

基于机器学习的地标大米掺假鉴别模型研究

王靖会¹, 秦润蒙¹, 程娇娇¹, 王艳辉², 陈雷³, 王朝辉^{4*}

(1. 吉林农业大学信息技术学院, 长春 130118; 2. 吉林省长春市净月开发区福祉街道办事处, 长春 130122; 3. 吉林省长春市交警支队南关区大队, 长春 130000; 4. 吉林农业大学食品工程技术学院, 长春 130118)

摘要:为有效鉴别国家地理标志大米(以下简称地标大米)中是否被掺入了普通大米,本研究以大米中矿物元素含量和近红外光谱中级融合数据为基础,建立SVM、Adaboost以及Adaboost-SVM三种机器学习鉴别模型。研究表明:三种模型均有优异的鉴别能力。SVM模型在小比例(2%~6%)鉴别时更优于其他两种模型,准确率达100%。Adaboost模型在最优融合数据集选择方面更有优势。三种模型鉴别的最低检出比可达2%,准确率分别为100%、100%及97.75%。数据融合技术结合机器学习方法可以作为大米掺假精确鉴别的可靠工具,为维护大米市场的健康有序发展提供技术支持。

关键词:掺假; Adaboost模型; Adaboost-SVM模型; 数据融合方法; K折交叉验证; 混淆矩阵

中图分类号: F203; TS210.7

文献标识码: A

文章编号: 2096-5877(2021)02-0138-07

Identification Model of Adulterated Landmark Rice Based on Machine Learning

WANG Jinghui¹, QIN Runmeng¹, CHENG Jiaojiao¹, WANG Yanhui², CHEN Lei³, WANG Zhaohui^{4*}

(1. College of Information Technology, Jilin Agricultural University, Changchun 130118; 2. Fuzhi Sub-district Office, Jingyue Development Zone, Changchun 130122; 3. Changchun City Traffic Police Detachment, Nanguan District Brigade, Changchun 130000; 4. College of Food Engineering and Technology, Jilin Agricultural University, Changchun 130118, China)

Abstract: In order to effectively identify whether the National Geographic Indication rice (hereinafter referred to as the landmark rice) is mixed with ordinary rice, three machine learning identification models including SVM, AdaBoost and AdaBoost-SVM were established based on the intermediate fusion data of mineral element content and near infrared spectrum. The result shows that all the three models have excellent discriminating ability. The SVM model is better than the other two models in small proportion (2% - 6%) discrimination, and the accuracy of the 100%. Adaboost model is better than that of the other two models in the selection of optimal fusion data sets. The lowest detection rate of the three models can be up to 2%, and the accuracy of the three models is 100%, 100% and 97.75%, respectively. Data fusion technology combined with machine learning method can be used as a reliable tool for accurate identification of rice adulteration, and provide technical support for maintaining the healthy and orderly development of rice market.

Key words: Adulterated; Adaboost model; Adaboost-SVM model; Data fusion method; K-fold cross-validation; Confusion matrix

近年来,大米欺诈事件层出不穷^[1],不法商贩利用地标大米的商业和营养价值^[2]做文章,从中获取暴利^[3-4]。如2010年“五常大米掺假”事件^[5],使大米安全备受社会关注,尤其在地标大米掺假

方面更为突出。国内外学者使用单源技术手段,研究鉴别食品掺假的方法。Chen H等^[6]利用SVM结合近红外光谱技术对掺杂酒样品进行研究,模型准确率达94.9%。Lim D K等^[7]采用质谱靶向脂质组学技术建立RF、SVM、C5.0、神经网络和K临近模型对韩国白米掺假进行研究,RF和SVM模型准确率达100%。孙俊等^[8]利用高光谱技术建立SVM模型对东北大米掺假进行鉴别,准确率达98%。周晓旋^[9]采用近红外光谱技术建立大米的掺假比例

收稿日期: 2019-03-01

基金项目: 吉林省重点科技研发项目(20180201051NY)

作者简介: 王靖会(1974-),女,副教授,硕士,主要从事数据挖掘与人工智能研究。

通讯作者: 王朝辉,男,博士,副教授, E-mail: wzhlndsp@aliyun.com

PLS判别模型,预测集相关系数为0.984 5,均方根误差为6.46。现有研究显示,采用单源样本信息数据作为食品掺假的数据信息建立模型,可以鉴别食品掺假的问题。但食品自身信息具有很强的复杂性,单源技术不能够精准地描述食品自身信息,使鉴别结果不够准确,不利于食品掺假研究的进一步发展。

数据融合技术是将多源技术数据块整合到单个矩阵中,可以解决单源技术局限性的问题,提供关于样本更准确的信息并产生良好推断,可以成为获得更可靠结果的有力工具^[10]。随着大数据分析需求不断加大,机器学习方法能够针对数据所提供的全部信息有效地挖掘出具有价值的部分,从而使模型精度更高。Adaboost算法是根据分类器的分类性能赋予权重,构建分类器的加权组合模型,就是将训练的多个弱分类器组成一个强分类器以提高分类器的分类精度^[11],是一种集成学习方法。SVM算法是将样本空间经过非线性映射到高维的特征空间使其可进行线性划分,在特征空间中建立一个超平面作为最优的分类决策曲面,使两种类别样本能够最大化地远离彼此,即求最优分类超平面^[12-13]。Adaboost-SVM算法是在SVM算法基础上引入Adaboost算法,通过利用SVM分类器对弱分类器进行训练,然后不断更新弱分类器自身权重,经过多次迭代运算后,通过加权得到最终的强分类算法。

本研究旨在探讨矿物元素指纹技术和近红外光谱技术的数据融合技术在掺假鉴别方面的预测能力,采用SVM、Adaboost及Adaboost-SVM三种机器学习方法,利用PCA分析技术和RF算法进行特征提取和变量评估,为保护地标大米的真实可靠性提供一种新的有效技术手段。

1 材料与方 法

1.1 数据来源及制备

本研究以松原市前郭县地标大米和苏州市金庭镇普通大米作为研究对象。两地大米外表相似,肉眼难辨。为确保研究样本的真实性,采用空间分层采样法进行实地田间采样。采样区域及采样点分布如表1所示。

将40份地标大米样品和10份普通大米样品按1~40和1~10分别进行样品编号。利用Excel生成每组4个不同样品编号的随机序列将地标大米等质量混合作为1个代表性地标大米样本,共制备60个;将所有编号的普通大米等质量充分混

表1 大米样品采集点分布表

前郭县	数量	金庭镇	数量
东三家子乡	2	劳村	1
大德营子村	2	蛇头山	1
深井子镇	4	东蔡村	2
新立乡	16	元山村	2
平风乡	12	前堡村	2
八朗镇	4	谢家堡	2

合作为1个代表性普通大米样本。向制备的地标大米样本中按2%、4%、6%、8%、10%、12%、14%、16%、18%、20%、25%、30%比例掺入普通大米样本,每种比例包括60个样本。最终得到60个地标大米样本和12×60个掺假大米样本。

1.2 样品检测方法

本研究使用新丰牌JLGJ4.5 磨谷机与HNMJ3碾米机分别进行稻米去壳与糙米去糙作业,JXFM110锤式旋风磨进行大米样品的研磨作业。根据我国GB/T 35876-2018、GB 5009.91-2017、GB 5009.12-2017、GB 5009.15-2014食品检测标准,检测大米样品中钴(Co)、硒(Se)、锶(Sr)、钼(Mo)、镉(Cd)、铅(Pb)、铝(Al)、铜(Cu)、锌(Zn)、铁(Fe)、锰(Mn)、钙(Ca)、镁(Mg)13种矿物元素含量数据和近红外光谱数据。ICP-OES检测铝(Al)、铜(Cu)、锌(Zn)、铁(Fe)、锰(Mn)、钙(Ca)、镁(Mg)元素含量,其他元素含量采用ICP-MS检测^[14-18],MAP型傅里叶近红外光谱仪检测近红外光谱数据^[19-21]。

1.3 研究方法

机器学习方法可以从大数据所提供的全部信息中挖掘出最有利用价值的信息,使模型精度更高更准确。本研究采用SVM、Adaboost及Adaboost-SVM三种机器学习方法建立地标大米掺假的鉴别模型。

1.4 融合方法

数据融合技术用于将来自不同技术的样本信息聚结,以获得比单源实现更准确、更全面的描述,使预测准确度提高。为了找到能够鉴别地标大米和掺假大米样品数据的最佳组合,本研究采用融合发生在不同数据源提取的特征级别上的中级数据融合策略,将矿物元素指纹技术和近红外光谱技术检测到的描述性信息连接成单个矩阵,运用融合矩阵进行分析。

1.5 模型评估方法

建立分类模型时,将数据分成两个部分用于

评估模型的性能。一部分用于训练模型,另一部分用于测试模型,训练集数量与测试集数据量比例为2:1^[22-23]。

1.5.1 K折交叉验证

K折交叉验证技术能够解决过度适应的问题,被广泛应用于分类器性能评测领域^[24]。其思想是将原始数据集随机分为K份大小相近但不相交的数据集,将K-1份数据集作为训练集,剩余1份作为测试集,通过训练集得到一个分类模型,然后用测试集调整每个个体分类器的权重因子,基于训练集得到的分类模型就可以通过测试集来进行评估^[25]。将上述过程重复n次,将n次检验的正确率平均值作为模型分类的最终结果。

1.5.2 混淆矩阵

混淆矩阵是一种可视化算法性能评价标准,是通过矩阵反映样本数据真实类别属性和预测结果之间的关系^[26]。混淆矩阵由真正例(True Positive, TP)、假正例(False Positive, FP)、真反例(True Negative, TN)、假反例(False Negative, FN)四部分组成,总样本数为四者之和。分类模型的准确度、灵敏度和特异度三个性能指标的计算如公式(1)(2)(3)所示。本研究中混淆矩阵的设置如表2所示。

$$\text{准确率}(\%) = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \dots\dots\dots(1)$$

$$\text{灵敏度}(\%) = \frac{TP}{TP + FN} \times 100\% \dots\dots\dots(2)$$

$$\text{特异度}(\%) = \frac{TN}{FP + TN} \times 100\% \dots\dots\dots(3)$$

表2 地标大米和各比例掺假大米分类的混淆矩阵

分类	预测结果	
	地标大米	各比例掺假大米
地标大米	TP	FN
各比例掺假大米	FP	TN

2 结果与分析

本研究以R语言实现SVM、Adaboost、Adaboost-SVM的建模过程,分别建立地标大米与12种不同比例的掺假大米鉴别模型。

2.1 模型的建立

分别建立SVM、Adaboost、Adaboost-SVM三种模型。SVM模型选择线性核函数, Cost值默认为1; Adaboost模型Maxdepth=3、Mfinal=30; Adaboost-SVM模型参数值(除Maxdepth)同上两种模型。各

模型性能的测试结果见表3。三种模型的准确率都很低。Adaboost-SVM模型准确率高与其他模型,当鉴别比例为8%时,三种模型准确率最高,分别为70.52%、68.42%和71.46%。

表3 各模型不同比例的准确率结果

掺假比例	SVM	Adaboost	Adaboost-SVM
地标与2%	58.78%	60.00%	61.79%
地标与4%	34.69%	37.03%	40.00%
地标与6%	66.87%	65.21%	67.28%
地标与8%	70.52%	68.42%	71.46%
地标与10%	52.66%	47.05%	45.54%
地标与12%	40.38%	41.66%	43.77%
地标与14%	45.47%	44.00%	49.89%
地标与16%	58.67%	56.25%	60.52%
地标与18%	53.44%	52.38%	55.47%
地标与20%	42.58%	44.82%	50.29%
地标与25%	37.31%	36.36%	40.66%
地标与30%	50.69%	45.83%	49.87%

2.2 特征变量选择

采用主成分分析方法选择Savitzky-Golay光谱数据的主成分作为关键数据。对预处理下的近红外光谱数据进行主成分降维,得到3个主成分,且贡献率大于90%;分别用3个主成分PC1, PC2, PC3作为x, y, z建立三维分类图,选择分类效果最好的主成分数据。Savitzky-Golay预处理的三维分类图如图1所示,红色表示地标大米,蓝色表示所有比例掺假大米。对于元素数据的变量选择,首

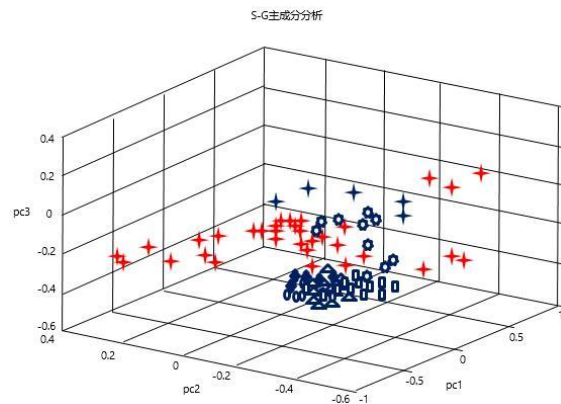


图1 S-G主成分分类

先利用RF算法中基于基尼指数观测值的重要排名机制评估变量重要性;按照变量重要性排名生成特征子集 $K=\{k_1, k_2, \dots, k_m\}$, m表示选择属性个数, k_m 表示全部属性子集, k_1 表示重要性度量最高的属性子集,以此类推,每个比例大米样本数据排名情况均有所不同。地标大米与2%掺假大米

表4 各比例各模型最优融合子集数据结果及性能比较

掺假比例	准确率(%)	特异度(%)	灵敏度(%)	参数与核函数	最优融合数据集	
地标 与 2%	SVM	100	100	100	Gamma=0.1 linear	Pb+Al+Cd+Co+Fe+PC1+PC2+PC3
	Adaboost	100	100	100	Maxdepth=2 Mfinal=30 Cost=100	Pb+Al+PC1+PC2+PC3
	Adaboost-SVM	97.75	100	100	Mfinal=10 linearl	Pb+Al+Cd+PC1+PC2+PC3
地标 与 4%	SVM	100	100	100	Cost=0.01 linear	Pb+Fe+Al+Co+PC1+PC2+PC3
	Adaboost	98.75	100	97.5	Maxdepth=2 Mfinal=10 Cost=0.01	Pb+Fe+PC1+PC2+PC3
	Adaboost-SVM	98.75	100	97.5	Mfinal=10 linear	Pb+Fe+Al+Co+Cd+PC1+PC2+PC3
地标 与 6%	SVM	100	100	100	Cost=0.1 linear	Pb+Al+Fe+Co+PC1+PC2+PC3
	Adaboost	100	100	100	Maxdepth=2 Mfinal=10 Cost=10	Pb+PC1+PC2+PC3
	Adaboost-SVM	100	100	100	Mfinal=10 linear	Pb+PC1+PC2+PC3
地标 与 8%	SVM	97.5	100	95	Cost=0.1 linear	Pb+Cd+Fe+Co+Al+Ca+PC1+PC2+PC3
	Adaboost	98.75	97.72	100	Maxdepth=2 Mfinal=10 Gamma=0.1	Pb+Cd+Fe+Co+Al+Ca+Sr+Mo+Mg+Cu+Zn+Se+ PC1+PC2+PC3
	Adaboost-SVM	97.5	97.25	97.5	Cost=1000 Mfinal=10 sigmoid	Pb+PC1+PC2+PC3
地标 与 10%	SVM	97.5	95.83	100	Cost=0.1 linear	Co+PC1+PC2+PC3
	Adaboost	97.5	95.83	100	Maxdepth=2 Mfinal=10 Cost=0.1	Co+PC1+PC2+PC3
	Adaboost-SVM	97.5	95.83	100	Mfinal=10 linear	Co+PC1+PC2+PC3
地标 与 12%	SVM	100	100	100	Cost=0.1 linear	Co+Fe+Al+Se+Zn+Mn+Cd+Sr+Cu+Pb+Mg+Mo+ PC1+PC2+PC3
	Adaboost	96.25	97.72	95	Maxdepth=2 Mfinal=10 Cost=0.1	Co+PC1+PC2+PC3
	Adaboost-SVM	96.25	97.25	95	Mfinal=10 linear	Co+PC1+PC2+PC3
地标 与 14%	SVM	97.5	97.72	95	Cost=0.1 linear	Se+Co+Cd+Cu+Fe+Zn+Mn+Sr+PC1+PC2+PC3

续表 4

		掺假比例	准确率(%)	特异度(%)	灵敏度(%)	参数与核函数	最优融合数据集
地标 与 14%	Adaboost	97.5	95.45	100	Maxdepth=2 Mfinal=10		Se+Co+Cd+Cu+Fe+PC1+PC2+PC3
	Adaboost-SVM	96.25	97.22	95	Cost=1 Mfinal=10 linear		Se+Co+Cd+Cu+Fe+Zn+Mn+PC1+PC2+PC3
	SVM	98.75	100	97.5	Gamma=0.1 Cost=0.001 polynomial		Fe+Cd+Co+Ca+PC1+PC2+PC3
地标 与 16%	Adaboost	97.5	97.5	97.5	Maxdepth=2 Mfinal=10		Fe+Cd+Co+Ca+Cu+PC1+PC2+PC3
	Adaboost-SVM	97.5	97.5	97.5	Gamma=0.1 Cost=0.001 Mfinal=10 polynomial		Fe+Cd+Co+Ca+Cu+PC1+PC2+PC3
	SVM	100	100	100	Gamma=0.01 Cost=0.001 polynomial		Fe+Al+Cd+Sr+Cu+PC1+PC2+PC3
地标 与 18%	Adaboost	96.25	97.5	95	Maxdepth=2 Mfinal=20		Fe+Al+Cd+PC1+PC2+PC3
	Adaboost-SVM	98.75	100	97.5	Cost=1 Mfinal=10 linear		Fe+Al+Cd+Sr+Cu+Zn+Ca+Mg+Mo+Se+Mn+Pb+ PC1+PC2+PC3
	SVM	87.5	82.29	100	Cost=0.001 Gamma=0.1 polynomial		Fe+Cd+Sr+Co+Ca+Cu+PC1+PC2+PC3
地标 与 20%	Adaboost	97.5	97.25	97.5	Maxdepth=2 Mfinal=10		Fe+Cd+Sr+Co+Ca+Cu+Zn+Mg+Mo+Al+Se+Mn+ PC1+PC2+PC3
	Adaboost-SVM	98.75	100	97.5	Cost=0.01 Mfinal=10 linear		Fe+Cd+Sr+Co+Ca+Cu+Zn+Mg+Mo+Al+Se+PC1+ PC2+PC3
	SVM	98.75	97.72	100	Gamma=0.01 Cost=0.001 polynomial		Mo+Cu+PC1+PC2+PC3
地标 与 25%	Adaboost	98.75	100	97.5	Maxdepth=2 Mfinal=10		Mo+Cu+Cd+Sr+PC1+PC2+PC3
	Adaboost-SVM	97.5	95.83	100	Gamma=0.01 Cost=1 Mfinal=10 radial		Mo+PC1+PC2+PC3
	SVM	100	100	100	Cost=10 linear		Cu+PC1+PC2+PC3
地标 与 30%	Adaboost	100	100	100	Maxdepth=2 Mfinal=10		Cu+Cd+Mg+Co+Mn+Sr+Se+Mo+Ca+Al+Zn+Fe+ Pb+PC1+PC2+PC3
	Adaboost-SVM	100	100	100	Cost=0.01 Mfinal=10 linear		Cu+Cd+Mg+Co+Mn+Sr+Se+PC1+PC2+PC3

的元素重要性从高到低的顺序为:Pb、Al、Cd、Co、Fe、Mg、Ca、Mn、Mo、Zn、Se、Sr、Cu。最后元素数据的每个子集用于与 Savitzky-Golay 光谱数据的主成分数据融合。在本研究中,大米样品确定了13个元素,所以鉴别每个比例时均有13个子集用于分析。

2.3 模型的优化与评估

三个模型的建立与优化均在相同的训练集中进行,而测试集从未参与任何模型的建立,因此基于测试集三个模型分类精度可以有效代表模型对未知样本的预测能力。

在4次4折交叉验证下,按照RF算法把变量子集的重要性排名和 Savitzky-Golay 光谱数据的主成分融合数据作为输入数据,优化SVM、Adaboost、Adaboost-SVM三个模型。针对每种比例的每个融合子集的每种鉴别模型都重新选择核函数及参数调优,最终选取最优融合数据子集。依次对SVM、Adaboost、Adaboost-SVM三个模型进行评估比较,得到模型结果变化及性能如表4所示。表4显示,在优化模型后,三种模型准确率均得到提升,且在所有比例下均有优异的表现。当鉴别比例为6%和30%时,三种模型准确率均达到100%。针对小比例(2%~6%)鉴别时,SVM模型鉴别结果更优秀,准确率均为100%,Adaboost、Adaboost-SVM模型准确率也达到97%以上。但在鉴别比例为20%时,SVM模型鉴别结果最低,准确率仅为87.5%,而Adaboost、Adaboost-SVM模型准确率分别为97.5%和98.75%。在最优融合数据集的选择上,Adaboost模型普遍优于SVM、Adaboost-SVM模型,可使用更少的变量进行鉴别。

3 讨论

本研究以大米中矿物元素含量和近红外光谱中级融合数据为基础,建立SVM、Adaboost以及Adaboost-SVM三种机器学习鉴别模型。建立的三种模型均有优异的鉴别能力。SVM模型在小比例(2%~6%)鉴别时更优于其他两种模型,准确率达100%。Adaboost模型在最优融合数据集选择方面更有优势。三种模型的鉴别最低检出比例可达2%,准确率分别为100%、100%及97.75%。综上所述,本研究利用大米中矿物元素含量和近红外光谱中级融合数据结合机器学习方法可以作为大米掺假精确鉴别的可靠工具,为维护大米市场健康有序发展提供技术支持。

参考文献:

- [1] 梁文文. 分析食品欺诈形势,寻求解决应对方案[J]. 食品安全导刊, 2018(21): 30-31.
- [2] 周广春,孟维韧,全东兴,等. 吉林省第八届优质食味水稻品种鉴评报告[J]. 东北农业科学, 2018, 43(6): 1-4.
- [3] 吴浩,靳保辉,陈波,等. 葡萄酒产地溯源技术研究进展[J]. 食品科学, 2014, 35(21): 306-314.
- [4] 姜佳丽,孙荣. 地理标志产品生产企业质量问题症结何在—五常大米造假引发的思考[J]. 才智, 2011(7): 249.
- [5] 胡立彪. 别让五常米变“五常米”[N]. 中国质量报, 2019-01-08(005).
- [6] Chen H, Tan C, Wu T, et al. Discrimination between authentic and adulterated liquors by near-infrared spectroscopy and ensemble classification [J]. Spectrochimica Acta, 2014, 130(15): 245-249.
- [7] Lim D K, Long N P, Mo C, et al. Combination of mass spectrometry-based targeted lipidomics and supervised machine learning algorithms in detecting adulterated admixtures of white rice[J]. Food Research International, 2017, 100(1): 814-821.
- [8] 孙俊,金夏明,毛罕平,等. 高光谱图像技术在掺假大米检测中的应用[J]. 农业工程学报, 2014, 30(21): 301-307.
- [9] 周晓璇. 基于近红外光谱技术的大米掺伪定量判别研究[D]. 合肥:安徽农业大学, 2016.
- [10] Drake J M, Randin C, Guisan A. Modelling ecological niches with support vector machines[J]. Journal of Applied Ecology, 2006, 43(3): 424-432.
- [11] RTSCH G. Soft margins for Ada Boost[J]. Machine Learning, 2001, 42(3): 287-320.
- [12] 李航. 统计学习方法[M]. 北京:清华大学出版社, 2012: 95-123.
- [13] 王献锋,王震,王旭启,等. 基于SVM和形态学的作物病斑图像分割方法[J]. 吉林农业科学, 2015, 40(1): 51-53, 60.
- [14] 何凤芹,张定煌,林庆昶,等. 微波消解-ICP-MS法测定大米中10种重金属的方法[J]. 安徽化工, 2017, 43(5): 121-123.
- [15] 伍燕湘,周明慧,张洁琼,等. 稀酸提取-ICP-MS法快速测定大米中锰、铜、锌、铅、镉、铷、铯的含量[J]. 中国粮油学报, 2019, 34(2): 112-117.
- [16] 叶润,刘芳竹,刘剑,等. 微波消解-电感耦合等离子体发射光谱法测定大米中铜、锰、铁、锌、钙、镁、钾、钠8种元素[J]. 食品科学, 2014, 35(6): 117-120.
- [17] 丁宝君,赖亚辉,卢钢. ICP-OES法测定吉林省部分地区大米中常量元素和微量元素的含量[J]. 北华大学学报(自然科学版), 2009, 10(6): 539-541.
- [18] 王小平,李柏. ICP-OES和ICP-MS测定中日两国大米中27种矿质元素含量[J]. 光谱学与光谱分析, 2010, 30(8): 2260-2264.
- [19] 李跑,吴红艳,李尚科,等. 近红外光谱技术结合化学计量方法用于大米的快速分析[J]. 食品研究与开发, 2018, 39(19): 117-124.
- [20] 蔡鑫茹,刘广新,焦仁海. 近红外光谱仪测定玉米子粒淀粉

- 含量的研究[J]. 吉林农业科学, 2006, 31(6): 10-11.
- [21] 任广跃, 李秀娟, 尹君, 等. 稻米品质检测技术研究进展及展望[J]. 中国粮油学报, 2014, 29(2): 115-120, 128.
- [22] Sheu S J, Hwang W Z, Chiang Y C, et al. Use of tuf gene-based primers for the PCR detection of probiotic bifidobacterium species and enumeration of bifidobacteria in fermented milk by cultural and quantitative real-time PCR methods[J]. Journal of Food Science, 2010, 75(8): M521-528.
- [23] 刘宇佳, 贺丽苹, 张泳, 等. 近红外光谱-人工神经网络的模型优化用于银耳产地识别研究[J]. 食品工业科技, 2016, 37(3): 303-306, 311.
- [24] 丘祐玮. 机器学习与R语言实战[M]. 北京: 机械工业出版社, 2016: 173-174.
- [25] 胡局新, 张功杰. 基于K折交叉验证的选择性集成分类算法[J]. 科技通报, 2013, 29(12): 115-117.
- [26] 魏益民, 郭波莉, 魏帅, 等. 食品产地溯源及确证技术研

(上接第46页)

4 结 论

生物炭显著提升壤土水溶性钾离子、速效钾离子、交换性钾离子含量, 且土壤水溶性钾离子、速效钾离子、交换性钾离子均与生物炭添加量之间呈指数相关关系。综合考虑土壤酸碱度、土壤钾素和经济因素, 推荐在杨凌壤土中提前30天施入50 t/hm²生物炭。

参考文献:

- [1] Cakmak I. Potassium for better crop production and quality[J]. Plant and Soil, 2010, 335(1-2): 1-2.
- [2] 李德忠, 吕岩, 朱明志, 等. 钾肥运筹对春玉米农学效应和钾素利用的研究[J]. 吉林农业科学, 2013, 38(4): 25-27.
- [3] 尹彩侠, 侯云鹏, 秦裕波, 等. 吉林省不同类型土壤玉米施用钾肥效应研究[J]. 吉林农业科学, 2010, 35(5): 22-24.
- [4] Xu X, He P, Pampolino M F, et al. Fertilizer recommendation for maize in China based on yield response and agronomic efficiency[J]. Field Crops Research, 2014, 157: 27-34.
- [5] Yang G, Tang H, Nie Y, et al. Responses of cotton growth, yield, and biomass to nitrogen split application ratio[J]. European Journal of Agronomy, 2011, 35(3): 164-170.
- [6] 王忠江, 张正, 刘卓, 等. 生物炭配施沼液对淋溶状态下土壤养分的影响[J]. 农业机械学报, 2018, 49(11): 260-267.
- [7] Wilhelm W W, Doran J W, Power J F. Corn and soybean yield response to crop residue management under no-tillage production systems[J]. Agronomy Journal, 1986, 78(1): 184-189.
- [8] Angst T E, Sohi S P. Establishing release dynamics for plant nutrients from biochar[J]. Global Change Biology Bioenergy, 2013, 5(2): 221-226.
- [9] 谢祖彬, 刘琦, 许燕萍, 等. 生物炭研究进展及其研究方向[J]. 土壤, 2011, 43(6): 857-861.
- [10] 郭大勇, 郭凯丽, 王旭刚, 等. 基于Web of Science和CNKI的生物炭研究文献计量分析[J]. 东北农业科学, 2017, 42(4): 49-54.
- [11] Sarikhani M R, Khoshru B, Oustan S. Efficiency of Some Bacterial Strains in Potassium Release from Mica and Phosphate Solubilization under In Vitro Conditions[J]. Geomicrobiology Journal, 2016, 33(9): 1-7.
- [12] Kuzyakov Y, Subbotina I, Chen H, et al. Black carbon decomposition and incorporation into soil microbial biomass estimated by ¹⁴C labeling[J]. Soil Biology and Biochemistry, 2009, 41(2): 210-219.
- [13] 秦巧燕, 贾陈忠, 曲东, 等. 我国设施农业发展现状及施肥特点[J]. 湖北农学院学报, 2002, 22(4): 373-376.
- [14] 李俊, 李建明, 胡晓辉, 等. 亚低温及钾肥对温室番茄光合作用和品质的影响[J]. 西北植物学报, 2012, 32(12): 2471-2478.
- [15] 曹雪娜. 生物炭对设施土壤养分及作物生长的影响初探[D]. 沈阳: 沈阳农业大学, 2017.
- [16] 李明, 李忠佩, 刘明, 等. 不同秸秆生物炭对红壤性水稻土养分及微生物群落结构的影响[J]. 中国农业科学, 2015, 48(7): 1361-1369.
- [17] 聂新星, 李志国, 张润花, 等. 生物炭及其与化肥配施对灰潮土土壤理化性质、微生物数量和冬小麦产量的影响[J]. 中国农学通报, 2016, 32(9): 27-32.

(责任编辑: 刘洪霞)