

数据驱动下电力负荷预测与储能协同优化控制研究

顾顺利

西藏博源综合能源服务有限公司 西藏 林芝 860000

摘要：本文聚焦于数据驱动范式，系统性地探讨了现代电力负荷预测所面临的挑战，并深入剖析了从传统统计模型到深度学习等先进人工智能技术的演进路径。在此基础上，论文构建了一个“预测-决策-控制”一体化的协同优化框架，将高精度的短期及超短期负荷预测结果作为核心输入，驱动储能系统的充放电策略制定。该框架综合考虑了电网运行约束、储能物理特性、市场电价信号及可再生能源出力不确定性等多重因素，旨在实现削峰填谷、平抑波动、降低购电成本及提升新能源消纳能力等多重目标。研究表明，通过深度融合时序数据分析、不确定性量化与智能优化算法，能够显著提升电力系统的灵活性、可靠性和经济性，为构建以新能源为主体的新型电力系统提供坚实的技术支撑。

关键词：电力负荷预测；储能系统；数据驱动；协同优化

引言

在全球能源清洁低碳转型背景下，风能、太阳能等高比例可再生能源并网加剧了电力系统净负荷的波动性与不确定性，对电网平衡调节能力构成严峻挑战。精准的电力负荷预测与高效的储能调控成为保障频率稳定、供电可靠、降本增效及促进新能源消纳的关键。传统负荷预测方法难以刻画气象、经济、社会活动等多源异构因素驱动下的复杂非线性动态，且储能控制常与预测脱节，缺乏协同前瞻性。随着大数据、云计算与人工智能技术发展，“数据驱动”范式为电力系统分析带来新机遇：海量多维数据助力揭示负荷深层规律，先进机器学习算法支撑高精度预测与优化控制。因此，构建紧密耦合、高效互动的数据驱动型“负荷预测-储能控制”协同体系，已成为提升新型电力系统智能化水平的核心课题。

1 数据驱动电力负荷预测的技术演进与挑战

1.1 从传统模型到机器学习的跨越

早期的预测方法主要基于时间序列分析，如自回归滑动平均（ARMA）模型及其季节性扩展（SARIMA）。这类模型假设负荷序列具有平稳性或可被差分至平稳，并通过历史数据的线性组合来预测未来值。尽管在特定场景下表现尚可，但其对非线性、非平稳特征的刻画能力极为有限。随后，人工神经网络（ANN），特别是多层感知机（MLP），因其强大的非线性拟合能力而被引入负荷预测领域，能够在一定程度上捕捉气象因素（如温度、湿度）与负荷之间的复杂关系。然而，标准ANN在处理具有长期依赖性的时序数据时，容易遭遇梯度消失或爆炸问题，且对输入特征工程的依赖较强。

1.2 深度学习引领的预测精度革命

近年来，以循环神经网络（RNN）及其变体长短期记忆网络（LSTM）和门控循环单元（GRU）为代表的深度学习模型，在时序预测任务中取得了突破性进展。LSTM/GRU通过精心设计的门控机制，能够有效学习和记忆时间序列中的长期依赖关系，对于捕捉负荷的日周期、周周期乃至更长的季节性模式具有天然优势。在此基础上，研究者们进一步探索了更为强大的架构^[1]。例如，将卷积神经网络（CNN）与RNN结合，利用CNN提取负荷序列的局部时空特征（如突变点、趋势），再由RNN进行序列建模；或者采用完全基于注意力机制的Transformer模型，通过自注意力（Self-Attention）机制动态地为序列中不同时间步分配权重，从而更灵活地捕捉全局依赖关系，避免了RNN固有的顺序计算瓶颈。此外，图神经网络（GNN）也被用于区域负荷预测，通过构建电网拓扑或地理邻接关系图，有效融合了空间相关性信息。

1.3 多源异构数据融合与不确定性量化

现代高精度负荷预测已不再局限于单一的历史负荷数据。一个全面的预测模型需要融合多源异构数据，包括但不限于：精细化的数值天气预报（NWP）数据、日历信息（节假日、工作日）、社会经济指标、甚至来自社交媒体或移动信令的实时人流数据。如何有效地对齐、清洗、特征化并融合这些来源不同、尺度各异、质量不一的数据，是提升预测鲁棒性的关键。更重要的是，任何预测都存在不确定性。对于后续的优化决策而言，仅提供一个点预测值是远远不够的，还需要对其置信区间或概率分布进行量化。为此，研究者们开发了多种不确定性量化方法，如分位数回归（Quantile Regression）、蒙特卡洛Dropout、集成

学习 (Ensemble Learning) 以及贝叶斯神经网络 (Bayesian Neural Networks) 等。这些方法能够生成预测区间或完整的概率密度函数, 为风险意识下的储能优化控制提供了至关重要的输入。

2 储能系统在电力系统中的角色与控制逻辑

2.1 储能作为灵活性资源的核心价值

储能系统, 无论是电化学电池 (如锂离子电池)、抽水蓄能, 还是新兴的压缩空气、飞轮等, 其核心价值在于打破了电力“发-用”必须实时平衡的刚性约束, 为系统提供了宝贵的“时间转移”能力。在时间维度上, 储能可以将低谷时段 (电价低、新能源出力过剩) 的富余电能储存起来, 在高峰时段 (电价高、负荷大、新能源出力不足) 释放, 从而实现削峰填谷, 平抑净负荷曲线, 降低对昂贵调峰机组的依赖。在功率维度上, 储能具有毫秒级的响应速度, 能够快速吸收或释放功率, 有效平抑可再生能源出力的短时波动和负荷的瞬时冲击, 为电网提供一次调频、二次调频等辅助服务, 增强系统的动态稳定性。

2.2 储能系统的基本物理模型与约束

对储能系统进行优化控制, 首先需要建立其精确的物理数学模型。一个典型的电化学储能模型通常包含以下几个核心要素: 荷电状态 (State of Charge, SOC), 它表征了储能当前的剩余能量, 是控制的核心变量; 充放电功率, 受逆变器额定功率限制; 充放电效率, 描述了能量转换过程中的损失; 以及SOC的上下限约束, 以防止过充过放, 保护电池寿命^[2]。此外, 还需考虑电池的退化模型, 即频繁的深度充放电会加速容量衰减, 这在长期经济性优化中是一个不可忽视的因素。所有这些物理特性和运行约束, 共同构成了储能优化问题的可行域。

2.3 储能控制策略的演进

早期的储能控制策略多为基于规则的 (Rule-based), 例如, 当电价低于某一阈值时充电, 高于另一阈值时放电。这类策略简单直观, 但缺乏全局最优性, 无法适应电价和负荷的动态变化。随着优化理论的发展, 基于模型预测控制 (Model Predictive Control, MPC) 的策略成为主流。MPC的核心思想是在每个控制周期, 基于对未来一段时域 (预测时域) 内系统状态 (如负荷、电价、新能源出力) 的预测, 求解一个有限时域的开环最优控制问题, 并将得到的最优控制序列的第一个动作施加于系统。在下一个周期, 滚动更新预测信息并重复此过程。这种滚动优化、反馈校正的机制, 使得MPC能够很好地处理系统的动态性、多变量耦合和各种运行约束。

3 负荷预测与储能协同优化控制的集成框架

3.1 “预测-决策-控制”一体化架构

为了最大化系统效益, 必须打破负荷预测与储能控制之间的壁垒, 构建一个紧密集成的协同优化框架。该框架遵循“预测-决策-控制”的闭环逻辑。首先, 在预测层, 利用前述的数据驱动模型, 融合多源信息, 生成对未来T个时段 (如未来24小时或15分钟) 的高精度点预测及概率预测。其次, 在决策层, 将预测结果 (特别是其不确定性信息) 作为核心输入, 构建一个随机优化 (Stochastic Optimization) 或鲁棒优化 (Robust Optimization) 模型。该模型的目标函数可以是多元的, 如最小化总购电成本、最小化峰谷差、最大化新能源消纳量等, 可通过加权求和等方式进行多目标融合。模型的约束条件则涵盖了电网潮流、节点电压、储能物理特性、设备运行极限等。通过求解该优化模型, 得到未来T个时段内储能的最优充放电功率计划^[3]。最后, 在控制层, 将该计划下发给储能系统的本地控制器执行。同时, 实际运行数据会被实时采集并反馈回预测层, 用于在线更新和校正预测模型, 形成一个持续学习和优化的闭环。

3.2 面向不同时间尺度的协同策略

电力系统的运行涉及多个时间尺度, 协同优化策略也需分层设计。对于日前 (Day-ahead) 调度, 主要依赖于高精度的短期负荷预测 (24-72小时) 和新能源出力预测。此时, 优化目标侧重于经济性, 即根据日前市场的分时电价, 制定储能的充放电计划以套利。由于预测时域较长, 不确定性较大, 应采用随机规划方法, 将负荷和新能源出力视为随机变量, 以其概率分布为基础进行决策, 以规避高风险方案。对于日内 (Intra-day) 或实时 (Real-time) 控制, 则依赖于超短期负荷预测 (15分钟-4小时) 和滚动更新的新能源预测。此阶段的优化目标更侧重于安全性与跟踪性, 即快速响应净负荷的实时偏差, 平抑波动, 确保系统实时平衡。此时, 可采用基于确定性预测的MPC策略, 因其计算速度快, 能更好地适应快速变化的工况。

3.3 不确定性下的鲁棒与自适应优化

在协同优化中, 如何妥善处理预测的不确定性是决定策略成败的关键。鲁棒优化方法通过定义一个不确定性集 (Uncertainty Set), 寻求在最坏情况下性能仍可接受的解决方案, 具有较强的保守性, 适用于对安全性要求极高的场景。而随机优化则通过期望值或条件风险价值 (CVaR) 等风险度量, 寻求在统计意义上最优的方案, 通常能获得更高的期望收益, 但可能面临尾部风险^[4]。此

外,还可以引入自适应优化思想,即优化模型的部分参数(如风险厌恶系数)可以根据最新的预测误差或系统状态进行动态调整,使控制策略更具灵活性和适应性。例如,当检测到预测误差显著增大时,自动切换到更为保守的鲁棒优化模式。

4 关键技术与未来发展方向

4.1 先进人工智能算法的深度融合

未来的协同优化系统将更加深度地融合前沿AI技术。强化学习(Reinforcement Learning, RL)作为一种“试错”学习范式,无需显式的系统模型,而是通过与环境的交互来学习最优策略,特别适合处理模型未知或高度复杂的动态优化问题。将RL应用于储能控制,可以让系统在长期运行中自主学习到适应特定电网环境和市场规则的最优行为模式。此外,联邦学习(Federated Learning)等隐私计算技术,可以在不共享原始数据的前提下,聚合多个区域或用户的负荷数据,训练出泛化能力更强的全局预测模型,这对于提升整体预测精度具有重要意义。

4.2 多能互补与综合能源系统视角

随着能源互联网的发展,电力系统正与热力、天然气等其他能源系统深度融合,形成综合能源系统(Integrated Energy System, IES)。在此背景下,负荷预测与储能优化的范畴也随之扩展。电力负荷预测需要考虑与其他能源负荷(如热负荷、冷负荷)的耦合关系。储能也不再局限于电化学储能,还包括储热、储冷、储氢等多种形式。协同优化的目标也从单一的电力系统经济性,转向整个综合能源系统的多能协同、梯级利用和全局最优。这要求建立跨能源品种的耦合模型,并设计相应的多时间尺度、多目标协同优化算法。

4.3 云边协同的分布式智能架构

面对海量终端设备和实时性要求,集中式的“云”计算架构可能面临通信延迟和带宽瓶颈。未来的协同优化系统将更多地采用“云-边-端”协同的分布式智能架

构。在“端”侧(如变电站、用户侧),部署轻量化的边缘智能设备,负责本地数据的预处理、超短期预测和快速控制指令的执行。在“边”侧(如区域调度中心),进行区域内资源的协调优化。在“云”侧(如省级或国家级调度中心),则负责全局态势感知、长期规划和模型训练。通过这种分层分级的架构,既能保证控制的实时性,又能实现全局资源的优化配置。

5 结语

在构建以新能源为主体的新型电力系统进程中,数据驱动的负荷预测与储能协同优化控制至关重要。本文系统阐述了高精度、不确定性感知的负荷预测方法、考虑多重约束的储能物理建模,以及二者深度融合的“预测-决策-控制”一体化协同框架。研究表明,借助大数据与人工智能技术,不仅能显著提升预测精度与可靠性,还可制定前瞻性、鲁棒性强且经济性优的储能运行策略,有效应对可再生能源并网带来的波动性挑战,全面提升电网灵活性、韧性与运行效率。未来,随着强化学习、联邦学习、综合能源系统建模及云边协同等前沿技术的发展,该协同体系将迈向更高水平的智能化与自主化,为实现清洁、高效、安全的能源利用提供核心支撑。

参考文献

- [1]胡永强.分布式储能系统在电力负荷管理中的应用研究[J].城市建设理论研究(电子版),2025,(03):1-3.
- [2]丁甲,施开波,王俊,等.具有时变延迟和脉冲效应的含储能单元的电力系统滑模负荷频率控制[J].成都大学学报(自然科学版),2025,44(04):377-382.
- [3]张运长,蒋昕潼,郑涛,等.基于CNN-LSTM的电力储能系统地区短期负荷预测研究[J].电子设计工程,2025,33(07):131-135.
- [4]彭钧敏,张树泓,姬彦豹.含储能的区域互联电力系统负荷频率预设性能控制[J].电力科学与工程,2024,40(09):24-32.