

基于神经网络的区域综合能源系统多时间尺度功率预测

王 炼¹, 窦真兰², 施超寅¹, 夏 景¹, 徐瀚诚², 贺林钰²

(1. 国网上海市电力公司松江供电公司, 上海 201600; 2. 国网上海综合能源服务有限公司, 上海 200023)

摘要: 考虑到区域综合能源系统 (RIES) 中可再生能源及负荷需求的时变性、不确定性等特点, 提出基于长短期记忆神经网络和卷积神经网络的短期 - 超短期多时间尺度功率预测方法, 为区域综合能源系统的优化调度提供有效准确的数据支撑。首先, 应用广泛处理较长时间序列问题的长短期记忆神经网络 (LSTM), 在采用数据处理以及贝叶斯优化求最佳超参数的基础上, 实现区域综合能源系统供需侧日前短期功率预测。为进一步提高预测准确度, 利用卷积神经网络 (CNN) 在数据提取方面的高效性, 同时采用双向长短期记忆神经网络 (BiLSTM) 进行双向训练, 实现 RIES 供需侧日内超短期功率预测。最后, 根据评价指标通过仿真验证了所提预测方法在 RIES 日前 - 日内优化调度中的有效性和适用性。

关键词: 神经网络; 多时间尺度; 功率预测; 区域综合能源系统; 评价指标

Multi-time scale power prediction of RIES based on neural network

WANG Lian¹, DOU Zhenlan², SHI Chaoyin¹, XIA Jing¹, XU Hancheng², HE Linyu²

(1. Songjiang Power Supply Company, State Grid Shanghai Electric Power Company, Shanghai 201600, China;

2. State Grid Shanghai Integrated Energy Service Co., Ltd., Shanghai 200023, China)

Abstract: Considering the time-varying and uncertain characteristics of renewable energy and load demand in the regional integrated energy system, a multi-time scale power prediction method based on long short-term memory neural network and convolutional neural network is proposed, which will provide effective and accurate data support for the optimal dispatch of regional integrated energy system. First, the short-term power prediction of the RIES supply and demand side based on data processing and Bayesian optimization to find the best hyperparameters is realized by using the LSTM neural network which widely deals with long-time series problems. To further improve the prediction accuracy, the intraday ultra-short-term power prediction on the supply and demand side of RIES is realized using the efficiency of CNN in data extraction and the bidirectional training of BiLSTM. Finally, the effectiveness and applicability of the proposed forecasting method in RIES multi-time scale optimal scheduling are verified by simulations according to the evaluation index.

Key words: neural network; multi-time scale; power prediction; regional integrated energy system; evaluation index

0 引言

为减少对化石能源的依赖, 光伏、风电等可再生能源被广泛应用。同时, 引入电-氢-热-气的区域综合能源系统, 推动可再生能源大规模利用

以及多种能源技术的融合与发展^[1-2]。针对可再生能源和负荷需求的时变性、不确定性等特点, 区域综合能源系统的供需侧功率预测可为其优化调度提供重要支撑, 是作为系统制订合理调度计

划的重要步骤^[3]。目前,供需侧功率预测主要包括以日或周为周期的短期预测和以小时、分钟甚至秒为周期的超短期预测。功率预测常采用的方法有常规统计方法(如回归分析、时间序列)、传统方法(如卡尔曼滤波、灰色预测)、智能预测法以及一些新兴的方法^[4]。

回归分析法、时间序列法作为常规统计方法,其主要区别为对数据特性的认知不同。回归分析法体现数据的独立性,预测误差不会随预测时间的增加而积累,但其学习能力较差,无法处理非线性关系^[5-6]。文献[7]利用模糊预测法对回归分析法进行改进,提高了负荷预测准确度。时间序列法是短期预测中使用最为广泛的一种方法,利用数据间的相关性达到预测目的,虽然所需历史数据较少,且计算较快,但其预测误差会随预测时间的增加而积累,且异常数据对预测结果影响较大,导致其预测具有不确定性。回归分析法与时间序列法都适用于历史数据较平稳的条件。卡尔曼滤波法又称为状态空间法,文献[8]对卡尔曼滤波法进行了改进,并应用于负荷短期预测中,其预测结果较时间序列法预测更为精确,但在实际应用中较为复杂。灰色预测法可以应用于处理非线性关系的数据预测,但当历史数据离散程度较大时,其预测准确度较差,具有一定局限性。

区域综合能源系统(Regional Integrated Energy System, RIES)供给侧的光伏、风电等可再生能源具有随机性、波动性,直接并网会影响公共电网的安全稳定,大规模应用会造成弃光、弃风现象^[9]。同时,需求侧的多样化负荷受天气、节假日等因素的影响具有波动性^[10]。因此,常规统计方法和传统方法已不再适用现阶段的短期功率预测。自20世纪90年代以来,越来越多的人工智能算法应用于RIES供需侧功率预测。其中,人工神经网络(Artificial Neural Network, ANN)具有自主学习和自适应能力,可以用于处理天气、节假日和温度等外部因素对供需侧功率的影响,且计算能力强、容错程度高,因此在短期功率预测中具有较强的效

果。除了ANN外,BP神经网络具有出色的非线性映射能力、泛化能力和容错能力,同样在短期功率预测中有较好的预测效果^[11]。但ANN和BP神经网络作为常规神经网络,对训练样本的依赖性较强,在训练过程中会出现过拟合现象,表现为拟合误差减小,预测误差增加,泛化能力下降。

深度神经网络(Deep Neuron Net, DNN)学习算法具有优良的拟合能力,如递归神经网络(Recursive Neural Network, RNN)、长短期记忆(Long Short-Term Memory, LSTM)神经网络和卷积神经网络(Convolutional Neural Network, CNN)等^[12]。文献[13]将多个RNN层叠加形成深层循环神经网络预测模型,在处理家庭负荷不确定性问题时表现较为突出。但RNN存在梯度弥散、长期记忆能力较差等问题。因此,文献[14]采用LSTM神经网络构建负荷预测模型,在训练过程中不仅考虑了负荷历史数据,还考虑了气温、节假日等因素,与K近邻算法和支持向量机相比预测准确度更高。LSTM神经网络具有时序性和非线性特点,适用于RIES供需侧短期功率预测。

为进一步提高超短期功率预测准确度,可以利用CNN降低人为提取特征所带来误差的优势,与其他智能算法共同实现综合模型预测。文献[15]将CNN和门控循环单元(Gated Recurrent Unit, GRU)结合构建了CNN-GRU模型,与CNN、GRU两种单一模型相比,具有更高的预测准确度。文献[16]利用时间卷积神经网络(Temporal Convolutional Network, TCN)对LSTM进行改进,采用改进LSTM-TCN模型对风电进行超短期预测,与两种单一模型相比,可以改善过拟合现象,提高预测准确度,节省模型训练时间。由于LSTM无法挖掘非连续数据之间的关系,本文将CNN与双向长短期记忆(Bi-directional Long Short Term Memory, BiLSTM)神经网络结合,利用CNN在数据提取方面的优势,同时采用BiLSTM进行双向训练,提高RIES供需侧超短期功率预测准确度。

1 区域综合能源系统构成

本文研究的电-氢-热-气RIES的结构如图1所示,包括能源供给侧、需求侧以及能源转换存储层三部分。在此RIES中,属于能源供给侧的风电机组和光伏机组是可再生能源,具有清洁无污染的优点,但同时具有间歇性和波动性,会造成弃风、弃光现象。能源需求侧的电负荷、氢负荷、热负荷和气负荷的波动性较强,结合风电机组和光伏机组发电的不确定性,需要合理的多时间尺度供需侧功率预测为RIES精确的优化调度提供数据支撑,以提高系统的经济性、可靠性和安全性。




图1 电-氢-热-气 RIES 结构图

Fig. 1 Electrical-hydrogen-thermal-gas RIES structural diagram

2 基于LSTM神经网络的日前短期功率预测

本文的短期功率预测为未来一天以1 h为时间尺度的预测值,适用于RIES日前优化调度。采用LSTM神经网络对供需侧功率进行短期预测,并采用时间序列法对历史数据进行一定间隔的采集和记录。

2.1 LSTM神经网络

RIES中供需侧功率的历史数据是按照一定的时间跨度存储的,具有时序性,一般神经网络(如BP神经网络)无法提取长时间序列中隐藏的时间信息,因此需要DNN。DNN是具有多层隐含层的神经网络,第一层为输入层,最后一层为输出层,中间均为隐含层,如图2所示。




图2 深度神经网络结构示意图

Fig. 2 Schematic diagram of the structure of a deep neural network

DNN的隐含层常见的神经元结构有RNN、LSTM神经网络和CNN等。LSTM神经网络可以有效解决RNN的梯度弥散、长期记忆能力较差等问题,被广泛用于处理较长时间序列的问题^[17]。标准的LSTM神经网络结构如图3所示,与RNN的不同之处在于提出了门机制,并引入记忆细胞。门机制使LSTM神经网络可以实现信息选择性存储,记忆细胞的存在可以控制模型信息的增减以及修改,因此更适用于较长的时间序列数据。LSTM神经网络具有时序性和非线性特点,适用于RIES的供需侧功率预测。




图3 标准 LSTM 神经网络结构

Fig. 3 Standard LSTM neural network structure

图3中, C 为细胞状态; x 为输入值; h 为输出值; σ 为激活函数,常使用Sigmoid。LSTM神经网络的三个门为遗忘门(Forget Gate)、输入门(Input Gate)和输出门(Output Gate)。

细胞状态:贯穿于整个LSTM神经网络的链式系统中,其表达式为

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

式中, f_t 为遗忘门; i_t 为输入门; $\tilde{C}_t$ 为细胞状态更

新值。

遗忘门 f_t ：前一时刻的记忆细胞中哪些信息会被用于计算当前时刻记忆细胞，由前一时刻的输出值以及当前时刻的输入值组成，其表达式为

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

式中， W_f 为遗忘门权重参数； b_f 为遗忘门偏置项。

输入门 i_t ：保留当前有用信息到当前时刻记忆细胞中，同时可以更新细胞状态，其表达式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (4)$$

式中， W_i 为输入门权重参数； b_i 为输入门偏置项； W_c 为细胞状态更新的权重参数； b_c 为细胞状态更新的偏置项。

输出门 O_t ：控制细胞状态的输出量到最终输出 h_t ，其表达式为

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

$$h_t = O_t \times \tanh(C_t) \quad (6)$$

式中， W_o 为输出门权重参数； b_o 为输出门偏置项。

2.2 日前短期功率预测模型

进行相关分析和输入到神经网络之前，对数据进行数据归一化处理，即

$$x = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

式中， x 为输入数据； $x_{\max}$ 为输入数据最大值； $x_{\min}$ 为输入数据最小值。

LSTM神经网络结构如图4所示。贝叶斯优化算法可以利用已有的信息影响后续超参数的选择，同时贝叶斯优化兼具搜索速度快以及高效准确的特点^[18]。因此，本文采用贝叶斯优化得到隐含层节点数、初始学习率和正规化系数等最佳超参数。在数据处理以及采用贝叶斯优化求最佳超参数的基础上，所构建的LSTM神经网络模型包括一个输入层、多个LSTM网络层作为隐含层和一个输出层，激活函数采用ReLU，梯度下降算法采用自适应矩估计。




图4 LSTM神经网络结构图

Fig. 4 LSTM neural network structure diagram

2.2.1 激活函数

激活函数ReLU指代斜坡函数，相较于Sigmoid函数，ReLU函数具有无梯度消失问题、网络稀疏、运算简单以及收敛快等特点，更适用于激活机制，其表达式为

$$f(x) = \max(0, x) \quad (8)$$

2.2.2 梯度下降算法

自适应矩估计(Adam)优化算法同时利用了动量随机梯度下降法的一阶矩估计以及均方根传递优化算法的二阶矩估计进行学习率的动态调整，其表达式为

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (9)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (10)$$

$$\tilde{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (11)$$

$$\tilde{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (12)$$

$$\theta_t = \theta_{t-1} - \frac{\alpha}{\sqrt{\tilde{v}_t} + \epsilon} \tilde{m}_t \quad (13)$$

式中， m_t 为梯度的一阶矩估计； v_t 为梯度的二阶矩估计； g_t 为梯度； $\tilde{m}_t$ 为修正后的一阶矩估计

值； $\tilde{v}_t$ 为修正后的二阶矩估计值； θ_t 为第 t 轮梯度下降法的参数； α 为学习率，取 0.001； β_1 、 β_2 为指数衰减速率，分别取 0.9、0.999； ε 为常数，取 10^{-8} 。

3 基于CNN-BiLSTM的日内超短期功率预测

本文的超短期功率预测为未来一天以 15 min 为时间尺度的预测值，以用于RIES日内优化调度。日内优化调度所需的供需侧功率预测数据需要更高的预测准确度，而采用LSTM神经网络进行超短期预测时，其准确度较差。因此本文采用CNN和BiLSTM神经网络的混合模型进行超短期预测，以提高预测准确度，满足日内优化调度需求。

3.1 CNN-BiLSTM网络

CNN结构如图5所示，包括一个输入层、两个卷积层、一个最大值池化层、一个全连接层和一个输出层，激活函数采用ReLU，梯度下降算法采用Adam。其中，第一个卷积层使用32个特征图，第二个卷积层使用64个卷积层。




图5 CNN结构图

Fig. 5 CNN structure diagram

基于LSTM神经网络的功率预测是按照时间序列以从前至后的顺序进行学习，具有单向性，不利于挖掘数据间的前后属性关系^[19]。BiLSTM神经网络结构如图6所示。




图6 BiLSTM神经网络结构示意图

Fig. 6 Schematic diagram of the biLSTM neural network structure

BiLSTM神经网络的隐含层是在正向LSTM的基础上改良为由正向LSTM和反向LSTM共同组成。正向LSTM即利用历史信息对未来信息进行预测，反向LSTM即利用未来信息对历史信息进行预测，因此BiLSTM学习具有双向性，可进一步提高模型的预测准确度。

3.2 日内超短期功率预测模型

本文所构建的日内超短期功率预测模型为CNN-BiLSTM混合神经网络模型，采用时间序列法对供需侧功率进行超短期预测，结合CNN和BiLSTM神经网络各自的优点，将RIES供需侧功率的历史数据作为输入，先利用CNN高效提取数据信息形成特征向量，并将特征向量作为新的时间序列数据输入到BiLSTM神经网络中进行以 15 min 为时间尺度的超短期预测。CNN-BiLSTM神经网络结构如图7所示，包括一个输入层、两个卷积层、一个最大值池化层、三个隐含层、一个全连接层和一个输出层，激活函数采用ReLU，梯度下降算法采用Adam。

4 算例分析

4.1 评价指标

本文采用均方根误差（Root Mean Square Error, RMSE）、平均绝对误差（Mean Absolute

Error, MAE) 以及决定系数 (R-Square, R2) 作为预测模型的评价指标, 分析RIES供需侧功率预测结果^[20]。




图7 CNN-BiLSTM神经网络结构图

Fig. 7 CNN-BiLSTM neural network structure diagram

RMSE: 评价预测数据与真实数据之间的误差, 对异常数据较敏感, 预测数据的误差越大, 则RMSE值越大, 因此可以用RMSE评价预测模型的误差情况, 其表达式为

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \hat{P}_i)^2} \quad (14)$$

式中, n 为样本数量; P 为光伏机组出力真实数据; $\hat{P}$ 为光伏机组预测数据。

MAE: 评价预测数据与真实数据之间的平均绝对误差, MAE越小, 表示预测模型越优秀, 其表达式为

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - \hat{P}_i| \quad (15)$$

R2: 评价预测模型拟合程度的好坏, R2越大, 表示拟合程度越好, 预测模型越精确, 其表达式为

$$R2 = 1 - \frac{\sum_{i=1}^n (P_i - \hat{P}_i)^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (16)$$

式中, $\bar{P}$ 为真实数据的平均值。

4.2 日前短期功率预测

以某RIES 2019年11月1—21日的光伏机组出力504个历史数据作为训练集, 对11月22日00:00~23:00的光伏发电功率进行预测, 以每1 h为间隔的24个时段预测结果如图8所示, 预测误差评价指标见表1。




图8 光伏短期预测结果

Fig. 8 PV short-term forecast results

表1 基于LSTM的光伏日前短期功率预测误差评价指标

Tab. 1 Short-term power forecast error evaluation index of photovoltaic days ahead based on LSTM

预测模型	RMSE	MAE	R2
LSTM	8.115 5	4.938 2	0.965 7

基于LSTM神经网络的光伏日前短期功率预测的RMSE为8.115 5, 在预期误差准确度要求范围10以内。MAE约为4.938 2, 表明LSTM预测模型较为优秀; R2约为0.965 7, 说明预测模型拟合度较好。综上, LSTM预测模型可用于RIES供需侧日前短期功率预测。

采用LSTM预测模型, 2019年11月22日供给侧风电短期预测结果如图9所示, 需求侧短期功率预测结果如图10所示, 供需侧预测误差见表2。由表2可知, 采用LSTM神经网络对光伏、风电、电负荷、氢负荷、热负荷和气负荷进行短期功率预测, 满足日前优化调度要求, 即供给

侧预测功率的RMSE小于10,需求侧预测功率的RMSE小于5。其中,风电短期预测结果虽有较大误差,但其RMSE为9.013,仍满足日前优化调度要求。




图9 RIES 供给侧风电短期预测结果

Fig. 9 RIES supply-side wind power short-term forecast results




图10 RIES 需求侧短期预测结果

Fig. 10 RIES demand-side short-term forecast results

表2 基于LSTM的日前短期功率预测误差评价指标

Tab. 2 Evaluation index of short-term power forecast error based on LSTM

区域综合能源系统		RMSE	MAE	R2
供给侧	光伏	8.115 5	4.938 2	0.965 7
	风电	9.013 4	6.16	0.811 8
	电负荷	2.402 9	1.954	0.925 8
需求侧	氢负荷	2.125 4	1.412 2	0.950 8
	热负荷	2.927 7	2.079 5	0.887 8
	气负荷	0.841 2	0.613 9	0.920 9

4.3 日内超短期功率预测

4.3.1 预测模型对比

以某RIES 2019年11月1—21日的光伏机组出力2 016个历史数据作为训练集,分别使用

CNN、LSTM和CNN-BiLSTM三种预测模型对2019年11月22日00:00~23:45的光伏发电功率进行预测,以每15 min为间隔的96个时段预测结果如图11所示,预测误差评价指标见表3。




图11 光伏超短期预测结果

Fig. 11 PV ultra-short-term forecast results

表3 光伏日内超短期功率预测误差评价指标

Tab. 3 Photovoltaic intraday ultra-short-term power prediction error evaluation index

预测模型	RMSE	MAE	R2
CNN	5.364 1	2.355 6	0.987 6
LSTM	5.196 3	2.560 2	0.986 4
CNN-BiLSTM	4.714 9	2.235 5	0.990 5

对比表1与表3中的光伏发电功率预测误差指标,日内超短期预测的RMSE为5.196 3,小于日前短期预测的8.115 5, RMSE降低了35.98%,这表明基于CNN-BiLSTM的日内超短期功率预测准确度较高。根据表3可知, CNN-BiLSTM预测模型的RMSE较CNN降低了12.10%,较LSTM降低了10.19%,表明预测数据误差较小; MAE较CNN降低了5.10%,较LSTM降低了12.68%,表明预测模型更优秀; R2较CNN升高了0.29%,较LSTM升高了0.42%,表明拟合程度越好。综上,基于CNN-BiLSTM的超短期功率预测准确度比CNN和LSTM更高,从而满足日内优化调度供给侧预测数据的RMSE小于5的要求。

光伏发电功率的日前短期预测与日内超短期预测对比如图12所示。日前短期预测趋势与真实数据趋势基本一致,而日内超短期预测数据与真实数据误差更小,准确度更高,因此超短期预测较短期预测更适用于日内优化调度。




图 12 光伏不同时间尺度预测结果对比

Fig. 12 Comparison of forecast results for different time scales of photovoltaics

4.3.2 基于 CNN-BiLSTM 的超短期预测结果

RIES 2019年11月22日基于CNN-BiLSTM预测模型的供给侧风电功率超短期预测结果如图13所示,需求侧功率超短期预测结果如图14所示,供需侧超短期预测误差评价指标见表4。




图 13 RIES 供给侧风电超短期预测结果

Fig. 13 RIES supply-side wind power ultra-short-term forecast results




图 14 RIES 需求侧超短期预测结果

Fig. 14 RIES demand-side ultra-short-term forecast results

表 4 基于 CNN-BiLSTM 的日内超短期功率预测误差评价指标

Tab. 4 Evaluation index of intraday ultra-short-term power prediction error based on CNN-BiLSTM

区域综合能源系统		RMSE	MAE	R2
供给侧	光伏	4.714 9	2.235 5	0.990 5
	风电	3.497	2.734 1	0.974 7
需求侧	电负荷	1.852 7	1.367 8	0.957 4
	氢负荷	1.228 3	0.602 5	0.983 7
	热负荷	1.928 2	1.288 4	0.950 9
	气负荷	0.449 2	0.330 3	0.972 0

从表4可知,光伏、风电日内超短期功率预测的RMSE均小于5,电负荷、氢负荷、热负荷和气负荷的RMSE均小于2,满足日内优化调度要求。同时,考虑到预测结果可能存在不良数据,如供需侧预测功率为负,此类不符合实际的情况,因此在进行日前优化调度和日内优化调度之前,需要将不良数据进行修正。

5 结束语

面对RIES中具有时变性、不确定性等特点的可再生能源及负荷需求,本文提出基于神经网络的短期-超短期多时间尺度功率预测方法。其中,LSTM神经网络广泛应用于处理较长时间序列问题,适用于对RIES供需侧功率进行日前短期预测。为进一步提高预测准确度,采用高效提取数据的CNN及双向训练的BiLSTM对RIES供需侧功率进行日内超短期预测。最后,根据评价指标通过仿真结果证明了本文所提方法的有效性。基于LSTM神经网络的短期预测方法可用于RIES日前优化调度,基于CNN和BiLSTM神经网络的超短期预测方法较CNN和LSTM神经网络预测准确度更高,适用于RIES日内优化调度。

参考文献

- [1] 王永利,刘振,薛露,等.基于多主体博弈的综合能源系统运行优化方法[J].控制理论与应用,2022,39(3):499-508.
- [2] 李云鹭,刘吉臻,马素玲,等.基于变工况模型的综合能源系统源-荷互动多目标优化调度[J].电网技术,2022,46(7):2472-2485.

- [3] 路朋, 叶林, 裴铭, 等. 风电集群有功功率模型预测协调控制策略[J]. 中国电机工程学报, 2021, 41(17): 5887-5900.
- [4] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152.
- [5] 成珂, 孙琦琦, 马晓瑶. 基于主成分回归分析的气象因子对光伏发电量的影响[J]. 太阳能学报, 2021, 42(2): 403-409.
- [6] 王雁凌, 吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. 电力自动化设备, 2018, 38(3): 133-139.
- [7] 冯斌. 基于改进模糊回归分析法的负荷预测[J]. 黑龙江电力, 2010, 32(4): 258-261.
- [8] 李明干, 孙健利, 刘沛. 基于卡尔曼滤波的电力系统短期负荷预测[J]. 继电器, 2004(4): 9-12.
- [9] 杨留锋. 光伏发电预测中人工智能算法的应用研究综述[J]. 太阳能, 2020(8): 30-35.
- [10] 周佃民, 管晓宏, 孙婕, 等. 基于神经网络的电力系统短期负荷预测研究[J]. 电网技术, 2002(2): 10-13, 18.
- [11] 丁明, 王磊, 毕锐. 基于改进BP神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制, 2012, 40(11): 93-99, 148.
- [12] 刘春, 蒯生宝, 李维华, 等. 基于NAR动态神经网络的BDS周跳探测与修复方法[J]. 电子测量与仪器学报, 2021, 35(7): 36-43.
- [13] SHI H, XU M, LI R. Deep Learning for Household Load Forecasting—A Novel Pooling Deep RNN[J]. IEEE Transactions on Smart Grid, 2018, 9(15): 5271-5280.
- [14] 庞传军, 张波, 余建明. 基于LSTM循环神经网络的短期电力负荷预测[J]. 电力工程技术, 2021, 40(1): 175-180, 194.
- [15] 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.
- [16] 符杨, 任子旭, 魏书荣, 等. 基于改进LSTM-TCN模型的海上风电超短期功率预测[J]. 中国电机工程学报, 2022, 42(12): 4292-4303.
- [17] 陈海鹏, 周越豪, 王趁录, 等. 基于改进的CNN-LSTM短期风功率预测的系统旋转备用经济性分析[J]. 高电压技术, 2022, 48(2): 439-448.
- [18] 党凯凯. 基于时间序列和贝叶斯神经网络的非平稳时期光伏功率预测[D]. 西安: 西安理工大学, 2021.
- [19] 史凯钰, 张东霞, 韩肖清, 等. 基于LSTM与迁移学习的光伏发电功率预测数字孪生模型[J]. 电网技术, 2022, 46(4): 1363-1372.
- [20] 简献忠, 顾洪志, 王如志. 一种基于双通道CNN和LSTM的短期光伏功率预测方法[J]. 电力科学与工程, 2019, 35(5): 7-11.

作者简介

王炼(1982—), 男, 工程师, 研究方向为电气工程及其自动化、电力市场营销。

(收稿日期: 2022-09-18)