

基于深度学习方法的传送带缺陷检测

钟信, 彭力

(江南大学 物联网工程学院物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

摘要: 针对传送带瑕疵在图像中所占有的像素相对有限、特征相对微弱且分布不均匀的问题, 设计了一个传送带缺陷检测系统, 并提出了一种基于高斯混合模型的标签分配策略; 利用特征感受野遵循高斯分布的先验信息进行高斯建模, 并通过动态调整机制适应不同尺度的传送带缺陷, 能够更有效地提升对微小瑕疵的捕捉能力; 使用感受野距离取代交并比来衡量高斯感受野和真实标签的相似度, 并通过二者之间的相似度来分配样本, 从而有效提高了样本分配的准确性; 使用高斯混合模型并通过期望最大化算法拟合概率分布, 实现了对特征点的自适应正负样本分配, 能够有效避免微小瑕疵特征微弱所导致的漏检问题; 结果表明, 高斯混合模型标签分配策略对传送带缺陷检测精度的提升十分明显, 相对于基准网络, 精度提升 3.8%。

关键词: 传送带; 高斯分布; 感受野; 高斯混合模型; 缺陷检测

Belt Defect Detection Based on Deep Learning Methods

ZHONG Xin, PENG Li

(Engineering Research Center of Internet of Things Technology Applications,

School of IoT Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: To address limited pixels, relatively weak features, and uneven distribution of defects in conveyor belt images, a conveyor belt defect detection system is designed, and a label assignment strategy based on Gaussian mixture model is proposed. The Gaussian distribution prior information of the feature receptive fields is applied to build the Gaussian model, which can adapt to defects in different belts through dynamic adjustment mechanisms, thereby effectively improving the detection capability for minor defects. The intersection over union with receptive field distance is replaced to measure the similarity between Gaussian receptive fields and true labels, the sample based on their similarity is allocated to effectively improve the accuracy of sample assignment. The Gaussian mixture model and expectation maximization algorithm are used to implement the probability distribution fitting, achieve the adaptive allocation of positive and negative samples for feature points, and effectively avoid the missed detections caused by minor defects. Experimental results show that the Gaussian mixture model label assignment strategy increases a significant accuracy of conveyor belt defect detection, improving the accuracy by 3.8% compared to the baseline network.

Keywords: belt; Gaussian distribution; receptive field; Gaussian mixture model; defect detection

0 引言

随着工业自动化的深入发展, 传送带作为生产线中不可或缺的组成部分, 其作用至关重要。传送带的运行质量直接影响着生产效率和产品质量^[1]。然而, 由于全年几乎无休地使用, 以及工作环境十分极端, 传送带常常面临各种缺陷和故障。一方面, 传送带在长期使用过程中胶面会产生磨损, 而胶面磨损的严重程度直接关系到传送带的使用寿命和物料输送的效率及安全; 另一方面, 传送带上往往会出现如鼓包、凹坑、断裂、裂纹、磨损等瑕疵, 这些瑕疵会对生产质量和效率产生重大的影响, 甚至可能引发事故。因此, 为了提高生产效率和生产质量, 对传送带上的瑕疵进行准确、快速地检测^[2-3]显得尤为重要。由于传送带瑕疵在图像中所占有的像素相对有限、特征相对微弱

且分布稀疏, 因此被归类为微小目标。这些特性使得传送带微小瑕疵相对于一般的缺陷而言, 其检测难度显著提高。

不过, 已经有许多研究者提出了各种不同的方法和技术用于传送带瑕疵的检测和识别^[4-5], 如传统的图像处理方法、深度学习等。文献 [6] 提出了一种基于导向滤波和最大类间方差法的改进型 Canny 算子边缘检测方法, 可以做到传送带缺陷的在线检测。文献 [7] 采用坐标统计法与分组近似法相结合的方式, 可以有效检测出传送带的故障特征。文献 [8] 提出基于小波融合的边缘检测算法, 提取裂纹纹理信息, 最后用图像融合技术逆小波重建原始图像。还有研究者采用 YOLOv4 算法判断传送带撕裂缺陷, 并通过相邻帧判断策略确认缺陷。然而, 传统的图像处理方法

收稿日期: 2024-01-15; 修回日期: 2024-02-23。

基金项目: 国家自然科学基金(61873112, 61802107)。

作者简介: 钟信(1999-), 男, 硕士研究生。

通讯作者: 彭力(1967-), 男, 博士, 教授, 博士生导师。

引用格式: 钟信, 彭力. 基于深度学习方法的传送带缺陷检测[J]. 计算机测量与控制, 2024, 32(8): 64-71.

通常需要大量的人工设计和调试, 难以适应瑕疵种类繁多、形态复杂、大小不一的情况^[9-10]。而深度学习方法虽然准确率相较于传统方法有了很大地提升, 但也需要大量的数据和计算资源, 而且对于光线不充足下缺陷图片^[11-12]中的微小瑕疵以及图片边缘的失真微小瑕疵不一定能够准确地进行识别^[13]。

为了缓解上述问题, 利用了一种基于高斯分布的新颖先验信息, 并构建了一种更有利于识别传送带微小缺陷的标签分配策略。具体来说, 利用高斯感受野解决先验框和先验点所引起的微小目标检测效果不佳问题, 并使用新设计的感受野距离 (RFD, receptive field distance) 直接测量高斯感受野和真实标签 (GT, ground truth) 区域之间的相似性。一方面, 高斯分布不是阶跃变化的。每个个体先验的域是整幅图像, 其中每个位置的权重从中心到外围逐渐衰减, 且值大于 0。因此可以对图像上任意特征点与任意 GT 之间的位置关系进行建模, 使得整个图像能够获得不同大小目标的平衡正样本。另一方面, 高斯先验可以更好地拟合高斯有效感受野 (ERF, effective receptive field) 的性质, 从而缓解感受野失配问题, 尤其是对于微小目标。此外, 由于理论感受野 (TRF, theoretical receptive field) 和有效感受野并不是线性的比例关系, 针对该问题设计了一种动态半径模块, 可以更好地从多个维度匹配不同尺度的微小目标。

为了保证任何特征点和任何 GT 之间的位置关系都可以得到解决, 在 RFD 的基础上计算了特征点与 GT 之间的 RFD 得分矩阵, 设计了一个高斯混合模型标签分配器 (GLA, gaussian-mixture-modellabel assigner)。分配策略表述为概率分布的似然最大化, 以便模型能够以概率方式推理分配, 它可以逐步减少离群 GT 样本并为微小目标获得足够的训练。

本文算法部分的贡献总结如下:

1) 引入了基于高斯感受野的先验信息, 并使用不同的分布距离来探究特征点与 GT 之间的距离。

2) 由于理论感受野和有效感受野并不是线性的比例关系, 针对该问题设计了一种动态半径模块, 可以更好地从多个维度匹配不同尺度的微小目标。

3) 设计了一种基于高斯混合模型的标签分配策略。GLA 可以取代主流探测器中的基于框先验和点先验的标签分配策略, 从而提高其在微小目标检测 (TOD, tiny object detection) 上的性能。

1 系统设计与工作流程

1.1 系统架构设计

系统架构设计如图 1 所示, 分别包括 18 个工业相机、5 台小工控机、1 台交换机、1 台上位机和 1 台可编程逻辑控制器 (PLC, programmable logic controller)。传送带的图像通过工业相机传输至工控机, 工控机将数据转发至上位机。上位机位于系统的核心检测单元, 是具备高性能图像处理 (GPU, graphics processing unit) 算力的平台。上

位机负责运行预训练好的网络模型对图像进行检测, 挑选出其中的瑕疵图像并进行标记。

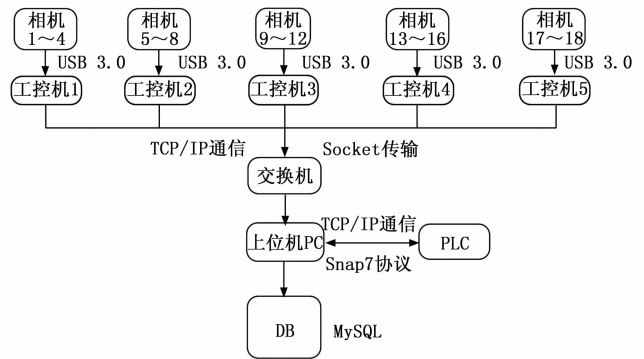


图 1 系统架构图

1.2 硬件设备

本小节详解硬件设备的实现, 包括设备选型和部分具体参数。设备包括工业相机、光源设备、嵌入式工控机、上位机和 PLC。选型要求遵循技术可行性和经济可行性, 尽量在保障检测条件的前提下, 减少成本。

1) 工业相机。工业相机选取海康威视系列相机 MV-CA016-10UM, 160 万像素 USB3.0 面阵黑白相机, 支持自动或手动调节增益、曝光时间、白平衡、Gamma 和 LUT 校正等。机身整体结构紧凑, 外形尺寸 29 mm×29 mm×30 mm, 适用于较小的安装要求。可以兼容 USB3 Vision 协议以及 GenICam 标准, 可与第三方软件平台无缝连接。动态范围高, 适用于各种需要高帧率、高分辨率和高动态范围的应用场景以及电子半导体、工厂自动化等行业。具体参数如表 1 所示。

表 1 工业相机参数

镜头选型	分辨率	最大帧率	动态范围	信噪比	增益
MVL-HF0628M-6MPE	1 440 * 1 080	249.1	71 dB	40 dB	0~17 dB

2) 光源设备。由于传送带的吸光性很强, 且在运动状态下进行检测, 为了避免运动模糊, 对光源的功率、照度和频闪要求都较高。综合考虑这些因素, 本文选择了直流 24 V 的光源, 每组光源由 100 W 和 200 W 的灯泡组成, 脚手架两侧均有 3 组进行打光, 共需 6 组对照打光的方案。

3) 嵌入式工控机。嵌入式工控机搭载英特尔四核处理器、8 GB 内存以及 128 GB 固态硬盘, 运行 Ubuntu 系统。该工控机配备有 4 个 USB3.0 接口, 使其能够同时连接和控制 4 个相机。每个嵌入式工控机在系统组建中的角色是至关重要的, 通过 PLC 获取传送带的启停信号, 负责相机的启停控制、图像采集工作。在图像初筛处理后, 检测到的缺陷图像将被传送到上位机进行进一步的精细处理和展示。需要强调的是, 整个系统中使用了 5 个相同配置的嵌入式工控机, 以确保对 4 个相机的同时高效控制和协同工作。

4) 上位机。选用研勤工控的 610-4U 系列机器, 运行 Windows 操作系统, 可以兼容各种软件。此外, 配备了 RTX2070 系列显卡, 为检测算法提供了强有力的算力支持。

5) PLC。PLC 采用的是西门子 S7-200, 它是一种小型的可编程控制器, 比较适用于中小型自动化项目, 具有模块化设计、灵活编程和通信能力。

1.3 软件系统

本系统的图形用户接口 (GUI, graphical user interface) 界面是基于 PyQt5 开发完成的。PyQt5 是一个功能强大、易于使用且灵活的 Python GUI 工具包, 可以用于开发各种类型的 GUI 应用程序, 包括桌面应用程序、嵌入式系统和移动应用程序等, 故此选用 PyQt5 来开发 GUI 页面。软件整体界面如图 2 所示。



图 2 软件界面图

界面分为 4 个部分, 分别为传送带信息输入、缺陷信息展示、缺陷图片展示以及报警人工分类。首先, 在系统启动之初, 工人输入上皮带或者下皮带的信息, 包括订单号、型号和长度。当上位机检测到缺陷图片时, 就会保存到数据库中, 这时软件界面就会将其展示出来, 缺陷信息包括上下皮带信息、上下表面信息、 x 位置、 y 位置和报警等级; 同时, 发送信号给 PLC, 亮起报警指示灯。工人看到指示灯修复完缺陷后, 判断报警信息是否正确, 如果正确, 则修复完成; 如果错误, 则选择正确缺陷类型, 如图 3 所示。

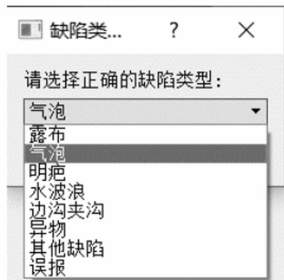


图 3 缺陷类型

1.4 缺陷检测流程

整体的缺陷检测流程如图 4 所示。工人在选择检测模式之后, 手动输入产品信息, 并启动系统。系统启动之后

会自动进行相机和 PLC 的正常与否的校验, 一旦发现异常会发出警报, 并提示工人进行检查; 如果一切正常, 相机会不间断采集图像, 在传送带停止运行期间将图片由工控机初筛完毕之后发送至上位机上进行图片的处理, 最后将瑕疵图像展示在 GUI 界面并提示工人进行修复, 瑕疵图像保存在数据库中。

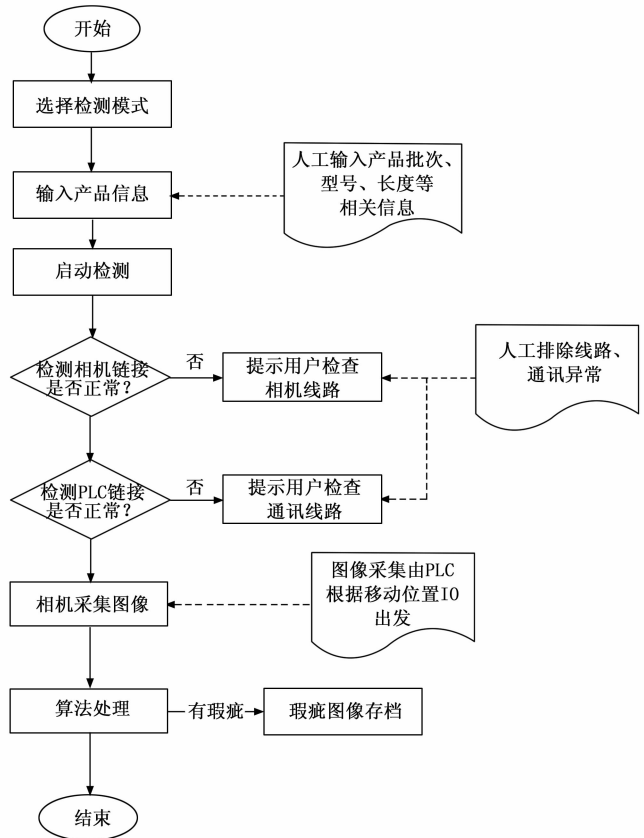


图 4 缺陷检测流程图

1.5 数据集

本系统应用于对 PVG 阻燃传送带的检测, 该传送带在煤矿井下等恶劣环境中具有广泛应用。采用的测试瑕疵数据集从生产现场采集的传送带图像, 其中包含 385 张有瑕疵图像和 400 张无瑕疵图像, 总共 785 张。在采集时还针对同一缺陷采用不同的倾斜角度拍摄来增加数据集的复杂性。其中瑕疵主要包括鼓包、凹坑这类显著瑕疵, 并且无瑕疵图像中存在异物、碎屑等干扰, 对于传送带瑕疵检测系统具有一定挑战。传送带瑕疵数据集如图 5 所示。

2 高斯混合模型标签分配算法

2.1 YOLOv6 算法介绍

YOLOv6 以其检测速度快、稳定性高而著称, 且更偏向于工业应用领域, 在平衡检测精度和速度的情况下, 本文选用 YOLOv6s 作为基准模型。YOLOv6 网络结构如图 6 所示, 其采用了轻量级的网络结构和优化的特征提取算法, 使得检测速度明显提升, 有助于及时发现传送带上的缺陷并进行处理。




图 5 传送带数据集 (有缺陷与无缺陷)

YOLOv6 的主干网络 Efficient Rep 是引入重参数化视觉几何组 (Rep VGG, re-parameterization visual geometry group) 结构设计出的高效可重参数化网络, 可以实现速度与精度的平衡。YOLOv6 的 Neck 结构受到硬件感知神经网络设计思想的启发, 基于 RepVGG 风格设计了可重参数化、更高效的 RepPAN, 这种设计能够将低层次的物理特征与高层次的语义特征进行聚合。至于 Head 部分, YOLOv6 采取了无先验框检测方式, 并采用标准交并比边界回归损失函数进行监督网络学习, 以提升回归精度, 同时设计了一个更高效的 Decoupled Head 结构, 在维持精度的同时降低了延时。

2.2 策略整体设计思路

YOLOv6 采用 ATSSAssigner 和 TaskAlignedAssigner 组合而成的标签分配策略, 由 ATSSAssigner 经过 4 个 epoch 的预热之后, 继而采用 TaskAlignedAssigner 完成标签分配策略。然而, 这一方法对于具有特殊形状、分布或有限像素的传送带微小瑕疵, 可能会导致其被忽略。因此, 本文提出了一种基于高斯混合模型的标签分配策略, 旨在降低训练时间并增强对微小目标的关注度。

高斯混合模型标签分配策略整体结构如图 7 所示。数据经过预处理和加载后, 通过 YOLOv6 网络的 Backbone 和 Neck 提取特征。GLA 将特征点与真实目标框匹配, 以确定

正负样本。最后, 基于匹配结果计算损失函数, 通过反向传播优化网络权重。在 GLA 中, 通过将特征点构建为高斯感受野, 并使用感受野距离衡量其与 GT 区域之间的匹配程度获得得分, 最后将前 K 个得分拟合高斯混合模型来实现正负样本自适应分配。GLA 策略综合考虑了特征点与 GT 区域的相对位置信息, 能够有效提高目标检测的性能。下面分 3 个小节详细描述 GLA 中的感受野建模、感受野距离以及自适应样本分配环节。

2.3 感受野建模

在文献 [14] 中指出, 在神经网络的理论感受野中, 并非每个像素对输出单元产生相同的影响。实际上, 理论感受野中的各个像素对输出单元的贡献呈现高斯分布特性, 即感受野中央区域的像素对输出单元的影响更为显著, 而随着距离中心区域的增加, 贡献逐渐减小。这表明在感受野内部, 不同位置的像素在影响输出单元时具有不同的权重分布, 呈现出中心权重较大、边缘权重较小的趋势。遵循这一工作, 提出了直接测量有效感受野和 GT 区域之间的匹配程度来进行标签分配, 去掉了影响 TOD 的先验框或先验点, 并试图将每个特征点的 ERF 建模为高斯分布, 并且通过公式 (1) 推导出标准卷积神经网络上的第 $i+1$ 层的理论感受野为:

$$TRF_{i+1} = TRF_i + (k - 1) \times S_i \quad (1)$$

其中: TRF_{i+1} 表示当前层的感受野, TRF_i 表示上一层的感受野, k 表示卷积核的大小, S_i 表示之前所有层的步长的乘积 (不包括本层), 公式如下:

$$S_i = \prod_{j=1}^i Stride_j \quad (2)$$

正如文献 [14] 中研究的, ERF 和 TRF 在空间上共享相同的中心位置, 每个特征点的 ERF 仅占据整个 TRF 的一部分, 且高斯分布呈指数级衰减, 使得 ERF 和 TRF 在整体上呈比例关系。为了灵活地调整比例, 提出了一种设计, 允许 ERF 半径根据 TRF 随着比例而变化。具体而言, 设计的公式如下:

$$R_{ERF} = \alpha \cdot R_{TRF} + \beta \cdot g(R_{TRF}) \quad (3)$$

其中: R_{ERF} 为 ERF 的半径, R_{TRF} 为 TRF 的半径, α 表示比例因子, β 是可以调整的动态参数, 动态调整函数 $g(R_{TRF})$ 参考 sigmoid 函数, 其范围在 (0, 1) 之间, 设

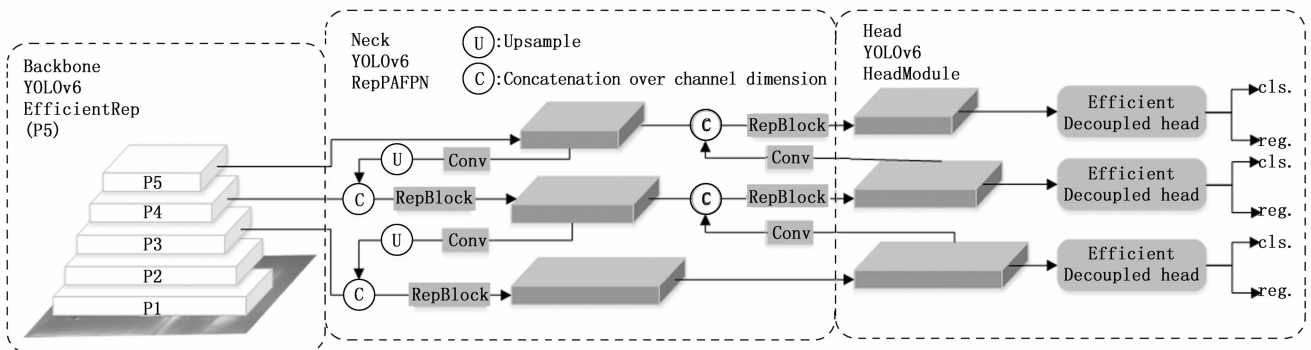


图 6 YOLOv6 网络结构图

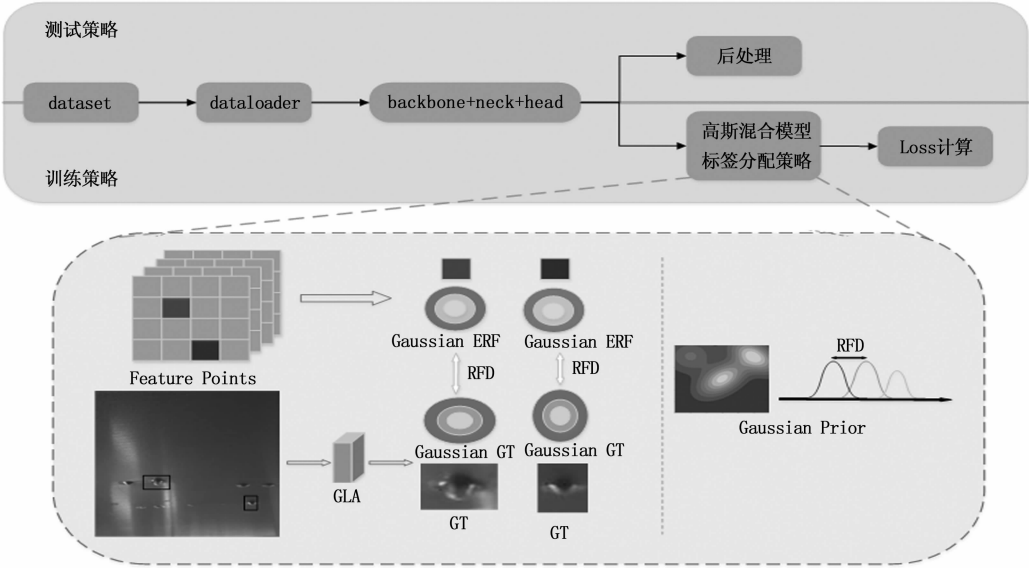


图 7 GLA 标签分配策略架构图

计为：

$$g(R_{TRF}) = \frac{1}{1 + e^{-\alpha R_{TRF}}} \quad (4)$$

式中， $g(\cdot)$ 可以更有效地捕捉神经网络结构和激活函数对有效感受野和理论感受野的影响。公式 (4) 涉及到需要调整的两个参数， α 负责控制 ERF 半径的主要比例，而 β 和 $g(\cdot)$ 的作用则是对半径进行微调以灵活适应不同尺度的微小目标。 β 带来了轻微的调整效果，而不会显著改变整体调整机制的趋势。这样的设计能够在保留一定的调整灵活性的同时，减小了对网络的过度调整可能带来的潜在风险。

因此，选择以每个特征点的位置作为标准二维高斯分布的均值向量。通过高斯分布的参数化来建模每个特征点的 ERF，以更精细地描述其在输入空间中的影响范围。综上所述，将 ERF 的范围建模为二维高斯分布 $N_{ERF}(\mu_{ERF}, \sum_{ERF})$ ：

$$\begin{cases} \mu_{ERF} = [x_i, y_i]^T \\ \sum_{ERF} = \begin{bmatrix} ERF_i^2 & 0 \\ 0 & ERF_i^2 \end{bmatrix} \end{cases} \quad (5)$$

其中： (x_i, y_i) 为特征点的坐标， \sum_{ERF} 为 ERF 的协方差矩阵。

从文献 [15] 可以知道，目标的主体聚集在边界框的中心，所以将 $GT(x, y, w, h)$ 建模成二维高斯分布 $N_g(\mu_g, \sum_g)$ ，其中均值向量和协方差矩阵分别为：

$$\begin{cases} \mu_g = [x, y]^T \\ \sum_g = \begin{bmatrix} \frac{w^2}{4} & 0 \\ 0 & \frac{h^2}{4} \end{bmatrix} \end{cases} \quad (6)$$

2.4 感受野距离

在得到了高斯形式的 ERF 后，接下来的关键步骤是衡

量特征点的 ERF 与某个 GT 之间的匹配程度。针对高斯分布之间的 3 种经典距离作为初始感受野距离 (IRFD, initial receptive field distance)。这些距离测量包括 Wasserstein 距离 (WD, wasserstein distance)^[16]、Kullback-Leibler 散度 (KLD, kullback-leibler divergence)^[17] 和 Jensen-Shannon 散度 (JSD, jensen-shannon divergence)^[18]。

Wasserstein 距离。WD 将衡量一个概率分布变换为另一个概率分布的最小“成本”，它也被称为地面距离或推土机距离。对于高斯分布，WD 涉及寻找最优传输方案，它提供了一个度量，能够捕捉分布之间的位置和扩散差异。

$$D_{WD}(N_E, N_G)^2 = \|\mu_E - \mu_G\|_2^2 + Tr[\sum_E + \sum_G - 2(\sum_G^{1/2} \sum_E \sum_G^{1/2})^{1/2}] \quad (7)$$

其中： N 代表二维高斯分布， μ 为均值向量， \sum 为协方差矩阵。

WD 的主要优点是它可以测量两个不重叠的分布。因此，WD 的性质有利于 TOD，它能一致地反映所有特征点与某个 GT 之间的匹配程度，使网络模型能够按照合理的优先级对微小目标进行更多的正样本补偿。然而，WD 有两个缺点：1) 中心点单独优化会出现检测结果的位置偏移；2) 不具备尺度不变性。所以当数据集包含大规模方差的目标时，它可能效果不佳。

K-L 散度。KLD 是一种经典的统计距离，用来衡量两个概率分布之间的信息差异。两个高斯分布之间的 KLD 也有封闭形式解，ERF 与 GT 区域之间的 KLD 如下：

$$2D_{KL}(N_E, N_G) = Tr(\sum_G^{-1} \sum_E) + (\mu_G - \mu_E)^T \sum_G^{-1} (\mu_G - \mu_E) - k + \ln \frac{\det(\sum_G)}{\det(\sum_E)} \quad (8)$$

KLD 在两个二维高斯分布之间具有尺度不变性，而尺

度不变性是检测的关键^[19]。而 KLD 的主要缺点是, 当两个分布的重叠可以忽略不计时, 它不能一致地反映两个分布之间的距离。

广义 J-S 散度。JSD^[18] 继承了 KLD 的尺度不变性, 可以度量 GT 与附近非重叠先验的相似度。此外, 它克服了 KLD 不对称的缺点。然而, 高斯分布之间的 JSD 的封闭式解不可用, 此, 决定使用其扩展形式广义 Jensen-Shannon 散度 (GJSD, generalized jensen-shannon divergence)^[20], 它可以产生一个可用的封闭式解。ERF 高斯分布和 GT 高斯分布间的 GJSD 可以表示为:

$$D_{GJSD}(N_E, N_G) = (1 - \alpha)D_{KL}(N_a, N_E) + \alpha D_{KL}(N_a, N_G) \quad (9)$$

其中: D_{KL} 代表 KLD , 而 $N_a(\mu_a, \sum_a)$ 可以表示为:

$$\begin{cases} \mu_a = (1 - \alpha)\mu_E + \alpha\mu_G \\ \sum_a = (1 - \alpha)\sum_E + \alpha\sum_G \end{cases} \quad (10)$$

综上所述, 展示了度量高斯分布距离的 3 种方法, 其中 WD 、 KLD 和 $GJSD$ 都被称之为初始感受野距离, 且范围不在 $(0, 1)$ 之间的距离需要进行归一化处理:

$$RFD = \begin{cases} \frac{1}{1 + IRFD}, IRFD = D_{WD}, D_{KLD} \\ IRFD, IRFD = D_{GJSD} \end{cases} \quad (11)$$

2.5 自适应样本分配

由于微小目标在 anchor-free 检测方法的策略中容易被忽视, 因此设计出通过分数排名为微小目标分配标签的策略。为了保证任何特征点和任何 GT 之间的位置关系都可以得到解决, 所提出的高斯混合模型标签分配策略建立在 RFD 的基础上。在分配之前, 根据上述方法计算特征点与 GT 之间的 RFD 得分矩阵。分配策略应表述为概率分布的似然最大化, 以便模型能够以概率方式推理分配。

为了让模型能够推理是否应该以概率方式将特征点预测为正样本, 所以将某个 GT 的分数建模为从概率分布中抽取的样本。然后, 根据每个样本为正样本或负样本的概率将特征点分为正样本和负样本。由于目标是将一组特征点分为两组 (正组和负组), 因此可以使用任何可以对样本的多模态进行建模的概率分布。本文选择两种模态的高斯混合模型 (GMM, gaussian mixture model) 来对得分分布进行建模:

$$p(x) = w_1 \cdot N(\mu_1, \sum_1) + w_2 \cdot N(\mu_2, \sum_2) \quad (12)$$

其中: $p(x)$ 是高斯混合模型的概率密度函数, $N(\mu, \sum)$ 表示均值为 μ 、协方差矩阵为 \sum 的多变量高斯分布, w_1 和 w_2 是两个高斯分布的权重, 满足 $w_1 + w_2 = 1$ 。

在给定一组特征点得分的情况下, 可以使用期望最大化 (EM, expectation-maximization) 算法来优化 GMM。利用 EM 算法估计的 GMM 参数, 可以确定每个特征点为正样本或负样本的概率。利用这些概率值, 可以使用各种技术将特征点分成两个组。图 8 说明了基于特征点概率的分离边界的不同示例。算法 1 中描述了具体的执行步骤。首

先对特征点和 GT 进行高斯建模 (第 3~4 行)。为了提高 EM 算法的效率, 将每个特征点与特定 GT 的 RFD 分数进行排名, 对于具有前 K 个最高 RFD 分数 (第 5~11 行) 的特定 GT 的特征点, 执行 EM 算法 (第 12 行), 非顶部 K 个锚点被指定为负样本 (第 16 行)。

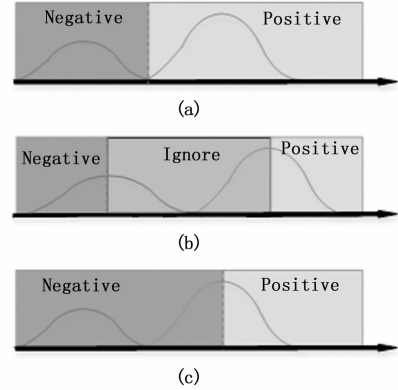


图 8 边界分离的不同情况

算法 1: 高斯混合模型拟合算法

输入: G, A, A_i, L, K

G 是一组真实框

A 是所有特征点的集合

A_i 是第 i 层金字塔的一组特征点

L 是金字塔层数 K 每个金字塔的候选点数量

输出: P, N, I

P 是一组正样本

N 是一组负样本

I 是一组被忽略的样本

1: $P \leftarrow \emptyset, N \leftarrow \emptyset$

2: 从 $g \in G$ 开始循环

3: $G_{A_i} \leftarrow$ 为特征点高斯建模 (A_i)

4: $G_g \leftarrow$ 为真实框高斯建模 (g, G)

5: $Z_g \leftarrow \phi$

6: 从 $i = 1$ 到 L

7: $S_i \leftarrow$ 计算感受野距离 (G_{A_i}, G_g) {公式 (11)}

8: $k_i \leftarrow$ 找到前 K 个分数 (s_i, K)

9: $Z_g^i \leftarrow \{a_j \in G_{A_i} \mid k_i \leq s_j \in S_i\}$

10: $Z_g \leftarrow Z_g \cup Z_g^i$

11: 结束循环

12: $B, F \leftarrow$ 拟合高斯混合模型 ($Z_g, 2$) {两个高斯分布的概率为 Z_g }

13: $N_g, P_g \leftarrow$ 分离特征点 (Z_g, B, F) {使用图 8 中的某个情况分离特征点}

14: $P \leftarrow P \cup P_g, N \leftarrow N \cup N_g, I \leftarrow I \cup (Z_g - P_g - N_g)$

15: 结束循环

16: $N \leftarrow N \cup (A - P - N - I)$

17: 返回 P, N, I

3 实验结果与分析

3.1 实验配置

本实验训练和测试的模型均使用基于 PyCharm 的集成

开发环境, 并使用 Python3.8 开发完成。运行在 Windows10 操作系统的个人计算机上, 显卡为 NVIDIA GeForce GTX1080Ti, 深度学习框架为 PyTorch1.8。

3.2 评价指标

在本次实验中, 使用均值平均精度 (mAP, mean average precision)、精度 (precision) 和召回率 (recall) 来作为模型的评估指标。

mAP 是评估目标检测模型性能的常用指标。它结合了多个置信度阈值下的精确率和召回率, 提供了全面的评估。精度衡量模型对正样本的预测准确性, 是真正例与所有预测为正例的样本 (真正例 + 假正例) 的比率。召回率, 又称为敏感性或真正例率, 衡量模型捕获所有相关正例的能力, 是真正例与所有实际正例的样本 (真正例 + 假负例) 的比率。具体公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N \int_0^1 P(R) dR \quad (15)$$

其中: TP 表示真正例, FN 表示假负例, FP 表示假正例, N 表示取间隔点的个数。

3.3 实验流程及结果分析

本实验模型设置参数为: 输入图片大小为 640×640 , 训练轮数为 300 轮, 批次大小为 48, 交并比阈值为 0.5, 初始学习率设置为 0.01, 其参数均在不添加预训练权重下进行训练。将标注好的数据集按 3:1:1 的比例划分为训练集、测试集和验证集。

本实验采用了两种模型进行对比: 使用原始 YOLOv6, 用 YOLOv6 表示; 使用 GLA 策略的 YOLOv6, 用 YOLOv6-GLA 表示。为了保证实验的可靠性, 对两种模型采用相同的超参数设置。在传送带缺陷数据集上, 实验结果如表 2 所示。


表 2 缺陷数据集实验结果 %

模型	Precision	Recall	mAP ₅₀	mAP ₇₅	mAP ₅₀₊₉₅
YOLOv6	86.1	73.2	77.3	56.9	57.8
YOLOv6-GLA	88.9	76.1	81.1	58.5	59.8

根据表中数据, 可以看出 YOLOv6-GLA 在传送带缺陷的识别方面表现出色, 在所有指标上的表现都优于 YOLOv6, 其多个指标提升了约 2.0~4.0% 左右, precision 的提升更是达到了 3.8%。GLA 能够更准确地为传送带瑕疵分配标签, 其通过高斯混合模型来动态调整标签分配, 适应不同尺度和形状的瑕疵, 这有助于模型更好地捕捉传送带上的微小瑕疵, 因此可以提高模型在检测瑕疵时的精度和召回率。这标志着在传送带缺陷检测任务中, 采用 GLA 策略能够显著提升模型的性能。

为了更直观地展示这一进步, 传送带缺陷检测结果的

可视化图表可参见图 9。尽管 YOLOv6 在对大多数传送带缺陷的识别方面表现出色, 然而在处理角落边缘上的缺陷或者像素信息相对较少的缺陷时, 其识别能力存在明显不足。相较之下, YOLOv6-GLA 针对传送带瑕疵的特点进行了优化, 提高了模型对微小瑕疵的识别能力, 并在暗光环境下增强了检测效果, 还有效减少了图片边缘处缺陷因失真而被漏检的情况, 这样可以更好地适应不同尺度和形状的瑕疵。这表明了 GLA 在传送带瑕疵检测任务中表现更加稳健和可靠, 为自动化生产过程中缺陷检测提供了有效的解决方案。



(a) YOLOv6 (b) YOLOv6-GLA

图 9 传送带缺陷检测效果对比图

4 结束语

在本研究中, 针对传送带瑕疵在图像中存在像素相对有限、特征微弱且分布稀疏的问题, 提出并实现了一个创新的传送带缺陷检测系统, 该系统包含硬件设备和软件界面。通过采用深度学习方法, 本文设计了一个基于高斯混合模型的标签分配策略, 以应对传统方法中存在的挑战性问题。首先利用特征感受野, 并遵循高斯分布的先验信息进行高斯建模, 通过灵活的动态调整机制, 使其能够适应不同尺度的传送带缺陷, 从而提高了系统的泛化性能。同时, 通过引入高斯混合模型并借助 EM 算法进行概率分布的拟合, 本文实现了对特征点的自适应正负样本分配, 使得模型更加灵活地适应复杂的图像场景。实验结果表明, 本文提出的高斯混合模型标签分配策略在传送带缺陷检测的精度提升方面取得了显著成果, 相对于基准网络, Precision 提升了 3.8%, 这验证了本文所提出方法的有效性。

因主要采取自己拍摄缺陷数据集, 可能数据集样本的

丰富程度不足, 这在一定程度上导致了网络的准确率, 未来将继续扩大数据集, 并提高照片的拍摄质量, 以满足更高的实际应用场景需求。

参考文献:

- [1] 葛迪, 陈文韬, 侯群. 高速传送带上的工业元件瑕疵检测分类系统 [J]. 电子测量技术, 2020, 43 (10): 42-47.
- [2] QI Y, FANG L, HONG T, et al. A new knowledge-distillation-based method for detecting conveyor belt defects [J]. Applied Sciences, 2022, 12 (19): 10051-10051.
- [3] JI M, PENG G, LI S, et al. A neural network compression method based on knowledge-distillation and parameter quantization for the bearing fault diagnosis [J]. Applied Soft Computing, 2022, 127: 109331.
- [4] WANG Z, ZHU D. An accurate detection method for surface defects of complex components based on support vector machine and spreading algorithm [J]. Measurement, 2019, 147: 106886.
- [5] CAO J, WANG S, WANG R, et al. Content-oriented image quality assessment with multi-label SVM classifier [J]. Signal Processing: Image Communication, 2019, 78: 388-397.
- [6] 杨林顺, 董志勇. 基于图像处理的输送带跑偏故障在线检测技术研究 [J]. 煤炭工程, 2020, 52 (10): 116-120.
- [7] 王磊, 张磊, 董妍, 等. 基于FPGA的输送带跑偏检测系统设计 [J]. 煤矿机械, 2019, 40 (7): 27-30.
- [8] 贾焕. 基于图像处理的输送带撕裂和跑偏检测研究 [D]. 山西: 太原科技大学, 2019.
- [9] 生鹏飞, 郝晓丽, 吕进来. 改进区域卷积神经网络的输送带撕裂检测 [J]. 计算机工程与设计, 2023, 44 (3): 908-915.
- [10] 袁海立, 徐锋, 李昭, 等. 基于视觉分析的皮带智能检测系统 [J]. 电子技术与软件工程, 2022 (23): 124-127.
- [11] 陈明宇. 基于机器视觉的传送带缺陷检测系统研究与实现 [D]. 秦皇岛: 燕山大学, 2022.
- [12] 赵鑫. 输送带纵向撕裂在线检测系统的研究与开发 [D]. 太原: 太原科技大学, 2019: 30-45.
- [13] 庄昌乾, 李璟文. 基于YOLOv5和生成对抗网络的塑料标签缺陷检测 [J]. 计算机测量与控制, 2023, 31 (7): 91-98.
- [14] LUO W, LI Y, URTASUN R, et al. Understanding the effective receptive field in deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2016, 29 (17): 22159-22171.
- [15] TONG K, WU Y. Deep learning-based detection from the perspective of small or tiny objects: a survey [J]. Image and Vision Computing, 2022, 123: 104471.
- [16] YANG X, ZHANG G, YANG X, et al. Detecting rotated objects as gaussian distributions and its 3-D generalization [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45 (4): 4335-4354.
- [17] YANG X, YANG X, YANG J, et al. Learning high-precision bounding box for rotated object detection via kullback-leibler divergence [J]. Advances in Neural Information Processing Systems, 2021, 34: 18381-18394.
- [18] ENDRES D M, SCHINDELIN J E. A new metric for probability distributions [J]. IEEE Transactions on Information theory, 2003, 49 (7): 1858-1860.
- [19] LIU Y, SUN P, WERGELES N, et al. A survey and performance evaluation of deep learning methods for small object detection [J]. Expert Systems with Applications, 2021, 172: 114602.
- [20] NIELSEN F. On a generalization of the Jensen-Shannon divergence and the Jensen-Shannon centroid [J]. Entropy, 2020, 22 (2): 221.
- [21] WANG D, TAN D, LIU L. Particle swarm optimization algorithm: an overview [J]. Soft Computing, 2018, 22: 387-408.
- [22] MAYER A. A genetic algorithm with randomly shifted gray codes and local optimizations based on quadratic approximations of the fitness [C] // Proceedings of the Genetic and Evolutionary Computation Conference Companion, 2017: 195-196.
- [23] 周明, 孙树栋. 遗传算法原理及应用 [M]. 北京: 国防工业出版社, 1999.
- [24] JJF 1001-2011, 国家质量监督检验检疫总局, 通用计量术语及定义 [S]. 北京: 国家质量监督检验检疫总局, 2011: 15-20.
- [25] ISO 5725-1-1994. Accuracy (trueness and precision) of measurement methods and results-Part 1: General principles and definitions [S]. Geneva, International Organization for Standardization, 1994: 1-12.
- [26] 中国国检测试控股集团股份有限公司. 电线电缆产品——绝缘厚度能力验证计划中期报告 [R]. 北京: 中国国检测试控股集团股份有限公司, 2022: 1.
- [27] 中国国检测试控股集团股份有限公司. 电线电缆导体产品——绝缘厚度能力验证计划结果报告 [R]. 北京: 中国国检测试控股集团股份有限公司, 2023: 1.

(上接第63页)