

# 基于改进 GoogLeNet 的玻璃安瓿瓶微孔检测

曹林杰, 任德均, 任秋霖, 闫宗一, 李 鑫, 唐 洪

(四川大学机械工程学院, 成都 610065)

**摘 要:** 在玻璃安瓿瓶包装完整性检测领域,常用高压放电法对微米级漏孔缺陷进行检测,针对现有方法存在的难以找到合适滤波方式、判别阈值依赖人工设计、检测准确率较低的问题,提出一种基于改进的 GoogLeNet 的微孔检测方法.对于原始放电电流数据,利用小波变换(WT),以广义 Morse 小波函数(GMW)为基小波,将一维的电流时间序列转换为二维的时频索引图以呈现数据完整的细节信息.在 GoogLeNet 原型基础上引入 Relu 激活函数以减少过拟合,将输入端卷积缩减至 1 层,然后进行了三种不同层次的 Inception 模块裁剪,对比分析发现只用前 6 个 Inception 模块并调高 Inception(4d)的大尺寸卷积核占比时,模型能在参数量更少的情况下同样达到很好的微孔判别效果.在生产现场工控机中用训练好的模型替换原有算法,进行 1000 个正负样本的验证测试,结果表明该算法的准确率达到 99.15%,阳性样品漏检率仅 0.8%,优于现有方法的 96.45%准确率和 5.3%漏检率,具有较好实用价值.

**关键词:** 玻璃安瓿; 高压压漏; 时间序列分类; GoogLeNet; 小波变换

**中图分类号:** TP399      **文献标识码:** A      **DOI:** 10.19907/j.0490-6756.2022.052002

## Microhole detection of glass ampoule based on improved GoogLeNet

CAO Lin-Jie, REN De-Jun, REN Qiu-Lin, YAN Zong-Yi, LI Xin, TANG Hong

(School of Mechanic Engineering, Sichuan University, Chengdu 610065, China)

**Abstract:** In the field of glass ampoule packaging integrity detection, high voltage discharge method is commonly used to detect micron-level leaky hole defects. In view of the existing methods, it is difficult to find appropriate filtering mode, discrimination thresholds depend on manual design, and detection accuracy is low, a microhole detection method based on improved GoogLeNet is proposed. For the original discharge current data, through the wavelet transform (WT), and using the generalized Morse wavelet function (GMW) as the basic wavelet, transform the one-dimensional current time series into a two-dimensional time-frequency index graph to present the complete details of the data. On the basis of GoogLeNet prototype, Relu activation function is introduced to reduce overfitting, the input convolution is reduced to 1 layer, and then Inception module cutting at three different levels is carried out. Comparative analysis shows that when only the first 6 Inception modules are used and the proportion of large-size convolution kernels is increased for Inception(4D), the model can also achieve a better effect of microhole discrimination with fewer parameters. In the industrial computer of production site, the trained model was used to replace the original algorithm, and 1000 positive and negative samples were tested. The results show that the accuracy of the algorithm is 99.15%, and the positive sample missing rate is only

收稿日期: 2021-12-13  
作者简介: 曹林杰(1997-), 男, 四川成都人, 硕士研究生, 研究方向为嵌入式系统. E-mail: SCUlinjie@163.com  
通讯作者: 任德均. E-mail: rdjw@163.com

0.8%, which is better than the 96.45% accuracy rate and 5.3% missing rate of the existing method.

**Keywords:** Glass ampoule; High voltage leak detection; Time series classification; GoogLeNet; Wavelet transform

# 1 引 言

玻璃安瓿瓶的质量直接影响国民医疗安全,其瓶壁上如果存在超最大允许漏率的微孔,极易造成药剂泄露和微生物入侵.近年来相关监管部门越来越重视对药品包装密封性的检验,2020 年国家药品监督管理局颁布的《化学药品注射剂包装系统密封性研究技术指南(试行)》要求,“熔封的产品(如玻璃或塑料安瓿等)应当作 100% 的密封性检测”.在众多检测方法中,高压放电法以其准确度高、可靠性好、非破坏性、高速可在线的特点得以在实际生产中大量应用<sup>[1]</sup>.高压放电过程的电流数据属于一维时间序列,需要采取合适的时间序列分类算法识别出阳性瓶波形.当使用高压放电法检测药品包装密封性时,通常通过设置阈值来判断<sup>[2]</sup>,阳性样品理论上有部分波形的幅值会超过此阈值.此算法简单易行但存在以下问题:(1) 特征阈值的设置依赖专家系统,需要现场工人大量观察对比后进行手动设置,操作过程繁琐;(2) 高压放电本身的特性导致数据对温度、湿度等环境变量敏感,当现场环境条件有所变动,原先设置的阈值很可能将不再适用;(3) 复杂的生产现场,以及高压放电本身会对数据采集系统产生噪声干扰,滤除数据中的干扰波形所需的滤波器难以设计.近年来,基于卷积神经网络(Convolutional Neural Network, CNN)的深度学习快速发展,其不仅在图像处理领域能力突出<sup>[3]</sup>,也被广泛应用于序列分类.例如 Cruz 等将 CNN 应用于真核生物基因组中转座因子序列的分类<sup>[4]</sup>;Zhao 等将并行的 2D CNN 与残差网络相结合用于语音的情感识别<sup>[5]</sup>;Luo 等提出一种混合卷积循环网络来对心电图数据中的心律失常进行分类<sup>[6]</sup>.鉴于 CNN 能自动提取特征、对信号质量要求不高的优点,本文将基于 CNN 的深度学习方法引入玻璃安瓿瓶微孔检测领域,并研究其技术路线.

# 2 检测原理与数据获取

## 2.1 高压放电法检测原理

高压放电检测法原理<sup>[7-9]</sup>如图 1a 所示,将正弦高压交流电源的两极分别布置在待检部位和瓶身另一侧,在此放电回路中两个电极所正对的玻璃瓶

壁各自等价为一个容性负载,而瓶内药液呈现阻性,其等效电路如图 1b 所示.当检测电极正对的瓶壁出现漏孔时,电极不再受到瓶壁的阻隔而直接通过药液放电,如图 1c 所示,可视为 C1 被短路. C1 的短路导致高压源的输出负载阻抗下降,放电电流在微孔通过电极时暂时升高,反映在电流波形上则是一个凸起的波峰,通过检测这一异样而与正常样品相区分.




图 1 高压放电法检测原理  
(a) 原理示意图; (b) 完好瓶等效电路;  
(c) 阳性瓶等效电路

Fig. 1 The principle of high voltage discharge detection  
(a) Schematic diagram; (b) equivalent circuit of intact bottle;  
(c) equivalent circuit of bad bottle

## 2.2 样本数据获取

实际生产中,微漏孔可能会出现在玻璃安瓿瓶的任意部位,通常会设立多个电极工位来全面覆盖瓶身表面,为研究方便本文仅针对瓶底部位所存在的微漏孔.产品刚性包装可采纳的最大允许泄露限度为  $6 \times 10^{-6} \text{ mbar} \cdot \text{L} \cdot \text{s}^{-1}$ , 相当于直径介于  $0.1 \sim 0.3 \mu\text{m}$  的孔,选择这个保守的最大允许漏率可确保微生物侵入及液体泄露的风险较低,因而本文将含最小孔径  $0.1 \mu\text{m}$  的玻璃安瓿瓶作为阳性样本研究其检测算法.本文选用如图 2a 所示在靠近瓶底含有直径  $0.1 \sim 5 \mu\text{m}$  微孔的阳性瓶样品 1200 个,其微孔显微图像如图 2b 所示,以及表面完整的好瓶样品 1200 个.玻璃安瓿瓶样品规格为 2 mL 容积,装盛等量等浓度葡萄糖注射液.

在运动试验台上,安瓿瓶样品按照实际生产过程中 300 个/min 产量条件下的运动速度滚动通过高压电极区域,通过数据采集卡采集串联进高压放电回路的采样电阻的电压,得以获取放电过程的电流数据.




图 2 玻璃安瓿瓶样品  
(a) 样品外观; (b) 微孔显微图像  
Fig. 2 Glass ampoule samples  
(a) The sample appearance; (b) microscopic image

3 数据与算法

3.1 数据分析

在 15 kV、1 kHz 正弦交流高压条件下, 典型放电电流波形如图 3 所示. 样品通过电极放电区域所需时间为 75 ms, 为了留有一定余量设置数据采集时长为 90 ms 共 7500 个采样点, 所以在电流波形开头和结尾处样本并未位于放电区间, 电极通过等效阻抗更大的空气间隙放电, 电流幅值较小, 峰值仅约 0.4 mA; 如图 3a 中, 当完好样品处在电极覆盖区间内时, 电极通过“电容-电阻-电容”等效电路放电, 总负载阻抗较空气间隙放电更低, 电流峰值上升并稳定在约 0.6 mA 水平; 而在图 3b 所示阳性样本的微孔运动至靠近电极位置时, 高压电极通过等效阻抗更低的“电阻-电容”等效回路放电, 电流幅值明显上升形成凸起, 峰值超过 2 mA.

除上述主要特征外, 电流波形还耦合了高斯白噪声, 导致电流细节形状并非标准正弦波, 包含明显的高频纹波造成的毛刺. 高斯白噪声功率较低, 易于通过低通滤波器滤除, 一般不会对判别算法的结果造成影响. 但除此之外电流波形上还存在由数据采集系统和复杂工业现场带来的随机干扰造成的瞬时尖峰脉冲. 这种瞬时尖峰对分类算法影响较大, 在图 3 中可以看到, 尖峰的幅值甚至可能超过微漏孔正对电极放电时的电流峰值, 在直接进行超阈值判别的微孔检漏设备上, 瞬时尖峰会直接降低算法准确率. 实际生产中, 通常会对原始电流数据进行滤波, 本文选择常用的低通滤波器和均值滤波对上图中好瓶样本电流进行滤波, 其中低通滤波器为 FIR 滤波器, 通带频率 1 kHz, 止带频率 1.5 kHz, 按等纹波设计, 均值滤波器步长为 5 个采样点, 结果如图 4 所示. 可见滤波处理较好的消除了

高频噪声, 但都无法完全滤除尖峰脉冲, 直接使用传统的阈值判别分类算法仍难有较好效果.




图 3 典型电流波形  
(a) 好瓶电流波形; (b) 阳性瓶电流波形  
Fig. 3 Typical current waveform  
(a) Waveform of intant bottle; (b) waveform of bad bottle




图 4 好瓶样本滤波后波形  
(a) 低通滤波结果; (b) 均值滤波结果  
Fig. 4 The filtered waveform of intant bottle  
(a) Result of low-pass filtering; (b) result of mean filtering

3.2 小波变换预处理

卷积神经网络常用于二维图像处理, 而一维的电流数据不适合直接投入网络模型进行训练, 为此需要选用一种变换方式将电流数据转化为二维时频图像. 信号处理的传统傅里叶变换是对信号的全局性频率分量计算, 无法表示具体时刻的信号构成<sup>[10]</sup>, 常用于分析周期性平稳信号, 从图 3 可知, 样本信号关键特征点在于微漏孔正对高压电极时才产生的短时幅值跳变, 属于非平稳信号. 短时傅里叶变换(STFT)利用窗口平移的方式突破了全局性的限制, 但因窗口一旦选定就不能改变, 对信号的分辨尺度缺乏灵活性. 小波变换继承和发展于 STFT, 从低频到高频范围内都具备清晰的分辨能力<sup>[11]</sup>, 更适用于解耦间歇、瞬态、非周期的信号<sup>[12]</sup>. 小波  $\Psi(x)$  即满足式(1)的一系列函数, 常用的小波函数有<sup>[13]</sup>: dbN 小波函数、morlet 小波函数、mexican hat 小波函数和 symN 小波函数.

$$\int_{-\infty}^{+\infty} \Psi(x) dx = 0 \tag{1}$$

我们用  $y(t)$  表示待分析信号,将  $y(t)$  分别与选定的小波函数平移和水平缩放后得到的小波序列积分,如式(2)所示,即为  $y(t)$  的小波变换:

$$(W_{\psi}y)(a,b) = \sqrt{\frac{1}{|a|}} \int y(t) \Psi(\frac{t-b}{a}) dt \tag{2}$$

其中  $a$  和  $b$  分别为缩放因子和平移因子,小波序列中不同  $a$  和  $b$  参数的小波积分后的结果便能体现出原始信号不同时刻上不同频率的信号所占分量,将整个小波序列和信号的积分结果结合在一起就获得了目标信号的所有时间和频率细节特征分布,并由一维序列转换到了二维时频矩阵.对于信号瞬时频率,广义 Morse 小波(GMW)<sup>[14,15]</sup>是完全解析的,比通常采用的复 Morlet 小波具有更好的时频分辨率<sup>[16]</sup>,式(3)是 GMW 的傅里叶变换形式.

$$\psi_{\beta,\gamma}(\omega) = U(\omega) a_{\beta,\gamma} \omega^{\beta} e^{-\omega^{\gamma}} \tag{3}$$

其中  $U(\omega)$  是阶跃函数;  $a_{\beta,\gamma}$  是一个常数;  $\gamma$  和  $\beta$  分别是与小波的对称性和衰减性相关,当  $\gamma=3, \beta=20$  时,GMW 的实部和虚部波形如图 5 所示.




图 5 GMW 波形  
Fig. 5 Waveform of GMW

利用此参数下的 Morse 小波序列对电流数据进行小波变换,得到  $120 \times 7500$  的复数系数矩阵,求模后将结果等比例缩放至区间  $[0,1]$ ,以之作为系数生成 128 色的索引图,如图 6a 和 6b 所示.对比二者可发现波形主体频率成分为 1 kHz 左右,与高压频率吻合,而好瓶的 1 kHz 成分波形均匀分布在放电过程中,阳性瓶则是在微孔正对电极时频图上 1 kHz 频率成分的暖色明显突增(即幅值增大),与前后形成显著差异.此外图上高频部分的雪花状背景由白噪声产生,而竖直的明亮条带则对应了随机出现的瞬时尖峰脉冲干扰,成条带状说明瞬时尖峰包含了大频率范围的谐波.将索引图转换为对应的 RGB 图矩阵,尺度为  $120 \times 7500 \times 3$ ,为适应常用图形处理网络模型的输入层维度,将 RGB 图形压缩至  $224 \times 224 \times 3$ ,图 6a 和 6b 的最终转化结果分别如图 6c 和 6d 所示.

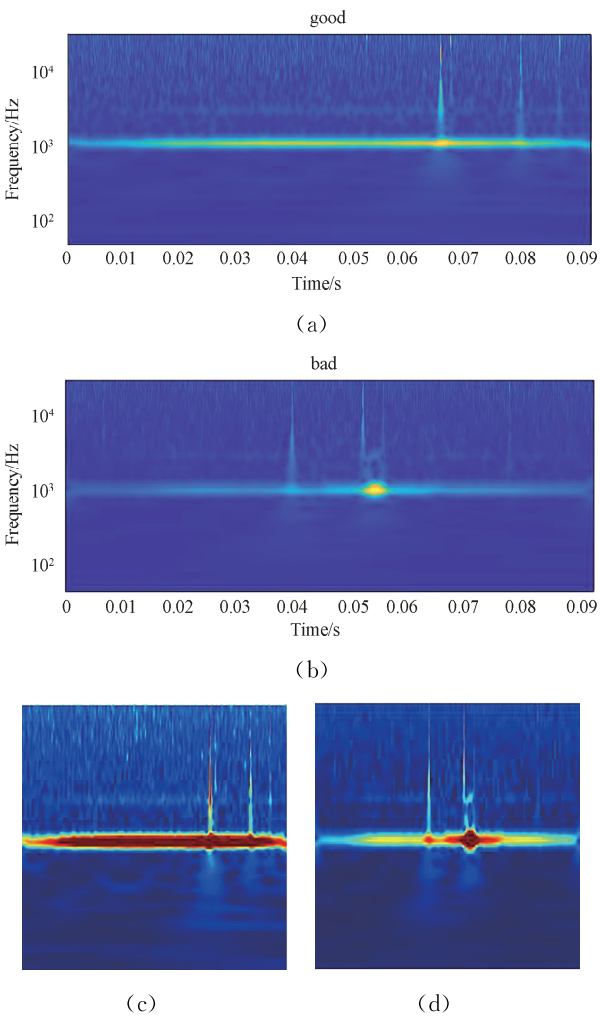


图 6 电流小波变换时频图  
(a) 好瓶电流时频图; (b) 阳性瓶电流时频图;  
(c) 好瓶预处理结果; (d) 阳性瓶预处理结果

Fig. 6 Time-frequency diagram of current after wavelet transform

(a) Time-frequency diagram of infant bottle's current; (b) time-frequency diagram of bad bottle's current; (c) pretreatment result of infant bottle; (d) pretreatment result of infant bottle

3.3 模型建立

3.3.1 GoogLeNet 网络架构 GoogLeNet 是谷歌 2014 年推出的用于图片分类的深度学习神经网络模型<sup>[17]</sup>,在当年的 ImageNet 视觉识别竞赛中获得冠军,top5 错误率仅 6.63%,参数较少且性能优越<sup>[18]</sup>,所以本文选择 GoogLeNet 作为原始模型.一般来说增加神经网络的深度和宽度能够获得能力更强的深度学习模型,但深度和宽度过大会导致:(1) 参数变多,计算开销过大;(2) 需要更大的训练数据集,否则容易出现过拟合;(3) 容易出现梯度弥散现象不利于优化模型.

GoogLeNet 的提出正是为了解决上述问题,在增加网络深度及宽度的同时有效降低计算量,其



实现方式是提出了名为“Inception”的小型网络,以之为基本模块串联形成主体框架。Inception 有 V1、V2、V3 等版本<sup>[19]</sup>,本文仅采用最经典的 V1 版本进行算法构建。其模块结构<sup>[20]</sup>如图 7 所示。




图 7 Inception 模块结构  
Fig. 7 Structure of Inception module

一个 Inception 模块由并行的三路卷积通道组成,卷积核大小分别为  $1\times1$ 、 $3\times3$  和  $5\times5$ ,它们提供了 3 种不同大小的感受野,外加一路被大量实验证明有效的 max 池化,训练过程中模型自主决定对四个通道特征的取舍和组合。该结构最大的创举在于在  $3\times3$  和  $5\times5$  卷积核之前先使用一个  $1\times1$  的卷积核,通过调整  $1\times1$  卷积核的数量达到对输入特征降维的同时保持信息提取能力的效果。在 max pooling 层后紧随的  $1\times1$  卷积层同样降低了输出特征的维度。完整的 GoogLeNet 结构如图 8 所示,输入图片先经过核大小分别为  $7\times7$ 、 $1\times1$ 、 $3\times3$  的三个卷积层,然后连接到 9 个 Inception 模块组成的主体网络,末尾是一个全连接层连接到分类器,总深度达到了 22 层。在 Inception (4a) 和 Inception (4d) 的末尾分别加入了两个 softmax 分支,由  $5\times5$  的 average pooling,  $1\times1$  的卷积,两个全连接和 softmax 组成,用于训练时对抗梯度消失和提供正则化,最终执行分类任务时不会使用。

3.3.2 模型改进 GoogLeNet 原本是为 1000 分类任务而设计的,不能直接用于本文场景,需要将原网络中最后实现分类任务的 fully connected layer 输出尺寸由 1000 改为 2,并替换一个新的 classification layer。线性模型的分类能力有限,通过引入激活函数对卷积输出做非线性映射处理<sup>[21]</sup>,以提高网络的学习能力。在常用的激活函数中,Relu 函数有计算简单、收敛快、不存在梯度消失

现象以及可减少过拟合的优点,所以本文选择在模型中引入 Relu 函数作为激活单元,其定义见式(4)。

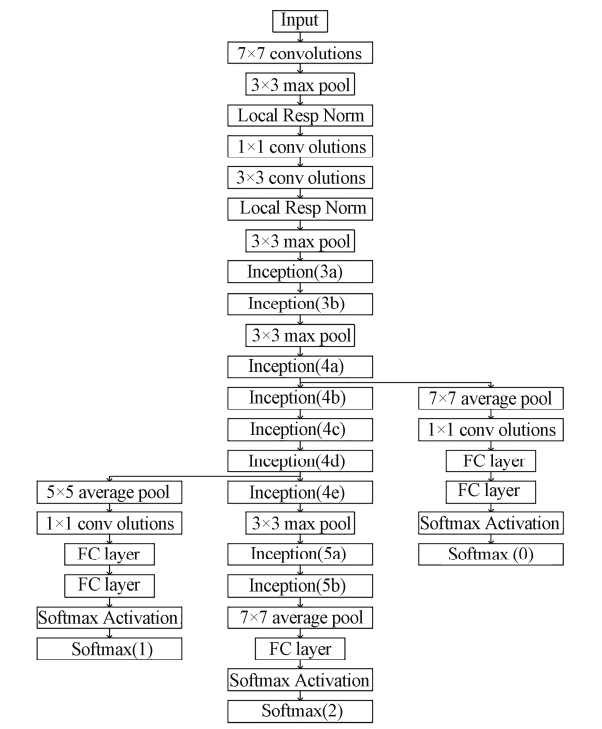
$$Y(x)=\max(0,x) \tag{4}$$


图 8 GoogLeNet 结构细节  
Fig. 8 Structure details of GoogLeNet

由于玻璃安瓿瓶放电电流的时频图特征较为明显,不需要很深的网络层次来学习分类的边界特征,出于减少参数和降低过拟合风险的目的,对 GoogLeNet 原本的 9 组 Inception 模块网络进行剪裁。虽然每一个 Inception 的结构相同,但靠近输入端的 Inception 主要学习纹理、轮廓等细节特征,因而感受野小的  $1\times1$  和  $3\times3$  的卷积核占比更高;而靠近输出端的 Inception 偏向于处理更整体更抽象的信息,大感受野的  $5\times5$  卷积核占比更多,所以如表 1 所示越靠后的 Inception 参数量越大。为了更大限度的减少整体参数量,本文从末端进行裁剪,并对不同裁减情况的效果进行对比。此外也对图片输入层与 Inception(3a)之间做精简,将原本的  $7\times7$ 、 $1\times1$ 、 $3\times3$  的三层卷积结构替换为单层的  $3\times3$  卷积,进一步节省参数。

表 1 Inception 模块参数量									
Tab. 1 Parameter numbers of Inception modules									
Inception(x)	3a	3b	4a	4b	4c	4d	4e	5a	5e
参数量/ $\times10^3$	159	380	364	437	463	580	840	1072	1388

4 结果分析

本文的研究过程在 windows 10 上进行,所用 CPU 型号为 i5-9300H,运行内存 16 G,GPU 为 GTX 1650,以 Pytorch 作为深度学习框架.从上文提到的 1200 个好瓶和 1200 个阳性瓶的电流时频图中各随机选 1000 个作为训练集,剩余的作为测试集.设置 batch size 为 20,epoch 设定为 3 轮,学习率设定为 0.0001,利用交叉熵函数作为损失函数(Loss function),使用带有动量的随机梯度下降(SGDM)优化器,训练结果如表 2.

表 2 训练结果  
Tab.2 Training results

Inception 裁剪个数	训练准确率/%	验证准确率/%
0	99.0	98.6
1	99.0	98.8
2	99.2	99.0
3	98.5	98.0

从表 2 可见,在未裁剪、裁剪 1 个、裁剪 2 个 Inception 模块时,模型的训练、验证准确率表现十分相近,其中裁减掉 2 个 Inception 模块的效果最好,训练准确率比其他两组高 0.2 个百分点,验证准确率达到 99%.对此认为当 Inception 模块网络达到 7 层时已经有足够的网络深度来学习电流曲线时频图的分类特征.剪裁个数从 2 到 0 模型的两个准确率指标略有下降是因为在深度已经足够的情况下模型在一些不太重要的特征上产生了过拟合.此外,在剪裁掉末端 3 个 Inception 模块时,模型的表现出现了较明显下降,相比剪裁掉 2 个 Inception,训练准确率下降了 0.7%,验证准确率下降了 1%.注意到在 GoogLeNet 中从 Inception (4d)到 Inception(4e), $5\times 5$  的卷积核数量由 64 上升到了 128,目的是在深度更深的 Inception 中加大对整体性特征的提取比例,而裁剪掉最后 3 个 Inception 把  $5\times 5$  卷积核占比大的 Inception 都舍弃了,可能正是由此导致了此时模型表现的较大劣化.受此分析启发,当模型裁剪 3 个 Inception 模块时,将裁剪后末端的 Inception(4d)中  $5\times 5$  卷积核数从 64 增加至 128, $3\times 3$  卷积核数从 288 降低到 144 以提高大感受野卷积核的占比,再次训练模型,过程曲线如图 9 所示.最终的训练准确率达到 99.5%,比之前效果最好的剪裁掉 2 个 Inception 模块的实验组还高 0.3%,利用验证集进行验证,准确率为 99%,与最好效果持平.可见,增大最

后一个 Inception 模块  $5\times 5$  卷积核占比使得模型在深度更浅、参数更少的情况下仍然取得了很理想的分类效果.对于正负样本,考察详细的分类情况,结果如表 3 所示,发现分类错误全部来自于正常样本,有个别正常品因为局部噪音占比过大引起了模型误判,而对于可能引起严重后果的阳性样本则达到了 100%的分辨准确率.




图 9 训练过程曲线  
(a) 训练准确率; (b) 过程损失  
Fig.9 Training process curve  
(a) Training accuracy; (b) loss curve

我们将本文所提出的算法部署到某公司现场玻璃安瓿分类设备工控机上,在 300 个/min 产量条件下与原本使用的基于均值滤波+手动设定阈值的算法进行效果比较,结果如表 4 所示.在现场的 1000 个阳性瓶中,本文所述算法正确检出了其中的 992 个,明显优于传统算法的 947 个;而在 1000 个正常瓶的检测中,本文算法仅误判 9 个,误检率 0.9%,为传统算法的一半;综合准确率为 99.15%,高于原算法的 96.45%.但从时间开销来看,本文算法平均耗时 48 ms,比起传统算法多消耗了 31 ms,在当前产量条件下单瓶周期为 200 ms,耗时能够满足要求,但若产量提高较多可能在实时性方面更难满足要求.

表 3 验证集分类结果

Tab.3 Classification results of validation set		
样本类型	样本数/个	分类正确数/个
阳性瓶	200	200
正常瓶	200	196

表 4 现场效果对比

Tab.4 Comparison of spot effect					
算法	阳性瓶		正常瓶		平均耗时/ms
	总数/个	检出/个	总数/个	误判/个	
滤波+阈值判定	1000	947	1000	18	17
CWT+GoogLeNet	1000	992	1000	9	48

5 结 论

通过小波变换和改进的 GoogLeNet,本文将深度学习的方法引入了玻璃安瓿瓶微孔检测,达到

了比传统算法更好的检测效果,为提高玻璃安瓿的安全性提供了更好的技术保障.未来将在进一步轻量化模型、提高模型泛化能力等方面作进一步研究,使得在更高产量、更复杂工况、更多产品规格的场景中满足实用要求.除了玻璃安瓿瓶,深度学习在整个包装密封性检测领域都有较大应用潜力,加以推广将极大提升行业水平.

## 参考文献:

- [1] 曾凡云,李姝洁,李伟,等.注射剂一致性评价与无菌药品包装系统密封性创新验证[J].流程工业,2020(8):46.
- [2] Luo Y, Cui G X, Li D G, *et al.* An improved gesture segmentation method for gesture recognition based on CNN and YCbCr [J]. Can J Elect Comput E, 2021, 2021: 1.
- [3] Wang Z G, Yan W Z, Oates T. Time series classification from scratch with deep neural networks: A strong baseline [C]//Proceedings of the 2017 International joint conference on neural networks (IJCNN). [S.l.]: IEEE, 2017.
- [4] da Cruz M H P, Domingues D S, Saito P T M, *et al.* TERL: classification of transposable elements by convolutional neural networks [J]. Brief Bioinform, 2021, 22: bbaa185.
- [5] Zhao Z P, Li Q F, Zhang Z X, *et al.* Combining a parallel 2D CNN with a self-attention Dilated Residual Network for CTC-based discrete speech emotion recognition [J]. Neural Networks, 2021, 141: 52.
- [6] Luo X Y, Yang L Y, Cai H Y, *et al.* Multi-classification of arrhythmias using a HCRNet on imbalanced ECG datasets [J]. Comput Meth Prog Bio, 2021, 208: 106258.
- [7] 严扎杰,任德均,陈儒侠,等.基于高压放电的大输液塑料瓶泄漏检测技术研究[J].机械,2018,45:19.
- [8] 邵建设,明星,雷学堂,等.正弦波高压放电塑料瓶漏液检测可靠性的仿真和实验研究[J].高压电技术,2014,40:1895.
- [9] 宫黛.用于药瓶漏液检测的高压放电电源系统研制[D].上海:上海交通大学,2015.
- [10] 张颖,马承泽,杨平,等.基于小波变换和改进PCA的人脸特征提取算法[J].吉林大学学报:理学版,2021,59:1499.
- [11] Da Silva M, Oleskovicz M, Coury D V. A hybrid fault locator for three-terminal lines based on wavelet transforms [J]. Electr Pow Syst Res, 2008, 78: 1980.
- [12] Addison P S. A review of wavelet transform time - frequency methods for NIRS-based analysis of cerebral autoregulation [J]. IEEE Rev Biomed Eng, 2015, 8: 78.
- [13] Singh C B, Choudhary R, Jayas D S, *et al.* Wavelet analysis of signals in agriculture and food quality inspection [J]. Food Bioprocess Tech, 2010, 3: 2.
- [14] Tiryaki E, Kocahan Ö, Özder S. An improved method for determination of refractive index of dielectric films from reflectance spectrum by using the generalized morse wavelet [J]. Meas Sci Rev, 2021, 21: 61.
- [15] Kocahan Ö, Özcan S, Coşkun E, *et al.* The generalized Morse wavelet method to determine refractive index dispersion of dielectric films [J]. Meas Sci Technol, 2017, 28: 045013.
- [16] 王超,朱宏平.基于广义Morse小波和EWT的移动载荷下结构时变频率识别[J].振动与冲击,2020,39:24.
- [17] Szegedy C, Liu W, Jia Y, *et al.* Going deeper with convolutions [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.]: IEEE, 2015.
- [18] Szegedy C, Vanhoucke V, Ioffe S, *et al.* Rethinking the inception architecture for computer vision [C] //Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.]: IEEE, 2016.
- [19] Huang X H, Chen W H, Yang W D. Improved algorithm based on the deep integration of googlenet and residual neural network [J]. J Phys Confer Ser, 2021, 1757: 012069.
- [20] Ding A J, Liu T Z, Zou X. Integration of ensemble googlenet and modified deep residual networks for short-term load forecasting [J]. Electronics, 2021, 10: 2455.
- [21] 李国权,徐永海,林金朝,等.基于深度学习的无线物理层关键技术研究综述[J].重庆邮电大学学报:自然科学版,2020,32:503.

## 引用本文格式:

中 文:曹林杰,任德均,任秋霖,等.基于改进 GoogLeNet 的玻璃安瓿瓶微孔检测[J].四川大学学报:自然科学版,2022,59:052002.

英 文:Cao L J, Ren D J, Ren Q L, *et al.* Microhole detection of glass ampoule based on improved GoogLeNet [J]. J Sichuan Univ: Nat Sci Ed, 2022, 59: 052002.