

基于变分自编码器和注意力 Seq2Seq 模型的风电功率预测

李辰龙¹, 李逗¹, 车畅畅², 潘苗¹, 高进¹

(1. 江苏方天电力技术有限公司, 南京 211102; 2. 南京林业大学汽车与交通工程学院, 南京 210037)

摘要: 针对风电场功率影响因素多、有效数据量小、预测时序长的复杂特点, 提出了基于变分自编码器和注意力 Seq2Seq 模型的风电功率预测方法。采集测风塔数据和对应的连续功率值构造样本集, 利用变分自编码器模型将样本进行数据增强, 从而获得足够多的样本用于支撑预测模型训练; 构建从测风塔多个监测指标到连续功率值的回归分析模型, 充分挖掘不同指标与功率值的映射关系; 将扩充后的不同指标分别输入到注意力 Seq2Seq 模型中进行指标时序预测, 并将数值天气预报数据用于修正预测结果, 从而得到更准确的指标加权预测结果; 将实时获取的测风塔和数值天气预报数据输入到训练好的加权预测模型和回归分析模型中, 实现风电功率的多步预测。利用风电场站实际运行数据集进行了模型验证, 结果表明: 与传统时序预测方法相比, 基于变分自编码器和注意力 Seq2Seq 模型能够在较小的重构误差下得到更准确的风电功率预测结果。

关键词: 变分自编码器; 注意力机制; 注意力 Seq2Seq 模型; 风电功率预测

Wind Power Prediction Based on Variational Autoencoder and Attention-Based Seq2Seq Model

LI Chenlong¹, LI Dou¹, CHE Changchang², PAN Miao¹, GAO Jin¹

(1. Jiangsu Frontier Electric Technology Co., Ltd., Nanjing 211102, China; 2. College of Automobile and Traffic Engineering, Nanjing Forestry University, Nanjing 210037, China)

Abstract: A method for wind power prediction based on variational autoencoder and attention-based Seq2Seq model is proposed to address the complex characteristics of multiple influencing factors, limited amount of effective data, and long time series. The method involves collecting wind tower data and corresponding continuous power values to construct a sample set. Then, variational autoencoder model is used to augment the samples, and generate sufficient samples to support the training of the prediction model. A regression analysis model is built to explore the mapping relationship between multiple monitoring indicators from the wind towers and the continuous power values. The augmented different indicators are separately input into an attention-based Seq2Seq model for indicator time series prediction. Numerical weather forecast data is used to refine the prediction results, yielding more accurate weighted prediction results for the indicators. By inputting real-time wind tower data and numerical weather forecast data into the trained weighted prediction model and regression analysis model, multi-step wind power prediction can be achieved. The proposed method is validated using actual operational data from wind farms. The results show that compared to traditional time series prediction methods, the approach based on variational autoencoder and attention-based Seq2Seq model provides more accurate wind power predictions with smaller reconstruction errors.

Key words: variational autoencoder; attention mechanism; Seq2Seq-based model; wind power prediction

0 引言

以风电为代表的新能源装机比重和发电量占比正在大幅提升,电力系统逐步向“高比例可再生能源”和“高比例电力电子设备”的“双高”方向发展。但由于风电具有间歇性强、随机性大、可调度性弱等特点,大规模接入后对电网运行会产生较为明显的影响。为了适应我国区域集中性的大容量风电场发展模式,保障电网运行的安全稳定,需要准确掌握新能源发电场的运行特性和功率分布特性,提高新能源功率控制水平。风电等新能源场站功率预测精度有效提升可使设备无故障运行时间增加、场站运营管理效能不断提升^[1]。

以数值天气预报、测风塔数据为驱动的风电功率预测方法可以分为统计分析方法、浅层机器学习方法和深度学习方法^[2]。统计分析方法包括:指数平滑、小波分析、Holt-Winters法、差分整合移动平均自回归模型(autoregressive integrated moving average model, ARIMA)等。王丽捷等人^[3]提出基于奇异值分解与卡尔曼滤波的短期风电功率预测模型用于降低数值天气预报系统误差。张婉莹等人^[4]结合经验模态分解、样本熵、Yeo-Johnson转换分位数回归和高斯核函数构建多步概率密度预测模型用于短期风电功率预测。XIONG B等人^[5]提出一种用于短期风电预测的自适应变分模式分解方法,采用鲸鱼优化算法提高模型鲁棒性,提取局部抽象特征和全局趋势特征以提高短期风电预测的性能。LI D等人^[6]采用纸群优化算法对传统的卡尔曼滤波器进行改进以提高风电功率预测准确度。统计分析方法能够通过算法建模对少量样本进行简单线性特征提取难以对风电场复杂多维监测指标进行深入分析。浅层机器学习方法包括:极限学习机、支持向量机、集成学习等^[7]。黄文聪等人^[8]利用基于完全噪声辅助聚合经验模态分解、小波阈值去噪和粒子群算法来优化核极限学习机以构建风电功率短期预测模型。Ye L等人^[9]提出考虑滚动误差校正策略的集成学习和超参数优化的风电功率短期预测方法。Zheng Y等人^[10]提出核岭回归模型,并将其结果与支持向量机和人工神经网络的两个参考预测模型进行了比较以验证该模型在3个不同预测时段的有效性。Shan J等人^[11]针对现有短期风电预测模型容易陷入局部最优、训练速度慢、精度差的问题提出基

于小波变换和核极限学习机相结合的改进人工蜂群算法。Zheng H等人^[12]利用变分模态分解将历史风功率段分解为子信号将其视为风功率序列的波动模式,同时引入分量注意机制来建立每个波动模式与历史风电分段之间的相关性关系,从而构建混合模型用于风电功率预测。浅层机器学习能够处理大量多维监测样本,并构建其与预测功率的映射关系,但是对长时间序列的非线性特征的提取能力有限,同时模型在多个场景下的泛化能力较差,难以通过模型参数的优化显著提升预测精度。

为了准确高效的实现长时序、非线性特征提取,以循环神经网络(recurrent neural network, RNN)、长短时记忆网络(long short-term memory, LSTM)、门控循环单元(gate recurrent unit, GRU)为代表的深度学习方法也被初步应用于风电功率预测^[13]。杨国清等人^[14]提出基于注意力机制GRU数值天气预报风速修正和Stacking多算法融合的短期风电功率预测模型。杨京渝等人^[15]为提高风电功率短期预测的准确度提出基于贝叶斯优化调参的特征挖掘改进深度学习模型。苗长新等人^[16]在利用时间序列相关性检验和残差通道注意力网络对数值天气预报风速进行修正的基础上构建了基于双向GRU的风电功率预测模型。Xiong J等人^[17]提出将互补集成经验模式分解、样本熵、随机森林、改进的爬行动物搜索算法、双向LSTM网络和极限学习机相结合的风电预测混合模型。Yu G等人^[18]使用时空多重聚类算法和混合神经网络来学习区域风电场的潜在时空相关性,进而建立了由改进CNN和双向LSTM网络组成的时空子聚类综合预测模型。Han Y等人^[19]针对风速变化不确定性特点提出基于时间起始卷积网络和变分模式分解的混合区间预测模型。

虽然具有强大非线性特征提取能力的深度学习方法能够在海量样本的支撑下获取较好的风电功率预测效果,但是在风电场数据采集过程中会存在数据缺失、噪声干扰、罕见或极端的情况下有效数据量少的问题,对深度学习模型的训练和预测精度产生不利影响。随着风电场的不断发展和增长,未来还需要更多的数据来训练新的模型或适应新的场景。同时,考虑到风速高波动性变化、考核要求等因素,需要在关注重点序列的基础上精准高效地获取预测结果。因此,本文提出基于变分自编码器(variational autoencoder, VAE)和注意力Seq2Seq

模型的风电功率预测方法。与传统浅层机器学习模型相比, 该方法能够将深度学习模型集成在 Seq2Seq 框架下通过添加注意力机制实现对多维长时序样本的深层非线性特征提取和多步组合预测。同时为了给深度学习模型训练提供充足高质量数据支撑, 本文采用 VAE 学习原始数据的潜在分布并实现数据增强, 从而增加数据的多样性和覆盖范围。

1 基于变分自编码器的数据增强

VAE 是一种生成式深度学习模型, 它能够将高维数据映射到潜在空间, 并从潜在空间中重构出原始数据。与传统的自编码器不同, VAE 通过学习数据分布的特征实现了更加灵活的数据生成。VAE 不仅可以生成高质量的新数据, 还可以在潜在空间中进行插值和探索, 以实现更加灵活的数据生成。VAE 模型包含编码器和解码器两个部分。编码器将原始数据映射到一个潜在空间, 解码器将这个潜在空间的向量转化为与原始数据相似的重构数据。在 VAE 模型中, 编码器将数据编码成一个概率分布, 用于描述每个样本在潜在空间中的位置。训练 VAE 模型的目标是最小化重构误差和潜在空间的正则化误差, 以防止模型过拟合。重构误差用于描述重构数据与原始数据的相似性; 而正则化误差用来约束潜在空间的分布, 使其更加接近于高斯分布。VAE 模型流程如图 1 所示^[20]。首先将样本 x 输入到编码器中计算均值 m 和方差 v ; 然后从正态分布 $N(0, 1)$ 中得到采样数据 s ; 再计算隐层特征 $z = m + v \times s$, 并将其输入到解码器中得到重构样本 $\hat{x}$, 最后计算重构误差和正则化误差得到变分下界 (evidence lower bound, ELBO), 通过反向传播优化编码器和解码器参数。

假设样本服从分布 $p(x)$, 隐变量为 Z , 分布 $q(z|x)$ 被用于近似 z 的后验分布。使用 KL 散度 (Kullback-Leibler divergence) 来表示两种分布之间的差异, 设置样本数量为 n , 损失函数 E_{VAE} 定义如式 (1) 所示^[21-22]。

$$\begin{aligned}
 E_{\text{VAE}} &= E_{z \sim q(z|x)} [\log p(x|z) - D_{\text{KL}}[q(z|x) \| N(0, I)]] \\
 &= \sum_{i=1}^n [-x_i \cdot \log(\hat{x}_i) + (1 - x_i) \cdot \log(1 - \hat{x}_i)] + \\
 &\quad \frac{1}{2} \sum_{i=1}^n (m_i^2 + v_i^2 - \log v_i^2 - 1)
 \end{aligned} \quad (1)$$




图 1 VAE 模型流程图

Fig. 1 Flowchart of VAE model

式中: $E_{z \sim q(z|x)}$ 为 z 的期望, $z \sim q(z|x)$ 表示 z 是从近似后验分布中 $q(z|x)$ 采样得到的; D_{KL} 为 KL 散度; x_i 和 $\hat{x}_i$ 分别为第 i 个数据点及其预测值; v_i 为隐变量 z 的方差; m_i 为隐变量 z 的均值; $N(\cdot)$ 为高斯分布; I 为单位矩阵。通过上述推导和转换可以得到由均值 m 、方差 v 、输入 x 和输出 $\hat{x}$ 组成的损失函数, 从而便于偏导求解和模型的反向传播优化。

2 基于注意力 Seq2Seq 的时序预测

Seq2Seq 能够通过编码器和解码器结构实现从输入序列到输出序列的映射, 其基本原理是将输入序列编码为一个固定长度的向量, 然后将该向量解码为输出序列^[23]。在编码和解码的过程中注意力机制可以被用于帮助模型关注输入序列中的不同部分。注意力机制通过计算编码器中每个时间步产生的向量与解码器当前时间步的向量之间的相似度来实现。这些相似度被用来计算一个权重向量, 该权重向量指示了对于当前的解码器时间步应重点关注的输入序列。在解码器的每个时间步, 注意力机制都会根据权重向量对编码器的输出进行加权平均。因此, 注意力 Seq2Seq 模型能够通过注意力机制更好地理解输入序列, 并得到更加准确的输出序列。注意力 Seq2Seq 模型流程如图 2 所示^[24]。

给定输入序列 $X = \{x_1, x_2, \dots, x_m\}$, 经过编码和解码过程后可以得到长度可变的序列 $Y = \{y_1, y_2, \dots, y_n\}$ 的条件概率分布为:




图2 注意力Seq2Seq模型流程图

Fig. 2 Flowchart of attention-based Seq2Seq

$$p(Y) = \prod_{i=1}^T p(y_i | \{y_1, \dots, y_{i-1}\}, c) \quad (2)$$

式中 c 是中间语义。

为预测第 t 个序列 y_t 需要求解条件概率 $p(y_t | \{y_1, y_2, \dots, y_{t-1}\}, c)$ 。将 X 输入到编码器的 LSTM 网络 $f_1(\cdot)$ 中计算 h_t 。 h_t 为 t 时刻输入数据的隐藏状态，其计算公式如式(3)所示。

$$h_t = f_1(x_t, h_{t-1}) \quad (3)$$

在解码器的 LSTM 网络 $f_2(\cdot)$ 中利用 t 时刻的中间语义 c_t 、 $t-1$ 时刻的预测结果 y_{t-1} 和解码器隐状态 s_{t-1} 计算 t 时刻的解码器隐状态 $s_t^{[25]}$ 。

$$s_t = f_2(y_{t-1}, s_{t-1}, c_t) \quad (4)$$

$$c_t = \sum_{j=1}^{T_s} \left(\frac{e^{a(s_{t-1}, h_j)}}{\sum_{j=1}^{T_s} e^{a(s_{t-1}, h_j)}} h_j \right) \quad (5)$$

式中： $a(\cdot)$ 函数为衡量输入隐状态和解码器隐状态的匹配程度； T_s 为解码器隐状态的维度； s 为由式(3)得到的解码器隐状态。

因此，可以得到预测目标 y_t 的条件概率。

$$p(y_t | y_1, \dots, y_{t-1}, X) = g(y_{t-1}, s_t, c_t) \quad (6)$$

根据式(6)可以得到添加注意力机制后的 Seq2Seq 模型用于构建从多变量长时序输入到多步长输出的映射，从而得到端对端多步时间序列预测结果。

根据上述公式可以得到添加注意力机制后的 Seq2Seq 模型用于构建从多变量长时序输入到多步长输出的映射，从而得到多步时间序列预测结果。

同时为了进一步提升预测精度将天气预报数据用于修正风速和风向时间预测结果，假设第 i 个指标的时序模型预测结果为 $\hat{P}_i^m$ ，实际值为 P_i^m ，对应

权重为 α_i ；数值天气预报结果为 $\hat{P}_i^n$ ，实际数值天气预报值为 P_i^n ，权重为 β_i ，可以得到第 i 个指标的最终加权预测结果 P_i 为：

$$P_i = \alpha_i \hat{P}_i^m + \beta_i \hat{P}_i^n \quad (7)$$

其中：

$$\alpha_i = \frac{|P_i^m - \hat{P}_i^m|}{|P_i^m - \hat{P}_i^m| + |P_i^n - \hat{P}_i^n|} \quad (8)$$

$$\beta_i = \frac{|P_i^n - \hat{P}_i^n|}{|P_i^m - \hat{P}_i^m| + |P_i^n - \hat{P}_i^n|} \quad (9)$$

3 风电功率预测模型

本文提出的基于变分自编码器和注意力 Seq2Seq 模型的风电功率预测技术路线如图 3 所示，主要包含 3 个部分：风电数据增强与回归分析、测风塔多监测指标预测和风电功率多步预测。首先采集测风塔数据和对应的风电功率数据，并将其在一维空间内进行拼接后输入到基于 VAE 的数据增强模型中得到生成样本，同时将多指标时间序列数据转化为监督学习问题，即把过去几个时间步的多指标数据作为模型的输入，预测未来某个时间步的功率作为输出，从而构建多指标回归分析模型用于单采样点的功率预测；然后构建基于注意力 Seq2Seq 的时序预测模型用于实现对不同测风塔指标的变化趋势预测，并且利用数值天气预报数据对时序预测结果进行修正以得到更准确的指标预测结果；最后将实时多维长时序的测风塔数据输入到已训练好的加权预测模型中，使用实时数值天气预报数据进行预测结果修正，得到多指标多时序的预测结果并将其输入到已训练好的回归分析模型中，从而实现风电功率多步预测。

4 实例验证

为了证明本文提出方法的有效性，利用实测的测风塔测量数据和对应的风电功率数据用于构建样本，来训练和优化风电功率预测模型。测风塔测量数据包括 10 m 风速(m/s)、10 m 风向($^\circ$)、30 m 风速(m/s)、30 m 风向($^\circ$)、50 m 风速(m/s)、50 m 风向($^\circ$)、70 m 风速(m/s)、70 m 风向($^\circ$)、风机轮毂风速(m/s)、风机轮毂风向($^\circ$)、气温($^\circ\text{C}$)、气压(hPa)和湿度(%rh)共 13 个指标，采样频率为 15




图3 风电功率预测技术路线

Fig. 3 Technical route for wind power prediction


min。数值天气预报数据的预测指标包括风速和风向, 采样频率也是 15 min。同时, 可以得到每次指标采样对应的风电功率。为了统一量纲并进行持续预测, 采用 Z-score 方法进行标准化处理, 可以得到如图 4 所示的连续 11 d 的 1 056 个采样点的测量数据和风电功率, 以及 2—11 d 的天气预报数据。从图中可以看出经过归一化后指标的 Z-score 在 -3~+3 的范围内, 说明数据分布良好。

4.1 风电数据增强与回归分析


选取连续 11 d 的测风塔数据对应的 13 维测量数据和 1 维风电功率, 每个样本包含 96 个时间序列, 将每个样本的多维序列一维展开为 1 344 个节点, 构建样本用于数据增强。综合考虑神经网络的特征提取能力和训练效率, 将 VAE 模型的编码器和解码器设置为节点为 [1 344, 512, 128, 10] 和 [10, 128, 512, 1 344] 的 2 层神经网络, 可以得到 VAE 模型的结构如图 5 所示。

将 11 个样本带入到 VAE 模型中进行训练, 由每个原始样本生成 50 个新样本, 得到图 6 所示的对比结果, 可以看出生成样本与原始样本有相似的变化趋势, 重构误差也较小。将按天为单位的生成数据进行拼接可以得到连续的测风塔数据用于进一步的时间序列预测。


统计 11 个样本所生成的共 550 个样本的重构误差结果可以得到如图 7 所示的箱型图。可以看出生成样本与原始样本的误差集中在较小的范围内, 只



(a) 多采样点的测风塔测量数据



(b) 多采样点的风电功率数据



(c) 数值天气预报数据

图4 风电场多采样点数据

Fig. 4 Multi-sampling point data of wind farm

有极少数异常值误差较大, 但也能够满足误差要求, 说明 VAE 模型的生成结果较好, 基本能够对原始输入进行重构, 在提高样本量的同时保留样本基本特征, 用于进一步的样本分类。

为了验证 VAE 模型的有效性, 构建生成对抗网络 (generative adversarial network, GAN) 用于模型对比。GAN 模型包括生成器和判别器。生成器接收随机噪声作为输入, 并通过反向传播逐渐学习




图5 VAE 模型结构图

Fig. 5 Structure diagram of VAE model




图6 原始样本与生成样本对比

Fig. 6 Comparison of original sample and generated sample

如何生成逼真的时间序列样本。判别器接收真实样本和生成器生成的样本，并辨别真伪。GAN通过交替优化生成器和判别器来实现模型训练。利用节点设置分别为[1 056, 500, 100, 1 056]和[1 056, 500, 100, 2]的两个神经网络作为生成器和判别器，经过训练可以得到GAN模型用于样本增强。统计11个样本所生成的共550个样本的重构误差结果并与VAE模型的重构误差进行对比，可以得到如图8所示的结果。

可以看出对于S1样本，GAN的生成样本误差




图7 样本生成误差分布箱型图

Fig. 7 Box plot of sample generation errors distribution

为 2.42×10^{-4} 小于VAE的 5.63×10^{-4} ，但是GAN针对其他样本的生成样本误差远大于VAE。结果表明：GAN的生成器产生的样本过于单一或缺乏多样性，导致GAN无法捕捉到真实数据的全貌和多样性，从而陷入模式崩溃。而VAE通过学习数据的潜在分布，可以更好地控制样本的生成过程，从而得到多样且误差较小的样本。

考虑到进行多指标功率回归预测时输入层和输出层节点较少，但是样本量较大，因此构建多层感知机模型用于多指标特征提取和功率预测。为获取




图8 生成模型误差对比

Fig. 8 Comparison of generative model errors

最优模型结构设置3—5层的神经网络进行模型对比,结果表明其误差没有明显差异,然而随着神经网络层数的增加,训练时间也大幅增加。因此,选取层数为3的神经网络进行回归分析,节点按照经验设置为 $[13, 100, 50, 20, 1]$,样本量为1 056,定义损失函数为均方差(mean squared error, MSE),学习率为0.1,训练和测试样本比例为4:1。经过100个Epoch的训练后得到模型的训练和测试误差如图9所示。可以看出经过100个Epoch的训练后模型的训练和测试误差分别逐渐下降到0.015和0.018,训练和测试的决定系数 R^2 得分为0.99和0.96,说明模型能满足多指标回归分析的精度要求。




图9 多指标回归分析模型训练和测试结果

Fig. 9 Training and testing results of multi-indicator regression analysis model

4.2 测风塔多指标参数预测

为了充分考虑不同指标的特点,针对每个指标构建注意力 Seq2Seq 模型如图10所示。为了寻求最优节点,分别将隐层节点设置为32、64和96,经

过实验选取训练误差较低的节点用于构建编码器和解码器,其中基于LSTM的编码器和解码器的隐层节点分别设置为32和64,输入为结构为 $[550, 96, 1]$ 的多维长时序测量数据,输出为 $[550, 16, 1]$ 的风电预测功率。通过LSTM模型的构建可以实现基于前一天96个采样点数据预测次日16个采样点的超短期4 h功率预测。

选取指标10 m风速对应的生成样本用于时间序列预测,设置训练样本和验证样本比例为4:1,选取Adam作为优化器,定义损失函数为均方差,经过训练可以得到其误差变化如图11所示。

可以看出训练误差和验证误差随着Epoch的增加快速下降到较小值并保持平稳,同时测试误差略大于训练误差。因此,模型训练和测试过程中无过拟合和欠拟合现象,说明模型能够取得较好的预测结果。同理可以得到其他12个指标的时间序列预测模型。

以10 m风速为例,将一天96个采样点作为输入预测其接下来超短期4 h 16个采样点的数值,同时将预测结果进行反复迭代可以得到如图12所示的整天96个采样点的时序预测值。同时,根据式(7)—(9)利用天气预报数据用于修正风速预测结果可以得到加权预测值。

其中加权预测和时序预测的绝对误差分别为0.17和0.33,说明添加了天气预报数据进行修正能够得到与真实值更接近的指标预测效果。经统计,13个指标的平均加权预测和时序预测的绝对误差分别为0.24和0.35。

为实现以天为单位的指标修正可以根据测风塔指标获取的功率预测结果可以将4 h预测值与历史值组合成新的样本用于下一个4 h的指标预测,经过多次反复迭代可以获取一整天的指标预测结果,结合天气预报获取的次日风速和风向指标得到最终的指标修正结果。

4.3 多步风电功率预测

考虑在进行多指标时序预测过程,简单的维度展开和拼接容易忽略指标之间的相互关系,因此本文将13个指标作为输入,风电功率值作为输出,在对不同指标进行时序预测的基础上经过回归分析得到风电功率预测结果。以第一天的13个指标的96个采样点数据为输入,经过时序预测和反复迭代得到次日的指标预测结果,再使用天气预报数据修




图 10 注意力 Seq2Seq 模型结构图

Fig. 10 Structure diagram of attention-based Seq2Seq model




图 11 注意力 Seq2Seq 模型的误差图

Fig. 11 Error graph of attention-based Seq2Seq model




图 12 指标预测结果对比图

Fig. 12 Comparison of indicator prediction results

正次日指标预测结果, 得到 13×96 的加权预测结果作为输入进行回归分析, 从而得到次日的 96 个采样点的功率预测结果如图 13 所示。经统计其预测 MSE 误差为 0.035, 预测功率与实际功率具有相同的变化趋势, 说明本文提出的预测模型能够取得较好的风电功率预测结果。

为验证模型有效性, 选取传统时序预测方法如 ARIMA、未添加注意力机制的 LSTM、RNN 用于对生成的 550 个样本进行功率预测。可以得到其测试总 MSE、均方根误差 (root mean squared error,

RMSE) 和平均绝对误差 (mean absolute error, MAE)。假设第 i 个样本的真实值为 x_i , 预测值为 $\tilde{x}_i$, 样本数量为 n , RMSE 值 R_{RMSE} 和 MAE 值 R_{MAE} 的计算公式为:

$$R_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^n (x_i - \tilde{x}_i)^2}{n}} \quad (10)$$

$$R_{\text{MAE}} = \frac{\sum_{i=1}^n |x_i - \tilde{x}_i|}{n} \quad (11)$$

同时, 按照考核规则可以得到功率预测合格率的定义为:




图 13 指标预测结果对比图

Fig. 13 Comparison of indicator prediction results

$$\text{合格率} = \left(1 - \frac{P_i^M - P_i^N}{C}\right) \times 100\% \quad (12)$$

式中: P_i^M 为 i 时刻的实际功率; P_i^N 为 i 时刻的预测功率; C 为额定容量。

根据上述定义, 可以得到风电功率预测结果如表 1 所示, 结果表明: 与 ARIMA、RNN 和 LSTM 相比, 本文提出的注意力 Seq2Seq 模型的功率预测误差最小, 功率预测合格率分别提升了 3.92%、1.53% 和 0.7%。

表 1 不同模型的风电功率预测结果对比

Tab. 1 Comparison of wind power prediction results of different models

模型	MSE 值	RMSE 值	MAE 值	合格率/%
ARIMA	0.138	0.371	0.323	91.93
LSTM	0.051	0.227	0.194	95.15
RNN	0.064	0.254	0.227	94.33
注意力 Seq2Seq	0.035	0.187	0.166	95.85

5 结论

为了深入提取测风塔和数值天气预报数据特征, 实现精准预测风电功率, 本文提出了基于 VAE 和注意力 Seq2Seq 组合预测方法, 并通过实例分析验证了所提出方法的有效性, 得出以下结论。

1) 通过 VAE 模型对较少的原始样本进行数据增强以获得充足样本用于人工智能模型训练, 并使用多层感知机用于多指标回归分析。VAE 相较于 GAN 能够避免模式崩溃, 得到多样且误差更小的生成样本。

2) 将注意力 Seq2Seq 模型用于测风塔不同监测指标的时序预测, 并利用数值天气预报数据对预测

结果进行加权优化, 将多指标预测结果的平均绝对误差从 0.35 降低至 0.24。

3) 将实时测风塔数据和数值天气预报数据输入到训练好的回归分析模型和加权预测模型中, 可以得到实时风电功率多步预测结果。与 ARIMA、RNN 和 LSTM 相比, 功率预测合格率分别提升了 3.92%、1.53% 和 0.7%。

参考文献

- [1] 吴慧军, 郭超雨, 苏承国, 等. 基于 EEMD-GRU-MC 的短期风功率组合预测方法[J]. 南方电网技术, 2023, 17(2): 66–73.
WU Huijun, GUO Chaoyu, SU Chengguo, et al. Combined prediction method for short-term wind power based on EEMD-GRU-MC [J]. Southern Power System Technology, 2023, 17(2): 66–73.
- [2] 商立群, 李洪波, 黄辰浩, 等. 基于多变量相空间重构和优化深度极限学习机的短期风电功率预测[J]. 南方电网技术, 2023, 17(2): 82–91.
SHANG Liqun, LI Hongbo, HUANG Chenhao, et al. Short-term wind power prediction based on multivariate phase space reconstruction and optimized deep extreme learning machine [J]. Southern Power System Technology, 2023, 17(2): 82–91.
- [3] 王丽婕, 刘田梦, 王勃, 等. 基于奇异值分解与卡尔曼滤波修正多位置 NWP 的短期风电功率预测[J]. 太阳能学报, 2022, 43(12): 392–398.
WANG Lijie, LIU Tianmeng, WANG Bo, et al. Short-term wind power prediction based on SVD and Kalman filter correction of multi-position NWP [J]. Acta Energetica Solaris Sinica, 2022, 43(12): 392–398.
- [4] 张婉莹, 何耀耀, 杨善林. 基于 TVFEMD-SE 和 YJQRG 的短期风电功率多步概率密度预测[J]. 系统工程理论与实践, 2022, 42(8): 2225–2242.
ZHANG Wanying, HE Yaoyao, YANG Shanlin. Multi-step probability density prediction of short-term wind power based on TVFEMD-SE and YJQRG [J]. Systems Engineering-Theory & Practice, 2022, 42(8): 2225–2242.
- [5] XIONG Bangru, MENG Xinyu, XIONG Gang, et al. Multi-branch wind power prediction based on optimized variational mode decomposition [J]. Energy Reports, 2022(8): 11181–11191.
- [6] LI Daoqing, YU Xiaodong, LIU Shulin, et al. Wind power prediction based on PSO-Kalman [J]. Energy Reports, 2022(8): 958–968.
- [7] 徐扬, 张耀, 陈宇轩, 等. 基于 Bagging 混合策略的多风电场稀疏向量自回归概率预测[J]. 电力系统保护与控制, 2023, 51(7): 95–106.
XU Yang, ZHANG Yao, CHEN Yuxuan, et al. Bagging ensemble method of probabilistic forecasting for multiple wind farms by sparse vector autoregression [J]. Power System Protection and Control, 2023, 51(7): 95–106.
- [8] 黄文聪, 潘风, 杨子潇, 等. 基于改进核极限学习机的风电功率短期预测[J]. 重庆理工大学学报(自然科学), 2023, 37(2): 241–250.
HUANG Wencong, PAN Feng, YANG Zixiao, et al. Short-term prediction of wind power based on improved kernel

- extreme learning machines [J]. Journal of Chongqing University of Technology (Natural Science), 2023, 37(2): 241 – 250.
- [9] YE Lin, DAI Binhua, LI Zhuo, et al. An ensemble method for short-term wind power prediction considering error correction strategy[J]. Applied Energy, 2022(322):119475.
- [10] ZHENG Yun, GE Yisu, MUHSEN Sami, et al. New ridge regression, artificial neural networks and support vector machine for wind speed prediction[J]. Advances in Engineering Software, 2023(179): 103426.
- [11] SHAN Jinning, WANG Hongzhe, PEI Gen, et al. Research on short-term power prediction of wind power generation based on WT-CABC-KELM[J]. Energy Reports, 2022(8):800 – 809.
- [12] ZHENG Huan, HU Zhenda, WANG Xuguang, et al. VMD-CAT: a hybrid model for short-term wind power prediction[J]. Energy Reports, 2023(9): 199 – 211.
- [13] 陈峰, 余轶, 徐敬友, 等. 基于 Bayes-LSTM 网络的风电出力预测方法[J]. 电力系统保护与控制, 2023, 51(6): 170 – 178.
- CHEN Feng, YU Zhi, XU Jingyou, et al. Prediction method of wind power output based on a Bayes-LSTM network [J]. Power System Protection and Control, 2023, 51(6): 170 – 178.
- [14] 杨国清, 刘世林, 王德意, 等. 基于 Attention-GRU 风速修正和 Stacking 的短期风电功率预测[J]. 太阳能学报, 2022, 43(12): 273 – 281.
- YANG Guoqing, LIU Shilin, WANG Deyi, et al. Short-term wind power forecasting based on attention-GRU wind speed correction and stacking [J]. Acta Energeticae Solaris Sinica, 2022, 43(12): 273 – 281.
- [15] 杨京渝, 罗隆福, 阳同光, 等. 基于气象特征挖掘和改进深度学习模型的风电功率短期预测[J]. 电力自动化设备, 2023, 43(3): 110 – 116.
- YANG Jingyu, LUO Longfu, YANG Tongguang, et al. Wind power short-term forecasting based on meteorological feature exploring and improved deep learning model [J]. Electric Power Automation Equipment, 2023, 43(3): 110 – 116.
- [16] 苗长新, 王霞, 李昊, 等. 基于数值天气预报风速误差修正的风电功率日前预测[J]. 电网技术, 2022, 46(9): 3455 – 3464.
- MIAO Changxin, WANG Xia, LI Hao, et al. Day-ahead prediction of wind power based on NWP wind speed error correction[J]. Power System Technology, 2022, 46(9): 3455 – 3464.
- [17] XIONG Jinlin, PENG Tian, TAO Zihan, et al. A dual-scale deep learning model based on ELM-BiLSTM and improved reptile search algorithm for wind power prediction [J]. Energy, 2023(266):126419.
- [18] YU Guangzheng, LIU Chengquan, TANG Bo, et al. Short term wind power prediction for regional wind farms based on spatial-temporal characteristic distribution [J]. Renewable Energy, 2022(199):599 – 612.
- [19] HAN Yuchao, TONG Xiangqian, SHI Shuyan, et al. Ultra short-term wind power interval prediction based on hybrid temporal inception convolutional network model [J]. Electric Power Systems Research, 2023(217):109159.
- [20] YANG Yangfang, YU Bo, WANG Wei. Research on equipment health prediction technology based on edge computing and VAE-TCN [J]. Procedia Computer Science, 2021(183): 100 – 106.
- [21] 华回春, 邓彬, 刘哲, 等. 基于变分自编码高斯混合模型的发电企业串谋智能预警[J]. 电力系统自动化, 2022, 46(4): 188 – 196.
- HUA Huichun, DENG Bin, LIU Zhe, et al. Intelligent early-warning of collusion between power generation enterprises based on variational autoencoding Gaussian mixture model [J]. Automation of Electric Power Systems, 2022, 46(4): 188 – 196.
- [22] 任建亭, 汤宝平, 雍彬, 等. 基于深度变分自编码网络融合 SCADA 数据的风电齿轮箱故障预警[J]. 太阳能学报, 2021, 42(4): 403 – 408.
- REN Jianting, TANG Baoping, YONG Bin, et al. Wind turbine gearbox fault warning based on depth variational autoencoders network fusion SCADA data [J]. Acta Energeticae Solaris Sinica, 2021, 42(4): 403 – 408.
- [23] DAI Yeming, YANG Xinyu, LENG Mingming. Optimized Seq2Seq model based on multiple methods for short-term power load forecasting [J]. Applied Soft Computing, 2023(142):110335.
- [24] 姜建国, 陈鹏, 郭晓丽, 等. 基于双注意力机制的 Seq2Seq 短期负荷预测[J]. 吉林大学学报(信息科学版), 2023, 41(2): 251 – 258.
- JIANG Jianguo, CHEN Peng, GUO Xiaoli, et al. Seq2seq short-term load forecasting based on double attention mechanism [J]. Journal of Jilin University (Information Science Edition), 2023, 41(2): 251 – 258.
- [25] 杨子民, 彭小圣, 熊予涵, 等. 计及邻近风电场信息与 CNN-BiLSTM 的短期风电功率预测[J]. 南方电网技术, 2023, 17(2): 47 – 56.
- YANG Zimin, PENG Xiaosheng, XIONG Yuhuan, et al. Short-term wind power prediction based on information in neighboring wind farms and CNN-BiLSTM [J]. Southern Power System Technology, 2023, 17(2): 47 – 56.

收稿日期: 2023-06-15; 网络首发日期: 2024-04-25

作者简介:

李辰龙(1980), 男, 高级工程师, 硕士, 研究方向为电力系统分析运行及新能源技术, lichenlong@js. sgcc. com. cn;

李逗(1992), 男, 工程师, 硕士, 研究方向为电站环保系统数据分析, 253209908@qq. com;

车畅畅(1994), 男, 通信作者, 副教授, 博士, 研究方向为复杂系统智能运维、大数据分析, 821116775@qq. com。