

基于改进残差网络的黑毛猪肉新鲜度识别方法

焦俊¹ 王文周¹ 侯金波² 孙裴³ 何屿彤¹ 辜丽川¹

(1. 安徽农业大学信息与计算机学院, 合肥 230036; 2. 安徽泓森物联网有限公司, 亳州 236800;
3. 安徽农业大学动物科技学院, 合肥 230036)

摘要: 为了提高黑毛猪肉新鲜度的识别准确率, 提出基于改进残差网络和迁移学习的黑毛猪肉新鲜度识别方法。首先, 根据猪肉的微生物菌体浓度、大肠杆菌体浓度和 pH 值, 结合国家标准, 将猪肉新鲜度分为 7 个类别; 然后, 将 ResNet-50 模型用 PfidSet 数据集训练, 使其具有抽取图像特征的能力, 利用模型迁移和模型微调对 ResNet-50 模型进行改进, 即用 3 层的自适应网络取代 ResNet-50 模型的全连接层和分类层, 再使用在 PfidSet 上训练的网络参数初始化改进的 ResNet-50 模型权重, 运用 LReLU-Softplus 作为自适应网络的激活函数; 最后, 将改进 ResNet-50 模型在猪肉样品的图像数据集上学习得到的知识, 迁移到黑毛猪肉新鲜度识别任务。选取 7 类共计 23 427 幅黑毛猪肉图像组成样本集, 从样本集中随机选择 80% 的样本用作训练集、其余 20% 用作测试集进行测试, 试验结果表明, 迁移学习能够明显提高模型的收敛速度和识别性能, 数据扩充有助于增加数据的多样性, 避免出现拟合现象, 在迁移学习和数据扩充方式下的总体识别准确率达到 94.5%, 是一种高效的猪肉新鲜度识别方法。

关键词: 猪肉; 新鲜度; 迁移学习; LReLU-Softplus 激活函数; 改进残差网络

中图分类号: TS251.7 **文献标识码:** A **文章编号:** 1000-1298(2019)08-0364-08

Freshness Identification of Iberico Pork Based on Improved Residual Network

JIAO Jun¹ WANG Wenzhou¹ HOU Jinbo² SUN Pei³ HE Yutong¹ GU Lichuan¹

(1. School of Information & Computer, Anhui Agricultural University, Hefei 230036, China

2. Anhui Hongsen Internet of Things Co., Ltd., Bozhou 236800, China

3. College of Animal Science and Technology, Anhui Agricultural University, Hefei 230036, China)

Abstract: In order to improve the accuracy of pork freshness identification, a method for pork freshness identification based on improved residual network and transfer learning was proposed. First of all, the pork freshness was classified into seven grades, according to the aerobic plate count, coliform bacteria and pH value of pork combined with national pork food standards (national standards). The ResNet-50 model was trained with the PfidSet data set to have the ability of extracting image features. Then, the ResNet-50 model was improved by using model transferring and model fine-tuning in the following ways: firstly, replacing the full connection and classification layers of the ResNet-50 model with a 3-layer adaptive network; next, initializing the improved ResNet-50 model weights by using the network parameters trained on the PfidSet; then using LReLU-Softplus as the activation function of the adaptive network; finally, transferring the knowledge gained by the improved ResNet-50 model on the image data set of the pork sample to the task of Iberico pork freshness identification. A total of 23 427 images were selected to form the sample set. Then, 80% of the samples were randomly selected from the sample set to be used as the training set, and the remaining 20% for the test set. The test results showed that transfer learning could significantly improve the convergence speed and classification performance of the model, and data augmentation could increase the diversity of data, avoiding over-fitting phenomena. The accuracy of classification in transfer learning and data augmentation could reach as high as 94.5%. Moreover, the test method was an efficient method for classifying pork freshness.

Key words: pork; freshness; transfer learning; LReLU-Softplus activation function; improved residual network

收稿日期: 2019-01-21 修回日期: 2019-02-13

基金项目: 安徽省重点研究与开发计划项目 (1804a0702130)、国家自然科学基金项目 (31671589、31771679)、安徽省科技重大攻关项目 (16030701092) 和农业农村部农业电子商务重点实验室开放基金项目 (AEC2018010、AEC2018003)

作者简介: 焦俊 (1964—), 男, 教授, 主要从事物联网研究, E-mail: jiaojun2000@sina.com

通信作者: 辜丽川 (1974—), 男, 教授, 博士生导师, 主要从事智能计算研究, E-mail: gulichuan@ahau.edu.cn

0 引言

猪肉在存放过程中,由于酶的作用、微生物污染或宰杀前患病等原因,造成猪肉自溶、腐败分解等变化,导致猪肉新鲜度下降。猪肉成分的分解必然使其营养价值降低,而且参与腐败的微生物和毒素,以及腐败后产生的有毒分解物,可能引起食用者中毒或诱发疾病。猪肉质变是一个渐进过程,受诸多因素的影响。因此快速识别猪肉品质和安全性有助于维护消费者的健康和切身利益。

猪肉品质的评价指标有颜色、质地、pH 值、嫩度、新鲜度等,新鲜度反映微生物、理化和生化特性,是评价猪肉品质和安全性的重要指标。猪肉的主要成分(蛋白质、脂肪和碳水化合物)被酶和细菌分解,产生气味;猪肉中的蛋白质将逐渐分解为氢、硫化物、氨、乙基硫醇等,产生包括组胺、酪胺、腐胺和色胺有毒小分子;脂肪分解成醛类化合物和醛酸;碳水化合物分解为醇类、酮类、醛类、烃类和羧酸类酸性气体。在贮藏过程中,这些物质和其他碱性氮化合物一起将影响猪肉的颜色、纹理和形状特征^[1-3]。

理化分析挥发性盐基氮(Total volatile basic nitrogen,TVB-N)和微生物种群是猪肉新鲜度检测的常规方法,但是该方法有损、低效和耗时。近红外(Near-infrared,NIR)光谱具有快速、简单检测肉品性状的能力,将其与计算机视觉(Computer vision,CV)结合评估猪肉新鲜度,已经取得了较好的效果^[4-5]。高光谱结合成像技术也在食品品质检测中得到了应用,文献[6-7]利用高光谱图像(Hyperspectral imaging,HSI)技术检测猪肉中细菌总数(Total viable count,TVC),效果良好;文献[8-9]用 HSI 评估肴肉的新鲜度,也获得了较好的检测结果。多光谱成像(Multispectral imaging,MSI)同样是新型的检测技术,该方法将图像和光谱结合起来,获得检测对象的空间信息和光谱信息^[10-15],以实现对猪肉新鲜度高精度的无损检测。文献[16]将 MSI 与线性算法相结合,检测有氧包装牛肉在不同贮藏温度下的品质状况,结果表明,其对牛肉腐烂等级有较好的分类效果。MSI 与线性偏最小二乘回归(Partial least squares regression,PLSR)相结合,检测熟猪肉香肠中需氧平板数(APC)的快速无损检测技术,表现出良好的检测能力^[17]。

近红外、高光谱和多光谱检测设备价格高昂,这些设备只能作为一种实验室研究设备。为了满足消费者的需要,研究低成本猪肉新鲜度检测方法尤为重要。

随着深度学习和计算机视觉技术的快速发展,

开发基于深度学习和计算机视觉的猪肉新鲜度识别系统成为可能。迁移学习运用在大样本数据集上训练好的模型,再提取小样本特征,为小样本检测对象的识别提供了途径^[18-25]。

黑毛猪是淮猪的一个品系,是生长于淮北平原的地方优良品种,由于现有淮猪肉新鲜度图像样本数量较少,因此对其新鲜度的识别较为困难。

针对小样本黑毛猪肉新鲜度识别问题,本文提出一种改进残差网络的黑毛猪肉新鲜度识别模型,以兽医病理生物学与疫病防控安徽省重点实验室多年积累的各类猪肉新鲜度图像为样本数据集(Pork freshness image as data set, PfidSet),并完成分类标注。运用残差网络(Residual networks, ResNet) ResNet-50 在该数据集上进行识别训练,构建残差网络 ResNet-50 的参数模型,然后运用迁移学习和模型微调将训练好的 ResNet-50 模型迁移到黑毛猪肉图像数据集(Iberico pork image data set, IpidSet)中微调,在黑毛猪肉图像样本较少的情况下,实现黑毛猪肉新鲜度的准确识别。

1 试验数据

1.1 样本制备

黑毛猪肉新鲜度分级的主要依据是微生物菌群总量、大肠菌群和 pH 值。大肠菌群的计数方法根据 GB/T 4789. 32—2002《食品大肠菌群快速检验标准》;微生物菌落总数计数根据 GB 47892—2010《食品微生物菌落总数测定标准》;pH 值根据 GB 5009. 237—2016《食品测定标准》。因此,黑毛猪肉图像样本的设计思路是:采用正常宰杀、未经冷冻处理的黑毛猪后腿部位肌肉和脂肪组织,拍摄保存为新鲜的猪肉样本图像。把新鲜猪肉样本分为 A、B、C 共 3 组。其中 A 组样本由 14 块肉组成,每两块放进一个密封袋,共 7 份;B 组样本由 12 块肉组成,每两块肉放进一个密封袋,共 6 份;C 组样本由 10 块肉组成,每两块放进一个密封袋,共 5 份。

将 3 组样本放进 -20℃ 环境保存,1 d 后,拿出标签为 A 的全部样本放进 4℃ 环境继续保存 1 d,再取 A 组样本中的第 1 份猪肉样本编号,分别统计其微生物菌群总量和大肠菌群,检测 pH 值。

然后,从 -20℃ 冷冻的环境中取出保存 2 d 的 B 组肉样本放在 4℃ 环境保存 1 d 后,再取出 A 组样本中的第 2 份样本和 B 组样本中的第 1 份样本分别编号并统计其微生物菌群总量和大肠菌群,检测 pH 值。

最后,把 C 组样本全部从保存 3 d 的 -20℃ 环境中取出,放进 4℃ 环境保存 1 d,再取出 A 组样本

中的第3份、B组样本中的第2份和C组样本中的第1份样本,分别编号并统计其微生物菌群总量和大肠菌群,检测pH值。

以后每天取出A、B、C组各一份猪肉样本,统计微生物总数和检测pH值,全部样本检测需要7d。不同新鲜度猪肉样本制备流程图如图1所示。




图1 制备不同新鲜度猪肉样本流程图

Fig. 1 Procedures for preparing pork samples with different freshness

1.2 新鲜度分类标准

依据国家规定,把被检测猪肉的pH值在5.6~6.2之间、稀释度为1/10 000的条件下,微生物菌体浓度在2.46~16.2 CFU/mL之间、大肠菌菌体浓度在3.48~5.97 CFU/mL之间规定为新鲜肉;pH值在6.2~6.7之间、稀释度为1/10 000的条件下微生物菌体浓度在16.8~370.43 CFU/mL之间、大肠菌菌体浓度在9.24~93 CFU/mL之间规定为次鲜肉;pH值大于6.7、稀释度为1/10 000的条件下微生物菌体浓度在410~3 070 CFU/mL之间、大肠菌菌体浓度在240~1 100 CFU/mL之间规定为腐败肉。

把次鲜肉微生物菌体浓度在16.2~28.4 CFU/mL之间、大肠菌菌体浓度在5.97~9.2 CFU/mL之间且pH值在6.1~6.3之间规定为次鲜肉一级;微生物菌体浓度在28.4~142 CFU/mL之间、大肠菌菌体浓度在9.2~28 CFU/mL之间且pH值在6.2~6.5之间规定为次鲜肉二级;微生物菌体浓度在142~370 CFU/mL之间、大肠菌菌体浓度在28~93 CFU/mL之间且pH值在6.4~6.7之间规定为

次鲜肉三级。

把腐败肉微生物菌体浓度在370~1 040 CFU/mL之间、大肠菌菌体浓度在93~240 CFU/mL之间且pH值在6.7~6.8之间规定为腐败肉一级;微生物菌体浓度在1 040~1 420 CFU/mL之间、大肠菌菌体浓度在240~290 CFU/mL之间且pH值在6.8~7.0之间规定为腐败肉二级;微生物菌体浓度1 420~3 020 CFU/mL之间、大肠菌菌体浓度在290~1 100 UFC/mL且pH值大于7.0规定为腐败肉三级。

1.3 样本图像获取与扩增

在每次检测黑毛猪肉样本微生物菌体浓度、大肠菌菌体浓度和pH值前,采用高清晰摄像头拍摄被检测样本,拍摄时选择单一背景颜色、光线明亮适中,摄像头背光,拍摄的图片以JPG或PNG格式保存。待试验完成后,根据微生物菌体浓度、大肠菌菌体浓度和pH值,对照1.2节的分类标准,把A、B、C组猪肉样本图像分别标记,归到7个类别的相应类别中。最终把所有7类图像以等级名称命名放在samples文件夹中。7类样本图像如图2所示。




图2 猪肉样本

Fig. 2 Pictures for pork freshness samples

利用边缘的最小外接矩,裁剪样本为 224 像素 × 224 像素,使之缩小,样本裁剪前后如图 3 所示,每个样本约 11 kB。对样本分别运用仿射变换、透视变换和旋转进行增广处理,其中初始图像 7 823 幅、增广图像 15 604 幅。




图 3 样本裁剪

Fig. 3 Cutting samples

2 试验方法

2.1 深度残差神经网络

深度残差神经网络(ResNet)是由残差学习模块重复堆积而形成的一个完整网络^[26],由于其引入残差模块,解决模型在训练时的梯度弥散问题,增强了模型的特征学习能力,以及模型的识别性能。残差模块如图 4 所示。




图 4 残差模块

Fig. 4 Residual module

设 x 为输入,经过卷积层 W_1 、 W_2 运算后输出为 $F(x, W_1, W_2)$,激活函数为 ReLu,因此,残差模块单元的最终输出 y 可表示为

$$y = F(x, W_1, W_2) + W_s x \quad (1)$$

式中 W_1 、 W_2 ——卷积神经网络 1、2 层所要学习的权重参数

W_s ——将变量 x 从输入残差模块维度变换到输出维度的方阵

x 跨层后与 $F(x, W_1, W_2)$ 融合,成为下个残差模块的输入。

当 W_s 的模为 1 表示残差模块的输入与输出维度相同;当 W_s 的模不为 1 表示残差模块的输入与输出维度不相同,需要通过 W_s 将残差模块的输入与输出维度变换到相同的维度。当 $y - x = 0$,表示为恒等映射;当 $y - x \neq 0$,表明残差网络只需要学习输入输出的差别部分。深度残差神经网络在训练时,深层的误差通过捷径传播到浅层,减轻梯度弥散现象。

ResNet-50 被本文选为图像的特征提取器,来学习图像的抽象特征。

2.2 迁移学习

在监督学习方式下,需要大量数据训练残差网络模型,然而,目前带标签的黑毛猪肉新鲜度图像数据较少,难以满足训练深度网络模型的需求。

为了改善黑毛猪肉新鲜度图像识别精度和 ResNet-50 模型的泛化能力,采用基于中层表达的迁移学习方法,将迁移学习和深度学习结合,先利用 PfidSet 对 ResNet-50 网络进行预训练,使其具有抽取图像特征的能力,并将训练好的网络参数作为网络模型的初始参数;然后,改进 ResNet-50 网络,利用 7 类黑毛猪肉图像对改进的 ResNet-50 进行微调,实现黑毛猪肉新鲜度图像自动识别。

2.3 ResNet-50 模型的改进

为了使 PfidSet 训练后的 ResNet-50 模型更具有泛化能力,采用一个 3 层的自适应网络取代 ResNet-50 模型的全连接层和分类层,再运用 LReLU-Softplus 作为网络的激活函数。

ReLU 非线性映射函数为

$$f(x) = \begin{cases} 0 & (x \leq 0) \\ x & (x > 0) \end{cases} \quad (2)$$

图 5a 为其示意图。当输入 $x \leq 0$ 时,ReLU 输出 0,该单元处于未激活状态。

LReLU 线性整流单元的表达式为

$$f(x) = \begin{cases} x & (x > 0) \\ \alpha x & (x \leq 0) \end{cases} \quad (3)$$

取 $\alpha = 0.01$,图 5b 为其示意图,当输入 $x < 0$ 时,输出负值,神经元仍处于激活状态,避免了神经元的坏死。

Softplus 激活函数为

$$f(x) = \ln(e^x + 1) \quad (4)$$

从图 5c 可见,函数变化平缓,其值与 ReLu 接近,具有较高的模型识别性能和较好的泛化性,并且其规避了 ReLu 函数强制性稀疏的缺点。但是 Softplus 函数存在一个与 ReLu 一样的问题,即输出偏移现象,这会影响网络的收敛性。

虽然 LReLU 函数解决 ReLu 函数会导致神经元死亡的问题,但函数光滑度不高。Softplus 函数具有优良的光滑特性,可是该函数的输出偏移会影响网络的收敛性。考虑到 LReLU 和 Softplus 函数的特点,结合这 2 个函数特点,本文设计一种改进的激活函数,即 LReLU-Softplus 函数,公式为

$$f(x) = \begin{cases} \alpha x & (x \leq 0) \\ \ln(e^x + 1) - \ln 2 & (x > 0) \end{cases} \quad (5)$$

其中 α 是个常数,接近于 0,初始值设为 0.25,图 5d




图5 激活函数

Fig. 5 Activation functions

为其示意图。

本文提出的改进残差网络的黑毛猪肉新鲜度识别模型是基于迁移学习和 LReLU - Softplus 激活函数的残差网络模型,即 Proposed(LReLU - Softplus),其结构如图 6 所示,其中,M1、M2、M3、M4 分别为 ResNet - 50 所示模型中的 4 个残差块,自适应网络

N1 层的神经元有 1 000 个;N2 层有 256 个神经元;有 7 个神经元在 N3 层,每层神经元的激活函数采用 LReLU - Softplus,在深度神经网络的训练过程中,加入 dropout(“丢弃”)机制,以一定的概率“暂时丢弃”一些神经元,减少神经元之间的依赖性,提高模型的泛化能力,取 dropout 为 0.8。




图6 基于中层表达的迁移学习

Fig. 6 Transfer learning based on middle-level expressions

3 试验结果及分析

试验软硬件环境主要配置:主板为华硕 Z170, CPU 为 Intel Core i7 - 6700k,硬盘为三星 SSD 950 PRO256GB + 希捷 ST2000 2.0TB,显卡为 GeForce GTX1080,内存为金士顿 DDR46 4GB,操作系统为 Windows 10 企业版,Caffe 系统是 Windows 10 版,模型训练参数见表 1。

训练与测试用的黑毛猪肉新鲜度图像数据共有 23 427 幅,其中初始图像 7 823 幅,扩展图像 15 604 幅,如表 2 所示。

按照 4:1 的比例随机分配训练集和测试集,按照 9:1 的比例分配训练集与验证集。利用可以度量

表 1 模型训练参数


Tab. 1 Parameters for model training	
参数	数值/类型
动量	0.89
学习率	1×10^{-3}
迭代次数	1 000
衰减系数	1×10^{-5}
优化器	SGD
批量	20

真实样本分布与预测样本分布差异的交叉熵代价函数,监督本文提出的 Proposed (LReLU - Softplus) 模型训练,图 7 为训练时的模型损失率和模型准确率变化曲线,可以发现经过 800 代遍历,训练和验证集上的模型损失率均趋向零。也可以发现经过 800 代遍历后,训练集的识别准确率趋向于 99.7%,验证

表 2 初始图像和扩展图像数量

Tab.2 Total number for initial and extended images			幅
类别	初始图像数量	初始和增广图像数量	用于验证的图像数量
新鲜肉	1 239	3 679	368
次鲜肉一级	2418	7 254	725
次鲜肉二级	670	2 010	201
次鲜肉三级	604	1 810	181
腐败肉一级	257	771	77
腐败肉二级	1 832	5 495	550
腐败肉三级	803	2 408	240

集的准确率最高达到 95%。可见,本文设计的基于改进残差网络和迁移学习的猪肉新鲜度识别模型具



有较好的肉品图像识别性能。

本文利用混淆矩阵来定量评估猪肉各类新鲜度之间的混淆程度,矩阵的行和列分别代表真实和预测情况,矩阵中任意一个元素 x_{ij} 代表将第 i 种类别预测为第 j 种类别的图像数占该类别图像总数的百分比。对角线元素值分别表示各种黑毛猪肉新鲜度识别的准确率,其他位置为错分率。表 3 为混淆矩阵,分析表 3 可知,新鲜肉的识别效果最好,具有 99% 的准确率,次鲜肉三级和腐败肉一级的识别准确率最差,为 91%;各类黑毛猪肉新鲜度的总体识别准确率为 94.5%,可见,本文设计的 Proposed (LReLU - Softplus) 模型对黑毛猪肉新鲜度的识别具有较高准确率。




图 7 模型损失率和识别准确率变化曲线

Fig. 7 Changing curves for model loss and recognition accuracy rate

表 3 混淆矩阵

Tab.3 Confusion matrix		%					
	新鲜肉	次鲜肉一级	次鲜肉二级	次鲜肉三级	腐败肉一级	腐败肉二级	腐败肉三级
新鲜肉	99	1	0	0	0	0	0
次鲜肉一级	0	98	0	0	2	0	0
次鲜肉二级	7	0	92	8	0	0	0
次鲜肉三级	0	0	9	91	0	0	0
腐败肉一级	0	0	0	4	91	5	0
腐败肉二级	0	0	0	0	4	94	2
腐败肉三级	0	0	0	0	2	1	97

表 4 模型性能比较

Tab.4 Comparison for models performance		训练时间/h	识别时间/h	识别准确率/%
模型名称	层数			
ResNet - 50 (IpidSet)	50	23. 60	0. 051 0	68. 93
ResNet - 50 (PfidSet)	50	43. 00	0. 057 4	85. 77
Proposed(ReLu)	52	41. 70	0. 048 2	94. 78
ResNet - 50(迁移)	50	41. 85	0. 051 0	94. 57
Proposed(LReLU - Softplus)	52	41. 25	0. 047 9	95. 22

同时,将 Proposed (LReLU - Softplus) 模型,与仅使用 PfidSet 数据集训练的 ResNet - 50 (PfidSet) 模型、仅使用 IpidSet 数据集训练的 ResNet - 50 (IpidSet) 模型和基于迁移理论与 ReLu 激活函数的改进 ResNet - 50 模型,即 Proposed (ReLu) 进行比较,表 4 是比较结果。表 4 中模型的识别准确率均是在测试集上获得,分析表 4 可得,ResNet - 50 (IpidSet) 的识别准确率最差,这是由于 IpidSet 的样本数量较少;综合表 3 和表 4 可知,仅使用 PfidSet 数据集训练模型会出现过拟合现象。本文提出的 Proposed (LReLU - Softplus) 模型是利用 PfidSet 数据集预训练模型,然后迁移到 IpidSet 数据集上微调模

型,优于仅使用 PfidSet 或 IpidSet 训练的模型。此外,本文通过对 ResNet - 50 模型的改进,减少了模型的运算量和训练时间,而且模型识别准确性能相对于未改进的 ResNet - 50 模型也有较好的提高。网络中利用 LReLU - Softplus 激活函数对模型的效率影响,较利用 ReLu 激活函数明显,模型的识别准确率也有所提高。

4 结束语

为了解决小样本黑毛猪肉新鲜度识别问题,使用 PfidSet 源数据制作了包含 7 类各品种的猪肉新鲜度图像数据集,构建基于中层表达的迁移学习模型,利用一个 3 层的自适应网络取代 ResNet - 50 模型的全连接层和识别层,并使用 7 类黑毛猪肉图像

数据对模型进行微调,实现对7类新鲜猪肉图像的有效识别。试验结果表明,Proposed(LReLu-Softplus)模型适合黑毛猪肉新鲜度识别,各类新鲜度猪肉总体识别准确率为94.5%。

参 考 文 献

- [1] KAMRUZZAMAN M, EIMASRY G, ALLEN P, et al. Prediction of some quality attributes of lamb meat using near-infrared hyperspectral imaging and multivariate analysis[J]. *Anal. Chim. Acta*, 2012, 714: 57–67.
- [2] SCHIRMER B C, LANGSRUD S. Evaluation of natural antimicrobials on typical meat spoilage bacteria in vitro and in vacuum-packed pork meat[J]. *J. Food Sci.*, 2010, 75(2): 98–102.
- [3] LEROY B, LAMBOTTE S, DOTREPPE O, et al. Prediction of technological and organoleptic properties of beef *Longissimus thoracis* from near-infrared reflectance and transmission spectra[J]. *Meat Sci.*, 2004, 66(1): 45–54.
- [4] LIU D, PU H, WANG L, et al. Combination of spectra and texture data of hyperspectral imaging for prediction of pH in salted meat[J]. *Food Chem.*, 2014, 160: 330–337.
- [5] GIROLAM A, NAPOLITANO F, FARAONE D, et al. Measurement of meat color using a computer vision system[J]. *Meat Sci.*, 2013, 93(1): 111–118.
- [6] 彭彦昆, 杨清华, 王文秀. 基于近红外光谱的猪肉水分在线检测与分级[J/OL]. *农业机械学报*, 2018, 49(3): 347–353. PENG Yankun, YANG Qinghua, WANG Wenxiu. On-line detection and classification of pork moisture based on near-infrared spectra[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(3): 347–353. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20180343&flag=1. DOI: 10.6041/j.issn.1000-1298.2018.03.043. (in Chinese)
- [7] 李小昱, 钟雄斌, 刘善梅, 等. 不同品种猪肉 pH 值高光谱检测的模型传递修正算法[J/OL]. *农业机械学报*, 2014, 45(9): 216–222. LI Xiaoyu, ZHONG Xiongbao, LIU Shanmei, et al. Comparison of transfer and correctional methods for pork pH value detection of different varieties by hyperspectral imaging technique[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2014, 45(9): 216–222. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20140935&flag=1. DOI: 10.6041/j.issn.1000-1298.2014.09.035. (in Chinese)
- [8] CHEN Q, ZHANG Y, ZHAO J, et al. Nondestructive measurement of total volatile basic nitrogen (TVB-N) content in salted pork in jelly using a hyperspectral imaging technique combined with efficient hypercube processing algorithms[J]. *Anal. Meth.*, 2013, 5(22): 6382–6388.
- [9] CHEN M Y, YANG Y H, HO C J, et al. Automatic Chinese food identification and quantity estimation[C]//*Proceedings of SIGGRAPH Asia 2012 Technical Briefs*. Singapore, 2012: Article No. 29.
- [10] 李翠玲, 彭彦昆, 汤修映. 基于多光谱成像技术的猪肉新鲜度无损快速检测装置[J/OL]. *农业机械学报*, 2012, 43(增刊): 202–206. LI Cuiling, PENG Yankun, TANG Xiuying. Device for rapid nondestructive detection of pork freshness based on multispectral imaging technology[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2012, 43(Supp.): 202–206. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=2012S40&flag=1. DOI: 10.6041/j.issn.1000-1298.2012.S0.040. (in Chinese)
- [11] CHENG J H, SUN D W, ZENG X A, et al. Non-destructive and rapid determination of TVB-N content for freshness evaluation of grass carp (*Ctenopharyngodon idella*) by hyperspectral imaging[J]. *Innovat. Food Sci. Emerg. Technol.*, 2014, 21: 179–187.
- [12] LIU C, LIU W, LU X, et al. Nondestructive determination of transgenic *Bacillus thuringiensis* rice seeds (*Oryza sativa* L.) using multispectral imaging and chemometric methods[J]. *Food Chem.*, 2014, 153: 87–93.
- [13] BOWLING M B, VOTE D J, BELK K E, et al. Using reflectance spectroscopy to predict beef tenderness[J]. *Meat Science*, 2009, 82(1): 1–5.
- [14] LIU D, SUN D W, QU J, et al. Feasibility of using hyperspectral imaging to predict moisture content of porcine meat during salting process[J]. *Food Chem.*, 2014, 152: 197–204.
- [15] MA F, YAO J, XIE T, et al. Multispectral imaging for rapid and non-destructive determination of aerobic plate count (APC) in cooked pork sausages[J]. *Food Res. Int.*, 2014, 62: 902–908.
- [16] PANAGOUE E Z, PAPADOPOULOU O, CARSTENSEN J M, et al. Potential of multispectral imaging technology for rapid and non-destructive determination of the microbiological quality of beef filets during aerobic storage[J]. *Int. J. Food Microbiol.*, 2014, 174: 1–11.
- [17] XIONG Z J, SUN D W, ZENG X A, et al. Recent developments of hyperspectral imaging systems and their applications in detecting quality attributes of red meats: a review[J]. *Journal of Food Engineering*, 2014, 132: 1–13.
- [18] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//*2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2014.
- [19] SZEGEDY C, VANHOUCHE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//*Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV. IEEE, 2016: 2818–2826.

- [20] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge[J]. *Int. J. Comput Vision*, 2015, 115(3): 211 – 252.
- [21] PAN S J, YANG Q. A survey on transfer learning[J]. *Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345 – 1359.
- [22] CHERIYADAT A M. Unsupervised feature learning for aerial scene classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(1): 439 – 451.
- [23] YANG Y, NEWSAM S. Spatial pyramid co-occurrence for image classification[C] // *IEEE International Conference on Computer Vision*. IEEE, 2011: 1465 – 1472.
- [24] LIN K, YANG H F, CHEN C S. Flower classification with few training examples via recalling visual patterns from deep CNN [C] // *IPPR Conference on Computer Vision, Graphics, and Image Processing (CVGIP)*, 2015.
- [25] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. *Neural Network*, 2014, 61: 85 – 117.
- [26] CHEN N, XING C, ZHANG X, et al. Space-borne earth-observing optical sensor static capability index for clustering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(10): 5504 – 5518.
-

(上接第363页)

- [14] FONTAINE J, HORR J, SCHIRMER B. Near-infrared reflectance spectroscopy enables the fast and accurate prediction of the essential amino acid contents in soy, rapeseed meal, sunflower meal, peas, fishmeal, meat meal products, and poultry meal [J]. *Journal of Agricultural and Food Chemistry*, 2001, 49(1): 57 – 66.
- [15] FERREIRA D S, GALAO O F, PALLONE J A L, et al. Comparison and application of near-infrared (NIR) and mid-infrared (MIR) spectroscopy for determination of quality parameters in soybean samples[J]. *Food Control*, 2014, 35(1): 227 – 232.
- [16] FAN Xia, TANG Shichuan, LI Guozhen, et al. Non-invasive detection of protein content in several types of plant feed materials using a hybrid near infrared spectroscopy model[J]. *PIOS One*, 2016, 11(9): e163145.
- [17] AURELI R, UEBERSCHLAG Q, KLEIN F, et al. Use of near infrared reflectance spectroscopy to predict phytate phosphorus, total phosphorus, and crude protein of common poultry feed ingredients[J]. *Poultry Science*, 2016, 96(1): 160 – 168.
- [18] 王乐, 史永革, 李勇, 等. 在线近红外过程分析技术在豆粕工业生产上的应用[J]. *中国油脂*, 2015, 40(1): 91 – 94.
- WANG Le, SHI Yongge, LI Yong, et al. Application of online near-infrared process analytical technology in industrial production of soybean meal[J]. *China Oils and Fats*, 2015, 40(1): 91 – 94. (in Chinese)
- [19] BOUVERESSE E, MASSART D L. Standardisation of near-infrared spectrometric instruments: a review[J]. *Vibrational Spectroscopy*, 1996, 11(1): 3 – 15.
- [20] FEARN T. Standardisation and calibration transfer for near infrared instruments: a review[J]. *Journal of Near Infrared Spectroscopy*, 2001, 9(4): 229 – 244.
- [21] 高云, 高建芹, 王小天. 油菜籽品质指标近红外数学模型的仪器间转移优化[J]. *江苏农业科学*, 2012, 40(3): 292 – 295.
- [22] BELLON V, VIGNEAU J L, SEVILA F. Infrared and near-infrared technology for the food industry and agricultural uses: on-line applications[J]. *Food Control*, 1994, 5(1): 21 – 27.
- [23] GONZALEZMARTIN I, ALVAREZGACIA N, HERNANDEZANDALUZ J L. Instantaneous determination of crude proteins, fat and fibre in animal feeds using near infrared reflectance spectroscopy technology and a remote reflectance fibre-optic probe[J]. *Animal Feed Science & Technology*, 2006, 128(1 – 2): 165 – 171.
- [24] 褚小立. 化学计量学方法与分子光谱分析技术[M]. 北京: 化学工业出版社, 2011.
- [25] MODRONO S, SOLDADO A, MARTINEZ F A, et al. Handheld NIRS sensors for routine compound feed quality control: real time analysis and field monitoring[J]. *Talanta*, 2017, 162: 597 – 603.
- [26] SISOUANE M, CASCANT M M, TAHIRI S, et al. Prediction of organic carbon and total nitrogen contents in organic wastes and their composts by infrared spectroscopy and partial least square regression[J]. *Talanta*, 2017, 167: 352 – 358.
- [27] PREECE S L M, AUVERMANN B. W, MACDONALD J C, et al. Predicting the heating value of solid manure with visible and near-infrared spectroscopy[J]. *Fuel*, 2013, 106(2): 712 – 717.
- [28] WILLIAM P. Near-infrared technology-getting the best out of light[M]. Nanaimo: PDK Grain, 2007.