU和SVR方法分别降低了10.52%和17.72%;RMSE指标为15.73%,相比GRU和SVR方法分别降低了14.72%和23.90%。GRU方法由于网络结构较简单且对每个输入时间点赋以同样的学习权重,使得长期预测效果不理想,从第10d起误差水平显著增加。而SVR方法由于对各输入点单独学习,无法考虑输入序列之间隐层联系,因此误差水平最高,第10d的MAE和RMSE就达到21.13%和31.89%,无法实现精确预测。

5 结语

本文提出一种基于门控循环单元并结合注意

力机制的编解码器模型对风电故障诊断进行预测,并由改进灰狼优化算法对学习率和神经元个数等超参数进行调优选取。在以美国堪萨斯州某风电场为案例的分析中,得到以下结论:

1) Seq2Seq模型的编码器-解码器结构能够深入挖掘输入时序点间联系,注意力机制则可以加强关键输入时刻的表达,提升模型长期预测的精度;

2) GWO算法可以同时兼顾局部寻优和全局最优,自适应能力强,IGWO算法进一步提升了算法搜索最优解的效率,提升收敛速度;

3) 通过对2012年该风电场数据的算例分析,本文方法可以准确预测12月风电机组故障的发生,相比GRU方法误差指标分别降低了10.52%和14.72%,预测更为精准可靠。

参考文献:

- [1] 谭显东,刘俊,徐志成,等.“双碳”目标下“十四五”电力供需形势[J].中国电力,2021,54(5):1-6.
TAN Xiandong, LIU Jun, XU Zhicheng, et al. Power supply and demand balance during the 14th Five-Year Plan period under the goal of carbon emission peak and carbon neutrality[J].Electric Power,2021,54(5):1-6.
- [2] 阮佳琪,孙浩.浅谈海上风电与智能制造在“双碳”目标下的发展结合点[J].水电与新能源,2024,38(10):47-50.
RUAN Jiaqi, SUN Hao. On the development integration point of offshore wind power and intelligent manufacturing considering the carbon peaking and carbon neutrality goals[J].Hydropower and New Energy, 2024,38(10):47-50.
- [3] 袁晓冬,曾飞,缪惠宇,等.电热氢综合能源系统建模及容量规划研究[J].高压电器,2024,60(7):34-47.
YUAN Xiaodong, ZENG Fei, MIU Huiyu, et al. Study on modelling and capacity planning of electric-thermal-hydrogen integrated energy systems[J]. High Voltage Apparatus,2024,60(7):34-47.
- [4] 巫春平,赵鑫.“双碳”背景下广西陆上风电开发现状及发展前景展望[J].红水河,2023,42(3):55-59.
WU Chunping, ZHAO Xin. Current status and development prospects of onshore wind power development in guangxi under the "Dual Carbon" background [J].Red River,2023,42(3):55-59.
- [5] 何坤敏.基于信息融合的风电机组齿轮箱故障诊断方法研究[D].贵阳:贵州大学,2023.
HE Kunmin. Research on fault diagnosis method of wind turbine gearbox based on information fusion[D]. Guiyang:Guizhou University,2023.
- [6] 郭慧军.基于深度学习的风电机组状态监测与健康评

- 价[D].呼和浩特:内蒙古工业大学,2021.
- GUO Huijun. Condition monitoring and health evaluation of wind turbine based on deep learning[D]. Hohhot:Inner Mongolia University of Tehchnology,2021.
- [7] 张利慧,李殊瑶,李晓波,等.基于时频域特征参数的风电机组滚动轴承故障诊断方法及应用[J].内蒙古电力技术,2024,42(3):13-19.
- ZHANG Lihui, LI Shuyao, LI Xiaobo, et al. Diagnostic method of wind turbine rolling bearing failure based on time frequency domain characteristic parameters and its application[J].Inner Mongolia Electric Power,2024,42(3): 13-19.
- [8] 连莎莎.基于模型的风电机组变桨距系统故障预测的研究[D].北京:华北电力大学,2015.
- LIAN Shasha. Research on model-based fault prediction of pitch system for wind turbines[D]. Beijing: North China Electric Power University,2015.
- [9] 张小田,鄢盛腾,周雪青,等.基于状态监测的风电机组主轴早期故障预测方法[J].广东电力,2012,25(11):6-9+50.
- ZHANG Xiaotian, YAN Shengteng, ZHOU Xueqing, et al. Early stage failure forecast method for main bearing of wind turbine based on state monitoring[J].Guangdong Electric Power,2012,25(11):6-9+50.
- [10] 王朋飞,刘长良,徐健,等.基于图注意力和时间卷积网络的风电齿轮箱故障预警方法[J].电子测量与仪器学报,2023,37(8):204-213.
- WANG Pengfei, LIU Changliang, XU Jian, et al. Wind turbine gearbox fault warning method based on graph attention and temporal convolutional networks[J]. Journal of Electronic Measurement and Instrumentation, 2023,37(8):204-213.
- [11] 于浩,张东,方文墨,等.基于关联分析的生成式对抗神经网络的风电机组故障诊断研究[J].沈阳工程学院学报(自然科学版),2022,18(4):1-6.
- YU Hao, ZHANG Dong, FANG Wenmo, et al. Research on wind turbine fault diagnosis based on generating adversarial neural network based on correlation analysis [J].Journal of Shenyang Institute of Engineering (Natural Science Edition),2022,18(4):1-6.
- [12] 程江洲,冯馨以,冯梦婷,等.计及气象因素的风电机组故障诊断与风险预测[J].科学技术与工程,2022,22(22): 9645-9651.
- CHENG Jiangzhou, FENG Xinyi, FENG Mengting, et al. Wind turbine fault diagnosis and risk prediction considering meteorological factors[J]. Science Technology and Engineering,2022,22(22):9645-9651.
- [13] 陈亚楠,胡凯凯,陈刚,等.基于机器学习的风电机组齿轮箱故障预警[J].控制与信息技术,2021(5):108-112.
- CHEN Yanan, HU Kaikai, CHEN Gang, et al. Fault early warning of wind turbine gearbox based on machine learning[J].Control and Information Technology,2021(5): 108-112.
- [14] 尹子康,林忠伟,吕广华,等.基于数据驱动的风电机组变桨系统故障诊断与健康状态预测研究[J].东北电力大学学报,2024,43(5):1-11+17.
- YIN Zikang, LIN Zhongwei, LYU Guanghua, et al. Research on fault diagnosis and health state prediction of wind turbine variable pitch system based on data drive [J].Journal of Northeast Electric Power University,20,43 (5):1-11+17.
- [15] 朱彦民,李忠虎,王金明,等.基于Transformer的风电机组故障预测[J].电子测量技术,2024,47(13):45-52.
- ZHU Yanmin, LI Zhonghu, WANG Jinming, et al. Transformer based fault prediction for wind turbines[J]. Electronic Measurement Technology,2024,47(13):45-52.
- [16] 成志伟,王晓丹,李雪娇,等.基于大数据分析技术的风电机组齿轮箱故障预警[J].内燃机与配件,2023(4): 73-75.
- CHENG Zhiwei, WANG Xiaodan, LI Xuejiao, et al. Wind turbine gearbox fault warning based on big data analysis technology [J]. Internal Combustion Engines and Accessories,2023 (4):73-75.
- [17] 李刚,张曦月,杨维.基于改进Seq2Seq模型的电力智能客服系统设计方法研究[J].电力信息与通信技术,2023, 21(8):68-74.
- LI Gang, ZHANG Xiyue, YANG Wei. Research on design method of electric power smart customer service system based on improved Seq2Seq model[J]. Electric Power Information and Communication Technology,2023,21(8): 68-74.
- [18] 杨秀,胡钟毓,田英杰,等.基于Attention机制的CNN-GRU配网线路重过载短期预测方法[J].电力科学与技术学报,2023,38(1):201-209.
- YANG Xiu, HU Zhongyu, TIAN Yingjie, et al. Short-term heavy overload forecasting method of distribution net line based on CNN-GRU with Attention mechanism[J]. Journal of Electric Power Science and Technology,2023, 38(1):201-209.
- [19] 杨楠,贾俊杰,邢超,等.基于E-Seq2Seq技术的数据驱动型机组组合智能决策方法[J].中国电机工程学报,2020, 40(23):7587-7600.
- YANG Nan, JIA Junjie, XING Chao, et al. Data-driven intelligent decision-making method for unit commitment based on E-Seq2Seq technology[J]. Proceedings of the CSEE,2020,40(23):7587-7600.
- [20] 牧慧琴.车联网通信中基于深度学习的信道估计技术研究[D].南昌:华东交通大学,2023.

- MU Huiqin. Research on channel estimation technology based on deep learning in vehicle networking communication[D]. Nanchang: East China Jiaotong University, 2023.
- [21] 刘振涛. 基于深度学习方法的中文分词和词性标注研究[D]. 天津:中国民航大学, 2020.
- LIU Zhentao. Research on Chinese word segmentation and part-of-speech tagging based on deep learning methods[D]. Tianjin: Civil Aviation University of China, 2020.
- [22] 林玲,陈福集,谢加良,等. 基于改进灰狼优化支持向量回归的网络舆情预测[J]. 系统工程理论与实践, 2022, 42(2):487-498.
- LIN Ling, CHEN Fuji, XIE Jialiang, et al. Prediction of network public opinion based on improved grey wolf optimized support vector machine regression[J]. Systems Engineering—Theory & Practice, 2022, 42(2):487-498.
- [23] 李文哲,李开明,岳屹峰,等. 基于时空注意力-Seq2Seq网络的ISAR包络对齐方法[J]. 信号处理, 2024, 40(9): 1659-1673.
- LI Wenzhe, LI Kaiming, YUE Yifeng, et al. ISAR range alignment based on a spatiotemporal attention-Seq2Seq network[J]. Journal of Signal Processing, 2024, 40(9): 1659-1673.
- [24] 朱咏明,何龙,王清彬,等. 基于灰狼优化算法的PMU配置模型[J]. 电力设备管理, 2024(18):202-204.
- ZHU Yongming, HE Long, WANG Qingbin, et al. PMU configuration model based on grey wolf optimization algorithm[J]. Electric Power Equipment Management, 2024(18):202-204.
- [25] 任振宇,张师. 基于灰狼算法的电力系统无功优化控制[J]. 黑龙江电力, 2021, 43(1):64-67.
- REN Zhenyu, ZHANG Shi. Reactive power optimization control in power system based on gray wolf algorithm[J]. Heilongjiang Electric Power, 2021, 43(1):64-67.
- [26] 冯严冰,王洪亮. 基于入侵杂草优化和灰狼优化算法的混合优化算法研究[J]. 信息技术与信息化, 2024(9): 67-70.
- FENG Yanbing, WANG Hongliang. Research on hybrid optimization algorithm based on invasive weed optimization and grey wolf optimization algorithm[J]. Information Technology and Informatization, 2024(9): 67-70.
- [27] 侯勇严,杨澳,郭文强,等. 基于灰狼算法优化的神经网络短期发电量预测[J]. 陕西科技大学学报, 2022, 40(4): 171-177.
- HOU Yongyan, YANG Ao, GUO Wenqiang, et al. Short-term power generation prediction using grey wolf optimization algorithm and neural network[J]. Journal of Shaanxi University of Science and Technology, 2022, 40(4):171-177.
- [28] 刘晖,朱德康,许凌杰,等. 基于改进灰狼算法优化支持向量机的边坡位移预测[J]. 自动化技术与应用, 2024, 43(9):30-33+171.
- LIU Hui, ZHU Dekang, XU Lingjie, et al. Slope displacement prediction based on improved grey wolf algorithm and support vector machine[J]. Techniques of Automation and Applications, 2024, 43(9):30-33+171.