

人工智慧與數位創新引領的 未來林業與農林複合經營

金京鎮律師

本書由人工智慧整理製作。

彙集並整理了以世界主要語言公開的資料。

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

上方連結是本書製作時參考資料的公開 NotebookLM 收藏。

任何人都可以自由開啟與使用。

目錄

第1章	森林典範的轉變：以資料與人工智慧為基礎的森林大數據與數位孿生	3
1.1	森林資源管理的典範轉移與數位孿生建構	5
1.2	多模態遙測資料融合技術	11
1.3	森林專用大型語言模型（ForestGPT）與智慧決策支援	17
第2章	精準林業：單木分析與生物量及碳的精確量測	24
2.1	以無人機光達與高解析影像為基礎的單木樹種分類	26
2.2	地上生物量（AGB）與森林碳儲量的估算	32
2.3	監測森林土壤動態與土地覆蓋變化	37
第3章	森林災害與生態系健康監測：AI監視與早期預警	45
3.1	機器學習與深度學習的野火風險預測與過火面積偵測	47
3.2	基於影像的病蟲害（含松材線蟲病）與枯死樹木的早期診斷	52
3.3	非法伐木聲學偵測與物聯網／區塊鏈森林保護網路	57
第4章	智慧林業作業與機器人技術：作業安全、自動駕駛與林道網路最佳化	62
4.1	自動擷取林道與集材道，以及配合地形的採伐規劃	64
4.2	遙控採伐機、自主集材機與林業機器人	68
4.3	以電腦視覺與穿戴式感測器為基礎的工人安全監控	72
第5章	永續農林業與木材供應鏈數位轉型	77
5.1	農林業系統中的用水效率（WUE）與生態系服務最佳化	79
5.2	以ICT為本的木材可追溯性（QR／電子標籤）與自動木材品質評估	84
5.3	循環生物經濟與森林碳權	89

第1章

森林典範的轉變：以資料與人工智慧為基礎的森林大數據與數位孿生

1.1

森林資源管理的典範轉移與數位孿生建構

清晨六點，調查員繫緊登山鞋鞋帶，把捲尺、胸高直徑尺和紙本野外紀錄簿放進背包。今天要前往的樣區位於海拔700公尺的稜線坡面，走到地圖上標示的座標需要兩個多小時。韓國山林廳在全國森林設置了5,400個樣區。調查員在這些地點記錄林木蓄積量、森林健康狀況等69個項目，並以五年為週期重返同一樣區。抵達樣區後，調查員用尺逐一環繞每棵樹，讀取刻度，再把胸高直徑（DBH，於胸口高度測得的樹幹直徑）抄進野外紀錄簿。坡度陡峭時，把測高儀對準視線高度、測量角度，再計算樹高，每一步都很費時。即使工作一整天，一名調查員最多也只能完成兩三個樣區。指尖被捲尺磨得乾裂，突如其來的陣雨一過，紀錄簿上的鉛筆字跡便暈開，難以辨認。

這樣收集的數字很精確，卻很快就會過時。在每五年一次的樣區調查之間，即使森林火災燒過稜線，或病蟲害啃食整片林分，這些變化也要等到下一次調查才會出現在官方統計中。長久以來，不論國有林或私有林，國家森林資源調查和二類森林調查都是以這種方式進行。依靠人的雙腳和雙眼進行調查，速度慢、成本高，也無法在時間與空間上形成細密的觀測。問題不只如此。即使要制定精準的採伐計畫，也只能用五年前的數字推測樹木目前的狀況。

從樣區走向網格地圖

整個林業領域都在嘗試跨越這些限制。林業的數位轉型（DX），始於把紙本單據和手繪圖面轉移到行動應用程式與地理資訊系統（GIS）資料。下一階段，累積的資料會與森林管理、木材供需媒合及電子申請系統串接。到了最後階段，資料會從採伐、造林等林業上游流程，流向運銷、加工等下游流程，甚至延伸到與其他產業的接點，並且即時流動，重新塑造決策本身。

這股趨勢在韓國也不陌生。國立山林科學院森林ICT研究中心持續在江原道加里山先導森林經營園區進行試驗，同時部署航空光達、地面光達與背包式光達，收集數位森林資源資訊，並將其用於精準林業。每種設備的資料收集精度和作業速度不同，因此還要進行後處理，判斷哪一種組合最適合實際現場。

過去依照行政區或慣例劃分的小班邊界，也就是為森林管理而細分的區塊，來製作統計，存在長期缺陷。即使位於同一小班，山谷與稜線的微地形也會造成樹高和生長速度差異，但一旦以小班為單位取平均，差異就會被抹平。近年來，為了解決這個問題

，研究人員持續嘗試把森林空間資料重新整理為邊長20公尺的正方形網格。目的在於把航空雷射掃描（ALS）與衛星資料的精度完整保留在每一個網格中。

這項轉變的核心，是決策支援系統（DSS，Decision Support System）和整合多種資料的平台。DSS是一種軟體，它會收集並分析多個資料集，再顯示數字和圖表，供人們做決策時參考。DigiMedFor計畫由拿坡里腓特烈二世大學主導，隸屬歐盟 Horizon Europe計畫，圍繞三大支柱整合技術：森林資源監測與清查建置、木材履歷追蹤與分級，以及森林規劃的決策支援。該計畫開發的Forest Pathway，是一套網路專家系統，使用者輸入樹種、生物氣候帶、立地生產力與經營目標後，系統會提出森林培育路徑。它並不是能自動處理特定地區無人機清查資料與法規的現場模擬器，而更接近協助森林經營者縮小選項範圍的指引工具。

森林數位孿生的架構可分為四層。最底層是由真實森林、土壤和微氣候組成的物理環境。其上是由衛星、無人飛行載具（UAV）、地面物聯網感測器與地面光達收集的資料層。第三層整合這些資料，透過深度學習擷取特徵，並運行在時間與空間上對齊的模擬引擎。最上層則產生精準森林管理、預測分析、碳吸收量驗證，以及自主作業串接等實際用途。

這項技術歷經幾個階段發展。最初只是一個模仿森林的靜態三維模型。接著進入數位影子階段，感測器資料只往單一方向反映，真實狀況會映入虛擬模型，卻不會回傳。現在的目標，是完成真正的數位孿生，讓真實森林與虛擬森林互相交換訊號，並且即時回饋。

光達描繪的一棵樹

光達（LiDAR）是一種發射雷射光，再測量光線撞擊物體後返回所需時間，以此計算距離的裝置。原理並不困難。裝置安裝的位置不同，名稱也不同。裝在飛機上稱為航空雷射掃描（ALS），裝在無人機上稱為無人機雷射掃描（ULS），固定在地面上稱為地面雷射掃描（TLS），背在身上行走時則稱為行動測繪系統（MMS）。

傳統光達通常只發射單一波長，因此雖然能精確定位雷射從哪裡反射，卻不擅長分辨回波來自葉片還是樹枝。近年來，同時發射三種波長的多光譜光達開始處理這個問題。有一項研究讓多個深度學習模型在公開基準資料集ForestSemantic-MS上競爭。Point Transformer V3（PTv3）模型接受六類構成要素的分類測試，包括地面、灌木、樹幹、樹枝、葉片和倒木。它的平均交並比（mIoU，模型預測區域與真實區域重疊程度的平均值）達到69.1%，比其他模型高出21.8個百分點。葉片和樹枝交纏的地方，使用單一波長很難區分樹木部位，但使用三種波長後，情況便有所不同。倒木的辨識準確率提高12.7個百分點，樹枝提高4.5個百分點，樹幹提高2.5個百分點。

另一種方法是單次掃描地面光達，只掃過一次，不必依賴費工的多次掃描。在美國印第安納州Martell Forest的闊葉混合林中，研究人員把單次掃描的點雲資料轉換為二維投影影像，再使用結合卷積與注意力機制的CoAtNet神經網路，估算單棵樹的地上部生物量。儘管樹後遮蔽仍是限制，這個方法的解釋力達到0.73，表現優於隨機森林與Point Transformer等比較模型。

2026年又出現了一種完全不同的點雲處理方式。這項研究把光達資料導入名為Gaussian Splatting的渲染技術，將每一個點轉換為小型半透明橢圓，再逐層堆疊，更逼真地重建樹木表面。研究團隊表示，透過分別處理堅硬樹幹與柔軟擺動葉片的規則，減少了初始化時常見的模糊與晃動。

先在虛擬森林裡試著採伐

虛擬森林不只是一幅漂亮的三維圖像。把樹木位置、高度、樹冠寬度和胸高直徑等真實清查資料搬進去，就能建立模擬環境，事先查看疏伐或皆伐等作業的結果。

DigiMedFor計畫開發的虛擬森林決策支援系統（VFDSS，Virtual Forest Decision Support System），會把虛擬樹木種在幾乎與真實樹木相同的位置，複製整片森林。系統計算隨日期和時間變化的日照量，追蹤樹木在生長過程中獲得多少陽光。使用者可以透過桌上型電腦螢幕俯瞰整片森林，也可以戴上虛擬實境（VR）頭戴式裝置，走進森林，挑選一棵樹，嘗試採伐或栽植。選定疏伐木的瞬間，剩餘樹木的數量與密度、未來生長趨勢，以及採伐木材的收穫量等統計資料，會立刻顯示在螢幕上。實際應用於美國密西西比州的林分與Douglas fir林分後發現，只要有樹木位置和尺寸資料，以及約40個樹種的三維樣本，幾個小時內便能建立當地森林的數位孿生。

Keskes與Niță（2026）把芬蘭多來源國家森林資源調查資料，加入以羅馬尼亞現地資料建立的模型。芬蘭林木蓄積量預測的解釋力從0.483提高到0.718。這項研究並非直接製作碳地圖，而是連結不同國家的資料，改善林分結構預測。模型跨國使用時，必須用當地樣本重新校準。

美國也持續進行類似嘗試。奧勒岡州立大學建立了一套數位孿生，涵蓋Elliott State Forest的77.6平方公里和約280萬棵樹。其中2萬6,000棵樹在遊戲引擎裡得到細緻呈現。使用者可以在虛擬森林內改變時間和天氣，走過地形，事先查看選擇性採伐或皆伐會留下什麼痕跡。密西根州立大學與維吉尼亞理工學院的研究人員，在維吉尼亞州中部一片7.5英畝的Pinus taeda林中調查3,555棵樹，比較數種疏伐情境。不同區塊與情境的移除材積差異介於7.9%至18.2%。在其中一個區塊，依假設的原木價格計算，每英畝相差約70美元。這只是單一試驗地的計算，不能據此斷定其他森林也會獲得相同收益。

現場畫面與機器人的預演

累積在數位孿生中的資料，不會只留在螢幕裡。現場工作人員若使用智慧型手機、平板電腦，或Microsoft HoloLens 2、Apple Vision Pro等混合實境裝置，就能看到疊加在真實樹木上的擴增實境（AR）圖像。Arboreal Forest、ForestScanner、Tree Scanner等應用程式，結合智慧型手機內的光達、RGB-D感測器和名為SLAM的定位技術。SLAM是Simultaneous Localization and Mapping的縮寫，能讓機器一邊繪製周遭地圖，一邊確認自身位置。工作人員在現場行走時，可以立即查看樹木的胸高直徑、高度和座標，並搭配擴增的三維圖像。這些技術的成熟度涵蓋從原型到已上市產品。在北方林中，利用無人機光達和SLAM測得的胸高直徑誤差較小，介於2.0至4.0公分。在樹木密集的亞熱帶都市林中，誤差增加到5.13公分，比例達22.01%。

林業機械的虛擬訓練場也在建置。研究人員在瑞典Vindeln地區，使用Leica BLK360地面光達掃描30個位置，再加入無人機資料，重建高精度數位孿生。他們在虛擬森林中隨機改變視角和太陽角度，自動產生名為SimForest的合成資料集。這等於是在林業機器人或自動駕駛集材機進入真實森林前，先用虛擬資料測試安全功能，確認它能否即時辨識人、樹木和障礙物並停車。

芬蘭自然資源研究所（Luke）正在開發面向碳交易市場的數位孿生。搭載光達的無人機記錄每棵樹的高度、胸高直徑和樹種，將資料與多個衛星資料集疊合後，再轉換成動態三維模型。目標是把碳吸收量分析與VERRA或Gold Standard等驗證制度串接。這個計畫仍處於研究階段，正在尋找商業化途徑。

精度再次變得模糊

儘管成果不斷累積，研究發現仍經常互相衝突。多次掃描地面光達在樹木體積測量精度方面表現出色，但整合從多個位置取得的資料，需要大量工作。相較之下，結合單次掃描與深度學習的方法大幅提高收集速度，卻無法完全消除樹木後方遮蔽所造成的錯誤，例如漏掉樹枝或倒木。多光譜光達也是如此。各部位的辨識準確率明顯提高，但設備昂貴，待處理資料量也大幅增加。預算有限的森林合作社，很難立刻購置這些設備。

在一片試驗林中取得高準確率的模型，移到溫帶混合林或亞熱帶林後，效能可能下降。樹種、樹冠結構、感測器和資料切分方法都不相同。要把模型用於另一片森林，必須使用當地資料重新校準。

在林下植被茂密、上層樹冠緊密交錯的森林裡，無人機或衛星發出的光無法抵達地面，測量樹木下部和樹幹粗度時，誤差會增大。飛行於樹冠下方的自主無人機，依賴VIO、SLAM等結合視覺與慣性資訊的定位技術。光線不足、樹枝搖晃時，無人機可

能失去位置，甚至完全迷航。計算乾旱和高溫壓力的生長模型已經存在。仍然罕見的，是能在數位孿生中持續更新現場感測器與極端氣候資料的作業系統。

無論是Vision Transformer (ViT) 或三維卷積神經網路，模型的效能越高，越可能仍是一個無法說明內部判斷依據的黑箱。從森林政策決策者的角度看，這種不透明會拖慢信任的建立。這類模型通常需要高效能GPU，因此難以直接移植到通訊容易中斷的偏遠地區無人機或現場裝置。

聯合國糧食及農業組織（FAO）在2026年2月發表的文章中，從另一個角度提出了類似憂慮。文章指出，在把人工智慧產生的數字直接用於政策前，必須進行現場驗證；訓練有素的人員和標準程序等制度建置，往往比導入技術本身更花時間。

填補這道缺口的工作也同時進行。研究開始引進SHAP與Grad-CAM等可解釋人工智慧（XAI）方法，反向追查模型做出判斷時依據了哪些資訊，也把樹種特定的開花期、土壤水分等生態知識，以規則形式寫入模型，兼顧準確率與可解釋性。研究人員也在運用剪枝、量化與知識蒸餾等輕量化技術，建立可在無人機和現場裝置上運行的模型，並把散落於不同地區和設備的資料整理成同一套標準格式。

資料來源與參考文獻

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. (February 27, 2026). 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/> (accessed August 2, 2026)
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> (accessed August 2, 2026)
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. (August 1, 2024). 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/> (accessed August 2, 2026)
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> (accessed August 2, 2026)
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. (February 6, 2026). 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> (accessed August 2, 2026)
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. Korea Forest Service. (n.d.). National Forest Inventory.
https://forest.go.kr/kfswb/kfi/kfs/cms/cmsView.do?mn=NKFS_04_05_08&cmsId=FC_000344 (accessed August 2, 2026)
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

多模態遙測資料融合技術

某個夏天，梅雨鋒面已經連續三天籠罩朝鮮半島。坐在國家森林衛星資訊應用中心螢幕前的研究員，打開剛下載的衛星影像後嘆了口氣。畫面有一半像倒了牛奶般，籠罩著朦朧的白色。研究員原本要查看江原道東海岸的松材線蟲病防治區，但雲層遮住整座山，一棵樹也分辨不出來。畫面下方散布著標示防治對象樹木位置的紅點，卻因上方雲層覆蓋，無法確認它們最近的狀況。坐在旁邊的同事放下紙杯，簡短說了一句：「今天的天空還是沒有放晴。」光學衛星的原理和相機相同。它記錄太陽光從地表反射後進入鏡頭的量，因此一旦有雲，就像有人用手掌遮住相機鏡頭。下一顆衛星要再次通過同一片天空，還得再等幾天。在這段時間裡，病木悄悄蔓延，乾燥落葉下的火種也逐漸長大。

多模態遙測資料融合，正是在這種時刻派上用場。只用一隻眼睛從天空觀看森林，必然會出現看不見的區域。衛星頻繁拍攝廣大地區，卻會受雲霧阻擋，視線也無法抵達樹梢下方。無人飛行載具（UAV）或地面雷射掃描儀，可以用公分尺度捕捉一片葉、一根枝條，但受限於電池和人力成本，無法掃遍整個國土。一顆無人機電池最多只能撐40分鐘。於是研究人員改變方法，轉向把擁有不同視野的設備疊放在同一畫面中。這是一套空中、大氣與地面的多層觀測網，把天空中的衛星、空氣中飛行的無人機，以及固定在地面的感測器，連成一個整體。

天空與地面之間的三層視野

三個層級各有不同任務。衛星每三天或五天掃過整個朝鮮半島，無人機挑選一片林分，逐棵查看樹木，地面感測器則固定在同一地點，以秒為單位累積數月甚至數年的變化。

負責巨觀尺度的衛星層，包括歐洲太空總署的Sentinel系列、美國的Landsat系列，以及中國的GF-2。直接測量樹冠高度的ICESat-2與GEDI也屬於這一層。GF-2是一顆高解析度衛星，可把地表細分到0.8公尺網格。Landsat 8與Landsat 9搭載熱紅外波段，連森林火災剛發生後的餘熱也能捕捉。GEDI安裝在國際太空站上，以點狀取樣方式測量世界各地的森林高度。2025年，de Conto、Armston與Dubayah把超過1億3,000萬個點位資料，透過深度學習與合成孔徑雷達（SAR）資料結合。由此產生的全球森林結構地圖，網格大小為25公尺，解釋力達0.82。這是以參數不到40萬個的相對輕量模型取得的成果。

這個層級也出現了新成員。美國國家航空暨太空總署（NASA）與印度太空研究組織（ISRO）共同研製的NISAR衛星，於2025年7月30日發射。它在距地表約747公里的軌道運行，以L波段與S波段雷達測量土壤水分、森林生物量和地面細微位移。這顆衛星收集的L波段資料，自2026年7月20日起開放所有人下載。過去只有國家機構或大型研究所能處理的資料，如今韓國研究生也能從網路免費下載，用於自己的論文。歐洲太空總署的Biomass衛星更進一步，首度搭載波長比傳統雷達更長的P波段。波長越長，越能深入穿透葉片和樹枝，估算樹幹木質部體積。這顆衛星在2025年4月發射，同年12月19日公布第一批開放資料。在歐洲觀測網中，Sentinel-1D於2025年11月進入軌道，與既有的Sentinel-1C配對後，恢復了每六天重訪同一地點的舊有體系。

韓國也在這個層級新增了一顆衛星。由宇宙航空廳、農村振興廳與山林廳共同研製的農林衛星，是次世代中型衛星4號。SpaceX的Falcon 9火箭把它送上太空，發射日期是2026年7月7日。這顆衛星每三天拍攝一次整個朝鮮半島，影像解析度約5公尺，預計用於快速辨識大範圍森林火災和山崩受災區。韓國民間企業Hancom InSpace於2026年3月發射的高光譜衛星Sejong 3，也值得關注。一般相機只把光分成紅、綠、藍三色，這顆6單元（6U）級超小型衛星的大小約等於兩個鞋盒首尾相接，卻能把光分成442個波段記錄。它的重量不到11公斤，因而有潛力分辨的不只是葉片顏色，還包括構成葉片的物質本身所具有的反射特性。

在負責中等尺度的無人機層，光達、高光譜與多光譜感測器，以及超高解析度相機，會同時收集林分與單棵樹的立體結構和色彩指紋。光達是一種發射光線、測量回波時間，藉此算出物體距離的裝置。搭載於無人機的光達低空飛越樹木，連每個樹冠的起伏都能捕捉。微觀尺度層幾乎貼近地面，由地面雷射掃描儀（TLS）、背負式行動測繪設備（Backpack MMS）、測量土壤水分與氣溫的物聯網微氣候感測器，以及拍攝季節變化的PhenoCam塔組成。PhenoCam每天從同一角度拍攝同一棵樹，以日期為單位記錄葉片何時長出、何時轉紅。物聯網感測器埋在地下15公分，將土壤乾燥速度即時傳送到伺服器。這些設備不間斷地測量並記錄樹木胸高直徑、樹幹彎曲程度、林下植被和土壤水分。胸高直徑是計算單棵樹木材體積與碳儲量的第一個輸入值，因此即使只有幾毫米誤差，乘上整片森林後，也會膨脹到難以忽視的程度。

國立山林科學院在2026年1月公開的光達自主飛行無人機，橫跨地面層與無人機層。過去一個人拿著捲尺徒步調查一公頃需要22小時，這架無人機只用2.3小時便完成。和現地直接測量值相比，準確率達96%，連被葉片遮住、肉眼難以測量的胸高直徑也能捕捉。

對齊時間與空間

問題在於，這些資料就像用不同尺規量出來的結果。衛星影像一個網格涵蓋10至30公尺，無人機影像可細到數公分，地面掃描儀甚至能達到數毫米。只要偏移一個像素，地圖上的整棵樹就可能落入旁邊樹木的陰影。要疊合這些資料，首先必須進行地面控制點作業，在山路各處放置反光板與十字標記，再用衛星導航測量座標。接著使用有理函數模型和基於特徵點的幾何校正。每種感測器的解析度和座標系統不同，因此還必須依研究區與設備檢查配準誤差。

對齊時間同樣不容易。在雙衛星系統下，Sentinel-2大約每五天重訪同一地區；單顆Landsat衛星約每16天重訪一次；無人機和地面調查則依研究人員的行程零星進行。在這段時間裡，樹木會長出葉片，含水量也會改變。若把不同時間點的資料直接疊合，同一棵樹也會產生顏色不同的錯覺。這正是為什麼資料要經過Sen2Cor、Fmask等演算法過濾雲與陰影，並選擇同一季節的多幅影像加以合成。像素位置與觀測時間一旦錯位，模型的輸入訊號就會混雜，因此每項研究都必須分別報告配準誤差與時間差。

近期一項針對坦尚尼亞南部高地小農人工林的研究，為這個問題提供了一條線索。Mauya與Jonas指出，在多雲地區以隨機森林和支援向量機（SVM）模型，融合Sentinel-1雷達與Sentinel-2光學資料後，小農栽植樹種的分類準確率高於只使用光學資料。梅雨季控制室裡那片白色畫面的問題，正以這種方式逐步累積答案。

把光、電波與雷射合而為一

三種感測器觀察森林的不同性質。光學感測器利用可見光、近紅外線和短波紅外線波段，讀取葉片葉綠素、水分狀態與植生指數。不過在葉片濃密的區域，反射值會達到飽和，無法再區分更多差異。合成孔徑雷達發射微波，例如Sentinel-1的C波段或ALOS PALSAR的L波段，不受雲層影響，能捕捉從粗枝和樹幹反射的訊號，推測森林內部骨架。即使梅雨季的衛星照片被抹成一片白色，微波仍可直接穿過雲層。光達發射雷射脈衝，以公分尺度直接測量樹高、樹冠體積、垂直層次和地面高低。三隻眼睛同時張開，就能互相補足盲點。

把這三類資料送進人工智慧模型的方法，大致可分為幾種。早期融合在輸入階段串接光學、雷達和光達通道，再送入單一神經網路，結構簡潔；但若輸入維度相對於樣本數過大，過度擬合的風險會提高。後期融合為每種感測器訓練獨立神經網路，再於最終決策階段以投票或加權平均合併結果，能保留各感測器特性，卻容易錯過感測器之間細微的交互作用。混合融合則在中間階段透過交叉注意力結構混合特徵，代價是計算量增加，但能更深入學習各感測器資訊之間的關係。

幾項現地研究顯示了這些方法的實際差異。針對中國山下與黃豐橋地區亞熱帶混合林的MTSCFNet研究，透過三個編碼器與交叉融合模組，連結無人機光達、超高解析度

RGB影像及GF-2衛星影像。相較只用光學或光達資料，樹種分類準確率明顯提高。這項研究使用RIEGL miniVUX-1 UAV光達，每平方公尺記錄87.14個點，並用DJI M300 RTK無人機收集像素大小6.23公分的RGB影像。中國另行建立了疊合GF-2光學衛星與GF-3雷達衛星資料的公開資料集，用於細分森林、灌木地與草地界線模糊交錯的地區。另一項結合高光譜與光達的研究中，只使用光學資料時，整體準確率僅80.39%；以交叉注意力連結兩類資料後，準確率提高9.21個百分點，達到89.60%。在製作全球樹高地圖的研究中，直接光達觀測值的貢獻最高，其次為地形變數，再其次是光學與雷達的間接指標。

在馬來西亞婆羅洲的Deramakot與Tangkulap熱帶雨林，Komatsu Kotaro等研究人員從無人機RGB影像中自動辨識龍腦香科樹木，再把結果與衛星資料和隨機森林模型連結。只用無人機影像辨識龍腦香科樹木時，生產者準確率為0.71，使用者準確率為0.67。沒有現地樣本、只用衛星資料的模型，解釋力為0.43，誤差為每公頃70.60百萬克。加入無人機擷取的變數後，解釋力提高到0.51，誤差降至60.53百萬克。這表示逐一走訪現場並清點樣本的成本可以大幅降低。

在俄羅斯庫頁島的經營林中，也有研究把林分小班資料、Sentinel-2時間序列和地形資料，分別送入隨機森林、XGBoost和TabNet三種模型比較。XGBoost在樹高、胸高斷面積、木材蓄積量與碳儲量方面，誤差都小於另外兩種模型，綜合解釋力達0.68。

婆羅洲的無人機調查與江原道的自主無人機調查，指向相同方向。過去人們拿著開山刀穿過森林，逐棵清點樹木，現在天平正逐漸傾向由天空與地面之間某一層的機器代為清點。接下來的問題，是這個天平能夠信任到什麼程度。

互相矛盾的結果與尚待解決的課題

技術越快增加，各項研究就越可能給出不同答案。在松樹等由單一樹種構成的森林中，光達測得的立體結構，也就是樹冠寬度、高度和樹枝配置，在辨識樹種與生物量時扮演重要角色。尋找葉色尚未明顯改變的早期受害木時，也有研究採取同時觀察光學指標與立體結構的方法。相反地，在物種混雜、灌木交錯的熱帶或亞熱帶混合林，單靠光達並不足夠，還必須觀察光學與高光譜感測器捕捉的葉片和水分訊號。哪一種融合方法表現最好，取決於感測器配準、樣本數和森林形態。

難以直接搬到現場的問題仍然存在。在一個地區取得高準確率的模型，到了樹種和季節不同的森林，仍須重新校準。在樹木濃密的閉鎖林中，衛星或無人機的雷射與光學訊號無法抵達下層和地面，使樹幹直徑與林下植被估算誤差累積。低空飛行於森林下方的無人機，一旦失去衛星導航訊號，也必須重新推算自身位置。光線不足、樹枝在風中搖動時，視覺慣性里程計（VIO）與同步定位與地圖建構（SLAM）的定位誤差會增大。三維神經網路與Vision Transformer所需的記憶體和電力，會依輸入大小與裝置而增加，因此要放進現場設備，還需要模型輕量化和裝置別速度測試。

降低這道門檻的工作也在持續。研究人員透過知識蒸餾、模型量化和專用半導體加速，縮小三模態模型，使其能在無人機和現場裝置運行。Grad-CAM或SHAP等可解釋人工智慧方法，會在畫面上顯示神經網路做出判斷的依據。另一個方向是把樹木的季節變化與土壤水分物理模型放進神經網路作為限制條件，減少偏離生態規律的答案。TreeSatAI、PureForest與ForestSemantic-MS等橫跨多個地區和感測器的公開資料集越廣，為朝鮮半島森林另行調整模型的基礎也會越穩固。

資料來源與參考文獻

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> (accessed August 2, 2026)
2. European Space Agency. (2025a, November 4). Copernicus Sentinel-1D launch highlights. https://www.esa.int/ESA_Multimedia/Videos/2025/11/Copernicus_Sentinel-1D_launch_highlights (accessed August 2, 2026)
3. European Space Agency. (2025b, December 19). Biomass' first open data products now available. Earth Online. <https://earth.esa.int/eogateway/news/biomass-first-open-data-products-now-available> (accessed August 2, 2026)
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. (July 20, 2026). 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> (accessed August 2, 2026)
9. 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>
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. (July 3, 2026). Korea' s first agriculture and forestry satellite launched...precision observations every three days, from crop growth to disasters. <https://www.newspim.com/news/view/20260703000799> (accessed August 2, 2026)
14. Herald Economy. (2026a, January 28). Korea Forest Service opens the era of “autonomous drones” navigating through forests. <https://biz.heraldcorp.com/article/10665629> (accessed August 2, 2026)
15. Herald Economy. (2026b, March 31). Hancom InSpace hyperspectral satellite “Sejong 3” successfully communicates with ground station. <https://biz.heraldcorp.com/article/10706270> (accessed August 2, 2026)

1.3

森林專用大型語言模型（ForestGPT）與智慧決策支援

江原道某個地方森林合作社的辦公室，時間剛過下午三點。晚夏陽光斜斜照進窗內，承辦人的桌上並排攤著《森林資源法施行細則》手冊和邊角磨損的林業便覽。光是今天上午，就有三通電話詢問，松材線蟲病防治區砍下的枯死木，能否暫時堆放在村裡的空地。承辦人翻遍法規索引、搜尋便覽附錄，甚至打開去年的公文檔案，還是找不到確切答案。最後，他闔上便覽，把問題原封不動輸入電腦螢幕上的搜尋框：松材線蟲病枯死木的燻蒸處理，必須在哪裡完成？

越來越多人把這類問題交給人工智慧聊天機器人。大型語言模型（LLM，Large Language Model）從龐大文本中學習，能像人一樣生成句子，如今對大多數問題都能流暢作答。問題出在答案錯誤的時候。ChatGPT或Claude等通用模型，雖然學習了網路上流通的海量文字，卻相對較少讀到森林法規、林業作業規範等狹窄而專業的文件。因此在遇到林業問題時，模型有時會借用從建築或一般工程領域學到的知識，拼湊出聽來合理的答案。模型把不存在的事實說得像真的一樣，這種現象稱為幻覺。它像是一個滿臉自信說謊的人。在森林現場，幻覺不會只是一場小插曲。承辦人若依錯誤的燻蒸指引處理枯死木，松材線蟲可能擴散到鄰近森林；若依錯誤的坡度標準進行採伐，梅雨季可能引發山崩。

2026年，學術期刊Current Forestry Reports刊登一篇系統性文獻回顧，整理人工智慧在整個林業工程領域的擴散。Forkuo等人指出，這股趨勢已從感測器、衛星照片等結構化資料處理，延伸到法規、指引和報告等非結構化文件。處理結構化資料的人工智慧，計算的是森林面積或樹高等能明確化為數字的值；處理非結構化文件的人工智慧，則必須閱讀句子並理解脈絡。後者困難得多。

為填補這道缺口，研究人員開始嘗試森林專用大型語言模型，簡稱ForestGPT。奧地利研究者Ehrlich-Sommer、Eberhard與Holzinger在2025年發表於Electronics的論文中，把這個模型描繪成守在森林專家身邊、但把最終判斷留給人的助手。研究團隊提出四階段開發路徑：從閱讀森林資料的互動工具開始，接著走向檢索增強生成、生長模擬器，以及現場感測器連線。2025年Futa Expo測試的是第一階段多語聊天機器人，以約1MB的篩選資料為訪客提供導覽。檢索增強生成、模擬器和感測器整合，仍位於路線圖上。

韓國也開始出現類似趨勢。國立山林科學院舉辦第一場結合森林大數據與人工智慧的競賽，並頒獎給七個團隊。大學與新創公司開始進行各種實驗，把深度學習、生成式人工智慧，以及能自行判斷和行動的代理技術，接到森林政策與現場服務上。

替人尋找並閱讀法律的助手

ForestGPT等森林專用模型使用的技術，大致分為兩類。一類是微調，重新訓練基礎模型內部的權重；另一類是檢索增強生成（RAG，Retrieval-Augmented Generation），保留模型權重不變，每次提問時，把相關法規和指引文件一併送入。在森林領域，後者更為普遍。法規經常變動，重新訓練整個模型需要大量時間和成本。使用RAG時，問題輸入後，模型會先搜尋相關文件庫，找出可作為依據的條文，再引用條文產生答案。如果找不到依據文件，就回答不知道，而不是自行編造，已經成為防止幻覺的實際方法。

歐盟FOREST4EU計畫開發的對話代理Farm Assistant，是展現這套原理的案例。它連接收集農戶與林農知識的FarmBook資料庫。當使用者詢問能預防森林火災的放牧方式，或減少生物量的方法時，它會附上依據資料編號回答。相反地，若詢問資料庫沒有的內容，例如外部政治人物的發言，它不會編造答案，而會直接說自己沒有相關資訊。在亞美尼亞，American University of Armenia（AUA）的Acopian Center for the Environment，與瑞士聯邦森林、雪與地景研究所（WSL）合作，建立一套對話式聊天機器人，協助政策人員進行氣候變遷影響評估並撰寫國家報告。即使缺乏森林科學背景的公務員，也能在聊天機器人的建議下制定再造林計畫、計算碳匯。

目前還沒有任何技術能徹底消除幻覺。以檢索文件為答案提供依據的RAG，加上不確定性估計、自我一致性檢查與回答安全機制，可以減少錯誤，但效能會因模型和測試資料而異。肥料用量或防治時機等建議一旦出錯，可能毀掉一整年的收成，因此仍須由人類專家做最後確認。採伐許可或燻蒸標準等問題，錯誤可能造成罰款或松材線蟲擴散，更必須明確劃線：模型回答只是參考資料，不是最終核准。

守護危險現場的顧問

辦公室裡在法典前猶豫的午後，至少還算安全。進入山林的伐木工人，面對的是另一種危險。林業是一個事故率很高的產業。誤判樹木倒下方向，或在坡面操作鏈鋸時滑倒的事故，每年一再發生。日本近畿大學的研究團隊嘗試以遊戲和人工智慧顧問代理處理這個問題。他們事先把安全指引和專業知識卡輸入以ChatGPT為基礎的代理。受訓者描述現場狀況後，代理便指出危險因素。在預載知識前，第1輪和第2輪合計出現八次錯誤回答與脈絡偏離；完成處理後，第3輪和第4輪的錯誤回答合計降至兩次。由40個項目構成的安全行為量表分數，也明顯高於訓練前。

現場語音命令試驗揭露了另一種問題。代表防護服的chaps，以及日語「かかり木」，也就是伐倒木卡在另一棵樹上、未完全倒下的狀態，這些林業專用詞在自動語音辨識（ASR，Automatic Speech Recognition）階段，被錯誤轉錄成無關字詞。錯誤字詞直接進入下一階段的自然語言處理（NLP，Natural Language Processing），也就是讓電腦理解人類語言與文字的技術，進一步放大偏離脈絡的回答。這在噪音大、訊號容易中斷的山林十分常見。研究團隊提出的解法，是另建專業詞彙字典，並加入由人再確認一次辨識句子的程序。

視覺監控採取的是另一種方法。Kundu等人在2025年發表於Scientific Reports的研究，把YOLOv8物件偵測模型與LangChain代理串接。系統從無人機與衛星照片中尋找樹樁、伐木機械和未經許可的人員，再把疑似森林破壞區整理成GIS報告。訓練損失下降，最高召回率達0.24，但mAP50仍約為0.07。這個效能還不足以成為能穩定辨識小型樹樁和設備的現場系統，因此仍需人工複核。

要砍多少，又要運到哪裡

智慧決策支援系統（DSS，Decision Support System）是一種同時計算多項條件、比較不同選項的工具。森林經營的一份計畫中，木材生產、工人安全、土壤侵蝕和碳儲存彼此衝突。Eberhard等人在2025年的預印本中提出一套GIS模型，同時考量坡度、土壤侵蝕風險與保留木損傷，比較架空集材機、集材機和絞盤輔助設備。它尚不是經過同儕審查的現場作業系統。

Deng與Feng以遺傳演算法解決運送伐採木卡車的派車與路線問題。這種計算方法模仿生物世代演化、保留較佳性狀的過程，先產生多條候選路線讓它們競爭，再逐步改變存活的路線，找出最佳派車表。更早以前，Görgens等人已建立多目標最佳化規劃演算法，在提高採伐量的同時，抑制作業道路壓實土壤的程度。

也有研究不只以金錢衡量森林經營成果，而是同時使用多種尺度。資料包絡分析（DEA，Data Envelopment Analysis）是一種統計技術，計算投入資源和產生成果的比例，區分效率較高與較低的森林經營單位。Zadmirzaei等人在2026年的回顧論文中，檢視過去30年的林業DEA研究，指出近年的DEA正迅速與人工智慧結合。越來越多研究使用隨機森林選出關鍵輸入因素，以神經網路預測效率分數，再把DEA與NSGA-II結合。NSGA-II是一類遺傳演算法方法，能同時最佳化作業效率、木材收益、環境保育與碳固定等不同目標，產生具體政策情境。

在長期預測方面，國家尺度統計能發揮力量。把坦尚尼亞國家森林資源監測與評估（NAFORMA）資料連接機器學習，預測到2054年的森林面積變化，就是一個例子。2014年森林與疏林面積為4,809萬公頃。若現有開發趨勢維持不變，面積將減至3,299萬公頃；在開發壓力較高的情境中，更會降到2,830萬公頃。相較之下，採用永續管理的情境，下降幅度明顯縮小，提供可用於政策決策的量化依據。

在樹木與作物共同生長的農林複合經營中，計算也開始深入其中。印尼的Ridlo等人利用圖論，判斷遮蔭樹應種在咖啡樹之間的什麼位置，才能維持適當濕度和二氧化碳濃度。他們在網格狀農地圖上套用名為RIDS，也就是Resolving Independent Dominating Sets的圖形演算法，決定遮蔭樹位置，再把智慧感測器收集的濕度與二氧化碳資料送入時空圖神經網路（STGNN，Spatial-Temporal Graph Neural Network），預測未來10至20天的微氣候變化。由96棵咖啡樹和26棵遮蔭樹組成的區塊，估計每年可固定520公斤二氧化碳；以網格種植31棵遮蔭樹的區塊，估計每年可固定620公斤。各項預測誤差指標低於既有比較模型，解釋力介於0.73至0.81，也優於其他方法。

如何辨識充滿自信的錯誤答案

把研究結果並列後，會看到互相衝突的主張。ChatGPT等通用大型語言模型，在廣泛常識與跨語言彈性方面領先，但面對森林法規或作業安全規則等狹窄專業問題時，經常產生幻覺。相反地，RAG模型或ForestGPT把答案固定在依據文件上，法規查詢準確度較高，也更能提出根據；但它們被設計成拒答指定知識庫以外的問題，因此不容易自由對話。要同時取得準確與自由，目前仍不容易。

不同計算方式之間也存在同樣張力。傳統DEA模型以線性方程式清楚顯示效率分數的計算過程，政策人員較容易接受。深度學習預測模型則相反，準確率較高，內部計算卻難以查看，仍是一個黑箱。對必須引用法律依據的政策文件而言，這種不透明是一項障礙。

技術之外的問題也同樣棘手。林業自動化和自主決策代理的導入速度加快，森林政策與法律制度卻尚未釐清，人工智慧自行做出的判斷應由誰負責。代理若提供錯誤安全指引並造成事故，很難判定現場管理者或開發公司誰應負責。瑞典研究者Bergqvist等人在2026年的Hawaii International Conference on System Sciences（HICSS）指出，林業現場不同於資料已標準化的其他產業，記錄方式各異，仍保留大量紙本文件，因此資料整理必須先於自動化。從採伐到加工和流通的資料，分別累積在不同機構中的資料孤島問題，也拖慢整合決策。大型語言模型與時空圖神經網路需要龐大圖形運算資源，在網路容易中斷的偏遠森林裡，無人機和手持裝置仍面臨運算緩慢、儲存空間不足的問題。

未來課題十分明確。決策引擎必須加入SHAP或Grad-CAM等可解釋人工智慧方法，顯示模型為什麼做出某項判斷。也需要符合森林法規與職業安全標準的指引。模型經量化與知識蒸餾縮小後，還要在LoRa無線網路或5G基地台稀少的森林裡，測試各裝置的回應時間與耗電量。跨越國家與地區的森林資料共享制度，以及標準基準，也仍有待完成。

這股趨勢並不限於語言模型。地理空間基礎模型Prithvi由美國國家航空暨太空總署（NASA）與IBM共同建立。壓縮後的模型於2026年5月在澳洲Kanyini衛星和國際太空站（ISS）的IMAGIN-e設備上運行。軌道展示所處理的任務是洪水與雲層偵測。森林高度與採伐痕跡分析只是被提出的地面應用，必須與這次軌道測試結果區分。

森林現場向人工智慧提出的問題會越來越多，但在可以預見的未來，人仍須親自確認每個答案背後有哪一份文件提供依據。模型已能摘要法規、預先指出風險，並計算卡車路線。然而，一個充滿自信的句子仍然可能是錯的。核准欄裡依舊需要人的簽名。

資料來源與參考文獻

1. AUA Acopian Center for the Environment, & WSL. (July 2026). A validated predictive framework: Climate-smart reforestation and resilience mapping in Armenia [Video]. YouTube. <https://www.youtube.com/watch?v=LBrq1KNUUyE> (accessed August 2, 2026)
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. (November 2025). Webinar: Exploring the role of knowledge repositories: Farm Assistant chatbot demo [Video]. YouTube. <https://www.youtube.com/watch?v=slRhC5sfbjA> (accessed August 2, 2026)
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_JOSH-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. Zadmiraeei, 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. Korea Policy Briefing. (July 24, 2026). Forest issues challenged with AI...National Institute of Forest Science holds competition. <https://www.korea.kr/briefing/pressReleaseView.do?newsId=156751645> (accessed August 2, 2026)

第2章

精準林業：單木分析與生物量及碳的精密量測

2.1

以無人機光達與高解析影像為基礎的單木樹種分類

破曉時分，霧尚未完全散去，一架無人機在江原道山腳下的一片韓國松人工林上方低空升起。螺旋槳的噪音在山谷間四散開來，無人機像拖拉機犁田一樣，在天空中以網格狀來回穿梭。光達（LiDAR, Light Detection and Ranging）懸掛在機身下方。它每秒發射數十萬道雷射脈衝，藉由量測光線擊中葉片與枝條後返回所耗的時間來計算距離。無人機每飛過一次，數以千計的韓國松樹冠輪廓便從天空被一點一點地標記下來。當所有的點都彙整完成後，它們所呈現的不只是整片森林，而是每一棵樹的位置與高度，甚至連枝條伸展的形態都清楚可見。

長久以來，林業以林分（stand）為單位管理森林，把樹木當作一整團的群體。它大致估算某一區域內生長了多少棵松樹、平均高度是多少。精準林業把計算的單位降低到單一棵樹。辨識每一棵樹站立的位置稱為單木偵測（individual tree detection, ITD），而只把那棵樹的葉片與枝條所佔據的區域裁切出來則稱為單木樹冠劃分（individual tree crown delineation, ITCD）。過去，人們爬上山，用捲尺與目測直接數樹，或是在航空照片中利用分水嶺分割法尋找亮度下降的邊界，藉此把樹木區分開來。在枝條密不透光地遮蔽天空的密林，以及含有多種樹種的混合林中，這些方法經常失效。把相鄰兩棵樹合併成一棵的分割不足（undersegmentation），以及把一根枝條錯誤地歸給另一棵樹的過度分割（oversegmentation），一再地發生。

為了克服這些限制，一批迅速壯大的研究把無人機雷射掃描所產生的三維點雲，也就是由返回的雷射脈衝所登錄、由數百萬個點組成的資料，與高解析影像及電腦視覺深度學習結合起來。類似的組合在韓國也已進入現場。2025年9月，隨著松材線蟲病再度蔓延，韓國山林廳公布了一套系統，把直升機與無人機的調查、人工智慧與光達結合起來，自動篩選出疑似受感染的松樹。從天空拍攝的點雲與影像，因而執行了過去由人們爬上山、逐棵檢查樹木所做的篩檢工作。不過，這項作業屬於尋找病樹的篩檢階段，其目的與辨識樹種本身的樹種分類並不相同。

繪出樹木輪廓的深度學習

即時物件偵測演算法家族 YOLO (You Only Look Once) 只掃描影像一次，便能同時找出物件的位置與類型。它的運算速度使它在樹冠偵測上同樣好用。在越南同奈省的一片 *Pinus kesiya* 人工林中，由 Nguyen Thanh Tuan 帶領的團隊把無人機光達與高解析航空照片疊合，並比較了 YOLOv8m-Seg、YOLOv11m-Seg、YOLOv12m，以及通用型分割模型 SAM2。最初的 SAM 是以約1,100萬張影像與超過10億個分割遮罩訓練而成，而 SAM2 則是以大規模影片資料加以擴充的模型。

YOLOv11m-Seg 在樹木偵測中記錄到 0.62 的 mAP50 與 0.59 的 F1 分數。結合 YOLOv12m 與 SAM2 的模型，以及 YOLOv8m-Seg，都未達到這些數值。在松樹冠密集重疊的區域，以現場資料訓練的模型表現優於通用型分割模型。當這些邊界與光達點雲疊合並與現場實測比對時，估算樹高的解釋力介於 0.85 到 0.93 之間。樹冠寬度估算的解釋力介於 0.58 到 0.86 之間。由於這些結果來自單一地區的人工林，還必須在其他樹種與天然林中再次驗證。

另一支同時使用衛星影像與航空照片的團隊，提出了 BRO 混合模型，把 YOLOv5 與 Faster R-CNN 家族的一種密度估計神經網路結合起來。它使用一種名為 Battle Royal Optimisation 的搜尋技術來調整多尺度上採樣，設計目的是無論樹木稀疏散布還是密集叢生都能加以計數。該模型記錄到 97.8% 的樹木計數估算準確率，以及 0.0912 的平均絕對誤差 (MAE)。

U-Net 神經網路被廣泛用於描繪樹冠細緻的曲線。它的結構先把影像壓縮到很小的尺寸，再一邊還原到原始尺寸、一邊復原細部輪廓。跳躍連接 (skip connections) 把壓縮前的資訊橫跨整個網路傳遞，避免枝條這類細薄邊界變得模糊。由 Wang Linlong 帶領的團隊在中國安徽省績溪與廣西壯族自治區的亞熱帶混合林中開發了 MTSCFNet。它的輸入包含由搭載 Zenmuse P1 的 DJI M300 RTK 拍攝的無人機 RGB 相機影像。它也接收由 RIEGL miniVUX-1UAV 蒐集的光達點雲，以及中國 GF-2 衛星的影像。光達點的密度為每平方公尺 87.14 點。研究人員把編碼器分成三個分支分別處理資料，再加上一個三支特徵融合模組將它們結合起來。與使用單一感測器的模型相比，樹冠面積分割與樹種分類的重疊準確度指標都有所提升。

也有人嘗試僅用高解析可見光正射影像來分離密集的樹冠。一種名為 FSC-Mask2Former 的方法，是以958張裁切成 512×512 像素的影像訓練而成。每一張影像都搭配了精準描繪出總計7,636棵樹的真值資料。除了影像紋理資訊之外，該方法還套用了在頻域（檢視顏色與亮度的模式重複頻率）擷取的特徵，並結合對比學習（讓相似的樹在特徵空間中靠近、不同的樹彼此遠離的訓練方式）。它顯著減少了在枝葉茂密的混合林中分離樹木邊界的誤差。

Point Transformer V3 (PTv3) 是直接逐點處理三維點雲的神經網路之一。它把自注意力 (self-attention, 一種計算資料中各部分彼此關聯程度、原本用於檢視句子中詞與詞之間關係的方法) 移轉到三維的樹木結構上。在一項研究中, 由發射三個波段的多光譜光達所擷取的點雲, 被輸入到四個模型中: PTv3、KPConv、Superpoint Transformer (SPT) 與隨機森林。森林被劃分為六層: 地面、低矮植被、樹幹、枝條、葉片與木質殘體。在這場比較中, PTv3 達到 69.1% 的重疊準確度 (mIoU), 比其餘三維模型高出 21.8 個百分點。

2026年1月發表的一項相關統合分析 (meta-analysis), 也以數字印證了這股趨勢。Aldaeri 及其同僚蒐集並檢視有關單木偵測的論文後發現, 把單棵樹裁切出來的實例分割 (instance-segmentation) 方法約占整體的 46%, 而以一般 RGB 航空照片作為輸入的研究占比最大, 達到 73%。這意味著, 結合照片與樹冠高度模型 (CHM, 像地圖一樣呈現樹頂高度) 的作法, 比單獨使用光達更為常見。

為混合林中的樹木命名

單棵樹冠一旦被裁切出來, 下一階段便檢視其中的顏色、紋理與三維輪廓, 以判定其為何種樹種。這項工作在混合林中相當困難, 因為上層林冠樹木與下層灌木反射的光線交織在一起, 各棵樹之間的樣本數量差異懸殊, 而稀有樹種往往只存在寥寥幾張照片。

Qin Tianyi 與 Zhao Qingjian 於2025年在 Scientific Reports 發表了一篇關於多分支多標籤樹種分類 (MMTSC) 的研究。它運用 TreeSatAI 這個在歐洲建立、含有15種主要樹種的多感測器基準資料集, 共同分析無人機航空照片與 Sentinel 衛星影像。研究人員比較了六個用於樹種辨識的骨幹神經網路, 包括 DenseNet121、EfficientNet-B0 與 ConvNeXt-Tiny。即使各樹種之間的樣本數量差異極大, 以 DenseNet121 為骨幹的模型仍優於其餘五個。它的 F1 分數約為 72%, 精確率 (precision) 約為 82%。

在馬來西亞婆羅洲島上的 Deramakot 與 Tangkulap 森林管理單位 (FMUs), 研究人員使用 DeepForest (DF Scanner Pro) 與 EfficientNet-B4 神經網路, 在熱帶雨林中把高聳突出的龍腦香科 (Dipterocarpaceae) 樹木與其他樹木區分開來。生產者準確度 (producer's accuracy, 即實際的龍腦香樹被正確辨識出來的比例) 為 0.71。使用者準確度 (user's accuracy, 即被 AI 判定為龍腦香的樹木實際上確為龍腦香的比例) 為 0.67。把由此得出的樹種資訊加入作為衛星式機器學習模型的訓練材料, 可降低地上碳量 (AGC) 估算的誤差。僅使用衛星影像的模型, 其均方根誤差 (RMSE) 為每公頃 70.60 百萬克。當加入經無人機驗證的樹種資訊後, 誤差降至每公頃 60.53 百萬克。

Kotaro Komatsu 及其同僚於2026年1月在 Scientific Reports 發表的一篇論文，在更大範圍內證實了類似的趨勢。在馬來西亞與印尼的395個調查樣區中，當僅以衛星指標估算碳存量與生物多樣性指數時，解釋力停留在 0.43 與 0.46。加入934組無人機影像之後，解釋力上升到 0.51 與 0.48。由無人機擷取的單木資訊，以更精細的解析度填補了衛星照片的粗略尺度。

混合林中含有樣本極少的稀有樹種，因此若把一般的損失函數（loss function，即計算模型錯誤程度的方法）原封不動地套用，預測結果就會偏向個體數量多的樹種。M-MoENet（多模態稀疏專家混合網路，Multimodal Sparse Mixture-of-Experts Network）便是為了矯正這種失衡而開發。它以光學影像、Sentinel-1 衛星雷達（SAR）與數值高程模型（DEM）資料作為輸入，並在編碼器內部置入數個專門處理少數樹種的專家子模型。它還使用信心度調整式閘控（confidence-adjusted gating），在對某項預測的信心較低時，把判斷交給這些專家。根據 Lou 及其同僚所報告的結果，整體準確度（OA）為 79.46%，重疊準確度（mIoU）為 60.08%，Kappa 係數為 0.74。常綠松樹與椴樹這類低樣本樹木在地圖上消失、或以零散且不連續的斑塊形式出現的問題，大幅減少。

一項在賽普勒斯分類九種主要樹種的研究，提出了另一種解決方案。它以 ResNet50 為骨幹，並結合弱監督學習（weakly supervised learning，以模型所指派的暫定標籤補充訓練）。這個接收 RGB、近紅外、地形與土壤資料的模型，記錄到 90% 的整體準確度。該研究並未直接量測其所宣稱的、標註成本減少超過一半的說法。

因研究而異的數字

樹冠分割與樹種分類在個別實驗中會產生相當精確的數字，但結果會隨樹種結構與感測器組合而明顯分歧。在具有清晰圓錐形狀的松樹單一樹種針葉林中，例如 Pinus kesiya 與 Pinus taeda，YOLOv11m-Seg 與以樹冠高度模型為基礎的分割模型都展現出很高的樹高估算準確度，解釋力介於 0.85 到 0.93 之間。在葉片廣泛伸展、枝條交錯纏繞、又夾雜枯枝的亞熱帶與熱帶闊葉混合林中，即使使用同樣的 YOLO 家族或 Mask R-CNN 模型，樹冠寬度估算的解釋力也會降到 0.58 至 0.68 之間。樹木本身的形狀是規則還是不規則，區分了人工智慧的準確度。

基礎模型（foundation models）與領域專用模型的排名也可能翻轉。以大規模影像與影片資料訓練的 SAM2，能分離出許多物件的輪廓，但在枝條相互重疊的森林中，它比以林業資料訓練的 YOLOv11m-Seg 產生了更多的誤偵測。即使是龐大的通用型模型，也無法取代針對特定現場所做的微調。

從天空看不見的東西

無論無人機飛得多麼精準，仍有一些地方從天空看不見。在茂密枝葉遮蔽天空的森林中，森林上方光學相機與光達的訊號無法穿透到中層與下層。因此，矮小的樹木一再被錯誤地併入其上方大樹的樹冠之中。

訓練深度學習模型需要真值資料，也就是為每一棵樹繪製出精準的二維或三維輪廓。然而在枝葉茂密的森林裡，即使是經驗極為豐富的現場專家，對於一棵樹的樹冠在哪裡結束也各執己見。這種判斷上的差異會以標註雜訊（annotation noise）的形式殘留下來，並進入模型的訓練。因此，製作精準的真值資料，與設計演算法一樣耗費人力。

當地區改變時，準確度同樣會下降。即使是在某片森林中得分很高的樹種分類模型，換到另一片地形、日照與樹種組成都不同的森林時，表現也可能變差。下降的幅度會因資料與評估指標而異，無法歸結為單一的範圍。

下一階段的課題

彌合這些落差的努力已經展開。混合微調（hybrid fine-tuning）研究正把零樣本（zero-shot）基礎模型 SAM2，以無人機光達所建立的三維樹冠高度模型資訊層層疊加，重新在林業資料上訓練。其目標是同時達到通用性與精準度。研究也在改良頻率成分分解、對比學習，以及像 M-MoENet 與 FSC-Mask2Former 那樣結合數個專家子模型的閘控演算法，以提升對稀有樹種的自動辨識。

由 Wang Xinbo 及其同僚開發、於2026年5月在 GIScience & Remote Sensing 發表的 Crown-BERT，正是這個方向的近期實例。它加入了動態樹冠遮罩（dynamic crown masking，反映樹冠形狀的差異並只選出有效的樹冠區域），以及樹冠位置編碼（crown positional encoding，把位置資訊嵌入樹冠之內）。接著它再置入一個自監督學習階段，能以未標註的樹冠樣本對模型進行預訓練。這個作法力求即使對於缺乏真值標籤的稀有樹種，也能萃取出有用的特徵。

仍必須持續擴充並共享橫跨多個生態系的三維與二維單木基準資料集，例如 TreeSatAI、PureForest 與 ForInstance。在模型表現因大陸與樹種而差異甚大的當下，擴充資料集本身，與精修演算法同等重要。

資料來源與參考文獻

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). 融合頻域感知與對比學習的無人機影像森林全要素解譯方法：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日查閱)
13. Digital Times. (September 24, 2025). Using advanced technologies including AI and LiDAR...halting the spread of pine wilt disease. <https://www.dt.co.kr/article/12019894> (2026年8月2日查閱)

2.2

地上生物量（AGB）與森林碳儲量的估算

若要直接測定一棵樹的乾重，一個人必須拿起鋸子，鋸穿樹幹基部並把樹放倒，再把枝條、樹幹和葉子分開，逐一秤重，然後放進乾燥窯把水分驅除。這類具破壞性的直接測量，被用來取得建立異速生長方程式所需的參考值。長久以來，整片森林的生物量都是依靠以胸高直徑、樹高與木材密度為基礎的異速生長方程式來估算。這些方程式讓人得以在保護區內不砍樹就算出重量，但當地區與樹種和方程式原本建立的對象不同時，誤差就會擴大。

人們想知道一棵樹的重量是有原因的。要把原木送到市場並定價，就必須知道體積與重量，於是採伐與測量在很長一段時間裡都難以分開。然而，有一種方法可以在不砍樹的情況下估算重量。只要測量樹幹的粗細與高度，再把這些數值代入為該樹種所規定的方程式就足夠了。

在人的胸口高度測得的樹幹直徑，稱為胸高直徑（DBH）。異速生長模型透過輸入胸高直徑，連同樹高、木材密度以及依樹種與地區而定的係數，來估算一棵樹的體積與重量。直徑與高度之間的關係會隨發育階段與環境而變化，並非固定為某個恆定比例。要估算一棵成長中的樹在樹幹與枝條裡累積了多少碳，就必須把這些誤差納入計算。地上生物量（AGB）的精確度會直接影響國家碳帳與碳市場的數字。

以人工方式測量胸高直徑與樹高並非易事。測量員用捲尺量出樹幹周長，再用一種叫測高儀的量角器具仰望樹梢，然後以三角學計算樹高。這個過程每棵樹要花上好幾分鐘。要測量整片森林，需要好幾名測量員工作數天，有時甚至數週。誤差也會隨之而來，因為每個人對於樹幹從哪裡開始、到哪裡結束的判斷各不相同。近年來，森林調查的重心已從捲尺轉向雷射與相機，也從測量員的兩條腿轉向無人機與人造衛星。

地面雷射與無人機如何讀取樹木

地面雷射掃描儀（TLS）繞著一棵樹旋轉，發出無數道光脈衝，並測量它們返回所需的時間，藉此描繪出由數百萬個點組成的三維地圖。這一群點的集合稱為點雲。多重掃描法把掃描儀在數個位置之間移動，連樹木的背面也毫無遺漏地擷取下來，但移動掃描儀並把各次掃描配準成一體要花費相當多時間。若必須調查數百棵樹，這項工作很難在一天內完成。相較之下，單次掃描法只站在一個位置掃描一次，可在數分鐘內完成，但其他樹幹與枝條會遮蔽樹木的背面，在點資料中留下稀疏的空缺。

在美國印第安納州的馬泰爾森林（Martell Forest），研究人員在一片含有37個樹種的溫帶闊葉林中，把單次掃描TLS與CoAtNet結合起來。地面真值是透過把野外實測的胸高直徑代入北美通用異速生長方程式計算而得。在60棵測試樹木中，判定係數為0.73。百分比偏差中位數為0.99%，但絕對百分比誤差中位數為25.06%，平均絕對百分比誤差為29.40%。偏差小絕不能被解讀為每一棵樹的誤差都不到百分之一。

也有一種從天空俯視的方法。把多張無人機照片拼接起來、並校正其變形所製成的地圖，稱為正射影像。因為它是從比衛星影像近得多的距離拍攝，所以每一根枝條都清晰可辨。在馬來西亞沙巴的德拉馬科特（Deramakot）與丹古拉（Tangkulap）熱帶雨林中，研究人員把無人機拍攝的RGB正射影像與名為EfficientNet-B4的深度學習模型結合，用來辨識龍腦香科樹木的樹冠，也就是由枝條與葉子形成、狀如傘蓋的樹梢，然後套用熱帶森林的異速生長方程式來估算碳。一個僅以衛星影像、且不使用任何野外樣本所執行的基準模型，其解釋力停留在0.43。而加入無人機所拍攝的樹冠結構資訊的模型，把解釋力提升到0.51，並把誤差從每公頃70.6噸降到約60.5噸。

在歐洲山毛櫸（*Fagus sylvatica*）森林中也做過類似的嘗試。研究人員以無人機雷射掃描測量三維樹冠體積，並把這個數值加入原本僅以胸高直徑為基礎的計算中，顯著降低了生物量估算的誤差。由於是在原本只考慮樹幹直徑的方程式中加入了樹冠體積資訊，這樣的改善看來也是自然的結果。

不過，異速生長方程式本身也有弱點。為了在全北美或所有熱帶森林通用而建立的通用型公式，無法完整反映特定地區土壤的肥沃程度、當地的氣候，或即使同一樹種也會因生長地點而異的樹形。即使在同一種雲杉之內，長在多雨山坡上的樹和長在乾燥山脊上的樹，可能直徑相同，內部填實的密實程度卻不同，也就是木材密度不同。這會產生系統性偏差，也就是一種隨地區持續朝同一方向偏移的誤差。所幸，一旦精確測得的當地異速生長資料累積起來，受監督式的深度學習模型便可重新訓練以校正這種偏差。這種做法比起從一開始就尋找一個完美的公式，更接近於不斷蒐集資料並修正模型。

把國家森林資源調查與衛星資料連結起來

無論用雷射與無人機精確測量單棵樹的技術再怎麼進步，都無法用這種方式調查一個國家的每一棵樹。國家的森林越大，樹木的數量就越容易超過數億棵。無人機一天只能檢視有限的範圍，但人造衛星卻能一舉跨越這個限制。要把逐棵測得的數值、或幾個樣區的資料擴展成全國性的地圖，需要另一種做法：以人工智慧，把地面實測的國家森林資源調查（NFI）資料與能一眼調查廣大範圍的人造衛星遙測資料連結起來。

在美國康乃狄克州的溫帶混合林中，研究人員把美國林務署（U.S. Forest Service）國家森林資源調查中142個樣區的資料，與Sentinel-1雷達訊號、由Sentinel-2與Landsat衛星依葉片綠色反射率所推導的NDVI等植生指數，以及太空載雷射高度計

GEDI所測得的樹高資料相互疊合，製作出10公尺解析度的生物量地圖。在測試了數種機器學習方法後，當同時輸入GEDI測得的樹高與Sentinel植生指數時，準確度最高。森林以外的區域被賦予生物量值為零並加以過濾，以降低樣本中的雜訊。

在俄羅斯庫頁島（Sakhalin Island）的經營林中，研究人員把Sentinel-2衛星影像的時間序列變化與地形資料，和NFI的林分小班調查資料結合起來，然後比較隨機森林（random forest）、XGBoost與TabNet。XGBoost表現最佳。這套演算法把一連串決策樹串接起來，每一棵樹都透過如枝條般的問題逐步收斂出答案，而後續的每一棵樹又減少前一棵所遺漏的誤差。平均絕對百分比誤差，即MAPE，在估算樹高時為0.18，在估算碳儲量時為0.37，而整體解釋力為0.68。

一項針對中國黑龍江省天然林的研究，涵蓋了長得多的時間軸。它匯集了從1976年到2015年共九輪NFI固定樣區的資料。研究人員疊合了過去與未來的氣候及二氧化碳濃度資料，並建立了一個名為知識引導機器學習（KGML）的架構。它是一個兩階段的結構。首先，把以方程式表達樹木生態生長過程的森林碳吸存模型加以精修，使其能反映二氧化碳施肥效應。這個模型所計算出的數值，接著作為先驗資訊傳遞給XGBoost。加入生態知識後，碳密度預測的解釋力從0.85提高到0.90以上。在積極抑制碳排放的低排放情境下，黑龍江天然林的碳儲量預估在2060年將介於1,379.26至1,439.02特克（teragram）之間。由於事先嵌入了生態規則，即使模型預測的未來超出其訓練資料的範圍，數值也不會跳升到不合理的程度。一般的黑箱機器學習模型在它從未見過的極端氣候條件下，很容易產生毫無意義的數值，因為一旦離開訓練資料中所存在的模式，它就不知道該根據什麼來給出答案。

另一項研究則在以羅馬尼亞野外資料建立的模型中，加入了芬蘭國家森林資源調查的樣本與Sentinel-2時間序列。芬蘭立木蓄積量預測的解釋力從0.483升至0.718。它的對象並非碳地圖，而是樹高、斷面積、材積等林分屬性。一項坦尚尼亞的研究以2014年的森林與疏林面積為起點，計算了直到2054年的三種情境：現有趨勢延續、永續經營，以及開發壓力加大。

這些從康乃狄克州、途經庫頁島與黑龍江、一直延伸到芬蘭的研究，呈現出一幅共同的圖像。地面樣區資料越豐富、越多樣，疊合的衛星感測器資料類型越多，廣域地圖就越準確。

為什麼數字會出現分歧

研究數字必須謹慎地並排比較。單棵樹的重量、林分材積，以及每公頃的生物量，是不同的目標變數，而 R^2 會隨資料範圍與驗證方法而變化。NFI樣區座標的誤差取決於林冠、地形、接收器與校正方法。有些公開資料為了保護私有財產，會刻意模糊座標。一個衛星像素裡同時包含大樹、幼樹與裸地，使得近距離測得的單棵樹數值與像素平均值之間出現落差。

光學衛星與雷達衛星之間的排名也會反轉。光學與短波長雷達訊號在高生物量森林中可能很快就飽和。飽和點會隨森林結構、水分、極化、入射角與迴歸模型而變化，因此很難固定出單一門檻。長波長雷達與光達（LiDAR）在讀取密林結構方面相對占有優勢。由於GEDI是波形光達，它並不與雷達後向散射歸類在相同的飽和標準之下。感測器之間的差異，在涉及金錢的計算裡，例如碳權（carbon credit），會帶來敏感的成果。

遺留下來的問題，以及下一個階段

技術上的限制依然存在。NFI與衛星觀測的週期不同，因此會在不同的日子測量同一片森林。若干國家的公開NFI資料為了保護私有財產，可能會模糊實際座標，在與高解析度像素比對時便產生誤差。以異速生長方程式建立的生物量參考值，也含有源自方程式選擇的不確定性。遙測得到的AGB地圖絕不能被當成森林中碳的總量。國家溫室氣體清冊可能會把地下生物量、枯立木、枯枝落葉與土壤，當作各自獨立的碳庫來計算。

未來的工作必須在廣大地區檢驗知識引導機器學習，也就是把生長方程式與碳循環模型置入神經網路之中的做法。GEDI與ICESat-2等各自獨立的太空載光達任務所得的樹高資料，也可以與NFI資料一併加以比較。唯有當人工智慧把估計值與不確定性並排報告出來，它的輸出才能接近一份適合用於國家溫室氣體清冊的碳地圖。

資料來源與參考文獻

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

監測森林土壤動態與土地覆蓋變化

那是在連續三天大雨之後。在江原道某處的採伐跡地，一片被剝去樹木的坡地，赤裸裸地承受著雨水的直接沖刷。從切割坡面沖刷下來的土壤呈紅色，那是風化作用形成的花崗岩腐土所特有的顏色。一位穿著膠靴的研究人員蹲在泥水前，抓起一把泥土。單憑泥土從指縫間滑落的觸感，研究人員就能大致推估這片土壤流失了多少有機質，下一場雨還會再沖走多少。幾步之外，在樹根仍然抓住土壤的坡面上，泥土顏色深得多，也結實得多。即使是同一座山，土壤的狀態也會因為有沒有樹木而有這麼大的差別。但觸覺無法描述整片坡地，更遑論採伐跡地之外的整座山。一把泥土永遠是不夠的。正因如此，能同時讀取地底與整座山之外的感測器與衛星，以及把兩者連接起來的人工智慧，已經移到了森林土壤觀測的中心。

由地下感測器與空中之眼一同讀取的水分

土壤水分與有機質、溫度與相對濕度，以及二氧化碳濃度，決定了樹木生長得好不好、用水效率有多高，以及能保留多少碳。過去唯一的方法，就是在既定日期進入現場採集樣本，或安裝單一儀器，只看它讀出的數字。以這種方式讀取一座廣闊的山，很容易漏掉某棵樹樹蔭下或某條溪谷內的狀況。如今做法正在改變：在地裡埋入多個物聯網（IoT）感測器，用低功耗廣域網路 LoRa 連結它們的訊號，再與無人機和衛星拍攝的影像一同讀取結果。

有一項研究把無人機取得的多光譜、熱紅外線與一般照片，連同深度學習一起分析，用以推估苜蓿根部周圍的土壤水分。這項由 Yin 等人（2024）發表於《European Journal of Agronomy》的研究顯示，結合多種感測器的模型，其誤差明顯小於單一感測器的模型。換句話說，僅憑可見顏色無法得知的根部周圍水分狀況，在疊加多個波長之後才浮現出來。

一篇針對以小麥為基礎的農林複合經營農場所作的綜述，也得出類似結論。這篇由 Singh 等人（2026）發表於《International Journal of Environment, Agriculture and Biotechnology》（IJEAB）的文章說明，把控制樹蔭寬度的樹冠管理，與地下水分感測器，以及衛星推導的地表水指數（LSWI）與溫度植被乾旱指數（TVDI）結合起來，就能事先預警樹木與小麥何時會開始爭奪水分。在這場競爭開始之前就偵測到它，便為節省用水留出了餘地。

插入樹幹、透過電氣特性測量水分的多探針感測器，連同一顆電池就能運作數月的 LoRa 閘道器，都已安裝於現場。已經有一套流程，把在山中深處測得的數值不經人手，直接送往伺服器與邊緣裝置，也就是設在現場附近的小型電腦。過去需要研究人員每月爬一次山、親手抄錄儀器讀數的工作，如今只要打開手機螢幕就能查看。不過這套流程並不完美。當電池耗盡或通訊中斷時，那整段區間的數字就會留成空白。

一篇綜述蒐集了這些技術並整理出其發展方向。Wang 等人（2026）在《Frontiers in Plant Science》上，綜述了把森林資源觀測所用的光達（LiDAR）、衛星影像、物聯網感測器與無人機資料納入單一模型的多模態資料融合研究。他們指出，資料種類愈多，準確度愈高，但由於各資料集的時間與空間解析度不同，前處理相當困難。範圍更廣、涵蓋森林健康監測的綜述也重複相同結論。Amoah-Nuamah 等人（2025）與 Saha 等人（2025）分別綜述以人工智慧為基礎的森林健康監測，以及遙感與智慧監測系統，都觀察到：把感測器、衛星與人工智慧疊加使用而非各自分開時，誤報與漏報都會減少。

把土壤品質化為分數的地圖

有效水容量、有機質含量、酸鹼度與養分，都是森林健康的量度。這些數字最終決定了樹根能延伸多遠，又能撐過多久的乾旱。問題在於，這些數字無法憑一鏟挖出的一把土得知，必須把樣本送到實驗室、經過好幾天才浮現出來。把這些數字繪成一張地圖的工作，近年來迅速增加。

在一項針對天然松林的研究中，Poudel 等人（2025）把模糊層級分析法（Fuzzy-AHP）與隨機森林結合，計算出土壤品質指數。這項發表於《Scientific Reports》的研究報告指出，納入土壤結構、有機質與保水能力的機器學習模型，能比傳統統計模型更精細地繪出土壤狀況的局部差異。

以衛星直接辨識土壤有機碳（SOC）本身的嘗試也在持續。Li 等人（2025）把 Sentinel-2 衛星的光譜影像與地形變數結合，推估中國博斯騰湖綠洲的土壤有機碳濃度。Parvizi 與 Fatehi（2025）繪製了橫跨多種土地利用類型的土壤有機碳分布圖，並比較了廣義線性模型、Cubist、支援向量機與隨機森林。隨機森林的解釋力為 0.64，明顯優於廣義線性模型的 0.39 與支援向量機的 0.41。沒有任何一種演算法永遠獲勝，因此當土壤與地形改變時，該把哪個模型排在最前面的選擇，必須重新斟酌。

由此得出的土壤品質指數與土壤有機碳分布圖，並不會止於單一數字。地圖一旦上色，就能一眼看出，在同一座山內，土壤狀況會因坡向、以及某處是匯水的溪谷還是山脊，而有多麼鮮明的差異。對於要決定在哪裡種樹、又要讓哪塊地不受擾動的林業人員而言，這張地圖成了在實地勘查之前就指引方向的參考資料。

計算遮蔭樹配置的圖神經網路

在農林複合經營中，上層樹木投下的一塊遮蔭落在什麼位置，會改變下層作物所感受到的陽光、濕度、二氧化碳濃度與土壤水分。遮蔭若太濃密，作物就長得細弱；若太稀疏，葉子就會在烈日下灼傷。因此，遮蔭樹該種在哪裡、該種幾棵，是一個計算問題，而非憑直覺。

Ridlo 等人（2025）以圖論中的獨立支配集演算法計算遮蔭樹與感測器的配置，並以時空圖神經網路（STGNN）預測相對濕度與二氧化碳濃度。在一個有 96 棵咖啡樹與 26 棵遮蔭樹的情境中，年二氧化碳固存量算得為 520 公斤。而在網格狀排列 31 棵遮蔭樹的情境中，數值為 620 公斤。這些是模型的計算結果，並非在長期實地研究中直接測得的碳固存量。

其預測表現也值得關注。該模型預測了未來 10 天、15 天與 20 天的微氣候。與歷史平均、ARIMA、支援向量迴歸（SVR）、圖卷積網路（GCN）與門控循環單元（GRU）等既有方法相比，其誤差明顯較小，決定係數介於 0.7350 至 0.8109 之間。一個新時代已經開始：過去人們每天都要出門去測量的相對濕度與二氧化碳濃度，如今可以提前十天算出，並用來選擇該把遮蔭樹種在哪裡。

由衛星拍攝、長達三十多年的影片

氣候變遷、非法採伐、農地擴張與野火，持續改變著森林的面貌。要捕捉這種變化，需要的不是一張照片，而是長達數十年的影片。由 Landsat、Sentinel、MODIS 等衛星層層累積下來的時間序列影像，正扮演著那卷影片的角色。在韓國，同一系列的衛星時間序列分析，也用於檢視江原道野火受災地區，以及因松材線蟲病而遭採伐的地點的復育情況。採伐或火災之後，隨即出現大面積的裸土。幾年之後，先是草類與灌木進駐，然後樹木才紮下根。這一連串過程，完整地呈現在衛星影像不斷變化的色彩之中。

Obata 及其同事於 2021 年研究了美國喬治亞州的森林。他們在 Google Earth Engine 上，把從 1984 年到 2016 年、長達 33 年的 Landsat 影像疊加起來。他們透過纓帽轉換萃取出亮度、綠度與濕度指數，套用調和迴歸分析，再以隨機森林把結果與國家森林資源調查的樣區連接起來。與只使用三年影像的模型相比，它更準確地辨識出最近一次擾動的日期，並降低了立木蓄積量的誤差。同一項研究於 2026 年又在一份日本期刊上再度被介紹，但引用時以原始出版年份與 DOI 為準。

擾動成因的分類已擴展到全球尺度。Wang 等人（2026）運用 Landsat 時間序列與深度學習，建立了一套量化 2000 年至 2020 年全球森林損失的資料集，把損失劃分為野火、伐採與採伐、遊耕、病害與風害，並發表於《Earth System Science Data》。這意味著，如今的地圖不僅能區分森林在何處消失，還能區分它為何消失。

另一項研究比較了辨別土地利用與土地覆蓋的人工智慧模型。Çalışkan (2026) 以相同資料訓練支援向量機、隨機森林與決策樹，並比較它們的表現。沒有任何單一方法在每個地區都獲勝。在地形複雜、土地利用被切割成小地塊的地方，隨機森林方法表現較佳；而在邊界清晰的大片農業地區，結構較為簡單的決策樹方法也相去不遠。

標籤稀少的地區需要另一種策略。哥倫比亞的熱帶乾燥林會隨季節落葉，也經常發生火災，導致其光譜特性大幅波動。González-Vélez 等人 (2026) 提出的 Semi-FCMNet，是一種半監督式學習架構，會同時以地面真值標籤，以及無標籤的 Sentinel-1 雷達與 Sentinel-2 光學時間序列一起訓練。即使在標籤受限的條件下，它仍維持了 90% 以上的準確度。人力時間的節省並未另行測量。

也有研究專門辨識森林消失之後進駐的是什麼。Pišl 等人 (2026) 使用一種會學習位置資訊的深度學習模型，來區分清除熱帶森林之後的土地變成了牧場、農地還是道路。該研究顯示，即使森林損失相同，若後續的土地利用不同，政策因應之道也必須有所不同。

也有森林擴張的故事。Silva 等人 (2026) 研究了巴西亞熱帶的一處農林複合經營區。研究人員以巴西的衛星土地覆蓋製圖計畫 MapBiomass 的資料，在 2000 年、2010 年與 2020 年三個時間點追蹤變化。面積從 405.80 公頃，經 500.60 公頃，擴張到 659.81 公頃。棲地聚合指數在同一期間上升。這種擴張看來是因為農林複合經營區充當生態廊道，連接了破碎化的天然林所致。該研究指出，這類廊道有助於保護生物多樣性，並防止土壤被沖刷流失。

也有研究展望未來。Zella (2026) 運用坦尚尼亞的國家森林資源監測與評估 (NAFORMA) 資料，在三種情境下計算了 2014 年至 2054 年的森林面積。若現有趨勢延續，森林與林地將從 4,809 萬公頃減少到 3,299 萬公頃。在開發壓力沉重的情境下，最低會降至 2,830 萬公頃。在永續管理情境下，預估將維持 4,385 萬公頃。

也有即時偵測採伐的嘗試。Kundu 等人 (2025) 在《Scientific Reports》上發表了一套系統，把 YOLO 物件偵測模型，與一個以 LangChain 為基礎、自主執行一連串判斷的代理人結合起來。它能在近乎即時的情況下，偵測衛星與無人機影像中疑似採伐的變化並發出警報。人工智慧會先選出疑似採伐的區域，但誤報並不會完全消失，因此最終判斷仍須由人來做。

這類時間序列監測，如今在實驗室之外也具有價值。歐盟《無毀林產品法規》(EUDR) 要求，將附件一所列的咖啡、可可與木材相關產品投放市場或出口的業者，提供產地的地理定位資訊。四公頃以下的地塊可用一個經緯度點表示；更大的地塊則需要多邊形邊界。截止日期為 2020 年 12 月 31 日。大型業者與部分中小企業自 2026 年 12 月 30 日起適用該規則。自然人與部分微型企業的適用日期為 2027 年 6

月 30 日。由於日期會依商品代碼與業者身分而不同，各家公司必須分別確認自己的產品與角色。

相互矛盾的數字與尚待完成的工作

即使累積了這麼多技術，數字仍然對不上。地面感測器測的是一個狹小點位上的數值，而一個 Sentinel-2 或 Landsat 像素看到的是廣闊區域的平均值。要疊加兩組在礫石、遮蔭、林冠與土壤水分上都有差異的資料集，就需要進行把它們對齊到同一日期與同一空間尺度的驗證。

已有報告指出，這類不吻合在現場造成了問題。僅憑衛星指數判定為安全的區域，實地走訪時卻已相當乾燥；或衛星發出異常訊號，到現場一看卻證實只是一次普通的季節性變化。除非現場手冊事先規定，當兩者不一致時該先相信哪個訊號，否則管理人員會做出不同判斷，混亂隨之而來。

光學衛星與雷達（SAR）衛星之間，還存在另一種矛盾。在雲霧頻繁的熱帶與亞熱帶雨林中，光學影像常常出現空缺，容易錯過葉子萌發與凋落的週期。在雨季持續數月的地區，可能過了半年都拍不出一張可用的光學影像。雷達能穿透雲層成像，但雨後不久濕潤土壤的粗糙度會擾動訊號，在其實沒有變化之處誤測出變化。

在林冠密閉的森林裡，從上方衛星或無人機發出的訊號會從葉面反彈回來，別無選擇，只能透過間接指標去推測下方的土壤狀況。當在某一氣候帶訓練出來的變化偵測模型，被搬到另一個生態系時，它可能把落葉季節誤讀為野火或採伐。準確度下降的幅度會因資料與指標而異，無法歸結為單一區間。偏遠地區的感測器經常喪失電力與通訊，因此需要長期的實地測試。

未來的一項課題，是物理資訊神經網路（PINN），它把神經網路，與以物理定律表達地下水運動的方程式結合起來。只以資料訓練的模型，一旦遇上訓練資料中沒有的極端乾旱或破紀錄降雨，就可能產生荒謬的數值。若把水如何滲入地面、又如何蒸發的物理定律嵌入神經網路，即使在這種陌生的條件下，模型也更有可能是維持合理的數值。把時空圖神經網路與 Transformer 精簡為可直接嵌入無人機與現場裝置的輕量形式，是另一項課題。多篇論文反覆強調，有必要跨越不同生態系，持續擴充時間序列的土壤與土地覆蓋基準資料。唯有當一顆電池就能運作數月的低功耗 AI 晶片遍布山林的每個角落，眼下感測器與衛星之間的落差，才會開始縮小。

資料來源與參考文獻

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., & Saflı, 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> (於 2026 年 8 月 2 日查閱)

第3章

森林災害與生態系健康監測：AI監視與早期預警

3.1

機器學習與深度學習的野火風險預測與過火面積偵測

晚春的一個午後，乾燥天氣特報已進入第三天，覆蓋整面牆的野火狀況室螢幕上，一角出現了一個紅點。窗外的風乾燥而強勁，昨天灑下的水早已蒸發。室內只有無線電通訊與敲鍵盤的聲音。操作員立刻放大CCTV畫面，查看熱像儀溫度，並打開附近通報的畫面。要判斷那個紅點是真正的火災、燒田埂產生的煙，還是被夕陽曬熱的屋頂，最多只有幾分鐘時間。在這幾分鐘裡，在人的眼睛掃遍每一個螢幕之前，AI演算法已經做出了初步判斷。

2025年3月在慶尚北道義城郡開始的那場火災，顯示了那個判斷的分量。火勢蔓延到安東、青松、英陽與盈德。官方統計記錄了26人死亡、71人受傷。慶尚北道的暫定森林受損面積為99,289公頃，暫定損失為1兆1,306億韓元。慶尚北道、慶尚南道與蔚山的復原費用估計為1兆8,809億韓元。這些數字之所以不同，是因為受災評估與復原計畫的地理涵蓋範圍與會計分類不同，而不是因為損失在夏天增加了。

用來預防這類火災的AI，分兩大階段運作。機器學習從資料中找出規則，而深度學習則透過多層神經網路更深入地尋找規則。一種預測模型可在起火數天前、甚至長達一個月前，找出處於風險的地點；另一種偵測模型則能在起火後幾分鐘內辨識出火災。

濕度最先變動

較舊的野火風險評估依賴固定的地形與單一張植生指數影像。坡度與樹種每年變化不大，但野火並非只由地形造成。一座昨天安全的山，在雨後濕度驟降時，今天就可能變得危險。因此，森林AI正朝向結合天氣、地形、燃料植生，以及顯示人為進出的社會經濟資料，每天重新計算起火機率的方向發展。

野火資料有一個棘手的不平衡問題：發生火災的日子很少，而未發生火災的日子壓倒性地多。若模型未經處理就以這些資料訓練，只要一律預測為安全的日子就能得到高分，卻會漏掉火災。因此研究者使用SMOTE（Synthetic Minority Over-sampling Technique，合成少數類過採樣技術），以統計方式生成類似的火災日額外樣本，讓模型能平均地學習兩類。他們也使用對未發生火災日進行欠採樣，以及對漏掉火災施以更重懲罰的成本敏感學習。

一項江原道的研究，將此方法應用於2013年至2023年共11年的天氣、森林與人口資料。對於表格型資料，樹狀模型往往勝過深層神經網路，因為其分支決策能處理天氣

與地形這類差異很大的變數。在邏輯迴歸、XGBoost、LightGBM、隨機森林與極端隨機樹之中，極端隨機樹以0.839的AUC領先。AUC衡量的是區分火災日與非火災日的能力：1為完美，0.5則與擲硬幣無異。隨機森林在避免漏掉火災方面表現較佳，召回率為0.828。

該研究也使用了SHAP（SHapley Additive exPlanations），這是一種把賽局理論中共同貢獻分配的概念引入預測模型的方法。相對濕度以0.25的貢獻度領先所有變數；濕度下降時風險急劇上升。降水量以0.15緊隨其後，每日最高氣溫為0.05，人口密度為0.04。林木蓄積量、墓地佔比、針葉林佔比與農地佔比也有貢獻。將太白山脈以東、暴露於海風的嶺東，與山脈背後的嶺西分開的區域變數也有類似效果。此結果顯示，除了氣候之外，人為進出與縱火習慣也會提高風險。

針葉樹佔比與林木蓄積量這類燃料變數，不必逐棵樹去測量。包括LSWI、TVDI，以及由無人機雷射掃描產生的樹冠高度模型（CHM）在內的遙測觀測，可以取代實地踏查。利用無人機LiDAR繪製每棵樹的位置、周長與樹冠寬度的研究仍在持續。一項針對越南卡西亞松（Pinus kesiya）的深度學習研究，自動化了單株樹木偵測與樹冠劃分，為野火燃料圖的基礎資料開闢了一條途徑。

江原道的研究是一個地方性的隔日模型，而由蔚山科技大學（UNIST）林正浩教授團隊於2026年在《Communications Earth & Environment》發表的FWI-Net，則能預測未來最多31天的全球火災天氣指數。該指數結合氣溫、濕度、風與雨量，用以顯示可能的火勢蔓延。ECMWF的數值預報在兩週之後準確度迅速下降，而FWI-Net在整個31天區間內將誤差降低了6.6%，第一週更降低了12.4%。改善幅度最大的地方，是野火風險高但預報系統薄弱之處。一篇結合地理空間技術與機器學習成果的國際回顧文獻，得出了類似的結論：結合天氣、地形與人為活動資料的模型，一再勝過僅使用衛星影像或GIS資料的模型。

山上的感測器與天空之眼即時相連

地面上的感測器與天上的衛星注視著同一個時刻。LoRaWAN是一種用於長距離傳輸的低功耗無線方式。在土耳其的Zeytinpark，安裝了80個測量溫度、濕度與一氧化碳的感測器。研究者測試了一個結合自適應加權隨機森林與XGBoost的模型；感測器佈置的涵蓋率計算為95.58%，電池壽命最長達11個月。

一項在西伯利亞克拉斯諾亞爾斯克地區的研究，圍繞野火點畫出從1公里到100公里的六個同心圓區帶。它結合各區帶內30天的天氣與地形時間序列，以XGBoost對火災範圍進行分類，回報88.8%的準確度。作者指出，這是一個經過在地調校的結果，在轉用到另一個大陸之前，需要以當地資料重新校準。

Earth Fire Alliance首批三顆進入運作的FireSat於2026年7月7日進入軌道。官方路線圖從當年年底起為早期使用者提供每日兩次觀測，目標為2028年達成全球取用、2029年一小時內重訪，並鎖定在2030年代初達成20分鐘內重訪。衛星數量與時程可能隨發射與資金而變動。

一篇韓國的遙測回顧文獻也追溯了AI與衛星監測橫跨整個野火週期的情形：起火前的風險預測、火災期間的即時偵測，以及撲滅後的受災面積估算，各需要不同的衛星資料與模型。韓國的天氣衛星GEO-KOMPSAT-2A拍攝自然色的地球影像，可在視覺上區分雲、野火煙霧與塵土，其土壤水分觀測則支援乾旱與野火風險評估。國立山林科學院在國家野火風險預報系統中整合這些資料，並最近推出了在使用者所在位置顯示風險的行動服務。

不論是煙還是雲，相機先做判斷

一旦起火，另一場競賽便開始：必須在煙擴散之前，於幾分鐘內辨識出火災。固定的CCTV與紅外線相機從下方監看，而無人機則涵蓋難以到達的山脊與死角。可見光相機可能被霧霾、雲或傍晚的反光所欺騙。熱像儀能偵測熱能，但影像粗糙，可能把燃燒的樹木與被曬熱的岩石混淆。

以中國福建省資料訓練的EFFNet，結合了可見光與熱紅外線影像。其驗證mAP50為97.2%，精確度為94.9%，召回率為94.1%；這些是在福建測試條件下的結果。

Akhyar及其同事開發了DeepFire S3GA-Net，用以從無人機影像中分割野火區域。測試資料得出平均IoU為0.8723，精確度為0.9347，召回率為0.9194。Hindarto及其同事在另一個野火影像資料集上比較了MobileNetV3、ResNet50與YOLOv8。針對越南卡西亞松（Pinus kesiya）的YOLO分割與SAM2的比較，涉及的是單株樹木與樹冠的劃分，而非野火研究。

當模型各說各話

這些結果並非全都說著同一件事。僅使用天氣的傳統火災天氣指數模型，能辨識出大範圍的區域趨勢，卻無法區分在相同天氣下哪一小片森林會起火。針對江原道、摩洛哥與印度的研究回報，加入人口密度、農地與墓地佔比、與道路距離等社會經濟變數之後，AUC與召回率提升了10到15個百分點。即便在完全相同的天氣下，在人們頻繁造訪或附近有農地與墳墓之處，實際起火的可能性更高。

僅有可見光的相機價格低廉，但在起霧、逆光與夜間條件下，誤報與漏報會上升。像EFFNet那樣的雙模態設備表現強勁，但紅外線感測器昂貴且影像解析度較低。一個涵蓋整座山的地方政府，仍必須在密集部署廉價可見光相機與稀疏部署昂貴雙模態相機之間取得平衡。

侷限必須明白說清楚。SMOTE可能引入人工的樣式；LTE與5G在深山中經常失效；誤報會浪費消防員、直升機與預算，而漏報則延誤初期反應。像NVIDIA Jetson這樣的邊緣AI電腦必須在無人機上完成運算，但若模型無法壓縮，決策就會變慢。表現優異的視覺Transformer與3D CNN，對於必須以自己名義批准機器決策的官員來說，也仍然難以解釋。未來的工作朝兩個方向前進：透過SHAP或Grad-CAM把理由可視化，並把熱與風的物理嵌入神經網路；以及將低功耗感測器網路與雙模態無人機連結起來，同時測量端到端的警報時間。有人提出了針對野火、病蟲害與乾旱逆境的統一網路，但一個能在山中一分鐘內完成行動、充分驗證過的自主反應系統，尚未獲得證實。

資料來源與參考文獻

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/> (擷取於2026年8月2日)
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. National Institute of Forest Science. (2026). National Wildfire Risk Forecast System.
<https://forestfire.nifos.go.kr> (擷取於2026年8月2日)
16. Korea Forest Service. (2025, April 18). Provisional wildfire damage in North Gyeongsang, South Gyeongsang, and Ulsan: 104,000 ha; Korea Forest Service commits to recovery.
https://www.forest.go.kr/kfswweb/cop/bbs/selectBoardArticle.do?bbsId=BBSMSTR_1036&nttId=3206769
(擷取於2026年8月3日)
17. Government of the Republic of Korea. (2025). Total wildfire recovery support of KRW 1.8809 trillion, the largest ever. https://gonggam.korea.kr/newsContentView.es?content=NC002&news_id=f4f9ac3e-81e6-4479-a9e2-6f8cf1c6a34b (擷取於2026年8月3日)

3.2

基於影像的病蟲害（含松材線蟲病）與枯死樹木的早期診斷

週三清晨，三名調查人員攀上江原道的一座山麓。他們的背包裡裝著GPS裝置與基因診斷試劑盒，望遠鏡掛在脖子上，每到一處山脊，就有人停下來，在綠色山坡上尋找三、四棵呈紅褐色的松樹。一旦找到，他們就記錄座標，用生長錐取出鋸屑，並檢測是否感染。早已枯死的樹木甚至已聞不到強烈的樹脂氣味。

這種方法有一個決定性的缺陷：當松針看起來變紅時，其實已經太遲了。感染松材線蟲病的松樹，在媒介昆蟲松斑天牛把線蟲帶入之後會逐漸乾枯；若不加以干預，一片森林可能在數年內轉為紅色。然而肉眼可見的變色需要數週。在這數週之間，媒介昆蟲移往其他樹木，感染悄然擴散。透過望遠鏡發現的樹木已越過死亡的門檻，擴散也早已開始。

發現感染樹之後，工作仍在繼續：必須將其伐倒並粉碎，或覆蓋後燻蒸以消滅媒介昆蟲的幼蟲。一個人一天只能查看山坡的幾道皺褶，而密林更會拖慢工作進度。韓國山林廳在公布其2025年秋季防治計畫時表示，將在直升機與無人機調查中加入AI與LiDAR。AI先篩選出疑似樹木，人員再以基因診斷試劑盒加以確認。優先的人力與設備先投入國家保護的最前線區域、白頭大幹以及金剛松林。2026年6月，機張郡開始對難以徒步進入的地形與盲區進行無人機調查，製作高解析度正射影像，並與釜山分享疑似樹木的位置。

在變色之前判讀

當病原體感染一棵樹時，其導管會受到阻塞。樹木關閉葉片氣孔以減少水分流失，蒸散量下降，葉面溫度緩緩上升，就像關掉冷氣之後的房間一樣。這個訊號在松針變紅之前數週就已開始。若把樹冠溫度、NDVI與SAVI等植被指數以及氣象資料結合起來，無人機上的熱紅外線感測器就能偵測到它。準確度取決於樹種、拍攝時間、陰影與水分狀態。在早晨、中午與傍晚反覆拍攝，有助於把虛假的陰影訊號與生理逆境區分開來；訊號本身無法確認病原體，因此必須接著進行現場樣本檢測。

這幾天或幾週的差別具有決定性。若感染樹只在變色之後才被發現，媒介昆蟲可能已在鄰近的數棵樹上產卵。若在變色之前偵測到，移除一棵樹或許就能阻止擴散。這個時間窗口正是早期診斷的目標。

另一種方法測量的是成分而非顏色。葉綠素、水分與色素比例在變紅之前就會改變，產生紅緣（red-edge）與短波紅外線訊號。在美國林務局與明尼蘇達大學的一項橡樹實驗中，乾旱逆境最早可提前27天被區分出來，橡樹萎凋病的反應最早可提前24天被區分出來。西班牙2021年的一項研究，以高光譜與熱影像檢視與樟疫黴（*Phytophthora cinnamomi*）感染及水分逆境相關的橡樹衰退。橡樹萎凋病與橡樹衰退具有不同的病原體與病理。

同樣的方法也正被嘗試用於松材線蟲病。2025年《Remote Sensing》的一項研究，在無人機高光譜影像中結合色素與含水量指數，以追蹤感染早期的生化逆境。2024年的一項研究，把每月的無人機時間序列與深度學習結合，以推估感染階段與每月擴散距離。一項使用ResNet18、CBAM與LSTM的受管理楊樹苗實驗，回報品種與乾旱逆境分類的準確度達99.69%，這是一個驚人的數字，但不應被解讀為橫跨無人管理森林的野外結果。

2026年《Frontiers in Plant Science》的一篇綜述描述了更廣泛的趨勢：用於大範圍覆蓋的衛星遙測、用於中等範圍覆蓋的無人機高光譜感測，以及用於近距離精密的地面感測器，正被層層疊合起來，用於樹種分類、森林災害監測與樹木健康評估。

清點已經枯死樹木的眼睛

躲過早期診斷的樹木會一路紅到樹幹，落盡所有松針，乾枯成灰色。這類站立枯死木仍然難以清點與製圖。Chowdhury與十三位同僚在2026年的一篇綜述發現，在枯死樹木零散分布之處，YOLO系列模型表現強勁。2022年發表的LDS-YOLO，是為了在背景複雜的防護林中不遺漏小型枯死樹木而設計。當一棵樹只佔影像中的少數幾個像素時，笨重的模型可能會把它當作背景雜訊抹去。2025年一項雙路徑特徵融合的研究，降低了密集枯死木斑塊中的偽陽性。

在樹冠彼此重疊之處，矩形物件偵測不如把每個像素標記為活或死的分割法適用。德國2021年的Silvi-Net同時運行兩個CNN，用於樹種分類與枯死樹木判定。

Chowdhury的綜述也涵蓋較新的模型，如FSC-Mask2Former與ADA-Net；來自不同資料集的精度數值，必須連同拍攝條件與評估指標一起判讀。

一項重要的變化是資料累積的方式。deadtrees.earth由Mosig、Kattenborn與同僚於2026年在《Remote Sensing of Environment》中提出，是一個結合來自世界各地數千張公分級解析度航空影像的開放資料庫。它涵蓋超過一百萬公頃，人類已在超過58,000公頃中標記了活樹與枯樹。使用者可以上傳無人機影像、接收AI分類、加以修正，並把該修正回饋給模型。這是一種嘗試，用以解決在某一片森林有效卻在別處失效的模型；隨著共享資料庫的成長，把模型從歐洲雲杉重新訓練到韓國松樹的工作量或許會減少。

2025年的一項實驗說了解析度的重要性。它以U-Net在7公分解析度的無人機影像，以及中國BJ3N與BJ3A衛星在30公分與50公分解析度的影像中，偵測松材線蟲病感染樹。無人機影像取得F1值89.1%，多光譜融合的30公分衛星影像取得88.9%。使用未經校正的1.2公尺與2公尺影像，則把分數降低到66.6%與58%。當一個像素比一棵樹還大時，AI的視覺也會變得模糊。

繪製擴散路徑

診斷一棵樹，與繪製疾病將往何處擴散，是不同的任務。每月反覆的無人機拍攝可以把時間序列連接起來，以推估感染階段與每月擴散距離。把同一林分的多光譜與熱影像堆疊起來，可以繪製疾病推進的邊緣，並指引下一步應從何處開始防治，甚至可以沿著仍然健康的森林邊緣設下一條預防線。機張郡把成果與釜山分享也是出於同樣目的：當擴散圖跨越行政邊界時，它會變得更有用。

防治並非終點。在空中噴藥、樹幹注射，或伐倒與燻蒸之後，每隔兩三週對同一地點拍攝影像，並把光譜指數與樹冠溫度和健康的參照樣區相比較，就能衡量成效。

Sevinç在2025年《Scientific Reports》的研究，運用人工神經網路來評估機械、化學與生物防治方法對工業用材生產與森林健康的影響。單靠化學防治會加重土壤與鄰近溪流的負擔；單靠生物防治則可能比擴散還慢，因此成效的數值紀錄有助於選擇下一季的綜合病蟲害管理策略。2026年發表的兩篇中國《農業科學》論文，同樣綜述了用於森林資源調查與病蟲害防治的無人機遙測，以及用於病蟲害防治與精細管理的智慧技術。

相近的工作涉及樹皮甲蟲。2026年7月《Remote Sensing》的一篇論文，在XGBoost中把每週的Sentinel-2影像與樹齡、地形等固定資訊結合，回報其早期偵測相較於僅用衛星、僅用固定資料以及較早的方法都有所改善。一項捷克雲杉研究發現，以無人機高光譜影像區分健康、感染與枯死樹木的準確度為81%，相較於載人飛機的73%。共同的限制在於，從甲蟲侵入到成蟲羽化的期間，可能比衛星或無人機注意到樹冠變化所需的時間還要短。

相互矛盾的結果與尚待解決的課題

高光譜感測器能在變色之前很早就偵測到肉眼看不見的光譜位移，但價格昂貴且處理緩慢。RGB與多光譜的YOLO或U-Net系統較為便宜，能迅速覆蓋大範圍區域，但往往只有在松針變紅之後才能有效偵測到樹木。選擇也取決於森林結構：對於偏遠山區零散分布的枯死樹木，YOLO較有效率；而在密集混合林分中，重疊的框會增加偽陽性，此時U-Net或Mask R-CNN分割法可能較佔優勢。

即使是優異的無人機與衛星，也無法看見每一棵樹。在上層樹冠密集的森林中，光學與熱訊號大多來自最頂層，並掩蓋下方的早期感染。在某一生態系準確的模型，可能

在他處的地形或樹種上喪失效能；其下降程度因資料與指標而異。人類在描繪枯冠邊界時的差異，也會改變驗證結果。溫帶針葉樹的模型在亞熱帶闊葉林中可能失靈，因為葉片厚度、蠟質、林分密度與土壤濕度都與其學習到的條件不同。

下一階段有兩個方向：在無標記影像上進行自監督學習，並與deadtrees.earth等全球資料庫結合；以及搭載熱、高光譜與LiDAR感測器並在機上運算的無人機，讓疑似感染能在一分鐘之內向現場發出警報。若調查人員的望遠鏡有朝一日完全被無人機與AI取代，那麼在樹木變紅之前，干預或許就已經展開。

資料來源與參考文獻

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, June 27). Gijang County conducts precision surveillance of pine wilt disease using drones. <https://www.metroseoul.co.kr/article/20260627500013> (於2026年8月2日查閱)
17. World Environment Newspaper. (2026, June 25). Korea Forest Service announces 2026 pine wilt disease control results. <https://www.e-newsp.com/news/article.html?no=88960> (於2026年8月2日查閱)
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, September 24). Korea Forest Service will combat pine wilt disease with AI: a control action plan is established. <https://www.etnews.com/20250924000152> (於2026年8月2日查閱)

3.3

非法伐木聲學偵測與物聯網／區塊鏈森林保護網路

在熱帶雨林的高樹上懸掛著一個帶有太陽能板與麥克風的小型裝置。它是來自美國非營利組織Rainforest Connection的Guardian。它在裝置端分析森林聲音，一旦偵測到電鋸或車輛等人類入侵跡象，便發出警報。該組織表示，其聲學監測計畫已協助保護超過726,000公頃。由於公開報導的累計數字採用不同的專案期間與標準，因此裝置數量、錄音時數與已確認物種無法作為單一整套成果進行比較。同一份錄音中包含鳥類、蛙類與昆蟲：為入侵警報而安裝的麥克風，也可能成為聆聽生物多樣性的耳朵。

衛星照片只有在樹木被移除之後才能顯示，而雲層甚至能遮住那一刻。徒步巡邏無法每天掃遍整片森林。要制止砍伐，必須有人在啟動電鋸到樹木倒下之間的短短幾分鐘內知情。這項需求促成了結合安裝於樹上的麥克風與感測器、低功耗通訊，以及能即時判斷聲音的AI的網路擴散。

午夜時分，麥克風可能捕捉到分成兩拍的波形，那是人反覆扣下與放開扳機時引擎的節奏。一枚小晶片在數秒內掃描它，將它與斷裂的樹枝或路過的摩托車區分開來，並給出一個信心分數。從這一刻起，辨識聲音的AI、現場的運算與通訊，以及追蹤被伐木材的帳本，開始協同運作。

辨認電鋸的森林之耳

動力設備的引擎聲是伐木的線索。附著於樹幹或支架上的超低功耗聲學物聯網感測器接收環境聲音，並在小型電腦中加以分析。Andreadis等人（2021）測試了一個原型，將擷取聲音特徵的CNN置於超低功耗裝置上，並透過LoRa發送警報。該論文報告在受限的實驗資料下分類準確率為85%。當森林類型、季節或設備改變時，不能假定會有相同的準確率。

訓練比看起來更困難。摩托車與小型發電機的旋轉頻率與電鋸相似，而遠處自然斷裂的樹木與雷聲也會使早期模型混淆。研究人員收集了實際伐木場與一般森林數個月的聲音，並將這類情況教給模型。覆蓋範圍也隨地形與樹木密度而異；保護一片大型保留區需要數十或數百個網格狀節點，並在通行路線與歷來遭伐區域優先配置。

在濃密的雨林中，聲音可能不足，因為它在傳遠之前就已擴散。Prasetyo等人（2018）製作了一種感測器，同時偵測電鋸聲音與樹幹被切割時透過幹身傳遞的細微振動。這種組合大幅減少了誤報：當一種訊號減弱時，另一種可以支持判斷。

電池供電的決策與無人機派遣

在偏遠森林中，難以將連續的原始錄音傳送至伺服器。將模型置於裝置上，僅在電鋸機率高時傳送座標與判斷結果，可減少流量與耗電。LoRaWAN本質上是一種「星狀之星」（star-of-stars）網路，感測器直接與閘道通訊，而非由相鄰感測器轉發訊號的網狀網路。位於無線電覆蓋範圍之外的山谷需要額外的閘道或獨立的中繼。

Sharma等人（2022）的LoED提出了一種結合LoRa與邊緣運算的森林監測架構；它並未提供能在每一片森林都做出低於一分鐘警報或減少40%流量之通用主張的實地驗證。電池續航力會隨面板尺寸、遮蔭、傳輸頻率與運算負載而變化。

在控制中心，這一切運算會呈現為地圖上的一個點，帶有座標、信心度，以及與最近巡邏路線的距離。人員決定是否派遣；反覆出現的誤報可能導致他們調低當地模型的靈敏度。派往警報座標的無人機可以增加影像確認。Ramadan等人（2024）提出了一種聲學感測器／無人機（UAV）結構。Kundu等人（2025）在另外的影像上測試了YOLOv8與代理型（agentic）AI，最大召回率約為0.24，mAP50約為0.07。這些研究並未展示已部署的自動派遣系統；就目前而言，在聲學警報後必須由人確認影像。

從樹樁到陳列架的數位軌跡

森林中的執法無法阻止已攜帶看似合法文件的木材進入市場。歐盟毀林管制規則EUDR（2023/1115號規則）要求在歐盟市場上供應或自歐盟出口附錄I商品（包括木材）的業者，提供地理定位並執行盡職調查。四公頃或以下的地塊可以用單一經緯度點來表示；較大的地塊則需要邊界多邊形。並非每一項木材產品與每一塊小地塊都須提交多邊形。

區塊鏈是一種分散式帳本技術，參與者各自持有同一份帳本的副本。它使日後對已議定紀錄的竄改更容易被察覺，但一開始就輸入的虛假來源或物種資訊仍然是虛假的。Stopfer等人（2024）與Düdder和Ross（2017）探討了它在分享木材供應鏈紀錄與降低盡職調查成本方面的潛力。並無實地證據顯示區塊鏈單靠自身即可防止合法與非法木材混合，或保證為每一棵樹提供履歷。RESET.org的ForestGuard是一個針對無毀林咖啡的開源原型，而非木材供應鏈專案。

圖表顯示採伐機記錄座標與直徑，運輸與製材量測在同一份帳本中延續。實務上，各製造商與各企業之間的資料格式不同，而當原木被劈成木板或與其他木材混合時，這條連結就會減弱。來源證明對於海關與貿易可能是必要的，但它本身並不保證高售價。必須結合感測器、驗證、實體標記與實地稽核，才能縮小帳本與木材之間的落差。條碼、QR碼與RFID仍是必要的實體連結，但結合採伐機自動標記、鋸木廠光達（LiDAR）、年輪指紋與區塊鏈的系統尚未經過驗證。Triplat等人（2026）在另外的照片中依市場價值等級對原木進行分類；那並非木材可追溯性或三維指紋的測試。

參與在歐盟市場上供應附錄I商品或自歐盟出口該等商品之供應鏈的韓國企業，可能受到影響。僅憑家具或膠合板等產品名稱並不能決定是否適用；必須將海關代碼、企業的角色與原料路徑一併檢視。

相互衝突的抉擇與尚未解決的工作

聲學感測器在數秒內做出反應且相對便宜，但可能因雷聲、斷裂的樹枝或樹葉而引發誤報。合成孔徑雷達（SAR）衛星或無人機影像能繪製實際的清除面積，但因取得週期與雲層而反應較慢，且安裝與營運成本較高。目前尚無任何方法能同時提供即時反應與廣泛確認。反覆的誤報可能使巡邏人員對真正的警報反應遲緩，因此精準度也關乎維護現場人員的信任。

以太坊（Ethereum）等公有區塊鏈透明，但每秒能處理的交易很少且可能昂貴。在採伐尖峰期，每小時可能有數百根原木送達鋸木廠的磅秤，形成瓶頸。因此，許多木材供應鏈研究偏好僅供特定工廠與公部門存取的私有鏈或聯盟鏈，例如Hyperledger Fabric；限制參與者會削弱該系統原本想保護的開放性。

標籤可能在雨水、泥濘與崎嶇的山路運輸中脫落或失效，而將原木加工成木材或木片可能抹去標記。偏遠的聲學感測器在風、雨與野生動物噪音中會喪失準確度，其太陽能電池也需要持續的能源管理。對於一位小型私有林所有人而言，在陌生的應用程式中輸入採伐紀錄，其門檻與擁有專職人員的大公司截然不同。跨越多年的維護，包括更換電池與面板、修復節點與重新訓練聲音模型，其成本可能高於初次安裝。

歐盟一再調整EUDR的時程。依照現行時間表，一般業者自2026年12月30日起適用。於2024年12月31日或之前設立的自然人微型與小型企業另行延期至2027年6月30日；這並不代表每一家小型企業都能獲得相同的延期。必須查核其法律形式與設立日期。DNA與穩定同位素分析則是將木材組織中的遺傳或化學痕跡與參考物質比對，以推估物種或來源。它可以在標籤遺失後發揮作用，但參考資料庫的覆蓋有限，且需要時間與金錢。實地系統必須結合聲學警報、地理空間資訊、實體標籤、文件查核與樣本檢測。StanForD是森林機械的生產與作業資料交換標準，而非國際木材貿易表單，而尚無任何單一區塊鏈能連結各國盡職調查紀錄與海關系統並成為公認的運作標準。

資料來源與參考文獻

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. Düdder, 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, January 28). 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> (查閱日期：2026年8月2日)
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/> (查閱日期：2026年8月3日)
 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, March 24). 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

智慧林業作業與機器人技術：作業安全、自動駕駛與林道網路最佳化

4.1

自動擷取林道與集材道，以及配合地形的採伐規劃

地圖上，一條綠線平順地穿過山坡，卡車導航系統顯示集材場就在前方400公尺。轉過彎後，路卻消失了。夏季豪雨把一半路基沖進山谷，另一半則長滿手臂粗、齊頭高的灌木。滿載原木的卡車停了下來。山與山之間無線電訊號中斷，只能派人徒步上山，目測坍塌路段和坡度，在筆記本上畫下草圖，再走回來。後方兩輛卡車急速等候。地圖是三年前的，森林早已改變。

這種情況在韓國並不陌生。每年都有林道興建，也有林道坍塌。韓國山林廳把2026年預算編列為3兆260億韓元，比前一年增加15.6%，也就是4,091億韓元。為極端天候建造和修復堅固林道，是其中的優先事項。國會通過《林道設置法》，把規劃、設置、營運和維護納入同一套法律架構。然而，只要地圖與現況不符，卡車運輸仍會停擺。這正是利用空載資料自動重繪道路的做法日益普及的原因。

從空中重新繪製道路

傳統調查仰賴人員步行或駕車巡查道路、查看路面，再以手工更新地圖。在濃密樹冠下，細微地形變化、路面損壞和新開闢的軌跡，往往要到下次調查才會被發現。航空雷射掃描能填補這道缺口。飛機或無人機上的光達可以篩選抵達地面的回波，製作數值地形模型（DTM），並建立樹冠高度模型（CHM）和坡度圖。道路會留下痕跡：坡度平緩、表面平順、寬度一致的帶狀地形。人工智慧學會辨識這些痕跡後畫出線條，分析橫斷面以判斷可用寬度和路面狀況，並在既有路網檔案中更新中斷、侵蝕和植被入侵路段。輸出通常是可直接用於GIS的向量檔。

Roussel等人在2022年開發的ALSroads系統，從點雲擷取道路寬度、坡度、曲率等七項指標，再結合路徑搜尋，修正舊有道路地圖。更早以前，Buján等人已採用結合坡度、曲率和反射率的規則式混合分類。CNN與U-Net模型同樣能在DTM中，把平坦、平順的道路形態與周圍地形區分開來，即使道路位於閉鎖樹冠下方也能辨識。

在廣域作業方面，Morley等人於2024年使用單光子光達更新北方林區的道路網。Winiwarter等人則把CNN應用於3公尺解析度的PlanetScope CubeSat影像。他們選用沒有雲和煙霧的鑲嵌影像，因此缺乏乾淨影像的地點仍留下空白。這不是光學衛星穿透雲層進行觀測。Siafali等人結合航空光達、行動SLAM光達和iPhone光達，重建山區道路表面。廣域觀測和近距離精測，解決的是不同問題。

卡車真正能通過的寬度

地圖上畫出一條線，不代表大型木材卡車就能通過。Karjalainen與Waga展示了如何利用機器學習，分析垂直於道路的地表橫斷面。即使枝葉遮擋，無法直接從上方量測寬度，剖面仍能顯示可通行寬度、侵蝕、裂縫、排水溝堵塞和路旁植被。清楚的剖面中央是平坦壓實的路面，兩側是平緩排水坡，再往外才是原始山坡；剖面模糊或一側坍塌，則表示道路需要維護。

Hruža等人（2025）結合無人機與航空光達，找出阻礙道路施工的岩石、未切除樹樁和倒木，並在擾動地面前，先模擬通往集材場的路線。Tanaka等人（2025）展示一套日本演算法，只使用光達分析結果，便能為森林作業道建設排定優先順序，從單一資料集推導坡度、微氣候、立木和適合集材場的位置。無力負擔獨立測量團隊的小型合作社或企業，也能從中受益。

測量車輪痕跡

林道是卡車通行的正式道路，集材道則是採伐機、集材機和拖拉集材機形成的臨時路線。重型機械反覆通行會壓實土壤，使輪轍越來越深。壓實土壤失去容納空氣和水的孔隙，地表逕流增加，殘留樹根生長變慢，損害也可能引發山崩和溪流混濁。Abdi等人（2022）使用高密度航空光達和U-Net，分割部分被林下植被遮蔽的路徑。Latterini等人在五個地中海地點，比較採伐前後的無人機光達資料，使用暈渲圖、局部地形模型、相對密度模型和SkidRoad_Finder。相對密度模型表現最佳，準確率約73%、敏感度66%，還能估算輪轍深度、體積和土壤壓實風險。Usui（2021）則以GAN生成的資料增強，處理路徑影像不足的問題。

先計算能避開損害的路線

道路建成後再測量損害，只能辨識已經存在的問題。要減少損害，必須在伐木前選定路線。Görgens等人（2020）把光達推導的樹木位置與材積、地形坡度、土壤濕度指標，和遺傳演算法、動態規劃及線性規劃結合。模型在避開高壓實風險和陡坡區域的同時，縮短原木運送距離。Picchio等人（2018）為義大利山區建立一套GIS決策支援模型，考量坡度、侵蝕敏感性、保留木損傷，以及應使用架空集材機、集材機或絞盤輔助設備。Eberhard等人在2025年把相關模型延伸到陡峭地形。集材機在緩坡作業，坡度更陡時則用架空集材機吊運原木。輸出路線可以印在紙上，也可以送到平板電腦。

理論與現場之間仍有落差。單光子光達和CubeSat影像能以低成本涵蓋主要路網，卻無法解析狹窄路徑與輪轍。無人機光達、地面SLAM和手機光達能達到公分尺度，但覆蓋範圍小、處理時間更長。Görgens算出的理論最佳路線，未必與Abdi觀察到的駕駛實際行駛路徑一致，因為每日天氣、障礙物和駕駛行為並未被完全納入。濃密的夏

季葉片與林下植被會減少地面回波，高密度點雲需要大量運算，移轉到地形與樹種不同的森林時也必須在地驗證。

積雪還會帶來另一個問題。Podolskaia與Sinitsina在2026年建立的Krasnoyarsk冬季道路資料集，記錄只在冬天看得見、解凍後便消失的道路，顯示演算法必須因應不同季節和緯度重新學習。Gao等人於2026年改良DeepLabv3+，使用多時期衛星影像辨識供森林火災救援人員進入的林道。這些模型全都需要加上標籤的訓練資料，但各地道路和路徑差異很大，取得標籤十分緩慢。未來工作包括建立介面，向技術人員顯示人工智慧判斷道路可通行時所依據的坡度與路面起伏。當計畫傳送到機械時，可以把StanForD視為生產資料串接方式，但它本身並不保證安全導航；路徑資料、機械控制和安全規則仍須分別驗證。

資料來源與參考文獻

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, December 12). 2026 priority initiatives: “Forests that save people, people who save forests.” <https://v.daum.net/v/20251212095549587> (accessed August 2, 2026)
20. Korea Forest Service. (2026). Parliament passes the Forest Road Installation Act, providing a legal basis for forest-road installation and management. <https://idsn.co.kr/news/view/1065599659428633> (accessed August 2, 2026)

4.2

遙控採伐機、自主集材機與林業機器人

操作員坐在辦公椅上，腳下是地毯，桌上放著冷掉的咖啡，窗外是停車場，面前排列六個螢幕，手裡握著像電玩控制器的搖桿。幾年前，這個人還會坐在陡坡上不斷震動的駕駛艙裡，在引擎噪音中伐木。現在，只要輕推搖桿，數百公尺外的機械手臂便會夾住一棵樹。一個螢幕顯示夾爪在樹幹基部的角度，另一個顯示機械傾斜度，還有一個播放影像，確認周圍是否有人員與設備。過去從駕駛艙看不到的角度，如今可在辦公室裡同時看見，剩下的只有手指細微移動。

這已不再是科幻小說。2025年秋季，一輛新造的Komatsu集材機抵達瑞典烏普薩拉附近Jälla的Troëdsson Forestry Teleoperation Lab，並配備遙控作業功能。研究人員與于默奧大學合作，擷取資料供人工智慧模型使用，訓練機器人自行做出判斷。他們的目標，是建立人不受傷、樹木也不受傷，而且作業能維持永續的林業。

韓國也展開類似工作。2025年8月，國立山林科學院宣布進行智慧林業作業機器人的行駛測試。這部機器人結合GNSS與INS，並直接在機身內運行由相機影像訓練的人工智慧。它能辨識林道、找出道路中心線，並沿線行駛。由於運算在機身內完成，即使通訊訊號微弱或完全中斷也不會停下。這種方式適合連手機訊號都不可靠的韓國深山森林。

讓機器先進入危險地點的原因很清楚：鏈鋸伐木和木材搬運，同時面臨陡坡、落石、機械翻覆和肌肉骨骼負荷。有些實驗利用影像和慣性感測器，以高準確率分類工作姿勢或作業階段，但這些數值來自小型測試集或受限的活動類別，並不能證明所有森林姿勢和疲勞狀態都能同樣準確地辨識。在慶尚北道奉化郡，韓國山林廳所屬榮州國有林管理所將從2026年8月起，營運專用基地，存放和維修採伐機、集材機、碎木機等高效能設備。購買、操作和維修機器人的基礎設施，正與機器人本身同步發展。

45度坡面上的機械

絞盤輔助設備以堅固纜索提供持續拉力。纜索一端固定在上坡處的粗壯樹木或專用錨定機械，另一端連接下方採伐機。當車輪或履帶原本會打滑時，纜索能使機械貼住地面，在30度到超過45度的坡面作業。這種設備出現前，人們必須扛著鏈鋸走過這些坡面。沒有纜索的機械若被放在陡坡上，可能空轉、撕裂土壤，甚至翻覆。

日本林業機械化協會的示範，依坡度清楚區分作業方式。在中等坡度，遙控採伐機負責伐木，自主集材機負責搬運，過去需要五六個人的工作，現在兩人即可完成。在坡度更陡的地方，遙控絞盤輔助採伐機取代人力攜帶鏈鋸作業，再用纜索夾爪或塔式集材機把木材運出。人留在螢幕前，機械爬上危險坡面。2025年發表的歐洲研究，以GIS決策支援模型提供佐證，模型結合坡度、侵蝕風險和保留木保護。某個區域的地面可能足以使用絞盤輔助，另一個區域則可能需要不留下輪轍的架空集材。答案由地圖數值選出，而不是憑直覺。

樹木阻斷衛星訊號的地方

進入森林深處，天空便消失了。濃密樹冠可能切斷GNSS訊號，或讓反射訊號混合成錯誤位置。遙控或自主機械無法依賴人的視覺和感覺，因此需要SLAM，利用地面感測器同時建立位置和周遭地圖。2025年，Yao等人調整Hector SLAM，使其適用於在密林中移動的林業機械。他們過濾從葉片與細枝反射的光達點，融合IMU測量值，修正崎嶇地面造成的掃描變形，並透過配對光達點估算移動，而不是依賴可能打滑的車輪轉動。

與基準Hector SLAM相比，誤差下降47.65%。平均製圖誤差為4.78公分，最大誤差低於8.7公分。停止時的平均定位誤差為9.9公分。在三種速度設定下，水平誤差保持在7.9公分內，航向誤差低於36.5度。在狹窄林道上，幾公分就可能決定車輪是否離開道路，或損傷保留木的根。國立山林科學院的道路測試與Yao的森林內部測試，目標並不相同，但兩者共同顯示，在GNSS失效的森林中實現自主移動，是一項國際性問題。

四足機器人與載重機器人

森林地面高度不規則，巨石、腐朽倒木、及膝灌木和坑洞，都會妨礙輪式與履帶式機械。歐盟DigiMedFor計畫以Boston Dynamics四足機器人Spot處理這個問題。Spot搭載三維光達、高解析度相機、小型電腦、光學濾鏡、GPS和傾斜感測器。它越過碎石、灌木和坡面，收集點雲與影像，更新包含單木資訊的數位孿生。輪子會空轉停下的地方，它能逐腿調整。

瑞典的研究則以科技、組織、環境（TOE）架構檢視自主集材機。森林不同於工廠地板或都市道路，天氣、土壤水分和樹木形態不斷變化。因此研究人員提出人機協作，而不是完全自主：由經驗豐富的駕駛判斷整體計畫，機器人則處理有限度的導航、避障，以及與保留木保持距離。這不只改變機械，也改變工作。操作員移到遠端控制站，維修人員則需要接受自主設備訓練。

為了在測試緊急煞車和感知功能時避免損壞機械與森林，拉普蘭應用科學大學和瑞典RISE建立了一片虛擬森林。他們的Vindeln數位孿生使用無人機影像和高解析度雷射

掃描等現地資料。在其中改變視角、太陽角度和樹木位置，可以產生SimForest，也就是合成RGB-D實例分割資料集。工人突然進入機械路徑、濃霧等情境，可以重複數百次，在沒有真實危險的情況下測試。

尚未成熟的自動化

步行機器人能在糾結地面穩定移動，精確掃描林下環境，但只能承載數十公斤，無法伐木或搬運木材。自主集材機與遙控採伐機能處理數公噸原木，卻可能在崎嶇密林中陷住或壓實土壤。沒有任何單一機體適合所有森林，必須依地形部署不同機體。虛擬森林的結果與真實森林之間也存在落差。霧、雨、鏡頭灰塵、搖動枝葉和逆光都會降低相機與光達的判斷能力，效能損失大小取決於感測器、天氣和測試資料。使用合成資料訓練的模型，需要另外在真實森林評估。

Spot這類電動步行機器人在戶外可能一兩個小時就耗盡電池，不適合長時間偏遠任務。SLAM長距離穿越密林時，可能失去迴環閉合，定位誤差持續累積，直到螢幕顯示機械仍在道路上，實際卻已偏入樹間。高額初期成本對小型森林所有者十分困難，故障責任也尚未釐清。機器未辨識到人而發生事故後，製造商、林業公司和遠端搖桿操作員都可能牽涉其中。Chen等人（2025）提出的分散式多機器人控制，或許能連結檢查道路的無人機、勘查地形的步行機器人和運輸木材的集材機，但要部署於林業，必須共同驗證間歇性通訊、現場運算、避碰和緊急停止。StanForD支援紀錄交換，不等於保障機器人安全。停止時間必須根據速度、煞車距離、感測範圍和工人隔離距離設定。法律安全連鎖裝置和國際資料標準等制度工作，可能比重新設計機器人本身更耗時。

資料來源與參考文獻

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 [video]. YouTube.
<https://www.youtube.com/watch?v=58rjC9O-1Mk> (accessed August 2, 2026)
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, December 9). The next step in the automation of forestry machines. <https://forestmachinemagazine.com/the-next-step-in-the-automation-of-forestry-machines/> (accessed August 2, 2026)
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 FFPRI public lecture: Forests in 2050 and their role in a depopulating society [video]. YouTube. <https://www.youtube.com/watch?v=OEhqSNoACCo> (accessed August 2, 2026)
10. Japan Forest Machinery Association. (2026). Part 3, FY2025 smart forestry machinery and new wood-based materials symposium [video]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (accessed August 2, 2026)
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, August 6). National Institute of Forest Science develops an intelligent forestry-work robot based on onboard AI. <https://www.irobotnews.com/news/articleView.html?idxno=41635> (accessed August 2, 2026)
14. Eze Insurance News. (2026, July 31). Carrying the future of forests: high-performance forestry-machine depot begins full operation. https://dazabi.com/insurance_magazine/article.php?id=40560 (accessed August 2, 2026)

4.3

以電腦視覺與穿戴式感測器為基礎的工人安全監控

清晨六點，江原道麟蹄郡一處伐木現場，一名工人把安全帽帶拉緊了兩次。帽簷內側裝著一個指甲大小的灰色慣性測量單元（IMU），用來測量身體傾斜度和步行速度。公司在三個月前發下這頂安全帽，工人最清楚的感覺，是它重了大約20克。鏈鋸啟動後，鳥鳴消失，引擎聲充滿山谷。今天預定砍三棵樹，坡度比昨天更陡。

2026年3月，韓國雇用勞動部報告，2025年林業與漁業合併類別共有18人因事故死亡，比前一年增加11人。統計沒有單獨區分林業，但這個類別與批發零售業一樣，被列為安全管理體系薄弱的小型事業單位。遭倒木擊中、在坡面滑倒、被設備壓傷致死的故事一再發生。《職業安全衛生法施行令》第24條，把林業與製造業、廢水廢棄物產業歸為同一類；經常僱用20人以上、未滿50人的事業單位，至少必須指定一名安全衛生管理負責人。但指定一個人，並不能讓他即時看見獨自在陡坡使用鏈鋸者的姿勢。林業工人年齡逐漸升高，許多人仍用比過去更難承受衝擊的身體，攀爬陡峭山區。

林業把不規則坡面、沉重原木和高風險動力機械集中在一起。美國勞工統計局2023年資料顯示，伐木工人每10萬人的死亡率為98.9，約是全體工人平均3.5的28倍。伐倒、打枝和造材需要長時間彎腰、扭身和傾斜，容易造成工作相關肌肉骨骼疾病（WMSDs）。OWAS依背部、手臂、腿部和負重，把風險分為四級：第1級不需要改變，第4級則必須立即矯正。RULA與REBA是相關系統，但傳統上都需要人逐格查看影片。電腦視覺與穿戴式裝置的出現，是為了自動化一項工作量太大的任務，人不可能持續觀察所有森林工人。

相機如何閱讀姿勢

人體姿態估計會追蹤影片中的肩膀、手肘、膝蓋等關節點。Forkuo等人使用影像與骨架連接線訓練ResNet-50。在252張類別平衡的測試影像上，OWAS準確率與F1都達99.8%。這是一個小型且平衡的測試集，不能證明在真實森林中面對遮蔽與光線變化時，仍有相同表現。同一團隊2025年的論文發現，模型比人工評估快19至53倍；人工評分者之間的Fleiss' kappa為0.28至0.49。這些數字描述的是速度和人與人之間的意見差異，不是模型更準確或更能抵抗相機角度改變的證明。

他們另一項工作利用Inception V3與SqueezeNet進行影像嵌入，開發期間的準確率分別達84%和89%，但在未見資料上只有約49%至60%。論文並未展示智慧型手機的現場部署。小型模型與在山區手機上穩定運行，是兩種不同主張。

戴在身上的感測器與聲音

身體被樹冠、葉片和枝條遮住時，相機便會失效。穿戴式裝置填補這個盲點。手機或手錶中的三軸加速度計與陀螺儀，加上配戴在身體或設備上的噪音劑量計，可以不靠相機測量動作與振動。無論陰影或霧氣，握鏈鋸手部的顫動、肩膀傾斜和不穩定步態，都會變成數字。Borz等人在造材作業中，把加速度計和噪音劑量計裝在工人與鏈鋸上，測試七種模型。只使用背部一個加速度計時，準確率為63%；有些結合鏈鋸加速度和噪音的設定達99.8%。這項研究區分的是工作、休息和移動等活動狀態，並不是用同樣準確率診斷關節過度彎曲或疲勞。感測器位置與行為類別改變後，效能必須重新測試。

韓國已引進配備感測器的安全帽。2025年5月21日的一篇報導指出，Asgard為營建工人開發的智慧安全帽TUGU，具備衝擊和溫濕度感測器、相機及無線電功能。這是製造商說法，不是獨立現場驗證，也不是林業專用設備。韓國山林廳曾在2020年10月，於國立漆谷森林體驗中心展示供森林火災人員使用的穿戴式機器人與智慧安全帽原型，但沒有找到證據顯示這些設備後來成為全國伐木現場的標準配備。穿戴式裝置也面臨汗水和粗重作業造成脫落、電池無法撐過一整天，以及工人拒絕配戴等問題。

安全帽開口說話時

另一部分研究評估大型語言模型能否支援林業安全諮詢。Arimizu Kengo（2026）評估模型對林業事故情境和專家問題的回答。這並不是一套已部署、能根據過往事故報告與照片自動判斷風險的完整現場系統。掛枝木等高度依賴脈絡的危險，應由有經驗的實務人員確認，不能只交給模型。

Hayashi等人在2025至2026年的研究中，把以ChatGPT為基礎的對話代理加入林業安全卡牌遊戲，擔任顧問。每張卡呈現一種可能發生在伐木現場的狀況與問題，由代理評估參與者的回答。學生和初學者的前後比較顯示，在40題工作場所安全量表中，安全溝通、個人安全等五個領域全都出現統計上顯著提升。然而，早期通用模型在回答燃料容器材質、鏈鋸磨利等林業專業問題時，給出了八次不相關的機械工程回答。加入林業安全知識卡、採用脈絡學習的客製模型，把這類回答減少到兩次。自動語音辨識還曾把chaps和kakarigi，也就是掛枝木等詞彙轉錄錯誤，因此研究人員提出標準確認程序。

Ehrlich-Sommer等人於2025年提出的ForestGPT，是一個對話原型，曾在奧地利Pötta Expo使用約1MB活動資料回答訪客問題。檢索增強生成、森林生長模擬，以及

感測器、無人機與機械資料整合，屬於後續開發階段。目前的原型並不是具備所有功能的完整現場模型。

被監視的感覺

在想像中的現場部署裡，辦公室螢幕會即時顯示多名伐木工人的風險等級，達到第4級時，警示會送到管理者手機。對安全管理而言，這是好事，但對戴著安全帽的人來說，感受並不相同。相機不需要在身體上安裝任何東西，卻會漏掉枝葉後方的工人；穿戴式裝置能穿越遮蔽持續工作，卻帶來汗水、電池和接受度負擔。通用語言模型能以多種語言靈活對話，卻可能因林業知識淺薄而產生幻覺。加入指定知識的客製模型可以減少錯誤，但遇到知識卡範圍外的問題，可能只會回答沒有資訊。無論只追求精準，或只追求靈活對話，都不夠。

實驗室分類與現場緊急煞車之間，仍存在根本缺口。在通訊中斷的森林中，把姿勢判斷或人員辨識連接機械控制，並完成整體驗證的案例仍很少。真實伐木現場必須把泥濘、低溫、網路中斷和不同機械的煞車距離放在一起測試。

持續拍攝也帶來資料治理問題：從安全帽感測器傳到公司伺服器的資料屬於誰、要保存多久、是否會被用於事故以外的目的？現有文獻尚未明確解決這些問題。辦公室工作的人工智慧監控爭議，一再指出安全資料可能在無聲無息中被挪作其他評估。

2026年5月，韓國國土交通部與國土安全管理院修訂智慧安全設備指引，把穿戴式相機等工人保護設備重新整理為三大類、七個中類。這是營建業指引；截至2026年8月，林業專用的對應版本仍未出現。

預期要支付相機、感測器和伺服器月費的企業，多半是規模極小的伐木業者。有些因無力負擔而延後導入；另一些雖能負擔，卻與工人爭論資料用途。遙控採伐機與自主集材機或許能把人移出危險坡面，但手持鏈鋸的人仍會留下。安全監控技術最終關係到的，正是這些留下來的工人。下一階段的提案包括使用Grad-CAM與SHAP建立可解釋人工智慧儀表板，顯示風險判斷所依據的身體部位，並透過知識蒸餾，把較小模型放進與網路中斷的山區終端。論文已提出整合相機、穿戴式裝置和語言模型的流程，用來預防WMSDs並及早發現事故。然而，這些系統何時會成為伐木作業標準設備，以及由誰保留影像和訊號、保存多久的規則，都尚未到來。風險評級與警示變得更加精密的速度，快過人們制定規則、決定可以把結果託付給誰的速度。

資料來源與參考文獻

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). FY2025 forestry and wood-industry work-safety promotion webinar, full version [video]. YouTube. <https://www.youtube.com/watch?v=Q1w9DxFpgE8> (accessed August 2, 2026)
10. Japan Forest Machinery Association. (2026). Part 3, FY2025 smart forestry machinery and new wood-based materials symposium [video]. YouTube. https://www.youtube.com/watch?v=uzSCOk_qQI8 (accessed August 2, 2026)
11. Ministry of Employment and Labor. (2026, March 31). Supplementary statistics on industrial accidents in 2025 (cumulative). https://www.moel.go.kr/news/enews/report/enewsView.do?news_seq=19159 (accessed August 2, 2026)
12. Ministry of Land, Infrastructure and Transport and Korea Authority of Land & Infrastructure Safety. (2026, May 6). Selection and use of smart safety equipment at construction sites becomes easier. <https://v.daum.net/v/20260506110012733> (accessed August 2, 2026)
13. Mechanical Equipment Newspaper. (2025, May 21). Asgard develops “TUGU,” a smart helmet tailored to construction workers. <https://www.kmecnews.co.kr/news/articleView.html?idxno=41084> (accessed August 2, 2026)
14. Security News. (2020, October 31). Wearable robots and intelligent helmets respond to forest disasters. <https://m.boannews.com/html/detail.html?idx=92245> (accessed August 2, 2026)

第5章

永續農林業與木材供應鏈數位轉型

5.1

農林業系統中的用水效率（WUE）與生態系服務最佳化

在印度北部旁遮普邦，清晨的陽光照到麥田時，穿過田中央的一排白楊樹開始緩緩移動樹影。每棵樹都超過20公尺高，早晨時樹影覆蓋田地西側的犁溝；中午退到樹腳下，傍晚又覆蓋另一側的犁溝。從土裡升起的熱氣像海市蜃樓般顫動，麥穗在初夏的風裡反覆低頭又挺起。在那片田裡耕作多年的農民知道，樹蔭走過與未走過的地方，麥子的顏色有細微差別。對農民來說，這些樹是有兩張面孔的鄰居。它們的根扎得很深，會吸走小麥也需要的水；但樹幹和葉子擋住熱風，將水分留在土中。光靠眼看，無法回答樹木是偷水者，還是保水的哨兵。這些白楊樹並非只為投下樹蔭而立。樹幹長粗後，可作為火柴、夾板或紙張的木材出售，因此同一塊地同時進行小麥耕作與樹木經營。答案要靠數字量測根部下方發生的事，以及每片葉子釋放多少水分。

在同一塊土地上同時種植樹木和作物，有時也飼養家畜，稱為農林業。樹根可能與作物爭水，卻也能透過樹蔭和落葉減少蒸發與土壤流失。以產量除以實際蒸散量所得的用水效率，是衡量這兩種作用結果的指標。聯合國糧食及農業組織廣泛採用的統計顯示，農業占全球淡水取水量超過70%。「消耗80%」和「取水超過70%」不是同一個指標。

在韓國，於農地種樹時的法定土地類別與是否符合公益型直接給付資格，取決於土地狀態、耕作方式以及相關計畫的要求。種下一棵樹不會自動把農地變成林地，也不會使農民失去給付資格。有意採行此方式的農民，應先向地方政府及國立農產品品質管理院確認該筆土地適用的要求。

根部下方的算術

農學家大致以兩種方法進行這項計算。第一種是把手伸進土地裡直接量測。將時域反射儀（TDR）和頻域反射儀（FDR）探針插入根部附近土壤後，設備會依土粒間水分傳遞電訊號的速度判定含水量。為取得這些數值，研究人員必須從清晨穿著靴子在田裡走動，插入探針。訊號會隨土壤狀況而改變，即使同一地點也要在數天內重複量測，才能得到可靠數值。再加入中子探針和自動氣象站，便能逐小時記錄樹根與作物根在同一土層共享多少水分。2026年一項小麥農林業系統性回顧指出，研究人員會把這些田間量測資料輸入CROPWAT、AquaCrop、APSIM等作物與土壤水分模型，模擬水分如何穿過各層根系。

這種親手量測無法覆蓋整片田地，於是衛星接手這項工作。可從Sentinel和Landsat等衛星影像取得標準化差異水體指數（NDWI，即分析植物葉片反射光波長以推估水分的指標）和地表溫度等數值。將這些數值輸入SEBAL或METRIC等蒸散模型，便能繪出田中哪些地方乾、哪些地方濕。再加入隨機森林，即由許多決策樹模型各自給出答案並以多數決定最終答案的機器學習方法，以及支援向量機、人工神經網絡和XGBoost等演算法，模型便能一併學習土壤條件、灌溉時程和樹蔭程度，預測用水效率。這項回顧發現，只調整修枝與樹蔭間距，就能透過減少林下作物表面的失水、增加灌溉水滲入地面的比例，顯著提高整個系統的水分效率。這項計算對農民的重要性很明白。灌溉時間或水量只要提前或延後一兩天，就可能大幅影響當年收成。在乾旱日益頻繁的時代，一滴水的價值已不同以往。

衛星繪製的農林業地圖

印度西岸果阿邦有一種名為kulagar的傳統耕作系統。檳榔樹與胡椒、可可或香蕉一起種植，分享樹蔭和濕度。走進一塊kulagar田地，頭頂是棕櫚葉形成的屋頂；下方胡椒藤纏上棕櫚樹幹，香蕉和香料作物長在腳邊。各層植物在不同高度分享水和陽光。光從衛星影像，很難區分這類田地、相鄰的純棕櫚園與天然林。Uthappa及其同事以Sentinel衛星影像運行隨機森林、梯度提升和支援向量機三種機器學習模型，處理這個區分問題。一般植被指數只顯示葉子有多綠，因而可能把灌溉良好的農林業田地與雨季過後的天然林混淆。因此需要採用另一種對水分敏感的指數。結果很清楚：直接反映樹木和作物葉片水分的水分指數NDWI2，在三種模型中都是決定田地分類精度的關鍵變數。梯度提升模型的精度為0.86，排除偶然一致的卡帕係數為0.83，分類結果是三者中最穩定的。

衛星能讀取作物與樹木交錯的田地，為希望擴大農林業的政策制定者提供了有用工具。他們不用逐一到每塊田目測，就能每年繪出指定地區農林業擴張的範圍。韓國的年度林業經營調查處理相近統計，但仍主要依賴農戶問卷和田野調查，似乎尚未建立以衛星地圖自動更新的系統。

精確計算咖啡樹的樹蔭

在印尼咖啡園，問題的問法稍有不同：為保護咖啡樹免受直射日光與水分壓力，上層應在何處種、種多少遮蔭樹？Ridlo及其同事採用源自圖論的RIDS演算法來處理這個配置問題。簡單說，它把田地看作點與點相連的網絡，計算樹木應種在哪裡，才能不讓遮蔭過度，且均勻覆蓋田地每個角落。

Ridlo及其同事把遮蔭樹與感測器位置以圖形方式計算。在96棵咖啡樹和26棵遮蔭樹的情境中，年二氧化碳固存量計算為520公斤；在31棵遮蔭樹呈格狀配置的情境中，數值為620公斤。這些是模型計算，不是在田間長期測得的碳量。

研究人員使用時空圖神經網絡，預測未來10至20天的相對濕度和二氧化碳濃度。依設定不同，解釋力介於0.73至0.81。這些結果來自模型比較，並非顯示咖啡農實際用這套系統安排灌溉、改善產量或用水的長期田間試驗。

水以外的生態系服務

生態系服務是自然無須人為介入所提供的益處，如森林、濕地和潮間帶所提供的功能。過濾乾淨水源、減緩洪水，以及維持蜜蜂和鳥類生存以協助下一代作物授粉，都屬於這個概念。農林業的好處不止於產量和用水效率。樹根防止雨水沖走土壤，落葉與樹蔭為鳥類和昆蟲提供棲身處。

Silva及其同事觀察巴西南部亞熱帶地區20年的衛星時間序列分析，為這種價值提供了數字。約在2000年，農林業占用的棲地面積略多於400公頃；到2020年，增至接近660公頃。同一時期，連接零散天然林的棲地聚合指數也上升。原本像碎片般散落在稻田和農地之間的天然林，開始沿著農林業帶重新連接。

這並不代表農林業能完全取代天然林。Doherty與Häger (2026) 利用遙測和田間資料，比較哥斯大黎加的天然林、咖啡農林業與牧草地農林業。地上碳儲存和樹種多樣性因土地類型而異。在天然林中，碳量豐富地點與樹種多樣性高地點的空間重疊率為25.5%。農林業可以增加耕作地的樹木和連通性，卻不能保證具備天然林的碳和生物多樣性價值。

Jemal (2026) 在F1000Research發表系統性回顧第1版，整理衣索比亞農林業中遙測和深度學習的研究趨勢。這不是在同一地點直接比較卷積神經網絡、U-Net和視覺Transformer的實驗論文。世界資源研究所則在迦納發表利用遷移學習區分天然林、單一栽培園與農林業的研究。若分類結果將用於政策，各類別的田間樣本與誤分類地圖應一併公開。

在印度，Chavan及其同事在印度醋栗樹下種植大豆的實驗顯示，即使在退化土壤，只調整遮蔭強度也能改變大豆的生理狀態和產量。Jinger及其同事展示一項實驗：將藥用與芳香植物樹木和保育土壤水分技術結合的林業芳香作物系統，能修復退化地的土壤結構並固存二氧化碳。藥用與芳香樹木未扎根前，退化土地遇雨常有泥水沿溝渠流失，旱季只揚起塵土。樹木與水資源管理設施一同設置後，同一塊地流失的土壤減少，雨水有更多時間滲入根系之間。這些在不同國家、使用不同樹種進行的研究指向同一方向：同時種植樹木和作物的土地可以固土、保水並儲碳。2022年一項回顧在土壤健康架構下整理這些個案，將農林業描述為少數能不依賴化學肥料而恢復土壤肥力的農業系統之一。

數字遺漏的部分

即使使用同一張衛星影像，模型有時也會給出不同答案。在果阿kulagar研究中，隨機森林和梯度提升模型估算的農林業面積大於支援向量機。前兩種模型對樹木與作物密集混合田地的複雜邊界，採取較寬鬆且非線性的判讀；支援向量機則傾向畫出保守邊界。只看單一衛星水分指數的模型，可以快速計算廣大區域的乾旱狀況，卻無法捕捉作物各生長階段的土壤水分變化。相反地，結合物聯網感測器和神經網絡的模型很精準，但也帶來安裝與維護感測器的成本。

衛星和無人機影像會把樹冠、作物與裸土的反射率混進一個10至30公尺的像素。想像一個衛星影像格同時包含樹頂、樹下陰影、土壤與作物：它反射的光，就像多種顏色已經混在一起的顏料。要電腦從這種混合色中分離出作物訊號，如同要從已混好的顏料還原原來每種顏色。農林業水分平衡與土壤碳變化至少要觀測10年才看得出模式，但目前多數深度學習研究只依賴數年短期資料，難以完整檢驗對氣候變遷的韌性。開發中國家的農地越偏遠，越可能同時缺乏物聯網感測器的資金和無線網絡，因此智慧水管理技術往往無法到達最需要它的田地。

麥田提出的問題，即樹木會取水還是保水，在歐洲中期天氣預報中心的計算中再次出現。2026年一項研究顯示，策略性選擇植樹位置的情境，能使蒸散量最多減少60%，地下水儲量最多增加三倍。這是模型情境，不是每一塊耕地都可保證的數值。

研究人員正在準備下一步：把物理定律與人工神經網絡結合。研究正嘗試把CROPWAT和APSIM等依物理方程建立的既有模型限制，整體放入稱為物理資訊神經網絡（PINN）的深度學習架構，讓系統可一併計算微氣候和水分，同時降低衛星混合像素造成的誤差。人們也在討論建立涵蓋乾燥區、亞熱帶和熱帶的開放資料集，並把以這些資料訓練的輕量AI模型裝入農民手機，即時提供灌溉時機。農民手機上的這個輕量模型，設想能在早晨傳來一則訊息，告訴他當天田地該在何時施多少水。在網路常中斷的山村，計算可在手機上完成，省去向伺服器傳送與接收訊號的時間。不過，這個願景仍較接近實驗室論文中的提案，經多年真實田間驗證的案例很少。

聯合國糧食及農業組織說明，印度的農場林業與農林業系統供應約93%的年度木材需求。這個數字指年度木材需求，不是所有木製品的國內消費。要擴大小農的樹木生產，必須同時關注樹苗、技術、市場進入機會，以及對土地和收穫物的權利。

資料來源與參考文獻

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 *Emblica 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, April 14). 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> (accessed August 2, 2026)
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., & Pocza, 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., Lorean, 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> (accessed August 2, 2026)
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> (accessed August 3, 2026)
13. Food and Agriculture Organization of the United Nations. (2026). AQUASTAT methodology: Water use. <https://www.fao.org/aquastat/en/overview/methodology/water-use> (accessed August 3, 2026)

5.2

以ICT為本的木材可追溯性（QR／電子標籤）與自動木材品質評估

Nakazawa及其同事的系統圖，顯示一條把收穫機量測的原木資訊傳送到伺服器的線路。收穫機量測直徑和長度，並以StanForD格式留下作業資料。把實體標籤、運輸紀錄與鋸木紀錄連接到這些資料，可為原木追溯系統提供設計方向。然而，引述的資料並沒有描繪一間會自動在每根原木上附加QR碼或RFID標籤的鋸木廠。

電子紀錄能迅速分享採伐位置和量測數值。讓紀錄一路與實際原木相連，則是另一個問題。標籤脫落，或原木被鋸成板材時，連結就可能中斷。

QR碼和RFID只是調出紀錄的鑰匙，本身不能保證原木身分。供應鏈可追溯性只有在採伐紀錄、實體標記、運輸交接、鋸切後的束材管理和現場稽核都具備時，才會成立。

木材流通過去依賴紙本傳票和手寫現場表單。由人輸入的數字可能有錯，而非法伐採的木材混入合法原木時，也難以篩出。韓國林務局曾以一年試行方式運作合法木材貿易促進制度，全面實施日為2019年10月1日。進口受管制木材和木製品的業者，必須在通關前證明木材在原產國為合法採伐。韓國林務局發布按國別編製的標準指引。收穫機感測器、電子標籤和人工智慧，是縮小文件審查落差的輔助手段。

刻在原木上的第二個名字

智慧收穫機進入採伐現場後，在伐倒樹木並加工成規定長度的同時寫入資料。裝在切割頭上的感測器每秒量測原木直徑、長度和樹幹彎曲的程度，衛星定位裝置則記錄準確的採伐位置。機器切下一棵樹的短暫瞬間，便完成了人們過去靠眼睛做的計算。

Nakazawa及其同事以StanForD為基礎，開發分享收穫機原木量測與品質判定結果的系統。其研究範圍是連接森林機械的生產與作業資料，並未涵蓋全日本的交易和結算系統。

僅靠收穫機資料，無法一路追蹤一棵樹。可以設計在原木附上條碼或RFID標籤、由下一家業者接收的流程。但結合收穫機自動貼標、端面年輪的三維指紋，以及區塊鏈比對的運作系統，尚未得到驗證。

RFID可不經接觸讀取識別號碼，但需要標籤成本和耐用性、附掛的人工，以及加工後的束材管理。單一標籤無法保證原木的來源或合法性。

如何計算載上卡車的樹木

量測集材場原木堆或運輸卡車所載原木的體積，長期以來是直接用手完成的工作。人們用捲尺量每根原木的直徑，再估算整堆材積。近年來，這項工作轉向智慧手機相機與iPad內建的LiDAR感測器。LiDAR透過發射光線並計算光線返回所需時間來量測物體距離，利用這個原理把原木堆輪廓繪成密集點雲。

Elias及其同事2025年的原型研究、Ucar及其同事在土耳其進行的試驗，以及Purfürst及其同事的比較研究，都以智慧手機照片和LiDAR估算原木堆體積。以影像量測可能縮短現場時間，但誤差會隨樹種、裝載配置和相機角度而變化。

卡車貨台中原木之間存在空隙。Niță及其同事評估一種演算法，利用LiDAR點雲估算載物外形和木材體積。這不是一項能毫無誤差地確定實際木材體積，或在檢尺站自動完成結算的研究。

若要把LiDAR估算用於交易，利害關係人必須反覆與基準量測比較，以設定容許誤差，並建立感測器校正和異議程序。演算法在試驗中的表現，不會自動成為付款結算的法律標準。

攝影機發現節疤的瞬間

進入鋸木廠的原木和板材，其價值最終由缺陷決定。同一棵樹，會因節疤多少、有無裂縫、顏色是否褪去而獲得不同等級。長久以來，這項判定交給分等人員的眼睛。即使熟練的人，一整天看板材後判斷也可能搖擺；不同人採用的標準略有差異，同一塊板材就可能得到不同等級。同一批原木在早上和下午由分等人員檢查，寫出不同等級表單的情況並不罕見。Sandvik及其同事2024年的文獻回顧指出，原木檢尺和分等方法約在2018年前後迅速轉向深度學習，取代其他機器學習方法。

Qiu及其同事在2026年介紹名為PADDL-YOLO的木材表面缺陷偵測模型。在測試資料中，精確率為91.5%，召回率為91.4%，mAP@0.5為95.0%，計算負荷比基線模型低25.6%。模型變輕，增加了部署到現場設備的可能性，但這不表示它已在鋸木廠輸送帶上以商業速度長期運作。

許多研究以不同路徑追求同一目標。He及其同事以全卷積神經網絡定位木材內部缺陷；Hwang及其同事則把遷移學習應用於影像辨識常用的ResNet-34神經網絡，以區分節疤種類。Urbonas及其同事用Faster R-CNN尋找單板表面缺陷。Longuetaud及其同事使用改良的YOLOv5s，Zhang與Zhao使用YOLOv7，即時偵測沿輸送帶移動板材的缺陷。Ozkan及其同事以2,972片山毛櫸層板訓練Mask R-CNN系列神經網絡以找出缺陷，準確率達90.90%。Hwang及其同事採取略有不同的方法，擷取節疤表面的紋理與局部形狀資訊，輸入人工神經網絡以區分健全、腐朽和脫落的節疤。方法不同，目標卻相同：用攝影機和神經網絡增加人眼一天能檢查的板材數量。

曾由分等人員整天盯看的板材，如今從攝影機前通過，人們只重新檢查機器標記為模糊的少數板材。畫面中有些板材會被黃色輪廓框起，這些是神經網絡沒有把握、交給人判斷的板材。分等人員現在可專注於這些篩選出的板材，而非整條輸送帶。工作不是消失了，而是人站的位置從輸送帶前移到螢幕前。

為何一張照片不能替木材定價

找出缺陷與評定市場價值等級，是不同工作。2026年，Triplat及其同事以斯洛維尼亞原木拍賣會的5,549張照片，比較市場價值等級分類模型。若干模型的整體準確率超過90%，但對低價等級的表現相對較弱。整體準確率很高，也可能掩蓋罕見等級的誤分類。

影像分類學習的是拍攝到的表面和資料集中的等級標籤。它無法直接判斷照片未呈現的因素，例如內部缺陷、含水率和強度。訓練資料中罕見的等級，會更受樣本不足影響。

市場價值判斷也可能包含照片以外的檢驗與交易條件。因此影像模型應用於輔助篩選，低信心和罕見等級仍應由人再檢查。

拍賣時等級一旦判錯，金錢立刻流動。高等級原木被誤判為低等級，林地主就拿不到應有價值；相反地，低等級原木若被當作高等級出售，買下它的鋸木廠可能要到鋸成板材後才發現損失。這就是自動評估系統仍要保留人工最終核對的原因。

PADDL-YOLO的mAP@0.5和Triplat研究中的分類準確率來自不同資料和不同任務，不能直接比較。表面缺陷偵測、市場價值分類和內部強度評估，必須各自驗證。

雨水抹去的，以及價格阻擋的

採伐現場的實體標記可能因泥土、雨水、撞擊和樹皮脫落而無法閱讀或掉落。RFID也可能因附掛方式和運輸衝擊受損。年輪的三維指紋尚未成為能解決這個問題的已驗證運作系統。標記耐久測試、交接紀錄和抽樣稽核都不可少。

二維攝影機的限制依然存在。表面影像無法捕捉樹幹內部正在進行的腐朽或隱藏裂縫，意外缺陷可能要到鋸切後才顯現。取得所有這些設備的成本，對小型鋸木廠和林地主是相當沉重的負擔。一次裝設高性能LiDAR掃描器、X光CT設備和現場AI電腦，需要龐大的初期投資，小型業者的門檻更高。國立森林科學院等有研究預算的機構或可試行導入，但對經營一座山的微型林地主或社區鋸木廠仍遙不可及。技術存在卻買不起時，用手量、用眼分等的老方法會持續下去。Forkuo與Borz在2026年針對林業作業中AI應用的回顧，也把木材可追溯性和品質評估列為收穫機械化之後成長最快的領域之一。

X光CT和聲學檢測，是用於辨識照片看不到內部缺陷的輔助工具。Nocetti及其同事把攝影測量和聲學測量並列用於橡木原木。區塊鏈研究提出讓多家業者共享同一紀錄、並檢查後續變更的方法。它無法消除最初輸入的虛假資訊、標籤替換，或真實原木與其紀錄之間的斷裂。遵循EUDR需要地理定位資訊、盡職調查、風險評估和文件保存一併到位。StanForD等作業資料標準和區塊鏈只是協助合規證據的工具，並不保證合規。

資料來源與參考文獻

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. Forestry Agency, Japan (林野庁). (2025, June 3). 令和6年度 森林・林業白書 [FY2024 White Paper on Forests and Forestry]. <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 [Development of a log information sharing system for harvesters equipped with an automatic log quality judgment device]. *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/for4153-016>

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. Korea Forest Service. (2019, September 18). Imports of timber will require proof of legality for customs clearance from October 1. https://www.forest.go.kr/kfsweb/cop/bbs/selectBoardArticle.do?bbsId=BBSMS TR_1036&nttId=3136493 (accessed August 3, 2026)

5.3

循環生物經濟與森林碳權

採伐結束後，枝條、樹皮和樹樁留在斜坡上。要把它們留在原地回歸土壤，還是切碎後運走作為燃料或材料原料，必須同時考慮野火風險、養分循環、運輸距離和加工需求。高含水率會增加運輸重量，卻可能降低燃料熱值。只按重量定價，可能使品質和能源效率失去對應。

可從木質殘餘物提取木質素和纖維素製成材料，符合規格的原木則可製成工程木材。不是每一根枝條和根部都具有經濟可行性，可作為原料。計算時必須扣除收集、乾燥、運輸和加工所需的能源，以及森林中必須保留的有機物量。碳權也只有在專案通過登錄、額外性、基線和查證要求後才會核發。

從殘餘物到新材料

樹木主要由三種物質構成：形成纖維的纖維素、填滿纖維間空隙的半纖維素，以及使樹木挺立、堅硬的木質素。長期以來，紙漿廠把木質素視為麻煩物。它只是混在提取紙漿後剩下的黑液裡的副產品，然後被燃燒或丟棄。日本森林綜合研究所（FFPRI）和環境省在2025年與2026年發布的資料顯示，透過重構木質素化學結構的改質木質素技術正在改變這個情況。經改變結構以耐熱、抗斷裂的改質木質素，可用於汽車零件、電子產品外殼和可生物分解樹脂的原料。把木材纖維解離至奈米厚度的纖維素奈米纖維（CNF），也日益用來取代石油基塑膠。改質木質素製成的零件，開始出現在汽車內飾和電子產品外殼等地方，光靠觸摸很難分辨木材和塑膠。

不能預先假定木質材料的溫室氣體排放必然低於石油基材料。原料來源、加工熱源、化學品、產品壽命、再利用和處置，都必須透過生命週期評估進行比較。循環生物經濟是一個尋求長期使用可再生生物資源，並讓其再次循環的架構。Wang及其同事把氣候智慧林業整理為一種連接人工智慧支援森林經營與氣候調適、減緩的方法。

種在城市裡的一座森林

讓碳長期留在木材中的一種方法，是用這些木材建造建築。交錯層壓木材（CLT）由紋理交錯的木板逐層膠合而成，膠合木用於柱與梁，這類工程木材即使取代混凝土或結構鋼，也足以建起相當層數的建築。以這種厚木材建造的中高層建築，稱為大型木構建築。日本林野廳和環境省正推進「森林之國、木之城市」政策，以木構造取代都市的鋼筋混凝土建築。走進木構工地，氛圍從一開始就與混凝土澆置不同。沒有預拌混凝土的噪音和粉塵，起重機從工廠吊起預裁木板，工人鎖緊螺栓。燒製混凝土和熔煉鋼鐵所排放的二氧化碳，從一開始就被減少；完工建築的骨架則保留樹木數十年甚至數百年吸收的碳。曾經長在山裡的樹，搬到城市中心，成為儲碳的第二座森林。

木構建築的氣候效益，出現在木材來自合法、永續經營的森林，採伐後森林碳得以恢復，且產品確實替代高排放材料的情況。建築需求增加，不會自動帶來造林與森林投資。供應鏈認證和森林經營規則必須創造這些條件。

優良樹木與輪伐採收

樹齡與碳累積，不能用一句話定論。全球資料顯示，大型單株樹木即使隨年齡增加，每年仍可能增加更多碳。林分單位面積的淨生產力可隨樹齡下降，但會因樹種、土壤、擾動和經營歷史而不同。並不存在適用所有森林的「30至40年達到高峰」。育種和基因組選拔可以縮短選出優良生長或木材性狀的時間，但生長改善的幅度也因樹種和試驗條件而異。

採伐是否有利於碳，不能只依固定輪伐年齡判斷。森林中殘留的碳、採伐和運輸的排放、木製品的儲存期間、混凝土和鋼鐵的替代效果，以及再造林是否成功，都必須放在同一個生命週期評估中。保育老齡天然林的選擇，與以輪伐方式經營生產林的選擇，會因森林功能和地方條件而有不同答案。大範圍種植速生品種時，病蟲害和遺傳一致性的風險也要一併計算。

計算碳的眼睛：衛星與人工智慧

伐採樹木作為材料後再造林的循環，是否有助於碳中和，必須用數字驗證。量測森林碳的變化、報告結果並由第三方確認的程序，稱為MRV。韓國森林碳抵換制度包含新造林與再造林、森林經營、木製品利用和森林生質能利用等專案類型。制度列出某種專案類型，不會讓一堆小樹枝立刻成為減排成果。它仍須通過登錄的方法學、基線、額外性、監測和查證要求。

地面樣本和遙測會一起用來量測移除量。GEDI沿軌道留下波形LiDAR樣本；兩顆Sentinel-2衛星在赤道附近約每五天重訪同一地點。單一Landsat衛星的重訪問隔約為16天。雲層會使實際可用的光學影像間隔更長。地面樣本是校準模型的錨點，衛星和LiDAR則是估算樣本間空間的眼睛。

Geng等人（2026）把黑龍江省天然林的長期調查資料、生態模型和氣候情境與知識引導機器學習結合。在低排放情境下，預測2060年的碳儲量介於1,379.26太克至1,439.02太克。這是模型預測，不是已觀測到的未來。

Keskes與Niță（2026）把芬蘭多源國家森林清查資料加入以羅馬尼亞田間資料建立的模型。研究對象不是碳地圖，而是芬蘭立木材積的預測。解釋力從0.483升至0.718。Lamahewage及其同事對美國混合林的研究顯示，結合多種遙測資料集可以改善地上生物量估算。由於各研究的目標變數與驗證區域不同，不能把一個模型的數字移用到另一國的碳地圖。

膨脹的數字與信任問題

Swinfield等人（2026）將截至2020年已核發碳權的REDD+專案中約45%，與六項獨立評估結果比較。相關集合包括44個專案。所有核發量合計的過度核發比例為10.7倍，這個數字受到幾個大型專案推高。典型專案的中位數為4.1倍。許多專案確實減少毀林的結果，和基線被高估的結果同時出現。「專案失敗」與「專案核發的碳權多於其績效所能證明的數量」不是同一種說法。

Verra的VM0048提供以司法管轄區毀林風險資料分配基線的架構。該方法學中的10年是歷史參考期間，6年是基線的適用期間。它不是把相同的重新計算週期從10年縮短成6年。數位MRV可以協助資料收集和稽核，卻不會自動解決基線選擇或利益衝突。

若國家森林清查樣區公開座標出於安全原因被位移，直接與10公尺衛星像素配對，就會產生位置誤差。新木質材料的氣候效益，也必須從原料開採、化學品和熱源，計算至產品壽命和處置的完整生命週期。製造過程中消失的效果，不能當作固定比例處理。《巴黎協定》第6.4條下已有方法學和標準，但自願市場與國家減緩成果之間的互通性，以及防止重複計算，尚未完成。

原始老齡林是重要碳庫，大型單株樹木可以持續累積碳。在生產林中，可一併考量採伐木材的儲存與材料替代效果。哪一種選擇有利氣候，取決於森林類型、採伐強度、更新速度、產品壽命、加工排放和被替代的材料。凡是把所有森林都在30至40年採伐的規則，或禁止一切採伐的規則，都不能取代這項計算。

若把採伐位置和材積、木製品生產、建築的材料規格，以及新材料製程的生命週期資料連接起來，就能從森林到產品建立碳帳本。能追蹤到某面特定牆壁所用每一棵樹的整合數位孿生，目前較接近設計目標，而非正在運行的系統。


防止同一減排被重複計算，需要唯一識別碼、登錄系統間的協調、所有權規則、註銷紀錄與獨立查證。區塊鏈或物理資訊神經網絡本身，都無法從結構上解決這個問題。

資料來源與參考文獻

1. Carbon Market Watch. (2026). Quality assessment of REDD+ carbon credit projects.
<https://carbonmarketwatch.org/publications/quality-assessment-of-redd-carbon-credit-projects/>
(accessed August 2, 2026)
2. Carbon Pulse. (2026). Digital MRV could strengthen carbon credit integrity but data quality concerns persist, ICVCM survey says. <https://carbon-pulse.com/491240/> (accessed August 2, 2026)
3. Forestry and Forest Products Research Institute, Forest Research and Management Organization. (2025, September 3). 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 [Announcement of the 2025 FFPRI public lecture, “Forests in 2050: What roles will forests play in a society with a declining population?”].
<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. Ministry of the Environment, Japan (環境省). (2025, February 18). 地球温暖化対策計画 [Plan for Global Warming Countermeasures]. <https://www.env.go.jp/content/000291618.pdf>
8. Saha, R., Bagchie, P., Lalremasang, 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. Korea Forest Service. (2026). Forest Carbon Offset Scheme.
https://www.forest.go.kr/newkfsweb/html/HtmlPage.do?pg=/fcm/UI_FCS_111000.html&mn=KFS_02_10_11_10&orgId=fcm (accessed August 2, 2026)
12. Korea Forestry Promotion Institute. (2026). Operation of the Forest Carbon Offset Scheme.
https://www.kofpi.or.kr/intro/bizGuide_04_02.do (accessed August 2, 2026)
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/> (accessed August 3, 2026)

請支持本書

如果本書對您有所幫助，歡迎透過 PayPal 支持後續翻譯、
公開版本製作與開放的 AI 知識計畫。



PayPal

<https://paypal.me/kimkjkj>

請掃描 QR 碼，或開啟上方連結。