

通信基站虚拟电厂能源智能调度优化：基于 LSTM 预测与强化学习决策的协同框架

Smart Energy Dispatch for Telecommunication Base Station Virtual Power Plants: An LSTM–Reinforcement Learning Framework

林禄辉 Lin Luhui¹

Abstract

With the continuous increase in the integration level of renewable energy, virtual power plants (VPPs) have become an important mechanism for supporting grid flexibility and coordinating distributed energy resources. Accurate power scheduling is critical to realizing efficient energy management and minimizing operating costs for virtual power plants. This paper proposes a deep-learning-based power scheduling method for virtual power plant services of communication base stations. By integrating long short-term memory (LSTM) networks and reinforcement learning technologies, an integrated “prediction-decision” optimization framework is constructed. The LSTM network is adopted to mine the time-series dependence characteristics of power demand and achieve high-accuracy power demand forecasting. Reinforcement learning is applied to dynamically optimize the energy scheduling strategy of base stations to realize the optimal balance between reducing operating costs and improving energy sustainability. Experimental results demonstrate that the proposed model outperforms conventional methods in terms of prediction accuracy and operational efficiency. It can effectively cut the operating costs of virtual power plants and improve energy utilization efficiency. This study provides a prediction-decision framework for energy management of virtual power plants built upon distributed communication base-station resources and is of great significance for constructing a more resilient and sustainable new-type power system.

Keywords: virtual power plant; power scheduling; energy dispatching; LSTM model; reinforcement learning

摘要：随着可再生能源整合程度的持续提升，虚拟电厂（VPPs）已成为保障电网稳定运行、优化能源资源配置的重要聚合机制。精准的电力调度是实现虚拟电厂高效能源管理和

¹ 林禄辉，专注于新能源行业应用平台产品专家，具备丰富的软件产品从 0-1、1-n 的经验和项目管理经验。目前，正在美国金门大学攻读工商管理博士学位，研究方向聚焦于企业管理和治理方向。

最小化运营成本的关键。本文提出了一种面向通信基站虚拟电厂服务的深度学习电力调度方法，通过融合长短期记忆（LSTM）网络与强化学习技术，构建“预测-决策”一体化优化框架：利用 LSTM 网络挖掘电力需求的时序依赖特性，实现高精度电力需求预测；基于强化学习动态优化基站能量调度策略，在运营成本与可再生能源利用之间进行动态权衡。实验结果表明，所提出的模型在预测精度和运营效率方面均优于传统方法，能够有效降低虚拟电厂运营成本并提升能源利用率。本研究为分布式基站资源虚拟电厂的能源管理提供了一种预测—决策协同框架，对构建更具韧性和可持续性的新型电力系统具有重要意义。

关键词：虚拟电厂；电力调度；能量调度；LSTM 模型；强化学习

引言²

高效的电力调度是现代能源系统管理的基础，尤其是在可再生能源和分布式储能技术日益普及的背景下。虚拟电厂（VPPs）作为一种分布式资源聚合与协调机制，能够聚合和管理这些分布式资源，确保电网稳定性并优化能源分配。然而，可再生能源的波动性和电力需求的动态变化，给设计兼具适应性和成本效益的调度系统带来了显著挑战。开发能够应对这些挑战并整合先进计算技术的智能电力调度框架，对于提升虚拟电厂的调度适应性与运行效率具有重要意义。

近年来，电力调度与能量管理领域在预测建模、优化调度与智能决策等方面取得了显著进展：深度预测模型显著提升了负荷预测精度（Hong 和 Fan, 2016; Kong 等, 2019）；模型预测控制与数学规划方法在微电网与配电网调度中得到广泛应用（刘志文等, 2018; 肖浩等, 2016）；深度强化学习在经济调度与需求响应中的潜力不断被验证（张虹等, 2020; 杨挺等, 2021）。然而，现有研究仍存在两方面不足：一是预测与调度两个环节多相对独立，预测误差向调度决策的传导机制未被系统刻画；二是针对通信基站这一规模庞大、负荷时变性强且配备备用储能的可调资源，尚缺乏“预测-决策”一体化的智能调度框架。

具体而言，杨挺等（2021）针对综合能源系统提出的深度强化学习动态调度策略尚未充分拓展至通信基站场景；张虹等（2025）的多智能体协同机制在面临多目标优化时存在可扩展性瓶颈；吴成辉等（2020）的分布式模型预测控制在应对基站负荷高度不确定性时实时性不足。针对上述缺口，本文提出一种融合长短期记忆网络（LSTM）和深度强化学习的能量分配优化模型，面向通信基站虚拟电厂：首先利用 LSTM 挖掘基站电力需求的时序依赖特性，为后续调度提供需求预测输入；预测结果作为强化学习系统的状态输入，实现动态优化能量分配，在成本效益与可持续性之间取得平衡，并在保障基站供电可靠性的同时显著提升虚拟电厂的经济运行效率。

相较于现有方法，本文的主要贡献包括：（1）场景创新：面向通信基站虚拟电厂这一新兴场景，构建了覆盖“数据获取-预测-决策-响应”全流程的调度框架，将基站备用储能与可调负荷纳入虚拟电厂统一调度；（2）方法创新：设计 LSTM 预测与强化学习决策深度融合的“预测-决策”闭环机制，明确预测精度向调度价值传导的信息路径，而非简单叠加两种成熟技术；（3）架构创新：提出云端集中训练与边缘轻量化部署相结合的两级落地架构，兼顾全局优化与实时响应；（4）实证贡献：基于一年的实际

运营数据，从预测精度、运营成本与可再生能源利用率三个维度系统验证所提框架的有效性。

1 相关研究综述

1.1 电力需求预测

电力需求预测是能量调度的首要输入，预测精度直接决定后续优化决策的信息质量。传统方法以 ARIMA、指数平滑与移动平均等统计模型为主，对线性平稳序列具有较好的拟合能力，但难以刻画负荷受天气、电价与用户行为共同作用形成的非线性、非平稳特征（Hong 和 Fan, 2016）。随着深度学习的发展，以 LSTM 为代表的循环神经网络凭借门控机制有效捕捉时序长依赖，在居民负荷与建筑能耗预测中取得优于统计模型的精度（Kong 等, 2019）；基于注意力机制的时序模型进一步实现多变量融合与多步预测的可解释建模（Lim 等, 2021）。上述研究表明，深度预测模型能够为调度决策提供更高精度的需求信息，但预测与调度两个环节在多数研究中仍相对独立，预测误差向调度决策的传导机制未被系统刻画。

1.2 分布式能源优化调度

在调度优化层面，既有研究主要沿数学规划与模型预测控制两条技术路线展开。周文辉等（2015）基于自适应动态规划提出面向用户的微电网能量调度策略，实现了对需求波动的快速响应；刘志文等（2018）针对配电网检修计划提出考虑灵活约束的双层优化方法；肖浩等（2016）将模型预测控制引入微电网多时间尺度协调调度；吴成辉等（2020）进一步提出基于分布式模型预测控制的微电网群协同调度方法；冉金周等（2022）则面向高比例可再生能源接入的孤岛微网，提出考虑灵活性供需匹配的优化调度策略。针对储能与需求侧资源，王尚斌等（2024）提出计及新能源波动的分布式储能分层控制策略，鲍毅等（2018）研究了需求侧管理下的智能家庭用电多目标优化控制。此类方法依赖较为精确的物理模型与参数估计，在可再生能源出力与负荷高度不确定的场景下，实时性与自适应性面临挑战。

1.3 深度强化学习在能源管理中的应用

强化学习通过与环境的持续交互学习最优决策策略，能够在不依赖精确模型的情况下适应动态不确定环境。Mnih 等（2015）提出的深度 Q 网络（DQN）实现了高维状态下的端到端控制，为深度强化学习在能源系统中的应用奠定了基础。在能源管理领域，张虹等（2020）将多智能体异步深度强化学习应用于居民住宅能耗在线优化调度；杨挺等（2021）提出基于深度强化学习的综合能源系统动态经济调度方法；张虹等（2025）针对多智能楼宇微电网提出基于分布式信息交互的区间滚动 P2P 电能交易策略；周航等（2022）研究了适用于各单元共识交易的电力区块链系统优化调度。在更广泛的智能电网与建筑能源管理场景中，Yu 等（2021）系统综述了深度强化学习在建筑能源管理中的应用进展；Cao 等（2020）将深度强化学习与电池退化模型相结合，实现储能套利策略的在线优化；任务调度与需求侧管理领域也涌现了大量深度强化学

习应用（Ghafari 等，2022；王汝言等，2025）。上述工作表明深度强化学习在处理高维、时变能源决策问题上的潜力，但多数研究将预测与决策视为两个独立模块，缺乏对“预测-决策”信息耦合的系统设计。

1.4 虚拟电厂与通信基站灵活性资源

虚拟电厂通过聚合分布式电源、储能与可调负荷参与电网调度与市场交易，是实现分布式资源规模化利用的重要机制（Pudjianto 等，2007；Naval 和 Yusta，2021）。梁绥东（2025）研究了面向虚拟电厂的储能运行优化与可调节资源协同调度。随着 5G 网络规模化部署，通信基站负荷与备用储能已成为一类规模可观的可调资源：基站休眠与功率控制技术可显著降低通信网络能耗（Wu 等，2015）；Ma 等（2024）将 5G 基站纳入虚拟电厂优化框架，验证了基站储能与可调负荷参与电网需求响应的经济潜力。然而，基站负荷兼具强时变性与高可靠性约束，现有调度研究多基于静态优化或简单规则，尚未充分结合高精度预测与智能决策实现基站虚拟电厂的在线自适应调度。

1.5 研究缺口与研究问题

综上，现有研究在以下方面仍存在明显缺口：其一，预测与调度两个环节在多数研究中相互独立，预测精度向调度价值传导的机制未被系统刻画；其二，以模型预测控制为代表的优化方法依赖较精确的物理模型，在基站负荷高度不确定场景下实时性与自适应性不足（吴成辉等，2020）；其三，深度强化学习调度研究多面向综合能源系统与微电网场景（杨挺等，2021；张虹等，2025），面向通信基站虚拟电厂的“预测-决策”一体化调度框架尚属空白。基于上述缺口，本文提出如下研究问题：

RQ1（预测精度）：LSTM 模型能否在基站负荷预测任务上取得优于 ARIMA、移动平均等传统基线的预测精度，其相对优势是否可进一步经 GRU、TFT 等深度基线检验？

RQ2（经济性）：在“预测-决策”耦合框架下，基于强化学习的调度模型能否显著降低虚拟电厂的总运营成本？

RQ3（可持续性）：该框架能否在保障基站供电可靠性的前提下显著提升可再生能源利用率？

RQ4（耦合机制）：预测-决策耦合为何优于“先预测、后独立优化”的分离式范式？预测精度如何经状态空间传导至调度收益？

2 方法论

精确的电力需求预测是虚拟电厂（VPPs）实现源-荷协同优化的核心前提，也是提升能源管理效率的关键基础。本研究采用长短期记忆（LSTM）网络进行电力需求预测，该模型作为循环神经网络（RNN）的重要变体，在处理时序数据、捕捉长时依赖关系方面具有显著优势。LSTM 模型以历史能耗数据、天气要素和电网负荷等多源异构数据作为输入，通过编码时序演化特征，输出高精度的日前/日内电力需求曲线，为后续强化学习调度策略提供精准的决策依据，以支持基站供电可靠性、虚拟电厂运行经济性与电网互动能力之间的协同权衡。

2.1 预测——决策耦合机制

本文从决策理论与信息处理视角构建“预测-决策”耦合机制：调度决策本质上是不确定性条件下的序贯决策问题，决策质量取决于智能体对系统状态不确定度的压缩程度以及对状态-动作价值关系的估计精度。**LSTM** 预测模块通过挖掘需求时序依赖，将高不确定性的原始负荷信息转化为低不确定性的需求估计，压缩了状态空间中的信息熵；强化学习决策模块以该估计为状态输入，通过与环境的持续交互逼近最优调度策略。预测误差经状态空间传导至 **Q** 值估计：预测越精确，**Q** 值估计越集中于最优动作邻域，调度决策越接近最优；反之，预测偏差将导致次优动作被高估、调度收益受损。该耦合机制与“先预测、后优化”的决策范式（Elmachtoub 和 Grigas, 2022）一脉相承，但通过闭环在线交互进一步实现了预测信息与决策目标的联合优化。

2.2 LSTM 电力需求预测模型

LSTM 模型由输入层、两个 **LSTM** 层和输出层组成，专门针对电力数据的时序特性设计，能够有效处理序列输入数据。**LSTM** 单元通过前一时刻单元状态 s_{t-1} ，和当前时刻输入 x_t ，更新当前单元状态 s_t ，并计算隐藏状态 h_t ，具体过程如下：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + d_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + d_i) \quad (2)$$

$$\tilde{s}_t = \tanh(W_s \cdot [h_{t-1}, x_t] + d_s) \quad (3)$$

$$s_t = f_t * s_{t-1} + i_t * \tilde{s}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + d_o) \quad (5)$$

$$h_t = o_t * \tanh(s_t) \quad (6)$$

其中， f_t 、 i_t 、 o_t 分别表示遗忘门、输入门和输出门； W_f 、 W_i 、 W_s 、 W_o 分别为各个门的权重矩阵； d_f 、 d_i 、 d_s 、 d_o 分别为各个门的偏置项。该目标函数用于度量预测误差并指导模型参数优化，为动态能量分配优化提供可靠输入。目标函数定义为：

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

其中， y_i 表示实际电力需求， $\hat{y}_i$ 表示预测电力需求， N 为样本数量。

2.3 强化学习能量调度模型

能源调度模型的核心目标是在保障基站稳定供电的前提下，最小化虚拟电厂的运营成本。本文研究采用强化学习（**RL**）框架，基于基站实时用电负荷与 **LSTM** 预测结果，动态优化能量分配策略。该强化学习（**RL**）模型以马尔可夫决策过程（**MDP**）为核心架构，通过智能体（虚拟电厂控制器）与环境持续交互，学习较优的能量调度策略。

2.3.1 马尔可夫决策过程定义

状态（ s_t ）： t 时刻的系统状态包含三部分核心信息——**LSTM** 模型输出的电力需求预测结果、基站当前实际负荷需求、储能系统剩余电量水平。

动作（ a_t ）：表示 t 时刻向每个基站分配的能量额度。考虑到工程调度指令通常 15min 为周期按离散功率等级下发，且深度 **Q** 网络（**DQN**）要求动作空间离散，本文将各基站的可调度功率在 $[0, P_{max}]$ 范围内均匀量化为 K 个离散等级，动作空间定义为离散集合 $A=\{a_1, a_2, \dots, a_K\}$ ，在保持调度灵活性的同时确保与 **DQN** 算法的兼容性。

奖励（ r_t ）：奖励函数旨在在满足系统运行约束的前提下，平衡运营成本节约与可再生能源利用目标，定义为：

$$r_t = -(C_{op}(a_t) + \lambda \cdot E_{non-renewable}) \quad (8)$$

其中, $C_{op}(a_t)$ 为执行动作 a_t 相关的运营成本, $E_{non-renewable}$ 为不可再生能源的消耗能量。 λ 为权重系数, 用于调节成本最小化与可再生能源利用之间的平衡关系; 该权重系数取值越大, 系统越倾向于优先消纳可再生能源, 其设置依据与敏感性分析见下文“运行约束与参数设定”部分。

2.3.2 运行约束与参数设定

为保证模型物理可行与工程可部署, 调度优化需满足以下运行约束: (1) 功率平衡约束: 任意时刻 t , 基站总负荷 $P_{load}(t)$ 电网购电 $P_{grid}(t)$ 、光伏出力 $P_{pv}(t)$ 与储能净放电功率 $P_{batt}(t)$ 共同满足, 即 $P_{load}(t) = P_{grid}(t) + P_{pv}(t) + P_{batt}(t)$; (2) 储能荷电状态 (SOC) 边界约束: $SOC_{min} \leq SOC(t) \leq SOC_{max}$, 同时为保证基站备电可靠性, $SOC(t)$ 需不低于备电保障阈值 $SOC_{res}(t)$, 该阈值由基站最低备电时长要求确定; (3) 储能充放电约束: $0 \leq P_{ch}(t) \leq P_{ch,max}$, $0 \leq P_{dis}(t) \leq P_{dis,max}$, 且 $SOC(t+1) = SOC(t) + \eta_{ch} \cdot P_{ch}(t) \cdot \frac{\Delta t}{E_{cap}} - P_{dis}(t) \cdot \frac{\Delta t}{\eta_{dis} \cdot E_{cap}}$, 其中 η_{ch} 、 η_{dis} 分别为充放电效率, E_{cap} 为储能额定容量, Δt 为调度步长; (4) 电网交互约束: 购电功率不超过配网接入容量 $P_{grid,max}$, 反向送电遵循当地电力市场交易规则; (5) 需求响应约束: 参与需求响应时, 基站可调负荷的调节量与响应时间窗需满足运营商与电网调度部门约定的协议约束。

在奖励函数中, 运营成本涵盖电网购电费用、储能运行维护费用、电池退化成本 (Cao 等, 2020) 以及基站供电可靠性违约惩罚: 当 SOC 低于备电保障阈值或出现失电风险时, 施加惩罚项以约束策略优先保障基站可靠供电。权重系数 λ 用于权衡成本最小化与可再生能源利用: λ 越大, 策略越倾向于优先消纳可再生能源, 但可能抬升运营成本。

2.3.3 模型训练与优化

本文采用深度 Q 网络 (DQN) 训练强化学习模型, 使其能够学习最优能量调度策略。DQN 通过深度神经网络近似 Q 值函数 s_t, a_t 评估状态 s_t 下执行动作 a_t 的期望累积奖励。Q 值函数基于贝尔曼方程进行迭代更新, 并引入目标网络与经验回放机制以缓解估值偏差与样本相关性问题, 更新公式如下:

$$Q(s_t, a_t) = Q(s_t, a_t) + \varepsilon [r_t + \theta \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t)] \quad (9)$$

其中, ε 为学习率, 用于控制每次更新的步长; θ 为折扣因子, 用于平衡即时奖励与未来奖励的权重。模型通过经验回放缓冲区采样数据批次进行迭代训练, 并引入目标网络与探索策略以提高训练过程的稳定性, 最终获得最优能量调度策略。

训练过程中, 网络参数采用 Adam 优化器更新, 经验回放缓冲区存放历史交互样本并随机抽样小批量数据训练网络; 同时设置目标网络定期与在线网络同步, 并采用贪婪探索策略平衡探索与利用 (探索率由 1.0 线性衰减至 0.01)。以一个调度日 (96 个 15 min 决策步) 为一个训练回合, 训练终止条件为连续 50 个回合平均奖励不再提升; 训练在配备 GPU 的云端算力服务器上进行, 硬件配置详见“硬件基础设施要求”部分。为保证评估可靠性, 实验在 3 个不同随机种子下重复训练, 报告结果取各次运行的均值。主要超参数设置见表 1。

表 1 DQN 训练主要超参数设置

参数	取值
网络结构	三层全连接网络（256-256），ReLU 激活函数
优化器	Adam
学习率	1×10^{-4}
折扣因子 θ	0.99
经验回放缓冲区容量	100 000
批大小	64
目标网络同步间隔	每 200 步
探索策略	贪婪探索率由 1.0 线性衰减至 0.01
动作离散等级数 K	20
训练回合数	500
随机种子	3 个独立种子

3 算法应用流程

算法设计上，基于负荷特性与数据现状，结合智能预测与运筹优化技术，形成基站、换电柜等资源参与需求响应交易的全流程决策方法，构建覆盖建模、响应、预测、评估在内的策略库；具体整体应用架构图如下，涵盖数据获取、量化建模、智能预测、统筹优化、响应闭环等整个流程环节。




图 1 算法应用流程架构图

3.1 核心数据源要求

本框架属于数据驱动型智能调度系统，运营商规模化部署需持续采集、对接三类标准化数据源：（1）基站负荷时序数据：基站 15 分钟级连续用电负荷、通信主设备功耗、机房空调能耗、备用储能充放电，至少积累 12 个月完整时序样本，用于 LSTM 模型离线训练与线上周期性迭代更新；（2）新能源与环境数据：区域逐时气温、光照强度、风速等气象时序数据，分布式光伏、风电实时出力数据，储能电池 SOC、充放电功率状态数据；（3）电网及电力市场数据：分时阶梯电价、峰谷价差、电网需求响应补贴标准、配网线路容量约束、主网功率限额等市场化调度参数。其中，数据采集依托运营商现有基站动环监控平台、储能 EMS 管理系统以及第三方气象开放接口完成标准化对接；针对小型运营商历史数据缺失问题，可通过时序插值、迁移学习完成数据补全，适配数据不完备的实际运营场景。

3.2 硬件基础设施要求

按部署模式分为云端集中部署与基站边缘轻量化部署两类方案：（1）云端集中调度方案（大型运营商省级虚拟电厂平台），配备 GPU 算力服务器支撑 LSTM 预测、

DQN 强化学习在线训练，配套数据库服务器存储全量时序数据、调度指令下发服务器、安全隔离网关对接电网调度平台；（2）边缘本地化部署（地市分公司/片区基站集群），采用边缘计算盒子、轻量化算力模组，通过模型压缩、知识蒸馏降低推理算力消耗，直接在基站动环设备本地完成短期负荷预测与实时调度，降低云端传输延迟；（3）终端配套硬件，基站智能电表、储能 BMS 控制系统、光伏逆变器数据采集终端、负荷可调智能空调控制器，实现负荷、储能、新能源设备可控可调，支撑调度指令下发执行。

整体落地实施路径分为三阶段：首先，完成数据打通与历史数据集构建；其次，离线训练 LSTM-RL 基准模型，小规模区域基站试点仿真；最后，全区域上线在线自适应调度，持续在线迭代优化模型参数。

4 实证分析

4.1 实验设置

为全面验证所提模型的性能，采用实际运营数据开展系列实验。实验数据集来源于某通信运营商实际运营的基站集群（地理范围与基站数量见表 2），包含连续 12 个月的基站负荷需求、气象要素及电网运行数据，采样步长为 15 min；数据经匿名化与脱敏处理后使用，以保障运营商商业信息与用户隐私安全。数据预处理包括缺失值插补、异常值剔除与 Min-Max 归一化；特征集包括历史负荷、气温、光照、风速、分时电价与储能 SOC 等变量。数据集按时间顺序划分为训练集（80%）与测试集（20%），并从训练集末端划分验证子集用于超参数选择，以避免随机划分造成的时间泄漏（数据说明见表 2）。实验从三个核心维度进行性能评估：（1）电力需求预测精度；（2）运营成本优化效果；（3）可再生能源利用率。评估指标包括预测精度类指标（平均绝对误差 MAE、均方根误差 RMSE）与运营效率类指标（总运行成本、可再生能源利用率），并与传统方法进行对比分析。

表 2 数据集与预处理说明

项目	说明
数据来源	某通信运营商实际运营数据（匿名化处理）
地理范围	浙江
基站数量	4 万站
观测周期	连续 12 个月
采样步长	15 min
缺失数据比例	5.2%
预处理规则	缺失值插补、异常值剔除、Min-Max 归一化
特征集	历史负荷、气温、光照、风速、分时电价、储能 SOC
数据划分	时间顺序划分：训练集 80%、测试集 20%，训练集末端划分验证子集

4.2 实验 1：电力需求预测精度

本实验旨在验证 LSTM 电力需求预测模型相较于多种基准模型的精度优势。为公平比较并避免时间泄漏，数据集按时间顺序划分，并采用滚动原点（rolling-origin）验证：以固定长度的历史窗口滚动前移，对多个测试窗口逐一预测并汇总误差，以检验模型的跨期泛化能力。基准模型包括：（1）ARIMA，经典的线性统计时序模型；（2）简单移动平均（MA）模型，反映传统平滑方法的水平。精确的需求预测对于优化虚拟电厂的能量调度、确保成本效益和电网稳定性至关重要。

4.2.1 结果与分析

实验结果显示，如图 2，LSTM 模型在预测精度上显著优于 ARIMA 模型与简单移动平均模型，LSTM 模型表现出显著更低的平均绝对误差(MAE)和均方根误差(RMSE) 值，这表明其在本研究数据集上具有更好的预测表现。具体而言，LSTM 模型的 MAE 为 2.8，RMSE 为 3.9，优于 ARIMA 的 MAE 为 4.5，RMSE 为 6.2 和移动平均模型的 MAE 为 5.1，RMSE 为 7.0。这些结果凸显了 LSTM 模型在预测精度上的优越性。




图 2 不同模型预测效果的 MAE 与 RMSE 对比

4.2.2 算法分析优势

LSTM 模型的核心优势在于其独特的门控机制，能够有效捕捉时序数据中的长期依赖关系和非线性模式。与依赖静态假设，仅能捕捉短期时序特征的 ARIMA 模型和移动平均模型不同，LSTM 通过遗忘门、输入门与输出门的协同作用，利用门控机制选择性地保留长时过程相关信息、过滤无关噪声数据，从而适应电力需求受天气变化、负荷波动等多因素影响的动态特性，特别适用于实际虚拟电厂运营。此外，LSTM 模型在处理具有不规则趋势的数据序列方面表现突出，而传统方法往往难以充分应对此类问题，这些特性使 LSTM 模型能够有效应对虚拟电厂运营中的复杂需求模式，为后续调度决策提供高精度数据支撑。

4.3 实验 2：能源成本优化

本实验旨在评估基于 RL 的能源调度模型相较于传统基于规则的调度方法，在降低虚拟电厂运营成本方面的优化效果。实验以总运营成本为核心评估指标，对比两种方法在相同运营场景下的成本消耗。其目标是通过基于电力预测和基站负荷需求来优化调度，从而最小化总能源成本。

4.3.1 结果与分析

实验结果表明，如图 3，基于强化学习的调度模型在当前实验设定下实现了较低的总运行成本。基于 RL 的模型将总成本降低了约 31%，实现了 203,000 元的成本，而传统方法的成本为 294,000 元。




图3 传统调度方法与基于强化学习（RL）调度方法的总运行成本对比（单位：元）

为验证该优化效果并非单次仿真随机扰动造成，本文以调度周期为分析单元，对两种方法在完全相同运行场景下的成本序列开展配对样本 t 检验：由于两种方法基于同一组负荷、电价与天气序列运行，周期内成本构成一一对应的配对样本，采用配对检验可剔除周期间共性波动，比独立样本检验更具统计效力。同时计算成本降低率的95%双侧置信区间，置信区间计算公式为：

$$C = \bar{x} \pm t_{\alpha/2}(n-1) \cdot \frac{s}{\sqrt{n}} \quad (10)$$

式中： $\bar{x}$ 为指标均值； $t_{\alpha/2}(n-1)$ 为对应自由度下95%置信度 t 分布分位数； s 为样本标准差； n 为样本总量。

成本降幅统计结果显示：本模型成本降低均值为31.24%，95%置信区间[30.73%,31.75%]，区间下限远大于0，说明在95%置信水平下，模型可稳定实现30.73%以上的运营成本削减，文中31%为均值四舍五入。配对样本 t 检验结果 $p < 0.001$ ，显示相较传统调度方案，成本差异在当前检验设定下具有统计显著性。

4.3.2 算法优势分析

基于RL的调度模型的成本优势在于其动态自适应决策能力。与静态的基于规则调度系统不同，强化学习模型通过与实时环境的持续交互，能够根据电价波动、负荷变化等动态信息调整能量分配策略：在电价低谷期合理储备能量，在电价高峰期优化能量供给，同时充分利用低成本可再生能源，实现运营成本的全局优化。这种自适应决策机制使其能够灵活应对复杂多变的能源市场环境，相较于固定规则的传统方法具有显著优势。

4.4 实验3：可再生能源利用与可持续性

本实验聚焦于评估模型在保障供电可靠性和成本效益的前提下，提高可再生能源利用率的能力。实验基于一年的观测数据，以其中连续选取的100个调度周期（每个调度周期对应一个调度日，含96个15 min决策步）为评估窗口，统计对比传统调度方法与强化学习调度模型的可再生能源使用比例，以检验模型在跨期场景下的可持续性表现。

4.4.1 结果与分析

实验结果表明，如图 4，基于 RL 的调度模型在可再生能源利用率方面取得了较高数值：其可再生能源利用率达到了 56%，而传统调度方法的可再生能源利用率为 40%。其中，可再生能源利用率定义为统计窗口内可再生能源实际消纳电量占基站总用电量的比例，即 $RU = E_{re} / E_{total} \times 100\%$ ，分子计及光伏直接供电与储能放电中的可再生电量，并扣除弃光及储能充放电损耗，分母为基站总用电量（含电网购电、光伏与储能供给）。可再生能源利用率的提升，符合可持续发展目标，增强了虚拟电厂的环境效益。




图 4 传统调度方法与基于强化学习（RL）调度方法的可再生能源利用率对比（100 个调度周期；单位：%）

基于全周期样本开展统计校验，以 100 个调度周期为配对分析单元，计算可再生能源利用率 95%置信区间并完成配对样本 t 检验：本文模型可再生能源利用率均值 55.87%，95%置信区间[55.25%,56.49%]，文中 56%为均值四舍五入；传统调度方法利用率稳定均值为 40.12%，两组指标置信区间无重叠，直观体现方案性能差距。配对样本 t 检验结果 $p < 0.001$ ，在 95%置信水平下，本文框架可再生能源消纳能力显著优于传统调度策略，利用率差异在当前样本与检验设定下具有统计显著性。

4.4.2 算法优势分析

RL 调度模型通过在奖励函数中融入可再生能源利用激励机制，实现了成本目标和可持续性目标的协同优化。模型在训练过程中持续学习成本与可再生能源利用的平衡关系，能够根据可再生能源出力的实时变化，动态调整能量分配策略，优先选用可再生能源供电，减少对化石燃料等不可再生资源的依赖。这种主动优化机制使虚拟电厂的运营不仅满足经济性要求，更符合可持续发展目标，为构建低碳环保的能源系统提供了有效技术路径。

4.5 结果与讨论

实验结果表明，所提出的深度学习与强化学习框架在当前实验设定下改善了虚拟电厂电力需求预测与能量调度表现。每项实验均较传统方法展现出明显改进，显示了这种人工智能驱动方法在改进虚拟电厂能源管理中的应用潜力。该框架整合了先进的机器学习技术，以捕捉复杂的时间依赖关系和实现动态决策，从而实现更精确的调度安排和高效的能量分配。下文将详细讨论从每个实验中获得的见解，强调所提出方法的优势，同时指出其局限性和未来可能的改进方向。

4.5.1 电力需求预测精度

LSTM 模型凭借其门控结构优势，能够有效捕捉电力需求数据中的复杂时序依赖与非线性模式，相较于传统时序预测方法，MAE 与 RMSE 均显著降低。实验也验证了 LSTM 模型能够有效捕捉电力需求数据中复杂时间模式和长期依赖关系，能够在不同时刻选择性地保留关键信息，同时过滤无关数据。这种选择性记忆机制在动态能源系统中尤为有益，因为此类系统的需求模式受历史趋势、天气变化和实时负荷波动等因素影响。从决策视角看，预测精度之所以重要，在于预测误差会经状态空间直接传导至调度策略：需求估计的偏差将抬高状态中的噪声水平，使 Q 值估计偏离最优动作，进而侵蚀调度收益（Elmachtoub 和 Grigas, 2022）。因此，预测精度不仅是统计指标，更是调度价值的先决条件。

通过提供更精准、更可靠的需求预测，有助于 LSTM 模型做出知情且主动的能量调度决策，从而提升虚拟电厂的操作效率和经济性。然而，该模型对大量高质量历史数据的依赖也构成了潜在局限性，即在数据稀疏、不完整或存在噪声的环境中，其性能可能会下降。这一限制凸显了未来研究探索混合方法的必要性，即将 LSTM 和其他补充数据源（如实时电网状况、可再生能源预测或市场动态）相结合。此外，引入迁移学习等技术可以增强模型在不同运营场景中的适应性，进一步提高其在多样化虚拟电厂环境中的实用性。

4.5.2 能源成本优化

与基于规则的传统调度方法相比，基于 RL 的调度模型在降低运行成本方面表现出较低的运行成本，实现了约 31% 的成本节约。这一结果表明了强化学习在基于预测电力负荷需求优化实时能量调度决策方面的有效性。与静态基于规则的系统不同，RL 模型能够持续适应不断变化的条件，通过在低成本时段分配能量、在电价高企时节约电力，最大限度地提高成本效率。RL 方法的优势在于其能够从过去的动作中学习并优化累积奖励，这使其特别适合动态能源市场。但模型性能受训练数据的质量与多样性影响较大，若能源市场出现突发价格波动或需求模式突变，可能导致模型决策效率下降。未来可通过引入场景化训练数据、融合迁移学习与在线学习技术，增强模型对极端场景与突发情况的适应能力，进一步提升成本优化的稳定性与可靠性。该成本优势的关键机理在于“预测-决策”闭环：LSTM 提供的高精度需求估计使 RL 智能体能够在更准确的可行域内分配能量，在电价低谷时段利用低成本电能储能、在高峰时段释放，从而将预测信息转化为可量化的成本节约。

4.5.3 可再生能源利用和可持续性

基于 RL 的模型实现了 56% 的可再生能源利用率，相较于传统调度方法的 40% 有显著提升。这一结果表明，该模型能够通过根据可用性和成本考量动态调整能量调度，优先考虑可再生能源。通过在奖励函数中纳入可再生能源激励措施，RL 模型会在奖励函数设定下提高对可再生能源的选择倾向，使能量调度决策与可持续发展目标保持一致。对于虚拟电厂而言，这种对可再生能源的优先考虑具有特别重要的意义，因为它可以减少总体碳排放，符合全球可持续能源系统的发展目标。未来可进一步优化模型设计，将天气预报、可再生能源出力预测等信息纳入状态空间，使模型能够更精准地预判可再生能源供应情况，进一步提升可再生能源利用率。预测信息同样支撑了可再

生能源的高效利用：准确的需求与出力估计使智能体能够预判可再生出力的充裕时段并提前调整储能状态，避免弃光与过充，从而在奖励函数激励下实现可再生消纳的最大化。

4.5.4 总体见解和未来方向

LSTM 模型与 RL 模型的融合框架通过“预测-决策”闭环设计，充分发挥了深度学习的精准预测能力与强化学习的动态优化优势，为复杂虚拟电厂调度问题提供了可行的协同优化方案。其中，LSTM 模型提供精确的需求预测，并作为基于 RL 的调度器优化实时分配决策的关键输入。这种协同关系凸显了该框架的核心优势，即充分利用深度学习的预测能力和强化学习的动态优化能力。

需要说明的是，本文结论成立的前提边界如下：一是电价波动与负荷突变的幅度处于训练数据所覆盖的分布范围内，超出该范围的极端场景下（如突发负荷激增、电网故障、数据大规模缺失等）模型性能可能下降，本文未对上述扰动场景开展显式鲁棒性评估；二是实验基于离线历史数据仿真，未计及通信时延、设备故障等工程实现因素；三是电池老化对调度策略的长期影响仅以退化成本形式近似计入。上述边界条件不满足时，模型性能需重新评估，相关扰动实验与实网验证将作为后续工作。

尽管该模型在管理波动的负荷需求和多变的运行条件方面在所测试运行条件下保持了较稳定的表现，但仍存在一些可改进空间：一是在极端不确定性或罕见事件（如突发负荷激增、电网故障）场景下，模型的鲁棒性有待进一步提升，未来可引入鲁棒优化与异常检测技术，增强模型对非典型场景的适应能力；二是模型的计算复杂度较高，在资源受限的实时调度系统中部署面临挑战，可通过知识蒸馏、模型压缩等技术降低计算开销，或结合边缘计算架构提升实时响应能力；三是当前模型未充分考虑多主体协同调度场景，未来可探索多智能体强化学习技术，实现分布式基站虚拟电厂的集群协同优化。

5 结论与展望

本文提出一种融合 LSTM 模型与强化学习（RL）的通信基站虚拟电厂能源调度优化框架。围绕本文提出的四个研究问题，主要结论如下：（1）针对 RQ1（预测精度），LSTM 模型的 MAE 与 RMSE 均显著低于 ARIMA 与移动平均模型，验证了其在基站负荷预测上的精度优势；（2）针对 RQ2（经济性），基于 RL 的调度模型在相同运行场景下将总运营成本降低约 31%，配对样本 t 检验 $p < 0.001$ ，具有统计显著性；（3）针对 RQ3（可持续性），基于 RL 的调度模型将可再生能源利用率由 40% 提升至 56%；（4）针对 RQ4（耦合机制），预测精度经状态空间传导至调度决策，高精度需求估计显著提升了 RL 策略的决策质量，验证了“预测-决策”闭环优于分离式范式的机理判断。理论贡献方面，本文将预测精度与调度价值纳入统一分析框架，刻画了预测误差向调度收益传导的机制，为“预测-决策”耦合型调度方法提供了理论依据；实践方面，所提框架与云端集中、边缘轻量化的两级部署架构相匹配，支持以 15 min 为周期的在线调度，可为电信运营商与虚拟电厂聚合商参与电网需求响应、降低运营成本、提升可再生能源消纳提供可落地的技术路径。研究局限在于：模型性能依赖高质量历史数据，对极端扰动场景的鲁棒性尚未显式评估，多基站集群协同调度有待进一步研究，上述方向将作为后续工作重点。

未来研究可从以下方向进一步拓展：一是引入实时天气数据、电网运行状态、能源市场价格等多源信息，丰富模型输入特征，进一步提升预测精度与调度决策的适应性；二是针对模型的实时部署需求，通过模型压缩、知识蒸馏等技术优化计算效率，结合边缘计算架构降低调度延迟，提升系统可扩展性；三是探索多智能体强化学习技术，实现多基站虚拟电厂的协同调度，提升区域能源系统的整体优化效率。本研究为虚拟电厂的自适应能源管理提供了智能化解决方案，对推动构建韧性更强、可持续性更高的新型电力系统具有重要意义。

参考文献

- 鲍毅, 楼凤丹, 王万良. 需求侧管理下智能家庭用电多目标优化控制[J]. 智能系统学报, 2018, 13(1): 125-130.
- Cao J, Harrold D J B, Fan Z, et al. Deep reinforcement learning-based energy storage arbitrage with accurate lithium-ion battery degradation model[J]. IEEE Transactions on Smart Grid, 2020, 11(5): 4513-4521.
- Elmactoub A N, Grigas P. Smart “predict, then optimize”[J]. Management Science, 2022, 68(1): 9-26.
- Ghafari R, Kabutarkhani F H, Mansouri N. Task scheduling algorithms for energy optimization in cloud environment: a comprehensive review[J]. Cluster Computing, 2022, 25(2): 1035-1093.
- Hong T, Fan S. Probabilistic electric load forecasting: a tutorial review[J]. International Journal of Forecasting, 2016, 32(3): 914-938.
- Kong W, Dong Z Y, Jia Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.
- 梁绥东. 面向虚拟电厂的储能运行优化与可调节资源协同调度研究[J]. 电网与清洁能源, 2025, 41(9): 27-36.
- Lim B, Arik S O, Loeff N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting[J]. International Journal of Forecasting, 2021, 37(4): 1748-1764.
- 刘志文, 董旭柱, 吴争荣, 等. 考虑灵活定义约束的配电网检修计划双层优化方法[J]. 电工技术学报, 2018, 33(10): 2208-2216.
- Ma D, Liuz, Guo M, et al. Research on decentralized resource operation optimization of virtual power plant with 5G base station[J]. International Journal of Low-Carbon Technologies, 2024, 19: 1124-1137.
- Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529-533.
- Naval N, Yusta J M. Virtual power plant models and electricity markets: a review[J]. Renewable and Sustainable Energy Reviews, 2021, 149: 111393.
- Pudjianto D, Ramsay C, Strbac G. Virtual power plant and system integration of distributed energy resources[J]. IET Renewable Power Generation, 2007, 1(1): 10-16.
- 冉金周, 李华强, 李彦君, 等. 考虑灵活性供需匹配的孤岛微网优化调度策略[J]. 太阳能学报, 2022, 43(5): 36-44.
- 王汝言, 杨安琪, 吴大鹏, 等. 异步移动边缘计算网络中的联合任务调度与计算资源分配优化策略[J]. 电子与信息学报, 2025, 47(2): 470-479.
- 王尚斌, 苑丽伟, 方莹, 等. 计及新能源波动的分布式储能分层控制策略[J]. 山东电力技术, 2024, 51(9): 74-84.
- 吴成辉, 林声宏, 夏成军, 等. 基于模型预测控制的微电网群分布式优化调度[J]. 电网技术, 2020, 44(2): 530-538.
- Wu J, Zhang Y, Zukerman M, et al. Energy-efficient base-stations sleep-mode techniques in green cellular networks: a survey[J]. IEEE Communications Surveys & Tutorials, 2015, 17(2): 803-826.
- 肖浩, 裴玮, 孔力. 基于模型预测控制的微电网多时间尺度协调优化调度[J]. 电力系统自动化, 2016, 40(18): 7-14.
- 杨挺, 赵黎媛, 刘亚闯, 等. 基于深度强化学习的综合能源系统动态经济调度[J]. 电力系统

自动化, 2021, 45(5): 39-47.

Yu L, Qin S, Zhang M, et al. A review of deep reinforcement learning for smart building energy management[J]. IEEE Internet of Things Journal, 2021, 8(15): 12046-12063.

张虹, 申鑫, 穆昊源, 等. 基于 Multi-Agent 异步深度强化学习的居民住宅能耗在线优化调度研究[J]. 中国电机工程学报, 2020, 40(1): 117-127.

张虹, 张泽熙, 李亚洲, 等. 基于分布式信息交互的微电网多智能楼宇区间滚动 P2P 电能交易策略[J]. 电工技术学报, 2025, 40(13): 4292-4305.

周航, 姜河, 赵琰, 等. 适用于各单元共识交易的电力区块链系统优化调度研究[J]. 计算机科学, 2022, 49(S1): 771-776.

周文辉, 钟伟锋, 余荣. 微电网中面向用户的自适应能量调度策略[J]. 北京邮电大学学报, 2015, 38(3): 77-81.