



**2025 | 16-20**  
**GIJÓN | JUNIO**

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1766**

Actas del Noveno Congreso Forestal Español  
Edita: **Sociedad Española de Ciencias Forestales. 2025.**  
ISBN: **978-84-941695-7-1**

Organiza





## Förecast 3.0: uso combinado de sensores remotos, modelización e IA para el inventario forestal continuo

ALONSO PONCE, R. (1,2), PÉREZ-RODRÍGUEZ, F. (1), ANTÓN, J. (1), CAMPANARIO, A. (1), LIZARRALDE, I. (1)

(1) Fora Forest Technologies SLL.

(2) Instituto Universitario de Investigación Gestión Forestal Sostenible iuFOR.

### Resumen

El inventario forestal continuo es una herramienta clave para la gestión sostenible y operativa, en términos ecológicos y económicos, de los bosques. Con el avance de tecnologías como los sensores remotos, productos como **Förecast** (<https://forecast.fora.es>) ya ofrecen inventarios forestales precisos y actualizados en tiempo real a partir de datos LiDAR.

En este trabajo se presentan los últimos avances en el desarrollo del nuevo Förecast 3.0, que ya integrará en una única herramienta los tres elementos fundamentales que han de conformar un inventario forestal continuo: identificación de especies, detección de cambios forestales y cálculo de existencias. Los dos últimos ya están plenamente operativos de manera independiente, mientras que el primero de ellos se encuentra en fase de prototipado.

Förecast 3.0 combina información LiDAR con imágenes satelitales multiespectrales de Sentinel-2 y modelos de inteligencia artificial para estimar biomasa, volumen de madera y otros muchos parámetros forestales de interés. Para lograr esta integración, Fora ha generado, a partir de las imágenes de Sentinel-2 y con algoritmos propios, mosaicos libres de nubes y neblinas con granularidad mensual, y con resolución de 10 m en todas sus bandas mediante algoritmos de super resolución. Además, para la identificación automática de especies, se han utilizado modelos CNN, ResNet y LSTM.

### Palabras clave

LiDAR, Sentinel-2, existencias, crecimiento, clasificación supervisada.

#### 1. Introducción

Un inventario forestal continuo (IFC) es un sistema de recopilación y análisis de datos sobre la estructura, composición y dinámica de los bosques que se realiza de manera periódica o en tiempo real. Su objetivo es proporcionar información detallada y actualizada que permita la toma de decisiones informadas para la gestión, conservación y aprovechamiento sostenible de los recursos forestales. Estos inventarios emplean una combinación de datos de campo, sensores remotos y algoritmos de modelización para generar estimaciones de multitud de variables de rodal o incluso de árbol, tales como biomasa, volumen, distribución diamétrica, especies y, por supuesto, cambios en la cobertura forestal.

Para que un sistema pueda ser considerado como un inventario forestal continuo,



debe cumplir dos características críticas: *actualización* y *escalabilidad*. La primera, obviamente, se refiere a que los resultados deben proporcionarse de la manera más actualizada posible (a ser posible, en tiempo real o casi real), para reflejar las dinámicas forestales, mientras que la segunda alude a que debe ser aplicable a diferentes escalas espaciales, desde parcelas locales hasta áreas regionales o nacionales. Tradicionalmente, los IFC se han realizado mediante la remediación de parcelas permanentes con un diseño estadístico apropiado (LETOURNEAU, 1966); ejemplos de ello son los inventarios forestales nacionales que vienen proporcionando, desde hace décadas, estadísticas nacionales sobre los bosques de multitud de estados, entre ellos, España (Bravo et al. 2002). Este método implica intrínsecamente una incertidumbre espacial y otra temporal: por un lado, cada vez que se remiden las parcelas es posible conocer con precisión las características del bosque en el lugar en el que éstas se ubican, pero hemos de inferir estadísticamente lo que ocurre en el territorio donde no se ubican parcelas, siendo éste normalmente un porcentaje altísimo de todo el área de interés. Y, por otro lado, en el lapso de tiempo que transcurre entre una medición y la siguiente tampoco es factible conocer la evolución del bosque y es necesario acudir a técnicas de modelización para *rellenar* ese periodo de la manera más precisa posible. Como es lógico, cuanto mayor sea la distancia temporal entre dos tomas de datos de campo consecutivas, más error se comete en la predicción, a igualdad de otros factores.

Con el desarrollo casi explosivo, durante las últimas décadas, de tecnologías basadas en diferentes sensores remotos, cada vez más precisas, tanto espacial como temporalmente, y a un coste día a día más reducido, se está produciendo una auténtica revolución en la manera de abordar la tarea de la medición, en su sentido más amplio, de los bosques y otros ecosistemas forestales (FASSNACHT et al. 2024). La utilización de este tipo de datos, unido a los avances asombrosos en técnicas de inteligencia artificial (IA), están ya permitiendo el desarrollo de sistemas que calculan una plétora de variables forestales fundamentales tanto para la gestión como para la planificación, en tiempo casi real (RODRÍGUEZ-PUERTA et al. 2021).

A pesar de ello, siguen existiendo discrepancias entre el potencial que los sensores remotos pueden aportar a la medición y monitoreo de los bosques y lo que finalmente aterriza en el mundo real de la gestión de los montes, debido a múltiples factores, tanto tecnológicos como sociopolíticos, y que además son dependientes de la región o estado de que se trate (WULDER et al. 2007).

Existen actualmente multitud de sistemas o plataformas que brindan la oportunidad de obtener en tiempo real diversos productos cartográficos y alfanuméricos relacionados con atributos forestales (p.ej. <https://forestmap.eu/es/> o <https://www.planet.com/products/forest-carbon/>), pero hasta donde nuestro conocimiento alcanza ninguna de ellas integra los tres ejes sobre los que se debe articular una herramienta que sea plenamente operativa para la obtención de inventarios forestales automáticos, multiescalar y en tiempo real: identificación de especies, cálculo de existencias y seguimiento de cambios. La plataforma Förecast ([www.forecast.fora.es](http://www.forecast.fora.es)), desarrollada por Fora y operativa (TRL9) desde 2019,



incluye los dos últimos ejes pero no integrados entre sí, pero que en el momento de redactar esta comunicación está en fase de periodo de pruebas la versión 3.0, que fusiona ya los dos últimos ejes mencionados y el primero de ellos se encuentra en fase de prototipado.

## 2. Objetivos

El objetivo de esta comunicación es presentar los últimos avances del nuevo Förecast 3.0, una herramienta operativa desde hace 5 años y que ya incorpora los tres ejes sobre los que deben desplegarse los IFC en tiempo real, con el fin de dar a conocer sus capacidades, ventajas e inconvenientes, así como los desarrollos planificados a futuro.

## 3. Metodología

La idea central que orienta Förecast es la de que debe servir para que el usuario (gestor forestal, propietario, empresa privada, etc.) pueda obtener inventarios forestales, asistidos por sensores remotos, sin tener conocimientos profundos de estos últimos, en cualquier ubicación, actualizados y en tiempo (casi) real, es decir, IFC. Se parte de la hipótesis de que el usuario necesita obtener una serie de parámetros forestales, que pueden implicar a numerosos y variados atributos en función de sus objetivos, en un área de la que posiblemente conozca sólo sus límites. Obviamente, si el usuario dispone de más detalles (especies, datos dendrométricos de campo, etc.), el sistema le permitirá utilizarlos para mejorar la calidad de las predicciones.

Así pues, para hacer operativa la herramienta, resulta imprescindible ser capaces de responder a tres preguntas clave, qué, cuánto y cuándo, y que están relacionadas directamente con los tres ejes mencionados más arriba:

- Qué: alude a conocer cuáles son las *especies* que pueblan el área de interés (AOI). Este aspecto es crítico no sólo por su interés intrínseco, sino también porque las otras dos preguntas dependen de esta primera para poder obtener predicciones fiables.
- Cuánto: se refiere a conocer las *existencias*, en su sentido forestal más amplio. Es decir, poder estimar con una precisión suficiente tanto las variables de rodal *clásicas* imprescindibles para la gestión (densidad, área basimétrica, altura dominante, volúmenes en pie, etc.) como otras que ya resultan ineludibles en cualquier plan de gestión (biomasa, carbono, carga de combustible, densidad aparente de copa, etc.).
- Cuándo: alude al aspecto dinámico del sistema, es decir, que resulta imprescindible conocer la evolución temporal de los dos ejes anteriores, principalmente el segundo, ya que en los ecosistemas forestales no son comunes las sustituciones súbitas de especies.

Estos tres ejes se organizan en Förecast 3.0 mediante sendas herramientas (Tabla 1) cuya arquitectura y funcionamiento se detallan más abajo. Aunque el orden



lógico de exposición debería ser el que aparece en la Tabla 1, se ha considerado óptimo dejar en último lugar la primera herramienta, ya que se encuentra en fase de prototipado.

Tabla 1. Ejes del IFC en Förecast 3.0 y herramientas asociadas

Pregunta	Eje	Herramienta	Estado
Qué	Determinar la(s) especie(s) que pueblan el AOI	Identificador de especies	Prototipado
Cuánto	Estimación precisa de los atributos forestales	Cálculo de existencias	Operativa
Cuándo	Conocer la evolución temporal de los otros dos ejes	Control de cambios	Operativa

En la Figura 1 se muestra el esquema de la arquitectura general de la parte de la plataforma dedicada a la ejecución de IFC. En líneas punteadas se presentan los elementos del sistema aún no operativos.

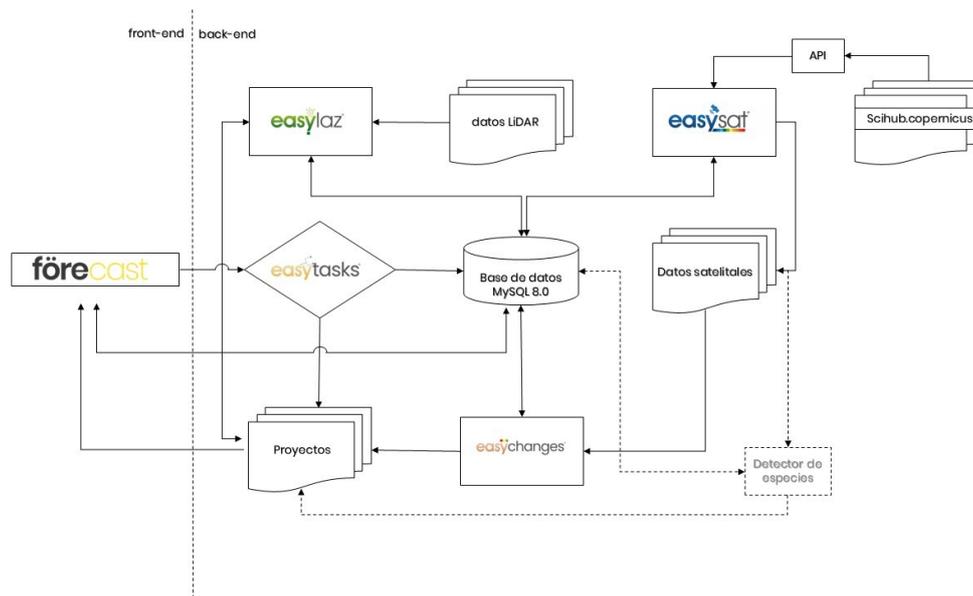


Figura 1. Arquitectura general de la plataforma Förecast. En línea discontinua, los elementos en fase de prototipado.

### 3.a. Cálculo de existencias

Esta herramienta está diseñada para ejecutar automáticamente inventarios forestales con tecnología LiDAR por métodos de masa (ABA, *area based approach*, en su acepción anglosajona) (Næsset 2002), es decir, genera cartografía espacialmente explícita y continua para todo el AOI con predicciones de un gran número de



variables de interés para la gestión forestal (ver apartado 4.1), a una resolución dada (habitualmente, de 20 o 25 m de tamaño de píxel).

El volumen de datos que se maneja en un inventario forestal ABA es enorme. Además, dado que la vocación de Förecast es posibilitar su utilización en cualquier localidad de España (aunque su arquitectura permite teóricamente su uso en cualquier punto del planeta), solamente con la información procedente de las dos primeras coberturas del PNOA (2022) ya se alcanzan en torno a 9 Tb de memoria de almacenamiento. Por ello, con el fin de manejar eficientemente esta cantidad de datos, cada archivo de nubes de puntos LiDAR (en formato \*.laz) se registra junto con sus metadatos en una base de datos, incluyendo los límites del área definida por la nube de puntos. Este primer registro posibilita conocer fácilmente qué archivos deben ser empleados en un AOI al ser solicitado por el usuario.

La transformación de las nubes de puntos LiDAR en variables útiles y operativas para las técnicas de modelización implicados en los inventarios forestales ABA es un proceso complejo que es resuelto en Förecast con easyLaz® (ALONSO PONCE et al. 2018), una aplicación autónoma desarrollada por Fora y basada en el ecosistema FUSION/LDV (MCGAUGHEY, 2021) para el procesado masivo de archivos LiDAR.

El flujo de trabajo para el cálculo de existencias incluye múltiples etapas, que son gestionadas mediante un servidor de entrada que es implementado como balanceador de tareas (easyTasks®), también desarrollado por Fora, el cual envía la información básica necesaria (datos vectoriales de entrada, datos de campo si existen, archivos laz, etc.) a las aplicaciones necesarias (easyLaz, scripts de R, etc.) en un procedimiento multitarea. Dichas etapas son:

1. Procesado de las nubes de puntos LiDAR: se determinan los archivos laz necesarios para el AOI solicitado, se calculan el modelo digital del terreno, la nube de puntos con alturas normalizadas, y las métricas LiDAR.
2. Si el usuario no ha facilitado datos de campo, se pasa directamente a la etapa 3. Si sí están disponibles, dichos datos son procesados en la plataforma y con ellos se ajustan automáticamente nuevas ecuaciones LiDAR (o se calibran las ya existentes en la plataforma), es decir, expresiones matemáticas que predicen variables de rodal a partir de métricas LiDAR. En este último caso, la plataforma brinda además la posibilidad de ejecutar el diseño de muestreo óptimo para el AOI.
3. Cálculo de inventarios forestales ABA para cada vuelo y lote disponible en el AOI. Si se utilizan ecuaciones preexistentes en la plataforma el procedimiento se denomina *Inventario LiDAR sin datos de campo*, mientras que si se ajustan o calibran nuevas ecuaciones se denomina *Inventario LiDAR con datos de campo* o *Inventario LiDAR con calibración*, respectivamente.
4. Unión de todos los inventarios calculados, asegurando la coherencia y continuidad cartográfica de todos ellos.
5. Cálculo de crecimientos, si hay más de una fecha de escaneo LiDAR disponible.
6. Agregación a nivel de unidad de gestión (rodal, subrodal, cantón, etc.) de



- los cálculos de todas las variables dasométricas modelizadas.
7. Depuración de archivos y entrega al usuario en formato comprimido.

### 3. b. Control de cambios

Esta herramienta resuelve de manera automática el análisis espacio-temporal para la localización y delimitación de perturbaciones (cortas, claras, derribos, incendios, etc.) basándose en índices espectrales calculados a partir de las imágenes procedentes de la constelación Sentinel-2 del programa Copernicus de la ESA.

Debido a la gran cantidad de información que provee la ESA y su actualización cada 5 días, se hace necesario el desarrollo de un gestor que automatice la descarga y la organice de manera eficaz. Por ello, Fora ha desarrollado easySat@ (PÉREZ-RODRÍGUEZ et al. 2019), un programa de ordenador de escritorio en entorno Windows para realizar las descargas masivas, organización y almacenado de productos de la ESA, en concreto productos de imágenes Sentinel-2 (dos satélites: 2a y 2b). De esta manera es factible disponer de la información para postprocesos de manera rápida y eficaz, conjugando API de descarga, almacenamiento en discos NAS y base de datos.

EasySat 1.0 ha sido desarrollado en Visual Studio community en lenguaje de programación C#. Para grabar las opciones y scripts se utiliza el formato estándar XML, el cual es leído y escrito en el directorio donde se disponga el ejecutable. El *framework* de compilación ha sido la versión: 4.7.1. EasySat 1.0 se conecta a MySQL 8 a través de la librería MySQL.Data en su versión 6.10.6.0. Además, easySat utiliza dos programas externos para la llamada a los APIs que la propia ESA ofrece de manera gratuita en su repositorio del programa Copernicus: <https://scihub.copernicus.eu>. Estos son el curl.exe 7.59.0 (Licencia GPL) y el wget.exe 1.11.4 (GNU General Public License).

Paralelamente, otros dos desarrollos creados por Fora resultan imprescindibles para satisfacer los niveles de calidad exigidos por los usuarios. En primer lugar, se aplica a cada imagen Sentinel-2 una adaptación de la red neuronal convolucional DSen2 (Lanaras et al. 2018) para alcanzar una resolución espacial de 10 m en todas las bandas de Sentinel-2, y de esta manera tener una visión mucho más precisa espacialmente de la respuesta espectral de la vegetación. Y, en segundo lugar, se utiliza la adaptación de la red neuronal convolucional HRNet+OCR (Wang et al. 2021) para generar mosaicos mensuales libres de nubes y neblinas de las imágenes de Sentinel-2. Este desarrollo supera notablemente el desempeño del algoritmo Sen2Cor de la ESA, lo cual es particularmente útil para las zonas con una dinámica forestal más acelerada como son Galicia y la Cornisa Cantábrica, precisamente en las que el número de días con nubosidad es muy elevado.

Una vez obtenidas las imágenes mensuales libres de nubes y neblinas, con todas las bandas a 10 m de resolución, el procedimiento para la delimitación de las cortas se basa en el principio de que *una corta supone una disminución rápida*,



*persistente y no recurrente de los índices de vegetación relacionados con el vigor.* Siguiendo este principio se ha desarrollado un algoritmo de series temporales que resultan en polígonos que delimitan las áreas de perturbación, con siete niveles de probabilidad: (1) *sin aviso*, (2) *1er aviso temprano (muy alta probabilidad de falso positivo)*, (3) *2º aviso temprano (alta probabilidad de falso positivo)*, (4) *corta probable (probabilidad de falso positivo)*, (5) *corta muy probable*, (6) *corta delimitada*, (7) *corta anteriormente ya detectada*.

Por últimos, estos polígonos etiquetados como *corta delimitada* se intersecan con los productos generados en la herramienta *Cálculo de existencias* para corregir las desviaciones en la predicción fruto de las perturbaciones acaecidas después del último escaneado LiDAR.

### 3.c. Identificación de especies

Esta última herramienta, aún en fase de prototipado, utiliza de forma efectiva algoritmos de aprendizaje supervisado (entre ellos, redes convolucionales simples, *ResNet* y múltiples *Long Short Term Memory*, utilizando las predicciones de cada una de ellas en un modelo conjunto) para resolver el problema de clasificación de especies a partir de imágenes de la misión Sentinel-2 del programa Copernicus de la ESA. La verdad terreno para entrenar estos algoritmos se está extrayendo de las bases de datos del Cuarto Inventario Forestal Nacional (IFN4).

El preprocesado de las imágenes de Sentinel-2 es el mismo que en el Control de cambios, por lo que los productos generados allí (imágenes mensuales libres de nubes y neblinas a 10 m de resolución en todas sus bandas) son utilizables directamente en esta herramienta.

Las etapas necesarias para alcanzar resultados satisfactorios actualmente en desarrollo son:

#### 1. *Construcción, entrenamiento y selección de los mejores modelos.*

Para abordar el problema de clasificación, se emplean tres tipos distintos de modelos:

- Modelos basados en Redes Neuronales Convolucionales sencillas (CNN).
- Modelos basados en *ResNet* (convolucional con conexiones residuales).
- Modelos basados en LSTM (*Long Short-Term Memory*), que es un tipo de red neuronal recurrente (RNN).

En cada área de interés es imprescindible probar diferentes parametrizaciones, cambiando la composición de sus capas, su profundidad o añadiendo métodos de optimización, seleccionando aquella que obtenga mejor valor de precisión en el conjunto de validación.

Las predicciones que devuelve cada modelo son el porcentaje de probabilidad de que una observación dada sea cada una de las clases (especies) previstas. A partir



de estos valores se puede obtener la clase predicha extrayendo la que obtuvo el mayor porcentaje.

Una vez que se obtiene la mejor versión de cada uno de los tres, se crea un modelo conjunto, que combina las predicciones de cada uno, y devuelve una predicción final. Esta combinación se aborda de dos maneras diferentes. Por un lado, con una media de las probabilidades para cada clase obtenidas por los 3 modelos y, a partir de esas medias, considerando como clase predicha la que haya obtenido el mayor valor de probabilidad. Por otro lado, se obtiene la clase predicha por cada modelo a partir de sus probabilidades, y cada modelo “vota” su clase, siendo la clase predicha por el modelo conjunto la que haya obtenido la mayoría de votos.

El modelo conjunto devuelve ambos grupos de resultados, los obtenidos por media y los obtenidos por voto, como salida final.

### 2. Evaluación de la eficacia de los modelos.

Para comprobar la eficacia en la predicción de los modelos seleccionados se tienen en cuenta cuatro métricas:

Exactitud/Accuracy:

$\text{observaciones\_clasificadas\_correctamente} / \text{observaciones\_totales}$

Precisión:

$\text{observaciones\_clasificadas\_correctamente} / (\text{observaciones\_clasificadas\_correctamente} + \text{falsos\_positivos})$

Recall:  $\text{observaciones\_clasificadas\_correctamente} / (\text{observaciones\_clasificadas\_correctamente} + \text{falsos\_negativos})$

F1-Score:  $2 \cdot \text{Precisión} \cdot \text{Recall} / (\text{Precisión} + \text{Recall})$

### 3. Optimizaciones.

Para mejorar la capacidad predictiva de los modelos se están prototipando las siguientes optimizaciones:

- Introducir capas de normalización entre las convolucionales y las de agrupación en los modelos CNN y dentro del bloque residual después de sus capas convolucionales en los modelos *ResNet*. Estas capas de normalización se implementan con *BatchNormalization* de *Keras* en Python y sirven para evitar el sobreajuste y promover la generalización de los modelos.
- *Dropout* del 50% en las capas totalmente conectadas del final de los modelos. Esto hace que en el entrenamiento se desactiven la mitad de los nodos de dichas redes aleatoriamente en cada iteración y así se fuerza al modelo a no confiar excesivamente en un conjunto de nodos que de buenos resultados en entrenamiento, mejorando la capacidad de generalización del modelo y la obtención de buenos resultados con datos de prueba fuera del conjunto de entrenamiento.
- Aplicar técnicas de clasificación supervisada jerárquica, esto es, entrenar conjuntos de modelos a diferentes problemas de clasificación partiendo de las situaciones más sencillas hasta llegar a las más complicadas (p.ej., partir de clasificar caducifolio-perennifolios para, en distintas etapas, al final llegar a diferenciar hayas de cualquier otro planifolio caducifolio)

#### 4. Resultados

En este apartado se presentan, muy resumidamente, ejemplos de salidas ofrecidas por la plataforma con sus diferentes herramientas, de manera individualizada para una mejor comprensión.

##### 4.a. Cálculo de existencias

A continuación se muestra un ejemplo de procesado de unas 2600 ha (Figura 2), así como los tiempos de procesado necesarios (Tabla 2) para obtener resultados en los servidores dedicados de la plataforma (instancia de 8 CPU y 16 Gb de RAM). Las dos etapas más exigentes en procesado son el procesado de los inventarios parciales y el cálculo del crecimiento. No obstante, en total se necesitaron menos de 3 h para acabar el proceso.

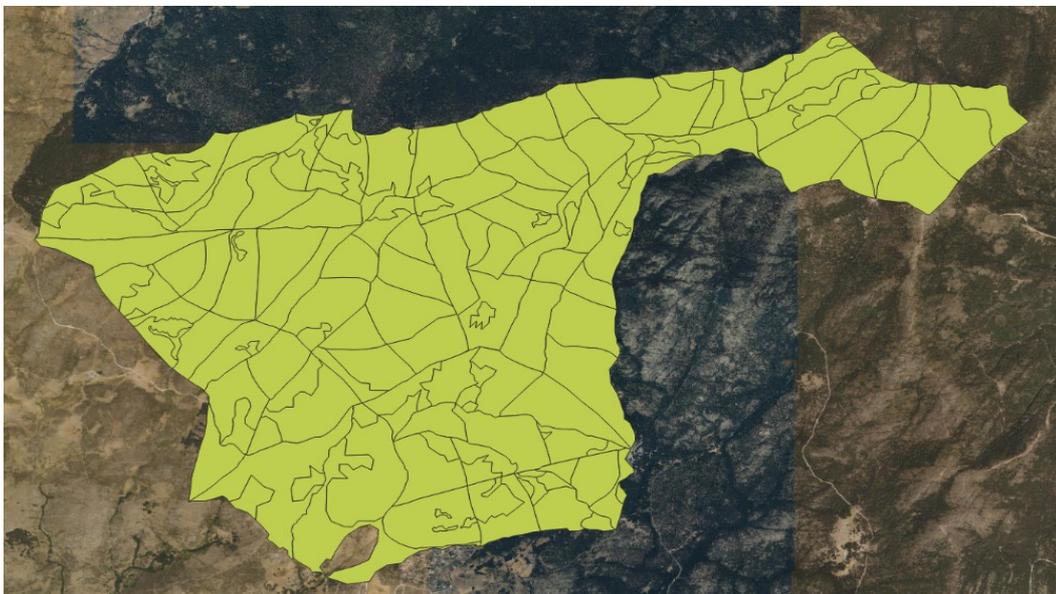


Figura 2. AOI de ejemplo (2600 ha).

Tabla 2. Tiempos de procesado en Förecast para el ejemplo considerado

Etapa	Tiempo
Procesado LiDAR e inventarios parciales	1:27:20
Unión de inventarios	0:05:47
Cálculo de crecimientos	1:10:22
Agregación por unidades de gestión	0:04:00
Compresión de resultados	0:00:05
<b>Total</b>	<b>2:47:34</b>

En la Figura 3 se expone un ejemplo de la cartografía obtenida tras resolver el inventario forestal. En cada una de sus celdas, así como en cada unidad de gestión para las que se haya solicitado la agregación de resultados, la plataforma devolverá un elevado número de variables dasométricas, tal y como se detalla en la Tabla 3.

En caso de que se trate de un inventario con datos de campo o con calibración, la plataforma devuelve además la expresión algebraica de todas las ecuaciones ajustadas, así como la bondad del ajuste, numérica y gráfica, de todas ellas. Si se trata de un inventario sin datos de campo (es decir, empleando ecuaciones LiDAR preexistentes en la plataforma), únicamente se devuelve la diagnosis numérica de las ecuaciones utilizadas.

*Tabla 3. Variables dasométricas o de rodal que puede devolver la plataforma al solicitar un inventario forestal. El conjunto de variables disponibles dependerán de la especie y el AOI.*

Variable	Descripción	Ud
N	Densidad de pies	árboles/ha
G	Área basimétrica	m <sup>2</sup> /ha
DG	Diámetro medio cuadrático	cm
HO	Altura dominante	m
IS	Índice de sitio	m
VCC	Volumen con corteza	m <sup>3</sup> /ha
VSC	Volumen sin corteza	m <sup>3</sup> /ha
IAVC	Incremento anual del volumen con corteza	m <sup>3</sup> /ha/año
VLE	Volumen de leñas	m <sup>3</sup> /ha
W	Biomasa anhidra del estrato arbóreo	t/ha
CARB	Stock de carbono del estrato arbóreo	t/ha
CO2	Stock de CO2 del estrato arbóreo	t/ha
IA_CARB	Incremento anual del stock de carbono en madera	t/ha/año
IA_CO2	Incremento anual del stock de CO2 en madera	t/ha/año
B_W3	Parámetro de escala de la función Weibull triparamétrica para la distribución diamétrica	-
C_W3	Parámetro de forma de la función Weibull triparamétrica para la distribución diamétrica	-
CFL	Carga de combustible disponible	kg/m <sup>2</sup>
HCB	Altura de la base del dosel de copas	m
DAC	Densidad aparente de copa	kg/m <sup>3</sup>

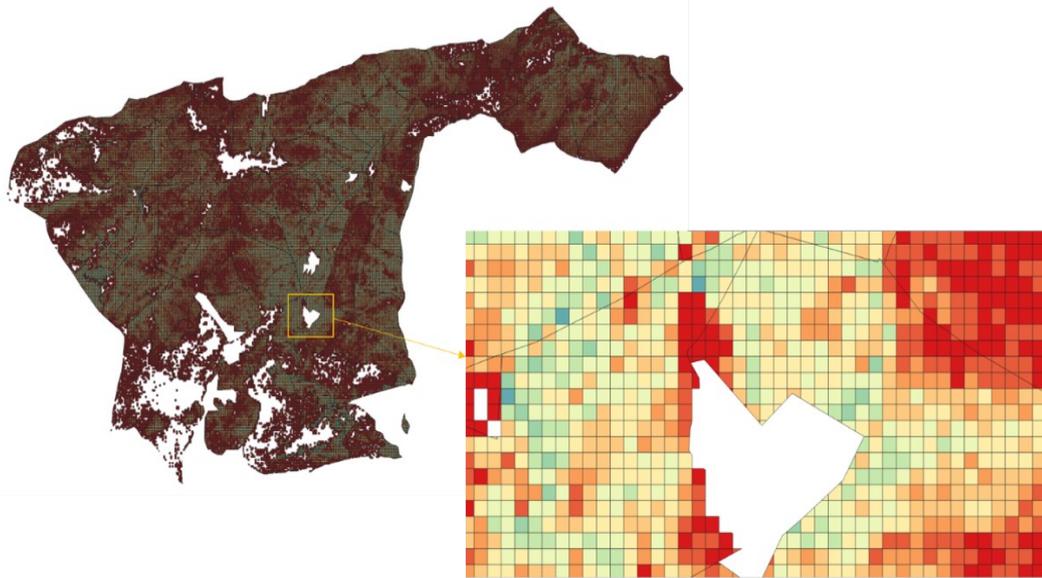


Figura 3. Ejemplo de cartografía resultante del proceso de inventario LiDAR.

#### 4.b. Control de cambios

En la Figura 4 se expone un ejemplo de detalle de la salida producida por la herramienta de control de cambios, para enero de 2025, tal y como puede consultarse en el visor disponible en la propia plataforma. Puede observarse cómo la mayor parte del territorio es identificado como “sin aviso”, es decir, no se detecta cambio alguno, mientras que se facilitan diversos polígonos con niveles crecientes de probabilidad de corta. Los polígonos azules (“corta delimitada”) son los que serán cruzados automáticamente con el inventario LiDAR generado en la herramienta correspondiente, con el fin de proporcionar estimaciones actualizadas de existencias. Las zonas sin datos (transparentes) se corresponden con aquellos píxeles en los que los algoritmos de generación de imágenes libres de nubes no han encontrado suficientes datos válidos para el mes analizado.



Figura 4. Ejemplo de cartografía resultante del proceso control de cambios.

#### 4.c. Identificación de especies

Como ya se ha comentado, esta herramienta aún está en prototipado, por lo que no podemos ofrecer ejemplos disponibles en la propia plataforma. No obstante, se muestra a continuación un ejemplo de identificación de haya en la zona pirenaica de Navarra, en la que se entrenaron modelos para identificar las clases no arbolado (R), haya (FSY), otras frondosas caducifolias (FC), coníferas caducifolias (CC) y coníferas perennifolias (CP). El número de observaciones de verdad terreno para cada clase fue de unas 500. Para las clases FC y CC fue necesario densificar la muestra procedente del IFN4 mediante fotointerpretación sobre ortofotogramas de otoño de 2020.

Las métricas de la muestra de validación (20% del total) se ofrecen en la Tabla 4, y una imagen de la cartografía con las cinco clases predichas en la zona de Roncesvalles, sobre ortofoto de 2020, en la Figura 5.

Tabla 4. Métricas evaluadoras de la eficacia del modelo para la muestra de validación.

Etiqueta	Precisión	Recall	F1-score
CC	0.98	0.96	0.97
CP	0.89	0.95	0.92
FC	0.98	0.83	0.90
FSY	0.92	0.95	0.94
R	0.91	0.97	0.94

Accuracy	0.93		
----------	------	--	--

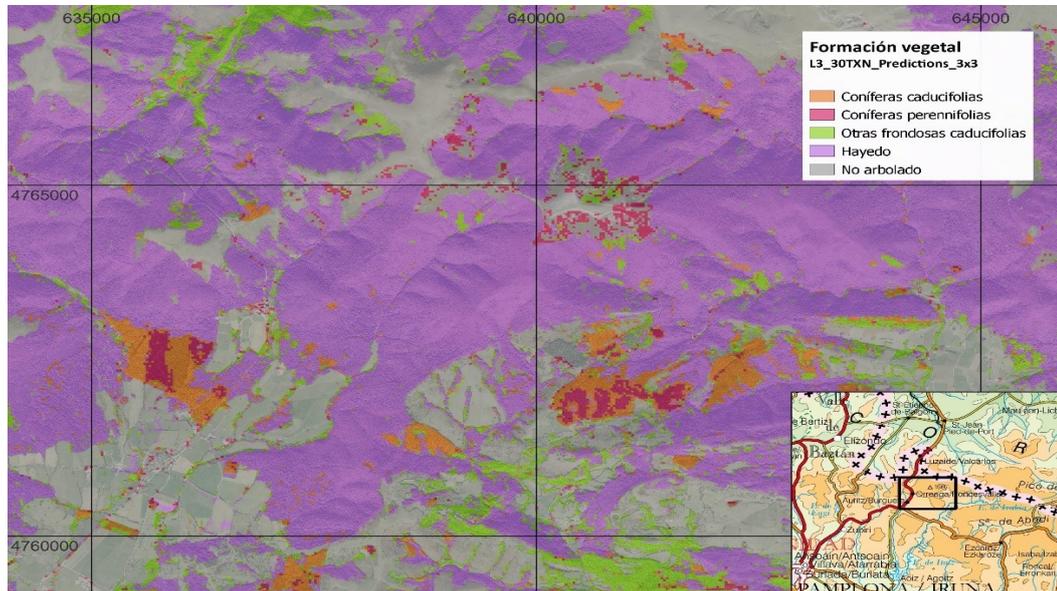


Figura 5. Ejemplo de cartografía resultante del proceso identificación de especies en el valle del Roncal.

## 5. Discusión

En este trabajo se ha expuesto resumidamente la arquitectura, funcionamiento y parte de los resultados que pueden obtenerse en la nueva versión de la plataforma Förecast 3.0 para la ejecución de IFC mediante el apoyo de sensores remotos. El objetivo de Förecast ha sido desde su diseño inicial ofrecer la oportunidad a gestores, propietarios e investigadores, de realizar inventarios forestales ABA de manera ágil y sencilla, en tiempo real, y sin tener que poseer unos grandes conocimientos en sensores remotos, más allá de estar al tanto de su fundamento teórico, fortalezas y limitaciones.

Para alcanzar ese objetivo ha sido necesario dotar a la plataforma, como se ha explicado, de varias características distintivas. Por un lado, Förecast es muy versátil tanto territorial como específicamente. Su arquitectura le permite trabajar en cualquier parte del planeta y, de hecho, además de en España funciona actualmente en el estado de Durango (México), fruto del proyecto INNOWWIDE 2020-1876 förecast-MX *Förecast: the next generation of forest inventory arrives in the Americas*. Sin embargo, es en España donde la plataforma demuestra su mayor potencial y versatilidad, al facilitar al usuario realizar IFC en cualquier punto del territorio y para la mayoría de las especies arbóreas más importantes. De hecho, entre otras colecciones de herramientas matemáticas, en la plataforma están implementadas casi la totalidad de las ecuaciones de índice de sitio, de cubicación



(fundamentalmente, ecuaciones de perfil) y de biomasa publicadas en la literatura científica, así como más de 4000 ecuaciones altura-diámetro generalizadas (por especies, forma principal de masa y tipo de mezcla) ajustadas por Fora para habilitar el cálculo de alturas de manera sencilla y, por consiguiente, poder obtener multitud de parámetros dendrométricos que, a su vez, permiten el cómputo de un gran número de variables de rodal con las que realizar los ajustes necesarios en los inventarios forestales ABA.

Por otro lado, dado que este tipo de procedimientos son altamente demandantes de capacidad de computación, al estar diseñado como servicio web y disfrutar de servidores exclusivos dedicados en las dependencias de Fora, la rapidez en el procesado no va a depender en ningún caso de la calidad de conexión o de la potencia de computación del equipo del usuario, al que únicamente se le solicita que cargue en la plataforma los archivos vectoriales que delimitan su área de interés, su división en unidades de gestión y las especies que lo pueblan (esto último será opcional el futuro próximo, cuando se finalice el prototipado de la herramienta *Identificación de especies*).

Así mismo, resulta destacable la oportunidad que brinda la plataforma de realizar IFC con diferentes niveles de precisión. Así, en su nivel más modesto (*inventario sin datos*), el usuario únicamente facilita su área de interés y la plataforma decide qué ecuaciones son óptimas, de entre las disponibles, para el procesado, aprovechando la transferibilidad temporal de las ecuaciones LiDAR bajo ciertas restricciones (DOMINGO et al. 2019). Si se cuenta con datos dendrométricos de campo, estos se pueden procesar previamente en la propia plataforma, que los pondrá a disposición del usuario para que los pueda utilizar si lo desea en los dos niveles superiores de precisión de los IFC, el *inventario con calibración* y el *inventario con datos*, con los que se realizarán ajustes de manera automática para predecir las variables de rodal útiles para la gestión a partir de la información remota.

Un aspecto absolutamente crítico para los IFC que soluciona la plataforma es la actualización en tiempo real de los cálculos. Por un lado, Förecast aprovecha la potencia de contar con al menos dos coberturas LiDAR en el territorio español para estimar la calidad de estación en masas puras mediante la estimación de la curva de calidad de estación más probable por comparación de las alturas de la vegetación en dos fechas diferentes (ALONSO PONCE et al. 2022; NOORDERMEER et al. 2018) y, a partir de esa curva, simular el crecimiento de la masa hasta la fecha deseada mediante diagramas de manejo de densidad. Y, por otro, la integración de la herramienta *Control de cambios*, que identifica las perturbaciones acaecidas en la vegetación, con periodicidad mensual, desde la fecha del último escaneo LiDAR disponible, gracias a los mosaicos libres de nubes y de resolución espacial de 10 m generados a partir de las imágenes Sentinel-2.

Sin embargo, quedan muchos retos que afrontar en la elaboración de IFC asistidos por sensores remotos y que aún no soluciona Förecast 3.0. Es conocida la dificultad para obtener buenas predicciones de la densidad de árboles mediante el método ABA a partir de LiDAR aerotransportado de baja densidad (Adhikari et al. 2023; Madueño et al. 2021), pero con una densidad nominal algo mayor, homologable a



la que está planificada en la tercera cobertura PNOA (2025), ya es factible obtener mejoras significativas en la predicción (López y Sandoval 2023). Igualmente constituye un reto emplear esta metodología para obtener buenas predicciones en masas complejas, como pueden ser las mixtas, irregulares, o con ambas características a la vez, aunque la utilización de técnicas estadísticas más sofisticadas y de imágenes multiespectrales también en el proceso del cálculo de existencias están abriendo nuevos caminos para mejorar sensiblemente las predicciones (ADHIKARI et al. 2023; BROWN et al. 2022; OZKAN et al. 2022). Así mismo, perturbaciones difusas derivan en cambios sutiles de la repuesta espectral y, por consiguiente, su detección mediante sensores remotos constituye un auténtico reto para los métodos y datos disponibles actualmente. Algunos investigadores ya han publicado resultados prometedores en el caso de la detección de los primeros síntomas de estrés a causa de perforadores (YE et al. 2021) o por claras débiles bajas o mixtas (ZHANG et al. 2023). Por último, la herramienta de *Identificación de especies* va a necesitar forzosamente de técnicas de jerarquización (WAŚNIEWSKI et al. 2022) para lograr resultados suficientemente satisfactorios en ecosistemas con características muy variadas tanto en cuanto a sus patrones climáticos como fenológicos.

## 6. Conclusiones

En este trabajo se ha puesto de manifiesto la trascendencia de disponer de herramientas operativas y amigables para la ejecución de inventarios forestales continuos apoyados en información remota, incluso para aquellos usuarios no especialistas en sensores remotos. La aplicación Förecast constituye un ejemplo de éxito en este sentido, ya que está completamente operativa desde 2019 y facilita las soluciones a buena parte de los retos que implican los IFC. Las nuevas mejoras desarrolladas para la versión 3.0 integran ya dos de los ejes fundamentales sobre los que se apoyan los IFC, y el tercero de ellos está en fase de prototipado.

Sin embargo, aún quedan muchos retos que abordar, como la predicción más robusta de la densidad de árboles, la modelización en masas mixtas o irregulares, la detección de cambios sutiles en la vegetación o la generalización de los modelos de clasificación de especies a condiciones ambientales muy heterogéneas, que son demandados constantemente por los usuarios.

## 7. Agradecimientos

Los autores desean expresar su agradecimiento a todo el personal de Fora por sus continuos esfuerzos y contribuciones para desarrollar, mantener, mejorar y difundir la plataforma Förecast.

## 8. Bibliografía

ADHIKARI, A.; MONTES, C. R.; PEDUZZI, A.; 2023. A Comparison of Modeling Methods for Predicting Forest Attributes Using Lidar Metrics. *Remote Sensing*, 15(5), 1284. <https://doi.org/10.3390/rs15051284>



- ALONSO PONCE, R.; LIZARRALDE, I.; RODRÍGUEZ-PUERTA, F.; PÉREZ-RODRÍGUEZ, F.; 2018. EasyLaz 1.0 (Registro de la Propiedad Intelectual SO-8/2018).
- ALONSO PONCE, R.; RODRÍGUEZ-PUERTA, F.; HERNÁNDEZ, Á.; MARTÍN-GARCÍA, S.; PÉREZ-RODRÍGUEZ, F.; LIZARRALDE, I.; 2022. ¿Podemos estimar la calidad de estación de nuestros rodales forestales a través exclusivamente de la información de dos vuelos LiDAR? Actas del 8o Congreso Forestal Español2.
- BRAVO, F.; DEL RÍO, M.; DEL PESO, C.; 2002. El inventario forestal nacional, elemento clave para la gestión forestal sostenible. Fundación General de la Universidad de Valladolid.
- BROWN, S.; NARINE, L. L.; GILBERT, J.; 2022. Using Airborne Lidar, Multispectral Imagery, and Field Inventory Data to Estimate Basal Area, Volume, and Aboveground Biomass in Heterogeneous Mixed Species Forests: A Case Study in Southern Alabama. *Remote Sensing*, 14(11), 2708.  
<https://doi.org/10.3390/rs14112708>
- DOMINGO, D.; ALONSO PONCE, R.; DE LA RIVA, J.; LAMELAS, M. T.; RODRÍGUEZ, F.; MONTEALEGRE, A. L.; 2019. Temporal Transferability of Pine Forest Attributes Modeling Using Low-Density Airborne Laser Scanning Data. *Remote Sensing*, 11(3), 261. <https://doi.org/10.3390/rs11030261>
- FASSNACHT, F. E.; WHITE, J. C.; WULDER, M. A.; NÆSSET, E.; 2024. Remote sensing in forestry: current challenges, considerations and directions. *Forestry: An International Journal of Forest Research*, 97(1), 11-37.  
<https://doi.org/10.1093/forestry/cpad024>
- LANARAS, C.; BIOUCAS-DIAS, J.; GALLIANI, S.; BALTSAVIAS, E.; SCHINDLER, K.; 2018. Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 305-319. <https://doi.org/10.1016/j.isprsjprs.2018.09.018>
- LETOURNEAU, L.; 1966. A FOREST INVENTORY BY CONTINUOUS FOREST CONTROL. *The Forestry Chronicle*, 42(4), 414-419. <https://doi.org/10.5558/tfc42414-4>
- LÓPEZ, M.; SANDOVAL, S.; 2023. Estimation of stand density using aerial LiDAR information: Integrating the area-based-approach and individual-tree-detection methods in plantations of *Pinus radiata*. *Bosque*, 44(2), 377-386.  
<https://doi.org/10.4067/S0717-92002023000200377>
- MADUEÑO, S.; SALAS, F. M.; CARRASCO, M. D.; LÓPEZ QUINTANILLA, J.; 2021. Estimación de variables forestales mediante análisis de información LiDAR PNOA frente a la aplicación de técnicas clásicas de muestreo sistemático. *Montes2*, 2, 34-41.
- MCGAUGHEY, R. J.; 2021. FUSION/LDV: Software for LIDAR Data Analysis and Visualization. V4.20. USDA.
- NÆSSET, E.; 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, 80(1), 88-99. [https://doi.org/10.1016/S0034-4257\(01\)00290-5](https://doi.org/10.1016/S0034-4257(01)00290-5)
- NOORDERMEER, L.; BOLLANDSÅS, O. M.; GOBAKKEN, T.; NÆSSET, E.; 2018. Direct and indirect site index determination for Norway spruce and Scots pine using bitemporal airborne laser scanner data. *Forest Ecology and Management*.  
<https://doi.org/10.1016/j.foreco.2018.06.041>
- OZKAN, U. Y.; DEMIREL, T.; OZDEMIR, I.; SAGLAM, S.; MERT, A.; 2022. Predicting forest stand attributes using the integration of airborne laser scanning and Worldview-3 data in a mixed forest in Turkey. *Advances in Space Research*, 69(2), 1146-1158. <https://doi.org/10.1016/j.asr.2021.10.049>
- PÉREZ-RODRÍGUEZ, F.; ALONSO PONCE, R.; LIZARRALDE, I.; RODRÍGUEZ-PUERTA, F.; MARTÍN-GARCÍA, S.; 2019. EasySat 1.0 (Registro de la Propiedad Intelectual



SO-8/2019).

PNOA.; 2025. Especificaciones técnicas PNOA LiDAR.

<https://pnoa.ign.es/web/portal/pnoa-lidar/especificaciones-tecnicas>.

RODRÍGUEZ-PUERTA, F.; PÉREZ-RODRÍGUEZ, F.; ÁGUEDA, B.; ALONSO PONCE, R.;

GARCÍA-PEDRERO, Á. M.; OLANO, J. M.; GARCÍA-HIDALGO, M.; 2021. La inteligencia artificial ya es una realidad en el sector forestal. *Foresta*, 81, 22-23.

WANG, J.; SUN, K.; CHENG, T.; JIANG, B.; DENG, C.; ZHAO, Y.; LIU, D.; MU, Y.; TAN, M.; WANG, X.; LIU, W.; XIAO, B.; 2021. Deep High-Resolution Representation Learning for Visual Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(10), 3349-3364.

<https://doi.org/10.1109/TPAMI.2020.2983686>

WAŚNIEWSKI, A.; HOŚCIŁO, A.; CHMIELEWSKA, M.; 2022. Can a Hierarchical Classification of Sentinel-2 Data Improve Land Cover Mapping? *Remote Sensing*, 14(4), 989. <https://doi.org/10.3390/rs14040989>

WULDER, M. A.; CAMPBELL, C.; WHITE, J. C.; FLANNIGAN, M.; CAMPBELL, I. D.; 2007. National circumstances in the international circumboreal community. *The Forestry Chronicle*, 83(4), 539-556. <https://doi.org/10.5558/tfc83539-4>

YE, S.; ROGAN, J.; ZHU, Z.; HAWBAKER, T. J.; HART, S. J.; ANDRUS, R. A.; MEDDENS, A. J. H.; HICKE, J. A.; EASTMAN, J. R.; KULAKOWSKI, D.; 2021. Detecting subtle change from dense Landsat time series: Case studies of mountain pine beetle and spruce beetle disturbance. *Remote Sensing of Environment*, 263, 112560.

<https://doi.org/10.1016/j.rse.2021.112560>

ZHANG, T.; WU, L.; LIU, X.; LIU, M.; CHEN, C.; YANG, B.; XU, Y.; ZHANG, S.; 2023.

Detection of Forest Disturbances with Different Intensities Using Landsat Time Series Based on Adaptive Exponentially Weighted Moving Average Charts. *Forests*, 15, 19.