doi:10.6041/j.issn.1000-1298.2025.11.038

# 基于无人机与深度学习的森林特征参数估测模型构建与可解释性研究

孙　钊[1]　谢运鸿[2]　丁志丹[2]　李　睿[2]　谭　军[1]　袁　新[1]

(1.中国地质调查局军民融合地质调查中心, 成都 610036;
2.北京林业大学森林资源和环境管理国家林业和草原局重点开放性实验室, 北京 100083)

**摘要**:森林特征参数是评估森林生态系统生长状况的关键指标,为高效、精确地估测森林特征参数,本研究探索结合无人机技术和 DNN(Deep neural network)模型的森林特征参数的估测方法,并通过 SHAP(Shapley additive explanations)方法提高模型预测的可解释性。使用无人机高分辨率影像作为数据源,利用 DNN 对平均胸径(Average diameter at breast height, AD)、林分胸高断面积(Area of forest stand at breast height, BA)、Lorey's 树高(Lorey's tree heights, HL)、样地地上生物量(Above-ground biomass of sample plots, AGB))等森林特征参数进行估测。设计了多层次的 DNN 模型处理和分析影像数据,预测森林特征参数。同时,采用 SHAP 方法对 DNN 模型的预测结果进行可解释性分析,以理解每个特征在模型预测中的作用。深度学习 DNN 模型可以利用 DAP(Digital aerial photograph)数据中获取的二维光谱特征和三维点云特征进行森林特征参数的估测模型构建。BA 和 AGB 参数的估测模型性能从大到小为 DOM + DAP 点云、DOM(Digital orthophoto mosaic)、DAP 点云,BA 和 AGB 最优模型的 $R^2$ 平均值分别为 0.743 8、0.776 2,而 AD 和 HL 的参数估测模型性能从大到小排序为 DOM + DAP 点云、DAP 点云、DOM,AD 和 HL 最优模型的 $R^2$ 平均值分别为 0.613 3、0.727 6。SHAP 值反映了每个特征变量对预测结果的贡献,树高变异系数在各模型中均占据了较为重要的位置,点云高度变量对特征参数具有更高的解释能力。DNN 模型具有较高的估测精度,而 SHAP 方法提升了模型预测结果的解释性,同时强调了点云变量在整体预测模型中的重要性。这表明现代遥感技术与先进的机器学习方法相结合,可为利用无人机数字航空摄影技术进行森林资源调查监测提供必要的技术支持。

**关键词**:森林特征参数;深度学习;SfM 算法;多视角立体视觉技术;SHAP 可解释性分析

**中图分类号**:S771.8　　**文献标识码**:A　　**文章编号**:1000-1298(2025)11-0397-11　　**OSID**:

# Estimation Model of Forest Feature Parameters and Its Interpretability Based on UAV and Deep Learning

SUN Zhao[1]　XIE Yunhong[2]　DING Zhidan[2]　LI Rui[2]　TAN Jun[1]　YUAN Xin[1]

(1. *Civil-Military Integration Center of China Geological Survey*, *Chengdu* 610036, *China*
2. *State Forestry and Grassland Administration Key Laboratory of Forest Resources and Environmental Management*, *Beijing Forestry University*, *Beijing* 100083, *China*)

**Abstract**: Forest structural parameters are critical indicators for assessing forest ecosystem growth conditions. To achieve efficient and accurate estimation of these parameters, a method that integrated unmanned aerial vehicle (UAV) technology with deep neural network (DNN) models was explored, and the interpretability of model predictions was further enhanced by using the shapley additive explanations (SHAP) approach. High-resolution UAV imagery was employed as the primary data source, and the DNN model was used to estimate key forest parameters, including average diameter at breast height (AD), stand basal area (BA), Lorey's tree height (HL), and above-ground biomass of sample plots (AGB). A multi-level DNN model was designed to process and analyze the imagery, enabling parameter prediction. In addition, the SHAP method was applied to interpret DNN outputs, thereby clarifying the contribution of each feature to the predictions. The DNN model leveraged both two-dimensional spectral

收稿日期:2024-07-20　修回日期:2024-09-20
**基金项目**:中国地质调查局地质调查项目(DD20243093)
**作者简介**:孙钊(1996—),男,工程师,博士,主要从事无人机林业遥感研究,E-mail:sun_zhaosz@163.com
**通信作者**:袁新(1992—),男,工程师,主要从事自然资源综合调查评价研究,E-mail:502840714@qq.com

features and three-dimensional point cloud features extracted from digital aerial photographs (DAP) for forest parameter estimation. For BA and AGB estimation, model performance ranked as follows: DOM + DAP point cloud, DOM, DAP point cloud. The optimal models achieved mean $R^2$ values of 0.743 8 for BA and 0.776 2 for AGB. For AD and HL estimation, performance ranked as DOM + DAP point cloud, DAP point cloud, DOM, with optimal mean $R^2$ values of 0.613 3 for AD and 0.727 6 for HL. SHAP values revealed the relative contribution of each feature, showing that the coefficient of variation of tree height consistently played a key role across models, while point cloud height variables provided stronger explanatory power for forest parameters. Overall, the DNN model demonstrated high estimation accuracy, while the SHAP method enhanced interpretability of the results and emphasized the importance of point cloud variables in the predictive framework. These findings indicated that the integration of modern remote sensing technology with advanced machine learning methods provided essential technical support for the application of UAV-based digital aerial photogrammetry in forest resource inventory and monitoring.

**Key words**: forest feature parameters; deep learning; SFM algorithm; multi-view stereo vision technology; SHAP interpretability analysis

## 0 引言

森林是人类宝贵的自然资源,森林资源的调查与监测是林业经营管理的基础。树高、胸径、冠幅等森林特征参数,是评估森林生态系统健康、功能及生长状况的核心指标。精准、高效且无损地监测这些参数,对于制定科学的森林管理策略和保护森林资源至关重要。林分特征参数一般通过单木测树因子统计获得,例如林分的平均胸径、平均高度、胸高断面积、株数及生物量。近年来,许多研究将光学卫星和雷达数据与地面测量数据结合起来估算这些参数[1-3]。被动光学遥感数据主要提供森林表层的平面信息,如植被指数和纹理特征,在获取森林垂直结构信息方面存在局限[4-5]。作为主动遥感技术的 LiDAR,在提取森林垂直特征参数方面显示出显著优势[6],但星载 LiDAR 精度低,机载 LiDAR 成本相对较高。无人机数字航空摄影(Digital aerial photography, DAP)能够获取超高分辨率 RGB 影像,利用运动恢复结构算法(Structure for motion recovery, SfM)、多视角立体视觉技术(Multi-view stereo, MVS)生成的三维密集匹配点云和数字正射影像(Digital orthophoto mosaic, DOM)在大尺度的森林生物量估算中非常有效。数字航空摄影成本低,操作简单,高重叠度影像可以获取高密度结构完整的森林冠层,DAP 生成的密集点云,RGB 影像提供和 LiDAR 点云类似的点云高度信息和点云密度信息,且可以提供植被的光谱特征,以此为基础可以进行林分尺度的特征参数估测。

寻找合适的参数估计方法至关重要,传统回归方法包括多元非线性回归、混合效应方程、岭回归、随机森林和支持向量机等,而深度神经网络回归则在非线性建模方面更具优势。深度学习(Deep learning, DL)是机器学习的重要分支,通过多层结构实现表征学习,能自动提取数据特征,并在图像识别、语音识别和自然语言处理等领域取得显著成果[7]。其中,深度神经网络(Deep neural network, DNN)是典型模型,由多层隐藏层和输出层构成,借助非线性激活函数实现复杂映射,比传统机器学习模型更为强大和灵活[8-11]。DNN 回归已在多个领域得到广泛应用[12],包括高分辨率影像分类[13]、物体实例分割[14]、道路提取[15]等。但进行植被生长或特征参数预测的研究相对较少,已有研究显示了其潜力[16-17]。目前,基于 DNN 模型进行植被资源监测和生长预测的研究多集中在农业领域,在森林特征参数估计方面的应用还相对有限。借助深度学习 DNN 强大的复杂非线性关系与特征表示能力以及优秀的预测能力,实现森林结构参数的精准估测。

由于深度神经网络回归过程具有“黑盒子”的特性,自变量之间、自变量与因变量之间的关系难以分析,因此增加可解释性分析对参数估计机制有重要作用。SHAP 是一种基于博弈论中 Shapley 值的方法,用于解释回归和分类模型的预测结果,它能够计算每个特征对模型预测的具体影响[18]。SHAP 在解释模型、准确性和一致性方面都很有效,已被广泛应用于各种类型的模型,包括线性模型、树模型和深度学习模型[19]。

本文基于无人机 DOM 和 DAP 点云数据源,利用 DNN 构建森林特征参数预测模型,通过 DNN 模型对不同组合的数据源衍生特征进行估测精度比较,最后使用 SHAP 来解释各建模变量对预测结果的贡献,以探索 2 种数据源组合状态下的森林特征参数预测潜力。

## 1　研究区概况与数据来源

### 1.1　研究区概况

研究区位于福建省三明市将乐国有林场梅花谷(26°40′~26°50′ N，117°25′~117°35′ E)，研究区位置如图 1 所示。地处福建省西北部，属亚热带季风气候，年平均温度为 18.8℃。日照充足，雨量充沛，降水主要集中在夏季，年平均降水量为 1 750 mm，最高海拔 1 203 m，最低海拔 140 m，平均海拔 400~800 m，研究区内地形复杂，山岭耸峙，丘陵起伏，主要土壤类型为山地红壤，区内森林多为人工林，以针叶林为主，少数为混交林[20]。本研究以梅花谷内的杉木人工林为研究对象，无人机航摄区域内地形复杂且林分郁闭度较高。

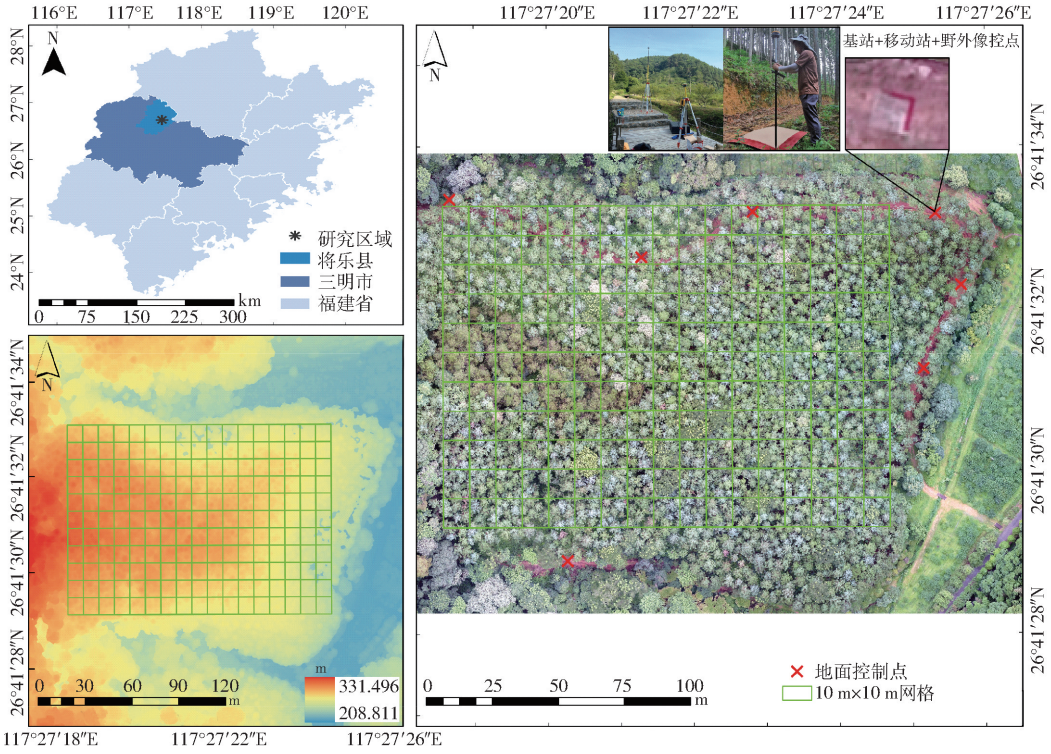



图 1　研究区概况

Fig. 1　Location of study site

### 1.2　无人机影像采集与输入变量提取

本研究所使用的无人机影像由 DJI Inspire 2 型无人机采集，其搭载了 RGB 传感器(ZENMUSE X5S 型)，像素宽高比为 3∶4，有效像素为 1 600 万像素。为了获得高质量的影像，在当地时间 11∶40(±1 h)，天气晴朗的条件下进行了飞行。使用 DJI GO4 软件设置了自主飞行计划：无人机巡航速度为 5 m/s，飞行高度为 200 m，影像重叠率为 80%。飞行前，在每个区域均匀地设置了 7 个地面控制点(GCPs)。在每个 GCP 位置，使用实时动态测量技术(Real-time kinematic，RTK)收集地理坐标。经过后处理程序，GCPs 的平均水平和垂直精度分别为 10、12 cm。最后，使用 PiX4D 软件(v4.4.12，Pix4D，瑞士)生成了平均地面采样距离(Ground sample distance，GSD)4 cm 的数字正射影像图、数字表面模型以及森林冠层结构 DAP 点云数据。图 1 展示了无人机影像，该林分郁闭度为 0.8，坡度为 22°，按照 10 m×10 m 的网格尺寸对该区域进行划分，去除其中包含马尾松和阔叶林的样方以及边缘样方，调查 151 个 10 m×10 m 杉木纯林样方。

研究以 RGB 3 个可见光波段的高分辨率 DOM 数据为数据源，依据植被指数的构造原理和形式，使用 RGB 可见光波段的 DN 值取代不同波段的反射率或辐射度以此构建可见光植被指数。二维植被指数可以在一定程度上反映植被生长差异，以此来分析植被指数因子对几种林分特征参数估测的能力。共计算了 13 个可见光植被指数及 3 个可见光波段的 DN 值，分别为：可见光差异植被指数(VDVI)、可见光大气阻抗指数(VARI)、绿红比值指数(GRRI)、绿蓝比值指数(GBRI)、红蓝比值指数(RBRI)、模拟 NDVI 的植被指数(VI)、超绿超红差分指数(ExGR)、超绿指数(ExG)、绿叶植被算法(GLA)、归一化绿红差分指数(NGRDI)、植被指数(VEG)、植被提取颜色指数(CIVE)、联合指数(COM)，以及 R、G、B。所有的二维植被指数均使 Python 3.8 进行计算。目前已经提出了几种点云指标作为森林 AGB 的潜在预测因子[21]，点云高度变量(如高度百分位数、平均值、中位数和标准

差)可以反映林冠的垂直结构信息,点云密度变量可以反映森林冠层的水平结构信息。同时,DAP 点云能够有效克服基于光学遥感的森林 AGB 预测饱和现象[22-24],DAP 点云变量可以从三维角度突出森林植被冠层信息,从而有效估计林分特征参数。由于 DAP 点云的特性,本文未选择冠层盖度和 LAI 变量。最后根据归一化后的点云数据共计提取了 41 个点云变量(表 1),所有的点云参数均使用 LiDAR360 5.1 软件进行计算。

**表 1 三维特征变量及描述**

**Tab. 1 Feature variables and descriptions**

| 指标 | 描述 | |
|---|---|---|
| 点云高度变量 | H_1th, H_5th, H_10th, H_20th, H_25th, H_30th, H_40th, H_50th, H_60th, H_70th, H_75th, H_80th, H_90th, H_95th, H_99th | 高度百分位数 1th, 5th, 10th, 20th, 25th, 30th, 40th, 50th, 60th, 70th, 75th, 80th, 90th, 95th, 99th |
| | H_AAD | 平均绝对偏差 |
| | H_CRR | 冠层起伏率 |
| | H_IQ | 高度百分位数 4 分位数间距 H_75 - H_25 |
| | H_CV | 树高变异系数 |
| | H_AIH_IQ | 累计高度百分位数 4 分位数间距 |
| | H_KURT | 峰度 |
| | H_MAD | 中位数绝对偏差 |
| | H_MAX | 最大值 |
| | H_MIN | 最小值 |
| | H_MEAN | 平均值 |
| | H_MEDIAN | 中位数 |
| | H_SKE | 偏斜度 |
| | H_STD | 标准差 |
| | H_V | 方差 |
| | H_SQRT | 二次幂平均 |
| | H_CURT | 三次幂平均 |
| 点云密度变量 | D_1, D_2, D_3, D_4, D_5, D_6, D_7, D_8, D_9, D_10 | 将原始点云数据分成 10 个等高切片,每层回波数的比例就是相应的密度变量 |

### 1.3 林分森林特征参数计算

根据测得的胸径和树高,根据行业标准 LY/T 2264—2014《立木生物量模型及碳计量参数-杉木》地上生物量模型计算每个样地生物量,以此作为生物量真实值。单木生物量 $M$(kg)计算公式为

$$M = 0.032\,718 D^{2.110\,93} H^{0.602\,12} \quad (D \geqslant 5\ \text{cm}) \tag{1}$$

式中 $D$——胸径,cm

$H$——树高,m

分别以单木胸径、树高、单木胸高断面积以及单木地上生物量作为单木特征参数。通过单木测树因子,按照 10 m×10 m 小样方计算得到 151 个样地的林分特征参数,包括:平均胸径(AD,cm)、林分胸高断面积(BA,$m^2$)、Lorey's 树高(HL,m)、样地生物量(AGB,kg),AD 和 HL 计算公式为

$$D_A = \sqrt{\frac{1}{N}\sum_{i=1}^{N} D_i^2} \tag{2}$$

$$H_L = \frac{\sum_{i=1}^{N} H_i g_i}{\sum_{i=1}^{N} g_i} \tag{3}$$

式中 $D_A$——平均胸径,cm

$N$——样地内株数

$D_i$——第 $i$ 株树的胸径,cm

$H_L$——Lorey's 树高,m

$H_i$——第 $i$ 株树树高,m

$g_i$——第 $i$ 株树胸高断面积,$m^2$

## 2 研究方法

### 2.1 DNN 模型架构

深度神经网络(DNN)是一种基于人工神经网络的机器学习模型,它模仿了人脑的处理方式。它由多层神经元组成,包括输入层、多个隐藏层和输出层(图 2)。每个神经元可以接收输入,对其进行加权,应用激活函数,并传递给下一层。DNN 通过输入层接收数据,然后数据在多个隐藏层中进行处理,每层都可以提取和学习数据的不同特征。最终,输

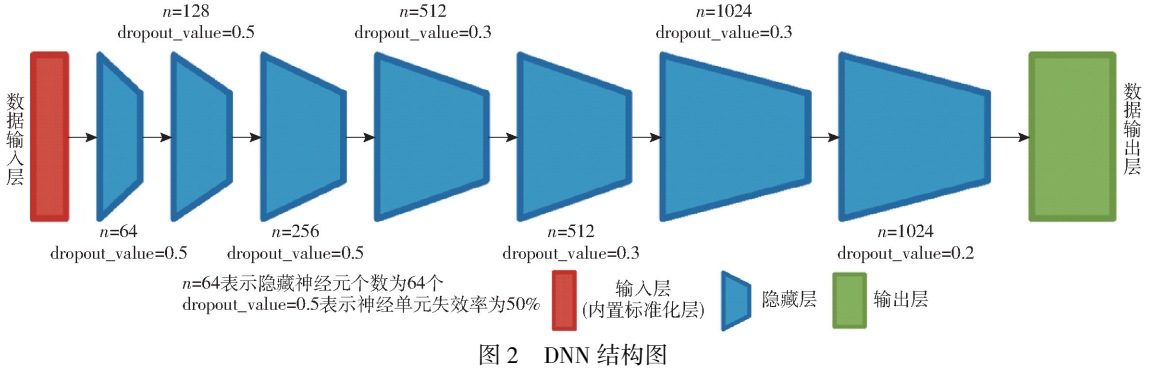



图 2 DNN 结构图

Fig. 2 DNN structure diagram

出层生成模型的预测或分类结果。DNN 擅长处理非线性和复杂的数据模式,这是因为多层结构和非线性激活函数使得它能够学习和建模复杂的关系[25]。

DNN 整体架构采取层次化特征提取原则,目的是通过多层处理逐步提取和组合进入网络的输入特征,从而使模型能够捕捉到输入数据之间复杂的非线性关系;隐藏层中包含不同数量的神经元,随着网络深度的增加,神经元数量递增,更加适应复杂的非线性回归。为了找到最优的优化器和学习率,通过网格搜索法进行了一系列实验,最终选择 Adam 和 Rmsprop 优化器,然后尝试了 11 个不同的学习率和学习衰减率组合,学习率范围为[0.000 5,0.005],学习衰减率范围为[0.000 01,0.000 5]。在本研究中,DNN 的隐藏层数设置为 6 层,第 1 层至最后 1 层的隐藏神经元个数分别为[64, 128, 256, 512, 512, 1 024, 1 024],此外每层加入了 Dropout 机制,Dropout 是一种常用的正则化方法,它在神经网络训练期间随机地让一些神经元不工作。这可以防止过拟合,并且有助于提高模型的泛化能力。在使用 Dropout 时,需要设定一个 Dropout 参数,通常称为 Dropout 比例。这个参数定义了随机不工作的神经元比例。通常需要通过超参数调优来选择一个合适的 Dropout 比例,并不存在一个适用于所有情况的最佳值。一般而言,使用较低的 Dropout 比例(例如 0.1)可以更好地保留模型复杂度,而使用较高的 Dropout 比例(例如 0.5)可以更有效地减少过拟合。第 1 层至第 6 层的 Dropout 值分别为[0.5, 0.5, 0.5, 0.3, 0.3, 0.3, 0.2]。每层网络引入了改良的 ReLU 激活函数 LeakyReLU,从而加快模型收敛,减少过拟合,LeakyReLU 的数学表达式为

$$y = \max(0,x) + \alpha_{\text{leak}} \min(0,x) \tag{4}$$

其中 $x$ 和 $y$ 分别表示输入与输出;max( )和 min( )分别表示取最大值、最小值函数;$\alpha_{\text{leak}}$ 表示一个很小的常数,如此保留了一些负轴的值,使得负轴的信息不会完全丢失。

为了避免梯度爆炸、梯度消失和过度拟合的问题,本研究使用了分配权重衰减(也称作 L2 正则化)策略。损失函数选择平均绝对误差(Mean absolute error)、均方误差(Mean squared error)、平均绝对百分比误差(Mean absolute percentage error)(表 2)。每个模型迭代次数(epoch)为 1 000 次,每个模型的最佳参数由训练集决定系数以及测试集决定系数确定。每个模型进行参数选择时,同一组超参数组合重复训练 50 次,最终保留模型平均预测结果最优的超参数组合,并输出最优超参数组合的 50 次预测结果。首先,对训练数据集进行预处理,以提高模型的准确性。然后使用 DNN 方法使用预处理后的训练数据集建立模型。最后,使用测试数据集验证模型的性能,并使用训练后的模型进行预测。

**表 2　4 种特征参数保留模型的最佳超参数组合**

**Tab. 2　Best hyperparameter combinations for four models with retained feature parameters**

| 特征参数 | 数据源 | 输出层激活方法 | 损失函数 | 学习率 | 学习衰减率 | 激活函数 |
|---|---|---|---|---|---|---|
| AD | DOM | Linear | 平均绝对百分比误差 | 0.005 0 | 0.000 01 | Adam |
| | DAP 点云 | Linear | 平均绝对误差 | 0.000 5 | 0.000 01 | Rmsprop |
| | DOM + DAP 点云 | Linear | 平均绝对百分比误差 | 0.005 0 | 0.000 01 | Rmsprop |
| BA | DOM | Linear | 平均绝对百分比误差 | 0.001 0 | 0.000 05 | Rmsprop |
| | DAP 点云 | Linear | 平均绝对误差 | 0.005 0 | 0.000 10 | Adam |
| | DOM + DAP 点云 | Linear | 平均绝对百分比误差 | 0.000 5 | 0.000 05 | Adam |
| HL | DOM | Linear | 平均绝对误差 | 0.000 5 | 0.000 10 | Adam |
| | DAP 点云 | Linear | 平均绝对百分比误差 | 0.005 0 | 0.000 05 | Adam |
| | DOM + DAP 点云 | Linear | 平均绝对百分比误差 | 0.005 0 | 0.000 05 | Adam |
| AGB | DOM | Linear | 平均绝对百分比误差 | 0.005 0 | 0.000 01 | Rmsprop |
| | DAP 点云 | Linear | 平均绝对百分比误差 | 0.005 0 | 0.000 50 | Adam |
| | DOM + DAP 点云 | Linear | 平均绝对误差 | 0.001 0 | 0.000 01 | Rmsprop |

## 2.2　SHAP 解释器

在回归模型中,SHAP 通过计算每个变量的 Shapley 值来解释模型的预测。Shapley 值表示每个特征对预测结果的贡献。SHAP 通过分析模型的输出来计算 SHAP 值,每个特征的 SHAP 值显示了它对预测结果的正面或负面影响。与全局可解释性方法相比,局部可解释性方法更专注于解释模型的特定部分,提供更详细的解释。全局可解释性方法则试图从宏观角度理解整个模型的结构,但这对于复杂的模型可能较难理解,局部可解释性方法则提供针对单个预测的独立解释[26]。SHAP 专注于计算不同变量对特定预测的重要性,并在单个实例周围构

建代理模型来解释模型是如何处理这个实例的。

SHAP 通过建立一个与原始模型具有相同输入输出的解释模型(Explanatory model,EM)来近似原始模型。解释模型可以是一个简单的线性模型,也可以是一个基于树的模型。然后,SHAP 通过计算每个特征在所有可能子集上的平均贡献来计算 Shapley 值,这个过程需要进行多次模型预测[27]。让给定的数据驱动模型例如(RF、DNN)用输入 $X_I=(x_1,x_2,\cdots,x_n)$ 进行训练,SHAP 使用 EM 评估每个输入变量对机器学习模型的贡献,可以描述为

$$\mathrm{EM}=\varphi_0+\sum_{i=1}^{n}\varphi_i t_i \tag{5}$$

$$\varphi_i(\mathrm{ML},x)=\sum_{t\subseteq x}\frac{|t|!\ (n-|t|-1)!}{n!}[\mathrm{ML}(t)-\mathrm{ML}(t\backslash i)] \tag{6}$$

式中 $n$——输入变量数

$t_i$——输入变量 $i$ 的简化

$\varphi_i$——变量 $i$ 对机器学习模型的贡献度

ML( )——机器学习模型

\——集合运算的差集表示法

SHAP 包括树解释器(Tree explainer)、深度解释器(Deep explainer)、梯度解释器(Gradient explainer)、线性解释器(Linear explainer)和核解释器(Kernel explainer),本文基于 DNN 回归的研究基于核解释器计算 SHAP 值和作图,分割样本数量与输入数量一致,采样次数为 100,链接函数选用适合回归模型的 identity 函数,深度剖析输出与输出的架构,得出模型的局部可解释性和全局可解释性。

### 2.3 参数的精度评价

为了保证验证模型的准确性,采用 10 折交叉验证法来验证模型的性能。以决定系数($R^2$)、均方根误差(Root mean squared error,RMSE)和相对均方根误差(Relative root mean squared error,rRMSE)评价不同回归模型的准确性。

## 3 研究结果

DNN 模型的输入变量为删除了与响应变量完全不相关及高度一致的变量后的特征变量集(AD、BA、HL、AGB 分别保留了 38、44、41、45 个变量)。本研究将数据源分为 DOM 光谱数据源、DAP 点云数据源以及组合数据源构建林分尺度的特征参数 DNN 预测模型,共 24 组数据,分别进行训练和验证。在训练阶段,通过试错模型进行调整,以确定模型的超参数组合。

### 3.1 林分特征参数 DNN 预测结果

表 3 展示了林分 4 个特征参数不同数据源各模型拟合精度,林分尺度下,AD、BA、HL 和 AGB 均是组合数据源的表现最好,由表 3 可知,重复 50 次的平均 $R^2$ 分别为 0.613 3、0.743 8、0.727 6、0.776 2,平均 RMSE 分别为 0.95 cm、4.37 $m^2$、0.75 m、151.22 kg,rRMSE 分别为 4.07%、8.16%、3.33%、7.62%,相较于单一 DOM 数据源,AD、BA、HL、AGB 平均 $R^2$ 分别提高了 0.276 6、0.262 1、0.389 3、0.160 1,平均 RMSE 降低 0.17 cm、1.48 $m^2$、0.49 m、44.77 kg;相较于单一 DAP 点云数据集,AD、BA、HL、AGB 平均 $R^2$ 分别提高 0.222 3、0.272 4、0.146 0、0.274 4,平均 RMSE 降低 0.12 cm、1.53 $m^2$、0.24 m、72.48 kg,可以看到在进行 HL 拟合时,组合数据源比起单一 DOM 数据提升最大,说明 DAP 点云数据源对 HL 的拟合起到了较大的作用。取得最优拟合效果的是 AGB,$R^2$ 为 0.776 2,rRMSE 为 7.62%,BA 和 AGB 的估测除了组合数据源最优以外,DOM 数据源的效果要优于 DAP 点云数据源,BA 和 AGB 参数估测模型,模型性能从优到劣排序为 DOM + DAP 点云、DOM、DAP 点云,而 AD 和 HL 参数估测模型,模型性能从优到劣排序为 DOM + DAP 点云、DAP 点云、DOM。

**表 3 林分尺度 DNN 各模型预测结果**

**Tab.3 Predictive results of DNN models for stand level**

| 特征参数 | 数据源 | 平均 $R^2$ | 平均 RMSE | 平均 rRMSE/% |
|---|---|---|---|---|
| AD | DOM | 0.336 7 | 1.12 cm | 4.81 |
| | DAP 点云 | 0.391 0 | 1.07 cm | 4.62 |
| | DOM + DAP 点云 | 0.613 3 | 0.95 cm | 4.07 |
| BA | DOM | 0.481 7 | 5.85 $m^2$ | 10.93 |
| | DAP 点云 | 0.471 4 | 5.90 $m^2$ | 11.03 |
| | DOM + DAP 点云 | 0.743 8 | 4.37 $m^2$ | 8.16 |
| HL | DOM | 0.338 3 | 1.24 m | 5.51 |
| | DAP 点云 | 0.581 6 | 0.99 m | 4.38 |
| | DOM + DAP 点云 | 0.727 6 | 0.75 m | 3.33 |
| AGB | DOM | 0.616 1 | 195.99 kg | 9.88 |
| | DAP 点云 | 0.501 8 | 223.70 kg | 11.28 |
| | DOM + DAP 点云 | 0.776 2 | 151.22 kg | 7.62 |

图 3 展示了 AD、BA、HL、AGB 4 个参数各模型预测结果散点图,可以看出,在仅使用 DOM 数据源时,BA 实测值大于 60 时,出现了明显了高值低估;在仅使用 DAP 点云数据时,AD 预测值出现了明显了低值高估,使用组合数据源进行模型构建时,显著改善了点云的分布,模型精度有明显提升。除 AD 以外,BA、HL、AGB 在组合数据源时散点均较为均匀地分布在 1∶1线附近,DOM 数据源时,从散点与对角线的分布位置关系和散点分布疏密程度来看,效果最优的为 AGB。DAP 点云数据源时除 BA 参数

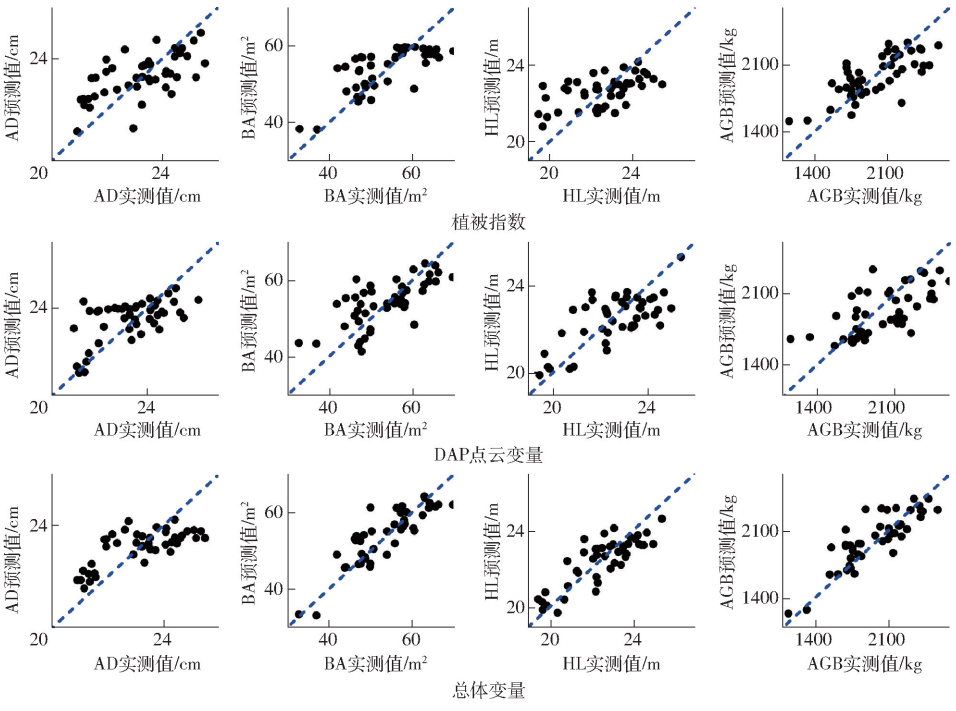



图 3　林分尺度 DNN 的各模型预测结果(蓝色 1∶1虚线仅供参考)

Fig. 3　Prediction results of various models for stand tree level DNN (blue 1∶1 dotted line was for reference only)

外,其他参数在实测值居于高处时,其模型估测值均偏小。组合数据源拟合效果最优的为 AGB;观察 AD 参数散点图与其他散点图,可以得知 AD 参数估测过程中,存在明显的低值高估和高值低估的现象,这导致了 AD 的估测精度相对较低,拟合效果也是4种特征参数中最差的。

### 3.2　SHAP 解释器分析结果

从 3.1 节可以看出基于组合数据源的特征参数模型拟合精度都要显著优于单一数据源模型,所以仅对组合数据源模型进行 SHAP 解释性分析。图 4 展示了林分尺度共 4 种特征参数前 20 位 SHAP 绝对值排序,表 4 统计了前 20 个不同数据源特征的频数以及排序第一的特征数据源与特征名称,结合图 4 和表 4 可知,前 20 个特征以 DAP 点云为数据源的特征总是占比较大,且占比达 60% 以上,占据前 20 个特征的主体位置;在林分尺度上所有组合数据源模型的第一特征统一为 H_CV,H_CV 变量在林分尺度上的参数估计占据较为重要的地位。

#### 3.2.1　局部可解释性分析

局部可解释性分析可以看出每个样本中每个特征变量对于预测结果的影响,SHAP 值用来解释模型预测结果时,需要先为模型的响应变量计算一个基础值(base value),base value 表示在样本的输入特征变量的特征值为缺失值或者为默认值的情况下,模型对样本的预测结果。base value 的结果在特定的情况下可以等于训练样本目标变量的均值。在解释特定样本(任意一组数据)的预测时,每个特征变量的 SHAP 值被计算为该特征变量对预测结果的贡献度。然后,通过将各个特征的 SHAP 值与 base value 相加,得到该样本的最终预测值。

局部可解释分析可以对任意一组样本的预测结果进行解释,图 5 分别为林分尺度下 AGB 实测最大值和最小值单样本解释的力图(Force plot)。SHAP 将各个特征的贡献度表示为力量,这些力在样本的实际预测中相互抗衡,得到最终的预测结果,蓝色表示对 AGB 预测的负向力,红色表示对 AGB 预测的正向力。样本的局部可解释性图中,每个特征变量所占宽度越大,代表该特征变量在该样本中较大的影响了预测值的大小。当样本实测值远高于 base value 时,各特征变量通常会正向的推动预测值,使得预测值达到接近实测值的水平,相反,当样本实测值远低于 base value 时,各特征变量通常会负向的推动预测值,使得预测值达到接近实测值的水平。AGB 的预测中,H_CV 在最大值的预测中 SHAP 值为 77.89,在最小值的预测中 SHAP 值为 -50.56,把同一个特征变量在每个样本的 SHAP 值的绝对值相加就得到了全局可解释性。

#### 3.2.2　全局可解释性分析

全局可解释性散点图(Global explanatory scatter plot)也叫做蜂群图,可以用来展示所有样本的每个特征的SHAP 值,并用颜色表示实际观测值。具

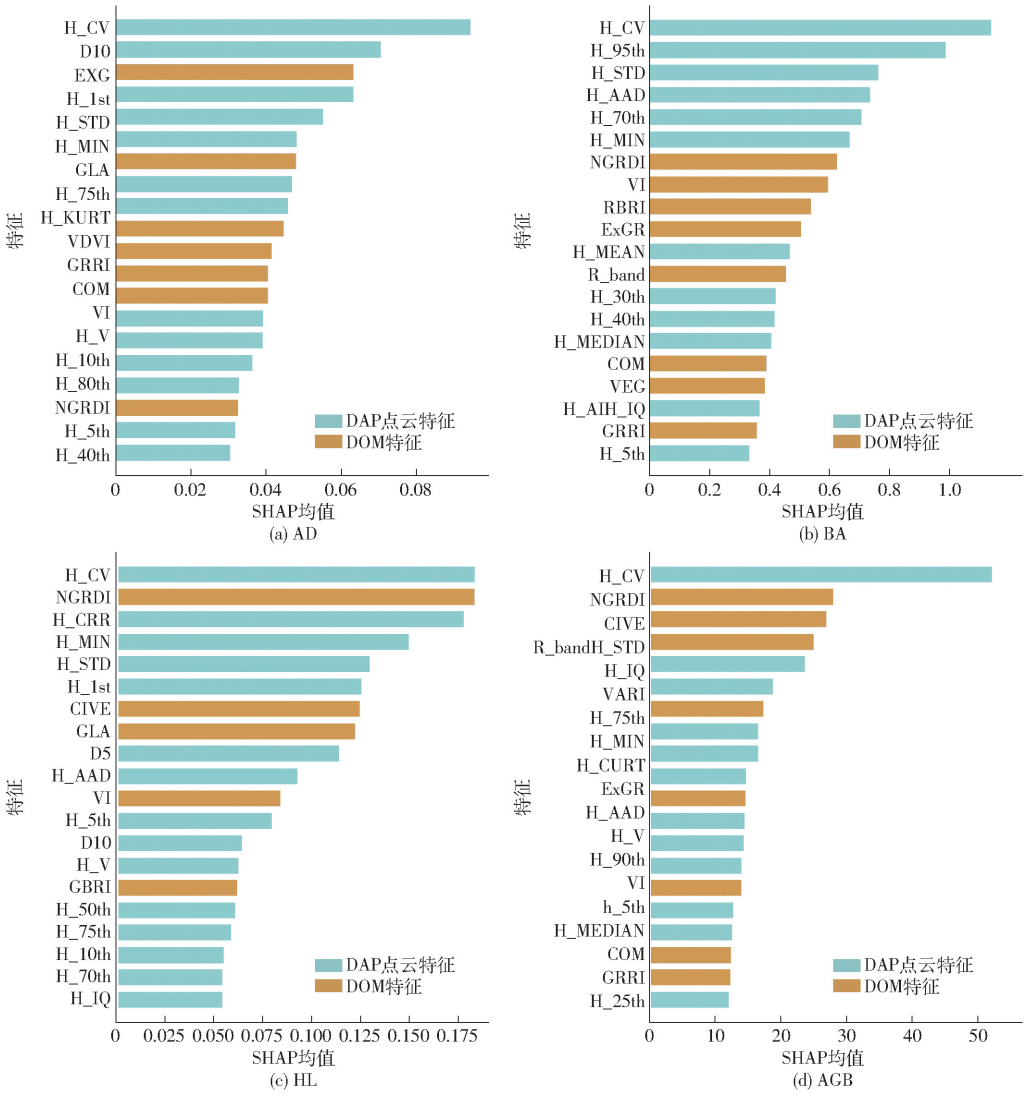



图 4 组合数据源下 DNN SHAP 绝对值排名前 20(从大到小)特征排序

Fig. 4 Absolute value of SHAP ranking plot of top 20 features for DNN model with combined data sources

**表 4 组合数据源下 DNN 模型前 20 个特征统计**

**Tab. 4 Top 20 features of DNN model with combined data sources**

| 特征参数 | DOM 特征数 | DAP 点云特征数 | 最重要特征 | |
|---|---|---|---|---|
| | | | 数据源 | 特征名称 |
| AD | 7 | 13 | DAP 点云 | H_CV |
| BA | 8 | 12 | DAP 点云 | H_CV |
| HL | 5 | 15 | DAP 点云 | H_CV |
| AGB | 8 | 12 | DAP 点云 | H_CV |

体来说,全局可解释性散点图的 $x$ 轴表示 SHAP 值的平均值,$y$ 轴表示特征的名称,每个散点代表一个样本。在散点图中,可以通过颜色来表示该样本的实际观测值,从而更好地理解该样本的预测结果。

图 6 为基于组合数据源的 4 种林分特征参数 DNN 模型的特征全局可解释性图,每一行都代表一个输入的特征变量,SHAP 值为正则对模型预测结果有正影响,为负则为负影响,按照每个变量 SHAP

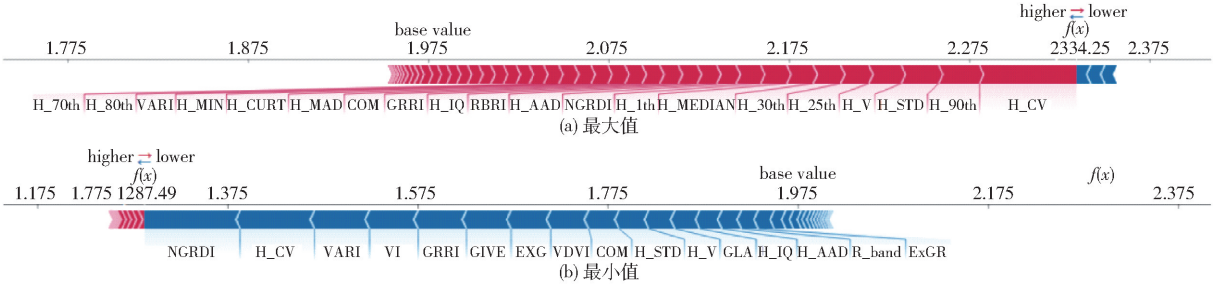



图 5 林分生物量单样本解释性力图

Fig. 5 Stand biomass SHAP force plot for a single sample

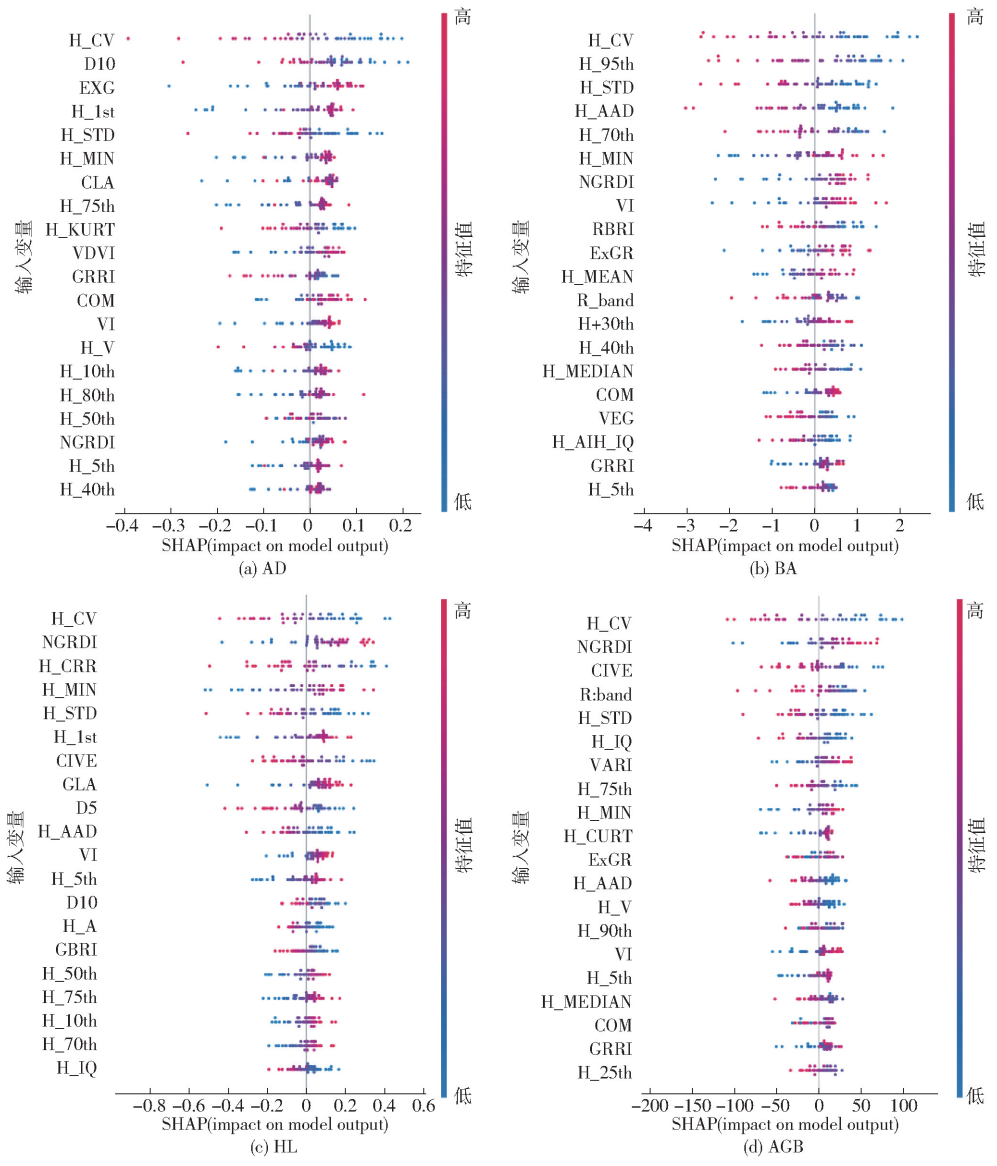



图 6　4 组输入变量进行排序 DNN 模型的全局可解释性图

Fig. 6　Global interpretability plots of DNN model with input variables sorted into four groups

值的绝对值的均值对特征变量进行排序，从下往上越往上特征变量越重要，行中的每个点代表其中一个建模样本，点的颜色代表该特征变量的大小，颜色由蓝到红每个样本的特征值逐渐增大，特征排序越高，对响应变量的影响越大。图 6 中各个图的散点总体也呈现“T”字形规律，即排名靠前的特征均对因变量估测的反馈绝对值更高，排名靠后的特征均对因变量估测的反馈绝对值更低。占据最重要位置的特征变量在 AD、BA、HL 和 AGB 中均是 H_CV，尤其是对于 AD 的预测，H_CV 存在明显的长尾现象，说明 H_CV 越大，林分特征参数 AD 的估测值越小。不同特征变量的极值对响应变量的预测值影响较大，导致了 SHAP 全局可解释性图出现了较多离散值，尤其是 AD 的预测，这也说明了不管是二维光谱变量还是三维点云变量都对 AD 的预测影响较大，这也是 AD 的精度最低的原因。

## 4　讨论

深度学习模型自动特征学习能力使得模型具有更高的泛化能力和鲁棒性[28]，很多研究表明，深度学习可以更好地处理高维数据和非线性关系[7,29-30]，尚未尝试在深度神经网络框架内使用多数据源进行森林特征参数（AD、BA、HL、AGB）的预测。尝试利用 DNN 模型进行 4 种特征参数的模型构建，更充分地挖掘二维光谱数据和三维点云数据中对建模更有用的信息，可以提高无人机影像进行森林资源调查和监测的精度。

DNN 作为一种在机器学习基础上发展起来的深度学习算法，先前的研究表明，该算法更好地从数据集中挖掘有效信息，以准确估计感兴趣的参数[31-32]。在本研究中，将 DNN 回归模型应用于准确估计森林特征参数。深度学习能够很好地概括离

散和连续数据,并且几乎不受地形、树种等因素的影响[33]。与常见的机器学习方法类似,深度学习也被称为“黑匣子”,是一种端到端的建模算法,模型的内部机制和特征的提取过程很难直观理解[7]。尽管该模型获得了最佳拟合结果,但了解 DNN 模型如何工作以及学习哪些知识具有重要意义。为了解释预测模型,使用 SHAP 解释器来确定每个度量的权重,这代表了输入 DNN 模型中的每个特征变量的相对重要性。对于 DNN 模型,使用核解释器进行 SHAP 值计算能够帮助理解特征变量对预测做出的贡献。通过 SHAP 值可以看出,DNN 模型最重要的特征变量有一定的差异,但是 H_CV 在各模型中均占据了最重要的位置,点云高度变量对特征参数具有更高的解释能力,点云高度变量在各模型中都占据了较大的比例。不同森林特征参数的 SHAP 绝对值较高的变量不同,这可能是因为不同的参数对输入变量的敏感性和依赖性存在差异。不同的特征参数(比如树高和生物量)反映了树木不同的生长特征。例如,树高可能主要受环境因素(如光照、土壤类型)或竞争压力影响,而生物量则可能更依赖于树木的整体生长状况,包括树干直径、叶面积指数等因素[34],这体现在不同的光谱或点云变量中。深度学习和机器学习模型通常能够捕捉输入变量与输出参数之间的复杂非线性关系,模型可能会根据具体的森林特征参数产生不同的变量重要性,这导致了每个变量的 SHAP 绝对值的不同,模型会根据特定的森林特征参数权衡这些相关变量的影响[35]。

综上所述,DNN 模型在利用多源数据时,具有较高的稳定性和精度,DAP 点云高度变量具有更高的重要性。虽然样本量较小,但 DNN 模型的多层次结构确保了有限训练样本下各特征参数模型仍能取得较好的精度,同样的,也是由于样本量较小,导致了模型并不能取得更高的精度。

未来的工作需要检验在有限的样本情况下,更先进的深度学习框架用于多元数据集或者多模态数据集模型预测的能力。此外,基于深度学习的回归算法 DNN 可以通过调整超参数来实现更好的拟合模型,DNN 模型训练以及超参数分析较机器学习回归算法更耗费算力,因此需要考虑训练时间以及精度的权衡。

## 5 结论

(1)在基于组合数据源时,DNN 模型的精度要优于单一数据源。林分尺度下,BA 和 AGB 参数数据源精度从高到低依次为 DOM + DAP 点云、DOM、DAP 点云,而 AD 和 HL 参数数据源精度从高到低依次为 DOM + DAP 点云、DAP 点云、DOM。组合数据源有助于提高模型适用性。

(2)SHAP 解释器能够解释每个特征变量在每个样本中所起到的作用,最后得出每个特征变量对每个特征参数预测的重要值。

(3)DNN 模型仍然可以在小样本量下实现特征参数的拟合,基于 DAP 获取的二维和三维特征在森林特征参数的预测中显示出了巨大的潜力。

(4)利用无人机 DAP 数据能够进行林分尺度森林特征参数的预测,数据源的本身属性是限制森林特征参数估测精度的主要因素,因此在对森林特征参数进行估测时,除不同的特征参数做响应变量以外,还应考虑不同的数据源及回归模型,选取最优组合从而达到最优的估测结果。

## 参 考 文 献


[1] PROISY C, COUTERON P, FROMARD F. Predicting and mapping mangrove biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images[J]. Remote Sensing of Environment, 2007, 109(3): 379 - 392.

[2] PAGAN J I, BANON L, LOPEZ I, et al. Monitoring the dune-beach system of Guardamar del Segura (Spain) using UAV, SfM and GIS techniques[J]. Science of the Total Environment, 2019, 687: 1034 - 1045.

[3] YANG H, LI F, WANG W, et al. Estimating above-ground biomass of potato using random forest and optimized hyperspectral indices[J]. Remote Sensing, 2021, 13(12): 2339.

[4] XU Z, SHEN X, CAO L, et al. Tree species classification using UAS-based digital aerial photogrammetry point clouds and multispectral imageries in subtropical natural forests[J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 92: 102173.

[5] 营永峰, 韩泽民, 黄光体, 等. 基于高分辨率遥感影像的北亚热带森林生物量反演[J]. 生态学报, 2020, 41(6): 2161 - 2169.
JIAN Yongfeng, HAN Zemin, HUANG Guangti, et al. Estimation of forest biomass using high spatial resolution remote sensing imagery in north subtropical forests[J]. Acta Ecologica Sinica, 2020, 41(6): 2161 - 2169. (in Chinese)

[6] BOUVIER M, DURRIEU S, FOURNIER R A, et al. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data[J]. Remote Sensing of Environment, 2015, 156: 322 - 334.

[7] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436 - 444.

[8] CHARU C A. An introduction to neural networks[M]. Springer, Cham, 2018.

[9] RYU S, NOH J, KIM H. Deep neural network based demand side short term load forecasting[J]. Energies, 2017, 10(1): 10003.

[10] QIAN C, QIANG H, WANG F, et al. Estimation of forest aboveground biomass in karst areas using multisource remote sensing data and the K - DBN algorithm[J]. Remote Sensing, 2022, 13(24): 5030.

[11] 秦格霞，吴静，李纯斌，等. 基于机器学习算法的天祝藏族自治县草地地上生物量反演[J]. 草地学报，2022，31(4)：177－188.
QIN Gexia，WU Jing，LI Chunbin，et al. Inversion of grassland aboveground biomass in Tianzhu Zangzu Autonomous County based on a machine learning algorithm[J]. Acta Agrestia Sinica，2022，31(4)：177－188.（in Chinese）
[12] 王赞，闫明，刘爽，等. 深度神经网络测试研究综述[J]. 软件学报，2020，31(5)：1255－1275.
WANG Zan，YAN Ming，LIU Shuang，et al. Survey on testing of deep neural networks[J]. Journal of Software，2020，31(5)：1255－1275.（in Chinese）
[13] PAN X，ZHANG C，XU J，et al. Simplified object-based deep neural network for very high resolution remote sensing image classification[J]. ISPRS Journal of Photogrammetry and Remote Sensing，2021，181：218－237.
[14] XIE Y，WANG Y，SUN Z，et al. Instance segmentation and stand-scale forest mapping based on UAV images derived RGB and CHM[J]. Computers and Electronics in Agriculture，2024，220：108878.
[15] ABDOLLAHI A，PRADHAN B，SHUKLA N，et al. Deep learning approaches applied to remote sensing datasets for road extraction：a state-of-the-art review[J]. Remote Sensing，2020，12(9)：1444.
[16] JIN X，LI Z，FENG H，et al. Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index[J]. Crop Journal，2020，8(1)：87－97.
[17] MAIMAITIJIANG M，SAGAN V，SIDIKE P，et al. Soybean yield prediction from UAV using multimodal data fusion and deep learning[J]. Remote Sensing of Environment，2020，237：111599.
[18] ZHANG Y，HAN X，LI Q，et al. A game theoretic approach to explainable machine learning[C]//Proceedings of the AAAI Conference on Artificial Intelligence，2019：1146－1153.
[19] MOLNAR C. Interpretable machine learning[M/OL]//A Guide for Making Black Box Models Explainable，2020. https：//christophm. github. io/interpretable-ml-book/
[20] 徐雪蕾. 间伐对杉木人工林的生长调控作用研究[D]. 北京：北京林业大学，2020.
XU Xuelei. Regulation of thinning on the tree growth in Chinese fir plantations[D]. Beijing：Beijing Forestry University，2020.（in Chinese）
[21] JARRON L R，COOPS N C，Mackenzie W H，et al. Detection of sub-canopy forest structure using airborne LiDAR[J]. Remote Sensing of Environment，2020，244：111770.
[22] HE Q，CHEN E，AN R，et al. Above-ground biomass and biomass components estimation using lidar data in a coniferous forest[J]. Forests，2013，4(4)：984－1002.
[23] MATHEWS A，JENSEN J. Visualizing and quantifying vineyard canopy lai using an unmanned aerial vehicle（UAV）collected high density structure from motion point cloud[J]. Remote Sensing，2013，5(5)：2164－2183.
[24] 杜春雨. 基于主被动遥感数据协同的森林 AGB 估算及其饱和点分析[D]. 哈尔滨：东北林业大学，2021.
DU Chunyu. Estimation of forest aboveground biomass and determination of its saturation values based on passive and active data[D]. Harbin：Northeast Forestry University，2021.（in Chinese）
[25] FENG S，ZHOU H，DONG H. Using deep neural network with small dataset to predict material defects[J]. Materials & Design，2019，162：300－310.
[26] HONG S，HULLMAN J，BERTINI E. Human factors in model interpretability：industry practices，challenges，and needs [C]// Proceedings of the ACM on Human-Computer Interaction，2020：1－26.
[27] 陈蒙，王华. 地震动强度参数估计的可解释性与不确定度机器学习模型[J]. 地球物理学报，2022，65(9)：3386－3404.
CHEN Meng，WANG Hua. Explainable machine learning model for prediction of ground motion parameters with uncertainty quantification[J]. Chinese Journal of Geophysics，2022，65(9)：3386－3404.（in Chinese）
[28] CARRIO A，SAMPEDRO C，RODRIGUEZ-RAMOS A，et al. A review of deep learning methods and applications for unmanned aerial vehicles[J]. Journal of Sensors，2017，2017：3296874.
[29] 王鹏新，田惠仁，张悦，等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报，2022，53(2)：1－14.
WANG Pengxin，TIAN Huiren，ZHANG Yue，et al. Crop growth monitoring and yield estimation based on deep learning：state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery，2022，53(2)：1－14.（in Chinese）
[30] POUYANFAR S，SADIQ S，YAN Y，et al. A survey on deep learning：algorithms，techniques，and applications[J]. ACM Computing Surveys，2018，51(5)：1－36.
[31] RYU S，NOH J，KIM H. Deep neural network based demand side short term load forecasting[J]. Energies，2017，10(1)：10003.
[32] KHELIFI L，MIGNOTTE M. Deep learning for change detection in remote sensing images：comprehensive review and meta-analysis[J]. IEEE Access，2020，8：126385－126400.
[33] SEELIG H，HOEHN A，STODIECK L，et al. The assessment of leaf water content using leaf reflectance ratios in the visible，near-，and short-wave-infrared[J]. International Journal of Remote Sensing，2008，29(13)：3701－3713.
[34] MA T，ZHANG C，JI L，et al. Development of forest aboveground biomass estimation，its problems and future solutions：a review[J]. Ecological Indicators，2024，159：111653.
[35] 蒋星驰，温苏雅勒图，李俊瑶，等. 基于 SHAP 值方法的乌拉特梭梭(*Haloxylon ammodendron*)林保护区土壤表层碳氮储量及其影响因素研究[J]. 中国沙漠，2023，43(2)：170－183.
JIANG Xingchi，WENSUYALETU，LI Junyao，et al. Study on storage of soil surface carbon and nitrogen and its influencing factors in Urad National Nature Reserve of *Haloxylon ammodendron* based on SHAP values[J]. Journal of Desert Research，2023，43(2)：170－183.（in Chinese）