电气自动化中的人工智能技术应用与效能评估

张冬阳

中广核核电运营有限公司　广东　深圳　518124

摘　要：人工智能与电气自动化的融合正推动控制系统从规则驱动向数据驱动转变。本文梳理了机器学习、深度学习、强化学习及知识图谱在电气自动化中的应用场景，涵盖故障诊断、预测性维护、自适应控制、智能巡检等方向，并构建了从技术性能、经济效益和工程适用性三个维度的效能评估体系。AI 技术能有效提升故障识别准确率与系统自适应能力，运维效率提升显著。本文还分析了数据质量、模型泛化及可解释性等制约因素，并对发展趋势进行了展望。

关键词：电气自动化；人工智能；故障诊断；预测性维护；效能评估

引言：电气自动化是工业生产的核心支撑技术，传统控制系统依赖精确数学模型和专家经验整定规则，在处理非线性、强耦合、大时滞等复杂工况时存在显著局限。以深度学习、强化学习为代表的人工智能技术取得突破性进展，为电气自动化赋予了数据驱动的感知、认知与决策能力。在智能制造和能源数字化转型驱动下，AI 应用正从试验验证加速迈入工程落地阶段，在设备监测、过程优化和系统调度等方向取得显著成效。本文从应用场景出发，系统梳理关键技术路径，构建面向工程实践的效能评估体系，为技术选型与工程决策提供参考。

1 人工智能技术与电气自动化的融合基础

1.1 电气自动化系统的智能化需求

电气自动化系统的核心任务是对电能生产、传输、分配和利用各环节的设备和过程进行监测、控制与优化。传统自动化系统已实现基于 PLC、DCS 和 SCADA 的可靠控制，但在以下场景中暴露出能力不足：设备退化趋势难以提前预判，导致非计划停机频发；复杂工业过程的控制参数整定依赖人工经验，难以适应工况波动；大量巡检数据、运行日志和故障记录未被有效利用，数据价值未充分释放。人工智能技术的引入，可使系统从“预设逻辑执行”向“自主感知—智能决策—持续进化”的能力跃升。

1.2 面向电气自动化的人工智能技术谱系

应用于电气自动化领域的人工智能技术主要包括四类：机器学习（含深度学习）用于从历史数据中建立输入—输出映射关系，适用于负荷预测、故障识别和设备寿命预测等任务；强化学习通过与环境的试错交互学习最优控制策略，适用于电力系统调度、电压无功控制等序贯决策问题；知识图谱将设备参数、故障模式、操作规程等结构化知识进行关联推理，适用于故障诊断辅助决策；计算机视觉用于设备外观检测、表计读数识别和作业安全监控[1]。各类技术在实际应用中常组合使用，形成“感知—诊断—决策—执行”的智能化闭环。

1.3 融合的技术架构

人工智能赋能电气自动化的技术架构自下而上分为四层。感知层通过智能传感器、边缘计算设备实现多源数据的实时采集与预处理；数据层依托时序数据库和数据中台实现海量运行数据的存储、治理与特征工程；算法层提供机器学习建模、模型训练与部署的工程框架，支持多种算法的快速迭代与对比；应用层面向具体业务场景（如设备诊断、优化控制、智能巡检）封装 AI 能力，以 API 或微服务形式供上层系统调用。该架构强调数据闭环和模型持续优化机制，是 AI 能力在电气自动化场景中有效落地的基础保障。

2 人工智能在电气自动化中的典型应用

2.1 设备故障诊断与预测性维护

设备故障诊断和预测性维护是人工智能在电气自动化领域应用最成熟、成效最显著的方向。传统阈值报警和定期检修模式存在“报而不预、修而不精”的缺陷，AI 技术通过分析设备振动、电流、温度、电压等多维监测数据，构建健康状态评估模型和剩余寿命预测模型。在变压器故障诊断中，基于深度信念网络（DBN）或卷积神经网络（CNN）的油中溶解气体分析可将故障识别准确率提升至 95%以上，较传统三比值法提高约 20 个百分点。在电机轴承诊断中，一维 CNN 或长短时记忆网络

（LSTM）对振动信号的时频域特征进行自适应提取，可提前数百小时预警潜在故障。预测性维护通过构建设备退化曲线，将维修策略从“到期必修”升级为“状态预知、按需维护”，使非计划停机减少 50%—70%，维护成本降低 20%—35%。

2.2 智能控制与过程优化

智能控制是将 AI 嵌入实时控制回路的关键方向，旨在解决传统 PID 控制在非线性、时变、强耦合系统中控制品质下降的问题。模糊逻辑控制将人工操作经验规则化，在电厂主汽温控制、水泥窑煅烧等大惯性过程应用中控制精度较传统 PID 提高 30% 以上。神经网络控制通过对系统动态特性的在线学习实现模型自适应，适用于负载频繁波动的电机调速系统。强化学习在电力系统优化调度中展现出独特优势。深度 Q 网络（DQN）和近端策略优化（PPO）算法可在高维状态空间和复杂约束条件下学习近似最优决策策略[2]。典型应用包括微电网能量管理、电动汽车充电负荷调度和新能源场站有功无功协调控制。与传统优化算法相比，强化学习可在毫秒级完成在线决策，对不确定性和动态变化具有良好的适应能力。

2.3 智能巡检与视觉检测

计算机视觉技术的成熟使电气设备的智能巡检成为可能。利用安装在固定点位或搭载于无人机、机器人上的高清摄像头，结合目标检测（YOLO、FasterR-CNN）和语义分割算法，可自动完成以下任务：变电站仪表读数识别，识别准确率超过 98%；设备外观异常检测（如绝缘子破损、套管漏油、连接点过热变色）；红外热成像自动分析，定位电气连接点异常温升；高压输电线路的鸟巢、异物悬挂识别。相比人工巡检，AI 视觉巡检的效率提升 5—10 倍，可覆盖人工难以到达的危险和狭窄区域。

2.4 电力负荷预测与能源管理

精准的电力负荷预测是发电计划制定、电力市场交易和电网安全运行的基础。传统时间序列方法（如 ARIMA）难以捕捉负荷的复杂非线性特征和多重影响因素。深度学习模型如 LSTM、门控循环单元（GRU）和 Transformer 通过建模历史负荷、气象数据、日期类型等多因素之间的复杂映射，24 小时负荷预测平均绝对百分比误差可控制在 2%—4%，较传统方法降低 30%—50%。在新能源发电预测方面，CNN 与 LSTM 的组合模型对光伏和风电功率的短期预测精度提升显著，为高比例新能源接入下的电网调度提供了有效支撑。

3 人工智能应用的效能评估方法

3.1 效能评估指标体系

建立科学的效能评估体系是指导 AI 技术选型和投资决策的前提。本文提出“技术性能—经济效益—工程适用性”三维评估框架。技术性能维度包括：预测准确率/精确率/召回率/F1 值、模型推理延迟、模型更新频率、泛化误差（训练集与测试集性能差距）等。经济效益维度包括：故障停机损失减少量、维护成本降低率、人力替代率（以人时计）、能耗节约率、投资回收期等。工程适用性维度包括：数据可得性与质量要求、模型可解释性、部署难度（依赖第三方库及硬件要求）、系统集成工作量、运维人员接受度等。每个指标根据应用场景赋予不同权重，最终形成综合评分。

3.2 评估流程与实施方法

AI 效能评估应贯穿项目全生命周期。事前评估（可行性阶段）重点评估数据条件是否满足建模需求、目标场景是否存在明确的性能基线对比、预期收益是否覆盖投入成本。事中评估（开发部署阶段）采用 A/B 测试或影子模式（即新模型与旧系统并行运行但不输出控制指令，仅对比输出差异）验证模型性能，关注指标包括在线准确率、推理延迟、资源占用率等。事后评估（运行维护阶段）关注长期稳定性、模型漂移程度和实际经济效益是否达到预期，建立定期复评和模型再训练机制。评估数据的获取应避免“自评自证”，建议引入第三方历史数据或公开基准数据集进行横向对比[3]。对于分类任务，重点报告混淆矩阵和 PR 曲线而非仅依赖准确率单指标；对于回归任务，同时报告 MAE、RMSE 和 MAPE 多个误差指标。

3.3 典型场景的效能数据

综合公开文献和行业调研数据，各典型应用场景的效能表现如下。变压器故障诊断：准确率 92%—97%，较传统方法提升 15—25 个百分点，漏报率低于 3%。预测性维护：非计划停机减少 50%—70%，备件库存周转率提升 30%。强化学习优化控制：系统响应时间缩短 20%—40%，目标跟踪误差降低 25%—45%。视觉智能巡检：单站巡检时间从 2 小时缩短至 15 分钟，缺陷检出率从 75%提升至 95%以上。负荷预测：MAPE 为 2%—4%，预测精度提升 30%—50%，对应燃煤电厂可降低煤耗 0.5—1.5g/kWh。上述数据表明，AI 技术在电气自动化各方向均能带来可量化的显著增益，但具体数值高度依赖数据质量、工况条件和模型工程化水平，实际应用中应审慎参考、因地制宜。

4 工程落地的主要制约因素

4.1 数据质量与获取成本

AI 模型的效果高度依赖训练数据的数量、质量和代表性。电气自动化场景中的数据困境表现在：故障样本稀缺（高压设备几十年不发生一次严重故障，正常样本远多于故障样本），导致模型对罕见故障的学习不充分；数据标注依赖领域专家，标注成本高且一致性难以保证；不同工况、不同厂家设备的数据分布差异大，跨场景泛化能力不足。解决路径包括：利用生成对抗网络进行少数类样本增强、引入迁移学习从相关领域借力、推动行业数据共享联盟建设等。

4.2 模型泛化能力与可解释性

深度学习模型的“黑箱”特性在安全等级要求高的电气应用中受到严重制约。运维人员难以接受“模型认为设备将要故障但无法解释依据”的判断。模型在不同季节、不同负荷区间的性能衰减（即泛化不足）也可能导致误报或漏报，造成经济损失或安全隐患。解决方案包括：采用 SHAP（Shapley 加法解释）等可解释性工具进行特征归因分析；在关键决策环节保留人工复核机制；对模型进行定期的分布漂移检测和增量学习更新[4]。

4.3 工程部署的系统性挑战

AI 算法从实验环境到工业现场的“最后一公里”依然困难重重。算力方面：深度学习模型对 GPU 等加速硬件的依赖增加了边缘侧部署的难度和功耗，推理延迟可能无法满足实时控制需求（毫秒级）。集成方面：AI 模块需要与现有 DCS/SCADA 系统对接，涉及工业通信协议转换、数据接口标准化和网络安全防护等系统性问题。运维方面：模型性能随时间下降（即概念漂移），需要建立持续监控和再训练机制，但多数企业缺少专业的数据科学家团队。建议采用“云端训练—边缘推理”的架构，将计算密集型任务上移云端，实时推理下沉至边缘侧，兼顾精度与实时性。

5 发展趋势与展望

5.1 大模型与多模态融合

以 Transformer 架构为代表的大模型正在向电气自动化领域渗透。预测性维护领域的时序大模型通过对海量设备运行数据的预训练，有望实现“一个模型适配多类设备”的通用故障诊断能力。多模态融合技术将振动信号、红外热像、可见光图像、油化数据等多种异构信息联合分析，可大幅提升状态感知的全面性和诊断结论的可靠性，是未来智能运维的重要方向。

5.2 边缘智能与轻量化部署

为满足实时控制和数据隐私保护的需求，AI 模型正向边缘侧下沉。模型压缩技术（如剪枝、量化、知识蒸馏）使轻量级神经网络能在嵌入式设备和工业边缘网关（如 AI 加速盒）上高效运行，推理延迟可控制在毫秒级。同时，联邦学习允许多个边缘节点在不共享原始数据的前提下协同训练全局模型，在保障数据隐私的同时提升模型泛化能力，尤其适用于跨厂区的电力设备联合建模场景。

5.3 自主进化与知识融合

下一代电气智能系统将具备持续学习与自主进化能力。基于元学习的“学会学习”机制使系统能够在面对新设备、新工况时快速适应，无需大规模重新训练。知识图谱与深度学习的融合则为模型注入物理约束和领域先验，使预测结果更符合工程实际，同时提升可解释性。最终形态是“AI+ 机理”混合驱动模型——以物理方程和领域知识为骨架，以数据驱动参数为补充，实现既符合物理规律又具有自适应性。

结束语

本文系统梳理了人工智能在电气自动化领域的典型应用与效能表现。研究表明，AI 在设备故障诊断、预测性维护、智能控制、视觉巡检及负荷预测等方向已具备显著工程价值，故障识别准确率可达 95%以上，运维效率提升 40%—60%。未来，大模型赋能通用诊断、边缘智能支持实时响应、知识融合增强可解释性将是主要发展方向。AI 与电气自动化的融合正从“技术验证”迈向“经济验证”，构建系统化效能评估方法并降低落地门槛，是推动规模化应用的关键路径。

参考文献

[1] 李虎. 人工智能技术在电气自动化控制系统中的应用 [J]. 科技与创新，2026(14)：70-73.

[2] 周平阳. 人工智能技术在电气自动化控制系统中的应用研究 [J]. 今日自动化,2026(4):117-119.

[3] 祁永强. 人工智能技术在电气自动化控制领域中的应用实践研究 [J]. 科技资讯,2026,24(5):84-86.

[4] 刘敏涛. 人工智能技术在电气自动化控制中的应用研究 [J]. 中国高新科技,2025(5):19-20,23.