

大模型赋能的电力装备运行状态智能感知新模式探索

何 成^{1,2}, 王子信¹, 周云天¹, 贺泳霖¹, 张传计^{1,2}, 李红斌^{1,2}, 程时杰^{1,2}

(1. 华中科技大学电气与电子工程学院, 武汉 430070; 2. 强电磁技术全国重点实验室, 武汉 430070)

摘 要: 电力装备运行状态智能感知是支撑新型电力系统安全可靠运行的关键技术, 为实现装备的预防性运维与健康状态动态评估提供核心信息。该文综述了电力装备运行状态智能感知的技术发展与研究现状, 从先进传感技术、集群感知方法与人工智能学习范式 3 个层面系统梳理了相关研究进展, 并归纳了其典型工程应用。最后, 针对新型电力系统呈现的强随机、宽动态、高时变等复杂特性, 分析了现有感知技术在传感性能、多模态数据融合与泛工况适应方面的不足, 进而探讨了大模型赋能电力装备状态智能感知的关键技术路径, 旨在为实现电力装备的状态自评估、故障自诊断与工况自适应提供参考。

关键词: 电力装备; 智能感知; 先进传感技术; 人工智能; 大模型

Exploration of Large-model-enabled IntelliSense Paradigms for Power Equipment Operation States

HE Cheng^{1,2}, WANG Zixin¹, ZHOU Yuntian¹, HE Yonglin¹, ZHANG Chuanji^{1,2}, LI Hongbin^{1,2}, CHENG Shijie^{1,2}

(1. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430070, China;

2. State Key Laboratory of Advanced Electromagnetic Technology, Wuhan 430070, China)

Abstract: IntelliSense of operation state for power equipment is a key technology underpinning the safe and reliable operation of new-type power systems, and it provides core information to enable real-time health-state assessment and preventive maintenance. This paper reviews the development and current status of IntelliSense technologies from three perspectives, i.e., advanced sensing techniques, collective sensing methods, and artificial intelligence learning paradigms, and then their applications in typical engineering scenarios are also outlined. Finally, the limitations of existing technologies are analyzed in terms of sensing performance, multimodal fusion, and general operating-condition adaptability, in response to the strong stochasticity, wide dynamic range, and high time variability exhibited by new-type power systems. On this basis, key technical pathways for large-model-enabled IntelliSense of operation state for power equipment are discussed. This work aims to provide technical references for enabling self-assessment, self-diagnosis, and operating-condition adaptation of power equipment.

Key words: power equipment; IntelliSense; advanced sensing technique; artificial intelligence; large models

0 引言

电力设备的良好运行是电网可靠供电的基础。随着我国经济社会快速发展, 在运电力装备规模持续扩大, 省级电网保有装备规模可达亿级, 电力装备的运维工作量巨大^[1]。传统运维依赖计划性状态检测方法, 其检测效率低、实时性差且精准评价困难。通过实时感知电力装备的运行状态, 有目的地制定运维策略, 实现电力装备的精准运维, 已成为学界和行业共识^[2]。

电力装备运行状态感知遵循信号传感、数据处理与运行状态诊断的基本流程^[3]。信号传感将温度、振动、电磁场等物理量转换为便于采集的电信号, 为感知提供信息基础^[4]; 数据处理将分散的测量信息整合为可信特征, 为感知提供特征基础^[5]; 运行状态诊断将特征映射为装备健康状态, 实现状态辨识与故障诊断^[6]。

新型电力系统建设推动电网逐步成为结构复杂、设备繁多的高维信息物理系统, 亟需高敏感、多参与与强泛化的状态感知新技术支撑。然而, 现有技术存在传感灵敏度与响应带宽不足^[7]、多源异构数据融合对齐困难^[8]、少样本条件下模型泛化能力与可解释性不足^[9]等缺陷, 无法满足感知需求。

为此, 需构建具备自主感知、自适应融合与可解释推理能力的智能感知体系。

大模型技术的兴起为突破上述瓶颈提供了新路径。相较于面向单一任务的传统深度学习模型, 大模型的突出作用不在于参数规模扩大本身, 而在于其通过大规模预训练实现了知识表征、跨模态理解、推理生成与任务编排能力的统一, 能够支撑跨模态对齐、知识组织和跨任务迁移^[10]。传统深度学习方法多针对特定任务和特定数据构建专用模型, 虽在状态识别、故障分类和趋势预测等方面取得了较好效果, 但总体仍属于“单任务-单模型”的数据拟合范式, 存在知识利用不足、跨场景迁移能力弱、复杂工况适应性有限及难以支撑系统级协同推断等问题。相比之下, 大模型有望将传感波形、巡检图像、运维文本和运行规程等多源异构信息纳入统一语义空间和同一分析流程, 推动电力装备状态感知由局部判别向“感知—推理—决策”一体化演进, 更好服务于状态识别、异常诊断和决策生成等业务。

目前, 大模型已在电力设备运维、缺陷识别和知识问答等方面展现出初步应用潜力。然而, 电力装备运行状态感知所依赖的连续时序信号具有强非平稳性、强工况耦合性和显著物理约束特征, 现有电力大模型尚未针对电力传感信号统计规律、跨模态关联机理及装备状态演化过程开展充分适配, 因而难以直接迁移至高精度、高可靠的运行状态感知任务^[11]。因此, 大模型在电力领域的价值不在于简单替代传统深度学习模型, 而在于与专用感知模型、物理机理模型及领域知识协同融合, 系统拓展智能感知方法的能力边界。

亟需从感知数据、感知模型和感知功能 3 个层面系统探索大模型赋能的智能感知技术路径, 提升电力装备状态感知在传感性能、多模态融合和泛工况适应等方面的能力。本文综述电力装备运行状态智能感知的技术发展与研究现状, 梳理电力传感技术、集群感知方法与人工智能学习范式的研究进展, 分析新型电力系统下面临的新挑战, 讨论大模型的应对潜力及适用边界, 进而总结其发展脉络及电力应用现状, 并从电力传感、集群感知与学习范式演进等方面探讨大模型赋能电力装备运行状态感知的实现路径, 为实现自评估、自诊断与自适应的电力装备运行状态智能感知提供参考。

1 电力装备运行状态感知的关键技术

电力装备运行状态感知通过观测并分析装备运行过程中的物理量来评价装备的运行状态, 主要包括信号传感、数据处理及状态分析等环节。本章将从感知载体、数据保障与核心功能 3 个层面梳理相关研究进展, 并选取典型电力装备, 综述状态感知技术的应用效果(如表 1 所示)。

1.1 感知载体: 电力传感技术

电力装备的绝缘老化、载流发热、机械松动与局部放电等状态劣化, 往往以电磁量、热量、化学组分与力学响应等多物理量耦合形式体现于运行过程。相较于通用传感技术, 电力传感面临强电磁干扰、极端温湿度与高动态范围等挑战, 需围绕传感新原理、新材料与新器件开展研究, 从而为后续数据处理提供多维度信息, 具体技术如表 2 所示。

1.1.1 电力传感原理

电力传感原理是电力传感材料与器件研发的理论基础, 其本质是利用不同物理效应实现对电力装备运行状态相关信号的感知与转换。围绕电磁、热力、化学、力学等典型状态信息, 研究者已揭示出多种可用于传感的物理效应, 为敏感材料筛选、器件结构设计和应用场景拓展提供了理论依据。

在电磁信号感知方面, 磁电阻效应、磁致伸缩效应、电光效应和量子效应构成了主要理论基础。磁电阻效应反映了材料电阻随外加磁场变化的规律, 包括各向异性磁电阻效应^[12]、巨磁阻效应^[13]及隧道磁电阻效应^[14]等; 磁致伸缩效应是铁磁材料在外加磁场作用下产生机械应变的现象^[15]; 电光效应是某些晶体在外电场作用下折射率发生改变的现象^[16]; 以金刚石氮空位色心(NV 色心)为代表的量子效应则为高灵敏磁场测量提供了新的机理基础^[16]。这些效应共同支撑了电流、电场和磁场等电磁量传感技术的发展。

在热力信号感知方面, 热光效应、热膨胀效应和散射光谱效应是实现主要途径。热力信号的传感主要依托热光效应、热膨胀效应与布里渊散射效应等实现。热光效应是介质折射率随温度变化而改变的现象^[17]。热膨胀效应体现材料尺度对温度变化的响应特性^[18]。布里渊散射效应则揭示了光与介质中声子相互作用产生频移散射光的机理^[19]。上述效应为温度及相关热过程感知提供了重要理论支撑。

在化学信号感知方面, 吸收光谱效应、光声效

表 1 电力装备运行状态感知的关键技术

Table 1 Key technologies for operation status sensing of power equipment

类别	具体内容
电力传感	电磁信号：磁电阻效应、磁致伸缩效应、电光效应、量子效应
	热力信号：热光效应、热膨胀效应、布里渊散射效应
	化学信号：吸收光谱效应、光声效应、拉曼散射效应
	力学信号：压电效应、光弹效应
电力传感	电磁敏感材料：Terfenol-D 合金、TbFe/FeCo 多层膜、铌酸锂晶体、金刚石 NV 色心
	热敏材料：石英光纤、光子晶体光纤、标准单模光纤
	化学敏感材料：石英玻璃、氟化钙、压电石英晶体、空心光子晶体光纤
	力学敏感材料：锆钛酸铅压电陶瓷、聚偏氟乙烯柔性压电聚合物、透明聚合物
传感器件	电磁信号传感器：磁阻电流传感器、磁致伸缩光纤磁场传感器、光波导电场传感器、NV 色心传感器
	热力信号传感器：FBG 温度传感器、液体填充光子晶体光纤温度传感器、BOTDR/BOTDA、拉曼分布式温度传感系统
	化学信号传感器：TDLAS 多气体检测器件、光声光谱传感器、CERS 检测器件
	力学信号传感器：压电晶片主动传感器、压电阻抗传感器、压电浮栅传感器、偏振式光纤应力传感器、FBG 压力传感器
集群感知	硬件冗余法：静态表决、自适应表决
	解析冗余法：变点检测、约束构造、主成分分析
	混合冗余法：信息冗余法、多样性冗余法
	机理模型法：加权最小二乘
软测量	数据驱动法：偏最小二乘回归、支持向量回归、集成学习
	灰箱融合法：混合建模、物理信息神经网络、集合卡尔曼滤波
	约束一致性求解法：约束最小二乘、交替方向乘子法
	概率递推融合法：卡尔曼滤波、粒子滤波、因子图建模
广义标准器	结构化重构法：低秩矩阵补全
	聚类分析：K-means 算法、DBSCAN
	生成建模：自编码器、变分自编码器、生成对抗网络
	传统机器学习：支持向量机、集成学习
人工智能学习	深度神经网络：卷积神经网络、循环神经网络、图神经网络
	聚类与图结构方法：标签传播算法、图卷积网络
	生成建模方法：半监督生成对抗网络、变分自编码器
	绕组匝间短路：轴向磁通传感器、主成分分析、CNN、LSTM
典型应用	轴系扭转振动：电涡流传感器、磁电式拾振器、卡尔曼滤波、LSTM、CNN-LSTM
	热故障：基于 TDLAS 的多组分气体检测装置、支持向量回归、ISSA-CNN、DNN
	局部放电：超高频传感器、静态表决、Swin Transformer
	机械故障：压电式加速度传感器、主成分分析、CNN、度量学习
断路器	绝缘故障：超高频局放传感器、支持向量回归、Swin Transformer
	外力侵扰损伤：DAS 分布式光纤传感、集成学习、GRT-Transformer
	绝缘劣化：超高频传感器、主成分分析、一维 CNN
	过充过放故障：光声光谱气体传感器、卡尔曼滤波、物理约束的深度学习方法
动力电池	短路故障：FBG 光纤温度/应变传感器、集成学习、ResNet+迁移学习

应和拉曼散射效应奠定了原理基础。吸收光谱效应反映了特定气体对特定波长光的吸收特性^[20]。光声效应描述了气体吸收调制光能后产生周期性声波的过程^[21]。拉曼散射效应揭示了光与分子相互作用后产生频率偏移散射光的规律^[22]。这些效应为气体组分分析和绝缘介质状态检测等提供了理论依据。

在力学信号感知方面，压电效应与光弹效应构成了主要原理基础。压电效应是晶体在机械力作用下产生电荷的现象^[23]。光弹效应是材料在应力作用下产生双折射的现象^[24]。上述效应为振动、应力以

及应变等力学量感知提供了重要理论支撑。

1.1.2 电力传感材料

传感材料是实现传感原理的物质载体，其性能直接影响传感器件的灵敏度、响应速度、稳定性及适用范围。近年来，随着电力装备感知需求由单一物理量测量向多场耦合、复杂环境和高可靠运行场景拓展，电力传感材料在电磁、热学、化学和力学等方向均取得了明显进展，并呈现出高灵敏化、宽量程化、集成化和场景适配化的发展趋势。

在电磁感知方面，相关材料主要用于磁场和电

表 2 电力传感技术
Table 2 Power sensing techniques

信号	传感原理	传感材料	传感器/器件
电磁	磁电阻效应	AMR/GMR/TMR 多层膜	磁阻电流/磁场传感器
	磁致伸缩效应	铽镝铁合金、铽铁/铁钴多层膜	磁致伸缩光纤磁场传感器
	电光效应	铌酸锂	光波导电场传感器
	量子效应	金刚石 NV 色心	NV 色心传感器
热力	热光效应	液体填充光子晶体光纤	液体填充光子晶体光纤温度传感器
	热膨胀效应	标准单模光纤	光纤布拉格光栅温度传感器
	布里渊散射效应	传感光纤	布里渊光时域反射仪、分析仪
	吸收光谱效应	石英玻璃、氟化钙	可调谐半导体激光吸收光谱多气体检测系统
化学	光声效应	压电石英晶体	光声光谱传感器
	拉曼光谱效应	空心光子晶体光纤 金属纳米颗粒基底	腔增强拉曼光谱检测系统
力学	压电效应	锆钛酸铅压电陶瓷、 聚偏氟乙烯柔性压电聚合物	压电晶片主动传感器、 压电阻抗传感器、 压电浮栅传感器
	光弹效应	保偏/侧孔光纤、聚醚醚酮封装光纤光栅	偏振式光纤应力/压力传感器、FBG 压力传感器

场信号检测。磁电阻材料和超磁致伸缩材料提升了弱磁场检测^[25]与磁-应变转换能力^[26]；电光晶体材料拓展了宽带电场传感应用^[27]；以超纯金刚石为代表的新型量子敏感材料，则为超高灵敏磁场测量提供了新的实现路径^[28]。总体上，电磁敏感材料正向高灵敏、宽频带和新机理并行发展的方向演进。

在热学感知方面，光纤类材料仍是温度传感的核心载体。基于热光效应的石英光纤材料具有技术成熟、适用范围广等优势，是分布式温度传感的重要基础^[29]；光子晶体光纤通过结构设计增强了温度响应能力^[30]；基于布里渊散射效应的光纤材料则适用于长距离分布式温度监测^[31]。热敏材料的发展总体呈现出高精度、远距离和分布式并重的特点。

在化学感知方面，材料发展主要围绕高灵敏、高选择性和微量检测展开。高透过率光学材料为痕量气体吸收光谱检测提供了基础^[32]；压电石英晶体支撑了光声检测应用；空心光子晶体光纤和金属纳米颗粒基底进一步拓展了拉曼光谱检测能力^[33-34]。总体上，化学敏感材料正朝着高选择性和低检测限方向发展。

在力学感知方面，相关材料主要用于实现振动、应力与形变测量。其中，锆钛酸铅等无机压电

材料适用于高灵敏振动与应力检测^[35]；聚偏氟乙烯等柔性压电聚合物适用于复杂曲面和低频微振动感知^[36]；环氧树脂、聚碳酸酯等透明聚合物则广泛用于应力场测量^[37]。该方向呈现出高灵敏与柔性适配并重的发展趋势。

1.1.3 电力传感器件

电力传感原理与材料的突破，最终需通过传感器件实现工程化应用。传感器件是在一定传感原理指导下，将敏感材料与辅助结构集成为可实际部署的功能单元，是连接传感机理与装备应用的关键载体。通过敏感材料、结构形式和封装方式的优化，同类器件可适配不同电力装备的状态感知需求。

在电磁信号感知方面，相关器件主要包括磁阻电流传感器、磁致伸缩光纤磁场传感器、光波导电场传感器和 NV 色心传感器等。其中，巨磁阻器件通常采用电桥结构实现电流检测^[38]；磁致伸缩光纤器件通过敏感材料与光纤光栅耦合实现磁场测量，适用于强电磁环境^[39]；光波导电场传感器基于干涉或耦合结构实现宽带电场检测^[40]；NV 色心传感器包括激光激发模块、金刚石、微波天线及荧光探测模块，可实现纳米级磁场成像^[41]。

在热力信号传感器件方面，光纤布拉格光栅温度传感器通过在光纤纤芯刻写周期性光栅，形成布拉格反射结构，可实现多点准分布式测量^[42]；光子晶体光纤温度传感器通过特殊结构或填充介质增强温度响应^[30]；布里渊光时域反射仪和布里渊光时域分析仪可实现长距离分布式温度测量^[43]，均可实现千米级分布式测量、米级空间分辨率。拉曼分布式温度传感系统则已广泛用于电力电缆等设备在线温度监测^[44-45]。该类器件总体呈现出高精度、长距离和分布式发展的趋势。

化学信号传感器件方面，相关器件主要面向气体组分与绝缘介质状态检测。可调谐半导体激光吸收光谱传感器通过激光光源、气室和探测电路实现多组分气体检测^[46]；光声光谱传感器利用调制激光与光声池结构实现高灵敏检测^[47]；腔增强拉曼光谱器件则借助高精细度谐振腔提升弱信号探测能力^[48]。总体上，化学传感器件正向高灵敏、高选择性和多组分联合检测方向演进。

在力学信号感知方面，相关器件主要包括压电晶片主动传感器、压电阻抗传感器、压电浮栅传感器、偏振式光纤传感器和光纤布拉格光栅压力传感器等^[49]。压电类器件适用于裂纹、脱黏、腐蚀和局

部刚度变化等状态监测^[50-51]；偏振式光纤传感器通过应力引起的偏振态变化实现压力测量^[52]；光纤布拉格光栅压力传感器则通过封装结构优化增强压力响应能力^[53]。这类器件的发展特点是高灵敏检测与复杂结构适配并重。

总体来看，电力传感器件的发展体现为由原理到材料、再到器件集成的持续推进。一方面，新型器件不断拓展可感知物理量范围和响应频域；另一方面，器件结构设计与封装优化推动传感能力由点式向分布式、由单参量向多参量方向发展，逐步形成信息维度更丰富、时空分辨率更高、环境适应性更强的电力传感体系，为电力装备运行状态感知提供了可靠的物理基础。

1.2 数据增强：集群感知方法

集群感知方法是指面向同一系统中存在同类和异类信息的多源数据体系，综合利用数据间的时空相关性、统计一致性与物理耦合约束，对状态感知开展全维增强的技术^[54]，其核心在于从系统层面将离散观测组织为可校核的信息集群^[55]。该技术目前主要形成自确认、软测量以及广义标准器 3 类关键方法，具体如下表 3 所示。

表 3 集群感知方法

Table 3 Collective sensing methods

技术类别	方法类别	典型方法
自确认技术	硬件冗余法	静态表决、自适应表决
	解析冗余法	变点检测、约束构造、主成分分析
	混合冗余法	信息冗余法、多样性冗余法
软测量技术	机理模型法	加权最小二乘
	数据驱动法	偏最小二乘回归、支持向量回归、集成学习
	灰箱融合法	混合建模、物理信息神经网络、集合卡尔曼滤波
广义标准器技术	约束一致性求解法	约束最小二乘、交替方向乘法
	概率递推融合法	卡尔曼滤波、粒子滤波、因子图建模
	结构化重构法	低秩矩阵补全

1.2.1 自确认

自确认技术是以“同构数据互证”为主线，利用传感器冗余关系实现其自身状态评估的技术，其典型方法有硬件冗余法、解析冗余法及混合冗余法。

硬件冗余法通过部署多路同构传感通道，并借助投票裁决机制实现一致性输出，属于基于多通道一致性比较的自确认方法。该方法结构相对简单、

实时性较好，且不依赖精确物理模型，适用于对可靠性和实时性要求较高的场景，典型方法有静态表决(多数表决^[56]、加权平均表决^[57]、中值表决^[58])、自适应表决^[59]等，适用于一般容错聚合、存在持续偏差或离群通道以及通道可信度动态变化等场景。

解析冗余法主要利用同构量测的时间连续性、统计稳定性或变量间解析关系，构造虚拟参照并开展一致性检验，从而实现在线偏离判别与异常定位。与硬件冗余法相比，该方法无需额外增加硬件成本，能够充分利用已有测量信息实现冗余校核，但其有效性通常依赖于系统关系或数据统计规律的合理建模，典型方法有基于累积和的变点检测^[60]、基于解析冗余关系的约束构造^[61]及基于主成分分析的统计冗余^[62]等，分别适用于在线突变识别与统计决策、系统关系或变量间一致性方程约束构造及多变量相关性压缩与重构残差刻画等场景。

混合冗余法是一种在关键节点保留少量硬件冗余作为长期稳定锚点、同时用解析冗余模块为其余通道构造虚拟参照、并在统一裁决层对两类证据进行融合的自确认技术，通过物理锚点与解析规律的协同，实现多源证据的动态融合与漂移自动校正，优势是兼具硬件冗余的稳定性与解析冗余的灵活性，典型方法为信息冗余法^[63]，多样性冗余法^[64]等，适用于硬件冗余成本过高且解析冗余难以建立精确数学模型的场景。

1.2.2 软测量

软测量技术是以“异构信息映射”为主线，利用物理量间数学关联从多个易测物理量推断少数难测物理量的技术^[65]，可分为机理模型法、数据驱动法以及灰箱融合法。

机理模型法是一种以物理方程约束为基础进行可解化推断的软测量技术，典型方法有加权最小二乘状态估计^[66]等，通过建立状态估计模型将多源量测统一纳入同一可观测性框架，实现一致的系统状态与目标变量估计，优势是可解释性强且结果可校核，适用于机理明确且观测覆盖充分的场景。

数据驱动法是一种聚焦高维非线性映射学习与泛化的软测量技术，从历史数据中学习辅助变量与目标变量之间的映射关系，实现难测量目标量的预测估计，优势是无需精确物理模型且能适应复杂非线性关系，典型方法有偏最小二乘回归^[67]、支持向量回归^[68]及集成学习^[69]等，分别适用于多重共线性与小样本场景、机理难以显式建模而数据关联稳

定的场景以及噪声与变量冗余条件下的场景。

灰箱融合法是一种将物理先验与数据驱动模块进行结构化耦合的软测量技术,通过机理模型提供结构与边界约束、数据驱动模块补偿未建模动态与参数漂移,实现兼具物理可解释性与数据驱动灵活性的软测量推断,优势是泛化能力强且小样本条件下仍能保持精度,典型方法有混合建模^[70]、物理信息神经网络^[71]及集合卡尔曼滤波^[72],分别适用于参数漂移补偿场景、偏微分方程约束下的稀疏数据推断场景以及长期在线递推更新等场景。

1.2.3 广义标准器

广义标准器技术以“参考系推断”为主线,将同构一致性证据与异构物理约束证据组织成统一推断框架,输出目标量的最佳估计及其不确定度表述,满足可追溯的应用需求的技术。其典型方法有约束一致性求解、概率递推融合与结构化重构等。

约束一致性求解法是一种将参考系表达为可解约束方程组的广义标准器技术,通过将守恒关系、拓扑耦合与同构一致性固化为约束并进行优化求解,实现收敛到统一参考系的一致性估计,优势是结构清晰且收敛性有保证,典型方法有约束最小二乘^[73]及交替方向乘法^[74]等,适用于存在硬约束的估计场景以及大规模分布式约束并行计算的场景。

概率递推融合法是一种用后验分布表述参考值与不确定度的广义标准器技术,通过贝叶斯递推将先验信息与观测证据融合为后验分布,实现参考值与不确定度的联合估计与在线更新,优势是能够提供完整的不确定度量化且支持在线递推更新,典型方法有卡尔曼滤波^[75]、粒子滤波^[76]及因子图消息传递^[77]等,分别适用于线性高斯系统的实时状态估计场景、非线性或非高斯系统的后验分布近似场景以及约束可分解为局部因子的分布式推断场景。

结构化重构法是一种在参考约束下恢复高置信度样本的广义标准器技术,通过利用数据在时空与变量维度上的低秩结构将缺失恢复转化为带正则项的凸优化求解,实现可控的缺失数据重构,优势是在满足低秩条件与随机采样假设下可精确恢复且重构结果可融入物理约束进行校核,典型方法有低秩矩阵补全^[78]等,适用于传感器数据缺失恢复、多变量时序数据插补等场景。

1.3 功能应用：人工智能学习范式

数据驱动的人工智能学习范式因能从多源量测数据中学习复杂非线性模式^[79],在异常检测、故障诊

断与健康评估等任务上被广泛应用。根据训练数据集中标签数据的可获得性及其对建模目标的影响,相关方法可分为无监督、有监督与半监督3类。本节将从数学原理与算法范式角度回顾上述方法,如表4所示。

表4 人工智能学习范式

Table 4 Artificial intelligence paradigms			
方法类别	特点	技术分类	代表方法
无监督学习	不依赖标签 适用于未知故障发现、 样本稀缺场景	聚类分析	K-means 算法、 DBSCAN
		生成建模	自编码器、 变分自编码器、 生成对抗网络
有监督学习	高度依赖数据标签 适用于故障机理明确、 高精度诊断任务	传统机器学习	支持向量机、 随机森林
		深度神经网络	卷积神经网络、 循环神经网络、 图神经网络
半监督学习	仅需有限标签数据 适用于标签获取昂贵、 海量监测数据场景	聚类与图结构	标签传播算法、 图卷积网络
		生成建模	半监督生成对抗网络、 变分自编码器

1.3.1 无监督学习

无监督学习不依赖人工标注信息,利用数据自身的统计规律挖掘潜在结构。给定仅包含特征数据的集合 $\{x_i\}_{i=1}^N$,通过最大化似然函数推断最优参数,获得概率密度函数或学习低维流形表示,计算式为:

$$\theta^* = \arg \max_{\theta} \sum_{i=1}^N \ln p(x_i; \theta) \tag{1}$$

式中: θ^* 为最优模型参数; θ 为待估计的模型参数; N 为数据集中样本数量; x_i 为第 i 个输入样本; $p(x_i; \theta)$ 为在参数 θ 下样本 x_i 的概率密度函数。

在故障检测任务中,由于故障样本稀缺,该任务可等价转化为对已知正常样本分布特性进行建模的问题,即对于新样本 x_{new} ,若 $|p(x_{\text{new}}) - \sigma| > \sigma$ (σ 为设定阈值),则判定为异常^[80]。根据对数据分布特征的先验假设,无监督学习可以分为基于几何聚类^[81]与基于生成建模两类方法。

聚类方法侧重于挖掘样本在特征空间中的几何结构,代表性方法是 K-means^[82]和基于密度的带噪声应用空间聚类(density-based spatial clustering of applications with noise, DBSCAN)^[83]。具体而言, K-means 通过迭代优化簇中心以最小化簇内样本的误差平方和,计算效率极高。而 DBSCAN 则基于密度连通性寻找高密度区域,能够有效识别任意不规则形状的运行模式并自动剔除离群噪声。

生成建模方法侧重于学习正常数据的统计分布或流形映射,将异常检测转化为重构质量的评估,代表性方法包括自编码器(autoencoder, AE)^[84]、变分自编码器(variational AE, VAE)^[85]和生成对抗网络(generative adversarial neural network, GAN)^[86]。AE利用重构残差量化异常程度,有效克服了传统方法在高维稀疏数据上的局限。VAE则引入了概率推断增强了模型对随机不确定性的鲁棒性。GAN则将生成器与判别器拆分为两个网络,隐式逼近正常数据的概率分布,常用于解决故障样本极度匮乏下的数据增强问题。

1.3.2 有监督学习

有监督学习方法是在已知完备标签的条件下,建立量测特征与设备运行状态之间的强映射关系。给定包含输入与标签的数据集 $D_L = \{(x_i, y_i)\}_{i=1}^M$ ($y_i \in Y$ 代表故障类别或健康指数),有监督学习通过最小化结构风险函数寻找最优模型参数 θ ,以最小化经验损失,即:

$$\theta^* = \arg \min_{\theta} \frac{1}{M} \sum_{i=1}^M L(y_i, f(x_i; \theta)) \quad (2)$$

式中, θ^* 为最优模型参数; θ 为待估计的模型参数; M 为数据集中样本数量; x_i 为第 i 个输入样本; y_i 为真实标签; $L(\cdot)$ 为衡量预测偏差的损失函数(如交叉熵或均方误差)。

此类方法在故障类型明确、精度要求较高的任务中应用最为广泛。根据模型结构的差异,有监督学习主要分为传统机器学习与深度神经网络两类。

传统机器学习方法通常依赖人工特征工程,侧重于在中小样本下实现鲁棒判别,典型模型包括支持向量机(support vector machine, SVM)^[87]和人工神经网络(artificial neural network, ANN)^[88]。例如, SVM 利用核技巧将非线性数据映射至高维空间,通过求解凸二次规划寻找最大间隔超平面,在小样本高维数据上具有严格的数学理论保证。除了上述基础模型,也有研究通过集成学习将多个弱机器学习模型集成为一个整体增强学习能力,代表性方法是随机森林^[69],其采用 Bagging 策略集成多个决策树,增强了机器学习方法的泛化性^[89]。深度神经网络方法侧重于通过多层非线性变换实现端到端的特征提取,代表性方法包括卷积神经网络(convolutional neural network, CNN)^[90]、循环神经网络(recurrent neural network, RNN)^[91]和图神经网络(graph neural

network, GNN)^[92]。CNN 利用卷积核进行局部感知与权值共享操作,能够有效提取图像中的平移不变特征。RNN 和 GNN 则通过隐藏状态的时间递归和邻域节点的消息聚合机制,能够解决长序列时间依赖与非欧空间拓扑关联的建模难题。

1.3.3 半监督学习

半监督学习方法旨在通过联合利用少量标注样本 D_L 与大量未标注样本 D_U 进行模型训练,解决电力装备场景中“标签稀缺”的难题^[93]。具体而言,半监督学习假设数据分布呈现聚类或流形结构,在有监督学习的基础上引入对应假设的正则化约束,构建最终的优化目标函数 $J(\theta)$, 即:

$$J(\theta) = \sum_{(x,y) \in D_L} L_{\text{sup}}(y, f(x; \theta)) + \gamma \sum_{x \in D_U} L_{\text{unsup}}(f(x; \theta), f(\tilde{x}; \theta)) \quad (3)$$

式中: θ 为待估计的模型参数; D_L 为有标签样本集合; (x, y) 为 D_L 中的有标签样本对(x 为输入样本、 y 为对应标签); L_{sup} 为有监督损失函数; γ 为平衡系数; D_U 为无标签样本集合; $\tilde{x}$ 为由无标签样本 x 经数据扰动后得到的样本; L_{unsup} 为无监督一致性损失函数,通常约束模型对 $\tilde{x}$ 保持输出一致性,或迫使决策边界穿过数据低密度区域。

依据先验假设的不同,现有半监督学习方法可分为基于图结构的流形正则化与基于生成建模的分布对齐两类范式。

基于图结构的流形正则化方法利用“流形假设”刻画数据的几何拓扑,即相似样本在低维流形上具有相似的标签,代表性方法包括标签传播算法(label propagation algorithm, LPA)和图卷积网络(graph convolutional network, GCN)^[94]。LPA 构建样本近邻图并计算拉普拉斯矩阵,通过最小化平滑性能函数,将有限标签信息沿数据流形的高密度区域扩散至未标注样本。GCN 则通过图卷积聚合邻域节点的特征与拓扑信息,实现对未标注数据的有效约束。

基于生成建模的分布对齐方法通过构建潜在变量模型,在特征学习过程中引入无监督正则化项,代表性方法包括半监督生成对抗网络(semi-supervised GAN, SSGAN)^[95]和变分自编码器(Semi-VAE)。SSGAN 通过博弈过程迫使模型同时优化监督分类损失与无监督分布匹配损失,从而辅助修正决策边界。Semi-VAE 通过最大化联合似然的证据下界实现特征空间的分布对齐,显著增强了

模型在标签稀缺情况下的泛化能力。

1.4 智能感知典型应用

本节以电力行业较为关注的发电机、变压器、断路器、电缆与动力电池等 5 类关键设备为例, 梳理了状态感知技术的应用现状, 如表 5 所示。大型汽轮发电机组故障主要分为电气与机械两类。电气故障以绕组匝间短路为代表, 不及时切除将导致机组振动, 并最终引发设备损毁或机组非计划停运^[96]。现有研究采用轴向磁通传感器^[97]采集漏磁通信号, 通过主成分分析提取信号主成分构建故障判别特征^[62], 利用卷积神经网络^[98]与长短期记忆网络(long short-term memory, LSTM)^[99]的方法实现故障诊断。机械故障以轴系扭振为代表, 扭转振动长期累积将导致轴段、叶片及联轴器等部件的疲劳损伤^[100]。现有研究采用电涡流传感器或磁电式拾振器等非接触式传感器获取扭振信号^[4], 通过卡尔曼滤波递归估计扭矩特征^[75], 利用 LSTM^[101]与 CNN-LSTM 融合网络^[3]预测剩余寿命。

截至 2024 年, 全国 220 kV 及以上变压器超 2.7 万台, 其故障主要包括热故障与局部放电两类。热故障是最常见的故障类型, 持续过热将加速绝缘纸纤维的脆化与机械强度的下降, 引发绝缘击穿事故^[102]。现有研究采用调谐半导体激光吸收光谱(tunable diode laser absorption spectroscopy, TDLAS)技术的多组分气体检测装置^[103]获取油中溶解气体信号, 通过支持向量回归拟合溶解气体时序变化构建趋势特征^[68], 利用改进搜索的卷积网络(improved sparrow search algorithm-CNN, ISSA-CNN)^[104]与深度神经网络(deep neural network, DNN)^[105]实现变压器故障诊断。局部放电是绝缘劣化的重要表征, 持续放电将导致绝缘失效^[106]。现有研究采用超高频传感器^[107]获取放电信号, 通过多传感器阵列静态表决构建放电电源定位特征^[56], 利用移位窗口变换器(shifted window transformer, Swin Transformer)实现局放识别^[108]。

截至 2024 年, 全国 220 kV 及以上断路器共 55 339 台, 故障以机械故障为主^[109], 将引发分合闸不及时或拒动, 导致故障扩大、设备损毁甚至大面积停电事故。现有研究采用压电式加速度传感器采集振动信号^[110], 通过主成分分析提取振动信号主成分构建低维振动特征^[62], 利用 CNN^[110]与度量学习^[111]等方法实现故障检测。绝缘故障是断路器另一类重要故障, SF₆ 气体分解产物积累会引发闪络事故^[112]。现有研究采用超高频(ultra-high frequency,

表 5 典型应用

Table 5 Typical applications

典型设备	典型故障	电力传感技术	集群感知方法	人工智能学习范式
发电机	绕组匝间短路	轴向磁通传感器	主成分分析	CNN、LSTM
	轴系扭转	电涡流传感器、磁电式拾振器	卡尔曼滤波	LSTM、CNN-LSTM
	振动			
变压器	热故障	TDLAS 的多组分气体检测装置	支持向量回归	ISSA-CNN、DNN
	局部放电	超高频传感器	静态表决	Swin Transformer
断路器	机械故障	压电式加速度传感器	主成分分析	CNN、度量学习
	绝缘故障	超高频传感器	支持向量回归	Swin Transformer
电缆	外力侵扰损伤	DAS 分布式光纤传感	集成学习	GRT-Transformer
	绝缘劣化	超高频传感器	主成分分析	一维 CNN
动力电池	过充过放故障	光声光谱气体传感器	卡尔曼滤波	物理约束的深度学习模型
	短路故障	FBG 光纤温度/应变传感器	集成学习	ResNet+迁移学习

UHF)局放传感器^[107]检测放电信号, 通过支持向量回归拟合融合学习多类 SF₆ 分解气体组分特征^[68], 利用 Swin Transformer 方法实现 GIS 局放识别^[113]。

截至 2024 年, 全国 220 kV 及以上电缆线路共 25 874 km, 电力电缆故障主要包括外力侵扰损伤与绝缘劣化两类^[114]。外力作用可直接破坏电缆护层与绝缘结构, 导致短路、停电甚至爆炸事故。现有研究采用 DAS 分布式光纤传感技术采集振动信号^[115], 通过集成学习构建时空事件分类特征^[69], 利用 GRT-Transformer 方法实现电缆入侵识别^[115]。在绝缘劣化检测方面, 局部放电是电缆绝缘老化的重要表征^[114], 持续放电将导致电树枝生长并最终引发绝缘击穿失效。现有研究常用高频电流互感器和超高频传感器^[107]检测放电信号, 通过主成分分析提取局放统计特征主成分构建缺陷演化特征^[62], 利用一维 CNN 实现局放监测系统构建^[116]。

锂离子电池的典型故障可分为过充过放故障与短路故障两大类, 均是热失控的主要诱因^[117]。持续的过充电将导致电解液分解与锂枝晶生长, 最终引发热失控甚至起火爆炸事故。现有研究采用光声光谱传感器^[47]检测电池产气信号, 通过卡尔曼滤波构建含噪场景下的 BMS 荷电状态特征^[75], 利用物理约束的深度学习模型实现锂离子电池在线故障诊断^[118]。短路故障可直接引发起火爆炸等严重后

果^[119]。现有研究采用光纤布拉格光栅(fiber Bragg grating, FBG)传感器^[120]监测电池内部温度与应变信号,通过集成学习组合多分类器对充放电特征进行分类构建短路判别特征^[69],利用残差网络(residual neural network, ResNet)以及迁移学习可实现电池健康状态诊断^[121]。

随着新型电力系统的加速构建,电力设备的状态感知技术面临新的挑战:高比例可再生能源与电力电子设备的深度耦合使电网呈现出强随机、宽动态、高时变的复杂特性,导致传感器信噪比下降、多源数据融合困难、模型泛化能力不足,现有技术的感知准确性下降,难以支撑装备状态的实时精准感知^[122]。未来亟需在传感增强、数据融合与模型泛化3个方面实现突破,为电力装备状态感知向智能化方向演进提供技术支撑。

2 大模型赋能智能感知

随着新型电力系统持续建设,电力装备正加速向高电压、大容量和高度集成化方向发展,部署场景也不断向“沙戈荒”、深远海等复杂环境拓展,对运行状态感知的精准性与可靠性提出了更高要求。然而,现有技术在高质量数据感知、多源信息融合和状态应用支撑等方面仍存在不足:

1) 装备集成化和电力电子化使故障特征更加隐蔽、运行信号动态性更强,现有传感技术在灵敏度、动态范围和环境适应性等方面仍受限制。

2) 状态感知涉及波形量测、在线监测、巡检

影像和运维文本等多源异构信息,现有方法在多模态协同融合和跨工况稳定推断方面能力不足^[123]。

3) 故障样本有限、标注成本高且工况持续演化,传统有监督模型在小样本和分布漂移条件下泛化能力受限,纯数据驱动方法的可解释性亦难以满足工程需求^[9]。

近年来,大模型技术的发展为突破上述瓶颈提供了新的思路。大模型通常是指基于 Transformer 架构、在海量数据上预训练并具有大规模参数的深度学习模型^[124]。得益于大规模预训练,其在知识表征、语义理解、推理生成和跨任务迁移等方面展现出明显优势,可为跨文献知识整合、多模态语义对齐和跨场景协同感知提供新的技术支撑。基于此,下文将梳理大模型技术的发展脉络,并进一步探讨其赋能电力装备运行状态智能感知的实现路径与应用模式,如图1所示。

2.1 大模型技术发展演进

人工智能技术总体经历了由传统机器学习、深度学习到大模型的发展过程。传统机器学习主要依赖统计建模^[125]与人工特征设计,深度学习则通过端到端表征学习提升了复杂特征提取能力;近年来,随着算力提升、数据扩展和模型结构创新,以大规模预训练为基础的大模型快速发展,推动模型范式由面向单一任务的定制化建模转向面向多任务、多模态和跨场景应用的统一能力建模。对电力装备运行状态感知而言,这一演进趋势表明,感知模型正由依赖人工经验的浅层建模,逐步走向依托预训练




图1 大模型技术的发展脉络

Fig.1 Development trajectory of large model technology

表征、知识迁移和领域适配的统一感知框架,为跨设备、跨工况和跨区域条件下的稳定感知提供了新的技术基础。

2.1.1 大模型的起源

大模型是人工智能方法持续演进的阶段性结果,其本质是在深度学习基础上,通过大规模预训练推动模型由“任务级”向“能力级”演进。其形成首先得益于 Transformer 架构的提出。Vaswani 等以自注意力机制为核心构建 Transformer,实现了对序列全局依赖关系的高效建模,并显著提升了并行训练能力,为大规模模型训练奠定了结构基础^[126]。随后, BERT 通过在大规模无标注语料上进行预训练,验证了“预训练—微调”范式的有效性,奠定了预训练大模型的发展基础^[127]。

随着参数/数据规模和计算资源持续扩展,大模型进一步由预训练表征模型演进为兼具推理与生成能力的通用大模型。GPT-3 将模型规模提升至千亿参数量级,“Scaling Law”揭示了模型性能随参数、数据和算力协同扩展而持续提升的规律^[128],推动大模型在上下文学习、跨任务迁移和复杂生成等方面展现出显著优势。进一步,结合指令微调、对齐学习、检索增强和工具调用等机制,大模型逐步形成面向多任务、多模态和多场景的统一能力框架。

进一步面向高电压技术等强物理约束、强安全要求的专业领域,大模型开始向专用化方向发展。通过领域数据增强、专业知识注入、物理机理嵌入和任务定制化训练,可在保留通用能力的同时增强其对特定对象、特定工况和工程约束的适应能力,进而形成“通用能力为底座、专业能力为强化”的技术路径。对于电力装备运行状态感知而言,这一路径为多源异构信息融合、统一语义空间构建和复杂工况下的高可靠感知提供了重要支撑。

2.1.2 通用大模型

通用大模型是在大规模预训练范式基础上发展形成的统一模型形态,其核心特征是在少量任务适配条件下支撑多样化下游应用。其典型训练流程包括预训练与对齐两个阶段^[129]:在预训练阶段,模型在海量无标注数据上学习通用语言或多模态表示,获得基础理解与生成能力;在对齐阶段,通过指令微调与偏好对齐等方法,使模型输出更符合人类意图、安全约束与应用规范。

通用大模型的优势根源于其在表征学习与跨任务迁移方面的系统性提升。生成式预训练范式具

备多样化输出能力,奠定了其作为多任务基座的内在机制;而深层模型不同网络层次能够编码句法、语义等不同粒度信息,奠定了层次化通用表征的结构基础。在此基础上,当模型参数规模达到一定阈值后,模型可能在未进行显式监督的情况下表现出推理与迁移等涌现能力,而链式思维提示的引入则可进一步提升模型在多步推理任务中的稳定性与一致性^[130]。上述机理共同支撑了大模型的“通用”能力。

而在功能层面,通用大模型已逐步形成面向复杂任务的系统化范式与工具链。针对知识密集型任务,检索增强生成通过将外部知识库作为非参数化记忆引入生成过程,在推理阶段动态检索并融合相关信息,从而提升生成结果的准确性^[131]。在“推理—执行”一体化方向,推理与行动框架 ReAct 通过将推理过程与外部工具调用交织进行,提高了多步骤任务执行的可控性^[132],而 Toolformer 等则使模型能够自主学习工具调用时机、参数传递与结果利用方式,为复杂任务求解提供了新的技术路径^[133]。

尽管通用大模型在表征学习与跨任务迁移方面展现出显著优势,但仍存在“幻觉”和应用成本高等问题^[134]。而面向电力系统这一强物理约束场景,通用大模型在知识、数据与安全层面的领域适配能力仍显不足,其预训练语料对电力系统物理机理、运行规程与设备特性的覆盖有限,难以充分刻画电力数据强时序性、多模态耦合与严格物理约束等特征,且在面对虚假数据注入等完整性威胁时缺乏有效约束机制,亟需探索面向电力系统特性的专用化与可信化发展路径,以实现可靠、可控与可解释的状态感知。

2.1.3 专用大模型

专用大模型(亦称行业大模型或领域大模型)是在通用大模型基础上,通过领域预训练和任务微调,将领域知识、数据结构与任务偏好系统性注入模型,从而获得对特定行业或应用场景的高适配能力^[135]。在领域预训练阶段,模型在专业领域的大规模语料上进一步学习,以掌握领域术语、知识结构与典型推理模式;在任务微调阶段,则通过指令微调或偏好对齐,使模型输出更好地契合具体业务需求。在应用层面,专用大模型往往与领域知识图谱、专业计算工具等深度集成,以增强模型对结构化知识的利用能力和对业务规则的遵循程度^[136],从而实现“通用能力为基座、领域能力为强化”的模型体系。

专用大模型已在多个行业领域初步应用。在自动驾驶领域,基于 LLaMA2 的自动驾驶系统 DriveGPT4 能够分析行车视频,以自然语言解释驾驶决策并预测车辆控制信号;在气候文本处理领域,基于 DistilRoBERTa 基座的 ClimateBERT 在超过 200 万段气候相关文本上持续预训练,在多项下游任务中显著降低了错误率^[137]。在电力行业,国家电网于 2024 年发布“光明电力大模型”,通过引入标准规程等经验知识,在电力知识理解、多模态分析和业务推理等方面相较基座模型取得约 20% 的性能提升;南方电网则构建了“大瓦特”模型体系,形成了覆盖调度、运检、规划和客服等多业务场景的分层大模型架构。

相较通用大模型,专用大模型在能力结构上具有更强的领域指向性,能够密集表征专业知识并准确理解行业术语、业务规程与逻辑,在专业问答、技术文档生成、数据分析与辅助决策等任务中表现出明显优势,同时在电力、医疗和金融等关键领域更强调输出的可解释性与可信性。然而,现有专用大模型的能力边界仍主要集中于认知型任务,尚难直接支撑电力装备运行状态的智能感知,其核心瓶颈可归结为准确性与可靠性不足:一方面,多模态建模尚未系统刻画电力传感信号的统计特性与物理机理,限制了感知精度与可解释性^[138];另一方面,工程知识虽可被检索或调用,但难以在推理过程中形成强约束,导致结果可溯源性与工程可靠性仍显不足^[139]。因此,有必要在专用大模型基础上,进一步探索与物理模型、传感机理及安全约束深度融合的技术路径,以实现高准确、高可靠的电力装备运行状态智能感知。

2.2 大模型赋能智能感知展望

针对专业大模型采用单一模型范式难以满足电力装备运行状态智能感知的需求,构建大模型与专用小模型协同赋能的智能感知框架成为一条更具可行性与发展潜力的技术路径:通过引入大模型在通用知识表征、跨模态理解与高层推理方面的能力,为状态感知提供统一的语义空间与知识支撑,同时发挥专用小模型在特定传感信号建模、物理特征提取与高精度判别方面的优势,以满足关键状态感知任务对准确性与稳定性的严苛要求^[140]。借助大小模型在功能层级与决策层级上的分工协作与优势互补,有望在保持系统整体泛化能力的同时,实现对电力装备运行状态的高精度与高可靠感知。基于这

一协同思想,后文将从大模型赋能电力传感、集群化智能感知以及人工智能学习范式演进 3 个层面,系统探讨其在电力装备运行状态智能感知中的实现路径与关键科学与工程问题,具体方式如图 2 所示。




图 2 大模型赋能运行状态智能感知

Fig.2 Large models empower IntelliSense

2.2.1 大模型赋能电力传感

大模型赋能电力传感,是指利用其在知识挖掘、推理生成与多模态信息理解方面的能力,从传感原理发现、敏感材料设计与器件结构优化等关键环节提升传感技术的研发效率与性能水平。不同于传统深度学习主要针对既有传感数据进行分类、回归和识别,大模型的突出作用在于可将文献知识、实验记录、结构参数与性能指标纳入统一分析过程,推动模型能力由感知结果判别前移至传感技术设计与优化,为电力装备运行状态高精度感知提供传感支撑,如图 3 所示。




图 3 大模型赋能电力传感

Fig.3 Large models empower power sensing

在传感原理发现方面,大模型主要通过文献知识提取、假设生成推理与跨学科知识融合发挥作用。传统传感原理探索高度依赖研究者经验,且大量机理知识以非结构化形式分散于文献之中,难以系统利用。基于自然语言处理能力,大模型可对海量文献进行自动解析,提取材料—结构—性能之间的潜

在关联, 并转化为可计算的结构化知识表示, 其在材料与化学文献的信息抽取任务中已展现出接近监督学习方法的性能^[141]。同时, 得益于多学科语料预训练, 大模型具备从实验现象或工程观测出发生成可验证机理假设的能力, 其在生物医学等领域的实验验证表明该思路具有可行性^[142]。此外, 多模态基础模型通过联合建模材料结构、电子特性与文本描述, 实现了跨模态信息的统一表征, 为复杂传感机理的系统分析提供了新工具^[143]。

在敏感材料设计方面, 大模型推动材料研发由传统“结构-性能正向筛选”向“目标性能驱动的逆向设计”转变。生成式大模型可从目标性能出发直接生成满足约束条件的材料结构, 将材料设计问题转化为条件生成问题, 例如 MatterGPT 已实现由目标性能反推晶体结构的自动生成^[144]。针对传感材料研究中普遍存在的小样本问题, 材料领域基础模型通过在大规模数据库上预训练获得通用表征能力, 并结合迁移学习, 可显著提升小样本条件下的性能预测精度与稳定性^[145]。同时, 大语言模型支持基于自然语言的人机交互, 使研究人员能够通过文本描述性能需求获取设计建议, 从而降低材料设计对专业经验的依赖^[146]。

在器件结构优化方面, 大模型主要体现为结构逆向生成与零样本性能预测能力。传统传感器件结构设计依赖有限元仿真与大量试错实验, 难以在高维参数空间内高效搜索。生成式大模型通过将器件结构参数编码为序列表示, 可从目标性能直接生成结构方案, 大幅缩短设计周期。例如, OptoGPT 在多层薄膜光学器件设计中实现了亚秒级逆向生成^[147], MetaFO 等模型在超材料结构设计中展现出良好的零样本预测与分布外泛化能力^[148]。尽管相关研究主要集中于光学与超材料领域, 其方法框架对电力传感器件结构优化具有重要借鉴价值。

总体来看, 大模型可在传感原理发现、敏感材料设计与器件结构优化等关键环节对电力传感技术形成系统性赋能, 其核心作用在于加速机理认知、支撑材料与结构的逆向设计并显著提升研发效率。这一路径有望突破传统传感技术研发周期长、试错成本高的瓶颈, 为面向电力装备运行状态感知的高性能传感技术发展提供新的方法基础。

2.2.2 大模型赋能集群感知

面向新型电力系统的广域协同运行需求, 电力设备集群感知正由局部、独立的状态判断向系统级

协同推断演进^[149], 如图 4 所示。大模型凭借知识组织、任务编排与推理生成等能力, 可将分散的多源数据、专业知识与分析工具整合为可执行的推断流程, 推动集群感知由经验驱动的“拼接式分析”向模型驱动的流程化协同转变。不同于传统深度学习主要在单一数据集上训练面向特定对象和特定任务的局部诊断模型, 大模型的突出作用不在于单点诊断精度的局部提升, 而在于能够面向复杂系统实现多源信息整合、跨任务流程衔接以及全局推断组织。其赋能作用主要体现在大规模协同组织、多模态证据融合与泛工况稳定推断等 3 个方面^[150]。




图 4 大模型赋能集群感知

Fig.4 Large models empower collective sensing

在大规模协同组织方面, 大模型通过任务分解与逻辑编排, 将系统级感知目标拆解为具备明确依赖关系的原子任务, 并结合电网拓扑与业务约束, 协同专业求解工具完成一致性校核与证据汇总, 从而降低复杂场景对人工经验的依赖, 并抑制设备规模扩展带来的运维复杂度增长^[151]。

在多模态证据融合方面, 大模型以语言推理为中枢, 联合视觉、传感与文本信息实现跨模态语义对齐, 将多源观测重构为可互证的证据链, 并与运行规程等规范性文本联动, 提升集群诊断与处置决策的可解释性与可核验性^[152]。

在泛工况稳定推断方面, 大模型通过知识检索、任务重编排与人机交互互补机制, 在模态缺失或场景切换条件下维持推断链路连续性, 并与物理模型和专业算法形成分工协同, 将强约束校核固化为结论发布环节, 以保障输出结果的可控与可靠性^[153]。

总体来看, 大模型对电力设备集群感知的赋能, 实质上是对规模协同、证据收敛与稳定发布 3 类关键能力的系统性增强: 通过流程化协同提升大规模系统的组织效率, 通过多模态证据融合构建可解释的诊断闭环, 并通过可控推断机制支撑复杂工

况下的可靠运行^[154]。这一技术路径为大模型深度嵌入电力设备运检与协同决策流程、实现可控演进的工程化部署奠定了重要基础。

2.2.3 大模型赋能人工智能学习范式

在电力装备运行状态智能感知这一高复杂、高可靠应用场景中，大模型以大规模预训练为基座，实现了知识表征、推理生成与任务执行能力的统一沉淀，为构建具备感知—推理—决策能力的智能系统提供了通用能力中枢^[155]。不同于传统深度学习主要依赖单一监督学习范式、面向特定任务进行专用建模，大模型的突出作用不在于单项识别性能的局部提升，而在于通过无监督、有监督与半监督学习的协同演进，形成兼具数据生成、推理校核与快速适配能力的统一学习框架^[156]，这一多范式协同机制共同决定了模型在复杂工况下的生成能力、感知准确性与跨场景泛化能力，从而为电力装备运行状态智能感知提供了更强的基础支撑，如图5所示。




图5 大模型赋能人工智能学习范式

Fig.5 Large-model empowered artificial intelligence learning paradigms

在无监督学习范式下，大模型通过对大规模运行数据、仿真数据与历史工况分布的隐式建模，为电力装备状态感知提供高覆盖的数据生成与工况补齐能力。在故障样本稀缺、极端工况难以复现的场景中，生成模型可合成具有统计一致性的波形、物理场或状态演化轨迹，用于扩展训练数据分布、支撑仿真分析与算法验证^[157]。在引入物理约束与评价函数后，生成过程可进一步与设备机理和运行边界对齐，使状态空间探索由随机采样转向目标驱动发现，为后续感知模型训练与对齐奠定基础。

在有监督学习范式下，大模型通过指令微调、偏好对齐与强化学习^[158]，将通用生成能力压缩至符合电力工程规程与安全约束的任务执行空间，从而提升状态识别、异常诊断与风险评估结果的准确性

与可控性。同时，检索增强与结构化外部记忆机制可将运行规程、设备参数与历史案例引入推理过程，构建可追溯的证据链；多步推理与过程约束则有助于抑制逻辑漂移，使模型在复杂状态演化分析与处置决策中形成可复核的推导路径^[159]。

在半监督学习范式下，大模型的优势主要体现在面向电力系统多设备、多场景与持续演化工况的低成本适配能力。参数高效微调方法使模型能够在少量标注数据条件下快速适配不同设备类型与运行环境^[160]；元学习与少样本学习增强了模型在新工况和分布迁移条件下的鲁棒性；提示学习则通过上下文约束激活预训练知识，为新设备上线或运行策略调整提供快速部署路径，支撑电力感知系统的长期演进。

总体来看，大模型学习范式对电力装备运行状态智能感知的赋能，本质上体现在对数据生成、推理校核与能力适配3类关键环节的系统性重构：在赋能路径上，无监督学习范式提供高覆盖的数据补齐与状态空间探索能力，有监督学习范式保障结果的准确性与可解释性，半监督学习范式支撑模型在多设备、多场景与持续演化工况下的快速部署与长期演进。从工程意义上看，这种多范式协同机制使电力智能感知由依赖静态模型与离线经验的分析方式，转向具备生成、校核与自适应能力的闭环体系，为在复杂工况下实现高准确、高可靠、可演进的电力装备运行状态感知提供了基础支撑。

3 结论

1) 面向新型电力系统建设对电力装备运行状态智能感知的迫切需求，本文系统梳理了电力装备状态感知的关键技术体系与发展脉络。从底层感知层面，综述了电力传感技术在新型电力系统复杂工况下的发展现状与瓶颈，阐明其为状态感知提供高质量原始数据的基础性作用；从系统层面，总结了设备集群感知方法由局部独立分析向系统级协同推断的演进趋势，明确了其在支撑广域协同运行与复杂状态判别中的核心价值；从方法论层面，归纳了人工智能学习范式在电力感知中的应用进展，指出无监督、有监督与半监督学习在数据补齐、推理校核与低成本适配方面对智能感知能力形成的关键支撑作用。上述3类关键技术共同构成电力装备运行状态智能感知的数据基础、模型基础与功能基础。

2) 在此基础上，本文进一步从大模型技术发

展历程与能力演进出发, 系统分析了大模型赋能电力装备运行状态智能感知的内在机理与实现路径。针对新型电力系统强随机、宽动态、高时变等特征带来的跨模态对齐困难、泛场景适应能力不足以及可信性与可解释性有待增强等突出问题, 从大模型赋能电力传感、大模型支撑集群感知以及大模型驱动人工智能学习范式演进等方面进行了前瞻性展望。相关分析表明, 大模型并非以“单一模型替代”为目标, 而是通过在知识组织、推理生成与任务编排层面的能力注入, 与物理模型、专用算法及工程规则形成协同体系, 从而推动电力装备状态感知由经验驱动向模型驱动、由静态分析向闭环演化转变。

3) 总体而言, 大模型赋能电力装备运行状态智能感知的本质, 在于通过统一表征与推理能力打通传感、认知与决策环节, 并在生成、校核与适配的闭环中提升系统的准确性、可靠性与可演进性。其发展路径既涵盖面向科学的人工智能(AI for science, AI4S)理念下的电力传感原理发现、敏感材料与器件设计, 也面向运行阶段的自评估、自诊断与自适应需求, 为构建安全、高效、智能的新型电力系统提供了重要技术支撑。未来, 随着专用大模型、大小模型协同框架以及可信与可解释机制的不断完善, 大模型有望在电力装备运行状态智能感知中发挥更加基础性与体系化的作用, 成为支撑新型电力系统长期稳定运行的重要智能底座。

参考文献 References

- [1] 周孝信, 陈树勇, 鲁宗相, 等. 能源转型中我国新一代电力系统的技术特征[J]. 中国电机工程学报, 2018, 38(7): 1893-1904.
ZHOU Xiaoxin, CHEN Shuyong, LU Zongxiang, et al. Technology features of the new generation power system in China[J]. Proceedings of the CSEE, 2018, 38(7): 1893-1904.
- [2] LEI Y G, YANG B, JIANG X W, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [3] ZHAO R, YAN R Q, CHEN Z H, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [4] 何成, 陈伟根, 胡军, 等. 先进电气传感材料及技术发展战略[J]. 高电压技术, 2025, 51(8): 3846-3875.
HE Cheng, CHEN Weigen, HU Jun, et al. Development strategy of advanced electrical sensing materials and technologies[J]. High Voltage Engineering, 2025, 51(8): 3846-3875.
- [5] 顾菊平, 赵佳皓, 张新松, 等. 电力设备多参量监测数据清洗研究现状及展望[J]. 高电压技术, 2024, 50(8): 3403-3420.
GU Juping, ZHAO Jiahao, ZHANG Xinsong, et al. Research review and prospect of data cleaning for multi-parameter monitoring data of power equipment[J]. High Voltage Engineering, 2024, 50(8): 3403-3420.
- [6] 叶琳, 杨滢, 洪道鉴, 等. 深度学习在电力系统中的应用研究综述[J]. 浙江电力, 2019, 38(5): 83-89.
YE Lin, YANG Ying, HONG Daojian, et al. A survey of deep learning technology application in power system[J]. Zhejiang Electric Power, 2019, 38(5): 83-89.
- [7] 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.
- [8] BALTRUŠAITIS T, AHUJA C, MORENCY L P. Multimodal machine learning: a survey and taxonomy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(2): 423-443.
- [9] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [10] BROWN T B, MANN B, RYDER N, et al. Language models are few-shot learners[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver, Canada: Curran Associates Inc., 2020: 159.
- [11] 严新荣, 高翔, 林达, 等. 大模型在电力行业的应用与挑战[J]. 发电技术, 2025, 46(4): 637-650.
YAN Xinrong, GAO Xiang, LIN Da, et al. Application and challenges of large models in power industry[J]. Power Generation Technology, 2025, 46(4): 637-650.
- [12] THOMSON W. On the electro-dynamic qualities of metals: -effects of magnetization on the electric conductivity of nickel and of iron[J]. Proceedings of the Royal Society of London, 1857(8): 546-550.
- [13] BAIBICH M N, BROTO J M, FERT A, et al. Giant magnetoresistance of (001)Fe/(001)Cr magnetic superlattices[J]. Physical Review Letters, 1988, 61(21): 2472-2475.
- [14] MOODERA J S, KINDER L R, WONG T M, et al. Large magnetoresistance at room temperature in ferromagnetic thin film tunnel junctions[J]. Physical Review Letters, 1995, 74(16): 3273-3276.
- [15] JOULE J P. On the effects of magnetism upon the dimensions of iron and steel bars[J]. The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 1847, 30(199): 76-87.
- [16] DOHERTY M W, MANSON N B, DELANEY P, et al. The nitrogen-vacancy colour centre in diamond[J]. Physics Reports, 2013, 528(1): 1-45.
- [17] GANGWAR R K, KUMARI S, PATHAK A K, et al. Optical fiber based temperature sensors: a review[J]. Optics, 2023, 4(1): 171-197.
- [18] CAMPANELLA C E, CUCCOVILLO A, CAMPANELLA C, et al. Fibre Bragg grating based strain sensors: review of technology and applications[J]. Sensors, 2018, 18(9): 3115.
- [19] BRILLOUIN L. Diffusion de la lumière et des rayons X par un corps transparent homogène[J]. Annales de Physique, 1922, 9(17): 88-122.
- [20] HODGKINSON J, TATAM R P. Optical gas sensing: a review[J]. Measurement Science and Technology, 2013, 24(1): 012004.
- [21] BELL A G. On the production and reproduction of sound by light[J]. American Journal of Science, 1880, s3-20(118): 305-324.
- [22] RAMAN C V, KRISHNAN K S. A new type of secondary radiation[J]. Nature, 1928, 121(3048): 501-502.
- [23] JIAO P C, EGBE K J I, XIE Y W, et al. Piezoelectric sensing techniques in structural health monitoring: a state-of-the-art review[J]. Sensors, 2020, 20(13): 3730.
- [24] BREWSTER D. On the communication of the structure of doubly refracting crystals to glass, muriate of soda, Fluor spar, and other substances, by mechanical compression and dilatation[J]. Philosophical Transactions of the Royal Society of London (1776-1886), 1816, 106: 156-178.
- [25] QUANDT E, LUDWIG A. Magnetostrictive actuation in microsys-

- ments[J]. *Sensors and Actuators A: Physical*, 2000, 81(1/3): 275-280.
- [26] CLARK A E, BELSON H S. Giant room-temperature magnetostriptions in TbFe_2 and DyFe_2 [J]. *Physical Review B*, 1972, 5(9): 3642-3644.
- [27] WEIS R S, GAYLORD T K. Lithium niobate: summary of physical properties and crystal structure[J]. *Applied Physics A*, 1985, 37(4): 191-203.
- [28] TAYLOR J M, CAPPELLARO P, CHILDRESS L, et al. High-sensitivity diamond magnetometer with nanoscale resolution[J]. *Nature Physics*, 2008, 4(10): 810-816.
- [29] KERSEY A D, DAVIS M A, PATRICK H J, et al. Fiber grating sensors[J]. *Journal of Lightwave Technology*, 1997, 15(8): 1442-1463.
- [30] QIAN W W, ZOU C L, HE S L, et al. High-sensitivity temperature sensor based on an alcohol-filled photonic crystal fiber loop mirror[J]. *Optics Letters*, 2011, 36(9): 1548-1550.
- [31] HORIGUCHI T, TATEDA M. BOTDA-nondestructive measurement of single-mode optical fiber attenuation characteristics using Brillouin interaction: theory[J]. *Journal of Lightwave Technology*, 1989, 7(8): 1170-1176.
- [32] HAAS J, MIZAIKOFF B. Advances in mid-infrared spectroscopy for chemical analysis[J]. *Annual Review of Analytical Chemistry*, 2016, 9: 45-68.
- [33] YU R W, CHEN Y X, SHUI L L, et al. Hollow-core photonic crystal fiber gas sensing[J]. *Sensors*, 2020, 20(10): 2996.
- [34] MOSKOVITS M. Surface-enhanced spectroscopy[J]. *Reviews of Modern Physics*, 1985, 57(3): 783-826.
- [35] UCHINO K. Piezoelectric actuators and ultrasonic motors[M]. Boston, USA: Kluwer Academic Publishers, 1997.
- [36] KAWAI H. The piezoelectricity of poly (vinylidene fluoride)[J]. *Japanese Journal of Applied Physics*, 1969, 8(7): 975-976.
- [37] DALLY J W, RILEY W F. Experimental stress analysis[M]. 2nd ed. New York, USA: McGraw-Hill, 1978.
- [38] OUYANG Y, HE J L, HU J, et al. A current sensor based on the giant magnetoresistance effect: design and potential smart grid applications[J]. *Sensors*, 2012, 12(11): 15520-15541.
- [39] QUINTERO S M M, BRAGA A M B, WEBER H I, et al. A magnetostriptive composite-fiber Bragg grating sensor[J]. *Sensors*, 2010, 10(9): 8119-8128.
- [40] BULMER C H. Sensitive, highly linear lithium niobate interferometers for electromagnetic field sensing[J]. *Applied Physics Letters*, 1988, 53(24): 2368-2370.
- [41] ZHANG J X, XU L X, BIAN G D, et al. Diamond nitrogen-vacancy center magnetometry: advances and challenges[EB/OL]. arXiv: 2010.10231, 2020[2026-06-24]. <https://arxiv.org/abs/2010.10231>.
- [42] HILL K O, MELTZ G. Fiber Bragg grating technology fundamentals and overview[J]. *Journal of Lightwave Technology*, 1997, 15(8): 1263-1276.
- [43] BAO X Y, CHEN L. Recent progress in Brillouin scattering based fiber sensors[J]. *Sensors*, 2011, 11(4): 4152-4187.
- [44] BOLOGNINI G, HARTOG A. Raman-based fibre sensors: trends and applications[J]. *Optical Fiber Technology*, 2013, 19(6): 678-688.
- [45] LI J, ZHANG Q, XU Y, et al. High-accuracy distributed temperature measurement using difference sensitive-temperature compensation for Raman-based optical fiber sensing[J]. *Optics Express*, 2019, 27(25): 36183-36196.
- [46] SUN J C, CHANG J, WANG C, et al. Tunable diode laser absorption spectroscopy for detection of multi-component gas: a review[J]. *Applied Spectroscopy Reviews*, 2024, 59(8): 1086-1107.
- [47] WIJESINGHE D R, ZOB AIR M A, ESMAEELPOUR M. A review on photoacoustic spectroscopy techniques for gas sensing[J]. *Sensors*, 2024, 24(20): 6577.
- [48] WANG P Y, CHEN W G, PENG F, et al. Cavity-enhanced Raman spectroscopy with optical feedback frequency-locking for gas sensing[J]. *Optics Express*, 2019, 27(23): 33312-33325.
- [49] AONO K, HASNI H, POCHETTINO O, et al. Quasi-self-powered piezo-floating-gate sensing technology for continuous monitoring of large-scale bridges[J]. *Frontiers in Built Environment*, 2019, 5: 29.
- [50] GIURGIUTIU V. Structural health monitoring with piezoelectric wafer active sensors[M]. 2nd ed. Amsterdam, The Netherlands: Academic Press, 2014.
- [51] PARK G, SOHN H, FARRAR C R, et al. Overview of piezoelectric impedance-based health monitoring and path forward[J]. *The Shock and Vibration Digest*, 2003, 35(6): 451-463.
- [52] BOCK W J, CHEN J, EFTIMOV T, et al. A photonic crystal fiber sensor for pressure measurements[J]. *IEEE Transactions on Instrumentation and Measurement*, 2006, 55(4): 1119-1123.
- [53] LIU Y, LI L Q, ZHAO L, et al. Research on a new fiber-optic axial pressure sensor of transformer winding based on fiber Bragg grating[J]. *Photonic Sensors*, 2017, 7(4): 365-371.
- [54] 余涛, 梁敏航, 罗庆全, 等. 新型电力系统专用传感与边缘智能关键技术及其展望[J]. *高电压技术*, 2024, 50(8): 3324-3338.
- YU Tao, LIANG Minhang, LUO Qingquan, et al. Key technologies and perspectives of specialized sensing and edge intelligence for new power systems[J]. *High Voltage Engineering*, 2024, 50(8): 3324-3338.
- [55] KHALEGHI B, KHAMIS A, KARRAY F O, et al. Multisensor data fusion: a review of the state-of-the-art[J]. *Information Fusion*, 2013, 14(1): 28-44.
- [56] LATIF-SHABGAHI G R, BASS J M, BENNETT S. A taxonomy for software voting algorithms used in safety-critical systems[J]. *IEEE Transactions on Reliability*, 2004, 53(3): 319-328.
- [57] LATIF-SHABGAHI G R. A novel algorithm for weighted average voting used in fault tolerant computing systems[J]. *Microprocessors and Microsystems*, 2004, 28(7): 357-361.
- [58] AO B K, WANG Y C, YU L, et al. On precision bound of distributed fault-tolerant sensor fusion algorithms[J]. *ACM Computing Surveys (CSUR)*, 2017, 49(1): 5.
- [59] RAY A, LUCK R. An introduction to sensor signal validation in redundant measurement systems[J]. *IEEE Control Systems Magazine*, 1991, 11(2): 44-49.
- [60] PAGE E S. Continuous inspection schemes[J]. *Biometrika*, 1954, 41(1/2): 100-115.
- [61] FRANK P M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy: a survey and some new results[J]. *Automatica*, 1990, 26(3): 459-474.
- [62] DUNIA R, QIN S J, EDGAR T F, et al. Identification of faulty sensors using principal component analysis[J]. *AIChE Journal*, 1996, 42(10): 2797-2812.
- [63] ZHONG J, ZHANG H, MIAO Q. Enhancing aircraft reliability with information redundancy: a sensor-modal fusion approach leveraging deep learning[J]. *Reliability Engineering & System Safety*, 2025, 261: 111068.
- [64] YIN Y, XU F Q, PANG B. Online intelligent fault diagnosis of redundant sensors in PWR based on artificial neural network[J]. *Frontiers in Energy Research*, 2022, 10: 1011362.
- [65] KADLEC P, GABRYS B, STRANDT S. Data-driven soft sensors in the process industry[J]. *Computers & Chemical Engineering*, 2009, 33(4): 795-814.
- [66] MONTICELLI A. Electric power system state estimation[J]. *Proceedings of the IEEE*, 2000, 88(2): 262-282.
- [67] WOLD S, SJÖSTRÖM M, ERIKSSON L. PLS-regression: a basic tool of chemometrics[J]. *Chemometrics and Intelligent Laboratory Systems*, 2001, 58(2): 109-130.

- [68] SMOLA A J, SCHÖLKOPF B. A tutorial on support vector regression[J]. *Statistics and Computing*, 2004, 14(3): 199-222.
- [69] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [70] PSICHOGIOS D C, UNGAR L H. A hybrid neural network-first principles approach to process modeling[J]. *AIChE Journal*, 1992, 38(10): 1499-1511.
- [71] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [72] EVENSEN G. The ensemble Kalman filter: theoretical formulation and practical implementation[J]. *Ocean Dynamics*, 2003, 53(4): 343-367.
- [73] LAWSON C L, HANSON R J. Solving least squares problems[M]. Philadelphia, USA: Society for Industrial and Applied Mathematics, 1995.
- [74] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. *Foundations and Trends® in Machine Learning*, 2011, 3(1): 1-122.
- [75] KALMAN R E. A new approach to linear filtering and prediction problems[J]. *Journal of Basic Engineering*, 1960, 82(1): 35-45.
- [76] ARULAMPALAM M S, MASKELL S, GORDON N, et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. *IEEE Transactions on Signal Processing*, 2002, 50(2): 174-188.
- [77] KSCHISCHANG F R, FREY B J, LOELIGER H A. Factor graphs and the sum-product algorithm[J]. *IEEE Transactions on Information Theory*, 2001, 47(2): 498-519.
- [78] CANDÈS E, RECHT B. Exact matrix completion via convex optimization[J]. *Communications of the ACM*, 2012, 55(6): 111-119.
- [79] 谢庆, 王春鑫, 李帆, 等. 知识及数据驱动的电力一次设备健康管理方法综述[J]. *高电压技术*, 2024, 50(2): 605-620.
XIE Qing, WANG Chunxin, LI Fan, et al. Review of knowledge and data-driven primary equipment health management methods[J]. *High Voltage Engineering*, 2024, 50(2): 605-620.
- [80] GOLDSTEIN M, UCHIDA S. A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data[J]. *PLoS One*, 2016, 11(4): e0152173.
- [81] BLASHFIELD R K, ALDENDERFER M S. The literature on cluster analysis[J]. *Multivariate Behavioral Research*, 1978, 13(3): 271-295.
- [82] LIKAS A, VLASSIS N, VERBEEK J J. The global k -means clustering algorithm[J]. *Pattern Recognition*, 2003, 36(2): 451-461.
- [83] KRIEGER H P, KRÖGER P, SANDER J, et al. Density-based clustering[J]. *WIREs Data Mining and Knowledge Discovery*, 2011, 1(3): 231-240.
- [84] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [85] KINGMA D P, WELING M. Auto-encoding variational bayes[C]//*Proceedings of the 2nd International Conference on Learning Representations*. Banff, Canada, 2014.
- [86] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [87] HEARST M A, DUMAIS S T, OSUNA E, et al. Support vector machines[J]. *IEEE Intelligent Systems and Their Applications*, 1998, 13(4): 18-28.
- [88] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533-536.
- [89] BREIMAN L. Bagging predictors[J]. *Machine Learning*, 1996, 24(2): 123-140.
- [90] O'SHEA K, NASH R. An introduction to convolutional neural networks[EB/OL]. arXiv: 1511.08458, 2015[2026-06-24]. <https://arxiv.org/abs/1511.08458>.
- [91] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. *IEEE Transactions on Signal Processing*, 1997, 45(11): 2673-2681.
- [92] WU Z H, PAN S R, CHEN F W, et al. A comprehensive survey on graph neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(1): 4-24.
- [93] VAN ENGELEN J E, HOOS H H. A survey on semi-supervised learning[J]. *Machine Learning*, 2020, 109(2): 373-440.
- [94] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]//*Proceedings of the 5th International Conference on Learning Representations*. Toulon, France: OpenReview.net, 2017.
- [95] RUTHOTTO L, HABER E. An introduction to deep generative modeling[J]. *GAMM-Mitteilungen*, 2021, 44(2): e202100008.
- [96] 韩力, 欧先朋, 高友, 等. 同步发电机励磁绕组匝间短路故障在线分析方法综述[J]. *重庆大学学报*, 2016, 39(1): 25-31.
HAN Li, OU Xianpeng, GAO You, et al. A review on the on-line analysis of inter-turn short circuit faults in field winding of synchronous generators[J]. *Journal of Chongqing University*, 2016, 39(1): 25-31.
- [97] 齐鹏, 李永刚, 马明晗. 抽水蓄能电机转子匝间短路无传感器检测方法[J]. *电工技术学报*, 2024, 39(20): 6431-6443.
QI Peng, LI Yonggang, MA Minghan. Sensorless detection method of rotor inter-turn short circuit in pumped storage motors[J]. *Transactions of China Electrotechnical Society*, 2024, 39(20): 6431-6443.
- [98] WU X, GENG Y F, LI M L, et al. Inter-turn short circuit diagnosis of permanent magnet synchronous motor based on Siamese convolutional neural network under small fault samples[J]. *IEEE Sensors Journal*, 2024, 24(16): 26982-26993.
- [99] JIANG Y T, JI B J, ZHANG J, et al. An overview of diagnosis methods of stator winding inter-turn short faults in permanent-magnet synchronous motors for electric vehicles[J]. *World Electric Vehicle Journal*, 2024, 15(4): 165.
- [100] WALKER D N, ADAMS S L, PLACEK R J. Torsional vibration and fatigue of turbine-generator shafts[J]. *IEEE Transactions on Power Apparatus and Systems*, 1981, PAS-100(11): 4373-4380.
- [101] ZHANG H, ZHANG Q, SHAO S Y, et al. Attention-based LSTM network for rotatory machine remaining useful life prediction[J]. *IEEE Access*, 2020, 8: 132188-132199.
- [102] LIU Y X, SONG B, WANG L N, et al. Power transformer fault diagnosis based on dissolved gas analysis by correlation coefficient-DBSCAN[J]. *Applied Sciences*, 2020, 10(13): 4440.
- [103] 秦潘昊, 陈威宇, 胡秦然, 等. 新型电力系统设备状态监测与故障诊断传感芯片关键技术与展望[J]. *电力系统自动化*, 2024, 48(6): 83-95.
QIN Panhao, CHEN Weiyu, HU Qinran, et al. Key technologies and prospect of equipment condition monitoring and diagnosis sensor chips for new power systems[J]. *Automation of Electric Power Systems*, 2024, 48(6): 83-95.
- [104] SHANG H K, LIU Z D, WEI Y L, et al. A novel fault diagnosis method for a power transformer based on multi-scale approximate entropy and optimized convolutional networks[J]. *Entropy*, 2024, 26(3): 186.
- [105] WANG M H. A novel extension method for transformer fault diagnosis[J]. *IEEE Transactions on Power Delivery*, 2003, 18(1): 164-169.
- [106] WANG Y, ZHAO D, JIA Y G, et al. Acoustic sensors for monitoring and localizing partial discharge signals in oil-immersed transformers under array configuration[J]. *Sensors*, 2024, 24(14): 4704.

- [107] CHAI H, PHUNG B T, MITCHELL S. Application of UHF sensors in power system equipment for partial discharge detection: a review[J]. *Sensors*, 2019, 19(5): 1029.
- [108] LI Y F, GONG C, DENG T, et al. Partial discharge pattern recognition based on swin transformer for power cable fault diagnosis in modern distribution systems[J]. *Processes*, 2025, 13(3): 852.
- [109] JANSSEN A, MAKAREINIS D, SÖLVER C E. International surveys on circuit-breaker reliability data for substation and system studies[J]. *IEEE Transactions on Power Delivery*, 2014, 29(2): 808-814.
- [110] ALSUMAIDAEE Y A M, YAW C T, KOH S P, et al. Review of medium-voltage switchgear fault detection in a condition-based monitoring system by using deep learning[J]. *Energies*, 2022, 15(18): 6762.
- [111] YAN J, WANG Y X, YANG Z, et al. Few-shot mechanical fault diagnosis for a high-voltage circuit breaker via a transformer-convolutional neural network and metric meta-learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3528011.
- [112] ZHUANG Y, HU X T, TANG B, et al. Effects of SF₆ decomposition components and concentrations on the discharge faults and insulation defects in GIS equipment[J]. *Scientific Reports*, 2020, 10(1): 15039.
- [113] LI J W, MA S G, JIN F B, et al. A study on partial discharge fault identification in GIS based on swin transformer-AFPN-LSTM architecture[J]. *Information*, 2025, 16(2): 110.
- [114] MOHAMED F P, SIEW W H, SORAGHAN J J, et al. Remote monitoring of partial discharge data from insulated power cables[J]. *IET Science, Measurement & Technology*, 2014, 8(5): 319-326.
- [115] HUANG X L, WANG X C, QIN H, et al. Research on power cable intrusion identification using a GRT-transformer-based distributed acoustic sensing (DAS) system[J]. *Informatics*, 2025, 12(3): 75.
- [116] SRIVASTAVA R, AVASTHI V, KRISHNA PRIYA R. Deep convolutional neural network for partial discharge monitoring system[J]. *Advances in Engineering Software*, 2023, 180: 103407.
- [117] LI B, CHEN P Y, LI G Z, et al. Fault diagnosis technology overview for lithium-ion battery energy storage station[J]. *IET Energy Systems Integration*, 2024, 6(Supplement1): 684-701.
- [118] CAO R, ZHANG Z J, SHI R W, et al. Model-constrained deep learning for online fault diagnosis in Li-ion batteries over stochastic conditions[J]. *Nature Communications*, 2025, 16(1): 1651.
- [119] 杨梦洁, 杨爱军, 叶奕君, 等. 基于气体分析的锂离子电池热失控早期预警研究进展[J]. *电工技术学报*, 2023, 38(17): 4507-4538. YANG Mengjie, YANG Aijun, YE Yijun, et al. Research progress on early warning of thermal runaway of li-ion batteries based on gas analysis[J]. *Transactions of China Electrotechnical Society*, 2023, 38(17): 4507-4538.
- [120] 王浩, 曹珊珊, 苏俊豪, 等. 基于双包层光纤布拉格光栅传感器的锂电池组温度场监控[J]. *物理学报*, 2022, 71(10): 104207. WANG Hao, CAO Shanshan, SU Junhao, et al. Temperature field monitoring of lithium battery pack based on double-clad fiber Bragg grating sensor[J]. *Acta Physica Sinica*, 2022, 71(10): 104207.
- [121] SUN T, ZHU H, XU Y W, et al. Internal short circuit fault diagnosis for the lithium-ion batteries with unknown parameters based on transfer learning optimized residual network by multi-label data processing[J]. *Journal of Cleaner Production*, 2024, 444: 141224.
- [122] LI T F, ZHAO Z B, SUN C, et al. Domain adversarial graph convolutional network for fault diagnosis under variable working conditions[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3515010.
- [123] 王臻, 刘东, 徐重酉, 等. 新型电力系统多源异构数据融合技术研究现状及展望[J]. *中国电力*, 2023, 56(4): 1-15. WANG Zhen, LIU Dong, XU Chongyou, et al. Status quo and prospect of multi-source heterogeneous data fusion technology for new power system[J]. *Electric Power*, 2023, 56(4): 1-15.
- [124] 李刚, 方鸿, 刘云鹏, 等. 新型电力系统中的大模型驱动技术: 现状、机遇与挑战[J]. *高电压技术*, 2024, 50(7): 2864-2878. LI Gang, FANG Hong, LIU Yunpeng, et al. Large-model drive technology in new power system: status, challenges and prospects[J]. *High Voltage Engineering*, 2024, 50(7): 2864-2878.
- [125] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [126] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA: Curran Associates, 2017: 5998-6008.
- [127] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[C]//*Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*. Minneapolis, USA: Association for Computational Linguistics, 2019: 4171-4186.
- [128] KAPLAN J, MCCANDLISH S, HENIGHAN T, et al. Scaling laws for neural language models[EB/OL]. arXiv: 2001.08361, 2020[2026-06-24]. <https://arxiv.org/abs/2001.08361>.
- [129] WIGGINS W F, TEJANI A S. On the opportunities and risks of foundation models for natural language processing in radiology[J]. *Radiology: Artificial Intelligence*, 2022, 4(4): e220119.
- [130] WEI J, WANG X Z, SCHUURMANS D, et al. Chain-of-thought prompting elicits reasoning in large language models[C]//*Proceedings of the 36th International Conference on Neural Information Processing Systems*. New Orleans, USA: Curran Associates, 2022: 1800.
- [131] LEWIS P, PEREZ E, PIKTUS A, et al. Retrieval-augmented generation for knowledge-intensive NLP tasks[C]//*Proceedings of the 34th International Conference on Neural Information Processing Systems*. Vancouver, Canada: Curran Associates, 2020: 793.
- [132] YAO S Y, ZHAO J, YU D, et al. ReAct: synergizing reasoning and acting in language models[C]//*Proceedings of the 11th International Conference on Learning Representations*. Kigali, Rwanda: Open-Review, 2023: 1-34.
- [133] SCHICK T, DWIVEDI-YU J, DESSÍ R, et al. Toolformer: language models can teach themselves to use tools[C]//*Proceedings of the 37th International Conference on Neural Information Processing Systems*. New Orleans, USA: Curran Associates, 2023: 2997.
- [134] JI Z W, LEE N, FRIESKE R, et al. Survey of hallucination in natural language generation[J]. *ACM Computing Surveys*, 2023, 55(12): 248.
- [135] GU Y, TINN R, CHENG H, et al. Domain-specific language model pretraining for biomedical natural language processing[J]. *ACM Transactions on Computing for Healthcare (HEALTH)*, 2022, 3(1): 2.
- [136] PAN J Z, RAZNIEWSKI S, KALO J C, et al. Large language models and knowledge graphs: opportunities and challenges[J]. *Transactions on Graph Data and Knowledge (TGDK)*, 2023, 1(1): 2: 1-2: 38.
- [137] WEBERSINKE N, KRAUS M, BINGLER J A, et al. ClimateBERT: a pretrained language model for climate-related text[C]//*Proceedings of AAAI 2022 Fall Symposium: the Role of AI in Responding to Climate Challenges*. Arlington, USA: AAAI Press, 2022: 1-9.
- [138] 陈晓红, 傅文润, 刘朝明, 等. 人工智能大模型在电力设备运维场景中的应用探讨[J]. *中国工程科学*, 2025, 27(1): 180-192. CHEN Xiaohong, FU Wenrun, LIU Chaoming, et al. Application of artificial intelligence large language model in power equipment operation and maintenance[J]. *Strategic Study of CAE*, 2025, 27(1): 180-192.
- [139] 唐文虎, 牛哲文, 赵柏宁, 等. 数据驱动的人工智能技术在电力设备状态分析中的研究与应用[J]. *高电压技术*, 2020, 46(9): 2985-2999.

- TANG Wenhui, NIU Zhewen, ZHAO Boning, et al. Research and application of data-driven artificial intelligence technology for condition analysis of power equipment[J]. High Voltage Engineering, 2020, 46(9): 2985-2999.
- [140] 黄济宇, 管霖, 郭梦轩, 等. 图深度学习技术在智能暂态稳定评估中的应用及展望[J]. 电网技术, 2023, 47(4): 1500-1511.
- HUANG Jiyu, GUAN Lin, GUO Mengxuan, et al. Application and prospect of graph deep learning technique in intelligent transient stability assessment[J]. Power System Technology, 2023, 47(4): 1500-1511.
- [141] XIANG J, LI Y Z, ZHANG X Y, et al. Local large language model-assisted literature mining for on-surface reactions[J]. Materials Genome Engineering Advances, 2025, 3(1): e88.
- [142] ABDEL-REHIM A, ZENIL H, ORHOBOR O, et al. Scientific hypothesis generation by large language models: laboratory validation in breast cancer treatment[J]. Journal of the Royal Society Interface, 2025, 22(227): 20240674.
- [143] MORO V, LOH C, DANGOVSKI R, et al. Multimodal foundation models for material property prediction and discovery[J]. Newton, 2025, 1(1): 100016.
- [144] ZHANG C, LV S Y, GONG H J, et al. Inverse design of high-performance piezoelectric semiconductors via advanced crystal representation and large language models[J]. Applied Physics Letters, 2025, 126(11): 111901.
- [145] PYZER-KNAPP E O, MANICA M, STAAR P, et al. Foundation models for materials discovery-current state and future directions[J]. NPJ Computational Materials, 2025, 11(1): 61.
- [146] JIANG X, WANG W R, TIAN S H, et al. Applications of natural language processing and large language models in materials discovery[J]. npj Computational Materials, 2025, 11(1): 79.
- [147] MA T G, WANG H Z, GUO L J. OptoGPT: a foundation model for inverse design in optical multilayer thin film structures[J]. Opto-Electronic Advances, 2024, 7(7): 240062.
- [148] KIM N, LEE D S, YU J B, et al. Toward a robust and generalizable metamaterial foundation model[J]. npj Computational Materials, 2026, 12(1): 54.
- [149] 赵俊华, 文福拴, 黄建伟, 等. 基于大语言模型的电力系统通用人工智能展望: 理论与应用[J]. 电力系统自动化, 2024, 48(6): 13-28.
- ZHAO Junhua, WEN Fushuan, HUANG Jianwei, et al. Prospect of artificial general intelligence for power systems based on large language model: theory and applications[J]. Automation of Electric Power Systems, 2024, 48(6): 13-28.
- [150] MAJUMDER S, DONG L, DOUDI F, et al. Exploring the capabilities and limitations of large language models in the electric energy sector[J]. Joule, 2024, 8(6): 1544-1549.
- [151] YAO Q, FANG F, CHEN Y Y, et al. AI large models for power system: a survey and outlook[J]. IET Smart Energy Systems, 2025, 1(1): 3-21.
- [152] ZHANG X D, SUN W L, CHEN K, et al. A multimodal expert system for the intelligent monitoring and maintenance of transformers enhanced by multimodal language large model fine-tuning and digital twins[J]. IET Collaborative Intelligent Manufacturing, 2024, 6(4): e70007.
- [153] SHI H, FANG L R, CHEN X Y, et al. Review of the opportunities and challenges to accelerate mass-scale application of smart grids with large-language models[J]. IET Smart Grid, 2024, 7(6): 737-759.
- [154] ZHANG S, HUANG Q C, ZHANG Q, et al. ElecBench: a large language model benchmark in electric power domain[J]. Engineering Applications of Artificial Intelligence, 2025, 162: 112310.
- [155] 舒文韬, 李睿潇, 孙天祥, 等. 大型语言模型: 原理、实现与发展[J]. 计算机研究与发展, 2024, 61(2): 351-361.
- SHU Wentao, LI Ruixiao, SUN Tianxiang, et al. Large language models: principles, implementation, and development[J]. Journal of Computer Research and Development, 2024, 61(2): 351-361.
- [156] GUI J, CHEN T, ZHANG J, et al. A survey on self-supervised learning: algorithms, applications, and future trends[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 9052-9071.
- [157] YANG L, ZHANG Z L, SONG Y, et al. Diffusion models: a comprehensive survey of methods and applications[J]. ACM Computing Surveys, 2024, 56(4): 105.
- [158] ZHANG S Y, DONG L F, LI X Y, et al. Instruction tuning for large language models: a survey[J]. ACM Computing Surveys, 2026, 58(7): 169.
- [159] PLAAT A, WONG A, VERBERNE S, et al. Multi-step reasoning with large language models, a survey[J]. ACM Computing Surveys, 2026, 58(6): 160.
- [160] WANG L P, CHEN S, JIANG L N, et al. Parameter-efficient fine-tuning in large language models: a survey of methodologies[J]. Artificial Intelligence Review, 2025, 58(8): 227.



HE Cheng
Ph.D.

Associate professor



ZHANG Chuanji
Ph.D.

Corresponding author



LI Hongbin
Ph.D., Professor



CHENG Shijie
Ph.D., Professor
CAS member

何 成

1989—, 男, 博士, 副研究员

主要从事计算智能及电气智能感知技术的研究, 将进化计算、机器/深度学习应用于电力量测设备状态评估

E-mail: chenghe_sece@hust.edu.cn

张传计(通信作者)

1992—, 男, 博士, 助理研究员

主要从事电气信息检测、高压电气设备状态感知技术研究

E-mail: chuanjizhang@hust.edu.cn

李红斌

1967—, 女, 博士, 教授, 博导

主要从事强电磁环境下的复杂电信号测量研究

E-mail: lihongbin@hust.edu.cn

程时杰

1945—, 男, 博士, 教授, 博导, 中国科学院院士
主要从事电力系统自动化与电力储能的研究, 率先在国内倡导并积极推进电工材料以及储能技术在电力系统中的应用研究

E-mail: sjcheng@hust.edu.cn

收稿日期 2026-02-06 修回日期 2026-08-26 编辑 曹昭君