

基于小样本学习与特征配准的面饼异常检测

马凯龙 杨超宇

(安徽理工大学, 安徽 淮南 232001)

摘要: [目的]为实现方便面面饼中细小异物的高效检测,提出一种小样本学习与特征配准的面饼异常检测方法。[方法]采用预训练的残差网络作为特征提取网络,用于高效提取面饼图像的特征;通过引入空间变换网络对图像进行几何变换,以便更好地对特征进行对齐和提取;通过引入特征配准用于对齐图像中的关键特征,确保模型在检测面饼异常时的精确度与泛化能力。[结果]在自制的方便面面饼数据集上进行试验,所提方法在 5-shot 图像级和像素级的曲线下面积分别达到 86.2% 和 93.3%,优于其他方法在面饼数据集上的表现。[结论]所提方法在面饼异常检测任务中可以有效检测出细小异物。

关键词: 面饼检测;小样本学习;孪生网络;异常检测;残差网络

Instant noodle anomaly detection based on few-shot learning and feature alignment

MA Kailong YANG Chaoyu

(Anhui University of Science & Technology, Huainan, Anhui 232001, China)

Abstract: [Objective] To achieve efficient detection of fine foreign objects in instant noodle, this paper proposes an instant noodle anomaly detection method based on few-shot learning and feature alignment. [Methods] The method uses a pre-trained residual network as a feature extraction network for efficiently extracting the features of the instant noodle image. The image is geometrically transformed by introducing a spatial transformation network for better alignment and extraction of features. Feature alignment is used to align the key features in the image so that the accuracy and generalization ability of the model can be ensured in detecting instant noodle anomalies. [Results] Experiments are conducted on a self-made instant noodle dataset, and the proposed method achieves areas under the curve (AUCs) of 86.2% and 93.3% at the 5-shot image level and pixel level, respectively, which outperforms other methods on the instant noodle dataset. [Conclusion] The proposed method can effectively detect fine foreign objects in the instant noodle anomaly detection task.

Keywords: instant noodle detection; few-shot learning; Siamese network; anomaly detection; residual network

当今社会,人们对食品安全^[1]问题日益关注,食品生产中的质量监管^[2]显得尤为重要。方便面面饼作为日常食品,其生产过程中的质量直接关系到产品安全和消费者健康。传统的面饼质量检测方法多依赖人工或简单的图像处理技术,虽然这些方法在早期阶段被广泛应用,但存在效率低下、精度不足的问题,难以满足现代化大规模生产的需求。因此,如何引入先进的自动化技术以提升面饼异物检测的精确性和效率,已成为亟待解决的关键

问题。

近年来,深度学习在异常检测领域得到了广泛应用。传统异常检测方法通常依赖异常样本,但在实际应用中,异常样本往往稀缺。王亭^[3]开发了一种基于机器视觉的面饼检测系统,利用图像预处理技术和多特征提取技术实现对面饼表面缺陷的自动检测,提高了检测效率和准确性。该方法侧重于表面缺陷检测,但对微小缺陷的检测能力有限。Ahmed等^[4]提出了一种基于小样本学习的

基金项目:国家自然科学基金资助项目(编号:52227901)

通信作者:杨超宇(1981—),男,安徽理工大学教授,博士。E-mail: yangchy@aust.edu.cn

收稿日期: 2024-11-24 **改回日期:** 2025-07-18

引用格式: 马凯龙,杨超宇. 基于小样本学习与特征配准的面饼异常检测[J]. 食品与机械, 2025, 41(10): 52-58.

Citation: MA Kailong, YANG Chaoyu. Instant noodle anomaly detection based on few-shot learning and feature alignment[J]. Food & Machinery, 2025, 41(10): 52-58.

牛油果成熟度检测方法,利用微波图像和预训练的卷积神经网络进行成熟度评估,通过迁移学习在少量标注样本下实现高精度检测,在4-Fold交叉验证下平均训练精度和测试精度达到86%和84%。虽然该方法在小样本条件下表现不错,但其应用场景主要集中在果蔬领域,尚未应用于复杂的食品检测领域。Liao等^[5]提出了一种基于小样本学习的面包圈缺陷检测方法,利用原型网络和微波图像对面包圈上的孔洞、裂纹和污染进行检测,并通过数据增强方法使检测精度有所提升。该方法适用于特定缺陷类型,但面对不同食品或更复杂的缺陷类型时,可能需要进一步优化。Argüeso等^[6]提出了一种基于小样本学习的植物病害分类方法,采用孪生网络架构进行图像匹配与分类。通过结合小样本学习与数据增强技术,对少量标注样本进行训练,实现了对不同植物病害的有效识别。但对于具有微小缺陷和复杂背景的检测任务中需要进一步的调整以适应更多的缺陷模式。Jadon^[7]提出了一种名为SSM-net的深度学习方法,用于在少量数据情况下对植物病害进行识别。该方法采用Siamese网络架构,结合了卷积神经网络和VGG16两种特征提取网络,并通过对比学习提高模型的特征表示能力,使模型在小样本环境下保持较高的检测精度。然而,该模型仍需要进一步的优化以适用更复杂的食品缺陷检测。研究拟基于小样本学习实现对方便面饼中的异物检测,通过结合预训练的残差网络和空间变换网络更好地提取特征,并利用孪生网络进行特征配准,以满足生产环境中稀少的训练样本以及高精度的检测要求。

1 方便面饼检测方法

1.1 面向面饼检测的模型架构

面饼生产过程中,由于原料、温度和环境的变化,面饼的外观特征如颜色、形状、纹理等可能发生较大差异。传统的异常检测方法通常依赖于大量的样本进行训练,

并且对类别的特征有较强的依赖性,导致在生产过程中遇到新样本时,检测准确率显著下降。针对这一问题,提出了一种小样本异常检测(few-shot anomaly detection, FSAD)框架,通过对正常面饼样本进行训练,能够有效识别待检测样本中的异常,从而克服传统方法对大量样本和类别依赖的局限性。如图1所示,模型基于Siamese Network^[8]孪生网络架构,通过孪生网络将输入图像与测试图像进行比较,学习图像特征之间的相似度,帮助模型判断两者是否属于同一类别。为了进一步增强对不同生产批次面饼外观变化的适应性,架构中加入了多个空间变换网络^[9](spatial transformer networks, STN)。STN通过自适应仿射变换,对面饼图像的姿态、角度和比例进行标准化操作,实现特征空间的对齐,从而确保模型在面对不同生产环境的面饼时,能够保持鲁棒性。

为了更好地降低模型的复杂度同时保留更多的空间信息,模型选用预训练的ResNet-18作为骨干网络提取面饼的纹理特征。通过保留其前3个卷积残差块,模型不仅能够捕捉到丰富的局部特征信息,还能保持较高的空间分辨率。同时为了提高模型在不同生产环境中的适用性,采用特征配准策略,通过对不同批次图像的相同特征进行对齐,进而减少外观差异对检测精度的影响。即使在出现新的特征时,模型也能够利用已学习的特征进行异常检测,通过最小化同类别面饼图像特征之间的余弦相似度,使得模型能够学习到稳定一致的特征表示,减少了模型对特征的依赖,从而灵活应对各种外观变化。这种特征表示使得在检测新类型面饼时,无须重新训练或微调,从而提高了模型的适应性和准确性。

在推理阶段,模型利用支持集进行特征对比,以判断待检测图像是否存在异常。支持集以正常样本作为基准,模型通过计算待检测样本与支持集之间的特征相似度来判断待检测图像是否为正常样本。为了提高检测准




图1 模型架构图

Figure 1 Model architecture diagram

确性,模型还采用正态分布估计方法,计算待检测样本的异常得分。具体而言,模型通过分析支持集中的正常特征分布,建立一个正常分布模型,如果待检测样本的特征显著偏离这一正常分布,模型会赋予较高的异常得分,从而准确地检测到面饼中的缺陷。此过程不仅提升了检测的敏感性,还使得模型能够在没有具体类别标签的情况下,灵活应对各种潜在的异常情况。通过特征对比与异常得分计算,模型实现了高效且准确的面饼缺陷检测。

1.2 基于对齐策略的特征提取模块

面饼在不同生产批次中可能存在显著的外观差异,如形状、颜色和纹理等,这些变化可能会影响传统检测方法的准确性。为了解决这一问题并提高模型在不同生产环境和批次下的适应性,提出了一种基于对齐策略的特征提取模块。该策略通过 ResNet^[10] 提取面饼图像的深层特征,并结合 STN 对提取的特征进行对齐,从而减少外观差异对检测结果的影响,确保模型能够聚焦于面饼表面上的异物。ResNet^[11] 在捕捉图像的纹理、形状以及局部细节方面表现出色,能够有效应对面饼在颜色和形状上的变化,保留前 3 个残差块可同时确保网络保留较高空间分辨率与对细微缺陷的处理能力。STN 则通过对输入图像应用仿射变换,如旋转、平移、缩放等,对提取的特征进行标准化,从而实现特征空间的对齐。无论面饼的姿态、角度或比例如何变化,STN 都能够确保特征表示的一致性,进而帮助模型在面对不同生产批次或环境变化时,保持较高的缺陷检测精度。通过将 ResNet 与 STN 结合,模型不仅能够高效提取深层特征,还能够对特征进行精确的对齐。如图 2 所示,ResNet 从面饼图像中提取丰富的纹理和局部特征,而 STN 则确保这些特征在不同视角、姿态和比例下能够保持一致性。这一结合方式有效地消除了生产批次和环境差异对特征表示的影响,显著提升了模型对面饼缺陷的敏感性和检测准确性。




图 2 特征对齐操作

Figure 2 Feature alignment operation

具体而言,给定一对输入特征 $f_{i,a}^s$ 和 $f_{i,b}^s$,这些特征由卷积残差块提取,分别对应于训练图像 I_a 和支持图像 I_b ,利用定位网络^[12]生成仿射变换矩阵^[13] $\Theta_{i,a}$ 和 $\Theta_{i,b}$ 进行特征配准。为了对输入特征进行变形,采用逐点变换方法,具体表示为:

$$\begin{pmatrix} x_i^s \\ y_i^s \end{pmatrix} = S_i(f_i^s) = \Theta_i \begin{pmatrix} x_i^i \\ y_i^i \\ 1 \end{pmatrix}, \quad (1)$$

式中:

x_i^s, y_i^s ——输入特征的坐标;

S_i ——空间变换模块;

f_i^s ——输入特征;

Θ_i ——仿射变换矩阵;

x_i^i, y_i^i ——输出特征坐标。

其中 (x_i^i, y_i^i) 是输出特征 f_i^i 的目标坐标, (x_i^s, y_i^s) 是输入特征 f_i^s 源坐标中的相同点, Θ_i 为仿射变换矩阵,具体形式为:

$$\Theta_i = \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \end{bmatrix}, \quad (2)$$

式中:

Θ_{ij} ——线性映射权重系数。

这个变换将输入特征的坐标 (x_i^s, y_i^s) 通过仿射变换矩阵映射到输出特征的坐标 (x_i^i, y_i^i) 。然后,使用网格生成器^[14]用于生成变换网格,而可微采样器则从中提取特征点,以确保输入特征能够被映射到目标特征空间,从而输出相应的输出特征 $f_{i,a}^s$ 和 $f_{i,b}^s$ 。接着,使用定位网络计算输入特征的仿射变换矩阵 Θ_i ,其结构与空间变换网络结构相同。最后,特征对齐模块 S_i 通过结合定位网络、网格生成器和可微采样器实现输入图像特征与支持集特征的精确对齐。这种结合残差网络和 STN 的编码器能够更有效地实现特征的深层次表达和精确对齐,在面饼检测等任务中,增强了模型在复杂场景下的鲁棒性和适应性。

1.3 基于孪生网络的特征配准模块

在面饼检测任务中,为了有效处理面饼在生产过程中产生的形状和位置变化,选择加入特征配准模块,使得正常样本与异常样本的特征可以在空间上对齐。如图 1 所示,以从训练图像中提取的配对特征 $f_{3,a}^i$ 和来自支持图像集的特征 $f_{3,b}^i$ 作为最终的变换输出,利用 Siamese Network 进行特征配准。其采用一个参数共享的编码器 E,对输入特征进行编码处理,编码后的特征通过由两个 1×1 卷积层组成的预测头 P 进行进一步处理,通过第一个卷积层减少特征的通道数并进行线性变换,通过第二个卷积层进一步细化特征表示,增强特征的表达能力和对齐精度,同时预测头 P 还可以通过停止梯度操作防止特征坍塌。在训练过程中,模型借鉴了自监督对比学习方法^[15] (simple siamese network, SimSiam),以避免在没有负样本的情况下优化时出现特征塌陷问题。这种特征塌陷,通常会导致模型在训练时输出趋向一致,从而失去对特征差异的区分能力,而 SimSiam 的训练策略通过特定的对称损失机制克服了这一点。定义输出的特征表示为

$p_a = P(E(f_{3,a}^t))$ 和 $z_b = E(f_{3,b}^t)$, 然后应用负余弦相似度^[15]损失:

$$D(p_a, z_b) = -\frac{p_a}{\|p_a\|_2} \cdot \frac{z_b}{\|z_b\|_2}, \quad (3)$$

式中:

p_a ——预测特征;

z_b ——参考特征。

其中 $\|\cdot\|_2$ 是 L2 范数。类似地, 对于特征

$p_b = P(E(f_{3,b}^t))$ 和 $z_a = E(f_{3,a}^t)$, 应用对称相似度损失:

$$D(p_b, z_a) = -\frac{p_b}{\|p_b\|_2} \cdot \frac{z_a}{\|z_a\|_2}, \quad (4)$$

式中:

p_b ——预测特征;

z_a ——参考特征。

为了提高算法的鲁棒性, 使用特征级配准损失, 这种配准相较于像素级配准更为宽松。同时, 为了防止特征塌陷, 一旦预测头 P 应用于一个分支, 如图 1 所示, 另一个分支会应用停止梯度操作。最后, 定义对称特征配准损失为:

$$L = \frac{1}{2} \{D[p_a, \text{sg}(z_b)] + D[p_b, \text{sg}(z_a)]\}, \quad (5)$$

式中:

p_a, p_b ——预测特征;

z_a, z_b ——参考特征。

其中 $\text{sg}(\cdot)$ 是停止梯度操作, 与直接进行图像级比较相比, 特征级比较具有更高的鲁棒性和优越的性能。因此, 采用特征级别的配准方式, 以直接提取配准特征。

1.4 基于分布建模的异常检测

在测试阶段, 特征配准模块被直接应用于目标类别的支持集, 无须进行参数微调。支持图像经过多种数据增强操作, 以确保特征的多样性。由于孪生网络的两个分支完全相同, 因此仅使用一个分支的特征来估计正常分布。假设图像被划分为 $W \times H$ 的网格, 其中 $(i, j) \in [1, W] \times [1, H]$ 是用于估计正常分布的特征的分辨率。在每个网格位置 (i, j) 处, 定义 $F_{i,j} = \{f_{i,j}^k, k \in [1, N]\}$ 是从增强支持图像提取的配准特征。通过对 3 个空间变换网络输出上采样和拼接, 获得聚合特征 f_{ij} 。在获得特征后, 使用基于统计的估计器^[16]来估计目标类别特征的正态分布, 利用多元高斯分布 $N(\mu_{ij}, \sum_{ij})$ 表示这些特征的分布, 其中样本协方差矩阵为:

$$\sum_{ij} = \frac{1}{N-1} \sum_{k=1}^N (f_{ij}^k - \mu_{ij})(f_{ij}^k - \mu_{ij})^T + \epsilon I, \quad (6)$$

式中:

N ——训练样本总数;

f_{ij}^k ——第 k 张图像在 (i, j) 处的深度特征嵌入向量;

μ_{ij} ——正常样本在 (i, j) 处特征向量的均值;

ϵ ——正则化系数;

I ——单位矩阵。

在推理阶段, 超出正常分布的测试样本被视为异常。通过计算马氏距离^[16] $M(f_{ij})$ 为每个位置 (i, j) 计算异常分数, 定义为:

$$M(f_{ij}) = (f_{ij} - \mu_{ij})^T \sum_{ij}^{-1} (f_{ij} - \mu_{ij}), \quad (7)$$

式中:

f_{ij} ——聚合特征;


μ_{ij} ——正常样本在 (i, j) 处特征向量的均值。

从而生成马氏距离矩阵 M , 形成异常图。通过逆仿射变换将异常图与原始图像对齐, 得到最终异常分数图 M_{final} , 其中高分区域表示异常部分。整个图像的最终异常分数为 M_{final} 中的最大值。

2 试验设置

2.1 数据采集装置

在机器视觉检测中, 数据采集非常关键。研究使用环形输送检测装置模拟工厂生产线, 通过光学传感器触发海康威视 MV-CS016-10GC 高速工业相机, 配合凤凰光学 FA0824 镜头, 对面饼进行图像采集。这一装置如图 3 所示, 它不仅包括了上述的相机和镜头, 还整合了传感器和环形输送带, 形成了一个完整的数据采集系统。该系统能够精确地在面饼经过时触发相机对图像进行采集, 模拟工厂生产线的实际检测流程。



1. 警报器 2. 显示器 3. 开关 4. 传送带 5. 工业相机 6. 茶色门板 7. 光学传感器 8. 不锈钢框架 9. 升降装置 10. 工控机 11. 控制电箱

图 3 环形输送检测装置

Figure 3 Ring conveyor inspection device

2.2 数据集设置

如图 4 所示, 以来自工厂生产的 200 张真实面饼图片作为试验数据集, 面饼异常检测的小样本任务可以定义为 1 way- k shot 小样本任务, 1 way 表示只有面饼一个类别, k -shot 表示样本数量为 k 个。为评估不同样本匮乏度对检测结果的影响, 将数据集划分为 5-shot、10-shot、20-shot 和测试集。



图 4 数据集例图

Figure 4 Image examples of dataset

2.3 试验环境与参数

选用 ResNet-18 作为主干网络,编码器由 3 个 1×1 卷积层组成,预测器包含 2 个 1×1 卷积层,且均不使用池化操作。输入图像尺寸为 224×224 ,模型在训练数据集上进行 50 个 epoch 训练,训练过程中采用带动量的 SGD 优化器,初始学习率设为 0.000 1,批处理大小为 8,学习率衰减采用单周期余弦策略进行动态调整。环境选择 PyTorch1.12 和 Python3.10,训练和测试均在 RTX3080 上进行。

2.4 消融试验

为更全面评估不同模块在试验中的作用,在自制数据集上进行了 1 way- k shot 面饼异常检测消融试验。通过逐步保留或移除各模块,评估其对检测精度和定位性能的影响,结果以曲线下面积(area under the curve, AUC)百分比表示。如表 1 所示,所提出的支持集增强对于模型检测和定位能力都有所提升,通过引入支持集增强,在 $k=\{5,10,20\}$ 情况下,模型在自制数据集上的 AUC 分别提高了 8.3%,7.7%,7.7%。所提特征配准聚合训练则有利于正态分布估计,在有无支持集增强的情况下均有效。如表 1 所示,在 $k=\{5,10,20\}$ 并且没有支持集增强的情况下,模型在自制数据集上的 AUC 分别提高了 3.6%,3.8%,4.4%;而在有支持集增强的情况下,模型在自制数据集上的 AUC 分别提高了 1.3%,1.3%,1.0%。所提空间变换网络模块有利于提高模型的特征配准能力,如表 1 所示,在仅有特征配准的情况下引入空间变换网络,模型在 $k=\{5,10,20\}$ 上的 AUC 分别提高了 0.7%,1.6%,1.2%;而在有支持集增强和特征配准的情况下引入空间变换网络,模型在 $k=\{5,10,20\}$ 上的 AUC 分别提高了 1.4%,1.1%,0.6%。综上,不同的改进模块均对模型的检测精度有所提升,验证了其对面饼检测的有效性。

对 STN 模块多种转换版本进行消融试验,并在 $k=5$ 的条件下评估其性能。如表 2 所示,试验对比了不同空间变换网络变换类型对检测性能的影响,其中旋转加缩放

表 1 在自测数据集上进行消融试验[†]

Table 1 Ablation experiments on self-made dataset %								
模块			自制数据集					
			图像			像素		
A	F	S	$k=5$	$k=10$	$k=20$	$k=5$	$k=10$	$k=20$
			75.2	77.5	79.2	87.2	89.4	90.8
✓			83.5	85.2	86.9	91.5	93.2	94.5
	✓		78.8	81.3	83.6	88.6	90.7	91.2
	✓	✓	79.5	82.9	84.8	89.2	91.1	93.2
✓	✓		84.8	86.5	87.9	91.5	92.9	93.8
✓	✓	✓	86.2	87.6	88.5	93.3	94.5	95.6

[†] A 表示支持集增强,F 表示特征配准聚合训练,S 表示空间变换网络,✓ 表示是否启用模块。

的组合表现最佳,AUC 达到 86.2%。无 STN 的模型 AUC 为 84.8%,表明未加入任何变换时,特征适配能力较弱。单一变换中,旋转的 AUC 为 85.7%,缩放为 85.4%,两者均对检测性能有所提升。组合变换中,旋转加缩放显著优于其他组合,AUC 提升至 86.2%,说明其能够更有效地处理样本中多样化的形变问题。总体而言,合理的空间变换类型能够显著提升模型的特征对齐能力和检测精度。试验验证了旋转加缩放在增强模型性能上的有效性。

2.5 对比试验

为全面评估研究所提方法在面饼数据集上的性能,选取当前主流的 PaDiM^[16] (patch distribution model)、FastFlow^[17] (fast anomaly detection with normalizing flows)、PatchCore^[18] (memory bank-based patch feature core)、CflowAD^[19] (conditional normalizing flow-based anomaly detection) 和 FYD^[20] (focus your distribution) 5 种异常检测算法进行对比试验,其结果如表 3 所示。在 $k=5$ 的条件下,研究所提方法在图像级和像素级的 AUC 分别达到了 86.2% 和 93.3%,显著优于其他方法。相比之下,PatchCore 的图像级 AUC 为 85.3%,像素级为 92.3%,尽管

表 2 STN 变换的影响[†]

Table 2 Effect of different STN transformations %									
数据	无 STN	T	R	S	C	R+S	T+S	T+R	T+R+S
自制数据集	84.8	85.2	85.7	85.4	85.4	86.2	85.4	85.5	85.3

[†] T 表示平移,R 表示旋转,S 表示缩放,C 表示剪切。

接近但仍低于研究所提方法。PaDiM 和 FastFlow 的图像级 AUC 分别为 83.6% 和 82.3%, 在像素级表现也略低, 分别为 90.2% 和 89.5%。综上, 研究所提方法在检测精度和异常定位准确性上表现优异, 得益于支持集增强与特征对齐提升泛化能力, 空间变换网络增强对形变问题的处理, 及特征比较策略强化异常捕捉能力, 从而全面优化了模型的检测性能。

表 3 在自制数据集上的表现

Table 3 Performance on self-made dataset %					
方法	图像	像素	方法	图像	像素
PaDiM	83.6	90.2	CflowAD	83.1	91.2
FastFlow	82.3	89.5	FYD	83.6	90.6
patchcore	85.3	92.3	研究所提方法	86.2	93.3

如图 5 所示, 在 MVTEC AD^[21] (MVTEC anomaly detection dataset) 和 VIsA^[22] (a large-scale virtual inspection surface anomaly dataset) 两个官方异常检测数据集上的试验进一步验证了研究所提方法的性能优势。在 $k=10$ 时, 研究所提方法在大多数类别的平均 AUC 优于对比方法, 展现了较高的鲁棒性和适用性。相比之下, PatchCore 在应对复杂形变和细微异常时稍显不足, 而 PaDiM 和 FastFlow 因特征建模依赖性较强, 鲁棒性较低。综上, 研究所提方法在多数类别的检测上均具有良好的表现, 能够更好地适用实际生产线中。

2.6 检测效果分析

面饼中的异物本质上是面饼的一种异常表现, 模型通过特征相似性比较机制和配准操作, 学习区分正常面饼和含异物面饼的特征, 从而准确完成异常检测任务。通过对真实场景中的面饼进行测试, 进一步验证研究所提方法在面饼上的检测效果。试验从测试集中随机选取图片进行检测, 结果如图 6 所示。试验中模型通过引入空




图 5 各方法试验结果对比图

Figure 5 Comparison of experimental results of different methods

间变换网络代替传统的图像预处理方法, 使其能够更加精确地提取面饼图像中的关键特征, 而通过特征配准对关键特征进行对齐, 使模型在复杂纹理背景下对面饼中的细小异物识别更加精准, 减少了因拍摄角度、不同背景等因素带来的误检和漏检, 表明模型在面饼检测任务中具有明显优势。

如图 7 所示, 对于给定的测试图像进行热力图可视化分析, 热力图中的颜色深浅异常得分呈正相关关系, 颜色越深表明该区域越有可能存在异常。通过与真实二值图像对比, 可以清晰看到研究所提方法能够高效、准确地检测出面饼表面的异物位置。

3 结论

研究针对方便面面饼表面细小异物进行检测, 提出了一种基于小样本学习与特征配准的检测方法。该方法在传统卷积神经网络的基础上, 通过在预训练残差网络中引入空间变换网络, 从而提高模型的特征提取能力; 通过利用孪生网络的特征相似性比较机制, 对提取的特征进行配准操作, 从而增强模型的异常检测能力。结果表明, 模型在自制的面饼数据集和官方基准测试集上均具



图 6 模型检测效果图

Figure 6 Model detection effect diagram




图 7 模型检测热力图

Figure 7 Heat map of model detection

有良好的检测效果,证明了其在实际生产应用中的可行性。后续可探索引入生成模型以增强模型在样本稀缺情况下的检测能力,以应对更复杂的背景和异物形态变化。

参考文献

- [1] 王春艳, 韩冰, 李晶, 等. 综述我国食品安全标准体系建设现状[J]. 中国食品学报, 2021, 21(10): 359-364.
WANG C Y, HAN B, LI J, et al. A research review on the current situation of food safety standard system construction in China[J]. Journal of Chinese Institute of Food Science and Technology, 2021, 21(10): 359-364.
- [2] 李欣铭. 食品安全监管法律法规体系完善路径探析[J]. 食品与机械, 2024, 40(8): 246-250.
LI X M. Analysis on the improvement path of food safety supervision laws and regulations system[J]. Food & Machinery, 2024, 40(8): 246-250.
- [3] 王亭. 基于机器视觉的面饼检测系统开发[D]. 成都: 电子科技大学, 2020: 15-45.
WANG T. Development of cake defect system based on machine vision[D]. Chengdu: University of Electronic Science and Technology of China, 2020: 15-45.
- [4] AHMED M, MUSTAFA H, WU M Z, et al. Few shot learning for avocado maturity determination from microwave images[J]. Journal of Agriculture and Food Research, 2024, 15: 100977.
- [5] LIAO H Y, CHEN C C, CHENG A B. Few-shot learning for bagel defect detection[C]// 2023 IEEE 6th Eurasian Conference on Educational Innovation (ECEI). Piscataway: IEEE, 2023: 143-145.
- [6] ARGÜESO D, PICON A, IRUSTA U, et al. Few-shot learning approach for plant disease classification using images taken in the field[J]. Computers and Electronics in Agriculture, 2020, 175: 105542.
- [7] JADON S. Ssm-net for plants disease identification in low data regime[C]// 2020 IEEE/ITU International Conference on Artificial Intelligence For Good (AI4G). Piscataway: IEEE, 2020: 158-163.
- [8] CHICCO D. Siamese neural networks: an overview[J]. Methods in Molecular Biology, 2021, 2190: 73-94.
- [9] JADERBERG M, SIMONYAN K, ZISSERMAN A. Spatial transformer networks[J]. Advances In Neural Information Processing Systems, 2015, 28: 2 017-2 025.
- [10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [11] HE F X, LIU T L, TAO D C. Why resnet works? residuals generalize[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(12): 5 349-5 362.
- [12] HAN Z M, LIN Z Y, FU M Y. A survey on distributed network localization from a graph laplacian perspective[J]. Journal of Systems Science and Complexity, 2024, 37(1): 273-293.
- [13] 范宜凯, 刘石坚, 潘正祥. 一种基于改进仿射变换的基础矩阵估计方法[J]. 计算机工程与科学, 2021, 43(11): 2 003-2 010.
FAN Y K, LIU S J, PAN Z X. A fundamental matrix estimation method based on improved quasi-affine transformation[J]. Computer Engineering & Science, 2021, 43(11): 2 003-2 010.
- [14] TRIPATHI S M, TIWARI A N, SINGH D. Grid-integrated permanent magnet synchronous generator based wind energy conversion systems: a technology review[J]. Renewable and Sustainable Energy Reviews, 2015, 51: 1 288-1 305.
- [15] CHEN X L, HE K K. Exploring simple siamese representation learning[C]// Proceedings of The IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2021: 15 750-15 758.
- [16] DEFARD T, SETKOV A, LOESCH A, et al. PaDiM: a patch distribution modeling framework for anomaly detection and localization[C]// International Conference on Pattern Recognition. Cham: Springer International Publishing, 2021: 475-489.
- [17] YU J, ZHENG Y, WANG X, et al. Fastflow: unsupervised anomaly detection and localization via 2d normalizing flows[J/OL]. Cornell University Library. (2021-11-15) [2024-11-20]. <https://arxiv.org/abs/2111.07677>.
- [18] YAN P, WANG G, LU L. Patchcore: a core abstraction framework for medical image segmentation[J]. Medical Image Analysis, 2022, 79: 102926.
- [19] GUDOVSKIY D, ISHIZAKA S, KOZUKA K. Cflow-ad: real-time unsupervised anomaly detection with localization via conditional normalizing flows[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Piscataway: IEEE, 2022: 98-107.
- [20] ZHENG Y, WANG X, DENG R, et al. Focus your distribution: coarse-to-fine non-contrastive learning for anomaly detection and localization[C]// 2022 IEEE International Conference on Multimedia and Expo (ICME). Piscataway: IEEE, 2022: 1-6.
- [21] BERGMANN P, FAUSER M, SATTLEGLER D, et al. Mvtec ad--a comprehensive real-world dataset for unsupervised anomaly detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2019: 9 592-9 600.
- [22] ZOU Y, JEONG J, PEMULA L, et al. Spot-the-difference self-supervised pre-training for anomaly detection and segmentation[C]// European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 392-408.