

电子通信设备异常信号识别技术研究

章 宇

浙江浙天通信工程有限公司 浙江 宁波 315000

摘 要：本文探讨了电子通信设备中异常信号识别技术的基础理论、研究方法以及面临的挑战与未来发展方向。通过信号处理技术和机器学习算法的融合，提出了针对异常信号的有效识别策略，为电子通信设备的稳定运行提供技术保障。

关键词：电子通信设备；异常信号识别；信号处理技术

引言：随着电子通信技术的飞速发展，通信设备的稳定性和安全性成为日益关注的重点。异常信号识别作为通信设备故障预警和故障诊断的关键技术，对于保障通信质量具有重要意义。本文将从信号处理技术和机器学习算法两个角度，深入探讨异常信号识别技术的研究进展。

1 异常信号识别技术基础理论

1.1 信号处理技术基础

信号处理技术基础是异常信号识别的关键所在。该领域主要分为数字信号处理和模拟信号处理两大分支，各自在不同场景中发挥着重要作用。数字信号处理（DSP）在数字域内对信号进行精细分析、滤波和检测，以其高精度、强抗干扰能力和灵活的处理方式著称。在异常信号识别中，DSP技术能够提取信号的关键特征，如频率、幅度和相位，为信号的分类和识别提供坚实基础。借助快速傅里叶变换（FFT）等技术，DSP将信号从时域转换至频域，使信号特性一目了然。模拟信号处理则在信号初步采集和预处理阶段展现独特优势，能够迅速响应并处理信号，为数字信号处理提供高质量的输入。其中，模拟滤波器作为重要组成部分，负责滤除噪声、提取特定频率成分，从而获得纯净信号。滤波技术是信号处理的核心，能够有效去除原始信号中的噪声和干扰，保证信号的质量。在数字与模拟信号处理中，滤波技术均扮演着关键角色，对提升异常信号识别的准确性和可靠性起着至关重要的作用。

1.2 机器学习与深度学习在异常信号识别中的应用

1.2.1 机器学习在异常信号识别中的应用

随着人工智能技术的飞速发展，机器学习在异常信号识别领域的应用愈发广泛。其中，几种主要方法尤为突出：一是决策树算法。该算法通过学习训练数据，构建树状分类模型。模型内部节点代表属性测试，分支为测试输出，叶节点为分类结果。在异常信号识别中，将

信号特征（如频率、时域波形等）作为输入，通过层层判断确定信号是否异常。二是支持向量机（SVM）。SVM旨在特征空间中找到最优分类超平面，以区分正常与异常信号。利用核函数，SVM能将低维信号特征映射至高维空间，处理非线性可分情况^[1]。在电子通信设备中，提取信号时域、频域特征向量后，SVM能有效识别异常信号，尤其在小样本数据下表现优异。

三是随机森林算法。该算法由多个决策树组成，通过有放回抽样构建决策树，并综合预测结果进行分类。在异常信号识别方面，随机森林抗过拟合能力强，对噪声数据不敏感，能稳健处理复杂通信信号，降低误判率，提高识别准确性。

1.2.2 深度学习在异常信号识别中的应用

深度学习作为机器学习的重要分支，通过构建深层神经网络模拟人脑学习，在异常信号识别中展现显著优势。它能自动从原始信号中提取高层次特征，无需人工设计，泛化能力强，识别精度高。其中，卷积神经网络（CNN）是深度学习在信号识别中的常用方法。CNN具有局部连接、权值共享等特性，擅长处理网格结构数据，如时间序列数据。通信信号在时域上可视为时间序列，经预处理后输入CNN，其卷积层自动提取信号的多层次特征，池化层进一步压缩降维，最后全连接层进行分类，判断信号异常。例如，在光纤通信中，CNN能准确识别因光纤弯曲、损坏等导致的异常光信号。循环神经网络（RNN）及其变体（LSTM、GRU）也适用于异常信号识别。RNN擅长处理序列数据，能记忆和利用信号的前后时序信息，对动态变化的通信信号异常识别特别有效。然而，传统RNN存在梯度问题，其变体LSTM和GRU通过门控机制解决了这一难题。在电子通信设备中，如语音通信，这些网络能依据语音的先后顺序、语调变化等时序特征，精准判断因编码解码错误、信道干扰等导致的异常，实现更精确的异常信号识别。深度学

习在异常信号识别领域的应用,为通信信号的智能监测和维护提供了有力支持。

2 异常信号识别技术研究方法

2.1 数据集构建与预处理

2.1.1 数据集的来源与构建方法

异常信号识别的数据集通常来源于多个渠道,包括实验室环境下的模拟数据、实际通信系统中的监测数据,以及公开数据集等。实验室模拟数据可以根据特定的异常类型(如频率偏移、相位抖动等)进行人工生成,以模拟真实环境中的异常情况。而实际通信系统中的监测数据则更贴近实际应用场景,但往往存在噪声大、标签不完整等问题。公开数据集则为研究者提供了丰富的数据资源,有助于进行算法的比较和验证。在构建数据集时,需要考虑数据的多样性、代表性和平衡性。多样性意味着数据集应包含多种不同类型的异常信号,以涵盖实际应用中可能遇到的各种情况。代表性则要求数据集能够真实反映实际通信系统中的信号特性。平衡性则是指数据集中各类异常信号的比例应相对均衡,以避免算法对某一类信号的过度拟合。

2.1.2 数据预处理技术

数据预处理在异常信号识别中至关重要,直接影响着后续特征提取和模型训练的效果。去噪是数据预处理的首要步骤,旨在消除信号中的噪声,这些噪声可能源自设备本身或传输过程中的干扰。常用的去噪技术有滤波法和小波变换,滤波法通过设计滤波器滤除噪声,但需注意可能损失部分有用信息;小波变换则能在时域和频域同时分析信号,实现更精细的去噪。归一化是另一项关键预处理技术,它将信号数据转换到特定范围,以消除量纲差异对模型训练的影响。最小-最大归一化将数据缩放到0到1之间,而Z-score归一化则根据均值和标准差进行标准化。缺失值处理也不容忽视。在异常信号识别中,由于设备故障或数据传输错误,数据集中可能存在缺失值。处理缺失值的方法有删除法、均值填充法和插值法。删除法虽简单直接,但可能导致数据量减少;均值填充法易操作,但可能引入误差;插值法则根据缺失值前后数据进行计算,能得到更准确的填充值。合理选择数据预处理技术,对于提高异常信号识别的准确性和可靠性具有重要意义。

2.2 特征提取与选择

2.2.1 异常信号的特征分析

异常信号的特征分析是识别过程中的关键环节。特征是指能够描述信号特性的参数或指标,它们对于区分正常信号和异常信号至关重要。异常信号的特征通常包

括时域特征、频域特征、统计特征等。时域特征是指信号在时域上的表现,如信号的幅度、相位、周期等。这些特征能够直观地反映信号的时变特性。频域特征则是信号在频域上的表现,如信号的频率成分、功率谱密度等。频域特征能够揭示信号的频率分布特性。统计特征则是对信号进行统计分析得到的特征,如均值、方差、峰度、偏度等。这些特征能够反映信号的统计特性。

2.2.2 特征提取方法

特征提取是将原始信号转换为特征向量的过程。常用的特征提取方法包括时域特征提取、频域特征提取、变换域特征提取等。时域特征提取通过计算信号的统计量、峰值、过零点等参数来提取特征^[2]。频域特征提取则利用傅里叶变换、小波变换等方法将信号转换到频域,然后提取频率成分、功率谱密度等特征。变换域特征提取则是将信号转换到其他变换域(如希尔伯特变换域、分数傅里叶变换域等)进行特征提取。

2.2.3 特征选择策略与优化

特征选择是从原始特征集中选择出对分类或识别最有用的特征子集的过程。特征选择能够减少计算复杂度、提高模型性能、避免过拟合等问题。常用的特征选择方法包括过滤式、包裹式和嵌入式等。过滤式方法根据特征的相关性、重要性等指标进行筛选,如相关系数法、互信息法等。包裹式方法则是通过构建多个分类器来评估不同特征子集的性能,如递归特征消除法(RFE)、前向/后向搜索法等。嵌入式方法则是在模型训练过程中自动选择特征,如Lasso回归、决策树等。特征选择后,还需要对特征进行优化处理。优化处理包括特征降维、特征变换等。特征降维是通过主成分分析(PCA)、线性判别分析(LDA)等方法将高维特征空间降为低维特征空间,以减少计算复杂度和提高模型性能。特征变换则是通过线性变换、非线性变换等方法将原始特征转换为新的特征空间,以更好地反映信号的特性。

2.3 模型训练与优化

2.3.1 模型训练流程与算法选择

模型训练是将预处理后的数据和提取的特征输入到分类器或回归模型中,通过训练过程得到最优模型参数的过程。模型训练流程包括数据划分、模型构建、训练过程、验证过程等步骤。数据划分是将数据集分为训练集、验证集和测试集。训练集用于训练模型,验证集用于评估模型性能并进行参数调优,测试集则用于最终评估模型的泛化能力。模型构建是根据具体应用场景和数据特性选择合适的分类器或回归模型。常用的分类器包括支持向量机(SVM)、K近邻(KNN)、决策树、随

机森林等。回归模型则包括线性回归、多项式回归、岭回归等。训练过程是通过迭代优化算法不断调整模型参数,使得模型在训练集上的性能达到最优。验证过程则是在验证集上评估模型的性能,并根据评估结果进行参数调优。

2.3.2 超参数调优方法

超参数是模型训练前需要设定的参数,它们对模型的性能具有重要影响。超参数调优是通过搜索不同的超参数组合来找到最优的模型配置。常用的超参数调优方法包括网格搜索、随机搜索、贝叶斯优化等。网格搜索是在指定的超参数范围内进行穷举搜索,找到最优的超参数组合。随机搜索则是在超参数范围内随机选择一组参数进行训练,并多次重复以找到最优配置。贝叶斯优化则是利用贝叶斯定理来指导超参数的搜索过程,通过不断迭代更新超参数的后验分布来找到最优解。

2.3.3 模型性能评估指标

模型性能评估指标是衡量模型性能好坏的标准。在异常信号识别中,常用的评估指标包括准确率、召回率、F1分数等。准确率是指模型正确识别的样本数占总样本数的比例。召回率则是指模型正确识别的异常样本数占实际异常样本数的比例。F1分数是准确率和召回率的调和平均数,用于综合评估模型的性能。除了准确率、召回率和F1分数外,还可以利用混淆矩阵、ROC曲线、AUC值等指标来评估模型的性能。混淆矩阵能够直观地展示模型在各个类别上的识别情况,ROC曲线则能够反映模型在不同阈值下的性能表现,AUC值则是ROC曲线下的面积,用于衡量模型的分类性能。

3 异常信号识别技术的挑战与展望

3.1 面临的挑战

复杂多变的通信环境是异常信号识别技术面临的首要难题。在现代通信系统中,信号传输受到多种因素的影响,如多径效应、衰落、噪声干扰等,这些因素导致接收到的信号往往呈现出高度的复杂性和不确定性^[3]。这种复杂性增加了异常信号识别的难度,因为异常信号可能隐藏在正常的信号波动之中,难以被准确检测和识别。新型异常信号的识别也是一大挑战。随着通信技术的不断进步,新型通信方式和调制技术的不断涌现,异常信号的形式和特征也在不断变化。传统的识别方法往往难以适应这些新型信号,导致识别效果不佳。实时性

与准确性的平衡问题同样不容忽视。在实际应用中,异常信号识别系统需要同时具备高实时性和高准确性。这两者往往存在一定的矛盾。提高实时性可能会牺牲一定的准确性,而追求准确性又可能导致处理时间的延长,影响实时性。如何在保证准确性的前提下提高实时性,是异常信号识别技术面临的又一重要挑战。

3.2 未来发展方向

面对上述挑战,异常信号识别技术需要不断创新和发展,以适应未来通信环境的变化和应用需求。结合人工智能、大数据等新技术,为异常信号识别提供了新的解决方案。人工智能算法,特别是深度学习和强化学习,能够从大量数据中自动学习并提取特征,提高识别的准确性和效率。大数据技术则能够处理和分析海量数据,为异常信号识别提供丰富的数据资源和计算能力支持。通过融合这些新技术,可以构建更加智能、高效的异常信号识别系统。随着物联网、智能交通等领域的快速发展,异常信号识别技术的应用场景也在不断拓展。在物联网领域,异常信号识别可以用于监测设备状态、预警故障等;在智能交通领域,则可以用于识别交通违规行为、预测交通流量等。这些应用领域的拓展为异常信号识别技术提供了更广阔的发展空间和市场前景。为了推动异常信号识别技术的广泛应用和健康发展,需要加强标准化与规范化建设。通过制定统一的技术标准和规范,可以确保不同厂商、不同系统之间的兼容性和互操作性,降低应用成本和技术门槛。

结束语

异常信号识别技术在电子通信设备中发挥着重要作用,对于保障通信质量和设备稳定运行具有重要意义。通过信号处理技术和机器学习算法的融合应用,可以有效提高异常信号的识别精度和效率。面对未来通信环境的变化和应用需求,异常信号识别技术需要不断创新和发展以适应新的挑战。

参考文献

- [1]周燕,孙萌,刘辉.电子通信工程中设备抗干扰接地措施分析[J].数字通信世界,2021(3):124-125.
- [2]任红星,郑海霞.电子通信工程中设备抗干扰的措施[J].电子技术与软件工程,2021(1):3-4.
- [3]梅娟.探究电子信息通信工程中的设备抗干扰接地设计[J].长江信息通信,2021,34(3):174-176,180.