

基于长短期记忆的图像化短期电力负荷预测方法

杨书强¹, 王涛¹, 檀晓林¹, 黄凯¹, 刘梅^{2*}

(1. 国网河北省电力有限公司经济技术研究院, 河北省 石家庄市 050022;

2. 北京清软创新科技股份有限公司, 北京市 昌平区 100085)

Image Based Short-term Power Load Forecasting Method Using Long Short-term Memory

YANG Shuqiang¹, WANG Tao¹, TAN Xiaolin¹, HUANG Kai¹, LIU Mei^{2*}

(1. Economic and Technological Research Institute of State Grid Hebei Electric Power Co., Ltd., Shijiazhuang 050022,

Hebei Province, China;

2. Beijing Tsingsoft Co., Ltd., Changping District, Beijing 100085, China)

Abstract: Under the “double carbon” goal, China’s power system will present the characteristics of “double height” and the balance of supply and demand in power system will face new challenges. A more accurate power load forecasting method is urgently needed. Therefore, a method to visualize the load data is presented and the long short-term memory (LSTM) artificial neural network is used for short-term power load forecasting. Firstly, the graphical load data expression method is introduced, including the transformation of time series load curve into an RGB format picture and its inverse process. Secondly, the graphical time series load data is used as the input of LSTM for forecasting. Finally, the predicted picture is transformed into time series curve to obtain the final short-term load forecasting results. This method not only enriches the expression of load data, but also highlights the advantages of LSTM method in image analysis and processing. The experimental results show that this method improves the accuracy of short-term load forecasting to a certain extent and meets the needs of practical engineering.

Keywords: short-term load forecasting; time series load curve; image conversion; RGB format; long short-term memory

摘 要: “双碳”目标下, 中国电力系统将呈现“双高”特点, 供需平衡面临新的挑战, 亟需更加精确的电力负荷预测方法。为此, 提出了一种将负荷数据图像化, 并应用长短期

记忆(long short-term memory, LSTM)人工神经网络进行短期电力负荷预测的方法。首先, 研究图像化的负荷数据表达方法, 包括时序负荷曲线转换为RGB(红绿蓝三原色)格式图片及其逆过程。其次, 将图像化的时序负荷数据作为LSTM的输入进行预测。最后, 将预测图片进行时序曲线转化得到最终的短期负荷预测结果。此方法在丰富了负荷数据表达方式的同时, 还凸显了LSTM方法在图像分析和处理上的优势。实验结果表明, 该方法在一定程度上提高了短期负荷预测的精度, 满足实际工程需求。

关键词: 短期负荷预测; 时序负荷曲线; 图像转化; RGB格式; 长短期记忆

0 引言

2020年, 习近平主席在第75届联合国大会上提出了“双碳”目标, 即中国的二氧化碳排放力争于2030年前达到峰值, 努力争取2060年前实现碳中和^[1]。实现此目标的过程中将出现新能源大规模并网以及电动汽车、分布式电源等交互式设备的大量接入。届时, 电力系统将呈现“双高”特点(即高比例新能源、高比例电力电子设备), 在供需平衡、系统调节等方面将面临新的挑战。电力负荷预测是电力供需形势分析的基础, 是保障电力供应的有效手段。

短期负荷预测是负荷预测的重要组成部分, 主要预测未来某日内各个时刻点(例如日内15 min一个点, 共96点)的负荷值。准确的短期负荷预测结果对于调度部门进行未来日的机组最优组合经济调度十分重要, 对于电力市场运营同样具有重要意义。短期负

基金项目: 国网河北省电力有限公司科技项目(新常态经营形势下电力市场分析预测方法研究, 5204JY200001)。

Science and Technology Foundation of State Grid Hebei Electric Power Co., Ltd. (Research on Power Market Analysis and Prediction Method Under the New Normal Operation Situation, 5204JY200001).

荷预测的最大特点是其在年、月、星期、日等不同时间维度上都具有明显的周期性, 具体包括: 重大节假日的负荷曲线在不同年度之间具有一定的相似性; 同一星期类型日 (例如星期一) 的负荷曲线在不同星期之间具有一定的相似性; 不同日负荷曲线的变化规律 (即曲线走势) 相似, 但工作日和休息日的负荷曲线变化趋势有所区别。从短期负荷特点来看, 考虑周期性的同类型日预测方法、考虑周期性的时间序列预测方法以及神经网络预测方法等均具有较好的预测效果。从预测原理来看, 电力负荷预测一般基于可知性、可能性、可控性和系统性原理^[2]。常用的预测方法可以分为三类: 第一, 基于经典的数学统计模型的预测方法, 比如时间序列分析、回归分析、灰色系统理论等^[3-4]; 第二, 基于机器学习理论体系的预测方法, 比如人工神经网络、支撑向量机、专家系统、深度学习等^[5-9]; 第三, 混合方法, 可以进一步分为两类, 一是使用多种方法分别进行负荷预测, 再综合形成最终的预测结果^[10], 二是先对负荷进行分解, 对各分量分别预测后再加和得到最终预测结果^[11-14]。以上负荷预测技术大多将时序曲线作为输入并依赖数理统计方法和先验知识构建数学模型, 未深入挖掘负荷曲线所包含的信息, 预测模型的自适应和自学习能力还有提升空间。

图像处理、自然语言处理、语音识别等领域更易于人们的直觉理解和判断, 具有自适应和自学习能力的人工智能技术被成功应用于这些领域之后, 逐步被应用于电力等其他领域^[15]。当前, 随着深度学习技术的发展, 越来越多的新兴深度学习技术在图像处理等领域表现突出。一些深度学习模型, 如生成对抗网络和卷积神经网络, 输入多为图像矩阵, 时序负荷数据无法直接作为其输入。而将负荷数据转化为图像之后, 就可以很容易地将与图像处理相关的深度学习模型应用于负荷数据的分析和数据挖掘。使用图像化负荷有助于数据信息的自动化分析和新兴深度学习模型的快速构建。

当前, 已有研究将负荷数据转换为图像格式作为深度学习模型的输入, 用于负荷数据的处理与分析。文献[16]基于生成对抗网络和双重语义感知实现了配电网量测数据中缺失功率数据这类异常数据的重构, 在重建建模过程中, 将96点负荷数据转换为 10×10 的灰度矩阵, 并用作生成对抗网络模型的输入。文献[17]将基于24 d、24点/d采样家庭用电负荷数据构建的 24×24 灰度矩阵作为卷积神经网络模型的输入, 实现

对家庭的24点/d用电负荷曲线的聚类分析, 根据用电数据识别家庭生活方式。文献[18]将负荷数据转换成彩色图像作为卷积神经网络模型的输入, 对商业负荷进行了有效的聚类分析。鉴于人工智能技术在图像处理领域的成熟应用, 以及负荷数据图像化应用在负荷缺失数据重构和负荷聚类分析上的成功案例, 负荷数据可视化将有助于负荷预测模型的构建。

本文提出一种将负荷数据转化为彩色图像后应用长短期记忆 (long short-term memory, LSTM) 人工神经网络进行短期电力负荷预测的方法。首先, 分析图像化的负荷数据表达方法, 包括时序负荷曲线转换为RGB (red, green, blue, 三原色) 格式图片及其逆过程。其次, 将图像化的时序负荷数据作为LSTM的输入进行预测。最后, 通过中国某地区的实际算例对比分析图像化与非图像化输入的预测效果。


1 负荷数据图像化表达

二维曲线是最简单的描述和分析负荷变化趋势的可视化方法, 所以在学术研究和工程应用中, 负荷数据一般被绘制为时序负荷曲线进行表达。


图1 (a) 显示某地区一天的负荷曲线, 可以看出其在呈现少量负荷数据时非常清晰。但在一幅图片中同时呈现大量数据时辨识度不高, 例如图1 (b) 为7 d负荷曲线纵向排布, 图1 (c) 为7 d负荷曲线横向排布。

此外, 热力图也是展示负荷数据的一种有效方法, 其图像清晰、易于理解。但它只能完成数据可视化的单向处理, 一般仅在数据处理后的展示阶段使用^[19]。


本文采用一种双向转换方法, 既可正向将负荷数



(a) 某地区2020年4月13日96点时序负荷曲线



(b) 某地区2020年4月13日至19日各日负荷曲线



(c) 某地区2020年4月13日至19日负荷时序曲线

图1 负荷时序曲线表达示例

Fig. 1 Examples of load time series curve

据转换为负荷图像作为人工智能预测方法的输入，又可将图像反向转换为精确的负荷数据，用于将模型预测输出的图像结果转换为负荷数据。

1.1 负荷数据图像化

负荷数据图像化正向转换时，使用 x 轴表示从周一到周日每天的采样时间点， y 轴表示从第一周到最后一周的周数，像素颜色表示归一化处理后的负荷数值。将负荷数据所有的基本参数存储在图片的第一行，用于后续逆向转换时解析像素颜色恢复成负荷数据。基本参数包括负荷数据的开始时间、结束时间、采样周期、图片的长宽尺寸和颜色类型等。负荷数据转换为RGB像素的具体步骤如下。

步骤1：数据预处理。本文研究对象为系统负荷数据，利用线性插值法将缺失数据补齐并替换零值数据，确保待转换负荷数据集的时序性和完整性^[20]。

步骤2：统计计算获得基本参数，并将参数均转化为整数型，每一参数占两个像素，填充在图片的第一行，第一行剩余像素置为白色（ R 、 G 、 B 值均设为

255）。基本数据类型主要是日期时间、整数和实数。其中，日期采用标准的UNIX历元时间，将时间数据从1970年1月1日起转换为 s ，变为整数型。

对于任意整数 $I \in [0, 2^{24} - 1]$ 的RGB彩色像素可分别根据式（1）、（2）、（3）获得：

$$R = (I / 256) / 256 \quad (1)$$

$$G = (I / 256) \% 256 \quad (2)$$

$$B = I \% 256 \quad (3)$$

式中： $/$ 是求商的除法运算； $\%$ 是求余数的模运算^[18]。

步骤3：将RGB格式 (r_i, g_i, b_i) 转换为HSV格式 (h_i, s_i, v_i) 显示。HSV表示色相（hue）、饱和度（saturation）和亮度（value），是一种对人类视觉而言比较直观的颜色模型。

步骤4：采用成熟商用软件函数库将HSV格式转换为RGB格式像素值。

步骤5：按时序从图片的第二行开始逐个像素加载负荷信息。加载完成后，最后一行的剩余空格用黑色填充。

1.2 负荷图像数值化

负荷图像数值化过程是1.1节的逆过程，其流程如图2所示。




图2 负荷图像数值化流程图

Fig. 2 Flow chart of load image digitization

2 长短期记忆 (LSTM) 网络模型

LSTM是循环神经网络 (recurrent neural network, RNN) 的一种变体, 其在RNN的基础上添加相应的“门”结构。在训练过程中, LSTM通过这些“门”对序列中的特征信息进行保留或移除。因此, LSTM可以沿长链序列传递相关特征信息以进行预测, 从而克服了RNN短时记忆的影响, 该机制对于提高预测精确度至关重要。标准的LSTM细胞结构如图3所示。




图3 LSTM的细胞结构和运算

Fig. 3 Cell structure and operation of LSTM

LSTM的核心在于图3中的三个共同控制细胞状态的“门”结构: 遗忘门、输入门以及输出门。

遗忘门确定前一时刻的细胞状态 C_{t-1} 中需要保留的重要信息。来自前一时刻的隐藏状态信息和当前时刻的信息同时传递到sigmoid函数 $\sigma(\cdot)$ 中, 输出值介于0和1之间, 越接近0意味着越应该丢弃, 越接近1意味着越应该保留。公式描述为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

式中: x_t 为负荷图片第二行起的像素值 r_{ij} 、 g_{ij} 或 b_{ij} (i 表示第 i 行, j 表示第 j 列); h_{t-1} 的定义与上节不同, 本节为上一时刻的隐藏状态输出值; W_f 和 b_f 分别为该遗忘层的权重矩阵和偏置, 下标 f 表示遗忘门。

输入门确定当前输入中的重要信息, 用于更新细胞状态。分别将前一层隐藏状态的信息和当前输入的信息传递到sigmoid函数和tanh两个函数中。前者将值调整到0至1之间以确定需要更新的信息, 数字越大表示越重要; 后者创造一个新的候选值向量。最后将sigmoid的输出值与tanh的输出值相乘, sigmoid的输出值将决定tanh的输出值中重要且需要保留下来的信息。公式描述为

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\bar{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \bar{c}_t \quad (7)$$

式中: i_t 和 $\bar{c}_t$ 分别是sigmoid函数和tanh函数的输出, 分别表示重要程度和候选值向量; W_i 和 b_i 、 W_c 和 b_c 分别为这两层的权重矩阵及偏置, 下标 c 表示输入门。 C_t 更新后的细胞状态会继续向下一个时刻传递。

输出门确定下一个隐藏状态的值。计算过程如下:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (9)$$

式中: W_o 和 b_o 分别是权重矩阵和偏置, 下标 o 表示输出门。

其求解过程为: 前向计算每个神经元的输出值; 反向计算每个神经元的输出值与实际值的误差; 使用某种优化算法在迭代过程中逐步缩小误差, 使输出值逼近实际值。

3 预测方法总体框架

本文所提预测方法的执行流程如图4所示。首先, 获取历史时序负荷数据并对其进行数据预处理, 对缺值、零值等异常数据采用线性插值法进行修正。其次, 对异常数据修正后的时序负荷数值进行统计分析, 计算基本参数 (包括负荷数据的开始时间、结束时间、采样周期、图片的长宽尺寸和颜色类型等),




图4 预测流程

Fig. 4 Forecasting process

利用1.1节中的负荷数据图像化方法,将其填充在图片的第一行,第一行剩余像素置为白色。再次,将负荷数值转化为 R 、 G 、 B 值,从图片的第二行开始逐行填充,最后一行剩余像素置为黑色,得到负荷图片。最后,将负荷 R 、 G 、 B 值按照时序排列分别输入多层LSTM模型中进行训练与预测,例如,输入为历史多日的96点 R 值序列,输出为待预测日的96点 R 值序列。将输出的96点 R 、 G 、 B 值逐点组合转化为负荷数值,形成待预测日的96点负荷预测时序曲线。

4 实例分析

实验数据选取中国某地区2020年1月1日至2020年9月30日的负荷数据,共40周。采样间隔为15 min,每日96个采样点。绘制负荷RGB彩图,并将其转化为HSV格式直观显示,如图5所示。可以看到,该负荷图片的色彩分布以周为周期具有一定的规律性,但同时也包含细节上的差异,为预测过程提供了大量信息。




图5 负荷HSV彩图
Fig. 5 Load HSV picture

构建LSTM模型时,选择待预测日前30日至前2日共28天的图像化负荷的 R (或 G 、 B)信息数据作为LSTM模型的训练集;待预测日前1日的图像化负荷的 R (或 G 、 B)信息作为LSTM网络预测模型的验证集;待预测日的 R (或 G 、 B)信息作为测试集。以 R 值的预测为例,使用LSTM模型对待预测日96点 R 值进行预测时,首先训练LSTM模型,训练时使用均方根误差(root mean square error, RMSE)作为损失函数;堆叠层数为2,各层LSTM的神经元数量分别为16和32,分别在第一层LSTM的输入层、两层LSTM之间使用Dropout和BN(batch normalization, 批归一化)层,以降低过拟合风险;优化器使用Adam算法;时间步长设为16,训练集样本量设为96;LSTM训练批量为256,方法为从1024起逐次折半对该参数进行设置,选择训练RMSE降低时,即性能有所提高时的数值作为此参数值。

训练完成后,将前一日的图像化负荷信息数据作为“特征”输入模型,以此预测待预测日第一个采样时刻的图像化负荷 R 值。然后将预测值分别加入 R 序列

的最后,窗口向后滑动一个时刻,再用最后96个负荷 R 值继续预测待预测日的第二个采样点的负荷 R 值。依次类推,直至完成待预测日96个采样点图像化负荷 R 值的迭代预测。 G 值和 B 值预测时,采用同样的LSTM模型构建和参数设置方法。各分量预测完成后,将RGB图像转化为负荷数值序列,即可获得待预测日96点负荷值的时序预测结果。

为了说明将时序负荷数据进行图像化处理对于拓展负荷信息维度、丰富负荷信息量的作用,本文使用两种方法做对比。图像化负荷LSTM(算法1,即本文算法):使用LSTM模型,将负荷图像化后的 R 、 G 、 B 分量数据分别作为模型的输入进行训练与预测。负荷值序列LSTM(算法2):同样使用LSTM网络模型,但将时序负荷数据作为整体进行预测。两种方法对于2020年7月12日的负荷预测结果如图6所示。将两种算法的预测值与实际值相比可知,本文方法通过数据图像化拓展了信息维度,提高了LSTM预测算法的自适应能力,显著提高了2020年7月12日的短期负荷预测精度。




图6 预测结果对比
Fig. 6 Comparison of forecasting results

将预测从单日扩展到多日以验证预测效果的稳定性,考查2020年7月11日至2020年8月1日连续三周预测的平均效果,采用平均绝对百分比误差(mean absolute percentage error, MAPE)和RMSE指标进行度量。结果如表1所示,从两项指标来看,算法1均明显优于算法2。

为了选择更优的图像化负荷的算法模型,对以下几种模型进行比较:图像化负荷LSTM(算法1,即本文算法)、BP神经网络(算法3)、随机森林算法(算法4),各模型的输入均为负荷图像化后的 R 、 G 、 B 分量。调整各模型参数,使其在训练集上的拟合情况和实际预测情况达到各算法的最优效果。对2020年7月

表 1 基于图像化负荷LSTM与基于负荷值序列LSTM的预测效果对比

Table 1 Comparison of forecasting results based on digital LSTM and graphic LSTM

指标 \ 算法	图像化负荷LSTM (算法1)	负荷值序列LSTM (算法2)
MAPE	4.36%	9.72%
RMSE	4 957.1	9 566.8

12日96个采样点的负荷实际值进行误差分析,结果如表2所示。通过对比MAPE和RMSE两项指标发现,采用LSTM网络模型的预测结果优于BP神经网络和随机森林算法,说明LSTM网络模型在图像化负荷预测上的适用性更强。尤其是与BP神经网络相比,作为一种特殊的、加入了记忆功能的循环神经网络,LSTM的长期依赖特性对于有一定周期性的负荷时间序列的预测效果明显更好。

表 2 本文方法与其他方法的预测效果对比

Table 2 Comparison of forecasting results of the method in this paper with other methods

指标 \ 算法	图像化负荷LSTM (算法1)	BP神经网络 (算法3)	随机森林算法 (算法4)
MAPE	2.74%	11.42%	3.28%
RMSE	3 349.5	10 375.3	4 572.6

5 结论与展望

本文提出了一种将负荷数据转化为RGB图像后应用LSTM人工神经网络进行短期电力负荷预测的方法,对图像化负荷的人工智能预测进行了初步尝试。该方法将一维负荷数值信息扩展为R、G、B三个维度,分别应用LSTM模型进行训练与预测。实验结果表明,本文所提出的方法丰富了负荷信息的展现方式,扩展了负荷预测的信息应用维度,提升了预测精度,具有一定的可行性。

本文只针对负荷本身进行了研究,下一步将尝试采用本文负荷图像化的思路将气象等重要影响因素数据进行图像化转换,利用卷积神经网络(convolutional neural network, CNN)在图像理解和特征提取上的优势,提取负荷图像和气象数据的特征,构建CNN与LSTM相结合的图像化短期负荷预测模型,使空间特征和上下文特征信息同时用于短期负荷图像的分析 and 预测中,有望进一步提升图像化负荷预测方法的准确率。

参考文献

[1] 谭显东, 刘俊, 徐志成, 等. “双碳”目标下“十四五”电力供需形势[J]. 中国电力, 2021, 54(5): 1-6.
TAN Xiandong, LIU Jun, XU Zhicheng, et al. Power supply and demand balance during the 14th five-year plan period under the goal of carbon emission peak and carbon neutrality[J]. Electric Power, 2021, 54(5): 1-6(in Chinese).

[2] 岳有军, 刘英翰, 赵辉, 等. 基于CEEMDAN-SE和DBN的短期电力负荷预测[J]. 电测与仪表, 2020, 57(17): 59-65.
YUE Youjun, LIU Yinghan, ZHAO Hui, et al. Short-term load forecasting based on CEEMDAN-SE and DBN[J]. Electrical Measurement & Instrumentation, 2020, 57(17): 59-65(in Chinese).

[3] 邓带雨, 李坚, 张真源, 等. 基于EEMD-GRU-MLR的短期电力负荷预测[J]. 电网技术, 2020, 44(2): 593-602.
DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. Power System Technology, 2020, 44(2): 593-602(in Chinese).

[4] 董治强. 基于DTW-FCBF-LSTM模型的超短期风速预测[J]. 电测与仪表, 2020, 57(4): 93-98.
DONG Zhiqiang. Ultra-short term wind speed prediction based on DTW-FCBF-LSTM model[J]. Electrical Measurement & Instrumentation, 2020, 57(4): 93-98(in Chinese).

[5] 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.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152(in Chinese).

[6] HAFEEZ G, ALIMGEER K S, KHAN I. Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid[J]. Applied Energy, 2020, 269: 114915.

[7] GE Q B, GUO C, JIANG H Y, et al. Industrial power load forecasting method based on reinforcement learning and PSO-LSSVM[J]. IEEE Transactions on Cybernetics, 2022, 52(2): 1112-1124.

[8] 张金金, 张倩, 马愿, 等. 模糊聚类-Elman神经网络短期光伏发电预测模型[J]. 电测与仪表, 2020, 57(12): 46-51.
ZHANG Jinjin, ZHANG Qian, MA Yuan, et al. Fuzzy clustering-Elman neural network model for short-term photovoltaic power generation prediction[J]. Electrical Measurement & Instrumentation, 2020, 57(12): 46-51(in Chinese).

[9] 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.
PANG Chuanjun, ZHANG Bo, YU Jianming. Short-term power load forecasting based on LSTM recurrent neural network[J]. Electric Power Engineering Technology, 2021, 40(1): 175-180(in Chinese).

[10] DU P, WANG J Z, YANG W D, et al. Multi-step ahead forecasting in electrical power system using a hybrid

- forecasting system[J]. Renewable Energy, 2018, 122: 533-550.
- [11] 唐振浩, 赵赓楠, 曹生现, 等. 基于SWLSTM算法的超短期风向预测[J]. 中国电机工程学报, 2019, 39(15): 4459-4468.
- TANG Zhenhao, ZHAO Gengnan, CAO Shengxian, et al. Very short-term wind direction prediction via self-tuning wavelet long-short term memory neural network[J]. Proceedings of the CSEE, 2019, 39(15): 4459-4468(in Chinese).
- [12] BENTO P M R, POMBO J A N, CALADO M R A, et al. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting[J]. Neurocomputing, 2019, 358: 53-71.
- [13] 张倩, 马愿, 李国丽, 等. 频域分解和深度学习算法在短期负荷及光伏功率预测中的应用[J]. 中国电机工程学报, 2019, 39(8): 2221-2230.
- ZHANG Qian, MA Yuan, LI Guoli, et al. Applications of frequency domain decomposition and deep learning algorithms in short-term load and photovoltaic power forecasting[J]. Proceedings of the CSEE, 2019, 39(8): 2221-2230(in Chinese).
- [14] HENG J N, WANG C, ZHAO X J, et al. A hybrid forecasting model based on empirical mode decomposition and the cuckoo search algorithm: a case study for power load[J]. Mathematical Problems in Engineering, 2016, 2016: 3205396.
- [15] KONG W C, DONG Z Y, JIA Y W, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.
- [16] 杨玉莲, 齐林海, 王红, 等. 基于生成对抗和双重语义感知的配电网量测数据缺失重构[J]. 电力系统自动化, 2020, 44(18): 46-54.
- YANG Yulian, QI Linhai, WANG Hong, et al. Reconstruction of missing measurement data in distribution network based on generative adversarial network and double semantic perception[J]. Automation of Electric Power Systems, 2020, 44(18): 46-54(in Chinese).
- [17] OZAWA A, FURUSATO R, YOSHIDA Y. Determining the relationship between a household's lifestyle and its electricity consumption in Japan by analyzing measured electric load profiles[J]. Energy and Buildings, 2016, 119: 200-210.
- [18] WANG H, QI L H, YAN L, et al. Load photo: a novel analysis method for load data[J]. IEEE Transactions on Smart Grid, 2021, 12(2): 1394-1404.
- [19] YE C J, DING Y, WANG P, et al. A data-driven bottom-up approach for spatial and temporal electric load forecasting[J]. IEEE Transactions on Power Systems, 2019, 34(3): 1966-1979.
- [20] AL-WAKEEL A, WU J Z, JENKINS N. K-means based load estimation of domestic smart meter measurements[J]. Applied Energy, 2017, 194: 333-342.
- 收稿日期: 2021-11-02; 修回日期: 2022-04-01。
- 作者简介:
- 杨书强 (1993), 男, 硕士, 工程师, 研究方向为电力系统分析和配电网规划, E-mail: 2464473685@qq.com。
- 刘梅 (1971), 女, 硕士, 高级工程师, 研究方向为电力市场分析预测。通信作者, E-mail: lm@tsingsoft.com.cn。
- (责任编辑 张宇 翁宇威)



杨书强