

[人工智能]

基于人工智能的高压试验数据分析与故障预测方法

文/刘凯¹ 闫静²

1. 国网江苏省电力有限公司扬州市江都区供电分公司; 2. 国网江苏省电力有限公司超高压分公司

随着高压设备在电力、能源等行业中的广泛应用,如何提高高压设备的故障诊断与预测准确度,保障设备安全运行,成为亟待解决的问题。传统的高压试验数据分析方法依赖于人工经验和规则,往往面临着高维度、非线性数据处理的挑战。为此,提出一种基于人工智能的高压试验数据分析与故障预测方法,通过特征提取和优化,提升数据质量。提出一种结合人工智能技术的故障预测模型,通过提取高压试验数据中的异常特征,进行故障信息统计,并采用多种人工智能算法对故障进行精确预测。实验结果表明,人工智能方法能够有效识别潜在故障,并提供较高的预测准确率和较短的检测时间,具有较高的应用价值和广阔的前景。

高压设备在电力、化工和交通等多个工业领域中广泛应用,其可靠性直接影响着系统的安全性与稳定性。高压试验作为确保设备性能和安全性的关键环节,通过模拟设备在实际工作环境中的高压状态,检测其在极端条件下的表现,以识别潜在的故障风险。然而,随着高压设备的复杂性和试验数据量的急剧增加,传统的高压试验数据分析方法在效率和准确性上面临着巨大挑战。人工智能(AI)技术,尤其是机器学习与深度学习算法,因其在处理大规模数据和挖掘复杂模式方面的优势,逐渐成为高压试验数据分析中的重要工具^[1]。

人工智能不仅能够通过数据挖掘技术从海量试验数据中提取关键特征,还能够对试验数据中的噪声进行有效抑制,识别出异常变化,并对潜在故障进行预测。通过智能化的数据分析和故障预测,不仅可以提高设备的故障诊断准确性,还能提前预警可能发生的故障,从而有效降低设备故障率,提高设备的运行可靠性和安全性^[2]。

本文将围绕基于人工智能的高压试验数据分析

与故障预测方法展开探讨,首先介绍高压试验数据的特征及其分析需求,然后分析人工智能在噪声检测、频谱特性分析及横向分布规律分析等方面的应用,最后讨论如何通过智能算法提取异常特征并进行故障预测。希望通过这一研究,能够为高压设备的故障检测与预警提供一种新的思路与方法。

基于人工智能的高压试验数据分析

1. 基于人工智能的高压试验数据噪声检测

本文基于自编码器进行噪声检测,通过学习数据的低维表示来捕捉数据的潜在结构。自编码器由编码器和解码器组成,编码器将输入数据映射到低维空间,解码器再从低维空间重构出原始数据。噪声数据通常会在重构误差上表现为较大的偏差。因此,自编码器可以通过最小化重构误差来检测和去除噪声。设输入数据为 X ,通过编码器得到低维表示 z ,再通过解码器重构输出数据 $\hat{X}$,则重构误差为

$$\text{Loss} = \|X - \hat{X}\|^2 \quad (1)$$

对于噪声数据,重构误差会显著增大,因此通

过对比重构误差，可以有效识别噪声。通过深度学习和机器学习技术，自动从数据中学习噪声特征，并进行有效的噪声抑制。

2. 高压试验数据频谱特性分析

本文使用傅里叶变换进行高压试验数据频谱特性分析。设时域信号为 $x(t)$ ，其频谱表示为 $x(f)$ ，傅里叶变换的公式为

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (2)$$

式中， f 为频率； j 为虚数单位； t 为时间变量； $X(f)$ 为频域信号。

傅里叶变换能够将复杂的时域信号转化为不同频率分量的组合，进而揭示信号中潜在的周期性成分。

高压试验数据包含多种频率成分，其中高频成分由设备噪声、外部干扰等因素引起，而一些低频成分则反映出设备的正常工作状态或潜在故障。通过频谱分析，可以识别不同频率成分对应的物理现象，进一步判断设备是否存在异常或故障^[3]。

进一步分析功率谱密度，功率谱密度描述了信号在各个频率范围内的能量分布。设信号的自相关函数为 $R_x(\tau)$ ，功率谱密度通过自相关函数与傅里叶变换的关系得到

$$S_x(f) = \int_{-\infty}^{\infty} R_x(\tau)e^{-j2\pi f\tau} d\tau \quad (3)$$

式中， $S_x(f)$ 为信号的功率谱密度； $R_x(\tau)$ 为自相关函数。

功率谱密度能够揭示出信号在不同频率上的能量集中情况，从而帮助识别设备工作过程中的特征频率以及潜在的故障信号^[4]。

本文结合小波变换来提高对非平稳信号的分析能力。与傅里叶变换不同，小波变换能够同时提供信号的时间信息和频率信息，因此在处理高压试验数据中的非平稳信号时具有更大的优势。小波变换的基本形式为

$$W_x(a, b) = \int_{-\infty}^{\infty} x(t)\psi\left(\frac{t-b}{a}\right) dt \quad (4)$$

式中， $\psi(t)$ 为母小波函数； a 为尺度因子； b 为平移因子。

通过小波变换，分析在不同尺度下信号的局部频率特性。

3. 高压试验数据横向分布规律分析

基于多个测量点的数据进行比较与统计，挖掘

出空间上的不均匀性。设高压试验数据为 x_i ，其中 $i=1, 2, \dots, N$ 代表不同的测试点或设备部件， x_i 表示在第 i 个点的测量值。为了研究这些数据的分布规律，采用均值、标准差和协方差等统计指标来描述其横向分布特性。

首先计算数据集的均值，用来表示所有测量点的平均水平

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (5)$$

均值反映了高压试验数据的中心趋势，通过计算均值，了解设备整体性能的大致水平。

接着，计算数据的标准差，标准差用来衡量数据在各个测量点之间的离散程度，反映了各个测量点之间的差异性。标准差的计算公式为

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (6)$$

标准差较大的数据集通常意味着设备的各个部件响应不均匀，可能存在故障隐患；而标准差较小则表明设备各部件的响应较为一致，表明设备在高压试验下的性能较为稳定。

协方差是描述两个变量之间关联性的指标。如果测量点之间存在某种关联性，协方差值将揭示这种关系。设两个测量点的数据分别为 x_i 和 x_j ，则其协方差定义为

$$\text{cov}(x_i, x_j) = \frac{1}{N} \sum_{k=1}^N (x_{ik} - \mu_i)(x_{jk} - \mu_j) \quad (7)$$

式中， μ_i 和 μ_j 分别为两个测量点数据的均值。

协方差能够识别设备中不同部件之间的相互影响关系，对于判断设备是否均匀运行、是否存在局部故障具有重要意义。

最后利用空间自相关分析研究高压试验数据的横向分布规律。空间自相关分析通过计算数据之间的空间相关性，揭示出测量点之间的空间依赖关系。假设测量点 x_i 和 x_j 之间的空间距离为 d_{ij} ，则可以通过以下自相关函数来度量两点之间的相关性

$$\rho(d_{ij}) = \frac{\sum_{i=1}^{N-d} (x_i - \mu)(x_{i+d} - \mu)}{\sum_{i=1}^N (x_i - \mu)^2} \quad (8)$$

空间自相关函数可以揭示数据随距离变化的依赖程度，如果在某些区域内，测量点的数值变化相似，能意味着该区域内的设备性能均匀，反之则表

明可能存在性能不均匀的情况。

基于高压试验数据分析的故障预测

1. 高压试验数据异常特征提取

在高压试验数据中，异常通常表现为与正常工作状态不同的信号波动、频率特征或时间序列模式。

通过时频域特征提取进一步帮助识别高压试验数据中的隐性异常。高压试验数据包含不同频率的成分，故障往往会在特定的频段中表现出异常特征。通过傅里叶变换或者小波变换，将数据从时域转换到频域，提取出不同频率下的能量分布特征。在时频域中，某些频率成分的异常变化可能代表设备的故障。傅里叶变换后得到的功率谱密度函数 $S(f)$ 揭示出数据的频率分布情况。设 $S(f)$ 为高压试验数据的功率谱密度，其在特定频率 f_0 的值显著增大，可能表示设备在该频率处发生异常振动或故障。

2. 基于人工智能的高压试验数据故障预测

设数据集为 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ ，其中 x_i 为输入数据（如传感器测量值）， y_i 为对应的故障标签（如“正常”或“故障”）。分类算法通过学习数据 D 中的特征和标签之间的关系，建立一个分类模型 $f(x)$ ，用于预测新数据的故障类别

$$f(x) = \operatorname{argmax} P(y|x) \quad (9)$$

基于这个模型，可以统计每种故障类型出现的频率，帮助识别常见的故障模式，并评估其发生概率。

通过回归模型预测连续变量，分析高压试验数据中的故障趋势。根据回归分析，计算出不同设备在不同试验条件下的故障严重程度，进而实现故障预测。

设故障严重度为 y ，试验数据为 x ，回归模型的目标是最小化预测值与实际值之间的误差。回归模型通常通过最小二乘法进行训练，目标是求解参数 θ ，使得损失函数最小化

$$L(\theta) = \sum_{i=1}^n (y_i - f(x_i, \theta))^2 \quad (10)$$

通过回归模型统计的结果，预测设备在不同运行状态下的故障风险，帮助制定更有效的维护策略。

在没有标签的情况下，利用聚类算法从高压试

验数据中自动发现潜在。通过聚类分析，将相似的故障模式分为一类，从而识别出设备在不同运行状态下可能发生的故障类型。

假设数据集 $D = \{x_1, x_2, \dots, x_n\}$ 是未标记的数据，聚类算法通过计算数据点之间的相似度来将数据分为 K 个簇。设 C_k 为第 K 个簇，聚类目标是最小化簇内数据点之间的距离

$$\sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2 \quad (11)$$

式中， μ_k 为第 k 个簇的中心。

聚类结果可以揭示出数据中隐藏的故障模式，进而为故障信息统计提供依据。通过统计每个簇的样本数量及其特征，可以估算出不同类型故障的发生概率。

实验研究

为了验证本文提出的基于人工智能的高压试验数据分析与故障预测方法的实际应用效果，设定对比实验。设置实验参数见表1。

表1 实验参数

项目	参数
处理器型号	CD-5562
噪声范围/dB	10~15
传感器	PM2.5传感器
显示方式	数字显示/灯光显示
定时检测	支持定时检测
额定输入功率/W	52
额定输出功率/W	30
工作系统	Windows10
额定电压/V	600
检测时间/min	20

根据上述参数进行实验，选取本文研究的检测方法和传统方法，记录两种系统检测分析花费时间，以及故障预测结果的准确率。

分析时间实验结果如图1所示。

从图1中可以看出，基于人工智能的检测方法与传统方法相比，在大部分故障类型的检测时间上都有明显的优势。尤其在处理复杂的高压试验数据时，人工智能方法显著缩短了检测时间。这是因为人工智能算法能够通过高效的数据处理和特征提取，大大提高故障诊断的速度。




图1 分析时间实验结果图

对于传统方法而言，检测时间较长，尤其在处理多维度数据时，算法往往需要逐步进行特征提取、数据分析和计算，导致检测过程的延时。相比之下，基于人工智能的检测方法通过模型训练和实时数据分析，能够快速完成数据处理和故障预测，节省了大量时间。

进一步分析故障预测准确率，得到的实验结果见表2。

表2 故障预测准确率实验结果

故障类型	传统方法准确率 (%)	人工智能方法准确率 (%)
机械故障	85.45	92.63
电气故障	78.22	96.47
热故障	82.15	90.15
短路故障	80.36	92.44
超负荷故障	74.22	93.15

根据表2的实验结果，可以明显看出，基于人工智能的检测方法在所有故障类型上的预测准确率均高于传统方法。尤其是在电气故障和机械故障的预测中，人工智能方法的准确率提高约10%。这表明，人工智能方法能够更好地从复杂的高压试验数据中提取有效特征，并实现更准确的故障预测。

综上所述，人工智能技术不仅能够提高故障预测的效率，还能提升预测结果的准确性，为高压试验设备的故障诊断与预测提供更为可靠的技术手段。因此，基于人工智能的故障预测方法具有较强的应用前景，尤其适用于复杂系统和大规模数据处

理的场景。

结束语

随着高压设备的广泛应用和复杂性不断增加，如何在高压试验中实现有效的故障预测和实时监控，成为确保设备安全运行的关键问题。本文详细探讨了高压试验数据的噪声检测、频谱特性分析以及横向分布规律分析等数据处理方法，展示了人工智能如何帮助改善数据的质量与准确性。在故障预测方面，本文通过对异常特征提取、故障信息统计和预测模型的构建，提出基于人工智能的高压试验数据故障预测方案，并通过实验验证该方法在准确率和效率上的优势。实验结果表明，基于人工智能的方法在故障预测准确率和检测时间上均优于传统方法，特别是在处理复杂、高维度的高压试验数据时，人工智能方法展现出显著的优势。

然而，尽管基于人工智能的高压试验数据分析与故障预测方法具有较高的准确性和效率，但仍存在一定的挑战，例如数据质量、算法的适用性及其泛化能力等。未来的研究可以进一步探索如何利用更多种类的深度学习模型、强化学习等先进算法来提高故障预测的准确性和可靠性。同时，结合实时监控系统和边缘计算的应用，将进一步提升系统的智能化水平，为高压设备的运行安全提供更强有力的支持。EA

(收稿日期：2025-03-01)

参考文献

[1] 薛晓茹，徐道磊，路宇，等．基于知识图谱与人工智能的电力数据分析算法研究[J]．电子设计工程，2023，31(22)：139-143．

[2] 张春玲，赵训威，王志刚，等．基于人工智能的多源遥感数据融合在电网勘测应用研究[J]．现代电子技术，2024，47(4)：128-133．

[3] 张春玲，赵训威，王志刚，等．基于人工智能的多源遥感数据融合在电网勘测应用研究[J]．现代电子技术，2024，47(4)：128-133．

[4] 崔焱，李学龄，冯志宏．基于人工智能的电网运营数据安全管控系统[J]．信息技术，2023，47(4)：117-122．