

基于负荷预测的峰谷分时电价时段划分优化方法

孟亦超^{1,2}, 张跃军^{1,2,*}

1. 湖南大学 工商管理学院, 长沙 410082;
2. 湖南大学 资源与环境管理研究中心, 长沙 410082



摘要： 为提升峰谷分时电价政策的科学性与前瞻性，本文提出了一种基于负荷预测的时段划分优化方法，构建了融合负荷预测、曲线聚类与时段分类的分时优化框架，并以某省实际负荷数据开展实证分析。结果表明，该方法能够更精准地预测未来电力供需特征，有效区分不同季节的用电差异，从而增强时段划分在不同月份之间的适应性。优化后的时段方案负荷一致性更高，更贴近实际负荷曲线拐点，显著改善了原方案存在的过度切分与特征不匹配问题。本文为电力市场环境下定时电价政策的动态优化提供了可行技术路径。

关键词： 峰谷分时电价；时段划分；负荷预测；图注意力网络

中图分类号： X322; F275 **文献标志码：** A **文章编号：** 2097-4981(2026)01-0174-14
DOI: 10.3724/j.issn.2097-4981.JECC-2025-0072

0 引言

峰谷分时电价机制是中国电价体系的关键机制之一。时段划分规则不仅直接影响该政策的实施效果，更对电力中长期市场分时段交易具有重要指导作用^[1-2]。在多年发展过程中，中国分时电价机制已从最初的仅区分峰、谷两类时段^[3]，逐步拓展为涵盖尖峰时段、季节性分时和丰枯分时等更加细致的模式^[4]。随着可再生能源装机比例的持续提升，电动汽车、电采暖、智能家居等新型用电负荷的广泛普及，以及政策对低碳环保目标的强调，中国电力系统的供应结构与消费模式均已发生显著变化^[5-6]。在此背景下，电力供需的时间特性日益凸显，峰谷分时电价机制亟需相应调整以适应新的供需关系^[7]。为此，2021年7月，国家发展和改革委员会发布《关于进一步完善分时电价机制的通知》（以下简称《通知》），

明确提出要完善峰谷电价机制、设立尖峰电价机制、健全季节性电价机制，并加强与电力市场建设的衔接^[8]。自2023年起，为适应可再生能源大规模接入带来的新型电力供需格局，国家电网及南方电网区域内各省份（指省级行政区）相继调整了分时电价政策时段划分原则（表1），普遍在午间时段设置了不低于2 h的低谷时段^[9-10]。然而，各省份峰谷时段划分的具体方法仍缺乏科学依据和详尽披露。因此，亟需深入分析各省份分时电价政策的调整特点与现存问题，并针对性地构建一种兼具科学性与前瞻性的时段划分方法，为各省份分时电价政策的优化提供理论支持与方法参考。

由表1可知，各省份分时电价政策的调整具有4个方面的特点。1）分时电价政策的最新调整时间集中在2022年及2024年。第1次调整高峰集中在2022年，各省份为紧跟和落实《通知》要求而积极调整，

收稿日期： 2025-10-12; **接受日期：** 2025-11-26

基金项目： 国家社会科学基金重点项目（22AZD128）；国家自然科学基金专项项目（72243003）；教育部哲学社会科学研究重大课题攻关项目（23JZD021）

作者简介： 孟亦超（1992—），男，博士，助理研究员，研究方向为电力市场理论与实务。E-mail: myc199297@163.com

通讯作者： 张跃军（1980—），男，博士，教授，研究方向为资源与环境管理。E-mail: zyjmis@126.com

引用格式： 孟亦超, 张跃军. 基于负荷预测的峰谷分时电价时段划分优化方法[J]. 能源与气候变化, 2026, 2(1): 174–187.

MENG Y C, ZHANG Y J. Optimization Method for Time-of-Use Pricing Based on Load Forecasting[J]. Journal of Energy and Climate Change, 2026, 2(1): 174–187.

表 1 各省份峰谷分时电价政策调整周期及调整内容
Table 1 Adjustment cycles and content of time-of-use electricity pricing policies in various provinces

地区	电网区域	最新调整时间	调整事项	上次调整时间	调整周期
华东地区	山东	2024 年 1 月	扩大执行范围、设定峰谷上限	2023 年 1 月	1 年
	江苏	2025 年 6 月	扩大执行范围、增设午间谷段、拉大峰谷价差	2024 年 7 月	11 个月
	安徽	2025 年 7 月	优化峰谷时段、试行节假日深谷电价	2024 年 4 月	1 年 3 个月
	浙江	2024 年 3 月	统一峰谷时段、试行深谷电价、 调整峰谷浮动比例	2021 年 10 月	2 年 5 个月
	江西	2025 年 7 月	按季节精细化调整峰谷时段、 扩大峰谷价差、恢复执行	2024 年 5 月	1 年 2 个月
	福建	2024 年 1 月	优化时段划分和峰谷浮动幅度	2015 年 4 月	8 年 9 个月
	上海	2024 年 9 月	扩大工业用电深谷实施时间以及电价浮动比例	2023 年 1 月	1 年 8 个月
华南地区	广东	2021 年 10 月	优化峰平谷比价、拉大峰谷价差	2012 年 7 月	9 年 3 个月
	广西	2023 年 9 月	暂停尖峰电价、调整峰谷时段	2023 年 3 月	6 个月
	海南	2024 年 10 月	差异化调整不同用户峰谷时段，尤其电动汽车	2022 年 2 月	2 年 8 个月
华北地区	北京	2023 年 9 月	优化时段划分和峰谷价比	2016 年 1 月	7 年 8 个月
	天津	2025 年 10 月	调整时段划分、浮动比例、 鼓励电动汽车充电桩执行峰谷电价	2021 年 10 月	4 年
	河北南网	2022 年 12 月	优化时段划分以及浮动比例	2021 年 12 月	1 年
	冀北	2024 年 1 月	优化时段划分、拉大浮动比例	2021 年 12 月	2 年 1 个月
	山西	2022 年 1 月	调整峰谷分时电价浮动比例	2016 年 1 月	6 年
	内蒙古	2024 年 2 月	调整峰谷时段、拉大峰谷价差	2021 年 11 月	2 年 3 个月
华中地区	河南	2024 年 6 月	优化峰谷时段设置、调整峰谷浮动比例	2023 年 1 月	1 年 5 个月
	湖北	2024 年 5 月	优化时段划分和浮动比例	2022 年 12 月	1 年 5 个月
	湖南	2025 年 8 月	优化峰谷时段和浮动比例、 调整尖峰电价月份、扩大执行范围	2021 年 12 月	3 年 8 个月
西南地区	四川	2025 年 5 月	分季节细化峰平谷时段、 建立灵活尖峰和动态调整机制	2023 年 6 月	1 年 11 个月
	贵州	2023 年 8 月	扩大执行范围、优化峰谷时段划分、 拉大峰谷电价差	2021 年 10 月	1 年 10 个月
	重庆	2023 年 6 月	建立居民分时电价机制	2022 年 7 月	11 个月
	云南	2025 年 1 月	调整峰谷时段划分、暂缓执行尖峰电价	2024 年 1 月	1 年
	西藏	2023 年 12 月	执行大工业用电分季节峰谷电价	2020 年 12 月	3 年
西北地区	陕西	2025 年 8 月	取消用户选择执行平均电价的权利、 优化峰谷和尖峰电价时段	2022 年 1 月	3 年 7 个月
	甘肃	2024 年 8 月	优化时段划分和价差比例	2022 年 1 月	2 年 7 个月
	青海	2024 年 5 月	明确尖峰电价和峰谷浮动比例	2023 年 11 月	6 个月
	宁夏	2023 年 1 月	扩大峰谷时段应用范围、峰谷价差拉大	2021 年 10 月	1 年 3 个月
	新疆	2023 年 10 月	优化峰谷时段划分、拉大浮动比例、 设置深谷和尖峰电价机制	2022 年 1 月	1 年 9 个月
东北地区	辽宁	2023 年 9 月	扩大执行范围、完善峰谷时段划分和浮动比例	2016 年 1 月	7 年 8 个月
	吉林	2025 年 2 月	调整峰谷时段划和浮动比例	2024 年 10 月	4 个月
	黑龙江	2025 年 1 月	调整时段划分和浮动范围、暂停执行尖峰电价	2022 年 4 月	2 年 9 个月

注：根据国家和各省份公开资料整理得到。

体现了自上而下的政策推动特征。第二次调整集中在2024年,这与近年来各省份电力供需紧张、新能源快速发展等背景相吻合,调整具有明显的问题导向性。2)调整方式主要为扩大执行范围、优化时段划分及拉大价差比例等。其中,时段划分调整侧重于新增午间低谷时段。3)调整目标主要围绕落实国家政策、发挥电价信号、适应负荷特性及推动新能源发展等方面。各省份主要依据历史负荷曲线特性与实时供需形势变化进行调整,但对具体调整方法、关键参数的确定依据等均未详尽披露。4)分时电价政策的调整频率差别较大,主要省份的调整周期约为1年,但部分省份的政策调整存在明显滞后。

目前,全国分时电价政策逐步走向成熟,精细化与差异化的时段划分及浮动比例的拉大,较好地发挥了分时电价机制的价格引导作用,进一步促进了新能源的消纳。但通过分析全国分时电价政策调整情况,本文发现其存在4方面的问题。1)时段划分缺乏科学性与前瞻性。各省份目前的划分依据主要依赖历史负荷数据或当前电力需求状况,未能充分考虑未来电力负荷的变化趋势,导致分时电价机制难以灵活适应系统运行特征的变化。易造成时段划分与实际负荷曲线失配,削弱价格信号对用户用电行为的引导作用,影响削峰填谷的实际效果。2)调整缺乏科学依据。各省份最新的调整文件虽明确了关键参数(如时段划分、峰谷电价浮动比例等)的调整结果,却普遍未详细阐述这些参数设定的具体测算过程、模型方法及量化分析过程。3)调整周期较长且时效性不足。各省份分时电价的调整周期有所差异,多数省份的调整周期为1年以上。而在新型电力系统及新能源快速发展的背景下,较长的调整间隔使得分时电价信号无法及时有效地反映最新的电力供需关系,价格的引导作用被大幅削弱。4)缺乏定期化的动态评估机制。现有分时电价机制的有效性缺少系统化、周期性的评估反馈和动态调整机制,导致政策实施效果难以被科学量化与及时优化。

峰谷分时电价的制定,本质上是运用价格信号优化资源配置的过程。国内外学者围绕这一核心议题从不同维度展开了深入探讨^[1]。1)需求侧响应视角。此类研究重点刻画了电价与负荷变化的互动关

系,核心方法为利用价格弹性构建优化模型,通过基于弹性考虑多种评价指标优化价格浮动比例或精细化设计价差引导用户用电行为,实现削峰填谷的调控目标^[12-15]。2)系统成本与经济均衡视角。此类研究在边际供电成本、拥塞与备用成本等约束下,结合两部制定价与拉姆齐定价来实现效率与公平的权衡^[16-17],或以系统负荷率及风险成本为依据来优化分时电价^[18-20]。3)协同优化视角。此类研究将电价制定与发电调度、储能应用等环节进行联合建模,以寻求系统全局最优^[21-22]。尽管上述方法在各自维度上日趋完善,但其有效性大多建立在历史数据的校准基础之上。而政策实施面向的是未来的电力供需格局。因此,更合理的峰谷时段应以前瞻性的供需预测为基础,进行时段划分与定价。

峰谷时段划分的本质是依据电力系统的时变供需与负荷结构将日内用电划分为差异化区间,为分时电价提供可执行的调整边界,从而支撑资源的动态优化配置,现有研究可被概括为3类。1)聚类与模糊聚类,将小时在负荷、气象与清洁能源出力等特征空间中分群,再以隶属度或用户响应类型校正,直观且数据需求适中,但对划分精度及异常情形的刻画有限^[23-24]。2)统计阈值与变化点检测,以分位数、熵或密度阈值来识别拐点并形成连续区间,可解释性强、实现简洁,但多为静态判别,难以应对不确定性与样本外波动^[4,25]。3)与定价联动的优化,将分段数、边界和最小时长作为决策变量,在峰谷差、成本或福利目标下整体求解,兼顾可实施性,但对预测质量依赖较高、计算复杂度较大^[26-27]。现有文献多采用聚类与模糊聚类或分位数与变化点等统计判别方法进行时段划分,方法较为简单,但对未来变化的分析相对有限^[28]。

为此,本文提出了一种基于未来负荷预测与时序聚类的动态优化方法。首先,基于历史负荷曲线引入图注意力网络(Graph Attention Network, GAT)-Transformer融合模型,充分挖掘历史负荷数据中的时空依赖关系,实现对未来负荷趋势的精准预测;然后,利用K-Shape聚类算法对预测负荷曲线进行形态特征聚类,自动识别出各月典型负荷模式,并在此基础上客观划分高峰月、非高峰月及峰谷时段;最后,在同类型月份中以负荷水平为基础识别

各时间点所属峰平谷时段,实现基于负荷预测的峰谷分时电价政策时段划分优化。

本文的边际贡献主要包括两方面。1) 本文创新性地提出了基于负荷预测的峰谷时段划分方法,突破了传统划分方式中仅依赖历史负荷数据的局限。该方法使分时电价政策不再滞后于实际用电需求变化,能够前瞻性地契合用户未来负荷趋势并滚动调整,增强了时段划分的科学性与精确度,为分时电价政策的设计提供了更加可靠的理论与实践依据。2) 本文在预测过程中构建了GAT-Transformer融合模型。该模型结合了图神经网络与Transformer模型的各自优势,通过GAT捕捉特征间的复杂空间关联,精准挖掘负荷曲线的时间编码特征,同时可以深度提取时间维度上的长短期序列规律。与传统负荷预测方法相比,GAT-Transformer融合模型通过GAT显式建模不同特征间的空间关联,同时利用Transformer捕获负荷数据中的长期时间依赖,实现了对时空特征的协同挖掘。这一设计使模型能够更加全面、精准地反映电力负荷的时空演化规律,为后续时段划分提供了更加可靠的预测基础,从而在方法论上提升了峰谷分时电价优化的前瞻性与精确度。

1 研究方法

1.1 模型框架

本文以历史负荷数据为基础,首次构建了一套融合预测、聚类与时段划分的系统性优化流程。在预测阶段,本文采用GAT-Transformer混合深度学习模型,充分挖掘负荷数据的时空特征,实现对未来一年相应月份负荷曲线的精准预测;在聚类阶段,本文应用K-Shape方法对预测所得的负荷曲线进行聚类,提取各月典型日负荷模式,客观识别不同月份所属的高峰与非高峰类别;在分时阶段,本文依据聚类获得的典型曲线形态,自动、无监督地划分各月份的峰谷时段,摒弃传统依赖主观经验的做法。最后本文通过对比预测曲线和实际曲线、优化后的分时方案和原始时段划分方案,验证所提方法在提升划分准确性方面的有效性与优越性。研究思路如图1所示。

首先对原始负荷数据进行预处理,包含两部




图1 时段划分优化路径

Fig.1 Optimized path for time period division

分: 1) 提取时间编码特征。通过三角函数变换将小时、星期、月份等周期性时间信息转化为6个连续特征,有效保留时间周期性规律。2) 进行变分模态分解(Variational Mode Decomposition, VMD)处理。针对原始负荷功率序列的非线性、非平稳特性构建变分优化模型,将负荷功率分解为6个相互独立的模态分量(Intrinsic Mode Function, IMF)。每个分量对应不同频率尺度的负荷波动特征(如高频分量反映短期负荷波动,低频分量反映长期负荷趋势),通过分解降低原始序列复杂度,为后续特征学习提供更精准的输入。两部分操作共同形成12维特征矩阵。其次,将历史负荷数据按月份划分为12个数据集,针对每个月数据集分别构建GAT-Transformer预测模型,通过模型训练实现对该月份负荷功率的精准学习。随后,利用训练完成的12个月份预测模型,分别对未来对应月份的负荷功率进行预测,得到未来全年逐小时负荷功率预测结果。最后,基于未来预

测功率序列，采用K-Shape聚类算法对不同时段负荷功率特征进行聚类分析，实现对未来负荷功率模式的有效划分^[29]。

1.2 GAT-Transformer预测模型

GAT-Transformer预测模型构建前需先完成VMD处理^[30]，再通过GAT空间特征提取层与Transformer时间特征提取层实现预测，具体构建过程如下。

(1) VMD处理

针对原始负荷功率序列 $y(t)$ （ t 为时间变量，对应小时维度），VMD通过求解变分问题实现模态分离，其核心为构建变分模型，如下所示：

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \exp^{-jw_k t} \right\|_2^2 \right\}, \text{ s.t. } \sum_{k=1}^K u_k(t) = y(t) \quad (1)$$

式中， $\{u_k\} = \{u_1(t), u_2(t), \dots, u_K(t)\}$ 为分解得到的 K 个模态分量（ $K=6$ ，即IMF1~IMF6）； $\{w_k\} = \{w_1, w_2, \dots, w_K\}$ 为各模态对应的中心频率； ∂_t 为时间导数； $\delta(t)$ 为狄拉克函数； $*$ 为卷积操作； j 为虚数单位； $\|\cdot\|_2$ 为 L_2 范数；约束条件确保所有模态分量叠加后等于原始负荷序列。

为求解上述变分问题，本文引入拉格朗日乘数 $\lambda(t)$ 与惩罚因子 α （用于平衡重构误差与模态稀疏性，取值为2 000），将有约束优化转化为无约束优化。

$$\mathcal{L}(\{u_k\}, \{w_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \exp^{-jw_k t} \right\|_2^2 + \left\| y(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), y(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (2)$$

通过交替方向乘子法迭代更新 $u_k^{(n+1)}$ 、 $w_k^{(n+1)}$ 、 $\lambda^{(n+1)}$ （ n 为迭代次数），直至满足收敛条件（如模态中心频率变化小于 10^{-7} ），最终得到6个稳定的IMF，将其作为后续模型的核心输入特征之一。

将6个时间编码特征与6个VMD得到的IMF融合，构建特征序列 $\mathbf{X} = [x_1, x_2, \dots, x_L] \in \mathbb{R}^{T \times 12}$ 。其中， T 为

序列长度（即时间步长，对应小时数）。每个时间步 $x_t \in \mathbb{R}^{12}$ ，代表该时刻的12维特征向量。

(2) GAT空间特征提取

GAT空间特征提取层被用于挖掘不同特征间的空间关联关系。首先，对输入特征 $\mathbf{X}$ 进行线性变换，得到特征映射矩阵 $\mathbf{H}^0 = \mathbf{X}\mathbf{W}^0 \in \mathbb{R}^{T \times d}$ 。其中， $\mathbf{W}^0 \in \mathbb{R}^{12 \times d}$ 为线性变换权重矩阵； d 为隐藏层维度。随后，通过图注意力机制^[31]计算注意力权重，每个时间步的特征向量 $\mathbf{h}_t^0 \in \mathbb{R}^d$ ，其与其他特征向量 $\mathbf{h}_j^0$ （ j 为相对于时间步 t 的其他时间步引）的注意力系数 e_{ij} 如下所示：

$$e_{ij} = \text{LeakyReLU} \left(\mathbf{a}^T \left[\mathbf{h}_t^0 \mathbf{W}^a \parallel \mathbf{h}_j^0 \mathbf{W}^a \right] \right) \quad (3)$$

式中， $\mathbf{W}^a \in \mathbb{R}^{d \times d_a}$ 为注意力权重矩阵； $\mathbf{a} \in \mathbb{R}^{2d_a}$ 为注意力系数向量； $\parallel$ 为向量拼接操作；LeakyReLU为激活函数。接着，使用Softmax函数对注意力系数进行归一化。

$$\alpha_{ij} = \text{Softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k=1}^T \exp(e_{ik})} \quad (4)$$

最后，根据归一化注意力系数对特征进行加权聚合，得到空间特征提取后的输出 $\mathbf{H}^1 = [h_1^1, h_2^1, \dots, h_T^1] \in \mathbb{R}^{T \times d}$ 。其中， $\mathbf{h}_t^1 = \sum_{j=1}^T \alpha_{tj} \mathbf{h}_j^0 \mathbf{W}^o$ ， $\mathbf{W}^o \in \mathbb{R}^{d \times d}$ 为输出权重矩阵。

(3) Transformer时间特征提取

将GAT输出的空间特征 $\mathbf{H}^1$ 作为输入，通过Transformer编码器^[32]提取时间维度特征。Transformer编码器由多头自注意力机制与前馈神经网络组成，多头自注意力机制计算公式如下：

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) \mathbf{W}^M \quad (5)$$

式中， $\mathbf{Q} = \mathbf{K} = \mathbf{V} = \mathbf{H}^1 \mathbf{W}^q$ （ $\mathbf{W}^q \in \mathbb{R}^{d \times d_k}$ 为投影矩阵）； $\text{head}_i = \text{Attention}(\mathbf{Q} \mathbf{W}_i^Q, \mathbf{K} \mathbf{W}_i^K, \mathbf{V} \mathbf{W}_i^V)$ ， $\mathbf{W}_i^Q, \mathbf{W}_i^K, \mathbf{W}_i^V \in \mathbb{R}^{d_k \times d_k/h}$ 为第 i 个注意力头的参数； h 为注意力头数量； $\mathbf{W}^M \in \mathbb{R}^{d_k \times d}$ 为多头注意力输出投影矩阵。注意

力计算采用缩放点积注意力，计算公式如下：

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}(\mathbf{K})^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (6)$$

多头自注意力输出经过层归一化与前馈神经网络处理后，得到时间特征提取结果 $\mathbf{H}^2 \in \mathbb{R}^{T \times d}$ 。

通过线性投影将 $\mathbf{H}^2$ 映射为负荷功率预测值 $\hat{y} \in \mathbb{R}^T$ ，即 $\hat{y} = \mathbf{H}^2 \mathbf{W}^y + b^y$ 。其中， $\mathbf{W}^y \in \mathbb{R}^{d \times 1}$ 为输出权重矩阵， $b^y \in \mathbb{R}$ 为偏置项。模型训练以预测值与真实值的均方误差为损失函数，即 $\mathcal{L} = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2$ ，通过Adam优化器迭代更新模型参数，直至损失函数收敛。

1.3 K-Shape 聚类模型

K-Shape聚类模型^[33]以未来逐小时负荷功率预测序列为处理对象，核心为基于时序相似性实现聚类划分，具体构建步骤如下。

(1) 数据预处理

将未来预测功率序列按时间周期划分为子序列集 $\mathbf{S} = [s_1, s_2, \dots, s_n]$ 。其中，每个子序列 $s_i = [y_{i1}, y_{i2}, \dots, y_{im}] \in \mathbb{R}^m$ 代表某一固定时长（如1天、1周）的负荷功率序列； n 为子序列数量； m 为每个子序列的长度（时间步长）。

(2) 距离度量选择

采用动态时间规整（Dynamic Time Warping, DTW）^[34]距离衡量两个子序列的时序相似性，从而避免传统欧氏距离对时序错位敏感的问题。对于子序列 s_i 与 s_j ，首先构建距离矩阵 $\mathbf{D} \in \mathbb{R}^{m \times m}$ ， $D(p, q) = |y_{ip} - y_{jq}|$ （ $p, q \in [1, m]$ ）；随后寻找一条从 $D(1, 1)$ 到 $D(m, m)$ 的规整路径 $P = \{(p_1, q_1), (p_2, q_2), \dots, (p_k, q_k)\}$ ，满足路径约束条件（如单调性、连续性）；最后，将路径上的距离进行求和，总和即为DTW距离。

$$\text{DTW}(s_i, s_j) = \min_p \sum_{t=1}^k D(p_t, q_t) \quad (7)$$

(3) 聚类中心初始化与迭代更新

首先，随机选择 k 个初始聚类中心 $C = \{c_1, c_2, \dots, c_k\}$ （ k 为预设聚类数量）；其次，计算每个子序

列 s_i 与各聚类中心 c_j 的DTW距离，将 s_i 分配到距离最近的聚类簇 c_j 中，得到 $C_j = \{s_i | \text{DTW}(s_i, c_j) = \min_{l \in [1, k]} \text{DTW}(s_i, c_l)\}$ ；然后使用K-Shape算法通过求解簇内所有子序列的平均序列，将其作为新聚类中心（采用基于DTW距离的中心计算方法，确保新中心能代表簇内子序列的时序特征）；最后，重复“分配-更新”过程，直至聚类中心变化小于预设阈值或达到最大迭代次数，从而完成K-Shape聚类模型构建。

2 研究数据和模型参数

为验证所提方法的可行性与准确性，本文选取A省2020—2023年全省历史负荷数据进行算例模拟，数据来自相关电力部门。首先，根据A省2020—2022年的历史负荷数据，预测2023年相同月份的负荷曲线并进行聚类，以聚类后的各月典型预测曲线为基础进行峰谷时段划分。其次，将预测负荷曲线、实际负荷曲线、改进后的分时结果及原始分时结果进行对比，通过时段划分与实际负荷曲线的相似度，验证本文所提方法的有效性。A省2020—2022年全年负荷特性如图2所示，相关数据已做脱敏处理，负荷变化趋势不受影响，负荷绝对值不具有参考意义。

可以看出，A省电力负荷呈现显著的季节差异与时段波动特征。全省用电负荷总体呈增长趋势，但不同年份的负荷曲线趋势并不完全一致。冬季及夏季的负荷水平相对较高，且冬季整体负荷略高于夏季；日负荷曲线均呈现“双高峰”形态。因此在制定峰谷时段划分方案时，应充分考虑负荷曲线的动态变化趋势，依据不同季节、不同月份的具体负荷特性进行精细化调整。同时应建立定期评估与动态调整机制，以适应电力供需形势的持续变化。

在预测及聚类模拟的参数选取中，关键参数的选择均基于其在预留验证集上的性能表现综合确定。具体而言，为平衡模型容量与训练稳定性，GAT与Transformer的架构深度分别被设置为2个头与3层；为给复杂特征学习提供充分容量，隐藏层维度被设置为256；由于系统动态需作为一个整体进行宏观刻画，K-Shape聚类数被设置为1。




图2 A省2020—2022年全年负荷特性

Fig.2 Annual load characteristics of Province A from 2020 to 2022

3 结果与讨论

3.1 负荷预测及聚类

根据A省2020—2022年的历史负荷曲线，对2023年相同月份的负荷曲线进行预测并聚类，如图3所示。结果表明，A省负荷曲线整体呈“双峰一谷”结构：早间负荷上升形成高峰，午间平段或回落，晚间再迎高峰并持续较长时间。同时，A省负荷曲线存在明显季节差异：冬季曲线尖峭，早间爬升快，晚间高峰集中，峰谷差与日内波动较大；夏季午后平段长，叠加晚间高峰，日均负荷高且季节敏感性强；春秋曲线平滑，双峰不显，午间平段延长，峰谷差小。整体而言，冬夏峰值与振幅高于春秋季节，冬季晚间高峰强度最强、夏季次之；午间高负荷时段夏季更长。该形态主要受气候与用电行为共同影响：冬季采暖与照明负荷集中于早晚时段，夏季空调需求撑高日间负荷，春秋季节气候温和则曲线平缓^[4,8,12]。聚类结果的季节性差异提示，分时电价设计应重视季节因素，尤其在冬夏高峰期需动态调整峰谷时段边界，以增强价格信号的有效性^[14,16]。

3.2 季节聚类

不同季节的负荷水平存在明显差异，若全年各月统一进行时段划分，则极易出现“春秋季节无高峰、冬夏季节无低谷”的反常结论。因此，需要依据各月的负荷峰值、负荷整体水平及曲线波动特性因素，将全年各月先聚类为高峰、非高峰两类，再分别进行时段划分。聚类后的典型负荷曲线如图4所示。图中，细曲线为图3中的各月典型预测曲线，粗曲线为最终聚类出的两类曲线。

根据聚类结果，A省2023年典型日负荷可分为高峰月与非高峰月两类。其中，高峰月包括1、7、8、11、12月，其余7个月为非高峰月。两类曲线虽均呈双峰结构，但在峰值、谷值、时段集中性等方面存在显著差异。高峰月整体负荷水平较高，早间负荷迅速上升，曲线陡峭，日内振幅较高。非高峰月负荷整体较低，上升平缓，日内波动小，曲线更为平滑。这种差异主要源于气温变化对空调与采暖负荷的季节性影响，叠加工业生产节奏、居民生活规律及新能源出力的不均衡分布^[5,9,11]。上述特征表明，电力负荷结构具有由气候驱动的季节性。因此，在




图3 A省2023年各月预测负荷曲线聚类结果

Fig.3 Clustering results of the monthly forecast load curves in Province A for 2023




图4 A省2023年高峰及非高峰月聚类结果

Fig.4 Clustering results of peak and non-peak months in Province A for 2023

制定分时电价时，建议以月或季为周期进行动态时段优化，以增强适应性及调节效果^[13,15]。同时，本文结合负荷预测进行聚类，能在保持数据自适应性的同时捕捉不同月份间峰谷结构的迁移趋势，与近年政策中动态分时电价的思路相契合^[6,10]。

3.3 各季节时段划分结果

以同类型月份典型聚类曲线中各时刻的负荷水平为基础，分别对高峰月及非高峰月进行时段划分聚类，结果如图5、图6所示。图中各点代表各时刻的聚类负荷位置。由于A省2023年负荷曲线相对平




图5 A省2023年高峰月时段划分结果

Fig.5 Division results of peak month time periods in Province A for 2023




图6 A省2023年非高峰月时段划分结果

Fig.6 Division results of non-peak month time periods in Province A for 2023

滑，没有明显尖峰现象产生，其在聚类过程中自动聚类为峰、平、谷3类，没有产生尖峰及深谷时段。

在高峰月中，低谷时段主要为00:00—05:00，负荷处于日内最低水平且波动幅度小；06:00—09:00为由低谷向平峰过渡阶段，负荷开始逐步抬升；10:00—16:00以平段为主，该时段内的负荷变化相对温和，相邻时刻差异不大，持续时间较长；17:00—21:00多为高峰时段，峰值集中且负荷显著高于其他时段；22:00—24:00为由高峰向平段或低谷过渡过程，负荷出现明显回落。同时发现，2023年1月（冬季高峰月）存在长达4 h的午间低谷负荷，其他月份午间则以平段为主。综合而言，3类时段在负荷水平与稳定性方面呈现清晰的梯度差异：低谷时段表现出谷值

深且稳定的特点；平段表现出持续性强、变化平缓的特点；高峰时段以峰值高度与时间聚集性为主要特征。从时长分配看，平段占比最高，低谷次之，高峰时段集中分布于傍晚至夜间。

在非高峰月中，日负荷曲线总体维持“双峰一谷”结构。00:00—05:00多为低谷时段；06:00—09:00为由低谷向平段的过渡时段，各月负荷同步上行但爬升速率存在差异；10:00—21:00各月连续保持平段或高峰时段，说明非高峰各月负荷平滑度极高，用户用电惯性稳定、气候性负荷（空调、供暖）影响较小。综合来看，非高峰月的时段结构以时段波动较小、峰值强度适中为主要特征。各月峰谷时段划分结果如表2所示。

表2 基于负荷预测及聚类的A省2023年各月峰谷时段划分结果
Table 2 Classification results of peak and valley time periods for each month in Province A for the year 2023 based on load forecasting and clustering

时段	1月	2月	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月
00:00—01:00	低谷	低谷	平段	低谷	低谷	低谷	低谷	低谷	低谷	低谷	平段	低谷
01:00—02:00	低谷	低谷	平段	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷
02:00—03:00	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷
03:00—04:00	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷
04:00—05:00	低谷	低谷	平段	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷	低谷
05:00—06:00	低谷	低谷	平段	低谷	低谷	平段	低谷	低谷	低谷	低谷	平段	低谷
06:00—07:00	平段	平段	平段	平段	低谷	平段	低谷	低谷	平段	平段	平段	平段
07:00—08:00	平段	平段	高峰	平段	平段	平段	低谷	低谷	平段	平段	高峰	平段
08:00—09:00	平段	高峰	高峰	高峰	平段	高峰	平段	平段	高峰	平段	高峰	高峰
09:00—10:00	平段	高峰	高峰	平段	平段	高峰	高峰	高峰	高峰	平段	高峰	高峰
10:00—11:00	平段	高峰	高峰	平段	平段	高峰	高峰	高峰	高峰	平段	高峰	高峰
11:00—12:00	低谷	平段	平段	平段	平段	高峰	高峰	高峰	高峰	平段	平段	平段
12:00—13:00	低谷	平段	平段	平段	低谷	高峰	高峰	高峰	高峰	平段	平段	平段
13:00—14:00	低谷	平段	平段	平段	平段	高峰	高峰	高峰	高峰	平段	平段	平段
14:00—15:00	低谷	平段	平段	平段	平段	高峰	高峰	高峰	高峰	平段	平段	平段
15:00—16:00	平段	平段	平段	平段	平段	高峰	高峰	高峰	高峰	平段	高峰	平段
16:00—17:00	高峰	平段	高峰	平段	平段	高峰	高峰	高峰	高峰	高峰	高峰	高峰
17:00—18:00	平段	高峰	高峰	平段	平段	高峰	高峰	高峰	高峰	高峰	高峰	高峰
18:00—19:00	平段	高峰	高峰	高峰	平段	高峰	平段	平段	高峰	高峰	高峰	高峰
19:00—20:00	平段	高峰	高峰	高峰	平段	高峰	平段	平段	高峰	平段	高峰	高峰
20:00—21:00	平段	高峰	高峰	高峰	平段	高峰	高峰	平段	平段	平段	高峰	高峰
21:00—22:00	低谷	平段	高峰	平段	平段	高峰	平段	平段	平段	平段	高峰	平段
22:00—23:00	低谷	平段	平段	平段	低谷	平段	平段	平段	平段	低谷	高峰	平段
23:00—24:00	低谷	平段	平段	平段	低谷	平段	平段	平段	平段	平段	平段	平段

综合而言，A省2023年的各月负荷在日内呈现出稳定的双峰型结构，并表现出显著的季节差异。不同季节的高峰时段在出现时间和持续时间方面各有特点：夏季高峰主要集中在午后至傍晚，持续时间较长；冬季表现为早晚双峰并强且晚间高峰持续至21:00甚至更晚；春秋季节以平段为主、峰值强度与持续性介于冬夏之间。同时，2月与6月分别呈现由冬向春、由春向夏过渡的边界特征。与全年统一规则或仅根据历史样本聚类的方法不同^[3,27]，本文先按月份同质性聚类再划分峰平谷时段，既验证了已有研究中“夏季午间低谷、冬季晚高峰”的普遍共识^[4]，又在边界位置与持续时间上更贴合典型日拐点，避免了“一刀切”的错配情况。

3.4 时段划分效果对比

为验证所提时段划分方法的科学性与有效性，本文同时对A省2023年各月的实际负荷曲线进行了聚类，对比预测负荷曲线、实际负荷曲线、改进后的时段划分、原有时段划分，从而判断时段划分的精确度以及与负荷曲线的一致性。本文在4个季节中各取一个典型月聚类后的曲线进行详细对比分析，如图7所示。

可以看出，本文利用A省历史负荷数据生成的2023年预测负荷曲线与实际曲线在4个典型月均保持较高的一致性。各季节预测负荷曲线与实际负荷曲线的皮尔逊系数均大于97.70%。其中，夏季相似度最高，为99.54%。预测曲线准确复现了夜间低谷、




图7 各季节典型月时段划分结果

Fig.7 Results of the typical month period division in each season

日间爬升与晚间高峰等关键日内结构，并清晰反映了不同季节的负荷差异，表明模型具有较高的趋势捕捉能力与预测精度。在时段划分方案方面，相较于固定阈值和经验规则等方法^[23-24]，本文以负荷形态簇为识别边界，优化后的时段划分方案更贴近负荷曲线的形态特征与转折点。该方案形成了以连续平段与集中峰段为主体的稳定结构，类内一致性与边界连贯性更高，并减少了日间碎片化切分。结果表明，本文优化后的时段划分在边界位置、区间连续性、峰段完整性等方面与实际曲线的贴合度更高，体现出更强的精确性与方法学合理性。

4 结论与政策建议

4.1 主要结论

为解决传统峰谷时段划分中缺乏考虑未来电力供需关系导致的分时精确度不足问题，本文从预测、聚类与分时三个层面构建了基于未来负荷波动的电力峰谷时段划分框架，并利用A省历史负荷数据进行了有效性验证。预测阶段采用GAT-Transformer混合深度学习模型挖掘负荷数据的时间特征。聚类阶段应用K-Shape方法提取各月典型日负荷模式，识别不同月份所属的高峰与非高峰类别。分时阶段依据聚类获得的典型曲线形态，自动、无监督地划分各月的峰谷时段。最终通过对比预测曲线和实际曲线、优化后的分时方案和原始分时方案，验证所提方法在时段划分准确度方面的有效性与优越性。主要结论如下：

（1）面向未来的负荷预测提升了峰谷时段划分的精确性。引入图注意力的时序预测框架对未来负荷曲线进行预测，能够使峰谷时段划分更加接近真实的电力供需关系，准确捕捉电力负荷曲线的日内结构及波动边界，并在不同季节之间形成清晰的负荷分层。这说明在峰谷分时政策制定中引入前瞻性预测，有助于抑制“以史定段”带来的结构错配。

（2）先聚类后分段降低了季节因素导致的分类误差。基于预测曲线的月度聚类将月份自然分解为高峰与非高峰两类，在月内刻画峰、平、谷的拐点与时长，较好地分离了不同季节导致的用电惯性差异，可以跨季节适应不同月份的电力需求特性，使

时段分类科学性得到显著提升。

（3）相较于原有时段，改进后的时段在负荷一致性与完整性方面具有显著优势。对比4个季节的典型月负荷曲线发现，优化方案的边界更贴近实际负荷曲线的拐点，时段设计更连续、高峰更集中，能够避免原有政策对时段的过度切分与碎片化现象。冬季双峰被完整覆盖，夏季长高峰得到准确识别，春秋长时间平段的完整性得到保持，整体贴合度及可解释性均有所提高。

需要指出的是，本文仍以单个省份样本为主，未涉及极端气象、新能源出力快速增长及电动汽车负荷等新因素的扰动。未来可引入新能源电力渗透率在电力供需场景生成中的边界设置，并将时段划分与分时电价定价、电力现货市场交易决策或需求响应参与机制联立求解，形成目标一致的协同优化框架。

4.2 政策建议

基于上述研究结论，为提升各地区峰谷分时电价政策时段划分的科学性与前瞻性，本文提出如下政策建议：

（1）推动划分依据从历史数据向预测负荷转变。随着能源结构与用电行为的持续演变，仅依赖历史曲线易导致政策滞后。将预测负荷作为分时依据，能够更准确地反映未来电力系统的实际供需态势，增强分时电价政策在引导削峰填谷中的时效性与精准度。

（2）建立周期性的动态调整机制，实现分时方案的滚动优化。不同月份、季节之间的负荷特性存在显著差异，固定时段划分难以适应全年波动特征。建议以月度或季度为周期，根据最新预测结果持续优化时段划分，使分时电价政策能够适应负荷形态的中长期演化趋势。

（3）在划分方法上应强化人工智能等前沿技术的应用，减少主观干预。传统依赖专家经验划定时段的方式易引入偏差，而聚类、人工智能等算法可依据负荷曲线的内在结构实现客观分段，提升方案的稳健性与可解释性，同时契合电力系统智能化转型的内在要求。

本文提出的基于负荷预测的时段划分方法，为

电力市场环境下的分时电价动态优化提供了有效的技术路径。后续研究将进一步融合更复杂的市场因素，如新能源出力波动性、现货市场价格信号及跨省区交易机制等动态因素，探索多因素耦合驱动下的自适应时段划分策略。这将在统一电力市场建设不断深化的背景下，进一步增强分时电价政策与实时供需及市场环境的协同性，推动形成更具弹性与效率的电力价格机制。

参考文献

- [1] 喻小宝, 董真余, 郑丹丹, 等. 计及煤耗率的尖峰电价优化模型及灵敏度分析[J]. 系统工程理论与实践, 2024, 44(7): 2260–2272.
- [2] 孙传旺, 占妍泓, 徐梦洁. 电力需求响应信号与新能源制造企业绩效[J]. 管理世界, 2024, 40(12): 185–203.
- [3] 刘严, 谭忠富, 乞建勋. 峰谷分时电价设计的优化模型[J]. 中国管理科学, 2005, 13(5): 87–92.
- [4] 黄剑平, 陈皓勇, 林镇佳, 等. 需求侧响应背景下分时电价研究与实践综述[J]. 电力系统保护与控制, 2021, 49(9): 178–187.
- [5] ZHENG Y W, ZHENG Y F, HE G N, et al. Decomposition and decoupling analysis of electricity consumption carbon emissions in China[J]. Frontiers of Engineering Management, 2022, 9(3): 486–498.
- [6] ZHANG J X, YU S W, ZHANG Y J, et al. How do renewable energy policies affect energy green development? Evidence from Chinese listed energy firms[J]. Energy Economics, 2025, 142: 108154.
- [7] 范英, 衣博文. 能源转型的规律、驱动机制与中国路径[J]. 管理世界, 2021, 37(8): 95–105.
- [8] 中华人民共和国国家发展和改革委员会. 关于进一步完善分时电价机制的通知[EB/OL]. (2021-07-29)[2025-09-22]. https://www.gov.cn/zhengce/zhengceku/2021-07/29/content_5628297.htm.
- [9] 湖南省发展和改革委员会. 关于优化我省分时电价政策有关事项的通知[EB/OL]. (2025-06-18)[2025-09-22]. http://www.hunan.gov.cn/zqt/zcsd/202507/t20250704_33729798.html.
- [10] 江苏省发展和改革委员会. 关于优化工商业分时电价结构促进新能源消纳降低企业用电成本支持经济社会发展的通知[EB/OL]. (2025-04-25)[2025-09-22]. http://fzggw.jiangsu.gov.cn/art/2025/4/30/art_284_11557001.html.
- [11] CHU W J, FAN L W, ZHOU P. Examining the interactions of carbon, electricity, and natural gas markets[J]. Frontiers of Engineering Management, 2025, 12: 543–557.
- [12] 唐文升, 王阳, 张煜, 等. 基于多维价格弹性系数的分时电价对负荷特性影响机理[J]. 中国电力, 2024, 57(2): 202–211.
- [13] 刘浩田, 陈锦, 朱熹, 等. 一种基于价格弹性矩阵的居民峰谷分时电价激励策略[J]. 电力系统保护与控制, 2021, 49(5): 116–123.
- [14] 李春燕, 许中, 马智远. 计及用户需求响应的分时电价优化模型[J]. 电力系统及其自动化学报, 2015, 27(3): 11–16.
- [15] 汪磊, 杨贺钧, 马英浩, 等. 考虑多重评价指标的多时段分时电价优化模型[J]. 中国电力, 2019, 52(6): 54–59.
- [16] 孔强, 付强, 林亨君, 等. 基于成本效益分析的峰谷分时电价优化模型[J]. 电力系统保护与控制, 2018, 46(15): 60–67.
- [17] 薛云涛, 陈伟超, 李秀文, 等. 基于用户满意度和Ramsey定价理论的峰谷分时阶梯电价联合模型[J]. 电力系统保护与控制, 2018, 46(5): 122–128.
- [18] 黄海涛, 吴洁晶, 顾丹珍, 等. 计及负荷率分档的峰谷分时电价定价模型[J]. 电力系统保护与控制, 2016, 44(14): 122–129.
- [19] 徐永丰, 吴洁晶, 黄海涛, 等. 考虑负荷率的峰谷分时电价模型[J]. 电力系统保护与控制, 2015, 43(23): 96–103.
- [20] 陈沧杨, 胡博, 谢开贵, 等. 计入电力系统可靠性与购电风险的峰谷分时电价模型[J]. 电网技术, 2014, 38(8): 2141–2148.
- [21] 赵晋泉, 胡佳, 王珂, 等. 一种日前发电调度与日前分时电价联合优化模型[J]. 电力系统保护与控制, 2019, 47(9): 56–63.
- [22] 李艳梅, 任恒君, 张致远, 等. 考虑储能系统调度与风电消纳的峰谷分时电价优化模型研究[J]. 电网技术, 2022, 46(11): 4141–4149.
- [23] 程瑜, 翟娜娜. 基于用户响应的分时电价时段划分[J]. 电力系统自动化, 2012, 36(9): 42–46.
- [24] CHARWAND M, GITIZADEH M. Optimal TOU tariff design using robust intuitionistic fuzzy divergence based thresholding[J]. Energy, 2018, 147: 655–662.
- [25] SANDMEIER T, SCHARNHORST L, GEIS-SCHROER J, et al. Detecting residential power peaks for innovative tariff designs: A living lab experiment[J]. Energy and Buildings, 2025, 330: 115350.
- [26] 艾欣, 周树鹏, 赵阅群. 考虑风电不确定性的用户侧分时电价研究[J]. 电网技术, 2016, 40(5): 1529–1535.
- [27] ZHU J Z, MIAO Y W, DONG H J, et al. Short-term residential load forecasting based on K-shape clustering and domain adversarial transfer network[J]. Journal of Modern Power Systems and Clean Energy, 2024, 12(4): 1239–1249.
- [28] ALVES M J, ANTUNES C H. A semivectorial bilevel programming approach to optimize electricity dynamic time-of-use retail pricing[J]. Computers & Operations Research, 2018, 92: 130–144.
- [29] XU R Y, SONG Z R, WU J G, et al. Change-point detection with deep learning: A review[J]. Frontiers of Engineering Management, 2025, 12(1): 154–176.
- [30] 刘晓军, 熊健, 王艺博, 等. 考虑不确定变量变分模态分解及绿证-碳联合交易的综合能源系统经济优化调度[J]. 电工技术学报, 2025, 40(13): 4276–4291.
- [31] 白泽, 刘灏, 毕天姝. 基于图注意力网络的配电网分布式光伏实时消纳能力评估方法[J]. 电力自动化设备, 2024, 44(12): 92–99.
- [32] 叶林, 吕可欣, 裴铭, 等. 考虑NWP传递熵因果验证的光伏功率预测误差溯源方法[J]. 电力系统自动化, 2025, 49(15): 110–122.
- [33] WANG X, SONG R B, XIAO J M, et al. Accelerating k-shape

time series clustering algorithm using GPU[J]. IEEE Transactions on Parallel and Distributed Systems, 2023, 34(10): 2718–2734.

[34] 詹莹, 王潇添, 王旭, 等. 基于综合距离相似的CEEMDAN-Informer光伏功率组合预测模型研究[J]. 太阳能学报, 2025, 46(8): 315–326.

Optimization Method for Time-of-Use Pricing Based on Load Forecasting

MENG Yichao^{1,2}, ZHANG Yuejun^{1,2,*}

1. Business School, Hunan University, Changsha 410082, China;

2. Center for Resource and Environmental Management, Hunan University, Changsha 410082, China

Abstract : To enhance the scientific rigor and foresight of the time-of-use electricity pricing policy, this paper proposes a period division optimization method based on load forecasting and constructs a time-of-use optimization framework that integrates load forecasting, curve clustering, and period classification. Using actual load data from a province, an empirical analysis is conducted. The results demonstrate that the proposed method can enhance the adaptability of time-of-use period divisions across different months by more accurately predicting future electricity supply and demand characteristics and effectively distinguishing seasonal variations in electricity consumption. The optimized time-of-use scheme exhibits higher load consistency, aligns more closely with the inflection points of actual load curves, and significantly mitigates the issues of over-segmentation and feature mismatches present in the original scheme. This study provides a feasible technical approach for the dynamic optimization of time-of-use pricing policies under the electricity market environment.

Key Words : time-of-use electricity pricing; time period division; load forecasting; graph attention network