

基于触压反力与深度学习的盐渍海参熟度识别

侯宇佩¹, 张旭^{1*}, 崔佳鹏¹, 隋倩倩¹, 王显强², 孙纬宸²

¹大连工业大学机械工程与自动化学院, 辽宁 大连

²好为尔机械(山东)有限公司, 山东 济南

收稿日期: 2026年3月21日; 录用日期: 2026年4月16日; 发布日期: 2026年4月28日

摘要

针对盐渍海参煮制过程中熟化程度人工触压检测主观性强、效率低、难以量化的问题, 本研究旨在构建基于触压力学特征与深度学习的海参熟度精准识别方法。以大连仿刺参盐渍原料为研究对象, 依据感官评定将其分为对照组(未煮制)、三成熟、五成熟、七成熟、全熟及过熟6个熟度等级, 通过质构仪模拟人工触压开展整参压缩试验, 提取21个位移点对应的触压力-位移时序特征数据; 选取KNN、随机森林、SVM三种传统机器学习模型与1DCNN深度学习模型进行对比, 引入果蝇优化算法对1DCNN模型超参数进行智能寻优, 提升模型熟度识别性能。结果表明, 1DCNN深度学习模型适配触压力-位移时序特征提取需求, 基础模型整体识别准确率达95.83%, 其中对照组、三成熟、七成熟样本识别准确率为100%; 经果蝇优化算法优化后, 模型训练初始准确率从20%提升至80%, 最终整体识别准确率提升至98.75%, 较优化前提升2.92%, 损失值从0.22降至0.10; 优化后对照组、三成熟、五成熟、七成熟样本识别准确率均达100%, 过熟样本识别准确率从85%提升至97.5%, 有效解决了相邻熟度误判问题。本研究证实基于触压力-位移时序特征与果蝇优化1DCNN模型的识别方法, 可实现盐渍海参6个熟度等级的精准、高效识别, 为开发海参加工熟度快速、客观、无损的自动化检测技术提供了理论依据与数据支撑。

关键词

盐渍海参, 熟度识别, 1DCNN, 深度学习, 果蝇优化算法

Cooking Degree Recognition of Salted Sea Cucumber Based on Contact Pressure Reaction and Deep Learning

Yupei Hou¹, Xu Zhang^{1*}, Jiapeng Cui¹, Qianqian Sui¹, Xianqiang Wang², Weichen Sun²

¹College of Mechanical Engineering and Automation, Dalian Polytechnic University, Dalian Liaoning

²Hiwell Machinery (Shandong) Co., Ltd., Jinan Shandong

Received: March 21, 2026; accepted: April 16, 2026; published: April 28, 2026

*通讯作者。

文章引用: 侯宇佩, 张旭, 崔佳鹏, 隋倩倩, 王显强, 孙纬宸. 基于触压反力与深度学习的海参熟度识别[J]. 软件工程与应用, 2026, 15(2): 285-295. DOI: 10.12677/sea.2026.152027

Abstract

Aiming at the problems of strong subjectivity, low efficiency and difficulty in quantifying the cooking degree of salted sea cucumber during cooking, this study aims to build a precise identification method of sea cucumber cooking degree based on the characteristics of touch mechanics and deep learning. Taking the salted raw material of *Apostichopus japonicus* in Dalian as the research object, according to the sensory evaluation, it was divided into six cooking degree levels: control group (uncooked), three cooking degree, five cooking degree, seven cooking degree, full cooking degree and over cooking degree. The integrated parameter compression test was carried out by using texture analyzer to simulate the artificial contact pressure, and the characteristic data of contact pressure displacement time series corresponding to 21 displacement points were extracted; Three traditional machine learning models, namely KNN, random forest and SVM, are selected to compare with 1DCNN deep learning model. The fruit fly optimization algorithm is introduced to intelligently optimize the 1DCNN model's super parameters to improve the model's cooking degree recognition performance. The results show that the 1DCNN deep learning model adapts to the needs of feature extraction of contact pressure displacement time series. The overall recognition accuracy of the basic model is 95.83%, and the recognition accuracy of the control group, three mature and seven mature samples is 100%; After optimization by Drosophila optimization algorithm, the initial accuracy of model training increased from 20% to 80%, and the final overall recognition accuracy increased to 98.75%, increased by 2.92% compared with that before optimization, and the loss value decreased from 0.22 to 0.10; After optimization, the recognition accuracy of the control group, three mature samples, five mature samples and seven mature samples reached 100%, and the recognition accuracy of over mature samples increased from 85% to 97.5%, which effectively solved the problem of misjudgment of adjacent cooking degree. This study confirmed that the identification method based on contact pressure displacement time series characteristics and Drosophila optimized 1DCNN model can realize the accurate and efficient identification of six cooking degree grades of salted sea cucumber, which provides a theoretical basis and data support for the development of rapid, objective and Nondestructive Automatic Detection Technology of sea cucumber processing cooking degree.

Keywords

Salted Sea Cucumber, Cooking Degree Recognition, 1DCNN, Deep Learning, Fruit Fly Optimization Algorithm

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

海参蛋白质含量高, 维生素和微量成分含量丰富, 是优良的保健食材[1]。我国作为全球唯一的海参养殖与加工大国, 随着市场需求扩大及消费者对品质要求的提升, 实现海参加工的标准化、规模化成为行业发展的必然趋势[2]。盐渍海参在加工过程中需经煮制、泡发、调味或干燥等工序, 由于蛋白质、水分以及组织结构上存在个体差异[3], 即使在同一煮制工艺和时间下, 海参的熟化品质仍表现为较大分散性。煮制不足会导致海参体壁胶原蛋白变性不充分, 质地紧实、韧性过强, 不仅延长后续泡发时间, 还易造成泡发不均、口感偏硬[4]; 而过度熟化则会引起胶原结构断裂水解, 导致体壁松散、弹性丧失、营养成分流失, 严重降低产品附加值[5]。目前, 生产中常采用人工触压法判别熟度: 即将海参捞出后凭经

验按压,挑出已熟化的个体,余者继续煮制。该方法是影响海参产品口感与品质的核心工艺质量控制环节,但存在依赖主观经验、劳动强度大、效率低下、易出现感官疲劳等问题,难以满足规模化加工中对稳定性和一致性的要求。因此,实现海参煮制熟度的快速、客观、量化检测,已成为行业亟待解决的技术需求。

随着人工智能技术的快速发展,深度学习与机器学习已成为食品熟度无损分级的核心技术手段,有效解决了传统人工分级耗时费力、主观性强、易造成破坏性检测等问题,为食品采后加工、存储运输及品质管控提供了精准高效的技术支撑[6]。吴智丽等人[7]提出深度学习可通过模拟人类视觉识别过程,借助色度、形状、纹理、尺寸等多维度特征分析实现果蔬成熟度精准识别,同时提及当前该领域面临数据收集难度大、模型训练复杂、实时检测性能待提升等共性挑战,为后续熟度分级技术优化指明了方向。在国外研究中,SK Behera 等人[8]针对木瓜果实成熟度分级需求,提出基于机器学习 LBP/HOG/GLCM 特征+KNN/SVM/朴素贝叶斯分类器与迁移学习 ResNet 系列、VGG 系列等预训练模型的两种分级方法,其中 HOG 特征结合加权 KNN 模型及 VGG19 迁移学习模型均实现 100% 的分类准确率,较现有方法提升 6 个百分点;S Marimuthu 等人[9]从 CIELab 色彩空间提取香蕉的峰值色相、归一化棕色面积特征,通过分类回归树算法构建模糊系统并结合粒子群优化技术优化模型参数,在 MUSA 数据库上实现 93.11% 的成熟度分类准确率,性能优于主流算法;Atif Mahmood 等人[10]基于迁移学习改进 AlexNet 和 VGG16 模型,对枣果实图像进行数据增强后开展训练,VGG16 模型在扩充后的 4398 张数据集上分类准确率达 99.17%,为果实自动化采收分选系统开发提供了技术参考;N. Saranya 等人[11]针对香蕉 4 个成熟阶段视觉特征差异小的难题,构建自定义 CNN 模型并结合数据增强技术,模型整体验证准确率达 96.14%,为多等级成熟度识别提供了新的模型选择。以上的研究为依靠深度学习模型对盐渍海参熟度的快速预测提供了切实可行的思路和技术路径。

为此,本研究以大连仿刺参盐渍原料为对象,通过行业标准感官评定划分多梯度熟度等级,开展整参触压试验采集力-位移时序特征数据;对比传统机器学习与 1DCNN 深度学习模型的熟度识别性能,引入果蝇优化算法对 1DCNN 模型超参数进行智能寻优,提升模型对熟度特征的挖掘与识别精度;旨在构建高效、精准的熟度智能识别方法,为开发海参熟度无损、快速的自动化检测技术提供理论依据与技术支撑。

2. 材料与方法

2.1. 材料与试剂

大连仿刺参(*Apostichopus japonicus*)盐渍原料选自辽宁省大连市海参加工企业。试验样品在企业生产现场同一批次盐渍海参原料煮制过程中随机选取,共选取 120 只体壁完整无破损的个体作为实验样本,经统计海参单体重约 12 ± 1.2 g、体长 55 ± 5.3 mm、高 16 ± 1.5 mm、宽 20 ± 2.1 mm。

2.2. 仪器与设备

质构仪 TMS-PRO 型,(配有触压探头, $R = 5$ mm 球形,直径 5 mm,美国 FTC 公司);游标卡尺(量程 0~150 mm,精度 0.02 mm,三丰精密仪器有限公司);厨房秤 i2000 (精度 0.1 g,永康市皓然衡器有限公司);多功能搅拌蒸煮锅(诸城市中润有限公司);温度计(量程 0°C ~ 100°C ,郑州云湛科技有限公司);滤纸,直径 12.5 cm;机械停钟(精度 0.2 s,上海天大科教器材有限公司)。

2.3. 实验样本制备

生产企业某批次盐渍海参原料煮制的一般生产流程为:批次海参原料在 85°C 恒温条件下进行煮制,

煮制过程中间隔一定时段将所有海参物料捞出, 经过冷水过冷或冲洗处理, 使其温度降至 $40^{\circ}\text{C}\sim 50^{\circ}\text{C}$, 由有经验的技术人员对物料逐个触压来判断海参的熟度(如图 1), 将已熟化的海参个体挑出, 剩余的海参物料再次进行恒温煮制, 并重复上述工艺, 直至所有海参原料完成熟化。

为了研究熟化过程海参力学特性的变化规律, 本研究将海参的熟度定义为: 三分熟、五分熟、七分熟、全熟、过熟等 5 个等级, 以未经煮制的海参作为对照组, 熟度的感官评定标准如表 1 所示。试验样本选取的过程如下: 在某批次原料煮制之前, 选取 20 只样本作为对照组; 设置煮制全程时间为 150 min, 煮制过程每间隔 10 min 随机捞出 40 只, 将所有抽取的海参样本混合, 通过感官评定, 选取 5 个熟化程度等级的海参样本各 20 只; 所选海参立即投入冰水浴($0^{\circ}\text{C}\sim 4^{\circ}\text{C}$)快速冷却 10 min, 用滤纸吸干表面水分。



Figure 1. Manual touch pressure detection of cooking degree of sea cucumber
图 1. 海参熟度的人工触压检测

Table 1. Sensory evaluation standard for texture properties

表 1. 质构特性感官评价标准

熟度	感官评定
对照组	体壁触感坚硬致密, 触压时整体软硬度基本一致、弹性强且瞬时回弹
三成熟	体壁触感较坚硬, 触压时外部稍软、内部较硬、弹性较强且回弹较快
五成熟	体壁触感偏软, 触压时内外质地明显不均、有较大硬芯、弹性一般且回弹较快
七成熟	体壁触感较软, 触压时内外质地较不均、有较小硬芯、弹性偏弱且回弹偏慢
全熟	体壁触感软嫩, 触压时内外质地均匀、无硬芯、弹性弱仅回弹较慢
过熟	体壁触感绵软, 触压时内外质地均匀、无硬芯、弹性微弱且回弹慢

2.4. 数据采集

为模拟人工触压判别海参熟度的实际过程并获取海参整体压缩的力学响应特征, 采用质构仪球形探头对海参样本进行压缩试验(图 2)。试验对象包括对照组及三成熟、五成熟、七成熟、全熟、过熟共 6 组不同熟度海参。将探头以 10 mm/min 的恒定速度垂直下压至海参背部中间无刺区域, 初始触发力设为 0.05 N , 最大压缩位移设定为 5 mm , 每个样品重复 10 次, 记录并导出压缩力-位移曲线。该曲线反映了不同熟度海参在模拟触压条件下的整体力学行为, 为后续机器学习和深度学习模型对海参熟度的预测提供数据基础。




Figure 2. Compression test on the whole sea cucumber
图 2. 海参整体压缩试验

3. 模型选择与构建

3.1. 模型选择

本研究聚焦海参熟度六分类任务，核心数据为质构仪采集的 1 维力 - 位移时序数据(21 个力值特征点)，需适配时序特征提取与小样本场景需求。结合任务特性与模型适配性，最终选取随机森林、KNN (K 近邻)、SVM (支持向量机)三种传统机器学习模型与 1DCNN (一维卷积神经网络)深度学习模型开展对比实验，各模型选型逻辑如下：

随机森林模型：基于集成学习思想构建多决策树并行训练，兼具优秀的特征筛选与抗过拟合能力，能自主挖掘力 - 位移特征与海参熟度的关联权重，无需复杂数据预处理，适配小样本时序数据的分类任务，可有效规避单一决策树泛化能力不足的问题。

KNN 模型：以距离度量为核心进行类别判定，原理直观易懂、训练成本低，对时序特征的原始分布保留度高，能精准捕捉力 - 位移数据间的相似性差异，可作为基础基准模型，验证力值原始特征空间下的熟度判别可行性。

SVM 模型：依托核函数实现低维到高维空间的非线性映射，可有效解决力 - 位移特征与海参熟度间的非线性关联建模难题，在小样本数据集上分类精度稳定，泛化能力突出，能针对性挖掘特征隐含的分类边界信息。

1DCNN 模型：通过 1 维卷积核直接提取力值数据的局部时序特征(如力值增长斜率、关键节点力值变化)，运算量适中且特征提取针对性强，契合海参熟度与力值局部变化的关联规律，同时适配时序数据的序列特性，相较传统模型更易挖掘深层特征关联。

四种模型覆盖了集成学习、距离度量、核映射、深度学习等不同建模维度，兼顾了特征挖掘的全面性与模型类型的差异性，既能全面验证不同算法在海参熟度识别中的适用性，也能通过对比筛选出最优适配模型。

3.2. 核心模型结构设计

1DCNN 模型的网络结构如图 3 所示。该图呈现了 1DCNN 模型的基础架构逻辑，本研究中采用的 1DCNN 模型以局部时序特征提取为核心，由输入层、深度卷积特征提取模块、全局池化层及全连接分类层构成。模型输入层接收维度为(21, 1)的 3D 标准化时序数据，对应 21 个位移点的力值特征；深度卷积

特征提取模块包含 3 组卷积块，每组由 2 层 1D 卷积(首组卷积核大小 5、后两组卷积核大小 3，padding 均设为“same”)、BatchNormalization 层组成，滤波器数量依次为 64、128、256，前两组卷积块后衔接 2×2 最大池化层与 Dropout 层(率 0.32)，第三组后设 Dropout 层(率 0.38)，并搭配 12 正则化($2e-4$)约束参数，高效捕捉多尺度局部时序特征的同时抑制过拟合；经 GlobalAveragePooling1D 层压缩时序维度后，全连接分类层设 4 层全连接层，神经元数量依次为 128、64、32，均采用 ReLU 激活函数，前三层后搭配 BatchNormalization 层与 Dropout 层(率依次为 0.28、0.22)；输出层设 6 个神经元，采用 Softmax 激活函数，输出对照组、三成熟、五成熟、七成熟、全熟、过熟 6 类熟度的概率分布，完成分类预测。




Figure 3. Network structure diagram of 1DCNN model

图 3. 1DCNN 模型的网络结构图

3.3. 模型优化

1DCNN 模型的训练效果与超参数配置直接相关，为实现 1DCNN 模型超参数的智能精准优化，本研究引入果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)，该算法基于果蝇群体觅食行为的仿生优化策略，通过模拟果蝇利用嗅觉与视觉协同搜索食物的自然机制，在超参数空间中高效寻找全局最优解，其核心优势在于原理简洁、收敛速度快且全局寻优能力突出，适配小样本与混合数据集下的模型超参数优化需求。

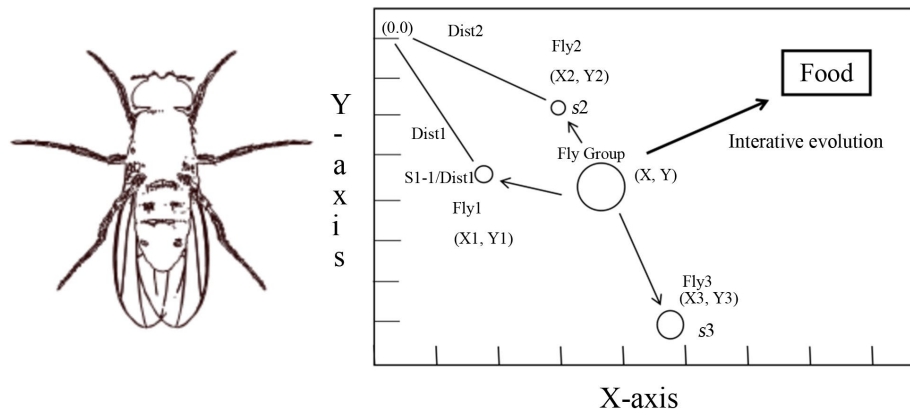


Figure 4. Core logic diagram of fruit fly optimization algorithm

图 4. 果蝇优化算法核心逻辑图

果蝇作为嗅觉灵敏度极高的昆虫，在觅食过程中可通过感知食物散发的气味浓度判断食物方位，气味浓度越高表明与食物距离越近；当果蝇靠近食物区域后，会进一步通过视觉精准定位食物位置并向最优区域聚集。FOA 算法将这一自然行为抽象为数学模型每只果蝇代表一个潜在的超参数组合，食物位置

对应超参数全局最优解，气味浓度对应超参数组合的适应度值，通过果蝇群体的迭代搜索实现超参数寻优。其核心逻辑如图 4 所示。

结合 1DCNN 模型超参数优化需求，FOA 算法的数学描述与执行步骤如下：

初始化果蝇种群规模为 N ，在各超参数取值范围内随机生成 N 个果蝇个体的初始位置，即 N 组潜在超参数组合，数学表达式如下：

$$\begin{cases} lr_i \sim U(lr_{\min}, lr_{\max}) \\ l2_reg_i \sim U(l2_{\min}, l2_{\max}) \\ dropout_rate_i \sim U(drop_{\min}, drop_{\max}) \end{cases} \quad (i = 1, 2, \dots, N) \quad (1)$$

式中 lr 为学习率、 $l2$ 为正则化系数、 $dropout_rate$ 为 Dropout 率。

对于每个果蝇个体对应的超参数组合 $(lr_i, l2_reg_i, dropout_rate_i)$ ，将其输入 1DCNN 模型进行训练，以模型验证集最高准确率作为该个体的适应度值 $fitness_i$ ，即“气味浓度”。适应度值越高，表明该超参数组合对 1DCNN 模型的适配性越好，数学定义如下：

$$fitness_i = \max(Accuracy_{\text{val}}(lr_i, l2_reg_i, dropout_rate_i)) \quad (2)$$

其中， $Accuracy_{\text{val}}$ 表示 1DCNN 模型在验证集上的分类准确率，通过训练过程中监控验证损失与准确率变化获取。

遍历所有果蝇个体的适应度值，筛选出当前迭代中的最优适应度值 $fitness_{\text{best}}$ 及其对应的超参数组合 $(lr_{\text{best}}, l2_reg_{\text{best}}, dropout_{\text{best}})$ ，作为当前种群的“最优食物位置”，并记录该位置信息：

$$\begin{cases} fitness_{\text{best}} = \max(fitness_1, fitness_2, \dots, fitness_N) \\ (lr_{\text{best}}, l2_reg_{\text{best}}, dropout_{\text{best}}) = \arg \max(fitness_i) \end{cases} \quad (3)$$

为实现全局寻优，引导所有果蝇个体向当前最优位置附近移动，同时通过随机扰动避免陷入局部最优。基于高斯扰动策略更新每只果蝇的位置，确保更新后的超参数仍处于合理取值范围，更新公式如下：

$$\begin{cases} lr_i^{t+1} = \text{clip}(lr_i^t + N(0, \sigma_1), lr_{\min}, lr_{\max}) \\ l2_reg_i^{t+1} = \text{clip}(l2_reg_i^t + N(0, \sigma_2), l2_{\min}, l2_{\max}) \\ dropout_rate_i^{t+1} = \text{clip}(dropout_rate_i^t + N(0, \sigma_3), dropout_{\min}, dropout_{\max}) \end{cases} \quad (4)$$

其中， t 表示当前迭代次数； $N(0, \sigma)$ 表示均值为 0、标准差为 σ 的高斯随机扰动，本研究中 $\sigma_1 = 0.0005$ 、 $\sigma_2 = 1e-6$ 、 $\sigma_3 = 0.02$ ，通过调节扰动强度平衡寻优精度与收敛速度； $\text{clip}(x, a, b)$ 为区间截断函数，确保超参数更新后不超出预设合理范围。

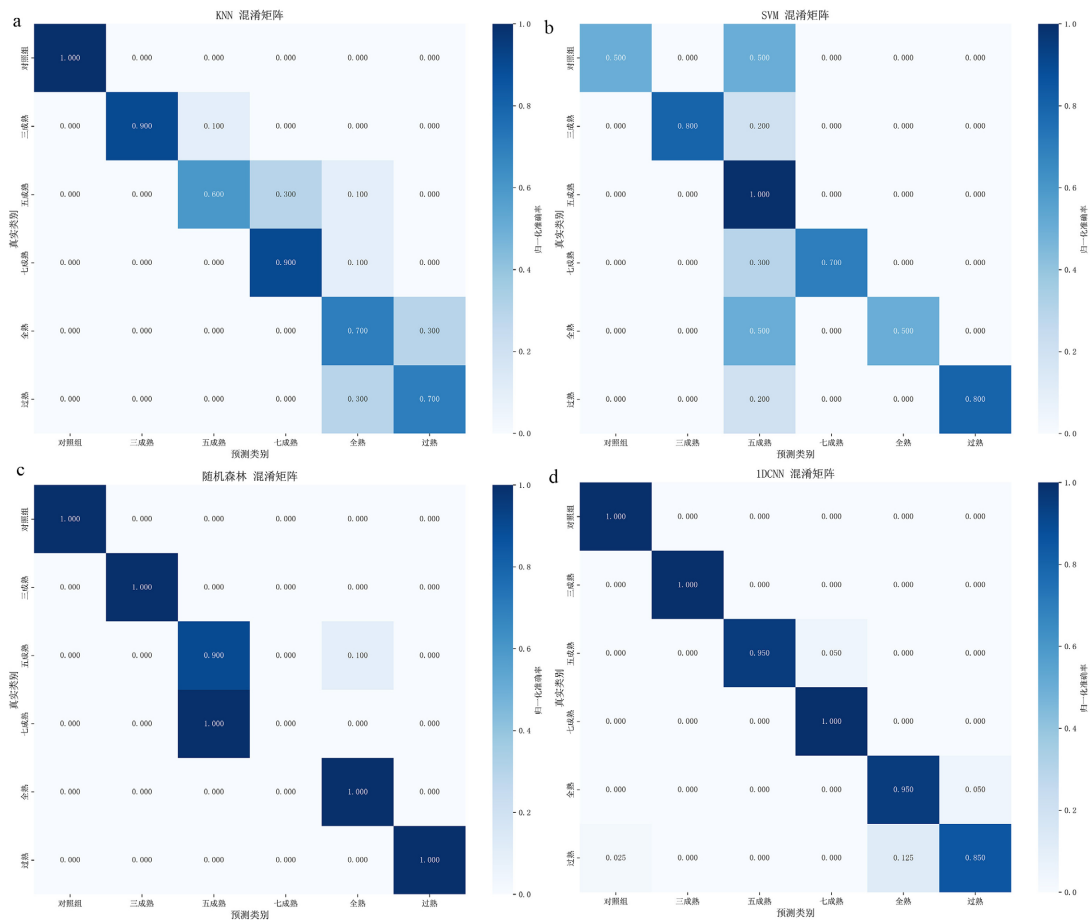
重复步骤直至达到预设最大迭代次数 t (本研究设为 15 次) 或适应度值连续 5 轮无明显提升 (提升幅度 ≤ 0.001)，此时记录的全局最优超参数组合即为 1DCNN 模型的最终优化参数。

3.4. 模型训练与评估

实验基于 TensorFlow 平台搭建模型，硬件配置为 13th Gen Intel (R) Core (TM) i9-13980HX CPU、64.0 GB RAM、8 GB 显存 GPU。训练集与验证集比例为 8:2。模型训练参数设置：批次大小 10，最大训练轮次 200，引入早停机制 (耐心值 50)，避免过拟合；损失函数为 Categorical Crossentropy，以准确率为核心评估指标。通过混淆矩阵分析模型对各熟度等级的识别效果，对比优化前后模型的训练准确率、损失值及测试集识别精度。

4. 结果与分析

4.1. 不同模型训练结果



注: (a) KNN 混淆矩阵, (b) SVM 混淆矩阵, (c) 随机森林混淆矩阵, (d) 1DCNN 混淆矩阵。

Figure 5. Confusion matrix of each model training

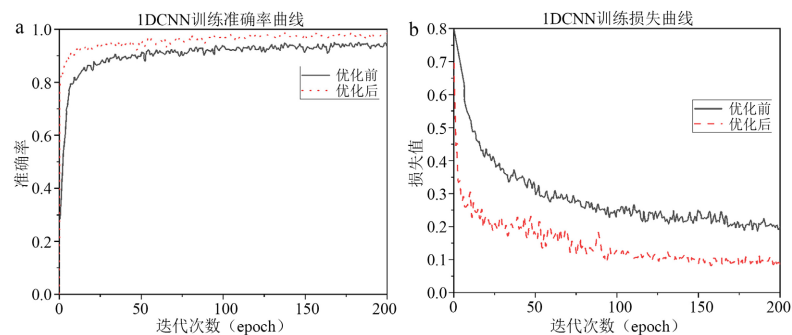
图 5. 各模型训练的混淆矩阵

基于 TensorFlow [12] 平台, 本研究在不同熟度海参质构仪触压力 - 位移曲线的自建数据集基础上, 本研究将样本按 8:2 比例划分为训练集与测试集, 完成了 KNN、SVM、随机森林、1DCNN 四种模型的训练与测试, 各模型的训练混淆矩阵如图 5 所示, 由图 5 可知, KNN 模型测试中对照组的预测准确率达 100%, 三成熟样本有 90% 被正确预测、10% 误判为五成熟, 五成熟样本有 60% 被正确预测、30% 误判为七成熟、10% 误判为全熟, 七成熟样本有 90% 被正确预测、10% 误判为全熟, 全熟样本有 70% 被正确预测、30% 误判为过熟, 过熟样本有 70% 被正确预测、30% 误判为全熟; SVM 模型测试中五成熟类别的预测准确率达 100%, 对照组样本有 50% 被正确预测、50% 误判为五成熟, 三成熟样本有 80% 被正确预测、20% 误判为五成熟, 七成熟样本有 70% 被正确预测、30% 误判为五成熟, 全熟样本有 50% 被正确预测、50% 误判为五成熟, 过熟样本有 80% 被正确预测、20% 误判为五成熟; 随机森林模型测试中对照组、三成熟、全熟、过熟类别的预测准确率均达 100%, 仅五成熟样本有 90% 被正确预测、10% 误判为全熟, 七成熟全被误判成五成熟; 1DCNN 模型测试中对照组、三成熟、七成熟类别的预测准确率均达 100%, 五成熟样本有 95% 被正确预测、5% 误判为七成熟, 全熟样本有 95% 被正确预测、5% 误判为过熟, 过熟样本有

85%被正确预测、15%误判为全熟。由于全熟、过熟属于熟度过渡阶段，海参触压力特征与相邻熟度存在相近性，故易出现混淆。对比可知，1DCNN 模型对多数熟度类别的区分能力更优，准确率更高。

4.2. 模型优化后的准确率与损失率对比结果

算法优化前与果蝇算法优化后 1DCNN 模型训练的准确率及损失值如图 6 所示。由图可知，在使用优化前的 1DCNN 模型时，训练初始准确率为 20%左右，最终准确率收敛至 95.83%，收敛速度较快，初始损失值为 0.78，最终损失值降低到 0.22 左右。替换成果蝇优化算法后的 1DCNN 模型时，训练初期的准确率与损失值均表现更优，初始准确率为 80%，最终准确率稳定在 98.75%。初始损失值约为 0.55，最终损失值最低降至 0.10 左右。从最终效果来看，果蝇算法优化后的 1DCNN 模型不仅收敛速度更快，且准确率提升了约 3%，损失值下降了 0.12，整体优化效果更显著。



注：(a) 1DCNN 训练准确率曲线，(b) 1DCNN 训练损失曲线。

Figure 6. Comparison of accuracy and loss rate curves of 1DCNN model before and after optimization
图 6. 1DCNN 模型优化前后的准确率与损失率曲线对比

4.3. 模型优化后的训练结果

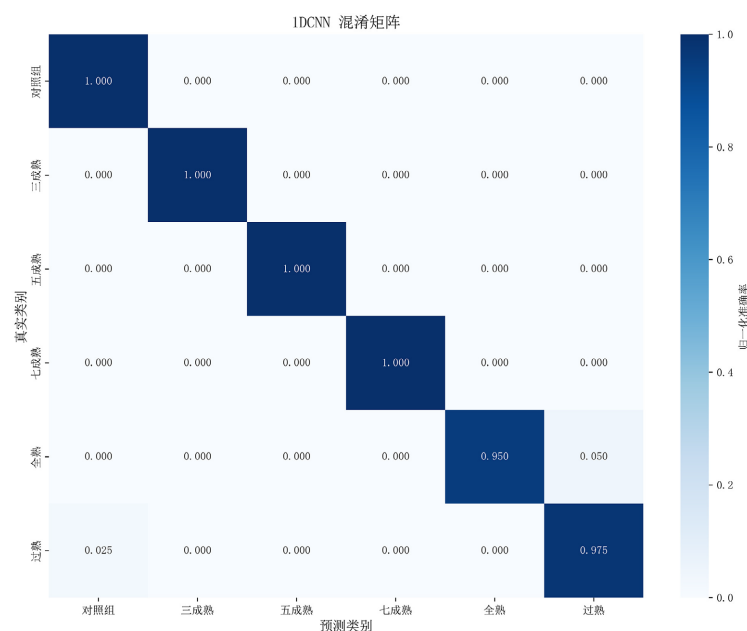


Figure 7. Confusion matrix after 1DCNN model optimization
图 7. 1DCNN 模型优化后的混淆矩阵

果蝇优化算法优化后的 1DCNN 模型的训练结果如图 7 所示, 对照组, 三成熟, 五成熟, 七成熟样本预测准确率均达到 100%, 全熟样本有 95% 被正确预测, 5% 误判为过熟, 过熟样本有 97.5% 被正确预测, 仅 2.5% 误判为对照组。与优化前相比, 五成熟预测准确率提升 5%, 过熟预测准确率提升 12.5%, 全熟预测准确率保持稳定。优化后模型的总体预测准确率为 98.75%, 较优化前提升 2.92%, 有效提升了模型对海参熟度的识别精度, 尤其解决了过熟样本的误判问题, 达到了提高模型测试准确率的目的。

5. 结论

本研究针对海参加工中熟度人工判断主观性强、效率低的问题, 以大连仿刺参盐渍原料为研究对象, 通过整参触压试验获取不同熟度海参的力-位移时序特征数据, 对比传统机器学习与深度学习模型的熟度识别性能, 并引入果蝇优化算法优化核心模型超参数, 系统开展盐渍海参熟度智能识别研究。结果表明, 以 21 个位移点对应的力值特征为输入, KNN、SVM、随机森林三种传统机器学习模型识别效果存在明显短板, 相邻熟度误判率较高, 而 1DCNN 深度学习模型适配力-位移时序特征提取需求, 基础模型对 6 个熟度等级的识别准确率达 95.83%, 其中对照组、三成熟、七成熟样本识别准确率为 100%, 仅全熟、过熟样本存在轻微误判。引入果蝇优化算法对 1DCNN 模型的学习率、正则化系数、Dropout 率进行智能寻优后, 模型训练初始准确率从 20% 提升至 80%, 收敛速度显著加快, 最终识别准确率提升至 98.75%, 较优化前提升 2.92%, 损失值从 0.22 降至 0.10; 优化后模型对五成熟样本识别准确率提升至 100%, 过熟样本识别准确率从 85% 提升至 97.5%, 全熟样本保持 95% 的识别准确率, 有效解决了相邻熟度的误判问题。本研究构建的基于触压力-位移时序特征与果蝇优化 1DCNN 模型的盐渍海参熟度识别方法, 实现了 6 个熟度等级的精准、高效识别, 为海参熟度的快速、客观、量化检测提供了可行的技术方案。

基金项目

山东省科技型中小企业创新能力提升工程项目(2025TSGCCZZB0061)。

参考文献

- [1] Hossain, A., Dave, D. and Shahidi, F. (2022) Antioxidant Potential of Sea Cucumbers and Their Beneficial Effects on Human Health. *Marine Drugs*, **20**, Article 521. <https://doi.org/10.3390/md20080521>
- [2] 胡荣炊, 刘燕飞, 林丹, 等. 福建海参产业发展现状、问题与高质量发展路径研究[J]. 中国水产, 2025(12): 72-75.
- [3] Huang, Y., Xie, Y., Li, Y., Zhao, M., Sun, N., Qi, H., et al. (2023) Quality Assessment of Variable Collagen Tissues of Sea Cucumber (*Stichopus Japonicus*) Body Wall under Different Heat Treatment Durations by Label-Free Proteomics Analysis. *Food Research International*, **165**, Article 112540. <https://doi.org/10.1016/j.foodres.2023.112540>
- [4] 张悦容, 胡玲萍, 刘文, 等. 处理方法对仿刺参体壁蛋白纤维超微结构的影响[J]. 中国食品学报, 2015, 15(5): 219-224.
- [5] Xiong, X., Zhang, C., Li, H., Qi, H., Xu, Z., Jiang, Y., et al. (2025) Dual Role of Calcium in Regulating Collagen Integrity and Proteolytic Response during Sea Cucumber *Apostichopus japonicus* Tenderization. *Food Research International*, **221**, Article 117389. <https://doi.org/10.1016/j.foodres.2025.117389>
- [6] 姚仁朋, 孙玉敬, 赵圆, 等. 机器学习在食品工业中的应用[J]. 中国食品学报, 2024, 24(1): 349-363.
- [7] 吴智丽, 杜志龙, 何亚凯, 等. 深度学习在果蔬品质检测中的应用综述[J]. 农业工程, 2025, 15(1): 120-128.
- [8] Behera, S.K., Rath, A.K. and Sethy, P.K. (2021) Maturity Status Classification of Papaya Fruits Based on Machine Learning and Transfer Learning Approach. *Information Processing in Agriculture*, **8**, 244-250. <https://doi.org/10.1016/j.inpa.2020.05.003>
- [9] Marimuthu, S. and Roomi, S.M.M. (2017) Particle Swarm Optimized Fuzzy Model for the Classification of Banana Ripeness. *IEEE Sensors Journal*, **17**, 4903-4915. <https://doi.org/10.1109/jsen.2017.2715222>
- [10] Mahmood, A., Singh, S.K. and Tiwari, A.K. (2022) Pre-Trained Deep Learning-Based Classification of Jujube Fruits According to Their Maturity Level. *Neural Computing and Applications*, **34**, 13925-13935. <https://doi.org/10.1007/s00521-022-07213-5>

-
- [11] Saranya, N., Srinivasan, K. and Kumar, S.K.P. (2022) Banana Ripeness Stage Identification: A Deep Learning Approach. *Journal of Ambient Intelligence and Humanized Computing*, **13**, 4033-4039.
<https://doi.org/10.1007/s12652-021-03267-w>
- [12] Novac, O., Chirodea, M.C., Novac, C.M., Bizon, N., Oproescu, M., Stan, O.P., *et al.* (2022) Analysis of the Application Efficiency of Tensorflow and Pytorch in Convolutional Neural Network. *Sensors*, **22**, Article 8872.
<https://doi.org/10.3390/s22228872>