

基于配网智能终端遥信和遥测数据的设备故障检测报告

引言

确保电力配网的安全稳定运行是能源供应的关键。及时准确地检测设备故障,能够有效避免电力中断,减少经济损失,并保障人身安全。随着智能电网技术的进步,配网中广泛部署了智能终端,这些终端能够实时上报大量的遥信和遥测数据。如何有效地利用这些数据来检测一次设备(绝缘击穿、气体泄露、机械锈蚀、密封油漏、触头烧蚀)和二次设备(电源烧毁、通信异常、电池失压、精度偏移、遥信抖动、板卡损坏、软件故障)的本体故障,成为当前电力系统研究的重要课题。本报告旨在探讨仅基于配网智能终端上报的遥信和遥测数据,实现对上述一次和二次设备本体故障进行有效检测的方法和策略。通过深入分析各类故障可能引起的遥信和遥测数据变化,并结合先进的数据处理和分析技术,为构建智能化的配网故障检测系统提供理论指导和实践参考。电力配网的智能化发展,使得我们能够获取前所未有的丰富运行数据。这些数据蕴含着设备运行状态的关键信息,通过对其进行深入挖掘和分析,可以实现从传统的被动维护向主动预测性维护的转变,从而提升配网的整体可靠性和运行效率。

配网智能终端上报的关键遥信和遥测数据及其意义

配网智能终端实时上报的遥信和遥测数据是进行故障检测的基础。理解这些数据的具体含义及其在反映设备运行状态方面的作用至关重要。用户查询中提及的关键数据包括: COS (功率因数)、IO (零序电流)、IA、IB、IC (三相电流)、P (有功功率)、Q (无功功率)、UA、UB、UC (三相电压)、UAB、UBC、UCA (线电压)。

功率因数(COS)是衡量电力设备效率的重要指标。正常情况下,设备的功率因数应维持在一定的范围内。功率因数过低可能表明设备存在过载、效率降低或某些类型的故障¹。

零序电流(IO)是指三相电流矢量之和。在正常的三相平衡系统中,零序电流应为零。当发生接地故障,例如绝缘击穿时,会产生明显的零序电流¹。因此,零序电流的升高是判断接地故障的重要依据。

三相电流(IA、IB、IC)反映了电力系统的负荷状况和平衡程度。正常运行时,三相电流应基本平衡且在额定范围内波动。三相电流的严重不平衡可能指示相间短路、断相或设备内部绕组故障¹。电流幅值的异常增大则可能是短路故障或过载的表现。

有功功率(P)和无功功率(Q)分别表示电力系统中实际消耗的功率和用于建立磁场或电场的功率。它们的数值变化直接反映了设备的运行负荷和状态。例如,有功功率的突然降低可能表示设备停运或故障,而无功功率的异常波动可能与设备的无功补偿装置或自身故障有关。

三相电压(UA、UB、UC)和线电压(UAB、UBC、UCA)是衡量电力系统电压质量的关键参

数。正常情况下，电压应维持在额定值的合理范围内。电压的骤降可能由短路故障或系统过载引起，而电压的骤升则可能与雷击或某些类型的设备故障有关。三相电压的不平衡也可能指示系统或设备故障。

表 1: 遥信和遥测数据及其潜在故障指示

遥信/遥测数据	潜在故障指示	说明
COS(功率因数)	设备效率降低、过载、触头烧蚀	功率因数过低可能与设备运行效率下降或故障有关。
IO(零序电流)	接地故障、绝缘击穿	正常情况下为零，升高可能指示接地故障。
IA、IB、IC(三相电流)	相间短路、断相、内部故障、过载、绝缘击穿	不平衡可能指示相间故障或内部故障，异常增大可能指示短路或过载。
P(有功功率)	设备停运、故障	突然降低可能表示设备停止运行或发生故障。
Q(无功功率)	无功补偿装置故障、设备自身故障	异常波动可能与设备的无功补偿或自身故障有关。
UA、UB、UC(三相电压)	短路故障、系统过载、设备故障	骤降可能由短路或过载引起，不平衡可能指示系统或设备故障。
UAB、UBC、UCA(线电压)	短路故障、系统过载、设备故障	与相电压类似，异常波动可能指示故障。

理解这些遥信和遥测数据在正常和故障状态下的特性，以及它们之间的相互关系，是构建有效故障检测模型的关键。例如，电压骤降往往伴随着电流的急剧增大¹，而功率因数的降低可能与电流和电压的谐波含量增加有关。

一次设备和二次设备常见本体故障类型

电力配网中的设备种类繁多，根据其在系统中的功能可以分为一次设备和二次设备。一次设备直接参与电能的生产、传输和分配，而二次设备则用于对一次设备进行控制、保护和监测。不同类型的设备具有不同的故障模式。

一次设备：

- 绝缘击穿：指设备绝缘材料的绝缘能力下降，导致带电部分与不带电部分之间发生非正常导通。这通常会导致短路故障，并可能引发零序电流的升高和三相电流的急剧变化¹。
- 气体泄露：主要发生在充气绝缘的设备（如GIS开关、SF6断路器）中。气体泄露会降低设备的绝缘性能，长期可能导致绝缘击穿。虽然气体泄露本身可能不会立即引起遥测数据的变化，但严重的泄露可能间接导致设备过热等问题。
- 机械锈蚀：指设备金属部件由于环境因素发生腐蚀，影响设备的机械性能和电气连接。严重的锈蚀可能导致接触不良，引起电流不稳定或电压波动。
- 密封油漏：主要发生在充油设备（如变压器、油断路器）中。油漏会降低设备的绝缘和冷却性能，长期可能导致设备过热甚至烧毁。与气体泄露类似，油漏本身不直接影响遥测数据，但油位下降可能间接影响设备的运行温度和电气参数。
- 触头烧蚀：主要发生在开关、断路器等设备的触头部位。频繁的开合操作或过电流可能导致触头表面烧蚀，增加接触电阻，引起电流减小、电压升高（负载侧）、功率损耗增加和功率因数降低¹。

二次设备：

- 电源烧毁：指二次设备的电源模块发生故障，导致设备无法正常供电。这通常会直接导致设备停止工作，无法上报任何遥信和遥测数据。
- 通信异常：指二次设备与主站或其他设备之间的通信链路发生故障，导致数据传输中断、延迟或错误。这会表现为遥测数据的上报延迟、丢失或出现乱码。
- 电池失压：指二次设备备用电源（通常为电池）的电压低于正常工作范围。这会影响设备在主电源故障时的可靠性，但可能难以从常规遥测数据中直接判断。
- 精度偏移：指二次设备测量传感器或电路的精度发生变化，导致上报的遥测数据与实际值之间存在持续的偏差。
- 遥信抖动：指二次设备上报的开关状态等遥信信号在短时间内频繁变化，这通常指示开关或触点存在机械故障或控制逻辑异常。
- 板卡损坏：指二次设备内部的电子板卡发生硬件故障。根据损坏板卡的功能不同，可能导致部分或全部遥测和遥信数据异常或丢失。
- 软件故障：指二次设备运行的软件出现错误或异常，可能导致数据上报格式错误、数值异常、系统无响应或重启等问题。

识别这些不同类型故障的特点及其可能影响的遥信和遥测数据，是设计针对性故障检测算法的基础。不同的故障往往会在遥信和遥测数据中留下独特的“指纹”。

基于遥信和遥测数据的通用故障检测方法

利用配网智能终端上报的遥信和遥测数据进行设备故障检测，通常需要经历数据预处理、建立基线模型、以及应用各种异常检测方法等步骤。

数据预处理与特征工程

原始的遥信和遥测数据往往包含缺失值、异常值和噪声,需要进行预处理以提高数据质量,使其更适合用于故障检测模型的训练和应用。²

数据清洗: 处理缺失值是数据预处理的重要环节。缺失值的类型可以分为随机缺失(MAR)、完全随机缺失(MCAR)和非随机缺失(MNAR)⁴。针对不同类型的缺失,需要采取不同的处理方法。对于少量随机缺失的数据,可以考虑删除包含缺失值的行或列。但如果缺失比例较高或删除可能导致关键信息丢失,则需要进行填充。常用的填充方法包括使用均值、中位数或众数进行填充⁵。对于时间序列数据,还可以使用插值法进行填充⁴。处理异常值同样至关重要。异常值是指明显偏离正常范围的数据点,可能是由于传感器故障、通信错误或真实的设备异常导致⁶。识别和处理异常值的方法包括基于统计学的方法,如 3σ 原则和箱线图⁷,以及基于时间序列分解的方法⁸,或者更复杂的基于模型的方法¹⁰。

数据变换: 数据变换的目的是将数据转换为更适合模型处理的格式。数据归一化或标准化是将不同量纲的数据缩放到相同的数值范围,例如或以均值为中心、标准差为1的分布⁵。常用的方法包括Min-Max缩放和Z-Score标准化⁵。这有助于加快算法的收敛速度并提高模型性能。对于时间序列数据,可能需要将其转换为适合特定算法的格式,例如通过滑动窗口技术将时间序列分割成多个样本¹⁴。

特征工程: 特征工程是指从原始数据中创建新的、更具代表性的特征,以提高故障检测模型的性能⁵。对于遥测数据,可以提取各种统计特征,如均值、标准差、方差、最大值、最小值、峰度、偏度等,以捕捉数据的整体分布特性¹⁵。对于时域信号,可以提取上升时间、下降时间、脉冲宽度等特征,这些特征对于捕捉瞬态故障非常有用¹⁶。通过傅里叶变换或小波变换等方法,可以将时域信号转换到频域进行分析,识别与特定故障相关的频率成分¹⁶。小波变换尤其适用于分析电力系统中常见的非平稳信号¹⁷。

建立设备正常运行状态的基线模型

建立准确的设备正常运行状态基线模型是检测故障的前提²¹。基线模型描述了设备在无故障情况下的预期行为。常用的基线模型包括:

- 基于历史数据的统计基线: 通过分析历史正常运行数据,计算每个遥测参数的均值、标准差和置信区间等统计量。将当前的遥测数据与这些基线值进行比较,如果超出预设的范围,则认为可能存在异常⁷。
- 基于时间序列模型的基线: 使用ARIMA²⁴, Prophet²⁸等时间序列模型对历史正常运行数据进行建模,预测未来的正常值。然后将实际观测值与预测值进行比较,如果偏差超过一定的阈值,则标记为异常¹⁰。
- 基于机器学习的基线: 利用无监督或半监督学习方法,如自编码器¹¹和One-Class SVM¹⁴,学习正常数据的模式和分布。对于新的数据点,如果其与模型学习到的正常模式显著不同,则被认为是异常。

选择合适的基线模型需要考虑数据的特性和预期行为的复杂性。统计基线简单直观,但可

能无法捕捉复杂的时序依赖关系。时间序列模型可以处理具有季节性和趋势的数据。机器学习模型则能够学习高度复杂的非线性模式。此外, 还需要考虑基线漂移的问题, 并定期对基线模型进行更新和校准⁸。

基于统计学的异常检测方法

基于统计学的异常检测方法通常基于对数据分布的假设, 通过分析数据是否偏离预期分布来判断是否存在异常³³。

- 阈值检测: 为每个遥测参数设定一个正常运行的上限和下限阈值。如果某个数据点超出了这个阈值范围, 则被标记为异常³⁴。阈值的设定可以基于历史数据的统计分析或专家经验。
- 统计过程控制(SPC): 利用控制图等工具, 监控遥测数据的统计特性(如均值、方差)是否超出预先设定的控制限。超出控制限的点被认为是异常, 可能指示系统过程发生了改变³⁵。
- 时间序列分析: 使用如STL分解⁸等方法将时间序列分解为趋势、季节性和残差等成分。通过分析残差序列是否超出正常范围(例如, 基于残差的标准差设定阈值), 可以检测出与正常模式不符的异常点⁸。

这些方法简单易于理解和实现, 但通常假设数据服从特定的分布, 且对于复杂、多变量的数据可能效果不佳。

基于机器学习的异常检测方法

机器学习方法在处理复杂的异常检测问题上展现出强大的能力³⁶。根据是否需要标签数据, 可以分为无监督学习、有监督学习和半监督学习方法⁴⁵。

- 无监督学习:
 - 聚类算法: 如K-Means⁸和DBSCAN⁴⁷。这些算法将相似的数据点聚集到一起形成簇。正常数据点应该形成较大的簇, 而异常点要么不属于任何簇, 要么形成很小的簇²⁹。
 - 基于距离的方法: 如K近邻(KNN)²⁹和局部离群因子(LOF)¹¹。KNN计算每个数据点与其他K个最近邻居的距离, 距离过大的点被认为是异常。LOF则评估一个数据点相对于其局部邻域的离群程度, 局部密度远低于其邻域的点被认为是异常。
 - 降维方法: 如主成分分析(PCA)⁵。PCA将高维数据投影到低维空间, 保留数据的主要方差。正常数据在降维空间中的重构误差应该较小, 而异常数据的重构误差通常较大。
 - 自编码器: 是一种神经网络, 旨在学习输入数据的压缩表示。通过仅使用正常数据训练自编码器, 使其能够很好地重构正常数据。当输入异常数据时, 由于模型没有学习过这些模式, 其重构误差会显著增大, 从而可以检测到异常¹¹。
 - 孤立森林: 是一种基于树的异常检测算法。它通过随机选择特征并随机分割数据来构建孤立树。异常点由于其稀疏性, 更容易被孤立到树的较浅层⁸。

- 有监督学习：
 - 分类算法：如支持向量机(SVM)³²、决策树²⁹和神经网络¹⁰。这些算法需要预先标记好的正常和异常数据进行训练，学习区分正常和异常样本的分类器。然后，可以使用训练好的分类器对新的遥测数据进行分类，判断其是否为异常。
- 半监督学习：
 - **One-Class SVM**：是一种只使用正常数据进行训练的SVM变体¹⁴。它学习正常数据的边界，将落在边界之外的数据点视为异常。

选择哪种机器学习算法取决于具体的故障类型、数据的特性以及是否拥有标记好的故障数据。在实际应用中，通常会尝试多种算法并进行比较，选择性能最佳的。集成学习方法²，即结合多个不同算法的预测结果，往往可以提高异常检测的鲁棒性和准确性。

基于特定遥信和遥测数据的设备故障诊断策略

针对不同的一次和二次设备故障类型，可以结合其特点以及遥信和遥测数据可能的变化，制定具体的诊断策略。

一次设备故障诊断

- 绝缘击穿的特征分析与检测：绝缘击穿通常会导致三相电流急剧增大，并且可能出现不平衡¹。同时，电压可能会骤降，功率因数会异常降低。零序电流(IO)的出现是判断接地故障(通常由绝缘击穿引起)的关键指标¹。此外，遥信数据中保护装置的动作信号也可以作为辅助判断依据。检测绝缘击穿可以关注电流的突变、电压的跌落以及零序电流的显著升高，并结合功率因数的变化进行综合判断。
- 气体泄露的特征分析与检测：气体泄露本身可能不会直接导致遥测数据的立即变化。然而，长期的气体泄露会影响设备的绝缘性能，可能导致设备过热，从而间接引起电流和电压等参数的异常。虽然无法直接通过所列遥测数据判断气体泄露，但可以监测设备的长期运行趋势，如果出现持续的温度升高(如果可获取此数据)或其他电气参数的缓慢异常变化，可能需要进一步检查是否存在气体泄露。
- 机械锈蚀的特征分析与检测：机械锈蚀通常是一个缓慢的过程，可能不会直接引起遥测数据的显著变化。在极端情况下，锈蚀可能导致连接部件接触不良，从而引起电流的不稳定或电压的微小波动。检测机械锈蚀可能需要关注电流和电压数据的噪声水平是否异常增加，或者是否存在间歇性的数据波动。
- 密封油漏的特征分析与检测：密封油漏本身不直接影响遥测数据。但如果油位下降导致设备的冷却和绝缘性能下降，可能会引起设备过热，从而间接影响电流和电压等参数(如果可获得油位数据)。与气体泄露类似，仅凭所列遥测数据难以直接判断油漏，但可以关注设备运行温度的变化趋势以及电流和电压是否出现与过热相关的异常。
- 触头烧蚀的特征分析与检测：触头烧蚀可能导致接触电阻增大，引起电流减小，电压在负载侧可能升高，功率损耗增加，功率因数降低¹。同时，电流波形可能出现畸变或噪声增加。检测触头烧蚀可以关注电流是否逐渐减小，功率因数是否持续下降，以及电

流波形中是否出现异常谐波或噪声。

二次设备故障诊断

- 电源烧毁的特征分析与检测：电源烧毁最直接的表现是设备完全停止工作，没有任何遥测数据上报。在烧毁之前，可能出现电压或电流的异常波动。因此，如果某个智能终端突然停止上报数据，或者在上报数据消失前出现明显的电压或电流异常波动，应首先怀疑是电源故障。
- 通信异常的特征分析与检测：通信异常通常导致遥测数据的上报延迟、数据包丢失或数据内容损坏(乱码)。可能会出现间歇性的数据中断或数据更新频率异常。检测通信异常需要关注数据的时间戳是否连续，是否存在数据缺失或数值突变等情况。
- 电池失压的特征分析与检测：在主电源正常供电的情况下，电池失压可能难以从所列的遥测数据中直接判断。除非有专门的电池电压监测参数，否则只能在主电源中断时，通过观察设备是否能够正常切换到备用电源来判断电池状态。
- 精度偏移的特征分析与检测：精度偏移会导致所有或部分遥测参数的读数持续偏高或偏低。发现精度偏移通常需要将该设备的读数与其他同类型设备的读数进行比较，或者进行定期的现场校准。如果一个设备的多个参数都显示出一致的偏差，则可能是精度偏移。
- 遥信抖动的特征分析与检测：遥信抖动是指遥信状态(如断路器分合状态)在短时间内频繁快速地切换。这通常指示开关或触点存在机械故障或控制逻辑错误。可以通过监测遥信状态的变化频率来检测遥信抖动。
- 板卡损坏的特征分析与检测：板卡损坏可能导致部分或全部遥测和遥信数据异常或丢失，具体取决于损坏的板卡功能。例如，通信板卡损坏可能导致所有数据丢失，而某个传感器的接口板卡损坏可能只影响该传感器数据的上报。如果遥信数据中包含设备的自检或错误代码信息，也可以用于辅助判断板卡是否损坏。
- 软件故障的特征分析与检测：软件故障可能导致数据上报格式错误、数值出现逻辑上的异常、系统无响应或设备自动重启等现象。例如，某些参数的值始终为零或超出合理的物理范围，或者设备频繁重启。分析软件故障可能需要结合设备的日志信息。

表 2: 常见故障类型及其可能的遥测特征

故障类型	主要影响的遥测参数	预期变化
绝缘击穿	IA, IB, IC, UA, UB, UC, IO, COS	电流急剧增大(可能不平衡)，电压骤降，功率因数显著降低，零序电流升高。
触头烧蚀	IA, IB, IC, UA, UB, UC, P, COS	电流减小，电压(负载侧)升高，有功功率损耗增加，功率因数降低，可能出现电流波形畸变或噪

		声。
电源烧毁	所有遥测参数	突然无数据上报或上报前出现剧烈波动。
通信异常	所有遥测参数	数据上报延迟、丢失、乱码、间歇性中断。
精度偏移	部分或全部遥测参数	读数持续偏高或偏低。
遥信抖动	特定遥信状态	在短时间内频繁切换。
板卡损坏	部分或全部遥测/遥信参数	异常或丢失，取决于损坏板卡功能。
软件故障	所有遥测参数	数据格式错误、数值异常、系统无响应、重启。

故障检测系统的实施与优化建议

实施基于遥信和遥测数据的故障检测系统需要周密的规划和持续的优化。

数据采集、存储与管理

首先需要确定数据采集的频率和范围，确保覆盖所有关键的遥信和遥测数据⁵。选择可靠的数据存储方案至关重要，以保证数据的完整性和可访问性。由于遥测数据量通常较大，需要建立有效的数据管理流程，包括数据清洗、转换、备份和恢复等⁵。对于需要实时故障检测的应用，可能还需要考虑实时数据流的处理能力。

故障检测模型的选择与训练

根据具体的故障类型和数据特点，选择合适的异常检测算法是关键¹³。可以使用统计方法、机器学习方法或将两者结合的混合方法。选择合适的历史数据对模型进行训练和验证，并不断优化模型参数⁵。在选择模型时，需要权衡模型的实时性和计算资源需求，以满足实际应用的要求。模型需要定期进行重新训练和验证，以保持其准确性并适应系统行为的变化⁸。

实时监控与告警机制

建立实时的遥测数据流监控系统，持续分析上报的数据⁵²。配置灵活的告警规则和阈值，当检测到异常时能够及时发出告警³⁴。告警信息应清晰地指出发生故障的设备、可能的故障类型以及发生时间等关键信息，以便运维人员快速定位和处理问题。告警系统应具有高可

靠性, 并尽量减少误报, 同时确保关键故障能够被及时报告⁵⁴。

模型评估与持续优化

定期评估故障检测模型的性能至关重要。可以使用准确率、召回率和F1值等指标来衡量模型的检测效果³⁰。根据评估结果, 可以调整模型的参数, 或者选择更合适的算法⁵。随着时间的推移, 可能会出现新的故障模式或系统行为发生变化, 因此需要利用新的故障数据不断更新和优化模型⁸, 以保持故障检测系统的有效性。

结论与未来展望

本报告详细探讨了如何仅基于配网智能终端上报的遥信和遥测数据来检测一次和二次设备的本体故障。通过分析关键遥信和遥测数据的意义, 阐述了常见故障类型及其可能的遥测特征, 并介绍了通用的故障检测方法, 包括数据预处理、基线模型建立以及基于统计学和机器学习的异常检测技术。最后, 报告还提出了故障检测系统实施与优化的建议。

未来, 基于配网智能终端遥信和遥测数据的故障检测技术将朝着更智能化的方向发展。更先进的机器学习和深度学习算法将被应用, 以提高故障检测的准确性和鲁棒性。多源数据的融合(例如, 结合气象数据、设备历史维护记录等)将提供更全面的设备状态信息, 从而实现更精确的故障诊断和预测。此外, 故障预测技术的研究也将成为重要的发展方向, 通过分析历史数据和实时数据, 预测设备未来可能发生的故障, 从而实现真正的预防性维护, 进一步提升电力配网的安全性和可靠性。

Works cited

1. Schematic diagram for fault location with the proposed model. ARIMA - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/figure/Schematic-diagram-for-fault-location-with-the-proposed-model-ARIMA-autoregressive_fig3_320389298
2. A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data - Frontiers, accessed May 8, 2025, <https://www.frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2021.652801/full>
3. (PDF) Data Preprocessing in Electrical Energy Consumption Profile Clustering Studies, accessed May 8, 2025, https://www.researchgate.net/publication/370105694_Data_Preprocessing_in_Electrical_Energy_Consumption_Profile_Clustering_Studies
4. What Is Data Cleaning? - MATLAB & Simulink - MathWorks, accessed May 8, 2025, <https://www.mathworks.com/discovery/data-cleaning.html>
5. Data Preprocessing in Machine Learning: Steps & Best Practices - lakeFS, accessed May 8, 2025, <https://lakefs.io/blog/data-preprocessing-in-machine-learning/>
6. Smart Grid Outlier Detection Based on the Minorization–Maximization Algorithm

- PMC, accessed May 8, 2025,
<https://pmc.ncbi.nlm.nih.gov/articles/PMC10574855/>
- 7. Outlier Detection in Buildings' Power Consumption Data Using Forecast Error - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1996-1073/14/24/8325>
- 8. Outlier Detection Time Series: A Primer - Eyer.ai, accessed May 8, 2025, <https://www.eyer.ai/blog/outlier-detection-time-series-a-primer/>
- 9. Outlier filtering from time series data - Data Science Stack Exchange, accessed May 8, 2025, <https://datascience.stackexchange.com/questions/124350/outlier-filtering-from-time-series-data>
- 10. Detection of Outliers in Time Series Power Data Based on Prediction Errors - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/publication/366865604_Detection_of_Outliers_in_Time_Series_Power_Data_Based_on_Prediction_Errors
- 11. Research on Anomaly Detection Model for Power Consumption Data Based on Time-Series Reconstruction - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1996-1073/17/19/4810>
- 12. Data Preprocessing in Depth: Advanced Techniques for Data Scientists - Data Expertise, accessed May 8, 2025, <https://www.dataexpertise.in/data-preprocessing-techniques-for-data-scientists/>
- 13. Data Preprocessing Techniques in Machine Learning [6 Steps] - Scalable Path, accessed May 8, 2025, <https://www.scalablepath.com/data-science/data-preprocessing-phase>
- 14. Anomaly Detection in Satellite Telemetry Data Using a Sparse Feature-Based Method, accessed May 8, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC9460388/>
- 15. A Data Scientist's Guide to Signal Processing | DataCamp, accessed May 8, 2025, <https://www.datacamp.com/tutorial/a-data-scientists-guide-to-signal-processing>
- 16. Data Preprocessing for Condition Monitoring and Predictive ..., accessed May 8, 2025, <https://www.mathworks.com/help/predmaint/ug/data-preprocessing-for-condition-monitoring-and-predictive-maintenance.html>
- 17. Fault Detection and Classification in Electrical Power Transmission System Using Wavelet Transform - MDPI, accessed May 8, 2025, <https://www.mdpi.com/2673-4591/59/1/71>
- 18. Detection of Faults in Power System Using Wavelet Transform and Independent Component Analysis - arXiv, accessed May 8, 2025, <https://arxiv.org/pdf/1609.08650>
- 19. Power System Fault Detection and Classification Using Wavelet Transform and Artificial Neural Networks - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/publication/334032239_Power_System_Fault_Detection_and_Classification_Using_Wavelet_Transform_and_Artificial_Neural_Networks
- 20. A Study on the Preprocessing Method for Power System Applications Based on Polynomial and Standard Patterns - MDPI, accessed May 8, 2025,

- <https://www.mdpi.com/1996-1073/15/4/1441>
21. Baseline Methods for the Parameter Estimation of the Generalized Pareto Distribution, accessed May 8, 2025, <https://www.mdpi.com/1099-4300/24/2/178>
 22. Overview about power and performance tuning for the Windows Server | Microsoft Learn, accessed May 8, 2025, <https://learn.microsoft.com/en-us/windows-server/administration/performance-tuning/hardware/power/power-performance-tuning>
 23. www.energynetworks.org, accessed May 8, 2025, <https://www.energynetworks.org/assets/images/ON20-WS1A-P7%20Baselining%20Assessment-PUBLISHED.23.12.20.pdf>
 24. Location of Faults in Power Transmission Lines Using the ARIMA Method - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/publication/320389298_Location_of_Faults_in_Power_Transmission_Lines_Using_the_ARIMA_Method
 25. Location of Faults in Power Transmission Lines Using the ARIMA Method - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1996-1073/10/10/1596>
 26. Frequency prediction of a post-disturbance power system using a hybrid ARIMA and DBN model - Frontiers, accessed May 8, 2025, <https://www.frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2024.1363873/full>
 27. Online Forecasting and Anomaly Detection Based on the ARIMA Model | Papers With Code, accessed May 8, 2025, <https://paperswithcode.com/paper/online-forecasting-and-anomaly-detection>
 28. A Real-Time Anomaly Detection in Satellite Telemetry Data Using Artificial Intelligence Techniques Depending on Time-Series Analysis, accessed May 8, 2025, https://asc.journals.ekb.eg/article_326373_a6d450f8a76a18b92178ac2fee1bce1d.pdf
 29. Anomaly Detection in Time Series - neptune.ai, accessed May 8, 2025, <https://neptune.ai/blog/anomaly-detection-in-time-series>
 30. Outlier Detection and Correction in Smart Grid Energy Demand Data Using Sparse Autoencoders - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1996-1073/17/24/6403>
 31. Detecting Anomalies of Satellite Power Subsystem via Stage-Training Denoising Autoencoders - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1424-8220/19/14/3216>
 32. Anomaly Detection for Power Quality Analysis Using Smart Metering Systems - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1424-8220/24/17/5807>
 33. Detection of Outliers in Time Series Power Data Based on Prediction Errors - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1996-1073/16/2/582>
 34. Telemetry Fault-Detection Algorithms: Applications for Spacecraft Monitoring and Space Environment Sensing | Journal of Aerospace Information Systems - AIAA ARC, accessed May 8, 2025, <https://arc.aiaa.org/doi/full/10.2514/1.1010587>
 35. How to identify outliers in a time series with correlated variables - Cross Validated, accessed May 8, 2025,

<https://stats.stackexchange.com/questions/406863/how-to-identify-outliers-in-a-time-series-with-correlated-variables>

36. Machine learning for modern power distribution systems: Progress and perspectives | Journal of Renewable and Sustainable Energy | AIP Publishing, accessed May 8, 2025, <https://pubs.aip.org/aip/jrse/article/15/3/032301/2900695/Machine-learning-for-modern-power-distribution>
37. (PDF) Explainable anomaly detection in spacecraft telemetry - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/publication/378214516_Explainable_anomaly_detection_in_spacecraft_telemetry
38. Anomaly detection in power distribution system measurements using machine learning, accessed May 8, 2025, <https://rex.libraries.wsu.edu/esploro/outputs/graduate/Anomaly-detection-in-power-distribution-system/99900890797601842>
39. Machine learning-based real-time anomaly detection using data pre-processing in the telemetry of server farms - PubMed, accessed May 8, 2025, <https://pubmed.ncbi.nlm.nih.gov/39375416/>
40. Machine Learning for Time Series Anomaly Detection Ihssan Tinawi - DSpace@MIT, accessed May 8, 2025, <https://dspace.mit.edu/bitstream/handle/1721.1/123129/1128282917-MIT.pdf?sequence=1&isAllowed=y>
41. MSL Telecom Automated Anomaly Detection - NASA Technical Reports Server (NTRS), accessed May 8, 2025, <https://ntrs.nasa.gov/citations/20220000760>
42. Machine learning detects anomalies in OPS-SAT telemetry★ - The International Conference on Computational Science, accessed May 8, 2025, <https://www.iccs-meeting.org/archive/iccs2023/papers/140730301.pdf>
43. Performance Evaluation of Machine Learning Methods for Anomaly Detection in CubeSat Solar Panels - MDPI, accessed May 8, 2025, <https://www.mdpi.com/2076-3417/12/17/8634>
44. Telemetry-mining: A machine learning approach to anomaly detection and fault diagnosis for space systems - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/publication/224640791_Telemetry-mining_A_machine_learning_approach_to_anomaly_detection_and_fault_diagnosis_for_space_systems
45. A look at automated fault management with machine learning - Ericsson, accessed May 8, 2025, <https://www.ericsson.com/en/blog/2019/6/automated-fault-management-machine-learning>
46. An Introductory Review Of Anomaly Detection Methods In Smart Grids - EUDL, accessed May 8, 2025, <https://eudl.eu/pdf/10.4108/eai.7-12-2021.2314604>
47. A Data Preprocessing Based on Cluster and Testing of Parameter Identification Method in Power Distribution Network - MDPI, accessed May 8, 2025, <https://www.mdpi.com/1996-1073/15/21/8007>
48. Full article: A high dimensional functional time series approach to evolution outlier

- detection for grouped smart meters - Taylor & Francis Online, accessed May 8, 2025, <https://www.tandfonline.com/doi/full/10.1080/08982112.2022.2135009>
49. Outlier Detection in Smart Grid Communication - arXiv, accessed May 8, 2025, <https://arxiv.org/pdf/2108.12781>
50. (PDF) Time Series Anomaly Detection for Smart Grids: A Survey - ResearchGate, accessed May 8, 2025, https://www.researchgate.net/publication/356671950_Time_Series_Anomaly_Detection_for_Smart_Grids_A_Survey
51. Machine Learning-Based Fault Location for Smart Distribution Networks Equipped with Micro-PMU - PMC - PubMed Central, accessed May 8, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC8838615/>
52. StruxureWare Power Monitoring Expert | Schneider Electric USA, accessed May 8, 2025, <https://www.se.com/us/en/product-range/61280-struxureware-power-monitoring-expert/>
53. Power Distribution Monitoring and Control - Eaton, accessed May 8, 2025, <https://www.eaton.com/us/en-us/digital/brightlayer/brightlayer-industrial-suite/power-distribution-monitor-and-control.html>
54. Telemetry data explained - Quix, accessed May 8, 2025, <https://quix.io/blog/telemetry-data-explained>