

考虑元胞负荷时空特征的空间负荷预测方法

肖 白¹,张福生¹,张大弛²,辛昊阔²,姚 狄²,孔译辉³

(1. 东北电力大学 现代电力系统仿真控制与绿色电能新技术教育部重点实验室,吉林 吉林 132012;

2. 国网吉林省电力有限公司经济技术研究院,吉林 长春 130021;

3. 国网吉林省电力有限公司延边供电公司,吉林 延吉 133000)

摘要:为了避免Ⅰ类元胞的形状、数量、大小和位置改变给空间负荷预测带来误差,以及深入挖掘元胞负荷之间的空间影响关系以提升空间负荷预测精度,提出一种考虑元胞负荷时空特征的空间负荷预测方法。采用广义极端学生化偏差算法对Ⅰ类元胞历史负荷数据中的奇异值进行检测和修正;利用空间电力负荷网格化技术将基于Ⅰ类元胞刻画的空间电力负荷转化为基于Ⅱ类元胞刻画的空间电力负荷;使用图卷积网络和门控循环单元构建空间负荷预测模型,其中利用图卷积网络提取Ⅱ类元胞负荷之间的空间维度特征,利用门控循环单元获取Ⅱ类元胞负荷的时间维度特征,通过全连接层输出基于Ⅱ类元胞的空间负荷预测结果。算例分析结果验证了所提方法的有效性。

关键词:空间负荷预测;图卷积网络;元胞;地理信息系统;门控循环单元

中图分类号:TM73

文献标志码:A

DOI:10.16081/j.epae.202603015

0 引言

空间负荷预测(spatial load forecasting, SLF)是对供电区域内电力负荷大小和位置分布的预测^[1],开展SLF的研究对提高电力系统建设的经济性、高效性、可靠性具有重要意义。

SLF方法根据预测原理的不同可以划分为趋势类SLF方法^[2]、相关分析类SLF方法^[3]、用地仿真类SLF方法^[4-5]以及负荷密度指标类SLF方法^[6-8]4种。

趋势类SLF方法利用空间负荷历史数据外推负荷发展趋势进行预测^[2]。尽管这种方法操作方便且对数据的要求较低,但是在面对负荷转移或负荷非线性增长等情况时预测精度较低。

相关分析类SLF方法通过计算每个元胞年负荷历史数据的最大值与影响负荷最大值的各变量之间的相关关系进行预测^[3]。因为该方法对数据的质和量都有很高的要求,同时影响空间负荷的变量较多,所以其可操作性较差,这种方法已经被淘汰。

用地仿真类SLF方法通过分析土地使用特性和发展模式,预测土地用途、地理分布及面积,进而推算出相应的空间负荷^[4-5]。然而,该方法将分类负荷密度当作已知量,忽视了负荷同时率的问题,也没有

考虑同类负荷的不同发展程度问题,导致预测精度较低。

负荷密度指标类SLF方法通过计算不同功能区域的占地面积和负荷密度求得负荷值^[6-7]。这种方法因其在应对城市规划方案调整时所表现出的强适应性而受到我国学者的广泛关注。随着人工智能领域快速发展以及智能电表等设备收集到的大量历史数据为人工智能算法的应用提供数据基础^[8-12],目前已有许多基于人工智能算法的负荷密度指标类SLF方法。文献[13]利用秩次集对分析理论在多种不同集合容量下分别建立模型进行SLF,选取相对误差最小的预测值作为最终的预测值。文献[14]根据区域分类、负荷分类对样本进行划分,根据待测地块的属性信息对样本空间进行匹配,使用支持向量机进行SLF。文献[15]利用 3σ 准则对元胞负荷数据进行预处理,并利用自适应噪声完备集合经验模态分解对元胞负荷时间序列进行分解,再使用长短期记忆(long short term memory, LSTM)网络实现SLF。文献[16]提取不同地块的空间负荷密度分布规律和负荷曲线典型形态,构建Softmax模型匹配未知地块的负荷水平类型进行SLF。然而,上述文献均侧重挖掘元胞负荷数据的时间特征规律,没有充分考虑到元胞之间的空间影响关系。

文献[17]使用Ⅰ类元胞历史负荷数据和元胞之间的电网拓扑结构构建空间负荷时空信息图,利用时空图卷积网络(spatio-temporal graph convolutional network, STGCN)结合元胞负荷的空间维度特征和时间维度特征进行SLF。文献[18]利用时空图注意力网络(spatio-temporal graph attention network, STGAT)综合考虑元胞负荷之间的空间影响关系和

收稿日期:2024-11-13;修回日期:2026-01-21

在线出版日期:2026-03-24

基金项目:国家自然科学基金重点项目(U22B20105);国家重点研发计划项目(2017YFB0902205);吉林省产业创新专项基金项目(2019C058-7)

Project supported by the National Natural Science Foundation of China(U22B20105), the National Key R&D Program of China(2017YFB0902205) and the Industrial Innovation Foundation of Jilin Province(2019C058-7)

元胞负荷的时序发展规律进行SLF。但上述文献均使用Ⅰ类元胞构成的图数据进行预测,邻接矩阵建立困难,且无法应对在预测时间段内Ⅰ类元胞形状、数量和大小发生变化的情况。文献[19]使用空间卷积技术对相邻元胞产生的负荷影响进行量化,利用变异系数法评估元胞接受相邻元胞影响的能力,综合考虑二者的共同作用进行SLF,但该文献仅考虑相邻元胞对本位元胞的影响,没有更进一步挖掘元胞负荷之间的相互影响关系。

综上,为了避免直接使用由Ⅰ类元胞刻画的空间电力负荷历史数据进行预测所带来的问题,并更好地挖掘元胞负荷之间的空间关系,本文提出一种考虑元胞负荷时空特征的SLF方法,将由Ⅱ类元胞刻画的空间电力负荷作为SLF数据集,同时利用图卷积网络(graph convolutional network, GCN)和门控循环单元(gated recurrent unit, GRU)构建预测模型,综合考虑元胞负荷之间的空间影响关系和元胞负荷自身的时序发展规律,并在我国东北某市的部分行政区域进行SLF,结果验证了该方法的有效性。

1 考虑元胞负荷时空特征的SLF基本原理

本文提出的考虑元胞负荷时空特征的SLF方法基本原理图如图1所示。




图1 基本原理图

Fig.1 Diagram of basic principle

首先,整合待预测区域的网架结构、用地信息、10 kV 馈线供电范围和历史负荷数据。其次,建立配准基图、用地信息图层、Ⅰ类元胞图层和Ⅱ类元胞图层。再次,应用广义极端学生化偏差(generalized extreme studentized deviate, GESD)算法检测

Ⅰ类元胞历史负荷数据的奇异值,并采用文献[20]中的空间电力负荷网格化技术生成Ⅱ类元胞负荷数据,将各Ⅱ类元胞的几何中心作为节点,将元胞负荷数据作为节点的特征信息,并将元胞之间的结构作为边,构建由Ⅱ类元胞刻画的空间负荷时空信息图。然后,构建基于GCN-GRU的SLF模型,将Ⅱ类元胞的空间负荷时空信息图数据和对应的邻接矩阵作为输入,利用GCN构建空间特征提取模型,提取Ⅱ类元胞负荷之间的空间特征,利用GRU构建时序特征提取模型,提取Ⅱ类元胞负荷的时序特征,并通过全连接层输出基于Ⅱ类元胞的SLF结果。最后,将本文方法与其他对比方法的预测结果进行比较分析。

对于Ⅰ类元胞和Ⅱ类元胞,有以下几点说明。

1)空间电力负荷的刻画。

为了能够在电力地理信息系统(geographic information system, GIS)中明确空间电力负荷的位置和分布,将待预测区域按照既定标准划分为规则或不规则的供电小区,将每个供电小区称为一个负荷元胞(简称元胞),并以元胞为最小“像素”来辨识空间电力负荷。

2)元胞的分类。

在电力GIS中,将按供电设备、供电设施等的供电范围生成的元胞记作Ⅰ类元胞,将按等大小规则网格生成的元胞记作Ⅱ类元胞。

3)Ⅱ类元胞的特点。

采用Ⅰ类元胞来刻画空间电力负荷的优势在于负荷数据获取方便,可直接通过供电设备的关口表来获得元胞负荷数据。其不足之处在于,随着电网的发展,Ⅰ类元胞的形状、数量、大小和位置都可能发生变化,从而出现历年关口表数据无法与目标年的Ⅰ类元胞相匹配的情况,进而导致预测方法失效或预测精度下降。

采用Ⅱ类元胞来刻画空间电力负荷的优势在于,Ⅱ类元胞的形状、数量、大小和位置可以始终保持不变。虽然该方法存在直接获取Ⅱ类元胞负荷值非常困难的问题,但是可以利用空间电力网格化技术来间接获取。

2 元胞负荷数据奇异值的检测与修正

SLF使用的数据质量会影响预测结果的准确性。负荷异常变化或采集人员误操作都会使Ⅰ类元胞的负荷数据出现奇异值,若直接使用元胞负荷数据的实测值进行预测,则会导致预测精度降低。

目前常见的数据奇异值检测方法主要分为三大类:第1类是基于机器学习的方法,包含支持向量机、随机森林、孤立森林等方法,该方法适用于复杂度较高的数据,但需要进行复杂的模型训练,超参数选择困难;第2类是基于距离的方法,包含K均值聚类、密度峰值聚类等方法,该方法简单直观,但

面对规模较大或分布复杂的数据集时检测效果并不理想;第3类是基于统计学的方法,包含 3σ 法则、GESD算法等方法,该类方法具有解释性强、无需复杂的模型训练(即不需要定义复杂的超参数)、易于实现的优点,但不适用于高维数据的奇异值检测。

虽然 I 类元胞负荷历史数据量庞大且奇异值较多,但是这类元胞数据不属于高维数据,且 GESD 算法除了具有第3类检测方法的优点之外,还能通过每次迭代来逐步剔除最偏离的奇异值并重新调整统计量,避免奇异值对后续计算的过度影响,具有较好的检测效果,因此本文采用 GESD 算法对 I 类元胞负荷中的奇异值进行检测,该算法的实现流程如下。

1) 定义 I 类元胞负荷数据集中奇异值数的上限为 M , 循环次数记作 i , 并令初始 $i=1$ 。

2) 计算 I 类元胞负荷数据集的平均值 $\bar{X}$ 和标准差 δ , 其中 δ 的计算公式如式(1)所示。

$$\delta = \frac{1}{P} \sqrt{\sum_{j=1}^P (X_j - \bar{X})^2} \quad (1)$$

式中: $X_j (j=1, 2, \dots, P)$ 为第 j 个 I 类元胞的负荷值, P 为既定时间段内 I 类元胞负荷的采样数。

3) 分别计算每个时间点的 I 类元胞负荷值与负荷数据平均值的数据偏差, 选择其中最大的偏差计算检验统计值, 将第 i 次检验统计值记作 S_i , 其计算公式为:

$$S_i = \frac{\max |Y_i - \bar{X}|}{\delta} \quad (2)$$

式中: Y_i 为第 i 次检验统计对应的 I 类元胞负荷值。

4) 计算检验统计值 S_i 对应的检验临界值 λ_i , 其计算公式为:

$$\lambda_i = \frac{(P-i)t_{P-i-1, \beta}}{\sqrt{(P-i-1+t_{P-i-1, \beta}^2)(P-i+1)}} \quad (3)$$

$$\beta = 1 - \frac{\alpha}{2(P-i-1)} \quad (4)$$

式中: $t_{P-i-1, \beta}$ 为自由度是 $P-i-1$ 、概率水平是 β 的 t 分布值; α 为显著性水平, 通常取 0.05。

5) 将检验统计值 S_i 与检验临界值 λ_i 相比较: 若 $S_i > \lambda_i$, 则该数据为奇异值; 若 $S_i \leq \lambda_i$, 则转至步骤 7)。

6) 在原始数据集中删除检验统计值 S_i 对应的 I 类元胞负荷数据 Y_i , 得到新的 I 类元胞负荷数据集。若 $i=M$, 则执行步骤 7); 否则, $i=i+1$, 并返回步骤 2) 继续循环。

7) 输出 I 类元胞负荷数据集的全部奇异值, 结束循环。

对 GESD 算法检测出的 I 类元胞负荷数据奇异值进行如下处理: 对于检测出的单一奇异值, 使用当日负荷数据的平均值进行替换; 对于检测出的连续奇异值序列, 使用相似日负荷数据进行替换。使用空间电力负荷网格化技术将修正后的 I 类元胞负荷

数据转化成由 II 类元胞刻画的空间电力负荷数据。

3 基于 GCN-GRU 的 SLF

3.1 基于 GCN 的空间特征提取模型

考虑到 GCN 是一种处理图结构信息的深度学习模型, 可以对图中的节点进行特征学习和提取^[21-23], 因此, 本文在进行 SLF 时, 使用 GCN 来提取 II 类元胞负荷的空间特征。

II 类元胞的空间负荷时空信息图 G 可以描述为 $G=(V, E)$ 。其中: V 为所有 II 类元胞节点的集合, 包含节点的特征信息; E 为边的集合, 图中的边用于连接 2 个相邻的 II 类元胞节点。

本文利用 II 类元胞的图结构生成邻接矩阵 $A \in \mathbf{R}^{N \times N}$ (N 为 II 类元胞数), 对 II 类元胞的空间相关性进行建模。在 II 类元胞的空间分布中, 若 2 个 II 类元胞存在公共边, 则认为 2 个 II 类元胞是相邻关系。由于任意 2 个相邻 II 类元胞节点之间的距离均相等, 因此在 II 类元胞的图结构中: 若元胞节点 v_p 与元胞节点 v_q 相邻, 则 $a_{pq}=1$ (a_{pq} 为邻接矩阵中第 p 行第 q 列的值); 反之, 若元胞节点 v_p 与元胞节点 v_q 不相邻, 则 $a_{pq}=0$ 。以第 1 行、第 2 行的前 3 列 II 类元胞为例, 由 II 类元胞的空间分布可以得到对应的图结构和邻接矩阵, 如附录 A 图 A1 所示。

II 类元胞负荷的空间特征提取模型如图 2 所示, 图中 σ_1 为 ReLU 激活函数。空间特征提取模型包含多个隐藏层, 每个隐藏层仅处理 1 阶邻域特征信息, 通过多个隐藏层的叠加可以实现多阶邻域特征信息的传递与聚合。若仅使用 1 个隐藏层, 则每个 II 类元胞节点只能获取与之相邻的元胞节点特征; 若使用多个隐藏层, 则会导致不同 II 类元胞节点之间的特征区分度逐渐降低, 出现过平滑现象。由于 II 类元胞负荷的数量较多且特征区分度较小, 因此本文的空间特征提取模型使用 2 个隐藏层来处理 II 类元胞负荷的邻域特征信息。




图2 空间特征提取模型

Fig.2 Spatial feature extraction model

通过空间特征提取模型提取 II 类元胞负荷空间特征的步骤如下。

首先, 为了在聚合相邻 II 类元胞的节点特征时结合元胞自身的节点特征, 将邻接矩阵 A 和度矩阵 D 各自加上单位矩阵得到新的邻接矩阵 $\tilde{A}$ 和度矩阵 $\tilde{D}$, 分别通过式(5)和式(6)进行计算。 D 是一个对角矩阵, d_{mm} 为与 II 类元胞节点 v_m 相邻的元胞数, 是度

矩阵中第 m 行第 n 列的值,通过式(7)进行计算。

$$\tilde{A} = A + I \quad (5)$$

$$\tilde{D} = D + I \quad (6)$$

$$d_{mn} = \sum_{n=1}^N a_{mn} \quad (7)$$

式中: I 为单位矩阵; a_{mn} ($m=1,2,\dots,N; n=1,2,\dots,N$) 为邻接矩阵中第 m 行第 n 列的值。

其次,利用 $\tilde{D}$ 对 $\tilde{A}$ 进行处理,得到归一化后的邻接矩阵 $\hat{A}$,防止 II 类元胞节点因接收过量的相邻元胞节点特征信息而影响聚合过程。 $\hat{A}$ 的计算公式为:

$$\hat{A} = \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} \quad (8)$$

最后,将 $\hat{A}$ 乘以 II 类元胞节点的特征矩阵和对应的权重矩阵,通过激活函数得到聚合元胞自身节点特征和相邻元胞节点特征后的 II 类元胞节点特征,其计算公式为:

$$H^{(l+1)} = \sigma_1(\hat{A}H^{(l)}W^{(l)}) \quad (9)$$

式中: $H^{(l+1)}$ 为第 l 个隐藏层输出的 II 类元胞节点特征矩阵; $H^{(l)}$ 为第 l 个隐藏层输入的 II 类元胞节点特征矩阵; $W^{(l)}$ 为第 l 层的权重矩阵。

空间特征提取模型将 II 类元胞自身的节点特征与相邻元胞的节点特征进行聚合,输出含有空间特征的 II 类元胞负荷。

3.2 基于 GRU 的时序特征提取模型

本文使用 GRU 构建 II 类元胞负荷的时序特征提取模型,其结构如图 3 所示。图中:“ $\odot$ ”为哈达玛积运算,即相同阶数矩阵中的对应元素相乘;“ $\oplus$ ”为加法运算;“ $\ominus$ ”为被减数是 1 的减法运算; σ_2 为 Sigmoid 函数; T 为 II 类元胞负荷的总时间步长; x_T 为 T 时刻的 II 类元胞负荷数据; r_T, z_T 分别为 T 时刻重置门和更新门的状态向量; $\tilde{h}_T, h_T$ 分别为 T 时刻的候选状态向量和 GRU 输出状态向量。




图3 时序特征提取模型

Fig.3 Sequential feature extraction model

GRU 是基于 LSTM 网络的改进循环神经网络模型,将 LSTM 模型中的 3 个门结构^[24]整合为重置门和更新门 2 个门结构,重置门负责控制保存前一时间步的神经元输出数据特征权重,更新门负责控制当前时间步的神经元输入数据信息权重^[25-27]。这些权重在训练过程中通过训练集进行更新,训练完成后保存权重,形成时序特征提取模型。在保证精度的前提下,

由于参数较少,GRU 更容易训练,计算效率更高^[28-29]。

时序特征提取模型在 t 时刻有当前时刻的 II 类元胞负荷数据 x_t 和上一时刻的输出向量 h_{t-1} 这 2 个输入,通过式(10)~(12)计算得到时序特征提取模型中 t 时刻的 II 类元胞候选状态向量 $\tilde{h}_t$ 。

$$r_t = \sigma_2(W_r[h_{t-1}, x_t] + b_r) \quad (10)$$

$$z_t = \sigma_2(W_z[h_{t-1}, x_t] + b_z) \quad (11)$$

$$\tilde{h}_t = \tanh(W_{\tilde{h}}[r_t h_{t-1}, x_t] + b_{\tilde{h}}) \quad (12)$$

式中: r_t, z_t 分别为 t 时刻重置门和更新门的状态向量; $W_r, W_z, W_{\tilde{h}}$ 分别为重置门、更新门、候选集的权重参数矩阵; $b_r, b_z, b_{\tilde{h}}$ 为偏置向量; “[]”表示向量拼接。

利用 $\tilde{h}_t, h_{t-1}$ 和 z_t 计算得到 t 时刻的 II 类元胞负荷时序特征向量 h_t , 计算公式为:

$$h_t = (1 - z_t)h_{t-1} + z_t\tilde{h}_t \quad (13)$$

3.3 基于 GCN-GRU 的负荷时空特征提取模型

为综合考虑 II 类元胞之间的空间影响以及元胞的时序发展规律,首先通过空间特征提取模型输出 II 类元胞节点的空间特征,然后通过时序特征提取模型输出 II 类元胞负荷的时空特征,其提取过程如图 4 所示。




图4 II类元胞负荷的时空特征提取过程

Fig.4 Spatio-temporal feature extraction process of Type II cellular load

3.4 构建基于 GCN-GRU 的 SLF 模型

本文使用 GCN 和 GRU 构建基于 II 类元胞的 SLF 模型,其结构如图 5 所示。

首先,将 II 类元胞的空间负荷时空信息图数据和对应的邻接矩阵作为空间特征提取模型的输入,利用 2 个隐藏层对每个 II 类元胞节点的特征和相邻元胞节点的特征进行聚合,实现对 II 类元胞负荷空间特征的提取。然后,将提取空间特征后的 II 类元胞负荷输入时序特征提取模型中进行时序特征提取,得到 II 类元胞负荷的时空特征矩阵。最后,通过全连接层输出基于 II 类元胞的 SLF 预测值。

4 算例分析

在每年均对电网发展规划的 5 a 计划进行滚动修订的场景下,依据本文提出的 SLF 方法,以我国东北某市的部分行政区域为例,使用其 2009—2013 年




图5 基于II类元胞的SLF模型

Fig.5 SLF model based on Type II cell

的历史负荷数据值,预测该区域2014年的空间负荷值(每个II类元胞负荷的年最大值)。

4.1 建立电力GIS

在电力GIS中,根据城市规划方案,将待预测区域划分为8种用地类型,建立用地信息图层;按照10 kV供电范围生成I类元胞图层;按照边长为300 m的等大小正方形规则网格生成II类元胞图层。待预测地区用地信息图层和I类元胞图层如附录A图A2所示。

4.2 相关数据的处理

4.2.1 历史负荷数据中奇异值的检测与修正

在待预测区域内,与各条10 kV馈线对应的I类元胞的历史负荷数据实测值采样间隔为5 min,即在2009—2013年中每个I类元胞均有52万多个负荷数据值。将I类元胞的历史负荷数据按月进行分组,使用GESD算法分别检测各组历史负荷数据中的奇异值,将单一的奇异值替换为当天的平均负荷值,并将连续的奇异值替换为相似日对应时段的负荷数据。

4.2.2 模型的输入/输出数据

由于本文提出的SLF方法主要用于电力系统规划的短期(1 a或5 a)预测,因此将修正后的2009—2013年每个I类元胞负荷中各月的最大负荷值作为该I类元胞的月负荷合理最大值,并在电力GIS中,采用空间电力负荷网格化技术将其转化为II类元胞负荷合理最大值,作为预测模型的输入。通过预测2014年II类元胞各月的负荷值,确定II类元胞的年负荷最大值,并将其作为预测模型的输出。

4.3 预测模型参数设置

本文所构建的基于GCN-GRU的SLF模型的参数如下:GCN的网络层数为2,隐藏层单元数为32,

训练迭代轮数为100,学习率为0.001;GRU的网络层数为1,隐藏层单元数为64,训练迭代轮数为100,批处理大小为32,输入层时间步长为5,学习率为0.001。模型使用均方误差损失函数。GCN使用设置为0.2的Dropout以防止模型过拟合;GRU使用L2正则化以防止模型过拟合,权重衰减系数为0.01。

4.4 预测结果分析

4.4.1 预测结果的幅值误差比较

将本文方法与传统的灰色理论法、线性回归法、指数平滑法以及GCN预测法、GRU预测法、GCN-LSTM预测法、STGAT预测法的预测结果进行对比分析。其中STGAT预测法使用图注意力网络(graph attention network, GAT)来提取元胞负荷之间的空间关系。对比方法的模型参数如附录A表A1所示。

为了更加直观地展示II类元胞的预测结果,本文将II类元胞准实测值和除传统方法外其他3种方法的II类元胞预测值在电力GIS中显示,所有II类元胞负荷数据的大小均以颜色深浅表示,颜色越深表示元胞负荷数据越大,反之则越小,如附录A图A3所示。表1给出了所有预测方法的幅值误差,评价指标采用平均绝对误差和平均相对误差。

表1 II类元胞负荷预测值的幅值误差

Table 1 Amplitude errors of forecasted values for Type II cellular load

预测方法	平均绝对误差 / MW	平均相对误差 / %
灰色理论法	0.099	28.34
线性回归法	0.091	24.43
指数平滑法	0.090	27.96
GCN预测法	0.060	7.71
GRU预测法	0.063	9.29
GCN-LSTM预测法	0.046	5.65
STGAT预测法	0.055	4.17
本文方法	0.042	5.29

由表1可知:相较于GCN预测法和GRU预测法,本文方法的平均绝对误差分别降低了0.018 MW和0.021 MW,平均相对误差分别降低了2.42个百分点和4个百分点,这说明无论是仅考虑元胞负荷之间空间影响关系还是仅考虑元胞负荷自身时序发展规律的预测方法,均劣于本文方法,即综合考虑元胞负荷空间和时间两方面的影响可以有效提高预测精度;GCN预测法和GRU预测法的平均绝对误差和平均相对误差均高于GCN-LSTM预测法和STGAT预测法,这进一步表明在进行SLF时仅考虑元胞负荷之间的空间关系或元胞负荷的时序发展规律是不够的;相较于GCN-LSTM预测法,本文方法的平均绝对误差和平均相对误差分别低了0.004 MW和0.36个百分点,可见本文方法优于GCN-LSTM预测法,这也说明在处理时间序列时GRU优于LSTM。

图6是8种SLF方法预测结果的幅值误差比较,

图中黄色部分是以本文方法所得预测结果为半径绘制的圆。可见,预测结果幅值误差值落在黄色圆外的方法预测精度均低于本文方法。




图6 预测结果的幅值误差比较

Fig.6 Amplitude error comparison of forecasting results

由图6可知,与人工智能预测方法(本文方法、GCN预测法、GRU预测法、GCN-LSTM预测法、STGAT预测法)相比,传统预测方法的预测结果平均绝对误差和平均相对误差离原点均更远,即传统方法的幅值误差普遍更大,这说明应用人工智能技术的SLF方法能够显著提高预测精度。

由图6(a)可知,除本文方法之外的其他7种预测方法所得预测结果的平均绝对误差均在黄色圆之外,显然本文方法的预测精度最高。由图6(b)可知,只有本文方法和STGAT预测法的平均相对误差在黄色圆内,这2种方法优于其他6种SLF方法,但STGAT预测法的平均相对误差更接近原点,因此,若仅通过幅值误差的比较,则很难判断本文方法和STGAT预测法的优劣。

4.4.2 预测结果的幅空误差比较

平均绝对误差和平均相对误差都是对预测结果误差的幅值大小进行量化,但实际上仅考虑幅值大小来评价SLF方法的效果是不充分的,即使2种SLF方法的幅值误差相同,误差的空间位置差异也会对配电设施容量的优化配置、投放位置等产生不同的影响。

为了更充分地分析不同SLF方法的预测效果,引入文献[30]中的幅空误差评价方法。该方法将Ⅱ类元胞预测结果的正负误差进行抵消,得到幅空抵消影响值 O_{EIV} ,将剩余未抵消的误差进行叠加,得到

幅空叠加影响值 O_{REIV} ,将2个影响值相加得到的误差影响值 O_{EIV} 作为综合评价指标。 O_{OEIV} 值越小,说明已抵消误差对电网规划不利影响的削弱效果越显著; O_{REIV} 值越小,说明未抵消误差给电网规划带来的不利影响越小; O_{EIV} 值越小,说明SLF方法的预测效果越好,对电网规划造成的不利影响越小。

表2为各种预测方法的幅空误差。由表可知,相较于其他对比方法,本文方法的 O_{EIV} 指标最小,即本文方法对电网规划造成的不利影响最小。

表2 Ⅱ类元胞负荷预测值的幅空误差

Table 2 Amplitude-space errors of forecasted values for Type II cellular load
单位: MW·m

预测方法	O_{OEIV}	O_{REIV}	O_{EIV}
灰色理论法	398.035	458.901	856.936
线性回归法	389.133	428.417	817.550
指数平滑法	412.511	411.012	823.523
GCN预测法	425.817	351.861	777.678
GRU预测法	460.254	302.649	762.903
GCN-LSTM预测法	442.896	316.877	759.773
STGAT预测法	446.051	305.678	751.729
本文方法	434.296	308.037	742.333

图7比较了本文方法与其他7种方法预测结果的3个误差评价指标,图中方法1—8分别表示灰色理论法、线性回归法、指数平滑法、GCN预测法、GRU预测法、GCN-LSTM预测法、STGAT预测法、本文方法。可见,本文方法的平均绝对误差和误差影响值均为最低,虽然其平均相对误差略高于STGAT预测法,但从总体来看,本文方法的预测效果明显优于其他7种预测方法。




图7 Ⅱ类元胞预测结果的误差比较

Fig.7 Error comparison of forecasting results for Type II cell

5 结论

本文提出一种考虑元胞负荷时空特征的SLF方法,通过分析得到以下结论:

1)该方法采用由Ⅱ类元胞刻画的空间电力负荷进行预测,能够很好地克服既定时间段内待预测区域供电范围改变或新电力设备投入导致Ⅰ类元胞的形状、数量和大小发生改变,从而影响SLF的问题;

2)该方法通过利用GESD算法对Ⅰ类元胞负荷历史数据进行奇异值检测和处理,能够有效地消除负荷数据中奇异值给SLF带来的不利影响;

3)该方法综合考虑了利用GCN挖掘的Ⅱ类元胞间的空间影响关系以及利用GRU挖掘的Ⅱ类元胞负荷在时序上的发展规律,比其他典型SLF方法具有更高的预测精度。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 肖白,周潮,穆钢. 空间电力负荷预测方法综述与展望[J]. 中国电机工程学报,2013,33(25):78-92.
Xiao Bai, Zhou Chao, Mu Gang. Review and prospect of the spatial load forecasting methods[J]. Proceedings of the CSEE, 2013, 33(25):78-92.
- [2] 王雁凌,吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. 电力自动化设备,2018,38(3):133-139.
Wang Yanling, Wu Mengkai. Medium and long term load forecasting model based on partial least-square regression under new normal economy[J]. Electric Power Automation Equipment, 2018, 38(3):133-139.
- [3] Melo J D, Carreno E M, Padilha-Feltrin A. Estimation of a preference map of new consumers for spatial load forecasting simulation methods using a spatial analysis of points[J]. International Journal of Electrical Power & Energy Systems, 2015, 67:299-305.
- [4] 伊桂玲,张焰. 基于用地仿真法的配电系统空间负荷预测[J]. 电力自动化设备,2004,24(2):20-23.
Yi Guiling, Zhang Yan. Land usage-based spatial load forecasting in distribution system[J]. Electric Power Automation Equipment, 2004, 24(2):20-23.
- [5] Ye C J, Ding Y, Wang P, et al. A data-driven bottom-up approach for spatial and temporal electric load forecasting[J]. IEEE Transactions on Power Systems, 2019, 34(3):1966-1979.
- [6] 肖白,孙旭,张大弛,等. 基于DBSCAN和改进ConvLSTM的空间负荷预测方法[J]. 电力自动化设备,2026,46(2):169-175.
Xiao Bai, Sun Xu, Zhang Dachi, et al. Spatial load forecasting method based on DBSCAN and improved ConvLSTM[J]. Electric Power Automation Equipment, 2026, 46(2):169-175.
- [7] 邓燕国,王冰,曹智杰,等. 基于熵权法与GRA-ELM的配电网空间负荷预测[J]. 电力工程技术,2021,40(4):136-141.
Deng Yanguo, Wang Bing, Cao Zhijie, et al. Spatial load forecasting of distribution network based on entropy weight method and GRA-ELM[J]. Electric Power Engineering Technology, 2021, 40(4):136-141.
- [8] 余凯峰,吐松江·卡日,张紫薇,等. 基于级联MCNN-MMLP双残差网络的短期负荷预测[J]. 电力系统保护与控制,2025,53(2):151-162.
Yu Kaifeng, Tusongjiang·Kari, Zhang Ziwei, et al. Short-term load forecasting based on a cascade MCNN-MMLP double residual network[J]. Power System Protection and Control, 2025, 53(2):151-162.
- [9] 崔杨,朱晗,王议坚,等. 基于CNN-SAEDN-Res的短期电力负荷预测方法[J]. 电力自动化设备,2024,44(4):164-170.
Cui Yang, Zhu Han, Wang Yijian, et al. Short-term power load forecasting method based on CNN-SAEDN-Res[J]. Electric Power Automation Equipment, 2024, 44(4):164-170.
- [10] 封钰,宋佑斌,金晟,等. 基于随机森林算法和粗糙集理论的改进型深度学习短期负荷预测模型[J]. 发电技术,2023,44(6):889-895.
Feng Yu, Song Youbin, Jin Sheng, et al. Improved deep learning model for forecasting short-term load based on random forest algorithm and rough set theory[J]. Power Generation Technology, 2023, 44(6):889-895.
- [11] 刘锦翔,张江丰,董山玲,等. 基于条件增强扩散模型的短期负荷概率预测[J]. 电力系统自动化,2024,48(23):197-207.
Liu Jinxiang, Zhang Jiangfeng, Dong Shanling, et al. Short-term load probabilistic forecasting based on conditional enhanced diffusion model[J]. Automation of Electric Power Systems, 2024, 48(23):197-207.
- [12] 余强,韩静娴,杨子梁,等. 基于改进双重压缩和激励与多头特征注意力机制的电-热负荷协同预测[J]. 电力自动化设备,2025,45(3):201-208.
Yu Qiang, Han Jingxian, Yang Ziliang, et al. Collaborative forecasting of electricity-thermal load based on improved dual squeeze and excitation and multi-head feature attention mechanism[J]. Electric Power Automation Equipment, 2025, 45(3):201-208.
- [13] 肖白,张婕,姜卓,等. 基于秩次集对分析理论的空间负荷预测方法[J]. 电力自动化设备,2020,40(4):153-158.
Xiao Bai, Zhang Jie, Jiang Zhuo, et al. Spatial load forecasting method based on rank set pair analysis[J]. Electric Power Automation Equipment, 2020, 40(4):153-158.
- [14] 刘思,傅旭华,叶承晋,等. 考虑地域差异的配电网空间负荷聚类及一体化预测方法[J]. 电力系统自动化,2017,41(3):70-75,82.
Liu Si, Fu Xuhua, Ye Chengjin, et al. Spatial load clustering and integrated forecasting method of distribution network considering regional difference[J]. Automation of Electric Power Systems, 2017, 41(3):70-75, 82.
- [15] 肖白,高文瑞,李道明,等. 基于3 σ -CEEMDAN-LSTM的空间负荷预测方法[J]. 电力自动化设备,2023,43(3):159-165.
Xiao Bai, Gao Wenrui, Li Daoming, et al. Spatial load forecasting method based on 3 σ -CEEMDAN-LSTM[J]. Electric Power Automation Equipment, 2023, 43(3):159-165.
- [16] 郑伟民,叶承晋,张曼颖,等. 基于Softmax概率分类器的数据驱动空间负荷预测[J]. 电力系统自动化,2019,43(9):117-124.
Zheng Weimin, Ye Chengjin, Zhang Manying, et al. Data-driven spatial load forecasting method based on Softmax probabilistic classifier[J]. Automation of Electric Power Systems, 2019, 43(9):117-124.
- [17] 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.
- [18] 赵紫昱,陈渊睿,陈霆威,等. 基于时空图注意力网络的超短期区域负荷预测[J]. 电力系统自动化,2024,48(12):147-155.
Zhao Ziyu, Chen Yuanrui, Chen Tingwei, et al. Ultra-short-term regional load forecasting based on spatio-temporal graph attention network[J]. Automation of Electric Power Systems, 2024, 48(12):147-155.
- [19] 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 fore-

- casting considering acceptability of standard cell and influence of load of adjacent cells[J]. Automation of Electric Power Systems, 2021, 45(12): 57-64.
- [20] 肖白, 杨修宇, 穆钢, 等. 基于元胞历史负荷数据的负荷密度指标法[J]. 电网技术, 2014, 38(4): 1014-1019.
Xiao Bai, Yang Xiuyu, Mu Gang, et al. A load density index method based on historical data of cell load[J]. Power System Technology, 2014, 38(4): 1014-1019.
- [21] Hossain R R, Huang Q H, Huang R K. Graph convolutional network-based topology embedded deep reinforcement learning for voltage stability control[J]. IEEE Transactions on Power Systems, 2021, 36(5): 4848-4851.
- [22] 李轻言, 林涛, 杜蕙, 等. 面向直流受端新型电力系统暂态电压稳定的紧急控制策略[J]. 电力自动化设备, 2024, 44(3): 195-202.
Li Qingyan, Lin Tao, Du Hui, et al. Emergency control for transient voltage stability of HVDC receiving-end new power system[J]. Electric Power Automation Equipment, 2024, 44(3): 195-202.
- [23] Liao W L, Bak-Jensen B, Radhakrishna P J, 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.
- [24] 张哲, 王勃. 基于CBAM-LSTM的风电集群功率短期预测方法[J]. 东北电力大学学报, 2024, 44(1): 1-8.
Zhang Zhe, Wang Bo. Short-term power prediction method of wind power cluster based on CBAM-LSTM[J]. Journal of Northeast Dianli University, 2024, 44(1): 1-8.
- [25] Liu W, Wang Q, Zhu Y L, et al. GRU: optimization of NPI performance[J]. The Journal of Supercomputing, 2020, 76(5): 3542-3554.
- [26] 张丽, 李世情, 艾恒涛, 等. 基于改进Q学习算法和组合模型的超短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(9): 143-153.
Zhang Li, Li Shiqing, Ai Hengtao, et al. Ultra-short-term power load forecasting based on an improved Q-learning algorithm and combination model[J]. Power System Protection and Control, 2024, 52(9): 143-153.
- [27] 臧海祥, 赵勇凯, 张越, 等. 基于低风速功率修正和损失函数改进的超短期风电功率预测[J]. 电力系统自动化, 2024, 48(7): 248-257.
Zang Haixiang, Zhao Yongkai, Zhang Yue, et al. Ultra-short-term wind power prediction based on power correction under low wind speed and improved loss function[J]. Automation of Electric Power Systems, 2024, 48(7): 248-257.
- [28] 庞昊, 高金峰, 杜耀恒. 基于多神经网络融合的短期负荷预测方法[J]. 电力自动化设备, 2020, 40(6): 37-42.
Pang Hao, Gao Jinfeng, Du Yaoheng. Short-term load forecasting method based on fusion of multiple neural networks[J]. Electric Power Automation Equipment, 2020, 40(6): 37-42.
- [29] 王建军, 潘佳音, 赵珍珠, 等. 基于特征时间双注意力机制的短期光伏发电预测深度学习模型研究[J]. 智慧电力, 2025, 53(4): 81-87.
Wang Jianjun, Pan Jiayin, Zhao Zhenzhu, et al. A deep learning model for short-term photovoltaic power generation forecasting based on dual feature-temporal attention mechanism[J]. Smart Power, 2025, 53(4): 81-87.
- [30] 肖白, 李学思. 基于误差幅空特性分析的空间负荷预测误差评价方法[J]. 中国电机工程学报, 2024, 44(3): 880-893.
Xiao Bai, Li Xuesi. Evaluation method for spatial load forecasting error based on amplitude-space characteristic analysis of the error[J]. Proceedings of the CSEE, 2024, 44(3): 880-893.

作者简介:

肖白(1973—),男,教授,博士,通信作者,研究方向为电力系统规划与运行优化、多能互补协调发电(E-mail: xbxiaobai@126.com);

张福生(1999—),男,硕士研究生,研究方向为空间负荷预测(E-mail: 1539786255@qq.com)。

(编辑 王锦秀)

Spatial load forecasting method considering spatial and temporal characteristic of cellular load

Xiao Bai¹, Zhang Fusheng¹, Zhang Dachi², Xin Haokuo², Yao Di², Kong Yihui³

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education, Northeast Electric Power University, Jilin 132012, China;

2. Power Economic Research Institute of State Grid Jilin Electric Power Co., Ltd., Changchun 130021, China;

3. Yanbian Power Supply Company of State Grid Jilin Electric Power Supply Co., Ltd., Yanji 133000, China)

Abstract: In order to avoid error in spatial load forecasting caused by the change of shape, quantity, size and position of Type I cell, and to deeply explore the spatial impact relationship between cellular loads for improving spatial load forecasting accuracy, a spatial load forecasting method considering the spatial and temporal characteristic of cellular load is proposed. The generalized extreme studentized deviate algorithm is adopted to detect and correct the singular values in the historical load data of Type I cell. The grid technology for spatial power load is used to transform the spatial power load described by Type I cell into the spatial power load described by Type II cell. The graph convolutional network and gated recurrent unit are used to construct a spatial load forecasting model, in which, the graph convolutional network is used to extract the spatial dimension characteristic of Type II cell, the gated recurrent unit is used to obtain the time dimension characteristic of Type II cell, and the spatial load forecasting results based on Type II cell are output through the full connection layer. The example analysis results verify the effectiveness of the proposed method.

Key words: spatial load forecasting; graph convolutional network; cell; geographic information system; gated recurrent unit