

基于机器学习的杉木树高-胸径模型研建

王贵林^{1,2}, 谭伟^{1,2*}

(1. 贵州大学林学院 贵州 520025; 2. 贵州大学林业信息工程研究中心 贵州 520025)

摘要:【目的】基于 TensorFlow 和 Sklearn 平台利用深度神经网络 (DNN)、支持向量回归 (SVR) 和随机森林 (RF) 3 种机器学习算法建立杉木的树高-胸径模型, 探求一种更加高效的杉木树高预测方法。【方法】以清镇国有林场 49 块样地中杉木的胸径、树高数据, 分成不同比例的训练集和测试集组, 分别为建模数据占比 (20%、30%、40%、50%、60%、70%、80%) 和检验数据占比 (80%、70%、60%、50%、40%、30%、20%)。利用 DNN、SVR 和 RF 拟合树高-胸径模型, 并将 3 种算法拟合的模型与 11 个传统基础模型进行比较, 通过 R^2 、RMSE 和 MAE 的结果对比选出预测效果最好的模型。【结果】利用 DNN 和 SVR 建立的树高-胸径模型在训练集较少的情况下, 其预测精度 R^2 分别能达到 0.671 和 0.65 以上。在训练集占比 40% 时, 传统基础模型才能在精度上略高于机器学习的方法。在基础模型的预测中, 精度最高的为在训练集占比 20% 情况下的 DNN 模型, 其 R^2 为 0.671, RMSE 和 MAE 分别为 2.024 和 1.599, 在所有模型中, 其预测精度最高。而 SVR 预测精度最高在训练集占比 30% 时, 其 R^2 为 0.658, RMSE 和 MAE 分别为 2.072 和 1.652。对 DNN 中的 Dropout、L2、Reduce 和 Relu 四种模型进行其预测值与真实值进行残差分析, 四种模型的拟合分布符合客观规律。【结论】使用深度神经网络、支持向量回归和随机森林构建杉木的树高-胸径模型, 并且通过与传统模型的对比, 得出深度神经网络和支持向量回归在训练集占比较少少的情况下, 其预测精度要高于传统基础模型。而利用 DNN 构建的模型比传统基础模型在某些特定情况下可以不用受到传统统计学的限制, 能够更加简单的使数据收敛, 为精准预测树高提供更好的可能。从而能够在数据量较少的情况下精准预测出杉木的树高。
关键词: 杉木; 深度神经网络; 支持向量回归; 随机森林; 树高胸径模型;

Research and construction of a height diameter model for *Cunninghamia lanceolata* based on machine learning

Abstract: 【Objective】Based on TensorFlow and Sklearn platforms, three machine learning algorithms, namely deep neural network (DNN), support vector regression (SVR) and random forest (RF), were used to establish the tree height-DBH model of Chinese fir, and a more efficient tree height prediction method was explored. 【Method】The DBH and tree height data of Chinese fir trees in 49 plots of Qingzhen State-owned forest farm were divided into training set and test set groups with different proportions, which were respectively the proportion of modeling data (20%, 30%, 40%, 50%, 60%, 70%, 80%) and the proportion of inspection data (80%, 70%, 60%, 50%, 40%, 30%, 20%). DNN, SVR and RF were used to fit the tree-height-DBH model, and the models fitted by the three algorithms were compared with 11 traditional basic models. The model with the best prediction effect was selected by comparing the results of R^2 and RMSE and MAE. 【Result】The tree height diameter model established using DNN and SVR can achieve R^2 prediction accuracy of 0.671 and 0.65, respectively, when the training set is small. Only when the training set accounts for 40% can traditional basic models have slightly higher accuracy than machine learning methods. In the prediction of basic models, the DNN model with the highest accuracy is the one with a training set proportion of 20%, with an R^2 of 0.671, RMSE and MAE of 2.024

第一作者: 王贵林 (1998 年-), 硕士研究生, 主要从事森林可持续经营, E-mail: 1320474920@qq.com;

通信作者: 谭伟 (1973 年-), 教授, 主要从事森林可持续经营、林业信息和 3S, E-mail: wtan@gzu.edu.cn ;

分类号: S757

and 1.599, respectively. Among all models, its prediction accuracy is the highest. The highest prediction accuracy of SVR is achieved when the training set accounts for 30%, with an R^2 of 0.658, RMSE and MAE of 2.072 and 1.652, respectively. Residual analysis was conducted on the predicted and true values of Dropout, L2, Reduce, and Relu models in DNN, and the fitting distribution of the four models followed objective laws. 【Conclusion】 Deep neural network, support vector regression and random forest were used to construct a height-DBH model of Chinese fir. Compared with the traditional model, it was concluded that the prediction accuracy of deep neural network and support vector regression was higher than that of the traditional basic model when the training set was relatively small. Compared with the traditional basic model, the model constructed by DNN can not be restricted by traditional statistics in some specific cases, and can more easily converge the data, providing a better possibility for accurate prediction of tree height. Thus, the tree height of fir can be accurately predicted in the case of a small amount of data.

Keywords: *Cunninghamia lanceolata*; DNN; SVR; RF; Height-diameter model.

树高和胸径作为林业行业中基础的调查因子，在树木的描述中占据极大的比重（曾翀等，2009；梁瑞婷等，2021）。通过树木的树高和胸径能够进行单木材积计算、林分生长预测以及森林资源状况统筹等重要工作（牛思圆等，2023；Wu *et al.*, 2019；Fu *et al.*, 2023）。胸径在调查中可以通过围尺进行最简单也最为精准的测定（Mokroš *et al.*, 2018），但是树高在实际工作实践中由于受到环境因子限制而不易获得。大量研究证明，树木的胸径和树高之间存在着显著相关关系，通过胸径建立树高-胸径模型能够对树高进行预测，大部分都是通过先建立基础树高-胸径模型，在通过广义模型加入其余参数，拟合出高精度模型，采用非线性混合效应模型提升模型精度，做到高精度预测树高（郭卫红等，2022；王景弟等，2021；刘金义，2022；李晓晶，2020；卯光宪等，2020；郭嘉等，2019）。树高-胸径模型建立的好坏还能够影响森林地上生物量（Loubota *et al.*, 2021；Deng *et al.*, 2019）。而在以往的树种胸径相关关系的研究中，采用的模型主要采用传统的非线性基础模型对两者的相关关系进行拟合，并且在此基础上会考虑到地形、树种、坡度和坡位等因素的具体影响力大小，并借此提高模型拟合精度（Mensah *et al.*, 2018；Khamyong *et al.*, 2018）。

近年来，机器学习的不断发展，为林业带来机遇，深度学习与林业产业的结合在不断提高工作效率。Dantas 等人利用混合效应模型、ANN 和 SVM 三种方法预测桉树材积（Dantas *et al.*, 2020）。而 Aguilar 等人则是通过机器学习算法，通过影像以树高和胸径的关系反向预测柚子树的胸径（Aguilar *et al.*, 2021）。还能利用胸径和年龄预测出树高因子，在相关研究中能够达到RMSE=0.70（Casas *et al.*, 2022；Wang *et al.*, 2019）。机器学习可以不通过具体的模型形式就可以用来处理一些复杂性较高以及非线性的数据，卯光宪就利用 BP-ANN 来进行树高-胸径模型的建立（卯光宪等，2020）。Corte 等人利用 SVR、RF、人工神经网络和极限梯度提升方法在 LiDar 点云数据上进行单木数据的提取，证明 SVR 的提取效果比 RF 和人工神经网络的效果要好（Chen *et al.*, 2021；Ercanli *et al.*, 2020；Malek *et al.*, 2019；Corte *et al.*, 2020），同样在 Malek 等人的研究中，也提出 SVR 与 RF 对于树木的预测上能够比传统的方法精度要更高（Loubota *et al.*, 2021）。而梁瑞婷等人也利用深度学习对杉木进行胸径、树高模型的建立（梁瑞婷等，2021）。

杉木（*Cunninghamia lanceolata*）作为中国南方主要树种之一，在中国西南地区主要生活在海拔 1800 米以下，因为其具有较高的生态经济和药用价值，构建杉木树高-胸径模型为合理经营杉木林具有实际意义。因此，本文基于深度学习算法构建树高-胸径模型，通过对比传统基础模型，采用多重不同数据比例验证，对比在不同数据集的情况下的模型精度，选取最优树高-胸径模型，为合理经营杉木林以及野外调查提供理论支撑。另外本文选取贵州省清镇市国有林场作为研究区，亦为探究贵州省中高海拔地区杉木的生长状况。

1 研究区概况

研究地点为贵州省清镇市国有林场（研究区位置如图 1），海拔 1300 米。于 2021 年 12 月在林场中共

设立 49 块圆形样地，对样地中的杉木以 5cm 为起测径阶进行每木检尺，测定杉木的树高以及胸径，经对所测林木进行异常值去除后得到有效杉木共计 3795 株。为了进行不同训练集以及测试集的建模精度比较，根据调查的杉木数据，将数据分成 8 组建模数据和检验数据。分别为建模数据占比（20%、30%、40%、50%、60%、70%、80%）和检验数据占比（80%、70%、60%、50%、40%、30%、20%）。样地调查因子统计如表 1。

表 1 样地调查因子统计
Tab. 1 Fitting data of survey factors in the sample plots

变量 Variable	建模数据 Fitting data (n = 3054)				
	平均值 Mean value	最小值 Minimum	最大值 Maximum	标准差 Standard deviation	变异系数 Coefficient of variation
胸径 Diameter at breast height / cm	17.68	5.1	49.4	6.91	0.39
树高 Tree height / m	12.81	2.7	22.2	3.38	0.26




图 1 研究区示意图
Fig. 1 Schematic diagram of the study area

2 研究方法

2.1 基础模型选择

基于调查数据并参考已研究成果，用 R 语言依据最小二乘法拟合了 11 个生物学意义良好且精度高利用广的树高胸径模型(表 2，其中 H 为树高；D 为胸径； a_1 、 a_2 和 a_3 为模型的参数)，后对拟合方程进行评价与比较，以模型的拟合精度为依据筛选出预测精度最高的模型作为杉木树高胸径关系的基础模型。

表 2 树高一胸径基础模型选择
Tab. 2 Basic model selection of H-D relation

模型编号 Model No.	模型名称 Model name	参数类型 Function type	模型表达式 Model expression
M1	Power 模型	二参数 2-parameter	$H = 1.3 + a_1 D^{a_2}$
M2	Michaelis-Menten 模型	二参数 2-parameter	$H = 1.3 + a_1 D / (a_2 + D)$
M3	Curtis 模型	二参数 2-parameter	$H = 1.3 + a_1 D / (1 + D)^{a_2}$
M4	Meyer 模型	二参数 2-parameter	$H = 1.3 + a_1 [1 - \exp(-a_2 D)]$
M5	Wykoff 模型	二参数 2-parameter	$H = 1.3 + \exp[a_1 - a_2 (D + 1)^{-1}]$
M6	Hossfeld IV 模型	三参数 3-parameter	$H = 1.3 + a_1 / (1 + 1/a_2 D^{a_3})$
M7	Weibull 模型	三参数 3-parameter	$H = 1.3 + a_1 [1 - \exp(-a_2 D^{a_3})]$
M8	Chapman-Richards 模型	三参数 3-parameter	$H = 1.3 + a_1 [1 - \exp(-a_2 D)]^{a_3}$
M9	Prodan 模型	三参数 3-parameter	$H = 1.3 + D^2 / (a_1 D^2 + a_2 D + a_3)$
M10	Logistic 模型	三参数 3-parameter	$H = 1.3 + a_1 / [1 + a_2 \exp(-a_3 D)]$
M11	Gompertz 模型	三参数 3-parameter	$H = 1.3 + a_1 \exp[-a_2 \exp(-a_3 D)]$

2.2 深度神经网络模型（DNN）

深度神经网络模型具有多层的隐藏层，普遍的深度神经网络都是采用三层以上的隐藏层，而针对于每一个隐藏层存在多个神经元。DNN 在对数据进行训练时，主要分为训练集和测试集。在进行数据的训练时，其主要是通过逐层进行训练，而每一层又在上一层的基础上继续进行特征提取，因此可以用 DNN 进行数据的识别、分类以及预测等任务。DNN 的主要超参数主要包含了隐藏层层数、神经元个数、激活函数类型、权重优化算法、正则化参数和 Dropout 的比例等，本文中主要采用以上几种。为更好的拟合数据的预测情况，因此采用三层隐藏层，而每一层有 64 个神经元个数，用来增加网络容量。模型原理如下图 2。




图 2 DNN 模型工作原理
Fig. 2 DNN model operation principle

2.3 支持向量回归（SVR）

支持向量回归是（SVR）是支持向量机（SVM）的一个分支，SVR 主要是将数据映射到一个高维空间中，通过在该空间中寻找一个回归超平面，使得样本点尽可能的靠近该平面，让其距离变小，而计算样本

点与该平面之间的距离则是使用核函数。在本文中主要采用正则化参数 C 、容错参数 ϵ 和 γ 参数，其中 C 主要是用来控制模型的复杂度， ϵ 用于更好的适应训练数据中的噪声和异常值， γ 参数和 ϵ 差不多，都是用来适应训练数据中的噪声和异常值，只是与 ϵ 函数不一样的是，前者控制超平面与支持向量之间的距离，而后者决定核函数的宽度。本文采用的 C 参数的取值范围为 0.1~10， ϵ 参数的取值范围是 0.01~1， γ 参数的取值范围为 0.01~1。




图 3 支持向量回归原理示意图

Fig. 3 Schematic diagram of support vector regression principle

2.4 随机森林 (RF)

随机森林指的是利用多棵树对样本进行训练并预测的一种分类器，构建随机森林主要是进行两个方面的步骤：分别为随机性选取以及待选特征的随机选取。其原理示意图分别如下：




图 4 数据的随机选取
Fig. 4 Random selection of data




图 5 待选特征的随机选取
Fig. 5 Random selection of features to be selected

2.5 模型及参数检验

模型的检验采用确定系数 (R^2)、均方根误差 (RMSE) 以及平均系统误差 (MAE) 来进行评价。 R^2

越接近 1，代表模型的拟合度越高；RMSE值越小，代表模型的拟合度越高；MAE是反映在一定范围内模型的拟合效果，越接近 0 值表示该模型的拟合精度越高。具体的公式如下：

$$R^2 = 1 - \frac{\sum_{i=1}^m \sum_{j=1}^{n_i} (H_{ij} - \hat{H}_{ij})^2}{\sum_{i=1}^m \sum_{j=1}^{n_i} (H_{ij} - \bar{H})^2}$$

(1)

$$RMSE = \sqrt{\frac{\sum_{i=1}^m \sum_{j=1}^{n_i} (H_{ij} - \hat{H}_{ij})^2}{n}}$$

(2)

$$MAE = \sum_{i=1}^m \sum_{j=1}^{n_i} \left| \frac{H_{ij} - \hat{H}_{ij}}{n} \right|$$

(3)

式中: H_{ij} 与 $\hat{H}_{ij}$ 分别为第 i 个样地中第 j 株树高的实测值和预测值(m) ； $\bar{H}$ 为树高实测值的均值(m) ； m 为样地的数量； n 为样本的数量。

3 结果与分析

3.1 精度对比

利用 R Studio 拟合传统树高胸径模型的基础 11 个模型，以及利用 Python3.9 构建深度神经网络（DNN）模型、支持向量回归（SVR）模型以及随机森林（RF）模型，其拟合结果如表 3，其中还含有各模型的确定系数（ R^2 ）、均方根误差（RMSE）以及平均系统误差（MAE）。根据所有拟合结果看出，11 个基础模型中，根据数据的训练集和测试集比例不同，通过精度对比，本表列出了其中精度最好的 3 个模型（M1、M2、M3）数据精度情况。在整体上看，DNN 和 SVM 在预测精度上最好，只有在训练集占比 40%时，传统基础模型才能在精度上略高于机器学习的方法。在基础模型的预测中，精度最高的为在训练集占比 20%情况下的 DNN 模型，其 R^2 为 0.671，RMSE和MAE分别为 2.024 和 1.599，在所有模型中，其预测精度最高。而 SVR 预测精度最高在训练集占比 30%时，其 R^2 为 0.658，RMSE和MAE分别为 2.072 和 1.652，综合以上，在使用较少数据量的同时，采用 DNN 模型预测杉木树高。

表 3 传统基础模型和机器学习拟合结果表
Tab. 3 Traditional base model and machine learning fitting results

二八比例 Ratio of two to eight									
方法 Method	M1	M2	M3	DNN			SVR	RF	
R2	0.634	0.661	0.63	0.661	0.669	0.671*	0.661	0.666	0.638
MAE	1.716	1.634	1.726	1.622	1.606	1.599*	1.63	1.615	1.673
RMSE	2.137	2.053	2.149	2.053	2.029	2.024*	2.052	2.037	2.12
三七比例 Ratio of three to seven									
方法 Method	M1	M2	M3	DNN			SVR	RF	
R2	0.638	0.659	0.634	0.584	0.584	0.583	0.587	0.658*	0.635
MAE	1.766	1.688	1.774	1.716	1.715	1.716	1.711	1.652*	1.696
RMSE	2.191	2.107	2.201	2.116	2.117	2.12	2.11	2.072*	2.14
四六比例 Ratio of four to six									

方法 Method	M1	M2	M3	DNN			SVR	RF
R2	0.634	0.662*	0.631	0.654	0.656	0.657	0.654	0.617
MAE	1.646	1.571*	1.654	1.568	1.563	1.562	1.573	1.646
RMSE	2.055	1.971*	2.065	1.976	1.971	1.968	1.976	2.081

注：*标注的为结果最好。




图 6 模型精度变化
Fig. 6 Model accuracy changes

由表 3 中信息可知，Dropout、L2、Reduce 和 Relu 四种模型是属于 DNN 的其中不同参数调整对比的结果，并结合图 6 来看，相对于所有模型来说此四种的 R^2 较高，并且 MAE 和 RMSE 随着 R^2 的增加在不断减少，符合客观规律。在使用深度神经网络构建树高-胸径模型过程中，采用 R^2 、RMSE、MAE作为主要模型精度评价指标。在不同比例下的 DNN 模型的 R^2 不同，原因在于每次运行的结果都在变化中，但都是在 0.6 以上。在 DNN 模型中，主要分 4 种模型：模型 1 采用基础的 4 个隐藏层，前 3 个隐藏层含 64 个神经元，最后一层为 1 个，以 relu 激活函数对输入数据进行训练，采用 Adam 神经网络训练优化器对训练样本进行优化，每个模型优化系数为 0.001，MSE作为代价函数；模型 2 在模型 1 的基础上，第一个隐藏层上神经元个数改为 32 个，是为了解决过拟合问题，采用减少网络权重的方法；模型 3 则是加入 L2 正则化，目的主要是为了防止出现过拟合问题，其原理是在原本的损失函数的基础上增加了所有层所有参数的平方和；模型 4 则是加入 Dropout 正则化，目的是为了使数据进行过拟合，与模型 1 一样，分为 4 个隐藏层，在每一层中添加 0.3 比例的测试集进行过拟合，判断出模型之间的精度差异。对比 4 个模型的拟合结果，对每个模型运行结果进行多次运行取平均值，得到最优拟合精度如表 3。在所有拟合结果中，DNN 和 SVR 对树高胸径模型的拟合精度最高，因此采用 DNN 和 SVR 在基础情况下预测树高效果要高于传统模型。

3.2 拟合效果

根据模型的拟合精度比较选择 DNN 中的四种不同参数模型，图 7 表示对 DNN 中的四种不同参数模型的预测值与其残差的分布关系，由残差图可以看出，使用 DNN 中的 L2 正则化模型其预测值与残差之间的相关关系表现最好，并且针对同一种参数模型来说，加入的训练集样本越大，预测值越接近于真实值，

这是由于机器学习本身的模拟状况决定的。根据残差图可以得出，在树高 $18\text{m} > H > 10\text{m}$ 时，残差大多数在 $-4 \sim 4\text{m}$ 的范围内，说明利用 DNN 对杉木树高进行预测时，可采用大量的实测数据作为训练样本，在对模型进行多次训练之后，完善模型的预测参数效果，可以更加方便的对杉木中幼林进行树高预测，以此达到提高林业工作效率的目的。




图 7 DNN 模型独立性检验残差图

Fig. 7 Residual Diagram of DNN Model Independence Test

4 讨论

本研究基于深度神经网络、支持向量回归、随机森林 3 个算法，采用 Python 中的 TensorFlow 和 Sklea

两个平台进行树高胸径模型的构建,利用该方法构建出的杉木树高胸径模型在不同比例训练集与测试集下,表现出不同的拟合精度。在训练集占比较低的情况下,深度神经网络和支持向量回归的方法对树高的预测精度较高,其 R^2 均大于传统模型,说明机器学习方法构建的树高胸径模型精度比传统模型高,与之前的大部分学者研究结论一致(Ercanli *et al.*, 2020;Corte *et al.*, 2020)。另外深度学习算法由于其本身并不需要像传统的模型一样有具体形式,因此,其对于数据的要求并不像传统模型一样需要一定的结构形式,导致采用深度学习进行模型拟合时更容易收敛。而支持向量回归在进行数据处理时主要是在线性函数两侧建立起“隔离带”,对其中的所有数据都不计算损失,因此可以通过最小化总损失和最大化间隔来得出优化后的模型。

在本研究中,由于未加入其余的变量因子,仅仅是进行传统基础模型与机器学习算法的比较,因此在加入其余变量因子的情况下其结果尚未可知。但是在深度学习未来的发展中,模型还会不断进行完善,在最后的模型拟合结果上能够更加合理化和精准化。因此使用机器学习来进行杉木树高的预测,可以在过程上减少很多繁琐的步骤,并且可以在少量样本的基础上就能够得到准确的预测结果。

5 结论

本研究采用中国贵州省清镇市国有林场的 49 块杉木标准地调查数据,共计 3795 棵杉木,基于 Tensor Flow 和 Sklearn 平台的深度学习、支持向量回归和随机森林三种算法,建立多个杉木树高-胸径模型。同时利用传统的非线性回归按不同训练集和测试集,每个训练集个测试集建立传统的树高-胸径基础模型,用来与机器学习的三种算法构建的模型进行比较。研究表明:(1)深度神经网络和支持向量回归在训练集占比较少的情况下,其预测精度要高于传统基础模型,DNN、SVR、RF3 种拟合模型 R^2 分别为 0.671、0.65、0.638。(2)利用 DNN 和 SVR 构建的杉木树高-胸径模型只用了三个隐藏层,每个隐藏层具有 64 个神经元即可用来预测出杉木的树高。(3)利用 DNN 构建的模型比传统基础模型在某些特定情况下可以不用受到传统统计学的限制,能够更加简单的使数据收敛,为精准预测树高提供更好的可能。

参考文献

- 郭嘉,孙帅超,田相林,等.2019.引入优势木树高建立的秦岭林区松栎林树高-胸径模型[J].东北林业大学学报,47(11):66-72.
(Guo J,Sun S C,Tian X L et al.2019.Introduction of Dominant Tree Height to Establish a Tree Height DBH Model for Pine and Quercus Forests in Qinling Forest Region [J]. Journal of Northeast Forestry University.47(11):66-72. [in Chinese])
- 郭卫红,郑庆荣,胡砚秋,等.山西五台山主要针叶树种树高一胸径曲线模型研究[J].湖南林业科技,2022,49(06):72-77.
(Guo W H,Zheng Q R,Hu Y Q,et al.2022.Study on height diameter curve model of main conifer species in Mount Wutai of Shanxi Province [J]. Hunan Forestry Science and Technology.49 (06): 72-77. [in Chinese])
- 李晓晶.2020.杂种落叶松树高-胸径模型的研究[J].林业科技情报,52(04):28-30.
(Li X J .2020. Study on the height diameter model of hybrid deciduous pine trees [J]. Forestry Science and Technology Information, 52 (04): 28-30. [in Chinese])
- 梁瑞婷,孙玉军,李芸.2021.深度学习和传统方法模拟杉木树高-胸径模型比较[J].林业科学研究,34(06):65-72.
(Liang R T, Sun Y J, Li Y. 2021. Comparison of deep learning and traditional methods for simulating the height diameter model of Chinese fir trees [J]. Forestry Science Research, 34 (06): 65-72. [in Chinese])
- 刘金义.2022.辽东山区人工红松枝下高模型的研建[J].林业科技通讯,(08):95-98.
(Liu Jinyi (2022) Research and construction of a height model under artificial Korean pine branches in the mountainous areas of Liaodong [J]. Forestry Science and Technology Communication, (08): 95-98. [in Chinese])
- 卯光宪,谭伟,柴宗政,等.2020.基于 BP 神经网络的马尾松人工林胸径-树高模型预测[J].浙江农林大学学报.37(04):752-760.
(Mao G X, Tan W, Chai Z Z, et al. 2020. Prediction of Masson Pine Plantation DBH Tree Height Model Based on BP Neural Network [J]. Journal of Zhejiang A&F University. 37 (04): 752-760. [in Chinese])
- 牛思圆,刘鹏举,雷相东,等.2023.基于连清样地数据的全国杉木人工林平均木树高-胸径模型[J].林业科学研究 36(01):117-123.

- (Niu S Y, Liu P J, Lei X D, et al. 2023. A National Average Tree Height Chest Diameter Model for Chinese Fir Plantation Based on Lianqing Sample Land Data [J]. *Forestry Science Research* 36 (01): 117-123. [in Chinese])
- 王景弟,杨蕊,田育新.2021.枫香和杉木树高-胸径模型的拟合与评价[J].*湖南林业科技*.48(04):64-67.
- (Wang J D, Yang R, Tian Y X. 2021. Fitting and evaluation of height diameter models for maple and Chinese fir trees [J]. *Hunan Forestry Science and Technology*. 48 (04): 64-67. [in Chinese])
- 曾翀, 雷相东, 刘宪钊, 等. 2009.落叶松云冷杉林单木树高曲线的研究[J]. *林业科学研究*, 22 (2): 182-189.
- (Zeng C, Lei X D, Liu X Z, et al .2009. Study on the Height Curve of a Single Tree in Larch, spruce, and fir Forests [J] *Forestry Science Research*, 22 (2): 182-189. [in Chinese])
- Aguilar FJ, Nemmaoui A, Aguilar MA, et al. Building Tree Allometry Relationships Based on TLS Point Clouds and Machine Learning Regression. *Applied Sciences*. 2021; 11(21):10139.
- Casas, G.G; Gonz les, D.G.E; Villanueva, J.R.B; et al. Configuration of the Deep Neural Network Hyperparameters for the Hypsometric Modeling of the Guazuma crinita Mart. in the Peruvian Amazon. *Forests* 2022, 13, 697.
- Chen, X; Jiang, K; Zhu, Y; et al. Individual Tree Crown Segmentation Directly from UAV-Borne LiDAR Data Using the Point Net of DNN. *Forests* 2021, 12, 131.
- Corte A , Souza D V , Rex F E , et al. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes[J]. *Computers and Electronics in Agriculture*, 2020, 179(2020):105815.
- Dantas, D , Calegario, N , Fausto Weimar Acerbi J nior, et al. Multilevel nonlinear mixed-effects model and machine learning for predicting the volume of eucalyptus spp. trees. *Cerne*, 2020, 26(1), 48-57.
- Deng C , Zhang S , Lu Y ,et al.Thinning Effects on the Tree Height – Diameter Allometry of Masson Pine (*Pinus massoniana* Lamb.)[J].*Multidisciplinary Digital Publishing Institute*, 2019(12).
- Ercanli I. Artificial intelligence with DNN algorithms to model relationships between total tree height and diameter at breast height [J]. *Forest Systems*, 2020, 29 (2) : e103.
- Ercanli I. Innovative DNN artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height[J]. *Forest Ecosystems*, 2020, 7 (1) : 7-12.
- Fu, L., Duan, G., Ye, Q.L., et al. Prediction of individual tree diameter using a nonlinear mixed-effects modeling approach and airborne LiDAR data. *Rem. Sens.* 2020. (7), 1066.
- Khamyong, N.; Wangpakapattanawong, P.; Chairuangsi, S.; et al. Tree species composition and height-diameter allometry of three forest types in Northern Thailand. *CMU J. Nat. Sci.* 2018, 17, 289 – 306.
- Loubota Panzou G J , Bocko Y E , Mavoungou A Y ,et al.Height-diameter allometry in African monodominant forest close to mixed forest[J].*Journal of Tropical Ecology*, 2021(2):37.
- Malek S , Miglietta F , Gobakken T , et al. Prediction of stem diameter and biomass at individual tree crown level with advanced machine learning techniques[J]. *iForest-Biogeosciences and Forestry*, 2019(3).
- Mensah, S.; Pienaar, O.L.; Kunneke, A.; Height-Diameter allometry in South Africa’ s indigenous high forests: Assessing generic models performance and function forms. *For. Ecol. Manag.* 2018, 410, 1 – 11.
- methods for estimating tree diameters. *ISPRS Int. J. Geo-Inf.* 2018,7 (3), 93.
- MokroS, M., Liang, X., Surov y, P., et al. Evaluation of close-range photogrammetry image collection
- Wang, J; Chen, X; Cao, L; et al. Individual Rubber Tree Segmentation Based on Ground-Based LiDAR Data and Faster R-CNN of DNN. *Forests* 2019, 10, 793.
- Wu, X., Zhou, S., Xu, A., et al. Passive measurement method of tree diameter at breast height using a smartphone. *Comput. Electron. Agric.* 2019,163, 104875.