

基于改进 ResNet34 卷积神经网络的 硅棒缺陷检测

刘 帅, 嵇小辅

(江南大学 物联网工程学院轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

摘要: 针对现有人工检测太阳能硅棒导致准确率低、识别速度慢的问题, 提出一种基于改进深度学习网络的硅棒外观缺陷分类系统; 该系统把硅棒检测分为两个部分, 运用图像算法对硅棒图像进行预处理, 结合阈值分割和连通域分割方法对硅棒图像区域分割, 根据区域轮廓采用内接圆的方法将硅棒从图像中提取, 减少特征提取干扰因素; 其次改进残差网络的残差模块的结构, 提高网络训练速度; 实验模型加入正则化和 Dropout 层改善过拟合现象, 采用改进余弦退火的学习率衰减方式寻找模型的最优解; 实验结果显示, 与未改进的残差网络相比, 改进的网络总体识别准确度提高 2.41%, 该模型有效地提高硅棒外观缺陷分类的高效性和泛化能力。

关键词: 外观缺陷; 阈值分割; 残差网络; L2 正则化; 余弦退火

Silicon Rod Defect Detection Based on Improved ResNet34 Convolutional Neural Network

LIU Shuai, JI Xiaofu

(Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education,
School IoT Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Aiming at the problems of low accuracy and slow recognition caused by existing manual detection of solar silicon rods, a silicon rod appearance defect classification system based on improved deep learning network is proposed. This system divides the silicon bar detection into two parts. The image algorithm is used to preprocess the silicon rod image, and combine the threshold segmentation and connected domain segmentation to segment the silicon bar image region. Firstly, based on the contour of the region, the silicon bar is extracted from the image using the inscribed circle method to reduce the interference factors of feature extraction. Secondly, the model structure of residual network is improved for the training speed of the network. The regularization layer and Dropout layer are added to the experimental model to improve the overfitting phenomenon, and the learning rate attenuation method with improved cosine annealing is used to search the optimal solution for the model. Experimental results show that compared with the unimproved residual network, the improved network increases the overall recognition accuracy by 2.41%, and the model can effectively improve the efficiency and generalization ability of silicon rod appearance defect classification.

Keywords: appearance defect; threshold segmentation; residual network; L2 regularization; cosine annealing

0 引言

晶体硅作为一种半导体材料, 因其良好的光电效应和经济效益成为目前主流的光伏材料。硅棒在生产加工过程中经常伴随着表面缺陷问题, 这些外观缺陷的硅棒会严重降低工业加工效率, 需要对其做进一步的处理。因此, 针对硅棒外观的缺陷检测在工业生产上具有现实

意义。

目前, 国内传统的硅棒外观检测主要以人工检测为主, 在当前工业速度与精度的双重标准下, 人工检测难以达到高效性和准确性的要求, 针对工业现场的大批量生产显然不适用。近年来, 深度学习作为机器学习研究中的一个新的领域, 它允许机器模拟人类思维并不断反馈优化, 从而实现图像、语音和文本的识别以及其他

收稿日期: 2023-12-11; 修回日期: 2024-01-17。

作者简介: 刘 帅(1998-), 男, 硕士研究生。

引用格式: 刘 帅, 嵇小辅. 基于改进 ResNet34 卷积神经网络的硅棒缺陷检测[J]. 计算机测量与控制, 2025, 33(2): 37-43.

工操作。卷积神经网络作为深度学习的代表性算法之一,在计算机视觉领域的应用成为目前众多学者的研究热点。针对目标分类的不同需求,国内外学者以卷积神经网络为基础提出了不同的思路与解决方案。从机器视觉处理方面入手,针对目前缺陷检测图片的预处理方法,阈值分割算法^[1]等做出总结与分析,对提升工业智能化做出进一步的展望^[2-3]。麦俊佳等人^[4]利用仿射变换技术对缺陷部件的图片进行增强,增加了训练数量以及多样性,提升模型的鲁棒性,并采用 U-Net 全卷积神经网络对处理后的图片进行语义分割,部件检出率高达 92.5%。采用变异系数法来检测太阳能电池硅片的裂纹,对特定杂质的多晶硅棒取得不错的检测效果^[5-6]。王宪保等人^[7]运用深度置信网络对太阳能电池片的图像做特征提取,并用反向传播算法对网络参数进行数值调整,通过建立图像的对比关系来达到分类的效果,极大地提高了检测速度。朱莉等人^[8]使用残差网络(ResNet, residual network),改进残差块结构的内部顺序,并利用迁移学习的知识加快模型的训练时间,使模型在对树种识别的精确度提高了 1.33%。王理顺等人^[9]通过对网络中除池化层外的每层网络添加一个归一化层(BN, batch normalization),提高了模型的泛化能力,并去掉局部归一化层(LRN, local response normalization)与 Dropout 层的方式来降低模型的复杂度,设计出一种织物缺陷的检测模型。

面对复杂多变的工业化生产,需求的多样性产生越来越多的神经网络架构,所能实现的效果也各不相同。许多模型只有在特定的工业环境下取得较好的效果,不具有普遍适用性,针对以上问题,本文基于卷积神经网络的 AI 网络框架,提出了一种改进 ResNet34 卷积神经网络的硅棒缺陷检测分类系统,整个系统分为两个部分。第一部分通过对工业现场的图片进行识别前的预处理,除去图片多余的干扰部分,降低卷积神经网络特征提取难度,提高识别的速度和精度。第二部分通过对识别网络 ResNet34 的改进,设计了一种精确度更高、训练速度更快的硅棒缺陷分类检测方法。

1 图像处理

当前图像存在噪声和曝光不足的问题。本文采用中值滤波的方法对图像进行处理,有效地除去噪声的干扰,保护边缘信息的完整。其次采取灰度变换的方法,扩充了图像的灰度取值的动态范围,有利于硅棒与背景的分割。

1.1 图像的阈值分割

预处理过后,针对硅棒图像的特征进行提取,如图 1 所示,基于硅棒和背景占据不同的灰度级范围,本文采用阈值分割的方法对硅棒图片进行分割处理,提取感

兴趣的部分。单次阈值分割计算公式为:

$$g(x,y) = \begin{cases} 255, f(x,y) \geq T \\ 0, f(x,y) < T \end{cases} \quad (1)$$

式中, T 为分割阈值, $f(x,y)$ 表示像素在 (x,y) 位置的灰度值, $g(x,y)$ 表示处理后的像素的灰度值。



图 1 原始硅棒图像

预处理后的图片背景为黑色的,硅棒的正上方为光照部分,为白色,在灰度图中白色为 255,黑色为 0,故结合灰度直方图采用两次单阈值分割完成。选取一个小的分割阈值除去背景,如图 2 所示,再选取一个较大的分割除去光亮部分。这种方法实现简单且效果明显。




图 2 阈值分割后图像

1.2 硅棒的分离

如图 3 所示,硅棒的整体轮廓已经有所展现,根据二值形态学变化特性,采用先腐蚀后膨胀的开运算^[10],一方面除去图像上一些孤立的小点,保留总体的位置和形状不变,另一方面断开一些细小的连接,可以使目标分离明确。

在对整体进行细小部分的分解之后,只需将保有大部分面积的区域中将圆棒截面完整地提取下来。本文采用了连通域分割的算法处理分割后的图片,计算图片所有的连通域,根据面积选取其中最大的区域,在选定区域做内接圆处理,即可得到硅棒的精确定位,图像裁剪后如图 4 所示。

此时,图片的细节不够明显,因此采用 gamma 变



图 3 开运算后图像



图 4 定位后图像

换来进行图像增强, 计算公式为:

$$s = cr^\gamma \quad (2)$$

式中, r 为灰度图像的输入值, 取值范围为 $[0, 1]$ 。 s 为经过伽马变换后的绘图输出值, c 为灰度缩放系数, γ 为伽马因子大小, 控制整个变换的缩放程度。通过非线性变换, 使得较亮的区域灰度被压缩, 较暗的区域灰度被拉伸, 这样能够增加对比度, 利于分辨低灰度值时的图像细节, 最后对图像进行居中裁剪, 得到图 5 作为训练的数据集。



图 5 训练数据

2 卷积神经网络

卷积神经网络^[11]是一类运用卷积计算且具有深度结构的前馈神经网络, 因为它包含局部区域连接, 权值

共享、降采样等结构优点^[12], 在图像处理领域具有代表地位。

2.1 ResNet34 基本网络

在 2015 年的 ImageNet 大规模机器视觉领域挑战赛上, 来自微软研究院的学者提出了 ResNet^[13], 采用残差学习的方法达到了不同层的特征信息相互传递, 成功缓解网络退化的问题, 真正实现了网络越深, 准确率越高的理论。残差网络主体的网络结构是由多个卷积层组成, 每个卷积层本质上是由一系列的基本块组成, 每个残差块的结构如图 6 所示。




图 6 残差模块

残差块分为直接映射部分和残差部分, 通用的数学符号公式表示为:

$$y_l = h(x_l) + F(x_l, W_l) \quad (3)$$

$$x_{l+1} = f(y_l) \quad (4)$$

式中, $h(x)$ 是直接映射, 在 shortcut 通路中, $h(x_l) = x_l$, $F(x_l, W_l)$ 是残差部分, $f(\cdot)$ 是激活函数。基于以上两个公式, 忽略激活函数的影响, 做出假设 $f(y)$ 是直接映射, 此时, 残差块就可以表示为:

$$x_{l+1} = x_l + F(x_l, W_l) \quad (5)$$

随着层数 L 的不断加深, 对于任意层 l 之间的联系可以表示为:

$$x_L = x_l + \sum_{i=l}^{L-1} F(x_i, W_i) \quad (6)$$

由公式 (6) 可知, L 层可以表示为任意一个比其浅的 l 层和他们之间的残差部分之和, 在前向传输的过程中, 随着层数的增加, 特征图所能包含的图像信息会逐层减少, 采用直接映射, 保证 $L+1$ 层网络的信息必定大于或等于 L 层的图像信息。根据反向传播中的链式法则可知, 损失函数 ϵ 关于 x_l 的梯度可以表示为:

$$\frac{\partial \epsilon}{\partial x_l} = \frac{\partial \epsilon}{\partial x_L} \frac{\partial x_L}{\partial x_l} = \frac{\partial \epsilon}{\partial x_L} \left[1 + \frac{\partial}{\partial x_l} \sum_{i=l}^{L-1} F(x_i, W_i) \right] \quad (7)$$

由公式 (7) 可知, 残差网络在训练过程中, 由于 $\frac{\partial}{\partial x_l} \sum_{i=l}^{L-1} F(x_i, W_i)$ 在网络的学习过程中不断变换, 因此, 任意两层的反向传播, 可以避免梯度消失问题, 解决了网络加深训练困难的问题。通过对残差网络的正向和反向两个过程的分析, 在满足假设的前提下, 残差

网络的存在足以使深度模型的训练成为可能。

2.2 ResNet34 框架

ResNet34^[14]是目前常用的残差网络结构，该网络主要由 16 个残差块，1 个 7 * 7 卷积层与一个全连接层构成，共计 34 层。卷积层负责提取输入图像的特征信息以及特征映射，为图像识别做准备。全连接层是针对前面卷积层和池化层所产生的信息提取的一个汇总，通过将前面局部特征的整合，转化为一维向量，从而实现分类作用，最后由输出层对结果进行输出。本文选用 ResNet34 作为硅棒分类模型框架。ResNet34 网络首先对输入图像做 5 个卷积组操作，目的是对图像特征做提取处理，以及在反向传播时，对卷积单元的参数做进一步更新优化，在平均池化层采样的作用下除去特征图中一些不重要的特征参数，最后通过全连接层转化为一维矩阵后到达输出层进行分类操作。但 ResNet34 在对硅棒照片的训练中存在训练时间较长、精度低等问题，不能达到工业上生产标准。因此，针对这一现象，提出了一种基于 ResNet34 的改进模型。

3 模型改进

3.1 模型函数的选取

本文提出的硅棒外观分类模型在输出层使用了 Softmax 分类器，得到不同类型的预测结果。Softmax 作为一种线性分类器，可以为硅棒的多分类问题预留余地，其监督模式的分类方法，使得模型不再仅仅取决于某个最大值，而是对每一种输出类别的结果都有确切的概率值，Softmax 的定义为：

$$\text{Softmax}(x_i) = \frac{\exp(\theta_i^T x)}{\sum_{k=1}^K \exp(\theta_k^T x)} \quad (8)$$

其中：Softmax (x_i) 表示输入样本 x 为 i 类型的概率， $\exp(\theta_i^T x)$ 为输入的样本， θ_i^T 表示所有模型参数， $\sum_{k=1}^K \exp(\theta_k^T x)$ 为归一化项，概率总和为 1。损失函数采用交叉熵误差，是一种用来定义神经网络模型的效果以及优化的目标函数。任意两个概率分布为 p 和 q ，通过 p 表示 q 的交叉熵的公式为：

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (9)$$

交叉熵误差在神经网络的分类问题方面应用较广，其本质是用来衡量输出向量和期望向量的差距，其值越小，代表模型预测越准确，可以根据初始的误差值改变每轮的样本数以及误差值的收敛情况来判定迭代次数的选取，从而实现参数的优化。

3.2 过拟合处理

过拟合现象往往使得模型在训练集上的评估指标表现良好，但在测试集的应用上却表现较差，模型泛化性能差。本文构造的模型为避免过拟合问题，加入 L_2 正

则化^[15]和 Dropout，以此降低模型的复杂度。在损失函数中加入正则化，需添加正则化参数，计算公式为：

$$J(w, b) = J_0(w, b) + \lambda R(w) \quad (10)$$

其中：模型在训练数据上表现的损失函数为 $J_0(w, b)$ ， w 为权重矩阵， b 为偏置项。模型的复杂度为 $R(w)$ ， λ 为正则化参数，表示模型复杂损失在总损失的比例，采用的是 L_2 正则化，计算公式为：

$$R(w) = \|w\|_2^2 = \sum_i |w_i^2| \quad (11)$$

正则化的加入，可以避免数据权值矩阵过大，即当正则化参数足够大的时候，权重矩阵为一个接近于 0 的值，大量隐藏元的影响变小，神经网络变得更加简单，降低了过拟合现象产生的概率。本文在输出层前加入概率为 0.4 的 Dropout，通过对隐藏层的神经元的激活情况以一定的概率停止工作，减少神经元之间复杂的共适关系，实现权重参数的压缩，有效地防止网络过拟合，更能加快计算。

3.3 模型结构的优化

由公式 (6) 可知，残差块的加入，提出了一种直接映射的思想^[16]，这种思想使得深层网络能够直接获取来自浅层的梯度信息，有利于梯度信息的稳定传递。因此，为了能达到更好的训练效果，将 shortcut 回路移到主路上，可以构造一种满足直接映射的结构，从而实现主通路梯度信息的通畅。此时，可以看作 shortcut 路径为主干路径，残差路径为旁路。

原残差结构如图 7 所示，其中，ReLU 为修正线性单元，是人工神经网络中常用的激活函数，激活函数的引入为神经网络添加非线性因素。因此，网络模型可以拟合任何非线性函数。通常，ReLU 函数是指数学中的斜坡函数，如公式 (12) 所示：

$$\text{ReLU}(x) = \max\{0, x\} = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (12)$$




图 7 原始残差结构

ReLU 函数定义其在计算的正值方向，ReLU 为线性的，保持原先的值不变，负值方向，原先值变为 0。这种函数的优势不仅计算开销小，训练时间缩短，而且本身在非负区间梯度为定值，故梯度不会出现消失现象，能加快收敛速度。BN 层与卷积层、池化层、全连接层一样，属于神经网络的一层，在网络的每一层输入的时候，插入一个归一化层，先做一个归一化处理，归

一化至均值为 0、方差为 1, 之后再进入网络的下一层。BN 层作为神经网络的一层, 解决了中间层数据分布发生改变时, 梯度出现消失或爆炸的问题、针对残差单元改进后框架如图 8 所示。




图 8 改进残差结构

本文改进一共两点, 第一点是通过保持 shortcut 路径的直接映射, 让信息在前向传播和反向传播中平滑传递。第二点是在残差路径上, 将 BN 和统一放在 weight 层前作为 fullpre-activation 模式。这一结构在 16 年的微软研究院的学者的^[17]有更详细讲解。

3.4 学习率调整的改进

学习率^[18]作为深度学习的重要参数, 其数值的设定决定目标函数的收敛的速度和效果。学习率增大虽然能加快学习速率, 帮助模型跳出局部最优解, 但是容易造成模型训练不能够收敛, 从而影响模型的精确度, 学习率过小则相反。因此, 在深度学习的过程中, 采用增大学习率加快模型找到最优解, 跳出局部最优解。在接近损失函数的全局最小值时, 对学习率适当的降低能够使模型尽可能达到最优化。本文采用余弦退火算法^[19]来调整学习率, 在训练过程中, 学习率会先上升再下降, 上升的时候使用线性上升, 学习率的突然提高, 能够跳出局部最小值, 去寻找全局最小值的路径。下降的时候使用模拟余弦函数下降, 学习率先缓慢下降, 然后加速下降, 最后缓慢下降。这种上升下降模式, 实现动态调整学习率, 提高模型的性能, 余弦函数退火算法计算公式为:

$$\eta_i = \eta_{min}^i + \frac{1}{2} (\eta_{max}^i - \eta_{min}^i) \left[1 + \cos\left(\frac{T_{cur}}{T_i} \pi\right) \right] \quad (13)$$

式中, i 为索引值的次数, η_{min} 和 η_{max} 分别为学习率的最小值和最大值, 规定了学习率的界限, 本文设置了 10^{-7} 和 0.001, T_{cur} 为当前执行的迭代轮次, T_i 为重启周期。

现有的余弦退火算法在调整学习率上存在模型振荡, 收敛较慢等问题。设计一种多周期的余弦退火衰减算法, 学习率曲线如图 9 所示。

首先, 针对训练模型初期采用较大的学习率会带来模型的不稳定以及从最小学习率突然跳变到最大学习率导致训练误差的突然增大等问题, 在算法中每个周期都




图 9 多周期的余弦退火衰减算法

加入预热机制, 学习率在开始训练的迭代轮次从小学习率逐步增大, 直到达到正式训练的预定学习率值。其次, 根据在对大型小批量算法的研究中得到的线性缩放原则^[20], 即学习率与批次大小的线性关系, 同步缩放批次大小, 将批次大小从固定的值转变为在合理区间内的循环变化值。最后, 针对热重启后学习率初值为一定值而造成模型不易收敛问题, 采用逐渐衰减初值的方法进行改进, 即:

$$\eta_{max}(T_{i+1}) = \lambda \eta_{max}(T_i) \quad (14)$$

式中, $\eta_{max}[T_{i+1}]$, $\eta_{max}(T_i)$ 分别为相邻两周期的重启最大初始学习率, λ 为衰减因子, 本实验取值为 0.75。为了防止步长减小而掉入局部最优的情况, 在每次搜索过程中记录当前最优解, 并及时更新使之能记住搜索过程中用到的最优解。

4 实验验证和结果分析

本文采用的数据集为两种硅棒的图像, 外观正常和外观有缺陷, 每种数量为 1 000 张, 共计 2 000 张, 其图片的格式均为 bmp, 图片的尺寸大小统一, 同时采用数据增强处理, 对图片采取随机翻转、随机旋转等操作。为了防止人为主观因素干扰, 本文实验对训练样本集和测试样本集采取了随机划分的方式, 二者的比例为 80% 和 20%, 部分数据集图像如图 10 所示。




图 10 训练数据集

4.1 实验环境

本次实验数据全程采用 CPU 进行训练，实验环境基于 Windows10x64 位操作系统，处理器 AMD Ryzen 7 5800H，采用 tensorflow-cpu2.10.0 的 keras 进行训练学习，虚拟环境为 Anaconda3，conda 版本为 22.9.0，编程语言版本为 Python 3.9.12。

4.2 评价指标

本文实验根据网络模型在测试集的分类效果作为评价标准。

$$Acc = \frac{\sum_{i=0}^{N-1} [f(x_i) == y_i]}{N} \quad (15)$$

式中， Acc 为分类的精确度， N 为总数据集， y_i 为样本 x_i 的种类， $f(x_i)$ 为样本 x_i 的预测种类。

在对模型更进一步的评估的过程中，采用统计学中的混淆矩阵来直观地显示分类模型对应各个类别的准确率。

表 1 混淆矩阵

类别	无缺陷	有缺陷
无缺陷	TP	FN
有缺陷	FP	TN

4.3 实验结果

基于改进 ResNet34 的硅棒外观识别模型包括卷积神经网络的训练和模型的应用，本文选取的 2 000 张图片都采用了预处理、分割、定位的方法。初始学习率设为 0.001，运行 50 个迭代轮次，样本大小初始为 16，采用 shuffle 的方法打乱训练集样本，实验选定 ResNet34 和本文改进的 ResNet34 (Our-Model) 进行对比，实验结果如图 11 所示，其中，纵坐标为准确率，横坐标为迭代次数 epoch，在实验过程中，对初始学习率，Dropout 等参数做了多次尝试性微调，选取了效果最好的一次作为本次的对比，模型改进前后准确率对比如图 11 所示。

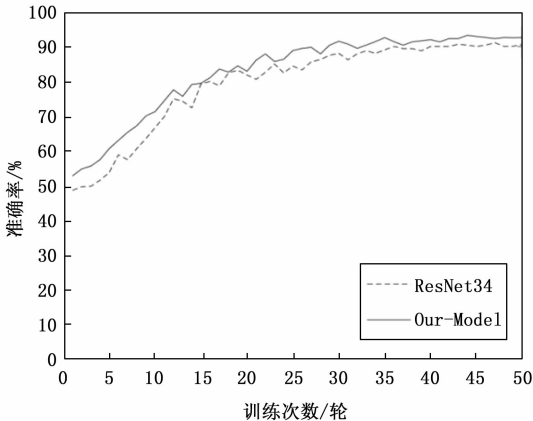
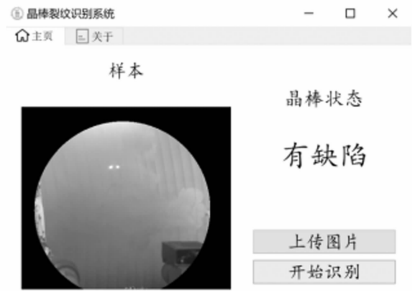
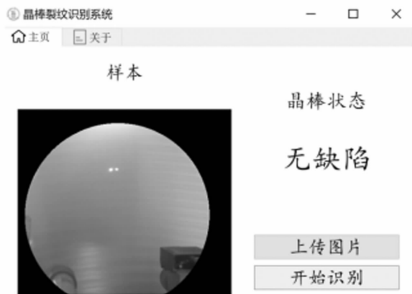


图 11 训练效果对比图

通过对比，改进前模型的精度为 90.05%，改进后模型的精度为 92.46%，不仅提升了训练的精度，而且加快了训练速度。实验选取多张硅棒的照片放入训练好的模型中作为测试对象，测试结果都能得到准确的判断，如图 12 所示。



(a) 有缺陷检测结果



(b) 无缺陷检测结果

图 12 检测结果

如图 12 所示，根据预处理后的样本放入系统中，图 (a) 左侧有腐蚀的痕迹，这种产品不符合生产的需要，图 (b) 为正常的样本，可以直接流入下一生产环节。

4.4 误差分析和验证

改进后的模型相对于原始模型而言，因其在动态变换的学习率中进行模型的学习，所以其能够跳出局部最优解，此外，模型在隐藏层的神经元的激活数量的减少，使得计算量减少，有利于学习后的反向传播。改进后模型的精度目前受两个因素影响，一个是目前所收集的数据集的数量存在不足的问题，无法对缺陷种类进一步分类，另一个是由于训练数据是由人工标注，在一些硅棒轮廓上的缺陷可能因不明显造成标注成无缺陷的，对于训练的判断产生一定的影响，使得在对部分图片的类型判断上产生误判的现象。

对比改进前后 ResNet34 在相同数据集下的训练，得到了两种模型在训练集和测试集上训练效果最好的模型，将其送入测试集图片测试模型的准确度，改进前后测试的结果如表 2 所示。

表 2 改进前后准确率对比 %
(a)改进前准确率

原始模型	无缺陷	有缺陷
无缺陷	90	10
有缺陷	9	91

(b)改进后准确率

本文模型	无缺陷	有缺陷
无缺陷	93	7
有缺陷	6	94

由表 2 数据分布可知, 两种模型对存在缺陷的图片识别效果都高过无缺陷图片的识别, 相比较而言, 改进后的模型在每类的准确率都有提高, 对于工业工艺的改进起着推进效果, 具有一定的应用与推广作用。

5 结束语

本文围绕工业硅棒外观检测进行研究, 针对硅棒图片干扰因素较多的问题, 采用了预处理、阈值分割和连通域分割相结合的方法以内接圆的形式成功定位硅棒的位置, 将其裁剪出来。在卷积神经网络的选取问题上, 基于网络越深, 精度越高的理念, 考虑到精度加深而产生梯度消失对模型的影响, 选取了具有特殊结构的残差网络, 理论上解决了梯度信息前向传播和后向传播过程中丢失的问题。

模型基于 Google 的深度学习平台 TensorFlow 搭建了 ResNet34 网络, 采用 Full pre-activation 结构。在对拟合的问题上, 通过 Dropout 和正则化处理, 能够有效降低隐藏层的神经元在权重更新的影响。在对学习率的调整上, 采用改进的多周期余弦退火衰减算法, 有利于模型跳出局部最优解的问题, 提高模型的收敛速度。经过实验对比, 模型通过进一步的改进, 准确率提升 2.41%, 对工业的外观检测方法研究有重要意义。

参考文献:

- [1] 陆雨薇, 秦世林, 罗 捷, 等. 基于机器视觉的非完整小圆弧测量方案研究 [J]. 工具技术, 2023, 57 (9): 154 - 159.
- [2] 马忠平. 一种基于机器视觉的轴承环形表面缺陷检测 [J]. 中国科技信息, 2023 (19): 129 - 132.
- [3] 万继尧, 孙田成, 陆 毅, 等. 基于机器视觉的海苔表面缺陷检测方法研究 [J]. 工业控制计算机, 2023, 36 (9): 13 - 21.
- [4] 麦俊佳, 曾懿辉, 胡壮丽, 等. 基于深度学习的输电线路航拍照片目标检测应用 [J]. 广东电力, 2020, 33 (9): 174 - 182.
- [5] 叶祖坤, 李 恒, 查文彬, 等. 采用局部阈值分割的刀具损伤视觉检测方法 [J]. 西安交通大学学报, 2021, 55

- (4): 52 - 60.
- [6] 高 晗, 刘卫东, 高立娥. 基于前视声呐的水下目标检测算法研究 [J]. 计算机测量与控制, 2022, 30 (11): 17 - 24.
- [7] 王宪保, 李 洁, 姚明海, 等. 基于深度学习的太阳能电池片表面缺陷检测方法 [J]. 模式识别与人工智能, 2014, 27 (6): 517 - 523.
- [8] 朱 莉, 宋绪秋, 邢 鑫, 等. 基于改进 ResNet34 网络的树种识别研究 [J]. 国外电子测量技术, 2022, 41 (7): 119 - 125.
- [9] 王理顺, 钟 勇, 李振东, 等. 基于深度学习的织物缺陷在线检测算法 [J]. 计算机应用, 2019, 39 (7): 2125 - 2128.
- [10] 唐佐星. 基于机器视觉的单晶硅单晶硅电池片表面缺陷检测系统设计 [D]. 杭州: 杭州电子科技大学, 2022.
- [11] 张丽英, 孙海航, 孙玉发, 等. 基于图卷积神经网络的节点分类方法研究综述 [J]. 计算机科学, 2024, 51 (4): 95 - 105.
- [12] 游忠辉. 卷积神经网络的加速与压缩方法研究 [D]. 北京: 北京大学, 2020.
- [13] 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.
- [14] CHEN T, SON Y, PARK A, et al. Baseline correction using a deep-learning model combining ResNet and UNet [J]. Analyst, 2022, 147 (19): 4285 - 4292.
- [15] ZHUANG Q, GAN S, ZHANG L. Human-computer interaction based health diagnostics using ResNet34 for tongue image classification [J]. Computer Methods and Programs in Biomedicine, 2022, 226: 107096.
- [16] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks [C] //Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, 2016: 630 - 645.
- [17] PRIETO F G, REZAEI A, SAMAVAKI M, et al. -norm vs. -norm fitting in optimizing focal multi-channel tES stimulation: linear and semidefinite programming vs. weighted least squares [J]. Computer Methods and Programs in Biomedicine, 2022, 226: 107084.
- [18] SMITH S L, KINDERMANS P J, YING C, et al. Don't decay the learning rate, increase the batch size [J]. Arxiv Preprint Arxiv: 171100489, 2017.
- [19] CAZENAVE T, SENTUC J, VIDEAU M. Cosine annealing, mixnet and swish activation for computer go [M]. Advances in Computer Games. Springer. 2021: 53 - 60.
- [20] GOYAL P, DOLLÁR P, GIRSHICK R, et al. Accurate, large minibatch sgd: training imagenet in 1 hour [J]. Arxiv Preprint Arxiv: 170602677, 2017.