亮点

极端事件下韧性电动汽车-电网规划与决策支持的科学机器学习

王一帆

- 跨尺度物理注入将微观遥测与城市尺度韧性相衔接
- 单调性约束查找表跨越尺度差距保持物理一致性
- 物理注入恢复单调应力响应（斯皮尔曼 ρ: $-0.8 \rightarrow +1.0$）
- 混合策略通过超加性交互效应使积压量减少79.1%
- 韧性边界将需求灵活性与最大可承受应力联系起来

arXiv:2602.01261v1 [eess.SY] 1 Feb 2026

极端事件下韧性电动汽车-电网规划与决策支持的科学机器学习

奕帆 王[a], *

[a]新加坡南洋理工大学电气与电子工程学院，*639798*，新加坡 *ore*

文献信息

关键词：
电动汽车充电网络 科学机器学习 跨尺度物理注入 时空图神经网络 配电网韧性 极端事件评估 政策评估

摘 要

电动汽车（EV）充电基础设施给城市配电网络带来了复杂挑战，尤其是在极端需求事件期间。韧性评估面临的一项关键障碍，是微观充电物理与城市尺度规划之间的尺度差距：小时级聚合数据集无法呈现分钟分辨率下的可交付性约束，导致纯数据驱动模型在高压力状态下表现出不符合物理规律的行为。

本文提出一个五阶段科学机器学习框架，通过物理信息知识迁移弥合这一差距。阶段1利用瑞士直流快充遥测数据，在单调性约束下学习温度–压力可供给性曲面。阶段2通过锚定分位数映射实现跨尺度注入。阶段3部署双头时空图神经网络，联合预测需求和服务损失率。阶段4模拟压力冲击下的积压动态，并评估政策干预。第4阶段通过变压器负载分析，将服务结果与配电网压力关联起来。

在深圳 UrbanEV 数据集上的验证表明，物理注入恢复了单调的压力—风险响应（斯皮尔曼 $\rho = +1.0$，而未注入时为 -0.8），并提高了预测准确度。在一个具有代表性的需求冲击下，混合策略将积压量减少了79.1%，在研究时限内恢复了全面服务，并将电网压力仅增加2小时。由此得出的韧性边界 $m_{\mathrm{crit}}(\varepsilon) \approx 1.7 - 1.0\varepsilon$ 为需求灵活性与最大可承受应力之间的关系提供了可操作的指导，使得极端事件下的风险感知应急规划成为可能。

1. 引言

全球能源转型正加速分布式能源资源融入电力配电网络，而电动汽车（EV）充电基础设施已成为其中至关重要但在运营上颇具挑战的组成部分。在人口密集的城市环境中，充电需求呈现显著的时空异质性，受天气和出行模式影响，并容易在节假日、中断事件或极端事件期间大幅激增[1, 2]。这些情况可能引发拥堵事件，导致无法完全满足充电需求，既损害用户体验，也会因电压波动和变压器过载而加重配电资产的压力 [3, 4]。

对于基础设施规划者和电网运营商而言，基本的运营问题不仅是预测将有多少需求到来，还要了解在物理约束下能够满足多少需求，以及至关重要的哪些干预措施能够在极端条件下维持系统功能。随着极端天气事件的频率和严重程度不断上升，这种以韧性为导向的视角变得愈发迫切，因为这些事件威胁着充电服务连续性和配电网可靠性 [5]。

1.1. 跨尺度挑战

韧性评估中的一项根本困难，源于尺度差距：微观充电物理与城市尺度运行数据之间的差距。可交付性——即请求充电功率中实际能够得到满足的比例——受微观尺度机制支配，而这些机制在城市尺度数据产品中大多不可见：当总需求超过站点容量时发生的瞬时功率截断、并发会话之间由竞争引起的分配、控制器再分配逻辑，以及温度相关降额 [6]。这些现象发生在分钟或亚分钟的时间尺度上

s

并且需要借助高分辨率遥测才能直接观测。

相比之下，城市尺度数据集通常为小时级且经过空间聚合，因而无法直接学习可供电性机制。因此，在此类数据上训练的纯数据驱动模型或许能够较好地拟合平均工况，但在高压力尾部可能表现出非物理行为——例如预测需求增加会导致降低的服务损失。这种病态外推在我们的实验中已被观察到（第5.1节），恰恰出现在韧性决策最为敏感、且准确预测对应急响应最为关键之处。

1.2. 科学机器学习机遇

科学机器学习（Sci-ML）通过将机制先验与数据驱动学习相结合，为弥合这一尺度差距提供了一种有原则的方法。物理信息神经网络及相关技术已在电力系统应用中展现出成效，能够改善分布偏移下的外推性能，减轻非物理行为，并减少数据需求 [7–11]。其核心洞见在于，物理约束——单调性、守恒定律、

*通讯作者WANG2115@e.ntu.edu.sg （Y. Wang）ORCID：0000-0000-0000-0000（Y. Wang）

边界条件——能够对学习模型进行正则化，使其即使在超出训练分布的范围内运行，也能保持与领域知识的一致性。

本文将跨尺度物理迁移落实于电动汽车充电韧性评估。我们并不把可交付性视为不可观测的潜变量，而是从微尺度遥测数据中学习可交付性规律，并通过分布对齐将其注入城市尺度面板数据。由此得到的机制推导的服务损失率，为原本无法获取真实可交付性观测的预测模型提供了具有物理依据的监督。

1.3. 相关工作

先前研究已推进了与本工作相关的多条线索，但它们在很大程度上仍彼此割裂。

充电需求预测与运行。 Applied Energy 已报道了用于短期充电需求预测的有影响力的深度学习模型 [1, 2, 12], 运行协调 [13, 14], 以及分层概率预测 [15, 16]。尽管这些研究对总需求实现了较高的预测精度，但它们通常将服务质量视为隐含因素，使极端尾部可交付性状态的刻画仍不充分。

时空图学习。 图神经网络已成为充电与出行场景中大规模时空预测的主导范式 [17–20]。然而，现有时空图神经网络研究预测的是总需求，而非拥堵导致的服务损失，并且很少约束尾部行为，使其在压力下保持物理一致性。

电动汽车—电网耦合。 综述和运营研究强调，必须结合配电约束评估充电网络 [3, 4, 21, 22]。这促使我们明确建立服务水平结果与电网压力指标之间的耦合关系，从而能够权衡充电服务质量与变压器负载。

韧性评估。 充电系统的韧性要求进行明确的压力测试并描述恢复特征，而不能仅依赖平均性能指标 [5, 23]。现有研究很少纳入跨尺度可交付性传递；本框架通过统一物理注入弥补了这一不足。

鲁棒与不确定性感知控制。近期研究强调能源基础设施的分层式、鲁棒和不确定性感知控制 [24–26]。这些理念促使我们聚焦于面向决策的评估和政策权衡量化，而非单纯追求预测准确度。

1.4. 研究空白与贡献

受这些观测结果启发，我们确定了当前韧性评估流程面临的三个局限性：

(i) 尺度差距： 微观尺度可交付性物理机制（削波以及竞争条件下的分配）未能迁移到城市尺度预测中，导致模型学到在极端条件下失效的虚假相关性。

(ii) 可验证性缺口： 策略压力测试依赖的服务代理指标并非机制一致，尤其是在韧性决策最为集中的高压力尾部。

(iii) 耦合缺口： 韧性结果很少被转化为会约束可行干预措施的配电网压力指标，从而阻碍了协调的服务—电网规划。

本研究构建了一个五阶段、跨尺度且融入物理机制的框架，以解决这些差距。主要贡献如下：

1. **Mi跨尺度机制利用分钟级堂况充电遥测数据 [16] 学习温度–压力可供给性曲面，并施加单调性约束，生成稳健的查找表，以刻画资源争用情况下的功率削波和分配行为。**

2. **跨尺度物理注入（阶段2）**。我们提出锚定分位数映射方法，以对齐相差三个数量级的尺度差距下不同的压力分布，并将微观定律注入城市尺度的UrbanEV面板数据 [27], ，从而得出基于机理推导的服务损失率，具有物理可解释性和可迁移性。

3. **双头时空预测（阶段3）**。我们设计了一种双头时空图神经网络（ST-GNN），通过注重韧性决策关键高压力状态的尾部感知训练，联合预测需求量和服务损失。

4. **基于积压的韧性仿真（第4阶段）**。 我们构建了一个基于排队论的积压仿真器，其中考虑了拥堵诱发的放弃，并在压力冲击下评估各项策略杠杆（基于价格的需求调节、定向容量提升、混合策略）。

5. **电网耦合评估（第5阶段）**。 我们将服务轨迹转换为变压器负载和压力时段指标，量化服务—电网权衡，并推导出经验韧性边界 $m_{\text{crit}}(\epsilon)$，将需求灵活性与最大可承受应力联系起来。

本文其余部分安排如下。第2节介绍数据集和问题formulation。第3 节阐述五阶段方法论。第4 节详述实验设计。第5 节报告针对三个研究问题的结果。第6 节讨论其意义和局限性。第7 节作总结。

2. 数据与问题 formulation

本研究通过配对微尺度充电遥测数据集（源域）与城市尺度分区小时面板数据（目标域），将跨尺度迁移付诸实践。这两个数据集具有互补特征：微观域揭示细粒度的功率削波和分配行为，而宏观域则提供广泛的空间覆盖范围，适用于预测、压力测试和策略评估。

表1跨尺度流程所用数据集摘要。

数据集	领域	Res.	时段	尺度
瑞士 [6]	微观	1分钟	2022.10–2023.02	19,943条记录
UrbanEV [27]	宏观	1 h	2022.09–2023.02	275×4,344

2.1. 数据集与预处理

源域：瑞士分钟级充电遥测数据（阶段1）。阶段1采用瑞士直流快速充电站的分钟级遥测数据（2022年10月至2023年2月；来自601次充电会话的19,943条有效分钟记录）[6]。每条记录包含请求充电功率P_{req}、控制器设定值 P_{set} （竞争情况下的预期分配）、实际功率 P_{real}，以及与附近气象站匹配的环境温度。分钟级分辨率至关重要，因为功率削顶事件和控制器重新分配发生在亚小时级的时间尺度上，而按充电会话汇总的数据会掩盖这些情况。

目标域：深圳分区-小时 UrbanEV 面板（阶段2–阶段5）。第2至第5阶段使用基于深圳 UrbanEV 数据集[27]构建的城市尺度面板数据。该面板包含 $Z = 275$ 个空间分区和 $T = 4,344$ 个小时级时间步（2022 年 9 月至 2023 年 2 月），共计$Z \times T = 1,194,600$ 个分区-小时观测值。对于每个区域 z 和小时 t，面板提供观测需求量 $V_{t,z}$（所需的小时充电能量）、占用率和时长统计数据、当地温度$T_{t,z}$，以及区域级静态属性，包括装机容量 C_z 和充电桩数量。空间图 $G = (\mathcal{V}, \mathcal{E})$ 连接 5 公里半径范围内的区域，以支持时空学习。

时间划分与归一化。我们对目标域采用按时间顺序划分的方式：70% 用于训练，15% 用于验证，15% 用于测试。输入特征使用训练集统计数据进行标准化。对于阶段1，将温度离散为 5°个区间，并将压力划分为宽度为 0.1 的区间，以构建稳健的可交付能力查找表。表1 总结了数据集特征，图1 展示了两个数据源之间的跨尺度互补性。

2.2. 变量与符号

我们在不同尺度上采用统一的压力–可交付能力表述体系。表2 总结了核心符号。

微观尺度物理压力与可交付能力。令P_{cap} 表示额定物理容量（每枪：86.25 kW；双枪配置下的站级容量：172.5 kW）。无量纲压力指标为

$$s = \frac{P_{req}}{P_{cap}}, \tag{1}$$

其中， $s \approx 1$ 对应于以容量上限运行，$s > 1$表示过载。可交付性比率用于量化服务比例：

$$\eta_{set} = \frac{P_{set}}{P_{req}}, \qquad \eta_{real} = \frac{P_{real}}{P_{req}}. \tag{2}$$

城市尺度压力代理指标与服务损失率。在城市面板中，直接的微观变量无法观测。我们

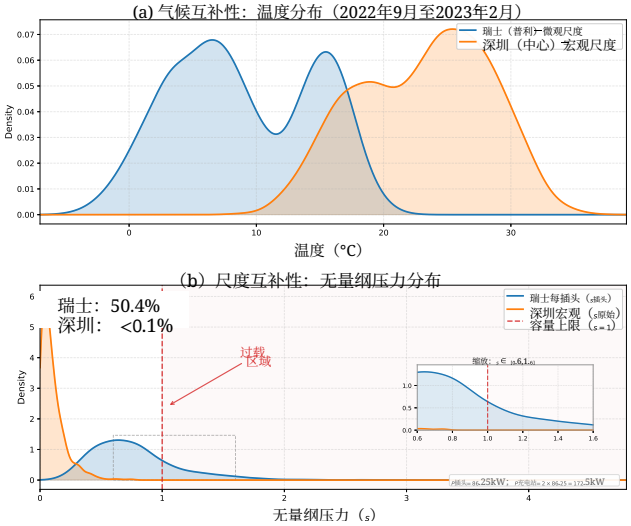

图 1： 数据源与跨尺度互补性。瑞士分钟级遥测数据提供微观可交付性物理机制，且过载暴露率较高（$s = 1$以上的观测值占50.4%）；深圳区域-小时面板提供城市尺度需求动态及聚合压力代理指标（超过$s = 1$的比例为<0.1%）。过载暴露率相差三个数量级，因此需要进行分布对齐。

构建一个无量纲压力代理指标：

$$s_{raw}(t,z) = \frac{V_{t,z}}{C_z \Delta t}, \tag{3}$$

其中， $\Delta t = 1$小时。阶段2通过分位数映射，将 s_{raw} 映射至经瑞士数据校准的压力域，以获得s_{mapped} ，并接入可交付性查找表，生成 $\hat{\eta}$ 和服务损失率 $SLR = 1 - \hat{\eta}$。

预测目标和仿真变量。 阶段3$\hat{\ }$ $\widehat{\ \ }$基于24小时回溯窗口预测下一小时的目标 $(V_{t+1,z}, SLR_{t+1,z})$ 。第4阶段在压力乘数 m_t 和政策行动下模拟积压量$B_{t,z}$。第5阶段将汇总的充电功率映射到变压器负载 $\lambda(t)$ ，以量化电网压力。

2.3. 问题 formulation

预测任务（阶段3）。给定24小时回溯窗口内的图结构输入 $\{X_{t-\tau:t,z}\}_{z=1}^{Z}$ 和区域图 G，阶段3学习一个预测器 f_Θ ，使得

$$(\hat{V}_{t+1,z}, \widehat{SLR}_{t+1,z}) = f_\Theta\big(\{X_{t-\tau:t,z}\}_{z=1}^{Z}, G\big), \quad \tau = 23, \tag{4}$$

对所有区域 z均成立。我们评估需求量的均方根误差、平均绝对误差和平均绝对百分比误差，并通过针对SLR的单调应力–风险响应评估其物理合理性。

韧性评估任务（第4–5阶段）。给定预测结果和情景参数，第4阶段模拟积压轨迹并计算韧性指标（积压面积、峰值、恢复时间）。第5阶段汇总充电功率，以计算变压器负载 $\lambda(t)$ 和压力时段指标，从而支持服务—电网权衡分析。

表2五阶段流程中使用的核心符号。

符号	定义
阶段*1*：微观尺度变量	
$P_{req}, P_{set}, P_{real}$	请求功率 / 设定点 / 实际功率
P_{cap}	额定物理容量
s	无量纲压力，$s = P_{req}/P_{cap}$
η_{set}，η_{real}	可交付性比率，$\eta = P/P_{req}$
阶段*2–3*：城市尺度变量	
s_{raw}, s_{mapped}	原始和对齐的压力代理指标
$\widehat{\eta}$	来自查找表的注入可交付能力
$SLR, \widehat{SLR}$	服务损失率；$\widehat{SLR}$ 为预测值
$V, \widehat{V}$	需求量；$\widehat{V}$ 为预测值
第*4*阶段：韧性仿真	
$A_{t,z}$ $S_{t,z}$	到达量和有效服务（千瓦时/小时）
$B_{t,z}$	积压量（千瓦时，未服务的累积量）
m_t	压力乘数（外生冲击）
ϵ	需求价格弹性（$\epsilon < 0$）
第*5*阶段：电网耦合	
$\lambda(t)$	变压器负载率
H_{stress}	高于阈值的累积应力时长
	old

3. 方法论

3.1. 概述与统一的科学机器学习主题

我们开发了一套包含五个阶段的闭环数据–物理–决策–电网流程。其核心理念是跨尺度物理信息知识迁移：将基于瑞士遥测数据学习的微观尺度可交付性定律注入城市尺度面板数据，以生成机制推导目标和基于物理原理的特征，为预测、政策压力测试和配电网耦合提供支持。物理先验在多个环节发挥作用：

(i) **阶段1：** 单调性正则化确保压力升高不会改善可交付性。(ii) **阶段2：** 通过锚点分位数映射进行分布对齐，从而保持跨尺度的物理一致性。(iii) **阶段3：** 尾部感知损失加权着重关注物理上至关重要的高压状态。(iv) **第4阶段：** 排队式守恒定律控制积压动态。

3.2. 阶段1：微观尺度可交付性学习

目标。 阶段1使用瑞士直流快速充电遥测数据 [6] 来学习经验可交付性定律，以刻画服务效率如何随环境温度和资源竞争而下降。分钟级分辨率至关重要，因为功率削波发生在小时以下的时间尺度上。

压力构造。无量纲压力指1）定义，其中 $s \approx 1$ 表示容量限制运行，而 $s > 1$ 表示过载，可能导致服务削减。

基于单调性先验的响应面估计。我们估计温度-压力响应面 $\eta(T, s)$ 在离散网格 (T_{bin}, s_{bin}) 上进行，温度分箱间隔为 5℃，并采用左闭右开约定：[0, 5)、[5, 10)、……、[30, 35]℃（共 7 个分箱）；压力分箱间隔为 0.1：[0, 0.1)、[0.1, 0.2)、……，最高至 $s = 3.0$（共 30 个分箱），总计约有 7×30 个网格单元。超出这些范围的观测值将截断至边界分箱（即 T <0℃ 映射到 [0, 5) 分箱；$s > 3.0$ 映射到 [2.9, 3.0]分箱）。

在温度固定时，压力升高不应提高可交付性；原始估计中看似违反这一规律的情况，源于高-s 尾部的采样稀疏。我们针对每个温度分箱应用单调包络，使用累积最小值：

$$\eta_{smooth}(T, s) = \min_{s' \le s} \eta_{raw}(T, s'), \tag{5}$$

这等同于沿 s方向执行累积最小值（cummin）操作。我们选择 cummin 而非保序回归，因为它能施加硬单调性约束（物理上必须如此：压力越高，可交付性不能提高），计算效率高（$O(n)$ 每个温度切片），并且无需调整参数，就能稳健应对高压分箱中稀疏数据里的离群值。这项科学机器学习约束引入了物理先验，使学习到的微观定律免受采样噪声影响而更加稳定，并提升了跨尺度可迁移性 [7, 8]。图 3 展示了由此得到的可交付性曲面。

3.3. 阶段2：跨尺度压力统一与物理注入

在阶段1中确立了微观定律后，阶段2着眼于跨尺度迁移。由于两个区域的压力分布差异极大，直接将瑞士微观尺度响应应用于深圳原始压力并不适用：瑞士数据中有 >50%的观测值超过 $s = 1$（过载），而深圳为 <0.1%——相差三个数量级（图4）。因此，我们先进行分布对齐，再进行查表注入。

锚定分位数映射。令 s_{raw} 为目标域中的区域—小时气压代理量。我们定义以下分布函数：

- $F_{SZ}(s)$：深圳气压的经验累积分布函数，返回百分位秩 $\in [0, 1]$。
- $F_{CH}(s)$：瑞士压力的经验累积分布函数。
- $F_{CH}^{-1}(q)$：瑞士压力的逆累积分布函数（分位数函数），将百分位数 $q \in [0, 1]$ 映射为气压值。

原始分位数映射将深圳气压转换到瑞士域：

$$s_{qm} = F_{CH}^{-1}\left(F_{SZ}(s_{raw})\right), \tag{6}$$

将每个深圳观测映射到具有相同百分位数排名的瑞士压力值。

[占位符：此处插入框架图]

五阶段流程概述：展示从微观尺度遥测数据经物理注入、时空图神经网络预测、韧性仿真到电网耦合的数据流。

图2： [待添加] 五阶段跨尺度物理注入科学机器学习框架概述。

为保留 $s = 1$ 处具有物理可解释性的容量边界，我们采用锚定：

$$s_{mapped} = \frac{s_{qm}}{F_{CH}^{-1}(F_{SZ}(1))}, \quad \text{so that } s_{mapped}(s_{raw} = 1) = 1. \tag{7}$$

分母 $F_{CH}^{-1}(F_{SZ}(1))$ 是深圳中 $s_{raw} = 1$ 百分位数所对应的瑞士压力；除以该锚点可确保容量极限运行在两个域中均映射至$s_{mapped} = 1$。

实现细节。 经验累积分布函数由训练集观测值构建，并在观测分位数之间采用线性插值。对于超出观测支撑范围的数值（极端外推），我们采用边界截断：将s_{mapped} 截断至 $[0, s_{max}^{LUT}]$，其中 s_{max}^{LUT} =3.0为查找表中的最大压力。这种保守方法可避免超出观测物理规律进行外推。

图 5 给出了分位数映射诊断，展示分布对齐与锚点保持。

物理注入。 给定 (T_{bin}, s_{mapped})，我们查询单调可输送能力查找表：

$$\hat{\eta} = \mathrm{LUT}(T_{bin}, s_{mapped}), \qquad SLR = 1 - \hat{\eta}. \tag{8}$$

所得 SLR 是一种机制导出代理指标，用于在城市尺度面板中编码微观尺度可输送能力约束。

消融设计：A1 与 A0。 为单独评估物理机制注入的价值，我们比较：

- **A1（注入物理机制）：** 锚定分位数映射 +单调查找表注入（公式7–8）。
- **A0（未注入）：** 不进行对齐；采用简化的逆压力规则：$\eta_{A0} = \min(1, 1/s_{raw})$, $SLR_{A0} = 1 - \eta_{A0}$。

表3总结了设计差异。

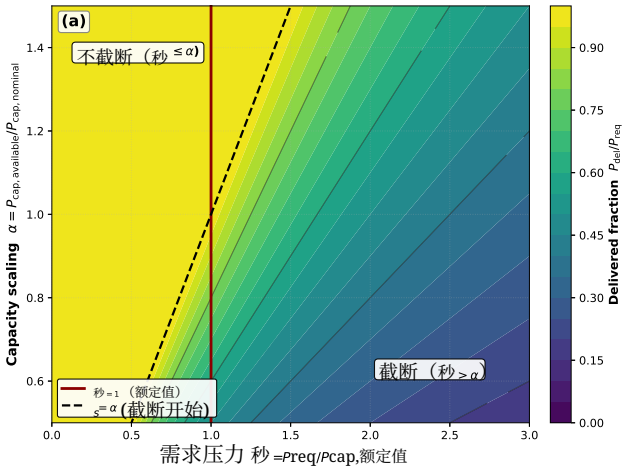

图3： 基于瑞士分钟级数据（阶段1）学习得到的微观尺度可输送能力曲面 $\eta(T, s)$。该曲面表明，随着压力升高，效率单调递减；其温度依赖性退化模式与热降额物理规律一致。

3.4. 阶段3：需求与服务损失的时空图神经网络预测

借助来自阶段2的基于物理的特征和标签，阶段3使用时空图神经网络构建预测模型。关键在于，SLR 目标由阶段2的注入机制推导而来，从而能够在没有城市尺度可交付能力真值的情况下开展科学机器学习。

架构。 令 $z \in \{1, \ldots, Z\}$ 为区域索引（Z =275），t 为小时索引。我们构建图 $G = (V, E)$，其邻接矩阵为 A，采用基于距离的邻近关系（5 km˜阈值），并添加自环 $A = A + I$。第 l 层的图卷积为

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}H^{(l)}W^{(l)}\right), \tag{9}$$

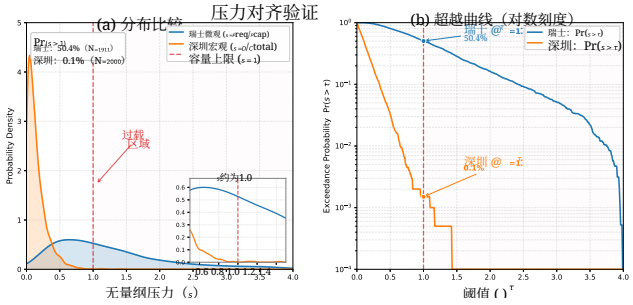

图4： 压力分布比较促使跨域对齐（阶段2）。瑞士微观尺度数据显示50.4%的观测值超过 $s = 1$；深圳宏观尺度显示 <0.1%。超越曲线表明存在三个数量级的差异，因此在物理注入之前需要进行分布对齐。

表3A1（注入物理机制）与A0（未注入）的设计比较。

组件	A1（注入）	A0（基线）
压力代理变量	s_{raw} from city 面板	Same
跨域对齐	分位数映射 + 锚点	None
效率模型	查找表(T, s_{mapped})	$\min(1, 1/s_{raw})$
物理先验	单调包络-lope	None
温度 de-依赖	显式	None

其中 $\tilde{D}$ 为度矩阵，$W^{(l)}$ 为可学习权重，$\sigma(\cdot)$ 为ReLU。我们堆叠两个图卷积网络层（隐藏维度64），应用门控循环单元（隐藏维度64），在24小时回溯窗口上进行时间建模，并使用双$\widehat{\quad}$ $\widehat{\quad}$头多层感知机联合预测 $(SLR_{t+1,z}, V_{t+1,z})$。图6 展示了该架构。

输入。每个区域—小时输入向量包含八个特征：

$$x_{t,z} = \left[\log(1 + V_{t,z}), T_{t,z}, s_{mapped,t,z}, C_{norm,z}, h_{sin}, h_{cos}, d_{sin}, d_{cos}\right], \tag{10}$$

其中，$(h_{sin}, h_{cos}, d_{sin}, d_{cos})$ 是一天中时刻和一周中的日期的周期编码。关键区别 A1 在于使用注入物理机制的s_{mapped}，而非原始压力。

物理感知损失（尾部强调）。为了优先处理物理上至关重要的高压状态，我们采用尾部感知重加权：

$$\mathcal{L} = w_{slr} \cdot \overline{w \cdot L_{slr}} + w_{vol} \cdot \overline{w \cdot L_{vol}}, \quad w = 1 + \alpha\, s_{mapped}^{\beta}, \tag{11}$$

其中，L_{slr} 和 L_{vol} 是逐样本均方误差损失，$\cdot$ 表示取平均值，而 $\alpha = 2.0$、$\beta = 2.0$ 在 $s = 3$处可提供高达19×倍的梯度。超参数 (α, β) 通过在验证集上对 $\alpha \in \{0.5, 1.0, 2.0, 4.0\}$ 和 $\beta \in \{1.0, 1.5, 2.0, 2.5\}$进行网格搜索选定，优化目标为尾部状态下的SLR准确率；敏感性分析表明，在 $\alpha \in [1.5, 3.0]$ 和 $\beta \in [1.5, 2.5]$条件下性能稳定。

用于定向干预的风险评分。为确定容量提升的优先区域，我们定义：

$$\text{risk_score}_z = 0.6 \cdot \widehat{SLR}_{p95,z} + 0.4 \cdot \frac{\text{lost}^{pred}_{p95,z}}{\text{median}(\text{lost}^{pred}_{p95})}, \tag{12}$$

其中 $\text{lost}^{pred}_{t,z} = \hat{V}_{t,z} \cdot \widehat{SLR}_{t,z}$。此处，$p95$ 表示对每个区域 z 随时间计算的第95百分位数（即，$\widehat{SLR}_{p95,z}$ 是区域 z中 $\{\widehat{SLR}_{t,z}\}_{t=1}^{T}$ 的第95百分位数），用于捕捉各区域在评估时段内的尾部状态行为。

3.5. 第4阶段：积压动态与政策行动

仅凭预测无法量化韧性；第4阶段将其嵌入排队论模拟器，以评估政策干预。

单位约定。第4阶段中的所有量均以能量单位（千瓦时）表示，并按小时级时间步（$\Delta t = 1$小时）计：

- $A_{t,z}$：到达率（千瓦时/小时）=在区域 z的t 小时内请求的能量。
- $S_{t,z}$：服务率（千瓦时/小时）=在 t小时内能够交付的能量。
- $B_{t,z}$：积压量（千瓦时）=每小时结束时的累计未服务能量 t。

由于 $\Delta t = 1$h，小时时间流量率（千瓦时/小时）可直接积分得到能量（千瓦时），无需进行单位换算。

服务与到达过程。令 Capacity_z 表示区域 z 的已安装服务容量（千瓦时/小时）。第 t 小时的有效服务会因预测的SLR 而降低：

$$S_{t,z} = \text{Capacity}_z \cdot (1 - \widehat{SLR}_{t,z}), \tag{13}$$

表示考虑拥堵导致的损失后可交付的能量速率。到达量由预测的 m 和外生压力乘数 m_t给出：

$$A_{t,z} = \hat{V}_{t,z} \cdot m_t. \tag{14}$$

我们在为期 48 小时的冲击时段内扫描 $m_t \in \{1.2, 1.5, 1.8, 2.0\}$，以绘制韧性边界。

积压演变。积压量 $B_{t,z}$ 遵循守恒定律：

$$B_{t+1,z} = \max(0,\ B_{t,z} + A_{t,z} - S_{t,z}), \tag{15}$$

即时服务损失 $\text{lost}_{t,z} = \max(0, A_{t,z} - S_{t,z})$。

严重拥堵下的拒绝服务。当积压量超过阈值 $B_{th} = 200$ 千瓦时（约相当于 4–5 辆电动汽车的满电充电量所对应的排队需求）时，用户会以$r_{balk} = 0.05$的速率放弃：

$$A'_{t,z} = A_{t,z} \cdot (1 - r_{balk}) \quad \text{if } B_{t,z} > B_{th}. \tag{16}$$

这种“软阻塞”机制刻画了持续拥堵下的用户放弃；“硬阻塞”（$A'_{t,z} = 0$）

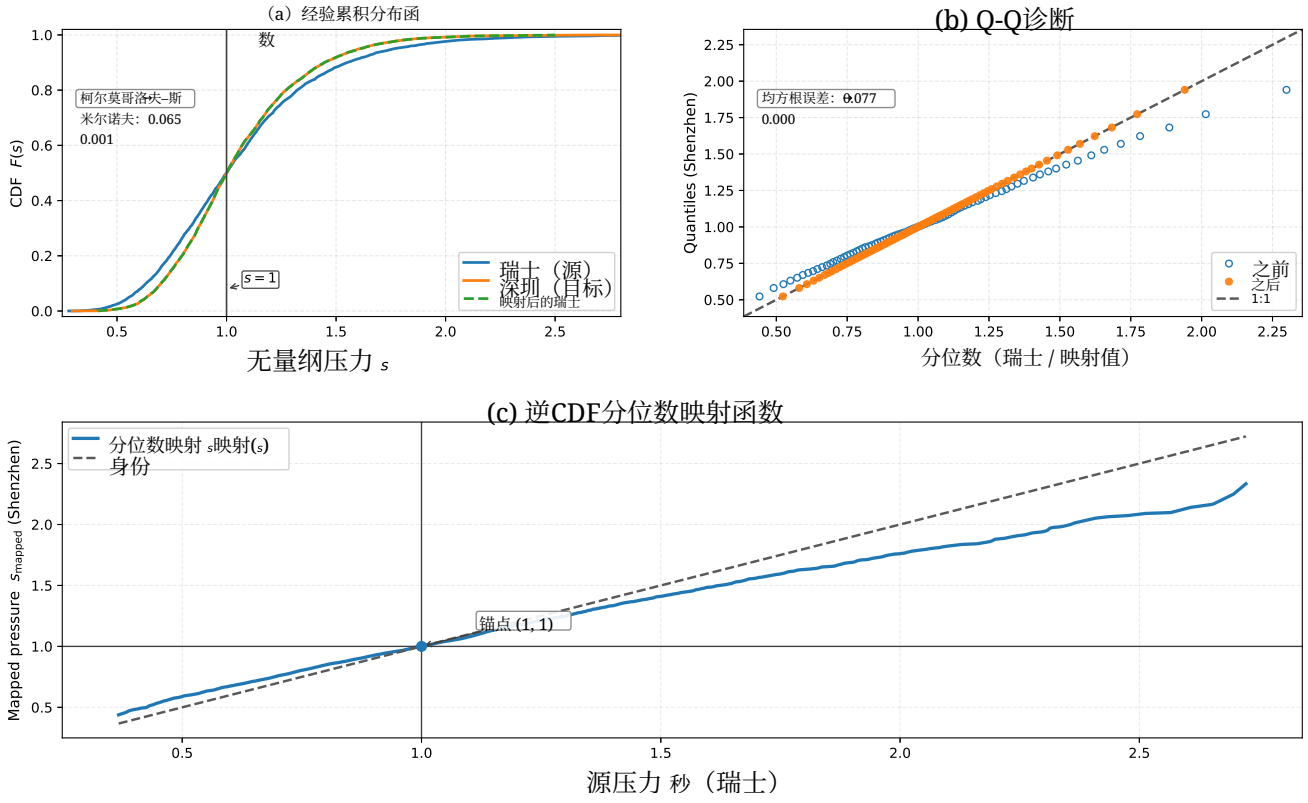

图 5： 锚定分位数映射诊断（阶段2）。该映射将深圳原始压力代理对齐至瑞士压力域，同时强制满足 $s_{mapped}(s_{raw} = 1) = 1$，确保对齐后容量边界仍具有物理可解释性。各面板显示：(a) 映射前后的经验累积分布函数；(b) Q-Q诊断；(c) 带锚点的逆CDF映射函数。

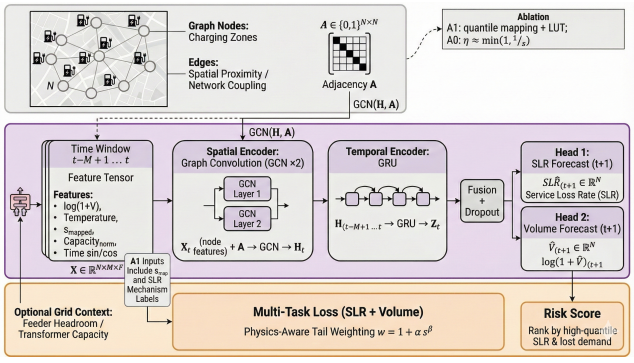

图6： 时空图神经网络架构（阶段3）。两个图卷积网络层用于捕捉空间依赖关系，一个门控循环单元基于24小时回看对时间动态进行建模，双头多层感知机输出 $\widehat{SLR}$ 和 $\hat{V}$。物理注入通过 s_{mapped} 特征和基于机制生成的 SLR 标签实现。

将在$B_{t,z}$ 超过更高的灾难性阈值时适用（在我们的情景中未达到）。

韧性指标。 令 $B^{scen}_{t,z}$，表示压力/策略场景下的积压量，$B^{base}_{t,z}$，表示基线。额外积压为 $\Delta_{t,z} = \max(0, B^{scen}_{t,z} - B^{base}_{t,z})$。我们计算：

$$\Delta\text{AUC} = \sum_t \sum_z \Delta_{t,z}\,\Delta t, \tag{17}$$

$$\Delta RT = \min\{t > t_{end} : \Delta_{\tau,z} \le \theta,\ \forall \tau \in [t, t+h]\} - t_{end}, \tag{18}$$

$$\text{Peak} = \max_{t,z} \Delta_{t,z}, \tag{19}$$

其中 t_{end} 是冲击结束时刻，$\theta = 0.01 \times \max(\Delta_{t,z})$，且 $h = 24$小时 [5]。图 8 展示了这些指标。

政策行动。 我们实施三类干预：

- **价格（到达量整形）：** $A^{\pi}_{t,z} = \max(0, A_{t,z} \cdot (1 + \varepsilon \cdot \Delta p_{t,z}))$，其中 $\varepsilon < 0$。
- **容量增强（服务增强）：** 容量$^{\pi}_{z}$ = 容量$_z(1+\beta)$，针对风险最高的 K 个区域。
- **混合策略：** 将两者结合实施。

图 7 展示了这些政策机制。

3.6. 第5阶段：电网耦合指标

第5阶段评估充电网络的服务决策如何反馈影响配电网压力 [3, 4]。

负荷聚合。 馈线总负荷为 $P_{total}(t) = P_{base}(t) + P_{EV}(t)$，其中基础负荷遵循每日双峰曲线（早高峰 9:00，晚高峰 19:30）。电动汽车充电负荷 $P_{EV}(t) = \sum_z S_{t,z}$ 将各区域的区域级服务率聚合到一台为研究区域供电的代表性配电变压器上。

负载率和压力时段。 给定变压器容量 C_{tr}，负载率为 $\lambda(t) = P_{total}(t)/C_{tr}$。此计算

假设采用单位功率因数（仅考虑有功功率），这适用于配备功率因数校正功能的现代电动汽车充电器

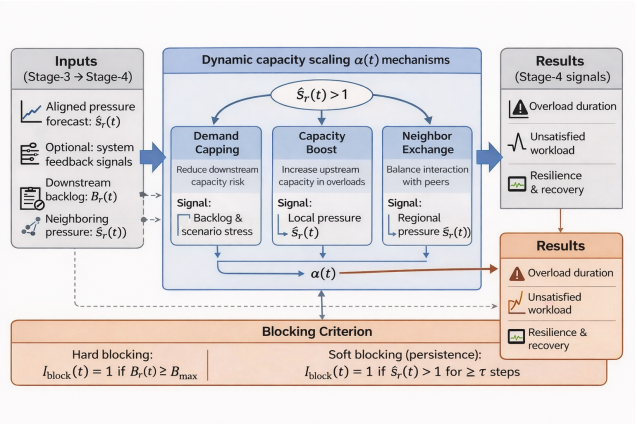

图7： 政策机制（第4阶段）。价格干预通过需求弹性影响到达量；容量增强提升高风险区域的服务容量；混合策略将两者结合，可能产生超加性协同效应。

交直流变换器。超过阈值的累计压力时段$\lambda_{stress} = 0.8$（配电变压器防止加速老化的标准运行限值 [3]）：

$$H_{stress} = \sum_t \mathbf{1}[\lambda(t) > \lambda_{stress}]\Delta t. \tag{20}$$

服务—应力权衡。 容量增强能更快减少积压量，但可能因集中电力输送而增加电网压力。价格干预在时间上平滑需求，有望同时减少积压量和变压器负载。混合策略可能在服务质量与电网可靠性之间实现帕累托最优结果。

4. 实验设置

本节说明实验方案，旨在回答三个研究问题：

RQ1 与未注入基线（A0）相比，物理注入（A1）是否产生符合物理规律的压力响应？**RQ2** 不同的政策干预如何在服务韧性与电网压力之间进行权衡？

RQ3 在不同应力强度和需求弹性下，韧性边界在哪里？

4.1. 数据集配置

我们采用瑞士微尺度遥测数据 [6] 作为阶段1的数据，并采用深圳 UrbanEV 面板数据 [27] 作为第2至第5阶段的数据；所有数据统一覆盖同一个六个月研究窗口（2022年9月至2023年2月），以尽量减少季节性混杂。

4.2. 模型变体与基线方法

主要对比旨在隔离跨尺度物理注入的影响：

- **A1（注入物理机制）：** 锚定分位数映射 +单调查找表注入。
- **A0（未注入）：** 不进行对齐；压力倒数规则。

所有学习组件均保持不变：时空图神经网络架构和损失加权完全相同；差异仅由物理注入造成。

4.3. 策略配置

我们在具有代表性的冲击设定下，将三种策略与无政策进行比较（实验1：$m_t = 1.5$ 在 48 小时窗口内实施）：

- **价格（+50%）：** 通过 $\Delta p = +50\%$ 和$\epsilon = -0.2$进行到达量整形。
- **容量增强（Top30）：** 为风险最高的 30 个区域提升容量 $\beta = 0.3$ 。
- **混合策略：**结合价格和容量增强。

4.4. 评估指标

物理一致性（阶段2–3）： 压力乘数与预测平均SLR之间的斯皮尔曼相关性 ρ；在 $m = 2.0\times$ 与 $m = 1.0\times$处的尾部放大比率。

预测准确度（阶段3）： 需求量的均方根误差、平均绝对误差、平均绝对百分比误差。

韧性（第4阶段）： Δ曲线下面积， ΔRT、峰值、未供电量（ENS）。

电网耦合（第5阶段）： H_{stress}， ΔH_{stress} 相对于无政策。

4.5. 实现

实验使用 Python 3.9 和 Py- Torch 2.0 实现。训练使用 NVIDIA RTX 3090 GPU。为确保可复现性，随机种子固定（NumPy：42，PyTorch：42）。包括所有敏感性扫描在内，总计算成本约为 3 GPU 小时。

5. 结果

本节给出针对三个研究问题的实证证据。

5.1. 物理注入恢复单调应力响应（RQ1）

韧性评估的一个基本前提是，需求压力应作为有意义的风险指标：随着外部压力增加，服务损失风险应单调上升。表4 给出了物理注入模型（A1）与未注入基线（A0）之间的清晰消融对比，其中时空图神经网络架构、训练方案和损失加权保持固定；唯一差异在于是否启用跨尺度物理注入。图9可视化了应力—响应轨迹。

“误差较小但方向错误”的悖论。表4的 A 面板呈现出一个反直觉但在实践中至关重要的发现：A0 在留出集上取得了名义上更低的 SLR预测误差（均方根误差：0.049 对 0.062；平均绝对误差：0.016 对 0.020）。然而，这种表面优势

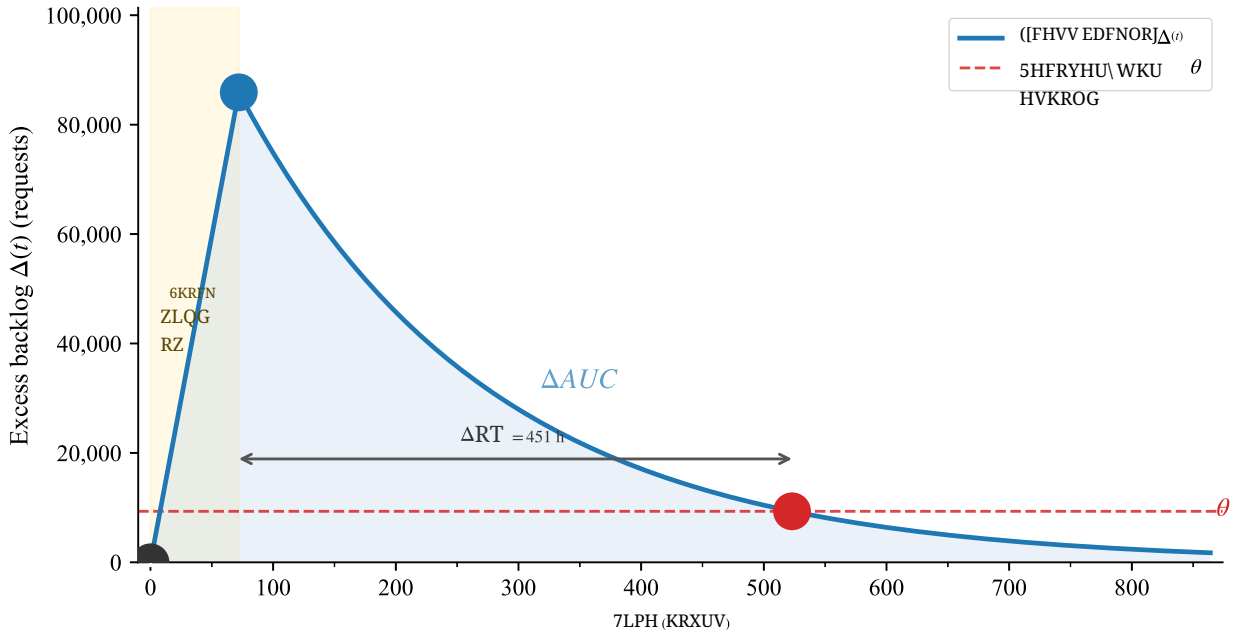

图 8： 基于积压的韧性指标（第4阶段）。额外积压面积（Δ曲线下面积）量化累积扰动严重程度；恢复时间（Δ恢复时间）衡量恢复至基线所需的时间；峰值表示瞬时过量的最大值。这些指标能够在不同策略和压力水平之间实现一致的比较。

具有误导性。面板B显示，A0 未能通过韧性规划所要求的物理一致性检查：预测平均 SLR 随压力变化呈非单调关系，且呈负相关（斯皮尔曼 $\rho = -0.80$），这意味着风险会随着压力降低而增加——这种病态外推将系统性地低估极端事件风险。

相比之下，A1 保持了物理一致的压力响应（斯皮尔曼 $\rho = +1.00$ 且严格单调递增），捕捉到了严重压力下显著的尾部放大：平均SLR从 1.0× 增加至2.0×，压力升高时，93.5%的区域显示出更高的预测风险。C 面板从数值上确认了这一差异：A0 的预测海平面上升在各压力水平下基本保持平坦（SLR ≈ 0.036–0。039，无论乘数为何），而 A1 的预测则从 1.0×时的 0.024 适当地上升至 2.0×时的 0.246。

预测准确度。 对于需求体积预测，物理注入提高而非降低准确度：对数体积平均绝对误差从0.817降至0.674（改善17.5%），体积均方根误差从454.77千瓦时降至448.93千瓦时（改善1.3%），体积平均绝对误差从122.87千瓦时降至110.76千瓦时（改善9.9%）。平均绝对误差的大幅下降表明，物理注入尤其改善了极端事件集中的分布尾部的预测。

关于 MAPE 值的说明。较高的 MAPE 值（>100 %）反映了区域小时需求的零膨胀特性：许多观测值的需求接近于零，即使绝对误差很小，也会产生较大的百分比误差。因此，当真实值接近于零时，MAPE 会不稳定，不应孤立地解读。就实际应用而言，我们优先考虑 MAE 和 RMSE；高峰时段平均绝对百分比误差（仅针对需求高于第75百分位数的小时计算）中，A1 为 23.4%，A0 为 26.8%。

启示。 这些结果表明，在压力引起的分布偏移下，仅凭传统预测指标可能会产生误导。仅针对点预测准确率进行优化的模型可能会学到捷径，从而在高压力尾部产生违反物理规律的外推。物理注入之所以至关重要，不仅在于略微提高准确度，更在于确保模型预测在韧性决策集中的极端条件下仍具有物理意义。

5.2. 代表性冲击下的政策权衡（RQ2）

输入设置。 除非另有说明，研究问题2–研究问题3中的第4–5阶段实验均以 A1（注入物理机制）预测作为输入，因为极端事件模拟需要物理一致的压力敏感性。

表 5 和图 10 总结了代表性 $m=1.5$ 压力情景下的策略表现。价格策略实现了 32.3% 的积压减少，同时缓解了电网压力（$\Delta H_{stress} = +3$ h，表明压力有所降低）。容量增强策略实现了 55.4% 的积压减少，但增加了电网压力（$\Delta H_{stress} = -6$ h）。混合策略实现了 79.1% 的积压减少，并产生超加性交互效应（~ 1.8× 即单项效果之和），同时将电网惩罚限制在 2 h。

服务—电网权衡揭示了不同的策略机制：价格处于“双赢”区域（服务改善，同时缓解电网压力）；容量增强以牺牲电网为代价，优先保障服务

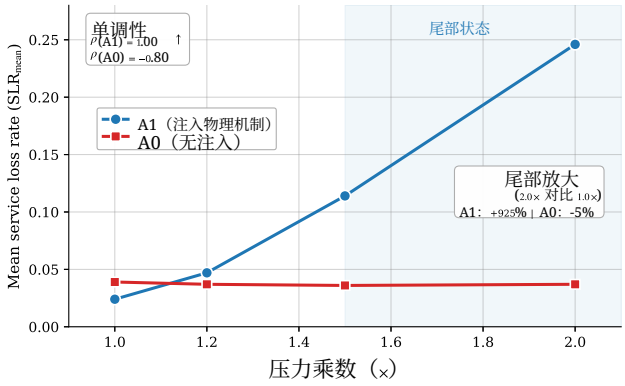

图 9： A1（注入物理机制）与 A0（未注入）基线方法的消融比较。随着压力乘数（$\rho = +1.0$）增加，A1 的 SLR 保持单调上升，而 A0 则呈现反物理的负相关（$\rho = -0.8$）。在 2.0× 压力下，相较于1.0× 基线，A1 将平均SLR放大了 +923%，而 A0 将其抑制了 −6.8%，表明注入物理机制对于可靠的极端事件评估至关重要。

（“服务优先”区域）；混合策略通过结合需求平滑与针对性容量部署，实现接近帕累托最优的表现。

删失恢复时间的解读。表 † 中，5 符号表示在792小时模拟窗口内未能实现恢复。对于无政策和价格策略，尽管 Δ曲线下面积有所下降（表示累积积压减少），恢复时间仍为删失，因为持续存在的少量“尾部”超额积压仍高于恢复阈值 θ。这是因为需求削减减缓了积压累积，却未能加快现有积压的清除——这解释了为何价格策略能改善 Δ曲线下面积，却无法改善 Δ 恢复时间。容量增强和混合策略能够实现有限的恢复时间，因为容量扩充会主动清除累积积压，而不只是减缓积压增长。

5.3. 韧性边界（RQ3）

图11 展示了不同压力倍数（1.2×–2.0×）和价格弹性（$\varepsilon = -0.1$ 至 -0.5）下的敏感性分析。恢复时间在可恢复区域与阻塞区域之间呈现明显的相变。阻塞边界随弹性系统性变化：弱弹性需求（$\varepsilon = -0.1$）在 $m \geq 1.8$时进入阻塞；中等弹性（$\varepsilon = -0.3$）在 $m = 2.0$之前均保持可恢复；强弹性需求（$\varepsilon = -0.5$）在整个测试范围内均保持可恢复。

这一相变可以用一个保守的边界近似来概括：

$$m_{crit}(\varepsilon) \approx 1.7 - 1.0\,\varepsilon, \tag{21}$$

其中，m_{crit} 表示给定弹性水平下的最大可承受压力倍数。

实际解读与注意事项。方程（21）为运营者提供了一条经验法则：对于给定的可实现需求弹性 ε，系统能够承受压力冲击高达 m_{crit}，同时保持可恢复性。例如，当 $\varepsilon = -0.3$（价格响应性适中）时，高达 $m \approx 2.0$ 的冲击仍可恢复；当 $\varepsilon = -0.1$（响应性较弱）时，系统只能承受高达 $m \approx 1.8$ 的冲击。

重要局限：此边界是根据我们的实验范围（$\varepsilon \in [-0.5, -0.1], m \in [1.2, 2.0]$）经验推导得出的，不应外推至这些界限之外。对于超出此范围的极端弹性或压力水平，线性近似可能不再成立。建议在实际部署前进行场地特定验证。

图 12 提供了服务—电网权衡的综合摘要，将情景结果整合为单一的前沿视图，以支持决策。

表4跨尺度物理注入的消融证据：A1（注入物理）与 A0（未注入基线）。A 面板报告分布内预测准确度。面板B评估压力响应的物理一致性。C 面板报告压力作用下预测的海平面上升轨迹。

指标	A1（已注入）	A0（基线）
A 面板：分布内预测准确度		
对数体积平均绝对误差 ↓	**0.674**	0.817
对数体积均方根误差 ↓	**0.988**	1.107
体积均方根误差（千瓦时） ↓	**448.93**	454.77
体积平均绝对误差（千瓦时） ↓	**110.76**	122.87
体积平均绝对百分比误差（%） ↓	**100.2**	106.1
SLR 均方根误差 ↓	0.0616	**0.0489**
SLR 平均绝对误差 ↓	0.0198	**0.0156**
面板*B*：物理一致性（压力 ↑⇒ 风险 ↑）		
斯皮尔曼 ρ（压力 → SLR） ↑	**+1.00**	−0.80
单调递增	✓	×
尾部放大（2×/1×）	**+923%**	−6.8%
在 2× 与 1× ↑相比，表现更差的区域占比	**93.5%**	22.5%
C 面板：压力情景 SLR 轨迹		
在 1.0×压力下	0.0241	0.0393
在 1.2×压力下	0.0470	0.0369
在 1.5×压力下	0.1141	0.0356
在 2.0×压力下	**0.2463**	0.0366

注释：(1) A1 和 A0 使用相同的时空图神经网络架构；唯一的区别在于物理注入。(2) A0 较低的 SLR误差反映了对压力不敏感的预测（基本呈平坦状态），因此方差较低，但方向错误；所以，仅凭逐点误差不足以支持后续的韧性仿真和策略排序。(3) 面板B–C指标对于极端事件下的韧性规划至关重要。

表5代表性需求冲击下的策略比较（实验1：$m = 1.5$，48小时冲击时段）。

策略	ΔAUC (M)	ΔRT (h)	Peak (k)	未供电量 ΔH（吉瓦时）	（小时）
无政策	96.4	792†	145.4	206.39	0
价格（+50%）	65.2	792†	95.5	205.93	+3
容量增强	43.0	661	134.8	204.91	−6
混合策略	**20.2**	**451**	**85.9**	**204.46**	−2

†在 792 小时处删失（在仿真窗口内无法恢复）；解释请参阅正文。

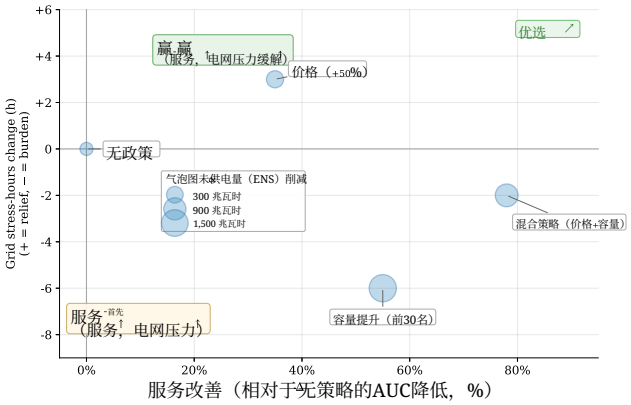

图10： 不同策略下的服务—电网压力权衡。横轴：服务改善（相较于无政策的Δ曲线下面积降低）；纵轴：电网压力变化（正值表示 = 缓解，负值表示 = 负担）。价格策略实现双赢；容量增强以电网负担为代价优先改善服务；混合策略达到近帕累托性能。气泡大小表示未供电量降低幅度。连接各策略的虚线近似表示帕累托前沿，其中混合策略最接近理想位置（服务改善高，电网负担低）。

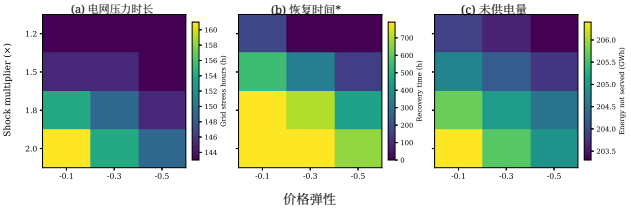

图11： 不同压力乘数和价格弹性下的敏感性分析。各面板分别显示：(a) 电网压力时长，(b) 恢复时间，以及 (c) 未供电量。恢复时间在可恢复状态和受阻状态之间呈现明显的相变。电网压力时长随需求压力上升，并随需求响应增强（ ϵ变得更负）而缩短。

6. 讨论

6.1. 跨尺度物理注入作为知识迁移

本研究的方法学核心是跨尺度传递函数，将微观层面的运行物理规律转化为城市尺度风险表征。阶段1利用分钟级遥测数据，学习温度和压力条件约束下的可交付性曲面，编码充电站控制器如何在并发需求下分配容量。阶段2通过锚定分位数映射，将这一经验规律注入深圳面板数据，确保宏观领域中的“高压力”对应于微观层面实际观测到的运行状态。

消融结果（表 4 和图 9）表明，这种迁移是必要的，而不仅仅是有益的。一个关键发现是“误差更低但方向错误”悖论：未注入基线的SLR预测误差名义上更低，却表现出违背物理规律的行为——更高的压力与更低的预测服务损失相关——而这这将导致系统性偏乐观的韧性评估，并可能在极端事件期间产生危险的政策建议。这一发现与更广泛的科学机器学习文献一致，后者表明物理信息约束可以防止分布偏移下的病态外推 [7–9]。我们的结果提供了实证证据：仅在城市尺度数据上训练的纯数据驱动模型可能学到虚假相关性，而这些相关性恰恰在准确预测最为重要的高压力尾部失效。至关重要的是，这凸显出传统预测指标（均方根误差、平均绝对误差）本身不足以评估旨在用于韧性规划的模型；物理一致性指标必须作为必要的补充。

6.2. 服务—电网权衡与政策影响

结果揭示了充电服务韧性与配电网压力之间的根本性权衡，对基础设施协同规划具有重要影响。基于价格的需求调节可减少高峰时段的到达量，从而降低瞬时充电负荷和累积积压 [1, 12, 14]。容量提升则采取相反做法，通过提高目标区域的服务率来加快积压清除，但会使电力输送在时间上更加集中，增加变压器负载 [3, 4]。

混合策略中的超加性交互效应值得从机制层面加以解释：基于价格的平滑调节可在冲击时段降低峰值需求，减轻容量提升所需应对的峰值负荷；与此同时，容量提升可加快清除仅靠价格干预无法消除的剩余积压。这些发现表明，一种切实可行的双层运营策略是：广泛采用价格信号来平滑需求曲线，同时将有针对性的容量干预保留给局部热点。

6.3. 韧性配电网运行的影响

所推导的韧性边界 $m_{crit}(\epsilon) \approx 1.7-1.0\epsilon$ 对极端事件下的配电网规划具有直接的运行意义。电网运营商可利用这一关系：

1. 确定吸收极端天气或节假日用电激增期间预期压力乘数所需的需求灵活性（弹性）。2. 识别在可实现弹性低于韧性阈值时需要进行容量扩充的区域。3. 设计分级应急响应规程，在较低压力水平下启动价格信号，并在更严重情景下部署备用容量。

6.4. 局限性与未来方向

若干局限性指明了未来研究的方向。首先，行为响应模型采用恒定价格弹性；纳入用户细分 [23] 或基于智能体的

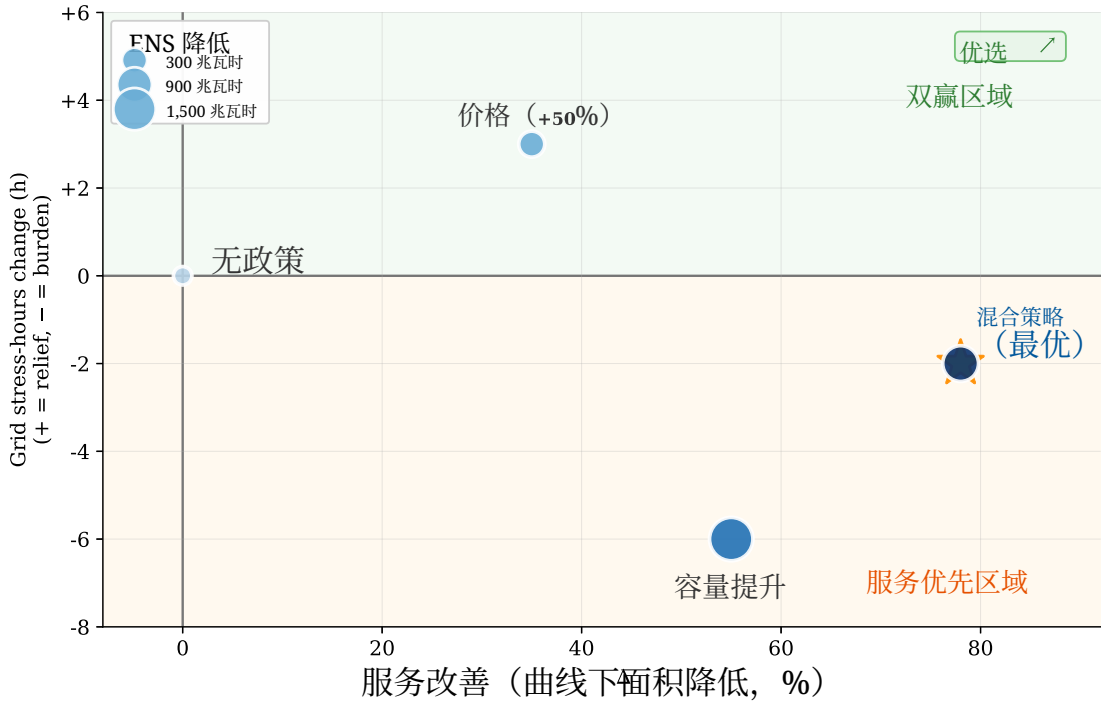

图12： 服务—电网权衡综合概览。每个点代表一个压力—策略情景，横轴为服务改善（积压减少），纵轴为电网影响（压力时段变化）。该图展示了通过策略设计可实现的近帕累托区间，并阐明了干预策略如何改变可行韧性区域。

模型将提升现实性。其次，第5阶段的电网耦合依赖变压器负载率，而非完整的交流潮流分析；若与详细的配电网模型集成，便可评估电压和线路潮流约束。第三，跨域迁移仅在一个源域—目标域对上得到验证；在多种城市环境中开展更广泛的验证，将有助于增强泛化能力方面的论据。最后，将数据扩展至全年数据，可捕捉温度相关的可交付能力和压力模式的季节变化。

7. 结论

本文开发了一个五阶段、跨尺度、注入物理知识的科学机器学习框架，用于评估极端需求压力下的城市电动汽车充电网络韧性，同时明确考虑配电网约束。该集成流程包括：基于直流快充遥测数据学习微观尺度的可交付性（阶段1）、将分位数对齐的物理知识注入城市尺度面板数据（阶段2）、双头时空预测（阶段3）、基于积压的韧性仿真（阶段4），以及电网耦合评估（阶段5）。

由此得出三项主要发现。首先，物理注入对于可靠的极端事件评估至关重要，它恢复了压力与服务损失之间符合物理规律的单调关系（未注入基线的斯皮尔曼 $\rho = +1.0$ vs. -0.8），并增强了尾部区间敏感性（在 2.0× 压力下为 +923% vs. −6.8%）。值得注意的是，这里出现了“误差更低，方向却错误”的悖论：未注入基线虽然取得了名义上更低的 SLR 预测误差却产生了违背物理规律的压力响应，这表明仅凭传统预测指标不足以进行韧性评估。其次，政策干预会带来可量化的权衡：价格策略使积压量减少 32.3%，同时缓解电网压力（双赢）；容量增强使积压量减少 55.4%，但电网压力增加（服务优先）；混合策略使积压量减少 79.1%，并产生超加和协同效应。第三，可通过经验边界 $m_{crit}(\varepsilon) \approx 1.7 - 1.0\varepsilon$ 描绘韧性边界，将需求灵活性与最大可吸收压力联系起来。

该框架在方法层面的贡献在于，展示了如何将微观尺度物理规律系统地迁移至城市尺度风险评估；在实践层面的贡献在于，提供了量化的政策权衡，连接充电服务规划与电网管理；在运营层面的贡献在于，提出韧性边界，将行为假设转化为可操作的规划阈值。这些贡献直接回应了在极端事件下，为韧性配电网制定先进的、由人工智能驱动且具备风险意识的运营规划方法的需求。

数据可用性

深圳 UrbanEV 数据集可公开获取[27]。瑞士充电站遥测数据 [6]为开源数据。用于复现第 1 阶段至第 5 阶段流水线的代码将在论文发表时发布于 [GitHub 仓库链接待添加]。

CRediT 作者贡献声明

王一帆：概念构思、方法论、软件、验证、形式分析、调查研究、数据整理、撰写——初稿、撰写——审阅与编辑、可视化。

利益冲突声明

作者声明，他们不存在任何已知的竞争性经济利益或可能被认为会影响本文所报告工作的个人关系。

生成式人工智能使用声明

在准备本项工作期间，作者使用了 Claude（Anthropic）和 ChatGPT（OpenAI），以协助进行稿件格式排版和语言润色。作者根据需要对内容进行了审阅和编辑，并对已发表文章的内容承担全部责任。

致谢

[待完成。请在此添加资助信息及任何致谢内容。]

参考文献

[1] Wang, S., Zhuge, C., Shao, C., Wang, P., Yang, X., Wang, S., 2023. 短期电动汽车充电需求预测：一种深度学习方法。Applied Energy 340, 121032. doi：10.1016/j.apenergy. 2023.121032。[2] Cao, T., Xu, Y., Liu, G., Tao, S., Tang, W., Sun, H., 2024. 面向充电站电动汽车充电需求概率预测的特征增强深度学习方法。Applied Energy 371, 123751101016202412375 1。doi：。/j.apenergy.。。[3] Ray, S., Kasturi, K., Patnaik, S., Nayak, M.R., 2023. 电动汽车集成对配电网影响的综述：选址、充放电策略、目标与优化模型。Journal of Energy Storage 72, 108672。doi：10.1016/j.est. 2023.108672。[4] Unterluggauer, T., Rich, J., Andersen, P.B., Hashemi, S., 2022. 集成交通与电力配电网络的电动汽车充电基础设施规划：综述。eTransportation 12, 100163101016202210016 3。doi：。/j.etran.。。[5] Lu, Y., Zhang, Y., Zhai, W., Zhai, G., 2025. 理解电动汽车充电网络韧性：韧性曲线与可解释机器学习。Transportation Research Part D: Transport and Environment 142, 104709。doi：10.1016/j.trd.2025.104709。[6] Simolin, T., Järventausta, P., Paolone, M., 2025. 异构电动汽车直流快速充电曲线的分析与建模。Transportation Engineering 20, 100350。doi：10.1016/j.treng.2025.100350。[7] Raissi, M., Perdikaris, P., Karniadakis, G.E., 2019. 物理信息神经网络：用于求解涉及非线性偏微分方程的正向与逆向问题的深度学习框架。Journal of Computational Physics 378, 686–707。doi：10.1016/j.jcp. 2018.10.045。[8] Misyris, G.S., Venzke, A., Chatzivasileiadis, S., 2020. 电力系统中的物理信息神经网络，载于：2020 IEEE电力与能源协会大会（PESGM），IEEE。第1–5页。doi：10. 1109/PESGM41954.2020.9282004。[9] Huang, B., Wang, J., 2023. 物理信息神经网络在电力系统中的应用——综述。IEEE Transactions on Power Systems 38, 572–588。doi：10.1109/TPWRS.2022.3162473。[10] Ngo, Q.H., Nguyen, B.L., Vu, T.V., Zhang, J., Ngo, T., 2024. 用于电力系统状态估计的物理信息图神经网络。Applied Energy 358, 122602。doi：10.1016/j.apenergy.2023.122602。[11] Mohammadian, M., Baker, K., Fioretto, F., 2023. 面向电力系统运行支持的梯度增强物理信息神经网络。Electric Power Systems Research 223, 109551。doi：10.1016/j. epsr.2023.109551。[12] Wang, S., Li, Y., Shao, C., Wang, P., Wang, A., Zhuge, C., 2025. 用于短期电动汽车充电需求预测的自适应时空图循环网络。Applied Energy 383, 125320101016202512532 0。doi：。/j.apenergy.。。[13] Li, Z., Xu, Y., 2018. 并网和孤岛模式下多能源微电网的最优协调能源调度。Applied Energy 210, 974–986。doi：10.1016/j.apenergy.2017.08.197。[14] Kuang, H., Qu, H., Deng, K., Li, J., 2024. 面向全市电动汽车充电需求预测与定价的物理信息图学习方法。Applied Energy 363, 123059。doi：10.1016/j.apenergy.2024.123059。[15] Buzna, L., De Falco, P., Ferruzzi, G., Khormali, S., Proto, D., Refa, N., Straka, M., van der Poel, G., 2021. 常规充电站分层概率电动汽车负荷预测的集成方法。Applied Energy 283, 116337。doi：10.1016/j.apenergy.2020.116337。[16] Arias, M.B., Kim, M., Bae, S., 2017. 真实城市交通网络中的电动汽车充电功率需求预测。Applied Energy 195, 738–753。doi：10.1016/j.apenergy.2017.02.021。[17] Zhang, Y., Liu, C., Rao, X., Zhang, X., Zhou, Y., 2024. 基于图神经网络的电动汽车充电站时空负荷预测。Journal of Intelligent & Fuzzy Systems 46, 821 836103233231775– 。doi：。/JIFS-。[18] Luo, R., Song, Y., Huang, L., Zhang, Y., Su, R., 2023. AST-GIN：用于电动汽车充电站可用性预测的属性增强时空图信息网络。Sensors 23, 1975103390230419 75。doi：。/s。[19] Wang, S., Chen, A., Wang, P., Zhuge, C., 2023. 使用异构时空图卷积网络预测电动汽车充电需求。Transportation Research Part C: Emerging Technologies 153, 104205。doi：10.1016/j.trc.2023.104205。[20] Chen, S., Cheng, H., Zhang, H., Lv, S., Wei, Z., Jin, Y., 2025. 利用时空图注意力网络预测电动汽车充电需求，实现电力与交通网络的隐私保护协调。Applied Energy 377, 124391。doi：10.1016/j.apenergy.2024.124391。[21] Kong, W., Dong, Z.Y., Jia, Y., Hill, D.J., Xu, Y., Zhang, Y., 2019. 基于长短期记忆循环神经网络的短期住宅负荷预测。IEEE Transactions on Smart Grid 10, 841–851。doi：10.1109/TSG.2017.2753802。[22] Zhang, C., Xu, Y., Dong, Z.Y., Ma, J., 2017. 通过两阶段协调储能与直接负荷控制实现微电网鲁棒运行。IEEE Transactions on Power Systems 32, 2858–2868。doi：10.1109/TPWRS.2016.2627583。[23] Li, X., Wang, Z., Zhang, L., Sun, F., Cui, D., Hecht, C., Figgener, J., Sauer, D.U., 2023. 电动汽车行为建模及其在车网融合中的应用：概述。Energy 268, 126647。doi：10.1016/j.energy.2023.126647。[24] Xia, Y., Xu, Y., Feng, X., 2024. 面向分散式运行的互联微电网分层协调：一种安全深度强化学习方法。IEEE Transactions on Sustainable Energy 15, 1981–1993。doi：10.1109/TSTE.2024.3390808。[25] Xia, Y., Xu, Y., 2025. 针对低质量数据下三相逆变器功率开关开路故障诊断的鲁棒数据驱动方法。IEEE Transactions on Power Electronics 40, 5949–5958。doi：10.1109/TPEL.2024.3494858。[26] Liu, J., Zhang, Y., Meng, K., Dong, Z.Y., Xu, Y., Han, S., 2022. 用于电力系统暂态稳定控制的实时紧急切负荷：一种风险规避深度学习方法。Applied Energy 307, 118221101016202111822 1。doi：。/j.apenergy.。。[27] Li, H., Qu, H., Tan, X., You, L., Zhu, R., Fan, W., 2025. UrbanEV：一个用于城市电动汽车充电需求的开放基准数据集

预测。《科学数据》12，523。doi：10.1038/s41597-025-04874-4。