

DOI: 10.13382/j.jemi.B2205696

CNN 集成机器学习的金属缺陷少样本分类方法*

刘铭璇¹ 唐东林¹ 何媛媛² 周立¹

(1. 西南石油大学机电工程学院石油天然气装备教育部重点实验室 成都 610500;

2. 四川省特种设备检验研究院 成都 610100)

摘要:针对金属缺陷分类,以深度学习为代表的分类方法主要是基于大规模数据的统计学习方法,一方面需要大量优质的标注样本,另一方面对数据中未能涵盖的样本泛化性能差。提出了一种利用集成学习思想,将人类分类知识嵌入到深度学习的少样本分类方法。首先搭建了一个卷积神经网络作为分类模型的骨干网络,并设计了一个利用机器学习的类人学习模块,利用人类分类所用特征进行分类。此外,为了提高模型的泛化性、鲁棒性和更好的融合效果,设计了一种以对数函数为核心的数学集成模型,模块中的数学集成模型利用集成学习思想将骨干网络和类人学习模块的输出进行耦合。实验结果表明,对于小训练集大测试集的金属缺陷数据在分类性能和训练参数量方面优于深度学习方法。此外,类人学习模块和数学集成模型嵌入到不同的骨干网络上均取得了很好的性能,表明所提出的方法适用于多种深度卷积神经网络。

关键词:金属缺陷分类;CNN;集成学习;机器学习;数学集成模型

中图分类号: TP183;TN06 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Classification of metal defects with few-shot based on CNN integrated machine learning

Liu Mingxuan¹ Tang Donglin¹ He Yuanyuan² Zhou Li¹

(1. School of Mechanical Engineering, Southwest Petroleum University, Chengdu 610500, China;

2. Sichuan Special Equipment Inspection Institute, Chengdu 610100, China)

Abstract: For the classification of metal defects, the mainstream classification methods represented by deep learning are mainly statistical learning methods based on large datasets. However, when applying deep learning, not only many quality labeled samples are needed, but also the result may suffer poor generalization. A classification approach with few samples is proposed, which embeds the hierarchical and concise knowledge of humanoid into deep learning. First, a CNN is built as the backbone of the classification model, and a humanoid learning module is designed, which uses the features of human classification to classify. To improve the generalization, robustness and better fusion effect of the model, a mathematical integration model based on logarithmic function is designed. The mathematical integration model in the module couples the outputs of backbone network and humanoid learning module by using the idea of integrated learning. The experimental results show that for the metal defect data of small training set and large test set, the classification performance and the amount of training parameters are better than the deep learning method. Humanoid learning module and mathematical integration model are embedded in different backbone, and good performance is achieved, which shows that the proposed method is suitable for various deep convolution neural networks.

Keywords: classification of metal defects; CNN; ensemble learning; machine learning; mathematical integration models

0 引言

金属腐蚀缺陷严重危害输油管道、原油储罐等油气装备的安全运行,必须对装备缺陷进行及时检测和分类识别^[1]。人工检测缺陷不仅工作量大,且分类结果不稳定易受主观因素影响,因此通过模式识别方法进行分类的需求非常迫切。近年来深度学习中的卷积神经网络(convolution neural network, CNN)在模式识别中被广泛应用。

深度学习被成功应用于计算机视觉、语音识别、自然语言处理、模式识别等领域^[2-4],许多研究^[5]证明了它的通用性和有效性。其中深度学习中的 CNN 在数据分类领域具有巨大优势。CNN 需要大量标注数据作为训练样本,且模型训练时间长,收敛缓慢。在油气装备腐蚀缺陷识别研究领域,金属表面缺陷存在类型多样,样本稀缺,标注困难等问题。

针对上述问题,许多学者从模型本身、模型所用数据、迁移学习等方面进行了研究。早期研究主要集中在模型本身上,如使用正则化^[6]、dropout^[7-8]、修改损失函数等。这些方法可以缓解样本稀缺问题,但是也存在局限性,在数据量较小时修改损失函数和正则化效果有限^[6]。除了对 CNN 模型进行优化,也有针对数据进行改进的方法,如对数据进行扩充的数据增强技术^[9-11]。能够有效减小过拟合风险,但也可能增加无用的样本,且可能只在特定数据集表现良好,不具有普适性。2015~2021 年大量文献利用元学习中的迁移学习来解决深度学习中训练样本不足的问题^[12-14],将在源领域已训练好的模型参数迁移到目标领域模型,但因为迁移学习中源领域与目标领域的数据分布不一致,源领域中所有标记的数据实例和目标领域不匹配易导致分类效果差。近年来,大量学

者对深度学习融合人工提取特征进行了研究。文献[15]将灰度共生矩阵和 Gabor 提取的强特征与 CNN 隐藏层的抽象特征进行融合,并将融合后的特征输入 SVM 进行分类。文献[16]利用统计特征作为 CNN 的训练数据集,使用 CNN-SVM 算法获得了准确的肌肉疲劳分类。在文献[17]中人工提取特征输入到 CNN 中,传统机器学习取代 CNN 的 softmax 层。岳研等^[18]提出一种多通道融合特征提取器从传感器原始信号提取轴承退化特征。这些方法对于分类准确率有一定提升,但在金属表面缺陷数据稀缺、类型多样的实际背景下,也存在融合粗糙,不能充分利用两者优势的缺点,存在实际应用的局限性。

在此基础上,本文提出了一种 CNN 集成机器学习的分类模型。利用集成学习思想将机器学习的分类结果与 CNN 结合,并利用数学集成模型进行结果的融合,能够有效解决 CNN 训练需要大量带标签样本和泛化能力差的问题,将少样本学习引入到金属表面缺陷检测中。针对目前金属表面缺陷数据稀缺问题,快速准确地实现金属缺陷数据和金属非图像数据识别分类,进一步提高缺陷检测领域的自动化程度。

1 本文方法

1.1 本文模型

本文提出的模型结构如图 1 所示。该方法由 3 个部分组成:骨干网络(Backbone)、类人学习模块(humanoid learning module, HLM)、数学集成模型(mathematical integration model, MIM)。Backbone 由一个浅层 CNN 构成。HLM 利用人类分类用到的特征进行分类。最后利用集成学习思想通过 MIM 将 Backbone 和 HLM 各自的输出进行集成融合后得到输出。

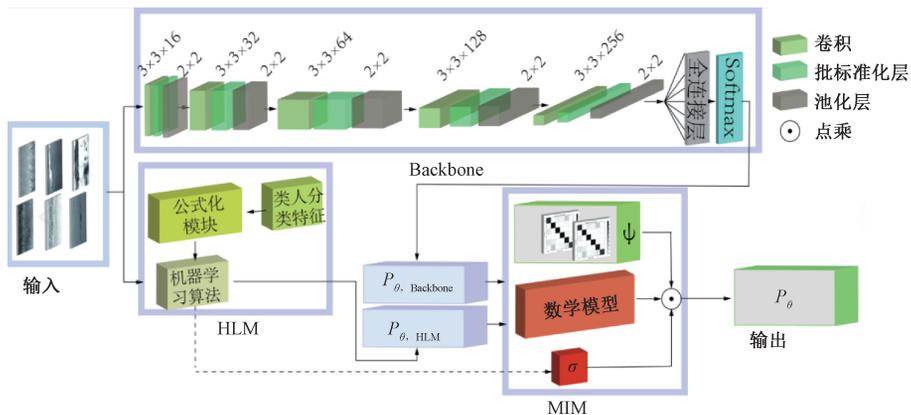


图 1 本文模型结构

Fig. 1 The architecture of the proposed approach

1.2 Backbone

针对小样本数据识别分类,设计了一个浅层 CNN 作为 Backbone 对输入数据进行分类。选择浅层的 CNN 可以缓解深层网络存在的结构复杂、训练参数多、在小样本金属缺陷数据上容易过拟合和需要耗费大量训练时间等问题。

浅层 CNN 如图 1 中 Backbone 模块所示,由 5 个卷积层及相应的批标准化层、5 个池化层、1 个全连接层、1 个 softmax 层组成。卷积操作采用步长为 1、边缘填充 1 个单位的方式进行窗口滑动,对数据做卷积运算。将卷积运算结果输入到池化层中,池化层采用最大池化和步长为 2 的方式进行窗口滑动,来压缩数据消除冗余信息,降低过拟合风险。数据经 5 次卷积和池化操作后输入到全连接层,再输入到 softmax 层,最后输出值即为样本属于每一类的概率,定义如下:

$$\vec{P}_{\theta, \text{Backbone}} = (y_{\theta, \text{Backbone}}^{(1)}, y_{\theta, \text{Backbone}}^{(2)}, \dots, y_{\theta, \text{Backbone}}^{(N)}) \quad (1)$$

式中: θ 表示第 θ 个样本, N 为分类的类别数, Backbone 表示其属于 Backbone 模块。

1.3 HLM

HLM 可缓解 CNN 需要大量金属缺陷训练样本和面对小样本数据泛化性能差的问题。该模块如图 1 中 HLM 部分所示,由类人分类特征、公式化模块和机器学习算法组成。类人分类特征为人类分类该样本时提取的特征,如图片主体灰度值、峭度等。该特征与 CNN 提取的特征具有差异,满足集成学习思想中样本应有所差异的要求。

公式化模块利用一系列公式将类人分类特征模块中的特征具体化,主要使用的公式有灰度平均值、灰度方差、灰度偏斜度、灰度熵、 $p+q$ 阶中心矩等。

机器学习模块由机器学习分类算法构成,利用类人分类特征中的特征进行分类,将其预测的分类结果输入到数学集成模型模块中。最终该模块的输出值为样本属于每一类的概率,定义如下:

$$\vec{P}_{\theta, \text{HLM}} = (x_{\theta, \text{HLM}}^{(1)}, x_{\theta, \text{HLM}}^{(2)}, \dots, x_{\theta, \text{HLM}}^{(N)}), x_{\theta, \text{HLM}}^{(i)} = \begin{cases} 1, & t = i \\ 0, & t \neq i \end{cases} \quad (2)$$

其中, θ 表示第 θ 个样本, N 为分类的类别数, i 为机器学习预测的类别, HLM 表示其属于类人学习模块。

1.4 集成学习

集成学习广泛用于分类任务中,其核心思想是个体学习器有较好性能且每个个体学习器具有差异,最后通过某种策略将学习器结合起来得到最终输出。

由于 CNN 通过卷积操作得到的特征与人类提取的特征不同,由图 2 的混淆矩阵可看出,两种方法在不同缺陷类别上均表现良好。针对样本稀缺的金属表面缺陷,

CNN 提取人类无法理解的特征,而 HLM 则选择性地提取层次化且高度凝练的特征,所以 CNN 和 HLM 是具有差异的分类器,符合集成学习的核心思想。

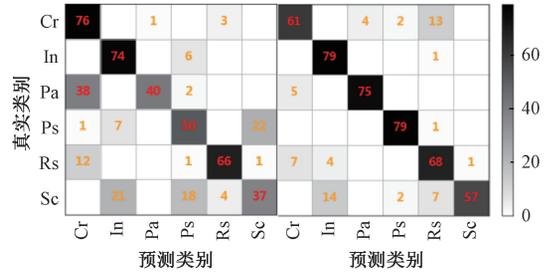


图 2 分类混淆矩阵图(左:CNN,右:HLM)

Fig. 2 Classification confusion matrix graph (left: CNN, right: HLM)

1.5 MIM

通过集成学习思想,利用数学模型将类人学习模块的输出与 Backbone 的输出进行融合。目前多数集成学习只是简单地使用投票、平均、加权平均等方法来组合不同的模型,为更好地融合骨干网络和 HLM 的输出,本文建立了如图 1 中的 MIM,该模块由数学模型 Φ 、混淆惩罚因子 ψ 和机器学习算法影响因子 σ 这 3 部分组成。

1) 数学模型

数学模型的公式定义为:

$$\Phi(x_{\theta, \text{Backbone}}^{(i)}) = (\beta_{\theta}^{(i)} \ln(\alpha_{\theta}^{(i)} x_{\theta, \text{Backbone}}^{(i)} + 1) + \lambda_{\theta}^{(i)}) \quad (3)$$

其中:

$$\alpha_{\theta} = \frac{1}{9N} \sum_{n=1}^N x_{\theta, \text{Backbone}}^{(n)} \quad (4)$$

$$\beta_{\theta} = \frac{1}{N-1} \sum_{n=1}^N (x_{\theta, \text{Backbone}}^{(n)} - \alpha_{\theta})^2 \quad (5)$$

$$\lambda_{\theta} = \left| \sum_{n=1}^N x_{\theta, \text{Backbone}}^{(n)} \right| \quad (6)$$

$$x_{\theta, \text{Backbone}}^{(n)} = \frac{9(y_{\theta, \text{Backbone}}^{(n)} - y_{\theta, \text{Backbone}, \text{min}}^{(n)})}{y_{\theta, \text{Backbone}, \text{max}}^{(n)} - y_{\theta, \text{Backbone}, \text{min}}^{(n)}} \quad (7)$$

其中, α, β, λ 分别表示样本分属种类的数字特征, $x_{\theta, \text{Backbone}}^{(i)}$ 为标准化后的 $y_{\theta, \text{Backbone}}^{(i)}$ 。图 3 说明了 α, β, λ 对数学模型的影响,每个图为控制单一变量, $x_{\theta, \text{Backbone}}^{(n)}$ 增大根据式(4)~(6),对应的数字特征 α, β, λ 也会增大,从而使 $\Phi(x_{\theta, \text{Backbone}}^{(i)})$ 增长更快,且因为式(3)使用对数函数,函数斜率逐渐变小,不会导致 $\Phi(x_{\theta, \text{Backbone}}^{(i)})$ 因 $x_{\theta, \text{Backbone}}^{(n)}$ 增长而变得过大,其变化趋势符合本文模型要求。

2) 混淆惩罚因子

混淆惩罚因子 ψ 由 Backbone 和 HLM 在各类上的准确率组成,从而可以惩罚分类效果较差的部分,定义为:

$$\psi_{\theta}^{(i)} = \frac{\xi_{\theta}^{(i)}}{\mu_{\theta}^{(i)}} \quad (8)$$

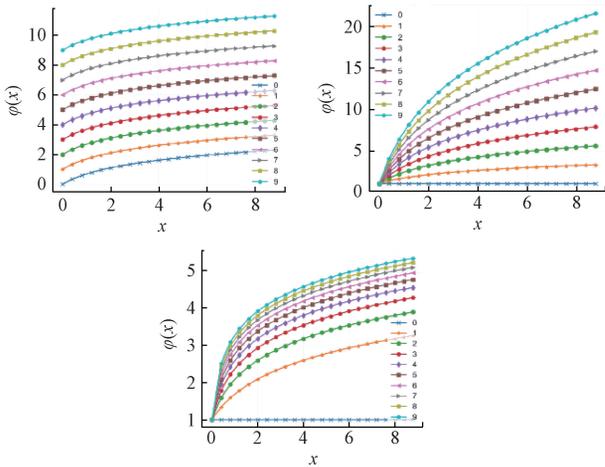


图3 α, β, λ 参数对数学模型输出值的影响

Fig. 3 Effect of α, β, λ on result value of mathematical model

式中： $\mu_{\theta}^{(i)}, \xi_{\theta}^{(i)}$ 分别为 Backbone 和 HLM 前次迭代在 i 类上的准确率。

3) 类人学习影响因子

类人学习影响因子 σ 影响 HLM 的输出所占权重。在 HLM 中嵌入不同机器学习算法会产生不同的分类结果,因此 σ 将根据不同算法人为设定不同的值,其值只和 HLM 嵌入不同机器学习算法有关,与分类种类 i 和样本 θ 无关。

4) 数学集成模型的输出

将 $\varphi_{\theta}^{(i)}, \Phi(x_{\theta, \text{Backbone}}^{(i)}), \sigma$ 为 3 部分相乘,可以得到 MIM 模块在样本 θ 上第 i 类的值,定义如下:

$$x_{\theta, \text{MIM}}^{(i)} = \varphi_{\theta}^{(i)} \Phi(x_{\theta, \text{Backbone}}^{(i)}) \sigma \quad (9)$$

最终可以得到 MIM 模块最终的输出,其为一个概率函数,具体如下:

$$\vec{P}_{\theta} = (x_{\theta}^{(1)}, x_{\theta}^{(2)}, \dots, x_{\theta}^{(N)}),$$

$$x_{\theta}^{(i)} = \begin{cases} x_{\theta, \text{Backbone}}^{(i)} + x_{\theta, \text{MIM}}^{(i)}, & t = i \\ x_{\theta, \text{Backbone}}^{(i)}, & t \neq i \end{cases} \quad (10)$$

其表明对于第 θ 个样本,类人学习模块预测它为第 i 类,则在归一化后的 Backbone 模块输出中的 $x_{\theta, \text{Backbone}}^{(i)}$ 上加上 $x_{\theta, \text{MIM}}^{(i)}$,这样便能将 HLM 和 Backbone 的输出利用集成学习思想融合到一起,得到最终的输出概率 \vec{P}_{θ} 。在进行缺陷识别分类时,最大概率值所属类别缺陷即判定该样本属于那一类缺陷。

2 实验

2.1 数据集

为了验证本文模型的性能,主要采用 NEU-DET 钢铁缺陷数据集进行实验,且选择仿真缺陷数据集 DAGM

2007 进一步进行实验验证。此外引入超声 A 扫描缺陷信号数据集 ULTRA-DET 验证模型在非图像数据上的性能。

图像缺陷数据集 NEU-DET 是文献[19]开放的金属缺陷数据集,收集了热轧钢带的 6 种典型表面缺陷,即轧制氧化皮(Rs)、斑块(Pa)、开裂(Cr)、点蚀表面(Ps)、内含物(In)和划痕(Sc)。每类缺陷含 300 个样本,共计 1 800 张灰度图像,样本分辨率为 200×200 ,如图 4 所示。

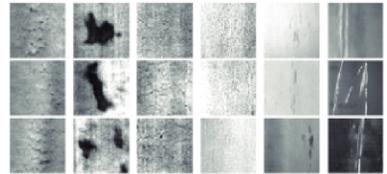


图4 NEU-DET 缺陷样本

Fig. 4 NEU-DET sample

为了进一步验证本文算法针对缺陷数据的分类性能,DAGM 2007^[20]是开放的人工生成的仿真缺陷数据集,仿真缺陷类似真实纹理,共包括 10 种缺陷图像,类别 1~6 包含 150 张缺陷图像,本文使用 6 种缺陷图像验证少样本算法性能,如图 5 所示。

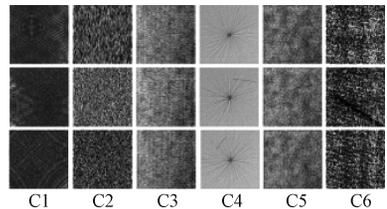
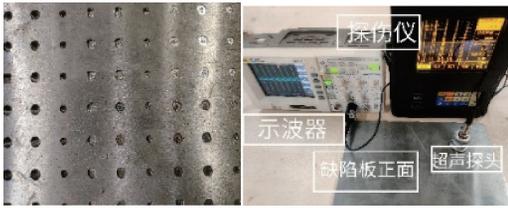


图5 DAGM 2007 缺陷样本

Fig. 5 DAGM 2007 sample

为验证模型在非图像数据上的性能,制作了超声 A 扫描信号非图像缺陷数据集 ULTRA-DET。该数据集模拟实际金属缺陷的不同深度和形状,在厚度为 11 mm 的 Q235 样板上加工了 2、5、8 mm 的 3 种深度缺陷,每种深度均有矩形、圆形、椭圆和不规则形状,如图 6(a)所示,实验以缺陷深度为分类标准。本次实验采用直径 20 mm,频率 2.5 MHz 的超声直探头,TUD210 型数字式超声波探伤仪,RIGOL DS1102D 型示波器,实物连接图如图 6(b)所示,将超声探头涂满耦合剂贴合金属缺陷样板背面进行检测,示波器收集到的缺陷信号为 1×16384 的数据,以 CSV 文件格式输出储存。

为验证本文模型具有的类人分类的性能,设置小训练集大测试集来进行实验。具体样本分布如表 1~3 所示,可测试本文模型是否具有类似人类看少数样本便能分类多数样本的性能。为减小实验随机性,本文实验数据均取每 10 次实验的平均值。



(a) 实验缺陷板 (b) 装置连接图
(a) Experimental defect plate (b) Device connection diagram

图 6 实验样本和设备

Fig. 6 Experimental samples and equipment

表 1 图像缺陷数据集 NEU-DET 缺陷样本分布

Table 1 DataSet NEU-DET defects sample distribution

类型	训练样本	验证样本	测试样本	标签	总计
Rs	10	10	80	0	100
Pa	10	10	80	1	100
Cr	10	10	80	2	100
Ps	10	10	80	3	100
In	10	10	80	4	100
Sc	10	10	80	5	100
总计	60	60	480	-	600

表 2 图像缺陷数据集 DAGM 2007 缺陷样本分布

Table 2 DataSet DAGM 2007 defects sample distribution

类型	训练样本	验证样本	测试样本	标签	总计
Class 1	15	15	120	0	150
Class 2	15	15	120	1	150
Class 3	15	15	120	2	150
Class 4	15	15	120	3	150
Class 5	15	15	120	4	150
Class 6	15	15	120	5	150
总计	90	90	720	-	900

表 3 非图像缺陷数据集 ULTRA-DET 缺陷样本分布

Table 3 DataSet ULTRA-DET defects sample distribution

缺陷深度	训练样本	验证样本	测试样本	标签	总计
2 mm	10	10	69	0	89
5 mm	10	10	68	1	88
8 mm	10	10	67	2	87
总计	216	30	204	-	264

2.2 实验环境和参数设置

本文方法实验平台为 Pycharm, 基于深度学习框架 Pytorch 实现, CPU 为 Intel Yeon (R) E5-1620, 内存为 40 G, GPU 为 GTX1050TI (4 G)。

用 Backbone 分类时, 根据数据集的数据规模大小选择不同学习率和批训练块, 具体如表 4 所示。HLM 的参数设定如表 5 所示。

表 4 Backbone 参数

Table 4 Parameters of Backbone

参数类型	参数
优化算法	Adam 算法
损失函数	交叉熵
学习率	0.001 (ULTRA-DET 数据集) 0.000 1 (NEU-DET/DAGM 2007 数据集)
批训练块	10 (ULTRA-DET 数据集) 10 (NEU-DET/DAGM 2007 数据集)

表 5 HLM 中机器学习的参数

Table 5 Parameters of HLM

算法	设置参数
SVM	C=0.005, kernel='linear',
DT	criterion='gini'
KNN	n_neighbors=5
RF	n_estimators=10, min_samples_split=2

3 实验结果与分析

3.1 HLM 与 MIM 的分析实验

为证明类人学习模块和数学模型的性能, 本文在 CNN 与 CNN+HLM (SVM) 与 CNN+HLM (SVM)+MIM 3 种条件下进行实验。通过观察 NEU-DET 数据集, 可以采用简单的灰度特征和几何特征作为 HLM 所用特征, 具体如表 6 所示。为了说明分类性能好坏, 使用混淆矩阵作为性能评价指标。

表 6 类人提取 NEU-DET 数据集的特征类型

Table 6 Feature types of humanoid extraction NEU-DET dataset

缺陷特征	具体缺陷特征	数量
几何特征	缺陷面积、缺陷周长	2
灰度特征	灰度平均值、灰度方差、歪度、峭度、能量、熵、最大灰度值、最小灰度值、灰度幅值	9

3 种模型分类混淆矩阵如图 7 所示, 可看出 CNN 分类的召回率、精度、准确率都较低。加入 HLM 和 MIM 后, 虽然在识别缺陷 Cr 类上精度有所降低, 这是由于人工设计的特征不适合缺陷 Cr 类, 但在其他缺陷上的评价指标均有显著提高, 整体准确率有较大提升, 通过混淆矩阵图可以计算出 CNN+HLM 和 CNN+HLM+MIM 准确率相比与 CNN 分别提升了 14% 和 14.7%。

CNN+HLM (SVM)+MIM 训练过程如图 8 所示, 前 28 次迭代为 CNN, 第 29 次迭代开始加入 HLM (嵌入 SVM)+MIM。从图中训练集准确率可以看出 CNN 模型在迭代 15 次左右收敛, 测试集准确率在 0.72 左右波动。最后模型加入了 HLM+MIM 准确率达到 0.88。以上结果说明了 HLM 和 MIM 的有效性。

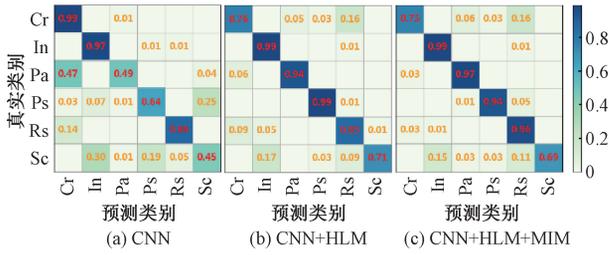


图7 各模型的分​​类混淆矩阵

Fig. 7 Classification confusion matrix

3.2 HLM 嵌入不同机器学习算法

本文的 HLM 可以嵌入不同机器学习算法作为分类算法,为验证该性能,分别将主流的机器学习算法 SVM、DT、KNN 和 RF 嵌入后进行实验。实验结果如图 9 所示,图 9(a)~(d) 分别为 CNN+HLM 嵌入不同算法的混淆矩阵,图 9(e)~(h) 为 CNN+HLM+MIM 嵌入不同算法的混淆矩阵,从这些图可以看出嵌入 RF 算法的效果最好,由混淆矩阵图可计算出 CNN+HLM(RF)+MIM 的平均准确率达到 0.903。嵌入 KNN 算法的效果最差, CNN+HLM(KNN)+MIM 平均准确率为 0.755,其中的 Pa 类下降最多,这是由于 KNN 算法只度量了样本之间的距离相似度而忽略了特征的内在联系。此外,通过 ae、bf、cg、dh 对比,总体上 efgh 分别好于 abcd 也再一次证明了本文数学模型的有效性。

此外,针对小数据集主流方法波动较大,需要多次迭代,且不一定能达到稳定,如图 10 和 11 所示,为 VGG16 和 ResNet50 准确率曲线图,迭代了 300 次还存在剧烈波动的情况,间接说明了卷积神经网络需要大量优质的标注样本和对数据中未能涵盖的样本泛化性能差的问题。相比于主流方法,本文方法具有结构简单、参数量少和迭代次数少的优点。

3.3 对比实验

为了更好地验证本文方法的有效性,采用深度学习主流分类方法、机器学习方法与本文方法进行对比。

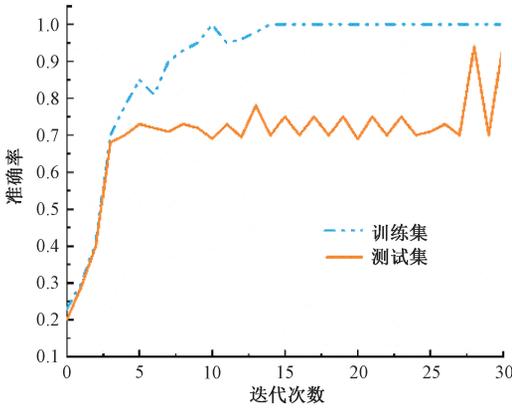


图8 CNN+HLM+MIM 的训练曲线

Fig. 8 Training curve of CNN + HLM+ MIM

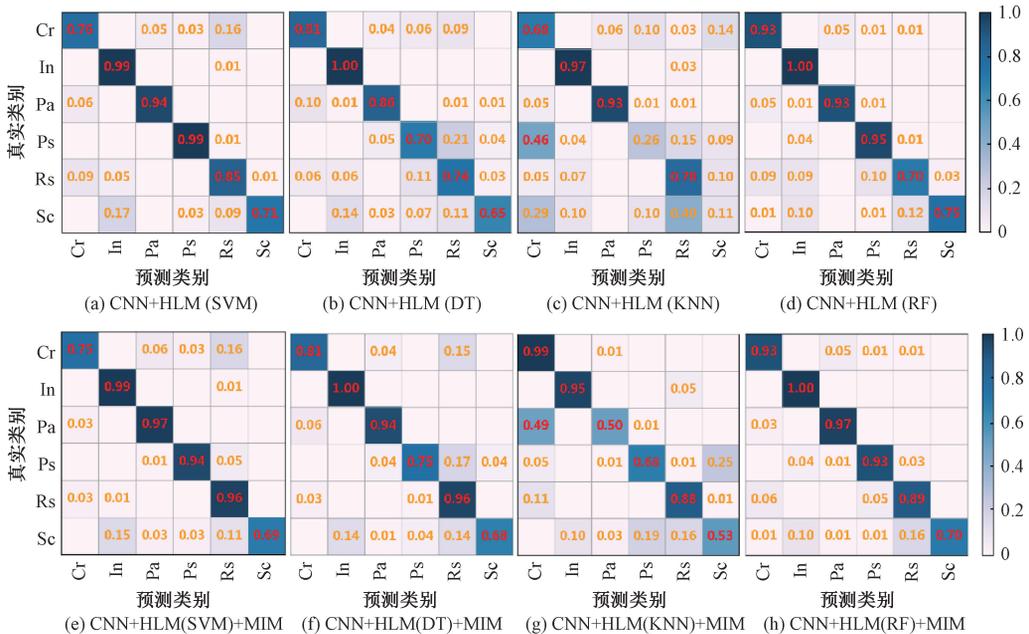


图9 HLM 嵌入不同机器学习算法的混淆矩阵

Fig. 9 Confusion matrix embedded with different machine learning classification algorithms

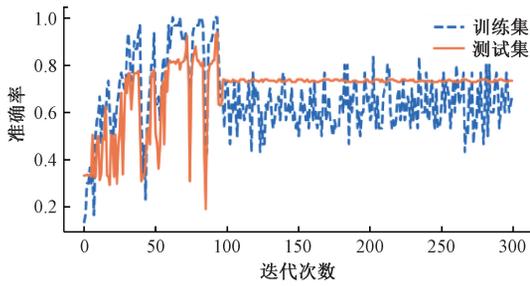


图 10 VGG16
Fig. 10 VGG16

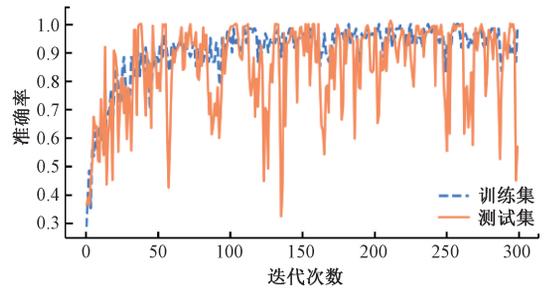


图 11 ResNet50
Fig. 11 ResNet50

深度学习选择经典的 AlexNet、VGG16、ResNet50 和 SqueezeNet 网络进行实验,机器学习选择 SVM 和一种能够提高缺陷识别率的新的特征描述子方法的文献[19]进行对比实验。对比方法采用迁移学习来进行训练,只对最后一层进行修改,修改为输出 6 类,对比实验结果如表 7 所示。可知针对小训练集本文方法有优势,4 种深

度学习算法中只有 SqueezeNet 的分类准确率 89.97% 与本文最优方法 (CNN+HLM (RF) +MIM) 90.03% 接近,但需迭代多次,分类效率远不如本文方法,而 AlexNet、VGG16、ResNet50 的分类准确率更低,分别只有 78.23%、73.25%、80.56%。

表 7 对比实验结果

Table 7 Comparative experimental results

(%)

方法	算法类型	特征提取方式	DAGM 2007			NEU-DET		
			准确率	精准率	召回率	准确率	精准率	召回率
SVM	机器学习	人工	79.36	79.29	79.11	77.35	77.21	77.29
文献[19]	机器学习	人工	89.21	89.64	89.92	88.97	87.36	88.99
AlexNet	深度学习	卷积	80.33	80.46	80.68	78.23	78.11	78.35
VGG16	深度学习	卷积	76.12	75.53	75.83	73.25	72.67	72.91
ResNet	深度学习	卷积	83.89	84.55	84.24	80.56	80.14	80.06
SqueezeNet	深度学习	卷积	91.47	90.03	89.62	89.97	89.22	89.43
本文	本文模型	卷积	92.79	91.53	91.76	90.03	89.59	89.88

3.4 HLM 和 MIM 的适用性

为证明本文的类人学习模块和数学模型的有效性和易嵌入性,将深度学习主流方法作为 backbone 嵌入本文类人学习模块和数学模型中。结果如图 12 所示,可以看出对于 AlexNet、VGG16、ResNet50,嵌入 HLM (RF) 准确率提升最大约 10%。尽管 SqueezeNet 本身准确率较高,但将其以 backbone 嵌入 HLM (SVM) 后准确率仍有 0.94% 的提升。证实了本文 HLM 和 MIM 的优异性能,嵌入到其他骨干网络依然能取得很好的效果。

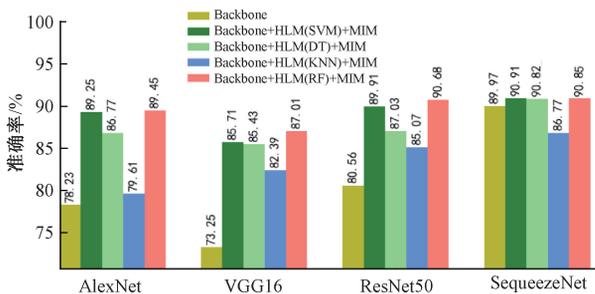


图 12 不同骨干网络嵌入 HLM 和 MIM 的准确率

Fig. 12 Embedding HLM+MIM into baselines

3.5 可视化分析

为了更好地体现本文少样本学习模型的有效分类,在 NEU 数据集上使用 t-SNE (t-distribution stochastic neighbour embedding) 对 6 个种类缺陷图像的分类情况进行可视化,针对本文最优方法 (CNN+HLM (RF) +MIM) 和经典网络 ResNet50 进行对比分析,每个类别设置 100 个样本的特征嵌入,实验结果如图 13 所示。

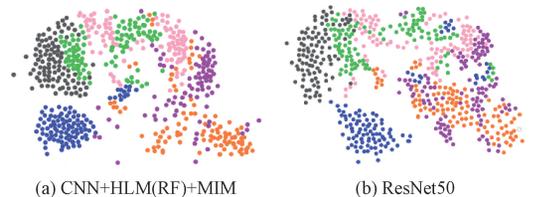


图 13 t-SNE 可视化结果

Fig. 13 Visualization results of t-SNE

从可视化结果可以看出选择实验的两个网络均能实现缺陷分类,可正确区分出 6 个类别的金属表面缺陷,两个可视化图对比中可看出明显差异,在本文方法上如图

13(a)进行训练的分类区分度明显优于基于迁移学习的 ResNet50 深度学习方法如图 13(b)所示,证明了本文使用方法的优异性。

3.6 非图像金属缺陷分类

CNN 模型多用于图像数据,为了验证本文模型在非图像数据上的性能,对非图像数据集 ULTRA-DET 进行了分类。ULTRA-DET 为 1×16 384 的 csv 文件,将超声信号转化为二维图像时需对超声检测信号进行变换计算,先对数据进行归一化处理,后将其幅值范围缩放到 [0, 255] 区间内后将超声检测信号转化为二维 128×128 灰度图像形式,如图 14 所示。

ULTRA-DET 数据集可以采用简单的灰度特征和几何特征作为 HLM 的分类特征,具体特征如表 8 所示。采用准确率、召回率、精度和模型参数量作为评价指标,从多个方面来描述模型性能,对比实验结果如表 9 所示。

表 9 在 ULTRA-DET 数据集上各类方法的对比

Table 9 Comparison of various methods on ULTRA-DET dataset

	CNN	CNN+ HLM(RF)	CNN+HLM (RF)+MIM	ResNet50	VGG16	AlexNet	SqueezeNet	SVM	文献 [19]
准确率	74.76±1.3	75.65±2.8	80.88±0.8	75.86±2.8	75.01±3.1	80.43±0.4	75.71±1.6	70.23±1.1	73.88±0.2
召回率	75.11±0.3	75.32±1.9	80.66±0.5	77.23±2.5	73.21±2.7	79.56±0.8	75.13±1.5	71.46±0.9	74.13±0.3
精度	74.89±0.9	76.97±2.5	83.65±1.2	74.42±2.8	76.83±3.5	81.25±0.7	76.44±1.3	70.74±0.5	73.92±0.7
参数量/百万	0.597	0.585	0.591	24.033	138.361	2.498	1.250	-	-

不同于卷积神经网络,机器学习对数据进行识别时的特征主要是利用特征工程进行特征的提取,其特征主要是利用变换特征。针对超声数据集 ULTRA-DET,选取信号时域有量纲参数和时域无量纲指标参数作为缺陷信号的特征值。时域无量纲参数包括斜度、峰度、峰值、清除指标等,时域有量纲参数包括方差、平均值、最值、幅值等。每个样本提取变换特征后可以得到 6 个本征分量,利用本征分量可以得到共 72 个无量纲统计参数作为缺陷特征。

通过对比 CNN、CNN+HLM(RF)、CNN+HLM(RF)+MIM 的评价指标可以看出:HLM(RF)和 MIM 模块在缺陷图像数据集 ULTRA-DET 上有效,在准确率、召回率、精度上均有较大提升。此外,从表中可以看出,针对小训练集样本,CNN+HLM(RF)+MIM 方法相比于 AlexNet、VGG16、ResNet50、SqueezeNet 和机器学习算法在准确率、召回率、精度都占据优势,且机器学习方法人工提取特征耗时更长。同时,CNN+HLM(RF)+MIM 采用结构简单的浅层 CNN,参数量远远小于 AlexNet、VGG16、ResNet50 和 SqueezeNet,相比经典的网络,本文模型运行效率高,且适用于非图像数据分类。

4 结论

针对少样本金属缺陷数据提出了一种有效的分类模

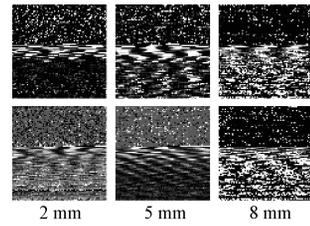


图 14 超声数据灰度图像

Fig. 14 Ultrasonic data converted into images

表 8 类人提取 ULTRA-DET 数据集的特征类型

Table 8 Feature types of ULTRA-DET dataset

缺陷特征	具体缺陷特征	数量
几何特征	缺陷面积、缺陷周长	2
灰度特征	灰度平均值、偏度、标准差、前 5 000 个像素点中像素为 0 的个数	4

型。该模型由浅层 CNN 作为骨干网络进行目标分类,类人学习模块利用人类分类特征,并利用集成学习思想提出了数学集成模型,使浅层 CNN 和类人学习模块的输出能够更好地融合。实验结果表明,人类分类所用特征和 CNN 提取的分类特征有较大差异,采取有效的方式将两者进行融合能有效提高分类器性能,选择小训练集大测试集可以有效分类,且在分类精度和效率方面优于几种主流的 CNN 分类器和机器学习算法。在未来的工作中,主要有以下两个方向可以深入研究:

- 1) 设计更有效的骨干网络,在不影响性能的前提下降低网络复杂性。
- 2) 本文的数学集成模型对于融合两者的输出还能进一步优化,可以进一步探索合适的数学集成模型,找到更合适两者融合的方法。

参考文献

[1] 王海云,王剑平,罗付华.融合多层次特征 Faster R-CNN 的金属板带材表面缺陷检测研究[J].机械科学与技术,2021,40(2):262-269.
WANG H Y, WANG J P, LUO F H. Research on surface defect detection of metal sheet and strip based on Faster R-CNN with multilevel feature[J]. Mechanical Science and Technology for Aerospace Engineering, 2021,40(2):262-269.

[2] ZHU P, WEN L, DU D, et al. VisDrone-VDT2018:

- The vision meets drone video detection and tracking challenge results [C]. Proceedings of the European Conference on Computer Vision (ECCV) Workshops, 2018.
- [3] BIAN X, LIM S N, ZHOU N. Multiscale fully convolutional network with application to industrial inspection [C]. 2016 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2016: 1-8.
- [4] ESTEVA A, ROBICQUET A, RAMSUNDAR B, et al. A guide to deep learning in healthcare [J]. Nature Medicine, 2019, 25(1): 24-29.
- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [6] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[J]. Advances in Neural Information Processing Systems, 2016, 29.
- [7] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [8] BOUTHILLIER X, KONDA K, VINCENT P, et al. Dropout as data augmentation[J]. arXiv preprint arXiv: 1506.08700, 2015.
- [9] GAN J, ZHAI Y, HUANG Y, et al. Research of facial beauty prediction based on deep convolutional features using double activation layer [J]. Acta Electronica Sinica, 2019, 47(3): 636.
- [10] SANTORO A, BARTUNOV S, BOTVINICK M, et al. Meta-learning with memory-augmented neural networks[C]. International Conference on Machine Learning. PMLR, 2016: 1842-1850.
- [11] JIA Y, DARRELL T. Latent task adaptation with large-scale hierarchies [C]. Proceedings of the IEEE International Conference on Computer Vision, 2013: 2080-2087.
- [12] CHEN W Y, LIU Y C, KIRA Z, et al. A closer look at few-shot classification [J]. arXiv preprint arXiv: 1904.04232, 2019.
- [13] AYTAR Y, ZISSERMAN A. Tabula rasa: Model transfer for object category detection [C]. 2011 International Conference on Computer Vision. IEEE, 2011: 2252-2259.
- [14] OQUAB M, BOTTOU L, LAPTEV I, et al. Learning and transferring mid-level image representations using convolutional neural networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1717-1724.
- [15] JIA A D, LI B Z, ZHANG C C. Detection of cervical cancer cells based on strong feature CNN-SVM network [J]. Neurocomputing, 2020, 411: 112-127.
- [16] WANG J, SUN Y, SUN S. Recognition of muscle fatigue status based on improved wavelet threshold and CNN-SVM[J]. IEEE Access, 2020, 8:207914-207922.
- [17] DEMIR F, TURKOGLU M, ASLAN M, et al. A new pyramidal concatenated CNN approach for environmental sound classification [J]. Applied Acoustics, 2020, 170: 107520.
- [18] 岳研,刘畅,刘韬. 基于深度融合神经网络的轴承健康指标构建[J]. 电子测量与仪器学报, 2021, 35(7): 44-52.
- YUE Y, LIU CH, LIU T. Deep fusion neural network for health indicator construction of bearings[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(7): 44-52.
- [19] SONG K, YAN Y. A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects [J]. Applied Surface Science, 2013, 285: 858-864.
- [20] Weakly Supervised Learning for Industrial Optical Inspection [EB/OL]. <https://hci.iwr.uni-heidelberg.de/node/3616>. Accessed: 2020-4-5.

作者简介



刘铭璇, 2018 年于西南石油大学获得学士学位, 现于西南石油大学硕士研究生在读, 主要研究方向为模式识别、图像处理。

E-mail: mingxuanliu99@126.com

Liu Mingxuan received her B. Sc. degree from Southwest Petroleum University in 2018. Now she is a M. Sc. candidate in Southwest Petroleum University. Her main research interests include pattern recognition and image processing.



唐东林 (通信作者), 2006 年于天津大学获得博士学位, 现为西南石油大学教授, 博士生导师, 主要研究方向为模式识别、光机电一体化技术。

E-mail: tdl840451816@163.com

Tang Donglin (Corresponding author) received his Ph. D. degree from Tianjing University in 2006. Now he is a professor and doctoral supervisor in Southwest Petroleum University. His main research interests include pattern recognition and optoelectro-mechanical integration technology.