

基于动态关联图注意力网络的虚拟电厂居民短期负荷预测

张峻凯, 胡旭光, 刘要博, 许 晴, 马大中, 孙秋野

(东北大学信息科学与工程学院, 辽宁省沈阳市 110819)

摘要: 居民短期负荷预测能够为虚拟电厂提供实时、灵活的电力需求信息, 有助于虚拟电厂实现能源高效利用与优化电力市场交易。由于居民负荷相关性的日益凸显, 传统预测方法仅基于单个居民历史负荷进行时序预测, 无法满足规模化虚拟电厂对居民负荷关联性的综合需求。基于此, 文中提出一种基于动态关联图注意力网络的虚拟电厂居民短期负荷预测方法。首先, 提出了混合相关性分析方法刻画居民负荷之间的线性与非线性关系, 并进一步提出了权重剪枝阈值机制得到居民负荷混合相关性矩阵; 然后, 基于该矩阵构建动态关联图结构, 进而提出时间图注意力网络机制以深入学习居民负荷的时空关联特性, 并实现居民短期负荷预测目标; 最后, 以某地区实际居民负荷数据为例, 验证了所提方法的有效性。

关键词: 虚拟电厂; 短期负荷预测; 混合相关性; 动态关联图; 图神经网络; 时间图注意力机制

0 引言

虚拟电厂(virtual power plant, VPP)作为能源互联网技术的典型技术组态能够保障电力供应安全性, 是新质生产力在能源领域应用的重要实践^[1-2]。虚拟电厂通过价格激励、负荷削峰等需求响应机制, 实现动态的负荷管理和稳定的电力供应。作为虚拟电厂多能源调配与优化需求的重要一环, 居民短期负荷预测为具有随机性强、社会行为解析困难的海量分布式灵活资源运营主体提供了有效支撑^[3-5]。

针对居民负荷预测研究, 自回归差分滑动模型、回归方法、指数平滑方法等统计学方法被广泛应用, 但均难以适用于波动较大的时间序列负荷数据^[6-8]。随着虚拟电厂聚合资源规模化, 电力负荷呈现出日益复杂的趋势, 机器学习及相关技术凭借其在特征提取和处理大规模数据中复杂非线性关系方面的优势, 已成为短期负荷预测的主流方法^[9-10]。其中, 支持向量机、人工神经网络、反向传播算法等方法能够有效针对负荷数据的波动性进行求解, 但对数据规模要求较高^[11-13]。深度学习模型通过更深的隐藏层模拟人类的思考方式, 提高了对复杂居民负荷时序特征的建模和表征学习能力^[14]。时间卷积网络

(temporal convolutional network, TCN)相较于卷积神经网络(convolutional neural network, CNN), 在处理时序数据时能够识别负荷数据的长期依赖, 但随着模型深度增加, 较大的参数量可能导致在小规模数据集上的过拟合^[15-16]。长短期记忆(long short-term memory, LSTM)网络基于循环神经网络(recurrent neural network, RNN)引入了门控机制, 解决了处理长期居民负荷数据时容易导致梯度消失或爆炸的问题, 优化了对长期居民负荷关系的记忆与捕捉能力^[17-18]。此外, 双向长短期记忆(bidirectional long short-term memory, BiLSTM)网络在LSTM网络多个门控单元的基础上, 通过整合前向和后向居民负荷的隐藏状态, 更高效地提取和传递居民负荷特性^[19]。

上述针对短期负荷预测的深度学习模型集中分析了单一居民的负荷特性, 忽略了居民间的消费行为、生活习惯以及用电时段等群体行为模式的相互影响^[20]。文献[21-22]基于图神经网络(graph neural network, GNN)捕捉具有非欧性质图结构数据的空间依赖关系, 但并非所有居民间的相互作用均存在已知图结构可以直观表示。因此, 基于成对相似性方法^[23], 文献[24]提出了一种结合图卷积网络(graph convolutional network, GCN)与TCN融合的时空图卷积网络(spatio-temporal graph convolutional network, STGCN)模型, 依据电网拓扑结构构建了负荷时空信息图, 并通过阈值高斯核方法来确定STGCN的邻接矩阵。文献[25]将

收稿日期: 2024-03-28; 修回日期: 2024-06-15。

上网日期: 2024-09-23。

国家自然科学基金资助项目(62303103); 辽宁省教育厅基本科研项目(JYTQN2023161); 辽宁省自然科学基金资助项目(2023-BSBA-140)。

GCN与LSTM网络结合,挖掘具有空间和时间信息相似性的居民消费模式。此外,图注意力网络(graph attention network, GAT)相较于GCN在模型设计上引入了注意力机制,通过为居民负荷连接动态地分配权重,使其能够更加有效地处理居民关系的非均匀性,从而为图结构数据的挖掘任务提供了更为精准和有针对性的表示学习能力^[26-27]。

综上所述,现有研究在进行虚拟电厂居民负荷预测时,由于考虑居民相互关系不足,对负荷预测的精度存在影响。为了提升预测精度,本文提出了一种基于动态关联图注意力网络(dynamic association graph attention network, DAGAT)的居民短期负荷预测方法。该方法通过基于成对相似性策略,提出了综合反映居民负荷间线性和非线性关系的混合相关性矩阵,能够深入分析居民负荷之间的关联性。在此基础上,进一步提出了权重剪枝阈值机制,构建能够反映居民间关系变化的动态图结构。通过提出时间图注意力网络(temporal graph attention network, TGAT)机制,深入学习居民间的时空动态关联特性,并实现对居民短期负荷的预测。

1 混合相关性分析与权重剪枝阈值机制

1.1 混合相关性分析

随着虚拟电厂应用场景的多元化,获取居民间高线性关联的信息能够揭示居民间成比例的相互作用。然而,随着虚拟电厂运营的动态性和复杂性日益凸显,居民间也存在复杂的非线性关系。因此,混合相关性分析综合考虑居民间的线性和非线性关系,能够准确描述负荷之间的相关性。

1.1.1 线性相关性

典型相关分析(canonical correlation analysis, CCA)通过计算并分析一系列典型变量对的相关系数,进而选取能够最大化相关系数的典型变量对,以此揭示两组变量间的线性相关性。

假设两组居民历史负荷向量分别为 X 和 Y ,其中, X, Y 分别包含 m, n 个变量, $X=[x_1, x_2, \dots, x_m]$, $Y=[y_1, y_2, \dots, y_n]$ 。设置 u, v 为特定向量变量, CCA用于探索多组特定变量的线性组合(即 $U=Xu$ 和 $V=Yv$),通过最大化典型相关系数 r_k 来描述向量 X 和向量 Y 之间的相关性。CCA计算过程如下:

$$\begin{cases} C_{CCA}(X, Y) = \max(r_1, r_2, \dots, r_k) \\ \text{s.t. } k = \min(m, n) \end{cases} \quad (1)$$

$$r_k = \frac{u_k^T \Sigma_{XY} v_k}{\sqrt{u_k^T \Sigma_{XX} u_k v_k^T \Sigma_{YY} v_k}} \quad (2)$$

式中: $C_{CCA}(X, Y)$ 为向量 X 和向量 Y 之间的线性相关系数; r_k 为向量 X 和向量 Y 之间第 k 个典型相关系数; u_k, v_k 分别为 U, V 的权重向量; Σ_{XX}, Σ_{YY} 分别为向量 X, Y 的协方差矩阵; Σ_{XY} 为向量 X 和向量 Y 之间的协方差矩阵。

CCA不仅可以量度居民之间的线性关联强度,而且通过对权重向量 u_k 和 v_k 进行分析,能够更加直观地反映不同时间窗下负荷数据在居民关系中的关键作用。

1.1.2 非线性相关性

动态时间规整(dynamic time warping, DTW)能够处理时间序列数据的非线性模式和时间轴扭曲问题。通过深度挖掘居民行为中的非线性特征及其在时间上的潜在位移,DTW能够更精确地捕捉并反映居民负荷之间的非线性相关性。

DTW通过匹配居民历史负荷向量 X 和向量 Y 中的元素,旨在最小化它们之间的整体差异,从而衡量它们的非线性相关性。DTW通过迭代更新成本矩阵,能够确定两组居民负荷数据之间的最佳对齐路径。其中,矩阵中的每个元素 $D(x_i, y_j)$ 表示从序列开始到元素 x_i 和元素 y_j 的最小累计距离, $x_i \in X$, $y_j \in Y$ 。DTW的计算过程如下:

$$D(x_i, y_j) = \min \{ D(x_{i-1}, y_j), D(x_i, y_{j-1}), D(x_{i-1}, y_{j-1}) \} + d(x_i, y_j) \quad (3)$$

式中: $d(x_i, y_j)$ 表示元素 x_i 和元素 y_j 之间的距离度量。

DTW非线性相关性计算公式为:

$$P_{\text{path}}(o) = (i, j) \quad (4)$$

$$C_{\text{DTW}}(X, Y) = \min \sum_{o=1}^O D(i_o, j_o) \quad (5)$$

式中: $P_{\text{path}}(o)$ 表示点 i 到点 j 的路径, o 为路径上的步数; O 为完成路径的总步数; $D(i_o, j_o)$ 为路径上起始点到第 o 步的累计距离; $C_{\text{DTW}}(X, Y)$ 表示向量 X 和向量 Y 的非线性相关系数。

通过分析DTW确定的匹配路径,能够挖掘居民负荷行为的潜在规律以及关键时间节点,有助于揭示居民负荷之间的非线性相关性。

1.2 权重剪枝阈值机制

在混合相关性分析基础上,以居民负荷向量 X 和 Y 的 $C_{CCA}(X, Y)$ 和 $C_{\text{DTW}}(X, Y)$ 为权重,构建了反映居民间相互联系的初始加权邻接矩阵。对该矩阵进行预处理,将矩阵中所有负值置换为零,然后执行归一化,得到优化后的居民线性和非线性相关性加权邻接矩阵 $\tilde{A}_l$ 和 $\tilde{A}_n$,为居民相互关系提供定量表征与具象的图形化表示。

基于 $\tilde{A}_l$ 和 $\tilde{A}_{nl}$ 进一步提出了权重剪枝阈值机制,通过设置具体的阈值 T_{thre1} 和 T_{thre2} 筛选具有强关联性的居民负荷关系,即

$$A_l = \begin{cases} \tilde{a}_{l,pq} & \tilde{a}_{l,pq} \geq T_{\text{thre1}} \\ 0 & \text{其他} \end{cases} \quad (6)$$

$$A_{nl} = \begin{cases} 1 - \tilde{a}_{nl,pq} & 1 - \tilde{a}_{nl,pq} \geq T_{\text{thre2}} \\ 0 & \text{其他} \end{cases} \quad (7)$$

式中: A_l 和 A_{nl} 分别为线性和非线性相关性加权邻接矩阵,均为 $m \times m$ 阶矩阵,其中, m 为居民个数; $\tilde{a}_{l,pq}$ 为矩阵 A_l 中的元素; $\tilde{a}_{nl,pq}$ 为矩阵 A_{nl} 中的元素; T_{thre1} 和 T_{thre2} 分别为 A_l 和 A_{nl} 对应的可调节阈值, $T_{\text{thre1}}, T_{\text{thre2}} \in [0, 1]$ 。

混合相关性矩阵能够同时捕捉线性关系以及非线性关系之间的相互作用,如式(8)所示。

$$A^{\text{mix}} = A_l // A_{nl} \quad (8)$$

式中: $A^{\text{mix}} \in \mathbf{R}^{2m \times m}$ 为混合相关性矩阵; $//$ 表示矩阵之间垂直拼接。

混合相关性分析流程见附录A图A1,输入 z 个居民的历史负荷数据 $\{X_{r,1}, X_{r,2}, \dots, X_{r,z}\}$,在每个滑动窗口下根据 $C_{\text{CCA}}(X_{r,\alpha}, X_{r,\beta})$ 和 $C_{\text{DTW}}(X_{r,\alpha}, X_{r,\beta})$ 计算居民负荷间的线性和非线性相关系数,其中, $X_{r,\alpha}, X_{r,\beta}$ 分别为第 α, β 个居民的历史负荷数据。经过矩阵预处理后,通过权重剪枝阈值筛选具有强关联性的居民负荷关系,并将最终线性和非线性相关性加权邻接矩阵通过垂直拼接得到每个滑动窗口下的混合相关性矩阵。

2 动态关联图注意力网络

2.1 动态关联图结构

为了深入研究虚拟电厂调控环境下的居民短期负荷预测问题,构建图结构 $G_r = (N_r, B_r)$ 刻画居民负荷之间具有强关联性的变化关系。其中, $N_r = \{N_{r1}, N_{r2}, \dots, N_{r\lambda}\}$ 为居民节点集合, $N_{r\lambda}$ 为第 λ 个居民节点的负荷; B_r 为连接节点,表示居民间的关联性。

本文中,居民节点特性和居民间关联性分别采用特征矩阵 $X_{N_r} \in \mathbf{R}^{|N_r| \times d_{N_r}}$ 和 $X_{B_r} \in \mathbf{R}^{|B_r| \times d_{B_r}}$ 表示,其中, $|N_r|$ 和 $|B_r|$ 分别为居民节点和其连接个数; d_{N_r} 和 d_{B_r} 分别为居民节点和其连接的维度。考虑虚拟电厂对居民负荷调控的动态性,如居民负荷节点和相关性连接(边)的增减,以及属性随时间演变的特性,动态度描述了图的结构和属性随时间变化的速率和模式。具体分为以下4种典型类型:

类型1:静态节点和静态连接;

类型2:静态节点和动态连接;

类型3:动态节点和动态连接;

类型4:连边固定而节点集动态变化,而连接的存在依赖于节点,故在现实应用中不具有分析意义。

具体情形如附录B图B1所示。图中: $f_{\text{fix}, N_r, B_r}, f_{\text{fix}, N_r}, f_{\text{fix}, \text{none}}$ 分别表示类型1、2、3。动态图被分为离散时间动态图(discrete time dynamic graph, DTDG)和连续时间动态图(continuous time dynamic graph, CTDG)两类,其具体机理如附录B图B2所示。本文共设置 T 个时间点, $D_{\text{DTDG}} = \{G_1, G_2, \dots, G_T\}$ 为静态图集合,其中, G_T 为第 T 个时间点的静态图,可以被视为在不同时间点或时间窗口的静态图的序列。CTDG使用一组事件来表示随时间连续变化的动态图结构,每个事件都与一个时间戳关联,通过给定节点对 (N_{re}, N_{rf}) 和时间 t 来表示图中边的创建、存在或消失的确切时间点,其中, $e, f \in [1, \lambda]$ 。通过在固定的滑动窗口内构建静态图的快照序列,与DTDG相比,CTDG能够更有效地捕捉负荷需求的周期性模式。

为表征和捕捉居民负荷之间的动态变化,本文依据DTDG在每个滑动窗口下的静态图快照,提出一种基于混合相关性矩阵的动态关联图结构。将 A^{mix} 代替 G_r 中的 B_r 并融入时间维度,动态滑动窗口与后续预测模型的训练时间步长一致,具体表示为:

$$G_{\text{dy},r}(t) = \{N_r, A^{\text{mix}}(t), G(t)\} \quad (9)$$

式中: $G_{\text{dy},r}(t)$ 为 t 时刻 f_{fix, N_r} 类型的居民动态图结构; $A^{\text{mix}}(t)$ 为 t 时刻居民混合相关性矩阵; $G(t)$ 为 t 时刻居民负荷节点及其相互关系的时间快照。

所提动态图结构中,通过调整权重剪枝阈值参数 T_{thre1} 和 T_{thre2} ,可以灵活地筛选居民负荷之间的关联强度。较低的 T_{thre1} 和 T_{thre2} 会在动态关联图中保留较多的连接,反映居民间复杂的交互关系。但是,提高 T_{thre1} 和 T_{thre2} 时,动态关联图中的连接会减少,仅保留具有强关联性的居民关系。

2.2 TGAT机制

考虑到GAT在处理动态图数据时,仍依据静态的自注意力机制,难以充分捕捉居民负荷之间的时间序列依赖关系,导致其在动态图上缺乏有效的时间维度建模能力。基于此,本文提出了TGAT机制,通过将时间信息融入自注意力框架中,增强模型对动态图数据的表示学习及预测能力。

多头TGAT机制见附录B图B3。假设 N_{re} 为第 e 个居民节点; $x_{N_{re}}$ 为节点的初始特征向量, $x_{N_{re}} \in \mathbf{R}^{d_0}$, 其中, d_0 为对应特征向量的维数。在 t 时刻,多头TGAT机制的输入为 t 时刻 $l-1$ 层中 N_{re} 与其邻居节点的集合 $\Omega(N_{re}, t)$ 的隐藏信息由

$\tilde{h}_{l-1,e}(\tau_{N_{re}})$ 和 $H = \{\tilde{h}_{l-1,1}(\tau_{N_{e1}}), \tilde{h}_{l-1,1}(\tau_{N_{e2}}), \dots, \tilde{h}_{l-1,\lambda}(\tau_{N_{e\lambda}})\}$ 表示,其中, $N_{re} \in \Omega(N_{re}, t)$, $\tau_{N_{re}}$ 为第 e 个居民节点的时间编码。通过整合 N_{re} 及 $\Omega(N_{re}, t)$ 的负荷特征与时间编码特征 $\Phi(\tau_{N_{re}})$, 得到 N_{re} 的时间编码特征矩阵 $Z_{N_{re}}(t)$ 。进一步,由多个注意力头并行更新 N_{re} 的特征,并通过前馈神经网络捕捉居民负荷随时间变化的复杂交互过程。最终,输出为 l 层中目标节点 N_{re} 在 t 时刻的隐藏信息 $\tilde{h}_{l,e}(t)$ 。

为了弥补 GAT 在动态图表征上的不足, TGAT 在自注意力机制的基础上提出了时间编码特征矩阵 $Z(t) \in \mathbb{R}^{\lambda \times (d_{N_{re}} + d_\tau)}$, 其中, d_τ 为时间编码的维度。 $Z(t)$ 的具体表示如下:

$$Z(t) = \begin{bmatrix} \tilde{h}_{l-1,e}(\tau_{N_{re}}) // \Phi(\tau_{N_{re}}) \\ \tilde{h}_{l-1,1}(\tau_{N_{e1}}) // \Phi(t - \tau_{N_{e1}}) \\ \vdots \\ \tilde{h}_{l-1,\lambda}(\tau_{N_{e\lambda}}) // \Phi(t - \tau_{N_{e\lambda}}) \end{bmatrix} \quad (10)$$

式中: $\Phi(t)$ 为 t 时刻的时间编码映射函数。

对 $Z(t)$ 进行线性变换, 将其转换至 3 个不同的线性投影下, 以获得 t 时刻“查询”、“键”和“值”对应的矩阵 $q(t)$ 、 $K(t)$ 和 $F(t)$, 设置 $W_{q(t)}$ 、 $W_{K(t)}$ 、 $W_{F(t)}$ 分别为 $q(t)$ 、 $K(t)$ 和 $F(t)$ 对应的权重矩阵, 具体计算公式如附录 A 式(A1)一式(A3)所示。

根据 $q(t)$ 和 $K(t)$ 计算注意力权重, 即

$$\alpha_{N_{re}, N_{id}}(t) = \frac{e^{q^T(t)K_{N_{re}, N_{id}}(t)}}{\sum_{e=1}^{\lambda} e^{q^T(t)K_{N_{re}, N_{id}}(t)}} \quad (11)$$

式中: $\alpha_{N_{re}, N_{id}}(t)$ 为 N_{re} 在 $\Omega(N_{re}, t)$ 下与 N_{id} 的归一化注意力权重系数, $N_{id} \in \Omega(N_{re}, t)$; $K_{N_{re}, N_{id}}(t)$ 为 t 时刻

$\alpha_{N_{re}, N_{id}}(t)$ 对应的“键”矩阵。

将 $\alpha_{N_{re}, N_{id}}(t)$ 与对应的“值”矩阵 $F_{N_{re}, N_{id}}(t)$ 的乘积的结果进行求和, 获得 $v_{N_{re}}$ 的隐藏邻域 $h_{N_{re}}(t)$, 即

$$h_{N_{re}}(t) = \text{Attention}(q(t), K(t), F(t)) = \sum_{e=1}^{\lambda} \alpha_{N_{re}, N_{id}}(t) F_{N_{re}, N_{id}}(t) \quad (12)$$

进一步, 通过前馈神经网络(feedforward neural network, FFN)整合 N_{re} 与 $h_{N_{re}}(t)$ 之间的相互作用。

$$\tilde{h}_{N_{re}, l}(t) = \text{FFN}(h_{N_{re}}(t) // x_{N_{re}}) = \text{ReLU}((h_{N_{re}}(t) // x_{N_{re}})W_{N_{re}, l} + b_{0, l})W_{N_{re}, l} + b_{1, l} \quad (13)$$

式中: $b_{1, l}$ 为 l 层前馈神经网络的偏执; $b_{0, l}$ 为经过 ReLU 非线性变换的 l 层前馈神经网络的偏执; $\tilde{h}_{N_{re}, l}(t) \in \mathbb{R}^{d_l}$ 为 N_{re} 在第 l 层输出的隐藏状态。

为进一步增强 TGAT 机制对动态图的表征能力, 将 TGAT 扩展到多个注意力头并行处理多尺度特征:

$$h_\mu(t) = \text{Attention}(q(t), K(t), F(t)) \quad \mu = 1, 2, \dots, \varsigma \quad (14)$$

$$\tilde{h}_{N_{re}, l}(t) = \text{FFN}(h_l(t) // h_{l+1}(t) // \dots // h_\varsigma(t) // x_{N_{re}}) \quad (15)$$

式中: $h_\mu(t)$ 为 t 时刻第 μ 个注意力头的隐藏特征; ς 为总注意力头个数。

2.3 居民短期负荷预测框架

所提出的预测框架旨在利用多个居民的历史负荷数据 $X \in \mathbb{R}^{\lambda \times d_0}$, 通过综合分析它们之间的关联性, 实现 T 个步长的居民短期负荷预测目标。所提预测框架如图 1 所示, 主要包括以下 5 个部分。




图1 DAGAT预测框架
Fig. 1 Forecasting framework of DAGAT

1) 居民负荷相关性分析

CCA 通过最大化典型变量对的相关系数来揭示两组居民负荷变量集合之间的线性相关性,而 DTW 通过最小化时间序列数据之间的整体差异来弥补前者对居民负荷之间的非线性相关性的捕捉。所得混合相关性矩阵可以为预测模型提供初步的关联信息。

2) 居民负荷关联强度筛选

基于混合相关性分析的结果,通过设置 2 个阈值参数 T_{thre1} 和 T_{thre2} 筛选出具有显著线性和非线性相关性的居民负荷关系,进而构建出反映居民负荷之间关联性变化的动态关联图,从而为模型提供更精确的关联信息。

3) 居民负荷动态关联图构建

利用权重剪枝阈值机制筛选出的强关联性居民关系,构建不同滑动窗口下的动态关联图结构 $G_{\text{dy},r}(t)$ 。通过提取每个滑动窗口下居民节点集合 V_r 以及动态居民间的关联性 $A^{\text{mix}}(t)$,动态关联图能

够适应虚拟电厂调控下居民负荷相关性的动态变化。

4) 居民负荷特征提取

将构建的动态关联图作为输入,通过引入时间编码特征矩阵 $Z(t)$,多头 TGAT 模型动态提取居民历史负荷数据中的时空关联特性。在每个注意力头中,整合时间信息和居民负荷特征,并通过前馈神经网络来捕捉居民负荷随时间变化的复杂交互过程。

5) 居民负荷预测网络训练与优化

通过利用 TGAT 捕捉负荷时空关联特性,并通过 Dropout 技术增强模型泛化能力,Dense 层进一步提取特征。选择 MSE 损失函数评估预测误差,以及使用 Adam 优化器来调整训练参数,最终在训练集上优化模型并在测试集上进行准确性验证。

3 算例分析与展望

3.1 算例设置

选取 2023 年 1 月 1 日至 7 月 30 日的居民负荷数据进行算例验证,具体拓扑结构如图 2 所示。




图 2 居民负荷数据结构
Fig. 2 Structure of residential load data

其中,配电网电压等级为 10 kV,共 104 个节点;燃气网为中压网,压力范围为 0.2~0.4 MPa,共

102 个节点;供热网为一级网,供水温度为 120 ℃,回水温度为 70 ℃,共 102 个节点。负荷节点根据用途

不同分为工业负荷、商业负荷、公共负荷和居民负荷等4种常规负荷类型。居民负荷数据采集间隔为1 h,每1 h内居民的平均用电峰值负荷为6.73 kW。

3.2 算例指标

为全面评估所提预测模型的性能,依据以下4个性能指标:均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)以及绝对系数(R-square, R^2),具体如下式所示:

$$\varphi_{\text{RMSE}} = \sqrt{\frac{\sum_{g=1}^G (y_g - \hat{y}_g)^2}{G}} \quad (16)$$

$$\varphi_{\text{MAE}} = \frac{\sum_{g=1}^G |y_g - \hat{y}_g|}{G} \quad (17)$$

$$\varphi_{\text{MAPE}} = \frac{\sum_{g=1}^G \left| \frac{y_g - \hat{y}_g}{y_g} \right|}{G} \times 100\% \quad (18)$$

$$\varphi_{R^2} = 1 - \frac{\sum_{g=1}^G (y_g - \hat{y}_g)^2}{\sum_{g=1}^G (y_g - \bar{y})^2} \quad (19)$$

式中: φ_{RMSE} 、 φ_{MAE} 、 φ_{MAPE} 、 φ_{R^2} 分别为RMSE、MAE、MAPE、 R^2 值; y_g 为第 g 次采样的真实值; $\hat{y}_g$ 为第 g 次采样的预测值; $\bar{y}$ 为平均值; G 为总采样数。

3.3 模型参数设置

为保证模型能够更好地学习和捕捉居民负荷之间的时空关联特性,提升居民短期负荷预测精度,附录A表A1给出本文所提的DAGAT模型参数设置。

3.4 居民负荷相关性分析

考虑到训练数据包含多个滑动窗口,选取第1、50和100个滑动窗口为代表,对20个居民负荷数据进行相关性分析,对应的相关性矩阵经过预处理后如附录C图C1左侧所示。综合分析3个不同的滑动窗口,所给出的CCA线性相关性矩阵元素在热力图中像素颜色大多为橙色和深红色,具有明显的线性相关性;而DTW非线性相关性矩阵元素在热力图中对应像素颜色分布较为平均,能够弥补CCA线性相关性难以捕捉并反映居民负荷之间的非线性相关性。

由于 $\tilde{A}_l$ 和 $\tilde{A}_n$ 可能包含一些弱相关性的居民负荷关系,掩盖了居民负荷间的真实依赖性,通过选择合适的阈值得到 $\mathbf{A}^{\text{mix}}$,进而构建动态关联图能够提

高居民负荷预测的准确性。进一步分析附录C表C1所给数据,大部分CCA均超过0.5,反映数据集中居民间存在明显的线性相关性,与热力图上半部分变化明显相对应。同时,DTW值呈现出长尾分布特征,大多数居民间的非线性相关性值在0.5至0.8的区间内。

因此,初步给定 T_{thre1} 和 T_{thre2} 分别为0.7和0.6,对附录C图C1左侧的居民负荷关系进行筛选,经过权重剪枝阈值机制后的最终相关性矩阵如附录C图C1所示。其中,如果对于弱关联性用户间的特征进行提取,需观察不同滑动窗口下相关性矩阵元素的分布。如附录C图C1所示,设定 $T_{\text{thre1}} = 0.6$, $T_{\text{thre2}} = 0.1$,对弱相关性用户间的特征进行提取。

为更加直观地表示不同滑动窗口下的居民负荷相关性,基于附录C图C1右侧所示动态窗口下的CCA和DTW权重剪枝阈值矩阵,构建对应的动态关联图,具体如附录C图C2所示。图中:左侧表示线性动态关联图,右侧表示非线性关联图;每个节点颜色深度对应居民负荷关联的个数,每条边的宽度对应居民负荷的相关性权重。

为此,利用RMSE和MAE作为评估指标,并以居民间的CCA和DTW值为基础绘制热力图来辅助确定最优阈值。通过附录C图C3中各像素点,观察到当 T_{thre1} 和 T_{thre2} 同时设定为0.7时,热力图中像素点变化最明显, $\varphi_{\text{RMSE}} = 0.204$, $\varphi_{\text{MAE}} = 0.180$ 时达到局部最小值。通过附录C图C2的视觉分析与附录C表C1的相关性分布结合,验证了本文所提出的DAGAT预测模型在可解释性方面的优势。

3.5 居民负荷预测分析

基于本文所提出的DAGAT预测方法,对随机选取的20个居民负荷归一化后进行短期负荷预测分析,其中,4个居民负荷在12个步长下的实际值与预测值的结果对比以及误差指标见附录C表C2、表C3。

在居民短期负荷预测的研究中,模型在负荷高峰与低谷期的预测性能至关重要。为直观分析所提出的DAGAT模型在居民短期负荷预测中的有效性,本文进一步通过对比120个步长下单个居民负荷预测结果,可视化评估DAGAT模型与BiLSTM^[19]、STGCN^[24]和GCN-LSTM^[25]之间的预测性能对比,具体如图3所示。在持续的负荷高峰期间(50 h附近),DAGAT与GCN-LSTM模型的预测效果展现了与实际负荷曲线高度的一致性,其性能明显优于BiLSTM和STGCN模型,突显了DAGAT和GCN-LSTM在捕捉负荷峰值及处理负

荷波动方面的优势。然而,在负荷低谷期,GCN-LSTM模型的预测精度明显降低,与实际负荷数据相比,其预测偏差的平均值达到31.2%,表明GCN-LSTM模型在低负荷情境下存在潜在的过拟合问题。相反,DAGAT与STGCN模型在负荷低谷期时表现出更高的鲁棒性,预测曲线更精确地反映了居民的实际用电负荷。




图3 预测模型对比
Fig. 3 Comparison of forecasting models

所提的DAGAT预测模型的准确性既呈现在模型对趋势的有效拟合上,又表现在预测性能指标的验证支持上。表1给出20个居民负荷预测的平均指标对比,量化评估本文所提的DAGAT预测模型具有最低的误差率和最高的可解释性,验证了DAGAT模型在所提性能指标上均优于其他模型。

表1 预测模型指标对比				
Table 1 Comparison of forecasting model indices				
预测方法	φ_{RMSE}	φ_{MAE}	$\varphi_{MAPE}/\%$	φ_{R^2}
BiLSTM	0.047	0.039	10.253	0.916
STGCN	0.031	0.026	7.208	0.945
GCN-LSTM	0.029	0.025	6.571	0.952
DAGAT	0.023	0.019	4.655	0.976

为进一步验证所提出的DAGAT预测方法在虚拟电厂集群负荷预测中的有效性,本文随机选取4个居民负荷样本,构建了虚拟电厂集群,并在12个不同的时间步长内对20个不同的集群进行了负荷预测的准确性验证,预测结果及其相应的评估指标见附录C表C4、表C5。由于每个虚拟电厂集群包含了多个居民负荷,DAGAT模型难以捕捉集群内部居民负荷之间复杂的相关性,所提出的DAGAT模型在4个集群中的MAPE值相较于单个居民负荷的MAPE值略低。但是, R^2 值依然表明DAGAT模型对预测数据具有显著的解释能力,验证了所提模型在虚拟电厂集群负荷预测中的有效性和可靠性。

本文所提的DAGAT居民短期负荷预测方法

中,动态关联图和注意力网络是两个关键的步骤,用于提高模型对居民负荷时空关联性的提取,2种方法及其作用的消融实验分析见附录C表C6。其中,实验2为移除注意力机制的预测结果,可视为类似本文所提TGAT架构的时间图卷积网络(temporal graph convolutional network, TGCN),仅能够提取动态关联图的局部时间关联性;实验3为移除动态关联图,可近似视为忽略负荷时间特性的GAT网络;实验4同时移除动态关联图与注意力网络(GCN),仅通过平均聚合邻近节点的空间特性进行居民短期负荷预测。消融实验预测结果表明,本文所提的动态关联图与注意力网络均能有效捕捉居民负荷时空关联特性,提升短期负荷预测准确性。

3.6 展望

在未来,虚拟电厂将能够利用居民短期负荷预测技术,实现对分布式能源资源的优化配置和实时调度。通过精确预测居民用电需求的波动,虚拟电厂可以及时调整其控制策略,鼓励和引导用户参与需求响应计划。这种需求侧管理不仅能够减轻电网的负担,还能为用户带来经济效益,从而实现更加清洁、高效、可靠的电力供应,为构建可持续的能源未来贡献力量。

4 结语

本文提出一种基于动态关联图注意力网络的居民短期负荷预测方法。该方法针对在大规模虚拟电厂调控背景下,旨在克服现有预测模型对居民间关联性研究不足导致的预测精度问题。本方法的关键贡献及结论概括如下:

- 1)通过结合典型相关分析和动态时间规整的混合相关性分析方法,综合描述居民负荷之间的线性和非线性关系,以量化居民负荷之间的关联性,为后续模型提供准确的居民负荷关联信息。
- 2)基于混合相关性分析结果,通过权重剪枝阈值机制的调整策略,筛选出具有强关联性的居民负荷关系,并进一步构建反映居民负荷之间关联性变化的动态关联图。
- 3)通过所提的时间图注意力机制,能够深入挖掘居民负荷数据中的时空关联特性,有助于模型更加精确地辨识决定负荷变化的关键因素,并提升了居民短期负荷预测的准确性。

为更有效地支持虚拟电厂的资源配置和决策制定,短期负荷预测仍有以下问题需要进一步研究:

- 1)考虑到虚拟电厂调控下,商业和工业用户的行为模式与居民用户可能存在显著不同,需要通过

多任务学习或迁移学习技术,增强模型的泛化能力;

2)针对不同用户类型的关联特性进行调整,需要研究自适应动态关联图结构,并随着用户类型的增加,需要探索更高效的算法和并行计算技术,以提高预测模型的计算效率和可扩展性。

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,陈启鑫,苏剑,等.新型电力系统规模化灵活资源虚拟电厂科学问题与研究框架[J].电力系统自动化,2022,46(18): 3-14.
KANG Chongqing, CHEN Qixin, SU Jian, et al. Scientific problems and research framework of virtual power plant with enormous flexible distributed energy resources in new power system [J]. Automation of Electric Power Systems, 2022, 46 (18): 3-14.
- [2] 陈启鑫,高洪超,冯成,等.虚拟电厂动态构建与可信量化:理论分析与关键技术[J].电力系统自动化,2022,46(18):26-36.
CHEN Qixin, GAO Hongchao, FENG Cheng, et al. Dynamic construction and trustworthy quantification of virtual power plant: theoretical analysis and key technologies [J]. Automation of Electric Power Systems, 2022, 46(18): 26-36.
- [3] 田滔,董凯元,饶贇,等.考虑冰灾天气时空分布影响的电力系统故障恢复策略研究[J].广东电力,2023,36(8):39-46.
TIAN Tao, DONG Kaiyuan, RAO Yun, et al. Research on power system fault recovery strategy considering the influence of temporal and spatial distribution of ice disaster weather [J]. Guangdong Electric Power, 2023, 36(8): 39-46.
- [4] 刘鑫蕊,常鹏,孙秋野.基于XGBoost和无迹卡尔曼滤波自适应混合预测的电网虚假数据注入攻击检测[J].中国电机工程学报,2021,41(16):5462-5475.
LIU Xinrui, CHANG Peng, SUN Qiuye. Grid false data injection attacks detection based on XGBoost and unscented Kalman filter adaptive hybrid prediction [J]. Proceedings of the CSEE, 2021, 41(16): 5462-5475.
- [5] 高洪超,陈启鑫,雷振,等.考虑事件数据的产消者负荷预测方法及极端误差抑制策略[J].电力系统自动化,2023,47(13): 47-55.
GAO Hongchao, CHEN Qixin, LEI Zhen, et al. Load forecasting method and extreme error suppression strategy for prosumers considering event data [J]. Automation of Electric Power Systems, 2023, 47(13): 47-55.
- [6] ZHANG J L, WEI Y M, LI D Z, et al. Short term electricity load forecasting using a hybrid model [J]. Energy, 2018, 158: 774-781.
- [7] SANTIAGO C B, GUO J Y, SIGMAN M S. Predictive and mechanistic multivariate linear regression models for reaction development [J]. Chemical Science, 2018, 9(9): 2398-2412.
- [8] 李亚龙,刘文颖,田浩,等.基于纵-横向误差匹配的联合降损基线计算方法[J].中国电机工程学报,2016,36(21):5831-5841.
LI Yalong, LIU Wenying, TIAN Hao, et al. Calculation method of combined loss reduction baseline based on matching vertical and horizontal errors [J]. Proceedings of the CSEE, 2016, 36(21): 5831-5841.
- [9] WU D, WANG B Y, PRECUP D, et al. Multiple kernel learning-based transfer regression for electric load forecasting [J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1183-1192.
- [10] HU X G, ZHAN Z K, MA D Z, et al. Spatiotemporal generative adversarial imputation networks: an approach to address missing data for wind turbines [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3530508.
- [11] WANG Y, XIA Q, KANG C Q. Secondary forecasting based on deviation analysis for short-term load forecasting [J]. IEEE Transactions on Power Systems, 2011, 26(2): 500-507.
- [12] KHOTANZAD A, AFKHAMI-ROHANI R, LU T L, et al. ANNSTLF—a neural-network-based electric load forecasting system [J]. IEEE Transactions on Neural Networks, 1997, 8 (4): 835-846.
- [13] 刘洋,刘洋,许立雄.适用于海量负荷数据分类的高性能反向传播神经网络算法[J].电力系统自动化,2018,42(21):96-103.
LIU Yang, LIU Yang, XU Lixiong. High-performance back propagation neural network algorithm for classification of mass load data [J]. Automation of Electric Power Systems, 2018, 42 (21): 96-103.
- [14] ASLAM S, HERODOTOU H, MOHSIN S M, et al. A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids [J]. Renewable and Sustainable Energy Reviews, 2021, 144: 110992.
- [15] SADAIEI H J, DE LIMA E SILVA P C, GUIMARÃES F G, et al. Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series [J]. Energy, 2019, 175: 365-377.
- [16] 杨国华,郑豪丰,张鸿皓,等.基于Holt-Winters指数平滑和时间卷积网络的短期负荷预测[J].电力系统自动化,2022,46 (6):73-82.
YANG Guohua, ZHENG Haofeng, ZHANG Honghao, et al. Short-term load forecasting based on Holt-Winters exponential smoothing and temporal convolutional network [J]. Automation of Electric Power Systems, 2022, 46(6): 73-82.
- [17] 李丹,孙光帆,缪书唯,等.基于多维时序信息融合的短期电力负荷预测方法[J].中国电机工程学报,2023,43(增刊1): 94-106.
LI Dan, SUN Guangfan, MIAO Shuwei, et al. Short-term power load forecasting method based on multidimensional time series information fusion [J]. Proceedings of the CSEE, 2023, 43(S1): 94-106.
- [18] KONG W C, DONG Z Y, JIA Y W, et al. Short-term residential load forecasting based on LSTM recurrent neural network [J]. IEEE Transactions on Smart Grid, 2019, 10 (1): 841-851.
- [19] 孙辉,杨帆,高正男,等.考虑特征重要性值波动的MBILSTM短期负荷预测[J].电力系统自动化,2022,46(8): 95-103.
SUN Hui, YANG Fan, GAO Zhengnan, et al. Short-term load forecasting based on mutual information and bi-directional long

- short-term memory network considering fluctuation in importance values of features[J]. Automation of Electric Power Systems, 2022, 46(8): 95-103.
- [20] 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.
- [21] ZHANG Z W, CUI P, ZHU W W. Deep learning on graphs: a survey [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(1): 249-270.
- [22] 胡家祥,曹迪,胡维昊,等.融入拓扑知识的图神经网络配电网抗差状态估计方法[J].电力系统自动化,2023,47(10):84-97.
HU Jiaxiang, CAO Di, HU Weihao, et al. Robust state estimation method for distribution network based on graph neural network incorporating topology knowledge [J]. Automation of Electric Power Systems, 2023, 47(10): 84-97.
- [23] 赵雅雪,王旭,蒋传文,等.基于最大信息系数相关性分析和改进多层级门控LSTM的短期电价预测方法[J].中国电机工程学报,2021,41(1):135-146.
ZHAO Yaxue, WANG Xu, JIANG Chuanwen, et al. A novel short-term electricity price forecasting method based on correlation analysis with the maximal information coefficient and modified multi-hierarchy gated LSTM [J]. Proceedings of the CSEE, 2021, 41(1): 135-146.
- [24] 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.
- [25] LIN W X, WU D, BOULET B. Spatial-temporal residential short-term load forecasting via graph neural networks[J]. IEEE Transactions on Smart Grid, 2021, 12(6): 5373-5384.
- [26] SATORRAS G, RANGAPURAM S, JANUSCHOWSKI T. Multi-variate time series forecasting with latent graph inference [EB/OL]. [2024-01-01]. <https://arxiv.org/abs/2203.03423>.
- [27] CINI A, ZAMBON D, ALIPPI C. Sparse graph learning for spatiotemporal time series [EB/OL]. [2024-01-01]. <https://arxiv.org/pdf/2205.13492v1>.
- 张峻凯(1998—),男,博士研究生,主要研究方向:能源系统负荷预测及分区并行恢复。E-mail:2490116@stu.neu.edu.cn
- 胡旭光(1992—),男,通信作者,博士,副教授,硕士生导师,主要研究方向:基于数据驱动的故障诊断、智慧能源系统的综合高效利用与优化调控。E-mail:huxuguang@mail.neu.edu.cn
- 刘要博(1997—),男,博士研究生,主要研究方向:能源系统建模、故障诊断与优化控制。E-mail:2310258@stu.neu.edu.cn

(编辑 冯慧敏)

Short-term Residential Load Forecasting Based on Dynamic Association Graph Attention Networks for Virtual Power Plant

ZHANG Junkai, HU Xuguang, LIU Yaobo, XU Qing, MA Dazhong, SUN Qiuyue

(College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Short-term residential load forecasting can provide real-time and flexible power demand information for virtual power plants, which is helpful for virtual power plants to realize efficient utilization of energy and optimize electricity market transactions. With the increasing prominence of correlation among residential loads, traditional forecasting methods, which primarily rely on time-series forecasting based on individual residential historical load, fail to satisfy the comprehensive demands for load interconnectivity in large-scale virtual power plant. Based on this, a short-term residential load forecasting method based on dynamic association graph attention networks for the virtual power plant is proposed. Firstly, a hybrid correlation analysis method is proposed to describe the linear and nonlinear relationship between residential loads, and a weight pruning threshold mechanism is further proposed to derive the hybrid correlation matrix of residential loads. Secondly, a dynamic association graph structure is constructed based on the hybrid correlation matrix, and a temporal graph attention mechanism is proposed to deeply learn the spatial-temporal association characteristics of residential loads, achieving the objective of short-term residential load forecasting. Finally, the effectiveness of the proposed method is verified by actual residential load data from a specific region.

This work is supported by National Natural Science Foundation of China (No. 62303103), Scientific Research Project of Liaoning Provincial Department of Education (No. JYTQN2023161) and Liaoning Provincial Natural Science Foundation of China (No. 2023-BSBA-140).

Key words: virtual power plant; short-term load forecasting; hybrid correlation; dynamic association graph; graph neural network; temporal graph attention mechanism

