

DOI:10.12158/j.2096-3203.2020.06.015

基于双向长短时记忆网络的母线负荷分解方法

钱甜甜¹, 王珂¹, 徐立中², 石飞¹

(1. 中国电力科学研究院有限公司南京分院, 江苏 南京 210003;

2. 国网浙江省电力有限公司, 浙江 杭州 310007)

摘要:目前在负荷分解领域的研究多以家庭住宅的总负荷分解为电器级别的负荷为主,对于中高电压等级的母线负荷分解研究较少,为解决这一问题,提出基于双向长短时记忆网络(Bi-LSTM)的中高电压等级母线负荷分解算法。首先在长短时记忆(LSTM)的基础上构建了Bi-LSTM;其次以母线负荷和其对应的外部信息源(如日期类型、天气等)作为Bi-LSTM的输入量,母线负荷的各下属建筑负荷作为输出量,对Bi-LSTM进行训练;最后以网络分解的母线负荷构成值与实际值间的平均相对误差作为评价指标。实验结果表明该方法可有效对构成成分未知的母线负荷进行分解。

关键词:母线负荷;负荷分解;人工智能;深度学习;双向长短时记忆网络

中图分类号:TM769

文献标志码:A

文章编号:2096-3203(2020)06-0104-06

0 引言

电网的中高电压等级母线通常汇聚了大量不同种类、特性迥异的负荷资源,如何有效预测这些母线负荷的功率变化以及如何利用这些母线上汇聚的柔性负荷是电网调度人员关心的重点^[1-5]。

分解母线负荷得到其构成是开展上述研究的基础和关键,但国内外还鲜有对于中高电压等级母线负荷构成分解的研究。目前国内外学者在低电压等级的居民家庭负荷构成分解方面已经开展了大量相关研究^[6-12],数学优化和模式识别是该问题的两大类求解方法。在数学优化方面,文献[13]提出一种基于改进鸡群算法的家电负荷分解方法;文献[14]提出一种基于粒子群算法搜索的负荷分解方法;文献[15-16]提出一种基于遗传优化的非侵入式负荷分解方法。近年来,随着负荷种类的增多,数学优化方法的求解效率面临挑战。在模式识别方面,近年来人工神经网络逐渐被用于负荷分解,且取得了不错的效果。文献[17]提出一种基于循环神经网络(recurrent neural network, RNN)模型的负荷辨识方法,能够有效地实现用户内部负荷设备状态的辨识要求;文献[18]提出一种基于长短时记忆(long short-term memory, LSTM)的负荷辨识方法;文献[19]提出一种基于深度序列翻译模型的非侵入式负荷分解算法;文献[20]使用自编码器对非侵入式功率进行分解;文献[21]基于深度学习的框架提出一种基于序列到序列和注意力机制的负荷

分解模型。

但低电压等级负荷的非侵入式分解算法并不适用于直接解决中高电压等级的母线负荷分解问题,原因如下:(1)中高电压等级的母线负荷汇聚了海量的用电设备,该数量远大于单户居民家庭的用电设备数量,将中高电压等级的母线负荷分解为以电器负荷为单元的负荷,其分解误差很大,且对于电网调度部门来说,该负荷分解方式没有太大意义;(2)低压负荷分解算法中需要用到电力负荷瞬时总功率的变化、瞬时电流的变化等,在中高电压等级的母线处,由于电压、电流、功率的基数很大,负荷特性较为平稳,鲜少有瞬时较为明显的跃变。因此,亟需研究一种中高电压等级母线负荷分解方法来解决母线负荷的构成分解问题。

综上,文中针对中高电压等级母线负荷的构成分解问题,利用人工智能善于处理非线性、交互影响的复杂数据关系的优势,提出一种基于双向长短时记忆网络(bi-directional long short-term memory, Bi-LSTM)的母线负荷构成分解算法,实验结果表明所提方法可以有效分解出中高电压等级母线的构成负荷。

1 母线负荷构成分解方法

1.1 Bi-LSTM 模型

LSTM是一种特殊的循环神经网络模型,能较好地克服目前较为常用的RNN由于序列较长所带来的梯度弥散问题,能够学习长期依赖关系。文中在LSTM的基础上构建了一种Bi-LSTM模型,网络结构如图1所示,将每一个训练序列的正向和反向

收稿日期:2020-06-05;修回日期:2020-07-17

基金项目:国家电网有限公司科技项目(52110418002A)

分别作为 2 个 LSTM, 2 个 LSTM 相互独立并连接同一个输出层, 相对单向 LSTM 来说, Bi-LSTM 理论上能够捕获更多特征信息。在前向层从 1 时刻到 t 时刻正向计算一遍, 得到并保存每个时刻向前隐含层的输出; 在反向层沿着时刻 t 到时刻 1 反向计算一遍, 得到并保存每个时刻向后隐含层的输出。最后, 在每个时刻结合正向层和反向层相应时刻输出的结果得到最终的输出, 表达式如下:

$$H_t = f(W_1 X_t + W_2 H_{t-1}) \quad (1)$$

$$H'_t = f(W_3 X_t + W_5 H'_{t+1}) \quad (2)$$

$$O_t = g(W_4 H_t + W_6 H'_t) \quad (3)$$

式中: X_t 为 t 时刻的输入量; H_t , H_{t-1} 分别为 $t, t-1$ 时刻正向层的输出量; $f(\cdot)$ 为隐层神经元激活函数; H'_t , H'_{t+1} 分别为 $t, t+1$ 时刻反向层的输出量; $g(\cdot)$ 为输出层神经元激活函数; W_1 为正向计算时输入层至隐层的权重矩阵; W_2 为反向计算时输入层至隐层的权重矩阵; W_3 为正向计算时上一时刻至下一时刻隐层的权重矩阵; W_4 为反向计算时下一时刻至上一时刻隐层的权重矩阵; W_5 为反向计算时隐层到输出层的权重矩阵; W_6 为正向计算时隐层到输出层的权重矩阵。




图 1 Bi-LSTM 的网络结构

Fig.1 The network structure of Bi-LSTM

1.2 基于 Bi-LSTM 的母线负荷分解算法

母线负荷分解的问题可描述如下。

目标任务: 给定母线负荷时序序列 $X = \{x_1, x_2, \dots, x_T\}$, x_t 为母线负荷在时刻 $t = \{1, 2, \dots, T\}$ 时的值, 由 N 种不同类型的负荷 (如公寓建筑群负荷、商场建筑群负荷、学校建筑群负荷等) 复合而成。负荷分解的目标是识别出负荷 $i \in \{1, 2, \dots, N\}$ 时的下属构成负荷时序序列 $Y_i = \{y_{1,i}, y_{2,i}, \dots, y_{T,i}\}$, 使得其在时刻 t 的负荷值 $y_{t,i}$ 满足:

$$x_t = \sum_{i=1}^N y_{t,i} + \sigma(t) \quad (4)$$

式中: $\sigma(t)$ 为其他未考虑的负荷类型以及噪声的影响。

学习任务: 给定训练集 $\{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)\}$ 以及验证集 $\{(X_{n+1}, Y_{n+1}), \dots, (X_{n+m}, Y_{n+m})\}$, 其中 (X_k, Y_k) 为第 $k = \{1, 2, \dots, n\}$ 个训练样本,

X_k 为母线负荷时序序列, $Y_k = \{Y_k^1, Y_k^2, \dots, Y_k^N\}$ 为 N 种分解负荷对应的负荷变化序列。基于训练集可训练得到学习模型 M , 使用 M 可预测测试集上每一个 $X_j (j = \{n+1, n+2, \dots, n+m\})$ 对应的每一类分解负荷变化序列 $Y_j = \{Y_{j,1}, Y_{j,2}, \dots, Y_{j,N}\}$ 。

文中所提母线负荷分解方法的具体研究流程如图 2 所示。

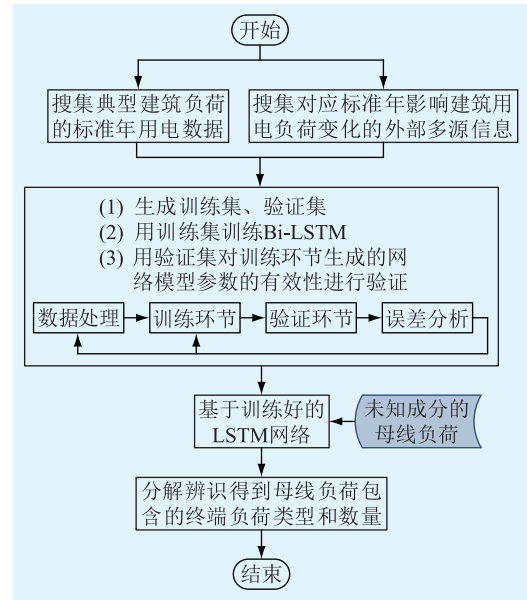


图 2 基于 Bi-LSTM 的中高电压等级
母线负荷构成分解方法流程

Fig.2 The flow chart of bus load identification and decomposition analysis method based on Bi-LSTM

步骤一: 搜集典型建筑负荷的标准年用电数据, 包括工业用途的建筑负荷 (如钢厂、水泥厂、电子厂的生产负荷等)、商业用途的建筑负荷 (如写字楼、宾馆、商场的用电负荷等) 和居住用途的建筑负荷 (居民小区、公寓住宅的用电负荷等), 形成典型建筑用电负荷特征数据库。

步骤二: 搜集对应标准年影响建筑用电负荷变化的外部信息, 如外部气象 (如温度、湿度、风向、风速和太阳辐射热等)、日期类型 (节假日、工作日、非工作日) 等, 结合典型建筑负荷特征库, 形成用于该区域母线负荷分解的外部信息源数据库。

步骤三: 确定训练、验证网络模型参数用的训练集和验证集。训练集、验证集是指构成成分已知的母线负荷及其分解负荷时间序列集合。训练集用来训练 Bi-LSTM 的网络模型参数, 验证集用来验证训练好的网络模型参数的有效性, 即验证母线负荷分解的准确度。

步骤四: 基于训练好的 Bi-LSTM 对构成成分未知的母线负荷进行分解。

其中,步骤三使用 Bi-LSTM 对形成的样本数据进行训练和验证,又分为如下步骤:

(1) 数据处理环节,对用于母线负荷构成分解的多信息源数据进行数据处理,包括归一化、滤波和差分处理,如式(5)一式(7)所示;

(2) 训练环节,用已知母线负荷构成的样本集对 Bi-LSTM 进行训练,训练生成相应的神经网络模型参数;

(3) 验证环节,用验证集数据验证训练环节生成的网络模型参数的有效性;

(4) 误差分析和计算,分析网络模型的分解误差,以其作为参考,调整 Bi-LSTM 的神经网络层数、隐含层节点数、时间步长等参数。

其中,对于输入量时序序列数据的处理方法如下:

(1) 归一化。文中采用 Min-max 进行归一化处理。Min-max 标准化也称离差标准化,是对原始数据进行线性变化,使得结果映射到[0,1]之间。

$$x^* = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (5)$$

式中: x_{\max} 为样本数据最大值; x_{\min} 为样本数据的最小值。

(2) 滤波处理。使用均匀量化对输入时序序列数据进行处理,即把输入信号的取值域平均间隔分割,可消除瞬时的尖峰值。

$$y_Q(t) = \delta \cdot \left\lfloor \frac{y_P(t)}{\delta} + \frac{1}{2} \right\rfloor \quad (6)$$

式中: $y_Q(t)$ 为量化处理后的时间序列; δ 为量化参数; $y_P(t)$ 为总功率时间序列。

(3) 差分处理。将滤波后相邻时间点的总功率值相减,从而求得总功率的差分波形。

$$\Delta(t) = y_P(t) - y_P(t - 1) \quad (7)$$

2 母线负荷构成分解方法验证

实验采用的机器硬件配置为 intel (R) Core (TM) i7-6700 CPU @ 3.4GHz 处理器和 ST1000DM 003-1SB102 SCSI Disk Device 磁盘驱动器,采用的程序编译软件为 python3.5,人工智能算法框架为基于谷歌研发的第二代人工智能学习系统 Tensorflow。

由于目前还未能从实际电网中获取母线负荷及其下属构成负荷的量测数据,因此文中实验数据来源为基于 EnergyPlus 软件生成 5 种典型建筑负荷 1 a 的负荷曲线,采样频率为每 15 min 一个点,并通过乘以不同的系数模拟合成 30 000 组不同的母线负荷。所用到的外部信息源数据为日期类型(工作日或节假日)和温度。网络模型的输入量为日期类

型、温度、总的母线负荷量和母线负荷差分量;标量为各建筑负荷用电量;输出量为母线负荷的分解量。为了对分解效果做出定量评价,使用平均相对误差(mean relative error, MRE) 作为评价指标来评估分解值和目标值在各时刻的误差,其表达式为:

$$\gamma_{\text{MRE}} = \frac{1}{T} \sum_{t=1}^T \frac{|\hat{p}_t - p_t|}{p_t} \quad (8)$$

式中: p_t 为 t 时刻该母线负荷下某建筑负荷的真实功率; \hat{p}_t 为 t 时刻分解出的该母线负荷下属某建筑负荷功率; T 为设定的一段时间。

不同超参数设置、不同情形(不同负荷构成占比)母线负荷分解结果如表 1、表 2 所示。情形一中负荷构成占比为宾馆 4%,超市 17%,办公楼 61%,学校 1%,仓库 17%;情形二中负荷构成占比为宾馆 30%,超市 10%,办公楼 30%,学校 25%,仓库 5%。

表 1 情形一不同超参数设置下的母线负荷分解结果
(分解值与目标值的平均相对误差)

Table 1 The bus load decomposition results under different hyperparameter settings in case 1 (the average relative error between the decomposition value and the target value) %

超参数设置	各构成负荷平均相对误差				
	宾馆 (4%)	超市 (17%)	办公楼 (61%)	学校 (1%)	仓库 (17%)
超参数一	79.0	87.0	85.2	78.8	88.9
超参数二	87.6	88.4	86.9	85.1	89.2
超参数三	89.5	90.4	92.3	88.6	90.5
超参数四	90.3	91.6	94.1	89.7	91.3
超参数五	82.2	83.5	84.6	77.3	83.7
超参数六	83.4	84.8	85.0	78.4	84.1

表 2 情形二不同超参数设置下的母线负荷分解结果
(分解值与目标值的平均相对误差)

Table 2 The bus load decomposition results under different hyperparameter settings in case 2 (the average relative error between the decomposition value and the target value) %

超参数设置	各构成负荷平均相对误差				
	宾馆 (30%)	超市 (10%)	办公楼 (30%)	学校 (25%)	仓库 (5%)
超参数一	81.3	80.1	82.4	81.4	78.0
超参数二	82.6	81.4	85.3	82.3	79.2
超参数三	90.4	89.4	91.3	90.6	89.5
超参数四	91.3	90.0	93.2	91.2	90.1
超参数五	80.7	79.7	81.6	80.3	77.7
超参数六	80.4	80.0	82.1	81.4	79.1

各关键超参数设置如表 3 所示,超参数设置是指网络训练过程中的一些关键网络模型配置参数(如时间步长、隐藏层节点数、滑动步长等)的设置,

需注意其与网络模型参数(即权重)不同。可以观察得出:这些网络模型超参数的设置对分解结果的精度有较大影响,在训练过程中,需要经过多次试验调整参数设置,才能得到较优的分解结果。

表 3 Bi-LSTM 网络模型的关键超参数设置
Table 3 Important network model hyperparameter settings of Bi-LSTM

超参数设置	时间步长	隐藏层神经元数 (正向,反向)	输入层 维度	滑动 步长
超参数一	96	10	4	10
超参数二	96	16	4	96
超参数三	120	10	4	10
超参数四	120	16	4	120
超参数五	672	10	4	10
超参数六	672	16	4	672

以表 1 中超参数设置四下的结果为例展示母线负荷分解值与目标值的对比结果,截取的时间长度为一周,如图 3 所示。





图 3 母线负荷分解结果(分解值与目标值的对比)

Fig.3 The result of bus load decomposition identification (comparison of decomposition value and target value)

在不同方法下的母线负荷分解结果的平均相对误差如表 4 所示,可以看出,Bi-LSTM 方法下的母线负荷分解平均相对误差最小,LSTM 次之,RNN 最大。

表 4 不同方法下的母线负荷
分解评价指标对比

Table 4 Comparison of bus load decomposition evaluation indicators under different algorithms %

方法	各构成负荷平均相对误差				
	宾馆 (4%)	超市 (17%)	办公楼 (61%)	学校 (1%)	仓库 (17%)
RNN	85.4	86.2	89.3	83.5	88.1
LSTM	89.0	90.8	93.6	88.2	90.4
Bi-LSTM	90.3	91.6	94.1	89.7	91.3

由上述实验可以分析得出,文中所提母线负荷分解方法是可行的,能够较为准确地将构成成分未知的母线负荷分解为以建筑负荷为单位的负荷,且分解误差控制在一定范围内。

3 结语

现有负荷分解方法多针对小规模家庭用户,研究方法难以应用于大规模、多样化的中高电压等级母线负荷侧资源分解问题。文中提出的基于 Bi-LSTM 的母线负荷分解方法能够有效将中高电压等级母线负荷分解为以建筑负荷为单元的负荷,可以为后续的母线负荷预测和需求响应管理等提供有力分析依据。下一步研究工作会基于实际的母线负荷及其下属构成负荷数据,继续完善母线负荷构成成分辨识工作。

参考文献:

- [1] 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.

- [2] 朱泽磊,程鑫,杨桂钟,等. 基于母线负荷预测改进的省地协同发电计划优化方法[J]. 中国电机工程学报,2017,37(3):665-675.
ZHU Zelei, CHENG Xin, YANG Guizhong, et al. Collaborative scheduling optimization method for provincial grid and regional grid based on refined busload forecast[J]. Proceedings of the CSEE, 2017, 37(3):665-675.
- [3] 程林,万宇翔,张放,等. 基于负荷聚合商业业务的空调服务运作模式及控制策略[J]. 电力系统自动化,2018,42(18):8-18.
CHENG Lin, WAN Yuxiang, ZHANG Fang, et al. Operation mode and control strategy for air-conditioning service based on business of load aggregator[J]. Automation of Electric Power Systems, 2018, 42(18):8-18.
- [4] 骆柏锋,穆云飞,贾宏杰,等. 基于负荷特征库的大用户供电接入决策方法[J]. 电力系统自动化,2018,42(6):66-72.
LUO Bofeng, MU Yunfei, JIA Hongjie, et al. Decision method of power supply access for large consumers based on load feature library[J]. Automation of Electric Power Systems, 2018, 42(6):66-72.
- [5] XIAO F, FAN C. Data mining in building automation system for improving building operational performance[J]. Energy and Buildings, 2014, 75:109-118.
- [6] ZHOU L, PENG Z W, DENG C R, et al. A generalized synthesis load model considering network parameters and all-vanadium redox flow battery[J]. Protection and Control of Modern Power Systems, 2018, 3(1):32.
- [7] 黎鹏,余贻鑫. 非侵入式电力负荷在线分解[J]. 天津大学学报, 2009, 42(4):303-308.
LI Peng, YU Yixin. Nonintrusive method for on-line power load decomposition[J]. Journal of Tianjin University, 2009, 42(4):303-308.
- [8] 肖江,荆朝霞. 基于贝叶斯信息准则的非侵入式负荷事件检测算法[J]. 电力系统保护与控制,2018,46(22):8-14.
XIAO Jiang, JING Zhaoxia. Non-intrusive load event detection algorithm based on Bayesian information criterion[J]. Power System Protection and Control, 2018, 46(22):8-14.
- [9] LIN Y, TSAI M. Development of an improved time-frequency analysis-based nonintrusive load monitor for load demand identification[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(6):1470-1483.
- [10] 宋旭帆,周明,涂京,等. 基于k-NN结合核Fisher判别的非侵入式负荷监测方法[J]. 电力系统自动化,2018,42(6):73-80.
SONG Xufan, ZHOU Ming, TU Jing, et al. Non-intrusive load monitoring method based on k-NN and kernel Fisher discriminant[J]. Automation of Electric Power Systems, 2018, 42(6):73-80.
- [11] HASSAN T, JAVED F, ARSHAD N. An empirical investigation of VI trajectory based load signatures for non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2014, 5(2):870-878.
- [12] DONG M, MEIRA P C, XU W, et al. Non-intrusive signature extraction for major residential loads[J]. IEEE Transactions on Smart Grid, 2013, 4(3):1421-1430.
- [13] 许仪勋,李旺,李东东,等. 基于改进鸡群算法的非侵入式家电负荷分解[J]. 电力系统保护与控制,2016,44(13):27-32.
XU Yixun, LI Wang, LI Dongdong, et al. Disaggregation for non-invasive domestic appliances based on the improved chicken swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(13):27-32.
- [14] 李如意,黄明山,周东国,等. 基于粒子群算法搜索的非侵入式电力负荷分解方法[J]. 电力系统保护与控制,2016,44(8):30-36.
LI Ruyi, HUANG Mingshan, ZHOU Dongguo, et al. Optimized nonintrusive load disaggregation method using particle swarm optimization algorithm[J]. Power System Protection and Control, 2016, 44(8):30-36.
- [15] 孙毅,崔灿,陆俊,等. 基于遗传优化的非侵入式家居负荷分解方法[J]. 电网技术,2016,40(12):3912-3917.
SUN Yi, CUI Can, LU Jun, et al. A non-intrusive household load monitoring method based on genetic optimization[J]. Power System Technology, 2016, 40(12):3912-3917.
- [16] 徐青山,娄藕蝶,郑爱霞,等. 基于近邻传播聚类和遗传优化的非侵入式负荷分解方法[J]. 电工技术学报,2018,33(16):3868-3878.
XU Qingshan, LOU Oudie, ZHENG Aixia, et al. A non-intrusive load decomposition method based on affinity propagation and genetic algorithm optimization[J]. Transactions of China Electrotechnical Society, 2018, 33(16):3868-3878.
- [17] 刘恒勇,史帅彬,徐旭辉,等. 一种关联RNN模型的非侵入式负荷辨识方法[J]. 电力系统保护与控制,2019,47(13):162-170.
LIU Hengyong, SHI Shuaibin, XU Xuhui, et al. A non-intrusive load identification method based on RNN model[J]. Power System Protection and Control, 2019, 47(13):162-170.
- [18] 刘恒勇,刘永礼,邓世聪,等. 一种基于LSTM模型的电力负荷辨识方法[J]. 电测与仪表,2019,56(23):62-69.
LIU Hengyong, LIU Yongli, DENG Shicong, et al. A power load identification method based on LSTM model[J]. Electrical Measurement & Instrumentation, 2019, 56(23):62-69.
- [19] 任文龙,许刚. 基于深度序列翻译模型的非侵入式负荷分解方法[J]. 电网技术,2020,44(1):27-37.
REN Wenlong, XU Gang. Non-intrusive load decomposition method based on deep sequence translation model[J]. Power System Technology, 2020, 44(1):27-37.
- [20] BONFIGLI R, FELICETTI A, PRINCIPI E, et al. Denoising autoencoders for non-intrusive load monitoring: improvements and comparative evaluation[J]. Energy and Buildings, 2018, 158:1461-1474.
- [21] 王轲,钟海旺,余南鹏,等. 基于seq2seq和Attention机制的居民用户非侵入式负荷分解[J]. 中国电机工程学报, 2019, 39(1):75-83, 322.

- WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive load monitoring based on sequence-to-sequence model with Attention mechanism [J]. Proceedings of the CSEE, 2019, 39(1):75-83,322.
- [22] SCHMIDHUBER J. Deep learning in neural networks: an overview [J]. Neural Networks, 2015, 61:85-117.
- [23] KONG W, DONG Z Y, JIA Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network [J]. IEEE Transactions on Smart Grid, 2017, 10(1):841-851.
- [24] 陶玉波, 陈昊, 秦晓辉, 等. 短期风电功率预测概念和模型与方法 [J]. 电力工程技术, 2018, 37(5):7-13.
- TAO Yubo, CHEN Hao, QIN Xiaohui, et al. A review of the short-term wind power forecasting theory, model and approach

[J]. Electric Power Engineering Technology, 2018, 37(5):7-13.

作者简介:



钱甜甜

钱甜甜(1990),女,博士,高级工程师,从事电网智能调度与控制、电力负荷建模、能源管理与能源经济相关工作(E-mail:qiantiantian@epri.sgcc.com.cn);

王珂(1980),女,博士,研究员级高级工程师,从事需求响应、调度优化、电力系统仿真相关工作;

徐立中(1983),男,博士,高级工程师,从事调度运行工作和节能经济调度研究等。

The bus load decomposition method based on bi-directional long short-term memory model

QIAN Tiantian¹, WANG Ke¹, XU Lizhong², SHI Fei¹

(1. China Electric Power Research Institute (Nanjing), Nanjing 210003, China;

2. State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310007, China)

Abstract: The current research work is mainly based on the decomposition of the total load of the family house into the electrical level load, and less research on the bus load of the high voltage level. To solve this problem, a bus load composition decomposition algorithm based on bi-directional long short-term memory (Bi-LSTM) is proposed. Firstly, Bi-LSTM is constructed on the basis of LSTM. Secondly, bus load and its corresponding external information sources (such as date type, weather, et al) are used as input of Bi-LSTM after training. Finally, taking the mean relative error between the predicted value and the target value of the building power load decomposed by the network as the evaluation index. The experimental results show that the method can effectively identify the bus load with unknown components. Compared with the traditional recurrent neural network and long-term and short-term memory network, the proposed algorithm has better identification ability.

Keywords: bus load; load decomposition; artificial intelligence; deep learning; bi-directional long short-term memory (Bi-LSTM)

(编辑 钱悦)