

# 基于二值化赋范梯度的中厚板表面缺陷检测

梁颖<sup>1</sup>, 詹光曹<sup>2</sup>, 徐科<sup>1</sup>

(1. 北京科技大学 钢铁共性技术协同创新中心, 北京 100083;

2. 福建三钢闽光股份有限公司中板厂, 福建 三明 365000)

**摘要:** **目的** 针对中厚板表面复杂、缺陷识别率低的问题, 设计一种有效的候选窗口提取方法, 提升中厚板表面缺陷检测的准确性与实时性。**方法** 引入视觉选择性注意机制, 采用一种基于二值化赋范梯度特征 (Binarized Normed Gradients, BING) 的一般对象估计算法来快速准确地提取缺陷感兴趣区域 (Region of Interest, ROI), 有效缩短搜寻过程。首先将样本归一化到  $8 \times 8$  大小, 提取规范化梯度特征 (Normed Gradients, NG), 学习一个测量显著性的线性 SVM 分类器来预测图像窗口含有缺陷的可能性。然后再通过样本尺度优化显著性评分, 学习一个校准显著评分的线性 SVM 分类器。最后将两个 SVM 模型级联, 用于在线检测, 提取缺陷感兴趣区域。**结果** 将训练好的 BING 模型与 Inception-V3 卷积神经网络相结合, 用于中厚板表面缺陷检测与识别, BING 算法有效减少了 ROI 数量, 在 ROI 数量为 500 的情况下, 达到了 98.2% 的召回率。**结论** 在保证缺陷召回率的前提下, BING 生成的 ROI 数量比滑动窗口遍历方式少 2 个数量级, 有效减少了后续识别算法的计算量, 有利于引入复杂的分类器提升中厚板表面缺陷识别的准确率。

**关键词:** 中厚板; 缺陷检测; 二值化赋范梯度 (BING); ROI 提取; 规范化梯度 (NG); 线性 SVM

**中图分类号:** TG142.71 **文献标识码:** A **文章编号:** 1001-3660(2019)10-0336-06

**DOI:** 10.16490/j.cnki.issn.1001-3660.2019.10.041

## Surface Defect Detection of Medium and Heavy Plates Based on Binarized Normed Gradients

LIANG Ying<sup>1</sup>, ZHAN Guang-cao<sup>2</sup>, XU Ke<sup>1</sup>

(1. Collaborative Innovation Center of Steel Technology, University of Science and Technology Beijing, Beijing 100083, China;

2. Medium Plate Mill, Fujian Sangang Minguang Co., Ltd, Sanming 365000, China)

**ABSTRACT:** The work aims to design an effective candidate window extraction method to improve the accuracy and real-time of surface defect detection of medium plates for problems of complex surface and low defect recognition rate in medium plates. The visual selective attention mechanism was introduced and generic object estimation algorithm based on Binarized Normed Gradients (BING) was used to quickly and accurately extract the defect region of interest (ROI) and shorten the search process effectively. Firstly, the samples were normalized to  $8 \times 8$  size, and Normed Gradients (NG) were extracted to learn a linear SVM classifier for measuring saliency to predict the possibility of defects in image windows. Then, a linear SVM classifier calibrating

收稿日期: 2019-02-27; 修订日期: 2019-05-20

Received: 2019-02-27; Revised: 2019-05-20

基金项目: “十三五”国家重点研发计划课题 (2018YFB0704304); 国家自然科学基金项目 (51674031)

Fund: Supported by the "Thirteenth Five-Year" National Key R&D Program of China (2018YFB0704304) and the National Natural Science Foundation of China (51674031)

作者简介: 梁颖 (1991—), 女, 博士研究生, 主要研究方向为表面检测、机器视觉。

Biography: LIANG Ying (1991—), Female, Doctoral candidate, Research focus: surface detection, machine vision.

通讯作者: 徐科 (1972—), 男, 博士, 研究员, 博士生导师, 主要研究方向为表面检测、机器视觉、智能制造等。邮箱: xuke@ustb.edu.cn

Corresponding author: XU Ke (1972—), Male, Doctor, Researcher, Doctoral tutor, Research focus: surface detection, machine vision, intelligent manufacturing. E-mail: xuke@ustb.edu.cn

the saliency score was learned by optimizing the saliency score at the sample scale. Finally, two SVM models were cascaded for on-line detection and extraction of defect interest region. The trained BING model and Inception-V3 convolutional networks were combined for defect detection and identification in medium plates. BING algorithm effectively reduced the number of windows of interest and achieved a recall rate of 98.2% when the number of ROI was 500. Under the premise of ensuring defect recall rate, the number of ROIs generated by BING is two orders of magnitude smaller than the sliding window method, which effectively reduces the computational complexity of subsequent identification modules and is conducive to introducing complex classifiers to improve the accuracy of surface defect detection of medium plates.

**KEY WORDS:** medium plates; defect detection; Binarized Normed Gradients (BING); extraction of ROI; Normed Gradients (NG); linear SVM

近年来, 机器视觉技术越来越多地应用于钢铁工业产品的在线监测, 表面缺陷检测技术取得了飞跃式的进步, 出现了各种各样的检测方法。安宗权等<sup>[1]</sup>提出一种非线性扩散与图像差分的方法, 实现背景简单的金属表面缺陷检出。闵永智<sup>[2]</sup>利用钢轨图像中不同区域的灰度和梯度特征, 采用双边滤波及背景差分方法, 实现了不同轨道环境下的疤痕和裂纹缺陷检测。陈海永<sup>[3]</sup>提出一种基于谱残差视觉注意模型的带钢表面缺陷在线检测算法, 实现了背景比较干净的冷轧带钢表面缺陷分割。

对于中厚板, 其表面存在大量氧化铁皮, 严重影响真实缺陷的检出, 因此将表面缺陷检测系统更好地应用于中厚板生产还存在难点, 值得更多地关注和研究。由吴贵芳等<sup>[4]</sup>提出的基于形态小波的特征分类方法对中厚板裂纹检测有较好的效果, 但不适用于其他缺陷的识别。周鹏等<sup>[5]</sup>采用尺度不变特征转换 (scale-invariant feature transform, SIFT)<sup>[6]</sup>算子来提取具有尺度旋转不变性的特征向量, 并采用 Euclidean 距离相似性判定度量实现图像匹配, 进而识别出中厚板表面缺陷。该方法更适用于相同缺陷重复出现的情况。贺笛等<sup>[7]</sup>采用 selective-search 方法<sup>[8]</sup>从原始图像中提取 ROI (Region of Interest, 感兴趣区域), 并进行人工标定, 生成缺陷样本, 将深度学习方法应用于中厚板表面缺陷识别, 使识别率得到了很大提高。

文中设计了一种基于二值化赋范梯度特征的候选窗口提取及深度学习分类的中厚板表面缺陷检测识别方法。传统的基于机器视觉的中厚板表面缺陷检测系统工作时, 需要在全图进行缺陷目标的搜寻 (如文献[9]采用  $64 \times 64$  的窗口进行滑动窗口操作)、比对、识别, 计算量大, 较难实现实时的在线检测。通常情况下, 钢板表面缺陷面积占比小, 该方法也造成了计算、存储资源的浪费。因此, 有必要引入视觉选择性注意机制, 初判缺陷所在感兴趣区域 (region of interest, ROI), 以有效缩短搜寻过程。再对获取的显著性缺陷目标区域图像进行识别, 以降低待识别窗口数量, 实现实时准确检测。本文采用一种基于二值化赋范梯度特征的一般对象估计算法 (Binarized Normed Gradients, BING<sup>[10]</sup>) 来快速有效地生成缺陷 ROI。并使用 Inception-

v3<sup>[11]</sup>卷积网络进行 ROI 的分类识别。BING 算法的思想是: 在固定的窗口尺寸下, 物体与背景的梯度分布有所不同, 因此可将其作为特征, 训练线性 SVM (Support Vector Machine, SVM)<sup>[12]</sup>分类器来区分物体与背景。该算法同时将特征及权重向量进行二值化表示, 通过移位的原子操作提升计算速度。其处理速度达 300 帧/s, 可显著提高中厚板缺陷检测算法的准确性与实时性。

## 1 BING 算法原理

BING 算法由南开大学程明明等人于 2014 年提出, 相关论文于同年在 CVPR (Conference on Computer Vision and Pattern Recognition) 会议上发表。BING 算法基于这样一项发现: 对于具有明确封闭边界的一般物体, 当把他们相应的图像窗口缩小至固定的尺寸后, 他们的规范化梯度 (Normed Gradients, NG) 会呈现出很强的相关性, 且与背景的梯度模式具有明显差异。BING 算法中规范化梯度定义为: 通过一个  $[-1, 0, 1]$  模板计算图像各像素点处  $x$  和  $y$  方向的梯度, 分别设为  $G_x, G_y$ , 则该点处的 NG 特征值为  $\min(|G_x| + |G_y|, 255)$ , 如图 1a 所示。游轮和人物窗口对应的规范化梯度如图 1b 所示, 背景窗口对应的规范化梯度如图 1c 所示。可见, 物体的规范化梯度分布呈现出比较杂乱的模式, 而背景的规范化梯度分布则较为单一和均匀。为了能够有效地量化这种显著性, 将图像窗口调整到  $8 \times 8$  大小, 然后计算规范化梯度, 并将其二值化表示为一个简单的 64 维特征向量, 最终学习到一个一般物体显著测量的线性 SVM 分类器来预测图像窗口含有物体的可能性。

要在一幅图像中找到显著目标, 需要使用预先统计的一系列量化窗口尺寸 (包括尺度和纵横比) 来遍历扫描图像, 然后用训练好的线性模型  $w \in R^{64}$  (见图 1d) 对每个窗口打分来衡量存在物体的可能性。如式 (1) 和式 (2) 所示:

$$s_l = \langle w, g_l \rangle \quad (1)$$

$$l = (i, x, y) \quad (2)$$

式中:  $s_l$  为线性 SVM 对该窗口的打分;  $g_l$  为该

窗口的规范化梯度特征;  $l$  为某个指定的窗口,  $i$  和  $(x, y)$  分别代表该窗口的尺寸和位置。

BING 算法通过使用非极大抑制<sup>[13]</sup> (Non-Maximum Suppression) 算法在每一个预定义的尺寸下选择部分最优的窗口作为可能包含物体的候选窗口, 从而去除了数据冗余, 提高后续窗口验证识别的效率。在实际应用中, 一些尺寸的窗口 (如  $10 \times 500$ ) 含有物体的可能性会明显低于其他尺寸如 ( $100 \times 100$ )。在本文中, 具体哪些尺寸的窗口更可能含有缺陷则取决于收集的样本情况。因此 BING 算法对 (1) 式的显著性评分进行了扩展优化, 并称之为校准后的显著评分, 式 (3) 给出了其计算表达式:

$$o_l = v_i \cdot s_l + t_i \quad (3)$$

式中:  $v_i, t_i \in R$ , 分别表示量化尺寸  $i$  对应的线性 SVM 分类器所学习到的系数和偏差项。

为了学习 BING 模型各项参数, 本文采用上述两阶段线性 SVM 级联的方式。第一阶段, 将缺陷与背景的 NG 特征作为训练样本, 学习测量显著性的线性 SVM 分类器, 即式 (1) 中的  $w$ 。第二阶段, 对每一种尺寸  $i$ , 学习一个校准显著评分的线性 SVM 分类器, 即式 (3) 中的  $v_i, t_i$ 。首先由式 (1) 计算尺寸  $i$  下训练图像各窗口的显著性得分  $s_l$ , 并使用非极大抑制方法选择部分最优窗口, 然后将这些最优窗口作为第二阶段的训练样本, 将其显著性得分  $s_l$  作为一维特征, 并根据样本标签区分目标与背景, 最终训练校准显著评分的线性 SVM 分类器。

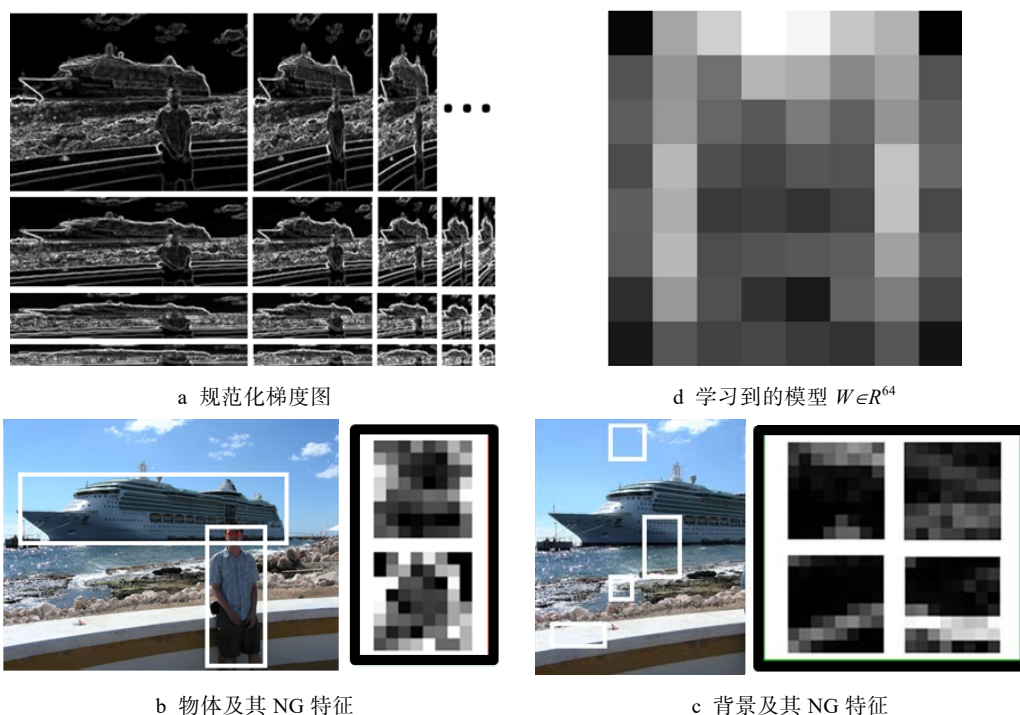


图 1 BING 算法辅助说明图<sup>[10]</sup>

Fig.1 Auxiliary illustration diagram of BING: a) Normed gradients maps; b) Object and NG features; c) Background and NG features; d) Learned model  $W \in R^{64}$

为了加快计算速度, BING 算法利用了二值近似模型的优点, 将 NG 特征进行二值化处理得到二值化规范梯度 BING, 如式 (4) 所示。同时将线性模型  $w$  进行二值表示, 如式 (5) 所示。

$$g_l = \sum_{k=1}^{N_g} 2^{8-k} b_{k,l} \quad (4)$$

$$w = \sum_{j=1}^{N_w} \beta_j \alpha_j \quad (5)$$

式 (4) 中: 梯度特征由一个字节的  $N_g$  二进制位近似表示,  $b$  为 64 维的二值向量。式 (5) 中:  $w \in R^{64}$ ,  $\alpha_j \in \{-1, 1\}^{64}$  为基向量,  $\beta_j \in R$  为各基向量的系数, 也就是说  $w$  由一组基向量的线性组合表示, 线性组合的基向量个数为  $N_w$ 。

综上所述, BING 是一种基于机器学习的算法,

可以通过训练过程, 学习指定的目标, 从而能够快速、更有针对性地输出可能存在目标的候选窗口。因此本文选则 BING 算法来提取缺陷候选窗口。

## 2 基于 BING 算法的中厚板缺陷区域提取

本文采用 BING 算法进行缺陷区域搜索, 生成缺陷 ROI, 并使用 CNN 卷积网络对 ROI 进行缺陷类别的判定。算法流程如图 2 所示。缺陷检测算法包括线下学习和在线检测两个阶段: 线下学习由 BING 训练和 CNN 训练两部分组成; 在线检测主要由缺陷区域提取、缺陷识别两模块组成。

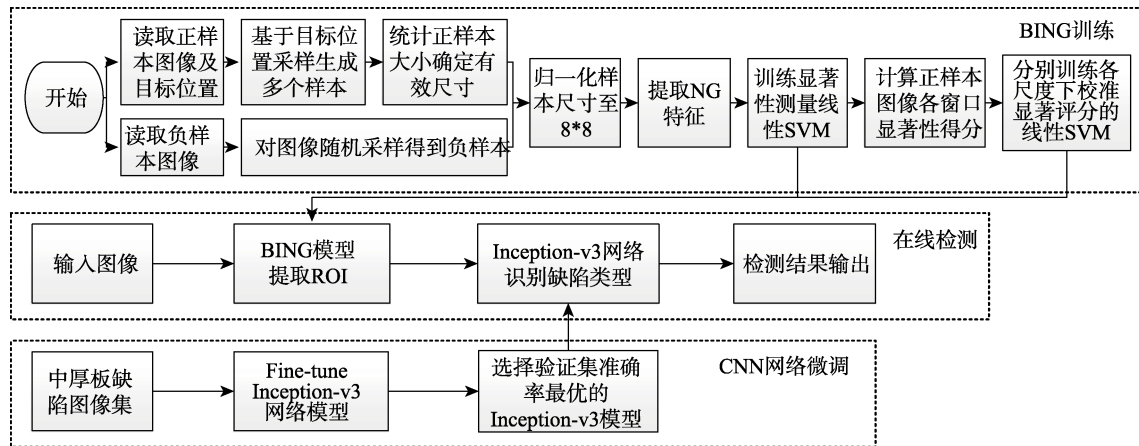


图 2 缺陷检测算法流程

Fig.2 Flow chart of the defect detection algorithm

在线下学习阶段,为了获得针对中厚板表面缺陷的 BING 模型,对某钢厂现场采集的图像进行缺陷位置标注(如图 3 所示)。将翘皮、横向裂纹、纵向裂纹等缺陷作为正样本,具体获取方式即在标注框附近采样,得到多个缺陷图像,并通过水平翻转操作扩增正样本数量。将背景及氧化铁皮区域作为负样本,具体操作是将无缺陷图像随机分块来生成大量负样本。




图 3 BING 训练数据示例(翘皮标注图像)

Fig.3 Examples of BING training data (labeled image of surface upwarping defects)

训练 BING 模型部分即使用生成的样本学习两个级联的线性 SVM 的模型参数。第一级测量显著性的线性 SVM 以  $8 \times 8$  图像尺寸下的 64 维 NG 特征作为输入向量学习权重向量  $w$ 。第二级校准显著评分 SVM 模型即训练不同尺度的参数。首先统计正样本图像的尺寸分布,确定更可能存在缺陷的尺度。然后使用训练好的第一级 SVM 对每个尺度的样本进行预测,得到分数  $S_i$ ,最后以  $S_i$  为特征分别训练,得到该尺度对应的线性 SVM 分类器。

在两个级联线性 SVM 模型参数学习完毕后,便可以将训练好的 BING 模型用于在线检测来预测输入图像,进而生成低于  $10^3$  量级的缺陷候选窗口。这些候选窗口将作为验证识别模块的输入,通过 CNN 网络进行类别属性的判定。

深度学习是机器学习的一个分支,近些年来成为机器学习领域取得的重大突破和研究热点之一。2006 年,加拿大多伦多大学教授、机器学习领域泰斗 Geoffery

Hinton 和他的学生 Ruslan Salakhutdinov 在国际顶尖学术期刊《Science》上发表文章<sup>[14]</sup>,第一次提出了深度学习思想。在深度学习的图像识别领域,卷积神经网络(Convolutional neural Networks, CNN)正在成为最有前途的算法,它将卷积层和池化层结合到传统的神经网络中进行图像特征提取。CNN 已经在数字识别、人脸检测、行人检测和物体检测方面表现出令人满意的结果<sup>[15]</sup>。Inception<sup>[16]</sup>是谷歌提出的一种流行的卷积神经网络模型,它独特细致的 inception 块设计,使得模型在增加网络的深度和宽度的同时,保持了计算量不变。Inception-v3 网络是其第三个版本, v3 版本最大的改变就是将  $7 \times 7$  的卷积核分解成为两个  $1 \times 7$  和  $7 \times 1$  的一维卷积核。这样有利于加速计算,同时也能将 1 个卷积层拆分成成为 2 个卷积层,使网络的深度进一步增加,加强网络的非线性。由于本文使用的中厚板表面缺陷数据集与 ImageNet<sup>[17]</sup>数据集有较大的差异,因此采用网络微调(fine-tune)的方式进行训练,即在已经基于 ImageNet 训练好的 Inception-v3 模型上调整部分参数,以实现对中厚板表面缺陷的分类。同时为了保持模型的容纳能力(capacity),从而保证模型表示能力的迁移,增加了两个全连接层,并引入 Dropout 防止过拟合,如图 4 所示。

在线下训练部分,本文使用某中厚板厂收集到的 9 类缺陷,共 45 849 张图像数据,对 Inception-v3 中 Inception3 卷积块开始的网络层进行参数微调。由于大部分缺陷相对较小,故将所有图片缩放到  $192 \times 192$  像素,使用随机梯度下降算法(Stochastic gradient descent optimizer, SGD)、多类别对数损失函数(categorical crossentropy),并将学习率设置为 0.001,动量参数设置为 0.9 进行训练,迭代轮数为 100。训练结束将最优模型用于在线检测的 ROI 识别模块中。

在线检测部分具体流程为:将钢板区域图像输入 BING 模型, BING 模型预测并生成  $T$  个 ROI; 将 ROI 图像以 64 为一批,输入 Inception-v3 网络进行识别,并根据最高得分判定缺陷类别;最终通过窗口聚类,将同类别有重叠的缺陷窗口融合,输出检测结果。



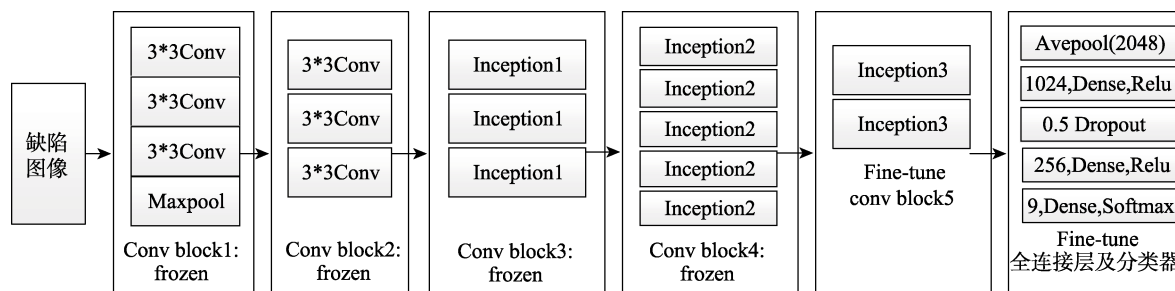


图4 Inception-v3 需要 fine-tune 的网络结构  
Fig.4 Network structure of Inception-v3 requiring fine-tune

### 3 实验分析

本文使用在某钢厂中厚板生产线收集的 240 幅含有翘皮、横向裂纹、纵向裂纹缺陷的图像进行了实验,以验证 BING 算法提取 ROI 的快速性和准确性。

#### 3.1 训练参数介绍在线检测效果分析

为了训练针对中厚板缺陷的 BING 模型,预先标注了 586 幅中厚板图像,将无缺陷图像随机分块作为负样本,在标注框附近采样得到多个缺陷图像,连同其水平翻转作为正样本。基于标注框位置采样得到的图像归类为正样本的依据是:采样图像与标注框的覆盖率 (overlap) 大于 0.6 及为缺陷样本图像。其中 overlap 的定义如式 (6) 所示。

$$\text{overlap} = \frac{B_T \cap B_H}{B_T \cup B_H} \quad (6)$$

式中,  $B_T$  表示标注矩形框的面积 (True Bounding Box);  $B_H$  表示采样得到的窗口面积 (Hypothesized Bounding Box)。在训练阶段,通过统计 36 种尺度下的  $\{(w, h)\}$ , 其中  $(w, h) \in \{16, 32, 64, 128, 256, 512\}$  为正样本的数量。根据缺陷训练样本种类及数量, BING 模型最终保留了 5 种尺度  $\{(128, 128), (128, 256), (256, 256), (256, 512), (512, 512)\}$  用于在线检测。同时使用中厚板表面缺陷数据集训练了 inception-v3 网络模型,并选用测试集准确率 99.7%、验证集准确率 95.3% 的模型用于在线识别缺陷 ROI。

#### 3.2 在线检测效果分析

在线检测过程中,通过调节每个尺度保留的感兴趣窗口数  $M$  来控制 BING 生成的 ROI 总数  $T$ ,再取按得分排序的前  $N$  个候选窗口用于后续缺陷识别,从而保证缺陷检出的准确性及后续 CNN 识别的效率。本文对大小为  $3733 \times 1024$  的钢板区域进行测试,对比分析了 BING 与传统的滑动窗口在生成候选窗口数量上的优势。实验中  $M$  值的设置与候选窗口的总量关系见表 1。同时,根据 BING 的窗口尺度,实验测试了滑动窗口 ROI 提取方式生成的候选窗口数量,其中窗口尺度为上述 5 种,每个尺度的横纵向滑动步距设为  $0.1 \times w$ 、 $0.1 \times h$ 。

表 1 候选窗口数量对比

Tab.1 Comparison of candidate window number

	Candidate window extraction based on BING				Candidate window extraction based on sliding window
$M$	50	100	150	200	
Number of windows ( $T$ )	250	455	634	784	40 785

由表 1 可见,在保证缺陷区域检测的前提下,BING 大大减少了候选窗口的数量,比滑动窗口遍历方式少 2 个数量级,有效减少了后续识别模块的计算量。

实验对 240 幅图像进行了 ROI 提取,同时使用卷积神经网络进行了识别,以辅助展示实验效果。实验中,将  $M$  值设置为 100,同时取得分较高的前 100 个候选窗口进行识别,最终效果示例如图 5 所示。

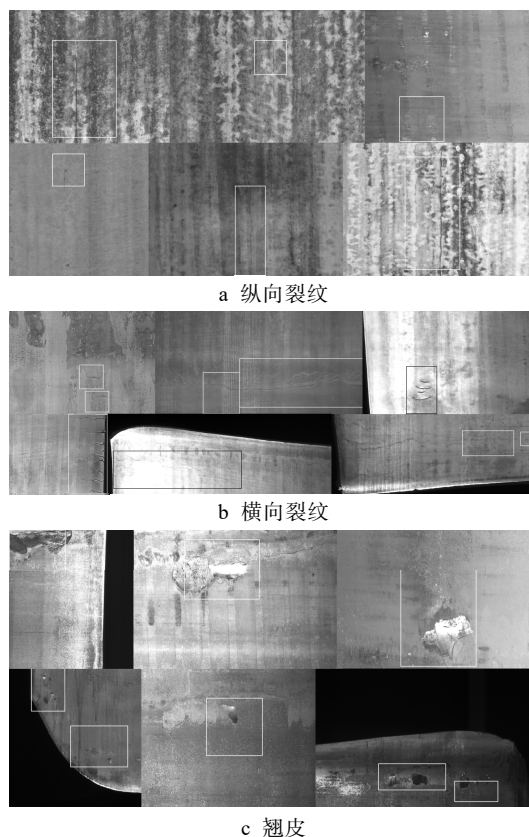


图 5 缺陷检出效果示例

Fig.5 Examples of defect detection effects:  
a) Longitudinal crack; b) Transverse crack; c) Surface upwarping

由图 5 可见，BING 算法能够在各种背景复杂的钢板图像中提取出缺陷窗口，缺陷召回率能够达到 92%。保留窗口数量与缺陷召回率的关系见表 2，随着送入识别模块窗口数量的增加，BING 算法对缺陷的召回率显著提升。

表 2 保留窗口数量与缺陷召回率关系  
Tab.2 Relationship between the number of reserved windows and defect recall rate

Number of reserved windows	100	200	300	400	500
Defect recall rate/%	92	94.5	96.4	97.2	98.2

本实验中，BING 算法在 CPU 为 Interl Core i5 处理器，主频为 2.4 GHz，内存为 8 GB 的计算机上运行。实验将图像归一化为 1024\*800，进行 BING 训练和预测，BING 算法能够达到 18 fps 的平均处理速率。

4 结论

- 1) BING 算法很大程度上减少了候选窗口的数量，比滑动窗口遍历方式少 2 个数量级，有效减少了后续识别模块的计算量。
- 2) BING 算法能够在各种背景复杂的钢板图像中提取出缺陷窗口，在缺陷窗口为 500 的情况下，缺陷召回率能够达到 98.2%。
- 3) 对 1024\*800 的中厚板图像，BING 算法能够达到 18 fps 的平均处理速率。有效减少了后续识别模块的计算量，有利于引入复杂的分类器最终显著提升中厚板缺陷检出识别效果。

参考文献：

[1] 安宗权, 王匀. 一种非线性扩散与图像差分的金属表面缺陷检测方法[J]. 表面技术, 2018, 47(6): 289-295.  
AN Zong-quan, WANG Yun. A metal surface defect detection method based on nonlinear diffusion and image difference[J]. Surface technology, 2018, 47(6): 289-295.

[2] 闵永智, 岳彪, 马宏锋, 等. 基于图像灰度梯度特征的钢轨表面缺陷检测[J]. 仪器仪表学报, 2018, 39(4): 220-229.  
MIN Yong-zhi, YUE Biao, MA Hong-feng, et al. Rail surface defects detection based on gray scale gradient characteristics of image[J]. Chinese journal of scientific instrument, 2018, 39(4): 220-229.

[3] 陈海永, 徐森, 刘坤, 等. 基于谱残差视觉显著性的带钢表面缺陷检测[J]. 光学精密工程, 2016, 24(10): 2572-2580.  
CHEN Hai-yong, XU Sen, LIU Kun, et al. Surface defect detection of steel strip based on spectral residual visual saliency[J]. Optics and precision engineering, 2016, 24(10): 2572-2580.

[4] 吴贵芳, 徐科, 徐金梧, 等. 形态小波在中厚板表面裂纹缺陷检测中的应用[J]. 北京科技大学学报, 2006, 28(6): 591-594.

WU Gui-fang, XU Ke, XU Jin-wu, et al. Application of morphological wavelet in surface crack defect detection of medium plates[J]. Journal of University of Science and Technology Beijing, 2006, 28(6): 591-594.

[5] 周鹏, 徐科, 杨朝霖. 基于 SIFT 的中厚板表面缺陷识别方法[J]. 清华大学学报(自然科学版), 2018, 58(10): 881-887.  
ZHOU Peng, XU Ke, YANG Chao-lin. Surface defect recognition for moderately thick plates based on a SIFT operator[J]. Journal of Qinghua University (natural science edition), 2018, 58(10): 881-887.

[6] LOWE D G. Object recognition from local scale-invariant features[C]// International conference on computer vision. Greece: IEEE computer society, 1999.

[7] 贺笛, 徐科, 孙金胜. 深度学习在中厚板表面缺陷识别中的应用[C]// 第十一届中国钢铁年会论文集—S18. 冶金自动化与智能管控. 北京: 冶金工业出版社, 2017.  
HE Di, XU Ke, SUN Jin-sheng. Application of deep learning to surface defect recognition of medium and heavy plates[C]// Papers collection of the eleventh China iron and steel annual conference—S18. Metallurgical automation and intelligent control. Beijing: Metallurgical Industry Press, 2017.

[8] UIJLINGS J R R, VAN De Sande K E A, GEVERS T, et al. Selective search for object recognition[J]. International journal of computer vision, 2013, 104(2): 154-171.

[9] 李文峰, 徐科, 杨朝霖, 等. 中厚板表面缺陷在线检测系统的分类器设计[J]. 钢铁, 2006, 41(4): 47-50.  
LI Wen-feng, XU Ke, YANG Chao-lin, et al. Classifier design of on-line surface defect inspection system for plates[J]. Iron and steel, 2006, 41(4): 47-50.

[10] CHENG M M, ZHANG Z, LIN W Y, et al. BING: Bin-arized normed gradients for objectness estimation at 300fps[C]// Computer vision and pattern recognition. Piscataway, NJ: IEEE, 2014: 3286-3293.

[11] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]// IEEE conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2016: 2818-2826.

[12] CORTES C, VAPNIK V. Support-vector networks[J]. Machine learning, 1995, 20(3): 273-297.

[13] NEUBECK A, GOOL L V. Efficient non-maximum suppression[C]// International conference on pattern recognition. Piscataway, NJ: IEEE, 2006: 850-855.

[14] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.

[15] XU G, ZHU X, FU D, et al. Automatic land cover classification of geo-tagged field photos by deep learning[J]. Environmental modelling & software, 2017, 91: 127-134.

[16] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// IEEE Conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2015: 1-9.

[17] DENG J, DONG W, SOCHER R, et al. Image Net: A large-scale hierarchical image database[C]// 2009 IEEE Conference on computer vision and pattern recognition. Piscataway, NJ: IEEE, 2009: 248-255.