

文章编号:1001-2060(2023)06-0137-10

基于深度学习模型的新能源电站一体化短期功率预测

尹兆磊, 刘嗣萃, 于立强, 毕圆圆

(国网冀北电力有限公司承德供电公司, 河北 承德 067000)

摘要:为了解决风力发电和光伏发电随机性、波动性、间歇性造成的新能源功率预测建模和精度不高问题,基于深度学习模型变分自动编码器(Variational Auto-Encoder, VAE)在时间序列建模和非线性逼近特征提取方面的优异性能,开展新能源电站VAE模型功率短期预测研究,并与循环神经网络(RNN)、长短期记忆(LSTM)深度学习方法和支持向量回归(SVR)机器学习方法的预测结果进行了对比。光伏电站和风电场独立功率预测结果表明,深度学习模型较基线机器学习模型预测性能更好,基于VAE的预测方法能够学习更高级别的特征,其预测性能表现更佳,光伏功率预测模型的RMSE、MAE和 R^2 值分别为1.593、1.098和0.973;风光一体化功率预测结果表明,VAE和RNN模型能够提高功率预测准确性,其一体化功率预测模型的 R^2 值分别为0.96和0.97。

关键词:一体化功率预测;深度学习;变分自动编码器;RNN

中图分类号:TM73 文献标识码:A DOI:10.16146/j.cnki.rndlge.2023.06.016

[引用本文格式] 尹兆磊, 刘嗣萃, 于立强, 等. 基于深度学习模型的新能源电站一体化短期功率预测[J]. 热能动力工程, 2023, 38(6): 137-146. YIN Zhao-lei, LIU Si-cui, YU Li-qiang, et al. Short-term power prediction for integrated new energy power station based on deep learning model[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(6): 137-146.

Short-term Power Prediction for Integrated New Energy Power Station based on Deep Learning Model

YIN Zhao-lei, LIU Si-cui, YU Li-qiang, BI Yuan-yuan

(Chengde Power Supply Company, State Grid Jibei Electric Power Co., Ltd., Chengde, China, Post Code: 067000)

Abstract: In order to solve the problem of new energy power prediction modeling and low precision caused by the randomness, volatility and intermittence of wind power generation and photovoltaic power generation, based on the excellent performance of variational auto-encoder (VAE) deep learning model in the aspect of time series modeling and nonlinear approximation feature extraction, the VAE model was used to carry out the short-term power prediction research of new energy power station. The prediction result of VAE was compared with the prediction results of the recurrent neural network (RNN) and long short-term memory (LSTM) deep learning methods and the support vector regression (SVR) machine learning method. The independent power prediction results of photovoltaic power plants and wind farms show that the deep learning model has better prediction performance than the baseline machine learning model, and the VAE-based prediction method can learn higher-level features and its prediction performance is better. The RMSE, MAE and R^2 values of photovoltaic power prediction model are 1.593, 1.098 and 0.973 respectively. The wind-solar integrated power prediction results show that the VAE and RNN models can improve the accuracy of power prediction, and R^2 values of integrated power prediction model

收稿日期:2022-06-19; 修订日期:2022-07-25

基金项目:国家自然科学基金项目(71471070)

Fund-supported Project: National Natural Science Foundation of China (71471070)

作者简介:尹兆磊(1990-),男,国网冀北电力有限公司承德供电公司工程师。

are 0.96 and 0.91 respectively.

Key words: integrated power prediction, deep learning, variational auto-encoder (VAE), recurrent neural network (RNN)

引言

截止 2021 年底, 我国可再生能源发电装机达到 10.63 亿千瓦, 占总发电装机容量的 44.8%。其中, 风电装机 3.28 亿千瓦、光伏发电装机 3.06 亿千瓦, 分别占全国总发电装机容量的 13.8% 和 12.9%^[1]。为实现双碳目标, 十四五期间规划在沙漠、戈壁、荒漠地区建设 4.5 亿千瓦的大型风电光伏基地, 未来随着新能源大基地的开发推进, 同一地区光伏电站、风电场在空间和时间上进一步关联, 同时大基地的特高压外送通道安全稳定运行对集群化新能源电站时间尺度上的一体化预测需求更加迫切^[2-4]。此外, 精准预测区域总出力对电力系统制定调度计划、安排旋转备用容量以及电力市场交易具有重要的意义^[5]。

国内外针对一体化功率预测研究还非常少, 集群功率预测的方法主要有累加法和统计尺度法^[6]。累加法受电站信息完备程度影响有较大的局限性, 统计尺度法划分若干子区域, 选取相关性强的基准场站, 通过倍增加和得到区域功率预测结果。文献[7]采用累加法对内蒙地区区域功率预测开展初步研究。文献[8]采用统计尺度法对区域风电场进行预测。两种方法忽略了风光资源时空相关特性。文献[9]建立了基于深度多任务学习的风光集群功率联合预测模型, 实现了同时预测风光功率。近年来, 浅层机器学习 (Machine Learning, ML) 作为非参数模型, 可以模拟过程变量之间的复杂关系, 已被广泛用于改进预测^[10-11]。随着人工智能技术发展, 深度学习已广泛应用于计算机视觉^[12]、自然语言处理^[13]、语音识别^[14]、可再生能源预测^[15]、异常检测^[16]、强化学习^[17]等领域。由于其数据驱动的方法, 深度学习带来了时间序列数据中相关信息的提取和分析方式的范式转变。通过将多层网络连接到神经网络结构中, 深度学习驱动的方法能够灵活有效地对过程变量之间的隐式交互进行建模, 并在

人工指令有限的情况下从海量数据集中自动提取相关信息。功率预测方面^[18-20]已表现出高效学习时间序列数据中的非线性特征和相关信息的能力, 应该加以广泛应用。

本文引入变分自编码器 (Variational Auto-Encoder, VAE) 方法应用于光伏电站和风电场发电时间序列数据的预测。并与循环神经网络 (Recurrent Neural Networks, RNN)、长短期记忆 (Long Short-Term Memory Networks, LSTM) 深度学习方法和支持向量回归 (Support Vector Regression, SVR) 机器学习方法的预测输出进行了比较, 这些模型考虑了固有的时间依赖性和非线性特征。为了指导光伏系统的短期和长期运营策略, 对单步和多步提前预测进行了对比研究。基于确定的最优模型进行了风光一体化功率预测研究, 为区域新能源电站一体化功率预测提供了可行途径。

1 模型方法

深度学习技术在自动学习嵌入数据的相关特征方面具有良好的能力, 可用于预测光伏功率输出。变分自编码器模型是深度生成模型的一种, 可以有效地以无监督的方式从数据中自动提取信息^[21], 能够降低输入维数, 对于使用随机梯度下降法逼近复杂数据分布非常有效^[22]。与传统的自编码器相比, 变分自编码器在训练阶段使用调节机制有效解决传统自编码器中的过拟合问题, 已证明在处理各种类型的复杂数据方面有效^[19]。图 1 为 1 个变分自编码器的构建示意图。

作为自动编码器的变体, VAE 包含 1 个编码器和 1 个解码器, 其中编码器的任务是将给定的观察集 X 编码到潜在空间 Z 作为分布 $q(z|x)$ 。与观察集的维度相比, 潜在(称为隐藏)空间维度减少。事实上, 编码器的构建是为了有效地将观察到的集合压缩到这个维度减少的空间。然后, 使用学习到的概率分布, 通过 $z \sim q(z|x)$ 生成样本。另一方面, 解码器 $p(x|z)$ 主要用于根据输入随机变量 z 生成观测

值 x 。 $p(z)$ 是标准的高斯分布, $p(x|z)$ 是高斯分布。需要强调的是, 使用解码器重建数据会导致一些重建偏差, 在 VAE 模型的训练阶段, 通过最小化观察集和编码 - 解码集之间的偏差来最小化该误差。

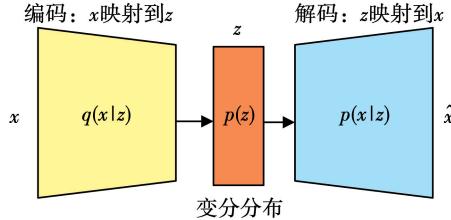


图 1 变分自编码器模型基本原理

Fig. 1 Basic schematic illustration of a variational auto-encoder (VAE)

因此, VAE 编码器通过近似后验 $q_\theta(z|x)$ 得到, 解码器通过似然 $p_\varphi(x|z)$ 得到, 其中 θ 和 φ 分别为编码器和解码器的参数。训练过程中构建了一个神经网络来学习 θ 和 φ 。本质上, VAE 编码器的作用是根据收集的传感器数据学习潜在变量 z , 解码器使用学习到的潜在变量 z 来恢复输入数据。重构数据与输入数据的偏差应尽可能接近于零。值得注意的是, 从编码器学习到的潜在变量 z 用于基于输入数据的特征提取, 编码器输出的维数小于原始数据的维数。编码器通过包含编码器和解码器的整个 VAE 来训练的。

损失函数对于训练 VAE 的特征提取有着本质的影响。假设 $X_t = [x_{1,t}, x_{2,t}, \dots, x_{N,t}]$ 是 VAE 在时间点 t 的输入数据, X 是使用 VAE 模型重建的数据。假设最大化参数的边际似然学习表示为^[22]:

$$\log p_\phi(x') = D_{KL}[q_\theta(z|x) \| p_\phi(z)] + L(\theta, \phi; x) \quad (1)$$

式中: $D_{KL}[\cdot]$ —Kullback-Leibler 散度; L —编码器和解码器参数(即 θ 和 φ)的似然性。

VAE 的损失函数由两部分组成: 重建损失和正则化器。重建损失试图获得有效的编码 - 解码过程。相比之下, 正则化器部分允许对潜在空间构造进行正则化, 以尽可能接近前缀分布(例如, 正态分布)来逼近编码器外的分布。

$$l(\theta, \phi) = \underbrace{E_{z \sim q_\theta(z|x)} (\log p_\phi(x'|z))}_{\text{重构项}} - \underbrace{D_{KL}(q_\theta(z|x) \| p_\phi(z))}_{\text{正则化项}} \quad (2)$$

式(2)允许增强解码器学习数据重建的能力。较高的重建损失值意味着执行的重建不合适, 而较低的值意味着模型正在收敛。使用 Kulback-Leibler (KL) 散度报告正则化器, 该散度将编码器函数($q_\theta(z|x)$)和潜在变量先验($z, | p_\varphi(z)$)的分布分开。实际上, KL 用于计算分隔两个给定概率分布的距离。梯度下降法用于在训练阶段最小化编码器参数和解码器损失函数。总体而言, 尽可能最小化损失函数以确保获得规则的潜在空间 z , 并使用 $z \sim p_\varphi(z)$ 对新观察进行充分采样^[23]。图 2 为损失函数的计算过程。

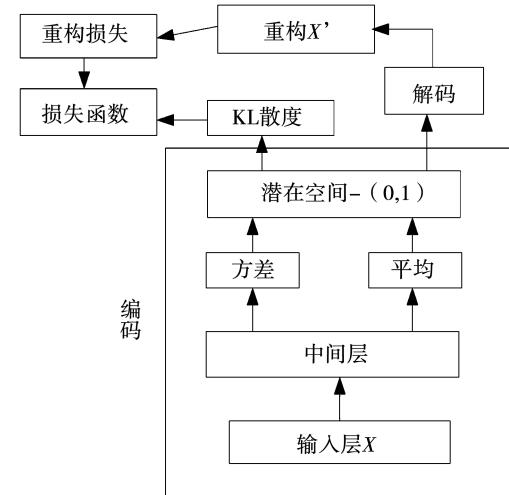


图 2 损失函数和散度计算过程

Fig. 2 Computational process of loss function and Kulback-Leibler (KL) divergence

假设 $p_\varphi(z) = N(z; 0, I)$, 则 $q_\theta(z|x)$ 可写为:

$$q_\theta(z|x) = N(z; \mu, \sigma^2 I) \quad (3)$$

编码器和解码器的参数是通过使用训练观测值最小化损失函数 $L(\theta, \varphi)$ 来获得的。重构误差项可以表示为以下形式:

$$I(\theta, \phi, x) = \frac{1}{2} \sum_i (1 + \log(\sigma_i^2 - \mu_i^2 - \sigma_i^2)) + \frac{1}{L} \sum_{l=1}^L \log p_\phi(x|z^l) \quad (4)$$

2 功率预测过程

2.1 数据预处理

当使用 RNN 模型处理一些大值数据时, 可能会发生梯度爆炸并对 RNN 的性能产生负面影响, 会降

低 RNN 的学习效率。为了解决这个问题,对输入数据进行归一化,然后用于构建深度学习模型,归一化后允许在不考虑光伏设施规模的情况下比较预测性能。原始测量值 y 的归一化定义为:

$$\tilde{y} = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (5)$$

式中: y_{\min}, y_{\max} —光伏电站的输出功率数据的最小值和最大值,MW。

在获得预测输出后,应用反向操作来确保预测数据与原始光伏功率时间序列数据匹配。

$$y = \tilde{y} \cdot (y_{\max} - y_{\min}) + y_{\min} \quad (6)$$

由于光伏电站功率与天气条件的高度相关性,功率输出曲线显示高度的可变性和波动性。为了减轻不确定性对光伏功率预测准确性的影响,采用一个深度学习框架来预测光伏功率输出时间序列。从本质上讲,深度学习模型是从复杂数据集中学习相关特征和处理非线性的有效工具。

功率预测流程如图 3 所示。太阳能功率预测分两个阶段完成。原始功率数据被拆分为训练子数据和测试子数据。首先,对原始数据进行标准化以构建深度学习模型。Adam 优化器用于通过基于训练数据最小化损失函数来选择每个模型的参数值。模型的质量使用若干统计指标进行量化,包括决定系数(Coefficient of Determination, R^2)、解释方差(Explained Variance, EV)、平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE) 和标准均方根误差(Normalized RMSE, NRMSE)。深度学习驱动的预测方法学习隐藏在光伏功率输出数据中的时间相关性,并有望揭示和捕获光伏功率时间序列中的序列特征。

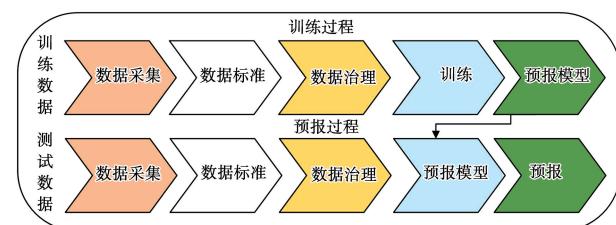


图 3 功率预测流程

Fig. 3 Flow chart of deep learning power prediction

2.2 训练过程

训练过程使用的模型大体可分为编码器模型和 RNN 模型两类。数据集首先进行归一化处理,自动

编码器模型需要进行数据整形预处理,以将单变量功率时间序列数据转换为二维矩阵,用作自编码器的输入。两类模型在训练阶段的主要区别在于学习方式不同,RNN 为完全受监督训练,而自动编码器首先以无监督的方式预训练,然后基于监督学习完成训练。RNN 模型通过使用训练子集作为输入序列($X = x_1, \dots, x_k$)和输出变量 $Y = x_{k+1}$,以监督方式进行训练。

训练基于 RNN 的模型来学习从输入到输出的映射函数。之后,经过训练的模型用于完成新数据序列的预测。另一方面,逐层无监督加微调应用于 VAE。基于自动编码器的光伏功率输出预测是通过降维来实现的,即模型无法发现时间依赖性或模型时间序列数据。对每一层进行逐层无监督学习,进行微调后,改进了专用于预测问题或降维(如自动编码器)的神经网络的特征提取和学习过程。预处理步骤的 VAE 训练过程如图 4 所示。

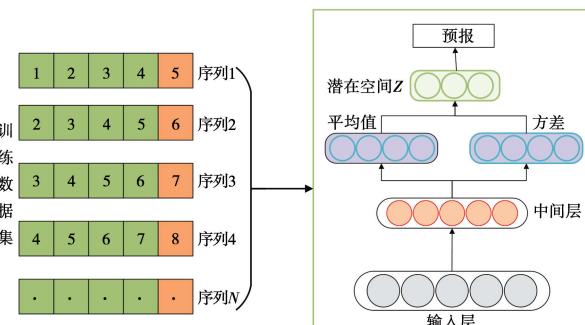


图 4 VAE 训练过程

Fig. 4 Train process of VAE

2.3 测量评价

使用 R^2 、RMSE、MAE、EV 和 NRMSE 5 个指标评估深度学习模型性能:

$$R^2 = \frac{\sum_{i=1}^n [(y_i - \bar{y}_m) \cdot (y_i - \bar{y}_e)]^2}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}_m)^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y}_e)^2}} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_e)^2} \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_e| \quad (9)$$

$$EV = 1 - \frac{V_{ar}(y_e - y)}{V_{ar}(y)} \quad (10)$$

$$\text{NRMSE} = \left(1 - \sqrt{\frac{\sum_{i=1}^n (y_i - y_e)^2}{\sum_{i=1}^n (y_i - y_m)^2}} \right) \times 100\% \quad (11)$$

式中: y_i —实际值; y_e —相应的估计值; y_m —测得的功率数据点的平均值; n —测量次数。

与使用依赖于测量值范围的 RMSE 不同, 使用 NRMSE 作为统计指标的好处是其不依赖于测量值的范围。NRMSE 指标反映预测模型响应与测量数据的匹配程度, NRMSE 值为 100% 表示完美的预测, 较低的值表示预测性能不佳。较低的 RMSE 和 MAE 值以及 EV 和 R^2 越接近 1 说明预测性能越高。

3 案例分析

3.1 光伏电站功率预测

3.1.1 光伏电站数据

采用来自贵州地区某太阳能光伏电站数据来验证深度学习模型预测方法的性能。光伏电站的实时监测辐照度及实际功率曲线如图 5 所示。光伏电站的时间分辨率为 15 min。该电站于 2021 年 7 月份全部投产, 装机容量 50 MW, 采集的数据时间从 2021 年 8 月 1 日到 2021 年 10 月 16 日。

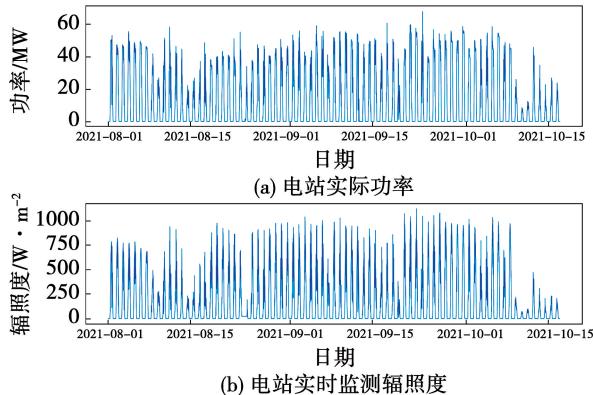


图 5 光伏电站的功率及辐照度

Fig. 5 Power and irradiance of photovoltaic power station

3.1.2 预测结果分析

基于测试光伏电站功率数据, 评估 4 个学习模型(即 SVM、DRNN、ConvLSTM 和 VAE)的预测性能。首先, 构建模型以捕获训练数据中的最大方差, 然后使用各学习模型来预测未来光伏功率输出的趋势。对于所有模型, 使用交叉熵作为损失函数, 使用 Rmsprop 作为训练中的优化器。表 1 为训练模型对应的调整参数。测试数据集 85% 的数据用于训练, 15% 的数据用于测试。

表 1 模型对应的调整参数

Tab. 1 Corresponding tuning parameters of the model

参数	VAE	DRNN	SVM	ConvLSTM
学习速率	0.000 5	0.000 5	0.000 5	0.000 5
训练周期	800	800	500	500
层数	5	-	4	-

光伏电站功率输出的主要特征是其间歇性。图 6 显示了使用 4 个模型的预测输出。这些结果说明了深度学习模型在光伏功率预测方面的优势。

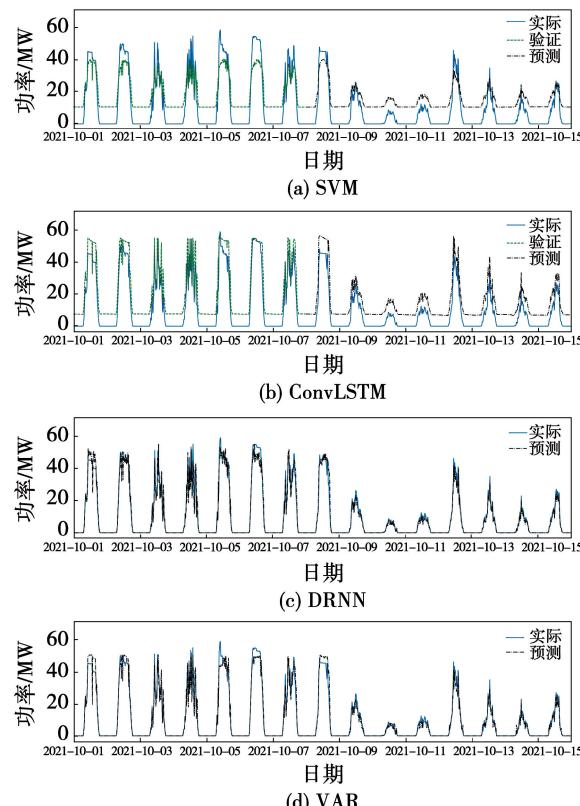


图 6 不同模型预测结果对比

Fig. 6 Comparison of prediction results of different models

为定量评估 4 个模型的预测精度, 计算了 5 个性能统计指标, 结果如表 2 所示。ConvLSTM 与其他模型相比在预测精度方面表现不佳, 不能很好地跟踪功率的变化, 并且没有描述数据中的最大差异。与其他模型相比, VAE 模型统计指标显示, RMSE (1.593)、MAE (1.098) 值较低, RMSLE (0.466) 值较低, R^2 值 (0.98) 最高, EV 值接近 1, 意味着数据中的大部分方差被 VAE 模型捕获, 表明 VAE 方法用于光伏功率预测具有优越的性能, 能够提供准确的预测。DRNN 模型在统计指标 (RMSE、RMSE、MAE、EV 和 NRMSE) 方面的性能与 VAE 略有可比性。基于 RNN 的模型具有很强的描述时间相关数

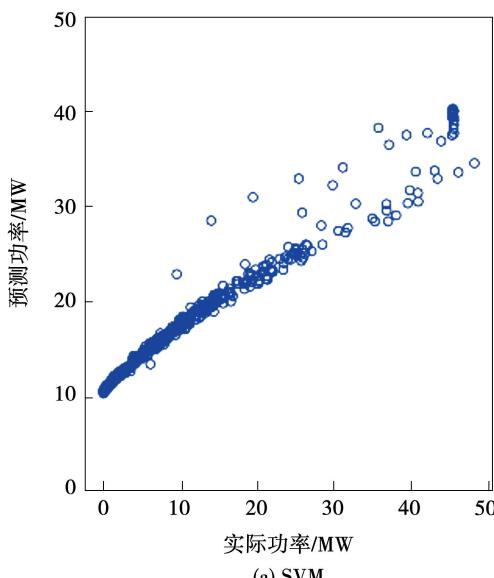
据的能力,可以比其他方法更好地模拟历史和未来功率输出数据之间的复杂关系。表 2 表明,VAE 和 DRNN 深度学习模型表现出更好的预测性能。

表 2 不同模型的预测性能指标

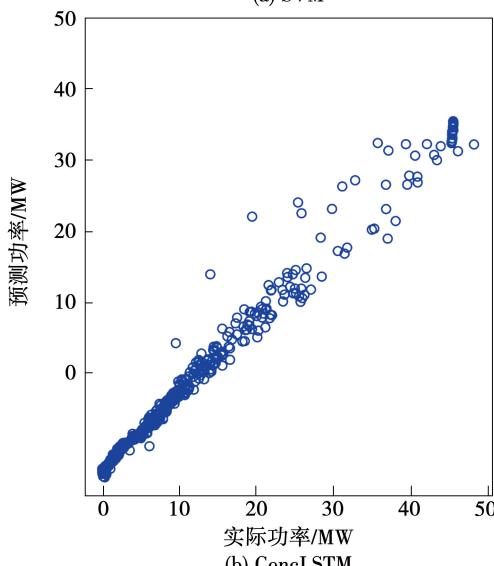
Tab. 2 Prediction performance indexes of different models

模型	MAE	MSE	RMSE	RMSLE	R^2
SVM	10.574	11.123	3.335	1.204	-0.116
ConvLSTM	2.747	3.321	1.822	0.600	0.901
DRNN	1.282	2.664	1.632	0.490	0.970
VAR	1.098	2.537	1.593	0.466	0.973

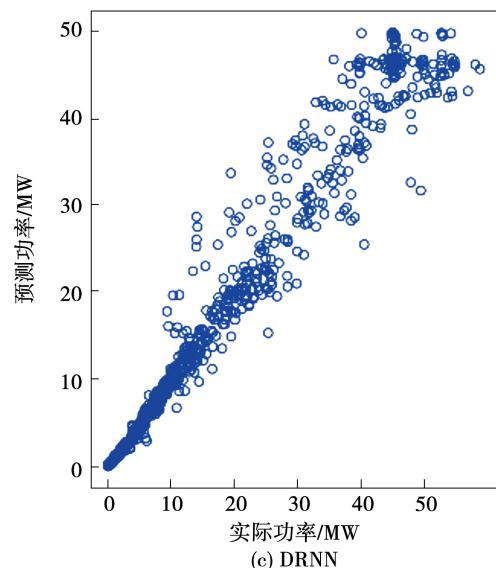
图 7 为各模型预测数据的散点图。可以清楚地看出,各模型的实际和预测数据的一致性。ConvLSTM 预测结果与测量的功率数据的相关性相对较弱。另一方面,基于 DRNN 的模型和 VAE 模型的预测功率与测量功率密切相关。



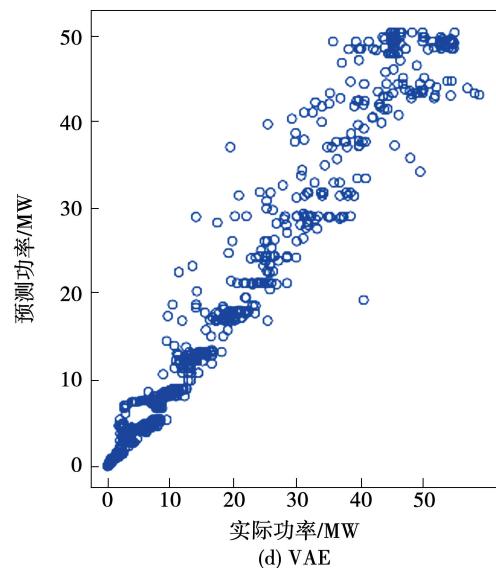
(a) SVM



(b) ConvLSTM



(c) DRNN



(d) VAE

图 7 不同模型的光伏功率预测和测量的散点图

Fig. 7 Scatter graphs of PV power prediction and measurements of different models

图 7 和表 2 中的结果表明,使用基于 DRNN 的模型和 VAE 方法提高了预测性能。误差分析结果表明,这些模型获得的预测精度可以满足实际需要。应该注意的是,VAE 模型是以无监督的方式训练的,这意味着预测仅基于过去数据中的信息。然而,其他模型通过使用训练的子集作为输入序列(x_1, \dots, x_k)和输出变量 x_{k+1} 以监督方式进行训练,训练基于 DRNN 的模型来学习从输入到输出。应用经过训练的模型用于预测新数据。即使 VAE 模型以无监督的方式进行训练,也可以提供与基于 DRNN 的监督模型相当的预测性能。

NRMSE 可以量化预测功率数据时间序列的质量水平,数值越大,表示预测性能越佳。图 8 为电站的 4 种学习模型方法得出的 NRMSE。与 ConvLSTM 和 SVM 模型以及基于 DRNN 的模型相比,VAE 模型更好地实现了光伏潮流的预测。此外,VAE 模型在捕获具有不同时间分辨率的功率数据中的线性和非线性特征方面是有效的。

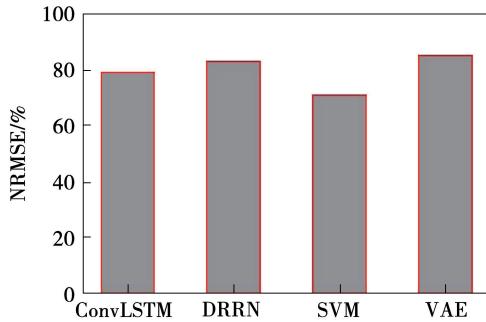


图 8 不同方法模型的 NRMSE

Fig. 8 NRMSE of models by different methods

3.1.3 多步提前功率预测

精确的多步提前预测对于适当管理光伏系统的运行至关重要。基于光伏电站运行数据评估 4 种方法对光伏功率输出进行多步提前预测的能力。对于时间序列 $x = [x_1, x_2, \dots, x_l]$, 计算的单步、两步和多步提前预测分别为 x_{l+1}, x_{l+2} 和 x_{l+n} 。两个光伏电站的 5, 10, 15 步光伏功率数据提前预测结果如表 3 所示。

表 3 多步提前预测的验证指标

Tab. 3 Validation metrics for multistep-step-ahead forecasts

模型	时间步	分钟	RMSE	MAE	R^2	EV
SVM	5	15	32.135	18.617	0.9	0.91
ConvLSTM	5	15	23.47	7.914	0.945	0.955
DRNN	5	15	18.101	8.474	0.952	0.953
VAE	5	15	17.31	7.566	0.956	0.956
SVM	10	30	29.687	19.131	0.89	0.903
ConvLSTM	10	30	24.485	9.707	0.932	0.932
DRNN	10	30	22.458	11.99	0.926	0.93
VAE	10	30	21.461	9.878	0.932	0.932
SVM	15	45	25.172	21.536	0.873	0.863
ConvLSTM	15	45	27.298	11.912	0.92	0.921
DRNN	15	45	26.152	13.208	0.914	0.918
VAE	15	45	23.134	11.664	0.921	0.921

由表 3 可以看出,除了 ConvLSTM,其他模型提前 5 步、10 步、15 步预测都有一致合理的预测结果。VAE 模型 R^2 值达到 0.956, 0.932, 0.921。在大多情况下,DRNN、ConvLSTM 和 VAE 模型在 R^2 、MAPE 和 RMSE 方面的表现大致相同。对于提前 10 步预测,所有模型的 R^2 值都开始下降。在提前 15 步预测中,观察到 SVM 和 ConvLSTM 的预测性能较差。DRNN 和 VAE 模型的整体预测性能较好,随着步数的增加,可以保持合理的预测性能来预测太阳能光伏发电量。

在大多数情况下,DRNN 和 VAE 用于单步和多步提前预测的平均性能略好于其他模型。具有监督学习的 RNN 和具有无监督学习的 VAE 都可以准确地进行一步和多步预测。总体而言,VAE 深度学习模型提供了一种有效的方法来建模和预测 PV 功率输出。

3.2 风电场功率预测

同样,为了验证模型在风电功率预测方向的性能,采集光伏电站同地区同时间段的风电场数据来验证深度学习模型预测方法的性能。光伏电站和风场距离相差约 5 km。该电站于 2017 年 5 月份全部投产,装机容量 50 MW,采集的数据时间从 2021 年 8 月 1 日到 2021 年 10 月 16 日。风电场的实时风速及实际功率曲线如图 9 所示。时间分辨率为 15 min。

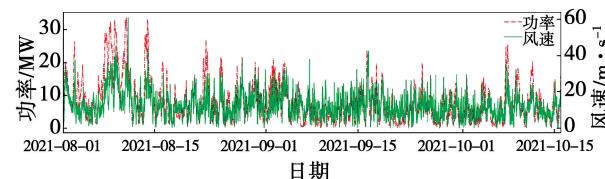


图 9 风电场风速及功率曲线

Fig. 9 Wind speed and power curves of wind farm

图 10 展示了不同模型对应的风电场预测功率与实际功率曲线。由图可以看出,相较于光伏电站功率预测,风电场功率预测整体上效果稍差,在波动趋势和幅值方面预测效果不理想,主要是因为风速变化的随机特性,而日照辐射变化具有一定的周期特性。

表 4 为不同模型下对应的预测性能指标。与光伏功率预测相似,DRNN 的模型和 VAE 方法同样提

高了预测准确度。可以看出,与其他模型相比,DRNN、VAE 模型 R^2 值分别达到了 0.91 和 0.92,意味着数据中的大部分方差被模型捕获。

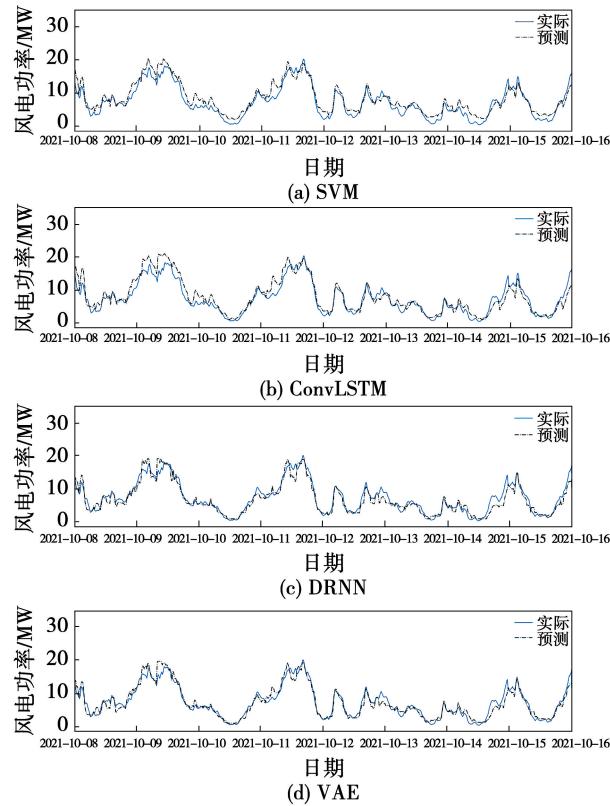


图 10 不同模型预测结果对比

Fig. 10 Comparison of prediction results of different models

表 4 不同模型的预测性能指标

Tab. 4 Prediction performance indexes of different models

模型	MAE	MSE	RMSE	RMSLE	R^2
SVM	2 086.3	2 515.9	50.15	3.91	0.73
ConvLSTM	1 464.5	1 831.8	42.80	3.75	0.86
VAE	1 134.3	1 519.1	38.97	3.66	0.91
DRNN	1 071.7	1 428.8	37.80	3.63	0.92

3.3 风光一体化功率预测

采用光伏和风电预测性能较好的 DRNN 和 VAE 两个模型进行功率一体化预测研究。为便于对比,模型参数选择与光伏预测一致。

图 11 是两种模型下风光一体化功率预测曲线。可以看出,两个模型的风光一体化预测幅值和波动趋势吻合较好。光伏电站数据集、风电场数据集、联

合功率数据集的模型准确性分别达到了 0.948, 0.890, 0.95。相对于风电数据集,模型的一体化预测准确度得到了较大的提升。对于分布在同一区域内的风光场站,资源在空间上的差异性使得风光场站之间通过协同产生了解耦作用,解耦作用一定程度抵消了对方的波动,从而在大的空间尺度上缓解了风光功率的间歇波动性。从曲线可以发现,相较于独立功率曲线,风光功率曲线展现了明显的平滑效应。

由于风能和太阳能产生能量的随机变化特性,单个模型无法准确完整捕捉预测,需要不同的太阳能和风能模型来捕捉。表 5 为两种预测模型组合的预测性能指标。两模型的预测评价指标相近,DRNN 模型的 MAP、MSE、RMSE、RMSLE 值高于 VAE 方法, R^2 值相近。结合独立电站功率预测结果,对于太阳能数据集不同模型间的预测准确度差异较小,而风电数据集不同模型间的预测准确度差异增大。

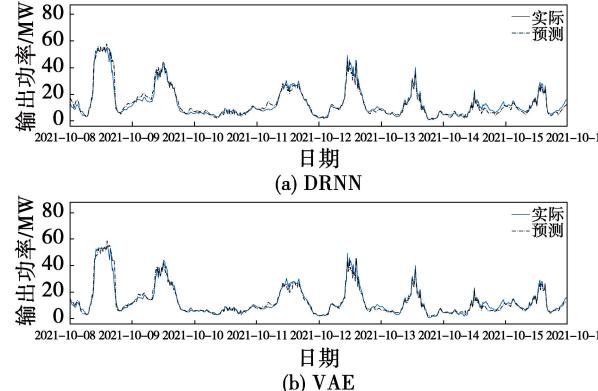


图 11 一体化功率预测曲线

Fig. 11 Integrated power forecast curve

表 5 两种模型的一体化预测性能指标

Tab. 5 Integrated prediction performance indexes of combined two models

模型	MAE	MSE	RMSE	RMSLE	R^2
DRNN	1 822.0	2 866.2	53.5	3.98	0.97
VAE	1 518.5	2 216.7	47.1	3.85	0.96

4 结 论

风能和太阳能功率输出的可靠预测对于能源管理和电力系统的有效运行是必不可少的。本文基于

风电和光伏电站数据对比分析了4种不同预测模型方法的预测性能,基于最优模型进行了风光一体化功率预测。结果表明:

(1) 光伏功率预测VAE模型的RMSE、MAE、RMSLE、 R^2 值分别达到1.593、1.098、0.466、0.98,表明基于VAE的预测方法能够学习更高级别的特征,其预测性能更佳。

(2) 风电功率预测DRNN和VAE模型的 R^2 值分别为0.92和0.91,表明两种模型方法同样能够较好预测风电功率变化趋势,但较太阳能功率预测(光伏功率预测模型的 R^2 值达到0.97)性能差。

(3) 一体化功率预测方面,DRNN和VAE模型的 R^2 值分别为0.96和0.97,表明两种模型方法适用于风光一体化功率预测。本研究为区域集群或基地化电站功率预测提供了可行途径。

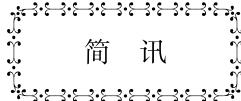
为了进一步提高预测性能,在未来的研究中,需进一步通过结合天气数据来考虑多变量预测及一体化预测中模型参数适用性问题。

参考文献:

- [1] 国家统计局.中华人民共和国2021年国民经济和社会发展统计公报[EB/OL].北京:国家统计局,2022[2022-02-28].
<http://www.tjcn.org/tjgb/00zg/36925.html>.
National Bureau of Statistics of China. Statistical communiqué of the People's Republic of China on the 2021 national economic and social development[EB/OL]. Beijing: National Bureau of Statistics of China, 2022 [2022-02-28]. <http://www.tjcn.org/tjgb/00zg/36925.html>.
- [2] LAI Chang-wei, LI Jing-hua, CHEN Bo, et al. Review of photovoltaic power output prediction technology[J]. Transactions of China Electrotechnical Society, 2019, 34(6):1201-1217.
- [3] BAI X, LIANG L, ZHU X. Improved Markov-chain-based ultra-short-term PV forecasting method for enhancing power system resilience[J]. Journal of Engineering, 2021, 2021(2):114-124.
- [4] 李冰,张妍,刘石.基于LSTM的短期风速预测研究[J].计算机仿真,2018,35(11):468-473.
LI Bing, ZHANG Yan, LIU Shi. Wind speed short term prediction study based on LSTM[J]. Computer Simulation, 2018, 35(11): 468-473.
- [5] 田剑刚,张沛,彭春华,等.基于分时长短期记忆神经网络的光伏发电超短期功率预测[J].现代电力,2020,37(6):629-638.
TIAN Jian-gang, ZHANG Pei, PENG Chun-hua, et al. Ultra short term forecast of photovoltaic generation based on time-division long short term memory neural networks[J]. Modern Electric Power, 2020, 37(6):629-638.
- [6] 白永祥,房大中,侯佑华,等.内蒙古电网区域风电功率预测系统[J].电网技术,2010,34(10):157-162.
BAI Yong-xiang, FANG Da-zhong, HOU You-hua, et al. Regional wind power forecasting system for Inner Mongolia power grid[J]. Power System Technology, 2010, 34(10):157-162.
- [7] 崔杨,陈正洪,许沛华.基于机器学习的集群式风光一体短期功率预测技术[J].中国电力,2020,53(3):1-7.
CUI Yang, CHEN Zheng-hong, XU Pei-hua. Short-term power prediction for wind farm and solar plant clusters based on machine learning method[J]. Electric Power, 2020, 53(3):1-7.
- [8] 刘永前,林爱美,阎洁,等.基于深度学习的风光场群功率预测方法研究[J].分布式能源,2021,6(2):14-21.
LIU Yong-qian, LIN Ai-mei, YAN Jie, et al. Research on power forecasting method for wind farms and photovoltaic stations based on deep learning[J]. Distributed Energy, 2021, 6(2):14-21.
- [9] 林爱美.基于多任务学习的风光电站群功率预测方法研究[D].北京:华北电力大学(北京),2021.
LIN Ai-mei. Research on multi-task learning based method for power forecasting wind and solar power station cluster[D]. Beijing: North China Electric Power University, 2021.
- [10] 黄亚峰,何威,吴光琴,等.基于K-means++和LSTM网络的光伏功率预测研究[J].电气自动化,2020,42(5):25-27,34.
HUANG Ya-feng, HE Wei, WU Guang-qin, et al. Research on photovoltaic power prediction based on K-means++ and LSTM network[J]. Electrical Automation, 2020, 42(5):25-27,34.
- [11] WANG Ke-jun, QI Xiao-xia, LIU Hong-da. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. Applied Energy, 2019, 251:113315.1-113315.14.
- [12] RANA M, RAHMAN A. Multiple steps ahead solar photovoltaic power forecasting based on univariate machine learning models and data re-sampling[J]. Sustain Energy Grids and Networks, 2020, 21:100286.1-100286.15.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6):84-90.
- [14] YOUNG T, HAZARIKA D, PORIA S, et al. Recent trends in deep learning based natural language processing[J]. IEEE Computational Intelligence Magazine, 2018, 13(3):55-75.
- [15] GRAVES A, RAHAMN M A, HINTON G. Speech recognition with deep recurrent neural networks[C]//Canada: In Proceedings of the 2013 IEEE International Conference on Acoustics, 2013.

- [16] ZEROUAL A, HARROU F, DAIRI A, et al. Deep learning methods for forecasting COVID-19 time-series data: a comparative study[J]. Chaos Solitons Fractals, 2020, 140: 110–121.
- [17] LI Gang-qiang, WANG Huai-zhi, ZHANG Sheng-li, et al. Recurrent neural networks based photovoltaic power forecasting approach[J]. Energies, 2019, 12(13): 1–17.
- [18] WANG Fei, XUAN Zhi-ming, ZHAO Zhen, et al. A day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework[J]. Energy Conversion and Management, 2020, 212: 112766. 1 – 112766. 14.
- [19] APRILLIA H, YANG H T, HUANG C M. Short-term photovoltaic power forecasting using a convolutional neural network-salp swarm algorithm[J]. Energies, 2020, 13(8): 1 – 20.
- [20] SHI Xing-jian, CHEN Zhou-rong, WANG Hao, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[J]. Computer Vision and Pattern Recognition, 2015, 28: 802 – 810.
- [21] DOERSCH C. Tutorial on variational autoencoders[OL]. Eprint arXiv:1606.05908, 2016.
- [22] KEMPINSK K, MURCIO R. Modelling urban networks using variational autoencoders[J]. Applied Network Science, 2019, 114: 1 – 11.
- [23] KINGMA D, SALIMANS T, JOSEFOWIEZ R, et al. Improving variational inference with inverse autoregressive flow[C]//Barcelona: 30th Conference on Neural Information Processing Systems, 2016.

(丛 敏 编辑)



简讯

罗尔斯·罗伊斯公司宣布成功完成 UltraFan 技术演示机的首次测试

据官网5月18日报道,罗尔斯·罗伊斯公司已经在其位于英国德比的工厂成功完成了其 UltraFan 技术演示机的首次测试。第一次测试使用 100% 可持续航空燃料(SAF)进行。UltraFan 的效率比 Trent XWB 提高了 10%, Trent XWB 已经是世界上最高效的大型航空发动机。

测试在世界上最大、最智能的室内航空发动机测试设施——Testbed 80 上进行。

演示机的主要工程特征包括:

一个新的经过验证的 Advance 3 发动机核心架构,结合 ALECSys 贫燃燃烧系统,提供最大的燃油燃烧效率和低排放性能;碳钛风扇叶片和复合外壳;齿轮传动设计,为未来的高推力、高涵道比发动机提供高效动力;动力变速箱的功率为 64 MW,创下了航空航天业的纪录。

(孙嘉忆摘译自 <https://www.rolls-royce.com>)