

应用周期选择和变量交叉注意的光伏电力长时间序列预测^①



周 恒, 艾 青, 张婧汇

(湖北民族大学 智能科学与工程学院, 恩施 445000)

通信作者: 艾 青, E-mail: 14873028@qq.com

摘 要: 准确的综合能源负荷预测是区域综合能源系统前期规划和后期按需协调运行的关键前提. 近期基于 Transformer 的方法由于其优秀的全局建模能力, 在长序列预测方面显示了显著潜力. 然而, Transformer 中的排列不变自注意力机制导致了时间信息丢失, 且忽视了多能源负荷预测中不同变量之间的关键依赖关系. 为解决上述挑战, 本文提出了一种补丁与变量混合模型 (patch and variable mixing model, PVMM) 以实现准确多能源负荷预测. PVMM 采用补丁嵌入技术, 将输入的多能源负荷序列转换为 3D 向量, 从而保留补丁的时间和变量信息. 其次, 本文提出了基于深度可分离卷积的补丁混合模块 (patch mixing module, PMM) 建立时间依赖关系模型. 另外, 本文还提出了变量动态投影注意力模块 (variable dynamic projection attention module, VDP-AM) 将查询 (Query) 和数值 (Value) 变量映射到更高维空间, 并通过自注意力机制处理多变量之间的相互作用. 最后, 本方法在亚利桑那州立大学公开的在线系统数据集的预测精度和泛化能力均超越现有方法.

关键词: 综合能源系统; 多能源负荷预测; 深度可分离卷积; 注意力机制

引用格式: 周恒,艾青,张婧汇.应用周期选择和变量交叉注意的光伏电力长时间序列预测.计算机系统应用,2025,34(4):256-265. <http://www.c-s-a.org.cn/1003-3254/9826.html>

Photovoltaic Power Long-sequence Time Series Forecasting via Period Selection and Variable Cross-attention

ZHOU Heng, AI Qing, ZHANG Jing-Hui

(College of Intelligent Systems Science and Engineering, Hubei Minzu University, Enshi 445000, China)

Abstract: Accurate integrated energy load forecasting is a key prerequisite for the preliminary planning and subsequent on-demand coordinated operation of regional integrated energy systems. The recent Transformer-based method has shown significant potential in long sequence forecasting for its excellent global modeling capabilities. However, the permutationally invariant self-attention mechanism in Transformer leads to the loss of temporal information and ignores the key dependencies between different variables in multi-energy load forecasting. To address the above challenges, this study proposes a patch and variable mixing model (PVMM) to achieve accurate multi-energy load forecasting. PVMM uses patch embedding technology to convert the input multi-energy load sequence into a 3D vector, thereby retaining the temporal and variable information of the patch. Secondly, this study proposes a patch mixing module (PMM) based on deep separable convolution to establish a temporal dependency model. In addition, this study also proposes a variable dynamic projection attention module (VDP-AM) to map Query and Value variables to a higher dimension and handle the interaction between multiple variables through a self-attention mechanism. Finally, the prediction accuracy and generalization ability of this method on the online system dataset publicly available at Arizona State University surpass existing methods.

① 收稿时间: 2024-10-10; 修改时间: 2024-11-12; 采用时间: 2024-11-18; csa 在线出版时间: 2025-03-04

CNKI 网络首发时间: 2025-03-06

Key words: integrated energy system (IES); multi-energy load forecasting; depthwise separable convolution; attention mechanism

1 引言

随着化石能源储量的逐渐枯竭以及由此带来的环境污染加剧,如何有效提升各类能源的综合利用效率,已经成为构建现代能源体系过程中亟待解决的关键问题^[1].综合能源系统(integrated energy system, IES)通过整合电力、天然气、热力及制冷等多领域的能源系统,并结合多种能源供给、转化与存储设施,在能源的产生、传输与消耗各环节实现了多类型能源的深度融合. IES 不仅降低了特定区域内对单一能源形式的依赖度,还起到了缓解能源供应风险和增强能源安全的重要作用^[2]. 鉴于此,众多国家已明确指出,基于各种能源需求互补特性的 IES 建设至关重要. 因此,多能源负荷预测已成为学术界和工业界共同关注的研究热点.

近年来,越来越多的学者致力于综合能源系统(IES)中的多能源负荷预测研究,涵盖了电、冷、热等具有不同物理特性的能源,推动了该领域多样化发展. 目前,多能源负荷预测方法大致可分为3类:基于统计的方法^[3-5],基于机器学习的方法^[6-10],以及基于深度学习的方法^[11-16].

基于统计的方法. 文献[4]将多元线性回归模型(multiple linear regression, MLR)与季节性自回归移动平均模型(seasonal autoregressive integrated moving average, SARIMA)相结合,使用自适应方法进行时间序列和线性回归预测. 文献[5]基于矢量自回归(vector autoregression, VAR)模型,针对冷、电、气负荷预测,通过分析负荷与温度的相关性构建 VAR 模型,结合环境因素与负荷的耦合关系. 尽管这些基于统计的方法在处理简单关系时有效,但面对高度复杂的非线性关系和长期依赖性时,表现出一定的局限性.

基于机器学习的方法. 为应对统计方法在复杂问题上的不足,研究者们转向了机器学习方法. 基于机器学习的方法通过更灵活的模型结构,能够在一定程度上缓解非线性问题. 例如,文献[6]提出了一种基于长短期记忆网络(long short-term memory, LSTM)的多任务学习负荷预测方法,通过共享层来模拟多元负荷之间的耦合特性,提升预测精度. 文献[9]则提出了一个考虑

时间动态和耦合特性的预测方法,构建多能负荷耦合特征矩阵,利用梯度增强决策树(gradient boosting decision tree, GBDT)作为特征融合层. 虽然这些基于机器学习的方法速度较快,但其泛化能力有限,且在处理高维特征时表现不佳.

基于深度学习的方法. 随着数据量的增加和模型复杂性的提升,研究者们进一步探索了基于深度学习的方法,以应对更复杂的能源负荷预测挑战. 例如,文献[11]提出了一种基于 ResNet-LSTM 网络与注意力机制的多任务学习模型,用于拟合多能源负荷的空间耦合与时间耦合关系. 文献[12]结合图学习与图卷积网络(graph convolutional network, GCN),聚合多能源及其辅助特征的信息,并利用多尺度卷积模块提取不同时间步长的多维时间特征.

最近,Transformer 模型因其在序列建模和时序数据处理上的强大能力,广泛应用于各种预测任务中. 例如,文献[13]利用 Transformer 网络与多任务学习,提出了园区综合能源系统电-热短期负荷预测模型. 然而,随着研究的深入,Transformer 模型在捕捉时间依赖性方面的表现受到了质疑. Transformer 中的自注意力机制由于其对排列的不敏感性,往往无法有效保留时间顺序信息,导致时间特征的丢失. 此外,现有模型通常过于关注时间依赖性建模,而忽略了在多能源负荷预测中,不同变量之间的关键关联性.

为解决上述问题,本文提出了补丁与变量混合模型(PVMM),以实现精确的综合能源系统的多能源负荷预测. PVMM 首先通过补丁嵌入技术,将多能源负荷序列转换为三维向量数组,保留时间和变量信息. 然后,本文设计了基于深度可分离卷积的补丁混合模块(PMM),通过分组卷积捕捉补丁内部的周期模式,并通过逐点卷积增强补丁间的交互,从而提升全局特征的捕捉能力. 此外,提出了变量动态投影注意力模块(VDP-AM),将查询和数值变量映射到更高维空间,并通过自注意力机制处理多变量间的相互作用. 实验结果表明,方法在预测准确性和模型效率方面具有显著优势. 本文的主要贡献如下.

(1) 提出了补丁与变量混合模型(PVMM),将补丁

嵌入技术与变量混合相结合,有效保留了时间和变量信息,提高了模型对多能源负荷复杂关系的捕捉能力。

(2) 设计了补丁混合模块,实现了对补丁内部周期模式的有效捕捉,同时增强了补丁间的交互,从而显著提升了模型对全局特征的捕捉能力。

(3) 引入了变量动态投影注意力模块,利用高维空间的自注意力机制处理变量间的相互作用,提高了预测的准确性和模型效率。

2 综合能源负荷数据分析

在综合能源系统中,不同能源的特性及其相互组合会对负荷性能产生影响,进而影响整体系统的表现。在实际应用中,能源转换设备的效率受到非线性因素的显著影响。在综合能源系统的负荷预测中,气象因素是影响预测结果的关键变量。因此针对电力、制冷、供热等不同类型的负荷与气象特征之间的相关性进行定量分析,从而科学选择输入变量。

传统相关性分析方法,如皮尔逊相关系数 (Pearson correlation coefficient, PCC)、斯皮尔曼等级相关系数 (Spearman rank correlation coefficient, SRCC) 和肯德尔等级相关系数 (Kendall rank correlation coefficient, KRCC), 它们在处理非单调或非线性关系时往往表现不足。相比之下,最大信息系数 (maximum information coefficient, MIC) 通过在样本空间中创建网格,并在网格上计算互信息,量化两个变量间的关系强度。它不仅能够捕捉变量间的线性关系,还能衡量复杂非线性关系。因此,为更准确地分析多能源负荷的耦合关系及其与气象因素的相关性,本研究采用 MIC 算法,公式为:

$$I(G_{i,j}) = \sum_{x,y} p(x,y) \log_2 \frac{p(x,y)}{p(x)p(y)} \quad (1)$$

$$MIC(x,y) = \frac{\max I(G_{i,j})}{\log_2 \min(x,y)} \quad (2)$$

其中, $p(x,y)$ 表示变量 x 和 y 的联合概率,而 $p(x)$ 和 $p(y)$ 分别表示变量 x 和 y 的边际概率。

本研究利用了亚利桑那州立大学校园代谢系统 2019 年的多能源负荷数据集,该数据集涵盖了坦佩校区的电力、制冷和供热负荷的历史记录。同时,气象数据,包括温度、大气压、风速和风向,来源于美国国家气候数据中心。表 1 揭示了电力、制冷和供热负荷之间存在显著的耦合关系,尤其是这些负荷与温度之间有着较强的相关性。

表 1 多能源负荷与气象因素的最大信息系数

影响因素	电负荷	冷负荷	热负荷
露点	0.28	0.24	0.24
风速	0.04	0.05	0.03
降水量	0.36	0.31	0.34
风向	0.10	0.16	0.12
湿度	0.10	0.15	0.13
温度	0.57	0.70	0.57
大气压	0.17	0.22	0.25

具体而言,制冷负荷与温度之间的 MIC 值达到 0.70,这符合对高温下制冷需求增加的预期。此外,除温度和降水量外,其他气象因素如大气压、风速和风向与多能源负荷的 MIC 值均低于 0.3。因此,本研究决定将温度和降水量作为多能源负荷预测模型的主要输入变量。

3 方法

本研究提出 PVMM 模型用于预测未来 6 h、12 h、24 h 和 96 h 的多能源负荷。该模型的核心由两个相互协作的模块组成:补丁混合模块和具有动态投影的变量注意力模块。接下来,本研究将对 PVMM 模型的整体网络架构进行全面概述,并详细阐述这两个模块的具体工作原理。

3.1 PVMM 总体框架

在多能源负荷预测中,给定多能源负荷历史数据气象数据日历数据 $X_{1:L} \in R^{L \times M}$ 来预测未来的多能源负荷值 $\hat{Y}_{1:\hat{L}} \in R^{\hat{L} \times 3}$ 。其中, L 和 $\hat{L}$ 分别表示过去和未来的时间步数, M 是数据集中的变量数。预测过程如图 1 所示。首先,为有效缓解训练数据和测试数据之间的分布偏移效应^[17],将多变量时间序列从时间索引 $1-L$, 输入归一化层 (RevIN)。为处理时间序列数据,输入时间序列被分割成不重叠的补丁。假设每个补丁的长度为 P , 共生成 N 个补丁 (其中 N 是 L 除以 P)。接下来,每个补丁经过线性投影嵌入到一个向量中:

$$\hat{x}_{m,n} = \text{Linear}(x_{m,n}) \quad (3)$$

其中, $x_{m,n} \in R^P$ 表示第 m 个变量的第 n 个补丁, $\text{Linear}(x_{m,n})$ 表示为使用全连接层将 $x_{m,n}$ 投影到 $\hat{x}_{m,n} \in R^{d_{\text{model}}}$ 。

经上述线性投影,输入数据被转换为 $\hat{x} \in R^{M \times N \times d_{\text{model}}}$,紧接着经过混合补丁模块去捕获输入序列中的全局感受野和局部位置特征。然后,利用具有动态投影的注意力模块去捕获变量间的相关性。最后,利用全连接层,将其线性投影到目标预测输出 $\hat{Y}_{1:\hat{L}} \in R^{\hat{L} \times 3}$ 。




图1 补丁与变量混合模型(PVMM)框架图

3.2 补丁混合模块

补丁混合模块(PMM)采用深度可分离卷积作为核心模块。PMM设计将每个位置的(补丁内)操作与深度卷积分离开来,而跨位置的(补丁间)操作则通过逐点卷积实现。这种设计使得此模型能够捕捉输入序列中的全局感受野和局部位置特征。

深度卷积使用一种特定的分组卷积,其组数等于补丁 N 数量。为了扩展感受野,采用了更大的卷积核尺寸,通常与补丁长度 P 相等。在此过程中,输入特征图中的 N 个补丁中的每个补丁都与一个卷积核(大小为 P)进行单独卷积。此操作生成 N 个特征图,每个特征图对应于一个补丁。然后,这些特征图按顺序拼接,形成具有 N 个通道的输出特征图。深度卷积有效地使用相同空间位置的补丁共享的组卷积核,从而使模型能够捕捉时间补丁中的潜在周期性模式。

假设有 K 个PMM层,其中第 k 个PMM层的输入为 $x^{k-1} = PM(x^{k-2})$ 。由于深度卷积无法有效捕捉补丁间的特征相关性,因此在其后引入逐点卷积。通过这一层,实现了补丁之间的时间交互,从而提升模型对跨补丁关系的捕捉能力。输入序列 $x^{k-1} \in R^{M \times N \times d_{\text{model}}}$ 在第 k 层通过深度卷积和逐点卷积核的过程,其中深度卷积和逐点卷积核的输入和输出通道数为 N ,每个卷积操作之后,应用一个GELU函数和批归一化(BatchNorm)。

3.3 变量动态投影注意力模块

为深入研究变量间的相互作用,特别是解决多能源负荷之间的耦合关系及其与辅助变量的复杂关联,本文提出了一种变量动态投影注意力模块(VDP-AM)。如图1(d)所示,该模块主要由3部分组成:动态投影的变量注意力机制、带有残差连接的层归一化组件,以及前馈神经网络。具体而言,动态投影的变量注意力模

块首先利用动态投影技术将查询 (K) 和值 (V) 变量维度 N 映射至高维空间 $4 \times N$. 然后, 借助 *Softmax* 函数对这些高维特征的权重进行归一化处理, 以确保模型聚焦于最重要的变量. 接下来, 通过将变换后的查询 (K') 和值 (V') 向量与原始 K 和 V 向量相乘, 进一步增强模型对变量间依赖关系的建模能力. 最终, 基于自注意力机制, 模型能够根据不同变量的重要性分配权重, 从而更高效地处理变量及其交互关系.

假设有 K 个 $VDP-AM$ 层, 其中 PMM 模块的第 k 层输出是第 k 个 $VDP-AM$ 层的输入 $x^k = VDP-AM(x_p^k)$, 以单头注意力机制为例 $VDP-AM$ 模块表达式如下:

$$x^k = \text{Permute}(x_p^k) \quad (4)$$

$$Q, K, V = \text{split}(\text{linear}(x^k)) \quad (5)$$

$$K' = K \cdot (\text{Softmax}(\text{Conv}_{1d} K)) \quad (6)$$

$$V' = V \cdot (\text{Softmax}(\text{Conv}_{1d} V))^T \quad (7)$$

$$x_V^k = \text{BatchNorm} \left(\text{Softmax} \left(\frac{Q \cdot (K')^T}{\sqrt{d_{\text{model}}}} \right) \right) \cdot V' \quad (8)$$

$$x^{k+1} = \text{BatchNorm}(x_V^k + \text{FFN}(x_V^k)) \quad (9)$$

4 实验

4.1 数据集与评价指标

本研究利用了亚利桑那州立大学坦佩校区新陈代谢项目提供的数据集, 该数据集包含了电力负荷 (kW)、冷却需求 (ton/h) 及供暖需求 (mBtu/h). 为了统一计量单位, 将冷却需求和供暖需求单位标准化为千瓦, 其中转换比例为 $1 \text{ kW} = 3.4 \text{ mBtu/h} = 0.284 \text{ ton/h}$. 气象数据则来源于距离坦佩校区最近的气象站, 并可通过国家可再生能源实验室的官方网站获取. 数据集覆盖了从 2017 年 1 月 1 日–2019 年 12 月 31 日, 共 1095 天的每个小时的恶多能源负荷数据和相应的气象测量值.

在数据收集过程中, 诸如电力中断、天然气供应中断、测量设备故障、噪声干扰及数据传输错误等不可预见的事件, 可能导致异常值或缺失值的出现, 从而影响预测模型的准确性. 为解决这些问题, 采用了箱线图四分位数检测算法来识别时间序列中的异常值, 并结合一阶指数平滑算法进一步验证这些异常点. 一旦识别出异常值, 便将其标记为 NaN, 随后使用线性插值法对缺失数据进行填充, 以确保数据集的质量和完整性.

此外, 为了保证模型中每个变量的影响能得到公平对待, 尤其是在各特征值范围可能存在显著差异的情况下, 对数据进行了归一化处理. 具体而言, 使用式 (10)

对每个变量进行标准化处理:

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

其中, x 表示原始数据, $x_{\min}$ 表示特征的最小值, $x_{\max}$ 表示特征的最大值.

综合能源系统的能源需求虽然相对于整个电网来为了提高多能源负荷预测模型的准确性, 选择合适的输入变量显得尤为重要. 基于第 2 节的分析结果, 选定了降水量和温度作为气象因素中的辅助特征, 以反映天气条件对负荷需求的影响.

考虑到节假日和周末可能会显著改变能源消耗模式, 还引入了节假日 (以 1 表示假日, 0 表示非假日) 和周末 (以 1 表示周末, 0 表示非周末) 作为额外的辅助特征. 同时, 为了捕捉季节性和日常变化的影响, 还将月份、日期和小时纳入预测模型的输入变量之中. 为了评估和优化模型, 将多能源负荷预测数据集按照 7:1:2 的比例划分为训练集、验证集和测试集. 这种划分方式有助于确保模型不仅能在已知数据上表现良好, 还能在未知数据上保持较高的泛化能力.

为全面评估模型性能, 本文采用平均绝对误差 (MAE)、均方根误差 (RMSE) 以及决定系数 (R^2) 这 3 种评价指标. 单一指标往往存在各自局限性: RMSE 由于对异常值极为敏感, 可能导致评估结果的波动; MAE 虽然较为稳健, 但它忽略了不同大小预测误差间的区别; R^2 能够反映模型解释变量变异的程度, 然而其值会因模型特性及数据集的不同而有所变化. 因此, 结合使用 RMSE、MAE 和 R^2 可以多维度地评价模型表现, 进而提供一种更全面、精确且可靠的性能衡量方法. 实验中使用的硬件平台包括 Intel Core i7-13700KF CPU 与 NVIDIA GeForce RTX 4070Ti GPU, 软件平台则基于 Python 编程语言和 PyTorch 框架实现.

4.2 实验结果

为了全面评估 PVMM 模型在 6 h、12 h、24 h 以及 96 h 连续时间预测任务中的性能, 本文将 PVMM 与 9 种不同的基准方法进行了对比. 这些基准方法涵盖了基于 Transformer 架构的模型, 如 Transformer^[18]、Informer^[19]、Autoformer^[20]、FEDformer^[21]、Reformer^[22] 和 Pyraformer^[23], 同时也包括了基于 MLP 的模型, 如 LightTS^[24]、TiDE^[25] 和 TSMixer^[26].

图 2 和图 3 分别展示了在短时 6 h 和 96 h 电负荷的预测对比. 从中可以看出本研究提出的 PVMM 的预测轨迹更加贴合真实数据.




图2 6 h 电负荷预测对比图




图3 96 h 电负荷预测对比图

根据表 2 的数据分析显示, PVMM 在所有 4 个时间跨度的预测任务中均表现出显著的性能优势. 特别是与基于 Transformer 架构的模型 FEDformer 相比.

(1) 在电力负荷预测上, PVMM 的平均绝对误差 (MAE) 和均方根误差 (RMSE) 分别降低了 30.01% 和

28.1%, 并且确定系数 (R^2) 提高了 5.57%;

(2) 在冷却负荷预测上, MAE 和 RMSE 分别减少了 44.27% 和 43.33%, R^2 提高了 2.81%;

(3) 在加热负荷预测上, MAE 和 RMSE 分别下降了 46.08% 和 41.44%, R^2 提高了 4.66%.

表 2 不同方法电多能源负荷预测精度

方法	连续时间 (h)	电负荷			冷负荷			热负荷		
		MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE	R^2
FEDformer	6	0.210	0.269	0.895	0.166	0.217	0.958	0.175	0.251	0.907
	12	0.180	0.231	0.922	0.121	0.161	0.977	0.161	0.217	0.930
	24	0.223	0.284	0.882	0.173	0.223	0.955	0.186	0.263	0.896
	96	0.240	0.306	0.859	0.186	0.239	0.947	0.205	0.239	0.947
LightTS	6	0.224	0.288	0.879	0.121	0.164	0.976	0.142	0.206	0.938
	12	0.263	0.335	0.837	0.142	0.190	0.967	0.156	0.229	0.923
	24	0.232	0.295	0.873	0.125	0.168	0.975	0.136	0.197	0.942
	96	0.247	0.318	0.848	0.141	0.190	0.967	0.143	0.213	0.922
Pyraformer	6	0.201	0.258	0.903	0.093	0.127	0.985	0.162	0.200	0.941
	12	0.231	0.292	0.875	0.111	0.149	0.980	0.145	0.187	0.949
	24	0.234	0.297	0.871	0.111	0.147	0.980	0.154	0.196	0.942
	96	0.304	0.379	0.785	0.145	0.196	0.965	0.168	0.221	0.916
TiDE	6	0.215	0.280	0.886	0.117	0.161	0.977	0.129	0.190	0.947
	12	0.205	0.265	0.897	0.111	0.152	0.979	0.124	0.183	0.951
	24	0.205	0.267	0.895	0.112	0.154	0.979	0.123	0.182	0.950
	96	0.210	0.272	0.889	0.116	0.157	0.977	0.124	0.182	0.943
TSMixer	6	0.215	0.273	0.892	0.085	0.116	0.988	0.105	0.150	0.967
	12	0.258	0.323	0.848	0.098	0.132	0.984	0.125	0.169	0.958
	24	0.258	0.325	0.845	0.106	0.142	0.982	0.121	0.172	0.955
	96	0.334	0.423	0.732	0.131	0.173	0.972	0.149	0.218	0.918
PVMM	6	0.140	0.185	0.950	0.092	0.121	0.987	0.099	0.143	0.970
	12	0.136	0.181	0.952	0.083	0.112	0.989	0.097	0.140	0.971
	24	0.139	0.184	0.950	0.085	0.114	0.988	0.096	0.140	0.971
	96	0.149	0.196	0.942	0.090	0.119	0.987	0.098	0.142	0.965

另外, 当与基于 MLP 的模型 TiDE 进行比较时, PVMM 同样展示了其优越性.

(1) 在电力负荷预测中, PVMM 相比 TiDE, MAE 和 RMSE 分别下降了 28.62%, 27.68%, R^2 增加了 5.33%;

(2) 在冷却负荷预测中, MAE 和 RMSE 分别降低了 21.05% 和 23.72%, R^2 增加了 0.09%;

(3) 在加热负荷预测中, MAE 和 RMSE 分别减少了 21.60% 和 22.93%, R^2 增加了 1.79%.

4.3 多能源负荷耦合性分析

根据表 1 的最大信息系数结果, 电力负荷、冷却负荷和热负荷之间存在显著的相关性. 这种相关性帮助模型更全面地理解和模拟多能源系统中的负荷特性. 为了研究这些复杂的相互作用如何影响预测精度, 本文测试了组合预测和单独预测的区别.

具体来说, 通过两个不同的案例进行了研究.

案例 1. 忽略电力负荷、冷却负荷和热负荷之间的相互耦合, 分别对各类负荷进行独立预测. 在这种情况下, 模型使用气象信息和日期信息作为辅助变量.

案例 2. 充分考虑 3 种负荷类型的相互作用, 实施联合预测.

通过对两个案例的实证分析 (结果如表 3 所示), 可以发现, 案例 2 中的联合预测方法表现显著优于案例 1 的独立预测方法. 电力负荷的 MAE 和 RMSE 相较于案例 1 分别降低了 8.97% 和 4.84%, R^2 提升了 0.51%. 对于冷负荷, MAE 和 RMSE 分别降低了 7.71% 和 8.33%, R^2 提升了 0.71%. 热负荷的 MAE 和 RMSE 则分别降低了 4.26% 和 3.65%, R^2 提升了 0.52%. 这些结果表明, 联合多能源负荷预测方法不仅能够揭示不同能源负荷间的内在联系, 还显著提升了预测模型的泛化能力, 使其更准确地反映现实中的能源需求模式.

表3 组合负荷预测与单独预测结果的比较

案例	连续时间 (h)	电负荷			冷负荷			热负荷		
		MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE	R ²
案例1	6	0.198	0.256	0.904	0.131	0.174	0.973	0.144	0.189	0.948
	12	0.194	0.248	0.910	0.129	0.173	0.973	0.147	0.198	0.942
	24	0.197	0.253	0.907	0.124	0.173	0.973	0.137	0.199	0.940
	96	0.364	0.460	0.683	0.220	0.286	0.924	0.203	0.286	0.859
案例2	6	0.255	0.326	0.845	0.173	0.227	0.954	0.168	0.225	0.925
	12	0.237	0.302	0.867	0.152	0.203	0.963	0.172	0.231	0.921
	24	0.236	0.305	0.864	0.188	0.242	0.947	0.169	0.233	0.918
	96	0.317	0.400	0.759	0.204	0.266	0.935	0.242	0.308	0.836

4.4 辅助信息分析

根据表1提供的数据,电力负荷、冷却负荷与热负荷与气象条件之间显示出显著的相关性.为了评估气象数据和日历数据对于多能源负荷预测的价值,设计并实施了以下4个不同的实验案例.

案例3.仅使用电力负荷、冷却负荷和热负荷的历史数据进行预测,不包含任何外部辅助信息.

案例4.在案例3的基础上,引入气象数据作为预

测模型的附加特征.

案例5.在案例4的基础上,进一步增加日历数据,以便模型能够考虑到日期相关的因素.

案例6.直接在案例3的基础上,同时引入气象数据和日历数据作为预测模型的额外特征.

表4汇总了4个案例在预测长度为96 h时的实验结果,展示了随着辅助信息加入,预测模型的表现得到显著提升,尤其是在案例6中.

表4 具有不同辅助信息的性能比较

案例	电负荷			冷负荷			热负荷		
	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE	R ²
案例3	0.161	0.214	0.936	0.098	0.121	0.982	0.116	0.154	0.961
案例4	0.154	0.201	0.940	0.086	0.113	0.988	0.104	0.146	0.964
案例5	0.157	0.203	0.940	0.088	0.116	0.986	0.108	0.148	0.963
案例6	0.148	0.197	0.942	0.077	0.108	0.990	0.095	0.140	0.966

具体而言,与案例3相比,案例4的MAE和RMSE分别减少了4.35%和6.07%,R²提升了0.43%;而与案例3相比,案例5的MAE和RMSE分别减少了2.48%和5.14%,R²同样提升了0.43%.值得注意的是,案例5相比案例4有更高预测精度,这表明日历数据对于负荷预测的重要性可能超过了气象数据.这一发现进一步证明了在PVMM方法中,探索负荷特性与气象数据之间的线性和非线性关系的必要性.通过综合使用气象数据和日历数据,模型能够更深入理解多能源系统中的负荷变化规律,显著提升预测精度.这表明合理利用多种辅助信息能有效提高负荷预测整体表现,尤其在多能源系统的复杂情境下,联合考虑多个外部变量对模型性能至关重要.

4.5 消融实验

为评估深度可分离卷积的有效性,在补丁混合模块中分别将其替换为自注意力机制(-SAA)和标准卷积层(-Conv),并保持相同的配置,每个替代方案均使

用一层.预测长度为96 h时的实验结果如表5所示,结果显示深度可分离卷积在大多数情况下优于标准卷积.虽然深度可分离卷积的性能接近自注意力机制,但后者在计算效率和参数量上有较大开销.

表5 各模块的分解实验

方法	电负荷			冷负荷		
	MAE	RMSE	R ²	MAE	RMSE	R ²
-SAA	0.149	0.197	0.941	0.077	0.110	0.989
-Conv	0.152	0.201	0.941	0.079	0.108	0.991
-WO-VDP	0.176	0.222	0.927	0.115	0.159	0.975
-SA	0.149	0.197	0.940	0.078	0.108	0.989
PVMM	0.148	0.197	0.942	0.077	0.108	0.990

为了深入探讨VDP-AM在PVMM中的重要性,设计了两组实验.首先,构建了一个名为-WO-VDP的变体模型,通过移除PVMM中的VDP-AM来观察模型性能的变化.其次,为了比较VDP-AM与传统自注意力模块的有效性,将PVMM中的VDP-AM替换为传统自注意力模块,形成一个新模型,命名为-SA.

通过比较PVMM、-WO-VDP和-SA的性能,可以

更加精准地评估 VDP-AM 对模型效果的影响. 实验结果如表 5 所示, PVMM 在所有评估指标上均优于-WO-VDP 和-SA, 这充分证明了 VDP-AM 在提升模型性能方面的重要作用. 这进一步验证了 VDP-AM 相较于传统自注意力模块的优越性, 也解释了本文中的模型在多个基准测试中展现出更优的表现.

5 结论与展望

本文提出了一种补丁与变量混合模型 (PVMM), 旨在解决多能源负荷预测中的复杂时序和多变量依赖问题. PVMM 的核心创新在于引入补丁嵌入技术, 将多能源负荷序列转化为三维向量数组, 从而全面保留时间和变量信息. 同时, 本文设计了两个关键模块: 补丁混合模块 (PMM) 和变量动态投影注意力模块 (VDP-AM). 补丁混合模块通过深度可分离卷积来捕捉补丁内部的周期性模式, 并通过逐点卷积增强补丁间的特征交互, 极大提高了模型对全局特征的感知能力. 而变量动态投影注意力模块则通过将变量映射至高维空间, 并利用自注意力机制处理多变量间的复杂关系, 有效提升了模型的预测精度和泛化能力. 实验结果表明, PVMM 在电力、冷却和供热负荷预测中表现卓越, 尤其在长期预测中大幅度优于现有 Transformer 和 MLP 等模型.

参考文献

- 1 朱刘柱, 王绪利, 马静, 等. 基于小波包分解与循环神经网络的综合能源系统短期负荷预测. 电力建设, 2020, 41(12): 131–138.
- 2 曾鸣, 杨雍琦, 李源非, 等. 能源互联网背景下新能源电力系统运营模式及关键技术初探. 中国电机工程学报, 2016, 36(3): 681–691. [doi: 10.13334/j.0258-8013.psee.2016.03.011]
- 3 Lindberg KB, Bakker SJ, Sartori I. Modelling electric and heat load profiles of non-residential buildings for use in long-term aggregate load forecasts. Utilities Policy, 2019, 58: 63–88. [doi: 10.1016/j.jup.2019.03.004]
- 4 Vaghefi A, Jafari MA, Bisse E, *et al.* Modeling and forecasting of cooling and electricity load demand. Applied Energy, 2014, 136: 186–196. [doi: 10.1016/j.apenergy.2014.09.004]
- 5 Li YJ, Yuan XL, Xu JY, *et al.* Medium-term forecasting of cold, electric and gas load in multi-energy system based on VAR model. Proceedings of the 13th IEEE Conference on Industrial Electronics and Applications. Wuhan: IEEE, 2018. 1676–1680.
- 6 Fang X, Zhang W, Guo YH, *et al.* A novel reinforced deep RNN-LSTM algorithm: Energy management forecasting case study. IEEE Transactions on Industrial Informatics, 2022, 18(8): 5698–5704. [doi: 10.1109/TII.2021.3136562]
- 7 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. 电力系统自动化, 2021, 45(5): 63–70.
- 8 马建鹏, 龚文杰, 张智晟. 基于 Copula 理论与 KPCA-GRNN 结合的区域综合能源系统多元负荷短期预测模型. 电工电能新技术, 2020, 39(3): 24–31. [doi: 10.12067/ATEEE.1903001]
- 9 Chen BY, Wang YF. Short-term electric load forecasting of integrated energy system considering nonlinear synergy between different loads. IEEE Access, 2021, 9: 43562–43573. [doi: 10.1109/ACCESS.2021.3066915]
- 10 Wang SM, Wang SX, Chen HW, *et al.* Multi-energy load forecasting for regional integrated energy systems considering temporal dynamic and coupling characteristics. Energy, 2020, 195: 116964. [doi: 10.1016/j.energy.2020.116964]
- 11 王琛, 王颖, 郑涛, 等. 基于 ResNet-LSTM 网络和注意力机制的综合能源系统多元负荷预测. 电工技术学报, 2022, 37(7): 1789–1799.
- 12 Zhuang W, Fan JL, Xia M, *et al.* A multi-scale spatial-temporal graph neural network-based method of multi-energy load forecasting in integrated energy system. IEEE Transactions on Smart Grid, 2024, 15(3): 2652–2666. [doi: 10.1109/TSG.2023.3315750]
- 13 黄旭锐, 于丰源, 杨波, 等. 基于 Transformer 网络和多任务学习的园区综合能源系统电-热短期负荷预测方法. 南方电网技术, 2023, 17(1): 152–160.
- 14 Peng DG, Liu Y, Wang DH, *et al.* Multi-energy load forecasting for integrated energy system based on sequence decomposition fusion and factors correlation analysis. Energy, 2024, 308: 132796. [doi: 10.1016/j.energy.2024.132796]
- 15 Fan JL, Zhuang W, Xia M, *et al.* Optimizing attention in a Transformer for multihorizon, multienergy load forecasting in integrated energy systems. IEEE Transactions on Industrial Informatics, 2024, 20(80): 10238–10248.
- 16 丁浩, 周成杰, 车超, 等. 基于渐进式分解架构的风电时间序列预测. 计算机系统应用, 2024, 33(7): 112–120. [doi: 10.15888/j.cnki.csa.009561]
- 17 Kim T, Kim J, Tae Y, *et al.* Reversible instance

- normalization for accurate time-series forecasting against distribution shift. Proceedings of the 10th International Conference on Learning Representations. OpenReview.net, 2022.
- 18 Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 6000–6010.
- 19 Zhou HY, Zhang SH, Peng JQ, *et al.* Informer: Beyond efficient Transformer for long sequence time-series forecasting. Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI Press, 2021. 11106–11115.
- 20 Wu HX, Xu JH, Wang JM, *et al.* Autoformer: Decomposition Transformers with auto-correlation for long-term series forecasting. Proceedings of the 35th International Conference on Neural Information Processing Systems. Curran Associates Inc., 2021. 1717.
- 21 Zhou T, Ma ZQ, Wen QS, *et al.* FEDformer: Frequency enhanced decomposed Transformer for long-term series forecasting. Proceedings of the 39th International Conference on Machine Learning. Baltimore: PMLR, 2022. 27268–27286.
- 22 Kitaev N, Kaiser Ł, Levskaya A. Reformer: The efficient Transformer. Proceedings of the 8th International Conference on Learning Representations. OpenReview.net, 2020.
- 23 Liu SZ, Yu H, Liao C, *et al.* Pyraformer: Low-complexity pyramidal attention for long-range time series modeling and forecasting. Proceedings of the 10th International Conference on Learning Representations. OpenReview.net, 2022.
- 24 Campos D, Zhang M, Yang B, *et al.* LightTS: Lightweight time series classification with adaptive ensemble distillation. Proceedings of the ACM on Management of Data, 2023, 1(2): 171.
- 25 Das A, Kong WH, Leach A, *et al.* Long-term forecasting with TiDE: Time-series dense encoder. arXiv:2304.08424. 2023.
- 26 Ekambaram V, Jati A, Nguyen N, *et al.* TSMixer: Lightweight MLP-mixer model for multivariate time series forecasting. Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach: ACM, 2023. 459–469.
- (校对责编: 王欣欣)