

DOI:10.19651/j.cnki.emt.2107171

改进关系网络的小样本带钢表面缺陷分类方法^{*}

薛文亮 靳伍银 王全

(兰州理工大学 机电工程学院 兰州 730000)

摘要: 在带钢表面缺陷分类方法的研究中,提出了一种基于改进关系网络的小样本带钢表面缺陷分类方法。该方法借鉴网中网模型可以增强网络对局部感知野的特征辨识能力和非线性表达能力的特点,将该模型与关系网络模型相结合,并采用一种新的自正则化、非单调函数作为激活函数及修正后的平均绝对误差作为损失函数,可以允许更多的信息流入神经网络,使模型学习到更精细的特征表达能力,从而具有更好的准确性和泛化能力。将新模型在 NEU-DET 数据集上进行实验,结果表明,在 5-way 1-shot 任务中获得的缺陷分类准确率为 79.95%,比原模型提高 7.22%;在 5-way 5-shot 任务中获得的缺陷分类准确率为 92.04%,比原模型提高 2.15%。

关键词: 小样本学习;激活函数;损失函数;关系网络;缺陷分类

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.2060

The surface defects classification method of strip steel with small samples based on improved relation network

Xue Wenliang Jin Wuyin Wang Quan

(School of Mechanical and Electrical Engineering, Lanzhou University of Technology, Lanzhou 730000, China)

Abstract: To study the surface defects classification method of strip steel, a small sample classification method of strip steel surface defects based on improved relational network is proposed. In this method, firstly, the net-work-in-network model was used as reference to enhance the characteristics of the network's feature recognition ability and non-linear expression ability of the local receptive fields. Secondly, the model was combined with the relational network model. Thirdly, a new self-normalized non-monotonic function was used as the activation function and the modified average absolute error was used as the loss function to allow more information to flow into the neural network. In this way, the model is enabled to learn more refined feature expression capabilities, so as to have better accuracy and generalization ability. The new model is tested on the NEU-DET data set, and the test results show that the defect classification accuracy rate obtained in the 5-way 1-shot task is 79.95%, which is 7.22% higher than the original model, the defect classification accuracy rate obtained in the 5-way 5-shot task is 92.04%, which is 2.15% higher than the original model.

Keywords: few-shot learning; activation function; loss function; relation network; defects classification

0 引言

带钢是各类轧钢企业为了适应不同工业部门工业化生产各类金属或机械产品的需要而生产的一种窄而长的钢板。其生产技术是钢铁工业发展水平的一个重要标志。带钢以其良好的机械性能在汽车工业、国防工业、航空航天等领域得到了广泛的应用。带钢的表面缺陷不仅会影响产品的外观质量,而且会降低产品的使用寿命,给企业和消费者带来损失。因此在带钢的生产过程中必要对其进行表面质

量检测,以便及时发现缺陷并加以控制,提高企业的经济效益。

近年来,许多学者对钢铁产品表面缺陷的分类方法进行了研究。刘坤等^[1]提出一种融合特征筛选和样本权值更新的 R-AdaBoost 特征选择算法,该算法可以有效提取具有高区分性和独立性的特征,同时提高了缺陷检测算法的准确率。在解决分类问题时,支持向量机(SVM)及其变体是使用较多的一类分类器,并被应用到多个领域。针对如何利用高光谱影像的空间和光谱特征实现地物目标的精确分

收稿日期:2021-07-05

* 基金项目:甘肃省重点研发计划项目(18YF1GA063)资助

类,李玉等^[2]在径向基核函数(RBF)的基础上,提出一种基于张量径向基核函数(Tensor-RBF)和SVM的高光谱影像分类算法。针对传统的运动状态识别方法不能对非跌倒运动进行具体区分的问题,杨智超等^[3]提出了一种结合了分散熵和SVM的运动状态识别方法。王永浩^[4]提出了一种加权结构支持向量机(W-SSVMs)模型,在结构支持向量机(SSVM)的基础上,结合权重生成算法来解决钢板表面缺陷分类问题。

以上方法大都采用了传统的图像分类方法,较多依赖设计者的专业知识和数据的分布特征,很难充分挖掘数据内在的关联。随着基于深度学习的相关技术的迅猛发展,这类技术可以通过学习的策略对数据提取出鲁棒性更高、表达性更强的特征^[5],并应用到故障诊断^[6]、图形分类等任务。张飞等^[7]提出了一种基于深度学习技术的云型图像分类方法,可以获得 85.19% 的测试准确率,比 K 近邻算法和 SVM 算法分别高 53.19%、50.79%。与深度学习相关的表面缺陷分类方法被广泛应用在带钢的生产线上,然而深度模型的性能依赖大量的数据样本,在某些样本数量稀少或者样本获取代价昂贵的领域,很难获得充足的样本,如果强行在样本量不足的数据集上训练模型,则会产生过拟合问题。

为了解决训练样本不足的问题,最直接的办法就是进行数据增强^[8],如图像的几何变换、色彩空间变换、几何形状相对于光度的变换等。然而当样本数量仅有几个或者几十个时,以上方法依然无法构造出满足训练要求的样本数量。此时便需要一种能够满足少样本的学习方法,即小样本学习^[9]。该方法不仅可以应用在机器的智能故障诊断^[10],还可以用于医学罕见病的辅助诊断^[11-12]。基于小样本学习的图像分类方法可以分为迁移学习^[13]、元学习^[14]、对偶学习^[15]和贝叶斯学习^[16]等。其中元学习又叫学会学习,利用以往的知识经验来指导新任务的学习,使网络具备学习的能力,其具有代表性的研究成果是匹配网络模

型^[17],原型网络模型^[18]及关系网络模型^[19]。

针对带钢表面缺陷分类方法的研究,本文提出一种基于改进关系网络的小样本带钢表面缺陷分类方法。该方法将网中网^[20](network in network)与关系网络模型相结合,更换更高效的激活函数与损失函数,实现少量样本情况下对带钢表面缺陷的分类。

1 基本原理

1.1 模型的选择

近两年小样本学习较为优秀的模型有匹配网络、原型网络、关系网络、模型未知网络^[21]。根据文献[17-19, 21]对比模型在 mini-ImageNet 数据集上的准确率,结果如表 1 所示。从表 1 可以看出,关系网络模型的准确率较模型不可知网络和匹配网络均有一定幅度的提升,与原型网络相比,关系网络模型的准确率在 5-way 1-shot 时有一定的提升,在 5-way 5-shot 时表现略有不足。综合对比后选择关系网络模型作为本文的基础模型。

表 1 不同模型在 mini-ImageNet 数据集上的准确率

模型	是否微调	5-way 1-shot	5-way 5-shot	%
模型未知网络	是	48.70±1.84	63.11±0.92	
匹配网络	是	43.56±0.84	55.31±0.73	
原型网络	否	49.42±0.78	68.20±0.66	
关系网络	否	50.44±0.82	65.32±0.70	

1.2 关系网络模型

文献[19]提出的关系网络模型主要分为嵌入模块和关系模块,如图 1 所示。其中,嵌入模块的主要作用是将支撑集样本与查询集样本映射到某个特征空间得到特征向量;关系模块的主要作用是评估支撑样本与查询样本的相似性。

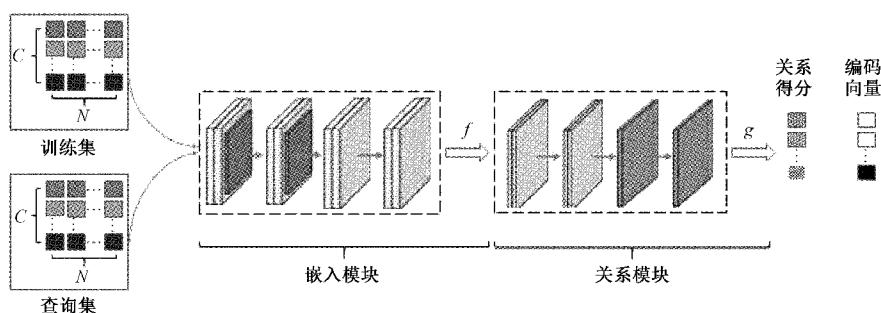


图 1 关系网络结构

1.3 改进关系网络模型

1) 关系模块

本文关系模块保留原网络关系模块的结构,包含 2 个卷积单元和 2 个全连接层,每个卷积单元包含 1 个卷积核为 3×3 的 64 通道的卷积层,其后接 ReLU 激活函数和

1 个 2×2 的最大池化层,第 1 个全连接层使用 ReLU 激活函数,第 2 个全连接层使用 Sigmoid 激活函数。

2) 嵌入模块

由于带钢表面缺陷呈现形式具有随机性与多变性、缺陷类内样本差异较大,导致从图像中提取的全局特征具有

不稳定,受网中网模型可以增强网络对局部感知野的特征辨识能力和非线性表达能力的启发改进嵌入模块。在该结构中,通过在每个卷积层后增加 1 个卷积核为 1×1 的卷积层形成网中网模型结构,使得模型能够提取更加抽象的特征以解决复杂的非线性问题。同时,在嵌入模块中将卷积核为 3×3 的卷积层先利用卷积核为 1×1 的卷积层降维,再利用卷积核为 3×3 的卷积层升维的操作达到减少参数数量的目的。

原关系网络模型中使用 ReLU 作为激活函数。如图 2 所示,当 $x > 0$ 时,ReLU 激活函数收敛较快;当 $x < 0$ 时,梯度为 0,这个神经元及之后的神经元梯度永远为 0,导致相应参数永远不会被更新,出现神经元坏死现象 (dead ReLU problem)。针对这一问题,本文使用 Mish^[22] 作为激活函数,其形式及一阶导形式分别如式(1)、(2)所示。

$$f(x) = xtanh(\text{softplus}(x)) = xtanh(\ln(1+e^x)) \quad (1)$$

$$f'(x) = \frac{e^x w}{\delta^2} \quad (2)$$

其中, $f(x) \in (-0.31, \infty)$, $w = 4(x+1) + 4e^{2x} + e^{3x} + e^x(4x+6)$, $\delta = 2e^x + e^{2x} + 2$ 。该激活函数上无边界,避免了由于封顶而导致的饱和,饱和通常会导致训练速度因接近 0 的梯度而大幅下降。函数下端保留较小的负值信息,而不是像 ReLU 那样的硬零边界,他的属性有助于更好地表达和信息流动。此外,与 ReLU 不同的是,Mish 是连续可微的,这是一个更好的特性,因为它避免了奇异点,从而避免了在执行基于梯度的优化时产生的副作用。激活函数曲线对比如图 2 所示。

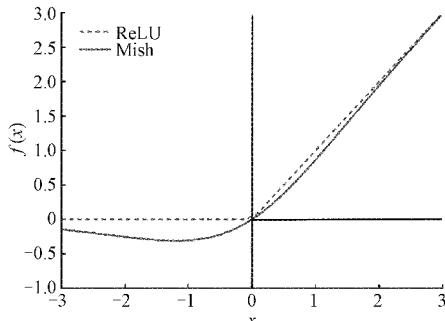


图 2 激活函数对比图

原关系网络模型使用均方误差 (mean square error, MSE) 作为损失函数。如图 3 所示,该函数曲线光滑,处处可导,便于使用梯度下降算法,而且随着真实值和预测值的差值 x 的减小,梯度也在减小,这有利于收敛。MSE 的公式如式(3)所示,其中 $f(x)$ 是样本的预测值, y 是该样本对应的真实值。由公式可知当真实值和预测值的差值大于 1 时,会放大误差;当差值小于 1 时,则会缩小误差,这是平方运算决定的,也就是说该损失函数对离群点比较敏感。

$$\text{MSE} = \frac{\sum_{i=1}^n (f(x_i) - y_i)^2}{n} \quad (3)$$

本文使用修正后的平均绝对误差 SmoothL1 作为损失函数。公式如式(4)、(5)所示,其中 $f(x_i), y_i$ 分别是样本 x_i 对应的预测值与真实值。相比于 MSE 损失函数,该损失函数对离群点、异常值不敏感,梯度变化相对更小,在某些情况下防止了梯度爆炸,使模型获得更好的训练效果。损失函数曲线对比如图 3 所示。

$$\text{SmoothL1} = \frac{1}{n} \sum_{i=1}^n z_i \quad (4)$$

$$z_i = \begin{cases} 0.5(f(x_i) - y_i)^2, & |f(x_i) - y_i| < 1 \\ |f(x_i) - y_i| - 0.5, & \text{其他} \end{cases} \quad (5)$$

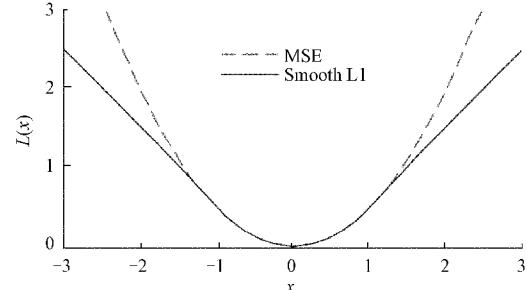


图 3 损失函数对比图

1.4 模型训练的基本原理

训练前,需要将数据集划分为训练集 D_{Train} 、 D_{Support} 和测试集 D_{Test} 3 部分。其中训练集 D_{Train} 用于泛化性能学习的元训练,测试集 D_{Test} 用于模型的性能测试,并且 D_{Train} 和 D_{Test} 没有交集, D_{Support} 和 D_{Test} 具有相同标签空间。训练时,每个周期由若干个元任务组成,每个元任务中的数据均取样自 D_{Train} 并划分为训练集 D_{train} 和查询集 D_{query} 。对于 C -way K -shot 的问题(其中, C 代表类别数量, K 代表每类中的样本数量),训练集 $D_{\text{train}} = \{(x_i, y_i)\}_{i=1}^m$, 其中, x_i 是从 D_{train} 中随机选取的 C 个类别样本中的样本, y_i 是 x_i 对应的标签,且 $m = C \times K$; 查询集 $D_{\text{query}} = \{(x_j, y_j)\}_{j=1}^n$, 其中, x_j 与 x_i 属于同一类别的不同样本, y_j 是 x_j 对应的标签。

假设嵌入模块的映射函数为 f_φ , 关系模块的映射函数为 g_ϕ 。训练集的样本 x_i 与查询集的样本 x_j 进入嵌入模块分别得到嵌入向量 $f_\varphi(x_i)$ 和 $f_\varphi(x_j)$, 嵌入向量经过组合后得到 $\mathbf{C}(f_\varphi(x_i), f_\varphi(x_j))$ 。然后将组合向量输入关系模块得到一个关于 x_i 与 x_j 的关系评价 $r_{i,j}$ 且 $r_{i,j} \in [0, 1]$, 即 x_i 与 x_j 属于同一类别, $r_{i,j} = 1$; x_i 与 x_j 不属于同一类别, $r_{i,j} = 0$ 。 $r_{i,j}$ 的计算公式如下^[19]:

$$r_{i,j} = g_\phi(\mathbf{C}(f_\varphi(x_i), f_\varphi(x_j))), i = 1, 2, \dots, m \quad (6)$$

训练的目标函数为:

$$\varphi, \phi \leftarrow \begin{cases} \underset{\varphi, \phi}{\operatorname{argmin}} \sum_{i=1}^m \sum_{j=1}^n 0.5(r_{i,j} - y_i)^2, & |r_{i,j} - y_i| < 1 \\ \underset{\varphi, \phi}{\operatorname{argmin}} \sum_{i=1}^m \sum_{j=1}^n (|r_{i,j} - y_i| - 0.5), & \text{其他} \end{cases} \quad (7)$$

训练过程即模拟小样本任务的分类场景。

2 实验分析与讨论

2.1 实验环境与数据集

实验均在 Intel(R) Core(TM) i7-9700K, 3.60 GHz、32 GB 内存, NVIDIA GeForce RTX2080Ti 显卡, Windows 10 操作系统上, 通过 PyTorch 深度学习框架完成实验。本文在 mini-ImageNet 数据集和东北大学发布的 NEU-DET 数据集^[23]进行实验验证, 数据集的部分图像示例如图 4 所示。训练时每个训练周期都从训练集中随机选取 C 类, 每类选取 K 个样本进行元训练, 测试时以同样的方法在测试集中选取样本进行测试。所有实验都采用 Adam 优化算法^[24], 初始学习率设为 0.001。训练时增强样本的方式为 [0, 90, 180, 270] 中随机角度旋转, 每训练 1 000 个周期就从查询集中随机抽取 1 000 个元任务验证模型分类的准确率。

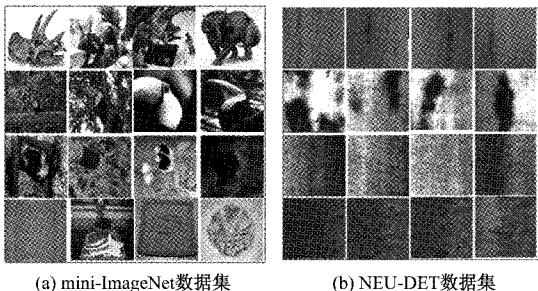


图 4 数据集部分图片示例

2.2 mini-ImageNet 数据集的小样本学习任务

mini-ImageNet 数据集包含 100 个类共 60 000 张彩色图片, 其中每类有 600 个样本, 每张图片的规格为 84×84。本文在 mini-ImageNet 数据集进行实验验证时, 延续文献[20]中对数据集的划分方式: 使用其中的 64 个类作为训练集, 20 个类作为测试集, 剩下的 16 个类作为验证集。

图 5 为改进关系网络与原关系网络 200 000 次迭代的测试准确率和损失曲线。从图中可以看出, 图 5(a)在前 80 000 次的迭代中原关系网络的准确率曲线上升较改进后的关系网络快, 在 80 000 次后的迭代中, 改进后的关系网络准确率曲线超过原关系网络准确率曲线, 并有了一定幅度的提升; 图 5(b)在前 100 000 次的迭代中原关系网络准确率曲线上升较改进后的关系网络快, 在 100 000 次后的迭代中, 改进后的关系网络的准确率曲线超过原关系网络准确率曲线, 并有了一定幅度地提升。而两幅图中改进后的关系网络损失曲线明显比原关系网络下降的快, 且损失曲线振幅要小得多。

在带钢表面缺陷分类任务中, 带钢表面缺陷数据集的图像样本数量远远小于 mini-ImageNet 数据集, 为了探寻训练样本的充分度与模型分类能力之间的关系, 利用改进后的关系网络模型, 在保持 mini-ImageNet 测试集不变的前提下, 改变训练集的类别数和每一类包含的样本数进行

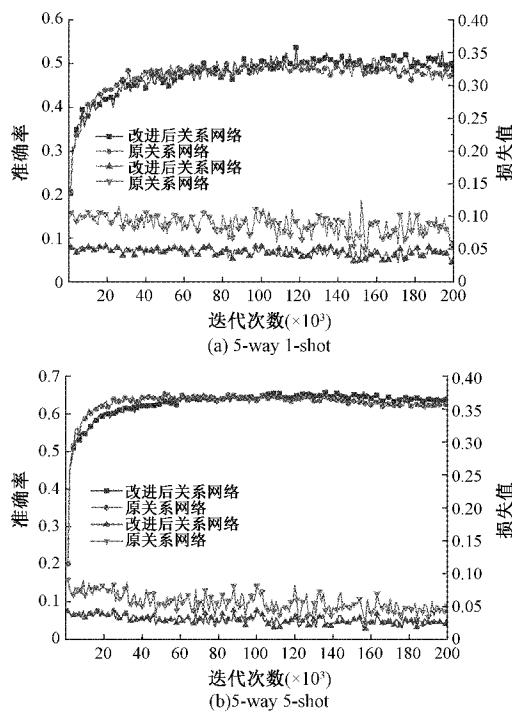


图 5 mini-ImageNet 数据集上测试准确率和损失曲线

训练。根据训练结果得到如图 6 所示准确率变化曲线。图 6(a)、(b)是在 mini-ImageNet 的训练集中保持每类样本数不变, 分别抽取 16、32、48、64 类作为训练集, 迭代 200 000 次得到的准确率变化曲线。由图可以看出, 随着训练集样本类别数的增加, 模型的分类准确率明显呈现上升趋势, 稳定性也逐渐增强; 图 6(c)、(d)是在 mini-ImageNet 的训练集中保持类别总数不变, 从每类分别抽取 100、200、300、400、500、600 个样本作为训练集, 迭代 200 000 次得到的准确率变化曲线。由图可以看出, 当每类包含 100 个样本时, 模型很快进入过拟合状态, 但是在训练样本数超过 300 后, 训练集每类的样本数量对模型分类能力影响不大。

产生上述现象的原因是关系网络采用元学习的训练策略, 该策略以多个并行任务为核心思想, 通过计算获得各个任务的合成梯度来更新网络参数。训练集的类别越多, 元任务之间的梯度差异性也越大, 训练出来的模型对新类别的泛化能力也越强。在每类的样本数量方面, 只要该类现有的样本具有足够的代表性, 即使增加该类的样本数量, 在元学习策略下, 对训练结果也不会有明显的影响。

2.3 NEU-DET 数据集的小样本学习任务

数据集内收集了 6 类带钢表面缺陷图片各 300 张。缺陷分别为压入氧化铁皮 (rolled-in scale, RS)、斑块 (patches, Pa)、裂纹 (crazing, Cr)、麻点 (pitted surface, PS)、夹杂 (inclusion, In) 以及划痕 (scratches, Sc)。NEU-DET 数据集的类别数只有 6 类, 不足以构成足够多

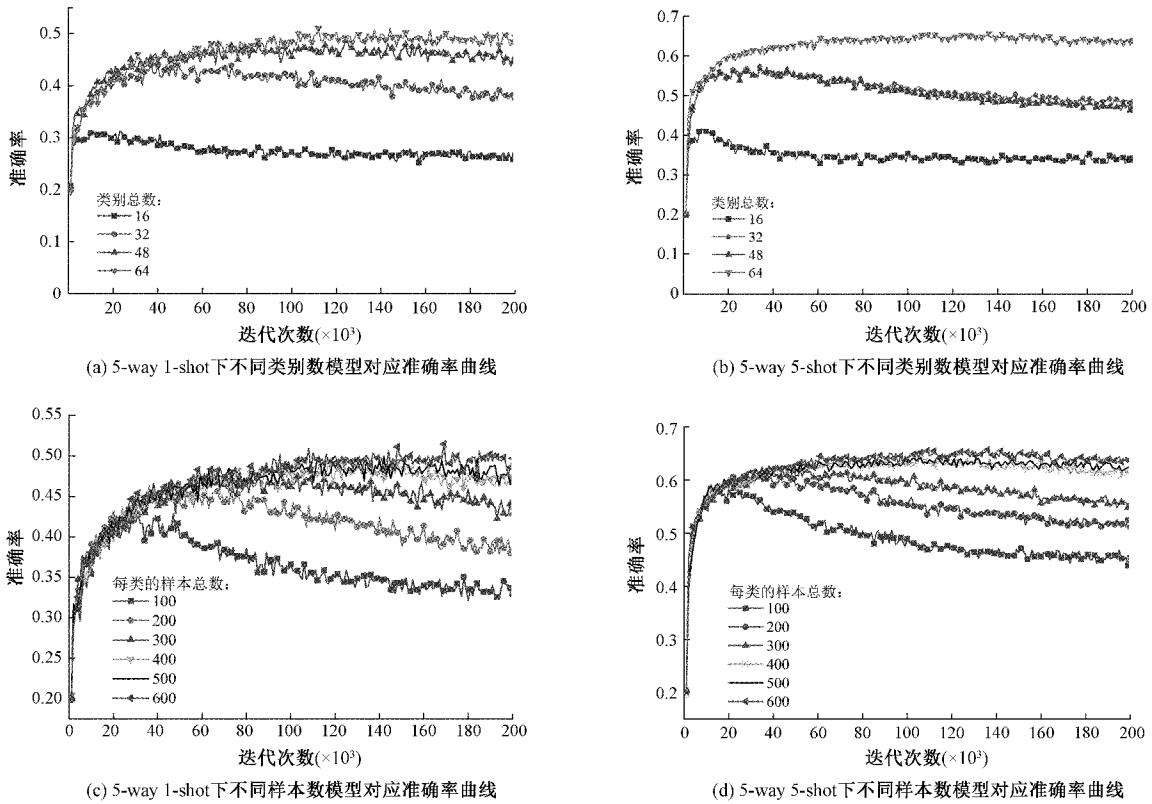


图 6 模型在 mini-ImageNet 数据集上测试准确率与训练样本充分度之间的关系

样的元训练集,所以先随机抽取 mini-ImageNet 数据集的 64 类作为训练集对模型进行预训练,使模型获得一定的学习能力,再从 NEU-DET 数据集中随机抽取一类对模型进行微调,最后将 NEU-DET 数据集剩下的类作为测试集验证模型的分类效果。本文在 NEU-DET 数据集上的实验分别在原关系网络和改进后的关系网络上进行。同时,实验设置了 5-way 1-shot 实验组和 5-way 5-shot 实验组。

实验结果如表 2 所示,在原关系网络上进行实验得到的结果:5-way 1-shot 任务中获得的准确率为 $72.73\% \pm 0.44\%$,5-way 5-shot 任务中获得的准确率为 $89.89\% \pm 0.14\%$;

在改进后关系网络上进行实验得到的结果:5-way 1-shot 任务中获得的准确率为 $79.95\% \pm 0.59\%$,5-way 5-shot 任务中获得的准确率为 $92.04\% \pm 0.12\%$ 。得到上诉实验结果的原因是:实验开始时只在 mini-ImageNet 数据集上训练,模型获得良好的学习样本特征的能力,再将 NEU-DET 数据集的一类样本引入训练集,使得训练数据与测试数据在某些域间有相似的分布,进一步改善模型学习样本特征的能力。对比不同模型在相同实验设置的实验结果可知:改进后的关系网络模型在 5-way 1-shot 任务中比原关系网络的分类准确率高约 7.22%,在 5-way 5-shot 任务中比原关系网络的分类准确率高约 2.15%。

表 2 改进前后模型对带钢表面缺陷分类的准确率

%

分组	模型	训练集	测试集	5-way 1-shot	5-way 5-shot
1	关系网络	mini-ImageNet+NEU-DET	NEU-DET	72.73 ± 0.44	89.89 ± 0.14
2	本文网络	mini-ImageNet+NEU-DET	NEU-DET	79.95 ± 0.59	92.04 ± 0.12

3 结 论

本文提出了一种基于改进关系网络的小样本带钢表面缺陷分类方法。通过增加网络的深度,更换更高效的激活函数与损失函数,实现了在少量样本情况下对带钢表面缺陷的分类;该方法将预测样本与支撑样本的特征连接起来得到的关系值作为类别的判断依据,即使某些类别的标

注样本数量很少,该方法也能达到较好的分类效果;新关系网络模型在东北大学发布的 NEU-DET 数据集上进行实验,在 5-way 1-shot 任务中获得的准确率为 79.95%,比原关系网络模型提高 7.22%;在 5-way 5-shot 任务中获得的准确率为 92.04%,比原关系网络模型提高 2.15%。下一步将考虑如何将小样本学习应用到缺陷的定位及检测等视觉任务。

参考文献

- [1] 刘坤, 赵帅帅, 屈尔庆, 等. R-AdaBoost 带钢表面缺陷特征选择算法[J]. 电子测量与仪器学报, 2017, 31(1):9-14.
- [2] 李玉, 宫学亮, 赵泉华. 基于张量径向基核函数支持向量机的高光谱影像分类[J]. 仪器仪表学报, 2020, 41(12):253-262.
- [3] 杨智超, 李国辉, 李佳韵, 等. 基于分散熵和支持向量机的运动状态识别[J]. 国外电子测量技术, 2019, 38(7):28-31.
- [4] 王永浩. 基于加权结构 SVM 的钢板表面缺陷分类[J]. 电子测量技术, 2020, 43(11):69-73.
- [5] 金璐, 刘士建, 王霄, 等. 基于改进关系网络的小样本红外空中目标分类方法[J]. 光学学报, 2020, 40(8):87-96.
- [6] XIA M, SILVA C W D. Gear transmission fault classification using deep neural networks and classifier level sensor fusion[J]. Instrumentation, 2019, 6(2): 101-109.
- [7] 张飞, 同杰. 基于深度卷积神经网络的云分类算法[J]. 西北工业大学学报, 2020, 38(4):740-746.
- [8] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning [J]. Journal of Big Data, 2019, 6 (1), DOI: 10.11861840537-019-0197-0.
- [9] WANG Y, YAO Q, KWOK J T, et al. Generalizing from a few examples: a survey on few-shot learning[J]. ACM Computing Surveys, 2020, 53(3):1-34.
- [10] WU J, ZHAO Z, SUN C, et al. Few-shot transfer learning for intelligent fault diagnosis of machine[J]. Measurement, 2020, 166: 108202.
- [11] KIM S, AN S, CHIKONTWE P, et al. Bidirectional rnn-based few shot learning for 3D medical image segmentation[J/OL]. ArXiv Preprint, 2020, (2020-11-19)[2020-02-15]. <https://arxiv.org/abs/2011.09608>.
- [12] LI C, ZHANG D, TIAN Z, et al. Few-shot learning with deformable convolution for multiscale lesion detection in mammography [J]. Medical Physics, 2020, 47(7): 2970-2985.
- [13] ZHANG Z, ZHANG Y, TENG Y L, et al. Adaptive transfer learning framework for dense prediction of human activity recognition[J]. The Journal of China Universities of Posts and Telecommunications, 2019, 26(5): 1-10,21.
- [14] QIN Y X, ZHANG W G, ZHAO C X, et al. Prior-knowledge and attention-based meta-learning for few-shot learning[J/OL]. ArXiv Preprint, 2018, (2018-12-11) [2020-02-15]. <https://arxiv.org/abs/1812.04955v5>.
- [15] 丛晓峰, 章军, 胡强. 基于对偶学习的图像去雾网络[J]. 应用光学, 2020, 41(1):94-99.
- [16] LIU Z L, NAN F, ZHENG X, et al. Color prediction of mushroom slices during drying using Bayesian extreme learning machine [J]. Drying Technology 2020, 38(14): 1869-1881.
- [17] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]. Neural Information Processing Systems 2017, New York, 2016: 3630-3638.
- [18] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]. Neural Information Processing Systems 2017, New York, 2017: 4077-4087.
- [19] SUN F, YANG Y G, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]. The IEEE Conference on Computer Vision and Pattern Recognition(CVPR), New York, 2018: 1199-1208.
- [20] LIN M, CHEN Q, YAN S C. Network in network[J/OL]. ArXiv Preprint, 2013, (2013-12-16) [2014-03-04]. <https://arxiv.org/abs/1312.4400>.
- [21] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]. Proceedings of the 34th International Conference on Machine Learning. Sydney, NSW, Australia, 2017, 70: 1126-1135.
- [22] MISRA D. Mish: A self regularized non-monotonic neural activation function [J/OL]. ArXiv Preprint, 2019, (2019-08-23)[2020-08-13]. <https://arxiv.org/abs/1908.08681>.
- [23] 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(21):858-864.
- [24] KINGMA D P, BA J. Adam: A method for stochastic optimization[J/OL]. ArXiv Preprint, 2014, (2014-12-22) [2017-01-30]. <https://arxiv.org/abs/1412.6980>.

作者简介

薛亮, 硕士研究生, 主要研究方向为机器视觉与图像处理。

E-mail: xwl12173114@163.com

靳伍银, 教授, 博士生导师, 主要研究方向为神经科学及动力系统分析、机器视觉与图像处理、嵌入式系统与信号处理、非线性动力学理论与方法。

E-mail: wuyinjin@hotmail.com

王全, 硕士研究生, 主要研究方向为信号处理。

E-mail: quan.wong@outlook.com