

基于无人机高光谱遥感的东北粳稻冠层叶片氮素含量反演方法研究

冯 帅¹, 许童羽^{1, 2*}, 于丰华^{1, 2}, 陈春玲^{1, 2}, 杨 雪¹, 王念一¹

1. 沈阳农业大学信息与电气工程学院, 辽宁 沈阳 110161

2. 沈阳农业大学辽宁省农业信息化工程技术中心, 辽宁 沈阳 110161

摘 要 为探究遥感监测水稻冠层叶片氮素含量的较优高光谱反演模型, 以水稻小区试验为基础, 获取了不同生长期水稻冠层高光谱数据。在综合比较一阶导数变换(1-Der)、标准正态变量变换(SNV)和SG滤波法等处理方法基础上, 提出一种将SNV与一阶导数变换的SG滤波法相结合的光谱处理方法(SNV-FDS-GF), 并将处理后的数据经无信息变量消除法(UVE)与竞争自适应重加权采样法(CARS)选出不同生长期的敏感波段。将各生长期的敏感波段两两随机组合, 并构建与水稻叶片含氮量相关性较高的差值光谱植被指数(DSI)、比值光谱植被指数(RSI)、归一化光谱植被指数(NDSI)。其中分蘖、拔节和抽穗3个时期的最优植被指数和决定系数 R^2 分别为: DSI(R_{857}, R_{623}), 0.704; DSI(R_{670}, R_{578}), 0.786; DSI(R_{995}, R_{508}), 0.754。以各生长期内的较优的三种植被指数作为输入分别构建自适应差分优化的极限学习机(SaDE-ELM)、径向基神经网络(RBF-NN)以及粒子群优化的BP神经网络(PSO-BPNN)反演模型。结果表明: SaDE-ELM建模效果最好, 在模型稳定性和预测能力上比RBF-NN和PSO-BPNN都有了明显提高, 各生长期反演模型的训练集和验证集决定系数 R^2 均在0.810以上, RMSE均在0.400以下, 可为东北水稻冠层叶片含氮量的检测与评估提供科学和技术依据。

关键词 水稻; 氮素; 无人机; 高光谱处理; 植被指数; 反演模型

中图分类号: TP79 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2019)10-3281-07

引 言

氮素是水稻生长过程中必要元素, 因此对水稻含氮量的检测与评估, 有利于水稻氮素营养检测、长势和水稻产量的预测^[1]。目前, 水稻氮素诊断的方式一般采用稻田间破坏性获取样本和在室内对水稻组织进行化学方法分析。虽然室内检测结果较为精准, 但是该方法消耗大量人力、物力、费时且具有滞后性^[2-3]。因此利用无人机高光谱技术进行水稻含氮量诊断, 能够弥补传统方法的不足。

目前, 随着高光谱技术的快速发展, 国内外学者陆续采用高光谱技术对果蔬^[4-5]、粮食作物^[6-8]的冠层叶片含氮量进行了大量的研究, 并取得了一定的成果。Yu等^[9]结合水稻冠层数据和环境数据建立了水稻叶片氮素含量反演模型。Wang等^[10]经研究发现, 采用三波段构建植被指数对水稻冠层叶片含氮量进行估测, 估测效果较为准确。李旭青等^[11]利用改进的随机森林算法进行反演建模, 估测效果较有提升。

王仁红等^[12]经研究发现采用新的红边参数对冬小麦氮素含量建立反演模型, 模型精度较高($R^2=0.86$, $RMSE=0.08$)。Inoue等^[13]研究发现740和522nm的一阶导数值构成的简单指数RSI(D_{740}, D_{522})对于农作物冠层含氮量的评估是最准确和鲁棒的。

本工作采用无人机获取水稻冠层不同时期的高光谱数据进行分析, 构建各生长期较优的植被指数以及不同的建模方法对水稻冠层叶片含氮量进行估测, 以望为东北水稻冠层叶片含氮量的检测与评估提供科学和技术依据。

1 实验部分

1.1 研究区概况

试验区设立在辽宁省沈阳市辽中区卡力玛村院士工作站的水稻培育基地, 位于 $122^{\circ}39'56.05''E$, $41^{\circ}31'4.51''N$ 。供测试的水稻品种为千重浪1号。试验田各小区占地10亩, 划分为20个小区, 试验小区分布如图1所示。其中, 氮肥处理设

收稿日期: 2018-05-08, 修订日期: 2018-10-30

基金项目: 国家“十三五”重点研发计划项目(2016YFD0200600, 2016YFD0200603)资助

作者简介: 冯 帅, 1992年生, 沈阳农业大学信息与电气工程学院博士研究生 e-mail: int_crazy@163.com

* 通讯联系人 e-mail: yatongmu@163.com

置 4 个水平, 分别为 N0(不含氮), N1(50 kg · hm⁻²), N2(100 kg · hm⁻²), N3(150 kg · hm⁻²), 每个小区 5 个重复, 且随机分布。于 2017 年 6 月 20 日—8 月 23 日在试验小区共采样多次, 所对应的生长期分别为分蘖期、拔节期和抽穗期。所采集的样本中去粗大误差, 最终用于水稻叶片氮素含量测定的样本量为 170 个。




图 1 试验小区分布图

Fig. 1 Distribution of experimental plots

1.2 高光谱数据采集

水稻冠层光谱数据采用 GaiaSky-mini 高光谱成像仪进行获取。光谱范围为 400~1 000 nm, 光谱分辨率为 2.0 nm。为了获取稳定的水稻冠层高光谱反射率数据, 数据的采集均在天气晴朗、无风或微风时进行, 采集试验时间与地面样本采集日期相同, 飞行时间均在 9:00—14:00。飞行高度设定为 50 m, 地面分辨率为 2 cm。

采用 ENVI 软件获取各个小区感兴趣区(ROI)内的平均水稻光谱反射率, 并将其作为该小区的水稻冠层光谱反射率。

1.3 水稻叶片氮素含量测定

在获取水稻冠层高光谱反射率数据的同时, 从每个小区破坏性获取具有代表性水稻植株 4 株, 带回实验室。首先将各时期的水稻鲜叶放入烘箱, 并于温度为 105 °C 内杀青 30 min。并在 70 °C 的烘箱中将叶片烘干至恒量。称量后将其粉碎, 使用传统的凯氏定氮法检测代表性水稻叶片的含氮量(N, %)。170 个水稻叶片氮素含量统计数据见表 1。

表 1 水稻叶片氮素含量统计表

Table 1 A statistical table of nitrogen content in rice leaves

样本数量	最小值/%	最大值/%	平均值/%	标准差/%
170	1.146	4.784	3.320	0.639

1.4 数据分析方法

1.4.1 光谱处理

由于无人机高光谱数据会受到光照不均、风速大小, 背景因素等外界环境的干扰, 本工作为获取更加准确并增加光谱的有效信息, 综合比较三种处理方法的优缺点, 提出一种基于标准正态变量变换(SNV)处理的一阶导数(1-Der)与 SG 滤波法相结合的光谱处理方法(SNV-FDSGF)。

1.4.2 构建光谱植被指数

为进一步减少模型输入量, 将所有有效样本按水稻生长期分为三组, 分别代表拔节期、分蘖期、抽穗期, 先采用无

信息消除法(UVE)和竞争自适应重加权采样(CARS)相结合的方法对处理过后的光谱数据提取最优敏感波段, 并将三个生长期筛选出的敏感波段两两随机组合构建植被指数, 形成与水稻冠层叶片含氮量的决定系数等势图, 得到较优植被指数。采用的植被指数包括: 差值光谱植被指数(difference spectral index, DSI)、比值光谱植被指数(ratio spectral index, RSI)以及归一化光谱植被指数(normalized difference spectral index, NDSI), 分别定义如下

$$DSI(x, y) = x - y \quad (1)$$

$$RSI(x, y) = \frac{x}{y} \quad (2)$$

$$NDSI(x, y) = \frac{y - x}{y + x} \quad (3)$$

式中 x 和 y 分别为 400~1 000 nm 波段内的敏感波段的光谱反射率(R_i, R_j)。并分析 DSI, RSI 以及 NDSI 与水稻叶片含氮量的相关性 R^2 。用以筛选较优的光谱植被指数并将筛选出的各时期较优的三种光谱植被指数与东北粳稻冠层叶片含氮量建立反演模型。

1.4.3 反演建模方法

为提高模型预测精度, 避免样本集选择陷入极值化和局部化, 将三个生长期的有效样本按照 Kennard-Stone 算法(KS)划分样本的训练集和验证集, 其中分蘖期训练集和验证集个数分别为 47 和 24; 拔节期训练集和验证集个数分别为 30 和 16; 抽穗期训练集和验证集个数分别为 35 和 18。采用自适应差分优化的极限学习机(SaDE-ELM)、径向基神经网络(RBF-NN)、粒子群优化的 BP 神经网络(PSO-BPNN)3 种方法建模并进行对比分析, 得到最优的水稻冠层叶片含氮量反演模型。

ELM 本身有学习速率快和训练误差小等特点。但由于该神经网络的输入权值和隐含层偏执矩阵均采用随机生成的方式, 经研究发现所建立的反演模型稳定性与泛化能力较差。因此将自适应差分优化算法(SaDE)对 ELM 进行优化, 利用 SaDE 所具有的全局搜索性能获取与训练集较好匹配的输入权值与隐含层偏执矩阵, 从而提高 ELM 的稳定性和泛化能力。具体执行步骤如下:

(1)构建模型的训练集和原始种群, 并设置 ELM 隐含单元个数 N 、激励函数 $g(x)$ 和 P 个维度的参数向量 $M_{r, g}$ ($r = 1, 2, \dots, P$), 如式(4)所示, 迭代次数为 g , ω_i 和 d_i 分别为输入层权值和隐层的偏置矩阵, 种群中每一个个体每一维的数值范围为 $[-1, 1]$ 。

$$M_{r, g} = [\omega_{1, (r, g)}^T, \dots, \omega_{N, (r, g)}^T, d_{1, (r, g)}, \dots, d_{N, (r, g)}] \quad (4)$$

(2)将模型种群中各个个体 $M_{r, g}$ 通过式(5)算出隐层的输出矩阵, 并将矩阵 H 由式(6)得出权重 β , 并通过式(7)得出每一个种群个体的标准误差(RMSE)。

$$H = \begin{bmatrix} g(\omega_{1, (r, g)} x_1 + d_{1, (r, g)}) & \cdots & g(\omega_{N, (r, g)} x_1 + d_{N, (r, g)}) \\ \cdots & \cdots & \cdots \\ g(\omega_{1, (r, g)} x_k + d_{1, (r, g)}) & \cdots & g(\omega_{N, (r, g)} x_k + d_{N, (r, g)}) \end{bmatrix} \quad (5)$$

$$\beta_{r, g} = H_{r, g}^+ T \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^k \left[\sum_{j=1}^N \|\beta_j g(\omega_{j, (r, g)}) x_i + d_{j, (r, g)} - t_i\| \right]}{k}} \quad (7)$$

(3)最后随机选取种群中的一个群体,采用式(8)(r_1, r_2 和 r_3 表示不同个体且互不相同, F 代表变异概率)进行变异处理,得到每个变异的个体 $v_{r, g}$,再将 $v_{r, g}$ 和 $M_{r, g}$ 根据式(9)(CR 代表交叉概率,取值范围 $[0, 1]$)进行交叉操作得到 $u_{r, g+1}$ 。并将新得到的 $u_{r, g+1}$ 与 $M_{r, g}$ 进行对比分析。重复进行 g 次变异、交叉与对比,最终计算得出输出权重 β ,得到模型。

$$v_{r, g} = M_{r_1, g} + F(M_{r_2, g} - M_{r_3, g}) \quad (8)$$

$$u_{r, i} = \begin{cases} v_{r, i} & \text{randi}(0, 1) \leq CR \text{ or } i = \text{rand}(1, N) \\ M_{r, i} & \text{other} \end{cases} \quad (9)$$

2 结果与讨论

2.1 各时期的水稻冠层光谱曲线

分析图 2,在水稻 3 个时期内,光谱曲线呈现出较为一致的规律性。在 400~500 nm,反射率呈现为较为平缓的状态;在 500~550 nm 后,反射率表现出慢慢上升的现象,并在 550 nm 呈现较为明显的高峰。在 556~680 nm 反射率缓慢下滑,在 680 nm 呈现较为显著的低谷。进入 681~772 nm 后三个生长期反射率变化基本一致,反射率迅速上升。光谱放射率在 772 nm 形成反射率平台。同时,在图 2 两个放大的小图中可以发现,拔节期和分蘖期的反射率在 400~772 nm 中呈现多次交叉,但并没有出现明显差异,抽穗期反射率在 400~772 nm 中较相对于其他两个时期。

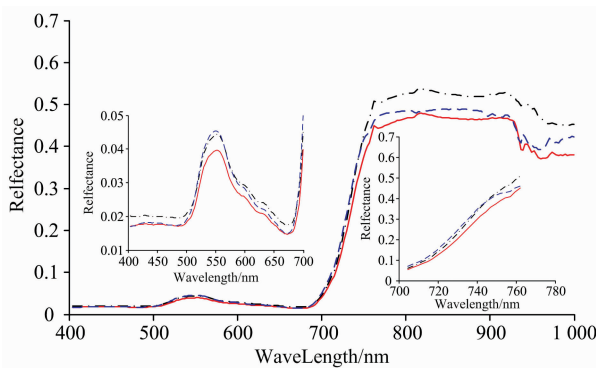


图 2 不同生长期水稻冠层原始高光谱反射率
Fig. 2 Canopy original hyperspectral reflectance at different growth stages

2.2 光谱处理分析

首先采用 SNV 方法对原始光谱进行处理,其具有消除高光谱获取过程中产生的水稻冠层散射与光程变化对光谱的影响的优点。多次处理发现,SNV 处理过后的光谱产生了一些反射光谱的基线漂移,对光谱数据产生了一定影响。因此将处理过后的光谱数据进行一阶导数变换处理,该处理方法能够较为有效地消除基线漂移旋转,提高了光谱的分辨率与

灵敏度。最后采用 SG 滤波法对数据处理。图 3 为 SNV-FDSGF 处理后水稻冠层的反射光谱。




图 3 SNV-FDSGF 处理后水稻冠层的反射光谱
Fig. 3 Reflectance spectra of rice canopy after SNV-FDSGF treatment

将所获取的全部光谱数据采用 4 种处理方法进行处理,并将得到的处理结果作为 PLSR 模型的输入,实测水稻叶片氮素含量作为输出,利用交叉验证法将模型调整至最佳,按不同生长期和不同处理方法建立水稻冠层氮素含量的定量预测模型,所建模型的预测结果如表 2 所示。

由表 2 可得,通过对比经四种处理和未经处理的 PLSR 建模结果,发现未经处理的原始数据建模效果较差,决定系数 R^2 较低, RMSE 较高;经 SNV-FDSGF 处理后的 PLSR 反演结果与其他处理方法反演效果相比较优,建模集和预测集角决定系数 R^2 高于 0.58, RMSE 低于 0.40。

表 2 3 个时期光谱数据的 4 种处理方法建模结果
Table 2 Modeling results of four processing methods for spectral data of three periods

生长期	预处理方法	因子数	建模集		预测集	
			R^2	RMSE	R^2	RMSE
分蘖期	无	3	0.562 9	0.425 7	0.551 4	0.444 7
	1-Der	5	0.725 0	0.512 8	0.453 1	0.470 3
	SNV	1	0.707 9	0.440 3	0.574 1	0.371 5
	SNV-FDSGF	2	0.725 2	0.420 7	0.587 6	0.311 6
拔节期	SG 平滑	4	0.653 5	0.460 2	0.533 6	0.673 6
	无	2	0.640 7	0.384 6	0.572 9	0.478 1
	1-Der	3	0.717 4	0.449 6	0.536 8	0.464 8
	SNV	2	0.703 1	0.361 5	0.529 3	0.426 5
抽穗期	SNV-FDSGF	2	0.733 9	0.352 0	0.616 1	0.388 0
	SG 平滑	2	0.640 8	0.482 4	0.597 8	0.573 6
	无	4	0.620 3	0.458 8	0.626 2	0.444 0
	1-Der	2	0.603 7	0.593 7	0.582 6	0.354 0
抽穗期	SNV	3	0.684 9	0.474 1	0.602 8	0.402 4
	SNV-FDSGF	1	0.719 9	0.395 9	0.644 8	0.391 0
	SG 平滑	3	0.686 9	0.462 6	0.534 9	0.471 3

2.3 植被指数与水稻叶片的含氮量相关性

将经 SNV-FDSGF 处理后的水稻 3 个生长期光谱数据进

行 UVE 与 CARS 相结合获取较优的敏感波段, 分别将 3 个生长期(分蘖期、拔节期和抽穗期)的光谱波段由 300 个分别降低为 24 个、28 个和 31 个, 明显降低了数据维度。

同时, 为进一步减少模型输入变量个数, 提高建模效率与精度, 将 3 个生长期任意两个敏感波段组合构成 NDSI (R_i, R_j), RSI(R_i, R_j)和 DSI(R_i, R_j)。图 4(a,b,c)和图 5(a,b)分别代表水稻三个不同时期的植被指数与水稻冠层叶片含氮量的 R^2 等势图。

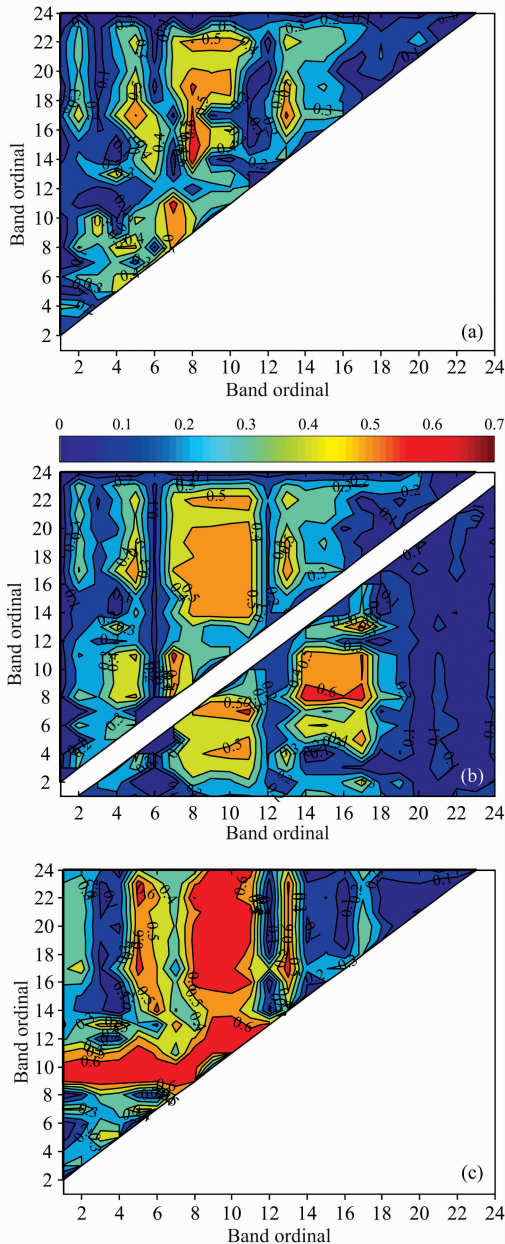


图 4 水稻分蘖期植被指数与叶片含氮量的 R^2 等势图

(a): 分蘖期 NDSI(R_i, R_j); (b): 分蘖期 RSI(R_i, R_j);
(c): 分蘖期 DSI(R_i, R_j)

Fig. 4 Contour of R^2 between vegetation index and nitrogen content of rice canopy during tillering stage

(a): Tillering stage NDSI(R_i, R_j); (b): Tillering stage RSI(R_i, R_j);
(c): Tillering stage DSI(R_i, R_j)

从图 4 中可知, 对于分蘖期 NDSI 植被指数[图 4(a)]而言, 在第 8(623 nm)波段与第 14(737 nm)到 17 波段(772 nm)的波段组合的 NDSI 最佳, 决定系数 R^2 达到 0.60 以上, 其中相关性最好的波段组合为 NDSI(R_{737}, R_{623}), R^2 为 0.684。在分蘖期 RSI 指数[图 4(b)]中, 最优的波段组合同样出现在第 8(623 nm)波段与第 14(737 nm)到 17 波段(772 nm)之中, 但是植被指数与叶片含氮量的相关性 R^2 具有略微的提高, 最优的植被指数为 RSI(R_{745}, R_{623}), 决定系数 R^2 为 0.689。在分蘖期 DSI 指数中[图 4(c)], 每个特征波段间的组合与叶片氮素含量的相关性比其他两个植被指数均较高, 最佳特征波段范围为第 7(598 nm)到 8 波段(623 nm)与第 16(759 nm)到 22 波段(857 nm)之间, 其中 DSI(R_{857}, R_{623})与叶片氮素含量的相关性最好, R^2 为 0.704。

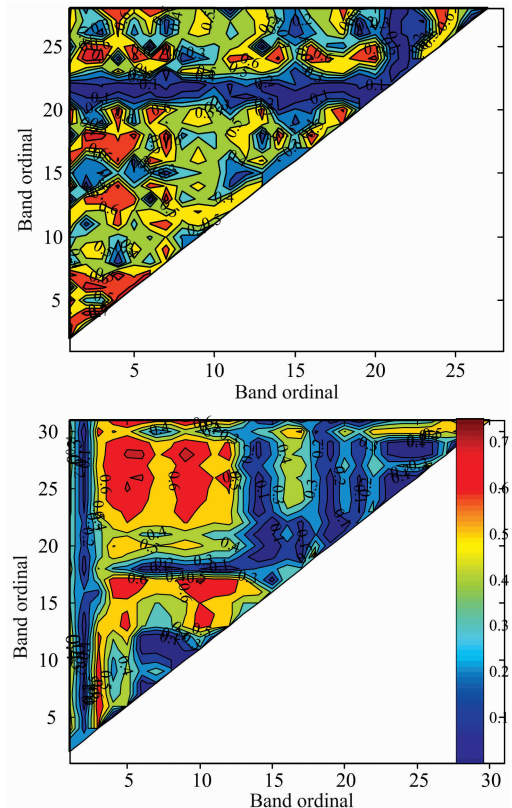


图 5 水稻拔节期和抽穗期 DSI 与叶片含氮量的 R^2 等势图

(a): 拔节期 DSI(R_i, R_j); (b): 抽穗期 DSI(R_i, R_j)

Fig. 5 Contour of R^2 between DSI at jointing stage and heading stage and nitrogen content of rice canopy leaf

(a): Jointing stage DSI(R_i, R_j); (b): Heading stage DSI(R_i, R_j)

同理, 由图 5 可判断, 拔节期与抽穗期的三种较优的植被指数与水稻叶片含氮量的相关性 R^2 均在 0.69 以上, 其中拔节期和抽穗期较优 NDSI(R_i, R_j)和 RSI(R_i, R_j)指数分别为 NDSI(R_{767}, R_{504}), RSI(R_{767}, R_{500})和 NDSI(R_{667}, R_{597}), RSI(R_{587}, R_{431}), 决定系数分别为 0.770, 0.771 和 0.738, 0.752, 但 DSI(R_i, R_j)与水稻叶片氮素含量的相关性相比较低, 因此本文仅列出拔节期和抽穗期的 DSI(R_i, R_j)与叶片氮素含量的决定系数等势图[图 5(a)和(b)]。由图 5 可知,

拔节期植被指数 $DSI(R_{670}, R_{578})$ 的决定系数 R^2 为 0.786, 抽穗期植被指数 $DSI(R_{995}, R_{508})$ 的决定系数 R^2 为 0.754。

2.4 自适应差分优化的极限学习机反演模型

分别将水稻各个生长期较优的三种植被指数作为模型的输入变量, 水稻叶片氮素含量作为模型的输出变量, 建立基

于自适应差分极限学习机(SaDE-ELM)水稻冠层叶片氮素含量反演模型。经反复测试确定 SaDE-ELM 的参数为: 激活函数 $g(x)=\text{sigmoid}$, 交叉概率 $CR=0.8$, 变异因子 $F=0.5$ 。水稻 3 种不同生长期建模结果如图 6(a,b,c) 所示。




图 6 基于水稻三种生长期的 SaDE-ELM 反演模型验证图

(a): 分蘖期; (b): 拔节期; (c): 抽穗期

Fig. 6 Verification diagram of SaDE-ELM inversion model based on three growth stages of rice

(a): Tillering stage; (b): Jointing stage; (c): Heading stage

由图 6 可知, 采用 SaDE-ELM 反演建模中, 水稻的 3 个生长期反演建模效果均较好, 训练集与验证集的 R^2 均在 0.81 以上, RMSE 均低于 0.40。其中, 采用水稻拔节期数据建立的 SaDE-ELM 模型效果最好, 训练集与验证集的 R^2 为 0.865 和 0.839, RMSE 为 0.189 和 0.211, 拔节期训练集和验证集的 R^2 与 RMSE 相差不大, 模型的稳定性与预测能力较高。在水稻抽穗期, 训练集与验证集的 R^2 分别为 0.839 和 0.832, RMSE 分别为 0.201 和 0.178, 建模效果仅次于拔节期。而在分蘖期, 建模效果相比上述两个时期较差, 训练集的 R^2 与 RMSE 为 0.850 和 0.269, 验证集的 R^2 与 RMSE 为 0.810 和 0.386。由此可见, SaDE-ELM 对水稻三个生长期冠层叶片含氮量预测的建模效果较好, 提高了模型的稳定性和预测能力。

2.5 与其他反演模型比较

将本文反演模型与其他两种比较好的反演模型: RBF-NN 和 PSO-BPNN 进行对比分析, 建模效果如图 7 和图 8 所示。两个模型均采用每个生长期较优的三种植被指数作为输入变量并通过数据整理, 参数调整等达到最优模型反演状态。由图 7 和图 8 可得, RBF-NN 反演模型和 PSO-BPNN 反演模型对水稻冠层叶片含氮量的预测效果较好。训练集和预测集的 R^2 高达 0.70 以上, RMSE 均低于 0.50。但与 SaDE-ELM 方法比较, SaDE-ELM 反演模型决定系数 R^2 最高, RMSE 低于其他两种模型。经对比分析得出采用 SaDE-ELM 建模的预测能力和模型稳定性均要优于其他两种方法所建立的反演模型。




图 7 基于水稻 3 种生长期的 PSO-BPNN 反演模型验证图

(a): 分蘖期; (b): 拔节期; (c): 抽穗期

Fig. 7 Verification diagram of PSO-BPNN inversion model based on three growth stages of rice

(a): Tillering stage; (b): Jointing stage; (c): Heading stage




图 8 基于水稻 3 种生长期的 RBF-NN 反演模型验证图

(a): 分蘖期; (b): 拔节期; (c): 抽穗期

Fig. 8 Verification diagram of RBF-NN inversion model based on three growth stages of rice

(a): Tillinging stage; (b): Jointing stage; (c): Heading stage

本工作采用机载高光谱摄像机获取田间水稻 3 个生长期的高光谱图像, 使用 ENVI 软件选取感兴趣区域并进行光谱提取。首先对水稻的 3 个生长期光谱数据进行 1-Der, SNV, SNV-FDSGF 和 SG 滤波法等 4 种不同的处理, 同时, 使用 PLSR 构建叶片含氮量反演模型, 经分析确定 SNV-FDSGF 方法效果最优。同时, 为了降低冗余信息, 提高建模效率与精度, 采用 UVE 与 CARS 方法筛选敏感波段, 并构建归一化植被指数等光谱植被指数。在使用较优的光谱植被指数构建与东北粳稻冠层叶片含氮量建立反演模型时, 分别采用径向基神经网络、粒子群优化 BP 神经网络和自适应差分进化极限学习机等 3 种方法建立模型, 经验证, 所建立的反演模型获得了较好的预测效果, 能为实时、快速、无损和准确监测水稻冠层叶片含氮量提供了一种新的方法。

本研究中还存在一定的不足之处。如更多考虑单一水稻品种、无人机飞行高度等因素下对反演的影响。而在后续研究中, 将更进一步对不同水稻品种、无人机飞行高度、植株形态密度以及叶面积指数等影响因素进行建模分析, 以确保能够得出更加充分地建立水稻冠层氮素含量反演模型。

4 结论

采用光谱处理技术分析水稻冠层叶片的光谱特点, 探究

了 4 种的处理方法的数据处理能力, 并采用 UVE-CARS 方法筛选各生长期水稻敏感波段并构建 3 种光谱植被指数, 建立多种反演模型。研究结果表明:

(1) 根据不同的光谱处理方法对数据进行处理并构建 PLSR 估测模型, 研究表明 SNV-FDSGF 处理方法是一种较为有效的数据处理方法, 能够有效地消除或降低光照等外界环境因素的影响, 提高了建模效率与精度。

(2) 采用 UVE 与 CARS 相结合的方法筛选特征波段, 并构建水稻生长各时期的植被指数与水稻冠层叶片含氮量的 R^2 等势图。其中分蘖、拔节和抽穗 3 个时期的最佳植被指数和决定系数 R^2 分别为: DSI(R_{857}, R_{623}), 0.704; DSI(R_{670}, R_{578}), 0.786; DSI(R_{995}, R_{508}), 0.754。

(3) 每个生长期分别采用 3 种较优的植被指数进行反演建模, 对比发现, SaDE-ELM 模型优于 RFB 和 PSO-BP 模型, 原因在于 SaDE-ELM 构建的反演模型能够更加极端地接近非线性函数, 具有较好的泛化能力和更快的学习速率。在 3 个生长期的 SaDE-ELM 反演模型中训练集与验证集的 R^2 均在 0.81 以上, RMSE 均低于 0.40。

References

- [1] CHEN Yong-zhe, FU Bo-jie, FENG Xiao-ming(陈永喆, 傅伯杰, 冯晓明). Acta Ecologica Sinica(生态学报), 2017, 37(18): 6240.
- [2] QIN Zhan-fei, CHANG Qing-rui, XIE Bao-ni, et al(秦占飞, 常庆瑞, 谢宝妮, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2016, 32(23): 77.
- [3] WANG Shu-wen, ZHAO Yue, WANG Li-feng, et al(王树文, 赵越, 王丽凤, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2016, 32(20): 187.
- [4] Tyler J Nigon, David J Mulla, Carl J Rosen, et al. Computers & Electronics in Agriculture, 2015, 112(C): 36.
- [5] LI Lan-tao, MA Yi, WEI Quan-quan, et al(李岚涛, 马驿, 魏全全, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2015, 31(20): 147.
- [6] YANG Bao-hua, CHEN Jian-lin, CHEN Lin-hai, et al(杨宝华, 陈建林, 陈林海, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2015, 31(22): 176.

- [7] LI Fen-ling, CHANG Qing-rui(李粉玲, 常庆瑞). Transactions of the Chinese Society for Agricultural Machinery(农业机械学报), 2017, 48(7): 174.
- [8] Martin L Gnyp, Yuxin Miao, Fei Yuan, et al. Field Crops Research, 2014, 155(155): 42.
- [9] Yu F H, Xu T Y, Cao Y L, et al. Int. J. Agric. & Biol. Eng., 2016, 9(5): 132.
- [10] Wang Wei, Yao Xia, Yao Xinfeng, et al. Field Crops Research, 2012, 129(384): 90.
- [11] LI Xu-qing, LIU Xiang-nan, LIU Mei-ling, et al(李旭青, 刘湘南, 刘美玲, 等). Journal of Remote Sensing(遥感学报), 2014, 18(4): 923.
- [12] WANG Ren-hong, SONG Xiao-yu, LI Zhen-hai, et al(王仁红, 宋晓宇, 李振海, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2014, 30(19): 191.
- [13] Yoshio Inoue, Eiji Sakaiya, Yan Zhu, et al. Remote Sensing of Environment, 2012, 126(6829): 210.

Research of Method for Inverting Nitrogen Content in Canopy Leaves of Japonica Rice in Northeastern China Based on Hyperspectral Remote Sensing of Unmanned Aerial Vehicle

FENG Shuai¹, XU Tong-yu^{1, 2, *}, YU Feng-hua^{1, 2}, CHEN Chun-ling^{1, 2}, YANG Xue¹, WANG Nian-yi¹

1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110161, China

2. Liaoning Agricultural Information Technology Center, Shenyang Agricultural University, Shenyang 110161, China

Abstract In order to explore a better hyperspectral inversion model for monitoring nitrogen content in rice canopy leaves by remote sensing, based on rice plot experiments, the canopy height spectral data of rice at different growth stages were obtained. Based on the comprehensive comparison of the first derivative (1-Der), standard normal variable transformation (SNV) and SG smoothing method, a spectral processing method (SNV-FDSGF) combining standard normal variable transformation with SG filtering method of first derivative was proposed. The sensitive bands of different growth stages were screened out by non-information variable - competitive adaptive reweighted sampling method (UVE-CARS). Two sensitive bands of each growth period were randomly combined to construct a difference spectrum index DSI (difference spectral index), a ratio spectral index RSI (ratio vegetation index) and a normalized spectrum index NDSI (normalized difference spectral index) with high correlation with nitrogen content in rice leaves. Among them, the optimal vegetation index and determination coefficient R^2 at the tillering, jointing and heading stages were: $DSI(R_{857}, R_{623})$, 0.704; $DSI(R_{670}, R_{578})$, 0.786; $DSI(R_{995}, R_{508})$, 0.754. Using the superior three planting indices in each growth period as inputs, the adaptive differential optimization extreme learning machine (SaDE-ELM), radial basis function (RBF-NN) and particle swarm optimization BP neural network (PSO-BPNN) inversion models were constructed respectively. The results showed that SaDE-ELM had the best modeling effect. Compared with RBF-NN and PSO-BPNN, the stability and prediction ability of the model were significantly improved. The determination coefficient R^2 of training set and verification set of each growth phase inversion model was above 0.810 and RMSE was below 0.400, which could provide certain theoretical basis for quantitative prediction of nitrogen content in rice canopy leaves.

Keywords Rice; Nitrogen; Unmanned aerial vehicle; Hyperspectral processing; Vegetation index; Inversion model

(Received May 8, 2018; accepted Oct. 30, 2018)

* Corresponding author