

基于SVR-LSTM-BP的分布式光伏短期出力预测方法研究

李俊伟, 龚新勇, 朱元富, 辛平安

(云南电网有限责任公司昆明供电局, 云南 昆明 650200)

摘要: 提出一种分布式光伏短期出力组合预测方法, 以 BP 神经网络耦合支持向量回归 (Support Vector Regression, SVR) 和长短期记忆 (Long Short-Term Memory, LSTM) 神经网络实现组合预测。首先分别构建两个单一模型: 以高斯径向基函数为核函数的支持向量回归模型和三层长短期记忆神经网络, 并分别预测, 再通过三层 BP 神经网络将前两个单一模型的预测结果耦合并输出, 以提高预测的准确度。利用江苏某光伏发电装置采集的真实数据进行仿真验证, 得出结论: SVR-LSTM-BP 模型的准确度与 SVR 模型相比有显著提高, 而与 LSTM 模型接近, 稳定性则比 LSTM 模型有一定提高。

关键词: 分布式光伏发电; 光伏出力预测模型; 支持向量回归; 长短期记忆神经网络; BP 神经网络

A research on short-term distributed photovoltaic power prediction model based on SVR-LSTM-BP

LI Junwei, GONG Xinyong, ZHU Yuanfu, XIN Pingan

(Kunming Power Supply Bureau of Yunnan Power Grid Co., Ltd., Kunming 650200, China)

Abstract: A new combined prediction model for short-term distributed photovoltaic output is proposed, using support vector regression (SVR), long short-term memory neural network (LSTM) and backpropagation neural network (BP). Two simple models using SVR with Gaussian radial basis function and 3-layer LSTM are constructed, respectively. Then, to increase the prediction accuracy, the outputs of the two simple models are combined by a 3-layer BP neural network. Numerical experiments based on the real data of a photovoltaic power station in Jiangsu Province shows that the SVR-LSTM-BP model has a significantly improved prediction accuracy than that of the SVR model, which is close to that of the LSTM model. The stability of the SVR-LSTM-BP model is slightly improved than that of the LSTM model.

Key words: distributed photovoltaic power generation; photovoltaic output prediction model; support vector regression; long short-term memory neural network; backpropagation neural network

0 引言

为应对全球气候变化, 世界多国相继提出了碳中和目标。2020年9月, 习近平主席指出, 中国将力争于2030年实现碳达峰, 2060年前实

现碳中和。太阳能发电是实现碳中和的重要手段之一, 在全球能源结构加速调整的背景下, 太阳能利用已实现跃升式发展。党的十八大以来, 我国已成为全球最大的可再生能源市场。目前, 我

国光伏发电规模位列世界第一。光伏发电受太阳辐射强度等气象因素影响,具有随机性、波动性和间歇性的特点,对电网的安全稳定运行是很大挑战,对光伏出力进行预测具有重要意义。

《“十四五”现代能源体系规划》中提出,要增强电源协调优化运行能力,提高光伏发电功率预测水平。

学术界针对光伏发电出力预测有大量研究,常见的预测方法有BP神经网络^[1-2]、梯度下降决策树(Gradient Boosting Decision Tree, GBDT)^[3]、多元线性回归^[4]和随机森林^[5]等方法。

支持向量机(Support Vector Machine, SVM)由Cortes^[6]于1995年正式提出,由于在文本分类中显示出卓越性能^[7],SVM很快成为当时的机器学习主流技术,这一风潮一直持续到深度学习的兴起。SVM通过映射函数将输入变量映射到一个高维度的特征空间,并在这个高维度的特征空间内构造线性函数,保证模型的泛化性能^[8]。SVM基于结构风险最小化原则设计,通过设置罚函数兼顾经验风险最小化^[9],广泛应用于光伏出力预测^[10-11]。SVM最初是一种分类模型,经过一定改进后可用于回归预测,称为支持向量回归(Support Vector Regression, SVR)。

长短时记忆(Long Short-Term Memory, LSTM)网络是一种改进的循环神经网络(Recurrent Neural Network, RNN),是由文献[12-13]提出的解决传统RNN长时学习问题的门网络(Gate Network)。LSTM具有跨多时间步长传递信息的能力,被广泛应用于各领域^[14],常用来预测光伏功率^[15-16]。

BP神经网络作为众多人工神经网络实现方法之一,是迄今为止研究最成熟、应用最广泛的人工神经网络模型之一^[17],也是一种监督学习模型。神经网络方法有分布并行处理、自适应学习、非线性映射和泛化能力的特征,对于光伏集群预测具有强适应能力^[18]。

基于上述分析,本文利用BP神经网络耦合SVR和LSTM模型实现组合预测,提出一种分布

式光伏短期出力的组合预测方法,并验证该模型的有效性和准确性。

1 数据来源和处理

本文研究的是数据驱动的分布式光伏短期出力预测,原始数据仅包含历史发电功率,并不直接包含对发电功率影响很大的天气因素数据。在此场景下,对海量历史大数据进行学习的方法通常并不适用,因为即使一个模型对历史数据拟合得很好,也无法从中提取天气特征用于预测,而在没有很好提取天气特征的情况下,单纯学习海量历史数据很容易过拟合。因此,本文的方法是基于少量数据学习的,具体来说,以前7日的历史数据作为训练集学习,预测第8日24 h的出力数据。

本文所使用的数据来自江苏省某分布式光伏发电装置2019年1月1日—12月31日全年的真实数据,采样频率为每15 min一次。对数据初步分析后发现,该装置发电时段最多为5:00~19:00,因此只需截取每日这一时段的数据,每日共有57个采样数据。

用min-max方法将原始数据归一化,具体公式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, x' 为原始数据 x 归一化后的值; $x_{\min}$ 和 $x_{\max}$ 分别为原始数据中的最小值和最大值。

归一化后原始数据都映射到[0, 1]区间。

2 预测模型构建

2.1 支持向量回归(SVR)预测

SVR模型的数学描述:假设有 n 个 m 维训练样本 $D = \{(x_i, y_i) | i=1, \dots, n\}$,其中 $x_i \in R^m$ 是输入变量, $y_i \in R$ 是输出变量,设非线性映射函数为 $\phi(x)$,目标是学习到一个函数 $f(x) = w^T \phi(x) + b$,使得它与 y 尽可能接近,其中 w 和 b 是需要学习的参数, w 为权值向量, b 为偏置。对样本 (x, y) ,SVR模型假设能容忍 $f(x)$ 与 y 之间最多有 δ 的偏差,当且仅当 $f(x)$ 与 y 的差别绝对值大于 δ 时才计

算损失。此时相当于以 $f(x)$ 为中心, 构建一个宽度为 2δ 的间隔带, 若训练样本落入此间隔带, 则认为是被预测正确。因此, SVR的损失函数可表示为

$$l_\epsilon(z) = \begin{cases} 0 & \text{if } |z| \leq \delta \\ |z| - \delta & \text{otherwise} \end{cases} \quad (2)$$

引入松弛变量 ξ_i 、 ξ_i^* 和惩罚因子 C 后, SVR的数学模型可表示为

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \\ \text{s.t. } w^T \phi(x_i) + b - y_i \leq \delta + \xi_i \\ y_i - w^T \phi(x_i) - b \leq \delta + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, \dots, n \end{cases} \quad (3)$$

将SVR模型转换为对偶形式

$$\begin{cases} \max_{\alpha, \alpha^*} \sum_{i=1}^n (\alpha_i^* - \alpha_i) y_i - \sum_{i=1}^n (\alpha_i + \alpha_i^*) \delta - \\ \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) \kappa(x_i, x_j) \\ \text{s.t. } \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C \end{cases} \quad (4)$$

式中, $\kappa(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 为核函数。

上述过程中须满足KKT条件, 即要求

$$\begin{cases} \alpha_i (w^T \phi(x) + b - y_i - \delta - \xi_i) = 0 \\ \alpha_i^* (-w^T \phi(x) - b + y_i - \delta - \xi_i^*) = 0 \\ \alpha_i \alpha_i^* = 0, \xi_i \xi_i^* = 0 \\ (C - \alpha_i) \xi_i = 0, (C - \alpha_i^*) \xi_i^* = 0 \end{cases} \quad (5)$$

SVR的解形如

$$f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \kappa(x_i, x_j) + b \quad (6)$$

在对数据没有任何先验假设的情况下, 一般选择高斯核函数(也称RBF核), 即

$$\kappa(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (7)$$

式中, $\sigma > 0$ 称为高斯核的带宽。

本文也选取高斯核函数。实验时SVR模型的各个参数由程序自动寻优确定。

本文使用SVR回归预测的方法是逐点预测, 即将前7日同一时间点的发电功率作为SVR

的输入, 将预测值作为第8日此时间点的预测值。这样设计的原因在于, 每日同一时间点的太阳照射角在8日的时间范围内变化不大, 因此认为8日内每日同一时间点的发电功率有一定的相关性。

2.2 LSTM预测模型

LSTM是RNN的一种, 传统RNN处理序列数据, 网络的输出依赖当前输入和前序输入及输出, 可以学习数据中的序列相关性。RNN中, 对输入序列 $\text{seq}_{\text{in}} = \{x_1, \dots, x_n\}$, 在时间步(time-step)为 t 时, 输出值 y_t 可表示为

$$\begin{aligned} h_t &= \sigma_h(W_h x_t + U_h h_{t-1} + b_h) \\ y_t &= \sigma_y(W_y h_t + b_y) \end{aligned} \quad (8)$$

式中, h_t 为隐藏层在 t 时刻的输出, 与上期隐藏层输出 h_{t-1} 和本期输入 x_t 有关; σ 为激活函数。

典型的RNN结构如图1所示。




图1 典型的RNN结构

Fig. 1 Typical RNN structure

RNN的一个显著缺陷是只能学到较短的时序关系, 当序列过长时易引起梯度爆炸或梯度消失现象。LSTM则较好地解决了这一问题。LSTM由一个个记忆块构成, 记忆块内包含多个小的神经元, 主要为记忆单元(Cell)、输入门(Input Gate)、输出门(Output Gate)和遗忘门(Forget Gate)。LSTM网络的基本单元结构如图2所示。

其中, 输入门和输出门用来接收、输出和修正参数, 遗忘门作用是有选择地清除特定修正参数, 记忆单元(Cell)是记录保存神经元目前状态的单元。

本文使用连续7日的发电功率数据作为训练集, 步长设为8, 隐含层数设为3, 训练LSTM模型后用其预测第8日的出力数据。




图2 LSTM网络的基本单元结构

Fig. 2 Basic unit structure of LSTM network

2.3 BP神经网络耦合SVR和LSTM模型

BP神经网络的拓扑结构包括输入层、隐含层及输出层,典型的神经网络结构如图3所示^[19]。




图3 BP神经网络结构

Fig. 3 BP Neural network structure

本文使用BP神经网络耦合SVR和LSTM模型,其流程如图4所示。




图4 SVR-LSTM-BP模型流程图

Fig. 4 Flow chart of SVR-LSTM-BP model

利用SVR和LSTM获得的预测结果作为训练集来训练BP神经网络。具体步骤为:SVR和LSTM模型训练好后,对样本 (x_i, y_i) 分别用这两个模型预测,得到预测值记为 $SVR(x_i)$

和 $LSTM(x_i)$,再将二维向量 $(SVR(x_i), LSTM(x_i))$ 和对应的真实值 y_i 作为输入来训练BP神经网络,即BP神经网络的学习样本是 $((SVR(x_i), LSTM(x_i)), y_i)$ 的形式。BP神经网络的训练使用的是小样本,以SVR和LSTM连续7日的预测值和对应的真实值为训练集,训练好后用来预测第8日的出力数据。

当BP神经网络训练好后用于预测时,对新的输入变量 x ,先用SVR和LSTM模型做预测,得到一组预测值 $(SVR(x), LSTM(x))$,再将此向量输入BP神经网络得到新的预测值。

对于BP神经网络中隐含层的数目,可根据下式设定^[20]

$$y = \sqrt{n+m} + a \quad (9)$$

式中, y 为隐含层的数目; m 和 n 分别为输出值和输入变量的维数; a 为1~10的常量。

本文中,输入变量维数为2,输出值维数为1,根据式(9)可得隐含层数目范围为3~13。

隐含层的数目通过实验方法确定,具体做法:首先用训练好的SVR和LSTM模型对全年的所有时间点做预测,与对应的真实值一起组成形如 $((SVR(x_i), LSTM(x_i)), y_i)$ 的向量,作为BP神经网络的备选训练集;然后将BP神经网络备选训练集中的数据编组,连续8日的数据作为一组,再从所有编组中随机抽取30组,假设隐含层数目固定为 l ,对一个编组数据,将其中前7日数据作为训练集,第8日数据作为测试集,用该训练集训练一个 l 层的BP神经网络,并求该网络在测试集上的预测值和真实值之间的误差;在30组数据上做同样的计算,之后求BP神经网络的平均误差;再令 l 从3变化至13,分别计算 l 取不同值时BP神经网络在30组数据上的平均误差,将产生平均误差最小的 l 定为隐藏层数量。其中,误差的度量选用均方根误差(RMSE),这是在光伏发电功率预测中常用的表征预测准确度的方法^[21]。均方根误差的计算公式为

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (10)$$

式中, n 为样本个数; $\hat{y}_i$ 和 y_i 分别为第 i 个样本的

预测值和真实值。

通过实验得到的BP神经网络隐含层数量与平均误差的关系如图5所示,因此最终确定BP神经网络隐藏层数量为3。




图5 BP神经网络隐含层数量与平均误差的关系

Fig. 5 Relationship between the number of hidden layers and the average error of BP neural network

SVR、LSTM以及BP神经网络所处理的数据都是归一化后的,最终对BP神经网络的预测结果要做反归一化处理再输出,即

$$x'' = x'(x_{\max} - x_{\min}) + x_{\min} \quad (11)$$

式中, x' 为归一化的数据; x'' 为反归一化后的结果。

由于 $x_{\min}=0$, 式(11)可简化为 $x''=x'x_{\max}$ 。

3 实验结果与分析

本文实验编程语言为Python (V3.9), SVR模型通过Scikit-learn学习库实现, LSTM和BP神经网络的运行环境前端为Torchkeras, 后端为Pytorch。以江苏省沛县某分布式光伏发电装置为例, 将数据预处理后分别输入SVR、LSTM模型预测, 再用BP神经网络模型耦合SVR和LSTM的预测结果, 经反归一化后输出。

在用SVR模型预测时, 模型参数可由Scikit-learn学习库程序自动寻优确定。在LSTM预测模型中, 步长设为8, 隐含层数设为3。

不同算法模型的光伏发电功率预测结果逐点(第一个预测日的57个时间点)对比, 如图6所示。

为了测试不同模型在夏季典型、冬季典型和一般场景下的表现, 故选取了三组不同的数据集分别测试, 分别是1月全月数据、7月全月数据和全年平均抽取的30组数据。在对三组数据用不同

模型预测后, 得出各模型在测试集上的平均误差(RSME), 见表1。




图6 不同模型对发电功率预测结果

Fig. 6 Prediction results of generation power by different models

表1 不同模型的平均误差

Tab. 1 Average error of different models

场景	模型		
	SVR	LSTM	SVR-LSTM-BP
全年平均	2.33	1.34	1.57
夏季典型	2.41	1.48	1.69
冬季典型	2.41	1.04	1.32

容易看出, SVR-LSTM-BP模型准确率相比于SVR模型有显著改进, 与LSTM模型较为接近。

为了衡量模型的稳定程度, 对每个模型在三种场景下的误差求标准差, 得到的结果见表2。

表2 不同模型三种场景下误差的标准差

Tab. 2 Standard deviation of errors in three scenarios of different models

模型	SVR	LSTM	SVR-LSTM-BP
三种场景下误差的标准差	0.037 7	0.183 6	0.154 1

由表2可知, SVR模型最稳定, LSTM最不稳定, SVR-LSTM-BP居中, 比LSTM略优。

4 结束语

本文研究了分布式光伏短期出力预测问题, 提出了SVR-LSTM-BP组合模型。以江苏某光伏发电装置实测数据为例, 测试了SVR-LSTM-BP模型与单一SVR和LSTM模型在全年平均、夏季典型和冬季典型三种场景下的表现并进行比较, 得出结论: 准确度方面, SVR-LSTM-BP模型相较于SVR模型有显著改进, 而比LSTM模型略

低；稳定性方面，SVR最稳定，而SVR-LSTM-BP比LSTM稳定性有一定提高。因此，SVR-LSTM-BP在一定程度上兼具了SVR的稳定性和LSTM准确性的优点。

参考文献

- [1] 李旭. 基于典型日出力特性分析的光伏电站功率预测研究[D]. 北京: 华北电力大学, 2016.
- [2] 李松威. 基于神经网络的光伏发电功率预测研究[D]. 沈阳: 沈阳工程学院, 2017.
- [3] 郑凯文, 杨超. 基于迭代决策树 (GBDT) 短期负荷预测研究[J]. 贵州电力技术, 2017, 20(2): 82-84.
- [4] DE GIORGI M G, CONGEDO P M, MALVONI M. Photovoltaic power forecasting using statistical methods: impact of weather data[J]. IET Science, Measurement and Technology, 2014, 8(3): 90-97.
- [5] AHMAD M W, MOURSHED M, REZGUI Y. Tree-based ensemble methods for predicting PV power generation and their comparison with support vector regression[J]. Energy, 2018, 164: 465-474.
- [6] CORTES C, VAPNIK V N. Support vector networks[J]. Machine Learning, 2015, 20(3): 273-297.
- [7] JOACHIMS T. Text classification with support vector machines: Learning with many relevant features[C]. In Proceedings of the 10th European conference on Machine Learning (ECML), 1998: 137-142, Chemnitz, Germany.
- [8] 胡智强, 黄南天, 王文婷, 等. 基于布谷鸟搜索优化支持向量机的短期负荷预测[J]. 水电能源科学, 2016, 34(12): 673-680.
- [9] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- [10] 姜恩宇, 季亮, 夏能弘, 等. 基于支持向量机的光伏发电功率预测[J]. 上海电力学院学报, 2015, 31(6): 511-513, 524.
- [11] 张雨金, 周杭霞. Stacking-SVM的短期光伏发电功率预测[J]. 中国计量大学学报, 2018, 29(2): 121-127.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [13] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks[C]. In IEEE International Conference on Acoustics, Speech and Signal Processing, May 26-31, 2013, Vancouver, Canada.
- [14] JIN L, XIONG C, LIU H. Improved bilateral filter for suppressing mixed noise in color images[J]. Digital Signal Processing, 2012, 22(6): 903-912.
- [15] 李丰君, 王磊, 赵健, 等. 基于天气融合和 LSTM 网络的分布式光伏短期功率预测方法[J/OL]. 中国电力. <https://kns.cnki.net/kcms/detail/11.3265.TM.20220217.0933.006.html>
- [16] 卿会, 郭军红, 李薇, 等. 利用SVM-LSTM-DBN的短期光伏发电预测方法[J]. 华侨大学学报 (自然科学版), 2022, 43(3): 371-378.
- [17] KALOGIROU S A. Artificial neural networks in renewable energy systems applications: A review[J]. Renewable and Sustainable Energy Reviews, 2001, 5(4): 373-401.
- [18] 孙东磊, 王艳, 于一潇, 等. 基于 BP 神经网络的短期光伏集群功率, 山东大学学报 (工学版), 2020, 50(5): 70-76.
- [19] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2020.
- [20] 李志宽. 光伏并网微逆变器监控系统研究[D]. 广州: 华南理工大学, 2016.
- [21] 胡俊灵. 基于深度学习算法的短期光伏发电功率预测研究[D]. 广州: 广东工业大学, 2019.

作者简介

李俊伟 (1991—), 男, 本科, 工程师, 主要从事电网运行方式安排策划工作。

(收稿日期: 2022-10-08)