

DOI:10.20033/j.1003-7241.(2026)02-0040-06

# 基于GRU网络的油田测风塔超短期风电功率预测系统研究

赵永平<sup>1</sup>, 李春保<sup>1</sup>, 剡 炜<sup>1</sup>, 白 洁<sup>1</sup>, 白贞妮<sup>2</sup>, 陈彦润<sup>3</sup>

(1. 中国石油青海油田分公司油气工艺研究院, 甘肃 敦煌 736202; 2. 中国航发航空科技股份有限公司, 四川 成都 610000;  
3. 西安石油大学 新能源学院, 陕西 西安 710000)

**摘要:**针对油田测风塔超短期风电功率预测准确性差的问题,研究提出基于循环单元神经网络的预测方法。该方法通过循环单元神经网络处理时间序列数据,利用支持向量机优化分类性能,并采用粒子群优化算法优化网络超参数。结果显示,在对比实验中,该模型的准确率和 $F_1$ 分数分别达到了0.85和0.83,平均绝对百分比误差降至7.5%,显著优于其他对比算法。此外,在实际应用中,该系统展现出了极高的预测准确率,误差严格控制在1 kW以内,显著优于其他方案。结论表明,研究提出电功率预测系统在油田测风塔功率预测中具有优越的性能和广泛的应用前景。

**关键词:**GRU; 粒子群优化算法; 支持向量机; 风电功率预测

中图分类号: TP18; TN355.5

文献标志码: A

文章编号: 1003-7241(2026)02-0040-06

## Research on ultra short term wind power prediction system for oilfield wind tower based on GRU network

ZHAO Yongping<sup>1</sup>, LI Chunbao<sup>1</sup>, YAN Wei<sup>1</sup>, BAI Jie<sup>1</sup>, BAI Zhenni<sup>2</sup>, CHEN Yanrun<sup>3</sup>

(1. China Petroleum Qinghai Oilfield Branch Oil and Gas Technology Research Institute, Dunhuang 736202, Gansu, China;  
2. China Aerospace Science and Technology company limited, Chengdu 610000, Sichuan, China;  
3. Xi'an University of Petroleum New Energy College, Xi'an 710000, Shaanxi, China)

**Abstract:** A prediction method based on recurrent unit neural network is proposed to address the issue of poor accuracy in predicting ultra short term wind power of oilfield wind turbines. This method processes time series data through a recurrent unit neural network, optimizes classification performance using support vector machines, and uses particle swarm optimization algorithm to optimize network hyperparameters. The results show that in the comparative experiment, the accuracy and  $F_1$  score of the model reaches 0.85 and 0.83 respectively, and the average absolute percentage error decreases to 7.5%, significantly better than other comparative algorithms. In addition, in practical applications, the system demonstrates extremely high prediction accuracy, with an error strictly controlled within 1 kW, significantly better than other solutions. The conclusion shows that the electric power prediction system has superior performance and wide application prospect in the oilfield wind tower power prediction.

**Keywords:** GRU; particle swarm optimization algorithm; support vector machine; wind electric power prediction

油田测风塔在渤海油田的风能利用中占据了重要地位,对油田的能源多元化和节能减排起到了关键作用<sup>[1-2]</sup>。然而,油田测风塔产生的风电功率受到多种因素的影响,如风速、风向等,这使得风电功率的输出存在一定的不确定性和波动性。为了实现油田风电的高效利用,需要对油田测风塔的超短期风电功率进行准确预测<sup>[3-4]</sup>。杨菁等针对地铁通信系统光功率数据缺失的预测问题,提出基于双池化多层感知机模型的方法。结果显示,该模型能有效利用数据信息,充分考虑光功率突变特点,具备较高预测精度,有效解决了光功率时常突变、难以预测的问题<sup>[5]</sup>。Huang等针对5G光伏基站网络配置管理效率低和

恶劣天气下光伏功率预测不准确的问题,提出融合改进北方苍鹰优化反向传播神经网络和循环生成对抗网络的预测方法。结果显示,该方法在各种天气条件下均表现出较高的预测精度<sup>[6]</sup>。但相关研究的功率预测模型的鲁棒性较差,在油田测风塔中的准确率较差<sup>[7-8]</sup>。鉴于此,研究融合了门控循环单元神经网络(gated recurrent unit, GRU)、支持向量机和粒子群优化算法,构建了一个综合性的预测模型GRU-SVM-PSO,通过引入改进的自适应经验模态分解算法噪声完备集合算法,解决端点发散问题,利用变分自编码器进行数据扩充,最终设计出油田测风塔超短期风电功率预测系统(ultra-short-term wind power

收稿日期:2024-05-24;录用日期:2024-06-03

基金项目:青海省中国石油青海科研项目(2004012)

作者简介:赵永平(1986—),男,本科,中级工程师,研究方向:油气田新能源清洁替代、清洁电力、储能等相关技术。

引用本文:赵永平,李春保,剡炜,等.基于GRU网络的油田测风塔超短期风电功率预测系统研究[J].自动化技术与应用,2026,45(2):40-44,137.  
(ZHAO Yongping, LI Chunbao, YAN Wei, et al. Research on ultra short term wind power prediction system for oilfield wind tower based on GRU network [J]. Techniques of Automation and Applications, 2026,45(2):40-44,137.)

prediction system for oilfield wind tower, UWPPS-OWT)。期望该研究能提升风电功率预测的准确性和稳定性,为油田风电场的安全和高效运营提供有力保障。

## 1 基于GRU的UWPPS-OWT预测系统

### 1.1 GRU-SVM-PSO模型设计与优化

油田测风塔超短期风电功率预测的特点在于其时间范围相对较短,主要关注几分钟到几十分钟内的风速、风向等参数变化<sup>[9-10]</sup>。这种预测对于优化风电场的实时运行和调频至关重要。GRU能够有效处理时间序列数据中的依赖关系<sup>[11]</sup>。GRU通过门控机制来控制信息的流动,使得网络能够捕获数据中的长期依赖关系,提高预测的准确性和稳定性<sup>[12]</sup>。针对这些特点,研究采用GRU神经网络进行风电功率预测,其内部结构如图1所示。

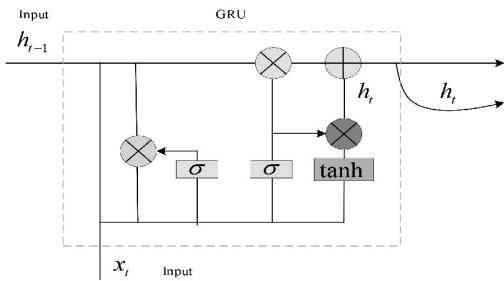


图1 GRU结构示意图

Fig. 1 Schematic diagram of the GRU structure

从图1中可见,门控循环单元(GRU)的结构与长短时记忆网络(long-and short-time memory network, LSTM)相似,GRU通过将遗忘门和输入门组合成一个更新门。在当前时刻,输入 $x_t$ 与前一时刻的状态 $h_{t-1}$ 共同作用于更新门和重置门。决定前一时刻状态信息被带到当前状态中的程度,有效地减少了门的数量,从而简化了网络结构。而重置门则控制前一时刻状态有多少信息被写入到当前的候选状态 $h_t$ 中,如式(1)所示。

$$\begin{cases} z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \\ r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \\ h^- = \tanh(W \cdot [r_t \times h_{t-1}, x_t]) \\ h_t = (1 - z_t) \times h_{t-1} + z_t \times h^- \end{cases} \quad (1)$$

式中, $z_t$ 表示的是更新门。 $r_t$ 表示重置门。 $\sigma$ 为Sigmoid激活函数。它将输入值映射到0~1之间,用于计算更新门和重置门的值。 $\tanh$ 表示双曲正切激活函数。它将输入值映射到-1~1之间,用于计算候选状态的值。 $W_z, W_r, W$ 是权重矩阵。它们分别用于计算更新门、重置门和候选状态。这些权重矩阵在训练过程中会被优化,以最小化预测误差。但单纯的GRU网络并不能准确地对油田测风塔超短期风电功率进行预测<sup>[13-14]</sup>。因此研究引入了支持向量机(support vector machine, SVM)与粒子群优化(optimization of particle groups, PSO)对系统进行优化。从而构建出GRU-SVM-PSO模型,该模型主要包含了3大模块,即数据处理模块,GRU-SVM模块以及PSO优化模块,其结构示意图如图2所示。

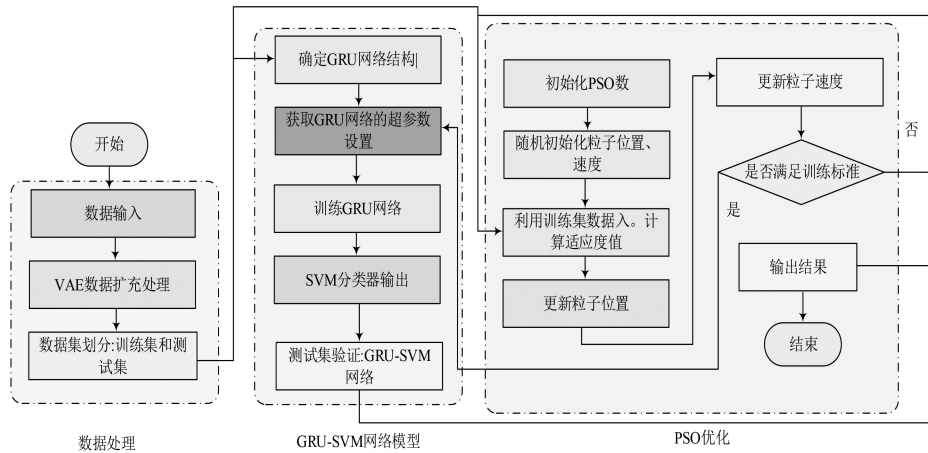


图2 GRU-SVM-PSO算法模型结构示意图

Fig. 2 Schematic diagram of the GRU-SVM-PSO algorithm model structure

从图2中可以看出GRU-SVM-PSO算法模型是一个结合了深度学习、机器学习和优化算法的综合性模型。首先,原始数据经过变分自编码器(variational autoencoder, VAE)进行数据扩充,通过学习输入数据的潜在表示来生成新的数据点,从而增加数据集的多样性和模型的泛化能力。扩充后的数据集被划分为训练集和测试集,为后续模型的训练和验证做准备。在模型构建阶段,首先确定GRU网络的结构,为了优化GRU网络的性能,研究引入

粒子群优化(PSO)算法来搜索最佳的超参数设置。PSO通过初始化粒子群,并不断更新粒子的位置和速度,以寻找最优解。在每次迭代中,利用训练集数据计算适应度值,评估当前超参数的性能,并根据评估结果更新粒子的位置和速度。当满足训练标准时,PSO返回最优的超参数设置给GRU网络。GRU算法输出层激活函数通常采用Softmax函数,但这种函数只能进行单分类,因此使用优化后的超参数配置训练GRU网络,然后采用SVM优化GRU

的输出,通过利用 SVM 替换 GRU 中的 Softmax 激活函数。提取特征后传递给支持向量机 (SVM) 分类器进行训练和输出。最后,使用测试集对训练好的 GRU-SVM 网络进行验证,输出结果,从而完成了整个算法模型的流程。通过这种方式,GRU-SVM-PSO 算法模型能够实现对序列数据的高效处理与分类。

## 1.2 UWPPS-OWT 系统总体流程与功能性设计

UWPPS-OWT 油田测风塔超短期风电功率预测系统首先借助数值天气预报系统广泛搜集包括风速、电压、风电功率以及温度等在内的多维数据。这些数据是风电场运行管理的核心要素。为了更深入地剖析这些数据,需要利用经验模态分解算法 (empirical mode decomposition, EMD) 进行数据处理。然而,标准的 EMD 方法在操作过程中,因每次需计算最大和最小值包络线,会引发端点发散的困扰。为了解决这个问题,研究引入改进的自适应 EMD 噪声完备集算法,首先获取  $N$  个精准的初始量,对于这些初始量利用 EMD 方法分解出各阶的本征模态分

量,公式为

$$C_1^j(t) = A(f_N(t)) - \gamma^1 \quad (2)$$

式中,  $C_1^j(t)$  代表通过 EMD 算法分解得到的第一阶本征模态分量 (intrinsic mode function, IMF)。  $j$  表示这是针对第  $j$  个初始量的分解结果,而  $t$  代表时间。  $f_N(t)$  这个表达式中的  $A$  代表一个操作,  $f_N(t)$  代表第  $N$  个初始量,它是时间  $t$  的函数。  $\gamma^1$  代表一个常数,用于调整或修正  $A(f_N(t))$  以便得到更准确的 IMF 分量。然后对每个 IMF 求平均值得到第 1 阶 IMF 分量,公式为

$$\text{IMF}_1 = \frac{1}{N} \sum_{j=1}^N C_1^j(t) \quad (3)$$

式中,  $N$  表示分解后的初始量总数。然后计算  $\text{IMF}_1$  的残差值,公式为

$$r_1(t) = f(t) - \text{IMF}_1 \quad (4)$$

然后通过求平均值第 2 阶 IMF 分量,重复上述步骤,直到残差无法被分解。UWPPS-OWT 系统的结构示意图如图 3 所示。

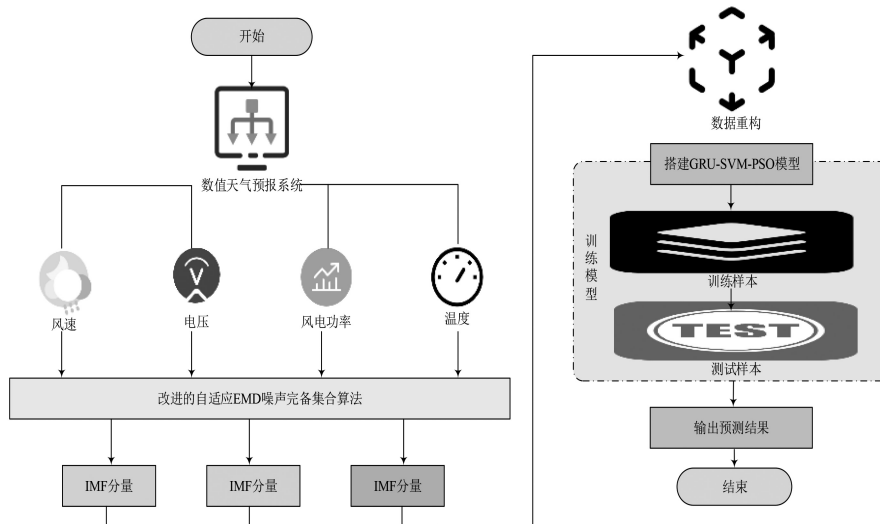


图 3 UWPPS-OWT 结构示意图

Fig. 3 Schematic diagram of the UWPS-OWT structure

从图 3 中可以看出,研究提出的油田测风塔超短期风电功率预测系统是一个复杂而精细的预测体系。首先,依赖数值天气预报系统全面而精准地采集风速、风向、温度及气压等多元化的气象数据,对于缺失和不完整的数据研究采用滑动平均法进行处理,其计算公式为

$$x_n = \frac{x_{n-i} + \dots + x_{n-1} + x_{n+1} + \dots + x_{n+i}}{2i} \quad (5)$$

式中,  $x_n$  是经过滑动平均处理后的数据值,对应于数据点  $n$ 。  $x_{n-i}$  是在时间点  $n$  之前的第  $i$  个数据点,这些值都被用来计算滑动平均值。  $2i$  表示在滑动平均处理中用于计算平均值的数据点总数。这些数据是风电功率预测不可或缺的基础。紧接着,采集到的数据会被传输到改进的自适应 EMD 噪声完备集算法模块中,进行深度的分解与重构。以达到提炼出数据中的核心特征,去除噪声干扰的目的。完成数据的预处理后,重构的数据会被输入到研究提出的 GRU-SVM-PSO 算法模型中。其中,风电功率的计算

公式为

$$E = \rho S V^3 \alpha / 2 \quad (6)$$

式中,  $E$  代表风电功率,即风能转化为电能的功率,单位是 kW,表示风力发电机从风中捕获并转化为电能的速率。  $\rho$  为空气密度,单位是  $\text{kg}/\text{m}^3$ 。  $S$  表示的是扫风面积,这是指风力发电机叶片旋转时所扫过的面积,它决定了风力发电机能够从风中捕获多少能量,单位是平方米。  $V$  表示的是风速,单位是  $\text{m}/\text{s}$ 。  $\alpha$  为能量转换效率系数,它表示风力发电机将风能转换为电能的效率。通过对训练集和测试集的反复学习、优化与验证,模型能够捕捉到风电功率变化的深层次规律。最终,经过模型的综合分析,输出具有高度准确性和可靠性的风电功率预测结果,为油田风电场的安全运营提供有力支持。

## 2 UWPPS-OWT 系统性能测试与应用性分析

为了充分验证 GRU-SVM-PSO 的综合性能,研究设计

了五个实验组以探究不同优化手段对 GRU 网络预测性能的影响。基础模型采用标准的 GRU 网络,不涉及额外优化。接着,加入基于改进的自适应 EMD 噪声完备集合算法的数据预处理,以提升数据质量。另一实验组则运用粒子群优化(PSO)来调优 GRU 的超参数,旨在找到最佳网络配置。此外,还用支持向量机(support vector machine, SVM)取代了 GRU 的输出层,以期改进分类性能。最后,实验

整合了 GRU、PSO 和 SVM,构建出完整的 GRU-SVM-PSO 模型。为评估模型,研究选择了准确率、 $F_1$  分数、平均绝对百分比误差(mean absolute percentage error, MAPE)、确定系数( $R^2$ )及时间效率作为评价指标。GRU 层数为 2,隐藏单元数为 128,学习率为 0.001,批次大小为 64,迭代次数为 100,实验实际预测结果如图 4 所示。



图 4 系统实际预测界面图

Fig. 4 The actual prediction interface diagram of the system

根据图 4 的实验数据,可以明显看到各种优化手段对 GRU 网络预测性能的积极影响。基础模型的准确率为 0.75,  $F_1$  分数为 0.70,显示出一定的预测能力,但仍有提升空间。通过引入改进的数据预处理技术,准确率和  $F_1$  数分别提升了 0.03 和 0.03,达到 0.78 和 0.73,同时 MAPE 也从 10.5%降低到 9.8%,表明数据质量的提升确实能够提高模型性能。进一步地,通过 PSO 优化 GRU 超参数,准确率和  $F_1$  分数再次小幅提升,分别达到 0.79 和 0.75,MAPE 也降至 9.5%。而将 SVM 作为输出层后,模型的准确率和  $F_1$  分数显著提升至 0.82 和 0.80,MAPE 大幅下降至 8.2%。最终,在完整模型中结合了所有优化手段,准确率和  $F_1$  分数达到了最高的 0.85 和 0.83,MAPE 也降至最低的 7.5%,确定系数  $R^2$  提升至 0.90,验证了 GRU-SVM-PSO 模型的综合性能优势。虽然时间效率从基础模型的 120 s 增加到完整模型的 300 s,但考虑到性能上的显著提升,这一牺牲是值得的。为了进一步验证该模型的优越性,研究引入了最近邻居/ $k$ -近邻算法( $k$ -nearest neighbors algorithm, KNN)、梯度提升决策树 (gradient boosting

decision tree algorithm, GBDT)、朴素贝叶斯算法 (naive bayes algorithm, NB) 来与 GRU-SVM-PSO 进行对比,以 MAE、RMSE 数值作为指标,采用 UIYQ 数据集分别对这 4 种算法进行测试,实验结果如图 5 所示。

从 5 图中可以明确看到,朴素贝叶斯(NB)算法在这次对比中表现最为不佳,其 RMSE 和 MAE 的均值分别高达 9.5 和 9.0。相较之下, $K$  近邻(KNN)算法的性能稍好一些,其 RMSE 和 MAE 的均值分别为 6.3 和 6.0。而梯度提升决策树 (GBDT) 算法则表现得更为出色,其 RMSE 和 MAE 的均值进一步降低到 5.8 和 5.3。研究提出的 GRU-SVM-PSO 算法在所有对比算法中表现出最优异的性能,其 RMSE 和 MAE 的均值分别低至 3.8 和 3.3,这充分证明了该算法在预测精度上的卓越表现。研究充分地验证了 UWPPS-OWT 系统在预测利用的优越性能,为了进一步验证该系统在实际的油田测风塔超短期风电功率预测中也有同样良好的表现,研究引入了文献[15]提出的 IPSO-Elman 方法进行对比,在实际的油田测风塔中进行了测试,实验结果如图 6 所示。

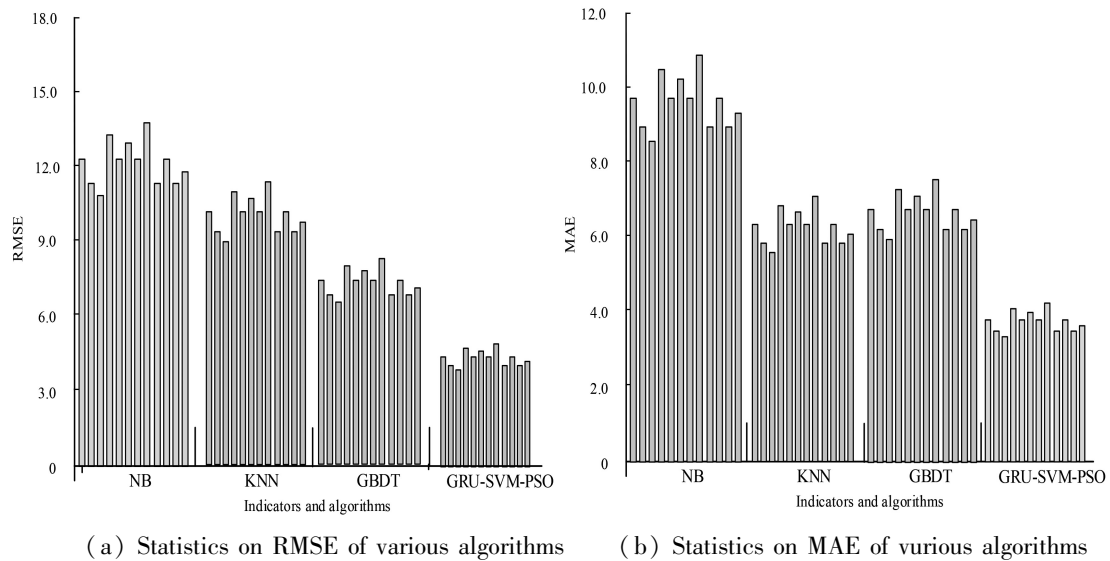


图5 四种算法的MAE、RMSE指标对比情况

Fig. 5 The comparison of MAE and RMSE indicators among the four algorithms

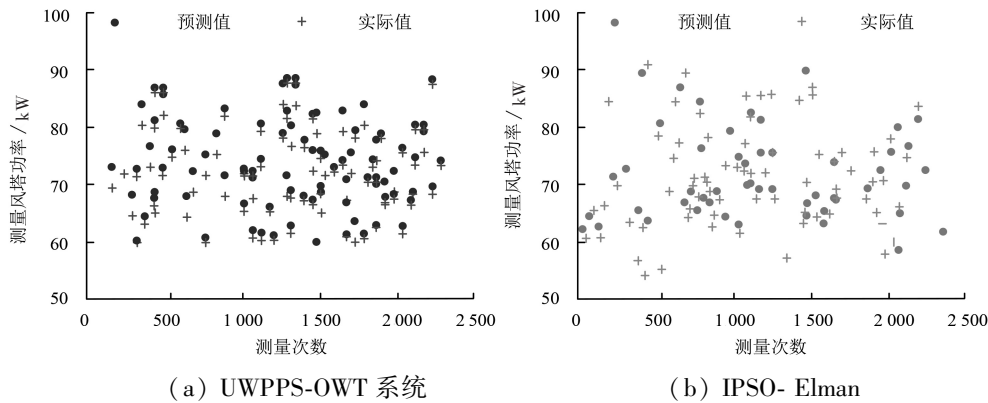


图6 UWPPS-OWT系统应用性实验结果

Fig. 6 Experimental results of the application of the UWPS-OWT system

图6清晰地展示了UWPPS-OWT和IPSO-Elman两种电功率预测系统的应用性实验结果。通过图6(a),可以明确地看到,研究提出的UWPPS-OWT系统在预测电功率方面展现出了极高的准确率。其预测值与实际值几乎完全吻合,误差被严格控制在1 kW以内,这无疑证明了该系统在预测精度上的卓越性能。相比之下,从图6(b)中可以看出,IPSO-Elman方案在测风塔的电功率预测上就显得逊色许多。IPSO-Elman的预测值与实际值之间存在着较大的偏差。在多个数据点上,其误差甚至超过了5 kW。综上所述,WPPS-OWT系统在电功率预测方面准确率极高,误差极小。而IPSO-Elman方案预测结果与实际值偏差较大,误差较明显。UWPPS-OWT系统表现更优异。

### 3 结论

研究针对油田测风塔超短期风电功率预测的问题,提出了基于GRU-SVM-PSO的综合性预测模型。实验结果显示,GRU-SVM-PSO模型在准确率、 $F_1$ 分数、平均绝对百分比误差(MAPE)和确定系数( $R^2$ )等方面均表现出显著优势,具体而言,其准确率达到0.85, $F_1$ 分数为0.83,

MAPE低至7.5%, $R^2$ 提升至0.90,相较于其他对比算法,其MAE和RMSE均值分别为3.8和3.3,显示出了卓越的预测性能。研究提出的UWPPS-OWT系统在预测电功率方面展现出了极高的准确率。其预测值与实际值几乎完全吻合,误差被严格控制在1 kW以内,PSO-Elman的预测值与实际值之间存在着较大的偏差。在多个数据点上,其误差甚至超过了5 kW。总结来说,GRU-SVM-PSO模型为油田测风塔超短期风电功率预测提供了高效、准确的解决方案,对于提升油田风电场的安全运营和能源利用效率具有重要意义。然而,研究仍存在一些不足。首先,模型的时间效率有待进一步提高,从基础模型的120 s增加至完整模型的300 s,尽管性能提升显著,但时间成本的增加仍值得进一步优化。

### 参考文献

- [1]柳想,陈春玲,王慧,等.基于TOPSIS-GRNN的机理-数据混合驱动光伏电站功率预测[J].可再生能源,2024,42(4):471-478.
- [2]周育才,肖添,谢七月,等.基于聚类的HPO-BILSTM光伏功率短期预测[J].太阳能学报,2024,45(4):512-518.

(下转第137页)