

1-4-2019

## Fault Diagnosis of High Speed Train Bogie Based on Multi-domain Fusion CNN

Yunpu Wu

*School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;*

Weidong Jin

*School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;*

Yingkun Huang

*School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Fault Diagnosis of High Speed Train Bogie Based on Multi-domain Fusion CNN

## Abstract

**Abstract:** The performance degradation and failures of high-speed train bogie components directly threaten the operation security of train. A fault detection method based on multi-domain fusion convolutional neural network is proposed to address the high complexity, high coupling and strong nonlinearity of vibration signals. *Noise injection for time domain signal is used to enhance noise robustness and generalization of the model. Signal time-frequency representation information is obtained through embedded time-frequency transformation layer. Adaptive weight-based fusion is implemented through intrinsic characteristics of the convolutional neural network to handle the multi-domain multi-channel information.* The experimental results show that the proposed method improves the accuracy of fault diagnosis of high-speed train bogies with good noise robustness and adaptability to work condition.

## Keywords

high speed train bogie, fault diagnosis, multi-domain fusion, convolutional neural network

## Recommended Citation

Wu Yunpu, Jin Weidong, Huang Yingkun. Fault Diagnosis of High Speed Train Bogie Based on Multi-domain Fusion CNN[J]. Journal of System Simulation, 2018, 30(11): 4492-4497.

# 基于多域融合 CNN 的高速列车转向架故障检测

吴昀璞, 金炜东, 黄颖坤

(西南交通大学电气工程学院, 四川 成都 610031)

**摘要:** 高速列车转向架在服役运行中发生构件的性能退化和各类故障会严重威胁到列车的运行安全。针对高速列车振动信号的高复杂度、高耦合和强非线性, 提出一种基于多域融合卷积神经网络的转向架故障检测方法, 对于时域信号进行噪声注入以增强噪声鲁棒性与模型泛化性能, 使用内嵌时频变换层获取信号时频表示信息, 对于获得的多域多通道信息, 利用卷积神经网络的固有特性实现自适应权重特征融合。实验结果表明, 提出的方法提高了高速列车转向架故障诊断的准确率, 同时具有较强的噪声鲁棒性与工况适应性。

**关键词:** 高速列车转向架; 故障诊断; 多域融合; 卷积神经网络

中图分类号: TP277

文献标识码: A

文章编号: 1004-731X (2018) 11-4492-06

DOI: 10.16182/j.issn1004731x.joss.201811053

## Fault Diagnosis of High Speed Train Bogie Based on Multi-domain Fusion CNN

Wu Yunpu, Jin Weidong, Huang Yingkun

(School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

**Abstract:** The performance degradation and failures of high-speed train bogie components directly threaten the operation security of train. A fault detection method based on multi-domain fusion convolutional neural network is proposed to address the high complexity, high coupling and strong nonlinearity of vibration signals. *Noise injection for time domain signal is used to enhance noise robustness and generalization of the model. Signal time-frequency representation information is obtained through embedded time-frequency transformation layer. Adaptive weight-based fusion is implemented through intrinsic characteristics of the convolutional neural network to handle the multi-domain multi-channel information.* The experimental results show that the proposed method improves the accuracy of fault diagnosis of high-speed train bogies with good noise robustness and adaptability to work condition.

**Keywords:** high speed train bogie; fault diagnosis; multi-domain fusion; convolutional neural network

## 引言

随着高速列车在世界范围内的发展与应用, 高速列车的安全运行及保障技术已经成为研究不可

或缺的方面。高速列车在服役运行中, 会不可避免的发生构件的性能退化和各类故障, 这对高速列车长期安全的运行造成了威胁, 转向架是连接车体和轨道的唯一通道, 转向架关键部件的性能蜕变和故障状态直接导致车体和转向架振动形式改变, 同时也严重威胁到列车的运行安全。高速列车的振动信号是典型的复杂度高、耦合性和不确定性强的非线性信号, 包括轮轨接触力, 摩擦力以及悬挂系统间



收稿日期: 2018-05-25

修回日期: 2018-07-12;

作者简介: 吴昀璞(1991-), 男, 江苏, 博士生, 研究方向为故障诊断, 贝叶斯深度学习等; 金炜东(1959-), 男, 安徽, 博士, 教授, 博导, 研究方向为智能信息处理, 系统仿真与优化方法等。

<http://www.china-simulation.com>

• 4492 •

的相互作用, 加大了故障分析的难度<sup>[1]</sup>。同时, 高速列车的运行工况还受到包括环境、负载等在内的诸多影响因素的作用<sup>[2]</sup>, 这些都会对车厢上不同部位的振动形式造成影响。



图 1 高速列车转向架结构

Fig. 1 Structure of high speed train bogie

针对以上问题, 文献[3]通过提取多种小波熵特征结合支持向量机进行高速列车转向架故障辨识, 文献[4]先利用经验模态分解获得振动信号的固有模态分量, 而后人工选择分量提取多元多尺度熵进行故障辨识, 文献[5]使用多准则特征选择方法, 对转向架振动信号的多种时域及频域特征进行选择, 实现转向架分类。传统方法进行高速列车转向架故障诊断时, 对提取的故障特征需要进行一定程度的人工选择, 因此很大程度上依赖专家经验和领域知识。

深度神经网络作为近年来兴起的一种高效的机器学习模型, 已经在诸多应用领域内取得了巨大的成功<sup>[6]</sup>, 而在振动信号分析领域, 文献[7]使用预训练自动编码器, 提取频谱特征, 对滚动轴承信号进行分类, 文献[8]使用卷积神经网络依据信号频谱进行故障分类, 但使用频谱作为神经网络输入的方法, 并不适用于非平稳信号。而文献[9]使用了全连接卷积神经网络结合 LSTM 进行单变量时间序列分类。除了基于单通道信号的故障辨识, 另一些学者针对深度学习与多通道数据融合进行了研究。文献[10]使用多个子神经网络的输出进行数据融合, 文献[11]则选择了拼接多通道数据的方法, 而且为了获得更宽频带的频域特征, 选取了较大的卷积核。与此同时, 也有学者将深度神经网络应用于高速列车故障监测, 文献[12]使用自动编码器提

取转向架故障特征, 而后结合深层神经网络故障进行分类, 文献[13]则使用故障信号频谱作为深层神经网络输入进行转向架故障监测。然而, 以上研究中对检测算法的噪声鲁棒性及工况适应性关注较少, 而高速列车运行环境具有的强噪声与高度复杂性, 都会对故障检测的准确率造成影响。

针对高速列车运行工况复杂多变, 本文提出一种基于多域融合卷积神经网络(multi-domain fusion convolutional neural network, MDF-CNN)的转向架故障检测方法, 对于时域信号进行噪声注入以增强模型鲁棒性, 使用内嵌时频变换层获取信号时频表示信息, 对于获得的多域多通道信息, 利用卷积神经网络的固有特性实现自适应权重特征融合, 提高了转向架故障诊断的准确率, 同时具有较强的噪声鲁棒性与工况适应性, 对于保证高速列车安全高效运行具有重要的实际意义。

## 1 随机噪声正则化

噪声注入作为神经网络的正则化方法之一<sup>[14]</sup>, 将噪音注入到确定的隐含层单元中相当于构成了随机隐含层单元。训练期间的噪声注入会为模型和优化器引入随机性。因而可以利用定义概率公式来分析相应的训练过程。

设所有隐含层的激活单元集合为  $z$  :

$$z = g(\mathbf{h}_\phi(\mathbf{x}), \epsilon) \sim p_\phi(z|\mathbf{x}) \quad (1)$$

式中:  $\mathbf{h}_\phi(\mathbf{x})$  是对应输入和模型参数  $\phi$  的激活的隐含层单元;  $g(\cdot, \cdot)$  是施加在其上的加性或乘性噪声; 其中  $\epsilon$  表示噪声是从某概率分布(例如高斯分布)中采样获得。

因此, 训练具有这类随机隐藏单元的神经网络需要优化随机隐含单元的边际似然:

$$\mathcal{L}_{\text{marginal}} = \log \mathbb{E}_{p_\phi(z|\mathbf{x})}[p_\theta(\mathbf{y}|\mathbf{z}, \mathbf{x})] \quad (2)$$

式中:  $p_\theta(\mathbf{y}|\mathbf{z}, \mathbf{x})$  表示对应于给定输入  $\mathbf{x}$  和隐含单元  $\mathbf{z}$  的输出真实  $\mathbf{y}$  的概率;  $\theta$  表示模型参数。

为获得式(2)的边际似然, 使用重新参数化方法<sup>[15]</sup>(reparameterization trick), 用式(1)代换随机变量  $\mathbf{z}$ , 则对应于噪声的边际似然函数可表示为:

$$\mathcal{L}_{marginal} = \log \mathbb{E}_{p(\epsilon)} [p_{\theta}(y | g(h_{\phi}(x), \epsilon), x)] \quad (3)$$

其中  $p(\epsilon)$  是噪声的分布, 通过式(3)可以看到, 对注入噪声的神经网络的优化会同时实现对噪声的边缘似然。

本文对输入信号的时域添加噪声层, 既相当于输入含噪声信号, 同时相当于对神经网络施加了正则化, 这样做的好处是相当于直接对输入振动信号注入了噪声, 因而实质上提升了卷积神经网络的噪声鲁棒性。

## 2 卷积神经网络数据融合

对于多通道信号处理, 数据融合技术作为一种有效的性能提升手段已经得到了广泛应用<sup>[16]</sup>, 线性组合法, 作为一种基于分数(score-based)的方法具有很高的灵活性与适应性, 特别是目标对象存在各方面差异时, 而线性组合法的关键问题在于如何为涉及的目标分配合适的权重。

本文利用卷积神经网络的固有特性<sup>[17]</sup>实现数据融合。对于处理多通道的卷积神经网络而言, 其可以表示为:

$$h_j^n = \sum_{k=1}^K h_k^{n-1} * w_{kj}^n \quad (4)$$

本文使用一维卷积神经层进行多通道数据处理, 一维卷积层的工作方式如图2所示, 结合式(4)可以看到, 多通道卷积层通过可训练的卷积核, 对各通道特征进行了加权, 通过网络训练学习到的核

参数对应学习到的多通道的融合权重, 因此, 使用多通道卷积神经网络等效于自适应权重特征融合。

## 3 基于MDF-CNN的转向架故障检测

时域和频域是振动信号分析检测中最主要的分析域, 振动信号的时域描述随时间变化的振动信号变化情况, 容易提取出信号的简单特征, 可以直接有效的分离出低频, 骤变等振动形式, 但直接使用时域信号进行故障诊断时, 其抗干扰性较差, 当传感器采集的信号中含有噪声时, 则会影响结果, 容易产生误判等问题, 因此, 只使用时域信号作为模型输入会降低模型的噪声鲁棒性。另一方面, 故障的发生发展往往引起振动信号频率结构的变化, 周期性磨损、冲击等在时域中较难区分, 而变换至频域则可以获得信号的频率结构以及各谐波幅值、相位、功率及能量与频率的关系。传统的频域变换会丢失信号的时频相关性, 因而无法适用于非平稳信号, 联合时频表示有助于更好地体现并理解信号的特征, 已经在振动信号特征提取中取得了广泛的应用, 而获得高分辨率的时频表示意味着较高的计算复杂度, 也对分类识别的特征提取(降维)环节提出了更高的要求, 因为, 在频率轴的  $N$  个频率点意味着将原始时域数据维度增加了  $N$  倍。此外, 低信噪比下的故障信号特征较为微弱, 一般的时频变换技术难以有效的处理<sup>[18]</sup>。

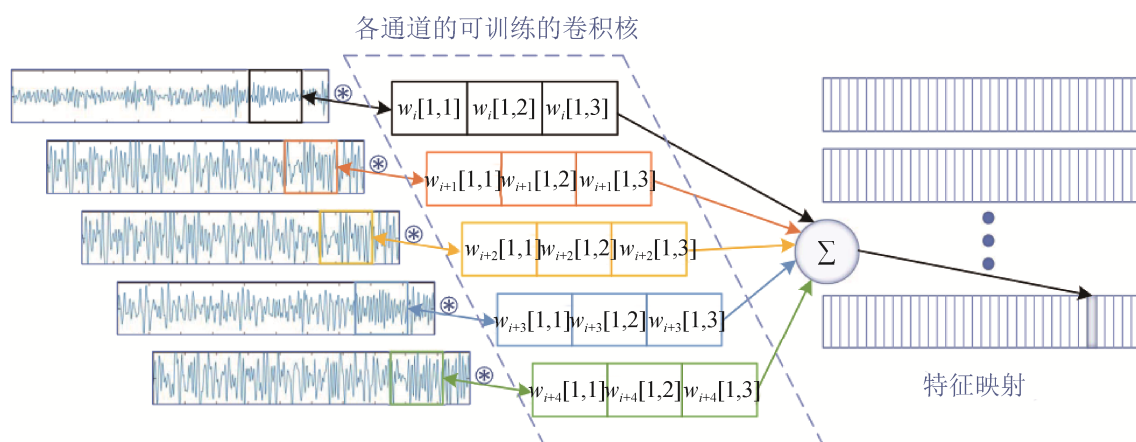


图2 一维卷积层多通道权重融合示意图

Fig. 2 Weight based fusion of one-dimension convolution layer for multi-channel

转向架故障的监测数据, 来自与列车及转向架上各相关部位的振动信号, 主要包括车体、构架、轴箱上各个部位横向、纵向和垂向振动加速度和车体、构架、轮对、一系、二系各部位 3 个方向的振动位移, 兼具周期频率结构与非平稳性, 将原始时域信号与时频表示共同作为信号表征是有必要的。

基于以上理由, 本文采取如图 3 所示的时域及时频域并行的结构(multi-domain fusion convolutional neural network, MDF-CNN), 对于时域原始信号, 使用一维卷积神经网络进行, 在训练过程中, 对原始信号进行噪声注入, 实现正则化的同时提高其噪声鲁棒性, 对于使用内嵌短时傅里叶变换(short-time Fourier transform, STFT)获得的时频表示, 使用二维卷积神经网络获取完整的特征, 对于每个支路, 均使用前一节所述的多通道卷积神经网络, 等效于自适应权重特征融合, 而后使用全连接层对两个支路的输出特征进行融合。

需要注意的是, 出于对检测性能的权衡, 训练过程中, 对于时频域分支不进行噪声注入, 以保证网络学习到故障信号的时频域特征。

## 4 实验分析

实验数据来自西南交通大学牵引动力国家重点实验室高速列车转向架仿真平台, 该平台基于多体动力学分析软件 Simpack 建立某动车组车辆系统非线性动力学模型, 充分考虑轮轨接触几何非线性、轮轨蠕滑非线性和非线性悬挂, 仿真实验采用

武汉—广州客运专线实测轨道激扰谱, 分别在多运行速度下进行实验。

故障的监测数据, 包括车体、构架、轴箱上各个部位横向、纵向和垂向振动加速度和车体、构架、轮对、一系、二系各部位三个方向的振动位移, 采样频率为 243 Hz, 样本含 58 通道。转向架工况主要涉及无故障状态(normal condition, NORM)、空气弹簧失气(air spring fault, AS)、横向减振器故障(lateral damper fault, LD)和抗蛇行减振器故障(yaw damper fault, YD)。本文中, 对实验数据采取滑动窗采样, 采样时长 1 s, 作为模型输入。

为了验证本文所提出的 MDF-CNN 的有效性, 本文对比了未使用多域融合的神经网络, 以下称其为 Simple-CNN, 其结构只包含两层一维卷积层及一层全连接层, 即仅有时域特征提取支路, 无多域融合层, 且不采用噪声注入方法。

### 4.1 基准实验

在基准实验中, 使用运行速度为 40 km/h, 80 km/h, 120 km/h, 140 km/h, 160 km/h, 200 km/h 下的不包含噪声的仿真平台车体监测数据作为实验数据集, 以验证本文所提模型的基础性能, 基准实验故障分类准确率及归一化混淆矩阵如图 4 所示。通过实验可以看到, 相较于 Simple-CNN 的 90.13% 的准确率, 以及传统人工通道择选方法的平均准确率 68.07%<sup>[3]</sup>, 85.62%<sup>[4]</sup>, MDF-CNN 提高将故障检测的准确率提高到了 99.75%。

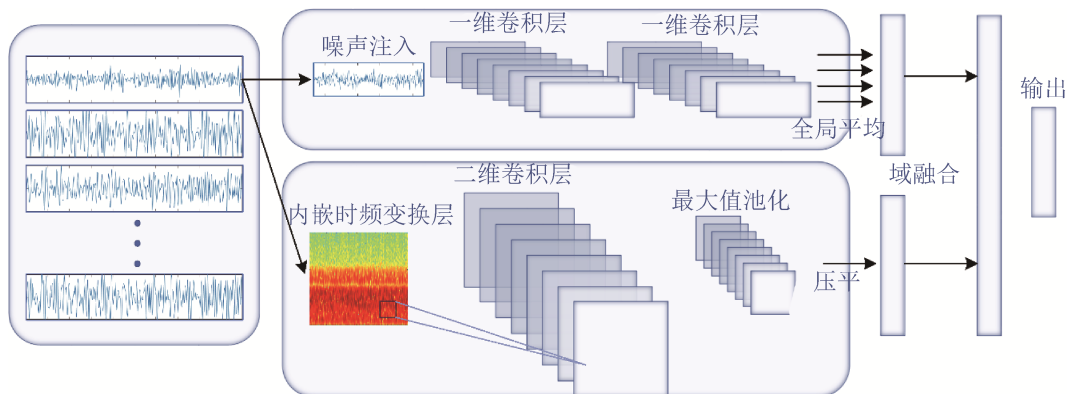


图 3 多域融合卷积神经网络结构

Fig. 3 Structure of multi-domain fusion convolutional neural network

<http://www.china-simulation.com>

• 4495 •

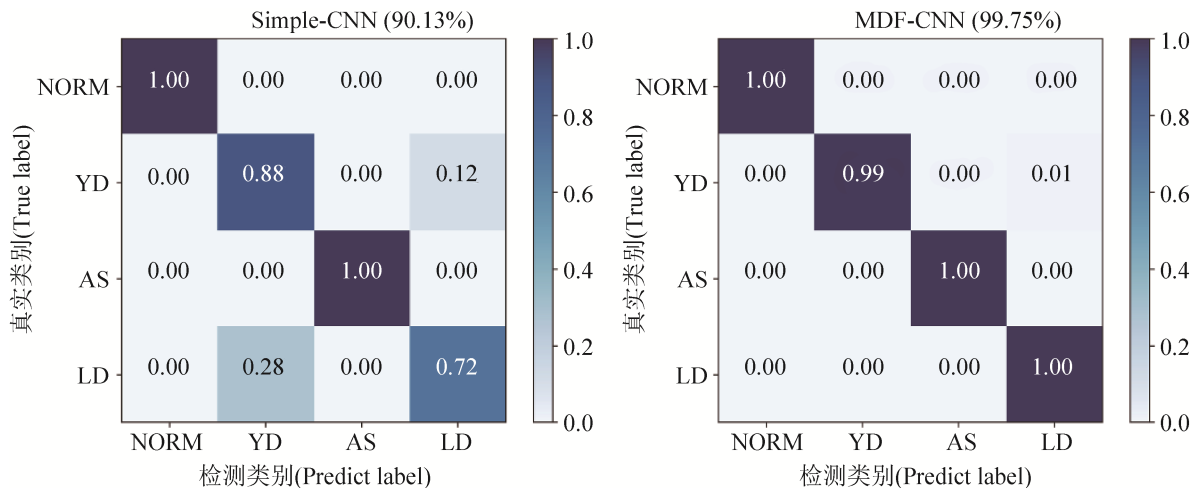


图4 基准实验准确率及归一化混淆矩阵

Fig. 4 Accuracy and confusion matrix for baseline experiments

## 4.2 噪声鲁棒性实验

为了验证模型对于含噪声信号的鲁棒性,使用不同信噪比下的故障信号进行测试,我们进行10次模型训练与准确率测试,每次采用随机的训练集与测试集样本划分,以获得相应的准确率均值及相应标准差,如表1所示。

表1 不同信噪比下的准确率  
Tab. 1 Accuracy under different SNR

SNR/dB	方法	
	Simple-CNN	MDF-CNN
10	71.07±2.58	98.13±0.79
8	62.82±5.63	97.55±0.71
6	52.11±9.24	96.46±0.89
4	43.25±13.56	94.62±1.51
2	42.01±14.41	91.53±2.32
0	39.30±13.91	86.89±3.65

通过实验可以看到,随着振动信号所含噪声分量的增加,即信噪比降低,Simple-CNN对故障分类的准确率降低,以至无法为列车安全提供保障,而本文提出的MDF-CNN即使在较低的信噪比下仍可以保持相对较高的故障识别准确率。

## 4.3 工况适应性实验

考虑到高速列车运行中,运行速度及负载均处于不断变化中,因此要求故障诊断模型具有良好的

泛化性能。这里选择单一运行速度下的数据进行模型训练,使用非训练工况的数据进行模型评估,实验数据集分组如表2所示。这里同样进行10次模型训练与准确率测试以获得相应的准确率均值及标准差,实验结果见表3。

表2 单工况实验数据集分组  
Tab. 2 Dataset settings for experiments under single work condition

实验组	训练集/(km/h)	测试集/(km/h)
A	120	40,80,140,160,200
B	140	40,80,120,160,200
C	160	40,80,120,140,200

表3 不同实验数据组下的准确率  
Tab. 3 Accuracy under different dataset settings

实验组	方法	
	Simple-CNN	MDF-CNN
A	77.64±12.45	94.90±5.16
B	78.88±4.56	96.51±1.94
C	76.29±0.73	91.89±1.83

通过实验可以看到,即使使用相对单一工况的监测数据进行训练,对于未训练过的工况下振动信号监测数据,MDF-CNN仍具有良好的故障识别能力,这意味着MDF-CNN具有较强的工况适应性与模型泛化性能,因此,在实际应用中对所需获取的转向架故障训练数据集的要求也相对较低。

## 5 结论

本文提出一种基于多域融合卷积神经网络的高速列车转向架故障检测方法, 通过时域噪声注入增强噪声鲁棒性与模型泛化性能, 使用内嵌时频变换层获取信号时频表示信息, 利用卷积神经网络的固有特性实现多域多通道信息自适应权重特征融合。实验结果表明, 该方法不仅提高了高速列车转向架故障诊断的准确率, 还具有较好的噪声鲁棒性, 此外, 使用单一工况训练的实验表明该模型还具有良好的泛化能力与工况适应性。该模型具有较好的易用性和推广性, 为实现高速列车转向架的快速准确的故障诊断提供了一种实用方案。

### 参考文献:

- [1] Lu Y, Xiang P, Dong P, et al. Analysis of the effects of vibration modes on fatigue damage in high-speed train bogie frames[J]. *Engineering Failure Analysis* (S1350-6307), 2018, 89: 222-241.
- [2] Iglesias E L, Thompson D J, Smith M, et al. Anechoic wind tunnel tests on high-speed train bogie aerodynamic noise[J]. *International Journal of Rail Transportation* (S2324-8378), 2017, 5(2): 87-109.
- [3] Qin N, Jin W D, Huang J, et al. High Speed Train Bogie Fault Signal Analysis Based on Wavelet Entropy Feature[J]. *Advanced Materials Research* (S1662-8985), 2013, 753/754/755: 2286-2289.
- [4] Wu Z, Jin W, Qin N. Fault feature analysis of high-speed train suspension system based on multivariate multi-scale sample entropy[C]//2016 35th Chinese Control Conference (CCC), 2016: 3913-3918.
- [5] Du J, Jin W, Cai Z, et al. A New Feature Evaluation Algorithm and Its Application to Fault of High-Speed Railway[C]//Proceedings of the Second International Conference on Intelligent Transportation. Springer, Singapore, 2016: 1-14.
- [6] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature* (S1476-4687), 2015, 521(7553): 436-444.
- [7] Jia F, Lei Y, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. *Mechanical Systems and Signal Processing* (S0888-3270), 2016, 72/73(Supplement C): 303-315.
- [8] Janssens O, Slavkovikj V, Vervisch B, et al. Convolutional Neural Network Based Fault Detection for Rotating Machinery[J]. *Journal of Sound and Vibration* (S0022-460X), 2016, 377(Supplement C): 331-345.
- [9] Karim F, Majumdar S, Darabi H, et al. LSTM fully convolutional networks for time series classification[J]. *IEEE Access* (S2169-3536), 2018, 6: 1662-1669.
- [10] Chen Z, Li W. Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder and Deep Belief Network[J]. *IEEE Transactions on Instrumentation and Measurement* (S0018-9456), 2017, 66(7): 1693-1702.
- [11] Jing L, Wang T, Zhao M, et al. An Adaptive Multi-Sensor Data Fusion Method Based on Deep Convolutional Neural Networks for Fault Diagnosis of Planetary Gearbox[J]. *Sensors* (S1424-8220), 2017, 17(2): 414-415.
- [12] Hu H, Tang B, Gong X, et al. Intelligent Fault Diagnosis of the High-Speed Train With Big Data Based on Deep Neural Networks[J]. *IEEE Transactions on Industrial Informatics* (S1551-3203), 2017, 13(4): 2106-2116.
- [13] Zhao Y, Guo Z H, Yan J M. Vibration signal analysis and fault diagnosis of bogies of the high-speed train based on deep neural networks[J]. *Journal of Vibroengineering* (S2538-8460), 2017, 19(4): 2456-2474.
- [14] Noh H, You T, Mun J, et al. Regularizing Deep Neural Networks by Noise: Its Interpretation and Optimization[G]//Guyon I, Luxburg U V, Bengio S, et al. *Advances in Neural Information Processing Systems 30*. Curran Associates, Inc., 2017: 5109-5118.
- [15] Kingma D P, Welling M. Auto-encoding variational bayes [J]. *arXiv preprint* (S2331-8422) arXiv:1312.6114, 2013.
- [16] Zheng Y. Methodologies for Cross-Domain Data Fusion: An Overview[J]. *IEEE Transactions on Big Data* (S2332-7790), 2015, 1(1): 16-34.
- [17] Stutz D. Understanding convolutional neural networks [R]. In *Seminar Report, Fakultät für Mathematik, Informatik und Naturwissenschaften Lehr- und Forschungsgebiet Informatik VIII Computer Vision*, 2014.
- [18] 鞠萍华. 旋转机械早期故障特征提取的时频分析方法研究[D]. 重庆: 重庆大学, 2010.  
Ju Pinghua. Research on the Time-frequency Analysis Method to Extract Early Fault Features of Rotating Machinery[D]. Chongqing: Chongqing University, 2010.