

本文引用格式: 杨志明,黄天仑,薛艳,等.不平衡样本条件下的注塑产品缺陷高精度检测方法[J].自动化与信息工程,2024,45(6):53-58;72.

YANG Zhiming, HUANG Tianlun, XUE Yan, et al. High precision detection method for defects in injection molded products under unbalanced sample conditions[J]. Automation & Information Engineering, 2024,45(6):53-58;72.

不平衡样本条件下的注塑产品缺陷高精度检测方法*

杨志明¹ 黄天仑^{2,3} 薛艳⁴ 刘家欢⁵ 钟震宇³ 张云⁵

(1.深圳市信宇人科技股份有限公司, 广东 深圳 518172

2.中国科学院深圳先进技术研究院, 广东 深圳 518055

3.广东省科学院智能制造研究所/广东省现代控制技术重点实验室, 广东 广州 510070

4.广州宝力特液压技术有限公司, 广东 广州 510070

5.华中科技大学材料科学与工程学院/材料成形与模具技术国家重点实验室,
湖北 武汉 430074)

摘要: 注塑产品缺陷的高精度检测依赖于模型提取的图像特征, 然而, 注塑产品缺陷样本收集困难, 导致训练数据集出现类别不平衡的问题, 致使模型性能下降。针对该问题, 提出一种不平衡样本条件下的注塑产品缺陷高精度检测方法。利用多尺度卷积神经网络提取多尺度图像特征, 并利用其他分类任务的图像知识, 通过两阶段迁移学习改变模型训练时的样本采样分布, 提高模型对缺陷样本图像特征的提取能力, 从而提高模型的性能。实验结果表明: 该方法具有较高的平均检测准确率, 在极端类别不平衡 ($IR = 25:1$) 的情况下, 检测准确率达到 99.26%, 相较于 3 种对比方法提高了 3.48~8.46, 满足高品质注塑产品生产的需求。

关键词: 不平衡样本; 注塑产品缺陷检测; 多尺度神经网络; 两阶段迁移学习

中图分类号: S225

文献标志码: A

文章编号: 1674-2605(2024)06-0008-07

DOI: 10.3969/j.issn.1674-2605.2024.06.008

开放获取

High Precision Detection Method for Defects in Injection Molded Products under Unbalanced Sample Conditions

YANG Zhiming¹ HUANG Tianlun^{2,3} XUE Yan⁴
LIU Jiahuan⁵ ZHONG Zhenyu³ ZHANG Yun⁵

(1.Xinyuren Technology Co., Ltd., Shenzhen 518172, China

2.Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China

3.Institute of Intelligent Manufacturing, Guangdong Academy of Sciences/Guangdong Key Laboratory of Modern Control Technology, Guangzhou 510070, China

4.Guangzhou Baolite Hydraulic Technology Co., Ltd, Guangzhou 510070, China

5.School of Materials Science and Engineering, Huazhong University of Science and Technology/
State Key Laboratory of Material Processing and Die & Mold Technology, Wuhan 430074, China)

Abstract: The high precision detection of defects in injection molded products relies on the image features extracted by the model. However, the difficulty in collecting defect samples in injection molded products leads to class imbalance in the training dataset, resulting in a decrease in model performance. A high-precision detection method for defects in injection molded products under unbalanced sample conditions is proposed to address this issue. Using multi-scale convolutional neural networks to extract multi-scale

image features, and utilizing image knowledge from other classification tasks, two-stage transfer learning is used to change the sample sampling distribution during model training, thereby improving the model's ability to extract features from defective sample images and enhancing its classification performance. The experimental results show that this method has a high average detection accuracy. In the case of extreme class imbalance (IR=25:1), the detection accuracy reaches 99.26%, which is 3.48~8.46 higher than the three comparative methods, meeting the demand for high-quality injection molded product production.

Keywords: unbalanced samples; defect detection in injection molded products; multi-scale neural network; two-stage transfer learning

0 引言

塑料注射可以成型各种复杂结构,适用于生产精密产品,具有成型周期短、效率高、生产过程易于自动化等特点。注塑产品被广泛应用于汽车、航空航天、电子电气等领域^[1-3],但其缺陷种类繁多、变化多样,导致缺陷检测难度较大,进而影响产品质量。

目前,基于深度学习的视觉检测技术已被广泛应用于注塑产品的缺陷检测^[4-6]。文献[7]采用 ResNet18 模型实现了钢板表面 6 种缺陷的检测,检测准确率达到 99.56%。文献[8]构建了基于深度学习模型的注塑产品外观缺陷分类系统,该模型包含一个 8 层的简单卷积神经网络,以整幅产品图像为输入,缺陷识别精度达到 90%以上。文献[9]将深度卷积神经网络模型作为图像特征提取器,以支持向量机为特征分类器,对树脂制品的缺陷检测准确率超过 99%。文献[10]利用卷积神经网络模型提取图像特征,以决策树为特征分类器,利用决策树的规则特性提高液晶显示器的缺陷检测性能和检测模型的可解释性,平均检测准确率约为 85%。文献[11]以卷积神经网络模型为图像特征提取器,以随机森林为特征分类器,提高了缺陷检测精度,在开源纹理图像数据集上的平均检测精度约为 99.85%。然而,当缺陷样本数量较少或样本类别不平衡时,上述模型难以提取缺陷的有效特征,导致缺陷检测准确率偏低。注塑产品的缺陷发生率较低且变化多样,现有方法难以从数量稀少的缺陷样本中提取准确描述缺陷的图像特征。因此,需要构建缺陷特征提取能力更强的图像检测模型,以解决数据不平衡导致的图像特征偏移问题,从而实现更高的缺陷检测性能。

为此,本文提出一种不平衡样本条件下的注塑产品缺陷高精度检测方法。该方法通过多尺度卷积神经网络(multi-scale convolutional neural network, MSCNN)的多分支特征提取结构,提高缺陷图像特征语义信息的丰富性和表达能力;采用两阶段迁移学习方法,改变模型训练时的样本采样分布,提高模型对缺陷样本图像特征的提取能力,实现注塑产品缺陷的高精度检测。

1 注塑产品案例分析

本文采用的注塑产品案例是一个长、宽、高约为 35 mm × 6 mm × 2 mm,表面光滑的白色壳状产品。该产品常见的缺陷类型主要有针眼、披锋、模凹、浇口等 4 种。注塑产品实物图和缺陷位置示意图如图 1 所示。




图 1 注塑产品实物图与缺陷位置示意图

该注塑产品的出模合格率约为 90%,缺陷样本较少。本文收集并标记了约 70 个披锋、80 个针眼、280 个浇口和 200 个模凹缺陷样本。这 4 种缺陷均与注塑产品的工艺流程相关,常出现在注塑产品相对固定的位置,可采用先验知识裁剪方法从原始图像中提取疑似缺陷区域的图像块。在区域图像特征识别时,该缺陷检测任务存在类别不平衡、缺陷尺度与外观多样性的问题,如浇口和模凹缺陷均有超过 20 种不同的外观形态。浇口缺陷的多种表现示例如图 2 所示。




图2 浇口缺陷的多种表现示例

2 MSCNN 模型

本文设计了一种 MSCNN 模型，通过多个特征提取分支从输入图像中同时提取概貌特征和细节特征，提高了缺陷图像特征信息的丰富性，并设计了互纠正分类器模块，使 MSCNN 模型能够从数量有限的缺陷样本中提取高质量的图像特征。MSCNN 模型结构如图 3 所示。

1) 利用 2 个卷积层从输入图像中提取图像低级特征；

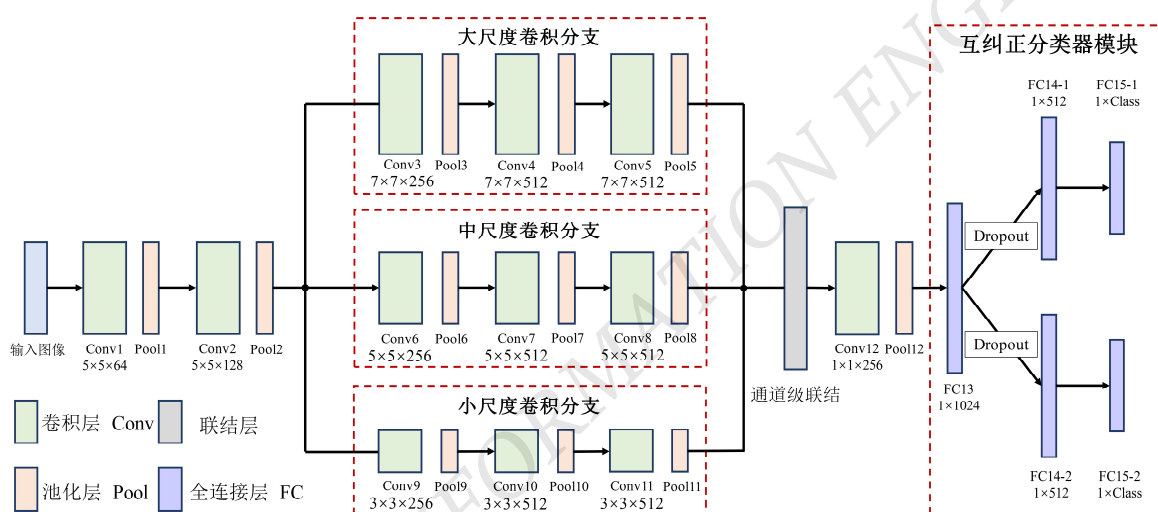


图3 MSCNN 模型结构

2) 采用 3 个感受野不同的卷积分支分别提取不同尺度的图像高级特征，其中，大尺度 (7×7) 卷积分支以较大的感受野粗略观察图像，小尺度 (3×3) 卷积分支以较小的感受野精细观察图像，中尺度 (5×5) 卷积分支则介于两者之间；

3) 将 3 个不同的卷积分支提取的多尺度图像特征，在通道维度上以并联的方式拼接在一起，实现特征汇总；

4) 利用一个 1×1 的卷积层将这些汇总的多尺度图像特征混合在一起，实现不同精细程度的多尺度图像的特征融合；

5) 利用 2 个互纠正分类器 (由 2 个全连接层 FC 组成的互相独立的分类器) 对多尺度图像特征进行分类，并将 2 个互纠正分类器预测结果的平均值，作为

模型最终的预测结果，可避免模型过度自信的问题，减轻了模型过拟合风险。

3 两阶段迁移学习模型训练

两阶段迁移学习模型训练包含类别不平衡数据集划分、第一阶段迁移学习与第二阶段迁移学习，其原理示意图如图 4 所示。

类别不平衡数据集划分方法参考文献[12]，可使类别不平衡问题变弱甚至消失。

在第一阶段迁移学习中，MSCNN 模型先在仅包含正常样本的子数据集上训练，使模型能够学习注塑产品缺陷检测任务的背景知识。MSCNN 模型含有大量的随机初始化参数，训练时需要一个大型图像数据集来防止过拟合的问题。然而，工业产品图像数据集

通常仅含有成百上千幅图像, 容易导致 MSCNN 模型过拟合, 致使其准确性和泛化性能下降。为此, 第一阶段迁移学习是大型开源图像数据集和工业产品缺陷图像数据集之间的知识迁移^[13], 即将在开源数据集 ImageNet^[14]上训练模型的图像特征知识迁移到缺陷

检测任务中。由于 MSCNN 模型在拓扑结构上与经典的 VGG-16 模型相似, 本文采用基于模型的迁移学习方法, 共享在 ImageNet 数据集上训练好的 VGG-16 模型的部分参数, 将其学习到的图像特征用于注塑产品的缺陷检测任务。

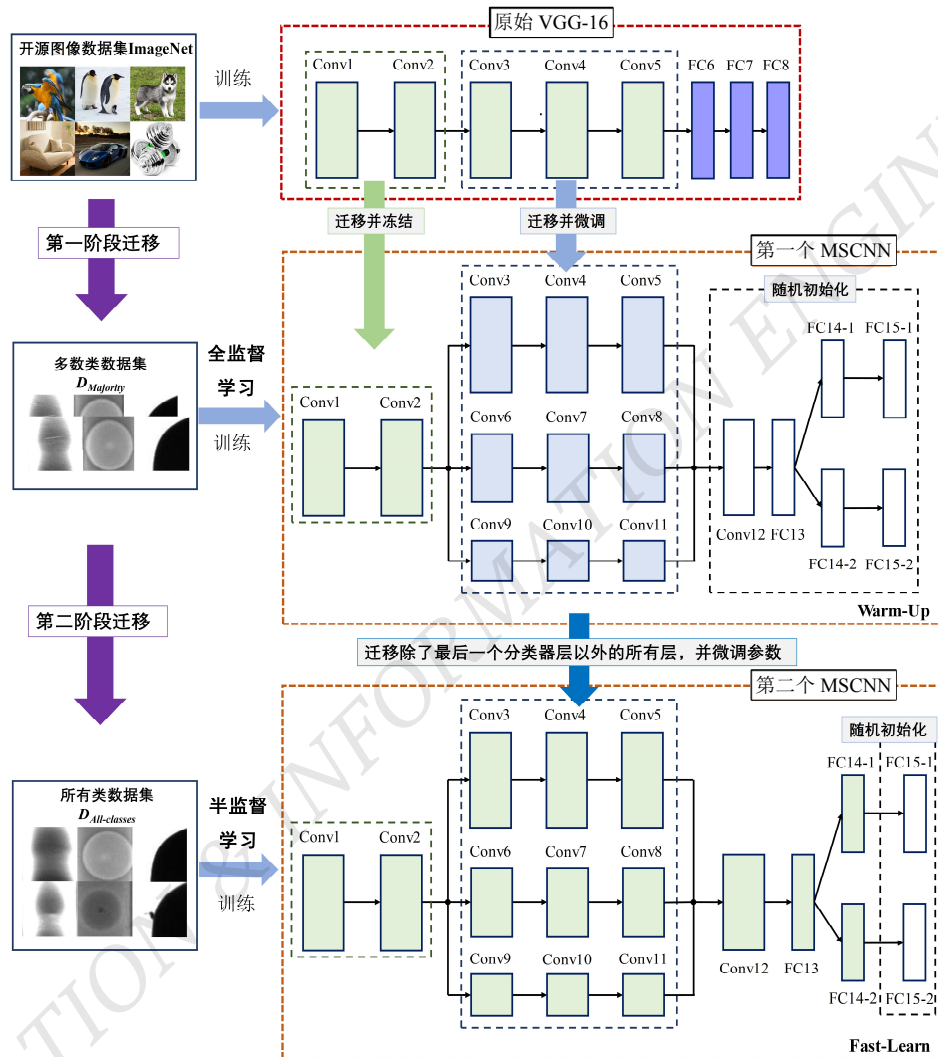


图4 两阶段迁移学习原理示意图

第二阶段迁移学习将第一阶段迁移学习得到的 MSCNN 模型参数迁移到另一个结构相似的 MSCNN 模型中。除了最后一个卷积层和全连接层的参数外, 第一个 MSCNN 模型的所有参数都被迁移到第二个 MSCNN 模型中, 并在第二阶段迁移学习的训练中继续更新, 以适应新的训练数据集。第二个 MSCNN 模型分类器的最后一层参数重新随机初始化并训练更

新。第二个 MSCNN 模型在第一个 MSCNN 模型的帮助下, 能够快速地学习从数据集中学习到缺陷图像和正常图像之间的细微差异, 实现缺陷样本的准确识别。本文将这个阶段得到的第二个 MSCNN 模型称为快速学习阶段模型。

第二阶段迁移学习中的半监督学习的训练流程可分为 3 个步骤:

1) 仅有标签样本的损失对模型总体损失函数有贡献;

2) 首先, 无标签样本被纳入 MSCNN 模型的训练过程, 并以缓慢增长的方式对模型总体损失函数做出贡献, 以防止带有错误伪标签的无标签样本破坏模型学习到的图像特征; 然后, 增加无标签样本对模型总体损失函数的贡献, 促进模型特征的学习过程;

3) MSCNN 模型在所有训练样本上微调参数。

4 实验及结果分析

本实验用于验证本文方法对注塑产品缺陷检测的有效性。网络训练实验平台配置: Python 语言、开源的深度学习框架 Tensor-Flow 和图像处理库 Open-CV、scikit-image 等。实验硬件设备: Ubuntu 系统的计算服务器, NVIDIA GeForce 1080 GPU。所有实验均在相同的软、硬件环境下完成。本文采用两阶段迁移学习方法, 不需要重新训练模型, 学习率设置在 $1 \times 10^{-4} \sim 3 \times 10^{-4}$ 之间。考虑到网络训练实验平台 GPU 的内存容量和训练样本数量, 将批量大小设置为 32 个。第一阶段迁移学习重用预训练模型的图像特征, 使 MSCNN 模型能够快速收敛, 训练轮次设置为 20 个左右。第二阶段迁移学习引入半监督学习方法, 训练轮次延长至 40 个左右。Dropout 层的神经元保留概率设置为 0.5, 选择 Adam 优化器来训练 MSCNN 模型。

在第一阶段迁移学习中, MSCNN 模型的训练过程曲线如图 5 所示。




图 5 第一阶段迁移学习中 MSCNN 模型的训练过程曲线

由图 5 可知, 训练约 5 个轮次后, MSCNN 模型

便趋于稳定, 模型训练损失值接近 0, 模型检测准确率接近 100%, 表明开源模型的图像特征知识迁移至 MSCNN 模型也有很好的特征表达能力, 能够帮助 MSCNN 模型从数量有限的样本中提取高质量的图像特征, 从而迅速达到收敛状态, 证明了第一阶段迁移学习的合理性和有效性。

在第二阶段迁移学习中, MSCNN 模型的训练过程曲线如图 6 所示。

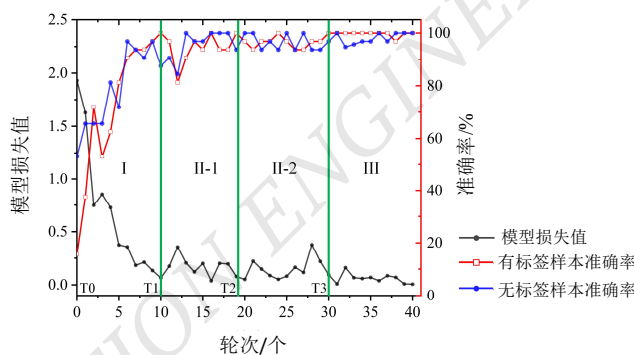


图 6 第二阶段迁移学习中 MSCNN 模型的训练过程曲线

由图 6 可知, MSCNN 模型的收敛曲线变化趋势呈现与第二阶段迁移学习中的半监督学习方法对应的 3 个区间:

1) 训练轮次在 $T_0 \sim T_1$ 之间为第一个区间 I, 无标签样本不参与训练过程, 模型在 10 个轮次内即可获得较高的检测准确率, 表明来自第一个 MSCNN 模型的图像特征能够帮助本阶段的 MSCNN 模型提取正常样本和缺陷样本的图像特征;

2) 训练轮次在 $T_1 \sim T_3$ 之间为第二个区间, 包含两个子区间 (II-1 和 II-2), 此时无标签样本逐渐加入模型训练, 且子区间 II-1 中无标签样本的损失权重较小, 子区间 II-2 中无标签样本的损失权重较大; 首先, 训练轮次 T_1 右侧的有标签样本检测准确率突降, 表明在引入无标签样本后, 模型在第一个区间 I 内学习的图像特征遭到破坏, 这是无标签样本的错误伪标签误导模型引起的; 然后, 模型检测准确率迅速上升至较高水平, 表明本文采用的互纠正分类器和半监督学习方法具有较好的纠错能力, 能够减少错误伪标签带来的不利影响, 并从无标签样本中提取出有效的图像特征; 最后, 在子区间 II-2 中, 无标签样本的损失权

重迅速增加,但模型的训练趋势无明显变化,表明模型提取到较好的图像特征,能够避免无标签样本导致的性能下降,并充分利用无标签样本的有效特征;

3) 在训练轮次 T3 之后为第三个区间 III, 此时模型的损失权重保持不变, 并对所有样本进行微调; T3 后有标签样本的检测准确率趋于稳定, 而无标签样本的检测准确率渐渐收敛, 表明模型经过 T3 个轮次的训练后, 已提取到表达能力较强的图像特征, 在有标签样本和无标签样本上均能获得良好的泛化性能。

将本文方法与 VGG-16、文献[15](VGG-16+重采样)、文献[16](VGG-16+Focal Loss)方法在不同的不平衡比例下进行对比实验, 并采用平均检测准确率(Ave_Acc)作为评价指标, 结果如表 1 所示, 其中最佳性能加粗标出。

表 1 4 种方法在 3 种类别不平衡比例下的平均检测准确率 %

| 实验序号 | 方法配置 | 类别不平衡比例 | | |
|------|-------------------|--------------|--------------|--------------|
| | | 5 : 1 | 10 : 1 | 25 : 1 |
| 1 | VGG-16 | 96.75 | 94.73 | 90.80 |
| 2 | VGG-16+重采样 | 98.36 | 97.62 | 95.78 |
| 3 | VGG-16+Focal Loss | 97.66 | 96.99 | 95.18 |
| 4 | 本文方法 | 99.39 | 99.28 | 99.26 |

由表 1 可知, 4 种方法在注塑产品缺陷数据集上的平均检测准确率均随着类别不平衡比例的增大而减小, 证明类别不平衡问题会降低模型的性能, 且类别不平衡比例越大, 模型性能越差。这是因为类别不平衡比例较大时, 模型从数据集中随机抽取的缺陷样本数量较少, 导致模型提取的图像特征偏向数量较多的正常样本, 使缺陷样本图像特征的表达力不足, 检测准确率下降。

然而, 本文方法在 3 种类别不平衡比例的数据集上获得的平均检测准确率相当, 均达到 99% 以上, 表明 MSCNN 模型和两阶段迁移学习方法能够较好地解决类别不平衡问题, 且均能实现较高的模型性能。

此外, 表 1 中实验 2、3 的结果表明, 文献[15]、

[16]方法的检测性能相近, 均不如本文方法。这两种方法本质上均为改变数据集中样本的抽样权重, 并未实质性地改变模型训练时随机抽取样本批次的组成, 即模型使用的数据集依旧不平衡, 特别是当类别不平衡比例较大时, 这两种方法的模型性能较差。

5 结论

注塑产品缺陷样本数量较少, 导致图像数据集类别不平衡; 且缺陷外观变化多样, 导致图像样本类内差异较大, 从而降低了缺陷检测的准确性。为此, 本文提出了 MSCNN 模型, 通过多分支特征提取结构同时提取概貌特征和细节特征, 提高了图像特征的表达能力和辨识能力, 解决了样本类内差异大的问题; 提出两阶段迁移学习模型训练策略, 将类别不平衡数据集转化为两个类别平衡的子数据集, 采用两阶段迁移学习, 依次在这两个类别平衡的子数据集上训练 MSCNN 模型, 从而解决了类别不平衡的问题。注塑产品缺陷数据集上的实验结果表明, 与 VGG-16、文献[15]、[16]的方法相比, 本文方法具有更高的平均检测准确率, 在极端类别不平衡 (IR = 25 : 1) 的情况下, 检测准确率达到 99.26%, 提升了 3.48~8.46, 满足高品质注塑产品生产的需求。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

参考文献

- [1] LIU J, MACGREGOR J.F. Modeling and optimization of product appearance: application to injection-molded plastic panels[J]. Industrial & Engineering Chemistry Research, 2005, 44(13):4687-4696.
- [2] 李伟国,张志斌,卢森锐,等.世界技能大赛及塑料模具工程项目综述[J].机床与液压,2021,49(10):177-183.
- [3] 张天友,殷蕾,张军,等.Moldflow 填充案例在模具教学中的应用[J].机电工程技术,2022,51(12):200-203;237.
- [4] ZHAO W, HUANG H, LI D, et al. Pointer defect detection based on transfer learning and improved cascade-RCNN[J]. Sensors, 2020, 20(17): 4939.

(下转第 72 页)