

DOI: 10.11830/ISSN.1000-5013.202104018



利用 SVM-LSTM-DBN 的 短期光伏发电预测方法

卿会^{1,2}, 郭军红^{1,2}, 李薇^{1,2}, 亢朋朋³, 王金明⁴, 潘张榕^{1,2}

- (1. 华北电力大学 环境科学与工程学院, 北京 102206;
2. 华北电力大学 资源环境系统优化教育部重点实验室, 北京 102206;
3. 国网新疆电力有限公司, 新疆 乌鲁木齐 830002;
4. 国网新疆电力有限公司 阿勒泰供电公司, 新疆 阿勒泰 836500)

摘要: 为解决传统预测算法的不足,利用深度信念网络(DBN)耦合支持向量机(SVM)和长短期记忆神经网络(LSTM),提出一种新的光伏功率组合预测方法.分别构建以高斯径向基函数为核函数的支持向量机预测模型、4层长短期记忆神经网络为单项预测模型,通过深度信念网络组合,优化预测结果并输出.根据实际出力与预测结果的误差,利用 DBN 动态调整以获得最优值,进一步验证 SVM-LSTM-DBN 模型的有效性和准确性,并以新疆维吾尔自治区某光伏电站的实测数据进行仿真验证.结果表明:基于 SVM-LSTM-DBN 组合的光伏出力预测模型与单一模型相比,预测精度明显提高.

关键词: 光伏发电; 光伏出力预测模型; 支持向量机; 长短期记忆神经网络; 深度信念网络

中图分类号: TM 615; TP 181 **文献标志码:** A **文章编号:** 1000-5013(2022)03-0371-08

Short-Term Photovoltaic Power Forecasting Method Based on SVM-LSTM-DBN

QING Hui^{1,2}, GUO Junhong^{1,2}, LI Wei^{1,2},
KANG Pengpeng³, WANG Jinming⁴, PAN Zhangrong^{1,2}

- (1. College of Environmental Science and Engineering, North China Electric Power University, Beijing 102206, China;
1. Key Laboratory of Resources and Environment System Optimization of Ministry of Education,
North China Electric Power University, Beijing 102206, China;
2. State Grid Xinjiang Electric Power Company Limited, Urumqi 830002, China;
3. Altay Power Supply Company, State Grid Xinjiang Electric Power Company Limited, Altay 836500, China)

Abstract: In order to solve the shortcomings of traditional forecasting algorithms, a new combination prediction method of photovoltaic power is proposed by using deep belief network (DBN) coupled support vector machine (SVM) and long short-term memory neural network (LSTM). The support vector machine prediction model with the kernel function of Gaussian radial basis function and the 4-layer long-short-term memory neural network as a single prediction model. Through the combination of deep belief networks, the prediction results are optimized and output. According to the actual output and the error of the prediction results, the DBN is

收稿日期: 2021-04-12

通信作者: 李薇(1974-),女,教授,博士,博士生导师,主要从事能源环境污染控制、环境影响评价、环境规划与管理、节能减排优化、能源与环境系统分析等研究. E-mail:925657837@qq.com.

基金项目: 国家重点研发计划项目-战略性国际科技创新合作重点专项(2018YFE0208400)

used for dynamic adjustment to obtain optimal value, to further verify the validity and accuracy of the SVM-LSTM-DBN model. To take simulate and verify the actual measurement data of a photovoltaic power station in Xinjiang Uygur Autonomous Region. The results show that: compare the photovoltaic output prediction model based on the combination of SVM-LSTM-DBN and a single model, the prediction accuracy is significantly improved.

Keywords: photovoltaic power generation; photovoltaic output prediction model; support vector machine; long and short-term memory neural network; deep belief network

2020 年 9 月,国家主席习近平在第七十五届联合国大会一般性辩论会上宣布,我国二氧化碳排放力争于 2030 年前达到峰值,努力争取 2060 年前实现碳中和.为实现这一目标,最主要的路径是使用可再生能源、减少碳排放,提升电气化水平.太阳能是可再生能源的重要部分,利用太阳能发电是实现碳中和目标的重要路径.然而,太阳能独特的随机性、间歇性和波动性,随着光伏装机容量需求逐渐增大,给电网安全带来了诸多考验.精准的光伏发电出力预测对光伏电站制定发电计划、保证电网稳定运行有着重要作用.

国内外诸多学者在光伏发电出力预测上展开了大量研究,如 BP(back propagation)神经网络^[1-2]、梯度下降决策树(gradient boosting decision tree,GBDT)^[3]. de Giorgi 等^[4]采用多元线性回归方法,以光伏发电系统的太阳能辐射等气象因素来预测发电功率;Ahmad 等^[5]提出了基于随机森林算法和额外树算法组合光伏发电预测模型,以气象因素预测下一小时的光伏输出功率.支持向量机(support vector machine,SVM)以结构风险最小化原则为优势取代了传统机器学习中的经验风险最小化,广泛应用于光伏出力预测.如姜恩宇等^[6]基于支持向量机以某一天数据为训练样本预测出力,结果表明,支持向量机能够明显提高小样本预测精度;张雨金等^[7]引入集成学习的思想和方法,提出 Stacking-SVM 短期光伏发电预测方法,通过次级 SVM 对多个预测结果输出耦合得到最终预测结果.

循环神经网络(recurrent neural network, RNN)具有跨多时间步长传递信息的能力,被广泛应用于各领域^[8]. Du 等^[9]证明了 RNN 具有较强记忆性且图灵完备.然而,在实际应用中,RNN 模型对变量序列间的时间依赖关系较强,使得其对于具有关联性的点序列输入具有好的预测效果,造成偏差较大.为了解决 RNN 模型的这个问题,以 RNN 为基础的长短期记忆网络(long short-term memory,LSTM)模型应运而生^[10]. LSTM 以记忆单元取代传统人工神经元,目前已被应用于空气质量指数^[11]、语音识别^[12]等领域,并表现出良好的预测性能.陈卓等^[13]基于 LSTM 以电力负荷为短期预测对象,效果良好,该算法有望用于预测光伏发电功率. Hinton 在 2006 年提出深度信念网络(deep belief network, DBN). 该算法具有强大的特征提取能力,并可通过玻尔兹曼机(restricted Boltzmann machine,RBM)的预训练有效解决局部最优等问题^[14]. Yun^[15]和耿博等^[16]的研究表明,对影响光伏出力特征信息进行有效挖掘,并结合混合模型仿真,可有效提高预测精度.

基于上述分析,本文利用 DBN 耦合 SVM 和 LSTM 模型,提出一种新的光伏功率组合预测方法,根据实际出力和预测结果的误差利用 DBN 动态调整以获得最优值,并验证 SVM-LSTM-DBN 模型的有效性和准确性.

1 数据来源

1.1 初始数据处理

采用新疆某光伏电站 2019 年 2 月 16 日—9 月 7 日的每日 15 min 实测气象数据,如表 1 所示. 表 1 中: θ 为温度; φ 为相对湿度; D_{th} 为太阳散射强度; H_{th} 为太阳直接辐射强度; P 为实时发电功率.

模型构建中,初始数据通过 z -score 进行标准化处理,从而消除不同特征的量纲的影响和提高模型的计算能力和收敛速度. 具体计算公式为

$$z = \frac{x - \mu}{\sigma} \tag{1}$$

式(1)中: x 为标准化前的数据; z 为标准化后的数据; μ 为样本的均值; σ 为样本的标准差.

数据经过 z -score 标准化后呈标准正态分布, 预测模型完成训练后, 对预测的输出数据进行反标准化处理, 即 $x = z\sigma + \mu$, 则可得到预测功率数据.

表 1 某光伏电站的部分历史实测数据
Tab. 1 Some historical measured data of photovoltaic power station

日期	时刻	$\theta/^\circ\text{C}$	$\varphi/\%$	$D_{\text{th}}/\text{W}\cdot\text{m}^{-2}$	$H_{\text{th}}/\text{W}\cdot\text{m}^{-2}$	P/kW
2019-02-16	11:15:00	-8.8	51.39	48.99	694.83	24.28
2019-02-16	11:30:00	-8.5	52.59	50.99	761.81	28.70
2019-02-16	11:45:00	-7.7	51.19	52.99	817.80	30.21
2019-02-16	12:00:00	-6.7	48.29	57.99	866.79	28.70
2019-02-16	12:15:00	-6.6	47.29	60.99	906.78	32.72
2019-02-16	12:30:00	-6.6	48.49	62.98	950.77	33.05
2019-02-16	12:45:00	-6.3	49.89	63.98	987.76	32.59
2019-02-16	13:00:00	-6.5	47.49	67.98	1 023.75	27.76

1.2 气象因素筛选

光伏出力与气象因素间具有一定的相关性, 即使是相同天气状态下也会因为云层的变化导致光伏板受太阳辐射的面积与强度产生变化. 光伏组件仅在太阳升起至降落的时间段内工作, 为了避免大量光伏出力零值数据对分析造成影响, 考虑到光伏组件的敏感程度, 结合该光伏电站所在新疆省当地的实际气候情况. 因此, 文中以正午时刻(12:00)为例, 对温度、相对湿度、太阳直接辐射强度、太阳散射强度等 4 种气象参数, 在不同时间点采集的数据分别进行相关性分析.

光伏出力数据与各气象因素经预处理后的结果, 如图 1 所示. 图 1 中: θ 为温度; φ 为相对湿度; D_{th} 为太阳散射强度; H_{th} 为太阳直接辐射强度; P_{out} 为光伏出力.

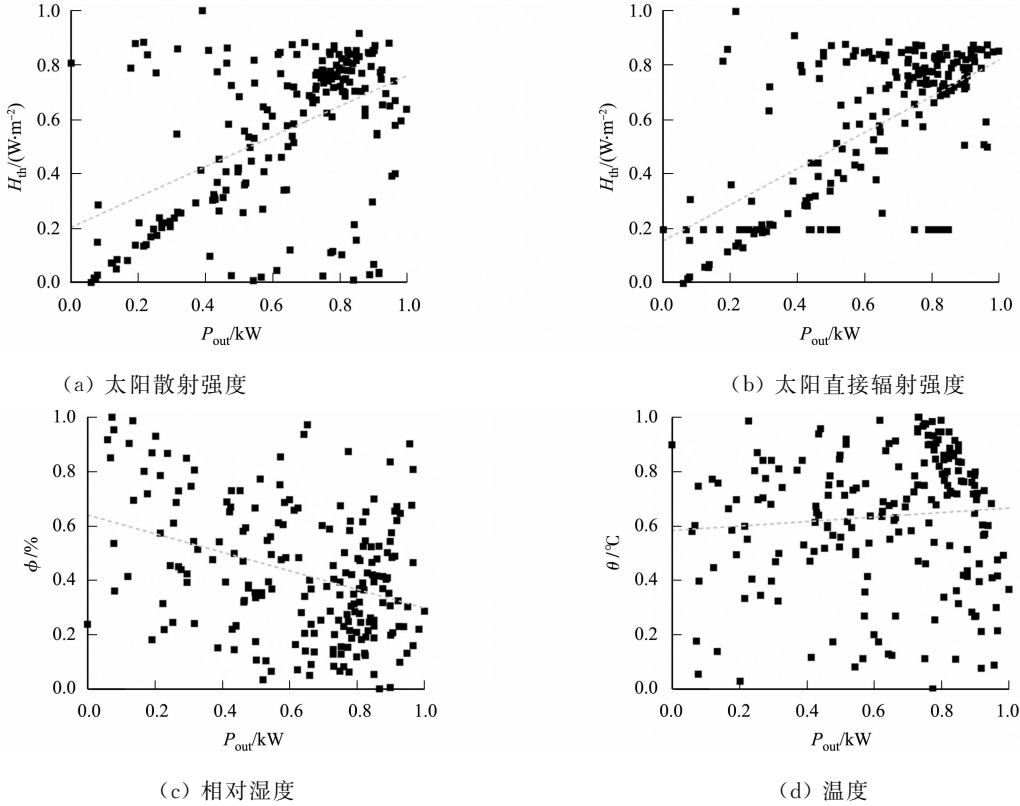


图 1 12:00 的各气象因素与光伏出力散点图

Fig. 1 Scatter diagram of meteorological factors and photovoltaic output at 12:00

从图 1 可知: 太阳散射强度、太阳直接辐射强度与出力值变化的拟合性较高, 散点图分布较为集中, 正相关较明显, 其中太阳直接辐射强度与出力的相关性更强; 同一时刻, 相对湿度、温度与出力值的关系较为分散. 从图 1 还可知: 当出力值较大时, 相对湿度偏低而温度偏高. 整体来看相对湿度的拟合曲线呈负相关, 温度与出力值的拟合曲线较为平缓, 相关性较不明显.

对温度、相对湿度、太阳散射强度、太阳直接辐射强度与光伏出力进行协方差和 Pearson 相关性分析,得到结果见表 2. 表 2 中: θ 为温度; φ 为相对湿度; D_{th} 为太阳散射强度; H_{th} 为太阳直接辐射强度; r 为 Pearson 相关系数.

从表 2 可知:协方差与 Pearson 相关系数所得相关性结果趋势大致相同,与图 1 初步分析结果一致. 结合图 1、表 1 分析可知:在所有影响因素中,太阳直接辐射强度、太阳散射强度、相对湿度与光伏出力显现出较明显的相关性,其中太阳直接辐射强度正相关性最强. 太阳散射强度和太阳直接辐射强度反映了太阳热辐射能,当太阳热辐射能较强时,半导体材料在界面层获得的能量较强,产生更多的电子-空穴对,进而光伏出力较大;相对湿度与光伏出力表现出负相关性,相对湿度较高往往是阴雨天气,太阳热辐射能较弱,光伏发电受到影响出力变小,相关系数计算结果与物理解释一致.

1.2 评价指标

为验证模型的预测精度,采用均方根误差(RMSE)和平均绝对误差(MAE)作为模型性能的评价指标,其具体计算公式^[17]为

$$\gamma_{\text{RMSE}} = \frac{1}{N} \sqrt{\sum_{i=1}^N (X_i - \hat{X}_i)^2}, \tag{2}$$

$$\gamma_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |X_i - \hat{X}_i|. \tag{3}$$

式(2),(3)中: X_i 为测试集的第 i 个数据点出力实际值; \hat{X}_i 为第 i 个数据点的出力预测值; N 为测试集样本总数.

2 预测模型的构建

2.1 SVM 单项预测模型构建

设 $x_\lambda \in \mathbf{R}^n$ 为训练样本中的各项气象参数, $y_\lambda \in \mathbf{R}^n$ 为光伏出力,两者共同组成样本集合 $(x_\lambda, y_\lambda) \in \mathbf{R}^n \times \mathbf{R}$. 其中, n 为样本的个数, $\lambda=1,2,\cdots,n$. 通过线性回归函数对样本集合拟合,可得

$$f(x) = \boldsymbol{\omega}^\text{T} \varphi(x) + b. \tag{4}$$

式(4)中: $\boldsymbol{\omega}$ 为权值矢量; $\varphi(x)$ 为非线性映射关系; b 为阈值.

核函数的选择对预测效果起重要作用,常用的核函数有线性核函数、多项式核函数、高斯径向基核函数等. 其中,高斯核函数具有计算效率高和计算结果可靠等优点,较适合表示气象参数与光伏出力间的复杂非线性关系. 其具体表达形式为

$$K(x_i, x_j) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - x_j\|^2\right). \tag{5}$$

式(5)中: σ 为高斯核函数的核宽度.

由此,构建以高斯径向基为核函数的 SVM 单项预测模型,采用滚动预测,Lookback 取值为 7,Delay 取值为 1,以序列号前 50 个预测点为例,比较 SVM 的单项预测值与实际出力值之间的偏差,结果如图 2 所示. 图 2 中: P_{out} 为光伏出力. 从图 2 可知:支持向量机在不同时刻显示出不同的预测精度,整体有一定的重合度,但预测精度有一定的提升空间.

2.2 LSTM 单项预测模型构建

LSTM 常见的块结构包含输入、遗忘、输出三个门,以及块输入、块输出、记忆细胞、输出激活函数和窥视孔连接,而块输出反复连接块输入和所有门,如图 3 所示. LSTM 训练过程包括信息的向前传递和误差的反向传播.

1) 信息向前传递. 设 t 时刻的输入向量为 \mathbf{x}' ,LSTM 块的数量为 N ,输入数量为 M . 即一个

表 2 相关性计算结果
Tab. 2 Calculation results of correlation

气象参数	协方差	r
θ	0.124	0.116
φ	-0.282	-0.325
D_{th}	0.640	0.639
H_{th}	0.713	0.720

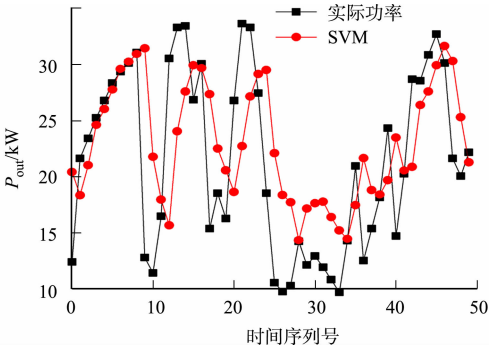


图 2 某地区光伏发电 SVM 预测结果
Fig. 2 SVM prediction results of photovoltaic power generation in a certain area

LSTM 网络层的各权值向量为

$$z^t = g(W_zx^t + R_zy^{t-1} + b_z), \tag{6}$$

$$\bar{i}^t = (W_ix^t + R_iy^{t-1} + p_iec^{t-1} + b_i), \tag{7}$$

$$f^t = \sigma(W_fx^t + R_fy^{t-1} + p_fec^{t-1} + b_f), \tag{8}$$

$$c^t = z^tei^t + c^{t-1}ef^t, \tag{9}$$

$$o^t = \sigma(W_ox^t + R_oy^{t-1} + p_oec^t + b_o), \tag{10}$$

$$y^t = h(c^t)eo^t. \tag{11}$$

式(6)~(11)中： z^t 为块输入， \bar{i}^t 为输入门， f^t 为遗忘门； c^t 为细胞状态； o^t 为输出门； y^t 为块输出。

2) 误差反向传播 . LSTM 块内部的增量 δ ，其计算式为

$$\delta y^t = \Delta^t + R_z^T\delta z^{t+1} + R_i^T\delta i^{t+1} + R_f^T\delta f^{t+1} + R_o^T\delta o^{t+1}, \tag{12}$$

$$\delta \bar{o}^t = \delta y^te h(c^t) e \sigma''(\bar{o}^t), \tag{13}$$

$$\delta c^t = \delta y^te o^te h'(c^t) + p_o e \delta \bar{o}^t + p_i e \delta \bar{i}^{t+1} + p_f e \delta \bar{f}^{t+1} + \delta c^{t+1} e \bar{f}^{t+1}, \tag{14}$$

$$\delta \bar{f}^t = \delta c^te c^{t-1} e \sigma''(\bar{f}^t), \tag{15}$$

$$\delta \bar{i}^t = \delta c^te z^te \sigma''(\bar{i}^t), \tag{16}$$

$$\delta \bar{z}^t = \delta c^te i^te g''(\bar{z}^t). \tag{17}$$

式(12)中： Δ^t 为上一层向下传递的增量向量。

与经典神经网络相比，LSTM 训练最大区别在于若预测 t 时刻的值 p_t ，则前面的 n 个样本 $\{p_{t-n}, \cdots, p_{t-1}\}$ 都需要通过网络训练。因此，在设置网络时对时间步数 n 进行定义来满足预测精度，记忆细胞将根据训练状态存储并输出预测值 p_t 。

LSTM 模型结构的搭建与参数的设置，对于样本训练过程的优化、训练时耗、预测精度起关键性作用。通过大量迭代过程，对 2~6 层隐层的网络进行对比分析，最终确定最佳的网络深度。比较不同隐层模型训练完成时间与训练后的评价指标 MAE 和 RMSE，如表 3 所示。隐层层数增加与训练时间的关系，如图 4 所示。表 3，图 4 中： N 为隐层层数； t 为训练时间； γ_{RMSE} ， γ_{MAE} 分别为 RMSE 值和 MAE 值。

表 3 不同隐层模型训练后的评价指标
Tab.3 Evaluation index after training
of different hidden layer models

N	γ_{MAE}	γ_{RMSE}	t/s
2	3.32	4.36	349.20
3	2.21	4.36	600.34
4	1.87	2.04	849.86
5	3.14	4.20	1310.28
6	3.19	4.28	3494.35

从表 3 可知：当隐层层数少于 4 层时，MAE 和 RMSE 值随隐层数目增加而减小；而当隐层层数大于 4 时，MAE 和 RMSE 值随隐层层数增大而增大。随着隐层层数的逐渐增加，训练时长呈指数型增加，当隐层层数为 4 时，模型训练时长较长并出现过拟合现象。综上所述，当隐层数目为 4 时，MAE 和 RMSE 值均最小，训练时间较合理，预测精度最高。因此，文中选用隐层为 4 层的 LSTM 网络。

2.3 基于 SVM-LSTM-DBN 的光伏发电组合预测模型

通过支持向量机和长短期记忆神经网络分别建立单项预测模型，以气象参数相对湿度、太阳散射强度、太阳直接辐射强度等为特征向量输入，以光伏出力为输出。单项模型的预测结果进一步深度信念网络训练，优化后输出。图 5 为光伏发电出力预测组合模型示意图。图 5 中： V 为 DBN 显层； H 为隐层； W

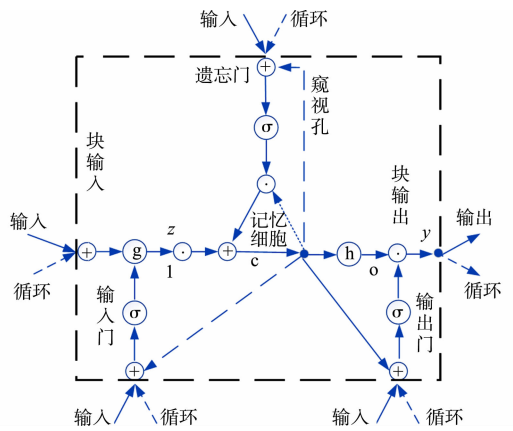


图 3 RNN 网络隐层中的 LSTM 块
Fig. 3 LSTM block in RNN hidden layer

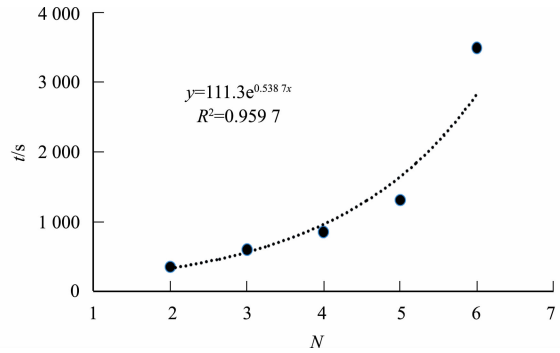


图 4 隐层层数与训练时长增加关系图
Fig. 4 Relationship between number of hidden layers and increase of training duration

为 V 和 H 的连接权重.

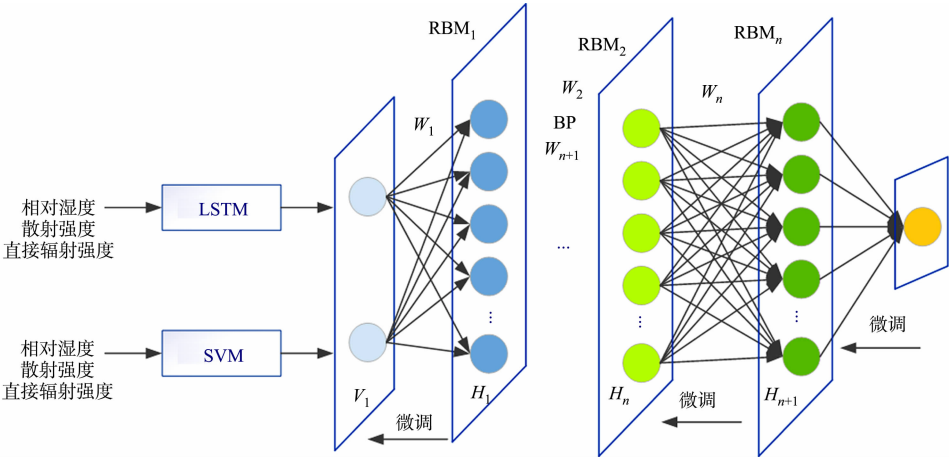


图 5 光伏发电出力预测组合模型示意图

Fig. 5 Schematic diagram of photovoltaic power generation output prediction combination model

光伏发电出力预测具体流程,如图 6 所示. 单项预测模型构建完成后,通过 DBN 对预测结果优化,具体过程有如下 3 个方面.

1) 以各单项模型的预测值作为 DBN 的输入向量,分别由 $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3$ 表示.

2) 通过枚举法^[18]选取 DBN 隐层的层数及单元数,然后通过训练样本确定各单项模型的最优权重,此训练过程有两步:

(a) 通过无监督的逐层训练来训练 DBN 中的 RBM. 设 RBM 中的显层、隐层神经元的数目分别为 n , n , 而 v_i, h_j 分别为显层第 i 个、隐层第 j 个神经元的状态,它们对应的偏置分别为 a_i, b_j ; $w_{i,j}$ 为显层第 i 个、隐层第 j 个神经元之间的连接权重. 设 $\beta=(w_{i,j}, a_i, b_j)$ 为 RBM 的参数;则 RBM 在状态 (v, h) 上的能量函数可表示为

$$E(v, h | \beta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{i,j} h_j. \tag{18}$$

当显层单元向量 $\mathbf{v}=(v_1, \cdots, v_i, \cdots, v_n)$ 随机给定后,隐层第 j 个单元 h_j 被激活的概率为

$$p(h_j = 1 | \mathbf{v}) = \text{Sigmoid}(b_j + \sum_{i=1}^n v_i w_{i,j}). \tag{19}$$

式(19)中: $\text{Sigmoid}(x)=(1+e^{-x})^{-1}$ 为激活函数.

当隐层单元向量 $\mathbf{h}=(h_1, \cdots, h_i, \cdots, h_n)$ 随机给定后,显层第 i 个单元 v_i 被激活的概率为

$$p(v_i = 1 | \mathbf{h}) = \text{Sigmoid}(a_i + \sum_{j=1}^m w_{i,j} h_j). \tag{20}$$

采用对比散度法对 RBM 的参数 $\beta=(w_{i,j}, a_i, b_j)$ 寻优.

$$\Delta w_{i,j} = \sigma_{\text{CD}}(\langle v_i h_j \rangle - \langle v_i' h_j' \rangle), \tag{21}$$

$$\Delta a_i = \sigma_{\text{CD}}(\langle v_i \rangle - \langle v_i' \rangle), \tag{22}$$

$$\Delta b_j = \sigma_{\text{CD}}(\langle h_j \rangle - \langle h_j' \rangle). \tag{23}$$

式(21)~(23)中: σ_{CD} 为对比散度法的学习速率; $\langle \cdot \rangle$ 为变量的数学期望.

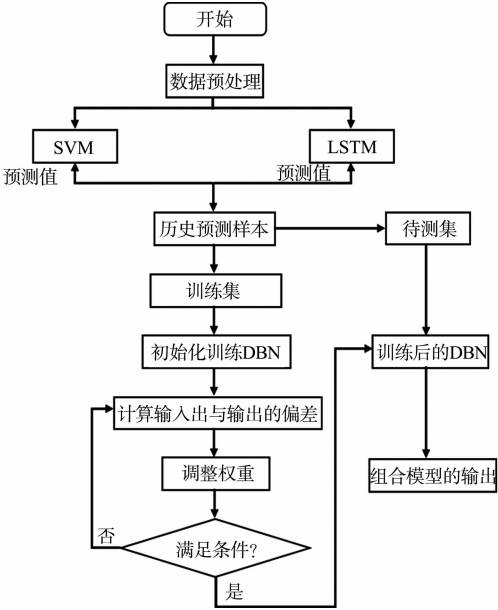


图 6 光伏发电出力预测流程图

Fig. 6 Flow chart of photovoltaic power generation output forecast

- (b) 根据 BP 算法进行反向微调,以 DBN 的输出值反向更新其网络和权重.
- 3) 将待测日的气象数据代入算法训练,输出预测值 P_i .

3 实验结果与分析

使用 Python 语言(V3.6)编写,运行环境前端为 Keras,谷歌第二代人工智能学习系统 TensorFlow 为后端^[19],以新疆某光伏电站为例,将预处理后的样本代入 SVM,LSTM 和 SVM-LSTM-DBN 模型中.2019 年 2 月 16 日—9 月 7 日的全时间序列光伏发电的组合预测结果,如图 7 所示.不同算法模型的光伏发电功率预测结果逐点(序列号前 50 预测点)对比,如图 8 所示.图 7,8 中: P_{out} 为光伏出力.

图 7 可知:SVM-LSTM-DBN 组合预测模型具有一定的预测精度,其预测曲线与实际曲线变化趋势基本一致,具有较好的预测效果.由图 8 可知:LSTM 模型的预测精度与 SVM-LSTM-DBN 组合模型相比较低,SVM 模型预测精度最低.

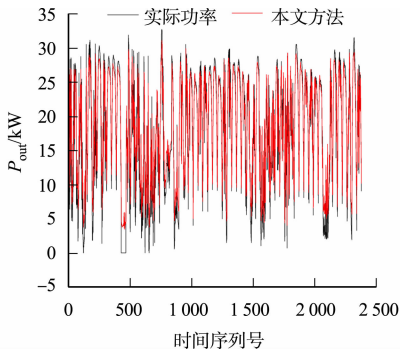


图 7 全时间序列光伏发电预测结果
Fig. 7 Prediction results of full time series photovoltaic power generation

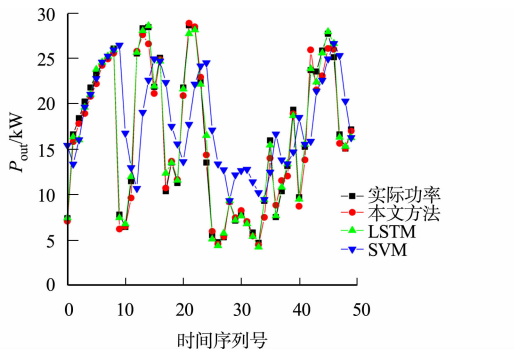


图 8 不同算法光伏发电功率预测结果逐点对比
Fig. 8 Point by point comparison of photovoltaic power prediction results of different algorithms

不同预测模型的光伏发电功率预测性能比较,如表 4 所示.表 4 中: γ_{RMSE} , γ_{MAE} 分别为 RMSE 值和 MAE 值.从表 4 可知:文中所提出的 SVM-LSTM-DBN 组合预测模型具有最小的 MAE 值及 RMSE 值,分别为 1.073 及 1.840,即具有最高预测精度,降低了整体预测误差.

表 4 不同预测模型预测性能比较
Tab. 4 Comparison of prediction performance of different prediction models

预测模型	γ_{MAE}	γ_{RMSE}
SVM-LSTM-DBN	1.073	1.840
LSTM	1.870	2.040
SVM	2.248	4.068

4 结论

文中利用 DBN 提出 SVM-LSTM-DBN 组合模型进行短期光伏出力预测.以新疆某光伏电站实测数据为例,将 SVM-LSTM-DBN 模型与单一模型实验效果对比,得出如下 3 点主要结论.

- 1) 文中提出的 SVM-LSTM-DBN 模型将 SVM 与 LSTM 模型采用枚举法加权组合,修正单一模型中误差较大的时序值,以降低误差.实验结果表明,SVM-LSTM-DBN 模型能有效提高短期光伏出力预测精度.
- 2) 通过 SVM-LSTM-DBN 模型与单一模型实验效果对比,表明单一模型的出力预测精度是组合模型精度有效提高的前提,因此正确选择或调节参与组合的单一模型参数至关重要.
- 3) 数据基础是实现预测精准的基石.在后续研究中,应重点关注光伏电站运行的稳定性,有利于挖掘更多有效信息,从而提升预测精度以制定发电计划,进一步提高太阳能利用率,减少碳排放的同时保证电网稳定运行.

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. DOI: 10.7666/d.Y3114962.

[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. DOI:10.19317/j.cnki.1008-083x.2017.02.019.
- [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. DOI:10.1049/IET-SMT.2013.0135.
- [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. DOI:10.1016/j.energy.2018.08.207.
- [6] 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 DOI:10.3969/j.issn.1006-4729.2015.06.002.
- [7] 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. DOI:10.3969/j.issn.2096-2835.2018.02.002.
- [8] JIN Lianghai, XIONG Caiquan, LIU Hong. Improved bilateral filter for suppressing mixed noise in color images [J]. Digital Signal Processing, 2012, 22(6): 903-912. DOI:10.1016/j.dsp.2012.06.012.
- [9] DU Nan, DAI Hanjun, TRIVEDI R, *et al.* Recurrent marked temporal point processes: Embedding event history to vector[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 1555-1564. DOI:10.1145/2939672.2939875.
- [10] GONZÁLEZ-HIDALGO M, MASSANET S, MIR A, *et al.* Improving salt and pepper noise removal using a fuzzy mathematical morphology-based filter[J]. Applied Soft Computing, 2018, 63: 167-180. DOI:10.1016/j.asoc.2017.11.030.
- [11] 张春露,白艳萍. 基于 TensorFlow 的 LSTM 模型在太原空气质量 AQI 指数预测中的应用[J]. 重庆理工大学学报(自然科学), 2018, 32(8): 137-141. DOI:10.3969/j.issn.1674-8425(z).2018.08.021
- [12] 赵淑芳,董小雨. 基于改进的 LSTM 深度神经网络语音识别研究[J]. 郑州大学学报(工学版), 2018, 39(5): 63-67. DOI:10.13705/j.issn.1671-6833.2018.02.004
- [13] 陈卓,孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法[J]. 电子技术设计与应用, 2018, 01(001): 39-41. DOI:10.3969/j.issn.1000-0755.2018.01.011.
- [14] 李飞,高晓光,万开方. 基于动态 Gibbs 采样的 RBM 训练算法研究[J]. 自动化学报, 2016, 42(6): 931-942. DOI:10.16383/j.aas.2016.c150645.
- [15] YUN Luo. An islanding detection method for photovoltaic power generation system using fluctuation characteristic of PCC harmonic voltage[J]. Advanced Materials Research, 2014, 998/999: 574-577. DOI:10.4028/www.scientific.net/AMR.998-999.574.
- [16] 耿博,高贞彦,白恒远,等. 结合相似日 GA-BP 神经网络的光伏发电预测[J]. 电力系统及其自动化学报, 2017, 29(6): 118-123. DOI:10.3969/j.issn.1003-8930.2017.06.019.
- [17] 贾俊平,何晓群,金勇进. 统计学[M]. 7 版. 北京:中国人民大学出版社, 2018.
- [18] 孔祥玉,郑锋,鄂志君,等. 基于深度信念网络的短期负荷预测方法[J]. 电力系统自动化, 2018, 42(5): 133-139. DOI:10.7500/AEPS20170826002
- [19] 林大贵. TensorFlow+Keras 深度学习人工智能实践应用[M]. 北京:清华大学出版社, 2018: 193-196.

(责任编辑: 黄仲一 英文审校: 吴逢铁)