

高光谱影像的鲜桃可溶性固形物含量预测模型

杨宝华, 高志伟, 齐麟, 朱月, 高远

安徽农业大学信息与计算机学院, 安徽合肥 230036

摘要 可溶性固形物含量(SSC)是决定鲜桃风味和品质的重要成分。高光谱影像的特征提取为无损检测可溶性固形物含量提供了数据基础和方法路径。先前的研究表明,基于多光谱、荧光谱、近红外光谱、电子鼻的水果内部品质评估取得较好的结果。但是,由于缺少多特征融合,从而限制了水果品质的精准估测。为此,提出了一种基于堆栈自动编码器-粒子群优化支持向量回归(SAE-PSO-SVR)模型预测鲜桃可溶性固形物含量。首先,利用高光谱影像提取光谱信息、空间信息及空-谱融合信息。其次,设置普适性堆栈自动编码器(SAE)提取光谱信息、空间信息及空-谱融合信息的深层特征。最后,将深层特征作为粒子群优化支持向量回归(PSO-SVR)模型的输入数据进行鲜桃可溶性固形物含量的预测。其中,对于光谱信息作为输入的SAE模型,设计了453-300-200-100-40, 453-350-250-150-50, 453-350-250-100-60的三个隐含层结构。对于空间信息作为输入的SAE模型,设计了894-700-500-300-50, 894-650-350-200-80, 894-800-700-500-100的三个隐含层结构。对于融合信息作为输入的SAE模型,设计了1347-800-400-200-40, 1347-750-550-400-100, 1347-700-500-360-150的三个隐含层结构。实验结果表明,对于输入数据分别为光谱信息、空间信息及融合信息的SAE模型,结构为453-300-200-100-40, 894-800-700-500-100和1347-750-550-400-100的模型效果较好,而且基于融合信息的模型预测精度明显优于基于光谱信息或者图像信息的模型。为了验证模型的普适性,利用结构为1347-750-550-400-100的SAE模型提取融合信息的深层特征估测不同品种鲜桃的可溶性固形物含量并进行可视化。结果表明,基于结构为1237-650-310-130的SAE-PSO-SVR模型预测效果最好($R^2=0.8733$, $RMSE=0.6451$)。因此,所提出的SAE-PSO-SVR模型提高了鲜桃可溶性固形物含量的估计精度,为鲜桃的其他成分检测提供了技术支撑。

关键词 可溶性固形物含量; 高光谱影像; 深层特征; 支持向量回归; 鲜桃

中图分类号: O433.4 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2021)11-3559-06

引言

鲜桃是一种营养丰富和风味甜香的水果,可溶性固形物含量(soluble solids content, SSC)作为影响鲜桃风味的重要成分,也成为衡量鲜桃品质的重要参考标准,因此,精准估测SSC对于鲜桃分级和评价具有重要的研究意义和应用价值。

目前,随着传感器和数据分析技术的快速发展,无损估测水果可溶性固形物含量被广泛研究及应用。其中,近红外光谱、多光谱、荧光谱、电子鼻等已经成功地检测鲜果SSC^[1-4]。然而,目前大部分研究基于单一特征检测,从而限制了水果SSC预测模型的进一步探究。近年来,高光谱影像

(hyperspectral image, HSI)不仅提供光谱维信息,还提供空间维信息,常常被广泛用来检测水果的SSC^[5]。Fan等融合了光谱特征和纹理特征成功检测苹果的SSC^[6],Li等利用高光谱影像估测鲜桃的SSC^[7]。结果表明,基于高光谱影像特征估测SSC的可行性。然而,大部分研究仅基于光谱维信息,容易导致SSC估测模型过拟合。

随着深度学习在不同领域的应用,为鲜桃SSC预测提供了新思路和新方案。堆叠自动编码器(stacked auto-encoder, SAE)^[8]作为深度学习方法,具有较强的特征能力,从而提高预测模型的精确性。因此,在这项研究中设计不同结构的堆叠自动编码器,分别提取高光谱影像的光谱维、空间维及空-谱维信息的深层特征,为鲜桃SSC的定量分析提供技术路径。

收稿日期: 2020-08-12, 修订日期: 2021-01-09

基金项目: 安徽省自然科学基金项目(1808085MF195), 安徽农业大学茶树生物学与资源利用国家重点实验室开放基金项目(SKLT0F20200116)资助

作者简介: 杨宝华, 女, 1974年生, 安徽农业大学信息与计算机学院教授 e-mail: ybh@ahau.edu.cn

1 实验部分

1.1 数据获取

1.1.1 鲜桃样本及 SSC 数据采集

2019 年 6 月, 在市场上购买了不同品种的成熟鲜桃样本 120 个(黄金蜜桃、蟠桃和油桃各 40 个, 单果重量在 160~240 g 之间)。所有鲜桃表面被清洁处理后放置于 25 °C 的环境中保存 12 h, 使样品温度与室温基本一致。

通过手持型折射计(Model: LYT-330, Shanghai Linyu Trading Co., Ltd., China)测量鲜桃样本的 SSC, 其测量范围为 0~32°Brix, 分辨率为 0.2°Brix。测量鲜桃样本 SSC 时, 在样品进行光谱采集部位对应的鲜桃果肉深度为 5~8 mm 处, 取出果汁滴在折射计的检测窗口, 3 次重复采集的均值作为鲜桃样本 SSC 的真实值。所测样本集 SSC 含量在 6.0~14.2°Brix 之间。共计 120 个样本, 按照 3:1 划分为校正集(90 个)和验证集(30 个)。

1.1.2 高光谱影像采集

利用高光谱影像采集系统获取鲜桃高光谱影像数据, 该系统包括 1 个光谱成像仪(Imspector V17E, Spectral Imaging Ltd., Oulu, Finland)、1 个摄像机为 CCD 相机(IPX-2M30, ImperxInc., Boca Raton, FL, USA), 2 个 150 W 的卤素灯(3900, Illumination Technologies Inc., New York, USA), 1 个数据采集暗箱, 图像采集和分析软件(Spectral Image Software, Isuzu Optics Corp., Taiwan, China)组成, 反射式线性光道管和电控位移平台(MTS120, 北京光学仪器厂, 中国), 光源照射方向与竖直方向呈 45°, 整个采集系统置于暗箱内。

为了获得高质量的图像, 鲜桃样本的最高点到物镜距离为 220 mm, 电动机控制速度和曝光时间分别设置为 0.8 mm·s⁻¹、2 ms, 系统的光谱分辨率和图像大小分别为 5 nm、636×838 像素。为了尽可能降低图像噪声和暗电流的影响, 扫描鲜桃样本后, 使用标准白色和深色参考图像对获得的高光谱数据进行校准。

1.2 基于堆栈自动编码器-粒子群优化支持向量回归模型

1.2.1 堆栈自动编码器

自动编码器(auto-encoder, AE)是一种运行在人工神经网络上的基于无监督学习, 由编码器和解码器两部分构成, 其功能就是对输入样本进行学习并在输出中重构数据。通常将输入数据通过非线性激活函数映射到隐含层的阶段称为编码, 将隐含层映射至输出层称为解码。因此, AE 就是一个小型的深度神经网络, 该模型主要包括输入层、隐含层和输出层。

堆栈自动编码器(SAE)是通过多个自动编码器堆叠构成的^[10]。按照无监督的方式, 利用贪婪训练的方法, 对每个自动编码器进行单独训练。编码器相邻层中, 前一层的输出结果既是该隐含层的输出, 也是后一隐含层的输入。SAE 通过逐层训练可以从原始数据中获得有效的特征, 以减少原始信息的数据维数和干扰因素, 避免因过高的维数和原始数据的共线性等问题而导致过拟合现象。因此, 最后一个隐含层的输出结果就是利用 SAE 提取原始信息的深层特征。

1.2.2 估测鲜桃 SSC 的模型构建及评价

精确地提取特征是模型构建的重要前提。为了获取光谱信息和空间信息的特征, 首先获取鲜桃样本的光谱数据, 在鲜桃的邻近赤道部位选定一个 200×200 pixels 的图像感兴趣区域(region of interest, ROIs), 利用 ENVI 软件提取该区域范围内所有像素点的反射率; 其次, 利用 HSI 获得每个鲜桃样本的 636×838×508 图像; 然后, 提取有效波段对应高光谱影像的特征。最后, 为了提取空-谱特征, 将光谱维和空间维的原始信息进行融合。

为了预测鲜桃 SSC, 设计了堆栈自动编码器-粒子群优化支持向量回归(stacked autoencoder-particle swarm optimization-support vector regression, SAE-PSO-SVR)模型。将光谱维、空间维和融合信息分别输入到 SAE 模型, 在 SAE 提取光谱信息、图像信息和融合信息的深层特征基础上, 采用粒子群优化支持向量回归(particle swarm optimization-support vector regression, PSO-SVR)模型估测鲜桃 SSC, 如图 1 所示。其中, 本研究设计的 SAE 结构包括三层隐含层, 隐含层神经元节点数通过模型训练及参数微调确定。第三层隐含层的输出作为 PSO-SVR 模型的输入变量。

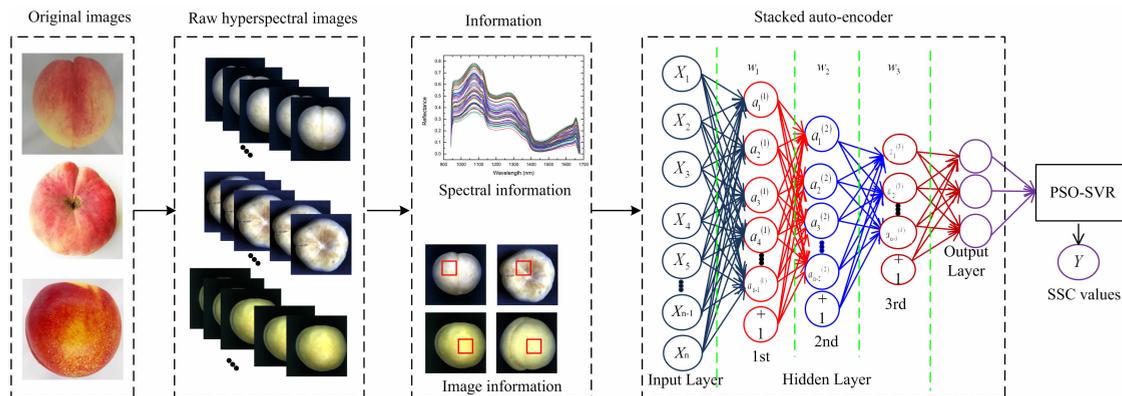


图 1 基于堆栈式自动编码器-粒子群优化支持向量回归预测鲜桃可溶性固形物含量模型

Fig. 1 Model for predicting the soluble solid content of peaches based on stacked autoencoder-particle swarm optimization-support vector regression

最后, 利用决定系数(coefficient of determination, R^2)和均方根误差(root mean square error, RMSE)作为解释和量化预测鲜桃 SSC 模型的评价指标。实验的硬件实验环境配置如下: 主板为 Z370 HD3-CF, CPU 为 Intel Core i7-8700, 显存为 8GB GDDR5, 内存 16 GB。软件环境配置为: 操作系统为 Windows 10(64 位), 编程软件和语言分别为 Anaconda3、matlab2017 和 python3.6, 深度学习框架为 Keras。

2 结果与讨论

2.1 基于鲜桃高光谱影像的信息获取

图 2 所示为从不同鲜桃样本高光谱影像中提取的光谱反射率, 该光谱曲线包含 508 个波段(908~1 735 nm), 去除部分噪声明显的首尾波段, 包括光谱曲线首端 908~940 nm 共 21 个波段, 末端 1 681~1 735 nm 共 34 个波段。剩余的 453 个波段(942~1 680 nm)作为光谱信息。鲜桃样本的光谱曲线可以有效地反映鲜桃中 SSC 等主要成分的化学信息, 光谱反射强度与 SSC 含量存在一定的相关性。因此, 含有不同 SSC 的鲜桃样本在不同波段下的光谱反射率存在一定的差异。

为了获取空间维信息, 利用鲜桃样本高光谱影像设置 5

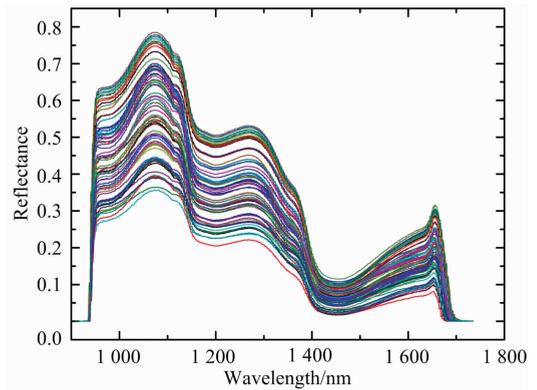


图 2 鲜桃的高光谱原始曲线

Fig. 2 The original hyperspectra of fresh peaches

个不同的感兴趣区域(50×50 pixels)提取 2 500 维像素信息, 取其平均值作为该样本的空间信息。为了提取敏感空间信息, 利用随机森林(random forest, RF)选取相对重要性大于 0.11 的信息(如图 3 所示), 共计 894 个敏感空间信息作为 SAE 的输入, 输出的结果就是高光谱影像的深层特征。为了获取鲜桃高光谱影像的融合信息, 将 453 维光谱信息和 894 维空间信息融合, 共计 1 347 维融合信息。

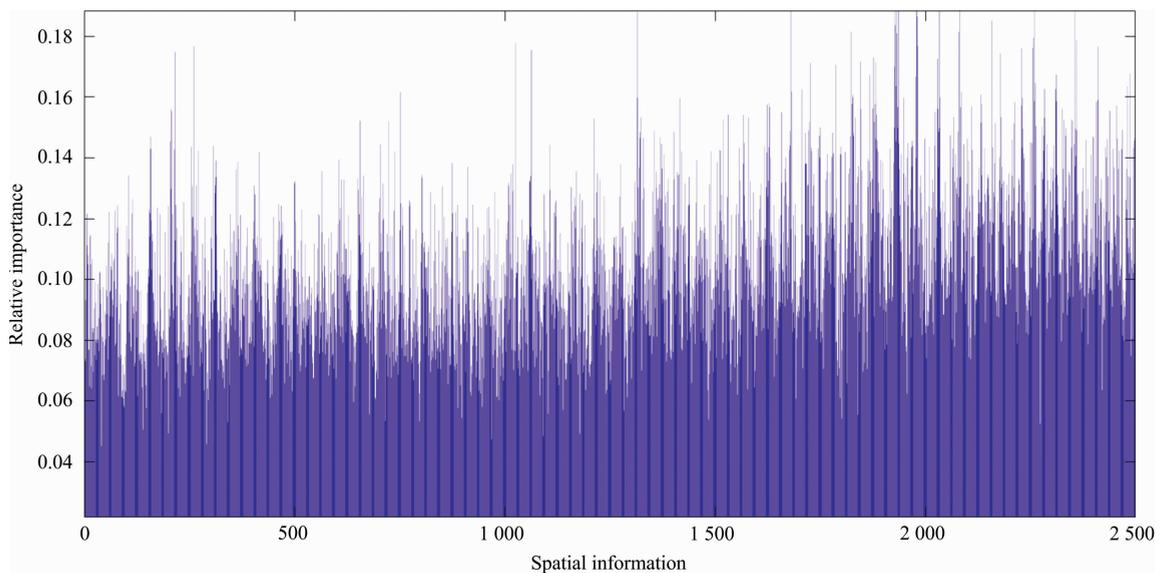


图 3 鲜桃高光谱影像空间信息的相对重要性

Fig. 3 The relative importance of spatial information of fresh peach hyperspectral images

2.2 基于 SAE-PSO-SVR 模型估测鲜桃可溶性固形物含量

为了对比不同 SAE 结构的预测效果, 分别利用光谱信息、空间信息和融合信息设置不同的 SAE 结构提取深层特征, 作为粒子群优化支持向量回归(PSO-SVR)模型的输入变量, 构建鲜桃 SSC 的估测模型, 结果如图 4 所示。对于校正集, 基于光谱信息深层特征、图像信息深层特征、融合信息深层特征的估测模型 R^2 分别分布在 0.723 4~0.826 9, 0.739 2~0.802 6 和 0.758 3~0.873 3 之间。对于验证集, 基于光谱信息深层特征、图像信息深层特征、融合信息深层

特征构建的估测模型 R^2 分别分布在 0.677 5~0.782 5, 0.685 5~0.776 6 和 0.693 7~0.820 9 之间。其中, 基于融合信息提取的深层特征估测鲜桃 SSC 的效果出色。尤其是, SAE 模型结构为 1347-750-550-400-100 模型的 R^2 达到 0.873 3(校正集)和 0.820 9(验证集), 比基于光谱信息的模型(SAE 结构为 453-300-200-100-40) R^2 提高 5.3% 和 4.7%, 比基于图像信息的模型(SAE 结构为 894-800-700-500-100) R^2 提高 8.1% 和 5.4%。

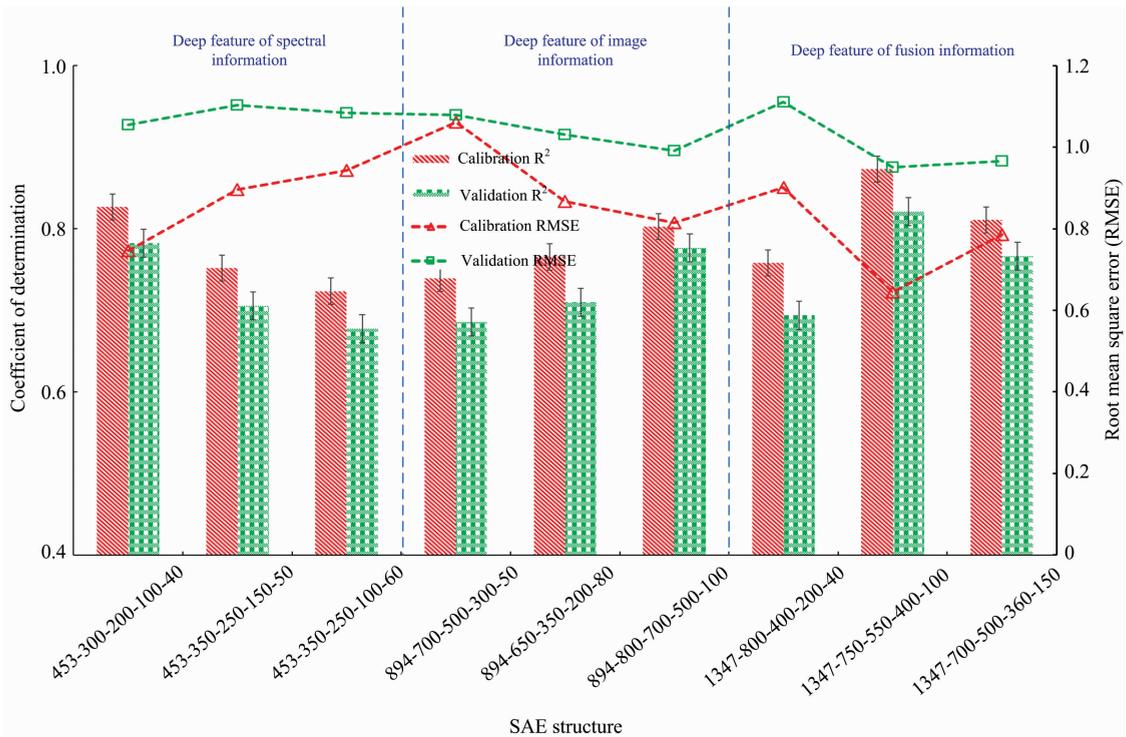


图 4 基于不同结构的 SAE-PSO-SVR 模型预测鲜桃 SSC 结果

Fig. 4 The results of predicting SSC of peach based on the SAE-PSO-SVR model with different structures

隐含层神经元节点是 SAE 模型的关键参数之一, 设置合适的节点对提高模型精度起到重要作用。因此, 根据鲜桃高光谱影像不同类型原始信息提取的深层特征, 经过参数调整、数据训练以选择合适的 SAE 模型。对于光谱信息, SAE 模型设置了三种结构(453-300-200-100-40, 453-350-250-150-50, 453-350-250-100-60)。其中, 利用隐含层为 300, 200 和 100 的 SAE 提取深层特征进行鲜桃 SSC 预测的精度是最好的, 比其他两种 SAE 结构预测效果分别提高 9.8% 和 13.4%。对于空间信息, SAE 模型设置了三种结构(894-700-500-300-50, 894-650-350-200-80, 894-800-700-500-100), 从模型训练的结果表明第一层、第二层和第三层隐含层节点数为 800, 700 和 500 的 SAE 模型表现更佳, 比其他两种模型的预测结果提高 11.7% 和 8.6%。对于融合信息, SAE 模型设置了三种结构(1347-800-400-200-40, 1347-750-550-400-100, 1347-700-500-360-150), 其中, 隐含层为 750, 550 和 400 的 SAE 提取的深层特征预测鲜桃 SSC 的精度最高, 比其他两种结构提取的深层特征预测精度分别提高 15.5% 和 6.6%。

2.3 鲜桃可溶性固形物含量可视化

为了直观地表示鲜桃 SSC, 选择成熟的黄金蜜桃、蟠桃和油桃作为测试样本, 利用 SAE-PSO-SVR 模型预测其 SSC 含量, 可视化结果如图 5 所示。从图 5 中可以看出, 第一行为鲜桃原始高光谱影像, 第二行为不同品种鲜桃 SSC 含量的伪彩色图。由图例可以看出不同品种鲜桃样本含有不同的 SSC。其中, 黄金蜜桃样本的 SSC 含量范围为 6.0~13.6° Brix, 蟠桃样本的 SSC 含量范围为 6.5~14.2° Brix, 油桃样

本的 SSC 含量范围为 6.0~14° Brix。由图 5 还可以直观看出, 黄金蜜桃和油桃的 SSC 分布于鲜桃赤道及桃核中心部分, 蟠桃的 SSC 主要分布于鲜桃核的四周区域。

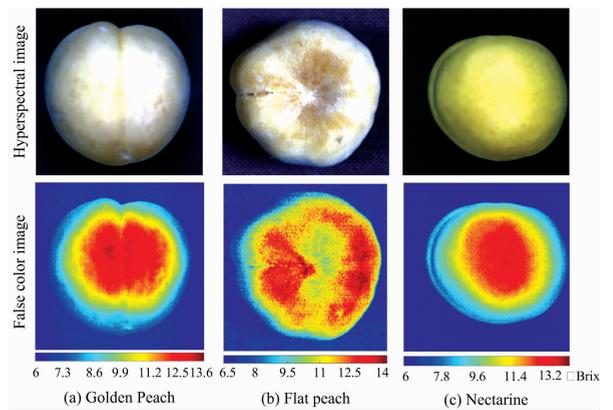


图 5 不同品种鲜桃的可溶性固形物含量可视化
Fig. 5 Visualization of the soluble solid content of different varieties of fresh peaches

3 结 论

可溶性固形物含量是衡量鲜桃品质和风味的关键因素。提出了一种 SAE-PSO-SVR 模型估测鲜桃 SSC。将深度学习理论应用到鲜桃可溶性固形物含量估测中, 并将无监督训练的 SAE 特征提取与有监督训练的微调相结合。主要结论如下:

(1) 通过对比不同隐含层神经元节点的 SAE 模型, 表明基于网络结构为 1347-750-550-400-100 模型估测效果最好。

(2) 通过对比输入不同信息的 SAE 模型估测效果, 表明基于融合信息的模型精度最高(校正集 $R^2=0.8733$, 验证集 $R^2=0.8209$)。

(3) 通过不同品种鲜桃样本的 SSC 可视化, 表明 SAE-

PSO-SVR 模型具有较好的普适性。基于 SAE 提取鲜桃高光谱影像的光谱信息和空间信息深层特征, 进一步通过融合信息的深层特征构建了基于 SAE-PSO-SVR 的鲜桃 SSC 估测模型, 有效的提高了模型的估测精度。今后将利用不同深度学习方法验证及检测鲜桃的其他品质参数, 如酸度、硬度及水分, 为鲜桃等水果的无损检测提供参考。

References

- [1] CHEN Dong-jie, JIANG Pei-hong, GUO Feng-jun, et al(陈东杰, 姜沛宏, 郭风军, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2020, 40(6): 1839.
- [2] Li J, Xue L, Liu M H, et al. Advanced Materials Research, 2011, 186: 126.
- [3] Penchaiya P, Bobelyn E, Verlinden B E, et al. Journal of Food Engineering, 2009, 94(3-4): 267.
- [4] Zhang W, Pan L, Zhao X, et al. Int. International Journal of Food Properties, 2016, 19(1): 53.
- [5] Pu Y Y, Sun D W, Riccioli C, et al. Food Analytical Methods, 2017, (11): 1.
- [6] Fan S, Zhang B, Li J, et al. Biosystems Engineering, 2016, 143: 9.
- [7] Li J, Chen L. Computers & Electronics in Agriculture, 2017, 142: 524.
- [8] Li S, Yu B, Wu W, et al. Neurocomputing, 2015, 151: 565.
- [9] Blaschke T, Olivecrona M, Engkvist O, et al. Molecular Informatics, 2018, 37: 1700123.
- [10] SUN Jun, JIN Hai-tao, LU Bing, et al(孙俊, 靳海涛, 芦兵, 等). Transactions of the Chinese Society of Agricultural Engineering (农业工程学报), 2019, 35(15): 295.

Prediction Model of Soluble Solid Content in Peaches Based on Hyperspectral Images

YANG Bao-hua, GAO Zhi-wei, QI Lin, ZHU Yue, GAO Yuan

School of Information and Computer, Anhui Agricultural University, Hefei 230036, China

Abstract Soluble solid content (SSC) is a key factor to evaluate the flavor and quality of fruits. The feature extraction of hyperspectral images provides the data basis and method path for the non-destructive estimation of the solid soluble content. Previous studies have shown that fruit internal quality evaluation based on multi-spectrum, fluorescence spectrum, near-infrared spectrum, and electronic nose has achieved good results. However, the lack of multi-feature fusion limits the accurate estimation of fruit quality. Therefore, this study proposed a model based on stacked autoencoder-particle swarm optimization-support vector regression (SAE-PSO-SVR) to predict the solid soluble content of fresh peaches. Firstly, hyperspectral images extracted spectral information, image pixel information corresponding to different bands, and fusion information. Secondly, a universal stacked autoencoder (SAE) was set up to extract the deep features of spectral information, spatial information, and space-spectrum fusion information. Finally, the deep features were used as the input data of the particle swarm optimization-support vector regression (PSO-SVR) model to predict the solid soluble content of fresh peaches. Among them, three hidden layer network structures were designed for the SAE model with spectral information as input data, including 453-300-200-100-40, 453-350-250-150-50 and 453-350-250-100-60. Three network structures of hidden layer nodes were designed for the SAE model with image information as input data, including 894-700-500-300-50, 894-650-350-200-80 and 894-800-700-500-100. Three hidden layer network structures were designed for the SAE model with fusion information as input data, including 1347-800-400-200-40, 1347-750-550-400-100 and 1347-700-500-360-150. The experimental results show that the models with SAE structures of 453-300-200-100-40, 894-800-700-500-100 and 1347-750-550-400-100 have the better estimation effect for spectral information, image information and fusion information as input data of the SAE model, and the prediction accuracy of the model based on the deep features of the fusion information was significantly better than that of the model based on spectral features or image features. The SAE model with the structure of 1347-750-550-400-100 was used to extract the deep features of the fusion information to estimate and visualize the solid soluble content of different varieties of fresh peaches. The results show that the prediction performance based on the SAE-PSO-SVR model was the best ($R^2=0.8733$, $RMSE=0.6451$). Therefore, the SAE-

PSO-SVR model proposed can improve the estimation accuracy of solid soluble content of fresh peaches, which provide technical support for detecting other components of fresh peaches.

Keywords Solid content; Hyperspectral image; Deep feature; Support vector regression; Peach

(Received Aug. 12, 2020; accepted Jan. 9, 2021)

本 刊 声 明

近期以来,一些不法分子假冒《光谱学与光谱分析》期刊社名义,以虚假网站等形式欺骗广大作者、读者。这些虚假网站公然假冒《光谱学与光谱分析》期刊名义进行大肆的征稿并骗取作者的审稿费和版面费。经部分作者及读者举报,现有有关部门已就此介入调查。本刊将通过法律途径向假冒者追究相应的责任,维护本刊权利。

本刊官方网站已正式开通,网址为

<http://www.gpxygpx.com/>

在此郑重声明,本网址为《光谱学与光谱分析》期刊唯一开通运行的官方网站。本刊从未授权任何单位或个人以任何形式(包括网上网下)代理本刊征稿、审稿等项业务。

希望广大读者和作者切实维护好自身的合法权益,防止受骗上当。

《光谱学与光谱分析》期刊社

2019年3月15日