

基于机器学习的无线网络故障预测与诊断

刘亚菲 杨淋舒

郑州电子信息职业技术学院, 河南 郑州 451450

摘要: 随着无线网络在现代社会中的广泛普及, 其复杂性和动态性不断提升, 导致故障问题变得愈发多样且难以诊断。传统的监测与故障定位方法在应对日益庞大的数据量和复杂的网络环境时表现出明显的局限性, 尤其是在实时性和准确性方面。为此, 为了提升无线网络运行的稳定性和故障管理的智能化水平, 本文以机器学习为核心技术, 从数据预处理、特征选择与融合、模型优化等方面探讨故障预测与诊断的实现路径。通过引入深度学习技术, 进一步增强模型对复杂非线性关系的捕捉能力, 为无线网络的高效运行和故障管理提供了理论支持和实践指导, 具有显著的现实意义。

关键词: 机器学习; 无线网络故障; 预测; 诊断

Fault Prediction and Diagnosis of Wireless Network Based on Machine Learning

Liu,Yafei Yang,Linshu

Zhengzhou Professional Technical Institute of Electronic & Information, Zhengzhou, Henan, 451450, China

Abstract: With the wide spread of wireless network in modern society, its complexity and dynamics are constantly improving, which leads to the failure problems becoming more diverse and difficult to diagnose. The traditional monitoring and fault location methods show obvious limitations in dealing with the increasingly huge amount of data and complex network environment, especially in real-time and accuracy. Therefore, in order to improve the stability of wireless network operation and the intelligent level of fault management, this paper takes machine learning as the core technology, and discusses the realization path of fault prediction and diagnosis from the aspects of data processing, feature selection and fusion, model optimization and so on. By introducing deep learning technology, the model's ability to capture complex nonlinear relationships is further enhanced, which provides theoretical support and practical guidance for efficient operation and fault management of wireless networks, and has significant practical significance.

Keywords: Machine learning; Wireless network failure; Forecast; Diagnose

DOI: 10.62639/sspis05.20250203

随着无线网络在各个领域的广泛应用, 其复杂性与多样性日益增加, 使得网络运行中不可避免地面临各种类型的故障。传统的网络监测与诊断方法已难以满足对故障快速、准确定位的需求, 尤其是在数据规模迅速扩大的背景下, 如何高效地从海量数据中挖掘有用信息, 成为亟待解决的问题。在此背景下, 机器学习以其强大的数据处理能力和模式识别能力, 在无线网络故障预测与诊断中崭露头角。从数据预处理到特征提取, 再到故障预测与诊断模型的设计, 机器学习方法不仅丰富了故障管理的技术手段, 更为网络的智能化和自动化运行提供了坚实基础。

一、无线网络故障的类型与特征

(一) 节点故障

在无线网络中, 节点故障是常见的故障类型之一, 节点可能由于硬件损坏、软件故障、能量耗尽等原因而无法正常工作。传感器节点在恶劣的环境中可能会受到物理损坏, 导致无法

采集和传输数据^[1]。此外, 节点的软件可能会出现漏洞或错误, 导致系统崩溃或功能异常。能量耗尽也是节点故障的一个重要原因, 特别是在无线传感器网络中, 节点通常依靠电池供电, 当电池电量耗尽时, 节点将无法工作。

(二) 链路故障

链路故障是指无线网络中通信链路的中断或性能下降。链路故障可能由信号干扰、障碍物阻挡、设备故障等多种原因引起, 在复杂的无线网络环境中, 链路故障的诊断和定位是一个具有挑战性的问题。在物联网中, 大量的无线设备通过不同的通信协议进行连接, 当某个设备出现故障或通信链路受到干扰时, 可能会影响整个网络的性能。

(三) 干扰

干扰也是无线网络中另一个常见的故障类型。干扰可能来自其他无线设备的信号干扰、电磁干扰等外部环境, 也可能来自网络内部, 如节点之间的信号冲突、多径传播等。干扰会导致无线网络的信号质量下降, 影响数据传输的可靠性和效率。例如, 在城市环境中, 大量

(稿件编号: IS-25-3-1004)

作者简介: 刘亚菲 (1998-), 性别: 女, 民族: 汉, 籍贯: 河南省郑州市, 学历本科, 职称助教, 研究方向: 通信工程, 杨淋舒 (2000-), 性别: 女, 民族: 汉族, 籍贯: 河南省郑州市, 学历本科, 职称助教, 研究方向: 通信工程, 电子信息工程, 电气工程。

的无线设备和通信系统共存, 容易产生信号干扰, 影响无线网络的性能。

二、基于机器学习的故障预测方法

(一) 数据预处理

异常值去除: 在基于机器学习的无线网络故障预测中, 异常值的存在会对模型的准确性产生负面影响, 箱线图法等统计方法如是一种常用的异常值去除手段, 绘制数据的箱线图, 可以直观地观察到数据的分布情况, 从而确定异常值的范围并将其去除。除此之外, 孤立森林算法也是一种有效的异常值去除方法, 该算法通过随机分割数据空间, 将异常值孤立较小的子空间中, 从而实现异常值的检测和去除。

信号滤波: 信号滤波可以去除噪声和干扰, 提高数据的质量。低通滤波主要用于去除高频噪声, 保留低频信号成分。高通滤波则相反, 用于去除低频噪声, 保留高频信号成分。带通滤波可以选择特定频率范围内的信号, 去除其他频率的噪声和干扰。在无线网络故障预测中, 根据不同的信号特点和需求, 可以选择合适的滤波方法来提高数据的质量。

(二) 特征选择与融合

在无线网络故障预测中, 特征选择与多特征融合的过程非常关键, 其核心作用在于挖掘和整合数据中蕴含的有效信息, 特征选择作为其中的重要环节, 负责甄别那些与网络状态和潜在故障密切相关的特征, 比如信号强度、信噪比以及误码率等^[2]。这些特征犹如无线网络运行健康状况的“晴雨表”, 变化情况直接折射出潜在问题的蛛丝马迹。聚焦于关键特征, 可压缩数据维度, 随之而来的是计算量的明显减少和模型训练效率的显著提升, 可见该过程有助于抑制冗余特征对模型性能的不良影响, 从而增强预测的精确性。

多特征融合则为模型性能的进一步优化提供了可能, 该方法强调不同特征之间的互补性和协同作用, 将频率域特征、MFCC 特征和时域特征等多种属性整合为一体, 为模型注入多角度、多维度的信息源。具体而言, 频率域特征揭示信号在频率层面的分布规律, 是解析信号特性的有力工具; MFCC 特征则因其在语音信号处理中的卓越表现, 成为探索复杂模式的绝佳选择; 时域特征则以其对信号动态变化的敏锐感知, 提供了不可替代的直观视角。当这些特征被深度融合, 仿佛多种视角的叠加, 模型不再局限于单一特征的约束, 而是得以充分汲取每一类特征的独特优势。

(三) 预测模型

在无线网络故障预测中, 模型的选择直接影响预测的精度和效率, 其中 K 近邻算法 (K-Nearest Neighbor, KNN)、支持向量机 (Support Vector Machine, SVM) 和人工神经网络 (Artificial Neural Network, ANN) 各具特点。KNN 是一种基于实例的学习方

法, 依赖于计算样本之间的距离, 通过公式 $d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$ 确定最近邻样本, 从而对网络状态进行分类, 其简单明了的特性使其在小样本数据中表现优异, 但随着样本量的增加, 其计算复杂度 $O(n^2)$ 迅速攀升, 导致时间消耗增加。相比之下, SVM 基于统计学习理论, 旨在寻找最优超平面 $w \cdot x + b = 0$, 通过最大

化分类间隔 $\frac{2}{\|w\|}$ 实现高效分类, 尤其适用于处理小样本和非线性问题, 但需要谨慎选择核函数 $K(x, y) = \varphi(x) \cdot \varphi(y)$ 及参数, 复杂度依然较高。

ANN 则通过模拟生物神经元的连接模式, 利用激活函数 $f(x) = \frac{1}{1+e^{-x}}$ 映射复杂的非线性关系, 在捕捉网络状态与故障之间的关联方面具有明显优势, 但其训练过程依赖于大量数据, 资源需求显著^[3]。与此同时, 无线网络中的异常值去除方法, 如统计方法 (利用均值或标准差)、基于机器学习的方法 (如孤立森林), 以及基于图信号处理的技术, 则在提升预测效果方面扮演重要角色。综上, 根据网络环境、数据特性及计算资源选择合适的模型与异常值处理方式, 成为优化故障预测的关键路径。

三、基于深度学习的故障诊断方法

(一) 长短期记忆网络

长短期记忆网络 (Long Short-Term Memory, LSTM) 具有出色的处理时序数据的能力, 在故障诊断领域得到了广泛应用。LSTM 是一种特殊的循环神经网络 (RNN), 能够有效地处理长时间序列数据中的长期依赖关系。与传统的 RNN 相比, LSTM 通过引入门控机制, 即输入门、遗忘门和输出门, 能够更好地控制信息的流动和记忆的更新。这使得 LSTM 能够在处理时序数据时, 有效地捕捉到数据中的长期趋势和模式, 对于故障诊断中涉及的时间序列数据, 如传感器采集的设备运行数据等, 具有很强的适应性。例如, 在煤矿变电所故障诊断与预测维护中, 基于 LSTM 的深度学习方法被探讨。文章介绍了人工智能技术在煤矿变电所故障诊断中的应用背景与重要性, 详细阐述了 LSTM 在处理时间依赖数据方面的优势。通过对 LSTM 模型的构建与实验验证, 展示了该模型在准确诊断和预测变电所故障方面的有效性。实验结果表明, LSTM 模型相较于传统时间序列分析法, 在故障诊断的准确率和效率方面有显著提升。

LSTM 模型在多个领域的故障诊断中都有广泛应用, 以锅炉加热器故障诊断为例, 提出了一种基于 LSTM 深度学习模型的方法。将单数据包动态分配到不同节点, 优化信息素更新模式, 引入信息素负载调节因子, 使用蚁群优化算法采集锅炉加热器运行数据; 利用时间序列分析明确异常值特征并创建异常组合模型,

使用迭代检验法实现锅炉加热器数据清洗, 保证故障诊断结果可靠性; 通过 LSTM 深度学习模型筛选强、弱关联数据, 划分锅炉加热器典型故障征兆, 标准化处理数据训练集, 计算实际值和评估值的差异损失, 完成故障诊断目标。实验结果表明, 所提方法故障诊断精准度高、时效性强, 具有优秀的鲁棒性。此外, 在工业故障诊断中, 也有研究利用 LSTM 与其他模型结合, 如一些转移学习模型与 LSTM 结合用于从振动信号中早期检测故障。早期结果显示 VGG19、LSTM 和 InceptionV3 可以在验证集中以 100% 的准确率预测信号中的故障, 而 DenseNet-121、Resnet-50 分别显示出 97% 和 98% 的准确率。

(二) 卷积神经网络

卷积神经网络 (Convolutional Neural Network, CNN) 在提取空间特征方面具有显著优势, 为故障诊断提供了有力的工具, 它可通过卷积神经网络通过卷积层、池化层等结构, 自动学习数据中的空间特征。卷积层中的卷积核可以对输入数据进行局部感知和特征提取, 通过不同的卷积核可以提取不同的特征。池化层则可以对特征进行降采样, 减少数据维度, 同时保留主要特征。这种结构使得 CNN 能够有效地处理图像、信号等具有空间结构的数据。在故障诊断中, 传感器采集的信号或图像数据往往具有一定的空间结构, CNN 可以从中提取出与故障相关的特征。例如, 在滚动轴承智能故障诊断研究中, CNN 作为一种高效的深度学习算法已逐渐成为智能故障诊断领域研究的热点。传统 CNN 模型的全连接层结构存在训练参数量过多的不足, 使得模型训练和测试的时间较长。为此, 提出了一种改进 CNN 的新方法用于滚动轴承故障的快速智能诊断。该方法引入全局均值池化技术代替传统 CNN 的全连接层部分, 有效解决了传统 CNN 模型参数量过多的问题, 并运用数据增强、Dropout 等深度学习训练技巧防止模型过拟合。最后将提出的方法应用于滚动轴承故障实验数据的智能诊断, 并与传统智能诊断算法进行对比验证。结果显示, 改进的 CNN 算法的故障识别准确率高达 99.04%, 在诊断准确率及测试时间方面明显优于传统 CNN 和其他智能算法。

在机械设备智能故障诊断中, 基于卷积神经网络-长短期记忆网络 (Convolutional Neural Network-Long Short Term Memory, CNN-LSTM) 模型的故障诊断方法被提出。分析深度学习在继电保护故障诊断中存在的问题, 详细介绍该模型的结构和算法实现过程。通过收集和实验数据, 对所提出的方法进行验证, 并与传统方法进行对比。结果表明, 所提出的方法具有更好的故障诊断性能。另外, 在电机故障诊断中, 将振动信号视为图像, 使用适合这种处理的算法 CNN, 考虑电机速度开发深度学习算法, 采用合适的模型减少过拟合, 通过降低模型复杂性提高准确性。

(三) 生成对抗网络

生成对抗网络 (Generative Adversarial Network, GAN) 在数据增强中发挥着重要作用, 其核心由生成器和判别器两部分组成。生成器负责生成与真实数据相似的假数据, 而判别器用于区分真实数据与生成数据。通过不断的对抗训练, 这两部分相互促进, 最终生成器能够输出高质量的假数据。在故障诊断中, GAN 特别适合解决数据不平衡问题, 尤其在某些故障样本稀少的情况下, 可以生成更多具有判别性的故障样本, 从而改善模型的特征提取和分类性能。例如, 改进的 GAN 模型使用自动编码器 (AE) 提取少量样本的故障特征, 而非直接生成数据, 并以故障特征和诊断误差为引导进行训练, 从而增强样本的实用性和有效性。滚动轴承实验表明, 基于 GAN 的故障诊断模型在不平衡数据环境下显著提升了分类精度。在行星齿轮箱的故障诊断中, GAN 通过学习原始样本分布, 生成补充样本并优化特征提取, 进一步验证了其处理少样本问题的能力。此外, GAN 与堆叠去噪自动编码器 (SDAE) 的结合也显示出优异的效果, 通过生成增强数据并结合 SDAE 模型, 显著提高了振动信号故障诊断的准确性, 特别是在样本数据有限的条件下。多个研究案例显示, GAN 在旋转机械传动系统、行星齿轮箱等领域的应用, 能够有效提升诊断的精度与鲁棒性, 同时降低维护成本, 为智能故障诊断提供了重要支持。

四、结语

总的来说, 基于机器学习的无线网络故障预测与诊断在保障通信网络稳定运行方面发挥了重要作用。这一框架涵盖了从特征提取、数据预处理到模型优化的各个环节, 并得益于深度学习算法的加入, 大大提高了故障检测的效率和精确性。传统算法如 KNN 和 SVM 以其简单高效的特性, 在小样本和线性问题上表现突出; 而 LSTM、CNN 和 GAN 等深度学习模型则展示了在复杂非线性问题中的潜力。然而, 这些方法仍然需要应对诸如噪声数据的影响、跨场景的泛化能力不足以及多模型融合难度等实际挑战。展望未来, 优化算法以适应不同网络环境的需求, 并深化技术在实际应用中的落地, 将有助于进一步提升网络智能化水平, 推动故障管理能力迈向新的高度。

参考文献:

- [1] 谷奉锦. 基于知识图谱的 5G 网络故障诊断与分析方法研究 [D]. 南京邮电大学, 2023.
- [2] 陈彦. 无线网络中断检测技术研究 [D]. 东南大学, 2019.
- [3] 张恺帆. 数据驱动的无线网络性能分析和预测 [D]. 北京邮电大学, 2022.