

物理-数据-知识混合驱动的人机混合增强智能系统管控方法

张俊, 许沛东, 陈思远, 高天露, 戴宇欣, 张科, 赵杭,
高杰迈, 白昱阳, 李金星, 张浩然, 李湘, 陈玖香

(武汉大学电气与自动化学院, 湖北 武汉 430072)

摘要: 当代系统认知、管理与控制的核心理论、方法与技术已经转移到大数据和人工智能技术上, 这导致当前人工智能技术条件局限与复杂系统认知、管理、控制的需求之间形成了一道鸿沟。因此, 现实的需求催生了人工智能的一种新型形态——人机混合增强智能形态, 即人类智能与机器智能协同贯穿于系统认知、管理、控制等过程的始终, 人类的认知和机器智能认知互相混合, 形成增强型的智能形态, 这种形态是人工智能或机器智能可行的、重要的成长模式。提出了一种物理-数据-知识混合驱动的人机混合增强智能系统管控方法。从可信分布式数据、计算和算法, 物理深度学习, 融合系统运行规则的混合型深度强化学习, 因果分析, 可解释性 AI 与数字人 5 个方面详细阐述了所提方法。最后, 以电力系统调控为背景, 以 3 个应用为例分析了所提方法的应用方式和技术路径。

关键词: 物理-数据-知识混合驱动方法; 人机混合增强智能; 系统管理与控制; 物理深度学习; 因果分析; 可解释 AI; 虚拟数字人

中图分类号: TP319

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202237

A hybrid physics-data-knowledge driven approach for human-machine hybrid-augmented intelligence-based system management and control

ZHANG Jun, XU Peidong, CHEN Siyuan, GAO Tianlu, DAI Yuxin, ZHANG Ke, ZHAO Hang,
GAO Jiemai, BAI Yuyang, LI Jinxing, ZHANG Haoran, LI Xiang, CHEN Jiuxiang

School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China

Abstract: The core theories, methods and technologies of contemporary system cognition, management, and control have been transferred to big data and artificial intelligence technology, resulting in a gap between the limitations of current artificial intelligence technology and the needs of complex system cognition, management, and control. As a result, a real need has spawned a new form of artificial intelligence: human-machine hybrid-augmented intelligence form, that is, the cooperation of human intelligence and machine intelligence runs through the process of system cognition, management, control, and so on. Human cognition and machine intelligence cognition are mixed together to form enhanced intelligence form. This form is a feasible and important growth mode of artificial intelligence or machine intelligence. A hybrid physics-data-knowledge (PDK) driven approach for human-machine hybrid-augmented intelligence-based system management and control was proposed. The proposed approach was illustrated by the following: trustworthy distributed data, computing, and algorithm, physics-informed deep learning, hybrid deep reinforce learning incorporating system operation rules, causal analysis, and interpretable AI and virtual digital human. In the context of power system dispatch and control, three examples were used for explaining the applications and technical pathways of the proposed PDK approach.

Key words: hybrid physics-data-knowledge driven approach, human-machine hybrid-augmented intelligence, system management and control, physics-informed deep learning, causal analysis, interpretable AI, virtual digital human

收稿日期: 2022-06-22; 修回日期: 2022-07-18

通信作者: 张俊, jun.zhang.ee@ieee.org

基金项目: 科技创新 2030—“新一代人工智能”重大项目 (No.2021ZD0112700)

Foundation Item: The National Key Research and Development Program of China (No. 2021ZD0112700)

0 引言

系统科学是研究系统的结构体系、组分关系、功能现象、演化规律的科学,它以不同领域的系统为研究对象,揭示各种系统遵循的现象表征、管控优化方法和演进规律。特别地,复杂系统是复杂性科学和系统科学的交叉学科,复杂系统的研究对象包括系统的功能、行为及相互关系,系统整体的行为和功能,系统的涌现性、自制性、演化性和进化性等。系统理论、方法、技术在生命系统、太空系统、地球系统、社会组织系统、经济管理系统、军事作战系统以及复杂工程系统(如航天、航空、海洋、能源、电力、制造、材料、环保)等领域具有深广的研究和应用空间。

作为上述理论和方法的载体,一大批系统的建模、仿真、分析、管理、控制方法在系统学科发展过程中涌现出来,总体而言,包括机理分析法、统计分析法、回归分析法、层次分解分析法、蒙特卡洛分析法、灰色系统法、模糊集合论法、想定法、神经网络法、计算机辅助法等^[1-2]。近期出现的方法包括混合建模方法、组合建模方法、基于智能代理建模方法、基于 Petri-Net 的建模方法、基于马尔可夫模型的建模方法、基于 Bootstrap 的建模方法、基于贝叶斯网络的建模方法、定性建模方法、基于因果关系的建模方法、基于元胞包自动机的建模方法、专家系统方法、综合集成建模方法、自适应复杂系统建模方法、自组织理论建模方法、分形理论建模与方法等^[3-4]。从多模态线性控制方法(在多个模态点附近利用各自线性系统综合求取对复杂系统的控制量)到基于非线性理论分析和设计复杂系统的控制系统,系统的管理与控制也相应地走过了一个很长的历史时期,然而非线性理论受到太多的模型局限。当代又涌现出智能化控制技术,其将数据科学、人工智能理论和技术运用到系统的控制中,形成智能控制方法,包括模糊控制、神经网络控制、专家系统学习控制、拟人控制、分层递接控制等^[5]。

当代系统认知、管理与控制的核心理论、方法与技术已经转移到大数据和人工智能技术上,然而,当前人工智能技术条件局限与复杂系统认知、管理、控制的需求之间形成了一道鸿沟。一方面,一个系统,尤其是复杂系统,具有诸多的复杂性、不确定性、关联性和开放性,需要抽象层面的

思维能力,即通用人工智能,而仅通过各种人工智能模型的叠加是不可能得到这种通用人工智能的。另一方面,人脑智能的认知也是有限的,如信息带宽极为有限、处理速度缓慢、认知的广度/深度受限、缺乏精确计算的能力。因此,仅以人脑带宽为限制的管控往往无法支撑系统安全、高效、精准决策和运行,还需要引入计算、仿真、人工智能等工具,帮助拓宽认知带宽和提高效率。在系统的管控上,尤其是关键决策的制订和实施、流程过程管理,往往需要进行抽象思维和问题边界的划分,以保证复杂系统的安全运行。在大数据和人工智能的特定问题上,设计合理的机制以获取海量优质无偏化数据和训练鲁棒的人工智能模型,也需要依赖高层次抽象思维,因此,在当前技术条件下,训练和生成可用的、性能优异的人工智能模型也需要依赖人脑智能。

因此,现实的需求催生了人工智能的一种新型形态——人机混合增强智能形态,即人类智能与机器智能协同贯穿于系统认知、管理、控制等过程,将人类的认知和机器智能认知互相混合,形成增强型的智能形态,这种形态是人工智能或机器智能可行的、重要的成长模式^[6]。在参考文献[6]中,作者也提出了混合增强智能的两种基本形态,第一种是人在回路的混合增强智能,第二种是基于认知计算的混合增强智能。

一个系统中各组分结构的物理机理、系统产生的可观测数据以及该系统运行的知识经验构成了系统分析和管控的重要维度。同时,人机混合增强智能可以综合处理、协同运用系统的物理机理、系统观测数据以及人与机器智能及其产生的知识,并将它们融合进系统的复杂管控流程和任务过程,从而最终形成对系统的认知、管理与控制。因此,本文提出了一种基于人机混合增强智能的、融合物理-数据-知识(physics-data-knowledge, PDK)的复杂系统分析管控方法——物理-数据-知识混合驱动的人机混合增强智能系统管控方法,并以3个应用为例说明该方法的应用方式。

本文的组织如下。第1节总体描述物理-数据-知识混合驱动的人机混合增强智能系统管控方法,并从5个方面详细描述其组成部分及相互关联关系。第2节以电力系统调控为背景,以3个应用为例介绍所提方法在具体的复杂系统管控中的理论方法和技术路线。第3节总结全文。

1 物理-数据-知识混合驱动的人机混合增强智能系统管控

物理-数据-知识混合驱动的人机混合增强智能系统管控方法框架如图1所示, 主要由以下方面构成。

① 可信的分布式数据、计算和算法: 分布式、可信的数据采集、存储、计算、处理、下发构成了PDK方法的信息基础和底座。

② 物理深度学习 (physics-informed deep learning, PIDL): 新型的、可以融合物理机理与数据驱动的系统建模方法为PDK方法在小样本、样本失衡等限制下真实系统的建模提供了解决方法。

③ 融合系统运行规则的混合型深度强化学习: 融合系统运行规则与经验知识的数据混合驱动的强化学习方法为提高深度强化学习 (deep reinforcement learning, DRL) 管控策略的鲁棒性和合理性、加快其收敛速度提供了新型方法。

④ 从知识图谱到因果分析: 描述本体特征和实体间关联关系的知识图谱在融合了因果分析方法后, 实现从 if-then 到 what-if 的智能跃迁, 并具备迁移推理的能力。

⑤ 可解释性 AI 与数字人: 在 PDK 方法中, 可解释性技术成为人机智能和知识的交互接口, 而新兴的数字人技术则成为天然满足人机智能交互需求的智能接口技术。

1.1 可信的分布式数据、计算和算法: PDK 方法的信息基础和底座

由于系统各层次主体众多, 各组成部分的关联性存在差异, 想要构建一个集信息存储、计算和处理等功能于一体的系统存在一定的困难。各主体之间可能存在用户隐私、数据安全和管理规程等方面的问题, 数据整合会遇到困难, 与此同时, 高昂的成本也导致在不同机构之间聚合分散的数据十分困难。采用分布式、具有隐私保护和可信传输的架构可以更好地满足复杂系统内各主体和组分之间对信息安全的要求。

参考文献[7]构建了基于区块链、边缘计算和联邦隐私计算的系统分布式架构, 如图2所示。在通信层, 系统利用区块链技术将身份及密钥管理能力应用到平台、网络和节点的安全加固方面, 同时也为链上数据提供了增强版安全服务, 实现对终端设备的数据的分布感知与安全采集。在边缘层, 系统将具有计算、存储、应用等能力的智慧平台部署在靠近数据源头的网络侧, 提供边缘意义上的智能服务, 同时利用联邦计算实现“数据孤岛”的贯穿连通, 从而提升多主体间数据协同计算的安全性和高效性。在应用层, 根据业务需求形成初步的计算模型、应用层与边缘层的交互计算方式模式, 主要表现为结合边缘导向的云边协同和边边联邦计算协同的业务流程, 其数据交互有以下步骤: 1) 应用层将初步计算的模型发给选定的边缘节点, 这些边




图1 物理-数据-知识混合驱动的人机混合增强智能系统管控方法框架

缘节点在联邦架构中被称为聚合服务器 (aggregation server, AS); 2) 聚合服务器将收到的局部模型完整地下发给各联邦客户端; 3) 各客户端在本地利用本地数据更新联邦计算模型, 将更新后的模型参数上传给对应的聚合服务器; 4) 聚合服务器接收各客户端模型后, 利用一种基于区块链的联邦智能学习方式^[8]更新局部联邦聚合模型, 将更新后的模型上传至应用层并更新全局模型。




图2 可信的分布式数据、计算和算法模型构架

如图2中所示, 绿色节点代表智能终端层, 主要用于对底层数据进行采集、存储与传输; 在终端层之上是通信层, 本系统采用区块链技术保证通信过程中数据的可信任性; 经过通信层后, 分布式数据到达图2中蓝色边缘节点组成的边缘层, 它通过就地数据处理的方式, 在满足应用层数据需求的同时, 减轻应用层的数据通信压力; 最后, 经过边缘层处理后的数据进入应用层, 根据业务需求输出所需结果和模型。综上所述, 本节提出的可信的分布式数据、计算和算法模型, 在保护边缘节点的数据隐私和安全的前提下, 减轻了整个系统的通信压力, 提高了模型计算的高效性和可靠性, 为系统智能管理、控制、应用提供一个信息基础和底座。

1.2 物理深度学习: 物理机理与数据融合驱动的系统建模方法

深度学习在科学和工程领域得到了广泛的应用, 但在涉及高维线性和半线性抛物型偏微分方程的求解时, 深度学习效果不尽如人意。近年来, 一些学者提出了物理信息神经网络 (physics-informed neural network, PINN), 它用深度神经网络拟合微

分方程, 从而形成了一系列基于物理信息的人工智能方法, 即物理深度学习。由于物理深度学习是一个数据驱动和物理信息结合的方法, 只要有足够的输入数据, 它就能够高效地将数据驱动方法与物理约束结合起来对偏微分方程进行求解, 并且计算频率和精度都比传统方法高出许多。

对于动态系统的物理模型, 在确定深度学习的输入量和输出量后, 构建神经网络, 并初始化模型参数。该方法将物理定律的约束构建到神经网络中, 根据与时间、特定输入物理量相关的非线性偏微分方程对物理信息部分进行建模。动态系统的动力学方程为一般形式的参数化和非线性偏微分方程, 其形式可以表示为:

$$\frac{\partial u(t, \mathbf{x})}{\partial t} + N[u] = 0 \quad (1)$$

其中, $u(t, \mathbf{x})$ 表示潜在 (隐藏) 解, $\mathbf{x}$ 为输入向量, $N[\cdot]$ 是一个由 λ 参数化的非线性算子, 能够封装数学物理中的守恒定律、扩散过程、对流扩散反应系统和动力学方程等。

因此, 为了描述高动态系统的动力学特性, 定义一个基于物理信息的神经网络 $f(t, \mathbf{x})$, 其结构示意图如图3所示, 它可以由微分方程的左侧给出:

$$f := \frac{\partial u(t, \mathbf{x})}{\partial t} + N[u] \quad (2)$$

该方法构造一个深度神经网络来逼近 $u(t, \mathbf{x})$, 神经网络的输入为观测向量 $\mathbf{x}$ 和时间 t 。同时, 利用自动微分对偏微分方程的各项进行处理, 计算 $u(t, \mathbf{x})$ 对观测向量 $\mathbf{x}$ 和时间 t 的偏导数。因此, 基于物理信息的神经网络 $f(t, \mathbf{x})$ 与逼近 $u(t, \mathbf{x})$ 的神经网络拥有相同的网络参数, 但有不同的激活函数。

将物理约束写入损失函数, 构建一个共同的损失函数来优化两个神经网络的共享参数, 通过最小化均方误差损失来学习神经网络 $u(t, \mathbf{x})$ 和 $f(t, \mathbf{x})$ 之间的共享参数, 其损失函数表示为:

$$\text{MSE} = \text{MSE}_u + \text{MSE}_f \quad (3)$$

$$\text{MSE}_u = \frac{1}{N_u} \sum_{i=1}^{N_u} |u(t_u^i, \mathbf{x}_u^i) - u^i|^2 \quad (4)$$

$$\text{MSE}_f = \frac{1}{N_f} \sum_{i=1}^{N_f} |f(t_f^i, \mathbf{x}_f^i)|^2 \quad (5)$$

其中, MSE_u 和 MSE_f 分别为神经网络的数据误差和




图3 基于物理信息的神经网络结构示意图

物理信息误差。在训练过程中，通过将计算出的误差值反馈给优化器，实现对神经网络参数的更新，最终形成训练好的神经网络模型。

因此，物理深度学习在数据驱动的深度学习方法基础上，利用物理信息损失函数强化了动态系统的物理运行约束，从而捕捉了系统的物理机理特性。与传统的模型求解与数据驱动求解相比，物理深度学习不需要将高阶常微分方程转化为一阶方程来求解，它可以直接处理多个高阶微分方程组。在第2.1节中，笔者通过电力系统暂态过程的示例对物理深度学习的方法进行验证说明。

1.3 融合系统运行规则的混合型深度强化学习：知识-数据混合驱动的强化学习方法

深度强化学习方法可以通过与环境的交互学习最佳决策。在众多的决策问题中，深度强化学习方法具有优秀的表现^[9-10]。然而，在部分实际环境中随机探索的危险性与模拟环境的不可靠使得强化学习较难应用于某些决策问题。因此，为了使得强化学习算法在这些环境中能够得到应用，必须使智能体在整个训练过程中都具有比较良好的表现。

人类专家与先验知识往往有助于提高强化学习应对复杂环境的能力，保证强化学习在运行过程中受到经验知识的约束，使其能够安全高效地与环境交互。模仿学习（imitation learning）可以使智能体达到模仿人类决策的效果^[11]，但其上限只能达到人类经验，不能促使智能体进一步提升其决策性能。为了更好地将人类经验与机器智能结合，研究者提出利用人类知识引导强化学习训练——示教学习，即将人类经验、历史专家操作提炼、转化为“场景-决策”集合，通过添加与先验策略相关的有

监督损失引导强化学习在训练中融合人类经验^[12]。示教学习使智能体通过预训练后，在初期即可获得与人类经验相近的智能，从而缓解在部分实际场景中奖励稀疏或者探索困难等强化学习传统难题^[13]。示教学习较好的初始性能也使得强化学习在某些复杂、决策敏感的业务环境中可以安全地进行训练^[14]。近年来国内外学者围绕示教学习的示教数据质量和性能提升进行了相应研究，对其理论方法进行了积极探索^[13,15-19]。

在此基础上，针对深度强化学习在电力、通信等高动态系统中的安全学习探索和规则/知识高效融合问题，本文进行了融合规则的机器智能增强方法研究。首先，在规则融合方面，考虑到高动态系统的决策敏感性和其内部变量之间丰富的信息交互关系，笔者提出结合图神经网络和仿真约束的高动态系统调控强化学习方法，将高动态系统中复杂的运行规则融合到强化学习的“表征-探索-决策”环节中。考虑到高动态系统中网络拓扑的时变性，基于图注意力网络表征学习的邻域信息传播机制，对高动态系统中变量间的时变信息传递关系进行深入表示，提高智能体对高动态系统实时态势的感知能力；基于领域调控策略有效性判定规则，提出基于长期控制效果的蒙特卡洛树搜索方法，根据系统典型代表场景筛选有效性突出的调控动作，构建精简智能体动作空间；将机理明确的仿真器作为系统规则和约束的具象化表征，提出仿真结果深度引导的探索和部署机制，将机器智能的行为限制在近似的策略可行域中，提高其在约束复杂的高动态系统中探索和应用的稳定性，构造了决策敏感型复杂系统调控业务中人工智能稳定部署架构。基于规

则的知识-数据混合驱动的强化学习方法在复杂系统调控中取得了良好效果,实现了强系统约束下的稳定探索和高效学习^[20-21]。

1.4 从知识图谱到因果分析:从 if-then 到 what-if 的智能跃迁

知识图谱是一种图形数据模型,它捕获实体(例如事件、对象或概念)之间的语义关系,然后将其以图的形式表示。机器学习和深度学习极大地推动了知识图谱的发展,但它们通常无法学习语义之间的因果关系,如参考文献[22]指出的人工智能的未来发展取决于构建包含因果关系概念的系统,允许系统根据一般原则对未曾遇到的情况进行推理。

当前的知识图谱将因果关系表示为简单的二元关系,这些因果关系基于因果名词短语的语言模式^[23-24]。但是因果关系是一种复杂的关系,不能仅表示为当前知识图谱中的因果实体之间的单一链接。知识图谱应该根据实体来建模因果关系,而不仅仅是类似于维基数据(Wikidata)中的名词短语^[25]。知识图谱必须包含更多的因果关系知识用以支持其进行反事实推理,提高人工智能系统的可解释性,实现从 if-then 到 what-if 的智能跃迁。

看不见的未知场景被称为反事实^[26]。在电力系统调度控制中,研究者经常会思考发生这次事故的原因是什么、采取该动作会产生什么影响、如果采取另一个动作会发生什么等问题。人类对这些问题的思考本质上就是反事实推理。人脑对因果关系有着与生俱来的理解能力^[27],可以对少量的数据进行学习、做出推断并考虑反事实场景^[28]。人工智能系统也需要仿照人脑,对因果关系具有内在的理解,并具备反事实推理的能力^[22,29]。

Bareinboim E 等人^[30]将因果贝叶斯网络(causal Bayesian network, CBN)作为因果关系的表示工具,CBN 可评估概率将因外部干预而如何改变,并估计干预的效果。这种方法被广泛应用于政策分析、规划和医疗管理^[31]。Jaimini U 等人^[25]提出 CausalKG 模型,将因果知识集成到知识图谱中,以提高领域可解释性,促进下游 AI 任务中的介入、反事实推理和因果推理。Blomqvist E 等人^[32]通过从文本中自动生成高度准确的因果知识图谱来解决缺乏因果模型的问题,使用知识模式(knowledge pattern, KP)来满足特定用例的不同需求,确保生成的因果模型能够满足所需推理类型的需求或实现预测。

在将因果科学与机器学习结合方面,本文通过将全局加权样本与深度神经网络结合来解决新能源出力预测中的分布外泛化问题,直接对每个输入样本的所有特征进行去相关操作,从而消除相关和不相关特征之间的统计相关性。在数据预处理阶段,本文利用结构因果模型和潜在结果模型探究不同特征之间的因果关系,实现特征选择。本文提出的模型可以通过训练数据各特征之间存在的真实因果关系来改进预测效果,从而实现在未知的测试数据中学习一个稳定的预测模型,其形成的计算平台和结果见第2.2节。

1.5 可解释性 AI 与数字人:人机智能和知识的交互接口

当面对开放性问题时(例如电力调控、无人驾驶、疾病诊断等对安全性要求较高的领域),随着人工智能技术的广泛应用,人工智能系统逐渐表现出存在偏见、缺乏安全性和可靠性、透明度不足以及监管问责等机制混乱的问题。尤其是在关键决策过程中,人工智能技术中存在不透明特性以及无法与人协同决策等问题。人机混合增强智能系统需要满足所有复杂性、关联性、关键性需求,如何实现与人机智能之间的交互和协同决策成为现阶段阻碍人工智能发展的一个重要因素。人机智能接口包含可解释性技术和虚拟数字人技术等,在人机智能混合的实现过程中,研究人机智能接口对人机混合认知的作用机理和关键影响因素、探索人机智能混合过程中的人机是否能够达成互信、如何设计互信机制并验证是目前人机混合增强智能系统亟须研究的关键技术。

可以将机器学习可解释性理解为模型决策结果以可理解的方式向人类呈现,它有助于人们理解复杂模型的内部工作机制以及它们如何做出特定决策等重要问题,保证智能决策的完备性和安全性,使人类能够信任并有效地管理人工智能技术。在以电力系统调控为应用背景的典型任务场景中,本文提出了一种基于可解释性方法的动态系统调控机器智能的理解与表示方法,结合系统内部变量的连接关系图,构建适用于图结构的机器智能模型多层次可解释机制,该方法能够从节点和重要节点子图的角度为调度员提供关于图深度强化学习模型的决策的解释,为可解释技术在电力系统的应用提供了一种多维度且更全面的思路,提高了人工智能在电力系统中的可信度,从而提高了电力系统调

度、运行的效率和准确性^[33-35]。

针对电力系统控制场景下深度强化学习智能体的黑盒性、难以交互性等问题,进一步提出了一种基于信息增益比的加权倾斜决策树(information gain rate based weighted oblique decision tree, IGR-WODT)的策略提取模型,其可将参数在万级别的神经网络模型转换为百级别参数的、层级决策的决策树形式模型,并提供相匹配的控制性能,促进调度员对 AI 决策的理解,并为后续人机知识交互提供支撑^[36]。

基于虚拟数字人的新型人机智能交互接口关键技术集成了智能语音、人像建模、知识推理、TTSA(text to speech & animation)等 AI 技术。虚拟数字人为人机智能交互提供了一种直接的、自然的交互方式。

基于可解释性 AI 技术与虚拟数字人技术的新型人机智能接口能够降低人员工作负荷、提高机器智能辅助决策等性能、支持复杂信息的理解与整合等功能,从而在典型认知任务场景中提升人机认知的正确性、可靠性、高效性。

2 应用示例

2.1 物理深度学习示例

暂态失稳是电力系统发生大规模停电事故的重要原因,快速、准确地对受扰后系统的功角轨迹进行预测是电网安全防控需要考虑的重要问题。电力系统暂态稳定是一个强瞬态非线性过程,其转子运动方程为:

$$\frac{d\delta_i^2}{dt^2} = \frac{1}{T_i} \left(P_{mi} - \sum_{k \in \Omega_i} B_{ik} U_i U_k \sin(\delta_i - \delta_k) - D_i \frac{d\delta_i}{dt} \right) \quad (6)$$

其中, δ_i 是发电机 i 的功角, T_i 、 P_{mi} 、 U_i 和 D_i 分别是发电机 i 的惯性时间常数、机械功率、电压和系统阻尼常数, Ω_i 是发电机 i 的邻域发电机母线集合, b_{ik} 是电网简化导纳矩阵中发电机母线 i 和 k 之间的传输电纳。

本节选取的算例的拓扑图如图 4 所示,包含 14 个母线节点和 20 条支路,系统频率为 50 Hz,时间间隔取 0.01 s。对于转子运动方程中的参数,设置系统阻尼常数和惯性时间常数分别为 2 和 2.53。根据转子运动方程,将上一时刻的发电机功角、惯性时间常数、机械功率和发电机母线电压作为观测值以及神经网络的输入。




图 4 IEEE-14 节点拓扑图

通过 PSS/E 软件生成电力系统暂态仿真数据,在稳定运行的系统中,随机设置节点间线路短路故障,并在 0.1 s 时迅速自清除,将 8 号母线发电机转子作为观测对象,在有功负荷发生波动时预测系统的功角变化曲线,以观察系统是否出现失稳现象。经过 6 000 多条场景数据的训练,分别得到物理深度学习预测模型与深度学习预测模型,随机选择一个训练集之外的场景进行测试,测试曲线如图 5 所示。

对比图 5(a) 和图 5(b) 可以发现,物理深度学习和深度学习都可以取得不错的预测效果,但在细节放大图中可以看到,物理深度学习对功角曲线的波峰和波谷部分的预测效果要明显好于深度学习。这是因为,物理深度学习中采用的物理模型包含了系统的非线性阻尼振荡项,将这一部分的知识用于预测模型的算法可以帮助预测模型学习系统暂态过程中存在的惯量特性。因此,通过仿真验证可以看出,在深度学习已有不错预测效果的基础上,物理信息的融合使物理深度学习可以进一步提升系统变量特性的拟合精度。

2.2 知识图谱和因果分析示例

当前知识图谱只能表示因果实体之间的单一链接,无法表示更复杂的因果关系,同时无法体现因果实体间的因果效应值大小。为此本文提出了调度领域因果知识图谱框架,如图 6 所示。该框架由以下几个步骤组成:首先基于“预训练+微调”模式的文本信息抽取模型解决数据样本量少、监督学习无法保证其收敛的问题^[37];然后基于因果贝叶斯网络对因果知识进行表示,结合领域本体论和因果效应估计方法,将因果知识注入知识图谱,使用观察数据和领域专家知识构建因果知识图谱;最后基于因果知识图谱辅助调度员进行干预和反事实推理,提高知识图谱的领域可解释性,促进知识图谱与电




图5 物理深度学习与深度学习预测效果




图6 调度领域因果知识图谱框架

力系统的融合。

对于因果知识图谱框架中的因果效应估计,本文在风电预测领域进行了相关研究。首先采用基于线性非高斯无环模型 (linear non-gaussian acyclic model,

LiNGAM) 的因果发现算法生成风电预测领域各影响因素之间的因果关系; 然后基于获取的因果关系图, 采用双重机器学习 (double machine learning) 计算各特征与风电功率之间的因果效应值; 最后采用添加随

机常见原因 (random common causes, RCC) 和安慰剂治疗 (placebo treatment, PT) 的两种因果效应反驳方法测试每个因果关系的稳健性。风力发电影响因素因果关系如图 7 所示。

如图 7 所示, 本文以有向无环图 (directed acyclic graph, DAG) 的形式展示因果关系。每个 DAG 节点代表一个变量, 箭头表示因果连接, 箭头起点连接的特征表示原因, 终点连接的特征表示结果。其中结果变量是风电功率, 本文考察了 12 个天气因素对风电功率的影响以及各天气因素彼此之间的相互作用, 包括云层厚度、露点、湿度、臭氧、降水强度、气压、温度、紫外线、能见度、风向、阵风、风速。从图 7 可以看出, 风速、风向、温度与风电功率有直接的因果关系, 露点和气压与风电功率有间接因果关系, 而云层厚度、湿度、臭氧、降水强度、紫外线、能见度、阵风等与风电功率无明显因果关系。利用 LiNGAM 算法创建 DAG 后, 可以估计潜在因果关系的平均干预效果 (average treatment effect, ATE), 也可以利用该因果关系图创建因果知识图谱。

2.3 人机混合增强智能电网调度示例

本节以电力系统调控为场景, 对 PDK 驱动的人机混合增强智能系统管控的部署架构和模式进行讨论与展示。

在构建混合智能方面, 基于传统深度强化学

习, 结合图神经网络和物理/数学机理明确的电力仿真系统, 构建基于图注意力网络的电力系统变量关联关系提取方法和仿真深度探索的训练机制, 实现对电力系统状态的深入感知和对调控策略的稳定探索^[20-21]。进一步构建有监督学习辅助的深度强化学习机制, 为强化学习训练提供持续的指引信息, 提高人工智能技术在复杂电网中的适应性和学习效率^[18-19]。可以有效加快深度强化学习在高比例新能源接入下电网调控等复杂业务中的学习效率, 提高其稳定程度。融合调度规则和知识经验的复杂电力系统调控机器智能增强架构如图 8 所示。

在电力系统调控机器智能的理解与表示方面, 结合系统内部变量的联接关系图, 构建适用于图结构的机器智能多层级可解释机制, 以提高机器智能的可理解性^[33-35]。进一步构建基于新型倾斜决策树算法的深度强化学习控制策略提取框架, 将机器智能以深度神经网络呈现的复杂控制策略转换为具有可解释性的决策树形式策略^[38]。通过具象化重要特征、节点及其拓扑关系构建机器智能多层级可解释机制; 基于决策树模型将万级别参数的 DRL 模型蒸馏到百级别参数的模型, 可以帮助调度员直观理解机器智能决策, 提高机器智能在电力调控场景落地应用的透明度和安全性。基于可解释性方法的电力系统调控机器智能理解与表示如图 9 所示。




图7 风力发电影响因素因果关系




图 8 融合调度规则和知识经验的复杂电力系统调控机器智能增强架构




图 9 基于可解释性方法的电力系统调控机器智能理解与表示

在调度员与调控机器智能人机交互方面, 虚拟数字人关键技术基于实时内容开发平台 Unity 进行集成开发, 技术架构可分为基础层、平台层和应用层。基础层作为虚拟数字人的显示载体, 实现虚拟数字人的外观形象、动作及表情复现。平台层作为虚拟数字人的知识载体, 通过情感分析、语音识别等模型的集成应用, 模仿人类生理、心理及社会行为表现, 对不同类型场景及对话角色进行分析处理。应用层作为虚拟数字人的角色定义载体, 结合实际应用场景领域, 解

决应用问题。在人机交互过程中, 通过对平台层数据接口的调用, 实现虚拟数字人的拟人行为, 利用领域知识图谱进行知识推理, 得到领域知识答复。

作为机器智能的外在表现, 在与调度员的业务沟通中, 虚拟数字人利用部署的机器智能模型、构建的领域知识图谱等进行模型调用与知识推理, 进行业务执行或答疑。虚拟数字人通过行为、语言、表情、动作与调度员更加自然地交互与协作, 具体如图 10 所示。




图10 基于虚拟数字人的电力调控人机智能交互接口

最终, 依托主流电力仿真系统, 搭建 AI-仿真软件交互框架及 AI 训练环境, 构建人机混合增强智能系统调控平台原型系统。该系统通过将电力系统已有调控知识和经验与机器智能充分融合、具象化机器智能决策机制、构造友好的人机交互接口以及推动机器智能的良性进化, 促进人工智能与调度人员的协作配合, 提高调控操作的质量和效率, 增强电网调控水平。

3 结束语

本文首先回顾了系统科学中的系统特性、系统管理和控制的科学和工程方法, 以及人机混合增强智能的概念, 并提出物理-数据-知识混合驱动的人机混合增强智能系统管控方法。本文从可信分布式数据、计算和算法, 物理深度学习, 融合系统运行规则的混合型深度强化学习, 因果分析, 可解释性 AI 与数字人 5 个方面详细阐述了所提方法。最后, 以电力系统调控为背景, 以 3 个应用示例分析了所提方法的应用方式和技术路径。

希望本文为基于人机混合增强智能的复杂系统管理和控制的理论提供一种新的方法: 物理-数据-知识混合驱动方法。该方法是系统科学、控制科学、管理科学、认知科学、数据科学、人工智能科学等学科交叉的产物, 希望该方法能够在社会典型复杂系统的数字化建设和转型中(如航天、航空、海洋、能源、电力、制造、交通、材料、环保等领域)起到积极的作用。

参考文献:

[1] SHLESINGER M F. Complex adaptive systems: an introduction to

computational models of social life[J]. Journal of Statistical Physics, 2007, 129(2): 409-410.

[2] NIAZI M. Introduction to the modeling and analysis of complex systems: a review[J]. Complex Adaptive Systems Modeling, 2016, 4: 1-3.

[3] MANOJ B S, CHAKRABORTY A, SINGH R. Complex networks: a networking and signal processing perspective[M]. [S.l.:s.n.], 2018.

[4] THURNER S, KLIMEK P, HANEL R. Introduction to the theory of complex systems[M]. Oxford: Oxford University Press, 2018.

[5] WANG F Y, CHEN J L. Intelligent control method and application[M]. [S.l.]: China Science and Technology Press, 2020.

[6] ZHENG N N, LIU Z Y, REN P J, et al. Hybrid-augmented intelligence: collaboration and cognition[J]. Frontiers of Information Technology & Electronic Engineering, 2017, 18(2): 153-179.

[7] 白昱阳, 黄彦浩, 陈思远, 等. 云边智能: 电力系统运行控制的边缘计算方法及其应用现状与展望[J]. 自动化学报, 2020, 46(3): 397-410.

BAI Y Y, HUANG Y H, CHEN S Y, et al. Cloud-edge intelligence: status quo and future prospective of edge computing approaches and applications in power system operation and control[J]. Acta Automatica Sinica, 2020, 46(3): 397-410.

[8] CHEN S Y, ZHANG J, BAI Y Y, et al. Blockchain enabled intelligence of federated systems (BELIEFS): an attack-tolerant trustable distributed intelligence paradigm[J]. Energy Reports, 2021, 7: 8900-8911.

[9] HESTER T, STONE P. TEXPLORE: real-time sample-efficient reinforcement learning for robots[J]. Machine Learning, 2013, 90(3): 385-429.

[10] XIONG Y H, ZHENG G J, XU K, et al. Learning traffic signal control from demonstrations[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2019: 2289-2292.

[11] ROSS S, GORDON G, BAGNELL D. A reduction of imitation learning and structured prediction to no-regret online learning[C]//Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. [S.l.:s.n.], 2011: 627-635.

- [12] HESTER T, VECERIK M, PIETQUIN O, et al. Deep Q-learning from demonstrations[J]. arXiv preprint, 2017, arXiv:1704.03732.
- [13] JING M X, MA X J, HUANG W B, et al. Reinforcement learning from imperfect demonstrations under soft expert guidance[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(4): 5109-5116.
- [14] NAIR A, MCGREW B, ANDRYCHOWICZ M, et al. Overcoming exploration in reinforcement learning with demonstrations[C]//Proceedings of 2018 IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2018: 6292-6299.
- [15] GAO Y, XU H Z, LIN J, et al. Reinforcement learning from imperfect demonstrations[J]. arXiv preprint, 2018, arXiv:1802.05313.
- [16] RAMÍREZ J, YU W, PERRUSQUÍA A. Model-free reinforcement learning from expert demonstrations: a survey[J]. Artificial Intelligence Review, 2022, 55(4): 3213-3241.
- [17] KILINC O, MONTANA G. Reinforcement learning for robotic manipulation using simulated locomotion demonstrations[J]. Machine Learning, 2022, 111(2): 465-486.
- [18] LI X S, WANG X, ZHENG X H, et al. SADRL: merging human experience with machine intelligence via supervised assisted deep reinforcement learning[J]. Neurocomputing, 2022, 467: 300-309.
- [19] LI X S, WANG X, ZHENG X H, et al. Supervised assisted deep reinforcement learning for emergency voltage control of power systems[J]. Neurocomputing, 2022, 475: 69-79.
- [20] XU P D, PEI Y Z, ZHENG X H, et al. A simulation-constraint graph reinforcement learning method for line flow control[C]//Proceedings of 2020 IEEE 4th Conference on Energy Internet and Energy System Integration. Piscataway: IEEE Press, 2020: 319-324.
- [21] XU P D, DUAN J J, ZHANG J, et al. Active power correction strategies based on deep reinforcement learning—part I: a simulation-driven solution for robustness[J]. CSEE Journal of Power and Energy Systems, 2022, 8(4): 1122-1133.
- [22] PEARL J, MACKENZIE D. The book of why: the new science of cause and effect[M]. [S.l.:s.n.], 2018.
- [23] HEINDORF S, SCHOLTEN Y, WACHSMUTH H, et al. CauseNet: towards a causality graph extracted from the web[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM Press, 2020: 3023-3030.
- [24] SPEER R, CHIN J, HAVASI C. ConceptNet 5.5: an open multilingual graph of general knowledge[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. [S.l.:s.n.], 2017: 4444-4451.
- [25] JAIMINI U, SHETH A. CausalKG: causal knowledge graph explainability using interventional and counterfactual reasoning[J]. IEEE Internet Computing, 2022, 26(1): 43-50.
- [26] PEARL J. Causality[M]. Cambridge: Cambridge University Press, 2009.
- [27] VIALE R. Causal cognition and causal realism[J]. International Studies in the Philosophy of Science, 1999, 13(2): 151-167.
- [28] TENENBAUM J B, KEMP C, GRIFFITHS T L, et al. How to grow a mind: statistics, structure, and abstraction[J]. Science, 2011, 331(6022): 1279-1285.
- [29] MARCUS G, DAVIS E. Rebooting AI: building artificial intelligence we can trust[M]. [S.l.:s.n.], 2019.
- [30] BAREINBOIM E, BRITO C, PEARL J. Local characterizations of causal Bayesian networks[M]//Graph structures for knowledge representation and reasoning. Heidelberg: Springer, 2012: 1-17.
- [31] SHPITSER I, SHERMAN E. Identification of personalized effects associated with causal pathways[J]. Uncertainty in Artificial Intelligence, 2018: 198.
- [32] BLOMQVIST E, ALIREZAIE M, SANTINI M. Towards causal knowledge graphs - position paper[C]//Proceedings of the Knowledge Discovery in Healthcare Data. [S.l.:s.n.], 2020.
- [33] ZHANG K, XU P D, ZHANG J. Explainable AI in deep reinforcement learning models: a SHAP method applied in power system emergency control[C]//Proceedings of 2020 IEEE 4th Conference on Energy Internet and Energy System Integration. Piscataway: IEEE Press, 2020: 711-716.
- [34] ZHANG K, XU P D, GAO T L, et al. A trustworthy framework of artificial intelligence for power grid dispatching systems[C]//Proceedings of 2021 IEEE 1st International Conference on Digital Twins and Parallel Intelligence. Piscataway: IEEE Press, 2021: 418-421.
- [35] ZHANG K, ZHANG J, XU P D, et al. Explainable AI in deep reinforcement learning models for power system emergency control[J]. IEEE Transactions on Computational Social Systems, 2022, 9(2): 419-427.
- [36] DAI Y X, CHEN Q M, ZHANG J, et al. Enhanced oblique decision tree enabled policy extraction for deep reinforcement learning in power system emergency control[J]. Electric Power Systems Research, 2022, 209: 107932.
- [37] 李金星, 李湘, 高天露, 等. 基于电网多元信息知识图谱的故障处置研究及应用[J]. 电力信息与通信技术, 2021, 19(11): 30-38.
LI J X, LI X, GAO T L, et al. Research and application of fault handling based on power grid multivariate information knowledge graph[J]. Electric Power Information and Communication Technology, 2021, 19(11): 30-38.
- [38] 戴宇欣, 陈琪美, 高天露, 等. 基于加权倾斜决策树的电力系统深度强化学习控制策略提取[J]. 电力信息与通信技术, 2021, 19(11): 17-23.
DAI Y X, CHEN Q M, GAO T L, et al. Deep reinforcement learning control policy extraction based on weighted oblique decision tree[J]. Electric Power Information and Communication Technology, 2021, 19(11): 17-23.


[作者简介]



张俊(1981—),男,博士,武汉大学电气与自动化学院教授、博士生导师,中国自动化学会副秘书长,IEEE 射频识别理事会副主席。主要研究方向为大数据、人工智能、物联网等新一代信息技术及其在电力能源等复杂系统中的应用。



许沛东(1995-), 男, 武汉大学电气与自动化学院博士生, 主要研究方向为人工智能、智能电网。



高杰迈(1995-), 女, 武汉大学电气与自动化学院博士生, 主要研究方向为综合能源系统、智能电网和物理深度学习。



陈思远(1993-), 男, 武汉大学电气与自动化学院博士生, 主要研究方向为电力系统运行与控制、人工智能和机器学习。



白昱阳(1997-), 男, 武汉大学电气与自动化学院硕士生, 主要研究方向为深度强化学习在电力系统调度中的应用。



高天露(1994-), 男, 武汉大学电气与自动化学院博士生, 主要研究方向为自然语言处理、区块链和人机混合增强智能在电力系统运行分析和控制决策中的应用。



李金星(1996-), 男, 武汉大学电气与自动化学院硕士生, 主要研究方向为人工智能技术在电网故障定位及故障处置中的应用。




戴宇欣(1996-), 男, 武汉大学电气与自动化学院博士生, 主要研究方向为人工智能技术及其在电力系统中的应用。



张浩然(1999-), 男, 武汉大学电气与自动化学院硕士生, 主要研究方向为人工智能在电力系统中的应用。



张科(1993-), 女, 武汉大学电气与自动化学院博士生, 主要研究方向为人工智能技术在电力系统中的应用、可信任的人工智能系统以及人机混合智能。



李湘(2000-), 女, 武汉大学电气与自动化学院硕士生, 主要研究方向为人工智能在电力系统中的应用。



赵杭(1995-), 男, 武汉大学电气与自动化学院博士生, 主要研究方向为因果推理在电力系统中的应用。



陈玖香(2001-), 女, 武汉大学电气与自动化学院硕士生, 主要研究方向为人工智能在电力系统中的应用。