

DOI: 10.19783/j.cnki.pspc.220037

基于机器学习与疫情关联特征的短期负荷预测

程志友^{1,2}, 汪德胜²

(1. 教育部电能质量工程研究中心(安徽大学), 安徽 合肥 230601;

2. 安徽大学电子信息工程学院, 安徽 合肥 230601)

摘要: 准确的电力负荷预测是电力系统正常运转的重要保障。针对新冠疫情期间负荷需求波动大、历史参考负荷难以建模等问题, 提出了一种基于机器学习与静默指数、滚动焦虑指数的短期负荷预测方法。首先, 利用谷歌流动性数据和疫情数据构建出静默指数、滚动焦虑指数来量化经济、疫情的发展对电力负荷造成的影响。然后, 采用最大信息系数分析疫情期间电力负荷的强相关因素并引入疫情负荷关联特征。最后, 将气象数据、历史负荷以及构建的疫情关联特征合并作为预测模型的输入变量, 通过多种机器学习模型进行预测算例分析。结果表明, 引入疫情关联特征的负荷预测模型能够有效地提高疫情期间负荷预测的准确性。

关键词: 负荷预测; 新冠疫情; 机器学习; 静默指数; 焦虑指数

Short-term load forecasting based on machine learning and epidemic association features

CHENG Zhiyou^{1,2}, WANG Desheng²

(1. Power Quality Engineering Research Center (Anhui University), Ministry of Education, Hefei 230601, China;

2. School of Electronics and Information Engineering, Anhui University, Hefei 230601, China)

Abstract: Accurate power load forecasting is an important guarantee for normal operation of a power system. There have been problems of large fluctuations in load demand and difficulty in modeling historical reference load during the COVID-19 outbreak. Thus this paper proposes a short-term load forecasting method based on machine learning, silent index and rolling anxiety index. First, Google mobility data and epidemic data are used to construct the silent index and rolling anxiety index to quantify the impact of the economic and epidemic developments on the power load. Then, the maximal information coefficient is used to analyze the strong correlation factors of power load during the epidemic and introduce epidemic load correlation characteristics. Finally, meteorological data, historical load and the constructed epidemic correlation features are combined as the input variables of the prediction model, and the prediction algorithm is analyzed by multiple machine learning models. The results show that the load forecasting model with the introduction of the epidemic correlation features can effectively improve the accuracy of load forecasting during the epidemic.

This work is supported by the National Natural Science Foundation of China (No. 61672032).

Key words: load forecasting; COVID-19 outbreak; machine learning; silent index; anxiety index

0 引言

2020年2月底, 新冠肺炎在欧洲演变为以意大利为中心的疫情大爆发, 全球电力系统在此次突发性事件中均受到了不同程度的冲击。由于封锁措施的推出, 各国经济活动遭到严重破坏, 能源需求持续下降^[1]。全面封锁导致了法国、西班牙、英国、

印度、意大利以及美国西北部地区日电力需求至少减少了15%。

电力负荷需求的异常变化给负荷预测增加了难度。以往电力负荷的预测通常选取历史负荷值、日历信息和气象信息作为输入变量^[2-7], 但在疫情爆发期间, 电力系统受更多不确定性因素影响, 采用常规影响因素无法充分考虑电力负荷与社会性因素之间的复杂关系, 电力负荷预测精度有所欠缺^[8]。因此考虑引入反映疫情和经济活动情况的特征, 帮助模型深入学习疫情传播对电力系统所造成的影响。

基金项目: 国家自然科学基金项目资助(61672032); 安徽省科技重大专项资助(18030901018)

目前电力负荷预测的研究方法主要包括基于传统统计学的时间序列模型和基于机器学习的模型两大类。其中基于统计学的预测模型主要包括指数平滑模型(exponential smoothing model, ESM)^[9]、线性回归(linear regression, LR)模型^[10]和自回归移动平均(auto regressive moving average, ARMA)模型^[11]等。该类预测算法相对来说简单、成熟,训练速度快,人为干预性低,但无法捕捉历史负荷中的非线性特征,难以对复杂环境影响下的电力负荷进行建模,且对时间序列的平稳性有较高的要求。而机器学习模型^[12-16]相较于统计学模型优势在于其出色的非线性映射能力。文献[13]分析了传统气象因素处理方法在负荷预测中的不足之处,并提出基于费歇信息的气象因素建模策略,在支持向量机(support vector machine, SVM)预测模型中引入费歇信息对气象因素进行建模,解决了气象因素的累积效应以及气象因素变化造成的负荷滞后效应,提高了预测精度;文献[14]利用粒子群优化(particle swarm optimization, PSO)算法改良循环神经网络(recurrent neural networks, RNN)来解决梯度消失、梯度爆炸等问题,并整合了历史负荷、温度、日期等因素进行短期负荷预测;文献[15]提出一种基于卷积神经网络(convolutional neural networks, CNN)和门控循环单元(gated recurrent unit, GRU)混合神经网络的负荷预测方法,构建了日历因素、气象因素和相似日负荷的特征集,利用 CNN 网络提取负荷与特征在高维空间中的联系,并将得到的高维特征向量输入 GRU 网络进行训练,提升了对负荷特征的挖掘能力。

以上方法在负荷预测中采用了常用的日期、气象等负荷相关因素,但均未考虑经济以及其他因素的影响。在新冠疫情大爆发的背景下,电力负荷受到明显的冲击,传统预测方法势必会带来众多误差。文献[16]提出了一种基于可计及经济和气象因素的中期电力负荷预测方法,利用多种月度经济指标挖掘影响电量消费的信息,由于采用的是月度经济指标作为影响因素,无法对高时间分辨率要求的短期负荷进行预测。

因此,本文提出一种基于机器学习与疫情关联特征的短期负荷预测方法。首先采用最大信息系数(maximal information coefficient, MIC)分析不同特征与电力负荷之间的相关性。MIC 可以兼顾挖掘变量之间线性和非线性的相关性,确定静默指数、疫情滚动焦虑指数与电力负荷之间存在较强的相关性。然后将预处理过后的指数数据与日历数据、气象数据等相关特征合并作为负荷特征数据输入各机器学习模型进行训练。实验结果表明,与常规预测

模型相比,本文方法能够有效地提高疫情时期的负荷预测精度。

1 疫情关联特征构建

国家电力负荷需求与国民经济活动密切相关,比如意大利作为欧洲受疫情影响最严重的国家之一,其封锁时间从 2020 年 3 月 10 日到 4 月 3 日,范围扩大到整个国家,工业和商业部分的消费用电水平大幅下降,居民住宅的用电虽有所增加但难以弥补工商业的巨大下降。因此疫情期间的电力负荷预测有必要引入与电力负荷消耗密切关联的影响因素来捕捉其复杂的波动趋势,疫情对国家电力负荷造成的影响是时变的,而静默指数作为经济活动的代理指标可以弥补疫情数据的滞后性。

1.1 静默指数构建

受初期新冠疫情的严重影响,全球范围内的卫生健康、社会经济情况持续下降。各国纷纷采取紧急封禁措施,停工停产、居家隔离等不仅导致了经济层面数据的下滑,同时也造成了电力负荷的剧烈波动,一些研究开始针对疫情传播的特点,评估对国家经济活动造成的严重后果。文献[17]通过谷歌流动性指数(Google mobility index, GMI) I_{GMI} 构建了静默指数(silent index, SI) I_{SI} , 量化了地区流动性、新冠疫情、政府政策和经济发展之间的关系。

根据 5 种不同场所(商店、公园、交通站、娱乐区、工作区)的 I_{GMI} 构建 I_{SI} , 因为这些地区主要反映了包括城市活力、经济表现和流行病预防措施水平不同的城市功能^[17]。由于疫情的冲击对国民生活、生产带来了巨大的改变, I_{SI} 从侧面反映了电力负荷不寻常的波动。

$$I_{SI}(t) = -\frac{1}{5} \sum_{i=1}^5 I_{GMI}^i(t) \quad (1)$$

式中: i 表示不同的分类场所; t 表示该数据发生的时刻。

1.2 疫情滚动焦虑指数构建

新冠病例的快速增多,民众对疫情产生的焦虑也逐渐升高。新冠疫情每日攀升的数据一定程度上反映了该阶段疫情的紧迫性和生产活动的中断程度。针对新冠病毒潜伏期的特点,文献[18]根据每日报告的确诊病例数和每日死亡数构建了新冠疫情滚动焦虑指数(rolling anxiety index, RAI) I_{RAI} 。本文根据该指数,构建出应用于意大利短期电力负荷预测(short term load forecasting, STLF)的焦虑指数。

$$I_{RAI}(t) = 0.5 \times \left[\frac{\sum_{k=1}^{14} C_{t-14+k}}{\sum_{k=0}^{13} C_{t-14+k}} + \frac{\sum_{k=1}^{14} D_{t-14+k}}{\sum_{k=0}^{13} D_{t-14+k}} \right] \quad (2)$$

式中: $\sum_{k=1}^{14} C_{t-14+k}$ 和 $\sum_{k=1}^{14} D_{t-14+k}$ 分别表示包括第 t 天在内的 14 天潜伏期报告的总确诊数和总死亡数; $\sum_{k=0}^{13} C_{t-14+k}$ 和 $\sum_{k=0}^{13} D_{t-14+k}$ 分别表示前 14 天潜伏期报告的总确诊数和总死亡数。

1.3 电力负荷与疫情关联特征可视化分析

2020 年意大利能源需求持续下降, 1 月至 4 月与 2019 年同期相比下降了 7.5%。疫情关联特征在一定程度上反映了电力负荷的变化趋势。根据 SI 和 RAI 的公式构建疫情关联特征数据, 2 月 24 日至 4 月 26 日期间的电力负荷状况如图 1 所示。由图 1 可知, 随疫情的逐渐发展 RAI 呈现出持续下降的趋势, 且最后在低处趋于平稳; 而随社会活动、经济情况的下降 SI 逐渐上升, 在高位趋于平稳, 二者曲线突变的时间段与电力负荷出现突降的时间段基本吻合。

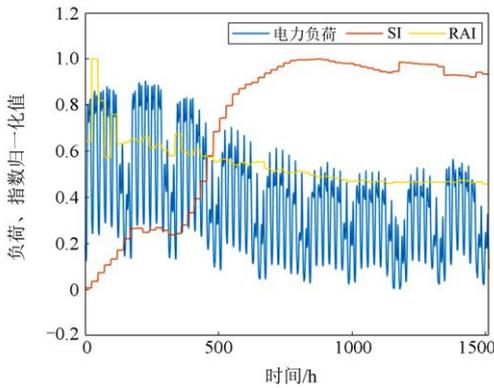


图 1 电力负荷、SI 和 RAI 曲线

Fig. 1 Load, SI and RAI curves

2 疫情关联特征与电力负荷相关性分析

2.1 最大信息系数

MIC 是 D. N. Reshef 等^[19]在 2011 年提出的一种基于互信息(mutual information, MI)的关联性分析算法, 该方法不仅适用于变量之间线性与非线性关系的度量, 更为重要的是可以研究变量间的非函数依赖关系^[20]。电力负荷数据与特征变量数据之间的相关性越强, 则 MIC 值越高, 反之越低。MIC 的具体计算步骤包括 MI 值 $f_{MI}(\mathbf{X}; \mathbf{Y})$ 的计算和网格划分。

$$f_{MI}(\mathbf{X}; \mathbf{Y}) = \sum_{y \in \mathbf{Y}} \sum_{x \in \mathbf{X}} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (3)$$

式中: 变量 $\mathbf{X} = \{x_i, i = 0, 1, 2, L, n\}$ 和变量 $\mathbf{Y} = \{y_i, i = 0, 1, 2, L, n\}$ 分别表示各时刻的特征值和对应的负荷值; $p(x)$ 和 $p(y)$ 分别是 \mathbf{X} 和 \mathbf{Y} 的概率密度; $p(x, y)$ 是 \mathbf{X} 和 \mathbf{Y} 的联合概率密度。

定义一个有限有序对的集合 D 和一个 $w \times z$ 的网格 G , 即将 \mathbf{X} 和 \mathbf{Y} 划分为 w 和 z 份; 求出网格 G 中划分的所有单元格的互信息 $f_{MI}(D|G)$, 并获得所有划分方式中的最大互信息值为

$$f_{MI^*}(D, w, z) = \max f_{MI}(D|G) \quad (4)$$

式中, $f_{MI}(D|G)$ 表示集合 D 在网格 G 下的 MI 值。

对使用不同划分方式得到的最大 MI 值逐一比较后得到负荷值和分析特征值的最大信息系数为

$$f_{MIC}(D) = \max_{wz < B(n)} \left\{ \frac{f_{MI^*}(D, w, z)}{\log_2 \min(w, z)} \right\} \quad (5)$$

式中: $f_{MIC}(D)$ 实质为归一化的最大互信息值, 取值范围为 $[0, 1]$; $B(n)$ 表示搜索的最大网格面积。

2.2 相关性分析

大量公共设施、工业设施关闭以及国家主要经济活动的减少, 改变了以往电力负荷的消费模式, 比较直观的反映就是日电力负荷曲线不同于以往的规律性。从图 2 可以看到: 在一天的前半部分由于缺少了往日的通勤高峰, 电力负荷缓慢攀升, 峰值电力负荷消耗曲线比较平坦; 后半部分的电力负荷曲线高峰仍在, 但已明显低于同期水平。

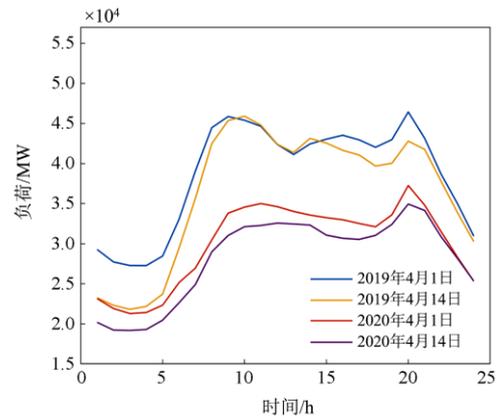


图 2 意大利 2020 年 4 月 1 日和 14 日与上一年负荷对比

Fig. 2 Load of April 1 and 14, 2020 in Italy compared to the load of the previous year

依靠传统负荷相关特征提高负荷预测精度的手段在疫情流行期间表现不佳, 因为这些特征无法捕捉到重大社会事件造成的社会经济活动中断、电力需求下降等重要信息。因此考虑分析与电力负荷波动变化密切相关的经济因素、疫情因素变得尤为重要。

选取 2020 年 1 月 1 日—2020 年 4 月 26 日期间几个欧洲国家的疫情、流动性数据来验证疫情关联特征与电力负荷之间的关联程度。图 3 分析了气象因素、SI、RAI 与电力负荷的 MIC 值。可以明显看

到温、湿度作为负荷预测常用的气象特征，与电力负荷的 MIC 值都达到了 0.6 以上，表明这些气象特征是负荷预测不可忽视的重要因素；而该时期与电力负荷关联性最大的两个特征是 SI 和 RAI，均高于常规的气象因素，意大利、德国和法国的 SI、RAI 与电力负荷序列的 MIC 值均在 0.65 以上，具有较强的相关性，这也反映了疫情时期的电力负荷受到了外部因素较大的影响。

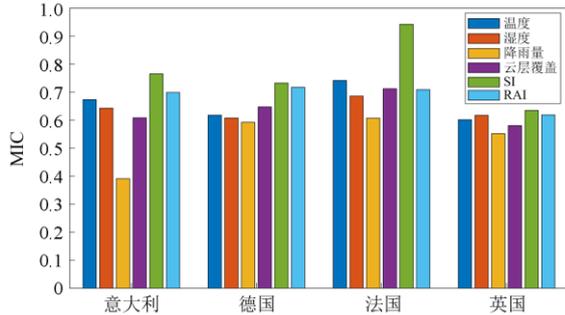


图 3 欧洲国家电力负荷相关因素 MIC 分析

Fig. 3 MIC analysis of power load related factors in European countries

3 基于机器学习的负荷预测模型

3.1 机器学习模型构建

(1) SVM 模型

文献[21]在统计学习理论上提出了 SVM 模型，该方法在解决小样本、非线性、高维度和局部极值的问题上有较好的表现，SVM 的思路是用一个非线性函数将样本集映射到高维特征空间^[22-23]，然后在高维空间中对目标数据进行线性回归。假设给定训练样本集为 $\{(x_i, y_i)\} (i=1, 2, 3, L, m)$ ，其中 x_i 为负荷影响因素， y_i 为负荷数据，得到高维空间线性回归函数为

$$f(x) = \mathbf{w}^T \varphi(x) + b \quad (6)$$

式中： \mathbf{w}^T 为权值向量； $\varphi(x)$ 为非线性映射函数； b 为实数偏置值。

(2) 注意力机制

深度学习中的注意力机制(attention mechanism)学习了人脑的注意力机制，着重处理输入的关键信息，从而有效地获取神经网络运算所需的特征信息，并将学习到的权重系数动态分配给模型来降低非关键信息的影响力。

在时序预测中，注意力机制能够更好地捕捉重点时间特征信息来提高负荷预测精度^[24]。图 4 为注意力机制结构图。

其中： h_t 为神经网络隐藏层隐藏状态； e_t 为注意力权重向量； α_t 为不同时刻输入序列的关注概

率； c_t 为注意力层输出； s_{t-1} 为 $t-1$ 时刻隐藏层输出。

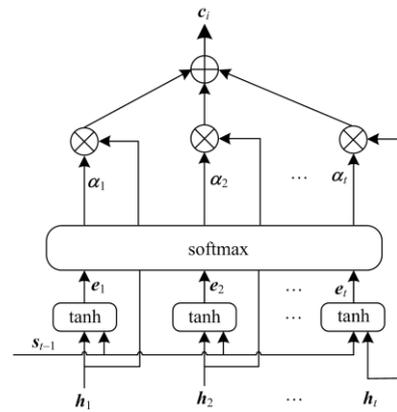


图 4 注意力机制结构

Fig. 4 Structure of attention mechanism

(3) 循环神经网络模型

RNN 凭借其独特的记忆功能可以有效地处理时间序列数据。RNN 网络结构分为输入、输出和隐藏三部分，每个隐藏层按照时间顺序连接。模型训练时，隐藏层的环路设计可以兼顾学习当前时刻状态以及上一时刻的隐藏状态信息，因此 RNN 可以实现任意时刻与之前时间序列的处理，但存在输入长时间序列会发生梯度消失的缺陷。

GRU 与长短时记忆(long short-term memory, LSTM)神经网络一样^[25-27]，都是由 RNN 改进而来，通过门结构的设计可以任意控制输入数据中信息的保留或者丢弃，从而实现在较长时间序列中保存信息的功能，解决了 RNN 神经网络在处理长时间序列时出现的梯度消失和梯度爆炸问题。GRU 结构如图 5 所示。

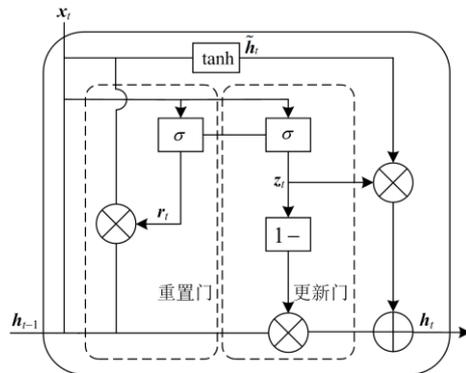


图 5 GRU 结构

Fig. 5 Structure of GRU

图 5 中， r_t 和 z_t 为 t 时刻 GRU 网络的重置门和更新门， \tilde{h}_t 是 t 时刻输入的候选隐藏状态， σ 和 \tanh 分别是激活函数 Sigmoid、tanh。

3.2 机器学习模型负荷预测流程

本文提出的疫情负荷预测流程如图 6 所示, 数据预处理阶段对本次实验所需的负荷数据以及特征数据进行异常值修正、缺失值填补。使用 MaxMin 的方法将数据归一化处理至区间[0, 1]内, 归一化公式为

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

式中: x 、 x_n 分别为归一化前后的数据值; x_{\max} 、 x_{\min} 分别为处理数据中的最大值和最小值。

负荷数据通过机器学习和深度学习模型进行负荷预测后, 预测值将通过反归一化处理得到最终负荷预测值。

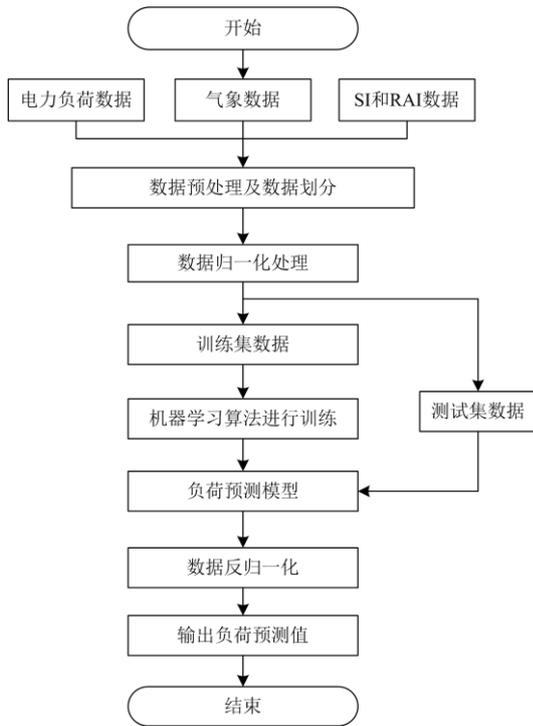


图 6 负荷预测流程图

Fig. 6 Flow chart of load prediction

4 预测实验及算例分析

4.1 实验数据选择

选取意大利电网公司 Terna^[28]2020 年 1 月 1 日至 2020 年 4 月 26 日期间的国家电力负荷数据作为疫情期间研究对象, 电力负荷数据采样频率为 30 min, 每天 48 个采样点, 并在世界天气^[29]选取该地区气象数据、同一时期世卫疫情数据^[30]和谷歌流动性数据^[31]。实验输入的负荷影响特征如表 1 所示, 其中电力负荷数据以及每个特征数据均为 5616 个样本。使用前 110 天的数据训练模型参数, 测试集为

最后一周共 336 个负荷数据样本, 选取待预测时刻点前 8 个采样点的所有负荷数据及特征值数据作为下一预测点的输入。

表 1 负荷影响特征

Table 1 Influencing features of load

特征	维度	说明
W _e	4	温、湿度、降雨量以及云层覆盖度
W _k	7	日类型, 格式为{1,0,0,0,0,0}
H _r	48	时刻类型, 同日类型格式
H _d	1	节假日类型, 按{0,1}格式编码
SI	1	流动性数据构建的静默指数
RAI	1	疫情数据构建的滚动焦虑指数

4.2 预测精度评价指标

模型预测结果的评估指标采用平均绝对百分比误差(mean absolute percentage error, MAPE) η_{MAPE} 和均方根误差(root mean square error, RMSE) η_{RMSE} , 计算公式分别为

$$\eta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{|Y_i|} \times 100\% \quad (8)$$

$$\eta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|^2} \quad (9)$$

式中: n 为预测结果个数; Y_i 为第 i 个样本的实际值; \hat{Y}_i 为第 i 个样本的预测值。

4.3 算例分析

对测试集 336 个数据进行滚动预测, 并构建 SVM、RNN、GRU 及 Attention 与 GRU 结合模型(记为 AGRU) 4 组对比模型, 验证加入疫情关联特征对预测精度提高的有效性。其中 SVM 模型选取径向基函数作为核函数, 惩罚参数设置为 1.0; RNN 网络模型由 1 层 SimpleRNN 单元组成, RNN 神经元个数为 64, 激活函数为 Sigmoid, 并使用 RMSProp 优化函数; AGRU 网络参数设置为 2 层 GRU 单元, 分别包含 64 个神经元, 激活函数为 tanh, 采用 RMSProp 优化函数, 损失函数设置为 mse, 单一 GRU 网络模型去掉注意力机制, 其余参数与 AGRU 网络一致。

对周四到周日进行负荷预测对比分析, 未引入和引入疫情关联特征负荷预测对比分别如图 7 和图 8 所示。由图 7 可以看到, 在未引入疫情关联特征时, 由于疫情期间的电力系统波动较大导致负荷预测复杂度增加, 各预测模型在周四到周日的预测结果与实际值偏差较大。在引入关联特征后, 图 8 各预测模型在周四、周五两日的负荷预测上均有明显改善, 其中 AGRU 模型可以更高效地捕捉电力负荷

与时序特征之间的时序依赖性，其预测曲线更好地拟合了真实值的变化。

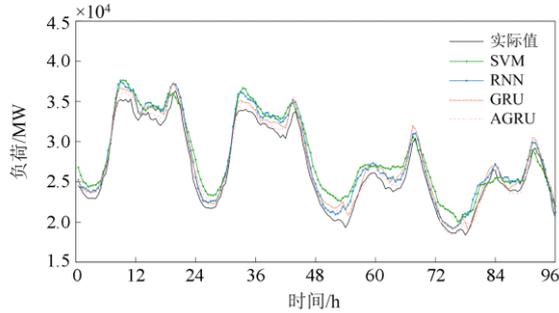


图 7 未引入疫情关联特征负荷预测对比
Fig. 7 Comparison of load prediction without correlation features

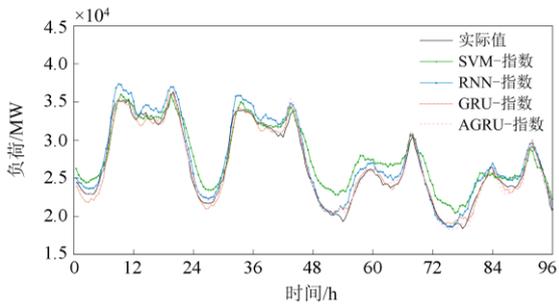


图 8 引入疫情关联特征负荷预测对比

Fig. 8 Comparison of load prediction with correlation features

意大利电力负荷以周为周期规律性地变化，其中工作日、休息日的电力负荷曲线差异比较明显，将周五、周六作为工作日和休息日两种日类型进行 MAPE 和 RMSE 分析，结果如表 2 所示。由表 2 可知，采用本文提出的引入疫情关联特征的负荷预测方法后，预测效果最好的 AGRU 模型在工作日和休息日的预测中均有效提高了负荷预测精度，预测误差明显降低。

对周五、周六进行预测误差对比分析，如图 9 所示，引入疫情关联特征能够帮助模型更有效地学

习负荷在工作日和休息日的变化规律，大幅度地降低了疫情时期的预测误差。

表 2 日类型预测结果对比

Table 2 Comparison of day type prediction results

方法	工作日		休息日	
	MAPE/%	RMSE/MW	MAPE/%	RMSE/MW
AGRU	3.31	775.24	1.69	509.72
AGRU-指数	1.16	301.20	1.29	331.06

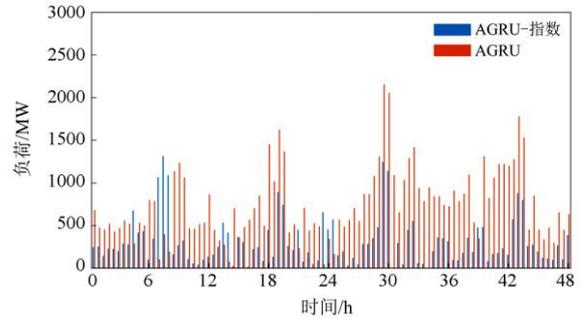


图 9 预测结果误差对比

Fig. 9 Error comparison of prediction results

分别计算 4 种机器学习模型在测试集上的 MAPE 和 RMSE，其中常规方法基于原始数据进行预测，本文方法为引入疫情关联特征的负荷预测，实验结果如表 3 所示。在不考虑疫情关联特征情况下，受模型自身特性影响，SVM 和 RNN 的预测效果较差，但在引入疫情关联特征后，4 种模型预测精度均有明显优化。在引入疫情关联特征后 SVM、RNN、GRU 和 AGRU 预测精度与常规方法相比分别提高了 10.29%、24.42%、19.92%和 20.59%，而与单一 GRU 网络模型相比较，加入注意力机制的 GRU 网络预测精度提高了 11.27%。并且在 RMSE 上可以看到引入疫情关联特征模型的预测误差显著下降：SVM、RNN、GRU 和 AGRU 的 RMSE 分别降低了 8.9%、22.91%、14.80%和 16.35%。实验结果表明，引入疫情关联特征对 4 种机器学习模型的预测精度都有较大的改善效果。

表 3 不同模型预测结果对比

Table 3 Comparison of prediction results of different models

方法	MAPE/%				RMSE/MW			
	SVM	RNN	GRU	AGRU	SVM	RNN	GRU	AGRU
常规方法	6.12	3.89	2.66	2.38	1835.94	1229.06	840.19	791.23
本文方法	5.49	2.94	2.13	1.89	1672.56	947.51	715.80	661.83

5 结论

本文基于疫情大流行对电力系统造成严重冲击的背景下，深入研究高时间分辨率的静默指数和疫

情滚动焦虑指数对提高负荷预测精度的作用。提出一种引入疫情关联特征的短期负荷预测方法，采用反映国民经济活动情况的静默指数和反映疫情严重

程度的滚动焦虑指数作为疫情发生时期负荷预测的特殊影响因素; 利用 MIC 分析气象特征、疫情关联特征与待预测负荷之间的相关性。分析结果与实验数据表明, 疫情关联特征与电力负荷之间具有强相关性; 同时结合多种机器学习模型进行对比预测, 验证了引入疫情关联特征对模型预测精度提高的普适性。实验结果表明, 引入疫情关联特征的负荷预测模型能够有效地提高疫情期间负荷预测精度。

参考文献

- [1] GHIANI E, GALICI M, MUREDDU M, et al. Impact on electricity consumption and market pricing of energy and ancillary services during pandemic of COVID-19 in Italy[J]. *Energies*, 2020, 13(13): 3357.
- [2] 靳冰洁, 林勇, 罗澍忻, 等. 基于负荷特性聚类及 Elastic Net 分析的短期负荷预测方法[J]. *中国电力*, 2020, 53(9): 221-228.
JIN Bingjie, LIN Yong, LUO Shuxin, et al. A short-term load forecasting method based on load curve clustering and Elastic Net analysis[J]. *Electric Power*, 2020, 53(9): 221-228.
- [3] 赵会茹, 赵一航, 郭森. 基于互补集合经验模态分解和长短期记忆神经网络的短期电力负荷预测[J]. *中国电力*, 2020, 53(6): 48-55.
ZHAO Huiru, ZHAO Yihang, GUO Sen. Short-term load forecasting based on complementary ensemble empirical mode decomposition and long short-term memory[J]. *Electric Power*, 2020, 53(6): 48-55.
- [4] 王永伟, 李新龙, 田斐, 等. 基于人群搜索算法的电网短期用电负荷预测研究[J]. *电网与清洁能源*, 2020, 36(12): 35-40.
WANG Yongwei, LI Xinlong, TIAN Fei, et al. Research on short-term electric load forecasting of power grid based on crowd search algorithms[J]. *Power System and Clean Energy*, 2020, 36(12): 35-40.
- [5] 丁学辉, 许海林, 罗颖婷, 等. 基于 CNN 特征选择与 QRGRU 的电力负荷概率密度预测方法[J]. *电力信息与通信技术*, 2021, 19(6): 32-38.
DING Xuehui, XU Hailin, LUO Yingting, et al. Power load probability density prediction method based on CNN feature selection and QRGRU[J]. *Electric Power Information and Communication Technology*, 2021, 19(6): 32-38.
- [6] 李正浩, 李孟凡. 基于深度学习的智能型负荷预测方法的研究[J]. *智慧电力*, 2020, 48(10): 78-85, 112.
LI Zhenghao, LI Mengfan. Smart load forecasting method based on deep learning[J]. *Smart Power*, 2020, 48(10): 78-85, 112.
- [7] 潘良军, 王楷, 赵宏炎, 等. 基于春节影响时期分析的中期负荷智能预测[J]. *智慧电力*, 2020, 48(9): 75-80, 117.
PAN Liangjun, WANG Kai, ZHAO Hongyan, et al. Mid-term load intelligent prediction based on the analysis of influence period of Spring Festival[J]. *Smart Power*, 2020, 48(9): 75-80, 117.
- [8] 张旭, 刘文君, 王建渊, 等. 新冠疫情期间陕西学校暑期短期电力负荷大数据分析[J]. *电网与清洁能源*, 2020, 36(11): 100-105.
ZHANG Xu, LIU Wenjun, WANG Jianyuan, et al. A short-term summer power load analysis of schools during summer holidays after COVID-19[J]. *Power System and Clean Energy*, 2020, 36(11): 100-105.
- [9] 叶宗斌, 周步祥, 林楠, 等. 基于等维新息指数平滑法模型的中长期负荷预测[J]. *电力系统保护与控制*, 2012, 40(18): 47-51.
YE Zongbin, ZHOU Buxiang, LIN Nan, et al. Medium/long term load forecast of exponential smoothing method based on information and equal dimensional operators[J]. *Power System Protection and Control*, 2012, 40(18): 47-51.
- [10] 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 power load forecasting based on EEMD-GRU-MLR[J]. *Power System Technology*, 2020, 44(2): 593-602.
- [11] 田波, 朴在林, 郭丹, 等. 基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型[J]. *电力系统保护与控制*, 2017, 45(4): 72-79.
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SE-ARMA[J]. *Power System Protection and Control*, 2017, 45(4): 72-79.
- [12] MADHIARASAN M. Accurate prediction of different forecast horizons wind speed using a recursive radial basis function neural network[J]. *Protection and Control of Modern Power Systems*, 2020, 5(3): 230-238.
- [13] 蔡舒平, 张保会, 汤大海, 等. 短期负荷预测中气象因素处理的费歇信息方法[J]. *电力自动化设备*, 2020, 40(3): 141-146.
CAI Shuping, ZHANG Baohui, TANG Dahai, et al. Fisher information method for processing weather factors in short-term load forecasting[J]. *Electric Power Automation Equipment*, 2020, 40(3): 141-146.

- [14] 程焕新, 黄震. 基于改进 PSO 优化 RNN 的短期电力负荷预测模型[J]. 电子测量技术, 2019, 42(20): 94-98.
CHENG Huanxin, HUANG Zhen. Short-term electric load forecasting model based on improved PSO optimized RNN[J]. Electronic Measurement Technology, 2019, 42(20): 94-98.
- [15] 姚程文, 杨苹, 刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
YAO Chengwen, YANG Ping, LIU Zejian. Load forecasting method based on CNN-GRU hybrid neural network[J]. Power System Technology, 2020, 44(9): 3416-3424.
- [16] 刘俊, 赵宏炎, 刘嘉诚, 等. 基于协整-格兰杰因果检验和季节分解的中期负荷预测[J]. 电力系统自动化, 2019, 43(1): 73-80.
LIU Jun, ZHAO Hongyan, LIU Jiacheng, et al. Medium-term load forecasting based on cointegration-Granger causality test and seasonal decomposition[J]. Automation of Electric Power Systems, 2019, 43(1): 73-80.
- [17] WANG S, TONG Y, FAN Y, et al. Observing the silent world under COVID-19 with a comprehensive impact analysis based on human mobility[J]. Scientific Reports, 2021, 11(1): 1-12.
- [18] YU X L, XIAO K T, LIU J P. Dynamic co-movements of COVID-19 pandemic anxieties and stock market returns[J]. Finance Research Letters, 2021, 102.
- [19] RESHEF D N, RESHEF Y A, FINUCANE H K, et al. Detecting novel associations in large datasets[J]. Science, 2011, 334: 1518-1524.
- [20] 程逸, 胡阳, 马素玲, 等. 基于 MIC-LSTM 与 CKDE 的风电机组机舱温度区间预测[J]. 智慧电力, 2020, 48(7): 16-23.
CHENG Yi, HU Yang, MA Suling, et al. Wind turbine nacelle temperature interval prediction based on MIC-LSTM and CKDE[J]. Smart Power, 2020, 48(7): 16-23.
- [21] VAPNIK V N. The nature of statistical learning theory[M]. New York: Springer, 1995.
- [22] 彭曙蓉, 黄士峻, 李彬, 等. 基于深度学习分位数回归模型的充电桩负荷预测[J]. 电力系统保护与控制, 2020, 48(2): 44-50.
PENG Shurong, HUANG Shijun, LI Bin, et al. Charging pile load prediction based on deep learning quantile regression model[J]. Power System Protection and Control, 2020, 48(2): 44-50.
- [23] 赵倩, 黄景涛. 基于 EMD-SA-SVR 的超短期风电功率预测研究[J]. 电力系统保护与控制, 2020, 48(4): 89-96.
ZHAO Qian, HUANG Jingtao. Research on ultra-short-term wind power prediction based on EMD-SA-SVR[J]. Power System Protection and Control, 2020, 48(4): 89-96.
- [24] 汪欣, 蔡旭, 李征. 合交叉局部异常因子和注意力机制的超短期风电功率预测方法[J]. 电力系统保护与控制, 2020, 48(23): 92-99.
WANG Xin, CAI Xu, LI Zheng. Ultra-short-term wind power forecasting method based on a cross LOF preprocessing algorithm and an attention mechanism[J]. Power System Protection and Control, 2020, 48(23): 92-99.
- [25] KONG W, DONG Z Y, JIA Y. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.
- [26] SHI H, XU M, LI R. Deep learning for household load forecasting — a novel pooling deep RNN[J]. IEEE Transactions on Smart Grid, 2019, 9(5): 5271-5280.
- [27] 谢谦, 董立红, 库向阳. 基于 Attention-GRU 的短期电价预测[J]. 电力系统保护与控制, 2020, 48(23): 154-160.
XIE Qian, DONG Lihong, SHE Xiangyang. Short-term electricity price forecasting based on Attention-GRU[J]. Power System Protection and Control, 2020, 48(23): 154-160.
- [28] Terna. Total load[EB/OL]. [2021-09-10]. <https://www.terna.it>.
- [29] World Weather Online. Historical weather[EB/OL]. [2021-09-10]. <https://www.worldweatheronline.com/hwd>.
- [30] EDEC. COVID-19 data[EB/OL]. [2021-09-11]. <https://www.edec.eropa.eu/en/COVID-19/data>.
- [31] Google. COVID-19 community mobility reports[EB/OL]. [2021-09-20]. <https://www.google.com/covid19/mobility>.

收稿日期: 2022-01-10; 修回日期: 2022-03-23

作者简介:

程志友(1972—), 男, 博士, 教授, 硕士生导师, 研究方向为电能质量分析、电力负荷预测; E-mail: czy@ahu.edu.cn

汪德胜(1996—), 男, 通信作者, 硕士研究生, 研究方向为电力负荷预测。E-mail: 1751355226@qq.com

(编辑 魏小丽)