

人工知能とデジタル革新が導く 未来の林業・アグロフォレストリー



キム・ギョンジン 弁護士

本書は人工知能によって整理・制作されたものです。
世界の主要言語で書かれた資料を収集し、まとめました。

<https://notebook.google.com/notebook/2d68677c-b410-4281-bd84-9368ae15eeb4>

上のリンクは、本書の制作で参照した資料を収集・保存した公開NotebookLMです。

誰でも自由にアクセスして利用できます。

目次

第1章	森林パラダイムの転換：データ・AIに基づく森林ビッグデータとデジタルツイン	3
1.1	森林資源管理のパラダイムシフトとデジタルツイン（Digital Twin）の構築	5
1.2	マルチモーダル（Multimodal）リモートセンシングデータ融合技術	13
1.3	森林専用大規模言語モデル（ForestGPT）と知的意思決定支援	20
第2章	精密林業（Precision Forestry）：単木解析とバイオマス・炭素の精密測定	28
2.1	UAV-LiDARと高解像度画像に基づく単木（Individual Tree）の樹種分類	30
2.2	地上部バイオマス（AGB）と森林炭素蓄積量の推定	37
2.3	森林土壌動態と土地被覆変化のモニタリング	43
第3章	森林災害と生態系の健全性モニタリング：AIによる監視と早期警報	50
3.1	機械学習・深層学習による山火事リスク予測と焼失域検出	52
3.2	病虫害（マツ材線虫病を含む）および枯死木の画像による早期診断	58
3.3	違法伐採の音響検知とIoT/ブロックチェーンによる森林保護ネットワーク	64
第4章	スマート林業作業とロボティクス：作業安全、自律走行、林道網の最適化	70
4.1	林道・集材路の自動抽出と地形に合わせた収穫計画	72
4.2	遠隔操縦ハーベスタ、自律走行フォワーダ、林業ロボティクス	77
4.3	コンピュータビジョンとウェアラブルセンサーに基づく作業安全監視	82
第5章	持続可能なアグロフォレストリーと木材サプライチェーンDX	88
5.1	アグロフォレストリーシステムにおける水利用効率（WUE）と生態系サービスの最適化	90
5.2	ICTに基づく木材トレーサビリティ（QR／電子タグ）と木材品質の自動判定	97
5.3	循環型バイオエコノミーと森林カーボンクレジット	103

第1章

森林パラダイムの転換：データ・AIに基づく森林ビッグデータとデジタルツイン

1.1

森林資源管理のパラダイムシフトとデジタルツイン（Digital Twin）の構築

朝6時、調査員は登山靴のひもを締め、バックパックに巻き尺と胸高直径テープ、紙の野帳を詰め込みます。今日登る標本点は標高700メートルの尾根斜面にあり、地図に記された座標までは歩いて2時間あまりかかります。韓国山林庁は全国の森林に5,400か所の標本点を配置しています。調査員はそこで林木蓄積や森林の健全性をはじめとする69項目を記録し、同じ標本点を5年周期で再訪します。標本点に着いた調査員は木を1本ずつ巻き尺で囲み、目盛りを読み、胸高直径（DBH、胸の高さで測った樹幹の直径）を野帳に書き写します。斜面が急なら、測高器を目の高さに合わせることも、角度を測って計算し、樹高を求めることも時間がかかります。丸一日を費やしても、調査員1人が終えられる標本点は多くて2、3か所です。指先は巻き尺に擦れてひび割れ、突然のにか雨が通り過ぎれば、野帳の鉛筆書きはにじんで読みにくくなります。

こうして集めた数値は正確ですが、古くなりやすいものです。5年に一度標本点を回る間に山火事が尾根を焼き、病害虫が林分を丸ごと食い荒らしても、次の調査までその変化は公式統計に現れません。国有林と私有林を問わず、国家森林資源調査と二類森林調査は長い間、このような形で運営されてきました。人の足と目に頼る調査は遅く費用がかかり、時間と空間をきめ細かく埋められません。それだけではありません。精密な収穫計画を立てようとしても、5年前の数値から現在の木の状態を推測するほかありません。

標本点からグリッド地図へ

こうした限界を越えようとする動きが、森林分野全体で進んでいます。林業のデジタルトランスフォーメーション（DX）は、紙の伝票や手書きの図面をモバイルアプリと地理情報システム（GIS）のデータに移すことから始まります。次の段階では、蓄積されたデータを森林管理や木材の需給マッチング、電子申請システムへと結び付けます。最終段階に至ると、伐採や造林といった林業の上流工程から、流通と加工という下流工程、さらには他産業との接点までデータがリアルタイムで流れ、意思決定そのものが組み直されます。

この流れは韓国でも珍しいものではありません。国立山林科学院の森林ICT研究センターは、江原道の加里山先導森林経営団地を舞台に、航空LiDAR、地上LiDAR、バックパック型LiDARを並行して投入し、デジタル森林資源情報を集めて精密林業に使う試験を続けてきました。機器ごとにデータ収集の精度と作業速度が異なるため、どの組み合わせが実際の現場に合うかを見極める後処理が続きました。

行政区域や慣習的に区分してきた小班、すなわち森林管理のために細かく分けた区画の境界に頼って統計を作る方式には、長年の欠陥がありました。同じ小班でも谷と尾根の微地形によって樹高や成長速度が異なるのに、小班単位で平均した瞬間、その差は埋もれてしまいます。近年はこの問題を解くため、森林空間データを一辺20メートルの正方形グリッドに組み直す試みが続いています。航空レーザー測量（ALS）と衛星データの精度を、各グリッドにそのまま収めることが目的です。

この変化の中心には、意思決定支援システム（DSS、Decision Support System）と、複数のデータを一つにまとめる統合プラットフォームがあります。DSSは複数のデータを集めて分析し、人が意思決定をするときに参照できる数値やグラフを示すソフトウェアです。欧州連合のHorizon Europe事業としてナポリ・フェデリコ2世大学が主導するDigiMedForプロジェクトは、森林資源のモニタリングとインベントリー構築、木材の履歴追跡と等級判定、森林計画の意思決定支援という三つの軸を中心に技術を統合しています。このプロジェクトのForest Pathwayは、樹種、生物気候帯、立地生産力、経営目標を入力すると、森林を育てる道筋を案内するウェブ専門家システムです。特定地域のドローンインベントリーと法令を自動処理する現場シミュレーターではなく、森林経営者が選択肢を絞る際に参照する指針ツールに近いものです。

森林デジタルツインの構造は、四つの層に分けて考えられます。最下層には実際の森林、土壌、微気候からなる物理環境があり、その上に衛星、無人航空機（UAV）、地上IoTセンサー、地上LiDARが集めたデータ層が積み重なります。第3層はこのデータを一つに結び、ディープラーニングで特徴を抽出し、時空間を合わせたシミュレーションエンジンを動かします。最上層では、精密森林管理、予測分析、炭素吸収量の検証、自律作業との連携といった実用が生まれます。

この技術は段階を踏んで発展してきました。当初は森林をそのまま写した静的な3次元モデルにとどまりました。次に、センサーデータが一方向にだけ反映されるデジタルシャドウ、すなわち現実の状況が仮想モデルに映るだけで戻ってこない段階を経ました。現在目指しているのは、現実の森林と仮想の森林が互いに信号をやり取りし、リアルタイムでフィードバックし合う完成形のデジタルツインです。

LiDARが描く1本の木

LiDARはレーザー光を照射し、その光が物体に当たって戻るまでの時間を測り、距離を計算する装置です。計算原理は難しくありません。この光をどこに取り付けるかで名称が変わります。航空機に搭載すれば航空LiDAR（ALS）、無人機に搭載すれば無人機LiDAR（ULS）、地上に据えれば地上LiDAR（TLS）、背負って歩けばモバイルマッピングシステム（MMS）になります。

従来のLiDARは多くの場合、一つの波長しか照射しないため、レーザーがどこから反射したかという位置は正確でも、それが葉なのか枝なのかを区別するのは苦手でした。近年は三つの波長を同時に照射するマルチスペクトルLiDARが、この問題に取り組んでいます。公開ベンチマークデータセットForestSemantic-MSを使い、複数のディープラーニングモデルを競わせた研究があります。この研究でPoint Transformer V3（PTv3）モデルは、地表、低木、幹、枝、葉、倒れた枯死木という六つの構成要素を分類する試験を受けました。平均Intersection over Union（mIoU、モデルの予測領域と実際の領域が重なる度合いの平均）で69.1%を記録し、他のモデルを21.8ポイント上回りました。葉と枝が絡み合う場所では、一つの波長で樹木の部位を区別することは困難ですが、波長を三つに増やすと状況が変わります。倒れた枯死木の認識精度は12.7ポイント、枝は4.5ポイント、幹は2.5ポイント上がりました。

手間のかかる複数回スキュンの代わりに、一度だけ走査して通り過ぎる単一スキュン地上LiDARもあります。米国インディアナ州のMartell Forestにある広葉樹混交林では、この単一スキュンの点群データを2次元投影画像に変換し、畳み込みとアテンションを併用するCoAtNetニューラルネットワークで、木ごとの地上部バイオマスを推定する実験が行われました。木の背後が遮蔽される欠点を抱えながらも、この方式の説明力は0.73に達し、ランダムフォレストやPoint Transformerなどの比較モデルを上回りました。

2026年には、点群をまったく異なる方法で扱う試みも登場しました。LiDARデータをGaussian Splattingというレンダリング技法へ導く研究で、一つ一つの点を小さな半透明の楕円に変えて重ね、木の表面をはるかに写實的に復元します。硬い幹と柔らかく揺れる葉を別々に扱う規則を入れ、初期化段階で起こりがちだったぼやけや揺らぎを減らしたと研究陣は報告しています。

仮想の森林で先に伐ってみる

仮想森林は、美しい3次元画像にとどまりません。木の位置、高さ、樹冠幅、胸高直径といった実際のインベントリーデータをそのまま移せば、間伐や皆伐のように木を間引き、伐り出す作業の結果を事前に目で確認できるシミュレーション環境が生まれます。DigiMedForプロジェクトが開発した仮想森林意思決定支援システム（VFSS、Virtual Forest Decision Support System）は、実際とほぼ同じ位置に仮想の木を植え、森林全体を複製します。このシステムは日付と時刻によって変わる日光の量を計算し、木がどれほど光を受けて育つかを追跡します。利用者は机の前のデスクトップ画面から森林全体を見下ろすことも、仮想現実（VR）ヘッドセットを着けて森の中に歩み入り、1本の木を選んで伐採や植栽を試すこともできます。間伐する木を選んだ瞬間、残る木の本数と密度、今後の成長推移、伐採木材の収穫量が統計としてすぐ画面に表示されます。米国ミシシッピ州とDouglas fir林分に実際に適用した結果、位置と木の寸法を含むデータと、およそ40樹種の3次元標本さえあれば、数時間以内にその地域の森林デジタルツインを構築できました。

KeskesとNiță（2026）は、ルーマニアの現地資料を基にしたモデルに、フィンランドの多元的国家森林資源調査資料を加えました。フィンランドの林木材積予測の説明力は0.483から0.718へ上がりました。炭素地図を直接作った研究ではなく、異なる国の資料をつなぎ、林分構造予測を改善した試験です。国を越えてモデルを使う際には、現地標本で再調整しなければなりません。

同様の試みは米国でも続いています。オレゴン州立大学は、Elliott State Forestの77.6平方キロメートルと約280万本の木を含むデジタルツインを作りました。このうち2万6,000本はゲームエンジンで精密に再現しました。この仮想森林では時間と天候を変えながら地形を歩き、択伐や皆伐が森林に残す痕跡を事前に調べられます。ミシガン州立大学とバージニア工科大学の研究陣は、バージニア州中部のPinus taeda林7.5エーカーで3,555本を調査し、複数の間伐シナリオを比較しました。ブロックとシナリオによる除去材積の差は7.9%から18.2%でした。あるブロックでは原木価格を仮定した場合、1エーカー当たり約70ドルの差が出ました。一つの試験地で得た計算なので、他の森林でも同じ収益が出るとは断定できません。

森の中の画面とロボットの予行演習

デジタルツインに蓄積されたデータは、画面の中だけにとどまりません。現場作業員がスマートフォンやタブレット、Microsoft HoloLens 2やApple Vision Proのような複合現実機器を使えば、実際の木に重なった拡張現実（AR）グラフィックを見ることができます。Arboreal Forest、ForestScanner、Tree Scannerなどのアプリケーションは、スマートフォンに搭載されたLiDARとRGB-Dセンサー、位置追跡技術のSLAM、すなわちSimultaneous Localization and Mappingという、機械が周囲の地図を自ら描きながら自分の位置を把握する技術を結び、現場を歩く間に木の胸高直径、高さ、座標を拡張された3次元グラフィックとともに、その場で確認できるようにします。技術成熟度は試作品の段階から、すでに商品として販売される段階まで幅があります。北方林で無人機LiDARとSLAMにより測った胸高直径の誤差は、2.0から4.0センチメートルと小さいものでした。木が密集する亜熱帯の都市林では、誤差が5.13センチメートル、比率で22.01%まで大きくなりました。

林業機械のための仮想訓練場も作られています。スウェーデンのVindeln地域では、地上LiDARのLeica BLK360で30か所をスキャンし、ドローンデータを加えて高精度デジタルツインを複製しました。こうして作った仮想森林の中で、視点と太陽角度を無作為に変えながら、SimForestという合成データセットを自動生成しました。林業ロボットや自動運転フォワーダが人、木、障害物をリアルタイムで認識して停止する安全機能を実際の森林に投入する前に、この仮想データで検証するわけです。

フィンランド天然資源研究所（Luke）は、炭素取引市場を見据えたデジタルツインを開発しています。LiDAR搭載ドローンで木ごとの高さ、胸高直径、樹種を記録し、複数の衛星資料を重ねた後、この原データを動的な3次元モデルへ変換します。炭素吸収量分析をVERRAやGold Standardのような検証制度につなぐことが目標です。まだ商用化の道を探る研究段階にあります。

再び曇る精度

これだけ成果が積み上がっても、研究結果が食い違う場合は少なくありません。複数回スキャンの地上LiDARは木の体積を測る精度に優れますが、複数の位置から撮ったデータをつなぎ合わせる位置合わせに多くの手間がかかります。反対に、単一スキャンとディープラーニングを組み合わせた方法は収集速度を大幅に高めました、木の背後に隠れた枝や倒れた枯死木を見落とす誤差を完全にはなくせませんでした。マルチスペクトルLiDARも同じです。部位別の認識精度は目に見えて上がりますが、機器が高価で、処理するデータ量もはるかに増えます。予算に余裕のない森林組合が、こうした機器をすぐ導入するのは容易ではなさそうです。

一つの試験林で高い精度を出したモデルも、温帯混交林や亜熱帯林へ移すと性能が低下することがあります。樹種、樹冠構造、センサー、データの分け方が異なるからです。他の森林に適用するには、その地域のデータでモデルを再調整する必要があります。

下層植生が繁茂し、木の上部が密に接する森林では、ドローンや衛星が放つ光が地面まで届かず、木の下部や幹の太さを測る誤差が大きくなります。木の下を飛ぶ自律飛行ドローンは、視覚情報と慣性情報を併用する位置追跡技術（VIO、SLAM）に頼りますが、光が足りず枝が揺れると位置を見失い、完全に迷うこともあります。干ばつと高温ストレスを計算する成長モデルはすでに存在します。まだ珍しいのは、現場センサーと極端気象のデータをデジタルツイン内で継続的に更新する運用システムです。

Vision Transformer（ViT）や3次元畳み込みニューラルネットワークのように性能の高いモデルほど、内部で何を根拠に判断したのか説明しにくいブラックボックスのままです。森林政策を決める側にとって、この不透明さは信頼の形成を遅らせる要因になります。このようなモデルは多くの場合、高性能GPUを必要とするため、通信が途切れやすい奥地のドローンや現場端末へそのまま移すことも簡単ではありません。

国際連合食糧農業機関（FAO）は、2026年2月に公表した記事で、同様の懸念を別の角度から指摘しました。AIが出した数値をそのまま政策に使うには、必ず現場検証が必要であり、それを扱う訓練された人材や標準手順といった制度の整備は、技術導入そのものより時間がかかるという指摘です。

この隙間を埋めようとする試みも並行して進んでいます。モデルがどの情報に基づいて判断したのかを逆にたどるSHAPやGrad-CAMのような説明可能な人工知能（XAI）を取り入れ、樹種別の開花時期や土壌水分といった生態学的知識を規則としてモデルに組み込み、精度と説明力の両方を確保する研究が続いています。枝刈り、量子化、知識蒸留などの軽量化技術でドローンや現場端末でも動くモデルを作る作業も、地域や機器ごとに散らばったデータを一つの標準形式にまとめる作業も進められています。

出典・参考文献

1. Amoah-Nuamah, J., Child, B., Okyere, E. Y., Adams, O., & Danquah, J. A. (2025). Applications of artificial intelligence in forest health surveillance and management. *Discover Forests*, 1, Article 56.
<https://doi.org/10.1007/s44415-025-00061-w>

2. AVNation. (2026年2月27日). Oregon State University builds immersive forest digital twin using scalable display technologies. <https://www.avnation.tv/2026/02/27/oregon-state-university-leverages-scalable-display-technologies-to-bring-oregons-forests-to-life-with-immersive-visualization/> (2026年8月2日閲覧)
3. DigiMedFor Project Consortium. (2025). DigiMedFor: digital tools and technology systems for the sustainable management of Mediterranean forest resources (Horizon Europe Project No. 101081928). <https://digimedfor.eu> (2026年8月2日閲覧)
4. Forkuo, G. O., & Borz, S. A. (2026). Deep learning-based computer vision in forest monitoring and management: a systematic review. *Biodiversity and Conservation*, 35(208), 1-37. <https://doi.org/10.1007/s10531-026-03412-x>
5. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
6. Jung, M., Choi, J., Carpenter, J., Fei, S., & Jung, J. (2025). Individual tree biomass estimation using single-scan terrestrial laser scanner with efficient projection-based deep learning. *Journal of Forestry*. <https://doi.org/10.1007/s44392-025-00065-6>
7. Keskes, M. I., & Niță, M. D. (2026). Digital twins in forest management using scalable deep learning pipeline. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 19, 8519-8547. <https://doi.org/10.1109/JSTARS.2026.3666924>
8. Lapland University of Applied Sciences, FrostBit Software Lab. (2024年8月1日). Developing a simulator platform to advance autonomous systems in forestry usage. <https://lapinamk.fi/en/blogArticle/developing-a-simulator-platform-to-advance-autonomous-systems-in-forestry-usage/> (2026年8月2日閲覧)
9. Liang, X., Yao, H., Qi, H., & Wang, X. (2024). Forest in situ observations through a fully automated under-canopy unmanned aerial vehicle. *Geo-Spatial Information Science*, 27(4), 983-999. <https://doi.org/10.1080/10095020.2024.2322765>
10. Natural Resources Institute Finland (Luke). (2026). Digital Forest Carbon Twins. <https://www.luke.fi/en/carbontwins> (2026年8月2日閲覧)
11. Platt, E., Carter, D. R., Reddy, A., Albaugh, T. J., Cook, R. L., Campoe, O., Rubilar, R., Barua, G., & Sumnall, M. J. (2026). Precision forestry: using machine learning and LiDAR to inform thinning in *Pinus taeda* plantations, a case study. *Journal of Forestry*. <https://doi.org/10.1007/s44392-026-00089-6>
12. Saha, R., Bagchie, P., Lalremsang, P., & Rai, K. C. (2025). Digital innovation in forest science: applications of artificial intelligence, remote sensing and smart monitoring systems for ecosystem conservation. *The Bioscan*, 20(3), 907-911. [https://doi.org/10.63001/tbs.2025.v20.i03.S.I\(3\).pp907-911](https://doi.org/10.63001/tbs.2025.v20.i03.S.I(3).pp907-911)
13. Takhtkeshha, N., Bocaux, L., Ruoppa, L., Remondino, F., Mandlbürger, G., Kukko, A., & Hyypä, J. (2026). 3D forest semantic segmentation using multispectral LiDAR and 3D deep learning. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 94, 377-397. <https://doi.org/10.1007/s41064-025-00369-4>
14. Toaza, J. M. M., Picchi, G., Nati, C., & Borz, S. A. (2025). Accuracy and time efficiency of a new app developed to source and map single tree data: A comparison to state-of-art LiDAR data collectors in terms of basal area estimates. *Ecological Informatics*, 91, Article 103417. <https://doi.org/10.1016/j.ecoinf.2025.103417>
15. Valbuena, P., et al. (2026年2月6日). Artificial intelligence in forest monitoring: uses, applications, adoption and precautions. *FAO Forest Monitoring Blog*. <https://www.fao.org/forest-monitoring/blog/detail/blog/2026/02/06/artificial-intelligence-in-forest-monitoring--uses--applications--adoption--and-precautions/en> (2026年8月2日閲覧)
16. Zhou, Z., Chen, Y., Deng, Y., Zheng, X., Liang, H., Zhong, X., & Li, Z. (2026). LiDAR-guided semantic 3D Gaussian splatting for forest digital twins. *Remote Sensing*, 18(11), 1696. <https://doi.org/10.3390/rs18111696>

17. 韓国山林庁. (n.d.). 国家森林資源調査. https://forest.go.kr/kfsweb/kfi/kfs/cms/cmsView.do?mn=NKFS_04_05_08&cmsId=FC_000344 (2026年8月2日閲覧)
18. 大萱直花. (2025). 真の林業DXとは. 森林応用研究, 34(1), 21-23. https://doi.org/10.20660/applfor.34.1_21

1.2

マルチモーダル（Multimodal）リモートセンシング データ融合技術

梅雨前線が3日間にわたり朝鮮半島を覆っていたある夏、国家森林衛星情報活用センターのモニター前に座った研究員は、新たにダウンロードした衛星画像を開き、ため息をつきました。画面の半分が牛乳を流したように白くかすんでいました。江原道東海岸のマツ材線虫病防除区域を確認しようとしていたところでしたが、雲が山全体を覆い、1本の木も見分けられませんでした。画面下部には防除対象木の位置を示す赤い点が散らばっていましたが、その上を覆う雲のため、最近の状態を確かめる方法がありませんでした。隣に座る同僚が紙コップを置き、「今日も空が開きませんね」と短く言って通り過ぎました。光学衛星はカメラと同じ原理で動きます。太陽光が地表で反射し、レンズに入る量を記録する装置なので、雲がかかるとカメラの前を手のひらで覆ったのと同じ状態になります。次の衛星が同じ空を再び通るまで、さらに数日待たなければなりません。その間にも病木は静かに広がり、乾いた落ち葉の下では火種が育ちます。

マルチモーダルリモートセンシングのデータ融合は、このようなときに必要になります。空から一つの目だけで森林を見れば、必ず見えない区間が生じます。衛星は広い地域を頻繁に撮りますが、雲や霧に遮られ、樹冠の下までは視線が届きません。無人航空機（UAV）や地上レーザースキャナーは、葉1枚、枝1本までセンチメートル単位で捉えますが、バッテリーと人件費のため国土全体を調べることはできません。ドローン1機のバッテリーは長くても40分です。そこで研究者は方法を変えました。異なる目を持つ装置を一つの画面に重ねる方向へ転じたのです。空に浮かぶ衛星、大気中を飛ぶドローン、地上に据えたセンサーを一つの体のように結ぶ、空中・大気・地上の多層観測網です。

空と地面の間にある三重の目

三つの階層は役割が異なります。衛星は朝鮮半島全体を3日または5日で走査し、ドローンは一つの林分を選び、1本の木の単位で見つめます。地上のセンサーは一か所に腰を据え、数か月、数年分の変化を秒単位で蓄積します。

マクロスケールを担う衛星階層には、欧州宇宙機関のSentinelシリーズ、米国のLandsatシリーズ、中国のGF-2が含まれます。樹冠高を直接測るICESat-2とGEDIも

この階層に位置します。GF-2は地表を0.8メートルのセルまで分けて撮る高解像度衛星です。Landsat 8とLandsat 9は熱赤外バンドも搭載し、山火事直後の熱まで捉えます。GEDIは国際宇宙ステーションに搭載され、世界各地の森林の高さを点単位で測る装置です。de Conto、Armston、Dubayahの研究者は2025年、1億3,000万点を超えるこのデータを合成開口レーダー（SAR）のデータとディープラーニングで結びました。その結果生まれた25メートルセルの全球森林構造地図は、0.82の説明力に達しました。パラメーターが40万個にも満たない、比較的軽量なモデルで得た結果です。

この階層には新顔も加わりました。米国航空宇宙局（NASA）とインド宇宙研究機関（ISRO）が共同開発したNISAR衛星は、2025年7月30日に打ち上げられました。地表から約747キロメートル上空を周回し、LバンドとSバンドのレーダーで土壌水分、森林バイオマス、地面の微細な動きを測ります。この衛星が集めたLバンドデータは、2026年7月20日から誰でもダウンロードできるようになりました。以前は国家機関や大規模研究所しか扱えなかったデータを、今では韓国の大学院生もインターネットから無料でダウンロードし、自分の論文に使えます。欧州宇宙機関のBiomass衛星は一歩進み、従来のレーダーより波長の長いPバンドを初めて搭載しました。波長が長いほど葉や枝を深く貫き、幹の木質部の体積まで推し量れます。この衛星は2025年4月に打ち上げられました。同年12月19日に最初の公開データを発表しました。欧州の観測網ではSentinel-1Dが2025年11月に軌道へ投入されました。既存のSentinel-1Cと対を組み、同じ場所を6日周期で再撮影する以前の体制が復活しました。

韓国もこの階層に新たな衛星を1基送りました。宇宙航空庁、農村振興庁、山林庁が共同開発した農林衛星は、次世代中型衛星4号です。SpaceXのFalcon 9ロケットがこの衛星を載せました。打ち上げ日は2026年7月7日でした。解像度5メートル級の画像を3日周期で朝鮮半島全域から撮るこの衛星は、山火事や地滑りの被災区間を広域で迅速に特定するために使われる予定です。韓国の民間企業Hancom InSpaceが2026年3月に打ち上げたハイパースペクトル衛星Sejong 3にも注目すべきです。通常のカメラが光を赤、緑、青の3色だけに分けて記録するのに対し、靴箱を二つほどつないだ大きさのこの6ユニット（6U）級超小型衛星は、442区間に分けて記録します。重量は11キログラムに届きません。葉の色ではなく、葉を構成する物質そのものの反射特性まで区別できる可能性を持っています。

中間スケールを担うドローン階層では、LiDAR、ハイパースペクトル、マルチスペクトルセンサー、超高解像度カメラが林分と個々の木の立体構造と色の指紋を同時に集めます。LiDARは光を照射し、戻る時間を測って物体までの距離を求める装置です。ドローン搭載LiDARは木の上を低く飛び、樹冠一つ一つの起伏まで捉えます。

ミクロスケールの階層は地面にほぼ接しています。地上LiDAR (TLS)、背負って運ぶモバイルマッピング装置 (Backpack MMS)、土壌水分と気温を測るIoT微気候センサー、季節変化を撮影するPhenoCam塔がこの階層を構成します。

PhenoCamは同じ木を毎日同じ角度から撮り、葉がいつ芽吹き、いつ赤く色づくかを日付単位で記録します。IoTセンサーは地下15センチメートルに埋められ、土が乾く速度をサーバーヘリアルタイムで送ります。これらの装置は、木の胸高直径、幹の曲がり具合、下層植生、土壌水分を休みなく測定して記録します。胸高直径は1本の木の木材体積と炭素蓄積量を計算する最初の入力値なので、数ミリメートルの誤差でも森林全体に掛け合わせれば、無視しにくい大きさに膨らみます。

国立山林科学院が2026年1月に公開したLiDAR搭載自律飛行ドローンは、地上階層とドローン階層の間にまたがる装置です。人が巻き尺を持って歩き、1ヘクタールを調査するのに22時間かかった作業を、このドローンは2.3時間で終わりました。現場で直接測った値と比べた精度は96%に達し、葉に隠れて人の目では測りにくかった胸高直径まで捉えました。

時空間を合わせる作業

問題は、こうして集めた資料が互いに異なる物差しで測ったものと同じだという点です。衛星画像は1セルに10メートルから30メートルを収めます。ドローン画像は数センチメートル、地上スキャナーは数ミリメートル単位まで緻密です。1画素ずれると、地図上では1本の木が隣の木の影の中に丸ごと入ってしまいます。このデータを重ねるには、山道の各所に反射板と十字標識を置き、衛星測位で座標を測る地上基準点の作業が先です。その後、合理関数モデルと特徴点に基づく幾何補正を行います。センサーごとに解像度と座標系が異なるため、調査地と機器に合わせた位置合わせ誤差のチェックが必要です。

時間を合わせる作業も容易ではありません。Sentinel-2は2基体制で約5日、Landsatは1基が約16日で同じ区域を再び通りますが、ドローンと地上調査は研究者の予定に合わせ、間を置いて行われます。その間に木は葉を出し、含む水分量も変わるため、時点のずれたデータをそのまま重ねると、同じ木でも違う色に見える錯覚が生じます。雲と影を除くSen2CorやFmaskなどのアルゴリズムを通し、同じ季節の複数画像を選んで合成するのはそのためです。画素位置と観測時点がずれるとモデルの入力信号が混ざるため、研究ごとに位置合わせ誤差と時間差を別々に報告しなければなりません。

タンザニア南部高原の小規模人工林で行われた最近の研究は、この問題に一つの手掛かりを加えました。MauyaとJonasの両研究者は、雲の多い地域でSentinel-1レーダーとSentinel-2光学データをランダムフォレストとサポートベクターマシン（

SVM) モデルで融合すると、光学データだけを使った場合より、小規模農家が植えた木の樹種分類精度が上がったと報告しました。梅雨時の管制室で出会った白い画面の問題に対する答えが、一つずつ積み上がっているのです。

光と電波とレーザーを一つに

三つのセンサーは森林の異なる性質を見ます。光学センサーは可視光、近赤外、短波赤外の帯域で、葉のクロロフィル、水分状態、植生指数を読み取ります。ただし、葉が密に茂った区間では反射値が上限に達し、それ以上を区別できません。合成開口レーダーはSentinel-1のCバンドやALOS PALSARのLバンドのようなマイクロ波を照射し、雲に関係なく太い枝や幹から返る信号を捉えて森林内部の骨格を推測します。梅雨時に衛星写真が白く消えていた瞬間にも、マイクロ波は雲をそのまま通り抜けます。LiDARはレーザーパルスを照射し、木の高さ、樹冠体積、階層構造、地面の高低をセンチメートル単位で直接測ります。三つの目を同時に開けば、互いの空白を埋められます。

この三つのデータをAIモデルへ入れる方法は、大きく分かれます。入力段階で光学、レーダー、LiDARのチャンネルをつないで一つのニューラルネットワークへ入れる早期融合は、構造が簡潔ですが、標本に比べて入力次元が過度に大きくなると過学習の危険が高まります。センサーごとに別々のニューラルネットワークで学習させ、最終判断段階で投票や加重平均によって結合する後期融合は、センサーごとの特性を保ちますが、センサー間の微妙な相互作用を見落としやすい方法です。中間段階でCross-Attention構造により特徴を混ぜるハイブリッド融合は、計算量が増える代わりに、センサー別情報の関係をより深く学べます。

これらの方式が実際にどのような違いを生むかは、いくつかの現地研究に表れています。中国の山下と黄豊橋地域の亜熱帯混交林を対象にしたMTSCFNet研究は、ドローンLiDAR、超高解像度RGB画像、GF-2衛星画像を三つのエンコーダーと交差融合モジュールで結び、光学またはLiDARだけを使った場合より樹種分類精度を明確に高めました。この研究ではLiDAR装置RIEGL miniVUX-1UAVで1平方メートル当たり87.14点を記録しました。DJI M300 RTKドローンでは画素サイズ6.23センチメートルのRGB画像を集めました。中国ではこれとは別に、GF-2光学衛星とGF-3レーダー衛星のデータを重ねた公開データセットも最近作られ、森林、低木、草地の境界が曖昧に混じる地域を細かく分ける研究に使われています。ハイパースペクトルとLiDARを組み合わせた別の研究では、光学データだけを使った全体精度が80.39%にとどまったのに対し、Cross-Attentionで二つのデータを結ぶと精度が89.60%まで上がり、9.21ポイント向上しました。全球樹高地図を作る研究では、寄与度はLiDARの直接観測値、地形変数、光学とレーダーの間接指数の順に高くなりました。

マレーシア・ボルネオ島のDeramakotとTangkulap熱帯雨林では、Komatsu Kotaroらの研究陣がドローンRGB画像からフタバガキ科の木を自動識別し、衛星データとランダムフォレストモデルに結びました。ドローン画像だけでフタバガキ科の木を識別した精度は、生産者精度0.71、利用者精度0.67でした。現場標本なしに衛星データだけを使ったモデルは説明力0.43、誤差は1ヘクタール当たり70.60メガグラムでした。ドローンから得た変数を加えると、説明力は0.51へ上がり、誤差は60.53メガグラムまで減りました。現場を歩き回って標本を数える費用を大きく節約できるという意味です。

ロシア・サハリンの管理林では、林分小班データ、Sentinel-2時系列、地形データをランダムフォレスト、XGBoost、TabNetの三つのモデルへそれぞれ入力して競わせた研究もありました。XGBoostは他の二つより、樹高、胸高断面積、木材蓄積量、炭素蓄積量の誤差がすべて小さく、統合説明力0.68を記録しました。

ボルネオのドローン調査と江原道の自律飛行ドローン調査が示す方向は同じです。人がなたを持って森林をかき分け、木を1本ずつ数える代わりに、空と地面の間どこかの層で機械が代わりに数える方向へ、はかりは傾いています。そのはかりをどれほど信頼できるかが、次の問題です。

食い違う結果と残された課題

技術が急速に増えるほど、研究ごとに異なる答えが出ます。マツのように一樹種だけで構成された森林では、LiDARが測る立体構造、すなわち樹冠幅、高さ、枝の配置が、樹種とバイオマスを見分ける上で大きな役割を果たします。葉色がまだ目立って変わっていない初期被害木を探す作業でも、光学指数と立体構造を同時に見る手法が研究されています。反対に、生物種が混じり、低木まで絡み合う熱帯・亜熱帯混交林ではLiDARだけでは足りず、光学とハイパースペクトルが捉える葉と水分の信号も見する必要があります。どの融合方式が優れるかは、センサーの位置合わせ、標本数、森林の形によって変わります。

現場へそのまま移しにくい問題も残っています。一つの地域で高精度を出したモデルも、樹種と季節が異なる森林では再調整が必要です。木が密に茂る閉鎖林では、衛星やドローンのレーザーと光学信号が下層と地面まで届かず、幹の直径と下層植生の推定値に誤差が積み重なります。森林の下を低く飛ぶドローンも、衛星測位信号が切れると自分の位置を再計算しなければなりません。光が足りず、枝が風に揺れると、視覚慣性オドメトリ（VIO）と自己位置推定・地図作成（SLAM）の位置誤差が大きくなります。3次元ニューラルネットワークとVision Transformerは、入力サイズと装置によって大きなメモリーと電力を必要とするため、現場機器に組み込むにはモデルの軽量化と装置別の速度試験が必要です。

この壁を低くする試みも続いています。知識蒸留、モデル量子化、専用半導体アクセラレーションによって三重モーダルモデルを縮小し、ドローンと現場端末で動かす研究が進んでいます。Grad-CAMやSHAPのような説明可能な人工知能は、ニューラルネットワークが何を根拠に判断したのかを画面に示します。木の季節変化と土壌水分の物理モデルを制約条件としてニューラルネットワークに入れ、生態学的に外れた答えを減らす方向もあります。TreeSatAI、PureForest、ForestSemantic-MSのように複数の地域とセンサーを網羅する公開データセットが広がるほど、朝鮮半島の森林に合わせてモデルを整える基盤も厚くなります。

出典・参考文献

1. de Conto, T., Armston, J., & Dubayah, R. (2025). Scalable deep fusion of spaceborne lidar and synthetic aperture radar for global forest structural complexity mapping. arXiv:2510.06299. <https://arxiv.org/abs/2510.06299> (2026年8月2日閲覧)
2. European Space Agency. (2025a, 11月4日). Copernicus Sentinel-1D launch highlights. https://www.esa.int/ESA_Multimedia/Videos/2025/11/Copernicus_Sentinel-1D_launch_highlights (2026年8月2日閲覧)
3. European Space Agency. (2025b, 12月19日). Biomass' first open data products now available. Earth Online. <https://earth.esa.int/eogateway/news/biomass-first-open-data-products-now-available> (2026年8月2日閲覧)
4. Forkuo, G. O., & Borz, S. A. (2026). Deep learning-based computer vision in forest monitoring and management: a systematic review. Biodiversity and Conservation, 35(208), 1-37. <https://doi.org/10.1007/s10531-026-03412-x>
5. Jung, M., Choi, J., Carpenter, J., Fei, S., & Jung, J. (2025). Individual tree biomass estimation using single-scan terrestrial laser scanner with efficient projection-based deep learning. Journal of Forestry. <https://doi.org/10.1007/s44392-025-00065-6>
6. Komatsu, K., Takeshige, R., Onishi, M., Fujiki, S., Imai, N., Miyamoto, K., Aiba, S., Kitayama, K., Tsen, S. T. L., Nilus, R., Dawat, J., Pereira, J., Onoda, Y., & Aoyagi, R. (2026). Quantifying carbon stock and tree community composition in tropical forests through combining satellite and UAV analyses. Scientific Reports, 16. <https://doi.org/10.1038/s41598-025-34938-9>
7. Mauya, E. W., & Jonas, J. (2026). Integrating Sentinel-1 SAR and Sentinel-2 multispectral data for tree species classification and mapping in smallholder planted forests of Tanzania. Discover Forests. <https://doi.org/10.1007/s44415-026-00085-w>
8. NASA Earthdata. (2026年7月20日). NISAR L-band data released, expanding record of surface changes. <https://www.earthdata.nasa.gov/news/nisar-l-band-data-released-expanding-record-surface-changes> (2026年8月2日閲覧)
9. Takhtkeshha, N., Bocaux, L., Ruoppa, L., Remondino, F., Mandlbürger, G., Kukko, A., & Hyyppä, J. (2026). 3D forest semantic segmentation using multispectral LiDAR and 3D deep learning. PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 94, 377-397. <https://doi.org/10.1007/s41064-025-00369-4>
10. Tasuev, U., Tregubova, P., Illarionova, S., Shadrin, D., Bernshteyn, A., & Burnaev, E. (2026). Machine learning-based geospatial assessment of forest structure characteristics and sequestration potential for informed carbon stocks inventories. Scientific Reports, 16, 20872. <https://doi.org/10.1038/s41598-026-50929-w>

11. Wang, L., Zhang, H., Fu, R., Lei, K., Liu, Y., Yang, T., Zhang, J., & Ge, X. (2026). MTSCFNet: a novel framework for improving tree species classification in a subtropical forest using RGB, LiDAR-derived, and GF-2 data. *Journal of Forestry Research*, 37(1), Article 22. <https://doi.org/10.1007/s11676-025-01964-2>
12. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
13. NewsPim. (2026年7月3日). 韓国初の農林衛星打ち上げ、農作物の生育から災害まで3日ごとに精密観測. <https://www.newspim.com/news/view/20260703000799> (2026年8月2日閲覧)
14. Herald Economy. (2026a, 1月28日). 山林庁、森を駆け巡る「自律飛行ドローン」の時代を開く. <https://biz.heraldcorp.com/article/10665629> (2026年8月2日閲覧)
15. Herald Economy. (2026b, 3月31日). Hancom InSpaceのハイパースペクトル衛星「Sejong 3」、地上局との通信に成功. <https://biz.heraldcorp.com/article/10706270> (2026年8月2日閲覧)

1.3

森林専用大規模言語モデル（ForestGPT）と知的意思決定支援

江原道のある地域森林組合の事務所、午後3時を少し回った時刻です。窓の外から晩夏の日差しが斜めに差し込み、担当者の机の上には森林資源法施行規則の冊子と、角がすり減った林業便覧が並んで開かれています。今日の午前だけで、マツ材線虫病防除区域で伐採した枯死木を村の空き地に一時的に積んでもよいかと尋ねる電話が3件ありました。法令集の索引をめくり、便覧の付録を探し、去年の公文書ファイルまで開いても、正確な答えは出ません。結局、担当者は便覧を閉じ、パソコン画面の検索欄に質問をそのまま入力します。マツ材線虫病による枯死木は、どこで燻蒸処理を終えなければならないのか。

このような質問をAIチャットボットに投げかける人が増えています。膨大な文章を学習し、人のように文を作る大規模言語モデル（LLM、Large Language Model）は、今では大抵の質問に滞りなく答えます。問題は答えが間違っていたときに起こります。ChatGPTやClaudeのような汎用モデルは、インターネット上の膨大な文章を学びましたが、森林法規や林業仕様書のように狭く専門的な文書は相対的に少ししか読んでいません。そのため森林に関する質問を受けると、建設や一般工学で学んだ知識を引き寄せ、もっともらしくつなぎ合わせた答えを出すことがあります。モデルが存在しない事実をあるように作り出すこの現象を、ハルシネーションと呼びます。自信に満ちた顔でうそをつく人に似ています。森林の現場でハルシネーションは、軽い笑い話では終わりません。燻蒸基準を誤って案内された担当者が枯死木を不適切に処理すれば、マツノザイセンチュウが隣の森林へ広がるおそれがあります。傾斜度基準を誤って案内されたまま伐採すれば、梅雨時の地滑りにつながりかねません。

林業工学全般にAIが広がる流れを整理した学術誌Current Forestry Reportsの2026年のシステムティックレビューで、Forkuoらは、この流れがセンサーや衛星写真のような構造化データの処理を越え、法規、指針、報告書のような非構造化文書の処理へ広がっていると指摘します。構造化データを扱うAIは、森林面積や樹高のように数値で明確に表せる値を計算しますが、非構造化文書を扱うAIは文を読み、文脈を理解しなければなりません。後者の方がはるかに難しい作業です。

この隙間を埋めようとする試みが、森林専用大規模言語モデル、略してForestGPTです。オーストリアの研究者Ehrlich-Sommer、Eberhard、Holzingerが2025年に学術誌Electronicsで発表した論文は、このモデルを森林専門家のそばに控えながら、最終判断は人に委ねる助手として描きます。研究陣は開発経路を四段階で提案しました。森林資料を読む対話型ツールから始め、検索拡張生成、成長シミュレーター、現場センサー接続へ進む構想です。2025年のFuta Expoで試験したのは、約1メガバイトの選別資料で来場者を案内する第1段階の多言語チャットボットでした。検索拡張生成、シミュレーター、センサー結合は、まだロードマップ上にあります。

韓国でも同様の流れが始まりました。国立山林科学院は森林ビッグデータとAIを結び付ける初のコンテストを開き、7チームを表彰しました。ディープラーニング、生成AI、自ら判断して動くエージェント技術を森林政策と現場サービスにつなげる実験が、大学とスタートアップへ広がっています。

法律を代わりに探して読む助手

ForestGPTのような森林特化モデルが使う技術は、大きく二つに分かれます。一つはベースモデル内部の重みそのものを再学習するファインチューニングです。もう一つはモデルの重みをそのままにし、質問するたびに関連法規と指針文書を一緒に与える検索拡張生成（RAG、Retrieval-Augmented Generation）です。森林分野では後者が広く使われます。法規は頻繁に変わり、モデル全体を再学習するには多くの時間と費用がかかるからです。RAG方式では質問が入ると、モデルはまず関連文書の保管庫を検索し、根拠となる条項を探し、その条項を引用しながら答えを作ります。根拠文書を見つけれないときは、答えを作り出す代わりに分からないと答える設計が、ハルシネーションを防ぐ実質的な方法として定着しました。

欧州連合のFOREST4EUプロジェクトが作った対話型エージェントFarm Assistantは、この原理を示す事例です。農家と林家の知識を集めたデータベースFarmBookにつながっており、山火事を防ぐ放牧形態やバイオマスを減らす方法を尋ねると、根拠資料の番号を付けて答えます。反対に、外部の政治家の発言のようにデータベースにない内容を尋ねると、答えを作らず、その情報を持っていないとはっきり言います。アルメニアでは、American University of Armenia（AUA）のAcopian Center for the Environmentと、スイス連邦森林・雪・景観研究所（WSL）が協力し、気候変動影響評価と国家報告書の作成を担う政策担当者を助ける対話型チャットボットを作りました。森林科学の背景知識が乏しい公務員も、このチャットボットの助言を受けながら再造林計画を立て、炭素吸収源を計算できます。

ハルシネーションを完全になくす技術は、まだ登場していません。根拠文書を検索して答えを支えるRAG、不確実性推定、自己整合性検査、回答の安全装置は誤りを

減らせますが、性能はモデルと試験データによって異なります。肥料量や防除時期のように、間違えばその年の農業を台無しにしかねない助言は、人の専門家が最終確認しなければなりません。伐採許可や燻蒸基準のように、間違いが罰金やマツノザイセンチュウの拡散につながる質問ほど、モデルの答えは参考資料であり、最終承認ではないという線を明確に引く必要があります。

危険な現場を守る助言者

法典の前でためらっていた事務所の午後は、まだ安全です。山に入った伐採作業員には別の危険が待っています。林業は事故率の高い産業です。木が倒れる方向を見誤ったり、斜面でチェーンソーを使って滑ったりする事故が毎年繰り返されます。日本の近畿大学の研究陣は、この問題をゲームとAI助言エージェントで解こうとしました。ChatGPTベースのエージェントに安全指針と専門知識カードをあらかじめ入れ、研修生が現場状況を説明すると、エージェントが危険要因を指摘する方式です。知識を事前に入れる処理をする前は、第1回と第2回を合わせて8件の誤答と文脈逸脱が出ました。処理後は第3回と第4回を合わせた誤答が2件に減りました。40項目で構成された安全行動尺度の点数も、教育前より目立って上がりました。

現場で音声命令を出す実験では、別の問題が明らかになりました。防護服を意味するチャップス（Chaps）や、伐倒木が別の木に引っ掛かり、完全には倒れていない状態を指す日本語の「かかり木」といった林業専用用語が、自動音声認識（ASR、Automatic Speech Recognition）の段階で無関係な単語に誤変換されました。誤変換された単語は、人の話し言葉と書き言葉をコンピューターが理解できるよう処理する次の段階、自然言語処理（NLP、Natural Language Processing）へそのまま渡され、文脈から外れた答えをさらに膨らませました。騒音が大きく、信号が途切れやすい山中ではよく起こることです。研究陣は専門用語辞書を別途作って追加し、認識された文を人がもう一度確認する手順を入れる方法を解決策として提案しました。

目で見える監視では別の方法が使われます。Kunduらが2025年にScientific Reportsで発表した研究は、物体検出モデルYOLOv8とLangChainベースのエージェントを接続しました。ドローンと衛星写真から切り株、伐採機械、許可を受けていない人員を探し、森林破壊の疑いがある区域をGIS報告書にまとめる構造です。学習損失は減り、最大再現率は0.24でしたが、mAP50は約0.07にとどまりました。小さな切り株と機器を安定して見つける現場システムと見なすには性能が低く、人による再確認が必要です。

どれだけ伐り、どこへ運ぶか

知的意思決定支援システム（DSS、Decision Support System）は、複数の条件を一度に計算して選択肢を比較する道具です。森林経営では、木材生産、作業員の安全、土壌侵食、炭素貯蔵が一つの計画内でぶつかります。Eberhardらは2025年のプレプリントで、傾斜、土壌侵食リスク、残存木への損傷をともに考慮し、ケーブルヤーダ、フォワーダ、ウインチ補助機器を比較するGISベースのモデルを提案しました。査読を終えた現場運用システムではありません。

DengとFengは、伐採木を運ぶトラックの配車と経路問題を遺伝的アルゴリズムで解きました。生物が世代を重ね、よりよい形質を残す過程を模したこの計算方式は、複数の候補経路を作って競わせ、生き残った経路を少しずつ変えながら最適な配車表を見つけます。Görgensらはそれ以前に、作業道が土を踏み固める程度を抑えながら伐採量を増やす、多目的最適化計画アルゴリズムを構築していました。

森林経営の成果を金銭だけで測らず、複数の尺度で同時に測ろうとする試みもあります。投入資源と、そこから生まれた成果の比率を計算し、効率の高い森林経営単位とそうでない単位を見分ける統計手法を、データ包絡分析（DEA、Data Envelopment Analysis）と呼びます。過去30年間に蓄積した森林分野のDEA研究を検討したZadmirzaeiらの2026年のレビュー論文によると、近年のDEAはAIと急速に結び付いています。入力変数を選ぶ際にはランダムフォレストで主要因を絞り、ニューラルネットワークで効率性スコアを予測し、運用効率、木材収益、環境保全、炭素固定という異なる目標を同時に最適化する遺伝的アルゴリズム系の手法NSGA-IIをDEAと組み合わせ、具体的な政策シナリオを作る研究が増えています。

長期予測では、国家単位の統計が力を発揮します。タンザニアの国家森林資源調査（NAFORMA）データを機械学習と結び、2054年までの森林面積変化を予測した研究がその例です。2014年に4,809万ヘクタールだった森林・ウッドランド面積は、従来の開発傾向をそのままにするシナリオでは3,299万ヘクタールへ減ります。開発圧力が大きいシナリオでは2,830万ヘクタールまで落ちます。一方、持続可能な管理を適用するシナリオでは減少幅が目立って縮まり、政策決定に使える定量的根拠を示します。

木と作物を一緒に育てるアグロフォレストリーにも、計算が入り込んでいます。インドネシアのRidloらは、コーヒーの木の中に日陰を作るシェードツリーをどこに植えれば、湿度と二酸化炭素濃度を適切に保てるかをグラフ理論で解きました。グリッド状に作った農地図面にRIDS、すなわちResolving Independent Dominating Setsというグラフアルゴリズムを適用してシェードツリーの植栽位置を決め、スマートセンサーで集めた湿度と二酸化炭素データを時空間グラフニューラルネットワー

ク（STGNN、Spatial-Temporal Graph Neural Network）へ入れ、10日から20日先の微気候変化を予測しました。コーヒーの木96本にシェードツリー26本を植えた区画は、年間520キログラムの二酸化炭素を保持すると計算されました。グリッド状にシェードツリー31本を植えた区画は、年間620キログラムを保持すると計算されました。予測誤差を示す指標は既存の比較モデルより低く、予測が実測値をどれだけ説明するかを示す説明力は0.73から0.81となり、他の方法を上回りました。

自信に満ちた誤答を見分ける方法

研究結果を並べると、互いに衝突する主張が出てきます。ChatGPTのような汎用大規模言語モデルは、幅広い常識と多言語を行き来する柔軟性では優れますが、森林法規や作業安全規則のように狭く専門的な質問では、ハルシネーションが頻繁に起こります。反対に、根拠文書へ答えを結び付けるRAGベースのモデルやForestGPTは、法規照会の正確性と根拠提示力は高い一方、指定された知識保管庫の外の質問には回答を拒むよう設計されており、自由な対話は難しくなります。正確さと自由さを同時に得ることは、まだ容易ではありません。

計算方式の間にも同じ緊張が現れます。従来のDEAモデルは、効率性スコアがどのような計算で出たかを線形式で明確に示し、政策担当者が受け入れやすい方式です。一方、ディープラーニングベースの予測モデルは、精度が高い代わりに、内部でどのような計算が行われたかを見通しにくいブラックボックスのままです。法的根拠として引用しなければならない政策文書では、この不透明さが障害になります。

技術の外的問題も容易ではありません。林業自動化と自律判断エージェントの導入は速まっていますが、森林政策と法制度は、AIが自ら下した判断に誰が責任を負うかをまだ整理できていません。エージェントが誤った安全指針を出して事故が起きた場合、現場管理者と開発会社のどちらの責任かを判断するのは困難です。スウェーデンの研究者Bergqvistらは、2026年のHawaii International Conference on System Sciences（HICSS）で、林業現場はデータが標準化された他産業と異なり、記録方式がばらばらで紙文書も多く残るため、自動化より先にデータ整理が必要だと指摘しました。伐採から加工、流通へ続くデータが機関ごとに別々に蓄積するデータサイロの問題も、統合意思決定を遅らせます。大規模言語モデルと時空間グラフニューラルネットワークは、大きなグラフィックス計算資源を必要とします。インターネットが途切れやすい奥地の森林のドローンや携帯機器では、計算の遅れと記憶容量の不足がそのまま残っています。

今後解くべき課題も明確です。SHAPやGrad-CAMのように、モデルがなぜその判断をしたかを示す説明可能な人工知能を意思決定エンジンへ付けなければなりません。森林法規と労働安全基準に合う指針も必要です。量子化と知識蒸留でモデルを

縮小した後、LoRa無線網や5G基地局の少ない森林で、装置別の応答時間と電力消費を試験しなければなりません。国家と地域を越える森林データ共有体制と標準ベンチマークも残された課題です。

言語モデルだけがこの流れに乗っているわけではありません。地理空間基盤モデル Prithvi は、米国航空宇宙局（NASA）と IBM が共同開発しました。圧縮モデルは 2026 年 5 月、オーストラリアの Kanyini 衛星と国際宇宙ステーション（ISS）の IMAGIN-e 装置で動作しました。軌道上実証が処理した任務は、洪水と雲の検出でした。森林高と伐採痕跡の分析は地上で可能な応用分野として示されており、今回の軌道試験結果とは区別しなければなりません。

森林の現場で AI に尋ねる質問は今後ますます増えるでしょうが、その答えの後ろにどの文書が根拠として付いているかを確かめる作業は、当分の間、人が自ら担わなければならないようです。モデルは法規を要約し、危険を事前に指摘し、トラックの経路を計算するところまで来ています。ただし、自信に満ちた一文が実際には誤答である可能性は変わりません。決裁欄には今も人の署名が入ります。

出典・参考文献

1. AUA Acopian Center for the Environment, & WSL. (2026年7月). A validated predictive framework: Climate-smart reforestation and resilience mapping in Armenia [Video]. YouTube. <https://www.youtube.com/watch?v=LBrq1KNUUyE> (2026年8月2日閲覧)
2. Bergqvist, M., Nylén, D., Lindberg, A., & Åkesson, M. (2026). Digital innovation in data-poor and unstructured environments: Envisioning autonomous systems in forestry. In T. X. Bui (Ed.), Proceedings of the 59th Hawaii International Conference on System Sciences (pp. 5881-5890). University of Hawaii. <https://doi.org/10.24251/HICSS.2026.697>
3. Deng, W., & Feng, X. (2025). A genetic algorithm for forest logging trucks routing and scheduling problem. Forests, 16(9), 1440. <https://doi.org/10.3390/f16091440>
4. Eberhard, B., Trailović, Z., Magagnotti, N., & Spinelli, R. (2025). A GIS-based decision support model (DSM) for harvesting system selection on steep terrain: Integrating operational and silvicultural criteria. Preprints, 2025011137. <https://doi.org/10.20944/preprints202501.1137.v1>
5. FOREST4EU Project Consortium. (2025年11月). Webinar: Exploring the role of knowledge repositories: Farm Assistant chatbot demo [Video]. YouTube. <https://www.youtube.com/watch?v=slRhC5sfbjA> (2026年8月2日閲覧)
6. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. Current Forestry Reports, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
7. Görgens, E. B., Mund, J. P., Cremer, T., de Conto, T., Krause, S., & Valbuena, R. (2020). Automated operational logging plan considering multicriteria optimization. Computers and Electronics in Agriculture, 170, 105253. <https://doi.org/10.1016/j.compag.2020.105253>
8. Hayashi, K., Shimazaki, K., Takahashi, A., Ikeda, M., & Matsumoto, Y. (2026). Practice of forestry safety education game by AI advisor and verification of learning effectiveness. Journal of Occupational Safety and Health, advance online publication. https://www.jstage.jst.go.jp/article/josh/advpub/0/advpub_JOS

H-2025-0011-GE/_pdf

9. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
10. Ridlo, Z. R., Dafik, Waluyo, J., Yushardi, & Venkatachalam, M. (2025). On RIDS analysis for shade tree placement and its application to STGNN multi-step forecasting on RH and CO2 concentration of coffee agroforestry. *Statistics, Optimization & Information Computing*, 14(4), 1889-1908. <https://doi.org/10.19139/soic-2310-5070-2643>
11. Ehrlich-Sommer, F., Eberhard, B., & Holzinger, A. (2025). ForestGPT and beyond: A trustworthy domain-specific large language model paving the way to Forestry 5.0. *Electronics*, 14(18), 3583. <https://doi.org/10.3390/electronics14183583>
12. Zadmirzaei, M., Cozzi, M., Romano, S., Amirteimoori, A., & Viccaro, M. (2026). Data envelopment analysis in forestry over three decades: An in-depth review of models and emerging directions. *Environment, Development and Sustainability*. <https://doi.org/10.1007/s10668-026-07610-z>
13. Zella, A. Y. (2026). Sustainable forest and land-use management in Tanzania: NAFORMA-based and machine learning forecasts to 2050 under Tanzania Dira 2050. *International Journal of Development and Management Review*, 21(1), 1-36. <https://doi.org/10.4314/ijdmr.v21i1.1>
14. 大韓民国政策ブリーフィング. (2026年7月24日). 森林の懸案にAIで挑戦、国立山林科学院がコンテストを開催. <https://www.korea.kr/briefing/pressReleaseView.do?newsId=156751645> (2026年8月2日閲覧)

第2章

精密林業（Precision Forestry）：単木解析とバイオマス・炭素の精密測定

2.1

UAV-LiDARと高解像度画像に基づく単木（Individual Tree）の樹種分類

霧がまだ晴れきらない夜明け、江原道の山麓にあるチョウセンゴヨウ造林地の上へ、1機のドローンが低く浮かび上がります。プロペラ音が谷に沿って散り、ドローンは畑を耕すトラクターのように、格子状に空を往復します。機体の下にはLiDAR、すなわちLight Detection and Rangingが吊られています。1秒に数十万回レーザーを照射し、その光が葉や枝に当たって戻る時間を測り、距離を計算する装置です。ドローンが一度通過するたび、数千本のチョウセンゴヨウの輪郭が、空から点一つ一つとして記録されます。この点をすべて集めると、森林全体ではなく、1本の木が立つ位置、高さ、枝の伸び方まで現れます。

林業は長い間、森林を林分（Stand）、つまり木が集まった塊の単位で管理してきました。ある区域にマツが何本ほどあるか、平均の高さはいくらかを概算する方式でした。精密林業は、この計算単位を1本の木まで下げます。木が1本ずつどこに立っているかを特定する作業を単木検出（Individual Tree Detection、ITD）と呼び、その木の葉と枝が占める領域だけを切り出す作業を単木樹冠分割（Individual Tree Crown Delineation、ITCD）と呼びます。以前は人が直接山に登り、巻き尺と目測で木を数えたり、Watershed Segmentationという方法で航空写真の明るさが低下する境界を探して木を分けたりしました。枝が空を隙間なく覆うほど密な森林や、複数の樹種が混じって育つ混交林では、この方法がたびたび誤りました。接する2本の木を一つにまとめる過少分割、1本の枝を別の木として誤って分ける過剰分割が繰り返されました。

この限界を越えるため、無人航空機レーザースキャニング（UAV-LiDAR）が作る3次元点群、すなわちレーザーの反射で記録された数百万点を集めたデータと、高解像度画像をコンピュータービジョンのディープラーニングに結び付ける研究が急増しています。韓国でも同様の組み合わせがすでに現場に入っています。山林庁は2025年9月、マツ材線虫病が再び広がると、ヘリコプターとドローン調査にAIとLiDAR技術を組み合わせ、感染が疑われるマツを自動で選び出すシステムを発表しました。人が山を歩き、木を1本ずつ調べていた作業を、空から撮った点群と画像

が代わりに選別するわけです。ただし、この作業は病木を見つける選別段階であり、木の種類そのものを見分ける樹種分類とは目的が異なります。

1本の木の輪郭を描くディープラーニング

リアルタイム物体検出アルゴリズムのYOLO、すなわちYou Only Look Onceの系列は、写真を一度走査し、物体の位置と種類を同時に見つける構造です。計算が速いため、樹冠検出にも使われます。ベトナムのDong Nai地域にあるPinus kesiya人工林で、Nguyen Thanh Tuanの研究陣はUAV-LiDARと高解像度航空写真を重ね、YOLOv8m-Seg、YOLOv11m-Seg、YOLOv12m、汎用分割モデルSAM2を比較しました。元のSAMは約1,100万枚の画像と10億個を超える分割マスクで学習し、SAM2は大規模動画データへ拡張されたモデルです。

YOLOv11m-Segは木の検出でmAP50 0.62、F1スコア0.59を記録しました。YOLOv12mとSAM2を組み合わせたモデル、YOLOv8m-Segはこの数値に達しませんでした。マツの樹冠が密に重なる区域では、現場データで学習したモデルが汎用分割モデルを上回りました。この境界とLiDAR点群を重ね、実測値と比較すると、樹高推定の説明力は0.85から0.93でした。樹冠幅推定の説明力は0.58から0.86でした。一つの地域の造林地で得た結果なので、他の樹種と天然林では再検証が必要です。

衛星画像と航空写真を一緒に使う別の研究チームは、YOLOv5と密度推定ニューラルネットワーク、Faster R-CNN系列を結んだBROハイブリッドモデルを発表しました。Battle Royal Optimisationという探索手法でマルチスケールアップサンプリングを調整し、木がまばらに立つ区間でも密集する区間でも、木の本数を数えるよう設計しました。このモデルは木の本数推定精度97.8%、平均絶対誤差（MAE）0.0912を記録しました。

樹冠の細かな曲線を描くには、U-Net系列のニューラルネットワークも広く使われます。画像を小さく圧縮した後、元の大きさへ戻しながら細部の輪郭を復元する構造で、圧縮前の情報を飛び越えて伝えるSkip Connectionのおかげで、枝のような細い境界もぼやけません。中国安徽省績溪县と広西チワン族自治区の亜熱帯混交林で、Wang Linlongの研究陣がMTSCFNetを開発しました。入力データは、DJI M300 RTKにZenmuse P1を搭載して撮影したUAV-RGBカメラ画像です。RIEGL miniVUX-1 UAVで集めたLiDAR点群と、中国のGF-2衛星画像も同時に受け取ります。LiDAR点の密度は1平方メートル当たり87.14点でした。エンコーダーを三つに分けてデータを別々に処理した後、結合するTriple Branch Feature Fusionモジュールを加え、センサー一つだけを使うモデルより、樹冠領域分割と樹種分類の両方で重なり精度指標が上がりました。

高解像度の可視光オルソ画像だけで、密な樹冠を分けようとする試みもあります。FSC-Mask2Formerというこの方法は、縦横512画素に切った写真958枚を学習に使いました。それぞれの写真に、合計7,636本の木の輪郭を精密に描いた正解データを付けました。写真のテクスチャ情報に加え、周波数領域、すなわち色と明るさがどれだけ頻繁に繰り返し模様として現れるかを見る方法から抽出した特徴と、似た木同士は近く、異なる木同士は遠くなるよう学ぶContrastive Learningと一緒に適用し、葉の密な混交林で木の境界を分ける誤差を目立って減らしました。

3次元点群を点ごとに直接処理するニューラルネットワークには、Point Transformer V3 (PTv3) があります。文中の単語間の関係を調べていたSelf-attention、すなわちデータの各部分が互いにどれほど関係するかを自ら計算する方式を、3次元の樹木構造へ移して適用したモデルです。三つの波長帯を照射するマルチスペクトルLiDARで撮った点群を、PTv3、KPConv、Superpoint Transformer (SPT)、ランダムフォレストの四つのモデルへ入れ、森林を地表、低い植生、幹、枝、葉、木質残材まで六層に分けた研究があります。この比較でPTv3は重なり精度 (mIoU) 69.1%を記録し、他の3次元モデルを21.8ポイント上回りました。

2026年1月に発表された関連メタ分析は、この流れを数値でも示します。Aldaeriの研究陣が単木検出論文を集めて調べたところ、木を個別に切り出すインスタンスセグメンテーション方式が全体の約46%を占め、入力データでは一般RGB航空写真を使う研究が73%で最も多くなりました。LiDAR単独より、写真と樹冠高モデル (Canopy Height Model、CHM、樹冠頂部の高さを地図のように表したデータ) を一緒に使う組み合わせが一般的だという意味です。

混じり合う森林で木の名前を見分ける

樹冠を個別に切り出した後は、その中の色、テクスチャ、3次元の起伏を見て、具体的にどの木かを識別する段階へ進みます。上層の高木と下層の低木の反射光が混じり、木ごとの標本数にばらつきがあり、希少な木は写真自体が数枚しかない混交林では、この作業が難しくなります。

欧州で作られたマルチセンサーベンチマークデータセットTreeSatAI、主要15樹種を含むデータを使い、UAV航空写真とSentinel衛星画像を一緒に分析したMMTSC、すなわちMulti-branch Multi-label Tree Species Classificationの研究を、Qin TianyiとZhao Qingjianが2025年にScientific Reportsで発表しました。研究者は樹種を見分けるAIの基幹ニューラルネットワークとして、DenseNet121、EfficientNet-B0、ConvNeXt-Tinyなど六つを並べて比較しました。樹種ごとの標本

数が大きく異なる条件でも、DenseNet121を基幹に使ったモデルの成績が他の五つを上回りました。F1スコアは約72%、適合率（Precision）は約82%でした。

マレーシア・ボルネオ島のDeramakotとTangkulap森林管理区（FMU）では、DeepForest（DF Scanner Pro）とEfficientNet-B4ニューラルネットワークを使い、熱帯雨林で高く抜きん出て育つフタバガキ科の木とその他の木を見分けました。フタバガキ科の木を実際に正しく当てた割合（Producer's Accuracy）は0.71、AIがフタバガキ科だと答えた木のうち実際に正しかった割合（User's Accuracy）は0.67でした。こうして識別した樹種情報を衛星ベースの機械学習モデルの学習材料に加えると、地上部炭素（AGC、Above-Ground Carbon）推定値の誤差が減ります。衛星写真だけを使ったモデルの誤差（RMSE）は1ヘクタール当たり70.60メガグラムでしたが、ドローンで確認した樹種情報を加えると、誤差は1ヘクタール当たり60.53メガグラムまで下がりました。

2026年1月にScientific Reportsへ掲載されたKomatsu Kotaroらの論文は、より広い地域でも同じ流れを確認しています。マレーシアとインドネシアの395調査区で、衛星指標だけから炭素量と生物多様性指数を推定したとき、説明力は0.43と0.46にとどまりました。ドローン画像934件を加えると、説明力は0.51と0.48へ上がりました。ドローンが撮った1本ずつの木の情報が、衛星写真の粗い目盛りを細かく埋めるわけです。

混交林には標本が極端に少ない希少樹種が混じるため、一般的な損失関数、すなわちモデルがどれだけ間違ったかを計算する方法をそのまま使うと、個体数の多い樹種へ予測が偏ります。この偏りを直すために登場したM-MoENet（Multimodal Sparse Mixture-of-Experts Network）は、光学画像、Sentinel-1衛星レーダー（SAR）、地形標高データ（DEM）を同時に入力し、エンコーダー内に少数樹種を専門に扱う小型エキスパートモデルを複数組み込みます。予測の確信度が低いときは、これらのエキスパートへ判断を渡すConfidence-adjusted Gatingも併用します。Louの研究陣が報告した結果によると、全体精度（OA）は79.46%、重なり精度（mIoU）は60.08%、カッパ係数は0.74でした。標本の少ない常緑マツやシナノキのような木が地図から消えたり、飛び飛びに途切れて現れたりする問題も大幅に減りました。

キプロスの主要9樹種を分類した研究は、別の解決策を示します。ResNet50を基幹に使いながら、モデルが付けた暫定正解で学習を補う弱教師あり学習を組み合わせました。RGB、近赤外、地形、土壌データを入力したモデルは、全体精度90%を記録しました。ラベル費用を半分以上削減したという数値は、研究で直接測定されていません。

研究ごとに異なる数値

樹冠分割と樹種分類技術は、実験ごとにかなり精密な数値を示しますが、樹種構造とセンサーの組み合わせにより結果が食い違う場合もはっきりしています。円すい形が明確なPinus kesiya、Pinus taedaなどの針葉樹単純林では、YOLOv11m-Segや樹冠高モデルに基づく分割モデルが、説明力0.85から0.93という高い樹高推定精度を示します。一方、葉が広がり、枝が絡み合い、枯れ枝も混じる亜熱帯・熱帯広葉樹混交林では、同じYOLO系列やMask R-CNNモデルを使っても、樹冠幅推定の説明力が0.58から0.68へ下がります。木の形そのものが整っているかどうか、AIの精度を分けるのです。

基盤モデルとドメイン専用モデルの順位が逆転することもあります。大規模な画像と動画データで学習したSAM2は、さまざまな物体の輪郭を分けられますが、枝が重なる森林では、林業データで学習したYOLOv11m-Segより誤検出が多くなりました。巨大な汎用モデルも、現場に合わせた微調整の代わりにはなりません。

空から見落とすもの

どれだけ精密にドローンを飛ばしても、空からは見えない場所があります。上空の光学カメラとLiDAR信号は、葉が密に空を覆う森林の下部、中層、下層の木まで貫けません。そのため、低い木が上にある大きな木の樹冠へ誤ってまとめられるエラーが繰り返し起こります。

ディープラーニングモデルを学習するには、木ごとに2次元または3次元の輪郭を精密に描いた正解データが必要です。しかし、葉の密な森林では、経験豊かな現場専門家でさえ、どこまでが1本の木の樹冠かを人によって異なって判断します。この判断の差が、そのままアノテーションノイズとして残り、モデル学習に混ざります。精密な正解データを作る作業は、アルゴリズムを設計する作業に劣らず手間がかかるということです。

地域を移すと精度が落ちる問題もあります。特定の森林で高得点を出した樹種分類モデルも、地形、日差し、樹種構成が異なる森林では性能が下がる場合があります。下落幅はデータと評価指標によって異なり、一つの範囲にはまとめられません。

次の段階に残された課題

このような隙間を埋める試みは、すでに始まっています。ゼロショット基盤モデルSAM2に、UAV-LiDARが作った3次元樹冠高モデルの情報を層状に重ね、林業データで再学習するハイブリッド微調整研究が続いています。汎用性と精密さを同時に得ようとする試みです。M-MoENetやFSC-Mask2Formerのように、周波数成分分解、Contrastive Learning、複数のエキスパート小型モデルを組み合わせるゲーティングアルゴリズムを改良し、希少樹種の自動認識能力を高める研究も進んでいます。

2026年5月にGIScience & Remote Sensingへ掲載されたWang XinboらのCrown-BERTは、この方向の最近の事例です。樹冠ごとに形が異なることを反映し、有効な樹冠領域だけを選ぶDynamic Crown Maskingと、樹冠内の位置情報を埋め込むCrown Positional Encodingを加え、ラベルのない樹冠標本でも事前学習できる自己教師あり学習の段階を挿入しました。正解ラベルの少ない希少樹種からも、役に立つ特徴を抽出しようとする手法です。

TreeSatAI、PureForest、ForInstanceのように複数の生態系を網羅する3次元・2次元単木ベンチマークデータセットを拡張し、共有する作業も続けなければなりません。大陸と樹種によってモデル性能が大きく分かれる現在、データセット自体を広げる作業は、アルゴリズムを改良する作業に劣らず大きな比重を占めます。

出典・参考文献

1. Aldaeri, A. S. T. M., Kit, C. Y., Ting, L. S., & Abdul Rahman, M. R. B. (2026). Deep learning for tree crown detection and delineation using UAV and high-resolution imagery for biometric parameter extraction: a systematic review. *Forests*, 17(2), 179. <https://doi.org/10.3390/f17020179>
2. Bansal, H., Sinha, A., Agarwal, G., Mishra, S. K., Gupta, S., Chaudhary, P., Ashokrao, P. R., Kushwaha, A., Bagaria, M. K., Reza, M. S., Agrawal, A., Bhad, S., Khalid, S., Lasisi, A., & Aseere, A. M. (2025). A hybrid DL with Battle Royal Optimisation algorithm for accurate tree counting using satellite images. *International Journal of Computational Intelligence Systems*, 18(1), Article 222. <https://doi.org/10.1007/s44196-025-00928-y>
3. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
4. Komatsu, K., Takeshige, R., Onishi, M., Fujiki, S., Imai, N., Miyamoto, K., Aiba, S., Kitayama, K., Tsen, S. T. L., Nilus, R., Dawat, J., Pereira, J., Onoda, Y., & Aoyagi, R. (2026). Quantifying carbon stock and tree community composition in tropical forests through combining satellite and UAV analyses. *Scientific Reports*, 16, Article 5442. <https://doi.org/10.1038/s41598-025-34938-9>
5. Lou, T., Wang, Z., Zhang, W., Li, C., Gu, J., Zou, W., & Jing, W. (2026). Dominant tree species classification using a sparse mixture-of-experts framework. *Forest Engineering*, 42(3), 637-648. <https://doi.org/10.7525/j.issn.1006-8023.2026.03.019>
6. Nguyen Thanh Tuan, Phan Van Tuan, Nguyen Thanh Hung, & Duong Tien Duc. (2026). Individual tree detection and crown segmentation for *Pinus kesiya* using UAV-LiDAR and deep learning models.

- Dendrobiology, 95, 156-169. <https://doi.org/10.12657/denbio.095.011>
7. Qin, T., & Zhao, Q. (2025). Multi-branch and multi-label tree species classification using deep learning for UAV aerial photography and Sentinel remote sensing images. *Scientific Reports*, 15, Article 32710. <https://doi.org/10.1038/s41598-025-19827-5>
 8. Takhtkeshha, N., Bocaux, L., Ruoppa, L., Remondino, F., Mandlbürger, G., Kukko, A., & Hyypä, J. (2025). 3D forest semantic segmentation using multispectral LiDAR and 3D deep learning. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 94(3), 377-397. <https://doi.org/10.1007/s41064-025-00369-4>
 9. Wang, L., Zhang, H., Fu, R., Lei, K., Liu, Y., Yang, T., Zhang, J., & Ge, X. (2026). MTSCFNet: a novel framework for improving tree species classification in a subtropical forest using RGB, LiDAR-derived, and GF-2 data. *Journal of Forestry Research*, 37(1), Article 22. <https://doi.org/10.1007/s11676-025-01964-2>
 10. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, Article 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
 11. Wang, X., Zhao, Y., Han, Y., Zhao, Y., & Zhen, Z. (2026). Crown-BERT: a crown-morphology-aware deep learning framework for individual tree species classification using UAV LiDAR and hyperspectral data. *GIScience & Remote Sensing*, 63(1), Article 2671600. <https://doi.org/10.1080/15481603.2026.2671600>
 12. Yang, Z., Zhang, X., et al. (2026). 融合頻域感知与对比学习的无人机影像森林全要素解译方法：FSC-Mask2Former [FSC-Mask2Former: a forest panoptic segmentation method fusing frequency domain perception and contrastive learning]. *National Remote Sensing Bulletin*. <http://www.publish.founderss.cn/rc-pub/front/front-article/download?id=158241355&attachType=lowqualitypdf&siteId=91> (2026年8月2日閲覧)
 13. Digital Times. (2025年9月24日). AI・LiDARなどの先端技術を活用、マツ材線虫病の拡散を防ぐ. <https://www.dt.co.kr/article/12019894> (2026年8月2日閲覧)

2.2

地上部バイオマス（AGB）と森林炭素蓄積量の推定

1本の木の乾燥重量を直接確かめるには、のこぎりを持って根元を切り倒し、枝、幹、葉を分けて重さを量り、窯で水分を飛ばします。このような破壊的な直接測定は、相対成長式を作る基準値を得るために使われました。森林全体のバイオマスは、古くから胸高直径、樹高、木材密度に基づく相対成長式で推定されてきました。保護区域で木を伐らずに重量を計算できましたが、式を作った地域や樹種と異なると誤差が大きくなりました。

木の重さを知りたいのには理由があります。丸太を市場へ出して価格を付けるには体積と重量を知る必要があります、伐採と測定は長い間、一体となっていました。しかし、木を伐らずに重量を推測する道があります。幹の太さと高さだけを測り、樹種別に定めた計算式を通せばよいのです。

人の胸の高さで測った幹の直径を胸高直径（Diameter at Breast Height、DBH）と呼びます。これに樹高、木材密度、樹種・地域係数を入れ、木の体積と重量を推定する式が相対成長モデルです。太さと高さの関係は生育段階と環境によって変わり、一定の比例関係には固定されません。木が成長しながら幹と枝に蓄えた炭素を推測するには、このような誤差も計算に入れなければなりません。地上部バイオマス（Aboveground Biomass、AGB）の精度は、国家炭素会計と炭素市場の数値へ直接影響します。

しかし、DBHと樹高を手で測る作業も容易ではありません。調査員が巻き尺で幹の周囲を測り、測高器という角度測定器具で梢を見上げた角度を測った後、三角法で高さを計算する方式は、1本当たり数分かかります。森林一つをすべて測るには、複数の調査員が数日、時には数週間かかりきりになり、人によって幹をどこからどこまでと見るかの判断が異なるため、誤差も入り込みます。ここ数年、森林調査の重心は巻き尺からレーザーとカメラへ、調査員の両足からドローンと人工衛星へ移りつつあります。

地上レーザーとドローンが木を読む方法

地上レーザースキャナー（Terrestrial Laser Scanner、TLS）は木の周囲を回りながら光を何度も照射し、その光が戻る時間を測り、数百万点で構成される立体地図を描きます。この点の集まりを点群と呼びます。スキャナーを複数の場所へ移しながら撮る複数回スキャン方式は、木の裏側まで漏れなく収めますが、スキャナーを移し、各スキャンを一つにつなぐのに時間がかかります。調査する木が数百本なら、1日で終わることは困難です。反対に、1か所に立って一度だけスキャンする単一スキャン方式は数分で終わりますが、木の裏側が別の幹や枝に遮られ、点データにまばらな空白ができます。

米国インディアナ州のMartell Forestでは、37樹種が混じる温帯広葉樹林を対象に、単一スキャンTLSとCoAtNetを組み合わせました。正解値は、現場で測ったDBHを北米の汎用相対成長式へ代入して計算しました。試験木60本で決定係数は0.73でした。中央値百分率バイアスは0.99%でしたが、中央値絶対百分率誤差は25.06%、平均絶対百分率誤差は29.40%でした。バイアスが小さいという事実を、個々の木の誤差が1%未満だという意味に読むではありません。

空から見下ろす方法もあります。ドローンが撮った写真をつなぎ、ひずみを直した地図をオルソ画像と呼びます。衛星写真よりはるかに近くから撮るため、枝が1本ずつ鮮明に写ります。マレーシア・サバ州のDeramakotとTangkulap熱帯雨林では、ドローンで撮ったRGBオルソ画像とEfficientNet-B4というディープラーニングモデルを組み合わせ、フタバガキ科の樹冠、すなわち枝と葉が傘のように広がる木の上部を認識し、熱帯林用相対成長式を適用して炭素量を推定しました。現場標本なしに衛星画像だけで動かした基本モデルは、説明力0.43にとどまりました。ドローンで撮った樹冠構造情報を加えたモデルは説明力が0.51へ上がり、誤差は1ヘクタール当たり70.6トンから約60.5トンへ減りました。

欧州のヨーロッパブナ（*Fagus sylvatica*）林でも同様の試みがありました。ドローンレーザースキャニングで樹冠の立体体積を測り、この値を従来のDBH単独計算式に加えると、バイオマス推定誤差が目立って減りました。幹の太さだけを見ていた計算式に樹冠体積情報を加えたので、成績がよくなったのも自然な結果に見えます。

ただし、相対成長式そのものに弱点があります。北米や熱帯林全域で使うために作られた汎用公式は、特定地域の土壌がどれほど肥沃か、その地域の気候がどうか、同じ樹種でも育つ場所ごとに木の形がどう変わるかをすべて盛り込めません。トウヒ1種だけを見ても、雨の多い山腹で育った木と乾いた尾根で育った木は、太さが同じでも中身の詰まり具合、すなわち木材密度が異なる場合があります。そのため地域によって一方向へ偏った誤差、すなわち系統的バイアスが生じることがありま

す。幸い、教師あり学習方式のディープラーニングモデルは、後にその地域で精密に測った相対成長データが集まれば、再学習でこの偏りを直せる余地があります。初めから完全な公式を探すより、データを集め続けて修正する方法に近いものです。

国家森林調査と衛星データをつなぐ

レーザーとドローンで個々の木を精密に測る技術がどれだけ進んでも、国全体の森林を1本ずつこの方法で調べることはできません。森林の広い国ほど、木の本数は数億を軽く超えます。ドローン1機が1日に調べられる面積には限界がありますが、人工衛星はその限界を一気に越えます。1本ずつ測った値や数か所の標本点データを国全体の地図へ広げるには、別の方法が必要です。地上で実測した国家森林資源調査（National Forest Inventory、NFI）データと、広域を一目で見る人工衛星リモートセンシングデータをAIで結ぶ作業です。

米国コネティカット州の温帯混交林では、米国森林局の国家森林資源調査標本点142か所のデータに、Sentinel-1衛星のレーダー信号、Sentinel-2・Landsat衛星が葉の緑色反射の程度を指数化した植生指数（NDVIなど）、GEDIという宇宙搭載レーザー高度計の樹高データを重ね、10メートル解像度のバイオマス地図を作りました。複数の機械学習手法を試した結果、GEDIが測った樹高とSentinel衛星の植生指数を一緒に入力したとき、精度が最も高くなりました。森林ではない地域はバイオマス値を0にして除外し、標本のノイズを減らしました。

ロシア・サハリン島の管理林では、NFI小班調査データにSentinel-2衛星画像の時系列変化と地形データを組み合わせ、ランダムフォレスト、XGBoost、TabNetの三つのアルゴリズムを競わせました。このうちXGBoost、すなわち質問を一つずつ投げて枝分かれするように答えを絞る決定木を順につなぎ、前の木が見落とした誤差を次の木が減らす方式のアルゴリズムが、最もよい成績を出しました。平均絶対百分率誤差、すなわちMAPEでは、樹高推定が0.18、炭素蓄積量推定が0.37で、全体説明力は0.68でした。

中国黒竜江省の天然林研究は、時間軸がはるかに長いものです。1976年から2015年まで、NFI固定標本点データを9回集めました。これに過去と未来の気候および二酸化炭素濃度データを重ね、Knowledge-Guided Machine Learning（KGML）という枠組みを作りました。木の生態的成長過程を数式にした森林炭素固定モデルに、二酸化炭素施肥効果を反映して改良し、このモデルが計算した値をXGBoostへ先に参照する情報として渡す二段階構造です。生態学的知識を加えたことで、炭素密度予測の説明力は0.85から0.90超へ上がりました。炭素排出を積極的に抑える低排出シナリオで、黒竜江省天然林の炭素蓄積量は2060年に1,379.26テラグラムから1,439.02テラグラムと見込まれました。生態学の規則をあらかじめ組み込んだため、

学習データの範囲外の未来を予測するときも、値が荒唐無稽に跳ねませんでした。一般的なブラックボックス機械学習モデルは、見たことのない極端な気候条件を前にすると、とんでもない値を出しやすくなります。学習データ内で見たパターンを外れると、何を根拠に答えるべきか分からないからです。

ルーマニアの現地データを基に作ったモデルへ、フィンランド国家森林資源調査の標本とSentinel-2時系列を加えた研究もあります。フィンランドの林木材積予測の説明力は0.483から0.718上がりました。研究対象は炭素地図ではなく、樹高、胸高断面積、材積などの林分属性でした。タンザニアの研究は2014年の森林・ウッドランド面積を出発点として、2054年まで従来傾向、持続可能な管理、開発圧力増加という三つのシナリオを計算しました。

コネティカットからサハリン、黒竜江、フィンランドへ続くこれらの研究は、共通する図を示します。地上標本点データが多く多様であるほど、衛星センサーを複数種類重ねて使うほど、広域地図の精度が上がるという事実です。

数値が食い違う理由

研究の数値を並べる際は注意が必要です。1本の木の重量、林分材積、1ヘクタール当たりバイオマスは異なる目的変数であり、 R^2 もデータ範囲と検証方式によって変わります。NFI標本点の座標誤差は、樹冠、地形、受信機、補正方式に左右されます。一部の公開データは、私有地を保護するため意図的に座標をぼかします。衛星画素には大木、若木、空き地が一緒に含まれるため、近くで測った個体木値と画素平均の間に隔たりが生じます。

光学衛星とレーダー衛星の間でも順位が逆転します。光学と短波長レーダーは、バイオマスの多い森林で信号飽和が早く現れる場合があります。飽和点は森林構造、水分、偏波、入射角、回帰モデルによって異なり、一つの閾値に固定することは困難です。長波長レーダーとLiDARは、密林の構造を読む上で相対的に有利です。GEDIは波形LiDARなので、レーダー後方散乱と同じ飽和基準にはまとめません。センサー別の違いは、炭素クレジットのように金銭が動く計算で敏感に作用します。

残された問題、次の段階

技術的な限界も残ります。NFIと衛星は観測周期が異なり、同じ森林を違う日に測ります。複数の国の公開NFIデータは、私有地を保護するため実際の座標をぼかすこともあり、高解像度画素と合わせると誤差が生じます。相対成長式で作ったバイオマス参照値にも、式の選択による不確実性が含まれます。リモートセンシング AGB地図を、森林全体の炭素量と見なしてはなりません。国家温室効果ガスインベントリーは、地下部バイオマス、枯死木、落葉、土壌を別々の炭素貯蔵庫として計算できます。

今後は、成長方程式と炭素循環モデルをニューラルネットワークに入れる知識誘導型機械学習を、広い地域で試験しなければなりません。GEDiとICESat-2のように独立した宇宙搭載LiDARミッションの樹高データも、NFIとともに比較できます。AIが推定値と不確実性を並べて出してこそ、国家温室効果ガスインベントリーで使える炭素地図に近づけます。

出典・参考文献

1. Geng, L., Bian, S., Ma, X., Fu, Q., Zhou, Y., & Wang, B. (2026). Prediction of carbon sequestration potential in Heilongjiang Province's natural forests based on the KGML model. Forest Engineering. Online first. <https://slgc.nefu.edu.cn/EN/abstract/abstract2592.shtml>
2. Jung, M., Choi, J., Carpenter, J., Fei, S., & Jung, J. (2025). Individual tree biomass estimation using single-scan terrestrial laser scanner with efficient projection-based deep learning. Journal of Forestry. <https://doi.org/10.1007/s44392-025-00065-6>
3. Keskes, M. I., & Nita, M. D. (2026). Digital twins in forest management using scalable deep learning pipeline. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 19, 8519-8547. <https://doi.org/10.1109/JSTARS.2026.3666924>
4. Khanal, S., Nolan, R., Medlyn, B., & Boer, M. (2025). Spatially explicit prediction of Nepal's forest biomass stocks, a data-driven bioregionalisation and machine learning approach. Carbon Balance and Management, 21(1), Article 23. <https://doi.org/10.1186/s13021-025-00367-4>
5. Lamahewage, S. H. G., Witharana, C., Riemann, R., Fahey, R., & Worthley, T. (2025). Aboveground biomass estimation using multimodal remote sensing observations and machine learning in mixed temperate forest. Scientific Reports, 15, Article 31120. <https://doi.org/10.1038/s41598-025-15585-6>
6. Liu, J., Liu, M., Shen, T., Yan, F., & Zhou, Z. (2025). Forest aboveground biomass estimation using high-resolution imagery and integrated machine learning. Forests, 16(12), Article 1777. <https://doi.org/10.3390/f16121777>
7. Obata, S., Cieszewski, C. J., Lowe, R. C., & Bettinger, P. (2021). Random forest regression model for estimation of the growing stock volumes in Georgia, USA, using dense Landsat time series and FIA dataset. Remote Sensing, 13(2), Article 218. <https://doi.org/10.3390/rs13020218>
8. Puletti, N., Innocenti, S., Guasti, M., Alvites, C., & Ferrara, C. (2025). Improving aboveground biomass estimation in beech forests with 3D tree crown parameters derived from UAV-LS. Remote Sensing, 17(9), Article 1497. <https://doi.org/10.3390/rs17091497>

9. Subedi, P., & Zurqani, H. (2026). Multi-sensor forest aboveground biomass estimation using GEDI, machine learning, and deep learning techniques. *Advances in Space Research*, 77(3), 2784-2806.
<https://doi.org/10.1016/j.asr.2025.12.032>
10. Tasuev, U., Tregubova, P., Illarionova, S., Shadrin, D., Bernshteyn, A., & Burnaev, E. (2026). Machine learning-based geospatial assessment of forest structure characteristics and sequestration potential for informed carbon stocks inventories. *Scientific Reports*, 16, Article 20872.
<https://doi.org/10.1038/s41598-026-50929-w>
11. Uyar, N. (2026). Tropical forest biomass assessment using LIDAR, DEM, and Sentinel-2 in the Daintree forest. *Plant Ecology*, 227(4), Article 42. <https://doi.org/10.1007/s11258-026-01602-9>
12. Wan, L., et al. (2025). Satellite-based mapping of annual canopy height and aboveground biomass in African dense forests. *Frontiers in Remote Sensing*, 6, Article 1724950.
<https://doi.org/10.3389/frsen.2025.1724950>
13. Wang, G., Zhao, L., Song, C., Zhang, W., Dong, W., & Ji, Y. (2026). Improving forest aboveground biomass estimation accuracy via optical and SAR data fusion using deep learning algorithms. *Remote Sensing*, 18(10), Article 1536. <https://doi.org/10.3390/rs18101536>

2.3

森林土壌動態と土地被覆変化のモニタリング

雨が止んだ江原道の伐採地で、土壌研究者が斜面に膝をついた。踏むたび、花崗岩が風化してできた赤い土が靴底にまとわりつく。雨水は表土を削り、細い溝を斜面の下へ伸ばしていた。森が伐られた直後、土壌は植生に覆われた時期とは別の速度で動き始める。水分、温度、有機物、炭素、そして地表を覆う植生の変化を追わなければ、回復も劣化も見えない。

地下のセンサーと空の目が一緒に読む水分

土壌水分、有機物、温度、相対湿度、二酸化炭素濃度は、森林の健康状態を知らせる基本の数値である。以前は調査員が土を採取し、実験室で測ることが多かった。今は土中に置いたIoTセンサー、LoRa通信、ドローン、衛星画像をつなぎ、数時間または数日ごとに変化を追える。地上の機器は狭い場所を詳しく測り、空からの画像は広い地域の違いを映す。

Yinら（2024）は、アルファルファの根域土壌水分を推定するため、ドローンのマルチスペクトル画像、熱画像、可視画像と深層学習を組み合わせた。根の近くの水分は空から直接見えない。それでも葉の色、温度、反射率に残る小さな差を拾えば、水分の不足を早く見つけれられる。

Singhら（2026）は、小麦を育てるアグロフォレストリーで、樹冠管理と地下センサー、LSWI、TVDIを結び付けた研究を整理した。木陰が濃すぎれば小麦に届く光が減る。木が少なすぎれば蒸発が増え、土が乾く。土壌水分と樹冠の状態を同時に見ることで、間伐、灌水、作物配置の時期を判断しやすくなる。

木の幹に複数のプローブを取り付け、LoRaでデータを送る方式は、広い林地でも使いやすい。電池で動くため電源線は要らないが、電池切れや通信の途絶が起きれば記録に空白が残る。センサーの数値をそのまま信じるのではなく、欠測、異常値、設置場所の違いを点検する仕組みが必要になる。

Wangら（2026）は、LiDAR、衛星、IoTセンサー、ドローンを組み合わせる森林資源モニタリングの研究を整理した。異なる機器は、解像度、観測時刻、測る対象が違う。融合の前に座標、時刻、単位、誤差をそろえなければならない。

Amoah-Nuamahら（2025）とSahaら（2025）は、こうした多源データとAIの組

合せが病虫害、枯死木、異常乾燥の見落としや誤報を減らし得ると報告した。ただし、精度が上がるほど、現場で何を根拠に警報を出すかという説明も求められる。

土の質を点数に変える地図

土壌の質は一つの数値では決まらない。利用可能水分量、有機炭素、酸性度、窒素、リン、カリウム、締め固めの状態を一緒に見る必要がある。これらを地図にすれば、谷筋と尾根、伐採地と未伐採地、畑と林の境目で、土がどこから弱り始めているかを読める。

Poudelら（2025）は、自然のマツ林における土壌の質を、ファジーAHPと予測型機械学習で評価した。ファジーAHPは、土壌水分や有機物のように境界がはっきりしない条件を重み付けする方法である。ランダムフォレストなどの機械学習と組み合わせれば、測定していない地点にも土壌の質を推定できる。

Liら（2025）は、Sentinel-2データと環境変数を用いてボステン湖オアシスの土壌有機炭素を予測し、地図化した。ParviziとFatehi（2025）は、異なる土地利用で土壌有機炭素を地図化した結果、ランダムフォレストの決定係数が0.64で、一般化線形モデルの0.39、サポートベクターマシンの0.41を上回ったと報告した。ただし、どの地域でも同じモデルが勝つわけではない。土壌の種類、測定点の数、季節、植生被覆が変われば、最も合う手法も変わる。

こうした地図は、専門家だけのものではない。斜面のどの方向に水が流れ、どの谷筋に有機物が集まり、どの尾根が乾いているかを、現場の担当者が一目で確かめられる。点で採った土壌試料を、土地全体の判断へつなぐ道具になる。

シェードツリーの配置を計算するグラフニューラルネットワーク

アグロフォレストリーでは、シェードツリーがつくる日陰の斑点が、日射、湿度、二酸化炭素濃度、土壌水分を変える。木を密に植えすぎれば、作物に必要な光が減る。疎にしすぎれば、暑さと蒸発を抑えられない。問題は、一本ずつの木ではなく、木々の距離と配置がつくる網目にある。

Ridloら（2025）は、独立支配集合に基づく方法と時空間グラフニューラルネットワーク（STGNN）を使い、コーヒー・アグロフォレストリーのシェードツリー配置を検討した。コーヒー96本とシェードツリー26本の配置では、年間の二酸化炭素吸収量が520kgと計算された。31本を格子状に配置した場合は620kgだった。この数値は現地で吸収量を測定した結果ではなく、モデルによる計算値である。

この研究では、相対湿度と二酸化炭素濃度を10、15、20ステップ先まで予測し、過去平均、ARIMA、SVR、GCN、GRUより小さな誤差を示した。決定係数は0.7350

から0.8109だった。10日先の湿度を見通せるなら、苗を植える時期や日陰を調整する時期を、経験だけに頼らず決められる。

衛星が撮り続けた30年以上のフィルム

気候変動、伐採、農地拡大、山火事は、土地被覆を少しずつ、時には一夜で変える。Landsat、Sentinel、MODISの時系列画像は、長い年月にわたる変化を記録してきた。韓国でも山火事跡地や松くい虫被害地で、植生がどのように戻り、どこで回復が遅れるかを追うことができる。

Obataら（2021）は、米国ジョージア州で1984年から2016年までの33年分のLandsat時系列とFIAデータをGoogle Earth Engineで処理した。タッセルドキャップの明るさなどの指標、調和回帰、国有森林資源調査の標本地、ランダムフォレストを組み合わせて、攪乱時期の推定精度を高め、蓄積量の推定誤差を下げた。衛星画像を一枚ずつ見るのではなく、長いフィルムとして読んだ結果である。

Wangら（2026）は、2000年から2020年にかけての世界の高解像度森林攪乱タイプのデータセットを作成した。原因には山火事、伐採、森林収穫、移動耕作、病害、風害がある。同じように木が減った場所でも、原因が違えば復旧の方法は変わる。

Çalışkan（2026）は、同じ土地利用・土地被覆データにSVM、ランダムフォレスト、決定木を適用して比較した。どの手法にも一律の勝者はなかった。区画が複雑で小さい地域ではランダムフォレストが有利な場合があり、大きく単純な圃場では決定木が使いやすい場合がある。

González-Vélezら（2026）は、コロンビアの熱帯乾燥林で、ラベル付きデータとラベルなしデータを一緒に使うSemi-FCMNetを試した。Sentinel-1のレーダー画像とSentinel-2の光学画像を組み合わせ、土地利用・土地被覆変化の検出で90%を超える精度を示した。ただし、ラベルを集める作業がどの程度減ったかは測定されていない。

Pišlら（2026）は、位置情報を考慮する深層学習で、熱帯林の伐採後に牧草地、農地、道路のどれに変わったかを地図化した。場所の文脈を入れることで、見た目が似た地表でも、周辺の土地利用とのつながりから変化の行き先を判断しやすくなる。

Silvaら（2026）は、ブラジルの亜熱帯大西洋岸森林で、MapBiomassデータを用いてアグロフォレストリーの面積を分析した。面積は2000年の405.80haから2010年の500.60ha、2020年には659.81haへ増えた。アグロフォレストリーは生息地をつなぐ集約地として働き、生態回廊、生物多様性、土壌保全に寄与し得る。

Zella (2026) は、タンザニアのNAFORMAデータと機械学習予測を使い、2014年から2054年までの森林と土地利用を見通した。既存の傾向が続けば森林面積は4,809万haから3,299万haへ減る。開発圧力が強い場合は2,830万haまで下がり、持続可能な管理を進める場合は4,385万haを保てるとした。

Kunduら (2025) は、YOLOとLangChainエージェントを組み合わせ、森林減少の異常をほぼリアルタイムで検出する方法を提案した。検出器が怪しい変化を見つけても、それが伐採なのか、雲の影なのか、季節変動なのかは人が最終確認する必要がある。

EU森林破壊防止規則 (EUDR) は、コーヒー、カカオ、木材など附属書Iの対象品目について、森林破壊に関係しないことを示す地理情報を求める。面積が4ha以下の区画では緯度・経度の一点でもよいが、それを超える区画ではポリゴンが必要になる。基準日は2020年12月31日である。大規模事業者と一部の中小企業には2026年12月30日から、自然人と一部の零細事業者には2027年6月30日から適用される。輸出入業者、製造業者、販売業者のどの役割を担うかによって、確認すべき義務は異なる。

食い違う数字と残る課題

地上センサーは狭い地点を詳しく測る一方、Sentinel-2やLandsatの画素は広い面積を平均して見る。この二つの数値を同じものとして比べることはできない。観測時刻、深さ、空間範囲をそろえ、現地調査で検証する必要がある。

衛星は安全な場所から広域を見られるが、画面上では湿って見える場所が、地上では乾いていることがある。反対に、地上センサーが乾燥を示しても、その一本が根の多い場所に刺さっているだけかもしれない。どの信号をどこまで信じるかを決めた運用手順が必要になる。

光学衛星は雲や霧に弱い。SARレーダーは雲を通して観測できるが、濡れた土や地表の粗さを土地被覆の変化と誤って読むことがある。閉鎖した樹冠の下にある土壌は、衛星から間接的にしか見えない。別の地域で学習したモデルは、落葉の季節を山火事や伐採と読み違える場合もある。すべての森林に通用する単一の精度範囲はない。

現場のセンサーにも、電池切れ、通信障害、泥や動物による破損がある。短い試験で高い精度が出ても、雨季、乾季、伐採後、植栽後をまたぐ長期試験を経なければ、実務で使えるとは言えない。

今後は、物理法則を組み込む物理情報ニューラルネットワーク (PINN) で推定の理由を示し、軽量化したSTGNNやTransformerを現場のドローンに載せる試みが

進むだろう。森林の種類、気候、土壌、管理方法が異なる地域で共通のベンチマークをつくり、低消費電力AIチップと組み合わせることも課題である。

出典・参考文献

1. Amoah-Nuamah, J., Child, B., Okyere, E. Y., Adams, O., & Danquah, J. A. (2025). Applications of artificial intelligence in forest health surveillance and management. *Discover Forests*, 1, Article 56. <https://doi.org/10.1007/s44415-025-00061-w>
2. Çalışkan, B. (2026). Machine learning innovations in LULC classification: a comparative study of SVM, random forest, and decision trees. *Land Management and Utilization*, 2(1), 48-62. <https://doi.org/10.54963/lmu.v2i1.2356>
3. González-Vélez, J. C., Torres-Madronero, M. C., Martínez-Vargas, J. D., Rodríguez-Marín, P., Perez-Guerra, J., & Herrera-Ruiz, V. (2026). Tropical dry forest land use/land cover change detection using semi-supervised deep learning algorithms and remote sensing. *Environmental Monitoring and Assessment*, 198(2), 197. <https://doi.org/10.1007/s10661-025-14897-4>
4. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
5. Li, S., Li, X., & Ge, X. (2025). Prediction and mapping of soil organic carbon in the Bosten Lake oasis based on Sentinel-2 data and environmental variables. *International Soil and Water Conservation Research*, 13, 436-446. <https://doi.org/10.1016/j.iswcr.2024.12.002>
6. Obata, S., Cieszewski, C. J., Lowe, R. C., & Bettinger, P. (2021). Random forest regression model for estimation of the growing stock volumes in Georgia, USA, using dense Landsat time series and FIA dataset. *Remote Sensing*, 13(2), Article 218. <https://doi.org/10.3390/rs13020218>
7. Parvizi, Y., & Fatehi, S. (2025). Geospatial digital mapping of soil organic carbon using machine learning and geostatistical methods in different land uses. *Scientific Reports*, 15, 4449. <https://doi.org/10.1038/s41598-025-88062-9>
8. Pišl, J., Sumbul, G., Lenczner, G., Zamora, C., Herold, M., Wegner, J. D., & Tuia, D. (2026). Mapping land uses following tropical deforestation with location-aware deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 232, 578-593. <https://doi.org/10.1016/j.isprsjprs.2025.12.007>
9. Poudel, D., Abiye, W., Dengiz, O., Pacci, S., & Safli, M. E. (2025). Soil quality dynamics in natural pine forests lands integrating fuzzy-AHP and prediction-based machine learning. *Scientific Reports*, 15, 32140. <https://doi.org/10.1038/s41598-025-21943-1>
10. Ridlo, Z. R., Dafik, Waluyo, J., Yushardi, & Venkatachalam, M. (2025). On RIDS analysis for shade tree placement and its application to STGNN multi-step forecasting on RH and CO2 concentration of coffee agroforestry. *Statistics, Optimization & Information Computing*, 14(4), 1889-1908. <https://doi.org/10.19139/soic-2310-5070-2643>
11. Saha, R., Bagchie, P., Lalremsang, P., & Rai, K. C. (2025). Digital innovation in forest science: applications of artificial intelligence, remote sensing and smart monitoring systems for ecosystem conservation. *The Bioscan*, 20(3), 907-911. [https://doi.org/10.63001/tbs.2025.v20.i03.S.I\(3\).pp907-911](https://doi.org/10.63001/tbs.2025.v20.i03.S.I(3).pp907-911)
12. Silva, B. B., Brum, D., Loregian, A. C., Urruth, L. M., & Tozetti, A. M. (2026). Agroforestry systems as habitat aggregators: a spatiotemporal analysis of the Brazilian subtropical Atlantic forest. *Agroforestry Systems*, 100(6), 185. <https://doi.org/10.1007/s10457-026-01557-w>
13. Singh, A., Atish, Singh, V., Kumari, B., Arya, S., & Kamboj, A. (2026). A systematic review on water use efficiency (WUE) and soil moisture dynamics in wheat-based agroforestry systems. *International Journal of Environment, Agriculture and Biotechnology*, 11(3), 72-87. <https://doi.org/10.22161/ijeab.113.8>

14. Wang, L., Liu, S., Zhang, J., & Song, W. (2026). Global high-resolution forest disturbance type dataset between 2000 and 2020. *Earth System Science Data*, 18, 1601-1618.
<https://doi.org/10.5194/essd-18-1601-2026>
15. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, 1710618.
<https://doi.org/10.3389/fpls.2025.1710618>
16. Yin, L., Yan, S., Li, M., Liu, W., Zhang, S., Xie, X., et al. (2024). Enhancing soil moisture estimation in alfalfa root-zone using UAV-based multimodal remote sensing and deep learning. *European Journal of Agronomy*, 161, 127366. <https://doi.org/10.1016/j.eja.2024.127366>
17. Zella, A. Y. (2026). Sustainable forest and land-use management in Tanzania: NAFORMA-based and machine learning forecasts to 2050 under Tanzania Dira 2050. *International Journal of Development and Management Review*, 21(1), 1-36. <https://doi.org/10.4314/ijdmr.v21i1.1>
18. Shin & Kim LLC. (March 17, 2026). ESG regulations to watch in 2026 (4): European Union Deforestation-Free Products Regulation. <https://www.shinkim.com/kor/media/newsletter/3174> (2026年8月2日アクセス)

第3章

森林災害と生態系の健全性モニタリング ：AIによる監視と早期警報

3.1

機械学習・深層学習による山火事リスク予測と焼失域検出

晩春の午後、乾燥注意報が3日目に入るなか、山火事対策室の壁一面を覆うモニターの片隅に、赤い点がひとつ現れる。外の風は乾いて強く、昨日撒いた水はすでに蒸発している。無線のやり取りとキーボードを叩く音だけが室内に満ちる。オペレーターはただちにCCTVの映像を拡大し、熱感知カメラの温度を確認し、付近からの通報画面を開く。その点が本物の火なのか、田んぼの畦を焼く煙なのか、それとも夕陽で熱せられた屋根なのかを判断するのに使えるのは、せいぜい数分だ。その数分のあいだ、人の目がすべての画面を見渡すより前に、AIアルゴリズムはすでに初期判断を下している。

2025年3月に慶尚北道義城で始まった火災は、その判断の重みを示した。火は安東、青松、英陽、盈徳へと広がった。公式集計では死者26人、負傷者71人が記録された。慶尚北道の森林被害面積の暫定値は99,289ヘクタール、暫定損失額は1兆1306億ウォンだった。慶尚北道、慶尚南道、蔚山の復旧費用は1兆8809億ウォンと見積もられた。これらが異なる数字なのは、被害査定と復旧計画の地理的対象範囲と会計上の区分が異なっていたからであって、損失が夏に増えたからではない。

こうした火災の防止を目的とするAIは、大きく二つの段階で機能する。機械学習はデータの中から規則を見つけ出し、深層学習は多層のニューラルネットワークを通じてその規則をより深く探索する。ある予測モデルは、発火の数日前、あるいは1か月も前から危険な場所を特定する。もう一つの検出モデルは、発火後わずか数分で火災を認識する。

湿度が最初に動く

かつての山火事リスク評価は、固定的な地形と単一の植生指数画像に頼っていた。斜面や樹種は年ごとにほとんど変わらないが、山火事は地形だけで起きるわけではない。昨日は安全だった山も、雨のあとに湿度が急に下がれば、今日は危険になりうる。そのため森林AIは、気象、地形、可燃性植生、そして人の立ち入りを示す社会経済データを組み合わせて、日ごとの発火確率を再計算する方向へと進んでいる。

山火事データには扱いにくい不均衡がある。火災の起きた日はごくわずかで、火災の起きなかった日は圧倒的に多い。そのデータをそのまま学習させたモデルは、安全な日だけを予測して火災を見逃しても高い成績を出せてしまう。そこで研究者は、火災日と似た事例を統計的に追加生成して、モデルが両方のクラスを均等に学習できるようにするSMOTE（合成少数オーバーサンプリング法、Synthetic Minority Over-sampling Technique）を用いる。また、火災の起きなかった日を減らすアンダーサンプリングや、火災の見逃しに重いペナルティを課すコスト考慮型学習も用いる。

江原特別自治道を対象とした研究は、この手法を2013年から2023年までの11年間にわたる気象・森林・人口データに適用した。表形式データでは、樹木ベースのモデルが深層ニューラルネットワークを上回ることが多い。分岐による判定が、気象と地形のように性質の異なる変数を扱えるからだ。ロジスティック回帰、XGBoost、LightGBM、ランダムフォレスト、エクストラツリーのうち、エクストラツリーがAUC 0.839で首位に立った。AUCは火災日と非火災日を区別する能力を測る指標で、1が完璧、0.5はコイン投げと変わらない。火災の見逃しを避ける点ではランダムフォレストが優れ、再現率は0.828だった。

この研究はSHAP（シャープレイ加法的説明、SHapley Additive exPlanations）も用いた。これはゲーム理論における共同貢献の配分を予測モデルに持ち込んだ手法である。相対湿度は寄与度0.25で全変数の首位に立ち、湿度が下がるほどリスクは急激に上がった。降水量が0.15で続き、日最高気温が0.05、人口密度が0.04だった。蓄積材積、墓地の割合、針葉樹林の割合、農地の割合も寄与した。太白山脈の東側で海風にさらされる嶺東と、山脈の背後にある嶺西とを分ける地域変数も、同様の効果を持った。この結果は、気候だけでなく、人の立ち入りや火入れの慣行がリスクを高めることを示唆している。

針葉樹の割合や蓄積材積といった可燃物の変数は、樹木を一本ずつ計測する必要はない。LSWI、TVDI、ドローンのレーザースキャンで生成する樹冠高モデル（CHM）などのリモート観測が、現地を歩く代わりになる。UAV LiDARを用いて各樹木の位置、周囲長、樹冠幅を地図化する研究も続いている。ベトナムのPinus kesiya（メルクシマツ）を対象とした深層学習研究は、個々の樹木の検出と樹冠の区分を自動化し、山火事の可燃物地図の基礎データへの道を開いた。

江原の研究が地域単位の翌日予測モデルであるのに対し、UNISTのイム・ジョンホ教授が率いるチームが2026年にCommunications Earth & Environmentで発表したFWI-Netは、全球の火災気象指数を最大31日先まで予測する。この指数は気温、湿度、風、降雨を組み合わせる火災の延焼しやすさを示す。ECMWFの数値予報は2

週間を過ぎると急速に精度を失ったが、FWI-Netは31日間の全区間にわたって誤差を6.6パーセント低減し、最初の1週間では12.4パーセント低減した。改善が最も大きかったのは、山火事リスクは高いのに予報システムが弱い地域だった。地理空間技術と機械学習を組み合わせた研究についての国際的なレビューも、同様の結論に達した。気象、地形、人間活動のデータを組み合わせたモデルは、衛星画像やGISデータのみを用いたモデルを繰り返し上回る。

山のセンサーと空の目がリアルタイムでつながる

地上のセンサーと上空の衛星が同じ瞬間を見守る。LoRaWANは、長距離伝送のための低消費電力の無線方式である。温度、湿度、一酸化炭素を測定する80個のセンサーが、トルコのZeytinparkに設置された。研究者は、適応的に重み付けしたランダムフォレストとXGBoostを組み合わせたモデルを試験した。センサー配置のカバー率は95.58パーセントと算出され、電池寿命は最大11か月だった。

シベリアのクラスノヤルスク地方を対象とした研究は、山火事地点を中心に1kmから100kmまで6つの同心円状のゾーンを描いた。各ゾーンで30日間の気象・地形の時系列を組み合わせ、XGBoostで火災の規模を分類し、精度88.8パーセントを報告した。著者らは、これは局所的に調整された結果であり、別の大陸へ移す前には現地データによる再校正が必要だと述べた。

Earth Fire Allianceの最初の3基の実運用FireSatが、2026年7月7日に軌道に入った。公式のロードマップは、その年の末までに初期利用者向けの1日2回の観測から始まり、2028年に全球アクセスを、2029年に1時間以内の再訪を目指し、2030年代前半には20分以内の再訪を目標とする。衛星の数とスケジュールは、打ち上げや資金によって変わりうる。

韓国のリモートセンシングのレビューも、山火事的全サイクルにわたってAIと衛星モニタリングを追った。発火前のリスク予測、火災中のリアルタイム検出、鎮火後の被害域推定は、それぞれ異なる衛星データとモデルを必要とする。韓国のGEO-KOMPSAT-2Aは、雲、山火事の煙、砂塵を視覚的に区別できる自然色の地球画像を捉え、その土壌水分観測は干ばつと山火事リスクの評価を支える。国立山林科学院は、これらのデータを国家山火事危険予報システムに統合し、最近では利用者の現在地のリスクを表示するモバイルサービスを導入した。

煙か雲か、まずカメラが判断する

火災が始まると、別の競争が始まる。煙が広がる前に、数分以内に認識しなければならない。固定式のCCTVと赤外線カメラが下から見張り、UAVが難所の尾根と死角をカバーする。可視光カメラは、もや、雲、夕方の反射に惑わされることがある。熱感知カメラは熱を検出するが、画像が粗いため、燃えている木と熱い岩を取り違えることがある。

中国福建省のデータで学習させたEFFNetは、可視画像と熱赤外画像を組み合わせた。その検証時のmAP50は97.2パーセント、適合率は94.9パーセント、再現率は94.1パーセントだった。これらは福建の試験条件下での結果である。Akhyarらは、UAV画像から山火事域を分割するDeepFire S3GA-Netを開発した。試験データでは平均IoU 0.8723、適合率0.9347、再現率0.9194が得られた。Hindartoらは、別の山火事画像データセットでMobileNetV3、ResNet50、YOLOv8を比較した。ベトナムのPinus kesiyaについてのYOLOセグメンテーションとSAM2の比較は、個々の樹木と樹冠の区分に関するものであり、山火事研究ではない。

モデルが異なることを語るとき

これらの結果がすべて同じことを語っているわけではない。気象のみを用いる従来の火災気象指数モデルは、広い地域的な傾向を捉えるが、同じ気象条件のもとでの小さな森林区画が発火するのかは区別できない。江原、モロッコ、インドを対象とした研究は、人口密度、農地・墓地の割合、道路までの距離といった社会経済変数を加えると、AUCと再現率が10から15パーセントポイント向上すると報告している。同一の気象条件下でも、人が頻繁に訪れる場所や、農地や墓が近い場所では、実際の発火が起こりやすい。

可視光のみのカメラは安価だが、霧、逆光、夜間の条件では誤報と見逃しが増える。EFFNetのような二重モダリティの機器は高い性能を示すが、赤外線センサーが高価で画像解像度が低い。山全体をカバーする自治体は、それでも安価な可視カメラを密に配置するか、高価な二重モダリティのカメラをまばらに配置するかの均衡を取らなければならない。

限界ははっきりと述べておかねばならない。SMOTEは人工的なパターンを持ち込むおそれがあり、LTEと5Gは深い山中でしばしば通じない。誤報は消防士、ヘリコプター、予算を浪費し、見逃しは初動対応を遅らせる。NVIDIA JetsonのようなエッジAIコンピューターはドローン上で計算を完了させなければならないが、モデルを圧縮できなければ判断が遅くなる。高性能なビジョントランスフォーマーや3次元CNNもまた、機械の判断を自らの名で承認しなければならない担当者にとって、説明しにくいままである。今後の研究は二つの方向に進む。一つはSHAPや

Grad-CAMを通じて理由を可視化し、熱と風の物理をニューラルネットワークに組み込むこと。もう一つは低消費電力のセンサーネットワークと二重モダリティのドローンをつなぎ、端から端までの警報時間を計測することである。山火事、病害虫、干ばつストレスを統合したネットワークが提案されているが、山中で1分以内に行動を完了する完全に実証された自律対応システムは、まだ証明されていない。

出典・参考文献

1. Akhyar, A., Lee, J., Shahar, N., Saputro, A. H., & Zulkifley, M. A. (2026). Automated forest fire detection in ecological monitoring using enhanced deep learning networks. *Scientific Reports*, 16, Article 2039. <https://doi.org/10.1038/s41598-025-31707-6>
2. Amoah-Nuamah, J., Child, B., Okyere, E. Y., Adams, O., & Danquah, J. A. (2025). Applications of artificial intelligence in forest health surveillance and management. *Discover Forests*, 1, Article 56. <https://doi.org/10.1007/s44415-025-00061-w>
3. Earth Fire Alliance. (2026, July 7). Earth Fire Alliance's first three operational FireSats reach orbit. <https://earthfirealliance.org/news-article/earth-fire-alliances-first-three-operational-firesats-reach-orbit/> (2026年8月2日閲覧)
4. Hindarto, D., Sani, A., & Gunawan, A. (2026). Deep learning-based forest fire classification using MobileNetV3, ResNet50, and YOLOv8. *Journal of Computer Networks, Architecture and High Performance Computing*, 8(2), 193-204. <https://doi.org/10.47709/cnahpc.v8i2.8112>
5. Kang, Y., Lee, S., Cho, D., et al. (2026). Deep learning-based forecasting provides a pathway to closing wildfire information gaps in underserved regions. *Communications Earth & Environment*. <https://doi.org/10.1038/s43247-026-03692-9>
6. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
7. Lee, C., Choi, E. H., Han, Y., & Lee, Y. (2025). Year-round daily wildfire prediction and key factor analysis using machine learning: a case study of Gangwon State, South Korea. *Scientific Reports*, 15, Article 29910. <https://doi.org/10.1038/s41598-025-15508-5>
8. Malashin, I. P., Masich, I., Nelyub, V., Borodulin, A., Gantimurov, A., & Tynchenko, V. (2025). Assessing wildfire extents in Siberian forests using machine learning. *Scientific Reports*, 15, Article 32834. <https://doi.org/10.1038/s41598-025-17465-5>
9. Mousa, M. H., Algamdi, A. M., Fouad, Y., & Elshewey, A. M. (2026). CNN-MLP framework for forest burned areas prediction using PSO-WOA algorithm. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-35836-4>
10. Nguyen, T. T., Phan, V. T., Nguyen, T. H., & Duong, T. D. (2026). Individual tree detection and crown segmentation for Pinus kesiya using UAV-LiDAR and deep learning models. *Dendrobiology*, 95, 156-169. <https://doi.org/10.12657/denbio.095.011>
11. Radhi, A. A., & Ibrahim, A. A. (2026). An intelligent IoT-machine learning framework for wildfire detection and prediction using a hybrid RF-XGB model. *Scientific Reports*. <https://doi.org/10.1038/s41598-026-52395-w>
12. Vibhandik, P., Sawant, S., Joshi, A., & Bidwe, R. (2026). A systematic literature review on forest fire susceptibility mapping using geo-spatial technologies and machine learning. *Discover Artificial Intelligence*, 6, Article 396. <https://doi.org/10.1007/s44163-026-00921-0>

13. Yang, D. Q., & Wu, J. J. (2026). Deep-learning detection of early forest fires from UAV visible-light and thermal-infrared fused imagery. *National Remote Sensing Bulletin*, 30(6), 1647-1663.
<https://doi.org/10.11834/jrs.20265227>
14. Yang, S., Kim, W., Sung, T., Lee, S., Lee, G., Xu, Z., & Im, J. (2026). Satellite-based wildfire monitoring across the fire lifecycle using artificial intelligence: trends, challenges, and future directions. *Korean Journal of Remote Sensing*, 42(3), 315-341. <https://doi.org/10.7780/kjrs.2026.42.3.3>
15. 国立山林科学院. (2026). 国家山火事危険予報システム. <https://forestfire.nifos.go.kr> (2026年8月2日閲覧)
16. 韓国山林庁. (2025年4月18日). 慶尚北道・慶尚南道・蔚山の山火事被害暫定値：104,000ヘクタール、韓国山林庁が復旧を約束. https://www.forest.go.kr/kfsweb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttId=3206769 (2026年8月3日閲覧)
17. 大韓民国政府. (2025). 山火事復旧支援総額1兆8809億ウォン、過去最大.
https://gonggam.korea.kr/newsContentView.es?content=NC002&news_id=f4f9ac3e-81e6-4479-a9e2-6f8cf1c6a34b (2026年8月3日閲覧)

3.2

病虫害（マツ材線虫病を含む）および枯死木の画像による早期診断

水曜日の早朝、三人の調査員が江原道の山裾を登る。背囊にはGPS機器と遺伝子診断キットが入り、首には双眼鏡が下がっており、尾根ごとに一人が立ち止まって緑の斜面から赤褐色になった三、四本のマツを探す。見つけると座標を記録し、成長錐でおがくずを採取し、感染を検査する。ずいぶん前に枯れた木はもはや樹脂の強い匂いさえしない。

この方法には決定的な欠陥がある。松葉が赤く見えるときには、すでに遅いのだ。マツ材線虫病に感染したマツは、媒介者であるマツノマダラカミキリが線虫を運び込んだ後、徐々に乾いていき、対処しなければ森は数年のうちに赤く染まりうる。しかし目に見える変色には何週間もかかる。その数週間のあいだに媒介者は他の木へ移り、感染は静かに広がる。双眼鏡で発見された木は死の閾値を越えており、拡散はすでに始まっている。

感染木を見つけたあとも作業は続く。伐倒してチップにするか、覆いをかけて燻蒸し、媒介者の幼虫を駆除しなければならない。一人が一日に調査できるのは山肌のわずかな襷だけであり、密生した林分はさらに作業を遅らせる。韓国山林庁は2025年秋の防除計画を発表するにあたり、ヘリコプターおよびドローンによる調査にAIとLiDARを加えると述べた。まずAIが疑わしい木を選び、次に人が遺伝子診断キットで確認する。優先的な人員と機材は、国が保護する最前線地域、白頭大幹、金剛松林へ先に投入された。2026年6月、機張郡は歩行困難な地形や死角のドローン調査を開始し、高解像度の正射画像を作成して、疑わしい木の位置を釜山と共有した。

色が変わる前に読み取る

病原体が木に感染すると、その導管が詰まる。木は水分の損失を減らすために葉の気孔を閉じ、蒸散が減り、エアコンを切ったあとの部屋のように葉の表面温度がゆっくりと上がる。この兆候は松葉が赤くなる何週間も前に始まる。UAVに搭載した熱赤外センサーは、樹冠温度、NDVIやSAVIといった植生指数、気象データを組み合わせれば、これを検出できる。精度は樹種、撮影時刻、影、水分状態に左右される。朝、昼、夕の撮影を繰り返せば、偽の影の兆候と生理的ストレスを分離しやすくなるが、その兆候だけでは病原体を確定できないため、現地の試料検査が続かなければならない。

この数日から数週間の差が決定的である。変色してから初めて感染木を見つけると、媒介者はすでに近隣の数本の木に産卵している可能性がある。色が変わる前に検出できれば、一本を除去することで拡散を止められるかもしれない。その時間の窓こそが早期診断の狙いである。

もう一つのアプローチは、色ではなく組成を測る。クロロフィル、水分、色素の比率は赤くなる前に変化し、レッドエッジおよび短波赤外の兆候を生む。米国森林局とミネソタ大学のオークの実験では、干ばつストレスは最大27日前に、オーク萎凋病の反応は最大24日前に識別された。スペインの2021年の研究は、*Phytophthora cinnamomi*の感染と水ストレスに関連するオークの衰退を、ハイパースペクトルおよび熱画像で調べた。オーク萎凋病とオークの衰退は病原体も病理も異なる。

同じアプローチがマツ材線虫病でも試みられている。2025年のRemote Sensingの研究は、UAVハイパースペクトル画像における色素指数と水分含有量指数を組み合わせ、感染初期の生化学的ストレスを追跡した。2024年の研究は、毎月のUAV時系列とディープラーニングを組み合わせ、感染段階と月ごとの拡散距離を推定した。ResNet18、CBAM、LSTMを用いた管理下のポプラ苗の実験は、品種と干ばつストレスの分類で99.69パーセントの精度を報告したが、これは目を引く数字であって、管理されていない森林全体の現場結果と読むべきではない。

2026年のFrontiers in Plant Scienceのレビューは、より広い傾向を記している。広範囲を対象とする衛星リモートセンシング、中間的な範囲を対象とするUAVハイパースペクトルセンシング、近接した精密さのための地上センサーが、樹種分類、森林災害監視、樹木の健康評価のために重ねて用いられている。

すでに枯れた木を数える目

早期診断を逃れた木は幹まで赤くなり、松葉をすべて落とし、灰色に乾く。こうした立枯れ木は依然として数え、地図化することが難しい。Chowdhuryと十三人の共著者による2026年のレビューは、枯死木が散在する場所でYOLO系のモデルが強いことを見出した。2022年に発表されたLDS-YOLOは、背景が複雑な防護林で小さな枯死木を見逃さないよう設計された。木が画像のわずか数ピクセルしか占めないとき、重いモデルはそれを背景ノイズとして消してしまうことがある。2025年の二経路特徴融合の研究は、密集した枯死木のパッチにおける誤検出を減らした。

樹冠が重なり合う場所では、矩形の物体検出は、各ピクセルを生か枯かで標識するセグメンテーションよりも適さない。ドイツの2021年のSilvi-Netは、樹種分類と枯死木判定のために二つのCNNを同時に動かす。Chowdhuryのレビューは、FSC-Mask2FormerやADA-Netといった新しいモデルも扱っている。異なるデータセットから得られた精度の値は、撮影条件と評価指標とともに読まなければならない。

重要な変化はデータの蓄積の仕方である。2026年にMosig、KattenbornらがRemote Sensing of Environmentで紹介したdeadtrees.earthは、世界中のセンチメートル解像度の航空画像を数千枚組み合わせたオープンデータベースである。100万ヘクタール超を対象とし、58,000ヘクタール超で人間が生木と枯死木を標識した。利用者はドローン画像をアップロードし、AI分類を受け取り、それを修正し、その修正をモデルに戻すことができる。これは、ある森では機能するが別の森では失敗するモデルに対処しようとする試みである。共有データベースが大きくなるにつれ、ヨーロッパのトウヒから韓国のマツまでモデルを再訓練する労力は減るかもしれない。

2025年のある実験は解像度の重要性を示している。この実験は、7センチ解像度のUAV画像と、30センチおよび50センチの中国のBJ3NおよびBJ3A衛星画像で、マツ材線虫病に感染した木をU-Netで検出した。UAV画像はF1 89.1パーセント、マルチスペクトルを融合した30センチ衛星画像は88.9パーセントを記録した。補正していない1.2メートルおよび2メートルの画像を用いると、スコアはそれぞれ66.6パーセントと58パーセントに下がった。ピクセルが木より大きいとき、AIの視覚もぼやける。

拡散の経路を地図化する

一本の木を診断することと、病気がどこへ広がるかを地図化することは別の作業である。毎月繰り返すUAV撮影は時系列をつなぎ、感染段階と月ごとの拡散距離を推定できる。同じ林分のマルチスペクトルおよび熱画像を積み重ねれば、病気の進行する縁を地図化し、次にどこで防除を始めるべきかを導くことができ、まだ健全な森の縁に沿って予防線を引くことさえ可能になる。機張郡の結果を釜山と共有することも同じ目的に資する。拡散図は行政境界を越えるときに一層有用になる。

防除で終わりではない。空中散布、樹幹注入、あるいは伐倒燻蒸のあと、同じ場所を二、三週間ごとに撮影し、スペクトル指数と樹冠温度を健全な参照区と比較すれば、効果を測ることができる。Sevinçの2025年のScientific Reportsの研究は、人工ニューラルネットワークを用いて、機械的、化学的、生物学的な防除法を、産業用木材生産と森林の健康に照らして評価した。化学防除だけでは土壌や近くの溪流に負担をかける。生物防除だけでは拡散より遅くなりうるため、結果の数値記録は次の季節の総合的病害虫管理戦略を選ぶのに役立つ。2026年に発表された二本の中国のAgricultural Scienceの論文も同様に、森林資源調査と病害虫防除のためのUAVリモートセンシング、および病害虫防除と精密管理のための知的技術を概観している。

比較しうる研究にキクイムシに関するものがある。2026年7月のRemote Sensingの論文は、毎週のSentinel-2画像を、樹齢や地形といった固定情報とXGBoostで組み合わせ、衛星のみ、固定データのみ、および以前のアプローチに比べて早期検出が改善したと報告した。チェコのトウヒの研究は、UAVハイパースペクトル画像で健全木、感染木、枯死木を分離する精度が81パーセントであり、有人航空機の73パーセントを上回ったことを見出した。共通する限界は、キクイムシの侵入から成虫の出現までの期間が、衛星やドローンが樹冠の変化に気づくのに要する時間より短いことがある点である。

相反する結果と残された課題

ハイパースペクトルセンサーは、目に見えないスペクトルの変化を変色よりずっと前に検出するが、高価で処理が遅い。RGBおよびマルチスペクトルのYOLOやU-Netのシステムは安価で、広い面積を素早くカバーするが、松葉が赤くなっただけでないと木をうまく検出できない傾向がある。選択は森林構造にも左右される。YOLOは遠隔の山中に散在する枯死木には効率的だが、重なり合う枠が誤検出を増やす密な混交林では、U-NetやMask R-CNNのセグメンテーションが優れる。

優れたドローンや衛星でも、すべての木を見ることはできない。上層の樹冠が密な森では、光学および熱の兆候は主に最上層から返り、下層の早期感染を隠す。ある

生態系で正確なモデルは、別の場所の地形や樹種では性能を失いうる。その低下はデータと指標によって異なる。枯れた樹冠の境界を描く人間のばらつきも検証結果を変える。温帯針葉樹のモデルは、葉の厚さ、蠟、林分密度、土壌水分が学習した条件と異なるため、亜熱帯広葉樹林ではつまずきうる。

次の段階には二つの方向がある。deadtrees.earthのような世界的データベースと組み合わせた、ラベルなし画像に対する自己教師あり学習と、熱、ハイパースペクトル、LiDARのセンサーを搭載し機上で計算することで、疑わしい感染を一分以内に現場へ知らせるUAVである。もし調査員の双眼鏡がドローンとAIによって完全に置き換えられる日が来れば、木が赤くなる前にすでに介入が始まっているかもしれない。

出典・参考文献

1. Briechle, S., Krzystek, P., & Vosselman, G. (2021). Silvi-Net: A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 98, 102292. <https://doi.org/10.1016/j.jag.2020.102292>
2. Chowdhury, A. I., Beloiu, M., Kattenborn, T., Mosig, C., Ahishali, M., Vastaranta, M., Puttonen, E., Honkavaara, E., Huo, L., Uddin, M. J., Griess, V. C., Kuzmin, A., Cheng, Y., & Junttila, S. (2026). Remote sensing and deep learning for standing dead-tree detection and mapping: A review of advances, challenges, and future directions. *EarthArXiv*. <https://doi.org/10.31223/X5BZ05>
3. Han, Z., Hu, W., Peng, S., Lin, H., Zhang, J., Zhou, J., Wang, P., & Dian, Y. (2022). Detection of standing dead trees after pine wilt disease outbreak with airborne remote sensing imagery by multi-scale spatial attention deep learning and Gaussian kernel approach. *Remote Sensing*, 14(13), 3075. <https://doi.org/10.3390/rs14133075>
4. Hornero, A., Zarco-Tejada, P. J., Quero, J. L., North, P. R. J., Ruiz-Gómez, F. J., Sánchez-Cuesta, R., et al. (2021). Modelling hyperspectral- and thermal-based plant traits for the early detection of *Phytophthora*-induced symptoms in oak decline. *Remote Sensing of Environment*, 263, 112570. <https://doi.org/10.1016/j.rse.2021.112570>
5. Hou, R., Zhang, B., Fang, G., Yang, S., Guo, L., Huang, W., et al. (2025). Early detection of pine wilt disease by combining pigment and moisture content indices using UAV-based hyperspectral imagery. *Remote Sensing*, 17(11), 1833. <https://doi.org/10.3390/rs17111833>
6. Mosig, C., Kattenborn, T., Chowdhury, A. I., et al. (2026). deadtrees.earth: An open-access and interactive database for centimeter-scale aerial imagery to uncover global tree mortality dynamics. *Remote Sensing of Environment*, 332, 115027. <https://doi.org/10.1016/j.rse.2025.115027>
7. Nie, Z., Qin, L., Xing, P., Meng, X., Meng, X., Qin, K., & Wang, C. (2025). Ultra-high-resolution optical remote sensing satellite identification of pine-wood-nematode-infected trees. *Plants*, 14(22), 3436. <https://doi.org/10.3390/plants14223436>
8. Sapes, G., Schroeder, L., Scott, A., Clark, I., Juzwik, J., Montgomery, R. A., Guzmán Q., J. A., & Cavender-Bares, J. (2024). Mechanistic links between physiology and spectral reflectance enable previsual detection of oak wilt and drought stress. *Proceedings of the National Academy of Sciences*, 121(7), e2316164121. <https://doi.org/10.1073/pnas.2316164121>
9. Sevinç, V. (2025). Evaluating the effectiveness of the forest pests and diseases control methods on the industrial wood production using deep learning. *Scientific Reports*, 15, 34679. <https://doi.org/10.1038/s41598-025-06932-8>

10. Tan, C., Lin, Q., Du, H., Chen, C., Hu, M., Chen, J., et al. (2024). Detection of the infection stage of pine wilt disease and spread distance using monthly UAV-based imagery and a deep learning approach. *Remote Sensing*, 16(2), 364. <https://doi.org/10.3390/rs16020364>
11. Wang, L., Zhang, H., Bian, L., Zhou, L., Wang, S., & Ge, Y. (2024). Poplar seedling varieties and drought stress classification based on multi-source, time-series data and deep learning. *Industrial Crops and Products*, 218, 118905. <https://doi.org/10.1016/j.indcrop.2024.118905>
12. Wang, M., Zhang, Q., Liu, X., Zhang, J., Yu, F., Zhang, X., & Zhao, R. (2026). Research progress on multimodal data fusion in forest resource monitoring. *Frontiers in Plant Science*, 16, 1710618. <https://doi.org/10.3389/fpls.2025.1710618>
13. Wang, X., Zhao, Q., Jiang, P., Zheng, Y., Yuan, L., & Yuan, P. (2022). LDS-YOLO: A lightweight small object detection method for dead trees from shelter forest. *Computers and Electronics in Agriculture*, 198, 107035. <https://doi.org/10.1016/j.compag.2022.107035>
14. Yang, C., Lu, J., Fu, H., Guo, W., Shao, Z., Li, Y., Zhang, M., Li, X., & Ma, Y. (2025). Detection of pine wilt disease-infected dead trees in complex mountainous areas using enhanced YOLOv5 and UAV remote sensing. *Remote Sensing*, 17(17), 2953. <https://doi.org/10.3390/rs17172953>
15. Zeinali, S., Olsson, P.-O., Kronvall, T., Wiktorsson, M., & Lindström, J. (2026). Detection of bark beetle attacks using time-aggregated satellite data with machine learning. *Remote Sensing*, 18(13), 2234. <https://doi.org/10.3390/rs18132234>
16. Metro Seoul. (2026年6月27日). ドローンをを用いた機張郡のマツ材線虫病精密監視. <https://www.metroseoul.co.kr/article/20260627500013> (2026年8月2日閲覧)
17. World Environment Newspaper. (2026年6月25日). 韓国山林庁、2026年マツ材線虫病防除の成果を発表. <https://www.e-newsp.com/news/article.html?no=88960> (2026年8月2日閲覧)
18. Zhang, Q. (2026). Research on the application of UAV remote-sensing technology in forest-resource surveys and pest control. *Agricultural Science*, 9(6), 211-213. <https://doi.org/10.32629/as.v9i6.4090>
19. Zhang, Y. (2026). Research on the application of intelligent technology in pest control and fine management of forest resources. *Agricultural Science*, 9(2), 202-204. <https://doi.org/10.32629/as.v9i2.3704>
20. Electronic Times. (2025年9月24日). 韓国山林庁、AIでマツ材線虫病に対抗する、防除実行計画を策定. <https://www.etnews.com/20250924000152> (2026年8月2日閲覧)

3.3

違法伐採の音響検知とIoT/ブロックチェーンによる森林保護ネットワーク

熱帯雨林の高い木に、ソーラーパネルとマイクを備えた小さな装置が吊り下げられている。それは米国の非営利団体レインフォレスト・コネクションによるガーディアンだ。装置内で森林の音を分析し、チェーンソーや車両など人の侵入の兆候を検知するとアラートを送る。同団体は、その音響監視プログラムが726,000ヘクタール以上の保護に貢献したとしている。公表される累積値はプロジェクト期間や基準が異なるため、装置数、録音時間、確認された種を一つの成果としてまとめて比較することはできない。同じ録音には鳥、カエル、昆虫の声が含まれる。侵入アラートのために設置されたマイクは、生物多様性の耳にもなり得る。

衛星写真は樹木の除去が起きた後にしかそれを映さず、雲がそれさえ隠すことがある。徒歩によるパトロールで森全体を毎日走査することはできない。伐採を止めるには、チェーンソーを始動してから木が倒れるまでのわずか数分の間に、誰かが知らなければならない。この必要が、木に取り付けたマイクやセンサー、低消費電力の通信、音を即時に判断するAIを組み合わせたネットワークを広げてきた。

真夜中、マイクは二拍に分かれた波形をとらえることがある。人が引き金を繰り返し引いては放すときのエンジンのリズムだ。小さなチップがそれを数秒で走査し、枝の折れる音や通り過ぎるバイクと区別し、確信度スコアを付与する。ここから、音を認識するAI、現地での計算と通信、伐採された木材を追う台帳が、連携して働き始める。

チェーンソーを聞き分ける森の耳

動力機器のエンジン音は伐採の手がかりだ。幹や支柱に取り付けた超低消費電力の音響IoTセンサーが周囲の音を受け取り、小さなコンピュータで分析する。

Andreadisら（2021）は、音の特徴を抽出するCNNを超低消費電力の装置に置き、LoRaでアラートを送るプロトタイプを試験した。この論文は、限られた実験データから分類精度85パーセントを報告した。森林の種類、季節、機器が変われば、同じ精度を前提にすることはできない。

学習は見た目より難しい。バイクや小型発電機はチェーンソーと似た回転周波数を持ち、遠くで自然に折れる木や雷も初期のモデルを混乱させる。研究者は、実際の伐採現場と通常の森から数か月の音を集め、そうした事例をモデルに教えた。カバー範囲も地形や樹木の密度によって変わる。広い保護区を守るには、格子状に配置した数十から数百のノードが必要で、進入路や過去に伐採された地域が優先される。

密林では音が遠くまで伝わる前に拡散するため、音だけでは不十分になり得る。Prasetyoら（2018）は、チェーンソーの音と、伐採時に幹を伝わる微細な振動の両方を検知するセンサーを構築した。この組み合わせは誤ったアラートを大幅に減らした。一方の信号が弱まる場所では、他方が判断を支えられる。

電池による判断とドローンの出動

遠隔の森では、連続した元の録音をサーバーに送ることが難しい。モデルを装置上に置き、チェーンソーの確率が高いときにのみ座標と判断だけを送信すれば、通信量と消費電力を減らせる。LoRaWANは本質的に、隣接するセンサーが信号を中継するメッシュではなく、センサーがゲートウェイと直接通信するスター・オブ・スターズのネットワークだ。電波の届かない谷では、追加のゲートウェイや別の中継が必要になる。Sharmaら（2022）のLoEDは、LoRaとエッジコンピューティングを組み合わせた森林監視アーキテクチャを提案した。それは、あらゆる森で1分未満のアラートや40パーセントの通信量削減を一般的に主張できるだけの現地検証は提供していない。電池の寿命は、パネルの大きさ、日陰、送信頻度、計算負荷によって変わる。

管制センターでは、これらすべての計算が、座標、確信度、最も近いパトロール経路までの距離を伴う地図上の一点として現れる。職員は出動するかどうかを決める。繰り返される誤報は、彼らに現地モデルの感度を下げさせることがある。アラートの座標に送られたドローンは、映像による確認を加えられる。Ramadanら（2024）は音響センサー/UAVの構成を提案した。Kunduら（2025）は別の画像でYOLOv8とエージェント型AIを試験し、最大の再現率は約0.24、mAP50は約0.07だった。これらの研究は配備済みの自動出動システムを実証していない。当面は、音響アラートの後に人が画像を確認しなければならない。

切り株から陳列棚までのデジタルな痕跡

森の中での取り締まりでは、一見合法的書類をすでに携えた木材が市場に入るのを止められない。EU森林破壊規則、EUDR（規則2023/1115）は、木材を含む附属書Iの産品をEU市場で入手可能にする、またはEU市場から輸出する事業者に対し、位置情報の提供とデューデリジェンスの実施を求める。4ヘクタール以下の区画は単一の緯度経度点で表せる。より大きな区画には境界のポリゴンが必要だ。すべての木材製品とすべての小区画がポリゴン提出の対象になるわけではない。

ブロックチェーンは、参加者が同じ台帳の複製を保持する分散台帳技術だ。合意された記録の後からの改ざんを検知しやすくするが、当初に入力された偽りの原産地や種の情報は偽りのまま残る。Stopferら（2024）とDüdderとRoss（2017）は、木材サプライチェーンの記録を共有し、デューデリジェンスのコストを減らす可能性を検討した。ブロックチェーン単独で合法木材と違法木材の混入を防ぐ、あるいはすべての木の履歴を保証するという現地の証拠はない。RESET.orgのForestGuardは、森林破壊のないコーヒーのためのオープンソースのプロトタイプであり、木材サプライチェーンのプロジェクトではない。

図では、ハーベスタが座標と直径を記録し、輸送と製材の計測が一つの台帳に続いていく様子が示される。実際には、データ形式は製造者や企業によって異なり、丸太が板に分割されたり他の木材と混ざったりすると、そのつながりは弱まる。原産地の証明は税関や貿易に必要なかもしれないが、それ自体が高い販売価格を保証するわけではない。台帳と木材の隔たりを狭めるには、センサー、検証、物理的な標識、現地監査を組み合わせなければならない。バーコード、QRコード、RFIDは依然として必要な物理的なつながりだが、ハーベスタの自動標識、製材所のLiDAR、年輪の指紋、ブロックチェーンを組み合わせたシステムは検証されていない。Triplatら（2026）は別の写真で丸太を市場価値の等級によって分類しているが、それは木材トレーサビリティや三次元の指紋認証の試験ではない。

附属書Iの産品をEU市場に置く、またはEU市場から輸出するサプライチェーンに参加する韓国企業は影響を受け得る。家具や合板といった製品名だけでは対象範囲は決まらない。税関コード、企業の役割、原材料の経路を合わせて確認しなければならない。

相反する選択と未解決の課題

音響センサーは数秒以内に反応し比較的安価だが、雷、折れる枝、葉から誤報を引き起こすことがある。SAR衛星やドローンの画像は実際の伐採面積を地図化できるが、取得周期や雲のために反応が遅く、設置と運用のコストが高い。即時の反応と広範な確認の両方を供給する手法はまだない。誤ったアラートが繰り返されると、パトロールが本物のアラートに反応するのが遅くなり得るため、精度は現場職員の信頼を保つ問題でもある。

イーサリアムのような公開ブロックチェーンは透明だが、毎秒に処理できるトランザクションが少なく、費用が高くなり得る。伐採の最盛期には、毎時数百の丸太が製材所の計量器に到達し、ボトルネックを生むことがある。そのため多くの木材サプライチェーン研究は、特定の製材所と公的機関だけがアクセスできるHyperledger Fabricのようなプライベートチェーンやコンソーシアムチェーンを好む。参加者を制限することは、システムが守ろうとした開放性を損なう。

タグは雨、泥、山中での荒い運搬で外れたり故障したりし、丸太を製材やチップに加工すると標識が消えることがある。遠隔の音響センサーは風、雨、野生生物の騒音で精度を失い、そのソーラー電池は継続的なエネルギー管理を必要とする。不慣れなアプリに伐採記録を入力することは、専任の職員を抱える大企業と小さな私有林の所有者とでは、まったく異なる障壁を持つ。交換用の電池やパネル、修理されたノード、再学習された音のモデルを含む数年にわたる保守は、初期設置よりも費用がかかることがある。

EUはEUDRの実施時期を繰り返し調整した。現行の日程では、一般の事業者は2026年12月30日から対象となる。2024年12月31日以前に設立された自然人の零細および小規模企業は、別に2027年6月30日まで延期される。これはすべての小規模事業者が同じ延期を受けることを意味しない。法的形態と設立日を確認しなければならない。DNAと安定同位体の分析は、その代わりに、木材組織の遺伝的または化学的な痕跡を参照物質と比較し、種や原産地を推定する。タグが失われた後でも機能し得るが、参照のカバー範囲が限られ、時間と費用を要する。現地のシステムは、音響アラート、地理空間情報、物理的なタグ、書類確認、試料検査を組み合わせなければならない。StanForDは森林機械の生産・作業データ交換の標準であり、国際的な木材貿易の様式ではない。各国のデューデリジェンス記録と税関システムを結ぶ単一のブロックチェーンは、まだ受け入れられた運用標準ではない。

出典・参考文献

1. Andreadis, A., Giambene, G., & Zambon, R. (2021). Monitoring illegal tree cutting through ultra-low-power smart IoT devices. *Sensors*, 21(22), 7593. <https://doi.org/10.3390/s21227593>
2. Düdler, B., & Ross, O. (2017). Timber tracking: Reducing complexity of due diligence by using blockchain technology. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3015219>
3. European Commission, Access2Markets. (2026年1月28日). Delay until December 2026 and other developments in the implementation of the EUDR Regulation. <https://trade.ec.europa.eu/access-to-markets/en/news/delay-until-december-2026-and-other-developments-implementation-eudr-regulation> (2026年8月2日閲覧)
4. European Parliament and Council of the European Union. (2023). Regulation (EU) 2023/1115 of the European Parliament and of the Council of 31 May 2023 on the making available on the Union market and the export from the Union of certain commodities and products associated with deforestation and forest degradation and repealing Regulation (EU) No 995/2010. *Official Journal of the European Union*, L 150, 206-247. <https://eur-lex.europa.eu/eli/reg/2023/1115/oj>
5. Kundu, S., Ninoria, S. Z., Chaturvedi, R. P., Mishra, A., Agrawal, A., Batra, R., Dubale, M., & Hashmi, A. (2025). Real-time deforestation anomaly detection using YOLO and LangChain agents for sustainable environmental monitoring. *Scientific Reports*, 15, Article 39961. <https://doi.org/10.1038/s41598-025-23617-4>
6. Prasetyo, D. C., Mutiara, G. A., & Handayani, R. (2018). Chainsaw sound and vibration detector system for illegal logging. In 2018 International Conference on Control, Electronics, Renewable Energy and Communications (ICCEREC) (pp. 93-98). IEEE. <https://doi.org/10.1109/ICCEREC.2018.8712091>
7. Rainforest Connection. (2026). Rainforest Connection. <https://rfcx.org/> (2026年8月3日閲覧)
8. Ramadan, M. N., Ali, M. A., Khoo, S. Y., & Alkhedher, M. (2024). AI-powered IoT and UAV systems for real-time detection and prevention of illegal logging. *Results in Engineering*, 24, 103277. <https://doi.org/10.1016/j.rineng.2024.103277>
9. RESET.org. (2025年3月24日). ForestGuard: An open-source blockchain for deforestation-free coffee supply chains. <https://en.reset.org/forestguard-an-open-source-blockchain-for-deforestation-free-coffee-supply-chains/>
10. Sasaki, N., & Abe, I. (2025). A digital twin architecture for forest restoration: Integrating AI, IoT, and blockchain for smart ecosystem management. *Future Internet*, 17(9), 421. <https://doi.org/10.3390/fi1709421>
11. Sharma, M., Rastogi, R., Arya, N., Akram, S. V., Singh, R., Gehlot, A., Buddhi, D., & Joshi, K. (2022). LoED: LoRa and edge computing based system architecture for sustainable forest monitoring. *International Journal of Engineering Trends and Technology*, 70(5), 88-93. <https://doi.org/10.14445/22315381/IJETT-V70I5P211>
12. Stopfer, L., Kaulen, A., & Purfürst, T. (2024). Potential of blockchain technology in wood supply chains. *Computers and Electronics in Agriculture*, 216, Article 108496. <https://doi.org/10.1016/j.compag.2023.108496>
13. Tandon, A., Kaur, P., Mäntymäki, M., & Dhir, A. (2021). Blockchain applications in management: A bibliometric analysis and literature review. *Technological Forecasting and Social Change*, 166, 120649. <https://doi.org/10.1016/j.techfore.2021.120649>
14. Triplat, M., Lukančič, Ž., & Kavčič, V. (2026). Evaluation of deep learning models for image-based classification of timber logs by market value. *Forests*, 17(5), Article 518. <https://doi.org/10.3390/f17050518>

第4章

スマート林業作業とロボティクス：作業安全、自律走行、林道網の最適化

4.1

林道・集材路の自動抽出と地形に合わせた収穫計画

地図の上では緑の線が山腹を滑らかに横切り、トラックのナビゲーションは土場まで400メートルと案内していました。カーブを曲がると、道は消えていました。夏の豪雨が路盤の半分を谷へ流し、残った半分には腕ほどの太さのやぶが人の背丈まで伸びていました。丸太を満載したトラックは止まりました。山の間では無線信号が切れ、人が歩いて上がり、崩れた区間と傾斜を目で測り、手帳にスケッチして戻るしかありませんでした。後ろに続いた二台のトラックもアイドリングしたまま待ちました。地図は三年前のもので、森林はすでに変わっていました。

この状況は韓国でもなじみ深いものです。林道は毎年つくられ、毎年崩れます。韓国山林庁は2026年の予算を3兆260億ウォンとし、前年より15.6パーセント、4,091億ウォン増やしました。極端な気象に耐える林道の新設と補修は優先課題の一つです。国会は林道設置法を可決し、計画、設置、運営、維持管理を一つの法的枠組みに入れました。それでも地図が地上の現実と合わなくなれば、トラックの移動は止まります。そこで、空から得たデータで道路を自動的に描き直す取り組みが広がっています。

空から道路を描き直す

従来の調査は、人が道路を歩くか車で走り、路面を点検して地図を手で更新する方法に依存していました。密な樹冠の下では、小さな地形変化、路面の損傷、新しい通行跡が次の調査まで地図に現れないことが多くありました。航空レーザー測量はこの隙間を埋めます。飛行機やドローンに載せたLiDARは地面まで届いた反射を選び、デジタル地形モデル（DTM）をつくるとともに、樹冠高モデル（CHM）と傾斜図をつくれます。道路には痕跡があります。緩やかで滑らかで、幅が一定した帯です。AIはこの痕跡を学び、線を引き、横断面から使える幅と路面状態を分析し、既存のネットワークファイルに、途切れた区間、侵食された区間、植生に覆われた区間を更新します。出力は通常、GISで使えるベクターファイルです。

Rousselらの2022年のALSroadsシステムは、道路幅、傾斜、曲率を含む七つの指標を点群から抽出し、経路探索と組み合わせて古い道路地図を補正しました。

Bujánらはこれより前に、傾斜、曲率、反射率を組み合わせるルールベースのハイ

ブリッド分類を使いました。CNNとU-Netモデルも、閉じた樹冠の下を含め、DTMに現れる平らで滑らかな道路形状を周囲の地形から区別します。

広い地域を対象にする作業では、Morleyらは2024年に単一光子LiDARで北部地域の道路網を更新しました。Winiwarterらは3メートル解像度のPlanetScope CubeSat画像にCNNを適用しました。雲と煙のないモザイクを選んだため、きれいな画像がない場所は空白として残りました。これは雲を通して光学衛星観測を行うものではありません。Siafaliらは、航空LiDAR、移動式SLAM LiDAR、iPhone LiDARを組み合わせ、山岳林道の路面を復元しました。広域観測と近距離の精密測定は、異なる問題を解きます。

トラックが実際に通れる幅

地図に引かれた線は、大型木材トラックが通れることの証明ではありません。KarjalainenとWagaは、道路に直角な地表面の横断面を機械学習で分析する方法を示しました。枝が上からの直接的な幅測定を妨げる場所でも、横断面から通行可能幅、侵食、亀裂、詰まった側溝、路傍植生を読み取れます。明瞭な横断面には、中央の平らに締め固められた部分、両側の緩やかな排水勾配、その外側の元の山腹斜面が現れます。横断面がぼやけたり、片側が崩れたりしていれば、補修が必要な合図です。

Hrůzaら（2025）は、UAVと航空LiDARを組み合わせ、道路建設を妨げる岩、切り残した切り株、倒れた枯死木を見つけ、地面を乱す前に土場までの経路をシミュレーションしました。Tanakaら（2025）は、LiDAR解析だけから傾斜、微気候、立木、適切な土場位置を一つのデータセットで導き、林業作業道の建設優先順位を付ける日本のアルゴリズムを示しました。別々の測量班に資金を出せない小規模な組合や企業にも役立つ可能性があります。

車輪の跡を測る

林道が正式なトラック道路であるのに対し、集材路はハーベスタ、フォワーダ、スキッダがつくる一時的な通路です。重い機械が繰り返し通ると土は締め固まり、わだちが深くなります。締め固められた土は空気と水のための孔隙を失い、流出が増え、残った木の根はゆっくりしか育たず、損傷は地すべりや濁った川に結び付くことがあります。Abdiら（2022）は、高密度航空LiDARとU-Netで、下層植生に一部隠れた集材路を区分しました。Latteriniらは地中海地域の五地点で、伐採前後のUAV LiDARを比較し、陰影図、局地起伏モデル、相対密度モデル、SkidRoad_Finderを使いました。相対密度モデルが最も良く、精度はおよそ73パーセント、感度は66パーセントで、わだちの深さ、体積、締め固めリスクも推定しました。Usui（2021）は、集材路画像が少ない問題に対し、GANで生成したデータ拡張を扱いました。

損傷を避ける経路を先に計算する

集材路をつくった後に損傷を測れば、すでに起きた問題が分かります。損傷を減らすには、伐採前に経路を選ばなければなりません。Görgensら（2020）は、LiDARから得た木の位置と材積、地形傾斜、土壌湿潤指数を、遺伝的アルゴリズム、動的計画法、線形計画法と組み合わせました。このモデルは、丸太の運搬距離を減らしながら、締め固めリスクの高い場所と急傾斜地を避けます。Picchioら（2018）はイタリアの山地について、傾斜、侵食感受性、残存木への損傷、ケーブルヤダ、フォワーダ、ウインチ補助のどれを使うかを考慮するGIS意思決定支援モデルをつくりました。Eberhardらは2025年に関連モデルを急傾斜地へ広げました。緩い地面ではフォワーダが動き、より急な斜面ではケーブルヤダが丸太をつり上げます。出力された経路は紙でもタブレットでも渡せます。

理論と現場の間にはなお隔たりがあります。単一光子LiDARとCubeSat画像は主要なネットワークを安く広く覆えますが、狭い集材路とわだちは解像できません。ドローンLiDAR、地上SLAM、携帯電話LiDARはセンチメートル単位に達しますが、覆える面積は小さく、処理にも時間がかかります。Görgensの理論上の最適経路は、日々の天気、障害物、運転者の行動を完全には捉えられないため、Abdiが観察した実際の運転経路と一致しない場合があります。夏の濃い葉と下層植生は地面からの反射を減らし、高密度点群は計算負荷が高く、地形と樹種が異なる森林へ移すには現地での検証が必要です。

雪は別の問題を加えます。PodolskaiaとSinitsinaの2026年のクラスノヤルスク地方の冬季道路データセットは、冬にだけ見え、雪解けとともに消える道路を記録しており、アルゴリズムが季節と緯度をまたいで学び直されなければならないことを

示します。Gaoらは2026年に、多時期衛星画像におけるDeepLabv3+を改善し、山火事対応者のための林道アクセスを識別しました。これらのモデルすべてにはラベル付き学習データが必要であり、地域ごとに異なる道路と集材路について、それを得るには時間がかかります。今後の課題には、AIが通行可能と判断した背景にある傾斜と路面のうねりを技術者に示す画面があります。StanForDは計画を機械へ渡すときの生産データ連結として考えられますが、それ自体が安全な航行を確立するものではありません。経路データ、機械制御、安全規則は別々に検証する必要があります。

出典・参考文献

1. Abdi, O., Uusitalo, J., & Kivinen, V. P. (2022). Logging trail segmentation via a novel U-Net convolutional neural network and high-density laser scanning data. *Remote Sensing*, 14(2), 349. <https://doi.org/10.3390/rs14020349>
2. Buján, S., Guerra-Hernández, J., González-Ferreiro, E., & Miranda, D. (2021). Forest road detection using LiDAR data and hybrid classification. *Remote Sensing*, 13(3), 393. <https://doi.org/10.3390/rs13030393>
3. Eberhard, B., Trailović, Z., Magagnotti, N., & Spinelli, R. (2025). A GIS-based decision support model (DSM) for harvesting system selection on steep terrain: Integrating operational and silvicultural criteria. *Preprints*, 2025011137. <https://doi.org/10.20944/preprints202501.1137.v1>
4. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
5. Gao, Z., Li, Z., Yao, W., Zhang, T., Qiu, S., & Liu, Z. (2026). Forest road extraction via optimized DeepLabv3+ and multi-temporal remote sensing for wildfire emergency response. *Applied Sciences*, 16(7), 3228. <https://doi.org/10.3390/app16073228>
6. Görgens, E. B., Mund, J. P., Cremer, T., de Conto, T., Krause, S., Valbuena, R., et al. (2020). Automated operational logging plan considering multicriteria optimization. *Computers and Electronics in Agriculture*, 170, 105253. <https://doi.org/10.1016/j.compag.2020.105253>
7. Hrůza, P., Mikita, T., & Žižlavská, N. (2025). Application of unmanned aerial vehicle and airborne light detection and ranging technologies to identifying terrain obstacles and designing access solutions for the interior parts of forest stands. *Forests*, 16(5), 729. <https://doi.org/10.3390/f16050729>
8. Karjalainen, T., Karjalainen, V., Waga, K., & Tokola, T. (2024). Predicting the roadway width of forest roads by means of airborne laser scanning. *International Journal of Applied Earth Observation and Geoinformation*, 133, 104109. <https://doi.org/10.1016/j.jag.2024.104109>
9. Latterini, F., Dyderski, M. K., Picchio, R., Venanzi, R., Spinelli, R., & Magagnotti, N. (2025). Mapping skid trails and evaluating soil disturbance from UAV-based LiDAR surveys in Mediterranean forests. *Land Degradation & Development*. <https://doi.org/10.1002/ldr.70162>
10. Morley, I. D., Coops, N. C., Roussel, J. R., Achim, A., Dech, J., & Meecham, D. (2024). Updating forest road networks using single photon LiDAR in Northern forest environments. *Forestry: An International Journal of Forest Research*, 97(1), 38-47. <https://doi.org/10.1093/forestry/cpad021>
11. Picchio, R., Pignatti, G., Marchi, E., Latterini, F., Benanchi, M., Foderi, C., Venanzi, R., & Verani, S. (2018). The application of two approaches using GIS technology implementation in forest road network planning in an Italian mountain setting. *Forests*, 9(5), 277. <https://doi.org/10.3390/f9050277>

12. Podolskaia, E., & Sinitsina, A. (2026). A machine learning dataset on winter roads of Krasnoyarsk Krai, Russia for the forestry and infrastructural projects. *European Journal of Forest Engineering*, 12(1), 7-22. <https://doi.org/10.33904/ejfe.1743822>
13. Roussel, J. R., Bourdon, J. F., Morley, I. D., Coops, N. C., & Achim, A. (2022). Correction, update, and enhancement of vectorial forestry road maps using ALS data, a pathfinder, and seven metrics. *International Journal of Applied Earth Observation and Geoinformation*, 114, 103020. <https://doi.org/10.1016/j.jag.2022.103020>
14. Siafali, E., Polychronos, V., & Tsioras, P. A. (2025). Fusion of airborne, SLAM-based, and iPhone LiDAR for accurate forest road mapping in harvesting areas. *Land*, 14(8), 1553. <https://doi.org/10.3390/land14081553>
15. Tanaka, K., Uehagi, H., Shiota, H., & Mishima, Y. (2025). Prioritizing forest-operation-road construction using LiDAR analysis results only: a method proposed for Fukuchiyama City, Kyoto Prefecture. *Journal of the Japan Forest Engineering Society*, 40(1), 15-20. https://www.jstage.jst.go.jp/article/jjfes/40/1/40_40.3/_article/-char/ja
16. Usui, K. (2021). Data augmentation using image-to-image translation for detecting forest strip roads based on deep learning. *International Journal of Forest Engineering*, 32(1), 57-66. <https://doi.org/10.1080/14942119.2021.1831426>
17. Waga, K., Tompalski, P., Coops, N. C., White, J. C., Wulder, M. A., & Malinen, J. (2020). Forest road status assessment using airborne laser scanning. *Forest Science*, 66(4), 501-508. <https://doi.org/10.1093/forsci/fxz053>
18. Winiwarter, L., Coops, N. C., Bastyr, A., Roussel, J. R., Zhao, D. Q. R., & Lamb, C. T. (2024). Extraction of forest road information from CubeSat imagery using convolutional neural networks. *Remote Sensing*, 16(6), 1083. <https://doi.org/10.3390/rs16061083>
19. Korea Forest Service. (2025年12月12日). 2026年の重点課題：「人を救う森林、森林を救う人」. <https://v.daum.net/v/20251212095549587> (2026年8月2日閲覧)
20. Korea Forest Service. (2026). 国会が林道設置法を可決、林道の設置と管理の法的基盤を整備. <https://idsn.co.kr/news/view/1065599659428633> (2026年8月2日閲覧)

4.2

遠隔操縦ハーベスタ、自律走行フォワーダ、林業ロボティクス

操作者は事務所の椅子に座っています。足元にはカーペットがあり、机には冷めたコーヒー、窓の外には駐車場、目の前には六つのモニターがあり、手にはゲームコントローラーのようなジョイスティックがあります。数年前なら、この人は急斜面で振動するキャビンに入り、エンジン音の中で木を切っていたはずです。今は、小さなジョイスティックの動きで、数百メートル先のロボットアームが木をつかみます。一つの画面は根元のグラップル角度を示し、別の画面は機械の傾きを示し、さらに別の画面は近くの人と機器を確認する映像を映します。キャビンからは見えなかった角度が、事務所では同時に見えます。残るのは指先の小さな動きだけです。

これはもうSFではありません。2025年秋、遠隔操作に対応した新造Komatsuフォワーダが、スウェーデンのウプサラ近郊、イエラにあるTroëdsson林業遠隔操作研究所へ入りました。ウメオ大学と共同する研究者は、ロボットが自ら判断するよう訓練するAIモデルのためのデータを取り出しています。人も木も傷つかず、作業を持続できる林業が目的です。

韓国でも似た作業が始まっています。国立山林科学院は2025年8月、GNSSとINSを組み合わせ、カメラで学習したAIを機体内部で直接動かす知能型林業作業ロボットの走行試験を発表しました。ロボットは林道を認識し、中心線を見つけ、それに沿って進みました。計算を機体に載せているため、通信が弱くなったり失われたりしても止まりません。携帯電話の電波さえ不安定な韓国の深い森林に合う方法です。

危険な場所へ先に機械を送る理由は明白です。チェーンソーによる伐倒と集材には、急斜面、落石、機械の転倒、筋骨格への負担が重なります。映像と慣性センサーから作業姿勢や作業段階を高い精度で分類する実験もありますが、その値は小さな試験集合や限定された活動区分から出たもので、すべての森林作業姿勢と疲労状態を同じように認識できることを示すものではありません。慶尚北道奉化郡では、韓国山林庁の永州国有林管理所が2026年8月から、ハーベスタ、フォワーダ、マルチャーを含む高性能機械を保管・整備する専用デポを運営する予定です。ロボットを開発することと並行して、それを買ひ、動かし、修理するための基盤も整えられています。

45度の斜面を進む機械

ウインチアシスト装置は、斜面上部の丈夫な木または専用アンカー機に固定した強いケーブルと、下にいるハーベスタをつなぎ、継続的な牽引力を加えます。このケーブルは、車輪や履帯だけでは滑る斜面で、30度から45度を超える傾斜でも機械を地面につなぎとめられます。この装備がなかったころ、人はチェーンソーを抱えてこうした斜面を歩きました。ケーブルなしで急傾斜地に置かれた機械は、車輪を空転させ、土を荒らし、転倒することがあります。

日本森林機械協会の実演は、傾斜ごとに方法を明確に分けます。中程度の斜面では、遠隔操縦ハーベスタが木を切り、自律走行フォワーダが運び、以前なら五、六人が行った作業を二人で進められます。さらに急な斜面では、人が担いで行うチェーンソー作業を遠隔操縦のウインチアシストハーベスタに置き換え、ケーブルグリップまたはタワーヤーダで木材を集材します。人は画面の前に残り、機械が危険な斜面を上ります。2025年に発表された欧州研究は、傾斜、侵食リスク、残存木保護を組み合わせるGIS意思決定支援モデルでこれを支えます。ある区域はウインチアシストに耐えられ、別の区域では車輪跡を残さないケーブル集材が必要かもしれません。答えを選ぶのは勘ではなく地図の値です。

木が衛星信号を遮る場所

森林の奥では空が消えます。密な樹冠はGNSS信号を切ったり、反射した信号を誤った位置として混ぜたりします。遠隔操縦または自律走行の機械は、人の目と感覚に頼れないため、地上のセンサーから位置と周囲の地図を同時につくるSLAMが必要です。Yaoらは2025年、密な森林を走る林業機械のためにHector SLAMを改良しました。葉と細い枝から反射したLiDAR点を取り除き、IMU測定値を融合して不整地で生じるスキンのゆがみを補正し、滑ることのある車輪回転には頼らず、LiDAR点を一致させて移動を推定しました。

基準となるHector SLAMと比べ、誤差は47.65パーセント下がりました。平均地図作成誤差は4.78センチメートル、最大誤差は8.7センチメートル未満でした。停止中の平均位置誤差は9.9センチメートルでした。三つの速度設定を通じて水平誤差は7.9センチメートル以内、方位誤差は36.5度未満にとどまりました。狭い林道では、数センチメートルの差が車輪が道を外れるか、残存木の根を傷つけるかを決めることがあります。国立山林科学院の道路走行試験とYaoらの森林内部試験は異なる対象ですが、二つを合わせると、GNSSが届かない森林での自律移動が国際的な問題であることが分かります。

四足歩行ロボットと荷を運ぶロボット

森林の地面は非常に不規則です。大きな岩、腐りかけの倒木、膝の高さの低木、落とし穴のようなくぼみが、車輪式と履帯式の機械をともに妨げます。EUのDigiMedForプロジェクトは、Boston Dynamicsの四足歩行ロボットSpotに三次元LiDAR、高解像度カメラ、小型コンピューター、光学フィルター、GPS、傾斜センサーを載せてこの問題に取り組みました。Spotは砂利、低木、斜面を越え、点群と画像を集め、一本ごとの木の情報を含むデジタルツインを更新しました。車輪なら空転して止まる場所でも、脚を一本ずつ調整しました。

スウェーデンの研究は、代わりに自律走行フォワードを技術・組織・環境（TOE）の枠組みで検討しました。工場の床や都市道路と違い、森林の条件は天気、土壌水分、木の形で変わります。そのため研究者は完全自律ではなく協働を提案しました。経験ある運転者が大まかな計画を判断し、ロボットは限定された航行、障害物回避、残存木からの距離確保を担う方法です。これは機械だけでなく仕事も変えます。操作者は遠隔ステーションへ移り、整備担当者は自律機器のための訓練を必要とします。

緊急停止と認識を試験するときに機械と森林を傷つけないよう、ラップランド応用科学大学とスウェーデンのRISEは仮想森林をつくりました。Vindelnのデジタルツインは、ドローン画像と高解像度レーザースキャンを含む現地資料を使います。その中で視点、太陽角度、木の位置を変えると、SimForestという合成RGB-Dインスタンスセグメンテーションデータセットが生成されます。作業者が突然機械の進路へ入る場面や濃霧のようなシナリオを何百回も繰り返せるため、現実の危険を伴わずに試験できます。

まだ成熟していない自動化

歩行ロボットは絡んだ地面を確実に進み、下層植生を精密にスキャンできますが、運べるのは数十キログラムに過ぎず、伐採や丸太運搬はできません。自律走行フォワードと遠隔操縦ハーベスタは数トンの丸太を扱えますが、荒く密な地形ではぬかるみにはまったり、土を締め固めたりします。一つの身体がすべての森林に合うわけではなく、異なる身体の機械を地形に応じて配置する必要があります。仮想森林での結果と実際の森林の間にも隔たりがあります。霧、雨、レンズのほこり、動く枝、逆光はカメラとLiDARの判断を弱め、性能低下の大きさはセンサー、天気、試験データによって変わります。合成データで学習したモデルには、実森林での別の評価が必要です。

Spotのような電動歩行ロボットは屋外では一、二時間で電池が尽きることがあり、長い遠隔任務には向きません。SLAMは密な森林を長く進む間にループ閉鎖を失い、

位置誤差を積み上げることがあります。その結果、画面には機械が道路上にあると表示されても、実際には木の間へそれているかもしれません。高い初期費用は小規模な林家にとって重く、誤作動の責任も定まっていません。人を認識できなかった事故の後には、製造者、林業会社、遠くでジョイスティックを操作していた人のいずれもが関係する可能性があります。Chenら（2025）が提案したような分散型マルチロボット制御は、道路を点検するドローン、地形を調べる歩行ロボット、木材を運ぶフォワーダをつながられるかもしれません。しかし林業で導入するには、断続的な通信、現場での計算、衝突回避、非常停止を一緒に検証する必要があります。StanForDは記録交換を助けるもので、ロボット安全ではありません。停止時間は速度、制動距離、検知範囲、作業者との距離から決める必要があります。法的な安全インターロックと国際データ標準を整える制度上の作業は、ロボットそのものを作り直すより時間がかかるかもしれません。

出典・参考文献

1. Bergqvist, M., Nylén, D., Lindberg, A., & Åkesson, M. (2026). Digital innovation in data-poor and unstructured environments: Envisioning autonomous systems in forestry. *Proceedings of the 59th Hawaii International Conference on System Sciences (HICSS)*, 5881-5890.
<https://umu.diva-portal.org/smash/get/diva2:2044606/FULLTEXT01>
2. Borz, S. A., Kaakkurivaara, T., Forkuo, G. O., & Kaakkurivaara, N. (2026). Activity recognition in motor-manual cross-cutting operations by machine learning on multimodal data. *Forest Science and Technology*, 22, 26-35. <https://doi.org/10.1080/21580103.2025.2543281>
3. Chen, J., Chen, M., Wang, J., Mao, Q., Xie, F., & Dames, P. (2025). Distributed multi-robot active gathering for non-uniform agriculture and forestry information. *Frontiers in Plant Science*, 16, Article 1699124.
<https://doi.org/10.3389/fpls.2025.1699124>
4. DigiMedFor Project Consortium. (2025). Webinar #3: Enhancing forestry inventory, quadruped robot (Spot) field performance and demonstration [動画]. YouTube. <https://www.youtube.com/watch?v=58rjC9O-1Mk> (2026年8月2日閲覧)
5. Eberhard, B., Trailović, Z., Magagnotti, N., & Spinelli, R. (2025). A GIS-based decision support model (DSM) for harvesting system selection on steep terrain: Integrating operational and silvicultural criteria. *Preprints*, 2025011137. <https://doi.org/10.20944/preprints202501.1137.v1>
6. Forest Machine Magazine. (2025年12月9日). The next step in the automation of forestry machines. <https://forestmachinemagazine.com/the-next-step-in-the-automation-of-forestry-machines/> (2026年8月2日閲覧)
7. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14.
<https://doi.org/10.1007/s40725-026-00275-x>
8. Forkuo, G. O., Bilici, E., & Borz, S. A. (2026). Automated OWAS in forestry using deep learning for posture classification. *International Journal of Industrial Ergonomics*, 113, 103930.
<https://doi.org/10.1016/j.ergon.2026.103930>
9. Forestry and Forest Products Research Institute. (2025). 2025年度FFPRI公開講演会：2050年の森と人口減少社会におけるその役割 [動画]. YouTube. <https://www.youtube.com/watch?v=OEhqSNoACCo> (2026年8月2日閲覧)

10. Japan Forest Machinery Association. (2026). 令和7年度スマート林業機械・新木質材料シンポジウム第3部 [動画]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (2026年8月2日閲覧)
11. Avula, R. R., Narkilahti, A., & Unga, J. (2026). From digital twin to AI-based perception system validation. In A. Saloniemi (Ed.), Digital Solutions for Forestry (Pohjoisen tekijät - Lapland University of Applied Sciences Publications, 7/2026). Lapland University of Applied Sciences. <https://urn.fi/urn:isbn:978-952-316-582-3>
12. Yao, L., Wen, J., Bian, C., Chen, Y., Xu, L., & Yao, L. (2025). Localization and mapping method for forestry mobile platforms based on enhanced Hector SLAM. Journal of King Saud University - Computer and Information Sciences, 37, Article 229. <https://doi.org/10.1007/s44443-025-00221-0>
13. Robot Newspaper. (2025年8月6日). 国立山林科学院、オンボードAIに基づく知能型林業作業ロボットを開発. <https://www.irobotnews.com/news/articleView.html?idxno=41635> (2026年8月2日閲覧)
14. Eze Insurance News. (2026年7月31日). 森林の未来を運ぶ：高性能林業機械デボが本格稼働を開始. https://dazabi.com/insurance_magazine/article.php?id=40560 (2026年8月2日閲覧)

4.3

コンピュータビジョンとウェアラブルセンサーに基づく作業安全監視

江原道麟蹄の伐採現場では、午前6時、作業者がヘルメットのあごひもを二度締めます。つばの内側には、爪ほどの大きさの灰色の慣性計測装置（IMU）があり、体の傾きと歩く速度を測っています。会社がこのヘルメットを支給したのは三か月前で、作業者が主に覚えているのは重さが約20グラム増えたことです。チェーンソーが始動すると鳥は鳴きやみ、エンジン音が谷を満たします。今日伐る予定の木は三本で、斜面は昨日より急です。

雇用労働部は2026年3月、2025年の林業・漁業を合わせた区分で労災死亡者が18人となり、前年より11人増えたと発表しました。統計は林業だけを分けていませんが、この区分は卸売・小売業と並び、安全管理体系が弱い小規模事業場の一つに挙げられました。倒れる木、斜面での転倒、機械による挟まれでの死亡事故は繰り返されます。産業安全保健法施行令第24条は、林業を製造業、下水・廃棄物処理業と同じ区分に入れ、常時20人超50人未満の労働者を使う事業場は少なくとも一人の安全保健管理担当者を置くよう定めます。人を指定しても、急斜面でチェーンソーを持ち一人で働く人の姿勢をリアルタイムで見ることはできません。林業の作業者は高齢化しており、多くは以前ほど強くない体で急な山を登り続けています。

林業には不規則な斜面、重い丸太、危険な動力機械が重なります。米国労働統計局の2023年データでは、伐採作業者の死亡率は10万人当たり98.9人で、全労働者平均3.5人のおよそ28倍でした。伐倒、枝払い、玉切りには、曲げる、ひねる、身をかがめる姿勢が長く続き、作業関連筋骨格障害（WMSDs）につながります。

OWASは背中、腕、脚、荷重を四つのリスク水準に分類します。水準1は変更不要、水準4は直ちに是正が必要という意味です。RULAとREBAも関連する体系ですが、従来はどれも人が動画をコマずつ確認する必要がありました。コンピュータビジョンとウェアラブル機器は、すべての林業作業者を人が継続して観察するには大き過ぎる仕事を自動化するために現れました。

カメラが姿勢を読む方法

人体姿勢推定は、映像で肩、肘、膝などの関節点を追います。Forkuoらは画像と骨格の接続線を用いてResNet-50を学習させました。均衡の取れた252枚の試験画像で、OWASの精度とF1は99.8パーセントでした。これは小さく均衡した試験集合であり、遮蔽と光の変化がある実際の森林で同じ性能を示すものではありません。同じ研究グループによる2025年の論文は、モデルが人の評価より19倍から53倍速かったこと、人の評価者間のFleissのカッパが0.28から0.49だったことを示しました。これらの数字は、人の速度と人同士の不一致を表すものであり、モデルがより正確で、カメラ角度が変わっても頑健である証明ではありません。

画像埋め込みとInception V3、SqueezeNetを使った彼らの研究は、開発時には84パーセントと89パーセントを達成しましたが、未知のデータではおよそ49パーセントから60パーセントでした。この論文はスマートフォンによる現場運用を示していません。小さなモデルであることと、山中の携帯電話で安定して動くことは別の主張です。

身体に着けるセンサーと音

樹冠、葉、枝の下で身体が見えないとき、カメラは役に立ちません。ウェアラブル機器はこの死角を埋めます。携帯電話や腕時計の三軸加速度計とジャイロスコープ、身体または機器に付ける騒音線量計は、カメラがなくても動きと振動を測れます。チェーンソーを持つ手の震え、肩の傾き、不安定な歩き方は、日陰や霧にかかわらず数字になります。Borzらは、玉切り作業中の作業者とチェーンソーに加速度計と線量計を取り付け、七つのモデルを試験しました。背中に一つだけ付けた加速度計の精度は63パーセントでしたが、チェーンソーの加速度と騒音を組み合わせた設定の一部は99.8パーセントに達しました。この研究は作業、休憩、移動のような活動状態を分けたもので、同じ精度で過度な関節屈曲や疲労を診断したものではありません。センサー位置と行動区分が変わるたびに性能を再試験する必要があります。

韓国ではセンサー付きヘルメットが導入されています。2025年5月21日の報道によると、Asgardの建設作業向けスマートヘルメットTUGUには、衝撃・温湿度センサー、カメラ、無線機能が入っています。これは製造者の説明であり、独立した現場検証ではなく、林業専用でもありません。韓国山林庁は2020年10月、国立漆谷森林体験館で山火事隊員向けにウェアラブルロボットと知能型ヘルメットの試作品を実演しましたが、これらが全国の伐採現場で標準装備になったことを示す資料は見つかりませんでした。ウェアラブル機器には、汗と荒い作業による脱落、一日持たない電池、着用を望まない作業者という問題もあります。

ヘルメットが話するとき

大規模言語モデルが林業安全相談を助けられるかを評価する研究もあります。

Arimizu Kengo (2026) は、林業事故の場面と専門家質問に対するモデルの回答を評価しました。過去の事故報告書と写真からリスクを自動判定する、実装済みの完全な現場システムではありません。かかり木のように文脈に敏感な危険は、モデルだけで扱わず、経験ある実務者が確認すべきです。

Hayashiらの2025年から2026年の研究は、林業安全カードゲームの助言者としてChatGPTに基づく対話エージェントを付けました。各カードはもっともらしい伐採現場の状況と質問を示し、エージェントが参加者の答えを見直します。学生と初心者を対象にした前後比較では、安全コミュニケーションと個人安全を含む五つの領域すべてで、40項目の職場安全尺度に統計的に有意な向上が見られました。しかし初期の汎用モデルの回答は、燃料容器の材質やチェーンソーの目立てのような林業特有の質問に対して、関係のない機械工学の回答を八件出しました。林業安全の知識カードを文脈内学習に使うカスタムモデルでは、これが二件に減りました。音声自動認識も、チャップスやかかり木といった用語を誤って文字起こししたため、標準的な確認手順が提案されました。

Ehrlich-Sommerらが2025年に紹介したForestGPTは、オーストリアのPötte Expoで、イベント資料およそ1MBをもとに来場者の質問へ答えた対話型試作品です。検索拡張生成、森林生長シミュレーション、センサー、ドローン、機械データとの統合は後の開発段階であり、現在の試作品はそれらすべての機能を持つ完全な現場モデルではありません。

見られているという感覚

想定した現場導入では、複数の伐採作業者のリアルタイムリスク水準が事務所モニターに現れ、水準4に達すれば管理者の携帯電話へ警報が送られます。これは安全管理には歓迎されますが、ヘルメットをかぶる人にとっては別の意味を持ちます。カメラは身体に何も付けずに済みますが、枝の後ろにいる作業者を見落とします。ウェアラブル機器は遮蔽を通して働きますが、汗、電池、受け入れの負担を課します。汎用言語モデルは多くの言語で柔軟に会話できますが、浅い林業知識をもっともらしく作ることがあります。知識を与えたカスタムモデルは誤りを減らしますが、カードの外にある質問には情報がないと答えるかもしれません。精度だけでも、柔軟な会話だけでも十分ではありません。

実験室の分類と現場での緊急停止の間には、根本的な隔たりが残ります。通信が切れる森林で、姿勢判定または人認識を機械制御につなげる完全な検証はまだ少ない

ものです。実際の伐採現場では、泥、寒さ、通信断、機械ごとの制動距離を一緒に試験する必要があります。

連続カメラはデータ統治の問いも生みます。ヘルメットのセンサーから会社サーバーへ送られるデータは誰のものか、どれほど保管するのか、事故以外に使うのかという問いです。文献はこれらを明確に解決していません。事務作業におけるAI監視の議論では、安全データが他の評価へひそかに再利用されることが繰り返し指摘されています。国土交通部と国土安全管理院は2026年5月、スマート安全装備の指針を改め、ウェアラブルカメラを含む作業者保護装備を三大分類、七中分類に整理しました。これは建設分野の指針であり、2026年8月までに林業に特化した対応物は現れていませんでした。

毎月のカメラ、センサー、サーバー料金を払うと予想される事業者の大半は、小さな伐採企業です。費用を負担できず導入を先送りするところもあれば、負担できてもデータ利用をめぐり作業者と争うところもあります。遠隔ハーベスタと自律走行フォワーダは人を危険な斜面から遠ざけられますが、チェーンソーを持つ人は残ります。安全監視技術が最終的に向き合うのは、その残る作業者です。次段階の提案には、Grad-CAMとSHAPを使ってリスク判断の背景となった身体部位を示す説明可能AIダッシュボード、通信の切れる山中端末に小さなモデルを載せる知識蒸留があります。論文はすでに、WMSDsを防ぎ事故を早期に捉えるための、カメラ、ウェアラブル機器、言語モデルを統合したパイプラインを提案しています。そのような体系が標準的な伐採装備になる日、また記録画像と信号を誰がどれだけ保有するかを決める規則は、まだ来ていません。リスク評価と警報は、その結果を誰かに委ねる規則より速く高度化しています。

出典・参考文献

1. Borz, S. A., Kaakkurivaara, T., Forkuo, G. O., & Kaakkurivaara, N. (2026). Activity recognition in motor-manual cross-cutting operations by machine learning on multimodal data. *Forest Science and Technology*, 22, 26-35. <https://doi.org/10.1080/21580103.2025.2543281>
2. Ehrlich-Sommer, F., Eberhard, B., & Holzinger, A. (2025). ForestGPT and beyond: A trustworthy domain-specific large language model paving the way to Forestry 5.0. *Electronics*, 14(18), 3583. <https://doi.org/10.3390/electronics14183583>
3. Forkuo, G. O., Borz, S. A., Kaakkurivaara, T., & Kaakkurivaara, N. (2025a). Postural classification by image embedding and transfer learning: An example of using the OWAS method in motor-manual work to automate the process and save resources. *Forests*, 16(3), 492. <https://doi.org/10.3390/f16030492>
4. Forkuo, G. O., Marcu, M. V., Kaakkurivaara, N., Kaakkurivaara, T., & Borz, S. A. (2025b). Human and machine reliability in postural assessment of forest operations by OWAS method: Level of agreement and time resources. *Forests*, 16(5), 759. <https://doi.org/10.3390/f16050759>

5. Forkuo, G. O., Bilici, E., & Borz, S. A. (2026). Automated OWAS in forestry using deep learning for posture classification. *International Journal of Industrial Ergonomics*, 113, 103930.
<https://doi.org/10.1016/j.ergon.2026.103930>
6. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14.
<https://doi.org/10.1007/s40725-026-00275-x>
7. Hayashi, K., Shimazaki, K., Takahashi, A., Ikeda, M., & Matsumoto, Y. (2025/2026). Implementation and learning-effect evaluation of a forestry-safety education game with an AI adviser: a pre/post comparison and utterance-analysis evaluation. *Journal of Occupational Safety and Health*, 18/19, 1-12.
<https://doi.org/10.2486/josh.JOSH-2025-0011-GE>
8. Arimizu, K. (2026). Possibilities and limitations of forestry-safety support using large language models. *Journal of the Japan Forest Engineering Society*, 41(1), 5-14. <https://doi.org/10.18945/jjfes.2026.250013>
9. Japan Forest Machinery Association. (2026). 令和7年度林業・木材産業労働安全推進ウェビナー全編 [動画]. YouTube. <https://www.youtube.com/watch?v=Q1w9DxFpgE8> (2026年8月2日閲覧)
10. Japan Forest Machinery Association. (2026). 令和7年度スマート林業機械・新木質材料シンポジウム第3部 [動画]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (2026年8月2日閲覧)
11. Ministry of Employment and Labor. (2026年3月31日). 2025年の産業災害補足統計（累計）. https://www.moel.go.kr/news/enews/report/enewsView.do?news_seq=19159 (2026年8月2日閲覧)
12. Ministry of Land, Infrastructure and Transport and Korea Authority of Land & Infrastructure Safety. (2026年5月6日). 建設現場でのスマート安全装備の選定・利用がより容易に. <https://v.daum.net/v/20260506110012733> (2026年8月2日閲覧)
13. Mechanical Equipment Newspaper. (2025年5月21日). Asgardが建設作業向けスマートヘルメット「TUGU」を開発. <https://www.kmecnews.co.kr/news/articleView.html?idxno=41084> (2026年8月2日閲覧)
14. Security News. (2020年10月31日). ウェアラブルロボットと知能型ヘルメットで森林災害に対応. <https://m.boannews.com/html/detail.html?idx=92245> (2026年8月2日閲覧)

第5章

持続可能なアグロフォレストリーと木材 サプライチェーンDX

5.1

アグロフォレストリーシステムにおける水利用効率（WUE）と生態系サービスの最適化

インド北部パンジャブ地方では、早朝、麦畑に日が差すと、畑の中央に並ぶポプラの影がゆっくり動き始めます。高さ20メートルを超える木の列は、朝には畑の西側の畝を覆い、昼には影が木の足元へ縮み、夕方には反対側の畝を再び覆います。土から上がる熱気は陽炎のように揺れ、麦の穂は初夏の風に低く伏しては起き上がります。木陰が通った場所と通らなかった場所で麦の色が微妙に異なることを、その畑で何年も過ごした農家なら誰でも知っています。農家にとって、この木は二つの顔を持つ隣人です。根は地中深く伸び、麦が飲むべき水を一緒に吸い上げますが、幹と葉は熱風を遮り、土の水分を守ります。木が水を奪う泥棒なのか、守ってくれる見張りなのかは、目で見ただけでは答えが出ません。このポプラは日陰をつくるためだけに立っているではありません。幹が太くなれば、マッチ棒、合板、紙の原料として売られる木材でもあり、同じ畑で麦作と木の栽培を同時にしていることになります。根の下で何が起きているのか、葉の一枚一枚がどれだけ水を放出するのかを、数値で測って初めて答えを探せます。

このように、木と作物、ときには家畜までを同じ土地で一緒に育てる農法をアグロフォレストリー（Agroforestry）と呼びます。木の根は作物と水を争う一方、日陰と落葉によって蒸発と土壌流失を減らすことがあります。収量を実蒸発散量で割った水利用効率は、この二つの働きの結果を示す指標です。国連食糧農業機関が広く用いる統計では、農業は世界の淡水取水量の70パーセント以上を占めます。「消費量の80パーセント」と「取水量の70パーセント以上」は同じ指標ではありません。

韓国で農地に木を植える場合の法的な地目と公益型直接支払の資格は、土地の状態、栽培方法、対象事業の要件によって判断されます。木を植えた瞬間に自動的に山林になったり、直接支払の資格を失ったりするわけではありません。導入を検討する農家は、まず管轄地方自治体と農産物品質管理院に当該筆地の要件を確認する必要があります。

根の下の計算

農学者がこの計算を行う方法は大きく二つに分かれます。一つは、土に手を入れて直接測る方法です。時間領域反射法（TDR）と周波数領域反射法（FDR）のプローブを根の近くの土に差し込むと、土粒子の間の水分が電気信号をどれだけ速く通すかから水分量を調べられます。この値を得るためには、研究者が夜明けから長靴を履き、畑のあちこちにプローブを差し込んで回らなければなりません。土の状態によって信号が揺れるため、同じ場所でも数日にわたり繰り返し測ってこそ信頼できる値になります。中性子プローブと自動気象観測所まで加えれば、木の根と作物の根が同じ層の水をどれだけ分けて使うかを時間単位で記録できます。2026年の小麦を基盤とするアグロフォレストリーの系統的文献レビューによると、研究者はこのような現地測定値を、CROPWAT、AquaCrop、APSIMといった作物・土壌水分計算プログラムに入れ、根の層ごとに水がどのように動くかをシミュレーションします。

この程度の手作業では畑全体を見渡せないため、衛星がその仕事を担います。SentinelやLandsatなどの衛星画像から、正規化水分指数（NDWI、植物の葉が反射する光の波長を分析して水分を推定する指数）や地表面温度を取り出し、SEBALやMETRICと呼ばれる蒸発散計算モデルに入れると、畑のどこが乾き、どこが湿っているかを区画ごとに地図化できます。さらに、複数の決定木モデルがそれぞれ答えを出し、多数決で最終答を決める機械学習方式であるランダムフォレスト、サポートベクターマシン、人工ニューラルネットワーク、XGBoostなどのアルゴリズムを重ねれば、土の状態、灌漑予定、木陰の度を同時に学習し、水利用効率を予測するモデルをつくれます。このレビューは、枝を間引く剪定と遮光間隔の調整だけでも、下にある作物の表面から無駄に逃げる水分を減らし、灌漑水が地中へ浸透する比率を高め、システム全体の水効率を明確に向上させられると示しました。農家にとってこの計算が重要なのは明白です。灌漑水をいつ、どれだけ与えるかが一、二日ずれるだけで、その年の収穫は大きく揺れるからです。干ばつが頻繁になる今日では、一滴の水の価値は以前とは違います。

衛星が描くアグロフォレストリー地図

インド西岸のゴア地方には、クーラガルと呼ばれる伝統農法があります。ビンロウヤシの間にコショウ、カカオ、バナナを植え、日陰と湿度を分け合う方法です。クーラガルの畑に入ると、頭上にはヤシの葉でできた屋根があり、その下ではコショウのつるがヤシの幹を巻いて上り、足元にはバナナと香辛料作物が並びます。層ごとに異なる植物が、異なる高さで水と日光を分け合う構造です。衛星画像だけでこの畑と隣の純粋なヤシ農園、自然林を区別するのは容易ではありません。Uthappa研究チームは、Sentinel衛星画像にランダムフォレスト、勾配ブースティング、サポートベクターマシンという三つの機械学習モデルを並行して適用し、この区別に挑みました。一般の植生指数は葉の緑の程度だけを見るため、十分に灌漑されたアグロフォレストリー畑と雨季直後の自然林を混同しやすいのです。水分に反応する指数を別に使う理由はここにあります。結果は明瞭でした。木の葉と作物の葉に含まれる水分を直接反映する水分指数NDWI2が、三つのモデルすべてで畑の区分精度を決める核心変数となりました。勾配ブースティングモデルは精度0.86、偶然の一致を除いたカッパ係数0.83を記録し、三つのモデルの中でも判定が安定していました。

作物と木が混じり合う畑を衛星がこのように読み取れることは、アグロフォレストリー面積を広げようとする政策担当者に有用な道具を与えます。目で畑を一つ一つ探し回らなくても、ある地域でアグロフォレストリーがどれほど広がっているかを毎年地図で確認できるからです。韓国山林庁が毎年行う林業経営実態調査も似た統計を扱いますが、農家への聞き取りと現地調査への依存が大きく、衛星地図で自動更新される体系にはまだ達していないようです。

コーヒーの木陰を精密に計算する

インドネシアのコーヒー畑では、問いが少し異なります。上層で影を落とすシェードツリーをどこに何本植えれば、コーヒーの木を直射日光と水分ストレスから守れるのかという問いです。Ridloらは、グラフ理論から取り入れたRIDSアルゴリズムでこの配置問題を解きました。簡単に言えば、畑を点と点を結ぶ網として扱い、影をつくり過ぎず、畑の隅々まで均等に影が届くように木を植える場所を計算する方法です。

Ridlo研究チームはシェードツリーとセンサーの位置をグラフとして計算しました。コーヒーの木96本とシェードツリー26本を置くシナリオでは、年間の二酸化炭素固定量は520キログラムと算出されました。シェードツリー31本を格子状に置くシナリオでは620キログラムでした。これは長期間の現場で測った炭素量ではなく、モデルによる計算値です。

研究チームは、時空間グラフニューラルネットワークで10日から20日後の相対湿度と二酸化炭素濃度を予測しました。説明力は設定により0.73から0.81でした。この結果はモデル比較から得られた値です。コーヒー農家が実際の灌漑予定に使い、収量や水使用量を改善したことを示す長期現場試験ではありません。

水を越える生態系サービス

生態系サービスとは、森林、湿地、干潟のように、人が手を加えなくても自然が与える恩恵を指します。きれいな水をろ過し、洪水を遅らせ、ハチや鳥を生かして次世代作物の受粉を助けることもすべて含まれます。アグロフォレストリーがもたらす価値は、収量と水効率にとどまりません。木の根は土が雨水で流されるのを防ぎ、落葉と日陰は鳥や昆虫にすみかを与えます。

ブラジル南部の亜熱帯地域を20年間観察したSilva研究チームの衛星時系列分析は、この価値を数字で示しています。2000年ごろ、アグロフォレストリーが占める生息地面積は400ヘクタール余りでした。2020年には、その面積は660ヘクタール近くまで増えました。同じ期間、散在する自然林をつなぐ生息地集約指数も上がりました。田畑の間に断片のように散らばっていた自然林が、アグロフォレストリーの帯に沿って再びつながり始めたことを意味します。

だからといって、アグロフォレストリーが自然林を完全に代替できるわけではありません。Doherty & Häger (2026) は、コスタリカの自然林とコーヒー・牧草地のアグロフォレストリーを、遠隔探査と現地資料で比較しました。地上部炭素貯蔵量と樹木種の多様性は土地類型ごとに異なりました。炭素が多い場所と樹木種多様性が高い場所の空間的一致度は、自然林で25.5パーセントでした。アグロフォレストリーは耕作地の樹木と連結性を増やしますが、自然林と同じ炭素・生物多様性の価値を保証するものではありません。

Jemal (2026) は、エチオピアのアグロフォレストリーにおける遠隔探査と深層学習の研究動向を整理した系統的文献レビューを、F1000Researchのバージョン1として公開しました。畳み込みニューラルネットワーク、U-Net、ビジョントランスフォーマーを一つの現場で直接比較した実験論文ではありません。ガーナでは世界資源研究所が、転移学習により自然林、単一栽培地、アグロフォレストリーを区分する研究を発表しました。分類結果を政策に使うなら、各類型の現地標本と誤分類地図を一緒に公開する必要があります。

インドでは、インドグーズベリーの木陰にダイズを植えるChavan研究チームの実験が、日陰の強さを調整するだけで、劣化した土でもダイズの生理と収量が変わることを示しました。Jinger研究チームは、薬用・芳香植物の木と一緒に植え、土壌水分を保つ技術を加えたシルボアロマティックシステムで、荒廃地の土壌構造を回

復し、二酸化炭素を固定する実験を実証しました。薬用・芳香植物の木が根を張る前の荒廃地は、雨が降れば泥水が溝を掘って流れ、乾季にはほこりだけが舞う裸地であることが多いのです。木を植え、水の流れを整える構造物を併設した後は、同じ土地でも土が流れず、根の間に雨水が浸透する時間が増えました。異なる国、異なる木を扱うこれらの研究は、方向だけは同じです。木と作物と一緒に植えた土地が土を守り、水を節約し、炭素を固定するという方向です。2022年のレビュー論文は、こうした個別事例を土壌健全性という枠組みでまとめ、アグロフォレストリーを化学肥料に頼らず地力を回復させられる数少ない農法の一つと説明しました。

数字が見落とすもの

同じ衛星写真でも、モデルごとに答えが分かれることがあります。ゴアのクーラガル研究では、ランダムフォレストと勾配ブースティングのモデルは、サポートベクターマシンよりアグロフォレストリー面積を広く見積もりました。前の二つのモデルは、木と作物が密に入り混じる畑の複雑な境界を非線形に広く読み取るのに対し、サポートベクターマシンは境界線を保守的に引く傾向があるためです。衛星の水分指数一つだけを見るモデルは、広い地域の干ばつ状態を素早く計算できますが、作物の生育段階ごとに土中水分がどう変わるかは捉えられません。反対に、IoTセンサーとニューラルネットワークを組み合わせたモデルは精密ですが、センサーを設置し管理する費用も伴います。

衛星やドローンで撮った画像は、10メートルから30メートルの一つの画素に、樹冠、作物、裸地の反射光まで混ぜて写します。一つの衛星画像セルの中に木の頂部、その下の日陰、土、作物がすべて入っている様子を考えれば、そこから反射して戻る光は、すでに何色も混ぜた絵の具と変わりません。コンピューターがこの混ぜた色から作物だけの信号を取り出す作業は、すでに混ぜた絵の具から元の色をたどって探すことに似ています。アグロフォレストリーの水収支と土中炭素の変化は、少なくとも10年は見守って流れが見えるものですが、現在の深層学習研究の大半は数年程度の短期資料に依存しており、気候変動への適応力を最後まで検証するのは難しい状況です。発展途上国の遠隔地の農家ほど、IoTセンサーを設置する資金と無線通信網が不足し、賢い水管理技術が、まさにそれを必要とする畑に届かない場合が少なくありません。

木が水を奪うのか守るのかという麦畑の問いは、欧州中期予報センターの計算にも戻ってきました。2026年の研究では、植栽場所を戦略的に選んだシナリオは、蒸発散量を最大60パーセント減らし、地下水の保有量を最大三倍に増やしました。この結果はモデルのシナリオであり、すべての農地に保証される値ではありません。

研究者は次の段階として、物理法則と人工ニューラルネットワークを結ぶ作業を進めています。CROPWATやAPSIMのような物理方程式に基づく既存モデルの制約条件を、物理情報ニューラルネットワーク（PINN）という深層学習構造の中に組み込み、衛星画素が混ざる誤差を抑えながら、微気候と水分を一度に計算しようとする試みです。乾燥地域、亜熱帯、熱帯を横断する公開データセットをつくり、そのデータで学習した軽量のAIモデルを農家の携帯電話に入れ、リアルタイムで灌漑時期を知らせる方向も議論されています。農家の携帯電話に入ったこの軽量モデルは、毎朝、その日の畑に水をどれだけ、いつ与えるかを一行のメッセージで知らせるところまで想定されています。インターネットがたびたび切れる山間の村でも、電話の中で計算が終わるため、サーバーと信号を送受信する時間が要りません。ただし、この構想はまだ実験室の論文にある提案に近く、実際の畑で何年も検証された事例は多くありません。

国連食糧農業機関は、インドの農場林業とアグロフォレストリーの体系が年間木材需要のおよそ93パーセントを供給すると説明します。この数字はすべての木質製品の国内消費を意味するのではなく、年間のtimber demandを指します。小規模農家の樹木生産を広げるには、苗木、技術、販路、土地・収穫の権利を一緒に見る必要があります。

出典・参考文献

1. Chavan, S. B., Rawale, G. B., Pradhan, A., Uthappa, A. R., Kakade, V. D., Morade, A. S., Paul, N., Das, B., Chichaghare, A. R., Changan, S., Khapte, P. S., Basavaraj, P. S., Babar, R., Salunkhe, V. S., Jinger, D., Nangare, D. D., & Reddy, K. S. (2025). Optimizing tree shade gradients in *Emblia officinalis*-based agroforestry systems: Impacts on soybean physio-biochemical traits and yield under degraded soils. *Agroforestry Systems*, 99, Article 21. <https://doi.org/10.1007/s10457-024-01123-2>
2. Doherty, S., & Häger, A. (2026). Forests and agroforestry as overlapping hotspots of woody species diversity and above-ground carbon storage in a Costa Rican landscape: A remote sensing analysis. *Frontiers in Sustainable Food Systems*, 10. <https://doi.org/10.3389/fsufs.2026.1770039>
3. European Centre for Medium-Range Weather Forecasts. (2026, 4月14日). The machine learning method advising on tree planting for water sustainability. <https://www.ecmwf.int/en/about/media-centre/news/2026/machine-learning-tree-planting-water-sustainability> (2026年8月2日閲覧)
4. Fahad, S., Chavan, S. B., Chichaghare, A. R., Uthappa, A. R., Kumar, M., Kakade, V., Pradhan, A., Jinger, D., Rawale, G., Yadav, D. K., Kumar, V., Farooq, T. H., Ali, B., Sawant, A. V., Saud, S., Chen, S., & Pocai, P. (2022). Agroforestry systems for soil health improvement and maintenance. *Sustainability*, 14(22), 14877. <https://doi.org/10.3390/su142214877>
5. Jemal, O. M. (2026). Deep learning based monitoring of forest dynamics and degradation in agroforestry landscapes of Ethiopia: A systematic review. *F1000Research*, 15, 769. <https://doi.org/10.12688/f1000research.180012.1>
6. Jinger, D., Kakade, V. D., Kaushal, R., Bhatnagar, P. R., Ghosh, A., Mahawer, S. K., Dinesh, D., Singh, G., Akula, C., Paramesh, V., Meena, V. S., Roy, T., Islam, S., Kumar, D., Uthappa, A. R., Chavan, S. B., Pradhan, A., Kumar, R., Kaledhonkar, M. J., & Madhu, M. (2025). Nature-based solutions for enhancing CO2

- sequestration and rehabilitating degraded lands through silvo-aromatic system and soil moisture conservation techniques. *Journal of Environmental Management*, 380, Article 124904. <https://doi.org/10.1016/j.jenvman.2025.124904>
7. Ridlo, Z. R., Dafik, Waluyo, J., Yushardi, & Venkatachalam, M. (2025). On RIDS analysis for shade tree placement and its application to STGNN multi-step forecasting on RH and CO2 concentration of coffee agroforestry. *Statistics, Optimization & Information Computing*, 14(4), 1889-1908. <https://doi.org/10.19139/soic-2310-5070-2643>
 8. Silva, B. B., Brum, D., Loregian, A. C., Urruth, L. M., & Tozetti, A. M. (2026). Agroforestry systems as habitat aggregators: A spatiotemporal analysis of the Brazilian subtropical agroforestry using MapBiomass datasets. *Agroforestry Systems*, 100, Article 185. <https://doi.org/10.1007/s10457-026-01557-w>
 9. Singh, A., Atish, Singh, V., Kumari, B., Arya, S., & Kamboj, A. (2026). A systematic review on water use efficiency (WUE) and soil moisture dynamics in wheat-based agroforestry systems. *International Journal of Environment, Agriculture and Biotechnology*, 11(3), 75-86. <https://doi.org/10.22161/ijeab.113.8>
 10. Uthappa, A. R., Das, B., Chavan, S. B., Raizada, A., Desai, S., Paramesha, V., Kumar, P., Jha, P. K., & Vara Prasad, P. V. (2025). Comparison of machine learning models for mapping Arecanut-based agroforestry system in Goa by enhancing precision and efficiency. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-27845-6>
 11. World Resources Institute. (2025). Transfer learning to detect natural, monoculture, and agroforestry tree-based systems in Ghana using remote sensing. <https://files.wri.org/d8/s3fs-public/2025-12/transfer-learning-to-detect-natural-monoculture-and-agroforestry-tree-based-systems-in-ghana-using-remote-sensing.pdf> (2026年8月2日閲覧)
 12. Food and Agriculture Organization of the United Nations. (2025). Agroforestry for wood production: Insights from multifunctional smallholder tree farming systems in Asia and the Pacific. <https://www.fao.org/in-action/forest-landscape-restoration-mechanism/news-and-events/news/news-detail/agroforestry-for-wood-production---insights-from-multifunctional-smallholder-tree-farming-systems-in-asia-and-the-pacific/en> (2026年8月3日閲覧)
 13. Food and Agriculture Organization of the United Nations. (2026). AQUASTAT methodology: Water use. <https://www.fao.org/aquastat/en/overview/methodology/water-use> (2026年8月3日閲覧)

5.2

ICTに基づく木材トレーサビリティ（QR／電子タグ）と木材品質の自動判定

Nakazawa研究チームのシステム構成図には、ハーベスタが測定した原木情報がサーバーへ送られる線が描かれています。伐採機械が直径と長さを測り、StanForD形式で作業データを残す構造です。この記録に物理タグと輸送・製材記録をつなげれば、原木追跡体系を設計できます。ただし、引用資料は、すべての原木にQRコードやRFIDが自動で取り付けられる製材所を示すものではありません。

電子記録は伐採位置と測定値を迅速に共有できます。記録と実際の原木を最後まで結ぶことは別の問題です。タグが外れ、原木が板材に分かれると、つながりが切れることがあります。

QRコードとRFIDは記録を呼び出す鍵に過ぎず、原木の身元を自ら保証するものではありません。サプライチェーン追跡は、伐採記録、物理的な標識、輸送時の引受け、製材後の束管理、現場監査をそろえて初めて機能します。

かつての木材流通は、紙の伝票と手書きの野帳に依存していました。人が記入する数値には誤差が入り、合法原木の間に違法木材が混じっても見分けにくいものでした。韓国山林庁は合法木材貿易促進制度を一年間試験運用しました。本格施行日は2019年10月1日でした。対象の木材と木材製品を輸入する事業者は、通関前に原産国で合法的に伐採されたことを証明しなければなりません。山林庁は国別の標準指針を配布しています。ハーベスタのセンサー、電子タグ、人工知能は、書類審査の隙間を減らす補助手段です。

原木に刻む第二の名前

伐採現場に入ったスマートハーベスタは、木を切り、決められた長さに玉切りする作業と同時にデータを書き込みます。切断ヘッドに付いたセンサーが、原木の直径、長さ、木がどれほど曲がって育ったかを秒単位で測り、衛星測位装置が正確な伐採位置を一緒に記録します。人が目測で行っていた計算を、機械が木を切る短い瞬間に終わらせるわけです。

Nakazawa研究チームはStanForDを基盤として、ハーベスタの原木測定値と品質判定を共有するシステムを開発しました。研究の範囲は森林機械の生産・作業データの接続であり、日本全域の取引と精算体系を扱ったものではありません。

ハーベスタのデータだけでは、木を最後まで追えません。原木にバーコードやRFIDを付け、次の事業者がそれを引き受ける方法は設計できます。伐採機による自動タグ装着、切断面の年輪の三次元指紋、ブロックチェーン照合を一体にした運用体系は、まだ検証されていません。

RFIDは非接触で識別番号を読めますが、タグの価格と耐久性、装着する人手、加工後の束管理が必要です。タグだけで原木の産地と合法性を保証することはできません。

トラックに積んだ木を数える方法

土場に積んだ原木の山や輸送トラックに積んだ丸太の体積を測ることは、長い間、人が手で直接行ってきた作業です。巻尺で原木一本一本の直径を測り、山全体の体積を概算していました。近年、この作業はスマートフォンのカメラやiPad内蔵のLiDARセンサーへ移りつつあります。LiDARは光を発射して戻るまでの時間を測り、物体までの距離を知る装置で、この原理で原木の山の起伏を密な点群として描き出します。

Elias研究チームの2025年の試作品研究、Ucar研究チームのトルコでの試験、Purfürst研究チームの比較研究は、スマートフォン写真とLiDARで原木の山の体積を推定しました。撮影に基づく測定は現場時間を減らす可能性があります。樹種、積み方、撮影角度によって誤差が変わります。

トラック荷台の丸太の間には空間があります。Niță研究チームは、LiDAR点群から積載物の外形と木材体積を推定するアルゴリズムを評価しました。実際の木材体積を誤差なく確定したり、検量所の精算まで自動化したりした研究ではありません。

LiDARの推定値を取引に使うには、基準測量と繰り返し比較して許容誤差を決め、センサー校正と異議申立ての手続きを整える必要があります。アルゴリズムの試験性能だけで、代金精算の法的基準が自動的に決まるわけではありません。

カメラが節を見つける瞬間

製材所に入る原木と板材の価値は、結局は傷が決めます。節がいくつ入っているか、割れ目があるか、色があせているかで、同じ木でも等級が分かります。この判定は長い間、等級判定士の目に委ねられてきました。熟練者でも一日中板材を見続ければ判断が揺らぎ、人ごとに基準が少し違うため、同じ板材でも等級が分かれることがありました。同じ原木を午前に見た判定士と午後に見た判定士が、異なる等級表を書いた例も珍しくありません。Sandvik研究チームが2024年にまとめた文献レビューによると、丸太の材積と等級を判定する技術は、2018年ごろを境に他の機械学習方式から深層学習へ急速に傾きました。

Qiu研究チームは2026年、PADDL-YOLOという木材表面欠陥検出モデルを発表しました。試験資料では、適合率は91.5パーセント、再現率は91.4パーセントでした。mAP@0.5は95.0パーセントでした。計算量は基準モデルより25.6パーセント減りました。軽量化は現場機器への搭載可能性を高めますが、製材所のコンベヤで商用速度のまま長期間運用された証拠ではありません。

同じ目標に向けて別の道を歩む研究も多くあります。He研究チームは完全畳み込みニューラルネットワークで木材内部欠陥の位置を特定し、Hwang研究チームは画像認識で広く使われるResNet-34ニューラルネットワークに転移学習を適用し、節を種類別に分けました。Urbonas研究チームは単板表面の傷を見つけるためにFaster R-CNNを使いました。Longuetaud研究チームは改良したYOLOv5sを、Zhang・Zhao研究チームはYOLOv7を使い、コンベヤベルトを通過する板材の欠陥をリアルタイムで検出しました。Ozkan研究チームはブナ板材2,972枚でMask R-CNN系列のニューラルネットワークを学習させて傷を検出し、精度は90.90パーセントに達しました。Hwang研究チームは少し異なる方法を選び、節表面の質感と局所的な形状情報を取り出して人工ニューラルネットワークに入れ、健全な節、腐った節、抜け節を区別しました。方法はそれぞれ異なっても、目標は一つです。人の目が一日に見られる板材の量を、カメラとニューラルネットワークで何倍にも増やすことです。

等級判定士が一日中見ていた板材は、今ではカメラの前を通り、人は機械が曖昧だと表示した数枚だけを再確認します。画面に出た板材の一部には黄色の枠が付きます。ニューラルネットワークが確信できず、人に渡した板材です。判定士はコンベヤベルト全体ではなく、このように選別された数枚に集中できます。仕事が消えたというより、人が立つ場所がコンベヤベルトの前からモニターの前へ移ったのです。

写真一枚で値段を決められない理由

欠陥を見つけることと、市場価値の等級を付けることは異なります。Triplat研究チームは2026年、スロベニアの原木競売場の写真5,549枚で市場価値等級の分類モデルを比較しました。複数のモデルが全体精度90パーセントを超えましたが、低い価値等級の性能は比較的弱いものでした。高い全体精度だけを見ると、まれな等級の誤分類を見落とすことがあります。

写真分類は撮影された表面と資料の等級ラベルを学びます。内部欠陥、水分、強度のように写真にない要因は直接判断できません。学習資料でまれな等級は、標本不足の影響をより大きく受けます。

市場価値の判定には、写真の外の検査と取引条件も入ることがあります。したがって写真モデルは選別を助ける道具として使い、確信度が低いものとまれな等級は人が再確認するほうが安全です。

競売場で等級を誤れば、お金がすぐ動きます。上級原木を下級に誤分類すれば山主は正価を受け取れず、反対に下級原木が上級として扱われれば、それを買った製材所は後に板材を挽いてから損失に気づきます。自動判定システムに人の最終確認が残る理由はここにあります。

PADDL-YOLOのmAP@0.5とTriplat研究の分類精度は、異なる資料と課題から出た値です。数値を直接比べてはいけません。表面欠陥検出、市場価値分類、内部強度評価は別々に検証する必要があります。

雨が消すものと価値が阻むもの

伐採現場の物理的標識は、泥、雨、衝撃、樹皮の剥離により読みにくくなったり、外れたりすることがあります。RFIDも装着方法と輸送時の衝撃により損傷し得ます。年輪の三次元指紋は、この問題を代替する検証済みの運用体系にはなっていません。標識の耐久性試験、引受け記録、標本監査が一緒に必要です。

二次元カメラの限界も残ります。表面画像は、木の中で進む腐れや内側に隠れた亀裂まで捉えられないため、製材後に予想外の不良が現れることがあります。このすべての機器を備える費用は、小規模な製材所と林家にとって大きな負担です。高性能LiDARスキャナー、X線CT装置、現場用AIコンピューターを同時に導入するには少くない初期投資が必要で、小規模事業所ほどその敷居を越えにくくなります。国立山林科学院のように研究予算を持つ機関はこうした装備を試験導入できますが、一つの山を抱える零細林家や地域の製材所には手が届きにくいものです。技術があっても導入できないところでは、人が手で測り、目で等級を決める以前の方法が続き

ます。ForkuoとBorzが2026年に林業作業全般のAI適用事例を整理したレビューでも、木材追跡と品質判定は伐採機械化に次いで急速に伸びる領域に挙げられました。

X線CTと音響検査は、写真では見えない内部欠陥を確認する補助手段です。

Nocetti研究チームはオーク原木に写真測量と音響調査を並行して適用しました。

ブロックチェーン研究は、複数の事業者が同じ記録を共有し、事後の変更を確認する方法を提案します。偽の初期入力、タグの交換、実際の原木と記録の断絶までなくすることはできません。EUDRの遵守には、地理情報、デューディリジェンス、リスク評価、文書保存が一緒に必要です。StanForDのような作業データ標準やブロックチェーンは、遵守の証拠を助ける手段に過ぎず、規制遵守を保証しません。

出典・参考文献

1. Damaševičius, R., & Maskeliūnas, R. (2025). Blockchain-enabled smart contracts for secure and transparent timber traceability. *Journal of Industrial Information Integration*, 48, Article 100934. <https://doi.org/10.1016/j.jii.2025.100934>
2. Elias, M., Forkuo, G. O., Picchi, G., Nati, C., & Borz, S. A. (2025). Accuracy of a novel smartphone-based log measurement app in the prototyping phase. *Sensors*, 25(18), Article 5847. <https://doi.org/10.3390/s25185847>
3. Forkuo, G. O., Picchio, R., Proto, A. R., & Borz, S. A. (2026). Applications of artificial intelligence in forest operations engineering research: A systematic review. *Current Forestry Reports*, 12, Article 14. <https://doi.org/10.1007/s40725-026-00275-x>
4. He, T., Liu, Y., Xu, C., Zhou, X., Hu, Z., & Fan, J. (2019). A fully convolutional neural network for wood defect location and identification. *IEEE Access*, 7, 123453-123462. <https://doi.org/10.1109/ACCESS.2019.2937461>
5. Hwang, S. W., Lee, T., Kim, H., Chung, H., Choi, J. G., & Yeo, H. (2022). Classification of wood knots using artificial neural networks with texture and local feature-based image descriptors. *Holzforschung*, 76(1), 1-13. <https://doi.org/10.1515/hf-2021-0051>
6. 林野庁. (2025年6月3日). 令和6年度 森林・林業白書. <https://www.rinya.maff.go.jp/j/kikaku/hakusyo/r6hakusyo/index.html>
7. Longuetaud, F., Mothe, F., Kerautret, B., Krähenbühl, A., Hory, L., & Leban, J. M. (2012). Automatic knot detection and measurements from X-ray CT images of wood: A review and validation of an improved algorithm on softwood samples. *Computers and Electronics in Agriculture*, 85, 77-89. <https://doi.org/10.1016/j.compag.2012.03.013>
8. Nakazawa, M., et al. (2021). 原木品質自動判定装置を備えたハーベスタのための原木情報共有システムの開発 [自動原木品質判定装置を備えたハーベスタのための原木情報共有システムの開発]. *Journal of the Japan Forest Engineering Society*, 36(1), 21-26. <https://doi.org/10.18945/jjfes.36.21>
9. Niță, M. D., Cucu-Dumitrescu, C., Candrea, B., Grama, B., Iuga, I., & Borz, S. A. (2025). The performance of a novel automated algorithm in estimating truckload volume based on LiDAR data. *Forests*, 16(8), Article 1281. <https://doi.org/10.3390/f16081281>
10. Nocetti, M., Aminti, G., Vicario, M., & Brunetti, M. (2025). Assessment of oak roundwood quality using photogrammetry and acoustic surveys. *Forests*, 16(3), Article 421. <https://doi.org/10.3390/f16030421>
11. Ozkan, M., Ozcan, C., & Gokmen, M. S. (2025). Deep learning based defect detection and quality classification on lamella pieces used in solid wood panel production. *Operations Research Forum*, 6(4), Article 160. <https://doi.org/10.1007/s43069-025-00534-w>

12. Purfürst, T., De Miguel-Díez, F., Berendt, F., Engler, B., & Cremer, T. (2023). Comparison of wood stack volume determination between manual, photo-optical, iPad-LiDAR and handheld-LiDAR based measurement methods. *iForest - Biogeosciences and Forestry*, 16(4), 243-252.
<https://doi.org/10.3832/ifor4153-016>
13. Qiu, C., Zhu, L., Liang, Z., Wang, Z., & Liu, T. (2026). A multi-scale feature aggregation algorithm for wood defect detection (PADDL-YOLO). *Forest Engineering*, 42(2), 387-401.
<https://doi.org/10.7525/j.issn.1006-8023.2026.02.014>
14. Sandvik, Y. J., Futsæther, C. M., Liland, K. H., & Tomic, O. (2024). A comparative literature review of machine learning and image processing techniques used for scaling and grading of wood logs. *Forests*, 15(7), Article 1243. <https://doi.org/10.3390/f15071243>
15. Triplat, M., Lukančič, Ž., & Kavčič, V. (2026). Evaluation of deep learning models for image-based classification of timber logs by market value. *Forests*, 17(5), Article 518. <https://doi.org/10.3390/f17050518>
16. Ucar, Z., Eker, R., Bilici, E., & Akay, A. E. (2024). Evaluating the use of smartphone applications for log stacks volume measurement in Turkish forestry practices. *Croatian Journal of Forest Engineering*, 45(2), 263-276. <https://doi.org/10.5552/crojfe.2024.2398>
17. Urbonas, A., Raudonis, V., Maskeliūnas, R., & Damaševičius, R. (2019). Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning. *Applied Sciences*, 9(22), Article 4898. <https://doi.org/10.3390/app9224898>
18. 韓国山林庁. (2019年9月18日). 今年10月1日から輸入木材は合法性の立証がなければ通関できない.
https://www.forest.go.kr/kfswb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttId=3136493
(2026年8月3日閲覧)

5.3

循環型バイオエコノミーと森林カーボンクレジット

伐採が終わった斜面には、枝、樹皮、根元が残ります。それを現場に残して土へ戻すか、破碎して燃料や素材原料として運ぶかは、山火事リスク、養分循環、運搬距離、加工需要を一緒に見て決めなければなりません。水分が多ければ輸送重量は増えますが、燃料の発熱量は低くなることがあります。重さだけで値を付けると、品質とエネルギー効率がずれます。

木質副産物からはリグニンとセルロースを取り出して素材をつくれ、規格に合う原木はエンジニアードウッドにできます。すべての枝と根が経済性のある原料になるわけではありません。回収、乾燥、輸送、加工に要するエネルギーと、森林に残すべき有機物の量を差し引いて計算する必要があります。カーボンクレジットも、事業登録、追加性、ベースライン、検証要件を通過して初めて発行されます。

副産物から新素材へ

木は大きく三つの物質から成ります。繊維をつくるセルロース（Cellulose）、その間を満たすヘミセルロース（Hemicellulose）、そして木を硬く立たせるリグニンです。紙やパルプをつくる工場では、リグニンは長く厄介者と思われてきました。パルプを取り出した後の黒い廃液に混ざり、燃やされるか捨てられる副産物に過ぎませんでした。日本の森林総合研究所（FFPRI）と環境省が2025年と2026年に出した資料を見ると、リグニンの化学構造を組み替える改質リグニン（Modified Lignin）技術が、この状況を変えています。熱に強く、折れにくい構造に変えた改質リグニンは、自動車部品、電子製品の外装、生分解性樹脂の原料に使われます。木の繊維をナノメートルの太さまでほぐしたセルロースナノファイバー（Cellulose Nanofiber, CNF）も、石油系プラスチックの代わりに使われる場面が増えています。改質リグニンでつくった部品は、自動車の内装材や電子製品の外装のように、手で触って木かプラスチックかを区別しにくい用途から使われ始めています。

木質素材が石油系素材より温室効果ガスを少なく出すと、あらかじめ決めることはできません。原料の産地、加工の熱源、薬品、製品寿命、再使用、廃棄をライフサイクル評価で比較する必要があります。循環型バイオエコノミーは、再生可能な生物資源を長く使い、再び循環させようとする枠組みです。Wang研究チームは、気

候スマート林業を、AIに基づく森林管理と気候適応・緩和をつなぐ観点として整理しました。

都市に植える森林

木の中の炭素を長期間閉じ込める方法の一つは、その木で建物をつくることです。板を木目が交差するように何層も貼り合わせた直交集成板（Cross-Laminated Timber, CLT）と、柱や梁に使う集成材（Glulam）のようなエンジニアードウッドは、コンクリートや鉄骨の代わりに使っても、かなりの階数を上げられるほど強い材料です。このような厚い木材でつくる中高層建築をマスティンバー建築と呼びます。日本の林野庁と環境省は、都市の鉄筋コンクリート構造物を木造へ変えていこうとする政策を、「森林の国、木の都市」という名で進めています。実際に木造建築の現場へ行くと、コンクリート打設現場とは雰囲気から異なります。生コンクリート車の騒音と粉じんの代わりに、工場であらかじめ切った木材パネルをクレーンで載せ、ボルトで締める作業が続きます。コンクリートを焼き、鉄を溶かす過程で出る二酸化炭素から減らせ、完成した建物は骨組みの中に木が吸収した炭素を数十年から数百年そのまま抱えます。山にあった木が都市の中心へ移り、炭素を閉じ込める第二の森林の役割を果たすわけです。

木造建築の気候効果は、木材が合法的で持続可能な森林から供給され、伐採後に森林炭素が回復し、実際に排出の多い材料を代替するときに生じます。建築需要が増えたからといって、再生林と森林投資が自動的に続くわけではありません。サプライチェーン認証と森林経営の規則が、その条件をつくらなければなりません。

優良木と循環伐採

木の年齢と炭素蓄積は、一文では整理できません。大きな個体木は年を取っても、毎年より多くの炭素を加えられるという世界の資料があります。林分面積当たりの純生産は林齢とともに下がる場合がありますが、樹種、土壌、攪乱、管理履歴によって異なります。すべての森林に通用する「30年から40年でピーク」というものではありません。育種とゲノム選抜は生長や木材形質を選ぶ時間を短縮できますが、生長改善の幅も樹種と試験条件ごとに異なります。

伐採が炭素に有利かどうかは、決まった林齢だけでは判断できません。森林に残る炭素、伐採と輸送の排出、木材製品に貯蔵される期間、コンクリート・鉄鋼の代替効果、再生林の成功の可否を、同じライフサイクル評価に入れる必要があります。古い自然林を保全する選択と、生産林を循環経営する選択は、森林の機能と地域条件によって答えが変わります。早生品種を広く植えるときには、病害虫と遺伝的画一化のリスクも一緒に計算しなければなりません。

炭素を数える目、衛星と人工知能

木を伐って素材に使い、再び植える循環がカーボンニュートラルに役立つかは、数字で検証する必要があります。森林の炭素変化を測り、報告し、第三者が確認する手続きをMRVと呼びます。韓国の森林炭素相殺制度には、新規植林・再植林、森林経営、木材製品の利用、森林バイオマスエネルギー利用のような事業類型があります。事業類型に名前があるからといって、枝の山がすぐに削減実績になるわけではありません。登録された方法論とベースライン、追加性、モニタリング、検証を通過しなければなりません。

吸収量の測定には地上標本と遠隔探査を一緒に使います。GEDIは軌道に沿って波形LiDAR標本を残し、Sentinel-2の二衛星システムは赤道付近でおよそ5日間隔で同じ場所を再び見ます。Landsat一衛星の再訪間隔はおよそ16日です。雲のため実際に使える光学画像の間隔はさらに長くなります。地上標本はモデルを補正するいかりであり、衛星とLiDARはその間の空間を推定する目です。

Geng et al. (2026) 研究チームは、黒竜江省の天然林の長期調査資料、生態モデル、気候シナリオを知識誘導型機械学習で結びました。低排出シナリオでは、2060年の炭素蓄積量は1,379.26テラグラムから1,439.02テラグラムの間と予測されました。この値は観測された未来ではなく、モデルによる見通しです。

Keskes & Niță (2026) は、ルーマニアの現地資料でつくったモデルにフィンランドの多元的国家森林資源調査資料を加えました。対象は炭素地図ではなく、フィンランドの立木材積の予測でした。説明力は0.483から0.718へ上がりました。

Lamahewage研究チームの米国混交林研究は、複数の遠隔探査資料を合わせると地上部バイオマス推定が改善し得ることを示します。研究ごとに対象変数と検証地域が異なるため、一つのモデルの数値を他国の炭素地図へ移してはいけません。

膨らんだ数字と信頼の問題

Swinfield et al. (2026) は、2020年までにクレジットを発行したREDD+事業のうち約45パーセントを、六つの独立評価結果と比較しました。該当する事業は44件でした。全発行量を合わせた過剰発行比率は10.7倍であり、一部の大型事業がこの値を押し上げました。典型的な事業の中央値は4.1倍でした。多くの事業が森林破壊を減らしたという結果と、ベースラインが膨らんでいたという結果が同時に現れました。「事業が失敗した」と「成果より多くのクレジットを発行した」は同じ意味ではありません。

VerraのVM0048は、管轄区域レベルの森林破壊リスク資料でベースラインを配分する枠組みを置いています。方法論の10年は歴史的参照期間であり、6年はベースラ

イン適用期間です。同じ再計算周期を10年から6年へ短縮したものではありません。デジタルMRVは資料収集と監査を助けますが、ベースラインの選択と利益相反まで自動的に解決するものではありません。

国家森林資源調査の標本点の公開座標が保安上移動されている場合、それを10メートルの衛星画素と直ちに一致させると位置誤差が生じます。木質新素材の気候効果も、原料採取、薬品、熱源、寿命、廃棄まで全過程で計算する必要があります。製造過程で消える効果を一つの固定比率に置くことはできません。パリ協定第6.4条の方法論と基準は存在しますが、自主的市場と国家削減実績の間の相互運用と二重計上の防止は、まだ完成していません。

老齢林は大きな炭素貯蔵庫であり、大きな個体木も炭素を加え続けられます。生産林では、収穫した木材の貯蔵と材料代替効果を一緒に見られます。どの選択が気候に有利かは、森林の種類、伐採強度、再生速度、製品寿命、加工排出、代替する材料によって異なります。すべての森林を30年から40年で伐る規則も、すべての伐採を禁じる規則も、この計算に代わるものではありません。

伐採位置と量、木材製品の生産、建築物の材料仕様、新素材工程のライフサイクル資料をつなげれば、森林から製品までの炭素台帳をつくれます。一本の木がどの壁に入ったかまでつながる統合デジタルツインは、運用体系というより設計目標に近いものです。

同じ削減量の二重計上を防ぐには、固有識別番号、登録簿間の調整、所有権規則、取消し記録、独立検証が必要です。ブロックチェーンや物理情報ニューラルネットワークだけで、この問題を構造的に解決することはできません。


出典・参考文献

1. Carbon Market Watch. (2026). Quality assessment of REDD+ carbon credit projects. <https://carbonmarketwatch.org/publications/quality-assessment-of-redd-carbon-credit-projects/> (2026年8月2日閲覧)
2. Carbon Pulse. (2026). Digital MRV could strengthen carbon credit integrity but data quality concerns persist, ICVCM survey says. <https://carbon-pulse.com/491240/> (2026年8月2日閲覧)
3. 国立研究開発法人森林研究・整備機構 森林総合研究所. (2025年9月3日). 2025年度森林総合研究所公開講演会「2050年の森：人口減少社会において森林の果たす役割とは」開催のお知らせ. <https://www.ffpri.go.jp/press/2025/20251015/index.html>
4. Geng, L., Bian, S., Ma, X., Fu, Q., Zhou, Y., & Wang, B. (2026). Prediction of carbon sequestration potential in Heilongjiang Province's natural forests based on the KGML model. Forest Engineering. Online first. <https://slgc.nefu.edu.cn/EN/abstract/abstract2592.shtml>
5. Keskes, M. I., & Niță, M. D. (2026). Digital twins in forest management using scalable deep learning pipeline. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 19, 8519-8547.

- <https://doi.org/10.1109/JSTARS.2026.3666924>
6. Lamahewage, S. H. G., Witharana, C., Riemann, R., Fahey, R., & Worthley, T. (2025). Aboveground biomass estimation using multimodal remote sensing observations and machine learning in mixed temperate forest. *Scientific Reports*, 15, 31120. <https://doi.org/10.1038/s41598-025-15585-6>
 7. 環境省. (2025年2月18日). 地球温暖化対策計画. <https://www.env.go.jp/content/000291618.pdf>
 8. Saha, R., Bagchie, P., Lalremsang, P., & Rai, K. C. (2025). Digital innovation in forest science: Applications of artificial intelligence, remote sensing and smart monitoring systems for ecosystem conservation. *The Bioscan*, 20(3), 907-911. [https://doi.org/10.63001/tbs.2025.v20.i03.S.I\(3\).pp907-911](https://doi.org/10.63001/tbs.2025.v20.i03.S.I(3).pp907-911)
 9. Swinfield, T., Williams, A., Coomes, D., Dales, M., Ferris, P., Guizar-Coutiño, A., Hartup, J., Holland, J., Jaffer, S., Jones, J. P. G., Lam, M. O. K., Keshav, S., Madhavapeddy, A., Toye-Scott, E., West, T. A. P., & Balmford, A. (2026). Learning lessons from over-crediting to ensure additionality in forest carbon credits. *Nature Communications*, 17(1), Article 3944. <https://doi.org/10.1038/s41467-026-71552-3>
 10. Wang, G. G., Lu, D., Gao, T., Zhang, J., Sun, Y., Teng, D., Yu, F., & Zhu, J. (2024). Climate-smart forestry: An AI-enabled sustainable forest management solution for climate change adaptation and mitigation. *Journal of Forestry Research*, 36(1), Article 7. <https://doi.org/10.1007/s11676-024-01802-x>
 11. 韓国山林庁. (2026). 森林炭素相殺制度. https://www.forest.go.kr/newkfsweb/html/HtmlPage.do?pg=/fcm/U_I_FCS_111000.html&mn=KFS_02_10_11_10&orgId=fcm (2026年8月2日閲覧)
 12. 韓国林業振興院. (2026). 森林炭素相殺制度の運営. https://www.kofpi.or.kr/intro/bizGuide_04_02.do (2026年8月2日閲覧)
 13. Stephenson, N. L., Das, A. J., Condit, R., Russo, S. E., Baker, P. J., Beckman, N. G., et al. (2014). Rate of tree carbon accumulation increases continuously with tree size. *Nature*, 507, 90-93. <https://doi.org/10.1038/nature12914>
 14. Verra. (2026). Technical background note: Verra's new REDD methodology. <https://verra.org/methodologies-main/technical-background-note-new-redd-methodology/> (2026年8月3日閲覧)

この本を支援してください

本書が役に立ったと感じられたら、今後の翻訳や公開版の制作、
開かれたAI知識プロジェクトをPayPalでご支援ください。



PayPal

<https://paypal.me/kimkjkj>

QRコードを読み取るか、上のリンクを開いてください。