

# SỬ DỤNG ẢNH VIỄN THĂM ĐỂ ƯỚC TÍNH SINH KHỐI RỪNG TRÊN MẶT ĐẤT: THÁCH THỨC VÀ TRIỂN VỌNG

Hồ Đình Bảo, Nguyễn Thị Thanh Hương

*Trường Đại học Tây Nguyên*

## TÓM TẮT

Định lượng sinh khối rừng trên mặt đất (AGB) là một trong những yếu tố vô cùng quan trọng trong giám sát biến đổi khí hậu toàn cầu. Kỹ thuật viễn thám đã phát triển trở thành một công cụ hữu hiệu không thể thiếu trong tiến trình này. Cho đến nay, đã có nhiều nghiên cứu liên quan đến xây dựng các nguyên tắc, nguồn dữ liệu cũng như phương pháp sử dụng viễn thám khác nhau để ước tính. AGB được ước tính dựa trên các chỉ số ảnh viễn thám kết hợp với dữ liệu điều tra ô mẫu trên mặt đất. Các nguồn dữ liệu thường được sử dụng là ảnh vệ tinh quang học, ảnh vệ tinh siêu cao tần, ảnh LiDAR. Mỗi loại nguồn dữ liệu đều có các ưu và nhược điểm riêng trong việc ước tính AGB. Cho dù vậy, viễn thám vẫn được dự đoán sẽ đóng một vai trò ngày càng quan trọng trong ước tính AGB vì nó cung cấp cơ sở lý thuyết để nghiên cứu chu trình carbon, dữ liệu cho việc mua bán tín chỉ carbon cũng như trong giám sát rừng. Bên cạnh đó, các phương pháp mô hình hóa khác nhau cũng mang lại kết quả ước tính khác nhau phụ thuộc vào tính sẵn có của dữ liệu đầu vào và sai số trong ước lượng. Tuy nhiên, để ước tính AGB một cách nhanh chóng, chính xác và chi phí thấp vẫn đang là một thách thức và cần tiếp tục được quan tâm trong nghiên cứu lâm nghiệp.

**Từ khóa:** Giám sát carbon rừng, sinh khối rừng trên mặt đất, viễn thám

## USING REMOTE SENSING IMAGES FOR ESTIMATING ABOVEGROUND FOREST BIOMASS: CHALLENGES AND PROSPECTS

Ho Dinh Bao, Nguyen Thi Thanh Huong

*Tay Nguyen University*

## ABSTRACT

Quantifying forests aboveground biomass (AGB) is one of the most important factors in monitoring global climate change. Remote sensing techniques have developed into an indispensable tool in this process. So far, there have been many studies related to building principles, data sources and methods of using different remote sensing to estimate. AGB is estimated based on remote sensing image indices combined with ground sample plot survey data. The data sources commonly used are optical satellite images, ultra-high frequency satellite images, LiDAR images. Each type of data source has its own advantages and disadvantages in estimating AGB. However, remote sensing is still predicted to play an increasingly important role in estimating AGB because it provides a theoretical basis for studying the carbon cycle, data for carbon credit trading and forest monitoring. In addition, different modeling methods also lead to different estimation results depending on the availability of input data and the error in estimation. However, estimating AGB quickly, accurately and inexpensively is still a challenge and needs to be further studied in forestry research.

**Keywords:** Forest Carbon monitoring, forest above ground biomass, remote sensing

## I. ĐẶT VẤN ĐỀ

Trong một vài thập kỷ gần đây, khí hậu toàn cầu thay đổi nhanh chóng đã ảnh hưởng nghiêm trọng đến các hệ sinh thái tự nhiên và xã hội loài người trên toàn thế giới, dẫn đến một loạt các vấn đề sinh thái như nước biển dâng (Nerem, R.S. *et al.*, 2018), băng tan (Kang, S.C., *et al.*, 2019; Radic, V., *et al.*, 2014; Zheng, G.X., *et al.*, 2021), thời tiết cực đoan (Ebi, K.L., *et al.*, 2021; Yin, J.B., *et al.*, 2018), giảm sản lượng lương thực (Hasegawa, T., *et al.*, 2018), tuyệt chủng các loài (Bellard, C., *et al.*, 2012) và những ảnh hưởng xấu đến sức khỏe con người (Frumkin, H.; Haines, A., 2019) đã đe dọa trực tiếp đến sự sống còn và an ninh của loài người.

Hệ sinh thái rừng là một bể chứa carbon trên cạn lớn nhất, lưu trữ khoảng 76 - 98% carbon hữu cơ trên cạn (khoảng 80% carbon trên mặt (t và 40% carbon dưới mặt đất) (Houghton, R.A., *et al.*, 2009; Pan, Y.D., *et al.*, 2011). Hơn nữa, hệ sinh thái rừng đóng một vai trò quan trọng trong chu trình carbon toàn cầu bằng cách hấp thụ khí nhà kính (GHG) như CO<sub>2</sub> trong khí quyển, do đó làm giảm nồng độ GHG từ đó giảm thiểu hoặc làm chậm lại quá trình biến đổi khí hậu toàn cầu (Molotoks, A., *et al.*, 2018; Payne, N.J., *et al.*, 2019; Tian, L., *et al.*, 2022; Xiao, J.F., *et al.*, 2019). Sinh khối rừng trên mặt đất phản ánh mối quan hệ phức tạp giữa chu trình dinh dưỡng và là một chỉ số quan trọng về khả năng hấp thụ carbon của hệ sinh thái rừng (Brown, S., *et al.*, 1996; Li, D.R., *et al.*, 2012). Do đó, ước tính AGB rừng trong bối cảnh biến đổi khí hậu có thể cung cấp cơ sở khoa học và dữ liệu cho việc quản lý, giám sát thay đổi về hấp thụ carbon của rừng nhằm chi trả dịch vụ hấp thụ carbon của rừng.

Ước tính một cách nhanh chóng và chính xác về AGB của rừng vẫn còn nhiều thách thức trong nghiên cứu lâm nghiệp (Huang, H.B., *et al.*, 2019; Zhang, R., 2019). Nói chung, các phương pháp ước tính AGB rừng có thể được

chia thành: Phương pháp đo thực địa, phương pháp tiếp cận dựa vào viễn thám và phương pháp mô hình hóa sinh thái (Huang, H.B., *et al.*, 2019; Zhang, Y.Z., *et al.*, 2019). Các phép đo thực địa đòi hỏi nhiều nhân lực và tốn kém chi phí. Cho đến nay, các phương pháp đo thực địa được coi là phương pháp chính xác nhất để thu thập dữ liệu sinh khối rừng (Chave, J., *et al.*, 2014; Lu, D.S., *et al.*, 2016). Để ước tính AGB trên phạm vi rộng và những nơi khó tiếp cận thì phương pháp viễn thám kết hợp dữ liệu đo mặt đất được xem là khả thi hơn để ước tính AGB. Phương pháp này được thực hiện bằng cách thu thập các đặc điểm quang phổ, chỉ số thực vật được tính từ dữ liệu viễn thám chẳng hạn như chỉ số thực vật (VIs), độ che phủ và chiều cao của tán cây, LAI (Leaf Area Index - diện tích tán lá), BA (BA-Basal Area) và V (Stand Volume - Trữ lượng lâm phần) (Baccini, A., *et al.*, 2012; Badreldin, N., Sanchez-Azofeifa, A., 2015; Bouvet, A., *et al.*, 2018; Narine, L.L., *et al.*, 2019; Santoro, M., *et al.*, 2015), sau đó mô hình ước tính AGB được xây dựng để lập bản đồ AGB khu vực nghiên cứu (Cartus, O., *et al.*, 2012). Ngoài hai phương pháp nói trên, mô hình hóa các mô hình sinh thái là một công cụ đầy hứa hẹn để đánh giá AGB lâm phần (Tian, X., *et al.*, 2017). Tuy nhiên, cách tiếp cận này thường chỉ áp dụng cho một khu vực có điều kiện sinh thái nhất định và đòi hỏi một số lượng lớn các tham số đầu vào mà nhiều khu vực khó có thể tiếp cận để thu thập được (Hurt, G.C., *et al.*, 2010; Waring, R.H., *et al.*, 2010). Do đó, các phương pháp tiếp cận dựa trên viễn thám vẫn là nguồn dữ liệu chủ yếu để lập bản đồ và ước tính AGB trong các điều kiện khác nhau (Bao Huy, *et al.*, 2022; Chopping, M., *et al.*, 2022; Yan, F., *et al.*, 2015; Zhang, R., *et al.*, 2019; Zhang, Y.Z., 2019).

Mục tiêu của bài báo này nhằm (1) Giới thiệu các nguyên tắc, phương pháp ước tính AGB rừng bằng cách sử dụng dữ liệu viễn thám; (2) Các thách thức trong việc sử dụng ảnh viễn


thảm để ước tính AGB và (3) Triển vọng của sử dụng ảnh viễn thám trong việc ước tính AGB của rừng.

**II. ƯỚC TÍNH AGB BẰNG ẢNH VIỄN THÁM**

**2.1. Các nguyên tắc ước tính AGB bằng ảnh viễn thám**

Trái ngược với ước tính sinh khối rừng trực tiếp, các kỹ thuật viễn thám thường đánh giá

AGB rừng thông qua việc xây dựng và sử dụng các thông số như sóng phản xạ bề mặt, VIs, LAI, độ che phủ thực vật, chiều cao cây và đường kính tán cây nhằm thiết lập các mối quan hệ đóng vai trò là đại diện cho AGB (Zhang, Y.Z., *et al.*, 2019). Các kỹ thuật viễn thám được sử dụng để ước tính AGB của rừng được minh họa trong hình 1.



**Hình 1.** Minh họa ước tính AGB bằng kỹ thuật viễn thám


Ngoài thông tin các band ảnh đơn phổ của dữ liệu viễn thám quang học, ước tính AGB thường được ước tính thông qua VIs bao gồm chỉ số khác biệt thực vật chuẩn hóa (NDVI - Normal Differences Vegetation Index), chỉ số khác biệt thực vật (DVI - Differences Vegetation Index) và chỉ số thực vật tăng cường (EVI - Enhance Vegetation Index) (Garrouette, E.L., *et al.*, 2016; Tian, F., *et al.*, 2016; Xiao, J.F., 2019). Tuy nhiên, khi thảm thực vật dày lên, sự hấp thụ mạnh các bước sóng ở dải bước sóng màu đỏ dẫn đến hiệu ứng bão hòa, do đó làm giảm độ chính xác trong ước tính AGB (Zhang, Y.Z., *et al.*, 2019). Vì vậy, một số chỉ số thực vật khác như NDVI chuẩn hóa lại (RNDVI - Renormalized DVI) và tỷ lệ đơn giản sửa đổi (MSR) đã được phát triển để cải thiện độ chính xác của ước tính sinh khối trong các khu vực có thảm thực vật dày (Chen, J.M., 1996;

Durante, P., *et al.*, 2019). Đối với các khu vực có thảm thực vật thưa thớt, VI vuông góc dựa trên biến đổi trục giao VI (PVI - Perpendicular VI), VI hiệu chỉnh đất (SAVI - Soil-adjusted VI) và SAVI điều chỉnh (MSAVI - Modified SAVI) được sử dụng để giảm thiểu nhiễu từ khí quyển và nền đất (Fatehi, P., *et al.*, 2015; Luo, S.Z., *et al.*, 2017; Sadeghi, Y., *et al.*, 2018). Hơn nữa, thông tin kết cấu ảnh viễn thám ngày càng được sử dụng nhiều hơn trong ước tính AGB của rừng (Kelsey, K.C.; Neff, J.C., 2014; Sarker, L.R.; Nichol, J.E., 2011). Các thông số bổ sung cần thiết cho ước tính AGB bao gồm các thông số mô tả cấu trúc rừng, chẳng hạn như chiều cao cây, đường kính ngang ngực (DBH - Diameter at Breast Height) và chiều cao tán cây. Chiều cao cây không chỉ phản ánh các đặc tính sinh học và khả năng sinh trưởng của cây, mà còn cho biết trữ lượng rừng

(Fang, J.Y., *et al.*, 2021). Các nghiên cứu trước đây đã chứng minh AGB có mối liên hệ với chiều cao cây (thông qua một hệ số) ở các khu rừng rậm bằng cách sử dụng dữ liệu khảo sát về tuổi cây và chiều cao cây trung bình (Fang, J.Y., *et al.*, 2006). Tuy nhiên, rất khó để xác định chiều cao cây ở quy mô lớn, đặc biệt là ở các khu rừng kín có chiều cao cây lớn; do đó, thông thường chỉ xác định chiều cao cây của một số cây cá thể và sau đó ước tính chiều cao tổng thể của ô mẫu bằng cách thiết lập mối tương quan giữa chiều cao cây và DBH (Fang, J.Y., *et al.*, 2021). Hơn nữa, phương trình sinh học hàm mũ thể hiện tương quan giữa AGB và chiều cao cây được xây dựng ở quy mô ô mẫu vẫn được áp dụng trên quy mô lớn (Wu, X.; Wang, X.P, *et al.*, 2015). Đây là một lợi thế đáng kể của việc ước tính AGB bằng viễn thám kết hợp với các phép đo mặt đất (Chopping, M., *et al.*, 2022; Huang, H.B., *et al.*, 2019; Zhang, Y.Z., *et al.*, 2019). Trong những năm gần đây, viễn thám siêu cao tần và viễn thám LiDAR (Light Detection And Ranging) đã được sử dụng rộng rãi để ước tính AGB. Chiều cao cây có thể được lấy chính xác và thuận tiện

từ dữ liệu InSAR và LiDAR (Asner, G.P.; Mascaro, J., 2014; Solberg, S., *et al.*, 2014; Yu, Y.F., *et al.*, 2010). Ngoài ra, chiều cao tán cây đã được chứng minh là cung cấp ước tính AGB chính xác (Bouvier, M., *et al.*, 2015; Simard, M., *et al.*, 2019). Đáng chú ý, chiều cao tán không phải là chiều cao cây; nó không chỉ phụ thuộc vào chiều cao của cây, mà còn phụ thuộc vào tán cây và mật độ cây gỗ (Zhang, Y.Z., *et al.*, 2019).

Nhìn chung, AGB được ước tính bằng cách sử dụng dữ liệu viễn thám thu được trên một dải bước sóng điện từ rộng, từ ánh sáng khả kiến đến vi sóng (hình 2). Ngoài các thông số quá trình sinh thái ở trên, các yếu tố môi trường (ví dụ: lượng mưa, nhiệt độ và áp suất khí quyển), địa hình và các yếu tố sinh học (ví dụ: đa dạng loài) cũng ảnh hưởng đến ước tính AGB của rừng. Cụ thể, các yếu tố như lượng mưa, nhiệt độ, độ cao và độ dốc thúc đẩy mô hình phân bố loài cây, trong khi tài nguyên đất và cường độ bức xạ xác định điều kiện tăng trưởng của thảm thực vật, tất cả đều ảnh hưởng đến AGB rừng (McEwan, R.W., *et al.*, 2011).



**Hình 2.** Sử dụng phổ điện từ ước tính sinh khối rừng trên mặt đất (Xiao và đồng tác giả, 2019)

Ghi chú: MLA: phương pháp học máy; NIR: cận hồng ngoại; SWIR: hồng ngoại sóng ngắn; TIR: hồng ngoại nhiệt; VIs: chỉ số thực vật; LAI: chỉ số diện tích lá; SIF: huỳnh quang diệp lục do năng lượng mặt trời gây ra; GPP: tổng tăng trưởng hàng năm của rừng.

**2.2. Nguồn dữ liệu ảnh viễn thám sử dụng ước lượng AGB**

AGB của rừng có thể được định lượng bằng nhiều dữ liệu và phương pháp viễn thám khác nhau (Zhang, Y.Z., *et al.*, 2019; Abbas, S., *et al.*, 2020; Ryu, Y., *et al.*, 2019; Schimel, D., *et al.*, 2015; Xiao, J.F., *et al.*, 2019). Các nguồn dữ liệu bao gồm dữ liệu viễn thám quang học thụ động, dữ liệu viễn thám chủ động siêu cao tần và dữ liệu viễn thám LiDAR,...

**2.2.1. Ảnh viễn thám quang học thụ động**

Viễn thám thụ động là hệ thống viễn thám không tự mang nguồn bức xạ. Cụ thể, nó là một hệ thống viễn thám trong đó thiết bị thu nhận và ghi lại thông tin điện từ phát ra từ chính vật thể mục tiêu hoặc phản xạ từ nguồn bức xạ tự nhiên (mặt trời) trong quá trình viễn thám. Viễn thám quang học thụ động được sử dụng rộng rãi để ước tính AGB rừng vì nó rất nhạy cảm với các đặc tính của tán cây. Dữ liệu có độ phân giải thô (250 - 8.000 m, ví dụ: MODIS, AVHRR) thường được sử dụng để ước tính AGB rừng ở quy mô khu vực hoặc toàn cầu (Baccini, A., *et al.*, 2017; Chopping, M., *et al.*, 2011; Chopping, M., 2022; Zhang, X.Y.; Kondragunta, S., 2006). Hơn nữa, dữ liệu độ phân giải không gian trung bình (~30 m như ảnh Landsat, Sentinel-2 Multispectral Imager (MSI) và Terra/Aqua ASTER) được áp dụng cho các ước tính AGB rừng quy mô địa phương và khu vực cho các hệ sinh thái khác nhau (Fremout, T., *et al.*, 2022; Luo, M., *et al.*, 2021; Muukkonen, P.; Heiskanen, J., 2005; Sibanda, M., *et al.*, 2015; Taddese, H., *et al.*, 2020). Dữ liệu có độ phân giải không gian cao (< 5 m, như IKONOS, QuickBird và WorldView-2) thường được sử dụng để tính toán AGB rừng quy mô lâm phần (Dillabaugh, K.A.; King, D.J., 2008; Eckert, S., 2012; Hirata, Y., *et al.*, 2014). Tuy nhiên, dữ liệu như vậy thường là các vệ tinh thương mại, điều này hạn chế ứng

dụng rộng rãi hơn của chúng trong lĩnh vực ước tính AGB rừng.

Phản xạ quang phổ, VIs, kết cấu không gian và đặc tính tán rừng là các biến số chính có được thông qua viễn thám quang học thụ động để ước tính AGB. VIs đã được phát triển để giảm thiểu ảnh hưởng của các yếu tố góp phần đại diện cho điều kiện thực vật, chẳng hạn như nền đất, khí quyển và địa hình (Bannari, A., *et al.*, 1995; Gao, X., *et al.*, 2000; Huete, A.R., 1988; Zeng, Y.L., *et al.*, 2022). Ngoài các VIs thường được sử dụng (ví dụ: NDVI, EVI, SR và chỉ số chênh lệch diệp lục), biến đổi phổ (TC) và phân tích thành phần chính (PCA - Principal Component Analysis) cũng thường được sử dụng để ước tính AGB (Xiao, J.F., *et al.*, 2019). Kết cấu không gian ảnh mô tả các đặc điểm không gian của hình ảnh và có thể phản ánh lượng AGB rừng ở một mức độ nào đó. Thông tin kết cấu này có thể được trích xuất bằng ma trận cấp độ xám, thường sử dụng kích thước cửa sổ 3 x 3 (Eckert, S., 2012; Ploton, P., *et al.*, 2017). Ngoài ra, các nghiên cứu trước đây đã cải thiện độ chính xác của các ước tính AGB bằng cách bao gồm các chỉ số phản ánh các thuộc tính tán rừng, chẳng hạn như LAI, mật độ tán rừng (FCD - Forest Canopy Density) và độ che phủ rừng (Blackard, J.A., *et al.*, 2008; Li, T.; Li, M.Y., *et al.*, 2022; Zhang, G., 2014).

Viễn thám quang học là một trong những công cụ tốt nhất để ước tính AGB rừng vì độ phân giải không gian khác nhau từ phạm vi rộng như MODIS đến chi tiết như Wordview, đa thời gian, phạm vi phủ sóng toàn cầu và chi phí thấp. Tuy nhiên, khả năng xuyên qua đối tượng kém, chủ yếu ghi lại thông tin về cấu trúc nằm ngang, do đó khó ước lượng được cấu trúc đứng của rừng, đồng thời bị ảnh hưởng bởi những yếu tố khác như mây, mưa,.... Hơn nữa, tín hiệu viễn thám quang học có thể trở nên bão hòa trong các khu rừng rậm rạp, dẫn đến việc đánh giá thấp hoặc quá cao mật độ sinh khối.

Do đó, để ước tính chính xác AGB rừng bằng cách sử dụng dữ liệu viễn thám quang học cũng là một thách thức (Xiao, J.F., *et al.*, 2019).

### 2.2.2. Ảnh viễn thám siêu cao tần

Trái ngược với viễn thám quang học, công nghệ viễn thám Radar (viễn thám chủ động) có khả năng chụp ảnh ngày đêm, xuyên qua các đám mây và thảm thực vật, thu thập thông tin về cấu trúc bên trong của rừng và không bị ảnh hưởng bởi điều kiện khí tượng và mức độ ánh sáng mặt trời. Do đó, nó mang lại những lợi thế nhất định trong việc ước tính AGB của rừng (Li, D.R., *et al.*, 2012; Zaki, N.A.M.; Abd Latif, Z., 2017). Ảnh ra-đar khẩu độ tổng hợp (SAR) chủ yếu ước tính AGB rừng dựa trên hệ số tán xạ ngược. Các bước sóng tán xạ ngược SAR khác nhau (hoặc tần số) và sự phân cực bắt nguồn từ các bộ phận cây khác nhau, dẫn đến khả năng ước tính AGB khác nhau. Hơn nữa, AGB rừng chủ yếu được ước tính bằng cách sử dụng SAR ở các băng tần X-(9,6 G, 3,0 cm), C- (5,6 G, 5,7 cm), S- (3,0 G, 10 cm), L- (1,27 G, 23,5 cm) và dải P (0,435 G, 70,0 cm) và các tín hiệu phân cực HH (Phân cực theo chiều ngang), HV (Phân cực theo chiều dọc), VH (Phân cực chéo VH) và VV (Phân cực chéo VV). Dải X tương tác với lá và tán cây và trích xuất thông tin từ lớp bề mặt của tán rừng, trong khi dải C xuyên qua lá và bị phân tán bởi các nhánh nhỏ và các đặc điểm dưới tầng. Dải L có khả năng thâm nhập cao qua lớp bề mặt tán và được phân tán bởi thân chính và các nhánh của rừng. Cuối cùng, băng tần P, có khả năng xuyên thấu lớn nhất, có thể xuyên qua toàn bộ tán cây và phần lớn các tín hiệu tán xạ ngược băng tần P được tạo ra bởi thân chính và tương tác của nó với mặt đất. Bốn kết hợp phân cực của dữ liệu SAR là (1) phân cực HH, trong đó cả tín hiệu truyền và tán xạ ngược đều được phân cực theo chiều ngang; (2) phân cực HV, trong đó các tín hiệu truyền và tán xạ ngược được phân cực ngang và dọc, tương ứng;

(3) phân cực VH, trong đó các tín hiệu truyền và tán xạ ngược được phân cực theo chiều dọc và chiều ngang, tương ứng; và (4) phân cực VV, trong đó cả tín hiệu truyền và tán xạ ngược đều được phân cực theo chiều dọc (Ghasemi, N., *et al.*, 2011).

Các nghiên cứu trước đây đã phát hiện ra rằng dữ liệu đồng phân cực (HH và VV) ở bước sóng dài hơn (ví dụ: băng tần P) rất nhạy cảm với điều kiện bề mặt thay đổi. Ngược lại, tín hiệu tán xạ ngược từ phân cực chéo (HV và VH) chủ yếu bao gồm nhiều tán xạ trong tán cây và ít bị ảnh hưởng bởi điều kiện bề mặt (Chen, R.X., 1999; Huang, Y.P.; Chen, J.S., 2013; Wang Xiaoyi, *et al.*, 2022). Đối với các khu vực sinh khối thấp, chẳng hạn như đồng cỏ, đầm lầy, rừng tái sinh, tín hiệu tán xạ ngược ở bước sóng dài hơn thấp hơn so với dải C; do đó, dải C được ưu tiên để ước tính sinh khối ở các khu vực sinh khối thực vật thấp hơn (Ghasemi, N., *et al.*, 2011).

Dải C bị hạn chế do không có khả năng thâm nhập hiệu quả vào tán cây và mức độ bão hòa của nó (khoảng 60 - 70 Mg/ha). Tuy nhiên, những hạn chế này có thể được khắc phục bằng cách sử dụng các dải dài hơn, có khả năng thâm nhập tán rừng cao hơn (ví dụ: băng L và dải P) (Huang, X.D., *et al.*, 2018). Các nghiên cứu đã chỉ ra rằng băng L và dải P thường bão hòa ở mức 100 Mg/ha đối với các cấu trúc rừng nhiệt đới không đồng nhất phức tạp (Sandberg, G., *et al.*, 2011); tuy nhiên, mức bão hòa này tăng lên khoảng 250 Mg/ha đối với các lâm phần có cấu trúc đơn giản và ít loài chiếm ưu thế (Lucas, R.M., *et al.*, 2006).

Mặc dù sóng radar có khả năng trích xuất thông tin cấu trúc thẳng đứng của rừng và được sử dụng rộng rãi trong ước tính sinh khối rừng, nhưng vẫn tồn tại nhiều khó khăn trong ước tính sinh khối rừng dựa trên SAR. SAR phản ánh độ nhám của bề mặt che phủ đất và do đó, không thể phân biệt giữa các loại thảm thực vật. Hơn nữa, tín hiệu SAR dễ bị nhiễu từ điều

kiện tốc độ, độ ẩm và nhiệt độ gió cao, do đó làm phức tạp việc ước tính sinh khối (Li, D.R., *et al.*, 2012). Ngoài ra, độ bão hòa tín hiệu SAR cũng ảnh hưởng đến độ chính xác ước tính sinh khối rừng (Chen, R.X., 1999; Liu, X., *et al.*, 2014; Wu, Y.R., *et al.*, 2007). May mắn thay, các nguồn dữ liệu đang được phát triển như PolInSAR và SAR chụp cắt lớp (TomoSAR), bao gồm BIOMASS, NISAR và TanDEM-L có thể khắc phục hiệu quả các vấn đề bão hòa trong ước tính AGB bằng cách đo trực tiếp các cấu trúc không gian rừng (Xiao, J.F., *et al.*, 2019). Do đó, việc sử dụng PolInSAR và TomoSAR cho thấy nhiều hứa hẹn trong tương lai gần.

### 2.2.3. Ảnh viễn thám LiDAR

Bản chất hai chiều (2D) của dữ liệu viễn thám quang học giới hạn ứng dụng của chúng trong việc định lượng trực tiếp các thông số thực vật, chẳng hạn như chiều cao cây, chiều cao tán và trữ lượng gỗ. LiDAR là một công nghệ tương đối mới và tiên tiến giúp khắc phục hạn chế này do khả năng thực hiện phân tích không gian ba chiều (3D). LiDAR trực tiếp đo chiều cao và cấu trúc thẳng đứng của rừng bằng cách phát ra các xung laser và đo thời gian trả lại tín hiệu (Lefsky, M.A., *et al.*, 2007; Pang, Y., *et al.*, 2008; Simard, M., *et al.*, 2011). Dữ liệu LiDAR trên mặt đất, máy bay và vệ tinh có sẵn đã được áp dụng để ước tính AGB của rừng, bao gồm hai loại chính: LiDAR sóng nhỏ (LiDAR trở lại rời rạc) và LiDAR sóng lớn (LiDAR dạng sóng đầy đủ) (Ju, Y.L., *et al.*, 2022; Van Aardt, J.A.N., *et al.*, 2006). LiDAR dạng sóng nhỏ thường có đường kính nhỏ hơn 1m và kích thước điểm nhỏ hơn chiều rộng tán cây của lâm phần. Do đó, ứng dụng trong thực tế đòi hỏi phải bổ sung các điểm lấy mẫu ngang để bù đắp cho việc thiếu hướng thẳng đứng, từ đó hình thành dữ liệu lấy mẫu đơn (cây cá thể) hoàn chỉnh để ước tính các thông số đứng phù hợp với việc đảo ngược ước tính thông số rừng

ở quy mô cây cá thể và ô mẫu (Xing, Y.Q., *et al.*, 2014). LiDAR dạng sóng lớn, chẳng hạn như Hệ thống đo độ cao laser khoa học địa chất (GLAS) (trong không gian) của Cơ quan Hàng không và Vũ trụ Quốc gia Hoa Kỳ (NASA) (Wang, Y., *et al.*, 2020) và Cảm biến hình ảnh thực vật bằng laser (LVIS) (hàng không) (Sun, G., *et al.*, 2008), thường có đường kính điểm lớn hơn chiều rộng tán của cây đứng và phù hợp để ước tính nội suy các thông số rừng quy mô lớn (Saatchi, S., *et al.*, 2011).

Cảm biến quét laser mặt đất (TLS) cung cấp dữ liệu đám mây điểm rất dày đặc với khoảng cách milimet cho thân, cành và lá cây (Liang, X.L., *et al.*, 2016). Khối lượng cành và tán lá sau đó được ước tính dựa trên thông tin hình dạng được trang bị từ đám mây điểm (Hauglin, M., *et al.*, 2013; Stovall, A.E.L., *et al.*, 2017), do đó cung cấp một phương pháp không chặt hạ để ước tính AGB rừng và phát triển phương trình sinh học Hauglin, M., *et al.*, 2013; Kankare, V., *et al.*, 2013). Ngoài ước tính AGB ở cấp độ cây cá thể, AGB rừng ở cấp độ lâm phần cũng đã được ước tính thành công bằng cách sử dụng dữ liệu TLS (Liang, X.L., *et al.*, 2016, Astrup, R., *et al.*, 2014).

Máy quét laser hàng không (ALS) có thể đo chính xác chiều cao và mật độ tán rừng. Ngoài ra, bằng cách phân đoạn mô hình chiều cao tán (CHM - Canopy Height Model) hoặc dữ liệu đám mây điểm mật độ cao, dữ liệu ALS có thể được sử dụng để định lượng chiều cao cây, chiều rộng tán cây và thể tích tán cây, do đó, có thể được sử dụng để ước tính sinh khối của từng cây (Ebi, K.L., *et al.*, 2021; Popescu, S.C., 2007). Gần đây, ngày càng có nhiều dữ liệu LiDAR thu được từ UAV đã được sử dụng để ước tính AGB rừng ở quy mô cảnh quan (Messinger, M., *et al.*, 2016; Poley, L.G., McDermid, G.J., 2020). Hơn nữa, dữ liệu ALS mật độ điểm thấp thường phù hợp để ước tính AGB rừng ở cấp độ lâm phần hoặc trên các khu


vực rộng lớn và được kết hợp với dữ liệu sinh khối từ các ô mẫu để xây dựng các mô hình ước tính sinh khối (Price, B., *et al.*, 2017; Zhao, K.G., *et al.*, 2009). Các cuộc khảo sát sinh khối quy mô khu vực dựa trên LiDAR có thể yêu cầu lấy mẫu thực địa ít hơn so với các phương pháp viễn thám khác (Wang Xiaoyi, *et al.*, 2022).

Ưu điểm chính của LiDAR hàng không là khả năng thu thập dữ liệu trên các khu vực rộng lớn hoặc thậm chí trên toàn cầu. Tuy nhiên, độ chính xác của nó trong ước tính nội suy tham số rừng bị ảnh hưởng bởi các yếu tố địa hình (Pang, Y., *et al.*, 2007). Ngoài ra, LiDAR bị hạn chế bởi chi phí thu thập dữ liệu cao, vùng phủ sóng dữ liệu không liên tục và vùng phủ sóng nhỏ; Do đó, nghiên cứu về các thông số rừng của nó vẫn còn hạn chế ở các khu vực cụ thể và chưa được áp dụng rộng rãi để ước tính phân bố sinh khối liên tục và lập bản đồ các khu vực lớn hơn. Mặc dù vậy, sự sẵn có ngày càng tăng của dữ liệu LiDAR đã đi kèm với sự phát triển của các hệ thống LiDAR thế hệ tiếp theo, bao gồm

Hệ thống đo độ cao laser địa hình tiên tiến (ATLAS) và Điều tra động lực học hệ sinh thái toàn cầu (GEDII). GEDII là LiDAR dựa trên vệ tinh đầu tiên được thiết kế để nghiên cứu rừng (Stavros, E.N., *et al.*, 2017) và kết hợp với ATLAS vệ tinh ICESat-2 (Markus, T., *et al.*, 2017) có thể tạo điều kiện thuận lợi cho các ước tính AGB rừng quy mô lớn.

#### 2.2.4. Phối hợp dữ liệu viễn thám thụ động và chủ động

AGB rừng phụ thuộc vào bốn thông số: chiều cao cây, mật độ, DBH và chiều rộng tán cây. Tuy nhiên, việc đo DBH trực tiếp bằng cách sử dụng dữ liệu hàng không và vệ tinh là một thách thức. DBH là tham số có thể được sử dụng để ước tính ba tham số còn lại. Do đó, để tạo điều kiện cho các ước tính AGB rừng chính xác, việc hợp nhất dữ liệu viễn thám thụ động và chủ động đã được sử dụng. Các thông số đo đếm của rừng liên quan đến các nguồn dữ liệu viễn thám khác nhau được thể hiện trong Hình 3.



**Hình 3.** Dữ liệu ảnh viễn thám khác nhau trong ước tính AGB

Ước tính AGB rừng thông qua viễn thám quang học đa phân giải chủ yếu tập trung vào thông tin kết cấu ảnh được cung cấp bởi dữ liệu ảnh có độ phân giải cao được bổ sung cho ảnh có độ phân giải trung bình hoặc các chỉ số thực vật. Ước

tính AGB bằng cách kết hợp thông tin kết cấu ảnh và chỉ số thực vật có độ chính xác cao hơn so với sử dụng từng biến đơn lẻ hoặc chỉ sử dụng các band quang phổ (Bastin, J.F., *et al.*, 2014; Nichol, J.E., Sarker, M.L.R., 2011).



Sự kết hợp giữa viễn thám chủ động và thụ động để ước tính AGB rừng chủ yếu dựa vào dữ liệu sinh khối thu được từ các điểm lấy mẫu hiện trường hoặc LiDAR làm điểm chuẩn và dữ liệu viễn thám thụ động hoặc SAR làm các biến độc lập. Sự kết hợp giữa SAR và dữ liệu quang học bổ sung cho nhau, do đó cải thiện độ chính xác ước tính và giảm vấn đề bão hòa, đặc biệt với chi phí thấp trên phạm vi rộng (Laurin, G.V., *et al.*, 2017; Navarro, J.A., *et al.*, 2019).

Mặc dù viễn thám làm giảm đáng kể thời gian và chi phí ước tính AGB rừng, dữ liệu đo đếm hiện trường là không thể thiếu cho cả việc xây dựng mô hình và đánh giá kết quả ước tính AGB rừng. Ngoài ra, chi phí mua ảnh, phạm vi phủ sóng và sự khan hiếm của các cảm biến khác nhau, việc lựa chọn một cảm biến phù hợp với tính sẵn có của dữ liệu cụ thể, ngân sách dự án và các yêu cầu kỹ năng kỹ thuật để phân tích dữ liệu vẫn là một thách thức thực tế (Issa, S., *et al.*, 2020).

### 2.3. Phương pháp ước tính AGB

Với sự phát triển nhanh chóng và liên tục, công nghệ viễn thám đã dần thay thế phương pháp ước tính AGB rừng truyền thống. Các phương pháp ước tính viễn thám AGB của rừng chủ yếu được phân loại thành các mô hình thực nghiệm, vật lý, cơ học và toàn diện.

#### 2.3.1. Mô hình thực nghiệm

Mô hình thực nghiệm là cách tiếp cận phổ biến nhất để ước tính AGB rừng. Cụ thể, một mô hình thống kê được xây dựng giữa các biến từ dữ liệu viễn thám và các dữ liệu ô mẫu, từ đó mô hình được sử dụng để ước tính AGB cho các vùng có diện tích lớn hơn (Fremout, T., *et al.*, 2022; Lu, D.S., *et al.*, 2016; Luo, M., *et al.*, 2021). Các mô hình thực nghiệm được phân loại thành mô hình tham số hoặc phi tham số. Các mô hình tham số chủ yếu đề cập đến hồi quy tuyến tính (LR), hồi quy đa biến (MR) và các phương pháp hồi quy phi tuyến tính. Theo

đó, các phương trình và hàm tham số đóng vai trò là mô hình mô phỏng. Mặc dù các mô hình thực nghiệm rất đơn giản và dễ hiểu, tạo điều kiện cho việc hiểu và phân tích các phát hiện, độ chính xác ước tính của chúng thường không cao lắm (Li, C., *et al.*, 2019; Li, J.R., Mao, X.G., 2020; Safari, A., *et al.*, 2018; Tanase, M.A., 2014).

Mô hình MR có thể tăng cường ước tính AGB bằng cách tích hợp độ phản xạ bề mặt, VIs và các yếu tố sinh lý (Zheng, D.L., *et al.*, 2004). Theo Eckert (Eckert, S., 2012), các phép đo kết cấu có mối tương quan mạnh hơn với carbon và sinh khối so với các đặc tính quang phổ. Ngoài ra, phương trình hồi quy phi tuyến tính bậc hai cũng cho thấy mối quan hệ chặt chẽ giữa diện tích tán lá với trữ lượng carbon ở rừng nhiệt đới (Zaki, N.A.M., *et al.*, 2016). Mô hình biến tối ưu phụ thuộc vào khu vực nghiên cứu, điều này hạn chế khả năng áp dụng mặc dù nhiều mô hình MR đã được thiết lập để dự đoán AGB rừng (Dube, T., Mutanga, O., 2015; Xiao, J.F., *et al.*, 2019). MR giả định rằng các biến dữ liệu viễn thám ở các dải phổ khác nhau là không tương quan, điều này hiếm khi xảy ra trong viễn thám. Do đó, Lu và đồng tác giả (2012) đề xuất sử dụng hệ số tương quan và phân tích hồi quy từng bước để xác định các biến dữ liệu viễn thám có tương quan cao với sinh khối trong khi có tự tương quan yếu.

Các mô hình tham số được xây dựng dựa trên các giả định phân phối dữ liệu lý tưởng, sao cho phân phối dữ liệu tuân theo phân bố chuẩn. Tuy nhiên, sự tương tác giữa các biến thành phần viễn thám được sử dụng để ước tính AGB rừng rất phức tạp và việc phân phối dữ liệu rất khó đánh giá hoặc thiếu các đặc điểm phân biệt. Ngược lại, các mô hình phi tham số liên quan đến phân tích dữ liệu thống kê trực tiếp mà không dựa vào khái quát hóa toàn bộ phân phối mẫu. Các mô hình phi tham số, thường được áp dụng trong học máy, là các mô hình được sử dụng nhiều nhất hiện nay trong các

ước tính AGB rừng dựa trên viễn thám và chủ yếu bao gồm người láng giềng gần nhất (kNN) (Beaudoin, A., *et al.*, 2014), artificial neural networks (ANN) (Gao, Y.K., *et al.*, 2018), support vector machine (SVM) (Tang, J., *et al.*, 2022), random forest (RF) (Ou, G.L., *et al.*, 2019), gradient boosting (GB) (Li, Y.C., *et al.*, 2019) và maximum entropy (ME) (Ferreira, I.J.M., *et al.*, 2023). Phương pháp RF và ME đang ngày càng được áp dụng để lập bản đồ AGB trong các môi trường phức tạp vì chúng có thể tích hợp hiệu quả các biến với các phân phối thống kê khác nhau để cung cấp các mô hình ổn định và chính xác. Ngoài ra, các phương pháp Deep learning (DL) cũng cho thấy tiềm năng lớn trong lĩnh vực ước tính AGB rừng (Ghosh, S.M., Behera, M.D., 2021; Narine, L.L., *et al.*, 2019; Pascarella, A.E., *et al.*, 2023; Schreiber, L.V., *et al.*, 2022).

RF cải thiện độ chính xác dự đoán bằng cách xây dựng một "rừng" gồm nhiều cây quyết định phân loại thông qua một sơ đồ toàn diện, trong đó cả mẫu và biến được xử lý đồng thời thông qua phương pháp bootstrap và "thuật toán đóng gói" tương ứng (Li, Y.C., *et al.*, 2019; Breiman, L., 2001). Ngoài ra, RF đạt được phân đoạn tối ưu tại mỗi nút bằng cách sử dụng cây phân loại và hồi quy. Mặc dù các cây riêng lẻ có thể yếu, sự kết hợp của tất cả các cây làm mạnh mẽ hơn các thuật toán khác và không bị giới hạn bởi sự xuất hiện của việc "học" quá mức (Breiman, L., 2001).

Thuật toán ME là một phương pháp thống kê chung được sử dụng để dự đoán các giá trị từ các bộ dữ liệu mẫu không đầy đủ. Về cơ bản, nó ước tính hàm phân phối xác suất của một mục tiêu từ một số lượng mẫu hữu hạn. Thông tin mô tả hàm phân phối xác suất của mục tiêu được gọi là "tính năng", với ràng buộc rằng giá trị kỳ vọng của mỗi tính năng phải khớp với giá trị trung bình thực nghiệm của nó (giá trị trung bình thu được từ các điểm lấy mẫu). Đối với ước tính AGB rừng sử dụng dữ liệu viễn thám,

thông tin hạn chế về môi trường có thể được lấy từ thông tin quang phổ của dữ liệu hình ảnh viễn thám (ví dụ: MODIS, ALOS, SRTM, Landsat). Hơn nữa, mô hình ME có thể chứa nhiều thuộc tính và do đó rất phù hợp để lập bản đồ AGB rừng quy mô lớn (Saatchi, S., *et al.*, 2008).

### 2.3.2. Mô hình hóa vật lý

Sinh khối có thể được ước tính bằng mô hình vật lý thông qua nội suy từ thông tin viễn thám bằng cách sử dụng mối quan hệ giữa các đặc điểm thực vật hai chiều và sinh khối. Các mô hình vật lý được sử dụng để ước tính AGB rừng chủ yếu bao gồm truyền bức xạ và mô hình quang hình học. Sử dụng LiDAR và dữ liệu viễn thám quang học để ước tính AGB thông qua các thông số cấu trúc của rừng như độ che phủ thực vật, LAI và chiều cao cây cho thấy có sự cải thiện đáng kể độ chính xác trong ước tính AGB của rừng (Koetz, B., *et al.*, 2007). AGB cũng được ước tính thông qua dữ liệu độ che phủ của tán cây và chiều cao trung bình của tán được xác định từ nguồn dữ liệu phản xạ đa góc làm mô hình quang hình học (Chopping, M., *et al.*, 2008). Mặc dù mô hình vật lý có ý nghĩa vật lý rõ ràng và tính ổn định cũng như khả năng ứng dụng tốt, việc tính toán rất phức tạp và hiện chỉ áp dụng cho các ước tính AGB quy mô nhỏ (Lou, X.T., 2011).

### 2.3.3. Mô hình hóa theo thuyết cơ học

Mô hình cơ học (hoặc quá trình) thường được sử dụng để mô phỏng tăng trưởng sinh khối hàng năm (NPP) của rừng và dựa trên các nguyên tắc sinh lý và sinh thái thực vật. Các mô hình trong danh mục này ước tính năng suất của thảm thực vật bằng cách mô phỏng việc chuyển đổi năng lượng mặt trời thành năng lượng hóa học trong quá trình sinh trưởng của thảm thực vật, quang hợp và thoát hơi nước từ tán cây, mất nước từ thân cây và đất (Xu, X.L.; Cao, M.K., 2006). Các mô hình cơ học

phổ biến bao gồm các mô hình liên quan đến khí hậu, quá trình sinh lý-sinh thái (biophysical) và hiệu quả sử dụng ánh sáng (Lou, X.T., *et al.*, 2011; Smith, B., *et al.*, 2008). Các mô hình liên quan đến khí hậu ước tính NPP của các khu vực khác nhau dựa trên nhiệt độ, lượng mưa và độ ẩm đất trung bình hàng năm (Adams, B., *et al.*, 2004). Hơn nữa, mô hình quá trình sinh lý-sinh thái sử dụng thông tin, chẳng hạn như độ che phủ thực vật và độ ẩm của đất, được cung cấp bởi dữ liệu viễn thám để mô phỏng các yếu tố sinh thái và sinh lý liên quan đến môi trường và sự phát triển của thực vật, tương ứng, để tạo thành một mô hình lai giữa sinh hóa và sinh lý (Peng, S.L., *et al.*, 2000). Các mô hình sử dụng ánh sáng hiệu quả ước tính NPP của thảm thực vật bằng cách sử dụng mối quan hệ giữa NPP thực vật và bức xạ quang hợp được hấp thụ chủ động bởi thảm thực vật được chuyển đổi thành chất hữu cơ (Peng, S.L., *et al.*, 2000; Piao, S.L., 2001).

Trái ngược với các mô hình thực nghiệm, các mô hình cơ học nhấn mạnh việc mô phỏng và mô tả các quá trình khác nhau hoạt động trong hệ sinh thái; do đó, kết quả ước tính đáng tin cậy hơn. Tuy nhiên, các phương pháp tiếp cận cơ học rất phức tạp và đòi hỏi đầu vào của nhiều thông số, chẳng hạn như sinh lý và sinh thái thực vật, đất, khí tượng và bức xạ mặt trời, một số trong đó không có sẵn, do đó hạn chế khả năng ứng dụng của chúng (Xu, X.L.; Cao, M.K., 2006).

#### 2.2.4. Mô hình hóa toàn diện

Các mô hình toàn diện sử dụng các mô hình ước tính có ý nghĩa sinh thái kết hợp với dữ liệu viễn thám để ước tính AGB của rừng. Các mô hình này sử dụng sự kế thừa sinh thái làm cơ sở lý thuyết và cho phép mô phỏng động các thay đổi của thực vật rừng (Zhang, N.N., *et al.*, 2009), bao gồm các mô hình FAREAST, LANDIS/LANDIS-II, FVS và SORTIE-ND được sử dụng rộng rãi (Brown, M.L., *et al.*,

2018; Mladenoff, D.J., 2004; Wu, Z., *et al.*, 2020; Yan, X.D., Shugart, H.H., 2005). Những thay đổi AGB trong rừng chủ yếu được thúc đẩy bởi sự tích lũy và khai thác, nhưng biến đổi khí hậu cũng góp phần rất lớn vào sự thay đổi AGB của rừng. Nhìn chung, mô hình toàn diện là mô hình hợp lý, linh hoạt về cấu trúc, đa dạng về hình thức. Tuy nhiên, khi độ phân giải không gian của dữ liệu viễn thám thấp, thông tin viễn thám được trích xuất (chẳng hạn như ánh sáng, độ ẩm, chất dinh dưỡng của đất và nhiệt độ) sẽ không thể phản ánh quy luật tích lũy sinh thái của rừng. Các mô hình toàn diện yêu cầu đầu vào các thông số của nhiều loài cây. Do đó, độ chính xác của mô hình không chỉ phụ thuộc vào dữ liệu viễn thám mà còn phụ thuộc vào độ chính xác của các tham số này. Điều này làm cho việc ước tính AGB rừng trở nên khó khăn ở những khu vực không có thông tin toàn diện về đặc điểm sinh học của các loài cây (Lou, X.T., *et al.*, 2011).

### III. THÁCH THỨC KHI SỬ DỤNG ẢNH VIỄN THÁM ĐỂ ƯỚC TÍNH AGB

Cho đến nay, các ước tính AGB rừng toàn cầu ngày càng đáng tin cậy, các ước tính này đạt được bằng cách sử dụng các dữ liệu và kỹ thuật viễn thám khác nhau (Badreldin, N., Sanchez-Azofeifa, A., 2015; Huang, X.D., *et al.*, 2018; Li, C., *et al.*, 2019; Waring, R.H., *et al.*, 2010; Zhang, G., *et al.*, 2014). Mặc dù vậy, tính chính xác của các ước tính vẫn còn nhiều thách thức để nghiên cứu hiệu quả chu trình carbon toàn cầu và biến đổi khí hậu (Huang, H.B., *et al.*, 2019; Xiao, J.F., *et al.*, 2019). Độ chính xác tính toán AGB rừng bị ảnh hưởng bởi nhiều sai số và sự không chắc chắn có thể xảy ra dẫn đến việc đánh giá sai AGB của rừng (Chen, Q., *et al.*, 2015; Montesano, P.M., *et al.*, 2015). Nhìn chung, các yếu tố nguyên nhân của các sai số và sự không chắc chắn trong ước tính AGB rừng dựa trên viễn thám bao gồm ảnh viễn thám, dữ liệu khảo sát ô mẫu, cấu trúc đứng và

mô hình thống kê (Knott, J.A., *et al.*, 2023; Lister, A.J., *et al.*, 2020).

Lỗi dữ liệu viễn thám chủ yếu liên quan đến các yếu tố như sự phức tạp của ảnh (ví dụ: phản xạ bề mặt hình ảnh, các chỉ số VIs, SIF và LAI), các yếu tố môi trường (ví dụ: khí quyển và độ ẩm), suy thoái cảm biến, kỹ thuật xử lý ảnh bị lỗi và thời gian thu nhận ảnh bị lỗi với các vị trí ô mẫu (Fang, H.L., *et al.*, 2012; Van Leeuwen, W.J.D., *et al.*, 2006). Sai số trong dữ liệu khảo sát ô mẫu bao gồm sai số đo cây cá thể (ví dụ: DBH và chiều cao), mm hình sinh học ước tính sinh khối ô mẫu và vị trí ô mẫu khớp với dữ liệu ảnh viễn thám (Knott, J.A., *et al.*, 2023). Ngoài ra, các nguồn dữ liệu kiểm kê rừng khác nhau cũng có thể gây ra sai số trong ước tính AGB (Knott, J.A., *et al.*, 2023). Các nguồn dữ liệu khảo sát thực địa khác nhau sử dụng các phương pháp hoặc phương pháp đo lường không nhất quán, đây là một trong những nguồn sai số trong các ước tính AGB cuối cùng. Sai số cấu trúc lâm phần chủ yếu đề cập đến việc thiếu thông tin, chẳng hạn như độ che phủ thực vật, tuổi lâm phần, chiều cao cây và cấu trúc đường kính cây để mô tả đầy đủ trạng thái lâm phần trên ảnh viễn thám. Cuối cùng, sai số của các mô hình thống kê chủ yếu là do mô hình không liên kết chính xác thông tin lâm phần với các thành phần ảnh viễn thám, dẫn đến các vấn đề sai số trong ước tính. Các sai số như vậy không bao gồm dữ liệu viễn thám (ví dụ: dữ liệu khí tượng), sai số trong cấu trúc mô hình (ví dụ: các quy trình và giả định cơ bản không đầy đủ hoặc thiếu sót) và sai số trong các tham số mô hình (ví dụ: các tham số không đầy đủ hoặc được xác định kém do thiếu thông tin) (Xiao, J.F., *et al.*, 2019).

Nhiều nghiên cứu đã đánh giá sai số của ước tính AGB từ ảnh viễn thám. Sai số tính toán của carbon rừng trên mặt đất (AGFC) do lỗi vị trí lô mẫu được đánh giá và dự đoán giảm khi tăng nhiều loạn khoảng cách vị trí ô mẫu. Ngoài ra, người ta phát hiện ra rằng sự gia tăng

độ phân giải không gian làm giảm ảnh hưởng của lỗi vị trí ô mẫu đối với độ chính xác của bản đồ so với những dữ liệu không được nâng cấp độ phân giải không gian (Zhang, M.Z., *et al.*, 2013). Ngoài ra, loại cảm biến là yếu tố quan trọng nhất ảnh hưởng đến độ chính xác của ước tính AGB (LiDAR vượt trội hơn ảnh đa phổ) và việc sử dụng dữ liệu đa phổ kết hợp với LiDAR không cải thiện độ chính xác của ước tính (Fassnacht, F.E., *et al.*, 2014). Bên cạnh đó, lỗi lấy mẫu có ảnh hưởng lớn tới việc ước tính AGB và được đánh giá là có sai số cao hơn so với sai số của các mô hình ước tính sinh khối (Fu, Y., *et al.*, 2014). Ảnh hưởng của các mô hình đối với ước tính AGB là đáng kể, tuy nhiên khả năng của các mô hình khác nhau để mô tả các khoảng AGB là rất khác nhau. Do đó, lựa chọn mô hình là một cân nhắc quan trọng để đảm bảo ước tính AGB chính xác.

Cấu trúc lâm phần bao gồm cả cấu trúc ngang và đứng, tuy vậy cấu trúc của hệ sinh thái rừng tương đối phức tạp. Ước tính sinh khối rừng dựa trên ảnh viễn thám được thực hiện bằng cách sử dụng thông tin cấu trúc lâm phần, do đó, đây là một yếu tố quan trọng ảnh hưởng đến các lỗi ước tính sinh khối rừng và sai số. Các loại thảm thực vật khác nhau được thể hiện trong các ảnh viễn thám là có thông tin quang phổ khác nhau và trong trường hợp này, rừng cần được phân loại thành các loại để cải thiện độ chính xác của ước tính AGB rừng dựa trên viễn thám (Nguyen Thi Thanh Huong, 2011; Singh, M., *et al.*, 2014). Tuy nhiên, lâm phần không chỉ chứa các lớp cây, mà còn các lớp cây bụi và thảo mộc. Ở các lâm phần kém phát triển, dữ liệu viễn thám cũng chứa thông tin về cây bụi và thảo mộc ở một mức độ nhất định, ảnh hưởng đến độ chính xác ước tính AGB của rừng.

Lập bản đồ AGB rừng dựa trên dữ liệu và phương pháp viễn thám khác nhau có thể thay đổi đáng kể. Một số bản đồ AGB rừng dựa trên dữ liệu đo đạc trên mặt đất và dữ liệu viễn thám.

Một số bản đồ kết hợp các phép đo trên mặt đất, viễn thám quang học, LiDAR hàng không và dữ liệu SAR để ước tính AGB rừng. Các mô hình cụ thể cho từng loại rừng và vùng sinh thái cũng được phát triển để ước tính và lập bản đồ AGB với độ chính xác cao hơn. Điều cần thiết là phải định lượng và giảm sự sai số trong viễn thám của các sản phẩm AGB của rừng để đánh giá lưu trữ carbon trong khu vực và toàn cầu để cung cấp thông tin cho việc quản lý và hoạch định chính sách khí hậu.

Định lượng và giảm sai số trong ước tính AGB của rừng vẫn là một thách thức đáng kể. Xem xét các nguồn sai số khác nhau, điều quan trọng là phải định lượng toàn diện sai số của các ước tính này để giảm hoặc loại bỏ ảnh hưởng của nó đối với độ chính xác ước tính AGB của rừng. Điều này cung cấp một hướng quan trọng cho nghiên cứu trong tương lai về ước tính AGB của rừng. Hơn nữa, độ chính xác của các ước tính AGB của rừng có thể được cải thiện bằng cách sử dụng độ phân giải cao và dữ liệu viễn thám theo phương pháp tốt hơn trong khi xem xét các tính kế thừa, tác động và quá trình hệ sinh thái.

#### IV. TRIỂN VỌNG SỬ DỤNG ẢNH VIỄN THÁM ĐỂ ƯỚC TÍNH AGB

Nhu cầu cấp thiết đối với xã hội để làm sáng tỏ chu trình carbon của Trái đất đã thúc đẩy các nghiên cứu gần đây tập trung vào nhiều yếu tố làm thay đổi thành phần CO<sub>2</sub> trong khí quyển. Tuy nhiên, vẫn còn nhiều khoảng trống trong kiến thức của chúng ta về các quá trình này. Hơn nữa, thảm thực vật trên cạn chứa trữ lượng carbon tương đương với tổng lượng CO<sub>2</sub> trong khí quyển và đóng một vai trò quan trọng trong chu trình carbon của Trái đất.

Vệ tinh quan sát trái đất và các nguồn viễn thám khác là phương tiện duy nhất để có được dữ liệu độ phân giải không gian và thời gian cao trên quy mô toàn cầu. Viễn thám quang học, siêu cao tần và LiDAR sẽ vẫn được sử

dụng để ước tính AGB. Việc sử dụng viễn thám kết hợp với dữ liệu điều tra thực địa cho phép đánh giá những thay đổi AGB của rừng trên toàn cầu. Viễn thám quang học, với độ phân giải không gian và thời gian cao, và vùng phủ sóng không gian và thời gian liên tục, vẫn là một nguồn dữ liệu quan trọng để ước tính AGB. Ví dụ: dữ liệu Harmonized Landsat và Sentinel-2 (HLS) được tạo ra bằng cách kết hợp dữ liệu Landsat 8 và Sentinel-2 có thể cung cấp dữ liệu với khoảng thời gian lên đến 5 ngày và độ phân giải không gian là 30 m. Điều này nâng cao khả năng của chúng ta để ước tính AGB một cách nhất quán từ quy mô địa phương đến toàn cầu bằng cách cho phép chúng ta ước tính AGB ở độ phân giải 30 m bằng cách sử dụng chuỗi thời gian lý tưởng (Claverie, M., *et al.*, 2018). Tuy nhiên, một lượng lớn dữ liệu AGB được đo chính xác cần thiết cho các mô hình thực nghiệm dựa trên dữ liệu viễn thám quang học cũng như cho các mô hình ước tính AGB được xây dựng bằng thuật toán học máy vẫn còn thiếu ở quy mô khu vực và toàn cầu. May mắn thay, dữ liệu viễn thám thụ động có độ phân giải cao (ví dụ: QuickBird, IKONOS và UAV) và dữ liệu LiDAR có thể tạo ra một số lượng lớn các mẫu AGB để đào tạo các mô hình ước tính AGB. Hơn nữa, sự hợp nhất của dữ liệu viễn thám đa nguồn (tức là viễn thám quang học thụ động với LiDAR và dữ liệu viễn thám siêu cao tần) dự kiến sẽ khắc phục một phần vấn đề bão hòa trong ước tính sinh khối viễn thám tối ưu thụ động (Xiao, J.F., *et al.*, 2019).

Để đánh giá AGB rừng và theo dõi sự thay đổi rừng, dữ liệu từ SAR dựa trên máy bay và vệ tinh đã trở thành nguồn tài nguyên quan trọng trong ba thập kỷ qua. Tuy vậy, ba hạn chế của ước tính AGB rừng từ SAR hiện đang tồn tại ở quy mô khu vực: vấn đề bão hòa, hiệu ứng địa hình và sự không phù hợp giữa đơn vị cơ sở của dữ liệu SAR và diện tích ô mẫu thực địa. Vấn đề bão hòa liên quan đến ước tính AGB sử

dụng cường độ tán xạ ngược radar của một khu rừng có cấu trúc không gian phức tạp có thể được cải thiện đáng kể bằng cách khai thác thông tin cấu trúc không gian thu được từ các dữ liệu khác, chẳng hạn như dữ liệu InSAR hoặc hình ảnh âm thanh nổi quang học (Sun, G.Q., *et al.*, 2011). Ngoài ra, NASA cung cấp dữ liệu InSAR băng tần L toàn cầu, cũng như dữ liệu PolInSAR hoặc TomoSAR, sẽ sớm được cung cấp rộng rãi miễn phí. Đặc biệt, dữ liệu băng tần L và P có thể đảo ngược trực tiếp cấu trúc 3D của tán rừng mà không cần mô hình số địa hình (DTM - Digital Terrain Model), cung cấp một giải pháp đầy hứa hẹn để lập bản đồ sinh khối toàn cầu và giám sát tác động vào rừng. Trong thực tế, các hiệu ứng địa hình có thể được khắc phục bằng cách phát triển mối quan hệ giữa hệ số tán xạ ngược radar và góc tới của các loại bề mặt chính. Điều này liên quan đến việc tính toán góc tới của từng yếu tố hình ảnh dựa trên góc tới radar, độ dốc và hướng dốc của địa hình. Hơn nữa, các hiệu ứng địa hình có thể sẽ được khắc phục bằng cách phát triển các mô hình lý thuyết và mô phỏng (Ni, W.J., *et al.*, 2018), trong khi vấn đề không phù hợp quy mô có thể được khắc phục bằng cách kết hợp SAR với các loại dữ liệu khác như LiDAR (Qi, W.L.; Dubayah, R.O., 2016).

Trong vài thập kỷ qua, những tiến bộ công nghệ dựa trên LiDAR đã cho phép thu thập dữ liệu địa hình chính xác và các thông số cấu trúc rừng. Hơn nữa, vì nhiều hệ thống LiDAR dựa trên vệ tinh được sử dụng để tạo điều kiện thuận lợi cho nghiên cứu chu trình carbon toàn cầu, các mô hình ước tính AGB dựa trên dữ liệu LiDAR sẽ đòi hỏi phải xem xét nhiều hơn để cho phép lập bản đồ sinh khối khu vực và toàn cầu.

Việc tích hợp dữ liệu viễn thám quang học, SAR và LiDAR trong không gian dự kiến sẽ cung cấp các ước tính AGB liền mạch và chính xác trên quy mô toàn cầu. Cụ thể, ở quy mô địa phương và khu vực, các kỹ thuật thu nhận

trong không khí, chẳng hạn như quang phổ hình ảnh, LiDAR, SAR và quang trắc quang học, cung cấp dữ liệu có độ phân giải không gian cao. Ngược lại, các cảm biến trong không gian, bao gồm các cảm biến trên Landsat, MODIS, SRTM, ALOS/PALSAR, ICESAT/GLAS và SAR băng tần L do ALOS-2 mang theo, cung cấp các quan sát ở quy mô liên lục địa và toàn cầu.

Rõ ràng, nhiều phương pháp ước tính AGB rừng tồn tại dựa trên dữ liệu viễn thám. Việc lựa chọn một phương pháp thích hợp phụ thuộc vào phạm vi của nghiên cứu/dự án cụ thể và tính khả dụng của các loại dữ liệu khác nhau. Mặc dù các thuật toán được thiết lập đã đạt được một số kết quả, cải thiện độ chính xác dự đoán và giảm sai số khi đối mặt với các điều kiện phức tạp vẫn là một hướng chính cho nghiên cứu trong tương lai. Ngoài ra, việc sử dụng các mô hình MR để ước tính sinh khối địa phương và khu vực vẫn còn tương đối phổ biến; tuy nhiên, các phương pháp tiếp cận phi tham số hoặc học máy có lợi thế lớn hơn cho các dự án quy mô khu vực và toàn cầu. Ngoài ra, cấu trúc tán, loài cây và các yếu tố môi trường khác là những cân nhắc quan trọng để phát triển các thuật toán và mô hình ước tính sinh khối, và sự can thiệp của các yếu tố này nên được giảm để cải thiện độ chính xác ước tính sinh khối.

## V. KẾT LUẬN

Trong bối cảnh biến đổi khí hậu toàn cầu, ước tính AGB của rừng cung cấp cơ sở lý thuyết để nghiên cứu chu trình carbon; tuy nhiên ước tính AGB nhanh chóng, chính xác vẫn còn nhiều thách thức trong nghiên cứu lâm nghiệp. Viễn thám là một phương pháp ước tính sinh khối tiên tiến cho phép ước tính AGB của rừng ở các quy mô khác nhau. Hiện tại, dữ liệu viễn thám từ các nền tảng/cảm biến khác nhau được áp dụng rộng rãi để ước tính AGB rừng, bao gồm quang học thụ động, siêu cao tần và viễn thám LiDAR, dẫn đến các phương pháp ước

tính AGB khác nhau được đề xuất, bao gồm các mô hình thực nghiệm, vật lý, cơ học và toàn diện. Các thông số liên quan đến AGB rừng, chẳng hạn như độ phản xạ bề mặt, VIs, LAI, độ che phủ, chiều cao cây và chiều cao tán cây, được sử dụng để phát triển các mô hình ước tính AGB của rừng. Tuy nhiên, những hạn chế của các nguồn dữ liệu viễn thám khác nhau và các phương pháp ước tính AGB rừng vẫn là một thách thức lớn trong nghiên cứu chu trình carbon. Do đó, ước tính AGB rừng đáng tin cậy đòi hỏi phải giảm hoặc loại bỏ các nguồn gây sai số.

Kết hợp dữ liệu viễn thám từ nhiều nguồn là chiến lược hứa hẹn nhất để ước tính AGB. Theo đó, VIs, thông tin quang phổ và kết cấu được trích xuất từ dữ liệu viễn thám quang học

và kết hợp với dữ liệu chiều cao cây được chiết xuất từ SAR/LiDAR, DHB và chiều cao tán để ước tính AGB rừng, dự kiến sẽ khắc phục một phần vấn đề bão hòa. Các phương pháp ước tính AGB rừng nên được lựa chọn theo các điều kiện cụ thể của khu vực nghiên cứu. Cho đến nay, các mô hình MR vẫn là một cách tiếp cận tương đối phổ biến để ước tính sinh khối địa phương và khu vực. Tuy nhiên, các phương pháp tiếp cận phi tham số hoặc học máy cung cấp thêm lợi thế cho các dự án quy mô khu vực và toàn cầu. Nhìn chung, dữ liệu viễn thám quang học, SAR và LiDAR hàng không vẫn hữu ích cho ước tính AGB, trong khi việc tích hợp dữ liệu đa nguồn dự kiến sẽ cung cấp các ước tính AGB liên mạch và chính xác cao trên quy mô toàn cầu.

## TÀI LIỆU THAM KHẢO

1. Abbas, S.; Wong, M.S.; Wu, J.; Shahzad, N.; Irteza, S.M., 2020. Approaches of Satellite Remote Sensing for the Assessment of Above-Ground Biomass across Tropical Forests: Pan-tropical to National Scales. *Remote Sens.* 2020, 12, 3351.
2. Adams, B.; White, A.; Lenton, T.M., 2004. An analysis of some diverse approaches to modelling terrestrial net primary productivity. *Ecol. Model* 2004, 177, 353 - 391.
3. Asner, G.P.; Mascaro, J., 2014. Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric. *Remote Sens. Environ.* 2014, 140, 614 - 624.
4. Astrup, R.; Ducey, M.J.; Granhus, A.; Ritter, T.; von Lupke, N., 2014. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. *Can. J. For. Res.* 2014, 44, 666 - 676.
5. Baccini, A.; Goetz, S.J.; Walker, W.S.; Laporte, N.T.; Sun, M.; Sulla-Menashe, D.; Hackler, J.; Beck, P.S.A.; Dubayah, R.; Friedl, M.A., 2012. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nat. Clim. Change* 2012, 2, 182-185.
6. Baccini, A.; Walker, W.; Carvalho, L.; Farina, M.; Sulla-Menashe, D.; Houghton, R.A., 2017. Tropical forests are a net carbon source based on aboveground measurements of gain and loss. *Science* 2017, 358, 230 - 233.
7. Badreldin, N.; Sanchez-Azofeifa, A., 2015. Estimating Forest Biomass Dynamics by Integrating Multi-Temporal Landsat Satellite Images with Ground and Airborne LiDAR Data in the Coal Valley Mine, Alberta, Canada. *Remote Sens.* 2015, 7, 2832-2849.
8. Bannari, A.; Morin, D.; Bonn, F.; Huete, A., 1995. A review of vegetation indices. *Remote Sens. Rev.* 1995, 13, 95 - 120.
9. Bao Huy, Nguyen Quy Truong, Nguyen Quy Khiem, Krishna P. Poudel, Hailemariam Temesgen, 2022. Deep learning models for improved reliability of tree aboveground biomass prediction in the tropical evergreen broadleaf forests. *Forest Ecology and Management*, 2022, 508, 120031.
10. Bastin, J.F.; Barbier, N.; Coutron, P.; Adams, B.; Shapiro, A.; Bogaert, J.; De Canniere, C., 2014. Aboveground biomass mapping of African forest mosaics using canopy texture analysis: Toward a regional approach. *Ecol. Appl.* 2014, 24, 1984 - 2001.

11. Beaudoin, A.; Bernier, P.Y.; Guindon, L.; Villemaire, P.; Guo, X.J.; Stinson, G.; Bergeron, T.; Magnussen, S.; Hall, R.J., 2014. Mapping attributes of Canada's forests at moderate resolution through kNN and MODIS imagery. *Can. J. For. Res.* 2014, 44, 521 - 532.
12. Bellard, C.; Bertelsmeier, C.; Leadley, P.; Thuiller, W.; Courchamp, F., 2012. Impacts of climate change on the future of biodiversity. *Ecol. Lett.* 2012, 15, 365 - 377.
13. Blackard, J.A.; Finco, M.V.; Helmer, E.H.; Holden, G.R.; Hoppus, M.L.; Jacobs, D.M.; Lister, A.J.; Moisen, G.G.; Nelson, M.D.; Riemann, R., 2008. Mapping US forest biomass using nationwide forest inventory data and moderate resolution information. *Remote Sens. Environ.* 2008, 112, 1658 - 1677.
14. Bouvet, A.; Mermoz, S.; Toan, T.L.; Villard, L.; Mathieu, R.; Naidoo, L.; Asner, G.P., 2018. An above-ground biomass map of African savannahs and woodlands at 25 m resolution derived from ALOS PALSAR. *Remote Sens. Environ.* 2018, 206, 156 - 173.
15. Bouvier, M.; Durrieu, S.; Fournier, R.A.; Renaud, J.P., 2015. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sens. Environ.* 2015, 156, 322-334.
16. Breiman, L., 2001. Random forests. *Mach. Learn.* 2001, 45, 5 - 32.
17. Brown, M.L.; Canham, C.D.; Murphy, L.; Donovan, T.M., 2018. Timber harvest as the predominant disturbance regime in northeastern US forests: Effects of harvest intensification. *Ecosphere* 2018, 9, e02062.
18. Brown, S.; Sathaye, J.; Cannell, M.; Kauppi, P.E., 1996. Mitigation of carbon emissions to the atmosphere by forest management. *Commonw. For. Rev.* 1996, 75, 80 - 91.
19. Cartus, O.; Santoro, M.; Kellndorfer, J., 2012. Mapping forest aboveground biomass in the Northeastern United States with ALOS PALSAR dual-polarization L-band. *Remote Sens. Environ.* 2012, 124, 466 - 478.
20. Chang, F.C.; Ko, C.H.; Yang, P.Y.; Chen, K.S.; Chang, K.H., 2017. Carbon sequestration and substitution potential of subtropical mountain Sugi plantation forests in central Taiwan. *J. Clean. Prod.* 2017, 167, 1099 - 1105.
21. Chave, J.; Rejou-Mechain, M.; Burquez, A.; Chidumayo, E.; Colgan, M.S.; Delitti, W.B.; Duque, A.; Eid, T.; Fearnside, P.M.; Goodman, R.C., 2014. Improved allometric models to estimate the aboveground biomass of tropical trees. *Glob. Change Biol.* 2014, 20, 3177 - 3190.
22. Chen, J.M., 1996. Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. *Can. J. Remote Sens.* 1996, 22, 229 - 242.
23. Chen, Q.; Laurin, G.V.; Valentini, R., 2015. Uncertainty of remotely sensed aboveground biomass over an African tropical forest: Propagating errors from trees to plots to pixels. *Remote Sens. Environ.* 2015, 160, 134 - 143.
24. Chen, R.X., 1999. Development of Forest Biomass Estimation Using SAR Data. *World For. Res.* 1999, 12, 18 - 23.
25. Chopping, M.; Moisen, G.G.; Su, L.H.; Laliberte, A.; Rango, A.; Martonchik, J.V.; Peters, D.P.C., 2008. Large area mapping of southwestern forest crown cover, canopy height, and biomass using the NASA Multiangle Imaging Spectro-Radiometer. *Remote Sens. Environ.* 2008, 112, 2051 - 2063.
26. Chopping, M.; Schaaf, C.B.; Zhao, F.; Wang, Z.S.; Nolin, A.W.; Moisen, G.G.; Martonchik, J.V.; Bull, M., 2011. Forest structure and aboveground biomass in the Southwestern United States from MODIS and MISR. *Remote Sens. Environ.* 2011, 115, 2943 - 2953.
27. Chopping, M.; Wang, Z.S.; Schaaf, C.; Bull, M.A.; Duchesne, R.R., 2022. Forest aboveground biomass in the southwestern United States from a MISR multi-angle index, 2000 - 2015. *Remote Sens. Environ.* 2022, 275, 112964.
28. Claverie, M.; Ju, J.; Masek, J.G.; Dungan, J.L.; Vermote, E.F.; Roger, J.C.; Skakun, S.V.; Justice, C., 2018. The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sens. Environ.* 2018, 219, 145 - 161.
29. Dillabaugh, K.A.; King, D.J., 2008. Riparian marshland composition and biomass mapping using Ikonos imagery. *Can. J. Remote Sens.* 2008, 34, 143 - 158.
30. Dube, T.; Mutanga, O., 2015. Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas. *ISPRS J. Photogramm.* 2015, 108, 12-32.



31. Durante, P.; Martín-Alcón, S.; Gil-Tena, A.; Algeet, N.; Tomé, J.L.; Recuero, L.; Palacios-Orueta, A.; Oyonarte, C., 2019. Improving Aboveground Forest Biomass Maps: From High-Resolution to National Scale. *Remote Sens.* 2019, 11, 795.
32. Ebi, K.L.; Vanos, J.; Baldwin, J.W.; Bell, J.E.; Hondula, D.M.; Errett, N.A.; Hayes, K.; Reid, C.E.; Saha, S.; Spector, J., 2021. Extreme Weather and Climate Change: Population Health and Health System Implications. In *Annual Review of Public Health*; Fielding, J.E., Ed.; Annual Review of Public Health: San Mateo, CA, USA, 2021; Volume 42, pp. 293 - 315.
33. Eckert, S., 2012. Improved Forest Biomass and Carbon Estimations Using Texture Measures from WorldView-2 Satellite Data. *Remote Sens.* 2012, 4, 810 - 829.
34. Fang, H.L.; Wei, S.S.; Jiang, C.Y.; Scipal, K., 2012. Theoretical uncertainty analysis of global MODIS, CYCLOPES, and GLOBCARBON LAI products using a triple collocation method. *Remote Sens. Environ.* 2012, 124, 610 - 621.
35. Fang, J.Y.; Brown, S.; Tang, Y.H.; Nabuurs, G.J.; Wang, X.P.; Shen, H.H., 2006. Overestimated biomass carbon pools of the northern mid- and high latitude forests. *Clim. Change* 2006, 74, 355 - 368.
36. Fang, J.Y.; Zhu, J.X.; Li, P.; Ji, C.J.; Zhu, J.L.; Jiang, L.; Chen, G.P.; Cai, Q.; Su, H.J.; Feng, Y.H., 2021. *Carbon Budgets of Forest Ecosystems in China*; Science Press: Beijing, China, 2021.
37. Fassnacht, F.E.; Hartig, F.; Latifi, H.; Berger, C.; Hernandez, J.; Corvalan, P.; Koch, B., 2014. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sens. Environ.* 2014, 154, 102-114.
38. Fatehi, P.; Damm, A.; Schaepman, M.E.; Kneubuhler, M., 2015. Estimation of Alpine Forest Structural Variables from Imaging Spectrometer Data. *Remote Sens.* 2015, 7, 16315 - 16338.
39. Ferreira, I.J.M.; Campanharo, W.A.; Fonseca, M.G.; Escada, M.I.S.; Nascimento, M.T.; Villela, D.M.; Brancalion, P.; Magnago, L.F.S.; Anderson, L.O.; Nagy, L., 2023. Potential aboveground biomass increase in Brazilian Atlantic Forest fragments with climate change. *Glob. Change Biol.* 2023, 29, 3098 - 3113.
40. Fremout, T.; Vinatea, J.C.D.; Thomas, E.; Huaman-Zambrano, W.; Salazar-Villegas, M.; de la Fuente, D.L.; Bernardino, P.N.; Atkinson, R.; Csaplovics, E.; Muys, B., 2022. Site-specific scaling of remote sensing-based estimates of woody cover and aboveground biomass for mapping long-term tropical dry forest degradation status. *Remote Sens. Environ.* 2022, 276, 113040.
41. Frumkin, H.; Haines, A., 2019. Global Environmental Change and Noncommunicable Disease Risks. In *Annual Review of Public Health*; Fielding, J.E., Ed.; Annual Review of Public Health: San Mateo, CA, USA, 2019; Volume 40, pp. 261 - 282.
42. Fu, Y.; Lei, Y.C.; Zeng, W.S., 2014. Uncertainty Assessment in Regional-Scale Above Ground Biomass Estimation of Chinese Fir. *Sci. Silvae Sinicae* 2014, 50, 79 - 86.
43. Gao, X.; Huete, A.R.; Ni, W.; Miura, T., 2000. Optical-Biophysical Relationships of Vegetation Spectra without Background Contamination. *Remote Sens. Environ.* 2000, 74, 609 - 620.
44. Gao, Y.K.; Lu, D.S.; Li, G.Y.; Wang, G.X.; Chen, Q.; Liu, L.J.; Li, D.Q., 2018. Comparative Analysis of Modeling Algorithms for Forest Aboveground Biomass Estimation in a Subtropical Region. *Remote Sens.* 2018, 10, 627.
45. Garrouste, E.L.; Hansen, A.J.; Lawrence, R.L., 2016. Using NDVI and EVI to Map Spatiotemporal Variation in the Biomass and Quality of Forage for Migratory Elk in the Greater Yellowstone Ecosystem. *Remote Sens.* 2016, 8, 404.
46. Ghasemi, N.; Sahebi, M.; Mohammadzadeh, A., 2011. A review on biomass estimation methods using synthetic aperture radar data. *Int. J. Geomat. Geosci.* 2011, 1, 776 - 778.
47. Ghosh, S.M.; Behera, M.D., 2021. Aboveground biomass estimates of tropical mangrove forest using Sentinel-1 SAR coherence data. The superiority of deep learning over a semi-empirical model. *Comput. Geosci.* 2021, 150, 104737.
48. Hasegawa, T.; Fujimori, S.; Havlik, P.; Valin, H.; Bodirsky, B.L.; Doelman, J.C.; Fellmann, T.; Kyle, P.; Koopman, J.F.L.; Lotze-Campen, H., 2018. Risk of increased food insecurity under stringent global climate change mitigation policy. *Nat. Clim. Change* 2018, 8, 699 - 703.

49. Hauglin, M.; Astrup, R.; Gobakken, T.; Naeset, E., 2013. Estimating single-tree branch biomass of Norway spruce with terrestrial laser scanning using voxel-based and crown dimension features. *Scand. J. Forest. Res.* 2013, 28, 456 - 469.
50. Herbert, C.; Fried, J.S.; Butsic, V., 2023. Validation of Forest Vegetation Simulator Model Finds Overprediction of Carbon Growth in California. *Forests* 2023, 14, 604.
51. Hirata, Y.; Tabuchi, R.; Patanaponpaiboon, P.; Pongpam, S.; Yoneda, R.; Fujioka, Y., 2014. Estimation of aboveground biomass in mangrove forests using high-resolution satellite data. *J. For. Res.* 2014, 19, 34 - 41.
52. Houghton, R.A.; Hall, F.; Goetz, S.J., 2009. Importance of biomass in the global carbon cycle. *J. Geophys. Res.-Biogeosci.* 2009, 114, G00E03.
53. Huang, H.B.; Liu, C.X.; Wang, X.Y.; Zhou, X.L.; Gong, P., 2019. Integration of multi-resource remotely sensed data and allometric models for forest aboveground biomass estimation in China. *Remote Sens. Environ.* 2019, 221, 225 - 234.
54. Huang, X.D.; Ziniti, B.; Torbick, N.; Ducey, M.J., 2018. Assessment of Forest above Ground Biomass Estimation Using Multi-Temporal C-band Sentinel-1 and Polarimetric L-band PALSAR-2 Data. *Remote Sens.* 2018, 10, 1424.
55. Huang, Y.P.; Chen, J.S., 2013. Advances in the estimation of forest biomass based on SAR data. *Remote Sens. Nat. Resour.* 2013, 25, 7 - 13.
56. Huete, A.R., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sens. Environ.* 25, 295 - 309.
57. Hurtt, G.C.; Fisk, J.; Thomas, R.Q.; Dubayah, R.; Moorcroft, P.R.; Shugart, H.H., 2010. Linking models and data on vegetation structure. *J. Geophys. Res.-Biogeosci.* 2010, 115, G00E10.
58. Issa, S.; Dahy, B.; Ksikisi, T.; Saleous, N., 2020. A Review of Terrestrial Carbon Assessment Methods Using Geo-Spatial Technologies with Emphasis on Arid Lands. *Remote Sens.* 2020, 12, 2008.
59. Ju, Y.L.; Ji, Y.J.; Huang, J.M.; Zhang, W.F., 2022. Inversion of forest aboveground biomass using combination of LiDAR and multispectral data. *J. Nanjing For. Univ.* 2022, 46, 58 - 68.
60. Kang, S.C.; Zhang, Q.G.; Qian, Y.; Ji, Z.M.; Li, C.L.; Cong, Z.Y.; Zhang, Y.L.; Guo, J.M.; Du, W.T.; Huang, J., 2019. Linking atmospheric pollution to cryospheric change in the Third Pole region: Current progress and future prospects. *Natl. Sci. Rev.* 2019, 6, 796 - 809.
61. Kankare, V.; Holopainen, M.; Vastaranta, M.; Puttonen, E.; Yu, X.W.; Hyypä, J.; Vaaja, M.; Hyypä, H.; Alho, P., 2013. Individual tree biomass estimation using terrestrial laser scanning. *ISPRS J. Photogramm.* 2013, 75, 64 - 75.
62. Kelsey, K.C.; Neff, J.C., 2014. Estimates of Aboveground Biomass from Texture Analysis of Landsat Imagery. *Remote Sens.* 2014, 6, 6407 - 6422.
63. Knott, J.A.; Liknes, G.C.; Giebink, C.L.; Oh, S.; Domke, G.M.; McRoberts, R.E.; Quirino, V.F.; Walters, B.F., 2023. Effects of outliers on remote sensing-assisted forest biomass estimation: A case study from the United States national forest inventory. *Methods Ecol. Evol.* 2023, 00, 1 - 16.
64. Koetz, B.; Sun, G.Q.; Morsdorf, F.; Ranson, K.J.; Kneubuhler, M.; Itten, K.; Allgower, B., 2007. Fusion of imaging spectrometer and LIDAR data over combined radiative transfer models for forest canopy characterization. *Remote Sens. Environ.* 2007, 106, 449 - 459.
65. Laurin, G.V.; Pirotti, F.; Callegari, M.; Chen, Q.; Cuzzo, G.; Lingua, E.; Notarnicola, C.; Papale, D., 2017. Potential of ALOS2 and NDVI to Estimate Forest Above-Ground Biomass, and Comparison with Lidar-Derived Estimates. *Remote Sens.* 2017, 9, 18.
66. Lefsky, M.A.; Keller, M.; Pang, Y.; de Camargo, P.B.; Hunter, M.O., 2007. Revised method for forest canopy height estimation from Geoscience Laser Altimeter System waveforms. *J. Appl. Remote Sens.* 2007, 1, 013537.
67. Li, C.; Li, Y.C.; Li, M.Y., 2019. Improving Forest Aboveground Biomass (AGB) Estimation by Incorporating Crown Density and Using Landsat 8 OLI Images of a Subtropical Forest in Western Hunan in Central China. *Forests* 2019, 10, 104.
68. Li, D.R.; Wang, C.W.; Hu, Y.M.; Liu, S.G., 2012. General Review on Remote Sensing-Based Biomass Estimation. *Geomat. Inform. Sci. Wuhan Univ.* 2012, 37, 631 - 635.
69. Li, J.R.; Mao, X.G., 2020. Comparison of Canopy Closure Estimation of Plantations Using Parametric, Semi-Parametric, and Non-Parametric Models Based on GF-1 Remote Sensing Images. *Forests* 2020, 11, 597.

70. Li, T.; Li, M.Y.; Ren, F.; Tian, L., 2022. Estimation and Spatio-Temporal Change Analysis of NPP in Subtropical Forests: A Case Study of Shaoguan, Guangdong, China. *Remote Sens.* 2022, 14, 2541.
71. Li, Y.C.; Li, C.; Li, M.Y.; Liu, Z.Z., 2019. Influence of Variable Selection and Forest Type on Forest Aboveground Biomass Estimation Using Machine Learning Algorithms. *Forests* 2019, 10, 1073.
72. Liang, X.L.; Kankare, V.; Hyypä, J.; Wang, Y.S.; Kukko, A.; Haggren, H.; Yu, X.W.; Kaartinen, H.; Jaakkola, A.; Guan, F.Y., 2016. Terrestrial laser scanning in forest inventories. *ISPRS J. Photogramm.* 2016, 115, 63 - 77.
73. Lister, A.J.; Andersen, H.; Frescino, T.; Gatzliolis, D.; Healey, S.; Heath, L.S.; Liknes, G.C.; McRoberts, R.; Moisen, G.G.; Nelson, M., 2020. Use of Remote Sensing Data to Improve the Efficiency of National Forest Inventories: A Case Study from the United States National Forest Inventory. *Forests* 2020, 11, 1364.
74. Liu, X.; Yang, L.; Liu, Q.H.; Li, J., 2014. Review of forest above ground biomass inversion methods based on remote sensing technology. *Natl. Remote Sens. Bull.* 2014, 19, 62-74.
75. Lou, X.T.; Zeng, Y.; Wu, B.F., 2011. Advances in the Estimation of Above-ground Biomass of Forest Using Remote Sensing. *Remote Sens. Nat. Resour.* 2011, 1, 1 - 8.
76. Lu, D.S.; Chen, Q.; Wang, G.X.; Liu, L.J.; Li, G.Y.; Moran, E., 2016. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *Int. J. Digit. Earth* 2016, 9, 63 - 105.
77. Lu, D.S.; Chen, Q.; Wang, G.X.; Moran, E.; Batistella, M.; Zhang, M.Z.; Laurin, G.V.; David, S., 2012. Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. *Int. J. For. Res.* 2012, 436537.
78. Lucas, R.M.; Cronin, N.; Lee, A.; Moghaddam, M.; Witte, C.; Tickle, P., 2006. Empirical relationships between AIRSAR backscatter and LiDAR-derived forest biomass, Queensland, Australia. *Remote Sens. Environ.* 2006, 100, 407 - 425.
79. Luo, M.; Wang, Y.F.; Xie, Y.H.; Zhou, L.; Qiao, J.J.; Qiu, S.Y.; Sun, Y.J., 2021. Combination of Feature Selection and CatBoost for Prediction: The First Application to the Estimation of Aboveground Biomass. *Forests* 2021, 12, 216.
80. Luo, S.Z.; Wang, C.; Xi, X.H.; Pan, F.F.; Qian, M.J.; Peng, D.L.; Nie, S.; Qin, H.M.; Lin, Y., 2017. Retrieving aboveground biomass of wetland *Phragmites australis* (common reed) using a combination of airborne discrete-return LiDAR and hyperspectral data. *Int. J. Appl. Earth Obs.* 2017, 58, 107 - 117.
81. Markus, T.; Neumann, T.; Martino, A.; Abdalati, W.; Brunt, K.; Csatho, B.; Farrell, S.; Fricker, H.; Gardner, A.; Harding, D., 2017. The Ice, Cloud, and land Elevation Satellite-2 (ICESat-2): Science requirements, concept, and implementation. *Remote Sens. Environ.* 2017, 190, 260 - 273.
82. McEwan, R.W.; Lin, Y.C.; Sun, I.F.; Hsieh, C.F.; Su, S.H.; Chang, L.W.; Song, G.Z.M.; Wang, H.H.; Hwong, J.L.; Lin, K.C., 2011. Topographic and biotic regulation of aboveground carbon storage in subtropical broad-leaved forests of Taiwan. *For. Ecol. Manag.* 2011, 262, 1817 - 1825.
83. Messinger, M.; Asner, G.P.; Silman, M., 2016. Rapid Assessments of Amazon Forest Structure and Biomass Using Small Unmanned Aerial Systems. *Remote Sens.* 2016, 8, 615.
84. Mladenoff, D.J., 2004. LANDIS and forest landscape models. *Ecol. Model* 2004, 180, 7 - 19.
85. Molotoks, A.; Stehfest, E.; Doelman, J.; Albanito, F.; Fitton, N.; Dawson, T.P.; Smith, P., 2018. Global projections of future cropland expansion to 2050 and direct impacts on biodiversity and carbon storage. *Glob. Change Biol.* 2018, 24, 5895 - 5908.
86. Montesano, P.M.; Rosette, J.; Sun, G.; North, P.; Nelson, R.F.; Dubayah, R.O.; Ranson, K.J.; Kharuk, V., 2015. The uncertainty of biomass estimates from modeled ICESat-2 returns across a boreal forest gradient. *Remote Sens. Environ.* 158, 95 - 109.
87. Muukkonen, P.; Heiskanen, J., 2005. Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. *Remote Sens. Environ.* 2005, 99, 434 - 447.
88. Narine, L.L.; Popescu, S.; Neuenschwander, A.; Zhou, T.; Srinivasan, S.; Harbeck, K., 2019. Estimating aboveground biomass and forest canopy cover with simulated ICESat-2 data. *Remote Sens. Environ.* 2019, 224, 1 - 11.
89. Narine, L.L.; Popescu, S.C.; Malambo, L., 2019. Synergy of ICESat-2 and Landsat for Mapping Forest Aboveground Biomass with Deep Learning. *Remote Sens.* 2019, 11, 1503.
90. Navarro, J.A.; Algeet, N.; Fernandez-Landa, A.; Esteban, J.; Rodriguez-Noriega, P.; Guillen-Climent, M.L., 2019. Integration of UAV, Sentinel-1, and Sentinel-2 Data for Mangrove Plantation Aboveground Biomass Monitoring in Senegal. *Remote Sens.* 2019, 11, 77.

91. Nerem, R.S.; Beckley, B.D.; Fasullo, J.T.; Hamlington, B.D.; Masters, D.; Mitchum, G.T., 2018. Climate-change-driven accelerated sea-level rise detected in the altimeter era. *Proc. Natl. Acad. Sci. USA* 2018, 115, 2022-2025.
92. Nguyen Thi Thanh Huong, 2011. *Forest Remote Sensing: Using multi-data sources for inventory of Natural broad-leaved ever-green forests in the Central Highlands of Vietnam*. Lambert Academic Publishing, Germany.
93. Ni, W.J.; Zhang, Z.Y.; Sun, G.Q.; Liu, Q.H., 2018. Modeling Interferometric SAR Features of Forest Canopies Over Mountainous Area at Landscape Scales. *IEEE Trans. Geosci. Remote* 2018, 56, 2958 - 2967.
94. Nichol, J.E.; Sarker, M.L.R., 2011. Improved Biomass Estimation Using the Texture Parameters of Two High-Resolution Optical Sensors. *IEEE Trans. Geosci. Remote* 2011, 49, 930 - 948.
95. Ou, G.L.; Li, C.; Lv, Y.Y.; Wei, A.C.; Xiong, H.X.; Xu, H.; Wang, G.X., 2019. Improving Aboveground Biomass Estimation of *Pinus densata* Forests in Yunnan Using Landsat 8 Imagery by Incorporating Age Dummy Variable and Method Comparison. *Remote Sens.* 2019, 11, 738.
96. Pan, Y.D.; Birdsey, R.A.; Fang, J.Y.; Houghton, R.; Kauppi, P.E.; Kurz, W.A.; Phillips, O.L.; Shvidenko, A.; Lewis, S.L.; Canadell, J.G., 2011. A Large and Persistent Carbon Sink in the World's Forests. *Science* 2011, 333, 988 - 993.
97. Pang, Y.; Lefsky, M.; Andersen, H.E.; Miller, M.E.; Sherrill, K., 2008. Validation of the ICESat vegetation product using crown-area-weighted mean height derived using crown delineation with discrete return lidar data. *Can. J. Remote Sens.* 2008, 34, S471 - S484.
98. Pang, Y.; Li, Z.Y.; Lefsky, M.; Che, X.J.; Chen, R.X., 2007. Effects of Terrain on the Large Footprint Lidar Waveform of Forests. *For. Res.* 2007, 20, 464 - 468.
99. Pascarella, A.E.; Giacco, G.; Rigioli, M.; Marrone, S.; Sansone, C., 2023. ReUse: REgressive Unet for Carbon Storage and Above-Ground Biomass Estimation. *J. Imaging* 2023, 9, 61.
100. Payne, N.J.; Cameron, D.A.; Leblanc, J.D.; Morrison, I.K., 2019. Carbon storage and net primary productivity in Canadian boreal mixedwood stands. *J. For. Res.* 2019, 30, 1667 - 1678.
101. Peng, S.L.; Guo, Z.H.; Wang, B.S., 2000. Ues of GIS and RS to estimate the light utilization efficiency of the vegetation in Guangdong, China. *Acta Ecol. Sin.* 2000, 6, 903 - 909.
102. Piao, S.L.; Fang, J.Y.; Guo, J.H., 2001. Application of CASA Model to The Estimation of Chinese Terrestrial Net Primary Productivity. *Chin. J. Plant Ecol.* 2001, 25, 603 - 608.
103. Ploton, P.; Barbier, N.; Coutron, P.; Antin, C.M.; Ayyappan, N.; Balachandran, N.; Barathan, N.; Bastin, J.F.; Chuyong, G.; Dauby, G., 2017. Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. *Remote Sens. Environ.* 200, 140 - 153.
104. Poley, L.G.; McDermid, G.J., 2020. A Systematic Review of the Factors Influencing the Estimation of Vegetation Aboveground Biomass Using Unmanned Aerial Systems. *Remote Sens.* 2020, 12, 1052.
105. Popescu, S.C., 2007. Estimating biomass of individual pine trees using airborne lidar. *Biomass Bioenerg.* 2007, 31, 646 - 655.
106. Price, B.; Gomez, A.; Mathys, L.; Gardi, O.; Schellenberger, A.; Ginzler, C.; Thurig, E., 2017. Tree biomass in the Swiss landscape: Nationwide modelling for improved accounting for forest and non-forest trees. *Environ. Monit. Assess.* 2017, 189, 1 - 14.
107. Qi, W.L.; Dubayah, R.O., 2016. Combining Tandem-X InSAR and simulated GEDI lidar observations for forest structure mapping. *Remote Sens. Environ.* 2016, 187, 253 - 266.
108. Radic, V.; Bliss, A.; Beedlow, A.C.; Hock, R.; Miles, E.; Cogley, J.G., 2014. Regional and global projections of twenty-first century glacier mass changes in response to climate scenarios from global climate models. *Clim. Dynam.* 2014, 42, 37 - 58.
109. Ryu, Y.; Berry, J.A.; Baldocchi, D.D., 2019. What is global photosynthesis? History, uncertainties and opportunities. *Remote Sens. Environ.* 2019, 223, 95 - 114.
110. Saatchi, S.; Buermann, W.; Ter Steege, H.; Mori, S.; Smith, T.B., 2008. Modeling distribution of Amazonian tree species and diversity using remote sensing measurements. *Remote Sens. Environ.* 2008, 112, 2000 - 2017.
111. Saatchi, S.; Marlier, M.; Chazdon, R.L.; Clark, D.B.; Russell, A.E., 2011. Impact of spatial variability of tropical forest structure on radar estimation of aboveground biomass. *Remote Sens. Environ.* 2011, 115, 2836 - 2849.

112. Sadeghi, Y.; St-Onge, B.; Leblon, B.; Prieur, J.F.; Simard, M., 2018. Mapping boreal forest biomass from a SRTM and TanDEM-X based on canopy height model and Landsat spectral indices. *Int. J. Appl. Earth Obs.* 2018, 68, 202-213.
113. Safari, A.; Sohrabi, H.; Powell, S., 2018. Comparison of satellite-based estimates of aboveground biomass in coppice oak forests using parametric, semiparametric, and nonparametric modeling methods. *J. Appl. Remote Sens.* 2018, 12, 046026.
114. Sandberg, G.; Ulander, L.M.H.; Fransson, J.E.S.; Holmgren, J.; Le Toan, T., 2011. L- and P-band backscatter intensity for biomass retrieval in hemiboreal forest. *Remote Sens. Environ.* 2011, 115, 2874 - 2886.
115. Santoro, M.; Beaudoin, A.; Beer, C.; Cartus, O.; Fransson, J.B.S.; Hall, R.J.; Pathe, C.; Schmillius, C.; Schepaschenko, D.; Shvidenko, A., 2015. Forest growing stock volume of the northern hemisphere: Spatially explicit estimates for 2010 derived from Envisat ASAR. *Remote Sens. Environ.* 2015, 168, 316 - 334.
116. Sarker, L.R.; Nichol, J.E., 2011. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. *Remote Sens. Environ.* 2011, 115, 968 - 977.
117. Schimel, D.; Pavlick, R.; Fisher, J.B.; Asner, G.P.; Saatchi, S.; Townsend, P.; Miller, C.; Frankenberg, C.; Hibbard, K.; Cox, P., 2015. Observing terrestrial ecosystems and the carbon cycle from space. *Glob. Change Biol.* 2015, 21, 1762-1776.
118. Schreiber, L.V.; Amorim, J.G.A.; Guimaraes, L.; Matos, D.M.; da Costa, C.M.; Parraga, A., 2022. Above-ground Biomass Wheat Estimation: Deep Learning with UAV-based RGB Images. *Appl. Artif. Intell.* 2022, 36, 2055392.
119. Sibanda, M.; Mutanga, O.; Rouget, M., 2015. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. *ISPRS J. Photogramm.* 2015, 110, 55 - 65.
120. Simard, M.; Fatoyinbo, L.; Smetanka, C.; Rivera-Monroy, V.H.; Castaneda-Moya, E.; Thomas, N.; Van der Stocken, T., 2019. Mangrove canopy height globally related to precipitation, temperature and cyclone frequency. *Nat. Geosci.* 2019, 12, 40 - 45.
121. Simard, M.; Pinto, N.; Fisher, J.B.; Baccini, A., 2011. Mapping forest canopy height globally with spaceborne lidar. *J. Geophys. Res.-Biogeosci.* 2011, 116, G04021.
122. Singh, M.; Malhi, Y.; Bhagwat, S., 2014. Biomass estimation of mixed forest landscape using a Fourier transform texture-based approach on very-high-resolution optical satellite imagery. *Int. J. Remote Sens.* 2014, 35, 3331 - 3349.
123. Smith, B.; Knorr, W.; Widlowski, J.L.; Pinty, B.; Gobron, N., 2008. Combining remote sensing data with process modelling to monitor boreal conifer forest carbon balances. *For. Ecol. Manag.* 2008, 255, 3985 - 3994.
124. Solberg, S.; Nasset, E.; Gobakken, T.; Bollandsas, O.-M., 2014. Forest biomass change estimated from height change in interferometric SAR height models. *Carbon Bal. Manag.* 2014, 9, 5.
125. Stavros, E.N.; Schimel, D.; Pavlick, R.; Serbin, S.; Swann, A.; Duncanson, L.; Fisher, J.B.; Fassnacht, F.; Ustin, S.; Dubayah, R. 2017. ISS observations offer insights into plant function. *Nat. Ecol. Evol.* 2017, 1, 194.
126. Stovall, A.E.L.; Vorster, A.G.; Anderson, R.S.; Evangelista, P.H.; Shugart, H.H., 2017. Non-destructive aboveground biomass estimation of coniferous trees using terrestrial LiDAR. *Remote Sens. Environ.* 2017, 200, 31 - 42.
127. Sun, G.; Ranson, K.J.; Kimes, D.S.; Blair, J.B.; Kovacs, K., 2008. Forest vertical structure from GLAS: An evaluation using LVIS and SRTM data. *Remote Sens. Environ.* 2008, 112, 107 - 117.
128. Sun, G.Q.; Ranson, K.J.; Guo, Z.; Zhang, Z.; Montesano, P.; Kimes, D., 2011. Forest biomass mapping from lidar and radar synergies. *Remote Sens. Environ.* 2011, 115, 2906 - 2916.
129. Taddese, H.; Asrat, Z.; Burud, I.; Gobakken, T.; Orka, H.O.; Dick, O.B.; Naesset, E., 2020. Use of Remotely Sensed Data to Enhance Estimation of Aboveground Biomass for the Dry Afromontane Forest in South-Central Ethiopia. *Remote Sens.* 2020, 12, 3335.
130. Tanase, M.A.; Panciera, R.; Lowell, K.; Tian, S.Y.; Garcia-Martin, A.; Walker, J.P., 2014. Sensitivity of L-Band Radar Backscatter to Forest Biomass in Semiarid Environments: A Comparative Analysis of Parametric and Nonparametric Models. *IEEE Trans. Geosci. Remote* 2014, 52, 4671 - 4685.
131. Tang, J.; Liu, Y.; Li, L.; Liu, Y.F.; Wu, Y.; Xu, H.; Ou, G.L., 2022. Enhancing Aboveground Biomass Estimation for Three Pinus Forests in Yunnan, SW China, Using Landsat 8. *Remote Sens.* 2022, 14, 4589.

132. Tao, S.L.; Guo, Q.H.; Li, L.; Xue, B.L.; Kelly, M.; Li, W.K.; Xu, G.C.; Su, Y.J., 2014. Airborne Lidar-derived volume metrics for aboveground biomass estimation: A comparative assessment for conifer stands. *Agric. For. Meteorol.* 2014, 198, 24 - 32.
133. Tian, F.; Brandt, M.; Liu, Y.Y.; Verger, A.; Tagesson, T.; Diouf, A.A.; Rasmussen, K.; Mbow, C.; Wang, Y.J.; Fensholt, R., 2016. Remote sensing of vegetation dynamics in drylands: Evaluating vegetation optical depth (VOD) using AVHRR NDVI and in situ green biomass data over West African Sahel. *Remote Sens. Environ.* 2016, 177, 265 - 276.
134. Tian, L.; Tao, Y.; Fu, W.X.; Li, T.; Ren, F.; Li, M.Y., 2022. Dynamic Simulation of Land Use/Cover Change and Assessment of Forest Ecosystem Carbon Storage under Climate Change Scenarios in Guangdong Province, China. *Remote Sens.* 2022, 14, 2330.
135. Tian, X.; Yan, M.; van der Tol, C.; Li, Z.; Su, Z.B.; Chen, E.X.; Li, X.; Li, L.H.; Wang, X.F.; Pan, X.D. 2017. Modeling forest above-ground biomass dynamics using multi-source data and incorporated models: A case study over the qilian mountains. *Agric. For. Meteorol.* 2017, 246, 1 - 14.
136. Van Aardt, J.A.N.; Wynne, R.H.; Oderwald, R.G., 2006. Forest volume and biomass estimation using small-footprint lidar-distributional parameters on a per-segment basis. *For. Sci.* 2006, 52, 636 - 649.
137. Van Leeuwen, W.J.D.; Orr, B.J.; Marsh, S.E.; Herrmann, S.M., 2006. Multi-sensor NDVI data continuity: Uncertainties and implications for vegetation monitoring applications. *Remote Sens. Environ.* 2006, 100, 67 - 81.
138. Wang Xiaoyi, Liu Caixia, Lv Guanting, Xu Jinfeng, Cui Guishan, 2022. Integrating Multi-Source Remote Sensing to Assess Forest Aboveground Biomass in the Khingán Mountains of North-Eastern China Using Machine-Learning Algorithms. *Remote Sensing*, Vol. 14 Issue 4, p. 1039, 2022
139. Wang, Y.; Day, J.L.; Davis, F.W., 1998. Sensitivity of Modeled C- and L-Band Radar Backscatter to Ground Surface Parameters in Loblolly Pine Forest. *Remote Sens. Environ.* 66, 331 - 342.
140. Wang, Y.; Fang, H.L.; Zhang, Y.H.; Li, S.J., 2020. Retrieval of Forest LAI Using Airborne LVIS and Spaceborne GLAS Waveform LiDAR Data. *Remote Sens. Technol. Appl.* 2020, 35, 1004 - 1014.
141. Waring, R.H.; Coops, N.C.; Landsberg, J.J., 2010. Improving predictions of forest growth using the 3 - PGS model with observations made by remote sensing. *For. Ecol. Manag.* 2010, 259, 1722-1729.
142. Wu, X.; Wang, X.P.; Wu, Y.L.; Xia, X.L.; Fang, J.Y., 2015. Forest biomass is strongly shaped by forest height across boreal to tropical forests in China. *J. Plant Ecol.* 2015, 8, 559 - 567.
143. Wu, Y.R.; Hong, W.; Wang, Y.P., 2007. The Current Status and Implications of Polarimetric SAR Interferometry. *J. Electron. Inform. Tech.* 2007, 29, 1258 - 1262.
144. Wu, Z.; Dai, E.F.; Wu, Z.F.; Lin, M.Z., 2020. Assessing differences in the response of forest aboveground biomass and composition under climate change in subtropical forest transition zone. *Sci. Total Environ.* 2020, 706, 135746.
145. Xiao, J.F.; Chevallier, F.; Gomez, C.; Guanter, L.; Hicke, J.A.; Huete, A.R.; Ichii, K.; Ni, W.J.; Pang, Y.; Rahman, A.F., 2019. Remote sensing of the terrestrial carbon cycle: A review of advances over 50 years. *Remote Sens. Environ.* 2019, 233, 111383.
146. Xing, Y.Q.; You, H.T.; Huo, D.; Sun, X.T.; Wang, R., 2014. Research Progress in Estimating Forest Tree Height Using Small Footprint Lidar Data. *World Forestry Res.* 2014, 27, 29 - 34.
147. Xu, X.L.; Cao, M.K., 2006. An Analysis of the Applications of Remote Sensing Method to the Forest Biomass Estimation. *J. Geo-Inf. Sci.* 2006, 8, 122-128.
148. Yan, F.; Wu, B.; Wang, Y.J., 2015. Estimating spatiotemporal patterns of aboveground biomass using Landsat TM and MODIS images in the Mu Us Sandy Land, China. *Agric. For. Meteorol.* 2015, 200, 119 - 128.
149. Yan, X.D.; Shugart, H.H., 2005. FAREAST: A forest gap model to simulate dynamics and patterns of eastern Eurasian forests. *J. Biogeogr.* 2005, 32, 1641 - 1658.
150. Yin, J.B.; Gentile, P.; Zhou, S.; Sullivan, S.C.; Wang, R.; Zhang, Y.; Guo, S.L., 2018. Large increase in global storm runoff extremes driven by climate and anthropogenic changes. *Nat. Commun.* 2018, 9, 4389.
151. Yu, Y.F.; Saatchi, S.; Heath, L.S.; LaPoint, E.; Myneni, R.; Knyazikhin, Y., 2010. Regional distribution of forest height and biomass from multisensor data fusion. *J. Geophys. Res.-Biogeosci.* 2010, 115, G00E12.

152. Zaki, N.A.M.; Abd Latif, Z., 2017. Carbon sinks and tropical forest biomass estimation: A review on role of remote sensing in aboveground-biomass modelling. *Geocarto Int.* 2017, 32, 701 - 716.
153. Zaki, N.A.M.; Abd Latif, Z.; Suratman, M.N.; Zainal, M.Z., 2016. Aboveground biomass and carbon stocks modelling using non-linear regression model. In *Proceedings of the 8th IGRSM International Conference and Exhibition on Geospatial and Remote Sensing (IGRSM)*, Kuala Lumpur, Malaysia, 13 - 14 April 2016.
154. Zeng, Y.L.; Hao, D.L.; Huete, A.; Dechant, B.; Berry, J.; Chen, J.M.; Joiner, J.; Frankenberg, C.; Bond-Lamberty, B.; Ryu, Y., 2022. Optical vegetation indices for monitoring terrestrial ecosystems globally. *Nat. Rev. Earth Environ.* 2022, 3, 447 - 493.
155. Zhang, G.; Ganguly, S.; Nemani, R.R.; White, M.A.; Milesi, C.; Hashimoto, H.; Wang, W.L.; Saatchi, S.; Yu, Y.F.; Myneni, R.B., 2014. Estimation of forest aboveground biomass in California using canopy height and leaf area index estimated from satellite data. *Remote Sens. Environ.* 2014, 151, 44 - 56.
156. Zhang, M.Z.; Lin, H.; Zeng, S.Q.; Li, J.P.; Shi, J.N.; Wang, G.X., 2013. Impacts of Plot Location Errors on Accuracy of Mapping and Scaling Up Aboveground Forest Carbon Using Sample Plot and Landsat TM Data. *IEEE Geosci. Remote Sens.* 2013, 10, 1483 - 1487.
157. Zhang, N.N.; Shugart, H.H.; Yan, X.D., 2009. Simulating the effects of climate changes on Eastern Eurasia forests. *Clim. Change* 2009, 95, 341 - 361.
158. Zhang, R.; Zhou, X.H.; Ouyang, Z.T.; Avitabile, V.; Qi, J.G.; Chen, J.Q.; Giannico, V., 2019. Estimating aboveground biomass in subtropical forests of China by integrating multisource remote sensing and ground data. *Remote Sens. Environ.* 2019, 232, 111341.
159. Zhang, X.Y.; Kondragunta, S., 2006. Estimating forest biomass in the USA using generalized allometric models and MODIS land products. *Geophys. Res. Lett.* 2006, 33, L09402.
160. Zhang, Y.Z.; Liang, S.L.; Yang, L., 2019. A Review of Regional and Global Gridded Forest Biomass Datasets. *Remote Sens.* 2019, 11, 2744.
161. Zhao, K.G.; Popescu, S.; Nelson, R., 2009. Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. *Remote Sens. Environ.* 2009, 113, 182-196.
162. Zheng, D.L.; Rademacher, J.; Chen, J.Q.; Crow, T.; Bresee, M.; le Moine, J.; Ryu, S.R., 2004. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. *Remote Sens. Environ.* 2004, 93, 402-411.
163. Zheng, G.X.; Allen, S.K.; Bao, A.; Ballesteros-Canovas, J.A.; Huss, M.; Zhang, G.Q.; Li, J.L.; Yuan, Y.; Jiang, L.L.; Yu, T., 2021. Increasing risk of glacial lake outburst floods from future Third Pole deglaciation. *Nat. Clim. Change* 2021, 11, 411 - 417.

**Email tác giả liên hệ:** hdbao@ttn.edu.vn

**Ngày nhận bài:** 12/11/2023

**Ngày phản biện đánh giá và sửa chữa:** 15/11/2023

**Ngày duyệt đăng:** 18/11/2023