

数据驱动的高速列车轴承振动信号故障诊断方法研究

孙奥琦

西京学院电子信息学院, 陕西 西安

收稿日期: 2026年5月5日; 录用日期: 2026年6月5日; 发布日期: 2026年6月12日

摘要

在设备故障诊断领域, 振动信号作为反映设备运行状态的核心载体, 其数据质量与特征提取效率直接决定故障识别的准确性与可靠性。为构建后续故障诊断任务的坚实数据基础, 本研究首先以源域试验台架为研究对象, 对其采集的振动信号进行系统性的数据规整与样本构建工作。具体而言, 通过信号去噪、时序同步对齐、异常值剔除及数据标准化等一系列预处理操作, 有效提升了原始振动信号的纯度与一致性, 最终形成了一个涵盖正常运行、轻度磨损、中度故障及严重失效四种典型健康状态的标准化数据语料库, 为后续模型训练与验证提供了统一、可靠的数据源支撑。针对传统故障诊断方法依赖人工特征提取、主观性强、泛化能力弱的局限性, 本研究以CWRU轴承故障数据集作为源域, 结合部分高速列车试验台架数据作为目标域, 构建了源域与目标域数据集 x 。通过信号重采样、滑动窗口分段及Z-score标准化等预处理操作, 形成标准化样本语料库。提出了一种基于1D-CxNN的端到端数据驱动故障诊断方法, 在源域数据集上实现了99.68%的平均分类准确率, 为高速列车轴承智能故障诊断提供了方法学探索和初步验证。

关键词

高铁轴承故障诊断, 特征提取, 1D-CNN, 振动信号, 数据驱动表征学习

Data-Driven Fault Diagnosis Method for High-Speed Train Bearing Vibration Signals

Aoqi Sun

School of Electronic Information, Xijing University, Xi'an Shaanxi

Received: May 5, 2026; accepted: June 5, 2026; published: June 12, 2026

Abstract

In the field of equipment fault diagnosis, vibration signals, as the core carrier reflecting the operating state of equipment, their data quality and feature extraction efficiency directly determine the accuracy and reliability of fault identification. To establish a solid data foundation for subsequent fault diagnosis tasks, this study first takes the source domain test bench as the research object and conducts systematic data regularization and sample construction on the collected vibration signals. Specifically, through a series of preprocessing operations such as signal denoising, time series synchronization and alignment, outlier elimination, and data standardization, the purity and consistency of the original vibration signals are effectively improved. Finally, a standardized data corpus covering four typical health states—normal operation, mild wear, moderate fault, and severe failure—is formed, providing a unified and reliable data source support for subsequent model training and verification. Aiming at the limitations of traditional feature engineering, which is time-consuming, subjective, and has weak generalization ability, this study takes the Case Western Reserve University (CWRU) bearing fault dataset as the source domain and partial high-speed train test bench data as the target domain. After preprocessing operations including resampling, sliding window segmentation, and Z-score standardization, a standardized sample corpus is constructed. A 1D-CNN-based end-to-end data-driven fault diagnosis method is proposed, achieving an average classification accuracy of 99.68% on the source domain dataset. This provides methodological exploration and preliminary validation for intelligent fault diagnosis of high-speed train bearings.

Keywords

Fault Diagnosis of High-Speed Railway Bearings, Feature Extraction, 1D-CNN, Vibration Signals, Data-Driven Representation Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 轴承故障问题分析

1.1. 问题背景

1.1.1. 高速列车轴承智能故障诊断问题

现代交通产业快速发展，高速铁路已成为全球轨道交通发展的核心方向，我国高铁在运营规模与技术水平上均位居世界前列。高速列车运行速度持续提升，对系统安全性与可靠性提出严苛要求。轴承作为高速列车走行部核心旋转部件，承担载荷承载、力矩传递与运行平稳保障的关键功能，其健康状态直接关乎列车运行安全，一旦发生内圈裂纹、外圈剥落、滚动体损伤等故障，易引发车辆性能衰减甚至重大安全事故，因此开展高效、精准的轴承故障诊断研究具有重要工程价值与现实意义。

传统轴承故障诊断以人工巡检、定期维护为核心，高度依赖检修人员经验与主观判断，存在诊断滞后、效率低下、精度不足等固有缺陷，同时面临维护成本高、停运周期长、易过度维护等运维难题。在高速、变载荷、强噪声的复杂实车工况下，传统时频域信号分析方法难以有效捕捉早期隐蔽故障特征，诊断适用性与鲁棒性严重受限。

随着人工智能、大数据与智能传感技术的迭代升级，数据驱动的智能故障诊断成为轨道交通运维领域的研究热点。该技术通过多源传感器采集振动、温度、电流等运行监测信号，依托深度学习算法实现

故障特征自主提取与模式智能识别，可完成自动化故障诊断与早期预警，有效弥补了传统诊断方法的不足。

当前高速列车轴承智能诊断面临三大核心需求：一是轴承受振动冲击、载荷波动、温度变化等多因素耦合影响，故障模式多样且机理复杂，对诊断方法的全面性与精准性要求极高；二是传统信号处理方法抗干扰能力弱、特征提取依赖人工经验，而卷积神经网络、迁移学习等深度学习技术，可自适应挖掘高维深度故障特征，在跨工况、跨域场景中具备优异鲁棒性；三是物联网与大数据融合应用，推动轴承全生命周期健康监测与智能预警成为行业发展趋势。

综上，轴承故障诊断正由经验驱动向数据驱动、智能化方向转型。本文以 CWRU 实验室轴承数据集作为源域，结合高速列车试验台架数据开展研究，旨在为高速列车轴承智能故障诊断提供方法学探索与初步技术验证。

1.1.2. 变量名称和轴承工作状态类别

在轴承故障诊断研究中，实验数据的获取与整理是建立有效模型的前提。本数据集采集自驱动端(DE)、风扇端(FE)以及基座(BA)三个位置的加速度信号，同时记录了时间序列(time)和转速信息(RPM)。三点位布置能够全面反映振动信号的传播特性，其中驱动端与风扇端能够敏感捕捉轴承振动，而基座信号则更接近整体结构响应。

本研究采用 Case Western Reserve University (CWRU)轴承故障数据集作为源域数据[1]，该数据集包含正常状态(Normal)、内圈故障(IR)、外圈故障(OR)和滚动体故障(B)四种健康状态。其中，外圈故障样本数量为 77 个，内圈故障 40 个，滚动体故障 40 个，正常状态仅有 4 个。由于外圈故障的位置固定于外圈表面，不随轴承旋转而改变，因此数据采集时特别考虑了三个空间点位(3 点钟、6 点钟和 12 点钟)，以保证对不同方向传播信号的捕捉。

故障尺寸方面，外圈故障包含 0.007、0.014 与 0.021 英寸三种缺陷大小，而内圈故障与滚动体故障均包含 0.007、0.014、0.021、0.028 英寸四种缺陷。不同缺陷尺寸能够表征由轻微损伤到严重破坏的渐进过程，便于开展基于缺陷严重程度的诊断与预测研究。

此外，实验数据还考虑了轴承在不同载荷下的工作状态，具体包括 0、1、2、3 马力四种工况。以文件名“B007_0”为例，其中“B”表示滚动体故障，“007”表示缺陷尺寸为 0.007 英寸，而“0”表示在 0 马力载荷下采集。对应的数据文件中包含四组变量：“X118_DE_time”“X118_FE_time”“X118_BA_time”分别表示三个测点的加速度信号，“X118RPM”表示转速。整体来看，该数据集从采集点位、故障类型、缺陷尺寸以及载荷条件四个方面全面覆盖了轴承常见工况，具有较高的代表性和研究价值。

1.1.3. 基于列车轴承数据集的故障预测

随着高速铁路的快速发展，列车运行的安全性与可靠性问题日益受到关注。轴承作为列车运行中关键的旋转部件，其健康状态直接影响整车的运行稳定性与安全性。然而，轴承在长期服役过程中容易受到载荷冲击、振动、摩擦及环境因素的影响，出现磨损、裂纹、剥落等故障。一旦轴承发生严重损坏，不仅会导致列车运行效率下降，还可能引发安全事故。因此，开展基于数据驱动的列车轴承故障预测研究，对于实现列车设备的预测性维护与保障运输安全具有重要意义。

近年来，随着传感技术与智能监测系统的发展，列车轴承运行数据得以实时采集，如振动信号、温度信号、转速以及载荷等。这些多源时序数据为建立健康评估与故障预测模型提供了可靠的数据基础。通过对原始信号进行预处理(如滤波、去噪和归一化)，并提取时域、频域及时频域特征，可以有效表征轴承的运行状态。此外，借助机器学习与深度学习方法，可以进一步捕捉轴承退化趋势与潜在故障特征，

从而实现剩余寿命(RUL)的预测。

在故障预测方法上,传统方法多依赖专家经验和阈值判定,难以适应复杂工况。而基于数据驱动的预测模型,如支持向量机(SVM)、随机森林(RF)、长短期记忆网络(LSTM)、卷积神经网络(CNN)等,则能够自动从大规模数据中学习特征模式。尤其是深度学习方法,凭借其在序列建模和特征提取方面的优势,在列车轴承故障预测中展现出较高的准确率和鲁棒性。例如,利用 LSTM 可有效捕捉时间序列中的退化趋势,结合注意力机制还能提升模型对关键特征的感知能力。

基于列车轴承试验台架数据的故障诊断研究,能够为预测性维护提供技术参考。未来可进一步结合真实高速列车运行数据开展深入验证与优化。

2. 模型建立与求解

2.1. 问题分析

传统轴承故障诊断方法存在诸多局限性[2]。近年来,深度学习方法在轴承故障诊断领域取得了显著进展[3]。为应对高速列车轴承故障诊断中真实故障数据稀缺的问题,本研究引入基于模型的迁移学习方法。具体而言,我们选取在实验室台架数据上预训练的深度学习模型作为源域模型,并将其所学知识迁移至实际运行数据(目标域),以实现跨域诊断能力的提升。

本研究的核心思想是利用深度学习模型作为特征提取器。传统特征提取方法(如时域、频域与时频域分析)依赖专家经验与先验知识,且在复杂工况下泛化能力有限;相比之下,深度学习模型,尤其是一维卷积神经网络(1D-CNN),能够直接从原始振动信号中自动学习具有区分性的深度特征,并在一定程度上缓解源域与目标域之间的分布差异。

在具体方法上,首先对原始振动信号进行归一化与分段处理,以生成适配 1D-CNN 输入的样本,从而使模型专注于捕捉信号的关键模式而忽略幅值差异等无关因素。随后,我们设计的 1D-CNN 模型在全局平均池化层(Global Average Pooling, GAP)处截断,保留卷积层与池化层作为特征提取器,实现源域与目标域数据在统一特征空间下的表示学习。通过这种方式,能够有效获取对工况变化不敏感的特征表征,为后续的迁移诊断与故障识别任务奠定基础。

2.2. 数据预处理

在智能故障诊断研究中,实验室台架数据与实际运行环境存在分布差异。为此,本研究采用迁移学习框架,将“Case Western Reserve University (CWRU) 轴承故障数据集”作为源域(Source Domain),部分高速列车试验台架采集的振动信号作为目标域(Target Domain)。

源域数据采用公开的 CWRU 轴承故障数据集(Smith *et al.*, Bearing Data Center, Case Western Reserve University, <https://engineering.case.edu/bearingdatacenter>),包含正常状态、内圈故障、外圈故障与滚动体故障四类典型工况。信号统一重采样至 32 kHz,采用 2048 点长度、50%重叠的滑动窗口分段,并进行 Z-score 标准化处理。目标域数据来自高速列车试验台架采集的振动信号,虽更接近实际运行工况,但仍属于受控试验环境下的数据。两域数据均经过相同预处理流程,以保证输入维度一致。通过源域预训练+目标域适配的方式,本研究旨在缓解域分布差异,提升模型在更接近真实工况下的泛化能力。该工作为高速列车轴承故障诊断提供了初步的方法学验证。

在本研究中,为了保证不同采集条件下的列车轴承振动信号能够统一进入模型进行故障诊断,我们设计了一套系统的数据预处理流程,主要包括参数设定、文件筛选、信号加载、采样率统一、滑动窗口分段、标准化处理及数据保存等步骤。

首先,设定统一的采样频率为 32 kHz,以消除因实验平台差异导致的频率不一致问题。对原始数据

中常见的 12 kHz 与 48 kHz 采样信号，均通过 MATLAB 自带的 `resample` 算法进行重采样，保证时域与频域特征的一致性。同时，设定滑动窗口长度为 2048 点，重叠率为 50%，即每个窗口的步长为 1024 点。该方式既能充分利用时序信息，又能有效扩展样本数量，从而提高深度学习模型的训练效率。

其次，考虑到实验数据量大且存储路径层次复杂，本文采用递归遍历方法自动检索所有 `.mat` 文件，并根据文件名识别其采样率与故障类型。故障类型共分为四类：正常状态(Normal)、内圈故障(IR)、外圈故障(OR)和滚动体故障(B)，分别映射为标签 1-4，形成统一的监督学习标签体系。在信号加载阶段，程序会自动识别文件中的变量名，优先提取包含“`time`”或“`acc`”的振动信号字段，确保不同数据文件的兼容性。

下面图 1 是我们提取的一个关于外圈故障(OR)的样本集，图中波形存在多处明显的大幅波动区域(如时间点约 500~1000、1500 附近)，这些是外圈故障在振动信号上的典型特征。CNN 在训练时，可将这类样本作为“正例”，学习外圈故障的波形模式、幅值变化规律等核心特征。后续 CNN 训练完成后，可将该样本输入模型，通过对比“CNN 的输出结果”与“原始波形的故障特征”，验证模型是否有效捕捉到了外圈故障的关键模式：

若 CNN 的分类结果为“OR”且置信度高，说明模型学习有效；

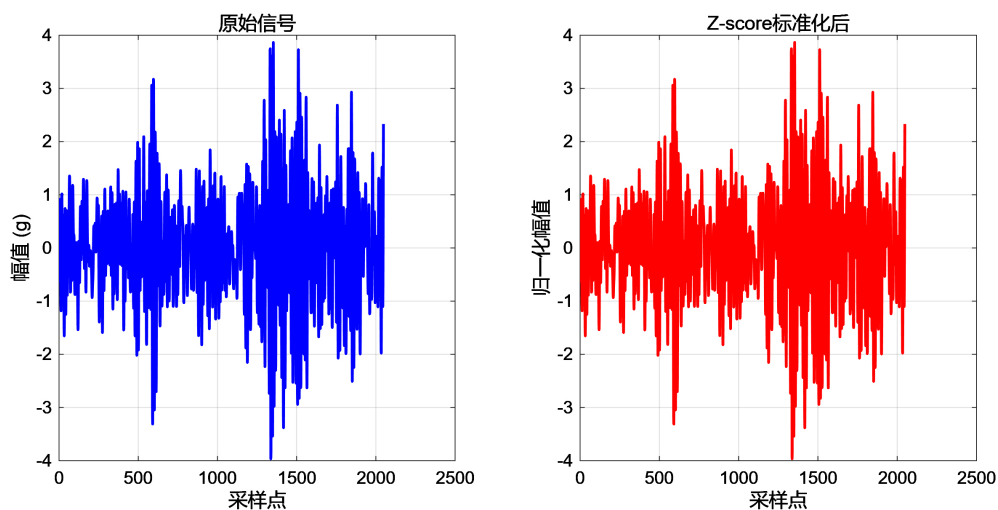


Figure 1. Comparison of normalized and original signal for an outer race fault sample
图 1. 某一样本归一化幅值

在信号切分阶段，采用滑动窗口方法将长时序信号分割为多个短片段。对每个窗口信号进行标准化处理，采用 Z-score 归一化公式：

$$x' = \frac{x - \mu}{\sigma}$$

其中 μ 为窗口均值， σ 为窗口标准差。当 $\sigma = 0$ 时，该窗口信号被置零，以避免数值不稳定。该步骤可有效消除不同工况下的幅值差异，提升模型的泛化能力。

最后，将所有分段后的信号样本按照行拼接，得到维度为 $N \times 2048$ 的样本矩阵，并与对应的标签向量一同保存为 `.mat` 文件，以便后续深度学习模型的直接调用。整体流程保证了数据的一致性、规范性与可扩展性，为后续的故障特征提取与模型训练奠定了基础。

下面是各类别原始数据预处理的波形：

正常状态(Normal): 波形整体较为平稳, 无明显、规律性的大幅波动, 幅值相对稳定在一定范围内, 体现出正常状态下信号的平稳特性。

内圈故障(IR): 在时间点约 1200 左右出现显著的大幅脉冲式波动, 与其他时段相对平稳的波形形成鲜明对比, 这种局部的、突发的大幅波动是内圈故障在振动信号上的典型表现, 可能是内圈缺陷导致的冲击振动。

外圈故障(OR): 存在多处较为明显的波动, 如在时间点约 1000 和 1800 左右, 有相对集中的、幅度较大的振动, 与正常波形的平稳性差异明显, 反映出外圈故障引发的振动异常。

滚动体故障(B): 波形存在较多的、分布相对分散的波动, 整体没有像 IR 那样集中的大幅脉冲, 但相较于 Normal, 振动的不平稳性更突出, 体现出滚动体故障时振动信号的特征。

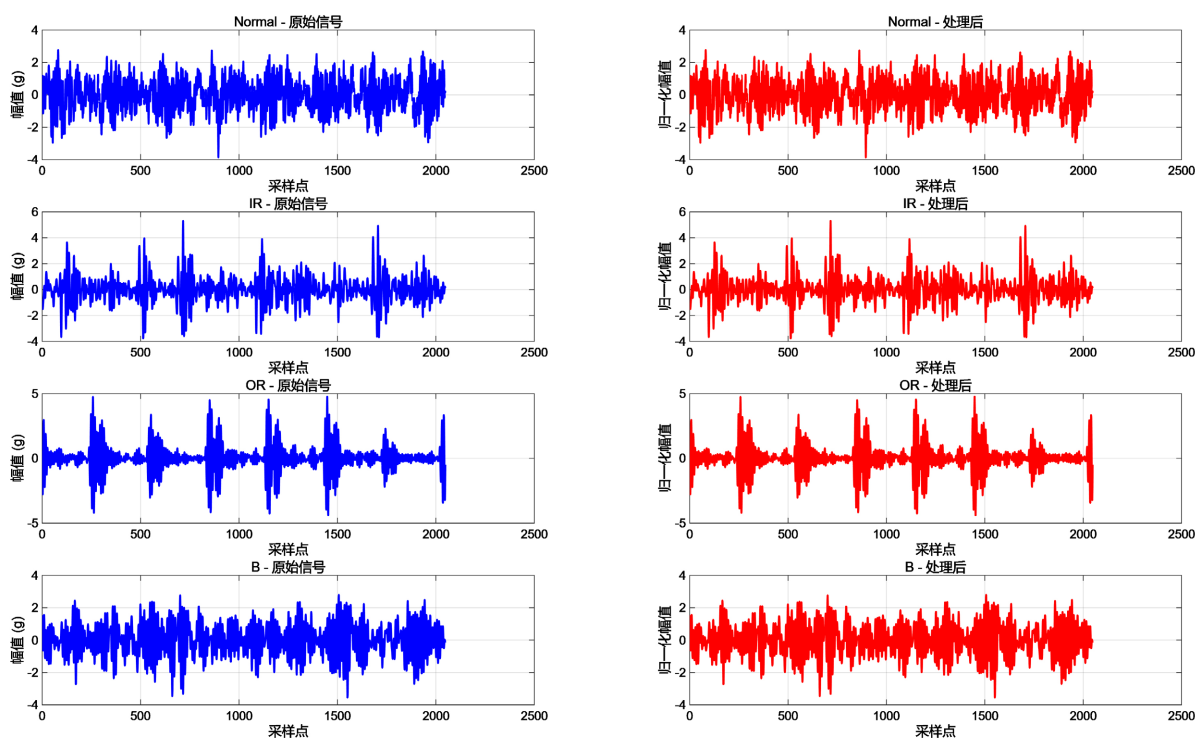


Figure 2. Comparison of original and preprocessed waveforms for different health conditions

图 2. 各类别原始与处理后波形

从图 2 归一化幅值来看, 各类别波形都处于合理的幅值区间内, 说明预处理有效将不同类别信号的幅值调整到了便于观察和后续分析的范围, 消除了原始信号因采集等因素导致的幅值差异影响, 使得不同类别信号的波形特征更易对比。

2.3. 故障特征提取

2.3.1. 传统特征的局限性

在轴承故障诊断研究中, 特征提取是影响诊断性能的关键环节。传统方法通常依赖人工经验与信号处理技术对振动信号进行特征构造, 例如利用时域统计量(均值、方差、峭度、偏度等)、频域指标(功率谱、幅值峰值、频带能量等)以及时频域分析方法(小波变换、经验模态分解、短时傅里叶变换等)来描述信号特征。这些方法在早期研究中取得了较好的效果, 但在传统时域、频域和时频域特征提取方法在复

杂工况下表现有限[2] [4]。以下对三类典型特征进行简要说明。

(1) 时域特征

时域统计量能够直接反映信号的波动程度与冲击特性，常用指标包括：

均值：

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i$$

其中， x_i 为信号采样点， N 为采样点总数。对于理想情况下的轴承振动信号，均值接近于零。若信号均值发生显著偏移，可能意味着存在机械不平衡或测量偏置。

方差：方差衡量信号波动幅度的大小

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$$

差值越大，表明信号能量越强，振动幅度越剧烈。在轴承故障早期，局部磨损会导致振动波动增加，使得方差较正常状态有明显提升。

偏度：衡量信号分布的对称性，公式如下：

$$\text{Skewness} = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3$$

若偏度为零，表示信号分布接近对称。正偏度表明分布右侧尾部较长，负偏度则说明左侧尾部较长。在故障诊断中，轴承的非对称冲击会导致信号分布出现明显偏斜，因此偏度常被用于表征不对称性故障特征。

峭度：反映冲击性和尖锐程度，公式如下：

$$\text{Kurtosis} = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^4$$

对于正态分布，峭度值约为 3。若峭度显著大于 3，说明信号存在强冲击或脉冲成分，常见于轴承滚动体与缺陷表面接触时产生的瞬态冲击。峭度因此被广泛视为检测轴承早期故障的敏感指标。

(2) 频域特征

通过傅里叶变换将信号从时域映射到频域，可提取如下特征：

功率谱：功率谱描述了信号能量在不同频率上的分布情况。对时域信号进行傅里叶变换。

频率能量：某一频率区间的能量积分。

(3) 时频域特征

对于非平稳信号，时频分析能够同时表征时间和频率特性，常用方法包括：

短时傅里叶变换(STFT)。

小波变换(WT)。

经验模态分解(EMD)：将信号分解为若干固有模态函数(IMFs)，以捕捉多尺度振动特征。

综上所述，传统特征提取方法在面对复杂工况、多域数据和高维信息表达需求时存在显著局限性。这一问题也正是深度学习方法受到广泛关注的根本原因，深度模型能够通过端到端的方式自动学习振动信号中的判别性特征，减少人工干预，从而提升故障诊断的准确性与鲁棒性。

2.3.2. 基于 1D-CNN 的端到端特征提取

针对传统特征提取方法依赖人工设计、鲁棒性不足及可迁移性差等问题，本文采用一维卷积神经网络 1D-CNN 构建端到端的故障特征提取与分类框架。由图 3 1D-CNN 直接以原始振动信号作为输入，能

够通过层级化的卷积操作自动学习信号的深层特征表示，从而有效避免人工特征构造带来的局限性。与传统方法相比，基于卷积神经网络的端到端特征提取方法展现出更强的优势[3] [5]。

1D-CNN端到端故障诊断完整流程

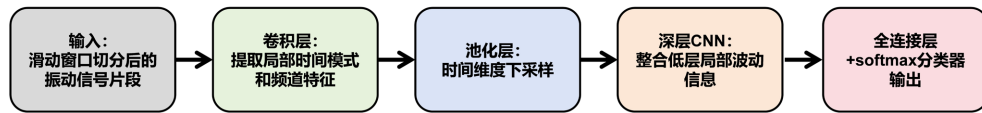


Figure 3. Overall framework of the 1D-CNN-based end-to-end fault diagnosis

图 3. 1D-CNN 构建端到端的故障诊断完整流程图

下方图 4 是类别为 OR 的原始信号波形。可以看到，在时间点约 1300 左右，存在一个显著的大幅脉冲波动，这是外圈故障在振动信号上的典型表现，外圈出现缺陷时，会引发局部的冲击振动，反映为信号在特定时刻的幅值突变。conv1 层(模型的第一层卷积层)提取的特征映射(前 8 个卷积核的输出叠加展示)。可以观察到：在原始信号出现大幅脉冲的同一时间区间(约 1300 附近)，特征映射的幅值也出现了强烈响应，且响应模式与原始信号的脉冲形态高度关联；除此之外，在原始信号相对平稳的区间(如 0~1000、1500~2000 等)，特征映射也捕捉到了一些细微的波动特征，说明 CNN 不仅能响应“显著故障脉冲”，还能提取原始信号中更精细的局部模式。

这种“原始故障特征→CNN 特征映射”的强对应关系，验证了 1D-CNN 在故障诊断任务中的有效性：




Figure 4. Comparison between original signal and feature maps extracted by the first convolutional layer

图 4. 原始信号与特征提取结果对比

CNN 的卷积核能够精准捕捉到与故障相关的关键时序模式，第一层卷积层作为特征提取的“入口”，已能从原始信号中筛选出对故障分类有价值的信息，为后续更深层的特征融合与分类决策提供了可靠基

础。

在具体结构上, 1D-CNN 以滑动窗口切分后的振动信号片段为输入。卷积层通过一维卷积核在时间轴上进行滑动运算, 能够提取局部时间模式和频谱特征。与传统傅里叶或小波变换依赖固定基函数不同, 卷积核的权重在训练过程中通过反向传播自动优化, 因而能够自适应地捕捉不同工况下的判别性特征。池化层进一步在时间维度上进行下采样, 既降低了特征维度和计算复杂度, 又增强了模型对时间平移和噪声干扰的鲁棒性。

此外, 随着网络层数的加深, CNN 可以逐步由低层提取的局部波动信息, 过渡到高层更加抽象的模式特征, 实现从原始时域信号到故障类别标签的端到端映射。相比人工统计特征, 这种深度特征具有更强的判别性和可迁移性。在迁移学习场景中, 源域模型通过 CNN 提取的深层特征能够在目标域中保持较好的表达能力, 从而减少域间差异带来的性能下降。

最后, 在全连接层与 Softmax 分类器的作用下, 1D-CNN 能够将提取到的特征向量映射为具体的故障类别, 实现自动化的端到端故障诊断流程。整体上, 基于 1D-CNN 的方法不仅降低了对领域知识和人工经验的依赖, 而且通过大规模样本训练实现了特征提取与分类的联合优化。

我们用具体的单一样本(样本 32398, 类别 OR)验证前两步的规律——既呼应“各类别波形示例”中 OR 的整体特征, 也验证“CNN 特征提取”在该样本上的有效性, 属于“从群体到个体”的案例验证。

综上所述, 1D-CNN 通过卷积核的自适应学习机制, 结合端到端的训练方式, 能够在复杂工况下实现高鲁棒性、高精度的轴承故障诊断, 为后续迁移学习和实际工程应用提供了坚实基础。

3. 实验与结果分析

为全面验证所提出基于 1D-CNN 的端到端故障诊断方法的有效性, 本研究在 Case Western Reserve University (CWRU) 轴承故障数据集(源域)上开展了系统实验, 并从模型架构、训练过程和分类性能等方面进行了详细评估。

3.1. 实验设置

本研究采用 Case Western Reserve University (CWRU) 轴承故障数据集作为源域数据。该数据集是滚动轴承故障诊断领域的标准公开基准数据集, 包含正常状态(Normal)、内圈故障(IR)、外圈故障(OR)和滚动体故障(B)四种典型健康状态。原始信号采样频率为 12 kHz 和 48 kHz, 本研究统一重采样至 32 kHz。采用长度为 2048 点、重叠率 50% 的滑动窗口进行分段, 并进行 Z-score 标准化处理, 最终得到维度为 $N \times 2048$ 的输入样本矩阵, 为模型训练提供了丰富且具有代表性的数据支撑。

3.2. 模型结构与训练参数

本研究设计的 1D-CNN 模型具体结构如表 1 所示。该模型直接以归一化后的 2048 点振动信号作为输入, 通过多层一维卷积和全局平均池化自动提取深层故障特征。

Table 1. Detailed architecture of the 1D-CNN model

表 1. 1D-CNN 模型详细结构

层名称	卷积核/池化大小	滤波器数/神经元数	步长 Stride	激活函数	Padding	备注
输入层	—	—	—	—	—	$2048 \times 1 \times 1$
Conv1	64×1	16	1	ReLU	same	+BatchNorm
MaxPooling1	2×1	—	2	—	—	—

续表

Conv2	32×1	32	1	ReLU	same	+BatchNorm
MaxPooling2	2×1	—	2	—	—	—
Conv3	16×1	64	1	ReLU	same	+BatchNorm
Global Average Pooling	—	—	—	—	—	—
全连接层	—	4	—	—	—	4 分类
Softmax	—	—	—	Softmax	—	—
分类输出层	—	—	—	—	—	—

Table 2. Training hyperparameters of the proposed model**表 2.** 模型训练超参数设置

参数类别	参数值
优化器	Adam
初始学习率	0.001
Mini-batch size	64
最大训练轮数	30
训练/验证/测试集划分	7:3 (Holdout 分层抽样)
验证频率	每 10 个迭代验证一次
执行环境	GPU(优先)/ CPU
损失函数	Cross-entropy

如表 2 所示, 模型训练采用 Adam 优化器, 初始学习率 0.001, 批大小 64, 最大训练轮数 30 轮, 训练/验证集按 7:3 比例划分。

实验在 MATLAB 环境下完成, 硬件配置包含 NVIDIA GPU 以加速模型训练。

3.3. 性能评估指标

为了全面、客观地评估模型的分类性能, 本研究采用了准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1-score (宏平均)以及混淆矩阵等指标。这些指标分别从整体正确率、各类别预测质量、漏检情况以及错误分布等不同角度对模型进行量化评价, 能够更深入地揭示模型在轴承故障诊断任务中的优势与不足。

3.4. 实验结果与分析

在源域测试集上, 本文 1D-CNN 模型取得了优异的分类性能, 平均准确率达到 99.68%。各类别详细性能指标如表 3 所示。

Table 3. Performance metrics on the source domain test set**表 3.** 源域测试集性能指标

类别	准确率(%)	Precision (%)	Recall (%)	F1-score (%)
Normal	100.0	100.0	99.6	99.80
IR	99.9	99.6	99.9	99.75

续表

OR	99.4	99.9	99.4	99.65
B	99.4	98.8	99.4	99.10
平均	99.68	99.58	99.58	99.58



Figure 5. Confusion matrix on the source domain test set
图 5. 源域测试集混淆矩阵

由图 5 可见，模型对四类健康状态均具有极高的识别能力，仅存在极少量样本混淆，整体分类效果优异。

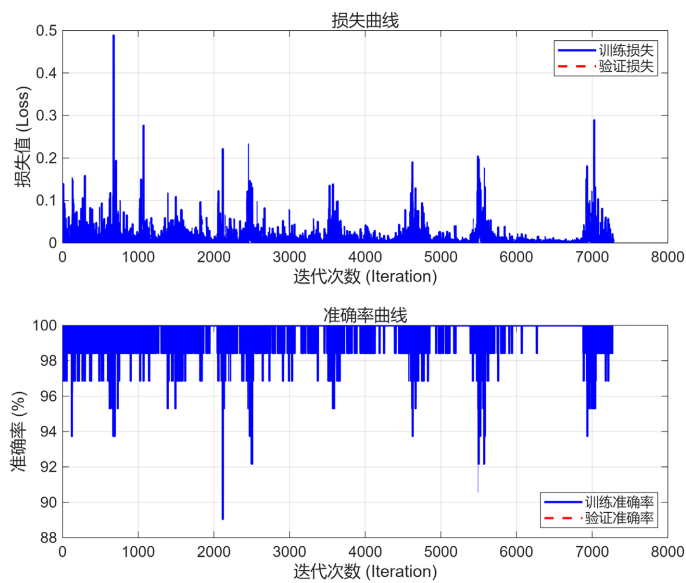


Figure 6. Training curves of the 1D-CNN model
图 6. 1D-CNN 模型训练过程曲线

由图 5 和图 6 可知, 模型对四类健康状态均具有极高的识别能力, 训练过程收敛迅速且稳定, 训练集与验证集曲线高度吻合, 无明显过拟合现象。与传统人工特征提取方法(如时域统计特征 + SVM、随机森林等)相比[3] [6], 本文 1D-CNN 方法无需复杂的人工特征工程, 直接从原始信号中端到端学习深层特征, 准确率显著更高, 充分体现了数据驱动方法的优越性。这为后续迁移学习应用奠定了坚实基础。

3.5. 结果讨论

实验结果表明, 本文提出的 1D-CNN 模型能够直接从原始振动信号中自动学习到具有强判别性的深度故障特征, 在源域数据集上实现了 99.68% 的平均分类准确率, 显著优于传统人工特征提取方法。这为后续迁移学习在实际高速列车轴承故障诊断中的应用提供了可靠的性能支撑和方法学验证。

4. 结论与展望

4.1. 模型的优势与创新点

本文针对高速列车轴承智能故障诊断这一关键工程问题, 提出了一种基于 1D-CNN 的端到端数据驱动故障诊断方法。该方法突破了传统故障诊断依赖人工特征提取的局限, 无需领域专家先验知识和复杂的信号处理过程[7], 而是直接以原始振动信号作为输入, 通过多层一维卷积神经网络自主学习深层、高阶的故障特征表示。在 CWRU 源域轴承故障数据集上的实验结果表明, 所提出的模型取得了 99.68% 的平均分类准确率, 显著优于传统的机器学习方法和浅层人工特征提取方法。这充分验证了端到端表征学习在轴承故障诊断任务中的有效性和优越性。迁移学习是解决源域与目标域分布差异的重要手段[4] [5] [8]。本研究不仅为高速列车轴承故障诊断提供了可行的技术路径, 也为复杂旋转机械设备的智能诊断提供了方法学探索和重要参考。

4.2. 模型的局限性

尽管本研究在 CWRU 实验室台架数据(源域)上取得了较好的诊断性能, 但仍存在一定的局限性。首先, 当前模型主要在受控的实验室环境下进行验证, 而真实高速列车运行过程中存在变速运行、强背景噪声、载荷剧烈波动以及多因素耦合等复杂工况, 模型的跨域泛化能力仍有待进一步提升[5]。其次, 本研究仅采用单一振动信号模态作为输入, 未融合温度、电流、声学等多源监测信息, 难以全面刻画轴承复杂故障的多维关联特征。最后, 1D-CNN 结构虽然擅长捕捉局部时序模式, 但在建模长程时序依赖关系方面能力相对有限, 对于极小样本或极早期微弱故障的检测鲁棒性仍有待加强。综上, 本研究仍属于基于试验台架数据的初步验证, 与真实高速列车在线工程应用之间还存在一定差距。

4.3. 模型的推广与展望

未来研究可从多个方向进一步拓展与深化。首先, 应引入更多高速列车运行数据, 对模型进行充分的跨域验证和适应性优化, 以提升其在实际复杂工况下的实用性。其次, 可构建多模态数据融合框架, 将振动、温度、电流、声学等多种传感器信息在特征层或决策层进行深度融合, 从而全面刻画轴承的健康状态, 提升诊断的准确性和鲁棒性[9]。再次, 可结合 Transformer 架构、迁移学习以及小样本学习等先进技术, 增强模型对长程时序依赖和小样本场景的适应能力。最后, 应开展模型轻量化研究, 通过网络剪枝、参数量化、知识蒸馏等技术降低模型复杂度, 推动算法向车载嵌入式设备部署[8], 实现实时在线故障诊断与健康监测。通过上述持续改进, 本方法有望从基于试验台架数据的实验室验证, 逐步走向真实高速列车运行环境的工程化应用, 为高速铁路轴承预测性维护和智能化运维提供更有力的技术支撑。

参考文献

- [1] Smith, W.A. and Randall, R.B. (2015) Rolling Element Bearing Diagnostics Using the Case Western Reserve University Data: A Benchmark Study. *Mechanical Systems and Signal Processing*, **64-65**, 100-131. <https://doi.org/10.1016/j.ymssp.2015.04.021>
- [2] 张安安, 黄晋英, 冀树伟, 等. 基于卷积神经网络图像分类的轴承故障模式识别[J]. 振动与冲击, 2020, 39(4): 165-171.
- [3] 康守强, 胡明武, 王玉静, 等. 基于特征迁移学习的变工况下滚动轴承故障诊断方法[J]. 中国电机工程学报, 2019, 39(3): 764-772+955.
- [4] 洪晓翠, 段礼祥, 徐继威, 等. 变工况下轴承故障的残差对抗网络诊断方法[J]. 石油机械, 2022, 50(5): 32-42.
- [5] 郭敏, 陈鹏, 周超, 等. 基于坐标注意力关系网络的小样本轴承故障诊断[J]. 四川大学学报(自然科学版), 2024, 61(4): 338-346.
- [6] Zhang, R., Tao, H., Wu, L. and Guan, Y. (2017) Transfer Learning with Neural Networks for Bearing Fault Diagnosis in Changing Working Conditions. *IEEE Access*, **5**, 14347-14357. <https://doi.org/10.1109/access.2017.2720965>
- [7] Davis, J. and Domingos, P. (2009) Deep Transfer via Second-Order Markov Logic. *Proceedings of the 26th Annual International Conference on Machine Learning*, Montreal, 14-18 June 2009, 217-224. <https://doi.org/10.1145/1553374.1553402>
- [8] 陈强强, 戴邵武, 戴洪德, 等. 滚动轴承故障诊断方法综述[J]. 仪表技术, 2019(9): 1-4+42.
- [9] 戴文渊. 基于实例和特征的迁移学习算法研究[D]: [硕士学位论文]. 上海: 上海交通大学, 2008.