

# 人工智能在铁路信号异常行为识别中的应用研究

魏鹏

国家能源集团新朔铁路有限责任公司新准铁路，甘肃省白银市，730900；

**摘要：**铁路信号系统的稳定运行对保障铁路运输安全至关重要。传统铁路信号异常行为识别方法存在效率低、准确性差等问题，难以满足日益增长的铁路运输需求。随着人工智能技术的快速发展，其在铁路信号异常行为识别中的应用成为研究热点。本文深入探讨了人工智能技术在铁路信号异常行为识别中的应用，详细阐述了基于机器学习和深度学习的异常行为识别方法，通过构建模型、实验验证等步骤，展示了人工智能技术在提高铁路信号异常行为识别准确性和效率方面的显著优势，为铁路信号系统的智能化发展提供了有力支持。

**关键词：**人工智能；铁路信号；异常行为识别；机器学习；深度学习

**DOI：**10.64216/3080-1508.25.08.032

## 引言

铁路作为关键基础设施，在国民经济中地位重要。其信号系统是运输“神经系统”，安全稳定运行直接关系到运输安全与效率。但受设备老化、环境变化、人为失误等影响，信号易出现异常，及时准确识别对保障安全、提升效率意义重大。

传统识别依赖人工经验和简单技术，存在效率低、准确性差、难判复杂异常等局限，已无法满足铁路发展需求。而人工智能凭借强大的数据处理和模式识别能力，能从海量数据中自动学习提取特征，精准识别异常，为信号系统智能化运维提供有力支持。

## 1 铁路信号异常行为概述

### 1.1 铁路信号系统组成及工作原理

铁路信号系统主要由信号机、轨道电路、转辙机、联锁设备、闭塞设备等构成。信号机通过灯光组合传递行车命令；轨道电路检测轨道是否有列车占用，列车进入时其电气参数会变化；转辙机控制道岔转换以选择列车路径；联锁设备借助逻辑运算保障车站内作业安全，实现信号机、道岔和轨道电路的相互制约；闭塞设备确保区间内仅一列列车运行，防止冲突。

该系统基于电气、电子和计算机技术，通过控制与监测各类设备，实现列车自动化控制和安全防护。正常情况下，各部分协同按预定规则运行，保障列车安全高效行驶；若某部分故障或受干扰，可能引发信号异常。

### 1.2 常见铁路信号异常行为类型及表现

常见异常包括信号错误显示、信号丢失、轨道电路故障、道岔故障、联锁故障等。信号错误显示为灯光颜色与命令不符或闪烁不稳；信号丢失指信号机应显示却无显示；轨道电路故障会错误检测列车占用或空闲；道岔故障有不能正常转换、转换不到位、挤岔等，导致路

径错误；联锁故障破坏设备间联锁关系，引发安全隐患。这些异常会影响列车运行，甚至导致事故，需及时识别处理。

### 1.3 铁路信号异常行为对铁路运输的影响

信号异常对铁路运输影响多方面。一是导致列车运行秩序混乱，出现晚点、停车，影响旅客出行和货物运输时效；二是排查处理异常需投入大量人力、物力和时间，增加运营成本；三是若未及时处理，可能引发严重安全事故，造成人员伤亡和财产损失，带来巨大社会负面影响。因此，提升信号异常识别能力对保障铁路运输安全高效意义重大。

## 2 人工智能技术在铁路信号异常行为识别中的应用优势

### 2.1 强大的数据处理能力

铁路信号系统在运行过程中会产生海量的数据，包括信号状态数据、设备运行数据、环境监测数据等。传统的数据分析方法难以对如此庞大的数据进行快速、有效的处理。人工智能技术，特别是机器学习和深度学习算法，具有强大的数据处理能力，能够自动从大量的数据中提取有用的信息和特征。例如，深度学习中的神经网络模型可以通过构建多层神经元，对数据进行层层抽象和特征提取，从而发现数据中的潜在模式和规律，为铁路信号异常行为识别提供有力的数据支持。

### 2.2 高效的模式识别能力

铁路信号异常行为往往具有一定的模式和特征，但这些模式和特征可能非常复杂，难以通过人工经验进行准确识别。人工智能技术具有高效的模式识别能力，能够通过大量历史数据的学习，建立起准确的异常行为识别模型。一旦模型训练完成，就可以快速、准确地识

别出实时信号数据中的异常行为模式。例如，支持向量机（SVM）算法可以通过寻找一个最优的分类超平面，将正常信号数据和异常信号数据准确地区分开来，实现高效的模式识别。

### 2.3 实时监测与预警功能

利用人工智能技术，可以对铁路信号系统进行实时监测，及时发现异常行为并发出预警。通过将实时采集的信号数据输入到已经训练好的异常行为识别模型中，模型可以迅速判断信号是否正常，并在发现异常时立即发出警报。这使得铁路运维人员能够在第一时间采取措施，避免异常行为进一步发展导致严重后果。与传统的定期巡检和事后维修方式相比，人工智能的实时监测与预警功能大大提高了铁路信号系统的安全性和可靠性。

### 2.4 持续学习与优化能力

铁路信号系统的运行环境是动态变化的，新的异常行为类型可能不断出现。人工智能技术具有持续学习与优化能力，能够随着新数据的不断积累，自动对异常行为识别模型进行更新和优化。通过增量学习、在线学习等技术手段，模型可以不断适应新的情况，提高对各种异常行为的识别能力，保持良好的性能表现。这种持续学习与优化能力使得人工智能技术在铁路信号异常行为识别中具有更强的适应性和生命力。

## 3 基于机器学习的铁路信号异常行为识别方法

### 3.1 机器学习算法简介

机器学习是多领域交叉学科，旨在让计算机从数据中学习模式并用于预测和决策。常见算法有决策树、随机森林、支持向量机、朴素贝叶斯、K近邻等。决策树以树形结构分类预测，内部节点为属性测试，叶节点为类别；随机森林由多个决策树构成集成模型，综合多树结果提升准确性与稳定性；支持向量机通过最优分类超平面实现数据分类；朴素贝叶斯基于贝叶斯定理和特征条件独立假设分类；K近邻算法计算待分类样本与训练样本的距离，依据最近的K个样本类别判定其类别。

### 3.2 基于机器学习的异常行为识别流程

该流程主要包含数据采集与预处理、特征提取与选择、模型训练与评估、异常行为识别与预测步骤。先通过传感器等采集铁路信号系统的信号状态、设备参数、环境信息等数据；再对数据预处理，去除噪声、填补缺失值、归一化以提升质量；接着从预处理数据中提取信号强度、频率等特征，并筛选出对识别最关键的特征；然后选合适算法，用训练数据训练模型并调整参数至最佳性能；最后用训练好的模型对实时信号数据识别预测，

判断是否异常。

### 3.3 特征提取与选择方法

准确提取和选择有效特征是铁路信号异常识别的关键。特征提取方法有三种：时域提取从时间序列中获取均值、方差等；频域提取通过傅里叶变换得到频率成分等频域特征；时频域提取结合时域和频域信息，如小波变换等。特征选择可采用过滤法，依据信息增益等统计信息筛选；包装法将特征选择与学习算法结合，按算法性能选择；嵌入法在模型训练中自动选择重要特征。合理运用这些方法能提高识别模型的准确性和效率。

### 3.4 模型训练与评估指标

选好算法和特征后，需用训练数据训练模型，通过调整参数使模型准确分类或预测，常用梯度下降法、随机梯度下降法等训练方法。模型训练完成后，需用准确率、召回率、F1值、精确率等指标评估性能。准确率是正确预测样本占总样本的比例；召回率是正确预测的正样本占实际正样本的比例；F1值综合准确率和召回率；精确率是预测为正且实际为正的样本占预测正样本的比例。全面评估可筛选出最佳模型用于铁路信号异常识别。

## 4 基于深度学习的铁路信号异常行为识别方法

### 4.1 深度学习技术特点及优势

深度学习是机器学习的分支，通过构建多层神经网络，从海量数据中自动学习复杂模式与特征。其核心优势在于强大的特征学习能力，可自动提取高级特征，无需人工设计。相较于传统机器学习，它在处理大规模、高维度、复杂数据时表现更优，能通过深层网络对数据层层抽象，深入理解内在规律，且泛化能力良好，在不同数据集和场景中均能保持较好性能。

### 4.2 深度学习模型在铁路信号异常行为识别中的应用

铁路信号异常识别中常用的深度学习模型有卷积神经网络（CNN）、循环神经网络（RNN）及变体长短期记忆网络（LSTM）。CNN凭借卷积层、池化层和全连接层结构，擅长提取图像、信号的局部与全局特征，广泛应用于铁路信号机图像识别、波形分析等，如识别信号机显示状态是否正常。RNN及LSTM则适合处理时间序列数据，能捕捉铁路信号随时间变化的依赖关系，精准预测异常，例如通过LSTM分析轨道电路电压、电流等时序参数，预测其是否会发生故障。

### 4.3 基于卷积神经网络的异常行为识别模型构建

该模型通常包含输入层、卷积层、池化层、全连接

层和输出层。输入层接收预处理后的铁路信号数据，形式可为波形图、图像等。卷积层通过卷积核滑动进行卷积操作，提取局部特征；池化层对特征图下采样，减少数据量和计算复杂度，同时保留关键特征；全连接层将池化层输出的特征向量全连接，映射到不同类别空间；输出层借助 softmax 等激活函数，输出数据属于各类别的概率，实现异常识别。构建时需结合应用场景和数据特点，合理选择卷积核大小、层数、步长等参数以优化性能。

#### 4.4 基于循环神经网络的异常行为识别模型构建

模型主要由输入层、循环层、全连接层和输出层构成。输入层输入铁路信号的时间序列数据；循环层是核心，逐时间步处理时序数据，捕捉时间依赖关系，可采用 RNN 单元或 LSTM 单元，其中 LSTM 通过输入门、遗忘门和输出门解决传统 RNN 的梯度消失与爆炸问题，更适合长序列数据。全连接层和输出层功能与 CNN 模型类似，对循环层输出特征进行全连接和分类，输出异常识别结果。构建时需依据信号时序特点，设置合适的隐藏层大小、时间步长等参数以提升模型性能。

### 5 实验验证与结果分析

#### 5.1 实验数据采集与预处理

为验证人工智能在铁路信号异常识别中的有效性，需采集大量实际运行的铁路信号数据，涵盖正常与各类异常信号，采集设备包括传感器、监测终端等，以确保信息准确。采集的数据存在噪声、缺失值等问题，需预处理：先用高斯滤波、中值滤波等去除噪声，再通过插值法、均值填充法填补缺失值，最后归一化处理，将数据映射到  $[0, 1]$  或  $[-1, 1]$  区间，提升模型训练效率与准确性。

#### 5.2 实验设置与模型训练

实验选用基于机器学习的随机森林算法，及基于深度学习的卷积神经网络、循环神经网络构建识别模型。预处理后的数据按比例分为训练集、验证集和测试集，分别用于模型训练、参数调整评估及泛化能力测试。训练中需设置合适参数，如学习率、迭代次数等，对随机森林调整树的数量等参数，对卷积和循环神经网络调整卷积核大小等参数，通过多次训练与验证找到最佳参数配置。

#### 5.3 实验结果对比与分析

用测试集测试模型，获取准确率、召回率等指标。对比发现，深度学习模型在各指标上均优于机器学习的随机森林模型。其中，卷积神经网络擅长处理图像类数

据，能精准识别信号机异常显示；循环神经网络在时间序列数据处理上有优势，对轨道电路、道岔等设备异常预测准确率高，为实际选模型提供依据。

#### 5.4 模型性能评估与优化建议

评估模型除基本指标外，还需考虑运行效率与泛化能力。运行效率上，分析不同硬件平台的运行时间和内存占用，低效模型可通过压缩、剪枝优化；泛化能力方面，用不同场景数据测试，不足时可增加训练数据、采用数据增强或调整模型结构。全面评估与针对性优化，能提升模型实用性与可靠性。

### 6 结论与展望

#### 6.1 研究成果总结

本文研究了人工智能在铁路信号异常识别中的应用，阐述了信号异常类型、影响及 AI 应用优势，介绍了基于机器学习和深度学习的识别方法，包括相关算法、流程、特征处理及模型构建。实验验证显示，深度学习模型识别准确率和召回率更高，为提升铁路信号系统安全性提供了新技术支持。

#### 6.2 研究不足与展望

研究存在不足：实验数据覆盖范围和多样性有限，影响模型泛化；模型融合与优化研究不深入；模型部署运维面临实时性匹配、解释性不足等挑战。

未来需扩大数据采集范围，利用物联网建多样化数据集；加强模型融合创新，结合新兴技术解决小样本问题；推动实际落地，开发轻量化模型并提升解释性，结合数字孪生技术，加强跨学科合作以促进技术发展。

#### 参考文献

- [1] 王得福. 基于人工智能的网络异常行为检测研究[D]. 北京邮电大学, 2020.
- [2] 李思远. 铁路信号系统网络流量异常行为检测方法研究[D]. 北京交通大学, 2024.
- [3] 付淳川. 高速铁路信号系统网络安全风险评估方法研究[D]. 西南交通大学, 2017.
- [4] 姚一杨, 聂礼强, 战新刚, 等. 复杂场景下基于人工智能的变电站内异常行为识别与检测方法: CN202010102771. 7[P]. CN111339883A[2025-08-24].
- [5] 宋佳明. 基于人工智能的网络异常行为分析[D]. 北京邮电大学[2025-08-24].

作者简介：魏鹏（1986.05.06—），男，汉族，甘肃会宁人，全日制本科学历，助理工程师，研究方向：铁路信号方向。