

# 基于深度置信网络的牵引电机轴承故障诊断方法

涂小卫<sup>1</sup> 张士强<sup>2</sup> 王 明<sup>2</sup>

(1. 上海申通地铁集团有限公司技术中心, 201103, 上海;

2. 株洲中车电力机车研究所有限公司, 412001, 株洲 // 第一作者, 工程师)

**摘要** 随着通信、存储技术的不断进步, 轨道交通已向“车辆大数据”的方向发展, 对故障诊断技术提出了更高的要求。给出了一种 FFT + DBN + 参数寻优的牵引系统电机轴承诊断方法, 完成了无监督特征提取与有监督微调网络模型的构建, 解决了网络参数设置难的问题, 并有效提高故障识别准确度, 为电机轴承故障诊断提供了解决方案, 具有很强的工程应用价值。

**关键词** 地铁; 车辆; 牵引电机轴承; 深度学习; 故障诊断

**中图分类号** TM307

DOI:10.16037/j.1007-869x.2020.01.042

## Fault Diagnosis Methodology Based on Deep Confidence Network Traction Motor Bearing

TU Xiaowei, ZHANG Shiqiang, WANG Ming

**Abstract** With the continuous progress of communication and storage technologies, urban rail transit has started the development towards the direction of "Vehicle Big Data", which puts forward higher requirements for fault diagnosis technology. A diagnosis methodology of motor bearings in traction system based on FFT + DBN + parameter optimization is proposed, which completes the unsupervised feature extraction and the construction of supervised fine tuning network mode, solves the problems in network parameter setting, improves the accuracy of fault identification. At the same time, the methodology provides a solution to fault diagnosis of motor bearings and therefore has strong engineering application value.

**Key words** metro; vehicle; traction motor bearing; deep learning; fault diagnosis

**First-author's address** Technology Center, Shanghai Shentong Metro Group Co., Ltd., 201103, Shanghai, China

地铁车辆的牵引电机轴承是传递力矩、承受载荷的重要结构, 其工作环境较恶劣, 轴承长时间负重载运行, 难免产生腐蚀或磨损等问题。而其他部件的微小缺陷也都会造成一定的车身振动, 进而加速整车电机轴承的磨损, 严重威胁车辆的安全运行。对电机轴承进行实时有效的诊断与预警, 不仅

可以确保车辆运行安全, 而且可以降低维护成本、促进智能诊断, 为自动驾驶及智能运维提供支持。

地铁车辆运行过程中, MVB(多功能车辆总线)、EDRM(数据记录模块)、故障记录文件都会产生大量数据。这些数据具有数量大、多源异构性及持续采集的特点, 是地铁运行进入“大数据”时代的特征。设备数据直接反映设备本身的健康状态, 各部件之间耦合性强, 某一微小故障都有可能引发重大问题<sup>[1]</sup>。在这给故障诊断带来了更大的挑战, 应利用有效的算法深入挖掘设备数据, 获取潜在的设备信息, 提供准确可靠的设备健康状况。

深度学习是机器学习领域的新方法, 通过多层网络深度构建各层神经元之间的抽象模型, 计算权值并获取高层、低维、有效的特征表达, 实现对大量数据的深层信息的挖掘, 解决了高维数据空间的复杂运算问题<sup>[2]</sup>。近年来, 深度学习方法理论与算法的发展尤为迅速, 其应用涉及航空、医疗、电力、交通等领域, 均取得了较好的效果。

但利用深度学习进行故障诊断的研究存在准确度不高和参数设置困难等问题。本文针对这些问题, 利用 FFT(快速傅里叶变换) + DBN(深度置信网络)并结合参数寻优取得了很好的结果。

## 1 深度学习概述

2006 年, Hinton 提出了深度学习的概念。深度学习属于人工神经网络的范畴, 通过构建模拟人脑思考的深层网络模型, 使对复杂的数据具有强分析与处理能力的无监督学习算法<sup>[3]</sup>。

理论方面: 最初由 Hinton 课题组针对深层网络训练过程中梯度消失的问题提出了利用无监督正向训练与有监督反向微调相结合的解决方案。继而伴随着 RELU 激活函数与多种训练模型的提出, 对于抑制梯度消失、减小过拟合、增强泛化能力等方面的研究逐渐深入。至今, 深度学习已进入了相

对成熟的发展阶段。应用方面：最初，深度学习以其优异的特征提取能力在计算机视觉、语音识别等方面的应用最为突出，继而在工业、AI 以及商用领域均有广泛的应用。除此以外，大量学者将深度学习算法与数据挖掘、模式识别等结合起来以解决实际问题，在故障诊断领域涌现出了诸多先进的方法，在传统故障诊断方法的基础上提升了诊断能力

与识别精准度。

深度学习算法故障诊断与传统故障诊断的流程如图 1 所示。由图 1 可见，深度学习算法直接从数据中获得深度描述的特征信息，能自适应地完成数据处理、数据训练、参数优化、模型建立等过程，在故障样本充足的条件下能有效地诊断故障。

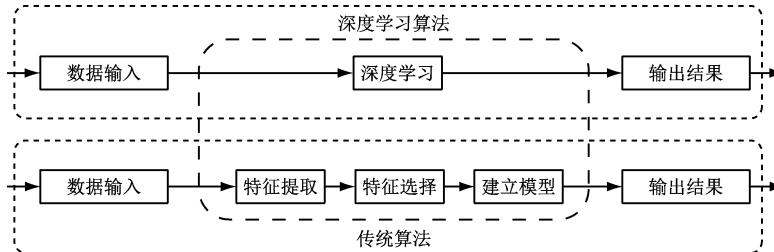


图 1 故障诊断方法对比

常用的深度学习算法模型有 DBN、卷积神经网络 (Convolutional Neural Network, CNN) 和堆叠自动编码器 (Stacked AutoEncoder, SAE)。其中，DBN 理论与应用的研究均比较完备，在故障诊断领域的应用效果较理想，故本文选择 DBN 方法用于地铁电机轴承的故障诊断。

## 2 基于 DBN 的故障诊断方法

### 2.1 DBN 训练过程

DBN 由无监督训练的预训练部分与有监督训练的微调部分构成。其中预训练部分主要由多层受限玻尔兹曼机 (restricted Boltzmann Machine, RBM) 组成<sup>[4]</sup>，无监督训练部分采用 BP(反向传播) 神经网络算法对整个 DBN 网络进行微调。DBN 是一个概率生成模型，通过堆叠 RBM 的 CD (Contrastive Divergence, 比散度) 快速贪婪学习算法获得数据原始特征，从而获得数据的高层次表达<sup>[5]</sup>。

单层 RBM 的结构如图 2 所示，其组成单元包括显层与隐层。显层负责接收原始数据，并输出上一层 RBM 的特征值，隐层为由显层提取的特征及输出结果。与传统判别模型不同的是，DBN 建立起标签与观测值之间的双向对应关系<sup>[6]</sup>，通过对 P (observation + label) 和 P (label + observation) 进行多次迭代计算而确定最大拟合结果。

DBN 网络结构如图 3 所示，其训练由正向的预训练阶段与反向微调阶段构成。

1) 预训练阶段。在预训练阶段，输入层获取训练数据，之后将数据传递至隐层提取特征，并将隐

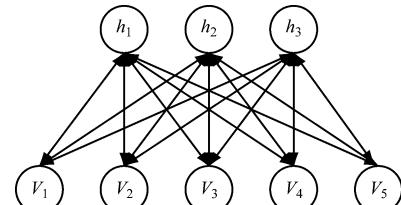


图 2 单层 RBM 结构

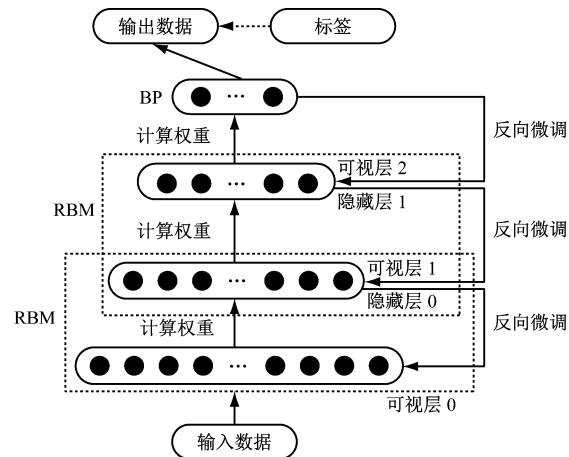


图 3 DBN 结构

层重构回前向隐层计算权重。每一个 RBM 的计算过程都由正向的特征提取和反向的数据重构组成，因此可建立起各 RBM 之间的双向对应关系，并经过神经元数量逐层递减的特征提取，以便获得原始数据更高层的表达。通过数据分批预训练多次迭代计算的方式来实现无监督预训练过程，从而保证每个 RBM 局部最优。

2) 微调阶段。预训练过程可大幅降低原始数据的维度，在 DBN 的顶层加入 Softmax 分类器，通

过 BP 神经网络算法,结合数据标签对整个 DBN 网络进行自上而下的有监督训练,同时微调各层 RBM 的权重矩阵与偏置矩阵,从而保证全局参数最优。

## 2.2 基于 DBN 的故障诊断过程

### 2.2.1 数据预处理预网络结构设置

利用 DBN 对轴承故障进行诊断之前,需要对轴承数据进行归一化及 FFT 处理,以提高时间效率和结果的准确率,故本文所使用的故障诊断方法为 FFT + DBN。另外,需要对原始数据进行样本分割及网络结构初始化(见表 1)。

表 1 基于 DBN 的故障诊断过程

步骤	主要任务
1	根据故障情况初步设定诊断流程
2	数据预处理,样本分割,构建数据集
3	初始化 DBN 网络
4	自下而上逐层特征提取,获得特征矩阵
5	自上而下微调网络,得到优化后的参数集合
6	计算均方根误差、分类精度,分类结果可视化

### 2.2.2 网格法参数寻优

诊断过程中最重要的就是设置网络节点数等相关参数。各参数之间的耦合性很大,而多数参数均无确定的设置规则。文献[7]中仅指出了大概的设置方案,但不同的设置值对结果的影响很大。本文采用网格参数寻优法,通过多次试验选取对结果影响最大的学习率、迭代次数和网络节点数为寻优对象,可大幅提高结果准确度和计算效率。

### 2.2.3 结果聚类分析

DBN 对故障数据分类,可得到各类故障数据的特征矩阵。但由于数据维度较高,需要通过主成分分析法(Principal Component Analysis,PCA)从特征矩阵中提取主要特征并绘制三维散点图<sup>[8]</sup>,从而观察 DBN 的分类能力。

PCA 可视化方法可直观反映 DBN 的分类能力,但并无量化指标以确定分类准确率。因此,本文根据式(1)计算分类结果的均方根误差( $E$ )<sup>[9]</sup>,并与其它主流算法进行对比,定量分析 DBN 的分类准确率与时间效率。

$$E = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (1)$$

式中:

$X_i$ ——原始数据;

$Y_i$ ——重构数据;  
 $N$ ——数据的维度特征。

## 3 试验验证

### 3.1 仿真数据集验证

#### 3.1.1 数据描述

故障轴承的振动信号包含各故障部位的固有频率。由于多数据振动信号都可由多个正弦波信号复合而成,故本文采用 3 个不同幅度不同频率的混合信号来模拟故障轴承的振动信号数据。此外,为了模拟真实工况,还加入白噪声信号<sup>[10]</sup>。

仿真振动信号  $x(t)$  由模拟信号  $x_1(t)$ 、 $x_2(t)$  及噪声信号  $w$  组成,即:

$$\begin{cases} W_{x_1}(t) = 5\cos(20\pi t) + 10\cos(40\pi t) \\ W_{x_2}(t) = 15\cos(60\pi t) + 20\cos(80\pi t) \\ W_w = 20 \cdot \text{randn}(1, n) \\ W_x(t) = W_{x_1}(t) + W_{x_2}(t) + W_w \end{cases} \quad (2)$$

仿真振动信号  $y(t)$  由各谐波信号和噪声信号  $w$  组成,即:

$$\begin{cases} W_{y_1}(t) = 5[1 + \cos(4\pi t)]\cos(20\pi t) \\ W_{y_2}(t) = 10[1 + \cos(4\pi t)]\cos(40\pi t) \\ W_{y_3}(t) = 15[1 + \cos(4\pi t)]\cos(60\pi t) \\ W_{y_4}(t) = 20[1 + \cos(4\pi t)]\cos(80\pi t) \\ W_w = 20 \cdot \text{randn}(1, n) \\ W_y(t) = W_{y_1}(t) + W_{y_2}(t) + W_{y_3}(t) + W_{y_4}(t) + W_w \end{cases} \quad (3)$$

仿真振动信号  $z(t)$  由模拟信号  $z_1(t)$ 、 $z_2(t)$  和噪声信号  $w$  组成,即:

$$\begin{cases} W_{z_1}(t) = 4\sin(25\pi t)\sin(30\pi t) + \sin(40\pi t^2) \\ W_{z_2}(t) = [10 + 5\cos(10\pi t)]\cos[2\pi t + 2\cos(5\pi t)] \\ W_w = 20 \cdot \text{randn}(1, n) \\ W_z(t) = W_{z_1}(t) + W_{z_2}(t) + W_w \end{cases} \quad (4)$$

式中:

$W_i$ ——信号  $i$  的幅值。

为与传统方法进行充分对比,根据文献[10]的采样频率对仿真信号进行离散化处理:采集 100 s 的数据,以 1 024 个数据点为样本长度对每个故障数据进行样本分割,共获得 3 类模拟故障数据,每类有 100 个样本。随机选择其中 60% 作为训练样本,

40%作为测试样本。DBN模型采用经典的5层模型,其网络输入层节点数由数据集的维度决定,输出层节点数由分类结果决定,网络隐层节点数设置为[512, 256, 128],学习率设置为0.01,迭代次数150次。

### 3.1.2 分析结果

经过DBN的特征提取与参数优化过程,得到仿真数据集的特征矩阵。利用PCA方法对该特征矩阵的前3个主要特征进行可视化处理,处理结果如图4及图5所示。可见,FFT+DBN故障诊断方法可提取各类故障的主要特征,并有效区分各类故障。

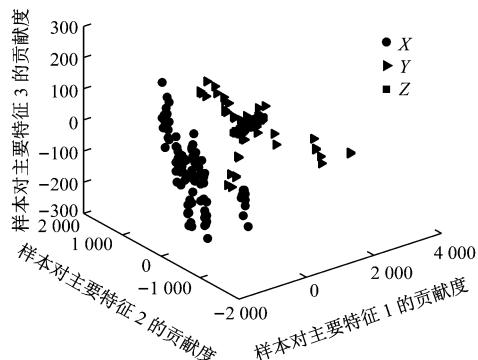


图4 仿真数据集原始数据的PCA可视化

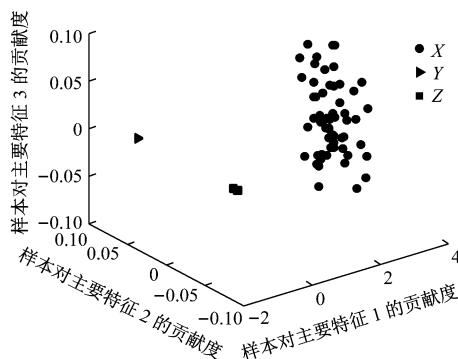


图5 仿真数据集特征提取结果的PCA可视化

为更准确地描述故障诊断结果,需计算分类准确率,并与其它方法进行比较。为避免偶然因素,采用多次试验平均值作为准确率最终值,计算结果见表2。

表2 仿真数据集故障诊断结果对比

方法	准确率/%	方法	准确率/%
PCA-BP <sup>[10]</sup>	66.83	ONPE-BP <sup>[10]</sup>	90.00
LLP-BP <sup>[10]</sup>	76.67	LLTSA-BP <sup>[10]</sup>	88.33
LDA-BP <sup>[10]</sup>	85.00	FFT + DBN	99.97

由表2可知,FFT+DBN的故障诊断方法无论

在准确率和稳定性上均优于其他方法。

## 3.2 轴承数据集诊断

### 3.2.1 轴承数据描述

滚动轴承内圈、外圈与滚子故障最为常见。本文参考标准数据集<sup>[11]</sup>对电机轴承内圈、外圈、滚子人为引入故障,并利用加速度传感器采集轴承运转时产生的振动信号,设置采样频率为12 000 Hz,采集20 s的试验数据用于构建数据集。

由于列车运行中转向架的振动会对电机轴承振动信号造成一定干扰,列车运行中转向架与轨道之间的常规振动会部分叠加到轴承振动信号中。此外,突发的强烈振动会使轴承振动信号出现毛刺,对轴承故障诊断造成较大影响。可见,牵引电机轴承振动信号极易受到外界干扰。

本文提出的FFT+DBN故障诊断方法可以深度获取数据本质特征,大多数干扰信号对其诊断结果的影响很少。但毛刺信号在数据归一化的过程中会严重影响其他故障数据表征特征,故在数据预处理前需对振动数据进行异常值处理,去除毛刺信号,并筛选稳态运行、有效的轴承数据进行分析。

本文选取内圈故障、外圈故障、滚珠故障与无故障等4类数据,故障类型与样本信息详见表3,选择样本数量的60%作为训练集。剩余部分作为测试集<sup>[12]</sup>。

表3 轴承数据集样本划分

数据类型	训练样本 数量/个	测试样本 数量/个	样本长度 (数据点数)/个	标签
正常	30	20	2 048	1
内圈故障	30	20	2 048	2
滚珠故障	30	20	2 048	3
外圈故障	30	20	2 048	4

根据试验采集的数据,绘制各类故障时域波形图如图6所示。

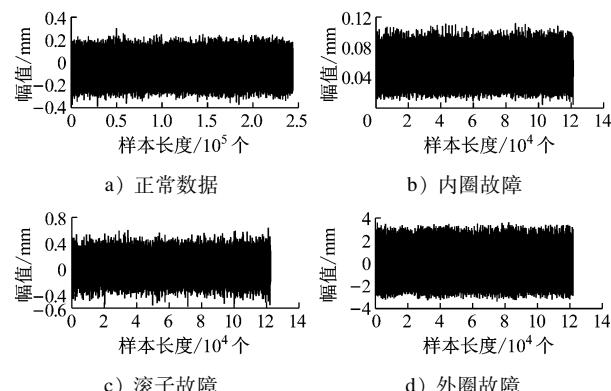


图6 故障数据时域波形图

由图 6 可知,多数故障较为相近,且数据特征不明显,会对程序运行效率造成较大的影响,故本文对原始数据进行简单的初始化,通过 FFT 方法在保留原始数据全部信息的情况下获得其频域特征(如图 7 所示)。

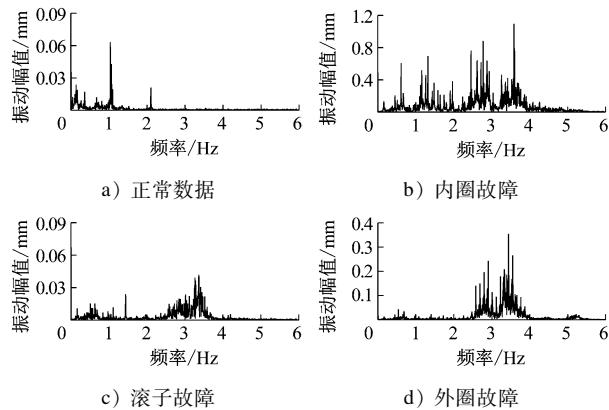


图 7 频域波形图

由图 7 可知,对频域数据的故障诊断仍有较大难度。本文利用 DBN 对故障数据进行训练,根据多次试验来确定最佳样本的分割长度,并采用线性归一化,设置 DBN 的训练隐层网络节点数为 [1 024, 512, 256], 设置预训练部分迭代 150 次, 微调迭代 200 次。以训练批量和学习率为目标量进行参数寻优<sup>[13]</sup>。

### 3.2.2 结果分析

通过网格法对训练批量和学习率进行参数寻优,最终确定参数集合为 [0.005, 10]。得到  $E$  值为 0.000 34, 为消除随机误差,取 20 次分类准确度的平均值作为最终的结果,经计算多次可以得到 100% 的准确率。

利用 PCA 对特征矩阵进行可视化处理,结果如图 8 及图 9 所示。

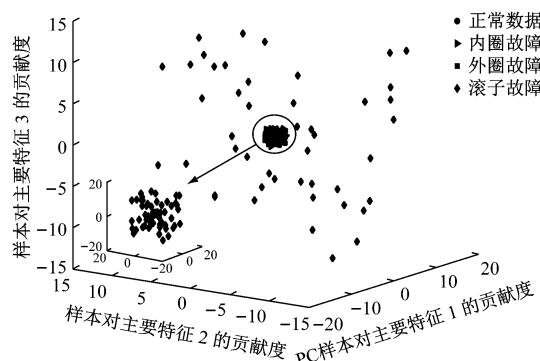


图 8 原始数据的 PCA 可视化处理结果

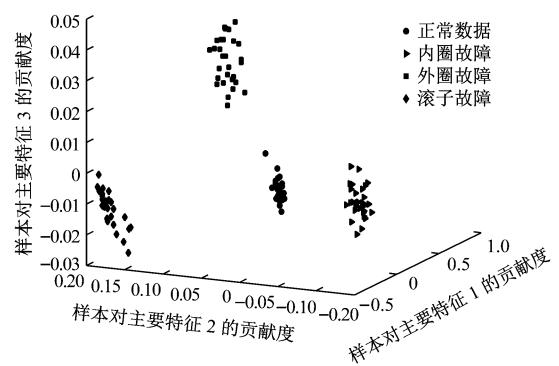


图 9 特征矩阵主成分可视化结果

为更加精准地表示诊断结果,以 20 次试验的分类准确率平均值作为分类准确率最终值,并结合  $E$  值,以表征基于 DBN 的轴承故障方法的可靠性。故障诊断结果如表 4 所示。

表 4 故障诊断结果对比

故障诊断方法	准确率/%		$E$
	训练集	测试集	
FFT + DBN	100	99.6	0.000 34
PCA-BP	93.5	91.70	0.002 81
LLP-BP	94.4	93.30	0.002 06
LDA-BP	97.1	96.7	0.001 60

由数据集的特征提取可视化结果与分类结果可知,基于 DBN 的轴承故障诊断方法可有效提取故障数据中的有效特征,并刻画各故障的内在本质,高精度地完成对各类故障的诊断。

## 4 结语

1) 简述了深度学习理论与应用的概要与主要模型,主要介绍了深度置信网络(DBN)的基本原理,给出应用 DBN 进行故障诊断的详细过程。

2) 给出了一种 FFT + DBN 的故障诊断方法,并利用仿真数据集与地铁电机轴承数据集进行验证。验证结果显示,FFT + DBN 方法可以有效处理轴承故障诊断问题。对于算法最复杂的参数设定过程给出了网格法参数寻优法作为初步解决方案,后续还可引入遗传算法等其他方法进行优化。

## 参考文献

- [1] 陈海周. 旋转机械传动件微弱故障融合诊断方法研究[D]. 重庆:重庆大学,2017.

(下转第 195 页)

在稳态时,并联整流器之间的均流和环流效果波形图如图 11 所示。

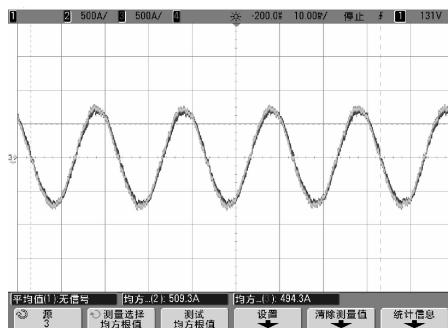


图 11 稳态均流及环流示波器波形截图

由此可见,引入调节因子  $k$  以后,两台整流器之间的零序环流得到了明显的抑制,而且在共电压外环控制下稳态均流效果也良好。

## 4.2 下垂控制运行效果

实际挂网运行中,双向变流器采用下垂控制策略与整流器协同运行,试验中记录了单次列车从加速到停车的数据,生成曲线图如图 12 所示(每秒钟采集 5 组数据)。

如图 12 所示,在列车加速过程中,双向变流器输出直流电压初始下降较快,中间经历了一段稳压输出区间;随着负载的继续增加,直流电压再次开始下垂,此时由整流机组继续补充牵引能量;在列车制动时,双向变流器通过稳压回馈把制动能量回馈至 35 kV 电网。整个运行过程中,直流输出电压根据负载变化不断进行调整,满足预定控制目标。

(上接第 178 页)

- [2] 彭雄伟. 电子鼻传感器阵列信号的差异校正及漂移补偿研究 [D]. 重庆:重庆大学,2015.
- [3] 刘灵. 基于深度学习的车型识别分析与研究 [D]. 济南:山东师范大学,2017.
- [4] HINTON G E, OSINDERO S, Teh Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006 (7):1527.
- [5] 胡伟,禹龙,田生伟,等. 基于深度信念网络的维吾尔语事件伴随关系识别[J]. 中文信息学报,2018,32(5):65.
- [6] 张彬超,寇雅楠,邬蒙,等. 基于深度置信网络的近距空战态势评估[J]. 北京航空航天大学学报(自然科学版),2017,43 (7):1450.
- [7] 赵一中. 基于 DBNs 网络的非限制性人脸识别算法研究

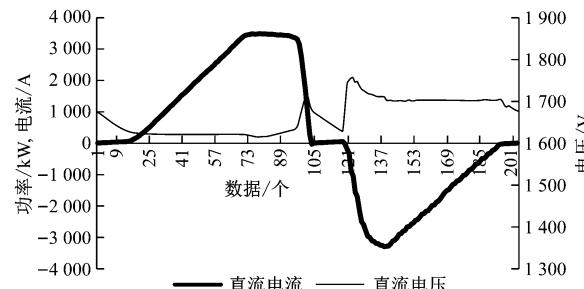


图 12 下垂控制策略下列车从加速到停车波形曲线图

## 5 结语

本文引入调节因子  $k$  对并联变流器的零序环流进行了有效压制,解决了双向变流器并联扩容的关键问题;又通过负载电流前馈的下垂控制策略,解决了双向变流器与整流机组协同供电的问题。

通过上述策略的应用,为成功研制大功率密度的双向变流器产品提供了理论和技术支撑。在城市轨道交通现场挂网应用表明,双向变流器能够与整流机组协同供电,双向变流器具备进一步推广应用的基础。

## 参考文献

- [1] 陈勇. 基于逆变回馈的地铁再生制动能量吸收的研究[D]. 成都:西南交通大学,2011.
- [2] 张志学,何多昌,张铁军,等. 城市轨道交通牵引供电系统的技术发展展望. 机车电传动,2012(1):43.

(收稿日期:2019-09-10)

[D]. 南京:南京航空航天大学,2017.

- [8] 雷雪. 基于深度学习理论的车载电源健康诊断方法研究 [D]. 兰州:兰州理工大学,2018.
- [9] 张名芳,付锐,石涌泉,等. 基于激光雷达的远距离运动车辆位姿估计[J]. 公路交通科技,2017,34(12):131.
- [10] 李锋. 基于流形学习的风电机组传动系统故障诊断方法研究 [D]. 重庆:重庆大学,2011.
- [11] 胡永涛. 基于多特征融合及深度信念网络的轴承故障诊断 [D]. 秦皇岛:燕山大学,2017.
- [12] 刘松华. 核矩阵低秩分解与核空间信息能度量研究及应用 [D]. 西安:西安电子科技大学,2011.
- [13] 张士强. 基于深度学习的故障诊断技术研究[D]. 哈尔滨:哈尔滨工业大学,2018.

(收稿日期:2019-04-16)