

# 基于深度学习的钢板表面缺陷检测研究综述

廖晓群, 李 丹, 徐清钊

(西安科技大学 通信与信息工程学院, 西安 710600)

**摘要:** 钢板作为现代制造业的基石, 其表面质量对产品的性能和可靠性具有决定性作用; 因此, 钢板表面缺陷检测具有重要的研究意义和应用价值; 钢板表面缺陷检测研究面临的主要挑战包括钢板表面缺陷类型多样、特征不明显以及实时性要求高; 采用深度学习技术对钢板表面缺陷检测进行研究, 系统总结了钢板表面缺陷常用的数据集及目标检测算法在表面缺陷中的应用, 同时全面整理并分析了这些算法的优缺点; 探讨了有监督学习、无监督学习和半监督学习等检测方法在钢板表面缺陷检测中的应用, 评估了当前算法性能的关键指标, 讨论了未来钢板表面缺陷检测面临的挑战, 并对未来的研究趋势进行了展望。

**关键词:** 深度学习; 钢板表面缺陷; 目标检测; 表面缺陷; 评估指标

## Review of Steel Plate Surface Defect Detection Based on Deep Learning

LIAO Xiaoqun, LI Dan, XU Qingchuan

(School of Communication and Information Engineering, Xi'an University  
of Science and Technology, Xi'an 710600, China)

**Abstract:** As the cornerstone of modern manufacturing, the surface quality of steel plates plays a decisive role in the performance and reliability of products. Therefore, it is of great significance and application value to detect the surface defects of steel plates. the surface defect detection of steel plates has main challenges such as diversity of defect types, indistinct features, and high real-time performance. Deep learning technology is used to study surface defect detection of steel plates, this paper systematically summarizes commonly used datasets and target detection algorithms in surface defects of steel plates, comprehensively arranges and analyzes the advantages and disadvantages of these algorithms, explores the applications of supervised learning, unsupervised learning, and semi-supervised learning methods in steel plate surface defect detection, evaluates key indicators of current algorithms, discusses the challenges of steel plate surface defect detection, and prospects research trends in the future.

**Keywords:** deep learning; steel plate surface defect; object detection; surface defect; evaluation indicator

## 0 引言

钢板作为关键的制造原材料, 在交通运输、航空航天及石油化工等多个工业领域发挥着举足轻重的作用。但生产和运输过程中容易出现表面缺陷, 影响其抗腐蚀性、耐磨性及整体质量<sup>[1]</sup>。在“工业 4.0”和“中国制造 2025”等战略倡议的推动下, 我国制造业正面临着对产品质量、形态和美观性要求全面提升的挑战<sup>[2]</sup>。因此, 研究高效的钢板表面缺陷检测算法对提高生产效率和保证产品质量具有重要意义。

钢板表面缺陷检测历史悠久。然而, 由于缺陷类型多样、特征不明显, 尤其是小目标缺陷的检测难度大, 且实时性要求高, 导致整个检测过程颇具挑战性。传统的人工检测方法不仅效率低, 还容易受到主观因素的影响, 难以满足现代工业的需求。尽管涡流检测、红外线检测、超声检测、渗透检测、漏磁检测法取得了一定的成就, 但其检测效率低、适用范围小, 且受制于成本、质量等因素影响, 在自动化和适用范围方面仍存在限制<sup>[3]</sup>。基于机器视觉的检测方法利用工业相机和图像算法检测缺陷, 但仍缺乏普适性和可移植性。传统的机器

收稿日期: 2024-05-17; 修回日期: 2024-07-03。

基金项目: 中国高校产学研创新基金(2021KSA05005)。

作者简介: 廖晓群(1969-), 男, 博士, 高级工程师, 硕士生导师。

通讯作者: 李 丹(2001-), 女, 硕士研究生。

引用格式: 廖晓群, 李 丹, 徐清钊. 基于深度学习的钢板表面缺陷检测研究综述[J]. 计算机测量与控制, 2025, 33(7): 1-10.

视觉检测流程如图 1 所示。




图 1 传统的机器视觉检测流程

随着计算机视觉技术的不断进步。许多研究人员将深度学习方法应用于表面缺陷检测，与传统机器视觉方法相比，深度学习可以提取更深、更抽象的图像特征，通过卷积和池化等操作，具有更强大的表征能力，无需人工设计特征提取规则，实现端到端的模型设计。本文对基于深度学习的钢板表面缺陷算法进行了全面梳理。

## 1 国内外研究现状

近年来，国内在基于深度学习的钢板表面缺陷检测领域取得了显著进展。研究主要集中在模型创新及工业应用等方面。文献 [4] 提出了 MFE-CasMVSNet 网络用于钢板表面缺陷检测。该方法结合点云处理技术，通过 PFEM 和 MFAFM 模块提高三维重建精度和信息提取能力，并提出 CS-DBSCAN 实现缺陷精确识别和三维检测框可视化。在 NEU 数据集上的识别率达 95%，显著提升检测和分类性能，为钢铁生产质量控制提供了有效的解决方案。文献 [5] 提出了 YOLO-VDCW，一种轻量化的带钢表面缺陷检测算法。该算法在 YOLOv8 基础上引入 Vanillanet、C2fDSCConv 模块和坐标注意力机制，并使用 Wise-IoU 损失函数。在 NEU-DET 数据集上的实验结果显示，YOLO-VDCW 的平均检测精度达 79.8%，计算量和参数量分别减少 34.1% 和 36.8%，检测速度提升 37.9%，显著提高了检测精度和速度，适用于实际工业生产中的缺陷检测任务。

在国外，基于深度学习的钢板表面缺陷检测技术同样发展迅速，研究主要集中在数据集构建、模型优化及智能化应用等方面。为了研究钢板表面缺陷检测任务，文献 [6] 对 NEU-CLS 数据集进行了升级，为图像中的所有缺陷添加了缺陷类别和位置边界框的标注，并公开了升级之后的数据集 NEU-DET，为后续深度学习模型的训练和验证提供了丰富的数据资源。文献 [7] 在模型优化创新方面取得了显著成果，通过结合 NEU-DET 数据集和自采数据，构建了一个涵盖多种缺陷类型的丰富数据集，并提出了改进的多尺度 Retinex 图像增强算法和优化的轻量级 YOLOv5 模型，以提高工业检测的精度和实时性能。文献 [8] 提出了一种结合视觉词袋 (BoVW) 和 BRISK 特征检测器的钢板表面缺陷检测方法，利用支持向量机 (SVM) 分类，该方法在 NEU 表面缺陷数据集上的识别率达 95.00%，在保持较低计算复杂度的同时显著提高了分类准确性和效率，为钢铁生产中的质量控制提供了有效的解决方案，

并且推动了智能应用的发展。文献 [9] 提出了一种多尺度轻量级神经网络模型 (MM)，以融合编码模块为核心，通过高斯差分金字塔构建多尺度网络，提高模式捕捉能力，达到 98.06% 的缺陷分类准确率。相比 ResNet-50、ResNet-101、VGG、AlexNet、MobileNetV2、MobileNetV3 等，MM 模型减少了参数和模型大小，同时显著提升了分类精度。

综上所述，近五年来，国内外在基于深度学习的钢板表面缺陷检测领域取得了显著进展。随着深度学习技术的不断进步和工业应用需求的日益增加，钢板表面缺陷检测技术将变得更加智能化和高效化，从而为制造业的高质量发展提供强有力的支持。

## 2 钢板表面缺陷类型和数据集

### 2.1 钢板表面缺陷类型

#### 2.1.1 斑块

呈现为疤痕状或者点状的不规则斑块，颜色通常为黑色或者黄色，通常在钢板中部或者边缘。这些斑块主要由于钢铁在加热和轧制的时候与空气中的气体反应生成黄色氯化亚铁，退火时铁的化合物还原成黑色铁粉。

#### 2.1.2 氧化皮

氧化铁皮附着在钢铁表面，呈现鱼鳞状、块状或点状。钢铁在加热过程中没有及时将氧化铁皮清理干净是形成氧化皮的主要原因。

#### 2.1.3 裂纹

中心位置向四周开裂，呈蛛网状，严重时呈放射状开裂。加热过程中，温度过高时进行形变导致钢表面产生裂纹。

#### 2.1.4 划痕

形状为竖状条形，区域大小以及深度不规则，有灰白色金属光泽。其形成原因主要是钢板加工过程中机器发摩擦或者轧件刮伤钢板表面。

#### 2.1.5 表面点蚀

连续块状或点状的粗糙表面，呈橘皮状，不均匀地分布于钢板表面。形成原因是氧化铁皮与高温的轧辊触时会形成点蚀。

#### 2.1.6 夹杂物

形状不规则的非金属杂质，通常呈点状、块状或条状，常见于钢铁的破裂区域，颜色各异。其形成的主要原因是在轧制过程中，非金属物质脱落到钢板表面。

### 2.2 钢板表面缺陷数据集

数据集在计算机视觉领域具有至关重要的地位。它不仅为算法提供训练和测试数据，还直接影响算法的性能和泛化能力。在钢表面缺陷检测中，高质量且多样化的数据集对算法的训练和优化尤为关键。随着工业制造技术的进步，缺陷产品的数量逐渐减少，使得收集和构

建高质量数据集变得更加困难, 对数据样本进行精确和详细的标注是一个耗时且劳动密集的过程。为了促进研究者在钢表面缺陷识别领域的研究, 本文总结了常用的公开可用的钢板表面缺陷数据集。

NEU 数据集, 共包含 1 800 张灰度图片, 分为 6 类缺陷, 如图 2 所示。该数据集有 NEU-CLS 和 NEU-DET 两个版本, 前者用于分类, 后者用于目标检测, 图片尺寸均为  $200\times200$ 。




图 2 NEU 数据集示例

Severstal 钢材数据集, 该数据集由 Severstal 钢铁公司所提供的, 其中涵盖了 4 种不同的带钢表面缺陷类型, 如图 3 所示。该数据集包含了丰富的图像数据, 12 568张训练集图片和 5 506 张测试集图片。这些图片的尺寸统一为  $1\,600\times256$  像素, 清晰展示了带钢表面的各种缺陷情况, 为相关研究和应用提供了宝贵的数据资源。

3 目标检测算法在表面缺陷的应用

目标检测, 作为计算机视觉领域的核心任务, 致力于在图像中精准定位和识别特定类别的对象。得益于卷积神经网络的迅猛进步, 目标检测算法在表面缺陷检测领域得到了广泛应用。图 4 为目标检测算法的发展历程, 清晰地呈现了算法技术的演进脉络。基于深度学习



图 3 Severstal 钢材数据集示例

的目标检测算法主要分为两大类: 一是基于区域的双阶段目标检测算法, 如 R-CNN<sup>[10]</sup>、Fast R-CNN<sup>[11]</sup>、Faster R-CNN<sup>[12]</sup> 和 Mask R-CNN<sup>[13]</sup> 等; 另一类是基于回归的单阶段目标检测算法, 如 YOLO<sup>[14]</sup> 和 SSD<sup>[15]</sup> 等。这两类算法分别体现了研究人员在追求高精度检测与提升检测速度方面的不懈探索与实践<sup>[16]</sup>。表 1 详细概括了目标检测网络模型的优缺点。

3.1 单阶段方法

在表面缺陷检测领域, 诸如 YOLO<sup>[14]</sup>、SSD<sup>[15]</sup>、RetinaNet<sup>[17]</sup>、EfficientDet<sup>[18]</sup> 等单阶段方法逐渐成为研究和应用的热点。相较于传统的双阶段方法, 单阶段方法通常具备更简单的架构和更高的处理速度, 在多个应用场景中展现出独特的优势。进一步的研究和优化使得单阶段方法在近年来取得了显著进展。单阶段方法在处理多尺度和复杂场景下表现出色, 例如, SSD 通过多层特征图捕获不同尺度的目标, 有效应对表面缺陷的大小和形状多样性。此外, RetinaNet 引入的特征金字塔网络 (FPN) 结构, 允许网络在多个尺度上进行特征提取, 从而提高了小目标检测的准确性, 并通过焦点损失优化技术解决了样本不平衡的问题<sup>[19]</sup>。在 2022 年, 一项研究进一步改进了 RetinaNet, 增加了 FPN 的深度, 结合细节信息增强、特征信息优化和语义信息增强结构, 充分利用图像信息, 提高分类能力, 最终实现了




图 4 目标检测算法发展历程

表 1 目标检测网络模型的优缺点

| 模型            | 类别 | 年份   | 网络框架         | 模型优点                         | 模型缺点               |
|---------------|----|------|--------------|------------------------------|--------------------|
| RCNN          | 双  | 2014 | AlexNet      | 引入候选区域和 CNN 网络，提出了双阶段目标检测新模型 | 模型复杂度高，训练速度慢且效率低   |
| SPP-Net       | 双  | 2014 | ZFNet        | 输入图像可以实现多尺度                  | 网络不能反向传播更新卷积层参数    |
| Fast RCNN     | 双  | 2015 | VGG          | 提出 ROI Pooling 池化层           | 无法满足实时应用           |
| Faster RCNN   | 双  | 2015 | VGG          | 提高了检测精度和速度，对小目标检测效果较好        | 无法满足实时应用           |
| Yolov1        | 单  | 2016 | 24-layer 卷积层 | 提出单阶段目标检测新模型                 | 对小目标和形状奇的缺陷检测率较低   |
| SSD           | 双  | 2016 | VGG          | 精度较高，速度较快                    | 难以检测小目标缺陷          |
| Mask R-CNN    | 双  | 2017 | ResNet       | 高精度的实例分割                     | 模型复杂，计算资源需求高       |
| RetinaNet     | 单  | 2017 | FPN          | 提高了单阶段目标检测器的精度               | 解决了正负样本不平衡问题       |
| Yolov2        | 单  | 2017 | DarkNet-19   | 使用先验框、特征融合等方法，检测效率提升         | 计算复杂，难以检测小目标缺陷     |
| Yolov3        | 单  | 2018 | DarkNet-53   | 独立的逻辑回归支持多标签预测               | 召回率较低，遮挡与拥挤情况检测率较低 |
| Cascade R-CNN | 双  | 2018 | RPN          | 高准确率，多阶段优化                   | 计算复杂，难以检测小目标缺陷     |
| Yolov4        | 单  | 2020 | CSPDarkNet   | 融合多种方法、模型，检测效率较高             | 预测框误检率高            |
| EfficientDet  | 单  | 2020 | BiFPN        | 高效且精度高                       | 适用于资源受限的环境         |
| Yolov5        | 单  | 2020 | CSPDarkNet   | 增加网络的深度和宽度，                  | 难以检测小目标缺陷          |
| Yolov7        | 单  | 2022 | CBS LAN MP-1 | 可以进行实时目标检测                   | 网络架构相对复杂，难以检测小目标缺陷 |
| Yolov8        | 单  | 2023 | Darknet53    | 检测结果更高且更具有灵活性                | 模型较复杂，需要较大的计算资源和时间 |
| Yolov9        | 单  | 2024 | GELAN        | 创新性的架构使得模型能够更高效地利用参数         | ——                 |

99.73%的高准确率<sup>[20]</sup>。此外，一种新的分流特征融合模型（ST-YOLO）被提出，该模型采用分割特征网络结构和自我校正传输分配方法，优化了分类和定位任务的处理，显著提高了检测速度<sup>[21]</sup>。还有研究改进了 EfficientDet 算法，使其检测准确率比现有最优算法高出 4 个百分点<sup>[22]</sup>，这些改进不仅提升了算法的性能，也为实际工业应用中的表面缺陷检测提供了更可靠和高效的解决方案。综上所述，单阶段方法在表面缺陷检测领域的应用正日益受到重视和广泛探索。通过持续的算法优化和网络结构创新，这些方法不仅提升了检测的准确性和效率，也为未来工业质量控制和自动化检测提供了坚实的技术基础。

3.2 双阶段方法

在表面缺陷检测领域，双阶段方法如 RCNN<sup>[10]</sup>、SPPNet<sup>[23]</sup>、Fast RCNN<sup>[11]</sup>、Faster RCNN<sup>[12]</sup>和 Cascade RCNN<sup>[24]</sup>等经典算法，因其较高的检测精度和鲁棒性而得到广泛应用。双阶段方法通过分阶段处理目标检测任务，分别提取特征和进行检测，有效应对了复杂的表面缺陷检测场景。基于 Faster R-CNN 的改进方法引入了加权 ROI 池、基于特征金字塔网络（FPN）的多尺度特征提取，以及严格的非极大值抑制（NMS）策略，显著提升了缺陷识别的准确性，这些技术优化使得算法能够更精准地定位和识别表面缺陷，适用于对高精度检测要求的工业应用场景<sup>[25]</sup>。有研究者提出了一种利用知识蒸馏训练 ResNet50 网络的新方法，将 KD-ResNet50 替代 VGG16 作为骨干网络，不仅提高了检测速

度，还比传统的 SSD 模型提升了性能，这种方法利用了知识蒸馏技术，通过从一个更强大的网络中提取和传递知识，显著提升了模型在复杂场景下的表现能力，能够满足工业实时检测的需求<sup>[26]</sup>。一种改进的 Faster RCNN 钢表面缺陷检测模型展示了其在实际任务中的显著效果和优势。该模型通过将 ResNet50 替换为 RegNet 网络，优化了基础网络结构，提升了性能。同时，引入了变压器空间注意力机制，增强了模型对目标缺陷的关注度，并采用了迁移学习和多尺度训练策略，进一步提高了检测精度。这些技术创新有效地解决了传统模型在复杂背景和小目标检测上的局限性，为表面缺陷检测的精准度和实用性带来了重要提升<sup>[27]</sup>。还有研究者为解决钢表面缺陷的不规则形状和密集分布而设计了一种新型的深度神经网络一级联自适应全局定位网络（CAGLNet），CAGLNet 结合残差和特征金字塔网络进行特征提取，采用 CAT-RPN 进行区域建议，使用全局局部回归模型进行缺陷检测，显著提升了检测效率<sup>[28]</sup>。

Faster RCNN 算法优化了候选框的生成过程在计算资源上的消耗。该算法的创新之处在于引入 RPN（Region Proposal Network），大幅减少了候选框的数量，提升了检测速度。Faster RCNN 的结构实质上是 RPN 与 Fast RCNN 的有机结合。该算法的实现步骤时，首先输入任意尺寸的图片，通过卷积神经网络进行特征提取，生成特征图。特征图与预选的候选区域一并送入 ROI 池化层，该层对特征图内各个候选框实施标准化操作。最后经过全连接层得到固定大小的特征向量，为后

续的物体分类和位置回归提供了基础数据。图 5 为 Faster RCNN 的网络结构。




图 5 Faster RCNN 网络结构

综上所述，双阶段方法在表面缺陷检测中的应用不断演进和完善，通过技术创新和算法优化，不仅提高了检测精度和速度，还增强了模型的实用性和适用性。这些研究成果为工业制造和质量控制领域带来了深远的影响，预示着未来表面缺陷检测技术将继续向前发展，应用范围也将不断扩展。

4 基于深度学习的钢板表面缺陷检测算法

深度学习相较于传统的机器学习展现出了更强大的表征学习能力，不需要依赖人工设计的特征提取规则，就能实现端到端的模型构建。卷积神经网络（CNN）<sup>[29]</sup>通过卷积和池化等操作，能够提取图像中的深层和抽象特征，进而捕获不同层次的语义信息，从而增强了模型的泛化能力。随着深度学习的迅速发展，其在表面缺陷检测领域的应用也日益广泛，不仅提高了检测精度和效率，还为自动化和智能化缺陷检测系统的实现提供了强大支持。其逐步取代传统方法，成为处理复杂和大规模数据集的首选方案，推动了整个行业向前发展。本节围绕深度学习的 3 种常见分类，有监督方法、无监督方法和半监督方法，对钢板表面缺陷检测进行介绍。基于深度学习的钢板表面缺陷检测方法的详细分类如图 6 所示。

4.1 有监督模型

深度学习的有监督方法需要标记良好的训练集和测试集来验证其性能，有监督方法通常比其他类型的方法更稳定、更准确。然而，训练集的质量直接影响算法的性能，在真实的工业缺陷检测场景中，很难生成标记良好的大型数据集。

基于 SqueezeNet 提出了一种轻量级卷积神经网络（CNN）模型，强调底层特征的学习并结合 MRF 模块，只需要少量的缺陷训练样本实现了准确的缺陷识别<sup>[30]</sup>。该模型能够满足实时在线检测的要求，运行速度超过了 100 fps。另一项研究提出了一种创新的分类优先网络（CPN）方法，并设计了专用于钢板表面缺陷分类的新型网络 MG-CNN，利用多组卷积神经网络（MG-CNN）对图像进行深度处理，精准地提取各种缺陷特征，基于




图 6 基于深度学习钢板表面缺陷检测方法详细分类图

这些分类结果，含有潜在缺陷的特征会被独立送入 YOLO 框架的神经网络中，实现对缺陷边界框的精确识别与定位<sup>[31]</sup>。在热轧钢表面缺陷检测的实际应用中，该方法展现出了卓越的性能，其平均检测率超过 94%，缺陷分类的准确率更是高达 96% 以上<sup>[31]</sup>。这些数据充分证明了该方法在钢板表面缺陷检测领域的有效性，展示了其在实际应用中的重要突破。

通过实验验证，预训练模型 ResNet50 是钢表面缺陷检测的分类网络的优选方案，一种能够自动识别并分类轧制金属表面缺陷的技术应运而生。为应对数据样本不平衡问题，该技术采用了二元焦点损失，显著提升了钢材表面缺陷的识别能力<sup>[32]</sup>。运用一级检测器 RetinaNet 模型进行钢材缺陷检测，通过对比分析 ResNet50 和 VGG19 两个主干网络，发现该模型在 NEU 数据集上取得了显著效果<sup>[33]</sup>。针对密集工件漏检率高的挑战，研究者提出了基于改进 SSD 的目标检测模型，通过融入 RFB 感受野模块、采用 PReLU 替代传统 ReLU 以及优化 CIoU 损失函数等改进措施，显著提高了特征提取能力，较原有 SSD 模型提升了 4.42% 的精度<sup>[34]</sup>。进一步的改进研究中，YOLOv5s 算法利用基于交并比（IoU）的 K-means 聚类方法重新对钢铁数据集进行分组，获取多组锚框，并在 Mosaic 上融入 MixUp，引入注意力模块，加强网络的特征提取能力，针对难以识别的样本，采用了 Focal loss，加快了网络的训练速度并提高检测的准确性，这一改进较原有 YOLOv5s 模型提高了 3% 的精度<sup>[35]</sup>。随后，基于轻量化 YOLOv8 的小样本钢板缺陷检测算法利用模糊搜索的数据增强算法解决了训练样本不足的问题，设计的 LMSRNet 网络提高了可移植性，并引入 CBFPN 和 ECSA 模块优化特征提取与融合，同时采用 Wise-IoU 损失函数提升检测性能。实验结果表明，该改进算法大幅减少了参数和计算量，

提高了 FPS, 显著提升了精确率、召回率和  $mAP$ , 充分验证了其优势<sup>[36]</sup>。YOLOv8 模型由输入 (Input)、骨干 (Backbone) 网络、颈部 (Neck) 模块和头部 (Head) 模块 4 个主要部分组成。

#### 1) Backbone 模块:

YOLOv8 的骨干网络架构使用的依旧是 CSPDarknet 思想, 将 C3 模块替换成了 C2f 模块, C2f 模块融合了 C3 和 ELAN 模块的理念, 还引入了更多的跨层连接, 从而在梯度反向传播时提供更丰富的梯度流信息。图 7 为 ELAN 模块的结构图。




图 7 ELAN 模块的结构

该模块巧妙地融合了 C3 模块与 ELAN 模块的核心思想, 采用梯度分流的理念对原本串联的 Bottleneck 模块进行重新连接。这种优化后的模块结构有效地缓解了深度网络在训练过程中可能出现的收敛性恶化问题, 确保了梯度流信息的丰富性, 使其在目标检测任务中展现出更为优越的表现。

#### 2) Neck 模块:

YOLOv8 在构建特征金字塔时, 选用了 FPN 与 PAN 相结合的结构, 以确保多尺度信息能够实现全面且有效的融合。与 YOLOv 的 FPN-PAN 结构相比, 除了将原有的 C3 模块替换为新型的 C2f 模块外, 其余部分的设计思路基本保持一致。这种改进不仅提升了特征提取的能力, 还进一步增强了模型对多尺度目标的检测性能。

#### 3) Head 模块:

YOLOv8 延续了解耦头 (Decoupled Head) 的概念这一创新, 同样采用解耦头的结构, 并且实现了从基于锚点 (Anchor-Based) 到无锚

点 (Anchor-Free) 的转变。这种设计不仅提高了模型的灵活性, 还有助于更准确地处理不同尺度和类别的目标, YOLOv8 网络结构如图 8 所示。

#### 4.2 无监督模型

无监督学习方法与有监督学习方法不同, 不需标签数据, 仅需无缺陷样本进行训练, 有效解决了有监督学习中标记困难的问题, 但相较于有监督方法, 无监督方法的缺陷检测精度通常稍低。在深度学习中, 利用未标记图像进行的钢板表面缺陷无监督学习常称为聚类, 旨在识别具有相似特性的样本组。缺陷检测采用基于像素的聚类方法探索纹理图像的潜在信息, 再利用多分类技术具体识别缺陷。常见的无监督方法包括生成对抗网络、深度置信网络、自动编码器等。

为消除伪缺陷的干扰, 有研究引入了各向异性扩散模型, 提出了一种新颖的 HWV 无监督模型, 用于描述图像中每个局部块的纹理分布特性, 最终通过自适应阈值技术, 实现了缺陷与背景的精确分割<sup>[37]</sup>。另一项研究提出了一种基于生成对抗网络的钢表面缺陷检测方法, 利用编解码器作为生成器, 通过对图像进行编码, 获取其隐藏空间特征, 并将生成器的第二层输出作为关键特征信息, 进一步输入到支持向量机中进行缺陷的精准分类, 该模型在实际数据集上测试后, 取得了令人满意的结果, 展示了其在钢表面缺陷检测方面的有效性和实用性<sup>[38]</sup>。此外, 还有研究开发了一种基于自编码器的深度学习模型, 专门用于钢表面缺陷分布图像的聚类任务。通过使用人工生成的数据集和真实的缺陷分布数




图 8 YOLOv8 网络结构图

数据集进行测试, 结果表明该模型能够准确识别和区分人工生成的缺陷分布, 并且不受缺陷堆积位置的影响, 在真实表面缺陷分布的情况下, 该算法的平均聚类准确率高达 98.97%, 显示出其强大的应用潜力<sup>[39]</sup>。

4.3 半监督模型

半监督学习方法在有监督和无监督方法之间架起了桥梁, 能够自动生成未标记样本数据, 提高模型的学习效果。这些方法通过充分利用未标记数据的信息, 提升了模型的检测能力, 目前在钢板表面缺陷检测中, 常见的半监督方法包括不完全监督法和不准确监督法。

不完全监督法是指在训练过程中, 仅有少量样本数据被赋予标签, 而大部分样本数据则未被标记。然而, 由于标记样本的数量有限, 往往难以支撑训练出一个性能卓越的模型。因此, 在不完全监督学习的情境下, 需要更加深入地研究如何利用未标记数据与有限的标记数据相结合, 以优化模型的训练效果。

一些研究提出了创新方法。例如, 一种改进的卷积神经网络 PLCNN 通过使用伪标签, 能够在训练过程中利用未标记数据, 与传统方法相比, 显著提升了模型性能<sup>[40]</sup>。另外, 一种基于残差网络的深度卷积神经网络, 通过堆叠两层残差模块, 构建了包含 43 层的结构, 研究者适当增加了网络的宽度, 平衡了网络的深度和宽度, 进一步提高了准确率, 这种创新性网络在多个数据集上展示了卓越性能, 证明了其在实际应用中的价值<sup>[41]</sup>。此外, 结合卷积自编码器 (CAE) 与生成对抗网络 (GAN) 的方法也被提出用于半监督学习, 充分利用未标记数据进行训练, 增强了模型在处理未标记数据时的鲁棒性和性能表现<sup>[42]</sup>。在实验中, 这些方法在不同数据集上显示了显著优势, 为半监督学习领域带来了新的思路和方法。

另一项创新工作结合了样本生成与半监督学习技术, 通过 CDCGAN 和 ResNet18 分类器, 在 NEU 数据集上进行对比实验, 显示出比传统监督学习和迁移学习方法更优越的性能, 为钢表面缺陷检测领域带来了新的突破<sup>[43]</sup>。同时, 采用类激活映射模型的缺陷检测网络, 通过少量图像级标签进行训练, 提高了检测精度和目标区域识别准确性<sup>[44]</sup>。该网络采用高效的残差网络作为主干进行特征提取, 并引入多层次特征融合网络生成类激活图, 从而提高了检测精度和目标区域的识别准确性。

在处理缺陷样本时, 首先将其输入到主干卷积神经网络 (CNN) 中, CNN 会在其各层级结构中提取出各种特征图。这些特征图在空间尺寸、维度和特性方面存在显著差异。为了综合不同层级的特征信息, 引入了一个多层次特征融合网络。这个网络的作用是将来自 CNN 各层级的特征图进行统一处理, 确保它们具有一

致的空间尺寸和维度<sup>[44]</sup>。然后, 将处理后的特征图依次连接, 构建出融合了多层特性的复合特征。接下来, 通过全局平均池化 (GAP) 技术, 将这些多层次特征转化为特征向量。完成这一步骤后, 特征向量被送入 CNN 的分类输出层, 计算得出缺陷的具体分类结果。

为了实现对缺陷位置的精确定位, 根据 CNN 的分类结果, 将输出层的权重参数进行反向映射, 并借助类激活图 (CAM) 模型, 生成能够凸显目标区域的类激活图, 以此精确地框选出缺陷的位置。整个网络如图 9 所示, 是由主干 CNN<sup>[29]</sup> 网络、多层次特征融合网络和类激活映射模型三部分组成。




图 9 弱监督缺陷检测网络

在整个处理流程中, 模型的训练完全依赖于仅带有图像级标签的样本。这种方式实现了基于 CNN 特征辨别力的弱监督缺陷检测。该方法不仅能够有效地利用有限的标注数据, 还能在保持较高检测精度的同时, 简化对数据的标注过程, 提高钢板缺陷的检测效率。

不准确监督法能够容忍一定程度的标签噪声, 并通过算法设计来减少不正确标签对模型性能的影响, 从而增强模型的鲁棒性和稳定性。此方法主要关注监控信息的存在, 但这些信息并不精确, 即仅包含粗粒度标签。相比于像素级标签, 图像级标签被视为一种粗粒度标签。

一种创新的钢材表面缺陷检测弱监督学习 (WSL) 框架由定位网络 (LNet) 和决策网络 (DNet) 组成<sup>[45]</sup>。LNet 通过利用图像级标签进行训练, 能够生成潜在缺陷位置的热图, 这些热图作为 DNet 的输入。DNet 采用创新的区域敏感注意力模块 (RSAM) 对 LNet 识别的区域进行加权处理, 以提高对缺陷区域的关注<sup>[45]</sup>。这一框架在实际工业数据集上的性能得到了充分验证, 显示出其在实际应用中的潜力。

虽然不准确监督法在表面缺陷检测领域的应用相对较少, 但由于具备有监督学习和无监督学习的双重优势, 该方法的潜在应用前景非常广泛。这些研究展示了半监督学习方法在钢板表面缺陷检测中的广泛应用和潜

力,为该领域的进一步发展提供了重要的实证和方法支持。

综上所述,有监督方法因其卓越的准确率而备受青睐,并在多个领域得到了广泛应用。然而,这种方法的局限性也不容忽视;无监督方法则顺应产业发展的趋势,展现出其独特的优势,但也存在其自身的特点与限制。相比之下,半监督方法虽然目前的应用尚不广泛,但随着研究的深入和技术的发展,展现出广阔的发展前景与潜力。总结来看,深度学习在表面缺陷检测中的 3 种方法的特点如表 2 所示。

表 2 深度学习方法特点总结

| 类别  | 优点       | 缺点       |
|-----|----------|----------|
| 有监督 | 高精度适用广   | 标记数据成本高  |
| 无监督 | 不需要标记数据  | 精度相对较高   |
| 半监督 | 可利用未标记数据 | 技术复杂、不稳定 |

## 5 评估指标

钢板缺陷检测算法的性能评估指标用于衡量设计的算法的效能,评估标准的选择应全面,因为不同的标准可能会呈现不同的结果。在钢铁缺陷检测领域,常用的算法性能评估指标可分为两类:精度类指标和效率类指标。

在钢板缺陷分类和定位任务中,精度类评估指标广泛用于衡量相关算法的准确性。如精度(PRE)、召回率(RECALL)、AP(平均精度)和 mAP(平均精度均值)等评估指标。通过这些指标,我们能够全面而准确地评估算法在缺陷检测任务中的性能。其中,PRE 表示正确预测的正样本数量与预测为正的样本数量的比例,是算法的分类精度,公式如下:

$$PRE = \frac{TP}{TP + FP} \quad (1)$$

更高的精度(PRE)意味着随机误差更小,方差也更小,表明预测结果的波动更小。召回率(RECALL)表示正确预测的正样本数量与实际正样本数量的比例,其公式如下:

$$RECALL = \frac{TP}{TP + FN} \quad (2)$$

更高的召回率(RECALL)值意味着算法更能有效地检测目标。

AP(平均精度)和 mAP(平均精度均值)这两个评估指标都是基于 PRE 和 RECALL 进行的计算。在计算 AP 时,通过计算 P-R 曲线下的面积来确定,该曲线是通过将 RECALL 值作为 X 轴,PRE 值作为 Y 轴来绘制的 PRE-RECALL 曲线。通过调整不同的置信度阈值,可以获得多组 PRE 和 RECALL 值的组合。一般来说,AP 的计算采用 11 点插值法,其具体计算公式

如下:

$$AP = \frac{1}{11} \times \sum_{i \in \{0,0.1,\dots,1\}} AP_r(i) \quad (3)$$

在计算了所有类别的 AP 后,可以使用以下公式计算所有类别的平均精度均值 mAP:

$$mAP = \frac{\sum_{i=1}^K i = 1AP_i}{K} \quad (4)$$

效率类指标是评估算法处理速度和计算复杂性的关键工具,对于确保算法在实际应用中快速、准确地识别缺陷具有重要意义。常用的效率类指标包括训练时长和测试时长、参数数量(Params)、推理时间(Inference Time)、FPS(Frames Per Second)和 FLOPs(Floating Point Operations)等。这些指标可以全面评估算法在钢板缺陷检测任务中的性能,为优化和改进算法提供重要的参考依据。

## 6 挑战与展望

随着钢板表面缺陷检测技术的应用与研究不断深入,其发展方向逐渐清晰。主要包括构建高质量且多样化的数据集、优化缺陷检测算法、提高检测精度、实现缺陷检测的工业应用等方面。钢板表面缺陷检测在深度学习领域面临诸多挑战,存在着许多问题亟待解决。以下总结了几个挑战供研究者参考。

1) 缺陷类型的多样性和复杂性极大地增加了模型的识别难度,缺陷形态各异且分布不均匀,从微小的点状缺陷到较大的块状缺陷,模型需要具备强大的多尺度感知能力来准确检测和分类。

2) 高质量且多样化的数据集稀缺是另一个重要挑战。采集和标注高分辨率图像数据既耗时又费力,且数据处理和存储成本高<sup>[46]</sup>。深度学习模型的训练通常依赖于大量有标签的数据,这种有监督的学习方式受限于样本数量,且标签标注过程需要人工参与,成本较高。无监督和半监督的学习方式无需大量数据标签,为钢板表面缺陷检测提供了新的发展方向,但这类数据集的获取依然是一个重大挑战。

3) 工业现场环境复杂多变,光照条件、摄像头角度和表面反光等因素都会影响图像质量,增加了检测的难度。深度学习模型通常需要大量计算资源和时间进行训练,如何在保证高精度的前提下提升训练和推理效率是另一大挑战。目前,缺乏统一的评价标准使得模型性能的评估存在困难,准确率和召回率等常用指标可能不能完全反映模型在实际应用中的表现。

综上,构建高质量的小样本缺陷数据集至关重要,有望突破监督学习的限制,提升检测准确性和效率。此外,建立客观准确的评价指标对于评估和比较不同缺陷检测模型的性能至关重要,是未来研究的重要方向。

在钢板表面缺陷检测领域,深度学习技术的不断进



步为研究者提供了强大的工具,促使他们在目标检测、缺陷分类等关键环节取得了显著进展。通过优化模型结构、提升数据质量和丰富数据集、改进训练方法和评价指标,可以进一步提升检测精度和效率,为钢板生产过程中的质量控制提供更加有效的解决方案。相信在不久的将来,随着深度学习技术的不断完善和发展,钢板表面缺陷检测将迎来更加精准和高效的解决方案,为钢铁制造业的发展提供重要支持。

## 7 结束语

综上所述,在深度学习技术快速发展的大背景下,钢板表面缺陷检测作为表面检测领域的主要研究方向之一,其核心目标是确保钢板产品质量和可靠性,提高生产效率,降低成本,满足市场需求。钢板表面缺陷检测是一个具有挑战性的领域,也是一个充满机遇的领域。本文通过综述近五年来的研究进展,总结了当前的研究现状和存在的问题,并展望了未来的研究方向。未来的工作应该聚焦于构建高质量数据集、优化算法提高检测精度、实现工业应用等方面。相信在学术界和工业界的共同努力下,钢板表面缺陷检测技术将迎来更加辉煌的发展。

### 参考文献:

- [1] WEN X, SHAN J, HE Y, et al. Steel surface defect recognition: A survey [J]. *Coatings*, 2022, 13 (1): 17 - 46.
- [2] KUMAR A. Computer-vision-based fabric defect detection: a survey [J]. *IEEE Transactions on Industrial Electronics*, 2008, 55 (1): 348 - 363.
- [3] LI L. The UAV intelligent inspection of transmission lines [C] // *Proceedings of the 2015 International Conference on Advances in Mechanical Engineering and Industrial Informatics*. Atlantis Press, 2015: 1542 - 1545.
- [4] 兰 欢, 余建波. 基于深度学习三维成型的钢板表面缺陷检测 [J]. *浙江大学学报 (工学版)*, 2023, 57 (3): 466 - 476.
- [5] 刘凤春, 张 靖, 薛 涛, 等. YOLO-VDCW: 一种新的轻量化带钢表面缺陷检测算法 [J/OL]. *中国冶金*, 1 - 13 [2024 - 06 - 20]. <https://doi.org/10.13228/j.boyuan.issn1006-9356.20240022>.
- [6] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features [J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 69 (4): 1493 - 1504.
- [7] YANG L, HUANG X, REN Y, et al. Steel plate surface defect detection based on dataset enhancement and lightweight convolution neural network [J]. *Machines*, 2022, 10 (7): 523 - 539.
- [8] IBRAHIM A A M S, TAPAMO J R. Steel surface defect detection and classification using bag of visual words with BRISK [C] // *Congress on Smart Computing Technologies*. Singapore: Springer Nature Singapore, 2022: 235 - 246.
- [9] SHAO Y, FAN S, SUN H, et al. Multi-Scale lightweight neural network for steel surface defect detection [J]. *Coatings*, 2023, 13 (7): 1202 - 1215.
- [10] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2014: 580 - 587.
- [11] GIRSHICK R. Fast r-cnn [C] // *Proceedings of the IEEE international conference on computer vision*. 2015: 1440 - 1448.
- [12] REN S, HE K, GIRSHICK R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks [J]. *Advances in Neural Information Processing Systems*, 2015, 28 - 36.
- [13] HE K, GKIOXARI G, DOLLÁR P, et al. Mask r-cnn [C] // *Proceedings of the IEEE International Conference on Computer Vision*. 2017: 2961 - 2969.
- [14] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 779 - 788.
- [15] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C] // *Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11 - 14, 2016, Proceedings, Part I 14*. Springer International Publishing, 2016: 21 - 37.
- [16] 李炳臻, 姜文志, 顾佼佼, 等. 基于卷积神经网络的目标检测算法综述 [J]. *计算机与数字工程*, 2022, 50 (5): 1010 - 1017.
- [17] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] // *Proceedings of the IEEE International Conference on Computer Vision*. 2017: 2980 - 2988.
- [18] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 10781 - 10790.
- [19] AKHYAR F, LIN C Y, MUCHTAR K, et al. High efficient single-stage steel surface defect detection [C] // *2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*. IEEE, 2019: 1 - 4.
- [20] ZHANG Y, GAO Y, SHEN L Y. Steel defect detection based on modified retinaNet [C] // *2022 26th Interna-*

- tional Conference on Pattern Recognition (ICPR), IEEE, 2022; 3572–3579.
- [21] MA H, ZHANG Z, ZHAO J. A novel ST-YOLO network for Steel-Surface-Defect detection [J]. Sensors, 2023, 23 (22): 9152–9169.
- [22] 杨连贺, 张超. 基于改进的 EfficientDet 的布匹疵点识别 [J]. 天津工业大学学报, 2023, 42 (4): 71–76.
- [23] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1904–1916.
- [24] CAI Z, VASCONCELOS N. Cascade r-cnn: Delving into high quality object detection [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6154–6162.
- [25] WEI R, SONG Y, ZHANG Y. Enhanced faster region convolutional neural networks for steel surface defect detection [J]. ISIJ International, 2020, 60 (3): 539–545.
- [26] LIU X, GAO J. Surface defect detection method of hot rolling strip based on improved SSD model [C] //Database Systems for Advanced Applications. DASFAA 2021 International Workshops: BDQM, GDMA, MLDLDSA, MobiSocial, and MUST, Taipei, Taiwan, April 11–14, 2021, Proceedings 26. Springer International Publishing, 2021: 209–222.
- [27] XU Y, YANG S, ZHANG X, et al. Steel surface defects detection based on improved faster R-CNN [C] //2022 4th International Conference on Control and Robotics (ICCR), IEEE, 2022: 353–357.
- [28] YU J, WANG Y, LI Q, et al. Cascaded adaptive global localisation network for steel defect detection [J]. International Journal of Production Research, 2023; 1–18.
- [29] 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.
- [30] FU G, SUN P, ZHU W, 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.
- [31] HE D, XU K, ZHOU P. Defect detection of hot rolled steels with a new object detection framework called classification priority network [J]. Computers & Industrial Engineering, 2019, 128: 290–297.
- [32] KONOVALENKO I, MARUSCHAK P, BREZINOVÁ J, et al. Steel surface defect classification using deep residual neural network [J]. Metals, 2020, 10 (6): 846–860.
- [33] SHARMA M, LIM J T, CHAE Y G. Steel surface defect detection using the retinaNet detection model [J]. International Journal of Internet, Broadcasting and Communication, 2022, 14 (2): 136–146.
- [34] 徐健, 陆珍, 刘秀平, 等. 基于改进 SSD 的密集工件检测 [J]. 组合机床与自动化加工技术, 2022, (11): 70–74.
- [35] 周彦, 孟江南, 吴佳, 等. 改进 YOLOv5s 的钢板表面缺陷检测算法 [J]. 激光与光电子学进展, 2023, 60 (4): 393–401.
- [36] 窦智, 高浩然, 刘国奇, 等. 轻量化 YOLOv8 的小样本钢板缺陷检测算法 [J]. 计算机工程与应用, 2024, 60 (9): 90–100.
- [37] LIU K, WANG H, CHEN H, et al. Steel surface defect detection using a new Haar-Weibull-variance model in unsupervised manner [J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66 (10): 2585–2596.
- [38] LIU K, LI A, WEN X, et al. Steel surface defect detection using GAN and one-class classifier [C] //2019 25th International Conference on Automation and Computing (icac), IEEE, 2019: 1–6.
- [39] NICPLAS CAMARGO-TORRES, JENS BRANDENBURGER. Unsupervised deep learning for detection of Non-uniform surface defect distributions in flat steel production [J]. Advances in Intelligent Systems and Computing, 2021, 1338: 92–103.
- [40] GAO Y, GAO L, LI X, et al. A semi-supervised convolutional neural network-based method for steel surface defect recognition [J]. Robotics and Computer-Integrated Manufacturing, 2020, 61: 101825–101832.
- [41] ZHENG X, WANG H, CHEN J, et al. A generic semi-supervised deep learning-based approach for automated surface inspection [J]. IEEE Access, 2020, 8: 114088–114099.
- [42] DI H, KE X, PENG Z, et al. Surface defect classification of steels with a new semi-supervised learning method [J]. Optics and Lasers in Engineering, 2019, 117: 40–48.
- [43] HE Y, SONG K, DONG H, 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.
- [44] 何彧, 宋克臣, 张德富, 等. 融合多层次特征的弱监督钢板表面缺陷检测算法 [J]. 东北大学学报 (自然科学版), 2021, 42 (5): 687–692.
- [45] XU L, LV S, DENG Y, et al. A weakly supervised surface defect detection based on convolutional neural network [J]. IEEE Access, 2020, 8: 42285–42296.
- [46] 宋育斌, 孔维宾, 陈希, 等. 钢材表面缺陷检测研究综述 [J]. 软件导刊, 2024, 23 (3): 203–211.