

基于EMD-LSTM的用电负荷预测

黄超¹, 丁咏梅^{2*}, 高翔¹, 刘丽珺³

¹武汉科技大学, 湖北 武汉

²武汉科技大学冶金工业过程系统科学湖北省重点实验室, 湖北 武汉

³中国邮政集团有限公司宜昌市夷陵区分公司, 湖北 宜昌

收稿日期: 2022年7月29日; 录用日期: 2022年8月21日; 发布日期: 2022年8月30日

摘要

基于电力数据分析处理的系统决策正在不断地推进电力系统优化, 我国对于构建有效的电力大数据模型有着强烈的现实诉求。本文运用经验模态分解及小波变换来降低该序列中的环境噪声, 并根据各个分解信号的样本熵值进行序列重组, 以降低重复建模的工作量, 进而提高模型预测精度。实证结果表明, 经过降噪处理和数据重组后, 长短期记忆网络模型的拟合效果较好, 所建模型具有稳健性。

关键词

经验模态分解, 样本熵, 小波变换, 长短期记忆网络

Electricity Load Forecast Based on EMD-LSTM

Chao Huang¹, Yongmei Ding^{2*}, Xiang Gao¹, Lijun Liu³

¹Wuhan University of Science and Technology, Wuhan Hubei

²Hubei Provincial Key Laboratory of System Science in Metallurgical Process, Wuhan University of Science and Technology, Wuhan Hubei

³Branch of Yiling District, Yichang City, China Post Group Co., Ltd., Yichang Hubei

Received: Jul. 29th, 2022; accepted: Aug. 21st, 2022; published: Aug. 30th, 2022

Abstract

System decision-making based on power data analysis and processing is continuously advancing

*通讯作者。

power system optimization, which appeals a strong practical application for building an effective power big data model in our country. In this paper, empirical mode decomposition and wavelet transform are used to reduce the environmental noise in the sequence, and the series recombination is performed according to the sample entropy of each decomposition signal to reduce the workload of repeated modeling and improve the prediction accuracy of the model. The empirical results show that the fitting effect of the long and short-term memory network model is better after reducing the noise and reorganization data, which shows our theoretical model effective and robust.

Keywords

Empirical Mode Decomposition, Sample Entropy, Wavelet Transform, Long Short-Term Memory Network

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

当前, 在新电改的影响之下, 电力行业信息化和工业化的不断融合促使电力数据量的暴增。电力大数据受到各个因素的影响, 产生大量多源异构数据, 且需求侧用电数据具有的随机性、非线性、时变性和分散性, 致使用电负荷预测的难度较大。因此, 亟需研究用电负荷预测技术与方法, 为高效的能源消费提供数据支撑。

近年来区域电网的互联升级, 电网规模的不断扩大以及用电需求的持续增长, 使得电力系统高峰负荷和峰谷负荷差不断增大, 电力系统所面临的风险受到电力部门的重点关注[1] [2]。精准的电力数据分析是降低电网运行风险的关键[3]。在电力大数据时代, 为充分挖掘数据的信息, 各种算法、模型纷纷被纳入各种尺度的数据分析中。深度学习是机器学习和人工智能研究的新趋势之一。作为神经网络的延伸, 它解决了 BP 网络随着网络层次的增加, 可能会出现局部最优解、过拟合、以及无标签数据的缺陷[4] [5]。深度学习中较为常用的网络模型有深度置信网络(Deep Belief Networks, DBN) [6], 卷积神经网络(Convolutional Neural Network, CNN) [7], 递归神经网络(Recurrent Neural Network, RNN) [8]。其中, 递归神经网络是一类具有短期记忆能力的神经网络。其神经元不但可以接收其他神经元的消息, 还可以接收自身的消息, 形成具有环路的网络结构。当输入序列比较长时, 会产生长期依赖问题。为了解决这个问题, 引入门控机制来改进递归神经网络, 于是诞生长短记忆网络和门控循环单元网络[9] [10]。陈振宇等建立 LSTM 与 XGBoost 的组合预测模型来预测超短期电力负荷, 并于 GRU 与 XGBoost 的组合预测模型相对比, 认为前者具有更高的预测精度[11]。吕海灿等基于 Wide&Deep-LSTM 模型预测台区电力负荷, 结果表明该模型具有较高的实用性[12]。

基于此, 在当前电力大数据环境下, 由于传统模型难以满足现实诉求, 故本文拟采用深度学习理论结合经验模态分解、样本熵、小波变换方法来挖掘用电负荷数据中的有效信息, 以期充分利用电力大数据, 提高用电负荷预测精度。

2. 理论分析

2.1. 经验模态分析

经验模态分解首先需要找出原始信号 y_i 中所有的局部极大值点和局部极小值点, 使用三次样条分别

连接极大值点和极小值点作为上包络线与下包络线，并求出上包络线与下包络线的均值 c_1 。信号 y_t 与 c_1 的差为 $r_1 = y_t - c_1$ ，若 r_1 满足在整个数据内，局部极值点与过零点的数目之差小于等于 1 或者在任意时刻，局部最大值的包络(上包络线)和局部最小值的包络(下包络线)的平均值必须为零，则第一个分量可以表示为 r_1 。若不满足 IMF 的条件，则可将 r_1 看成原始信号处理，再进行上述方法。经反复筛选 n 次，直到 r_n 是单调函数或是一个极小的常量时，停止分解过程，并得到下式：

$$y_t = \sum_{i=1}^n c_i + r_n \quad (1)$$

2.2. 样本熵 2.3 小波变换

y_t 是长度为 N 的原始数据，预先给定嵌入维数 m 和相似容限 γ ，依据原始信号重构一个 m 维向量，

$$y_t(i) = [y_t(i), y_t(i+1), \dots, y_t(i+m-1)] \quad (2)$$

距离 d_{ij} 代表了 $y_t(i)$ 和 $y_t(j)$ 两者对应元素差值绝对值的最大值，

$$d_{ij} = d[y_t(i), y_t(j)] = \max [|y_t(i+k) - y_t(j+k)|] \quad (3)$$

其中 $k = 0 \sim m-1$ 。

计算 $y_t(i)$ 与其余向量 $y_t(j)$ 的距离 d_{ij} ，统计 d_{ij} 小于 γ 的数目 n 以及次数目与距离总数 $N-m-1$ 的比值，即：

$$B_i^m(\gamma) = \frac{1}{N-m} n \quad (4)$$

其中 $i = 1 \sim N-m+1$ ； $i \neq j$ 。

进一步求出 $B_i^m(\gamma)$ 的平均值，

$$B^m(\gamma) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} B_i^m(\gamma) \quad (5)$$

同样的方法，对维数 $m+1$ ，求得到 $B^{m+1}(\gamma)$ 。

样本熵可以用 $\text{SampEn}(m, r, N)$ 表示，其中 m 表示维数， γ 表示相似容限， N 表示长度，则：

$$\text{SampEn}(m, \gamma, N) = -\ln \left[\frac{B^{m+1}(\gamma)}{B^m(\gamma)} \right] \quad (6)$$

由(6)可以看出 SampEn 的值与 m 和 γ 有关，一般情况下 $m = 1$ 或 2 ， $\gamma = 0.1\text{SD} \sim 0.25\text{SD}$ ，其中 SD 表示原始时间序列的标准差。

2.3. 小波变换 2.4 长短期记忆网络

小波变换理论的发展离不开小波函数的支撑，一般将定义时域具有紧支集且平均值为 0 的函数称为小波函数。令 $y(t) \in L^2(R)$ ，当傅里叶变换函数 $y(\omega)$ 满足(7)时，

$$C_y = \int_{-\infty}^{+\infty} \frac{|y(\omega)|^2}{|\omega|} d\omega < \infty \quad (7)$$

就称 $y(t)$ 为小波母函数。进一步对小波母函数 $y(t)$ 进行伸缩平移变化后, 得到:

$$y_{a,b}(t) = \frac{1}{\sqrt{a}} y\left(\frac{t-b}{a}\right) \quad (a > 0, b \in R) \quad (8)$$

其中, $y_{a,b}(t)$ 为依赖参数 a, b 的小波基函数, a 为尺度因子, b 为位移因子。

离散小波变换比连续小波变换具有更广泛的实际应用。对尺度因子 a 和位移因子 b 按照幂级数进行离散化处理。令 $a = a_0^j$, $b = ka_0^j b_0$, 其中 $j, k \in Z$, 则(8)可表示为:

$$y_{j,k}(t) = a_0^{-\frac{j}{2}} y(a_0^{-j} t - kb_0) \quad (j, k \in Z) \quad (10)$$

称(10)为离散小波函数, 进而得到离散小波变换为:

$$WT_f(j, k) = \langle f(t), y_{j,k}^*(t) \rangle = \int_{-\infty}^{+\infty} f(t) y_{j,k}^*(t) dt \quad (11)$$

其中, $WT_f(j, k)$ 为连续小波变换系数, $y_{j,k}^*(t)$ 为 $y_{j,k}(t)$ 的复共轭函数。

离散逆小波变换公式为:

$$f(t) = C \sum_{j=-\infty}^{+\infty} \sum_{k=-\infty}^{+\infty} WT_f(j, k) y_{j,k}(t) \quad (12)$$

其中, C 为一个常量。

2.4. 长短期记忆网络

长短期记忆网络是一种特殊的递归神经网络, 其具有能保存时间间隔较长的信息的特性, 即能够弥补递归神经网络在预测时间间隔较长的序列时预测结果出现偏差的缺点。长短期记忆网络模型的细胞单元, 如图 1 所示。

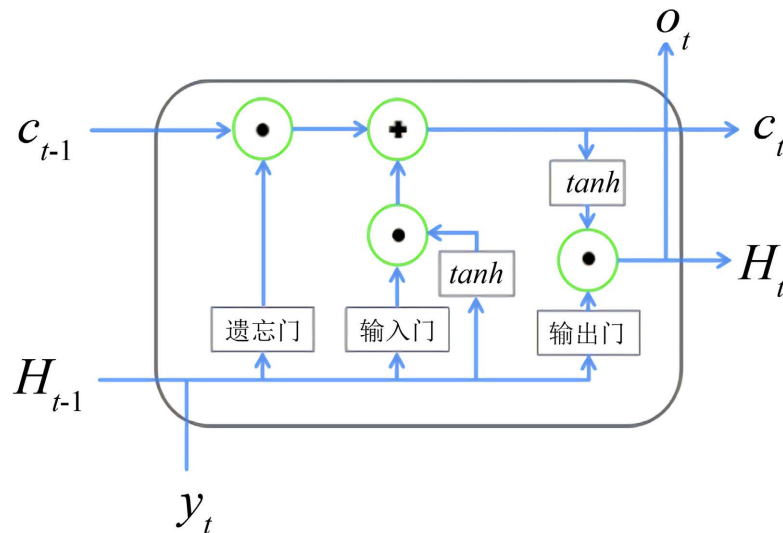


Figure 1. LSTM cell unit
图 1. LSTM 细胞单元

长短期记忆网络模型是在递归神经网络的基础上加入细胞状态和门限。其中, 细胞状态(cell state)是图 1 中一条单向流动的水平信息运输线, 信息在这条水平线上只会进行少量的信息交流。在遗忘门中, (13)决定哪一部分信息需要被丢弃,

$$f_t = \sigma(W_f \cdot [H_{t-1}, y_t] + b_f) \quad (13)$$

其中, f_t 代表了多大程度上忘记之前的信息, H_{t-1} 是上一时刻的输出结果, y_t 是当前时刻的信息输入, W_f 、 b_f 分别为遗忘门的权重和偏置。

输入门则是选择信息中哪一部分的需要被放入细胞状态。其中, i_t 代表有多少信息需要被更新, W_i 、 b_i 分别为遗忘门的权重和偏置, \tilde{C}_t 为 \tanh 层生成一个新的候选数值, C_t 为当前细胞状态。

$$i_t = \sigma(W_i \cdot [H_{t-1}, y_t] + b_i) \quad (14)$$

$$\tilde{C}_t = \tanh(W_c \cdot [H_{t-1}, y_t] + b_c) \quad (15)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (16)$$

输出门则是将需要被输出的细胞状态进行输出。其中 o_t 决定输出哪一部分的细胞状态, W_o 、 b_o 分别为输出门的权重和偏置, H_t 为需要输出的信息。

$$o_t = \sigma(W_o \cdot [H_{t-1}, y_t] + b_o) \quad (17)$$

$$H_t = o_t \times \tanh(C_t) \quad (18)$$

3. 实证分析

3.1. 数据的来源

电力系统的数据信息的获取通常具有局限性。基于数据的可行性, 本文从某开源网站上获取美国某地区 2019 年 1 月至 2021 年 4 月的居民用电负荷, 其采样间隔为 5 分钟。对于用电低谷负荷值的预测, 由于考虑到精确的负荷预测值能有助于供电部门更好的制定供电计划, 所以选择居民用电负荷日平均值作为研究对象。如图 2 所示, 即为居民日用电负荷序列, 可以看到该负荷曲线波动频繁。进一步分析一天中居民用电规律, 以 2019 年 1 月 1 日为例, 如图 3 所示, 可知早上 4 点到早上 8 点为居民用电增长阶段, 从早上 9 点到下午 5 点居民用电负荷较为稳定, 晚上 6 到晚上 8 点为居民用电的高峰期, 随后居民用电逐步减少。




Figure 2. Daily electricity load of residents

图 2. 居民日用电负荷




Figure 3. Hourly electricity load of residents on January 1, 2019
图 3. 2019 年 1 月 1 日居民每小时用电负荷


根据表 1 中的居民日用电负荷数据的描述性统计特征, 可知该序列偏度大于 0, 峰度大于 3, 即居民日用电负荷数据分布呈现右偏尖峰。

Table 1. Descriptive statistical characteristics of residents' weekly electricity load series
表 1. 居民周用电负荷序列描述性统计特征

	均值	中位数	最小值	最大值	标准差	偏度	峰度
居民日用电负荷	1384.70	1371.46	1052.04	2031.81	158.49	0.51	3.29

3.2. 经验模态分解

为得到的更为精确的峰谷负荷预测值, 本节运用长短期记忆网络对用电峰谷负荷进行预测。对美国居民日用电负荷序列进行经验模态分解, 分解后得到本征模函数 imf1、imf2、imf3、imf4、imf5、imf6、imf7 及残差 res。从经验模态分解图(如图 4 所示)中, 可以看到各个本征模函数的频率依次降低, 函数波形的变化渐缓且趋势趋于平滑。






Figure 4. Empirical mode decomposition

图 4. 经验模态分解

若直接对本征模函数建立长短期记忆网络模型，这无疑增加了重复建模的工作量，并且各个本征模函数之间的相关性也会被忽略，所以需要对本征模函数以残差序列进行数据重构。

3.3. 数据重组

样本熵值代表了数据的混乱复杂程度。在对 imf1、imf2、imf3、imf4、imf5、imf6、imf7 以及残差 res 求取相对应的样本熵值后，根据各本征模函数和残差序列的复杂程度对日用电负荷数据的各个分量进行划分重组。如图 5 所示，经过经验模态分解之后，样本熵值整体呈现递减趋势，即经过经验模态分解后各分量的复杂程度在逐步降低，进一步说明经验模态分解能有效地提取信号特征。

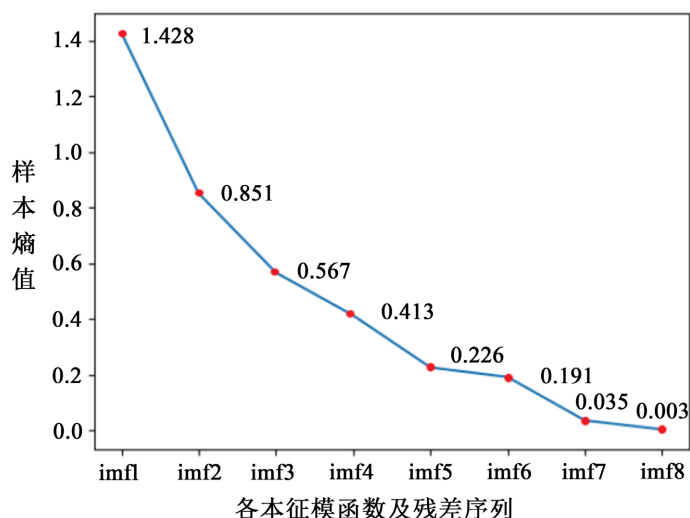


Figure 5. Sample entropy of original data and eigenmode function

图 5. 原始数据与本征模函数的样本熵值

本征模函数中 imf1 与 imf2 作为用电负荷序列中的高频分量，两者的样本熵值较大，说明两者中含有大量环境噪声，且相较于其他分量呈现出十分强烈的随机性和波动性，因此，可将 imf1 与 imf2 重组成为一个新的分量，称其为随机分量。而 imf3、imf4、imf5 和 imf6 的样本熵值较为接近，且根据经验模态分解图中的波形变化，认为 imf3 至 imf6 在复杂程度降低的同时呈现出了一定的规律，则将其进行叠加组合得到新的分量，即细节分量。imf7 和 res 的样本熵值较为接近，并且两者的波动性较小，序列变化趋势较为平缓，故将二者进行数据重新组合后得到趋势分量。重组后的各个分量如图 6 所示。

图 6 中的随机分量由于受到季节温度等环境因素的影响，导致其具有规律性差，波动性强的特征，故在一般情况下难以得到较为精准的预测结果。细节分量与样本序列的波动规律较为接近，反映了用电负荷的周期特征和居民活动规律。趋势分量的趋势变化与原始数据大致相同。




Figure 6. Intrinsic modulus function after sample entropy

图 6. 经样本熵处理后的本征模函数

在建立长短期记忆模型时，若直接剔除含有噪音的随机分量可能会造成信号失真，所以选择一维小波变换对随机分量进行降噪处理，小波函数选取 db4。对比去噪后的趋势分量与原始趋势分量，如图 7 所示。对比经去噪处理之后的趋势分量与未处理的随机分量后，发现经过降噪的随机分量的趋势更为平滑，这说明小波变换在一定程度上剔除了环境噪声对随机分量的影响。




Figure 7. Comparison of trend components after wavelet transform

图 7. 小波变换后的趋势分量对比图

3.4. 长短期记忆网络预测

由于用电负荷数据为单变量时间序列，故需要选择一定的时间步长作为滞后观察量。在本节中所使用的样本数据为居民日用电负荷，因为居民每周的生活工作基本重复，所以时间步长选择为 7。长短期记忆网络结构为单层，神经数为 256，其中，迭代次数固定为 10000 次，批量大小为 1000，将样本数据的 80%划分为训练集，剩余 20%为测试集。

EMD-LSTM、模型分别对随机分量、细节分量和趋势分量的预测结果分别如图 8、图 9 和图 10 所示。从图中可以看到细节分量和趋势分量的预测值与相对应的真实值基本一致。较难预测的趋势分量在经过降噪处理后，其预测值与趋势分量的真实值基本接近。并将各个分量的预测结果进行累加，得到还原后的居民日用电负荷数据预测结果，如图 11 所示。

为更加直观的观察 EMD-LSTM 模型的预测效果，选择最后一周的居民日用电负荷进行观察。如图 12 所示，我们给出居民用电量序列最后一周的预测结果，表 2 与表 3 为最后一周各个分量和居民日用电负荷与预测值对比与模型预测误差，从图 12 与表 2，表 3 中可以看到该网络模型的预测误差较小，拟合效果较好。

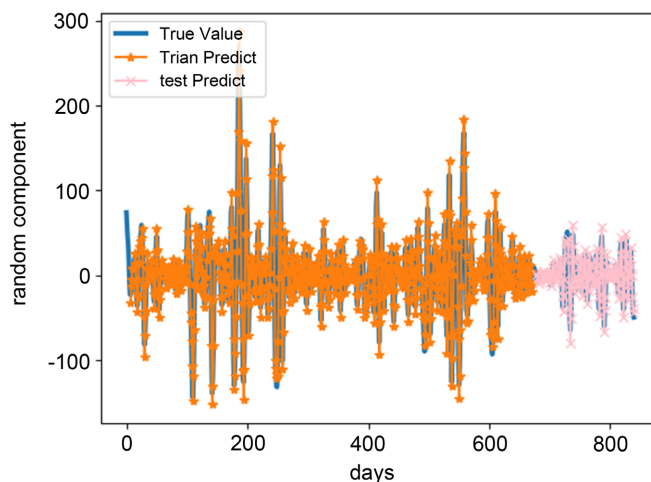


Figure 8. Random component prediction results

图 8. 随机分量预测结果

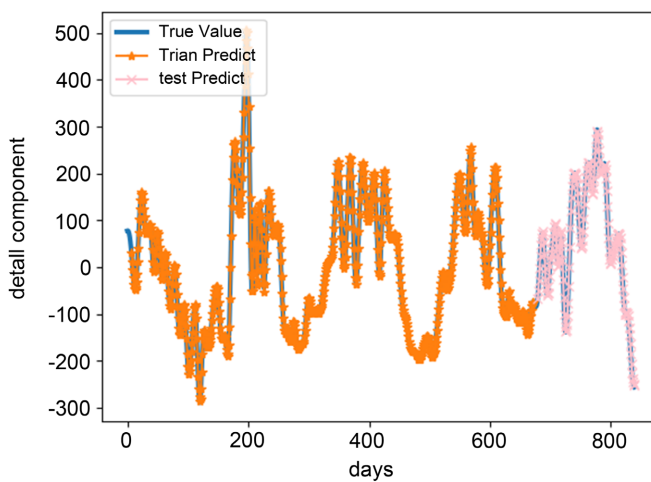


Figure 9. Detail component prediction results

图 9. 细节分量预测结果

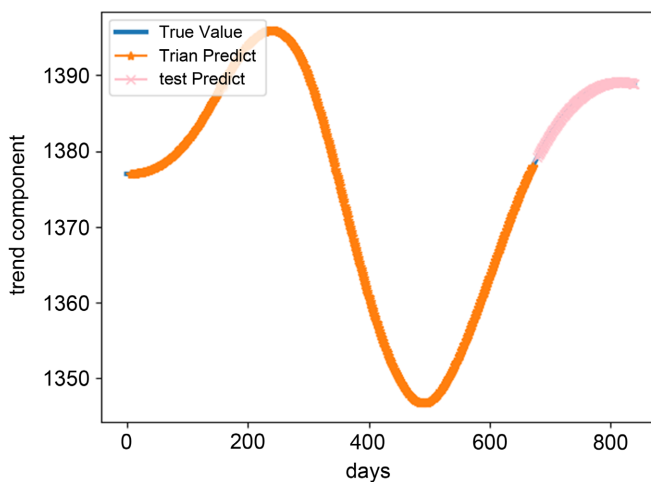


Figure 10. Trend component prediction results

图 10. 趋势分量预测结果




Figure 11. EMD-LSTM model prediction results

图 11. EMD-LSTM 模型预测结果




Figure 12. EMD-LSTM model prediction results (2019.4.13~2021.4.19)

图 12. EMD-LSTM 模型预测结果(2019.4.13~2021.4.19)

Table 2. Comparison of model predicted value and real value

表 2. 模型预测值与真实值对比

随机分量真实值	随机分量预测值	细节分量真实值	细节分量预测值	趋势分量真实值	趋势分量预测值	居民日用电负荷真实值	居民日用电负荷预测值
23.86	19.77	-188.80	-185.21	1388.97	1388.99	1224.03	1223.55
28.52	32.88	-209.09	-207.03	1388.95	1388.97	1208.38	1214.82
13.33	11.72	-226.01	-224.87	1388.94	1388.95	1176.26	1175.81
-3.96	-0.31	-239.06	-237.22	1388.92	1388.94	1145.90	1151.40
-30.07	-25.11	-248.35	-245.13	1388.90	1388.92	1110.48	1118.67
-46.24	-43.97	-254.02	-249.58	1388.88	1388.90	1088.62	1095.35
-49.55	-38.47	-256.23	-251.41	1388.86	1388.88	1083.08	1098.99

Table 3. Model prediction error
表 3. 模型预测误差

	随机分量	细节分量	趋势分量	居民日电负荷
RMSE	4.27	3.04	0.01	5.52

4. 结论

本文首先对用电负荷数据采用经验模态分解得到各本征模函数及残差, 然后根据各本征模函数及残差的样本熵值进行数据重组, 并运用小波变换提出随机分量中的环境噪声, 最后采用长短期记忆网络进行用电负荷预测。由模型的均方根误差中可以由此认为, 该模型能够为供电当局精准把控电力能源的利用提供可能。同时, 在一定程度上避免超负荷导致的大面积停电事故或者在用电负荷低谷时期对电网输送电量过大, 造成电力资源一定程度上浪费。

基金项目

冶金工业过程系统科学湖北省重点实验室开放基金(编号: Y201902); 武汉科技大学教学研究项目(2018X029); 武汉科技大学研究生教育教学改革研究项目(Yjg201815)。

参考文献

- [1] 吴裕生. 基于用户侧负荷优化的有源配电网可靠性评估[D]: [硕士学位论文]. 广州: 华南理工大学, 2017.
- [2] 杨海涛, 祝达康, 李晶, 庞爱莉, 杨琦. 特大型城市电网大停电的机理与预防对策探[J]. 电力系统自动化, 2014, 38(6): 128-135.
- [3] McNeil, M.A., Karali, N. and Letschert, V. (2019) Forecasting Indonesia's Electricity Load through 2030 and Peak Demand Reductions from Appliance and Lighting Efficiency. *Energy for Sustainable Development*, **49**, 65-77. <https://doi.org/10.1016/j.esd.2019.01.001>
- [4] 龚泽威一. 基于机器学习的居民用电行为分析[D]: [硕士学位论文]. 昆明: 昆明理工大学, 2018.
- [5] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
- [6] 徐春华, 陈克绪, 马建, 刘佳翰, 吴建华. 基于深度置信网络的电力负荷识别[J]. 电工技术学报, 2019, 34(19): 4135-4142.
- [7] 杨蹊, 钟力强, 殷豪. 基于卷积神经网络与纵横交叉算法的二维组合短期负荷预测方法研究[J]. 现代信息科技, 2019, 3(4): 160-162.
- [8] 白芬玉. 基于 RNN 神经网络的短期电力负荷预测模型研究[D]: [硕士学位论文]. 成都: 成都理工大学, 2019.
- [9] 杨甲甲, 刘国龙, 赵俊华, 等. 采用长短期记忆深度学习模型的工业负荷短期预测方法[J]. 电力建设, 2018, 39(10): 20-27.
- [10] 王增平, 赵兵, 纪维佳, 等. 基于 GRU-NN 模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 53-62.
- [11] 陈振宇, 刘金波, 李晨, 季晓慧, 李大鹏, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(2): 614-620.
- [12] 吕海灿, 王伟峰, 赵兵, 张毅, 郭秋婷, 胡伟. 基于 Wide&Deep-LSTM 模型的短期台区负荷预测[J]. 电网技术, 2020, 44(2): 428-436.