

DOI:10.3969/j.issn.2097-0706.2024.03.006

基于特征筛选的综合能源系统多元负荷 日前-日内预测

Multi-load day-ahead and intra-day forecasting for integrated energy systems
based on feature screening

徐聪¹, 胡永锋¹, 张爱平¹, 由长福²
XU Cong¹, HU Yongfeng¹, ZHANG Aiping¹, YOU Changfu²

(1. 中国华电科工集团有限公司, 北京 100160; 2. 清华大学 能源与动力工程系, 北京 100084)
(1.China Huadian Engineering Company Limited, Beijing 100160, China; 2.Department of Energy and Power
Engineering, Tsinghua University, Beijing 100084, China)

摘要: 负荷预测是指导综合能源系统调度与运行的前提。为更加经济高效地实施系统日前计划、日内优化, 提出一种基于特征筛选的多元负荷日前-日内预测方法。首先, 结合特征工程中 3 类特征筛选方法筛选预测模型输入特征, 简化模型的同时能够保存下最重要的特征, 针对日前-日内预测策略分别确立输入特征集; 然后通过多任务学习硬共享机制, 采用长短期记忆神经网络建立预测模型, 实现不同子任务信息共享, 并通过随机搜索方法优化网络参数以提高预测精度; 最后以北京某产业园区供暖季电、热负荷为案例进行分析, 日前、日内预测综合精度分别达到 91.3% 和 95.2%。分析结果表明, 该预测方法能够为系统日前调度和日内运行优化提供良好支撑, 且预测结果优于未经特征筛选预测和单独负荷预测, 证明了该预测方法具有更高的预测精度。

关键词: 综合能源系统; 多元负荷; 特征筛选; 日前-日内预测; 多任务学习; 长短期记忆神经网络

中图分类号: TK 01 **文献标志码:** A **文章编号:** 2097-0706(2024)03-0045-09

Abstract: Load forecasting is a prerequisite for guiding the scheduling and operation of integrated energy systems (IES). In order to carry out day-ahead scheduling and intra-day operation optimization on IES more economically and efficiently, a multi-load day-ahead and intra-day forecasting method based on feature screening is proposed. Firstly, by combining three types of feature screening methods in feature engineering, input features of forecasting models are selected. The combining method simplifies the models while preserving the important features, and the input feature sets for day-ahead and intra-day forecasting models are selected respectively. Then, taking hard parameter sharing in multi-task learning, the forecasting models are established based on long short-term memory neural network, achieving information sharing among different subtasks. And the forecasting accuracies of the models are optimized through random search method. Finally, taking an industrial park in Beijing as a study case, its energy system's electricity and heat loads are analyzed, and the comprehensive accuracies of the day-ahead and intra-day forecasting reach 91.3% and 95.2%, respectively. The method provides a sound support for IES day-ahead scheduling and intra-day operation optimization. Compared with the results of forecasting without feature screening and the forecasting on a single load, the method proposed has a higher forecasting accuracy.

Keywords: integrated energy system; multi-load; feature screening; day-ahead and intra-day forecasting; multi-task learning; long short-term memory neural network

0 引言

随着社会、经济不断发展, 环境形势日益严峻, 能源产业也在不断升级和转型, 基于传统化石能源

的单一供能模式已难以满足可持续发展的需求^[1]。综合能源系统(Integrated Energy System, IES)是多能流耦合以满足用户多类型负荷需求的高效能源系统^[2], 不仅能够促进可再生能源消纳、减少污染物排放, 还能实现能源互联网的协同优化控制和源网荷储一体化。而准确的负荷预测是指导 IES 规划、调度、运行优化的前提^[3]。随着大数据技术、人工智能的快速发展, 数据驱动的机器学习方法, 如支持

基金项目: 新疆维吾尔自治区重大科技专项(2022A1001-3)
Major Science and Technology Projects of Xinjiang Uygur
Autonomous Region(2022A1001-3)

向量机(SVM)、随机森林(RF)、人工神经网络(ANN)、深度神经网络(DNN)等成为负荷预测的主要技术^[4]。

IES中存在多种能源的转化利用过程,且多种负荷间存在差异性、随机性及耦合性,单一负荷预测技术难以兼顾。

近年来国内外学者提出了多元负荷联合预测方法^[5],并在负荷耦合特性分析、输入特征集构建、联合预测建模等重点内容上取得了一定研究进展。文献[6]分析了冷热电负荷的非线性关系,并提出反映负荷间非线性协同效应的负荷预测公式。文献[7]构建了基于Copula理论的负荷相关性计算模型,并提出了一种负荷间耦合度的度量方式。文献[8]从特征工程的角度,利用耦合特征挖掘算法,构造IES冷热电负荷耦合特征变量并将其作为模型输入,以此提高预测精度。文献[9]利用温湿指数构造计及多因素影响的输入变量,并利用核主成分分析法(KPCA)对输入空间进行降维处理,与对照模型相比,采用该方法的模型预测精度得到了提高。文献[10]采用变分模态分解方法实现负荷模态划分,然后分析多元模态子序列数据的具体特征,得到多元数据间的耦合关系,采用门控循环单元(GRU)模型分别对耦合共有分量及剩余分量进行分步预测,有效改善了小样本预测精度低的问题。以上研究通过不同方法挖掘了多元负荷之间的耦合关系,部分文献将耦合定量关系应用到预测网络中,提升了多元负荷整体预测的精度。然而,IES负荷影响因素复杂度不断加深,现有研究对外界影响因素尚考虑不足。

在神经网络模型方面,径向基函数神经网络、广义回归神经网络、领域自适应神经网络、反向传播(BP)神经网络等均已得到研究应用^[11-14]。由于循环神经网络(RNN)、长短期记忆(LSTM)神经网络、GRU为具有记忆功能的网络结构,在处理时间序列(如负荷预测)上表现出优势。LSTM神经网络能有效解决RNN梯度消失和梯度爆炸的问题。文献[15-21]以LSTM神经网络为基础,开展了短期或超短期多元负荷预测模型研究,提出了DBiLSTM-MLR, CNN-LSTM, CNN-BiLSTM, ResNet-LSTM, LSTM-XGboost等模型,并通过试验证明各模型在多元负荷预测上具有良好效果。文献[22]提出了能够提取耦合特征的CNN-GRU复合预测模型,并通过迁移学习实现小样本情况预测。由此可见,融合不同算法的复合模型能够改进单一神经网络模型的性能,是未来预测模型的发展方向,且随着深度学习的发展,集成学习、迁移学习、强化学习等理

论具有很大的应用潜力^[23]。

为实现多元负荷联合预测,多任务学习(MTL)的机器学习方法被应用到该领域。文献[24]以“硬共享机制+长短时记忆共享层”方式构建MTL负荷预测模型,通过神经网络可解释性技术证实所构建模型能够利用子任务提供的耦合信息来提高预测精度。文献[25]利用专家子网和门控单元学习多元负荷间耦合特性的差异,并通过公开数据集进行性能验证,表明所提出的基于多门控专家混合(MMoE)模型和LSTM模型能够有效提升多元负荷预测精度。文献[26]基于自适应局部迭代滤波(ALIF),将历史负荷序列分解为具有不同频段模态函数的多个分量,建立基于LSTM网络多任务学习的综合能源系统短期负荷预测模型,所提方法能够应对负荷波动剧烈的工况,预测精度较高。由以上研究可见,MTL能够通过共享机制实现耦合信息的共享,多个任务并行学习且结果相互影响,在多元负荷联合预测上表现优异。

以上理论研究各有侧重,但将预测模型应用到实际系统中还有很多工作需要完成。在IES实际调度运行中,需要提前制定第2天的调度策略,并在当日根据实际情况进行运行优化。因此,本文从实际应用的角度出发,基于特征筛选综合结论构建输入特征集;提出日前-日内多元负荷预测方法,并通过MTL共享机制,实现多元负荷之间的信息耦合;在LSTM神经网络模型中进行训练,并通过网络参数优化提高预测精度。

1 特征筛选

IES的负荷受生产生活、季节、天气、日类型、能源价格等多方面因素影响^[27-28],但将全部因素均作为特征输入会增加噪声干扰,使模型复杂、训练过程过长,且可能出现过拟合,因此构建合理的输入特征集对提高预测精度尤为重要。

特征工程中的特征筛选技术可以减少特征数量、减轻过拟合、增强模型泛化能力、提高模型训练速度和模型可解释性。特征筛选方法可分为过滤式、包裹式、嵌入式等3类方法。(1)过滤式特征筛选是在特征选择和模型训练之前独立进行,通过对特征的某些统计指标进行评估,来判断特征与目标变量之间的相关性,该方法算法简单易于实现,但没有考虑特征之间的关联性,可能忽略特征的组合效益;(2)包裹式特征筛选是在特征选择与模型训练之间进行,通过构建一个评估函数来判断特征的重要性,并利用特定的搜索算法来选择最佳特征子集,该方法可以更准确地筛选出对模型更有用的特

征,但计算成本较高;(3)嵌入式特征筛选是将特征选择和模型训练融合在一起,利用模型参数计算特征重要性,该方法可以在特征之间建立有效关系,更好地利用特征信息,但模型认为重要的特征不一定重要。

基于各类方法的特点,单一方法无法保障筛选出的特征集为最佳特征集。本文综合3类方法的筛选结果,构建输入特征集,具体方法为:分别采用3类方法中的典型方法,即相关系数法、递归特征消除法和XGBoost梯度提升树法,对所有待筛选特征进行排名计算;赋予3类方法的筛选结果相同的权重系数;最终按各特征重要度由大到小根据维度需求确定筛选出的输入特征。

1.1 相关系数法

相关系数法通过计算特征与目标变量之间的相关系数来评估特征重要性,相关系数绝对值越大,说明特征与目标变量的相关性越大,即对预测更重要,其中皮尔逊相关系数被广泛应用,其定义为

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}, \quad (1)$$

式中: r 为皮尔逊相关系数,取值范围为 $[-1, 1]$; \bar{X} , \bar{Y} 分别为变量 X_i , Y_i 的均值。

1.2 递归特征消除

递归特征消除的具体方法:首先训练一个模型(本文采用回归模型),根据特征的重要性排序剔除最不重要的特征;再重新训练模型,在剩余的特征上重复这个过程,直到所有特征都遍历。这个过程中特征被消除的次序就是特征的排序,是一种寻找最优特征集的贪心算法。

1.3 XGBoost梯度提升树

基于树模型的特征选择方法通过计算特征在决策树中的重要性来评估特征的重要性,常见的树模型包括决策树、随机森林、梯度提升树。XGBoost是对梯度提升算法的改进,在提升树被创建后,可以相对直接地得到每个特征的重要性得分。在单个决策树中通过每个特征分裂点改进性能度量的量来计算特征重要性,由节点负责加权和记录次数,即一个特征对分裂点改进性能度量越大,权值越大,被越多提升树所选择,特征越重要。

2 日前-日内MTL-LSTM预测模型

2.1 MTL

多元负荷如电、冷、热、生活热水等之间具有一定的相关性,如包括电制冷设备的供能系统,其电

负荷和冷负荷具有较大的正相关性,但其具体相关性大小由IES供能模式、用户用能特性及外界条件(如能源价格和政策等)决定。各负荷单独预测无法涵盖和学习到其他负荷的信息,忽略了负荷之间的相互影响,通过相关算法实现多元负荷联合预测能够很好地解决以上问题。MTL是并行学习多个相关但不同的子任务的联合学习方法,通过共享层来学习并获得其他子任务提供的辅助耦合信息,从而使模型达到更好的泛化能力。MTL共享机制分为硬共享和软共享:硬共享机制各子任务共享一个特征共享层,共享一套特征参数,可以有效降低过拟合的风险;软共享机制允许每个任务有自己的特定参数,但参数之间彼此约束,需要进行必要的正则化,适用于任务间相关性不强的情况。由于IES各负荷之间具有较大关联性,影响因素也具有一定重合性,本文采用硬共享机制,结构如图1所示。

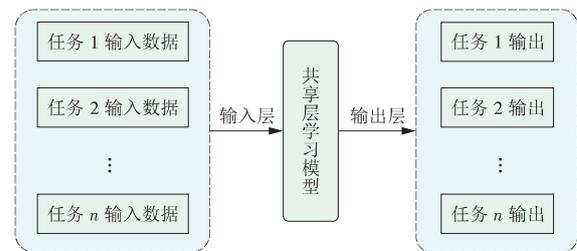


图1 MTL硬共享机制

Fig. 1 Structure of MTL hard sharing mechanism

2.2 LSTM神经网络

IES的负荷是时间序列,具有一定趋势特性、周期特性和随机特性。LSTM神经网络通过细胞状态的更新和控制门的引入,有选择地加入新信息,并有选择地遗忘之前累积的信息,能够有效地处理长时间序列,在负荷预测上具有良好效果,因此本文采用LSTM神经网络搭建MTL的共享层学习模型。各负荷预测子任务的输入经数据融合后,进入共享层,共享层由单层或多层LSTM神经网络构建,最后经全连接层分别输出各子任务的预测结果,MTL-LSTM预测模型如图2所示。LSTM神经网络的单元结构如图3所示,各参数含义见表1。

遗忘门决定上一时刻的单元状态有多少需要保留到当前时刻,计算公式为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (2)$$

式中: σ 为sigmoid激活函数,输出范围为 $[0, 1]$,描述了保存的有效信息比例^[3]; W 和 b 为权重和偏移量,其下角标 f 代表遗忘门。

输入门决定当前时刻网络的输入数据有多少需要保存到单元状态,计算公式为

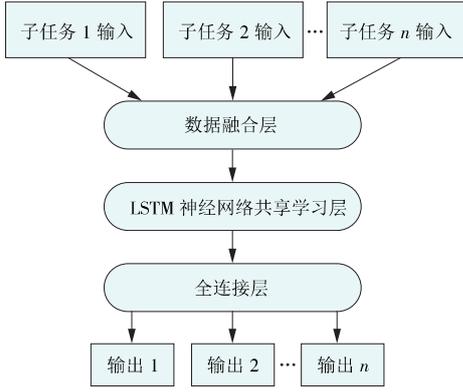


图2 MTL-LSTM预测模型

Fig. 2 MTL-LSTM prediction model

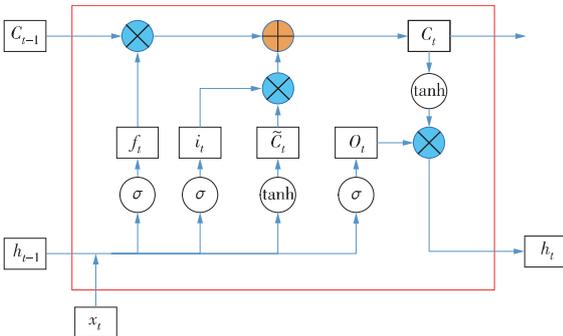


图3 LSTM神经网络单元结构

Fig. 3 Structure of the LSTM neural network unit

表1 LSTM神经网络参数

Table 1 LSTM neural network parameters

参数	含义	参数	含义
x_t	当前时刻输入值	h_t	当前时刻隐藏层输出
f_t	遗忘门控制信号	h_{t-1}	上一时刻隐藏层输出
i_t	输入门控制信号	C_t	当前时刻细胞状态
o_t	输出门控制信号	C_{t-1}	前一时刻细胞状态
\tilde{C}_t	信息候选状态		

$$\begin{cases} i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \end{cases} \quad (3)$$

输出门控制当前单元状态有多少需要输出到当前的输出值,计算公式为

$$\begin{cases} o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \cdot \tanh(C_t) \end{cases} \quad (4)$$

式中: \tanh 激活函数将一个实数映射到 $[-1, 1]$ 的范围,反映网络中状态及输出的变化^[3];下角标*i*、*o*分别代表输入门、输出门;下角标*C*代表候选记忆元。

2.3 日前-日内预测流程

IES调度需要提前制定运行计划,包括各机组启停状态和出力大小等,当日运行时又需根据负荷实时变化调整优化系统运行。因此,本文提出日前-日内负荷预测策略,不同策略对应不同输入特

征集,可分别得到次日24h的负荷预测和当日基于负荷实时更新的逐时负荷预测,预测流程如图4所示。

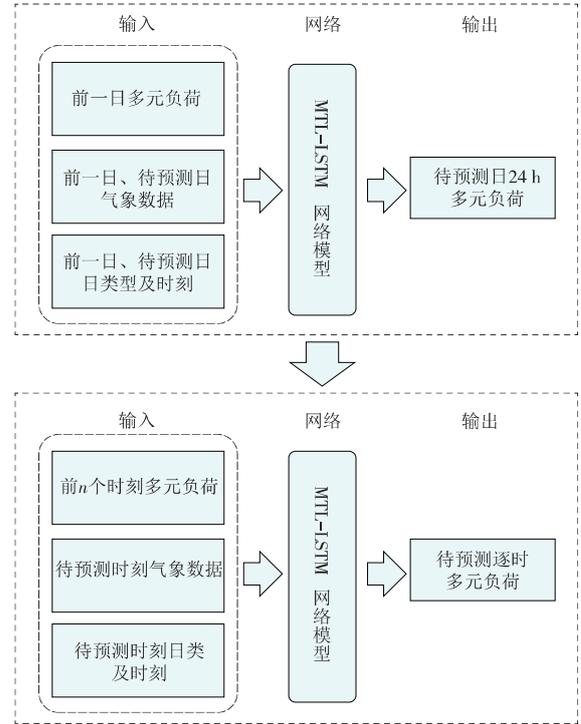


图4 日前-日内预测流程

Fig. 4 Day-ahead and intra-day forecasting process

2.4 评价指标

为直观体现负荷预测误差的大小和预测的准确度水平,本文采用平均绝对误差(Mean Absolute Error, MAE)、平均绝对百分误差(Mean Absolute Percentage Error, MAPE)和预测精度(δ)作为负荷预测的评价指标,即

$$l_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

$$l_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (6)$$

式中: y_i, \hat{y}_i 分别为负荷真实值和预测值; n 为预测小时数。

$$\delta = 1 - l_{MAPE} \quad (7)$$

通过给各子任务预测误差赋予权重得到多元负荷预测综合评价指标,

$$\bar{l}_{MAE} = \alpha l_{MAE1} + \beta l_{MAE2} + \dots + \lambda l_{MAEn} \quad (8)$$

$$\bar{l}_{MAPE} = \alpha l_{MAPE1} + \beta l_{MAPE2} + \dots + \lambda l_{MAPE_n} \quad (9)$$

$$\bar{\delta} = \alpha \delta_1 + \beta \delta_2 + \dots + \lambda \delta_n \quad (10)$$

式中: α, β, λ 为各子任务权重系数。

3 案例分析

3.1 数据预处理

以北京某产业园为研究对象,通过智能采集系

统获取到2022-11-16 T 00:00—2023-02-28 T 23:00的逐时电、热负荷数据,并以70%,15%,15%的比例划分为训练集、验证集、测试集。采集缺失点由前后时刻的平均值填补,异常值判断标准依靠用能规律,对跳跃点采用临近的相似日类型同时刻的值替换,数据预处理有利于提升模型学习效果。经预处理后的采样期电、热负荷如图5所示。

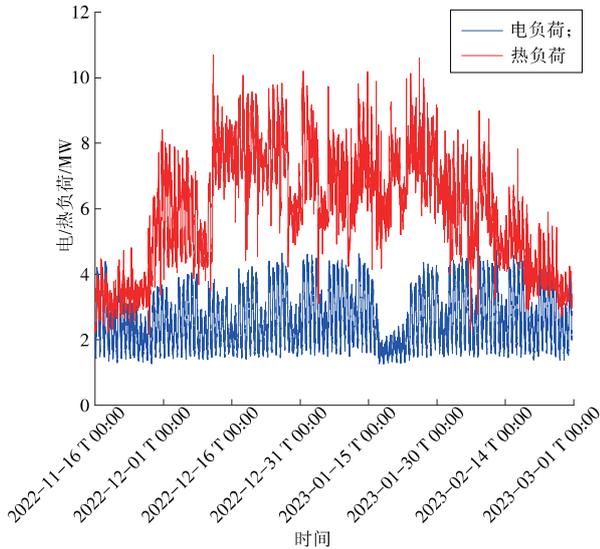


图5 采样期电、热负荷小时数据

Fig. 5 Hourly data of electric and heat loads during the sampling period

3.2 输入特征集构建

园区负荷主要受园区内人员活动以及天气因素影响,因此将日类型、时刻和气象因素作为输入特征。分别以0和1表示工作日、节假日2种日类型,以整数0~23表示时刻。依据前述3种特征筛选方法,采用SPSSPRO数据分析平台软件筛选气象因素中的关键特征。SPSSPRO内置了Pearson相关系数计算公式、回归模型、XGBoost算法。电负荷 e 、热负荷 h 与气象因素温度 t 、相对湿度 d 、气压 p 、风速 v 、辐照强度 w 的皮尔逊相关系数计算结果见表2。递归特征消除法、XGBoost梯度提升树法的电、热负荷特征重要度排序见表3。

表2 皮尔逊相关系数结果

Table 2 Pearson correlation coefficients

项目	e	h	t	d	p	v	w
e	1.000	0.367	0.498	-0.242	-0.060	0.082	0.520
h	0.367	1.000	-0.348	-0.490	0.202	0.038	0.197

根据前述综合筛选方法,对于电负荷,相关系数大小和重要度排名前2的均是 t 和 w ;对于热负荷,排名前2的均是 d 和 t 。为降低特征维度同时保持每个子任务的重要影响因素,对于电、热负荷联合预测,气象因素选择 t 、 d 和 w 作为输入特征。根据

表3 电、热负荷特征重要度排序

Table 3 Importance ranking for the characteristic quantities of electric and heat loads

排名	递归特征消除法		XGBoost 梯度提升树法	
	e	h	e	h
1	w	d	w	d
2	t	t	t	t
3	p	w	v	p
4	d	p	p	v
5	v	v	d	w

前述的日前-日内预测策略,构造日前输入特征集为 $e_{\tau-1}, h_{\tau-1}, t_{\tau-1}, d_{\tau-1}, w_{\tau-1}, \text{day}_{\tau-1}, \text{day}_{\tau}, i$,其中 τ 为待预测日, $\tau-1$ 为待预测日前一日, day 为日类型, i 为待预测时刻;日内输入特征集为 $e_{i-24}, e_{i-23}, \dots, e_{i-1}, h_{i-24}, h_{i-23}, \dots, h_{i-1}, t_i, d_i, w_i, \text{day}_i, i_0$

为降低学习难度提升网络收敛速度,通常将输入特征进行归一化处理,变化区间为 $[0, 1]$,归一化公式为

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}}, \quad (11)$$

式中: X_{\min}, X_{\max} 分别为变量 X 的最小值和最大值。

3.3 网络模型参数

网络模型参数的选择直接决定了所建立模型的预测效果。通过超参数调优可以一定程度上提高预测精度。超参数主要包括学习率(lr)、迭代次数(epochs)、网络层数(num_layers)、每个隐藏层神经元个数(hidden_size)、批量大小(batch_size)等。常见的超参数调优方法包括网格搜索、随机搜索和贝叶斯优化等,其中随机搜索计算量较小,能够在有限的时间内快速找到较好的超参数组合,因此本文采用此方法进行超参数寻优。设定各参数范围见表4, gamma为学习率衰减率, step_size为更新学习率步数间隔。

表4 网络模型参数设定

Table 4 Network model parameter settings

参数名称	设定范围	参数名称	设定范围
epochs	10~200(间隔为10)	batch_size	4, 8
num_layers	1, 2, 3	gamma	0.5
hidden_size	16, 32, 64, 128	step_size	5

3.4 预测结果与分析

3.4.1 日前预测

通过20次随机搜索得到最优训练模型参数,见表5。图6—7为训练过程中,学习率衰减情况和损失函数loss曲线的变化情况。在训练的开始阶段lr较大,loss可以快速下降,由于加入StepLr函数,每

训练 5 轮 lr 衰减一次,使 loss 尽快达到全局最小并减小了局部振荡。loss 函数采用均方误差 (Mean Square Error, MSE), 最终训练集上 loss 达到 0.006 1, 验证集上 loss 达到 0.008 4, 略大于训练集上 loss 且收敛平稳, 说明模型可靠。

表 5 最优参数

Table 5 Optimal parameters

参数名称	值	参数名称	值
epochs	100	lr	0.1
num_layers	2	batch_size	8
hidden_size	64		

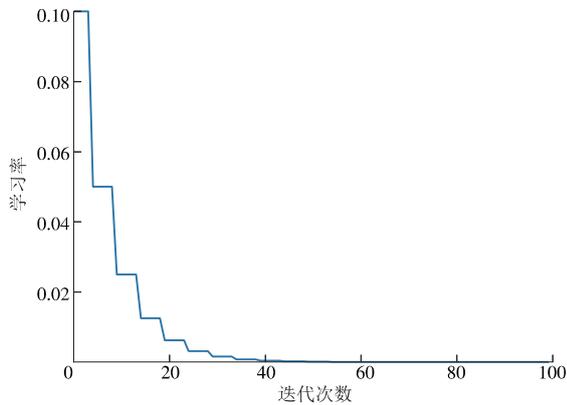


图 6 学习率变化曲线

Fig. 6 Learning rate variation curve

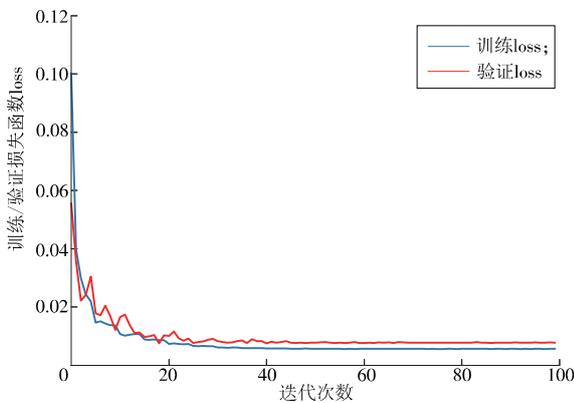


图 7 训练/验证 loss 曲线

Fig. 7 Training/validating loss curves

以验证集上 loss 最小为最佳模型, 在测试集上测试该最佳模型, 得到的电、热负荷预测值与真实值对比情况如图 8—9 所示。可以看出, 在负荷尖峰和低谷时, 预测误差较大, 预测曲线较为顺滑, 但实际负荷会有一些波动, 但整体趋势可以满足日前调度计划需求。测试结果各项评价指标见表 6。由于本案例热负荷由供能侧热量计采集, 因此随着供热设备的调整, 数据震荡较大, 导致预测精度略低于电负荷预测精度。电、热负荷权重系数均取 0.5, 日前预测综合精度达到 91.3%。

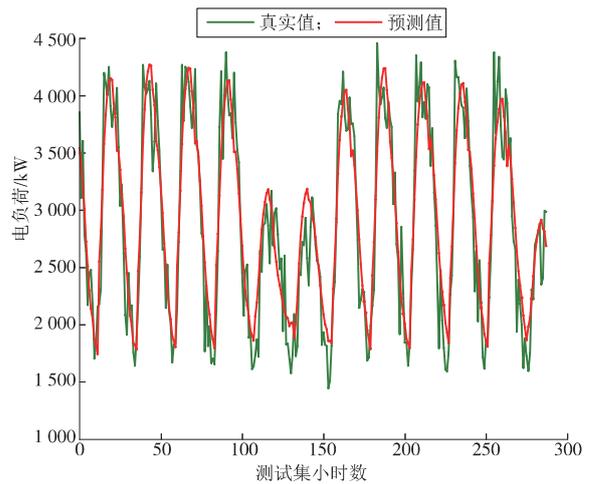


图 8 日前预测中电负荷预测值与真实值

Fig. 8 Forecasting and actual values of electric loads in day-ahead forecasting

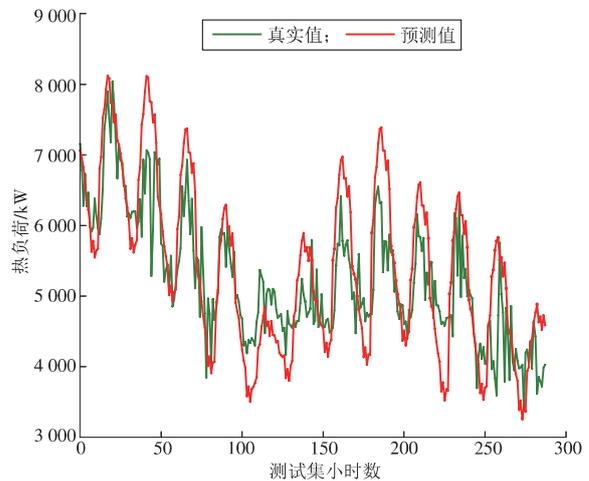


图 9 日前预测中热负荷预测值与真实值对比

Fig. 9 Forecasting and actual values of heat loads in day-ahead forecasting

表 6 日前预测评价指标

Table 6 Day-ahead forecasting evaluation index

指标	电负荷	热负荷	综合指标
MAE/kW	233.7	478.2	356.0
MAPE	0.084	0.090	0.087
$\delta/\%$	91.6	91.0	91.3

3.4.2 日内预测

参数寻优过程与日前预测相同不再赘述, 日内预测结果如图 10—11 所示, 预测评价指标见表 7。在日内预测策略下, 模型可以学习到更多待预测时刻之前的真实负荷情况, 预测精度有较大幅度的提升, 由此可见, 预测负荷受之前一段时间内负荷的影响较大, 与相关性分析具有一致性。电、热负荷预测精度分别达到 94.2% 和 96.2%, 综合精度为 95.2%, 能够为日内优化调整运行提供准确支撑。

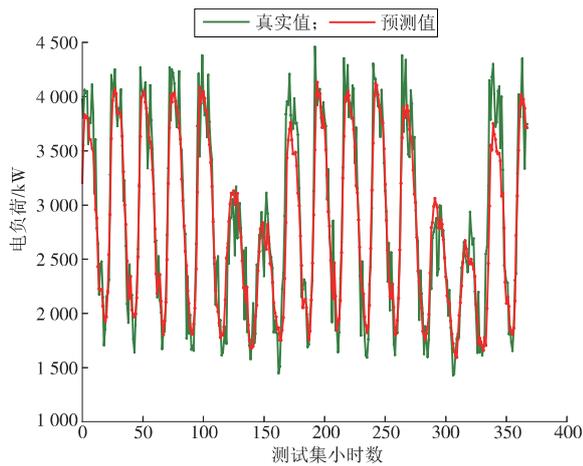


图 10 日内预测中电负荷预测值与真实值
Fig. 10 Forecasting and actual values of electric loads in intra-day forecasting

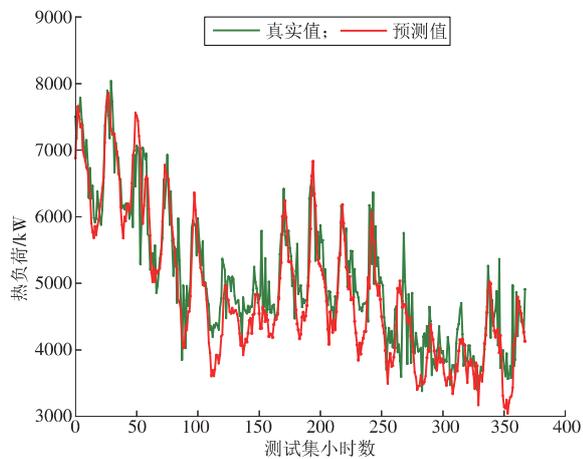


图 11 日内预测中热负荷预测值与真实值对比
Fig. 11 Forecasting and actual values of heat loads in intra-day forecasting

表 7 日内预测评价指标

Table 7 Intra-day forecasting evaluation index

指标	电负荷	热负荷	综合指标
MAE/kW	158.0	210.4	184.2
MAPE	0.058	0.038	0.048
$\delta/\%$	94.2	96.2	95.2

3.4.3 对比分析

将本文提出的基于特征筛选的多元负荷联合预测方法,分别与未经特征筛选的联合预测和负荷单独预测进行对比。未经特征筛选的联合预测将本文提到 5 个气象因素均作为输入特征,并采用 MTL-LSTM 模型进行预测;电、热负荷单独预测的输入气象因素与本文相同,也选取温度、相对湿度、辐照强度,采用 LSTM 神经网络进行建模。2 种方法预测精度见表 8。结果表明,本文日前-日内综合精度比未经特征筛选预测方法分别高 1.6 百分点、2.8 百分点;比负荷单独预测分别高 0.9 百分点、2.1 百

百分点。由此可见,输入特征筛选和相关任务联合学习对提升模型性能具有一定效果,且在日内预测策略上有更好的表现。

表 8 不同方法预测精度

Table 8 Forecasting accuracies of different methods %

项目	日前预测精度			日内预测精度		
	电负荷	热负荷	综合	电负荷	热负荷	综合
未经特征筛选	91.2	88.2	89.7	91.3	93.4	92.4
单独预测	90.6	90.2	90.4	92.4	93.7	93.1

4 结论

本文从综合能源系统实际调度运行出发,提出了日前-日内预测策略,结合 3 类特征筛选方法的典型方法(相关系数法、递归特征消除法和 XGBoost 梯度提升树法)的综合结果来筛选气象因素特征,并考虑多元负荷之间具有耦合性,采用多任务学习硬共享机制通过 LSTM 神经网络来实现信息共享,实际案例分析结果如下。

(1)通过负荷数据实时更新,日内预测策略可以累积更多真实负荷信息,预测精度相比于日前预测有一个显著提升,案例综合预测精度从 91.3% 提升至 95.2%,可见针对实际应用,灵活的预测策略可以更好地指导系统运行。

(2)特征筛选可以在简化模型的同时提升模型预测准确性,与未经特征筛选的预测方法相比,案例中日前、日内预测的综合精度分别提升了 1.6 百分点、2.8 百分点。

(3)对于具有一定相关性的多元负荷,采用 MTL-LSTM 联合预测模型,可以提升各子任务预测精度,案例中日内预测电、热负荷精度分别提升了 1.8 百分点、2.5 百分点。

本文后续将在特征集构建优化和多种多元负荷联合预测上进行深入研究。

参考文献:

[1]别朝红,王旭,胡源.能源互联网规划研究综述及展望[J].中国工程电机学报,2017,37(22):6445-6462.
BIE Chaohong, WANG Xu, HU Yuan. Review and prospect of planning of energy internet[J]. Proceedings of the CSEE, 2017,37(22):6445-6462.

[2]曾鸣,王永利,张硕,等.综合能源系统[M].北京:中国电力出版社,2020.

[3]付子昱.基于负荷预测的综合能源系统混合时间尺度优化运行[D].北京:华北电力大学,2021.
FU Ziyu. Hybrid-time scale optimal scheduling of integrated

- energy systems with load forecasting [D]. Beijing: North China Electric Power University, 2021.
- [4] 朱继忠, 董瀚江, 李盛林, 等. 数据驱动的综合能源系统负荷预测综述[J]. 中国电机工程学报, 2021, 41(23): 7905-7923.
- ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. Review of data-driven load forecasting for integrated energy system[J]. Proceedings of the CSEE, 2021, 41(23): 7905-7923.
- [5] 史佳琪, 谭涛, 郭经, 等. 基于深度结构多任务学习的园区型综合能源系统多元负荷预测[J]. 电网技术, 2018, 42(3): 698-706.
- SHI Jiaqi, TAN Tao, GUO Jing, et al. Multi-task learning based on deep architecture for various types of load forecasting in regional energy system integration [J]. Power System Technology, 2018, 42(3): 698-706.
- [6] CHEN B Y, WANG Y F. Short-term electric load forecasting of integrated energy system considering nonlinear synergy between different loads [J]. IEEE Access, 2021, 9: 43562-43573.
- [7] 王永利, 周泯含, 姚苏航, 等. 基于多能耦合机理的综合能源系统多元负荷协同预测模型[J]. 华北电力大学学报, 2022, 49(2): 118-126.
- WANG Yongli, ZHOU Minhan, YAO Suhang, et al. Multi-load cooperative prediction model of integrated energy system based on multi-energy coupling mechanism [J]. Journal of North China Electric Power University, 2022, 49(2): 118-126.
- [8] 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.
- LV Zhonglin, GU Jie, MENG Lu. Short-term load forecasting for integrated energy system based on coupling features and multi-task learning [J]. Automation of Electric Power Systems, 2022, 46(11): 58-66.
- [9] 金立, 张力, 唐杨. 考虑温湿指数与耦合特征的综合能源负荷短期预测[J]. 综合智慧能源, 2023, 45(7): 70-77.
- JIN Li, ZHANG Li, TANG Yang. Short-term prediction on integrated energy loads considering temperature-humidity index and coupling characteristics [J]. Integrated Intelligent Energy, 2023, 45(7): 70-77.
- [10] 李家钊. 基于特征迁移学习与耦合关系挖掘的综合能源系统小样本日前负荷预测[D]. 徐州: 中国矿业大学, 2021.
- LI Jiazhao. Small-sample day-ahead load forecasting of integrated energy system based on feature transfer learning and coupling relationship mining [D]. Xuzhou: China University of Mining and Technology, 2021.
- [11] 翟晶晶, 吴晓蓓, 王力立. 基于径向基函数神经网络的综合能源系统多元负荷短期预测[J]. 电力需求侧管理, 2019, 21(4): 23-17.
- ZHAI Jingjing, WU Xiaobei, WANG Lili. Multiple short-term load forecasting in integrated energy system based on RBF-NN model [J]. Power Demand Side Management, 2019, 21(4): 23-17.
- [12] 马建鹏, 龚文杰, 张智晟. 基于 Copula 理论与 KPCA-GRNN 结合的区域综合能源系统多元负荷短期预测模型[J]. 电工电能新技术, 2020, 39(3): 24-31.
- MA Jianpeng, GONG Wenjie, ZHANG Zhisheng. Short-term multiple load prediction model for regional integrated energy system based on Copula theory and KPCA-GRNN [J]. Advanced Technology of Electrical Engineering and Energy, 2020, 39(3): 24-31.
- [13] 何桂雄, 金璐, 李克成, 等. 基于改进 DaNN 的综合能源系统多元负荷预测[J]. 电力工程技术, 2021, 40(6): 25-33.
- HE Guixiong, JIN Lu, LI Kecheng, et al. Multiple energy load forecasting of integrated energy system based on improved DaNN [J]. Electric Power Engineering Technology, 2021, 40(6): 25-33.
- [14] 王玥, 鞠振河, 汤梓涵. 基于 GA-BP 神经网络冷热电联供系统的负荷预测[J]. 电工技术, 2022(7): 40-42, 189.
- WANG Yue, JU Zhenhe, TANG Zihan. GA-BP neural network based load prediction of combined cooling, heating and power energy supply [J]. Electric Engineering, 2022(7): 40-42, 189.
- [15] 陈锦鹏, 胡志坚, 陈纬楠, 等. 二次模态分解组合 DBiLSTM-MLR 的综合能源系统负荷预测[J]. 电力系统自动化, 2021, 45(13): 85-94.
- CHEN Jinpeng, HU Zhijian, CHEN Weinan, et al. Load prediction of integrated energy system based on combination of quadratic modal decomposition and deep bidirectional long short-term memory and multiple linear regression [J]. Automation of Electric Power Systems, 2021, 45(13): 85-94.
- [16] 张文栋, 刘子琨, 梁涛, 等. 基于 CNN-LSTM 的综合能源系统负荷预测模型[J]. 重庆邮电大学学报(自然科学版), 2023, 35(2): 254-262.
- ZHANG Wendong, LIU Zikun, LIANG Tao, et al. Load prediction model of integrated energy system based on CNN-LSTM [J]. Journal of Chongqing University of Posts and Telecommunications (Nature Science Edition), 2023, 35(2): 254-262.
- [17] 王琛, 王颖, 郑涛, 等. 基于 ResNet-LSTM 网络和注意力机制的综合能源系统多元负荷预测[J]. 电工技术学报, 2022, 37(7): 1789-1799.
- WANG Chen, WANG Ying, ZHENG Tao, et al. Multi-energy load forecasting in integrated energy system based on ResNet-LSTM network and attention mechanism [J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1789-1799.
- [18] 廖清阳, 王军, 胡凯强, 等. 基于深度并行 CNN-BiLSTM

- 的能源互联网电负荷和热负荷联合预测模型[J].中国测试,2022,48(4):146-153.
- LIAO Qingyang, WANG Jun, HU Kaiqiang, et al. Joint forecasting model of electrical load and thermal load based on deep parallel CNN-BiLSTM in energy internet [J]. China Measurement & Test, 2022, 48(4): 146-153.
- [19] YAO Z J, ZHANG T Y, WANG Q M, et al. Short-term power load forecasting of integrated energy system based on attention-CNN-DBiLSTM [J]. Mathematical Problems in Engineering, 2022, 1: 12.
- [20] ZHENG J Y, ZHANG L Y, CHEN J P, et al. Multiple-load forecasting for integrated energy system based on Copula-DBiLSTM [J]. Energies, 2021, 14(8): 2188-2201.
- [21] 王愈轩, 刘尔佳, 黄永章. 数据驱动下的综合能源系统短期多元负荷预测[J]. 计算机工程与设计, 2022, 43(5): 1435-1442.
- WANG Yuxuan, LIU Erjia, HUANG Yongzhang. Data driven short-term multiple load forecasting for integrated energy system [J]. Computer Engineering and Design, 2022, 43(5): 1435-1442.
- [22] LI C, LI G J, WANG K Y, et al. A multi-energy load forecasting method based on parallel architecture CNN-GRU and transfer learning for data deficient integrated energy systems [J]. Energy, 2022, 259(15): 124967.
- [23] LIU Y J, LI Y, LI G L, et al. Review of multiple load forecasting method for integrated energy system [J]. Frontiers In Energy Research, 2023, 11: 1296800.
- [24] 孙庆凯, 王小君, 张义志, 等. 基于 LSTM 和多任务学习的综合能源系统多元负荷预测[J]. 电力系统自动化, 2021, 45(5): 63-70.
- SUN Qingkai, WANG Xiaojun, ZHANG Yizhi, et al. Multiple load prediction of integrated energy system based on long short-term memory and multi-task learning [J]. Automation of Electric Power Systems, 2021, 45(5): 63-70.
- [25] 吴晨, 姚菁, 薛贵元, 等. 基于 MMoE 多任务学习和长短时记忆网络的综合能源系统负荷预测[J]. 电力自动化设备, 2022, 42(7): 33-39.
- WU Chen, YAO Jing, XUE Guiyuan, et al. Load forecasting of integrated energy system based on MMoE multi-task learning and LSTM [J]. Electric Power Automation Equipment, 2022, 42(7): 33-39.
- [26] 欧阳静, 杨吕, 尹康, 等. 基于 ALIF-LSTM 多任务学习的综合能源系统短期负荷预测[J]. 太阳能学报, 2022, 43(9): 499-507.
- OUYANG Jing, YANG Lv, YIN Kang, et al. Short-term load forecasting method for integrated energy system based on ALIF-LSTM and multi-task learning [J]. Acta Energetica Solaris Sinica, 2022, 43(9): 499-507.
- [27] 章昊. 基于中、短时间尺度的春节负荷特征滚动预测[J]. 东北电力技术, 2022, 43(2): 28-32.
- ZHANG Hao. Spring Festival load characteristic time-process forecasting based on medium and short time scales [J]. Northeast Electric Power Technology, 2022, 43(2): 28-32.
- [28] 秦爽, 朱秋成, 施宇丹. 基于 MI-LSTM 输电线动态参数修正的电力系统可用输电能力计算[J]. 东北电力技术, 2023, 44(11): 1-6.
- QIN Shuang, ZHU Qiucheng, SHI Yudan. Available transfer capability calculation of power systems based on MI-LSTM transmission line dynamic parameter modification [J]. Northeast Electric Power Technology, 2023, 44(11): 1-6.
- (本文责编:陆华)
-
- 收稿日期:2024-01-19;修回日期:2024-02-08
上网日期:2024-03-25;附录网址:www.ienergy.cn
- 作者简介:
徐聪(1989),女,博士后,博士,从事综合能源系统负荷预测、系统优化运行研究等方面的研究, xucong@chec.com.cn。