文章编号:2096-1472(2026)10-0062-05
DOI:10.19644/j.cnki.issn2096-1472.2026.010.010

基于单元门控神经网络的瓶盖缺陷检测

彭来湖[1],梁铭宇[1],陈 秀[2],徐步都[2]

(1.浙江理工大学机械工程学院,浙江 杭州 310018;
2.浙江理工大学龙港研究院,浙江 温州 325802)
✉ laihup@zstu.edu.cn; 2817408175@qq.com; 329173315@qq.com; ab55599@qq.com

摘 要:针对瓶盖工业生产中缺陷检测的精度与效率问题,提出一种新型单元门控神经网络(CGNet)框架。CGNet采用规则网格将输入图像划分为子图像单元(Cell Block),融合位置编码与通道门控机制,对RGB三通道特征进行并行提取,并利用门控控制单元(GCU)动态选择特征通路,有效减少了计算冗余。在模型训练中,引入基于滑动窗口的标签二次重构策略,由此引发的样本分布不均衡问题通过融合门控损失(GateLoss)与分类损失(LabelLoss)的联合损失函数进行优化。实验结果表明,CGNet的平均精度均值(*mAP*)达到93.8%,单张图像检测时间为10.5 ms,检测精度与速度均优于Faster R-CNN、YOLOv5等主流对比模型,同时在召回率与计算效率方面展现出显著优势。

关键词:单元门控神经网络;门控损失;图像检测
中图分类号:TP18 **文献标识码**:A

Bottle Cap Defect Detection Based on Cell Gating Neural Network

PENG Laihu[1], LIANG Mingyu[1], CHEN Xiu[2], XU Budu[2]

(1.*School of Mechanical Engineering, Zhejiang Sci-Tech University, Hangzhou* 310018, *China*;
2.*Longgang Research Institute of Zhejiang Sci-Tech University, Wenzhou* 325802, *China*)
✉ laihup@zstu.edu.cn; 2817408175@qq.com; 329173315@qq.com; ab55599@qq.com

Abstract: To address the accuracy and efficiency challenges of defect detection in industrial bottle cap production, a novel Cell Gating Neural Network (CGNet) framework is proposed. CGNet partitions the input image into sub-image cells (Cell Blocks) using a regular grid, integrates positional encoding with a channel gating mechanism to extract RGB channel features in parallel, and employs a Gate Control Unit (GCU) to dynamically select feature pathways, effectively reducing computational redundancy. During training, a sliding-window-based secondary label reconstruction strategy is introduced, and the resulting sample distribution imbalance is mitigated through a joint loss function that combines gating loss (GateLoss) and classification loss (LabelLoss). Experimental results demonstrate that CGNet achieves a mean Average Precision (*mAP*) of 93.8% with an inference time of 10.5 milliseconds per image, surpassing mainstream models such as Faster R-CNN and YOLOv5 in both detection accuracy and speed, while also exhibiting significant advantages in recall and computational efficiency.

Key words: Cell Gating Neural Network; GateLoss; image detection

0 引言(Introduction)

随着科技的迅猛进步,工业生产流程持续优化,必须保证每个步骤都满足严格的质量规范,才能达到最终产品的质量标准。然而,在瓶盖的工业生产中,频繁的装卸操作常引发各种难以预测的划痕和压痕,加上瓶盖生产车间环境不洁可能带来污染,因此瓶盖缺陷检测已成为关键环节。

深度学习技术[1]在瓶盖缺陷检测领域已被广泛应用,但核心难题依然突出,主要体现为对细微划痕、微小凹陷等缺陷的

收稿日期:2025-11-28

www.rjgczz.com

识别，以及在复杂瓶身图案、高反射材质和环境光影干扰等复杂背景下的检测。此外，在复杂印刷纹理、强反光及阴影影响下，准确区分真实缺陷与正常图案或伪影仍构成重大挑战，导致检测精度下降和误报增多。因此，行业迫切需要一种创新方法，能在瓶盖缺陷检测中全面兼顾微小缺陷特征保留、复杂背景下的鲁棒特征表达，以及适用于产线边缘设备实时检测的高计算效率。

1　相关研究(Related research)

众多研究团队在物体缺陷检测领域提出了多种创新算法。芦碧波等[2]提出了一种改进的RT-DETR(Real-Time DEtection TRansformer)目标检测器；贺勇等[3]提出了一种优化RT-DETR多尺度特征融合的OMSI-DETR改进模型；朱强军等[4]提出了改进的高效多尺度注意力机制和混合小目标层的YOLOv8小型模型；孙铭见等[5]提出一种基于改进YOLOv8s算法的饮品瓶盖缺陷检测模型；胡成峰等[6]提出基于Transformer的实时检测模型RT-TLTR；王军等[7]提出一种基于YOLOv5s的改进算法DTS-YOLO；贾岚等[8]提出了一种基于改进YOLOv7-tiny的跨阶段检测模型CrossStage-YOLO；Yu等[9]提出了一种面向VQA-Med的问题引导特征金字塔网络(Question-guided Feature Pyramid Network，QFPN)；Qin等[10]提出了一种具有自适应融合策略和增强语义信息的特征金字塔网络；Chen等[11]使用基于注意力机制的特征金字塔网络(Attention-based FPN，AFPN)来定位深度学习留下的修复痕迹；Sisniega等[12]以有序子集可分离二次代理优化的惩罚加权最小二乘形式开发了MBIR加速的综合框架；Eickhoff等[13]提出了一种结合fMRI的空间分辨率和MEG的时间分辨率的前向建模方法；Wu等[14]提出了一个强大的LiDAR-相机融合解决方案，利用注意力机制探索点云和图像之间的潜在关系；Song等[15]提出了一种多组多流属性注意力网络来分离不同类型属性的特征学习和属性外观差异较大类别的属性视觉特征学习。然而，将这些模型应用于瓶盖缺陷检测面临独特的挑战，主要涉及小缺陷的可靠识别、对复杂背景的鲁棒性以及与边缘部署相兼容的计算效率。

2　瓶盖检测算法(Bottle cap detection algorithm)

为解决工业场景下的瓶盖缺陷检测中对工业应用成本、检测速率以及正确率的需求，本文提出一种新型的单元门控神经网络(Cell Gating neural Network，CGNet)框架，将原始图像划分为规则网格单元，然后将每个单元的RGB三通道特征分别送入独立的通道门控分支进行并行训练，最终输出门控损失。门控损失在部署时决定是否开启门控，据此来解决图像在特征通道上存在的冗余信息问题。将原始图像信息提取出来的特征图与门控通道输出的特征图进行特征融合，用于瑕疵种类的分类，提出一种新型的损失函数，实现端到端的计算。基于滑动窗口对原有的图像进行切割，对原有的图像标签进行二次重构，用以减少部署端的计算量，能够用于工业端的计算。

2.1　图像标签二次重构

本文算法面向工业应用部署场景，因此需要考虑到模型在实际部署过程中所需要的计算量、所占用的内存要尽可能少。基于滑动窗口的思想对原始图像进行分割处理，如图1所示，将原始图像切割成所需要的子图像，称之为Cell Block。

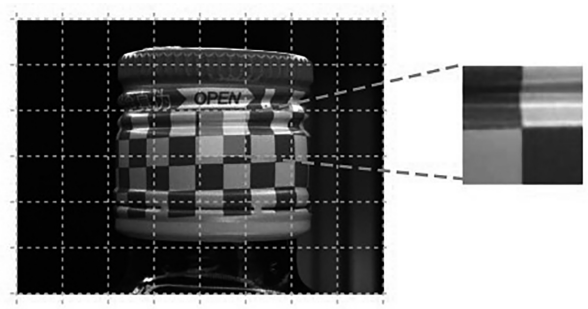

图1　原始图像切割成的子图像

Fig. 1 Sub-images segmented from original image

在原数据集中，每一张图像都有对应的标签，如图2中方框所示，它必然与Cell Block存在着交集。通过计算交集面积与Cell Block的面积之比(IOC)来表示当前Cell Block的标签。IOC分母为子图像单元(Cell Block)的面积，旨在量化缺陷在子图像中的占比，用于判断该子图像是否需要启动后续分类计算，避免因缺陷占比过小导致的计算冗余。当缺陷完全包含于Cell Block时，IOC=IoU；当缺陷跨多个Cell Block时，IOC可独立量化每个子图像的缺陷关联程度。IOC公式如式(1)所示：

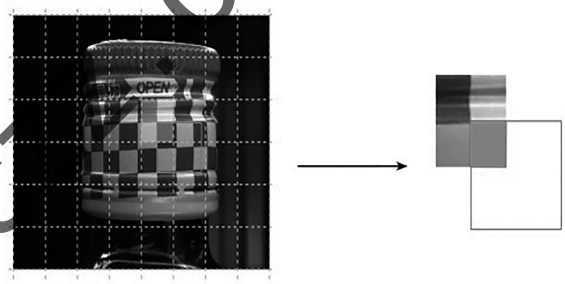

图2　图像对应的标签

Fig. 2 Labels corresponding to image

$$IOC=\frac{S_{\text{CellBlock}\cap\text{OriginalLabel}}}{S_{\text{CellBlock}}} \tag{1}$$

对于存在瑕疵的Cell Block来说，它的种类标签即为对应瑕疵种类的IOC，门控标签为1，即：

$$\begin{cases}\text{ClassLabel}=IOC\\ \text{GateLabel}=1\end{cases} \tag{2}$$

对于仅为背景的Cell Block来说，它的种类标签与门控标签都为0：

$$\begin{cases}\text{ClassLabel}=0\\ \text{GateLabel}=0\end{cases} \tag{3}$$

至此对于原始图像的分割及其标签重构完毕。

2.2　门控控制单元

门控机制主要依赖于对原始图像卷积提取特征之后的特征图进行门控开关是否开启的选择。据此提出一种新型的计算模块门控控制单元(Gate Control Unit，GCU)。

如图3所示，CBS模块是在YOLO中提出的一种较为实用的卷积模块结构，通常由卷积层、批归一化层、激活函数构成，在特征提取中发挥着重要的功能。GCU模块主要针对提取出来的图像特征获取门控状态(Gate Output)并生成一个对应的损失GateLoss。考虑到Cell Block是由窗口按固定大小分割，而在工厂环境中相机与瓶盖的相对位置稳定，因此在该环境下将GCU中引入Cell Block的Position Embedding作为

www.rjgc.com

特征进行训练，通过将 Cell Block 中心坐标进行归一化，将空间位置信息融入特征计算，显著提升门控对缺陷高发区域的识别针对性。Gate Output 与 GateLabel 通过 GateLoss 计算损失，反向优化门控决策参数，确保门控筛选的有效性。

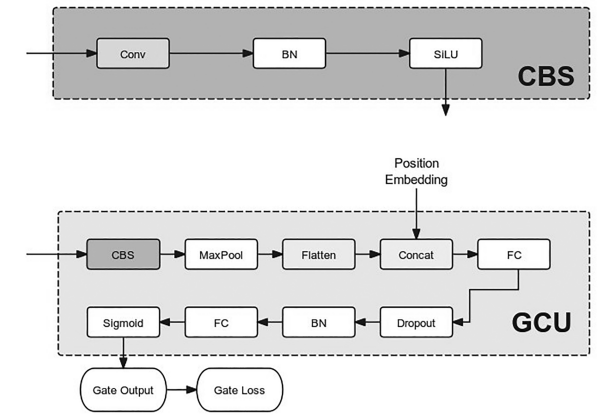

图 3 CBS 与 GCU 模块

Fig. 3 CBS and GCU modules

2.3 损失函数

模型通过滑动窗口将原始图像分割为子图像，并对标签进行重构后用于训练。这种处理方式导致样本严重不均衡：缺陷损失易被背景损失淹没，进而降低模型的检测性能。

标准的交叉熵损失函数中所有的样本权重都是相同的，$CE(p,y)$的公式如式(4)所示：

$$CE(p,y)=\begin{cases}-\log(p), & y=1\\ -\log(1-p), & y=-1\end{cases} \tag{4}$$

其中：$y\in\pm1$ 为标注的标签类别；$p\in[0,1]$是模型对标签 $y=1$的类别的概率估计。为了使符号表述清晰，定义符号p_t：

$$p_t=\begin{cases}p, & y=1\\ 1-p, & y=-1\end{cases} \tag{5}$$

可以得到

$$CE(p,y)=CE(p_t)=-\log(p_t) \tag{6}$$

为了改善样本不平衡带来的影响，Lin 等[10]提出了 Focal Loss 损失函数，公式如式(7)所示：

$$FL(p_t)=-\alpha_t(1-p_t)^{\gamma}\log(p_t) \tag{7}$$

其中：$\alpha_t\in[0,1]$为权重因子；$\gamma\in[0,5]$为调制因子，用于缓解对于易区分的负样本在训练过程中对正样本的淹没。

由于优先对缺陷点是否存在进行判断再二次进行缺陷点分类判断，因此本文在 Focal Loss 的基础上提出了 GateLoss 和 LabelLoss 用于构造模型的损失函数。

对于 GateLoss 而言，由于本身仅受子图像内是否存在缺陷影响，因而更加着重考虑子图像中的背景样本过多导致的对于缺陷样本的稀释作用，而作为背景的子图像往往有着易于区分的特性：

$$GL(p_{t_1})=-\alpha_1(1-p_{t_1})^{\gamma_1}\log(p_{t_1}) \tag{8}$$

其中：α_1、γ_1 分别为 GateLoss 的权重因子和调制因子；p_{t_1}是对于门控开关的概率估计。

对于 LabelLoss 而言，它本身有先验的门控用于启动类别的检测，$LL(p_{t_1},p_{t_2})$如式(9)所示：

$$LL(p_{t_1},p_{t_2})=p_{t_1}(-\alpha_2(1-p_{t_2})^{\gamma_2}\log(p_{t_2})) \tag{9}$$

其中：α_2、γ_2 分别为 LabelLoss 的权重因子和调制因子；p_{t_2}是对于缺陷的类别估计。

整合得到基于门控机制的卷积神经网络的损失函数如式(10)所示：

$$L(p_{t_1},p_{t_2})=-\omega\alpha_1(1-p_{t_1})^{\gamma_1}\log(p_{t_1})+(1-\omega)p_{t_1}(-\alpha_2(1-p_{t_2})^{\gamma_2}\log(p_{t_2})) \tag{10}$$

其中：$\omega\in[0,1]$为门控权重分配因子。GateLoss 和 LabelLoss 的维度不统一，GateLoss 用于门控开关而 LabelLoss 用于类别识别，因此需要门控权重因子用于对整个端到端模型的权重分配。

2.4 GCU Compare 单元和 FFM 特征融合单元

为减少部署中卷积运算所带来的资源消耗，门控在推理当中应激活决定特征提取的通路，因此本文框架中设计了专门的显式记忆存储单元，用于记录 GCU 在各个通道上的输出结果。为方便表述，将第 i 个通路对于 GCU Compare 单元输出记录为 $GCUC_i$，不同于直接的 GCU 输出结果 GCU Output，GCU Compare 更关注该通道的门控是否正常开启，同时配合特征融合模块(Feature Fusion Module，FFM)进行特征融合。在针对特殊场景下，以酒瓶瓶盖为例，因只有蓝白色，瓶盖上的瑕疵信息在 B 通道上更为显著。而通用场景下在三通道中的特征未必能有显著区分。GCU Compare 单元则是对于 GCU Output 的判断正例进行比较。此表达式如式(11)所示：

$$GCUC_i=\sum \mathrm{GOutput}_j^i \oplus \mathrm{label}_j^i \tag{11}$$

其中：j 为第 j 轮训练；i 为第 i 个通路；⊕为异或符号。

$$\mathrm{GOutput}=\begin{cases}1, & \mathrm{GateOutput}>0.5\\ 0, & \mathrm{other}\end{cases}$$

$$\mathrm{Feature}_{\mathrm{FFM}}=f_{ac}\left(\sum \mathrm{GateOutput}\times\mathrm{Feature}_i\right) \tag{12}$$

其中，$\mathrm{Feature}_{\mathrm{FFM}}$表示特征融合模块输出的特征；$f_{ac}(\cdot)$表示激活函数，$\mathrm{Feature}_i$表示第 i 个通道的特征输出。

2.5 基于门控机制的卷积神经网络整体框架

Gate Control Unit 用于缓解在推理部署的过程中出现的特征冗余的问题。整体框架如图 4 所示，原始图像在通道维度上进行分割，每个通道分支独立进行特征提取，并由对应的通道门决定该分支是否激活。在训练过程中，所有门控开关都开启，用于训练各个通道上的特征提取模型参数。在部署过程中，GCU Compare 可以用于显式选择开启和关闭门控，减少运算量。

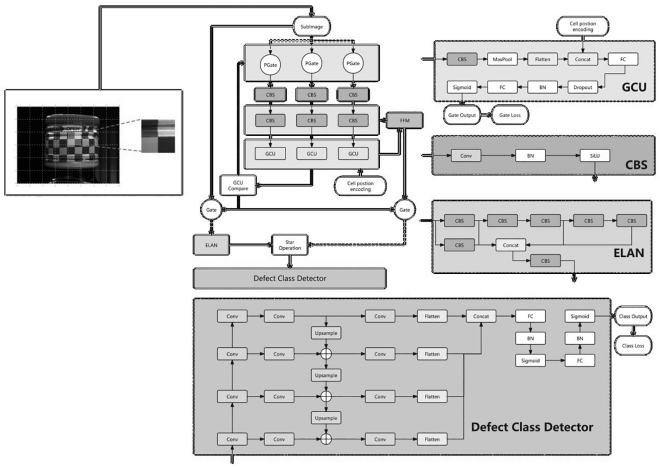

图 4 基于门控机制的卷积神经网络

Fig. 4 The overall framework of cell gating convolutional neural network

www.rjgzz.com

3 实验结果与分析(Experimental results and analysis)

3.1 数据集

实验数据来源于阿里云天池工业缺陷检测竞赛公开数据集，获取链接为 https://tianchi.aliyun.com/dataset/110147。该数据集共收录 2969 张具有瑕疵的酒瓶封盖图像样本，每幅图像至少呈现一种缺陷特征，部分样本存在多缺陷共存现象。数据集涵盖 7 类典型缺陷及其对照类别，如图 5 所示，具体包括：瓶盖破损(1619 例)、瓶盖变形(705 例)、瓶盖坏边(656 例)、瓶盖打旋(480 例)、瓶盖断点(614 例)，以及作为质量对照的喷码正常(489 例)与喷码异常(199 例)两个特征类别。

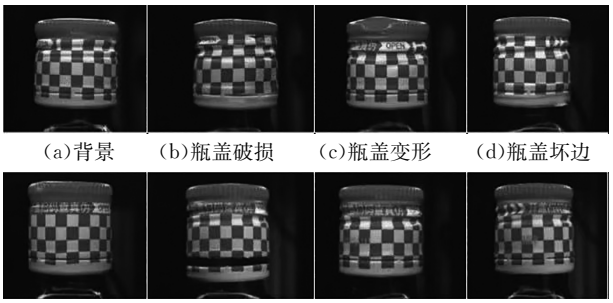

(a)背景　(b)瓶盖破损　(c)瓶盖变形　(d)瓶盖坏边

(e)瓶盖打旋　(f)瓶盖断点　(g)喷码正常　(h)喷码异常

图 5　缺陷类别

Fig. 5 Categories of defect

该数据集在工业检测任务中呈现出显著的技术挑战：图像中存在大量小尺度目标及非常规长宽比的缺陷特征，这对目标检测算法的定位精度与特征提取能力提出较高要求；原始数据规模与多类别检测需求存在失衡，2969 张原始样本需支撑 7 类缺陷的识别任务，容易导致模型过拟合。为解决上述数据集存在的问题，采用多种方式进行数据增强。在基础空间变换基础上，针对性实施亮度扰动和对比度调整以模拟工业现场复杂光照条件，通过高斯噪声注入增强模型抗干扰能力。对少数类样本(如喷码异常)实施 2 倍重复增强，而对多数类样本采用标准增强比例，有效缓解类别不均衡问题。经增强处理后，数据集规模扩展至 5938 张高质量图像，包含 9524 个精细化标注的缺陷实例。最后采用分层抽样策略划分数据集：训练集 5344 张(90%)和测试集 594 张(10%)。

3.2 实验环境

本实验所采用的操作系统为 Ubuntu 22.04，CPU 型号为 AMD EPYC 9654，内存为 128 GB，显卡为 NVIDIA 4090，深度学习框架为 PyTorch 2.6，CUDA 版本为 12.8。

3.3 评价指标

为评价模型综合检测性能，本文选取召回率(Recall，R)、平均精度均值(mean Average Precision，mAP)、参数量(parameters)、浮点计算次数(FLoating Point Operations Per second，FLOPs)作为评价指标。

$$R=\frac{T_p}{T_p+F_n} \tag{13}$$

其中：T_p 为模型成功预测的正例；F_n 为被模型错误预测为负例的正例；R 为召回率。

$$mAP=\frac{\sum_{j=0}^{n}AP_j}{n} \tag{14}$$

其中：AP_j 为第 j 类瑕疵的平均精度；n 为瑕疵类别数；mAP 为平均精度均值。

3.4 实验结果

基于瓶盖缺陷检测数据集，采用 CGNet 架构进行实验。实验设置如下：优化器选用 Adam 算法($\beta_1=0.85$、$\beta_2=0.973$，$\varepsilon=1\times10^{-8}$)；Batch Size 设为 8，初始学习率为 0.000 3，训练 Epoch 为 120；损失函数参数设置为 GateLoss 权重因子 $\alpha_1=0.7$、调制因子 $\gamma_1=2.0$，LabelLoss 权重因子 $\alpha_2=0.5$、调制因子 $\gamma_2=1.5$，门控权重分配因子 $\omega=0.3$。训练结果如图 6 所示。分析图中的损失函数曲线可知，CGNet 在训练过程中损失值波动幅度小且收敛快，最终稳定在较低水平，这表明模型具有较强的收敛性能。

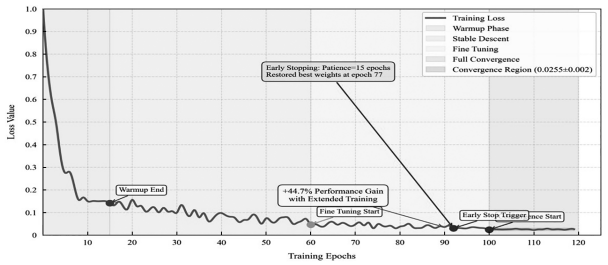

图 6　CGNet 的损失曲线

Fig. 6 CGNet's loss curve

检测精度分布如图 7 所示，不同缺陷类别的检测效能呈现显著差异性特征：瓶盖打旋、喷码异常及喷码正常 3 类大尺度目标因特征边界清晰、与背景对比度显著，检测性能处于优势区间；而瓶盖破损、坏边等类别受限于目标的形态异质性及特征干扰，检测精度相对较低。值得注意的是，瓶盖断点虽属小目标检测范畴，但它的空间分布呈现聚集特性且形态一致性较高，因而检测效能优于同类小目标缺陷。CGNet 平均检测精度达到 90.1%，能够满足工厂环境下对瓶盖瑕疵的初筛标准。

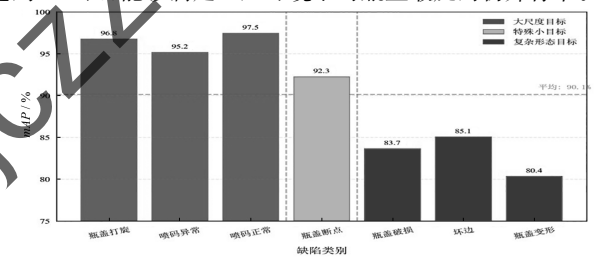

图 7　不同类别瓶盖缺陷检测精度

Fig. 7 Various detection accuracy

为进一步量化模型对各类缺陷的分类可靠性及误判规律，采用 7×7 混淆矩阵评估通道选择算法对瓶盖瑕疵的分类性能，结果如图 8 所示。矩阵主对角线元素表征各类瑕疵的检出可靠性，非对角线元素揭示系统性误判规律。整体来看，误判主要集中在特征边界模糊的缺陷类别间，无跨类别严重误判现象，验证了 CGNet 分类器的鲁棒性。

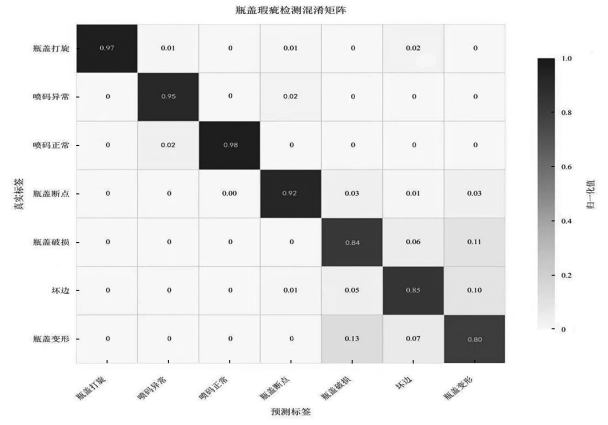

图 8　混淆矩阵

Fig. 8 Confusion matrix

www.rgcz.com

3.5 消融实验

为了验证CGNet中关键组件的有效性，并深入理解各组件对最终性能的贡献，进行系统的消融实验。消融实验通过逐步移除部分通道以及将FFM转化为简单的拼接卷积，来验证通道重要性并且引入灰度图进行对比。实验结果见表1。

表1 模块消融实验结果

Tab. 1 Module ablation experiment results

输入方案	检测 *mAP*/%
灰度图	84.3
R通道	27.8
G通道	28.8
B通道	86.8
R+G双通道	20.8
R+B双通道	88.4
G+B双通道	89.2
全通道(RGB)	89.6
GCU单通道	88.6
GCU双通道	89.7
GCU三通道	93.8

所采用的数据集是蓝色的瓶盖，因此其大部分信息会体现在B通道上。去除B通道后，物体在B通道的高亮特征几乎消失，模型对于纹理边缘特征学习能力会大幅度下降，剩下R、G通道可能只保留噪声或无关细节，此时模型几乎没有任何的识别能力。

3.6 对比实验

为了验证CGNet对瓶盖缺陷的检测效果，分别与Faster-RCNN、YOLOv5、YOLOv8、SSD512在统一数据集下开展了对比实验，所有模型均采用5次重复随机划分的交叉验证。

对每个模型，在设计的最优分辨率下测试。实验结果表明，CGNet的 *mAP* 相比Faster R-CNN提升了约7.1个百分点，检测时间缩短45 ms；比YOLOv5精度提升约0.8个百分点，检测时间缩短2.3 ms；比YOLOv8精度降低了约0.7个百分点，检测时间缩短3.5 ms；比SSD512精度提升了约11.9个百分点，检测时间缩短0.6 ms。

CGNet在精度上优于Faster R-CNN、YOLOv5和SSD512，但略低于YOLOv8。在检测速度上，CGNet在所有模型中更快，尤其在高分辨率下对比Faster R-CNN优势显著。在效率和轻量化上，CGNet的FLOPs和Params均大幅低于其他模型，凸显它在资源受限场景的优势(如移动设备或实时应用)。见表2，改进后的模型，对比同类型单阶段网络精度显著提升，改善较大，检测速度增加幅度低，对比双阶段网络精度提升明显，检测速度差距大。综上所述，本文算法在瓶盖缺陷检测方面优于其他网络，满足工厂包装对瓶盖检测精度及速度方面的需求。

表2 不同网络的性能对比实验

Tab. 2 Performance comparison experiment of different networks

网络	输入分辨率	*mAP*/%	FPS	FLOPs	Params/10^6
Faster R-CNN	1024×1024	86.7±1.1	18	210.6	41.3
YOLOv5	640×640	89.3±0.8	155	49.2	21.9
YOLOv8	640×640	90.8±0.7	130	78.7	25.1
SSD512	512×512	78.2±1.3	210	99.5	23.6
CGNet	1024×1024	93.8±0.4	95	38.9	15.8
CGNet	640×640	90.1±0.5	240	15.1	15.8

4 模型部署(Model deployment)

4.1 速度-精度权衡

如图9所示，在实际应用中，模型不仅需要追求高精度，还需考虑计算效率和推理速度，尤其是在工厂中，考虑到部署设备的成本问题，通常会采用较为便宜的设备进行部署。本节旨在分析提出的CGNet及其对比方法在推理精度与推理速度FPS之间的权衡关系，评估其实际部署潜力。

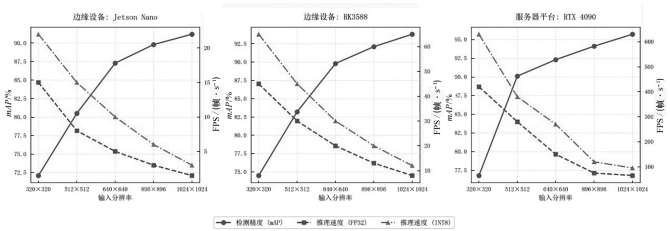

图9 不同硬件平台上的分辨率与性能关系

Fig. 9 Relationship between resolution and performance on different hardware platforms

4.2 边缘部署

工厂环境中，为了控制生产成本，通常会采用边缘处理芯片，例如Jetson Nano、RK3588等进行部署。通常情况下，该类芯片的内存和算力远不及服务器等计算集群，因此在模型部署中需要额外进行操作，对模型进行量化处理并使用专用的推理框架。为此针对Jetson Nano和RK3588这2款市面上常用的性价比较高的边缘处理设备进行加速推理对比实验，见表3，在量化和推理加速的情况下，RK3588在RKNN框架下具有较好的表现，FPS能够到达35.7，能够在较低成本的情况下实现工厂中的检测需求。

表3 部署在不同设备的对比实验

Tab. 3 Comparative experiment deployed on different devices

设备	引擎	延迟/ms	下降/%	FPS	提升/%
Jetson Nano	PyTorch	450	—	2.2	—
Jetson Nano	TensorRT (FP32)	320	28.9	3.1	40.9
Jetson Nano	TensorRT (INT8)	85	81.1	11.8	436.3
RK3588	ONNX (CPU)	380	—	2.6	—
RK3588	RKNN(NPU FP32)	42	90.89	23.8	815.3
RK3588	RKNN (NPU INT8)	28	92.6	35.7	1273.1

5 结论(Conclusion)

本文提出一种新型的单元门控神经网络框架，通过固定网格单元将原始图像分割为子图像，对每个子图实施少量卷积运算提取特征，并将子图特征与网格位置编码融合，通过双重特征分析预测子图缺陷状态。这种层级化处理方式有效降低了后续缺陷类型识别的计算复杂度。在天池公开的瓶盖瑕疵数据集上的实验结果表明，CGNet取得了93.8%的 *mAP* 和10.5 ms的单张检测时间。下一步研究将提高模型对极端长宽比瑕疵和小目标瑕疵的检测精度，采用注意力引导的特征采样策略，聚焦缺陷边缘区域特征，提升细长缺陷的定位精度，持续加强特征融合，以实现模型对瑕疵目标准确、快速的检测。

参考文献(References)

[1] 张子涵，赖清楠，周昌令.深度学习框架模糊测试研究综述[J].信息网络安全，2024，24(10)：1528-1536.

[2] 芦碧波，姚康为，冯伟华.改进RT-DETR无人机航拍小目标检测算法[J].电光与控制，2026，33(5)：15-21.

[3] 贺勇，欧郭林，庞宇凡.优化多尺度特征融合的无人机目标检测算法[J].电光与控制，2026，33(5)：49-55.

(下转第72页)

www.rjgcz.com

景下能够准确、高效地识别和提取 DES 密钥，显著提升了加密数据取证的效率与完整性。

该算法在特定场景下展现出优异性能，但受限于设计逻辑，它的应用场景仍存在一定边界。在加密库适配方面，算法的反混淆策略基于 OpenSSL 库的 DES 密钥混淆机制设计，若目标系统采用 Crypto++、Libgcrypt 等其他加密库，因不同库的密钥混淆逻辑与数据存储格式存在差异，算法将无法有效完成子密钥还原。为突破现有局限，进一步提升算法的适用性与性能，未来可针对主流加密库的 DES 密钥混淆机制开展系统性研究，梳理不同库的混淆逻辑差异并建立统一的反混淆规则库，通过动态识别目标系统使用的加密库类型，自动匹配对应的反混淆策略，实现跨库 DES 密钥搜索。

参考文献(References)

[1] Volatility Foundation. Volatility 3 technical reference manual [EB/OL]. (2025-05-20)[2025-10-30]. https://volatility-foundation.org.

[2] Sadek I, Chong P, Rehman S U, et al. Memory snapshot dataset of a compromised host with malware using obfuscation evasion techniques[J]. Data in Brief, 2019, 26: 104437.

[3] Dolan-Gavitt B, Leek T, Hodosh J, et al. Tappan zee (north) bridge: mining memory accesses for introspection [C/OL]// CCS, 2013: 839-850. https: // dl. acm. org/doi/10. 1145/2508859.2516661.

[4] Taubmann B, Frädrich C, Dusold D, et al. TLSkex: harnessing virtual machine introspection for decrypting TLS communication[J].Digital Investigation, 2016, 16: S114-S123.

[5] Taubmann B, Alabduljaleel O, Reiser H. DroidKex: fast extraction of ephemeral TLS keys from the memory of Android apps [J]. Digital Investigation, 2018, 26 (S): 67-76.

[6] Halderman J, Schoen S, Heninger N, et al. Lest we remember: cold-boot attacks on encryption keys[J]. Communications of the ACM, 2009, 52 (5): 91-98.

[7] Moriconi F, Levillain O, Francillon A, et al. X-Ray-TLS: transparent decryption of TLS sessions by extracting session keys from memory [C/OL]// ASIACCS, 2024: 35-48. https://dl.acm.org/doi/10.1145/3634737.3637654.

[8] Singh G, Supriya S. A study of encryption algorithms (RSA, DES, 3DES and AES) for information security[J]. International Journal of Computer Applications, 2013, 67(19): 33-38.

[9] Mishra D, Kulkarni P. A survey of memory management techniques in virtualized systems[J]. Computer Science Review, 2018, 29: 56-73.

[10] Ottmann J, Breitinger F, Freiling F. Defining atomicity (and integrity) for snapshots of storage in forensic computing[C/OL]// DFRWS EU, 2022. https: // www.dfrws.org/conferences/dfrws-eu-2022.

[11] 潘吴斌，程光，郭晓军，等.基于信息熵的自适应网络流概念漂移分类方法[J]. 计算机学报，2017, 40 (7): 1556-1571.

作者简介：

黄景昊(2001-)，男(汉族)，漳州，硕士生。研究领域：网络安全。

吴礼发(1968-)，男(汉族)，蕲春，教授，博士。研究领域：软件安全、网络协议逆向分析、网络安全。本文通信作者。

(上接第 66 页)

[4] 朱强军，胡斌.基于 IEMA 和混合小目标的 YOLOv8s 交通标志检测方法[J].湖北民族大学学报(自然科学版)，2025，43(2)：202-209.

[5] 孙铭见，刘国洋，李春伟.基于改进 YOLOv8s 算法的饮品瓶盖缺陷检测[J].包装与食品机械，2025，43(2)：20-29.

[6] 胡成峰，黄琳涵，郑权，等.RT-TLTP 番茄叶片病虫害检测方法研究[J].计算机工程与应用，2026，62(6)：253-266.

[7] 王军，万书东，程勇.基于改进 YOLOv5s 的白酒瓶盖瑕疵检测[J].包装工程，2024，45(7)：180-188.

[8] 贾岚，徐雪环，罗德弢，等.基于 CrossStage-YOLO 的跨阶段作物害虫检测[J].南京农业大学学报，2025，48(3)：744-754.

[9] Yu Y, Li H, Shi H, et al. Question-guided feature pyramid network for medical visual question answering[J]. Expert Systems with Applications, 2023, 214: 119148.

[10] Qin L, Pang W, Zhao D. A feature pyramid network with adaptive fusion strategy and enhanced semantic information[J]. Multimedia Systems, 2024, 30(4): 171.

[11] Chen Z, Zhang Y, Wang Y, et al. Robust image inpainting forensics by using an attention-based feature pyramid network[J]. Applied Sciences, 2023, 13(16): 9196.

[12] Sisniega A, Stayman J W, Capostagno S, et al. Accelerated 3D image reconstruction with a morphological pyramid and noise-power convergence criterion[J]. Physics in Medicine & Biology, 2021, 66(5): 055012.

[13] Eickhoff K, Hillebrand A, De Jong M C, et al. Population receptive field models capture event-related MEG responses[J]. Journal of Vision, 2024, 24(10): 647.

[14] Wu Y, Liu J, Gong M, et al. Joint semantic segmentation using representations of LiDAR point clouds and camera images[J]. Information Fusion, 2024, 108: 102370.

[15] Song L, Shang X, Zhou R, et al. A multi-group multi-stream attribute attention network for fine-grained zero-shot learning[J]. Neural Networks, 2024, 179: 106558.

[16] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C/OL] // ICCV, 2017: 2980-2988. https://ieeexplore.ieee.org/document/8237586.

作者简介：

彭来湖(1980-)，男(汉族)，温州，教授，博士。研究领域：机电一体化及智能制造。本文通信作者。

梁铭宇(2001-)，男(汉族)，杭州，硕士生。研究领域：机电一体化，机器学习。

陈　秀(1984-)，女(汉族)，温州，工程师，学士。研究领域：机器设计自动化装备。

徐步都(1992-)，男(汉族)，温州，高级工程师，学士。研究领域：机器设计自动化装备。

www.rjgcz.com