

面向新型电力系统运行的数据-物理融合建模综述

阮广春, 何一鏊, 谭振飞, 钟海旺

(清华大学电机工程与应用电子技术系, 北京市 海淀区 100084)

Review of Hybrid Data-driven and Physics-based Modeling for the Operation of New-type Power Systems

RUAN Guangchun, HE Yiliu, TAN Zhenfei, ZHONG Haiwang

(Department of Electrical Engineering, Tsinghua University, Haidian District, Beijing 100084, China)

ABSTRACT: Constructing new-generation power systems dominated by renewable energy is crucial to achieve China's carbon neutrality goal, but this will inevitably bring significant changes and challenges to the existing power grids. Hybrid data-driven and physics-based modeling (hybrid modeling for short) is an emerging technique to combine the advantages of physics laws and data, showing great potential to serve as an important analysis tool for the new-generation power systems. To this end, this paper clarifies the relevant concepts and use cases at first, and then discusses the research trends and hotspots in recent literature. A general framework to evaluate the performance of hybrid modeling from an aspect of technical features and hybrid patterns is also proposed. In addition, this paper is focused on the operation of new-generation power systems, and has fully summarized the pros and cons of hybrid modeling in addressing the existing technical challenges. Further suggestions for future research work and pilot projects are discussed at last.

KEY WORDS: new-type power system; high renewable energy penetration; data-driven; knowledge-driven; artificial intelligence; machine learning

摘要: 构建新型电力系统是我国实现碳达峰、碳中和目标的关键, 将给电力工业带来深刻变革与挑战。数据-物理融合建模(简称融合建模)是一类新兴的建模技术, 能够同时发挥物理机理与数据的价值, 有望成为新型电力系统重要的分析工具。为此, 该文首先梳理融合建模的相关概念与应用场景, 讨论近年来国内外的研究趋势与热点。进而从技术特征和融合模式两方面, 提出针对融合模型的分析框架。同时, 聚焦于新型电力系统运行领域, 全方位总结整理融合建模在应对现有技术挑战方面的潜在优势及不足, 并展望未来研究与工程实践的重点发展领域。

关键词: 新型电力系统; 高比例可再生能源; 数据驱动; 知识驱动; 人工智能; 机器学习

0 引言

人类社会正面临由化石能源过度消耗引发的严重环境危机, 大力发展绿色能源、推动电力系统低碳化转型成为世界各国的普遍共识。据国际能源署预测^[1], 按照世界各国颁布的低碳发展承诺推演, 到2030年全球可再生能源发电占比将达到46%, 到2050年该比例将进一步上升至71%。据美国能源信息署预测^[2], 如果光伏、风电成本下降超过预期, 2050年的可再生能源发电总量有望上涨近30%。

中国顺应国际发展形势, 于2021年3月15日首次提出构建新型电力系统的发展愿景^[3]。研究表明, 新能源占比一旦超过50%, 将对系统运行控制特性构成根本性影响^[4], 系统的电力电量平衡机理与动态稳定特性都将发生深刻变化^[5]。新型电力系统的复杂运行特性给系统分析方法提出了更高要求, 而在各类新兴技术中, 数据-物理融合建模(简称为融合建模)技术由于兼具物理模型(体现物理机理)与数据驱动模型(体现历史经验)的优势而拥有特殊的发展潜力。

然而, 物理模型与数据驱动模型的固有特性并不匹配, 表现为物理模型是自下而上逐层建立的; 而数据驱动模型则基于端到端训练, 侧重直接的端口映射关系。这就导致两类模型在适用条件、精度范围、数值特性等方面存在差异, 高效融合并非易事, 亟需深刻理解其中的底层协同逻辑与动态关系, 提出融合建模方法论。

目前, 学术界逐渐开始关注融合建模技术的发展动态, 但现有工作或局限于分析方法特性及模式

分类^[6-7],或侧重阐述融合效益^[8],或主要聚焦综合安全评估或动态安全防护等应用场景^[9-10]。总体而言,现有研究尚未充分挖掘融合建模在新型电力系统运行中的独特价值^[11]。另外,高比例可再生能源的研究与实践已开展多年,积累了不少研究成果^[5],但这些工作还无法全面展现融合建模的关键技术特征与发展脉络,亟需找到融合建模技术特征与新型电力系统需求的结合点,提炼典型应用场景与技术体系。

为此,本文重点关注面向新型电力系统运行的融合建模技术,梳理核心挑战与关键问题,全面揭示融合建模技术应用于新型电力系统运行领域的潜在优势与不足,为后续研究及工程实践提供参考。同时,本文也探讨了未来潜在的技术发展方向。

后续章节安排如下:1节介绍基本术语与发展趋势;2节分析关键技术特征与典型模式;3节全面综述面向新型电力系统运行的融合建模技术;4节讨论现阶段不足及未来发展方向;5节进行全文总结。

1 融合建模概念与发展趋势

本节首先聚焦于融合建模的概念与术语,明确界定本文关注的概念范围。接着讨论融合建模的主要应用场景,并分析其研究趋势及技术前景。

1.1 概念梳理与辨析

目前大部分文献并未对融合建模进行明确定义^[8],往往仅侧重于刻画融合建模在总体架构^[7]、内部衔接^[12]、性能效果^[13]等方面的特点。本文吸纳现有研究中的概念描述要点,将本文关注的融合建模技术具体定义如下。

融合建模是包含物理模型与数据驱动模型要素、具备机理规则与历史经验相结合特征、适用于多样化建模对象与应用场景、以提升建模精度及降低计算代价为主要目标、具有可解释性与可靠性优势的一类通用型架构体系与建模技术。其中,物理模型与数据驱动模型依据各自特性适配不同的建模环节,形成紧密的衔接关联,从而实现总体建模性能与效率的提升。

相关术语中,物理模型有时称作机理模型、解析模型、知识驱动模型、规则驱动模型等;数据驱动模型有时称作经验模型,或直接具象化为人工智能模型、机器学习模型、深度学习模型等。融合建模的同义概念包括混合建模、联合驱动模型、耦合

模型、知识引导型机器学习等。

融合建模作为一类通用型建模技术,可以应用于多种应用场景,包括现有文献大量讨论的电力物联网、电力信息物理系统、能源互联网、数字电网、智慧电网和数字孪生等。需要指出,这些应用场景的涌现得益于信息技术的快速发展,因而特性上都强调物理系统与信息技术结合,而新兴的融合建模技术正好与这类特性相匹配,应用潜力巨大。

1.2 适用条件

相比于传统物理模型,融合建模的流程与步骤更加复杂,因此使用前必须合理判断其适用性。

采用融合建模的基本前提是同时具备物理模型与数据资源条件,即物理机理大致明确且数据储备充足。如果前提条件不满足,融合建模方法将不再适用,或性能将受到影响。需要强调的是,前提条件不仅包括存在性,还应包括可获得性,比如不能忽视敏感数据与隐私数据的获取难度。

事实上,上述前提条件并不苛刻,现实中很多应用场景都能满足这些条件。其中,融合建模方法尤其适合处理以下3类情形:

1) 物理模型复杂度高。物理模型的计算复杂度受变量规模、0/1 变量数量、非线性环节性质、仿真步长等多重因素影响。大系统、强非线性、高分辨率的建模分析常常面临高复杂度,例如输电网的暂态仿真^[14]。在这类应用场景中,融合建模能够利用数据驱动方法提炼复杂模型的关键特征,实现模型降维。通过引入历史经验,融合建模还可以大幅简化决策环节,从而有效提升计算效率。

2) 物理模型精度不足。构建物理模型的前提假设通常较为理想化,当现实情况偏离假设或存在严重的随机干扰时,模型精度可能显著下降,例如用户侧竞价分析^[15]及电力市场博弈^[16]。在这类应用场景中,融合建模可以利用历史数据修正物理模型参数,或通过模式识别挖掘全新的解析表达式,还能够准确量化影响程度并识别极端场景。

3) 数据驱动模型可靠性不足。数据驱动模型的性能受数据质量、数据噪音、训练效率等因素影响,存在估计结果不可靠的隐患,例如深度学习模型难以避免对抗样本现象^[17]。在这类应用场景中,融合建模能够根据物理机理来设计数据预处理环节,或根据物理特性来改造数据驱动模型,还可以利用物理模型框定数据驱动模型估计的置信范围。

1.3 发展趋势简评

融合建模技术可视为数据驱动建模在新发展阶段的技术延伸与未来重要的发展方向，这符合人们对数据驱动方法的认知与应用过程。

纵观近些年的研究趋势，不难发现由于经典物理模型越来越难以精确刻画复杂系统运行规律，数据驱动方法受到越来越多的关注。事实上，数据驱动领域的文献数量正高速增长(尤其是以神经网络为代表的机器学习研究)，给传统基于物理机理的建模提供了新的思路与解决方案。

虽然目前数据驱动方法在预测、仿真计算、运行优化等领域已有一些应用，但经典的数据驱动方法也应用中也逐渐暴露出其不足(例如对抗样本问题^[17])，引发了学术界与工业界的广泛讨论与反思。

目前普遍认为，应当升级改造数据驱动技术，有效提升这类技术的透明性、稳健性、可解释性^[18]，加速迈入下一个发展阶段^[19]。其中，与现有物理模型深度配合、构建融合建模体系是一项重要的发展趋势。2 个典型案例如下：

1) 近年来基于人工智能的科学探索发展迅猛^[20]，其核心思想正是利用机器学习强大的数据归纳分析能力去学习甚至发掘新的科学规律，最终实现数据与知识、经验与规律的互促双赢。

2) 近年来智能计算成为数值计算领域的新兴发展方向^[21]，它将传统的统计计算拓展到认知智能、人机融合等多种计算范式。其中重要的发展理念正是以知识为目标，提供高质量、安全、可靠和透明的计算服务。

可以预见，随着研究经验的逐步积累，融合建模在各细分领域的主流技术框架与独特优势也将日益清晰，有助于加快新型电力系统数字化与智能化的发展进程。

2 融合建模的典型模式

作为一项快速发展的技术领域，融合建模并没有局限于单一的发展方向，而是多条技术路线同时发展，形成了丰富的方法体系。

本节聚焦于融合建模的技术特征与典型模式，旨在从繁杂的方法体系中剥离出核心建模思想，从而厘清融合建模的工作模式与机理。

2.1 关键技术特征

融合建模通常包括物理模型、数据驱动模型、交互接口 3 个子环节，如图 1 所示。实际上，融合

建模的技术特征可视作各子环节特性的总和。下面展开分析不同子环节中的关键技术要点。




图 1 融合建模的基本框架

Fig. 1 Basic framework of hybrid modeling

2.1.1 物理模型与数据驱动模型

物理模型依据物理机理建立，一般遵循系统论思路，采用自下而上的建模范式。这决定了物理模型内每个细小部件都具有明确的物理意义。例如经典的电力系统模型^[22]，就是按照元件模型、网络矩阵方程、系统模型逐级建立起来的。

数据驱动模型则基于经验建立，依赖大量的实测数据，通常采用端到端的建模范式。这类模型尤其适合处理机理模糊不清的应用场景，但模型内部单一参数缺乏明确的物理意义(甚至大量参数是冗余的)，只能确保所有参数在宏观上学习到数据的映射特征，另外模型性能也具有不确定性与不稳定性。例如许多基于机器学习的负荷预测模型^[23]，通常只能描述各相关因素对负荷的总体影响，而难以严格分析单因素作用与多因素耦合的机理。

建模形式的灵活度方面，物理模型具有一定的“刚性”。若假设的物理机理准确，物理模型往往能够得到简洁而精确的表达式；若存在偏差，则可能显著影响模型精度。而数据驱动模型则具有一定的“柔性”，这类模型不依赖先验的机理假设，自由度较高，但训练时需调用大量的标注数据资源。可见，融合建模可算作一种折中方案，能够弥补两类模型的不足，更适用于复杂多变的应用场景。

2.1.2 交互接口

交互接口是融合建模体系中的要点和难点，发挥着协调物理模型与数据驱动模型的重要作用。尽管具体实现方案各异，但大体可以将交互接口划分为基于数据和基于模型这两种类型。

基于数据的交互接口是指模型之间通过传递参数或变量的估计值进行交互，通常包括双向的信息传递流(见图 1)。例如，利用物理模型生成仿真数据以训练数据驱动模型^[24]，或通过数据驱动模型估计边界参数以提升物理模型计算精度^[25]。这类交互接口的性质主要受两方面因素影响，即数据本身

的估计精度、物理模型及数据驱动模型对该数据的敏感度。

基于模型的交互接口是指根据物理模型特征指导数据驱动模型的架构或表达式设计,一般表现为单向的信息传递流(见图1)。例如,根据物理模型结构性设计数据驱动模型的损失函数^[26-27],甚至直接将数据驱动模型近似转化为解析模型^[28]。这类交互接口的性质与架构设计、表达式设计细节息息相关,一般不具有通用法则,设计方案只适用于特定的应用场景。

需要补充的是,实际应用中两种交互类型可能同时存在,也可能按顺序出现。交互接口类型的多样化,本质上反映了应用场景的多元与复杂性。

2.2 典型融合模式

融合建模中3个子环节可以通过不同组合方式,构成多种融合模式。图2展示了其中4种典型模式:替代模式、嵌套模式、串联模式和反馈模式。下面逐一探讨这4种模式的基本思路与技术难点。

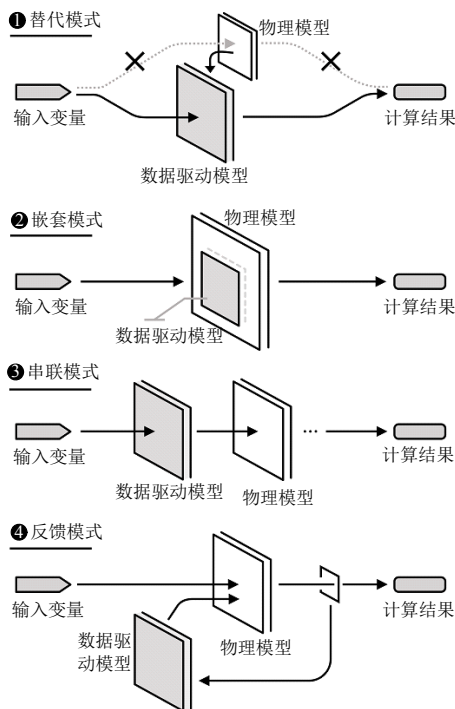


图2 融合建模的4种典型模式

Fig. 2 Four typical patterns of hybrid modeling

2.2.1 替代模式

如图2所示,替代模式是指用数据驱动模型直接替代原始物理模型的功能,主要适用于物理机理不清晰或任务复杂度较高的场景。

该模式的数据驱动模型通常采用强化学习模型^[29],部分文献采用知识引导型机器学习,例如物理引导神经网络^[30]。该模式一般采用基于模型的交

互接口,即在数据驱动模型设计中充分参考物理模型特性。该模式可以体现将物理模型嵌入数据驱动模型的思想。如何改进交互设计以及数据驱动模型的训练效率是主要难点。

例如,可采用替代模式处理输电网频率控制^[31]、微电网电压控制^[32]以及交通网-电网耦合规划问题^[33]。

另外,部分文献讨论的并行模式与替代模式相近^[34],但不直接丢弃物理模型分支,而是物理模型和数据驱动模型分别计算出结果,再求加权平均或选择较优解。

2.2.2 嵌套模式

如图2所示,嵌套模式是指将数据驱动模型整体嵌入物理模型当中,主要适用于物理模型有效但存在性能缺陷的场景。

该模式通常采用数据驱动模型生成经验函数,进而嵌入物理模型的优化目标、约束条件或状态方程中,一般是替代其中的非精确环节。交互接口设计比较复杂多变,既可以在求解过程中迭代交互(基于数据的交互接口),也可以将数据驱动模型近似转换成易于处理的解析形式(基于模型的交互接口)。

例如,可采用嵌套模式实现内嵌稳定约束的运行规划^[35]、考虑用户历史行为的定价决策^[36]以及精细化考虑用电特性的建筑能耗控制^[37]。

2.2.3 串联模式

如图2所示,串联模式是指物理模型与数据驱动模型以顺序或交替迭代的方式连接,主要适用于存在主从迭代或串联运行的场景。图2的模式图只作简化示意,其中物理模型与数据驱动模型的顺序可对调。

该模式主要采用基于数据的交互接口,而物理模型与数据驱动模型的选择较灵活,因此模式特性也各不相同。

例如,可采用串联模式加速分布式需求响应的定价过程^[38]、多阶段区域电网控制^[39]以及筛选电网安全准则^[40]。

2.2.4 反馈模式

如图2所示,反馈模式是指利用数据驱动模型反馈修正物理模型参数以保障最终的输出质量,主要适用于校正控制或逐次迭代优化的场景。

与串联模式类似,该模式主要采用基于数据的交互接口,而物理模型与数据驱动模型的选择较灵活。该模式一般具有明确的评价指标,用于快速判

断物理模型的输出质量。

例如，可采用反馈模式提升配网实时控制精度^[41]、逐次修正主干网暂态稳定参数^[7]以及提高动态安全检查与校正控制效率^[42]。

需要指出的是，典型模式与应用场景不具有严格的一一对应关系，需依靠方案比对以确定最佳模式。事实上，同一个应用场景的边界条件一旦改变，则可能需要切换模式，具体应用中需把握“问题特征决定适用模式”的基本思路。

3 新型电力系统运行中的融合建模技术

3.1 核心技术挑战

新型电力系统的源-网-荷-储形态将发生显著变化，传统建模方法在精确度与计算效率等方面面临全新挑战。经典建模理论广泛采用解析表达的物理模型，这是因为电源和电网的底层机理明确。然而，该先决条件在未来新型电力系统中将不再成立。本节将新型电力系统划分为用户层、设备层、网络层、系统层，层次结构如图 3 所示，各层次面临的建模难点具体表现为：

1) 用户层。与日俱增的灵活性负荷具备响应电网激励信号的潜力，但其响应行为模式与响应能力受到众多外部因素影响，难以用物理模型精确描述；此外，终端电气化水平提高与用户侧分布式新能源接入共同加剧了负荷建模的复杂性。

2) 设备层。系统中将涌现并接入了海量新型电力设备，包括新能源机组与储能电站。新能源波动性加剧了系统电力电量失衡风险，同时也对设备级智能化协同控制与故障诊断提出了更高要求。

3) 网络层。输配电网规模扩张、多区域互联、交直流混联等因素导致新型电力系统的网架规模与复杂度显著提高，加剧了电网拓扑辨识、状态估计等任务的技术难度。

4) 系统层。由于用户层、设备层、网络层的复杂度耦合交织，新型电力系统呈现出多时空强不确定性与高度电力电子化两个全新的形态特征^[5]，在系统控制、风险管理、资源优化配置等诸多维度面临全新挑战。

新型电力系统建设既面临挑战，也不乏机遇。目前已经积累了充足的可用数据资源，包括智能电表采集的海量用户数据、高分辨率数值天气预报数据以及覆盖主干网架的 PMU 数据等。完善的数据资源为融合建模技术的工程应用提供了重要机遇。




图 3 新型电力系统层次结构

Fig. 3 Hierarchical structure of the new-generation power systems

接下来，本节将分别从用户层、设备层、网络层、系统层入手，探讨融合建模技术如何在不同层级支撑新型电力系统建设。

3.2 用户层融合建模技术

3.2.1 负荷建模与灵活性挖掘

新型电力系统亟需挖掘负荷侧灵活性资源以应对发电侧调节能力不足带来的运行风险。负荷侧的关键技术包括：高精度用户用电行为建模、基准负荷预测、需求响应潜力预测等。

终端用户行为受到大量非机理性因素影响，通常采用灰箱模型建模，这类模型的参数无法直接量测获得，一般需采用数据拟合估计的方法。

灰箱模型的一种典型形式是基于效用函数的决策模型及多时段价格弹性模型^[43]。例如文献[44]将居民用户负荷的价格弹性用边际效用函数和功率约束表征，构建双层优化模型，并采用启发式算法进行估计；文献[45]采用解析化效用函数刻画空调和电动汽车充电负荷的灵活性，构建与文献[44]类似的双层优化模型以估计效用函数中的关键参数；文献[46]采用条件隐半马尔可夫模型对居民负荷的序费用用电决策行为进行概率化建模，其中依循串联模式，用半监督聚类 and 统计回归的数据分析方法估计状态转移分布参数，显著降低计算复杂度。

灰箱模型的另一种典型形式是组合式的非线性函数，属于融合建模中的串联模式。比如文献[47]将机器学习模型与柔性负荷解析模型组合起来，其中机器学习模型用于拟合柔性负荷解析模型与真实数据之间的残差。针对含分布式新能源的负荷侧建模问题；文献[48]将净负荷分解为实际负荷、光伏功率与残差，采用数据驱动模型估计实际负荷，采用物理模型计算光伏功率，通过迭代的串联模式对二者进行交替估计；文献[49]则分别构建实际负荷与光伏功率的样例库，并提出双层优化模型以选

取最合适的样例及其权重。

值得注意的是,现有文献在应用融合建模技术时很少考虑用户侧数据的质量问题以及隐私保护问题,这是实际应用中必须解决的难题。

3.2.2 新型负荷建模与分析

随着终端电气化水平提升,电热耦合设备、电动汽车等新型负荷大量涌现,造成负荷结构与形态的显著变化。传统物理模型往往难以准确刻画多样化的新型负荷特性,而融合建模技术可以挖掘历史数据中的潜在模式,形成新型负荷的自适应与高精度建模方法。

针对电热耦合设备,文献[50]基于热动态过程建立建筑能耗的简易物理模型,并结合实际数据以反馈模式修正模型参数;文献[51]采用局部线性模型描述建筑暖通空调系统的能耗特性,借助串联模式,同时保证物理模型的可解释性与数据驱动模型的强拟合能力;文献[52]在拟合空调负荷的等效热参数模型后,采用深度神经网络估计物理模型中的状态变量,使模型具有自适应校准的能力;文献[53]采用数据驱动模型对工业空气分离装置的动态特性进行近似,并作为约束条件内嵌于需求响应决策模型。针对电动汽车充电负荷;文献[54]对电动汽车行驶里程与充电模式进行聚类,并据此设计长短期记忆网络的训练策略;文献[55]建立条件随机场模型预测电动汽车充电负荷,模型结构体现出充电负荷弹性的时空相关性,并理论推导出模型参数与价格弹性之间的关联关系。

3.3 设备层融合建模技术

3.3.1 新能源发电预测与控制

新能源机组运行的安全经济性依赖于精准的预测和控制技术。新能源发电预测方面,以往通常采用纯数据驱动模型,而适当融入物理先验知识往往能够提升预测精度与稳健性。新能源发电控制方面,基于扰动-搜索的传统最大功率点跟踪方法,在搜索效率和稳定性方面存在不足,融合建模技术可以利用历史数据有效改进跟踪性能。

文献[56]根据光伏发电功率解析模型将关键气象因素重构为一系列特征数据,再采用主成分分析法提取关键特征,作为机器学习模型的输入变量,通过顺序连接的串联模式提升光伏出力的预测精度;文献[57]利用神经网络预测光伏模组的输出电流,利用迭代算法确定最大功率点电压;文献[58]用循环神经网络拟合风机的物理动态模型,并基于

反馈模式设计自适应动态控制算法以实现风机的最大功率点跟踪;文献[59]基于物理模型对风电异常数据进行清洗,避免数据驱动模型精度受到影响;文献[60-61]利用神经网络拟合废热温差发电系统的输入输出关系,并嵌套于贪心搜索算法中寻找最大功率点。

3.3.2 储能系统监测与控制

储能是支撑新型电力系统调峰调频的关键资源,其中荷电状态估计和异质储能协调控制是提升储能运行效率的关键技术。实践中,荷电状态估计面临模型精度与计算复杂度的矛盾,融合建模技术可以在同等计算复杂度下大幅提升估计精度;异质储能协调控制的难点在于大规模组合优化问题的求解,融合建模技术可实现高质量可行解的快速估计。

为提高锂离子电池荷电状态的估计精度,文献[62]基于串联模式,采用极限学习机对等效电路模型得到的荷电状态进行误差修正。误差修正的流程如图4所示,一般用于提升简化物理模型的精度,是一种常用的顺序串联融合模式;文献[63]关注异质储能电池组的协调控制问题,并依循替代模式,训练Q学习智能体控制各个电池的开关状态。训练策略根据任务特性进行设计,引入了即时奖励函数,实现储能缺额出现时给予超额惩罚;文献[64-65]提出将领域知识以约束的形式嵌入数据驱动模型,从而避免结果违反常规经验判断,有效降低微电网调度等场景中的运行风险。利用类似的嵌套模式,文献[66]在应用强化学习解决电池储能系统的动态规划问题时,利用物理约束减少训练过程中冗余的动作探索。

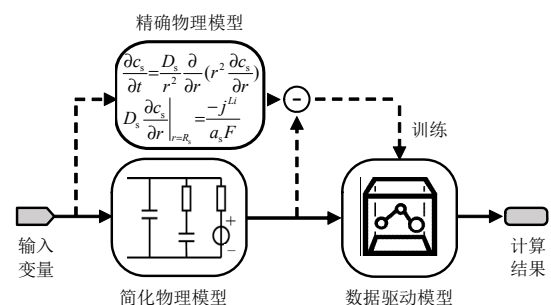


图4 误差修正流程

Fig. 4 Process of error modification

3.3.3 电气设备故障诊断

典型的电气设备故障诊断方法采用系统模型计算特定的残差信号,并与预设故障集对照以判断故障类型。在故障类型判断环节引入数据驱动模型往往能有效提升决策精度,目前关注的重点是如何

引入物理知识以提升故障诊断的一致性与效率。

文献[26-27]提出将领域知识嵌入机器学习模型的引导学习理论，通过在模型的损失函数中以嵌套模式添加领域知识判断函数进行引导，并将该模型应用于配电网健康指数综合分析与诊断；文献[67]用长短期记忆神经网络拟合风机状态相比健康状态的偏差量，并采用随机森林模型判断故障位置；文献[68]采用傅里叶变换和主成分分析对三相逆变器输出电压信号进行处理，并将结果以串联模式输入贝叶斯网络以判断故障开关位置；文献[69]同样利用主成分分析法，根据电池组的电压量测数据定位故障电池。变压器油的气体色谱分析是变压器故障诊断中的常用方法，文献[70]提出了利用决策树、神经网络等数据驱动模型根据色谱分析结果判断变压器故障种类，文献[71]综述通过色谱分析法与数据驱动模型诊断变压器绝缘情况的研究。

需要注意的是，建立故障诊断的数据驱动模型时，故障样本占比往往较低，因此需要特别关注样本分布不平衡问题，一些文献利用过采样抽样方法予以应对^[72]。

3.4 网络层融合建模技术

3.4.1 网络拓扑辨识

新型电力系统运行中，输、配电网规模与复杂性将大幅增加，拓扑变化更为频繁，基于物理模型的拓扑辨识方法由于计算速度慢、网络拓扑信息缺失等原因往往难以适用。融合建模技术能够将终端智能电表数据与网络物理拓扑信息结合，提升网络拓扑和线路参数的辨识精度与效率。

文献[41,73]关注配电网节点电压与注入功率的关系，提出近似线性假设替代完整解析模型，进而通过电压敏感度矩阵估计网络拓扑与线路参数；文献[74]在中低压配电网拓扑结构估计中，由配电网潮流推导出电压向量统计独立性的先验知识，并利用该知识设计基于概率图的数据驱动估计模型。文献[75]采用期望极大化算法与潮流模型对历史无标签样本进行拓扑辨识，并利用辨识结果训练机器学习模型以替代解析化方法。文献[76]提出一种数据驱动的系统拓扑和线路参数迭代估计框架，同时考虑了潮流模型中输入输出信号的测量误差；文献[77]进一步将算法拓展到系统拓扑改变的场景中。文献[78]将分布式电源出力对配网交换功率的影响建模为一个线性时变系统，利用实时运行数据计算灵敏度向量，最终得到系统参数估计结果。

3.4.2 状态估计

精准快速的状态估计算法是新型电力系统运营管理的重要需求。然而传统状态估计算法的收敛速度存在提升空间，对于错误数据与通信阻塞的容差性能也往往不够理想，融合建模技术主要从数据预处理与物理模型迭代两个角度加以改进。

针对状态估计中 Gauss-Newton 法对初始值敏感、迭代收敛慢的问题，文献[24]使用仿真数据集训练神经网络预测配电网状态量，将其作为 Gauss-Newton 法的迭代初始值，以串联模式提高收敛速度与稳定性。文献[79]采用长短期记忆神经网络预测的节点状态以校验量测数据，同时根据潮流方程补充缺失数据；文献[80]在状态估计模型中以嵌套模式添加数据驱动的置信度约束，从而提升算法抵御恶意数据攻击的能力；文献[81]提出一种替代模式的状态估计框架，高频在线状态估计中数据驱动模型完全取代了物理模型，而后者主要用于处理低频的完整量测数据，并对拓扑信息进行滚动更新；文献[82]遵循串联模式，采用直流潮流模型近似计算节点电压相角，并与其他量测数据拼接后输入图卷积神经网络，最终提升电压幅值与相角的估计精度；文献[83]用深度神经网络拟合量测与状态之间的映射关系，并将潮流方程算得的残差作为损失函数内嵌于训练过程中。为解决 PMU 量测数据不完整问题，文献[84]采用生成对抗网络近似补全缺失的 PMU 数据，该方法不依赖网络可观性和拓扑信息。

3.4.3 潮流计算与优化

潮流计算与优化方法普遍面临计算精度与计算效率的矛盾。当前研究主要关注如何通过融合建模技术，以少量精度损失换取大幅的计算速度提升。主流思路分为 2 类：1) 在简化物理模型的同时，采用数据驱动模型以串联模式修正模型误差；2) 构建物理机理引导的数据驱动模型，整体替代原始物理模型。

文献[85]提出一种基于串联模式的潮流线性化方法，利用偏最小二乘回归拟合线性化潮流模型的计算误差，该方法在精度上明显优于线性潮流模型或纯数据驱动模型；文献[86-87]采用线性回归形式替代完整潮流方程，并结合偏最小二乘与贝叶斯线性回归估计模型参数；文献[88]基于嵌套模式提出一种物理知识指导下的数据驱动潮流求解方法，依据物理模型设计全新的正则项函数，从而将物理知

识内嵌于潮流求解器的训练过程。文献[89]基于最优潮流物理模型设计由3部分构成的极限学习机,分别输出潮流、节点状态、最优控制变量与目标函数;文献[90]采用二项式回归得到交流潮流方程的凸近似,从而用凸二次规划模型替代原本的最优潮流模型;文献[91]利用数据驱动方法识别并剔除机组组合模型中的无效约束,从而简化模型,提升求解效率。

需要注意的是,融合建模技术还可以处理网络信息缺失下的潮流计算与优化问题。例如文献[92]基于替代模式提出结构化学习模型,提出基于支持矩阵回归的核函数估计方法,构建数据驱动的潮流函数。

3.5 系统层融合建模技术

3.5.1 不确定性建模与内嵌

强不确定性使新型电力系统的电力电量平衡发生深刻变化,传统的确定性优化方法难以保障电网运行的安全经济性。在不确定性优化模型中,对随机变量的刻画是影响优化结果的关键因素。融合建模技术通常采用嵌套模式,利用数据驱动模型描述随机变量波动,给出其不确定集或概率分布,进而嵌入解析优化模型中。

文献[25]采用数据驱动方法描述风电可调度范围,通过最大化扩充可行域以减少弃风量。文献[93]利用历史数据拟合一系列超平面作为风电出力不确定集的边界,并嵌入鲁棒机组组合模型;文献[94]采用随机过程混合模型构建风电预测误差的不确定集,并嵌入自适应鲁棒优化模型解决机组组合问题,改善了优化结果的保守性问题;文献[95]采用高斯混合模型描述风电出力不确定性,通过机会约束模型求解电-气耦合系统的最优潮流。

数据驱动的分布鲁棒优化是一类采用数据统计方法处理历史数据的融合建模场景,主要呈现为串联模式。其中关键步骤是构建随机变量概率分布的模糊集,构造方法包括3类^[96-97]:统计矩法、置信区间法、距离法。统计矩法通常需要历史数据分布的均值(一阶矩)和方差(二阶矩),置信区间法需要历史数据的累计分布情况,距离法需要历史平均分布并通常采用 Wasserstein 距离进行分布波动性衡量^[98]。

现有研究主要关注如何采用数据驱动方法提升模糊集的建模精度。文献[99]在统计矩法基础上增加考虑了多面体不确定区间,从而减小了模糊集

的保守性;文献[100]采用核支持向量聚类模型生成高精度的模糊集;文献[101]构建了基于场景的不确定集,包括一阶矩约束和场景凸包约束。文献[102]提出人工智能和大数据技术可以支撑更复杂的数据扫描、聚类和相关性分析,从而提升模糊集的建模精度。

现有研究也注重采用前置的数据驱动处理,保证模糊集内嵌后的计算效率。文献[103]用主成分分析法对美国德州4年的小时级风电数据进行降阶处理,大幅减小内嵌后等效约束的规模;文献[97]仿真分析了数据量增大后置信区间变窄和计算时间的趋势变化,以便选取精度-计算速度的最佳平衡点;文献[104]将机器学习模型作为前置处理环节,高效筛选出关键不确定性变量,从而大幅提升分布鲁棒优化计算速度。

值得注意的是,不确定性建模中,数据驱动环节对最终优化的影响有时难以精确分析。极端场景可能导致数据驱动环节性能不稳定,此时融合模型的性能如何改进,尚需进一步研究。

3.5.2 系统稳定性评估

大量电力电子设备接入使新型电力系统运行的稳定机理日趋复杂,而系统惯量的降低对稳定性评估方法的实时性与准确性提出了更苛刻的要求。在线稳定性评估中,以时域仿真为代表的物理模型难以满足计算速度的要求,而数据驱动模型在可解释性与可靠性方面存在不足,融合建模技术则提供了兼顾计算速度与可靠性的可能性。由于涉及安全稳定问题,相关的融合建模技术特别关注利用物理机理提升模型的可解释性与性能稳健性。

文献[105]基于串联模式,将频率响应简化模型的输出与其他因素共同作为极限学习机的输入,实现频率动态特征的在线预测。在此基础上,文献[106]进一步采用极限学习机预测切除负荷量与频率动态特性的关系;文献[107]在交直流系统故障预测问题中,提出采用极限学习机以串联模式对高压直流输电系统简化模型的误差进行修正;文献[108-109]将类似的串联模式用于临界切除时间的在线估计问题。针对样本数据获取难的问题,文献[109]提出采用物理模型产生的特征评估样本相似性,从而实现不同运行模态下的样本迁移;文献[34]提出一种基于并行模式的暂态稳定性评估方法,在数据驱动模型的结果可靠性不足时调用物理模型。文献[110]将潮流雅克比矩阵作为卷积神经网络的输入,从而

在线预测静态电压稳定性。

部分研究关注基于嵌套模式的系统稳定性约束提取方法，数据驱动环节最终转化成约束嵌入优化调度模型中。文献[35]提出采用稀疏斜决策树在给定的边界条件下判断稳定性，并提取电力系统的安全稳定规则，将其表达为线性约束条件嵌入经济调度模型中；文献[111]采用决策树从系统动态模型中提取频率动态安全规则并嵌入机组组合模型中；文献[112]建立一套基于深度置信网络的电力系统暂态稳定评估器用于拟合发电机出力与暂态稳定性之间的映射关系，作为非显式约束嵌入进化算法的迭代寻优过程中。

3.5.3 故障定位与系统保护

新型电力系统故障具有种类多样、机理复杂、定位困难等特点，实时运行中需要快速、精准地定位故障源，并从大量调节与保护手段中筛选出最优方案。

文献[113]提出一种适用于配电网的故障定位方法，通过深度优先搜索将故障区域范围缩小，基于量测电压数据确定故障位置；文献[114]提出基于混合整数非线性规划的潮流安全校正方法，并以顺序的串联模式加速求解，通过深度神经网络确定整数变量的取值后再以解析方法求解连续优化问题；文献[115]设计一种抑制区域间低频振荡的广域控制方法，其中内嵌了采用数据驱动的耦合矩阵以描述子区域间的相互影响；文献[116]基于随机矩阵理论，通过分析广域量测数据的相关性确定故障发生时间与区域。

3.5.4 市场运行与决策

随着电力市场的建设发展，新型电力系统运行中的供需平衡将主要通过市场交易的方式实现，信息不对称与市场成员行为的复杂性将显著影响市场有效性。实际市场中，存在大量难以用物理机制精确描述的要素，例如市场成员策略、用户偏好等^[117]。采用数据驱动模型描述这些复杂环节，并嵌入市场运行框架，往往能使模型结果更贴近真实情况。

针对用户偏好未知的难题，文献[118]提出基于嵌套模式的需求响应聚合商的两阶段调度策略，第一阶段采用基于噪声逆优化的数据驱动方法估计用户负荷的价格响应特性，第二阶段采用主从博弈模型描述聚合商与市场运营商之间的竞价过程。文献[36]提出将数据驱动模型转化为优化模型约束条件的方法，并将其应用于内嵌考虑用户价格响应特

性的负荷聚合商的决策过程；文献[38]提出在对偶分解法的迭代框架中采用神经网络选择拉格朗日乘子，以串联模式避免迭代过程中的振荡，从而加速分布式需求响应的定价过程；文献[119]采用神经网络拟合建筑热惯性模型，并提取为显示表达式作为约束嵌入售电商定价模型。在多个分布式电源聚合商竞争的市场中，文献[120]利用历史数据生成新能源预测误差和竞争者策略的不确定集，基于风险偏好以嵌套模式设计最优竞价策略。

值得注意的是，市场数据常常因涉及用户隐私或商业机密而被归为敏感数据，但目前相关应用研究中对隐私保护问题的关注还非常有限。

4 核心挑战与研究展望

融合建模给新型电力系统运行带来了新的发展机遇，但同时也引入了潜在的技术风险。

图 5 列出了现阶段融合建模技术面临的 3 项核心挑战：可解释性难题、性能稳健性难题、数据质量与体量难题。这些难题非常普遍，但在不同应用场景中的表现形式可能存在差异。因此，使用融合建模既需要遵循一般化的原则与方法论，也需要具体问题具体分析。

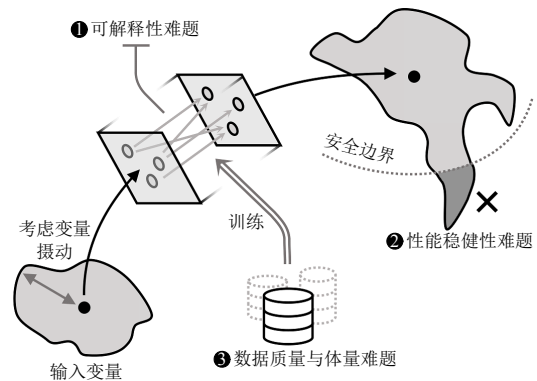


图 5 现阶段技术方法面临的主要风险
Fig. 5 Major risk factors for existing hybrid modeling techniques

本节聚焦融合建模的技术风险与不足，重点梳理常用的应对策略。深入理解并量化技术风险是后续推动技术迭代与工程应用的前提条件，因而本节还将针对未来研究方向展开讨论，包括一些具有前景的研究方向。

4.1 可解释性难题

许多数据驱动模型属于“黑箱”模型，尤其是近年快速发展起来的深度学习模型。所谓“黑箱”，是指模型内部参数大量冗余、缺乏直观物理意义，结果不容易理解与分析。融合建模通过将数据驱动

模型和物理模型有机融合,相当于将“黑箱”转化为“灰箱”(见图5),在可解释性上有所提升,但仍然具有一定不足。

可解释性不足的直接后果是模型作用机理模糊,缺乏对参数数值特性的认知,这会降低模型的可靠性。遗憾的是,现有研究一般并不追求严格的理论保障,转而采用叙述性而非证明性的方法论以分析模型效果。

因此,为应对可解释性难题,未来应重点研究可靠型融合建模技术:

1) 数据驱动建模应当尽量精简,优先采用简单模型与小规模模型,同时注意缩短映射环节数量。事实上,合理配置简单的小规模模型足以得到媲美大模型的性能表现,其中典型模型具体包括决策树与支持向量机。

2) 应积极借鉴机器学习领域的前沿研究成果。目前可解释机器学习已经得到长足发展,此外模型压缩方面也涌现出以模型剪裁、核稀疏化、模型蒸馏为代表的典型技术。

4.2 性能稳健性难题

现有研究大多测试规模小,验证融合建模有效性的案例数量不足,对模型性能的稳健性考虑不够充分。稳健性用于衡量不同输入变量摄动下,最终输出结果的变化程度。考虑到融合建模往往涉及多个子环节,性能波动的风险更大,在误差容忍度低的应用场景中需格外注意。

稳健性差具体表现为:模型输出质量深受输入变量摄动影响,甚至在一些极端摄动下,发生输出结果违背系统安全约束的现象(见图5右侧)。由于缺乏严格的稳健性检查,潜在风险可能被严重低估,此时融合模型的输出结果不再可靠,无法满足工程应用的性能要求。

因此,为应对性能稳健性难题,未来应重点研究融合建模的稳健性测试指标与方法体系:

1) 研究不同规模、不同模型结构的稳健性影响性质,提炼关键共性特征,推动建立标准化的稳健性测试指标。设计过程中应充分保证测试指标与电力系统现有性能指标的兼容与匹配性,需充分借鉴现有指标的设计思路。

2) 建立蒙特卡洛模拟与极端场景生成相结合的稳健性分析方法,重点关注输入摄动强度设置与测试场景生成两个技术要点。面向本文梳理的4种融合建模模式,应有针对性地选择测试技术与测试

条件。

3) 细化分析融合建模体系中不同子环节的稳健特性,识别影响整体稳健性性能的关键环节,设计识别关键环节的测试步骤与方法。

4.3 数据质量与体量难题

数据是融合建模的基本前提,数据问题对融合建模具有直接而深刻的影响。然而现有研究对数据问题的关注较少,数据往往作为前提条件而遵循简化或理想化假设。例如,质量方面,现有研究普遍使用仿真数据,假设数据免受噪音影响。数量方面,现有研究往往假设数据量充足,忽略数据量不足与数据高度冗余2种情况。

实际工程应用中,数据质量与体量难题往往是制约数据驱动及融合建模的首要障碍,应特别关注如何在不同的真实数据条件下提升建模效率与有效性。

因此,为应对数据质量与体量难题,未来应重点研究针对数据不足与高度冗余的融合建模技术:

1) 当数据不足时,可以引入先验结构化信息以降低数据驱动环节的数据需求量,典型技术包括小样本学习与迁移学习。深入研究数据噪声对小样本分布特性的影响,设计逐次自校正方法以抑制噪声影响扩散。

2) 当数据高度冗余时,研究高效的轻量级模型训练与超参优化方法,训练中注重设计并引入启发式方法。另外,针对实时性要求较高的应用场景,借鉴在线学习思路,设计逐次滚动迭代流程。

5 结论

海量新能源接入给新型电力系统运行带来一系列挑战,学术界与工业界开始关注数据-物理融合建模这一新兴技术路线。该技术能高效整合机理驱动与数据驱动方法的优势,显著提升建模精度,降低计算复杂度,具有广泛的应用前景。本文全面梳理融合建模的典型模式与发展趋势,结合新型电力系统运行的技术挑战讨论一系列融合建模案例,最后分析现有工作的不足与未来发展方向。

需要指出,融合建模技术作为数据驱动技术的深化发展,尚处于快速发展阶段,相关研究方兴未艾,实用价值还有很大的挖掘空间,亟需持续的研发投入与工程实践。本文通过总结融合建模的最新进展,旨在展现该技术方向的发展前景,为后续研究提供参考。

参考文献

- [1] International Energy Agency. World energy outlook 2021[R/OL]. [2021-10-01]. <https://www.iea.org/reports/world-energy-outlook-2021>.
- [2] U.S. Energy Information Administration. Annual energy outlook 2021 with projection to 2050[EB/OL]. [2021-02-03]. <https://www.eia.gov/outlooks/aeo>.
- [3] 澎湃新闻. 中央财经委员会: 构建以新能源为主体的新型电力系统 加快推进碳排放权交易[EB/OL]. [2021-03-16]. https://m.thepaper.cn/baijiahao_11725901. The Paper News. Central committee of finance and economics: establish new-generation and renewable-dominated power systems and accelerate the carbon emission trades[EB/OL]. [2021-03-16]. https://m.thepaper.cn/baijiahao_11725901(in Chinese).
- [4] 卓振宇, 张宁, 谢小荣, 等. 高比例可再生能源电力系统关键技术及发展挑战[J]. 电力系统自动化, 2021, 45(9): 171-191.
ZHUO Zhenyu, ZHANG Ning, XIE Xiaorong, et al. Key technologies and developing challenges of power system with high proportion of renewable energy[J]. Automation of Electric Power Systems, 2021, 45(9): 171-191(in Chinese).
- [5] 康重庆, 姚良忠. 高比例可再生能源电力系统的关键科学问题与理论研究框架[J]. 电力系统自动化, 2017, 41(9): 2-11.
KANG Chongqing, YAO Liangzhong. Key scientific issues and theoretical research framework for power systems with high proportion of renewable energy[J]. Automation of Electric Power Systems, 2017, 41(9): 2-11(in Chinese).
- [6] RUAN Guangchun, ZHONG Haiwang, ZHANG Guanglun, et al. Review of learning-assisted power system optimization[J]. CSEE Journal of Power and Energy Systems, 2021, 7(2): 221-231.
- [7] 李峰, 王琦, 胡健雄, 等. 数据与知识联合驱动方法研究进展及其在电力系统中应用展望[J]. 中国电机工程学报, 2021, 41(13): 4377-4389.
LI Feng, WANG Qi, HU Jianxiong, et al. Combined data-driven and knowledge-driven methodology research advances and its applied prospect in power systems[J]. Proceedings of the CSEE, 2021, 41(13): 4377-4389(in Chinese).
- [8] 赵鹏, 蒲天骄, 王新迎, 等. 面向能源互联网数字孪生的电力物联网关键技术及展望[J]. 中国电机工程学报, 2022, 42(2): 447-457.
ZHAO Peng, PU Tianjiao, WANG Xinying, et al. Key technologies and perspectives of power internet of things facing with digital twins of the energy internet[J]. Proceedings of the CSEE, 2022, 42(2): 447-457(in Chinese).
- [9] 郭庆来, 辛蜀骏, 孙宏斌, 等. 电力系统信息物理融合建模与综合安全评估: 驱动力与研究构想[J]. 中国电机工程学报, 2016, 36(6): 1481-1489.
GUO Qinglai, XIN Shujun, SUN Hongbin, et al. Power system cyber-physical modelling and security assessment: motivation and ideas[J]. Proceedings of the CSEE, 2016, 36(6): 1481-1489(in Chinese).
- [10] 杨杰, 郭逸豪, 郭创新, 等. 考虑模型与数据双重驱动的电力信息物理系统动态安全防护研究综述[J]. 电力系统保护与控制, 2022, 50(7): 176-187.
YANG Jie, GUO Yihao, GUO Chuangxin, et al. A review of dynamic security protection on a cyber physical power system considering model and data driving[J]. Power System Protection and Control, 2022, 50(7): 176-187(in Chinese).
- [11] RUBEN C, DHULIPALA S, NAGARAJ K, et al. Hybrid data-driven physics model-based framework for enhanced cyber-physical smart grid security[J]. IET Smart Grid, 2020, 3(4): 445-453.
- [12] 秦博雅, 刘东. 电网信息物理系统分析与控制的研究进展与展望[J]. 中国电机工程学报, 2020, 40(18): 5816-5826.
QIN Boya, LIU Dong. Research progresses and prospects on analysis and control of cyber-physical system for power grid[J]. Proceedings of the CSEE, 2020, 40(18): 5816-5826(in Chinese).
- [13] LIU Nian, LI Chenchen, CHEN Liudong, et al. Hybrid data-driven and model-based distribution network reconfiguration with lossless model reduction[J]. IEEE Transactions on Industrial Informatics, 2022, 18(5): 2943-2954.
- [14] TOMIM M A, MARTI J R, PASSOS FILHO J A. Parallel transient stability simulation based on multi-area Thévenin equivalents[J]. IEEE Transactions on Smart Grid, 2017, 8(3): 1366-1377.
- [15] HERRANZ R, SAN ROQUE A M, VILLAR J, et al. Optimal demand-side bidding strategies in electricity spot markets[J]. IEEE Transactions on Power Systems, 2012, 27(3): 1204-1213.
- [16] BALDICK R. Electricity market equilibrium models: the effect of parametrization[J]. IEEE Transactions on Power Systems, 2002, 17(4): 1170-1176.
- [17] LOWD D, MEEK C. Adversarial learning[C]// Proceedings of the 11th ACM SIGKDD International Conference on Knowledge Discovery in Data Mining. Chicago: ACM, 2015: 641-647.
- [18] ROSCHER R, BOHN B, DUARTE M F, et al. Explainable machine learning for scientific insights and discoveries[J]. IEEE Access, 2020, 8: 42200-42216.

- [19] DU Mengnan, LIU Ninghao, HU Xia. Techniques for interpretable machine learning[J]. Communications of the ACM, 2019, 63(1), 68-77.
- [20] STEVENS R, NICHOLS J, YELICK K. AI for science [R/OL]. 2019. [2020-03-01]. <https://publications.anl.gov/anlpubs/2020/03/158802.pdf>.
- [21] ZHU Shiqiang, YU Ting, XU Tao, et al. Intelligent computing: the latest advances, challenges, and future[J]. Intelligent Computing, 2023, 2: 0006.
- [22] 张伯明, 陈寿孙, 严正. 高等电力网络分析[M]. 2版. 北京: 清华大学出版社, 2007.
ZHANG Bomng, CHEN Shousun, YAN Zheng. Advanced power system network analysis[M]. 2nd ed. Beijing: Tsinghua University Press, 2007(in Chinese).
- [23] TAYLOR J W, BUIZZA R. Neural network load forecasting with weather ensemble predictions[J]. IEEE Transactions on Power systems, 2002, 17(3): 626-632.
- [24] ZAMZAM A S, FU Xiao, SIDIROPOULOS N D. Data-driven learning-based optimization for distribution system state estimation[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4796-4805.
- [25] QIU Feng, LI Zhigang, WANG Jianhui. A data-driven approach to improve wind dispatchability[J]. IEEE Transactions on Power Systems, 2017, 32(1): 421-429.
- [26] 尚宇炜, 马钊, 彭晨阳, 等. 内嵌专业知识和经验的机器学习方法探索(一): 引导学习的提出与理论基础[J]. 中国电机工程学报, 2017, 37(19): 5560-5571.
SHANG Yuwei, MA Zhao, PENG Chenyang, et al. Study of a novel machine learning method embedding expertise part I: proposals and fundamentals of guiding learning[J]. Proceedings of the CSEE, 2017, 37(19): 5560-5571(in Chinese).
- [27] 尚宇炜, 马钊, 彭晨阳, 等. 内嵌专业知识和经验的机器学习方法探索(二): 引导学习的应用与实践[J]. 中国电机工程学报, 2017, 37(20): 5852-5861.
SHANG Yuwei, MA Zhao, PENG Chenyang, et al. Study of a novel machine learning method embedding expertise (Part II): applications and practices of guiding learning [J]. Proceedings of the CSEE, 2017, 37(20): 5852-5861(in Chinese).
- [28] KIM Y J. A supervised-learning-based strategy for optimal demand response of an HVAC system in a multi-zone office building[J]. IEEE Transactions on Smart Grid, 2020, 11(5): 4212-4226.
- [29] DA SILVA F L, NISHIDA C E H, ROIJERS D M, et al. Coordination of electric vehicle charging through multiagent reinforcement learning[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2347-2356.
- [30] HUANG Bin, WANG Jianhui. Applications of physics-informed neural networks in power systems-A review[J]. IEEE Transactions on Power Systems, 2023, 38(1): 572-588.
- [31] YAN Ziming, XU Yan. Data-driven load frequency control for stochastic power systems: a deep reinforcement learning method with continuous action search[J]. IEEE Transactions on Power Systems, 2019, 34(2): 1653-1656.
- [32] LIU Zifa, LUO Ya, ZHUO Ranqun, et al. Distributed reinforcement learning to coordinate current sharing and voltage restoration for islanded DC microgrid[J]. Journal of Modern Power Systems and Clean Energy, 2018, 6(2): 364-374.
- [33] QIAN Tao, SHAO Chengcheng, WANG Xiuli, et al. Deep reinforcement learning for EV charging navigation by coordinating smart grid and intelligent transportation system[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1714-1723.
- [34] YI Jun, LIN Weifang, HU Jianxiong, et al. An integrated model-driven and data-driven method for on-line prediction of transient stability of power system with wind power generation[J]. IEEE Access, 2020, 8: 83472-83482.
- [35] HOU Qingchun, ZHANG Ning, KIRSCHEN D S, et al. Sparse oblique decision tree for power system security rules extraction and embedding[J]. IEEE Transactions on Power Systems, 2021, 36(2): 1605-1615.
- [36] RUAN Guangchun, ZHONG Haiwang, XIA Qing, et al. Embed neural network in optimization model: an application of demand response aggregation under information asymmetry[C]//Proceedings of 2019 IEEE Power & Energy Society General Meeting. Atlanta: IEEE, 2019: 1-5.
- [37] CHEN Yize, SHI Yuanyuan, ZHANG Baosen. Optimal control via neural networks: a convex approach[J]. arXiv: 1805.11835, 2018.
- [38] RUAN Guangchun, ZHONG Haiwang, WANG Jianxiao, et al. Neural-network-based Lagrange multiplier selection for distributed demand response in smart grid[J]. Applied Energy, 2020, 264: 114636.
- [39] BELLIZIO F, CREMER J L, SUN Mingyang, et al. A causality based feature selection approach for data-driven dynamic security assessment[J]. Electric Power Systems Research, 2021, 201: 107537.
- [40] 黄天恩, 郭庆来, 孙宏斌, 等. 模型-数据混合驱动的电网安全特征选择和知识发现关键技术与工程应用[J]. 电力系统自动化, 2019, 43(1): 95-101, 208.
HUANG Tianen, GUO Qinglai, SUN Hongbin, et al. Hybrid model and data driven concepts for power system security feature selection and knowledge discovery: key technologies and engineering application[J]. Automation of Electric Power Systems, 2019, 43(1): 95-101, 208(in Chinese).

- [41] XU Hanchen, DOMINGUEZ-GARCÍA A D, VEERAVALLI V V, et al. Data-driven voltage regulation in radial power distribution systems[J]. *IEEE Transactions on Power Systems*, 2020, 35(3): 2133-2143.
- [42] LIU Tingjian, LIU Youbo, LIU Junyong, et al. A Bayesian learning based scheme for online dynamic security assessment and preventive control[J]. *IEEE Transactions on Power Systems*, 2020, 35(5): 4088-4099.
- [43] RUAN Guangchun, KIRSCHEN D S, ZHONG Haiwang, et al. Estimating demand flexibility using Siamese LSTM neural networks[J]. *IEEE Transactions on Power Systems*, 2022, 37(3): 2360-2370.
- [44] SAEZ-GALLEGO J, MORALES J M, ZUGNO M, et al. A data-driven bidding model for a cluster of price-responsive consumers of electricity[J]. *IEEE Transactions on Power Systems*, 2016, 31(6): 5001-5011.
- [45] 鲁鹏, 吕昊, 刘念, 等. 数据-模型混合驱动的配电系统灵活性优化调度[J]. *湘潭大学学报: 自然科学版*, 2020, 42(5): 84-97.
- LU Peng, LV Hao, LIU Nian, et al. Hybrid data and model driven flexibility optimization dispatch of distribution system[J]. *Journal of Xiangtan University: Natural Science Edition*, 2020, 42(5): 84-97(in Chinese).
- [46] JI Yuting, BUECHLER E, RAJAGOPAL R. Data-driven load modeling and forecasting of residential appliances [J]. *IEEE Transactions on Smart Grid*, 2020, 11(3): 2652-2661.
- [47] KOPONEN P, NISKA H, HUUSKO R. Improving the performance of machine learning models by integrating partly physical control response models in short-term forecasting of aggregated power system loads[C]// *Proceedings of the ITISE 2017*. Granada: University of Granada, 2017: 795-806.
- [48] WANG Yi, ZHANG Ning, CHEN Qixin, et al. Data-driven probabilistic net load forecasting with high penetration of behind-the-meter PV[J]. *IEEE Transactions on Power Systems*, 2018, 33(3): 3255-3264.
- [49] BU Fankun, DEGHANPOUR K, YUAN Yuxuan, et al. A data-driven game-theoretic approach for behind-the-meter PV generation disaggregation[J]. *IEEE Transactions on Power Systems*, 2020, 35(4): 3133-3144.
- [50] 汤奕, 韩啸, 张潮海. 基于物理-数据融合的数字楼宇用电模型构建方法[J]. *供用电*, 2019, 36(10): 16-21, 29.
- TANG Yi, HAN Xiao, ZHANG Chaohai. Power consumption modeling method of digital buildings based on physical-statistical model[J]. *Distribution & Utilization*, 2019, 36(10): 16-21, 29(in Chinese).
- [51] HE Yiliu, ZHONG Haiwang, TAN Zhenfei, et al. Optimal high-level control of building HVAC system under variable price framework using partially linear model [J]. *IET Energy Systems Integration*, 2021, 3(2): 213-222.
- [52] SONG Zhaofang, SHI Jing, LI Shujian, et al. Data-driven and physical model-based evaluation method for the achievable demand response potential of residential consumers' air conditioning loads[J]. *Applied Energy*, 2022, 307: 118017.
- [53] TSAY C, KUMAR A, FLORES-CERRILLO J, et al. Optimal demand response scheduling of an industrial air separation unit using data-driven dynamic models [J]. *Computers & Chemical Engineering*, 2019, 126: 22-34.
- [54] JAHANGIR H, GOUGHERI S S, VATANDOUST B, et al. Plug-in electric vehicle behavior modeling in energy market: a novel deep learning-based approach with clustering technique[J]. *IEEE Transactions on Smart Grid*, 2020, 11(6): 4738-4748.
- [55] BAO Zhiyuan, HU Zechun, KAMMEN D M, et al. Data-driven approach for analyzing spatiotemporal price elasticities of EV public charging demands based on conditional random fields[J]. *IEEE Transactions on Smart Grid*, 2021, 12(5): 4363-4376.
- [56] WANG Jianxiao, ZHONG Haiwang, LAI Xiaowen, et al. Exploring key weather factors from analytical modeling toward improved solar power forecasting [J]. *IEEE Transactions on Smart Grid*, 2019, 10(2): 1417-1427.
- [57] ZEČEVIĆ Ž, ROLEVSKI M. Neural network approach to MPPT control and irradiance estimation[J]. *Applied Sciences*, 2020, 10(15): 5051.
- [58] CHEN Peng, HAN Dezhi, LI K C. Robust adaptive control of maximum power point tracking for wind power system[J]. *IEEE Access*, 2020, 8: 214538-214550.
- [59] 胡阳, 乔依林. 基于置信等效边界模型的风功率数据清洗方法[J]. *电力系统自动化*, 2018, 42(15): 18-23, 149.
- HU Yang, QIAO Yilin. Wind power data cleaning method based on confidence equivalent boundary model [J]. *Automation of Electric Power Systems*, 2018, 42(15): 18-23, 149(in Chinese).
- [60] LI Fusheng, LIN Dan, YU Tao, et al. Adaptive rapid neural optimization: a data-driven approach to MPPT for centralized TEG systems[J]. *Electric Power Systems Research*, 2021, 199: 107426.
- [61] ZHANG Xiaoshun, TAN Tian, YANG Bo, et al. Greedy search based data-driven algorithm of centralized thermoelectric generation system under non-uniform temperature distribution[J]. *Applied Energy*, 2020, 260: 114232.
- [62] 靳皓晴. 基于物理-数据融合模型的锂离子电池荷电状态估计[D]. 兰州: 兰州理工大学, 2020.
- JIN Haoqing. State-of-charge estimation of li-ion battery based on physical-data fusion model[D]. Lanzhou:

- Lanzhou University of Technology, 2020(in Chinese).
- [63] QIU Xin, NGUYEN T A, CROW M L. Heterogeneous energy storage optimization for microgrids[J]. IEEE Transactions on Smart Grid, 2016, 7(3): 1453-1461.
- [64] 尚宇炜, 郭剑波, 吴文传, 等. 数据-知识融合的机器学习(1): 模型分析[J]. 中国电机工程学报, 2019, 39(15): 4406-4415.
- SHANG Yuwei, GUO Jianbo, WU Wenchuan, et al. Machine learning methods embedded with domain knowledge(Part I): model analysis[J]. Proceedings of the CSEE, 2019, 39(15): 4406-4415(in Chinese).
- [65] 尚宇炜, 郭剑波, 吴文传, 等. 数据-知识融合的机器学习(2): 泛化风险[J]. 中国电机工程学报, 2019, 39(16): 4641-4649.
- SHANG Yuwei, GUO Jianbo, WU Wenchuan, et al. Machine learning methods embedded with domain knowledge(Part II): generalization risk[J]. Proceedings of the CSEE, 2019, 39(16): 4641-4649(in Chinese).
- [66] SHANG Yuwei, WU Wenchuan, GUO Jianbo, et al. Stochastic dispatch of energy storage in microgrids: an augmented reinforcement learning approach [J]. Applied Energy, 2020, 261: 114423.
- [67] LI Mengshi, YU Da, CHEN Ziming, et al. A data-driven residual-based method for fault diagnosis and isolation in wind turbines[J]. IEEE Transactions on Sustainable Energy, 2019, 10(2): 895-904.
- [68] CAI Baoping, ZHAO Yubin, LIU Hanlin, et al. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems[J]. IEEE Transactions on Power Electronics, 2017, 32(7): 5590-5600.
- [69] SCHMID M, KNEIDINGER H G, ENDISCH C. Data-driven fault diagnosis in battery systems through cross-cell monitoring[J]. IEEE Sensors Journal, 2021, 21(2): 1829-1837.
- [70] GUARDADO J L, NAREDO J L, MORENO P, et al. A comparative study of neural network efficiency in power transformers diagnosis using dissolved gas analysis [J]. IEEE Transactions on Power delivery, 2001, 16(4): 643-647.
- [71] MIROWSKI P, LECUN Y. Statistical machine learning and dissolved gas analysis: a review[J]. IEEE Transactions on Power Delivery, 2012, 27(4): 1791-1799.
- [72] DHINI A, FAQIH A, KUSUMOPUTRO B, et al. Data-driven fault diagnosis of power transformers using dissolved gas analysis(DGA)[J]. International Journal of Technology, 2020, 11(2): 388-399.
- [73] SOUMALAS K, MESSINIS G, HATZIARGYRIOU N. A data driven approach to distribution network topology identification[C]//Proceedings of 2017 IEEE Manchester PowerTech. Manchester: IEEE, 2017: 1-6.
- [74] LIAO Yizheng, WENG Yang, LIU Guangyi, et al. Urban MV and LV distribution grid topology estimation via group lasso[J]. IEEE Transactions on Power Systems, 2019, 34(1): 12-27.
- [75] MA Li, WANG Lingfeng, LIU Zhaoxi. Topology identification of distribution networks using a split-EM based data-driven approach[J]. IEEE Transactions on Power Systems, 2022, 37(3): 2019-2031.
- [76] YU Jiafan, WENG Yang, RAJAGOPAL R. PaToPa: a data-driven parameter and topology joint estimation framework in distribution grids[J]. IEEE Transactions on Power Systems, 2018, 33(4): 4335-4347.
- [77] YU Jiafan, WENG Yang, RAJAGOPAL R. PaToPaEM: a data-driven parameter and topology joint estimation framework for time-varying system in distribution grids[J]. IEEE Transactions on Power Systems, 2019, 34(3): 1682-1692.
- [78] XU Hanchen, DOMÍNGUEZ-GARCÍA A D, SAUER P W. Data-driven coordination of distributed energy resources for active power provision[J]. IEEE Transactions on Power Systems, 2019, 34(4): 3047-3058.
- [79] JI Xingquan, YIN Ziyang, ZHANG Yumin, et al. Real-time robust forecasting-aided state estimation of power system based on data-driven models [J]. International Journal of Electrical Power & Energy Systems, 2021, 125: 106412.
- [80] ANUBI O M, KONSTANTINOUC. Enhanced resilient state estimation using data-driven auxiliary models [J]. IEEE Transactions on Industrial Informatics, 2020, 16(1): 639-647.
- [81] HUANG Manyun, WEI Zhinong, SUN Guoqiang, et al. Hybrid state estimation for distribution systems with AMI and SCADA measurements[J]. IEEE Access, 2019, 7: 120350-120359.
- [82] WU Zhong, WANG Qi, HU Jianxiong, et al. Integrating model-driven and data-driven methods for fast state estimation[J]. International Journal of Electrical Power & Energy Systems, 2022, 139: 107982.
- [83] WANG Lei, ZHOU Qun, JIN Shuangshuang. Physics-guided deep learning for power system state estimation[J]. Journal of Modern Power Systems and Clean Energy, 2020, 8(4): 607-615.
- [84] REN Chao, XU Yan. A fully data-driven method based on generative adversarial networks for power system dynamic security assessment with missing data[J]. IEEE Transactions on Power Systems, 2019, 34(6): 5044-5052.
- [85] TAN Yi, CHEN Yuanyang, LI Yong, et al. Linearizing power flow model: a hybrid physical model-driven and data-driven approach[J]. IEEE Transactions on Power Systems, 2020, 35(3): 2475-2478.

- [86] LIU Yuxiao, ZHANG Ning, WANG Yi, et al. Data-driven power flow linearization: a regression approach[J]. IEEE Transactions on Smart Grid, 2019, 10(3): 2569-2580.
- [87] LIU Yuxiao, WANG Yi, ZHANG Ning, et al. A data-driven approach to linearize power flow equations considering measurement noise[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2576-2587.
- [88] HU Xinyue, HU Haoji, VERMA S, et al. Physics-guided deep neural networks for power flow analysis[J]. IEEE Transactions on Power Systems, 2021, 36(3): 2082-2092.
- [89] LEI Xingyu, YANG Zhifang, YU Juan, et al. Data-driven optimal power flow: a physics-informed machine learning approach[J]. IEEE Transactions on Power Systems, 2021, 36(1): 346-354.
- [90] HU Ren, LI Qifeng, QIU Feng. Ensemble learning based convex approximation of three-phase power flow[J]. IEEE Transactions on Power Systems, 2021, 36(5): 4042-4051.
- [91] PINEDA S, MORALES J M, JIMÉNEZ-CORDERO A. Data-driven screening of network constraints for unit commitment[J]. IEEE Transactions on Power Systems, 2020, 35(5): 3695-3705.
- [92] YUAN Jingyi, WENG Yang. Support matrix regression for learning power flow in distribution grid with unobservability[J]. IEEE Transactions on Power Systems, 2022, 37(2): 1151-1161.
- [93] WANG Cheng, GONG Zhihao, HE Chuan, et al. Data-driven adjustable robust unit commitment of integrated electric-heat systems[J]. IEEE Transactions on Power Systems, 2021, 36(2): 1385-1398.
- [94] NING Chao, YOU Fengqi. Data-driven adaptive robust unit commitment under wind power uncertainty: a Bayesian nonparametric approach[J]. IEEE Transactions on Power Systems, 2019, 34(3): 2409-2418.
- [95] WANG Jingyao, WANG Cheng, LIANG Yile, et al. Data-driven chance-constrained optimal gas-power flow calculation: a Bayesian nonparametric approach [J]. IEEE Transactions on Power Systems, 2021, 36(5): 4683-4698.
- [96] 鲁卓欣, 徐潇源, 严正, 等. 不确定性环境下数据驱动的电力系统优化调度方法综述[J]. 电力系统自动化, 2020, 44(21): 172-183.
- LU Zhuoxin, XU Xiaoyuan, YAN Zheng, et al. Overview on data-driven optimal scheduling methods of power system in uncertain environment[J]. Automation of Electric Power Systems, 2020, 44(21): 172-183(in Chinese).
- [97] DUAN Chao, JIANG Lin, FANG Wanliang, et al. Data-driven finely adjustable distributionally robust unit commitment[J]. IEEE Transactions on Power Systems, 2018, 33(2): 1385-1398.
- [98] GUO Yi, BAKER K, DALL' ANESE E, et al. Data-based distributionally robust stochastic optimal power flow—Part I: methodologies[J]. IEEE Transactions on Power Systems, 2019, 34(2): 1483-1492.
- [99] CHEN Xin, WU Wenchuan, ZHANG Boming, et al. Data-driven DG capacity assessment method for active distribution networks[J]. IEEE Transactions on Power Systems, 2017, 32(5): 3946-3957.
- [100] SHEN Feifei, ZHAO Liang, DU Wenli, et al. Large-scale industrial energy systems optimization under uncertainty: a data-driven robust optimization approach [J]. Applied Energy, 2020, 259: 114199.
- [101] HAJEBRAHIMI A, KAMWA I, DELAGE E, et al. Adaptive distributionally robust optimization for electricity and electrified transportation planning [J]. IEEE Transactions on Smart Grid, 2020, 11(5): 4278-4289.
- [102] QIU Haifeng, GU Wei, LIU Pengxiang, et al. Application of two-stage robust optimization theory in power system scheduling under uncertainties: a review and perspective [J]. Energy, 2022, 251: 123942.
- [103] FATHABAD A M, CHENG Jianqiang, PAN Kai, et al. Data-driven planning for renewable distributed generation integration[J]. IEEE Transactions on Power Systems, 2020, 35(6): 4357-4368.
- [104] GUEVARA E, BABONNEAU F, HOMEM-DE-MELLO T, et al. A machine learning and distributionally robust optimization framework for strategic energy planning under uncertainty[J]. Applied Energy, 2020, 271: 115005.
- [105] 王琦, 李峰, 汤奕, 等. 基于物理-数据融合模型的电网暂态频率特征在线预测方法[J]. 电力系统自动化, 2018, 42(19): 1-9.
- WANG Qi, LI Feng, TANG Yi, et al. On-line prediction method of transient frequency characteristics for power grid based on physical-statistical model[J]. Automation of Electric Power Systems, 2018, 42(19): 1-9(in Chinese).
- [106] WANG Qi, LI Feng, TANG Yi, et al. Integrating model-driven and data-driven methods for power system frequency stability assessment and control[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4557-4568.
- [107] 汤奕, 顾锐, 戴剑丰, 等. 基于数据-物理融合的直流系统后续换相失败预测方法[J]. 电力建设, 2021, 42(5): 69-80.
- TANG Yi, GU Rui, DAI Jianfeng, et al. Subsequent commutation failure prediction of HVDC by integrating physical-driven and model-driven methods[J]. Electric Power Construction, 2021, 42(5): 69-80(in Chinese).
- [108] LI Feng, WANG Qi, TANG Yi, et al. An integrated

- method for critical clearing time prediction based on a model-driven and ensemble cost-sensitive data-driven scheme[J]. *International Journal of Electrical Power & Energy Systems*, 2021, 125: 106513.
- [109] LI Feng, WANG Qi, TANG Yi, et al. Hybrid analytical and data-driven modeling based instance-transfer method for power system online transient stability assessment [J]. *CSEE Journal of Power and Energy Systems*, 2021. DOI: 10.17775/CSEEJPES.2020.03880.
- [110] 吴倩红, 韩蓓, 李国杰, 等. 极高光伏渗透率下基于潮流雅可比矩阵和卷积神经网络的静态电压稳定在线预测[J]. *中国电机工程学报*, 2021, 41(12): 4058-4067. WU Qianhong, HAN Bei, LI Guojie, et al. Power flow Jacobian matrix based static voltage stability forecast by CNN considering extremely high PV penetration [J]. *Proceedings of the CSEE*, 2021, 41(12): 4058-4067(in Chinese).
- [111] LAGOS D T, HATZIARGYRIOU N D. Data-driven frequency dynamic unit commitment for island systems with high RES penetration[J]. *IEEE Transactions on Power Systems*, 2021, 36(5): 4699-4711.
- [112] 苏童, 刘友波, 沈晓东, 等. 深度学习驱动的电力系统暂态稳定预防控制进化算法[J]. *中国电机工程学报*, 2020, 40(12): 3813-3823. SU Tong, LIU Youbo, SHEN Xiaodong, et al. Deep learning-driven evolutionary algorithm for preventive control of power system transient stability [J]. *Proceedings of the CSEE*, 2020, 40(12): 3813-3823(in Chinese).
- [113] HOSSAN S, CHOWDHURY B. Data-driven fault location scheme for advanced distribution management systems[J]. *IEEE Transactions on Smart Grid*, 2019, 10(5): 5386-5396.
- [114] 孙国强, 张恪, 卫志农, 等. 基于深度学习的含统一潮流控制器的电力系统快速安全校正[J]. *电力系统自动化*, 2020, 44(19): 119-127. SUN Guoqiang, ZHANG Ke, WEI Zhinong, et al. Deep learning based fast security correction of power system with unified power flow controller[J]. *Automation of Electric Power Systems*, 2020, 44(19): 119-127(in Chinese).
- [115] XU Ying, QU Zhihua, HARVEY R, et al. Data-driven wide-area control design of power system using the passivity shortage framework[J]. *IEEE Transactions on power systems*, 2021, 36(2): 830-841.
- [116] XIONG Yongxin, YAO Wei, CHEN Weibiao, et al. A data-driven approach for fault time determination and fault area location using random matrix theory [J]. *International Journal of Electrical Power & Energy Systems*, 2020, 116: 105566.
- [117] RUAN Guangchun, ZHONG Haiwang, SHAN Baoguo, et al. Constructing demand-side bidding curves based on a decoupled full-cycle process[J]. *IEEE Transactions on Smart Grid*, 2021, 12(1): 502-511.
- [118] LU Tianguang, WANG Zhaoyu, WANG Jianhui, et al. A data-driven stackelberg market strategy for demand response-enabled distribution systems[J]. *IEEE Transactions on Smart Grid*, 2019, 10(3): 2345-2357.
- [119] YOON A Y, KIM Y J, ZAKULA T, et al. Retail electricity pricing via online-learning of data-driven demand response of HVAC systems[J]. *Applied Energy*, 2020, 265: 114771.
- [120] LI Bosong, WANG Xu, SHAHIDEHPOUR M, et al. DER aggregator's data-driven bidding strategy using the information gap decision theory in a non-cooperative electricity market[J]. *IEEE Transactions on Smart Grid*, 2019, 10(6): 6756-6767.



阮广春

在线出版日期: 2023-07-28。

收稿日期: 2023-03-02。

作者简介:

阮广春(1993), 男, 博士后, 主要从事电力系统优化、需求响应、人工智能与大数据方面的研究, gruan@iceee.org;

何一鎏(1999), 男, 博士研究生, 主要从事异步分区电网优化方面的研究, he-y121@mails.tsinghua.edu.cn;

谭振飞(1994), 男, 博士后, 主要从事电力市场、电力系统经济运行方面的研究, zftan@outlook.com;

钟海旺(1986), 男, 副教授, 主要从事电力系统优化、源网荷储协调运行方面的研究, zhonghw@mail.tsinghua.edu.cn。

(编辑 乔宝榆, 李新洁)