

DOI:10.19651/j.cnki.emt.2210718

基于融合度量策略的小样本金属缺陷识别研究^{*}

唐东林^{1,3} 刘铭璇^{1,3} 何媛媛² 杨洲^{1,3} 程衡^{1,3} 丁超^{1,3}

(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; 3. 西南石油大学石油天然气装备教育部重点实验室 成都 610500)

摘要: 针对目前金属表面缺陷分类,数据稀缺且标注步骤繁琐昂贵的问题,将小样本度量学习引入金属表面缺陷分类中,提出了一种小样本分布度量网络模型 FDM-FSL;用信息更加丰富的细节描述子来表征图像特征,并通过空间注意力机制筛选获得更具判别力的描述子信息,最后引入融合 KL 散度和 EMD 距离的图像到类的度量方式以考虑查询集和支持集类别的分布一致性。实验结果表明,提出的网络模型在小样本数据集 MiniImageNet 上拥有更加优良的度量能力,5 类 5 样本下平均识别精度相较经典的 RelationNet、CovaMNet、DN4 算法识别准确率提高了 6.34%、5.78%、1.25%。在金属缺陷数据集 NEU-DET 上 5 类 5 样本平均识别准确率分别提高了 2.87%、3.34%、2.5%。

关键词: 金属缺陷分类;度量学习;小样本学习;空间注意力;细节描述子

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.40

Research on few-shot learning of metal defect recognition based on fusion distribution metric strategy

Tang Donglin^{1,3} Liu Mingxuan^{1,3} He Yuanyuan² Yang Zhou^{1,3} Cheng Heng^{1,3} Ding Chao^{1,3}

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

2. Sichuan Special Equipment Inspection Institute, Chengdu 610100, China; 3. Key Laboratory of Petroleum and Natural Gas Equipment of Ministry of Education, Southwest Petroleum University, Chengdu 610500, China)

Abstract: In view of the current metal surface defects classification, data is scarce and tagging process is cumbersome and expensive. This paper introduces the few-shot learning into the metal surface defect classification, proposes a few-shot learning network model with more informative detail descriptor to represent image features: Through adding spartial attention mechanism to screen local information and introducing the fusion measurement to class metric. Experiment results show that our model has better metric effect on MiniImageNet. We gains 6.34%, 5.78% and 1.25% improvements over RelationNet, CovaMNet and DN4 algorithms on the 5-way 5-shot task. The average accuracy of 5-way 5-shot on NEU-DET was improved by 2.87%, 3.34%, and 2.5% respectively.

Keywords: classification of metal defects; metric learning; few-shot learning; spartial attention mechanism; detail descriptor

0 引言

现代工业制造厂对工业制品的外观要求严格,金属缺陷对石油石化行业的大型石化装备如石油储罐、输油管道等具有重大影响^[1],会影响产品使用寿命,出现介质泄露等问题,甚至造成重大安全事故,因此必须定期进行检测。近年来,采用人工检测的方法检测效率低,准确度低,分类结果易受主观因素影响^[2]。且金属表面缺陷存在类型多样,样本稀缺等问题,传统的机器学习模型依赖人工前期处理,深度学习解决了这一难题,使得基于深度学习的缺陷检测

方法逐渐成为人们探索的目标。

近年来,随着深度学习尤其是卷积神经网络理论的不断发展,使得解决缺陷检测分类这一难题成为可能。卷积神经网络在数据分类领域有巨大优势,非常适合作为特征提取和分类的工具,尤其对于复杂周期纹理表面和随机纹理表面中的缺陷提取、识别和分类^[3]。LeNet^[4], VGG^[5], ResNet^[6], GoogleNet^[7]等经典卷积神经网络模型被广泛应用。沈晓海等^[8]基于 Faster RCNN 针对铝材缺陷检测提出了一种包含区域分割、缺陷多标签分类的多任务学习模型。王海云等^[9]采用包含融合多层次特征的金属板带材缺

收稿日期:2022-07-18

*基金项目:四川省市场监督管理局科技计划项目(SCSJZ2022007)资助

陷图,提出的 DNN 算法可检测出不同尺度的多类缺陷。李丹等^[10]提出了一种轻量级部分深度混合可分离网络,使用多种尺寸卷积核有效提升了模型精度。杨珂等^[11]对 Faster RCNN 进行改进,与 YOLOv3 融合后有效降低铸件缺陷漏检率。刘行谋等^[12]改进平衡交叉熵,增加空间金字塔池化结构,通过改进的 YOLOv4 算法有效识别绝缘子缺陷图像。李澄非等^[13]针对小目标检测采用单特征层结构和残差单元提高特征提取能力。

但 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。往往只能针对训练样本中出现过的类别进行识别,很难泛化到未学习过的新类别。为了解决这类问题,深度学习领域提出了小样本学习(few-shot learning, FSL)理论。

小样本学习简单来说就是在只有少量标签样本的情况下进行的深度学习任务。现有的小样本学习可分为 3 类:度量学习、元学习和数据增强。本文研究的度量学习方法通过将样本映射到特征空间,对样本特征间的距离进行度量,将学习到的知识迁移到小样本分类任务上,具有简单有效、计算速度快、容易优化等优点。Vinyals 等^[14]就单样本学习问题进行研究,提出了匹配网络(matching network),通过查询集对支持集样本计算注意力,可以看作带权的最近邻分类器。为了进一步解决小样本学习问题,Snell 等^[15]提出原型网络(prototypical networks),将每个列中的样例数据映射到空间中,提取均值来表示该类的原型。以上模型均基于距离函数来计算相似度,Sung 等^[16]提出的关系网络(relation network),通过构建深度神经网络来计算两个样本之间的距离。之前的方法大多聚焦于一阶统计量的表征上,Li 等^[17]提出了协方差度量网络(CovaMNet),从协方差构建各个样本的特征向量之间的协方差矩阵,实现类别表征与距离度量。以上方法忽略了局部特

征的信息,Li 等^[18]后又提出了深度最近邻神经网络(DN4),将图像与图像之间的相似性度量,不采用求和方式,而是改为图像与类别之间的相似性度量。

传统的度量方法只考虑一阶信息或二阶信息,只能捕获数据间的局部关系。查询集和支持集类别分布存在不对称的关系,现有方法大多采用对称的度量函数来计算查询集和支持集类别的关系。针对以上问题,本文提出了一种基于注意力机制和融合分布度量的小样本网络模型,采用经注意力机制筛选的信息更加丰富的细节描述子来表征图像,考虑相似性度量的非对称性,引入融合全局度量和局部度量的度量函数。将小样本学习引入金属表面缺陷检测中,将源域数据集上训练获取到的先验知识迁移到缺陷识别分类上,解决样本稀缺问题。

1 本文网络模型

1.1 问题设定

在小样本学习任务中,通常包括源域数据 A、支持集 S 和查询集 Q 三类数据集。待分类数据集称为查询集(query set),用以帮助完成分类任务的少量带标签数据集称为支持集(support set)。由于支持集中每类样本稀缺,引入源域数据集 A 去学习可迁移的知识,然后将模型迁移到目标任务中(S 和 Q)。并在给定支持集的条件下对 Q 中的样本进行分类。A 中包含更多的类别和样本数,且与支持集的类别不相交。假设支持集 S 中包含 N 个类别的图像,且每个类别有 R 个样本时,记为 N-way R-shot 小样本任务。

1.2 总体网络模型

本文提出的基于小样本的度量学习网络(fusion distribution metric few-shot learning, FDM-FSL)总体框架图如图 1 所示。

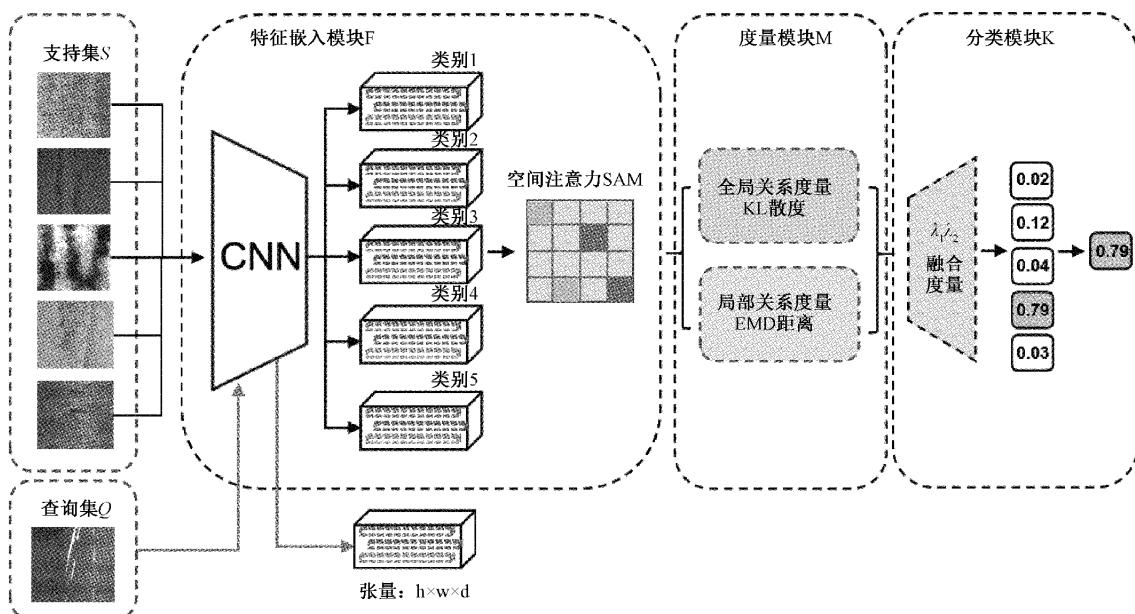


图 1 FDM-FSL 模型总体框架

本文网络主要包含特征集成模块 F, 度量模块 M 和分类模块 K。特征集成模块 F 不采用图像级的特征向量, 去掉全连接层, 使用若干个深度细节描述子, 对应图像的某个局部区域, 经过空间注意力机制输出更具判别力的描述子; 度量模块 M 定义了一个分布度量函数, 由 KL 散度和 EMD 距离利用二维权值向量 λ_1, λ_2 融合计算, 整合了全局级分布关系 GRM 和局部级分布关系 LRM 信息。最后经分类模块 K, 采用最近邻算法, 比较输入图像与支持集每个类别的细节描述子之间的相似度进行分类。

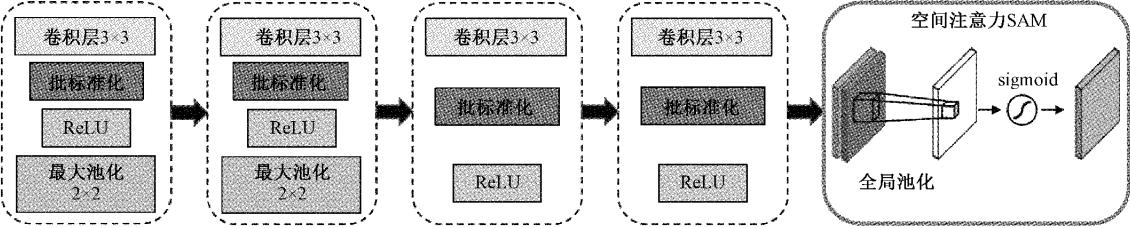


图 2 特征集成模型

前两层结构包含卷积层, 批量归一化层 (batch normalization layer), 线性激活层 (leaky ReLU layer), 2×2 最大池化层 (max-pooling layer)。后两个卷积层去除池化层, 可提高输出图像分辨率, 获得更加丰富的细节描述子信息来表征描述子的分布。

假设我们给定一张大小为 $h \times w$ 的图像, 经过卷积层输出, 特征图可表示为一个 $c \times h \times w$ 的三维张量 T, 可以看作一组 c 维的细节描述子, 则有:

$$\psi(X) = [x_1, x_2, \dots, x_{hw}], x_i \in R^{c \times h \times w} \quad (1)$$

其中, $\psi(X)$ 为映射函数, x_i 为第 i 个细节描述子, 描述子的感受野对应原图像的某块局部特征。对于每张输入的查询图像, 可以用提取的 hw 个描述子来表征空间中的分布。查询集中任意图像可表征为 $\psi(X^Q)$, 支持集图像的所有类别可表征为:

$$S_\psi = \{\psi(X_1^S), \psi(X_2^S), \dots, \psi(X_{NM}^S)\} \quad (2)$$

为了消除噪声描述子的干扰, 筛选出更有区分度的细节描述子, 本文在特征集成部分引入了空间注意力机制 (spartial attention module, SAM), 压缩通道维度^[19], 关注图像中缺陷的位置信息, 如图 2 所示。不同空间位置的细节描述子对样本图像的语义贡献不同, 例如对金属划痕缺陷图像, 有关划痕的延伸部分比背景金属样板的特征更重要, 该过程记为:

$$C = \sigma(f([F_{\text{avg}}^S; F_{\text{max}}^S])) \quad (3)$$

其中, F 为输入特征, AvgPool 和 MaxPool 两种池化操作获得不同信息的特征图合并后再进行特征融合, 得到 $2 \times h \times w$ 的张量, 经过 σ 卷积操作降维为一维向量 $C_{\text{SAM}} = (C_1, C_2, \dots, C_{hw})$ 作为权重系数。

1.4 度量模块 M

传统的度量学习只能捕获查询图像和支持集类别之间的局部相似性, 本文使用 KL 散度和 EMD 距离的融合

1.3 特征集成模块 F

样本量较小时采用基于图像级的特征来表示信息会损失很多有判别力的信息, 用信息丰富的细节描述子可以缓解小样本学习中的样本稀缺问题。为此, 本文采用可以为输入图像提取丰富的深度细节描述子的特征集成模块, 该模块包括卷积模块和注意力机制模块。

小样本度量学习中的特征集成模块一般由卷积神经网络构成。本文使用经典特征集成模块 Conv-64F^[18], 结构为带有四个卷积块的神经网络, 具体结构如图 2 所示。

度量方式来计算描述子之间的距离以获取全局和局部信息。

度量学习通常采用对称的度量函数来计算查询集和支持集类别之间的距离, 而数据集的分布通常并不对称, 测度 KL 散度具有不对称的特点, 可以计算两个随机分布间的距离, 捕获全局级非对称关系。假设经特征集成模块输出的描述子符合高斯分布, 则查询图像分布 $Q = N(\mu_Q, \sum_Q)$, 支持集的类别分布 $S = N(\mu_S, \sum_S)$, 其中 $\mu \in R^c$ 和 $\sum \in R^{c \times c}$ 分别表示一个特定分布的均值向量和协方差矩阵。因此查询集 Q 和支持集 S 之间的 KL 散度可以定义为:

$$D_{KL}(Q \parallel S) = \frac{1}{2} \left\{ \exp \left(\frac{\det \sum_S}{\det \sum_Q} \right) - 1 \right\} + (\mu_S - \mu_Q)^T \sum_S^{-1} (\mu_S - \mu_Q) + \text{tr}(\sum_S^{-1} \sum_Q) \quad (4)$$

其中, tr 是矩阵的迹, det 为矩阵的行列式, KL 散度通过同时计算均值和协方差来计算两个分布之间的距离, 捕获查询集和支持集之间的全局分布关系。但局部分布关系也需要考虑, 本文通过对称分布度量函数 EMD 距离进行计算, 其定义如下:

$$D_{EMD}(Q, S) = \| \mu_Q - \mu_S \|_2^2 + \| \sum_Q^{\frac{1}{2}} - \sum_S^{\frac{1}{2}} \|_F^2 \quad (5)$$

其中, $\| \mu_Q - \mu_S \|_2^2$ 为两个均值向量之间的平方欧氏距离, $\| \sum_Q^{\frac{1}{2}} - \sum_S^{\frac{1}{2}} \|_F^2$ 为两个协方差矩阵之差的 Frobenius 范数计算。该计算方式同时保留一阶和二阶信息, 基于细节描述子的距离计算可获得局部级关系。

获得 KL 散度的全局级度量和 EMD 距离产生的局部级度量结果后, 本文提出使用一种融合度量策略来整合这

两部分计算结果。采用一个二维权值向量 $\lambda = [\lambda_1, \lambda_2]$ 来实现融合,查询集和支持集之间的相似度可定义为:

$$D(Q, S) = \lambda_1 D_{KL}(Q \parallel S) + \lambda_2 D_{EMD}(Q, S) \quad (6)$$

1.5 分类模块 K

对于支持集图像的每一类,该类中的所有描述子将一起用来表征其在空间中的分布,针对类别 a,其所有细节描述子集合起来作为该类别的特征池,记为:

$$G_a = \{x_i; x_i \in \psi(X_h^S) \wedge (aM - M < h < aM)\} \quad (7)$$

针对查询集图像的描述子,通过 kNN 计算查询图像的局部特征到各类特征池之间的相似度,参数 k 值设为 1,每个描述子 x_i^Q 在支持集类别特征池中搜索与其度量距离最近的 K 个描述子,即有:

$$G_{i,a}^Q = kNN(G_m, x_i^Q, K) \quad (8)$$

查询集细节描述子 x_i^Q 与第 a 类特征池的相似度为:

$$S_{i,a}^Q = \sum_{x \in G_{i,a}^Q} \cos(x_i^Q, x) \quad (9)$$

将 X^Q 中所有描述子与第 a 类特征池相似度记为 $s_a^Q = [s_{1,a}^Q, s_{2,a}^Q, \dots, s_{h,a}^Q]$,由于小样本数据集类别样本少,kNN 搜索计算简单高效。以注意力机制输出的向量作为权重系数,查询集图像 X^Q 与第 a 类图像特征池 G_a 的特征相似度为:

$$S(X^Q, a) = \sum_{i=1}^{hw} C_i S_{i,a}^Q \quad (10)$$

整合经 kNN 搜索和融合度量函数的计算结果,图像 X^Q 属于支持集 S 中第 a 类的概率为:

$$p(y^Q = a) = \frac{\exp(S(X^Q, a) + D(Q, S))}{\sum_{a=1}^{hw} \exp(S(X^Q, a) + D(Q, S))} \quad (11)$$

最后使用交叉熵函数损失来度量损失值并更新网络,定义如下:

$$L = - \sum_{i=1}^n y_i \ln(P(y^Q = a | X^Q, S)) \quad (12)$$

其中, y_i 为样本图像的真实标签。

2 实验环境和数据预处理

2.1 实验数据集

本节在 2 个源域数据集和 2 个缺陷数据集上验证所提方法的有效性,主要利用 MiniImageNet^[14] 和 NEU-DET^[20] 数据集评估本文所提出的分类方法,并在本文建立的金属表面缺陷非图像数据集上进行实验。

1) 源域数据集:使用小样本学习经典数据集作为源域数据集,同时也用于测试和验证。

(1) MiniImageNet 数据集共有 100 个类别,每个类别 600 个样本,图片分辨率为 84×84 。在本实验中,64,16,20 类作为训练、验证和测试,并作为主要预训练模型。

(2) CUB200-2011^[21] 数据集共有 11 788 张鸟类图像,涵盖 200 类鸟类,每类约 60 张图像,分配其中 130,20,

50 类用于训练、验证与测试,仅在源域比较实验中使用此数据集。

2) 缺陷数据集:引入两种不同类型数据集作为支持集和查询集,为了证明相同源域数据集下的语义集和非语义集的分类有效性,提取的细粒度特征不依赖于对象的语义性。

(1) NEU-DET 是由东北大学发布的表面缺陷数据库,收集了热轧钢带的六种典型表面缺陷,即轧制氧化皮(RS),斑块(Pa),开裂(Cr),点蚀(PS),内含物(Im)和划痕(Sc),每类缺陷 300 个样本,共计 1 800 张灰度图像,样本分辨率为 200×200 ,部分数据集如图 3 所示。

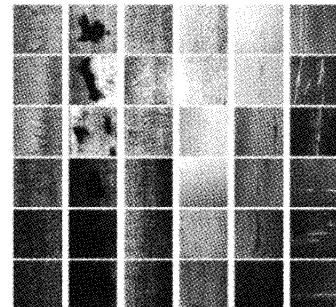
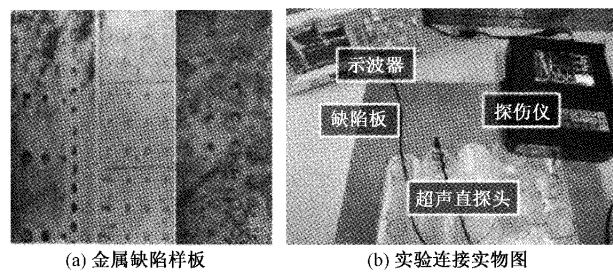
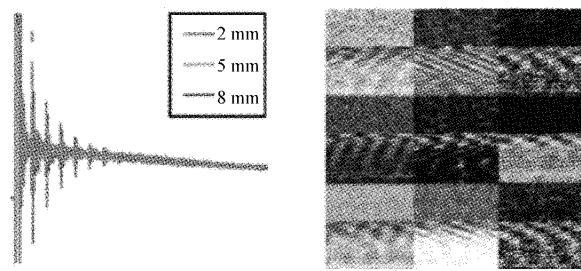


图 3 热轧带钢表面缺陷部分数据集

(2) ULFSL-DET 是本文制作的超声 A 扫描金属缺陷信号非图像数据集,样本包括 3 种不同缺陷深度 2、5 和 8 mm,实验金属样板如图 4(a)。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 4(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,示波器收集到的探伤仪数据以 CSV 文件格式输出储存,超声波形图像如图 4(c)所示。将波形转化成 128×128 的灰度图形式,如图 4(d)所示。



(a) 金属缺陷样板 (b) 实验连接实物图



(c) 超声波形图 (d) 超声灰度图像

图 4 超声 A 扫描金属缺陷信号非图像数据集

2.2 实验环境和参数设置

本文所提出方法的实验平台为 Pycharm, 基于深度学习框架 Pytorch 实现, 利用 Python 实现本文网络, 硬件采用为 Intel® Core™ i5-9400F CPU@2.90 GHz、NVIDIA Geforce GTX 1080 GPU, 运行内存 32 G, 实验超参数设置如表 1 所示。

表 1 实验超参数

参数类型	参数
优化算法	Adam 算法
N-way R-shot	N=5,R=1,5
学习率	0.001(ULFSL-DET) 0.0001(MiniImageNet,NEU-DET)
损失函数	交叉熵
批训练块	10(ULFSL-DET) 30(MiniImageNet,NEU-DET)

本文采用 episode 训练策略^[14] 模拟测试环境, 在源域数据集上预先模拟 N-way R-shot 目标任务, 训练时将任务输入模型, 可以增强知识的迁移能力和模型的泛化能力。

3 实验及结果分析

3.1 对比实验

为了证明本文小样本学习模型的有效性, 同时构造 5-way1-shot、5-way5-shot 两种小样本任务进行实验, 在数据集 MiniImageNet 和 NEU-DET 上进行训练测试。FineTune 为模型迁移后针对不同模型做出的微调处理。从表 2 可以看出, 针对 MiniImageNet 数据集, 5 类 5 样本下平均识别精度相较经典的 RelationNet、CovaMNet、DN4 等算法识别准确率分别提高了 6.34%、5.78%、1.25%。在金属缺陷数据集 NEU-DET 上 5 类 5 样本平均识别准确率分别提高了 2.87%、3.34%、2.5%。有效验证了本文所提 FDM-FSL 模型的有效性和优越性。

表 2 不同算法在 MiniImageNet 和 NEU-DET 上的测试结果

方法	Fine	MiniImageNet		NEU-DET	
	Tune	1 shot	5shot	1 shot	5shot
Prototypical Nets	Y	52.97±0.17	69.02±0.12	61.07±0.67	77.77±0.71
RelationNet	Y	55.12±0.23	71.77±0.19	62.33±0.11	77.45±0.28
MatchingNets	N	54.53±0.16	67.21±0.22	62.11±0.14	76.92±0.27
CovaMNet	N	54.62±0.14	72.33±0.21	62.54±0.12	76.98±0.27
DN4	N	55.28±0.18	76.86±0.17	64.29±0.19	77.82±0.11
FDM-FSL(our Model)	N	57.71±0.12	78.11±0.16	64.65±0.12	80.32±0.14

3.2 特征集成模块 F 对比实验

为了研究不同特征提取模块对小样本学习网络模型的影响, 分别使用经典特征集成网络 ResNet18、Conv-64F、WRN(wide ResNet) 和池化层保留位置不同的浅层卷积神经网络作为特征集成模块在数据集 MiniImageNet 上进行实验。为了保证实验效果, 暂不加入注意力机制, 只关注卷积部分效果, 同时也可验证空间注意力机制的有效性。实验结果如表 3 所示。

表 3 不同特征集成模块网络结构的对比

网络结构	模型参数 /		Acc / %	
	MB	5shot	10shot	
MaxPooling (layer 1)	1.3	71.09	73.02	
Our Model(layers 1,2)	1.3	76.72	78.91	
MaxPooling(layer 3)	1.3	72.57	73.09	
MaxPooling(layers 3,4)	1.3	74.03	75.33	
WRN	25.88	68.14	70.22	
ResNet18	11.69	60.56	63.01	

由表 3 可以看出, 本文使用的 Conv-64F 模块参数量小, 分类准确率最优。这是由于大规模参数模型过度拟合

源域数据集, 导致数据迁移能力下降, 参数量较少的 Conv-64F 可使模型获得更好的泛化能力。

3.3 度量函数消融实验

为了验证本文提出的融合度量策略的有效性, 分别针对 KL 散度、EMD 距离和融合度量策略在 NEU-DET 金属缺陷数据集上进行实验, 如图 5 分别为 EMD 距离、KL 散度和融合度量策略得到的混淆矩阵图。

本文使用的度量模块通过 KL 散度和 EMD 距离的融合度量方式来进行度量。非对称测度 KL 散度可以捕获查询集和支持集类别的细节描述子之间的全局分布关系, EMD 距离则只能度量局部分布关系, 融合两种度量方式可获得更加全面稳定的结果。

通过对六类典型缺陷数据混淆矩阵的计算可以得出单独使用 KL 散度作为度量函数的识别准确率高于使用 EMD 距离作为度量函数的准确率, 体现了非对称测度的优势。融合度量策略相比单独使用 KL 散度和 EMD 距离的度量方式识别准确率分别提高了 6.54% 和 7.23%, 证明了本文使用的融合度量策略的优异性。

3.4 可视化分析

为了更好的体现本文融合分布策略的度量学习模型

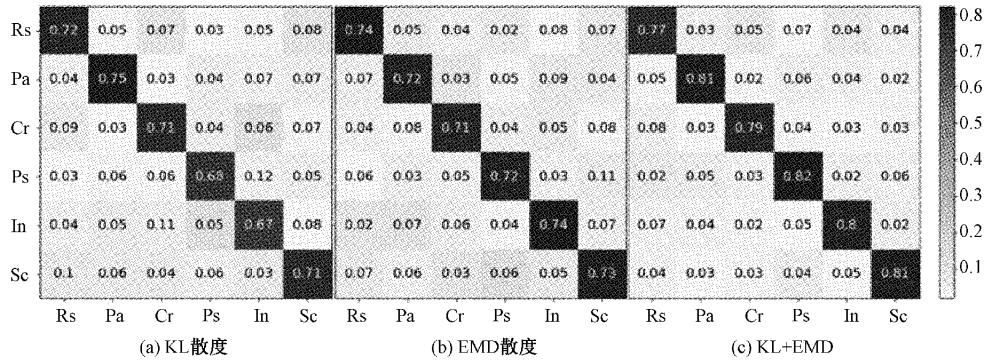


图 5 不同度量方式的混淆矩阵对比

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,每个类别设置 120 个样本特征,t-SNE 可将分类结果进行降维可视化,观察分类效果,如图 6。

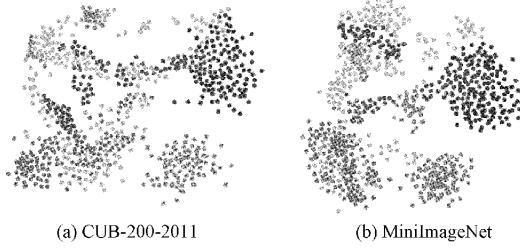


图 6 t-SNE 可视化

从图 6 可见,使用不同源域数据进行训练均能有效实现缺陷分类,图 6(b)在 MiniImageNet 上进行预训练的分类结果相比图 6(a)在 CUB 上预训练的训练结果类内差距小,更清晰区分出不同类别,分类效果优于 CUB 数据集。CUB 数据集每类样本数少,样本总数小,类内差异不明显,MiniImageNet 作为源域数据集进行学习获得了更加优良的泛化能力,用作主要预训练源域数据。

为了进一步说明本文模型注意力机制的有效性,进行了针对热轧钢带的 6 种典型表面缺陷的注意力权重矩阵与热力图的可视化实验,实验结果如图 7 所示。网络主要关注图像中缺陷较为明显和集中的关键位置,与周围金属表面背景的关联度弱。

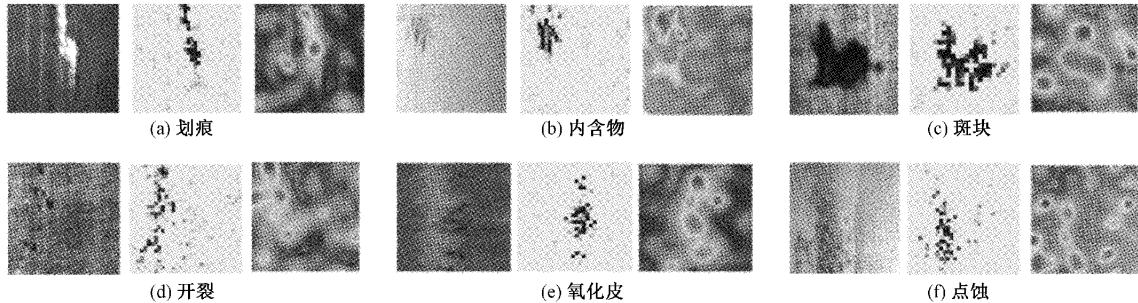


图 7 缺陷图像注意力可视化展示

加入空间注意力机制后,神经网络成功捕捉到了金属缺陷周围相关的细粒度特征。注意力机制针对划痕、斑块、内含物等聚集型缺陷可以进行较精准的识别,对点蚀、开裂、氧化皮等分散型缺陷的识别更困难。由于分散型金属表面缺陷与周围背景关联更强,缺陷较浅不易识别。

3.5 非图像金属表面缺陷分类

为了验证本文提出的小样本学习模型在非图像金属缺陷数据上分类的效果,使用 ULFSL-DET 超声数据集进行分类实验,通过提取灰度图的简单几何特征和灰度特征来实现分类。本数据集针对深度进行分类,类别分为 2、5 和 8 mm。预先在 MiniImageNet 上完成模型预训练,在源数据集上学会对不同类型样本的区分能力。

由于 ULFSL-DET 数据集本身样本量少,训练时每类选择 5 个或 10 个样本,测试时支持集每类也选择 5 个或 10 个样本。在图中对应描述为 5way 和 10way。实验结果曲线图如图 8 所示。

当训练集和测试集样本量相同时准确率有所提升,即 10way-10shot 和 5way-5shot 曲线相比 10way-5shot 和 5way-10shot 曲线准确率更高,这说明了情景训练机制的有效性,当训练集和测试集均取 10 个样本时(图中 10way-10shot 曲线)本文模型表现最优。实验证明本文模型 FDM-FSL 在相同源域数据集 MiniImageNet 下对于语义类和非语义类图像都具有较好的分类效果,提取的细粒度特征不依赖于对象的语义性。

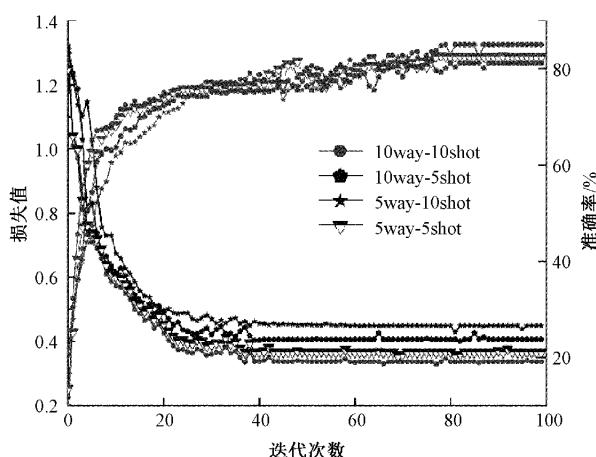


图8 不同样本种类检测曲线对比

4 结 论

针对小样本金属缺陷分类提出了一种有效的的分布度量网络模型 FDM-FSL, 通过深度细节描述子来实现图像特征的表征, 引入注意力机制筛选更具表现力的缺陷特征, 使用 KL 散度和 EMD 距离结合的融合度量策略进行度量。由于金属缺陷类型多样、样本稀缺, 将在源域数据上学习到的分类能力迁移到不相交的类别领域中, 本文使用的引入注意力机制的融合度量方式可以有效提高分类性能, 在分类准确度和模型尺寸方面优于几种主流的度量学习小样本学习模型, 在公开金属缺陷数据集和超声金属缺陷数据集上进行了有效分类。在未来的工作中, 主要有以下的两个研究方向可以深入研究: 针对各类样本数量分布不平衡问题, 即长尾分布问题, 设计有效的网络模型。和针对注意力机制的计算量, 采取更有效, 计算量更少的方式来提取相关特征。

参考文献

- [1] 李萍, 宋波, 毛捷, 等. 深度学习在超声检测缺陷识别中的应用与发展[J]. 应用声学, 2019, 38(3): 458-464.
- [2] 唐东林, 周立, 吴续龙, 等. CNN 融合 PCA-DT 模型的金属缺陷识别研究[J]. 机械科学与技术, 2022, 41(9): 1420-1427.
- [3] 卢荣胜, 吴昂, 张腾达, 等. 自动光学(视觉)检测技术及其在缺陷检测中的应用综述[J]. 光学学报, 2018, 38(8): 23-58.
- [4] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [5] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large scale image recognition[J]. Computer Science, 2014, 45(3): 1-4.
- [6] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [7] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [8] 沈晓海, 栗泽昊, 李敏, 等. 基于多任务深度学习的铝材表面缺陷检测[J]. 激光与光电子学进展, 2020, 57(10): 283-292.
- [9] 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.
- [10] 李丹, 王慢慢, 刘俊德, 等. 基于轻量级卷积神经网络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3): 240-248.
- [11] 杨珂, 方诚, 段黎明. 基于深度学习模型融合的铸件缺陷自动检测[J]. 仪器仪表学报, 2021, 42(11): 150-159.
- [12] 刘行谋, 田浩, 杨永明, 等. 复杂环境背景下绝缘子缺陷图像检测方法研究[J]. 电子测量与仪器学报, 2022, 36(2): 57-67.
- [13] 李澄非, 蔡嘉伦, 邱世汉, 等. 基于改进 YOLOv4 算法的 PCB 缺陷检测[J]. 电子测量技术, 2021, 44(17): 146-153.
- [14] VINYALS O, BLUNDELL C, LILLICRA-P T, et al. Matching networks for one shot learning[J]. Advances in Neural Information Processing Systems, 2016, 3637-3645.
- [15] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[J]. Advances in Neural Information Processing Systems, 2017, 4080-4090.
- [16] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1199-1208.
- [17] LI W, XU J, HUO J, et al. Distribution consistency based covariance metric networks for few-shot learning[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 8642-8649.
- [18] LI W, WANG L, XU J, et al. Revisiting local descriptor based image-to-class measure for few-shot learning [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 7260-7268.
- [19] WOO S, PARK J, LEE J, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision, 2018: 3-19.
- [20] 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.
- [21] WAH C, BRANSON S, WELINDER P, et al. The caltech-ucsd birds-200-2011 dataset [D]. Pasadena: California Institute of Technology, 2011.

作者简介

唐东林(通信作者),博士,教授,博士研究生导师。主要研究方向为机器人技术、无损检测技术、光机电一体化技术。
E-mail: tdl840451816@163.com

刘铭璇,硕士研究生,主要研究方向为模式识别、图像处理在无损检测中的应用。
E-mail: mingxunaliu99@126.com