

DOI: 10.19783/j.cnki.pspc.201117

# 基于混合神经网络的光伏电量预测模型的研究

崔佳豪, 毕利

(宁夏大学信息工程学院, 宁夏 银川 750021)

**摘要:** 精确的光伏发电量预测对光伏发电系统的安全运行有重要的作用。然而, 由于太阳能的不稳定性、间歇性和随机性, 现有光伏发电量的短期预测模型存在预测误差大、泛化能力低等问题。因此, 提出一种混合神经网络和注意力机制的分布式光伏电站电量短期预测模型(A-HNN)。利用残差长短期记忆网络与扩展因果卷积相结合提取数据的时间和空间特征, 加入注意力机制增强特征选择, 给出一种改进的混合神经网络模型。根据发电量数据时间序列本身的特性, 选取以日为周期的时间序列数据。最后, 通过实验与近期其他模型对比, 结果表明在同等条件下此混合模型可以大幅提高光伏发电量预测的精度。

**关键词:** 混合神经网络; 卷积神经网络; 循环神经网络; 发电量预测; 扩展因果卷积

## Research on photovoltaic power forecasting model based on hybrid neural network

CUI Jiahao, BI Li

(School of Information Engineering, Ningxia University, Yinchuan 750021, China)

**Abstract:** Accurate photovoltaic power generation prediction plays an important role in the safe operation of photovoltaic power generation system. However, due to the instability, intermittent and randomness of solar energy, the existing short-term prediction models of photovoltaic power generation have problems of large prediction error and low generalization ability. Therefore, a Hybrid Neural Network (A-HNN) and attention mechanism for short-term forecasting of distributed photovoltaic power station is proposed. The temporal and spatial characteristics of data are extracted by Residual LSTM and dilated causal convolution, and an improved hybrid neural network model is obtained by adding attention mechanism to enhance feature selection. According to the characteristics of the time series of power generation data, the time series data with daily cycle are selected. Finally, compared with other recent models, the results show that the hybrid model can greatly improve the accuracy of photovoltaic power generation prediction under the same conditions.

This work is supported by Ningxia Natural Science Foundation (No. 2020AAC03034) and Scientific Research Innovation Project of China Western First-class Universities (No. ZKZD2017005).

**Key words:** hybrid neural network; CNN; RNN; power generation forecast; dilated causal convolution

## 0 引言

光伏扶贫是实现精准扶贫的方式之一, 近年来, 光伏电站的规模和数量不断增加, 弃光量也不断增加, 电网消纳率的降低是光伏发电存在的主要问题之一。光伏发电固有的间歇性和波动性特点导致分布式光伏发电并网对电网的安全、稳定和经济运行造成很大冲击。精确地预测光伏发电量可以提高电网的稳定性, 能够有效帮助电网调度部门做好各

类电源的调度计划, 可以帮助光伏电站减少由于限电带来的经济损失, 提高光伏电站运营管理效率。

光伏发电量预测是光伏系统中重要的一环, 目前国内外学者对光伏发电量预测做了大量相关研究, 提出了机器学习、统计方法、神经网络模型以及混合模型等多种预测模型。文献[1]对直接光伏功率预测模型和技术进行了系统而全面的文献综述, 论述了光伏发电和光伏发电量预测的必要性, 预测结果取决于预测时间、可用数据和预测方法。文献[2]提出用加权的马尔科夫链修正支持向量机(SVM)预测模型, 修正后的模型预测精度更高, 模型具备可行性和有效性。文献[3]提出一种基于多元宇宙优

基金项目: 宁夏自然科学基金项目资助(2020AAC03034); 西部一流大学科研创新项目资助(ZKZD2017005)

化支持向量机的短期光伏发电功率预测模型, 预测精度有效提升。文献[4]提出基于粒子群优化 BP 神经网络的算法, 按季节、日类型划分 12 个子网组成的预测模型, 该模型预测误差均小于 20%。文献[5]提出一种基于天气分类的支持向量机光伏发电预测算法, 根据天气情况分类分别训练, 根据预报日的天气情况选择子模型, 均方根误差为 8.64%。文献[6]使用基于 PFA-MBAS-BP 神经网络的光伏发电短期预测模型, 预测精度达 92.5%。虽然经典的机器学习模型和统计方法模型在群智能算法的优化下电量预测有一定的提高, 但是仍然有一定的局限性, 未能很好地捕捉数据的特征, 准确率有待提高。

文献[7]使用 LSTM 结合注意力机制的模型, 可以提高特征选择, 提升光伏发电量预测的准确率。文献[8]提出使用双向长短时神经网络 BILSTM, 可以提高数据时间特征的选取, 与单向长短时神经网络相比提升了光伏发电量预测准确率。文献[9-10]提出将卷积神经网络(CNN)和 LSTM 混合使用, CNN 提取数据的空间特征, LSTM 提取数据的时间特征, 与单个模型相比, 提升了预测准确率。文献[11]使用相同数据情况, 将基于统计方法的时间序列模型和深度神经网络的时间序列模型对比, 得出基于深度学习的时间序列模型优于基于统计方法的时间序列模型。文献[12]比较了十种不同的机器学习算法, 提出使用混合算法集成模型, 与其单模型比较, 混合模型最优。文献[13]提出使用基于信息融合的动态神经网络光伏功率预测模型, 经验证预测方法可行有效, 且精度较高。文献[14]使用 CNN 和 LSTM, 考虑到时间序列对整体信息的长期依赖性, 将多个相关时间序列结合, 可以看作是一个多层叠加的深层神经网络。文献[15]按照天气聚类, 在原有的 LSTM 神经网络中加入 Attention 机制, 使模型在输入序列的不同时刻被分配到相应的注意权重, 从而增强了模型的特征提取能力。文献[16]提出使用多层双向循环神经网络用于负荷预测, 正向 LSTM 和反向门控循环单元(GRU)以及正向 GRU 和反向 LSTM 相结合, 模型取得了较好的预测效果。文献[17]提出基于注意力机制的 CNN-GRU 短期电力负荷预测方法, 提高了预测精度。文献[18]提出一种基于互信息熵 LSTM 的短期光伏功率预测方法, 通过对不同天气的功率预测分析, 验证了该方法具有较好的预测精度。深度学习可以对大量数据的特征进行提取, 目前许多学者已经使用深度学习模型进行电量预测, 均取得较好的效果。

综上, 大多文献采用实验室模拟数据, 在实际光伏电量预测中, 效果未能达到最优。深度学习模

型相对于经典模型来说, 可以更好地提取数据的特征, 部分学者已经使用多种混合模型进行电量预测, 混合模型的效果不仅可以克服单一模型的缺点, 而且可以利用多个模型的优点进行任务分析, 可以取得比单一模型更好的效果。但是, 目前的研究基本都是基于单电站的电量预测, 而对于分布式多电站的电量预测并不适用。因此, 本文通过分析紫外线强度、天气、温度、风速等环境因素, 提出一种基于注意力机制的混合神经网络的多电站电量预测模型 A-HNN。利用扩展因果卷积与 LSTM 各自的特点充分学习时间序列数据的不同间隔、不同层次的特征; 引入注意力机制可以使混合神经网络自适应地关注对当前输出更重要的输入特征, 减轻其他特征的干扰, 提升模型的性能。最后, 通过实验验证了该模型在解决多电站预测问题时可行有效。

## 1 模型结构

长短期记忆网络(LSTM)是循环神经网络(RNN)的一种变体, 可以提取数据的时间序列信息, 扩展因果卷积可以提取数据的不同层次、不同间隔的特征, 注意力机制(Attention)可以提高特征选择, 残差网络可以提高模型的精度和泛化能力。

### 1.1 LSTM

基础的神经网络包含输入层、隐藏层和输出层, 通过激活函数控制输出, 层与层之间通过权值连接。RNN 的特点是隐藏层中的神经元之间也建立了连接, 长短期记忆网络是 RNN 的一种变体。RNN 由于梯度消失的原因只能有短期记忆, LSTM 网络通过门控单元将加法运算代入网络中, 一定程度上解决了梯度消失的问题。LSTM 网络结构如图 1 所示。

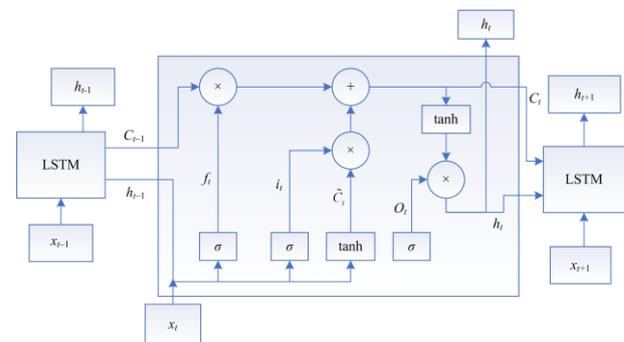


图 1 LSTM 网络结构

Fig. 1 LSTM network structure

其中包括遗忘门  $f_t$ 、记忆门  $i_t$  和输出门  $O_t$ 。遗忘门是 LSTM 中的第一个门, 用来决定前一时间刻神经元状态中需要遗忘的信息, 如式(1)所示。记忆门用来确定哪些新信息被存放在神经元状态中, 包括

两个部分: Sigmoid 部分决定哪些信息需要更新, 如式(2)所示; tanh 部分创建一个新的候选值向量, 会被加入到状态中, 如式(3)所示。遗忘门  $f_t$  和记忆门  $i_t$  用于更新神经元的状态, 如式(4)所示。输出门  $o_t$  作为最后一个门控, 控制神经元状态的输出, 如式(5)、式(6)所示。

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

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

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

式中:  $w$  为权值;  $b$  为偏置;  $x_t$  为  $t$  时刻的输入;  $C_t$  为  $t$  时刻的神经元状态;  $\tilde{C}_t$  为  $t$  时刻需要更新的神经元状态;  $\sigma$  为 Sigmoid 激活函数;  $\tanh$  为双曲正切激活函数。

### 1.2 扩展因果卷积

扩展因果卷积<sup>[19]</sup>是 2016 年被 OORD A V D 提出的, 因果卷积是卷积在时间序列数据的特殊应用, 可以保证卷积神经网络的卷积核能够使卷积运算完全符合时间序列, 卷积核只能读取当前信息和历史信息。文献[20]提出了一种新的时间序列结构, 基于扩展的因果卷积为主要架构, 可以充分地学习时间序列不同时间间隔的特征。

因果卷积结构如图 2 所示。对于因果卷积, 存在的一个问题是需要很多层或者很大的卷积核来增加卷积的感受野。本文通过扩展卷积来增加感受野。扩展卷积通过跳过部分输入来使卷积核可以应用于大于卷积核本身长度的区域。等同于通过增加零来从原始卷积核中生成更大的卷积核。利用扩张卷积系统地聚合多尺度的上下文信息, 减少了由于下采样操作而导致的分辨率或覆盖率损失, 扩展因果卷积结构如图 3 所示, 卷积感受野扩大了 1、2、4 倍, 扩展卷积使模型在层数不大的情况下有非常大的感受野。

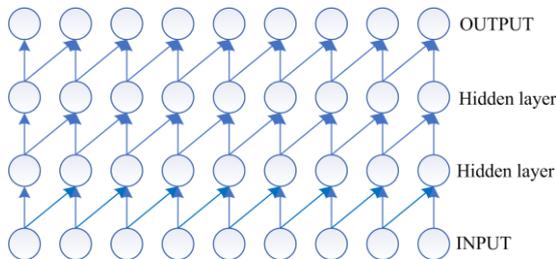


图 2 因果卷积结构

Fig. 2 Causal convolution structure

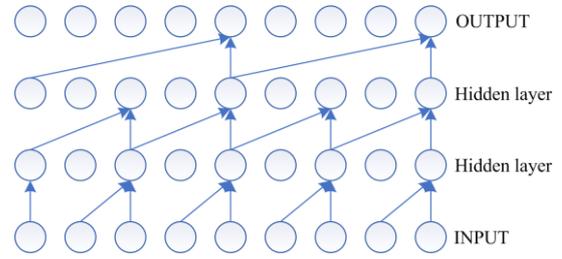


图 3 扩展因果卷积结构

Fig. 3 Dilated causal convolution structure

根据 RELU 函数的收敛快及求梯度简单的特点, 卷积神经网络的激活函数通常为 RELU 函数, 如式(7)所示。

$$RELU(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (7)$$

### 1.3 Attention

将注意力机制应用于深层神经网络可以使神经网络自适应地关注对当前输出更重要的输入特征, 并减轻其他特征的干扰。在注意力机制中, 将寻找输出特征  $h_i$  的注意权重  $\alpha_i$ 。利用隐藏层输出向量  $H = \{h_1, h_2, \dots, h_t\}$  作为注意力机制的输入, 注意力机制将寻找  $h_i$  的注意权重  $\alpha_i$ , 如式(8)、式(9)所示。

$$e_i = \tanh(W_h h_i + b_h), e_i \in [-1, 1] \quad (8)$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{i=1}^t \exp(e_i)}, \sum_{i=1}^t \alpha_i = 1 \quad (9)$$

式中:  $W_h$  为  $h_i$  的权重;  $b_h$  为偏置; 注意向量  $H' = \{h'_1, h'_2, \dots, h'_t\}$ , 其中  $h'_i$  可以通过将注意权重  $\alpha_i$  和  $h_i$  相乘得到, 如式(10)所示。

$$h'_i = \alpha_i \cdot h_i \quad (10)$$

上述公式中  $i = 1, 2, \dots, t$ 。注意力机制被实现为自定义层, 其中参数使用 RMSProp(Root Mean Square Propagation)反向传播进行优化。

### 1.4 残差网络

残差网络是 He Kaiming<sup>[21]</sup>于 2016 年提出的, 残差网络的特点是容易优化, 并且能够通过增加相当的深度来提高准确率。其内部的残差块使用了跳跃连接, 缓解了在深度神经网络中增加深度带来的梯度消失问题, 残差网络结构如图 4 所示。

为了提高模型的精度和泛化能力, 文献[22]提出一种新的残差连接方式, 在残差块的基础上, 建立两层新的快捷连接, 内层将部分残差块连接, 外层将整个网络的输入输出连接, 块间的残差连接输出的是平均值。

本文为提高模型的精度及泛化能力, 在残差块

及 LSTM 块的基础上, 使用多层快捷残差连接, 增加模型深度, 提高模型学习能力。

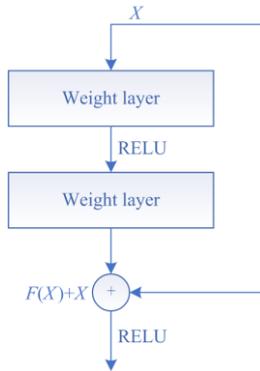


图 4 残差网络  
Fig. 4 Resnet

### 1.5 模型结构

采用双通道混合模型结构, 利用 LSTM 提取时间序列的整体特征, 扩展因果卷积可以学习时间序列不同层次、不同间隔的特征, 利用残差结构加深网络层数, 可以提升模型的学习能力和泛化能力, 最后使用注意力机制强化特征选择, 提出一种混合神经网络和注意力机制的多光伏电站发电量短期预测模型, 模型结构如图 5 所示。

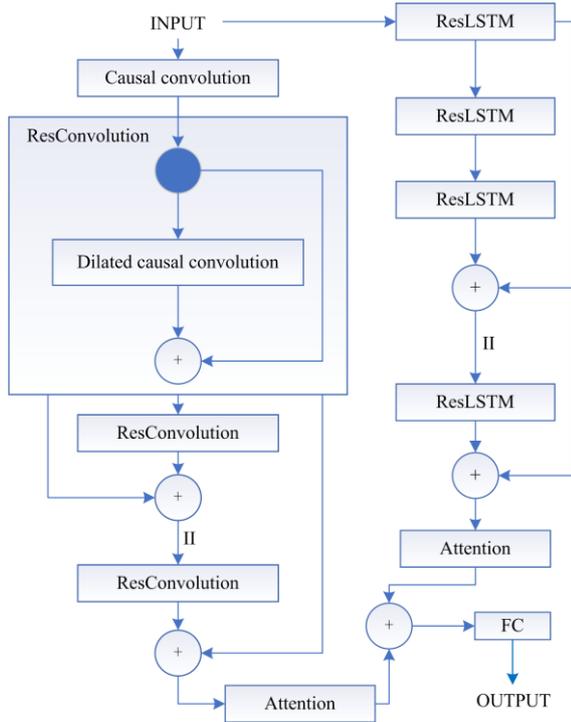


图 5 A-HNN 模型结构  
Fig. 5 A-HNN model structure

双通道设计是为了可以更好地利用两个模型的特性, 分为残差卷积(ResConvolution)通道和残差

LSTM(ResLSTM)通道。ResConvolution 是一个由 3 层扩展因果卷积组成的残差块, 扩展率分别为 1、2、4 倍, 残差块间的连接除网络主线, 有两层快捷连接, 内层连接是以残差块为单位的残差连接, 每 3 层残差块都会使用内层快捷连接, 外层连接是将卷积通道第一层因果卷积与卷积通道最后一个残差块的输出进行连接, 快捷连接相交处取特征的均值。LSTM 通道结构类似卷积通道残差块的结构。

将注意力机制用于增强两通道的特征抽取, 并将两个通道提取的特征使用式(11)方式连接。

$$Hstate = Cstate + Lstate \quad (11)$$

式中:  $Hstate$  为 Add 层的输出;  $Cstate$  为经过 CNN 提取的特征;  $Lstate$  为经过 LSTM 提取的特征。

## 2 数据处理

### 2.1 数据描述

光伏发电量数据采用宁夏某光伏公司 70 个电站的实时发电量数据, 数据为同一地区的多个电站, 电站所处地理位置、环境等基本情况相同; 唯一的区别是不同电站的并网容量不同, 使用有效利用小时数可以将不同电站发电量化分为统一单位。若采用单个电站的数据训练模型, 数据量不够; 故采用多电站的数据作为模型的训练数据, 将已经训练好的模型用于别的电站验证, 可以证明该学习模型具有较强的泛化能力。

辐照度是受照面单位面积上的辐射通量, 可以直接影响太阳能的发电情况, 但是由于电站分布地区不同, 需要安置多个辐照度传感器, 成本造价过高, 因此未能采集到实时的辐照度信息, 暂不考虑辐照度对发电量的影响。目前只能采集到电压电流以及实时发电量等数据。气象信息是实时从某气象网站爬取。因此, 将综合考虑 12 个影响条件, 即历史发电量、早晚天气情况、最高温度、最低温度、日照时长、湿度、实时温度、PM 值、风速、紫外线强度和时间点。时间点设置为 7~20, 14 个时间点。时间点的选用, 使模型可以更好地提取数据的以日为周期的特征。

### 2.2 相关性分析

为了提高光伏发电量预测的准确性, 需要考虑各种气候信息对发电量的影响。对气候信息做相关性分析, 使用 Pearson 相关性分析法, 如式(11)所示。相关系数取绝对值, 相关系数值如表 1 所示, 选取相关系数大于 0.1 的影响因素。

$$r = \frac{N \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{N \sum x_i^2 - (\sum x_i)^2} \sqrt{N \sum y_i^2 - (\sum y_i)^2}} \quad (12)$$

式中： $N$  为变量个数； $x$  和  $y$  为计算相关性的两个变量。表 1 中，PV 为光伏发电量，其余依次为早晚天气情况(Wea1、Wea2)、最高温度(MaxT)、最低温度(MinT)、日照时长(SD)、风力(WP)、PM 值(PM)、紫外线强度(UV)、时间点(TM)、温度(T)和湿度(RH)。

表 1 相关系数值

Table 1 Correlation coefficient value

气象	PV
Wea1	0.32
Wea2	0.24
MaxT	0.24
MinT	0.08
SD	0.20
WP	0.13
PM	0.05
UV	0.68
TM	0.24
T	0.31
RH	0.36

### 2.3 数据预处理

由于多电站实时数据不规律，需将发电量数据平滑为以小时为单位的平稳时间序列，然后将发电量数据化成有效利用小时数  $P$ ，如式(13)所示。

$$P = \frac{\text{发电量}}{\text{并网容量}} \quad (13)$$

异常数据包括发电量过大过小和骤增骤减以及为空的数据。数据以日为周期，将日周期内异常数据过多的去除，异常数据较少的按照百分位插补法进行填补。将数据按照电站、天气情况、紫外线强度进行分类，计算出每个分类的百分位数。将小于百分位为 0.2 的数据用百分位为 0.2 的数据替换，将大于百分位为 0.8 的数据用百分位为 0.8 的数据替换，数据为空的情况也按照百分位插补法进行填补。

将天气情况<sup>[23]</sup>以及紫外线强度数值化，数值化情况如表 2 所示。

表 2 数值化表

Table 2 Numerical table

天气	数值	紫外线强度	数值
晴	0.868	极强	6
云	0.562	很强	5
阴	0.459	强	4
雨	0.255	中等	3
雪	0.1	弱	2
—	—	很弱	1
—	—	无	0

将除发电量以外的数据按照式(14)归一化。

$$x' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$

式中： $x_i$  为初始数据； $x_{\min}$  为最小值； $x_{\max}$  为最大值； $x'$  为归一化后的值。

### 2.4 性能评估

使用平均绝对误差(MAE)、平均绝对百分误差(MAPE)、均方根误差(RMSE)验证模型的鲁棒性。

$$MAE = \left( \sum_{i=1}^N |y(i) - y'(i)| \right) / N \quad (15)$$

$$MAPE = \left( \sum_{i=1}^N \left| \frac{y(i) - y'(i)}{y(i)} \right| \right) / N \quad (16)$$

$$RMSE = \sqrt{\left( \sum_{i=1}^N (y(i) - y'(i))^2 \right) / N} \quad (17)$$

式中： $y(i)$ 、 $y'(i)$  分别为  $i$  时刻的测试值和预测值； $N$  为测试样本数。

## 3 实验设计

### 3.1 实验数据

实验数据将包括 70 个光伏电站、62 个电站的数据用于模型训练，包括 23 454 条数据，8 个电站用于模型测试，包括 3 013 条数据。数据包括 12 个影响属性，根据相关性分析，选取相关性大于 0.1 的十个影响属性。根据自相关系数公式，如式(18)，将时间步长设置为 14，即输入数据的结构为 14×10。

$$\rho = \frac{\sum_{i=1}^{n-h} (x_i - u)(x_{i+h} - u)}{\sum_{i=1}^n (x_i - u)^2} \quad (18)$$

式中： $h$  是时间步长； $u$  是序列的平均值； $x_i$  和  $x_{i+h}$  分别对应于两个时间点的值。

### 3.2 模型训练

A-HNN 模型使用 Python、tensorflow2.2 实现，在 Anaconda 环境中的 Jupyter Notebook 中搭建和训练模型。模型隐藏层神经元个数均是 256，同时损失函数为 MSE(Mean Squared Error)，使用 Adam (Adaptive Moment Estimation) 优化器进行优化，RELU 为激活函数。设置批处理大小为 1 024，迭代次数达 2 000 次时学习趋近稳定，为防止过拟合，加入 dropout 层，随机停用模型 20% 的神经元。

### 3.3 模型性能评估及误差分析

将 A-HNN 模型与 LSTM、GRU、CNN、RNN 等深度学习模型对比，并分别与文献[9-10]所提出的 CNN+LSTM 和 LSTM+CNN 混合模型、文献[8]使用的双向长短时神经网络 BILSTM、文献[15]提出的 LSTM+GRU 混合模型、文献[16]使用的基于注意力机制的 LSTM、文献[17]使用的基于注意力机

制的 CNN+GRU 相对比, 对比实验结果如表 3。

表 3 对比模型性能评估

Table 3 Comparison model performance evaluation

模型	MAE	MAPE	RMSE
LSTM	0.029	0.263	0.054
GRU	0.031	0.318	0.055
CNN	0.05	0.629	0.071
RNN	0.032	0.394	0.056
Bi-LSTM	0.028	0.366	0.053
LSTM+CNN	0.027	0.357	0.049
CNN+LSTM	0.025	0.177	0.0483
A-LSTM	0.031	0.194	0.057
A-CNN+GRU	0.03	0.197	0.055
LSTM+GRU	0.026	0.159	0.047
A-HNN	<b>0.017</b>	<b>0.084 6</b>	<b>0.035</b>

在相同数据情况下, 根据 MAE、MAPE、RMSE 性能评估方法, 所提出的 A-HNN 相较于目前所提出的混合深度学习网络有更低的误差。单模型效果最佳的是 LSTM, MAPE 为 0.263, 较 RNN 误差减少了 13.1%, 其可以有效地提取时间序列数据的特征。CNN 对于时间序列的特征提取效果较差。加入了注意力机制的 LSTM 和 GRU, 均取得了较好的效果, 与单模型相比, MAPE 分别降低了 6.9% 和 12.1%, 即加入了注意力机制的模型结果总体优于单模型。混合模型的误差都有所降低, 目前混合模型较好的是 CNN+LSTM 与 LSTM+GRU, MAPE 误差值分别为 0.177 和 0.159。A-HNN 分别与 CNN+LSTM、LSTM+GRU 以及 A-CNN+GRU 相比, 误差分别降低了 0.051、0.033 4、0.071, A-HNN 模型远远优于单模型, 且与目前其他混合神经网络相比误差更低。

表 4 表示三种两通道连接方式误差值, 分别是求和 (A-HNN-Add)、内积 (A-HNN-Multi)、连接 (A-HNN-Con), 以求和方式进行连接的预测误差最低, 因此两通道连接方式选择求和连接。

表 4 不同连接方式对比

Table 4 Comparison of different connection modes

模型	MAE	MAPE	RMSE
A-HNN-Add	<b>0.017</b>	<b>0.084 6</b>	<b>0.035</b>
A-HNN-Multi	0.024	0.1295	0.048
A-HNN-Con	0.025	0.1308	0.048

图 6—图 9 给出四个电站随机五天的预测结果, 横轴为五天的 7~20 个时间点, 纵轴表示有效利用小时。如图所示, 在气候波动较小的情况下, 各混合神经网络模型的预测效果均是较好的, 但对于气候波动较大的情况, A-HNN 模型对于多电站电量预

测效果更好, 与其他模型相比误差更低。

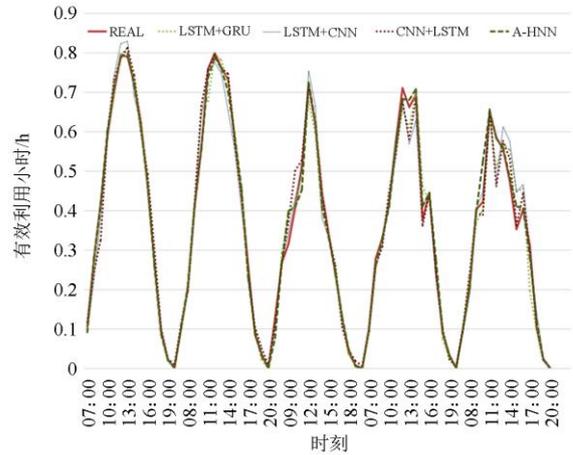


图 6 电站 1 预测结果

Fig. 6 Prediction results of power station 1

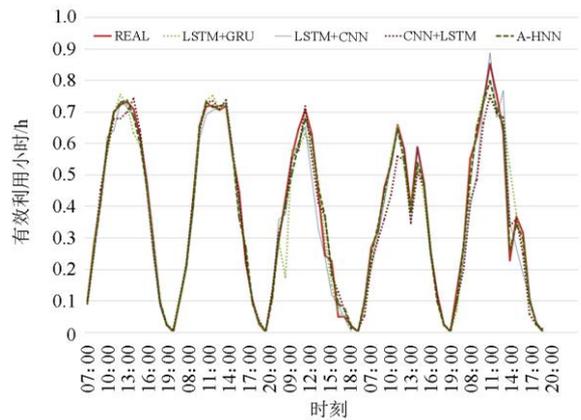


图 7 电站 2 预测结果

Fig. 7 Prediction results of power station 2

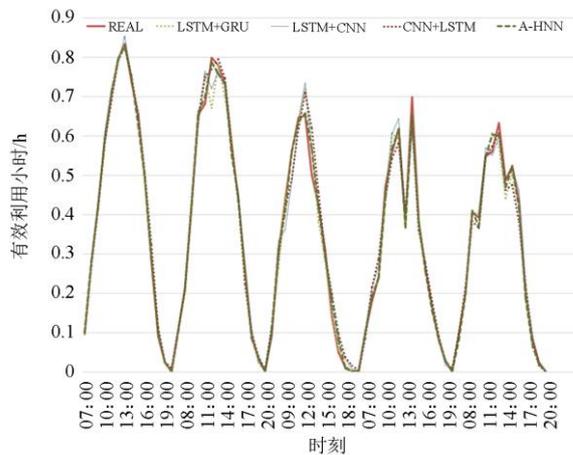


图 8 电站 3 预测结果

Fig. 8 Prediction results of power station 3

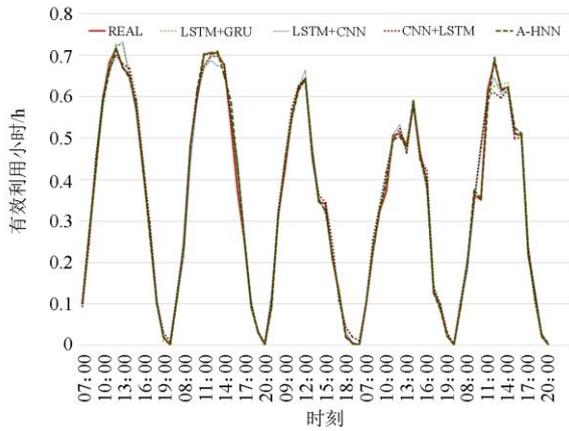


图 9 电站 4 预测结果

Fig. 9 Prediction results of power station 4

在实际应用过程中，5 个电站在实际应用过程中的预测准确率如表 5 所示。电站 1~4 为用于测试的电站，电站 5 为模型训练阶段使用过的电站。在实际应用过程中，电站 5 的预测效果优于电站 1~4，这是由不同电站之间细微的差距导致的。但从整体上看，MAPE 均在 0.15 以下，说明模型在实际预测时效果良好，符合应用的要求。因此，A-HNN 模型具有较强的泛化能力，在多电站预测中具有最佳的预测性能。

表 5 实际预测情况对比

Table 5 Comparison of different connection modes

电站	MAE	MAPE	RMSE
电站 1	0.02	0.107	0.041 4
电站 2	0.021	0.114	0.041 7
电站 3	0.02	0.110	0.040 6
电站 4	0.016	0.13	0.037 4
电站 5	0.015 5	0.092 3	0.032 5

## 4 结论

本文提出的 A-HNN 模型具有较高的准确率，较强的泛化能力，在多电站预测中，具有最佳的预测性能。其具有以下优势：

1) 根据皮尔逊相关系数选择了相关性较好的影响因素，然后根据自相关系数，计算出模型步长，并将小时数作为输入数据，使模型更容易提取以日为周期的数据特征。

2) 扩展因果卷积是卷积神经网络在时间序列的特别应用，它可以正确处理时间顺序并处理长期依赖，而不会导致模型复杂性的爆炸，它可以提取时间序列数据不同间隔、不同层次的特征。

3) LSTM 是时间序列预测的典型应用，具有较高的预测效果，所提出的模型结合了扩展因果卷积

和 LSTM 的优势，使用残差结构，增强了模型的泛化能力，实验结果表明，所提模型与现有人工智能预测方法相比具有较高的预测精度。

目前所提出的 A-HNN 模型已运用于多电站发电量预测系统中，天气情况的好坏直接影响光伏发电量的预测效果。接下来将研究不同天气对光伏发电的影响，并将环境影响因素细化到以电站为单位，用于模型训练中。

## 参考文献

- [1] DAS U K, TEY K S, SEYEDMAHMOUDIAN M, et al. Forecasting of photovoltaic power generation and model optimization: a review[J]. Renewable & Sustainable Energy Reviews, 2018, 81(1): 912-928.
- [2] 张静, 褚晓红, 黄学安, 等. 一种基于加权马尔科夫链修正的 SVM 光伏出力预测模型[J]. 电力系统保护与控制, 2019, 47(19): 63-68.  
ZHANG Jing, CHU Xiaohong, HUANG Xue'an, et al. A model for photovoltaic output prediction based on SVM modified by weighted Markov chain[J]. Power System Protection and Control, 2019, 47(19): 63-68.
- [3] 马骏, 江锐, 丁倩, 等. 基于多元宇宙优化支持向量机的短期光伏发电功率预测[J]. 热力发电, 2020, 49(4): 87-92.  
MA Jun, JIANG Rui, DING Qian, et al. Prediction of short-term photovoltaic generation power based on HIMVO-SVM[J]. Thermal Power Generation, 2020, 49(4): 87-92.
- [4] 朱琳琳, 钟志峰, 严海, 等. 一种新的光伏发电预测模型设计[J]. 太阳能学报, 2016, 37(1): 63-68.  
ZHU Linlin, ZHONG Zhifeng, YAN Hai, et al. A new design of photovoltaic power generation forecasting model[J]. Acta Energiæ Solaris Sinica, 2016, 37(1): 63-68.
- [5] SHI Jie, LEE W J, LIU Yongqian, et al. Forecasting power output of photovoltaic systems based on weather classification and support vector machines[J]. IEEE Transactions on Industry Applications, 2012, 48(3): 1064-1069.
- [6] 左远龙, 黄玉水, 杨晓辉, 等. 基于 PFA-MBAS-BP 神经网络模型的光伏发电短期预测[J]. 电力系统保护与控制, 2020, 48(15): 84-91.  
ZUO Yuanlong, HUANG Yushui, YANG Xiaohui, et al. Short-term prediction of photovoltaic power generation based on a PFA-MBAS-BP neural network model[J]. Power System Protection and Control, 2020, 48(15): 84-91.
- [7] ZHOU Hangxia, ZHANG Yujin, YANG Lingfan, et al.

- Short-term photovoltaic power forecasting based on long short term memory neural network and attention mechanism[J]. *IEEE Access*, 2019, 99: 78063-78074.
- [8] 郑强. 基于深度学习的光伏发电量预测模型研究[D]. 北京: 华北电力大学, 2019.
- ZHENG Qiang. Research on prediction model of photovoltaic generation based on deep learning[D]. Beijing: North China Electric Power University, 2019.
- [9] WANG Kejun, QI Xiaoxia, LIU Hongda. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network[J]. *Applied Energy*, 2019, 251.
- [10] WANG Kejun, QI Xiaoxia, LIU Hongda. Photovoltaic power forecasting based LSTM-convolutional network[J]. *Energy*, 2019, 189.
- [11] SHARADGA H, HAJIMIRZA S, BALOG R S. Time series forecasting of solar power generation for large-scale photovoltaic plants[J]. *Renewable Energy*, 2019, 150: 797-807.
- [12] SU D, BATZELIS E, PAL B. Machine learning algorithms in forecasting of photovoltaic power generation[C] // 2019 International Conference on Smart Energy Systems and Technologies (SEST), September 9-11, 2019, Porto, Portugal: 1-6.
- [13] 张旻, 李天喆, 张容进, 等. 基于信息融合的动态神经网络光伏功率预测[J]. *电力科学与技术学报*, 2020, 35(3): 68-73.
- ZHANG Min, LI Tianzhe, ZHANG Rongjin, et al. Photovoltaic power forecasting based on information fusion theory[J]. *Journal of Electric Power Science and Technology*, 2020, 35(3): 68-73.
- [14] ROSATO A, ARANEO R, ANDREOTTI A, et al. 2-D convolutional deep neural network for multivariate energy time series prediction[C] // 2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), June 11-14, 2019, Genova, Italy, 2019: 1-4.
- [15] HUANG Wei, ZHANG Chao, ZHANG Xinhe, et al. Photovoltaic power prediction model based on weather forecast[C] // 2019 IEEE Sustainable Power and Energy Conference (ISPEC), November 21-23, 2019, Beijing, China: 1596-1600.
- [16] TANG Xianlun, DAI Yuyan, WANG Ting, et al. Short-term power load forecasting based on multi-layer bidirectional recurrent neural network[J]. *IET Generation, Transmission & Distribution*, 2019, 13(17): 3847-3854.
- [17] 赵兵, 王增平, 纪维佳, 等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. *电网技术*, 2019, 43(12): 4370-4376.
- ZHAO Bing, WANG Zengping, JI Weijia, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU[J]. *Power System Technology*, 2019, 43(12): 4370-4376.
- [18] 吉梓铭, 李慧, 刘思嘉, 等. 基于 MIE-LSTM 的短期光伏功率预测[J]. *电力系统保护与控制*, 2020, 48(7): 50-57.
- JI Xingge, LI Hui, LIU Sijia, et al. Short-term photovoltaic power forecasting based on MIE-LSTM[J]. *Power System Protection and Control*, 2020, 48(7): 50-57.
- [19] OORD A V D, DIELEMAN S, ZEN H, et al. WaveNet: a generative model for raw audio[J]. *arXiv preprint arXiv: 1609.03499*, 2016.
- [20] SHEN Zhipeng, ZHANG Yuanming, LU Jiawei, et al. A novel time series forecasting model with deep learning[J]. *Neurocomputing*, 2020, 396: 302-313.
- [21] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C] // IEEE Conference on Computer Vision & Pattern Recognition, 2016: 770-778.
- [22] CHEN Kunjin, CHEN Kunlong, WANG Qin, et al. Short-term load forecasting with deep residual networks[J]. *IEEE Transactions on Smart Grid*, 2019, 10(4): 3943-3952.
- [23] 杨洁, 成珂. 基于数据挖掘的神经网络光伏发电预测研究[J]. *激光杂志*, 2018, 39(8): 59-62.
- YANG Jie, CHENG Ke. Research of neural network power forecasting model of photovoltaic system based on data mining method[J]. *Laser Journal*, 2018, 39(8): 59-62.

收稿日期: 2020-09-11; 修回日期: 2020-12-06

作者简介:

崔佳豪(1995—), 男, 硕士研究生, 研究方向为数据挖掘; E-mail: 502582283@qq.com

毕利(1968—), 女, 通信作者, 硕士, 教授, 硕士生导师, 研究方向为数据挖掘及智能信息系统集成。E-mail: billy1968@163.com

(编辑 魏小丽)