

基于时空图注意力网络的超短期区域负荷预测

赵紫昱¹, 陈渊睿¹, 陈霆威¹, 刘俊峰², 曾君¹

(1. 华南理工大学电力学院, 广东省广州市 510640; 2. 华南理工大学自动化科学与工程学院, 广东省广州市 510640)

摘要: 目前,空间负荷预测研究对复杂时空关系的考虑不足。为此,文中提出一种基于多维、多源特征的区域级负荷超短期时空预测模型。首先,根据已有的区域级负荷进行元胞划分,构建考虑元胞相关性的图拓扑。其次,分别通过图注意力网络、一维卷积神经网络和门控循环单元,从空间、特征和时间维度提取有效特征,连接全连接层输出结果。最后,基于美国新英格兰地区的真实电力负荷数据进行仿真验证,并提取模型注意力权重,分析元胞之间的空间依赖性。结果表明,所提模型相比传统模型在不同预测步长上均具有更高的预测精度和稳定性,有效挖掘了区域级负荷的空间依赖性。

关键词: 负荷预测; 负荷空间分布; 卷积神经网络; 门控循环单元; 注意力机制; 可解释性

0 引言

负荷预测通过对历史负荷数据进行分析 and 建模,预测未来一段时间负荷的变化趋势和大小^[1],是电力系统规划的重要组成部分,更是电力系统经济运行的基础。随着新型电力系统的发展,规模化新能源和电动汽车等新角色接入负荷侧,负荷预测呈现出预测范围更广、预测对象更多、不确定性更强等新的特征,实现多源负荷的多维度预测已成为数字化电网的基本要求^[1-2]。

现有负荷预测技术研究主要从时间与空间两个维度开展:时间尺度上分为中长期、短期和超短期预测;空间尺度的预测对象分为系统/区域、母线节点/馈线、微电网、用户集群或单一用户等。当前研究多关注时间维度的负荷预测,较少考虑空间关系,包括传统基于统计学的分析方法以及近年来兴起的基于数据驱动的人工智能方法,如卷积神经网络^[3](convolutional neural network, CNN)、注意力机制^[3-4]、门控循环单元^[4-5](gated recurrent unit, GRU)、长短时记忆^[5](long short-term memory, LSTM)网络等。空间负荷预测(spatial load forecasting, SLF)最早于1983年提出^[6],是指对未来一段时间内供电区域上总负荷需求及其空间分布进行预测,可为电网规划、电力平衡^[7]和市场交易^[8]提

供细粒度和更精确的信息,具有较高的研究价值和应用前景。但是,受限于数据处理技术与能力,早期的空间负荷预测本质上仍是时间序列预测问题,如文献[9]通过结合降噪自编码器、奇异谱分析和LSTM模型进行预测,并未能充分表征空间关系对负荷预测的影响。近年来,部分研究开始在空间负荷预测中引入空间信息,如文献[10]采用了时空图卷积网络结合时间维度和空间维度,即便未深入考虑温度和湿度等其他外界环境因素的影响,仅考虑日最大负荷,仍然展现出了考虑空间关系的作用和效果。总体而言,空间负荷预测技术发展缓慢,究其原因,主要存在以下难点。

1)元胞空间划分。以往空间负荷预测定义的元胞规模较小,负荷变化更取决于用地性质和用户用电习惯。而随着元胞规模变大,区域内的气象条件等外部影响存在连续性,使元胞之间也具有潜在空间相关性。对空间负荷预测而言,不同的负荷规模和空间尺度具有不同的适用范围,划分合适的元胞空间是首要挑战,直接关系到预测的精准度。

2)多模态数据融合^[11]。一般负荷预测或空间负荷预测都基于欧氏结构数据进行预测。而引入元胞之间的空间关系实现数据融合,数据结构将转变为非欧氏结构,而这种数据结构难以通过传统神经网络进行训练。虽然多个元胞的数据融合能有效提高目标感知的精确性和容错性,但如何融合并有效处理多源、多维的非欧氏数据是制约空间负荷预测进一步发展的关键难题。

3)负荷空间关系挖掘。当前大多数研究将空间

收稿日期: 2023-09-14; 修回日期: 2024-03-13。

上网日期: 2024-04-28。

国家自然科学基金资助项目(62173148);广东省基础与应用基础研究基金资助项目(2023A1515010184)。

负荷预测视为时序预测问题,即从时间维特征对空间元胞进行逐个预测,在空间维度上对元胞的空间相关性研究^[10,12]较少。部分研究^[10,13]直接定义先验负荷空间关系,与实际的潜在空间关系可能存在差异,导致难以挖掘出重要的负荷。

针对上述挑战,本文提出一种基于时空图注意力网络(spatio-temporal graph attention network, STGAT)的新型超短期空间负荷预测方法。首先,进行元胞划分,构建区域级元胞的图拓扑,对复杂负荷区域空间关系建模。其次,分别在空间维度、特征维度和时间维度提取和融合时空特征。最后,基于美国新英格兰地区真实负荷数据,挖掘与展现重要负荷和空间特性,验证了模型的有效性和稳定性。

1 深度学习模型基本原理

1.1 图注意力网络

图神经网络擅长处理图数据这类非欧氏数据,可以将空间维度的特征引入负荷预测,挖掘负荷空间关系,主要包括图卷积神经网络^[14](graph convolutional network, GCN)、图注意力网络^[15](graph attention network, GAT)和图采样与聚合^[16]等。其中,GAT通过注意力机制进行特征处理,重新分配邻居节点的注意力权重,更新特征表示。与GCN相比,GAT无须全图计算,仅处理邻居节点,且可实现并行计算。GAT结构如附录A图A1所示,运算过程如下^[15]。

首先,逐个计算注意力系数。

$$e_{ij} = a([\mathbf{W}\vec{h}_i \parallel \mathbf{W}\vec{h}_j]) \quad j \in N_i \quad (1)$$

式中: e_{ij} 为节点 j (节点 i 的邻居节点)对节点 i 的注意力系数; $a(\cdot)$ 为注意力函数,将拼接后的高维特征映射到一个实数上; \parallel 为特征拼接操作; \vec{h}_i 和 \vec{h}_j 分别为节点 i 和节点 j 的输入特征向量; \mathbf{W} 为线性变换的共享参数矩阵; N_i 为节点 i 的一阶邻居节点总数。

接着,进行非线性变换,并通过归一化后得到注意力权重 α_{ij} 。

$$\text{LeakyReLU}(x) = \begin{cases} x & x > 0 \\ -\gamma x & x \leq 0 \end{cases} \quad (2)$$

$$\alpha_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(\text{LeakyReLU}(e_{ij}))}{\sum_{k=1}^{N_i} \exp(\text{LeakyReLU}(e_{ik}))} \quad (3)$$

式中: $\text{LeakyReLU}(\cdot)$ 为非线性变换函数; x 为函数自变量; γ 为函数负区域的正斜率; $\text{softmax}(\cdot)$ 为归一化函数; $\text{softmax}_j(e_{ij})$ 为对邻居节点 j 的注意力系数 e_{ij} 进行归一化的函数; i_k 为节点 i 的第 k 个邻居节点。

最后,加权求和,并通过激活函数后得到节点 i 输出特征向量 \vec{h}'_i 。

$$\vec{h}'_i = \sigma \left(\alpha_{ii} \mathbf{W}\vec{h}_i + \sum_{j \in N_i} \alpha_{ij} \mathbf{W}\vec{h}_j \right) \quad (4)$$

式中: $\sigma(\cdot)$ 为sigmoid激活函数。

此外,本文对于邻接矩阵中不相关的节点采用掩码处理,具体说明和操作见附录A式(A1)。

1.2 门控循环单元

循环神经网络是解决时序问题的经典模型,可以从时间维度进行特征分析历史数据,但存在梯度消失和梯度爆炸问题。而GRU通过引入“门机制”有效解决了这一问题。GRU结构如附录A图A2所示,计算过程见附录A式(A2)至式(A5)。

1.3 一维卷积神经网络

卷积神经网络采用多个卷积核进行运算,本文引入一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)以增强模型在特征维度的信息提取能力。1DCNN结构如附录A图A3所示,计算过程见附录A式(A6)。

2 空间负荷特性研究

2.1 元胞划分

在以往研究中,负荷元胞(简称元胞)的定义为地理信息系统(geographic information system, GIS)环境下的一组供电小区,根据等大小网格或用户用电范围原则,划分为不规则(I类元胞)或规则(II类元胞)的元胞。文献[17]对电力负荷空间分辨率(spatial resolution of electric load, SREL)进行了详细阐述和定量分析,根据供电小区和供电区域的面积比例划分为不同尺度的SREL。

为了定性讨论和实验验证的方便,本文以美国新英格兰地区为例,采用I类元胞的划分规则,参照供电范围大小划分为系统级元胞(运营商供电范围)、区域级元胞(行政区供电范围)及用户级元胞(用户用电范围),如附录A图A4所示。依据不同供电范围进行元胞划分后,更有利于空间负荷预测利用空间关系进行研究和探索。

2.2 空间特性研究

不同级别的元胞具有不同的空间特性,而人类的生产活动和气象因素具有一定空间分布性,导致元胞之间也存在相互作用。

用户级元胞主要取决于空间用地属性,譬如商业属性、工业属性、农业属性以及居民属性等。这些空间用地属性决定了负荷变化和发展规律,且各元胞位置相近,具有一致的气象条件。因而,可认为气

象因素的差异难以反映用户级元胞的空间特性。

区域级和系统级元胞在海量用户负荷的叠加下,其负荷数据表现更为平稳,数据波动性更小,更有利于进行负荷预测的研究。同时,气象因素作为影响负荷变化的关键要素,在空间上存在一定的连续性,而不同元胞的气象数据在该空间尺度下存在明显差异。

3 基于STGAT的超短期空间负荷预测方法

3.1 模型框架

本文模型框架流程如图1所示,整体模型包括数据整合、元胞划分、数据处理、STGAT模型、误差评估与可视化部分和对比模型。

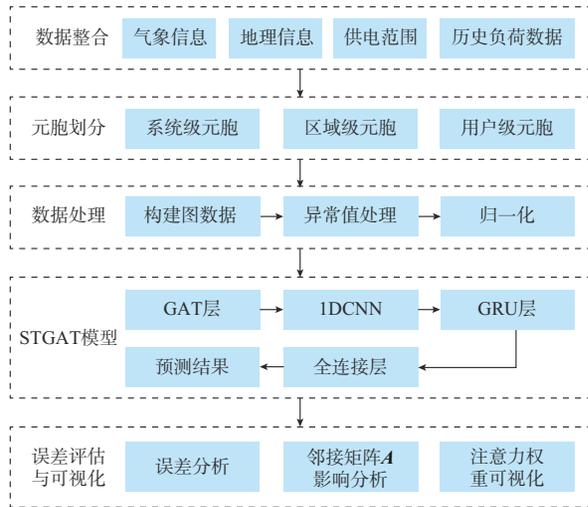


图1 模型框架图

Fig. 1 Framework diagram of model

3.2 时空图数据构建

3.2.1 时空图数据格式

本文视新型空间负荷预测为考虑空间关系的时空融合预测,即预测元胞 i 时,除了考虑元胞 i 自身特征之外,还同时考虑多个潜在空间相关元胞 j 的特征数据。在负荷预测中,输入数据的格式为(元胞数,样本数,特征数),而在新型空间负荷预测中则采用图结构数据,通过节点和边分别描述节点特征和节点关系,即图 $G=(A; X)$,其中, G 为图数据矩阵; A 为邻接矩阵; X 为输入数据矩阵。时空图数据的格式为(邻接矩阵;元胞数,样本数,特征数), $X \in \mathbb{R}^{N \times T \times F}$,其中, N 为元胞数; T 为输入时间步长; F 为特征数。

在本文中,区域级元胞对应图的节点,邻接矩阵对应图的边关系。由于元胞拓扑不发生改变,邻接矩阵 A 可认为是时不变参数矩阵,也称为同构图^[14],负荷特征则是一个时变参数矩阵 X 。选择区

域级负荷作为研究对象,其图拓扑构建示意图见图2。

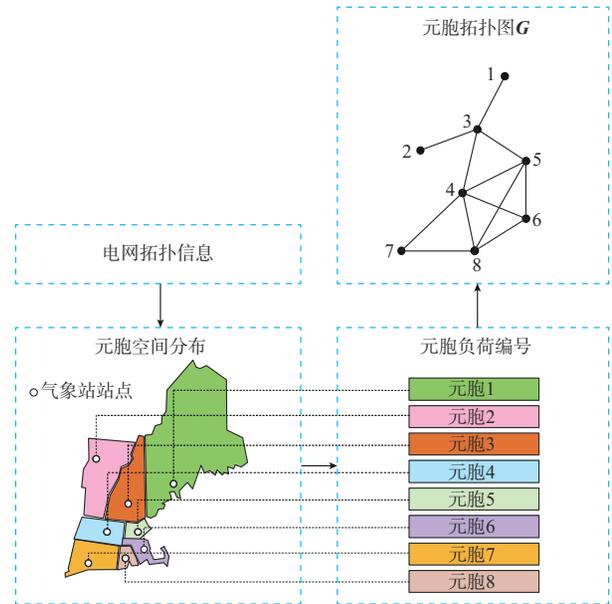


图2 元胞图拓扑构建示意图

Fig. 2 Schematic diagram of construction of cellular graph topology

由图1和图2可知,电网拓扑信息、气象信息和供电范围等多源数据生成了元胞拓扑图,经过数据整合和元胞划分后转化为时空图数据。其中,邻接矩阵 A 决定了哪些元胞进行特征交互,正确地构建邻接矩阵 A 对于准确刻画和理解图的结构和动态行为至关重要。

3.2.2 图邻接矩阵

部分研究中,邻接矩阵 A 设置的依据为元胞距离和位置,文献[10]认为用户级元胞之间的相互影响与线路连接的距离信息关系密切,采用阈值高斯核方法构建邻接矩阵,文献[13]采用皮尔逊相关性系数阈值定义相关性。上述方法直接对邻接矩阵赋予一定的权重系数,具有强烈的先验色彩,但实际的潜在元胞空间关系有待挖掘和验证。

为此,本文以相邻关系和距离阈值函数两种方法来探究元胞的空间特性,仅判定元胞的相关性,不赋予先验权重,通过模型对元胞空间的实际关系进行挖掘。以上两种方法的具体内容如下。

方法1:元胞相邻关系的方法根据地理空间上的毗邻来确定 A ,即相邻元胞取1,否则取0。

方法2:距离阈值函数的方法依据各元胞中心位置的距离进行阈值判定,本文选取气象站站点位置为元胞中心。距离阈值函数为:

$$A_{ij} = \begin{cases} 1 & d(i, j) \leq \delta \\ 0 & d(i, j) > \delta \end{cases} \quad (5)$$

式中: A_{ij} 为元胞 i 和元胞 j 的邻接矩阵的元素; $d(i, j)$ 为元胞 i 和元胞 j 中心之间的欧氏距离; δ 为阈值。

3.3 STGAT 模型

时空预测模型在时序预测的基础上考虑了各序列之间的相互影响关系, 以实现更准确的预测。时空预测模型需要耦合时间维度和空间维度, 当前主流方法分为融合^[18]、串联^[19]和并联^[20]3种。本文采用融合方式, 即在每个时间步的计算中引入图信息, 通过邻接矩阵来连接空间中相关序列的信息。

图网络仅解决空间上的特征交互, 需要引入时序结构使模型具备处理时间序列的能力^[21]。因此, 本文采用 GAT 层、1DCNN 和 GRU 层三部分构成 STGAT 模型, 数据流和模型计算过程见图 3。图中: X_t 为 t 时刻的输入数据矩阵; p 为预测步长; y_p 为未来 p 个时刻的预测值向量; H_t 为 t 时刻的 GRU 输出特征矩阵。

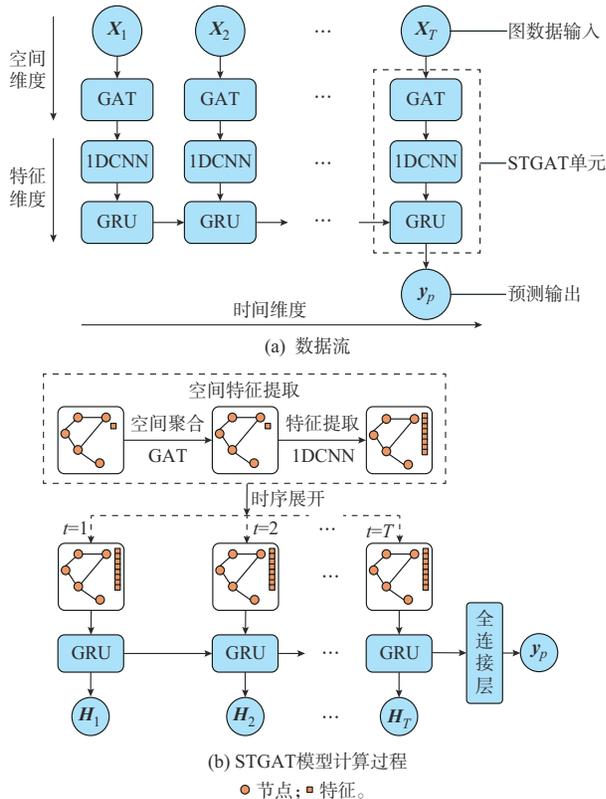


图3 STGAT数据流和模型计算过程

Fig. 3 STGAT data flow diagram and model calculation process

本文模型数据在计算过程中实现了在空间、特征和时间3个维度的耦合, GAT层在空间维度聚合特征, 1DCNN在特征维度进行特征提取和升维,

GRU层在时间维度提取时序信息, 并将最后时刻状态输入全连接网络, 预测未来 p 个步长的负荷值。

3.4 模型空间可解释性

当前许多研究着重于通过堆叠模型来提高性能, 但却忽视了模型结构的合理性和可解释性^[22-24]。神经网络中的激活函数具有非线性, 且模型训练过程中的初始化参数具有较大的随机性, 这导致模型可解释能力较差^[13], 通常被视为“黑箱”模型。深度学习, 注意力机制通过配置概率分布的方式, 对关键信息和无关信息增加和降低权重, 具有天然的模型可解释性。与一些复杂的可解释模型^[22-23]不同, 注意力机制具有局部可解释性且更简便, 适合模型的内部解释。

本文利用图注意力网络中注意力机制的局部可解释性来对空间依赖性进行定量分析。图注意力网络对选取的元胞进行注意力分配。因此, GAT层中注意力权重参数 α_{ij} 代表了不同元胞 j 对元胞 i 的影响程度, α_{ij} 越高, 元胞 i 和元胞 j 之间的空间依赖性越强, 反之即空间依赖性越弱。GAT层的注意力权重参数组成了一个 N 阶矩阵, 对其可视化以提供元胞在空间依赖性上的模型可解释性。这一过程为观测与解释元胞之间隐藏关系提供了有效解决方案, 通过注意力权重系数观测不同时刻的区域负荷状态和空间依赖关系, 便于监测重要负荷。

4 算例分析

4.1 数据集分析及数据处理

本文选用 GEFCom2017 数据集^[25]验证所提模型有效性, 记录了美国新英格兰地区的8个负荷区的负荷和气象数据, 采样间隔为 1 h, 选择 2010 年 1 月 1 日至 2010 年 12 月 31 日的数据构成样本集。样本集中存在少量异常值, 主要为零值点和突变点, 本文采用线性插值的方法替换异常数据, 以保证时间序列的连续性。将数据集划分为训练集(80%)和测试集(20%), 采用 min-max 归一化至区间 $[0, 1]$:

$$\hat{X}_t = \frac{X_t - X_{\min}}{X_{\max} - X_{\min}} \quad (6)$$

式中: X_{\max} 和 X_{\min} 分别为输入数据中的最大值和最小值向量; X_t 和 \hat{X}_t 分别为第 t 个时刻的原数据矩阵和归一化后的数据矩阵。

数据处理后的输入特征类型见表 1。

4.2 模型参数设置和评价指标

4.2.1 邻接矩阵参数设置

本文对元胞之间空间依赖性的基础建立在气象信息上, 因而选取气象站点的坐标作为元胞的中心, 具体的坐标参数和距离见附录 B 表 B1 和表 B2。

本文选取邻接矩阵 A_1 、 A_2 、 A_3 、 A_4 和 A^* 研究其

表1 模型的输入特征
Table 1 Input features of model

输入类型	具体名称	符号	单位	含义
时间信息	年	Y		时间标签
	月	M		
	日	D	无	
	小时	H		
	工作日	W	无	是否为工作日
气象信息	干球温度	DB	°F	实际温度
	露点温度	DP		反映空气湿度的温度
负荷信息	历史负荷	L	MW	负荷功率

空间关系的影响,其中, A_1 为不考虑邻居元胞关系的邻接矩阵,有 $A_1=O$,其中 O 为零矩阵; A_2 为考虑所有元胞关系的邻接矩阵,有 $A_2=1-I$,其中, 1 为全1矩阵, I 为单位矩阵; A_3 为根据元胞相邻关系设置的邻接矩阵,元胞相邻为1,否则取0; A_4 为根据不同元胞距离阈值设置的邻接矩阵,满足阈值条件为1,否则取0; A^* 为根据上述邻接矩阵结果进行调整的邻接矩阵。具体矩阵参数见附录C式(C1)和式(C2)。

4.2.2 超参数设置

当前研究认为CNN与GRU的组合模型CNN-GRU^[26]效果较好,而时空图卷积网络^[20](spatio-temporal graph convolutional network, STGCN)为经典的时空图模型。因此,以GRU、CNN-GRU和STGCN为对比模型,其中,GRU和CNN-GRU不考虑空间关系,在CNN-GRU基础上,STGCN引入GCN考虑空间关系,STGAT则引入GAT考虑空间关系。

STGAT模型具体参数如下:各网络模块的层数均为1层,隐藏层单元数为64,批大小为32,迭代次数为100,学习率为0.001,权重衰减系数为0.0015,正则化项权重取0.0015, γ 取0.01,训练算法为

adam。此外,本文中 N 为8, T 为24, F 为8。

4.2.3 损失函数与评价指标

为各个元胞预测值更接近观测值,模型损失函数选择均方误差函数 $L(f, F(\mathbf{X}))$,其中, f 为实际值; $F(\mathbf{X})$ 为预测值。模型训练目标为最小化 L 。加入L2正则化,防止过拟合,提高模型泛化能力。 $L(\mathbf{X})$ 和 L 分别为未加入正则化和加入正则化后的损失函数,其表达式如式(7)和式(8)所示。

$$L(f, F(\mathbf{X})) = \frac{1}{2} (f - F(\mathbf{X}))^2 \quad (7)$$

$$L = L(\mathbf{X}) + \frac{\lambda}{2} \sum_{m=1}^M \theta_m^2 \quad (8)$$

式中: θ_m 为第 m 个模型可训练参数; M 为模型可训练参数总数; λ 为正则化项的权重。

本文选取均方根误差 I_{RMSE} 、平均绝对误差 I_{MAE} 和平均绝对百分误差 I_{MAPE} 作为评价各类模型预测效果的依据,其计算公式如下。

$$I_{RMSE} = \sqrt{\frac{1}{NT} \sum_{i=1}^T \sum_{t=1}^N (f_{i,t} - F_{i,t})^2} \quad (9)$$

$$I_{MAE} = \frac{1}{NT} \sum_{i=1}^T \sum_{t=1}^N |f_{i,t} - F_{i,t}| \quad (10)$$

$$I_{MAPE} = \frac{1}{NT} \sum_{i=1}^T \sum_{t=1}^N \left| \frac{f_{i,t} - F_{i,t}}{f_{i,t}} \right| \times 100\% \quad (11)$$

式中: $f_{i,t}$ 和 $F_{i,t}$ 分别为第 i 个元胞 t 时刻的实际值和预测值。

4.3 结果对比

文章采用Pytorch深度学习框架搭建STGAT模型和对比模型,硬件配置包括AMD Ryzen 7 5800H和NVIDIA GeForce RTX 3060 6 GB。采用多输出的多步预测策略,通过历史24 h的数据分别直接预测出未来1、4、8和12 h内的负荷值。不同模型在不同预测步长下的预测评价结果如表2所示。表中: t_e 为迭代一次需要的时间。

表2 预测评价结果
Table 2 Forecasting evaluation results

预测步长 p/h	GRU				CNN-GRU				STGCN				STGAT			
	$I_{RMSE}/$ MW	$I_{MAE}/$ MW	$I_{MAPE}/$ %	t_e/s												
1	135.25	99.08	5.79	17	91.22	61.26	3.57	32	123.42	91.14	5.68	24	86.66	59.64	3.47	62
4	164.86	119.19	7.41	17	124.65	83.04	4.79	32	137.80	100.75	6.09	24	116.30	80.12	4.73	62
8	201.04	145.13	8.30	17	134.64	91.71	5.17	32	155.01	110.76	6.63	24	129.27	90.48	5.16	62
12	208.43	151.80	8.61	17	155.96	108.74	6.37	32	177.13	129.19	7.91	24	151.09	102.92	5.74	62

由表2可知,所提STGAT模型在各项评价指标上都有不同程度的提升。相比于GRU和STGCN模型,所提模型提升较大,在不同的预测步长下,各项预测误差指标均有不同程度的提升:相比

GRU, I_{RMSE} 最多降低了65.53 MW, I_{MAE} 最多降低了53.45 MW, I_{MAPE} 最多降低了3.14%;相比STGCN, I_{RMSE} 最多降低了36.76 MW, I_{MAE} 最多降低了31.5 MW, I_{MAPE} 最多降低了2.21%。相比于CNN-

GRU模型,所提模型提升效果不显著, I_{RMSE} 最多降低了8.35 MW, I_{MAE} 最多降低了5.82 MW, I_{MAPE} 最多降低了0.63%。具体模型训练损失与测试损失变化曲线见附录A图A5。由图可见,STGAT收敛速度最快。

选取全部元胞72 h的预测结果($p=1$)进行绘制,如图4所示。由图4可见,STGCN和GRU在峰

谷值预测表现上较差,且面对不同元胞时表现不稳定,GRU在元胞1、6、7和8上误差较大,STGCN在元胞2和3中误差较大。而模型整体表现上,CNN-GRU与STGAT在峰谷值预测上表现更优秀,且两者预测结果与真实值非常接近,所提STGAT模型略优于CNN-GRU。

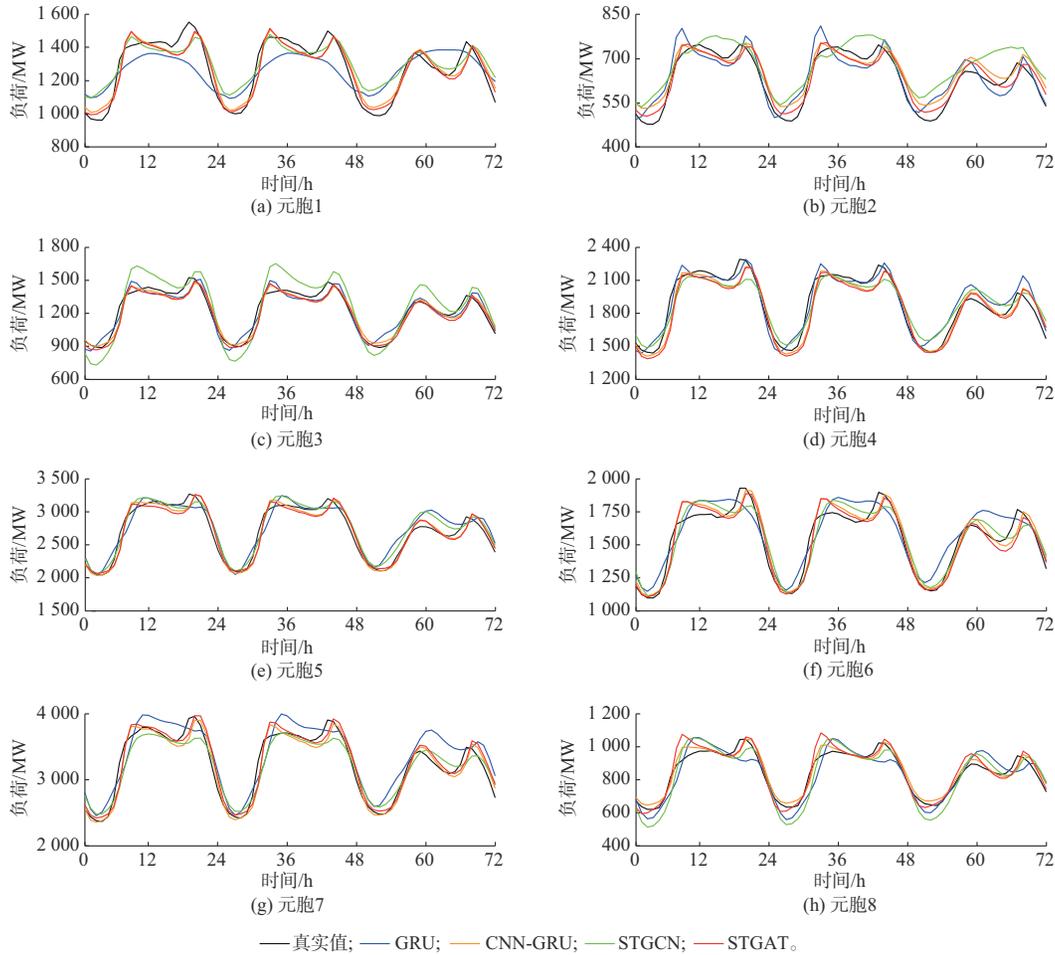


图4 不同元胞的负荷预测结果
Fig. 4 Load forecasting results of different cells

结果表明,引入邻居元胞特征的STGCN预测精度相比于GRU虽然有所提升,但多元胞空间特征信息的引入使得模型参数计算量骤增,而图卷积为线性运算,模型特征提取能力不强,无法充分挖掘空间依赖性。所提STGAT模型在原有基础上改用图注意力机制增强模型特征提取能力,预测效果提升显著,证实上述猜测。

4.4 空间依赖性分析与可解释性

邻接矩阵A的参数设置对于图模型非常重要,A决定了引入哪些元胞的历史负荷和特征数据,不同邻接矩阵设置的结果如表3所示。

表3 不同邻接矩阵的结果
Table 3 Result of different adjacency matrices

邻接矩阵	STGCN			STGAT		
	$I_{RMSE}/$ MW	$I_{MAE}/$ MW	$I_{MAPE}/$ %	$I_{RMSE}/$ MW	$I_{MAE}/$ MW	$I_{MAPE}/$ %
A_1	142.29	98.93	5.79	100.32	67.12	3.85
A_2	804.37	735.01	48.70	104.38	67.99	3.87
A_3	155.29	107.11	6.08	95.93	65.18	3.67
$A_4(\delta=120\text{ km})$	356.89	261.81	17.45	104.35	71.77	4.19
$A_4(\delta=140\text{ km})$	360.70	257.52	16.72	103.35	70.74	4.04
$A_4(\delta=160\text{ km})$	197.11	144.47	8.35	92.33	64.60	3.80
A^*	123.42	91.14	5.68	86.66	59.64	3.47

由表3可见,STGCN模型在引入全部元胞特征(对应邻接矩阵 A_2)和仅引入相邻元胞特征(对应邻接矩阵 A_3)的情况下,比不引入相邻元胞特征(对应邻接矩阵 A_1)的效果更差,并且在根据距离阈值 δ 确定的 A_4 下表现的结果异常,表明该模型在面对更多对象时特征提取能力和稳定性较差。相比之下,本文STGAT模型在多个邻接矩阵上都具有较好的稳定性。在 δ 的选择上,160 km相比于120 km和140 km,对STGAT模型的提升较大。显然,在负荷空间邻接矩阵的选取上,根据距离阈值函数进行选择能起到一定作用。

在实验过程中发现,相同方向元胞可能会带来数据冗余性,即重复、相似的样本过多可能会导致数据分布不均。本文在 A_1 — A_4 的基础上进行调整,针对部分元胞在 δ 为160 km基础上进行了修改:删去

了元胞1和5、元胞3和6、元胞3和8的相关性。最后在邻接矩阵参数 A^* 下,STGCN和STGAT的模型效果都具有显著的提升。

因此,邻接矩阵的参数设置对于图模型的预测效果至关重要,尽管 A^* 和其他邻接矩阵仅部分邻接关系不同,最终的预测效果却有显著的差异。在区域级负荷的邻接矩阵选取上,应该需要更重视多个邻居方向的元胞信息,避免相同方向元胞带来的数据冗余,选取合适的图模型邻接矩阵。

注意力权重参数可视化是本文STGAT模型的优势所在。相比于同样是图模型的STGCN,本文模型可以更直观分析不同元胞之间的空间依赖性。图5为12月STGAT模型的注意力权重热力图。由图5可见不同元胞之间的影响程度,如元胞8对元胞4、5、6、7具有明显影响,可视作为重要负荷。

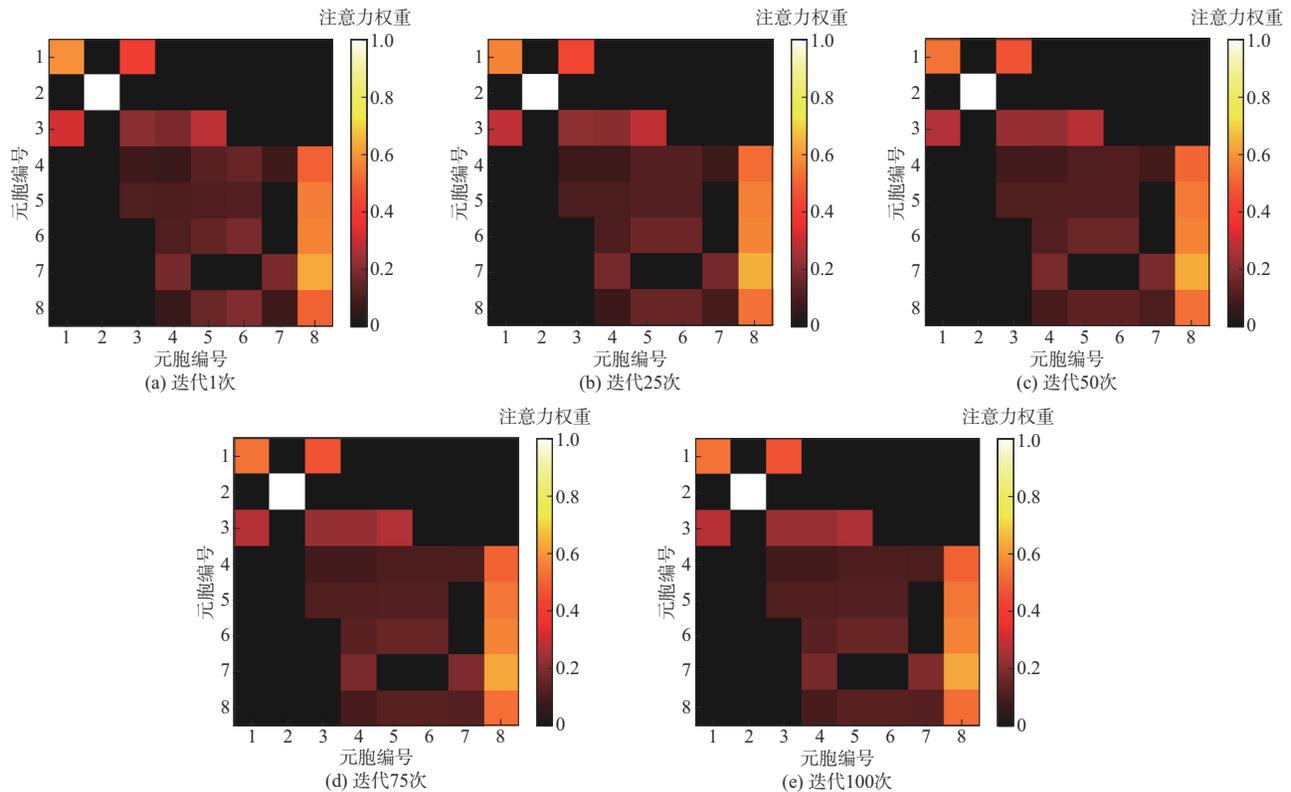


图5 STGAT注意力权重热力图(12月)

Fig. 5 STGAT attention weight heatmap (December)

邻接矩阵 A_1 、 A_2 、 A_3 和 A^* 的注意力权重如附录A图A6所示。由图A6可见,引入全部元胞信息的 A_2 ,将所有元胞特征进行计算,最终的注意力权重矩阵被稀释,模型被数据“淹没”,难以挖掘出有效的空间依赖性;而 A_3 与 A^* 则能反映出各相邻元胞的权重占比,有效挖掘元胞之间的空间依赖性。

5 结语

本文拓展了空间负荷预测中元胞在空间尺度上

的定义,并提出一种基于STGAT的新型超短期SLF模型,其优势在于:

1) 所提STGAT模型实现空间、特征和时间3个维度的耦合,在多个元胞之间进行信息交互,同时采用多变量输入的方式实现多维特征的充分利用,为空间负荷的多维、多源特征交互和提取技术提供理论支撑和可行性验证。

2) 通过对模型注意力权重的可视化,证明元胞之间存在空间依赖性,提升了所提模型的可解释性,

方便了进一步探索空间中的重要负荷。

3)算例结果表明,所提STGAT模型在不同步长下预测精度均有所提高,在不同邻接矩阵参数设置下具有更强的稳定性,相比已有方法能更精确地预测元胞的发展趋势。

需要指出的是,图模型对邻接矩阵 A 的参数设置要求较高,邻接矩阵 A 的参数自适应设置有待进一步研究。虽然所提STGAT模型最终精度较高,在不同邻接矩阵参数设置下模型表现更稳定,但仍然存在优化的空间。此外,引入多个元胞数据也增加了模型计算量,在面对更多对象时,可以通过本文提供的修正方法简化和优选相关元胞,避免数据冗余。

最后,近年来分布式光伏等可再生能源从低压侧大量接入,这些分布式资源在时间序列上的强不确定性和空间上的强相关性,使得空间特性对功率预测的影响不容忽视,空间负荷预测意义与价值将进一步凸显。本文通过多变量输入的STGAT模型对区域级负荷进行了研究,在未来研究中,预测对象将进一步拓展到区域级光伏、风力发电,以满足新型电力系统对多元负荷预测的需求。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参 考 文 献

- [1] 康重庆,夏清,张伯明.电力系统负荷预测研究综述与发展方向的探讨[J].电力系统自动化,2004,28(17):1-11.
KANG Chongqing, XIA Qing, ZHANG Boming. Review of power system load forecasting and its development [J]. Automation of Electric Power Systems, 2004, 28(17): 1-11.
- [2] 孔祥玉,马玉莹,艾芊,等.新型电力系统多元用户的用电特征建模与用电负荷预测综述[J].电力系统自动化,2023,47(13):2-17.
KONG Xiangyu, MA Yuying, AI Qian, et al. Review on electricity consumption characteristic modeling and load forecasting for diverse users in new power system [J]. Automation of Electric Power Systems, 2023, 47(13): 2-17.
- [3] 赵兵,王增平,纪维佳,等.基于注意力机制的CNN-GRU短期电力负荷预测方法[J].电网技术,2019,43(12):4370-4376.
ZHAO Bing, WANG Zengping, JI Weijia, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU [J]. Power System Technology, 2019, 43(12): 4370-4376.
- [4] 张宇帆,艾芊,林琳,等.基于深度长短时记忆网络的区域级超短期负荷预测方法[J].电网技术,2019,43(6):1884-1892.
ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level [J]. Power System Technology, 2019, 43(6): 1884-1892.
- [5] 肖白,张博,王辛玮,等.基于组合模态分解和深度学习的短期风电功率区间预测[J].电力系统自动化,2023,47(17):110-117.
XIAO Bai, ZHANG Bo, WANG Xinwei, et al. Short-term wind power interval prediction based on combined mode decomposition and deep learning [J]. Automation of Electric Power Systems, 2023, 47(17): 110-117.
- [6] WILLIS H L, NORTHGOTE-GREEN J E D. Spatial electric load forecasting: a tutorial review[J]. Proceedings of the IEEE, 1983, 71(2): 232-253.
- [7] 齐宁,程林,田立亭,等.考虑柔性负荷接入的配电网规划研究综述与展望[J].电力系统自动化,2020,44(10):193-207.
QI Ning, CHENG Lin, TIAN Liting, et al. Review and prospect of distribution network planning research considering access of flexible load [J]. Automation of Electric Power Systems, 2020, 44(10): 193-207.
- [8] 郭鸿业,郑可迪,唐庆虎,等.数据驱动的电力市场研究:挑战与展望[J].电力系统自动化,2023,47(1):200-215.
GUO Hongye, ZHENG Kedi, TANG Qinghu, et al. Data-driven research on electricity markets: challenges and prospects [J]. Automation of Electric Power Systems, 2023, 47(1): 200-215.
- [9] 肖白,肖志峰,姜卓,等.基于降噪自编码器、奇异谱分析和长短期记忆神经网络的空间电力负荷态势感知[J].中国电机工程学报,2021,41(14):4858-4867.
XIAO Bai, XIAO Zhifeng, JIANG Zhuo, et al. Spatial load situation awareness based on denoising autoencoder, singular spectrum analysis and long short-term memory neural networks [J]. Proceedings of the CSEE, 2021, 41(14): 4858-4867.
- [10] 张鹏飞,胡博,何金松,等.基于时空图卷积网络的短期空间负荷预测方法[J].电力系统自动化,2023,47(13):78-85.
ZHANG Pengfei, HU Bo, HE Jinsong, et al. Short-term spatial load forecasting method based on spatio-temporal graph convolutional network [J]. Automation of Electric Power Systems, 2023, 47(13): 78-85.
- [11] 王波,王红霞,姚良忠,等.电力系统多模态数据融合模式及关键技术问题[J].电力系统自动化,2022,46(19):188-199.
WANG Bo, WANG Hongxia, YAO Liangzhong, et al. Multi-modal data fusion mode for power system and its key technical issues [J]. Automation of Electric Power Systems, 2022, 46(19): 188-199.
- [12] 肖白,张小娜,姜卓,等.考虑本位元胞接受能力和相邻元胞负荷影响的空间负荷预测[J].电力系统自动化,2021,45(12):57-64.
XIAO Bai, ZHANG Xiaona, JIANG Zhuo, et al. Spatial load forecasting considering acceptability of standard cell and influence of load of adjacent cells [J]. Automation of Electric Power Systems, 2021, 45(12): 57-64.
- [13] 苏向敬,聂良钊,李超杰,等.基于MSTAGNN模型的可解释海上风电场多风机出力预测[J].电力系统自动化,2023,47(9):88-98.
SU Xiangjing, NIE Liangzhao, LI Chaojie, et al. Interpretable power output prediction of multiple wind turbines for offshore wind farm based on multiple spatio-temporal attention graph neural network model [J]. Automation of Electric Power Systems, 2023, 47(9): 88-98.
- [14] LIAO W L, BAK-JENSEN B, PILLAI J R, et al. A review of graph neural networks and their applications in power systems [J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(2): 345-360.

- [15] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs [EB/OL]. [2023-09-14]. <https://arxiv.org/pdf/1706.02216>.
- [16] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [EB/OL]. [2023-09-14]. <https://arxiv.org/pdf/1710.10903>.
- [17] 肖白,黎平.最佳电力负荷空间分辨率的获取方法[J].中国电机工程学报,2010,30(34):50-56.
XIAO Bai, LI Ping. Method for acquiring optimum spatial resolution of electric load[J]. Proceedings of the CSEE, 2010, 30(34): 50-56.
- [18] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting [EB/OL]. [2023-09-14]. <https://arxiv.org/pdf/1707.01926>.
- [19] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [C]// Proceedings of the 27th International Joint Conference on Artificial Intelligence, July 13-19, 2018, Stockholm, Sweden: 3634-3640.
- [20] ZHENG C P, FAN X L, WANG C, et al. GMAN: a graph multi-attention network for traffic prediction [C]// Proceedings of the AAAI Conference on Artificial Intelligence, February 7-12, 2020, New York, USA: 1234-1241.
- [21] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [22] 郑心仕,梁寿愚,苏晓,等.基于贝叶斯方法与可解释机器学习的负荷特性分析与预测[J].电力系统自动化,2023,47(13): 56-68.
ZHENG Xinshi, LIANG Shouyu, SU Xiao, et al. Characteristic analysis and load forecasting based on Bayesian method and interpretable machine learning [J]. Automation of Electric Power Systems, 2023, 47(13): 56-68.
- [23] LUNDBERG S, LEE S I. A unified approach to interpreting model predictions [EB/OL]. [2023-09-14]. <https://arxiv.org/pdf/1705.07874>.
- [24] RIBEIRO M T, SINGH S, GUESTRIN C. "Why should I trust you?": explaining the predictions of any classifier [EB/OL]. [2023-09-14]. <https://arxiv.org/pdf/1602.04938>.
- [25] HONG T, XIE J R, BLACK J. Global energy forecasting competition 2017: hierarchical probabilistic load forecasting [J]. International Journal of Forecasting, 2019, 35(4): 1389-1399.
- [26] 王轲,钟海旺,余南鹏,等.基于seq2seq和Attention机制的居民用户非侵入式负荷分解[J].中国电机工程学报,2019,39(1):75-83.
WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive load monitoring based on sequence-to-sequence model with Attention mechanism [J]. Proceedings of the CSEE, 2019, 39(1): 75-83.

赵紫昱(1999—),男,硕士研究生,主要研究方向:电力负荷预测、新能源功率预测、人工智能。E-mail: 202121015744@mail.scut.edu.cn

陈渊睿(1969—),男,博士,副教授,硕士生导师,主要研究方向:电力电子系统先进控制技术、新能源发电并网与控制技术。E-mail: yrchen@scut.edu.cn

陈霆威(1999—),男,硕士研究生,主要研究方向:电网优化调度及能量管理。E-mail: 1838063537@qq.com

曾君(1979—),女,通信作者,博士,教授,博士生导师,主要研究方向:微电网能量管理及优化、可再生能源发电系统中的电力电子及控制技术。E-mail: junzeng@scut.edu.cn

(编辑 吴崇昊)

Ultra-short-term Regional Load Forecasting Based on Spatio-Temporal Graph Attention Network

ZHAO Ziyu¹, CHEN Yuanrui¹, CHEN Tingwei¹, LIU Junfeng², ZENG Jun¹

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, China;

2. School of Automation Science and Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: At present, the research on spatial load forecasting lacks the consideration of complex spatial-temporal relationship. Therefore, a regional ultra-short-term spatio-temporal load forecasting model considering multi-dimensional and multi-source features is proposed in this paper. Firstly, based on the existing regional-level load, cell partitioning is carried out to construct a graph topology that considers cell correlation. Secondly, effective features are extracted from the spatial, feature, and temporal dimensions through the graph attention network, one dimensional convolutional network and gated recurrent unit, connecting the fully connected layers to output the results. Finally, simulation validation is conducted based on the real power load data from the New England region of the United States, and model attention weights are extracted to analyze the spatial dependencies between cells. The results show that, compared with the traditional models, the proposed model provides higher accuracy and stability with different prediction steps, effectively exploiting the spatial dependence of regional spatial load.

This work is supported by National Natural Science Foundation of China (No. 62173148) and Guangdong Basic and Applied Basic Research Foundation (No. 2023A1515010184).

Key words: load forecasting; load spatial distribution; convolutional neural network; gated recurrent unit; attention mechanism; interpretability

