文章编号:1674-7607(2026)02-0080-09 DOI:10.19805/j.cnki.jcspe.2026.240699

基于特征相似日和CNN-BiLSTM-Attention模型的风电短期出力预测

栾福明[1,2], 张 衡[1], 陈海平[1]
(1. 华北电力大学 能源动力与机械工程学院, 北京 102206;
2. 中国大唐集团科学技术研究总院有限公司华北电力试验研究院, 北京 100040)

摘 要: 短期风电功率预测对电力系统的实时调度至关重要,可靠的风电预测不仅能够保障电力系统的安全运行,还能提升电网的运行效率。为了获得更加准确、可靠的风电功率预测结果,针对风电功率数据的非线性和时序性特征,提出了一种将特征相似日和CNN-BiLSTM-Attention相结合的短期风电功率预测方法。首先,充分考虑气象因素对风电输出功率数据的影响,利用Spearman相关系数筛选出与风电输出功率最相关的气象因子作为模型的输入参数。其次,采用高斯混合模型(GMM)对风电数据进行聚类分析,通过手肘法确定最佳的聚类簇数,并结合特征相似度和余弦相似熵方法,确定待测日与历史数据中最相关的聚类类型。最后,使用CNN-BiLSTM-Attention模型进行训练,深度挖掘风电功率的时序特征,获得更加精准的风电功率预测结果。以新疆地区的实际风电功率数据为例进行了仿真分析,验证结果表明该方法的预测精度较高,能够为电力系统的规划与稳定运行提供有力支持。

关键词: 风电功率; 卷积神经网络; 双向长短期记忆网络; 注意力机制; 电力系统
中图分类号: TK81 **文献标志码:** A **学科分类号:** 480.60

Short-term Wind Power Output Prediction Based on Feature Similarity Day and CNN-BiLSTM-Attention Model

LUAN Fuming[1,2], *ZHANG Heng*[1], *CHEN Haiping*[1]
(1. School of Energy Power and Mechanical Engineering, North China Electric Power University, Beijing 102206, China; 2. North China Electric Power Test and Research Institute, China Datang Corporation Science and Technology General Research Institute Co., Ltd., Beijing 100040, China)

Abstract: Short-term wind power forecasting is crucial for real-time dispatch of power systems. Reliable wind power forecasts not only ensure the safe operation of power system but also enhance the operational efficiency of power grid. To obtain more accurate and reliable wind power forecasting results, considering the nonlinear and time-series characteristics of wind power data, a short-term wind power forecasting method based on feature similarity day combined with CNN-BiLSTM-Attention was proposed. Firstly, the impact of meteorological factors on wind power output was fully considered, and the Spearman correlation coefficient was used to select the meteorological factors most correlated with wind power output as model input parameters. Next, the Gaussian mixture model (GMM) was used to conduct cluster analysis on the

收稿日期: 2024-11-11 **修订日期:** 2025-01-09
基金项目: 华北电力大学中央高校基本科研业务费专项资金(2023MS028);国家重点研发计划资助项目(2022YFB2403200)
作者简介: 栾福明(1981—),男,新疆乌鲁木齐人,博士研究生,研究方向为清洁能源利用理论与技术,E-mail:28155819@qq.com。

wind power data. The elbow method was used to determine the optimal number of clusters, and in combination with the feature similarity and cosine similarity entropy methods, the most relevant cluster type for the day under test was determined among the historical data. Finally, the CNN-BiLSTM-Attention model was used for training to deeply extract the temporal features of wind power and obtain more accurate wind power prediction results. Taking the actual wind power data of Xinjiang region as an example, a simulation analysis was conducted. The verification results show that the prediction accuracy of the method is high, and it can provide strong support for the planning and stable operation of the power system.

Key words: wind power; convolutional neural network; bidirectional long short-term memory network; attention mechanism; power system

近年来，随着“碳达峰”、“碳中和”目标的制定[1]，风电产业得到了前所未有的巨大发展，成为推动新能源发展的重要支柱之一。然而，随着大规模风电的并网运行，风能的间歇性和波动性问题日益凸显，不稳定的风电出力特性给电力系统的调度带来了巨大挑战[2]。因此，如何有效提高风电预测的准确性，减轻风电波动性对电力系统的影响，已经成为新型电力系统发展中亟需解决的关键任务。

目前，国内外学者在风电预测领域进行了大量的研究，并取得了显著的进展。短期风电预测模型主要涵盖物理模型和统计模型2种[3]。物理模型主要依靠数值天气预报(NWP)、地形及风电场布局等因素来预测未来风电功率。文献[4]指出物理模型对气象等数据的依赖性强、抗干扰和可移植能力弱。相比之下，统计模型基于历史数据和风电功率的时序特性，采用数据驱动的方法进行风电预测，涵盖时间序列模型、机械学习模型和深度学习模型这三种方法。时间序列分析利用大量历史数据来预测未来风速变化[5]。文献[6]通过小波去噪处理风电数据，建立自动回归滑动平均模型(ARMA)，进行短期风电功率预测，但ARMA模型对非线性时间序列数据的预测效果不佳。文献[7]提出了一种改进差分自回归移动平均模型(ARIMA)，进行风电功率预测，优化了风功率时间序列的平稳性。近年来，深度学习模型在风电预测领域得到了广泛应用[8]，特别是在处理波动性较大的数据时表现出较好的预测性能，常用的模型有循环神经网络(RNN)、卷积神经网络(CNN)[9]和长短期记忆网络(LSTM)[10]等，但此类模型通常需要大量精确的运行数据，限制了它们在数据收集不完整时的应用。

为了克服单一模型的局限性，许多优化的组合模型逐渐被提出。文献[11]利用风电数据特征计算综合相似日，并结合改进粒子群优化算法和长短期记忆网络(PSO-LSTM)对风电功率进行预测，但相似度参数设置具有偶然性，可能会影响预测结果的稳定性和准确性。文献[12]提出了一种基于卷积神经网络-长短期记忆神经网络(CNN-LSTM)的规划阶段风电场发电功率预测模型，模拟结果表明该模型在预测能力和适用性方面表现出色。随着LSTM模型的发展，双向长短期记忆网络(BiLSTM)作为传统LSTM模型的扩展应运而生[13]。文献[14]提出了一种基于自适应二次模态分解、卷积神经网络与双向长短期记忆网络的超短期风电功率预测模型，有效降低了风电功率波动性对预测结果的影响，提高了模型的预测精度。此外，在风电预测的研究中，聚类方法得到了广泛应用。文献[15]提出了一种基于谱聚类和多元变分模态分解的人工神经网络风电出力预测方法，利用该方法对不同机组功率信息进行分类，并结合变分模态分解对信息进行分解，克服了神经网络的不稳定性和过拟合风险。文献[16]利用闭环聚类算法结合Bootstrap方法对风电场进行分类，并随机抽取样本训练卷积神经网络模型，从而提高了功率预测的精度。

上述方法主要从改进预测模型的角度进行考虑，未充分考虑气象数据与风电功率之间的相似性，这种忽视可能导致模型无法全面捕捉气象因素对风电功率的复杂影响，进而限制预测精度的进一步提升。针对以上局限，本文结合风电运行数据中的气象特征，提出了一种基于特征相似日和CNN-BiLSTM-Attention的短期风电功率预测方法。考虑气象因素对风电输出功率数据的影响，首先，利用Spearman相关系数筛选出与风电输出最相关的气象因子。其次，采用高斯混合模型(GMM)对风电数据进行聚类分析，通过手肘法确定最佳的聚类簇数，并结合特征相似度和余弦相似熵(CSE)计算结果，确定待测日与历史数据中形状和大小最相似的聚类类型。最后，利用CNN-BiLSTM-Attention模型对待测日对应最佳风电功率簇的时序特征进行深

度挖掘，获得更加精准的风电功率预测结果。

1 风电功率的影响因素

基于历史实测数据，包括测风塔 10、30、50、70 m 及轮毂高度的风速、风向以及温度、气压、湿度等气象因子，本文深入分析了气象条件对风电出力的影响。通过计算 Spearman 相关系数，评估不同气象因子与风电机组发电功率之间的相关性，从中选择相关性较高的气象因子作为每个自然日的气象指标。

1.1 Spearman 相关系数

Spearman 相关系数(R)是一种用来评估两个连续变量之间关系的非参数统计方法[17]，通过计算变量之间的相关性来衡量两者的关联程度，可表示为

$$R=\frac{\sum_{i=1}^{n}(x_i-\bar{x})(y_i-\bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i-\bar{x})^2\sum_{i=1}^{n}(y_i-\bar{y})^2}} \tag{1}$$

式中：n 为数据集的观测值数量；x_i 为气象因素；y_i 为风电发电功率；$\bar{x}$、$\bar{y}$ 分别为气象因子和风电发电功率的平均值。

$$R=\begin{cases}0\sim0.2 & \text{极弱相关或无相关}\\ >0.2\sim<0.4 & \text{弱相关}\\ 0.4\sim0.6 & \text{中等相关}\\ >0.6\sim<0.8 & \text{强相关}\\ 0.8\sim1.0 & \text{极强相关}\end{cases} \tag{2}$$

1.2 相关性分析

针对气象因子与风电输出功率的相关性分析，采用 Spearman 相关系数进行计算，可以得出风电输出功率与各气象因子之间的相关性 R 值。由图 1 可见，风电输出功率与风速之间的相关性显著高于其他气象因子，这主要是因为风速直接影响风电机组叶片的旋转速度，风速增加会增强叶片的推动力，从而提升风电机组的发电功率，需要注意的是，风速与发电功率之间并非线性关系。在风速达到切入风速后，功率随风速增加而提升，直到风速达到额定风速，此时功率趋于稳定。超过额定风速后，风电机组进入切出风速范围，系统会限制功率输出，以保护设备。同时，进一步分析不同高度的风速与发电功率的相关性可以发现，距地面越高，风速与发电功率的相关性越强，这是因为较高处的风速更接近风电机组的实际运行环境，能够更准确地反映风电机组的实际发电情况。此外，风电输出功率和风向、温度、气压和湿度的 R 值分别为 −0.41、−0.02、−0.15 和 −0.01，表明风电输出功率与风向呈中等相关，而与温度、气压和湿度的相关性极弱。因此，本文选取了中等及以上相关性的气象因子作为模型气象特征。

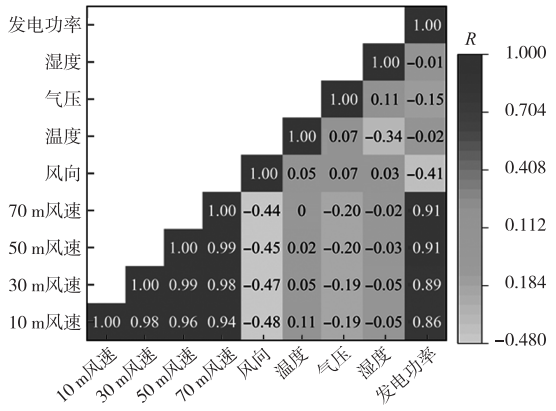


图 1 风电输出功率与气象因子相关性热力图

Fig. 1 Correlation heat map between wind power output and meteorological factors

2 基于 GMM 的特征相似日选取方法

2.1 GMM

高斯混合模型是一种基于概率模型的方法[18]，主要应用于聚类分析、图像分割等领域。GMM 利用高斯概率函数精确量化事物，其原理是任意的概率密度分布都可通过若干个正态分布的线性组合逼近得到。高斯混合模型的概率密度函数可表示为

$$p(\boldsymbol{x})=\frac{1}{(2\pi)^{\frac{n}{2}}|\sum|^{\frac{1}{2}}}\mathrm{e}^{-\frac{1}{2}(\boldsymbol{x}-\mu)^{\mathrm{T}}\sum^{-1}(\boldsymbol{x}-\mu)} \tag{3}$$

$$p_M(\boldsymbol{x})=\sum_{i=1}^{k}\alpha_i\cdot p(\boldsymbol{x}|\mu_i,\ \sum_i) \tag{4}$$

式中：$\boldsymbol{x}$ 为输入向量；μ 为高斯分布均值；$\sum$ 为高斯分布协方差矩阵；k 为混合成分个数；α_i 为混合系数；$p(\boldsymbol{x})$ 为 n 维高斯(正态)分布的概率密度函数；$p_M(\boldsymbol{x})$ 为高斯混合模型的总体概率密度函数；$p(\boldsymbol{x}|\mu_i,\ \sum_i)$ 为第 i 个高斯分量的概率密度函数。

GMM 训练采用期望最大化算法，其算法步骤如下：

(1) 初始化：根据已知数据的聚类中心，确定 GMM 中各个高斯密度分布的初始参数值。

(2) 期望步：计算每个样本属于第 j 个高斯模型的后验概率。

(3) 最大化步骤(M 步)：通过最大化样本数据的似然函数期望，计算得到新的 GMM 参数，用于下一次迭代。

(4) 停止条件：不断重复执行期望步骤(E 步)和最大化步骤(M 步)，直到算法收敛，获得 GMM

的最终参数；如果尚未收敛，则继续重复(2)～(4)步骤。

2.2　聚类有效性评价

误差平方和(SSE)是手肘法的核心指标，用于衡量每个簇内数据的聚合程度[19]。簇内聚合程度越高，误差平方和越小。随着簇数的增加，簇内数据的聚合会更加精细，误差平方和逐渐减小。在簇数小于实际最佳簇数时，增加簇数会显著降低误差平方和；而达到实际簇数后，继续增加簇数，误差平方和的下降幅度会明显减缓。因此，通过绘制误差平方和与簇数之间的关系图，找到弯曲处(即肘部)所对应的簇数，即为最佳簇数。

假设数据集被划分为 k 簇，每一簇的序列集合表示为 ϕ_i，其中：$a=\{a_1,\ a_2,\ \cdots,\ a_N\}$ 为该簇中的一条时间序列；$c_i=\{c_1,\ c_2,\cdots,\ c_N\}$ 为中心序列；N 表示时间序列 a 和 c_i 的长度，欧氏距离 d 的计算公式如下：

$$d=\sqrt{\sum_{i_a,i_c=1}^{N}(a_{i_a}-c_{i_c})^2} \tag{5}$$

式中：$i_a=1,2,\cdots,N$，$i_c=1,2,\cdots,N$；a_{i_a} 为该簇中时间序列的组成元素；c_{i_c} 为中心序列组成元素。

在此基础上，计算欧氏距离的平方，并累加得到该簇内的误差平方和 S_i，计算公式如下：

$$S_i=\sum_{a\in\phi_i}d^2 \tag{6}$$

进而，总体的误差平方和 S_{SE} 为

$$S_{SE}=\sum_{i=1}^{k}S_i \tag{7}$$

通过此方法，可以得到总体误差平方和与簇数之间的关系，从而通过手肘法确定最佳的聚类簇数。

2.3　选取相似度方法

高斯混合模型聚类后的每个簇内部样本具有较高的相似度，选取待测日与各聚类簇的典型日进行气象参数比较。因此，在聚类的基础上，引入特征相似度和余弦相似熵来表征待测日与典型日风速曲线的形状和大小相似程度，从而更精确地进行匹配和分析。

为了验证风电数据曲线形状上的相似性，引入特征相似度来衡量待测日与历史日的曲线相似程度：

$$d_{0,i}=\frac{\sum_{t=1}^{H}Z_0(t)Z_i(t)}{\sqrt{\sum_{t=1}^{H}Z_0^2(t)\sum_{t=1}^{H}Z_i^2(t)}} \tag{8}$$

式中：$Z_0(t)$、$Z_i(t)$ 分别为待测日、历史日 t 时刻的风速；H 为单日风速测量值总数；$d_{0,i}$ 为待测日与历史日形状相似度。

余弦相似熵[20]是一种结合余弦相似度和熵的度量方法，用于衡量两个变量之间的相似度及其复杂程度，可以间接反映它们在方向和大小上的相似性。余弦相似熵的值越大，表明两个变量之间的相关性越弱；反之，熵值越小，则表明两个变量之间的相关性越强。

余弦相似熵计算公式如下：

(1) 移除偏移量生成零中值序列 g_i，即

$$g_i=x_i-\mathrm{median}(\{x_i\}_{i=1}^{N}) \tag{9}$$

(2) 从零中值序列中构造嵌入向量，即

$$x_i^{(m)}=[g_i,\ g_{i+\tau},\ \cdots,\ g_{i+(m-1)\tau}] \tag{10}$$

(3) 定义余弦相似熵为

$$\begin{cases}\mathrm{AngDis}_{i,j}^{(m)}=\dfrac{1}{\pi}\cos^{-1}\left(\dfrac{x_i^{(m)}x_j^{(m)}}{|x_i^{(m)}|\ |x_j^{(m)}|}\right),\ i\neq j\\ B_i^{(m)}(r_{CSE})=\dfrac{1}{N-n-1}P_i^{(m)}(r_{CSE})\\ B^{(m)}(r_{CSE})=\dfrac{1}{N-n}\sum_{i=1}^{N-m}B_i^{(m)}(r_{CSE})\\ s(m,\tau,r_{CSE},N)=B^{(m)}(r_{CSE})\cdot\\ \quad\log_2B^{(m)}(r_{CSE})+(1-B^{(m)}(r_{CSE}))\cdot\\ \quad\log_2(1-B^{(m)}(r_{CSE}))\end{cases} \tag{11}$$

式中：$\mathrm{AngDis}_{i,j}^{(m)}$ 为第 m 阶的余弦相似度转换得到的距离；$x_i^{(m)}$、$x_j^{(m)}$ 为经过某种嵌入步骤得到的第 m 阶状态向量的第 i、j 个样本；$B_i^{(m)}(r_{CSE})$ 为第 m 阶、第 i 个点在半径 r_{CSE} 球邻域内的局部连接概率；$B^{(m)}(r_{CSE})$ 为所有点在半径 r_{CSE} 下的平均连接概率；$P_i^{(m)}(r_{CSE})$ 为点 i 在半径 r_{CSE} 球邻域中与其他点的关系数量；m 为嵌入维度；τ 为时间延迟；r_{CSE} 为半径；s 为余弦相似熵。

由于 CSE 是通过香农熵进行估计的，因此其熵值范围为(0,1]。当 CSE 接近 1 时，表示两个变量之间的相关性较弱；而当 CSE 接近 0 时，则表示两个变量之间的相关性较强。

2.4　选取框架

为了更准确地对风电输出功率进行预测，首先应用手肘法评估不同簇数下的误差平方和，选择最佳聚类簇数，确保聚类模型具有良好拟合性。接着，采用高斯混合模型对训练集数据进行聚类，将数据划分为若干个具有相似特征的簇，以便捕捉不同情况下风电输出功率的规律性。在完成聚类后，针对待测日的数据，通过计算其与各个聚类簇中的典型日(即每个簇的代表性数据点)之间的特征相似度和余弦相似熵，进行相似度匹配。通

过这种方式，可将待测日的数据精确地归类到最相似的聚类簇中，从而为风电输出功率的预测提供更加准确的依据。

3 CNN-BiLSTM-Attention 模型预测

3.1 CNN

卷积神经网络是一种广泛用于图像和视频处理的神经网络架构，通过反向传播优化网络中的权重，以最小化损失函数[21]。CNN 由多个卷积层、激活函数、池化层和全连接层组成。卷积操作通过滑动窗口对输入数据进行计算，提取局部特征；池化层负责降维，提取关键特征，减少参数量；全连接层则整合特征并传递至输出层，以增强网络的非线性拟合能力，从而实现高效的目标预测。

卷积计算方法如下：

$$Y_i=f(X_i\otimes w_i+b_b) \tag{12}$$

式中：$\otimes$为卷积操作；X_i 为卷积计算的序列；w_i 为卷积核的权重；b_b 为偏移量；f 为激活函数；Y_i 为卷积计算的输出结果。

3.2 BiLSTM

长短期记忆网络是一种特殊类型的循环神经网络，通过累加机制和门控机制实现信息的传递[22]。LSTM 的隐层单元具有独特的结构，能够在每个时间步将前一时刻的信息部分连接到当前状态，从而保留先前状态并累积新的输入，非常适合处理时间序列数据中的复杂模式。LSTM 由输入层、隐含层和输出层组成，利用门控机制有选择地控制信息的流动，从而有效地模拟数据中的特征规律，将短期和长期记忆结合起来，形成新的神经单元以控制信息传递。

LSTM 的门控机制包括遗忘门、输入门和输出门，分别负责遗忘、选择性记忆以及输出信息的处理。在这个结构中，遗忘门决定需要舍弃的历史信息，输入门控制长短期信息的存储，而输出门调节信息的最终输出。每个门的具体作用如下：遗忘门舍弃不必要的历史信息，输入门调控重要信息的存储，输出门则决定输入门处理结果的最终输出，其具体公式如下：

$$f_t=\sigma(W_f\cdot[h_{t-1},\ x_t]+b_f) \tag{13}$$

$$c'_{t-1}=f_t\cdot c_{t-1} \tag{14}$$

$$i_t=\sigma(W_i\cdot[h_{t-1},\ x_t]+b_i) \tag{15}$$

$$\bar{c}_t=\tanh(W_c\cdot[h_{t-1},\ x_t]+b_c \tag{16}$$

$$c_t=i_t\cdot\bar{c}_t+f_t\cdot c_{t-1} \tag{17}$$

$$\boldsymbol{o}_t=\sigma(W_o\cdot[h_{t-1},\ x_t]+b_o) \tag{18}$$

$$\boldsymbol{h}_t=\boldsymbol{o}_t\cdot\tanh(c_t) \tag{19}$$

$$\boldsymbol{y}=\sigma(\boldsymbol{W}_y\cdot\boldsymbol{h}_t+b_y) \tag{20}$$

式中：x_t 为 t 时刻的输入值；h_{t-1} 为 $t-1$ 时刻保存短期信息的隐藏状态；σ 为 sigmoid 函数；W_f 为遗忘门的权重；f_t 为上一时刻的状态 c_{t-1} 的遗忘系数，$f_t=0$ 时表示完全忘记上一时刻的状态，$f_t=1$ 时表示完全保留上一时刻的状态；c'_{t-1} 为上一时刻保留信息的单元状态；i_t 为输入值 x_t 和上一时刻隐藏状态 h_{t-1} 对当前单元状态 c_t 的更新程度；$\bar{c}_t$ 为被选中的更新内容；c_t 为遗忘门和输入门处理后的叠加信息；W_i、W_o 和 W_c 分别为输入门、输出门和候选状态的权重；b_f、b_i、b_c 和 b_o 为相应的偏置项；$\boldsymbol{o}_t$ 为输出门在 t 时刻的门控向量；$\boldsymbol{h}_t$ 为隐藏状态在 t 时刻的输出向量；$\boldsymbol{y}$ 为预测输出向量；$\boldsymbol{W}_y$ 为输出层的权重矩阵；b_y 为输出层的偏置项。

双向长短期记忆网络由 2 个普通的 LSTM 组成[23]。与单向 LSTM 只能按时间顺序从过去到未来学习特征不同，BiLSTM 能够在双向上处理时间序列数据，既能够利用过去的信息，也能挖掘未来时刻的特征，从而弥补了单向 LSTM 在时间依赖性处理上的不足。这种双向机制使得 BiLSTM 在处理径流预测等任务时，可以更高效地捕捉时间序列的复杂特征，增强模型的学习能力，提高预测精度。

3.3 注意力机制

高注意力机制源于人类视觉信号的处理过程[24]。当人们聚焦于某个图像区域时，其他可见信息往往会被自动忽略。基于这一原理，研究人员将注意力(Attention)机制广泛应用于各个领域。在径流预测中，Attention 机制通过分配神经网络隐藏单元的权重，评估气象和水文数据中不同特征对预测结果的影响程度，从而使对预测有较大影响的因素获得更高的权重。这种机制支持后续数据处理，减少了资源浪费，同时提升了模型的预测精度。

$$e_i=\tanh(Wh_i+b) \tag{21}$$

$$L_i=\frac{\exp(e_i)}{\sum_{i=1}^{T}\exp(e_i)} \tag{22}$$

$$c_i=\sum_{i=1}^{T}L_ih_i \tag{23}$$

式中：W 和 b 分别为权重和阈值；T 为输入序列的总长度；h_i 为 CNN 输出的隐藏单元状态，通过计算每个隐藏单元状态值的得分 e_i，再对注意力机制的得分进行归一化处理，最终将 e_i 和权重系数 L_i 进行加权求和，得出隐藏层状态 c_t。

3.4　CNN-BiLSTM-Attention 模型

为了更准确地预测风电输出功率，本文提出了一种基于 CNN-BiLSTM-Attention 模型的预测方法，其算法流程图如图 2 所示。在使用 CNN-BiLSTM-Attention 模型进行风电输出功率预测时，首先，通过包含一维卷积层和池化层的 CNN 框架自动提取风电输出功率数据的内部特征。卷积层负责提取数据的有效非线性局部特征，池化层采用最大池化方法对特征进行压缩，生成更重要的特征信息。接着，利用 BiLSTM 隐藏层对 CNN 提取的局部特征进行建模，学习其内部动态变化规律，并从中迭代提取更复杂的全局特征。同时，将 BiLSTM 隐藏层产生的特征输入到 Attention 机制，并利用 Attention 机制对时间信息进行加权，以区分各特征的重要程度，更有效地利用风电输出功率数据的时间序列特性，深入挖掘时间相关性。Attention 机制有效地减少了历史信息的丢失，并突出了关键历史时刻的特征，从而削弱了冗余信息对预测结果的影响。然后，将 Attention 层的输出输入到全连接层，生成风电输出功率的预测结果。最后，保存训练好的 CNN-BiLSTM-Attention 模型，并使用测试集验证其有效性，通过风电预测结果分析模型的不足，再不断优化。

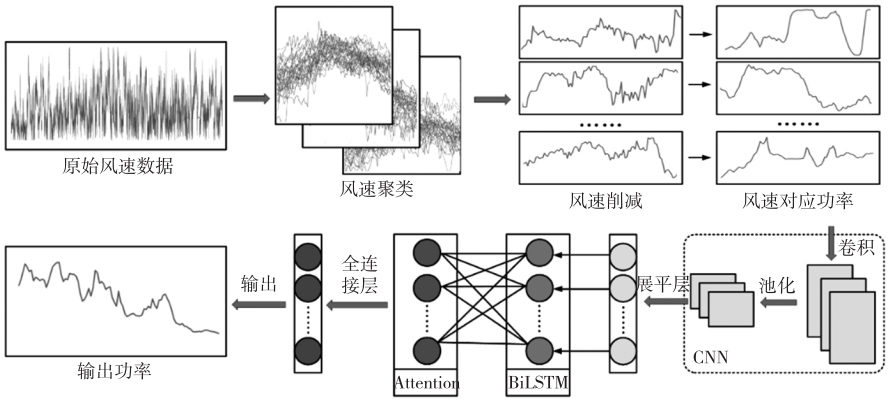


图 2　算法流程图

Fig. 2　Algorithm flowchart

4　算例分析

4.1　数据集介绍

为了验证本文所提预测方法的有效性，算例使用了新疆某 200 MW 风电场的历史运行数据以及数值天气预报数据，该风电场共安装了 134 台单机容量为 1.5 MW 的风力发电机组。数据集涵盖的时间范围为 2019-01-01—2021-12-31，NWP 的数据来自国家气象局，包括风速、风向和气压等多类常规预测气象要素，以及风电场的历史发电功率数据，时间分辨率均为 15 min，为本文风电功率预测模型的构建和训练提供了丰富的输入特征。

在数据划分方面，70％的数据用于构建模型的训练集，其余 30％的数据作为测试集，用于验证模型的泛化能力和预测性能。

4.2　评价指标

采用平均绝对百分比误差（M_{APE}）、均方根误差（R_{MSE}）和平均绝对误差（M_{E}）3 个指标来评估风电输出功率预测方法的性能。在风电输出功率预测中，M_{APE}、R_{MSE}和 M_{E} 的值越小，表示预测结果越准确，其计算公式如下：

$$M_{\mathrm{APE}}=\frac{1}{n}\sum_{t=1}^{n}\left|\frac{y(t)-y'(t)}{y(t)}\right|\times 100\% \tag{24}$$

$$R_{\mathrm{MSE}}=\sqrt{\frac{1}{n}\sum_{t=1}^{n}(y(t)-y'(t))^2} \tag{25}$$

$$M_{\mathrm{E}}=\frac{1}{n}\sum_{t=1}^{n}|y(t)-y'(t)| \tag{26}$$

式中：$y'(t)$、$y(t)$分别为 t 时刻风电功率的预测值和真实值。

4.3　聚类结果

为了深入挖掘风电数据中的特性，采用高斯混合模型对风电数据进行聚类分组。GMM 是一种基于概率统计的无监督学习方法，适用于处理具有复杂结构和多峰特性的风电数据。通过 GMM 进行聚类，可以将具有相似风速、风向等特征的数据点归为一组，从而更好地识别和区分风电数据中的不同模式和特征。

为确保聚类簇数的合理性，采用手肘法确定 GMM 模型的最佳簇数为 6，从而实现最优的聚类效果，误差平方和关系折线图和聚类结果如图3、

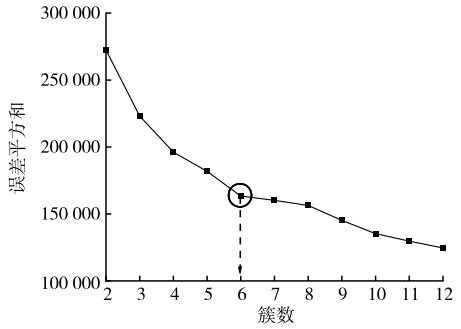


图 3 簇数与误差平方和的关系

Fig. 3 Relationship between cluster numbers and sum of squared errors

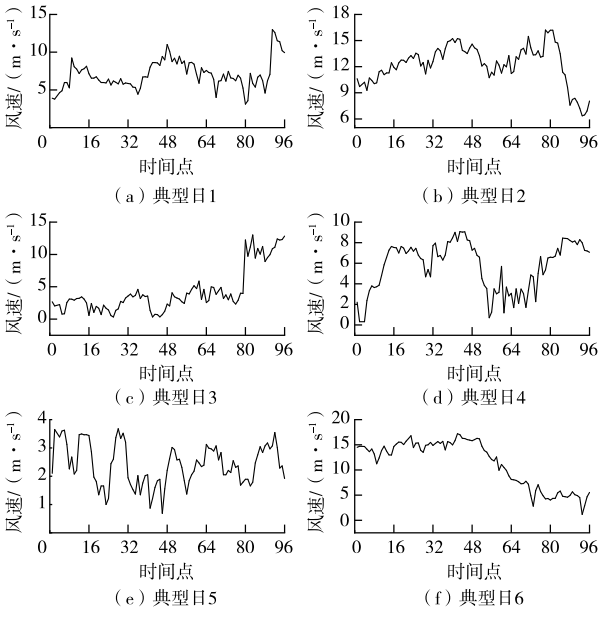


图 4 典型日 GMM 聚类结果

Fig. 4 GMM clustering results for typical days

图 4 所示,其中相邻两个时间点的时间间隔为 15 min(下同)。

4.4 最佳相似日

从测试集中选取 2021 年 12 月 26 日作为待测日,采用本文所提的相似日选择方法,可得到各聚类典型日与待测日的特征相似度和余弦相似熵,如表 1 所示。根据特征相似度和余弦相似熵计算结果,可以发现在典型日 2 处出现特征相似度最大值和余弦相似熵最小值。因此,选择典型日 2 的聚类簇作为训练样本。

表 1 相似日计算结果

Tab. 1 Calculation results on similarity days

参数	典型日 1	典型日 2	典型日 3	典型日 4	典型日 5	典型日 6
特征相似度	0.921	0.944	0.830	0.830	0.922	0.820
余弦相似熵	0.240	0.184	0.420	0.344	0.236	0.436

4.5 不同组合模型对比

将根据高斯混合模型和相似日选取出来的聚类簇作为训练样本,输入到相似日 CNN-BiLSTM-Attention 神经网络风电预测模型中,并与 CNN-LSTM-Attention、CNN-BiLSTM-Attention 及卷积神经网络-门控循环单元注意力机制(CNN-GRU-Attention)的预测结果进行对比。各算法的预测结果如图 5 所示,不同神经网络下的 M_{APE}、R_{MSE} 和 M_E 如表 2 所示。

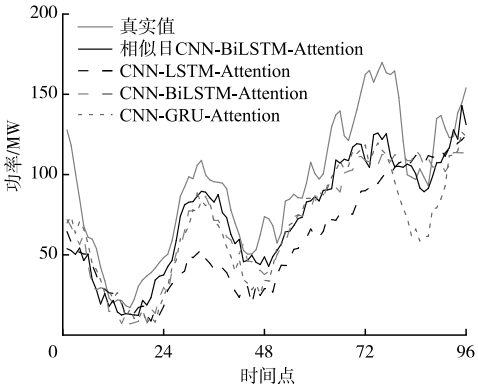


图 5 不同神经网络预测结果对比

Fig. 5 Comparison of prediction results from different neural networks

由图 5 可知,无论是在变化趋势的捕捉还是在功率输出水平的预测上,本文所提的预测方法在这几种神经网络算法中的表现效果最好。

表 2 不同算法预测误差对比

Tab. 2 Comparison of prediction errors for different algorithms

算法	M_{APE}	R_{MSE}	M_E
相似日 CNN-BiLSTM-Attention	0.216 29	24.172 5	18.952 4
CNN-LSTM-Attention	0.382 43	39.631 5	34.184 8
CNN-BiLSTM-Attention	0.284 09	27.648 6	23.748 3
CNN-GRU-Attention	0.297 31	29.962 8	25.873 7

从表 2 可以看出,BiLSTM 相较于传统的 LSTM 提供了更高的预测精度,而本文提出的基于特征相似日和 CNN-BiLSTM-Attention 的预测方法在精度上表现最佳。

5 结论

(1) 提出了 CNN-BiLSTM-Attention 预测模型,针对传统神经网络未充分考虑气象因素与风电输出功率之间的相关性,通过采用 Spearman 相关系数,选取与输出功率最相关的气象因素(风速和风向)作为模型的输入参数,有效提升了模型的输入质量。

（2）传统预测模型对训练集的整体训练可能会降低算法收敛速度，本文利用 GMM 对训练集进行聚类分组，并利用特征相似度和余弦相似熵选取与待测日在形状和大小上最相似的聚类簇作为训练集，显著提升了预测效果与算法的收敛速度。

参考文献：

[1] 魏泓屹，卓振宇，张宁，等. 中国电力系统碳达峰·碳中和转型路径优化与影响因素分析[J]. 电力系统自动化，2022，46(19)：1-12.
WEI Hongyi，ZHUO Zhenyu，ZHANG Ning，et al. Transition path optimization and influencing factor analysis of carbon emission peak and carbon neutrality for power system of China[J]. Automation of Electric Power Systems，2022，46(19)：1-12.

[2] 滕伟，许庆祥，王亚军，等. 平滑风电波动的飞轮协同电池混合储能系统经济性配置[J]. 动力工程学报，2024，44(7)：1101-1108.
TENG Wei，XU Qingxiang，WANG Yajun，et al. Economic configuration of flywheel collaborative battery hybrid energy storage system for smoothing wind power fluctuations[J]. Journal of Chinese Society of Power Engineering，2024，44(7)：1101-1108.

[3] 武煜昊，王永生，徐昊，等. 风电输出功率预测技术研究综述[J]. 计算机科学与探索，2022，16(12)：2653-2677.
WU Yuhao，WANG Yongsheng，XU Hao，et al. Survey of wind power output power forecasting technology[J]. Journal of Frontiers of Computer Science and Technology，2022，16(12)：2653-2677.

[4] 黄飞. 基于风速变化特性的短期风电功率预测方法研究[D]. 南京：南京信息工程大学，2019.

[5] 杨锡运，孙翰墨. 基于时间序列模型的风电场风速预测研究[J]. 动力工程学报，2011，31(3)：203-208.
YANG Xiyun，SUN Hanmo. Wind speed prediction in wind farms based on time series model[J]. Journal of Chinese Society of Power Engineering，2011，31(3)：203-208.

[6] 陈中慧，王海云，王维庆，等. 基于数据挖掘与小波去噪的短期风电功率预测[J]. 计算机仿真，2021，38(9)：90-94，133.
CHEN Zhonghui，WANG Haiyun，WANG Weiqing，et al. Short-term wind power prediction based on data mining and wavelet denoising[J]. Computer Simulation，2021，38(9)：90-94，133.

[7] 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 Junbo，ZHOU Renjun，DENG Xuehua，et al. Wind power forecast considering differential times of optimal ARIMA model[J]. Proceedings of the CSU-EPSA，2019，31(1)：105-111.

[8] 付炳喆，王玮，任国瑞，等. 考虑增强特征选择的深度卷积-时序网络短期风功率预测[J]. 动力工程学报，2024，44(10)：1565-1573.
FU Bingzhe，WANG Wei，REN Guorui，et al. Short-term wind power prediction with deep convolutional-temporal networks considering enhanced feature selection[J]. Journal of Chinese Society of Power Engineering，2024，44(10)：1565-1573.

[9] 刘忠，周泽华，邹淑云，等. 基于迁移学习和 CNN-LSTM 的水轮机空化状态识别方法[J]. 动力工程学报，2024，44(10)：1533-1540.
LIU Zhong，ZHOU Zehua，ZOU Shuyun，et al. Cavitation state recognition method of hydraulic turbine based on transfer learning and CNN-LSTM[J]. Journal of Chinese Society of Power Engineering，2024，44(10)：1533-1540.

[10] 胡阳，胡耀宗，程逸，等. 基于 FD-AT-LSTM 的大型风电机组变频器温度状态监测[J]. 动力工程学报，2023，43(9)：1207-1215.
HU Yang，HU Yaozong，CHENG Yi，et al. Temperature monitoring of heavy wind power unit inverters based on FD-AT-LSTM[J]. Journal of Chinese Society of Power Engineering，2023，43(9)：1207-1215.

[11] 周建新，王鸿滔. 基于相似日理论和改进 PSO-LSTM 模型的风电短期出力预测[J]. 中国工程机械学报，2024，22(4)：447-451，457.
ZHOU Jianxin，WANG Hongtao. Short-term wind power prediction based on similar day theory and improved PSO-LSTM model[J]. Chinese Journal of Construction Machinery，2024，22(4)：447-451，457.

[12] 唐清苇，向月，代佳琨，等. 基于 CNN-LSTM 的风电场发电功率迁移预测方法[J]. 工程科学与技术，2024，56(2)：91-99.
TANG Qingwei，XIANG Yue，DAI Jiakun，et al. Wind farm power transfer forecasting method based on CNN-LSTM[J]. Advanced Engineering Sciences，2024，56(2)：91-99.

[13] 王渝红，史云翔，周旭，等. 基于时间模式注意力机制的 BiLSTM 多风电机组超短期功率预测[J]. 高电压技术，2022，48(5)：1884-1892.
WANG Yuhong，SHI Yunxiang，ZHOU Xu，et al. Ultra-short-term power prediction for BiLSTM multi wind turbines based on temporal pattern attention[J]. High Voltage Engineering，2022，48(5)：1884-1892.

[14] 吴向明，宋楠，李晓军，等. 基于二次模态分解和卷

积双向长短期记忆神经网络的高比例光伏配电网线损预测[J]. 电网技术，2025，49(9)：3891-3899.
WU Xiangming，SONG Nan，LI Xiaojun，et al. Line loss prediction of high proportion photovoltaic distribution network based on quadratic mode decomposition and CNN-BiLSTM neural network[J]. Power System Technology，2025，49(9)：3891-3899.

[15] 徐睿麟，郑建勇，梅飞，等. 基于谱聚类和多元变分模态分解的风电机组功率预测[J]. 电网技术，2024，48(5)：2043-2053.
XU Ruilin，ZHENG Jianyong，MEI Fei，et al. Power prediction of wind turbine units based on spectral clustering and multivariate variational mode decomposition[J]. Power System Technology，2024，48(5)：2043-2053.

[16] 郭琦，闫军，郝乾鹏，等. 基于闭环聚类和多目标优化的风电短期功率预测方法[J/OL]. 上海交通大学学报，1-20(2024-07-03)[2024-10-19]. https://doi.org/10.16183/j.cnki.jsjtu.2024.079.
GUO Qi，YAN Jun，HAO Qianpeng，et al. Short-term wind power prediction method based on closed-loop clustering and multi-objective optimization[J]. Journal of Shanghai Jiao Tong University，1-20(2024-07-03)[2024-10-19]. https://doi.org/10.16183/j.cnki.jsjtu.2024.079.

[17] 高明裕，蔡林辉，孙长城，等. 一种基于斯皮尔曼秩相关结合神经网络的电池组内部短路故障检测算法[J]. 电子与信息学报，2022，44(11)：3734-3747.
GAO Mingyu，CAI Linhui，SUN Changcheng，et al. An internal short circuit fault detecting of battery pack based on Spearman rank correlation combined with neural network[J]. Journal of Electronics & Information Technology，2022，44(11)：3734-3747.

[18] 肖碧涛，赖晓路，郭鹏，等. 高斯混合模型风电机组异常数据识别方法研究[J]. 可再生能源，2023，41(8)：1051-1056.
XIAO Bitao，LAI Xiaolu，GUO Peng，et al. Abnormal data identification for wind turbine based on Gaussian mixture model[J]. Renewable Energy Resources，2023，41(8)：1051-1056.

[19] 苏丰睿，穆伟伟，赵宣茗，等. 一种划分聚类 k 值与中心初始化的改进方法[J]. 计算机工程，2023，49(11)：85-93.
SU Fengrui，MU Weiwei，ZHAO Xuanming，et al. Improved method for partitioning clustering k-values and center initialization[J]. Computer Engineering，2023，49(11)：85-93.

[20] 徐从云，郑近德，潘海洋，等. 基于余弦相似熵的滚动轴承状态表征方法[J]. 噪声与振动控制，2019，39(5)：167-172.
XU Congyun，ZHENG Jinde，PAN Haiyang，et al. A state characterization method for rolling bearings based on cosine similarity entropy[J]. Noise and Vibration Control，2019，39(5)：167-172.

[21] 张红颖，贾一超，汪江志，等. 考虑注意力机制的 CNN-LSTM 高渗透风电并网暂态电压稳定性研究[J]. 可再生能源，2024，42(3)：398-406.
ZHANG Hongying，JIA Yichao，WANG Jiangzhi，et al. Study on high penetration wind power integration and transient voltage stability in power grid using CNN-LSTM with attention mechanism[J]. Renewable Energy Resources，2024，42(3)：398-406.

[22] 吴家葆，曾国辉，张振华，等. 基于 K-means 分层聚类的 TCN-GRU 和 LSTM 动态组合光伏短期功率预测[J]. 可再生能源，2023，41(8)：1015-1022.
WU Jiabao，ZENG Guohui，ZHANG Zhenhua，et al. Dynamic combination of TCN-GRU and LSTM photovoltaic short-term power prediction based on K-means hierarchical clustering[J]. Renewable Energy Resources，2023，41(8)：1015-1022.

[23] 张越，臧海祥，韩海腾，等. 基于 FSN-MCCN-SA-BiLSTM 的短期风速预测[J]. 太阳能学报，2024，45(8)：529-536.
ZHANG Yue，ZANG Haixiang，HAN Haiteng，et al. Short-term wind speed forecasting based on FSN-MCCN-SA-BiLSTM[J]. Acta Energiae Solaris Sinica，2024，45(8)：529-536.

[24] 刘玉娟，刘颜达，闫振，等. 注意力机制的混合卷积高光谱图像分类方法[J]. 光谱学与光谱分析，2024，44(10)：2916-2922.
LIU Yujuan，LIU Yanda，YAN Zhen，et al. Classification of hybrid convolution hyperspectral images based on attention mechanism[J]. Spectroscopy and Spectral Analysis，2024，44(10)：2916-2922.