基于电气化交通负荷差异辨识的虚拟电厂建模与优化

张碧丹，谭谱祥，郑可迪，何冠楠*，宋 洁

北京大学 先进制造与机器人学院，北京 100871

扫码阅读

摘 要： 电动汽车充电负荷的高度异构性是当前电力系统面临的核心挑战之一。尽管虚拟电厂（Virtual Power Plant，VPP）为此提供了可行的解决方案，但忽略负荷差异的粗放式调度普遍导致其经济性欠佳。本文直面这一问题，提出了一种基于负荷差异化辨识的 VPP 精细化调度策略。研究主要包含 3 个层面：首先，通过一种计及不适成本的聚类算法实现对充电行为的精准分类，揭示不同类型负荷特征的差异性；然后，构建一个覆盖日前与实时的两阶段市场结算模型以优化 VPP 收益；最后，提出适应不同负荷类型的差异性优化调度策略，并构建基于双层优化博弈的负荷响应模型，实现 VPP 与负荷方在激励与调节互动中的策略均衡。结果表明，相较于传统方法，对负荷进行差异化管理的模式能够更准确地识别和捕捉不同负荷群体的需求特点，从而显著降低 VPP 的总调度成本。

关 键 词： 虚拟电厂；分布式能源；电动汽车；公共充电站；优化调度

中图分类号： TM721；TM614 **文献标志码：** A **文章编号：** 2097-4981(2025)05-0642-15

DOI：10.3724/j.issn.2097-4981.JECC-2025-0028

Modeling and Optimization of Virtual Power Plant Based on Identifying Differences in Electrified Transportation Loads

ZHANG Bidan, TAN Puxiang, ZHENG Kedi, HE Guannan*, SONG Jie

School of Advanced Manufacturing and Robotics, Peking University, Beijing 100871, China

Abstract: The high heterogeneity of electric vehicle charging loads poses a core challenge to modern power systems. While virtual power plant (VPP) offers a viable solution, broad dispatch strategies that ignore load diversity often lead to suboptimal economic performance. This paper directly addresses this issue by proposing a refined VPP dispatch strategy based on load differentiation. The research encompasses three main aspects. First, we employ a clustering algorithm that accounts for discomfort costs to precisely classify charging behaviors, revealing the distinct characteristics of different load types. Second, we construct a two-stage market settlement model, covering day-ahead and real-time markets, to optimize VPP revenue. Finally, we propose a differentiated optimal dispatch strategy tailored to different load types and develop a load response model based on a bi-level optimization game. This achieves a strategic equilibrium between the VPP and the loads through the interaction of incentives and regulation. Results demonstrate that this differentiated load management approach, compared to conventional methods, more accurately identifies and captures the unique demand characteristics of different load groups, thereby significantly reducing the total VPP dispatch cost.

收稿日期： 2025-06-25；**接受日期：** 2025-10-05

基金项目： 国家自然科学基金项目（72342004，72271008）

作者介绍： 张碧丹（1996—），女，博士，助理研究员，研究方向为新型能源系统优化。E-mail: 2306396105@pku.edu.cn

通讯作者： 何冠楠（1991—），男，博士，研究员，博士生导师，研究方向为低碳能源数智化、能源大数据及能源系统优化。E-mail: gnhe@pku.edu.cn

Key Words: virtual power plant; distributed energy; electric vehicles; public charging stations; optimal scheduling

0 引言

全球电动汽车（Electric Vehicle，EV）保有量的迅速增长，正对现有电力系统的负荷管理构成前所未有的挑战。EV的大规模普及直接导致了充电需求的激增，在高峰时段，集中的充电行为可能对电网稳定造成巨大冲击。以上海为例，EV充电需求将给电网基准负荷带来高达24.7%的增幅[1]，这一负荷波动在传统电网中难以有效消化。与此同时，电网中光伏与风能等间歇性可再生能源渗透率的提升使得电力供需平衡的复杂性与不确定性剧增，进一步加剧了电网的调度困境。

在此背景下，虚拟电厂（Virtual Power Plant，VPP）作为一种能够优化分布式能源资源调度的灵活平台[2]，通过智能调度系统将EV充电站（Charging Station，CS）、光伏发电和储能设备等分布式能源进行集成，动态调整负荷需求以平衡电网的供需[3-4]，从而有效地管理多种不确定性[5-6]。VPP试点项目已在全球多地成功实施，并在中国多个省级行政区展现了应用价值[5]。已有研究证实，VPP对交通电气化负荷的管理能够为电网释放显著的潜在价值。例如，VPP在负荷高峰期削减峰值负荷的能力可有效缓解电网压力[7-8]。面对大规模可再生能源并网的趋势，凭借灵活性与实时调度能力，VPP能够在保障电力系统稳定性的同时，与EV形成协同优化，进而降低系统总运行成本[9-10]。

目前，VPP研究主要集中于运行调度优化和系统灵活性提升两个方面。在运行调度优化方面，学者们提出了多种创新性模型和方法，包含VPP在多源互补机制[11]、可再生能源不确定性应对[12]、低碳经济性优化调度[13]等方面的贡献。在系统灵活性研究方面，目前的研究趋势呈现出需求响应和多元灵活性资源深度整合的特点，如基于碳电转换的VPP架构[14]、基于在线算法的分布式能源聚合协调[15]、多时间尺度下的协同调频控制[16]等方面。然而，一个不容忽视的现实是，随着分布式能源的类型与数量激增，电力系统的差异性与不确定性愈发凸显，从而对VPP调度算法和控制策略的复杂性与精细度提出了更高要求。因此，未来研究亟需立足于实际应用场景，充分挖掘分布式资源调节潜力及特性，以应对系统多样性与波动性挑战。

EV作为重要的分布式能源资源，近年来由于数量激增，在VPP中的应用逐渐得到重视。现有研究主要集中于EV充电对电力系统稳定性与经济效益的影响，尤其是如何通过优化调度策略来提高系统的运行效率。研究多侧重于EV的直接或间接控制，包括在大规模储能不足的情况下，EV协调控制策略[17]、基于强化学习的EV管理策略[18]、两阶段车网协同调度优化方法[19]、EV联合电网优化调度模型[20]等。尽管EV为VPP提供了巨大的潜在价值，但由于EV存在较强的个体差异性和随机性，VPP在面临新增的约束条件时，需要寻求更加精细的优化方案。特别是在最小化充电成本、温室气体排放、电力系统损耗、用户随机性和环境不确定性等多重目标的优化下，调度问题变得愈加复杂[21-22]。虽然目前提出了创新的智能充电协议[21]，用于协调分布式EV的充电行为，但在实际操作中，车主的充电行为往往受到多重因素的干扰，导致调度精度降低[23]。EV的数量庞大、容量小且分布广[24]，直接控制充电行为的手段十分有限。因此，调节CS成为更加现实的解决方案。

在实际应用中，公共CS是主要的EV充电设施所有者，可以充当EV能源调度的聚合器，因为其能够处理比单个家庭充电器所有者更多的充电桩[25]。因此，一些早期研究已经将CS纳入VPP运营。文献[26]针对一个由住宅、可再生能源、储能系统和CS组成的VPP开展了相关研究。文献[27]进一步探讨了包含火力发电机、可再生能源和储能系统的VPP，提出了CS在VPP与EV充电需求之间的协调模型，并通过综合日前与实时阶段的协调调度，提升了系统的经济效益和稳定性。文献[25]构建了基于多利益相关者的VPP-CS协同运营框架，通过日前报价、实时平衡模型、用户激励机制和成本分配方法，实现了VPP与CS的互利共赢，显著提升了系统整体经济效益。文献[13]在风光出力不确定的背景下，提出了一种双层

规划模型，通过源荷协调机制、动态定价策略和碳交易机制，优化了EV CS与VPP的利益协调。

然而，从调度视角来看，上述工作普遍采用两类处理。其一，将所有CS作为同质整体进行统一调度。这一做法有利于模型与交易流程的简化，便于快速求解与实施，但忽略了不同站点在用户偏好、充电桩收益和局部网络约束等方面的显著差异，易导致响应潜力被“平均化”，使边际收益提升受限。其二，对每个CS进行完全独立的逐站调度。这一做法能够刻画站点个体异质性与负荷随机性，但在站点数量较多时会造成决策维度急剧膨胀、计算代价与实施复杂度显著上升。为此，需要在以上两种方法之间构建一套有效的折中策略。

综上所述，尽管现有研究为应对EV数量激增带来的挑战已提出多种应对策略，但在一些关键领域仍存在研究空白。首先，现有以CS为核心的VPP协同研究，多将CS整体同质化统一调度或逐站独立细化，中间缺少一套更为平衡的解决方法。此外，在负荷特性的认知上，许多研究虽构建了EV负荷的数学模型，却对真实世界数据的内在规律挖掘不深，导致理论模型与实际运行状态存在脱节的风险。这种不足直接体现在调度模型层面：现有的VPP调度模型通常缺乏对不同CS之间差异的系统性识别和调控，主要集中在单一类型的充电设施或统一模型的应用，未考虑到CS在调度过程中作为聚合器所具备的多样化调节能力。

为此，本文聚焦于CS负荷的特征分类与差异化管理，通过对不同充电行为类型进行识别与分类，提出了一种基于电气化交通负荷差异辨识的VPP建模与优化方法。首先，本文对实测CS负荷数据进行精细分类，旨在揭示不同区域群体在充电行为下独特的负荷模式，为后续的差异化调控提供数据支撑与调度输入；然后，构建包含日前供应和实时平衡的两阶段结算模型，以协调VPP系统内各要素，实现系统总效益最大化；最后，为充分利用负荷的异质性，设计一种能够适应不同CS负荷类型的优化调度策略，通过差异化的负荷管理策略增强调节灵活性以降低电网的负荷波动，并构建基于双层优化博弈的负荷响应模型，实现VPP与负荷方在激励与调节互动中的策略均衡。

余文安排如下：第1节描述了VPP的运行管理模式；第2节提出并分析了一种基于电气化交通负荷差异辨识的VPP负荷调节策略；第3节通过案例分析深入讨论了数值模拟结果；第4节对全文进行了总结，并讨论了未来的研究方向。

1 VPP模型概述

VPP通过将分布式可再生发电、可控负荷和储能装置等多类资源整合管理，使其能够多点接入电网并参与电力市场的运行。本节首先描述VPP的整体框架，包括其资源聚合结构和能量管理体系；然后建立VPP参与日前和日内市场的模型，揭示其在双层市场环境下的调度机制；最后分别给出VPP中储能系统和CS的数学模型，以全面反映各单元的功率/能量约束和动态特性。

1.1 VPP管理系统框架

本文建立一个基于CS的VPP集成模型，同时包含可再生能源（聚焦于光伏系统）和用于调节能量偏差的储能系统。在该系统中，参与主体包括VPP、储能系统和EV用户。VPP可以直接管理多源参与者参与电力市场；CS能量管理系统可以直接管理EV的充/放电功率及充/放电行为。在这种配置下，利益相关者通过竞争性市场价格而获益，VPP通过利用CS的能源灵活性调节而获益。由于单个EV的容量较小且随机性较大，EV用户不参与市场运营。为兼顾EV用户的利益，EV用户的贡献将通过激励计划获得经济补偿。VPP管理系统框架如图1所示。

从市场运行视角来看，本文所构建的VPP采用含日前市场与实时平衡的双阶段管理架构[28-29]。日前阶段，基于预测的光伏出力和负荷需求，VPP提交发电计划和购电策略；实时阶段，系统通过储能调节及电网偏差结算机制实现功率平衡。各个分布式单元的数据交互与协同建立在信息物理系统之上。值得注意的是，CS的聚合功率调节能力被视为VPP整体优化目标中的关键变量。每个CS（电站1～n）通过其能源管理系统对充电行为进行激励、控制和监测，并将控制信号与监测信息等本地数据上报至VPP管理系统，以进行全局性的信息交互与调度决策。

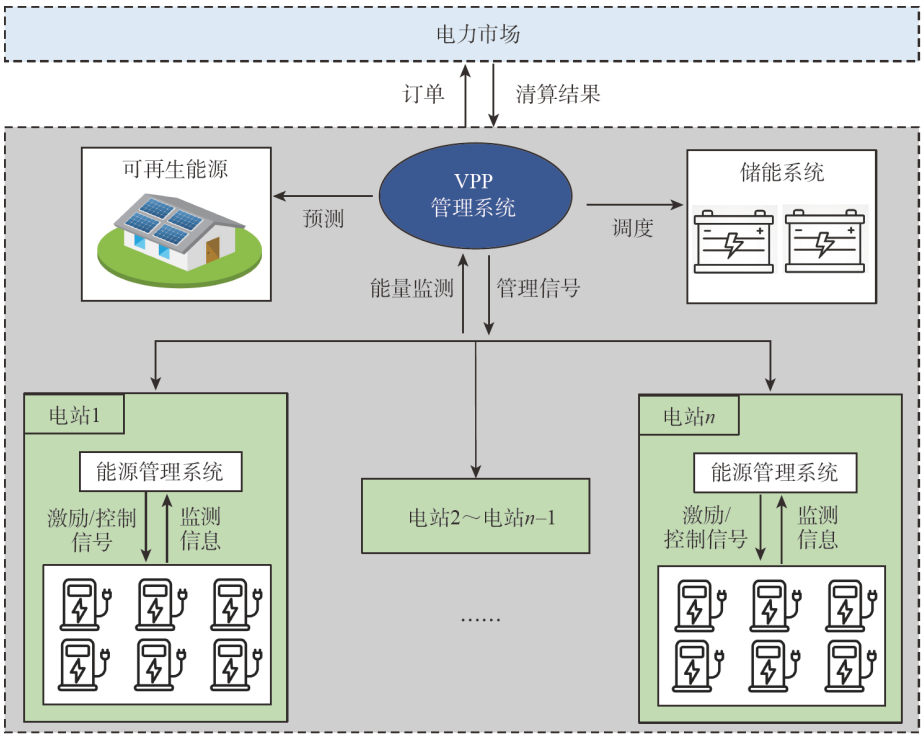


图 1 VPP管理系统框架

Fig.1 Framework of VPP management system

1.2 VPP优化模型

VPP的优化调度问题围绕电力市场的日前市场调度与实时偏差结算双阶段运行机制展开。在日前市场阶段，VPP需基于24h预测周期内的可再生能源出力（假设光伏发电的边际成本为0）及负荷需求预测，制定能量管理计划并提交购/售电订单。该优化问题以利润最大化为目标，兼顾可再生能源出力波动与CS负荷的动态平衡：

$$\min_{\left\{P_{\mathrm{DA}}^{\mathrm{buy}},P_{\mathrm{DA}}^{\mathrm{sell}},P_{\mathrm{EV}}\right\}} \sum_{t=1}^{T}\left(\pi_{\mathrm{DA}}^{\mathrm{buy}}(t)\cdot P_{\mathrm{DA}}^{\mathrm{buy}}(t)-\pi_{\mathrm{DA}}^{\mathrm{sell}}(t)\cdot P_{\mathrm{DA}}^{\mathrm{sell}}(t)\right)\cdot \Delta t+C_{\mathrm{EV}}(t)\cdot\Delta P_{\mathrm{EV}}(t) \tag{1}$$

式中，$P_{\mathrm{DA}}^{\mathrm{buy}}(t)$和$P_{\mathrm{DA}}^{\mathrm{sell}}(t)$分别为第$t$时刻日前市场买电和售电的电功率；$\Delta P_{\mathrm{EV}}$为第$t$时刻的CS负荷调节功率；$\pi_{\mathrm{DA}}^{\mathrm{buy}}(t)$和$\pi_{\mathrm{DA}}^{\mathrm{sell}}(t)$分别为第$t$时刻日前市场买电和售电的电价；$C_{\mathrm{EV}}(t)$为第$t$时刻CS负荷的调节成本；$\Delta t$为交易时间尺度。

上述目标方程受能量平衡及变量非负约束，即调节后的CS负荷量超过光伏发电量时需要向市场买电，反之售电：

$$P_{\mathrm{DA}}^{\mathrm{buy}}(t)=\begin{cases}P_{\mathrm{EV}}(t)+\Delta P_{\mathrm{EV}}(t)-P_{\mathrm{PV}}(t), & \text{if } P^{\mathrm{buy}}(t)\geqslant 0\\ 0, & \text{if } P^{\mathrm{buy}}(t)<0\end{cases} \tag{2}$$

$$P_{\mathrm{DA}}^{\mathrm{sell}}(t)=\begin{cases}P_{\mathrm{PV}}(t)-P_{\mathrm{EV}}(t)+\Delta P_{\mathrm{EV}}(t), & \text{if } P^{\mathrm{sell}}(t)\geqslant 0\\ 0, & \text{if } P^{\mathrm{sell}}(t)<0\end{cases} \tag{3}$$

式中，$P_{\mathrm{EV}}(t)$为第t时刻CS负荷功率；$P_{\mathrm{PV}}(t)$为第t时刻光伏出力；$\Delta P_{\mathrm{EV}}(t)$为第$t$时刻负荷调节量。若$\Delta P_{\mathrm{EV}}(t)$为正，表示为正功率调节（降低负荷使用）；若$\Delta P_{\mathrm{EV}}(t)$为负，则表示为负功率调节（增加负荷使用）。

进入实时运行阶段后，优化的重心转向如何以最低经济代价消纳功率偏差。为此，VPP必须在两种调节手段之间做出动态权衡：一是动用自身的储能系统进行充放电调节，这会产生成比例的损耗成本与运维成本；二是在电网的平衡机制下进行偏差电量结算，即为功率缺口向电网购电或将多余功率出

售给电网。该阶段优化问题的数学表述如下：

$$\min_{\left\{P_{\mathrm{RT}}^{\mathrm{buy}},P_{\mathrm{RT}}^{\mathrm{sell}},P_{\mathrm{c}},P_{\mathrm{d}}\right\}} \sum_{t=1}^{T}\left(\pi_{\mathrm{RT}}^{\mathrm{buy}}(t)\cdot P_{\mathrm{RT}}^{\mathrm{buy}}(t)-\pi_{\mathrm{RT}}^{\mathrm{sell}}(t)\cdot P_{\mathrm{RT}}^{\mathrm{sell}}(t)+ C_{\mathrm{BES}}(t)\cdot(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))\right)\cdot\Delta t \quad (4)$$

式中，$P_{\mathrm{RT}}^{\mathrm{buy}}(t)$和$P_{\mathrm{RT}}^{\mathrm{sell}}(t)$分别为第$t$时刻实时市场买电和售电的功率；$\pi_{\mathrm{RT}}^{\mathrm{buy}}(t)$和$\pi_{\mathrm{RT}}^{\mathrm{sell}}(t)$分别为第$t$时刻实时市场买电和售电的电价；$C_{\mathrm{BES}}(t)$为第$t$时刻储能系统调节负荷的成本；$P_{\mathrm{c}}(t)$和$P_{\mathrm{d}}(t)$分别为储能系统的充电和放电功率。

在电网平衡调节过程中，购售电决策主要取决于能量偏差（实际能量与日前市场申报能量的差值）和储能系统的充放电调节能力。具体而言，当VPP出现能量盈余时，将出售多余电能；反之，若存在能量缺额，则需购入相应电力以维持系统平衡：

$$P_{\mathrm{RT}}^{\mathrm{buy}}(t)=\begin{cases}|P_{\mathrm{IM}}(t)+(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))|, & \text{if } P_{\mathrm{IM}}(t)+(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))<0\\ 0, & \text{if } P_{\mathrm{IM}}(t)+(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))\geqslant 0\end{cases} \quad (5)$$

$$P_{\mathrm{RT}}^{\mathrm{sell}}(t)=\begin{cases}|P_{\mathrm{IM}}(t)+(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))|, & \text{if } P_{\mathrm{IM}}(t)+(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))>0\\ 0, & \text{if } P_{\mathrm{IM}}(t)+(P_{\mathrm{c}}(t)-P_{\mathrm{d}}(t))\leqslant 0\end{cases} \quad (6)$$

式中，$P_{\mathrm{IM}}(t)$为能量偏差。

1.3 储能系统模型

在本文所构建的VPP框架中，储能系统被定位为能量时移与动态平衡的核心执行单元。具体而言，在充电阶段，该系统负责存储来自电网或可再生能源发电单元的电能；在放电阶段，该系统将储存的电能向电网或负荷端传送。储能系统充放电过程可采用如下动态方程进行数学描述，以反映电能随时间变化的时序特性：

$$E(t)=E(t-1)+\eta_{\mathrm{c}}P_{\mathrm{c}}(t)\Delta t-\frac{1}{\eta_{\mathrm{d}}}P_{\mathrm{d}}(t)\Delta t \quad (7)$$

式中，$E(t)$为在第t时刻储能系统的剩余电能；η_{c}和η_{d}分别为充电和放电效率。

储能系统充电和放电功率的调度受功率的限制：

$$P_{\mathrm{BESc_min}}\leqslant P_{\mathrm{c}}(t)\leqslant P_{\mathrm{BESc_max}} \quad (8)$$

$$P_{\mathrm{BESd_min}}\leqslant P_{\mathrm{d}}(t)\leqslant P_{\mathrm{BESd_max}} \quad (9)$$

式中，$P_{\mathrm{BESc_min}}$和$P_{\mathrm{BESc_max}}$分别为最小充电功率和最大充电功率；$P_{\mathrm{BESd_min}}$和$P_{\mathrm{BESd_max}}$分别为最小放电功率和最大放电功率。

储能荷电状态（State of Charge，SOC）动态方程描述储能系统在第t时刻的荷电状态，其不能超过储能系统最大存储容量，也不能低于储能系统最低安全存储限度：

$$SOC(t)=SOC(t-1)+\frac{1}{C}\left[\eta_{\mathrm{c}}P_{\mathrm{c}}(t)-\frac{P_{\mathrm{d}}(t)}{\eta_{\mathrm{d}}}\right]\Delta t \quad (10)$$

$$SOC_{\min}\leqslant SOC(t)\leqslant SOC_{\max} \quad (11)$$

式中，$SOC_{\min}$和$SOC_{\max}$分别为SOC的最小值和最大值；C为电池的最大容量。

为防止储能同时充放电，模型中加入充/放互斥的二进制约束：

$$P_{\mathrm{c}}(t),P_{\mathrm{d}}(t)\in\{0,1\},\quad P_{\mathrm{c}}(t)+P_{\mathrm{d}}(t)\leqslant 1 \quad (12)$$

1.4 公共CS模型

CS的功率调节不仅需要满足电网的调度需求，还要考虑CS自身的充电设备技术特性。根据负荷的可调性质，CS的功率调节通常包括功率增减的动态调节，并且需要遵循电站的电气约束和充电特性，功率输出在其最大和最小限制范围内：

$$P_{\mathrm{EV}_{\min}}\leqslant P_{\mathrm{EV}}(t)+\Delta P_{\mathrm{EV}}(t)\leqslant P_{\mathrm{EV}_{\max}} \quad (13)$$

式中，$P_{\mathrm{EV}_{\min}}$和$P_{\mathrm{EV}_{\max}}$分别为CS充电功率的最小值和最大值。

考虑到充电设施的物理特性及其与电网的交互安全，CS的功率响应速率需要受到限制。因此，模型中必须引入充放电功率的爬坡速率限制，以确保其功率调节轨迹的平滑性，防止因功率梯度过大而冲击电网的稳定运行：

$$|P_{\mathrm{EV}}(t)+\Delta P_{\mathrm{EVC}}(t)-(P_{\mathrm{EV}}(t-1)+\Delta P_{\mathrm{EV}}(t-1))|\leqslant\Delta P_{\max} \quad (14)$$

式中，ΔP_{max}为功率变化的最大速率。

2 基于交通负荷差异辨识的 VPP 负荷调节策略

CS所汇集的充电负荷具有显著的时空波动性，可视为潜在的柔性资源[25]。然而在实际应用中，不同CS的负荷特征存在较大差异，将直接影响VPP的调度策略。例如，部分站点主要在白天高峰期出现高负荷，而部分站点在夜间或其他时段负荷偏高。为优化VPP的调节效能，关键需识别CS负荷模式的异质性特征，进而针对不同类型制定差异化的调控策略。本节重点阐述本文提出的基于负荷聚类分析的VPP差异化调节方法：首先对CS的负荷曲线进行聚类分析，将其划分为若干类别，以反映各类别站点的典型负荷特性[30]；然后根据聚类结果设计不同的调节目标和约束，通过建立双层博弈模型，动态调节CS能量管理计划，并向车主提供经济补偿，最终实现VPP优化目标。

2.1 融合差异性负荷识别的 VPP 调节框架

CS负荷差异化识别与VPP负荷管理框架如图2所示。该框架包含“聚类–调节”一体化策略，以CS负荷数据为基础，融合了聚类分析、策略匹配与优化调节3个关键环节。在日前市场中，首先提取各CS历史运行数据中的关键特征向量，如日负荷轮廓及边

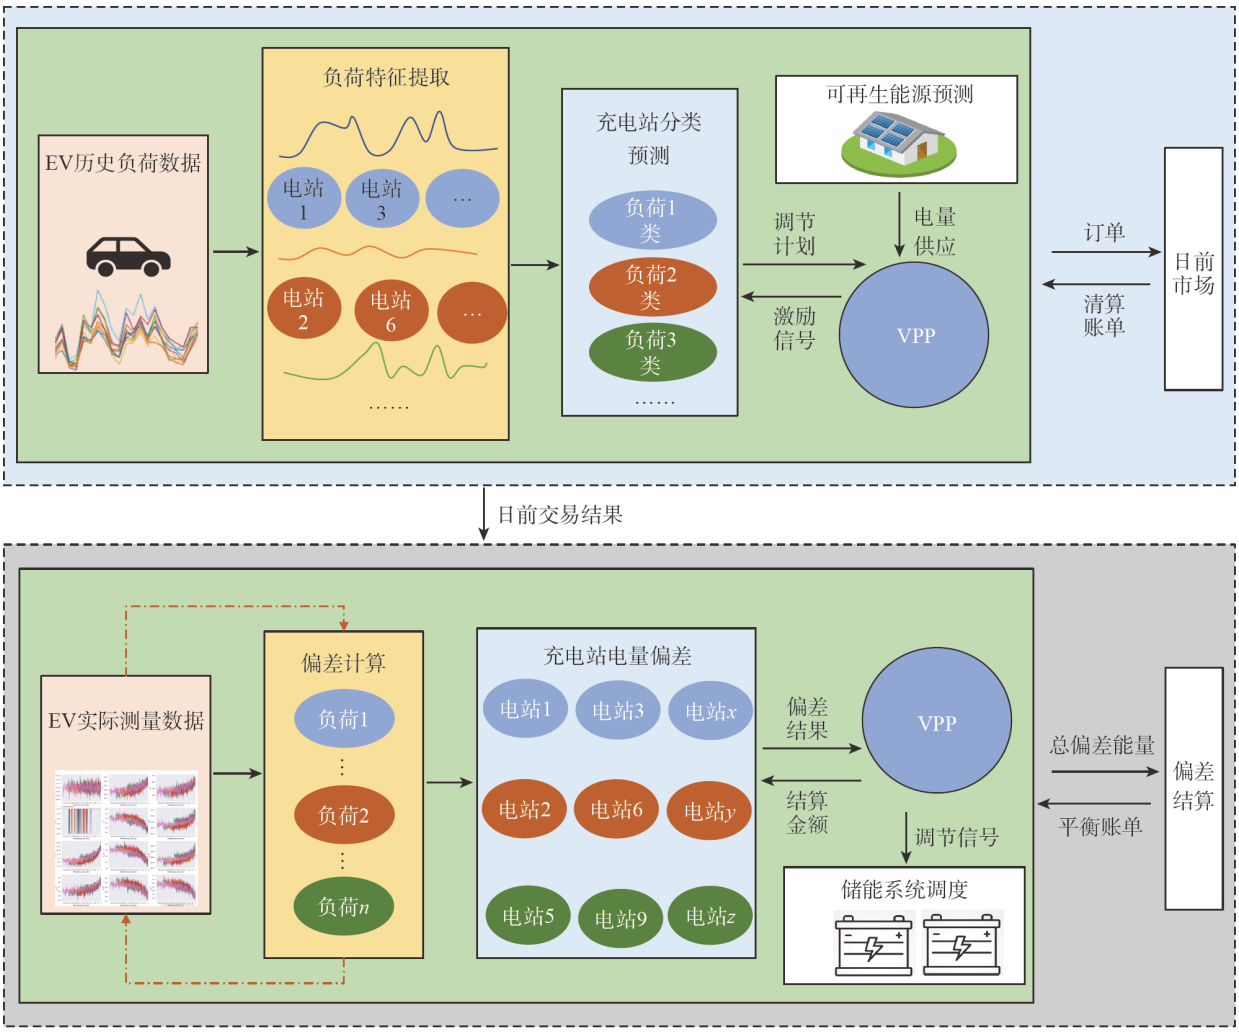


图 2 基于差异化负荷的 VPP 管理系统框架

Fig.2 Framework of VPP management system based on differentiated load

际调节成本；然后采用K-means无监督学习算法，依据上述特征将具有相似运行模式的CS进行自动分类。该算法能够自动地将运行模式相近的CS聚合为一类，从而有效识别出诸如“高峰集中型”或“夜间谷段充电型”等典型模式。基于该聚类结果，VPP将构建一个以总调度成本最小化为目标的优化模型。该模型在计及电价信号、物理安全约束与能量平衡限制后，为每个CS类别求解出次日各时段的最优调节功率基线。VPP下发的功率指令旨在通过站级的宏观引导，而非对个体用户的直接干预，并结合激励机制以保障CS的响应率与终端用户体验。

为应对预测误差与系统扰动，框架进一步引入了实时校正机制。在实时运行阶段，系统持续监测各CS的实际功率与日前计划值之间的偏差。一旦偏差超出阈值，VPP会立即激活内部的电池储能等快速响应资源进行动态补偿，或从电网购电以弥补缺口，同时通过闭环反馈来调整后续策略，确保VPP内外的功率平衡。最终，依据各CS在双层市场（日前与实时）中的实际电量贡献完成经济结算。

2.2 CS负荷优化调节模型

本文旨在通过调节能源方案降低总成本，一方面通过优化高峰期的电力需求以减少电网负担，另一方面通过借助峰谷电价差异以降低VPP在运行过程中的总体成本。CS管理系统根据VPP信号和自身约束来确定最终调节。调整能源计划会对EV车主产生负面影响，如延长充电时长，因此需要给予车主一定的补偿。本文设定补偿机制由VPP统一确定，CS则需综合考虑由调节引起的用户不适成本与获得的补偿金额，进而决策其愿意参与的调节能量。在该模型中，不适成本越高，CS可提供的调节量越小；而补偿金额越高，则能激励其提供更多的可调节能量。基于此，第k类负荷类型的CS的调节决策目标可表示为一个成本最小化问题，即以不适成本与补偿费用之和为目标函数进行优化：

$$\min \sum_{i=1}^{N}\sum_{t=1}^{T} C_{\mathrm{dis}}(i,t) - C_{\mathrm{com}}(i,t) \tag{15}$$

式中，$C_{\mathrm{dis}}(i,t)$为调节CS负荷引起的不适成本；$C_{\mathrm{com}}(i,t)$为调节负荷所得到的补偿费用。

根据文献[31]，调节能量所产生的不适成本可以通过二次函数进行建模。该模型反映了调节量与不适成本之间的非线性关系，可以看出调节量越大，不适成本越高：

$$C_{\mathrm{dis}}(i,t) = (\Delta P_{\mathrm{EV}}(i,t)\cdot \Delta t)^2 \cdot \lambda_{\mathrm{dis}}(i,t) \tag{16}$$

式中，$\lambda_{\mathrm{dis}}(i,t)$为CS负荷调节的不适成本系数。

为鼓励CS响应调节信号，对负荷减少部分给予补偿。具体地，当$\Delta P_{i,t} < 0$时，给予该站所属类别为$k(i)$的车主经济补偿，当功率为正调节时则不予补偿。对于每种充电负荷k，补偿费用表示每单位负荷调节的费用：

$$C_{\mathrm{com}}(i,t) = \begin{cases} \alpha_t |\Delta P_{\mathrm{EV}}(i,t)|, & \text{if } \Delta P_{\mathrm{EV}}(i,t) < 0 \\ 0, & \text{if } \Delta P_{\mathrm{EV}}(i,t) \geqslant 0 \end{cases} \tag{17}$$

式中，α_t为VPP设定的补偿系数。

因此，第t时刻的VPP负荷调节成本费用可计算为

$$C_{\mathrm{EV}}(t) = \sum_{i=1}^{N}\sum_{t=1}^{T} C_{\mathrm{com}}(i,t) \tag{18}$$

令第i个CS负荷类型在第t时刻的基准负荷为$P_{\mathrm{EV}}(i,t)$，则该类调节后负荷为

$$P_{\mathrm{EV}}^{\mathrm{adj}}(i,t) = P_{\mathrm{EV}}(i,t) + \Delta P_{\mathrm{EV}}(i,t) \tag{19}$$

假设VPP调度时段为$t = 1,\ldots,T$，共有N个CS参与调度，每站日负荷需满足能量守恒，即调节前能量总量和调节后能量总量一致：

$$\sum_{i=1}^{N}\sum_{t=1}^{T} P_{\mathrm{EV}}(i,t) = \sum_{i=1}^{N}\sum_{t=1}^{T} P_{\mathrm{EV}}^{\mathrm{adj}}(i,t) \tag{20}$$

每类充电负荷i在时段t内的电力调节量必须满足其最小和最大可调节范围：

$$\Delta P_{\mathrm{EV}}^{\min} \leqslant \Delta P_{\mathrm{EV}}(i,t) \leqslant \Delta P_{\mathrm{EV}}^{\max} \quad \forall i,t \tag{21}$$

式中，$\Delta P_{\mathrm{EV}}^{\min}$为充电功率的最小调节范围；$\Delta P_{\mathrm{EV}}^{\max}$为充电功率的最大调节范围。

在实施过程中，VPP运营者根据计算结果得到各站负荷调节策略后，向CS发出增减功率指令。例如，当系统需要降低负荷时，可设置$\Delta P_{i,t} < 0$并相应支付补偿，使车主将充电推迟或减速；当系统需要增加负荷（如吸收过剩新能源）时，可设置$\Delta P_{i,t} > 0$，鼓

励车主提前充电或增加充电功率。在此过程中，不直接对用户充电模式施加强制干预，而是通过分类负荷功率控制手段实现负荷调整。

2.3 CS负荷聚类及特征分析

不同CS在充电负荷的峰谷时段、持续时长、峰值功率与波动性等方面存在系统性差异，这些差异共同决定了其能量调节的可行边界和调节所需的经济补偿水平。为实现对CS负荷的精细化调度，有必要首先对采集的负荷数据开展特征提取并据此进行负荷类型划分。需要注意的是，任何以时移或限功率为手段的调度干预，均会影响用户补能体验，进而产生不适成本。这种成本并非均质的：工业园区站点的用户对临近出发前的充电保障有刚性需求；而商业中心“机会充电”用户的损失则更多地与充电过程的灵活性和可预测性有关。以往的负荷聚类研究[32]多聚焦于负荷曲线本身的时间序列特征。这种方法虽能区分负荷模式，但忽略了不同模式在响应调度时的经济敏感度差异。因此，本文在聚类分析中创新性地引入不适成本作为关键维度，旨在建立一个能同时反映负荷时序特性与调节经济性的多维分类体系，从而更精准地量化其参与功率调节的综合价值。

首先，将每日CS负荷曲线作为分析对象，把不同时间段（如小时）上的负荷作为特征向量$\mathbf{x}_i$。可进一步提取峰值、谷值、平均值、峰谷差等指标，构建每个站点的负荷特征向量。其次，根据CS参与功率调节引发的不适成本进行进一步的特征构建。由于负荷数据和不适成本数据的量纲不同，因此需要对数据进行归一化处理，以消除尺度差异对聚类结果的影响。采用K-means算法进行负荷聚类，其目标为将所有CS负荷样本划分为K个簇，使簇内数据相似度最大，簇间差异性最大。K-means算法的目标函数可表示为

$$J(U,M)\sum_{i=1}^{m}\sum_{j=1}^{k}u_{ij}^{*}\sqrt{\sum_{l=1}^{n}(x_{il}-\mu_{jl})^{2}} \tag{22}$$

式中，$\mathbf{x}_i=[x_{i1},x_{i2},\ldots,x_{in}]$为第$i$个CS负荷的特征向量，包含了所有相关的特征值$x_{il}$；$\boldsymbol{\mu}_j=[\mu_{j1},\mu_{j2},\ldots,\mu_{jn}]$为第$j$类（簇）的中心向量，包含了所有相关的簇中心值$\mu_{jl}$；$u_{ij}^{*}$为隶属度矩阵中的元素，表示将第$i$个对象分配给第$j$个类（簇）的程度（例如为0或1）；目标函数$J$表示各簇内样本与簇中心的欧氏距离加权和。

算法从初始簇中心出发，不断迭代更新样本分配和簇中心，直至目标函数收敛到局部最优。对于每个簇j，更新簇中心$\boldsymbol{\mu}_j$，即每个簇中所有CS的负荷特征向量的均值：

$$\boldsymbol{\mu}_j=\frac{1}{N_j}\sum_{i\in C_j}\mathbf{x}_i \tag{23}$$

式中，N_j为第j类簇中的CS数量；C_j为第j类簇中CS的索引集合。

通过计算每个CS到所有簇中心的欧氏距离，重新分配每个CS属于哪个簇：

$$u_{ij}=\begin{cases}1, & \text{if } j=\operatorname{argmin}_{j'}\left\|x_i-\mu_{j'}\right\|^{2}\\ 0, & \text{others}\end{cases} \tag{24}$$

聚类完成后，每个CS被归入某一类别k，记为$i\in C_k$，这些类别代表了CS负荷的典型模式。将不适成本这一经济维度引入聚类分析后，形成的负荷簇在形态上与仅依赖传统负荷特征（如峰谷差、波动程度）的聚类结果呈现出显著差异，如图3所示。这种形态上的分化，恰恰说明了不同CS群组在响应激励调度时，其经济性存在本质差异，而这并非仅凭分析物理用电行为就能完全捕捉的。

在基于K-means算法进行CS负荷模式识别时，聚类簇数K的合理选取对最终聚类效果具有显著影响。为规避不当的簇数（过多或过少）可能引发的过拟合或欠拟合问题，本文采用轮廓系数以辅助确定最优簇数K^{*}。轮廓系数能够同时量化聚类的两个关键维度：簇内样本的凝聚度和不同簇之间的分离度。对于任一聚类结果而言，轮廓系数越高，表示样本在本簇中越紧密且与其他簇越分离，聚类效果越优。对于样本i，其轮廓系数$s(i)$定义如下：

$$s(i)=\frac{b(i)-a(i)}{\max\{a(i),b(i)\}} \tag{25}$$

式中，$a(i)$为样本i与其所在簇中其他样本之间的平均欧氏距离，用于衡量簇内紧密度；$b(i)$为样本i至另一最近邻簇内所有样本的平均欧氏距离，用于衡量不同簇之间的分离程度。

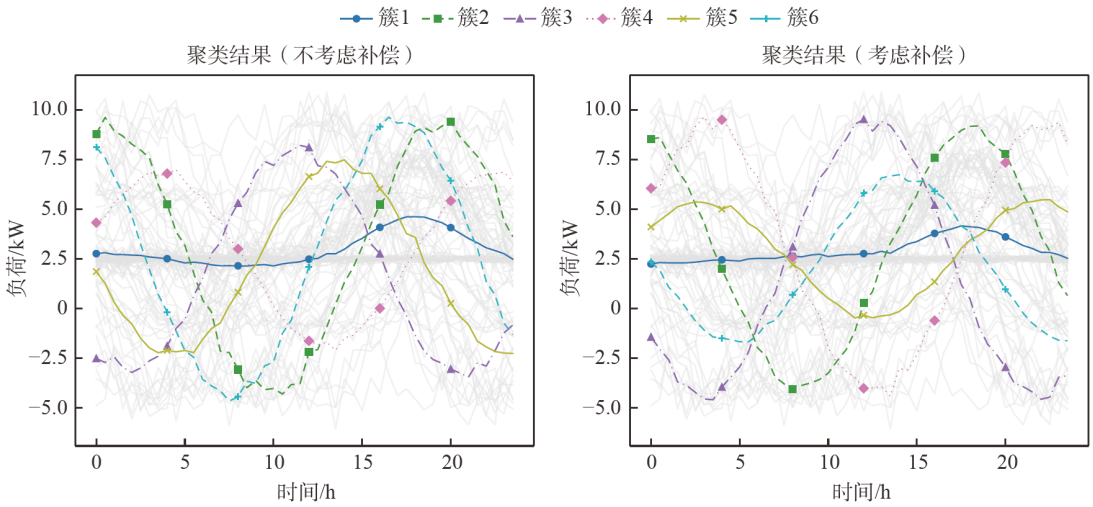


图 3　考虑不同负荷特征因素的聚类结果

Fig.3　Clustering results considering different load characteristic factors

值得注意的是，$s(i) \in [-1,1]$，当$s(i)$趋近于1时，表示样本i在空间分布上更贴近其自身簇的核心，同时远离其他簇，意味着聚类划分具有较高的合理性；当$s(i)$趋近于0时，表示样本位于两个簇之间的边界，聚类不明确；若$s(i) < 0$，则可能存在误分配情况，即其与邻近簇的平均距离小于其与所属簇的平均距离。

2.4　基于双层博弈的VPP负荷响应优化模型

在基于负荷响应的VPP协调机制中，VPP承担协调电网资源与负荷的职责。特别是在电价峰值时段，VPP需通过激励机制引导用户削减部分负荷，旨在降低整体购电成本并维持系统运行的稳定性。负荷参与方依据VPP提供的经济补偿，自主决策是否参与响应以及具体的负荷调节深度。该交互过程可被建模为一个双层优化博弈问题，VPP与负荷方分别作为博弈的参与者，该模型通过在VPP与负荷方之间进行信息交互与策略调整，达到系统调度目标与经济性之间的优化平衡。

该模型由上层VPP模型和下层负荷方响应模型两个主要部分组成。上层模型基于1.2节中介绍的VPP日前优化模型进行构建，VPP根据电力市场和系统需求设定初始化补偿系数α_t^0。下层模型则采用2.2节所述的负荷侧优化调节模型，根据VPP给定的补偿系数，CS方决定负荷其调节量$\Delta P_{EV}(i,t)$。模型的求解依赖于上下层之间的迭代过程，其具体流程（图4）如下。

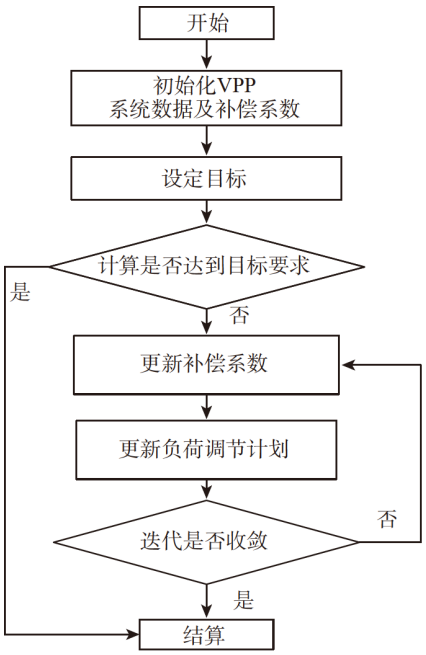


图 4　基于动态双层博弈模型的迭代优化流程

Fig.4　Iterative optimization process based on dynamic bi-level game model

步骤1：根据电力系统负荷预测、市场需求及调度目标，VPP初步设定初始化补偿系数α_t^0。

步骤2：根据电力系统需求设定能量调节目标，本文设置为用电高峰期$t \in [T_1, T_2]$降低负荷总量至目

标需求量E^{aim}。

步骤3：得到VPP设定的补偿系数后，CS负荷管理系统基于自身的成本函数和补偿系数进行决策，决定其负荷调节量。

步骤4：VPP汇总所有负荷方的调节量，并评估总体调节效果是否满足预设目标。若未达到目标，VPP将依据以下规则调整补偿系数，并将更新后的补偿系数α_t^{k+1}反馈给负荷方。补偿系数的调整遵循正向激励原则，即提高补偿水平以鼓励更大的负荷响应量：

$$\alpha_t^{k+1}=\alpha_t^{k}+\Delta\alpha \tag{26}$$

式中，$\Delta\alpha$为弹性系数，决定了补偿系数的增长量。弹性系数的更新策略如下：若总削减量已满足市场需求，则更新量为0；反之，则依据负荷调节量对货币激励的敏感度进行调整[33]：

$$\text{if}\left(\left|\sum_{i=1}^{N}\sum_{t=T_1}^{T_2}\Delta P_{\text{EV}}(i,t)\cdot\Delta t\right|\right)^{k}\geqslant E^{\text{aim}},\ \Delta\alpha=0 \tag{27}$$

$$\text{if}\left|\sum_{i=1}^{N}\sum_{t=T_1}^{T_2}\Delta P_{EV}(i,t)\cdot\Delta t\right|\leqslant E^{\text{aim}},\quad \Delta\alpha=\xi+\frac{E^{\text{aim}}-\left|\sum_{i=1}^{N}\sum_{t=T_1}^{T_2}\Delta P_{\text{EV}}(i,t)\cdot\Delta t\right|}{E^{\text{aim}}} \tag{28}$$

式中，ξ为适应性调节系数（可依据仿真需要设置以加速收敛）。

步骤5：步骤3到步骤4的过程会不断迭代，直至满足以下任意条件时为止：

（1）负荷方的总调节量达到或超过预设的目标量；

（2）负荷方已达到最大可调节量；

$$\left(\left|\sum_{i=1}^{N}\sum_{t=T_1}^{T_2}\Delta P_{\text{EV}}(i,t)\cdot\Delta t\right|\right)^{k}-\left(\left|\sum_{i=1}^{N}\sum_{t=T_1}^{T_2}\Delta P_{\text{EV}}(i,t)\cdot\Delta t\right|\right)^{k-1}=0 \tag{29}$$

（3）系统补偿系数变化大于设定的阈值。

$$\alpha_t^{k}\geqslant\alpha_{\max} \tag{30}$$

通过此迭代过程，VPP激励策略与负荷方的响应行为相互作用，最终收敛至一个纳什均衡点或次优均衡解，从而在系统经济性与调度目标之间实现优化权衡。

步骤6：当迭代终止后，模型输出最终的补偿系数与各负荷方的调节量，形成最终调度方案，VPP与负荷方依据此方案完成经济结算。

3 案例分析

本文算例基于湖北省武汉市的实测CS负荷数据，包含841个站点，使用了15min级别的时序数据。光伏发电数据来源于中国西北地区某光伏基地的历史发电记录。发电量/负荷量预测通过长短期记忆神经网络模型进行模拟。

在实验参数设置方面，本文假设VPP的储能系统功率容量为5MW，能量容量为10MWh，储能调节成本为0.1元/kWh，充放电效率为95%，电价策略采用峰谷分时电价，高峰时段VPP负荷削减目标为原始负荷数据的10%。在算法初始化阶段，为保证寻优过程的无偏性，VPP初始补偿系数α_t^{0}设为0，其取值上限则与动态电价的峰值一致。迭代弹性系数$\Delta\alpha$根据仿真经验取值为0.02，选用此较小的步长值是为保障迭代求解的稳定性与收敛性，有效避免调整幅度过大。此外，考虑工业区、商业区和居民区负荷对能量调节造成的不适成本差异，本文分别将3类区域的不适成本λ_{dis}基准值设定为0.1、0.15和0.08。为更贴近实际场景的随机特性，基于高斯分布在3个基准值附近进行小范围随机扰动，为每个站点分配各自的不适成本。所有调度与优化模型均基于Python语言环境编程实现，并调用Gurobi优化求解器进行求解。

为研究VPP在不同条件下的运行性能，本文设置3个不同的实验案例：案例1讨论不同聚类策略对VPP运行结果的影响，旨在探讨聚类方法如何优化VPP的资源调度与能效提升；案例2聚焦于不同调节范围对VPP运行效果的影响；案例3旨在评估预测精度变化对VPP运行性能的影响，本文通过向预测数据引入高斯噪声来模拟不同水平的预测误差。

3.1 VPP 差异性负荷调节优化运行结果分析

图5详细展示了将负荷划分为1～6类后进行差异性调节的VPP调节过程。可以看出，不同聚类情况下，VPP的管理策略一方面显示相同特征：在价格较高的峰值时段，系统执行负荷削减策略以缓解电网压力；而在价格较低的低谷时段，则反向引导负荷增长，旨在最大化能源利用的经济价值。另一方面，负荷分类使不同负荷集群在统一调度指令下的异质性响应特征得以凸显，各类别所承担的调节量也表现出显著的量化差异。

由图5可知，聚类数量为2～4类时，主要存在两类重点用电负荷，具有幅度较大的负荷波动。因此，VPP的调节资源绝大部分被分配至这两个高弹性负荷类别。其他类别由于负荷体量及变化幅度均较小，在整体调节中的作用会受到限制。当聚类粒度提升至5类及以上时，一个关键的转变为原先较为庞大的负荷集群被进一步分解为3个具有鲜明不同特性的子类别，各类负荷的电力需求画像开始呈现清晰的辨识度。与此相对应的是，VPP的调节策略也演变得更加精细，尤其是在调节量的分配上，涌现出3种独立的调节模式。这种策略上的精化，增强了负荷调度的灵活性与准确性。

图6描绘了在不同聚类数量下，负荷聚类的轮廓系数与系统总成本的变化趋势。可以看出，当聚类数量为5时，补偿系数为0.92，轮廓系数达到最大值。在该聚类方案下，负荷群体的内部同质性与不同群体间的异质性达到了最佳平衡，即负荷类型的划分效能最高。这种高质量的聚类效果直接转化为经济效益，对应的系统总成本也达到最低点。作为一个具体的量化比较，该成本较采用8个聚类的方案低约18%。这一现象说明，尽管在理论上增加聚类数量有助于更精细地刻画负荷特性并设计更具针对性的调节策略，但这并不意味着聚类粒度与系统性能之间存在单调正相关。实际上，过度细分的聚类会导致资源配置与控制模型的复杂度急剧上升，这种复杂性会转化为额外的经济成本与计算负担，从而抵消精细化带来的潜在优势。

图7为主成分分析降维聚类结果，可以看出，选择5类聚类能够有效地捕获负荷数据的内在结构特征。具体来看，聚类2与聚类4形成了两个高度聚合的密集区域，并分别位于主成分平面的两个远端，意味着二者之间存在显著的特征异质性与良好的分离度。聚类1和聚类5虽然在空间位置上更加靠近中心位置，但同样构成了界限分明、内部紧凑的群组，证实了其作为独立负荷模式的有效性。值得注意的是，聚类3由极少数样本构成，并在主成分空间的下方形成了一个孤立的分布区域，稀疏性与空间上的显著分离表明该类别代表了一种统计上独特且不常见的负荷行为模式。这一聚类分布结果表明，采用5类聚类方案可有效识别负荷数据的显著差异特征，并避免不必要的聚类冗余或过于精细的划分，使各聚类类别的边界相对清晰明确。

3.2 调节范围对差异化负荷调节的影响

表1为最优聚类情况下不同负荷可调范围的VPP运行结果。可以看出，VPP在日前市场中的负荷调度灵活性与其调节范围呈正相关。增强的灵活性使VPP能够更有效地响应市场价格信号，尤其是在价格峰值时段，通过将更大规模的负荷转移至价格低谷时段，能够实现购电成本的显著降低和整体经济效益的优化。然而，随着调节范围的增大，调节成本也随之上升。在负荷调节范围从95%～105%扩展至60%～140%的过程中，调节成本由1.65万元逐步增加至6.20万元。

尽管如此，从系统总成本的角度进行综合评估，增加的调度灵活性所带来的经济效益在很大程度上抵消了其调节成本的增长，使得日前成本呈现出递减的趋势。具体而言，在负荷调节范围达到60%～140%时，尽管调节成本达到峰值，但日前成本却降至101.84万元的最低点。这一结果表明，通过扩大负荷调节范围，能够使VPP实现更灵活的电力供需之间的优化平衡，进而降低系统的整体运营成本。

3.3 预测精度对运行结果的影响

表2为最优聚类情况下不同预测精度的能源市场成本结果。可以看出，随着预测误差的增大，日前成本表现出较低的敏感性与小幅波动，而实时成本则呈现显著的非线性增长。以具体数据为例，当预测误差由3.1%上升至8.0%时，日前成本的变动量仅

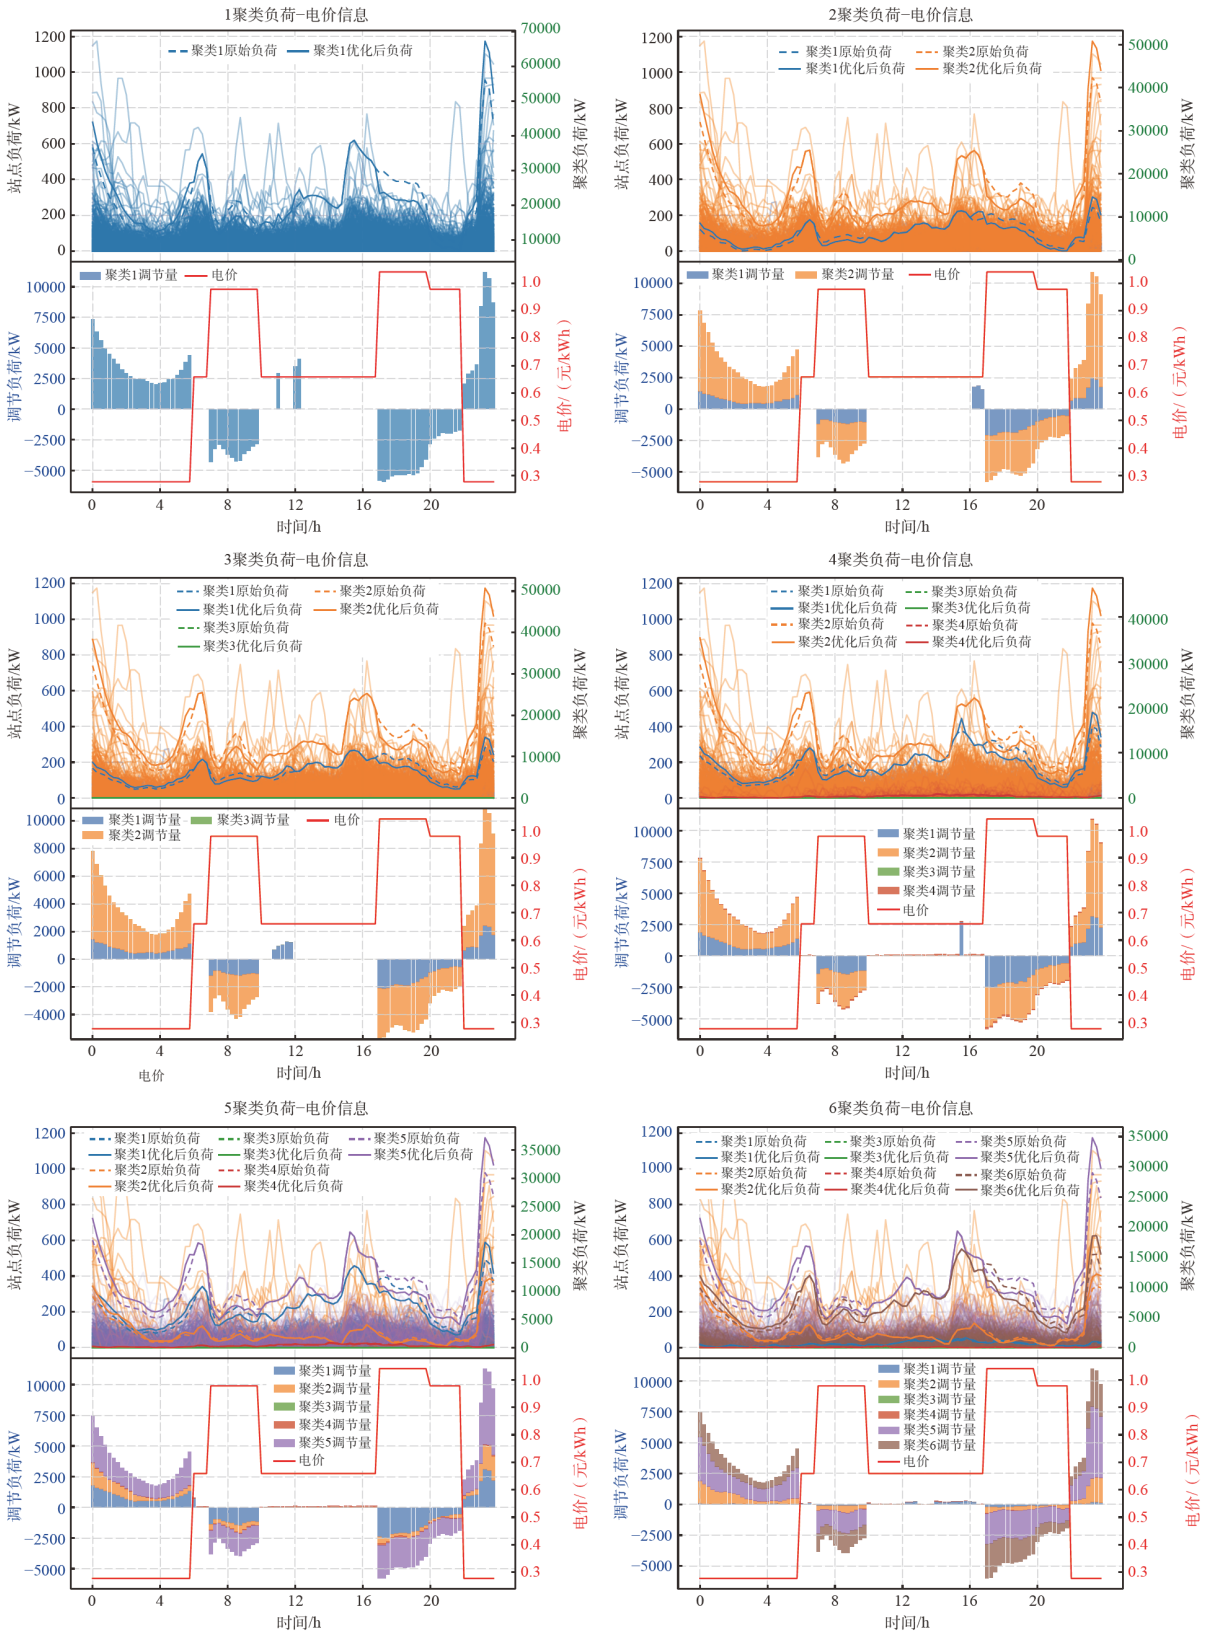


图 5　不同聚类负荷下的 VPP 运行结果

Fig.5　VPP operating results under different clustering loads

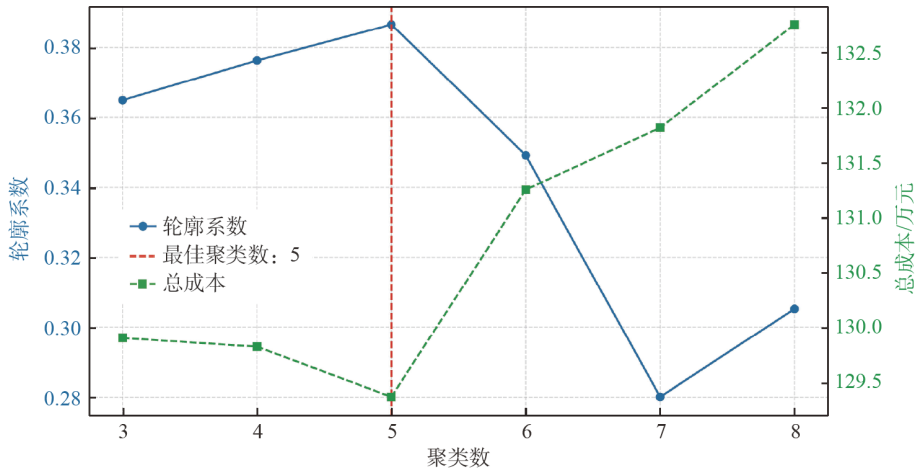


图 6 轮廓系数与成本随聚类数变化

Fig.6 Variation of silhouette coefficient and cost with the number of clusters

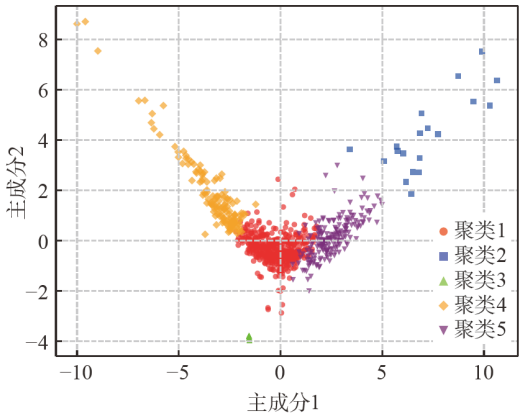


图 7 基于主成分分析降维的 5 类聚类结果分布

Fig.7 Distribution of clustering results for 5 categories based on principal component analysis dimensionality reduction

表 1 不同负荷可调范围下的成本比较

Table 1 Costs comparison under different load adjustable ranges

调节范围/%	调节成本/万元	购电成本/万元	日前成本/万元
95～105	1.65	111.84	113.49
90～110	1.96	109.52	111.48
85～115	2.62	107.21	109.83
80～120	3.29	104.89	108.18
70～130	4.71	100.27	104.98
60～140	6.20	95.64	101.84

为0.1万元，而实时成本的增幅高达6.3%。这一成本响应差异的深层机理归因于两个市场的基本运行逻辑与结算机制。日前成本主要由基于日前预测提交的竞价策略与市场出清价格共同决定。一旦市场出清，交易量与价格即被锁定，后续的预测误差虽可能影响调度计划的执行精度，但不会影响已确定的日前结算。

表 2 不同预测误差情况下的成本比较

Table 2 Costs comparison under different prediction error scenarios

预测误差/%	日前成本/万元	实时成本/万元	总成本/万元
3.1	108.2	22.3	130.5
4.5	108.2	22.4	130.6
6.8	108.2	23.5	131.7
8.0	108.3	23.7	132.0

相比之下，实时成本对预测误差表现出更高的敏感性。当VPP的实际发电量或负荷需求偏离其在日前市场锁定的计划值时，此偏差量必须利用自有储能或是在实时市场中进行强制平衡。具体而言，负荷超出预测结果意味着需要在价格通常更高的实时市场中紧急购电；而负荷低于预期则可能导致电力以低价抛售，甚至产生机会成本。整个过程通过偏差结算机制来执行，偏差量越大，平衡成本或惩罚就越昂贵。因此，预测精度的下降会直接放大物理偏差，从而推高对误差极为敏感的实时成本。

4 结论

本文针对CS负荷的差异性问题，提出了一种基

于电气化交通负荷差异辨识的VPP建模与优化方法，设计了一种精细化调度方案。该方法的核心在于，首先运用数据驱动的聚类算法，将高维、无序的充电行为数据降维并凝练为若干具有典型响应特性的负荷聚合簇。在此基础上，构建基于双层动态博弈的优化模型，该模型不仅能够对不同负荷簇的特征进行精细化响应与调度，还能够模拟VPP运营商与CS之间的策略互动及利益均衡过程。该方法在过度简化的同质化调度与管理复杂度高的个体单独调度之间取得了有效平衡。

基于实测负荷数据的结果验证了所提差异化调度策略的有效性。研究结果表明，通过选择最优的聚类粒度，VPP能够实现总运营成本的最小化。值得注意的是，研究同时揭示了过度细化的聚类划分并不能保证成本最优，反而会导致求解维度急剧增加，从而降低该方法在实际大规模应用中的可扩展性与实用性。此外，本研究的分析进一步证实，实时成本对日前负荷预测的准确性具有高度敏感性。预测误差会通过市场偏差惩罚机制直接转化为经济损失，并对系统稳定性构成潜在威胁，凸显了精确预测在VPP稳定运行中的关键作用。

为进一步增强所设计调度策略的鲁棒性，未来的研究方向将聚焦于随机优化理论与日前调度模型的融入，以能够内生性对冲预测不确定性的调度计划。另外，将开发自适应的实时控制算法，使VPP能够动态地响应和处理未预料到的调度偏差，从而显著提升其在复杂市场环境下的运行韧性与自主调节水平。

参考文献

[1] 中国自然资源保护协会, 中国电动汽车百人会. 电动汽车充电基础设施建设与运营的优化解决方案——以上海为例[R]. 北京, 2023.

[2] 张金良, 赵乐. 计及需求响应的虚拟电厂风险量化优化模型[J]. 能源与气候变化, 2025, 1(2): 286–296.

[3] 王杨洋, 茆美琴, 杨铖, 等. 面向多场景辅助服务的大规模电动汽车聚合可调度容量建模[J]. 电力系统自动化, 2024, 48(7): 103–115.

[4] 王晛, 张华君, 张少华. 风电和电动汽车组成虚拟电厂参与电力市场的博弈模型[J]. 电力系统自动化, 2019, 43(3): 155–162.

[5] Rouzbahani H M, Karimipour H, Lei L. A review on virtual power plant for energy management[J]. Sustainable Energy Technologies and Assessments, 2021, 47: 101370.

[6] Alabi T M, Lu L, Yang Z Y. Improved hybrid inexact optimal scheduling of virtual powerplant (VPP) for zero-carbon multi-energy system (ZCMES) incorporating Electric Vehicle (EV) multi-flexible approach[J]. Journal of Cleaner Production, 2021, 326: 129294.

[7] Ogunkunle O, Ahmed N A. A review of global current scenario of biodiesel adoption and combustion in vehicular diesel engines [J]. Energy Reports, 2019, 5: 1560–1579.

[8] 张高, 王旭, 蒋传文. 基于主从博弈的含电动汽车虚拟电厂协调调度[J]. 电力系统自动化, 2018, 42(11): 48–55.

[9] Sheidaei F, Ahmarinejad A. Multi-stage stochastic framework for energy management of virtual power plants considering electric vehicles and demand response programs[J]. International Journal of Electrical Power & Energy Systems, 2020, 120: 106047.

[10] 张亚朋, 穆云飞, 贾宏杰, 等. 电动汽车虚拟电厂的多时间尺度响应能力评估模型[J]. 电力系统自动化, 2019, 43(12): 94–103.

[11] Wei C Y, Xu J, Liao S Y, et al. A bi-level scheduling model for virtual power plants with aggregated thermostatically controlled loads and renewable energy[J]. Applied Energy, 2018, 224: 659–670.

[12] Chen Y, Niu Y G, Du M, et al. A two-stage robust optimization model for a virtual power plant considering responsiveness-based electric vehicle aggregation [J]. Journal of Cleaner Production, 2023, 405: 136690.

[13] 程明, 张新燕, 王志磊, 等. 考虑接入电动汽车充电站的虚拟电厂低碳经济调度[J]. 科学技术与工程, 2024, 24(19): 8115–8126.

[14] Ju L W, Yin Z, Lu X L, et al. A Tri-dimensional Equilibrium-based stochastic optimal dispatching model for a novel virtual power plant incorporating carbon Capture, Power-to-Gas and electric vehicle aggregator[J]. Applied Energy, 2022, 324: 119776.

[15] Fan S, Liu J, Wu Q, et al. Optimal coordination of virtual power plant with photovoltaics and electric vehicles: A temporally coupled distributed online algorithm[J]. Applied Energy, 2020, 277: 115583.

[16] 莫理莉, 兰峻焜, 周亮, 等. 虚拟电厂下灵活资源多时间尺度调频控制[J]. 电力系统自动化, 2024, 48(18): 76–86.

[17] Tian Z Y, Wang Z, Chong D T, et al. Coordinated control strategy assessment of a virtual power plant based on electric public transportation[J]. Journal of Energy Storage, 2023, 59: 106380.

[18] Feng B, Liu Z P, Huang G, et al. Robust federated deep reinforcement learning for optimal control in multiple virtual power plants with electric vehicles[J]. Applied Energy, 2023, 349: 121615.

[19] Zhou B, Zhang K, Chan K W, et al. Optimal coordination of electric vehicles for virtual power plants with dynamic communication spectrum allocation[J]. IEEE Transactions on Industrial Informatics, 2021, 17(1): 450–462.

[20] Cui J S, Wu J M, Wu C Y, et al. Electric vehicles embedded virtual power plants dispatch mechanism design considering charging efficiencies[J]. Applied Energy, 2023, 352: 121984.

[21] Ahmad F, Khalid M, Panigrahi B K. Development in energy storage system for electric transportation: A comprehensive review [J]. Journal of Energy Storage, 2021, 43: 103153.

[22] Prasanna U R, Singh A K, Rajashekara K. Novel bidirectional single-phase single-stage isolated AC–DC converter with PFC for charging of electric vehicles [J]. IEEE Transactions on Transportation Electrification, 2017, 3(3): 536–544.

[23] Ghanbari-Ghalehjoughi M, Taghizad-Tavana K, Nojavan S. Resilient operation of the renewable energy and battery energy storages based smart distribution grid considering physical-cyber-attacks[J]. Journal of Energy Storage, 2023, 62: 106950.

[24] 涂闯, 谢雨含, 王晶. 基于多主体建模城市私家车换电站运行策略优化研究[J]. 能源与气候变化, 2025, 1(3): 438–455.

[25] Wang H, Jia Y W, Shi M G, et al. A mutually beneficial operation framework for virtual power plants and electric vehicle charging stations[J]. IEEE Transactions on Smart Grid, 2023, 14(6): 4634–4648.

[26] Behi B, Arefi A, Jennings P, et al. Advanced monitoring and control system for virtual power plants for enabling customer engagement and market participation[J]. Energies, 2021, 14(4): 1113.

[27] Wang J N, Guo C L, Yu C S, et al. Virtual power plant containing electric vehicles scheduling strategies based on deep reinforcement learning[J]. Electric Power Systems Research, 2022, 205: 107714.

[28] 牛文娟, 李扬, 王蓓蓓. 考虑不确定性的需求响应虚拟电厂建模[J]. 中国电机工程学报, 2014, 34(22): 3630-3637.

[29] 邓靖微, 李华强, 温丰瑞, 等. 计及虚拟电厂市场交易的主动配电网两阶段优化调度[J]. 电力建设, 2021, 42(9): 22–31.

[30] Richard R, Cao H, Wachowicz M. EVStationSIM: An end-to-end platform to identify and interpret similar clustering patterns of EV charging stations across multiple time slices[J]. Applied Energy, 2022, 322: 119491.

[31] Liu W J, Qi D L, Wen F S. Intraday residential demand response scheme based on peer-to-peer energy trading[J]. IEEE Transactions on Industrial Informatics, 2020, 16(3): 1823–1835.

[32] Rajabi A, Eskandari M, Ghadi M J, et al. A comparative study of clustering techniques for electrical load pattern segmentation[J]. Renewable and Sustainable Energy Reviews, 2020, 120: 109628.

[33] Zhang B D, Du Y, Chen X Y, et al. A novel adaptive penalty mechanism for Peer-to-Peer energy trading[J]. Applied Energy, 2022, 327: 120125.