

考虑多变量建模的中期负荷预测模型

徐利美¹, 赵金², 李裕民³, 姚非⁴, 邢吉伟⁵, 续欣莹⁵

(1. 国网山西省电力公司, 太原 030000; 2. 国网山西省电力公司电力科学研究院, 太原 030001; 3. 山西电力交易中心有限公司, 太原 030021; 4. 国网太原供电公司, 太原 030012; 5. 太原理工大学电气与动力工程学院, 太原 030024)

摘要: 中期负荷预测受温度、节假日和周末等多个外部变量影响。长短时记忆网络(long short-term memory, LSTM)虽然在短期负荷预测中展现了强大的预测能力,但不能很好地建立起中期负荷预测多外部变量与预测负荷之间的相关关系。针对上述问题,提出了并行LSTM结构以及时间序列 N 节点树形LSTM(time-series N -node tree-LSTMs, t - N Tree-LSTMs)结构,通过引入分支结构和树形结构构建更细的特征粒度实现对中期负荷预测的建模。最后在2017年全球能源预测大赛数据集GEFCom2017上进行实验,结果表明在中期负荷预测过程中更细的特征粒度有利于获取更高精度的预测结果,验证了并行LSTM模型和 t - N Tree-LSTMs模型的有效性。

关键词: 中期负荷预测; 长短时记忆网络; 时间序列; 特征粒度; 多变量建模

Medium-Term Load Forecasting Model Considering Multivariate Modeling

XU Limei¹, ZHAO Jin², LI Yumin³, YAO Fei⁴, XING Jiwei⁵, XU Xinying⁵

(1. State Grid Shanxi Electric Power Company, Taiyuan 030000, China; 2. Electric Power Research Institute, State Grid Shanxi Electric Power Company, Taiyuan 030001, China; 3. Shanxi Electric Power Trading Center Co., Ltd., Taiyuan 030021, China; 4. State Grid Taiyuan Power Supply Company, Taiyuan 030012, China; 5. School of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: Medium-term load forecasting is influenced by multiple external variables such as temperature, holidays, and weekends. Although long short-term memory (LSTM) networks have shown strong predictive ability in short-term load forecasting, they cannot establish a good correlation between multiple external variables and predicted load in medium-term load forecasting. To address the above issues, parallel LSTM structures and time series N -node tree LSTM (t - N Tree LSTM) structures are proposed. By introducing branch structures and tree structures to construct finer feature granularity, modeling of medium-term load forecasting is achieved. Finally, experiments are conducted on the 2017 global energy forecasting competition dataset GEFCom2017, and the results show that finer feature granularity is beneficial for obtaining higher accuracy prediction results in the medium-term load forecasting process, verifying the effectiveness of the parallel LSTM model and t - N Tree LSTMs model.

Key words: medium-term load forecasting; LSTM; time series; feature granularity

0 引言

电力负荷预测能够为电力系统调度和安全评估提供依据,对指导电网规划建设和改善电力系统资源配置具有重要意义^[1-4]。基于时间序列的负荷预

测根据负荷数据历史变化情况对未来时间点一定时间周期内负荷的离散数据值进行预测。根据预测周期的长短可划分为超短期、短期、中期和长期负荷预测。超短期负荷预测的预测周期一般为几分钟,用于快速响应日内电力需求的波动^[5]。短期负荷预测的预测周期为几小时到几天,为电力系统经济运行以及电能质量调整提供决策参考^[6]。中期负荷预测的预测周期为几周到几个月,用于规划电网维护和电价调控^[7]。长期负荷预测的预测周期为一年至几年,为输电线路建设提供容量需求分析^[8]。目前

基金项目: 国家重点研发计划资助项目(2017YFA0700304);山西省自然科学基金面上项目(20210302123189)。

Foundation item: Supported by the National Key Research and Development Program of China (2017YFA0700304); the Natural Science Foundation of Shanxi Province (20210302123189)。

针对电力负荷预测的研究集中在超短期负荷和短期负荷,关于中期负荷预测的模型和算法较少。

基于时间序列的中期负荷预测要求模型具有较强的预测能力,能够高效精确地捕捉输出与输入之间的长期依赖,建立序列到序列的映射关系。传统的时间序列预测方法多建立在时间序列分解基础之上,如自回归移动平均模型(autoressive integrated moving average model, ARIMA)^[9]、Prophet 算法模型^[10]和局部加权回归周期趋势分解(seasonal and trend decomposition using local weight, STL)模型^[11]等。上述模型通过对时间序列进行乘性分解和加性分解,对分解后的序列进行统计学分析和处理,建立对应的回归模型,以此达到预测目的。但针对中期负荷预测,该类方法所建立的模型很多情况下并不能有效表征数据分布和变化趋势,模型阶次和有关参数选定较为困难^[12]。基于深度学习的预测模型以循环神经网络(recurrent neural network, RNN)为代表,通过构建序列到序列的自回归模型实现负荷预测^[13]。由于 RNN 模型训练过程存在梯度消失和无法捕获时间序列的长距离依赖等问题^[14],在进行负荷预测的场景中更多地采用长短期记忆网络(long short-term memory, LSTM)及其变体作为主干网络,并融入卷积神经网络或者 RNN 提取数据时序特征^[15-17]。但中期负荷预测影响因素复杂,涉及气候信息、时间周期信息和经济状况等外部变量^[18],LSTM 针对多变量建模过程需要建立外部变量间的权重分布,生成表征外部变量的隐向量,并建立负荷向量与隐向量之间的联系。这种方式过于强调从数据中学习规则,训练过程收敛困难。

在中期负荷预测的前沿研究中,文献[19]提出利用集成学习模型进行中期负荷预测,通过将特征与时间序列隔离建立更简单、更抗过拟合的模型。文献[20]提出了时间相关卷积模型和基于周期的长短时记忆网络模型,通过将原始长负载序列重构为多个短负荷序列,利用模型全局综合特征和短期局部相似特征挖掘负荷特征变化信息。文献[21]介绍了一种基于分位数回归的中期负荷预测组合概率密度模型,该模型结合随机森林回归、梯度提升决策树和支持向量机,并采用核密度估计方法实现负荷概率密度分布的估计。文献[22]设计了一种基于基因表达式编程的中期负荷预测算法,融合遗传算法

和遗传编程,采用进化算法的思想解决中期负荷预测问题。文献[23]设计了一种利用多层感知机、LSTM 和一维卷积核融合模型,提取局部变化趋势,建立短期和中期负荷预测的相同预测模式。

本文考虑到中期负荷预测影响因素较多,根据影响因素的不同对关联的外部变量进行划分,分别利用并行 LSTM 模型和时间序列 N 节点树形 LSTM (time-series n -node tree-LSTMs, t- N Tree-LSTMs) 模型建立多维变量下的中期负荷预测模型,最大程度地利用外部变量信息和负荷序列建立更细的特征粒度,从而提高了负荷预测的准确率。

1 中期负荷预测模型

1.1 并行 LSTM 模型

LSTM 网络是一种改进的循环神经网络,它通过引入门控制结构将短期记忆与长期记忆结合,在一定程度上解决了梯度消失的问题,建立了序列之间的长期依赖,增强了对长时间序列数据的建模能力。

LSTM 网络由重复的基本单元结构组成,每个单元结构包括遗忘门、输入门和输出门。计算公式如式(1)~(6)所示。

$$f_t = \sigma(W^{(f)} \cdot [h_{t-1}, x_t] + b^{(f)}) \quad (1)$$

$$i_t = \sigma(W^{(i)} \cdot [h_{t-1}, x_t] + b^{(i)}) \quad (2)$$

$$o_t = \sigma(W^{(o)} \cdot [h_{t-1}, x_t] + b^{(o)}) \quad (3)$$

$$u_t = \tanh(W^{(u)} \cdot [h_{t-1}, x_t] + b^{(u)}) \quad (4)$$

$$C_t = C_{t-1} \odot f_t + i_t \odot u_t \quad (5)$$

$$h_t = o_t \odot \tanh(u_t) \quad (6)$$

式中: f_t 、 i_t 、 o_t 分别为遗忘门、输入门和输出门向量; u_t 、 C_t 、 h_t 分别为当前时刻候选状态向量、状态向量和隐状态向量; $W^{(f)}$ 、 $W^{(i)}$ 、 $W^{(o)}$ 分别为遗忘门、输入门、输出门的权重矩阵, $b^{(f)}$ 、 $b^{(i)}$ 、 $b^{(o)}$ 分别为对应偏置; $W^{(u)}$ 为生成当前时刻候选状态 u_t 的权重矩阵; $b^{(u)}$ 为其偏置; σ 为 Sigmoid 函数; $\tanh$ 为双面正切函数; x_t 为当前时刻的模型输入。


并行 LSTM 中期负荷预测模型算法如图 1 所示,模型由 3 个 LSTM 网络分支并行构成,输入分别采用滑动窗口大小为 1、 l_{seq} 和 1 的外部影响因素在离散序列数据上滑动形成, t 时刻 3 个分支输入如下。

$$x_1 = [T_t^{\text{drybulb}}, T_t^{\text{dewpnt}}] \quad (7)$$

$$x_2 = [H_{t-l_{\text{seq}}+1}^{\text{load}}, H_{t-l_{\text{seq}}+2}^{\text{load}}, \dots, H_t^{\text{load}}] \quad (8)$$

$$\mathbf{x}_3 = [D_t^{\text{hourofday}}, D_t^{\text{dayofweek}}, D_t^{\text{monthofyear}}, D_t^{\text{holiday}}, D_t^{\text{weekend}}] \quad (9)$$

式中: $\mathbf{x}_1$ 为温度序列, 包含干球温度和露点温度两个变量; T_t^{drybulb} 为干球温度变量; T_t^{dewpnt} 为露点温度变量; $\mathbf{x}_2$ 为历史负荷序列; $\mathbf{x}_3$ 为日期序列; $H_{t-l_{\text{seq}}+1}^{\text{load}}, H_{t-l_{\text{seq}}+2}^{\text{load}}, H_t^{\text{load}}$ 为负荷序列特征变量; $D_t^{\text{hourofday}}, D_t^{\text{dayofweek}}, D_t^{\text{monthofyear}}, D_t^{\text{holiday}}, D_t^{\text{weekend}}$ 分别为小时、周、年、节假日以及周末或休息日特征变量。 $\mathbf{x}_1 \in \mathbb{R}^{1 \times 2}$, $\mathbf{x}_2 \in \mathbb{R}^{1 \times l_{\text{seq}}}$, $\mathbf{x}_3 \in \mathbb{R}^{1 \times 5}$, 3 个分支的输出结果通过线性组合得到最终模型输出。



注: V_{LSTM} 为 LSTM 的值; loss 为损失函数。

图 1 并行 LSTM 算法描述框图

Fig. 1 Parallel LSTM algorithm description block diagram

并行 LSTM 结构对比标准 LSTM 结构对多维变量的建模主要区分点在于: 标准 LSTM 结构输入为 $\mathbf{x} = [x_1, x_2, x_3]$ ($\mathbf{x} \in \mathbb{R}^{1 \times (7 + l_{\text{seq}})}$), 其中 l_{seq} 为历史负荷序列观测长度, 在输入模型过程中会将其转换为 $x_h \in \mathbb{R}^{1 \times S_{\text{hidden}}}$, S_{hidden} 表示 LSTM 隐层维度。模型实际

建立的是负荷与外部变量融合特征之间的关系, 外部变量之间通过权重矩阵相互联系, 但实际外部变量之间可能存在相互独立的部分, 部分变量之间权重联系并非必要。并行 LSTM 模型具有更细的特征粒度, 该模型将输入 $\mathbf{x} = [x_1, x_2, x_3]$ 分别转换为 x_{h1}, x_{h2}, x_{h3} , 并在一定程度上将外部变量进行隔离, 该方式下能够获取更细的特征粒度, 建立更优的负荷与外部变量之间的相关关系。

1.2 改进的 N-node Tree-LSTMs 模型

N-node tree LSTMs 模型最早用于解决自然语言处理中语法依存形成的语义信息中难以学习的问题^[24]。该模型通过设计多个遗忘门的结构选择性的从子节点抽取语义信息关联, 在根节点对语法依存进行建模。在中期负荷预测过程, 负荷与外部变量之间的建模与自然语言处理中的语义信息建模类似, 首先建立历史负荷与对应时刻外部变量之间的特征表示, 然后通过遗忘门结构对特征表示进行筛选, 然后通过输出门生成下一时刻负荷的隐状态向量。

参考 N-node Tree LSTMs 该模型将负荷作为根节点, 影响负荷的外部变量作为子节点, 将其应用于多变量中期负荷预测建模, 计算公式如下。

$$i_t = \sigma(W^{(i)}x_t + \sum_{\ell=1}^N U_{\ell}^{(i)}h_{\ell t} + b^{(i)}) \quad (10)$$

$$f_{kt} = \sigma(W^{(f)}x_t + \sum_{\ell=1}^N U_{k\ell}^{(f)}h_{\ell t} + b^{(f)}) \quad (11)$$

$$o_t = \sigma(W^{(o)}x_t + \sum_{\ell=1}^N U_{\ell}^{(o)}h_{\ell t} + b^{(o)}) \quad (12)$$

$$u_t = \sigma(W^{(u)}x_t + \sum_{\ell=1}^N U_{\ell}^{(u)}h_{\ell t} + b^{(u)}) \quad (13)$$

$$c_t = i_t \odot u_t + \sum_{\ell} f_{\ell t} \odot c_{\ell t} \quad (14)$$

$$h_t = o_t \odot \tanh(c_t) \quad (15)$$

式中: $k = 1, 2, \dots, N, k \neq \ell$; i_t, f_{kt}, o_t 分别为输入门、遗忘门和输出门向量; u_t, c_t 和 $h_{\ell t}$ ($1 \leq \ell \leq N$) 分别为当前时刻候选状态向量、状态向量和节点 ℓ 的隐状态向量; $W^{(i)}$ 和 $U_{\ell}^{(i)}, W^{(f)}$ 和 $U_{k\ell}^{(f)}, W^{(o)}$ 和 $U_{\ell}^{(o)}$ 分别为输入门、遗忘门、输出门的权重矩阵, $b^{(i)}, b^{(f)}$ 和 $b^{(o)}$ 为对应偏置; $W^{(u)}$ 和 $U_{\ell}^{(u)}$ 为生成当前时刻候选状态 u_t 的权重矩阵, $b^{(u)}$ 为其偏置; $c_{\ell t}$ ($1 \leq \ell \leq N$) 为外部变量节点 ℓ 的状态向量。在负荷预测中面向预测目标负荷的建模并不需要对外部




图3 负荷影响因素皮尔逊系数热力图

Fig. 3 Pearson coefficient heats map of load influencing factors




图4 露点温度与负荷变化散点拟合图

Fig. 4 Fitting plots of dew point temperatures and load variation scatter




图5 干球温度与负荷变化散点拟合图

Fig. 5 Dry bulb temperatures and load change scatter plots

间均存在非线性相关关系。

另外, 负荷数据表现为周期性变化, 如图6所示, 2003—2017年负荷呈现每年3个峰值和3个低谷的周期性变化, 并且数据的月周期变化明显, 需要在模型中引入与周期性变化关联的时间特征。




图6 负荷数据周期性变化图

Fig. 6 Periodic change plot of load data

中期负荷预测策略分为直接多步预测(direct multi-step forecasting, DMSF)和迭代多步预测(iterated multi-step forecasting, IMSF)。直接多步预测通过建立特征空间与输出空间的映射一次性获取全部预测长度范围的预测输出值, 虽然整个过程不存在迭代误差累积, 但该方式很难平衡全局预测误差与局部预测误差, 导致模型预测误差整体偏大。迭代多步预测由于自回归估计过程的存在因而预测方差较小, 但同时也不可避免地受到预测误差累积效应的影响^[26], 但引入外部变量建模可以在一定程度上减弱误差累积效果。基于上述考虑和分析, 本文中后期负荷预测模型基于迭代多步预测进行建模, 建模过程在模型中引入历史负荷作为参考, 外部气象因素选取干球温度和露点温度, 并引入日期信息作为静态协变量。

3 算例分析

3.1 数据集和实验环境

实验所用的数据集为2017年全球能源预测大赛数据集 GEFCom2017, 数据时间跨度从2003年3月到2017年4月, 根据第2节分析创建外部变量: $D_{\text{hourofday}}$ 、 $D_{\text{dayofweek}}$ 和 $D_{\text{monthofyear}}$, 同时数据中包含 D_{holiday} 和 D_{weekend} 以及干球温度和露点温度共7个外部变量, 考虑到负荷预测过程可能受历史负荷影响,

创建外部变量 H_{load} 。取 2003 年 3 月到 2016 年 12 月的数据构建训练集, 取 2017 年 1 月的数据构建验证集, 2017 年 2—4 月的数据构建测试集。为了分析模型效果, 将并行 LSTM 模型以及 t-N Tree-LSTMs 模型与标准 LSTM 模型对比, 在测试集上进行迭代多步预测, 验证模型效果。

本文所提模型的构建和训练在 pytorch1.11.0 框架下进行, 所用的硬件平台为 AMD R7 5 800 h 3.2 G CPU、16 G 内存、NVIDIA TITAN Xp GPU、12 G 显存。

3.2 数据归一化

为了消除量纲的影响, 对数据进行归一化处理, 其中将 $D_{\text{hourofday}}$ 、 $D_{\text{dayofweek}}$ 和 $D_{\text{monthofyear}}$ 日期特征归一化到 $[-0.5, 0.5]$, 将干球温度、露点温度和历史负荷按式(20)—(22)归一化到 $[0, 1]$ 。

$$T'_{\text{drybulb}} = \frac{T_{\text{drybulb}} - \min(T_{\text{drybulb}})}{\max(T_{\text{drybulb}}) - \min(T_{\text{drybulb}})} \quad (20)$$

$$T'_{\text{dewpnt}} = \frac{T_{\text{dewpnt}} - \min(T_{\text{dewpnt}})}{\max(T_{\text{dewpnt}}) - \min(T_{\text{dewpnt}})} \quad (21)$$

$$L'_{\text{history}} = \frac{L_{\text{history}} - \min(L_{\text{history}})}{\max(L_{\text{history}}) - \min(L_{\text{history}})} \quad (22)$$

式中: T_{drybulb} 、 T_{dewpnt} 、 L_{history} 分别为干球温度、露点温度和历史负荷; T'_{drybulb} 、 T'_{dewpnt} 、 L'_{history} 分别为干球温度、露点温度和历史负荷归一化后的值。

3.3 评价指标

本文使用平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)和可决系数作为模型的评价指标。计算公式如下。

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{\text{true}}(i) - y_{\text{pre}}(i)}{y_{\text{true}}} \right| \times 100\% \quad (23)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{true}}(i) - y_{\text{pre}}(i))^2} \quad (24)$$

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_{\text{true}}(i) - y_{\text{pre}}(i)| \quad (25)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{\text{true}}(i) - y_{\text{pre}}(i))^2}{\sum_{i=1}^n (y_{\text{true}}(i) - \bar{y}_{\text{true}}(i))^2} \quad (26)$$

式中: e_{MAPE} 、 e_{RMSE} 、 e_{MAE} 分别为平均绝对百分比误差值、均方根误差值和平均绝对误差值; n 为预测

点数量; $y_{\text{true}}(i)$ 为第 i 个时间点负荷真实值; $y_{\text{true}}(i)$ 为第 i 个时间点负平均值; $y_{\text{pre}}(i)$ 为第 i 个时间点负荷的预测值; R^2 为可决系数。

3.4 超参数设置

模型的超参数对实验预测精度有很大的影响, 综合考虑模型训练成本和预测精度, 为了消除实验过程硬件设备的影响, 每个模型均进行 5 次训练, 训练过程在验证集上对模型进行验证, 防止模型过拟合, 取过拟合点模型作为最佳模型, 并在测试集上对训练的模型进行预测, 取预测平均值作为最终实验结果。经过多次实验和调整优化, 各项参数设置如表 1 所示。

表 1 参数设置

Tab. 1 Parameter setting

名称	参数设置
全局参数	温度序列滑动窗口大小 $T = 1$ (并行 LSTM)
	时间序列滑动窗口大小 $T = 1$ (并行 LSTM)
	批次大小 $N_{\text{batchsize}} = 64$
	迭代次数 $N_{\text{epoch}} = 1\ 000$
训练参数	隐藏层大小 $N_{\text{hiddensize}} = 128$
	优化器 $O_{\text{optimizer}} = \text{Adam}$
	损失函数 $F_{\text{loss function}} = \text{MAE}$
	初始学习率 $L_{\text{learning rate (lr)}} = 0.01$
	最小学习率 $M_{\text{min lr}} = 0.000\ 1$
	学习率调整阈值 $P_{\text{patience}} = 15$
	衰减因子 $F_{\text{factor}} = 0.9$

3.5 负荷预测结果及分析

3.5.1 历史负荷序列长度对实验结果的影响

本节为了分析历史负荷长度($l_{\text{loadofpast}}$)对实验结果的影响, 选择 7 个不同的历史负荷长度进行实验, 即: $l_{\text{loadofpast}} \in \{1, 4, 8, 12, 16, 20, 24\}$, 选择 MAE 和 R^2 作为评价指标, 实验结果如图 7 所示。

图 7 中, MAE 直观描述模型误差, R^2 描述模型预测负荷曲线与真实负荷曲线的“拟合程度”。LSTM 模型、并行 LSTM 和 t-N Tree-LSTMs 在 $l_{\text{loadofpast}}$ 取 20 h、16 h 和 8 h 时 MAE 达到最小, R^2 最大, 模型预测效果最好, 之后随着历史负荷长度的增加模型预测精度均下降。同时, LSTM 模型、并行 LSTM 模型和 t-N Tree-LSTMs 模型的最优模型预测误差也依次减小。并行 LSTM 模型和 t-N Tree-LSTMs 模型拥有比标准 LSTM 模型更细的特征粒度, 模型只需要较短的历史负荷信息即可学习到负




图 7 历史负荷长度与模型预测精度关系图

Fig. 7 Relationship between historical load length and model prediction accuracy

荷与外部变量之间的相关关系,同时一定程度上减小了非必要历史负荷特征信息带来的噪声影响,降低预测误差。

3.5.2 不同模型预测结果对比

为验证本文提出的并行LSTM模型与t-N Tree-LSTMs模型在中期负荷预测中的有效性,将两者与Prophet模型^[27]、长短期时间网络(long and short-term time-series network, LSTNet)模型^[28]、DeepAR模型^[29]、和极限梯度提升(extreme gradient boosting, XGBoost)模型^[30]进行对比,实验结果如表2所示。

由表2的预测结果进一步分析可知,Prophet作为统计学模型难以学习负荷数据的非线性特征,预测误差较大。LSTNet模型利用卷积层捕捉多维输入变量之间的局部依赖,并通过循环跳跃以捕捉长期依赖,预测效果不理想。DeepAR模型将通过引入协变量建立多维输入变量之间的依赖,建模过程协变量与目标变量特征叠加,预测效果较好;XGBoost作为集成模型采用boosting的思想,每次迭代都学习一棵CART树来拟合前t-1棵树的预测

表 2 各模型预测精度对比

Tab. 2 Comparison of prediction accuracies of various models

模型名称	MAPE 值/%	MAE 值 /MW	RMSE 值 /MW	R ²
Prophet	9.137	1180	1483	0.42
LSTNet	6.037	785.8	963.2	0.76
DeepAR	4.721	556.1	623.7	0.83
XGBoost	3.980	475.5	606.6	0.85
并行LSTM	3.438	455.5	587.3	0.91
t-N Tree-LSTMs	1.897	310.8	378.5	0.94

结果与训练样本真实值的残差,预测效果较好;并行LSTM模型和t-N Tree-LSTMs模型利用分支结构建立负荷与外部变量之间的联系,预测效果有较大的提升。

3.5.3 不同预测长度模型预测结果对比

为了验证本文模型中期负荷预测的效果,将并行LSTM模型以及t-N Tree-LSTMs模型与LSTM模型进行对比。根据3.5.1节的实验结果,各模型的l_{loadofpast}长度分别设置最佳长度,分别对应为16 h、8 h和20 h,在测试集上各模型2017年2—4月预测精度如表3所示,自回归预测结果(取每月前15天)如图8所示。

表 3 2017年2—4月模型预测精度对比

Tab. 3 Comparison of model prediction accuracies from February to April 2017

预测时间段	模型名称	MAPE 值/%	MAE 值 /MW	RMSE 值 /MW	R ²
2017年2月	LSTM	2.881	406.5	542.6	0.91
	并行LSTM	2.519	351.4	454.9	0.93
	t-N Tree-LSTMs	1.761	250.4	289.7	0.97
2017年3月	LSTM	3.211	447.7	563.3	0.89
	并行LSTM	2.962	405.9	511.9	0.91
	t-N Tree-LSTMs	2.076	321.7	405.6	0.95
2017年4月	LSTM	4.224	513.8	650.8	0.85
	并行LSTM	4.112	501.3	620.4	0.87
	t-N Tree-LSTMs	2.432	416.9	487.6	0.93

由表3和图8实验结果可得如下结论。

1)标准LSTM模型、并行LSTM模型以及t-N Tree LSTMs模型随着自回归预测长度的增加,预测精度均会下降,表5中同一模型在3个时间段的MAE值、RMSE值均增大,MAPE值和R²均减小,在图6中4月份对比3月和2月份预测值与真实值偏




图 8 2017年2—4月负荷预测结果

Fig. 8 Load forecast results for February to April 2017

离程度均增大。这种现象主要是因为3个模型均采用迭代多步预测的方式进行负荷预测,该方法优点是不需要对不同的预测长度建立多个对应的预测模型,但预测过程,由于未来负荷值不可知,预测值取代真实值的操作导致误差累积;

2)并行LSTM模型, t -N Tree-LSTMs模型各时间段对比标准LSTM模型预测精度较高。以MAE为参考,并行LSTM模型对比标准LSTM模型在2017年2—4月MAE值分别减小55.1 MW、41.8 MW和12.5 MW; t -N Tree-LSTMs对比标准LSTM模型在2017年2—4月MAE值分别减小156.1 MW、126 MW和96.9 MW。正如1.1节和1.2节所述,并行LSTM在中期负荷预测中建立比标准LSTM更细的特征粒度,而 t -N Tree-LSTMs建立比并行LSTM更细的特征粒度,因此预测结果表现为 t -N Tree-LSTMs模型优于并行LSTM模型,并行LSTM模型优于标准LSTM模型。

4 结论

本文综合考虑中期负荷预测的影响因素和标准LSTM建模原理,提出了利用并行LSTM模型和

t -N Tree-LSTMs模型进行中期负荷预测。相关结论如下。

1)中期负荷预测中需要考虑多个外部变量因素,而皮尔逊相关系数在建立相关性方面存在局限性,通过多项式拟合和可视化分析能为非线性相关的外部变量选取提供补充依据。

2)并行LSTM模型和 t -N Tree-LSTMs模型在负荷预测中能够获取更细的特征粒度,对比标准LSTM模型,两者只需较短的历史负荷信息即可得到较高的预测精度。

3)在迭代多步预测过程中,误差累积不可避免,但更细的特征粒度有助于减小预测过程误差累积。并行LSTM模型和 t -N Tree-LSTMs模型预测精度随着预测长度的增加均下降,但对比标准LSTM模型,两者下降缓慢,预测精度较高。

参考文献

- [1] 张未,余成波,王士彬,等.基于VMD-LSTM-LightGBM的多特征短期电力负荷预测[J].南方电网技术,2023,17(2): 74-81.
ZHANG Wei, YU Chengbo, WANG Shibin, et al. Multi-featured short-term power load forecasting based on VMD-LSTM-LightGBM [J]. Southern Power System Technology, 2023, 17(2): 74-81.
- [2] 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.
ZHENG Haofeng, YANG Guohua, KANG Wenjun, et al. Load forecasting based on multiple load features and TCN-GRU neural network [J]. Electric Power, 2022, 55(11): 142-148.
- [3] 胡威,张新燕,李振恩,等.基于优化的VMD-mRMR-LSTM模型的短期负荷预测[J].电力系统保护与控制,2022,50(1): 88-97.
HU Wei, ZHANG Xinyan, LI Zhen'en, et al. Short-term load forecasting based on an optimized VMD-mRMR-LSTM model [J]. Power System Protection and Control, 2022, 50(1): 88-97.
- [4] AHMAD, GHADI N A, ADNAN Y A, et al. Load forecasting techniques for power system: research challenges and survey [J]. IEEE Access, 2022, 10(10): 71054-71090.
- [5] XIN Zhao, LI Qiushuang, XUE Wanlei, et al. Research on ultra-short-term load forecasting based on real-time electricity price and window-based XGBoost model [J]. Energies, 2022, 15(19): 7367.
- [6] HE Yaoyao, XIAO Jingling, AN Xueli, et al. Short-term power load probability density forecasting based on GLRQ-Stacking ensemble learning method [J]. International Journal of Electrical Power and Energy Systems, 2022(142): 108243.
- [7] SETIAWAN A, ARIFIN Z, SUDIARTO B, et al. Comparison of medium-term load forecasting methods (splitted linear regression and artificial neural networks) in electricity systems located in tropical regions [C]//2022 3rd International Confer-

- ence on Clean and Green Energy Engineering, August 28 – 30, 2022, Istanbul, Turkey. New York: IEEE, 2022: 84 – 88.
- [8] CARVALLO J P, LARSEN P H, SANSTAD A H, et al. Long term load forecasting accuracy in electric utility integrated resource planning[J]. *Energy Policy*, 2018(119): 410 – 422.
- [9] TARMANINI C, SARMA N, GEZEGIN C, et al. Short term load forecasting based on ARIMA and ANN approaches [J]. *Energy Reports*, 2023(9): 550 – 557.
- [10] TAYLOR S J, LETHAM B. Forecasting at scale [J]. *The American Statistician*, 2018, 72(1): 37 – 45.
- [11] QIU Yilei, HE Zhou, ZHANG Wenyu, et al. MSGCN-ISTL: A multi-scaled self-attention-enhanced graph convolutional network with improved STL decomposition for probabilistic load forecasting[J]. *Expert Systems with Applications*, 2024, 238: 121737.
- [12] 杨海民, 潘志松, 白玮. 时间序列预测方法综述[J]. *计算机科学*, 2019, 46(1): 21 – 28.
YANG Haimin, PAN Zhisong, BAI Wei. Review of time series prediction methods [J]. *Computer Science*, 2019, 46(1): 21 – 28.
- [13] AGRAWAL R K, MUCHAHARY F, TRIPATHI M M. Long term load forecasting with hourly predictions based on long-short-term-memory networks[C]//2018 IEEE Texas Power and Energy Conference, February 8 – 9, 2018, Texas, USA. New York: IEEE, 2018: 1 – 6.
- [14] LEI C. Deep Learning Basics[M]//Deep learning and practice with mindspore, Singapore: Springer, 2021: 17 – 28.
- [15] 康田雨, 覃智君. 基于超参数优化和双重注意力机制的超短期风电功率预测[J]. *南方电网技术*, 2022, 16(5): 44 – 53.
KANG Tianyu, QIAN Zhijun. An ultra-short-term wind power forecasting method based on hyperparameter optimization and dual-stage attention mechanism [J]. *Southern Power System Technology*, 2022, 16(5): 44 – 53.
- [16] MUSAED A, KHURSHEED A, IRTAZA S H. Hybrid CNN-LSTM model for short-term individual household load forecasting[J]. *IEEE Access*, 2020(8): 180544 – 180557.
- [17] BOUKTIF S, FIAZ A, OUNI A, et al. Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting[J]. *Energies*, 2020, 13(2): 391 – 404.
- [18] HAYDER I A, HABIB M A, AHMAD M, et al. Enhanced machine-learning techniques for medium-term and short-term electric-load forecasting in smart grids[J]. *Energies*, 2023, 16(1): 276 – 288.
- [19] MATRENIN P, SAFARALIEV M, DMITRIEV S, et al. Medium-term load forecasting in isolated power systems based on ensemble machine learning models [J]. *Energy Reports*, 2022(8): 612 – 618.
- [20] HAN L, PENG Y, LI Y, et al. Enhanced deep networks for short-term and medium-term load forecasting [J]. *IEEE Access*, 2019(7): 4045 – 4055.
- [21] WANG S, WANG D. Combined probability density model for medium term load forecasting based on quantile regression and kernel density estimation[J]. *Energy Procedia*, Elsevier, 2019 (158): 6446 – 6451.
- [22] 傅靖, 王栋, 白阳, 等. 基于基因表达式编程的中长期电力负荷预测挖掘[J]. *电力信息与通信技术*, 2020, 18(5): 7 – 12.
FU Jing, WANG Dong, BAI Yang, et al. Mid-long term load forecasting model mining based on gene expression programming [J]. *Electric Power Information and Communication Technology*, 2020, 18(5): 7 – 12.
- [23] BUTT F M, HUSSAIN L, MAHMOOD A, et al. Artificial intelligence based accurately load forecasting system to forecast short and medium-term load demands[J]. *Mathematical Biosciences and Engineering*, 2021, 18(1): 400 – 425.
- [24] TRAN N K, CHENG W. Multiplicative tree-structured long short-term memory networks for semantic representations[C]//Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, June 12 – 14, 2018, New Orleans, Louisiana. New Orleans: JCLCS, 2018: 276 – 286.
- [25] HONG T, XIE J, BLACK J. Global energy forecasting competition 2017: hierarchical probabilistic load forecasting [J]. *International Journal of Forecasting*, 2019, 35(4): 1389 – 1399.
- [26] ZENG A, CHEN M, ZHANG L, et al. Are transformers effective for time series forecasting? [J]//Proceedings of the AAAI conference on artificial intelligence, 2023, 37(9): 11121 – 11128.
- [27] ALMAZROUEE A I, ALMESHAL A M, ALMUTAIRI A S, et al. Long-term forecasting of electrical loads in kuwait using prophet and holt – winters models[J]. *Applied Sciences*, 2020, 10(16): 5627.
- [28] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks [C]//The 41th international ACM SIGIR Conference on Research & Development in Information Retrieval, July 8 – 12, 2018, Michigan, USA. Michigan: ACM SIGIR, 2018: 95 – 104.
- [29] SALINAS D, FLUNKERT V, GASTHAUS J, et al. Deep AR: probabilistic forecasting with autoregressive recurrent networks [J]. *International Journal of Forecasting*, 2020, 36(3): 1181 – 1191.

收稿日期: 2023-05-17; 网络首发日期: 2024-01-24

作者简介:

徐利美(1986), 女, 通信作者, 高级工程师, 硕士, 研究方向为电力系统调度自动化、电能量计量, 1821311050@163.com;

赵金(1991), 男, 工程师, 硕士, 研究方向为电力系统调度自动化、新能源发电, zhaojindky@163.com;

李裕民(1987), 男, 工程师, 学士, 研究方向为电力系统调度自动化, 394919824@qq.com。