

[光伏]

# 基于LSTM-SVR组合模型的光伏电站短期功率预测

文/朱东垣<sup>1</sup> 胡陆明<sup>2</sup> 柳想<sup>3</sup> 那正<sup>1</sup>

1. 沈阳工程学院电力学院; 2. 国网西咸新区供电公司; 3. 沈阳农业大学信息与电气工程学院

提出了一种基于长短期记忆网络和支持向量回归混合模型的光伏功率预测方法。通过对SVR模型引入松弛变量,对LSTM模型中较大的预测误差进行修正,从而达到更好的预测准确度。构建支持向量回归的长短期记忆混合网络(LSTM-SVR)光伏功率短期预测模型与LSTM模型一同预测并进行对比,得出指标量化预测误差结果。

当前,环境破坏与能源缺乏是世界范围内多个国家和地区需要面对的问题,这些问题已经严重阻碍了世界经济和社会的进步。为缓解这些问题,需要加大力度开发太阳能等可再生资源。光伏发电是对于太阳能的一种非常有代表性的利用方式,因为其具有清洁环保,对生态环境很友好,且不需要任何会污染环境的燃料等优势,故得到了普遍的开发和运用。

随着国内光伏产业的发展,关于光伏功率预测的相关学术研究正在受到更多学者的关注。文爽等人提出一种基于GWO算法耦合EEMD技术和BP神经网络算法构建复杂天气情形下,光伏电站发电功率有效预测模型,实现了复杂气象条件下光伏电站发电功率的准确预测,以减少并网冲击。谭海旺等人提出一种基于极端梯度提升(XGBoost)模型和长短期记忆网络(Long Short-term Memory, LSTM)模型的短期光伏发电功率预测组合模型,实验结果表明提出的方法相比随机森林、GBDT模型、单一的XGBoost模型和LSTM模型具有更高的预测准确度。姜文玲等人针对采用竖直安装的水平辐照度,提出辐照度斜面转换方法,解决由于不是倾斜安装光伏板而产生预测准确度不足的问题。程序等人提出一种实时辐射采集技术。这种

技术在晴空当中可实时监测采集并预测超短期功率,预测效果较好,满足国家要求的工程标准。Eseye等人提出了一种混合预测模型,用于光伏电站的短期发电预测。Zhang W等人提出一种改进天气聚类的方法,与马尔可夫链相结合便可进行预测。程启明等人使用神经网络法预测光伏电站短期功率,在对天气类型进行分类时使用密度峰值的层次聚类算法。王育飞等人提出了一种函数预测模型来预测光伏功率。苗言明等人通过对算法按照误差的大小分配权重,通过组合灰色模型和极限学习机两种方法来预测模型,提高了预测准确度。蒋峰等人首先应用灰色模型进行数据预测,然后使用马尔可夫链模型结合各自的特点对光伏发电量进行修正。刘博洋等人对光伏功率组合预测模型进行优化,解决了预测准确度不高的问题,但未对复杂气象类型下的光伏功率预测继续研究。赵亮等人为了提高对光伏输出功率准确度的预测,建立基于深度信念网络(Deep Belief Network, DBN)的短期光伏出力预测模型。赵滨滨等人提出了一种分布式光伏系统输出功率混合预测方法。Lee D&Kim K提出了一种基于深度学习的光伏功率预测模型,可以通过学习天气现象和季节的信息,提高模型对于光伏功率预测的性能。刘国海等

人提出一种结合注意力机制（Attention）与门控循环单元（GRU）的Attention-GRU短期光伏发电功率预测模型，解决了传统长短时记忆神经网络参数量较多以及在处理长时间序列时容易忽略重要时序信息的不足。商立群等人针对光伏发电功率存在随机性和波动性较强、预测准确度较低的问题，提出了一种基于变分模态分解（Variational Mode Decomposition, VMD）和改进松鼠觅食算法优化核极限学习机（Improved Squirrel Search Algorithm optimization Kernel Extreme Learning Machine, ISSA-KELM）的预测模型，结果表明：所提出的VMD-ISSA-KELM模型在不同天气条件下均能得到满意的预测精度，且明显优于其他模型。贾凌云等人针对用于光伏发电短期功率预测的人工神经网络模型和深度学习模型进行总结和评述，提出组合模型整体上优于单一预测模型。因此本文建立了基于神经网络的光伏改进后的组合功率预测模型（Long Short-term Memory-Support Vector Regression, LSTM-SVR），对神经网络算法进行了改进，并提高了预测准确度。

本文搭建LSTM与LSTM-SVR神经网络，沿用RNN模型使用的数据集对LSTM与LSTM-SVR模型进行训练，分别得出LSTM与LSTM-SVR模型短期预测的相关评价指标。与RNN预测模型进行对比，根据短期预测的相关评价指标进行分析，结果表明了LSTM-SVR神经网络拥有较好的泛化能力，能克服出现局部优化问题。

## 算法介绍

### 1. LSTM神经网络模型

LSTM与RNN在结构上相似，在此基础上LSTM改进了隐含层的结构，不仅添加了外部自循环模块，同时引入了“细胞（cell）”模块，在cell中包含“输入门（Input）”“遗忘门（Forget）”“输出门（Output）”三类不同的“门”以及存储单元。三类门具有保持和控制信息的功能。Input将当前 $t$ 时刻的信息筛选，存入单元状态；Forget将历史 $t-1$ 时刻产生的信息筛选，存入单元状态；Output控制是否将存储的信息作为输出。通常选择Sigmoid函数作为门的激活函数，当门单元输出1时，门单元打开；当输出0时，门单

元关闭。tanh也可以作为输入与输出的激活函数。LSTM神经网络为了减轻梯度消失的问题，通过引入门的概念，增加存储器存储和访问信息的时间。

LSTM创新之处在于模型结构中的隐藏层，隐藏层由储存单元构成，通过记忆单元实现信息状态确定及储存。LSTM主要由输入门 $f_i$ ，输出门 $o_i$ 和遗忘门 $i_i$ 三部分组成。输入门所代表的是输入给控制记忆单元有用的信息数据，输出门的含义是实输出信息数据，遗忘门的含义在于遗忘控制记忆单元的无用信息数据。LSTM结构示意图如图1所示。




图1 LSTM结构示意图

现将 $(x_1, x_2, \dots, x_n)$ 假设为输入序列， $(h_1, h_2, \dots, h_n)$ 作为隐藏层状态，首先选择要遗忘的信息，遗忘部分由输入 $x_t$ 和中间输出 $h_{t-1}$ 共同决定。

在 $t$ 时刻，遗忘门将本单位的 $x_t$ 和上一单元的输出生 $h_{t-1}$ 作为输入，通过激活函数得到 $f_i$ ，并将 $f_i$ 传递给上一时刻细胞状态 $C_{t-1}$ ， $f_i$ 计算公式为

$$f_i = \sigma(W_f [c_{t-1}, h_{t-1}, x_t] + b_f) \quad (1)$$

式中， $\sigma$ 为sigmoid函数； $W_f$ 为遗忘门与输入 $x_t$ 和中间输出 $h_{t-1}$ 乘积的矩阵权重； $b_f$ 为遗忘门的偏移量。

计算输入门，选择要记忆的信息。

输入门将本单元的输入 $x_t$ 和上一单元的输出生 $h_{t-1}$ 作为输入，通过激活函数得到输入门的输出 $i_t$ ，同时产生 $t$ 时刻细胞候选状态 $c_t$

$$i_t = \sigma(W_f [c_{t-1}, h_{t-1}, x_t] + b_i) \quad (2)$$

式中， $W_f$ 为输入门与输入 $x_t$ 和中间输出 $h_{t-1}$ 乘积的矩阵权重； $b_i$ 为输入门的偏移量。

$$c_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \quad (3)$$

式中， $\tanh$ 为候选状态单元的激活函数； $W_c$ 为候选状态单元与输入 $x_t$ 和中间输出 $h_{t-1}$ 乘积的矩阵权重；

$b_c$ 为候选状态单元的偏移量。

更新当前时刻的细胞状态。

计算当前时刻的 $c_t$ ，可由 $f_t$ 和 $i_t$ 分别与上一时刻 $c_{t-1}$ 和当前时刻 $c_t$ 组合得到

$$c_t = f_t c_{t-1} + i_t c_t \quad (4)$$

在 $t$ 时刻，细胞单元中的输出门结果和可记忆信息的隐藏层状态计算如下。

首先将本单元的输入 $x_t$ 和上一单元的输出 $h_{t-1}$ 作为输出门的输入，通过激活函数得到输出门的结果 $o_t$ ，将更新后的细胞状态值使用 $\tanh$ 函数激活，再与相乘得到最终的输出结果，其中 $o_t$ 和 $h_t$ 为

$$o_t = \sigma(W_o[c_t, h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \tanh(c_t) \quad (6)$$

式中， $\sigma$ 为sigmoid函数； $W_o$ 为输出门与输入 $x_t$ 和中间输出 $h_{t-1}$ 乘积的矩阵权重； $b_o$ 为输出门的偏移量； $x_t$ 为输入参数； $h_t$ 为输出参数； $o_t$ 为输出门的输出参数； $c_t$ 为 $t$ 时刻神经元的状态。

## 2. 支持向量机回归

支持向量回归（Support Vector Regression, SVR）是支持向量机（Support Vector Machine, SVM）在回归预测上的模型应用。为了在一定程度上避免“维数灾难”等问题，采用的原则是结构风险最小化。

支持向量线性回归模型为

$$f(x) = w^T x + b \quad (7)$$

式中， $w$ 为输入向量的法向量； $b$ 为偏差值。

SVR模型的预测结果允许存在一定的误差 $\epsilon$ ，若光伏功率的预测数据在预测值 $f(x)$ 两侧 $2 \times \epsilon$ 的范围内，就可以说明预测结果是对的，最靠近误差范围的输入向量为“支持向量”。为最大程度地降低损失，可以通过最小化法向量 $w$ 的欧几里得范数实现，SVR问题变为

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m l \in (f(x_i) - y_i) \alpha \quad (8)$$

$$\alpha, C > 0 \quad (9)$$

式中， $C$ 为正则化常数，前项表明在预测值都在误差可允许范围内，后项使用 $\epsilon$ 不敏感损失函数描述模型预测结果与实际光伏指数得符合程度，记为

$$l_\epsilon(z) = \begin{cases} 0, & |z| \leq \epsilon \\ |z| - \epsilon, & \text{其他} \end{cases} \quad (10)$$

并不一定所有的光伏数据均在正常范围内，外在因素亦会导致部分光伏数据脱离正常范围，成为离散值，采用上述“硬间隔”的处理方式并不适用。针对此种情况，引入松弛变量和“软化”间隔，SVR问题即转换为

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i - \xi_i^* \quad (11)$$

$$s.t. \begin{cases} f(x) - y_i \leq \epsilon + \xi_i \\ y_i - f(x) \leq \epsilon + \xi_i^* \end{cases} \quad (12)$$

$$i = 1, 2, \dots, m, \xi_i, \xi_i^* \geq 0$$

利用对偶原理并引入拉格朗日乘子 $\alpha_i$ 和 $\alpha_i^*$ ，SVR对偶问题的数学表述为

$$\begin{aligned} \max_{\alpha, \alpha^*} & \sum_{i=1}^m y_i (\alpha_i^* - \alpha_i) - (\alpha_i^* + \alpha_i) - \\ & \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m y_i (\alpha_i^* - \alpha_i) (\alpha_j^* + \alpha_j) x_i^T x_j \\ s.t. & \sum_{i=1}^m (\alpha_i^* - \alpha_i) = 0, 0 \leq \alpha_i^*, \alpha_i \leq C \end{aligned} \quad (13)$$

当模型预测值落入 $\epsilon$ -软间隔范围中， $\alpha_i$ 和 $\alpha_i^*$ 才会取到非零值。显然预测值只能落入同一个区域，那么两个值中至少有一为零值。SVR回归预测模型的函数公式为

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) x_i^T x + b \quad (14)$$

$$b = y_i + \epsilon - \sum_{j=1}^m (\alpha_j - \alpha_j^*) x_j^T x_i \quad (15)$$

光伏时序数据可以通过非线性映射函数 $\phi(x)$ 将SVR映射到高维空间，解决非线性化趋势，再将高维空间的向量内积 $\phi(x_i) \phi(x_j)$ 使用核函数 $K(x_i, x_j)$ 变换，核函数通常采用高斯径向基核函数，其表达式为

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (16)$$

式中， $\sigma > 0$ 为高斯核的带宽； $\gamma = 1/(2\sigma^2)$ ， $\gamma$ 为高斯径向基核函数参数。

SVR模型采用高斯径向基核函数进行计算的过程，处理非线性预测能力很强，可得到SVR回归函数为

$$f(x) = \sum_{i=1}^m (\alpha_i^* - \alpha_i) K(x, x_i) + b \quad (17)$$

## 基于LSTM-SVR组合模型的光伏预测建模

在LSTM-SVR混合模型中LSTM网络拥有识别

和存储这一特性，用于主趋势成分数列预测中恰如其分，而RNN网络的循环构造在挖掘模型深层特征中具有显著的优势。同时SVR模型因其对于非线性函数强大的映射功能，对于细节分量数列的预测、SVR参数集合的搜寻及择优选取有着很好的效果。

光伏数据属于时间序列数据，具有极大的不确定性，采用单一算法模型不能准确把握光伏变化规律，实现光伏精准预测。为充分发挥组合预测模型优秀的预测性能，引入SVR算法对LSTM进行误差修正，利用LSTM-SVR组合模型实现充电站光伏预测。由于LSTM在时序预测问题上无法准确预测在训练集中并未出现的数值，时间序列预测思想是以前 $N$ 个数据预测第 $N+1$ 个数据，但每次预测均会有一些的误差，滚动预测只会使预测误差逐渐增大。因此，利用SVR模型引入松弛变量法，对LSTM每个时刻的误差 $e_t$ 进行修正，有利于优化光伏预测准确度。输入待预测日前两天总辐照强度和环境温度数据和功率数据以及待预测日当天的总辐照强度和环境温度数据，输出待预测日的光伏功率预测数据。




图2 基于LSTM-SVR组合预测模型的光伏预测

基于LSTM-SVR组合模型的光伏预测流程图如图2所示。

步骤一：取2020年9月22日—10月31日的3 750组发电数据进行研究，包括与光伏功率输出相关性较高的总辐照强度和环境温度数据以及对应的光伏输出功率数据，对其进行预处理，消除数据中的错

误或异常因素。

步骤二：将光伏原始数据归一化处理得到 $x_t^*$ ，利用训练集对LSTM模型进行训练，利用训练好的LSTM模型预测输出一组预测值 $\bar{L}_t$ ；

步骤三：计算LSTM模型在 $t$ 时刻的预测误差 $e_t$ ，即 $e_t=x_t^*-\bar{L}_t$ ；

步骤四：采用SVR对LSTM模型在 $t$ 时刻的预测 $e_t$ 误差进行回归预测，并通过交叉验证和网格搜索寻找最优的核函数参数 $g$ 和惩罚因子 $c$ ，并得到预测值，也就是误差值 $e_t$ ，修正后的预测误差 $\bar{e}_t$ ；

步骤五：合并LSTM模型预测值 $\bar{L}_t$ 与修正预测误差 $\bar{e}_t$ ，得到基于LSTM-SVR组合算法模型的光伏预测结果 $\bar{X}_t$ ，即 $\bar{X}_t=\bar{L}_t+\bar{e}_t$ 。

### 算例仿真及结果分析

#### 1. LSTM及SVR的参数设置

支持向量回归模型在使用之前需要调整相关参数（主要核函数参数 $g$ 和惩罚参数 $c$ ），以达到更好的预测效果。本文支持向量回归模型中参数选取时用到了 $k$ 折交叉验证和网格搜索的方法，选择的参数比传统随机方法选取的参数在模型训练中表现的效果更好。由于LSTM网络具有处理时序性数据的优势，本文根据数据集中一年的实测短期功率数据进行最大互信息系数相关性分析，挑选出最佳的输入变量时长，经过多次训练发现，模型的具体参数设置见表1，此时LSTM-SVR模型的拟合效果最好。

表1 模型参数设置及预测方式

| 模型名称 | LSTM模型参数    | 参数说明    |
|------|-------------|---------|
| LSTM | Input_shape | (6, 1)  |
| LSTM | 输入层神经元数     | 6       |
| LSTM | 隐藏层         | 1       |
| LSTM | 隐藏层神经元数     | 40      |
| LSTM | 隐藏层激活函数     | Sigmoid |
| LSTM | 输出层神经元数     | 1       |
| LSTM | epochs      | 400     |
| LSTM | Batch_size  | 130     |
| SVR  | 核函数         | RBF     |
| SVR  | 核函数的gamma值  | 0.03    |
| SVR  | 惩罚系数C       | 8       |
| SVR  | $k$         | 10      |

2. 模型分析

取2020年9月22日—10月31日的3 750组发电数据进行研究，其中前3 500组用于训练LSTM模型参数，后250组数据作为测试样本，经过大量的数据训练之后，输入10月28日—10月29日的气象数据和功率数据以及10月30日和10月31日当天的气象数据，气象数据为前文选取的与光伏功率输出相关性较高的总辐照强度和环境温度，输出10月30日和10月31日的光伏功率预测结果，如图3所示。




图3 LSTM模型预测值与实际值对比

由图3预测结果对比可知，LSTM模型光伏短期预测结果与真实值非常接近，相较于RNN，在预测点1~23、预测点80~120和预测点185~215的预测效果更好。

基于LSTM-SVR组合模型的光伏预测功率选用与LSTM模型相同的数据进行训练和预测，结果如图4所示。




图4 LSTM-SVR模型预测值与实际值对比

由图4预测结果对比可知，LSTM-SVR模型光伏短期预测结果与真实值非常接近，在预测点1-23、预测点80-120和预测点185-215的预测效果比RNN和LSTM单一模型更好，基本上实现了拟合，论证了LSTM-SVR预测模型的优越的预测性能。

3. 模型性能分析

本文采用平均绝对误差（Mean Absolute

Error，MAE）、均方误差（Mean Squared Error，MSE）和均方根误差（Root Mean Square Error，RMSE）作为评价指标，分别对LSTM模型和LSTM-SVR组合模型的光伏功率预测性能进行评估。将LSTM-SVR组合模型和LSTM单一模型在同意测试集上进行预测效果对比，结果见表2。

表2 LSTM-SVR模型与LSTM、RNN单一模型效果对比

| 评价指标         | MAE (%) | MSE (%) | RMSE (%) |
|--------------|---------|---------|----------|
| LSTM         | 2.321   | 20.734  | 4.554    |
| RNN          | 2.536   | 24.975  | 4.998    |
| LSTM-SVR组合模型 | 1.511   | 9.055   | 3.009    |

由表2可知，LSTM-SVR模型短期预测准确度相较于单一LSTM、RNN模型有了一定的提升，其中，LSTM-SVR模型与LSTM模型相比，其平均绝对误差、均方误差和均方根误差分别降低了0.810%、11.679%和1.545%，与RNN模型相比分别降低了1.025%、15.92%和1.989%。

结束语

本文主要阐述了LSTM神经网络，包括神经网络的原理、新的网络结构和传播方式，并研究了利用权重更新的方法确定输入层、输出层数目，隐含层数目以及各类参数的数值。基于光伏电站的太阳辐照度、温度的数据进行LSTM算法与LSTM-SVR模型短期功率预测，得出预测结果，发现光伏发电的短期预测模型精度LSTM-SVR算法>LSTM算法>RNN算法。EA

（收稿日期：2023-08-16）

参考文献

[1] 李虹，董亮，段红霞. 中国可再生能源发展综合评价与结构优化研究[J]. 资源科学，2011，33(3): 431-440.

[2] 文爽，马逸骋，孙志强. 基于GWO-EEMD-BP神经网络的光伏发电功率短期预测[J]. 中南大学学报(自然科学版)，2022，53(12): 4799-4808.

[3] 谭海旺，杨启亮，邢建春，等. 基于XGBoost-LSTM组合模型的光伏发电功率预测[J]. 太阳能学报，2022，43(8): 75-81.