

数据驱动的人工智能技术在电力设备状态分析中的应用

唐文虎, 牛哲文, 赵柏宁, 季天瑶, 李梦诗, 吴青华

(华南理工大学电力学院, 广州 501641)

摘要: 电力设备作为电力系统的基本要素, 其运行状态对电网的安全经济运行有直接影响。随着电力物联网的建设和智能传感器技术的不断发展, 电力设备运行状态的相关信息呈现出多源、异构的数据特征。研究以海量多源异构数据为驱动的基于人工智能技术的设备状态分析方法, 对于全面、及时、准确地掌握电力设备运行状态及其发展趋势有重要意义。论文首先介绍了基于数据驱动的新一代人工智能技术; 然后, 以当前电力设备状态数据所呈现的海量、多源异构的特性为出发点, 针对图像、文本、时序这 3 种数据类型综述了基于人工智能的电力设备状态特征提取技术; 其次, 通过研究当前电力设备状态分析的总体需求, 总结和讨论了数据驱动的人工智能技术在电力设备智能巡检、故障诊断、状态预测等典型业务场景中的应用研究现状; 最后, 探讨了现阶段数据驱动的人工智能技术在电力设备状态分析中面临的挑战性问题, 并对相关技术的发展趋势进行了展望。

关键词: 人工智能; 电力设备; 数据驱动; 状态分析; 图像识别; 故障诊断

Research and Application of Data-driven Artificial Intelligence Technology for Condition Analysis of Power Equipment

TANG Wenhui, NIU Zhewen, ZHAO Boning, JI Tianyao, LI Mengshi, WU Qinghua

(School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China)

Abstract: As an essential element of power systems, power equipment has a direct impact on the safe and economic operations of power systems. With the continuous development of power internet of things and smart sensor technology, the information of power equipment operating states exhibits characteristics of multi-source and heterogeneous data. The analysis method for equipment conditions based on the implementation of artificial intelligence (AI) driven by massive multi-source heterogeneous data is of great significance for comprehensive, timely and accurate mastery of the operational status of power equipment. In this paper, the data-driven AI technology is introduced firstly. Secondly, based on the massive and multi-source heterogeneous characteristics presented in equipment operation data, the feature extraction methods based on the data-driven AI technology are discussed for three data types: image, text and time series. Thirdly, according to the analysis of the overall demand for power equipment condition assessment, the implementation status of the data-driven AI technology in typical business scenarios, such as smart inspection, fault diagnosis and condition prediction of power equipment, is summarized and discussed. Finally, the key challenges of the data-driven AI technology for condition assessment of power equipment are investigated, and the trend of technology development in this research field is explored.

Key words: artificial intelligence; power equipment; data-driven; condition assessment; image recognition; fault diagnose

0 引言

电力设备的良好运行状态是电力系统安全稳定运行的基础, 设备故障引发的停电事故会严

重影响电网的稳定运行, 并造成巨大的经济损失^[1]。因此, 对于运行在复杂工况与恶劣环境的设备, 全面、及时、准确地对设备运行状态进行监测与分析是保障设备安全稳定运行的重中之重。随着电力系统智能化程度的不断提高, 电力设备状态分析存在着设备种类多、数量大、状态类型多样化等挑战, 面临的问题集中表现在以下几个方面^[2]:

1) 信息系统分散, 数据结构复杂多样。大量

基金资助项目: 国家重点研发计划(2018YFE0208400); 国家自然科学基金(51977082); 中央高校基本科研业务费专项资金(x2dl-D2181850)。
Project supported by National Key R&D Program of China (2018YFE0208400), National Natural Science Foundation of China (51977082), Fundamental Research Funds for Central Universities (x2dl-D2181850).

电力设备数据分散于不同的信息平台或系统,缺乏统一的渠道收集和融合分析,数据交互共享存在壁垒。数据类型包括文本、音频、图像、视频等多种结构,数据的异构性会影响设备的状态分析和评估泛化,从而导致设备状态综合分析准确性较低,分析的置信度与效率也较低。

2) 传感器技术和通信技术的快速发展与数据处理能力瓶颈之间的矛盾。随着传感器的广泛安装,电力设备持续产生海量的状态监测数据,而传统的数据分析算法难以应对日益堆积的待处理数据。

3) 难以建立运行状态精细化评估及预测的物理模型。传统电力设备状态分析通常基于机理建模,通过理论分析、机理解释等手段建立相应的因果模型。但是电力设备运行工况复杂,影响因素众多,因此精确的因果关系建模难度较大。

4) 依赖于人工与专家判断,且诊断标准单一。运行数据复杂多样背景下,人工决断存在主观性较大、效率较低的问题,难以综合分析大量设备数据。由于人工经验有限,诊断标准多采用参数计算和阈值判断,在多工况下不同厂家设备的适应性不足。

随着电力物联网的建设与发展,大量传感器和测量设备投入使用,电网的运行数据、设备的监测数据、外部环境数据等剧增,逐渐形成了体量大、类型多、结构复杂的电力大数据体^[3]。目前,电力设备智能状态分析技术实施的主要矛盾已转化为日益增长的状态数据分析需求与传统方法处理维度、效率不匹配、不平衡之间的矛盾。以深度学习为代表的人工智能技术在基于数据驱动的海量数据深度挖掘及高维特征提取方面有着显著的优势。将数据驱动的人工智能技术引入到电力设备状态分析中,会为上述矛盾的解决提供了一种全新的思路^[4]。

人工智能的复兴与发展给传统电力设备状态分析难题带来了新的分析理念和技术途径。人工智能技术尤其是深度学习在众多领域,如图像检测、音频信号处理、数据分析等的应用中,取得了令人瞩目的成效^[5-7]。人工智能技术巨大的经济和科技潜力使其逐渐上升至国家发展战略层面,欧美等国家相继颁布了大数据相关的研究和发 展计划^[8],中国于 2013 年—2017 年相继发布了《中国电力大数据发展白皮书》^[9]、《促进大数据发展行动纲要》^[10]、《新一代人工智能发展规划》^[11]与《促进新一代人工智能产业发展三年行动计划(2018—2020 年)》^[12]等多个重要文件,确立了人工智能技术的发展地位

和战略价值,电力系统的运维、市场等各领域正在迈向人工智能时代。

本文在当前“互联网+”、“万物互联”、电力大数据的时代背景下^[13],从基于数据驱动的人工智能技术体系研究和应用现状出发,介绍了数据驱动的人工智能技术的主要分类,在此基础上对不同数据类型和结构的状态信息特征提取方法和关键技术进行了总结。接着,综述了电力设备状态分析典型场景中新一代人工智能技术的应用和优势,探讨了现阶段人工智能技术在电力设备状态分析中面临的关键共性问题,并对相关技术的发展趋势进行了展望。

1 数据驱动的人工智能技术概述

人工智能是计算机科学中以机器为载体的智能形式,是融合了数学、统计学、概率、逻辑、伦理等多学科于一身的交叉学科,其基本思路是在相应的环境中采取行动以使达到目标的成功机率最大化^[14]。机器学习是数据驱动的人工智能技术的核心研究方向,主要基于经验和历史数据,能够不断自动改进算法在解决任务过程中的性能。当前应用广泛的机器学习方法包括传统机器学习、深度学习、强化学习、迁移学习等。数据驱动的人工智能技术研究与应用已从浅层的传统机器学习模型逐渐发展至当前以深度学习为代表的新一代机器学习技术,大大提升了电力设备状态分析的准确性和高效性。本章概述了基于数据驱动的人工智能技术在电力设备状态分析中的典型应用,重点介绍了以深度学习为代表的驱动人工智能技术的发展现状。

1.1 传统机器学习

根据学习数据对应分类标签的有无,传统机器学习可分为监督学习、无监督学习和半监督学习,相应的典型算法如表 1 所示。为了应对单个学习模型无法精确估计、泛化能力差等缺点,集成学习通过训练一组基本学习器,然后利用模型的不同特点,按照策略组合结果,进一步提高了传统机器学习的泛化能力。典型的集成学习算法包括 Stacking、随机森林、Bagging、Boosting 等^[15]。其中基于 Stacking^[16]的集成学习框架如图 1 所示。

1.2 深度学习

深度学习是人工智能技术连接主义学派的代表,起源于对人工神经网络的研究。深度学习方法是一类具有多隐层的自动从原始数据中挖掘规律的算法,通过组合各类非线性模块来构建深层网络模

表 1 传统机器学习典型算法

Table 1 Typical algorithms for traditional machine learning method

类型	典型算法
监督学习	决策树 ^[17] (decision trees, DT)
	支持向量机 ^[18] (support vector machine, SVM)
	K 近邻算法 ^[19] (K-nearest neighbor, KNN)
	随机森林 ^[20] (random forest, RF)
	反向传播神经网络 ^[21] 等(back-propagation neural network, BP ANN)
无监督学习	K 均值聚类 ^[22] (K-means clustering, KMS)
	自组织映射神经网络 ^[23] (self-organizing map, SOM)
	主成分分析 ^[24] 等(principal component analysis, PCA)
半监督学习	转导支持向量机 ^[25] (transductive support vector machine, TSVM)
	半监督核均值漂移聚类 ^[26] 等(semi-supervised kernel mean shift clustering, SKMSC)

型。这些非线性模块从原始输入开始, 将人工神经网络每层的特征提炼为更高、更抽象的属性^[27], 较高的隐层会放大输入中对输出有重要影响的方面, 同时会抑制不相关的变化。深度学习通过逐层抽象提取和逐层迭代来实现深层次特征的学习。

当前具有代表性的深度学习网络包括: 卷积神经网络^[28](convolutional neural network, CNN)、深度置信网络^[29](deep belief network, DBN)、堆叠自编码器^[30](stacked auto-encoder, SAE)、长短期记忆网络^[31](long short-term memory, LSTM)、受限玻尔兹曼机^[32](restricted Boltzmann machine, RBM)和生成式对抗网络^[33](generative adversarial network, GAN)等。图 2 为典型深度置信网络的结构示意图。

1.3 强化学习

强化学习^[34]是行为主义学派将控制论引入机器学习的代表, 又称再励学习、评价学习, 其本质是智能体根据环境来制定决策以使累积奖赏最大化。在不断迭代和循环的过程中, 强化学习通过环境反馈奖惩值, 使智能体的决策不断优化直至达到平衡。强化学习不需要输入输出精确匹配, 相比于其他机器学习算法而言, 该方法具有更强大的在线学习能力。强化学习算法主要面向离散状态和行为空间的马尔可夫决策过程(Markov decision process, MDP), 目的是实现评价体系决策的连续优化。强化学习的理论研究包括时序差分学习和表格型强化学习收敛性、泛化方法^[35]。强化学习算法研究的代表为 Q 学习^[36]、深度 Q 网络^[37]、Sarsa 方法^[38]等。DeepMind 团队提出了基于深度神经网络(deep




图 1 基于 Stacking 的集成学习框架

Fig.1 Framework of ensemble learning based on Stacking




图 2 典型深度置信网络结构

Fig.2 Typical structure of deep belief networks

neural network, DNN)与强化学习的深度强化学习(deep reinforcement learning, DRL)。DRL 结合了深度学习的感知能力和强化学习的决策能力, 形成了人工智能技术领域新的研究热点, 其算法结构如图 3 所示。

1.4 迁移学习

迁移学习的核心是通过分析已有模型与目标模型直接的关系, 将机器在一个场景中学习到的知识迁移到新场景的应用中, 模拟了人类通过学习有限知识和技能来解决新问题的能力^[39]。迁移学习允许在训练和测试中使用不同的数据域, 大大提高了样本训练效率, 并能有效缩短新模型的训练时间和改善算法性能, 进而提升了模型和学习算法的泛化能力, 可应用于解决小样本学习和个性化问题。模型间可迁移项主要分为样本迁移、特征迁移、参数模型迁移和关系迁移这 4 种。迁移学习的类型包括归纳式迁移学习、传递式迁移学习和无监督迁移学

习，典型的迁移学习算法包括 TrAdaBoost^[40] (transfer adaptive boosting)、CoCC^[41] (co-clustering based classification) 和自我学习^[42] (seft-taught learning) 等。

2 数据驱动的人工智能技术在电力设备状态分析中的应用

随着电力物联网的建设和不断发展，相关设备的监测手段日益丰富，电力设备运行状态的监测信息呈现出多源、异构的数据特征。以深度学习为代表的驱动的人工智能技术，在应对数据特征不明显、具有关联性的多维异构数据时，具有良好的非线性拟合能力。本章对数据驱动的人工智能技术在电力设备状态分析中的应用现状进行总结和分析，其应用的基本技术路线如图 4 所示。

2.1 基于人工智能的电力设备状态特征提取技术

电力设备状态信息具有数据来源广泛、体量庞大、类型异构多样和关联复杂等特点，对海量多源异构数据的特征提取的效果决定了数据分析的有效性和准确性。运用人工智能技术，从数据内在规律分析的角度挖掘出对电力设备状态评估、故障诊断、状态预测等有价值的知识，从而为设备智能运维和电网优化运行提供有力支撑。本节主要阐述以深度学习、强化学习和迁移学习为代表的驱动人工智能技术在电力设备运行状态特征提取中的应用。

2.1.1 电力设备运维数据的主要来源与特征

电力设备数据是评估设备状态的基础，根据电力设备状态信息的更新频率，可将设备状态数据分为 3 类：静态数据、动态数据和准动态数据。静态数据主要包括设备台帐、铭牌参数、投运前试验数据、地理位置等；动态数据通常按分钟、小时或天为周期更新，主要包括设备在线监测数据、运行数据、巡检记录、带电检测数据、环境气象数据等；准动态数据通常按月或年定期或不定期更新，主要包括故障缺陷数据、检修试验数据、设备隐患记录、检修记录等。电力设备状态数据的来源如表 2 所示。

随着电力系统信息化平台采集数据的大量累积，电力设备运维状态数据所呈现的主要特征如下^[9,43-44]：

- 1) 数据体量大，增长速度快。电力设备类型多，数量庞大。另一方面，随着在线监测传感器的大量部署，状态监测数据体量的增长趋势愈发明显。
- 2) 设备数据来源广泛。随着数字化电网的不断发展，电力设备状态监测系统、能量管理系统、




图 3 深度强化学习算法结构

Fig.3 Flowchart of deep reinforcement learning algorithm

表 2 电力设备状态的主要数据来源

Table 2 Main data sources of power equipment condition

种类	数据源
静态数据	铭牌参数、设备台账、投运前实验数据、地理位置等
动态数据	在线监测数据、设备运行数据、设备巡检记录、带电检测数据、环境气象数据等
准动态数据	故障缺陷和检修试验数据、设备隐患记录、检修记录等

地理信息系统及气象信息系统等电力信息化平台逐步完善并广泛应用，使得电力设备运行状态数据的相关信息来源更加广泛，数据模型、格式和接口也更加多样。

3) 数据类型异构多样。设备数据的异构性主要表现在数据结构的多样化上，除去结构化数据外，还包括如文本记录、音频数据、局部放电图谱、红外图像、巡线图像、监控视频、频响和波形曲线等在内的大量半结构化和非结构化数据。这些异构的设备状态数据中包含了大量电力设备实时运行信息和检修维护历史数据，从中可以挖掘电力设备局部过热、局部放电、机械特性受损等故障状态特征。

2.1.2 针对电力设备运维状态的文本信息挖掘

电力设备长期运维过程中产生了大量周期性巡视日志、设备缺陷或故障日志以及检修运维报告，这些文本数据中蕴含了结构化数据之外的电力设备各种故障或缺陷状态信息。然而，在工作票、操作票、检修试验记录等文本数据中，夹杂了大量数字、字母符号，从而加大了关键信息提取和分析的难度^[45]。

针对文本信息特征提取的问题，首先需要将文本按照段、句、词、标点符号等进行划分，然后运用对照表将文本数据转化为计算机编码形式，接着再进行关键词、句的提取。文献[46]构建了基于语

义框架的电力设备缺陷文本知识图谱, 能够从缺陷语料中自动提取实体并进行关系抽取和关系筛选, 实现了对文本浅层特征的提取。针对传统机器学习方法存在的数据处理与特征提取能力不足等问题^[47], 文献[48]运用长短期记忆神经网络分析变压器分类模型提取事件句的深层语义特征, 有效提取了词前后长距离的依赖特征, 为非结构化数据提供了更有效的分析方法。文献[49]通过构建端到端的卷积神经网络网络结构, 实现了特征提取与分类评估两部分的有机统一, 可直接面向底层进行语义分析, 体现了深度学习的显著优势和效率上的可行性。

2.1.3 电力设备图像的特征识别

随着电力设备运行状态监测过程中高清视频监控和红外热成像检测技术的逐渐成熟^[50-51], 及无人机、巡视机器人的广泛应用, 电力系统中的图像信息呈现多样化爆炸性增长^[52]。人工筛选和分析已经无法满足日益增长价值密度低、体量大的电力设备图像分析需求。传统的图像识别算法仅能提取设备图像的形状、方向和颜色等浅层特征, 识别泛化能力较弱, 难以挖掘图像的丰富内涵信息, 从而影响了电力设备智能化巡检的准确率。而数据驱动的人工智能技术能够有效克服人工筛选的主观性、模糊性和不确定性, 并能够充分挖掘图像数据的深层特征。当前, 电力设备图像数据的特征挖掘方法主要针对图像分割、图像识别和语义分割这 3 个关键技术问题。

在图像分割方面, 由于电力设备图像背景的复杂性, 图像分割技术首先把输入图像划分为统一的非重叠区域, 从而将电力设备从干扰背景中剥离开

来, 有效提高了后续电力设备状态评估的准确性。图像分割的典型技术属于无监督聚类算法, 例如 K-means 聚类算法、模糊 C 均值(fuzzy C-means, FCM)聚类算法等。K-means 聚类是一种硬聚类算法, 具有较低的计算复杂度, 它使用欧几里得或余弦距离将图像分层, 能够有效剔除非关联数据^[53]。FCM 聚类算法属于软聚类算法, 对图像中存在的不确定性具有较好的描述能力, 将其运用在电力设备红外图像分析中可以实现温度特征提取^[54], 通过改进可避免局部最优和初始值敏感的缺点^[55], 从而提高图像分割的准确性。文献[56]以形态学运算的多尺度 Harr 小波变换以及逆变换系数矩阵为特征, 对复杂环境下覆冰绝缘子图像进行分割, 克服了图像背景、光照和清晰度等对绝缘子覆冰状况检测的不利影响。

在图像识别方面, 图像特征提取方法大致可分为人工设计的特征提取算法和基于深度网络的特征提取方法。其中, 前者使用人工设计的算法来提取图像中选定的特征, 如方向梯度直方图、尺度不变特征变换等。文献[57]利用梯度直方图、颜色特征来进行不同环境下绝缘子状态的检测。文献[58]通过多层感知机对设备图像的位置关联特征和局部轮廓特征进行提取, 实现了对绝缘子故障识别。文献[59]通过融合全局和局部信息特征来检测图像梯度的方式, 实现了无人机航拍视频中输电线的定位。然而, 由于电力设备具有不同的电压等级, 部件间联系关系多种多样, 且外部环境复杂多变, 因此传统的人工设计特征提取方法难以满足需求。深度学习的多层结构能够对图像特征进行逐层提取, 具备




图 4 数据驱动的人工智能技术在电力设备状态分析中的典型应用

Fig.4 Typical applications of data-driven artificial intelligence technology for power equipment condition analysis

复杂非线性建模、深层特征自动提取和表达能力。文献[60]通过卷积神经网络来提取变压器等电力设备图像的特征,检验结果表明,与人工提取的特征相比,深层图像特征的表达能力更强,可以获得高识别准确率。文献[61]提出了一种基于CNN和霍夫变换的输电线航拍图像特征提取方法。文献[62]通过对改进的区域卷积网络(Faster-region-CNN, Faster-RCNN)网络框的重新设计,构造了一种多角度的电力设备红外图像识别方法,为解决不同拍摄角度下电力设备图像特征的分析问题提供了可行的思路。

语义分割技术对图像数据深层特征识别提出了更高的要求,它需要区分电力设备图像中的每一个像素点,并在语义上理解每个像素点的角色^[63]。常规的语义分割方法主要是通过聚类、搜索匹配等方法来实现的,受分割样本的影响较大,不同数据样本和匹配方法将导致不同的语义分割结果。深度学习的发展为语义分割提供了新的方法。文献[64]和文献[65]分别通过空间卷积神经网络(spatial-CNN, SCNN)和Faster R-CNN对绝缘子串进行语义分割,以提取多个深层的故障特征,从而提高诊断的准确率。文献[66]构造了一种基于全卷积神经网络的语义分割方法,实现了航拍图像中绝缘子、塔杆、金具等关键部件的有效分割。文献[67]结合点卷积和空洞卷积的上采样结构,提出一种多信息融合的实时语义分割模型,该模型在移动端应用中取得了良好的效果。

2.1.4 电力设备时空数据的特征挖掘

电力设备传感器记录的数据组成了时空大数据,其特点为兼具时间和空间相关性,且两者不可分割^[68]。传统方法对于时空数据的处理往往存在着难以兼顾数据的时空关系与因果关系、忽视多维时空数据间的关联性问题。

以深度学习为代表的人工智能技术借助其强大的非线性函数拟合与逼近能力,能够有效捕捉和学习高维时空数据中的隐含规律,并且能够结合自主训练和特有的信息传递方式,实现多维时间序列中相关性地自适应学习。文献[69]利用支持向量机(support vector machine, SVM)分类器通过堆叠式稀疏自动编码器(sparse stacked autoencoder, SSAE)训练后,将PCA应用于特征识别,运用混淆矩阵实现具有从输电线路运维数据中挖掘特征进行可视化和分类的能力。文献[70]基于动态亚当和压差的深度

神经网络对电力变压器多维数据集进行故障特征提取和模式识别,该数据驱动方法可用于解决变压器内部绝缘难以直接检测和分析的难题。文献[71]采用一种具有最近序列记忆的Q学习算法实现对时间序列数据的特征挖掘。文献[72]提出了一种深度迁移强化学习算法,该算法通过对历史时间序列的有效信息进行知识存储,利用深度学习实现高精度的非线性迁移学习,并借助分布式计算优势,可快速获得高质量的最优解。

2.2 电力设备状态智能分析的典型应用场景

以大数据为驱动的基于人工智能的电力设备状态分析技术,有助于全面、及时、准确地掌握电力设备的运行状态及发展趋势。与此同时,全方位、精细化的状态预测与故障识别结果可为电力设备运维决策提供更加可靠的科学依据,从而进一步完善电力设备的运维状态管理体系。本节针对电力设备状态分析的3个主要应用场景,对基于数据驱动的人工智能技术的典型应用场景进行了总结和分析。

2.2.1 基于图像识别的电力设备智能巡检

常规的电力设备状态巡检方法一般是通过人工方式对电力设备进行定期的巡视和排查,如输电线路的人工巡检、变电站的人工巡视等。然而常规的人工巡检方法存在诸多问题^[73-75]:1)巡检人员的工作安全系数不高,大部分巡检设备常处于带电工作状态,且电压等级较高,因此巡检人员的工作安全难以得到保证;2)人工巡检容易受到主观判断的影响,且需要深厚的专业领域知识;3)人工巡检需要巡检人员用肉眼对电力设备的状态进行识别判断,巡检过程容易受到天气环境等诸多外部因素的干扰,巡检效率不高且巡检人员的工作强度较大。近年来,随着智能化设备在电力系统中的普及以及“互联网+智慧能源”项目的开展^[76],国家电网和南方电网均开始采用无人机、机器人等先进技术手段来代替人工方式开展电力设备的智能巡检。智能巡检将采集回来的大量图像数据实时地传输到监控后台,再由监控中心工作人员根据图像或视频中的外观对设备的运行状态进行评估。然而,由于数据量庞大,人工识别的效率不高且工作量巨大。

随着深度学习技术的不断发展,越来越多的研究人员开始采用深度学习对电力巡检影像进行分析和处理。电力深度视觉旨在采用深度学习技术对无人机、机器人采集回来的海量图像数据进行分析^[77],从而识别设备类型、异常运行状况,内外部缺陷

等, 进而实现电力设备的无人化智能巡检。通过人工智能技术对电力设备状态识别是实现电力设备智能巡检和诊断的首要步骤。图 5 展示了基于深度学习的电力设备状态智能化识别的典型流程: 首先对采集到的海量数据进行降噪、滤波、归一化等预处理, 剔除异常数据和“脏”数据; 然后分析待识别的设备形态特征, 对数据样本进行标签化处理得到训练集; 接着在公共数据集下对深度学习模型进行预训练, 再使用标记好的训练集对模型进行微调和改进; 最后将机器人、无人机等采集到的巡检测试图像传入微调后的模型, 进而获得识别结果。在此过程中, 图像采集^[78]、图像预处理^[79]方法均与传统方法无太大差异, 故在此不做展开。电力设备状态智能识别的核心在于采用深度学习分析框架对目标的特征进行提取与挖掘, 从而实现目标的有效检测^[80]。

目前, 基于深度学习的电力设备图像识别方法主要分为 2 大类: 一类是双阶法, 首先构造深度卷积神经网络对目标进行特征提取, 然后运用传统图像分割定位方法完成目标检测^[60,81-83], 如尺度不变特征转换(scale-invariant feature transform, SIFT)、Fast-RCNN、Faster-RCNN。文献[84]建立了一种基于改进 SIFT 与随机森林的隔离开关运行状态检测识别方法, 通过 SIFT 对隔离开关特征进行预提取, 再利用随机森林构建的分类器模型对三相隔离开关的运行状态进行精确识别。文献[85]构造了一种基于 Faster-RCNN 的输变电设备红外图像异常发热点目标检测方法, 该方法可以从较为复杂的检测背景中以较高的准确率将红外图像中的异常发热故障点识别定位出来; 随后, 作者还研究了不同置信度阈值对识别准确率的影响, 并通过实验验证了设定恰当的置信度阈值对于平衡故障点的漏检测和误检测概率具有重要意义。文献[86]通过建立多标记的电力巡检图像样本库, 提出了一种基于改进型 Faster-RCNN 的输电线路巡检图像多目标检测及定位模型, 并将其用于改进网络参数的学习效果; 同时, 通过正则化优化模型结构加快检测的速度, 进而提高巡检图像目标检测的工程实用性。基于 Faster RCNN 的巡检红外图像设备识别与定位结果如图 6 所示。

另一类为单阶法, 该类方法是将特征提取、边框定位、目标分类融合为一个网络, 构建一种端到端的训练模式, 从而有效地减少图像特征提取过程中的重复计算, 如 YOLO(you only look once)、SSD




图 5 电力设备状态智能分析的典型流程

Fig.5 Flowchart of intelligent condition inspection for power equipment




图 6 基于 Faster RCNN 的巡检红外图像设备识别与定位

Fig.6 Identification and location for power equipment infrared images using Faster RCNN

(single shot multibox detector)等。文献[87]利用 YOLO V3 算法, 并借鉴 Faster-RCNN 中的 anchor box 机制, 利用 K-means 算法在数据集上得到合适的 anchor box 个数和初始尺寸, 并将 anchor box 作为先验框来预测目标的边界框, 使得改进后的网络在识别螺栓和破损导线等较小目标时具有较高的准确率和良好的实时性。文献[88]提出了一种基于 YOLO V3 算法的输电线路鸟类检测方法, 并依据检测结果判断是否启动超声波驱鸟器; 考虑到检测目标通常比较小, 且经常出现多目标聚集的情况, 该方法对原 YOLO V3 算法的特征提取网络结构进行了改进; 此外, 为了提升运算速率, 保证任务的实时性, 模型中仅提取 2 组多尺度特征对鸟类位置和类别进行预测, 从而适应特定的输电线路鸟类检测任务。

当前国内外研究中, 将电力设备图像的深度视觉算法与机器人、无人机自动巡检相结合的工程实践刚刚起步, 但是已经取得了较好的成果。随着小微电力传感器的普及和电力物联网的构建, 数据驱动下的电力设备图像深度视觉无疑将为智能化巡检提供新的思路, 以深度学习算法为核心驱动力, 基于海量电力图像数据的智能识别工作方式, 将成为电力设备智能化巡检的主流技术方向之一。

2.2.2 基于多模异构数据的电力设备故障智能诊断

电力设备故障诊断旨在对已发生故障或存在

征兆的潜伏性故障进行故障种类识别、故障定位、故障严重等级判定。准确的故障诊断有利于运维人员制定有针对性的运维策略,从而有效防止设备运行状态进一步恶化^[73]。传统的故障诊断方法主要利用既定的阈值公式和专家经验综合分析来判定。以电力变压器为例,传统故障诊断方法主要通过局部放电、油中溶解气体等相关试验指标参量,采用横向纵向比较和阈值判断等分析方法对设备故障进行诊断^[89-90]。但是,由于电力设备故障类型繁多、故障机理复杂,且电力设备所处的环境会对故障判断产生干扰,因此传统方法的诊断结果较为泛化,缺乏针对性^[91]。结合电力大数据分析与人工智能技术的电力设备故障智能诊断成为近年的研究热点。

电力设备故障智能诊断方法主要包括 2 类:一类是由贝叶斯网络^[92]、支持向量机^[93]、决策树^[94]、随机森林^[95]、神经网络^[96]等为核心算法的传统机器学习方法;另一类是以卷积神经网络、循环神经网络、深度置信网络、自动编码器为核心算法的深度学习方法^[97]。相比于传统机器学习方法,深度学习方法在故障特征提取、学习能力,以及对海量数据和高维数据的处理中有着明显的优势。文献[98]利用深度堆栈自编码器从发电机励磁电流信号中提取故障特征,然后借助支持向量机对故障特征进行分类,从而完成对发电机故障的准确诊断。文献[99]通过分析油色谱特征气体与故障类型的关联度,建立了基于修正线性单元深度信念网络的电力变压器故障诊断模型。文献[100]采用深度置信网络对电力变压器的多维数据进行特征提取及分类,并结合 Dempster-Shafer 证据理论描述故障诊断中的不确定性因素,构造了电力变压器故障诊断的多级决策融合模型。文献[101]利用深度置信网络对弹簧操动机构断路器的断路器触头磨损、非同期合闸、局部放电等故障进行了诊断。文献[102]在风力发电机等设备的机械故障诊断中,利用 GAN 生成的数据与实际数据比对,提高了故障类型判断的准确率。文献[103]基于连续小波变换和卷积神经网络,构造了一种用于解决特征和分类器选择问题的方法,该方法可以准确地检测出故障馈线。文献[104]提出了一种“自适应神经-模糊”配电变压器故障诊断方法,可以在有限数据集下取得较好的诊断效果。

除此之外,随着小微智能传感器、物联网和工业互联网技术的推广和使用,电力设备状态采集数据逐渐从单一的结构化数据演变为以图像、文本、

音频等为主的非结构化数据。因此,通过基于数据驱动的电力设备故障智能诊断技术分析状态监测所采集到的数据,实现电力设备全方位多角度的全景状态监测和故障诊断,是当前的行业热点研究方向。文献[105]将故障时域信号数据转换成二维灰度图像来提取转换后的图像特征,提高了轴承故障诊断的效率和准确性。文献[106]提出了一种基于频率响应二值化图像的绕组变形故障诊断方法,利用数字图像处理技术获得了图像相关度诊断指标和判据,从而实现了电力变压器的绕组故障的诊断。文献[107]在分析归纳传统文本挖掘模型的局限性及电力变压器运维文档特点的基础上,构造了一种基于深度语义学习的变压器运维文档信息挖掘方法,对变压器运维过程中产生的工作票等文本信息进行了深入分析。文献[108]以电力设备故障案例为研究对象,引入双向 LSTM 提取事件文档语句的深层语义特征,实现了故障文本中故障因果关系的自动提取。电力设备运行过程中引起的机械振动会产生规律性的运行声音,当运行状态或运行结构发生改变时,其振动特性或部分频段内的振动能量将会发生改变,同时会伴随刺耳或不协调的异常声音^[109],利用数据驱动的人工智能技术对电力设备音频信号进行分析和特征挖掘,能够有效提高电力设备故障诊断的准确率。文献[110]利用理性扩张小波变换技术处理声学信号以提取电动机故障特征,实现了对三相感应电动机的故障诊断;文献[111]提出一种基于动态时间规整的电力设备故障检测方法,能够有效分离混音频信号,并对故障信号进行识别;文献[112]针对变压器噪声信号,利用加权和 PCA 算法得到改进的音频特征,并通过矢量量化对故障类型进行识别。

综上,基于数据驱动人工智能技术的电力设备故障诊断技术可以充分利用运维过程的在线监测、智能巡检和运维中的多模异构数据,从底层数据中挖掘设备的故障运行状态特征,有助于提升故障诊断的准确率。但是电力设备故障频率低、故障集数据量小且缺乏完备性,导致模型的泛化能力大大降低且易出现故障诊断偏差等问题,因此需要将电力设备故障机理与物理特性作为深度学习模型训练的辅助输入信息,以此来克服模型泛化能力低的难题。

2.2.3 基于深度学习的电力设备运行状态预测

电力设备运行状态预测是从现有的运行状态数据出发,结合预测对象的检测信息、设备特点、

运行工况及历史记录等, 从时间序列中挖掘规律进而对设备未来的状态进行分析及预测。传统的电力设备状态预测主要利用单一或少数检测参量, 通过构建分析模型来挖掘时间序列中的隐含规律, 从而推断时间序列的发展趋势。

当前, 电力设备运行状态预测的模型主要分为统计分析模型和学习模型。统计分析模型主要包括时间序列分析^[113]、回归分析^[114]和灰色模型^[115], 统计分析模型可以快速地对设备状态做出预测, 但其在长期预测场景中准确度较低。学习模型的核心在于通过智能算法来拟合输入数据与输出数据之间的非线性关系。学习模型的典型代表包括支持向量机^[116]、神经网络^[117]、极限学习机^[118]等机器学习模型。此外, 许多学者引入集成学习的技术思路, 将数据预处理方法、模型参数优化方法、模型预测方法集成于单个模型来进一步提高设备状态预测的准确性, 取得了优良的效果^[119-120]。然而, 传统机器学习方法对长时间序列的处理能力较弱, 面对特征性不明显且关联性较强的高维数据时收敛能力欠佳, 故传统的学习模型仅能利用电力设备状态监测量本身的信息, 而不能计及众多相关因素(如故障率、健康指数、环境因素等)的影响。

深度学习旨在构建更深层的网络结构, 从而加强模型在海量数据中捕捉其隐含特征的能力。与传统的浅层神经网络相比, 深度学习具有优秀的非线性函数拟合能力, 因而在处理特征性不明显且关联性较强的多维数据时有着显著的优势。因此, 以深度学习算法为核心的电力设备状态预测方法得到了众多研究人员的关注。文献[121]以变压器油中溶解气体的浓度为预测对象, 通过经验模态分解方法将气体浓度序列划分为一组平稳的子序列, 并利用 LSTM 网络对各个子序列进行特征提取后再叠加, 以达到提高预测准确性的目的。此外, 考虑到从单一参量或少量信息挖掘故障状态与表现特征之间的客观规律上存在一定的片面性, 无法保障模型稳定性和预测的科学性, 文献[122]将电网运行数据、变电站环境气象数据、设备在线监测数据作为输入特征, 构建了基于栅格 LSTM 的变压器状态参量预测方法, 对复杂变量之间的关联关系进行深度挖掘, 用该模型预测的稳定性和准确度均有所提升。文献[123]在电力系统故障前的动态安全评估中, 利用 GAN 生成的预测数据, 弥补了向量测量单元(phasor measurement unit, PMU)采集数据不足的缺

陷, 有效提高了故障预测的有效性。文献[124]利用 LSTM 提取线路数据的时空特征后使用 SVM 对配电线路跳闸故障进行预测, 并证明该方法的鲁棒性有一定的提升。

3 挑战与展望

随着人工智能技术在电力设备运维状态分析中的逐步应用, 电力设备状态分析方法已从传统“统计分析+专家诊断”的分析模式逐渐转变为具有设备、场景针对性的数据驱动分析模式。数据驱动人工智能技术的引入为解决电力大数据背景下的设备状态分析难题提供了新思路和新方法^[125], 但现阶段数据驱动人工智能技术在电力设备状态分析领域中的应用仍处于起步阶段, 还存在诸多亟待解决的技术问题。笔者认为数据驱动人工智能技术在电力设备状态分析研究领域的发展过程中, 还有如下技术难点值得讨论和关注。

3.1 数据集问题

基于数据驱动的人工智能技术核心在于通过训练来挖掘和学习海量数据中的数据特征及隐含规律, 它对于数据的规模和质量均有较高的要求。尽管随着带电检测、在线监测、智能巡检技术的推广应用, 电力设备状态监测数据已经得到了大量扩充, 但这些数据仍存在以下问题:

1) 数据质量难以保证。电力设备的运行环境复杂, 其数据源的物理分布较为广泛, 在数据传输过程中, 由于通讯干扰造成的数据重复、异常及缺失的现象时有发生, 这些“脏数据”会严重影响设备状态分析结果的准确性, 并增加数据“清洗”的难度。在未来电力设备状态分析数据库的建设过程中, 一方面应制定一系列数据处理及数据质量评价标准, 以提升数据的可用性和易用性; 另一方面, 对数据的预处理方法应当结合具体的状态分析模型和设备特征, 从而避免为规整数据而进行盲目的“清洗”。

2) 数据的互通共享问题。电力设备状态数据的来源涉及多业务部门和数据平台, 数据结构复杂、种类繁多、时间尺度跨度大, 且不同数据平台之间的数据传输格式不统一, 因此难以实现跨平台数据的交互共享。而如何满足电力设备状态分析所需要的多源异构数据需求是一个比较关键的问题, 需要研究规范不同地点、类型和功能数据库传输接口、降低网络传输延时, 实现不同部门、系统、平台之

间无障碍数据传输与存储方式的方法,从而为电力设备状态分析提供充分的数据保障。例如,有研究者提出在设备环境数据与设备运行数据之间建立实时更新一致性关联^[2],以解决多源数据之间一致性难以协调统一的问题。

3) 数据集分类不平衡问题。以深度学习为核心的人工智能算法需要训练集的各类之间具有相对均衡的数量分布,以保证深度学习网络的学习和泛化能力。然而,电力设备数量虽然庞大,但故障及异常状态的样本相对较少,且以往对故障及异常状态的信息记录缺乏针对性,因此造成了数据训练集的类不平衡的问题。针对数据类不平衡的问题,一方面需要将电力设备状态分析数据库的建设过程融入到日常巡检的过程中,在电力设备缺陷管理及数据处理相关标准的指导下完成数据的处理与入库;另一方面,要研究相应的数据集增强技术,如以GAN为核心的无监督学习方法,其最大的特点是深度网络提供一种对抗训练的方式,而此方式有助于解决一些监督学习中缺乏大量样本标签的问题。

3.2 数据驱动人工智能技术应用的局限性

3.2.1 人工智能技术尚缺乏理论层面的支撑

基于数据驱动的人工智能技术虽然在智能性、准确性上要比传统状态分析模型更有优势,但以深度学习为主的人工智能技术实质为黑箱模型,尚缺乏数学理论支撑,电力设备所具有的通用运行机理及专家经验还无法在人工智能模型中体现。因此,应进一步研究将设备运行的机理、物理规律和专家经验融入人工智能算法的方法,从而实现知识分析与数据挖掘的深度融合。加强数据驱动与物理驱动方法相融合可从以下3个方面展开:

1) 探究根据电力设备的运行机理、物理规律或专家知识对黑箱模型输入数据进行调整的方法,如将设备物理模型的运行参数、偏微分方程的权重等作为黑箱模型或是人工智能算法输入的数据预处理指导法则。

2) 探索将专家经验转化为黑箱模型在训练过程中的方向指导和限制条件,如指导网络结构、超参数、激活函数的选择,设定相应的正则化惩罚以限制模型的收敛走向等。

3) 尝试利用数据驱动方法的学习结果对传统物理数学模型和经验公式的超参数及阈值进行修正、补充完善和验证。

3.2.2 宏观泛化能力不足

当前的人工智能分析方法对某类特定设备的单一状态信息具有较好的分析和学习能力,但仅能够在局部层面对设备某部件、某故障类型做出准确的分析和判断,缺乏一定的泛化协调能力。以人工智能技术为核心算法的电力设备状态分析更倾向于辅助决策的作用,因此需要进一步探究如何整合现有分析评估技术,建立多方法融合的电力设备状态数据分析框架。

3.2.3 快速响应问题

电力设备的运行状态变化频繁、运行工况各异,要求状态分析模型具有一定的快速响应能力和在线实时处理能力。由于当前电力设备运行状态数据呈现多源异构的特性,而人工智能技术在处理图像、音频等庞大的数据时会耗费大量的计算时间,故难以满足某些毫秒级实时在线处理的需求。因此,未来仍需研究如何在有限时间尺度内做出快速响应。一方面,可将一、二次设备融合技术与边缘计算技术相结合,将数据感知、状态分析、设备动作融合到智能传感设备中,将传感器与深度学习芯片整合,从而实现电力设备运行状态的准确分析和就地动作;另一方面,可通过电力设备云后台^[125]预先完成对多种设备故障的算法训练,并利用物联网将判断依据下放到边缘计算设备中,从而提高状态分析算法的响应速度。

4 结论

1) 当前以数据驱动的人工智能技术为核心的电力设备运维状态分析还处于起步和探索阶段,初步研究表明,在电力大数据背景下,人工智能技术可以有效提高电力设备状态分析的准确性,在电力设备智能巡检、故障诊断、状态预测等应用场景下均展现了良好的应用效果。

2) 以深度学习为核心的人工智能技术在处理图像、音频、文本等非结构化数据中已经展现出了优异的特征挖掘和泛化能力,可以有效解决电力设备运维状态数据中非、半结构化数据难以有效利用的问题,可为实现多模异构状态数据分析奠定基础。

3) 由于受到数据集、智能算法本身以及应用场景等多重客观因素的限制,当前电力设备状态智能分析尚处于“专家系统宏观判断+人工智能辅助决策”的初级阶段。未来,仍需探究如何整合和改进现有的设备状态评估方法,并结合大数据技术和智能化数据分析平台,进而提供有效的数据增值服务。

参考文献 References

- [1] 江秀臣, 盛戈峰. 电力设备状态大数据分析的研究和应用[J]. 高电压技术, 2018, 44(4): 1041-1050.
JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition[J]. High Voltage Engineering, 2018, 44(4): 1041-1050.
- [2] 李 刚, 张 博, 赵文清, 等. 电力设备状态评估中的数据科学问题: 挑战与展望[J]. 电力系统自动化, 2018, 42(21): 10-20, 177.
LI Gang, ZHANG Bo, ZHAO Wenqing, et al. Data science issues in state evaluation of power equipment: challenges and prospects[J]. Automation of Electric Power Systems, 2018, 42(21): 10-20, 177.
- [3] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(4): 180-197.
ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems, 2019, 43(4): 180-197.
- [4] 刘云鹏, 许自强, 李 刚, 等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术, 2019, 45(2): 337-348.
LIU Yunpeng, XU Ziqiang, LI Gang, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers[J]. High Voltage Engineering, 2019, 45(2): 337-348.
- [5] 万晓琪, 宋 辉, 罗林根, 等. 卷积神经网络在局部放电图像模式识别中的应用[J]. 电网技术, 2019, 43(6): 2219-2226.
WAN Xiaoqi, SONG Hui, LUO Ling, et al. Application of convolutional neural networks in pattern recognition of partial discharge image[J]. Power System Technology, 2019, 43(6): 2219-2226.
- [6] 陈艺璇, 张孝顺, 郭乐欣, 等. 基于多智能体迁移强化学习算法的电力系统最优碳-能复合流求解[J]. 高电压技术, 2019, 45(3): 863-872.
CHEN Yixuan, ZHANG Xiaoshun, GUO Lexin, et al. Optimal carbon-energy combined flow in power system based on multi-agent transfer reinforcement learning[J]. High Voltage Engineering, 2019, 45(3): 863-872.
- [7] 牛哲文, 余泽远, 李 波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备, 2018, 38(5): 36-42.
NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting using deep gated recurrent unit networks[J]. Electric Power Automation Equipment, 2018, 38(5): 36-42.
- [8] KALIL T. Big data is big deal[EB/OL]. Washington, DC, USA: the White House, 2012[2012-03-29]. <https://obamawhitehouse.archives.gov/blog/2012/03/29/big-data-big-deal>.
- [9] 中国电机工程学会电力信息化专业委员会. 中国电力大数据发展白皮书[M]. 北京: 中国电力出版社, 2013.
Chinese Society for Electrical Engineering. The white paper on the development of big data on china electric[M]. Beijing, China: China Electric Power Press, 2013.
- [10] 国务院. 促进大数据发展行动纲要[EB/OL]. 北京: 国务院, 2015[2018-09-14]. http://www.gov.cn/zhengce/content/2015-09/05/content_10137.htm.
The State Council. To promote the development of big data[EB/OL]. Beijing, China: The State Council, 2015[2018-09-14]. http://www.gov.cn/zhengce/content/2015-09/05/content_10137.htm.
- [11] 国务院. 新一代人工智能发展规划[EB/OL]. 北京, 中国: 国务院, 2017[2017-07-20]. http://www.gov.cn/zhengce/content/2017-07/20/content_5211996.htm.
The State Council. Development planning of new generation artificial intelligence[EB/OL]. Beijing, China: The State Council, 2017[2017-07-20]. http://www.gov.cn/zhengce/content/2017-07/20/content_5211996.htm.
- [12] 工业和信息化部. 促进新一代人工智能产业发展三年行动计划(2018—2020 年)[EB/OL]. 北京, 中国: 工业和信息化部, 2017[2017-12-13]. <http://www.miit.gov.cn/n1146295/n1652858/n1652930/n3757016/c5960820/content.html>.
Ministry of industry and information. Three year action plan to promote the development of new generation artificial intelligence industry(2018—2020)[EB/OL]. Beijing, China: Ministry of industry and information, 2017[2017-12-13]. <http://www.miit.gov.cn/n1146295/n1652858/n1652930/n3757016/c5960820/content.html>.
- [13] 鞠 平, 周孝信, 陈维江, 等. “智能电网+”研究综述[J]. 电力自动化设备, 2018, 38(5): 2-11.
JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. "Smart Grid Plus" research overview[J]. Electric Power Automation Equipment, 2018, 38(5): 2-11.
- [14] RUSSELL S J, NORVIG P. Artificial intelligence: a modern approach[M]. Malaysia: Pearson Education Limited, 2016: 2-3.
- [15] LI L, HU Q, WU X, et al. Exploration of classification confidence in ensemble learning[J]. Pattern Recognition, 2014, 47(9): 3120-3131.
- [16] WOLPERT D H. Stacked generalization[J]. Neural Networks, 1992, 5(2): 241-259.
- [17] QUINLAN J R. Induction of decision trees[J]. Machine Learning, 1986, 1(1): 81-106.
- [18] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [19] PETERSON L E. K-nearest neighbor[J]. Scholarpedia, 2009, 4(2): 1883.
- [20] BREIMAN L. Random forest[J]. Machine Learning, 2001, 45(1): 5-32.
- [21] 邓万宇, 郑庆华, 陈 琳, 等. 神经网络极速学习方法研究[J]. 计算机学报, 2010, 33(2): 279-287.
DENG Wanyu, ZHENG Qinghua, CHEN Lin, et al. Research on extreme learning of neural networks[J]. Chinese Journal of Computers, 2010, 33(2): 279-287.
- [22] HARTIGAN J A, WONG M A. Algorithm AS 136: a k-means clustering algorithm[J]. Journal of the Royal Statistical Society. Series C (Applied Statistics), 1979, 28(1): 100-108.
- [23] KOHONEN T. The self-organizing map[J]. Proceedings of the IEEE, 1990, 78(9): 1464-1480.
- [24] SCHÖLKOPF B, SMOLA A, MÜLLER K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299-1319.
- [25] CHEN Y, WANG G, DONG S. Learning with progressive transductive support vector machine[J]. Pattern Recognition Letters, 2003, 24(12): 1845-1855.
- [26] ANAND S, MITTAL S, TUZEL O, et al. Semi-supervised kernel mean shift clustering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 36(6): 1201-1215.
- [27] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [28] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 66(6): 84-90.
- [29] 仇怡超, 闻 达, 王晓茹, 等. 基于深度置信网络的电力系统扰动后频率曲线预测[J]. 中国电机工程学报, 2019, 39(17): 5095-5104.
ZHANG Yichao, WEN Da, WANG Xiaoru, et al. A method of frequency curve prediction based on deep belief network of post-disturbance power system[J]. Proceedings of the CSEE, 2019, 39(17): 5095-5104.
- [30] 胡天宇, 郭庆来, 孙宏斌. 基于堆叠去相关自编码器和支持向量机的窃电检测[J]. 电力系统自动化, 2019, 43(1): 119-125.

- HU Tianyu, GUO Qinglai, SUN Hongbin. Nontechnical loss detection based on stacked uncorrelating autoencoder and support vector machine[J]. Automation of Electric Power Systems, 2019, 43(1): 119-125.
- [31] 朱乔木, 李弘毅, 王子琪, 等. 基于长短期记忆网络的风电场发电功率超短期预测[J]. 电网技术, 2017, 41(12): 3797-3802.
- ZHU Qiaomu, LI Hongyi, WANG Ziqi, et al. Short-term wind power forecasting based on LSTM[J]. Power System Technology, 2017, 41(12): 3797-3802.
- [32] FISCHER A, IGEL C. An introduction to restricted Boltzmann machines[C]//Iberoamerican Congress on Pattern Recognition. Berlin, Germany: Springer, 2012: 14-36.
- [33] 王守相, 陈海文, 潘志新, 等. 采用改进生成式对抗网络的电力系统量测缺失数据重建方法[J]. 中国电机工程学报, 2019, 39(1): 56-64.
- WANG Shouxian, CHEN Haiwen, PAN Zhixin, et al. A reconstruction method for missing data in power system measurement using an improved generative adversarial network[J]. Proceedings of the CSEE, 2019, 39(1): 56-64.
- [34] KAEHLING L P, LITTMAN M L, MOORE A W. Reinforcement learning: a survey[J]. Journal of Artificial Intelligence Research, 1996, 4: 237-285.
- [35] WIERING M, VAN OTTERLO M. Reinforcement learning[J]. Adaptation, Learning, and Optimization, 2012(12): 3.
- [36] WATKINS C J C H, DAYAN P. Q-learning[J]. Machine Learning, 1992, 8(3/4): 279-292.
- [37] VAN HASSELT H, GUEZ A, SILVER D. Deep reinforcement learning with double Q-learning[C]//Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, USA: AAAI, 2016: 2094-2100.
- [38] VELUSAMY B, ANOUNCIA S M, ABRAHAM G. SaGe framework-mapping of SARSA to adaptive e-learning using learning styles[J]. International Journal of Engineering & Technology, 2013, 5(2): 2306-2314.
- [39] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 22(10): 1345-1359.
- [40] AL-STOUHI S, REDDY C K. Adaptive boosting for transfer learning using dynamic updates[C]//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin, Germany: Springer, 2011: 60-75.
- [41] DAI W, XUE G R, YANG Q, et al. Co-clustering based classification for out-of-domain documents[C]//Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Jose, USA: ACM, 2007: 210-219.
- [42] DAI W, YANG Q, XUE G R, et al. Self-taught clustering[C]//Proceedings of the 25th International Conference on Machine Learning. Helsinki, Finland: ACM, 2008: 200-207.
- [43] 张东霞, 苗新, 刘丽平, 等. 智能电网大数据技术发展研究[J]. 中国电机工程学报, 2015, 35(1): 2-12.
- ZHANG Dongxia, MIAO Xin, LIU Liping, et al. Research on development strategy for smart grid big data[J]. Proceedings of the CSEE, 2015, 35(1): 2-12.
- [44] 廖瑞金, 王有元, 刘航, 等. 输变电设备状态评估方法的研究现状[J]. 高电压技术, 2018, 44(11): 3454-3464.
- LIAO Ruijin, WANG Youyuan, LIU Hang, et al. Research status of condition assessment method for power equipment[J]. High Voltage Engineering, 2018, 44(11): 3454-3464.
- [45] 邵冠宇, 王慧芳, 何奔腾. 电网设备缺陷文本的质量评价与提升方法[J]. 电网技术, 2019, 43(4): 1472-1479.
- SHAO Guanyu, WANG Huifang, HE Benteng. Quality assessment and improvement method for power grid equipment defect text[J]. Power System Technology, 2019, 43(4): 1472-1479.
- [46] 刘梓权, 王慧芳. 基于知识图谱技术的电力设备缺陷记录检索方法[J]. 电力系统自动化, 2018, 42(14): 158-164.
- LIU Ziquan, WANG Huifang. Retrieval method for defect records of power equipment based on knowledge graph technology[J]. Automation of Electric Power Systems, 2018, 42(14): 158-164.
- [47] 邱剑, 王慧芳, 应高亮, 等. 文本信息挖掘技术及其在断路器全寿命状态评价中的应用[J]. 电力系统自动化, 2016, 40(6): 107-112, 118.
- QIU Jian, WANG Huifang, YING Gaoliang, et al. Text mining technique and application of lifecycle condition assessment for circuit breaker[J]. Automation of Electric Power Systems, 2016, 40(6): 107-112, 118.
- [48] WEI D, WANG B, LIN G, et al. Research on unstructured text data mining and fault classification based on RNN-LSTM with malfunction inspection report[J]. Energies, 2017, 10(3): 406.
- [49] 刘梓权, 王慧芳, 曹靖, 等. 基于卷积神经网络的电力设备缺陷文本分类模型研究[J]. 电网技术, 2018, 42(2): 644-650.
- LIU Ziquan, WANG Huifang, CAO Jing, et al. A classification model of power equipment defect texts based on convolutional neural network[J]. Power System Technology, 2018, 42(2): 644-650.
- [50] 何立夫, 陆佳政, 刘毓, 等. 输电线路山火可见光-红外多光源精准定位技术[J]. 高电压技术, 2018, 44(8): 2548-2555.
- HE Lifu, LU Jiazheng, LIU Yu, et al. Precise positioning technology of wild fire nearby transmission lines by visible and infrared vision[J]. High Voltage Engineering, 2018, 44(8): 2548-2555.
- [51] 廖韵凯. 变电所遥视监控系统研究[J]. 自动化技术与应用, 2010, 29(1): 104-106.
- LIAO Yunkai. Remote video-monitoring and controlling system in substation[J]. Techniques of Automation and Applications, 2010, 29(1): 104-106.
- [52] 李军锋. 基于深度学习的电力设备图像识别及应用研究[D]. 广州: 广东工业大学, 2018.
- LI Junfeng. Research on electric equipment image recognition and its application based on deep learning[D]. Guangzhou, China: Guangdong University of Technology, 2018.
- [53] MOHD M R S, HERMAN S H, SHARIF Z. Application of K-means clustering in hot spot detection for thermal infrared images[C]//2017 IEEE Symposium on Computer Applications & Industrial Electronics. Langkawi, Malaysia: IEEE, 2017: 107-110.
- [54] WANG B, KANG L, ZHANG S. Research on fuzzy clustering image segmentation algorithm based on GA and gray histogram[C]//2015 3rd International Conference on Machinery, Materials and Information Technology Applications. Qingdao, China: Atlantis Press, 2015: 550-555.
- [55] PENG X, LIN Y, ZHANG L H. An improved PSO-FCM algorithm for image segmentation[C]//IOP Conference Series: Earth and Environmental Science. Guangzhou, China: IOP Publishing, 2019, 267(4): 042081.
- [56] 冯玲, 黄新波, 朱永灿. 基于图像处理的输电线路覆冰厚度测量[J]. 电力自动化设备, 2011, 31(10): 76-80.
- FENG Ling, HUANG Xinbo, ZHU Yongcan. Transmission line icing thickness measuring based on image processing[J]. Electric Power Automation Equipment, 2011, 31(10): 76-80.
- [57] ZHAI Y, WANG D, ZHANG M, et al. Fault detection of insulator based on saliency and adaptive morphology[J]. Multimedia Tools and Applications, 2017, 76(9): 12051-12064.
- [58] LIU Y, LI J, XU W, et al. A method on recognizing transmission line structure based on multi-level perception[C]//International Conference on Image and Graphics. Shanghai, China: Springer, 2017: 512-522.

- [59] LI Z, HAYWARD R, WALKER R, et al. A biologically inspired object spectral-texture descriptor and its application to vegetation classification in power-line corridors[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(4): 631-635.
- [60] 李军锋, 何双伯, 冯伟夏, 等. 基于改进 CNN 的增强现实变压器图像识别技术[J]. 现代电子技术, 2018, 41(7): 29-32.
LI Junfeng, HE Shuangbai, FENG Weixia, et al. Improved CNN based transformer image recognition technology in augmented reality environment[J]. Modern Electronics Technique, 2018, 41(7): 29-32.
- [61] PAN C, CAO X, WU D. Power line detection via background noise removal[C]//IEEE Global Conference on Signal and Information Processing. Washington, DC, USA: IEEE, 2017: 871-875.
- [62] GONG X, YAO Q, WANG M, et al. A deep learning approach for oriented electrical equipment detection in thermal images[J]. IEEE Access, 2018, 6: 41590-41597.
- [63] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [64] SAMPEDRO C, RODRIGUEZ-VAZQUEZ J, RODRIGUEZ-RAMOS A, et al. Deep learning-based system for automatic recognition and diagnosis of electrical insulator strings[J]. IEEE Access, 2019, 7: 101283-101308.
- [65] LEI X, SUI Z. Intelligent fault detection of high voltage line based on the Faster R-CNN[J]. Measurement, 2019, 138: 379-385.
- [66] 赵振兵, 李胜利, 戚银城, 等. 一种改进 FCN 的输电线路航拍图像语义分割方法[J]. 中国科技论文, 2018, 13(14): 1614-1620.
ZHAO Zhenbing, LI Shengli, QI Yincheng, et al. An improved FCN semantic segmentation method for aerial transmission line image[J]. China Sciencepaper, 2018, 13(14): 1614-1620.
- [67] 周晨轶, 王 文, 卢 杉, 等. 基于多层信息融合的实时语义分割及其在电力场景中的应用[J]. 计算机与现代化, 2019(8): 17-22.
ZHOU Chenyi, WANG Wen, LU Shan, et al. Real-time semantic segmentation based on multi-scale fusion and its application in electric power scene[J]. Computer and Modernization, 2019(8): 17-22.
- [68] 张宇航, 邱才明, 杨 帆, 等. 深度学习在电网图像数据及时空数据中的应用综述[J]. 电网技术, 2019, 43(6): 1865-1873.
ZHANG Yuhang, Robert. QIU, YANG Fan, et al. Overview of application of deep learning with image data and spatio-temporal data of power grid[J]. Power System Technology, 2019, 43(6): 1865-1873.
- [69] WANG Y, LIU M, BAO Z, et al. Stacked sparse autoencoder with PCA and SVM for data-based line trip fault diagnosis in power systems[J]. Neural Computing and Applications, 2019, 31(10): 6719-6731.
- [70] OU M, WEI H, ZHANG Y, et al. A dynamic adam based deep neural network for fault diagnosis of oil-immersed power transformers[J]. Energies, 2019, 12(6): 995.
- [71] CHEN Y, HUANG S, LIU F, et al. Evaluation of reinforcement learning-based false data injection attack to automatic voltage control[J]. IEEE Transactions on Smart Grid, 2018, 10(2): 2158-2169.
- [72] 包 涛, 张孝顺, 余 涛, 等. 反映实时供需互动的 Stackelberg 博弈模型及其强化学习求解[J]. 中国电机工程学报, 2018, 38(10): 2947-2956.
BAO Tao, ZHANG Xiaoshun, YU Tao, et al. A stackelberg game model of real-time supply-demand interaction and the solving method via reinforcement learning[J]. Proceedings of the CSEE, 2018, 38(10): 2947-2956.
- [73] 于德明, 沈 建, 汪 骏, 等. 直升机在电网运行维护中的研究与应用[J]. 电网技术, 2009, 33(6): 107-112.
YU Deming, SHEN Jian, WANG Jun, et al. Research and application of helicopter in patrol and hotline operating maintenance of power lines[J]. Power System Technology, 2009, 33(6): 107-112.
- [74] 全卫国, 苑津莎, 李宝树. 图像处理技术在直升机巡检输电线路中的应用综述[J]. 电网技术, 2010, 34(12): 204-208.
TONG Weiguo, YUAN Jinsha, LI Baoshu. Application of image processing in patrol inspection of overhead transmission line by helicopter[J]. Power System Technology, 2010, 34(12): 204-208.
- [75] GOLIGHTLY I, JONES D. Corner detection and matching for visual tracking during power line inspection[J]. Image and Vision Computing, 2003, 21(9): 827-840.
- [76] 牛哲文, 郭采珊, 唐文虎, 等. “互联网+智慧能源”的技术特征与发展路径[J]. 电力大数据, 2019, 22(5): 6-10.
NIU Zhewen, GUO Caishan, TANG Wenhui, et al. Technical features and development path of “internet+smart energy”[J]. Guizhou Electric Power Technology, 2019, 22(5): 6-10.
- [77] 王 波, 马富齐, 董旭柱, 等. 电力深度视觉: 基本概念、关键技术与应用场景[J]. 广东电力, 2019, 32(9): 3-10.
WANG Bo, MA Fuqi, DONG Xuzhu, et al. Electric power depth vision: basic concepts, key technologies and application scenarios[J]. Guangdong Electric Power, 2019, 32(9): 3-10.
- [78] LING Z, ZHANG D, QIU R C, et al. An accurate and real-time self-blast glass insulator location method based on faster R-CNN and U-net with aerial images[J]. CSEE Journal of Power and Energy Systems, 2019, 5(4): 474-482.
- [79] 冈萨雷斯 R, 伍兹 R. 数字图像处理[M]. 阮秋琦, 译. 北京: 电子工业出版社, 2007.
GONZALES R, WOODS R. Digital image processing[M]. YUAN Qiuqi, translated. Beijing, China: Publishing House of Electronics Industry, 2007.
- [80] 刘志颖, 缪希仁, 陈 静, 等. 电力架空线路巡检可见光图像智能处理研究综述[J/OL]. 电网技术: 1-14[2019-11-29]. <https://doi.org/10.13335/j.1000-3673.pst.2019.0349>.
LIU Zhiying, MIAO Xiren, CHEN Jing, et al. Review of visible image intelligent processing for transmission line inspection[J/OL]. Power System Technology: 1-14[2019-11-29]. <https://doi.org/10.13335/j.1000-3673.pst.2019.0349>.
- [81] ZHAO Z, FAN X, XU G, et al. Aggregating deep convolutional feature maps for insulator detection in infrared images[J]. IEEE Access, 2017(5): 21831-21839.
- [82] 李军锋, 王钦若, 李 敏. 结合深度学习和随机森林的电力设备图像识别[J]. 高电压技术, 2017, 43(11): 3705-3711.
LI Junfeng, WANG Qinruo, LI Min. Electric equipment image recognition based on deep learning and random forest[J]. High Voltage Engineering, 2017, 43(11): 3705-3711.
- [83] 付 晶, 邵瑰玮, 吴 亮, 等. 利用层次模型进行训练学习的线路设备缺陷检测方法[J]. 高电压技术, 2017, 43(1): 266-275.
FU Jing, SHAO Guiwei, WU Liang, et al. Defect detection of line facility using hierarchical model with learning algorithm[J]. High Voltage Engineering, 2017, 43(1): 266-275.
- [84] 方 盛. 基于机器视觉的隔离开关运行状态检测系统研究[D]. 长沙: 湖南工业大学, 2018.
FANG Sheng. Research of running state detection system for disconnecting switch based on machine vision[D]. Changsha, China: Hunan University of Technology, 2018.
- [85] 刘云鹏, 裴少通, 武建华, 等. 基于深度学习的输变电设备异常发热点红外图片目标检测方法[J]. 南方电网技术, 2019, 13(2): 27-33.
LIU Yunpeng, PEI Shaotong, WU Jianhua, et al. Deep learning based target detection method for abnormal hot spots infrared images of transmission and transformation equipment[J]. Southern Power System Technology, 2019, 13(2): 27-33.
- [86] 林 刚, 王 波, 彭 辉, 等. 基于改进 Faster-RCNN 的输电线巡检图像多目标检测及定位[J]. 电力自动化设备, 2019, 39(5): 213-218.

- LIN Gang, WANG Bo, PENG Hui, et al. Multi-target detection and location of transmission line inspection image based on improved Faster-RCNN[J]. Electric Power Automation Equipment, 2019, 39(5): 213-218.
- [87] 张迪, 樊绍胜. 基于YOLO V3的输电线路故障检测方法[J]. 自动化技术与应用, 2019, 38(7): 125-129.
ZHANG Di, FAN Shaosheng. Fault detection of transmission line based on YOLO V3[J]. Techniques of Automation and Applications, 2019, 38(7): 125-129.
- [88] 陈咏秋, 孙凌卿, 张永泽, 等. 基于YOLO v3的输电线路鸟类检测技术研究[J/OL]. 计算机工程: 1-7[2019-11-29]. <http://kns.cnki.net/kcms/detail/31.1289.TP.20190809.1140.013.html>.
CHEN Yongqiu, SUN Lingqing, ZHANG Yongyi, et al. Research on bird detection technology of transmission line based on YOLO v3[J/OL]. Computer Engineering: 1-7[2019-11-29]. <http://kns.cnki.net/kcms/detail/31.1289.TP.20190809.1140.013.html>.
- [89] 朱德恒, 严璋, 谈克雄, 等. 电气设备状态监测与故障诊断技术[M]. 北京: 中国电力出版社, 2009.
ZHU Deheng, YAN Zhang, TAN Kexiong, et al. Condition monitoring and fault diagnosis technology of electric apparatus[M]. Beijing, China: China Electric Power Press, 2009.
- [90] 严英杰, 盛戈峰, 陈玉峰, 等. 基于大数据分析的输变电设备状态数据异常检测方法[J]. 中国电机工程学报, 2015, 35(1): 52-59.
YAN Yingjie, SHENG Gehao, CHEN Yufeng, et al. An method for anomaly detection of state information of power equipment based on big data analysis[J]. Proceedings of the CSEE, 2015, 35(1): 52-59.
- [91] 严英杰, 盛戈峰, 陈玉峰, 等. 基于高维随机矩阵大数据分析模型的输变电设备关键性能评估方法[J]. 中国电机工程学报, 2016, 36(2): 435-445.
YAN Yingjie, SHENG Gehao, CHEN Yufeng, et al. The key state assessment method of power transmission equipment using big data analyzing model based on large dimensional random matrix[J]. Proceedings of the CSEE, 2016, 36(2): 435-445.
- [92] 赵文清, 李庆良, 王德文. 基于多模型的变压器故障组合诊断研究[J]. 高电压技术, 2013, 39(2): 302-309.
ZHAO Wenqing, LI Qingliang, WANG Dewen. Combinational diagnosis for transformer faults based on multi-models[J]. High Voltage Engineering, 2013, 39(2): 302-309.
- [93] 靳文娟, 季天瑶, 唐文虎. 基于多参量的高压断路器分/合闸线圈的故障诊断[J]. 高压电器, 2019, 55(3): 226-233.
JIN Wenjuan, JI Tianyao, TANG Wenhui. Fault diagnosis of tripping/closing coil of high-voltage circuit breaker based on multiple parameters[J]. High Voltage Apparatus, 2019, 55(3): 226-233.
- [94] 董明, 屈彦明, 周孟戈, 等. 基于组合决策树的油浸式电力变压器故障诊断[J]. 中国电机工程学报, 2005, 25(16): 35-41.
DONG Ming, QU Yanming, ZHOU Menge, et al. Fault diagnosis of oil-immersed power transformer using combinatorial decision tree[J]. Proceedings of the CSEE, 2005, 25(16): 35-41.
- [95] 程养春, 张振亮. 基于随机森林的变压器多源局部放电诊断[J]. 中国电机工程学报, 2018, 38(17): 5246-5256, 5322.
CHENG Yangchun, ZHANG Zhenliang. Multi-source partial discharge diagnosis of transformer based on random forest[J]. Proceedings of the CSEE, 2018, 38(17): 5246-5256, 5322.
- [96] 吐松江·卡日, 高文胜, 张紫薇, 等. 基于支持向量机和遗传算法的变压器故障诊断[J]. 清华大学学报(自然科学版), 2018, 58(7): 623-629.
KARI Tusongjiang, GAO Wensheng, ZHANG Ziwei, et al. Power transformer fault diagnosis based on a support vector machine and a genetic algorithm[J]. Journal of Tsinghua University (Science and Technology), 2018, 58(7): 623-629.
- [97] 张新伯, 唐炬, 潘成, 等. 用于局部放电模式识别的深度置信网络方法[J]. 电网技术, 2016, 40(10): 3733-3740.
ZHANG Xinbo, TANG Ju, PAN Cheng, et al. Research of partial discharge recognition based on deep belief nets[J]. Power System Technology, 2016, 40(10): 3733-3740.
- [98] 崔江, 唐军祥, 龚春英, 等. 一种基于改进堆栈自动编码器的航空发电机旋转整流器故障特征提取方法[J]. 中国电机工程学报, 2017, 37(19): 5696-5706, 5847.
CUI Jiang, TANG Junxiang, GONG Chunying, et al. A fault feature extraction method of aerospace generator rotating rectifier based on improved stacked auto-encoder[J]. Proceedings of the CSEE, 2017, 37(19): 5696-5706, 5847.
- [99] 代杰杰, 宋辉, 杨伟, 等. 基于油中气体分析的变压器故障诊断ReLU-DBN方法[J]. 电网技术, 2018, 42(2): 658-664.
DAI Jiejie, SONG Hui, YANG Yi, et al. Dissolved gas analysis of insulating oil for power transformer fault diagnosis based on re lu-dbn[J]. Power System Technology, 2018, 42(2): 658-664.
- [100] 李刚, 于长海, 范辉, 等. 基于多级决策融合模型的电力变压器故障深度诊断方法[J]. 电力自动化设备, 2017, 37(11): 138-144.
LI Gang, YU Changhai, FAN Hui, et al. Deep fault diagnosis of power transformer based on multilevel decision fusion model[J]. Electric Power Automation Equipment, 2017, 37(11): 138-144.
- [101] 石梦洁. 弹簧操动机构断路器建模与故障诊断方法研究[D]. 广州: 华南理工大学, 2017.
SHI Mengjie. Modeling and fault diagnosis of circuit breakers with spring operated mechanism[D]. Guangzhou, China: South China University of Technology, 2017.
- [102] WANG J, LI S, HAN B, et al. Generalization of deep neural networks for imbalanced fault classification of machinery using generative adversarial networks[J]. IEEE Access, 2019(7): 111168-111180.
- [103] GUO M F, ZENG X D, CHEN D Y, et al. Deep-learning-based earth fault detection using continuous wavelet transform and convolutional neural network in resonant grounding distribution systems[J]. IEEE Sensors Journal, 2017, 18(3): 1291-1300.
- [104] VANI A, MURTHY P S R C. An adaptive neuro fuzzy inference system for fault detection in transformers by analyzing dissolved gases[C] // 2014 The 1st International Conference on Information Technology, Computer, and Electrical Engineering. Semarang, Indonesia: IEEE, 2014: 328-333.
- [105] 肖雄, 王健翔, 张勇军, 等. 一种用于轴承故障诊断的二维卷积神经网络优化方法[J]. 中国电机工程学报, 2019, 39(15): 4558-4568.
XIAO Xiong, WANG Jianxiang, ZHANG Yongjun, et al. A two-dimensional convolutional neural network optimization method for bearing fault diagnosis[J]. Proceedings of the CSEE, 2019, 39(15): 4558-4568.
- [106] 赵仲勇, 唐超, 李成祥, 等. 基于频率响应二值化图像的变压器绕组变形故障诊断方法[J]. 高电压技术, 2019, 45(5): 1526-1534.
ZHAO Zhongyong, TANG Chao, LI Chengxiang, et al. Diagnosis method of transformer winding deformation faults based on frequency response binary image[J]. High Voltage Engineering, 2019, 45(5): 1526-1534.
- [107] 蒋逸雯, 李黎, 李智威, 等. 基于深度语义学习的电力变压器运维文本信息挖掘方法[J]. 中国电机工程学报, 2019, 39(14): 4162-4172.
JIANG Yiwen, LI Li, LI Zhiwei, et al. An information mining method of power transformer operation and maintenance texts based on deep semantic learning[J]. Proceedings of the CSEE, 2019, 39(14): 4162-4172.
- [108] 杜修明, 秦佳峰, 郭诗瑶, 等. 电力设备典型故障案例的文本挖掘[J]. 高电压技术, 2018, 44(4): 1078-1084.
DU Xiuming, QIN Jiafeng, GUO Shiyao, et al. Text mining of typical

- defects in power equipment[J]. High Voltage Engineering, 2018, 44(4): 1078-1084.
- [109] 翟永杰, 杨旭, 彭雅妮, 等. 基于计算机听觉技术的电力设备状态监测研究综述[J]. 广东电力, 2019, 32(9): 24-32.
ZHAI Yongjie, YANG Xu, PENG Yani, et al. Research overview on state monitoring of electrical equipment based on computer hearing technology[J]. Guangdong Electric Power, 2019, 32(9): 24-32.
- [110] HEMAMALINI S. Rational-dilation wavelet transform based torque estimation from acoustic signals for fault diagnosis in a three phase induction motor[J]. IEEE Transactions on Industrial Informatics, 2018, 15(6): 3492-3501.
- [111] 杜世斌. 基于音频特征的电气设备故障监测算法研究[D]. 济南: 山东大学, 2014.
DU Shibin. Research on electrical equipments fault detection based on audio feature[D]. Jinan, China: Shandong University, 2014.
- [112] 王丰华, 王邵菁, 陈颂, 等. 基于改进 MFCC 和 VQ 的变压器声纹识别模型[J]. 中国电机工程学报, 2017, 37(5): 1535-1543.
WANG Fenghua, WANG Shaojing, CHEN Song, et al. Voiceprint recognition model of power transformers based on improved MFCC and VQ[J]. Proceedings of the CSEE, 2017, 37(5): 1535-1543.
- [113] 彭刚, 周舟, 唐松平, 等. 基于时序分析及变量修正的变压器故障预测[J]. 电子测量技术, 2018, 41(12): 96-99.
PENG Gang, ZHOU Zhou, TANG Songping, et al. Time series analysis and external variable correction for transformer fault prediction[J]. Electronic Measurement Technology, 2018, 41(12): 96-99.
- [114] 刘航, 王有元, 梁玄鸿, 等. 基于多因素的变压器油中溶解气体体积分数预测方法[J]. 高电压技术, 2018, 44(4): 1114-1121.
LIU Hang, WANG Youyuan, LIANG Xuanhong, et al. Prediction method of the dissolved gas volume fraction in transformer oil based on multi factors[J]. High Voltage Engineering, 2018, 44(4): 1114-1121.
- [115] 徐名, 方洋洋, 杨鹏. 基于灰色模型算法的电力变压器油温预测[J]. 电力学报, 2018, 33(5): 359-364, 382.
XU Ming, FANG Yangyang, YANG Peng, et al. Study on prediction of oil temperature for power transformer based on improved grey model[J]. Journal of Electric Power, 2018, 33(5): 359-364, 382.
- [116] 廖才波, 阮江军, 蔚超, 等. 基于改进支持向量机的变压器实时热点温度预测方法研究[J]. 高压电器, 2018, 54(12): 174-179.
LIAO Caibo, RUAN Jiangjun, WEI Chao, et al. Research on real-time hot-spot temperature prediction method for transformer based on improved support vector machine[J]. High Voltage Apparatus, 2018, 54(12): 174-179.
- [117] 杨壮, 周渠, 赵耀洪, 等. 基于人工神经网络和多频超声波检测技术的变压器油界面张力预测[J]. 高电压技术, 2019, 45(10): 3343-3349.
YANG Zhuang, ZHOU Qu, ZHAO Yaohong, et al. Prediction of interfacial tension of transformer oil based on artificial neural network and multi-frequency ultrasonic testing technology[J]. High Voltage Engineering, 2019, 45(10): 3343-3349.
- [118] 李可军, 元孝武, 魏本刚, 等. 基于核极限学习机误差预测修正的变压器顶层油温预测[J]. 高电压技术, 2017, 43(12): 4045-4053.
LI Kejun, QI Xiaowu, WEI Bengang, et al. Prediction of transformer top oil temperature based on kernel extreme learning machine error prediction and correction[J]. High Voltage Engineering, 2017, 43(12): 4045-4053.
- [119] 李可军, 徐延顺, 魏本刚, 等. 基于 PSO-HKELM 的变压器顶层油温预测模型[J]. 高电压技术, 2018, 44(8): 2501-2508.
LI Kejun, XU Yanshun, WEI Bengang, et al. Prediction model for top oil temperature of transformer based on hybrid kernel extreme learning machine trained and optimized by particle swarm optimization[J]. High Voltage Engineering, 2018, 44(8): 2501-2508.
- [120] 张施令, 姚强. 基于 WNN-GNN-SVM 组合算法的变压器油色谱时间序列预测模型[J]. 电力自动化设备, 2018, 38(9): 155-161.
ZHANG Shiling, YAO Qiang. Predicting model of transformer DGA time series based on WNN-GNN-SVM combined algorithm[J]. Electric Power Automation Equipment, 2018, 38(9): 155-161.
- [121] 刘云鹏, 许自强, 董王英, 等. 基于经验模态分解和长短期记忆神经网络的变压器油中溶解气体浓度预测方法[J]. 中国电机工程学报, 2019, 39(13): 3998-4008.
LIU Yunpeng, XU Ziqiang, DONG Wangying, et al. Concentration prediction of dissolved gases in transformer oil based on empirical mode decomposition and long short-term memory neural networks[J]. Proceedings of the CSEE, 2019, 39(13): 3998-4008.
- [122] 代杰杰, 宋辉, 盛戈峰, 等. 考虑复杂关联关系深度挖掘的变压器状态参量预测方法[J]. 中国电机工程学报, 2019, 39(2): 621-628, 659.
DAI Jiejie, SONG Hui, SHENG Gehao, et al. A prediction method for power transformers state parameters based on deep association relation mining[J]. Proceedings of the CSEE, 2019, 39(2): 621-628, 659.
- [123] REN C, XU Y. A fully data-driven method based on generative adversarial networks for power system dynamic security assessment with missing data[J]. IEEE Transactions on Power Systems, 2019, 34(6): 5044-5052.
- [124] ZHANG S, WANG Y, LIU M, et al. Data-based line trip fault prediction in power systems using LSTM networks and SVM[J]. IEEE Access, 2017(6): 7675-7686.
- [125] 江秀臣, 刘亚东, 傅晓飞, 等. 输配电设备泛在电力物联网建设思路与发展趋势[J]. 高电压技术, 2019, 45(5): 1345-1351.
JIANG Xiuchen, LIU Yadong, FU Xiaofei, et al. Construction ideas and development trends of transmission and distribution equipment of the ubiquitous power internet of things[J]. High Voltage Engineering, 2019, 45(5): 1345-1351.



TANG Wenhua
Ph.D., Professor
Corresponding author



NI Zhewen
Ph.D.

唐文虎(通信作者)

1974—, 男, 博士, 教授, 博导

主要从事电力设计故障诊断和弹性电网方面的研究工作

E-mail: wenhutang@scut.edu.cn

牛哲文

1993—, 男, 博士

研究方向为基于人工智能的电力数据挖掘技术

E-mail: epepzwniu@mail.scut.edu.cn

收稿日期 2019-12-28 修回日期 2020-03-15 编辑 何秋萍