

DOI:10.19651/j.cnki.emt.2211178

基于迁移学习的肠衣质量检测

丁庆松¹ 孙昊¹ 李强² 刘明和¹ 徐悦轩¹

(1. 河北工业大学人工智能与数据科学学院 天津 300400; 2. 内蒙古秋实生物有限公司 乌兰察布 012000)

摘要: 为了对生产后的肠衣准确快速的分类,研究了一种基于 ResNet50 模型的迁移学习网络模型。通过构建神经网络模型,以及从合作工厂获得肠衣样本,并按实际质量制作成 A,B,C,D 四个等级的数据集总共 2 000 张。在 ResNet50 模型的基础上设计全新的全连接层。并按 7:1 的比例分成训练集和测试集。实验可知,迁移学习的准确率为 99% 远好于普通深度学习模型的准确率 94%,准确率有明显的提高。最后将训练好的模型利用 Python 图形工具 pyqt 制作成用户界面,便于实际应用。该研究建立的基于迁移学习的肠衣质量检测系统,可实现对肠衣质量快速准确的分类,减轻了人力成本,为以后肠衣质量检测提供了依据。

关键词: 迁移学习;肠衣检测;残差网络;图像识别

中图分类号: TP277 **文献标识码:** A **国家标准学科分类代码:** 520.20

Migration learning-based quality inspection of sausage casing

Ding Qingsong¹ Sun Hao¹ Li Qiang² Liu Minghe¹ Xu Yuexuan¹

(1. School of Artificial Intelligence and Data Science, Hebei University of Technology, Tianjin 300400, China;

2. Inner Mongolia Qiushi Biological Co., Ltd., Ulanqab 012000, China)

Abstract: A migration learning network model based on the ResNet50 model was studied for accurate and fast classification of the manufactured casings. By constructing a neural network model as well as obtaining sausage casing samples from a cooperative factory and making a total of 2 000 data sets of four grades A, B, C and D according to the actual quality. A new fully connected layer is designed based on the ResNet50 model. And divided into training set and test set in the ratio of 7:1. Experimentally, it can be seen that the accuracy of migration learning is 99% far better than the accuracy of 94% of the ordinary deep learning model, and the accuracy is significantly improved. Finally, the trained model is made into a user interface using pyqt, a Python graphical tool, for practical application. The migration learning-based intestinal coating quality detection system established in this study can achieve fast and accurate classification of intestinal coating quality, reduce labor cost, and provide a basis for future intestinal coating quality detection.

Keywords: migration learning; enteric coating; residual network; image recognition

0 引言

肠衣^[1-2]作为香肠的外包装,其主要功能是保证香肠在一定条件及时间内不发生变质,以满足贮存及流通的需要。肠衣按原材料可分为天然肠衣^[3]和人造肠衣^[4]。香肠是日常生活中常见的食品,因此肠衣的需求量也很大。在大规模生产的自动化肠衣生产线中,肠衣产品的常见缺陷为纹路不均匀,有明显结节,颜色不一致等。目前肠衣质量等级分类主要依靠有经验的技术人员感官分级,虽然比较简单直观,但是人工效率比较低,无法满足大规模的肠衣自动化生产^[5]。其次由于主观因素的判断会出现一定误差。再加上长期用眼工作也会对身体造成一定损害。所以目前我们

急需设计一套稳定性强、准确性高,自动化水平好的肠衣质量检测系统。随着智能技术高速发展,越来越多的新技术应用于肠衣检测领域。在国内,韦衡冰等^[6]设计了一种肠衣检测机,在生产过程中设有表面图像处理装置可以对肠衣是否合格进行检测,但是缺点是只能判断是否合格不能对其质量更精确的分类。赵换英等^[7]设计了一种肠衣爆破检测装置,检测肠衣爆破时的压力值,从而检测肠衣质量是否合格。但是存在一定的危险性,同样无法对肠衣的品质进行准确分类。元云飞等^[8]设计了一种肠衣缺陷在线检测系统,利用工业相机及计算机对肠衣进行检测,无需破坏已包装好的肠衣就可以完成检测,但是无法对所有肠衣样品

收稿日期:2022-08-25

检测实现全覆盖,并且检测肠衣特征有限,稳定性不足。在国外,德国 Holdijk Haambreg 公司研究开发了 MM70 肠衣长度测量机^[9],该设备采用单片机作为核心控制器,结合编码器进行测量,精度可精确到±10 cm。实现自动测量肠衣长度。缺点是需要手动复位,且测量不够精确。Landmark 等提出了一种基于机器视觉的柔性测量系统,实现对类似肠衣的多种薄软材料厚度进行测量,但是问题是成本较大,肠衣薄且透明的特性也会干扰测量结果^[10]。

本文研究的基于迁移学习的肠衣质量检测系统,有效的改进了前人的不足。首先可以更加精确的进行分类,不止局限于对合格不合格的分类。其次完全排除了前人肠衣爆破检测装置的危险性。最后检测肠衣的特征更多,可以保证对绝大多数肠衣进行检测,稳定性和准确性也很高。

本文以合作工厂内生产的肠衣为研究对象,采集各个等级的肠衣样本制作数据集,利用图像处理技术结合迁移学习技术,实现对成品肠衣进行准确的质量分级,准确率和效率较高。最后制作了肠衣质量等级划分可视化界面,便于实际应用。本文研究的基于迁移学习的肠衣质量等级系统为后续继续研究肠衣检测系统提供了理论依据。

1 实验数据

针对需要对生产的肠衣进行质量分级处理这一目的,以肠衣为研究对象,根据合作公司提供的肠衣质量的标准对肠衣进行分级,可分为 A,B,C,D 4 个等级。并准确的了解各个等级的分类标准,以确保学习到正确的信息。

1.1 肠衣质量等级划分

根据与有经验的工作人员沟通后,可知肠衣的等级大概分类标准。

首先 A 类需纹路顺滑良好,无尺寸波动或其他情况造成的纹路不均匀,无掉头,断尾,中间无断裂,尾部整齐,长短一致且符合要求长度,颜色均匀一致,内孔为均一圆形。如图 1 所示。




图 1 A 类肠衣

其次,以下几种可分为 B 类 1)有轻微纹路不均,圆棱,但无折痕明显的棱,如图 2(a)。2)纹路符合,但有一节轻微断裂的如图 2(b)。3)有轻微弯曲的,但纹路符合 B 级要求,如图 2(c)。4)有轻微花色的,但纹路符合。如图 2(d)。

C 级品肠衣为纹路有严重缺陷、有竹节状、断掉较多的、掉头的、断尾的、尺寸不均匀的、颜色不满足要求的、长短不一的、花色严重的等外观品相差,但不影响使用,且无




图 2 B 类肠衣

对人体有害因素的,均定为 C 级。总体分为以下几种情况: 1)有明显竹节状的,如图 3(a)。2)花色严重的如图 3(b)。




图 3 C 类肠衣

D 级主要就是残次品,包括有塑料接头的、有明显黑斑的、断套的(长度不够的、半根的)以下几种情况分为 D 级。

1)塑料接头如图 4(a)。2)有明显黑斑或者整体发黑的如图 4(b)。3)断掉的一截一截的如图 4(c)。




图 4 D 类肠衣

1.2 图像的采集与处理

实验采用工厂提供的肠衣作为数据集制作的原材料。根据以上质量分级标准,将肠衣分成 4 个等级。便于后续数据集的制作。

利用手机相机进行图像采集,拍摄工具使用华为 mate30 手机。分辨率为 2 340 像素×1 080 像素。保证数据集的质量不会因拍摄工具产生影响。收集数据时还要保证不同光照,不同场景,不同角度,不同时间段的肠衣图像存在,另外确保图像的完整性,图像需要包含肠衣的大部分特征。删除特征不完整和图像模糊的图像,防止外部因素影响系统准确性。共采集了 A 等 350 张,B 等 450 张,C 等 600 张,D 等 600 张作为原始图片。共计 2 000 张图像。不同类别的图像数量如表 1 所示。

表 1 肠衣质量等级及数量

肠衣质量等级	A	B	C	D
肠衣图像数量	350	450	600	600

对图像进行预处理操作。首先随机按 7 : 1 的比例,分别用于训练集和测试集,训练集 1 750 张,测试集 250 张。并将每张图像的格式统一修改为 224×224 像素,便于后续图像处理。

最后分别将不同质量等级的肠衣图像存放在 4 个文件夹内,命名为 A,B,C,D。每张图片进行逐一编号,数据集样本示例如图 5 所示。各个等级的肠衣数据集如图 6 所示。




图 5 数据集样本




图 6 各个等级肠衣

2 网络模型搭建

2.1 卷积神经网络模型

卷积神经网络是由^[11-13]为多个卷积层和顶端的全连接层(也可以使用 1×1 的卷积层作为最终的输出)组成的一种前馈神经网络。

其组成主要包括输入层、卷积层、池化层、全连接层、输出层。

常见的经典卷积神经网络模型包括:LeNet, AlexNet, ResNet, GooGLENet, 等。

2.2 迁移学习

迁移学习^[14-15]是指从相关领域中迁移标注数据或者知识结构、完成或改进目标领域或任务的学习效果。迁移训

练好的卷积层可以对各种不同的图像进行特征提取再加上新任务的全连接层对新网络稍加训练就可以完成新的检测任务。其往往不限制于特定领域,只要该问题满足迁移学习的场景,就可以使用迁移学习来解决。计算机视觉^[16]、文本分类^[17]、行为识别^[18]、人机交互^[19]等领域都可以使用到迁移学习技术。

2.3 残差网络迁移模型构建

本文使用残差网络模型(residual neural network, ResNet)^[20]进行迁移学习。ResNet 网络模型在 2015 年由何凯明提出。ResNet50 模型结构如表 2 所示。利用残差模型,使一部分输入不经过卷积直达输出,保留了一部分原始数据,这种结构有效防止了反向传播时的梯度弥散问题。解决了当网络深度达到一定程度时,深层网络的总体表现不如浅层网络的退化问题。残差块如图 7 所示。此模型允许网络尽可能的加深,并可以使准确率维持稳定。

表 2 ResNet50 网络模型

类型	块尺寸	输出尺寸
Conv1	7×7,64	112×112×64
Max pool	3×3	64×56×56
Conv2_x	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	56×56×256
Conv3_x	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	25×28×512
Conv4_x	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	14×14×1024
Conv5_x	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	7×7×2048
Average pool	7×7	1×1×2048
FC-100	logits	1×1×1000




图 7 残差模块

残差元的主要设计有两个,快捷连接和恒等映射,快捷连接使得残差变得可能,而恒等映射使得网络变深。残差

元公式如下：

$$y = F(x, \{w_i\}) + x \tag{1}$$

其中, x, y 分别为输入输出。 $F(x, \{w_i\})$ 为残差模型的残差映射。残差模块引入了一个恒等映射, 将原本网络要学习的函数 $H(X) = X$ 转换为 $H(X) = F(X) + X$, 由于保留了部分原始数据, 所以成功解决了深层模型准确率下降的问题。

2.4 模型调整

本次模型使用的是经过 ImageNet 数据集^[21] 预处理后的残差模型, 迁移其部分卷积层用来提取肠衣特征, 并对原来模型进行一定程度的修改。首先冻结模型参数, 修改一部分卷积层, 池化层和全连接层。

1) 卷积核尺寸调整

在深度学习网络中, ResNet50 网络的第一层为 7×7 卷积层, 虽然大的卷积核能提取图像中更加复杂的特征, 但是在本文中, 肠衣大多数瑕疵点非常小, 需要提取更加细微的特征。所以本文对第一层 7×7 卷积层进行改进由 3 个 3×3 的卷积替换 7×7 的卷积。这一改进使用了更多的非线性激活函数, 增加了函数的判决性。也同时降低了计算参数量。同时并不改变初始感受野的大小。

2) 全连接层、池化层调整

本文池化层采用自适应平均池化算法获得^[22], 使其达到降低卷积层输出的特征向量, 同时改善结果, 使其不易出现过拟合, 如图 8 所示。

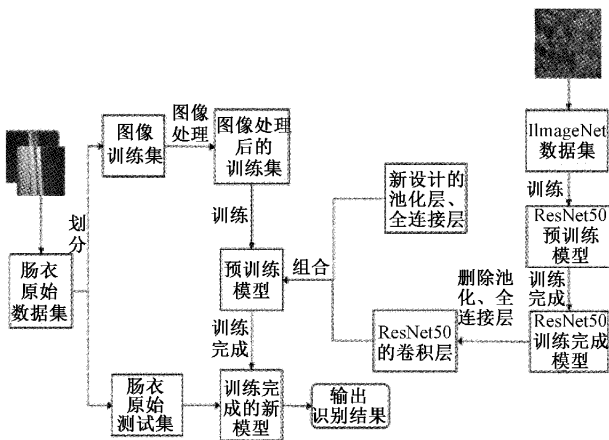


图 8 基于迁移学习的肠衣等级分类识别流程

全连接层修改需根据实际需求而修改。由于需要将肠衣的质量分为 4 个等级。因此全连接层的个数设置为 4。全连接层增加一个 512 维的全连接层, 一层 ReLU 激活层, 一层 Dropout 层, 一层 4 维的全连接层, 以及一层 softmax 分类层。如图 9 所示。

2.5 试验环境和超参数的设置

1) 实验环境搭建

为了验证迁移 ResNet50 网络模型的有效性。本文进行了肠衣质量检测的对比实验。实验采用 Inter Core i5-




图 9 重新设计后的模型结构

10400 F 2.9 GHz 处理器, 操作系统为 Windows10 64 bits。硬件环境的 GPU 采用 NVIDIA GEFORCE GTX 1050 Ti 4 GB 显存。软件利用 pycharm 环境搭建, 导入 Anaconda python 3.6。深度学习框架为 pytorch 1.0.2。

2) 超参数设置

超参数可以更科学地确定出高效的网络模型。超参数主要包括: 网络参数、优化参数、正则化参数 3 种, 通过超参数调优来达到最小化期望风险的目的。得到最优和较优的解。首先学习率是模型中比较重要的超参数。其决定了模型的有效容限能力。本文设置学习率为 0.001。其次设置 batch size, batch size 指每批数据的大小可以根据自身硬件的容量, 内存越大设置可以越高。本文选取了 16, 32, 64, 128 作为 batch size 值进行测试。最终将 batch-size 设置为 32。epoch 为总共训练的轮数, 将所有数据迭代训练一次是不够的, 前向传播一次加反向传播一次为一个 epoch。经过多次训练才能最终达到拟合、收敛的状态。本文 epoch 的设置根据实际准确率不断更改, 选择使准确率高并且 epoch 尽可能小。选取了 10, 20, 30 作为 epoch 值, 最终确定 epoch 取 20。

模型优化优化器采用 Adam 优化器^[23]。Adam 是在 RMSProp^[24] 和 AdaGrad^[25] 的基础上改进的。对梯度的一阶矩估计 (first moment estimation), 即梯度的均值和二阶矩估计^[26] (second moment estimation), 即梯度的未中心化的方差进行综合考虑, 计算出更新步长。其优势在于实现简单, 结构高效, 对内存需求很小。且超参数不需要或仅需很小的调整。本文将一阶矩估计指数衰减率取 0.9。二阶

矩估计指数衰减率取 0.99。

2.6 模型评估

为了评价提出的方法对肠衣质量检测是否有效,实验结束后分别测试了其准确率和召回率。

$$precision = t_p / (t_p + f_p) \quad (2)$$

$$recall = t_p / (t_p + f_n) \quad (3)$$

其中, $precision$ 为准确率, $recall$ 为召回率。 t_p 为预测为正的样本, f_p 为预测为负的正样本。 f_n 为预测为负的正样本。

3 实验与分析

为验证改进的迁移学习模型的性能及参数的选择分别把普通深度学习模型,改进前的迁移学习模型模型,改进后的迁移学习模型进行对比实验,3 种模型学习率分别取 0.001,0.000 1 两种。为得到改进后模型最优的训练轮数,分别取 epoch=10、20、30 训练改进迁移学习模型,验证精度及训练时长如表 3 所示,并分别绘制 3 种模型准确率与损失值的曲线,如图 10 所示。


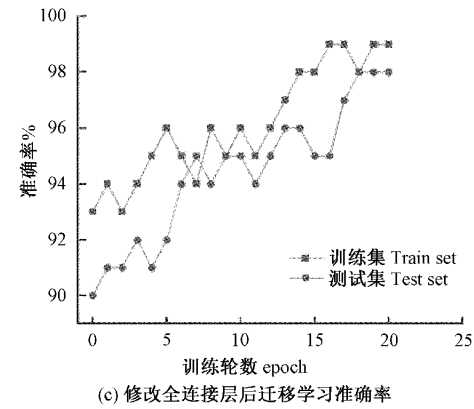


表 3 模型识别精度

训练方式	学习率	训练轮数	训练准确率/%	测试准确率/%	训练时长
普通模型	0.001 0	20	93.3	92.6	11 min51 s
	0.000 1		83.1	70.7	11 min58 s
未修改全连接层模型	0.001 0	20	93.1	83.5	39 min56 s
	0.000 1		86.5	80.0	40 min19 s
修改全连接层模型	0.001 0	20	99.3	98.7	39 min56 s
	0.000 1		89.5	88.5	42 min14 s
	0.001 0	30	99.1	98.7	56 min41 s
	0.000 1		90.6	89.2	59 min40 s

根据表 3 及图 10 所知,学习率 0.001 明显优于 0.000 1,学习率 0.000 1 明显过小导致收敛速度及准确率较低。如表 2 所知,改进后的迁移学习模型在训练轮数为 10 时,准确率并不高,而训练轮数 20 和 30 准确率很高,且相差不大,说明训练轮数为 20 时,已经达到训练要求,模型已经达到收敛,不需要再增加训练轮数。因此训练轮数选择 20 最为合适。

3 种模型在学习率及训练轮数相同的情况下,改进后的迁移学习模型相比其他两种准确率明显更高。在学习率为 0.001 时,准确率达到 99.3%,远高于其他两种模型。收敛速度根据图 13 所知也收敛更迅速。在第 12 轮左右基本达到收敛,准确率高,各方面性能更好。但由于迁移学习 ResNet50 的网络模型深度相比于普通模型较深,训练时长

迁移学习相比普通深度学习模型较长。但是实验中测试集分类时长并不长,对每张图像分类的时间不超过 1 s,并不影响在实际检测应用中对成品肠衣分类的速度,也不会因



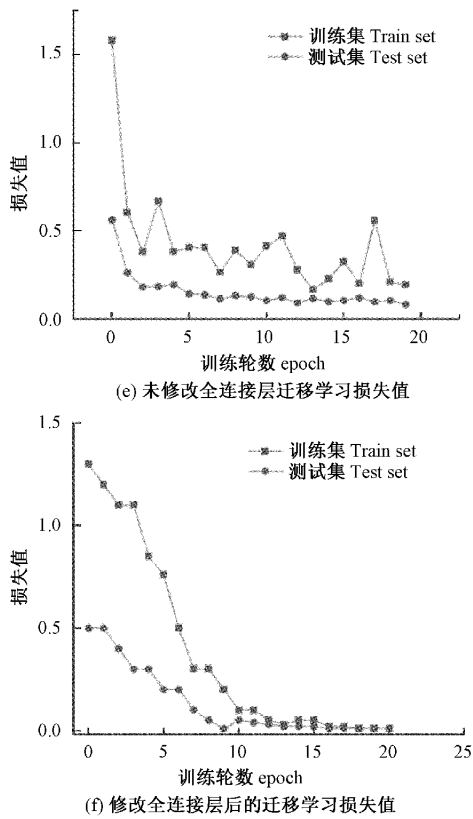


图 10 模型准确率及损失值曲线

此降低分类效率。

综上所述,改进后的迁移学习模型具有更优的性能。由于生产实际中需要分级的肠衣数量很大,准确率及各方面性能的提升可以有效的减少出现分类错误的概率,也会很大程度的提高生产效率。

3.1 质量分类及模型准确率

由于实际需要获得各个肠衣的实际质量等级。因此用该模型对所有肠衣进行分类,并统计其中各个肠衣的等级情况。每次随机选取 32 个肠衣显示其质量等级,如图 11 所示。

根据图 11 所示,抽取 32 张肠衣图像进行质量分级,分类后将等级标注在图片最上端,便于清晰的获取肠衣的实际质量等级。

3.2 混淆矩阵

混淆矩阵是一种表示精度评价的标准格式,主要用于比较分类结果和实际测得值。再利用混淆矩阵^[27]来对搭建的迁移学习实验结果进行分析,其可以直观,清楚,简洁的表示出分类模型的准确度,并可以把归对类,归错类用一个表表示出来。X 轴表示预测的质量等级,Y 轴表示真实的质量等级。同样利用混淆矩阵对普通模型分类作为对比实验。如图 12 所示。

根据图 12 混淆矩阵可以清晰的发现,2 000 张肠衣图像中预测正确的数量有 1 827 张预测正确的仅有 173 张预

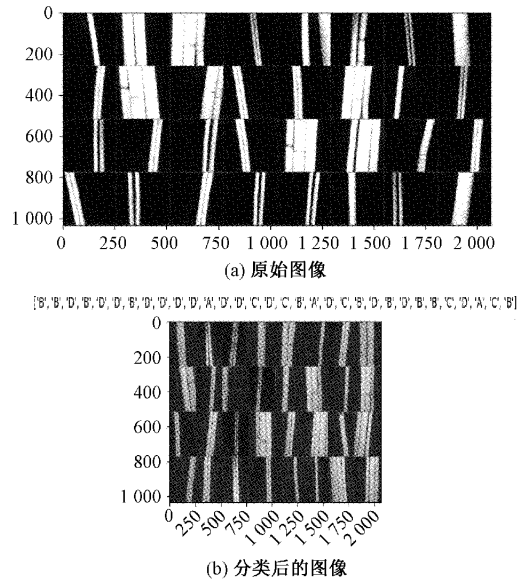
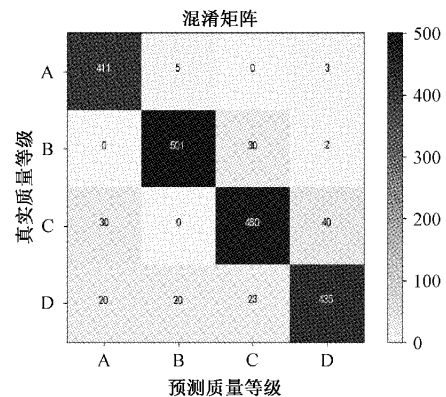
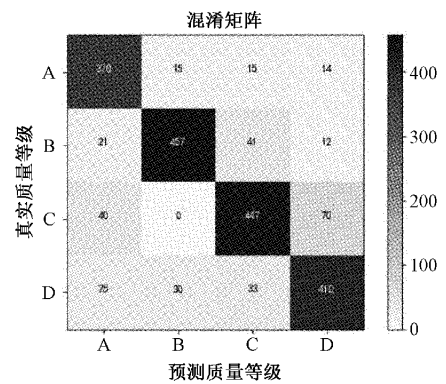


图 11 肠衣等级分类



(a) 改进后迁移学习模型混淆矩阵



(b) 普通模型混淆矩阵

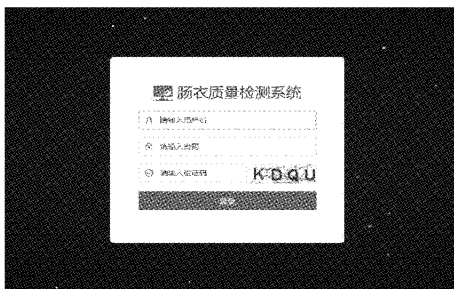
图 12 迁移学习模型混淆矩阵

测错误。预测错误的样本中 A 类有 5 张预测为 B 类 3 张预测为 D 类。B 类有 30 张预测为 C 类 2 张预测 D 类。C 类有 30 张预测为 A 类 40 张预测为 D 类,D 类有 20 张预测为 A 类 20 张预测为 B 类 23 张预测为 C 类。实际准确率超过 90%。样本搭建的迁移学习模型的准确性较高,可以


应用于实际检测场景中。对比普通模型结果仅有 1 684 张图像预测正确,正确率仅为 84.2%,相比迁移学习正确率的 91.35%,准确率相差 7%,有很大差距。

3.3 模型应用

为了将模型应用于检测,本文设计了一套肠衣检测应用程序。可以实时检测生产完成后的肠衣等级。利用 Python 脚本进行开发。Python 自带界面搭建模块 pyqt^[28]可以用于搭建可视化界面。并通过程序实时检测显示肠衣的质量等级和分类准确的概率。登录及检测界面如图 13 所示。



(a) 肠衣检测系统登录界面



(b) 肠衣质量检测系统界面

图 13 可视化识别检测系统检测结果

4 结 论

本文提出了一种基于迁移学习的肠衣质量检测系统。通过改进 ResNet50 网络模型的部分卷积层、全连接层和池化层,提升了肠衣产品的检测的精度。可以有效的将肠衣根据品质分类成 4 类。实验结果表明该预测模型的准确率达到 99%,准确率明显好于普通深度学习的模型,具有很好的稳定性和非线性特性。最后还搭建了质量分级可视化界面便于实时监测质量等级,提高了系统的实用性。模型局限性是由于需要分级的肠衣数量较多,肠衣分级速度还不够快,效率有待提高。后续将提升肠衣质量分级的速度,提高模型的效率。并将更多的自动化技术应用于肠衣领域中,实现肠衣智能生产、成型以及生产过程中故障的智能化监测等目标。

参考文献

[1] 李仁家,郭华伟,徐义帆,等. 纤维素肠衣生产香肠常见问题浅析[J]. 食品安全导刊, 2020(21):136-137.
[2] 杨书升. 压缩肠衣生产线的自动控制系统研究[D]. 哈

尔滨:哈尔滨工程大学,2017.

- [3] 陈士忠. 天然肠衣的优势[J]. 农产品加工, 2004(4):19.
[4] 李敏,刘锴锴,郝志娜,等. 人造胶原肠衣的研究进展[J]. 食品安全质量检测学报, 2019, 10(10):3159-3165.
[5] 王文捷. 人造肠衣生产线[J]. 肉类工业, 1986(7):44.
[6] 韦衡冰,蒙瑞彪,卢在盛. 一种肠衣检测机: CN201810141442. 6[P]. CN108333316A[2023-07-28].
[7] 赵换英,曹志鹏,宋立国. 肠衣爆破检测装置: CN201920707731. 8[P]. CN210487483U[2023-07-28].
[8] 元云飞,祝希. 一种肠衣缺陷在线检测系统: CN202020732565. X[P]. CN212159603U[2023-07-28].
[9] SHAH A, LEE J, MAYER M, et al. Online methods to measure breaking force of bonding wire using a CMOS stress sensor and a proximity sensor [J]. Sensors & Actuators A Physical, 2008, 148(2):462-471. DOI:10.1016/j.sna.2008.09.008.
[10] 徐兴波. 基于机器视觉的轴类零件尺寸测量系统的研制[D]. 武汉:华中科技大学,2015.
[11] 魏花. 基于卷积神经网络的细粒度图像识别关键技术分析与研究[D]. 长春:中国科学院大学(中国科学院长春光学精密机械与物理研究所),2021.
[12] 汪成龙,陈均泳,陈国壮,等. 基于深度学习的马铃薯机械损伤检测方法应用研究[J]. 电子测量技术, 2018, 41(20):118-122.
[13] 石昌友,孙强,卢建平,等. 多尺度卷积神经网络的图像边缘检测[J]. 电子测量技术, 2022(8):45.
[14] 石晨宇,周春,靳鸿,等. 基于卷积神经网络的农作物病害识别研究[J]. 国外电子测量技术, 2021, 40(9):93-99.
[15] 曲桂果,袁琦,李彦. 基于深度网络迁移学习的致痫区脑电识别[J]. 仪器仪表学报, 2020, 41(5): 164-173.
[16] DE KETELAERE B, WOUTERS N, KALFAS I, et al. A fresh look at computer vision for industrial quality control[J]. Quality Engineering, 2022(1):34.
[17] YUNLONG G, WANLI Z, YING W, et al. Short text classification model based on integrated neural networks [J]. Journal of Jilin University (Science Edition), 2018.
[18] 李晨,何明,王勇等. 基于深度学习的视频行为识别技术综述[J]. 计算机应用研究, 2022, 39(9):2561-2569.
[19] BISEN D, SHUKLA R, RAJPOOT N, et al. Responsive human-computer interaction model based on recognition of facial landmarks using machine learning algorithms [J]. Multimedia Tools and Applications, 2022, 81(13):18011-18031.
[20] 李聪,喻国威,张原嘉,等. 基于 ResNeXt 与迁移学习的干制哈密大枣果梗/花萼及缺陷识别[J]. 食品与机械, 2022, 38(1):135-140.
[21] AMIN M M, ALIREZA B, GUILHERME D F. A

- scoping review of transfer learning research on medical image analysis using ImageNet [J]. Computers in Biology and Medicine, 2021, DOI: 10. 1016/j. compbiomed. 2020. 104115.
- [22] 赵长乐, 何利力. 卷积神经网络中的自适应加权池化[J]. 软件导刊, 2022, 21(3): 83-88.
- [23] 潘锦业, 王苗苗, 阚威, 等. 基于 Adam 优化算法和长短期记忆神经网络的锂离子电池荷电状态估计方法[J]. 电气技术, 2022, 23(4): 25-30, 36.
- [24] YUE X, LIU Q. Improved FunkSVD algorithm based on RMSProp [J]. Journal of Circuits, Systems and Computers, 2022, DOI: 10. 1142/S0218126622501390.
- [25] 陇盛, 陶蔚, 张泽东, 等. 基于 AdaGrad 的自适应 NAG 方法及其最优个体收敛性[J]. 软件学报, 2022, 33(4): 1231-1243.
- [26] 袁业立, 乔方利, 尹训强, 等. 基于二阶矩闭合模式平衡解的海浪生湍流混合系数解析估计[J]. 中国科学: 地球科学, 2013, 43(2): 171-180.
- [27] LIU X F, LIU W, HUANG H S, et al. An improved confusion matrix for fusing multiple K-SVD classifiers[J]. Knowledge and Information Systems, 2022, 64(3).
- [28] 吴春波, 陈伟, 赵振华, 等. 基于 PyQt 的 SHPB 试验数据处理程序开发 [J]. 计算机应用与软件, 2021, 38(12): 11-13, 80.

作者简介

丁庆松, 硕士研究生, 主要研究方向为视觉处理, 物联网监测。

E-mail: 1150334328@qq. com

孙昊(通信作者), 博士, 副教授。主要研究方向为智能服务机器人, 主要包括医用服务机器人、智能化医疗器械、人机自然交互、机器学习等。

E-mail: sunhao@hebut. edu. cn