

基于多维融合特征提取和深度学习网络的短期负荷预测方法

刘 旭

(南京三新供电服务有限公司浦口分公司, 江苏 南京 211899)

摘要: 传统的短期负荷预测方法未考虑节假日、用户端用电行为习惯等因素, 导致负荷预测精度不高。为此, 文章提出一种基于多维融合特征和深度学习网络的短期负荷预测优化方法, 采用Prophet算法提取不同时间变量的用电负荷特征分量, 结合天气数据进行基于注意力机制的融合特征重构, 并采用CNN-GRU模型对融合特征进行训练, 获得未来短期负荷预测值。实验结果表明, 该方法能够有效提高短期用电负荷的预测精度, 为电力系统后续调度工作提供支撑。

关键词: 短期负荷预测; 融合特征; Prophet算法; CNN; GRU

中图分类号: TM763

Short-term Load Forecasting Method Based on Multi-dimensional Feature Fusion and Deep Learning Network

LIU Xu

(Nanjing Sanxin Power Supply Service Co., Ltd. Pukou Branch, Jiangsu Nanjing 211899, China)

Abstract: Traditional short-term load forecasting methods do not consider factors such as holidays and users' electricity consumption habits, which result in low load forecasting accuracy. To address this issue, this paper proposes an optimized short-term load forecasting method based on multi-dimensional feature fusion and deep learning network. Firstly, the Prophet algorithm is used to extract load characteristic components from different time variables, and the fusion feature reconstruction based on the attention mechanism is carried out in combination with weather data. Then, a CNN-GRU model is used to train the fused features and obtains future short-term load forecasting values. Experimental results show that this method can effectively improve the forecasting accuracy of short-term load, which provides a support for the subsequent dispatching work of power system.

Keywords: short-term load forecasting; fusion features; Prophet algorithm; CNN; GRU

0 引言

在新型电力系统中, 随着新能源渗透率的不断提升以及产业结构的变化升级, 短期负荷预测对于发电资源的优化配置和运行成本的有效控制具有重要意义。短期负荷预测指的是从一天到一周内的用电负荷预测, 相较于超短期负荷预测, 准确的短期负荷预测能够帮助电力系统运营商更好地应对突发事件(如极端天气条件或突发社会事件)引起的负荷变化, 确保电力供应的连续性和安全性^[1-2]。

随着人工智能的发展以及现代计算机计算能力水平的提升, 基于人工神经网络的负荷预测方法逐步取得了广泛的应用^[3]。与基于统计方法的预测模

型相比, 基于人工神经网络的预测模型能够有效地捕捉非线性数据中的时间特征, 且取得了不错的预测效果^[4-6]。但是, 此类模型其预测精度受到模型的结构参数以及所训练数据的质量影响较大, 且容易出现过拟合或欠拟合的情况, 对于所训练的数据集的完整性以及采样率有一定的要求^[7]。

随着人工智能技术的深入发展, 基于深度学习模型的负荷预测方法近年来得到了广泛的应用。相较于人工神经网络, 深度学习所构建的模型拥有更多的隐藏层, 拥有强大的特征提取能力。文献[8]提出了一种基于深度学习的多时间尺度卷积模型与Transformer相结合的电力系统多节点负荷预测方法, 融合后的深度学习模型能够很好地提取数据的时间和空间特征, 对于多节点的电力系统负荷预测有一

收稿日期: 2025-01-17

定的提升效果。文献 [9] 通过图注意力网络和一维卷积神经网络，对区域负荷的时间和空间特征进行提取，能够进一步挖掘区域级负荷的空间依赖性，为模型的预测提供更为丰富的特征变量。文献 [10] 提出了一种基于 Spearman-GCN-GRU 的深度学习模型对，通过 Spearman 相关性系数统计不同节点负荷的相关性大小，然后通过 GCN 网络构建不同节点之间的空间相关性以及利用 GRU 挖掘数据的时间相关性。在短期负荷预测中，所需要考虑的特征量更为复杂，因此所采用的模型应具备更合理的特征提取能力。

此外，对于不同的气象数据以及日历数据，直接采用该数据作为负荷特征，达不到理想的预测效果，同时过多的特征会产生一定的特征冗余。针对该问题，文献 [11] 采用多维时域特征作为模型的输入进行预测，首先，构建了基于周期趋势分解算法的负荷特征分解模型，得到表征负荷趋势性、周期性和随机性的特征分量。文献 [12] 通过变分模态分解将负荷数据分解为一系列包含不同中心频率的子模态数据，并通过对该子模态数据进行聚类，以获得不同频率中心的特征量。文献 [13] 使用导数项，即向量值之间的差异数据作为模型的补充特征，以获取不同时间段负荷变化特征。上述特征作为补充特征虽然取得了一定的优化提升，但是没有综合考虑时间特征和天气特征等具体特征的影响权重；因此，对于短期负荷预测特征处理仍须进一步优化。

基于此，本文提出了一种基于多维融合特征和深度学习网络的短期负荷预测优化方法。首先，对历史用电负荷数据进行预处理，构建基于节假日、年份、季节、月份、星期、工作日和非工作日等数据标签。然后，采用 Prophet 算法对该数据集进行时间特征分量提取，获得与用电负荷相关的不同特征量，并采用该时间分量与天气特征进行融合重构，得到基于时间、天气的融合特征。最后，结合 CNN-GRU 模型对该融合特征进行训练，以此获得未来短时用电负荷数据。

1 时间、天气融合特征

1.1 基于 Prophet 算法的时间分量提取

相较于超短期负荷预测，短期用电负荷由于时间尺度相对较长，因此其用电负荷的大小受到用户

的用电行为习惯、节假日特征以及不同时间段的用电需求等时间特征的影响，并且不同时间特征分量对于用电影响的程度和大小也不相同；因此，想要提高短期用电负荷的预测精度，须增加不同的时间分量作为预测模型的特征量。

Prophet 算法是由 Facebook 公司开发的一种时间序列预测工具，用于处理具有强烈季节性的时间序列数据，并且对于缺失数据和趋势变化数据具有较强的鲁棒性。相较于传统的算法，Prophet 具有更简易的参数调整，同时允许用户根据不同的场景进行自适应参数调整。本文采用 Prophet 算法对原始用电负荷数据的不同时间分量进行提取，其中包括对趋势特征分量、节假日特征分量、星期特征分量和日特征分量进行提取，其计算表达式可以表示为：

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (1)$$

式中： $y(t)$ 为原始用电负荷； $g(t)$ 为趋势项，表示时间序列在非周期上的变化趋势； $s(t)$ 为周期项； $h(t)$ 为节假日项，表示时间序列中那些潜在的具有非固定周期的节假日对预测值造成的影响； $\varepsilon(t)$ 为误差项，表示模型预测到的波动。

在趋势项中，有 2 个重要的函数，一个是基于逻辑回归的（非线性增长）函数，另一个是基于分段线性函数的（线性增长）函数，其中基于逻辑回归的趋势项可以表示为：

$$g(t) = \frac{C(t)}{1 + \exp(-(k + a(t)^T \delta) \cdot (t - (m + a(t)^T \gamma)))} \quad (2)$$

式中： $C(t)$ 为承载量，它是随时间变化的函数，限定了所能增长的最大值； k 为增长率； m 为偏移量； $a(t)$ 为变点指标向量； δ 为速率调整向量，表示每个变点处的增长率变化； γ 为偏移调整向量，确保趋势连续。此外，基于分段线性函数的趋势项表达式为：

$$g(t) = (k + a(t)^T \delta) \cdot t + (m + a(t)^T \gamma) \quad (3)$$

由于负荷的短期预测数据属于非线性增长，因此采用基于逻辑回归来表示增长项。而对于周期项，Prophet 算法采用傅里叶级数来表示，其表达式为：

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi n t}{P}\right) + b_n \sin\left(\frac{2\pi n t}{P}\right) \right) \quad (4)$$

式中： P 为周期，以天为单位； N 为平滑系数 a_n 和

b_n 的个数; n 为平滑系数的序号。

节假日项表示为:

$$h(t) = Z(t)\kappa \quad (5)$$

式中: $Z(t)$ 为回归矩阵; κ 为节假日对应的先验变化参数。

1.2 基于注意力机制的融合特征重构

在获取 Prophet 算法提取的分量后, 结合相关天气数据进行融合特征的重构, 以优化后续神经网络学习。本文采用基于 GRU 计算单元的注意力机制与不同特征分量的时间序列进行重构, 其结构如图 1 所示。




图1 基于注意力机制的特征重构模型

GRU 中隐藏状态与不同属性之间的相似度得分是根据时间 $t-1$ 的隐藏状态 h_{t-1} 和当前时间步的候选集 $\tilde{h}_t$ 计算获得, 之后用 softmax 函数进行归一化。通过归一化的相似度得分最终获得新的特征序列。

设经过特征融合后, 其表达式为:

$$\mathbf{X}^k = (x_1^k, x_2^k, \dots, x_L^k) \in \mathbb{R}^L \quad (6)$$

式中: $\mathbf{X}^k$ 为具有 k 维的融合特征; L 为特征分量的时间长度。经过特征编码后的输入分量可以表示为:

$$\varepsilon_t^k = V_\varepsilon \tanh(W_{\varepsilon c} c_{t-q} + W_{\varepsilon h} h_{t-1} + b_t) \quad (7)$$

式中: ε_t^k 为时间步 t 的编码输入分量, 维度 k ; c_{t-q} 为在时间步 $t-q$ 的 GRU 单元状态; h_{t-1} 为时间步 $t-1$ 时的隐藏状态; V_ε 、 $W_{\varepsilon c}$ 、 $W_{\varepsilon h}$ 分别为基于 GRU 结构训练得到的参数; b_t 为 t 时刻偏置项。对不同特征分量权重系数可以表示为:

$$a_t^k = \frac{\exp(\varepsilon_t^k)}{\sum_{i=1}^M \exp(\varepsilon_t^i)} \quad (8)$$

式中: i 为样本的索引; M 为特征数量。经过注意

力机制重构后的特征分量可以表示为:

$$\tilde{x}_t = (a_t^1 x_t^1, a_t^2 x_t^2, \dots, a_t^n x_t^n)^T \quad (9)$$

本文所采用的基于时间、天气融合的天气特征构建过程如图 2 所示。




图2 基于注意力机制的特征重构模型

2 短期负荷预测模型的构建

基于上述方法所构建的融合特征, 既包含了不同时间特征分量又包含了重要的天气特征分量, 且不同特征分量都为时间序列。因此, 可以将该融合特征视为具有时间时序的三维特征, 因此, 本文采用基于 CNN-GRU 为基本结构单元的深度学习网络作为预测模型。

由于上文提到的特征重构既包含了不同时间特征分量又包含了重要的天气特征分量, 且不同特征分量都为时间序列; 因此, 可以将该融合特征视为具有时间时序的三维特征, 而 CNN 可以有效地提取三维空间特征。因此通过卷积操作, 可以捕捉不同特征分量之间的相关性。

GRU 则用于捕捉时间序列数据的时间依赖性和长期记忆。GRU 通过引入门控机制 (如更新门和重置门) 来减少梯度消失问题, 从而更有效地捕捉时间序列中的长期记忆。在负荷预测中, GRU 能够利用历史负荷数据中的时间依赖性, 提高预测的准确

性。通过 CNN-GRU 模型，可以将这些多维特征进行有效融合，并以此提高预测精度。

3 算例分析

本文采用江苏某地区负荷相关实测数据进行算例验证。其中负荷数据部分记录了该地区 2021—2023 年全年的用电负荷情况，且数据的采样率为每 15 min 一个采样点。天气数据包括该地区不同区域的地表温度、风速、风向、湿度等。

本文选取该地区全社会总负荷数据作为验证数据，其中数据的 80% 用于训练集，20% 用于测试集。本文采用均方根误差 (root mean square error, RMSE)，平均绝对百分比误差 (mean absolute percentage error, MAPE) 作为预测模型的评价指标。

3.1 时间特征提取结果

首先，使用 Prophet 算法对该区域的不同时间分量进行提取，其结果如图 3 所示。从图中可以看出，该地区的用电负荷中，趋势分量、节假日分量、星期分量以及日分量对于总体用电负荷的作用明显。基于该地区的时间特征，选取趋势特征分量、节假日特征分量、星期特征分量以及日特征分量作为其时间特征。

随后，便将 Prophet 算法提取到的分量，结合




图3 基于 Prophet 算法提取的时间特征分量

天气数据，进行基于 GRU 计算单元的注意力机制融合特征重构，以进行后续预测实验。

3.2 预测结果分析

在算例分析方面，本文通过消融实验的方法，对特征量和预测模型进行对比验证。其中在特征量方面，对比分析采用单一的时间特征分量、单一的天气特征分量，以及本文所推荐的融合特征分量进行对比。在预测模型方面，通过对比 LSTM、CNN-LSTM、GRU 以及本文所采用的 CNN-GRU 进行对比分析。其对比实验结果预测结果见图 4，误差情况见表 1。




图4 负荷预测结果图

表1 基于不同深度学习模型的消融实验结果

模型	RMSE/MW	MAPE/%
CNN-GRU	70.1	0.9
GRU	129.4	1.8
CNN-LSTM	121.5	1.6
LSTM	166.8	2.3

从图 4 中可以看出，CNN-GRU 模型的预测曲线与真实负荷曲线最为接近，整体预测效果最好。GRU 和 CNN-LSTM 模型在某些时段表现较好，但在细节上存在偏差。LSTM 模型在负荷峰值和谷值处的预测误差较大，整体预测效果较差。

综合图 4 的分析和误差分析结果，本文所采用的 CNN-GRU 模型表现最为出色，其预测曲线与真实负荷曲线最为接近，且 RMSE 值最小、MAPE 值最低，这表明该模型在预测负荷时不仅绝对误差小，相对误差也小，预测结果最为精准和稳定。

为了进一步验证本文所提出的基于融合特征对

于短期负荷预测的性能提升，该部分通过采用基于 Prophet 特征分量的时间特征、基于天气特征分量的天气特征以及采用时间-天气分量的融合特征进行对比分析，实验采用相同的模型参数和训练数据，其对比实验结果误差如表 2 所示。

表2 基于特征量分析的消融该实验结果

预测地区	RMSE/MW	MAPE/%
Prophet特征分量	81.4	1.2
天气特征分量	98.6	1.3
融合特征	69.1	0.9

通过分析上述实验结果可知，采用本文基于融合特征相较于单一时间特征分量或天气特征分量具有明显的优势。

4 结论

针对短期负荷特征变量复杂且难以定量获取不同特征分量的影响权重，以及预测模型难以提取复杂特征变量的相关性而导致预测效果不佳的问题，本文提出了一种基于多维融合特征和深度学习网络的短期负荷预测优化方法。该方法主要包含 2 个重要部分，时间、天气融合特征的构建和 CNN-GRU 预测模型的构建。在第一阶段，首先采用 Prophet 算法提取不同时间特征分量，结合天气数据进行基于注意力机制特征融合重构。在第二阶段，对传统的 GRU 模型进行改进，从而获得能够适应该融合特征的 CNN-GRU 预测模型，并对所构建的融合特征进行训练和预测。通过对比不同算法的负荷预测效果，验证了本文所提方法在短期负荷预测性能的提升及其模型的鲁棒性。

参考文献

[1] WANG C,WANG Y,DING Z,et al.A transformer-based method of multienergy load forecasting in integrated energy system[J]. *IEEE Transactions on Smart Grid*,2022,13(4):2703-2714.

[2] KHAN Z A,ULLAH A,HAQ I U,et al.Efficient short-term electricity load forecasting for effective energy management[J/OL]. *Sustainable Energy Technologies and Assessments*,2022,53: 102337.https://doi.org/10.1016/j.seta.2022.102337.

[3] HABEN S,ARORA S,GIASEMIDIS G,et al.Review of low voltage load forecasting: Methods,applications,and recommendations[J]. *Applied Energy*,2021,304:117798.

[4] 吕忠麟,顾洁,孟璐.基于耦合特征与多任务学习的综合能源

系统短期负荷预测[J]. *电力系统自动化*,2022,46(11):58-66.

[5] IMANI M.Electrical load-temperature CNN for residential load forecasting[J/OL]. *Energy*,2021,227:120480.https://doi.org/10.1016/j.energy.2021.120480.

[6] 郑豪丰,杨国华,康文军,等.基于多负荷特征和TCN-GRU神经网络的负荷预测[J]. *中国电力*,2022,55(11):142-148.

[7] 李丹,张远航,李黄强,等.基于精准气象数据的地区电网短期负荷智能预测系统设计[J]. *中国电力*,2022,55(7):128-133.

[8] 唐旭辰,潮铸,段秦尉,等.基于分层测量数据的高压变电站概率负荷预测方法[J]. *中国电力*,2023,56(8):143-150.

[9] YAZICI I,BEYCA O F,DELEN D.Deep-learning-based short-term electricity load forecasting:A real case application[J/OL]. *Engineering Applications of Artificial Intelligence*,2022,109: 104645.https://doi.org/10.1016/j.engappai.2021.104645.

[10] ESKANDARI H,IMANI M,MOGHADDAM M P.Convolutional and recurrent neural network based model for short-term load forecasting[J/OL]. *Electric Power Systems Research*,2021,195: 107173.https://doi.org/10.1016/j.epsr.2021.107173.

[11] CHEN Y,ZHANG D.Theory-guided deep-learning for electrical load forecasting (TgDLF) via ensemble long short-term memory[J/OL]. *Advances in Applied Energy*,2021,1:100004.https://doi.org/10.1016/j.adapen.2021.100004.

[12] 朱莉,夏禹,朱春强,等.基于CEEMDAN和频谱时间图卷积网络的电力负荷预测方法[J/OL]. *计算机工程*,1-11[2024-06-21].

[13] WANG Y,SUN S,CHEN X,et al.Short-term load forecasting of industrial customers based on SVM and XGBoost[J/OL]. *International Journal of Electrical Power & Energy Systems*, 2021,129:106830.https://doi.org/10.1016/j.ijepes.2021.106830.

作者简介

刘旭（1996—），男，本科，助理工程师，主要从事电网系统负荷调度运行与管理方面研究，E-mail: Xf_Yang123@163.com。（责任编辑：袁航）

资讯

南方电网引入 DeepSeek 大模型 完成“大瓦特”模型体系升级迭代

2025 年 2 月 12 日，南方电网人工智能创新平台完成了开源大模型 DeepSeek 的本地部署，电力大模型体系全面引入、适配了 DeepSeek 系列模型，并已正式开放使用。基于“大瓦特”模型体系开放技术路线，实现了自然语言（NLP）基础模型快速升级迭代为千亿参数级。同时，通过深度整合 DeepSeek 的算法优化等创新能力，将进一步提升南方电网各业务领域人工智能应用效果。

信息来源：中国南方电网有限责任公司