

深度学习融合模型在机械故障诊断中的应用^{*}

王应晨¹, 段修生²

(1. 陆军工程大学电子与光学工程系 石家庄, 050003) (2. 石家庄铁道大学机械工程学院 石家庄, 050003)

摘要 为了解决浅层学习与传统深度学习模型因机械装备结构复杂、工作环境噪声和大数据等因素引起的诊断困难问题,提出了一种基于降噪自编码器和深度信念网络的融合模型,来实现高效准确的故障诊断。首先,降噪自编码器用于处理原始信号的随机噪声并学习低层特征;其次,深度信念网络用基于所学习的低层特征来学习深层特征;最后,将深度特征输入粒子群支持向量机中,对诊断模型进行训练。所提出的方法被应用于滚动轴承的故障诊断,结果表明与现有方法相比,该方法更加有效和鲁棒。

关键词 故障诊断; 深度信念网络; 降噪自编码器; 自适应学习率; 鲁棒性; 支持向量机

中图分类号 TH17; TN911

引言

机械装备的故障诊断是通过其监测数据来分析装备状态的健康状况,确定是否对其进行维护。现代武器装备系统中各个部分相互耦合,故障模式复杂多样,使故障诊断具有很大的难度和不确定性,对于复杂系统快速有效的故障诊断是装备保障的重要课题。传统的智能诊断方法在机械故障诊断中得到了广泛的应用,但仍存在 3 个固有的缺陷:a. 诊断性能很大程度上依赖于专家经验所提取特征的质量;b. 在不同的诊断问题中选择敏感的特征费时费力;c. 神经网络(neural network,简称 NN)和支持向量机(support vector machine,简称 SVM)等属于浅层学习模型,难以有效学习复杂的非线性关系。因此,有必要构建自动学习特征和精确故障诊断的深度学习架构。

为了克服浅层模型的缺点,Hinton 首先提出了深度学习理论,此后深度学习引起了广泛的关注,并取得了大量成功的应用^[1]。深度学习强大的非线性映射能力以及多隐含层使其与 NN,SVM 等浅层学习模型相比,能够更加有效、灵活地学习故障诊断问题中的复杂关系。赵光权等^[2]将深度信念网络(deep belief network,简称 DBN)用于轴承的故障诊断,该模型从原始时域信号中逐层提取故障特征,输入 Softmax 分类器,获得了较高的诊断精度。

Guo 等^[3]采用堆栈降噪自编码器(stacked denoising autoencoder,简称 SDAE)来实现旋转机械故障诊断。采用原始数据训练模型,通过与不同级别的随机噪声结合组成新的数据进行测试,取得了较好的结果,证明了该模型在自动提取特征的同时能有效处理原始信号的噪声。这些应用仍然存在以下局限性:a. 没有充分利用不同的模型来提高特征学习能力和抗干扰性;b. 标准的深度学习算法存在误差振荡,收敛速度慢。

笔者提出了利用降噪自动编码器和自适应高斯深度信念网络结合提取故障特征,粒子群支持向量机(particle swarm optimization SVM,简称 PSO-SVM)进行分类的诊断系统。利用不同基础模型的优点,在提取信号特征的同时进行去噪,并采用自适应学习率有效提高网络的诊断精度和收敛速度。

1 深度神经网络模型简介

1.1 降噪自编码器

降噪自编码器(denoising autoencoder,简称 DAE)是对普通自动编码器(autoencoder,简称 AE)的有效改进^[4],为使 AE 隐含层学习到的特征更具鲁棒性,在训练样本中加入随机噪声来污染输入数据,之后送到网络中进行编码和解码,DAE 从损坏的数据来重建未损的数据,以此提高模型的抽象能

^{*} 装备状态监控与维修总装重点实验室基金资助项目(ECMM2016007)
收稿日期:2018-01-16;修回日期:2018-03-23

力,得到对原始数据更加鲁棒的表达。

图1说明了 DAE 的结构与训练过程,主要目标是 minimized 重构误差,定义为

$$\min_w \|\text{sigm}(\mathbf{W}^T \text{sigm}(\tilde{\mathbf{W}}x)) - x\|_2 \quad (1)$$

其中: x 为原始输入样本; \tilde{x} 为损坏的样本; sigm 表示 sigmoid 函数; \mathbf{W} 为一个 $m \times n$ 的矩阵。

在训练过程中, DAE 被迫捕获数据中的隐含不变量,在诊断经常受噪声影响的振动信号时,抵抗噪声的鲁棒性是非常重要的特性。




图1 降噪自编码器的编码和解码过程

Fig. 1 The encoding and decoding process of DAE

1.2 高斯受限玻尔兹曼机

受限玻尔兹曼机 (restricted boltzmann machine, 简称 RBM) 是一个由可见层和隐含层组成的双层神经网络^[5]。可见单元和隐藏单元之间存在加权连接,但是其同层节点之间无连接,见图2。




图2 RBM 的结构

Fig. 2 The structure of RBM

在 RBM 中,各节点是二进制值,而故障信号是连续数值。因此笔者采用了高斯受限玻尔兹曼机 (Gaussian RBM, 简称 GRBM),将二进制的可见层节点值替换为具有高斯分布的连续实数,使输入层能够接受连续型信号,隐含层仍采用服从伯努利分布的二值神经元节点,GRBM 的能量函数为

$$E(v, h; \theta) =$$

$$\sum_{i=1}^m \frac{(v_i - a_i)^2}{2\sigma_i^2} - \sum_{i=1}^m \sum_{j=1}^n \frac{v_i w_{ij} h_j}{\sigma_i} - \sum_{j=1}^n b_j h_j \quad (2)$$

模型参数为 $\theta_{\text{GRBM}} = \{w_{ij}, a_i, b_j\}$, 其中: w_{ij} 为

可见单元 v 与隐藏单元 h 之间的权重; a_i 和 b_j 分别为它们的偏置; n 和 m 分别为可见层和隐含层单元的数量。

基于该能量函数,得到 (v, h) 联合概率

$$p(v, h; \theta) = \frac{1}{Z(\theta)} \exp(-E(v, h; \theta)) \quad (3)$$

其中: $Z(\theta) = \sum_v \sum_h \exp(-E(v, h; \theta))$ 为归一化因子。

由于隐藏层和可见层内部没有连接,同层的节点间相互独立,当给定可见层单元状态 v 时,隐含层第 j 个单元 h_j 的激活概率为

$$P(h_j = 1 | v; \theta) = \sigma\left(\sum_{i=1}^m w_{ij} \frac{v_i}{\sigma_i} + b_j\right) \quad (4)$$

可见单元 v_i 的激活概率为

$$P(v_i = v | h; \theta) = N\left(a_i + \sigma_i \sum_{j=1}^n w_{ij} h_j, \sigma_i^2\right) \quad (5)$$

其中: $\sigma = 1/(1 + e^{-x})$ 为 sigmoid 函数; $N(\mu, \sigma^2)$ 表示均值为 μ 、方差为 σ^2 的高斯分布。

GRBM 的训练采用由 Hinton^[6] 提出的 CD 算法:从训练样本的任一状态出发,按照式(4)计算出隐含单元的概率,然后固定隐含单元,按照式(5)重构出可见单元。这样,得到模型参数 $\theta_{\text{GRBM}} = \{w_{ij}, a_i, b_j\}$ 的近似调整规则

$$\Delta w_{ij} = \epsilon \left(\left[\frac{1}{\sigma} v_i h_j \right]_{\text{data}} - \left[\frac{1}{\sigma} v_i h_j \right]_{\text{recon}} \right) \quad (6)$$

$$\Delta a_i = \epsilon \left(\left[\frac{1}{\sigma} v_i \right]_{\text{data}} - \left[\frac{1}{\sigma^2} v_i \right]_{\text{recon}} \right) \quad (7)$$

$$\Delta b_j = \epsilon \left([h_j]_{\text{data}} - [h_j]_{\text{recon}} \right) \quad (8)$$

其中: $\langle \cdot \rangle_{\text{data}}$ 为由样本数据决定的期望; $\langle \cdot \rangle_{\text{recon}}$ 为重构数据的期望; ϵ 为学习率。

训练样本一般被分为多个小子集,每个小子集训练完成后,再更新模型的参数。

1.3 高斯深度信念网络

高斯深度信念网络 (Gaussian DBN, 简称 GDBN) 是通过层叠几个 GRBM 构建的。具有 3 个堆叠的 GRBM 的 GDBN 体系结构如图 3 所示。

GDBN 特征提取过程采用逐层无监督贪婪预训练^[7],将数据输入到第 1 个 GRBM 的可见层中,并使用激活函数将其转换为隐藏层,前 1 个 GRBM 学到的特征作为下 1 个的输入,直到最后 1 个 GRBM,无监督预训练结束, GDBN 从原始数据自动学习的特征被送入分类器中。

2 自适应学习率

学习率是影响 GDBN 收敛速度和提取特征性

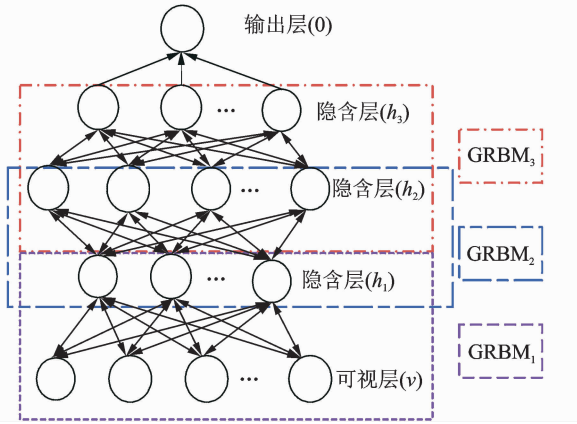


图 3 GDBN 结构
Fig. 3 The structure of GDBN

能的决定性因素^[8]。标准 GRBM 的学习算法中采用固定的学习率来训练网络,确定后,学习率在整个训练过程中保持不变,自适应性差。如果学习率过大,很可能会越过最优值,在局部最优点附近来回跳动;而如果学习率过小,优化的效率可能过低,算法长时间无法收敛,所以学习率对于算法性能至关重要。

为了获得更好的故障诊断性能并加速网络的学习过程,在传统 DBN 算法基础上,引入一种基于重构误差的自适应学习率算法,可以在训练中每一步自适应调整学习速率。重构误差是 RBM 学习规则中应用最广泛的判断标准,定义为

$$Err = \frac{1}{N} \sum_{i=1}^N (v_i - v'_i) \quad (9)$$

其中: v_i 为可见层输入样本; v'_i 为由隐含层得到的重构数据; N 为样本数。

可以在 RBM 训练规则中的每个时期调整学习速率。动态调整学习率为

$$\epsilon_{now} = \begin{cases} \epsilon_{old} + \eta & (\Delta > 0) \\ \epsilon_{old} (1 - \eta) & (\Delta < 0) \end{cases} \quad (10)$$

其中: $\eta \in (0, 1)$ 为增减因子,用来调整学习率; ϵ_{old} 为原来的学习率; ϵ_{now} 为更新后的学习率; $\Delta = Err_{old} - Err_{now}$ 。

对比连续的重构误差 Err_{now} 与 Err_{old} , 当重构误差减小时,加大学习率;当误差增大时,则减小学习率。

3 基于 DAE 和 GDBN 的融合模型

深层神经网络在构造时非常强调模型的混合^[9],目前的深度学习模型大都是由一些简单而相同的基本模型构建,不能同时充分利用不同基础模

型的优点。为了进一步提高模型的特征学习能力,有必要结合不同深度学习模型,设计一种混合模型。受限玻尔兹曼机和自编码器是构成神经网络的基本单元,文献[10]指出,自编码器擅长于扩充数据,而受限玻尔兹曼机擅长投影数据,并基于此提出了基于 DBN 和 SAE 的融合模型,较好地解决了作曲家分类问题,也证明了参数传递在自编码器和深度置信网络这两个模型间是可行并有效的。

降噪自编码器可以从损坏的输入中学习有用的信息并从隐含层重建干净的数据,具有保持原始数据的可恢复性的作用,这对于初级特征的提取非常重要^[10]。对于第 1 层网络,原始数据被映射到一个高维的空间能够增加数据的可分性,并且在这个投影过程中数据的可恢复性能够确保投影结果的相对稳定性,而 RBM 投影的结果依赖于隐节点的概率分布^[10],因此网络的第 1 层由降噪自编码器来构建,学习原始振动数据的鲁棒重构。

笔者结合 DAE 和 DBN 的优势进一步提高特征学习能力,DAE 用于处理原始信号的随机噪声并学习低层特征,DBN 用于基于所学习的低层特征来学习深层特征。

4 基于深度学习融合模型的故障诊断方法

诊断模型以降噪自动编码器和自适应高斯深度信念网络来提取故障特征,利用 PSO-SVM 作为分类器,如图 4 所示。

其步骤如下:

1) 利用传感器采集装备在不同故障状态下的监测信号;

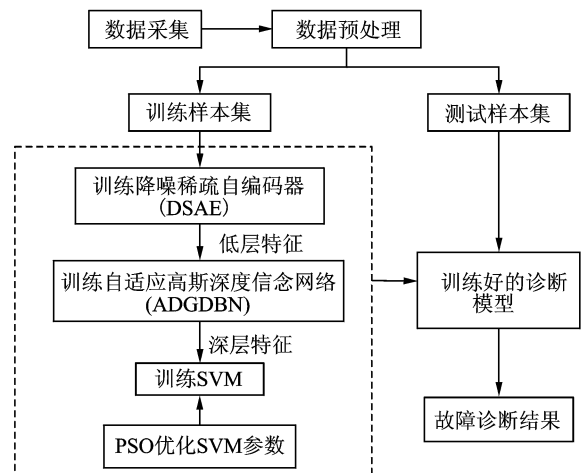


图 4 改进的故障诊断模型

Fig. 4 Flow chart of improved fault diagnosis model

2) 对采集到的数据进行等分样本段后线性归一化,划分训练集和测试集,对模型进行训练;

3) 建立单隐层的 DAE 对输入数据提取低层故障特征;

4) 将 DAE 的隐含层作为第 1 个 GRBM 的可视层,建立多隐层自适应高斯深度信念网络,无监督逐层预训练,提取故障深层特征;

5) 将深度网络提取到的故障特征输入 PSO-SVM 进行训练,得到训练好的诊断模型;

6) 将测试集数据输入训练好的模型,输出识别结果,完成故障诊断。

5 实例分析

滚动轴承是机械装备的核心部件,其健康状况对装备的机械性能、稳定性和寿命有重要的影响。笔者通过轴承故障诊断实验来验证所提算法的机械故障特征提取及诊断能力。

5.1 仿真信号描述

振动信号通常包含大量的信息,因此,基于振动信号的状态监测技术已被广泛应用。凯斯西储大学(CWRU)轴承数据中心以 12 kHz 采样频率从电机驱动机械系统的加速度计获得的轴承状态数据集有以下 4 种故障类型:正常、球故障、内圈故障和外圈故障,每种故障类型分别包含 0.177 8, 0.355 6 和 0.533 4mm 这 3 种故障直径,共有 10 个故障条件。将采集的振动信号以相等的窗口长度划分,每个样本包含 1 024 个数据点,数据集 A, B 和 C 分别包含不同负载下的 70 个训练样本和 30 个测试样本,数据集 D 包含所有 3 个负载的 210 个训练样本和 90 个测试样本。将这些时域振动信号的频谱直接作为特征向量来表示轴承的故障类型,数据集的每个样本都包含 512 个样本点。表 1 描述了所有数据集的细节,其中:RF, IF 和 OF 分别代表滚珠、轴承内圈和外圈故障; $R_{F_1} \sim R_{F_3}$ 代表不同的故障深度。

5.2 实验步骤

1) 原始数据是 512 维的,所以 DAE 输入层节点数为 512,隐含层将原始数据映射到高维度的空间,实验得到最优节点数为两倍空间即 1 024 左右;将 DAE 的隐含层作为 GDBN 第 1 个 GRBM 的可见层,之后依次通过节点数为 500 和 300 的隐层对数据进行压缩,提取深层特征。DAE 噪声系数取 0.5,经反复实验得到自适应学习率增减因子最优值

表 1 轴承故障数据

Tab. 1 Fault data of bearing fault

故障位置	类别标签	故障深度	数据集 A, B, C		数据集 D	
			训练	测试	训练	测试
无	正常	0	70	30	210	90
	RF_1	0.177 8	70	30	210	90
	RF_2	0.355 6	70	30	210	90
滚珠	RF_3	0.533 4	70	30	210	90
	IF_1	0.177 8	70	30	210	90
	IF_2	0.355 6	70	30	210	90
内圈	IF_3	0.533 4	70	30	210	90
	OF_1	0.177 8	70	30	210	90
	OF_2	0.355 6	70	30	210	90
外圈	OF_3	0.533 4	70	30	210	90

$\eta=0.7$, 训练迭代次数为 100。

2) 将提取到的特征输入 PSO-SVM, 初始化 PSO 参数为:最大进化代数为 200, 种群数量为 20, 学习因子 c_1 为 1.5, 学习因子 c_2 为 1.7, 训练和测试模型;

3) 为了验证所提方法的优越性与鲁棒性, 将本研究方法与标准 GDBN、标准 SDAE、自适应 GDBN 在相同的网络结构和 PSO-SVM 参数下的诊断精度进行对比, 标准 GDBN 学习率为 1, DAE 噪声系数取 0.5。

5.3 仿真结果分析

5.3.1 特征提取能力分析

为了观察深度学习的特征提取能力, 利用非线性降维算法(t-distributed stochastic neighbor embedding, 简称 t-SNE)将笔者所提融合模型学习到数据集 A 的故障特征转换映射, 显示为二维散点图, 分别命名为 t-SNE₁ 和 t-SNE₂, 见图 5~图 7。

可以看出, 提出的模型能够对不同故障深度和故障类型的数据进行较好的特征提取, 并且各原始特征点似乎是同心圆, 经过深度学习模型后被线性分割, 这展现深度学习强大的非线性映射能力。

5.3.2 收敛性分析

在实践中通常用平均重构误差来表示 RBM 对原始输入数据的似然度, 并反映训练过程中收敛速度的快慢。图 8 给出了自适应学习率和固定学习率性能的对比如。

可以看出, $\epsilon=1$ 时重构误差一开始呈现急速下降趋势, 引起了算法不稳定; $\epsilon=0.5$ 时收敛速度较慢; 采用自适应学习率时, 迭代到第 20 次时已基本达到稳定 并且重构误差最小, 证明了所提出的自适应策略在提高收敛速度和重构精度方面的有效性。




图 5 原始数据特征分布可视化

Fig. 5 Visualization of the raw data via t-SNE




图 6 DAE 提取低层特征分布可视化

Fig. 6 Visualization of the Low-level feature distribution extracted by DAE via t-SNE




图 7 GDBN 提取深层特征分布可视化

Fig. 7 Visualization of the Deep-level feature distribution extracted by GDBN via t-SNE




图 8 最后 1 个 RBM 的重构误差

Fig. 8 Reconstruction error of the last RBM

5.3.3 故障诊断能力分析

利用各诊断模型分别进行 10 次实验,取最好的 1 次测试结果表征模型的诊断精度。图 9 具体显示了本研究方法在数据集 A 的每个故障状态的识别准确度,数据集 A 的训练集全部被正确识别,测试集的两个样本识别错误。

表 2 为 4 种不同方法在 4 类数据集下的测试结果。分析得出,4 种方法的诊断时间相差不多,这是因为 4 种方法的特征提取网络结构和分类器都比较相似,处理的时间也相近。在不同的负载下笔者提出的融合模型的诊断精度都高于其他 3 种传统模型,并且自适应 GDBN 的性能优于标准 GDBN。

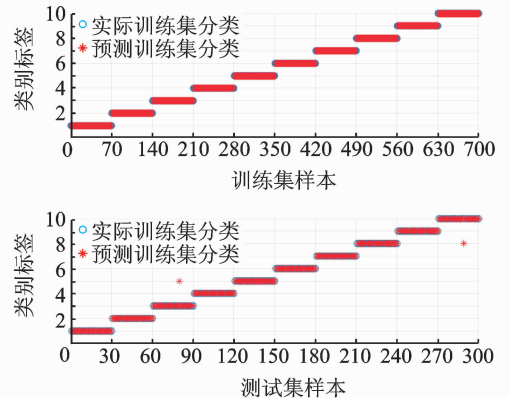


图 9 训练结果与测试结果

Fig. 9 Training results and test results

表 2 不同模型的诊断结果

Tab. 2 Diagnosis results among different models

数据集	本研究方法		标准 SDAE		自适应 GDBN		标准 GDBN	
	诊断时间/s	精确度/%	诊断时间/s	精确度/%	诊断时间/s	精确度/%	诊断时间/s	精确度/%
A	163.6	99.3	170.5	96.7	145.6	98.0	153.4	96.0
B	150.3	100.0	183.7	97.3	175.4	100.0	187.6	96.3
C	155.9	99.0	165.7	94.3	147.4	93.3	149.6	91.3
D	195.6	94.8	190.5	92.0	200.3	93.0	210.2	91.2

5.3.4 鲁棒性分析

为了验证所提方法处理随机噪声的能力,进一步证明所提出方法的优越性,实验中模型由原始数据进行训练,然后对含噪声的数据进行测试。数据集 A 的信号在时域中与加性高斯白噪声合成不同信噪比的信号,并在此之后转换为频率信号,定义为

$$SNR_{dB} = 10 \log_{10} \left(\frac{P_{sigml}}{P_{noise}} \right) \quad (11)$$

其中: P_{sigml} 和 P_{noise} 分别为信号功率和噪声功率。

图 10 给出了信号与噪声混合示例。

噪声信号范围为 $-4 \sim 10$ dB,比较本方法与自适应 GDBN、标准 SDAE,图 11 显示了不同噪声干

扰水平下 3 种模型的故障识别精度,可以看出所提方法略优于 SDAE。与传统 GDBN 相比,随着噪声水平的增加,所提方法的优越性变得明显,表明该方法对一定范围的噪声水平具有鲁棒性。

6 结束语

提出了一种基于降噪自编码器和自适应高斯深度信念网络的深度学习融合模型来解决机械装备故障诊断问题。该模型直接处理原始振动信号,无需耗时的手工特征提取过程,并采用自适应学习率提




图10 信噪混合示例

Fig. 10 Signal-to-noise mixing example




图11 不同模型在不同噪声环境下分类精度


Fig. 11 Classification accuracy of different models in different noise environments

高了网络的收敛速度和诊断精度,优于传统单一的深度学习模型,并且在噪声环境下工作良好。

参 考 文 献

- [1] Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives[J]. IEEE Transactions on Pattern Analysis And Machine Intelligence, 2013, 35(8): 1798-1828.
- [2] 赵光权,葛强强,刘小勇,等.基于DBN的故障特征提取及诊断方法研究[J].仪器仪表学报,2016,37(9):1946-1953.
- Zhao Guangquan, Ge Qiangqiang, Liu Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1953. (in Chinese)

- [3] Guo Xiaojie, Shen Changqing, Chen Liang. Deep fault recognizer: an integrated model to denoise and extract features for fault diagnosis in rotating machinery[J]. Applied Sciences, 2016, 7(1): 41-43.
- [4] Vincent P, Laroche H, Lajoie I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11: 3371-3408.
- [5] Shen Fura, Chao Jing, Zhao Jinxi. Forecasting exchange rate using deep belief networks and conjugate gradient method[J]. Neurocomputing, 2015, 167: 243-253.
- [6] Hinton G E. Training products of experts by minimizing contrastive divergence[J]. Training, 2006, 14(8): 1771-1800.
- [7] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks[C]// Proceedings of the Twentieth Annual Conference on Neural Information Processing Systems. Vancouver, British Columbia, Canada: DBLP, 2006.
- [8] Shao Haidong, Jiang Hongkai, Wang Fuan, et al. Rolling bearing fault diagnosis using adaptive deep belief network with dual-tree complex wavelet packet[J]. ISA Transactions, 2017, 69: 187-201.
- [9] Hassan Y F. Deep learning architecture using rough sets and rough neural networks[J]. Kybernetes, 2017, 46(4): 693-705.
- [10] 胡振,傅昆,张长水.基于深度学习的作曲家分类问题[J].计算机研究与发展,2014,51(9):1945-1954.
- Hu Zhen, Fu Kun, Zhang Changshui. Audio classical composer identification by deep neural network[J]. Journal of Computer Research and Development, 2014, 51(9): 1945-1954. (in Chinese)



第一作者简介:王应晨,男,1995年5月生,硕士生。主要研究方向为人工智能、装备测试与故障诊断。

E-mail: 791191357@qq.com

通信作者简介:段修生,男,1970年8月生,博士、教授。主要研究方向为装备测试与故障诊断。

E-mail: sjzdxsh@163.com

