

文章编号:1671-251X(2020)11-0006-06

DOI:10.13272/j.issn.1671-251x.17633

# 基于堆栈降噪自编码网络的 机械设备磨损状态识别

樊红卫<sup>1,2</sup>, 马宁阁<sup>1</sup>, 张旭辉<sup>1,2</sup>, 高烁琪<sup>1</sup>, 曹现刚<sup>1,2</sup>, 马宏伟<sup>1,2</sup>

(1. 西安科技大学 机械工程学院, 陕西 西安 710054;

2. 陕西省矿山机电装备智能监测重点实验室, 陕西 西安 710054)



扫码移动阅读

**摘要:**通过磨粒铁谱图像识别可实现机械设备磨损状态识别,但基于机器学习的磨粒铁谱图像识别存在较多人工干预、普适性差。为解决上述问题,提出了一种基于堆栈降噪自编码网络的机械设备磨损状态识别方法。将多个降噪自编码网络进行堆叠,即上一个降噪自编码网络隐含层的输出作为下一个降噪自编码网络的输入,并在最后一个降噪自编码网络隐含层后添加 Softmax 分类器,从而构建堆栈降噪自编码网络;利用磨粒铁谱图像对堆栈降噪自编码网络进行无监督预训练,并通过有监督微调优化网络参数,对磨粒铁谱图像进行分类,实现机械设备磨损状态智能识别。实验结果表明:当堆栈降噪自编码网络的激活函数为 Relu、优化器为 Adam、学习率为 0.001 时,网络性能最佳,识别准确率达 98.43%。

**关键词:**机械设备;磨损状态识别;铁谱图像;堆栈降噪自编码网络

中图分类号:TD67 文献标志码:A

## Wear state recognition of mechanical equipment based on stacked denoised auto-encoding network

FAN Hongwei<sup>1,2</sup>, MA Ningge<sup>1</sup>, ZHANG Xuhui<sup>1,2</sup>, GAO Shuoqi<sup>1</sup>,  
CAO Xiangang<sup>1,2</sup>, MA Hongwei<sup>1,2</sup>

(1. College of Mechanical Engineering, Xi'an University of Science and Technology,  
Xi'an 710054, China; 2. Shaanxi Key Laboratory of Mine Electromechanical  
Equipment Intelligent Monitoring, Xi'an 710054, China)

**Abstract:** Wear state recognition of mechanical equipment can be realized by image recognition of ferrography image of wear particle, but ferrography image of wear particle recognition based on machine learning has more manual intervention and poor universality. In order to solve the above problems, a wear state recognition method of mechanical equipment based on stacked denoised auto-encoding network was proposed. Multiple denoised auto-encoding networks are stacked, that is, the output of hidden layer of upper-level denoised auto-encoding network is taken as the input of the next-level denoised auto-encoding network, and Softmax classifier is added after hidden layer of the last level denoised auto-encoding network, so as to construct the stacked denoised auto-encoding network. The ferrography images of wear particle are used for unsupervised pre-training of stacked denoised auto-encoding network, network parameters are optimized by supervised fine-tuning, and ferrography images of wear particle are classified to achieve intelligent wear state recognition of mechanical equipment. The experimental results show that

收稿日期:2020-07-07;修回日期:2020-11-01;责任编辑:盛男。

基金项目:国家自然科学基金重点项目(51834006);陕西省重点研发计划项目(2018ZDCXL-GY-06-04,2019GY-093);陕西省自然科学基金基础研究计划项目(2019JLZ-08)。

作者简介:樊红卫(1984—),男,陕西扶风人,讲师,博士,主要研究方向为机电装备智能监测、诊断、预测与控制,E-mail:hw\_fan@xust.edu.cn。

引用格式:樊红卫,马宁阁,张旭辉,等.基于堆栈降噪自编码网络的机械设备磨损状态识别[J].工矿自动化,2020,46(11):6-11.

FAN Hongwei, MA Ningge, ZHANG Xuhui, et al. Wear state recognition of mechanical equipment based on stacked denoised auto-encoding network[J]. Industry and Mine Automation, 2020, 46(11): 6-11.

the stacked denoised auto-encoding network achieves the best performance when activation function is Relu, optimizer is Adam and learning rate is 0.001, and recognition accuracy is 98.43%.

**Key words:** mechanical equipment; wear state recognition; ferrography image of wear particle; stacked denoised auto-encoding network

## 0 引言

机械设备在长期运行中由于内部零件存在相对运动,零件表面会出现摩擦磨损。磨损不仅会造成材料损耗,还会降低机械设备工作可靠性,增加故障率<sup>[1]</sup>。煤矿井下环境复杂恶劣,且机械设备多处于重载工作状态,加剧了零件表面磨损,容易引发生产事故。因此,有必要对机械设备磨损状态进行识别,以便及早发现设备潜在故障,从而对设备进行有效维护。

油液分析技术是机械设备磨损检测的重要手段,通过分析机械设备油液中磨粒的形态、尺寸等信息,可判定设备的磨损类型和原因。油液分析技术包括光谱分析、铁谱分析、颗粒计数等<sup>[2]</sup>,其中铁谱分析能够检测的磨粒尺寸范围更广<sup>[3]</sup>,在获取磨粒分布图像方面具有一定优势。铁谱分析利用高梯度强磁场将油液中的磨粒按一定规律依次分离,通过对磨粒进行定性、定量分析,获得机械设备状态信息。

磨粒铁谱图像识别<sup>[4]</sup>是铁谱分析技术中的重要研究方向,通过对磨粒铁谱图像的预处理、特征提取等实现机械设备磨损状态识别。经典的铁谱图像智能识别通常采用机器学习算法对磨粒进行自动分类,存在较多人工干预,普适性较差。近年来,随着深度学习<sup>[5]</sup>在计算机视觉领域的飞速发展,基于深度学习的图像识别已成为主流研究方向,具有智能化程度高、适用范围广等优点。自编码(Auto-encoding, AE)网络是一种典型的深度学习方法<sup>[6-7]</sup>,本文在其基础上提出一种堆栈降噪自编码(Stacked Denoised Auto-encoding, SDAE)网络,通过该网络自动提取磨粒铁谱图像的深层特征并进行分类,从而实现机械设备磨损状态智能识别。

## 1 基本原理

### 1.1 AE 网络

AE 网络<sup>[8]</sup>属于前馈神经网络中的非循环神经网络,是一种 3 层无监督学习网络,结构上分为编码器和解码器 2 个部分,如图 1 所示。

编码器将输入样本  $x_i (i=1, 2, \dots, n, n$  为样本数)通过激活函数  $h(\cdot)$  变换到低维空间。

$$y = h(xw + b) \quad (1)$$




图 1 AE 网络结构

Fig. 1 AE network structure

式中:  $y$  为隐含层输出矩阵;  $x$  为输入样本矩阵,  $x = [x_1 \ x_2 \ \dots \ x_n]$ ;  $w$  为编码器的权值矩阵;  $b$  为编码器的偏置矩阵。

解码器将低维空间的信号  $y$  通过激活函数  $f(\cdot)$  逆变换到高维空间,进而重构输入样本。

$$z = f(y) = f(h(xw' + b')) \quad (2)$$

式中:  $z$  为重构后的样本矩阵,  $z = [z_1 \ z_2 \ \dots \ z_n]$ ,  $z_i$  为重构的输入样本;  $w'$  为解码器的权值矩阵;  $b'$  为解码器的偏置矩阵。

### 1.2 降噪自编码网络

在实际应用中,训练样本经常会混入噪声,导致通过 AE 网络学习得到的特征出现偏差。降噪自编码(Denoised Auto-encoding, DAE)网络在 AE 网络的基础上加入噪声,通过学习含噪声的数据,提取更具鲁棒性的特征<sup>[9]</sup>。DAE 网络结构如图 2 所示,引入条件分布  $C_L$  给定产生损坏样本的概率,得到加噪后的输入样本矩阵  $x'$ ,利用损失函数  $L(x, z)$  计算重构误差,通过最小化重构误差提取输入样本的有效特征。




图 2 DAE 网络结构

Fig. 2 DAE network structure

### 1.3 SDAE 网络

为提取输入样本的深层特征,采用深度网络结构<sup>[10-11]</sup>将 DAE 逐层堆叠,构成 SDAE 网络,如图 3 所示。下一个 DAE 网络隐含层的输入为上一个 DAE 网络隐含层的输出,网络使用无监督学习<sup>[12]</sup>的方式完成堆叠过程。SDAE 网络作为无监督学习网络,能够提取输入样本的深层特征并进行特征编

码,但无法进行样本分类。因此,在 SDAE 网络最后一层添加 Softmax 分类器,使整个网络变成有监督学习网络。




图 3 SDAE 网络结构

Fig. 3 SDAE network structure

2 机械设备磨损状态识别

基于 SDAE 网络的机械设备磨损状态识别流程如图 4 所示,具体步骤如下。




图 4 机械设备磨损状态识别流程

Fig. 4 Flow of wear state recognition of mechanical equipment

(1) 利用铁谱分析仪获取磨粒铁谱图像<sup>[13]</sup>,对图像进行灰度化、增强、分割等预处理,并划分训练集与测试集。

(2) 搭建 SDAE 网络,根据训练集输入样本的数据维度和故障类别分别确定输入层和输出层的神

经元数量,初始化 SDAE 网络参数(如激活函数、优化器和学习率等),根据不同参数下网络训练结果确定 SDAE 网络最优参数。

(3) 采用逐层贪婪算法<sup>[11]</sup>训练各个 DAE 网络,将上一个 DAE 网络隐含层的输出作为下一个 DAE 网络隐含层的输入,完成 SDAE 网络预训练。

(4) 在最后一个 DAE 网络隐含层后添加 Softmax 分类器进行训练,得到带标签的磨粒铁谱图像,并使用带标签的磨粒铁谱图像有监督微调 SDAE 网络参数。

(5) 使用测试集测试 SDAE 网络,若测试准确率达到预定要求则输出分类结果,否则转至步骤(2),继续调整 SDAE 网络参数。

3 实验验证

3.1 实验平台

由于煤矿机械设备多采用齿轮传动,为了制备实验所需的铁谱图像,搭建齿轮传动平台,如图 5 所示。该平台采用变频电动机作为动力源,变频电动机的输出轴依次连接由二级行星齿轮、二级直齿轮构成的减速器和用于模拟负载的磁粉制动器。




图 5 齿轮传动平台

Fig. 5 Gear transmission platform

收集齿轮传动平台运行一段时间后的油液样本,通过铁谱分析平台(图 6)将油液样本中的磨粒分离出来,并使磨粒通过磁场沉积在玻璃基片上,完成谱片制作。将谱片置于显微镜下观察,获取磨粒铁谱图像。




图 6 铁谱分析平台

Fig. 6 Ferrography analysis platform

铁谱分析平台主要参数见表 1。

3.2 实验数据

根据不同机械设备磨损状态,可将磨粒分为正常磨粒、切削磨粒、滚动磨粒和严重滑动磨粒,4 种磨粒对应的铁谱图像及特征见表 2。

铁谱图像制备工艺复杂、周期较长,难以在短时

表 1 铁谱分析平台主要参数

Table 1 Main parameters of ferrography analysis platform

| 项目                            | 参数          |
|-------------------------------|-------------|
| 油样用量/mL                       | 6           |
| 溶剂用量/mL                       | 2           |
| 水浴振荡温度/℃                      | 65          |
| 水浴振荡频率/(次·min <sup>-1</sup> ) | 68          |
| 油样水浴浸没范围                      | 完全浸没        |
| 使用溶剂                          | 四氯乙烯        |
| 油液速度/(mL·h <sup>-1</sup> )    | 15          |
| 油液最大压力/kPa                    | 8           |
| 油液输送时间/s                      | 230         |
| 清洗液速度/(mL·h <sup>-1</sup> )   | 5           |
| 清洗液最大压力/kPa                   | 2           |
| 清洗液清洗时间/s                     | 110         |
| 谱片倾角/(°)                      | 4           |
| 磁场强度/T                        | 1.5         |
| 磁场梯度/(T·cm <sup>-1</sup> )    | 5.0         |
| 谱片规格(长×宽×高)/<br>(mm×mm×mm)    | 60×24×0.17  |
| 试管规格(直径×长)/(mm×mm)            | 16×100      |
| 输油管规格(外径×内径×长)/<br>(mm×mm×mm) | 2.4×1.5×320 |
| 谱片加热温度/℃                      | 330~140     |
| 谱片加热时长/s                      | 90          |
| 显微镜使用最小倍率                     | 10×物镜       |
| 显微镜使用最大倍率                     | 50×物镜       |
| 显微镜绿灯背景光强度                    | 中等          |
| 图像捕捉感光度                       | 自动          |
| 图像捕捉曝光时间                      | 自动          |
| 图像捕捉分辨率                       | 2 592×1 944 |
| 图像保存分辨率                       | 2 592×1 944 |
| 图像处理分辨率                       | 220×160     |

表 2 磨粒铁谱图像及特征

Table 2 Ferrographic images and features of wear particle

| 铁谱图像                                                                               | 磨粒类型   | 磨粒特征                  |
|------------------------------------------------------------------------------------|--------|-----------------------|
|  | 正常磨粒   | 薄片,在谱片上沿磁力线呈链状分布      |
|  | 切削磨粒   | 具有环形、曲线形与螺旋形等形状,尺寸长而粗 |
|  | 滚动磨粒   | 较薄块状,轮廓不规则,表面有孔洞      |
|  | 严重滑动磨粒 | 表面光滑、有明显划痕,棱边平直       |

间内获取大量合格的样本供 SDAE 网络训练,因此需要对样本进行扩充。通过背景处理<sup>[14]</sup>和图像增强的方式对样本进行平移、旋转、对比度增强和翻转操作,将原始小样本扩充为深度学习所需的大样本。

3.3 SDAE 网络参数

选用 Tensorflow 作为深度学习框架,借助 Python 语言搭建由 2 个 DAE 网络堆叠组成的 SDAE 网络。设置输入层神经元个数为 784,第 1 个 DAE 网络隐含层神经元个数为 400,第 2 个 DAE 网络隐含层神经元个数为 100,输出层神经元个数为 4,损失函数采用交叉熵。将铁谱图像划分为训练集和测试集,针对 SDAE 网络中激活函数、优化器和学习率等关键参数进行研究,最终确定合理的网络模型。

3.3.1 激活函数

激活函数为神经元提供模拟复杂数据集所需的非线性特征<sup>[15]</sup>,该函数取所有输入的加权和,进而生成一个输出信号。分别设置激活函数为 Sigmoid,Tanh,Relu,SDAE 网络训练过程中训练集准确率如图 7 所示,测试集准确率见表 3。




图 7 不同激活函数下训练集准确率

Fig.7 Accuracy of training set under different activation functions

表 3 不同激活函数下测试集准确率

Table 3 Accuracy of test set under different activation functions

| 激活函数     | Sigmoid | Tanh  | Relu  |
|----------|---------|-------|-------|
| 测试集准确率/% | 87.50   | 87.50 | 98.43 |

从图 7 可看出,在迭代初期采用 Relu 函数的网络训练集准确率增长显著且很快趋于稳定,迭代末期训练集准确率稳定在 98%左右且未出现剧烈振荡;采用 Sigmoid,Tanh 函数时,在相同周期内训练集准确率从一个较低水平开始持续增长且最终未能稳定在较高水平。从表 3 可看出,采用 Relu 函数的网络测试集准确率最高,达 98.43%。因此选择 Relu 函数作为 SDAE 网络的激活函数。

3.3.2 优化器

优化器的任务是调整网络训练的损失至最小

值<sup>[16]</sup>,即使网络的重构误差达到最小值,进而提取输入样本的深层特征。分别设置优化器为 Adam, Adagrad, Ftrl, SDAE 网络训练过程中训练集准确率如图 8 所示,测试集准确率见表 4。




图 8 不同优化器下训练集准确率

Fig. 8 Accuracy of training set under different optimizers

表 4 不同优化器下测试集准确率

Table 4 Accuracy of test set under different optimizers

| 优化器      | Adam  | Adagrad | Ftrl  |
|----------|-------|---------|-------|
| 测试集准确率/% | 98.43 | 93.75   | 96.09 |

从图 8 可看出,使用 Adam 优化器的网络更快达到稳定,训练集准确率稳定在 99% 左右; Adagrad, Ftrl 优化器在整个训练过程的准确率比 Adam 优化器低。从表 4 可看出,使用 Adam 优化器的网络测试集准确率最高,达 98.43%。因此选择 Adam 作为 SDAE 网络的优化器。

3.3.3 学习率

学习率影响网络收敛到局部最小值的速度。若学习率设置过大,网络损失梯度相应增大,产生较大的波动;若学习率设置过小,网络收敛速度降低,所需训练时间过长<sup>[17]</sup>。分别设置学习率为 0.001, 0.01, 0.1, 1, SDAE 网络训练过程中训练集准确率如图 9 所示,测试集准确率见表 5。




图 9 不同学习率下训练集准确率

Fig. 9 Accuracy of training set under different learning rates

表 5 不同学习率下测试集准确率

Table 5 Accuracy of test set under different learning rates

| 学习率      | 0.001 | 0.01  | 0.1   | 1     |
|----------|-------|-------|-------|-------|
| 测试集准确率/% | 98.43 | 94.53 | 25.78 | 22.66 |

从图 9 可看出,当学习率为 0.001 时,网络在整个迭代周期内训练集准确率高达 98% 左右且未出现强幅振荡;当学习率为 0.01 时,整个训练过程的准确率较学习率为 0.001 时略差;当学习率为 0.1 和 1 时,训练集准确率很低。从表 5 可看出,当学习率为 0.001 时,测试集准确率最高,达 98.43%。因此选择 SDAE 网络的学习率为 0.001。

3.4 SDAE 网络性能评价

采用精确率、召回率、F1-score 3 个指标<sup>[18]</sup>评价 SDAE 网络对机械设备磨损状态的识别能力。精确率用于衡量 SDAE 网络对正样本分类的准确程度,精确率越高,表明分类结果越准确;召回率是针对全体样本而言,反映分类结果的全面程度,召回率越高,表明分类结果越全面;F1-score 指标为精确率和召回率的综合结果,F1-score 越高,表明分类综合能力越好。当 SDAE 网络的激活函数为 Relu、优化器为 Adam、学习率为 0.001 时,网络评价结果见表 6。

表 6 SDAE 网络评价结果

Table 6 Evaluation results of SDAE network %

| 磨粒类型   | 精确率 | 召回率 | F1-score |
|--------|-----|-----|----------|
| 正常磨粒   | 100 | 91  | 96       |
| 切削磨粒   | 94  | 100 | 97       |
| 滚动磨粒   | 91  | 97  | 94       |
| 严重滑动磨粒 | 93  | 90  | 92       |
| 平均值    | 95  | 95  | 95       |

从表 6 可看出,4 类磨粒铁谱图像识别的精确率平均值达 95%,表明 SDAE 网络对磨粒铁谱图像分类的准确程度较高,其中对正常磨粒铁谱图像的分类效果最好,未出现误检现象;召回率平均值为 95%,表明 SDAE 网络分类结果较全面,其中对切削磨粒铁谱图像分类时未出现漏检现象;F1-score 平均值为 95%,表明 SDAE 网络的分类综合性能较好。

4 结语

提出了一种基于 SDAE 网络的机械设备磨损状态识别方法。通过 SDAE 网络对磨粒铁谱图像进行深层特征提取,并在有监督微调下对铁谱图像进行自动分类,实现了机械设备磨损状态智能识别。实验结果表明,采用 Relu 激活函数、Adam 优化器和 0.001 学习率时,SDAE 网络性能最佳,识别准确率为 98.43%。

参考文献 (References):

[1] 杨文君,孙耀宁,杨延竹,等. 基于磨粒磨损机理的机

- 械磨损状态监测[J]. 航空动力学报, 2019, 34(6): 1246-1252.
- YANG Wenjun, SUN Yaoning, YANG Yanzhu, et al. Mechanical wear condition monitoring method based on abrasive particle wear mechanism[J]. Journal of Aerospace Power, 2019, 34(6): 1246-1252.
- [2] 安燕. 铁谱分析技术在油液监测中的应用[J]. 酒钢科技, 2019(3): 77-80.
- AN Yan. Application of ferrography analysis technology in oil monitoring[J]. Jiugang Science and Technology, 2019(3): 77-80.
- [3] 彭鹏, 陈李果, 汪久根, 等. 机械磨损的检测技术综述[J]. 润滑与密封, 2018, 43(1): 115-124.
- PENG Peng, CHEN Liguang, WANG Jiugen, et al. A review on detection technology of mechanical wear[J]. Lubrication Engineering, 2018, 43(1): 115-124.
- [4] 周利霞. 铁谱图像识别的理论与方法研究[D]. 杭州: 浙江大学, 2006.
- ZHOU Lixia. The theory and method research of ferrography image recognition [D]. Hangzhou: Zhejiang University, 2006.
- [5] 王联君. 基于深度学习的铁谱图像分类[D]. 南京: 南京航空航天大学, 2018.
- WANG Lianjun. Ferrography image classification based on deep learning [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2018.
- [6] 张春辉. 基于自编码器的稀疏深度模型的研究与应用[D]. 西安: 西安电子科技大学, 2017.
- ZHANG Chunhui. Research and application on sparse deep models based on autoencoders[D]. Xi'an: Xidian University, 2017.
- [7] 郭华平, 刁小宇, 刘宏兵. 一种基于降噪自编码的组合分类算法[J]. 信阳师范学院学报(自然科学版), 2020, 33(4): 657-662.
- GUO Huaping, DIAO Xiaoyu, LIU Hongbing. Ensemble learning based on denosing autoencoder[J]. Journal of Xinyang Normal University (Natural Science Edition), 2020, 33(4): 657-662.
- [8] 王丽华, 杨家巍, 张永宏, 等. 基于堆叠降噪自编码的刀具磨损状态识别[J]. 中国机械工程, 2018, 29(17): 2038-2045.
- WANG Lihua, YANG Jiawei, ZHANG Yonghong, et al. Tool wear condition recognition based on SDAE[J]. China Mechanical Engineering, 2018, 29(17): 2038-2045.
- [9] 尹爱军, 王昱, 戴宗贤, 等. 基于变分自编码器的轴承健康状态评估[J]. 振动. 测试与诊断, 2020, 40(5): 1011-1016.
- YIN Aijun, WANG Yu, DAI Zongxian, et al. Evaluation method of bearing health state based on variational auto-encoder [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(5): 1011-1016.
- [10] CHEN Yanming, LI Chao, GONG Luqi, et al. A deep neural network compression algorithm based on knowledge transfer for edge devices[J]. Computer Communications, 2020, 163: 186-194.
- [11] 李倩. 深度网络模型构建及学习算法研究[D]. 西安: 西安电子科技大学, 2014.
- LI Qian. Research on the model construction and learning algorithms of deep learning[D]. Xi'an: Xidian University, 2014.
- [12] LIANG Kaichao, ZHANG Li, YANG Hongkai, et al. A model-based unsupervised deep learning method for low-dose CT reconstruction[J]. IEEE Access, 2020: 159260-159273.
- [13] 樊红卫, 丁骁, 高烁琪, 等. 基于反相灰度图二值化修正的铁谱图像磨粒特征提取[J]. 润滑与密封, 2019, 44(6): 66-71.
- FAN Hongwei, DING Xiao, GAO Shuoqi, et al. Abrasive particle feature extraction in ferrography based on binary correction of inverse grayscale image [J]. Lubrication Engineering, 2019, 44(6): 66-71.
- [14] 陈展鸿. 基于计算机视觉算法的图像处理技术[J]. 电子世界, 2020(16): 202-203.
- CHEN Zhanhong. Image processing technology based on computer vision algorithm[J]. Electronics World, 2020(16): 202-203.
- [15] PANDA S, PANDA G. Fast and improved backpropagation learning of multi-layer artificial neural network using adaptive activation function[J]. Expert Systems, 2020, 37(5): 1-17.
- [16] 郭敏钢, 宫鹤. AlexNet 改进及优化方法的研究[J]. 计算机工程与应用, 2020, 56(20): 124-131.
- GUO Mingang, GONG He. Research on AlexNet improvement and optimization method[J]. Computer Engineering and Applications, 2020, 56(20): 124-131.
- [17] 郝晓丽, 刘伟, 牛保宁, 等. 基于自适应学习率的运动目标高效检测算法[J]. 电子科技大学学报, 2020, 49(1): 123-130.
- HAO Xiaoli, LIU Wei, NIU Baoning, et al. High-efficiency detection algorithm for moving targets based on adaptive learning rate [J]. Journal of University of Electronic Science and Technology of China, 2020, 49(1): 123-130.
- [18] 侯雪亮, 李新, 陈远平. 基于多神经网络混合的短文本分类模型[J]. 计算机系统应用, 2020, 29(10): 9-19.
- HOU Xueliang, LI Xin, CHEN Yuanping. Short text classification model based on multi-neural network hybrid[J]. Computer Systems & Applications, 2020, 29(10): 9-19.