

网络出版时间:2018-07-06 13:25

DOI:10.13207/j.cnki.jnwafu.2019.01.013

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1390.S.20180706.1323.026.html>

基于红边参数和人工神经网络的苹果叶片 叶绿素含量估算

罗 丹,常庆瑞,齐雁冰

(西北农林科技大学 资源环境学院, 陕西 杨凌 712100)

【摘要】【目的】应用人工神经网络来解决苹果叶片叶绿素含量与高光谱数据之间的非线性关系,建立估测苹果叶片叶绿素含量的最佳模型,为苹果叶片叶绿素含量的快速无损监测提供参考。【方法】以位于陕西扶风杏林镇的树龄为 4~5 年的 15 棵苹果树为研究对象,2015 年分别于果树花期(4 月 27 日)、幼果期(5 月 30 日)、果实膨大期(7 月 6 日)、果实着色期(8 月 5 日)、果实成熟期(9 月 11 日)采集叶片样本,利用 SVC HR-1024i 型高光谱仪和 SPAD-502 叶绿素仪同步获取苹果叶片光谱值和对应的叶绿素含量,对原始光谱和一阶导数光谱与叶绿素含量之间的关系进行分析,从一阶导数光谱中提取苹果叶片光谱的 5 个红边参数,从 5 个红边参数中筛选出相关性好的红边参数,使用传统单变量回归算法、反向传播(back propagation, BP)神经网络和径向基函数(radial basis function, RBF)神经网络,建立叶绿素含量估测模型,用决定系数(R^2)、均方根误差(RMSE)和相对误差(RE)来验证模型的准确性。【结果】与原始光谱相比,一阶导数光谱与苹果叶片叶绿素含量的相关性更高。5 个红边参数中,红边位置、峰度系数、偏度系数与叶绿素含量的相关系数均较高,且均达极显著水平。建立的传统单变量回归模型中,基于红边位置、峰度系数和偏度系数的 R^2 均大于 0.7,其中基于偏度系数建立的多项式模型模拟精度最高,验证结果 R^2 为 0.872, RMSE 为 4.631, RE 为 8.81%。选取红边位置、峰度系数和偏度系数为人工神经网络的输入变量,分别优化 BP 神经网络的隐含层节点数和网络类型以及 RBF 神经网络的扩展系数(SPREAD 值)来提高预测精度,结果发现,建立隐含层节点数为 4 的双隐含层 BP 神经网络最优模型 R^2 为 0.891, RMSE 为 3.844, RE 为 7.55%;当 SPREAD 值为 0.6 时,建立的 RBF 神经网络最优模型的 R^2 为 0.955, RMSE 和 RE 分别为 2.517 和 3.69%。【结论】估算苹果叶片叶绿素含量时,人工神经网络模型比传统单变量模型精度高,其中 RBF 神经网络模型学习速度快、精度高,拟合结果更加可靠。

【关键词】 叶绿素;红边参数;人工神经网络;苹果

【中图分类号】 TP79;TP183

【文献标志码】 A

【文章编号】 1671-9387(2019)01-0107-09

Estimation of chlorophyll content in apple leaves based on red edge parameters and artificial neural network

LUO Dan, CHANG Qingrui, QI Yanbing

(College of Resources and Environment, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: 【Objective】 The nonlinear relationship between hyperspectral data and chlorophyll content of apple leaf was solved using artificial neural network (ANN) and the best model for estimating chlorophyll content of apple leaves was established to provide basis for rapid and non-destructive monitoring of chlorophyll content in apple leaves. 【Method】 A total of 15 apple trees at the age of 4—5 years in Xinglin, Fufeng, Shaanxi were selected and leaf samples were collected in flowering (April 27), young fruit (May

【收稿日期】 2017-10-13

【基金项目】 国家高新技术研究与发展计划项目(“863”计划项目)(2013AA102401)

【作者简介】 罗 丹(1991—),女,山西运城人,硕士,主要从事遥感模型与信息处理研究。E-mail:luodan6568@163.com

【通信作者】 常庆瑞(1959—),男,陕西西洲人,教授,博士生导师,主要从事土地资源与空间信息技术研究。

E-mail:changqr@nwsuaf.edu.cn

30), young fruit expansion (July 6), coloring (August 5), and fruit maturation (September 11) stages in 2015. Hyperspectral reflectance was collected by spectrometer (SVC HR-1024i), and relative chlorophyll content was measured by chlorophyll meter SPAD-502. The corrections between original spectrum, first derivative spectrum and chlorophyll content were analyzed. Five red edge parameters were calculated as the first derivative. The traditional single variable empirical regression algorithms, back propagation (BP) and radial basis function (RBF) based on the well-related red edge parameters were applied to establish chlorophyll content estimated models. The accuracy of models was determined based on determination coefficient (R^2), root mean square error (RMSE) and relative error (RE). **【Result】** Compared with the original spectrum, the first derivative spectra had higher relevance with chlorophyll content of apple leaves. The red edge position, kurtosis and skewness had higher correlation among the 5 red edge parameters ($P < 0.01$). The correlation coefficients of models based on red edge position, kurtosis and skewness reached over 0.7. The skewness based polynomial model was the best with R^2 , RMSE and RE of 0.872, 4.631 and 8.81%, respectively. Red edge position, kurtosis and skewness were selected as input variables of ANN to build model for estimating chlorophyll content. The node of hidden layer and network type in BP-ANN and the SPREAD value in ANN-RBF were optimized to improve precision. The R^2 based on the BP neural network optimal model with 4 node of double hidden layer was 0.891, and RMSE and RE were 3.844 and 7.55%. When SPREAD was 0.6, R^2 , RMSE and RE of the optimized RBF-ANN were 0.955, 2.517 and 3.69%, respectively. **【Conclusion】** Compared to the models with single variable, ANN can improve estimation accuracy of chlorophyll content prediction. RBF-ANN had the advantages of rapid, accurate, and reliable.

Key words: chlorophyll; red edge parameter; artificial neural network; apple

植被叶绿素含量与其光合作用能力、生长发育阶段以及氮素水平有较好的相关性,已经成为一种评价植被长势的重要指标^[1]。在可见光波段,绿色植物的光谱反射率受叶绿素含量影响较大,因此可用植物的反射光谱来估算色素含量^[2]。近年来,高光谱遥感以其光谱分辨率高、简便有效以及非破坏性等优点,已成为监测植被叶绿素含量的一大发展趋势。

红边是植被在红光波段对叶绿素强烈吸收与近红外波段光在叶片内部多次散射而形成的强反射,可使光谱反射率在波长 680~760 nm 急剧上升,从而形成了植物光谱的最显著标志。学者们从叶绿素含量与红边位置之间的相关性入手,发现“红边”向长波方向的位移反映了植被叶绿素浓度的增加^[3];并基于红边参数构建了叶绿素含量的估算模型,且对其进行了精度评价^[4]。受田间管理、施肥及气候等条件的影响,学者们认识到利用传统的统计分析方法估算叶绿素含量时,模型的预测精度不高,因此需要构建一个准确性和稳定性兼备的估算模型。基于红边参数构建植物叶绿素含量估算模型,在玉米、小麦等一些作物上已开展过相关研究^[5-7],但在果树上的应用相对较少。

叶绿素含量与光谱反射参数之间是一种非线性

关系,将这 2 种参数以何种数学函数关系建立关联,是构建叶绿素含量反演模型及其预测精度的重要内容。近年来,学者们不断尝试各种数学函数关系,其中人工神经网络是处理复杂非线性问题的一种有效手段。随着高光谱遥感技术的发展,人工神经网络越来越多地应用于高光谱遥感研究中,如基于土壤光谱利用人工神经网络模型预测了土壤参数^[8-10],取得了较好的效果;基于高光谱建立人工神经网络模型进行小麦、水稻、玉米等作物生化参数的预测^[11-13]。苹果是西北地区重要的经济作物,其产量占到全国苹果产量的一半以上。叶片叶绿素含量是监测苹果产量与水肥状况的重要途径,利用人工神经网络进行苹果叶绿素含量预测具有重要的应用价值,目前这方面的研究较少,故本研究利用人工神经网络建立苹果叶片叶绿素含量估测模型,以期为实现快速无损监测苹果生长状况和施肥管理提供依据。

1 材料与方法

1.1 研究区概况

供试果园位于陕西省宝鸡市扶风县杏林镇(34°19'02"–34°23'33"N, 107°54'45"–108°02'40"E),海拔 470~570 m,属大陆性暖温带半湿润季风气候,

四季分明,全年日照 2 134.3 h,年平均气温 12.4 ℃,年平均降水量 591.9 mm。苹果品种为富士,树龄 4~5 年。2015 年分别于花期(4 月 27 日)、幼果期(5 月 30 日)、果实膨大期(7 月 6 日)、果实着色期(8 月 5 日)、果实成熟期(9 月 11 日)采集叶片样品。具体方法为:根据研究区分布情况,在园内选择具有代表性、生长均匀、树龄相近且没有病虫害的苹果树为采样树,共选取 15 棵果树作为研究样本。以随机方法采取叶样,每棵果树取叶色有明显差异的 4 组叶片,每组采集 4 片叶子,每期采集 60 组叶子,共采集 300 组叶片,进行光谱值和叶绿素含量测定。

1.2 测定项目与方法

1.2.1 光谱数据测定 采用美国 SCV HR-1024i 型便携式高光谱仪进行叶片漫反射光谱数据的测定。光谱仪测定的波长为 350~2 500 nm,通道数为 1 024 个,其中波长 350~1 000 nm 的光谱分辨率为 1.4 nm,波长 1 000~1 850 nm 的光谱分辨率为 3.8 nm,波长 1 850~2 500 nm 的光谱分辨率为 2.4 nm。测定工作在室内进行,每次进行样品光谱测定前,利用漫反射参考板进行仪器校正,从每组的 4 片叶子中选择 1 片叶子,先对叶面进行清洁,然后进行

光谱测定。每个点测定 2 次取平均值作为该点光谱测定值,每片叶子取 3~5 个点,最后取各点的平均值作为该叶片的光谱值。

1.2.2 叶绿素含量测定 在测定叶片光谱值时,使用日本 KONICA MINOLTA 公司生产的 SPAD (soil plant analysis development unit) 502 叶绿素仪测定叶片的叶绿素相对含量。研究表明,叶片绿色度 (SPAD) 值与叶绿素含量之间呈显著正相关性,故 SPAD 值可以直接表征叶绿素含量^[14]。在每片叶子的不同位置测定 10 个 SPAD 值,取平均值作为该叶片叶绿素含量,共获得 300 片叶子的 SPAD 值。

1.3 数据处理

在数据分析前,利用 SCVHR 1024i 型便携式高光谱仪自带的处理软件 ViewSpec Pro 6.0,将测定的苹果叶片光谱数据进行重采样,设置采样间隔为 1 nm。采用 Savitzky-Golay (SG) 平滑滤波^[15]对光谱数据进行预处理,设置平滑点数为 5。由原始光谱求得一阶微分光谱^[16],从一阶微分光谱中提取叶片的红边参数,包括红边位置、红边振幅、红边面积、峰度系数和偏度系数(表 1)。

表 1 红边参数的定义及算法

Table 1 Definition and algorithm of red edge parameters

红边参数 Red edge parameter	定义 Definition	算法 Algorithm
红边位置 Red edge position	红光范围内一阶导数光谱最大时对应的波长 The wavelength which corresponding the maximum of first derivative in red edge	λ_{red}
红边振幅 Red edge amplitude	红光范围内一阶导数光谱的最大值 The maximum of first derivative in red edge	$D_{\lambda} = \max[R'(\lambda)_{\lambda=680\sim760\text{ nm}}]$
红边面积 Red edge area	一阶导数光谱在红光范围内包围的面积 The area of first derivative in red edge	$S_{\text{red}} = \int_{680}^{760} R'(\lambda) d\lambda$
峰度系数 Kurtosis	红光范围内一阶导数光谱的峰度 The kurtosis of first derivative in red edge	$k = \frac{E(X-\mu)^4}{\sigma^4}$
偏度系数 Skewness	红光范围内一阶导数光谱的偏度 The skewness of first derivative in red edge	$s = \frac{E(X-\mu)^3}{\sigma^3}$

注: $R'(\lambda)$ 为任意波长一阶导数光谱; $E(X)$ 为向量 X 的期望值, μ 为向量 X 的平均值, σ 为向量 X 的标准差。

Note: $R'(\lambda)$ is the first derivative spectra. $E(X)$ is the expected value of vector X , μ is the average value of vector X , and σ is the standard deviation of vector X .

由于一些样本的测定结果误差较大或是光谱数据缺失,本研究选择其中的 286 组光谱数据和 SPAD 值进行分析。建模过程中,在 286 组数据中随机筛选 236 组用于建模,剩余 50 组用于模型验证。

1.4 模型构建与精度检验

采用一元线性、指数、对数、多项式和幂函数,构建叶片叶绿素含量与各红边参数的传统单变量线性和非线性回归模型,从中筛选出相关性好的红边参数作为自变量,构建叶绿素含量估算模型;之后将甄

选出的红边参数作为人工神经网络的输入向量,构建基于红边参数的人工神经网络模型。

人工神经网络有反向传播 (back propagation, BP) 神经网络和径向基函数 (radical basic function, RBF) 神经网络 2 种。BP 神经网络是一种多层前馈神经网络,该网络的主要特点是信号前向传递,误差反向传播^[17],由输入层、隐含层和输出层组成,其中隐含层层数和节点数对 BP 神经网络预测精度有较大的影响。RBF 神经网络是一种多维空间插值技术,结构同 BP 神经网络,基本思想是用 RBF 作为

隐单元的“基”构成隐含层空间,隐含层对输入矢量进行变换,将低维的模式输入数据变换到高维空间内,使在低维空间内的非线性问题在高维空间内线性可分,其中扩展系数 SPREAD 的选择对结果有一定影响^[18]。

为检验模型精度,将模型预测值与实测值进行回归拟合,采用通用的决定系数(R^2)、均方根误差(RMSE)、相对误差(RE)来验证模型的准确性。RMSE 和 RE 的计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i' - y_i)^2} \quad (1)$$

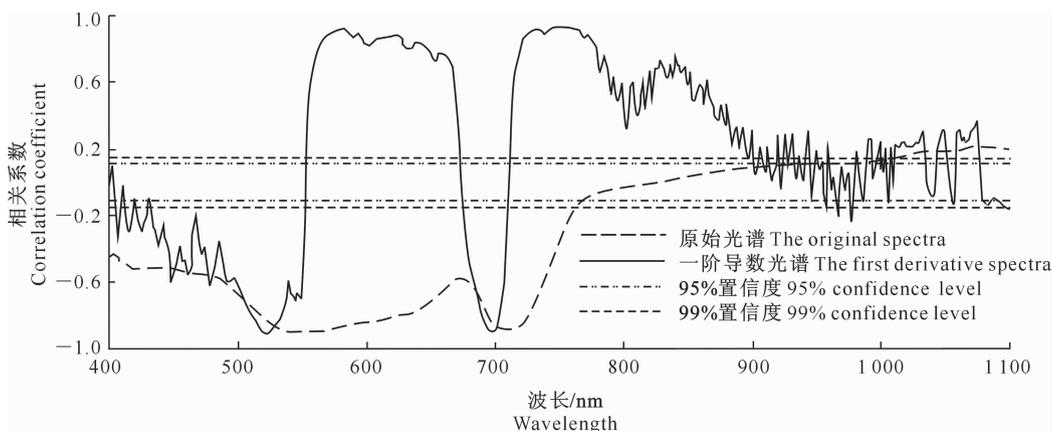


图 1 苹果叶片叶绿素含量与原始光谱和一阶导数光谱的相关性

Fig. 1 Correlations between chlorophyll content of apple leaf and spectra reflectance and its first derivative spectra

从图 1 可以看出,苹果叶片叶绿素含量与原始光谱在波长 400~760 nm 时呈极显著相关,当波长大于 700 nm 时相关系数绝对值开始减小,在波长为 810 nm 处相关系数接近 0,之后随波长增大,相关系数均较小,可知波长大于 810 nm 以后的波段几乎不反映叶绿素含量信息;在波长为 520~620 和 695~725 nm 时相关系数绝对值均较高,为 0.8~0.9,在波长为 554 nm 处相关系数绝对值达到最大值 0.899。苹果叶片叶绿素含量与一阶导数光谱在波长为 435~550 和 675~710 nm 时呈极显著负相关,在波长为 555~670 和 715~890 nm 时呈极显著正相关,当波长大于 890 nm 时相关系数逐渐减小且波动

较大,其中在波长为 575~585 和 725~765 nm 时相关系数均高于 0.9,在波长为 733 nm 处达到最大值 0.921。可知与原始光谱值相比,一阶导数光谱值与叶绿素含量的相关性更高。

2 结果与分析

2.1 苹果叶片叶绿素含量与原始光谱和一阶导数光谱的相关性

在各个波长处对原始光谱和一阶导数光谱与苹果叶片叶绿素含量进行相关性分析,结果见图 1。

较大,其中在波长为 575~585 和 725~765 nm 时相关系数均高于 0.9,在波长为 733 nm 处达到最大值 0.921。可知与原始光谱值相比,一阶导数光谱值与叶绿素含量的相关性更高。

2.2 基于红边参数的苹果叶片叶绿素含量单变量估算模型

从一阶微分光谱中提取相应的红边参数,这些红边参数与植物的各种理化参数是紧密相关的,叶绿素含量、植被覆盖度、冠层结构、叶面积指数、生物量等因素都能引起红边位置和振幅的变化^[19],本研究仅对叶片叶绿素含量与红边参数之间的相关性进行分析,结果如表 2 所示。

表 2 红边参数与苹果叶片叶绿素含量之间的相关系数

Table 2 Correlation coefficients between red edge parameters and chlorophyll content of apple leaf

红边参数 Red edge parameter	相关系数 Correlation coefficient	相关系数置信度 Confidence level
红边位置 Red edge position	0.799**	$R_{(0.05,286)} = 0.114$ $R_{(0.01,286)} = 0.148$
红边振幅 Red edge amplitude	0.598**	
红边面积 Red edge area	0.586**	
峰度系数 Kurtosis	0.734**	
偏度系数 Skewness	0.823**	

注: ** 表示相关性达到极显著水平($P < 0.01$)。下表同。

Note: ** indicates high significance at $P < 0.01$ level. The same below.

由表 2 可见,苹果叶片叶绿素含量与 5 种红边参数的相关性均达到极显著水平。在比较常用的红边位置、红边振幅、红边面积 3 个参数中,红边位置与叶绿素含量的关系最为密切,相关系数最高,达到 0.799,而红边振幅和红边面积与叶绿素含量间的相关系数偏低,这与前人研究结果^[20-21]一致。引入峰度系数和偏度系数是为了更好地描述波峰的分布状态^[22],偏度是反映数据分布对称性的统计量,峰度

是反映数据在均值附近集中程度的统计量。峰度系数和偏度系数与叶片叶绿素含量均呈极显著正相关,故用这 2 个指标来建立叶绿素含量估算模型是可行的。通过比较,以相关性水平为依据,选择红边位置、峰度系数和偏度系数这 3 个参数来建立传统的单变量线性和非线性叶绿素含量估算模型,结果见表 3(因峰度系数和偏度系数部分趋势数据含零值,故无法建立对数和幂函数模型)。

表 3 基于红边参数的苹果叶片叶绿素含量单变量线性和非线性估测模型及检验结果

Table 3 Estimation models and test results of linear and nonlinear single variable for chlorophyll content in apple leaf based on red edge parameter

红边参数 Red edge parameter	模型 Model	回归方程 Regression equation	建立模型 Calibration			验证模型 Validation		
			R ²	RMSE	RE/%	R ²	RMSE	RE/%
红边位置 Red edge position	一元线性 Linear	$y=2.0871x-1433.9$	0.807**	4.747	9.63	0.827**	6.377	11.75
	指数 Exponential	$y=4 \times 10^{-15} e^{0.0522x}$	0.800**	5.507	11.56	0.785**	6.216	10.72
	对数 Logarithm	$y=1475.6 \ln x - 9639.8$	0.807**	4.748	9.66	0.828**	6.376	11.78
	多项式 Polynomial	$y=0.0057x^2 - 5.9386x + 1403.5$	0.808**	13.300	33.52	0.824**	10.518	22.74
峰度系数 Kurtosis	一元线性 Linear	$y=-58.665x-33.738$	0.706**	5.959	12.30	0.819**	6.027	12.03
	指数 Exponential	$y=5.7513e^{-1.513x}$	0.733**	5.641	11.23	0.849**	5.711	10.88
	多项式 Polynomial	$y=63.794x^2 + 97.647x + 60.281$	0.734**	5.574	11.26	0.856**	5.216	9.68
	幂函数 Power	$y=2 \times 10^{-104} x^{36.945}$	0.801**	5.896	10.50	0.787**	8.425	14.98
偏度系数 Skewness	一元线性 Linear	$y=-52.676x+59.87$	0.793**	4.919	9.88	0.872**	4.677	9.09
	指数 Exponential	$y=63.528e^{-1.323x}$	0.792**	4.991	9.72	0.862**	4.751	8.63
	多项式 Polynomial	$y=10.78x^2 - 60.246x + 60.838$	0.794**	4.905	9.76	0.872**	4.631	8.81

由表 3 可知,建立的所有模型的 R² 均大于 0.7, 达到极显著相关水平。基于红边位置建立的模型, R² 均在 0.8 以上,以 R² 较大而 RMSE 和 RE 较小为标准,多项式模型虽然 R² 最大,但 RMSE 和 RE 也均最大,所以一元线性模型和对数模型的优势更大;而验证模型的 RMSE 和 RE 大于建立模型,说明模型的适宜性有待提高。基于峰度系数和偏度系数建立的模型, R² 在 0.7~0.8,均达到了极显著相

关,其中采用多项式建立模型时, R² 均最高,而 RMSE 和 RE 均较小,且验证模型的 R² 和 RMSE、RE 都与建立的模型接近,说明模型稳定性较好。总体来看,基于偏度系数建立的模型表现最好,且验证模型 R² 均在 0.86 以上, RMSE 和 RE 均最小,模型适应性良好,故选用偏度系数建立苹果叶片叶绿素含量的多项式反演模型(图 2),并对该模型进行验证,叶绿素实测值与预测值的比较结果见图 3。

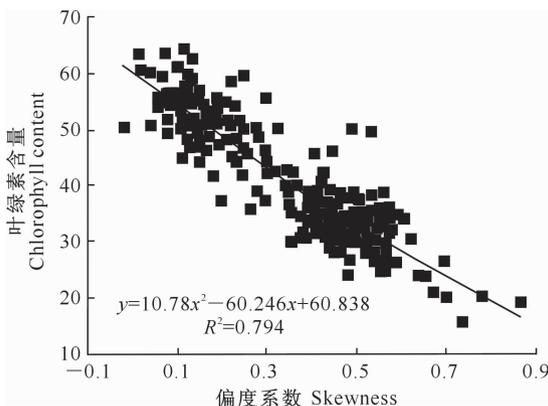


图 2 基于偏度系数的苹果叶片叶绿素含量多项式估算模型

Fig. 2 Polynomial estimation model based on skewness for chlorophyll content in apple leaf

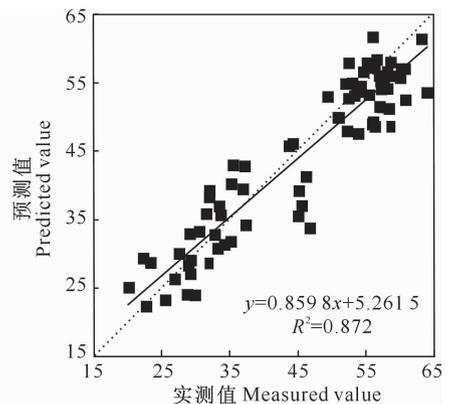


图 3 基于偏度系数的苹果叶片叶绿素含量多项式估算模型预测值与实测值的比较

Fig. 3 Comparison of measured and predicted values of apple leaf chlorophyll content by polynomial estimation model based on skewness

由图 3 可知,叶绿素含量实测值与预测值方程的回归系数达到 0.859 8, R^2 为 0.871 5,说明两者相关性极高。

2.3 基于 BP 神经网络的苹果叶片叶绿素含量估算模型

本研究利用 MATLAB 11.0 建立 BP 神经网络,输出层为苹果叶片叶绿素含量,输入层为红边位置、峰度系数和偏度系数。利用训练数据训练 BP 神经网络,使网络具有预测能力,用训练好的模型预

表 4 不同隐含层节点数下苹果叶片叶绿素含量 BP 神经网络估测模型的检验结果

Table 4 Estimation models and test results of BP neural network model with different nodes of hidden layer for chlorophyll content in apple leaf

隐含层节点数 Node of hidden layer	估测模型 Estimation			验证模型 Validation		
	R^2	RMSE	RE/%	R^2	RMSE	RE/%
3	0.864 **	4.279	8.53	0.899 **	3.729	8.39
4	0.883 **	3.925	7.59	0.909 **	3.842	7.68
5	0.886 **	3.913	7.63	0.917 **	3.461	6.37
6	0.881 **	3.994	8.34	0.880 **	3.986	7.73
7	0.876 **	4.019	7.98	0.876 **	4.327	7.61
8	0.869 **	4.155	7.96	0.888 **	3.909	7.80

表 5 不同网络类别下苹果叶片叶绿素含量 BP 神经网络估测模型的检验结果

Table 5 Estimation models and test results of BP neural network model with different network types for chlorophyll content in apple leaf

隐含层节点数 Node of hidden layer	网络类别 Network type	估测模型 Estimation			验证模型 Validation		
		R^2	RMSE	RE/%	R^2	RMSE	RE/%
4	单隐含层 Single-hidden layer	0.883 **	3.925	7.59	0.909 **	3.842	7.68
	双隐含层 Double hidden layers	0.891 **	3.844	7.55	0.916 **	3.083	6.05
5	单隐含层 Single-hidden layer	0.886 **	3.913	7.63	0.917 **	3.461	6.37
	双隐含层 Double hidden layers	0.887 **	3.875	7.45	0.911 **	3.469	6.93

从表 5 可以看出,当节点数相同时,与单隐含层 BP 神经网络相比,双隐含层 BP 神经网络 R^2 提高, RMSE、RE 均减小,预测精度提高。对比节点数分别为 4 和 5 时的双隐含层估测模型可知,从网络精度和训练时间上综合考虑,节点数为 4 的双隐含层估测模型表现最好,且验证结果准确性和稳定性都很高,故其为最佳的苹果叶片叶绿素含量 BP 神经网络估测模型。对此模型进行检验,结果(图 4)发现预测值与实测值之间相关性较高, R^2 为 0.916,是一种叶绿素无损估算的有效方法。

2.4 基于 RBF 神经网络的苹果叶片叶绿素含量估算模型

利用 MATLAB 11.0 中的 newrbe 函数构建 RBF 神经网络,苹果叶片叶绿素含量作为输出向量,红边位置、峰度系数、偏度系数作为输入向量,扩展系数 SPREAD 值设为默认,用 RBF 神经网络模型来研究红边参数与叶绿素含量的反演关系。经过模型构建、训练和检验发现,当 SPREAD 值为 1.0

时,并通过比较模型预测输出和期望输出来分析 BP 神经网络的拟合能力。BP 神经网络的隐含层节点数、网络类型对模型精度的影响很大,表 4 和表 5 分别为隐含层不同节点数和网络不同类别 BP 神经网络估测模型的精度及检验结果。由表 4 可以看出,BP 神经网络的精度随着隐含层节点数的增加呈现先提高后降低的趋势,当节点数为 5 时,估测模型的 R^2 最大, RMSE 和 RE 均较小,此时验证结果的准确性也最高,模型表现稳定。

时,估测模型 R^2 为 0.943, RE 为 4.41%, RMSE 为 2.825,验证模型 R^2 为 0.909, RE 为 4.25%, RMSE 为 2.500,比 BP 神经网络具有更高的稳定性。根据 SPREAD 值应小于输入向量之间的典型距离的原则^[23],确定 SPREAD 值应设置为 $[0, 1]$ 。不同 SPREAD 值的 RBF 神经网络模型估测结果见表 6。从表 6 可以看出,随 SPREAD 值减小, R^2 增大, RMSE、RE 均逐渐减小,建立的模型越精确;但当 SPREAD 值小于 0.6 以后,验证结果精度下降,说明网络性能变差,出现了过适应现象,所以选择 SPREAD 值为 0.6,此时建立的 RBF 神经网络模型的 R^2 达到 0.955, RMSE 为 2.517, RE 为 3.69%,且预测效果准确性高,模型稳定性好,故确定该模型为估测苹果叶片叶绿素含量的最佳模型。基于 RBF 神经网络的苹果叶片叶绿素含量最佳估测模型预测值与实测值的比较结果见图 5。由图 3—5 可见,与传统模型和 BP 神经网络模型相比, RBF 神经网络模型的拟合度更高,且其还具有速度更快、算

法简便的特点。

表 6 不同 SPREAD 值下苹果叶片叶绿素含量 RBF 神经网络估测模型的检验结果

Table 6 Estimation models and test results of RBF neural network model with different SPREAD values for chlorophyll content in apple leaf

SPREAD 值 SPREAD value	估测模型 Estimation			验证模型 Validation		
	R^2	RMSE	RE/%	R^2	RMSE	RE/%
1.0	0.943 **	2.825	4.41	0.909 **	2.500	4.25
0.9	0.945 **	2.734	4.16	0.925 **	2.274	3.93
0.8	0.948 **	2.694	4.08	0.924 **	2.307	3.99
0.7	0.953 **	2.577	3.93	0.938 **	2.039	3.39
0.6	0.955 **	2.517	3.69	0.939 **	2.009	3.43
0.5	0.957 **	2.451	3.64	0.937 **	2.054	3.62
0.4	0.962 **	2.300	3.17	0.847 **	3.188	5.50
0.3	0.974 **	1.893	2.36	0.799 **	7.118	3.67

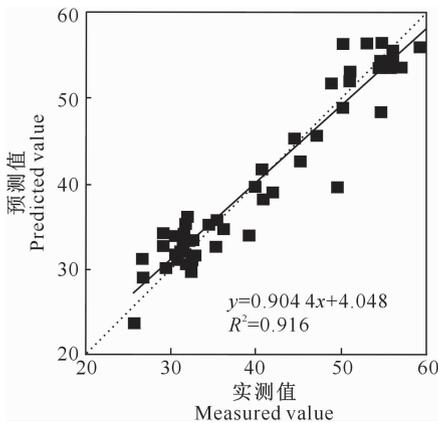


图 4 基于 BP 神经网络的苹果叶片叶绿素含量最佳估测模型预测值与实测值的比较

Fig. 4 Comparison of measured and predicted values of chlorophyll content in apple leaf based on optimal BP neural network model

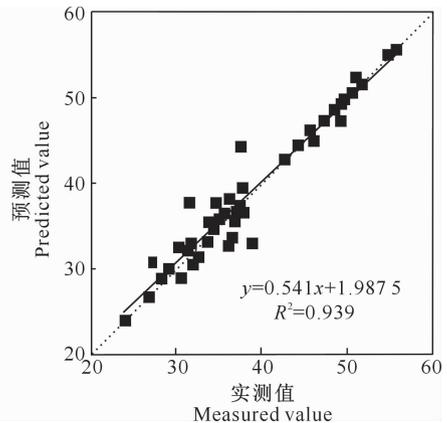


图 5 基于 RBF 神经网络的苹果叶片叶绿素含量最佳模型预测值与实测值的比较

Fig. 5 Comparison of measured and predicted values of chlorophyll content in apple leaf based on optimal RBF neural network model

3 讨论

本研究通过分析苹果叶片原始光谱和一阶导数光谱与叶绿素含量之间的关系,发现一阶导数光谱与叶绿素含量之间的相关性高于原始光谱,这与前人的研究结果^[24-25]一致。究其原因,可能是利用微分技术减少了背景噪音的影响,故一阶导数光谱与植被生化参数的相关性更好。从一阶导数光谱中提取的红边位置、红边振幅、红边面积 3 个参数中,红边位置与叶绿素含量关系最为密切,这是因为红边是植物光谱的最显著标志^[26],当叶绿素含量增加时,红边位置会向长波方向偏移^[27],当叶绿素含量减少时,红边位置则向相反方向变化,红边位置是红边区域中变化最快的波段。因此,红边位置较红边振幅和红边面积对叶绿素含量变化的反应更加敏感,是一种有效的叶绿素含量指示参数。

基于峰度系数和偏度系数建立的叶绿素含量估

算模型的稳定性和精度,均高于基于红边位置建立的模型,可能是由于峰度系数和偏度系数所包含的信息量更大所致。因为峰度系数和偏度系数本身可以体现出红边范围内光谱形状的整体变动,而光谱形状变动正是由于叶绿素含量的变化引起的,所以峰度系数和偏度系数也可以作为估测叶片叶绿素含量的参数。所建模型中,多项式模型优于其他模型,这可能是由于各项红边参数与叶绿素含量之间存在着比较复杂的非线性关系,线性关系难以反映其本质。

人工神经网络是处理复杂非线性问题的一种有效手段^[28],具有并行性高、非线性映射能力强、自学习能力和自适应能力强等特点,使得人工神经网络具有很强的处理不确定性信息的能力。本研究发现,BP 和 RBF 神经网络模型与传统单变量模型相比,具有更高的准确性和稳定性,而且能够解决同时存在多个自变量和多个因变量的问题,可以作为估

测叶片叶绿素含量的一种可行方法。与 BP 神经网络模型相比, RBF 神经网络具有更高的准确性和稳定性, 这是因为 BP 神经网络算法本质上是控制实际输出与期望输出之差, 利用输入样本正向传播和误差反向传播这一过程反复进行, 对网络的各层连接权值和各结点的阈值由后向前逐层调整的一种监督学习算法。所以 BP 神经网络性能依赖于初始条件, 收敛速度慢, 稳定性较差, 学习过程易陷入局部极小, 且随机性强, 因此使 BP 神经网络精度受到了影响。而 RBF 神经网络克服了 BP 神经网络的缺点, 具有结构自适应确定、输出不依赖于初始权值以及学习速度快等优良特性^[29], 能够最大程度地逼近实际测量值。此外, 本研究发现, 建立基于 RBF 神经网络苹果叶片叶绿素含量估测模型时, 要注意调整 SPREAD 值和网络结构, 以免造成过拟合。

4 结 论

本研究以陕西苹果叶片为试验对象, 对苹果叶片原始光谱、一阶导数光谱及其红边参数与叶绿素含量的相关性进行了分析, 建立了基于红边参数的传统单变量回归模型, 用红边位置、峰度系数、偏度系数 3 个参数建立叶绿素含量 BP 神经网络模型和 RBF 网络估算模型, 并比较了 3 种不同模型的精度, 得出以下结论:

1) 与原始光谱相比, 一阶导数光谱与叶绿素含量相关性更高, 在波长 733 nm 处相关系数达到最大值 0.921; 在苹果叶片红边参数中, 红边位置、峰度系数和偏度系数与叶绿素含量间的相关性较好, 相关系数均高于 0.7。

2) 用红边参数与叶绿素含量建立的单变量回归模型中, 多项式模型的模拟精度较高, 通过比较, 基于偏度系数建立的多项式模型为最佳估算模型, 验证结果显示 R^2 为 0.872, RMSE 为 4.631, RE 为 8.81%。

3) 以红边位置、峰度系数和偏度系数作为输入变量构建 BP 神经网络和 RBF 神经网络 2 种模型, 对苹果叶片叶绿素含量进行估测, 模型的精度高于传统单变量回归模型; 优化后的 RBF 神经网络模型 (SPREAD 值为 0.6) 验证结果 R^2 为 0.939, RMSE 为 2.009, RE 为 3.43%, 学习速度快、精度高, 拟合结果可靠, 是估测苹果叶片叶绿素含量的最佳模型。

[参考文献]

[1] Filella I, Penuelas J. The red edge position and shape as indica-

tors of plant chlorophyll content, biomass and hydric status. [J]. International Journal of Remote Sensing, 1994, 15(7): 1459-1470.

- [2] Blackburn G A. Quantifying chlorophylls and carotenoids at leaf and canopy scales: an evaluation of some hyperspectral approaches [J]. Remote Sensing of Environment, 1998, 66(3): 273-285.
- [3] Horler D N H, Barber J, Barringer A R. Effects of heavy metals on the absorbance and reflectance spectra of plants [J]. International Journal of Remote Sensing, 1980(2): 121-136.
- [4] 姚付启, 张振华, 杨润亚, 等. 基于红边参数的植被叶绿素含量高光谱估算模型 [J]. 农业工程学报, 2009(S2): 123-129.
- Yao F Q, Zhang Z H, Yang R Y, et al. Hyperspectral models for estimating vegetation chlorophyll content based on red edge parameter [J]. Transactions of the Chinese Society of Agricultural Engineering, 2009(S2): 123-129.
- [5] 黄文江, 王纪华, 刘良云, 等. 冬小麦红边参数变化规律及其营养诊断 [J]. 遥感技术与应用, 2003, 18(4): 206-211.
- Huang W J, Wang J H, Liu L Y, et al. The red edge parameters diversification disciplinarian and its application for nutrition diagnosis [J]. Remote Sensing Technology and Application, 2003, 18(4): 206-211.
- [6] 谭昌伟, 王纪华, 陆建飞, 等. 基于红边参数的夏玉米长势监测及其营养诊断研究 [J]. 中国生态农业学报, 2007, 15(1): 82-86.
- Tan C W, Wang J H, Lu J F, et al. Summer maize growth supervision and nutrition diagnosis with red edge parameters [J]. Chinese Journal of Eco-Agriculture, 2007, 15(1): 82-86.
- [7] 王秀珍, 王人潮, 李青梅, 等. 不同氮素营养水平的水稻冠层光谱红边参数及其应用研究 [J]. 浙江大学学报(农业与生命科学版), 2001, 27(3): 301-306.
- Wang X Z, Wang R C, Li Y M, et al. Study on red edge characteristics of rice spectral caused by nitrogen level [J]. Juurnal of Zhejiang University (Agriculture & Life Science), 2001, 27(3): 301-306.
- [8] 郑立华, 李民赞, 潘 变, 等. 基于近红外光谱技术的土壤参数 BP 神经网络预测 [J]. 光谱学与光谱分析, 2008, 28(5): 1160-1164.
- Zheng L H, Li M Z, Pan L, et al. Estimation of soil organic matter and soil total nitrogen based on NIR spectroscopy and BP neural network [J]. Spectroscopy and Spectral Analysis, 2008, 28(5): 1160-1164.
- [9] 高如泰, 陈焕伟, 李保国, 等. 基于 BP 神经网络的土壤水力学参数预测 [J]. 土壤通报, 2005, 36(5): 641-646.
- Gao R T, Chen H W, Li B G, et al. Prediction of soil hydraulic characteristic parameters based on BP neural network [J]. Chinese Journal of Soil Science, 2005, 36(5): 641-646.
- [10] Minasny B, McBratney A B. The method for fitting neural network parametric pedotransfer functions [J]. Soil Science Society of America Journal, 2002, 66(2): 352-361.
- [11] 樊 迪. 基于 BP 网络的小麦病害诊断专家系统的研究与实现 [D]. 陕西杨凌: 西北农林科技大学, 2015: 3-6.

- Fan D. Research and implementation of wheat disease diagnosis expert system based on BP network [D]. Yangling, Shaanxi:Northwest A&F University,2015;3-6.
- [12] Chen L, Huang J F, Wang F M, et al. Comparison between back propagation neural network and regression models for the estimation of pigment content in rice leaves and panicles using hyperspectral data [J]. *International Journal of Remote Sensing*,2007,28(16):3457-3478.
- [13] 李媛媛,常庆瑞,刘秀英,等. 基于高光谱和 BP 神经网络的玉米叶片 SPAD 值遥感估算 [J]. *农业工程学报*,2016,32(16):135-142.
- Li Y Y, Chang Q R, Liu X Y, et al. Estimation of maize leaf SPAD value based on hyperspectrum and BP neural network [J]. *Transactions of the Chinese Society of Agricultural Engineering*,2016,32(16):135-142.
- [14] 朱新开,盛海君,顾 晶,等. 应用 SPAD 值预测小麦叶片叶绿素和氮含量的初步研究 [J]. *麦类作物学报*,2005,25(2):46-50.
- Zhu X K, Sheng H J, Gu J, et al. Primary study on application of SPAD value to estimate chlorophyll and nitrogen content in wheat leaves [J]. *Journal of Triticeae Crops*,2005,25(2):46-50.
- [15] Ruffin C, King R L, Younan N H. A combined derivative spectroscopy and Savitaky-Golay filtering method for the analysis of hyperspectral data [J]. *Mapping Sciences & Remote Sensing*,2008,45(1):1-15.
- [16] Tsai F, Philpot W. Derivative analysis of hyperspectral data [J]. *Remote Sensing of Environment*,1998,66(1):41-51.
- [17] 李友坤. BP 神经网络的研究分析及改进应用 [D]. 安徽淮南:安徽理工大学,2012:14-20.
- Li Y K. Analysis and improvement applications of BP neural network [D]. Huainan, Anhui: Anhui University of Science and Technology,2012:14-20.
- [18] 周志华,曹存根. 神经网络及其应用 [M]. 北京:清华大学出版社,2004:101-110.
- Zhou Z H, Cao C G. Neural network and application [M]. Beijing: Tsinghua University Press,2004:101-110.
- [19] 唐延林,黄敬峰,王秀珍,等. 水稻、玉米、棉花的高光谱及其红边特征比较 [J]. *中国农业科学*,2004,37(1):29-35.
- Tang Y L, Huang J F, Wang X Z, et al. Comparison of the characteristics of hyperspectra and the red edge in rice, corn and cotton [J]. *Scientia Agricultura Sinica*,2004,37(1):29-35.
- [20] 朱咏莉,李萍萍,毛罕平,等. 生菜叶片光谱红边参数对氮营养的响应特征分析 [J]. *农业机械学报*,2011,42(11):174-177.
- Zhu Y L, Li P P, Mao H P, et al. Response features of red edge parameters for lettuce leaf spectra under different nitrogen levels [J]. *Transactions of the Chinese Society for Agricultural Machinery*,2011,42(11):174-177.
- [21] 姚付启,蔡焕杰,李亚龙,等. 基于红边参数的冬小麦 SPAD 高光谱遥感监测 [J]. *中国农村水利水电*,2015(3):84-87.
- Yao F Q, Cai H J, Li Y L, et al. Monitoring winter wheat SPAD based on red edge parameter derived from hyperspectral reflectance [J]. *China Rural Water and Hydropower*,2015(3):84-87.
- [22] 王晓星,常庆瑞,刘梦云,等. 冬小麦冠层水平叶绿素含量的高光谱估测 [J]. *西北农林科技大学学报(自然科学版)*,2016,44(2):48-54.
- Wang X X, Chang Q R, Liu M Y, et al. Hyper-spectral estimation of chlorophyll content in canopy of winter wheat [J]. *Journal of Northwest A&F University(Natural Science Edition)*,2016,44(2):48-54.
- [23] 谌爱文. 基于 BP 和 RBF 神经网络的数据预测方法研究 [D]. 长沙:中南大学,2007:6-10.
- Chen A W. Study on data prediction methods based on BP and RBF neural network [D]. Changsha: Central South University,2007:6-10.
- [24] 冯 伟. 基于高光谱遥感的小麦氮素营养及生长指标监测研究 [D]. 南京:南京农业大学,2007:9-12.
- Feng W. Monitoring nitrogen status and growth characters with canopy hyperspectral remote sensing in wheat [D]. Nanjing: Nanjing Agricultural University,2007:9-12.
- [25] 姚 霞,田永超,刘小军,等. 不同算法红边位置监测小麦冠层氮素营养指标的比较 [J]. *中国农业科学*,2010,43(13):2661-2667.
- Yao X, Tian Y C, Liu X J, et al. Comparative study on monitoring canopy leaf nitrogen status on red edge position with different algorithms in wheat [J]. *Scientia Agricultura Sinica*,2010,43(13):2661-2667.
- [26] 罗 丹,常庆瑞,齐雁冰,等. 基于光谱指数的冬小麦冠层叶绿素含量估算模型研究 [J]. *麦类作物学报*,2016,36(9):1225-1233.
- Luo D, Chang Q R, Qi Y B, et al. Estimation model for chlorophyll content in winter wheat canopy based on spectral indices [J]. *Journal of Triticeae Crops*,2016,36(9):1225-1233.
- [27] 丁永军,张晶晶,李修华,等. 基于光谱红边位置提取算法的番茄叶片叶绿素含量估测 [J]. *农业机械学报*,2016,47(3):292-297.
- Ding Y J, Zhang J J, Li X H, et al. Estimation of chlorophyll content of tomato leaf using spectrum red edge position extract algorithm [J]. *Transactions of the Chinese Society for Agricultural Machinery*,2016,47(3):292-297.
- [28] 吴 倩,林 蕾,王学军,等. 福海叶绿素含量的人工神经网络反演模型 [J]. *地理与地理信息科学*,2004,20(4):27-30.
- Wu Q, Lin L, Wang X J, et al. The neural network model on chlorophyll concentration in the Fuhai lake [J]. *Geography and Geo-Information Science*,2004,20(4):27-30.
- [29] 罗定贵,郭 清,王学军. 地表水质评价的径向基神经网络模型设计 [J]. *地理与地理信息科学*,2003,19(5):77-81.
- Luo D G, Guo Q, Wang X J. Neural network model design of surface water environmental quality assessment [J]. *Geography and Geo-Information Science*,2003,19(5):77-81.