

La teledetección como apoyo a los inventarios forestales nacionales EFN

Barbara Koch¹

EN ESTE CAPÍTULO, APRENDEREMOS LO SIGUIENTE:

- Una introducción a los métodos de teledetección aplicados a los inventarios forestales
- Aspectos destacados de las condiciones marco para emplear la teledetección en las EFN
- Una presentación de los nuevos sensores, como LIDAR y radar
- Ejemplos de aplicaciones prácticas

Introducción

Este capítulo aborda la integración en los inventarios forestales de los datos obtenidos por teledetección. Presentaremos las nociones básicas que sustentan la incorporación de los sistemas de teledetección a los inventarios forestales nacionales (EFN) y señalaremos los aspectos más importantes. Ofreceremos una perspectiva general sobre varios sistemas de teledetección y tipos de datos, sus ventajas y desventajas, así como su desarrollo futuro.

Ya hace mucho tiempo que los inventarios forestales vienen usando datos obtenidos mediante teledetección. De hecho, los especialistas en gestión forestal fueron, tras los militares, el colectivo que adoptó los datos de teledetección con más ahínco, como medio auxiliar para el trabajo de elaboración de los inventarios. Si hablamos de teledetección y sus sensores, nos referimos a todos los instrumentos aéreos y vía satélite diseñados para la observación de la Tierra, lo que abarca desde la fotografía aérea analógica hasta los instrumentos digitales por satélite, así como los radares de apertura sintética (SAR) y los

sistemas optoelectrónicos. Esta definición no incluye los sistemas de navegación o posicionamiento por satélite ni los sistemas de teledetección terrestres, como la fotogrametría terrestre o el láser escáner terrestre. Sin embargo, tanto los sistemas de navegación o posicionamiento como los sistemas de teledetección terrestre ganan cada vez más importancia para el muestreo y las tareas de medición de terrenos basadas en muestras. En consecuencia, no se puede ningunear su uso a la hora de describir el empleo de los sistemas de teledetección para las EFN. No obstante, cuando se habla de teledetección, la mayoría de las veces no se refiere a esto, y este es un aspecto que no se abarca en este capítulo.

Marco de referencia y objetivos

El uso de datos obtenidos por teledetección para las EFN tiene siempre carácter complementario para las mediciones realizadas sobre el terreno de acuerdo con la selección de muestras y deben integrarse en un diseño terrestre basado en muestreos.

¹ Department Remote Sensing and Landscape Information Systems, Faculty of Forest and Environmental Sciences, Albert-Ludwigs University of Freiburg

Las razones que subyacen a la integración de datos de teledetección en las EFN puede ser muy variado. Los principales argumentos a favor de la integración de los datos obtenidos por teledetección son:

- Se logra una cobertura total del área en un plazo relativamente breve.
- Se reduce la intensidad del muestreo y con ello, los costes. Hay algunos datos de satélite disponibles gratuitamente.
- Se dispone de documentación visual de la situación y los cambios.
- Permite generar datos cartográficos.
- Se puede contar con información de áreas terrestres inaccesibles o de difícil acceso.
- Incrementan la capacidad nacional para la elaboración de mapas cartográficos, la supervisión y la producción de informes.
- Hace posible una evaluación de la información más armonizada para el país en conjunto.
- Posibilita la realización de evaluaciones retrospectivas de los cambios (modificación de la situación desde el pasado hasta hoy).

Las ventajas enumeradas han favorecido la incorporación de la información obtenida mediante teledetección a los EFN. Sin embargo, existen también una serie de inconvenientes que aún hoy frenan la completa integración de los datos obtenidos por teledetección en las EFN y en los inventarios forestales en general. Mientras que la fotografía aérea se usa ampliamente en Europa para las EFN, en países fuera de este continente es más común la integración de los datos obtenidos vía satélite, eso en caso de que se realicen EFN. Esto se debe a que a menudo hay que cubrir áreas muy extensas y la obtención de datos de fotografía aérea se enfrenta a barreras logísticas muy considerables. Los principales obstáculos que hay que superar para integrar los datos obtenidos especialmente por teledetección vía satélite son:

- Disponibilidad de los datos (si es posible obtener los datos y dónde es posible obtenerlos)
- Condiciones meteorológicas
- Perspectivas a largo plazo de los sistemas de satélites (si los datos siguen disponibles durante un período de tiempo prolongado)
- Problemas para la asignación clara de áreas arboladas, pero también de áreas sin arbolado a zonas de bosque, de acuerdo con las respectivas definiciones
- Costes adicionales que surgen al conservar el diseño del sistema de muestreo terrestre existente
- Limitaciones para derivar el conjunto tradicional de parámetros forestales de los datos obtenidos por medios aéreos y vía satélite
- Déficit de cualificación del personal
- Permisos de vuelo para la recopilación de datos por teledetección aérea

Teniendo en cuenta el desarrollo de la tecnología y el creciente número de satélites dedicados a la observación terrestre en órbita a lo largo de los últimos 20 años, podemos asumir que los datos de teledetección remota obtenidos por métodos distintos de la fotografía aérea van a tener cada vez más peso para las EFN. Ya hay una serie de países que incorporan los datos de teledetección vía satélite como parte de sus EFN. Asimismo, la Evaluación de los recursos forestales mundiales (ERF) realizada en 2010 por la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO) ha integrado por completo la parte correspondiente a la teledetección. Tras probar la integración de la teledetección vía satélite en anteriores ERF, centradas en los bosques tropicales, se constató que: “Los datos satelitales permiten recopilar una información consistente a nivel mundial que posteriormente puede ser analizada utilizando los mismos criterios para distintos momentos en el tiempo, de manera que puedan realizarse estimaciones más precisas sobre el cambio. La teledetección no sustituye la necesidad de obtener sólidos datos

de campo, pero con la combinación de ambos métodos se consiguen mejores resultados que los que pueden obtenerse utilizando cada uno de los métodos por separado” (Evaluación de los recursos forestales mundiales 2010). Esto ha desembocado en la integración global de los datos obtenidos por satélite para las estimaciones de áreas forestales y sus cambios. La accesibilidad de las imágenes de teledetección a través de los mapas de Google es un estímulo más para utilizar la información procedente de satélite o datos de teledetección aérea. Esto provoca que se use información basada en teledetección aunque los mapas de Google solamente permiten emplear imágenes y no permiten procesar la información de los datos de la imagen (por ejemplo, para clasificar automáticamente los tipos de bosque). El objetivo de este capítulo es ofrecer información sobre la integración de los datos de teledetección en las EFN, cuáles son las consideraciones que debemos tomar a la hora de organizar un sistema, qué tipo de datos hay disponibles y qué métodos se pueden utilizar.

Consideraciones sobre cómo organizar y diseñar un sistema para integrar los datos de teledetección en proyectos de EFN

Antes de poder tomar una decisión sobre qué tipo de datos de teledetección integrar en las EFN y cómo hacerlo, es vital identificar la información que se obtendrá a partir de los datos de teledetección y qué tipo de producto y de información queremos obtener como resultado final. El diseño del inventario y los datos que se deben recoger se determinan según los parámetros forestales que se derivarán de los datos y según los resultados que queramos obtener finalmente. Si deben derivarse parámetros forestales basándose en inventarios con múltiples fases, habrá que prestar mucha atención al plantear el diseño de las muestras. Por ejemplo,

si se efectúa un muestreo con datos de teledetección (por ejemplo, datos de satélite de muy alta resolución) y es preciso calibrar la información basada en teledetección con datos procedentes de un muestreo terrestre, será necesario un solapamiento de las parcelas terrestres y las muestras obtenidas por satélite. En todos los inventarios forestales que utilizan datos de teledetección remota, la información más importante extraída de ellos son las estimaciones del área forestal y de sus cambios. Parece sencillo y es algo que se ha puesto en práctica muchas veces. Pero este objetivo, relativamente simple, ya comprende una serie de consideraciones y decisiones. La primera de las decisiones está relacionada con el producto final. ¿Es imprescindible proceder a realizar una cartografía completa, hay que adoptar un enfoque basado en muestreos o bien optar por combinar ambas posibilidades? En muchos casos la mejor solución pasa por combinar varios métodos, con una cobertura total y datos de resolución media o alta, como los datos Modis con resoluciones espaciales de 0,5 a 1 km, variante utilizada en la ERF 2010 o incluso con datos de alta resolución, como los de Landsat TM, incorporados a la EFN de Finlandia. La elección entre incluir datos de alta o media resolución depende sobre todo del área que tengamos que cubrir, del presupuesto disponible, de la escala y de si se debería obtener algún otro dato adicional. Basándose en los datos de la cobertura total, se produce una máscara de la superficie forestal o un mapa del uso del suelo combinado con una máscara forestal. Aunque a menudo se usan datos de Modis y Landsat TM para mapas de cobertura total, hay varios satélites más que se podrían encargar de esta tarea. Uno de los puntos claves para elegir el tipo de sensor es la vida útil del sensor del satélite. La Tabla 1 muestra una selección de sensores de satélites para la supervisión de los bosques, tal y como se describen en el documento de trabajo 141 de la ERF (Ridder 2007).

En el portal de EO encontrará información más detallada y actualizada (<https://directory.eoportal.org/index.php>). Este portal ofrece

Tabla 1:

Aptitud de los sensores de satélites seleccionados para la supervisión de áreas forestales (fuente: Ridder 2007)

Image type	Free / low cost	No copy right	Optimised for vegetation	Length of repeat cycle	Available time range	Future sensor continuation
Optical, 5 to 50 m pixel resolution						
ASTER	+	-	+	- (16 days)	2000 onwards	unclear
CBERS CCD + IR-MSS	?	?	+	- (26 days)	2000 onwards	expected
DMC	-	-	+	+ (near daily)	2005 onwards	unclear
IRS LISS	-	-	+	- (5-24 days)	1997 onwards	expected
Landsat MSS	+	+	+	- (16 days)	1972-1984	N/A
Landsat TM & ETM+	+	+	+	- (16 days)	1984 onwards, since 05/2003 SLC off	LDCM
RapidEye	-	-	+	+ (daily)	2007	unclear
SPOT HRV	-	-	+	- (26 days)	?	expected
Optical, 150 to 1000 m pixel resolution						
CBERS WFI	?	?	+	+ (3-5 days)	2000 onwards	expected
IRS WIFS	-	-	+	- (24 days)	1997 onwards	expected
MERIS	?	?	+	+ (daily)	2000 onwards	expected
MODIS	+	+	+	+ (daily)	2000 onwards	VIIRS
SPOT VEGETATION	+	-	+	+ (daily)	1998 onwards	Vegetation 2
SAR						
ERS	-	-	-			
JERS	+	-	+			
RADARSAT	-	-	-			
ENVISAT	-	-	-			
TerraSAR-X	-	-	+/-		To be launched in 2007	unclear
ALOS PALSAR	-	-	+		2006 onwards	unclear

también información sobre las próximas misiones de satélite. Un buen ejemplo es la misión Sentinel 2 de la ESA, que proporcionará datos gracias a satélites gemelos de alta resolución y gran amplitud de barrido, dedicados a la observación de la Tierra. Está previsto que la misión esté activa durante un largo período de tiempo. Se espera también que Brasil y China lancen satélites de larga vida útil, que se sumarán a los ya puestos en órbita por la India y los EE. UU. Otro aspecto muy importante para planificar la organización y puesta en marcha de la integración de la teledetección en las EFN es el período de repetición del tipo de sensores. Tiene especial importancia en países bajo condiciones meteorológicas desfavorables. Antes de tomar

una decisión sobre el tipo de sensor, se deben efectuar cálculos o aproximaciones para dilucidar cuál es la probabilidad de disfrutar de escenarios libres de nubes, ya que puede ser extremadamente importante si se necesitan los datos correspondientes a un plazo de tiempo determinado. La Figura 1 muestra un ejemplo de la media de fracción de nubosidad prevista para las operaciones de adquisición de datos de Landsat ETM (Yu y Roy 2007).

En el futuro, los tipos de sensores que ofrezcan períodos de repetición relativamente altos serán especialmente útiles para las EFN, como se contempla en el caso de Sentinel 2. El Sentinel 2 volverá a visitar los mismos puntos cada 5 días. De acuerdo con un estudio (de una fuente desconocida) basado en datos




Fig. 1: Fracción media de nubosidad para las operaciones de adquisición de datos de ETM para cada escenario global en 2002 0<púrpura<0,2; 0,2=<azul marino<0,3; 0,3=<azul celeste<0,4; 0,4=<verde<0,5; 0,5=<amarillo<0,6; 0,6=<naranja<0,7; 0,7=<rojo<1,0. (fuente: Yu y Roy 2007).

de Landsat TM y con la simulación de un período de repetición de las visitas de 5,5 días, las probabilidades de encontrar un escenario libre de nubes se incrementarían en un 30 % de media, en comparación con un período de repetición de las visitas de 16 días. Así, con un período de repetición de las visitas de 5 días, tan solo algunas regiones de bosques tropicales y sub-boreales seguirían presentando dificultades para lograr escenarios despejados dentro de un plazo de tiempo razonable. Para esas áreas se necesitan alternativas, como los sensores SAR o sensores ópticos con repeticiones diarias. Además, la época del año también influye sobre las probabilidades de encontrar un escenario sin nubes. En líneas generales, en muchas regiones se hace más difícil disfrutar de escenarios sin nubes durante las estaciones de invierno y verano que en otoño o primavera.

Aparte de la teledetección por satélite, también se puede emplear la teledetección aérea. Utilizar datos obtenidos por teledetección aérea en las EFN es, principalmente, cuestión de costes y posibilidades de puesta en práctica. En muchos países no funciona correctamente la integración de datos de teledetección aérea debido a las limitaciones existentes para conseguir permisos de vuelo. En segundo lugar, dada la extensión de algunos países, no es posible conseguir una cobertura total por medio de sistemas de teledetección aérea, e incluso un muestreo en varias fases de los datos por medio de sistemas aéreos supone un reto logístico.

Tras haber evaluado las condiciones generales que antes hemos mencionado, se debe analizar la gama de sensores entre los que podemos elegir, de acuerdo con cuatro características principales, con el fin de ajustarse al máximo a los requisitos de información y cartografía. La mejor solución para elegir entre los diferentes sensores es acudir a empresas que se ocupan de vender datos y productos de información como los que se necesitan. Sin embargo, siempre es una ventaja que el cliente sea plenamente consciente de la calidad de los distintos datos de satélite, ya que le brinda una idea acerca de qué información será posible obtener. Los principales ingredientes que definen la calidad de imagen que se obtendrá más adelante son los siguientes:

- La resolución espacial define hasta qué nivel de detalles es posible lograr una representación cartográfica de los objetos.




Fig. 2: Ejemplos de imágenes con tamaño de píxel diferente

- La resolución radiométrica define la capacidad de identificar y separar diferencias en la energía reflejada. Por ejemplo, si hay dos áreas llanas, digamos de 30 por 30 m cada una, y ambas reflejan la energía del sol de una forma muy similar en la región visible del espectro, en la imagen en blanco y negro de un sensor con baja resolución radiométrica no habrá diferencia entre ambas áreas, mientras que sí se apreciará en la imagen ofrecida por el sensor de alta resolución radiométrica.




Fig. 3: Resolución radiométrica de 1 y de 8 bits (fuente: desconocida)

- La resolución espectral identifica en cuántas regiones espectrales distintas puede medir el sensor la energía reflejada. Por ejemplo, para un compuesto de colores, el sensor debe ser capaz de medir la energía reflejada en al menos 3 regiones (canales) espectrales distintas.




Fig. 4: Diferentes canales espectrales de Landsat TM (de B2 a B4)

- La resolución temporal define la tasa de repeticiones de la visita del satélite, es decir, qué período de tiempo necesitará el satélite para contar con la posibilidad de recopilar los datos de una misma área; puede ser diaria, semanal, mensual, etc.

Sistemas de sensores ópticos

La incorporación a las EFN de los datos obtenidos por teledetección está relacionada mayoritariamente con sistemas ópticos. La fotografía aérea ostenta una larga tradición como fuente de información de apoyo para las EFN, al igual que sucede con los inventarios de empresa. De acuerdo con las características principales que hemos enumerado antes, las fotografías aéreas se caracterizan por tener una resolución espacial muy alta, una alta resolución radiométrica y porque su sensibilidad espectral se sitúa por encima

de la franja situada entre la parte visible y la cercana a los infrarrojos del espectro electromagnético (de 400 nm a 1.100 nm). Hace años se empleaban sistemas analógicos con películas, mientras que hoy se utilizan muchas más cámaras digitales montadas en aviones, que normalmente cuentan con cuatro bandas espectrales, tres en el espectro visible y una cercana a los infrarrojos. Para las fotografías aéreas no es aplicable la resolución temporal, ya que la fecha y hora de los vuelos se pueden elegir, más o menos, con libertad. Por lo tanto, la fotografía aérea cuenta con mayores probabilidades de obtener datos sin el estorbo de las nubes de los sistemas ópticos vía satélite, gracias a la flexibilidad para elegir el momento de la recogida de datos. La fotografía aérea sigue teniendo un papel predominante en los inventarios forestales, especialmente en Europa. Hay una serie de países en donde las decisiones sobre si un área es forestal o no y las modificaciones de las áreas forestales se toman basándose en fotografías aéreas. Las raíces de este uso intensivo de las fotografías aéreas en Europa se origina probablemente en la larga tradición que tiene el empleo de estos datos, de la alta resolución espacial que proporcionan, de la interrelación (a menudo muy fuerte) entre los institutos cartográficos que producen las fotografías aéreas y la administración forestal, de los costes relativamente altos que conllevan los datos vía satélite de alta resolución (siguen sin poder competir con los costes de las fotografías aéreas) y de la mayor probabilidad que tiene este método para lograr datos del área deseada sin la presencia de nubes dentro de cierto plazo de tiempo. Otros factores adicionales que favorecen la fotografía aérea en Europa son la facilidad para conseguir permisos de vuelo y las unidades de terreno que se deben cartografiar, relativamente pequeñas si las comparamos con otras regiones como los Estados Unidos o Sudamérica. La nueva generación de fotografía digital aérea seguramente impulsará el avance del uso complementario de la fotografía aérea en combinación con las mediciones

terrestres, gracias a sus mejores características espectrales y radiométricas, así como a las posibilidades más amplias que ofrecen para el procesamiento de datos. Las investigaciones de Hoffmann (2010) pusieron de relieve que era posible evaluar ciertos parámetros forestales de importancia (como las especies de árboles principales, los espacios rasos y los daños) basándose en fotografías aéreas digitales de infrarrojos. La información potencial de las fotografías aéreas en estéreo, la altura, normalmente no se utiliza para derivar o calcular más propiedades del bosque, como el volumen de madera o la biomasa superficial. Hay varios países donde las fotografías aéreas son el único tipo de datos de teledetección que se aplica en las EFN. Un ejemplo del aprovechamiento de las fotografías aéreas dentro de las EFN es el muestreo en dos fases para reducir el número de parcelas del muestreo terrestre sin perder información ni precisión (por ejemplo, Suiza).

En muchos países fuera de Europa y también en algunos europeos se emplean los datos ópticos obtenidos vía satélite como fuente de datos adicionales para las EFN. En general, se recurre a satélites de alta resolución como el Landsat TM, pero no a satélites de muy alta resolución. Los satélites Landsat son, con mucho, los más usados. Se debe esencialmente a los bajos costes y al largo ciclo de vida de la serie de satélites Landsat. En términos generales, se utilizan datos de satélite para realizar cartografías completas, como el caso del inventario finlandés, pero también se emplean para elaborar mapas basados en muestreos. Si nos detenemos a observar las cuatro características distintas de los sensores que hay que analizar antes de decidirse por un tipo de sensor particular, a día de hoy el requisito más problemático es la resolución temporal de los satélites disponibles, mientras que los niveles de resolución espacial, radiométrica y espectral son adecuados para una serie de satélites (como Landsat TM, Spot o IRS) con los que realizar los inventarios forestales. La resolución temporal es vital para los inventarios, ya que las regiones

boscosas principales se hallan en lugares con una presencia relativamente alta de nubosidad. Un estudio interno del DLR (Centro Aeroespacial Alemán) demostró que como media son necesarios 5 años para cubrir toda la superficie de Alemania con escenas sin nubosidad obtenidas a través de Landsat TM. Por lo tanto, es crucial dar la consideración que merece a la resolución temporal, que mejorará la disponibilidad de los datos. En segundo lugar, los costes influirán en gran medida sobre el tipo de datos de teledetección que se puedan integrar en las EFN. Cuanto más alta sea la resolución, más difícil será lograr una cobertura total de un área de grandes dimensiones y más caro. La Figura 5 enseña la relación entre las áreas de cobertura y las escenas obtenidas por distintos sensores.

No es factible realizar una cartografía completa para una EFN con satélites de muy alta resolución, debido a los costes y a las dificultades que conlleva lograr una cobertura total dentro de un plazo razonable. Sin embargo, la cartografía completa resulta útil para todo tipo de estratificación y para decidir si un área es forestal o no (Öhmichen 2007). Las investigaciones de McRoberts (2002) y Dees y Koch (1997) demuestran que una estratificación del área forestal basada en datos ópticos de teledetección vía satélite mejora la precisión de los cálculos o permite reducir el número de parcelas del muestreo sin perder precisión. Para aplicar la estratificación, hay dos modos de abordarla: la pre-estratificación o la post-estratificación.




Fig. 5: Relación de las áreas cubiertas por distintos sensores

Mientras que la pre-estratificación influye sobre el diseño de las parcelas de muestreo, la post-estratificación permite mantener sin modificar el diseño existente de las parcelas muestreadas.

La integración de los datos de teledetección se asienta en muchos casos sobre un enfoque con varias fases. En este caso, por ejemplo, la clasificación de un área como forestal o no forestal se basa en datos de resolución media, mientras que en una segunda fase se tomarían como muestreos datos de satélite de alta resolución, de muy alta resolución o fotografías aéreas. Los datos usados con el muestreo varían y van de datos de muy alta resolución a datos de satélite de alta resolución o fotografías aéreas. La selección del tipo de datos depende sobre todo de los parámetros forestales que se obtengan de los datos recopilados por teledetección. Si hay que cartografiar las condiciones forestales, las especies arbóreas o la estructura del bosque, habrá que acudir a la fotografía aérea o a los datos vía satélite con resoluciones espacial, espectral y radiométrica muy altas.

Se han desarrollado una serie de investigaciones para estimar el volumen de madera y la biomasa superficial a partir de regresiones basadas en datos ópticos. Existen correlaciones entre la señal reflejada y el volumen de madera, así como entre la biomasa superficial y algunos otros índices en la franja cercana a los infrarrojos y en los infrarrojos de onda corta. Con todo, hay que mencionar que la varianza es muy alta y que cuanto mayores sean el volumen de madera y la biomasa superficial de un bosque, menor será la correlación, que se pierde en el caso de trabajar con bosques densos caracterizados por los altos volúmenes de madera y de biomasa superficial. Sin embargo, especialmente para la modelización del secuestro de CO₂, los datos de teledetección tendrán una gran importancia en el futuro, ya que la teledetección es la única herramienta que puede ofrecer información sobre las condiciones de los bosques y el área forestal a nivel global. Las primeras líneas maestras sobre

las posibilidades de emplear los datos ópticos de los satélites para modelizar la fijación del CO₂ se describen en el libro GOF-C-Gold (2009). En el futuro, en las EFN también ganará peso e importancia la información sobre biodiversidad. Si se cartografía la biodiversidad, es preciso considerar dos tipos distintos de biodiversidad: estructural y de especies. La teledetección puede proporcionar información para ambas categorías a nivel de paisaje. La identificación de especies con datos de teledetección se limita a las especies arbóreas o los tipos de bosques. Mientras que la identificación de las especies arbóreas se basa principalmente en fotografías aéreas cercanas al infrarrojo, la identificación de los tipos de bosques se puede conseguir con datos de satélite multiespectrales de alta o muy alta resolución. Sin embargo, hay que prestar atención al hecho de que, en las fotografías aéreas y también en los datos de satélite, la identificación tiene limitaciones. Además de las similitudes espectrales entre ciertas especies de árboles, las limitaciones se deben a la edad de los árboles (las propiedades espectrales de un árbol pueden modificarse drásticamente a medida que envejece), al patrón de la mezcla de las especies arbóreas y a las condiciones de los árboles. Esta es la razón por la que, en áreas tropicales y subtropicales con una mezcla de un gran número de especies arbóreas, a menudo no es posible la identificación del tipo de bosque. Además, hay que considerar que la exposición de las áreas forestales varía, lo que incrementa el problema de identificar especies o tipos de bosques. Ningún algoritmo de corrección puede solucionar el problema que suponen las diferencias debidas a la distinta exposición al sol. A pesar de todo, con un buen tratamiento de los datos es posible lograr resultados razonables. Las investigaciones demuestran que el reconocimiento del tipo de bosque y de las especies se puede mejorar con la disponibilidad de los datos hiperespectrales. En general es más fácil acceder a la diversidad estructural con datos de teledetección. Se puede cartografiar particularmente bien la



Fig. 6: Segmentación de área forestal basada en imágenes fusionadas de IRS-1D y Landsat TM (fuente: Ivits et al. 2004)

diversidad estructural horizontal, e incluso mejor que con mediciones terrestres. La principal influencia sobre la calidad de los resultados deriva de que haya una correspondencia entre resolución espacial y la escala de cartografía solicitada para las estructuras (Figura 6).

Las investigaciones de FeLis¹ han demostrado que, basándose en la información estructural y sobre tipos de bosque extraída de los datos de Landsat TM e IRS-1D sí es posible modelizar estructuras de hábitat de especies de aves. Basándose en los valores en gris y en los índices derivados de valores en gris de Landsat TM y de IRS-1D se detectó que la prueba de bondad del ajuste era muy significativa (Hosmer y Lemeshow 2000) para obtener un modelo logístico final correspondiente que predijese la ausencia o la presencia de determinadas especies de aves determinada ($C=4,2610$, $P > \text{Chi-Sq}= 0,8328$) (Herrera 2003). Esto indica que la presencia y ausencia de aves mantiene una fuerte correlación con las covariables de valores grises incluidas en el modelo. La estadística




Fig. 7: Ejemplo de superficie de krigeaje ordinaria espacial de resultados de regresión logística; los datos observados y los valores previstos derivados de los valores de grises y los índices de mancha forestal de la imagen Quickbird se añadieron al modelo; la superficie más oscura indica una alta probabilidad de presencia, mientras que la superficie más clara indica la alta probabilidad de ausencia de las especies.

de c indica que el 92,9 % de la probabilidad de que ocurra la presencia de una especie de ave viene determinada por las covariables enumeradas.

Investigaciones de Ivits et al. (2004) demostraron también que los índices de mancha forestal y los valores en gris alcanzaban resultados similares al predecir la presencia de especies de aves. La regresión logística estaba dotada de un gran potencial de predicción de las variables de teledetección (Figura 7). Al parecer, los índices de teledetección pueden servir como indicadores muy útiles de la diversidad de especies de aves cuando éstas se tratan por separado, mientras que se acercan a sus límites si se clasifican las especies agrupándolas.

¹ Departamento de Teledetección y Sistemas de Información Geográfica, Universidad de Friburgo, Alemania



Fig. 8: Imagen del norte de Múnich con la codificación de colores de TerraSAR. Datos adquiridos el 26 de junio y el 7 de julio de 2007, 5:26 UTC, resolución: 3 m, modo: StripMap, polarización: VV y HH (fuente: DLR, Alemania)

de láser escáner y SAR

Datos de SAR

Si bien podemos asumir que los datos de teledetección óptica ganarán en importancia en las EFN futuras, la aplicación de los datos de SAR probablemente siga siendo limitada. Esto se debe a la gran complejidad que entraña el procesamiento de los datos del radar y a las limitaciones que se encuentran en áreas montañosas. La ventaja más importante de los datos de radar es que se transmiten a través de la capa de nubes, con lo que son bastante independientes de las condiciones meteorológicas. Con los datos de la banda L se puede evaluar bastante bien la decisión para clasificar una superficie como forestal o no forestal y por tanto, los cambios de la cubierta forestal (Håme et al. 2009), incluso con procedimientos de clasificación automática. También es posible representar áreas forestales mediante imágenes con datos de las bandas C y X (Figura 8).

No obstante, las áreas montañosas presentan grandes limitaciones debido a los problemas geométricos y radiométricos que acarrearán para los datos. A pesar incluso de la gama de algoritmos de corrección disponibles, la sombra del radar y las diferencias en la intensidad de la retrodifusión debidas al ángulo de incidencia no pueden corregirse por completo. Esto limita el uso de los datos de radar en las EFN incluso para la toma de

decisiones de clasificación de áreas como forestales o no forestales. Es difícil extraer parámetros forestales de los datos del radar y los resultados no son consistentes. Sí existen modelos y algoritmos, pero se encuentran más bien en fase de investigación, y aún no hemos alcanzado un estadio de desarrollo que haga práctica su integración en las EFN. Se ha trabajado mucho para utilizar los datos de radar para evaluar la biomasa superficial (Koch 2010), pero los estudios no estaban basados en ensayos firmes y solamente son válidos para una situación de área forestal y adquisición de datos específica. La evaluación de la biomasa superficial por medio de datos de radar está restringida por la saturación que se produce en las áreas forestales con altos niveles de volumen de madera o biomasa superficial. A pesar de todo, en el caso de áreas forestales cuya biomasa superficial es baja, como las regiones boreales o sub-boreales, sí es posible obtener mediciones fiables. Como resumen podemos decir que los datos de radar son bastante útiles y válidos para la integración en las EFN, siempre y cuando se cumplan ciertas condiciones ambientales, como trabajar sobre un área llana o con relieve suave, caracterizada por un volumen de biomasa superficial relativamente bajo respecto al volumen de madera. Sin embargo, hay varios proyectos de investigación nuevos que apuntan a que se puede esquivar el problema de la saturación, si bien por el momento se sigue investigando en ello. Nga (2010) informa de que los datos de las bandas L y P con polarización cruzada son los más sensibles a la biomasa superficial, como ya otros afirmaron anteriormente (LeToan 1992, Kurvonen 1999). Especialmente la banda P con polarización cruzada podría aportar una contribución sustancial a la modelización de la biomasa superficial (Henderson y Lewis 1998). Esto se debe al hecho de que la retrodifusión de polarización cruzada de las bandas L y P está relacionada con la difusión del volumen, que tiene una correlación con la biomasa superficial. Se puede limitar el problema que supone la saturación si se utilizan longitudes

de onda mayores, pero según la publicación de Nga (2020), continuará siendo problemática para los bosques cuya biomasa superficial sea superior a 200-250 Mg/ha. Hasta donde yo sé, no es posible practicar la identificación de las especies arbóreas o tipos de bosque. Ni siquiera es muy fiable la separación entre bosques de coníferas y caducifolias o de hoja ancha. Si tomamos en consideración las limitaciones de los datos de radar y la complejidad que entraña su procesamiento, así como la falta de series de datos de observación de la tierra correspondientes a las bandas P y L durante períodos largos de tiempo, parece que la integración de esta modalidad de datos en las EFN es difícil. No obstante, sí es posible emplear sistemas aéreos, aunque es bastante caro y no hay muchos proveedores comerciales que ofrezcan este tipo de datos para integrar los datos de radar aéreo en las EFN.

Datos de láser

El uso de datos obtenidos con tecnologías láser en inventarios forestales se ha disparado durante los últimos años. La mayoría de los proyectos siguen en fase de investigación, pero podrían demostrar su gran valía para las aplicaciones prácticas en inventarios forestales. (Næsset, E., 2004, McRoberts 2010). El uso de datos recogidos por láser aéreo (ALS, de Airborne Laser Scanner) para aplicaciones forestales constituye, probablemente, la mayor innovación en la teledetección para inventarios forestales de la última década. El gigantesco potencial de los datos de ALS se cimienta, fundamentalmente, en la posibilidad de modelar la superficie forestal y su suelo a partir de un conjunto de datos. Además es posible evaluar las estructuras forestales verticales. La extracción de información precisa sobre la altura correspondiente a los bosques ya permite modelizar varios parámetros forestales importantes. La altura es casi igual de adecuada que el diámetro normal (dap, diámetro a la altura del pecho) como variable para modelizar parámetros forestales importantes, como el volumen de madera y la biomasa superficial. A partir de la

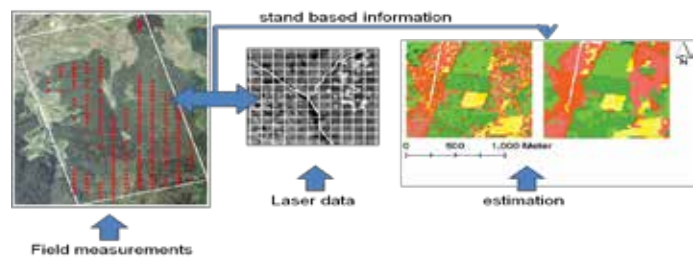


Fig. 9: Esquema de una aproximación que toma como base un área para calcular parámetros forestales

altura se pueden evaluar tanto el dap como la distribución del dap, datos muy importantes para los gestores forestales. Existen dos maneras de abordar la modelización de los parámetros forestales. La primera es adoptar un enfoque basado en el área, que puede trabajar con datos de baja densidad (Figura 9), mientras que la segunda es un enfoque basado en un solo espécimen de árbol, que precisa de datos de alta densidad, con 8-10 puntos por m² para lograr buenos resultados. Existen muchas investigaciones acerca de este aspecto, Hyypä et al. (2009) ofrece una perspectiva completa de cuál es el estado del uso de datos ALS para la elaboración de inventarios forestales.

Las aproximaciones basadas en áreas pueden realizarse como análisis de regresión, como análisis k-NN o bien por medio de métodos de tablas de rendimiento. Esto se describe detalladamente en Straub et al. 2009. Las investigaciones de Latifi et al. (2010) desvelan que emplear información derivada de tecnologías láser para calcular parámetros forestales importantes como son el volumen de madera y la biomasa superficial da mejores resultados que usar datos de Landsat TM y también de las fotografías aéreas (Tabla 2).

Además de estimaciones precisas del volumen de madera y la biomasa superficial, hay muchos otros parámetros que cada vez son más relevantes para las EFN, como la densidad de copa del bosque o parámetros de la estructura del bosque como indicadores de la biodiversidad forestal, que se pueden calcular y así obtener resultados de alta calidad con el enfoque basado en áreas a partir de datos obtenidos por láser. Lo que a día de hoy es muy difícil es identificar son las especies de árboles

o tipos de bosque. Si bien es posible separar las coníferas de las caducifolias (o árboles de hoja ancha) con distintos métodos, la identificación más detallada de especies arbóreas o tipos de bosques con datos obtenidos por láser no es nada fácil de conseguir. Aunque sí hay varias investigaciones con buenos resultados (Heinzel y Koch 2011, Vauhkonen et al. 2010, Hollaus et al. 2009, Höfle et al. 2008) utilizando información física y geométrica procedente de sistemas láser aéreos para la identificación de árboles. Los resultados no están preparados para su aplicación operativa en una EFN. Durante los últimos años, el enfoque basado en un único árbol se ha ido haciendo más y más interesante para los inventarios forestales. Las investigaciones han mostrado que la integración de información basada en muestreos de un único árbol es especialmente necesaria en el caso de bosques maduros para una mejor gestión, así como para la planificación de las talas y de la protección de la naturaleza. Delimitar y elegir un solo árbol es todo un reto y la calidad de los resultados que se logren dependerá de la calidad de los datos, de los tipos de bosques y de los algoritmos aplicados. Un grupo de investigadores ha realizado una comparación entre algoritmos con distintos tipos de bosques, dentro del marco del proyecto WoodWisdom (Fig. 10) (Vauhkonen et al. 2010). Si bien los distintos algoritmos se comportaron de forma

similar, sin grandes disparidades, el principal problema era el tipo de plantación. En el caso de bosques de coníferas la tasa de detección era mucho mejor que para los bosques de hoja ancha con múltiples variedades

Solamente es posible integrar datos de láser en las EFN realizando un inventario de varias fases, elaborado sobre la base de parcelas de muestreo, debido al hecho de que los láser son sistemas aéreos. El único sistema basado en satélites IceSat/Glas que hay está fuera de servicio y los datos solamente fueron útiles para investigación. Únicamente estará operativo, dentro de unos años, un sistema de satélites basado en LIDAR cuya entrada en servicio está ya planificada. Esto limita la aplicación de la obtención de datos por láser para los países más extensos. Por otra parte, en el marco de un inventario con varias fases, los datos obtenidos mediante láser pueden ofrecer información muy valiosa sobre multitud de parámetros forestales analizados durante los estudios de las EFN. El uso de datos muestreados basados en LIDAR reducirá el número de parcelas de muestreo terrestre y/o el nivel de precisión. La información que aportan estos datos es, comparada con otros datos obtenidos por teledetección, probablemente la mejor respecto a los parámetros forestales. Sin embargo, los datos siguen sin estar estandarizados y resultan más caros que la fotografía aérea, lo que

Tabla 2:

Error cuadrático medio del nivel de la parcela, % de error cuadrático medio y % de sesgo correspondientes a los datos de imágenes infrarrojas en color (CIR), Landsat TM y LIDAR para el volumen de madera en pie y la biomasa superficial en distintos métodos de imputación (fuente: Latifi et al 2010)

	CIR image			TM image			LiDAR data		
	RMSE	RMSE%	Bias%	RMSE	RMSE%	Bias%	RMSE	RMSE%	Bias%
Euclidean distance									
Volume	154.31	58.65	1.93	142.73	54.25	-2.91	119.61	45.46	0.75
Biomass	95.49	56.92	1.79	88.43	52.71	-2.80	74.46	44.38	0.30
Mahalanobis distance									
Volume	145.76	55.40	2.65	158.74	60.33	1.68	127.55	48.48	2.42
Biomass	89.15	53.14	2.28	97.37	58.04	1.71	79.60	47.45	2.56
MSN									
Volume	145.54	55.32	0.57	148.40	56.4	-0.33	98.411	37.40	0.72
Biomass	92.55	55.16	2.09	90.68	54.05	-3.39	61.59	36.71	1.94
RF									
Volume	109.21	41.51	-1.84	117.12	44.51	-1.48	54.438	23.97	-1.97
Biomass	65.01	38.75	-3.16	69.90	41.66	-3.31	37.32	22.24	-2.44

supone una preocupación importante para la integración de los datos de LIDAR en las EFN a día de hoy. En muchos países, además, la aplicación de LIDAR es dificultosa debido a que no se cuenta con proveedores comerciales y los vuelos están restringidos. Otro inconveniente adicional de primer orden es la pobre información acerca de las especies arbóreas. Por lo tanto, es necesario investigar más en la aplicación de las tecnologías láser para los enfoques que incluyan varios tipos de sensores en una misma plataforma, como sistemas láser combinados con escáneres multispectrales o sistemas LIDAR de longitudes de onda múltiples que trabajen con tres longitudes de onda distintas. Para seguir avanzando en este campo también es preciso investigar cómo lograr una mejor explotación de la información física y la información de la onda completa, como la intensidad.

Procesamiento de la información

La explotación de la información obtenida a partir de los datos de teledetección puede variar mucho. En muchas aplicaciones prácticas, la mejor forma de extraer la información necesaria es la interpretación

visual de las imágenes. Dentro de la evaluación ERF 2010 así como de la iniciativa REDD, la interpretación de imágenes se usa para identificar las áreas forestales, sus cambios y la degradación de los bosques. Ahora bien, la interpretación es costosa y subjetiva. Los resultados dependen en gran medida de la formación de los intérpretes y son difíciles de comparar. La subjetividad comienza ya con la propia clasificación del área forestal, puesto que la delimitación de la frontera del bosque no siempre es obvia para el intérprete. Sin embargo, hay que tener en cuenta que la evaluación terrestre también es subjetiva en muchos casos.

Principalmente por motivos de eficiencia y por una mejor estandarización del proceso, se prefieren algoritmos de entrenamiento mecánico para la clasificación. Tal vez los resultados no sean más correctos que la interpretación, pero sí son transparentes. Hay una serie de clasificadores distintos, perfectamente conocidos. **Distancia mínima, Probabilidad máxima y Red neuronal artificial** son los clasificadores que se usan desde hace muchos años. El método más sencillo es el de la Distancia mínima, que calcula las distancias más cortas de los vectores espectrales en el espacio

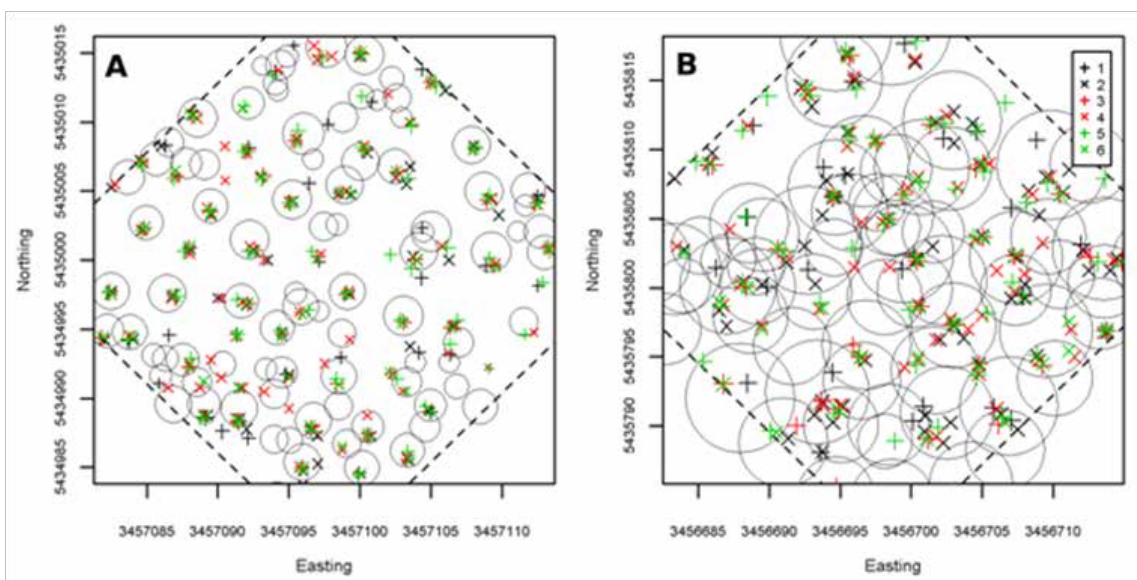


Fig. 10: A- Bosque de coníferas en Alemania y B- Bosque de caducifolias con múltiples variedades en Alemania. Los números del 1 al 6 representan los distintos algoritmos.

multidimensional, de acuerdo con la media de las clases de entrenamiento. La Probabilidad máxima calcula la probabilidad estadística (bayesiana) de que un píxel pertenezca a una clase, basándose en los vectores de media y las covarianzas de las clases de entrenamiento. Aquí se asume una distribución gaussiana, así como la equiprobabilidad para cada clase que se forme (NASA 2010). La asunción de la distribución gaussiana de los valores en gris, a menudo, no se ajusta a la realidad. Las redes neuronales artificiales no son demasiado prácticas; el motivo es que este clasificador exige un uso intensivo de la informática y aún no ha dejado patente su superioridad. Los algoritmos de las redes neuronales artificiales imitan la estructura neuronal del cerebro. Empiezan con un conjunto de datos de entrada y aprenden al comparar las clasificaciones con la clasificación real conocida. Los resultados son devueltos a la red y se usan para modificar el algoritmo de la misma (Zhang et al 2000) en tantas iteraciones como sea preciso.

En los años 90 los algoritmos de **clasificación orientada a objetos** (Lillesand et al. 2008) cobraron cada vez más interés. En este caso se aborda la clasificación en dos fases. En la primera fase se ejecuta una segmentación, basada principalmente en las propiedades de reflectividad (color), textura y forma. También se pueden tener en cuenta el patrón y el contexto. Todo esto se desarrolla como una clasificación jerárquica, de esta forma cada clase se puede describir a su escala óptima. En una segunda fase, se clasifican los segmentos. En muchos casos se utiliza el clasificador **Vecino más próximo** (McRoberts 2011), que se parece al clasificador Distancia mínima. Mientras que el clasificador Vecino más próximo se basa en distancias espectrales multidimensionales, el **Clasificador difuso** es otra opción. Este clasificador trata de considerar el problema de los píxeles mezclados. Esto implica que para cada píxel se calcula una función como participante y se obtiene la probabilidad de que pertenezca a una u otra clase (Nedeljkovic 2004). El software más destacado a día de hoy para la clasificación orientada a objetos es

eCognition. Los clasificadores **Máquina de soporte vectorial** y **Bosques aleatorios** son relativamente nuevos. Ambos clasificadores se hallan a día de hoy en el centro de atención de la comunidad científica. Con ambos clasificadores se obtienen buenos resultados en clasificaciones de terrenos forestales y de usos del suelo. Las máquinas de vectores de soporte (SVM) han demostrado que pueden manejar espacios con gran cantidad de información y rasgos y discriminaciones entre clases complejas mejor que otros métodos (Heinzel et al. 2010, Mountrakis et al. 2011). La clasificación de SVM es una técnica de aprendizaje estadístico supervisado y no paramétrico, que no requiere ninguna asunción sobre la distribución subyacente de los datos. He aquí la principal ventaja de este clasificador. La SVM siempre se relaciona con una separación en dos clases dentro de un espacio de características multidimensionales. Las separaciones multiclase son posibles al dividirse en problemas de dos clases, que se combinan de ciertas formas. El clasificador SVM tiene por objetivo encontrar un hiperplano con un método iterativo, donde los errores de clasificación se reduzcan al mínimo utilizando los ejemplos de entrenamiento. La clasificación de Bosques aleatorios se basa en muchos árboles sobre los que se toman decisiones individuales. Se trata de un algoritmo de aprendizaje supervisado, que puede trabajar con un gran número de atributos y funciona correctamente con grandes conjuntos de datos. Es independiente del número de atributos y se encarga de que el clasificador no padezca sobreajustes. En muchas clasificaciones ha ofrecido resultados de alta precisión (Klassen y Paturi 2010), Latifi et al. (2010) y también ha dejado patente que el clasificador Bosques aleatorios se comporta mejor que los sistemas SVM a la hora de clasificar atributos forestales. Su ventaja es que durante el procesamiento se lleva a cabo una evaluación de las clasificaciones. El clasificador Bosques aleatorios toma muestras "bootstraps" para remuestreo, que no son sino muestras del conjunto de datos

de entrenamiento. Genera clasificaciones de árboles paralelas y en cada nodo selecciona un muestreo aleatorio de variables. Elige y trabaja con la rama más favorable, mientras el árbol crece hasta alcanzar su máxima talla posible. El árbol con la menor tasa de error se elige a continuación como el clasificador más fuerte.

Además de los clasificadores ya mencionados antes, el estimador no paramétrico **Vecino más próximo k (k-NN)** es un método muy eficaz que se puede usar para los datos de teledetección en combinación con parcelas de muestreo si se desea obtener una información con cobertura total. El método k-NN se usa en la EFN de Finlandia, con buenos resultados (Tomppo 2002). Este método se basa en la regresión entre características espectrales de píxeles de imágenes sobre áreas con mediciones de campo y píxeles de imágenes sin mediciones de campo. Basado en las mediciones de distancias de Mahalanobis o euclidianas de números k de Vecinos más próximos, a los píxeles sin datos de campo se les asignará la información de campo de aquellos píxeles con los que mejor se correspondan. De esta forma, la información de las mediciones de campo se transfiere a las áreas que carecen de datos de campo. En el campo de la silvicultura, el método k-NN ha permitido desarrollar un gran número de investigaciones con distintos tipos de sensores. Ha demostrado ser un método útil, pero el tipo de datos y el tipo de bosques tendrán una gran influencia sobre los resultados (Latifi et al. 2011).

Observaciones finales

El autor no pretende que esta breve perspectiva panorámica abarque todos los detalles del uso de la teledetección para la elaboración de inventarios forestales nacionales. La intención era ofrecer un recorrido condensado sobre los puntos más importantes, de acuerdo con la experiencia personal. La autora no proporciona ninguna información sobre diseño de muestreos, ya que hay otros autores que tratan este tema, personas con una experiencia más específica

en ese campo. Si se quiere profundizar en la teledetección, recomendamos las obras que figuran a continuación.

Glosario

ALS	Láser escáner aéreo (Aerial Laser Scanner)
DAP	Diámetro a la altura del pecho
CIR	Color infrarrojo
ESA	Agencia Espacial Europea (European Space Agency)
FAO	Organización de las Naciones Unidas para la Agricultura y la Alimentación (Food and Agriculture Organisation)
ERF	Evaluación de los recursos forestales
GOFC	
Gold	Global Observation for Forest and Land Cover Dynamics
IRS 1D	Satélite de teledetección indio (Indian Remote Sensing)
k-NN	Clasificador Vecino más próximo k (k Nearest Neighbor)
Landsat	
ETM	Mapeador temático avanzado del satélite Landsat (Enhanced Thematic Mapper)
Landsat	
TM	Mapeador temático del satélite Landsat (Landsat Thematic Mapper)
Modis	Espectroradiómetro de imágenes con resolución moderada
EFN	Evaluación Forestal Nacional
REDD	Programa de reducción de las emisiones producidas por la degradación forestal en naciones en vías de desarrollo (Reducing Emissions from Deforestation and Forest Degradation in Developing Countries)
RMSE	Error cuadrático medio (Root Mean Square Error)

SAR	Radar de apertura sintética (Synthetic Aperture Radar)
SVM	Máquina de soporte vectorial (Support Vector Machine)

Bibliografía

Dees, M. and Koch, B., (1997): Poststratifizierung bei Klumpenstichprobendesign zur Nutzung von Fernerkundung und GIS bei Waldinventuren. In: Pelz, D. R. (Hrsg): Sammlung von Beiträgen aus der 10. Jahrestagung der Sektion Forstliche Biometrie und Angewandte Informatik des Deutschen Verbandes Forstlicher Forschungsanstalten, 24-26 Sept. 1997 in Freiburg Br.

Forest Resource Assessment 2010, Main Report, FAO Forestry Paper 163, Rom 2010, p. 340.

GOFC-GOLD, Sourcebook – Reducing Greenhouse Gas Emissions from Deforestation and Degradation in Developing Countries: A Sourcebook of Methods and Procedures for Monitoring, Measuring and Reporting. 2009, p. 108. Source book GOFC- Gold

Häme, T., Rauste, Y., Sirro, L., Stach, N., 2009. Forest cover mapping in French Guiana since 1992 using satellite radar imagery, Proceedings of ISRSE 33 Symposium. Stresa, Italia, 4 - 9 May 2009.

Heinzel, J. and Koch, B., 2011. Exploring full-waveform LiDAR parameters for tree species classification. / International Journal of Applied Earth Observation and Geoinformation/, *13*, 152-160

Heinzel, J., Ronneberger, O., Koch, B., 2010, A comparison of support vector and linear classification of tree species. Proceedings of SilviLaser 2010, 14.-17. September 2010, Freiburg, Germany, Enßle, F. and Weinacker, H. (Eds.), 479-488.

Herrera, B., 2003. Classification and Modeling of Trees Outside Forest in Central American Landscapes by Combining Remotely Sensed Data and GIS. Doctoral thesis. Faculty of Forestry and Environmental Sciences, Department of Remote Sensing and Landscape Information Systems, University of Freiburg, Germany.

Hoffmann, K., 2010. Erfassung von Waldstruktur- und Waldzustandsparametern aus digitalen Luftbilddaten der sachsenweiten Befliegung. Forstliche Forschungsberichte Nr. 209, „Der gepixelte Wald – Forstliche Fernerkundung vor dem Hintergrund aktueller Entwicklungen in Umwelt und Technik. Fachtagung in Freising, 25. Januar 2008, S. 18-29.

Höfle, B., Hollaus, M., Lehner, H., Pfeifer, N., Wagner, W., 2008. Area-based parameterization of forest structure using full waveform airborne laser scanning

data. Proc. Silvilaser 17-20. Sept. 2008, Edinburgh, Scotland, 227 – 235.

Hollaus, M., Mücke, W., Höfle, B., Dorigo, W., Pfeifer, N., Wagner, W., Bauerhansl, C. and Regner, B., 2009. Tree species classification based on full-waveform airborne laser scanning data. 9th International SilviLaser Conference, October 14-16, 2009, Texas A&M University, College Station, TX, USA, pp 54-62.

Hosmer, D.W., Lemeshow, S. 2000. Applied Logistic Regression. 2nd Edition. Wiley Series in Probability and Statistics. John Wiley & Sons, Inc. New York.

Hyyppä, J., Hyyppä, H., Yu, X., Kaartinen, H., Kukko, A., Holopainen, M., 2009. Forestry inventory using small-footprint airborne. Topographic Laser Ranging and Scanning, J. Shan and C.K. Toth (eds.), (Boca Raton: CRC Press), 335-370.

Ivits, E., Koch, B., Waser, L., Chamberlain, D. 2004. Modelling Biological Data with segmented Landscape Objects and Image Grey Values. Presented at the 1. Göttingen GIS and Remote Sensing Days, 7. – 8. Oktober 2004. J. D. Sauerländer's Verlag Frankfurt a. M., ISBN 3-7939-5138-3, Bd. 138, S. 349-359.

Ju, J. and Roy, D.P., 2008. The availability of cloud-free Landsat ETM data over the conterminous United States and globally. Remote Sensing of Environment 112 (2008) 1196-1211.

Koch, B. 2010. Status and Future using New Laser Scanning, Synthetic Aperture Radar and Hyperspectral Remote Sensing Data for Forest Biomass Assessment. In: ISPRS Journal of Photogrammetry and Remote. 65(2010) 581-590.

Kurvonen, Q., M., Coe, R., van Noordwijk, M., Ambagau, Y. and Palm, C.A., 2001. Reducing uncertainty in the use of allometric biomass equations for predicting above-ground tree biomass in mixed secondary forests. Forest Ecology and Management 146 (1-3), 199

Latifi, H., Nothdurft, A., Koch, B. 2010. Non-parametric prediction and mapping of standing timber volume and biomass in a temperate forest: application of multiple optical/LiDAR –derived predictors. Forestry 83(4): 395-407

LeToan, T., Beaudoin, A., Riou, J., Guyon, D., 1992. Relating forest biomass to SAR data. Geoscience and Remote Sensing, IEEE Transactions on 30 (2), 403-411.

Lillesand, T.M., Kiefer, R., W., Chipman, J., W., 2008. Remote Sensing and Image Interpretation. 6th ed. Hoboken, John Wiley & Sons, Inc.

McRoberts, R., M., Wendt D. G., Nelson, M., Hansen, M., H., 2002. Using a land cover classification based on satellite imagery to improve the precision

- of forest inventory area estimates. *Remote Sensing of Environment* (81), 2002, 36-44.
- McRoberts, St.**, 2010: Advances and emerging issues in national forest inventories. *Scandinavian Journal of Forest Research* 25: 368-381.
- McRoberts, St.**, 2011: Estimating forest attribute parameters for small areas using nearest neighbors techniques. *Forest Ecology and Management* (in press), Science direct (<http://www.sciencedirect.com/>)
- Mountrakis, G., Im, J., Ogole, C.**, 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (2011) 247-259.
- Naesset, E.**, 2004. Estimation of above- and below-ground biomass in boreal forest ecosystems. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 36 Part 8/W2, 3-6 October 2004, Freiburg, Germany, 145-148.
- Nga, N. T.**, 2010. Estimation and mapping of above ground biomass for the assessment and mapping of carbon stocks in tropical forests using SAR data – a case study in Afram Headwaters Forest, Ghana. Dissertation at International Institute for Geo-Information, Science and Earth-Observation, ITC, Enschede, Netherland, 2010, pp. 79.
- Öhmichen K.**, 2007. Satellitengestützte Waldflächenkartierung für die Bundeswaldinventur. Dissertation an der Universität, Hamburg, 2007, 105 S.
- Ridder R. M.**, 2007, Options and recommendations for a global remote sensing survey of forests. Food and Agricultural Organisation, Working paper 141, Rome 2007, p. 55.
- Straub, C., Weinacker, H., Koch, B.** 2009. A Comparison of Different Methods for Forest Resource Estimation using Information from Airborne Laserscanning and CIR Orthophotos. In: *European Journal of Forest Research* DOI 10.1007/s10 342-010-0391-2 (online).
- Tomppo, E., A. Pekkarinen**, 1997: Methodenerprobung der Finnischen Nationalen Multiquellen-Waldinventur in Nordrhein-Westfalen. In: *Landeswaldinventur –Konzeption, Verfahrenstest, Ergebnisse*, Schriftenreihe der Landesforstverwaltung Nordrhein-Westfalen Heft 5, 52-67
- Vauhkonen, J., Korpela, I., Maltamo, M. And Tokola, T.**, 2010. Imputation of single-tree attributes using airborne laser scanning-based height, intensity and alpha shape metrics. *Remote Sensing of Environment*. Doi 10.1016/j.rse.2010.01.016
- Vaukonen, J., Ene, L., Gupta, S., Heinzl, J., Holmgren, J., Pitkänen, J., Solberg, S., Wang, Y., Weinacker, H., Hauglin, K.M., Lien V., Packelen, P., Gobakken, T., Koch, B., Naesset, E., Tokola, T., Maltamo, M.**, 2010. Comparative testing of single-tree detection algorithms. *Proceedings of SilviLaser 2010*, 14.-17. September 2010, Freiburg, Germany, Enßle, F. and Weinacker, H. (Eds.).
- Zhang, G., P.**, 2000. Neural Networks for Classification: A survey. *IEEE Transactions on Systems, Man and Cybernetics-Part C: Applications and Reviews*, Vol. 30, No. 4, November 2000, 451-461.
- ESA, GMES Observing the Earth – Living Planet Programm http://www.esa.int/esaLP/SEM4T4KX-MF_LPgmes_0.html, (last access 17.02.2011)
- Klassen M., and Paturi, N.**, 2010. Web document classification by keywords using random forests. *NDT* (2), 2010, 256-261. <http://robles.callutheran.edu/~m-klassen/doc/NDT2010.pdf> (last access 28.2.2011)
- Leo Breiman and Adele Cutler, Random Forest**, http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm (last access 28.2.2011)
- NASA, Remote Sensing Tutorial 2010**, Image processing and Interpretation http://rst.gsfc.nasa.gov/Sect1/Sect1_19.html (last access 28.2.2011)
- Nedeljkovic, I.**, 2004. Image classification based on fuzzy logic. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 34, Part XX, 2004. <http://www.google.de/search?hl=de&q=IMAGE+CLASSIFICATION+BASED+ON+FUZZY+LOGIC&aq=f&aqi=&aql=&oq=> (last access 28.02.2011)
- Neural Network Classification, http://www.resample.com/xlminer/help/NNC/NNClass_intro.htm (last access 28.2.2011)
- Tomppo, E.**, 2002. Development of more efficient tools for the 21st century forest inventory using field and satellite data. In *Proceedings ForestSat 2002 National Forest Inventory*, August 6, 2002. <http://www.metla.fi/pp/ETom/index-en.htm> (last access 28.2.2011)

