

DOI: 10.13382/j.jemi.B2104661

钢板表面缺陷深度主动学习高效分类方法^{*}

周友行^{1,2} 孟高磊¹ 赵文杰¹ 易 倩¹

(1. 湘潭大学机械工程学院 湘潭 411105; 2. 复杂轨迹加工工艺及装备教育部工程研究中心 湘潭 411105)

摘 要:针对钢板表面缺陷图像分类传统深度学习算法中需要大量标签数据的问题,提出一种基于主动学习的高效分类方法。该方法包含一个轻量级的卷积神经网络和一个基于不确定性的主动学习样本筛选策略。神经网络采用简化的 convolutional base 进行特征提取,然后用全局池化层替换掉传统密集连接分类器中的隐藏层来减轻过拟合。为了更好的衡量模型对未标签图像样本所属类别的不确定性,首先将未标签图像样本传入到用标签图像样本训练好的模型,得到模型对每一个未标签样本关于标签的概率分布(probability distribution over classes,PDC),然后用此模型对标签样本进行预测并得到模型对每个标签的平均 PDC。将两类分布的 KL-divergence 值作为不确定性指标来筛选未标签图像进行人工标注。根据在 NEU-CLS 开源缺陷数据集上的对比实验,该方法可以通过 44% 的标签数据实现 97% 的准确率,极大降低标注成本。

关键词:表面缺陷;主动学习;卷积神经网络;全局池化

中图分类号: TH701;TN06 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Efficient deep active learning for steel plate surface defects classification

Zhou Youhang^{1,2} Meng Gaolei¹ Zhao Wenjie¹ Yi Qian¹

(1. School of Mechanical Engineering, Xiangtan University, Xiangtan 411105, China; 2. Engineering Research Center of Complex Tracks Processing Technology and Equipment of Ministry of Education, Xiangtan 411105, China)

Abstract: Aiming at the problem that traditional deep learning strategies used in steel plate surface defect images classification rely on abundant labeled samples. This paper proposes an efficient deep active learning method with a lightweight convolutional neural network and a novel uncertainty based active learning strategy. The network adopts a simplified convolutional base to do feature extraction, and replaces the hidden layer in the final densely connected classifier with global pooling layer to mitigate overfitting. To better measure model uncertainty about unlabeled image samples, this method first passes unlabeled images through the model trained by labeled image samples to obtain the probability distribution over classes (PDC) for every unlabeled sample, then uses the same model to make predictions on the labeled samples to get an average PDC for every class. The KL-divergence value between these two kinds of distributions can be used as a new uncertainty measure to select unlabeled images for annotation. According to the experiments on NEU-CLS dataset, the proposed method can reach 97% accuracy with 44% labeled data, which can reduce annotation cost greatly.

Keywords: surface defects; active learning; convolutional neural network; global pooling

0 引 言

钢板表面缺陷的精确分类可以帮助了解缺陷形成原因,改进生产工艺,提升产品质量和经济效益。采用深度

学习的机器视觉技术是目前金属表面缺陷分类领域的主流方法^[1-5],然而这些方法都需要大量的标签样本去训练模型,且模型结构复杂,计算成本高,效率低。在工业生产中,获取可以用于训练模型的标签样本集需要大量的人力、经济和时间成本。目前有 4 种有效的方法来降低

标注成本,分别是迁移学习^[6-7]、基于生成模型的数据扩增^[8-10]、半监督学习^[11-13]以及主动学习^[14-15]。其中迁移学习对目标数据的标签数量仍有较高要求,且包含复杂的 fine-tuning 过程,标签成本和计算成本相对较高;基于生成模型的方法虽然可以减少标签样本数量,但极大的增加了计算成本;半监督学习过程复杂,分类精度较低。

基于不确定性的主动学习方法仅利用模型对未标签数据集的预测结果,能够同时降低标注和计算成本。若模型对某个样本所属类别不确定,这个样本一定包含关于此任务的更多信息,通过逐步筛选出含信息量高的样本进行人工标注,可以用较小标签预算改善模型的分类能力。LC(least confident)^[14]、MS(margin sampling)^[15]和 EN(entropy)^[16]是目前 3 种最常用的不确定性采样策略。这类策略假定模型对未标签样本的预测结果包含模型对这些样本的不确定性,采用相应的不确定性度量,可以筛选出含信息量最高的样本。然而这类方法没有考虑到模型在标签数据集上的不确定性。

为解决上述问题,本文提出一种高效的主动学习表面缺陷分类方法。首先,主动学习中的分类网络不是特定的,针对钢板表面缺陷特征相对简单的特点,为提高学习效率,降低计算成本,本文采用简化的卷积网络来加速训练过程,用全局池化来改善模型的泛化能力,并通过在全局平均池化和全局最大池化上的实验找出最适合用主动学习对钢板表面缺陷进行分类的池化方法。其次,为融合两类不确定性,将通过标签数据计算出的针对某标签类别的平均概率分布(probability distribution over classes, PDC)作为模型在这个类别上的最优表现,通过量化某未标签样本 PDC 与模型在该样本预测标签上最优表现(平均 PDC)之间的差异,得到一个新的不确定性指标,利用该指标指导样本的筛选。根据在 NEU-CLS^[17]开源热轧钢板数据集上的实验,该方法可以用较少的标签数据在短时间内实现优异的分类效果。

1 深度主动学习高效分类方法

1.1 整体框架

本文所提方法包含两个要素,分别为用于模型训练的卷积神经网络(convolutional neural network, CNN)和用于数据收集的采样策略。对于已有的数据集,首先随机筛选一小部分进行标注,组成标签数据池,记为 D^L ;剩余的数据组成未标签数据池,记为 D^U 。模型首先通过初始标签数据进行训练。训练后的模型分别对标签数据和未标签数据进行预测,根据所提筛选策略从未标签数据池中筛选缺陷图像进行标注。根据新的标注信息更新两个数据池,开始下一轮训练,重复这个训练过程直到模型分类性能达到要求。

1.2 模型设计

1) 特征提取器

表面缺陷轮廓较简单,特征较少,故使用浅层网络提取特征来减少训练时间,本文使用的 convolutional base 是简化的 VGG^[18]网络。首先,其只保留 4 个卷积层,每两个卷积层跟一个最大池化层;其次,移除批量归一化层以加速训练。

2) 全局池化作为结构正则化项

传统的分类器(traditional classifier, TRC)包含有两个隐藏层和一个输出层^[18-19]。NIN^[20]首先提出用全局平均池化(global average pooling, GAP)作为分类器输出,指出 GAP 可以作为结构正则化项,并通过实验验证了 GAP 的正则化效应,ResNet^[21]和 GoogLeNet^[22]提出用 GAP 替换掉 TRC 中的隐藏层,GoogLeNet 指出这种替换可以将分类准确率提高 0.6%。特征提取器的输出是多个特征图,在 TRC 设定下,特征图需要先经过 Flatten 层展开为一维特征向量才可以传入到分类器。而 GAP 与全局最大池化(global max pooling, GMP)计算每个特征图的平均值和最大值作为此特征图的输出。Flatten 与全局池化(GAP 与 GMP)的区别如图 1 所示。




图 1 Flatten 与全局池化

Fig. 1 Flatten and global pooling

本文将基于全局池化的分类器(global pooling based classifier, GPC)与 TRC 和两个常用的正则化手段(dropout 和基于几何变换的数据扩增)进行对比,实验结果显示 GMP 亦可作为结构正则化项。完整 CNN 模型如图 2 所示。

1.3 取样策略

标签数据池 D^L 不仅可以用来训练模型,而且包含模型关于此数据集的不确定性。而传统不确定性采样仅考虑模型关于未标签数据池的不确定性,本文提出 KLS(Kullback-Leibler divergence sampling)取样策略,将模型关于标签数据池的不确定性融合进取样过程。

假定标签数据池 D^L 和未标签数据池 D^U 已存在,记单个样本为 x ,对应标签为 y 。初始模型由 D^L 训练得到,经过模型对 D^U 的预测,可得到任一样本的 PDC,对样本 $x_u \in D^U$,其 PDC 记为:

$$p(y = y' | x_u, W) = \{p(y^1 | x_u, W), p(y^2 | x_u, W), \dots,$$




图2 模型结构

Fig. 2 Architecture of the designed network

$$p(y^c | x_u, W), \{ \quad (1)$$

式中: $p(y^c | x_u, W)$, $c \in (1, \dots, C)$ 代表样本 x_u 标签为 y^c 的概率, C 是样本所有可能取的标签的个数, y' 是该样本的预测标签, 其计算公式为:

$$y' = \operatorname{argmax}_y p(y | x_u, W) \quad (2)$$

模型的预测结果可以根据样本的预测标签分为不同的PDC组。假定 $y' = y^c$, x_u 的PDC则包含于 y^c 组中, 表示为:

$$p(y = y^c | x_u, W) = \{ p(y^1 | x_u, W), p(y^2 | x_u, W), \dots, p(y^c | x_u, W) \} \quad (3)$$

下一步对标签数据进行预测。对于具有强正则效应的模型, 其训练后的结果最能拟合训练集(标签数据集 D^L), 因此模型对 D^L 的预测结果是其最优表现。对样本 $x_l \in D^L$, 其PDC和预测标签亦可由式(1)和(2)计算得出。对于标签 y^c , 其平均PDC $p(y = y^c | X_l^c, W)_{\text{avg}}$ 可由以下公式计算得出:

$$p(y = y^c | X_l^c, W)_{\text{avg}} = \frac{1}{N} \{ \sum_{n=1}^N p(y^1 | x_l^n, W), \sum_{n=1}^N p(y^2 | x_l^n, W), \dots, \sum_{n=1}^N p(y^c | x_l^n, W) \} \quad (4)$$

式中: X_l^c 代表预测标签为 y^c 的样本集; N 是该样本集中的样本数量。

将 $p(y = y^c | X_l^c, W)_{\text{avg}}$ 视为模型在标签 y^c 上的最优表现。在属于 y^c 的PDC组中, 正常样本的PDC应与上述平均分布相似, 若 $p(y = y^c | x_u, W)$ 与 $p(y = y^c | X_l^c, W)_{\text{avg}}$ 差异较大, 则样本 x_u 为异常样本, 即模型对该样本所属类别不确定。为衡量两类分布的差异, 本文引入KL divergence:

$$KL(P \| Q) = \sum_i P(i) \log \frac{P(i)}{Q(i)} \quad (5)$$

将两类分布的KL divergence值(记为 kls)作为模型对样本 x_u 的不确定性, 其计算公式为:

$$kls_u = KL(p(y = y^c | X_l^c, W)_{\text{avg}} \| p(y = y^c | x_u, W)) \quad (6)$$

计算每个标签的 $p(y = y^c | X_l^c, W)_{\text{avg}}$ 值并将其作为模型的在这个标签上分类性能的基准, 然后计算每个PDC组中对应元素的KLS值, 每组中KLS值最高的一批样本将被筛选出来进行标注, 令批次大小为 k , 则每次筛选出来的总样本数为 $k \times C$ 。

1.4 停止准则

主动学习是一个循环过程, 当模型的分类性能达到要求时要停止模型的训练以节省计算成本, 故必须设置一个停止准则, 停止准则需要与模型的表现密切相关。由于所设计网络具有强正则化效应, 本文采用验证准确度(validation accuracy, VA)作为这个准则。根据实验, 该网络的验证准确度一直小于等于测试准确度。

将原始数据集分为3部分, 用于训练的 D^L 、用于验证的 D^V 和用于取样的 D^U 。故仅 D^L, D^V , 和取样数据需要标注。所提方法伪代码如算法1所示。方法实现流程如图3所示。

算法1: 高效主动学习分类算法

输入: 初始训练数据池 D^L , 验证数据池 D^V , 未标签数据池 D^U , 随机初始化模型参数 W' , 停止准则 VA, 每类别取样数量 k 。

输出: 优化后的模型参数 W 。

- 1 Repeat
- 2 预测 D^U 并根据式(2)计算每个样本的预测标签;
- 3 统计所有样本的PDC, 并根据预测标签进行分组;
- 4 预测 D^L ;
- 5 根据式(4)计算模型在每个标签上的性能基准;
- 6 根据式(5)和(6)计算每个PDC对应的KLS值;
- 7 在每个PDC组中筛选出 k 个具有最高KLS值的样本;
- 8 标注样本并更新 D^L, D^U ;
- 9 用更新后的 D^L 训练模型;
- 11 用 D^V 验证模型性能并计算 VA';
- 12 Until VA' > VA。




图 3 方法实现流程
Fig. 3 The flow of the realization of proposed method

2 实验与结果

2.1 数据集简介与实验设置

实验采用 NEU-CLS 数据集,数据集包含热轧钢板常见的 6 种缺陷,分别是裂纹(Cr)、夹杂(In)、斑块(Pa)、麻点(PS)、氧化铁皮压入(RS)和划痕(Sc)。每种缺陷有 300 张像素值为 200×200 的灰度图像,共计 1 800 张。部分缺陷图像如图 4 所示。

实验中,60%的数据用于训练,20%的数据用于验证,剩余 20%的数据用于测试。随机抽取 0.05%的训练数据(每个类别取 9 张图片)作为 D^L , 剩余的训练数据组成 D^U 。Batch size 设为 8,optimizer 取 SGD,momentum 取 0.9。同时,当过拟合发生时用 early stopping 停止训练,patience 设为 10。实验结果均取 5 次实验的平均值,所有实验在配置为 i5-6400CPU,16 GB 内存和 GTX960 m




图 4 NEU-CLS 部分缺陷图像
Fig. 4 Example images of NEU-CLS dataset

NVIDIA GPU 的笔记本上完成。实验所用网络结构如表 1 所示,其以 200×200×1 pixel 图片为输入,输出 6 个标签预测。

1) 第 1 部分实验测试监督学习条件下基于 GPC 的正则化效果,用所有训练数据进行模型训练,学习率设

表 1 神经网络详细结构

Table 1 Detailed configuration of the designed network architecture

Layer	Kernel size/Stride	Output size
Convolution + ReLu	3×3/2	100×100×32
Convolution + ReLu	3×3/2	50×50×32
Maxpool	2×2/1	25×25×32
Convolution + ReLu	3×3/2	13×13×64
Convolution + ReLu	3×3/1	13×13×64
Maxpool	2×2/1	6×6×64
Global Average/Max Pool		1×1×64
Dropout 50%		1×1×64
FC + Softmax		1×1×6

为 0.005。TRC 与 dropout 和基于几何变换的数据扩增的不同组合作为对照,其中 TRC 的每个隐藏层单元个数设为 3 136。Dropout rate 设为 0.5,几何变换包括水平翻转、横/纵向偏移、旋转、剪切与缩放。后续实验中分别将基于全局平均池化和全局最大池化的分类器记为 GAPC 和 GMPC。

2)第 2 部分实验测试 KLS 取样策略在主动学习的效果,传统的不确定性取样方法包括 LC、MS 和 EN 作为对照。其中 LC 筛选预测标签概率最低的样本,样本预测标签对应的概率值为 $p(y' | x_u, W)$,则不确定性定义为:

$$Uncertainty = 1 - p(y' | x_u, W) \tag{7}$$

MS 采样则将不同标签概率差值作为不确定性的衡量指标,其公式为:

$$Uncertainty = p(y'_2 | x_u, W) - p(y'_1 | x_u, W) \tag{8}$$

式中: y'_1 和 y'_2 分别为模型第 1 和第 2 最可能的预测标签。EN 方法将样本预测标签概率分布的熵值作为模型对样本所属类别的不确定性,其公式为:

$$Uncertainty = - \sum_y p(y | x_u, W) \log p(y | x_u, W) \tag{9}$$

表 2 监督学习中 GPC 与 TRC 的分类效果

Table 2 The performance of GPC and TRC in supervised learning setting

方法	准确率/%	精确率/% (加权平均)	召回率/% (加权平均)	F1-score/% (加权平均)	时间/s	训练时间/s
TRC	91.4	91.6	91.4	91.2	3.66	116.29
TRC + 数据扩增	96.4	96.6	96.4	96.4	3.86	171.47
TRC + Dropout	90.8	91.2	90.8	90.8	3.77	141.78
TRC + 数据扩增+Dropout	95.6	95.6	95.6	95.6	4.02	237.29
GMPC	96.2	96.2	96.2	96.2	2.25	86.38
GAPC	96.2	96.2	96.2	96.2	2.19	125.52

图 5 和 6 所示为不同取样策略分别在 GAPC 与 GMPC 设定下分类性能与标签数量的关系。如图 5 所示,在 GAPC 较少标签条件下(<35%),随机采样的分类性能优于传统的不确定采样方法 5% 以上。当标签样本数量增加至 35% 以上时,随机采样表现停滞,传统不确定性采样表现开始超过随机采样。由图 6 可知,

式中: y 的取值为所有可能的标签,熵值越高,模型对样本所属类别越不确定。筛选过程中,每批次筛选相同数量的样本进行标注。

随机采样作为基准,其在每个训练循环从 D^U 随机筛选样本进行标注。停止准则 VA 设为 0.95。本实验将 GPC 与 dropout 结合以进一步强化模型的正则化效果。同时,使用 Inverse-Time-Decay 逐步减小学习率。学习率衰减公式定义为:

$$lr = l_{ini} \times \frac{1}{1 + \frac{dr \times epoch}{ds}} \tag{10}$$

式中: l_{ini} 为初始学习率; dr 为衰减率,设为 0.96; ds 为衰减步长,设为 162; $epoch$ 为当前训练过程的 epoch 数,其会在每次循环开始时重置。通过使用学习率衰减,可以将初始学习率设为一个较大值以加速模型训练并避免局部最小值^[23],故本部分实验 l_{ini} 设为 0.01。

2.2 实验结果

实验采用准确率 (accuracy),加权平均精确率 (weighted average precision),加权平均召回率 (weighted average recall),加权平均 F1-score (weighted average F1-score) 来衡量模型的分类性能。如表 2 所示,GMPC 与 GAPC 分类性能相似,能实现 96.2% 的分类准确率,比数据扩增低 0.2%,但优于 dropout 5.4%。二者之间的差异在于训练时间,GAPC 的训练时间比 GMPC 长 39 s。在分类效果为 95% 以上的条件下,GPC 能够将训练时间缩短 46 s 以上,有效降低计算成本。根据上述结果,全局池化的正则化效果显著,相比于其他两种正则化技术,使用基于全局池化的分类器是实现高精度分类效率最高的方法。

GMPC 设定下 3 种传统采样策略表现相似,随机采样分类性能最差。KLS 取样策略的分类性能则在两种分类器结构下一直优于随机采样和其他采样方法,尤其在少标签条件下(<29%),KLS 取样策略可以用相同数量的标签数据超过传统方法 4% 以上的分类性能,有效提高标签利用率。




图 5 GAPC 设定下不同取样策略分类性能
Fig. 5 The performance of different sample strategies with GAPC




图 6 GMPC 设定下不同取样策略分类性能
Fig. 6 The performance of different sample strategies with GAPC

GAPC 设定下,KLS 取样策略可以用 32% 的标签样本实现 91.8% 的分类准确率,相比于传统方法可以降低 3% 以上的标签成本。在 44% 标签样本条件下,KLS 可以取得 97% 的分类准确率,不仅优于其他 4 种采样方法,且由表 2 可知,这已经超过了监督学习条件下用全部样本训练得到的模型的性能(96.2%),可以降低 56% 的

标注成本。
根据以上分析,相比于传统不确定性采样方法,KLS 取样策略对标签数据的利用更加高效。且通过合适的筛选策略,主动学习能够用较少的标签样本实现比监督学习更好的分类效果。
从分类器的角度看,GAPC 的分类性能在主动学习

设定下优于 GMPC。如表 3 所示,以相同的分类性能(91.8%)为基准,除 EN 以外,基于 GAPC 的方法需要的标签数量比基于 GMPC 的方法少 3%~15%;根据表 4 可知,当标签样本数为 44%时,基于 GAPC 方法的分类效果比基于 GMPC 的方法高 3%~14%。图 7 所示为本文算法的损失与准确率曲线,由图 7 可知,模型验证损失与训练损失的差距没有随着训练时间延长而增大,GPC 的正则化效果显著。同时,在 0~150 epoch,GMPC 的收敛速

度更快,但在 200 epoch 之后,GMPC 表现停滞并开始大范围波动。由于主动学习中标签样本数量随时间阶段性递增,故可知 GMPC 在少标签样本条件下更易收敛,但当标签样本数量增加到一定程度之后,其便收敛失败,即 GMPC 更易受标签样本的影响。从以上实验结果可知,相比于 GMPC,GAPC 更适合主动学习。本文算法的训练时间(忽略标注时间)平均为 5 min,最终模型大小为 578.7 KB,进一步证明了其高效性。

表 3 模型分类性能达到 91.8%需要的标签数量

Table 3 Percentage of samples needed to reach 91.8% of corresponding performance metric (%)

	GAPC					GMPC				
	KLS	LC	MS	EN	RS	KLS	LC	MS	EN	RS
准确率	32	35	35	41	35	35	50	38	41	44
精确率(加权平均)	32	35	35	41	32	35	50	38	41	44
召回率(加权平均)	32	35	35	41	35	35	50	38	41	44
F1-score(加权平均)	32	35	35	41	35	35	50	38	41	44

表 4 模型使用 44%标签数据可以达到的分类性能

Table 4 Performance score achieved using 44% of labeled samples (%)

	GAPC					GMPC				
	KLS	LC	MS	EN	RS	KLS	LC	MS	EN	RS
准确率	97.0	96.5	95.5	94.3	95.4	93.8	88.0	91.8	80.6	90.2
精确率(加权平均)	97.0	96.5	95.8	94.3	95.6	93.8	88.8	92.4	83.4	91.0
召回率(加权平均)	97.0	96.5	95.5	94.3	95.4	93.8	88.0	91.8	80.6	90.2
F1-score(加权平均)	97.0	96.5	95.5	94.3	95.4	93.8	87.8	91.8	80.2	90.0




图 7 本文算法的损失与准确率曲线

Fig. 7 The loss and accuracy of the proposed algorithm over time

3 结 论

本文提出了一种用于钢板表面缺陷分类的高效主动学习方法。基于钢板表面缺陷特点,为提高模型分类效

率,设计了一个轻量但具有强正则化能力的 CNN 模型,然后将其与一新不确定性采样策略 KLS 结合,组成一个高效的主动学习方法。其中 CNN 采用简化的 convolutional base 进行特征提取,同时采用基于全局池化的分类器增强模型的正则化效果。

为了更好的衡量模型对未标签样本的不确定性,本文提出 KLS 取样策略,将模型在标签样本上的不确定性作为基准并将其纳入到新指标的计算中。实验证明了基于全局池化分类器在钢板表面缺陷分类问题中的正则化效果以及 KLS 优于其他不确定性采样策略。

本文同时探究了基于全局平均池化和最大池化的分类器在监督学习以及主动学习中的差异,结果表明基于全局平均池化的分类器更适合钢板表面缺陷分类的主动学习过程。

结合基于全局平均池化的分类器与 KLS 采样策略,本文方法可以在使用 NVIDIA GTX960 m 显卡的笔记本电脑条件下,在 5 min 内使用 44% 标签样本实现 97% 的分类准确率,极大的降低标注和计算成本。

参考文献

- [1] ZHOU S Y, CHEN Y P, ZHANG D L, et al. Classification of surface defects on steel sheet using convolutional neural networks [J]. Materials Technology, 2017, 51(1): 123-131.
- [2] YI L, LI G Y, JIANG M M. An end-to-end steel strip surface defects recognition system based on convolutional neural networks [J]. Steel Research International, 2017, 88(2): 176-187.
- [3] NATARAJAN V, HUNG T-Y, VAIKUNDAM S, et al. Convolutional networks for voting-based anomaly classification in metal surface inspection[C]. Proceedings of the 2017 IEEE International Conference on Industrial Technology (ICIT), 2017.
- [4] HE D, XU K, WANG D D. Design of multi-scale receptive field convolutional neural network for surface inspection of hot rolled steels [J]. Image and Vision Computing, 2019, 89: 12-20.
- [5] CHEN W, GAO Y P, GAO L, et al. A new ensemble approach based on deep convolutional neural networks for steel surface defect classification [J]. Procedia CIRP, 2018, 72: 1069-1072.
- [6] FU G Z, SUN P Z, ZHU W B, et al. A deep-learning-based approach for fast and robust steel surface defects classification [J]. Optics and Lasers in Engineering, 2019, 121: 397-405.
- [7] YANG Y T, YANG R Z, PAN L H, et al. A lightweight deep learning algorithm for inspection of laser welding defects on safety vent of power battery [J]. Computers in Industry, 2020, 123: 103306.
- [8] TANG W Q, YANG Q, XIONG K X, et al. Deep learning based automatic defect identification of photovoltaic module using electroluminescence images [J]. Sol Energy, 2020, 201: 453-460.
- [9] YUN J P, SHIN W C, KOO G, et al. Automated defect inspection system for metal surfaces based on deep learning and data augmentation [J]. Journal of Manufacturing Systems, 2020, 55: 317-324.
- [10] 邱根, 王锂, 白利兵. 基于生成对抗网络数据扩充的缺陷识别方法 [J]. 电子测量与仪器学报, 2021, 35(2): 212-220.
- QIU G, WANG L, BAI L B. Defects detection based on data augmentation by generative adversarial network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 212-220.
- [11] HE D, XU K, ZHOU P, et al. Surface defect classification of steels with a new semi-supervised learning method [J]. Optics and Lasers in Engineering, 2019, 117: 40-48.
- [12] GAO Y P, GAO L, LI X Y, et al. A semi-supervised convolutional neural network-based method for steel surface defect recognition [J]. Robotics and Computer-Integrated Manufacturing, 2020, 61: 101825.
- [13] HE Y, SONG K C, DONG H W, et al. Semi-supervised defect classification of steel surface based on multi-training and generative adversarial network [J]. Optics and Lasers in Engineering, 2019, 122: 294-302.
- [14] SETTLES B. Active learning [J]. Synthesis Lectures on Artificial Intelligence and Machine Learning, 2012, 6(1): 1-114.
- [15] LV X M, DUAN F J, JIANG J J, et al. Deep active learning for surface defect detection [J]. Sensors, 2020, 20(6): 1650.
- [16] WANG K Z, ZHANG D Y, LI Y, et al. Cost-effective active learning for deep image classification [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2016, 27(12): 2591-2600.
- [17] SONG K C, YAN Y H. 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.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2014, arXiv:14091556.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [20] LIN M, CHEN Q, YAN S. Network in network [J]. Computer Science, 2013, arXiv:13124400.

[21] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.

[22] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015.

[23] YOU K, LONG M, WANG J, et al. How does learning rate decay help modern neural networks? [J]. Computer Science, 2019,arXiv:190801878.

作者简介



周友行,1998 年于湖南大学获得硕士学位,2003 年于中南大学获得博士学位,现为湘潭大学教授,主要研究方向为数字化设计与制造、机器人学、制造过程监测与控制。
E-mail: zhouyouhang@xtu.edu.cn

Zhou Youhang received his M. Sc. degree from Hunan University in 1998 and Ph. D. degree from Central South University in 2003. He is currently a professor at Xiangtan University. His main research interests include digital design and manufacturing, robotics, manufacturing process monitoring and control.