

基于 EfficientNetV2 的鸡蛋无损检测与品质分级研究

陈嵩¹,王鲁²,孙震¹,赵亚茹¹,张承明^{1*}

1. 山东农业大学信息科学与工程学院, 山东 泰安 271018

2. 山东女子学院人工智能学院, 山东 济南 250300

摘要: 鸡蛋品质的无损检测是鸡蛋生产、销售与加工过程中的重要环节之一,传统的鸡蛋品质检测主要依靠人工进行破坏性检测,存在效率低、主观误差大等问题,而现有无损检测技术多局限于单一表征,难以实现内外部品质的综合分级。针对此类问题,提出了一种基于 EfficientNetV2 框架的鸡蛋品质判别模型,首先针对鸡蛋内外部品质进行无损检测,利用边缘检测、阈值分割及特征融合算法针对表征进行提取,将图像特征和数值特征通过拼接(concatenation)的方式进行融合,实现将所有特征向量连接成一个更长的向量,其次在 EfficientNetV2 基础上以裂纹、斑点、气室高度指标为特征参数,实现对鸡蛋内外部品质的综合表征,并将样本按 7:2:1 的比例分为训练集、验证集和测试集,并基于深度学习网络建立判别模型,在深度可分离卷积中引入 Fused-MBConv 模块以避免进行多次冗余的激活操作来减少结构占用,通过 NAS 网络搜索技术以优化网络架构,完善对鸡蛋品质进行分级的任务。试验结果显示, EfficientNetV2 模型的准确率为 95.76%,较改进前提升了 1.55 个百分点,参数量减少 20%,浮点计算量降低 2.33%,其综合性能明显优于 GoogleNet、VGG-16、ResNet-50 等主流模型。证明本文方法在针对鸡蛋品质进行检测与分级的任务实现上是可行的。

关键词: 鸡蛋; 无损检测; 品质分级; 机器视觉; EfficientNetV2

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-2324(2025)06-1018-10

Non-Destructive Detection and Quality Grading of Eggs Based on EfficientNetV2

CHEN Song¹, WANG Lu², SUN Zhen¹, ZHAO Ya-Ru¹, ZHANG Cheng-ming^{1*}

1. College of Information Science and Engineering/Shandong Agricultural University, Tai'an 271018, China

2. School of Artificial Intelligence/Shandong Women's University, Jinan 250300, China

Abstract: Non-destructive detection of egg quality is one of the crucial steps in the production, sales and processing of eggs. Traditional egg quality detection mainly relies on manual destructive testing, which has problems such as low efficiency and significant subjective errors. Meanwhile, existing non-destructive detection technologies are often limited to single characterization, making it difficult to achieve comprehensive grading of both internal and external quality. To address these issues, this study proposes an egg quality discrimination model based on the EfficientNetV2 framework. Firstly, non-destructive detection of the internal and external quality of eggs is conducted. Edge detection, threshold segmentation, and feature fusion algorithms are employed to extract the features. Image features and numerical features are fused via concatenation, connecting all feature vectors into a longer vector. Secondly, based on the EfficientNetV2, crack, spot and air cell height indicators are used as feature parameters to achieve comprehensive characterization of the internal and external quality of eggs. The samples are divided into training, validation and test sets at a ratio of 7 : 2 : 1, and a discrimination model is established based on the deep learning network. The Fused-MBConv module is introduced into the depthwise separable convolution to avoid multiple redundant activation operations, thereby reducing structural occupation. Furthermore, NAS network search technology is applied to optimize the network architecture, enhancing egg quality grading tasks. The experimental results show that the accuracy of the EfficientNetV2 model is 95.76%, which is 1.55 percentage points higher than that before the improvement. Meanwhile, the number of parameters decreases by 20%, and the floating-point computation quantity reduces by 2.33%. Its comprehensive performance is significantly better than that of mainstream models such as GoogleNet, VGG-16 and ResNet-50. These findings demonstrate the feasibility of the proposed method for egg quality detection and grading tasks.

Keywords: Eggs; non-destructive detection; quality grading; machine vision; EfficientNetV2

收稿日期: 2025-01-27

修回日期: 2025-11-14

第1作者简介: 陈嵩(2001-),男,硕士研究生,研究方向:计算机视觉。E-mail: cs20011028@163.com

*通讯作者: Author for correspondence. E-mail: chming@sdau.edu.cn

随着人们生活水平的提高,对禽蛋产品的品质要求也越来越高。因此,针对鸡蛋品质分级的研究,对禽蛋产品质量的提升和食品安全的保障具有重要意义。针对鸡蛋的品质而言,内部品质是衡量鸡蛋质量的关键,包括是否存在血斑、肉斑等异物等都作为其衡量标准之一^[1]。通过研究表明,由鸡蛋品种、周龄、产蛋姿态、产蛋时间、健康状况等因素造成的蛋壳破损率占总产蛋量的11%,而在采集、包装、分级、运输等整条蛋生产链中甚至高达20%^[2],传统的内部品质检测方法,例如:理化检测往往需要对鸡蛋进行破坏取样来测量鸡蛋中的化学成分或物理性质来评估其品质,不仅操作步骤繁多、效率较低,且容易导致资源浪费。因此,通过快速的无损检测方法挑选出其中的缺陷蛋,对保障食品安全、预防变质蛋的产生有重要意义^[3]。

鸡蛋作为重要的日常食品,其品质直接关系到消费者健康与食品安全。近年来,国内外学者在鸡蛋品质检测领域展开了多角度探索,涵盖理化检测、光谱成像、超声波检测以及机器视觉与图像处理等技术,旨在实现鸡蛋新鲜度和整体品质的快速无损检测。庄珑昱等^[4]通过对外部测定颜色、光泽、蛋壳强度与厚度、斑点,对内部测定蛋白质、卵黄膜强度、血斑等表征进行理化检测方法,探究对鸡蛋整体品质的检测分级与影响因素,其所提出的多类表征与测定方法为研究提供了可靠依据^[5]。

另一方面,随着机器视觉与图像处理技术的发展,利用该方法进行新鲜度检测的研究日渐增多,刘超等^[6]采用CIFAR-10数据集对EfficientNet模型进行训练,通过进行测试和验证,实现了该方法在猪肉新鲜度识别中的平均准确率达到98.62%,但此项研究只针对猪肉品质,对于鸡蛋品质及无损检测还未做研究。陈羽丽^[7]等利用EfficientNet构建了基于迁移学习的网络,用于训练鸡蛋裂纹与完好鸡蛋的分类模型。最终实现了96.7%的综合检测准确率,但此研究也只针对裂纹表征对品质进行检测的层面,虽然有效提升了裂纹检测的准确性,但对于针对整体鸡蛋的品质分级评价则是存在说服力不足的缺点。

鉴于鸡蛋蛋壳较厚且质密,其内部性状难以通过图像显现且结构复杂^[8,9],部分学者尝试从

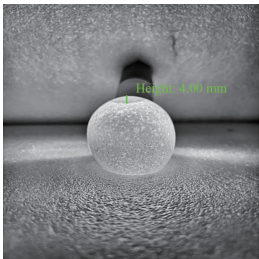
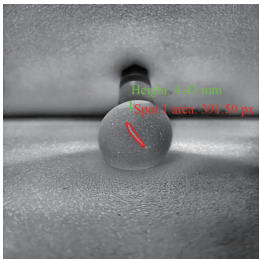
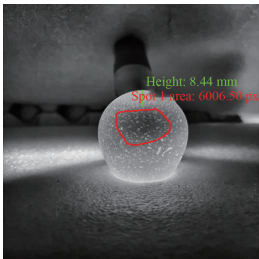
内部特征入手进行检测。Jiang等^[10]针对鸡蛋内部的表征研究,将关注点放到了鸡蛋气室与蛋黄区域上,基于GoogLeNet模型进行研究,融合气室图像特征与光谱数据,实现了对内部特征的精细化提取,使其对目标更好的进行关注,最终实现鸡蛋的新鲜度识别准确率达到94.05%。然而,该研究主要关注内部表征且特征融合方法没有体现在机器视觉与图像处理层面,对于气室和蛋黄特征与新鲜度之间的具体关系探讨不够深入。Botta等^[3]在蛋壳裂纹检测中,将图像纹理特征与蛋壳厚度数值特征拼接,显著提高了裂纹识别的准确性,但没有结合内部的表征数据采用融合的方法进行研究。沈等^[11]建立BP神经网络,在探究气室特征与蛋黄特征方法中,建立了新鲜度的特征值关系模型,识别新鲜度等级的最高准确率达到92%。刘等^[12]基于改进MobileNetV3-Large的轻量级模型,面向鸡蛋内部气室和蛋黄的形态特征变化并不显著的问题,通过提高对鸡蛋内部形态微小变化特征检测水平,最终实现MobileNetV3-DA模型在测试集上的准确率为97.26%,但该检测也仅仅表现在内部表征的新鲜度层面,对于鸡蛋其他品质指标的关联性分析尚显不足。因此,多数系统仅采用单一光谱表征手段,且普遍忽视内外部品质指标的关联性,导致综合分级准确率难以突破行业瓶颈。为此,本研究构建多模态表征融合框架以整合图像纹理特征与物理参数指标,开发改进型深度可分离卷积模块优化网络轻量化设计,引入神经架构搜索技术实现特征提取效率的显著提升,为实现鸡蛋的内外部品质的快速检测与分级,将通过有效的图像处理算法和计算机视觉技术对鸡蛋内外部品质进行快速、无损检测与品质分级。

1 材料与方法

1.1 常规新鲜度分级标准

关于鸡蛋新鲜度,国标SB/T 10638-2011的分级标准和鲜鸡蛋品质与分级团体标准T/CAAA 092—2022(见表1)^[13-15]指出鸡蛋的外观要求及气室高度与其品质密切相关,本文通过外部裂纹及斑点的表征与内部气室的图像特征进行研究。

表 1 分级标准
Table 1 Classification Standards

指标 Indicator	鲜品等级 Fresh product grade		
	优级 Premium grade	合格 Qualified grade	不合格 Unqualified grade
破损程度	未破损	未破损	破损
蛋壳污点	干净无污物,蛋壳颜色均匀	少量污物,蛋壳颜色均匀	可见霉斑,蛋壳颜色不一
气室高度/MM	≤4	>4且≤8	>8
形态			

注:Height表示气室高度;Spot表示斑点面积。在不合格级别中若单项指标达到不合格的明确标准,则无论其他指标如何均归为不合格。

Note: Height indicates the air cell height, and Spot represents the spot area. In the unqualified grade, if any single indicator meets the clearly defined unqualified standard, the sample will be classified as unqualified, regardless of the values of other indicators.

1.2 图像采集

数据采集地:山东省济宁市汶上县农业科技创新园。

光源:LED环形光源;功率:1.1W;型号:KW-R4225,上海芯龙光电科技股份有限公司生产;

相机:iPhone 15,有效像素为4800万像素,具备100%对焦像素、f/1.6光圈,苹果公司生产。

照蛋灯:LED强光专用照蛋器;功率:10W;杭州德意电器股份有限公司生产。

在本研究中,数据图像的采集工作是通过选取人工制造的裂纹鸡蛋,使用相机从两个不同角度对不同姿态鸡蛋进行拍摄,每个视角下采集多张图片,以增强模型对各种姿态下鸡蛋特征的识别能力,提高鲁棒性。如图1所示。实验采用强光LED环形光源,其中光源的打光方式为亮视野,光源以一定倾斜角度照射鸡蛋表面,从而避免直射产生强反光。最终,所有图像经过预处理,包括去噪和增强,为后续的无损检测与品质分级提供可靠的数据支撑。

本研究所有实验所用的鸡蛋样品均来源于芦花鸡品种,经处理表面污斑后通过人工仔细检查,确认鸡蛋均为无裂纹。控制条件保证在温度和湿度适宜的环境中,通过人为的方法制作实验




图 1 数据采集示例
Fig. 1 Data collection example

所用裂纹鸡蛋样品,以减少意外破损。本研究中通过工具小锤和压缩器在蛋壳上施加均匀的压力,注意力度应适中以产生微小裂纹,在每次施压后,仔细检查蛋壳,确保裂纹长度在1.5cm左右,并符合裂纹的标准。最后对无裂纹鸡蛋样品和裂纹鸡蛋样品进行图像的采集与处理。同时,以鸡蛋整体作为参照,通过轮廓检测与测量方法依据图像属性DPI,针对气室高度等多类表征采取像素值提取的方法来获取具体数值,并在模型训练时利用TensorBoard可视化工具监控关键指标。

1.3 鸡蛋图像预处理

数据采集工作通过摄像系统与光源配合完成,在基于EfficientNetV2的鸡蛋无损检测与品质分级研究中,数据采集和图像预处理是确保检

测系统准确性和鲁棒性的重要基础环节。通过对原始图像进行灰度化处理 and 图像自适应均衡化,去除RGB通道的冗余信息,去除多余的色彩信息,仅保留亮度特征^[16],而针对采集过程中可能存在的光照不均和亮度变化问题,采用对比度限制(Contrast Limited Adaptive Histogram

Equalization, CLAHE)技术进行调整,使得处理后的图像在保留细节的同时,减少亮度不均匀引起的影晌^[17],此外包括随机水平翻转、随机旋转、颜色抖动以及MixUp增强,以提升模型的泛化能力,最终得到经过数据增强处理后的图像(见图2)。

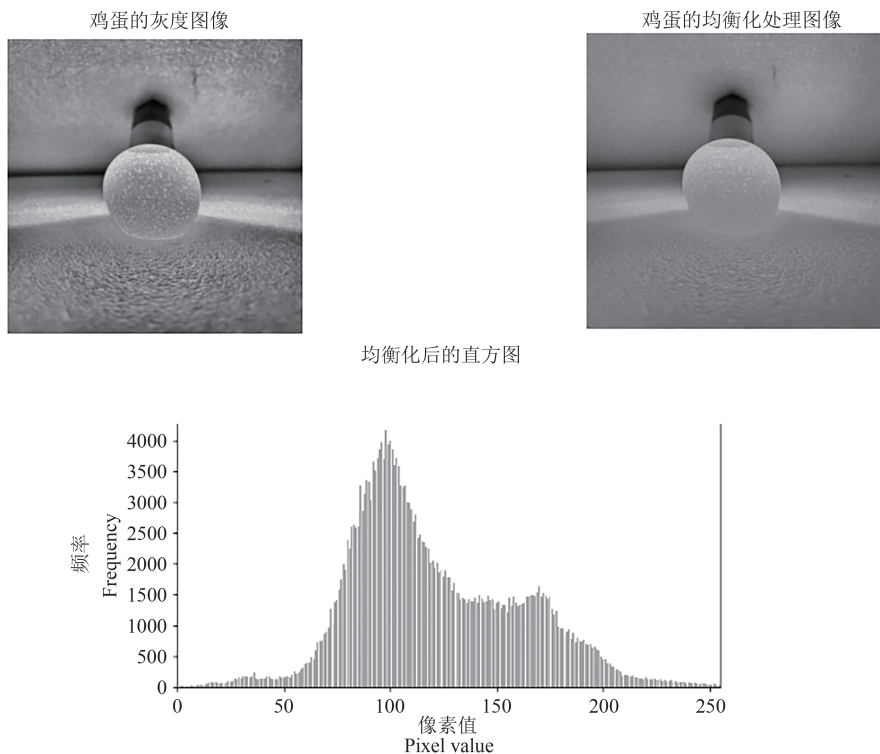


图2 鸡蛋图像的均衡化处理

Fig. 2 Equalization processing of egg image

经过预处理最终获得3 120幅图像数据集,其中,本研究将按照数据集比例将样本中的1 104幅优质品、1 025幅合格品和991幅不合格品通过随机选取,划分为不同数据集进行模型训练。

2 基于EfficientNetV2的鸡蛋品质分类方法

2.1 EfficientNetV2网络简介

2.1.1 EfficientNetV2模型整体结构 EfficientNetV2网络由Tan^[18-20]等学者于2021年提出,该架构在原始EfficientNet模型基础上进行了系统性改进。尽管EfficientNet已经在多个方面取得显著成就,但它的有效性和泛化能力对每层Stage进行同等放大的策略并非是最优的,并且受到图像尺寸过大的问题影响,导致在浅层

网络中使用Depthwise convolutions时速度会变慢。为了解决这些问题,EfficientNetV2应运而生,通过在EfficientNetV1的基础上进行的多项改进,其中包括引入了Fused-MBConv结构,通过融合扩张卷积和深度可分离卷积,采用标准的3×3卷积层来简化网络结构,降低计算成本,同时配合优化的复合缩放策略来适应Fused-MBConv结构,实现了在不同规模下效率与性能的最佳平衡。此外,EfficientNetV2还采用渐进式学习(Progressive Learning)策略,从较小模型开始训练,逐步扩展到更大规模,加速收敛并提升模型性能。通过这些改进,EfficientNetV2在保持准确率的同时,也实现了更快的训练速度和更低的参数量^[21]。EfficientNetV2网络结构(见图3)。

2.1.2 特征层信息融合 信息融合中的特征拼接

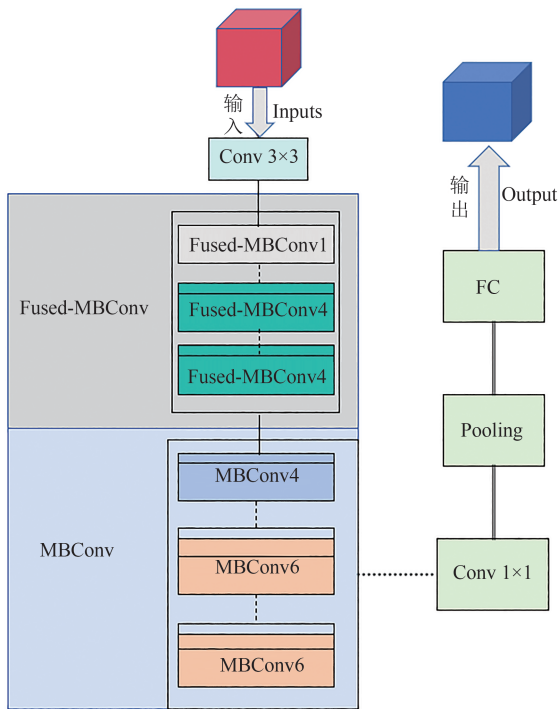


图3 EfficientNetV2 网络结构
Fig. 3 EfficientNetV2 network architecture

方法是一种将来自不同源或不同层次的特征向量在某一维度(通常是通道维度或特征维度)上进行直接连接的技术,以形成更宽或更丰富的特征表示。已有研究表明,相比于其他特征融合,特征层信息融合可以提高特征的区分度和稳定性,降低特征的冗余度和噪声干扰,在较短的时间内提取出数据的关键特征^[22]。基于此,本研究选择拼接融合的方法对数据进行信息融合,在多分支网络结构中,将不同分支的输出进行拼接以

整合针对鸡蛋研究的图像特征和数值特征信息。该方法通过整合来自不同源(如图像特征和内部气室高度的数值特征)的互补信息,显著增强了特征表示的全面性和丰富性,进而提升模型对鸡蛋品质分级的准确性和鲁棒性。

2.1.3 Fused-MBConv (Fused Mobile Inverted Bottleneck Convolution) 模块 Fused-MBConv 模块是 EfficientNetV2 中的一项重要创新,其目的是在提高计算效率的同时,降低模型的复杂度。在传统的 MBConv 模块中,主要由扩展卷积、深度可分离卷积和逐通道卷积组成,其中每个卷积操作在 MBConv 中是独立进行的,且它们通常需要分开计算,导致了计算效率低下和较高的内存访问开销。Fused-MBConv 结构则是将 MBConv 结构主分支中的 1x1 扩展卷积和 3x3 深度卷积替换为一个标准的 3x3 卷积,通过使用更大尺寸的卷积核,例如 3x3 卷积代替原本的扩展卷积和深度可分离卷积组合的方式,进而减少多个卷积步骤带来的计算和内存负担,使得每个卷积层可以在单次运算中完成多项任务,从而减少了计算量(FLOPs)和模型的参数量。

在实际应用分类工作中,Fused-MBConv 在卷积操作后通过快速的激活函数处理,可以避免在传统结构中进行多次的激活操作来进一步提升计算效率。通过这种方式,不仅减少了冗余计算,还加速了推理过程,尤其是在硬件加速器上的效果更加显著。具体来说,Fused-MBConv 模块结构(见图4)优化了内存占用,适用于低延迟和低计算量的实时应用。

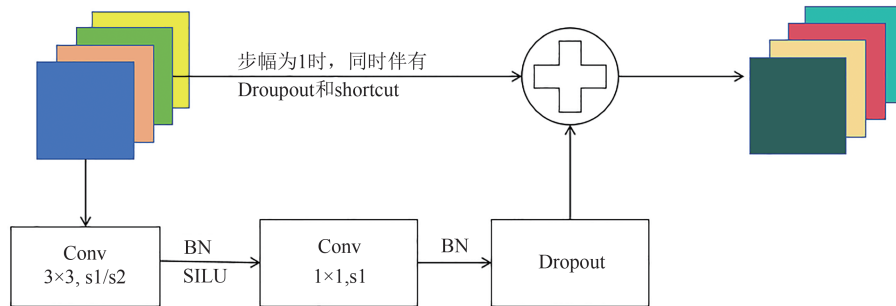


图4 Fused-MBConv 模块
Fig. 4 Fused-MBConv module

2.1.4 模型的构建与训练 EfficientNetV2 采用 training-aware NAS 来设计,优化目标包括准确率(accuracy)、参数效率(parameter efficiency)和训练效率(training efficiency),在 EfficientNetV2

中,存在 3 种不同的模型结构,分别是 EfficientNetV2-S^[18-20]、EfficientNetV2-L^[18-20]、EfficientNetV2-M^[23]。这些模型在网络结构的深度和输入图片的尺寸上有所区别,但其他方面保

持一致,包括使用了 MobileNetV2 和 Inverted Residuals 的变体,例如 Fused-MBConv 层也是一种更高效的 MBConv 块。Fused-MBConv 层通过融合和简化原有组件,大大减少了参数数量^[24],实现了更高效的计算和训练性能。它将扩张卷积和深度可分离卷积合二为一,使用一个标准的 3×3 卷积代替。这个单一的卷积层既负责通道扩张,又可以完成空间特征的提取工作,虽然其中仍有 SE 模块^[25],但在实际实现中并不存在。当 expansion 等于 1 时,主分支包含一个 3×3 卷积,紧随其后的是 BN 和 SILU 激活函数。如果 expansion 大于 1,则主分支首先应

用一个升维的 3×3 卷积,接着是 BN 和 SILU 激活函数,然后是一个 1×1 卷积,同样伴随 BN 和 Dropout,而只有在 stride 为 1 并且输入与输出的通道数相同时,才会存在 shortcut 连接。此外,只有存在 shortcut 连接的情况下,才会应用 Dropout,这里的 Dropout 仅指 Fused-MBConv 和 MBConv 中的 Dropout,不包括在最后一层全连接前的 Dropout,而为避免批量归一化 (BN) 和 Dropout 在一起使用可能会产生的问题,EfficientNetV2 将采用以一定概率完全丢弃主分支输出的方法,即直接使用上一层的输出来实现过程。EfficientNetV2-S 结构如表 2 所示。

表 2 EfficientNetV2-S 结构
Table 2 EfficientNetV2-S architecture

模块 Module	操作 Operation	步幅 Stride	输出特征矩阵通道数 Output feature matrix channel number	层数 Number of layers
模块 1	Conv3×3	2	24	1
模块 2	Fused-MBConv1, k3×3	1	24	1
模块 3	Fused-MBConv6, k3×3	2	68	4
模块 4	Fused-MBConv6, k5×5	2	64	4
模块 5	MBConv4, k3×3, SE0.25	2	128	6
模块 6	MBConv6, k5×5, SE0.25	1	160	9
模块 7	MBConv6, k5×5, SE0.25	2	256	15
	Conv11&Pooling&FC	-	1280	1

本研究针对 EfficientNetV2 模型基于 ImageNet-1k 数据集的预训练过程中,输入图像尺寸统一调整为 300×300 像素,优化器选用 AdamW,并采用余弦退火学习率调度策略 (Cosine Annealing Learning Rate Schedule),训练时批次大小为 64,共训练 100 个周期。在迁移至鸡蛋品质检测任务时,模型的全连接层被替换为适应三分类的输出层,其余层均保留预训练权重并参与微调,前 25 个周期仅训练全连接层,然后逐步解冻并微调网络深层特征提取模块,最终解冻全部网络层进行整体优化,以平衡特征迁移与任务适应性的关系,避免深层特征因过早调整而丢失通用性。

2.1.5 实验评价指标 本研究利用基于 EfficientNetV2 的模型在测试集上评估模型的性能,具体指标包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1-score)^[26]。此外,为了评估模型的复杂度,本文还计算了模型的参数量 (Parameters) 和浮点计算

量 (FLOPs)。为体现每一类样本的重要性,本研究采用宏平均 (Macro-averaging) 的方法计算精确率、召回率及 F1 分数。各指标的计算公式详见公式 (1) 至 (4)。

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Precision}_i = \frac{TP_i}{TP_i + FP_i} \quad (2)$$

$$\text{Recall}_i = \frac{TP_i}{TP_i + FN_i} \quad (3)$$

$$\text{F1-score}_i = 2 \cdot \frac{\text{Precision}_i \cdot \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad (4)$$

其中 N 表示样本总数, Precision_i 、 Recall_i 和 F1-score_i 分别表示第 i 类样本的精确率、召回率和 F1 分数。假设数据集包含 N 个样本,对于每类样本,第 i 类的精确率 Precision_i 表示在所有预测为该类的样本中,正确预测的比例;召回率 Recall_i 表示实际属于该类的样本中被正确预测的比例;F1 分数则是精确率和召回率的调和平均。总体指标如准确率衡量了模型预测正确样

本的比例,而通过宏平均(Macro Average)和加权平均(Weighted Average)方式,可以分别反映类别分布均衡或不均衡条件下模型的全局表现。此外,基于混淆矩阵的统计量,能够直观揭示模型在不同类别上的偏好和弱点,帮助识别需要优化的方向。通过这些指标的综合分析,本研究将全面评估基于 EfficientNetV2 的模型在鸡蛋无损检测与品质分级中的有效性和复杂度。

3 结果与分析

3.1 实验过程

为充分评估 EfficientNetV2 网络针对鸡蛋品质分级识别任务上的卓越性能与优势,本研究设置对比实验选取了同样具备优势的深度神经网络 CNN 包括 ResNet, VGG 等进行性能比较。

针对鸡蛋的无损检测与品质分级任务,确定

将其分为三分类的问题,在模型构建与训练过程中,为了优化模型训练效率并提升识别准确性,我们首先对 EfficientNetV2 网络进行了预训练。与 EfficientNetV1^[27]不同, EfficientNetV2 除了使用 MBConv 之外,在网络浅层也使用了 Fused-MBConv 模块,并将 EfficientNetV2 模型最后一个全连接层的输出节点数改为 3,使得模型的输出对应于三个类别的概率分布,实现模型适用三分类的问题。另外,鉴于卷积操作主要局限于局部空间内,通过引入全局平均池化的系统策略,旨在将每个通道上的空间特征进行编码并压缩为一个全局特征向量,从而实现特征信息的有效融合。对预训练后的模型通过优化进行消融实验,将其学习率设为 0.001。针对对比网络,包括 VGG-16^[28]、ResNet-50^[29]和 GoogLeNet^[30]采用 Adam 优化方法,则是将其学习率设为 0.001。通过函数对图片进行处理,各个模型的参数如表 3 所示。

表 3 深度学习模型参数

Table 3 Parameters of deep learning models

模型 Model	图像输入大小 Image input size	优化器参数 Optimizer parameters	学习率 Learning rate
GoogleNet	224×224	Adam($\beta_1=0.9, \beta_2=0.999$)	0.001
ResNet-50	224×224	Adam($\beta_1=0.9, \beta_2=0.999$)	0.001
VGG-16	224×224	Adam($\beta_1=0.9, \beta_2=0.999$)	0.001
EfficientNetV2	300×300	Adam($\beta_1=0.9, \beta_2=0.999$)	0.001

3.2 实验结果与分析

3.2.1 EfficientV2 与其他模型性能对比 在本研究中,通过将 EfficientNetV2 模型与多种同类型优秀的网络模型进行对比实验,包括 VGG-16、ResNet-50 和 GoogLeNet。其中所有模型的参数设置与原始文献中的配置保持一致,仅调整最后分类器的类别数量为 3。实验结果如表 4 所示。EfficientNetV2 在多个性能指标上均优于其他模型。与 VGG-16 和 ResNet-50 相比, EfficientNetV2 不仅在准确率上具有明显优势,同时在参数量和浮点计算量上也有显著的降低。与 GoogLeNet 相比, EfficientNetV2 虽然模型复杂度稍高,但其识别准确率却有所提升,提高了 1.22 个百分点,这表明 EfficientNetV2 在设计上优化了精度与效率的平衡,能够满足轻量化模型的需求,同时提供更高的检测准确率。在验证集的实验中, EfficientNetV2 不仅在准确率上占据领先地位,且具有最快的收敛速度,对比召回率

和 F1 分数也分别提高了 1.48 和 2.46 个百分点,这些结果表明, EfficientNetV2 成功地平衡了高识别准确率和低模型复杂度,展现了其在高效性与轻量化方面的优越性。

综上所述, EfficientNetV2 作为本研究中提出的模型,凭借其较高的识别准确率和较低的计算复杂度,能够有效满足鸡蛋品质检测任务对高效性和高精度的需求,展现了其在实际应用中的优势。

3.2.2 消融实验结果 本研究通过消融实验来验证基于 EfficientNetV2 的鸡蛋无损检测与品质分级模型优化策略的可行性,实验结果如表 5 所示。由表 5 可见,原模型的识别精确率为 94.21%,浮点计算量为 0.64 G。在最后结构中去掉一个 1×1 的卷积层,虽然模型复杂度基本相同,模型准确率也仅提升了 0.27 个百分点,但参数量降低了 2.2 M,浮点计算量降低 17%,验证了去掉最后一个卷积层的优化效果。进一步将

表 4 不同模型在测试集上的性能对比

Table 4 Performance comparison of different models on the test set

模型 Model	准确率/% Accuracy	召回率/% Recall	F1 分数/% F1-score	参数量/M Parameter quantity	FLOPs/G
VGG-16	90.22	90.21	90.15	134.28	15.46
ResNet-50	92.47	93.11	92.54	23.52	4.13
GoogleNet	94.54	94.23	93.45	5.98	1.58
EfficientNetV2	95.76	95.71	95.71	22	4.1

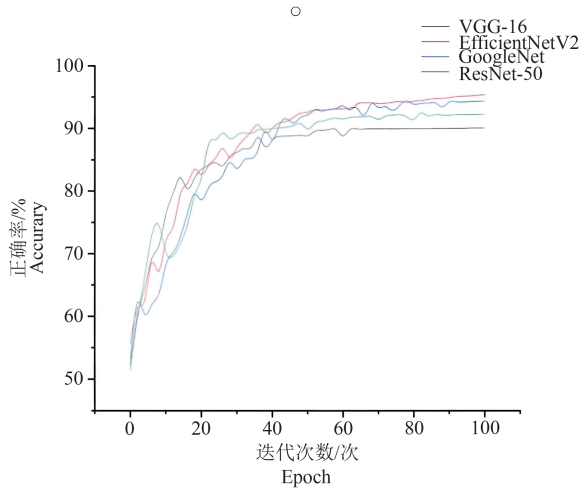


图 5 不同模型的正确率曲线图

Fig. 5 Accuracy curves of different models

Fused-MBConv 替换为 MBConv 后,精确率提升了 0.23 个百分点,表明 Fused-MBConv 在减少计算复杂度的同时保持了良好的识别性能。结合两种策略后,模型准确率共提升了 1.55 个百分点,综合性能显著提升。最终,结合所有优化策略的 EfficientNetV2 模型,相比原始 EfficientNet-B0 模型,精确率提升至 95.76%,参数量减少 20%,浮点计算量降低 2.33%。

图 5 展示的训练损失曲线表明, EfficientNetV2-S 在收敛速度和精度上均优于原模型,进一步验证了优化策略的有效性。同时,通过对验证集混淆矩阵和错误样本的详细分析,发现部分误差主要源于图像预处理过程中的光照不均、噪声干扰

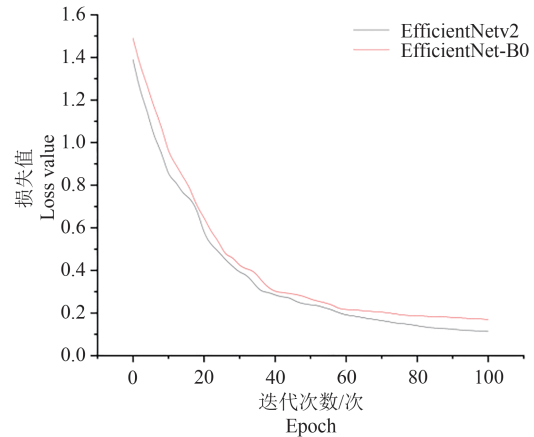


图 6 损失值变化曲线图

Fig. 6 Loss value variation curves

及样本类别分布不平衡问题,导致模型在捕捉鸡蛋表面细微裂纹和斑点特征时存在一定局限,从而影响了部分样本的正确分类。针对这些问题,本研究分析在数据层面引入更丰富的数据增强策略以扩充样本多样性,在模型结构中引入注意力机制和多尺度特征融合模块,来进一步增强对关键局部特征的提取能力,通过调优超参数和采用加权损失函数来有效缓解类别不平衡所带来的影响。

可视化方面,模型在裂纹与斑点检测任务中的若干测试样本进行目视检查,可观察到模型输出的检测框能够紧密包围各种形状和尺寸的缺陷区域,与人工标注框重叠度普遍较高,体现了特征融合后网络在定位多样化目标时的精准性。

表 5 消融实验结果

Table 5 Ablation experiment results

MBConv→Fused-MBConv	Remove-MBConv	准确率/% Accuracy	召回率/% Recall	F1 分数/% F1-score	参数量/M Parameter quantity	FLOPs/G
×	×	94.21	94.18	94.83	24.0	0.64
×	√	94.44	94.85	94.84	23.6	0.89
√	×	94.48	94.43	94.97	22.2	0.47
√	√	95.76	95.71	96.16	22.0	0.41

在细小裂纹与微小斑点场景中,Fused-MBConv模块对局部纹理信息的高效提取,使模型在低对比度条件下依然能够稳定地捕捉目标边界,从定性角度证明了各创新模块对目标检测能力的协同提升。

总的来说,所提出的优化策略显著提高了EfficientNetV2模型的性能,特别是在鸡蛋无损检测与品质分级任务中,展现了更优的性能效果。

4 结论

针对鸡蛋无损检测与品质分级方法的研究问题,本研究利用EfficientNetV2网络的高效性与适应性,将其应用于鸡蛋的品质分级任务中,能够有效识别鸡蛋表面的裂纹和斑点,同时准确检测内部气室的高度,为鸡蛋的品质分级提供了关键的检测指标,并得到如下结论:

(1)在实验中,该模型在检测实验各项性能指标上均达到了较高水平,尤其是精确率达到95.76%,与原模型EfficientNet-B0相比,改进模型的识别准确率提升1.55个百分点,参数量减少20%,浮点计算量降低2.33%。

(2)与主流的网络模型Vgg-16、ResNet-50,所提模型的识别精确率分别高出了5.54、3.29个百分点,模型参数量分别降至原来的约16.4%(VGG-16)和98.48%(ResNet-50)。与GoogleNet模型相比在轻量化上,EfficientNetV2模型参数量高于GoogleNet,但是模型的识别精确率提升了1.22个百分点。

此外,本研究通过逐步优化EfficientNetB0网络的层级结构,实现了对不同层的合理计算分配,使模型在复杂度与准确性之间的配合状态中实现了较为理想的平衡。这种优化使得模型不仅适用于大规模工业检测任务,还可以进一步推广应用于其他食品品质检测领域,为后续基于深度学习的食品质量检测 and 分级研究提供了有效的技术参考。综上所述,基于EfficientNetV2的鸡蛋品质分级方法是一种高效、精准的检测解决方案,具有重要的实际应用价值和推广前景。

参考文献

[1] 陈雁南.影响鲜鸡蛋品质分级的因素及调控措施[J].现代畜牧科技,2023(04):50-52.

- [2] 齐广海,王晶.鸡蛋蛋壳生物矿化和力学特性调控的研究进展[J].动物营养学报,2023,35(01):1-12.
- [3] Botta B, Gattam S S R, Datta A K. Eggshell crack detection using deep convolutional neural networks[J]. Food Eng,2022, 315:110798.
- [4] 庄珑昱,郑江霞.鸡蛋品质评价方法研究进展及其影响因素分析[J].中国家禽,2024,46(03):87-94.
- [5] 戴妍,陈德会,刘忠洪,等.壳蛋新鲜度评价、影响因素及保持的研究进展[J].食品工业科技,2023,44(08):495-501.
- [6] 刘超,张家瑜,戚超,等.基于EfficientNet网络模型的猪肉新鲜度智能识别方法[J].食品科学,2023,44(24):369-376.
- [7] 陈羽立,孙付春,郭兴华,等.基于EfficientNet的鸡蛋裂纹检测研究[J].成都大学学报(自然科学版),2020,39(04):385-389.
- [8] 罗睿杰,杨哲维,刘华伟,等.鸡蛋蛋壳颜色影响因素及其与蛋品质及营养特性关系研究进展[J].中国家禽,2022,44(07):96-104.
- [9] 王云浩,郑玉才,李志雄,等.不同种类禽蛋的蛋品质和蛋内营养成分的比较分析[J].畜牧与兽医,2022,54(05):40-44.
- [10] Jiang M, Mo L, Wu P. Study on egg freshness detection based on incepti and attention[C]. International Conference on Simulation Tools and Techniques.Springer, Cham, 2021: 613-626.
- [11] 沈昊.基于DSP图像处理的鸡蛋新鲜度实时无损检测研究[D].武汉:华中农业大学,2020.
- [12] 刘雪,沈长盈,吕学泽,等.基于改进MobileNetV3-Large的鸡蛋新鲜度识别模型[J].农业工程学报,2022,38(17):196-204.
- [13] T/CAAA 092—2022鲜鸡蛋品质与分级[J].畜牧产业,2023(12):14-17.
- [14] T/CAAA 089—2022规模化蛋鸡场无抗养殖技术规范[J].畜牧产业,2023(09):9-12.
- [15] (2011).SB/T 10638-2011.中华人民共和国商务部.
- [16] 吴鹏.基于无损检测技术的鸡蛋快速分级与产地溯源研究[D].太原:山西农业大学,2021.
- [17] Haoran C, Chuchu H E, Minlan J, et al. Egg crack detection based on support vector machine[C]. 2020 International Conference On Intelligent Computing and Human-computer Interaction (ICHCI). IEEE, 2020: 80-83.
- [18] Tan M X, Le Q V. EfficientNetV2: Smaller models and faster training[J].arXiv preprint arXiv,2021,2104:00298.
- [19] Sunil C K, Aidhar C D, Patil N. Cardamo piant

- diseasetsectionio anorch using efficient NetV2[J]. IEEE Access,2021,10:89-804.
- [20] Liu D,Wang W,Wu X,et al.Efficient Netv2 model for breast cancer histopathological image classification [C]//2022 3 rd International Conference on Electronic CommunicationandArtificial Intlligence(IWECAD).1 EE.2022:384-387.
- [21] 王浩宇,崔艳荣,胡玉荣,等. 基于改进EfficientNetV2的苹果叶片病害识别模型[J]. 山东农业科学,2024, 56(09):124-132.
- [22] 尚朝轩,王品,韩壮志,等. 基于类决策树分类的特征层融合识别算法[J]. 控制与决策,2016,31(06): 1009-1014.
- [23] 郭靖. 基于EfficientNetV2和迁移学习的乐器分类研究[J]. 电脑编程技巧与维护,2023(09):15-18.
- [24] Sandler M, Howard A, Zhu ML, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]// Proceedings of the2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [25] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the 2018 IEEE/CVF Conference on ComputerVision and Pattern Recognition,2018:7132-7141.
- [26] 刘雪,沈长盈,吕学泽,等. 基于改进MobileNetV3-Large的鸡蛋新鲜度识别模型[J]. 农业工程学报, 2022,38(17):196-204.
- [27] Tan M, Le Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C]. International Conference on Machine Learning. PMLR, 2019: 6105-6114.
- [28] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014..
- [29] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition. 2016: 770-778..
- [30] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]. Proceedings of the IEEE Conference on Computer Vision And Pattern Recognition. 2015: 1-9..