

文章编号: 1007-4619 (2002)04-0252-07

基于神经网络的水稻双向反射模型研究

申广荣, 王人潮

(浙江大学 农业遥感与信息技术应用研究所, 浙江 杭州 310029)

摘要: 水稻的双向反射特性与其冠层结构、各组分光谱性质以及入射光方向和观测方向之间存在着密切的、非线性的相关关系。运用人工神经网络技术, 采用水稻田间实测数据, 对这种关系进行拟合, 所建立的水稻双向反射 BP 前向和反演模型, 都达到了较高的拟合精度。研究表明: 采用人工神经网络技术计算水稻双向反射率和成批反演冠层结构参数是可行的。对所建模型做进一步的改进, 可模拟水稻双向反射的实际过程, 进而监测作物长势。

关键词: 神经网络; BP 算法; 水稻; 双向反射; 反演

中图分类号: TP79/TP39 **文献标识码:** A

1 引言

植被二向反射(Bidirectional Reflectance Distribution Function(BRDF))特性研究从 20 世纪 80 年代中期开始逐渐成为遥感界十分活跃的研究领域之一, 出现了各种各样的植被双向反射分布函数模型。其目的是通过双向反射函数模型模拟植被的双向反射过程, 获取植被的二向反射信息, 从而定量提取植被的生物物理参数和冠层结构信息, 监测作物长势。一个完美的模型是精确反演所期望的, 前向模型的目标是利用已知的一组生物物理和冠层结构参数模拟植被双向反射物理过程, 计算植被的二向反射率; 反演模型是在某些特定的条件下推导产生双向反射物理过程的一组生物物理和冠层结构参数。归纳起来, 现有的模型可以分为两类: 统计模型和物理模型。物理模型主要包括辐射传输模型, 几何结构模型, 混浊介质模型和计算机模拟模型。由于人类认知水平的限制, 特别是作物二向反射过程及地学系统的复杂性, 往往不能得到描述实际对象的完美模型。另一方面, 模型的完美化必然涉及更多的参数, 而参数的增加将极大地增加反演的难度。所以, 在现有模型的基础上从不同角度发展作物二向反射模型, 发掘现有测量精度数据中的潜在信息是必要的。

水稻是中国的主要粮食作物之一, 其二向反射模型的研究对掌握水稻的生长发育过程、监测其长势、估产具有重要意义。浙江大学遥感与信息所主持的国家基金项目“不同氮素水平水稻光谱特性机理研究”通过大田试验, 在 Nilson-Kuusk 模型的基础上, 集成了水稻的二向反射及其反演模型^[1], 并发展了水稻的多组分双向反射模型^[2]。但更多更详细的有关水稻二向反射模型的研究还鲜见报道。

神经网络的功能表现出在描述和表征自然界大量存在的非线性本质的形态、现象中具有其它学科难以比拟的优势。本文尝试利用 1999—2000 年水稻大田试验的实测光谱数据, 辅之于已建立的水稻多组分双向反射模型生成的数据, 综合考虑现有的作物双向反射物理模型, 假定水稻的二向反射率是水稻冠层结构参数, 土壤(薄层水体)背景和各组分(主要考虑叶)的反射及透射光谱特性以及太阳天顶角和观测角等变量的函数, 发展基于神经网络的水稻双向反射的前向和反演模型。

2 水稻双向反射 BP 模型的建立

2.1 神经网络 BP 模型介绍

神经网络(ANN)是建立以权重描述变量与目标之间特殊关系的非线性关系模型。Rumelhart 将反

收稿日期: 2001-06-26; 修订日期: 2001-09-03

基金项目: 国家自然科学基金资助项目(项目编号: 40171065)

作者简介: 申广荣(1965—), 女, 山西太谷人, 副教授, 1993 年于中国科学院遥感应用研究所获硕士学位。现为浙江大学农业遥感与信息

信息技术应用研究所博士研究生, 主要从事遥感光谱特性的研究, 已发表论文 20 多篇。

馈传播(Back Propagation, BP)算法引入神经网络中,很好地实现了多层神经网络的设想^[3]。

BP网络可看成是一从输入到输出的高度非线性映射,即 $F: R^n \rightarrow R^m, f(x) = Y$ 。其算法过程是将各项指标数据 X 加载到输入层的神经元上,通过连接权向前传播到隐含层神经元,经过转换函数 $f(x) = 1/(1 - \exp(-x))$ 处理后,再将隐含层的输出信号传播到网络输出层。BP算法的基本思想是将每次迭代的误差信号由输出层经隐含层至输入层反向传播,调整各个神经元之间的连接权植,如此反复迭代,直到误差达到容许水平,这种调节过程具有自组织、自学习的特点,同时也决定了BP网络的层数不易太多,应尽量保持在3层,因为层数愈多,反向传播误差在靠近输入层时就愈不可靠^[4-7]。根据人工神经网络基本原理和BP算法的特性,设计相应的神经网络:

令 Q_m, H_i, O_j 分别为第1, 2, 3层的输出; U_i, S_j 分别为2, 3层的输入; A_{im}, B_{ji} 分别为第1-2层, 2-3层单元的连接权值; X_i, Y_j 分别为第2, 3层单元的偏置值; F_i, G_j 分别为第2, 3层的误差信号。设有 L 个学习样本 $(Q^1, T^1), (Q^2, T^2), \dots, (Q^L, T^L)$ 。

定义误差函数

$$E = \frac{1}{2} \sum_{k=1}^L (T^k - O^k)^2$$

式中 T^k, O^k 分别表示样本 k 时网络的期望输出和实际输出值。

2.2 数据的获取

1999—2000年进行了两年的田间试验。水稻(品种为秀水63)的冠层结构与反射光谱以及农田辐射状况的测量均在浙江大学华家池校区实验农场进行。测量水稻及稻田背景值所用的仪器是美国ASD (Analytical Spectral Device) 公司的 Fieldspec® 光谱仪,波段值为350—1050nm,光谱分辨率为1.4nm。测量方位角为4个,即:0°, 90°, 180°, 270°。后向散射方向(即观测方向与太阳入射方向一致的方向)的方位角定义为0°;前向反射方向(即观测方向与太阳入射方向相反,探测器对着太阳的方向)的方位角定义为180°,其余方位角按顺时针计算。观测天顶角从0°到60°,每隔7.5°观测一次。对叶倾角、叶长、叶宽、冠层高度的测量于观测光谱数据的当天在田间进行,在观测光谱数据的小区中任选20个茎,用直尺量取叶长及叶宽,叶宽为叶的最宽处的宽度值,同时量取每个茎的高度。另外,在田间用量角器悬挂

一小锤量取叶脉与茎干的夹角。叶面积指数用叶片干重与叶面积的比例关系测定,另外通过将叶片形状扫描输入计算机,借助于地理信息系统工具求得图斑面积得到叶面积,再换算成叶面积指数,与前一方法所得值相互验证,以保证数据的精确性。叶片、茎及穗的反射率、透射率在观测光谱数据的当天在室内借助1800-12外部积分球用光谱仪测量。这样得到了11组完整的水稻BRDF观测数据,时间分别是1999-08-18, 1999-08-28, 1999-09-03, 1999-09-11, 1999-09-24, 1999-09-29, 1999-10-18, 2000-08-07, 2000-08-28, 2000-09-18, 2000-10-08。其中1999年的实测数据作为模型训练数据,用2000年的实测数据对模型进行校核。为了保证模型训练样本的数量,用已建立的水稻多组分双向反射模型生成虚拟数据参与模型训练。

水稻的多组分双向反射模型是在作物多组分双向反射模型的基础上,基于辐射传输原理和水稻群丛结构特征,特别是考虑水稻不同生长时期特点建立的。模拟与实测结果的比较表明:模型基本上能反映水稻多组分双向反射光谱的角度分布特征^[8]。参照现有的作物双向反射物理模型特别是已建立的水稻多组分双向反射模型,假定水稻双向反射率为冠层结构参数;叶的平均长/冠层高度(L_1),平均宽/长(P),叶面积指数 LAI ,反射率(R),透射率(T_1),模型倾角(θ),偏心率(D)和天空参数:太阳天顶角(θ_s),漫反射与总辐射之比(Q_1)及土壤(薄层水体)背景在不同观测天顶角下的反射率(sbf)以及观测天顶角和方位角的函数。利用水稻多组分双向反射模型生成建立基于神经网络的水稻二向反射模型所需数据时,冠层结构参数和天空参数,土壤(薄层水体)背景的反射率等输入参数参照1989—1991年浙江大学农业遥感与信息技术应用研究所主持的有关国家自然科学基金项目确定^[9]。表1是部分训练参数。

为了消除量纲影响,对已获得的训练数据做如下标准化处理:

(1) 影响因子数据处理

$$P' = P * 10; LAI' = LAI/5; \theta' = \theta/90; \theta_s' = \theta_s/90$$

其余不变。

(2) 二向反射率值数据处理

$$bf' = bf * 10$$

2.3 水稻双向反射主平面BP网络模型

2.3.1 前向模型

网络共分3层,输入层10个节点:稻叶的 L_1 ,

表 1 模型训练参数(1999 年实测 TM2 波段)

Table 1 The training parameters measured in 1999 used in BP model(TM2)

日 参 期 数	L_1	P	LAI	D	$\theta(^{\circ})$	R	T_1	$sbtf$	$\theta_s(^{\circ})$	Q_1
1999-08-18	0.46	0.045	1.9	0.9	80	0.19	0.219	0.181	17	0.24
1999-08-28	0.44	0.036	3.1	0.98	80	0.21	0.205	0.167	21	0.22
1999-09-11	0.39	0.04	5.4	0.99	78	0.24	0.16	0.079	26	0.18
1999-09-29	0.37	0.035	3.9	0.96	76	0.22	0.169	0.076	30	0.34

P, LAI, D, R, T_1 和 $\theta, \theta_s, sbtf$ 以及 Q_1 (这里 $\phi_s=0$); 输出层 17 个节点;输出参数为水稻前向反射和后向反射(观测天顶角 $-60^{\circ}-60^{\circ}$,间隔 7.5°)的双向反射率。即 $m=10, i=10, j=17$ 。偏置值 $x_i, y_j=0.45 (i=1, 2, \dots, 10, j=1, 2, \dots, 17)$, 权值 $A_{im}=0.03, B_{ji}=0.04 (m, i=1, 2, \dots, 10, j=1, 2, \dots, 17)$, 网络学习次数 10000 次。

TM1 波段:取学习步长 $\alpha=0.06$, 冲量因子 $\beta=0.07$, 最大学习误差 $E=0.005480$

TM2 波段:取学习步长 $\alpha=0.1$, 冲量因子 $\beta=0.2$, 最大学习误差 $E=0.005$

TM3 波段:取学习步长 $\alpha=0.08$, 冲量因子 $\beta=$

0.07, 最大学习误差 $E=0.001169$

将处理好的 10 组(7 组实测, 3 组模拟)样本参数输入模型进行训练, 得到模型训练结果如表 2(部分结果)。结果表明, 前向反射, 模型计算值略高于实测值; 在观测天顶角大于零即后向反射时模型计算值普遍低于实测值, 特别是在观测天顶角为 $30^{\circ}-52.5^{\circ}$ 的“热点”区域。1999-08-18 的模拟输出与期望输出的相对误差均在 $\pm 9.09\%$ 之间, 其中一些点的相对误差低于 1% 。1999-08-28, 1999-09-11, 1999-09-29 的相对误差也大部分在 $\pm 9.09\%$ 以内, 个别异常点和“热点”附近相对误差达 10% 以上。

表 2 水稻双向反射模型训练结果(1999 年实测 TM2 波段)

Table 2 Comparison of BRDF measured in 1999 and Network calculated for different viewing zenith angles and training error in principal plane

观测天顶角 $\theta(^{\circ})$	1999-08-18				1999-09-29			
	计算值	实测值	绝对误差	相对误差/%	计算值	实测值	绝对误差	相对误差/%
-60	0.0469	0.0426	-4.25×10^{-3}	-9.06	0.0484	0.0484	-2.32×10^{-5}	-0.06
-52.5	0.0433	0.0396	-3.70×10^{-3}	-8.53	0.0453	0.0446	-6.63×10^{-4}	-1.47
-45	0.0402	0.0384	-1.80×10^{-3}	-4.48	0.0423	0.0397	-2.60×10^{-3}	-6.23
-37.5	0.0359	0.0358	-8.43×10^{-5}	-0.23	0.0376	0.0321	-5.22×10^{-3}	-14.23
-30	0.0341	0.0345	3.50×10^{-4}	1.03	0.0357	0.0301	-5.53×10^{-3}	-15.8
-22.5	0.0324	0.0335	1.11×10^{-3}	3.43	0.0321	0.0281	-4.02×10^{-3}	-12.01
-15	0.0327	0.0327	1.06×10^{-5}	0.03	0.0343	0.0289	-5.44×10^{-3}	-16.16
-7.5	0.0379	0.0412	3.32×10^{-3}	8.79	0.0405	0.0342	-6.35×10^{-3}	-15.83
0	0.0443	0.0486	4.29×10^{-3}	9.69	0.0476	0.0424	-5.21×10^{-3}	-10.95
7.5	0.0493	0.0517	2.45×10^{-3}	4.97	0.0525	0.0424	-5.21×10^{-3}	-3.86
15	0.0569	0.0574	4.87×10^{-4}	0.86	0.0608	0.0620	1.21×10^{-3}	2.27
22.5	0.0633	0.0669	3.66×10^{-3}	5.79	0.0672	0.0670	-2.12×10^{-4}	-0.06
30	0.0676	0.0719	4.24×10^{-3}	6.27	0.0712	0.0719	7.35×10^{-4}	1.3
37.5	0.0703	0.0718	1.48×10^{-3}	2.1	0.0734	0.0754	1.93×10^{-3}	2.86
45	0.0717	0.0694	2.32×10^{-3}	-3.23	0.0745	0.0808	6.33×10^{-3}	8.8
52.5	0.0751	0.0683	-6.83×10^{-3}	-9.09	0.0781	0.0886	1.05×10^{-2}	13.75
60	0.0761	0.0705	5.63×10^{-3}	-7.4	0.0788	0.0882	9.42×10^{-3}	12.28

用 2000-08-07, 2000-08-28, 2000-09-18 和 2000-10-08 的实测数据, 对所建模型进行校核, 计算网络输出结果(表 3 是部分结果)。由表 3 可以看出, 除个别点和热点外, 所建立的 BP 网络模型计算值与实测值的相对误差绝大部分都在 10% 以下, 且由于水稻双向反射“热点”效应造成的相对误差增加得更为明显。2000-08-07 水稻分蘖期, 2000-09-18 水稻灌

浆期, “热点”分别在后向反射观测天顶角为 30°左右和 52.5°—60°时达到, 此时 BP 网络模型计算值与实测值的相对误差也分别达到最大。图 1 则从另一方面更直观地显示了模型的模拟效果和双向反射所具有的“热点”效应。总的来看, BP 模型模拟的水稻双向反射与实测结果变化趋势基本相同, 所具有的一定的误差, 从全局看是可以接受的。

表 3 水稻主平面双向反射率 BP 模型校核结果(2000 年实测数据 TM2 波段)
Table 3 Comparison of BRDF measured in 2000 and Network calculated for different viewing zenith angles and test error in principal plane

观测天顶角 /(°)	2000-08-07				2000-09-18			
	计算值	实测值	绝对误差	相对误差/%	计算值	实测值	绝对误差	相对误差/%
-60	0.1	0.0782	-0.0218	-21.83	0.0997	0.094	-0.0055	-5.49
-52.5	0.0838	0.0899	0.0061	7.28	0.092	0.089	-0.0032	-3.5
-45	0.0834	0.0912	0.0078	9.4	0.0836	0.081	-0.003	-3.65
-37.5	0.0849	0.0936	0.0087	10.32	0.0722	0.069	-0.0032	-4.46
-30	0.0928	0.1051	0.0123	13.28	0.0557	0.049	-0.0063	-11.3
-22.5	0.0855	0.0895	0.004	4.77	0.0518	0.05	-0.0017	-3.36
-15	0.0853	0.0867	0.0014	1.56	0.047	0.046	-0.0007	-1.34
-7.5	0.0843	0.0839	-0.0004	-0.5	0.0443	0.045	0.0003	0.72
0	0.0844	0.0818	-0.0026	-3.16	0.0436	0.043	-0.0003	-0.69
7.5	0.0884	0.0843	-0.0041	-4.65	0.0434	0.042	-0.0011	-2.47
15	0.0989	0.102	0.0031	3.14	0.0405	0.041	0.0007	1.57
22.5	0.0996	0.1069	0.0073	7.32	0.042	0.043	0.0009	2.28
30	0.0999	0.2195	0.1196	119.68	0.0429	0.047	0.0038	8.69
37.5	0.0998	0.0903	-0.0095	-9.55	0.0509	0.053	0.0019	3.66
45	0.0869	0.081	-0.0059	-6.87	0.0667	0.06	-0.0067	-9.97
52.5	0.0808	0.0813	0.0005	0.59	0.0821	0.089	0.0067	8.18
60	0.0909	0.0842	-0.0067	-7.29	0.0538	0.047	-0.0072	-13.3
平均			0.00704	7.264118			-0.00145	-2.02529

2.3.2 反演模型

采用具有 1 层隐含层的 3 层 BP 网络。输入层 22 个节点, 水稻主平面向前反射和后向反射即观测天顶角(-60°—60°, 间隔 7.5°)的 17 个反射率值和

稻叶的 R, T_1 以及 θ_s, sbf 和 Q 等 5 个天空参数和土壤背景参数。隐含层 22 个节点, 输出层 3 个节点, 稻叶的 LAI, L_1 和 P 。这样, $m=22, i=22, j=3$ 。偏置值 $x_i, y_j=0.45 (i=1, 2, \dots, 10, j=1, 2, \dots, 17)$ 。TM1 波段, 取学习步长 $\alpha=0.2$, 冲量因子 $\beta=0.2$, 最大学习误差 $E=6.1798 \times 10^{-3}$




图 1 BP 模型计算值与实测值的比较

Fig.1 Comparison of BRDF measured and calculated of BP model

TM2 波段:取学习步长 $\alpha=0.95$,冲量因子 $\beta=0.95$,最大学习误差 $E=0.0016$

TM3 波段:取学习步长 $\alpha=0.1$,冲量因子 $\beta=0.05$,最大学习误差 $E=6.1290 \times 10^{-3}$

比较分析水稻冠层结构参数 TM1, TM2, TM3 波段反演 BP 模型的训练结果, TM2 波段的反演结果最佳。从表 4 中可以看出,水稻冠层结构参数 LAI (叶面积指数), L_1 (平均长/冠层高度), P (平均宽/长)的反演精度均在 $\pm 81.2\%$ 之上。另外,当叶面积指数大于 3 时,模型反演精度均在 90% 以上。表 5 是 2000 年实测数据校核模型的结果,相比模型训练结果,模型模拟值和实测值的相对误差虽有稍许增加,但仍在 20% 以内,从农学角度是可以接受的。

3 结果分析

一般作物双向反射模型模拟结果与实测值的一致性用均方根误差 ($RMSE$ (Root Mean Square Error)) 检验, $RMSE$ 的计算公式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (mea - cau)^2}{n}}$$

其中, mea 是观测值, cau 是模拟计算值, n 是样本容量。 $RMSE$ 值越小,表明二者拟合得越好。从表示 2000 年实测数据与水稻双向反射 BP 模型不同观测天顶角下 $RMSE$ 值(表 6)可看出,模型拟合得较好。最大的 $RMSE$ 值是 10 的 -3 次方,发生在产生“热点”效应的观测天顶角为 30° 和 60° 左右,因

表 4 水稻冠层结构参数反演 BP 模型训练结果(1999 年 TM2 波段)

Table 4 Comparison of canopy parameters of rice measured in 1999 and invert modeling calculated and training error

日期	LAI			L1			P		
	模拟值	实测值	相对误差/%	模拟值	实测值	相对误差/%	模拟值	实测值	相对误差/%
1999-08-07	2.3	1.9	-17.5	0.40	0.46	15.4	0.039	0.045	16.7
1999-08-28	3.39	3.1	-8.6	0.42	0.44	5.8	0.037	0.036	-1.48
1999-09-18	4.95	5.4	9.1	0.48	0.39	-18.8	0.039	0.04	2.8
1999-10-08	3.55	3.9	9.8	0.37	0.37	0.58	0.038	0.035	-7.7

表 5 水稻冠层结构参数反演 BP 模型校核结果(2000 年 TM2 波段)

Table 5 Comparison of canopy parameters of rice measured in 2000 and invert modeling calculated and test error

日期	LAI			L1			P		
	模拟值	实测值	相对误差/%	模拟值	实测值	相对误差/%	模拟值	实测值	相对误差/%
2000-08-18	1.6	1.4	-19.6	0.49	0.58	15.82	0.039	0.045	13.9
2000-08-28	2.95	3.3	10.6	0.49	0.42	-17.83	0.038	0.037	-2.7
2000-09-11	2.8	3.4	21.4	0.42	0.38	-9.05	0.039	0.04	2.6
2000-09-29	3.4	3.7	8.10	0.587	0.77	23.73	0.045	0.037	-21.7

表6 水稻双向反射BP模型RMSE(2000年)

Table 6 Forward modeling performance using RMSE

观测天顶角/(°)	均方根误差 RMSE
-60	6.33×10^{-4}
-52.5	4.34×10^{-4}
-45	3.14×10^{-4}
-37.5	2.11×10^{-4}
-30	1.37×10^{-4}
-22.5	2.86×10^{-5}
-15	3.00×10^{-6}
-7.5	4.53×10^{-6}
0	1.49×10^{-5}
7.5	1.73×10^{-5}
15	4.79×10^{-6}
22.5	3.29×10^{-5}
30	3.67×10^{-3}
37.5	1.53×10^{-4}
45	2.78×10^{-4}
52.5	3.90×10^{-4}
60	8.81×10^{-4}

此也造成后向反射不如前向反射拟合程度高。这是因为作物双向反射函数是用来描述作物除取决于所测作物的几何形态(冠层结构)特征和光谱性质外,在很大程度上还与入射光方向和观测方向有关的光谱特性。当太阳位于观测者或传感器正后方时,观测者除了自己投射的阴影外,看不到任何植被组分投射的阴影,而所有组分的一次散射均能无阻挡地到达观测者,因而通常植被在此方向的反射达到一个峰值,称作热点效应^[10]。对物理模型而言,基于辐射传输原理和水稻群丛结构的水稻多组分双向反射函数模型,基本能反映出水稻不同生长期的角度分布特征和“热点”所在的位置^[8],但总的拟合精度不如BP模型的高。而神经网络是一组输入输出参数之间的非线性映射,未能包含更多的水稻双向反射的“热点”信息,所以水稻双向反射前向BP模型在“热点”区域,实测值与模拟值相对误差相对稍大(图2),但总的来看,除热点处外,拟合误差还是可以接受的。

研究双向反射模型的最终目的,就是要以遥感信息更精确地反演植被冠层更丰富的结构参数。水稻冠层结构参数的精确和快速反演对监测水稻长势具有重要意义。相比传统的反演方法比如最优化反演技术,水稻冠层结构参数BP反演模型具有同时

反演数个参数且反演速度快的优势,而且反演精度也有所提高^[1],特别是叶面积指数大于3时,由此证明通过水稻冠层结构参数BP反演模型进行水稻长势的监测是可行的。但要使其系统化用于实际,所建模型还有待做进一步的改进,比如引入更多不同水稻品种和年份数据对其进行检验。另外,本研究只选用了主平面不同观测天顶角下的双向反射率及其它有关参数作为输入参数,研究表明,森林垂直平面的双向反射率对森林冠层结构参数反演精度的提高具有重要的作用^[11]。

4 讨论

由于地学研究对象——各种地学系统的复杂性,使得地学模型的建立一直是地学系统定量描述的瓶颈。各种现代非线性科学的植入,给地学带来了新的思维方式和方法论。目前,人工神经网络已广泛应用于各个领域,但将其应用于水稻双向反射前向和反演模型的构建中,还是一种新的尝试。本研究中,由于基于水稻双向反射物理模型选择参数,主要采用实测的大田试验数据作为BP模型训练数据,因而所建水稻双向反射BP前向模型和反演模型,都达到了较高的拟合精度,为水稻双向反射过程的模拟包括前向计算水稻双向反射率和有效、成批反演冠层结构参数提供了一种新思路。水稻的生长状况和双向反射特性紧密相关,要使其BP前向模型和反演模型真正用于水稻的生长监测,还需进一步的探讨比如引入其它水稻品种进行模拟训练,反演模型中引入水稻垂直平面的双向反射率作为输入参数以便进一步的提高反演精度。

参考文献 (References)

- [1] Li YM, Wang RC *et al.* Effects of Rice Canopy Structural Change on Bi-directional Reflectance [J]. *Chinese Journal of Applied Ecology*, 2001, 12(3): 401-404 [李云梅, 王人潮等. 水稻冠层结构变化对双向反射率的影响[J]. 应用生态学报, 2001, 12(3): 401-404]
- [2] Shen GR, Wang RC. Modeling Birectional Reflectance of Multicomponent Rice Canopies [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2001, 17(5): 146-149. [申广荣, 王人潮. 水稻多组分双向反射模型的建立[J]. 农业工程学报, 2001, 17(5): 146-149.]
- [3] Rumelhart D E, Hinton G E, Williams R J. Learning Internal Representations by Error Propagation [A]. In: Rumelhart D E, McClelland J L, eds. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition* [C]. Cambridge: MIT Press, 1986.

- [4] Gong P, Wang D X, Liang S. Inverting a Canopy Reflectance Model Using a Neural Network [J]. *INT. J. Remote Sensing*, 1999, **20** (1): 111—122.
- [5] Helmut Schiller, Roland Doerffer. Neural Network for Emulation of an Inverse Model; Operational Derivation of Case II Water Properties from MERIS Data [J]. *INT. J. Remote Sensing*, 1999, **20** (9): 1735—1746.
- [6] Hong W, Wu CZ. *et al.* A Study on the Model of Forest Resources Management Based on the Artificial Neural Network [J]. *Journal of Natural Resources*, 1998, **13** (1): 130—135 [洪伟, 吴承祯等, 基于人工神经网络的森林资源管理模型研究 [J]. *自然资源学报*, 1998, **13** (1): 130—135]
- [7] Feng P. *et al.* A Drought Degree Evaluation Method Based on the Artificial Neural Network [J]. *Systems Engineer—Theory & Practice*, 2000, **2** (3): 141—144. [冯平等, 基于人工神经网络的干旱程度评估方法 [J]. *系统工程理论与实践*, 2000, **2** (3): 141—144]
- [8] Shen GR, Wang RC. Study on the Multicomponent Bidirectional Reflectance Model for rice [J]. *Chinese Journal of Applied Ecology*, [申广荣, 王人潮. 水稻多组分双向反射模型研究 [J], *应用生态学报*, 已录用。]
- [9] Wang RC, Chen MZ. *et al.* Studies on Agronomic Mechanism of the Rice Yield Estimation by Remote Sensing [J]. *Journal of Zhejiang Agricultural University*, 1993, **19** (Sup.): 7—23. [王人潮, 陈铭臻等. 水稻遥感估产的农学机理研究——II. 农学参数与光谱变量的相关分析 [J]. *浙江农业大学学报*, 1993, **19** (增刊): 7—23.]
- [10] Alan H. Strahler. Vegetation Canopy Reflectance Modeling—Recent Developments and Remote Sensing Perspectives [J]. *Remote Sensing Reviews*, 1997, **15** (15): 179—184.
- [11] Anelgadiri A Abuelgasim, Sucharita Gopal, Alan H Strahler. Forward and Inverse Modeling of Canopy Directional Reflectance Using a Neural Network [J]. *INT. J. Remote Sensing*, 1998, **19** (3): 453—471.

Study on Bi-directional Reflectance Model of Rice Using a Artificial Neural Network

SHEN Guang-rong, WANG Ren-chao

(*Institute of Agriculture Remote Sensing and Information Application, Zhejiang University, Hangzhou 310029, China*)

Abstract: There are nonlinear relations among the bi-directional reflectance of rice, its canopy architecture parameters, the spectral characteristics of the different components of rice, and the illumination and viewing geometry. This article explores the use of artificial neural network for both forward and inverse bi-directional reflectance modeling of rice based on the data measured in Zhejiang University (Hangzhou, China) for field experiments from 1999 to 2000. The assumption here is that the bi-directional reflectance of a rice canopy is the function of the geometry of its constituent elements, the spatial distribution, spectral features of the elements, and the illumination and viewing geometry. This implies that the bi-directional reflectance of the canopy is particular sensitive to the canopy's structural parameters, the spectral characteristic of foliage, and the illumination and viewing direction. It also implies that canopies with different parameters will exhibit different bi-directional reflectance. On the basis of these analysis, we decided to have 10 input parameters: model inclination angle of the canopy (θ), eccentricity (D), reflectance of foliage (R), transmittance (T_1), sun zenith angle (θ_s), soil reflectance ($sbrf$), the ratio of mean length to canopy height (L_1) and the ratio of width to length (P), leaf area index (LAI), diffuse to total incident radiation (Q_1). There are 17 output parameters: bi-directional reflectance of the canopy in the principal plane, from -60° in the forescattering direction to $+60^\circ$ in the backscattering direction at increments of 7.5° in forward BP model. On the other hand, there are 3 output parameters: leaf area index, the ratio of mean length to canopy height and the ratio of width to length, and other 22 parameters mentioned above except eccentricity and model inclination angle of the canopy are input parameters in inverse BP model.

After model development, the neural network model is tested against the independent data set. The Root mean square error between the bi-directional reflectance of rice measured and simulated varies from 4.53×10^{-6} to 3.67×10^{-3} . The inversion model of artificial neural network is able to inverse the rice canopy structural parameters with 81.8% accuracy. The results of both forward and inverse modeling suggest that the model of artificial neural network is of high precise to simulate the relations of the bi-directional reflectance of rice and its canopy structural parameters. Further research is needed to monitor the rice growth by the neural network model.

Key words: neural network; BP algorithm; rice; bi-directional reflectance; inverse