

叶片含水率推扫式高光谱成像去条纹标定法优化

赵茂程¹ 陈加新¹ 邢晓阳¹ 汪希伟¹ 顾越¹ 李忠²

(1. 南京林业大学机械电子工程学院, 南京 210037;
2. 南京林业大学机电产品包装生物材料国家地方联合工程研究中心, 南京 210037)

摘要: 由推扫式高光谱成像系统所采集的图像中会出现特有的条纹噪声,这些噪声会穿过化学计量学模型,最终出现在反映被测指标空间分布情况的可视化预测图中,干扰其空间特征的呈现及解读。以银杏叶含水率为例,基于偏最小二乘回归(PLSR)预测模型,将经去条纹标定法处理后的图像分别与原始图像及经传统均值滤波增强后的图像进行比较,研究去条纹标定法对化学计量学指标空间分布预测的改进作用。去条纹标定法和传统均值滤波增强不会对感兴趣区域均值 PLSR 预测模型决定系数 R_p^2 产生明显影响,其随主成分数增加,呈先增后减趋势,当主成分数为 10 时 R_p^2 均达到最大,且预测准度相当。将化学计量学模型应用到像素光谱,进行指标空间分布预测时,随主成分数由 6 增至 10,模型的波段增益系数逐渐增大,导致化学计量学可视化图像中条纹噪声逐渐增加;在由原始图像或经传统均值滤波增强图像得到的含水率可视化图像中,条纹噪声逐渐增加,甚至完全湮没叶面内部含水率空间分布信息;而去条纹标定法能够明显抑制本征条纹噪声,即使当主成分数增加到 8 时(R_p^2 为 0.88),含水率可视化图像仍然几乎不见条纹干扰,在叶面空间分布的细节特征依旧清晰可辨,显著提升对含水率空间分布的预测效果。比较研究表明,去条纹标定法明显抑制推扫式高光谱成像系统本征条纹噪声,能够提高靶向指标空间分布的可视化精度;在保留空间细节免受条纹干扰的情况下,得以采用波段增益系数更大的预测模型,从而提高指标空间分布的可视化预测准度。

关键词: 银杏叶; 含水率; 可视化; 去条纹标定法; 推扫式高光谱成像

中图分类号: TP391.41; O657.3 **文献标识码:** A **文章编号:** 1000-1298(2022)02-0212-09

OSID:



Method of De-stripe Calibration Applied in Water Content Spatial Visualization in Ginkgo Leaf on Spectral Imagery

ZHAO Maocheng¹ CHEN Jiaxin¹ XING Xiaoyang¹ WANG Xiwei¹ GU Yue¹ LI Zhong²

(1. College of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China
2. National-provincial Joint Engineering Research Center of Electromechanical Product Packaging with Biomaterials, Nanjing Forestry University, Nanjing 210037, China)

Abstract: A distinctive spatial noise pattern in the form of parallel stripes exists commonly in the images that are acquired using pushbroom hyperspectral imaging systems. Passing through chemometric systems, it often resurfaces in resultant images of the spatial distributions of various chemical or quality indices, blocking or breaking the spatial details therein, and undermining consequent interpretation. In regard of this, an image de-stripping calibration was investigated for its contribution to improving spatial chemometric predictions. The de-stripe calibration was first applied to the hyperspectral images of 155 ginkgo leaves before mapping the spatial distribution of water content (WC) using partial least squares regression-chemometric models. In comparison, the process was repeated twice, respectively, from either raw hyperspectral image without de-stripe calibration or those through a conventional image-enhancement of spatial smoothing-filtering. Results showed that neither the de-stripe calibration nor the conventional image enhancement would affect the accuracy of chemometric models, and that the coefficient of determination of prediction, or R_p^2 , irrespective of different preprocessing in all three cases, were risen up with the increase of number of principal components (PCs), until peaking at the number of 10 PCs ($R_p^2 =$

0.93 ~ 0.94)。However, difference emerged when applying chemometric models to the spectra at individual pixels to map the spatial distribution of WC over leaf-surface. As the number of PCs was increased from 6 to 10, so did the spectral gains of chemometric models causing strengthening stripy noise in the WC maps from either the un-treated or conventionally smooth-filtered images, with noise-stripes being the most prominent spatial feature at 8 PCs, and even deteriorating to the point, at 9 or 10 PCs, that any possible WC variation over a leaf would be totally blocked up. To the contrary, the de-stripe calibration successfully suppressed the distinctive noise patterns inherent from the pushbroom hyperspectral imaging system, so that no discernible stripes appeared in the WC maps from the de-striped hyperspectral images and stunning spatial details were preserved in the maps derived from the relatively high accuracy chemometric model of 8 PCs ($R_p^2 = 0.88$). It may be safely concluded from this comparative study that de-stripe calibration of pushbroom hyperspectral images did contribute rich spatial details and high accuracy to spatial chemometric predictions through keeping spatial details intact while enabling the application of models with high spectral gains.

Key words: ginkgo leaf; water content; visualization; de-stripe calibration; push-broom hyperspectral imaging

0 引言

近年来,高光谱成像技术由于其快速、无损的特点,被广泛地应用于农林产品质量安全检测工作中^[1-7],其中推扫式高光谱成像(Pushbroom hyperspectral imaging, P-B HSI)因在空间和光谱方面都具有很好的分辨率而备受关注^[8-10]。

高光谱图像中的每个像素点都包含特定位置的光谱信息,它可以实现被测样本组分含量分布的可视化^[11],以便实现品质在线检测^[12]。但是这些可视化图像中常出现多条贯穿整个样本区域的纵向条纹,例如文献[13]建立的猪肉腌制过程中水分变化的空间分布图像;文献[14]建立的三文鱼脂肪含量分布图像;文献[15]建立的变质牛肉掺假物在鲜肉糜中分布的可视化图像。这种条纹还会出现在图像处理工作中,如文献[16]将玉米根茬从裸露地表背景中分离。这些条纹并非样本自身的纹理,而是图像中的条纹噪声,其影响检测精度,干扰可视化图像中靶标物的判断,阻碍图像中靶标物与背景的分

离。目前,对于推扫式高光谱成像条纹噪声问题的研究主要是针对卫星遥感上的高光谱图像,处理方法包括数字滤波法^[17]、增益估计法^[18]、匹配法^[19]、变分法^[20]、图像分解法^[21]等,这些方法对图像中条纹噪声有一定的抑制效果,但是会改变相邻没有条纹噪声区域的像素值,容易损失原始图像中的真实信息,降低空间分布预测图像的可信度。而对于室内高光谱成像系统应用,可以对系统条纹噪声进行标定,通过使用专用的去条纹校正,更好地解决条纹噪声问题。而目前推扫式高光谱成像固有的条纹噪声对生物对象品质指标空间分布预测的影响及消除方法尚无专门研究报道。

我国是世界最大的银杏叶生产国和出口国,由银杏叶提取物制成的各类食品、保健品、药品等已超过了 100 种,市场每年对银杏叶有数以万吨的需求量^[22]。银杏叶的含水率可以用于监测银杏树苗对水分的需求情况,且在收购时有助于准确预估干叶质量。更重要的是,对化学计量学可视化图像中条纹噪声分析的关键是能够将其与样本纹理相区别,以验证其对细节部分的影响,而含水率对叶片表面的伤痕非常敏感,在可视化图像中可以呈现伤痕的空间细节。因此,本文以银杏叶含水率为例,基于化学计量学进行指标空间分布预测,利用标定法去除推扫式高光谱成像中的条纹噪声,以改善含水率预测的可视化效果。

1 材料与方法

1.1 实验材料

1.1.1 实验样本

银杏叶样本采自江苏省徐州市邳州市四户镇银杏种植基地,于 2020 年 8 月 12 日采摘银杏叶若干片,当天通过保温箱带回实验室,并置于冰箱 -18℃ 环境下保存。在第 5 ~ 15 天,每天 22:00 从冰箱中取出无破损的银杏叶 15 片,以吸水纸包裹,放置于室温(20℃)解冻 9 h,在第 2 天 07:00 将叶片表面水擦干,然后先采集银杏叶鲜叶质量,再采集高光谱图像,最后干燥后采集银杏叶干叶质量,计算含水率。

1.1.2 高光谱成像系统

高光谱成像检测平台包含高光谱成像系统、一条白色食品级传送带(HSIA-CSD800 型)、一套由 12 只 50 W 的卤素灯与一个穹顶构成的漫反射照明系统,以及一台计算机。高光谱成像系统为四川双利合谱成像技术有限公司生产的 GaiaField-N17E-

N3 型系统,主要包括成像光谱仪(Inspector N7E 型,900~1 700 nm)、探测器(InGaAs 型相机)、镜头(OLES22 型)。其中成像光谱仪光谱分辨率为 5 nm,被测样品置于传送带上的载物台上,由步进电机驱动,整个检测过程置于暗室中,以屏蔽其他杂散光对数据采集的影响。

1.2 实验方法

1.2.1 含水率测定

采用干燥法对银杏叶含水率进行测定。先用 JA003 型电子天平(上海浦春计量仪器有限公司)称量鲜叶质量,然后将叶片放入牛皮信封中,将其置于 DHG-9246A 型电热恒温鼓风干燥箱(上海精宏实验设备有限公司)中,于 80℃ 条件下干燥 2 h,使水分完全蒸发,再称量干叶质量。银杏叶含水率计算方法为

$$\omega = \frac{M_f - M_d}{M_f} \times 100\% \tag{1}$$

式中 M_f ——鲜叶质量,g
 M_d ——干叶质量,g

1.2.2 高光谱图像采集

高光谱图像数据由计算机中 Specview 软件获取,将高光谱相机与照明系统预热 30 min 后进行银杏叶图像数据采集。为了避免采集的图像失真,检测平台经过多次调整以获取最佳数据采集参数:成像光谱仪的曝光物距为 430 mm,曝光时间为 6 ms,传送带移动速度为 2.8 cm/s,扫描距离为 200 mm,图像分辨率为 640 像素×580 像素。

1.2.3 图像预处理

(1)反射率校正

由于高光谱相机在图像采集过程中存在暗电流影响,且光源系统照明通常不均匀,从而导致采集的图像中有大量噪声,因此需要对采集的图像进行反射率校正,以消除暗电流及光源不均匀的影响^[23]。校正方法为

$$R = \frac{R_o - R_b}{R_w - R_b} \times 100\% \tag{2}$$

式中 R ——高光谱图像反射率
 R_o ——原始高光谱图像反射率
 R_b ——黑色背景高光谱图像反射率
 R_w ——白板高光谱图像反射率

(2)传统均值滤波图像增强

平滑空间滤波一般通过模糊处理达到降低图像噪声的效果,传统均值滤波是其中的线性空间滤波^[24],它可以对图像中每个像素点进行处理。传统均值滤波主要是将图像中每个像素点的值用滤波器模板内像素的平均值代替,从而抑制噪声的影响,本

文采用圆形均值滤波模板,当半径为 3 像素时,条纹噪声被有效消除。

虽然传统均值滤波可以削弱条纹噪声的影响,并且算法简单,计算效率高,但是它使图像变得模糊,图像中的细节被严重削弱,真实信息丢失。

1.2.4 去条纹标定法

去条纹标定法同样也是対图像中每个像素点进行校正处理。首先将整个高光谱采集系统进行标定,计算出每个像素点在不同亮度下的误差,然后在采集新图像时,对每个像素点进行校正。校正方法为

$$I_{out}(w,r,c) = I_{in}(w,r,c) - g_c^w(I_{in}(w,r,c))$$

 $(w = 1, 2, \cdots, w_{max}; r = 1, 2, \cdots, r_{max}; c = 1, 2, \cdots, c_{max})$ (3)

式中 $I_{out}(w,r,c)$ ——经去条纹标定法处理后高光谱图像立方体中第 w 波段、第 r 行、第 c 列灰度

$I_{in}(w,r,c)$ ——原始高光谱图像立方体中第 w 波段、第 r 行、第 c 列灰度

$g_c^w(I_{in}(w,r,c))$ ——原始高光谱图像立方体中第 w 波段、第 r 行、第 c 列灰度偏差

去条纹标定法可以有效消除高光谱图像中的条纹噪声,并且不会影响图像中的细节,使真实信息保存良好。

1.2.5 建模与评价

(1)偏最小二乘回归法(PLSR)预测模型

偏最小二乘回归法^[25]主要用于多因变量对多自变量之间关系建立的模型,是一种广泛应用于光谱分析的多元回归方法。这种方法将因变量和自变量数据矩阵同时进行分解,在自变量分解过程中引入因变量,以建立图像数据中自变量主成分与样本中被测组分含量之间的关系。PLSR 本质上是一个线性预测模型,公式为

$$Y = \beta_0 + \sum_{w=1}^n \beta_w X_w \tag{4}$$

式中 Y ——模型预测值
 β_0 ——增益常数
 X_w ——第 w 波段图像
 β_w ——第 w 波段图像的增益系数
 n ——模型所用波段的数量

PLSR 模型中, β_w 越大,其对预测结果的贡献越高,相应波段高光谱图像的放大倍率也越高。然而,此时图像中蕴含的条纹噪声也将被放大。各 PLSR 模型的波段增益系数在本文中用于对指标分布预测结果图中条纹强度变化趋势的分析。

(2)模型评价

为了得到最佳性能的模型,采用交叉验证法 (Cross validation, CV) 确定最优主成分数。通过取得最小交叉验证均方根误差 (Root mean square error of cross validation, RMSECV) 获得最佳潜变量数。并采用决定系数 R^2 以及均方根误差 (Root mean square error, RMSE) 来验证模型的效果,通常来说, R^2 越大 (最大值为 1), RMSE (最小值为 0) 相对于实测值越小,模型效果越好。

1.2.6 含水率可视化

高光谱成像能够通过预测模型对样本高光谱图像中每个像素的含水率进行预测,从而得到被测组分含量的空间分布图像。分布图像的准确性受预测模型性能以及图像噪声的影响,预测模型性能可通过调整模型参数来改善;而对于图像噪声,部分可以通过反射率校正消除,而另一部分影响较为明显的条纹噪声,可通过去条纹校正削弱甚至消除,以获得最佳叶片含水率分布图。

2 结果与分析

2.1 银杏叶含水率及其分析

2.1.1 银杏叶光谱曲线提取

由于称量时按单片叶子称量,且每幅高光谱图像中只包含一片叶子,因此将图像中叶片的表面作为感兴趣区域。在 1 191 nm 处,每幅图像反射率阈值设置为 0.2,然后经过向内腐蚀 3 个像素,再向外膨胀 3 个像素,可有效提取银杏叶图像感兴趣区域的光谱信息。又因为采集的高光谱图像在 874.0 ~ 1 045.1 nm 和 1 556.5 ~ 1 731.0 nm 范围内噪声干扰很大,因此删除这两个光谱波段。当用去条纹标定法校正后建立银杏叶含水率分布图像时,图像在 1 179.2 nm 和 1 523.0 nm 处存在坏点,使分布图像中存在两条明显的深色纵向条纹,因此将这两个波长也删除。最终选择的有效光谱波段为 1 046.7 ~ 1 177.5 nm、1 180.9 ~ 1 504.6 nm 和 1 507.9 ~ 1 554.9 nm,光谱曲线如图 1 所示。




图 1 银杏叶原始反射率光谱曲线

Fig. 1 Original reflection spectrum curves of ginkgo leaves

从图 1 中可以看出,光谱曲线在 1 200 nm 左右存在微弱的吸收峰,在 1 400 nm 左右存在明显的吸收峰。在 1 200 nm 处为 C—H 的伸缩振动的二级倍频信息,是纤维素的吸收谷^[26];在 1 400 nm 附近为 O—H 的伸缩振动的一级倍频信息,此处主要为水分的吸收谷^[27]。

2.1.2 银杏叶含水率统计

本实验共采集 165 个样本,剔除异常数据的样本,最终剩余 155 个样本。根据含水率排序,以留出法将 117 个样本划分为训练集,38 个样本划分为预测集。如表 1 所示,训练集与预测集的平均值和标准差相近,说明样本集分布均匀,且总样本含水率在 56.86% ~ 73.22% 之间,样本之间有明显的差异性,有利于全波段的 PLSR 建模。

表 1 155 份银杏叶样本含水率
Tab.1 Moisture content of 155 ginkgo leaves

	数量	最小值/%	最大值/%	平均值/%	标准差/%
训练集	117	56.86	73.22	67.10	3.01
预测集	38	60.87	72.02	67.17	2.71
总样本	155	56.86	73.22	67.12	2.93

2.2 去条纹标定法及传统均值滤波增强处理

首先将原始高光谱图像进行反射率校正,得到原始反射率图像。然后将原始高光谱图像进行传统均值滤波增强,均值滤波采用圆形滤波器。当半径为 3 个像素时,条纹被有效削弱,再对增强后的图像使用反射率校正,得到经传统均值滤波增强后反射率图像。最后使用去条纹标定法对原始高光谱图像进行处理,并进行反射率校正,得到经去条纹标定法处理后的反射率图像。

为体现去条纹标定法的去条纹效果,选择叶片表面存在折痕、信息比较丰富的 146 号样本进行分析,分别选取该样本在 1 045.1 nm 处的原始反射率高光谱图像、经传统均值滤波增强反射率高光谱图像和经去条纹标定法处理的反射率高光谱图像,并将它们的叶片区域置于同一黑色背景中,最后将图像的色带刻度值范围设置为 25% ~ 40%,结果如图 2 所示。其中,图 2a 叶片区域存在明显的亮暗交替的纵向条纹,这些条纹穿插于银杏叶叶脉之间,将叶脉打断;图 2b 中,经过传统均值滤波图像增强后,银杏叶的反射率图像变得模糊,叶脉无法看清,条纹噪声虽然被削弱,但是依然存在,且被加粗;图 2c 中,经过去条纹标定法处理后,银杏叶表面无明显条纹,叶脉清晰,去条纹噪声效果明显。比较发现,推扫式高光谱图像的条纹噪声呈现纵向分布、亮暗交替;传统均值滤波增强将每个像素点的灰度以其周

围像素点的平均灰度代替,虽然削弱了条纹噪声的强度,但是会让条纹噪声变粗,使图像质量降低,原始信息丢失;去条纹标定法是对每个像素点的偏差进行增减,相邻像素点之间不会产生影响,可以很好地抑制条纹噪声,并保证图像质量,保留图像原始信息。




图 2 银杏叶反射率高光谱图像(1 045.1 nm)
Fig.2 Hyperspectral reflectance images of ginkgo leaf at 1 045.1 nm

2.3 偏最小二乘法预测建模

分别对经过传统均值滤波增强、去条纹标定法处理的高光谱反射率图像,和未经处理的原始高光 谱反射率图像计算每个波段的反射率均值,得到 3 种光谱数据,分别对它们进行 PLSR 建模,建模准度 如图 3 所示。从中可以看出,训练集决定系数 R_c^2 随 主成分数从 1 增加到 20 呈上升趋势,3 种光谱数据 的 R_c^2 从 0.63 逐渐接近 1。而预测集决定系数 R_p^2 呈先增后减趋势,随主成分数由 1 增加到 10, R_p^2 从 0.48 增大至 0.93;当主成分为 10 时,3 种光谱数据 PLSR 模型 R_p^2 都达到最大,此时它们的 R_c^2 在 0.92 ~ 0.93 之间,训练集均方根误差在 0.83% ~ 0.85% 之间, R_p^2 在 0.93 ~ 0.94 之间,预测集均方根 误差在 0.66% ~ 0.68% 之间;当主成分数大于 10 后, R_p^2 开始下降,模型过拟合。结果表明,经去条纹 标定法处理的图像与原始图像、经传统均值滤波增 强的图像所建立的模型准度相当,去条纹标定法不 能改善化学计量学建模准度。




图 3 化学计量学模型的预测能力
Fig.3 Predictive accuracy of chemometric models

2.4 银杏叶含水率可视化

2.4.1 含水率可视化图像建立

从图 3 中可以看出,主成分数小于 6 时 R_p^2 过

小,模型预测准度很低;在过拟合前即主成分数不大 于 10 时,随着主成分数增加, R_p^2 逐渐增大;因此选 择主成分数分别为 6、7、8、9 和 10,分别对原始反 射率图像、经传统均值滤波增强后反射率图像和经 去条纹标定法校正后反射率图像的光谱数据进行建 模。根据模型计算出相应高光谱图像中每个像素对 应的含水率,得到银杏叶含水率分布图。再将图像 可视化,色带刻度值范围设置为 45% ~ 78%,如图 4 所示。颜色越红,含水率越高;颜色越蓝,含水率 越低。

在图 4 中,每幅叶片图像大部分区域偏于红色, 而右上角区域和叶柄区域都呈现绿色甚至蓝色,说 明这两个区域含水率低于其他区域。对比银杏叶原 始样本,鲜叶中右上角区域泛黄,呈枯萎状态,这主 要是因细胞内水分流失而导致含水率降低;鲜叶中 叶柄区域由于趋于木质化,因此叶柄区域的含水率 也相对较低。每幅叶片图像右下角细节放大图是由 相应叶片图像上白色方框区域放大两倍得到,从 图 4a ~ 4c、图 4f ~ 4h 以及图 4k ~ 4n 中可以看到该 区域有一条向右下倾斜的“疤痕”,它的颜色比周围 偏绿,即含水率比周围低,对比银杏叶原始样本,该 区域上存在一条折痕,折痕处的细胞壁被损坏,导致 细胞内的水分流失,从而使折痕处含水率比周围含 水率低。结果表明含水率可视化图像可以体现样本 细节,反映样本的真实信息。

2.4.2 主成分数对可视化图像的影响

图 4a ~ 4e 为原始图像银杏叶含水率可视化图 像随主成分数变化的情况。从中可以看出,当主成 分数为 6 时,条纹噪声最小,图像中细节清晰,图像 可信度最佳;主成分数大于 6 后,条纹噪声越来越 严重,叶脉信息逐渐丢失,枯萎区域逐渐减小,“疤 痕”渐渐消失,图像可信度逐渐降低;主成分数为 10 时, 叶柄区域含水率分布情况与叶片区域一致,与实 际情况不符,图像可信度极差。

图 4f ~ 4j 为经传统均值滤波增强图像建立的 银杏叶含水率可视化图像随主成分数变化的情况。 从中可以看出,主成分数为 6 时,条纹噪声很小,除 了因传统均值滤波增强的特性导致叶脉无法显示 外,其他细节略微模糊,图像可信度较好;主成分数 大于 6 后,条纹噪声逐渐增大,“疤痕”渐渐消失,图 像可信度降低;主成分数为 10 时,叶柄区域含水率 分布情况与叶片区域一致,与实际情况不符,图像可 信度极差。

图 4k ~ 4o 为经去条纹标定法处理的图像建立 的银杏叶含水率可视化图像随主成分数变化的情 况。从中可以看出,主成分数分别为 6、7 和 8 时,没




图 4 不同处理方法的银杏叶含水率可视化图像

Fig. 4 Visualization images of water content of ginkgo leaf with different preprocessing methods

有明显的条纹噪声干扰,图像中细节部分都被保留,图像可信度都很好;当主成分数为 9 时,出现微弱的粗状纵向条纹,细节被削弱,图像可信度变差;当主成分数为 10 时,粗壮条纹明显,“疤痕”消失,叶柄区域含水率分布同样与叶片区域一致,与实际情况不符,图像可信度变得极差。

总之,随着主成分数的增加,化学计量学模型增益系数成倍增大,导致原始图像、经传统均值滤波增强图像以及经去条纹标定法校正的图像建立的含水率可视化图像中,条纹噪声和其他噪声逐渐增大,图像质量逐渐降低;而从图 3 中看到,随着主成分数从 6 增加至 10 的过程中,3 种图像的化学计量学模型预测能力逐渐提升,当主成分数为 10 时,达到最高,这与相应的可视化结果相悖。这表明受到推扫式光谱成像本征条纹噪声缺陷的影响,高准度化学计量学模型求得的像素光谱对指标的空间分布预测可信度不高,从而使其应用受到很大限制。

2.4.3 去条纹标定法与均值滤波增强法比较

从以上分析可知,原始图像在主成分数为 6 时建立的含水率可视化图像可信度最好,条纹噪声较

弱,此时预测模型 R_p^2 为 0.75,预测集均方根误差为 1.34%;经传统均值滤波增强后图像也是在主成分数为 6 时建立的含水率可视化图像可信度最好,条纹噪声被显著削弱,但是图像表面被模糊化,叶脉纹理丢失,此时预测模型 R_p^2 为 0.76,预测集均方根误差为 1.31%。

经去条纹标定法校正的图像在主成分数分别为 6、7 和 8 时建立的含水率可视化图像可信度都很好,条纹噪声被充分抑制;当主成分数为 8 时,预测模型 R_p^2 为 0.88,预测集均方根误差为 0.92%,预测准度最高。由此可以看出,反射率校正不会削弱条纹噪声,传统均值滤波增强因为将原始图像中的灰度用周围灰度的均值代替,在将异常灰度进行纠正、部分削弱条纹噪声影响的同时,弱化了图像中的部分细节。去条纹标定法是对每个像素的偏差进行纠正,这些偏差依据标准值得到,仅抑制条纹噪声,不会削弱图像中的细节,因此这种方法可以在保证含水率可视化图像可信度最佳的情况下,模型准度更好。综上所述,推扫式光谱成像经去条纹标定法处理,能够明显抑制本征条纹噪声,从而得以应用更高

准度的化学计量学模型,得到更加可信的靶向指标可视化图像。

2.4.4 条纹噪声强度影响因素

图4中,随着主成分数的增加,3种处理方法构建的含水率可视化图像中条纹噪声强度逐渐增加。

进一步对随主成分数从6增至10时3种预处理方法下建立的PLSR模型的波段增益系数进行分析,分别计算每个模型的波段增益系数的标准差、最大值和最小值。如图5所示,3条曲线上的点分别表示每个模型的波段增益系数的标准差,在每个主成分数处,工型图的下方表示增益系数最小值,上方表示最大值;蓝色线条、绿色线条、红色线条分别为原始图像、传统均值滤波增强图像、去条纹标定图像的增益系数。图中两条红色水平参考线表示波段增益系数分别为1和-1:当某波段的化学计量学模型增益系数介于两者之间时,即绝对值小于1时,对该波段图像中的数值及噪声起缩小作用,否则起放大作用。从图中可以看到,3种PLSR模型的波段增益系数的标准差、最大值和最小值变化趋势相似,它们的绝对值都随主成分数的增加而增大;当主成分数为6和7时,增益系数的绝对值都小于1,图像中的数值被缩小,条纹噪声被抑制;当主成分数为8时,增益系数标准差和最小值的绝对值仍然小于1,最大值略大于1,大多数波段图像中的数值仍被缩小,条纹噪声相对主成分数为7时略有增加;当主成分数为9时,增益系数标准差小于1,最大值和最小值的绝对值都大于1,更多波段的图像数值被放大,条纹噪声被放大;当主成分数为10时,增益系数标准差、最大值和最小值的绝对值都大于1,大部分波段的图像数值被放大,条纹噪声也被进一步放大。波段增益系数增大,条纹噪声增强,这与图4中银杏叶样本图像中条纹噪声的变化趋势一致。




图5 不同主成分数预测模型波段增益系数的变化趋势
Fig.5 Spectral gains of chemometric models
vs number of principle components

研究表明,当主成分数增加时,模型的波段增益系数增大,导致了化学计量学可视化图像中条纹噪

声逐渐加重。这意味着高预测能力的化学计量学模型,如果其波段增益较大,将更易受条纹噪声干扰。因此,一方面高预测能力的化学计量学模型不一定适用于指标分布的可视化;另一方面,去条纹校正从源头消除噪声,在保证指标分布可视化图像中空间信息不受固有条纹噪声干扰的情况下,在实际应用中可以采用波段增益系数更高、预测能力更强的化学计量学模型对农林产品品质进行空间分布预测。

3 结论

(1)比较3种反射率图像发现:反射率校正无法削弱条纹噪声;传统均值滤波图像增强可以减少条纹噪声,但图像中条纹噪声仍然明显;去条纹标定法可以很好地抑制条纹噪声,图像中无条纹噪声干扰。

(2)比较3种图像建立的PLSR模型准度发现:去条纹标定法和传统均值滤波增强均不会对模型的预测能力产生明显影响,随化学计量学模型波段增益增加,三者预测准度相当。

(3)比较3种图像建立的含水率可视化图像发现:当主成分数由6增加至10时,由原始图像或经传统均值滤波增强的图像所建立的含水率空间分布预测图像中,推扫式高光谱图像特有的条纹噪声逐渐显著降低,甚至完全湮没叶面内部含水率空间分布信息;而经去条纹标定法处理,能够明显抑制推扫式光谱成像系统引起的本征条纹噪声,即使预测模型波段增益系数较大(当主成分数为8个, R_p^2 为0.88,预测集均方根误差为0.92%),含水率可视化图像仍几乎不见条纹干扰,使得叶面含水率空间分布的局部特征依旧清晰可辨,其对含水率空间分布的预测效果明显优于传统高光谱图像所能达到的空间预测效果。

(4)比较3种图像建立的PLSR模型波段增益系数发现:随化学计量学模型波段增益系数的增大,可视化图像中的条纹噪声逐渐恶化。

(5)推扫式光谱成像由于本征条纹噪声影响,高准度化学计量学模型不一定适用于像素光谱,因此不一定能对靶向指标的空间分布可视化进行预测;而经过去条纹标定法处理,能够明显抑制高光谱图像的本征条纹噪声,保证可视化图像免受条纹噪声干扰的同时,使得在指标预测中可以使用具有更大波段增益系数、更高预测准度的化学计量学模型,从而更加可信地对靶向指标的空间分布情况进行预测。

参 考 文 献

[1] 王伟,姜洪喆,贾贝贝,等. 基于高光谱成像的生鲜鸡肉糜中大豆蛋白含量检测[J]. 农业机械学报,2019,50(12):357–364.
WANG Wei, JIANG Hongzhe, JIA Beibei, et al. Detection of soybean protein content in fresh minced chicken meat using hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 357–364. (in Chinese)

[2] LU Y, SAEYS W, KIM M, et al. Hyperspectral imaging technology for quality and safety evaluation of horticultural products: a review and celebration of the past 20-year progress[J]. Postharvest Biology and Technology, 2020, 170: 111318.

[3] WANG X W, XING X Y, ZHAO M C, et al. Comparison of multispectral modeling of physiochemical attributes of greengage: Brix and pH values[J]. Food Science and Technology, 2021, 41(Supp. 2): 611–618.

[4] 王伟,赵昕,褚璇,等. 基于可见/近红外高光谱的八角茴香与莽草无损鉴别[J]. 农业机械学报, 2019,50(11):373–379.
WANG Wei, ZHAO Xin, CHU Xuan, et al. Nondestructive identification of star anise and shikimmi by visible/near infrared hyperspectral imags[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11): 373–379. (in Chinese)

[5] 郑涛,刘宁,孙红,等. 基于高光谱成像的马铃薯叶片叶绿素分布可视化研究[J]. 农业机械学报,2017,48(增刊): 153–159.
ZHENG Tao, LIU Ning, SUN Hong, et al. Visualization of chlorophyll distribution of potato leaves based on hyperspectral imaging technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 153–159. (in Chinese)

[6] 赵茂程,杨君荣,陆丹丹,等. 基于高光谱成像的青梅酸度检测方法[J]. 农业机械学报, 2017, 48(9): 318–323.
ZHAO Maocheng, YANG Junrong, LU Dandan, et al. Detection methods of greengage acidity based on hyperspectral imaging [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9): 318–323. (in Chinese)

[7] 任志尚,彭慧慧,贺壮壮,等. 基于高光谱成像技术的面条中马铃薯全粉含量检测[J]. 农业机械学报, 2020, 51(增刊 2): 466–470.
REN Zhishang, PENG Huihui, HE Zhuangzhuang, et al. Detection of potato powder addition in noodles based on hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2): 466–470. (in Chinese)

[8] DAI Q, CHENG J H, SUN D W, et al. Prediction of total volatile basic nitrogen contents using wavelet features from visible/near-infrared hyperspectral images of prawn (*Metapenaeus ensis*)[J]. Food Chemistry, 2016,197:257–265.

[9] 李红,张凯,陈超,等. 基于高光谱成像技术的生菜冠层含水率检测[J]. 农业机械学报, 2021, 52(2): 211–217,274.
LI Hong, ZHANG Kai, CHEN Chao, et al. Detection of moisture content in lettuce canopy based on hyperspectral imaging technique[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(2): 211–217,274. (in Chinese)

[10] 石吉勇,李文亭,郭志明,等. 基于叶面叶绿素分布特征的黄瓜叶片氮钾元素亏缺诊断[J]. 农业机械学报, 2019, 50(8): 264–269.
SHI Jiyong, LI Wenting, GUO Zhiming, et al. Nondestructive diagnostics of nitrogen and potassium deficiencies based on chlorophyll distribution[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8): 264–269. (in Chinese)

[11] FENG C, MAKINO Y, OSHITA S, et al. Hyperspectral imaging and multispectral imaging as the novel techniques for detecting defects in raw and processed meat products: current state-of-the-art research advances[J]. Food Control, 2018, 84(1): 165–176.

[12] 邵园园,王永贤,玄冠涛,等. 基于高光谱成像的肥城桃品质可视化分析与成熟度检测[J]. 农业机械学报, 2020, 51(8): 344–350.
SHAO Yuanyuan, WANG Yongxian, XUAN Guantao, et al. Visual detection of SSC and firmness and maturity prediction for Feicheng peach by using hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 344–350. (in Chinese)

[13] LIU D, SUN D W, QU J H, et al. Feasibility of using hyperspectral imaging to predict moisture content of porcine meat during salting process[J]. Food Chemistry, 2014, 152(1): 197–204.

[14] 章海亮,代启,叶青,等. 基于高光谱成像技术的三文鱼脂肪含量可视化研究[J]. 江苏农业科学, 2019, 47(18): 220–223.
ZHANG Hailiang, DAI Qi, YE Qing, et al. Study on visualization of salmon meat fat content based on hyperspectral imaging technology[J]. Jiangsu Agricultural Sciences, 2019, 47(18): 220–223. (in Chinese)

[15] ZHAO H T, FENG Y Z, CHEN W, et al. Application of invasive weed optimization and least square support vector machine for prediction of beef adulteration with spoiled beef based on visible near-infrared (Vis-NIR) hyperspectral imaging[J]. Meat Science, 2019, 151(2): 75–81.

[16] 王春雷,陈婉芝,卢彩云,等. 基于高光谱成像的玉米收获后根茬行分割方法[J]. 农业机械学报, 2020, 51(增刊 2): 421–426.
WANG Chunlei, CHEN Wanzhi, LU Caiyun, et al. Segmentation method for maize stubble row based on hyperspectral imaging [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2): 421–426. (in Chinese)

[17] BEAT M, PAVEL T, FEDERICA M, et al. Stripe and ring artifact removal with combined wavelet—Fourier filtering[J]. Optics Express, 2009, 17(10): 8567–8591.

[18] CARFANTAN H, IDIER J. Statistical linear destriping of satellite-based pushbroom-type images[J]. IEEE Transactions on

Geoscience and Remote Sensing, 2010, 48(4): 1860–1871.

- [19] CAO B, DU Y M, XU D Q, et al. An improved histogram matching algorithm for the removal of striping noise in optical remote sensing imagery[J]. Optik, 2015, 126(23): 4723–4730.
- [20] ZHOU G, FANG H Z, YAN L X, et al. Removal of stripe noise with spatially adaptive unidirectional total variation[J]. Optik, 2014, 125(12): 2756–2762.
- [21] CHANG Y, YAN L X, WU T, et al. Remote sensing image stripe noise removal: from image decomposition perspective[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7018–7031.
- [22] 徐锐. 基于无人机遥感的叶用银杏产量预测[D]. 南京: 南京林业大学, 2020.
- XU Rui. Yield forecast of ginkgo leaf using UAV remote sensing [D]. Nanjing: Nanjing Forestry University, 2020. (in Chinese)
- [23] WANG X W, ZHAO M C, JU R H, et al. Visualizing quantitatively the freshness of intact fresh pork using acousto-optical tunable filter-based visible/near-infrared spectral imagery[J]. Computers and Electronics in Agriculture, 2013, 99: 41–53.
- [24] GONZALEZ R, WOODS R. Digital image processing [M]. Second Edition. Beijing: Publishing House of Electronics Industry, 2007: 119–123.
- [25] CHEN J H, SUN D W. Partial least squares regression (PLSR) applied to NIR and HSI spectral data modeling to predict chemical properties of fish muscle[J]. Food Engineering Reviews, 2017, 9(1): 36–49.
- [26] SCHWANNINGER M, RODRIGUES J, FACKLER X. A review of band assignments in near infrared spectra of wood and wood components[J]. Journal of Near Infrared Spectroscopy, 2011, 19(5): 287–308.
- [27] YANG Z, ZHANG M M, CHEN L, et al. Non-contact detection of surface quality of knot defects on eucalypt veneers by near infrared spectroscopy coupled with soft independent modeling of class analogy[J]. Bioresources, 2015, 10(2): 3314–3325.

(上接第 202 页)

- [30] ROSSEL R A V, BEHRENS T. Using data mining to model and interpret soil diffuse reflectance spectra[J]. Geoderma, 2010, 158(1–2): 46–54.
- [31] VASQUES G M, GRUNWALD S, SICKMAN J O. Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra[J]. Geoderma, 2008, 146(1–2): 14–25.
- [32] RITTHIRUANGDEJ P, RITTHIRON R, SHINZAWA H, et al. Non-destructive and rapid analysis of chemical compositions in Thai steamed pork sausages by near-infrared spectroscopy[J]. Food Chemistry, 2011, 129(2): 684–692.
- [33] 史秀志, 武永猛, 唐礼忠, 等. 偏最小二乘回归神经网络模型在爆破振动峰值速度预测中的应用[J]. 振动与冲击, 2013, 32(12): 45–49.
- SHI Xiuzhi, WU Yongmeng, TANG Lizhong, et al. Application of neural network model with partial least-squares regression in prediction of peak velocity of blasting vibration[J]. Journal of Vibration and Shock, 2013, 32(12): 45–49. (in Chinese)
- [34] 吕梦琪, 宋宇杰, 翁海勇, 等. 近红外高光谱成像扫描速度对拟南芥冠层含水率预测的影响[J]. 光谱学与光谱分析, 2020, 40(11): 3508–3514.
- [35] 宋高阳. 偏最小二乘回归的研究[D]. 杭州: 浙江大学, 2009.
- [36] 吴伟斌, 冯灼峰, 洪添胜, 等. 基于近红外反射的柑橘重叠叶片叶面积指数测量系统[J]. 农业机械学报, 2013, 44(1): 179–184.
- WU Weibin, FENG Zhuofeng, HONG Tiansheng, et al. Measurement system for citrus LAI based on near-infrared reflection [J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(1): 179–184. (in Chinese)
- [37] 彭彦昆, 赵芳, 李龙, 等. 利用近红外光谱与 PCA-SVM 识别热损伤番茄种子[J]. 农业工程学报, 2018, 34(5): 159–165.
- PENG Yankun, ZHAO Fang, LI Long, et al. Discrimination of heat-damaged tomato seeds based on near infrared spectroscopy and PCA-SVM method[J]. Transactions of the CSAE, 2018, 34(5): 159–165. (in Chinese)
- [38] 孙红, 邢子正, 张智勇, 等. 基于 RED-NIR 的主动光源叶绿素含量检测装置设计与试验[J]. 农业机械学报, 2019, 50(增刊): 175–181, 296.
- SUN Hong, XING Zizheng, ZHANG Zhiyong, et al. Design and experiment of chlorophyll content detection device for active light source based on RED-NIR[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 175–181, 296. (in Chinese)
- [39] 索炎炎, 张翔, 司贤宗, 等. 砂姜黑土区花生田种植前后土壤肥力空间变异特征分析及评价[J]. 核农学报, 2021, 35(4): 933–941.