

DOI: 10.12158/j.2096-3203.2026.02.012

# 基于 BiGRU-PLE 的电冷热负荷短期联合预测

徐怡豪, 梅飞, 陆嘉华

(河海大学电气与动力工程学院, 江苏南京 211100)

**摘要:**准确的电、冷、热负荷预测是综合能源系统运行调度、能量管理的重要前提和基础。利用多元负荷之间存在能源耦合的特点,文中构建一种基于双向门控循环单元(bidirectional gated recurrent unit, BiGRU)以及渐进分层提取(progressive layered extraction, PLE)网络结构的多元负荷联合预测模型。首先,通过最大信息系数筛选相关性较高的气象特征作为模型输入特征;其次,利用BiGRU网络对综合能源系统下的多元负荷时间序列进行时间特征提取,并以此重构数据;然后,针对不同能源相互耦合的特点,提出改进的PLE网络结构,通过多级共享特征提取层,达到从复杂多维数据提取耦合特征的目的;最后,通过改变子任务塔模块结构参数,差异化选择耦合特征信息,输出得到多元负荷预测结果。实际算例结果表明,文中采用的最大信息系数筛选方法相比传统Pearson系数筛选方法更贴合气象数据的特征选择,且提出的BiGRU-PLE多元负荷联合预测模型相比单任务模型能够降低预测误差超5%,相比普通多任务模型能够降低预测误差超3%。

**关键词:**双向门控循环单元(BiGRU);最大信息系数;耦合特征提取;多元负荷预测;综合能源系统;多任务学习

中图分类号:TM715

文献标志码:A

文章编号:2096-3203(2026)02-0110-11

## 0 引言

为加快实现“碳达峰、碳中和”目标,推动我国能源革命进程,亟须建立低碳环保、灵活可调的能源供应体系<sup>[1-4]</sup>。以往的单一能源系统缺乏供能灵活性,很难适应当前我国发展需求。而综合能源系统(integrated energy system, IES)作为新兴能源耦合系统<sup>[5]</sup>,能够实现电、冷、热等多种异质能源的协调优化、耦合互补<sup>[6]</sup>。IES在提供社会多类型用能服务的同时,由于不同类型能量间的耦合特点,其运行特性更加复杂,显著增加了系统设备运行的优化调度难度,因而对IES各类负荷的精确预测提出了更高要求<sup>[7-9]</sup>。

在处理单一负荷预测问题方面,传统研究大多选用机器学习预测方法。在电负荷预测方面,文献[10]考虑负荷数据和气象信息等,通过改进果蝇优化算法和广义回归神经网络的平滑因数,提高了预测精度;在冷负荷预测方面,文献[11]利用关联度分析法剔除输入变量中关联度较低的因素,采用模拟退火算法对反向传播(back propagation, BP)神经网络的权值进行优化,得到冷负荷预测结果;在热负荷预测方面,文献[12]采用交叉验证确定粒子群算法的适应度值,并进一步确定最优的正则化系数和核宽度系数,再基于最小二乘支持向量机实现热负荷的高精度预测。目前,针对传统单一能源子系统负荷预测方法已取得较好的研究成果,但随着

IES的出现及逐步应用,这些预测方法无法很好地处理多元负荷间的耦合特性,因此仅适用于解决单一负荷预测问题<sup>[13]</sup>。

近年来,深度学习广泛应用于多元负荷预测研究,通过设置若干层非线性映射逐层学习大量数据中隐藏的抽象特征,能较好拟合输入与输出的非线性关系<sup>[14-16]</sup>。在多元负荷特征解耦方面,文献[17]借助混沌理论,采用C-C法对时间序列进行多变量相空间重构,挖掘电、冷、热负荷和气象特征在时间上的耦合特性;针对IES负荷间关联敏感性高、季节泛化性差导致的预测精度受限问题,文献[18]基于动态最大信息系数(maximal information coefficient, MIC)构造特征输入变量,并使用变分模态分解将其划分为多个任务避免整体分解带来的前瞻性偏差问题;文献[19]提出一种基于长短期记忆(long short term memory, LSTM)神经网络的编码器-解码器模型,同时构建多能负荷耦合特征矩阵反映电、冷、热负荷的交叉影响,采用梯度提升决策树构建模型的特征融合层,为研究负荷本质特征提供了多维视角;文献[20]基于变分模态分解和卷积神经网络挖掘负荷自身规律,再利用双向门控循环单元(bidirectional gated recurrent unit, BiGRU)网络得到预测结果,减少模型的计算复杂度;文献[21]将电、冷、热负荷单元依靠“像素重构”转为图像,再利用多通道卷积神经网络对重构后的二维负荷图像进行特征提取融合,最后将综合特征输入LSTM神经网络实现负荷准确预测。对于区域型IES的

收稿日期:2025-06-13;修回日期:2025-09-21

基金项目:国家重点研发计划资助项目(2022YFE0140600)

电、冷、热联合预测, 多任务学习<sup>[22-24]</sup>(multi-task learning, MTL)通过共享层对多元负荷间的复杂耦合信息进行特征提取从而提高预测精度。上述研究并未结合单一负荷和多元负荷分析耦合特性, 且对气象因素考虑不够全面, 未充分考虑体感温度等人体舒适度指标; 对于预测对象划分不够细致, 未区分工作日和周末等情况, 因此仍存在一定缺陷。

综上所述, 考虑到 IES 多个子系统之间交互性强、耦合复杂的特点, 针对负荷易受气象因素影响的问题, 文中提出一种基于 MIC 的 BiGRU-渐进分层提取(progressive layered extraction, PLE)多元负荷预测模型。首先, 通过 MIC 相关性分析筛选不同季节的气象特征, 同时将多元负荷时序数据输入 BiGRU 神经网络, 有效捕获时序数据自身的时间特征; 然后, 以时间特征重构的多元负荷数据为 PLE 网络结构的输入变量, 实现多元负荷固有的耦合信息共享; 最后, 利用子任务塔模块输出得到负荷预测结果。该预测模型通过共享外部信息, 能够充分学习多元负荷间的耦合特征, 以提高预测精度。

## 1 IES 用能特性与 MIC 相关性分析

### 1.1 IES 子能源特性

针对特殊的多元负荷耦合关系, 需要对每种负荷曲线单独进行分析。文中以亚利桑那州立大学 Tempe 校区的电、冷、热负荷为研究对象, 分析了电、冷、热典型工作日负荷曲线, 负荷数据时间步长为 15 min, 日负荷曲线如图 1—图 4 所示。

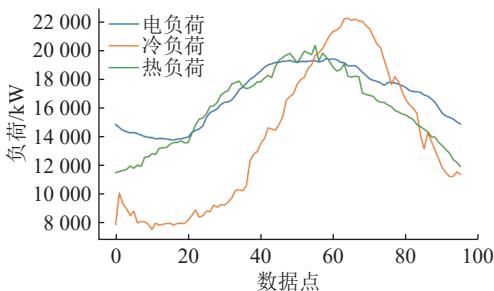


图 1 春季典型工作日负荷曲线

Fig.1 Load curves of typical spring weekday

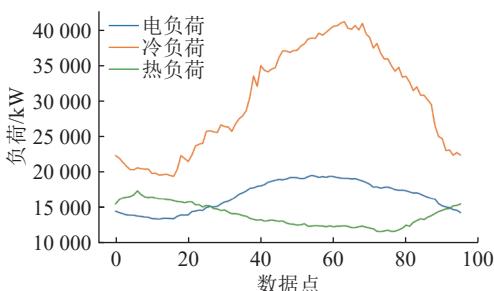


图 2 夏季典型工作日负荷曲线

Fig.2 Load curves of typical summer weekday

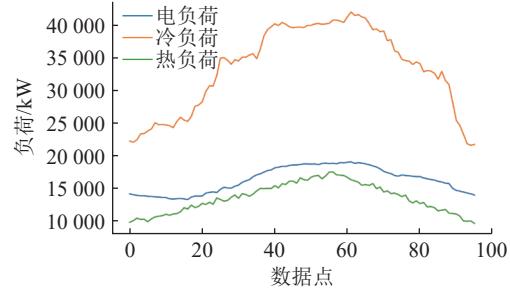


图 3 秋季典型工作日负荷曲线

Fig.3 Load curves of typical autumn weekday

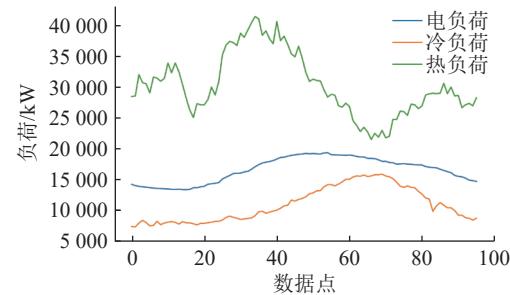


图 4 冬季典型工作日负荷曲线

Fig.4 Load curves of typical winter weekday

从图 1—图 4 可以得出, 春季电负荷和热负荷曲线的趋势比较相似, 呈现先升后降的特点, 而冷负荷有很大波动; 夏季和秋季的电负荷以及冷负荷走势相近, 而两季的热负荷走势则相反; 冬季电负荷和冷负荷变化比较平缓, 而热负荷变化幅度较大。由于该地为热带沙漠气候, 因此冷负荷在前三季都处于一个较高的水平, 热负荷只有在冬季才会用得比较多, 电负荷因具有明显的日周期规律性而全年趋势相对平稳。

### 1.2 MIC 相关性分析

MIC<sup>[25-26]</sup>最早于 2011 年提出, 属于最大的基于信息的非参数性探索, 其适用于衡量两个变量之间的关联程度, 常用于深度学习的特征选择。与 Pearson 线性相关性相比, MIC 基于互信息获得线性或非线性相关性, 通过计算样本的网格划分, 测量得到多个变量之间的复杂相关性, 为更准确的负荷预测特征选择奠定基础。该算法具有能够同时测量线性和非线性关系的优点, 计算复杂度低且具有良好的鲁棒性。具体表达式如下:

$$I_{\text{MIC}}(x, y) = \max_{\alpha, \beta < s} \left( \frac{\iint p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)}}{\log_2 \min(\alpha, \beta)} \right) \quad (1)$$

式中:  $I_{\text{MIC}}(x, y)$  为随机离散变量  $x$  和  $y$  之间的 MIC 值;  $\alpha, \beta$  分别为横轴网格和纵轴网格的个数;  $s$  为总网格数, 一般约为样本数量的 0.6 倍;  $p(x, y)$

为变量样本落在  $x$  和  $y$  所组成的网格中的概率;  $p(x)$ 、 $p(y)$  分别为  $x$ 、 $y$  的边缘概率分布函数。MIC 值的大小可直观反映两个变量的相关性大小, MIC 值大于 0.3, 表明两个变量之间具有很强的相关性; MIC 值小于 0.1, 表明两个变量之间相关性很弱; MIC 值介于两者之间则表明两个变量具有一定的相关性。

电、冷、热负荷实验的算例数据来源于亚利桑那州立大学 Tempe 校区的 IES, 气象因素初步考虑体表温度、气温、辐照度、湿度、平均风速、平均风向、气压、降水量, 气象数据从美国国家可再生能源实验室(NREL)官网采集。通过 MIC 相关性分析得到不同季节各负荷与气象因素的相关性大小, 如图 5—图 8 所示。

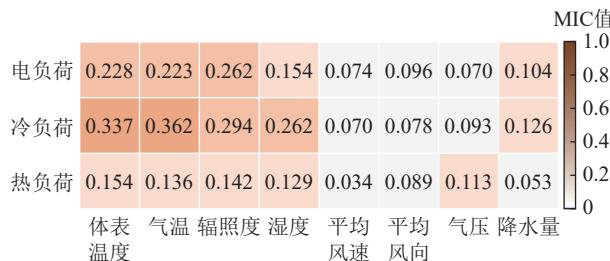


图 5 春季 MIC 热力图  
Fig.5 MIC heat map of spring



图 6 夏季 MIC 热力图  
Fig.6 MIC heat map of summer



图 7 秋季 MIC 热力图  
Fig.7 MIC heat map of autumn

图 5—图 8 显示出不同季节 3 种负荷与气象因素之间的 MIC 值, 揭示了 IES 中多元负荷与气象因素之间的季节差异性, 并且可以得出以下结论: (1) 在 IES 中, 多元负荷与气象因素之间存在明显的非线性关系; (2) 在不同季节, 电、冷、热负荷与气象因素之间的 MIC 相关性大小会发生变化。不同的

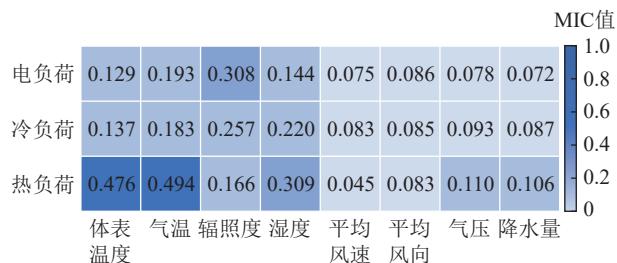


图 8 冬季 MIC 热力图

Fig.8 MIC heat map of winter

季节对应不同的负荷气象特征, 以春季为例, 对应的负荷气象特征为体表温度、气温、辐照度、湿度、降水量。通过季节性动态 MIC 相关性计算可以解决负荷易受气象因素影响、季节泛化性差的问题, 从而提高预测精度。

## 2 BiGRU 网络与 PLE 模型结构

### 2.1 BiGRU 神经网络

门控循环单元(gated recurrent unit, GRU)作为循环神经网络(recurrent neural network, RNN)结构的一种, 由 CHO K 等人在 2014 年提出<sup>[27]</sup>, 旨在解决标准 RNN 中出现的梯度消失问题, 并且 GRU 网络参数数量少, 训练时间短, 适用于大规模数据集。GRU 网络的基本结构如图 9 所示。

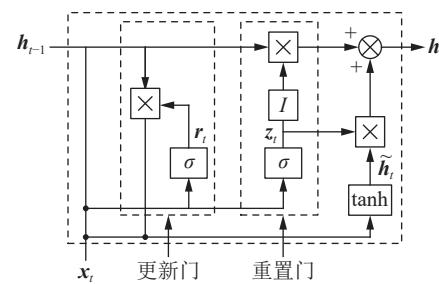


图 9 GRU 网络基本结构

Fig.9 Basic structure of GRU network

由图 9 可知, GRU 由更新门和重置门控制。其中,  $I$  为将重置门取反状态再加单位状态;  $z_t$ 、 $r_t$  分别为经过重置门和更新门后的状态向量, 重置门的计算公式为:

$$z_t = \sigma(W_z \otimes [h_{t-1}, x_t] + b_z) \quad (2)$$

更新门的计算公式为:

$$r_t = \sigma(W_r \otimes [h_{t-1}, x_t] + b_r) \quad (3)$$

从而得到新的候选状态的计算公式为:

$$\tilde{h}_t = \tanh(W_h \otimes [r_t \otimes h_{t-1}, x_t] + b_h) \quad (4)$$

更新隐藏状态的计算公式为:

$$h_t = (1 - z_t) \otimes h_{t-1} + z_t \otimes \tilde{h}_t \quad (5)$$

式中:  $W_z$ 、 $W_r$ 、 $W_h$  为权重矩阵;  $b_z$ 、 $b_r$ 、 $b_h$  分别为重置门、更新门控制器及候选状态的偏置项;  $\sigma$  为

Sigmoid 激活函数; tanh 为双曲正切激活函数;  $\otimes$  为对应元素相乘操作;  $[\mathbf{h}_{t-1}, \mathbf{x}_t]$  为当前时刻的隐藏状态和输入拼接而成的向量;  $\tilde{\mathbf{h}}_t$  为当前时刻的候选状态;  $\mathbf{h}_t$  为当前时刻的隐藏状态;  $\mathbf{x}_t$  为当前时刻的输入。

在 IES 的多元负荷预测中, 电、冷、热负荷是时变的, 与前一时刻  $\mathbf{x}_{t-1}$  的负荷高度相关, 并与下一时刻  $\mathbf{x}_{t+1}$  的负荷紧密相连。因此, 通过更深层次的 BiGRU 可以充分提取负荷之间的时间相关性。BiGRU 由正向和反向 GRU 组成, 其输出由两个 GRU 的状态共同确定。BiGRU 网络结构如图 10 所示。

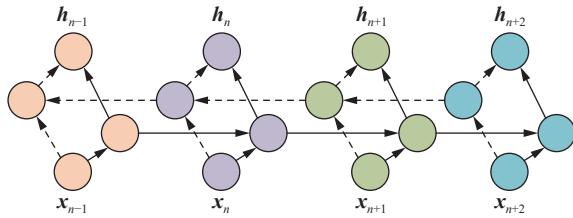


图 10 BiGRU 网络结构  
Fig.10 Structure of BiGRU network

BiGRU 的输出表示为  $\mathbf{H}$ , 步骤  $n$  的输出  $\mathbf{h}_n$  可以计算如下:

$$\mathbf{h}_n = B_i(\mathbf{H}_{n-1}, \mathbf{H}_n) \quad n \in [1, i] \quad (6)$$

式中:  $B_i$  为将  $i$  个 GRU 输出分别进行正向和反向连接;  $\mathbf{H}_n$  为 GRU 中正向的第  $n$  个输出。

## 2.2 PLE 特征提取网络

针对 IES 中能源转换设备多样、能量转换过程复杂, 且各能源子系统通过能量转换元件(热电联产单元、燃气锅炉等)以能量流的形式紧密耦合的特性, 需要对其进行特征信息提取。由于历史负荷数据中存在大量能量转换共享信息, 而这些能量转换特征很难用传统的人工特征提取方法概括, 且电、冷、热负荷之间有较强的耦合关系, 对多元负荷单独进行预测往往会忽略该关系, 从而影响预测精度。因此, 在 MTL 过程中, 文中采用一种具有新颖共享结构设计的 PLE 网络结构以共享特征信息, 从而有效利用能量转换过程中的复杂耦合特性<sup>[28]</sup>。PLE 网络结构如图 11 所示。

图 11 中,  $E_{A_{N,M}}, E_{B_{N,M}}, E_{C_{N,M}}$  分别为在第  $N$  层第  $M$  个专家网络模块 A、B、C;  $E_{S_{N,M}}$  为在第  $N$  层第  $M$  个共享专家网络模块 S;  $T_{A,N_A}, T_{B,N_B}, T_{C,N_C}$  分别为第  $N$  层任务塔模块  $T_A, T_B, T_C$ 。从图 11 可以看出, 在底层的特征提取网络中, 除了各个面向子任务的专家网络外, 还包含一个共享专家网络, 该专家网络的输入包含所有的原始输入, 而各个子任务的输入由特定专家网络和共享专家网络两部分

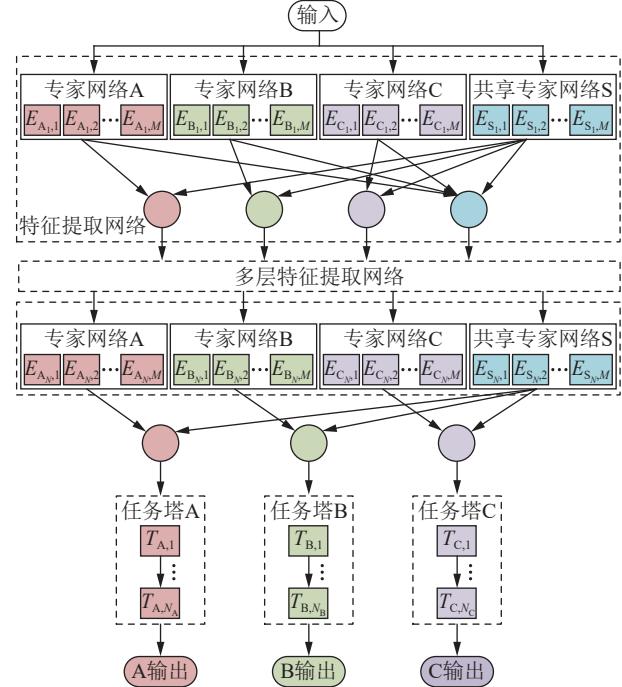


图 11 PLE 网络结构

Fig.11 Structure of PLE network

组成。并且在上层特征提取网络中, 输入的不再是原始输入向量, 而是上一层特征提取网络各输出结果的融合。任务  $k$  在第  $j$  层的输出为:

$$\mathbf{g}_{k,j}(x) = \omega_{k,j}(\mathbf{g}_{k,j-1}(x))\mathbf{S}_{k,j}(x) \quad (7)$$

式中:  $\omega_{k,j}(\cdot)$  为任务  $k$  在第  $j$  层的参数向量, 使用其下层的输出向量作为输入;  $\mathbf{S}_{k,j}(x)$  为任务  $k$  在第  $j$  层选择的专家组。最终任务  $k$  的预测为:

$$y_k(x) = t_k(\mathbf{g}_{k,N}(x)) \quad (8)$$

式中:  $t_k(\cdot)$  为任务  $k$  上面向任务的塔;  $\mathbf{g}_{k,N}(x)$  为任务  $k$  在第  $N$  层的专家组选择输出向量。在 MTL 中, 使用多个任务的优化目标共同训练, 其损失函数为各子任务损失的加权求和:

$$L_k(\theta_1, \dots, \theta_k, \theta_s) = \sum_{a=1}^k \omega_a L_a(\theta_a, \theta_s) \quad (9)$$

式中:  $L_k(\theta_1, \dots, \theta_k, \theta_s)$  为总损失函数;  $L_a(\theta_a, \theta_s)$  为第  $a$  个子任务的损失函数;  $\theta_a$  为第  $a$  个子任务的预测数据归一化值;  $\theta_s$  为原样本数据归一化值;  $\omega_a$  为第  $a$  个子任务的损失函数权重。权重的公式如下:

$$\omega_{a,T} = \omega_{a,0} \gamma_{a,T} \quad (10)$$

式中:  $\omega_{a,T}$  为第  $a$  个子任务在训练轮数  $T$  之后的损失函数权重;  $\omega_{a,0}$  为第  $a$  个子任务未训练前的损失函数权重;  $\gamma_{a,T}$  为第  $a$  个子任务在训练轮数  $T$  对应的更新率。

在特征提取网络的实际运用中, 将电、冷、热负荷数据分别输入专家网络 A、B、C 以提取各自负荷的特征信息, 同时将 3 种负荷数据共同输入共享

专家网络 S 以提取多元负荷之间的耦合特征信息,之后将两种特征信息拼接到同一维度。通过 3 个特定专家网络和 1 个共享专家网络输出的特征信息,拼接得到 3 个新的专家网络单元和 1 个共享专家网络单元,以此类推得到多层特征提取网络。此过程在处理相关性复杂的 IES 多元负荷预测问题时,利用分离的共享网络和特定任务网络,逐层学习和解耦多元负荷之间的耦合信息,因此提高了一般多任务机制中联合表征学习和信息路由的效率,使得模型预测准确性进一步提升,同时增强了泛化能力。

### 3 多元负荷预测模型

#### 3.1 MTL 预测模型

MTL 是一种经典的归纳迁移机制,可以通过共享层学习其他子任务提供的辅助耦合信息来并行训练多个子任务<sup>[29-30]</sup>。在 IES 中,传统的人工特征提取方法难以处理海量数据,而 MTL 可以并行处理和学习多个相关问题的信息,更有效地利用信息中共享的能量转换特征,挖掘多能耦合关系。考虑到电、冷、热负荷之间的强相关性,一般采用 MTL 的硬共享机制,即底层参数统一共享,顶层参数独立。将多元负荷预测函数定义为:

$$\mathbf{y}_t = f_t(\mathbf{x}_t, W_{sh}, W_t) \quad (11)$$

式中:  $\mathbf{y}_t$  为  $t$  时刻的输出;  $f_t$  为  $t$  时刻由输入变量和参数变量构成的多变量组合函数;  $W_{sh}$  为由不同任务共享的参数;  $W_t$  为  $t$  时刻与任务相关的参数。基于此,MTL 的总体优化损失函数可以定义为:

$$\min \sum_{a=1}^3 \omega_a L_a(W_{sh}, W_t) \quad (12)$$

同时可以获得共享参数  $W_{sh}$  的更新为:

$$\widetilde{W}_{sh} = W_{sh} - \lambda \left( \sum_{a=1}^3 \omega_a \frac{\partial L_a}{\partial W_{sh}} \right) \quad (13)$$

式中:  $\lambda$  为学习率。

不同类型能源的物理动力学和需求特性差异较大,导致负荷的波动性不同。文中热负荷曲线局部波动大,上下浮动明显,而电、冷负荷曲线相对平滑。由于预测模型同一顶层结构无法同时考虑不同负荷曲线波动特征,3 种负荷难以同时达到良好的拟合状态。因此,采用 3 种不同结构参数的任务塔作为输出模块,使得 3 种负荷同时收敛到最优。

#### 3.2 基于 MIC 的 BiGRU-PLE 多元负荷预测模型

文中提出的基于 MIC 的 BiGRU-PLE 多元负荷预测方法如图 12 所示。将 IES 中的电、冷、热负荷时序数据分别输入 BiGRU 模型,对电、冷、热负荷

时间相关性进行量化处理,得到带有时间特征的状态输出,作为 PLE 特征提取网络的输入;通过多层的 PLE 网络结构并行学习多元负荷之间的耦合特征信息,有效处理耦合关系复杂的多元负荷时序数据;最后由子任务塔模块得到多元负荷预测结果。综合上述分析,基于 MIC 的 BiGRU-PLE 电、冷、热负荷联合预测方法步骤如下。

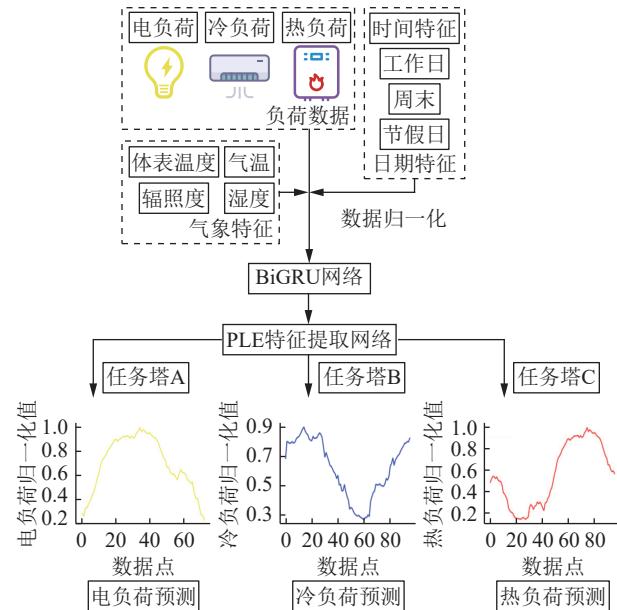


图 12 基于 MIC-BiGRU-PLE 的多元负荷预测方法

Fig.12 MIC-BiGRU-PLE-based multivariate load forecasting method

(1) 首先对得到的 IES 电、冷、热负荷数据进行归一化等预处理工作,并从定性角度选择对预测结果有干扰的气象因素:体表温度、气温、辐照度、湿度、平均风速、平均风向、气压、降水量。关于时间日期特征的信息包括时间特征(年、月、日、时、分)以及工作日、周末、节假日等。时间日期特征按表 1 进行编码。

表 1 时间日期特征符号及含义  
Table 1 Symbols and meanings of time and date features

特征	符号	含义
年	$Y$	预测点的公历年份
月	$M$	预测点的公历月份
日	$D$	预测点的公历日期
时	$H$	预测点时刻的小时数
分	$F$	预测点时刻的分钟数
工作日	$W$	预测点所属日是否属于工作日类型
周末	$R$	预测点所属日是否属于周末类型
节假日	$O$	预测点所属日是否属于节假日类型

(2) 通过 MIC 方法分析全年四季电、冷、热负荷与气象因素的相关性,由于文中是电、冷、热负

荷的联合预测,需要统一考虑气象因素对这3种负荷的影响。因此对于某一特定气象因素,若与电、冷、热负荷的相关性中有两项大于0.1,则将此气象因素视为有一定相关性,筛选为模型的输入特征;反之则视为弱相关性,不作为模型的输入特征。通过上述方法最终筛选得到的模型气象特征如表2所示。

表2 不同季节 MIC 值筛选出的气象特征

Table 2 Meteorological features screened by MIC values in different seasons

气象因素	春季	夏季	秋季	冬季
体表温度	1	1	1	1
气温	1	1	1	1
辐照度	1	1	1	1
湿度	1	1	1	1
平均风速	0	0	0	0
平均风向	0	0	0	0
气压	0	0	0	0
降水量	1	0	0	0

注:“1”表示筛选为模型的气象特征;“0”表示不作为模型的气象特征。

(3) 将电、冷、热负荷及相关特征影响因素的时间序列数据进行归一化后输入 BiGRU-PLE 多元负荷预测模型中,其中特定专家网络负责提取单一负荷的特征信息,共享专家网络负责提取多元负荷之间的耦合特征信息,将这两种特征信息拼接到同一维度实现特征信息共享。对选定的典型日中的3种负荷进行联合预测,同时调整任务塔输出模块结构参数,使得3种负荷的总体优化损失函数最小。

(4) 将得到的预测结果进行反归一化后计算各评价指标,并与不同模型预测效果进行对比,判断预测结果准确性是否符合要求,从而验证文中所提模型的有效性。

## 4 算例分析

### 4.1 数据采集和处理

文中以亚利桑那州立大学的 Tempe 校区为研究对象,分析电、冷、热负荷之间存在的耦合特点。该校区拥有 288 栋建筑、5 万多名学生和 73 190 块太阳能光伏板。实验算例数据来源于 Tempe 校区的 IES 电、冷、热负荷数据以及 NREL 官网上的气象数据,气象因素初步考虑体表温度、气温、辐照度、湿度、平均风速、平均风向、气压、降水量,日历规则考虑工作日、周末及节假日情况。数据选取自 2017 年 1 月 1 日—2018 年 12 月 31 日,每 15 min 采集一次数据,按 7 : 2 : 1 划分为训练集、验证集

和测试集。

### 4.2 评价指标

鉴于文中搭建的多元负荷预测模型需要在同一时间段内对多种负荷类型进行结果分析,因此文中选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)作为评价指标。具体表达式如下:

$$E_{\text{MAPE}} = \frac{1}{m} \sum_{c=1}^m \left| \frac{\hat{y}_c - y_c}{y_c} \right| \times 100\% \quad (14)$$

$$E_{\text{RMSE}} = \sqrt{\frac{\sum_{c=1}^m (y_c - \hat{y}_c)^2}{m}} \quad (15)$$

$$E_{\text{MAE}} = \frac{1}{m} \sum_{c=1}^m |\hat{y}_c - y_c| \quad (16)$$

式中:  $y_c$  为样本  $c$  的实际值;  $\hat{y}_c$  为样本  $c$  的预测值;  $m$  为参与计算的样本数量。

### 4.3 模型参数设置

模型的结构设计及超参数取值会直接影响预测结果的准确率,为得到文中模型的最优结构参数,采用控制变量法确定 BiGRU 网络参数和 PLE 网络参数的值。

由于文中是电、冷、热负荷联合预测,因此需要设置 3 个子任务模块和 1 个共享模块。经实验可得,将特征提取网络设置为 2 层最佳,用以提取和共享负荷间的耦合信息。对于顶层任务塔输出模块,设置电负荷和冷负荷预测模块隐藏层为 2 层,每层隐藏层大小为 32 个神经元,而热负荷预测模块隐藏层为 1 层,隐藏层大小为 64 个神经元;设置 Dropout 层的失活率为 0.1,以避免过拟合;选用 Sigmoid 作为激活函数。BiGRU 网络和 PLE 网络的超参数设置分别如表 3、表 4 所示。

表3 BiGRU 网络参数设置

Table 3 Parameter setting of BiGRU network

BiGRU 网络超参数	数值
隐藏层数	2
隐藏层神经元个数	32
失活率	0.2

### 4.4 预测结果对比分析

为验证基于 MIC 的 BiGRU-PLE 模型预测的准确性,将文中所提模型与另外 4 组预测模型进行对照分析。4 组对照模型分别为 LSTM 模型、BiGRU-MTL 模型、BiGRU-PLE 模型以及 Pearson-BiGRU-PLE 模型。前 3 组对照模型不经过气象特征筛选,第 4 组对照模型经过 Pearson 相关性系数筛选气象

表 4 PLE 网络参数设置

Table 4 Parameter setting of PLE network

PLE网络超参数	数值
特征提取层层数	2
失活率	0.1
学习率	0.001
优化求解器	Adam
目标损失函数	Huber Loss
限制迭代次数	150
批样本数量	128

特征。实验选取夏季和冬季的典型工作日和典型周末作为预测场景,对每个场景进行未来 24 h 的多点预测,采样间隔为 15 min,共 96 个预测点。最后根据电、冷、热负荷预测结果计算评价指标。

#### 4.4.1 电负荷预测效果分析

在夏季电负荷预测中,选取 2018 年 8 月 1 日为典型工作日,2018 年 8 月 4 日为典型周末;在冬季电负荷预测中,选取 2018 年 12 月 1 日为典型周末,2018 年 12 月 3 日为典型工作日。电负荷预测结果和评价指标如图 13—图 16 和表 5 所示。

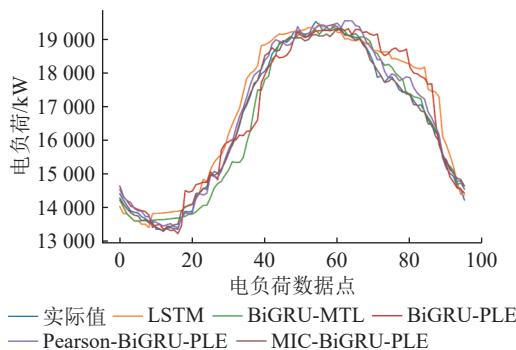


图 13 夏季典型工作日电负荷预测曲线

Fig.13 Electric load forecast curves of typical summer weekday

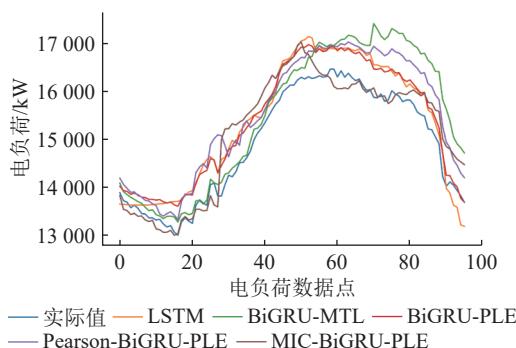


图 14 夏季典型周末电负荷预测曲线

Fig.14 Electric load forecast curves of typical summer weekend

在电负荷预测曲线中可以看到,季节的更替对电负荷需求的影响不大,并且周末用电比工作日用

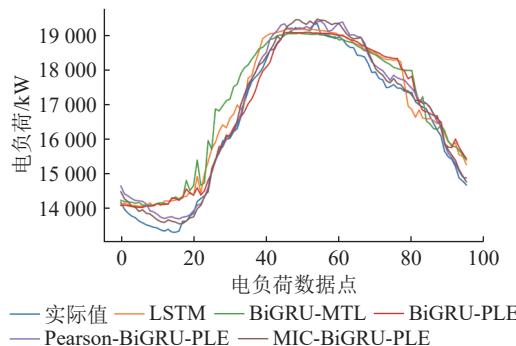


图 15 冬季典型工作日电负荷预测曲线

Fig.15 Electric load forecast curves of typical winter weekday

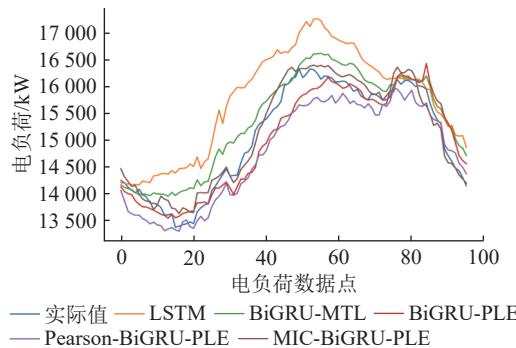


图 16 冬季典型周末电负荷预测曲线

Fig.16 Electric load forecast curves of typical winter weekend

表 5 电负荷预测评价指标

Table 5 Evaluation indexes of electrical load forecasting

预测模型	MAPE/%	RMSE/kW	MAE/kW
LSTM	8.943	903.843	804.843
BiGRU-MTL	7.462	861.347	717.843
BiGRU-PLE	7.164	749.247	657.757
Pearson-BiGRU-PLE	6.331	696.752	603.397
MIC-BiGRU-PLE	5.864	619.934	529.164

电稍微偏低;在模型预测方面,典型工作的预测准确性普遍高于典型周末,工作日用电习惯更加规律,易提取并学习其中的信息特征,模型训练拟合效果更好。从计算预测评价指标可以得到,与 LSTM 单任务学习模型相比,MTL 模型对复杂多维数据的特征学习能力更强,BiGRU-MTL 模型相较于 LSTM 模型 MAPE 降低了 16.56%;而 BiGRU-PLE 模型比 BiGRU-MTL 模型 MAPE 下降了 3.99%,说明通过 PLE 特征提取网络可以更好地得到负荷间的耦合特征,实现特征信息的共享;Pearson-BiGRU-PLE 模型相较于 BiGRU-PLE 模型 MAPE 降低了 11.63%;文中所提模型通过 MIC 相关性分析筛选重要的气象特征作为模型输入,相较于 Pearson-BiGRU-PLE 模型 MAPE 降低了 7.38%。综上,文中所提模型相

较于其他对照模型在电负荷预测准确率方面有一定程度提升。

#### 4.4.2 冷负荷预测效果分析

在夏季冷负荷预测中,选取2018年8月1日为典型工作日,2018年8月4日为典型周末;在冬季冷负荷预测中,选取2018年12月1日为典型周末,2018年12月3日为典型工作日。冷负荷预测结果和评价指标如图17—图20和表6所示。

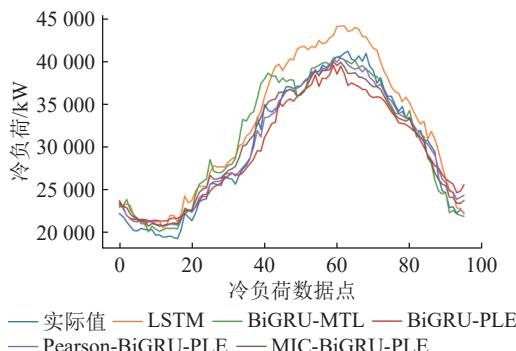


图 17 夏季典型工作日冷负荷预测曲线  
Fig.17 Cooling load forecast curves of typical summer weekday

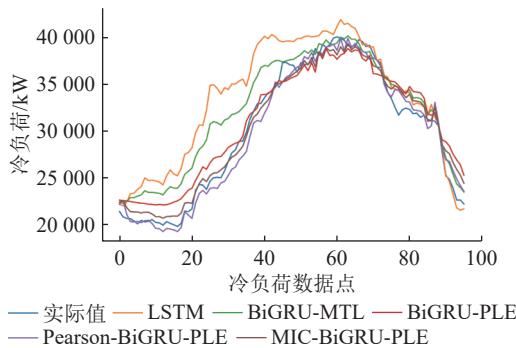


图 18 夏季典型周末冷负荷预测曲线  
Fig.18 Cooling load forecast curves of typical summer weekend

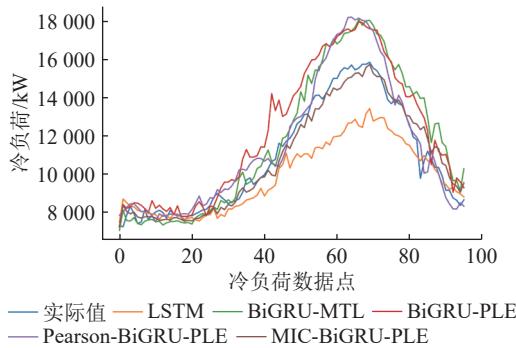


图 19 冬季典型工作日冷负荷预测曲线  
Fig.19 Cooling load forecast curves of typical winter weekday

在冷负荷预测曲线中可以看到,季节的更替对冷负荷需求的影响很大,夏季高温干燥,冷负荷需求量显著提升,冬季温度下降,冷负荷需求量也随

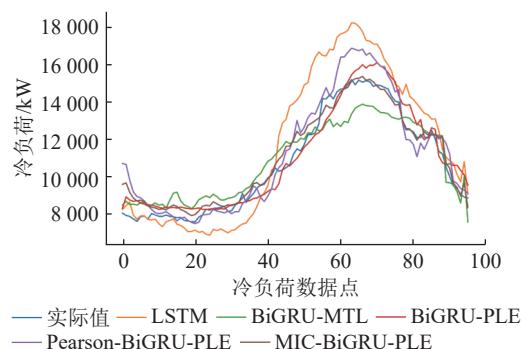


图 20 冬季典型周末冷负荷预测曲线

Fig.20 Cooling load forecast curves of typical winter weekend

表 6 冷负荷预测评价指标

Table 6 Evaluation indexes of cooling load forecasting

预测模型	MAPE/%	RMSE/kW	MAE/kW
LSTM	10.764	2 753.394	2 056.986
BiGRU-MTL	8.724	1 862.422	1 386.739
BiGRU-PLE	7.424	1 535.281	1 237.711
Pearson-BiGRU-PLE	6.358	985.360	728.471
MIC-BiGRU-PLE	5.935	924.517	654.179

之降低;冷负荷在周末和工作日的用量水平基本相当。在模型预测方面,夏季典型日的预测准确性普遍高于冬季典型日,由于夏季冷负荷用量很大,因此规律性呈现更加明显,易被模型学习提取变化特性,模型训练拟合效果较好。从计算预测评价指标可以看到,与 LSTM 单任务学习模型相比, BiGRU-MTL 模型的 MAPE 降低了 18.95%; BiGRU-PLE 模型比 BiGRU-MTL 模型 MAPE 降低了 14.90%, 表明建立合理的多任务信息共享机制可有效提取 IES 的多元负荷耦合信息;与 BiGRU-PLE 模型相比, Pearson-BiGRU-PLE 模型的 MAPE 降低了 14.36%, 说明合理的气象特征筛选可提高预测准确率;文中模型的气象特征经过 MIC 筛选,相较于 Pearson 相关性分析的 BiGRU-PLE 模型 MAPE 降低了 6.65%, 证明文中所提模型在冷负荷预测准确率方面有较大提升。

#### 4.4.3 热负荷预测效果分析

在夏季热负荷预测中,选取2018年8月1日为典型工作日,2018年8月4日为典型周末;在冬季热负荷预测中,选取2018年12月1日为典型周末,2018年12月3日为典型工作日。热负荷预测结果和评价指标如图21—图24和表7所示。

在热负荷预测曲线中可以看到,季节的更替对热负荷需求的影响同样很大,夏季热负荷需求量较低,冬季热负荷需求量有很大提高,热负荷在周末

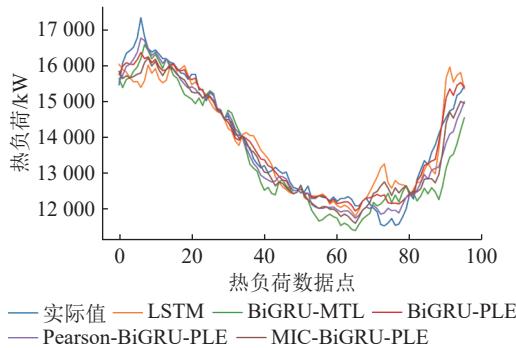


图 21 夏季典型工作日热负荷预测曲线

Fig.21 Heat load forecast curves of typical summer weekday

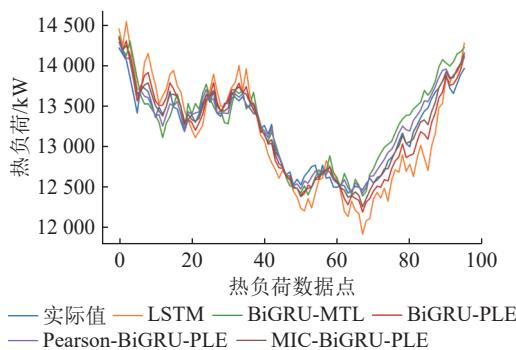


图 22 夏季典型周末热负荷预测曲线

Fig.22 Heat load forecast curves of typical summer weekend

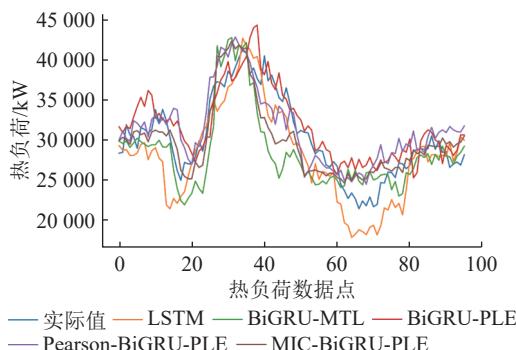


图 23 冬季典型工作日热负荷预测曲线

Fig.23 Heat load forecast curves of typical winter weekday

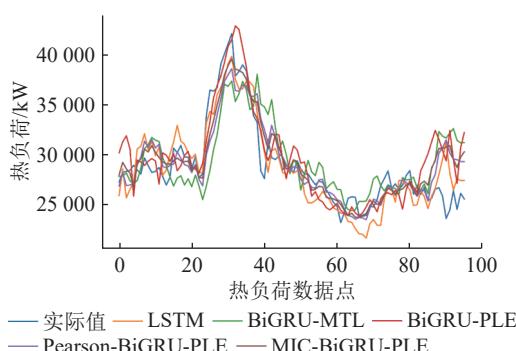


图 24 冬季典型周末热负荷预测曲线

Fig.24 Heat load forecast curves of typical winter weekend

表 7 热负荷预测评价指标

Table 7 Evaluation indexes of heat load forecasting

预测模型	MAPE/%	RMSE/kW	MAE/kW
LSTM	9.975	2 745.342	2 284.737
BiGRU-MTL	7.885	2 429.394	1 939.046
BiGRU-PLE	6.474	2 178.737	1 661.754
Pearson-BiGRU-PLE	6.159	1 981.573	1 569.924
MIC-BiGRU-PLE	6.031	1 942.741	1 536.847

比在工作日略有下降。在模型预测方面,文中所提模型在热负荷预测准确率方面提升较小,相比BiGRU-PLE模型MAPE预测精度仅提升6.84%,这与数据收集地区的环境因素有很大关系。亚利桑那州立大学处于热带沙漠气候,常年高温干燥,一年中大部分时间都处于夏季,冷负荷需求显著高于电负荷和热负荷,而夏季的热负荷属于刚性负荷,需求较少且相对固定,负荷曲线虽然小突变较多但走势较稳定,与电、冷负荷的相关性不强,因此基于历史时间序列数据对于热负荷预测精度的提升相对较低。

## 5 结论

针对IES存在的多类子能源交互耦合特点,文中提出一种基于MIC相关性分析的BiGRU-PLE多元负荷预测模型。该模型通过MIC理论筛选得到相关性高的气象特征作为模型输入,利用BiGRU网络对多元负荷时间序列提取时间特征并重构时序数据,将所得结果输入PLE网络结构,并行学习多元负荷之间的耦合特征信息,通过2层特征提取网络和3个特定结构参数的子任务塔输出模块,得到多元负荷预测结果,避免了冗余信息对预测过程的干扰,从而提高了多元负荷预测的准确性。通过算例分析可以得出以下结论:

(1) 电、冷、热负荷与气象因素特征、时间日期特征之间具有很强的相关性,影响程度各不相同。经过MIC值筛选后将相关性较高的气象特征输入模型,预测精度可以得到一定提升,证明了基于MIC相关性分析的输入特征选择的有效性。

(2) 在3种负荷的预测结果中,电负荷在时间维度上具有显著的周期规律性,受外界因素影响最小,故预测精度最高。而冷、热负荷易受气候环境因素的影响,数据曲线会产生较大的突变和波动,因此模型训练学习效果不如电负荷,导致预测精度有所降低。

(3) 文中提出的MIC-BiGRU-PLE组合模型预测精度相对最高,证明PLE网络结构能够充分学习

并共享多元负荷之间的耦合信息,相较于传统预测模型更能体现其显著优势。

文中在考虑 IES 多元负荷的影响因素时,并未涉及极端外部环境影响导致的负荷突变,此外,电动汽车的大规模使用也是影响负荷变化的重要因素,在后续研究工作中会将以上作为研究重点。

#### 参考文献:

- [1] 张沈习,王丹阳,程浩忠,等.双碳目标下低碳综合能源系统规划关键技术及挑战[J].电力系统自动化,2022,46(8): 189-207.  
ZHANG Shenxi, WANG Danyang, CHENG Haozhong, et al. Key technologies and challenges of low-carbon integrated energy system planning for carbon emission peak and carbon neutrality[J]. Automation of Electric Power Systems, 2022, 46(8): 189-207.
- [2] 宋晓通,师芊芊,巨云涛,等.综合能源系统低碳规划与运行研究述评[J].高电压技术,2024,50(3): 1053-1066.  
SONG Xiaotong, SHI Qianqian, JU Yuntao, et al. Review on low-carbon planning and operation of integrated energy system[J]. High Voltage Engineering, 2024, 50(3): 1053-1066.
- [3] 杨佳霖,赵鹏翔,窦真兰,等.计及经济性与可靠性的综合能源系统优化调度[J].供用电,2024,41(1): 90-99.  
YANG Jialin, ZHAO Pengxiang, DOU Zhenlan, et al. Optimal scheduling of integrated energy systems considering economy and reliability[J]. Distribution & Utilization, 2024, 41(1): 90-99.
- [4] 郭尊,安之,魏楠,等.计及氢能多环节利用和混合需求响应的综合能源系统多时间尺度低碳优化[J].供用电,2024,41(2): 52-63,72.  
GUO Zun, AN Zhi, WEI Nan, et al. Multi-time scale low-carbon optimization of an integrated energy system considering the multi-link utilization of hydrogen energy and mixed demand response[J]. Distribution & Utilization, 2024, 41(2): 52-63,72.
- [5] 韩富佳,王晓辉,乔骥,等.基于人工智能技术的新型电力系统负荷预测研究综述[J].中国电机工程学报,2023,43(22): 8569-8592.  
HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8592.
- [6] 黎静华,朱梦姝,陆悦江,等.综合能源系统优化调度综述[J].电网技术,2021,45(6): 2256-2272.  
LI Jinghua, ZHU Mengshu, LU Yuejiang, et al. Review on optimal scheduling of integrated energy systems[J]. Power System Technology, 2021, 45(6): 2256-2272.
- [7] 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): 698-707.  
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 Technol-
- ogy, 2018, 42(3): 698-707.
- [8] 吕金玲,王小君,窦嘉铭,等.考虑运行状态信息的综合能源系统图强化学习优化调度[J].电力系统保护与控制,2024,52(2): 1-14.  
LÜ Jinling, WANG Xiaojun, DOU Jiaming, et al. Optimal dispatch of an integrated energy system based on graph reinforcement learning considering operation state information[J]. Power System Protection and Control, 2024, 52(2): 1-14.
- [9] 李鹏,罗湘淳,孟庆伟,等.基于 Spearman 相关性阈值寻优和 VMD-LSTM 的用户级综合能源系统超短期负荷预测[J].全球能源互联网,2024,7(4): 406-420.  
LI Peng, LUO Xiangchun, MENG Qingwei, et al. Ultra short-term load forecasting of user level integrated energy system based on Spearman threshold optimization and variational mode decomposition and long short-term memory[J]. Journal of Global Energy Interconnection, 2024, 7(4): 406-420.
- [10] 祝学昌.基于 IFOA-GRNN 的短期电力负荷预测方法研究[J].电力系统保护与控制,2020,48(9): 121-127.  
ZHU Xuechang. Research on short-term power load forecasting method based on IFOA-GRNN[J]. Power System Protection and Control, 2020, 48(9): 121-127.
- [11] 黄馨乐,于军琪,赵安军.基于 GRA-SA-BP 神经网络算法的商场空调冷负荷预测模型[J].建设科技,2020(24): 113-116.  
HUANG Xinle, YU Junqi, ZHAO Anjun. Cold load prediction model of shopping mall air conditioning based on GRA-SA-BP neural network algorithm[J]. Construction Science and Technology, 2020(24): 113-116.
- [12] 赵秉文,李婉,金宇.基于 PSO-LSSVM 的供热负荷预测研究[J].建筑节能,2021,49(6): 46-49,78.  
ZHAO Bingwen, LI Wan, JIN Yu. Heating load prediction based on PSO-LSSVM[J]. Building Energy Efficiency, 2021, 49(6): 46-49,78.
- [13] 王丹,李宜哲,贾宏杰,等.面向广义能量品质分析的多能耦合流集线器建模[J].电力系统自动化,2023,47(24): 52-62.  
WANG Dan, LI Yizhe, JIA Hongjie, et al. Multi-energy coupled flow hub modeling for generalized energy quality analysis[J]. Automation of Electric Power Systems, 2023, 47(24): 52-62.
- [14] 王淞瑶,张智晟.基于量子加权多层次级 GRU 神经网络的综合能源系统多元负荷短期预测[J].电力系统保护与控制,2022,50(23): 85-93.  
WANG Songyao, ZHANG Zhisheng. Short-term multivariate load forecasting of an integrated energy system based on a quantum weighted multi-hierarchy gated recurrent unit neural network[J]. Power System Protection and Control, 2022, 50(23): 85-93.
- [15] 涂伟权,李辉,万铮.基于组合相关系数的综合能源系统多元负荷短期预测研究[J].发电技术,2025,46(1): 9-18.  
TU Weiquan, LI Hui, WAN Zheng. Research on short-term forecasting of multiple loads in integrated energy systems based on composite correlation coefficients[J]. Power Generation Technology, 2025, 46(1): 9-18.

- [16] 李楠, 姜涛, 隋想, 等. 一种时频尺度下的多元短期电力负荷组合预测方法[J]. 电力系统保护与控制, 2024, 52(13): 47-58.  
LI Nan, JIANG Tao, SUI Xiang, et al. A multi-component short-term power load combination forecasting method on a time-frequency scale[J]. Power System Protection and Control, 2024, 52(13): 47-58.
- [17] 窦真兰, 张春雁, 许一洲, 等. 基于多变量相空间重构和径向基函数神经网络的综合能源系统电冷热超短期负荷预测[J]. 电网技术, 2024, 48(1): 121-133.  
DOU Zhenlan, ZHANG Chunyan, XU Yizhou, et al. Ultra-short-term load forecasting of electrical, cooling and heating for integrated energy system based on multivariate phase space reconstruction and radial basis function neural network[J]. Power System Technology, 2024, 48(1): 121-133.
- [18] 黄璜, 张安安. 基于分解算法与元学习结合的综合能源系统负荷预测[J]. 电力系统自动化, 2024, 48(10): 151-160.  
HUANG Huang, ZHANG An'an. Load forecasting of integrated energy system based on combination of decomposition algorithms and meta-learning[J]. Automation of Electric Power Systems, 2024, 48(10): 151-160.
- [19] WANG S M, WANG S X, CHEN H W, et al. Multi-energy load forecasting for regional integrated energy systems considering temporal dynamic and coupling characteristics[J]. Energy, 2020, 195: 116964.
- [20] 杨胡萍, 余阳, 汪超, 等. 基于 VMD-CNN-BIGRU 的电力系统短期负荷预测[J]. 中国电力, 2022, 55(10): 71-76.  
YANG Huping, YU Yang, WANG Chao, et al. Short-term load forecasting of power system based on VMD-CNN-BIGRU[J]. Electric Power, 2022, 55(10): 71-76.
- [21] 栗然, 孙帆, 丁星, 等. 考虑多能时空耦合的用户级综合能源系统超短期负荷预测方法[J]. 电网技术, 2020, 44(11): 4121-4134.  
LI Ran, SUN Fan, DING Xing, et al. Ultra short-term load forecasting for user-level integrated energy system considering multi-energy spatio-temporal coupling[J]. Power System Technology, 2020, 44(11): 4121-4134.
- [22] LI K, MU Y C, YANG F, et al. A novel short-term multi-energy load forecasting method for integrated energy system based on feature separation-fusion technology and improved CNN[J]. Applied Energy, 2023, 351: 121823.
- [23] GUO Y X, LI Y, QIAO X B, et al. BiLSTM multitask learning-based combined load forecasting considering the loads coupling relationship for multienergy system[J]. IEEE Transactions on Smart Grid, 2022, 13(5): 3481-3492.
- [24] 王永利, 刘泽强, 董焕然, 等. 基于 CEEMDAN-CSO-LSTM-MTL 的综合能源系统多元负荷预测[J]. 电力建设, 2025, 46(1): 72-85.  
WANG Yongli, LIU Zeqiang, DONG Huanran, et al. Multivariate load forecasting of integrated energy system based on CEEMDAN-CSO-LSTM-MTL[J]. Electric Power Construction, 2025, 46(1): 72-85.
- [25] 崔树银, 汪昕杰. 基于最大信息系数和多目标 Stacking 集成学习的综合能源系统多元负荷预测[J]. 电力自动化设备, 2022, 42(5): 32-39, 81.  
CUI Shuyin, WANG Xinjie. Multivariate load forecasting in integrated energy system based on maximal information coefficient and multi-objective Stacking ensemble learning[J]. Electric Power Automation Equipment, 2022, 42(5): 32-39, 81.
- [26] 于越, 葛磊蛟, 金朝阳, 等. 考虑天气特征与多变量相关性的配电网短期负荷预测[J]. 电力系统保护与控制, 2024, 52(6): 131-141.  
YU Yue, GE Leijiao, JIN Zhaoyang, et al. Short-term load prediction method of distribution networks considering weather features and multivariate correlations[J]. Power System Protection and Control, 2024, 52(6): 131-141.
- [27] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar. Stroudsburg, PA, USA: ACL, 2014: 1724-1734.
- [28] TANG H Y, LIU J N, ZHAO M, et al. Progressive layered extraction (PLE): a novel multi-task learning (MTL) model for personalized recommendations[C]//Fourteenth ACM Conference on Recommender Systems. Virtual Event Brazil. ACM, 2020: 269-278.
- [29] 秦烁, 赵健, 徐剑, 等. 基于多任务学习和单任务学习组合模型的综合能源系统多元负荷预测[J]. 电网技术, 2024, 48(4): 1510-1522.  
QIN Shuo, ZHAO Jian, XU Jian, et al. Multivariate-load forecasting of integrated energy system based on combined multi-task learning and single-task learning model[J]. Power System Technology, 2024, 48(4): 1510-1522.
- [30] 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.

## 作者简介：



徐怡豪

徐怡豪(1999),男,硕士在读,研究方向为综合能源系统负荷预测(E-mail: [xyh19990403@163.com](mailto:xyh19990403@163.com));

梅飞(1982),男,博士,高级工程师,研究方向为电气设备在线监测与故障诊断;

陆嘉华(1998),男,硕士,研究方向为电力系统母线负荷预测。

(下转第 149 页)

## Mitigating subsynchronous resonance using supplementary damping control of battery energy storage in a wind-thermal-storage bundling system

HU Yongqiang<sup>1</sup>, WANG Xi<sup>2</sup>, WU Linlin<sup>3</sup>, XIE Xiaorong<sup>2</sup>, BU Haitang<sup>1</sup>, SU Tianyu<sup>3</sup>

(1. Beifang Duolun Renewable Energy Co., Ltd., Xilingol League 027200, China; 2. Tsinghua University (State Key Laboratory of Power System Operation and Control), Beijing 100084, China; 3. North China Electric Power Research Institute Co., Ltd., Beijing 100045, China)

**Abstract:** Subsynchronous resonance (SSR) caused by the interaction between thermal power generators and series-capacitor-compensated AC lines, has been a significant concern in China's power grids. An energy storage supplementary damping control (SDC) to suppress SSR is proposed in this paper. SDC enables local feedback, and utilizes the coupling between generators and power grid to enhance the overall damping level. Firstly, the target system is modelled and the mechanism and characteristics of its SSR problem are clarified through frequency and time-domain analyses. Then, the supplementary damping control strategy is established based on battery energy storage system (BESS). Its control parameters and adding positions are optimized, and the impact of SDC's control capacity on BESS's normal functions is analyzed. Finally, the effectiveness and feasibility of the proposed SDC are verified through electromagnetic transient simulations with a real-world project, i.e., the Shangdu wind-thermal-energy storage bundling system. The simulation results also show that the proposed SDC can effectively address the SSR issue with reduced control cost and equipment investment cost, serving as a more economical solution.

**Keywords:** subsynchronous resonance (SSR); supplementary damping control (SDC); resonance mitigation; battery energy storage system (BESS); wind-thermal-storage bundling system; series compensation

(编辑 陈雯嘉)

(上接第 120 页)

## BiGRU-PLE based short-term joint forecasting of electric, cooling and heat loads

XU Yihao, MEI Fei, LU Jiahua

(School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

**Abstract:** Accurate forecasting of electric, cooling and heating loads is an important prerequisite and foundation for the operation scheduling and energy management of integrated energy systems. Leveraging the energy coupling characteristics between multivariate load, this paper constructs a joint prediction model for multivariate load based on bidirectional gated recurrent units (BiGRU) and a progressive layered extraction (PLE) network architecture. Firstly, the meteorological features with high correlation are screened as input features of the model through the maximum information coefficient. Then, the BiGRU network is used to extract the temporal features of the multivariate load time series under the integrated energy system and reconstruct the data in this way. Secondly, for the characteristics of different energy sources that are coupled with each other, the improved progressive hierarchical extraction network structure is proposed, and the coupling features are extracted from the complex and multidimensional data through the multilevel sharing of the feature extraction layer. Finally, by changing the structural parameters of the sub-task tower module, the coupled feature information is differentially fused, and the multiple load prediction results are obtained. The actual example results show that the maximum information coefficient screening method adopted in the article is more suitable for feature selection of meteorological data than the traditional Pearson coefficient screening method, and the proposed BiGRU-PLE multivariate load prediction model can reduce the prediction error by more than 5% compared with the single-task model, and by more than 3% compared with the common multitask model.

**Keywords:** bidirectional gated recurrent unit (BiGRU); maximum information coefficient; coupled feature extraction; multivariate load forecasting; integrated energy system; multitask learning

(编辑 陆海霞)