

基于 LSTM 循环神经网络的短期电力负荷预测

庞传军^{1,2}, 张波^{1,2}, 余建明^{1,2}

(1. 南瑞集团(国网电力科学研究院)有限公司, 江苏南京 211106;
2. 北京科东电力控制系统有限责任公司, 北京 100192)

摘要:为了保障电网安全稳定和电力市场高效运行, 电网调度人员和电力市场参与者对电力负荷预测准确度提出了更高要求, 分布式电源和间歇性负荷是影响负荷精准预测的关键因素。针对传统负荷预测方法无法同时对负荷本身变化规律及其影响因素进行建模的问题, 提出基于长短期记忆单元(LSTM)的负荷预测方法。利用具备时序记忆功能的LSTM构建深度循环神经网络(RNN), 综合考虑历史负荷和各类负荷影响因素建立负荷预测模型。该方法利用神经网络的特征提取能力和LSTM的时序记忆能力, 能在更长的历史时间范围内辨识负荷内在变化规律及各类影响因素对负荷的非线性影响。基于实际负荷数据对不同历史时间窗口、不同网络架构的负荷预测性能进行验证, 并与其他负荷预测算法进行比较, 结果表明所提方法能有效提升负荷预测准确性。

关键词:电力系统; 负荷预测; 长短期记忆单元(LSTM); 循环神经网络(RNN); 机器学习

中图分类号: TM910.6

文献标志码:A

文章编号:2096-3203(2021)01-0175-06

0 引言

电力系统负荷预测可对未来一段时间的电力需求进行估计, 从而根据负荷预测结果安排未来一段时间的机组组合计划、发电计划、联络线交换计划, 组织电力现货交易。因此, 准确的负荷预测是实现电力系统安全、经济运行的基础^[1]。

电力系统负荷受天气、节假日、特殊事件等因素的影响, 负荷变化随机性较大^[2-4]。分布式电源的接入和电动汽车的广泛应用进一步加大了负荷的随机性和波动性^[5-7], 增加了负荷精准预测难度。电力负荷预测方法主要分为两大类:统计学方法和基于机器学习的方法。统计学方法采用时间序列方法进行预测^[8-9], 主要包括多元线性回归(multiple linear regression, MLR)、自回归(auto regression, AR)、自回归移动平均(auto regressive moving average, ARMA)等。该类方法对电力负荷序列的平稳性要求较高, 但电力负荷具有较强的随机性, 不是平稳时间序列。为了提高负荷预测的准确性, 诸多研究将机器学习算法应用在电力负荷预测领域。文献[10]采用 K 近邻(K-nearest neighbor, KNN)算法实现短期电力负荷预测, 提升了负荷预测的精度和计算速度;文献[11]基于深度信念网络构建母线负荷预测模型;文献[12]提出基于改进人工神经网络的短期负荷预测方法;文献[13]将随机森林回归算

收稿日期:2020-07-09;修回日期:2020-08-27

基金项目:国家电网有限公司科技项目(4000-201940193A-0-0-00)

法应用于短期电力负荷预测;文献[14]应用支持向量机(support vector machines, SVM), 并引入实时电价这一影响因素提升负荷预测准确度;文献[15]提出基于多模型融合 Stacking 集成学习方式的负荷预测方法。机器学习方法从历史负荷数据中学习隐含规律, 具备较强的非线性建模能力。传统的机器学习方法仅能学习各类影响因素与负荷之间的非线性关系, 未考虑负荷本身的时序依赖关系。

为了兼顾负荷本身的时序依赖关系, 采用长短期记忆单元(long short-term memory, LSTM)构建负荷预测模型。利用 LSTM 替代原有循环神经网络(recurrent neural network, RNN)中的神经元, 使普通 RNN 具备时序记忆能力, 实现对负荷本身时序特性、影响因素与负荷之间复杂关系的建模。该方法可以灵活定义历史窗口期、灵活添加负荷影响因素, 且预测准确性和稳定性较高。

1 RNN

1.1 普通 RNN

RNN 是一种能够处理时间序列数据的神经网络^[16], 广泛应用于自然语言处理领域^[17], 在电力系统中也有应用^[18]。RNN 架构如图 1 所示。

与前馈神经网络相比, RNN 隐藏层中的每个神经元可以通过自链接循环使用。给定输入数据 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t, \dots, \mathbf{x}_T\}$, RNN 采用式(1)和式(2)计算隐藏状态 $\mathbf{h} = \{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_t, \dots, \mathbf{h}_T\}$ 和输出 $\mathbf{y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_t, \dots, \mathbf{y}_T\}$ 。其中 T 为 1 d 内根据采样间隔计算的采样点数量。

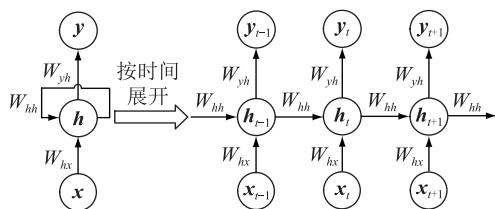


图 1 RNN 架构

Fig.1 The architecture of RNN

$$\mathbf{h}_t = f(W_{hx}\mathbf{x}_t + W_{hh}\mathbf{h}_{t-1} + \mathbf{b}_h) \quad (1)$$

$$\mathbf{y}_t = g(W_{yh}\mathbf{h}_t + \mathbf{b}_y) \quad (2)$$

式中: \mathbf{x}_t 为 t 时刻的输入; \mathbf{y}_t 为 t 时刻的输出; \mathbf{h}_t 为 t 时刻的隐藏状态; W_{hx} , W_{hh} , W_{yh} 分别为输入、隐藏和输出权重; \mathbf{b}_h , \mathbf{b}_y 分别为隐藏状态和输出的偏置; $f(\cdot)$, $g(\cdot)$ 分别为隐藏层和输出层激活函数。

RNN 采用 \mathbf{h}_{t-1} 记忆 t 时刻之前的所有输入信息, t 时刻输出 \mathbf{y}_t 不但受该时刻输入 \mathbf{x}_t 的影响, 还受 \mathbf{h}_{t-1} 的影响。RNN 采用时间反向传播(back propagation through time, BPTT) 算法进行训练^[16-17], 训练过程中存在梯度消失问题, 导致 RNN 不能学习时间序列的长距离时序依赖关系^[19]。LSTM 在神经元中加入记忆单元和门控单元, 使 RNN 具备记忆能力, 从而可以学习时序数据的长期依赖关系。

1.2 LSTM

LSTM 是对普通神经元的改进, 在隐藏层的每个神经元引入记忆单元, 并采用遗忘门、输入门、输出门 3 个门控单元控制记忆单元的状态, 解决普通 RNN 不能学习长距离时序依赖的问题^[19]。LSTM 结构如图 2 所示^[20-21]。

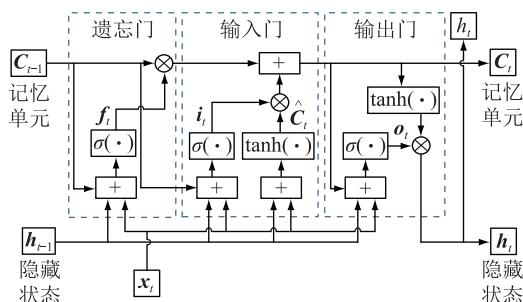


图 2 LSTM 结构

Fig.2 The structure of LSTM

记忆单元与隐藏状态一起记忆序列数据的历史信息。记忆单元中的信息受 3 个门控单元的控制。遗忘门根据 \mathbf{h}_{t-1} 和 \mathbf{x}_t 删除记忆单元中的信息。遗忘门为:

$$f_t = \sigma(W_f[\mathbf{h}_{t-1} \mathbf{x}_t]) + \mathbf{b}_f \quad (3)$$

式中: $\sigma(\cdot)$ 为 sigmoid 激活函数; W_f 为遗忘门权重; \mathbf{b}_f 为遗忘门偏置。

输入门根据 \mathbf{h}_{t-1} 和 \mathbf{x}_t 向记忆单元中新增信息,

如式(4)、式(5)所示。

$$i_t = \sigma(W_i[\mathbf{h}_{t-1} \mathbf{x}_t]) + \mathbf{b}_i \quad (4)$$

$$\hat{\mathbf{C}}_t = \tanh(W_c[\mathbf{h}_{t-1} \mathbf{x}_t]) + \mathbf{b}_c \quad (5)$$

式中: i_t 为需要记忆的信息; $\hat{\mathbf{C}}_t$ 为候选记忆单元, 用于更新记忆单元; W_i , W_c 为输入门权重; \mathbf{b}_i , \mathbf{b}_c 为输入门偏置。

遗忘门和输出门计算完成后, 采用式(6)更新记忆单元。

$$\mathbf{C}_t = f_t \circ \mathbf{C}_{t-1} + i_t \circ \hat{\mathbf{C}}_t \quad (6)$$

式中: \circ 为哈达玛乘积。

输出门根据 \mathbf{h}_{t-1} , \mathbf{x}_t , \mathbf{C}_t , 决定 \mathbf{h}_t 。

$$o_t = \sigma(W_o[\mathbf{h}_{t-1} \mathbf{x}_t]) + \mathbf{b}_o \quad (7)$$

$$\mathbf{h}_t = o_t \circ \tanh \mathbf{C}_t \quad (8)$$

式中: W_o 为输出门权重; \mathbf{b}_o 为输出门偏置。

采用 LSTM 替换普通 RNN 中的神经元构建负荷预测模型, 利用 LSTM 能学习长距离时序依赖的优点, 对电力负荷中隐藏的历史运行规律进行学习。

2 基于 LSTM 的负荷预测模型

2.1 基本思路

电力系统负荷受人们生产生活规律的影响, 具备周期性、趋势性, 同时又受天气变化、重大事件等随机因素的影响, 具有较大的不确定性。某天某一时刻的负荷 $l_{t,d}$ 受当天日期类型(周几、是否节假日)和当前时刻天气因素(温度、湿度等)的影响, 同时又与当天历史 n 个时刻的负荷和历史几天同一时刻的负荷有关。利用 LSTM 能学习长距离时序依赖的优点, 在考虑预测日当天相关因素对负荷影响的基础上, 从横向识别预测日当天负荷变化的规律, 从纵向上识别历史日期窗口内同一时刻负荷的变化规律。

2.2 模型结构

基于 LSTM 网络, 用预测日前 w 天的负荷曲线和负荷影响因素对预测日负荷进行预测, LSTM 网络结构如图 3 所示。图中, 模型输出为预测日的预测负荷, 如式(9)所示。

$$\hat{L}_d = \{\hat{l}_{0,d}, \hat{l}_{1,d}, \dots, \hat{l}_{t,d}, \dots, \hat{l}_{T,d}\} \quad (9)$$

式中: 当采样间隔为 15 min 时, $T=96$ 。

历史负荷为:

$$L_{t,d-w} = \{l_{t,d-1}, l_{t,d-2}, \dots, l_{t,d-w}\} \quad (10)$$

式中: $l_{t,d-w}$ 为预测日前 w 天 t 时刻的负荷。

负荷影响因素为:

$$F_{t,d} = \{w_{t,d}, e_{t,d}, \dots, h_{t,d}\} \quad (11)$$

式中: $w_{t,d}$ 为天气信息; $h_{t,d}$ 为 0-1 变量, 为 0 代表非

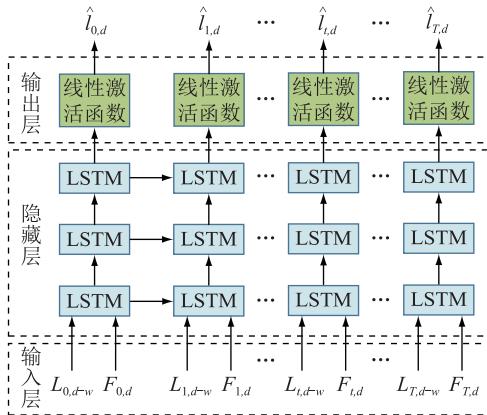


图 3 用于负荷预测的 LSTM 网络模型

Fig.3 LSTM network model for load forecast

工作日,为 1 代表工作日; $e_{t,d}$ 为影响负荷的特殊事件; $F_{t,d}$ 中还可包含影响负荷的其他因素。

建立的负荷预测模型中,第 t 时刻的输入由历史负荷和负荷影响因素共同构成,可表示为 $I_{\text{input}} = \{L_{t,d-w}, F_{t,d}\}$,输出为 $O_{\text{output}} = \hat{l}_{t,d}$ 。

2.3 模型训练过程

预测模型的训练过程包含数据预处理、模型训练、模型评价 3 个阶段。

2.3.1 数据预处理

数据预处理主要包括数据向量化和标准化 2 个步骤。神经网络基于线性代数理论,不能直接在原始数据上进行训练,在训练之前需要将原始数据转换为向量^[22]。数据向量化将 $L_{t,d-w}$ 与 $F_{t,d}$ 进行拼接,拼接后的数据转化为向量。

神经网络采用基于梯度下降的反向传播算法进行训练^[22],数据太大或太小会导致很难寻求到最优解。因此,将数据归一化到标准区间有利于模型求解。采用最小-最大归一化方法将向量中的每个元素归一化到区间 $[0,1]$,如式(12)所示^[22]。

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

式中: X_{\max} , X_{\min} 分别为最大、最小值; X 为原始值; X_{norm} 为归一化后的值。

2.3.2 模型训练

采用 BPTT 算法对用于负荷预测的 LSTM 网络进行训练。训练目标是调整网络参数使网络输出尽可能接近真实值,训练过程如图 4 所示。

图 4 中,(2)和(3)为前向推理过程,(4)和(5)为反向传播过程。损失函数包括均方误差 (mean square error, MSE) 损失、均方根误差 (root mean square error, RMSE) 损失、平均绝对误差 (mean absolute error, MAE) 损失等。文中采用 MSE 作为损失函数,表

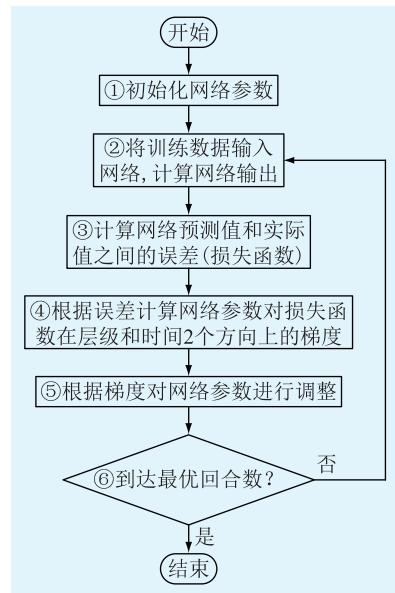


图 4 模型训练流程

Fig.4 Model training process

示为^[18]:

$$L_{a,b} = \frac{1}{N} \sum_{i=1}^N (\hat{L}_i - L_i)^2 \quad (13)$$

式中: N 为训练样本总数; \hat{L}_i 为预测负荷; L_i 为实际负荷; a, b 为模型参数。

2.3.3 模型评价

模型训练过程中,将所有数据输入网络并对其参数进行调整,称为一个回合。回合数过少导致网络欠拟合,回合数过多导致网络过度拟合。为了确定合适的回合数,选择最优的模型,需要在每个回合训练结束后对模型进行评价,过程如图 5 所示。

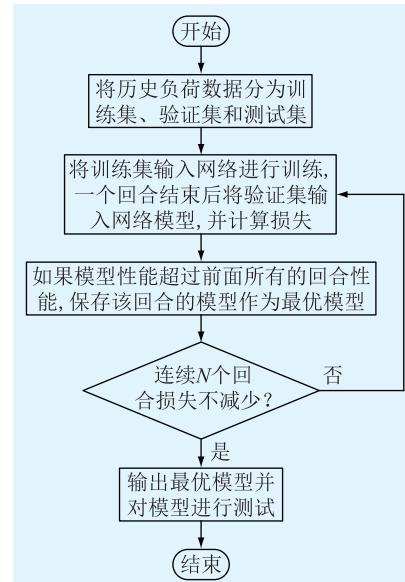


图 5 最优训练回合数确定流程

Fig.5 Determination process of optimal training epoch

3 算例分析

3.1 实验数据

采用美国德州可靠性委员会控制区域 2003 年—2018 年的每小时历史系统负荷数据对文中的模型进行验证^[23]。将 2003 年—2016 年的数据作为训练集,2017 年的数据作为验证集,2018 年的数据作为测试集。验证集用来验证最优训练回合数、最佳网络结构和参数。测试集用来测试模型预测效果。训练预测模型过程中考虑了天气(气温),日期类型(是否工作日,周几等),历史窗口期内同一时刻负荷,历史窗口期内每天的最大、最小负荷等因素,如表 1 所示。

表 1 实验所选取的负荷影响因素
Table 1 Power load influencing factors in the experiment

标识	负荷影响因素	说明
temperature	气温	℃
year	年	对应年份
month	月份	对应月份(1~12)
day_of_month	日/月	当月第几日
day_of_week	周几	当前周几(0~6)
hour	时刻	当前时刻(0~23)
is_business	是否工作日	(0 为否,1 为是)
day_of_year	第几天/年	当年第几天(1~365)
per_hour_load	历史窗口期内同一时刻的负荷	
per_max_load	历史窗口期内每天的最大、最小负荷	

3.2 评价指标

常用的负荷预测评价指标包括 RMSE、MAE、绝对百分比误差 (absolute percentage error, APE) 等。通常采用所有样本 APE 的平均值 (mean absolute percentage error, MAPE) e_{MAPE} 衡量负荷预测模型的整体性能。与其他方法进行比较时,采用 MAE、RMSE、APE 对算法性能进行分析,分别如式(14)—式(16)。

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |\hat{L}_i - L_i| \quad (14)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{L}_i - L_i)^2} \quad (15)$$

$$e_{\text{APE}} = \frac{|\hat{L}_i - L_i|}{L_i} \times 100\% \quad (16)$$

式中: N 为训练样本总数; \hat{L}_i 为预测负荷; L_i 为实际负荷。

3.3 网络结构

构建的 LSTM 网络,隐藏层数和每个隐藏层 LSTM 的数量对负荷预测精度均有影响。以 2017 年全年每小时历史负荷数据作为验证集,固定历史日期窗口 w 为 7 d,采用枚举法对隐藏层神经元数量进行逐层选取,确定最优网络结构。首先,确定第 1 层隐藏神经元的最佳数量并固定;然后,确定下一层隐藏层即第 2 层隐藏层神经元数量的最佳值;依次类推,直到预测精度不再提高为止。不同网络结构下的预测性能如表 2 所示。对每层神经元的数量进行选取时,依次设置为 5~40 个(间隔为 5 个),共 8 个级别。隐藏层的层数依次设置为 1,2,3 层。

表 2 不同 LSTM 网络结构的预测性能

Table 2 Forecasting performance of different LSTM network structures

隐藏单元数	1 层隐藏层		2 层隐藏层		3 层隐藏层	
	$e_{\text{MAPE}} / \%$	最优回合	$e_{\text{MAPE}} / \%$	最优回合	$e_{\text{MAPE}} / \%$	最优回合
5	4.60	500	4.75	172	4.59	180
10	4.72	38	4.99	57	4.58	65
15	4.74	53	4.77	38	4.74	48
20	4.94	40	4.72	42	4.65	55
25	4.79	30	4.71	35	5.14	20
30	4.99	24	5.11	20	4.65	52
35	4.80	35	4.83	16	5.00	20
40	4.80	16	4.75	16	4.87	39

由表 2 可知,隐藏层数为 1,每层神经元数量为 5 时, e_{MAPE} 取得最小值 4.6%;隐藏层数为 2,每层神经元数为 20 时, e_{MAPE} 取得最小值 4.72%;隐藏层为 3,每层神经元数为 10 时, e_{MAPE} 取得最小值 4.58%。因此, w 为 7 d 且隐藏层数目为 3,每层神经元的数目为 10 时,网络的预测性能较好。

3.4 历史日期窗口选择

设置网络层数分别为 1,2,3 层,隐藏单元数分别为 5,20,10。 w 取 1~60 d。同样采用 2017 年全年每小时历史负荷数据作为验证集。不同网络结构下 e_{MAPE} 随 w 的变化曲线见图 6。

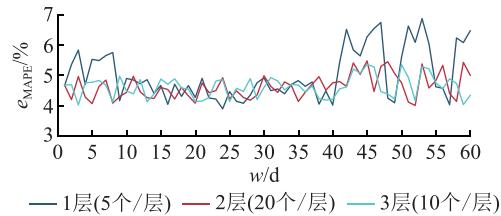


图 6 不同 LSTM 网络结构下 e_{MAPE} 随 w 的变化

Fig.6 The change of e_{MAPE} with w under different LSTM network structures

由图 6 可知,随着 w 增大,不同网络结构的 e_{MAPE} 相差不大,无明显下降或上升趋势,但 e_{MAPE} 的变化在 w 较大时不太稳定。特别是网络结构为 1 层,每层 5 个神经元时,较大的 w 使 e_{MAPE} 变化剧烈。3 种网络结构下, w 为 7~30 d 时,MAPE 都较低,且变化平稳。隐藏层为 1,每层神经元数为 5, w 为 23 d 时,预测性能最优, e_{MAPE} 仅为 3.9%。

3.5 结果分析

为了验证文中所提方法的性能,选择最优的预测模型(隐藏层为 1,每层神经元数为 5, w 为 23 d),采用 2018 年全年每小时负荷作为测试集对模型预测性能进行测试,并与 KNN、SVM 算法进行对比。2018 年 5 月的预测结果如图 7 所示。图 7(a)为实际负荷与每种方法预测负荷的对比;图 7(b)为每种预测方法每个时间点的 APE。由图 7 可知,与其他 2 种方法相比,LSTM 算法的 APE 较小且变化幅度不大,说明 LSTM 算法的预测性能和预测效果优于其他 2 种算法。

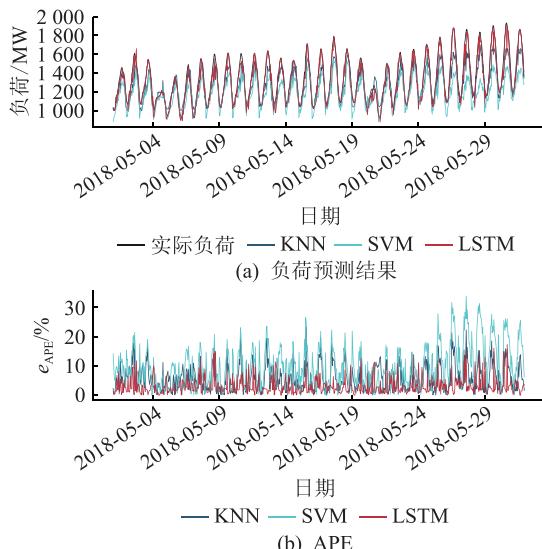


图 7 2018 年 5 月负荷预测结果及误差

Fig.7 Results and errors of load forecast on May 2018

为了进一步验证 LSTM 算法的性能,计算每种算法的 APE、MAE 和 RMSE。APE 箱形图见图 8。

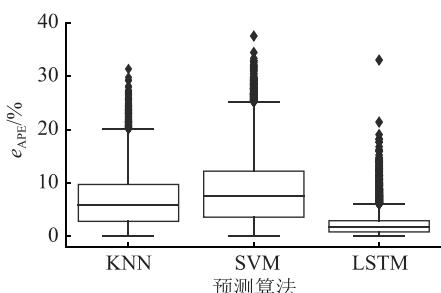


图 8 算法的 APE 分布

Fig.8 APE distribution of each algorithm

由图 8 可知,LSTM 算法与其他 2 种算法相比,APE 明显偏小(箱子偏下),且误差分布相对集中(箱子高度较小)。每种算法的 MAPE、MAE 和 RMSE 如表 3 所示。

表 3 不同算法预测性能对比

Table 3 Prediction performance comparison of different algorithms

算法	e_{MAPE} /%	e_{MAE} /MW	e_{RMSE} /MW
KNN	6.77	80.58	109.11
SVM	8.47	143.74	187.48
LSTM	2.14	41.22	59.29

由图 8 和表 3 可知,LSTM 算法的负荷预测效果较好,性能较稳定。

4 结语

文中采用 LSTM 构建负荷预测模型,利用 LSTM 能学习长距离时序依赖的优点,从横向(时间维度)辨识负荷本身的变化规律,从纵向(影响因素维度)识别天气、节假日等因素对负荷的非线性影响。采用实际的负荷数据对模型进行验证,比较了不同网络结构、不同历史时间窗口期对预测性能的影响,并与其他 2 种算法进行了比较。结果表明,所提方法提升了负荷预测准确性,且预测性能较稳定。

目前,深度神经网络无法进行负荷概率区间预测,且预测模型无法对预测结果进行解释。采用深度神经网络对负荷概率区间进行预测,并对预测结果进行解释是未来的研究方向之一。

参考文献:

- [1] 孔祥玉,郑峰,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.
KONG Xiangyu, ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems, 2018, 42(5): 133-139.
- [2] 戚任远. 上海用电负荷预测中气温累积效应分析[J]. 现代电力,2018,35(2):38-42.
QI Renyuan. Analysis on temperature accumulation effect in Shanghai power load forecast[J]. Modern Electric Power, 2018, 35(2): 38-42.
- [3] 龚钢军,安晓楠,陈志敏,等. 基于 SAE-ELM 的电动汽车充电站负荷预测模型[J]. 现代电力,2019,36(6):9-15.
GONG Gangjun, AN Xiaonan, CHEN Zhimin, et al. Model of load forecasting of electric vehicle charging station based on SAE-ELM[J]. Modern Electric Power, 2019, 36(6): 9-15.
- [4] 苏小林,张艳娟,武中,等. 规模化电动汽车充电负荷的预测及其对电网的影响[J]. 现代电力,2018,35(1):45-54.
SU Xiaolin, ZHANG Yanjuan, WU Zhong, et al. Forecasting the charging load of large-scale electric vehicle and its impact on the power grid[J]. Modern Electric Power, 2018, 35(1): 45-54.

- [5] 刘青,戚中译. 考虑空间运动特性的规模化电动汽车接入电网负荷预测模型[J]. 现代电力,2015,32(1):76-82.
LIU Qing, QI Zhongyi. The load forecast model for power grid with the accessing of large scale electric vehicles by considering spatial motion characteristics[J]. Modern Electric Power, 2015, 32(1):76-82.
- [6] 姚建刚,付强,叶伦,等. 考虑峰谷分时电价影响的变电站容量规划方法[J]. 电力系统自动化,2017,41(13):53-61.
YAO Jiangang, FU Qiang, YE Lun, et al. Substation capacity planning method considering influence of peak-valley time-of-use power price [J]. Automation of Electric Power Systems, 2017, 41(13):53-61.
- [7] LIU H, ZENG P, GUO J, et al. An optimization strategy of controlled electric vehicle charging considering demand side response and regional wind and photovoltaic[J]. Journal of Modern Power Systems and Clean Energy, 2015, 3(2):232-239.
- [8] 李博,门德月,严亚勤,等. 基于数值天气预报的母线负荷预测[J]. 电力系统自动化,2015,39(1):137-140.
LI Bo, MEN Deyue, YAN Yaqin, et al. Bus load forecasting based on numerical weather prediction[J]. Automation of Electric Power Systems, 2015, 39(1):137-140.
- [9] 郭建鹏,余颖铃,温步瀛. 基于EEMD-ARIMA模型的地区月负荷量预测[J]. 电力工程技术,2018,37(6):28-32,74.
GUO Jianpeng, SHE Yingling, WEN Buying. Regional monthly load forecast based on EEMD-ARIMA model [J]. Electric Power Engineering Technology, 2018, 37(6):28-32,74.
- [10] 林芳,林焱,吕宪龙,等. 基于均衡KNN算法的电力负荷短期并行预测[J]. 中国电力,2018,51(10):88-94,102.
LIN Fang, LIN Yan, LYU Xianlong, et al. Short-term parallel power load forecasting based on balanced KNN [J]. Electric Power, 2018, 51(10):88-94,102.
- [11] 石天,梅飞,陆继翔,等. 基于PSR和DBN的超短期母线净负荷预测[J]. 电力工程技术,2020,39(1):178-183.
SHI Tian, MEI Fei, LU Jixiang, et al. Ultra-short-term bus net load forecasting based on phase space reconstruction and deep belief network [J]. Electric Power Engineering Technology, 2020, 39(1):178-183.
- [12] 郭威麟,蒋晓艳,罗意,等. 基于EEMD-GABP的某地区短期负荷预测研究[J]. 电力工程技术,2019,38(6):93-98.
GUO Weilin, JIANG Xiaoyan, LUO Yi, et al. Short-term load forecasting in a certain area based on EEMD-GABP[J]. Electric Power Engineering Technology, 2019, 38(6):93-98.
- [13] 吴潇雨,和敬涵,张沛,等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测[J]. 电力系统自动化,2015,39(12):50-55.
WU Xiaoyu, HE Jinghan, ZHANG Pei, et al. Power system short-term load forecasting based on improved random forest with grey relation projection[J]. Automation of Electric Power Systems, 2015, 39(12):50-55.
- [14] 赵佩,代业明. 基于实时电价和加权灰色关联投影的SVM电力负荷预测[J]. 电网技术,2020,44(4):1325-1332.
ZHAO Pei, DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm[J]. Power System Technology, 2020, 44(4):1325-1332.
- [15] 史佳琪,张建华. 基于多模型融合Stacking集成学习方式的负荷预测方法[J]. 中国电机工程学报,2019,39(14):4032-4042.
SHI Jiaqi, ZHANG Jianhua. Load forecasting based on multi-model by stacking ensemble learning [J]. Proceedings of the CSEE, 2019, 39(14):4032-4042.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8):1735-1780.
- [17] MULDER W D, BETHARD S, MOENS M. A survey on the application of recurrent neural networks to statistical language modeling[J]. Computer Speech & Language, 2015, 30(1):61-98.
- [18] 王卉,王增平,刘席洋. 基于深度循环神经网络的换相失败边界检测[J]. 现代电力,2019,36(6):88-94.
WANG Hui, WANG Zengping, LIU Xiyang. Commutation failure boundary detection based on deep recurrent neural network [J]. Modern Electric Power, 2019, 36(6):88-94.
- [19] BENGIO Y, BOULANGER-LEWANDOWSKI N, PASCANU R, et al. Advances in optimizing recurrent networks [C]//IEEE International Conference on Acoustics. 2012:8624-8628.
- [20] YOSHUA B, PATRICE S, PAOLO F. Learning long-term dependencies with gradient descent is difficult[J]. IEEE Transactions on Neural Networks, 1994, 5(2):157-166.
- [21] LIPTON, ZACHARY C, BERKOWITZ, et al. A critical review of recurrent neural networks for sequence learning [EB/OL]. [2020-06-20]. <https://arxiv.org/abs/1506.00019>.
- [22] GIBSONA, PATTERSON J. Deep learning:a practitioner's approach[M]. Boston: O'Reilly Media, 2017.
- [23] Hourly load data archives [EB/OL]. [2020-06-20]. http://www.ercot.com/gridinfo/load/load_hist/.
- [24] 苏运,卜凡鹏,郭乃网,等. 基于低秩表示的多任务短期电力负荷预测的研究[J]. 现代电力,2019,36(3):58-65.
SU Yun, BU Fanpeng, GUO Naiwang, et al. Research on short-term load forecast using multi-task with low-rank representation [J]. Modern Electric Power, 2019, 36(3):58-65.

作者简介:



庞传军

庞传军(1984),男,硕士,高级工程师,从事电力系统及自动化、人工智能技术在电力系统中的应用相关工作(E-mail:pangchuanjun@sgepri.sgcc.com.cn);

张波(1978),男,硕士,高级工程师,从事电力系统及自动化相关工作;

余建明(1979),男,博士,高级工程师,从事电力系统高级应用软件研发工作。

(下转第194页)

Open-switch fault diagnosis of converters of doubly-fed induction generator-based wind turbine using deep belief networks

XIAOHOU Kaishun¹, LI Bo²

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China ;

2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China)

Abstract: The stator of doubly-fed induction generator-based wind turbine (DFIG-WT) is directly connected to the power grid, and the rotor of DFIG-WT system exchanges power with main grid via a back-to-back converter. The power electronic switches of back-to-back converter are prone to open-switch fault, which affects the stable operation of the system. A deep belief network (DBN) based fault diagnosis method for the open-switch faults of converters of DFIG-WT system is present in this paper. Firstly, the output response of DFIG-WT system with single and double switch faults of rotor-side converter (RSC) and grid-side converter (GSC) is analyzed. Based on the open-switch fault data of DFIG-WT, multilayer restricted Boltzmann machines (RBMs) are constructed to extract the deep information of rotor currents and grid currents under various fault and operation conditions, which fully takes advantage of excellent pattern recognition ability of DBN to improve the fault diagnosis accuracy. The simulation results indicate that the proposed DBN based fault diagnosis method is able to precisely detect the single and double open-switch faults of DFIG-WT system.

Keywords: doubly-fed induction generator-based wind turbine; rotor-side converter; grid-side converter; fault diagnosis; deep belief network

(编辑 方晶)

(上接第 180 页)

Short-term power load forecasting based on LSTM recurrent neural network

PANG Chuanjun^{1,2}, ZHANG Bo^{1,2}, YU Jianming^{1,2}

(1. NARI Group (State Grid Electric Power Research Institute) Co., Ltd., Nanjing 211106, China;

2. Beijing Kedong Power Control System Co., Ltd., Beijing 100192, China)

Abstract: In order to ensure the safety and stability of the power grid and the efficient operation of the power market, grid dispatchers and power market participants have put forward higher requirements for the accuracy of power load forecasting. However, the distributed power and intermittent loads increase the difficulty of predicting loads accurately. In order to solve the problem that the current load forecasting method cannot simultaneously model the change law of the load itself and its influencing factors, load forecasting method based on long short-term memory (LSTM) is proposed. LSTM is used to construct recurrent neural network (RNN), and comprehensively historical load and various load influence factors are considered to establish load forecasting model. The method utilizes the feature extraction ability of the neural network and the memory ability of the LSTM to identify the internal variation law of the load and the nonlinear influence of various influencing factors on the load in a longer historical time range. The actual load datas are used to verify the prediction performance of different historical time windows and different network architectures. Meanwhile, compare with other load prediction algorithms. Experimental results show that the model can improve the accuracy of load forecasting.

Keywords: power system; load forecasting; long short-term memory (LSTM); recurrent neural network (RNN); machine learning

(编辑 吴楠)