

控制与决策

Control and Decision

基于学习优化的智能电网能量管理研究综述

郭方洪, 徐博文, 张文安, 邓瑞龙

引用本文:

郭方洪, 徐博文, 张文安, 邓瑞龙. 基于学习优化的智能电网能量管理研究综述[J]. *控制与决策*, 2022, 37(5): 1089–1101.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1788>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度学习的行人轨迹预测方法综述

Survey of pedestrian trajectory prediction methods based on deep learning

控制与决策. 2021, 36(12): 2841–2850 <https://doi.org/10.13195/j.kzyjc.2020.1841>

基于地标特征和元学习方法推荐最适用优化算法

Recommending best suitable metaheuristic based on landmarking feature and meta-learning approach

控制与决策. 2021, 36(5): 1223–1231 <https://doi.org/10.13195/j.kzyjc.2019.0993>

移动机器人运动规划中的深度强化学习方法

Deep reinforcement learning for motion planning of mobile robots

控制与决策. 2021, 36(6): 1281–1292 <https://doi.org/10.13195/j.kzyjc.2020.0470>

基于MCPDDPG的智能车辆路径规划方法及应用

The method and application of intelligent vehicle path planning based on MCPDDPG

控制与决策. 2021, 36(4): 835–846 <https://doi.org/10.13195/j.kzyjc.2019.0460>

基于深度强化学习与迭代贪婪的流水车间调度优化

Scheduling optimization for flow-shop based on deep reinforcement learning and iterative greedy method

控制与决策. 2021, 36(11): 2609–2617 <https://doi.org/10.13195/j.kzyjc.2020.0608>

基于学习优化的智能电网能量管理研究综述

郭方洪¹, 徐博文^{1†}, 张文安¹, 邓瑞龙²

(1. 浙江工业大学 信息工程学院, 杭州 310023; 2. 浙江大学 控制科学与工程学院, 杭州 310027)

摘要: 受近年来人工智能浪潮的积极影响, 基于学习优化的智能电网能量管理研究不断涌现, 并被视为一个富有前景的研究方向. 现有学习优化方法的设计思路大相径庭, 了解这些思路的优势和局限性对掌握该交叉领域动态和推动其长足发展至关重要. 鉴于此, 总结 3 种主要的学习优化类型: 学习最优解、学习热启动、学习约束, 分析不同学习优化类型的设计思路和优点, 基于现有工作的缺憾进一步提出 5 大挑战, 并提供一些潜在的解决方案, 以期为该交叉领域的研究者提供更全面的信息和新的视角.

关键词: 学习优化; 深度学习; 神经网络; 人工智能; 能量管理

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1788

引用格式: 郭方洪, 徐博文, 张文安, 等. 基于学习优化的智能电网能量管理研究综述[J]. 控制与决策, 2022, 37(5): 1089-1101.

Learning-to-optimize based energy management in smart grid: A survey

GUO Fang-hong¹, XU Bo-wen^{1†}, ZHANG Wen-an¹, DENG Rui-long²

(1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China; 2. College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: With dramatic development of artificial intelligence in recent years, energy management based on “learning to optimize” is regarded as a promising research direction of smart grid. The designs of existing learning-based energy management approaches are quite different and there is no doubt that understanding the advantages and limitations of these ideas is essential to capture the research trends in this field. In this survey, references are carefully selected and categorized into three main groups: Optimal solution learning, warm-start learning, and constraints learning. The design details and advantages of these groups are systematically analyzed. Further, based on the shortcomings of existing studies, we propose five major challenges and provided some potential solutions. We hope this survey can provide more comprehensive information and new perspectives for researchers in this field.

Keywords: learning to optimize; deep learning; neural network; artificial intelligence; energy management

0 引言

建设安全高效、互联互通、共享经济的智能电网是实现我国“碳达峰、碳中和”战略目标的重要路径^[1]. 与传统电网将电力从几个中央发电机输送到大量用户不同的是, 智能电网使用双向电力和信息流创建自动化和分布式的先进能源输送网络. 通过利用现代信息技术, 智能电网能够以更高效的方式完成发电、输电、配电和用电任务, 并对各种突发紧急情况做出实时响应, 以实现更清洁、安全、可靠、有弹性、可持续的系统^[2]. 为了进一步总结智能电网与传统电网的区别, 表 1 给出了两者的简要对比.

智能电网中不同的控制任务具备不同的意义和

表 1 智能电网与传统电网的简要对比^[3]

特征	传统电网	智能电网
系统	机电	信息物理
通信	单向通信	双向通信
发电	集中式发电	分布式发电
传感器	少量	覆盖全网
监控	人工	自动
修复故障	人工	自动
用户选择	少	丰富

时间尺度. 因此, 一种分层控制架构^[4]被广泛采用, 如图 1 所示. 该分层控制策略由 3 个级别组成, 即主、次和三级控制. 智能电网中常见的优化问题位于顶层三级控制, 图 1 中由粉色表示. 事实上, 受传统优化算

收稿日期: 2021-10-18; 录用日期: 2022-01-12.

基金项目: 国家自然科学基金项目(61903333, 62173305, 62073285, 61130220); 浙江省“钱江人才”特殊急需类项目(QJD1902010); 浙江省自然科学基金项目(LZ21F020006).

[†]通讯作者. E-mail: bwxu@zjut.edu.cn.

法复杂度高、计算代价大的影响,时间尺度较大的顶层优化通常难以跟上时间尺度较小的底层控制算法,即底层控制算法需要“等”顶层优化结果,从而严重拖慢了整个控制框架的响应速度.因此,如何设计更智能的优化算法以加速顶层优化是一个亟待解决的难题.

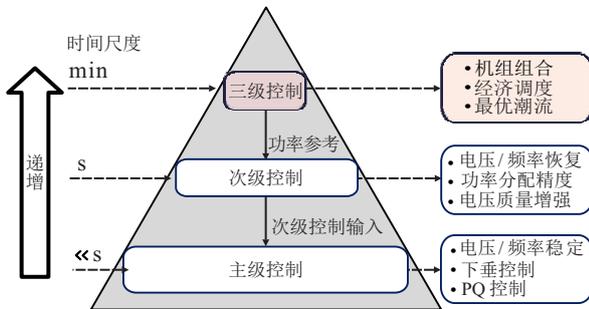


图1 智能电网的分层控制架构

能量管理是智能电网分层控制框架顶层中最为基础也颇具挑战的一类优化问题,旨在为不同的电网系统状态提供最佳发电、输电、配电和用电策略.常见的智能电网能量管理问题包括经济调度(economic dispatch, ED)^[5]、最优潮流(optimal power flow, OPF)^[6]和机组组合(unit commitment, UC)^[7]问题等.一方面,考虑到智能电网中高渗透率的可再生能源出力的间歇性和不确定性,短期的负荷波动幅度日益增加,系统净负荷需求的预测难度随之增大^[8],这为智能电网的优化和控制技术带来了严峻挑战.另一方面,现代计算机、通信、传感器、存储技术的蓬勃发展引导着大量智能测量设备接入智能电网,从而推动了数据采集与监视控制系统(supervisory control and data acquisition, SCADA)等智能量测系统的发展,在极大地增强系统实时响应能力的同时积累了庞大体量、能反映系统真实运行状态和其对应最优能量管理决策的历史数据.这些海量的历史数据为深度学习和智能电网的深度融合提供了可能.

迄今为止,深度学习已经在图像识别^[9]、语音识别^[10]、自然语言处理^[11]等多领域取得了革命性的性能突破,并迅速在学术界和工业界掀起了产研融合的浪潮.可以完成复杂函数的逼近是深度学习最主要的优势,作为学习的核心,深度神经网络(deep neural network, DNN)^[12]已被开发出多种架构,包括多层感知机(multilayer perceptron, MLP)^[13]、卷积神经网络(convolutional neural network, CNN)^[14]、循环神经网络(recurrent neural network, RNN)^[15]、图神经网络(graph neural network, GNN)^[16]以适应不同的学习任务.事实上,神经网络自1943年由心理学家 Warren McCulloch 和数理逻辑学家 Walter Pitts^[17]

提出以来几经沉浮,而其近年来的兴起与流行主要得益于以下几点:1)现代传感器与存储技术充分保证了数据规模与可用性;2)图形处理器(graphics processing unit, GPU)与分布式并行训练显著提升了训练速度;3)深度学习框架的普及为研究者们提供了友好的模型搭建环境^[18-20].

传统的基于数值优化的智能电网能量管理算法虽然已被研究者们通过严格的数学推导证明了求解精度,但求解过程背后的计算代价却鲜少得到关注.事实上,一方面,在处理单个能量管理问题时,这些算法因其迭代的结构设计和诸如衰减步长^[21]等用于保证算法收敛的计算技巧,难以在极短的时间内为管理员提供能量管理结果.另一方面,在长期的能量管理工作中,这些算法往往循环往复地解决类似的问题却不积累任何经验.算法背后高昂的算力负担和缺少经验驱动的计算机制造成了理论分析与实时运行之间的差距.为了弥补这一差距,近年来基于“学习优化”(learning to optimize)^[22]思想的智能电网能量管理方法受到了研究者的广泛关注.其核心思想是在离线阶段训练一个模型以表征系统状态与最优能量管理决策之间的非线性映射关系,并于在线阶段利用该模型为智能电网运行提供实时能量管理结果.不难发现,与传统优化算法相比,基于学习优化的算法实际上是在在线阶段高昂的算力负担转移到了离线训练阶段.大量研究表明,学习优化和智能电网的深度集成可以为解决复杂的能量管理问题实现数量级的优化加速^[23].

为了概述智能电网中学习优化的研究趋势,对“Web of Science”数据库中已编入索引的出版物进行了文献计量分析.对于主题为“智能电网中的学习优化”的出版物,搜索查询公式设置如下:TS=((“smart grid” or “power system”) and (“optimization” or “optimal” or “dispatch” or “scheduling” or “management” or “power flow” or “unit commitment”) and (“learning” or “neural network” or “artificial intelligence” or “data-driven”)).对于主题为“智能电网中的优化”的出版物,搜索查询公式设置如下:TS=((“smart grid” or “power system”) and (“optimization” or “optimal” or “dispatch” or “scheduling” or “management” or “power flow” or “unit commitment”)).文献类型均设置为(“Articles” or “Review Articles”).

图2展示了自“深度学习元年”2006年以来,“智能电网中的学习优化”出版物的数量(柱状图表示)和

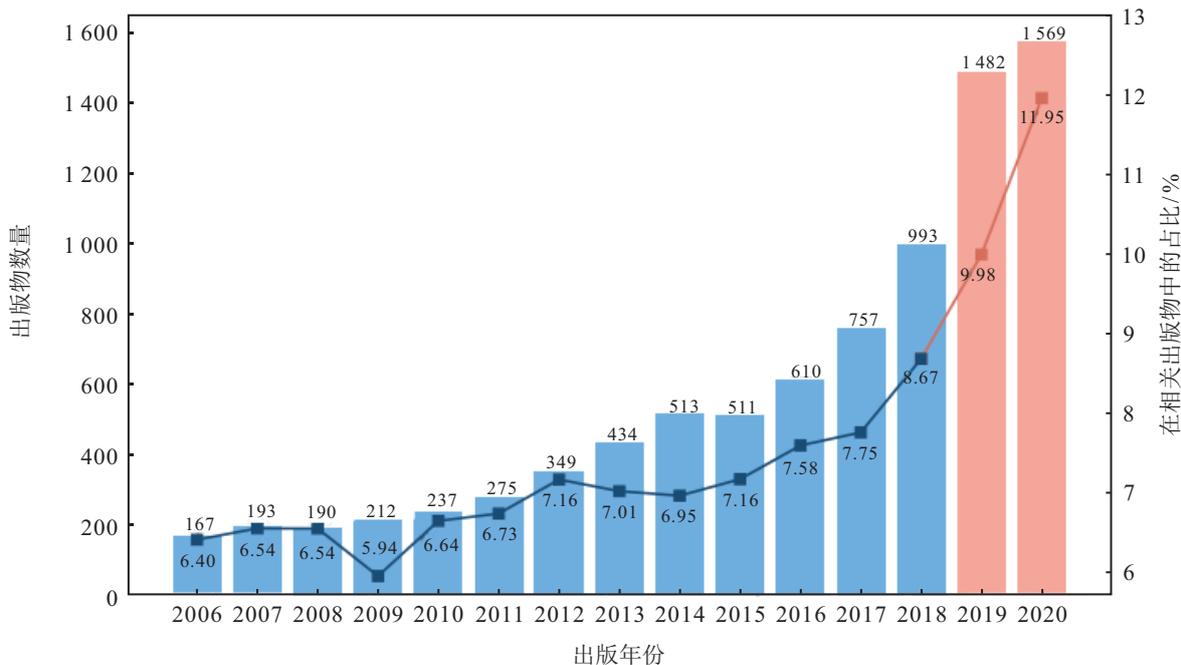


图2 智能电网学习优化的研究趋势

“智能电网中的学习优化”出版物在所有“智能电网中的优化”出版物中的占比(折线图表示). 可见,“智能电网中的学习优化”出版物数量2006年~2020年增幅约为840%,占比增幅约为87%. 显然,学习优化是一个发展势头迅猛且极具前景的热门研究方向.

事实上,学习优化的雏形最早由传统的机器学习技术驱动,如决策树^[24]、支持向量机^[25]和浅层人工神经网络^[26]. 然而,随着电力系统规模和量测数据规模的日益增长,缺乏复杂映射关系表征能力和大数据处理能力的传统机器学习模型难以满足含高比例可再生能源智能电网的要求. 反之,深度学习由于克服了传统机器学习模型的缺陷而受到研究者的广泛关注与研究. 因此,本文重点关注DNN驱动的学习优化方法. 其他诸如决策树、支持向量机等机器学习模型将不是本文关注的重点. 值得注意的是,虽然相关工作的目标是一致的,即加速优化,但研究者在算法的设计思路却大相径庭. 这促使本文作者梳理、分析并总结现有的研究工作,从而为该领域的研究者们提供更全面的信息和新的视角.

本文其余部分组织如下:系统梳理了现有基于学习优化思想的智能电网能量管理方法,并以“学习优化问题的哪一部分”为原则总结出3个主要类型;基于现有工作的空白和缺陷,提出5大挑战并提供一些潜在的解决方案;最后总结全文.

1 智能电网能量管理中的学习优化

从“学习优化问题的哪一部分”这一角度看,相关研究可以分为3个类型,即:学习最优解(optimal solution learning)、学习热启动(warm-start learning)、

学习约束(constraint learning). 此外,还有一些其他类型的方法值得关注. 图3简要说明了学习优化的不同类型及其与传统能量管理方法的区别. 图4展示了本文选定参考文献所针对的能量管理问题. 表2总结了3种学习优化类型的核心思想、性能表现和主要应用方向. 表3给出了本文所选定的学习优化参考文献训练方式总览. 下面将深入探讨每个类型的技术细节.

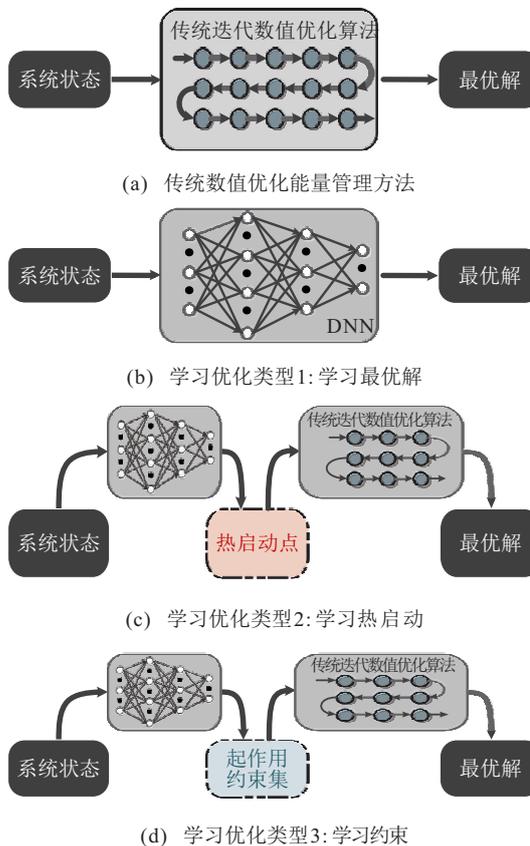


图3 学习优化不同类型对比

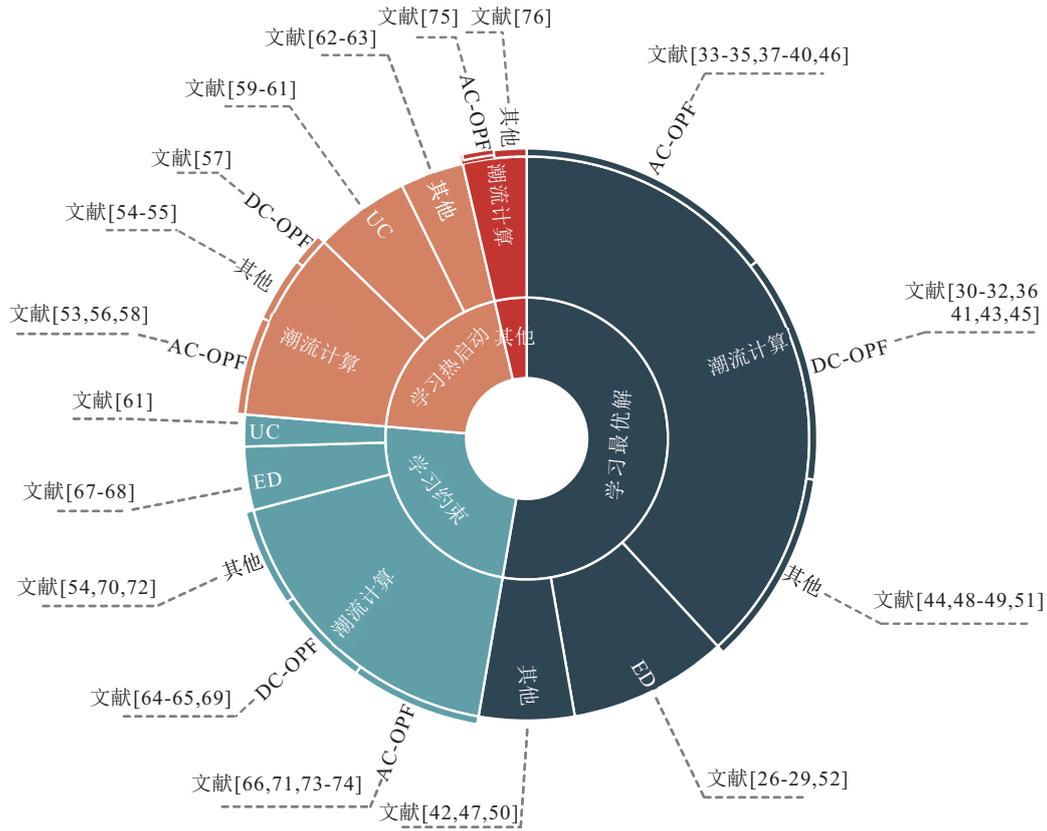


图4 本文选定参考文献所针对的能量管理问题类型概览

表2 学习优化不同类型对比

学习优化类型	参考文献	核心思想	性能表现	主要应用方向
学习最优解	[26-52]	学习系统状态和最优解之间的映射关系	实时性较强 最优性相对较弱	经济调度、DC-OPF等复杂度相对较低且决策变量类型单一的能量管理问题
学习热启动	[53-63]	学习产生热启动点以加速求解器	实时性与最优性表现均衡	机组组合、ACC-OPF等非凸、较复杂的能量管理问题
学习约束	[54,61,64-74]	学习识别或计算约束以缩小问题规模	实时性与最优性表现均衡	SCED、SCUC、SCOPF等考虑安全约束的能量管理问题

表3 选定学习优化参考文献训练方式总览

学习优化类型	有监督	无监督
学习最优解	[26-34,36-52]	[35]
学习热启动	[53,56-63]	[54-55]
学习约束	[61,64-74]	[54]

1.1 学习最优解(optimal solution learning)

学习最优解作为一种典型的端到端学习,旨在训练一个复杂的深度学习模型来表征智能电网优化问题的输入(时变的系统状态)与输出(最优解)之间的映射关系.相比其他类型,直接学习最优解在形式上更简洁明了,因而受到学者们的青睐.

实际上,用神经网络学习智能电网中的优化问题可以追溯到20世纪90年代.Nanda等^[26]首先对使用多层全连接的深度神经网络(deep neural network, DNN)和反向传播技术来解决电网经济调度(economic dispatch, ED)问题进行了初步探索,并在

IEEE 14-bus和IEEE 30-bus系统上探究了神经元数、隐藏层数、激活函数、学习率、训练迭代数等因素对神经网络学习效果的影响.Guo等^[27-28]基于“深度展开(deep unfolding)”思想从理论上证明了在给定逼近误差的条件下,DNN最多需要多少神经元数、隐藏层数和激活函数来学习不同的前置优化ED算法.Xu等^[29]提出了一种名为E²DNet的集成神经网络解决非凸ED问题,其灵感来自于观察到求解给定电网的ED问题等价于描述负荷与最优ED决策之间的映射关系.相比单个DNN,集成DNN在保证实时性的同时进一步提升了解的最优性.通过将发电单元状态和发电代价参数纳入特征中,E²DNet可以适应时变的发电单元状态和发电代价函数.

除了最早被关注到的ED问题,学习优化的思想也逐渐触及智能电网中的最优潮流(optimal power flow, OPF)问题.Pan等^[30]提出了一种名为DeepOPF

的基于DNN的直流最优潮流(DC-OPF)求解方法. 在DeepOPF中,DNN用于有监督地学习从负荷到发电机最优有功功率的映射. 考虑到DNN预测解难免存在误差从而导致在线运行阶段产生的解存在部分不可行的情况,DNN的预测解被进一步投影到可行域上从而保证可行性,最后利用发电机有功功率和导纳矩阵重构相角以完成对整个DC-OPF问题的求解. 在若干个IEEE标准测试系统上的实验结果表明,相比Pypower求解器,DeepOPF实现了两个数量级的加速且最优损失不超过2%. 同时,该方法被进一步应用于考虑安全约束的最优潮流问题(security-constrained OPF, SCOPF)^[31].

Zhao等^[32]对文献[30]的工作进行改进并提出了DeepOPF+以解决DC-OPF问题. 考虑到因DNN的逼近误差而产生的不可行解都落在可行域边界附近,DeepOPF+在生成训练集时对约束进行“校准”,即产生样本所使用的优化问题比原优化问题具备更严格的约束,从而使得训练好的DNN产生的可行解尽可能地落在原优化问题的可行域内. 随着校准幅度的上升,解的可行率逐步升高并收敛至100%,但解的最优性损失也会逐渐降低. Zamzam等^[33]也提出了相同的“校准”思想以解决更加复杂的交流最优潮流问题(AC-OPF). DNN被用来学习从负荷到发电机有功功率、电压幅值之间的映射,随后通过潮流方程重构发电机无功功率和电压相角. 在多个IEEE标准测试系统上的实验结果验证了所提出方法实现了一个数量级的加速,同时最优损失小于0.8%. 但在极少数情况下,潮流方程的求解会导致所推测的发电机无功功率违反约束.

Huang等^[34]进一步提出了DeepOPF-V以解决AC-OPF问题. DNN被用来有监督地学习负荷与电压之间的映射,随后利用预测的电压和潮流方程重构剩余决策变量以完整解决AC-OPF问题,并提出了一种快速的后处理算法调整预测电压以提高解的可行率,但难以完全保证解的可行性.

与其先前工作不同的是,Huang等^[35]另提出了一种名为DeepOPF-NGT的无监督学习方法解决AC-OPF问题. 该方法最大的好处是不需要像监督学习那样为训练准备带ground truth的数据集,从而有效减少了离线训练阶段的计算代价. DeepOPF-NGT通过设计一个合适的损失函数优化DNN的权重以学习负荷与电压之间的映射,而AC-OPF的多个约束则以惩罚项的形式出现在损失函数中. 在IEEE 30-bus系统上的实验结果验证了DeepOPF-NGT可以实现与

监督学习算法相当的最优性、可行性和加速表现. 然而,该文也不吝指出此方法仍难以严格保证AC-OPF各约束的满足.

为了进一步保证算法的泛化性能,Zhang等^[36]提出利用DC-OPF问题的凸性,限制神经网络具有输入凸结构. 其次,在损失函数中设计损失项以对违反KKT条件的情况进行惩罚. 通过结合这两种技术,训练后的模型具有可证明的泛化特性,即:小的训练误差意味着小的测试误差. 在实验中,与一些端到端方法相比将解的最优率提高了5倍,并将不可行率降低了一个数量级. Fioretto等^[37]结合深度学习与拉格朗日对偶理论解决AC-OPF问题. DNN被有监督地学习从负荷到发电机功率与节点电压之间的映射. 相关约束通过拉格朗日乘子添加到损失函数中. 作者设计了合适的学习算法以在算法迭代中更新DNN的权重和相关拉格朗日乘子,最后在不同规模的测试系统上验证了算法产生的解与ground truth之间的偏差很小. 但遗憾的是,该文并未对方案的不可行率做量化分析. Chatzos等^[38]进一步完善了该项工作. 相比传统的商业求解器IPOPT^[77],该方法最优损失小于0.01%,不可行率不超过1.70%,加速至多4个数量级. Yan等^[39]提出了一种基于拉格朗日的深度强化学习算法解决AC-OPF问题. 考虑到发电机的爬坡约束,DNN被用来学习从该时刻负荷及上一时刻发电机有功功率到该时刻发电机有功功率与电压幅值之间的映射关系,而相关约束则通过拉格朗日松弛技术以惩罚项的形式融合进动作值函数中. 此外,深度确定性策略梯度(deep deterministic policy gradient, DDPG)被用于优化DNN的权重,在IEEE 118-bus系统上的实验结果验证了该方法可以较好地处理约束并实现加速.

考虑到智能电网可以看作由节点(母线)和边(传输线)组成的一张图,Owerko等^[40]提出了一种基于图神经网络的AC-OPF解决方案. 图神经网络利用图嵌入等手段可以将大规模的抽象图表征为低维向量,从而具备更加丰富的计算方式. 该方法将发电机功率和母线电压作为节点属性,训练图卷积网络(graph convolutional network)产生AC-OPF的最优解,在IEEE 30-bus和IEEE 118-bus上的实验结果验证了该方法可以产生与求解器IPOPT相似的解. 遗憾的是,作者并未分析解的可行性和最优损失.

DNN作为一个“黑盒”,其鲁棒性,即:在运行阶段面对不同系统状态时形成的预测误差,是决定其能否胜任智能电网等相关实际工程应用的重要

指标之一. Venzke等^[41]首次提出了一种在最坏情况下保证DNN性能的框架,该方法中,DNN被用来学习从负荷到发电机有功与无功功率之间的映射以解决DC-OPF问题.作者们通过引入二进制变量重新表示作为激活函数的整流线性单元(rectified linear unit, ReLU),从而将DNN模型转变为混合整数线性规划(mixed-integer linear programming, MILP)问题,随后利用分支定界算法(branch-and-bound)获得DNN预测的最坏情况保证.该保证以3种方式体现:1)最大约束违反;2)预测解与ground truth之间的最大距离;3)目标函数上的最大次优性.最后提出可以通过在更大的输入域上进行训练来系统地减少最坏情况保证.

Misyris等^[42]利用电力系统的基本物理规律,首次提出了一种基于物理信息的神经网络(physics-informed neural networks, PINN)在电力系统中的应用框架.该框架将描述电力系统稳态和动态行为的各种数学模型转变为惩罚项并纳入其训练损失函数中,使得产生的解尽可能满足相应物理规律. PINN需要的训练数据相比常规DNN少得多,并且在得到更简单的神经网络结构的同时实现了高精度求解. Nellikkath等在文献[41-42]的基础上进一步将KKT条件结合进PINN,并应用于对DC-OPF问题预测结果的最坏情况保证^[43].一系列PGLib-OPF系统的实验结果展示了PINN如何提供最坏情况的保证,以及与常规DNN相比,如何减少最坏情况的违反. Hu等^[44]提出用DNN替换潮流方程,通过将功率重构误差、系统拓扑等电力系统的一般物理知识融入损失函数中正则化DNN从而提高DNN的泛化性能并防止过拟合问题.

DNN的离线训练代价同样是一个值得关注的评价指标. Singh等^[45]利用多参数规划(multiparametric programming)提取最优解对系统状态的偏导数,并通过在损失函数中添加一个最小化DNN权重和该偏导数之间偏差的正则项来训练一个基于敏感性的DNN(sensitive-informed DNN, SI-DNN)以解决DC-OPF问题.建立在IEEE 37-bus系统上的实验结果表明,SI-DNN可以以最小的计算开销将预测解与ground truth之间的均方误差缩小2或3个数量级.该项工作被进一步完善^[46]以解决更复杂的AC-OPF问题,在3个IEEE标准系统上的实验结果验证了在适当增加训练时间的情况下,通过使用大约1/10~1/4的训练数据,SI-DNN可以获得与以常规方式训练的DNN相同的预测性能.显然,该方法在改进样本效率

的同时减少了操作者生成训练数据集所需的时间.

除了常见的ED、OPF问题,学习最优解的思想还被用于智能电网中的其他优化问题. Kim等^[47]以有监督的方式训练了一个GCN网络以获取拓扑信息并预测防止输电线路在线路事故(即线路跳闸)下的最优减载(optimal load shedding)策略. Xiang等^[48]提出了一种基于DNN求解概率潮流(probabilistic power flow, PPF)的有效方法,采用叠加去噪自动编码器(stacked denoising auto-encoders, SDAE)提取可再生能源出力、负荷、电网拓扑组成的非线性特征,并通过迁移学习帮助DNN模型适应时变拓扑场景,在改进的IEEE 39-bus和IEEE 118-bus系统上验证了该方法的有效性. Yang等^[49]也提出类似思想解决PPF问题,DNN被用来学习从可再生能源出力及负荷到PPF最优解之间的映射,分支潮流约束以惩罚项的形式出现在损失函数中以提高DNN的逼近精度. Kim^[50]提出使用全连接结构的DNN解决最优需求响应(optimal demand response)问题.

除了常见的集中式框架,学习最优解的思想还被嵌入在分散式和分布式的框架中. Dobbe等^[51]提出了一种分散式的方法解决OPF问题,本地多元线性回归模型被用来学习从本地测量到本地最优功率输出之间的映射,这种分散式的方法可以找到接近最优的OPF解决方案. Guo等^[52]提出了一种基于DNN的分布式学习方法解决ED问题,通过动态平均一致(dynamic average consensus)算法以分布式的通信方式获得全网平均负荷,然后利用训练好的本地DNN完成从平均负荷到最优本地发电机功率输出的映射,最后通过在可行域上的投影保证解的可行性.

总结上述文献不难发现,由于DNN逼近误差的存在,基于学习最优解的方法常易陷入所得解违反约束的窘境.即便通过在损失函数中添加惩罚项以鼓励其满足约束,却仍难以完全保证解的可行性.因此,往往需要在DNN后设计一个后处理算法以微调所得解,从而实现可行性的完全保证.然而,当问题呈现非凸性时,如何设计合适的后处理算法仍缺少分析研究.此外,如何探索非凸问题的最优解亦是一个亟待解决的问题.在具体的应用问题上,经济调度、DC-OPF等复杂度相对较低且决策变量类型单一的能量管理问题较适合通过学习最优解这一思想予以解决.

1.2 学习热启动(warm-start learning)

该类型的核心思想是利用DNN(或其他学习的算法)为求解器(或其他迭代的优化算法)提供一个良好的热启动点,使得后者可以快速收敛至最优解.相

比端到端的、纯学习的 (purely learning-based) “学习最优解”思想,“学习热启动”通常结合了基于学习的算法与基于模型的数值优化算法,其仍然显式地使用已知的系统物理模型知识. 而这样一种结合体也继承了两者的优势,即基于学习的算法的实时性和基于模型的数值优化算法的精确性^[78]. 这背后的原因在于:即便DNN在提供热启动点时难免存在一定误差,该热启动误差一般不会后续对数值优化造成显著影响. 因此,该类方法通常能保证更好的可行性和最优性.

Pan等^[53]观察到即使在损失函数中添加惩罚项仍难以严格保证解的可行性,于是在其提出的DeepOPF框架内进一步提出将DNN产生的不可行解作为热启动点,再通过常规求解器得到最终结果. 在多个IEEE标准系统上的实验结果验证,与最先进的求解器相比,该方法可以将求解AC-OPF速度提高35倍且最优损失小于0.1%.

Robson等^[54]在Jamei等^[55]工作的基础上通过使用DNN预测内点原始变量的热启动点来减少后续OPF求解器迭代的总次数. 具体而言,提出一个度量已被热启动的OPF问题计算成本的元损失函数,该计算成本定义为内点求解器从热启动点到最优解所需的迭代次数. 通过在训练阶段使DNN最小化该元损失函数鼓励DNN产生一个好的热启动点,使得接下来的迭代次数最少. 考虑到该元损失函数不可微而导致反向传播算法无法应用,选择粒子群算法优化DNN权重. 多个案例验证了由元优化方法训练的DNN能显著提升整个框架的优化速度.

除了常见的全连接结构的DNN模型,还有其他结构的DNN被用于学习热启动. Chen等^[56]提出了一种基于一维卷积神经网络(convolutional neural network, CNN)的热启动算法解决AC-OPF问题. 1D-CNN被用来学习从DC-OPF最优解到对应AC-OPF问题的初始节点电压幅值和相位的映射关系. 该框架减少了基于传统牛顿-拉夫逊法的AC-OPF模型的迭代次数和求解时间. 在IEEE 118-bus和PEGASE 2869-bus研究系统上的实验表明,求解时间分别减少了33.56%和30.06%,迭代次数分别减少了66.47%和49.52%. 此外,讨论了所提出方法的局限,即:具有不同拓扑(具体地,不同数量的总线和/或连通性)的系统将需要训练不同的一维CNN来生成系统特定的热启动条件. 因此,需要进一步解决与此局限相关的训练时间过长、训练代价过大的问题. Biagioni等^[57]提出了一种基于RNN的方法加速交叉乘法

(alternating direction method of multipliers, ADMM)收敛从而解决DC-OPF问题. 该方法利用给定系统在变化负荷下ADMM轨迹的先前观测,将少量的初始ADMM迭代结果作为输入,并用RNN预测对偶变量和一致变量的收敛值,再将它们作为热启动点并继续ADMM迭代过程. 在多个测试系统上的实验结果验证了该方法能够取得相比标准ADMM算法约两个数量级的加速. 与Owerko等^[40]类似,Diehl等^[58]将智能电网看作由节点和边组成的一张图,在模拟德克萨斯州的综合电网上展示了GNN作为热启动优化器可以实现比常规AC-OPF算法快3.75倍的收敛速度.

一种“先用DNN优化整型变量,再用其他算法优化剩余变量”的热启动思想最早可以追溯到21世纪初,Nayak等^[59]用其解决常规的UC问题. 最近,Wu等^[60]提出了一种新的基于CNN的方法解决更复杂的带安全约束的机组组合(security-constrained unit commitment, SCUC)问题. 该方法分为两个阶段:首先,利用CNN预测机组组合决策相对应的二元变量的解;然后,用一个小规模的凸优化方法求解对应于发电单元功率输出的连续变量. 与已有工作相比,该方法避免了在优化问题中显式考虑基于场景的安全约束,从而大大降低了计算复杂度. 在考虑的10个发电单元系统中,该算法与最优解的平均差距只有0.0267%,而计算时间从大约1236.32s减少到0.8379s,从而验证了该算法的有效性和可扩展性. Xavier等^[61]也提出了类似的技术路线来解决大规模的SCUC问题.

除了常见的OPF、UC问题,还有一些其他问题被学习热启动的方法很好地解决. Zamzam等^[62]也提出了类似的“学习初始化”思想,训练一个全连接结构的DNN为高斯-牛顿算法预测热启动点从而加速解决配电网的状态估计问题. Perera等^[63]有监督地训练DNN生成热启动点从而帮助一种实际工程模型更快地到达Pareto解,结果显示该方法可以为能源系统优化问题加速近17倍.

总而言之,这类学习热启动方法通常结合了基于学习的算法和基于模型的数值优化算法,从而兼具前者的实时性和后者的最优性. 值得指出的是,学习热启动方法中包含的数值优化环节决定了其在实时性上往往略逊于端到端的学习最优解思想,但在最优性上的表现通常更胜一筹. 在具体的应用问题上,机组组合、AC-OPF等非凸的、较复杂的能量管理问题宜通过学习热启动这一思想予以解决. 同时值得注意的是,获取复杂能量管理问题的ground truth往注意

意味着更高的计算代价. 因此, 如何提高训练样本的利用率以减少计算代价将是该类型学习优化的主要挑战之一.

1.3 学习约束(constraint learning)

该类型能量管理方法的核心思路是对优化问题的约束进行计算与识别, 快速计算约束中的复杂项或移除不起作用的约束, 从而有效缩小问题的规模以显著减少求解器或数值优化方法的计算代价. 该类型与学习热启动类似, 是基于学习的算法和数值优化算法的混合体, 在加速优化的同时有较好的可行性和最优性表现.

Misra 等^[64] 率先证明了基于学习起作用约束集的方法对于实际问题是可行的, Deka 等^[65] 则进一步完善了工作, 以分类的方式用 DNN 识别出起作用约束, 再通过简单的矩阵求逆确定最优 DC-OPF 解, 在 IEEE PES PGLib-OPF 基准测试库中的多个系统上展示了该方法的识别起作用约束的准确率可达到 99%. 类似的思想在 Robson 等^[54] 的工作中也有所体现. Hasan 等^[66] 提出利用 DNN 作为分类器, 在求解 AC-OPF 优化问题前识别出不起作用的不等式约束, 并产生一个截断的 OPF 问题, 从而有效减小了问题规模和计算量. 实验结果表明, 该方法能以超过 95% 的准确率识别约束的属性, 省略不起作用的约束可以大大节省交流最优潮流的求解时间. 然而, 值得注意的是, 仍然有少数起作用约束会被错误地识别为不起作用约束, 从而导致所得解仍然不严格满足约束.

Yang 等^[67-68] 使用 DNN 学习从负荷到发电机有功功率的映射关系以解决带安全约束的经济调度 (security-constrained economic dispatch, SCED) 问题. 得到各发电机的有功功率输出后, 对其做 $N - 1$ 分析. 如果在 $N - 1$ 分析中没有新的起作用约束, 则可以得到 SCED 模型的最优解; 否则, 新识别的主动约束将被添加到 SCED 模型中. 基于 IEEE 标准测试系统的实验结果验证了该方法可以在大多数情况下在优化之前识别起作用约束, 从而避免传统方法中的迭代寻找起作用约束过程.

Chen 等^[69] 使用 DNN 学习从负荷到最优总成本的映射关系. 当然, 成本的最优值并非解本身. 使该神经网络计算成本对负荷的梯度, 将其识别为节点边际电价并进一步识别母线约束和传输线约束, 一旦确定了这些约束, 便可以通过求解一个简单的线性方程组给出 DC-OPF 问题的最优解. 基于 IEEE 30-bus 上的实验结果验证了该方法不可行率低于 0.5%.

King 等^[70] 提出了一种基于临界清除时间

(critical clearing time, CCT) 约束的暂态稳定约束 OPF 方法. 在该方法中, DNN 被用来学习从发电机电压幅值与有功功率到 CCT 之间的映射关系, 从而减少算法运行时计算 CCT 的时间.

其他许多学者还研究了如何利用深度学习算法将难以表示的动态安全约束纳入 OPF 数学模型中. Gutierrez 等^[71] 首先通过 DNN 表征安全边界 (security boundary), 并将其作为约束包含在 OPF 模型中, 然后用非线性规划求解器对该混合模型进行求解, 该方法确保了 OPF 解对应的操作点在可行和安全域内, 与常规的考虑安全约束的 OPF 算法相比, 所提出的技术可以更好地表示安全约束. Liu 等^[72] 训练了贝叶斯神经网络 (bayesian neural network, BNN) 以进行动态安全评估 (dynamic security assessment), 将训练好的 BNN 纳入 OPF 模型中以表征动态安全约束. Murzakhanov 等^[73] 建立了一个 DNN 模型判断操作点是否符合安全约束, 随后通过引入二进制变量重新表示 ReLU 函数, 将该 DNN 模型整合进一个新的数学模型以解决带安全约束的 AC-OPF 问题.

考虑到训练集中的样本平衡会直接影响模型的最终表现, Venzke 等^[74] 又提出了一种基于分离超平面的方法以创建一个安全和不安全操作点平衡的数据集. 该方法可以先验地将大部分输入空间表征为不安全, 从而显著减少计算时间和问题规模以处理更多数量级的控制变量, 并创建安全和不安全操作点的平衡数据集, 这对于数据驱动的应用程序至关重要.

总结上述文献可以发现, 与学习热启动类似, 学习约束通常结合了基于学习的算法和基于模型的数值优化算法, 其核心思想是对优化问题的约束进行快速识别从而缩小问题规模以减少求解器计算代价. 在具体的应用问题上, SCED、SCUC、SCOPF 等考虑安全约束的能量管理问题宜通过学习热启动这一思想予以解决. 值得注意的是, 将起作用约束识别为不起作用约束易导致产生不可行解. 因此, 如何进一步保证识别准确率是该类型学习优化的重点研究方向之一.

1.4 其他类型

除了上述 3 种主要的学习优化类型, 还有一些其他的学习优化思路值得关注. Wächter 等^[77] 用 DNN 建立一个学习牛顿-拉夫逊下降的迭代模型, 在该方法中, DNN 以本次迭代的变量值为输入预测下一次迭代的变量值. 对于较小的网络, 除了避免奇异雅可比矩阵和对病态矩阵求逆之外, 没有太大的好处. 然而, 对于较大的系统, 与内点求解器相比, DNN 模型

可以将优化速度提升数十倍. 对于文中考虑的若干电力系统, 所提出方法的最优损失皆小于1.2%. 然而, 对于PEGASE 1354-bus系统, 所提出方法的不可行率较高, 达到了9.95%.

King等^[76]提出了一个有趣的框架, 训练一个分类器为潮流问题选择最优的算法, 待选择的潮流算法包括最优潮流、基于潮流灵敏度的算法、基于约束满足的算法、线性规划. 实验结果验证了该框架相比始终为每个系统状态使用相同的潮流算法能够提供更好的性能.

2 挑战与机遇

学习优化的思想为智能电网的能量管理优化研究增添了新的活力, 但这一方向仍有许多问题值得进一步研究. 在本节中, 基于现有工作的空白和缺陷, 提出5大挑战并分享一些潜在的解决方案.

2.1 数据的可用性

基于学习优化的方法通常以数据驱动为基础. 与拥有大量公开数据集的计算机视觉社区不同, 智能电网优化领域几乎没有公开数据集. 因此, 研究者们通常利用仿真工具(例如MATPOWER^[79])作为替代方案以产生所需的训练样本. 值得注意的是, 通过仿真工具产生的数据集过于理想, 而现实世界中能收集到的数据集难免出现样本稀缺、样本不平衡等问题. 其次, 受现实世界多种因素(线路老化、温度湿度等)的影响, 电网内部参数(传输线阻抗等)通常是时变的且难以准确测量或估计^[80]. 研究者在利用仿真工具生成数据集时往往将如传输线阻抗等系统参数设为常值, 这无疑限制了现有方法在真实电网中的有效性. 因此, 在非理想场景下如何保证学习优化算法的有效性亟需研究. 一些新兴技术或许有助于解决这些问题, 例如少样本学习^[81]和数据增强^[82].

2.2 数据的安全性

大多数现有的基于学习优化的方法是集中式的, 这意味着需要指定一个管理者收集各节点的信息(例如发电代价函数). 而即使是在分散式/分布式框架下, 不同节点之间也需要交互相关信息. 然而, 节点所有者并不一定愿意共享这些信息, 因此, 如何在不影响学习优化效果的同时保证数据的隐私安全是一个颇具挑战的难题. 潜在的解决方案是联邦学习^[83]和群体学习^[84]. 联邦学习的优势是可以在各节点数据不共享的情况下联合共建一个模型, 其具体做法是将数据保留在本地, 由中央协调器以高效、安全、隐私的方式收集并聚合各节点的模型参数, 从而达成全局模型一致, 再将该全局模型分还给各节点. 群体学习

在联邦学习的基础上引入了边缘计算^[85]、基于区块链^[86]的点对点网络和动态中央协调器, 从而实现了去中心化. 联邦学习和群体学习都允许一定程度的性能损失, 但为所有节点提供了数据的安全性和隐私保护.

2.3 模型的精度

一枚硬币总有正反两面, 与传统的基于数值优化的方法相比, 基于学习的方法在实现优化加速的同时难以避免一定的精度损失^[30,33,38,53,75](可行性、最优性). 可行性问题会对作为关键基础设施的电力系统产生重大安全影响, 而最优性问题则会在电力系统的长期运行中导致大量经济损失. 因此, 对模型的精度进行系统地验证、分析是今后相关研究工作中必不可少的一部分. 遗憾的是, 部分现有研究工作缺失了此部分.

改善可行性的解决方案主要有两种: 一种是在损失函数中添加约束违反的惩罚项以鼓励模型满足约束, 然而大量的实验结果表明, 这一方法只能在一定程度上改善却难以完全保证所得解的可行性. 另一种是为所得解设计一个后处理算法以将其投影至可行域内, 这种方法往往可以保证解的可行性, 但在具体的投影思路上有两个问题值得注意: 若以最近原则将所得解投影至可行域内^[30,52], 则可能会造成较大的最优损失; 若以最小化目标函数为原则将所得解投影至可行域内^[53], 则当目标函数为非凸函数时, 这一思路往往需要借助包括进化算法在内的非凸优化算法, 从而牺牲一定的实时性.

改善最优性的解决方案包括收集大规模、高密度、平衡的数据集^[74]; 设计更好的DNN结构; 调整学习率(learning rate)、批大小(batch size)和迭代次数等超参数^[29].

2.4 模型的扩展性

模型的扩展性是学习优化的一大难题. 现有研究工作通常只将负荷视为时变的系统状态, 而将系统拓扑、发电代价函数等其他系统状态视为恒定量. 然而, 电网随时可能因故障等原因接入/移出发电机, 节点之间的连接状态也会发生变化, 从而导致时变的系统拓扑. 另外, 随着市场燃料价格的浮动等外界因素, 发电机的发电代价同样不是固定的. 因此, 现有方法由于只将负荷设为DNN的输入, 难以适应其他时变系统状态, 从而导致严重的模型扩展性问题. 一个直接的想法是, 随着其他时变系统状态的变化不断更新模型. 然而, 考虑到学习优化“先生成数据, 再训练模型”的工作模式, 该策略将面临极其高昂的计算代

价而难以实时更新模型. 另一个直接的想法是将其他时变因素和负荷一起作为DNN的输入. 然而,这通常会导致严重的维数灾难,即生成一个有代表性的数据集需遍历整个输入域,从而导致极其高昂的计算代价. 为了解决以上问题,一个潜在的解决方案是迁移学习(transfer learning)^[68]. 迁移学习旨在将一个领域学习到的知识迁移到另一个不同但相关的领域内,使得该领域中的问题可以利用已有的知识而无需被视为全新的问题. 遗憾的是,正如Yang等^[68]在其研究工作中指出的那样,除了节省一定的训练时间,迁移学习在适应不同拓扑场景上的表现仍差强人意. 另外,由于DNN的输出层节点通常需要与决策变量一一对应,发电机的接入/移除都将诱导DNN的结构发生变化,从而严重影响迁移学习的有效性.

2.5 模型的鲁棒性与可解释性

基于学习优化的模型被视为一个黑盒,这便导致了两大问题:鲁棒性和可解释性.

模型的鲁棒性通常可以由以下指标衡量:模型输入的微小改变会引起模型的输出如何变化? 基于学习优化的智能电网能量管理方法在面对一些扰动时的脆弱性已经被Chen等^[87]验证. 常规的解决方案是通过大规模的测试集来测试模型会产生的最大误差. 然而,这种离散样本的测试仍然难以建立操作者对基于学习优化方法的信任,从而严重影响了应用前景. 为了解决这一问题,一个可行的解决方案是通过将DNN转化为一个MILP模型获得其所有输入域中将出现的最大预测误差,并通过建立新的训练集以囊括识别出的对抗性样本从而获得更鲁棒的DNN模型^[41,88].

模型的可解释性可以由以下指标衡量:模型是如何产生其最终的输出的? 该问题是机器学习界长久以来仍未解决的难题^[89]. 通过学习优化建立的电网能量管理模型的可解释性同样在现有研究中甚少被关注. 可视化解释模型^[90]和直接构建可解释的模型(例如线性回归、决策树等)两个视角可被用于研究基于学习的模型的可解释性.

3 结语

本文对基于学习优化的智能电网能量管理研究进行了综述,全面梳理了最新的研究工作并总结了3种学习优化的主要类型,提出了实际应用中的5大关键挑战并提供了一些潜在的解决方案. 学习优化和智能电网的深度交互非常具有前景,同时仍有相当多的问题亟待解决,本文有望为该跨学科领域的研究人员提供一些有用的信息和新的见解.

参考文献(References)

- [1] 国家电网公司“碳达峰、碳中和”行动方案[J]. 国家电网, 2021(3): 50.
- [2] Gungor V C, Sahin D, Kocak T, et al. Smart grid technologies: Communication technologies and standards[J]. IEEE Transactions on Industrial Informatics, 2011, 7(4): 529-539.
- [3] Fang X, Misra S, Xue G L, et al. Smart grid—The new and improved power grid: A survey[J]. IEEE Communications Surveys & Tutorials, 2012, 14(4): 944-980.
- [4] Guerrero J M, Vásquez J C, Teodorescu R. Hierarchical control of droop-controlled DC and AC microgrids—A general approach towards standardization[J]. The 35th Annual Conference of IEEE Industrial Electronics. Piscataway: IEEE, 2009: 4305-4310.
- [5] Chowdhury B H, Rahman S. A review of recent advances in economic dispatch[J]. IEEE Transactions on Power Systems, 1990, 5(4): 1248-1259.
- [6] Dommel H W, Tinney W F. Optimal power flow solutions[J]. IEEE Transactions on Power Apparatus and Systems, 1968, PAS-87(10): 1866-1876.
- [7] Padhy N P. Unit commitment—A bibliographical survey[J]. IEEE Transactions on Power Systems, 2004, 19(2): 1196-1205.
- [8] Li Z L, Li Y Z, Liu Y, et al. Deep learning based densely connected network for load forecasting[J]. IEEE Transactions on Power Systems, 2021, 36(4): 2829-2840.
- [9] LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [10] Hinton G, Deng L, Yu D, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups[J]. IEEE Signal Processing Magazine, 2012, 29(6): 82-97.
- [11] Collobert R, Weston J, Bottou L, et al. Natural language processing (almost) from scratch[J]. Journal of Machine Learning Research, 2011, 12: 2493-2537.
- [12] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [13] Thimm G, Fiesler E. High-order and multilayer perceptron initialization[J]. IEEE Transactions on Neural Networks, 1997, 8(2): 349-359.
- [14] LeCun Y, Bengio Y. The handbook of brain theory and neural networks[M]. Cambridge: MIT Press, 1995: 255-258.
- [15] Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J/OL]. 2014, arXiv: 1406.1078.
- [16] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [17] McCulloch W S, Pitts W. A logical calculus of the

- ideas immanent in nervous activity[J]. *The Bulletin of Mathematical Biophysics*, 1943, 5(4): 115-133.
- [18] Abadi M, Barham P, Chen J M, et al. TensorFlow: A system for large-scale machine learning[J]. *CoRR*, 2016, abs/1605.08695: 265-283.
- [19] Paszke A, Gross S, Massa F, et al. Pytorch: An imperative style, high-performance deep learning library[J]. *Advances in Neural Information Processing Systems*, 2019, 32: 8026-8037.
- [20] Jia Y Q, Shelhamer E, Donahue J, et al. Caffe: Convolutional architecture for fast feature embedding[C]. *Proceedings of the 22nd ACM International Conference on Multimedia*. New York: ACM, 2014: 675-678.
- [21] Guo F H, Li G Q, Wen C Y, et al. An accelerated distributed gradient-based algorithm for constrained optimization with application to economic dispatch in a large-scale power system[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, 51(4): 2041-2053.
- [22] Sun H R, Chen X Y, Shi Q J, et al. Learning to optimize: Training deep neural networks for interference management[J]. *IEEE Transactions on Signal Processing*, 2018, 66(20): 5438-5453.
- [23] Ruan G C, Zhong H W, Zhang G L, et al. Review of learning-assisted power system optimization[J]. *CSEE Journal of Power and Energy Systems*, 2020, 7(2): 221-231.
- [24] Yang C C, Hsu Y Y. Estimation of line flows and bus voltages using decision trees[J]. *IEEE Transactions on Power Systems*, 1994, 9(3): 1569-1574.
- [25] Geng X B, Xie L. Learning the LMP-load coupling from data: A support vector machine based approach[J]. *IEEE Transactions on Power Systems*, 2017, 32(2): 1127-1138.
- [26] Nanda J, Sachan A, Pradhan L, et al. Application of artificial neural network to economic load dispatch[C]. *The 4th International Conference on Advances in Power System Control, Operation and Management*. Hong Kong, 1997: 707-711.
- [27] Guo F H, Xu B W, Zhang W A, et al. Real-time optimal power allocation for smart grid system via deep neural network: A learning based approach[C]. *Chinese Control and Decision Conference*. Hefei, 2020: 868-873.
- [28] Guo F H, Xu B W, Xing L T, et al. An alternative learning-based approach for economic dispatch in smart grid[J]. *IEEE Internet of Things Journal*, 2021, 8(19): 15024-15036.
- [29] Xu B W, Guo F H, Zhang W A, et al. E2DNet: An ensembling deep neural network for solving nonconvex economic dispatch in smart grid[J]. *IEEE Transactions on Industrial Informatics*, DOI: 10.1109/TII.2021.3105361.
- [30] Pan X, Zhao T Y, Chen M H. DeepOPF: Deep neural network for DC optimal power flow[C]. *The IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids*. Beijing, 2019: 1-6.
- [31] Pan X, Zhao T Y, Chen M H, et al. DeepOPF: A deep neural network approach for security-constrained DC optimal power flow[J]. *IEEE Transactions on Power Systems*, 2021, 36(3): 1725-1735.
- [32] Zhao T Y, Pan X, Chen M H, et al. DeepOPF+: A deep neural network approach for DC optimal power flow for ensuring feasibility[C]. *IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids*. Tempe, 2020: 6.
- [33] Zamzam A S, Baker K. Learning optimal solutions for extremely fast AC optimal power flow[C]. *IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids*. Tempe, 2020: 6.
- [34] Huang W J, Pan X, Chen M H, et al. DeepOPF-V: Solving AC-OPF problems efficiently[J]. *IEEE Transactions on Power Systems*, 2022, 37(1): 800-803.
- [35] Huang W, Chen M. DeepOPF-NGT: Fast no ground truth deep learning-based approach for AC-OPF problems[Z]. *ICML 2021 Workshop on Tackling Climate Change with Machine Learning*, 2021.
- [36] Zhang L, Chen Y Z, Zhang B S. A convex neural network solver for DCOPTF with generalization guarantees[J/OL]. 2020, arXiv: 2009.09109.
- [37] Fioretto F, Mak T W K, Van Hentenryck P. Predicting AC optimal power flows: Combining deep learning and Lagrangian dual methods[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(1): 630-637.
- [38] Chatzos M, Fioretto F, Mak T W K, et al. High-fidelity machine learning approximations of large-scale optimal power flow[J/OL]. 2020, arXiv: 2006.16356.
- [39] Yan Z M, Xu Y. Real-time optimal power flow: A Lagrangian based deep reinforcement learning approach[J]. *IEEE Transactions on Power Systems*, 2020, 35(4): 3270-3273.
- [40] Owerko D, Gama F, Ribeiro A. Optimal power flow using graph neural networks[C]. *IEEE International Conference on Acoustics, Speech and Signal Processing*. Barcelona, 2020: 5930-5934.
- [41] Venzke A, Qu G N, Low S, et al. Learning optimal power flow: Worst-case guarantees for neural networks[C]. *IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids*. Tempe, 2020: 7.
- [42] Misyris G S, Venzke A, Chatzivasileiadis S. Physics-informed neural networks for power systems[C]. *IEEE Power & Energy Society General Meeting*. Montreal, 2020: 1-5.
- [43] Nellikkath R, Chatzivasileiadis S. Physics-informed neural networks for AC optimal power flow[J/OL]. 2021, arXiv: 2110.02672.
- [44] Hu X Y, Hu H J, Verma S, et al. Physics-guided deep neural networks for power flow analysis[J]. *IEEE Transactions on Power Systems*, 2021, 36(3): 2082-2092.

- [45] Singh M K, Gupta S, Kekatos V, et al. Learning to optimize power distribution grids using sensitivity-informed deep neural networks[C]. IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids. Tempe, 2020: 6.
- [46] Singh M, Kekatos V, Giannakis G B. Learning to solve the AC-OPF using sensitivity-informed deep neural networks[J/OL]. 2021, arXiv: 2103.14779.
- [47] Kim C, Kim K, Balaprakash P, et al. Graph convolutional neural networks for optimal load shedding under line contingency[C]. IEEE Power & Energy Society General Meeting. Atlanta, 2019: 1-5.
- [48] Xiang M X, Yu J, Yang Z F, et al. Probabilistic power flow with topology changes based on deep neural network[J]. International Journal of Electrical Power & Energy Systems, 2020, 117: 105650.
- [49] Yang Y, Yang Z F, Yu J, et al. Fast calculation of probabilistic power flow: A model-based deep learning approach[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2235-2244.
- [50] 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.
- [51] Dobbe R, Sondermeijer O, Fridovich-Keil D, et al. Toward distributed energy services: Decentralizing optimal power flow with machine learning[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1296-1306.
- [52] Guo F H, Xu B W, Zhang W A, et al. Training deep neural network for optimal power allocation in islanded microgrid systems: A distributed learning-based approach[J]. IEEE Transactions on Neural Networks and Learning Systems, DOI: 10.1109/TNNLS.2021.3054778.
- [53] Pan X, Chen M H, Zhao T Y, et al. DeepOPF: A feasibility-optimized deep neural network approach for AC optimal power flow problems[J/OL]. 2020, arXiv: 2007.01002.
- [54] Robson A, Jamei M, Ududec C, et al. Learning an optimally reduced formulation of OPF through meta-optimization[J/OL]. 2019, arXiv: 1911.06784.
- [55] Jamei M, Mones L, Robson A, et al. Meta-optimization of optimal power ow[Z]. Climate Change: How Can AI Help, 2019.
- [56] Chen L J, Tate J E. Hot-starting the Ac power flow with convolutional neural networks[J/OL]. 2020, arXiv: 2004.09342.
- [57] Biagioni D, Graf P, Zhang X Y, et al. Learning-accelerated ADMM for distributed DC optimal power flow[J]. IEEE Control Systems Letters, 2022, 6: 1-6.
- [58] Diehl F. Warm-starting AC optimal power ow with graph neural networks[C]. The 33rd Conference on Neural Information Processing Systems. Piscataway: IEEE, 2019: 1-6.
- [59] Nayak R, Sharma J D. A hybrid neural network and simulated annealing approach to the unit commitment problem[J]. Computers & Electrical Engineering, 2000, 26(6): 461-477.
- [60] Wu T, Angela Zhang Y J, Wang S Y. Deep learning to optimize: Security-constrained unit commitment with uncertain wind power generation and BESSs[J]. IEEE Transactions on Sustainable Energy, 2022, 13(1): 231-240.
- [61] Xavier Á S, Qiu F, Ahmed S. Learning to solve large-scale security-constrained unit commitment problems[J]. INFORMS Journal on Computing, 2021, 33(2): 739-756.
- [62] Zamzam A S, Fu X, Sidiropoulos N D. Data-driven learning-based optimization for distribution system state estimation[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4796-4805.
- [63] Perera A T D, Wickramasinghe P U, Nik V M, et al. Machine learning methods to assist energy system optimization[J]. Applied Energy, 2019, 243: 191-205.
- [64] Misra S, Roald L, Ng Y. Learning for constrained optimization: Identifying optimal active constraint sets[J]. INFORMS Journal on Computing, DOI: 10.1287/ijoc.2020.1037.
- [65] Deka D, Misra S. Learning for DC-OPF: Classifying active sets using neural nets[C]. IEEE Milan Power Technology. Milan, 2019: 1-6.
- [66] Hasan F, Kargarian A, Mohammadi J. Hybrid learning aided inactive constraints filtering algorithm to enhance AC OPF solution time[J]. IEEE Transactions on Industry Applications, 2021, 57(2): 1325-1334.
- [67] Yang Y, Du S J, Zhu Z C, et al. Fast multi-period security-constrained economic dispatch based on deep neural networks[J]. IOP Conference Series: Earth and Environmental Science, 2021, 645(1): 012052.
- [68] Yang Y, Yang Z F, Yu J, et al. Fast economic dispatch in smart grids using deep learning: An active constraint screening approach[J]. IEEE Internet of Things Journal, 2020, 7(11): 11030-11040.
- [69] Chen Y Z, Zhang B S. Learning to solve network flow problems via neural decoding[J/OL]. 2020, arXiv: 2002.04091.
- [70] King R T F A, Tu X P, Dessaint L A, et al. Multi-contingency transient stability-constrained optimal power flow using multilayer feedforward neural networks[C]. IEEE Canadian Conference on Electrical and Computer Engineering. Vancouver, 2016: 1-6.
- [71] Gutierrez-Martinez V J, Cañizares C A, Fuente-Esquivel C R, et al. Neural-network security-boundary constrained optimal power flow[J]. IEEE Transactions on Power Systems, 2011, 26(1): 63-72.
- [72] Liu T J, Liu Y B, Liu J Y, 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.
- [73] Murzakhanov I, Venzke A, Misyris G S, et al. Neural

- networks for encoding dynamic security-constrained optimal power flow[J/OL]. 2020, arXiv: 2003.07939.
- [74] Venzke A, Molzahn D K, Chatzivasileiadis S. Efficient creation of datasets for data-driven power system applications[J]. *Electric Power Systems Research*, 2021, 190: 106614.
- [75] Baker K. A learning-boosted quasi-newton method for AC optimal power ow[J/OL]. 2020, arXiv: 2007.06074.
- [76] King J E, Jupe S C E, Taylor P C. Network state-based algorithm selection for power flow management using machine learning[J]. *IEEE Transactions on Power Systems*, 2015, 30(5): 2657-2664.
- [77] Wächter A, Biegler L T. On the implementation of an interior-point filter line-search algorithm for large-scale nonlinear programming[J]. *Mathematical Programming*, 2006, 106(1): 25-57.
- [78] Shlezinger N, Whang J, Eldar Y C, et al. Model-based deep learning[J/OL]. 2020, arXiv: 2012.08405.
- [79] Zimmerman R D, Murillo-Sánchez C E, Thomas R J. MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education[J]. *IEEE Transactions on Power Systems*, 2011, 26(1): 12-19.
- [80] Bockarjova M, Andersson G. Transmission line conductor temperature impact on state estimation accuracy[C]. *IEEE Lausanne Power Technology*. Lausanne, 2007: 701-706.
- [81] Snell J, Swersky K, Zemel R S. Prototypical networks for few-shot learning[J/OL]. 2017, arXiv: 1703.05175.
- [82] Zhong Z, Zheng L, Kang G L, et al. Random erasing data augmentation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 13001-13008.
- [83] Konečný J, McMahan H B, Yu F X, et al. Federated learning: Strategies for improving communication efficiency[J/OL]. 2016, arXiv: 1610.05492.
- [84] Warnat-Herresthal S, Schultze H, Shastry K L, et al. Swarm Learning for decentralized and confidential clinical machine learning[J]. *Nature*, 2021, 594(7862): 265-270.
- [85] Shi W S, Cao J, Zhang Q, et al. Edge computing: Vision and challenges[J]. *IEEE Internet of Things Journal*, 2016, 3(5): 637-646.
- [86] Swan M. *Blockchain: Blueprint for a new economy*[M]. New York: O'Reilly Media, Inc., 2015.
- [87] Chen Y Z, Tan Y S, Deka D. Is machine learning in power systems vulnerable?[C]. *IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids*. Aalborg, 2018: 1-6.
- [88] Venzke A, Chatzivasileiadis S. Verification of neural network behaviour: Formal guarantees for power system applications[J]. *IEEE Transactions on Smart Grid*, 2021, 12(1): 383-397.
- [89] Gilpin L H, Bau D, Yuan B Z, et al. Explaining explanations: An overview of interpretability of machine learning[C]. *IEEE 5th International Conference on Data Science and Advanced Analytics*. Turin, 2018: 80-89.
- [90] Zhang Q S, Zhu S C. Visual interpretability for deep learning: A survey[J]. *Frontiers of Information Technology & Electronic Engineering*, 2018, 19(1): 27-39.

作者简介

郭方洪(1988—), 男, 副教授, 博士, 从事智能电网可靠性与安全、微电网分布式控制与优化等研究, E-mail: fhguo@zjut.edu.cn;

徐博文(1997—), 男, 硕士生, 从事智能电网安全与分布式优化的研究, E-mail: bwxu@zjut.edu.cn;

张文安(1982—), 男, 教授, 博士生导师, 从事网络化控制、信息融合、工控系统安全等研究, E-mail: wazhang@zjut.edu.cn;

邓瑞龙(1987—), 男, 研究员, 博士生导师, 从事智能电网、工控安全、通信网络等研究, E-mail: dengruilong@zju.edu.cn.

科研团队简介

浙江工业大学信息工程学院网络化系统感知与控制团队依托“智能感知与系统”教育部工程中心、浙江省嵌入式系统联合重点实验室、“网络化运动控制”浙江省高校高水平创新团队等平台, 主要从事网络化运动控制、工业互联网及能源互联网等相关研究工作。相关研究成果获得教育部高校优秀科研成果(自然科学奖)一等奖。

近年来, 围绕“双碳”国家重大战略需求, 系统地开展了含有高比例新能源接入的新型电力系统分布式控制与能量管理相关研究, 提出了含高比例新能源的微电网分布式稳定控制方法、大规模电力系统分布式能量调度方法及新型电力系统可靠性与安全性分析方法等。围绕该方向, 近5年得到国家自然科学基金、浙江省自然科学基金、浙江省“钱江人才”计划、浙江省重点研发计划等项目资助。

课题负责人郭方洪副教授, 主要研究方向为智能电网可靠性与安全、微电网分布式控制与优化、工业大数据分析等。担任IEEE Transactions on Industrial Electronics杂志编委(Associate Editor)、中国自动化学会能源互联网专委会委员。出版英文学术专著1部, 在Automatica和IEEE汇刊等国际著名期刊上发表高水平学术论文40余篇, 个人Google Scholar引用1600余次, 其中单篇最高引用达500余次。

(责任编辑: 郑晓蕾)