

基于BP神经网络和支持向量机的杉木人工林收获模型研究

林卓¹ 吴承祯^{1,2} 洪伟¹ 洪滔¹

(1 福建农林大学林学院 2 武夷学院)

摘要:以闽西北杉木人工林为研究对象,选取涵盖中龄林、近熟林、成熟林3个龄组的700个小班作为样地进行调查,以林龄、地位指数、林分密度、平均胸径作为输入变量,单位蓄积量为输出变量,运用BP神经网络和支持向量机2种机器学习方法建立林分收获模型,并采用遗传算法对模型参数进行优化。随机将样本数据分成350个训练样本和350个验证样本,对不同模型的拟合精度、预测精度进行对比分析,其中参数优化后的BP神经网络和支持向量机模型训练样本精度分别达到0.93537和0.93633,预测结果精度分别为0.92130和0.92697,训练样本和验证样本的总体拟合平均相对误差值均低于7%。分析结果表明,2种模型拟合精度高、预测性能好,为杉木人工林林分收获模拟和预测奠定了基础。为比较2种方法预测结果的差异性,将350个验证样本样地平均分为7组,分别用优化后的2种模型计算各组的预测精度,对预测精度与训练精度的差值进行*t*检验,结果表明,2种建模方法的预测结果不存在显著性差异,但模型精度的提高对森林资源的精确监测和森林生长动态预测具有重要的理论价值。同时,研究发现支持向量机模型的拟合精度和泛化能力均优于BP神经网络,该方法为收获模型研究提供了新思路。

关键词:杉木人工林;收获模型;机器学习;预测;拟合

中图分类号:S758.5⁺1 文献标志码:A 文章编号:1000-1522(2015)01-0042-06

LIN Zhuo¹; WU Cheng-zhen^{1,2}; HONG Wei¹; HONG Tao¹. **Yield model of *Cunninghamia lanceolata* plantation based on back propagation neural network and support vector machine.** *Journal of Beijing Forestry University* (2015)37(1) 42-47 [Ch, 21 ref.]

1 College of Forestry of Fujian Agriculture and Forestry University, Fuzhou, Fujian, 350002, P. R. China;

2 Wuyi University, Wuyishan, Fujian, 354300, P. R. China.

Based on data from 700 sample plots of *Cunninghamia lanceolata* plantations in the northwestern area of Fujian Province, consisting of middle-aged, near-mature and mature trees, we established a yield model with stand age, site index, stand density and average diameter at breast height (DBH) as input variables and stand volume as the output variable. We used two machine learning methods, i. e., a back propagation (BP) neural network and a support vector machine (SVM). The parameters used in both modeling methods were optimized by a genetic algorithm. We randomly divided the plots into two halves, i. e., a 350 plot training set and a 350 plot test set and compared the fit and prediction accuracies of both models. After parameter optimization, the accuracies in fitting both models were 0.93537 for BP and 0.93633 for the SVM, with prediction accuracies of 0.92130 for BP and 0.92697 for the SVM. The average relative errors of both the training and test sets were less than 7% for both models. We conclude that both models established a basis for simulating and predicting stand yield of *C. lanceolata* plantations, given that the accuracy of both models was quite high with good performance of prediction. In order to analyze the differences in the results of both models, the 350 plot test set was evenly divided into seven groups. We calculated the prediction accuracy in each group with two optimization models and used a

收稿日期:2014-03-24 修回日期:2014-08-19

基金项目:福建省科技重大专项(2012NZ0001)。

第一作者:林卓,博士生。主要研究方向:森林经理学、森林可持续经营。Email:linchamp@163.com 地址:350002 福建省福州市仓山区上下店路15号福建农林大学林学院。

责任作者:吴承祯,教授,博士生导师。主要研究方向:森林经理学、森林生态学。Email:fjwcz@126.com 地址:同上。

本刊网址: <http://j.jbfu.edu.cn>; <http://journal.bjfu.edu.cn>

t-test to compare the absolute difference between the prediction and fitting accuracy. The results showed no significant difference between the two methods. All the same, the slight improvement in precision is important and valuable for monitoring forest resources as well as for predicting the dynamics of stand growth. We found that the accuracy of the fit and generalization ability of SVM were better than those of BP. Therefore, we recommend the SVM for providing new insights for research in forest yield models.

Key words *Cunninghamia lanceolata*; yield model; machine learning; predicting; fitting

林分收获模型的研究一直是森林资源监测与管理的重要组成部分,林分收获量的准确预测对森林经营及其方案编制意义重大,是实现森林资源可持续经营的基础。为此,广大林业科技工作者对其进行了大量研究。由林分生长理论可知,森林资源动态变化过程实质上是一个非线性的映射过程^[1]。以往的一些收获模型是通过简化假设进行表述,对一些复杂的和非线性的关系难以准确描述。随着科学技术的进步,基于机器学习的人工智能算法越来越受到关注,在林业领域中应用较多的是前馈神经网络,如 BP 神经网络和径向基神经网络。许多学者运用神经网络对林分收获模型进行了研究, Diamantopoulou 等^[2]、黄家荣等^[3]、李良松^[4]、徐步强等^[5]、杨潇等^[6]利用不同的输入输出因子建立林分收获模型,对林分的生长收获进行预测。支持向量机作为近 20 年来兴起的可训练机器学习方法,在解决小样本、非线性及高维模式识别中表现出许多特有的优势,进而被应用到不同领域的函数拟合回归问题中。该回归方法在林业领域上的应用鲜见报道,仅车少辉^[7]首次对杉木 (*Cunninghamia lanceolata*) 人工林林分断面面积构建了支持向量机的回归模型。在此基础上,本文以闽西北将乐县杉木人工林为研究对象,利用 BP 神经网络和支持向量机建立林分蓄积量收获模型,并比较和分析 2 种不同方法的建模效果,丰富林分收获预估理论与方法,为更有效地进行森林经营管理提供理论依据。

1 材料与方 法

1.1 材料来源

本研究选取福建省金森股份有限公司所经营的杉木人工林为研究对象,地处福建省西北部的三明市将乐县。在杉木人工林幼龄阶段,常采取多种幼林抚育措施对林分小班内的环境因子进行调整,不同的抚育管理模式会对林分蓄积生长产生较大的影响^[8],且幼龄林单位蓄积量较低。为降低人为因素对杉木生长和收获的影响,本研究仅以杉木中龄林、近熟林、成熟林为对象进行收获模型研究。为此,在研究区内选择不同年龄、不同立地质量、不同密度且未受到明显人为干扰的杉木人工林,设置样地 700

个,样地面积 600 m²。对各样地进行每木检尺,调查每株林木的胸径、树高及每 100 m² 优势木的胸径和树高,采用二元材积表计算每木材积并统计林分蓄积量。主要测树因子分布范围为:林龄 11 ~ 33 年,平均胸径 5.1 ~ 46 cm,林分密度 450 ~ 3 975 株/hm²,平均树高 4.2 ~ 19.6 m,优势木平均高 4.4 ~ 20.6 m,蓄积量 15 ~ 246 m³/hm²。

1.2 理论模型

林分生长收获模型是指用一组数学函数来描述林分的状态,揭示林木生长与立地条件的关系。根据 Avery 等^[9]、David 等^[10]的分类方法,全林分生长模型 (Whole stand growth model) 的特点是将林分生长量或收获量作为林分特征因子如年龄、立地条件、密度的函数来预测整个林分的生长和收获,即:

$$M = f(t, SI, SD) \quad (1)$$

式中: M 为蓄积量; t 为年龄;SI 为地位指数;SD 为林分密度。

地位指数是表示林分立地质量常用的指标,根据 Schumacher 方程,地位指数模型为:

$$H_T = SI \cdot \exp(-b/t + b/t_1) \quad (2)$$

式中: H_T 为林分优势高;SI 为地位指数; t_1 为地位指数基准年龄,杉木基准年龄为 20 年; b 为参数。

人工林林分密度常使用林分密度指数 (Stand density index, SDI) 表示,根据 Reineke^[11] 和 Daniel 等^[12]的研究,基本模型为:

$$SDI = f(N, D) \quad (3)$$

式中: N 为单位面积株数, D 为平均胸径。

综合式(1)、(2)、(3),根据获得的数据,本研究建立的模型为:

$$M = f(t, SI, N, D) \quad (4)$$

公式(4)中的 t 、SI、 N 、 D 为模型数据的输入向量, M 为输出向量,其中 SI 根据式(2)由 H_T 计算,其余数据由直接调查获得。

1.3 BP 神经网络

BP 神经网络 (Back propagation artificial neural network, BP-ANN) 是一种多层前馈神经网络,主要特点是信号前向传递、误差反向传播。在前向传递中,输入信号从输入层经隐含层逐层处理,直至输出层,每一层神经元状态只影响下一层神经元状态。

如果输出层得不到期望输出,则转入反向传播,根据预测误差调整网络权值和阈值,从而使预测输出不断逼近期望输出。将输入层和输出层看作自变量和因变量,BP神经网络就表达了自变量到因变量的非线性函数映射关系。BP-ANN模型在林业领域运用的研究成果较多,详细的模拟原理和步骤参阅文献[13-14]。

1.4 支持向量机

支持向量机(Support vector machine,SVM)是由Vapnik首先提出的,其主要思想是建立一个分类超平面作为决策曲面,使正例和反例之间的隔离边缘被最大化^[15]。SVM是基于统计学理论的VC维(Vapnik-Chervonenkis dimension)理论,是一种结果风险最小化的近似实现,其学习算法是对有限样本信息在模型复杂性(即对训练样本的学习精度)和学习能力中寻找最优折衷,以期获得最好的泛化能力^[16]。SVM运用于回归问题的基本思路参阅文献[17-18]。

1.5 遗传算法

遗传算法(Genetic algorithm,GA)是由Holland教授提出的根据模拟自然界遗传机制和生物进化论的并行随机搜索最优方法。受自然界“优胜劣汰,适者生存”的生物进化论的启发,GA对参数形成的编码串联群体进行优化,按照所选择的适应度函数并通过遗传过程中的选择(Select)、交叉(Crossover)、变异(Mutation)等操作对个体进行筛选,保留适应值好的个体,淘汰差的个体,子代种群继承父代,又优于父代,如此循环,直至满足预设条件^[19]。

本研究的编码过程采用实数法,选取轮盘赌注法作为选择策略,使用实数交叉法进行交叉操作。在建模过程中利用GA对BP-ANN和SVM进行参数寻优,全局搜索优化BP-ANN的初始权值和阈值,具体步骤参阅文献[20]。SVM的优化步骤类似,优化对象参数为惩罚参数 c 、核参数 g 、不敏感损失参数 p ,以CV验证(Cross-validation,交叉验证)的误差作为适应值进行判断。

2 结果与分析

对所有样本进行随机抽取,确定350个训练样本、350个验证样本,拟合结果使用均方误差(Mean square error,MSE)和决定系数(R^2)作为判别模型的标准,用相对误差(Relative error,RE)判断预测结果的精度。

2.1 基于BP神经网络的拟合

BP-ANN模型中隐含层可以分为单隐含层与多隐含层。Funahashi^[21]证明单隐含层BP-ANN模型能够以任意精度逼近任意函数。虽然与单隐含层相

比,多隐含层的BP-ANN可以提高精度,但训练时间较长,且参数较多。鉴于本研究输入输出因子相对简单,在网络精度达到要求的情况下,选取单隐含层进行模型构建。

2.1.1 运行环境设定

使用最大最小法将输入、输出向量分别归一化到[0,1]区间,消除初始数据的量纲差异。节点转移函数分别为logsig($f_H = 1/(1 - \exp(-x))$)和tansig($f_O = 2/(1 - \exp(-2x)) - 1$),学习训练函数选择trainlm(Levenberg-Marquardt优化算法)。学习速率为0.05,最大迭代次数为1000,最小训练误差目标为0.001,隐含层节点数经试凑法确定为10。GA设置进化代数50、种群规模为20、交叉概率为0.7、变异概率为0.01,对优化前后各进行10次模拟拟合,取训练样本精度最高的2组模型对检验样本进行验证,计算模型精度。

2.1.2 模型建立

经计算,参数未优化前模型对训练样本的拟合结果为 $MSE = 0.002655$, $R^2 = 0.91651$;GA进化过程中以平均误差量作为适应度指标,到第14代时平均误差量达到最小值11.909,优化后模型对训练样本拟合精度提高到 $MSE = 0.002053$, $R^2 = 0.93537$ 。利用优化前后2种模型对验证样本进行检验,计算预测结果和相对误差,并按龄组进行统计(表1),结果表明2种模型整体预测效果都较好,其中BP-ANN模型预测结果平均相对误差为6.97%,GA-BP-ANN模型预测结果相对误差平均值为6.64%。

2.2 基于SVM的拟合

2.2.1 运行环境设定

根据SVM模型的建模要求,在输入、输出向量归一化的基础上,默认采用栅格搜索法(Grid search,GS)寻找最优 c 和 g ,初始取值范围均为 $[-8,8]$, p 值取0.05,进行5折CV验证。在GA优化 c 、 g 、 p 参数值时,设置进化代数为100、种群规模为20、交叉概率为0.7、变异概率为0.01, c 值初始取值范围 $(0,100]$, g 值初始取值范围 $[0,1000]$, p 值初始取值范围 $[0.01,1]$,进行5折CV验证。

2.2.2 模型建立

通过GS法寻找到最优值 $c = 1.004$ 、 $g = 0.57435$,获得最小交叉验证均方误差 $CV_{mse} = 0.002559$,模型训练样本拟合结果为 $MSE = 0.002233$, $R^2 = 0.92973$;以 CV_{mse} 作为适应度指标,用GA优化参数进化100代终止,得到最小 $CV_{mse} = 0.002281$,优于GS法搜索结果,对应参数 $c = 74.863$ 、 $g = 0.5064$ 、 $p = 0.058641$,获得训练模型精度为 $MSE = 0.002044$, $R^2 = 0.93633$ 。计算2组模型对验证

样本的验证结果(表1),从预测相对误差量看,结果较为理想,其中 GS-SVM 模型预测相对误差平均值 6.62%; GA-SVM 模型预测相对误差平均值 6.27%。

表1 验证样本预测结果的相对误差

Tab.1 Relative error of predicting results from test samples

%

龄组 Age group	样本数 Number of samples	BP-ANN			GA-BP-ANN			GS-SVM			GA-SVM		
		平均值 Average (\overline{RE}_1)	最大值 Maximum	最小值 Minimum	平均值 Average (\overline{RE}_2)	最大值 Maximum	最小值 Minimum	平均值 Average (\overline{RE}_3)	最大值 Maximum	最小值 Minimum	平均值 Average (\overline{RE}_4)	最大值 Maximum	最小值 Minimum
中龄林(11~20年) Middle-aged plantation (11-20 years)	38	11.72	29.82	0.63	10.12	27.19	1.06	10.67	28.54	0.59	9.15	27.69	0.62
近熟林(21~25年) Near-mature plantation (21-25 years)	226	6.22	28.49	0.07	6.10	19.96	0.03	6.03	22.95	0.12	5.78	20.83	0.02
成熟林(26~35年) Mature plantation (26-35 years)	86	6.82	17.82	0.06	6.53	19.97	0.03	6.38	19.56	0.07	6.27	17.69	0.06

2.3 模型的比较分析

2.3.1 相对误差分析

从验证样本的预测相对误差值(表1)可以看出, BP神经网络和支持向量机对单位蓄积量的预测结果都比较理想,且支持向量机的整体预测效果略优于 BP神经网络($\overline{RE}_3 < \overline{RE}_1, \overline{RE}_4 < \overline{RE}_2$)。对训练样本的拟合结果也按龄组进行统计(表2)。不难发现,训练样本和验证样本的结果都表

明模型对近、成熟林的拟合效果优于中龄林。分析其原因,可能是由于中龄林的样本数偏少,导致训练不够充分,或是针对中龄林,模型选择的输入因子与输出因子间关系不够紧密或输入因子不够全面,以至于出现相对较大的偏差。但模型整体模拟效果仍然较好,进一步反映出 BP神经网络和支持向量机模型的稳定性和可靠性,说明模型具有较强的鲁棒性。

表2 训练样本拟合结果的相对误差

Tab.2 Relative error of fitting results from training samples

%

龄组 Age group	样本数 Number of samples	BP-ANN			GA-BP-ANN			GS-SVM			GA-SVM		
		平均值 Average (\overline{RE}_1)	最大值 Maximum	最小值 Minimum	平均值 Average (\overline{RE}_2)	最大值 Maximum	最小值 Minimum	平均值 Average (\overline{RE}_3)	最大值 Maximum	最小值 Minimum	平均值 Average (\overline{RE}_4)	最大值 Maximum	最小值 Minimum
中龄林(11~20年) Middle-aged plantation (11-20 years)	39	8.28	28.38	0.63	8.19	27.72	0.92	8.07	28.79	0.50	7.67	18.96	0.62
近熟林(21~25年) Near-mature plantation (21-25 years)	228	6.18	20.97	0.07	5.77	19.51	0.01	5.98	17.26	0.13	5.70	17.50	0.02
成熟林(26~35年) Mature plantation (26-35 years)	83	6.09	28.51	0.06	5.30	22.05	0.03	5.22	12.97	0.06	4.64	14.69	0.05

2.3.2 模型精度分析

模型的拟合结果表明 BP神经网络和支持向量机的建模方法都能满足公式(4)所建立的收获模型的精度要求(表3)。从训练样本结果来看,拟合能力依次为 GA-SVM > GA-BP-ANN > GS-SVM > BP-ANN,说明支持向量机与 BP神经网络都具有很强的逼近能力,其中支持向量机模型精度高于同等优

化条件下的 BP神经网络模型。同时,由于支持向量机是采用结果风险最小化为目标,所求的解是唯一值,且为全局最优,而 BP神经网络是基于经验风险最小化,且每次训练结果不固定,所以在泛化能力上支持向量机模型也会优于同等参数优化算法的 BP神经网络模型,从验证样本的预测结果精度 GA-SVM > GA-BP-ANN 得到验证。

模型建立的本质是参数的确定,参数的好坏决定了模型的性能,无论是BP神经网络还是支持向量机,找到参数的最优值是模型建立成功的关键。因此通过各种优化算法对模型参数进行寻优,对模型精度的提高有很大帮助。本研究通过遗传算法分别对BP神经网络和支持向量机进行参数优化后,模型精度得到相应的提高。从各模型训练样本和验证样本的 R^2 结果可以看出:GA-BP-ANN > BP-ANN,GA-SVM > GS-SVM。

表3 收获模型拟合结果比较

Tab. 3 Comparisons of the fitting results by different yield models

模型 Model	训练样本 Training samples		检验样本 Test samples	
	MSE	R^2	MSE	R^2
	BP-ANN	0.002 655	0.916 51	0.002 570
GA-BP-ANN	0.002 053	0.935 37	0.002 475	0.921 30
GS-SVM	0.002 233	0.929 73	0.002 318	0.926 86
GA-SVM	0.002 044	0.936 33	0.002 313	0.926 97

由于BP神经网络和支持向量机的基本原理不同,运行机理也不一致,所以对模型拟合结果差异显著性分析,能够更好地对结果进行分析比较。将350个验证样地随机分成7组,每组50个样本,选取训练好的参数优化后模型,即GA-BP-ANN和GA-SVM,对7组样地进行预测,并统计各组的预测精度 R^2 (表4),计算预测精度与训练精度的差值 $|D_{R^2}|$ 。

表4 验证样本分组拟合结果比较

Tab. 4 Comparisons of the fitting results of GA-BP-ANN and GA-SVM for seven groups

分组 Group	GA-BP-ANN		GA-SVM	
	R^2	$ D_{R^2} $	R^2	$ D_{R^2} $
第1组 No. 1	0.918 11	0.017 26	0.926 80	0.009 53
第2组 No. 2	0.919 36	0.016 01	0.921 15	0.015 18
第3组 No. 3	0.907 20	0.028 17	0.907 07	0.029 26
第4组 No. 4	0.944 72	0.009 35	0.942 61	0.006 28
第5组 No. 5	0.951 32	0.015 95	0.955 92	0.019 59
第6组 No. 6	0.925 50	0.009 87	0.934 12	0.002 21
第7组 No. 7	0.904 08	0.031 29	0.914 66	0.021 67

注: $|D_{R^2}|$ 为验证样本的 R^2 与训练样本 R^2 的差值。Notes: $|D_{R^2}|$ is the difference of R^2 between training and test samples.

利用SPSS软件对其进行差异显著性检验,选择 t 检验方法,得到结果sig(双侧)值为0.485,表明2种方法的拟合结果不存在显著性差异。虽然2种建模方法在结果上不存在显著性差异,但按精准林业、现代林业的建设要求,提高林业计测模型的精度对实现森林资源的精确监测与森林生长的动态预测具有重要的理论价值与实践意义。

3 结论与讨论

本研究利用BP神经网络和支持向量机等机器学习方法对杉木人工林的收获模型进行拟合,建立了以现实林分年龄、地位指数、平均胸径、单位面积株数为输入向量,单位蓄积量为输出向量的预测模型。模型拟合效果较好,估计精度高,其中支持向量机的拟合效果优于BP神经网络。在模型回归函数求解方面,BP神经网络类似“黑箱”学习,输出的函数结果常不确定,而支持向量机输出结果固定,可以求得唯一的回归函数。支持向量机回归在林业领域的运用还相对较少,值得研究和推广。

同时,研究结果表明,训练数据的准确性和可靠性影响着模型的精度和预测能力;提高模型利用有效数据的能力以减少噪音数据的影响以及运用优化算法对模型参数进行寻优,都是提高模型拟合能力、减少预测误差的有效手段。本研究通过利用遗传算法优化2种模型的参数,确实提高了模型的拟合能力,但模型优化通常会导致训练时间的增加,如何平衡训练速度和预测精度,使模型更加实用化也值得进一步探讨。

对林分收获模型的研究其目的一方面在于精确预测林分的蓄积量,另一方面则是希望通过模型揭示林分特征因子与林分收获量之间的关系,了解各因素的影响效果,为实施森林经营提供决策参考。利用对模型中可控变量的修正,如林分密度、立地条件等,通过适当的营林措施调整模型的输入,以达到预期森林经营目标的输出。虽然BP神经网络和支持向量机在对林分收获模型模拟预测的应用上值得肯定,但这些机器学习模型通常缺乏林学、生态学方面的解释,且本研究对象只选取未遭到明显人为干扰的中龄林、近熟林、成熟林,并未对幼龄林进行研究,所以如何充分应用已有的林分生长理论,在一定的生物学假设前提下,引入更多的影响因子建立更加准确的预测模型,并扩大模型适用范围,仍然需要林业工作者进行更深入的探索性研究。

参 考 文 献

- [1] 洪伟,吴承祯,何东进.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):69-72.

- HONG W, WU C Z, HE D J. A study on the model of forest resources management based on the artificial neural network [J]. Journal of Natural Resources, 1998, 13(1): 69-72.
- [2] DIAMANTOPOULOU M J, MILIOS E. Modelling total volume of dominant pine trees in reforestation via multivariate analysis and artificial neural network models [J]. Biosystems Engineering, 2010, 105(3): 306-315.
- [3] 黄家荣, 高光芹, 孟宪宇, 等. 基于人工神经网络的林分直径分布预测[J]. 北京林业大学学报, 2010, 32(3): 21-26.
HUANG J R, GAO G Q, MENG X Y. Forecasting stand diameter distribution based on artificial neural network. [J]. Journal of Beijing Forestry University, 2010, 32(3): 21-26.
- [4] 李良松. 南方红豆杉人工林生长与收益模型研究 [D]. 北京: 北京林业大学, 2011.
LI L S. Research on growth and profit model of *Taxus chinensis* var. *mairei* plantation [D]. Beijing: Beijing Forestry University, 2011.
- [5] 徐步强, 张秋良, 弥宏卓, 等. 基于 BP 神经网络的油松人工林生长模型[J]. 东北林业大学学报, 2012, 39(12): 33-35.
XU B Q, ZHANG Q L, MI H Z, et al. Growth model of *Pinus tabulaeformis* plantation based on BP neural network [J]. Journal of Northeast Forestry University, 2012, 39(12): 33-35.
- [6] 杨潇, 张秋良. 基于 BP 神经网络的大青山自然保护区华北落叶松人工林全林分生长模型研究[J]. 内蒙古农业大学学报: 自然科学版, 2012, 33(5-6): 76-79.
YANG X, ZHANG Q L. Based on artificial neural network modeling of the *Larix principis rupprechtii* Mayr plantation at daqing mountain in Inner Mongolia [J]. Journal of Inner Mongolia Agricultural University: Natural Science Edition, 2012, 33(5-6): 76-79.
- [7] 车少辉. 基于神经网络方法的杉木人工林林分生长模拟研究 [D]. 北京: 中国林业科学研究院, 2012.
CHE S H. Growth modeling for Chinese fir plantation based on artificial neural network [D]. Beijing: Chinese Academy of Forestry, 2012.
- [8] 陈文平. 杉木人工林不同幼林抚育模式对生长量影响的分析 [J]. 海峡科学, 2008(8): 26-27.
CHEN W P. Analysis of the influence of young Chinese fir's different plantation tending modes on the amount of growth [J]. Straits Science, 2008 (8): 26-27.
- [9] AVERY T E, BURKHAR H E. Forest Measurements [M]. 4th ed. New York: McGraw-Hill Book Company, 1994.
- [10] DAVIS L S, JOHNSON K N. Forest Management [M]. New York: McGraw-Hill Book Company, 1987.
- [11] REINEKE L H. Perfecting a stand-density index for even-aged forests [J]. Journal of Agriculture Research, 1933, 46: 627-638.
- [12] DANIEL T W, HELMS J A, BAKER F S. Principles of silviculture [M]. New York: McGraw-Hill Book Company, 1979.
- [13] GULLU M, YILMAZE İ, YILMAZE M, et al. An alternative method for estimating densification point velocity based on back propagation artificial neural networks [J]. Studia Geophysica et Geodaetica, 2011, 55(1): 73-86.
- [14] KOTB M T, HADDARA M, KOTB Y T. Back-propagation artificial neural network for ERP adoption cost estimation [J]. Enterprise Information Systems, 2011, 220: 180-187.
- [15] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20(3): 273-297.
- [16] BURGESS C J C. A tutorial on support vector machines for pattern recognition [J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121-167.
- [17] 胡欣欣. 龙栖山国家级自然保护区森林景观格局分析及其生态评价 [D]. 福州: 福建农林大学, 2009.
HU X X. Analysis of landscape pattern of Longqishan national nature reserve and its ecology evaluation [D]. Fuzhou: Fujian Agriculture and Forestry University, 2009.
- [18] 岳彩荣. 香格里拉县森林生物量遥感估测研究 [D]. 北京: 北京林业大学, 2011.
YUE C R. Forest biomass estimation in Shangri-La County based on remote sensing [D]. Beijing: Beijing Forestry University, 2011.
- [19] 林晗, 洪滔, 陈辉, 等. 应用遗传算法的工业原料林多树种造林设计 [J]. 林业科学, 2010, 46(5): 92-101.
LIN H, HONG T, CHEN H, et al. Multi-species design in planting industrial forests by genetic algorithm [J]. Scientia Silvae Sinicae, 2010, 46(5): 92-101.
- [20] SEDIGHI M, AFSHARI D. Creep feed grinding optimization by an integrated GA-NN system [J]. Journal of Intelligent Manufacturing, 2010, 21(6): 657-663.
- [21] FUNAHASHI K I. On the approximate realization of continuous mappings by neural networks [J]. Neural Networks, 1989, 2(3): 183-192.

(责任编辑 冯秀兰
责任编辑 惠刚盈)