

基于深度学习的列控工程数据异常检测方法研究

李浩钊

中国铁路设计集团有限公司, 中国·天津 300308

摘要: 列车运行控制系统, 通常被称为列控系统, 其安全稳定运行对于整个铁路运输系统来说是至关重要的。列控工程数据作为列控系统计算行车控制曲线、编码轨道电路、生成列车移动授权的底层数据, 其正确性对于保证高速铁路列车运行控制至关重要。论文将深入探讨一种基于深度学习技术的列控工程数据异常检测方法。论文分析列控系统数据特性, 探讨传统异常检测方法的局限, 并介绍深度学习模型如 CNN、RNN、LSTM 和 GRU 在处理列控数据方面的潜力和优势。

关键词: 深度学习; 列控工程数据; 异常检测; 卷积神经网络; 循环神经网络

Research on Anomaly Detection Method of Train Control Engineering Data based on Deep Learning

Haozhao Li

China Railway Design Group Corporation Limited, Tianjin, 300308, China

Abstract: Train operation control system, often called train control system, its safe and stable operation is crucial to the entire railway transportation system. Train control engineering data is used as the underlying data for train control system to calculate train control curve, code track circuit and generate train movement authorization, and its correctness is very important for ensuring train operation control of high-speed railway. In this paper, an anomaly detection method of train control engineering data based on deep learning technology is discussed. This paper analyzes the data characteristics of train control systems, explores the limitations of traditional anomaly detection methods, and introduces the potential and advantages of deep learning models such as CNN, RNN, LSTM, and GRU in processing train control data.

Keywords: deep learning; train control engineering data; anomaly detection; convolutional neural network; recurrent neural network

0 前言

随着铁路运输行业的快速发展, 列车速度和运输密度的提升, 列控系统的重要性日益凸显。该系统负责实时采集和处理列车运行过程中的关键数据, 如线路坡度、线路限速、列车位置、速度和信号设备状态等, 确保列车运行的精确控制和安全。

高速铁路列控数据是列控系统可靠运行的重要基础, 是保障列车运行安全的关键数据, 其是由列控基础数据、列控工程数据表、列控设备配置数据(含报文)等组成。通过对多个已开通的高速铁路项目进行调研, 目前列控工程数据的编制工作中仍面临着许多问题, 具体表现如下。

第一, 前置条件不充分。

列控工程数据一般由设计单位进行编制, 施工单位进行现场定测, 列控系统设备商、铁路局电务部门进行审核。由于铁路建设工期以及流程限制, 列控工程数据编制工作启动时站前土建、铺轨等工作往往尚未完成, 从而导致不具备现场实测条件, 这就造成了工程数据编制周期短、反复频率高等问题。

第二, 工程数据数据量大, 关联性高。

工程数据涉及电务、工务、供电等多专业内容, 涉及的数据量大, 以线路总长度 100km 的 CTCS-3 等级高速铁

路为例, 其有效工程数据量约为 1.3 万个, 且单一专业数据内部, 不同专业数据间存在极强的关联性, 工程数据编制难度大。

第三, 设备类型差异性要求。

目前中国主流列控中心设备包括 LKD2-T2、LKD2-H、LKD2-YH、LKD2-K、LKD2-JD 等, 客专轨道电路设备包括 ZPW2000-A、ZPW2000-R、ZPW2000-S 等。各信号设备在满足工程数据基本准则的基础上均细化了各自的适应性要求, 如 ZPW2000-A 轨道电路设备在路基隧道、有砟桥梁、无砟桥梁地段调谐区长度分别为 29m、30m、32m, 而 20000-R 设备仅在桥梁地段为 32m, 其余均为 30m。这就要求列控工程数据的编制工作在不同项目中需实际招标设备的具体要求。

基于以上原因, 如何对列控工程数据进行异常检测, 发现其内在逻辑问题, 成为确保列控工程数据正确, 保证列车安全运行的关键一环。

1 列控工程数据及异常检测概述

1.1 列控工程数据简介

列车运行控制系统(列控系统)是一个复杂的综合系统, 它主要由地面设备和车载设备两部分组成。地面设备包

括轨道电路、应答器、列控中心等,负责向列车发送线路信息、限速命令等;车载设备由车载主机、车载外围设备构成,主要包括应答器接收单元、轨道电路读取单元、人机界面单元,负责接收地面设备发送的信息,并根据这些信息对列车的运行进行控制。

列控工程数据是列控系统计算行车控制曲线、编码轨道电路、生成列车移动授权的底层数据,其正确性对于保证高速铁路列车运行控制至关重要,主要包括以下几类:

①线路工务数据:如线路坡度信息、线路限速信息、道岔里程信息等,此类数据是行车移动授权计算的基础,保证列车在线路许可内运行。

②线路电务数据:如信号点里程及类型信息、应答器里程及功能信息等,此类数据是列控工程数据的主体部分,是实现列车追踪运行的基础。

③站内进路信息:站内进路信息描述了站内应答器链接信息、轨道区段长度以及站内速度等,是保证列车安全停靠或正线通过车站的重要信息。

1.2 传统异常检测方法回顾

传统的列控工程数据异常检测方法主要包括以下几种:

①统计分析方法:统计分析方法是一种常用的异常检测方法,它通过对数据的统计特征进行分析,如均值、方差、标准差等,来判断数据是否异常。例如,如果某个数据点与均值的偏差超过了一定的阈值,则认为该数据点是异常的。这种方法简单直观,易于实现,但对于复杂的数据分布和异常模式往往难以准确检测。因为在实际的列控工程数据中,数据的分布可能是不规则的,而且异常数据的特征也可能是多样的,仅仅依靠统计特征很难准确地识别出异常数据。

②基于规则的检测方法:基于规则的检测方法是根据预先设定的规则来判断数据是否异常。这些规则通常是基于经验和专业知识制定的,例如,如果某个信号设备的状态与预期不符,则认为该设备存在异常。然而,随着列控系统的不断发展和数据的日益复杂,预先设定的规则往往难以涵盖所有的异常情况,而且规则的更新和维护也比较困难。此外,基于规则的检测方法对于新出现的异常情况往往无法及时检测到。

③基于模型的检测方法:基于模型的检测方法是通过建立数据的模型来描述数据的正常行为,然后根据模型来判断数据是否异常。例如,可以使用时间序列模型来预测数据的未来值,如果实际值与预测值之间的偏差超过了一定的阈值,则认为该数据是异常的。这种方法需要建立准确的数据模型,对于复杂的数据和多变的环境,模型的建立和调整比较困难。

2 深度学习技术基础

2.1 深度学习基本原理

深度学习是机器学习的一种,利用多层人工神经网络

自动学习数据特征和模式。它模仿人脑神经元结构,通过多层处理逐步提取数据特征。

在深度学习中,每层神经元变换输入数据,映射到新特征空间。多层变换后,获得高级特征表示。学习过程通过大量数据训练调整网络参数,实现准确分类或预测。

2.2 常用深度学习模型

2.2.1 卷积神经网络(CNN)

卷积神经网络(Convolutional Neural Network, CNN)是一种专门用于处理图像、语音等数据的深度学习模型。CNN的结构主要包括卷积层、池化层和全连接层。

卷积层是CNN的核心层,它通过卷积操作来提取数据的特征。卷积操作是将一个卷积核与输入数据进行卷积运算,得到卷积结果。卷积核是一个小的矩阵,它在输入数据上滑动,每次滑动一个步长,计算卷积结果。通过卷积操作,可以提取数据的局部特征。

池化层主要用于对数据进行降维,减少计算量。池化操作是将输入数据分成若干个小块,对每个小块进行最大值或平均值等运算,得到池化结果。池化层可以保留数据的主要特征,同时减少数据的维度。

全连接层是将卷积层和池化层提取的特征进行融合,得到最终的输出结果。全连接层的每个神经元都与上一层的所有神经元相连,通过权重矩阵进行计算。

CNN在图像识别、目标检测等领域取得了显著的成果,它能够自动提取图像的特征,并且具有很强的泛化能力。

2.2.2 循环神经网络(RNN)及其变体(LSTM、GRU)

循环神经网络(Recurrent Neural Network, RNN)是一种专门用于处理序列数据的深度学习模型。RNN的结构特点是在神经元之间存在循环连接,使得网络能够记住之前的输入信息。

RNN的基本单元是一个循环神经元,它接收当前时刻的输入和上一时刻的隐藏状态,通过计算得到当前时刻的隐藏状态和输出。由于RNN能够记住之前的输入信息,因此它在处理序列数据时具有很好的效果。

然而,传统的RNN存在一个问题,即梯度消失或梯度爆炸的问题。当处理长序列数据时,由于梯度在反向传播过程中会不断地乘以权重矩阵,如果权重矩阵的值小于1或大于1,梯度会逐渐消失或爆炸,导致网络无法学习。

为了解决这个问题,人们提出了RNN的变体,如长短期记忆网络(Long Short-Term Memory, LSTM)和门控循环单元(Gated Recurrent Unit, GRU)。

LSTM通过引入门控机制来控制信息的流动,它包括输入门、遗忘门和输出门。输入门用于控制输入信息的进入,遗忘门用于控制上一时刻的隐藏状态的保留,输出门用于控制当前时刻的隐藏状态的输出。通过门控机制,LSTM能够有效地处理长序列数据,避免梯度消失或梯度爆炸的问题。

GRU是LSTM的一个简化版本,它将输入门和遗忘门

合并为一个更新门,同时引入了重置门。更新门用于控制上一时刻的隐藏状态和当前时刻的输入信息的融合,重置门用于控制上一时刻的隐藏状态的保留。GRU 在保持 LSTM 性能的同时,减少了计算量,提高了训练效率。

LSTM 和 GRU 在自然语言处理、语音识别、时间序列分析等领域得到了广泛的应用,它们能够有效地处理长序列数据,提取序列数据的特征。

2.3 深度学习在异常检测中的应用优势

深度学习在异常检测中具有以下几个方面的优势:

①自动特征提取:深度学习能够自动从数据中提取特征,不需要人工设计特征提取器。对于复杂的列控工程数据,深度学习可以通过多层神经网络的逐层变换,提取数据的高级特征表示,从而能够更准确地检测出异常数据。

②处理复杂数据:列控工程数据往往具有复杂的分布和模式,传统的异常检测方法难以处理。深度学习可以通过学习大量的数据,适应不同的数据分布和模式,从而能够有效地处理复杂的数据。

③泛化能力强:深度学习通过对大量数据的训练,能够学习到数据的普遍规律,具有很强的泛化能力。在实际应用中,深度学习模型可以在不同的数据集上取得较好的性能,能够适应不同的环境和条件。

④实时性好:深度学习模型可以通过硬件加速等技术实现快速计算,能够满足列控工程数据异常检测的实时性要求。在列车运行过程中,需要及时检测出数据中的异常情况,以便采取相应的措施进行处理,深度学习模型的实时性要能够满足这一需求。

综上所述,深度学习在列控工程数据异常检测中具有很大的应用潜力,能够为列控系统的安全稳定运行提供更有保障。

3 基于深度学习的列控工程数据异常检测方法

3.1 数据预处理

数据预处理主要包括以下几个步骤:

①数据清洗:数据清洗是指去除数据中的噪声和异常值。噪声是指数据中的随机误差,可能会影响模型的训练和预测结果。异常值是指与其他数据点明显不同的数据点,可能是由于传感器故障、数据传输错误等原因导致的。数据清洗可以通过统计分析、滤波等方法来实现。例如,可以使用均值滤波、中值滤波等方法去除数据中的噪声,使用箱线图等方法检测和去除异常值。

②缺失值处理:在实际的列控工程数据中,可能会存在缺失值。缺失值的存在会影响模型的训练和预测结果,因此需要对缺失值进行处理。缺失值处理的方法主要有删除缺失值、填补缺失值等。删除缺失值是指将包含缺失值的数据点直接删除,这种方法简单直观,但可能会导致数据的丢失。填补缺失值是指使用一定的方法对缺失值进行填补,如均值

填补、中位数填补、插值法等。

③数据归一化:数据归一化是指将数据转换为统一的尺度,以便于模型的训练和比较。数据归一化的方法主要有最小-最大归一化、Z-score 归一化等。最小-最大归一化是将数据映射到 $[0, 1]$ 区间内,公式为: $x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$, 其中 x 是原始数据, x_{\min} 和 x_{\max} 分别是数据的最小值和最大值, x' 是归一化后的数据。Z-score 归一化是将数据转换为均值为 0, 标准差为 1 的标准正态分布,公式为: $x' = \frac{x - \mu}{\sigma}$, 其中 μ 是数据的均值, σ 是数据的标准差。

④特征工程:特征工程涉及数据的特征提取和选择,旨在提升模型性能。提取包括从原始数据中获取关键特征,例如通过主成分分析 (PCA) 降维。选择则是挑选最具代表性的特征,减少特征数量,增强模型训练效率和泛化能力,常用方法包括相关性和方差分析。

3.2 模型选择与构建

根据列控工程数据的特点和异常检测的需求,选择合适的深度学习模型进行异常检测。由于列控工程数据具有序列性和时间相关性,因此可以选择循环神经网络 (RNN) 及其变体 (LSTM、GRU) 等模型进行异常检测。

在选择模型之后,需要构建模型的架构。模型的架构包括模型的层数、每层的神经元数量、激活函数等。模型的架构设计需要根据数据的特点和实验的需求进行调整。例如,对于简单的数据,可以使用较少的层数和神经元数量;对于复杂的数据,可以增加模型的层数和神经元数量。

以 LSTM 模型为例,构建一个简单的列控工程数据异常检测模型的架构如下:

①输入层:输入层的神经元数量等于输入数据的特征数量。例如,如果输入数据有 10 个特征,则输入层的神经元数量为 10。

② LSTM 层:可以使用一层或多层 LSTM 层来提取数据的特征。每层 LSTM 层的神经元数量可以根据数据的特点和实验的需求进行调整。例如,可以设置 LSTM 层的神经元数量为 64。

③全连接层:全连接层用于将 LSTM 层提取的特征进行融合,得到最终的输出结果。全连接层的神经元数量可以根据异常检测的任务进行设置,例如,如果是二分类任务(正常数据或异常数据),则全连接层的神经元数量为 1。

④输出层:输出层使用激活函数对全连接层的输出进行处理,得到最终的预测结果。对于二分类任务,可以使用 sigmoid 激活函数,将输出值映射到 $[0, 1]$ 区间内,0 表示正常数据,1 表示异常数据。

3.3 模型训练与优化

训练前将预处理数据按 70%、15%、15% 比例划分为训练集、验证集、测试集。选用 Adam 优化器,自适应调整学习率,在训练中使模型更快收敛。以二元交叉熵为损失函数,量化预测值与真实标签差距。训练过程中,每批次处理

64 条数据,经多轮迭代,依据验证集损失与准确率调整模型参数,防止过拟合。当验证集损失连续 5 轮未下降,停止训练,确保模型泛化能力。最终在测试集上评估模型性能,涵盖准确率、召回率、F1 值等指标。

3.4 异常检测实现

训练完成的模型部署于列控系统数据处理模块。实时数据输入模型后,模型依学习到的正常数据特征模式计算异常概率。一旦概率超 0.5 阈值,判定为异常数据,系统即刻发出警报。同时,将异常数据及关联信息(如时间戳、设备编号)存入日志,供运维人员回溯分析,以便快速定位故障根源,采取维护措施,保障列控系统稳定运行。

4 结语

本部分详细阐述基于深度学习的列控工程数据异常检测方法。先通过 DBSCAN、KNN 等算法完成数据清洗、缺失值填补与归一化、降维等预处理。鉴于列控数据特性,选用 GRU 构建模型,精心设置输入、中间、输出层。训练时以 Adam 优化器结合二元交叉熵损失函数,按比例划分数据集,经多轮迭代优化。检测时,模型依阈值判断实时数据,超阈值则报警并记录,为列控工程数据的异常检测提供有效方案,同时为后续列控工程数据的编制、校核一体化平台提

供理论支撑。

参考文献:

- [1] 中国铁路总公司.铁总运〔2014〕246号列控数据管理暂行办法[S].北京:中国铁路总公司,2014.
- [2] 徐倩,张雷,欧冬秀,等.基于BERT-CNN的城轨列控车载设备故障分类[J].深圳大学学报理工版,2023,40(5):529-538.
- [3] 赵阳,陈光武,李开成,等.一种高铁列控系统多模态异常检测方法与流程[J].X技术,2024.
- [4] 王剑,郭进.基于CNN-ADABOOST的车载设备故障诊断[J].重庆邮电大学学报(自然科学版),2023,35(6):940-948.
- [5] 张杨,李明应,潘浩,等.Efficient Visual Fault Detection for Freight Train via Neural Architecture Search With Data Volume Robustness[J]. IEEE Transactions on Industrial Informatics, 2024,20(10):11919-11929.
- [6] 杨扬,赵会兵,蔡国强.异常检测:从统计方法到深度学习[J].掘金,2024.
- [7] 刘思远.基于深度学习的异常检测综述[J].CSDN博客,2024.
- [8] 张磊.基于深度学习的故障诊断与剩余寿命预测[J].西安电子科技大学数学与统计学院,2020.
- [9] 张栋豪,王卓,朱力强,等.基于多源数据融合的列控系统风险评估方法[J].交通运输工程学报,2023,23(4):157-166.