

冬小麦叶面积指数高光谱遥感反演方法对比

夏天^{1,2}, 吴文斌^{1,2}, 周清波^{1,2*}, 周勇³

(1. 农业部农业信息技术重点实验室, 北京 100081;
2. 中国农业科学院农业资源与农业区划研究所, 北京 100081;
3. 华中师范大学城市与环境科学学院, 武汉 430079)

摘要: 冬小麦叶面积指数 (LAI, leaf area index) 是评价其长势和预测产量的重要农学参数, 高光谱遥感能够实现快速无损地监测叶面积指数。该文旨在将田间监测与高光谱遥感相结合, 探索研究不同冬小麦叶面积指数高光谱反演方法的模拟精度及适应性。针对国际上普遍应用的 2 种高光谱遥感反演 LAI 模型方法, 即回归分析法和 BP 神经网络法, 在介绍 2 种 LAI 反演模型的基础上, 选择位于黄淮海平原的山东省济南市长清区为研究区域, 通过 ASD 地物光谱仪和 SunScan 冠层分析系统对冬小麦的冠层光谱及 LAI 变化进行田间观测, 然后利用回归分析法和 BP 神经网络法构建冬小麦 LAI 反演模型, 将模型估算 LAI 值和田间观测 LAI 值进行比对, 分析评价 2 种方法的反演精度。结果表明, BP 神经网络法较回归分析法估算冬小麦 LAI 的精度有较大提高, 检验方程的决定系数 (R^2) 为 0.990、均方根误差 (RMSE) 为 0.105。利用 BP 神经网络法构建反演模型能较好的对冬小麦 LAI 进行反演。研究结果可为不同冬小麦长势遥感监测提供理论和技术上的支持, 并为大尺度传感器监测冬小麦长势和估产提供参考。

关键词: 遥感, 回归分析, 神经网络, 估算, LAI, 冬小麦, 反演方法

doi: 10.3969/j.issn.1002-6819.2013.03.019

中图分类号: S127

文献标志码: A

文章编号: 1002-6819(2013)-03-0139-09

夏天, 吴文斌, 周清波, 等. 冬小麦叶面积指数高光谱遥感反演方法对比[J]. 农业工程学报, 2013, 29(3): 139-147.

Xia Tian, Wu Wenbin, Zhou Qingbo, et al. Comparison of two inversion methods for winter wheat leaf area index based on hyperspectral remote sensing[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2013, 29(3): 139-147. (in Chinese with English abstract)

0 引言

叶面积指数 (LAI, leaf area index) 是指单位面积上植物叶片的垂直投影面积的总和^[1]。传统地面测量法获取大范围农作物 LAI 效率低、成本高, 遥感技术的快速发展可以实现大区域 LAI 的快速、高效监测, 为实时了解农作物生长状态、预测粮食安全状况提供有效途径^[2-3]。国内外很多学者分别从不同角度和方法出发进行了农作物 LAI 遥感反演研究。如部分学者选取不同敏感波段来减少土壤等背景环境因素影响, 建立植被指数 (VI, vegetation

index) 与 LAI 参数的函数关系, 利用回归分析法进行 LAI 参数反演^[4-8]; 部分学者通过改进植被指数来构建回归模型, 以期提高模型估算作物 LAI 的精度^[9-12]; 还有一些学者利用反向传播神经网络 (BPNN, back propagation neural network) 来构建作物农学参数反演模型, 筛选光谱参数作为模型输入, LAI 作为模型模拟输出进行反演研究^[13-15]。统计模型相对比较简单, 适用性强, 但 LAI-VI 的关系不够确定, 对于非线性解释不足。而神经网络对非线性问题的拟合有着无可比拟的优势, 但是神经网络模型也有它自身的缺陷, 在模型建立过程中一定要保证样本量足够大, 才能有效的对模型进行训练与测试, 保证研究具有一定的普适性^[16]。除了常规的宽波段遥感数据外, 利用高光谱数据进行作物 LAI 估算研究日益受到学者的广泛关注, 利用高光谱遥感数据波段窄和连续的特点, 可以构建许多对叶面积指数相对敏感的 VI, 或将常规的 VI 指数变为连续的形式^[17], 叶面积指数高光谱遥感反演方法的比对研究成为定量遥感和精准农业的热点问题^[18-19], 同时不同地区、不同环境中的植被 LAI 对高光谱的敏感波段不尽相同, 植被指数在不同环

收稿日期: 2012-07-06 修订日期: 2012-12-24

基金项目: 国家自然科学基金项目(40971218 和 41201089); 国家高技术研究发展计划("863"计划)项目(2009AA122003 和 2012AA12A304); 农业部农业信息技术重点实验室开放基金项目(2011002)和农业部农业科研杰出人才基金项目资助

作者简介: 夏天 (1981-), 男, 湖北武汉人, 博士, 主要研究方向为农业遥感、资源环境等。北京 农业部农业信息技术重点实验室, 100081。Email: xiatianhau@gmail.com

*通信作者: 周清波 (1965-), 男, 湖南沅江人, 研究员, 博士生导师, 主要从事农情遥感领域的基础研究和应用基础研究。北京 农业部农业信息技术重点实验室, 100081。Email: zhouqb@mail.caas.net.cn

境的适应性也不同。基于此,本研究选取黄淮海平原山东省的济南市长清区为研究区,以冬小麦作为研究对象,利用回归模型法和 BP 神经网络法构建区域冬小麦 LAI 估算模型,比对 2 种不同反演方法的精度,研究结果可为不同冬小麦长势遥感监测提供理论和技术上的支持,并为大尺度传感器监测冬小麦长势和估产提供参考。

1 数据来源和预处理

1.1 田间测量

本研究选取山东省济南市长清区 (116°47 E,

36°37 N) 为研究区,该地区地处中纬度地带,境内土壤主要为棕壤、褐土、潮土和风沙土,由于受太阳辐射、大气环流和地理环境的影响,属于暖温带半湿润大陆性季风气候。其特点是季风明显,四季分明,春季干旱少雨,夏季炎热多雨,秋季较为干燥,冬季气温低。年平均气温 14.3℃,极端气温最高 40.5℃,最低-14.9℃,年平均降水量 660.7 mm。试验样区内选取 3 个不同品种的冬小麦(泰农 18 号、临麦 2 号和稳千 1 号)设置 8 个中心监测样点(如图 1 所示),样点田间行距为 2.57~3.07 m,行间距为 0.45~0.49 m^[20]。

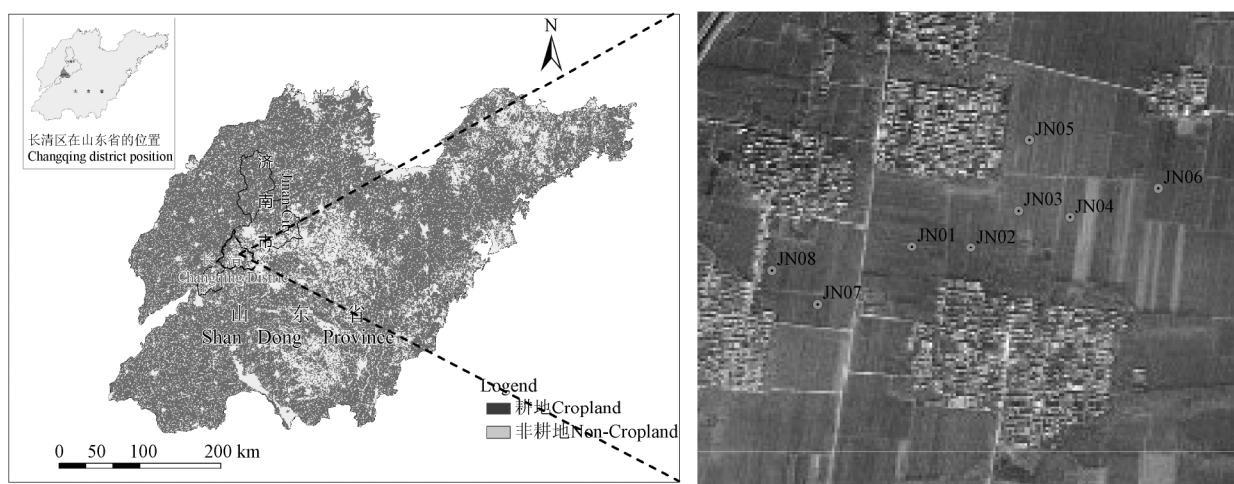


图 1 研究区样点分布图(影像源自 Google Earth)

Fig.1 Distribution map of winter wheat surveyed (Image from Google Earth)

2010 年 3 月至 2010 年 6 月,对冬小麦的冠层光谱反射率和 LAI 进行同步田间监测,跨越冬小麦拔节期、抽穗期、灌浆期和成熟期。以监测样点为中心,分别在东西南北中 5 个方位(各点与中心点相距 30 m)选用 ASD Fieldspec 3 光谱仪测量冬小麦冠层光谱反射率,监测均在天气晴朗、无风或者风速较小时进行,测定时间为 10:00—14:00 之间。监测时光纤探头离地表 120 cm 进行垂直测定,在视场范围内重复 10 次采集,并进行平均化处理,共获取 160 组光谱数据。各监测点在测量前均进行标准白板校正(标准白板反射率为 1,所得目标物光谱为无量纲的相对反射率)。LAI 采用英国 Delta 公司生产的 SunScan 冠层分析系统测定, SunScan 是一种利用间接测量法观测叶面积指数(LAI)的仪器,通过给定反映植被几何特征的椭球体叶倾角分布参数(ELADP),测量透射率获得 LAI。每个监测点采集 LAI 时采用 2 种方法,一种是斜穿于行法(垂直穿越作物行和垄),一种是平行于行法(平行于行测量只在作物行进行,不靠近垄)。2 种方法各做 3 次平行采集,然后再通过算数平均法获得该监

测点的 LAI,以消除由于不同种植方式引起的测量误差,最终获取与光谱相对应的 160 组 LAI 数据。

1.2 室内数据预处理

田间测量的冬小麦冠层光谱数据按采样时间、采样点和采样方位等进行分类,然后利用 ViewSpec 软件进行预处理。为减弱噪声对实际光谱数据的影响,对原始的高光谱数据进行噪声去除处理,将 350~2 500 nm 光谱范围内水汽吸收带 1 400、1 900 及 2 500 nm 等附近的噪声数据进行剔除,使光谱数据有利于进行数学建模分析。

冬小麦 LAI 观测数据分类方法和高光谱数据处理方法相同,每一个方位测定的冬小麦 LAI 数据进行均值处理。冬小麦在每一个生育期内变化不是特别明显,而相互之间有较明显差异,故选取冬小麦变化特征明显的 4 个生育期(拔节期、抽穗期、灌浆期和成熟期)中天气状况较好并能代表冬小麦当时生长状况的 4 个时间点监测数据进行研究。图 2 反映了研究区域冬小麦主要生育期 LAI 的变化态势,冬小麦 LAI 在其生育期内呈抛物线变化。当冬小麦处于拔节期时,冬小麦刚开始长出间节,覆盖

度较低, LAI 在 0.82~1.05 之间。随着温度的升高, 冬小麦开始不断生长, LAI 不断增加。进入抽穗期时, 冬小麦的长势较好, 叶片的生长状况在整个生育期中属于最好时期, 冬小麦 LAI 在整个生育期中处于峰值, 其中临麦 2 号的 LAI 为 5.87, 稳千 1 号和泰农 18 号分别为 5.03 和 3.70。随着生育期的推移, 进入灌浆期至成熟期时, 冬小麦叶片中的营养不断的供给麦穗, 下部叶片逐渐衰老脱落, 田间叶片的覆盖度降低, 临麦 2 号 LAI 降至 3.33, 稳千 1 号和泰农 18 号 LAI 降至 2.50~3.20 之间。




图 2 冬小麦叶面积指数 LAI 动态变化特征 (2010)
Fig.2 Variation characteristics of winter wheat LAI at different growth stages (2010)

2 研究方法

2.1 回归分析法

本研究以冬小麦 LAI 为因变量, 以高光谱遥感数据为自变量, 进行回归分析, 构建 LAI 反演的回归模型。由于高光谱遥感数据具有波段窄和连续的特点, 可以构建许多对植株 LAI 相对敏感的植被指数, 这种由高光谱数据产生的植被指数能够精确地表达植物内部物质吸收和散射的波形, 有助于提高高光谱数据表达 LAI 信息的精度。本研究利用 SPSS 软件统计分析功能进行冬小麦冠层光谱反射率与 LAI 相关性分析, 找出光谱敏感区域并计算植被指数, 然后将植被指数与冬小麦 LAI 建立回归模型, 确定拟合度高、误差小的冬小麦 LAI 回归反演模型。

各种植被指数和 LAI 的关系具有地域性和时效性, 结合研究区域冬小麦生育期光谱反射率变化特征, 选取以下 6 种植被指数 (表 1) 来构建冬小麦 LAI 的估算模型。其中, 比值植被指数 (RVI) 是绿色植物的敏感参数, 可以及时反映出作物 LAI 的变化。植被覆盖度影响 RVI, 当植被覆盖度较高时, RVI 对植被十分敏感; 当植被覆盖度 < 50% 时, 这种敏感性显著降低。归一化植被指数 (NDVI) 可以消除大部分与仪器定标、太阳角、地形、云阴影和大气条件相关辐射照度变化的影响, 常用于研究植被生长状态及覆盖度。差值植被指数 (DVI) 对土

壤背景的变化较 RVI 敏感, 植被覆盖度高时, 对植被的敏感度有所下降, 适宜于冬小麦初期的植被覆盖研究; 而绿波段指数 (GRVI) 在 LAI 超过 3.0 后对植被变化有较好的敏感性。EVI 与 NDVI 相比敏感度较高; 土壤调整植被指数 (SAVI) 降低了土壤背景的影响, 用于解释背景的光学特征变化并修正 NDVI 对土壤背景的敏感, 改善了植被指数与叶面积指数 LAI 的线性关系。与 NDVI 相比, 增加了土壤调节系数 L , 取值范围为 0~1, 本研究确定土壤调节系数 L 为 0.5。

表 1 本研究采用的高光谱植被指数列表
Table 1 Hyperspectral vegetation indices

高光谱植被指数	表达式
比值植被指数(RVI)	$RVI = NIR/Red^{[21]}$
差值植被指数(DVI)	$DVI = NIR - Red^{[22]}$
归一化植被指数(NDVI)	$NDVI = (NIR - Red)/(NIR + Red)^{[23]}$
绿波段指数(GRVI)	$GRVI = NIR/Green - 1^{[24]}$
环境植被指数(EVI)	$EVI = 2.5 \times \frac{NIR - Red}{NIR + 6 \times Red - 7.5 \times Blue + 1}^{[25]}$
土壤调整植被指数(SAVI)	$SAVI = \left(\frac{NIR - Red}{NIR + Red + L} \right) (1 + L)^{[26]}$

注: NIR 为近红外波段反射率; Red 为红光波段反射率; Green 为绿光波段反射率; Blue 为蓝光波段反射率; L 为土壤调节系数。

Note: NIR is near infrared band reflectance; Red is red band reflectance; Green is green band reflectance; Blue is blue band reflectance; L is soil adjustment coefficient.

2.2 神经网络法

BP (back propagation) 网络是 1986 年由 Rumelhart 和 McClelland 为首的科学家小组提出, 是一种按误差逆传播算法训练的多层前馈网络, 是目前应用最广泛的神经网络模型之一。BP 算法是一种有监督式的学习算法, 基本思想是: 若利用已有权重和阈值正向传播得不到期望的输出, 则反向传播反复修改 (迭代) 各节点的权重和阈值, 逐步减小代价函数, 直到达到预先设定的要求。一般以代价函数小于某一相当小的正数或迭代不再减小, 则停止反复振荡, 此时完成 BP 网络的训练及输入与输出之间映射关系的确定^[27]。BP 神经网络 (BPNN) 能学习和存贮大量的输入—输出模式映射关系, 而无需事前揭示描述这种映射关系的数学方程。

BP 神经网络模型拓扑结构包括输入层 (input)、隐藏层 (hide layer) 和输出层 (output layer), 本研究通过对高光谱反射率与冬小麦 LAI 进行相关性分析, 然后将冬小麦 LAI 变化敏感光谱区域的反射率输入 BP 神经网络模型的输入层, 通过多次调试构建 LAI 反演模型, 最后将预测数据与实测数据对比进行检验, 利用多元决定系数 (R^2) 和均方根误差 (RMSE, root mean square error) 对模型预测精度

进行分析。

2.3 比对分析方法

本研究采用回归分析法和 BP 神经网络法构建冬小麦 LAI 反演模型, 将 2 种模型反演的冬小麦 LAI 与地面实测值进行拟合, 采用多元决定系数 (R^2) 和均方根误差 (RMSE) 对模型进行精度检验, 对比 2 种方法的反演精度。

3 结果与分析

3.1 植被指数计算及相关性分析

冬小麦冠层高光谱反射率与 LAI 相关性分析结果如图 3 所示, 在可见光波段 (350~760 nm), 冬小麦冠层高光谱反射率与 LAI 总体表现为呈负相关, 可见光绿光波段 (500~560 nm), 由于叶绿素强吸收带的影响出现一个小波峰。红光波段 (620~720 nm) 呈负相关, 最低达到 -0.70 左右; 720 nm 附近相关系数迅速接近于 0; 720~760 nm 波段区间, 冬小麦冠层高光谱反射率与 LAI 呈正相关, 相关系数随着波长不断增加, 达到 0.65, 此区域色素对光能的吸收逐渐减弱, 而细胞结构对光的反射开始增强。近红外区域 (760~1 000 nm), 对冠层及叶片结构表现最为敏感^[28], 高光谱反射率与 LAI 相关性比较平稳, 维持在 0.65 左右。根据冠层光谱与 LAI 相关性分析, 本研究选取对光谱变化较为敏感的可见光蓝光 (Blue)450 nm、绿光波峰 (Green)550 nm、红光波谷 (Red)670 nm 及近红外 (NIR)870 nm 等波段光谱反射率计算植被指数^[29]。




图3 冬小麦高光谱反射率与 LAI 的相关性

Fig.3 Correlation between spectral reflectance and LAI

本研究选取的 6 种植被指数 (表 1) 都采用对冬小麦 LAI 敏感光谱波段反射率计算, 以便于后期的对比分析。将 6 种植被指数与随机选取的 53 组数据冬小麦 LAI 进行相关性分析, 结果如表 2 所示, 可以看出, 冬小麦 LAI 与 RVI、DVI、NDVI、GRVI、EVI 和 SAVI 的相关系数在 0.771~0.813 之间, 相关性均较高。根据统计学的划定, 相关系数 $|r| \geq 0.8$ 时, 视为高度相关; $0.5 \leq |r| < 0.8$ 时, 视为中度相关; $0.3 \leq |r| < 0.5$ 时, 视为低度相关; $|r| < 0.3$ 时, 说明变

量之间相关程度极弱, 可视为不相关。从结果上看分析, NDVI 与冬小麦 LAI 的相关性极高; RVI、DVI、GRVI、EVI 和 SAVI 与冬小麦 LAI 属于中度相关。这说明这几种植被指数都能够较好的反应冬小麦 LAI 变化, 可以用来构建反演模型。

表 2 冬小麦 LAI 与植被指数的相关系数
Table 2 Correlation coefficient between LAI and vegetation indices

参数	植被指数					
	RVI	DVI	NDVI	GRVI	EVI	SAVI
LAI	0.780**	0.759**	0.813**	0.774**	0.771**	0.772**

注: ** 表示在 0.01 水平 (双侧) 上显著相关; 样本数为 53。

Note: ** indicates significant correlation at 0.01 level; Sample number is 53.

3.2 基于回归模型的冬小麦 LAI 估算

为综合比较 6 种植被指数构建的回归模型对冬小麦 LAI 估算的效果, 将 6 种植被指数与冬小麦 LAI 进行拟合, 不同类型的回归模型对结果精度存在一定影响, 这里以决定系数 R^2 和回归剩余残差 RMSE (root mean square error) 作为评价指标, 通过选取拟合度较高、相对误差较小的模型为最终估算模型, 以期模拟结果更加接近实际值。本研究从监测样点中选取 38 组样点数据进行模型的构建, 拟合结果如图 4, 可以看出, 6 种拟合模型都能较好反映冬小麦生育期 LAI 与植被指数之间的变化关系, 构建的冬小麦 LAI 估算模型精度均较好, 决定系数 (R^2) 为 0.696~0.775 之间, RMSE 在 0.386~0.523 之间, 其中 NDVI、RVI 和 GRVI 拟合度较高, 误差较小。6 种植被指数构建的反演模型均为非线性模型, 其主要原因是整个生育期中 LAI 与植被指数之间呈非线性变化。RVI 在 LAI 较小时对植被敏感度较低, LAI 小于 2 时, RVI 没能反应出 LAI 变化, 随着冬小麦的生长, RVI 对植被敏感度升高, LAI 随着 RVI 升高呈正相关变化较为明显。GRVI 利用绿波段代替红波段, 对植被叶绿素具有较高的敏感性。LAI 大于 3 时, 能够较好的反映出 LAI 的变化。NDVI 能够反映出植被覆盖度和消除部分辐射误差等, 与 RVI 一样增强了土壤与植被的反射对比, 对于同一植被研究 RVI 和 NDVI 时, RVI 值增加速度高于 NDVI 增加速度, 即 NDVI 对于 LAI 较高时灵敏度较低。研究发现在 NDVI 接近 1 时, 模型出现了饱和现象, 但相对其他 5 种模型, 模型的拟合度和误差均相对较优。DVI、EVI 和 SAVI 这 3 种植被指数考虑到土壤、大气等周围环境因素的影响, 同时在 LAI 升高时一定程度缓解饱和现象的过早出现, 但模型的拟合度不佳, 估算误差相对较大。

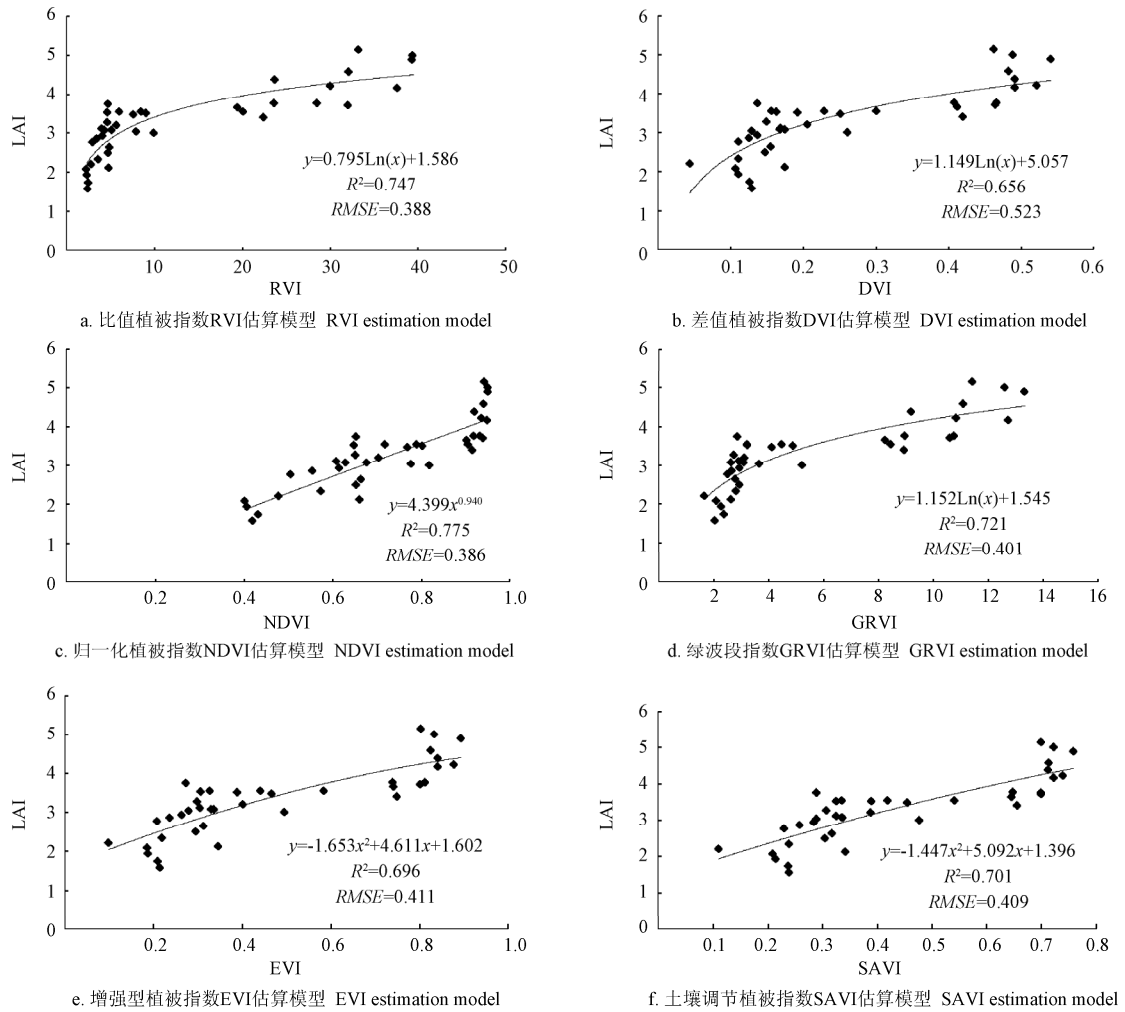


图 4 各种植被指数拟合的叶面积指数 LAI 估算模型

Fig.4 LAI estimation models with different vegetation indices

3.3 基于 BP 神经网络的冬小麦 LAI 估算

BP 神经网络模型拓扑结构包括输入层(input)、隐藏层 (hide layer) 和输出层 (output layer)。通常植被指数所包含的波段有一定的局限性，不同光谱波段之间的优势互补无法实现，因此本研究确定输入层为多个波段的光谱反射率，选用对冬小麦 LAI 变化较为敏感的可见光蓝光 450 nm 波段、绿光波峰 550 nm、红光波谷 670 nm 及近红外波段 870 nm 的反射率，作为模型输入矢量 P；输出层即为冬小麦 LAI；确定隐藏层为 1 层，隐藏层的节点数在试验中不断调整，经过多次试验，17 个神经元为最佳。本研究为了保证模型足够大的样本数（一般认为样本数 $n>50$ 即为大样本事件），在回归模型选取的 53 组数据中，新增了 18 组样区其他样点数据作为检验样本数据，即在 71 组冬小麦 LAI 数据中选取 53 组作为学习目标 T，剩余样本作为检验数据。初始训练速率为 0.5，初始权重和阈值为任意值。通过 BP 神经网络得到预测 LAI 数据，并利用实测值与模拟值进行线性拟合（如图 5），拟合

度达到 0.990，说明反演模型构建精度较高。

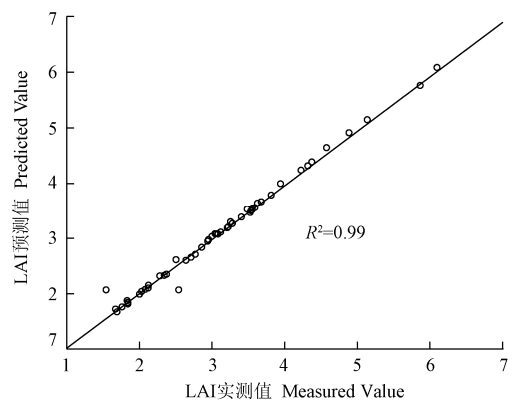


图 5 BP 神经网络模拟与实测叶面积指数 LAI

Fig.5 BP neural network simulated and measured LAI

3.4 LAI 反演精度比对

为了比较上述 2 种方法预测 LAI 的适应性和精确度，首先选取长清样区其他田块采集的 15 组数据进行回归估算模型精度测试，将测试数据代入估

算模型对冬小麦 LAI 估算进行检验,采用均方根误差法 (RMSE) 对模拟值和实际值的符合度进行了检验 (图 6)。结果显示 6 种植被指数模型精度检验 RMSE 在 0.468~0.501 之间,其中 NDVI 估算模型的 RMSE 相对最小为 0.468,其次是 GRVI 估算模型的 RMSE 为 0.478。DVI、EVI、SAVI 模型的

RMSE 均在 0.48 左右,RVI 估算模型的 RMSE 相对最大为 0.501。仅从验证的结果来看,这几种植被指数都能较好的进行模拟,模拟误差均较小。综合分析模型拟合度和均方根误差,NDVI 估算模型较其他几种植被指数估算模型,无论是模型拟合度还是模型预测精度都比较好。

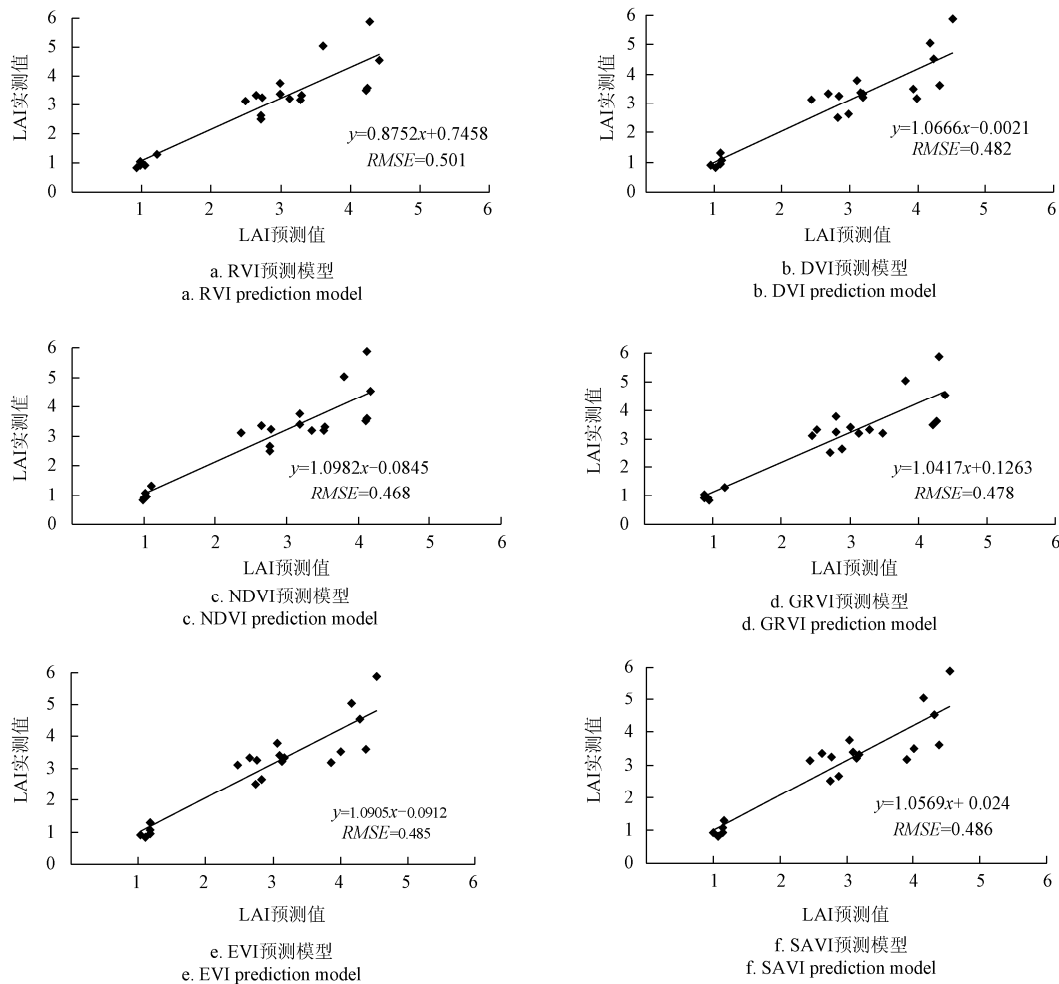


图 6 样区植被指数预测模型检验

Fig.6 Comparison between estimated and observed LAI

通过 BP 神经网络法构建冬小麦 LAI 反演模型,其中输入的 4 个波段的光谱反射率中,红光波段对结果的重要程度最高,其次是近红外波段和绿光波段。原因是由于红光波段是叶绿素强吸收波段,对叶绿素的变化较为敏感,同时红光波段与冬小麦 LAI 相关性也最高。近红外波段为叶绿素强反射波段,与冬小麦 LAI 相关性相对较高,故在红光波段和近红外波段的反射率对 BP 神经网络模拟 LAI 的精度有较大影响。对 BP 神经网络模型进行精度验证,结果显示 BP 神经网络法进行冬小麦 LAI 反演的精度较高,均方根误差 (RMSE) 仅为 0.105。如图 7 所示,模拟值与实际值之间误差较小,由此可见 BP 神经网络法相对传统的回归预测模型精度有

很大的提高。

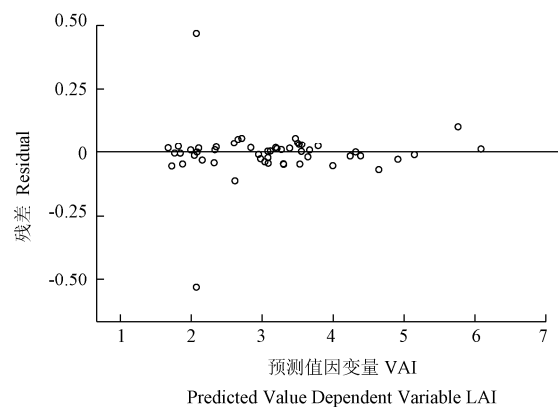


图 7 BP 神经网络估测冬小麦 LAI 误差

Fig.7 BP neural network estimating winter wheat LAI error

4 结 论

1) RVI、DVI、NDVI、GRVI、EVI 和 SAVI 这 6 种植被指数与冬小麦 LAI 关系密切, 相关性均达到了显著水平。利用回归分析构建估算模型, 模型拟合度在 0.696~0.775 之间, RMSE 在 0.386~0.523 之间, 其中 NDVI、RVI 和 GRVI 拟合度较高, 拟合误差较小。经模型精度检验 RMSE 为 0.468~0.501, NDVI 估算模型的 RMSE 为 0.468 相对最小, 其次是 GRVI 估算模型的 RMSE 为 0.478。但是在 LAI<2 时, RVI 和 GRVI 无法有效的反映出 LAI 的变化; 在 NDVI 接近于 1 时出现了较明显的饱和现象, 同时引起冬小麦 LAI 低估现象。综合分析 6 种模型的模拟及验证情况, 在冬小麦生长的不同阶段, 这 6 种植被指数各有优势和不足, 在尽可能避免 NDVI 出现饱和的情况下, NDVI 估算模型无论是模型拟合度还是模型验证精度都较好, 适合进行该地区冬小麦 LAI 反演。

2) 利用 BP 神经网络输入多个敏感波段反射率进行冬小麦 LAI 估算, 较大提高了反演精度。输入的多个敏感波段包含了蓝光 450 nm 波段、绿光波峰 550 nm、红光波谷 670 nm 及近红外波段 870 nm 4 个波段, 这些波段对冬小麦的变化均较敏感, 并与冬小麦 LAI 相关性较高。经检验, 模拟值与实测值拟合度高达 0.990, 均方根误差(RMSE)为 0.105。利用 BP 神经网络法比传统回归模型估测冬小麦 LAI 精度有较大提高, 由于神经网络的方法具有较好的非线性解释性, 有效的避免因植被指数饱和引起的冬小麦 LAI 低估现象。

本研究在利用高光谱数据进行作物 LAI 估算方面进行了尝试, 为冬小麦 LAI 的高精度估算提供了科学依据。研究发现 BP 神经网络方法较传统回归模型法较适合进行冬小麦 LAI 反演研究, 很大程度上提高了模型的反演精度, 但还存在一些不足, 在建立模型过程中一定要保证样本量足够大(一般认为样本数 $n>50$ 即为大样本事件), 才能保证研究的适普性。同时 BP 神经网络如果增加了学习样本, 训练好的网络就需要从头开始训练, 对于以前的权值和阈值是没有记忆的, 神经网络相对传统的回归模型在实用性方向有待进一步研究。笔者认为传统的回归模型和新兴的 BP 神经网络模型在冬小麦 LAI 反演研究中各有优势和不足, 冬小麦 LAI 反演研究应根据研究情况来选择适合模型才是关键。另外本研究在大田中测量, 由于种植方式、肥力状况、管理水平等的差异, 可能会对冬小麦的光谱特征产生一定影响, 模型是否适合其他更广阔的区域有待进一步验证。

[参 考 文 献]

- [1] 陈拉, 黄敬峰, 王秀珍. 不同传感器的模拟植被指数对水稻叶面积指数的估测精度和敏感性分析[J]. 遥感学报, 2008, 12(1): 143—151.
Chen La, Huang Jingfeng, Wang Xiuzhen. Estimating accuracies and sensitivity analysis of regression models fitted by simulated vegetation indices of different sensors to rice LAI[J]. Journal of Remote Sensing, 2008, 12(1): 143—151. (in Chinese with English abstract)
- [2] 王伟, 彭彦昆, 马伟, 等. 冬小麦叶绿素含量高光谱检测技术[J]. 农业机械学报, 2010, 41(5): 172—177.
Wang Wei, Peng Yankun, Ma Wei, et al. Prediction of chlorophyll content of winter wheat using leaf-level hyperspectral data[J]. Transactions of the Chinese Society For Agricultural Machinery, 2010, 41(5): 172—177. (in Chinese with English abstract)
- [3] 杨邦杰, 裴志远. 农作物长势的定义与遥感监测[J]. 农业工程学报, 1999, 15(3): 214—218.
Yang Bangjie, Pei Zhiyuan. Definition of crop condition and crop monitoring using remote sensing[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 1999, 15(3): 214—218. (in Chinese with English abstract)
- [4] Darvishzadeh R, Skidmore A, Schlerf M. LAI and chlorophyll estimation for a heterogeneous grassland using hyperspectral measurements[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2008, 63(4): 409—426.
- [5] Darvishzadeh R, Skidmore A, Atzberger C. Estimation of vegetation LAI from hyperspectral reflectance data: Effects of soil type and plant architecture[J]. International Journal of Applied Earth Observation and Geoinformation, 2008, 10(3): 358—373.
- [6] Darvishzadeh R, Atzberger C, Skidmore A K. Leaf Area Index derivation from hyperspectral vegetation indices and the red edge position[J]. International Journal of Remote Sensing, 2009, 30(23): 6199—6218.
- [7] Haboudanea D, Millera J R, Pattey E. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture[J]. Remote Sensing of Environment, 2004, 90(3): 337—352.
- [8] Zhao D H, Yang T W, An S Q. Effects of crop residue cover resulting from tillage practices on LAI estimation of wheat canopies using remote sensing[J]. International Journal of Applied Earth Observation and Geoinformation, 2012, 14(1): 169—177.
- [9] 唐延林, 王秀珍, 王福民, 等. 农作物 LAI 和生物量的高光谱法测定[J]. 西北农林科技大学学报: 自然科学版, 2004, 32(11): 100—104.
Tang Yanlin, Wang Xiuzhen, Wang Fumin, et al. Study on the determination of LAI and biomass of crop by hyperspectral[J]. Journal of Northwest Sci-Tech University of Agriculture and Forestry, 2004, 32(11): 100

- 104. (in Chinese with English abstract)
- [10] 姚付启, 蔡焕杰, 王海江, 等. 基于平稳小波变换的冬小麦覆盖度高光谱监测[J]. 农业机械学报, 2012, 43(3): 173—180.
Yao Fuqi, Cai Huanjie, Wang Haijiang, et al. Monitoring winter wheat percentage vegetation cover based on stationary wavelet transformation derived from hyperspectral reflectance[J]. Transactions of the Chinese Society For Agricultural Machinery, 2012, 43(3): 173—180. (in Chinese with English abstract)
- [11] 刘占宇, 黄敬峰, 王福民, 等. 估算水稻叶面积指数的调节型归一化植被指数[J]. 中国农业科学, 2008, 41(10): 3350—3356.
Liu Zhanyu, Huang Jingfeng, Wang Fuming, et al. Adjusted-normalized difference vegetation index for estimating leaf area index of rice[J]. Scientia Agricultura Sinica, 2008, 41(10): 3350—3356. (in Chinese with English abstract)
- [12] Wang F M, Huang J F, Zhou Q F, et al. Optimal waveband identification for estimation of leaf area index of paddy rice[J]. Journal of Zhejiang University Science B, 2008, 9(12): 953—963.
- [13] 孙焱鑫, 王纪华, 李保国, 等. 基于 BP 和 GRNN 神经网络的冬小麦冠层叶绿素高光谱反演建模研究[J]. 遥感技术与应用, 2007, 22(4): 492—496.
Sun Yanxin, Wang Jihua, Li Baoguo, et al. Contrastive analysis based on neural network of winter wheat's chlorophyll concentration inversion with hyperspectral data[J]. Remote Sensing Technology and Application, 2007, 22(4): 492—496. (in Chinese with English abstract)
- [14] 宋开山, 张柏, 王宗明. 基于人工神经网络的大豆叶面积高光谱反演研究[J]. 中国农业科学, 2006, 39(6): 1138—1145.
Song Kaishan, Zhang Bai, Wang Zongming. Soybean LAI estimation with in-situ collected hyperspectral data based on BP-neural networks[J]. Scientia Agricultura Sinica, 2006, 39(6): 1138—1145. (in Chinese with English abstract)
- [15] 王大成, 王纪华, 靳宁. 用神经网络和高光谱植被指数估算小麦生物量[J]. 农业工程学报, 2008, 24(增刊 2): 196—201.
Wang Dacheng, Wang Jihua, Jin Ning. ANN-based wheat biomass estimation using canopy hyperspectral vegetation indices[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2008, 24(Supp.2): 196—201. (in Chinese with English abstract)
- [16] Gong P, Wang D X, Liang S. Inverting a canopy reflectance model using a neural network[J]. International Journal of Remote Sensing, 1999, 20(1): 111—122.
- [17] 邢著荣, 冯幼贵, 李万明, 等. 高光谱遥感叶面积指数(LAI)反演研究现状[J]. 测绘科学, 2010, 35(增刊): 162—164.
Xing Zhurong, Feng Youguai, Li Wanming, et al. The research status of inversion of leaf area index with hyperspectral remote sensing[J]. Science of Surveying and Mapping, 2010, 35(Supp.): 162—164. (in Chinese with English abstract)
- [18] Kuusk A, Lang M, Nilson T. Simulation of the reflectance of ground vegetation in sub-boreal forests[J]. Agricultural and Forest Meteorology, 2004, 126(1/2): 33—46.
- [19] Fang H L, Liang S L. A hybrid inversion method for mapping leaf area index from MODIS data: experiments and application to broad leaf and needle leaf canopies[J]. Remote Sensing of Environment, 2005, 94(3): 405—424.
- [20] 夏天. 基于高光谱遥感的区域冬小麦生物量模拟及粮食安全评价[D]. 武汉: 华中师范大学, 2011.
Xia Tian. Regional Wheat Biomass Simulation and Food Safety Evaluation that Based on Hyperspectral Remote Sensing[D]. Wuhan: Central China Normal University, 2011. (in Chinese with English abstract)
- [21] Anderson G L, Hanson J D, Haas R H. Evaluating landsat thematic mapper derived vegetation indices for estimating above-ground biomass on semisrid rangelands[J]. Remote sensing of Environment, 1993, 45(2): 165—175.
- [22] Richardson A J, Wiegand CL. Distinguishing vegetation from soil background information[J]. Photogrammetric Engineering and Remote Sensing, 1977, 43(12): 1541—1552.
- [23] Miller J R, Hare E W, Wu J. Quantitative characterization of the vegetation red edge reflectance 1. An inverted-Gaussian reflectance model[J]. International Journal of Remote Sensing, 1990, 11(10): 1755—1773.
- [24] Gitelson A A, Kaufman Y, Merzlyak M N. Use of Green Channel in Remote of Sensing Global Vegetation from EOS-MODIS[J]. Remote Sensing of Environment, 1996, 58(3): 289—298.
- [25] Huete A R, Justice C, Liu H. Development of Vegetation and Soil Indices for MODIS-EOS [J]. Remote Sensing of Environment, 1994, 49(3): 224—234.
- [26] Huete A R. A soil vegetation adjusted index(SAVI)[J]. Remote sensing of Environment, 1988, 25: 295—309.
- [27] 李朝峰, 曾生根, 许磊. 遥感图像智能处理[M]. 北京: 电子工业出版社, 2007.
- [28] 冯伟, 朱艳, 田永强, 等. 基于高光谱遥感的小麦叶片氮积累量[J]. 生态学报, 2008, 28(1): 23—32
Feng Wei, Zhu Yan, Tian Yongqiang, et al. Monitoring leaf nitrogen accumulation with hyper-spectral remote sensing in wheat[J]. Acta Ecologica Sinica, 2008, 28(1): 23—32. (in Chinese with English abstract)
- [29] 夏天, 吴文斌, 周清波, 等. 基于高光谱的冬小麦叶面积指数估算方法[J]. 中国农业科学, 2012, 45(10): 2085—2092.
Xia Tian, Wu Wenbin, Zhou Qingbo, et al. An estimation method of winter wheat leaf area index based on hyperspectral data[J]. Scientia Agricultura Sinica, 2012, 45(10): 2085—2092. (in Chinese with English abstract)

Comparison of two inversion methods for winter wheat leaf area index based on hyperspectral remote sensing

Xia Tian^{1,2}, Wu Wenbin^{1,2}, Zhou Qingbo^{1,2*}, Zhou Yong³

(1. Key Laboratory of Agricultural Information Technology, Ministry of Agriculture, Beijing, 100081, China;

2. Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China;

3. College of Urban and Environment Sciences, Huazhong Normal University, Wuhan 430079, China)

Abstract: Leaf area index (LAI) is an important index for evaluating winter wheat's growth status and forecasting its yield. Hyperspectral remote sensing is a new technical approach that can be used to acquire the information of winter wheat LAI immediately. By integrating hyperspectral remote sensing and traditional field monitoring, this study aims to explore the best simulation accuracy and adaptability to the different method of high spectral monitoring winter wheat leaf area index inversion. Two kinds of universal LAI inversion methods based on hyperspectral remote sensing data through regression analysis method and the BP neural network (BPNN) are introduced and used in this study. The study area is Changqing district of Jinan city, Shandong province, China's Huang-huai-hai plain. On winter wheat growth stage, the winter wheat canopy spectral reflectance and LAI were monitored in field using the ASD FieldSpec 3 and SunScan canopy analysis system. The study selected the following 6 vegetation index (RVI, DVI, NDVI, GRVI, EVI and SAVI) combined with spectral reflectance characteristics of the study area. The 6 vegetation indexes are closely related to winter wheat LAI with correlation at a significant level. After correlation analysis of the Hyperspectral Vegetation Index (HVI) and LAI, winter wheat LAI regression models and BPNN model were established. Then simulation precisions for different models were analyzed and evaluated. The 6 winter wheat LAI regression models fits were 0.696~0.775, and root mean square errors (*RMSE*) were 0.386-0.523. Accuracy test showed that NDVI inversion model had the highest accuracy compared to other models. It is concluded that NDVI model is the most suitable model for inverting winter wheat LAI in the study area. However, the NDVI inversion model must avoid saturation phenomenon when NDVI is close to 1. This is the model's inadequacy. Input multiple sensitive reflectivity bands contain 450, 550, 670 and 870 nm bands to the BP neural network model. Upon examination, the simulation and measured fit values was 0.990 and the *RMSE* was 0.105. The results show that BP neural network model inversion method can build a better LAI inversion for winter wheat varieties in different regions. Among them, the inversion model has the highest R^2 (0.990) and least *RMSE* (0.105). The BP neural network method used to construct the inversion model is better on different varieties of winter wheat LAI inversion. However, establishing BP model needs to ensure enough samples (generally the number of samples $n > 50$ is a large sample of events) for the research adaptability. Both methods have their advantages and disadvantages. Overall, inversion method should be selected according to the number of samples and monitoring area.

Key words: remote sensing, regression analysis, neural networks, estimation, leaf area index, winter wheat, inversion method