

基于PXGBoost-GAE-GMM-GRU多风力机功率预测

彭驿尧¹, 关新宇², 李强仁², 李春华², 雷艾虎², 贺得琚²

(1. 广西大学电气与自动化学院, 南宁 530004; 2. 国网甘肃省电力公司白银供电公司, 白银 730900)

摘 要: 提出一种基于高斯图卷积的循环神经网络预测多风力机功率。首先, 利用粒子群算法(PSO)优化的极致梯度提升树(XGBoost)算法构成特征筛选网络选取重要特征; 其次, 利用图自编码器和余弦相关度融合的方法构建网络图有效挖掘站点间潜在相关性, 描述多风力机站点特征的空间相关性; 最后采用高斯图卷积神经网络深度提取网络图中的内在关系, 由循环神经网络整合其时空相关性实现多风力机功率预测。在真实风电场数据上开展实验, 将预测结果与其他模型对比。实验结果表明, 模型在MSE、RMSE、MAE和MAPE指标上分别达7.7851 MW、2.7902 MW、2.6851 MW和0.2283, 较传统方法降低60%~80%, 尤其在风速波动场景下误差降低40%, 所提模型能显著提升多风力机功率的预测性能。

关键词: 风电功率预测; 图自编码器; 高斯混合模型; 循环神经网络; PSO-XGBoost

中图分类号: TM715

文献标志码: A

0 引 言

风能作为一种绿色环保、可再生的清洁能源对于减缓气候变化和建设可持续能源体系至关重要^[1]。目前, 风力发电已成为全球可再生能源的重要组成部分。然而, 由于风速具有很强的随机性和波动性, 大规模风电并网会对电力系统的平稳运行带来严重威胁^[2]。预测风电功率可帮助风电场及电网及时调整调度计划, 为风电机组运维时间提供参考。西北电网拥有丰富的风能资源, 高准精度的风电功率预测将降低风能利用成本并提升风力发电接入效率。

目前, 风电功率预测方法主要分为传统统计模型和机器学习模型。传统统计模型通常是时间序列模型, 能很好地表征风电序列的线性波动。晏吴宇歆等^[3]基于损失函数和补丁时序Transformer网络对风功率超短期多步预测; 曹俊波等^[4]通过改进的差分自回归移动平均模型(autoregressive integrated moving average model, ARIMA)预测短期风速数据, 提出一种确定不同出力特性的风电场风功率时间序列转化为平稳序列所需的最优差分次数的方法; 刘震等^[5]采用多元回归-ARIMA-卡尔曼组合模型对风力发电进行了不同时间步长的短期预测; 符杨等^[6]考虑多种气象相似性和数值天气预报(numerical weather prediction, NWP)修正进行风电功率短期模型。总体而言, 统计模型在短期风电预测中表现出较好的预测性能。

随着计算机与人工智能技术的进步, 基于机器学习的模型被广泛运用在风电预测任务中。王帅党等^[7]使用灰狼算法优化双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)模型参数, 结合自适应变分模态分解(adaptive variational mode decomposition, AVMD)、卷积神经网络(convolutional neural network, CNN)和门控递归单元(gated recurrent unit, GRU)以及注意力(Attention)机制, 建立了AVMD-CNN-GRU-Attention模型, 充分提取风速与风功率之间的复杂关系, 提高短期风功率预测的准确性; 李进友等^[8]引入改进的XGBoost算法, 利用多特征融合方法提升了风电预测的精度, 强调了特征选择对模型性能的重要性。文献[7-8]研究表明, 结合智能优化算法和深度学习框架, 可有效增强模型的预测能力, 进而在工程应用中取得更好的预测效果。

近年来, 场站级多风力机预测开始受到关注。近年来, 随着多个风电场集中连网运行, 多风力机功率预测需求日益凸显。付波等^[9]针对多风电场超短期功率预测中时空特征提取不足的问题, 提出一种基于沙普利可加性解释(SHapley Additive exPlanations, SHAP)重要性排序和时空双流特征提取基于图注意力网络(improved graph attention network, IGAT)、多头注意力(multi-head attention, MHA)和时间卷积网络(temporal convolutional network, TCN)的综合模型(IGAT-MHA-TCN), 该方法通过SHAP分析从高维NWP中选取关键变量并构建自适应动态邻接矩阵, 以图注意力网络提取空间

特征,同时融合多头注意力与时间卷积网络增强时序信息学习,在西北某风电场的案例中显著优于传统方法;赵泽妮等^[10]研究表明,基于粒子群或遗传算法的特征选择、数据预处理与时空模型的协同设计是提高风电预测精度的核心路径;Ahmed 等^[11]提出的波动分解与极值检测相结合的提升-线性回归混合框架(Boosting-LR),以及基于时空相关性挖掘的风场簇预测方法,都进一步验证了特征预选与时空关联学习的必要性。此外,图卷积网络与循环网络相结合的混合模型^[12]在可再生能源功率预测中也取得了良好表现,证明了图卷积网络(graph convolutional network, GCN)-长短期记忆网络(long short-term memory, LSTM)架构在捕捉复杂空间拓扑与时间动态方面的有效性。综上,现有研究虽从各自侧重特征选择或时空建模,但尚缺乏一个能自动筛选高维关键特征、自适应构建动态图并深度协同时空信息的统一预测框架。

鉴于此,本文提出一种基于深度学习的风电场多站点风电功率集成预测模型(PXGBoost-GAE-GMM-GRU),通过多站点间的特征关联提升每个站点的预测效果。首先,提出基于粒子群优化(particle swarm optimization, PSO)的极致梯度提升树(eXtreme Gradient Boosting trees, XGBoost)算法(PXGBoost)构成特征筛选网络选出重要特征。然后将图自编码器(graph auto-encoder, GAE)和余弦相关度融合构建网络图以深度提取各风力机间特征的关系。最后利用高斯图卷积神经网络(Gaussian mixture model convolutional network, GMM)模型高效学习图结构相似性的能力,对图结构的特征再进行深度学习并将得到的深层特征数据输入到 GRU 中进行预测,根据风力机的特征和其邻接关系计算多风力机间相互作用后的功率预测值。

1 特征处理

1.1 XGBoost 算法

XGBoost 是针对梯度提升树优化后的一种集成学习算法,其基本思想是将多个弱学习器组合起来,形成一个强学习器,计算的准确性随迭代次数的增加而提高,每次迭代生成的强学习器拟合前一个强学习器的残差,这个过程被称为梯度提升。XGBoost 算法使用多棵分类回归树(classification and regression trees, CART)作为基学习器。在树的构建过程中,算法选择能最大化信息增益的特征作为分割点,每个特征的重要性由其在分裂过程中被选择的频率来衡量。

XGBoost 原理表示为:

$$\hat{\beta}_i = \sum_{k=1}^K f_k(\tau_i), f_k \in F \quad (1)$$

式中: $\hat{\beta}_i$ ——预测值; K ——树的数量; f_k ——空间 F 中第 k 棵树的预测函数; τ_i ——输入的第 i 个样本; F ——所有可能 CART 的集合。在计算中,得到所有可能 CART 的集合是比

较困难的,因此 XGBoost 选择梯度提升的方法是每次添加一棵新树,不断迭代并根据残差优化整体的测试结果。如果在第 t 轮的预测值为 $\hat{\beta}_i^{(t)}$,则前 t 轮预测结果为:

$$\begin{cases} \hat{\beta}_i^{(0)} = 0 \\ \hat{\beta}_i^{(1)} = f_1(\tau_i) = \hat{\beta}_i^{(0)} + f_1(\tau_i) \\ \hat{\beta}_i^{(2)} = f_1(\tau_i) + f_2(\tau_i) = \hat{\beta}_i^{(1)} + f_2(\tau_i) \\ \vdots \\ \hat{\beta}_i^{(t)} = \sum_{k=1}^t f_k(\tau_i) = \hat{\beta}_i^{(t-1)} + f_t(\tau_i) \end{cases} \quad (2)$$

在第 t 轮, XGBoost 的目标优化函数 $f_{\text{obj}}^{(t)}$ 为:

$$f_{\text{obj}}^{(t)} = \sum_{i=1}^n l(\beta_i, \hat{\beta}_i^{(t-1)} + f_t(\tau_i)) + \Omega(f_t) \quad (3)$$

式中: l ——损失函数; Ω ——正则化项,用于控制树的复杂度。通常将损失函数进行泰勒级数展开,只取前三项并移除高阶无穷小项,因此第 t 轮的目标优化函数为:

$$f_{\text{obj}}^{(t)} \approx \sum_{i=1}^n l(\beta_i, \hat{\beta}_i^{(t-1)} + g_i f_t(\tau_i) + \frac{1}{2} h_i f_t^2(\tau_i)) + \Omega(f_t) \quad (4)$$

式中: ζ_i 和 ψ_i ——损失函数的一阶导数和二阶导数。

$$\zeta_i = \partial_{\beta_i^{(t-1)}} l(\beta_i, \hat{\beta}_i^{(t-1)}) \quad (5)$$

$$\psi_i = \partial_{\beta_i^{(t-1)}}^2 l(\beta_i, \hat{\beta}_i^{(t-1)}) \quad (6)$$

定义其正则化项为:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (7)$$

式中: w_j ——树 f 中第 j 个叶子节点上的分值; T ——树 f 中叶子节点的总数; γ, λ —— L_1 正则的惩罚项和 L_2 正则的惩罚项,是 XGBoost 的自定义参数。

目标优化函数为:

$$f_{\text{obj}} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (8)$$

$$G_i = \sum_{i \in I_j} \zeta_i \quad (9)$$

$$H_i = \sum_{i \in I_j} \psi_i \quad (10)$$

式中: $I_j = \{i | q(\tau_i) = j\}$ ——第 j 片叶子上的样本集合,结构函数 q 为输入样本到叶子索引号之间的映射, $q(\tau_i) = j$ 表示样本 τ_i 对应的第 j 个叶子节点。

1.2 PXGBoost 算法

为降低模型输入的特征数量,提高模型的预测能力,本文提出基于 PXGBoost 的特征筛选算法筛选多风力机特征。PXGBoost 算法在搜索空间中定义粒子样本群,每个粒子代表一个参数组合的候选解,并根据其自身经验和群体经验调整速度和位置来寻找最优解。如图 1 所示,具体步骤如下:

1) 原始数据集导入,包含多风力机特征数据,如不同高度的风速、不同高度的风向等,并将数据集进行预处理,同时划分数据集为训练集和测试集。

2) 初始化算法参数: 首先算法随机生成若干粒子, 给每个粒子赋予随机的速度和位置, 设置 XGBoost 调整参数的搜索空间范围、最大迭代次数以及构建适应度函数。在 PXGBoost 算法中, 适应度函数选取均方根函数如式 (11) 所示:

$$\varepsilon = \sqrt{\frac{1}{N} \sum_{m=1}^N (y_m - \hat{y}_m)^2} \quad (11)$$

式中: y_m ——实际值; $\hat{y}_m$ ——预测值; N ——需调整的 XGBoost 参数的数量。




图1 PXGBoost算法流程

Fig. 1 Flowchart of PSO-XGBoost algorithm

3) PXGBoost 算法参数调优: 粒子每次迭代更新需重新计算自身的位置和速度, 在第 $t+1$ 轮中粒子的速度和位置的更新公式为:

$$v_m^{t+1} = \omega \cdot v_m^t + c_1 \cdot r_1 \cdot (p_{\text{Best}_m} - x_m^t) + c_2 \cdot r_2 \cdot (g_{\text{Best}_m} - x_m^t) \quad (12)$$

$$x_m^{t+1} = x_m^t + v_m^{t+1} \quad (13)$$

式中: v_m^t ——第 t 轮中粒子的速度; x_m^t ——第 t 轮中粒子的位置; ω ——惯性因子, 控制粒子的搜索能力; p_{Best_m} ——个体最优位置, 指第 m 个粒子在自身迭代过程中找到的最优参数组合; g_{Best_m} 是全局最优位置, 指所有粒子组成的群体中, 截至当前迭代找到的最优参数组合; c_1, c_2 ——加速常数, 分别代表个体和群体的学习因子, 通常取 2; r_1, r_2 ——在 0~1 之间的随机数。

4) 计算粒子的适应度: 通常依据适应度函数来计算每一次迭代的适应度值, 适应度的值也代表了粒子的优劣。如果算法满足设定要求, 则得到最优参数组合, 否则, 则更新粒子的信息, 迭代次数加 1, 并再次计算粒子适应度, 直到满足设定要求为止。

5) 将最优参数组合输入 PXGBoost 优化模型, 计算出每个特征的重要性, 筛选出特征重要性高的前 5 个特征, 得到多风力机的特征数据矩阵 W 。

2 GAE 和余弦相似度的融合模型

结合基于特征相关性网络图的图神经网络在多风力机风速预测中取得了较好的效果。然而, 图神经网络的性能取决于预定义图表征站点特征之间关系的能力, 比如基于皮尔逊相关系数的网络图。预定义的图通常不能反映风速特征的复杂动态变化, 其质量显著依赖于人为判断和准确的风速测量。考虑到这些因素, 本文定义一种新的组合算法来分析风速的时空属性。该算法在预定义图上采用 GAE 网络获取节点嵌入向量, 这些嵌入向量阐明了图的拓扑结构和节点之间的关系^[13]。接着, 通过使用余弦相似度量节点嵌入向量之间的距离, 最终通过余弦相似度的阈值对预定义图的边关系进行调整得出网络图。

2.1 预设图构建

将多风力机的特征数据矩阵 W 构建预设图 $G=(V, E)$, 其中 $V=\{V_1^T, V_2^T, V_3^T, \dots, V_g^T\}$ 代表节点集合。将矩阵 W 的每一列数据视为一个节点的特征向量, 于是所有节点的特征矩阵为矩阵 W^T , 维度为 $g \times D$, 其中 g 是节点数量, D 是每个节点特征的维度。 $E=(e_{pj})_{p,j=1}^g$ 是边集合, 表示节点之间的连接关系, 如果网络节点 V_p 和 V_j 之间有关联, 则存在一条边 $e_{pj}=1$, 其连接强度为 A_{pj} 。采用皮尔逊相关系数描述原始网络图的节点关联。

$$e_{pj} = \begin{cases} 1, & \frac{\sum_{t=1}^D (v_p(t) - \bar{v}_p)(v_j(t) - \bar{v}_j)}{\sqrt{\sum_{t=1}^D (v_p(t) - \bar{v}_p)^2} \sqrt{\sum_{t=1}^D (v_j(t) - \bar{v}_j)^2}} < \delta \\ 0, & \frac{\sum_{t=1}^D (v_p(t) - \bar{v}_p)(v_j(t) - \bar{v}_j)}{\sqrt{\sum_{t=1}^D (v_p(t) - \bar{v}_p)^2} \sqrt{\sum_{t=1}^D (v_j(t) - \bar{v}_j)^2}} > \delta \end{cases} \quad (14)$$

式中: δ ——相关性阈值; $\bar{v}_p$ ——节点 p 的均值。

2.2 基于 GAE 的节点嵌入向量

自动编码器(autoencoder, AE)是针对单个数据的特征提取网络, GAE 是 AE 在网络图上的推广, 由编码器和解码器两部分构成并能够提取网络图的特征^[14]。本文只使用 GAE 的编码器部分, 利用 GCN 将节点特征和邻接矩阵映射到节点的嵌入表示, 这些嵌入向量捕捉了图结构和节点特征的高阶信息。

GAE 由两层图卷积网络 GCN 组成,非线性激活函数为 ReLU,网络图特征 Z 为:

$$Z = \text{GCN}(X, A) = \tilde{A} \text{ReLU}(\tilde{A} X W^{(0)}) W^{(1)} \quad (15)$$

式中: Z 的元素 Z_p 为节点 V_p 的嵌入向量; $\tilde{A} = D^{-\frac{1}{2}} A D^{-\frac{1}{2}}$ ——对称归一化的邻接矩阵; $W^{(0)}, W^{(1)}$ ——第一层和第二层网络中可学习的参数矩阵。

2.3 网络图构建

通过 GAE 得到的节点嵌入向量捕获节点的特征和节点之间的关系。然而,它们并不直接用作网络图的组成部分。本文设置余弦相似度的相似性阈值来确定边缘连接,该阈值决定了节点之间的连通性。并将其大小作为网络图的边权重。

余弦相似度用于衡量两个向量之间相似度,特别适用于高维空间中的向量^[15]。它通过计算两个向量之间夹角的余弦值来度量的相似性,只需进行向量之间的点积运算并标准化。其计算公式为:

$$C(Z_p, Z_j) = \frac{Z_p \cdot Z_j}{\|Z_p\| \|Z_j\|} \quad (16)$$

式中: $Z_p \cdot Z_j$ ——节点嵌入向量 Z_p 和 Z_j 的点积; $\|Z_p\|$ 和 $\|Z_j\|$ 为节点嵌入向量 Z_p 和 Z_j 的范数。最后,在预定义的图形网络 $G=(V, E, A)$ 中,比较 $C(Z_p, Z_j)$ 和阈值 α 确定网络图的边 $E'=(e_{pj})_{i,j=1}^v$ 。

$$e_{pj} = \begin{cases} 1, & C(Z_p, Z_j) < \alpha \\ 0, & C(Z_p, Z_j) > \alpha \end{cases} \quad (17)$$

其边权重为:

$$A_{pj} = C(Z_p, Z_j) \quad (18)$$

于是得到新的网络图 $G'=(V, E', A')$ 。网络图的具体搭建过程如图 2 所示。图中的黑色表示目标节点,连线表示边的关系,连线的粗细表示边权重的大小。




图2 网络图搭建流程

Fig. 2 Network diagram building flowchart

3 基于 GMM 和 GRU 的时空综合预测模型

3.1 GMM

GMM 是一种基于图的卷积操作,旨在更好地捕捉图中

节点间的复杂关系^[16]。其使用高斯混合模型来表示节点及其邻居的特征分布,每个节点与其邻居特征的组合使用多个高斯分布来建模,这允许网络能从不同的群体中捕获特征^[17]。且在计算节点的特征时,GMM 会对节点及其邻居的特征进行聚合,通过使用高斯混合模型的权重来加权这些特征,有效地聚焦于最重要的信息,具有很强的灵活性和表达能力,特别适用于多风力机风电功率特征这类多维复杂图数据。其具体步骤如下:

1) 搭建权重函数。函数计算每个边的特征对于第 k 个高斯核的权重。定义基于可训练的均值向量 μ_k 和对角协方差矩阵 Σ_k 的权重函数 $w_k(e)$ 。

$$w_k(e) = \exp\left(-\frac{1}{2} (e - \mu_k)^T \Sigma_k^{-1} (e - \mu_k)\right) \quad (19)$$

2) 计算更新后的节点特征向量。对于每个节点 p ,对其邻居节点 $j \in N(p)$ 进行特征聚合。使用 3 个高斯核,通过边 e_{pj} 计算每个高斯核的权重 $w_k(e_{pj})$ 。最后由各高斯核的线性变换结果的加权聚合对所有邻居求平均得到节点特征向量 x'_p 。

$$x'_p = \frac{1}{|N(p)|} \sum_{j \in N(p)} \frac{1}{K} \sum_{k=1}^K w_k(e_{pj}) \odot \theta_k x_j \quad (20)$$

3.2 GRU

GRU 是一种循环神经网络,用于处理顺序数据,如自然语言、语音、视频等。GRU 的特点是使用两个门控结构,分别为重置门和更新门,来控制信息的流动和记忆,并能有效解决梯度消失的问题,保留长期依赖的信息,提高模型的性能。该网络用于提取时间相关性方面的信息^[18]。其步骤如下:

1) 计算更新门和重置门的值。更新门用于控制上一时刻的隐藏状态有多少保留到当前时刻,重置门用于控制上一时刻的隐藏状态有多少参与到当前时刻的计算。

$$\begin{cases} z_t = \sigma(U_z [h_{t-1}, x_t] + b_z) \\ r_t = \sigma(U_r [h_{t-1}, x_t] + b_r) \end{cases} \quad (21)$$

式中: z_t 和 r_t ——更新门和重置门的值; σ ——sigmoid 激活函数,用来方便计算梯度和反向传播; U_z 和 U_r ——权重矩阵; b_z 和 b_r ——偏置向量; h_{t-1} ——上一时刻的隐藏状态; x_t ——当前时刻的输入。

2) 计算候选隐藏状态,即当前时刻的输入和重置后的上一时刻的隐藏状态经过一个 tanh 激活函数的输出。

$$\tilde{h}_t = \tanh(U_h [r_t \odot h_{t-1}, x_t] + b_h) \quad (22)$$

式中: U_h ——权重矩阵; b_h ——偏置向量; $\odot$ ——逐元素相乘的操作。

3) 计算当前时刻的隐藏状态,即上一时刻的隐藏状态和候选隐藏状态的加权平均,权重由更新门决定。

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (23)$$

式中: h_t ——当前时刻的隐藏状态; z_t ——更新门的值; $\tilde{h}_t$ ——候选隐藏状态。




图3 GRU原理

Fig. 3 Principle of GRU

上述过程表示了通过门控循环单元来更新每个时刻的隐藏状态,从而捕捉顺序数据中的长期依赖和复杂模式。如图3为GRU的输入输出结构,有一个当前的输入 x_t ,和上一个节点传递下来的隐状态 h_{t-1} ,这个隐状态包含了之前节点的相关信息。结合 x_t 和 h_{t-1} ,GRU会得到当前隐藏节点的输出 y^t 和传递给下一个节点的隐状态 h_t 。

4 PXGBoost-GAE-GMM-GRU多风力机功率预测模型

基于GMM和GRU的预测模型学习多风力机各个特征间时空相关性和风向时空相关性来实现不同预测时域下的多站点本地功率预测。本文提出的GMM-GRU网络模型结构如图4所示,模型中GMM部分主要负责特征提取,GRU网络主要负责负荷预测。GMM设计有2层卷积层(GMMConv),依次经过聚合和更新两个操作。在GRU网络部分,经过实验发现通过增加GRU网络单元来增加模型的深度有助于提高模型的预测能力,因此本文提出的最终模型包含了2层GRU网络层,各层的神经元数量均为128。在每层GRU网络层间采用随机失活方法防止模型过拟合。最后通过全连接层输出指定格式的向量,即风电功率预测值。




图4 GMM-GRU网络模型结构

Fig. 4 Network model structure of GMM-GRU

使用PXGBoost算法对节点的风向数据、风速信息、温度信息和气压信息等特征数据进行筛选,用图自编码器和余弦

相关性融合的方法获得边信息搭建网络图。最后通过基于GMM和GRU的预测模型实现多风力机功率预测。整体模型结构如图5。




图5 PXGBoost-GAE-GMM-GRU模型结构

Fig. 5 Structure of PXGBoost-GAE-GMM-GRU model

1)使用PXGBoost算法构成的特征筛选网络得到特征数据矩阵 W ,以矩阵 W 作为图 $G=(V, E, A)$ 中 V 的节点。

2)采用GAE对预设图 $G=(V, E, A)$ 进行聚合更新得到节点嵌入向量,计算余弦相似度对节点嵌入向量进一步学习修改边,最后得到GMM的输入图 $G'=(V, E', A')$ 。

3)将网络图 $G'=(V, E', A')$ 作为GMM-GRU网络的输入。

5 仿真及结果分析

5.1 数据集和设置

5.1.1 数据来源及数据处理

该数据集是中国6个风电场两年(2019年、2020年)以15 min为间隔的采样数据,其中包括天气状况和发电信息。其来源于中国国家电网可再生能源发电预测数据集。预处理数据集的大小设置为5000,训练集、验证集和测试集的比例设置为6:2:2。表1描述了每个站点的数据集特征。

表1 站点数据集分类

Table 1 Classification of site datasets

类别	特征
气象特征	气压、相对湿度、温度、云量、降水
风特征	10 m 风速、10 m 风向、30 m 风速、30 m 风向、50 m 风速、50 m 风向、风力机轮毂处的风速、风力机轮毂处的风向
辐射特征	辐照度
能源特征	功率

5.1.2 实验设备

本实验基于Tensorflow2.10.0框架的Python 3.10语言实

现, 利用统一计算设备架构 (compute unified device architecture, CUDA) 加速, 仿真硬件平台设置: CPU 为 Intel Core i7-10875H 2.30 GHz, 内存 RAM 为 32 GB, GPU 为 Nvidia GeForce RTX 2070。

5.1.3 误差评估标准

针对基于网络图输入的风电场风电功率预测, 利用均方误差 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE)、归一化平均绝对误差 (root mean squared error, RMSE)^[19] 和归一化平均绝对误差 (mean absolute percentage error, MAPE)^[20] 等指标对其有效性进行了评价。

$$E_{\text{MSE}} = \frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2 \quad (24)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2} \quad (25)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{k=1}^n |y_k - \hat{y}_k| \quad (26)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{k=1}^n \left| \frac{y_k - \hat{y}_k}{y_k} \right| \times 100\% \quad (27)$$

式中: n ——样本数量; y_k ——第 k 个观测值; $\hat{y}_k$ ——第 k 个预测值。MSE 和 RMSE 衡量模型的拟合程度, 较小的值表示更好的性能和更低的预测误差, 它们对异常值敏感, 可反映预测误差的分布。MAE 是预测值与真实值之间绝对差的平均值, 它不受异常值影响, 提供了预测准确性的稳健衡量标准。MAPE 不受异常值影响, 提供了不同数据点相对误差的洞察。MSE 和 RMSE 通常用于评估模型性能, MAE 和 MAPE 提供了考虑异常值的替代视角评价。

5.2 实例仿真分析

5.2.1 特征选取

风电功率受到风速、风向、温度和湿度等多种因素共同影响, 为消除特征间的冗余性和相关性, 本文使用基于 PXGBoost 的特征筛选网络对初始特征集进行数据降维, 保留对风电功率预测影响最大的特征。

PSO 算法的参数设定如下: 迭代次数为 50 次, 加速常数 c_1 和 c_2 均设置为 2, 惯性因子 ω 设置为 0.9。寻优范围如下, 树的最大深度 5~20, 学习率 0.01~0.30, 树的数量 50~200。适应度迭代曲线如图 6 所示。最终得到的 PSO-XGBoost 的最优超参数组合如表 2 所示。

为提高模型的鲁棒性, 本文对各特征进行标准化处理, 将不同量纲的特征映射到同一尺度范围, 以确保模型能更有效地学习各特征之间的关系。本文选取风力机轮毂处的风速、50 m 高度的风速、30 m 高度的风速、温度和湿度这 5 个重要特征, 特征重要性如图 7 所示。其余特征也有一定相关性, 但相比重要特征, 影响可忽略不计。




图6 PSO算法适应度迭代曲线

Fig. 6 Fitness iteration curve of PSO algorithm

表2 PSO-XGBoost 最优超参数组合

Table 2 Optimal hyperparameter combination of PSO-XGBoost

超参数	含义	最优数值
max_depth	树最大深度	10
learning_rate	学习率	0.178
n_estimators	树的数量	73
加速常数 c_1, c_2	个体与群体学习因子	2, 2
惯性因子 ω	粒子的搜索能力	0.9

特征	风力机轮毂处的风速	0.4262
	50 m高度的风速	0.2331
	30 m高度的风速	0.1871
	气温	0.1455
	相对湿度	0.1273
	风力机轮毂处的风向	0.0857
	气压	0.0587
	10 m高度的风速	0.0432
	50 m高度的风向	0.0112

图7 特征重要度

Fig. 7 Score of feature importance

5.2.2 预测结果分析

GAE-GMM-GRU 模型集成了多种神经网络算法, 该模型具有较强的鲁棒性和泛化能力。仅使用 Pearson 相关系数构建的模型 (PR-GMM-GRU) 依赖于构建网络图的相关阈值方法虽然简洁, 但缺乏 GAE-GMM-GRU 模型固有的适应性和复杂性。本文对这两种模式进行了评估如表 3 所示, 以评估不同地点功率预报的稳定性。特别是在稳定性方面, GAE-GMM-GRU 模型始终优于单相关阈值模型。此外, GAE-GMM-GRU 模型在不同的数据集上显示出稳健的预测质量。本文研究强调了构建捕获风电功率特征之间复杂关系的图表的关键作用。通过在此图中嵌入层理向量, 提高了功率预

测的准确性。

表3 图构建的误差指标

Table 3 Error indicators for graph construction

误差	PR-GMM-GRU	GAE-GMM-GRU
MSE/MW	19.8968	7.7851
RMSE/MW	4.4606	2.7902
MAE/MW	2.5933	2.6851
MAPE	1.0692	0.2283

由图8可看出GAE通过图自编码器学习节点嵌入向量,能捕提高维特征空间中的非线性关联,结合余弦相似度动态调整边权重,更贴近实际风场中“远距离站点可能因气象模式相似而相关”的特性。且其误差曲线更平稳,且整体误差显著降低,表明GAE构建的网络图能有效刻画复杂空间依赖,提升预测稳定性。而皮尔逊相关系数构图仅能捕捉线性相关性,无法刻画复杂非线性关系。图8中,其误差曲线波动较大,尤其在风速剧烈变化的100~200时段,反映出传统静态图模型对动态复杂关联的捕捉不足。





图8 图构建的误差

Fig. 8 Error in graph construction

总的来说实际风电场中,气象条件随时间动态演化,站点间的相关性并非固定不变。GAE通过迭代学习节点嵌入向量,能适应这种动态变化,而皮尔逊相关系数依赖历史数据统计的静态阈值,无法实时更新关联强度,导致预测误差在极端天气下显著增。图9是两种模型构建的图网络。该图共有36个节点,分为6个相应的组即6个风电场,每个特征被描述为一个节点。由图9可看出皮尔逊相关系数网络图的边数较少、节点密度低,连接主要集中在近距离节点和强线性相关特征,但忽略了跨风电场、跨特征的潜在关联。而实际风电场中,机组功率不仅受本地风速影响,还可能受周边站点尾流效应、区域气象系统的影响。皮尔逊相关系数因仅依赖单一线性指标,无法捕捉此类“跨区域、多特征耦合”的关联,导致模型在整合空间信息时存在偏差。对比下来GAE构建的网络图边数更多、节点密度高,且存在跨风电场的长距离连接。由此看出GAE通过节点嵌入向量学习,自动识别对功率预测关键特征,并强化其与其他特征的连接。

风电场 1 2 3 4 5 6



皮尔逊相关性搭建的网络图

风电场 1 2 3 4 5 6



GMM和余弦相似度搭建的网络图

图9 不同方法搭建网络图的拓扑图

Fig. 9 Topology of network diagram constructed by different methods

如图10所示的消融实验结果表明,引入PXGBoost特征筛选前(灰色实线)的功率预测在多处高峰和波谷位置出现明显偏差:例如在150~200时段区间,未加入PXGBoost特征筛选的预测曲线(灰色实线)对实际功率(黑色实线)在70 MW以上的峰值存在明显高估;在650和750时段附近,则存在低估或峰值错位情况。相比之下,加入PXGBoost特征筛选后的预测结果(黑色虚线)能更精确跟踪实际功率




图10 消融实验结果

Fig. 10 Ablation experiment results




图11 各类风功率预测模型的误差对比

Fig. 11 Error comparison of different wind power forecasting models

的波动,不论是陡峭上升过程还是快速衰减阶段,蓝色曲线均与黑色曲线保持较小的偏差,且能准确捕捉高频小幅的功率起伏。整体来看,PXGBoost 特征筛选显著提升了模型对关键影响因子的判别能力,从而在整个样本区间显著改善了预测拟合度和稳健性。

为进一步验证 GMM-GRU 神经网络的有效性,将其与近

期一些风电功率预测模型进行对比:CNN-LSTM^[21]、GAT-GRU^[22]和 Gr-GRU^[23]。对于这些模型,本文 TensorFlow 2.10.0 框架构建了训练网络。使用 40 天的测试集对每个风电场的风电功率预测进行了评估,采用 4 个关键指标 MSE、RMSE、MAE 和 MAPE 来测评结果。不同神经网络模型预测的误差指标如表 4。

表 4 图神经网络的误差指标

Table 4 Error metrics for graphical neural networks

误差	CNN-LSTM	VMD-CNN-GRU	GAT-GRU	Gr-GRU	GAE-GMM-GRU
MSE/MW	89.4535	74.9595	27.1079	26.5891	7.7851
RMSE/MW	9.4580	8.6579	5.2065	5.1565	2.7902
MAE/MW	5.9025	5.1144	3.2044	3.0652	2.6851
MAPE	3.3782	1.2297	1.9543	0.9822	0.2283

从表 4 中可见,本文提出的 GAE-GMM-GRU 模型在所有关键误差指标上均取得了显著提升,其中相对于次优的 Gr-GRU 模型,MSE 从 26.5891 MW 降低至 7.7851 MW,下降比例约 70.7%;RMSE 由 5.1565 MW 降至 2.7902 MW,下降约 45.9%;MAE 由 3.0652 MW 降至 2.6851 MW,减少约 12.4%;MAPE 则由 0.9822 骤降至 0.2283,降低幅度达 76.8%。这一系列降幅表明,GAE 与 GMM 在捕获多风力机间复杂空间关联和抑制异常波动方面发挥了核心作用,显著削减了整体偏差。从图 11 的预测曲线也可观察到,GAE-GMM-GRU 模型在各种工况下均展现出更好的拟合效果和波动追踪能力,验证了三大模块协同提取时空特征的互补增益。

6 结 论

本文提出一种基于 PSO 优化的 XGBoost-GAE-GMM-GRU 风电功率预测模型,以提高风电功率的预测精度。通过对风电场数据集的实验验证,本文方法取得了以下成果和结论:

首先,通过 PXGBoost 筛选的 5 个核心特征,使模型输入维度从原始 20 多个特征缩减至 5 维,避免了冗余特征对预测的干扰。其次,本文通过图自编码器和余弦相似度的方法构建网络图,能有效捕捉站点之间的远距离相关性,使 MSE 从 19.8968 MW 降至 7.7851 MW,预测精度提升 60%,弥补了传统基于皮尔逊相关系数的静态图构建方法在复杂环境下的不足。最后,GMM-GRU 模型能深入提取图结构的时空特征并结合时间特性,实现了特征间时空相关性的高效整合,从而提高了预测的准确性。

通过与其他模型的对比实验,本研究提出的方法在短期风电功率预测中表现出优越的性能。实验结果表明,在相同的数据集和实验条件下,本文模型的 MAE 和 RMSE 指标明显优于传统的统计模型和其他机器学习模型。未来的研究

可进一步优化图结构的构建方法,例如引入更多的气象特征以及探索动态网络图的构建,以进一步提升风电功率预测的性能。

[参考文献]

- [1] 刘旺,邢晓帆,王戎.全球陆地风能发电潜力的历史变化及未来预测[J].北京大学学报(自然科学版),2023,59(5): 833-842.
LIU W, XING X F, WANG R. Historical trend and future projections of global on-shore wind power generation potential [J]. Acta scientiarum naturalium universitatis pekinensis, 2023, 59(5): 833-842.
- [2] 陈子含,滕伟,胥学峰,等.基于图卷积网络和风速差分拟合的中长期风功率预测[J].中国电力,2023,56(10): 96-105.
CHEN Z H, TENG W, XU X F, et al. Medium and long term wind power prediction based on graph convolutional network and wind velocity differential fitting [J]. Electric power, 2023, 56(10): 96-105.
- [3] 晏昊宇歆,张海波,刘童蕙,等.基于损失函数改进和补丁时序 Transformer 网络的风功率超短期多步预测[J].太阳能学报,2025,46(6): 510-521.
YAN W Y Y, ZHANG H B, LIU T H, et al. Ultra-short-term multi-step prediction of wind power based on loss function improvement and patch timing transformer network [J]. Acta energiae solaris sinica, 2025, 46(6): 510-521.
- [4] 曹俊波,周任军,邓学华,等.考虑优化 ARIMA 模型差分次数的风功率预测[J].电力系统及其自动化学报,2019,31(1): 105-111.
CAO J B, ZHOU R J, DENG X H, et al. Wind power forecast considering differential times of optimal ARIMA

- model[J]. Proceedings of the CSU-EPSC, 2019, 31(1): 105-111.
- [5] 刘震, 刘丹, 王彦文, 等. 基于多元回归-ARIMA-卡尔曼组合模型的风电功率超短期预测[J]. 风能, 2018(6): 74-78.
- LIU Z, LIU D, WANG Y W, et al. Ultra-short-term wind power forecasting based on multiple regression-ARIMA-Kalman combined model [J]. Wind energy, 2018(6): 74-78.
- [6] 符杨, 郑紫宸, 时帅, 等. 考虑气象相似性与数值天气预报修正的海上风功率预测[J]. 电网技术, 2019, 43(4): 1253-1259.
- FU Y, ZHENG Z C, SHI S, et al. Offshore wind power forecasting considering meteorological similarity and NWP correction [J]. Power system technology, 2019, 43(4): 1253-1259.
- [7] 王帅党, 程鹏. 基于GWO优化BiLSTM模型的地区短期风功率的预测[J]. 黑龙江科学, 2023, 14(16): 28-31, 35.
- WANG S D, CHENG P. Prediction of BiLSTM model based on GWO for regional short-term wind power prediction [J]. Heilongjiang science, 2023, 14(16): 28-31, 35.
- [8] 李进友, 李媛, 黄露秋, 等. 基于XGBoost-GRNN算法的分段式风功率预测[J]. 计算机集成制造系统, 2025, 31(10): 3831-3845.
- LI J Y, LI Y, HUANG L Q, et al. Piecewise wind power forecast based on XGBoost-GRNN algorithm [J]. Computer integrated manufacturing systems, 2025, 31(10): 3831-3845.
- [9] 付波, 李昊, 权轶, 等. 基于SHAP重要性排序和时空双流的多风场超短期功率预测[J]. 重庆理工大学学报(自然科学), 2024, 38(5): 249-258.
- FU B, LI H, QUAN Y, et al. Ultra-short-term power forecasting for multiple wind fields based on SHAP importance ranking and spatio-temporal dual flow [J]. Journal of Chongqing University of Technology (natural science), 2024, 38(5): 249-258.
- [10] 赵泽妮, 云斯宁, 贾凌云, 等. 基于统计模型的短期风能预测方法研究进展[J]. 太阳能学报, 2022, 43(11): 224-234.
- ZHAO Z N, YUN S N, JIA L Y, et al. Recent progress in short-term forecasting of wind energy based on statistical models [J]. Acta energiae solaris sinica, 2022, 43(11): 224-234.
- [11] AHMED U, MUHAMMAD R, ABBAS S S, et al. Short-term wind power forecasting using integrated boosting approach [J]. Frontiers in energy research, 2024, 12: 1401978.
- [12] 梁超, 刘永前, 周家慷, 等. 基于卷积循环神经网络的风电场内多点位风速预测方法[J]. 电网技术, 2021, 45(2): 534-541.
- LIANG C, LIU Y Q, ZHOU J K, et al. Wind speed prediction at multi-locations based on combination of recurrent and convolutional neural networks [J]. Power system technology, 2021, 45(2): 534-541.
- [13] 赵子琪, 杨斌, 张远广. 基于图自编码器和GRU网络的分层交通预测模型[J]. 计算机科学, 2024, 51(S1): 680-685.
- ZHAO Z Q, YANG B, ZHANG Y G. Hierarchical traffic flow prediction model based on graph autoencoder and GRU network [J]. Computer science, 2024, 51(S1): 680-685.
- [14] KIPF T N, WELING M. Variational graph auto-encoders [EB/OL]. 2016; arXiv: 1611.07308. <https://arxiv.org/abs/1611.07308>
- [15] JI Shan, 姜巍, 景鑫. 基于余弦相似度和图卷积网络的电力负荷预测方法[J]. 浙江电力, 2025, 44(1): 68-75.
- JI S, JIANG W, JING X. A power load forecasting method using cosine similarity and a graph convolutional network [J]. Zhejiang electric power, 2025, 44(1): 68-75.
- [16] BISHOP C M. Pattern recognition and machine learning [M]. New York: Springer, 2006.
- [17] 汪鸿翔, 柳培忠, 骆炎民, 等. 高斯核函数卷积神经网络跟踪算法[J]. 智能系统学报, 2018, 13(3): 388-394.
- WANG H X, LIU P Z, LUO Y M, et al. Convolutional neural network tracking algorithm accelerated by Gaussian kernel function [J]. CAAI transactions on intelligent systems, 2018, 13(3): 388-394.
- [18] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(S2): 1-6, 26.
- YANG L, WU Y Q, WANG J L, et al. Research on recurrent neural network [J]. Journal of computer applications, 2018, 38(S2): 1-6, 26.
- [19] 文洁. MSE与MAE对机器学习性能优化的作用比较[J]. 信息与电脑, 2018, 30(15): 42-43.
- WEN J. Comparison of the effects of MSE and MAE on machine learning performance optimization [J]. Information & computer, 2018, 30(15): 42-43.
- [20] 常振成, 游国栋, 肖梓跃, 等. 基于VMD-MBWO-KELM的短期风电功率预测[J]. 太阳能学报, 2025, 46(6): 623-631.
- CHANG Z C, YOU G D, XIAO Z Y, et al. Short-term wind power forecasting based on VMD-MBWO-KELM [J]. Acta energiae solaris sinica, 2025, 46(6): 623-631.
- [21] 陆继翔, 张琪培, 杨志宏, 等. 基于CNN-LSTM混合神

- 经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.
- LU J X, ZHANG Q P, YANG Z H, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of electric power systems, 2019, 43(8): 131-137.
- [22] 刘会家, 滕杰, 冯铃, 等. 基于GAT-GRU的高渗透率分布式新能源接入的配电网无功优化[J]. 现代电力, 2025, 42(3): 531-541.
- LIU H J, TENG J, FENG L, et al. GAT-GRU based reactive power optimization for distribution networks with high-penetration distributed renewable energy [J]. Modern electric power, 2025, 42(3): 531-541.
- [23] 殷豪, 李奕甸, 谢智锋, 等. 混合图神经网络和门控循环网络的短期光伏功率预测[J]. 太阳能学报, 2024, 45(3): 523-532.
- YIN H, LI Y D, XIE Z F, et al. Short-term photovoltaic power prediction method based on mixed graph neural network and gated recurrent unit network [J]. Acta energiae solaris sinica, 2024, 45(3): 523-532.

MULTI-WIND POWER FORECASTING BASED ON PSO-OPTIMIZED XGBoost-GAE-GMM-GRU MODEL

Peng Yirao¹, Guan Xinyu², Li Qiangren², Li Chunhua², Lei Aihu², He Dejun²

(1. College of Electrical Engineering, Guangxi University, Nanning 530004, China)

2. State Grid Gansu Power Company Baiyin Power Supply Company, Baiyin 730900, China)

Abstract: Wind power forecasting is a crucial topic in the field of wind energy generation. With the increasing penetration of renewable energy in power systems, wind energy, as a rapidly developing renewable resource, necessitates accurate short-term forecasting for the energy industry. In this paper, a Gaussian Mixture Model-gated Recurrent Unit (GMM-GRU) based on Gaussian graph convolution is proposed. Firstly, the XGBoost algorithm optimized by Particle Swarm Optimization (PSO) is utilized to construct a feature selection network for identifying important features. Secondly, using the graph auto-encoder and cosine correlation fusion method, a network graph to effectively capture the potential long-distance correlations among sites and accurately describe the spatial correlation of multi-site features are built. Finally, the Gaussian Mixture Model (GMM) is employed to deeply extract the intrinsic relationships within the network graph, and the Gated Recurrent Unit (GRU) integrates its spatio-temporal correlations to address the power forecasting problem. The experiments on real wind farm data are carried out. The comparisons with other models demonstrate that the proposed model significantly enhances wind power forecasting performance.

Keywords: wind power forecasting; graph autoencoder; Gaussian mixture models; recurrent neural networks; PSO-XGBoost