

基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测*

王晨阳¹⁾ 段倩倩¹⁾ 周凯¹⁾ 姚静¹⁾ 苏敏¹⁾ 傅意超¹⁾
纪俊羊¹⁾ 洪鑫¹⁾ 刘雪芹^{1)†} 汪志勇^{2)‡}

1) (重庆理工大学理学院, 绿色能源材料技术与系统重庆市重点实验室, 重庆 400054)

2) (西南大学物理科学与技术学院, 重庆 400715)

(2019年12月20日收到; 2020年2月6日收到修改稿)

光伏发电受天气与地理环境影响, 呈现出波动性和随机多干扰性, 其输出功率容易随着外界因素变化而变化, 因此预测发电输出功率对于优化光伏发电并网运行和减少不确定性的影响至关重要. 本文提出一种基于遗传算法 (GA) 优化的卷积长短记忆神经网络混合模型 (GA-CNN-LSTM), 首先利用 CNN 模块对数据的空间特征提取, 再经过 LSTM 模块提取时间特征和附近隐藏状态向量, 同时通过 GA 优化 LSTM 训练网络的超参数权重与偏置值. 在初期对历史数据进行归一化处理, 以及对所有特征作灰色关联度分析, 提取重要特征降低数据计算复杂度, 然后对本文提出来的经 GA 优化后的 CNN-LSTM 混合神经网络 (GA-CNN-LSTM) 算法模型进行光伏功率预测实验. 同时与 CNN, LSTM 两个单一神经网络模型以及未经 GA 优化的 CNN-LSTM 混合神经网络模型的预测性能进行比较. 结果显示在平均绝对误差率 (MAPE) 指标下, 本文提出的 GA-CNN-LSTM 算法模型比单一神经网络模型最好的结果减少了 1.537% 的误差, 同时比未经优化的 CNN-LSTM 混合神经网络算法模型减少了 0.873% 的误差. 本文的算法模型对光伏发电功率具有更好的预测性能.

关键词: 光伏发电, 人工智能, 卷积神经网络, 长短记忆神经网络

PACS: 07.05.Kf, 07.05.Mh, 05.45.Tp

DOI: 10.7498/aps.69.20191935

1 引言

随着全球传统化石能源日益枯竭, 并且污染严重, 能源危机与环境问题渐显突出. 当前光伏新能源具有清洁、可持续性等特点, 越来越受到人们的重视. 但是近些年我国新能源遭遇严重的弃光问题. 光伏发电受天气等多种因素影响呈现出波动不稳定^[1], 所以在其并网输出电力使用时, 提前预测发电输出功率变得尤其重要.

目前在光伏发电功率预测领域研究热点是基于人工智能的方法, 主要包括机器学习, 以及深度学习^[2]神经网络等技术. 2012年, Shi等^[3]建立基于支持向量机 (SVM) 的预测模型, 从预测效果来看机器学习模型明显好于传统数学统计模型. 2016年, Liu等^[4]采用最大期望 (EM) 算法将天气进行聚类, 通过聚类结果, 选出反应预测日天气特点的样本作为输入, 利用小波 SVM 回归模型进行输出预测, 分类后的机器学习模型表现出更好的预测效果. 2018年, Liu等^[5]提出反向传播 (BP) 神

* 国家自然科学基金 (批准号: 11774041) 和重庆市基础与前沿研究计划项目 (批准号: cstc2015jcyjA50033, cstc2015jcyjBX0056) 资助的课题.

† 通信作者. E-mail: xqliu@cqut.edu.cn

‡ 通信作者. E-mail: zywang@swu.edu.cn

神经网络模型, 利用 15 kW 并网光伏系统的四种光伏输出和气象数据对该方法进行了测试, 在置信度分别为 95%, 90%, 85% 和 80% 的置信水平下计算预测区间覆盖率 (PICPs), 它们所提出的模型在短期光伏功率输出和相关不确定性的预测方面优于传统的预测方法. 2019 年, Gao 等^[6] 提出利用长短记忆神经网络 (LSTM) 对光伏系统的输出功率进行预测, 该方法使用一年内不同地点的每小时数据集进行评估, LSTM 进一步减少了预测误差, 体现出更优的预测效果^[7]. 虽然上述的研究取得了不错的结果, 但是他们所采用的模型, 特别是人工神经网络模型, 过多的输入数据、隐含层数和隐含层节点很可能导致网络训练的过拟合、梯度消失和爆炸等问题, 并且单一神经网络模型普遍表现出预测精度不够高等缺点.

针对以上问题与缺点, 本文提出了一种基于遗传算法 (GA) 优化的卷积长短记忆神经网络混合模型 (GA-CNN-LSTM). 首先对数据进行归一化处理去除量纲, 统一数据范围, 然后对历史数据特征进行灰色关联度分析^[8], 选取最重要几个特征变量, 达到了降低计算复杂度和提高预测精度的目的. 该模型利用 GA 算法解决了训练容易陷入局部最小值、收敛速度慢等问题, 同时使用辍学机制^[9] (Dropout) 避免了模型易出现过拟合等缺点, 以及 CNN 和 LSTM 相结合的混合神经网络模型明显提高了预测精度, 并且在运行时间上表现出良好的性能.

2 数据预处理

本研究采用 DC 竞赛光伏发电输出功率预测数据^[10], 截取其中 66860 组单年份数据作分析, 其中有风速、风向、温度、压强、湿度和实发辐照度为输入变量特征, 输出为实际发电功率. 我们首先对数据进行预处理, 将所有输入数据特征进行数据标准化, 去除量纲, 便于一致性分析, 然后采取灰色关联度分析筛选其中与输出实际发电功率相关程度更高的变量特征, 降低整体计算的复杂度, 同时能提高模型的精度.

2.1 归一化

数据归一化主要目的是将多种变量的数据统一缩放到一个范围^[11], 这样的范围通常是 $(-1, 1)$

的一个数值区间, 转换函数为

$$x' = \frac{2[x - 0.5(\max + \min)]}{\max - \min}, \quad (1)$$

其中 \max 为样本数据的最大值, \min 为样本数据的最小值. x 为当前样本点的值, x' 为归一化转换计算所得的数值. 通过统一的归一化处理有利于加快模型的收敛速度, 同时能提升其计算结果的精度.

2.2 灰色关联度分析

通过分析两个变化量之间的关系, 来衡量两个量之间的关联程度, 以表达一个量对另外一个量的影响程度, 计算其灰色关联度的值通常有以下五个步骤^[12]:

- 步骤 1** 对所有数据进行归一化处理;
- 步骤 2** 计算每个样本点的差值绝对值 X ;
- 步骤 3** 找出样本点的最大值和最小值 MAX , MIN ;
- 步骤 4** 计算每个对应的关联系数 Y , 公式如 (2) 式所示:

$$Y = \frac{\text{MIN} + 0.5\text{MAX}}{X + 0.5\text{MAX}}; \quad (2)$$

步骤 5 对每列的所有关联系数 Y 做平均计算, 得出结果. 结果越接近于 1, 相关联程度越高.

通过归一化和灰色关联度分析后得出结果如表 1 所列, 其中实发辐照度的关联度值最高, 压强的关联度值最小. 在风况数据特征中, 虽然风速和风向与功率相关程度相近, 但是风速对光伏板的影响更为直接, 一方面, 风速越大光伏板的表面积尘越少, 进而使得光伏板实际接收到的辐照度越大; 另一方面, 在白天工作时, 风速越大光伏板表面散热效果越好, 光伏板表面温度降低, 有利于光伏输出. 实验数据分析选取前四个相关联程度最高的特征变量 (实发辐照度、湿度、温度、风速) 作为下一步算法模型的输入数据样本变量. 这样的筛选, 一方面减少了特征数量, 有助于降低计算成本; 另一方面, 通过选择相关联程度更高的特征量有利于提高模型预测精度.

表 1 灰色关联度分析值
Table 1. Grey relational analysis value.

| 变量特征 | 风速 | 风向 | 温度 | 压强 | 湿度 | 实发辐照度 |
|------|------|------|------|------|------|-------|
| Y | 0.34 | 0.28 | 0.45 | 0.01 | 0.62 | 0.97 |

3 算法模型

本文采用遗传算法 (GA) 优化后的 CNN-LSTM 混合算法模型, 如图 1 所示. 模型结构主要由卷积神经网络和长短记忆神经网络组成, 先由卷积神经网络提取数据的空间特征^[13], 再由长短记忆神经网络提取时间特征. 整个模型结合了两种神经网络的优势, 并且在训练 LSTM 神经网络的超参数时, 网络的权重系数和偏置值由 GA 更新计算, 替换了传统的梯度下降法的训练方法, 使得整个训练学习的过程得到了优化.

3.1 卷积神经网络 (CNN)

CNN 是一种专门用于处理具有已知网格状拓扑结构的数据的神经网络^[14]. 例如, 时间序列数据可以看作是按一定时间间隔采样的一维网格, 图像数据可以看作是由像素组成的二维网格, 在计算时, 网络主要采用了一种称为卷积的数学运算. 卷积是一种特殊的线性运算, 由它来代替一般矩阵计算可以达到多倍的运算效果^[15]. 随着 CNN 的发

展, 出现了许多卷积网络结构的变体, 但它们的基本结构大多相似, 包括输入层、卷积层、池化层、全连接层和输出层^[16]. 由于本文实验数据是以时间序列为主, 所以本文采用的是一维的卷积神经网络结构, 如图 2 所示, 这样的选择避免了前期输入和后期输出数据维度的转换. 一维卷积核以时间步长单一方向的滑动为主, 这样的设置更有利于对时间序列数据的卷积处理.

3.2 长短记忆神经网络 (LSTM)

LSTM 网络是一种递归神经网络^[17](RNN). 与所有的递归神经网络一样, LSTM 可以计算传统计算机在具有足够网络元素情况下的数据, 特别对时序数据能够体现更好的优势. 它的大体结构如图 3 所示.

图中三个模块框部分可以看成三个细胞结构, 前后两个细胞 A 代表前一个时刻和后一个时刻的细胞状态, 中间的细胞是当前时刻的状态, 它可以分为三个门控部分, 分别表示遗忘门、输入门、输出门^[18]. 三个门接收前一个时间状态的 LSTM 输




图 1 CNN-LSTM 混合算法模型

Fig. 1. CNN-LSTM hybrid algorithm model.




图 2 一维卷积神经网络结构^[14]

Fig. 2. One dimensional convolutional neural network structure.




图 3 LSTM 神经网络结构^[17]

Fig. 3. LSTM neural network structure.

出值 h_{t-1} 和当前时间的输入数据 x_t 作为输入^[19]. 遗忘门部分的 f_t 可以看成是由输入的 x_t 和 h_{t-1} 得到, 用来控制 c_{t-1} 中的信息的遗忘程度, f_t 中的每个值都是属于 $[0, 1]$ 的范围, 下界值 0 代表完全遗忘, 上界值 1 代表完全不变, 可以保留下来^[20]. 遗忘门决定了前一个时期状态信息的遗忘程度, 之后输入门的作用就是往当前状态信息中添加新的内容^[21]. 同样, 输入门部分由输入的 x_t 和 h_{t-1} 得到当前的 i_t 用以控制当前状态信息的更新程度. 这里当前状态信息 c_g 也是通过输入的 x_t 和 h_{t-1} 计算得出. 那么当前新的状态信息 c_t 就很显然可以通过下面的公式计算得出, 通俗地说就是遗忘一些旧信息, 更新一些新信息进去^[22]. 最后就是输出门部分, 类似地, 根据 x_t 和 h_{t-1} 计算得出 o_t 用以控制哪些信息需要作为输出. 具体计算公式为:

$$f_t = \sigma(\mathbf{w}_f [h_{t-1}, x_t] + \mathbf{b}_f), \quad (3)$$

$$i_t = \sigma(\mathbf{w}_i [h_{t-1}, x_t] + \mathbf{b}_i), \quad (4)$$

$$h_t = \tanh(\mathbf{w}_g [h_{t-1}, x_t] + \mathbf{b}_g), \quad (5)$$

$$c_t = f_t \times c_{t-1} + i_t \times h_t, \quad (6)$$

$$o_t = \sigma(\mathbf{w}_o [h_{t-1}, x_t] + \mathbf{b}_o), \quad (7)$$

$$h_t = o_t \times \tanh(c_t), \quad (8)$$

其中 \mathbf{w} 和 \mathbf{b} 表示上述门的权矩阵和偏置向量, C_i 表示存储单元, σ 和 \tanh 代表 s 型函数和双曲正切激活函数.

3.3 遗传算法 (GA)

遗传算法 (GA) 是模拟生物进化进行个体的选择、交叉和变异的一种算法, 它的主要核心是参数编码、初始群的设定和适应函数的确定, 然后通过最终的搜索得到最优解^[23]. 本论文采用 GA 优化 LSTM 神经网络训练时权值以及偏置的确定计算, 优化改进模型流程如图 4 所示.




图 4 遗传算法优化流程

Fig. 4. Optimization process of genetic algorithm.

4 误差性能指标

在衡量模型预测的性能时, 通常选取以下四个误差指标: 平均绝对误差 (MAE)、平均平方差 (MSE)、平均平方根误差 (RMSE) 和平均绝对误差率 (MAPE). MAE 是一种基础性的考察误差的指标; MSE 作为平方效果后的误差, 侧重放大偏差较大的误差, 可评估出一个模型的稳定性; RMSE 作为一种方均根误差对异常点比较敏感^[24]; MAPE 不仅考虑预测值与真实值的误差, 同时它更能显现出误差与真实值的比率^[25]. 假定预测值为 $x = \{x_1, x_2, x_3, x_4, \dots, x_n\}$, 真实值为 $y = \{y_1, y_2, y_3, y_4, \dots, y_n\}$, 四种指标的计算为:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - y_i|, \quad (9)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2, \quad (10)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2}, \quad (11)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{y_i} \right|. \quad (12)$$

5 结果与讨论

为验证算法模型的可行性, 本文选取前期预处理好的实验数据集, 将 80% 的数据作为训练集, 剩余 20% 的数据作为测试集. 实验选择在电脑上进行, CPU 配置为 Inter Core I7-3770k, 频率为 3.60 GHZ, 显卡为 MX250, 系统为 win10, 程序代码选择 python3.6 版本, 编辑器是 pycharm.

实验对本文提出的 GA-CNN-LSTM 算法模型进行测试, 同时与 CNN, LSTM 两个单一神经网络模型和未经优化的 CNN-LSTM 混合神经网络模型的预测结果进行比较. 本实验不仅考量模型的预测误差性能指标, 还考量整个模型的训练和测试运行时间.

5.1 多种模型实验误差性能对比结果

实验对 LSTM, CNN 两个单神经网络模型和 CNN-LSTM 混合神经网络算法模型, 以及一种经过 GA 优化过的 CNN-LSTM 混合神经网络算法模型进行性能测试. 实验测试结果如图 5—图 8 所示, 分别为四种模型截取一周预测数据的时间与发电功率的关系图, 选取每 15 min 为一个间隔的发电输出功率值, 其中红线代表实际发电输出功率, 绿线代表预测发电输出功率. 单方面从图的预测线和实际线重合程度来看, 经 GA 优化的 CNN-LSTM 混合神经网络模型明显优于其他三种模型, 特别是在夜晚时间呈现的拟合情况, 预测值更贴近于实际值.

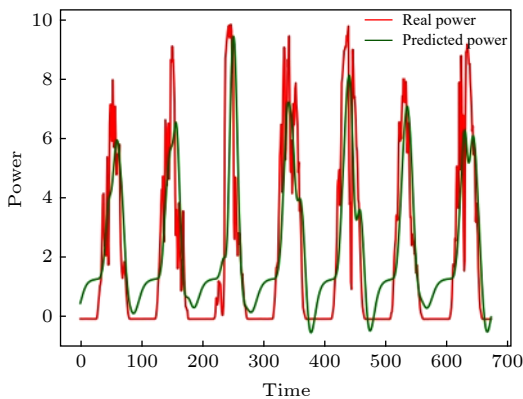


图 5 CNN 模型预测功率图

Fig. 5. Power diagram of CNN model prediction.




图 6 LSTM 模型预测功率图

Fig. 6. Power diagram of LSTM model prediction.

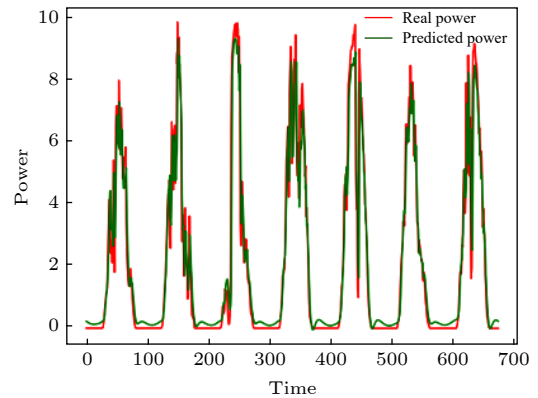


图 7 CNN-LSTM 模型预测功率图

Fig. 7. Power diagram of CNN-LSTM model prediction.




图 8 GA-CNN-LSTM 模型预测功率图

Fig. 8. Power diagram of GA-CNN-LSTM model prediction.

进一步通过具体的预测误差指标分析, 如表 2 所列, 在 MAE 和 MAPE 指标下, LSTM 预测值呈现性能最差, CNN 模型次之, GA-CNN-LSTM 预测最好. 特别是在 MAPE 指标下, GA-CNN-LSTM 比单一神经网络模型最好的结果减少了 1.537% 的误差, 比未经优化的 CNN-LSTM 混合神经网络算法模型减少了 0.873% 的误差. 在

MSE 和 RMSE 指标下, CNN 模型预测值呈现性能最差, LSTM 模型次之, GA-CNN-LSTM 预测效果依然是最好的. 尤其是在 RMSE 指标下, GA-CNN-LSTM 比 CNN-LSTM 减少了 8.108% 的误差, 体现了 GA 训练超参数的优势, 不仅避免了模型训练过拟合, 同时防止了梯度消失和爆炸的情况发生, 提高模型结果预测精度. 综合图像和图表结果, 本文提出的 GA-CNN-LSTM 模型在各种误差指标下都呈现最优效果, 而且相对于单一神经网络模型, 混合的神经网络模型的预测性能更好, 充分表现了 CNN-LSTM 混合模型既保留了 CNN 在空间特征提取的优势也发挥了 LSTM 在时间特征提取的优势.

表 2 模型预测误差指标
Table 2. Error index of model prediction.

| 模型 | CNN | LSTM | CNN-LSTM | GA-CNN-LSTM |
|------|---------|---------|----------|-------------|
| MAE | 0.34765 | 0.36681 | 0.28763 | 0.21424 |
| MSE | 0.65034 | 0.63447 | 0.60437 | 0.58529 |
| RMSE | 0.80643 | 0.77431 | 0.69321 | 0.61213 |
| MAPE | 0.06013 | 0.06233 | 0.05439 | 0.04476 |

5.2 多种算法模型运行时间对比结果

从运行时间方面来看, 具体训练与测试时间值如表 3 所列. 首先在训练时, CNN 和 LSTM 两个单神经网络模型所耗时间分别是 456.434 和 51.576 s, 而混合神经网络模型 CNN-LSTM 和 GA-CNN-LSTM 所耗时间分别为 611.88 和 503.74 s. 其次在测试时, CNN, LSTM, CNN-LSTM 和 GA-CNN-LSTM 四个模型所耗时间分别是 1.13, 1.22, 3.69 和 2.77 s. 单一神经网络模型消耗训练时间和测试时间都相对较少, 但是综合误差性能, 混合神经网络模型更具性价比, 尤其是经过 GA 优化后的混合算法模型更具优势.

表 3 模型运行时间
Table 3. Model running time.

| 模型 | CNN | LSTM | CNN-LSTM | GA-CNN-LSTM |
|--------|---------|--------|----------|-------------|
| 训练时间/s | 456.434 | 51.576 | 611.880 | 503.740 |
| 测试时间/s | 1.130 | 1.220 | 3.690 | 2.770 |

6 结 论

为了保证光伏发电与电网电力供需平衡, 进一步提高光伏发电预测的准确率, 本文提出了基于遗

传算法 (GA) 优化 CNN-LSTM 混合神经网络的模型, 通过数据处理和算法模型实验分析表明:

1) 采用归一化处理和灰色关联度分析, 降低了数据的维度, 减少了计算成本, 同时通过保留相关性较高的数据特征有助于为后期提高模型精度作准备;

2) 通过将 CNN 和 LSTM 混合, 等同于将两种神经网络在空间特征与时间特征提取的优势相结合. 在 MAPE 误差指标下, CNN-LSTM 混合模型比单一神经网络模型最好的结果减少了 0.574% 误差, 能够进一步提高模型精度;

3) 经 GA 优化 LSTM 训练后所得的 GA-CNN-LSTM 混合神经网络模型, 改进了传统梯度下降法的训练缺点. 在 MAPE 误差指标下, 比未经优化的 CNN-LSTM 混合神经网络算法模型减少了 0.873% 的误差, 表现出更高的预测精度;

4) 从训练与测试运行时间来看, GA-CNN-LSTM 模型所花费时间略高于单个神经网络模型, 但劣势不是太明显.

综合预测性能和运行时间比较结果, GA-CNN-LSTM 模型在光伏预测系统以及整个光伏电站运维工作中, 具有一定的应用价值.

参考文献

- [1] Wang K, Qi X, Liu H 2019 *Appl. Energy* **251** 113315
- [2] Kushwaha V, Pindoriya N M 2019 *RenewableEnergy* **140** 124
- [3] Shi J, Lee W J, Liu Y, Yang Y, Wang P 2012 *IEEE Trans. Ind. Appl.* **48** 1064
- [4] Liu Y, Zhao J, Zhang M, et al. 2016 *The 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery*, Changsha, August, 2016 p29
- [5] Liu L, Zhao Y, Chang D, Xie J, Ma Z, Sun Q, Wennersten R 2018 *Appl. Energy* **228** 70
- [6] Gao M, Li J, Hong F, Long D 2019 *Energy* **187** 115
- [7] Abdel-Nasser M, Mahmoud K 2019 *Neural Comput. Appl.* **31** 2727
- [8] Wei X H 2019 *M. S. Thesis* (Lanzhou: Lanzhou University) (in Chinese) [魏小辉 2019 硕士学位论文 (兰州: 兰州大学)]
- [9] SrivastavaN, Hinton G, Krizhevsky A, et al. 2014 *J. Mach. Learn Res.* **15** 1929
- [10] <https://www.pkbigdata.com/common/cmptIndex.html>[2019-12-20]
- [11] Ashburner J, Friston K J 1999 *Hum. Brain Mapp.* 7254
- [12] Wei G W 2011 *Expert Syst. Appl.* **38** 4824
- [13] Wang K, Qi X, Liu H 2019 *Energy* **189** 116225
- [14] Chua L O 1997 *Int. J. Bifurcation Chaos* **7** 2219
- [15] SajjadM, Khan S, Hussain T, Muhammad K, Sangaijah A K, Castiglione A, Baik S W 2019 *Pattern Recognit. Lett.* **126** 123
- [16] Xiao F, Xiao Y, Cao Z, Gong K, Fang Z, Zhou J T 2019 *Tenth International Conference on Graphics and Image Processing*, Chengdu, China, 2018 p11069
- [17] Hüskén M, Stagge P 2003 *Neurocomputing* **50** 223
- [18] Qing X, Niu Y 2018 *Energy* **148** 461

- [19] Ordóñez F, Roggen D 2016 *Sensors* **16** 115
- [20] Tan Z X, Goel A, Nguyen T S, Ong D C 2019 *14th IEEE International Conference on Automatic Face & Gesture Recognition*, Lille, France, May 14–18, 2019 p1
- [21] Gensler A, Henze J, Sick B, et al. 2016 *IEEE International Conference on Systems, Man, and Cybernetics*, Budapest, Hungary, October 9–12, 2016 p002858
- [22] Zhou X, Wan X, Xiao J 2016 *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, Texas, USA, November 1–5, 2016 p247
- [23] Goldberg D E, Samtani M P 1986 *In Electronic Computation American Society of Civil Engineers*, American, February 1986 p471
- [24] Willmott C J, Matsuura K 2005 *Clim. Res.* **30** 79
- [25] Ip W C, Hu B Q, Wong H, Xia J 2009 *J. Hydrol.* **379** 284

A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm*

Wang Chen-Yang¹⁾ Duan Qian-Qian¹⁾ Zhou Kai¹⁾ Yao Jing¹⁾
 Su Min¹⁾ Fu Yi-Chao¹⁾ Ji Jun-Yang¹⁾ Hong Xin¹⁾
 Liu Xue-Qin^{1)†} Wang Zhi-Yong^{2)‡}

1) (*Chongqing Key Laboratory of Green Energy Materials Technology and Systems, School of Science, Chongqing University of Technology, Chongqing 400054, China*)

2) (*School of Physical Science and Technology, Southwest University, Chongqing 400715, China*)

(Received 20 December 2019; revised manuscript received 6 February 2020)

Abstract

Photovoltaic power generation is affected by weather and geographical environment, showing fluctuations and random multi-interference, and its output power is easy to change with changes in external factors. Therefore, the prediction of output power is crucial to optimize the grid-connected operation of photovoltaic power generation and reduce the impact of uncertainty. This paper proposes a hybrid model of both convolutional neural network (CNN) and long short-term memory neural network (LSTM) based on genetic algorithm (GA) optimization (GA-CNN-LSTM). First, the CNN module is used to extract the spatial features of the data, and then the LSTM module is used to extract the temporal features and nearby hidden states. Optimizing the hyperparameter weights and bias values of the LSTM training network through GA. At the initial stage, the historical data is normalized, and all features were analyzed by grey relational degree. Important features are extracted to reduce the computational complexity of the data. Then, the GA-optimized CNN-LSTM hybrid neural network model (GA-CNN-LSTM) is applied for photovoltaic power prediction experiment. The GA-CNN-LSTM model was compared with the single neural network models such as CNN and LSTM, and the CNN-LSTM hybrid neural network model without GA optimization. Under the Mean Absolute Percentage Error index, the GA-CNN-LSTM algorithm proposed in this paper reduces the error by 1.537% compared with the ordinary single neural network model, and 0.873% compared with the unoptimized CNN-LSTM hybrid neural network algorithm model. From the perspective of training and test running time, the GA-CNN-LSTM model takes a little longer than the single neural network model, but the disadvantage is not obvious. To sum up, the performance of GA-CNN-LSTM model for photovoltaic power predicting is better.

Keywords: photovoltaic, artificial intelligence, convolutional neural network, long short-term memory neural network

PACS: 07.05.Kf, 07.05.Mh, 05.45.Tp

DOI: 10.7498/aps.69.20191935

* Project supported by the National Natural Science Foundation of China (Grant No. 11774041) and the Research Program of Basic Research and Frontier Technology of Chongqing, China (Grant Nos. cstc2015jcyjA50033, cstc2015jcyjBX0056).

† Corresponding author. E-mail: xqliu@cqut.edu.cn

‡ Corresponding author. E-mail: zywang@swu.edu.cn