



## 冷轧铜带表面缺陷智能识别方法

徐扬欢<sup>1</sup>, 王东城<sup>1,2</sup>, 刘宏民<sup>1,2</sup>, 于华鑫<sup>1,2</sup>

(1. 燕山大学 国家冷轧板带装备及工艺工程技术研究中心, 秦皇岛 066004;  
2. 燕山大学 亚稳材料制备技术与科学国家重点实验室, 秦皇岛 066004)

**摘要:** 表面质量是冷轧铜带重要质量指标之一。为实现铜带表面缺陷的精准自动检测, 首先对常见表面缺陷进行分类, 并制作了铜带表面缺陷图像数据集(YSU\_CSC); 然后, 以卷积神经网络 EfficientNet 为核心, 基于迁移学习策略, 通过训练实验建立了冷轧铜带表面缺陷智能识别模型, 同时与其他三种常用的卷积神经网络缺陷识别结果进行对比。结果表明: 该模型的精度较高, 准确率达到 93.05%, 单张缺陷图像平均识别时间为 197 ms, 综合性能较好, 可以满足工程要求; 最后, 将该模型在测试集上的缺陷识别结果进行可视化, 分析了该模型对部分图像识别错误的原因, 给出了进一步优化的方向。

**关键词:** 冷轧铜带; 表面缺陷; 卷积神经网络; 迁移学习; 识别模型

文章编号: 1004-0609(2022)-10-2950-15

中图分类号: TF35

文献标志码: A

**引文格式:** 徐扬欢, 王东城, 刘宏民, 等. 冷轧铜带表面缺陷智能识别方法[J]. 中国有色金属学报, 2022, 32(10): 2950-2964. DOI: 10.11817/j.ysxb.1004.0609.2021-42081

XU Yang-huan, WANG Dong-cheng, LIU Hong-min, et al. Intelligent recognition method for surface defects of cold rolling copper strip[J]. The Chinese Journal of Nonferrous Metals, 2022, 32(10): 2950-2964. DOI: 10.11817/j.ysxb.1004.0609.2021-42081

冷轧铜带是有色金属领域的典型高端产品, 广泛应用于新能源汽车、航空航天以及精密电子设备等领域<sup>[1-2]</sup>。表面质量是冷轧铜带重要质量指标之一, 表面缺陷不仅严重影响产品外观与成材率, 而且还可能对下游工序的生产造成不良影响<sup>[3-4]</sup>。实现铜带表面缺陷精确、快速分类识别, 对于提高产品质量具有重要意义。

目前, 工业生产中仍大量采用人工目测的方法进行铜带表面缺陷检测, 这种方法识别精度低、稳定性差、劳动强度高<sup>[5-6]</sup>。为此, 国内外部分学者采用传统机器视觉方法进行了相关研究。沈昱明等<sup>[7]</sup>采用双阈值分割方法对铜带表面缺陷特征进行提取, 并设计了软硬件系统, 利用 Labview 开发了

检测平台; 张学武等<sup>[8]</sup>利用 Gaussian 金字塔分解和 Gabor 滤波器, 通过提取铜带表面缺陷的颜色、亮度和朝向 3 个特征, 建立了马尔科夫缺陷分类模型, 实现了缺陷分类; 李嘉惠<sup>[9]</sup>将自适应分割算法用于缺陷图像分割, 提取了缺陷的长宽比、周长、面积、圆形度和重心这 5 个特征, 采用单隐含层 BP 神经网络建立了缺陷分类器, 实现缺陷识别; 孟繁明<sup>[10]</sup>基于改进的 Canny 算子与形态学方法, 提出了 MM-Canny 缺陷分割算法, 通过提取几何(面积和长短径比)、灰度(平均灰度、方差、倾斜度和缺陷区域能量)、纹理(角二阶矩阵、对比度、相关性和熵)3 类特征, 建立了支持向量机缺陷分类模型, 实现了缺陷分类; ZHANG 等<sup>[11]</sup>首先将铜带缺陷图像

基金项目: 国家自然科学基金资助项目(52074242); 河北省高端人才和“巨人计划”创新团队资助项目(2019)

收稿日期: 2021-07-25; 修订日期: 2021-09-24

通信作者: 王东城, 副教授, 博士; 电话: 18630320653; E-mail: wdc-731@163.com

分成若干个子图像, 再将子图像分为若干个小波单元, 以此得到缺陷图像的小波统计结果, 实现缺陷特征的提取, 再采用支持向量机模型, 完成缺陷分类。

总体而言, 将传统机器视觉方法用于铜带表面缺陷分类与识别时, 可以取得一定的效果, 但也存在一些尚未解决的问题。如图1所示, 采用传统机器视觉方法进行缺陷识别与分类时, 一般需经过特征设计、提取、分类三个步骤。其中特征设计是基础, 就铜带表面缺陷而言, 常见的特征包括颜色、亮度、形状、纹理等; 具体采用哪几种特征, 这将对设计者的专业知识依赖性很强, 通常需要进行大量试错才能找到较佳的特征组合。为突出主要特征, 抑制次要特征, 有时还会采用图像增强方法 (Image enhancement), 常见的图像增强方法包括去噪、提亮、超分辨率、去模糊等。

简而言之, 传统机器视觉是基于人为设计规则的方法, 具有很好的可解释性, 但最终模型识别精度的高低则与特征设计的好坏直接相关。当缺陷特征可精确描述、缺陷重复率较高时, 采用传统机器视觉能够取得十分理想的效果。铜带表面缺陷种类较多, 通常根据缺陷产生机理进行分类, 生产过程中很难精确描述某一类缺陷的具体形状与位置, 且有些不同类型缺陷的外观形貌却具有相似特征, 同时生产现场的检测环境也是不断变化的, 这些都为

传统机器视觉的应用造成很大障碍。

以深度学习为核心的人工智能理论与技术的快速发展, 使其在诸多领域取得了成功的应用<sup>[12]</sup>, 这为表面缺陷检测提供了新的思路及方向。如图2所示, 与传统机器视觉方法相比, 深度学习的主要优点在于无须通过人工进行特征设计, 而是通过智能方法自动学习图像的基本特征, 并自动进行特征提取与分类, 特别适合于变量环境中多种类缺陷的自动识别, 具有较强的通用性和鲁棒性。

目前, 已有部分学者运用深度学习方法进行钢带和铝材表面缺陷检测。在监督学习方面, SONG等<sup>[13-14]</sup>建立了热轧带钢表面缺陷数据集, 提出了多特征融合的卷积神经网络缺陷识别算法, 实现了6种常见热轧带钢表面缺陷的识别; SAIZ等<sup>[15]</sup>将传统机器学习技术与卷积神经网络相结合, 提出了带钢表面缺陷自动分类方法, 通过大量实验获得最佳的分类器参数, 完成了缺陷分类; 向宽等<sup>[16]</sup>通过引入特征金字塔结构, 提出改进的Faster RCNN铝型材表面缺陷识别方法, 实现了铝型材表面10种缺陷的检测; 张旭等<sup>[17]</sup>通过采用改变锚框数量的方式改进了YOLOv3模型, 提升了铝型材表面小缺陷的检测效果。叶刚等<sup>[18]</sup>首先采用ViBe算法从图像中分割出缺陷区域, 然后利用中值滤波和形态学运算, 进行缺陷区域的准确提取, 最后通过卷积神经网络实现铝带表面缺陷的识别分类。在半监督学习方面, GAO等<sup>[19]</sup>对NEU数据集建立了PLCNN半

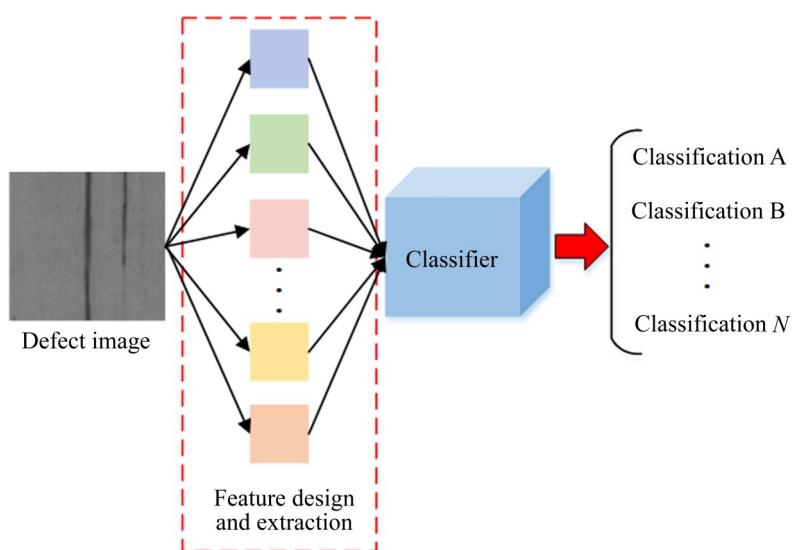


图1 基于传统机器视觉的缺陷识别示意图

Fig. 1 Schematic diagram of defect recognition with traditional machine vision

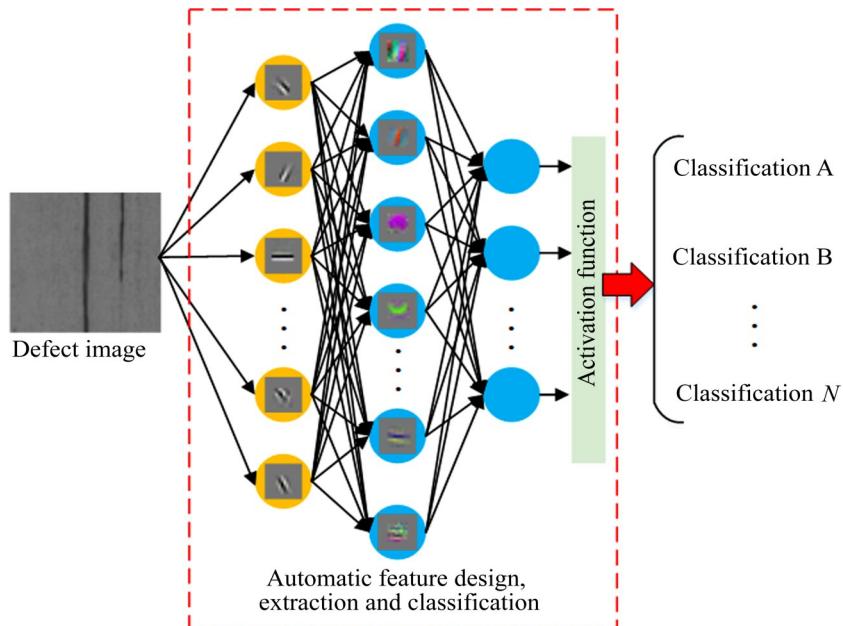


图2 基于深度学习的缺陷识别示意图

Fig. 2 Schematic diagram of defect recognition with deep learning

监督学习的带钢表面缺陷识别模型，并指出该方法能够减少数据标记量，提高效率，适合于标记受限的缺陷识别任务；HE等<sup>[20]</sup>采用生成对抗网络生成了大量未标记的缺陷图像样本，并提出了一种基于cDCGAN和Resnet18的多次训练方法，该方法提升了带钢表面缺陷的识别精度。

综上所述，迄今为止关于铜带表面缺陷检测的研究主要是采用传统机器视觉方法，但该方法极易受光线、雾气和振动等现场环境因素的干扰，具有较差的通用性和鲁棒性。另外，它能够识别的缺陷类别较少，故实际应用效果不够理想。与传统机器视觉方法相比，深度学习方法具有较好的非线性学习感知能力和泛化抗干扰能力，能很好地克服传统方法的不足。为此，研究一种适用于多类别的新型冷轧铜带表面缺陷智能识别方法具有较强的实际意义，对改善带材表面质量、提升装备的国产化与智能化水平具有重要意义。

## 1 冷轧铜带表面缺陷

### 1.1 表面缺陷的分类及特征

冷轧铜带表面缺陷可能发生在冷轧、退火和清

洗等工艺阶段。通常在清洗机组的末端，采用多组高速相机对铜带表面进行连续拍摄，数据采集过程如图3所示。在实际生产过程中，必须先对表面缺陷进行精准分类、识别和统计，后续才能制订有针对性的缺陷控制措施，改善表面质量，提升产品性能。

本文针对国内某冷轧铜带产线，经长期现场跟踪、取样分析和技术交流，最终判定该产线需识别的表面缺陷共有8类，分别为线条(Line mark, LM)、黑点(Black spot, BS)、凹凸包(Concave-convex pit, CP)、边裂(Edge crack, EC)、孔洞(Hole, Ho)、虫斑(Insect spot, IS)、起皮(Peeling, Pe)、脏污(Smudge, Sm)，这8类表面缺陷的形貌如图3所示。表1所列为8类表面缺陷的具体特征与产生机理，由表1可知，各缺陷之间的形状与纹路等特征均不完全一致，这对缺陷识别是有利的，但不同缺陷之间又有某些特征是相似的，如边裂(EC)与孔洞(Ho)均呈现块状特征，这增加了缺陷精确识别的难度。与此同时，这8类缺陷的产生机理与控制措施不尽相同，因此需要对每类缺陷进行精确识别。

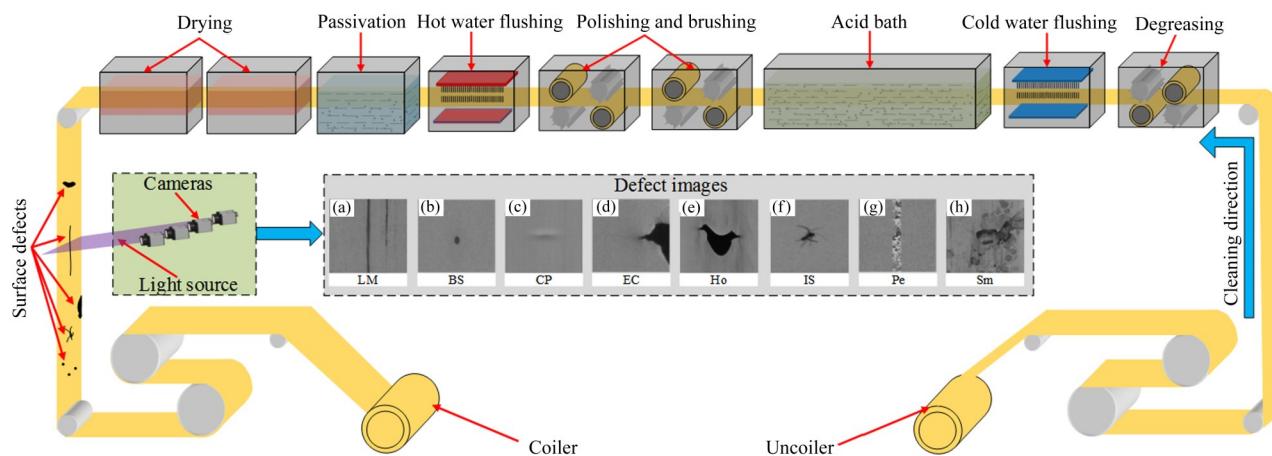


图3 冷轧铜带表面缺陷图像采集过程

Fig. 3 Image acquisition process for surface defects of cold rolling copper strip: (a) LM; (b) BS; (c) CP; (d) EC; (e) Ho; (f) IS; (g) Pe; (h) Sm

## 1.2 表面缺陷数据集

在国内某冷轧铜带生产线采集上述8类表面缺陷图像, 经一段时间现场跟踪发现, 线条(LM)、凹凸包(CP)和边裂(EC)这三类缺陷出现的次数相对较少, 分别采集到157张、204张和231张, 采集到的其余类别表面缺陷图像的数量均大于300张。为了保证各类缺陷图像数据分布均匀, 本文根据图像增广方法(image augmentation), 结合现场可能出现的环境工况, 采用表2所示的五种变换方式(添加高斯噪声、添加椒盐噪声、旋转角度、亮度减弱和亮度增强)随机对上述三类缺陷图像进行扩充, 每类缺陷图像均扩充至300张。此处采用图像增广方法的主要目的是增加数据量, 与前所述图像增强方法的目的是完全不同的。

图像添加噪声时, 假定原始图像为 $f$ , 所添加的噪声为 $n$ , 加噪后的图像 $g$ 表示为式(1)。如果噪声类型为高斯噪声, 那么需要服从正态分布<sup>[21]</sup>, 此时噪声 $n$ 的概率密度函数为 $p(n)$ , 应满足式(2); 如果噪声类型为椒盐噪声, 其在图像中表现为亮暗点状<sup>[22]</sup>, 此时噪声 $n$ 的概率密度函数为 $p'(n)$ , 应满足式(3):

$$g = f + n \quad (1)$$

$$p(n) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(n-\mu)^2/(2\sigma^2)} \quad (2)$$

式中:  $n$ 取值范围为0~255;  $\mu$ 为噪声 $n$ 的平均值;  $\sigma$ 为噪声 $n$ 的标准差。

$$p(n) = \begin{cases} p_a & n = a \\ p_b & n = b \\ 1 - p_a - p_b & \text{其他条件} \end{cases} \quad (3)$$

式中:  $0 \leq p_a \leq 1$ ;  $0 \leq p_b \leq 1$ ; 若 $a > b$ , 噪声 $n = a$ 表现为亮点, 噪声 $n = b$ 表现为暗点,  $a$ 和 $b$ 取值范围为0~255。

图像旋转时, 假定以图像中心为固定点, 原始图像中的任意点坐标为 $(x_0, y_0)$ , 将该点旋转 $\theta$ 角度后, 其坐标变为 $(x, y)$ , 两者之间的计算关系可表示为:

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x_0 \\ y_0 \end{bmatrix} \quad (4)$$

调整图像亮度是指对图像中所有像素点的RGB值统一进行增大或者减小。假定原始图像中的RGB值用 $\Omega$ 表示,  $\Omega'$ 调整之后的RGB值, 则两者之间的计算关系可表示为式(5):

$$\Omega' = \Omega \times (1 + \eta) \quad (5)$$

式中:  $\eta$ 为亮度变换因子。

图4所示为本文制作的冷轧铜带表面缺陷数据集(YSU\_CSC)。该数据集中共有2400张表面缺陷图像, 每类缺陷图像300张, 原始图像大小为200×200, 经预处理后, 数据集中每张图像大小统一为224×224。将其中70%作为训练集样本, 剩余30%中的一半作为验证集样本, 另一半作为测试集样本, 训练集和验证集用于训练模型, 测试集用于检验模型的泛化能力, 不参与模型训练。数据集中各类缺陷图像的具体分布情况如表3所示。

表1 表面缺陷特征与产生机理

Table 1 Characteristics and generation mechanism of surface defect

Defect	Detail information
	Characteristics: Single or multiple lines appear on the surface, with continuous or intermittent distribution and different lengths.
LM	Cause analysis: Defects or copper scraps are present on the surface of the roller or guide roller, causing surface scratches. Control measures: Regularly check the roller surface for defects and foreign objects.
	Characteristics: Single or multiple round black spots on the surface, usually single spot point is common.
BS	Cause analysis: Inclusions or segregation of components occur in the cast slab, and these hard particles or segregations will flow to the strip surface with plastic deformation during the rolling process. Control measures: Optimize the casting process to reduce slag inclusion and prevent the water in the charge from reacting with copper to form oxides.
	Characteristics: Pits or bulges of different sizes on the surface.
CP	Cause analysis: Particles are stuck on the surface of rollers, degreasing rollers, etc., or there are convex points on the roller surface, and pits or bulges are generated on the pressing surface during operation. Control measures: Regularly check whether the rollers have foreign body defects and local convex points.
	Characteristics: Cracks on the two sides extend from the outside to the inside.
EC	Cause analysis: The uneven crystallization of molten copper in the casting process leads to cracks on the edge of the cast slab, and edge cracks are formed in the subsequent rolling. Control measures: Improve the casting process parameters, check the working condition of the mold, and reduce the cracks on the edge of the cast slab.
	Characteristics: Holes with different sizes and irregular shapes on the surface.
Ho	Cause analysis: Segregation forms oxidized hard points, stress concentration occurs near the hard points during cold rolling, and holes are formed. Control measures: Reduce the cooling intensity, reduce the casting temperature as much as possible, and reduce the segregation and microstructure porosity during the casting process.
	Characteristics: Most are embedded in the copper strip surface, with insect appearance.
IS	Cause analysis: Flying insects are pressed into the surface. Control measures: Improve the production site environment and strictly control the number of insects.
	Characteristics: Serious upwarp appear on the copper strip surface.
Pe	Cause analysis: Oxide scales or folds on the surface of the cast slab, form peeling during the rolling process. Control measures: Strictly control the amount of oxide scale on the cast slab surface, and regularly clean the roller and transfer roller to prevent copper scraps from pressed into the slab.
	Characteristics: Irregular dispersive residue marks appear on the surface.
Sm	Cause analysis: Water stains, oil stains, emulsion, or other liquid residues on the copper strip surface during cleaning. Control measures: Adopt cooling lubricant and cleaning agent with better performance, maintain the cleaning line equipment in time, and strengthen regular inspections.

## 2 表面缺陷识别模型

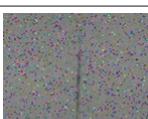
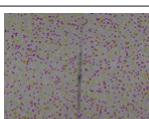
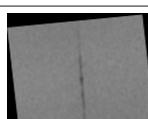
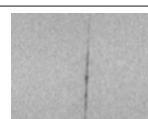
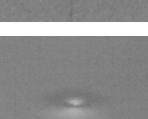
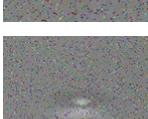
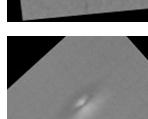
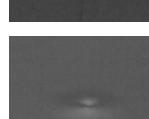
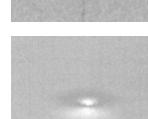
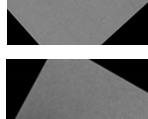
### 2.1 卷积神经网络(CNN)表面缺陷识别模型

为实现冷轧铜带表面缺陷自动化、高精度识别与检测,可采用传统机器视觉方法或深度学习智能

方法。若采用传统机器视觉方法进行缺陷特征的提取与分类,模型不仅很难具有较高的检测精度,而且很难具有较好的泛化及抗干扰能力。目前,人工智能及深度学习理论发展较快,卷积神经网络在很多工程领域取得了较好的应用效果,例如钢带表面缺陷的检测、故障诊断和模式识别等<sup>[23-27]</sup>。为此,

表2 表面缺陷图像数据增广

**Table 2** Surface defect image data augmentation

Defect	Original image	Image augmentation				
		Gaussian noise	Salt-pepper noise	Angle rotation	Brightness reduction	Brightness enhancement
LM						
CP						
EC						

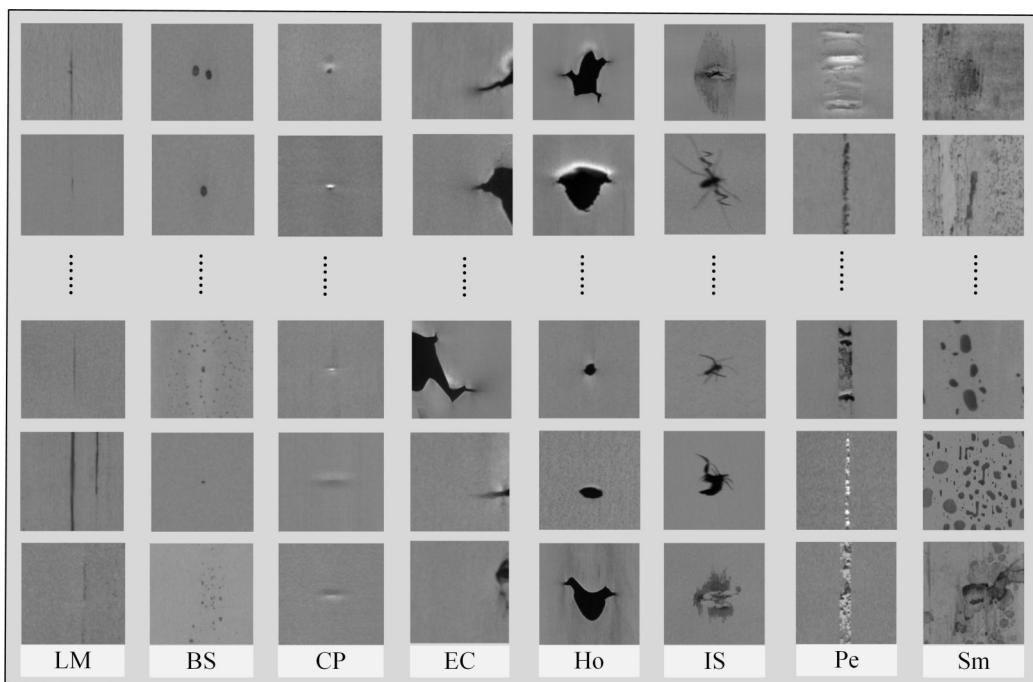


图4 冷轧铜带表面缺陷数据集(YSU CSC)

**Fig. 4** Surface defect dataset of cold rolling copper strip (YSU CSC)

表3 训练集、验证集和测试集中各类表面缺陷图像分布情况

**Table 3** Distribution of surface defect images on training set, validation set and testing set

本文基于深度卷积神经网络, 根据现场采集的表面缺陷图像数据, 建立冷轧铜带表面缺陷智能识别模型。网络模型的一般结构如图 5 所示, 主要由图像数据输入层、卷积层、池化层、全连接前馈神经网络层、输出层组成, 其中卷积层与池化层的具体层数需根据具体问题确定。铜带表面缺陷图像经过多次卷积、池化、非线性激活函数映射等运算后, 将表面缺陷特征信息抽取出来, 最后由全连接前馈神经网络层和输出层计算出某张图像属于各类缺陷的概率, 从而实现缺陷的分类。

## 2.2 EfficientNet 表面缺陷识别模型

目前, 国内外已经对深度卷积神经网络进行了大量的理论研究, 且普遍认为网络的深度、宽度和输入图像的分辨率是影响模型性能的主要因素。已有部分研究针对上述三种因素进行了网络结构的扩展, 例如常见的 ResNet、DenseNet 和 MobileNet 等<sup>[28]</sup>, 这些模型仅是在单一因素上对网络进行了扩展, 使其精度可以得到一定程度的提高。然而一味地增加一个维度又会使网络模型的结构更复杂、参数量更大, 容易出现过拟合等问题<sup>[29-30]</sup>, 不利于表面缺陷识别模型的建立。为此, 本文采用一种新型卷积神经网络模型 EfficientNet 进行表面缺陷的识别研究, 该模型通过采用复合缩放系数对网络的宽度、深度和分辨率三个维度进行结构综合扩

展<sup>[31-32]</sup>, 使其在具有相同精度前提下, 网络结构复杂程度显著降低。缩放系数的表达式如下:

$$\left\{ \begin{array}{l} \text{depth: } d = \alpha^\phi \\ \text{width: } w = \beta^\phi \\ \text{resolution: } r = \gamma^\phi \\ \text{s.t. } \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \\ \alpha \geq 1, \beta \geq 1, \gamma \geq 1 \end{array} \right. \quad (6)$$

式中:  $d$ 、 $w$ 、 $r$  分别是宽度、深度和分辨率三个维度的缩放系数;  $\phi$  是资源控制系数, 控制可用于模型缩放的资源(计算力);  $\alpha$ 、 $\beta$ 、 $\gamma$  是可以通过网格搜索确定的资源分配系数, 分别给宽度、深度和分辨率分配这些资源。在不增加模型参数量的前提下, 通过不断调整深度、宽度和分辨率的缩放系数  $d$ 、 $w$ 、 $r$ , 可使模型达到精度最优。

为了减少模型参数, 提高计算速度, 结合表面缺陷图像的分辨率, 本文采用 EfficientNet 建立冷轧铜带表面缺陷智能识别模型, 其结构由 1 个图像数据输入层、2 个 Conv 卷积层、16 个 MBCConv 移动逆瓶颈卷积模块层、1 个池化层和 3 个全连接层组成, 模型整体结构如图 6 所示。模型的主体是 MBCConv 模块, 根据扩展比采用  $1 \times 1$  逐点卷积改变输出通道维度, 经过一次深度卷积后, 再利用  $1 \times 1$  卷积恢复原始维度, 内部激活函数采用 Swish 函数<sup>[33-34]</sup>。MBCConv1 和 MBCConv6 模块结构如图 7 所示。

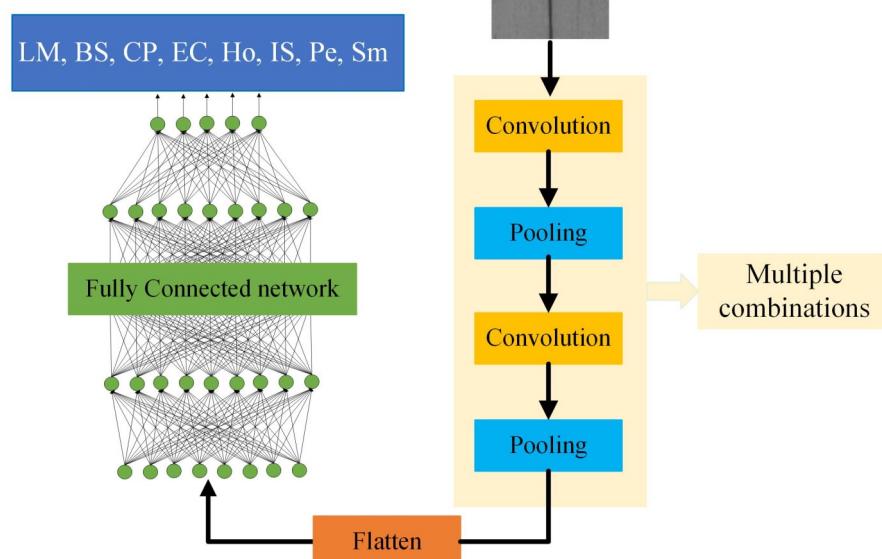


图 5 表面缺陷卷积神经网络模型的一般结构

Fig. 5 General structure of surface defect convolutional neural network model

### 3 结果与分析

#### 3.1 实验方法

采用迁移学习策略, 通过进行模型的训练实验, 分析网络结构与参数对表面缺陷识别精度和运算速度的影响。经过大量实验对比发现, 首先采用ImageNet数据集对模型进行预训练, 使其达到一定精度后, 再采用YSU\_CSC数据集对网络模型的最后7层(3个全连接层和4个卷积层)进行再训练, 此

时模型对表面缺陷能够取得较好的识别效果, 训练策略如图8所示。本文还采用其余三种常用的深度卷积神经网络算法(VGG16、MobileNetV2、ResNet50)建立了相应的缺陷识别模型, 用于模型对比。

#### 3.2 实验结果与分析

模型的训练步数(Epoch)为2000, 训练过程中的误差损失(Error loss)和准确率(Accuracy)如图9所示。由图9可知, 模型在训练集和验证集上的误差

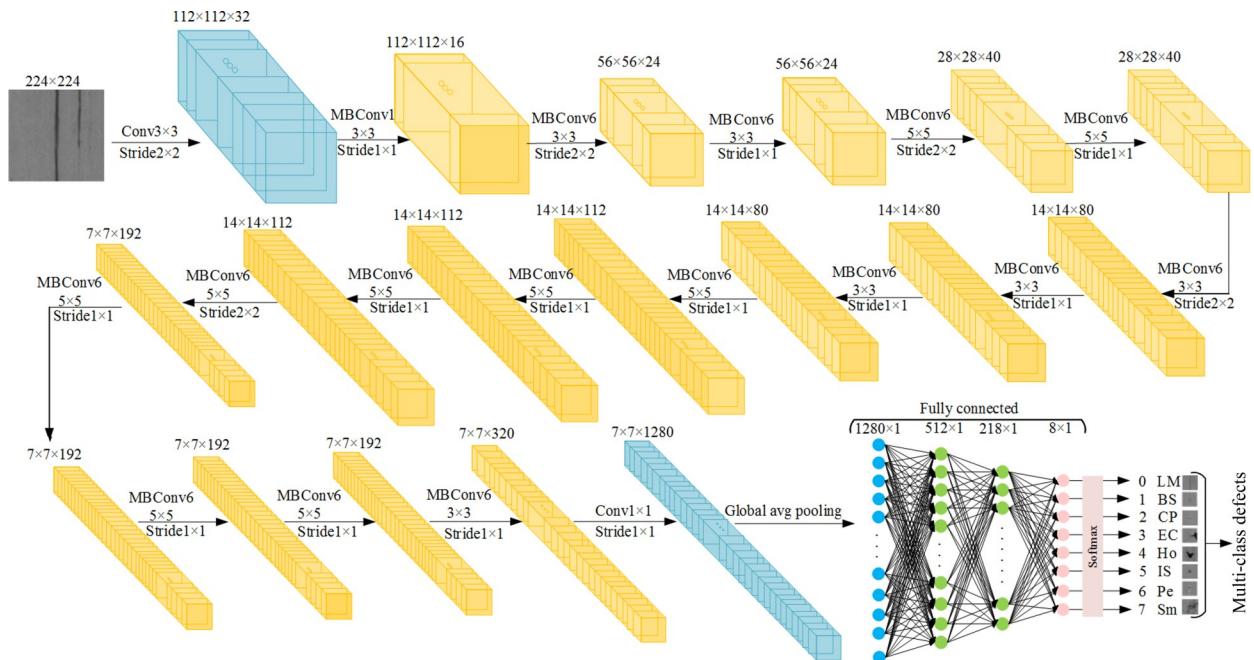


图6 EfficientNet表面缺陷识别模型

Fig. 6 EfficientNet recognition model of Surface defect

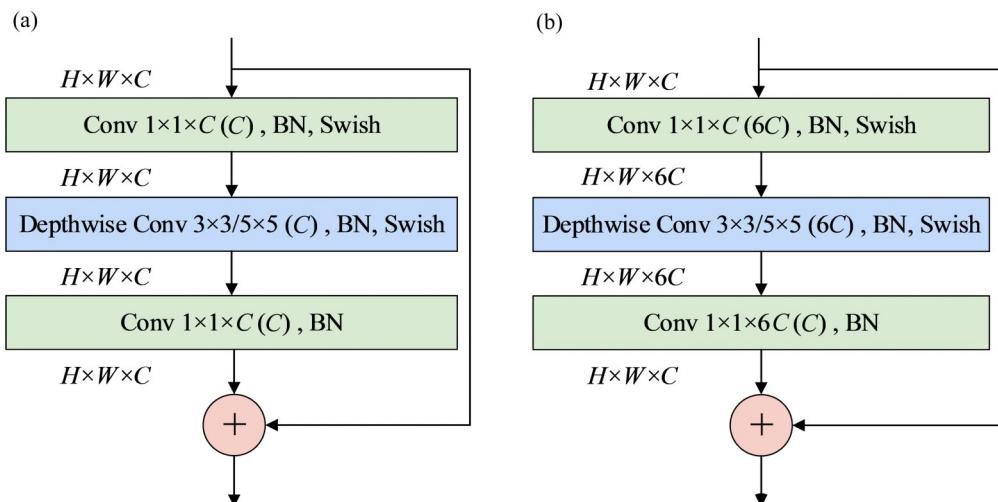


图7 MBConv模块结构图

Fig. 7 Structure diagram of MBConv block: (a) MBConv1; (b) MBConv6

分别达到0.25和0.34左右,整体训练过程表现得比较平稳,这表明模型具有较好的学习能力;训练完毕后,训练集和验证集的准确率分别达到0.93和0.95,表明模型具有一定的泛化能力。为了进一步验证模型的精度和泛化能力,采用该模型对“未见过”的测试集缺陷图像进行预测,同时与VGG16、MobileNetV2、ResNet50三个识别模型在相同测试

集上的表现进行对比,其结果如表4所示。其中VGG16、MobileNetV2、ResNet50识别模型的准确率分别为75.27%、65.83%、82.78%;相比这三个模型,本文模型准确率最高为93.05%。VGG16、MobileNetV2、ResNet50识别模型对于单张缺陷图像的平均识别时间为2412 ms、165 ms、1205 ms,本文模型为197 ms,与MobileNetV2相近。综

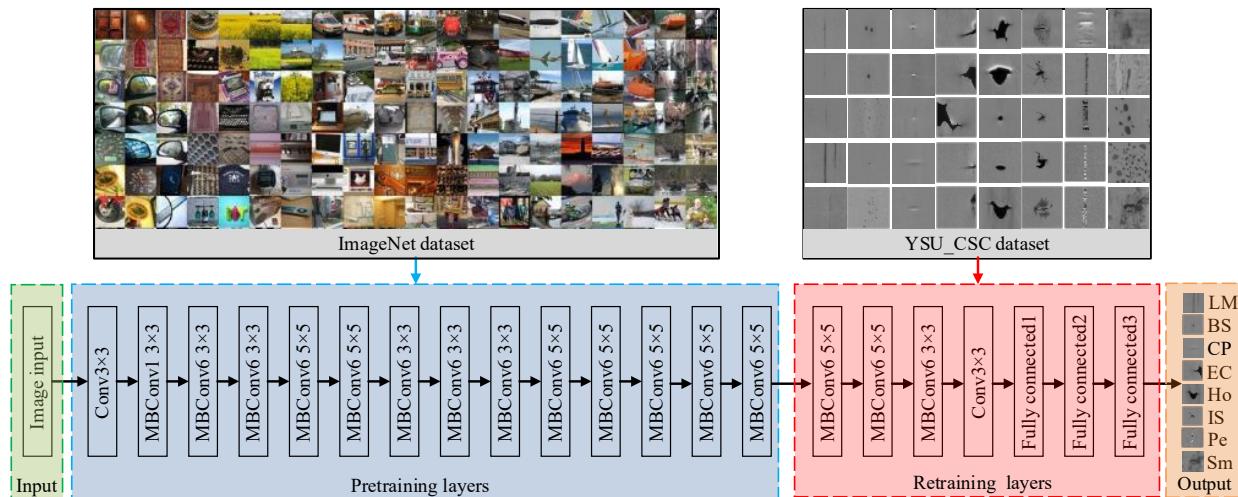


图8 模型的训练策略

Fig. 8 Training strategy of proposed model

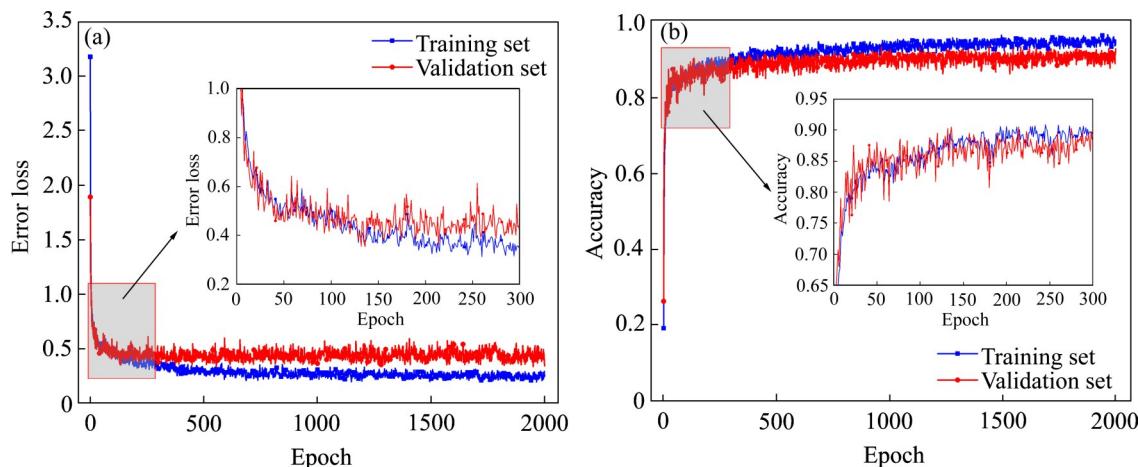


图9 模型的误差损失和准确率

Fig. 9 Error loss and accuracy of proposed model: (a) Error loss; (b) Accuracy

表4 不同模型在测试集上的结果对比

Table 4 Comparison of results of different models on testing set

Model	Accuracy/%	Recognition time of single defect image/ms
VGG16	75.27	2412
ResNet50	82.78	1205
MobileNetV2	65.83	165
Ours method	93.05	197

合考虑模型精度和识别速度, 本文模型是最佳的, 可以满足工程使用要求。

为了研究模型对缺陷图像的分类识别机制, 本

文对测试集中的缺陷图像识别结果进行了可视化分析。图10给出了模型对测试集中8类缺陷图像的识别概率。其中, 绿色柱代表类别识别正确的概率,

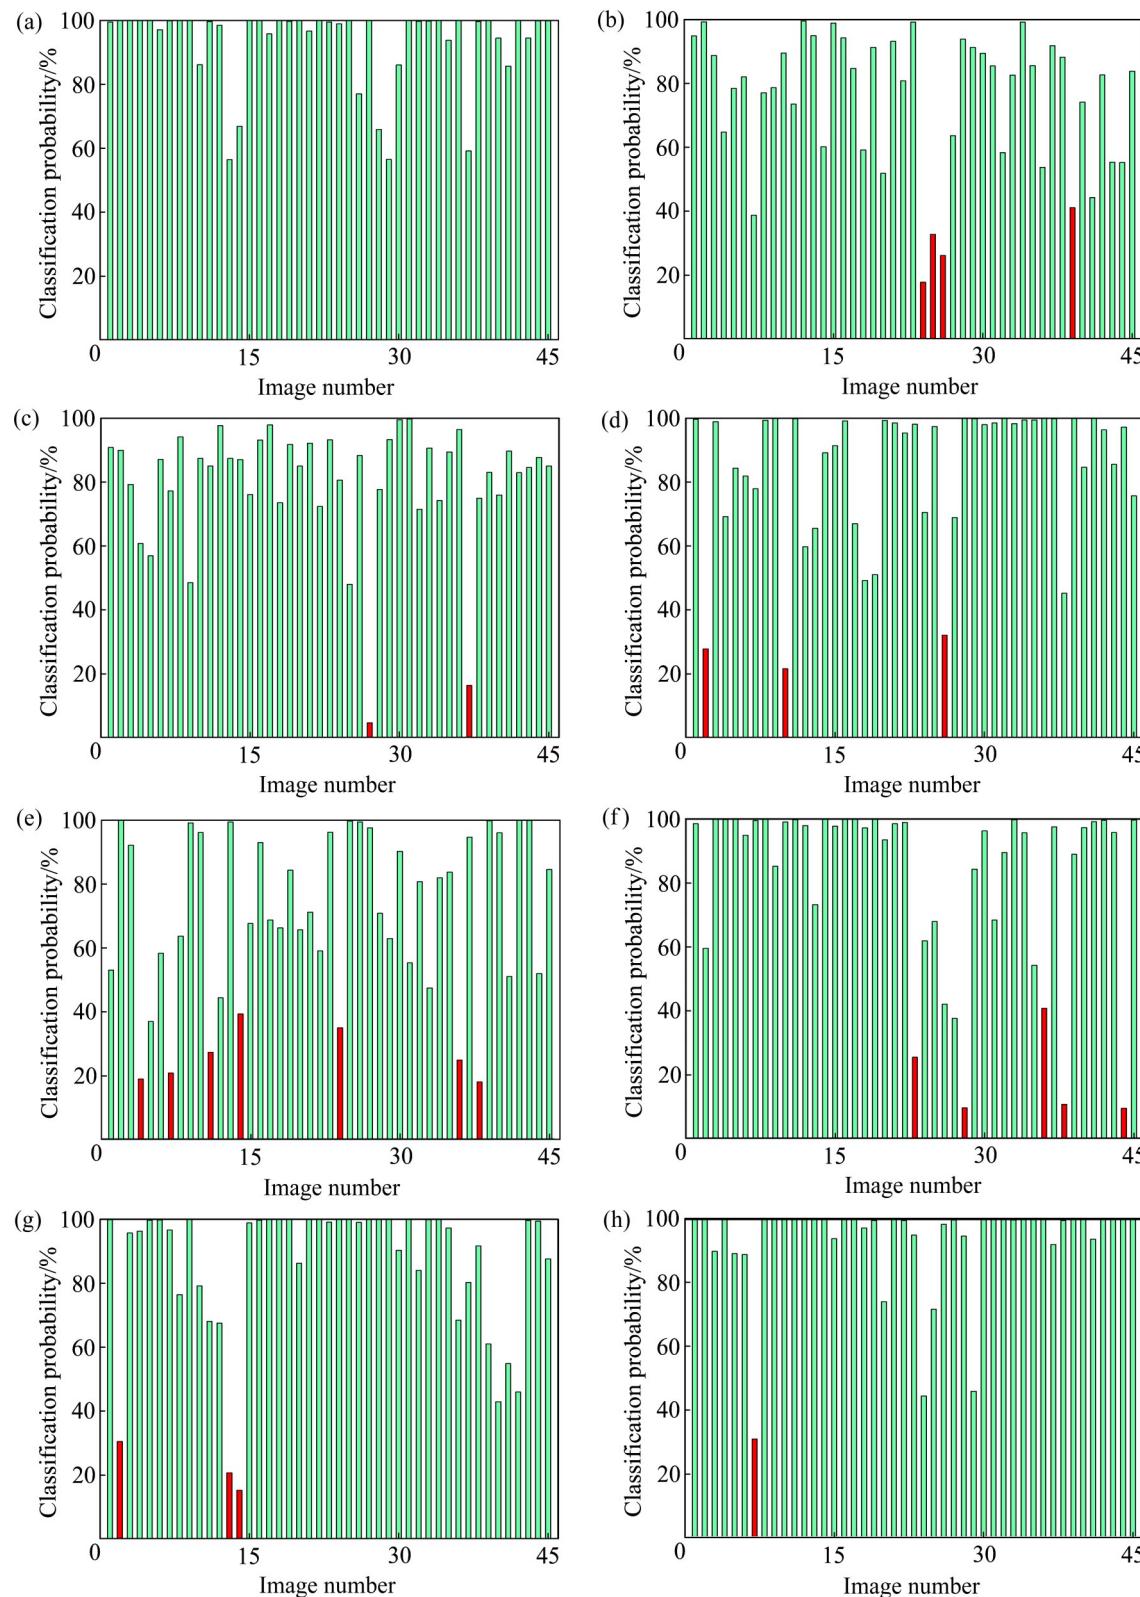


图10 模型对测试集中每张缺陷图像的识别概率

Fig. 10 Proposed model's recognition probability of each defect image on testing set: (a) LM; (b) BS; (c) CP; (d) EC; (e) Ho; (f) IS; (g) Pe; (h) Sm

红色柱代表类别识别错误的概率。由图10可知,模型对测试集中线条(LM)、凹凸包(CP)和脏污(Sm)3类缺陷的整体识别效果很好,其错误率较低,分别为0%、4.44%和2.22%;对黑点(BS)、孔洞(Ho)和虫斑(IS)3类缺陷的识别错误率相对较高,分别为8.89%、15.56%和11.11%。

为了进一步分析模型对缺陷识别错误的原因,分别作出训练集与测试集的混淆矩阵,其结果如图11所示。图11(a)和11(b)中纵轴表示真实的类别标签,横轴表示模型预测的类别标签,对角线上的数值表示识别结果的正确率,偏离对角线位置的数值表示识别结果的错误率,图中颜色的深浅对应着准确率的数值大小,从这两个图的对角线颜色也可以看出本文模型具有较好的学习能力和泛化能力。从图11(b)中可以看出,缺陷之间识别错误的类型有两种:相互型与单向型。典型的“相互型”识别错误是黑点(BS)与凹凸包(CP),这两种缺陷容易相互混淆,但基本不会或很少被识别为其他六类缺陷,相互之间的识别错误率分别为8.9%与4.4%,说明这两种缺陷的特征相似度较高。其他识别错误主要是“单向型”,即前一种缺陷很容易被误判为后一种缺陷,但后一种缺陷却很少或基本不会被误判为前一种缺陷,如孔洞(Ho)特别容易被错误识别为黑点(BS),错误率达到11.1%,但黑点(BS)却几乎不会被识别为孔洞(Ho),表明数据集中的某些孔洞

(Ho)缺陷的特征比较接近于黑点(BS),但黑点(BS)缺陷的特征却并不接近于孔洞(Ho)。与此类似的“单向型”识别错误还有边裂(EC)与凹凸包(CP)、虫斑(IS)与孔洞(Ho)。从图11(a)中也可得到类似规律。

图12所示为本文模型对8类缺陷的类激活图(Class activation mapping, CAM)结果,图中红色越深的区域对于模型缺陷分类的重要程度越高。由图12可知,模型对缺陷特征的整体识别效果较好,表明该模型的确可以用于学习各类缺陷的关键特征。其中,黑线(LM)与起皮(Pe)均呈现线条状决策区域,但两者之间又存在显著差异,易于区分;脏污(Sm)的决策区域相对于其他缺陷具有一定的分散性,相对易于识别;黑点(BS)与凹凸包(CP)两类缺陷均呈现圆形或椭圆形点状,相似度较高,容易引起相互混淆;孔洞(Ho)缺陷的决策区域呈现不规则块状,当孔洞(Ho)缺陷的面积较小且边缘较为平滑时,容易被误判为黑点(BS);虫斑(IS)的决策区域也出现了不规则的块状,当腿部与翅部特征不明显时,容易被误判为孔洞(Ho);此外,边裂(EC)与凹凸包(CP)缺陷的决策区域均呈现一定的辐射状,当边裂(EC)缺陷较小时,容易被误判为凹凸包(CP)。未来可以重点考虑增加缺陷图像数据量,并为缺陷图像制订更加细致的划分标准,以此进一步提高模型对表面缺陷的识别精度。

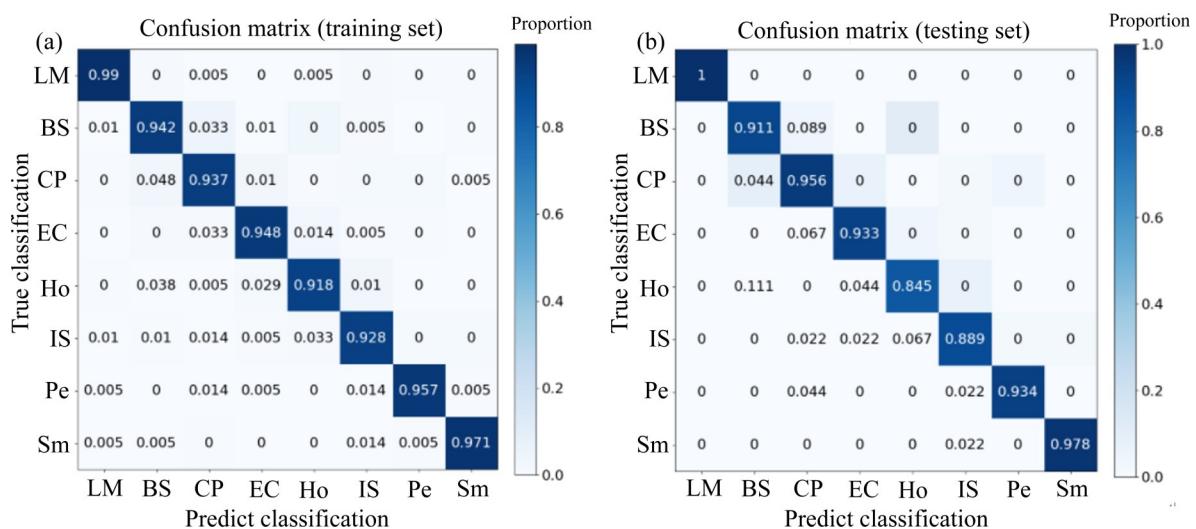


图11 模型对训练集与测试集的混淆矩阵

Fig. 11 Confusion matrix of training set and testing set by proposed model: (a) Training set; (b) Testing set

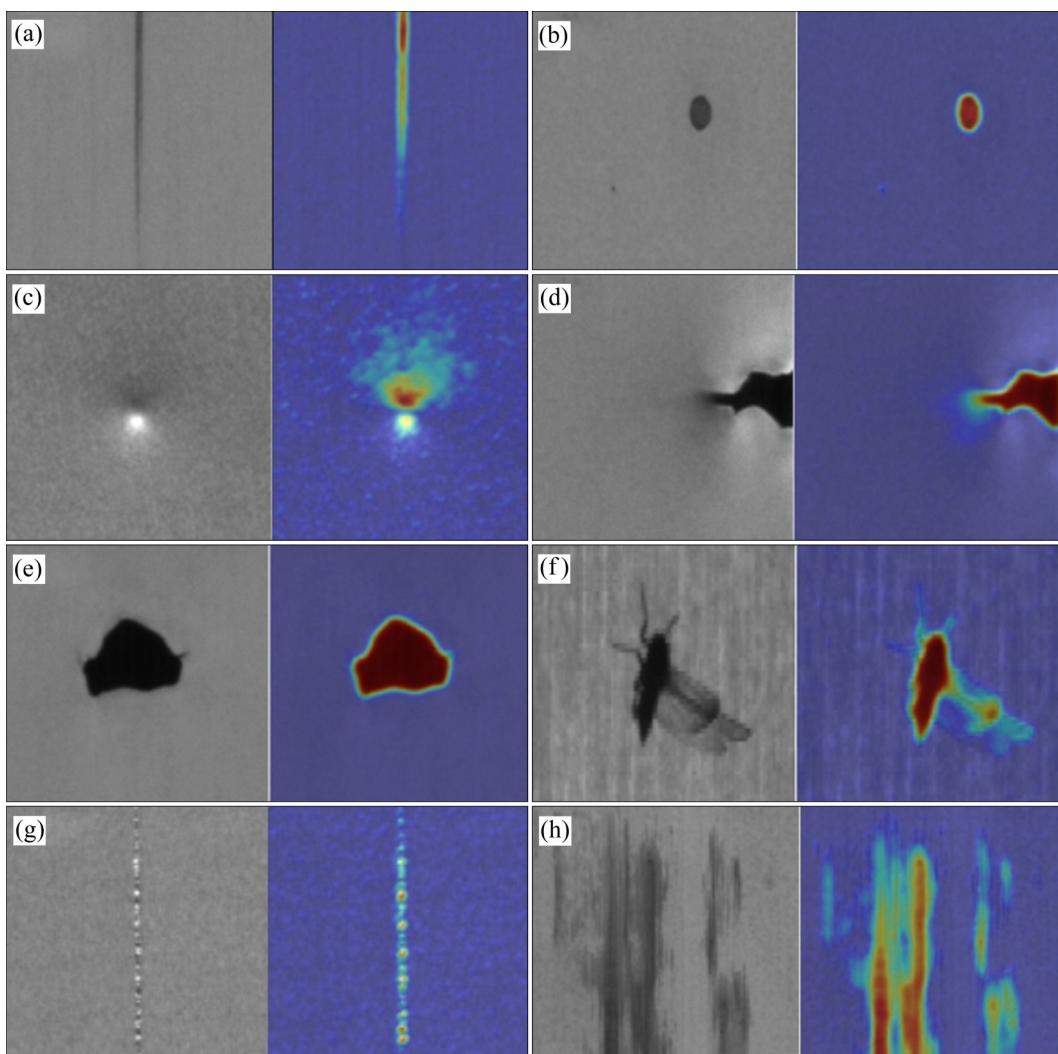


图12 模型对表面缺陷的类激活图结果

Fig. 12 CAM results of surface defect by the proposed model: (a) LM; (b) BS; (c) CP; (d) EC; (e) Ho; (f) IS; (g) Pe; (h) Sm

合表现最好。

3) 在测试集上, 模型对线条、凹凸包和脏污3类缺陷的整体识别效果较好, 错误率较低, 分别为0%、4.44%和2.22%; 对黑点、孔洞和虫斑3类缺陷识别错误率相对较高, 分别为8.89%、15.56%和11.11%。缺陷之间识别错误的类型有两种: 相互型与单向型, 属于“相互型”识别错误的是黑点与凹凸包, 属于“单向型”识别错误的是孔洞与黑点、边裂与凹凸包、虫斑与孔洞。

## 4 结论

1) 结合实际生产需求, 将冷轧铜带常见表面缺陷划分为线条、黑点、凹凸包、边裂、孔洞、虫斑、起皮和脏污8类, 并在国内某产线现场采集图像数据, 建立了一套冷轧铜带表面缺陷数据集(YSU\_CSC)。

2) 与VGG16、MobileNetV2、ResNet50三个识别模型在相同测试集上的表现相比, 基于EfficientNet卷积神经网络建立的冷轧铜带表面缺陷识别模型的准确率最高, 达到了93.05%, 单张缺陷图像平均识别时间为197 ms, 具有较好的泛化能力, 且运算速度较快, 可以满足实际工程要求, 综

4) 类激活图结果表明, 该模型的确可以用于学习各类缺陷的关键特征。黑线、起皮和脏污的决策区域差异明显, 易于区分; 黑点与凹凸包的决策区域相似度较高, 易相互混淆; 孔洞、边裂、虫斑3类缺陷易受特征影响, 从而引起误判。未来将考虑

从增加缺陷图像数据数量、细分相似缺陷图像和改进模型结构三个方面来进一步提升模型的综合性能。

## REFERENCES

- [1] 金平, 刘楚明, 余学德, 等. 中国铜加工产业现状及发展趋势[J]. 有色冶金设计与研究, 2015, 36(2): 32–35, 38.  
JIN Ping, LIU Chu-ming, YU Xue-de, et al. Present situation of Chinese copper processing industry and its development trend[J]. Nonferrous Metals Engineering & Research, 2015, 36(2): 32–35, 38.
- [2] 刘晓波, 袁光前, 熊珍艳. 冷轧铜板带斯通轧制力模型研究[J]. 机械设计与制造, 2015(1): 62–65.  
LIU Xiao-bo, YUAN Guang-qian, XIONG Zhen-yan. Study on cold rolled copper strips rolling force model of stone[J]. Machinery Design & Manufacture, 2015(1): 62–65.
- [3] 张文芹, 郑晨飞. 铜及铜合金带材表面质量控制及技术现状[J]. 有色金属材料与工程, 2016, 37(4): 125–131.  
ZHANG Wen-qin, ZHENG Chen-fei. Surface quality control and technical actuality of copper and copper alloy strip[J]. Nonferrous Metal Materials and Engineering, 2016, 37(4): 125–131.
- [4] 张玉杰. 浅析铜板带材的表面质量控制[J]. 有色金属加工, 2005, 34(5): 27–29, 52.  
ZHANG Yu-jie. Discussion on surface quality control of copper sheet and strip[J]. Nonferrous Metals Processing, 2005, 34(5): 27–29, 52.
- [5] 宋青. 机器视觉技术在铜板带表面检验中的应用[J]. 上海有色金属, 2012, 33(2): 77–80.  
SONG Qing. Applications of machine vision to the quality test of copper strip surfaces[J]. Shanghai Nonferrous Metals, 2012, 33(2): 77–80.
- [6] 袁红中, 付炜, 郭永魁. 一种基于动态阈值的镀铜表面缺陷检测算法[J]. 燕山大学学报, 2010, 34(4): 336–339.  
YUAN Hong-zhong, FU Wei, GUO Yong-kui. An algorithm of detecting surface defects of copper plating based on dynamic threshold[J]. Journal of Yanshan University, 2010, 34(4): 336–339.
- [7] 沈昱明, 杨征兵. 机器视觉在铜带表面缺陷检测系统中的应用[J]. 电子测量技术, 2010, 33(4): 65–67.  
SHEN Yu-ming, YANG Zheng-bing. Techniques of machine vision applied in detection of copper strip surface's defects[J]. Electronic Measurement Technology, 2010, 33(4): 65–67.
- [8] 张学武, 丁燕琼, 段敦勤, 等. 基于视觉仿生机理的铜带表面缺陷检测[J]. 中国图象图形学报, 2011, 16(4): 593–599.  
ZHANG Xue-wu, DING Yan-qiong, DUAN Dun-qin, et al. Surface defects inspection of copper strips based on vision bionics[J]. Journal of Image and Graphics, 2011, 16(4): 593–599.
- [9] 李嘉惠. 铝/铜板带表面缺陷检测关键技术研究[D]. 洛阳: 河南科技大学, 2019: 37–44.  
LI Jia-hui. Research on key technology of surface defect detection in aluminum/copper strip[D]. Luoyang: Henan University of Science and Technology, 2019: 37–44.
- [10] 孟繁明. 基于ARM和DSP的铜带缺陷在线检测系统研发[D]. 杭州: 中国计量大学, 2019: 24–39.  
MENG Fan-ming. Development of copper strip defect online detection system based on ARM and DSP[D]. Hangzhou: China University of Metrology, 2019: 24–39.
- [11] 张晓伟, 龚峰, 徐立军. 用多元统计方法和SVM检测铜带表面缺陷[J]. 国际计算机应用与软件, 2012, 43(1): 44–50.  
ZHANG X W, GONG F, XU L Z. Inspection of surface defects in copper strip using multivariate statistical approach and SVM[J]. International Journal of Computer Applications in Technology, 2012, 43(1): 44–50.
- [12] 郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12): 20–36.  
ZHENG Yuan-pan, LI Guang-yang, LI Ye. Survey of application of deep learning in image recognition[J]. Computer Engineering and Applications, 2019, 55(12): 20–36.
- [13] 宋克成, 袁亚海. 基于完备局部二值模式的热轧带钢表面缺陷检测[J]. 应用表面科学, 2013, 285: 858–864.  
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.
- [14] 何勇, 宋克成, 孟庆刚, 等. 基于端到端的钢带表面缺陷检测方法[J]. 仪表与量具, 2020, 69(4): 1493–1504.  
HE Y, SONG K C, MENG Q G, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1493–1504.
- [15] SAIZ F A, SERRANO I, BARANDIARÁN I, et al. A robust and fast deep learning-based method for defect classification in steel surfaces[C]//2018 International Conference on Intelligent Systems (IS). Funchal, Portugal. IEEE, 2018: 455–460.
- [16] 向宽, 李松松, 栾明慧, 等. 基于改进Faster RCNN的铝材表面缺陷检测方法[J]. 仪器仪表学报, 2021, 42(1): 191–198.  
XIANG Kuan, LI Song-song, LUAN Ming-hui, et al. Aluminum product surface defect detection method based on

- improved Faster RCNN[J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 191–198.
- [17] 张旭, 黄定江. 基于深度学习的铝材表面缺陷检测[J]. 华东师范大学学报(自然科学版), 2020(6): 105–114.
- ZHANG Xu, HUANG Ding-jiang. Defect detection on aluminum surfaces based on deep learning[J]. Journal of East China Normal University (Natural Science), 2020(6): 105–114.
- [18] 叶刚, 李毅波, 马逐曦, 等. 基于ViBe的端到端铝带表面缺陷检测识别方法[J]. 浙江大学学报(工学版), 2020, 54(10): 1906–1914.
- YE Gang, LI Yi-bo, MA Zhu-xi, et al. End-to-end aluminum strip surface defects detection and recognition method based on ViBe[J]. Journal of Zhejiang University (Engineering Science), 2020, 54(10): 1906–1914.
- [19] 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.
- [20] 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.
- [21] 熊鹏文, 童小宝, 宋爱国, 等. 基于变分贝叶斯高斯混合噪声模型的机器人跨模态生成对抗网络[J]. 中国科学: 信息科学, 2021, 51(1): 104–121.
- XIONG Peng-wen, TONG Xiao-bao, SONG Ai-guo, et al. Robotic cross-modal generative adversarial network based on variational Bayesian Gaussian mixture noise model[J]. Scientia Sinica (Informationis), 2021, 51(1): 104–121.
- [22] 龙敬文, 蒲亦非, 周激流. 基于BPANN噪声检测的反距离加权法滤除椒盐噪声[J]. 计算机应用研究, 2018, 35(4): 1266–1269, 1273.
- LONG Jing-wen, PU Yi-fei, ZHOU Ji-liu. Removal of salt and pepper noise by inverse distance weighted based on BPANN noise detection[J]. Application Research of Computers, 2018, 35(4): 1266–1269, 1273.
- [23] LEE S Y, TAMA B A, MOON S J, et al. Steel surface defect diagnostics using deep convolutional neural network and class activation map[J]. Applied Sciences, 2019, 9(24): 5449.
- [24] 王李管, 陈斯佳, 贾明滔, 等. 基于深度学习的黑钨矿图像识别选矿方法[J]. 中国有色金属学报, 2020, 30(5): 1192–1201.
- WANG Li-guan, CHEN Si-jia, JIA Ming-tao, et al. Beneficiation method of wolframite image recognition based on deep learning[J]. The Chinese Journal of Nonferrous Metals, 2020, 30(5): 1192–1201.
- [25] 魏立新, 魏新宇, 孙浩, 等. 基于深度网络训练的铝热轧轧制力预报[J]. 中国有色金属学报, 2018, 28(10): 2070–2076.
- WEI Li-xin, WEI Xin-yu, SUN Hao, et al. Prediction of aluminum hot rolling force based on deep network[J]. The Chinese Journal of Nonferrous Metals, 2018, 28(10): 2070–2076.
- [26] 李晓刚. 冷带轧机板形模式识别及板形自适应控制研究[D]. 秦皇岛: 燕山大学, 2020: 51–78.
- LI Xiao-gang. Research on flatness pattern recognition and flatness adaptive control of cold strip mill[D]. Qinhuangdao: Yanshan University, 2020: 51–78.
- [27] 郑伟达, 张惠然, 胡红青, 等. 基于不同机器学习算法的钙钛矿材料性能预测[J]. 中国有色金属学报, 2019, 29(4): 803–809.
- ZHENG Wei-da, ZHANG Hui-ran, HU Hong-qing, et al. Performance prediction of perovskite materials based on different machine learning algorithms[J]. The Chinese Journal of Nonferrous Metals, 2019, 29(4): 803–809.
- [28] 陈羽立, 孙付春, 郭兴华, 等. 基于EfficientNet的鸡蛋裂纹检测研究[J]. 成都大学学报(自然科学版), 2020, 39(4): 385–389.
- CHEN Yu-li, SUN Fu-chun, GUO Xing-hua, et al. Research on egg crack detection based on EfficientNet[J]. Journal of Chengdu University (Natural Science Edition), 2020, 39(4): 385–389.
- [29] 张敏, 赵雪青. 基于EfficientNets的织物疵点图像分类方法[J]. 纺织高校基础科学学报, 2020, 33(4): 64–70.
- ZHANG Min, ZHAO Xue-qing. EfficientNets-based method for fabric defect image classification[J]. Basic Sciences Journal of Textile Universities, 2020, 33(4): 64–70.
- [30] DUONG L T, NGUYEN P T, SIPIO C D, et al. Automated fruit recognition using EfficientNet and MixNet[J]. Computers and Electronics in Agriculture, 2020, 171: 105326.
- [31] TAN M X, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks[EB/OL]. 2019: arXiv: 1905.11946[cs.LG]. <https://arxiv.org/abs/1905.11946>.
- [32] ALHICHRI H, ALSWAYED A S, BAZI Y, et al. Classification of remote sensing images using EfficientNet-B3 CNN model with attention[J]. IEEE Access, 2021, 9: 14078–14094.
- [33] 刘贤梅, 景雅虹, 田枫, 等. 基于关键点估计的实时道路元素检测算法[J]. 模式识别与人工智能, 2020, 33(10):

- 917–925.  
LIU Xian-mei, JING Ya-hong, TIAN Feng, et al. Real-time road element detection based on keypoints estimation[J]. Pattern Recognition and Artificial Intelligence, 2020, 33(10): 917–925.
- [34] 尹梓睿, 张索非, 张磊, 等. 适于行人重识别的二分支
- EfficientNet 网络设计 [J]. 信号处理, 2020, 36(9): 1481–1488.  
YIN Zi-rui, ZHANG Suo-fei, ZHANG Lei, et al. Design of a two-branch EfficientNet for person re-identification[J]. Journal of Signal Processing, 2020, 36(9): 1481–1488.

## Intelligent recognition method for surface defects of cold rolling copper strip

XU Yang-huan<sup>1</sup>, WANG Dong-cheng<sup>1,2</sup>, LIU Hong-min<sup>1,2</sup>, YU Hua-xin<sup>1,2</sup>

(1. National Engineering Research Center for Equipment and Technology of Cold Rolling Strip, Yanshan University, Qinhuangdao 066004, China;  
2. State Key Laboratory of Metastable Materials Science and Technology, Yanshan University, Qinhuangdao 066004, China)

**Abstract:** Surface quality is one of the significant indicators of cold rolling copper strip product quality. In order to realize the accurate and automatic detection of copper strip surface defects, this article first classifies common surface defects, and creates a copper strip surface defect image dataset (YSU\_CSC). Then, with the EfficientNet convolutional neural network as the core, based on the transfer learning strategy, the optimal cold rolling copper strip surface defect recognition model was established through training experiments. At the same time, it was compared with the defect recognition model established by the other three convolution neural network algorithms. The results show that the accuracy of this model is the highest, and the accuracy reaches 93.05%, the average recognition time of single defect image is 197 ms, and the comprehensive performance is the best, which basically meets the engineering requirements. Finally, the defect recognition results of this model on the testing set were visualized, the causes of the error of defect recognition was analyzed, and the direction of further optimization is given.

**Key words:** cold rolling copper strip; surface defects; EfficientNet CNN; transfer learning; recognition model

---

**Foundation item:** Project(52074242) supported by the National Natural Science Foundation of China; Project (2019) supported by the High-end Talents and “Giant Plan” Innovation Team of Hebei Province, China

**Received date:** 2021-07-25; **Accepted date:** 2021-09-24

**Corresponding author:** WANG Dong-cheng; Tel: +86-18630320653; E-mail: wdc-731@163.com

(编辑 龙怀中)