异质性用户行为下电动汽车充电的随机动态定价：斯塔克尔伯格博弈框架

Yongqi Zhang[a]、Dong Ngoduy[a, *]、Li Duan[b]、Mingchang Zhu[a, c]、Zhuo Chen[a]

[a]莫纳什大学土木与环境工程系，澳大利亚墨尔本[b]华中科技大学土木与水利工程学院，中国武汉[c]同济大学道路与交通工程重点实验室，教育部，中国上海

arXiv:2601.13571v1 [cs.GT] 20 Jan 2026

摘要

电动汽车（EV）的快速增长给充电站运营商（CSO）带来了复杂的时空需求管理挑战，而需求失衡、行为异质性和系统不确定性又加剧了这些挑战。传统动态定价模型依赖确定性的电动汽车—充电站配对和网络均衡假设，往往过度简化用户行为，且缺乏可扩展性。本研究提出了一种随机且考虑行为异质性的动态定价框架，并将其建模为双层斯塔克尔伯格博弈。上层通过优化时变定价来最大化系统整体效用；下层则采用多项Logit（MNL）选择模型刻画分散式电动汽车用户，并纳入价格敏感度、电池老化、风险态度和网络出行成本，同时明确避免设置网络均衡约束，以提高可扩展性。拥堵效应通过排队论近似来表示等待时间和拒绝概率。为高效求解所得的大规模时变优化问题，同时保留领导者—跟随者结构，本研究采用一种滚动时域求解方法，将动态概率灵敏度分析引导的交叉熵方法（PSA-CEM）与逐次平均法（MSA）相结合。在墨尔本克莱顿开展的一项真实案例研究涵盖22个充电站（19个快充站和3个2级充电站），验证了该框架的有效性。仿真结果表明，与固定定价和分时定价相比，所提出的动态定价机制显著降低了排队惩罚，提高了电动汽车用户效用，并提升了整体系统性能。该框架能够适应充电站异质性和需求波动，为电动汽车充电的战略与运营管理提供了一种稳健且可扩展的工具。通过整合动态定价、随机用户选择和拥堵感知建模，该方法能够实现大规模、自适应的电动汽车充电优化，同时兼顾现实性与计算效率。关键词：电动汽车、动态充电定价、斯塔克尔伯格博弈、异质性、随机性

1. 引言

电动汽车（EV）在环境友好性、能源效率和维护需求低等方面，相较于传统车辆具有显著优势。近年来，随着人们日益重视可持续发展，许多国家通过补贴和税收激励积极推动电动汽车普及。与此同时，城市和农村地区的充电站（CS）布局不断完善，电动汽车及其充电基础设施也迅速发展。截至2024年底，全球道路上行驶的电动汽车总数已超过5800万辆，全球已安装约545万个公共充电桩（国际能源署，2025）。电动汽车充电需求的迅猛增长给充电系统的规划和运营带来了巨大挑战。然而，这一扩张趋势也带来了新的挑战。

首先，电动汽车保有量持续增长，其速度已超过新建充电站的建设速度（Afirev，2022）。其次，合理的充电站空间配置对电动汽车生态系统的可持续发展至关重要，但许多现有充电站的布局仍不理想，或分布缺乏科学性（Feng 等，2023）。更重要的是，当前面向电动汽车的充电定价策略需要更智能、更具自适应性的机制，以平衡充电站运营商（CSO）的盈利能力与电动汽车用户的福利，从而确保对充电需求进行合理调节（Cui 等，2023）。充电站的位置、容量和定价策略会显著影响电动汽车用户的充电选择，进而影响充电站运营商的定价决策。在需求不确定的情况下，这种相互作用往往会导致供需失衡和系统效率下降（Kazemtarghi 等，2024；Ben Gharbia 等，2023；Patel 等，2022；Wang 等，2025b；Amilia 等，2022）。例如，一些充电站可能出现严重拥堵，排队等待的电动汽车很多，而另一些充电站则利用不足，导致电网负荷失衡，并降低充电站运营商的盈利能力。因此，有效的充电定价机制对于引导电动汽车前往拥堵程度较低的充电站并实现资源的最优配置至关重要。

因此，建立需求驱动的动态定价机制已成为当务之急（Ali等人，2023）。现有的基于斯塔克尔伯格博弈的模型考虑了价格弹性和出行距离等因素，但往往忽视实际交通路线的影响（Lee

*通讯作者：Dong Ngoduy，电子邮箱：Dong.Ngoduy@monash.edu

等人，2019）。其他研究采用多智能体强化学习或随机优化框架，但要么缺乏明确的电动汽车-充电站吸引力模型闭式表达，要么未能充分刻画排队拥堵效应（Lu等人，2022）。在交通运输研究领域，学者们常采用双层优化模型来耦合交通系统与电力系统（Zhou等人，2021；Tran等人，2021b；Song等人，2025）。在此类框架中，上层旨在最大化整体系统福利，而下层则寻求用户均衡或系统最优交通分配。尽管这些模型能够详细揭示驾驶者的路径选择和网络拥堵情况，但对于大规模系统而言，它们计算量大且难以求解（Mi等人，2023；Yu等人，2021）。

不同于道路拥堵是由城市交通网络中所有车辆之间的相互作用引起的，充电站拥堵主要表现为充电服务过程中的过长等待时间。这种排队主要影响充电服务的质量，进而影响电动汽车用户获得的效用，同时也会影响站级运营效率（Grigorev等人，2021；Tran等人，2021a）。

此外，充电站排队主要由电动汽车的充电需求和充电基础设施的服务能力驱动，而不是由全市交通状况所决定。因此，本研究聚焦于城市尺度下电动汽车-充电站匹配机制和动态定价策略的优化，而不对一般交通拥堵进行显式建模。

为以可处理的方式应对大规模城市网络中的这些挑战，我们采用了如（Zhou等人，2021；Tran等人，2021b；Song等人，2025）所示的双层优化框架。具体而言，在我们的框架中，上层通过同时考虑充电站和电动汽车收益，旨在最大化整体系统效用；而下层则在随机且异质的出行条件下，最小化由排队溢出造成的电动汽车损失。

为降低计算复杂度并便于开展大规模分析，我们采用简化的充电需求和服务排队表示来建模下层交通网络。这种表示能够捕捉电动汽车到达与充电站容量之间的关键交互，而无需显式模拟全市范围内的交通流。该近似方法能够高效评估下层结果，同时保持上层优化的准确性。

综上所述，我们对相关文献的科学贡献如下。

1. 我们全面刻画了在充电站选择过程中因不完全信息和感知偏差而产生的电动汽车随机效用，同时明确考虑了电动汽车和充电站的异质性。

2. 我们构建了一个基于斯塔克尔伯格博弈的动态定价框架，其中上层政府主管机构确定时变价格，以最大化系统整体效用；下层电动汽车用户则在随机且异质的出行和拥堵状况下，以概率方式进行充电站选择，从而形成随机选择均衡，同时考虑容量约束和潜在的充电站过载问题。

3. 我们提出一种滚动时域启发式算法，以刻画决策过程的随机性和时变特性。数值实验表明，该方法能够高效地找到高质量解，为规划人员提供了一种实用工具，以纳入现实的运营考量。

本文结构如下：第二节回顾用于动态定价策略的双层优化问题，并指出研究空白。第三节介绍我们的方法论，以及针对所提优化问题的求解算法。第四节给出数值实验。

2. 文献综述

2.1. 电动汽车—充电站动态定价问题

作为减碳策略的重要组成部分，电动汽车已受到学术界和产业界的广泛关注（Song 等，2025）。随着电动汽车市场渗透率迅速提高，通过优化充电定价策略引导用户行为已成为核心研究课题（Gupta 和 Bhatnagar，2023）。然而，电动汽车保有量激增也带来了重大挑战，尤其是无序充电行为会导致充电站拥堵和电网过载（Bayram 等，2015；Chen 等，2024）。动态定价根据实时供需状况调整充电价格，已被广泛认为是缓解这些问题的有效机制（Saharan 等，2020）。

现有关于电动汽车充电动态定价的研究，大体可分为三种建模范式：集中式优化、分布式或协同优化，以及以博弈论模型为代表的混合方法（Amjad 等，2018）。

集中式方法为整个系统建立单一优化问题，可实现全局最优解，但对于大规模网络而言，往往会变得计算上难以处理（Wang 等，2021；Amjad 等，2018）。相比之下，分布式方法将问题分解

到多个主体（例如，单个充电站或电动汽车）中，使每个主体能够在与其他主体协调的同时进行本地决策，以实现系统级目标；这类框架可扩展性更强且能保护隐私，但需要有效协调（Qin 和 Zhang，2011；Amjad 等，2018；Popiolek 等，2023）。混合方法通常基于斯塔克尔伯格博弈等博弈论模型，将集中式控制与分布式决策相结合：领导者（例如，充电运营商）设定价格或政策，跟随者（例如，电动汽车用户或充电站）做出最优响应（Sheng 等，2021；Hu 等，2023）。代表性研究包括：针对交通运营商和电力运营商不同目标进行建模的多领导者斯塔克尔伯格博弈（Sheng 等，2021）、分析私人充电基础设施对公共市场影响的三阶段框架（Hu 等，2021），以及涉及政府、平台和私人所有者的三级博弈结构，用于补贴设计（Wang 等，2025a）。

尽管取得了成功，基于斯塔克尔伯格博弈的双层模型仍面临重大的建模与计算挑战。由于上层问题隐式依赖下层均衡，因此往往具有非凸、不可微的特性；而每次迭代都要反复计算用户均衡，导致计算成本呈指数级增长，限制了模型在大规模应用中的可扩展性。此外，大多数研究依赖确定性假设——假设用户完全理性且充电需求已知——但现实世界中的行为会因信息不完全、感知偏差和需求不确定性而呈现随机性与异质性。为解决这些问题，研究者探索了多种计算方法。数学规划已广泛应用于单阶段和多阶段定价问题，但随机优化等方法往往忽略排队延迟等关键因素，而排队延迟对于捕捉拥堵与用户选择之间的反馈至关重要（Kazemtarghi等人，2024）。滚动时域控制方法（如模型预测控制（MPC））将这些模型拓展至在线应用（Zheng等人，2019），但通常只针对单一的期望情景进行优化，因此难以明确捕捉随机变异性和不确定性传播。对于大规模或高度非线性问题，研究者采用启发式算法（如遗传算法、粒子群优化）来近似求解斯塔克尔伯格均衡（Tran等人，2021b、2023；Yin和Zhang，2024），但这类方法通常只能得到局部最优解，且不具备收敛保证。近年来，深度强化学习（DRL）已成为一种数据驱动的替代方法，无需显式解析建模即可推导出自适应的斯塔克尔伯格策略（Lu等人，2022），但通常无法以闭式形式解释如何将电动汽车分配至各充电站。

总之，尽管已有显著进展，现有研究仍存在若干关键局限，包括计算复杂度高、缺乏全局最优性保证，以及对不确定性和用户行为异质性的刻画不足。

2.2. 电动汽车充电与定价模型中的随机性层级

电动汽车充电与定价系统中的随机性存在于多个层级，反映了用户行为、外部环境和系统动态的复杂性与不确定性。从建模角度来看，现有研究大致可分为三种具有代表性的随机性表征层级：行为层、基于场景（外部）的层级，以及过程级随机性。

在微观层面，行为随机性刻画了用户的有限理性和异质性感知。通常通过离散选择公式来建模，例如带有感知误差的Logit模型（Soares 等人，2017），用于描述电动汽车用户在选择充电站时的不完全信息和概率决策。

在中观层面，基于场景的随机性（也称为外部环境随机性）利用有限数量的概率场景来表示外生不确定性，例如可再生能源发电、电价和电动汽车充电需求。具有代表性的研究在纯电动汽车（BEV）需求、光伏（PV）输出和调频信号不确定的情况下优化动态定价，以实现稳健的日前运行（Wu 和 Sioshansi，2019），或纳入对电动汽车到达率、充电功率和能源需求的预设不确定性（Kazemtarghi 等人，2024）。通过针对系统的多个概率实现进行优化，这些模型可实现期望最优或风险规避最优，确保定价策略在不同的环境和市场条件下仍接近最优（Elkholy 等人，2026）。

在宏观层面，过程随机性刻画了系统状态在随机过程噪声驱动下的时间演化，通常应用于随机动态规划（SDP）或马尔可夫决策过程（MDP）框架。与不确定性预先设定且保持静态的基于情景的模型不同，过程级随机性强调在不断演变的不确定性下进行序贯决策（Luo 等人，2018；Zanvettor 等人，2022）。随机性会随时间逐步显现，从而能够针对实时扰动，对动态定价、储能和电网交互实施自适应控制。这类框架通过嵌入时间耦合和递归优化结构，有效扩展了基于情景的模型

（例如，贝尔曼递归），从而更真实地描述动态市场和系统的响应。总的来说，这三个层面的随机性表征共同描述了动态定价系统的内在不确定性结构——从个体用户选择的随机性，到外部环境波动，再到随时间演变的过程动态。综合这些维度，有助于全面理解随机建模如何提升电动汽车充电与定价优化的鲁棒性、自适应能力和现实性。

2.3 电动汽车充电与定价模型中的异质性层级

在电动交通系统的建模与优化中，异质性体现在多个维度，反映了参与者的多样性以及现实系统中交互关系的复杂性。

首先，在车辆层面，研究人员通常会考虑不同类型电动汽车在能源效率、行驶里程和电池容量方面的差异。这些因素会直接影响路径选择和充电需求，进而影响系统内的能源分配和出行均衡（Mrkos and Basmadjian，2022；Elkholy et al.，2026）。

其次，在基础设施层面，学者研究了不同类型充电站的异质性。例如，不同功率等级的充电器（标准、快速和超快速）在投资成本和服务效率方面存在显著差异，这会影响充电站布局和最优投资决策。研究表明，引入多种充电器类型可以提升模型性能；然而，快速充电器的高成本往往会限制可安装充电站的总数，而增设超快速充电器未必能显著提高系统效率（Parkand Lee，2024；Kullmanetal.，2021）。

第三，在运营商层面，一些研究综合考虑了异构车队和非同质充电设施。例如，Çalık 等人（2021）通过同时对车辆类型、充电设施和部分充电行为的差异进行建模，研究了电动汽车选址—路径问题（EV-LRP）。他们提出了一种两阶段 Benders 分解算法，能够在现实的运营场景下高效求解该问题，并为异构电动汽车物流系统提供了方法论和管理方面的见解。

第四，在用户层面，异质性体现在收入和时间价值（VOT）的差异上。Zheng和Geroliminis（2020）将基于收入和时间价值的异质性纳入拥堵定价框架，以明确刻画不同用户群体对

收费的差异化反应。通过采用基于基尼指数的出行价值分布对样本群体进行建模，他们证明，基于出行价值的差异化定价能够显著提升异质性出行者之间的公平性，同时保持接近系统最优的效率。

最后，在多智能体交互层面，近期研究已将异质性扩展至复杂智能系统。Mao等人（2024）提出了一种异质性多智能体超图注意力演员-评论家（HMA-HGAAC）框架，用于捕捉电动汽车与换电站（BSSs）在状态空间、目标和决策逻辑方面的固有差异。这使得每类主体都能在统一的学习框架内进行独立但协调的决策，从而显著提升系统协作能力和全局最优性。类似地，Zhang等人（2022）从地理分布、用户需求、定价策略和能源接入等方面对充电站运营商之间的异质性进行了建模，实现了更加个性化和精细化的动态定价与调度策略。

总而言之，异质性已成为电动交通系统优化中的关键建模要素。其跨越车辆、设施、车队、用户和智能主体等多个层面的表现形式，不仅增强了模型的现实性和表征能力，也为未来在公平性、效率和协同优化方面的研究奠定了基础。然而，值得注意的是，在动态电动汽车充电定价模型中，同时纳入车辆与设施异质性的研究相对较少，尤其是在联合考虑行为随机模型组成部分的情况下。

2.4. 研究空白

尽管电动汽车动态定价问题及其在随机性和异质性建模方面的扩展已得到广泛研究，但从建模和方法论角度来看，仍存在一些关键的研究空白。

首先，在动态充电定价建模层面，尽管斯塔克尔伯格博弈已成为电动汽车-充电站配对和动态定价问题的主流框架，但现有模型通常依赖简化假设。大多数研究将上层设定为单一充电运营商或监管者，而下层仅关注电动汽车用户的理性均衡响应，忽略了价格信号、时空出行模式与排队动态之间的跨层反馈。此外，为了确保计算可行性，许多模型采用确定性或静态形式，无法捕捉动态定价调整中固有的路径依赖和时间耦合。从计算角度来看，传统的双层

规划和启发式算法可以为小规模或中等规模问题求得可行解，但在大规模、多智能体或多阶段系统中，往往面临沉重的计算负担和收敛不稳定问题。尽管交叉熵方法（CEM）在解决复杂、随机和多阶段优化问题方面已展现出显著优势，尤其凭借对决策空间的系统性探索，在大规模组合优化场景中表现突出，但随着问题规模扩大，其计算成本可能很高。因此，开发具有良好泛化能力、更高效且易于解释的求解方法，仍是一项有待解决的研究挑战。

其次，在随机建模层面，既有研究主要关注外生的、基于情景的不确定性（如可再生能源发电、电价或充电需求），或过程层面的随机演化。然而，对于电动汽车用户有限理性和感知偏差所导致的行为随机性，研究关注仍然不足。由于本研究的下层模型聚焦于电动汽车个体在充电站选择中的决策，因此将行为随机性视为主要随机维度。不同于以往确定性用户均衡假设，这一视角明确承认用户在价格和拥堵状况不确定时会做出概率性的、不完美的决策，从而为上层动态定价优化提供更真实的行为基础。

最后，在异质性建模层面，尽管现有研究已引入车辆、设施、用户和主体之间的异质性，但在随机动态定价框架下，仍缺少能够同时纳入车辆和设施异质性的模型。在大多数情况下，异质性与随机性被分开处理：异质性模型假设行为是确定性的，而随机模型通常依赖同质主体。这种分离限制了动态定价框架在真实电动出行系统中的表征能力和行为真实性。因此，未来研究应致力于建立一种集成范式，在层级结构中同时捕捉多源异质性和行为随机性，从而实现更稳健、公平且自适应的定价决策。

鉴于这些局限性，本研究提出了一种面向电动汽车—充电站系统的新型随机异质性 Stackelberg 动态定价框架。该框架在下层显式建模行为随机性，以刻画电动汽车充电选择中的有限理性和感知异质性，同时将车辆和设施层面的异质性纳入上层定价设计。这种统一表述不仅提升了对

用户响应和市场动态的可解释性，还有助于构建更高效、公平、低碳的电动出行系统。

3. 方法论

本节介绍系统模型及相应的求解方法，包括三个关键组成部分，如图 1 所示。首先，提出一种新颖的随机动态用户选择均衡模型，该模型将充电站吸引力模型与排队论相结合，以刻画电动汽车用户的理性充电行为以及充电站之间的竞争。其次，以序贯方式构建双层斯塔克尔伯格博弈框架及其相关约束条件。第三，开发一种采用滚动时域方案的动态定价优化模型，以求解斯塔克尔伯格博弈，并明确考虑用户异质性和需求随机性。后续各节所用符号汇总于表1。

表1：符号汇总

符号	说明
集合与索引	
i	充电站（CS）索引
j	电动汽车（EV）索引
t	时间索引
N_s	充电站总数
N_h	时段（小时）总数
ECA$_j(t)$	电动汽车 j 在时间 t的服务范围（可到达的充电站）
$\widetilde{\mathrm{ECA}}$	考虑风险和电池老化后调整的 ECA
电动汽车和充电参数	
$Attr_{ij}(t)$	时间 t充电站 i对电动汽车 j 的吸引力
$p_{ij}(t)$	电动汽车 j 在时间 t选择充电站 i 的概率
$x_{ij}(t)$	指标：如果电动汽车 j 在 t选择充电站 i，则为 1，否则为 0
θ	多项Logit模型中的敏感度参数
$\varepsilon_{ij}(t)$	感知误差项（服从极值分布）
$T_{ij}^{tra}(t)$	电动汽车 j 到充电站 i的行驶时间
$T_R^{tra}(t)$	基于荷电状态的最大可达里程

下页续

表1——接上页

符号	说明
$\widetilde{T_R^{tra}}(t)$	考虑风险和电池老化后的调整后的可达范围
$s_j^{ini}(t)$	电动汽车 j 在 t 时刻的初始荷电状态
$Q_{j,\max}$	电动汽车 j 的电池容量
φ_j	电动汽车 j 的能耗率（km/kWh）
α_{risk}	电动汽车 j 的风险规避系数
T	车辆年龄（年）
β	电池衰减率
$T_{ij}^c(t)$	电动汽车 j 在充电站 i的剩余充电时间
$T^{c,\text{ini}}_{ij}(t)$	本次访问前的初始充电时间
$Q_{ij}^{\triangle}(t)$	j 期间充电站 i 的电动汽车 t 充电需求
$f_i(\cdot)$	充电站 i 的充电函数
充电站运营与排队	
$P_i(t)$	充电站 i 在时间 t 的充电功率（kW）
$\lambda_i(t)$	充电站 i 的电动汽车到达率
μ_i	充电站 i 的服务率
$S_i(t)$	充电站 i 在时间 t 的充电桩数量
c_i	系统总容量（充电 + 等待位）
$\pi_{i,d}(t)$	充电站 i 系统中有 d 辆电动汽车的概率
$\pi_{i,0}(t)$	充电站 i 空闲（无电动汽车）的概率
$L_i(\lambda_i(t))$	充电站 i的期望队列长度
$W_i(\lambda_i(t))$	充电站 i 的期望等待时间
$T_{ij}^q(t)$	电动汽车 j 在充电站 i 的期望排队时间
$N_i^{\text{rejected}}(t)$	充电站 i 的电动汽车期望拒绝数量
定价与经济学	
$Pr_i(t)$	充电站 i在时间 t设定的充电价格
$\nu_i(t)$	充电站 i的电网电价
$\nu_{i,\max}(t)$	充电站 i 的最高允许价格
R_{CS}	所有充电站的总收入
U_j	电动汽车 j 的效用

续见下页

表1——接上页

符号	说明
U_{EV}	所有电动汽车的总效用
η_{rejected}	拒绝电动汽车的惩罚
PI	系统总性能指标
ω	目标函数中收入与效用的权重
ν	电动汽车驾驶员的时间价值
κ	电力消耗的边际效益
$C_{ij}^{total}(t)$	从电动汽车 j 到充电站 i的基于时间的总成本
求解算法（交叉熵法和 *PSA*）	
$F(\boldsymbol{\theta})$	优化问题的目标函数
$\boldsymbol{\theta}$	决策变量向量（动态价格）
Ω	决策变量的可行域
$f(\boldsymbol{\theta};\ \boldsymbol{\phi})$	抽样分布的概率密度函数
$\boldsymbol{\phi}^{(t)}$	迭代 t 时抽样分布的参数
N	交叉熵法（CEM）中的随机样本种群规模
q	用于筛选最佳样本的精英比例
$\hat{c}^{(t)}$	迭代 t 时的精英阈值
β (交叉熵法（CEM）)	交叉熵法（CEM）中参数更新的平滑参数
ϵ	收敛容差阈值
D_{KL}	Kullback-Leibler 散度（相对熵）
$\hat{f}_{(\ell)}(s)$	第 ℓ 次迭代时性能指标的估计概率密度函数
$\hat{g}_k^{(\ell)}(s)$	变量 k 固定在其精英均值时的条件概率密度函数
$D_k^{(\ell)}$	变量 k 在第 ℓ次迭代时的概率敏感性指数
τ	选择活跃（敏感）变量的阈值
$\mathcal{A}^{(\ell)}$	第 ℓ次迭代时活跃（敏感）决策变量的集合
$\bar{\theta}_k^{(\ell)}$	变量 k的精英样本均值
$s_k^{(\ell)}$	变量 k的精英样本标准差
$\boldsymbol{\mu}^{(\ell)}$	第 ℓ次迭代时抽样分布的均值向量
$\boldsymbol{\sigma}^{(\ell)}$	第 ℓ次迭代时抽样分布的标准差向量

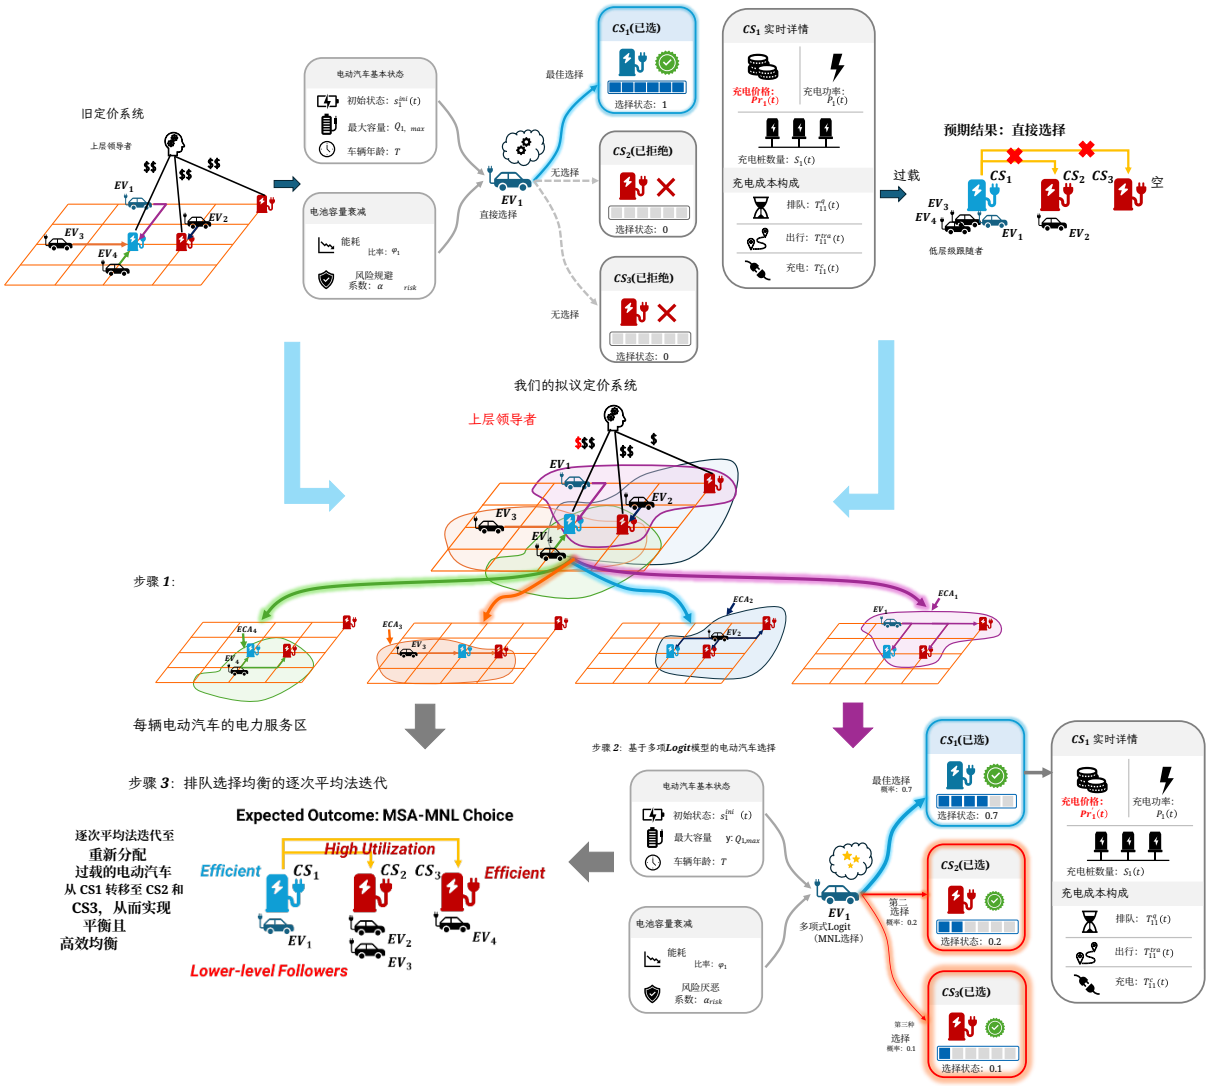


图1：总　　体框架：针对随机电动汽车充电站选址及动态定价的双层斯塔克尔伯格优化　　n
选址及　　动态定价。

3.1 充电站吸引力的形成与电动汽车选择模型

首先建立一组基本假设，为理论分析奠定基础。随后，逐步构建充电站吸引力函数、基于多项Logit的电动汽车选择模型，以及二者与排队动态的结合，以描述电动汽车用户的充电站选择行为。接下来，介绍特定电动汽车可到达的充电站、道路行驶时间，以及充电时长和能源需求；这些都是评估总充电成本的关键组成部分。总体而言，所提出的模型明确考虑了电动汽车用户决策过程中的异质性和随机性。

3.1.1. 假设

假设 1。 尽管多种因素可能影响电动汽车充电决策，例如社会人口特征和备选方案特定属性，本研究聚焦于充电站的运营属性，以构建一个在定量分析上易于处理的电动汽车充电行为模型。

假设 2. 假设每辆电动汽车都能获取充电系统的实时运行状态信息，包括已占用的充电插头数量以及预计驶入的车辆数量。

假设 3. 每辆电动汽车仅根据决策时刻的实时需求状况进行一次站点选择。作出决定后，电动汽车在驶往已选站点的途中不会更改目的地。

假设 4. 电动汽车独立作出决策，仅考虑自身状况和偏好。它们不会观察或预测其他电动汽车的实时决策，这会引入感知不确定性，并使各充电站的效用评估具有随机性。

3.1.2. 充电站吸引力建模

为鼓励电动汽车使用拥堵程度较低的充电站，从而提高整体系统效率，了解充电站选择背后的决策机制至关重要。零售引力法则阐释了消费者需求如何分布于各个竞争中心，可为这一建模提供有益的理论基础。类比而言，距离更近且服务属性更优的充电站——例如充电插头可用性更高、价格更低、等待时间更短——更有可能被电动汽车选中（Kazemtarghi 等，2024）。

基于假设 1，我们提出一种增强型吸引力函数，将充电功率、动态定价和充电总成本等其他重要影响因素纳入其中：

$$Attr_{ij}(t) = \frac{S_i(t) \cdot P_i(t)}{Pr_i(t) \left(C_{ij}^{total}(t)\right)^2} \tag{1}$$

这里， $Attr_{ij}(t)$ 表示充电站 i 对电动汽车 j 随时间变化的吸引力； $S_i(t)$ 表示时段 t 内充电站 i 可用充电桩的数量； $P_i(t)$ 表示可用充电功率（kW）。 $Pr_i(t)$ 表示动态充电价格（$/kWh），而 $C_{ij}^{total}(t)$ 表示

电动汽车 j 出行至充电站 i 所产生的基于时间的总成本，定义如下：

$$C_{ij}^{total}(t) = T_{ij}^{tra}(t) + T_{ij}^{q}(t) + T_{ij}^{c}(t) \tag{2}$$

其中， T_{ij}^{tra}（t）、 T_{ij}^{q}（t）和 T_{ij}^{c}（t）分别表示行驶时间、排队时间和充电时间，均以小时（h）为单位。

3.1.3. 通过多项*Logit*对电动汽车选择进行建模

为了更好地捕捉不完全信息和有限理性对电动汽车驾驶员决策的影响，我们在充电站吸引力函数中引入随机感知误差项。假设感知误差服从Gumbel分布。基于电动汽车 j对充电站 i 的感知吸引力，选择概率通过多项Logit（MNL）模型表示为：

$$p_{ij}(t) = \frac{\exp\left(\theta \cdot Attr_{ij}(t) + \varepsilon_{ij}(t)\right)}{\sum\limits_{k \in \mathrm{ECA}_j(t)} \exp\left(\theta \cdot Attr_{kj}(t) + \varepsilon_{kj}(t)\right)} \tag{3}$$

其中， $\theta \cdot Attr_{ij}$（t）表示确定性效用， ε_{ij}（t）表示随机感知误差。仅考虑满足 T_{ij}^{tra}（t） $\leq T_R^{tra}t$的充电站作为可达充电站，其中， T_R^{tra}（t）表示最大可达行驶时间。可达充电站集合构成电动汽车 j的电动汽车服务范围（ECA）：

$$\mathrm{ECA}_j(t) = \{k \mid T_{kj}^{tra}(t) \leq T_R^{tra}(t)\} \tag{4}$$

因此，电动汽车 j 在时间 t 选择充电站 i 的概率可以表示为一次伯努利试验：

$$\mathbb{P}\left(x_{ij}(t) = 1\right) = p_{ij}(t) \tag{5}$$

对所有电动汽车求和，可得时间 t 到达充电站 i的预期数量：

$$\mathbb{E}[\lambda_i(t)] = \sum_j p_{ij}(t) \tag{6}$$

其中， $\lambda_i(t)$ 是电动汽车在充电站 i 的到达率。因此，总体到达过程由各个独立的伯努利试验之和得出。

3.1.4. 排队动态建模

为刻画拥堵效应对电动汽车充电体验的影响，每个充电站的服务过程均采用 M/M/s/c 排队系统建模。在这一记法中，第一个“M”表示电动汽车到达服从比率为 $\lambda_i(t)$的泊松过程，而第二个“M”表示服务时间呈指数分布，平均比率为 μ_i。此外， s表示启用的充电桩数量 $S_i(t)$，而 c 表示有限的系统容量 c_i，包括充电空间和等候空间（Shafiei 和 Ghasemi-Marzbali, 2023）。

如果电动汽车到达充电站时所有充电桩都已被占用，则必须在队列中等待。充电站的充电过程可表示为马尔可夫链，其中系统状态由系统内电动汽车的数量（包括正在充电和等待的车辆）定义，记为 d。由于任一时刻的电动汽车数量仅取决于前一系统状态，因此满足马尔可夫性质。当队列达到最大长度时，其长度受充电站容量 c_i 限制，因此总共有 $c_i + 1$ 种可能状态。

在每个离散时段 t 内，到达过程服从均值率为 λ_i（t）的泊松分布，表示到达充电站充电的电动汽车的期望数量。服务率 μ_i 在概念上与正在工作的充电桩相关，而非严格等于充电时长的倒数。尽管正在工作的充电桩数量 S_i（t）可能会因前一时段仍在等待的车辆而随时间动态变化，但假设参数 λ_i（t）、 μ_i 和 S_i（t）在每个时间步内保持不变。作出这一假设是因为，从电动汽车驾驶员的角度来看，无法准确预测其他用户的实时充电需求。相反，每辆电动汽车会根据已知的充电功率和充电站当前的占用情况估算其期望等待时间。因此，服务率近似为一个与充电功率相关的常数，而不是其瞬时实时值。随后可以递归计算马尔可夫链的平稳概率分布，该分布表示在时间 t，充电站 i 处于状态 d 的概率，计算如下：

$$\pi_{i,d}(t) = \begin{cases} \dfrac{1}{d!}\left(\dfrac{\lambda_i(t)}{\mu_i}\right)^d \pi_{i,0}(t), & d \le S_i(t) \\ \dfrac{1}{S_i(t)!}\left(\dfrac{1}{S_i(t)}\right)^{d-S_i(t)}\left(\dfrac{\lambda_i(t)}{\mu_i}\right)^d \pi_{i,0}(t), & S_i(t) \le d \le c_i \end{cases} \tag{7}$$

其中，$\pi_{i,\ 0}$ 为初始条件，所有系统状态的概率满足以下约束：

$$\sum_{d=0}^{c_i} \pi_{i,d}(t) = 1 \tag{8}$$

因此，$\pi_{i,\ 0}(t)$ 表示充电站 i 队列中没有车辆的概率，可计算如下：

$$\pi_{i,0}(t) = \left[\sum_{d=0}^{S_i(t)-1} \frac{1}{d!} \left(\frac{\lambda_i(t)}{\mu_i} \right)^d + \sum_{d=S_i(t)}^{c_i} \frac{1}{S_i(t)!} \left(\frac{1}{S_i(t)} \right)^{d-S_i(t)} \left(\frac{\lambda_i(t)}{\mu_i} \right)^d \right]^{-1} \tag{9}$$

因此，可以直接建立到达率与期望队列长度之间的关系：

$$L_i(\lambda_i(t)) = \sum_{d=S_i(t)+1}^{c_i} (d - S_i(t)) \pi_{i,d}(t) \tag{10}$$

然后，根据利特尔法则，可以按如下方式计算电动汽车在充电站 i 的平均等待时间：

$$T_{ij}^q(t) = W_i(\lambda_i(t)) = \frac{L_i(\lambda_i(t))}{\lambda_i(t)(1 - \pi_{i,c_i}(t))} \tag{11}$$

此外，如果预计到达特定充电站的电动汽车数量远超该站的容量，那么尽管这些车辆不会被纳入正式队列来计算平均等待时间，但仍需将其视为拥堵导致的充电系统损失来源。因此，被拒绝的电动汽车应表示为：

$$N_i^{rejected}(t) = \lambda_i(t) \cdot \pi_{i,c_i}(t) \tag{12}$$

3.1.5. 可达性与行驶时间建模

在计算每辆电动汽车的平均等待时间之前，需要确定其离开充电站的时间。此时，应明确充电事件开始时的充电初始阶段（荷电状态，SOC）这一概念。电动汽车的出发时间与其初始荷电状态密切相关，初始荷电状态决定了车辆的最大可达里程。对于每辆电动汽车 j，选择范围必须小于其在时段 t当前荷电状态所对应的最大里程，以确保第一阶段的充电站选择 C_i 仍然可行。

因此， $T_R^{tra}(t)$ 定义为电动汽车 j 在时间 t 的最大可达里程：

$$T_R^{tra}(t) = \frac{s_j^{ini}(t) \cdot Q_{j,\max}}{\varphi_j}, \tag{13}$$

其中， $s_j^{ini}(t)$表示电动汽车 j的初始荷电状态， $Q_{j,\ \max}$ 表示其最大电池容量，而φ_j 表示能耗率（kWh/km），该比率可能因车辆类型而异

类型。借鉴地理学中常用的服务范围概念（Zhang等人，2024；Chang等人，2024），本文引入电力服务区（ECA），用于表示特定电动汽车基于其当前荷电状态可到达的充电站集合 j。据此，ECA可定义为：

$$\mathrm{ECA}(s_j^{ini}(t)) = \{i \mid T_{ij}^{tra}(t) \le T_R^{tra}(t)\} \tag{14}$$

其中，$T_{ij}^{tra}(t)$ 表示电动汽车当前位置到充电站i的所需出行距离，$T_R^{tra}(t)$ 表示式（13）中定义的最大可达里程。

$$\mathrm{ECA}(s_j^{ini}(t)) = \{i \mid T_{ij}^{tra}(t) \le T_R^{tra}(t)\} \tag{15}$$

为反映真实的驾驶状况，我们纳入风险厌恶与电池退化（RABD）模型：

$$\widetilde{T_R^{tra}}(t) = T_R^{tra}(t) \times (1 - \alpha_{risk}) \times e^{-\beta T} \tag{16}$$

其中，α_{risk} 表示驾驶员的风险规避程度，β 表示电池退化比率。调整后的 ECA 定义如下：

$$\widetilde{ECA}(s_j^{ini}(t)) = \{i \mid T_{ij}^{tra}(t) \le \widetilde{T_R^{tra}}(t)\} \tag{17}$$

3.1.6. 充电时长与需求建模

在前一小节中，初始荷电状态 $s_j^{ini}(t)$ 反映了到达前的部分充电情况，并与初始充电时长的关系如下：

$$s_j^{ini}(t) = \frac{f_i(T_{ij}^{c,ini}(t))}{Q_{j,\max}}. \tag{18}$$

由于充电时间与获得的荷电状态之间呈非线性关系，完成充电最后阶段（高荷电状态区域）所需的时间通常远长于初始阶段（低荷电状态区域）（Wang 等，2016）。鉴于本研究提出的动态定价模型基于按时间计费机制，因此有必要准确刻画三级充电站的这种非线性荷电状态—时间关系，以进一步描述建模中的异质性。

因此，充电函数 $f_i(\cdot)$ 遵循（Yu

等人，2021）提出的分层模型，并使用电池容量为 75 kWh 的特斯拉 Model 3（长续航版）进行校准：

$$f_i(T) = \begin{cases} f_{L2}(T) = \varphi \cdot T, & C_i \in \mathbb{C}^{L2}, \\ f_{L3}(T) = 1 + ae^{-bT} - (1+a)e^{-cT}, & C_i \in \mathbb{C}^{L3}, \end{cases} \tag{19}$$

其中 T r 表示充电时间（分钟），而 $f_i(T) \in [0,1]$ 表示归一化荷电状态 .

对于2级（L2）充电，荷电状态近似线性增加，对应于约20kW的恒定充电功率。给定电池容量为75 kWh，恒定充电速率确定为 $\varphi = 1/225$，这意味着约225分钟即可充满电。

对于3级（L3）直流快速充电，采用参数为 a =2.096, $b = 0.0749$ 和 $c = 0.0552$ 的双指数模型。该非线性模型准确地捕捉了典型的充电特性：初始充电速率较高，随着电池接近满容量，充电速率逐渐降低，以减少电池劣化。拟合后的L3模型满足边界条件 $f_{L3}(0) = 0$，以及 li $\mathrm{m}_{T\to\infty} f_{L3}(T) = 1$。

因此，车辆 j 在充电站 i 的实际充电时长可表示为：

$$T_{ij}^{c}(t) = f_i^{-1}(Q_j^{\max}) - T_{ij}^{c,ini}(t), \tag{20}$$

其中， $f_i^{-1}(\cdot)$ 表示充电曲线 $f_i(\cdot)$ 的反函数。

相应地，整个充电过程中的总充电需求可表示为：

$$Q_{ij}^{\Delta}(t) = f_i\big(T_{ij}^{c,ini}(t) + T_{ij}^{c}(t)\big) - s_j^{ini}(t)\, Q_{j,\max}. \tag{21}$$

3.2. 博弈构建

所提出的框架对公共充电网络中电动汽车与充电站之间的动态交互和优化过程进行了建模。其主要目标是通过动态定价机制缓解拥堵引起的排队损失，并提高资源分配效率。该系统被设计为斯塔克尔伯格博弈，其中政府主管机构作为领导者设定时变价格，而电动汽车用户作为跟随者，通过选择自己偏好的充电站作出响应。通过这种领导者—跟随者交互，该框架旨在实现系统级性能提升，在运营商收入与用户福利之间取得平衡。

3.2.1. 下层：电动汽车充电选择与排队损失最小化

在斯塔克尔伯格博弈的下层，电动汽车用户被建模为分散式跟随者，他们根据各自的充电需求、感知的出行时间、预期等待时间以及时变充电价格，独立选择充电站。由于有限理性和不完全信息，电动汽车充电选择采用概率型多项Logit模型表示，该模型能够刻画用户决策中的随机感知误差。

被拒绝的电动汽车与排队损失。 每个充电站的服务能力均有限，在需求高峰期，拥堵可能导致部分电动汽车被拒绝。为刻画拥堵引起的服务失效，充电站 i 被拒绝的电动汽车期望数量近似表示为

$$N_i^{\text{rejected}}(t) = \lambda_i(t)\,\pi_i^{\text{rej}}(t), \tag{22}$$

其中， $\lambda_i(t)$ 表示充电站 i 的电动汽车到达率， $\pi_i^{\text{rej}}(t)$ 表示因可用充电容量不足而被拒绝的到达电动汽车的概率，该概率根据站级排队状况进行近似。

单辆电动汽车效用。 对于由充电站 i 成功服务的每辆电动汽车 j ，其感知效用定义为

$$U_j = \sum_t \sum_i \left[\kappa Q_{ij}^{\Delta}(t) - T_{ij}^{c}(t)\,Pr_i(t) - T_{ij}^{q}(t)\,\nu\right] p_{ij}(t), \tag{23}$$

其中， $Q_{ij}^{\Delta}(t)$ 表示充入的电量， $T_{ij}^{c}(t)$ 表示充电时长， $Pr_i(t)$ 表示充电站 i 的充电价格， $T_{ij}^{q}(t)$ 表示期望等待时间， ν 表示单位等待时间惩罚， $p_{ij}(t)$ 表示电动汽车 j 在时段 t 选择充电站 i 的基于多项Logit模型的概率。电动汽车总体效用。 系统层面的电动汽车总体效用定义为

$$U_{\text{EV}} = \sum_j U_j - \sum_t \sum_i N_i^{\text{rejected}}(t)\,\eta_{\text{rejected}}, \tag{24}$$

其中，第二项使用固定惩罚系数 η_{rejected} 对被拒绝的电动汽车进行惩罚，以反映因拥堵导致充电需求未得到满足所带来的负效用。

3.2.2. 上层：面向系统性能优化的动态定价

在上层，政府主管机构作为领导者，随时间动态调整各充电站的充电价格，以影响下层的电动汽车充电行为。通过这些定价决策，该机构间接塑造充电网络中各站点层面的需求分布和拥堵模式。

为平衡经济激励与服务质量，上层目标将充电站收入和电动汽车用户效用纳入统一的系统性能指标。

充电站收入。 充电站收入主要来自电力销售，并受动态价格和电动汽车充电需求的共同影响。总收入可表示为

$$R_{\mathrm{CS}} = \sum_{t} \sum_{i} \sum_{j} Q_{ij}^{\Delta}(t) \left(Pr_i(t) - \nu_i(t) \right) p_{ij}(t), \tag{25}$$

w其中， $\nu_i(t)$ 表示充电站 i 的批发购电价格。

系统性能指标。 总体系统目标表示为运营商收入与电动汽车用户总效用的加权和：

$$PI = \omega R_{\mathrm{CS}} + (1 - \omega) U_{\mathrm{EV}}, \tag{26}$$

其中， $\omega \in [0, 1]$ 表示充电站收入相对于电动汽车用户福利的重要性。根据附录A中的敏感性分析，本文采用均衡设定（$\omega = 0.5$）。

3.2.3. 约束条件

约束条件 1. 充电价格受上限和下限约束，其中下限对应电网电价，上限代表预先设定的最高允许价格：

$$\nu_i(t) \leq Pr_i(t) \leq \nu_{i,max}(t) \tag{27}$$

约束 2。该约束根据公式（*17*）定义，反映了考虑风险规避和电池退化后，特定电动汽车的剩余续航里程受到调整后 *ECA* 的严格限制。

3.3. 博弈求解

正如 Jeroslow (1985) 所阐明的那样，一般双层规划问题属于 NP 难问题，这凸显了我们模型固有的复杂性。为解决所提出的斯塔克尔伯格博弈框架中具有排队动态的 NP 难随机优化问题，我们提出采用特别适用于大规模组合优化的交叉熵法（CEM）（Tran等人，2021b，2023），进行上层动态定价优化，并结合逐次平均法（MSA）开展下层电动汽车充电站均衡分析。具体而言，我们将交叉熵法与动态参数敏感性分析（PSA）机制相结合，以减轻高维定价策略空间带来的计算负担。这种混合方法通过自适应地识别并聚焦于影响最大的站点-时段价格变量，加速上层优化的收敛。

3.3.1. 交叉熵方法

如前所述，基于CEM的方法已在一系列大规模组合优化或连续优化问题中展现出寻找较优解的优势（Tran等人，2021b，2023；Ngoduy和Maher，2013；Zhong等人，2016）。因此，本文提出使用CEM算法求解该动态定价问题，具体可分为两个关键步骤：

1. 根据所选分布随机生成若干组试验参数。 2. 根据每组试验参数对应的目标函数值，按照“重要性抽样”原理更新用于生成随机试验参数的概率分布。

对于一般的优化问题，获得全局最优解可视为一种稀有事件。交叉熵方法（CEM）提供了一个基于蒙特卡洛的框架，用于估计此类稀有事件概率，并将优化过程重新表述为概率学习问题。本文所用CEM的详细推导见附录B。

3.3.2. 概率敏感性分析

然而，队列动态或电动汽车充电网络等随机系统的优化，往往涉及对系统性能产生不确定或相关影响的参数；此外，高维决策空间也可能导致CEM算法收敛缓慢。为应对这些挑战，Zhong等人(2016)提出了一种PSA-CEM框架

该框架基于信息论，用于量化输入参数的变化如何影响模型输出的概率分布（Liu等人，2006），从而为输出变异性提供更通用的度量；此外，该框架将PSA进一步融入CEM抽样程序，以“屏蔽”较小的参数，从而缩小高维决策空间的搜索范围。

PSA 不再采用传统的基于方差的指标（Saltelli 等人，2008），而是开始使用系统性能度量的无条件概率密度函数（PDF）与条件概率密度函数之间的相对熵（即 Kullback-Leibler 散度）。即使分布呈非线性、多峰或重尾特征，这种基于熵的指标也能稳健地度量敏感度。具体而言，给定两个分布，无条件分布f（y）和参数 g（$y|x_i$）固定时的条件分布 x_i，其相对熵表示为：

$$D_{\mathrm{KL}}(g(y|x_i) \,\|\, f(y)) = \int g(y|x_i) \ln \frac{g(y|x_i)}{f(y)} \, dy, \tag{28}$$

其中，较大的 D_{KL} 表明固定 x_i 会使输出概率密度函数产生更大的偏差，因此 x_i 的影响更大。

这种灵活性使基于相对熵的 PSA 能够应用于各种不确定性下的设计场景，例如基于可靠性的设计、稳健设计和效用优化。据称，基于相对熵的 PSA 既可用于设计前阶段，在尚未确定设计方案时进行变量筛选，也可用于最优设计确定后的设计后阶段，以降低不确定性（Liu 等人，2006）。

3.3.3. 动态概率敏感性分析与自适应交叉熵搜索

在Liu等人(2006)提出的基于相对熵的概率敏感性分析及其在Zhong等人(2016)中用于跟驰模型校准的基础上，本研究提出了一种动态概率敏感性分析引导的交叉熵法框架。与以往研究中的静态预处理不同，后者在优化前仅进行一次概率敏感性分析，且整个过程中重要变量集合保持不变；本研究提出的方案则基于最新样本群体，在交叉熵法迭代期间定期更新概率敏感性分析指标。

这种自适应机制使算法能够在线重新评估每个站点-时段价格分量对性能指标的影响，并动态区分敏感决策变量与不敏感决策变量。

令 $\boldsymbol{\theta} \in \mathbb{R}^d$ 表示所有充电站-小时价格组成的堆叠决策向量

$$\boldsymbol{\theta} = \left(p_{11}, \ldots, p_{1N_h}, \ldots, p_{N_s1}, \ldots, p_{N_sN_h}\right)^\top,$$

其中 N_s 为充电站的数量， N_h 为小时周期的数量，因此$d = N_sN_h$。给定价格向量 $\boldsymbol{\theta}$对应的性能指标（目标函数）记为 $F(\boldsymbol{\theta})$，该指标汇总了电动汽车和充电站的效用，定义见第3.2节。

在交叉熵法的第 ℓ 次迭代中，从当前抽样分布 $f^{(\ell)}(\boldsymbol{\theta})$ 中抽取 N 个价格样本 $\{\boldsymbol{\theta}^{(m)}\}_{m=1}^N$，并评估相应的得分 $\{F(m)\}_{m=1}^N$，其中$F(m) = F(\boldsymbol{\theta}^{(m)})$。利用这些样本，我们通过高斯分布近似性能指标，估计其概率密度函数 $\hat{}f^{(\ell)}(f)$。对于每个决策变量 θ_k （即特定充电站在某一小时的价格），我们构造相应的“冻结”样本群体：将 θ_k 固定为其精英均值 $\bar{\theta}_k^{(\ell)}$，同时保持其余分量不变，并由此获得性能指标的相应正态密度估计 $\hat{}g_k^{(\ell)}(f)$。根据上述式（28）， θ_k 在第 ℓ 次迭代时基于相对熵的概率敏感性指数定义如下：

$$D_k^{(\ell)} = \int \hat{g}_k^{(\ell)}(s) \ln \frac{\hat{g}_k^{(\ell)}(s)}{\hat{f}^{(\ell)}(s)} \, \mathrm{d}s, \tag{29}$$

该指标量化了移除 θ_k 中的变异性后性能指标分布的变化。随后，通过引入用户指定的阈值 $\tau > 0$，定义一个仅考虑最敏感决策变量的简化问题，并将第 ℓ 次迭代时的敏感决策变量活跃集定义为

$$\mathcal{A}^{(\ell)} = \left\{ k \in \{1, \ldots, d\} \mid D_k^{(\ell)} > \tau \right\}. \tag{30}$$

仅允许 $\mathcal{A}^{(\ell)}$ 中的变量根据标准 CEM 更新规则进行演化，而其余变量则暂时冻结在其当前均值和方差附近。令 $\boldsymbol{\mu}^{(\ell)}$ 和 $\boldsymbol{\sigma}^{(\ell)}$ 分别表示迭代 ℓ时抽样分布的均值向量和标准差向量，令 $\bar{\boldsymbol{\theta}}^{(\ell)}$ 和 $\boldsymbol{s}^{(\ell)}$ 分别表示在迭代 ℓ时选定的精英集的样本均值和样本标准差。自适应的概率敏感性分析引导的交叉熵法更新按分量表示为：

$$\mu_k^{(\ell+1)} = \begin{cases} \beta \mu_k^{(\ell)} + (1-\beta)\, \bar{\theta}_k^{(\ell)}, & \text{if } k \in \mathcal{A}^{(\ell)}, \\ \mu_k^{(\ell)}, & \text{if } k \notin \mathcal{A}^{(\ell)}, \end{cases} \tag{31}$$

$$\sigma_k^{(\ell+1)} = \begin{cases} \beta\sigma_k^{(\ell)} + (1-\beta)\, s_k^{(\ell)}, & \text{if } k \in \mathcal{A}^{(\ell)}, \\ \sigma_k^{(\ell)}, & \text{if } k \notin \mathcal{A}^{(\ell)}, \end{cases} \tag{32}$$

其中， $\beta \in [0,1]$ 是控制迭代之间更新程度的平滑参数。根据 CEM文献中的实证研究， β 取值在0.4到0.9之间通常可获得令人满意的结果；在本研究中， β 设为0.7。

总体而言，这种自适应“冻结—解冻”策略有效地实现了CEM框架内的在线变量筛选。对于概率敏感度持续较低的决策变量，将其保持在基准值附近；而高度敏感的变量则继续向帕累托最优区域演化。因此，所提出的动态PSA引导的CEM能够更有效地平衡探索与利用，降低高维价格空间中的计算负担，并缓解早熟收敛，从而将Zhong等人 (2016提出的静态PSA-CEM形式扩展到完全自适应的设置。

3.3.4. 混合*CEM-MSA*优化框架

在利用动态PSA-CEM模型求解上层动态定价问题的基础上，整体框架还在下层采用逐次平均法（MSA），以计算电动汽车-充电站选择均衡并捕捉排队动态。

为应对计算挑战和庞大的解空间，我们的框架纳入了三个关键特征：

(1) 滚动时域策略。将整个仿真时域划分为若干逐小时优化窗口，以动态捕捉排队现象和充电行为的时间演化，同时确保计算可行性。

(2) 动态PSA-CEM机制。如第 3.3.3 节和算法 1所述，所提出的动态PSA引导的CEM可在优化过程中自适应地识别关键决策变量。该方法对于大规模组合问题尤其有效，并展现出较强的鲁棒性，在寻求近似全局最优解方面表现出优势（Rubinstein和Kroese，2004年）。

（3）算法结构设计。整体框架借鉴了先前研究的思路，即结合混合元启发式算法与逐次平均法，在随机条件下求解双层优化问题（Tran等人，2021a，b）。在下层，该结构能够有效捕捉信息不完全情况下电动汽车用户的均衡充电决策。

在上层，该结构能够自适应地优化动态定价策略，从而提升系统整体效率和运营稳定性。这些特点共同凸显了将用户均衡建模与上层动态定价优化相结合，在现实出行系统中的实用性和适用性，图2所示的优化流程对此进行了说明。

在滚动时域框架下结合交叉熵法和逐次平均法的详细求解流程见算法1。具体而言，我们采用的样本量为 $N = 1000$ ，并将精英样本比例设为 $\rho = 1\%$。每次迭代均使用平滑率 $\alpha = 0.7$ 更新参数分布。收敛准则定义为：连续两次迭代中，精英样本的最大效用值与最小效用值之间的相对差异均低于预设阈值。

4. 实验结果

4.1. 实验设置

本研究考察了墨尔本克莱顿地区电动汽车（EV）充电基础设施的空间分布和时变需求。充电站数据采集自 www.plugshare.com，充电站分为两类：配备 CCS2连接器的快速充电站（FCS），以及配备 Type 2 或 J-1772连接器的 2级充电站。研究区域共包含 22 个充电站，其中有 19 个快速充电站和 3 个 2级充电站。

交通网络由研究边界内的主要道路路段构成，这些路段作为潜在的电动汽车行驶轨迹，来源于知名的 Openstreetmap 数据集。充电需求的时间分布曲线取自真实的澳大利亚数据集（Islam 和 Nadarajah，2016），呈现出明显的高峰时段（上午 8:00 至下午 5:00）和非高峰时段。如图3所示，充电站的空间分布和小时需求模式构成了仿真环境的基础。

在仿真中，电动汽车最初随机分布在道路网络中；为增强真实性，也可以将其集中分布在需求热点区域。根据预先设定的分布，为车辆分配初始荷电状态（SOC）、电池容量、车辆车龄和驾驶员风险态度。能耗率和充电过程遵循标准电动汽车规格及实证充电行为（Yu 等，2021；Islam 和 Nadarajah，2016），并纳入功率随时间衰减效应。因此，每辆电动汽车所需的充电时长取决于其剩余电池容量以及所选充电站的额定功率。

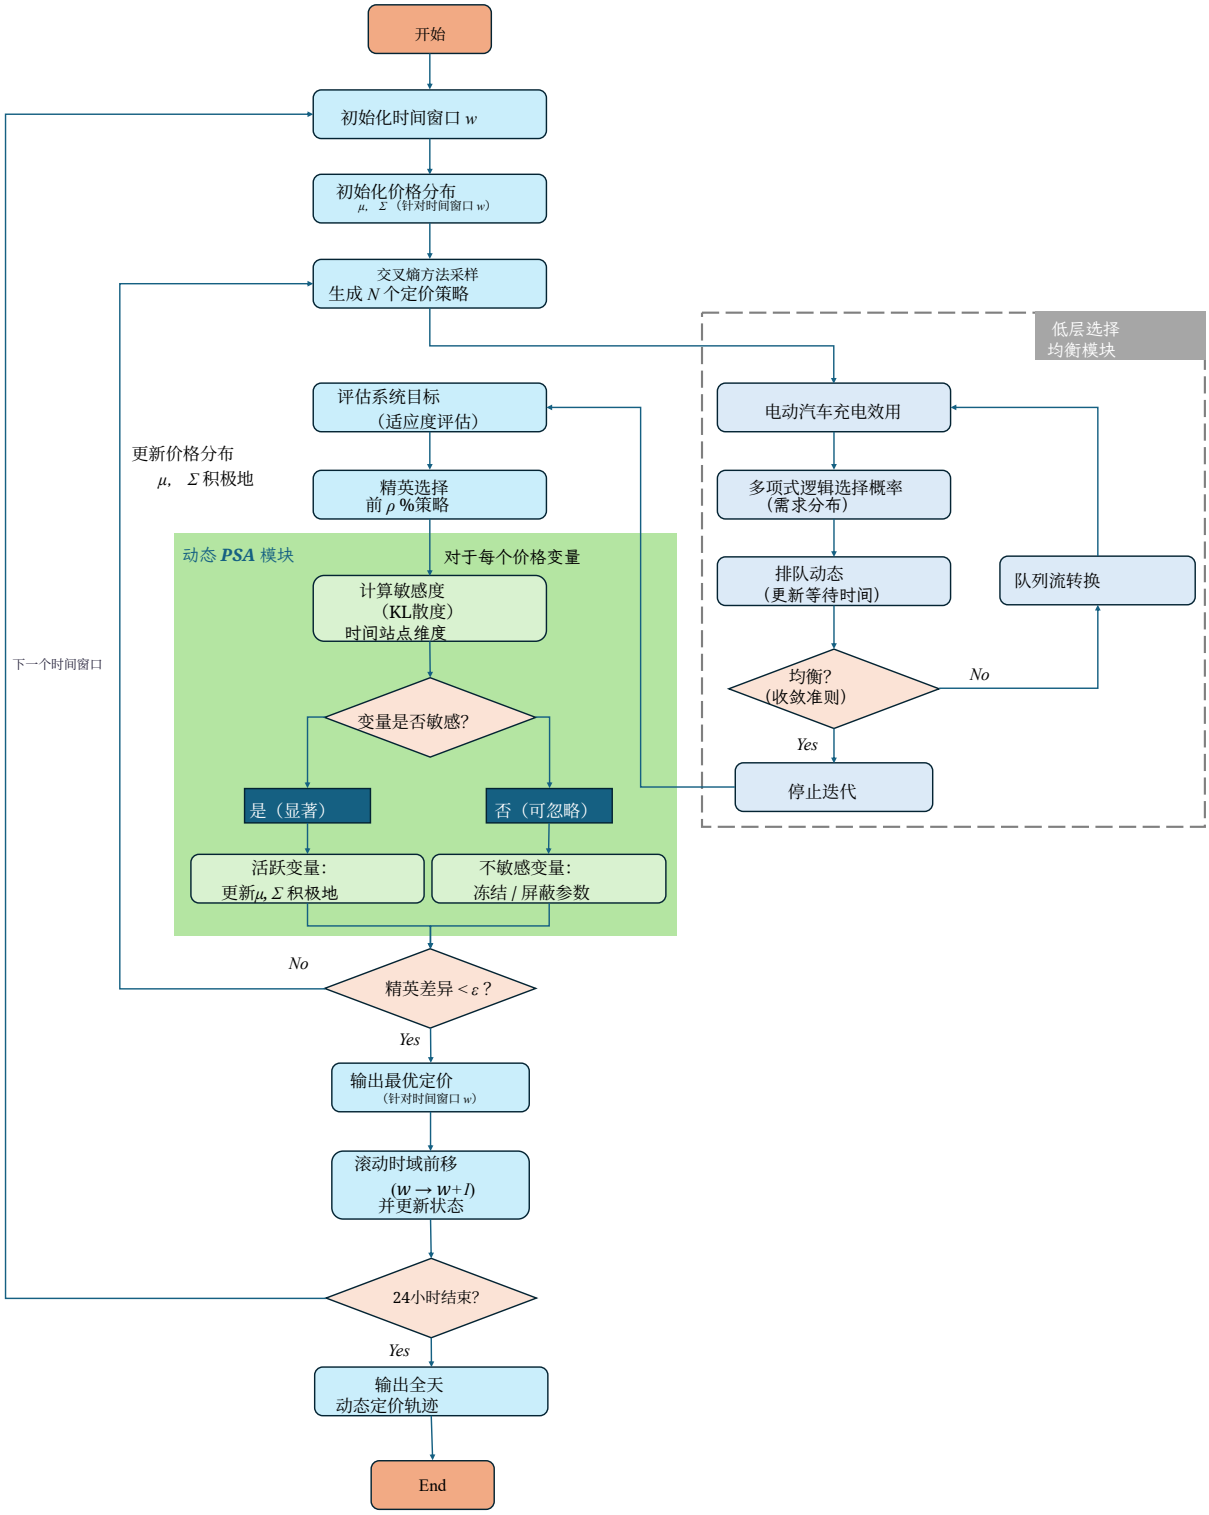


图2：所提出的双层优化框架的整体算法结构。

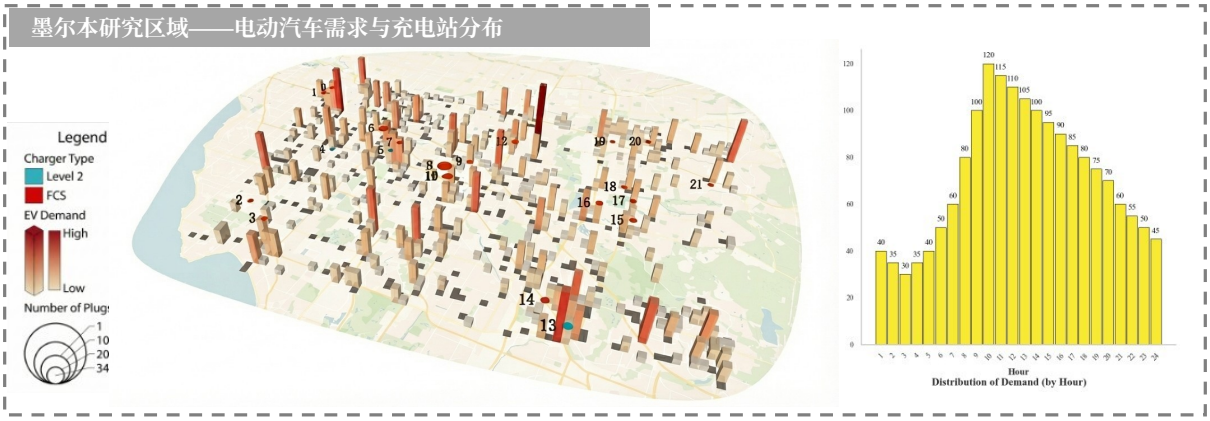


图3：研究区域的时空概况：（左）墨尔本2级充电站和快速充电站（FCS）的空间分布及电动汽车需求热点；（右）电动汽车每小时充电需求曲线。

表2：研究中使用的关键仿真参数和算法参数。

参数	符号	值
电动汽车与经济效用参数		
能耗	φ	5.0 km/kWh
充电满意度因子	κ	1.0 $/kWh
等待时间惩罚（时间价值）	ν	5.0 $/h
系统拒绝惩罚	η_{rejected}	30.0 美元/电动汽车
风险厌恶系数	α_{risk}	$\{0.0, 0.05, 0.15\}$
定价约束		
电网基准价格	$\nu_i(t)$	0.20 美元/kWh
最低价格限制	$Pr_{\min}$	0.20 美元/kWh
最高价格上限	$Pr_{\max}$	0.80 美元/kWh
算法（*PSA-CEM-MSA*）		
滚动时域窗口	H	1 小时
样本量	N	1000
精英比例	ρ	0.05（前 5%）
平滑因子	α	0.7
PSA更新频率	ψ	5次迭代
收敛阈值	ϵ	10^{-3}

仿真中使用的关键系统参数、电动汽车属性和算法超参数汇总于表2。所有实验均使用 Python 3.9 实现，并在一台配备 Intel(R) Ultra 9 185H CPU（2.30 GHz）和 32 GB 内存的高性能计算机上运行。

4.2. 所提算法的收敛性

为验证所提算法的收敛性，我们在一个划分为逐小时优化窗口的24小时仿真时域内考察其性能。收敛行为

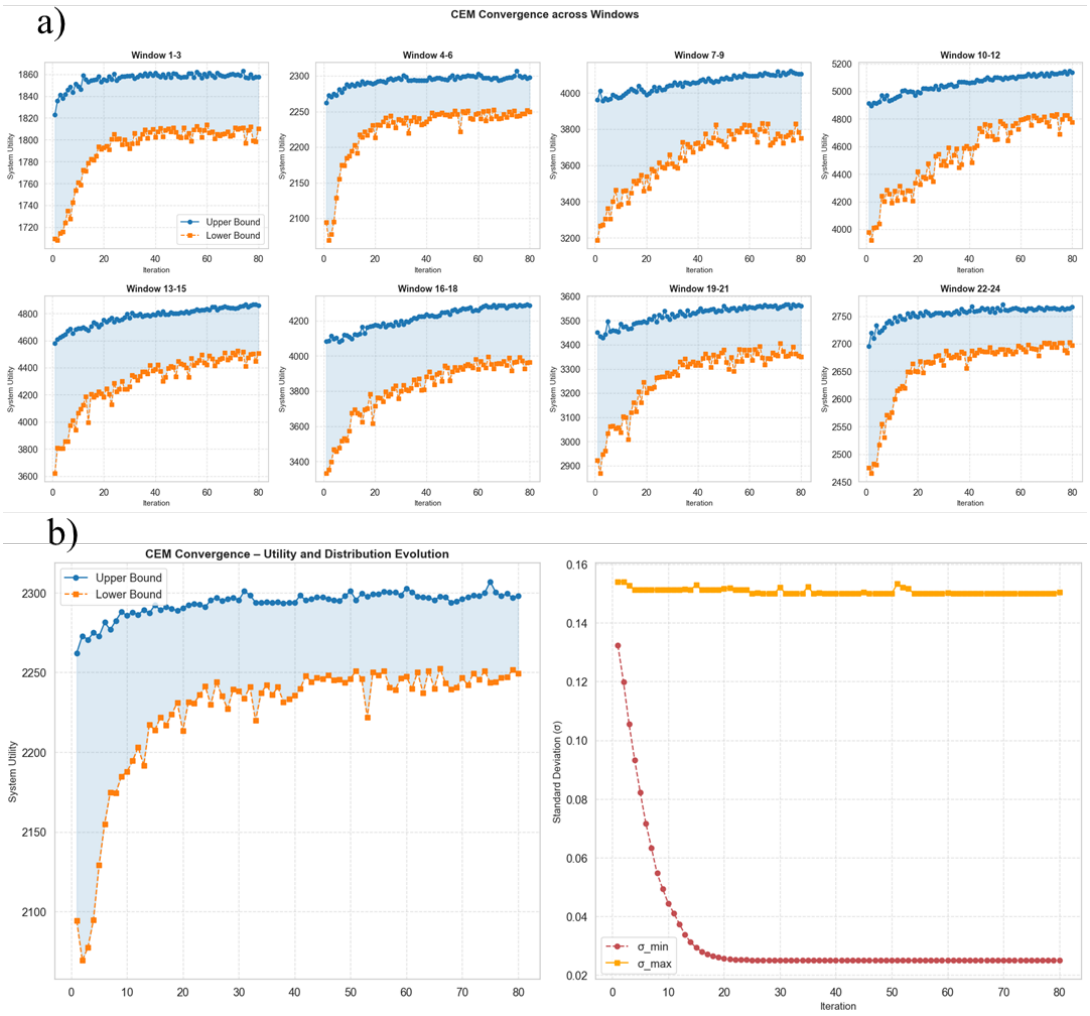


图4：CEM算法的收敛分析。(a) 24个时间窗口内的系统效用界限，凸显算法鲁棒性。(b) 效用和标准差的详细变化（σ），展示搜索空间收缩。

各时间窗口内整体系统效用上下界的4变化如图所示。总体而言，结果呈现出明显的上升收敛趋势，表明所提出的算法在连续迭代过程中持续提升系统性能。值得注意的是，随着迭代进行，上下界之间的差距逐渐缩小，展现了该算法逐步改进定价策略和电动汽车充电站（EV-CS）匹配决策的能力。

在所有时间窗口内，需求相对较低的时段（尤其是一天的开始和结束时），系统效用下界在前30次迭代中迅速上升。相比之下，在需求高峰期（例如上午7:00至下午6:00），收敛过程则更为缓慢。这一现象反映出，在拥堵程度较高时，平衡供需关系更加复杂，通常需要超过60次迭代才能收敛。

为进一步展示所提出的PSA-CEM算法在最优性、鲁棒性和收敛性方面的特征，图4(b) 展示了24小时周期内第二个时间窗口的系统效用及其相关标准差界限（即 $\sigma_{\min}$ 和 $\sigma_{\max}$）的详细变化情况。具体而言， $\sigma_{\max}$ 表示初始探索方差，用于确保候选定价方案具有足够的多样性；而 $\sigma_{\min}$ 则设定了一个下界，以防止早熟收敛。

如图所示，系统效用呈现稳步上升趋势，而有效标准差则逐渐从 $\sigma_{\max}$ 降至 $\sigma_{\min}$。这一变化表明，算法逐渐从全局探索转向局部利用，从而以受控的方式缩小搜索空间。当标准差接近 $\sigma_{\min}$时，定价分布变得高度集中，表明算法已收敛至充电站稳定且近乎最优的定价策略。由 $\sigma_{\min}$ 和 $\sigma_{\max}$ 控制的有界方差机制，确保了需求水平变化时收敛的稳定性和解的稳健性，这也解释了为何在不同时间窗口中观察到的收敛过程平滑而可靠。

此外，为了更直观地展示定价策略的收敛行为，选取8号站作为具有代表性的案例研究。图 5 展示了8号站在24小时周期内充电价格的三维概率密度函数（PDF）的变化。与典型的CEM收敛特性一致，价格分布起初较为宽泛，反映出最优定价存在较大的不确定性。随着迭代的进行，

分布逐渐收窄，并收敛至稳定的定价范围，表明CEM-MSA 算法能够有效确定兼顾充电需求与拥堵效应的最优价格。

尽管所有时间窗口最终都会收敛，但由于需求水平和充电站布局存在差异，不同时段的收敛模式也各不相同。在高峰时段，价格分布先收缩至相对狭窄的区域，随后略微扩宽，最终稳定在最优价格范围内。这一现象反映了高需求、拥堵与定价调整之间复杂的相互作用。相比之下，在非高峰时段，价格分布更直接地收敛至稳定范围，表明在拥堵状况较轻时，最优定价的变异性较低。这些观察结果凸显了所提出算法响应时变需求波动的自适应能力。

最后，从价格幅度的角度来看，三维概率密度函数演变揭示了8号站在24小时周期内清晰但非单调的定价模式。具体而言，充电价格在早些时候处于相对较低水平，随后随着需求上升而上涨，直至第10小时。价格保持在约0.5澳元/千瓦时，直到约第15小时降至0.4澳元/千瓦时；之后短暂下降，并在第16和第17小时再次稳定在约0.5澳元/千瓦时。随后，价格逐渐下降，到当天结束时降至约0.2澳元/千瓦时的最低水平。

重要的是，这种复杂且非单调的定价轨迹——而非简单地单调上升或下降——进一步体现了定价结果的现实性，并凸显了所提出算法在捕捉需求与拥堵之间动态相互作用方面的鲁棒性。

4.3. 随机选择下电动汽车-充电站配对策略的比较分析

本节通过比较三种不同的充电站选择策略，评估所提出优化算法的性能：(1) CEM-DC（直接选择，确定性）；(2) CEM-Standard（不采用逐次平均法的基于多项Logit的随机选择）；(3) CEM-MSA（所提出的多项Logit-逐次平均均衡选择）。该比较重点考察将随机性与逐次平均法（MSA）相结合，对系统整体效用和单个电动汽车决策的影响。

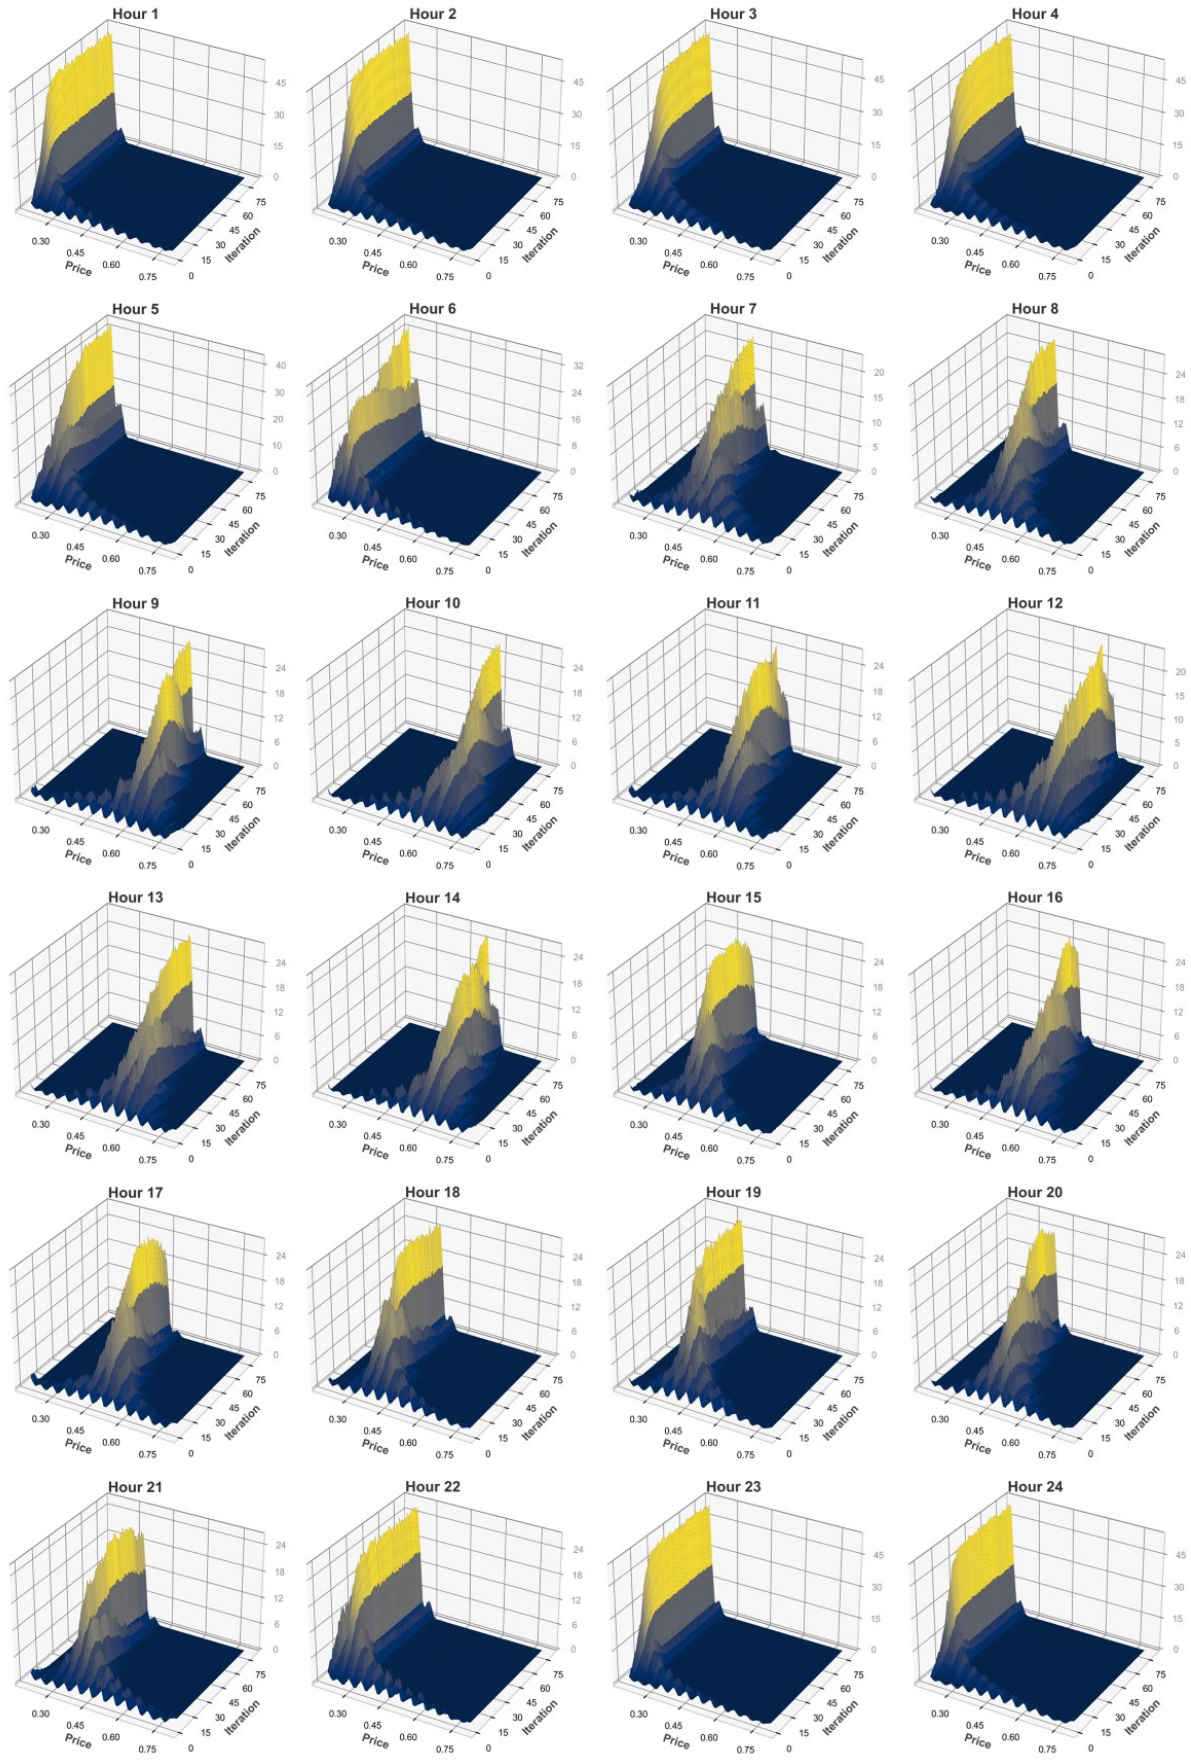


图5：8号站在24小时周期内价格分布的三维概率密度函数演变，展示了价格密度在优化迭代过程中的收敛情况。

4.3.1. 宏观层面分析：系统效用收敛

分析的第一个维度聚焦于不同优化窗口下系统平均效用的收敛情况，如图6所示。

如图所示，不同策略的收敛趋势存在显著差异。CEM-DC策略（橙色线）收敛迅速，但稳定在次优的效用水平。虽然DC在系统拥堵较低的早期窗口（如时间窗口1至3）表现尚可，但由于无法考虑用户随机行为，其系统整体优化潜力受到限制。相反，CEM-Standard策略（绿色线）在未进行均衡的情况下引入了基于MNL的随机性，因此在初始阶段性能最低。这表明，若仅引入随机性而没有平衡需求的机制，初期反而会产生噪声，降低效率。然而，随着后续窗口中系统拥堵加剧，CEM-Standard的表现超过了确定性基线，升至第二位并保持到最后。这一变化凸显了随机性在系统复杂度增加时，缓解确定性选择僵化问题的内在价值。

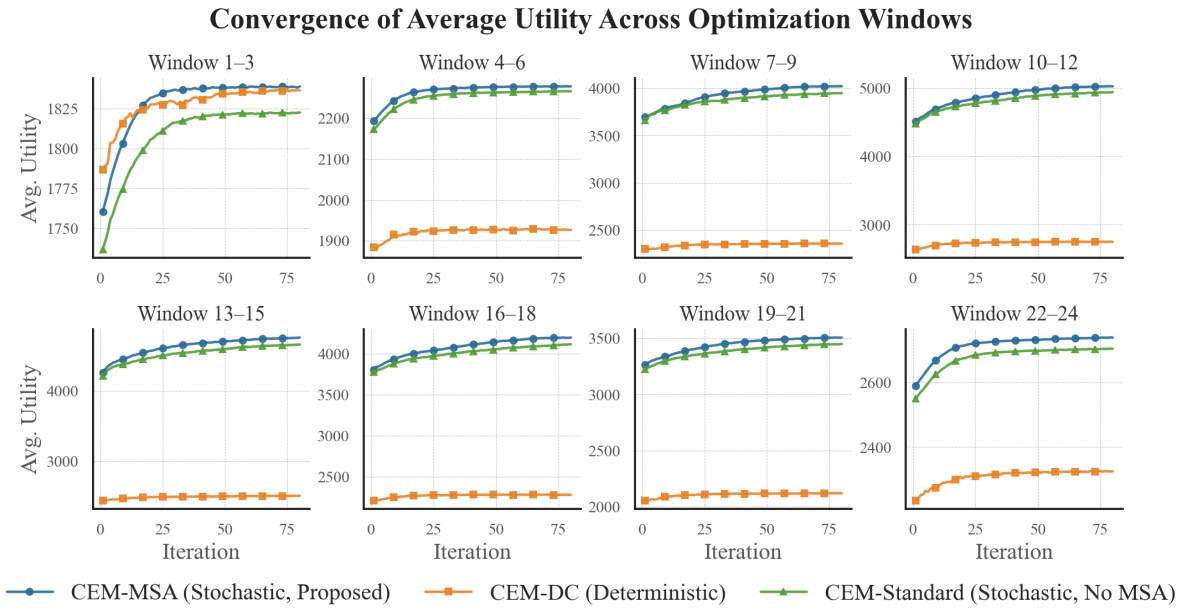


图6：八组优化时间窗口下平均系统效用的收敛情况，对比所提出的 CEM-MSA 与 CEM-DC和CEM-Standard基线。

值得注意的是，所提出的 CEM-MSA（蓝线）在所有时间范围内始终实现最高的平均效用。通过结合电动汽车选择的现实随机性与用于达到均衡的逐次平均法算法，CEM-MSA 有效缓解了拥堵效应。即使在无拥堵情形下，其表现也优于确定性基线，并且随着优化时间窗口的推进，展现出更强的可扩展性。

4.3.2. 微观层面分析：电动汽车选择概率分布

为了解释这些效用增益背后的机制，我们将分析扩展到微观层面的电动汽车选择行为，如图7所示。该图比较了第9小时两辆代表性车辆（EV 370 和 EV 371）的选择概率分布。

在CEM-DC准则下，选择是二元且确定性的。两辆电动汽车都将充电站06视为最优充电站，并以100%的概率选择该站（熵：0.00）。虽然这种方式对个体而言看似高效，但在车队层面汇总后，会导致充电站06严重拥堵。

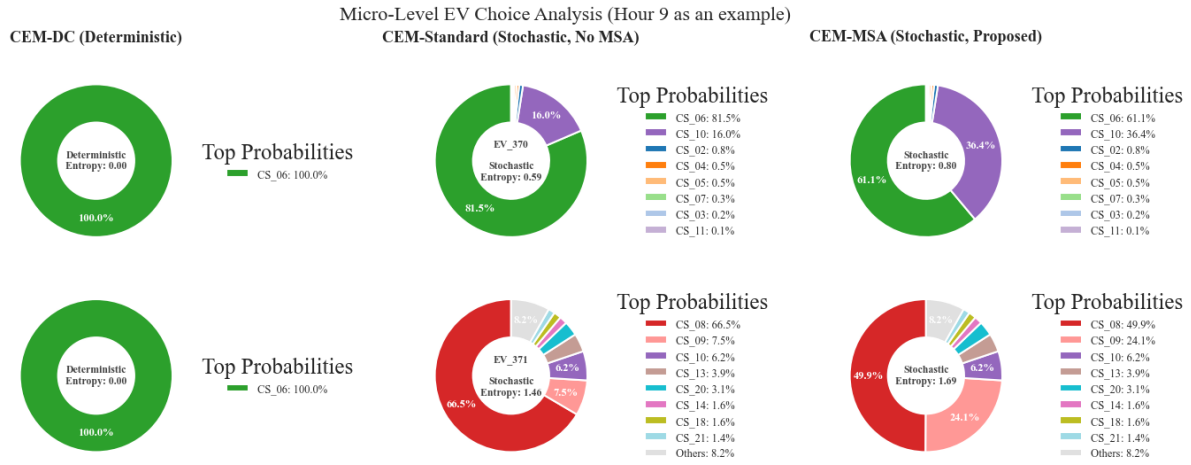


图7：第9小时代表性电动汽车的微观选择分析，对比CEM-DC（确定性）、CEM-Standard（随机）和本文提出的CEM-MSA（采用逐次平均法的随机方法）。

相比之下，随机方法会分散需求。CEM-Standard方法将选择概率分散到较广泛的充电站范围内（例如，EV 371会考虑9个以上的充电站）。虽然这会带来较高的熵（例如，EV 370的熵为0.99），并且比确定性方法更广泛地分散需求，但这种分配仍可能效率低下。这是因为分散仅基于感知误差，缺乏系统级认知（协调），因此形成的是随机而非策略性的分配。

CEM-MSA 策略实现了关键的平衡。如图 7第三列所示，MSA 会调整标准模型得出的概率。例如，对于 EV 370，CEM-MSA 将首选项（充电站06）的主导程度从 81.5%（标准模型）降至 61.1%，同时将相当大的概率（36.4%）转移至次选项（充电站10）。这一转变体现了均衡效应：算法识别出充电站06正变得过度拥堵，并引导部分需求转向虽非最优但利用率较低的充电站。这种重新分配确保电动汽车在首选项拥堵时不会选择该项，从而实现

更优的全局系统最优解。

4.4. 充电站异质性分析

异质性在塑造电动汽车充电系统中的充电需求分布、定价结果和用户感知效用方面发挥着关键作用。本小节基于所提出的 CEM-MSA 框架收敛后的解，对异质性进行考察。具体而言，我们开展事后分析，研究不同的站点层面特征如何影响均衡交通负荷、动态定价策略和电动汽车用户效用，而不在优化过程中引入额外的决策变量。本文考虑了两种主要的异质性来源：影响服务率的充电器类型异质性，以及影响充电需求聚合规模的容量异质性。

4.4.1. 充电器类型异质性

不同类型的充电器为电动汽车用户提供不同的服务率。在实验设置中，我们考虑两种类型的充电器：快速充电站和二级充电器。快速充电站提供更高的充电速度，而二级充电器的服务率较低。图 8。

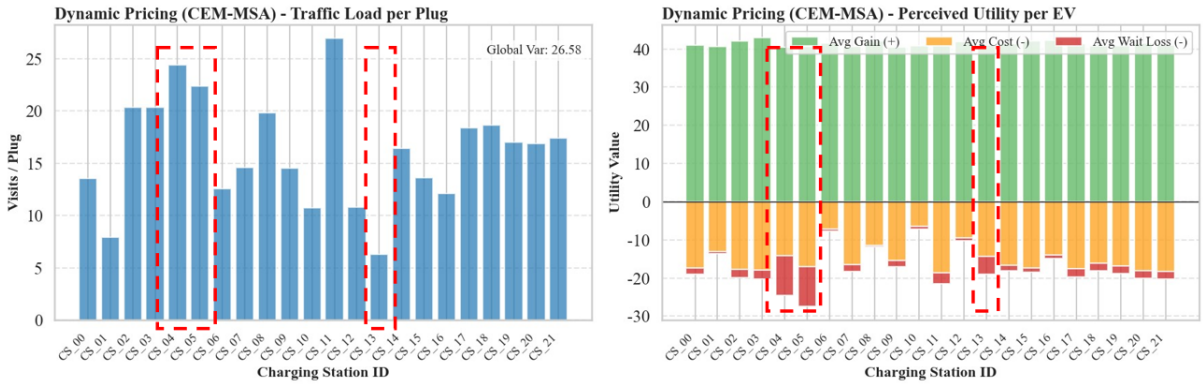


图8：动态定价下的系统性能（CEM-MSA）：（左）各充电站每个充电插头的交通负荷分布；（右）每辆电动汽车的感知效用构成，包括平均收益、电费和等待损失。

图8左侧面板显示了所有充电站的均衡交通负荷（即电动汽车充电需求），其中红框标出的充电站为二级充电器，其余充电站均为快速充电站。从交通负荷的角度来看，现有充电需求主导了拥堵模式。因此，CS 4、CS 5 和 CS 11 的交通负荷最高，而 CS 1 和 CS 13 在所有充电站中需求最低。

相比之下，右侧面板显示，与左侧观察到的交通负荷模式相比，电动汽车的感知效用存在明显差异。电动汽车用户的感知效用由三个部分构成：（i）完成充电过程所获得的正效用；（ii）与购电成本相关的负效用；以及（iii）充电站平均等待时间造成的负效用。平均等待损失这一部分的差异尤为显著。具体而言，除 CS 4、CS 5 和 CS 13 外，大多数充电站的等待损失相对较小，通常介于 -1 至 -3之间。然而，对于这三个二级充电站，等待损失大幅增加，达到约 -5 至 -9之间。

这些结果表明，尽管动态定价能够在一定程度上调节充电需求，但低速充电桩固有的服务率限制不可避免地会导致更长的等待时间，并增加电动汽车用户的负效用。虽然 CS 4 和 CS 5 的高等待损失在一定程度上可归因于其较高的充电需求，但与 CS 11 等其他高需求充电站进行比较后可以发现，充电桩类型的影响更为显著。CS 13 进一步凸显了这一影响：它在所有充电站中的交通负荷属于最低水平之一，但等待损失仍位居第三。总体而言，充电桩类型异质性主要体现为等待时间相关负效用，而非单纯的交通负荷，这凸显了在基于定价的拥堵管理中考虑服务率的重要性。

4.4.2. 容量异质性

接下来，我们考察容量异质性。它主要通过改变充电站可容纳的同时充电需求规模来影响系统性能，而非影响服务率。在本分析中，我们选取容量最大的五个充电站（充电站6、8、10、12和13），并将其与其余所有充电站的平均动态定价策略进行比较。此选取依据是 PSA-CEM 程序中采用的基于 PSA 的敏感性分析：由于定价敏感度较高的因素对定价结果影响更大，因此会优先考虑这些因素。

图 9 展示了该算法根据局部需求条件和充电站特定特征，在空间和时间维度上差异化设定充电价格的能力。在已选充电站中，8号站的容量最大，拥有34个充电插头，位于莫纳什大学校园内。由于白天充电需求旺盛，其定价策略会在白天时段显著提高价格，以平衡峰值需求并防止过度拥堵。

相比之下，地理位置靠近8号站但容量小得多（有12个充电桩）的10号站，会受到8号站的溢出或虹吸效应。因此，该站有意降低日间充电价格，以吸引电动汽车用户并分担部分充电需求，从而缓解8号站的压力。

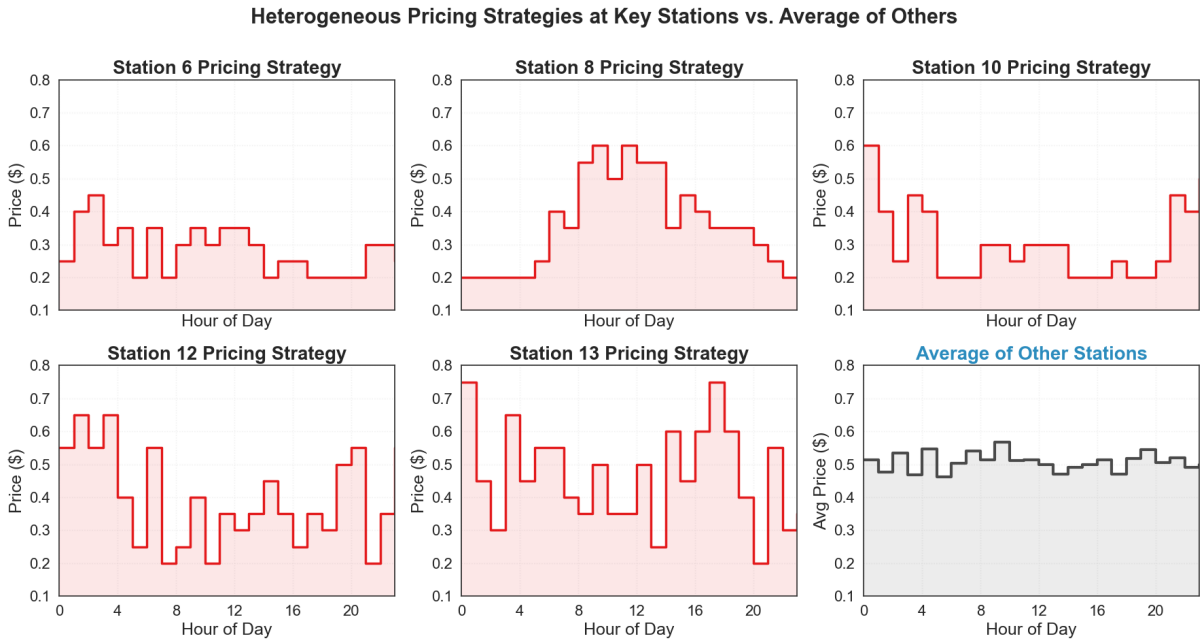


图 9：异质定价策略：已选高容量充电站（6、8、10、12 和 13）与 24小时周期内所有其他充电站的平均价格比较。

位于查德斯通购物中心的 6号站，与其他高容量充电站相比，采用了相对保守的定价策略。一天中的大部分时间，其充电价格都接近下界（约 0.2 美元），仅在深夜（约 22:00 之后）至中午之间不时上调价格。此类价格调整有助于协调本站与周边充电站的充电可用性；周边充电站的价格通常维持在 0.5 美元左右。通过策略性地调整自身价格，6号站调节了对电动汽车用户的相对吸引力，同时在下午和傍晚的购物高峰时段维持较低价格，以吸引前来购物中心的电动汽车消费者。

最后，12号站和13号站都表现出明显的时间价格波动，夜间充电价格通常高于白天价格。这一模式反映出，容量更大的充电站往往承担更大的充电流量负荷，因此需要更强的激励措施，以在时间和空间上重新分配需求，缓解系统整体压力。与12号站相比，13号站始终维持更高的价格，这反映了前文所讨论的充电器类型异质性相互作用。

由于充电速度相对较慢，系统有意抑制过多电动汽车流入13号站，以避免过大的等待损失。因此，13号站主要作为附近快速充电站的补充选项，仅在周边快速充电站出现严重拥堵时吸收溢出需求。

4.5. 斯塔克尔伯格模型下的动态定价：固定定价、分时定价与完全动态定价

最后，我们通过将所提出的动态定价策略与两种常用的基准机制进行比较，评估其在斯塔克尔伯格框架下的有效性：固定定价（传统定价）、分时定价（半动态定价），以及本研究提出的完全动态定价方案。这些机制在时间灵活性以及响应需求变化的能力方面各不相同。图10按小时比较了三种定价方案下的系统性能，而图11则基于主要效用组成部分进行了汇总评估。

4.6. 斯塔克尔伯格模型下的动态定价：固定定价、分时定价与完全动态定价

最后，我们通过将所提出的动态定价策略与两种常用的基准机制进行比较，评估其在斯塔克尔伯格框架下的有效性：固定定价（传统定价）和分时定价（半动态定价）。图10 按小时比较了系统性能，而图11 则基于总效用值进行了汇总评估。

4.6.1. 逐小时性能比较

图 10 展示了24小时周期内系统效用及其组成部分的时间演化。在固定定价下，充电价格保持不变，因此非高峰时段的充电站收入稳定，但无法抑制高峰时段的需求。这导致了严重的拥堵，平均排队惩罚高达670。2 ，电动汽车效用也未达到最优。

分时定价机制通过区分高峰和非高峰费率，在一定程度上缓解了这一问题。该机制将电动汽车平均效用提高至877。7，并将充电站收入提高至1001。7，但其

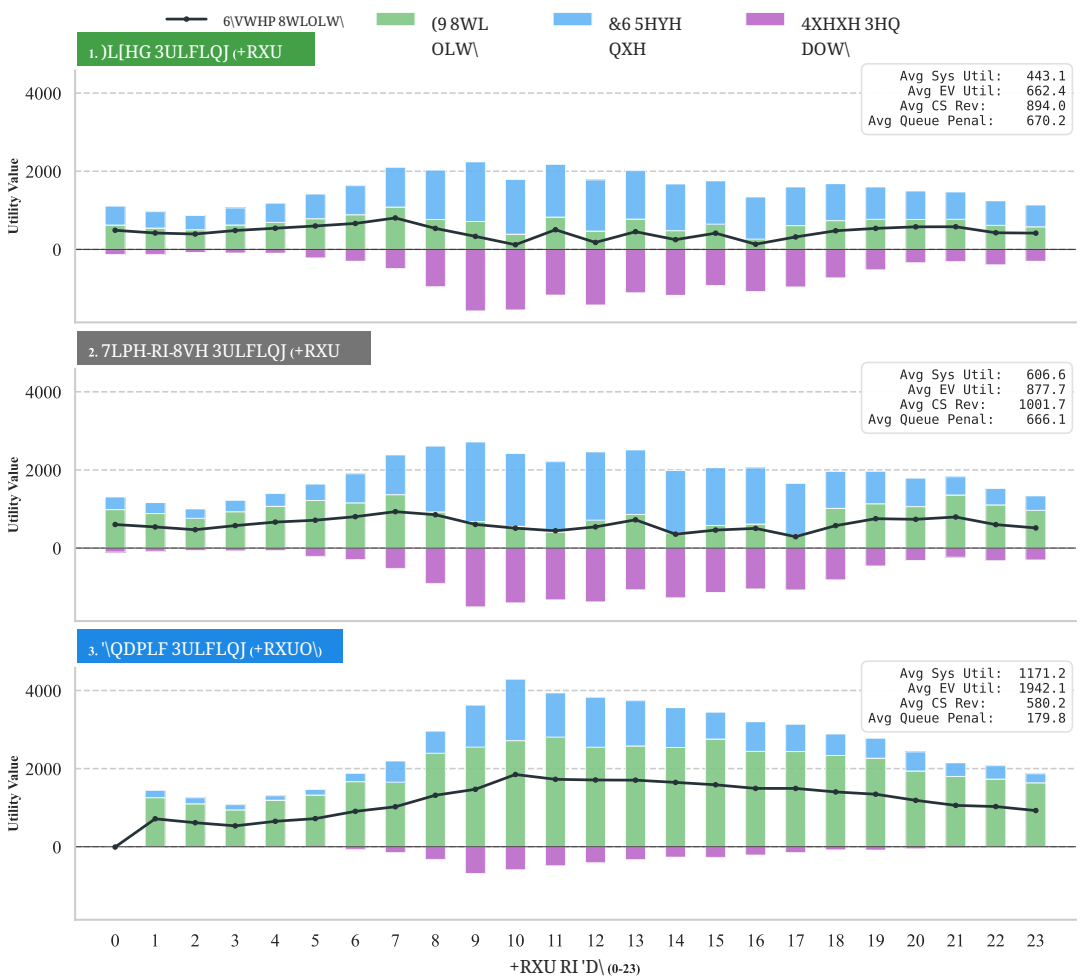


图 10：三种充电定价机制的性能对比。各面板分别展示了（1）固定定价、（2）分时定价和（3）动态定价在24小时周期内的情况。

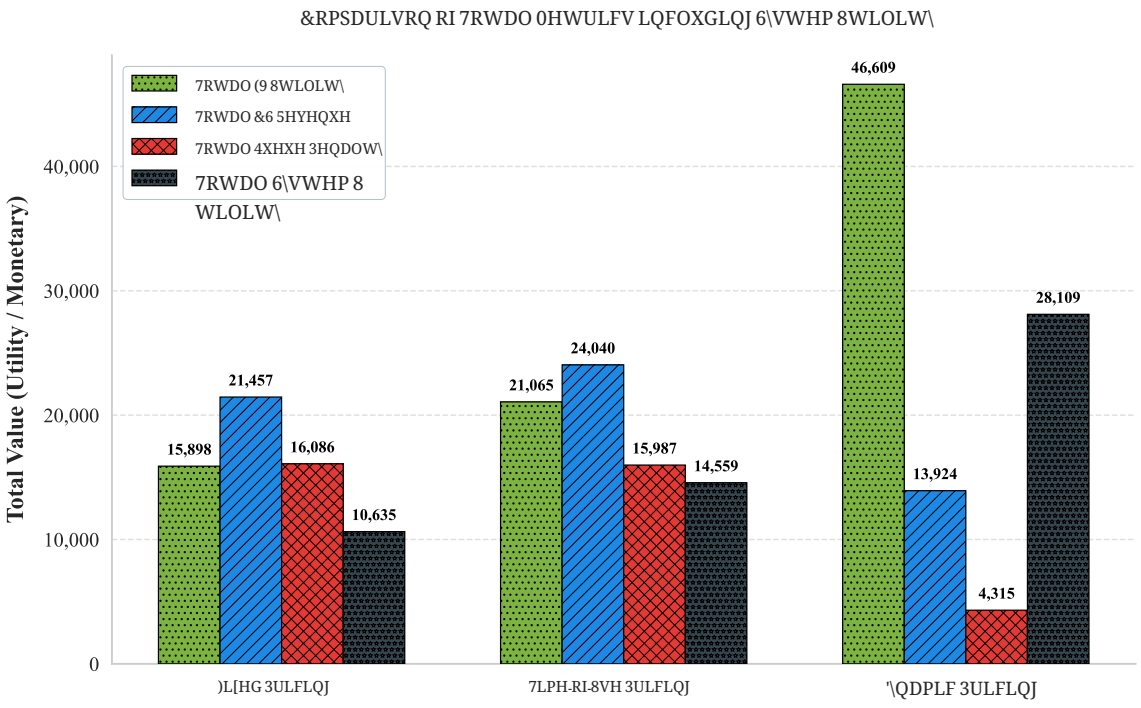


图 11：汇总　的性能指标，涵盖不同定价　　策略。

粗略的时间结构限制了其应对实时拥堵的能力。因此，平均排队惩罚仍然高达 666.1，与固定定价相比几乎没有改善。

相比之下，所提出的完全动态定价机制展现出更强的适应能力。尽管由于价格调整，充电站平均收入（580.2）有所下降，但该机制大幅缓解了拥堵。如图 10右上角图例所示，平均排队惩罚降至179.8，与基准方案相比降幅约为 73% 。这确保了系统效用在高需求时段仍能持续上升，避免了静态方法中观察到的性能下降。

4.6.2. 效用汇总比较与政策启示

图 11全面比较了累积指标，揭示了运营商收入与用户福利之间明显的权衡。

虽然固定定价和分时定价策略带来了较高的 CS 总收入（分别为 21, 457 和 24,040），但也造成了严重的拥堵成本，两种情况下总排队惩罚均约为 16,000。因此，这些机制的总系统效用有限，固定定价为 10, 635，分时定价为 14,559。

所提出的动态定价策略从根本上改变了这一平衡。通过有效内化拥堵外部性，该策略使电动汽车总效用大幅提升至46，609，超过分时定价所提供效用（21，065）的两倍。此外，动态方法将总排队惩罚抑制在仅4，315。这些改进最终使总系统效用达到28，109，较分时定价提高93%，较固定定价提高164%。

从政策视角来看，这些结果表明，最大化系统福利并不需要优先考虑运营商收入。相反，通过拥堵感知定价将剩余重新分配给电动汽车用户，可以带来显著的全系统收益。不同于以牺牲用户体验为代价保护运营商利润的传统机制，所提出的基于斯塔克尔伯格博弈的动态定价通过优化充电效率与拥堵管理之间的权衡，创造了更加平衡的结果。

5. 结论

本研究提出了一种适用于电动汽车充电网络的随机异质动态定价框架，该框架被构建为双层斯塔克尔伯格博弈，其中充电系统

运营商作为领导者，电动汽车用户则对定价信号作出最优响应。通过将感知误差纳入多项Logit模型，以表示随机的电动汽车充电选择行为，并采用排队论近似来刻画拥堵效应，所提出的框架在无需依赖确定性均衡假设的情况下，明确考虑了充电站异质性和电动汽车用户选择随机性。

本文的主要贡献有三点。首先，构建了统一的斯塔克尔伯格建模框架，以在不确定性下联合刻画动态定价决策与用户选择均衡行为。与固定定价和分时定价方案相比，所提出的完全动态定价机制能够有效内化拥堵外部性，从而大幅减少排队相关损失，并显著提升整体系统效用。

其次，提出了一种结合 PSA-CEM 与逐次平均法（MSA）的滚动时域优化算法，以高效求解由此产生的大规模时变定价问题。该求解方法在确保稳定收敛性和可扩展性的同时，保留了斯塔克尔伯格博弈中领导者与跟随者的交互结构，适用于现实充电网络环境。

第三，通过显式的异质性建模，研究揭示了充电站层面的特征与用户行为如何共同影响定价结果和系统性能。结果表明，充电器类型异质性主要通过服务率差异影响等待时间相关负效用，而容量异质性则推动充电需求与定价动态在空间和时间上的重新分配。此外，分析表明，最大化充电站收入并不一定能够最大化全系统福利；将剩余向电动汽车用户重新分配的拥堵感知定价策略，能够带来更优的整体表现。

基于墨尔本克莱顿真实案例研究的仿真实验进一步验证了所提出框架的有效性。结果表明，该动态定价机制始终优于传统定价方案，能够减少拥堵、提升电动汽车用户效用并实现更高的总系统效用，同时还能根据异质性的基础设施特征和需求模式做出自适应响应。

尽管取得了这些成果，仍存在若干局限。当前分析假设每个滚动时域内的需求模式已知，而现实中的电动汽车到达可能具有更高程度的不确定性和信息不完整性。此外，异质性

主要通过电动汽车用户选择行为和充电站特征来体现，而其他形式的行为异质性（例如异质性驾驶模式）并未明确纳入定价决策过程。尽管此类异质性可能会显著影响最优定价结果，但其影响难以事先量化，因此主要通过事后分析进行考察。此外，本研究聚焦于单运营商环境，未考虑多个充电服务提供商之间的竞争互动。

未来的研究可以从多个方向拓展这项工作。引入随机需求学习和实时信息更新，将有助于实现更稳健且更具适应性的定价策略。将该框架扩展至多运营商或竞争性市场环境，可以分析充电网络之间的策略互动。进一步纳入车辆电池特征、用户收入水平、充电灵活性以及异质性驾驶行为等异质性来源，可以进一步增强行为真实性。通过在不同异质性设置下开展系统性的实验比较，可以更明确地量化异质性的影响。最后，整合电网约束、可再生能源可用性以及车网互动，是设计可持续且电网友好的电动汽车充电系统的一个有前景的方向。

参考文献

Afirev, 2022。公共可用电动汽车充电服务质量观测站。在线。网址：https://www.observatoirerecharge-afirev.fr/。访问日期：2022年10月5日。

Ali, M.S.、Tangirala, N.T.、Knoll, A.、Eckhoff, D.，2023。通过数据驱动模型预测控制为按需出行重新平衡自动驾驶电动汽车，载于：IEEE智能交通系统国际会议（ITSC）论文集，毕尔巴鄂，西班牙。第215–221页。

Amilia, N., Palinrungi, Z., Vanany, I., Arief, M., 2022. 为城市区域设计优化的电动汽车充电站基础设施：来自印度尼西亚的案例研究，载于：IEEE智能交通系统国际会议（ITSC）论文集，中国澳门，第2812–2817页。

Amjad, M., Ahmad, A., Rehmani, M.H., Umer, T., 2018。《电动汽车充电综述：从能源优化、优化方法和充电技术的角度》。《交通研究D辑：交通与环境》62，386–417。

Bayram, I.S., Tajer, A., Abdallah, M., Qaraqe, K., 2015。面向多类别客户的电动汽车充电站容量规划框架。《IEEE智能电网汇刊》6，1934–1943。

Ben Gharbia, I., De Nunzio, G., Sciarretta, A., 2023. 电动汽车快速充电基础设施的最优布局：一种结合最优路径规划与空间聚类的方法，载于：IEEE智能交通系统国际会议（ITSC）论文集，西班牙毕尔巴鄂，第2685–2692页。

Chang, W., Zhang, Y., Fu, X., 2024. 融合情感分析的绿地可达性评估：一种改进的两步移动搜索法。《地球信息科学学报》26，2243–2253。

Chen, B., Chen, Z., Liu, X.C., Yi, Z., 2024. 基于贝叶斯推断的时空建模：纳入中间活动以研究电动汽车充电礼仪。《交通研究D辑：交通与环境》127，104060。

Cui, L., Wang, Q., Qu, H., Wang, M., Wu, Y., Ge, L., 2023. 基于深度强化学习的快速充电站动态定价。《应用能源》346，121334。

Elkholy, A.M., Rozhkov, A.N., Badalyan, A.V., Cherdintsev, I.A., 2026。自适应遗传算法通过对电网资源和交通动态进行多约束优化，增强电动汽车充电基础设施韧性。《电力系统研究》250，112045。

Feng, J., Hu, Z., Duan, X., 2023。基于随机动态均衡的考虑竞争因素的电动汽车快速充电站规划。《IEEE工业应用汇刊》59，3795–3809。

Grigorev, A., Mao, T., Berry, A., Tan, J., Purushothaman, L., Mihaita, A.S., 2021。电动汽车将如何影响交通拥堵和能耗：一种集成建模方法，载于：《IEEE智能交通系统国际会议》（ITSC）会议论文集，印第安纳波利斯，印第安纳州，美国。第1635–1642页。

Gupta, A., Bhatnagar, M., 2023。用于电动汽车充电的综合性基于定价的方案。《IEEE系统期刊》17，4073–4084。

Hu, X., Yang, Z., Sun, J., Zhang, Y., 2021. 电动汽车私人充电桩的共享经济。《交通研究B辑：方法论》152, 258–275。

Hu, X., Yang, Z., Sun, J., Zhang, Y., 2023. 电动汽车电池换电的最优定价策略：按次付费还是订阅？Transportation Research Part E: Logistics and Transportation Review 171, 103030。

国际能源署，2025。《全球电动汽车展望2025》。https://www.iea.org/reports/global-ev-outlook-2025。国际能源署，巴黎。许可协议：知识共享署名4.0国际许可协议。

Islam, M.S.、Nadarajah, M.，2016。商业场所充电站的日常电动汽车负荷曲线，载于：IEEE亚洲创新智能电网技术国际会议（ISGT-Asia）论文集，第787–792页。

Jeroslow, R.G.，1985。多项式层级与竞争分析的一个简单模型。《数学规划》32，146–164。

Kazemtarghi, A.、Mallik, A.、Chen, Y.，2024。用于分散拥堵并最大化收入的电动汽车充电站动态定价策略。《国际电力与能源系统杂志》158，109946。

Kullman, N.D.、Goodson, J.C.、Mendoza, J.E.，2021。采用公共充电站的电动汽车路径规划。《交通科学》55，637–659。

Lee, W., Schober, R., Wong, V.W.S., 2019. 异质性电动汽车充电站的价格竞争分析。《IEEE智能电网汇刊》10, 3990–4002。

Liu, H., Chen, W., Sudjianto, A., 2006. 工程设计中基于相对熵的概率敏感性分析方法。《机械设计杂志》128, 326–336。

Lu, Y., Liang, Y.C., Ding, Z.H., Wu, Q., Ding, T., Lee, W.J., 2022. 基于深度强化学习的自主按需出行系统充电定价。《IEEE智能电网汇刊》13, 1412–1426。

Luo, C., Huang, Y.F., Gupta, V., 2018. 可再生能源整合和储能条件下电动汽车充电站的随机动态定价。《IEEE智能电网汇刊》9, 1494–1505。

Mao, S., Jin, J., Xu, Y., 2024. 电动汽车电池换电系统的路径规划与充电调度：基于超图的异质多智能体深度强化学习。《IEEE智能电网汇刊》15, 4903–4916。

Mi, H., Chen, S., Ping, J., Yan, Z., 2023. 考虑电动汽车间异质性的交通均衡。IEEE 智能交通系统汇刊 24, 14944–14956。Mrkos, J., Basmadjian, R., 2022. 基于蒙特卡洛树搜索的电动汽车充电动态定价。智慧城市 5, 223–240。Ngoduy, D., Maher, M., 2013. 使用连续交叉熵方法校准二阶交通模型。《交通研究C辑：新兴技术》24, 102–121。

Park, H., Lee, C., 2024. 针对异质充电桩、非线性充电时间和路线偏离的最大电动汽车流覆盖问题的精确算法。《欧洲运筹学杂志》315, 926–951.

Patel, P., Kakani, H., Chaturvedi, M., Kumar, N., 2022. 电动汽车充电的定价模型，载于：IEEE智能交通系统国际会议（ITSC）论文集，中国澳门。第 158–163 页.

Popiolek, A., Dimitrova, Z., Hassler, J., Petit, M., Dessante, P., 2023. 电动汽车长途出行的分散式快速充电策略比较。《交通研究D辑：交通与环境》124, 103953.

Qin, H., Zhang, W., 2011. 电动汽车与充电站网络中的最小等待时间充电调度，载于：第八届ACM车辆互联国际研讨会（VANET）论文集，第 51–60 页.

Rubinstein, R.Y., Kroese, D.P., 2004年。《交叉熵方法：组合优化、蒙特卡洛模拟与机器学习的统一方法》。施普林格。

Saharan, S., Bawa, S., Kumar, N., 2020. 智慧城市智能交通系统的动态定价技术：系统综述。《计算机通信》150，603–625。

Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., Saisana, M., Tarantola, S., 2008. 全局敏感性分析：入门指南。约翰·威立父子出版公司。

Shafiei, M., Ghasemi-Marzbali, A., 2023. 考虑可再生能源概率模型和需求响应的电动汽车快速充电站设计。《Energy》267, 126545.

Sheng, Y., Guo, Q., Chen, F., Xu, L., Zhang, Y., 2021. 耦合城市电力—交通网络的协调定价：信息共享价值。《应用能源》301, 117428.

Soares, J., Ghazvini, M.A.F., Borges, N., Vale, Z., 2017. 使用随机规划制定电动汽车动态电价。Energy 122, 111–127.

Song, Y., Ngoduy, D., Dantsuji, T., Ding, C., 2025. 考虑电动汽车充电行为的交通与电力耦合网络动态均衡。Transportation Research Part A: Policy and Practice 199, 104590.

Tran, C.Q., Keyvan-Ekbatani, M., Ngoduy, D., 2023. 迈向清洁交通系统：行驶过程中电动汽车充电的基础设施规划。Sustainable Cities and Society 96, 104633.

Tran, C.Q., Keyvan-Ekbatani, M., Ngoduy, D., Watling, D., 2021a. 电动汽车快速充电设施部署中的随机性与环境成本纳入。Transportation Research Part E: Logistics and Transportation Review 154, 102460.

Tran, C.Q., Ngoduy, D., Keyvan-Ekbatani, M., Watling, D., 2021b. 考虑城市网络中异质车辆的基于用户均衡的快速充电站选址模型。《Transportmetrica A: Transport Science》17, 439–461。

Wang, Q., Liu, X., Du, J., Kong, F., 2016. 电动汽车智能充电：算法视角综述。IEEE Communications Surveys & Tutorials 18, 1500–1517。

Wang, Y., Bi, J., Guan, W., Lu, C., Xie, D., 2021. 纯电动汽车城际出行的最优充电策略。《交通研究D辑：交通与环境》96, 102870。

Wang, Y., Fan, R., Lin, J., Xie, X., Zhang, W., Srinivasan, D., 2025a. 共享私人电动汽车充电器的补贴：三级Stackelberg博弈分析。《交通研究D辑：交通与环境》140, 104626。

Wang, Y., Yang, M., Qin, B., Zhang, Y., 2025b. 通过可解释机器学习解码航班延误情况下的出行行为意图：保障乘客出行的启示。Transportation Research Part A: Policy and Practice 201, 104666.

Wu, F., Sioshansi, R., 2019. 用于控制电动汽车充电以提供频率调节的随机运行模型。《交通研究D辑：交通与环境》67, 475–490. Yin, L., Zhang, Y., 2024. 基于数据驱动的粒子群优化电动汽车充电站选址。Energy 310, 133197. Yu, Y., Su, C., Tang, X., Kim, B.S., Song, T., Han, Z., 2021. 基于时间的计费模型下联网电动汽车公共充电的层次博弈。《IEEE智能电网汇刊》22, 518–530. Zanvettor, G.G., Casini, M., Smith, R.S., Vicino, A., 2022. 电动汽车停车场的随机能源定价。《IEEE智能电网汇刊》13, 3069–3081.

Zhang, W., Liu, H., Han, J., Ge, Y., Xiong, H., 2022. 基于多智能体图卷积强化学习的动态电动汽车充电定价，载于：第28届ACM SIGKDD知识发现与数据挖掘会议论文集，美国华盛顿特区。第2471–2481页。

Zhang, Y., Fu, X., Yu, Z., Luo, S., 2024. 多模式出行如何提升旅游景点的可达性？基于多源数据的改进型两步浮动集水区法。《GIS汇刊》28，278–302。

Zheng, N., Geroliminis, N., 2020. 面向异质用户的多模式城市网络基于区域的公平定价策略。Transportation Research Part A: Policy and Practice 136，357–374。

Zheng, Y., Song, Y., Hill, D.J., Meng, K., 2019. 基于分布式模型预测控制的配电系统电动汽车充电站在线分布式最优调度。《IEEE工业信息学汇刊》15，638–649。

Zhong, R.，Fu, K.Y.，Sumalee, A.，Ngoduy, D.，Lam, W.H.K.，2016。用于校准微观交通模型的交叉熵方法与概率敏感性分析框架。《交通研究C辑：新兴技术》63，147–169。

Zhou, Z.，Moura, S.J.，Zhang, H.，Zhang, X.，Guo, Q.，Sun, H.，2021。融入行为理论的电力—交通网络均衡：势博弈视角。《应用能源》289，116703。

Çalık, H.，Oulamara, A.，Prodhon, C.，Salhi, S.，2021。异构车队电动车辆定位-路径问题：建模与Benders分解方法。《计算机与运筹研究》131，105251。

算法1： 用于滚动时域动态定价优化

输入： 网络拓扑、电动汽车和充电站参数，κ, φ, Q, η, μ, T, H, ω，样本量 N，PSA阈值 τ，平滑因子 β，PSA频率 ψ

输出： 优化后的定价方案 Pr^*，用户均衡流量 p^*，性能指标 PI^*

初始化抽样分布 $\gamma^{(0)} = \mathcal{N}(\mu^{(0)},\ \sigma^{(0)})$，迭代 $\ell \leftarrow 0$;

对于每个滚动窗口 $[t, t+H-1]$ 在时域 T 上**执行**

  初始化队列状态和初始价格 $Pr^{(0)}(t)$;

  当不满足停止准则**时执行**

    从 $f^{(\ell)}(\boldsymbol{\theta})$中抽取 N定价样本 $\{Pr^{(m)}(t)\}$;

    对于每个样本 $Pr^{(m)}(t)$ **执行**

      计算 $ECA^{(m)}(t)$，推导 $p^{(0,m)}(t)$ =多项Logit($ECA^{(m)}(t)$)，并更新 $p^{(m)}(t)$ =逐次平均法($p^{(0,m)}(t)$);

      评估队列时延 $T_{ij}^{q}(t)$、队列丢失 $QL^{(m)}(t)$ 和效用（$U^{(m)}$ 电动汽车 $R^{(m)}$ 充电站）;

      计算性能 $F_{(m)}(t) = \omega R^{(m)}$ 充电站 $+ (1-\omega) U^{(m)}$ 电动汽车 ;

    选择排名靠前的 N_e 精英样本，并估计 $\hat{f}^{(\ell)}(s)$;

    如果 $mod(\ell, \psi) = 0$ **则**

      // 有条件触发的动态 PSA 更新

      对于每个决策变量 θ_k **do**

        构建冻结种群并估计 $\hat{g}_k^{(\ell)}(s)$;

        计算敏感度 $D_k^{(\ell)} = \int \hat{g}_k^{(\ell)}(s) \ln[\hat{g}_k^{(\ell)}(s) / \hat{f}^{(\ell)}(s)]\, ds$;

      确定活跃集 $\mathcal{A}^{(\ell)} = \{k | D_k^{(\ell)} > \tau\}$;

      对于每个变量 k **执行**

        如果 $k \in \mathcal{A}^{(\ell)}$ **则**

          $\mu_k^{(\ell+1)} = \beta \mu_k^{(\ell)} + (1-\beta) \bar{\theta}_k^{(\ell)}$;

          $\sigma_k^{(\ell+1)} = \beta \sigma_k^{(\ell)} + (1-\beta) s_k^{(\ell)}$;

        else

          保持冻结：$\mu_k^{(\ell+1)} = \mu_k^{(\ell)}$，$\sigma_k^{(\ell+1)} = \sigma_k^{(\ell)}$;

    else

      // 标准 CEM 更新（本次迭代不使用动态 PSA）

      更新所有 $\mu_k^{(\ell+1)}, \sigma_k^{(\ell+1)}$ 使用精英均值 $\bar{\theta}_k^{(\ell)}$ 和偏差 $s_k^{(\ell)}$;

    $\ell \leftarrow \ell + 1$;

  存储优化后的 $Pr^*(t)$ 和均衡 $p^*(t)$;

返回 Pr^*，p^*，PI^*;

附录A。系统效用权重的敏感性分析

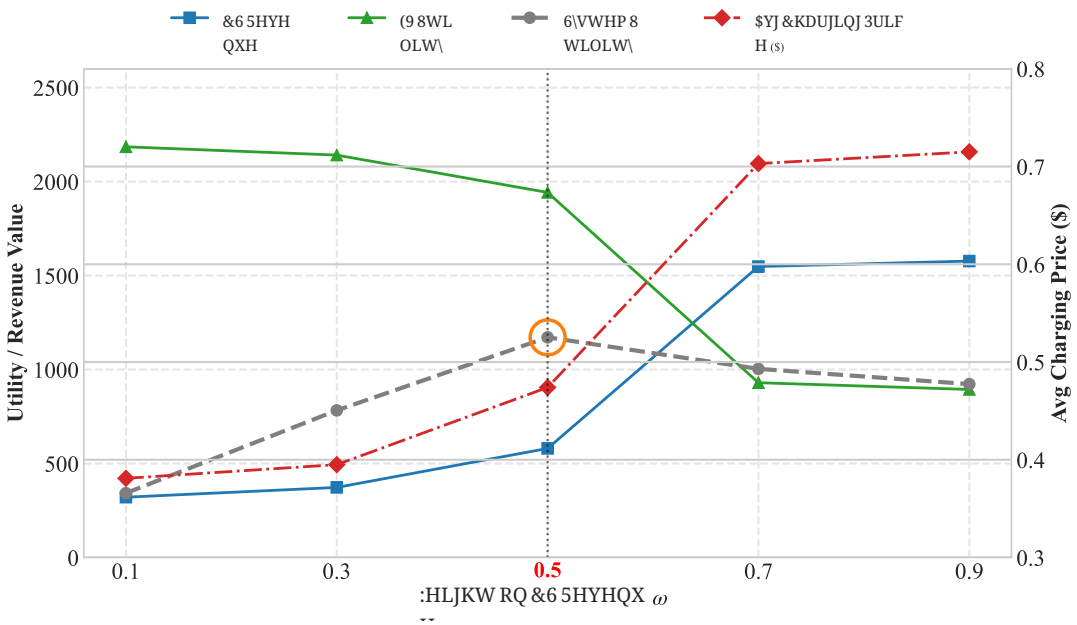


图 A.12：权重参数 ω 对系统绩效指标的敏感性分析。双纵轴分别显示效用/收入值（左轴）和平均充电价格（右轴）。橙色圆圈标出了均衡情景（$\omega = 0.5$）下实现的系统效用全局最大值。

在这项敏感性分析中，我们通过改变系统效用权重参数 $\omega \in \{0.1, 0.3, 0.5, 0.7, 0.9\}$，设置了五种实验情景，涵盖从电动汽车用户导向型机制（$\omega = 0.1$）到运营商收入导向型机制（$\omega = 0.9$）的连续范围。这一设计有助于系统地考察利益相关者目标的相对侧重如何影响定价决策和整体系统性能。

如图所示A.12， ω 的变化通过内生定价机制，引发了电动汽车用户效用与充电站收入之间显著的权衡。具体而言，随着 ω 增加，优化过程逐渐优先考虑运营商收入，平均充电价格从 $\omega = 0.1$ 时的 0.38 美元稳步升至 $\omega = 0.9$时的 0.72 美元。尽管这一定价策略有效提升了充电站收入（蓝线），但同时也使电动汽车用户承受越来越大的负效用，导致电动汽车效用（绿线）急剧且持续下降。这种此消彼长的变化清晰地反映了动态充电市场中用户可负担性与运营商盈利能力之间固有的冲突。

值得注意的是，系统总效用（灰色虚线）并非在这两个极端之间线性插值。相反，它呈现出明显的凹形趋势，表明存在内部最优解。极端的权重配置会导致次优的系统结果。在 $\omega = 0.1$ 时，过低的充电价格会过度偏向

电动汽车用户，但运营商收入不足会损害充电基础设施供给的可持续性，从而降低整体系统效用。相反，在 $\omega = 0.9$ 时，激进的收入导向定价会抑制有效需求，并大幅损害用户福利，同样导致系统整体绩效下降。

均衡情景（$\omega = 0.5$）对应于系统效用曲线的顶点，由橙色圆圈标出。该结果为所选加权方案提供了实证验证，表明等权重配置并非仅仅是一种启发式或规范性假设，而是在所探索的参数空间内内生地成为全局最优解。在这一点上，运营商收入的边际收益与用户效用的边际损失高度一致，在经济可行性与服务可负担性之间实现了最有效的折中。

进一步偏离这一均衡将呈现收益递减。将 ω 提高到0.5以上所带来的收入改善，无法抵消电动汽车用户效用的不成比例损失，从而导致社会福利迅速下降。相反，将 ω 降低到0.5以下会造成收入短缺，威胁运营商生存能力和长期系统韧性。综合来看，这些发现表明，$\omega = 0.5$ 代表了一个经验证的最优运营点，能够协调相互冲突的利益相关者目标，并最大化整体系统效率。因此，基于上述实证证据，在后续分析中采用 $\omega = 0.5$ 作为权重系数。

附录B. 优化的交叉熵方法

不失一般性，考虑在可行域 Ω 内，对决策向量 $\boldsymbol{\theta}$ 求目标函数 $F(\boldsymbol{\theta})$ 的最小值：

$$F^* = \min_{\boldsymbol{\theta} \in \Omega} F(\boldsymbol{\theta}), \tag{B.1}$$

其中，F^* 表示目标函数的最小值，$\boldsymbol{\theta}$ 表示可行域 Ω 内的决策向量。

交叉熵法引入一族参数化概率密度函数（概率密度函数）$f(\boldsymbol{\theta};\ \phi)$，用于刻画抽样分布。对于 $F(\boldsymbol{\theta})$的最小化，稀有事件定义为 $F(\boldsymbol{\theta}) \leq c$，其中 $c \geq F^*$ 是一个足够接近最优值的阈值。相应的

概率为

$$\ell(c) = \mathbb{P}_{\boldsymbol{\phi}}(F(\boldsymbol{\Theta}) \leq c) = \mathbb{E}_{\boldsymbol{\phi}}\left[\mathbb{I}_{\{F(\boldsymbol{\Theta})\leq c\}}\right], \tag{B.2}$$

其中， $\mathbb{P}_{\boldsymbol{\phi}}(\cdot)$ 和 $\mathbb{E}_{\boldsymbol{\phi}}(\cdot)$分别表示概率和期望算子， $\mathbb{I}(\cdot)$是指示函数。

CEM算法通过迭代更新抽样分布，以最大化生成精英样本的似然。该过程概述如下：

1. 初始化参数向量 $\boldsymbol{\phi}^{(0)}$ ，并设置迭代计数器 $t = 1$。

2. 在每次迭代中，从分布 $f(\boldsymbol{\theta};\, \boldsymbol{\phi}^{(t-1)})$中抽取 N个随机样本 $\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \ldots, \boldsymbol{\theta}_N$，并计算每个样本对应的目标函数 $F(\boldsymbol{\theta}_i)$。

3. 对目标函数值排序，并确定精英阈值：

$$\hat{c}^{(t)} = F_{(\lceil (1-q)N \rceil)}, \tag{B.3}$$

其中， $q \in (0,1)$为精英比例。

4. 通过最大似然估计更新分布参数：

$$\boldsymbol{\phi}^{(t,\text{new})} = \arg\max_{\boldsymbol{\phi}} \frac{1}{N} \sum_{i=1}^{N} \mathbb{I}_{\{F(\boldsymbol{\theta}_i)\leq \hat{c}^{(t)}\}} \ln f(\boldsymbol{\theta}_i; \boldsymbol{\phi}). \tag{B.4}$$

5. 应用平滑以避免早熟收敛：

$$\boldsymbol{\phi}^{(t)} = \beta \boldsymbol{\phi}^{(t,\text{new})} + (1-\beta)\boldsymbol{\phi}^{(t-1)}, \tag{B.5}$$

其中， $\beta \in [0,1]$ 为平滑因子。

6. 检查收敛性：如果抽样分布的标准差低于容差 ϵ，则设置

$$F^* = \hat{c}^{(t)}; \tag{B.6}$$

否则，将 $t \leftarrow t+1$ 递增，并重复步骤 2–5。

通过以这种方式迭代更新抽样分布，CEM 在高效探索可行域的同时，逼近原优化问题的最优解。