

竹叶片氮含量高光谱估测方法对比研究

郑一力¹ 赵燕东¹ 董 玮^{1,2} 尘兴灿^{1,3} 李逸新^{1,3}

(1. 北京林业大学工学院, 北京 100083; 2. 北京林业大学城乡生态环境北京实验室, 北京 100083;
3. 林业装备与自动化国家林业局重点实验室, 北京 100083)

摘要: 为实现快速无损检测竹叶片氮含量,采用波长范围为 350~2 500 nm 的地物光谱仪获取竹叶片光谱数据,以金镶玉竹叶片为样本,对其进行高光谱分析。将高光谱原始反射率及其一阶微分、对数一阶微分和二阶微分值,与化学法测量的竹叶片氮含量值进行了相关性分析,分别获得了不同微分变化下的特征波段;基于微分变换后的高光谱反射率数据,分别采用二元线性回归、多元逐步回归、偏最小二乘回归和基于主成分分析的 BP 神经网络方法,建立了 4 种金镶玉竹叶片的氮含量高光谱估测模型。对比 4 种估测模型的校验结果表明,在光谱反射率的对数一阶微分变换下,采用拓扑结构为 6-10-1 的基于主成分分析的 BP 神经网络估测模型,校验环节决定系数为 0.838,均方根误差 RMSE 为 0.045 2,具备较好的竹叶片氮含量估测效果。

关键词: 竹叶片; 氮含量; 高光谱; 二元线性回归; 多元逐步回归; 偏最小二乘回归

中图分类号: S795.9 **文献标识码:** A **文章编号:** 1000-1298(2018)S0-0393-08

Comparison on Hyperspectral Estimation Method of Nitrogen Content in Bamboo Leaf

ZHENG Yili¹ ZHAO Yandong¹ DONG Wei^{1,2} CHEN Xingcan^{1,3} LI Yixin^{1,3}

(1. School of Technology, Beijing Forestry University, Beijing 100083, China
2. Beijing Laboratory of Urban and Rural Ecological Environment, Beijing Forestry University, Beijing 100083, China
3. Key Laboratory of State Forestry Administration for Forestry Equipment and Automation, Beijing 100083, China)

Abstract: In order to achieve rapid and non-destructive detection of nitrogen content in bamboo leaves, *Phyllostachys aureosulcata* leaves were used as samples for the hyperspectral analysis. To a certain extent, the nitrogen content in plant leaves can reflect the nitrogen condition inside the plant, which has a good prediction effect on plant growth. The spectral data of bamboo leaf was obtained by using the field portable terrain spectrometer with spectral range from 350 nm to 2 500 nm. Correlational analysis was conducted between the nitrogen content measured by the chemical method and the hyperspectral reflectance, the first order differential reflectance, the logarithmic first order differential reflectance and the second order differential reflectance of bamboo leaves, respectively, and the characteristic bands were obtained. Four estimation models of nitrogen content of bamboo leaf were established by the binary linear regression, multivariate stepwise regression, partial least squares regression (PLRS) and principal component analysis-BP neural network regression (PCA-BP). respectively. The experimental results of four estimation models showed that by using the logarithmic first order difference of the hyperspectral reflectance, PCA-BP estimation model with 6-10-1 topology based on principal component analysis had better estimation result. The determination coefficient (R^2) and root mean square error (RMSE) were 0.838 and 0.045 2, respectively.

Key words: bamboo leaf; nitrogen content; hyperspectra; binary linear regression; multiple stepwise regression; partial least squares regression

收稿日期: 2018-07-15 修回日期: 2018-08-25

基金项目: 中央高校基本科研业务费专项资金项目(2015ZCQ-GX-04)、北京市科技计划项目(Z161100000916012)和北京市共建项目

作者简介: 郑一力(1981—),男,副教授,主要从事林业生态监测和林业工程装备研究,E-mail: zhengyili@bjfu.edu.cn

通信作者: 赵燕东(1965—),女,教授,主要从事生态信息智能检测与控制研究,E-mail: yandongzh@bjfu.edu.cn

0 引言

植物叶片氮含量在一定程度上可以反映植物内部的氮素情况,对植物生长状况有较好预测效果^[1-2]。竹资源具有重要经济价值和良好的生态功能^[3],快速精确地估测竹叶片的氮元素含量,对于竹林的林分结构调控、土壤管理和施用化肥等精细化管理具有重要作用^[4]。

检测叶片含氮量的传统方法是直接采摘植物叶片,进行室内化学实验。测试结果准确度高,但时间和经济成本较高^[5]。高光谱分析技术具有快速、准确和无损的优势,在叶片氮素分析领域应用广泛^[6-7]。VIGNEAU等^[8]利用高光谱成像装置获取了400~1 000 nm波段的小麦叶片光谱数据,发现该波段与叶片含氮量具有较高相关性;LI等^[9]采用偏最小二乘回归有效地预测了冬小麦叶片的氮含量;岳学军等^[10]采用5种流形学习算法建立了柑橘叶片的氮含量光谱估测模型;余克强等^[11]对尖椒植株不同叶位的氮含量进行高光谱检测,采用偏最小二乘回归模型实现氮含量预测;王渊等^[12]采用油菜冠层光谱的一阶导数变换,经多元逐步回归方法构建了氮元素预测模型;周丽丽等^[13]通过多元逐步线性回归方法建立了玉米叶片氮含量的光谱估测模型。已有研究多采用偏最小二乘回归或多元逐步回归,以期得到高光谱数据与氮含量的关系模型。

本研究采用高光谱分析技术对金镶玉竹叶片氮含量进行估测,通过对比不同数据回归方法所建立的估测模型,探索竹叶片氮含量的快速准确估测方法,为竹林的氮素管理提供技术支持。

1 材料与方法

1.1 试验样本采集和排序

试验样本为3盆共9株长势均匀的2年生金镶玉竹苗,3盆竹苗分别编号N0、N1、N2。试验用土经测定含氮质量比为0.8~0.9 ng/kg,含磷质量比为1.33~1.54 pg/kg。为比较氮肥施用量对竹叶片生长状况的影响,做了3个梯度施氮处理,N0号盆不施氮,N1号盆每次施加1 g纯氮,N2号盆每次施加2 g纯氮。3个月内共施肥3次,培养3个月后将开始采集竹叶片样本。采集的叶片样本避开新叶,选取第2、3展开叶,叶宽大于1.5 cm,叶长大于10 cm。每盆土壤上方竹竿共15节左右,将1棵竹子分成上中下3层,每层5节左右。分层后对3盆竹苗的上中下3层各随机采集21片竹叶,共获得189片样本。

在竹叶最宽处区域的叶脉两侧各取5处测量点,采用KONICA MINOLTA SPAD-502 Plus叶绿素检测仪进行SPAD值测量,共测量10次取平均值,

然后将每盆中各层的21片竹叶片按SPAD平均值升序排列。

1.2 高光谱数据采集

竹叶样本高光谱数据的测定采用美国ASD-SR-2500型野外便携式地物光谱仪,该光谱仪波段范围为350~2 500 nm,在350~1 000 nm波段的光谱分辨率为3 nm,其余波段范围光谱分辨率为22 nm。

高光谱测量在室内进行,数据采集环境如图1所示。使用双150 W卤素灯作为光源。高光谱采集的手枪式光纤手柄固定于灰板上方,也是光源照射的中心位置。光纤手柄的镜头到竹叶样本的垂直距离为20 cm。测量前进行白板标定。将清理表层浮尘后的竹叶片置于灰板上重复观测5次。189片竹叶样本的高光谱数据由手持仪中DARWin SP软件完成采集。




图1 高光谱数据采集环境

Fig. 1 Hyperspectral data acquisition environment

1. 手枪式光纤手柄
2. 地物光谱仪
3. 参考白板
4. 手持仪
5. 灰板和竹叶样本
6. 双150 W卤素灯

1.3 氮含量化学法测定

将按SPAD值升序排列后的竹叶每3片为一组装进信封中重新编号,分成63组竹叶片样本。样本置于105℃恒温箱中杀青10 min,并于80℃下干燥至恒质量。采用粉碎机将每组样本磨碎、混合均匀装入原信封中保存并记录。由万分之一电子天平称取0.2 g左右干样,在消煮室内消煮。将消煮后的溶液装入小白瓶,供定氮环节使用。定氮环节由K1100型凯氏定氮仪完成,共得到63组氮含量值,随机分配47组氮含量值为训练样本集,16组为校验样本集。

2 数据处理与分析

2.1 光谱数据预处理

首先观测每片竹叶的5条未处理的光谱数据曲线,剔除明显误差。将剔除误差后的高光谱数据进行均值处理,采用卷积平滑法(Savitzky-Golay)进行去噪^[14-15],得到189条原始高光谱反射率 R 的曲线,如图2所示。

2.2 光谱曲线特征

分别对N0、N1和N2号盆竹叶高光谱数据进行




图2 原始高光谱反射率曲线

Fig. 2 Original hyperspectral reflectance data

均值处理,图3显示了不同氮肥施用量下竹叶片高光谱反射率 R 的特征。在可见光波段 (350 ~ 700 nm),竹叶片光谱反射率由大到小依次为 N1、N0、N2,在近红外波段 (700 ~ 2 500 nm),竹叶片光谱反射率由大到小依次为 N1、N2、N0。可见光及近红外波段 N1 号盆的光谱反射率均最高。由此可以看出,不施加氮肥或施加过量氮肥均会影响竹叶片的光谱反射率。





图3 不同氮肥施用量下竹叶片光谱反射率特征

Fig. 3 Bamboo spectral reflectance characteristics under different levels of nitrogen fertilizer



2.3 特征波段选取与相关性分析

将竹叶片的高光谱原始反射率 R 、反射率一阶微分 R' 、反射率对数一阶微分 $\lg R'$ 和反射率二阶微分 R'' 与化学法测定的竹叶片氮含量进行相关性分析,图4为相关系数曲线。

图4a是竹叶片的原始反射率 R 与化学法测定氮含量的相关性曲线,相关系数在 $-0.379 \sim 0.278$ 之间,在波长 546、578、700 nm 处,相关系数绝对值分别为 0.353、0.378 和 0.379,相关性较低,不能选为特征波段用于回归估测。

图4b是反射率一阶微分 R' 和化学法测定氮含量的相关性曲线。相关系数在 $-0.684 \sim 0.693$ 之间,在波长 499、631、653、668、759 nm 处,相关系数绝对值分别为 0.684、0.662、0.635、0.655 和 0.693,具有较显著的相关性,可以选取为特征波段用于回归估测。

图4c是反射率对数一阶微分 $\lg R'$ 和化学法测定氮含量的相关性曲线。相关系数在 $-0.593 \sim 0.782$ 之间,在波长 670、738、753、771 nm 处,相关系数绝对值分别为 0.650、0.781、0.782 和 0.683,具有较显著的相关性,可以选取为特征波段用于回归估测。

图4d是反射率二阶微分 R'' 和化学法测定氮含量的相关性曲线。相关系数在 $-0.684 \sim 0.752$ 之间,在波长 646、683、708、722、741、756、959 nm 处,相关系数绝对值分别为 0.613、0.684、0.752、0.673、0.611、0.642 和 0.603,具有较显著的相关性,可以选取为特征波段用于回归估测。




图4 相关系数曲线

Fig. 4 Correlation coefficient curves

2.4 估测模型建立

分别采用二元线性回归、多元逐步回归法、偏最小二乘回归和基于主成分分析的 BP 神经网络方法,建立竹叶片氮含量估测模型。使用决定系数 R^2 和均方根误差 RMSE 检验模型精度, R^2 越大模型越稳定, RMSE 越小则模型预测能力

越好。

2.4.1 二元线性回归模型

对竹叶片反射率的一阶微分 R' 、对数一阶微分 $\lg R'$ 和二阶微分 R'' , 分别进行多次筛选 2 个特征波段, 进行二元线性回归分析, 得到竹叶片氮含量预测的估测模型, 如表 1 所示。

表 1 竹叶片氮含量 (N_c) 的二元逐步回归模型
Tab.1 Binary linear regression model of bamboo leaf nitrogen content

变换形式	回归模型	训练样本 R^2	训练样本 RMSE
R'	$N_c = 1.650\,5 - 4.205\,4R_{499} + 2.173\,94R_{759}$	0.623	0.081 3
$\lg R'$	$N_c = 1.345\,5 + 19.426R_{670} + 98.022R_{753}$	0.659	0.077 2
R''	$N_c = 1.559\,7 - 17.829R_{683} - 7.484\,3R_{741}$	0.631	0.080 4

注: R_{499} 、 R_{670} 、 R_{683} 、 R_{741} 、 R_{753} 、 R_{759} 表示波长 499、670、683、741、753、759 nm 处变换形式对应的反射率。

表 1 中, 在反射率对数一阶微分 $\lg R'$ 变换下, 二元线性回归估测模型相对较好, 其决定系数 R^2 最大, 为 0.659, 均方根误差 RMSE 为 0.077 2。

2.4.2 多元逐步回归模型

在建立二元线性回归模型时, 需要人为选取特征波段作为变量, 进行模型精度的比较选取最佳模型。多元逐步回归分析可避免人为选入相关性误差大的特征波段。

根据竹叶片反射率的一阶微分 R' 、对数一阶微分 $\lg R'$ 和二阶微分 R'' 的相关系数, 分别筛选 10 个相关系数最大的特征波长作为待筛选变量, 如表 2 所示。

多元逐步回归建模依次将 10 个待筛选变量加入, 同时执行 F 检验和 T 检验^[14], 当后续加入的变量导致先前加入变量不再显著时, 便将不显著变量剔除。变量筛选反复执行至没有变量被剔除。

由多元逐步回归法建立的模型如表 3 所示。在 3 种变换形式下, 分别筛选出来 2 个变量构建模型,

模型结构与二元线性回归模型类似, 但自变量对应的特征波段有区别。在反射率对数一阶微分 $\lg R'$ 变换下, 多元逐步回归估测模型相对较好, 其决定系数 R^2 为 0.668, 均方根误差 RMSE 为 0.072 5。

表 2 多元逐步回归选取的特征波长
Tab.2 Characteristic wavelengths for multiple stepwise regressions

序号	反射率一阶微分		反射率对数一阶微分		反射率二阶微分	
	波长/ nm	相关 系数	波长/ nm	相关 系数	波长/ nm	相关 系数
1	499	0.684	434	0.416	497	0.538
2	631	0.662	451	0.448	631	0.558
3	653	0.635	476	0.417	646	0.613
4	668	0.655	494	0.593	683	0.684
5	689	0.558	561	0.423	708	0.752
6	742	0.553	631	0.435	722	0.673
7	759	0.693	670	0.650	741	0.611
8	778	0.584	738	0.781	756	0.642
9	824	0.543	753	0.782	791	0.562
10	857	0.503	771	0.683	959	0.603

表 3 竹叶片的氮含量 (N_c) 多元逐步回归模型
Tab.3 Multiple linear stepwise regression model of bamboo leaf nitrogen content

变换形式	回归模型	训练样本 R^2	训练样本 RMSE
R'	$N_c = 1.637\,9 - 1.163\,5R_{689} + 2.880\,6R_{759}$	0.644	0.078 9
$\lg R'$	$N_c = 1.291 - 25.358R_{494} + 103.87R_{753}$	0.668	0.072 5
R''	$N_c = 1.729 + 7.159\,7R_{708} + 3.075\,2R_{959}$	0.617	0.081 9

注: R_{494} 、 R_{689} 、 R_{708} 、 R_{959} 表示波长 494、689、708、959 nm 处变换形式对应的反射率。

2.4.3 偏最小二乘回归估测模型

偏最小二乘回归方法 (PLSR) 可同时实现回归建模、数据降维、信息综合筛选和分析两组变量间的相关性, 具有较好的鲁棒性和预测稳定性^[15]。

对竹叶片的反射率一阶微分 R' 、反射率对数一阶微分 $\lg R'$ 和反射率二阶微分 R'' , 分别进行偏最小二乘回归分析, 以决定系数 0.98 为阈值确定模型的最佳分量个数, 结果如表 4 所示。

表 4 竹叶片的氮含量 (N_c) PLSR 模型

Tab.4 PLSR model of bamboo leaf nitrogen content (N_c)

变换形式	分量个数	训练样本 R^2
R'	12	0.980 2
	18	0.999 2
$\lg R'$	12	0.983 8
	17	0.999 4
R''	10	0.989 3
	15	0.999 4

从表 4 可看出,在反射率一阶微分和对数一阶微分变换下,估测模型需要引入 12 个分量解释 98% 以上的因变量信息;在反射率二阶微分变换下,需要引入 10 个分量解释 98% 以上的因变量信息。在反射率二阶微分变换下所建立的偏最小二乘回归模型相对较好,预测精度可通过测试样本进一步检验。

2.4.4 基于主成分分析的 BP 神经网络估测模型

(1)主成分分析和 BP 神经网络

主成分分析法(PCA)的思路是利用方差最大原则,对原始光谱数据所包含的多个自变量进行线性拟合,以新的低维变量代替原始高维变量,达到数据降维的目的^[16-17]。反向传播(Back-propagation, BP)神经网络方法通过相应的训练,可达到输入和输出数据间的高度非线性映射^[18-19]。

本文将主成分分析与 BP 神经网络相结合,通过 PCA 变换,在有效保留光谱信息的前提下对数据进行降维,减少输入层神经元个数,增强 BP 神经网络性能,改善预测效果^[20]。

(2)PCA-BP 神经网络估测模型构建

分别对竹叶片的反射率一阶微分、反射率对数一阶微分和反射率二阶微分进行 PCA 变换,对应的特征值和方差贡献率如表 5~7 所示。

表 5 和表 6 中,前 3 个和前 4 个主成分分量的累计方差贡献率大于 90%,为得到更加准确的结果,将主成分分量增加为 10 个。

表 7 中,在二阶微分变换下,前 11 个主成分分量的累计方差贡献率大于 90%,不适合作为减少神经网络输入层因子。

表 5 PCA 特征值和方差贡献率(反射率一阶微分)
Tab.5 PCA eigenvalue and variance contribution rate (the first order differential reflectance)

主成分 分量	特征值	方差贡献 率/%	累计方差 贡献率/%
1	3.306 2	53.015 2	53.015 2
2	2.228 4	35.732 8	88.748 0
3	0.253 7	4.069 2	92.817 2
4	0.141 4	2.268 3	95.085 5
5	0.096 0	1.540 8	96.626 3
6	0.075 4	1.209 7	97.836 0
7	0.031 1	0.499 0	98.335 0
8	0.016 0	0.258 1	98.593 1
9	0.015 7	0.252 8	98.845 9
10	0.009 5	0.152 4	98.998 3

为了对 10 个主成分分量进一步筛选,通过多元逐步回归法去除干扰主成分。一阶微分变换下,进一步筛选出第1、2、3、4、8、9共6个主成分,其累计

表 6 PCA 特征值和方差贡献率(反射率对数一阶微分)
Tab.6 PCA eigenvalue and variance contribution rate (logarithmic first-order differential reflectance)

主成分 分量	特征值	方差贡献 率/%	累计方差 贡献率/%
1	0.009 1	56.542 6	56.542 6
2	0.003 5	22.118 0	78.660 6
3	0.001 1	6.533 8	85.194 4
4	0.000 9	6.175 7	91.370 1
5	0.000 4	2.510 7	93.880 8
6	0.000 1	1.100 9	94.981 7
7	0.000 1	0.945 4	95.927 1
8	0.000 1	0.517 2	96.444 3
9	0.000 1	0.422 6	96.866 9
10	0.000 1	0.314 3	97.181 2

表 7 PCA 特征值和方差贡献率(反射率二阶微分)
Tab.7 PCA eigenvalue and variance contribution rate (the second order differential reflectance)

主成分 分量	特征值	方差贡献 率/%	累计方差 贡献率/%
1	0.150 1	34.295 1	34.295 1
2	0.114 3	26.132 7	60.427 8
3	0.044 5	10.179 1	70.606 9
4	0.026 5	6.073 8	76.680 7
5	0.020 3	4.660 3	81.341 0
6	0.011 3	2.598 3	83.939 3
7	0.008 2	1.877 4	85.816 7
8	0.006 1	1.398 9	87.215 6
9	0.005 6	1.298 9	88.514 5
10	0.004 4	1.005 7	89.520 2
11	0.004 2	0.967 6	90.487 8

方差贡献率达到 95.596 4%。对数一阶微分变换下,进一步筛选出第 1、2、3、4、8、10 共 6 个主成分,其累计方差贡献率达到 92.201 6%。

选取此两组主成分分量作为神经网络的 6 个输入层因子,以相对应训练样本的氮含量作为输出层因子,采用单隐含层结构的 PCA-BP 神经网络进行 400 次训练。

表 8 给出了一阶微分和对数一阶微分变换下,不同拓扑结构 PCA-BP 神经网络的估测性能结果。表 8 中拓扑结构 6-10-1,表示 PCA-BP 神经网络输入层为 6、隐含层为 10、输出层为 1。

3 模型校验实验

3.1 二元线性回归模型校验

使用 16 组校验样本对所建模型逐一进行模型校验。二元线性回归模型的预测值与实测值比较结果如图 5 所示。

在反射率对数一阶微分变换下,二元线性回归

表 8 PCA-BP 神经网络估测性能比较
Tab.8 Estimation performance comparison of
PCA-BP neural network

变换形式	拓扑结构	训练样本	测试样本	测试样本
		R^2	R^2	RMSE
一阶微分	6-2-1	0.714	0.648	0.052 0
	6-4-1	0.754	0.733	0.049 2
	6-6-1	0.770	0.682	0.053 5
	6-8-1	0.763	0.674	0.051 6
	6-10-1	0.787	0.642	0.058 6
	6-12-1	0.807	0.687	0.047 9
对数一阶微分	6-2-1	0.774	0.560	0.070 7
	6-4-1	0.856	0.657	0.057 3
	6-6-1	0.778	0.568	0.070 1
	6-8-1	0.713	0.673	0.051 2
	6-10-1	0.841	0.838	0.045 2
	6-12-1	0.806	0.779	0.047 8

模型校验精度较好,测试样本的决定系数 R^2 为 0.656,均方根误差 RMSE 为 0.058 9。

3.2 多元逐步回归估测模型校验

多元逐步回归模型的校验结果如图 6 所示。在反射率对数一阶微分变换下,多元逐步回归模型校验精度较好,校验样本的决定系数 R^2 为 0.681,均方根误差 RMSE 为 0.055 9。

3.3 偏最小二乘回归估测模型校验

偏最小二乘回归模型的校验结果如图 7 所示。在反射率对数一阶微分 $\lg R'$ 变换下,由 12 个分量建立的偏最小二乘回归模型校验精度较好,测试样本的决定系数 R^2 为 0.752,均方根误差为 0.072 4。

3.4 PCA-BP 神经网络估测模型校验

表 8 给出了 PCA-BP 神经网络估测模型结果。在反射率对数一阶微分 $\lg R'$ 变换下,拓扑结构为 6-




图 5 二元线性回归模型氮含量预测值与实测值比较

Fig.5 Comparison of predicted and measured nitrogen values in binary linear regression model




图 6 多元逐步回归模型氮含量预测值与实测值比较

Fig.6 Comparison of predicted and measured nitrogen values in multiple stepwise regression models

10-1 的校验精度较好,测试样本的决定系数 R^2 为 0.838,均方根误差 RMSE 为 0.045 2。PCA-BP 神经网络预测模型的预测值与实测值比较结果如图 8 所示。

通过对比二元线性回归、多元逐步回归、偏最小

二乘回归和 PCA-BP 神经网络估测模型在训练环节和测试环节的决定系数和均方根误差,在反射率对数一阶微分变换下,选取拓扑结构为 6-10-1 的 PCA-BP 神经网络估测模型为竹叶片氮含量的较佳预测模型。




图 7 偏最小二乘回归模型氮含量预测值与实测值比较

Fig. 7 Comparison of predicted and measured nitrogen values in partial least squares regression model




图 8 PCA-BP 神经网络模型氮含量预测值与实测值比较

Fig. 8 Comparison of predicted and measured nitrogen values of PCA-BP neural network model

4 结论

(1)不同施氮量会影响竹叶片的高光谱反射率。

(2)竹叶片高光谱反射率一阶微分、对数一阶微分和二阶微分与化学法测定氮含量的相关性较高。

(3)在高光谱反射率对数一阶微分变换下,二元线性回归模型、多元逐步回归模型、偏最小二乘回归和 PCA-BP 神经网络估测模型的校验精度均较好,其中拓扑结构为 6-10-1 的 PCA-BP 神经网络估测模型,具备更好的估测效果,可以作为金镶玉竹叶片氮含量的较佳估测模型。

参 考 文 献

1 陆景陵. 植物营养学[M]. 2 版. 北京: 中国农业大学出版社, 2016.

2 BARKER A V, PILBEAM D J. Handbook of plant nutrition[M]. Second Edition. New York: CRC Press, 2015.

3 孙茂盛, 鄢波, 徐田, 等. 竹类植物资源与用[M]. 北京: 科学出版社, 2014.

4 郭晓敏. 毛竹林平衡施肥与营养管理[M]. 北京: 科学出版社, 2013.

5 方孝荣, 高俊峰, 谢传奇, 等. 农作物冠层光谱信息检测技术及方法综述[J]. 光谱学与光谱分析, 2015, 35(7): 1949 - 1955.

FANG Xiaorong, GAO Junfeng, XIE Chuanqi, et al. Review of crop canopy spectral information detection technology and methods [J]. Spectroscopy and Spectral Analysis, 2015, 35(7): 1949 - 1955. (in Chinese)

6 王莉雯, 卫亚星. 植被氮素浓度高光谱遥感反演研究进展[J]. 光谱学与光谱分析, 2013, 33(10): 2823 - 2827.

WANG Liwen, WEI Yaxing. Progress in inversion of vegetation nitrogen concentration by hyperspectral remote sensing [J]. Spectroscopy and Spectral Analysis, 2013, 33(10): 2823 - 2827. (in Chinese)

7 张瑶, 郑立华, 李民赞, 等. 苹果叶片氮素含量快速检测模型[J/OL]. 农业机械学报, 2012, 43(增刊): 300 - 304. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2012s61&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2012.S0.061.

ZHANG Yao, ZHENG Lihua, LI Minzan, et al. Rapid determination model of apple leaf nitrogen content[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(Supp.): 300 - 304. (in Chinese)

8 VIGNEAU N, ECARNOT M, RABATEL G, et al. Potential of field hyperspectral imaging as a non-destructive method to assess leaf nitrogen content in wheat[J]. Field Crops Research, 2011, 122(1): 25 - 31.

9 LI F, MISTELE B, HU Y, et al. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression[J]. European Journal of Agronomy, 2014, 52(1): 198 - 209.

10 岳学军, 全东平, 洪添胜, 等. 基于流形学习算法的柑橘叶片氮含量光谱估测模型[J/OL]. 农业机械学报, 2015, 46(6): 244 - 250. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20150635&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2015.06.035.

YUE Xuejun, QUAN Dongping, HONG Tiansheng, et al. Estimation model of nitrogen content for citrus leaves by spectral technology based on manifold learning algorithm[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(6): 244 – 250. (in Chinese)

11 余克强, 赵艳茹, 李晓丽, 等. 高光谱成像技术的不同叶位尖椒叶片氮素分布可视化研究[J]. 光谱学与光谱分析, 2015, 35(3): 746 – 750.

YU Keqiang, ZHAO Yanru, LI Xiaoli, et al. Application of hyperspectral imaging for visualization of nitrogen content in pepper leaf with different positions[J]. Spectroscopy and Spectral Analysis, 2015, 35(3): 746 – 750. (in Chinese)

12 王渊, 黄敬峰, 王福民, 等. 油菜叶片和冠层水平氮素含量的高光谱反射率估算模型[J]. 光谱学与光谱分析, 2008, 28(2): 273 – 277.

WANG Yuan, HUANG Jingfeng, WANG Fumin, et al. Predicting nitrogen concentrations from hyperspectral reflectance at leaf and canopy for rape[J]. Spectroscopy and Spectral Analysis, 2008, 28(2): 273 – 277. (in Chinese)

13 周丽丽, 冯汉字, 阎忠敏, 等. 玉米叶片氮含量的高光谱估算及其品种差异[J]. 农业工程学报, 2010, 26(8): 195 – 199.

ZHOU Lili, FENG Hanyu, YAN Zhongmin, et al. Hyperspectral diagnosis of leaf N concentration of maize and variety difference [J]. Transactions of the CSAE, 2010, 26(8): 195 – 199. (in Chinese)

14 SAVITZKY A, GOLAY M J E. Smoothing and differentiation of data by simplified least squares procedures [J]. Analytical Chemistry, 1964, 36(8): 1627 – 1639.

15 于雷, 洪永胜, 耿雷, 等. 基于偏最小二乘回归的土壤有机质含量高光谱估算[J]. 农业工程学报, 2015, 31(14): 103 – 109.

YU Lei, HONG Yongsheng, GENG Lei, et al. Hyperspectral estimation of soil organic matter content based on partial least squares regression [J]. Transactions of the CSAE, 2015, 31(14): 103 – 109. (in Chinese)

16 贾俊平, 何晓群, 金勇进. 统计学[M]. 北京: 中国人民大学出版社, 2015.

17 PALSSON F, SVEINSSON J R, ULFARSSON M O, et al. Model-based fusion of multi- and hyperspectral images using PCA and wavelets[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(5): 2652 – 2663.

18 吴江, 黄富荣, 黄才欢, 等. 近红外光谱结合主成分分析和 BP 神经网络的转基因大豆无损鉴别研究[J]. 光谱学与光谱分析, 2013, 33(6): 1537 – 1541.

WU Jiang, HUANG Furong, HUANG Caihuan, et al. Study on near infrared spectroscopy of transgenic soybean identification based on principal component analysis and neural network[J]. Spectroscopy and Spectral Analysis, 2013, 33(6): 1537 – 1541. (in Chinese)

19 HAYKIN S S. Neural networks and learning machines[M]. Third Edition. London: Pearson Education, 2011.

20 叶勤, 姜雪芹, 李西灿, 等. 基于高光谱数据的土壤有机质含量反演模型比较[J/OL]. 农业机械学报, 2017, 48(3): 164 – 172. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170321&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2017.03.021.

YE Qin, JIANG Xueqin, LI Xican, et al. Comparison on inversion model of soil organic matter content based on hyperspectral data[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3): 164 – 172. (in Chinese)