

# 基于灰度关联-极限学习机的土壤全氮预测

周鹏 杨玮 李民赞 郑立华 陈玉青

(中国农业大学现代精细农业系统集成研究教育部重点实验室, 北京 100083)

**摘要:** 为了克服近红外光谱的多重共线性、吸光度非线性等特点给土壤全氮含量预测带来的影响,引入灰度关联-极限学习机方法选择出具有较好预测能力的波长组合,以建立高精度土壤全氮含量预测模型。首先利用一阶微分光谱得到反映土壤全氮含量的敏感谱区,再利用灰度关联法得到土壤全氮含量的敏感波长,分别为 1 007、1 128、1 360、1 596、1 696、1 836、2 149、2 262 nm。最后采用极限学习机,将上述敏感波长作为输入,建立了土壤全氮预测模型。作为对照,同时采用传统相关分析方法选择了敏感波长并建立了回归模型。2种建模结果表明,灰度关联-极限学习机建立的土壤全氮预测模型,其建模决定系数  $R_c^2$  为 0.913 4,预测决定系数  $R_v^2$  为 0.878 7,建模精度和预测精度都比传统建模方法高。特别在预测低氮含量土壤时,灰度关联-极限学习机方法优势更明显。

**关键词:** 近红外光谱; 波长选择; 灰度关联; 土壤全氮; 极限学习机

中图分类号: S158.2; S151.9<sup>+</sup>5 文献标识码: A 文章编号: 1000-1298(2017)S0-0271-06

## Soil Total Nitrogen Content Prediction Based on Gray Correlation-extreme Learning Machine

ZHOU Peng YANG Wei LI Minzan ZHENG Lihua CHEN Yuqing

(Key Laboratory on Modern Precision Agriculture System Integration Research, Ministry of Education, China Agricultural University, Beijing 100083, China)

**Abstract:** In order to overcome the influences of multi-collinearity and absorbance non-linearity in near-infrared spectroscopy on predicting soil total nitrogen content, the gray correlation-extreme learning machine method was used to select the combination wavebands with good prediction capability to establish high precision prediction model for soil total nitrogen content. First, the first derivative spectra was used to get the sensitive spectrum area. And then the grey correlation sensitive wavelength selection method was used to select wavelengths which were respectively 1 007, 1 128, 1 360, 1 596, 1 696, 1 836, 2 149 and 2 262 nm. Finally, by using the above sensitive wavelengths as input data, a soil total nitrogen prediction model was established based on the method of extreme learning machine and multiple linear regression. As a comparison, while using the traditional correlation analysis method to select the sensitive wavelengths, the results showed that  $R_c^2$  of the soil total nitrogen forecast model established by using gray correlation-extreme learning machine was 0.913 4, and the prediction  $R_v^2$  was 0.878 7. Its accuracy was higher than that of the traditional modeling method. It indicated that the gray correlation-extreme learning machine method had more obvious advantages especially in the prediction of low soil total nitrogen content.

**Key words:** near infrared spectroscopy; wavelength selection; gray correlation; soil total nitrogen; extreme learning machine

### 引言

在利用近红外光谱技术进行定量和定性分析

时,都需要通过一定的化学计量学方法进行标定和建模。但近红外光谱存在多重共线性、吸光度的非线性及基线变动和附加散射变动等特性<sup>[1]</sup>。基于

收稿日期: 2017-07-10 修回日期: 2017-11-20

基金项目: 国家重点研发计划项目(2017YFD0201500-2017YFD0201501、2016YFD0700300-2016YFD0700304)

作者简介: 周鹏(1990—),男,博士生,主要从事精细农业系统集成研究,E-mail: zhoupeng@cau.edu.cn

通信作者: 李民赞(1963—),男,教授,博士生导师,主要从事精细农业系统集成研究,E-mail: limz@cau.edu.cn

上述近红外光谱的复杂特性,如果用全谱进行建模,会导致建模效率低、计算量大、建模时间长甚至导致建立的模型不收敛。因此在用近红外光谱进行建模时,首先需要对参与建模的近红外光谱进行敏感波长的选择,在光谱分析波长选择方法中,有相关系数法<sup>[2]</sup>、蚁群算法<sup>[3]</sup>、小波分析法<sup>[4]</sup>等。其中相关系数法是最常用的方法,但不够准确,只能大致地进行波长选择。蚁群算法容易导致早熟现象发生,小波分析在高频段的频率分辨率较差。

灰度关联分析通过关联度计算来理清系统中各因素之间的主次关系,找出影响最大的因素。能够很好地消除近红外光谱多重共线性及吸光度非线性带来的影响<sup>[5-8]</sup>。

现有的BP神经网络、SVM等建模方法在建模过程中,存在着需要人为设置大量的网络参数,容易产生局部最优解等问题<sup>[9]</sup>。而极限学习机(Extreme learning machine)具有学习速度快、泛化性能好的优点<sup>[10]</sup>。MASRI等<sup>[11]</sup>运用极限学习机对非洲地区的土壤进行近红外光谱建模分析,并用土壤属性数据库验证模型,模型的预测精度很高;周美灵等<sup>[12]</sup>用改进的极限学习机对近红外光谱测得的氨水浓度进行预测,预测集相关系数 $R$ 由0.9951增至0.9979,优化后的PSO-ELM算法具有较高的精确度和良好的泛化性能,模型预测效果优于传统的定量回归分析算法。

本文提出灰度关联-极限学习机算法对土壤全氮敏感波长进行选择并建立土壤全氮预测模型,旨在探索实时土壤样本在未经预处理下,通过波长选择方法和建模方法建立模型预测土壤全氮。

## 1 材料与方法

### 1.1 实验设计

田间实验于2017年4月进行,实验地点为中国农业大学上庄实验站,位于北京市海淀区上庄镇辛力屯村,实验站占地66.67 hm<sup>2</sup>。本次实验采集的土壤类型属于褐土土质,具有很强的代表性。在土壤样本采集时,选取了75个样本点,每个样本点采集深度为5~20 cm处的土壤,每个土壤样本采集1 kg,用双层牛皮袋封装样品,防止水分散失,样本采集完成后,立即送往实验室进行土壤光谱的测量(2 h以内,最大限度减小水分的散失),测定采集样本的光谱吸光度,并用实验室化学方法测定采集的土壤样本全氮含量。

### 1.2 土壤全氮含量的测定

将干燥后的土壤样本进行研磨后,采用瑞典福斯公司的FOSS-2300型全自动凯氏定氮仪进行土

壤全氮的测量。首先,称取干燥并研磨的土壤样本2.0 g,加入6.2 g混合好的催化剂,催化剂用K<sub>2</sub>SO<sub>4</sub>和CuSO<sub>4</sub>·5H<sub>2</sub>O按30:1的比例进行混合并研磨。将称量好的土壤样本和催化剂装入长试管中,在加入20 mL浓硫酸,处理完毕的试管放入消化炉进行消化,消化炉温度为420℃,消化时间为2 h,消化完成后进行0.5 h的冷却,最后用凯氏定氮仪进行蒸馏,测得土壤全氮的含量。

## 1.3 光谱处理与数据分析方法

### 1.3.1 光谱数据预处理

实验一共采集了75个土壤样本的近红外光谱数据,根据凯氏定氮法测定的土壤氮素含量,用SPSS软件进行聚类分析,剔除异常点,采用剩余的70个样本来进行土壤全氮模型的构建,其中40个用于模型的构建,作为建模组;30个用于模型的验证,作为验证集。

实验测量的近红外光谱为没有进行干燥的原始土壤光谱,由于土壤水分的影响,土壤样本的吸收光谱整体较高。由于采集的土壤样本在光谱测量过程中,会受到仪器本身原因、实验温度以及操作等因素的影响。因此,首先对测量的土壤光谱进行S-G卷积平滑,去除噪声等的干扰<sup>[13]</sup>。

### 1.3.2 灰度关联算法

2个系统或因素之间关联性大小称为关联度。灰色关联度分析的基本思想就是通过关联度的计算来理清系统中各因素之间的主次关系,从中找出影响最大的因素<sup>[14-16]</sup>。设参考序列为

$$X_o = \{x_o(k), k = 1, 2, \dots, n\}$$

比较序列为

$$X_i = \{x_i(k), k = 1, 2, \dots, m\}$$

则 $X_o$ 和 $X_i$ 之间的灰色关联度 $\gamma(X_o, X_i)$ 定义为

$$\gamma(X_o, X_i) = \frac{1}{n} \sum_{k=1}^n \gamma(x_o(k), x_i(k)) \quad (1)$$

其中

$$\gamma(x_o(k), x_i(k)) = \frac{\min_k |x_o(k) - x_i(k)| + \rho \max_k |x_o(k) - x_i(k)|}{|x_o(k) - x_i(k)| + \rho \max_k |x_o(k) - x_i(k)|} \quad (2)$$

其中, $\rho$ 为分辨系数,且 $\rho \in [0, 1]$ 。通过计算参考序列与比较序列得到灰色关联度的关联序集,以此作为判断序列之间相关程度大小的量度。

### 1.3.3 极限学习机(ELM)

极限学习机是2004年由黄光斌提出的一种人工神经网络模型训练算法<sup>[17-19]</sup>,在使用时只需设置网络的隐层节点个数,在网络训练过程中不需要调整网络的输入权值以及隐元的设置,并且产生唯一

的最优解,因此 ELM 具有学习速度快、泛化性能好的优点<sup>[20-21]</sup>。

图 1 所示为典型的单隐含层前馈神经网络结构图,ELM 模型结构会因激励函数的不同而改变,常用的激励函数有 Sigmoid、Sine、Hardlim 等,本文采用 Sine 作为激励函数进行土壤全氮建模分析。




图 1 极限学习机网络结构图

Fig. 1 Extreme learning machine network structure

ELM 学习算法的步骤如下:

(1) 给定训练集和选定激励函数。

(2) 确定隐含层神经元个数,随机设定输入 ELM 输入层和隐含层的输入权重  $\omega_j$  和隐含层神经元的阈值  $b_j$ 。

(3) 计算隐含层输出向量  $H$ , 根据  $\hat{\beta} = H^+ T$  计算得到  $\hat{\beta}$ 。

(4) 通过求得的输出权值矩阵  $\beta$  和随机设置的矩阵  $H$  对测试集样本进行测试。

## 2 结果与分析

### 2.1 土壤样本的近红外光谱特征分析

由于在近红外光谱采集过程中不可避免地受到测试环境、仪器本身、样品背景、杂散光等因素的影响,导致光谱曲线不够平滑,需要对光谱曲线进行校正。首先去除噪声较大的边缘波段 830 ~ 850 nm 以及 2 450 ~ 2 500 nm。对光谱曲线的平滑方法有小波变换、S-G 卷积平滑滤波等,本文对光谱数据进行 5 点 2 次的 S-G 卷积平滑操作,图 2 为原始吸光度曲线和 S-G 卷积平滑后曲线对比。

由图 2 可以看出,在光谱曲线的前端和末端还是存在较多的噪声,经过去除噪声较大的敏感波段以及 S-G 卷积平滑滤波处理,得到平滑的光谱曲线。从地里采集的土样没有经过干燥和过筛处理,所以土样的吸光度较高。在 1 450、1 940 nm 处有水的强烈吸收带,在 2 210 nm 处也有较强的吸收带,不仅有水的吸收带而且是有机质的吸收带,是两者的合频,经过 S-G 卷积滤波后,光谱的信息有效去除噪声的同时还较好地保存了光谱曲线的




图 2 原始吸光度曲线和 S-G 卷积平滑后曲线对比  
Fig. 2 Contrast between raw soil spectral curves and soil spectral curves smoothed by Savitzky - Golay

总体特征。

### 2.2 土壤近红外光谱波长选择

土壤的近红外光谱包含很多的信息,通过对土壤近红外光谱数据进行处理,可以提取到需要的信息。本文首先用相关系数法对土壤全氮含量的敏感波长进行选择;然后用本文提出的灰度关联法从相关系数选择出的敏感谱区中再继续选择土壤全氮含量敏感波长。通过建立的土壤全氮含量预测模型比较分析不同波长选择方法的可靠性及实用性。

#### 2.2.1 基于相关系数的土壤全氮含量近红外光谱敏感波长选择

一阶微分光谱既可以消除土壤原始光谱的基线漂移和平缓背景干扰的影响,也能够提供比原始光谱更高的分辨率和更清晰的光谱轮廓变换。因此,选择一阶微分光谱进行分析。将 70 个土壤样本的一阶微分数据与土壤全氮含量分别进行相关分析,结果如图 3 所示。




图 3 土壤一阶微分光谱与全氮含量相关性分析  
Fig. 3 Correlation coefficient between spectra of soil samples and total nitrogen content

由图 3 可知,相关系数波动较大,反映了丰富的图谱信息。在 850 ~ 1 350 nm 范围内,相关系数一直在 0 附近快速震荡,最高的相关系数只在 0.3 左右,在 1 350 ~ 1 471 nm 范围内,相关系数波动幅度变大,在 0.4 左右,很难从上述 2 个波段区间里提取到有效波长。在 1 481 ~ 1 606 nm、1 958 ~ 2 253 nm 以及 2 208 ~ 2 262 nm 波长范围为正相关区域,在 1 657 ~

1 780 nm、1 862 ~ 1 958 nm 以及 2 274 ~ 2 441 nm 范围为负相关区域, 分别在不同区域选取相关系数绝对值在 0.65 附近的极值点作为土壤全氮含量预测的敏感波长。因此选择了 1 389、1 469、1 740、1 870、2 047、2 318 nm 这 6 个波长作为土壤全氮含量预测模型的输入变量。

### 2.2.2 基于灰度关联法的土壤全氮敏感波长选择

提出结合相关系数-灰色关联度的新方法来选择敏感波长。先选取相关系数较高的谱区, 再分别每个谱区内与全氮含量进行灰度关联分析, 从每




图4 土壤敏感谱区与全氮含量灰度关联分析

Fig. 4 Analysis of gray correlation between sensitive spectral region and soil total nitrogen

### 2.2.3 不同方法选择土壤全氮敏感波长分析

以一阶微分相关系数和灰度关联分析得到的敏感波长在整个原始光谱曲线的分布如图 5 所示。




图5 不同波长选择方法得到的土壤全氮含量敏感波长

Fig. 5 Soil total nitrogen sensitive wavelengths of different wavelengths selection methods

从图 5 可以看出, 以灰度关联分析得到的敏感波长均匀分散在整个光谱曲线上, 而只以一阶微分相关系数得到的敏感波长分布在 1 300 nm 以后的波段内, 说明相比于仅采用一阶微分相关系数, 灰度关联分析得到的敏感波长可以有效地减少所选波长的自相关和冗余度。对于土壤, 1 000 nm 区域不仅与铁元素有关, 也与有机质含量有关; 1 100 nm 波长处的反射光谱也可以估计有机质含量<sup>[22-23]</sup>。众所周知, 由于氮元素是有机质的重要组成, 全氮含量与土壤有机质具有很强的关联度, 而以一阶微分相关系数选择的敏感波长在这个波长区间内不能够选择敏感波长, 导致一定程度的信息丢失, 1 000 nm 和 1 700 nm 也与铁元素有关, 已经证实, 铁元素有助

于将氮元素肥料转为土壤中的有效氮<sup>[24]</sup>, 此外,

根据土壤全氮含量与一阶微分的相关性分析, 从中选择相关系数高的 850 ~ 1 450 nm, 1 460 ~ 1 900 nm 以及 1 960 ~ 2 300 nm 这 3 个谱区。分别用选出的 3 个谱区与土壤全氮含量进行灰度关联分析, 分辨系数选择为 0.5。图 4 为得到的土壤全氮含量与近红外光谱区的相关系数, 相关系数越大说明与氮素的关联度越高。因此本文选择 1 007、1 128、1 360、1 596、1 696、1 836、2 149、2 262 nm 这 8 个波长作为土壤氮素的敏感波长。

于将氮元素肥料转为土壤中的有效氮<sup>[24]</sup>, 此外, 2 149 nm 和 2 262 nm 在以微分光谱信息相关性分析的土壤全氮含量预测中均表现了非常重要的作用<sup>[25]</sup>。

通过上述分析可以得到, 基于相关系数-灰度关联分析所选的 8 个波长均与土壤全氮含量有直接且紧密的联系, 对土壤光谱敏感波长的选择具有重要意义。

## 2.3 土壤全氮含量预测建模与分析

### 2.3.1 相关系数法所选敏感波长的多元线性回归预测模型

通过对一阶微分光谱信号与土壤全氮含量进行相关性分析后选取获得 6 个波长, 分别为 1 389、1 469、1 740、1 870、2 047、2 318 nm。采用 6 个波长的原始吸光度与土壤全氮含量建立多元线性回归预测模型。从 70 个土壤样本中选取 40 个样本用于模型的建模校正, 30 个土壤样本用于土壤全氮含量的预测验证, 多元线性回归建立的模型为

$$Y = 1.105 + 9.204X_{1389} - 2.492X_{1469} + 2.996X_{1740} - 5.433X_{1870} + 0.043X_{2047} + 2.853X_{2318} \quad (3)$$

图 6 为建立的多元线性回归模型建模集和验证集的 1:1 关系图, 其中建模决定系数  $R_c^2 = 0.7982$ ,  $RMSEC = 0.144$  g/kg, 样本预测的决定系数为  $R_p^2 = 0.7446$ ,  $RMSEP = 0.0176$  g/kg。

### 2.3.2 基于灰度关联-极限学习机的土壤全氮含量预测建模

选用灰度关联分析得到的 1 007、1 128、1 360、1 596、1 696、1 836、2 149、2 262 nm 这 8 个敏感波长作为模型输入建立极限学习机模型。




图6 土壤全氮含量的多元线性回归建模与预测  
Fig. 6 Calibration of soil nitrogen content and validation of nitrogen content forecasting models based on multiple linear regression models

图7为建立的灰度关联-极限学习机模型的结果,  $R_c^2 = 0.9134$ ,  $RMSEC = 0.0114$  g/kg, 样本预测的决定系数为  $R_v^2 = 0.8787$ ,  $RMSEP = 0.0119$  g/kg。与前面建立的模型相比, 其建模精度和预测精度都有明显提高。原因首先是灰色关联算选择的敏感波




图7 土壤全氮含量的灰度关联-极限学习机建模与预测  
Fig. 7 Calibration of soil total nitrogen content and validation of nitrogen content forecasting models based on gray correlation analysis - ELM

段, 均匀分散在整个吸收光谱曲线上, 所选的敏感波长能有效减小特征波长之间的冗余度, 特别在 850 ~ 1400 nm 谱区, 有效地选择了敏感波长, 避免了一阶微分相关系数选择时的信息丢失; 另一方面, 极限学习机模型相比 BP 神经网络模型等, 在建模过程中不需要人为设置大量网络参数, 只需设置网络的隐层节点数, 在算法执行过程中不需要调整网络的输入权值以及隐元的偏置, 避免了人为过多设置参数产生误差, 并且产生唯一的最优解, 因此具有学习速度快且泛化性能好的优点。

### 3 结论

(1) 经过相关性分析得到了土壤全氮敏感谱区, 再通过灰度关联法选择出敏感波长, 结果显示, 采用灰度关联法选择的敏感波长均匀分布在吸收光谱曲线上, 一方面减小了波段间的冗余度, 另一方面也避免了光谱信息的丢失, 是一种有效的光谱敏感波长选择方法。

(2) 通过极限学习机建立的土壤全氮预测模型, 其建模决定系数为 0.9134, 预测决定系数为 0.8787, 显著提高了模型的泛化能力和预测精度, 模型实用性很强。

(3) 通过对不同光谱波长选择算法得到的土壤全氮敏感波长, 结合不同的建模方法得到的土壤全氮预测模型的分析, 用灰度关联法所选的敏感波长建立的极限学习机模型的精度最高。灰度关联-极限学习机在光谱波长选择及土壤全氮的预测中具有明显的优势, 能够实时、方便、高效地对土壤全氮进行建模和田间预测。

### 参 考 文 献

- 李民赞. 光谱分析技术及其应用[M]. 北京: 科学出版社, 2006.
- 陈斌, 王豪, 林松, 等. 基于相关系数法与遗传算法的啤酒酒精度近红外光谱分析[J]. 农业工程学报, 2005, 21(7): 99-102. CHEN Bin, WANG Hao, LIN Song, et al. Analysis of near infrared spectroscopy of beer alcohol content by correlation coefficients and genetic algorithms [J]. Transactions of the CSAE, 2005, 21(7): 99-102. (in Chinese)
- ZHANG Y, LI M Z, ZHENG L H, et al. Soil nitrogen content forecasting based on real-time NIR spectroscopy [J]. Computers and Electronics in Agriculture, 2016, 124: 29-36.
- 彭辉, 文友先, 王巧华, 等. 基于小波变换和 BP 神经网络的蛋壳破损检测[J]. 农业机械学报, 2009, 40(2): 170-174. PENG Hui, WEN Youxian, WANG Qiaohua, et al. Crack detection in eggs with multi-level wavelet transform and BP neural network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(2): 170-174. (in Chinese)
- 张勇, 赵冰. 灰度关联分析结合支持向量机用于近红外光谱研究[J]. 光谱学与光谱分析, 2013, 33(2): 363-366. ZHANG Yong, ZHAO Bing. Application of grey correlation analysis with support vector machine in near-infrared spectroscopy [J]. Spectroscopy and Spectral Analysis, 2013, 33(2): 363-366. (in Chinese)
- 郭克冰. 基于灰色关联度的图像边缘检测的理论研究[D]. 开封: 河南大学, 2016. GUO Kebing. Research on image edge detection based on grey correlation degree [D]. Kaifeng: Henan University, 2016. (in Chinese)
- 霍迎秋, 唐晶磊, 尹秀珍. 基于灰度关联分析的苹果病害识别方法研究[J]. 实验技术与管理, 2013, 30(1): 49-51. HUO Yingqiu, TANG Jinglei, YIN Xiuzhen. Research on identification method of apple disease based on gray relation analysis [J]. Experimental Technology and Management, 2013, 30(1): 49-51. (in Chinese)
- 金秀良, 徐新刚, 王纪华, 等. 基于灰度关联分析的冬小麦叶片含水量高光谱估测[J]. 光谱学与光谱分析, 2012, 32(11): 3103-3106.

- JIN Xiuliang, XU Xin'gang, WANG Jihua, et al. Hyperspectral estimation of leaf water content for winter wheat based on grey relational analysis (GRA) [J]. *Spectroscopy and Spectral Analysis*, 2012, 32(11): 3103–3106. (in Chinese)
- 9 张瑶, 李民赞, 郑立华, 等. 基于近红外光谱分析的土壤分层氮素含量预测[J/OL]. *农业工程学报*, 2015, 31(9): 121–126. [http://www.tcsae.org/nygxcb/ch/reader/view\\_abstract.aspx?file\\_no=20150919&flag=1](http://www.tcsae.org/nygxcb/ch/reader/view_abstract.aspx?file_no=20150919&flag=1). DOI:10.11975/j.issn.1002-6819.2015.09.019.
- ZHANG Yao, LI Minzan, ZHENG Lihua, et al. Prediction of soil total nitrogen content in different layers based on near infrared spectral analysis [J/OL]. *Transactions of the CSAE*, 2015, 31(9): 121–126. (in Chinese)
- 10 刘振丙, 蒋淑洁, 杨辉华, 等. 基于波形叠加极限学习机的近红外光谱药品鉴别[J]. *光谱学与光谱分析*, 2014, 34(10): 2815–2820.
- LIU Zhenbing, JIANG Shujie, YANG Huihua, et al. Drug discrimination by near infrared spectroscopy based on summation wavelet extreme learning machine [J]. *Spectroscopy and Spectral Analysis*, 2014, 34(10): 2815–2820. (in Chinese)
- 11 MASRI D, WEI L W, AUNG Z. Soil property prediction: an extreme learning machine approach[C]// *International Conference on Neural Information Processing*. Springer International Publishing, 2015: 18–27.
- 12 周美灵, 郑德智, 娄格, 等. 基于改进极限学习机的光谱定量建模方法[J]. *北京航空航天大学学报*, 2017, 43(6): 1208–1215.
- ZHOU Meiling, ZHENG Dezhi, LOU Ge, et al. Quantitative spectral modeling method based on improved extreme learning machine [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2017, 43(6): 1208–1215. (in Chinese)
- 13 RADIM V, RADKA K, ALES K, et al. Simple but efficient signal pre-processing in soil organic carbon spectroscopic estimation [J]. *Geoderma*, 2017, 298: 46–53.
- 14 蔡树美, 诸海燕, 余廷园, 等. 西瓜产量与养分含量的灰色关联度和通径分析[J]. *土壤*, 2014, 46(4): 651–655.
- CAI Shumei, ZHU Haitao, YU Tingyuan, et al. Grey correlation analysis and path coefficient analysis between nutrient content and yield of watermelon [J]. *Soils*, 2014, 46(4): 651–655. (in Chinese)
- 15 曹明霞. 灰色关联分析模型及其应用的研究[D]. 南京: 南京航空航天大学, 2007.
- CAO Mingxia. Research on grey incidence analysis model and its application [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2007. (in Chinese)
- 16 田民, 刘思峰, 卜志坤. 灰色关联度算法模型的研究综述[J]. *统计与决策*, 2008(1): 24–27.
- 17 NAHVI B, HABIBI J, MOHAMMADI K, et al. Using self-adaptive evolutionary algorithm to improve the performance of an extreme learning machine for estimating soil temperature[J]. *Computers and Electronics in Agriculture*, 2016, 124: 150–160.
- 18 ACHARYA N, SHRIVASTAVA N A, PANIGRAHI B K, et al. Development of an artificial neural network based multi-model ensemble to estimate the northeast monsoon rainfall over south peninsular India: an application of extreme learning machine [J]. *Climate Dynamics*, 2013, 43(5–6): 1303–1310.
- 19 DEO R C, TIWARI M K, ADAMOWSKI J F, et al. Forecasting effective drought index using a wavelet extreme learning machine (W-ELM) model[J]. *Stochastic Environmental Research and Risk Assessment*, 2017, 31(5): 1211–1240.
- 20 邹伟东, 张百海, 姚大喜, 等. 基于改进型极限学习机的日光温室温湿度预测与验证[J/OL]. *农业工程学报*, 2015, 31(24): 194–200. [http://www.tcsae.org/nygxcb/ch/reader/view\\_abstract.aspx?file\\_no=20152429&flag=1](http://www.tcsae.org/nygxcb/ch/reader/view_abstract.aspx?file_no=20152429&flag=1). DOI:10.11975/j.issn.1002-6819.2015.24.029.
- ZOU Weidong, ZHANG Baihai, YAO Fenxi, et al. Verification and forecasting of temperature and humidity in solar greenhouse based on improved extreme learning machine algorithm [J/OL]. *Transactions of the CSAE*, 2015, 31(24): 194–200. (in Chinese)
- 21 孙俊, 卫爱国, 毛罕平, 等. 基于高光谱图像及 ELM 的生菜叶片氮素水平定性分析[J/OL]. *农业机械学报*, 2014, 45(7): 272–277. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20140742&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20140742&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2014.07.042.
- SUN Jun, WEI Aiguo, MAO Hanping, et al. Discrimination of lettuce leaves nitrogen status based on hyperspectral imaging technology and ELM[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2014, 45(7): 272–277. (in Chinese)
- 22 TRIPATHI N K. Analysis of VNIR (400~1100 nm) spectral signatures for estimation of soil organic matter in tropical soils of Thailand [J]. *International Journal of Remote Sensing*, 2004, 25(3): 643–652.
- 23 杨福芹, 冯海宽, 李振海, 等. 基于可见光-近红外光谱特征参数的苹果叶片氮含量预测[J/OL]. *农业机械学报*, 2017, 48(9): 143–151. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170918&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170918&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2017.09.018.
- YANG Fuqin, FENG Haikuan, LI Zhenhai, et al. Prediction for nitrogen content of apple leaves using spectral features parameters from visible and near infrared lights[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2017, 48(9): 143–151. (in Chinese)
- 24 ZAKIA I A, Abdel MALIK E M, BABIKERH M, et al. Iron and nitrogen interactions in groundnut nutrition [J]. *Communications in Soil Science and Plant Analysis*, 1998, 29(17–18): 2619–2630.
- 25 SHI T, CUI L, WANG J, et al. Comparison of multivariate methods for estimating soil total nitrogen with visible/near-infrared spectroscopy [J]. *Plant and Soil*, 2013, 366(1): 363–375.