DOI:10.20033/j.1003-7241.(2026)07-0025-06

基于 PSO-CNN 算法的包装缺陷预测方法

刘丽平

(南京机电职业技术学院, 南京 210000)

摘　要:针对包装生产中常见的印刷缺陷进行多种神经网络下预测策略对比分析并进行对比,为同类的包装缺陷预测提供精确可靠的控制方案。以实际的某烟盒包装生产中的缺陷为例,根据不同包装缺陷决策统计工艺进行输入,而后进行池化后实现多层连接最终得到神经网络,而后通过引入粒子群寻优算法分别构造 PSO-BP 和 PSO-CNN,并与常规 BP 神经网络和 CNN 神经网络进行效率对比。在控制方案建立的基础上对统一包装缺陷输入特征加以确定,并与正常包装特征进行对照,最终对整个该类包装的各阶段进行计算并实现整个过程的良性评价。通过构建四种全面的预测网络方案,得到包装缺陷预测的多样本对照结果。通过结果可知 PSO-CNN 相较其他三种网络具有更强的预测精准度,其预测效率可达到 95.8%,其预测时间为 18.2 s。通过使用合适的粒子群寻优预测网络方案有效地优化了原有神经网络模型,为后续实际应用于相关生产过程中提供科学的理论支持并为后续研究奠定基础。

关键词:神经网络;粒子群卷积算法;预测;包装缺陷;寻优;缺陷评价

中图分类号: TB486;TP391.41　　**文献标志码**: A　　**文章编号**: 1003-7241(2026)07-0025-06

Packaging defect prediction method based on PSO-CNN algorithm

Liu Liping

(Nanjing Vocational Institute of Mechatronic Technology, Nanjing 210000, China)

Abstract: According to the common printing defects in packaging production, various neural networks are compared to provide accurate and reliable control scheme for the prediction of similar packaging defects. In the actual defects in the production of a cigarette packaging, for example, according to the different packaging defect decision statistics process for input, and then after pooling multilayer connection finally get neural network, and then through the introduction of PSO-BP and PSO-CNN, and with the conventional BP neural network and CNN neural network efficiency comparison. On the basis of the establishment of the control scheme, the input characteristics of the unified packaging defects are determined, and compared with the normal packaging characteristics, and finally the various stages of the whole type of packaging are calculated and finally realize the benign evaluation of the whole process. After the neural network strategy analysis and particle swarm optimization algorithm, four comprehensive prediction network schemes are constructed, and a variety of packaging defect prediction results show that PSO-CNN has stronger prediction accuracy than the other three networks, its prediction efficiency can reach 95.8%, and its prediction time is 18.2 s. The original neural network model is effectively optimized by using a suitable particle swarm optimization prediction network scheme, providing scientific theoretical support for the practical application in the related production process and laying a foundation for subsequent research.

Keywords: neural network; PSO; prediction; packaging defect; optimization; defect evaluation

在包装印刷制造过程中,由于生产工艺和环境因素的影响,可能会导致包装印刷成品出现与标准要求不符的缺陷或瑕疵[1]。例如,一些区域可能会因为比标准厚度薄而形成不同程度的斑点,缺陷部位可能会出现孔洞和裂缝,而外来杂物可能导致黑斑等问题。这些缺陷不仅会影响包装印刷品的质量,还会严重影响用户的使用体验[2-6]。因此,应及早发现包装印刷过程中的异常情况,及时剔除有缺陷的包装半成品区域。

近年来,国内外在基于深度学习的缺陷检测技术领域取得了显著进展,尤其是在目标检测算法优化、多场景应用及工程化落地方面展现了多层次创新。基于智能算法在实际生产中已经被视作一种高效而快捷的包装缺陷检测技术,其原理在于将图像的灰度级按照一个或多个划分为多个区域。当图像像素的灰度值不在预设的范围内时,系统会判定存在包装生产中的缺陷[7-13]。在已有的生产中,通常通过数学形态学来进行检查,而其往往对于描述数学形态学算子的性能要求相对较高,如果引入神经网络算法则可对系统损伤加以更快的判定,使得整个系统可以更适合于视觉信息的处理与分析。这一方法的优点在于克服了法检测中需要针对不同纸病设定不同的繁琐过程。以实时目标检测算法(you only look once, YOLO)系列为代表的实时检测算法成为研究核心,例如 Rhim[14] 将深度

收稿日期:2025-10-16;**录用日期**:2025-11-27

基金项目:南京机电职业技术学院科技项目资助(HX-202315)

作者简介:刘丽平(1985—),女,讲师,硕士,主要研究方向为信号与信息处理。

引用本文:刘丽平. 基于 PSO-CNN 算法的包装缺陷预测方法[J]. 自动化技术与应用, 2026,45(7):25-30. (Liu Liping. Packaging defect prediction method based on PSO-CNN algorithm[J]. Techniques of Automation and Applications, 2026,45(7):25-30.)

学习应用于增材制造的实时热监测,Pham 等[15]则分别通过 YOLO 框架实现包装缺陷和 PCB 混合缺陷的高效检测,验证了该算法在工业质检中的通用性[16]。国内研究同样聚焦于算法改进与本土化应用,如巩雪等[17]通过改进 Faster R-CNN 提升零食包装盒检测精度,胡丹等[18]结合图像区域与骨架特征优化条形码印刷缺陷识别,而马志程等[19]基于 Mask R-CNN 的光学元件划痕检测研究进一步拓展了实例分割技术的应用场景。技术优化层面,Zhao 等[20]提出的 Fire-YOLO 针对火灾巡检的小目标检测需求,通过模型轻量化与特征增强提升了极端环境下的鲁棒性;与之形成对比的是,Zafar 等[21]对池化方法的系统性比较揭示了传统卷积网络在特征提取效率上的局限性,而袁金丽等[22]设计的 MFMANet 通过多尺度注意力机制实现医学图像精准分割,体现了医疗领域对高精度分割网络的独特需求。值得注意的是,部分研究存在重复性问题,如 Vinod Kumar 团队[23]关于 PCB 缺陷检测的两篇文献内容高度重叠[23],反映出学术资源整合的必要性。

在食品、医药及消费品生产领域,包装质量是保障产品安全与市场竞争力的核心环节[24-27]。传统人工检测存在效率低、漏检率高等问题,而基于深度学习的自动化缺陷检测技术虽已应用,但面对包装行业缺陷类型多样(如表面划痕、印刷污渍、结构破损)、样本分布不均等复杂场景,仍面临特征提取能力不足、模型泛化性弱等挑战。在此背景下,本研究提出一种基于粒子群优化(particle swarm optimization, PSO)与卷积神经网络(convolutional neural network, CNN)融合包装缺陷预测模型的粒子群卷积算法(particle swarm optimization-convolutional neural network, PSO-CNN),旨在通过智能优化算法提升 CNN 对缺陷特征的识别精度与鲁棒性。该模型利用 PSO 算法模拟群体智能搜索机制,对 CNN 的关键参数进行全局优化,解决传统 CNN 训练易陷入局部最优的问题。

PSO-CN 的设计灵感来源于粒子群优化的群体智能和卷积神经网络在图像处理领域的强大能力。准确预测包装印刷过程中的缺陷,不仅可以帮助包装印刷中的运营者合理安排维护计划,降低维护成本,还能够减少由于机械故障引发的事故风险,在降低其印刷经济成本的同时甚至保障工人身体健康。本研究通过机器学习和数据分析相结合的方式来对包装印刷过程中的缺陷进行预测和识别。通过对实际生产中的大量数据进行识别分析,进而在此基础上搭建其神经网络预测模型,以实现对包装生产中的缺陷及时甄别与评价。通过研究在关注损伤发生的预测的同时,为维护人员提供生产过程中的产品信息,进而为后续产品分辨和后处理提供便利。

1 包装缺陷预测算法

基于卷积算法的高效与精准性,粒子群卷积算法具有聚类和高精准识别的双重优势,为数据分析和特征提取领域带来了强大的能力。在包装行业的缺陷预测领域[9]。该算法可以在机械设备运行数据的基础上,依据不同类型数据的特点加以提取,将其具有明确规律和特征的数据总结,构建出适合算法的训练集,便于对包装生产中的相关缺陷进行精准预测和识别。粒子群算法可以在识别时间序列数据的基础上,及时有效地对其内在相关的非线性特征进行捕捉,这一方式也成为包装缺陷预测检测核心内容[10]。通过将机械设备的运行数据与卷积神经网络结合,算法能够自动地从大量数据中提取有价值的信息,将这些信息转化为可预测和可识别的缺陷模式,粒子群卷积算法的引入将加速包装制造业的智能化进程。

1.1 卷积神经网络

卷积神经网络是一种在图像处理和模式识别领域表现出色的人工神经网络结构。它通过卷积操作和池化来对包装缺陷中的相关特征加以精准识别和分类。将卷积神经网络与粒子群优化结合,粒子群卷积算法可以在网络的训练过程中更精准地搜索最佳的权重参数配置,从而进一步提升模型的性能和泛化能力。卷积神经网络在多个领域取得了重大突破,如计算机视觉、图像识别以及自然语言处理[11]。其独特结构和特性使得它成为处理网格结构数据(如图像和文本序列)的强大工具,被认为是深度学习的核心技术之一。卷积神经网络的理念植根于生物视觉感知思想,旨在模拟视觉皮层对图像的处理方式。通过引入卷积层(convolutional layer, CL)、池化层(pooling layer, PL)以及全连接层(fully connected layer, FL)等构成,卷积神经网络能够自动地从原始数据中提取特征,并逐步形成更抽象的表达[12]。在卷积层中,局部感知机制使网络能够捕捉图像中的局部特征,而池化层则帮助缩减数据维度,从而减少计算量和过拟合风险。最终,通过全连接层,网络能够将从不同层级提取的特征整合,进行分类和预测。

在图 1 包装类卷积神经网络结构模型的基础上,可知

$$\begin{cases} Q_i = P, i = 1 \\ Q_i = g_i[h_i(Q_{i-1}, M_i, s)], i > 1 \end{cases} \tag{1}$$

式中,Q_i 表示第 i 层函数;i 表示网络层数;P 表示包装输入函数;$g[\cdot]$ 表示激活函数;$h_i(\cdot)$ 表示第 i 层函数加权计算值;M_i 表示第 i 层函数权值;s 表示加权偏置值。

在式(1)中,对于第 i 层函数加权列出方程组为

$$\begin{cases} h_i = h_{i-1} \otimes M_i + s, i \subset \text{Conv} \\ h_i = \text{Pooling}(g_{i-1}), i \subset \text{Pool} \\ h_i = h_{i-1} \cdot M_i, i \subset \text{FC} \end{cases} \tag{2}$$

式中,$\otimes$ 表示卷积层运算符号; Pooling(·)表示包装缺陷特征卷积运算结果参数。

利用式(2)的初期输入,其中包含了数据的特征。通过卷积神经网络的计算,这些特征将被转化为网络的预测结果。进而,将预测结果与实际结果进行对比,得出系统预测与实际相对比的结果。在算法中,对卷积网络中的计算流程可采取逆向计算结果来进行梯度下降加权,通过得到不同误差区间的阈值来得到其误差区间结果。在卷积

网络的计算过程中,大量输入数据被用于时间试错分析,从而得出包装印刷缺陷的预测区间。然而,这一过程常常费时且复杂。为了优化计算过程,引入粒子群算法进行二次寻优计算,对已有的卷积神经网络进行优化。通过这一方法能够有效提高整个神经网络的预测精度,使其更加准确和可靠,为计算过程带来了更高的效率和准确性。

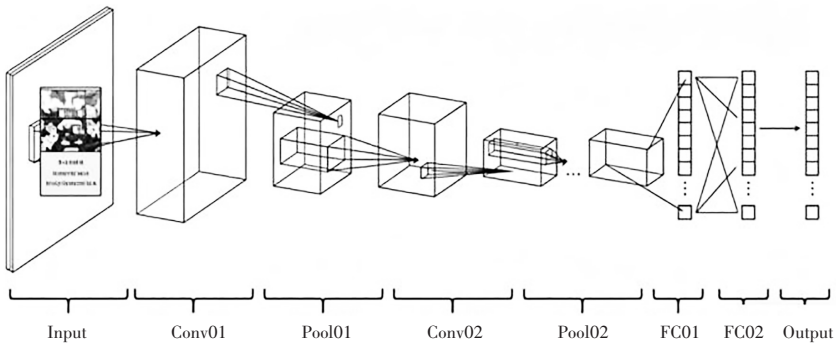


图 1 包装类卷积神经网络结构模型

Fig. 1 Packaging convolution neural network structure model

1.2 粒子群卷积算法

粒子群算法的核心是在卷积神经网络中粒子群优化的方式来调整其算法的权重和数据偏置。在粒子群的卷积中将不同粒子进行参数化的组合构建,其本质在于通过离散化处理。该算法种群则可被认为是由预设解构成,每个解可被表征为问题的预设解。在开始过程中,其相关粒子随机被分配,具有初定的位置和速度。并且在各层迭代过程中,可依据粒子所处的环境不同而及时进行自身速度和位置调整,最终在不断迭代下得到其解空间中最佳粒子[13]。通过将算法应用于卷积神经网络的优化过程中,可以提高网络的性能、特征提取和模式识别的准确性,其中粒子依据解空间的时序情况下个体最优解 Ψ 和全局最优解 Φ 来实时更新自身属性,明确粒子所在解空间的特定位置。在粒子群算法中,每个个体具有其个体最优解和整个种群的全局最优解。个体最优解指的是粒子在过去搜索过程中达到的最佳位置,全局最优解顾名思义,代表着所有的粒子在解空间中的最佳位置。在上述“两个标志性解”的基础上,可以保证粒子在运动过程中沿着全局最优解的方向移动,使得在整个算法中可以获得其过程中的最佳粒子。个体最优解和全局最优解在粒子群算法中扮演着重要角色。个体最优解允许每个粒子保持对自身在搜索过程中发现的最佳位置的记忆。与此同时,全局最优解鼓励粒子们共同朝着整体最优解的方向前进。通过不断调整粒子的速度和位置,每个粒子逐渐靠近全局最优解,同时在个体最优解和全局最优解之间找到了一个平衡。在上述原理的基础上,可以将粒子优化速度表示为

$$V_i = \dot{V}_i + \alpha_1\eta(\Psi_i - X_i) + \alpha_2\eta(\Phi_i - X_i) \tag{3}$$

式中,V_i 表示网络层数;$\dot{V}$ 表示粒子最新速度值;η 表示随机数值;α_1,α_2 表示学习系数,其两者数据分别为 1.4 和 1.5,维度为 16。

粒子群优化算法的核心在于对卷积神经网络权重迭代,结合算法的特点,在算法设计中将神经网络的训练损失函数依照其层级特征设定为聚类的优化目标。而在群中的不同粒子均对应着相应的加权比重,在算法中的粒子不同参数表征着不同权重下的算法组合结果[14],其中的寻优过程就是迭代粒子自身信息过程,直至其算法得到自身的最优解。该方法可以得到其算法运行结果下的最优权重参数,其算法的流程如图 2 所示。

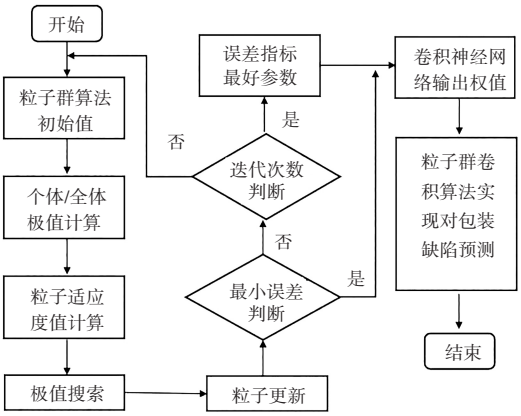


图 2 粒子群卷积算法的流程

Fig. 2 Process chart of the particle population convolution algorithm

粒子群卷积算法在包装缺陷预测模型由三个核心组成部分构建而成,并经过归一化处理,转化为结构化数据。这个过程将样本划分为正常数据集和损伤数据集。粒子群卷积算法发挥作用,从正常数据集和损伤数据集中提取关键特征,深入挖掘数据之间的内在联系,从而生成高维度的特征表示集。在模型构建借助粒子群卷积算法的智能优化,揭示了数据背后的信息蕴含和潜在规律。模型将当前状态的特征数据输入预测模块,执行计算,得出包装缺陷程度的偏差。

基于 PSO-CNN 的包装印刷生产线中的包装缺陷预测模型框架如图 4 所示。

预测模型主要包含 3 个部分:1)对包装印刷生产线中的包装历史数据样本进行分类,并对数据归一化处理将其转化为结构化数据,并整合为正常数据集和缺陷数据集;2)运用 PSO-CNN 模型提取不同数据集中的特征,挖掘不同数据之间的内在联系,从而得到高维度表征的特征集

合;3)将当前中部槽的特征数据输入至预测模型进行计算,得到包装缺陷偏差程度,拟合后输出预测结果。

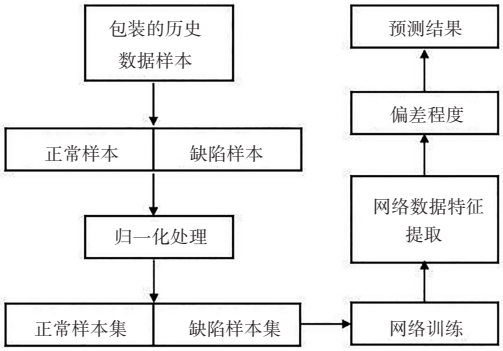


图 3 包装缺陷预测模型框架

Fig. 3 Framework of the prediction model of packaging defects

1.3 BP 神经网络参考算法

反向传播(back propagation, BP)神经网络在包装缺陷领域具有广泛的应用, BP 神经网络与粒子群优化结合形成粒子群反向传播优化(particle swarm optimization-back propagation, PSO-BP)算法。它是一种基于反向传播算法的人工神经网络,适用于处理复杂的非线性关系和模式识别任务。在包装缺陷预测和识别中,BP 神经网络的应用为提高质量控制和生产效率带来了显著的影响。BP 神经网络能够从大量的包装图像数据中自动学习特征,识别出隐藏在数据背后的模式和规律。它可以有效地捕捉不同缺陷类型的特征,并根据这些特征进行准确的分类和预测。这使得在包装印刷生产中,BP 神经网络可以通过反向传播算法不断优化模型的权重和偏置,提高模型的预测性能。通过在训练阶段引入大量真实缺陷样本,网络可以逐步调整自身以准确地识别不同缺陷。这种迭代优化的过程使得模型能够更好地应对新样本和不同类型的缺陷,从而提高预测的准确性。

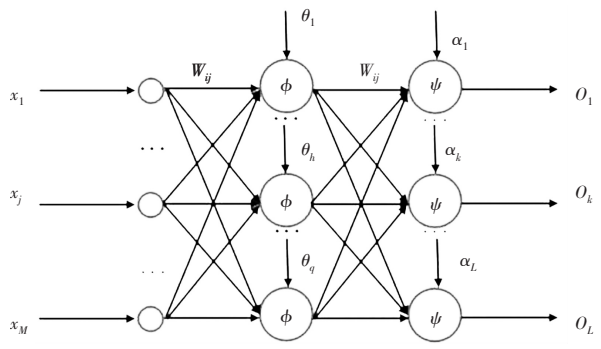


图 4 BP 网络算法程序流程

Fig. 4 Flow chart of the BP network algorithm program

在上图中 x_j 代表着输入的第 j 结点的输入值,w_{ij} 代表着第 i 结点隐藏层至输入层的权值;θ_h 代表隐藏层第 h 个神经元的偏置;$\phi(\cdot)$ 为隐藏层神经元激活函数;$\psi(\cdot)$ 为输出层神经元激活函数;a_k 表示输出层节点的阈值;o 为节点的输出。 BP 神经网络属于反向传播神经网络,是基于多层神经元结构的前馈式人工神经网络[15]。其原理基于梯度下降算法,通过不断调整权重和偏置来实现模型的训练和优化。该网络分为输入层、隐藏层和输出层,每一层由多个神经元组成。信息从输入层通过隐藏层传递到输出层,其中隐藏层通过激活函数处理输入数据,引入非线性关系,增加网络的表达能力。网络的训练目标是使预测输出与实际目标尽可能接近。BP 神经网络的核心在于反向传播算法。通过前向传播,将输入数据从输入层传递至输出层,计算预测值并与实际值比较,得到误差。根据链式法则计算每层的梯度,从而调整权重和偏置。梯度下降算法利用梯度信息来更新权重和偏置,使误差逐步减小。

2 粒子群卷积算法的预测分析

2.1 样本模型处理

基于粒子群卷积算法的包装缺陷预测模型的可比性,我们采用了相同的方法对同一数据集进行预测分析。这一数据集包含了来自某包装印刷设备试验室的包装缺陷数据,总计收集了 100 组样本。为了有效地划分数据,我们按照 7∶2 的比例将数据分为训练集和测试集。训练集被用于模型的训练,而测试集则用于进行包装的预测分析,以验证模型的适配效果和预测的准确性。条件属性包括透光率、反光率、负载、印刷矢量以及印刷行程等信息,而决策属性表示了包装的大小。这些属性信息将被用于构建预测模型,使模型能够基于这些条件属性预测出包装的情况。这一设计旨在以实验数据为基础,运用粒子群卷积算法模型对包装缺陷情况进行预测。通过训练集和测试集的划分,将验证模型在不同条件属性和决策属性下的表现。

2.2 预测模型性能评估

在对样本数据进行训练和测试时,可以利用多个评价指标来评估不同模型的预测性能和泛化能力,其中包括均方差(mean squared error, MSE)、平均绝对误差(mean absolute error,MAE)以及决定系数(coefficient of determination, R^2)等。MSE 和 MAE 是常用的评价指标,它们的计算结果越小,代表模型的性能越好。MSE 度量了预测值与实际值之间的差距的平方的平均值,而 MAE 则衡量预测值与实际值之间的绝对差的平均值。通过对这些指标进行分析,我们可以判断不同模型在预测中的准确度和误差水平。R^2 是衡量模型对总方差中可以解释部分的比例。R^2 的范围在[0, 1]之间,计算结果越接近 1,则表示模型的性能越好。

根据表 2 的数据显示,PSO-CNN 模型在 MSE、MAE、R^2 等评价指标上表现出色。与其他模型如 CNN 等相比,PSO-CNN 模型相较于其他类的模型在泛化效能上表现出了较为卓越的效果,同时其所对应的综合性能较为突出,而其耗时效能相对较长。更重要的是,该模型满足了工业场景下包装缺陷预测的实际应用要求。综合来看,PSO-CNN 模型在预测性能和泛化能力方面表现出色。

表 1　包装缺陷决策统计

Tab. 1　Packaging defect decision statistics

序号	透光率/%	反光率/%	负载/N	印刷矢量	印刷行程/mm	决策系数
1	68	31	264	654	1 100	0. 002 54
2	75	41	281	652	2 012	0. 003 22
3	71	35	291	545	1 570	0. 005 41
⋮	⋮	⋮	⋮	⋮	⋮	⋮
99	69	36	286	588	2 551	0. 003 45
100	75	37	288	591	1 201	0. 006 25

表 2　包装缺陷决策统计

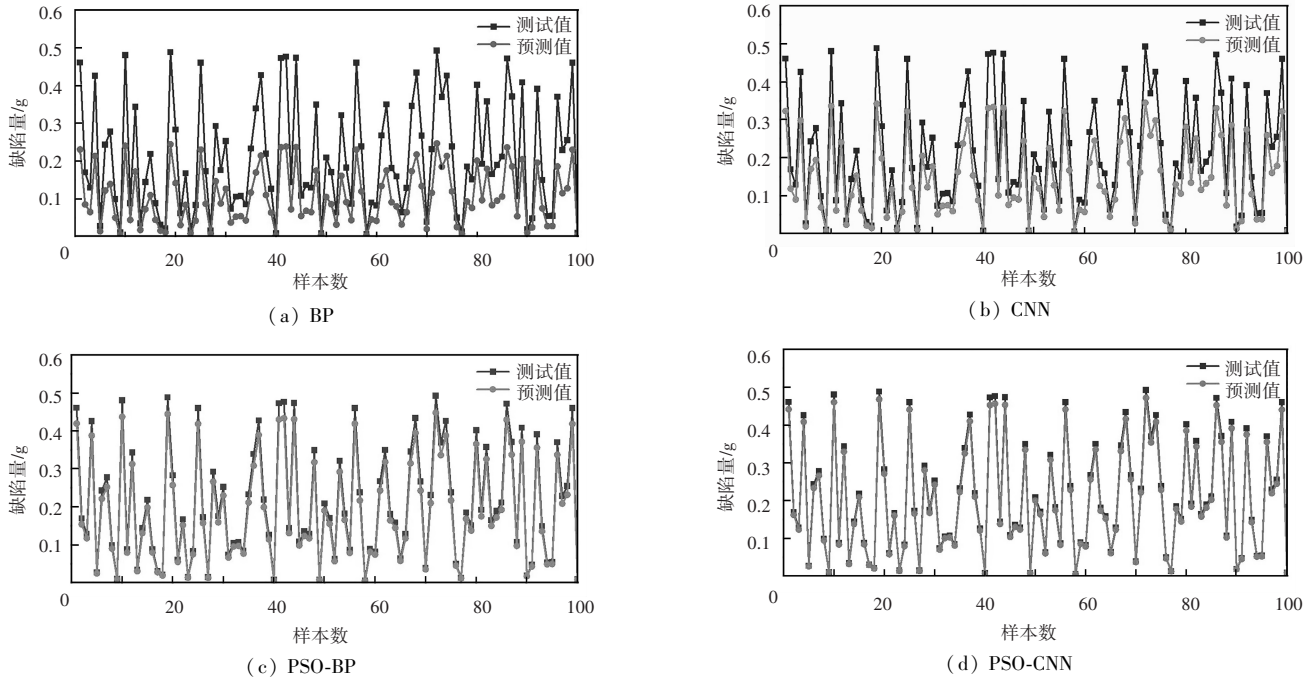
Tab. 2　Packaging defect decision statistics

预测模型	MSE	MAE	R^2	运行耗时/s
CNN	0. 285	0. 296	0. 564	12. 1
BP	0. 255	0. 224	0. 485	15. 4
PSO-BP	0. 301	0. 305	0. 641	16. 8
PSO-CNN	0. 384	0. 517	0. 884	18. 2

3　预测结果对比分析

在完成各类算法测评的基础上,进一步将其包装缺陷检测的工程问题代入相应的粒子群卷积算法模型,经计算分析对相关结果进行预测,所获得的结果同实际测量的结果相对比,得到如图 5 所示统计结果,其数据详细描述了各预测模型的输出值与实验数据之间的对比情况。这一对比分析的目的在于评价预测模型的合理性和可行性。通过预测值与实际值比较可以初步对其适配性加以评价,并在其结果上进行包装缺陷损伤归一化结果处理。

根据图 5 所示的结果,可以较为清晰地说明通过 PSO-CNN 模型可以较为准确地将包装缺陷的预测阈值加以统计,进而较为全面地将相关生产中的缺陷进行精准甄别,达到了其算法分析的预期目标。参考图 5 选取样本总数量为 100 个的某菊花纹案包装作为原始图样进行特征提取,具体的提取方法为选择没有瑕疵的某菊花纹案为参考原图,而后利用算法对不同包装缺陷进行对照分析,随后在 CNN,PSO-BP 以及 PSO-CNN 算法的框架下,对不同类型的包装缺陷预测,并在明确该包装的缺陷特征被很准确地标定的基础上,辨识其包装缺陷预测的准确性,选取上述 3 种方法的某菊花纹案包装缺陷预测结果如图 6 所示。



(a) BP　(b) CNN

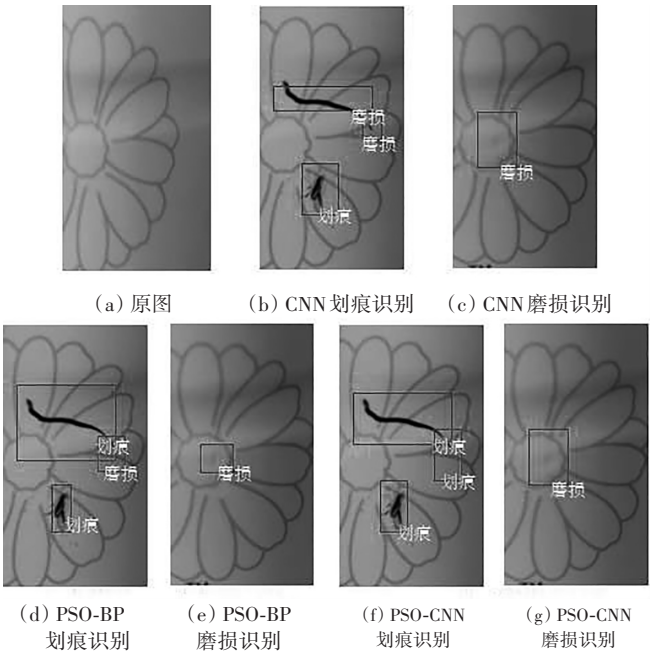
(c) PSO-BP　(d) PSO-CNN

图 5　两类模型实验值与计算对比

Fig. 5　Contrthe experimental values and calculations of two types of models

通过图 6 可知,在 100 组样本个数中采取 CNN,PSO-BP 以及 PSO-CNN 3 种算法对某菊花纹案进行特征分析,可知这 3 类算法基本可以较为准确地识别出缺陷位置,尤其基粒子群卷积网络中的粒子位置属性,可以及时地对其相关实验数据的变化规律进行统计归纳,而该类趋势在较大程度上符合实际的预测精度和可行性要求,但是在缺陷

的特征预测上,PSO-CNN明显高于PSO-BP,而PSO-BP高于CNN,PSO-BP和CNN算法在对复杂的包装缺陷上存在预测失误的现象,这也显示出PSO方法所表示的高贴合度和精准性也为更进一步的工程检验奠定良好的基础,在后续的研究中表现出较高的实用价值。



(a) 原图 (b) CNN划痕识别 (c) CNN磨损识别

(d) PSO-BP 划痕识别 (e) PSO-BP 磨损识别 (f) PSO-CNN 划痕识别 (g) PSO-CNN 磨损识别

图6 某菊花纹案包装缺陷的3种算法预测结果

Fig. 6 Prediction results of three algorithms for packaging defects of chrysanthemum pattern

4 结论

基于PSO-CNN算法可以有效地对相关包装缺陷进行统筹分析,相较于其他算法,该类方法相较于传统方法的包装缺陷有较高准确性和预测效率。将粒子群优化与卷积神经网络相结合的PSO-CNN算法可以有效增强其算法的聚类属性,基于该算法也为后续生产过程中对包装缺陷预测的实际需求验证奠定良好的基础。

参考文献

[1]王蓓. 一种多特征融合的目标跟踪算法[J]. 西安工业大学学报, 2025, 45(6): 948-957.

[2]孙聪妮, 郭艳. 基于计算机CNN技术的智能化纸病分类与辨识研究[J]. 造纸科学与技术, 2025, 44(5): 90-93.

[3]Tang B, Chen L, Sun W, et al. Review of surface defect detection of steel products based on machine vision[J]. IET Image Process, 2022, 17(6): 303-322.

[4]Rane N L. YOLO and faster R-CNN object detection for smart Industry 4.0 and Industry 5.0: applications, challenges, and opportunities[J]. SSRN Electronic Journal, 2023, 23(12): 39-52.

[5]Zhao Y, Wang H, Xie X, et al. An enhanced YOLOv5-based algorithm for metal surface defect detection[J]. Applied Sciences, 2023, 13(20): 11473.

[6]Branikas E, Murray P, West G M. A novel data augmentation method for improved visual crack detection using generative adversarial networks[J]. IEEE Access, 2023, 11(2): 22051-22069.

[7]Tang H, Liang S, Yao D, et al. Improved STMask R-CNN-based defect detection model for automatic visual inspection of an optics lens[J]. Applied optics, 2023, 62(33): 8869-8881.

[8]Dlamini S, Kuo C F J, Chao S M. Developing a surface mount technology defect detection system for mounted devices on printed circuit boards using a MobileNetV2 with Feature Pyramid Network[J]. Eng Appl Artif Intell, 2023, 121(2): 105875.

[9]顾文君, 谭永涛, 李强, 等. 基于深度学习的纸病检测系统设计与研究[J]. 中国造纸, 2024, 43(8): 154-159.

[10]陈钰枚, 李兆飞, 侯劲, 等. 改进YOLOv7的纸张表面缺陷检测研究[J]. 中国造纸, 2023, 42(11): 160-168.

[11]同剑飞. 基于图像分析技术的纸病识别策略[J]. 造纸科学与技术, 2023, 42(4): 42-45.

[12]汤伟, 张龙, 王锦韫, 等. 基于快速傅里叶变换和改进分水岭算法的纸病实时检测复合算法[J]. 中国造纸, 2023, 42(7): 153-160.

[13]Yu C, Gao C, Wang J, et al. Bisenet v2: bilateral network with guided aggregation for real-time semantic segmentation[J]. International Journal of Computer Vision, 2021, 129(11): 3051-3068.

[14]Rhim S. Real-time in-situ thermal monitoring system and defect detection using deep learning applied to additive manufacturing[J]. Materials Research Proceedings, 2024, 261(3): 43-56.

[15]Pham D L, CHANG T W. A YOLO-based real-time packaging defect detection system[J]. Procedia Computer Science, 2023, 217(4): 886-894.

[16]Ancha V K, Sibai F N, Gonuguntla A V, et al. Utilizing YOLO models for real-world scenarios: assessing novel mixed defect detection dataset in PCBs[J]. IEEE Access, 2024, 12(3): 100983-110990.

[17]巩雪, 孙雪刚, 褚洋洋, 等. 基于改进Faster R-CNN的零食包装盒表面缺陷检测[J]. 包装工程, 2024, 45(23): 232-240.

[18]胡丹, 黄辉. 基于图像区域和骨架特征的条形码印刷缺陷检测算法[J]. 工业控制计算机, 2024, 37(1): 126-131.

[19]马志程, 李丹, 张宝龙. 基于改进Mask R-CNN的光学元件划痕缺陷检测研究[J]. 电子测量与仪器学报, 2023, 37(4): 231-249.

[20]Zhao L, Zhi L, Zhao C, et al. Fire-YOLO: a small target object detection method for fire inspection[J]. Sustainability, 2022, 14(9): 4930.

[21]Zafar A, Aamir M, Nawi N M, et al. A comparison of pooling methods for convolutional neural networks[J]. Applied Sciences, 2022, 12(17): 8643.

[22]袁金丽, 李博华, 陈沐萱, et al. MFMANet:一种融合多尺度特征的多重注意力医学图像分割网络[J]. 中国医学物理学杂志, 2025, 42(2): 190-198.

[23]Ancha V K, Sibai F N, Gonuguntla V, et al. Utilizing YOLO models for real-world scenarios: assessing novel mixed defect detection dataset in PCBs[J]. IEEE Access, 2024, 12(3): 100983-110990.

[24]Darshangowdak R, Deekshitht H, Gowda D V, et al. Using deep learning for PCB fault detection[J]. International Journal of Advanced Research in Science, Communication and Technology, 2024, 17(3): 65-76.

[25]张枫毅, 王莉华, 叶文静. 基于多层级LSTM的铝板缺陷检测[J]. 力学学报, 2023, 55(11): 2566-2576.

[26]吕宜光, 郝明, 孙凯明, 等. 机器视觉技术在薄膜胶缺陷检测中的应用[J]. 自动化技术与应用, 2025, 44(5):131-134.

[27]黄臻臻, 赵雨茜, 石建全, 等. 基于改进YOLOv5的光伏硅片缺陷检测[J]. 自动化技术与应用, 2025, 44(6):144-148.