

## Importancia de las estimaciones por muestreo probabilístico para analizar dinámicas forestales regionales: una evaluación de los datos de Global Forest Change en el este de México

### *Importance of probability sampling estimates for analyzing regional forest dynamics: an evaluation of Global Forest Change data in eastern Mexico*

Carlos Alberto López Arcadia\* y Martha Bonilla Moheno\*\*

Recibido: 6/09/2023. Aceptado: 21/11/2023. Publicado: 21/03/2024

**Resumen.** La base de datos de Global Forest Change (GFC) ha facilitado el acceso al análisis y monitoreo de dinámicas del suelo a distintas escalas. Sin embargo, estos datos pueden presentar imprecisiones espacio-temporales ocasionadas por las características del paisaje, las prácticas de manejo agrícola y la escala espacial de la evaluación. Para reducir dichas inexactitud es recomendable realizar evaluaciones para cada caso de estudio utilizando estimaciones por muestreo probabilístico. En México ha habido un incremento en estudios con la base de datos de GFC para calcular la pérdida de cobertura forestal; sin embargo, pocos lo han hecho usando estimaciones por muestreo. En este estudio realizamos una evaluación utilizando estimaciones por muestreo probabilístico en cuatro regiones cafetaleras del este de México con características climáticas y topográficas complejas y una alta presencia de minifundistas. Utilizamos el GFC para llevar a cabo el muestreo probabilístico, agrupando los píxeles de pérdida de cobertura anual en tres categorías: *No Pérdida (NP)*, *Posible Pérdida (PP)* y *Pérdida (P)*. Para cada región, generamos aleatoriamente 200 puntos de muestreo para *P* y 100 para *PP* y *NP*. Con la ayuda de series de tiempo de los valores máximos y mínimos de NDVI y EVI e imágenes de alta resolución de Google Earth, llevamos a cabo una verificación visual para identificar el año en el que hubo una pérdida de cobertura forestal en cada punto de muestreo. Posteriormente, utilizamos tres procedimientos para

calcular la pérdida: una estimación basada en el mapa de GFC; una estimación por muestreo utilizando las categorías *P+PP*, y una estimación por muestreo utilizando las tres categorías (*P+PP+NP*). Adicionalmente verificamos la precisión temporal de la base de datos GFC, comparado el año en que se reportó la pérdida con el año en que se observó la pérdida en la evaluación. Encontramos que la pérdida de cobertura forestal fue detectada correctamente por la base de datos más del 90% de las veces en todas las regiones. Sin embargo, la pérdida observada en las categorías *PP* y *NP* no detectada por la base de datos fue alta (53-65% y 23-26%, respectivamente). Asimismo, encontramos que la pérdida calculada en las estimaciones por muestreo fue desde cuatro (*P+PP*) hasta 70 (*P+PP+NP*) veces mayor que la estimación basada en el mapa. Además, encontramos que la precisión temporal fue relativamente baja (59.5-77.5%), con una tendencia a reportar la pérdida de cobertura forestal uno o más años después de haber tenido lugar. Esto indica que, al realizar evaluaciones regionales en paisajes heterogéneos manejados por pequeños propietarios, la base de datos de GFC puede subestimar considerablemente la pérdida de cobertura forestal. Resaltamos la importancia de realizar evaluaciones por muestreo probabilístico para reducir imprecisiones espaciotemporales que podrían llevar a inferencias erróneas sobre los patrones de pérdida de cobertura forestal.

\* Red Ambiente y Sustentabilidad, Instituto de Ecología, A.C. Carretera antigua a Coatepec 351, col. El Haya, 91073, Xalapa, Veracruz, México. ORCID: 0000-0001-9516-4347. Email: [arcadiopteris@tutanota.com](mailto:arcadiopteris@tutanota.com). Autor de correspondencia.

\*\* Red Ambiente y Sustentabilidad, Instituto de Ecología, A.C. Carretera antigua a Coatepec 351, col. El Haya, 91073, Xalapa, Veracruz, México. ORCID: 0000-0002-2403-2002. Email: [martha.bonilla@inecol.mx](mailto:martha.bonilla@inecol.mx)

**Palabras clave:** deforestación, estimación por muestreo, paisajes complejos, degradación forestal, evaluación regional

**Abstract.** The Global Forest Change (GFC) database has facilitated access to soil dynamics analysis and monitoring at different scales. However, these data may contain spatial-temporal inaccuracies caused by landscape characteristics, agricultural management practices, and the spatial scale of the assessment. To reduce these inaccuracies, it is recommended to evaluate each case study using probabilistic sampling estimates. The number of studies that calculate forest cover loss in Mexico using the GFC database has increased; however, few studies have used sampling estimates for this purpose. This study assessed probabilistic sampling estimates in four coffee regions of eastern Mexico with complex climatic and topographic characteristics and numerous smallholders. We used the GFC to carry out probabilistic sampling, grouping the annual coverage loss pixels into three categories: No Loss (NP), Possible Loss (PP), and Loss (P). For each region, we randomly generated 200 sampling points for P and 100 for PP and NP. Using time series of maximum and minimum NDVI and EVI values and high-resolution images from Google Earth, we carried out a visual verification to identify the year with a loss of forest cover at each sampling point. We then used three

procedures to calculate the loss: an estimate based on the GFC map, a sampling estimate using the P+PP categories, and a sampling estimate using the three categories (P+PP+NP). Additionally, we validated the temporal accuracy of the GFC database by comparing the year in which the loss was reported with the year in which the loss was observed in the assessment. We found that forest cover loss was correctly detected by the database more than 90 % of the time in all regions. However, the loss observed in PP and NP and not detected by the database was high (53–65 % and 23–26 %, respectively). We also found that the loss calculated in the sampling estimates was four (P+PP) to 70 (P+PP+NP) times greater than map-based estimates. Furthermore, we found a relatively low temporal accuracy (59.5–77.5 %), showing a tendency to report the loss of forest cover one or more years after it occurred. This indicates that the GFC database can significantly underestimate the loss of forest cover by conducting regional assessments on heterogeneous landscapes managed by smallholders. This study highlights the importance of conducting probabilistic sampling assessments to reduce spatio-temporal inaccuracies that could lead to erroneous inferences about patterns of forest cover loss.

**Keyword:** deforestation; sample estimation; complex landscapes; forest degradation; regional assessment.

## INTRODUCCIÓN

La expansión de la frontera agrícola es uno de los mayores impulsores de degradación, fragmentación y deforestación de los bosques tropicales (Foley *et al.*, 2011; Armenteras *et al.*, 2017; Ceddia, 2019). Para desarrollar planes de manejo del suelo y políticas que aborden estos procesos es necesario monitorear sus dinámicas espaciotemporales (Chowdhury, 2006; Pettorelli *et al.*, 2014; Seymour y Harris, 2019). La disponibilidad actual de instrumentos globales que producen datos espaciales, tales como MODIS Land Cover (Friedl *et al.*, 2002), GlobeLand30 (Jun *et al.*, 2014), o Global Forest Change (Hansen *et al.*, 2013), ha hecho que el análisis espacial y temporal de las dinámicas y procesos del suelo resulte ampliamente accesible. Particularmente, la base de datos de Global Forest Change (GFC) ha jugado un papel clave en la evaluación de tendencias de cobertura forestal, ya que puede ser usado para estimar la deforestación a escala de bioma (Hansen *et al.*, 2013), nacional (Sannier *et al.*, 2016; Cunningham *et al.*, 2019; Galiatsatos *et al.*, 2020) y subnacional (McRoberts *et al.*, 2016; Linke *et al.*, 2017; Milodowski *et al.*, 2017).

La base de datos de GFC contiene varias capas con una resolución espacial de 30 metros: la cobertura del dosel para el año 2000, un agregado de recuperación forestal para el periodo 2000-2012, y la pérdida anual de cobertura forestal. Estas características, junto con su alcance global y la actualización anual, han proporcionado a investigadores y tomadores de decisiones una herramienta confiable para monitorear las tendencias de cobertura forestal, especialmente en sitios donde las bases de datos regionales no existen o son insuficientes (Sannier *et al.*, 2016). Sin embargo, debido al algoritmo usado para producir la base de datos, en algunos casos hay diferencias locales en la estimación de áreas de pérdida o recuperación forestal, las cuales pueden llevar a una sub o sobrestimación del cambio forestal, así como a imprecisiones temporales en el año asignado a la pérdida forestal (Hansen *et al.*, 2013; Galiatsatos *et al.*, 2020). Esta sobre/subestimación ha sido atribuida a características orográficas y climáticas del paisaje (Cunningham *et al.*, 2019); la presencia de cultivos arbóreos, y los claros a pequeña escala, usualmente asociados a la agricultura minifundista (Tropek *et al.*, 2014; Turubanova *et al.*, 2018;

Cunningham *et al.*, 2019). Las imprecisiones temporales han sido atribuidas principalmente a la presencia continua de nubes en los trópicos y a perturbaciones de pequeña escala (Milodowski *et al.*, 2017; Turubanova *et al.*, 2018). Además, la definición de bosque y pérdida forestal usada en la base de datos de GFC no considera procesos de degradación forestal, los cuales frecuentemente superan a la deforestación en paisajes tropicales (Ellis *et al.*, 2020; Matricardi *et al.*, 2020; Qin *et al.*, 2021). Para reducir estas imprecisiones y evitar hacer inferencias incorrectas del área de cambio forestal a partir de estimaciones basadas en mapas, las bases de datos deben de ser validadas para cada caso particular utilizando estimaciones por muestreo (Hansen *et al.*, 2014; Olofsson *et al.*, 2014; Tropek *et al.*, 2014; Sandker *et al.*, 2021).

Recientemente, ha habido un aumento en los estudios que usan la base de datos de GFC para evaluar la pérdida de cobertura forestal en México. Este ha sido usado para calcular la pérdida de hábitat y su efecto en la distribución de mamíferos (Klass *et al.*, 2020); para evaluar la deforestación asociada con la expansión agrícola y la extracción de madera (Blackman y Villalobos, 2021; Cho *et al.*, 2021); para evaluar la influencia de la tenencia de la tierra y el manejo del suelo sobre la extensión de cobertura forestal (Ellis *et al.*, 2017; Lawrence *et al.*, 2019; Haines, 2021); y para evaluar la eficacia de distintas estrategias (por ejemplo, pago por servicios ambientales y áreas protegidas) en la conservación de la cobertura forestal (Sims y Alix-García, 2017; Ramírez-Reyes *et al.*, 2018; Izquierdo-Tort *et al.*, 2019; Ellis, Sierra-Huelsz, *et al.*, 2020; Powlen *et al.*, 2021; González-Fernández *et al.*, 2022). Asimismo, la base de datos de GFC ha sido usada para evaluar tendencias e impulsores de deforestación a escalas nacionales (Portillo-Quintero y Smith, 2018; Figueroa *et al.*, 2021) y subnacionales (Krylov *et al.*, 2018). Sin embargo, de los estudios citados, solo tres utilizaron estimaciones por muestreo para calcular el área de pérdida forestal (Krylov *et al.*, 2018; Ramírez-Reyes *et al.*, 2018; González-Fernández *et al.*, 2022), mientras que en una hicieron una validación visual usando SIG (Portillo-Quintero y Smith, 2018) y en otra llevaron a cabo una validación en campo

(Izquierdo-Tort *et al.*, 2019). A pesar de que las estimaciones reportadas en la mayoría de estos estudios son confiables, la incertidumbre asociada con el uso de estimaciones basadas en mapas sin la validación a escala local podría dar resultados erróneos sobre la magnitud y tendencia del cambio forestal (Galiatsatos *et al.*, 2020).

En este estudio resaltamos la importancia de llevar a cabo estimaciones por muestreo a partir de la base de datos de GFC para reducir la incidencia de sub/sobreestimaciones del área de pérdida forestal y las imprecisiones temporales de cambio forestal. Realizamos la evaluación en cuatro regiones cafetaleras del este de México (Figura 1) donde el café es cultivado por minifundistas bajo el dosel de agrobosques (~1 ha) en paisajes montañosos complejos (López-Arcadia, 2022). Dadas las características orográficas y climáticas de la región, así como las prácticas de manejo de los cafecultores, es muy probable que, en este paisaje, la precisión de la base de datos de GFC se vea comprometida (Milodowski *et al.*, 2017; Turubanova *et al.*, 2018; Cunningham *et al.*, 2019). Además, en 2013, la región fue afectada por la epidemia de la roya, lo que desencadenó un proceso de degradación y pérdida forestal ocasionada por la reducción de árboles de sombra en las parcelas de café (López-Arcadia, 2022). Ya que esta epidemia coincide con el cambio en satélites usados para actualizar la base de datos de GFC (de Landsat 7 a Landsat 8), la evaluación de los datos puede también ayudar a separar los efectos de la epidemia de los ocasionados por la mayor sensibilidad del nuevo satélite.

## METODOLOGÍA

Siguiendo las recomendaciones de buenas prácticas para estimar áreas usando mapas (Olofsson *et al.*, 2014; Tyukavina *et al.*, 2015), llevamos a cabo un muestreo probabilístico estratificado utilizando la versión 1.8 de la base de datos de GFC (Figura 2), la cual integra los datos originales con datos actualizados que abarcan desde el año 2000 hasta el 2020 (Hansen *et al.*, 2013). Para establecer el área inicial de cobertura forestal, consideramos como bosque aquellos píxeles que en el año 2000 tuvieron

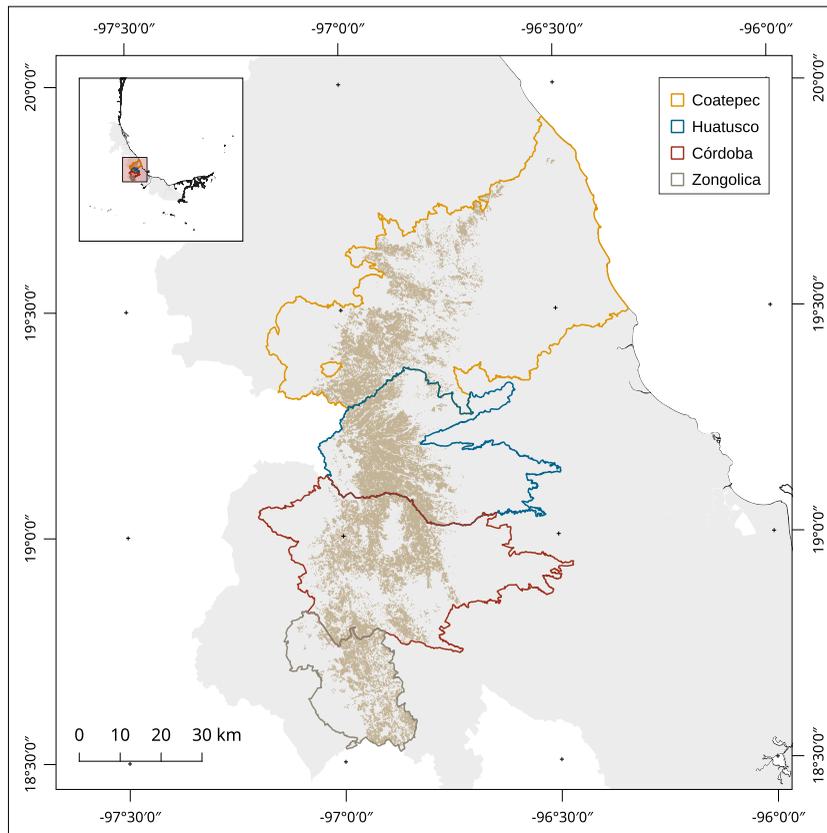


Figura 1. Área de estudio. Las líneas continuas de color representan los límites administrativos de las regiones cafetaleras estudiadas, localizadas en el estado de Veracruz, México. El área sombreada es el área cafetalera de cada región donde la evaluación fue realizada. Fuente: elaboración propia usando el censo cafetalero de SAGARPA para el año 2000.

una cobertura del dosel mayor a 50% (Sannier *et al.*, 2016). Posteriormente, usando la capa *lossyear*, agrupamos los píxeles en tres categorías de acuerdo al cambio reportado en la cobertura forestal de 2001 a 2020: 1) *No pérdida* – píxeles donde no se detectó pérdida de cobertura forestal; 2) *Posible pérdida* – píxeles que no mostraron pérdida, pero son adyacentes a un píxel donde se detectó pérdida, y 3) *Pérdida* – píxeles donde se detectó pérdida de cobertura forestal. Posteriormente, generamos puntos de muestreo aleatorios para cada categoría usando la función ‘sampleRandom’ del paquete *raster* en R (Hijmans y van Etten, 2012). Ya que nuestro mayor interés fue identificar áreas donde hubiera pérdida de bosque, para cada una de las cuatro regiones generamos 200 puntos para *Pérdida*, 100 puntos para *Posible pérdida*, y 100 puntos para *No pérdida*. Para verificar la pérdida de cobertura forestal, generamos mosaicos anuales (2001-2010) de los valores mínimos y máximos del índice de diferencia

normalizada (NDVI) y los valores mínimos y máximos del índice de vegetación mejorada (EVI) para cada región utilizando imágenes Landsat 7 para el periodo 2001-2012 y Landsat 8 para el periodo 2013-2020. Todas las imágenes fueron generadas en la plataforma Google Earth Engine (Gorelick *et al.*, 2017). A partir de las imágenes resultantes, extrajimos el valor de cada punto de muestreo y elaboramos series de tiempo para ayudar en la verificación de la pérdida de cobertura forestal. Siguiendo a Turubanova *et al.* (2018), hicimos una verificación visual con imágenes de alta resolución de Google Earth para identificar el periodo en el que ocurrió la pérdida (Figura 3A). Después, usando las series de tiempo generadas para EVI y NDVI (Figura 3B), verificamos el año en el que ambos índices disminuyeron dentro del periodo identificado previamente y lo designamos como el año de pérdida observada. Consideramos la pérdida de cobertura forestal como la reducción de

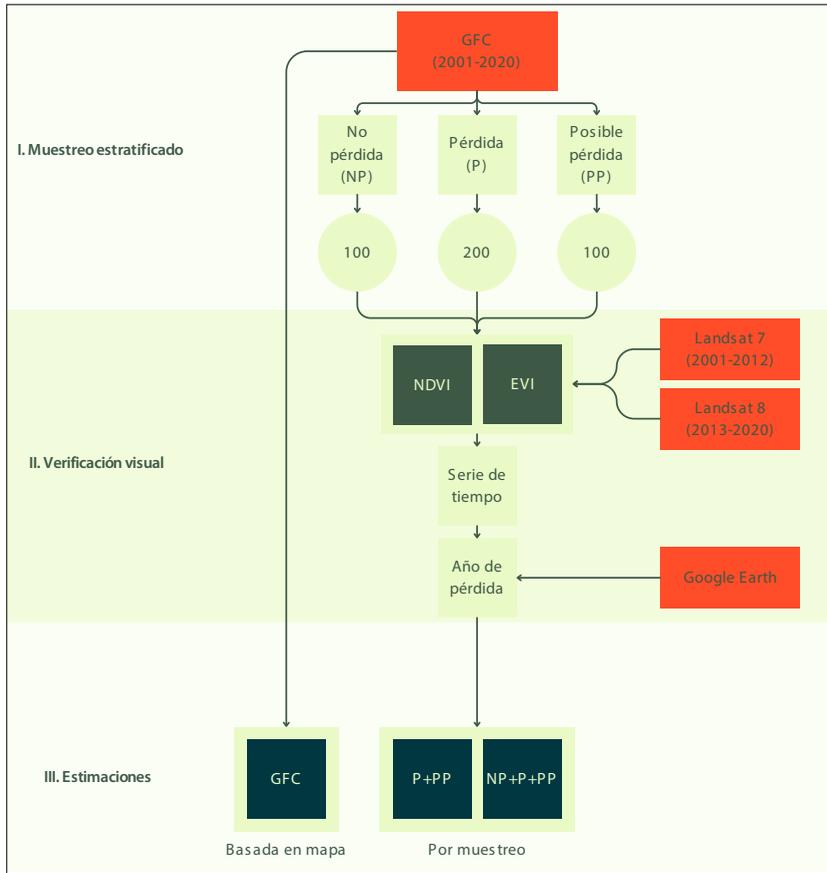


Figura 2. Metodología seguida para llevar a cabo las estimaciones de pérdida de cobertura forestal. En rojo se señalan las imágenes utilizadas y en azul las estimaciones calculadas.

la cobertura del dosel de los agroecosistemas de café (por ejemplo, degradación), así como la remoción total de la cobertura forestal (i.e. deforestación), la cual fue usualmente remplazada por cultivos comerciales y pastizales. La verificación visual fue llevada a cabo por el primer autor dos veces para asegurar la precisión de la interpretación.

Para calcular el área inicial de cobertura forestal para el año 2000 y el área de pérdida anual para el periodo 2001-2020 en cada región evaluada usamos la siguiente ecuación (Stehman, 2013; Turubanova *et al.*, 2018).

$$\hat{A} = A_{tot} * \sum_{h=1}^H \frac{N_h}{N} \bar{y}_h$$

donde:  
 $\hat{A}$  – Área estimada de pérdida de cobertura forestal

$A_{tot}$  – Área total de bosque dentro del área de estudio

$\bar{y}_h = \frac{\sum y_u}{n_h}$  – media de los valores  $y_u$  en la categoría h

$y_u = 1$  si el pixel u es interpretado como ‘pérdida de cobertura forestal en el año 20xx’, y 0 si no

H – Número de categorías muestreadas

$n_h$  – Tamaño de muestra (número de pixeles muestreados) en la categoría h

$N_h$  – Número total de pixeles en la categoría h

N – Número total de pixeles de bosque en el área de estudio

El error estándar fue estimado usando la siguiente ecuación:

$$SE(\hat{A}) = A_{tot} * \sqrt{\sum_{h=1}^H \left(\frac{N_h}{N}\right)^2 \frac{\bar{y}_h(1 - \bar{y}_h)}{n_h - 1}}$$

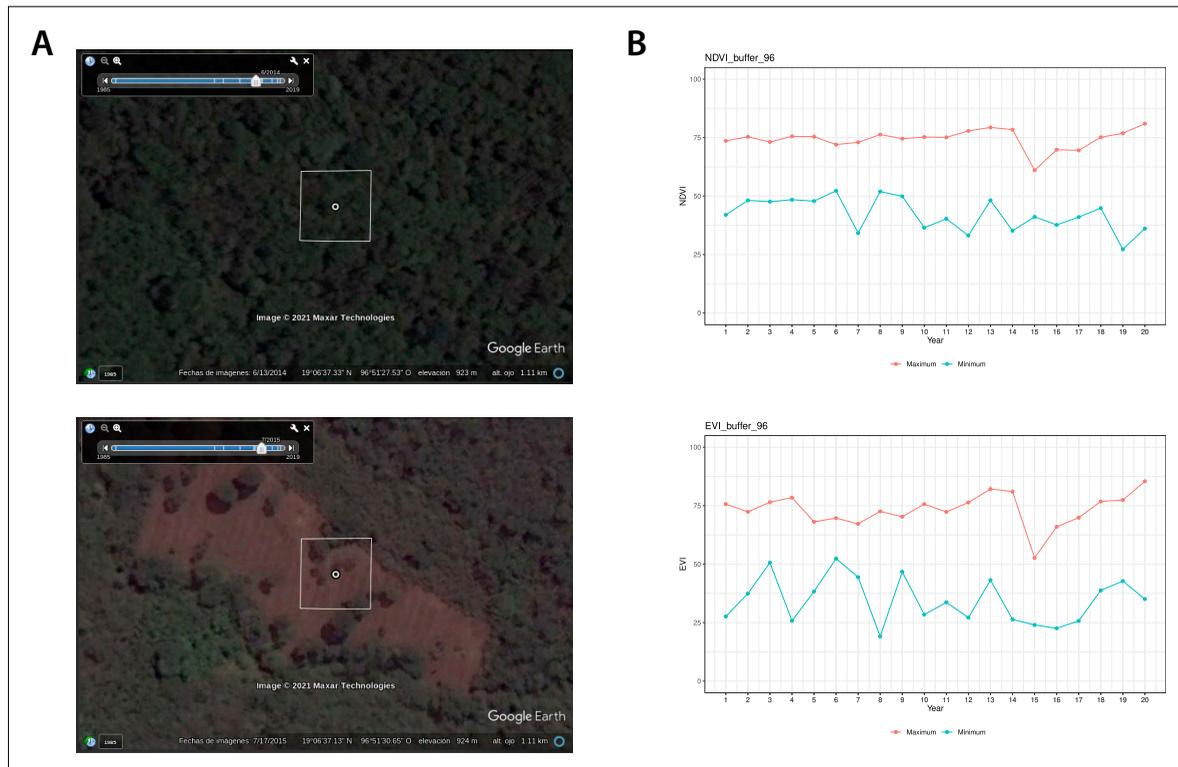


Figura 3. Ejemplo de imágenes usadas para verificar la pérdida de cobertura forestal. A. Establecimos visualmente el periodo en el cual la pérdida de cobertura ocurrió (junio de 2014-julio de 2015 en este ejemplo). B. Usamos la serie de tiempo para verificar el año en el cual ambos índices disminuyeron dentro del rango de tiempo establecido en A (2015 en este ejemplo).

Para evaluar si las estimaciones por muestreo de pérdida de cobertura forestal difirieron de las estimaciones basadas en el mapa, calculamos y comparamos el área de pérdida de cobertura forestal para el periodo 2001-2020 usando: 1) una estimación basada en el mapa a partir de los datos de GFC; 2) una estimación por muestreo utilizando solo las categorías de *Pérdida* y *Posible pérdida*; y 3) una estimación por muestreo considerando todas las categorías. Realizamos dos estimaciones por muestreo distintas para probar si la inclusión de la pérdida observada en las categorías de *Pérdida posible* y *No pérdida* tuvo un efecto en las estimaciones. Para comparar entre estimaciones, calculamos el cambio relativo del área estimada por los procedimientos por muestreo en relación con las estimaciones basadas en mapas. Para comparar los patrones temporales de pérdida, generamos series de tiempo de la pérdida anual de cobertura forestal para cada estimación.

Para las estimaciones basadas en muestreo, calculamos una media móvil de tres años para suavizar las fluctuaciones anuales de pérdida de cobertura forestal y ayudar a identificar las tendencias de cambio (Linke *et al.*, 2017). Para los años 2001 y 2020, la media móvil fue calculada usando solo el año posterior y el año anterior, respectivamente.

Dado que los datos usados fueron generados usando satélites con distintas sensibilidades para detectar cambios en la cobertura forestal (Landsat 7 de 2001 a 2012 y Landsat 8 de 2013 en adelante), verificamos: 1) si el año asignado a los píxeles marcados como *Pérdida* coincidieron con el año observado al realizar el muestreo; 2) si coincidieron dentro de  $\pm 1$  año, o 3) si ocurrieron dos o más años antes o después de lo reportado. Con esta información evaluamos la precisión temporal de los datos de GFC para detectar la pérdida de cobertura forestal en el área de estudio.

## RESULTADOS

El porcentaje de puntos correctamente asignado como *Pérdida* fue mayor del 90% para todas las regiones, con un valor mínimo de 92% (Zongolica) y un máximo de 98% (Huatusco). El porcentaje de puntos en la categoría de *Posible pérdida* (píxeles reportados como bosques adyacentes a píxeles de *Pérdida*) donde detectamos una pérdida de cobertura fue alto, entre 53% (Zongolica) y 65% (Córdoba). En cuanto a la categoría de *No pérdida*, el porcentaje de puntos donde observamos disminución fue considerable, con valores entre 23% y 26% (Huatusco y Coatepec, respectivamente; Cuadro 1).

El área de pérdida de cobertura forestal calculada a partir de la estimación basada en el mapa fue de 1433 ha (Coatepec), 699 ha (Córdoba), 1214 ha (Huatusco), y 388 ha (Zongolica). Al realizar las estimaciones por muestreo considerando solo la pérdida observada en las categorías de *Pérdida* y *Pérdida posible*, el área estimada se incrementó entre 348% y 396%. Al incluir la pérdida estimada en la categoría de *No pérdida*, la estimación de área de pérdida de cobertura forestal incrementó drásticamente, con valores que oscilaron entre 3057% y 7150% (Cuadro 2).

Al hacer la evaluación de las series de tiempo de pérdida de cobertura forestal, la estimación basada en el mapa mostró patrones similares para todas las regiones, con un periodo de pérdida relativamente estable de 2001 a 2012 y un incremento alto después de 2013 (Figura 4A). La estimación por muestreo usando las categorías de *Pérdida* y *Pérdida posible* (Figura 4B) muestra un patrón similar al de la estimación basada en el mapa, con un leve incremento principalmente entre 2001 y 2012. Al incluir la categoría de *No pérdida*, la estimación por muestreo mostró un incremento en la pérdida de cobertura forestal en el periodo de 2001-2012 (Figura 4C; Apéndice 1).

El año de pérdida observada en el muestreo coincidió entre 49% y 64.5% con el año asignado en los datos del GFC (Cuadro 3). El porcentaje de coincidencias se incrementó entre 59.5% y 77.5% al considerar los años inmediatamente antes y después del año asignado en los datos originales. Hubo una cantidad considerable de puntos de muestreo

Cuadro 1. Porcentaje de puntos de muestreo observados como pérdida en la cobertura forestal en la estimación por muestreo. Los valores corresponden a cada categoría evaluada: P = *Pérdida* (píxeles donde la pérdida de cobertura forestal fue originalmente reportada); PP = *Posible pérdida* (píxeles adyacentes a píxeles de *Pérdida*); NP = *No pérdida* (píxeles donde no se reportó pérdida en la cobertura forestal).

Región	P	PP	NP
Coatepec	95%	57%	26%
Córdoba	94.5%	65%	25%
Huatusco	98%	55%	23%
Zongolica	92%	53%	24%

Cuadro 2. Estimaciones de área de pérdida de cobertura forestal (hectáreas) para el periodo 2001-2020 calculadas con tres distintos procedimientos. El porcentaje en paréntesis indica el incremento en pérdida de cobertura forestal relativa a la estimación basada en el mapa. P = *Pérdida*; PP = *Posible pérdida*; NP = *No pérdida*.

Región	Basado en mapa	Por muestreo (P + PP)	Por muestreo (NP + PP + P)
Coatepec	1433	5102 (356%)	45 808 (3196%)
Córdoba	699	2624 (375%)	49 982 (7150%)
Huatusco	1214	4226 (348%)	37 116 (3057%)
Zongolica	388	1538 (396%)	24 090 (6208%)

(entre 15% y 28%) en los que la pérdida fue detectada dos o más años después de que ocurrió. Por otro lado, en una pequeña cantidad de puntos de muestreo, la pérdida fue detectada más de dos años antes de que tuviera lugar (de 1% a 5.5%).

## DISCUSIÓN

La disponibilidad de datos espacialmente explícitos para el monitoreo de las dinámicas de cobertura del suelo ha permitido a los investigadores, profesionales y tomadores de decisiones a evaluar las tendencias locales, regionales y nacionales de

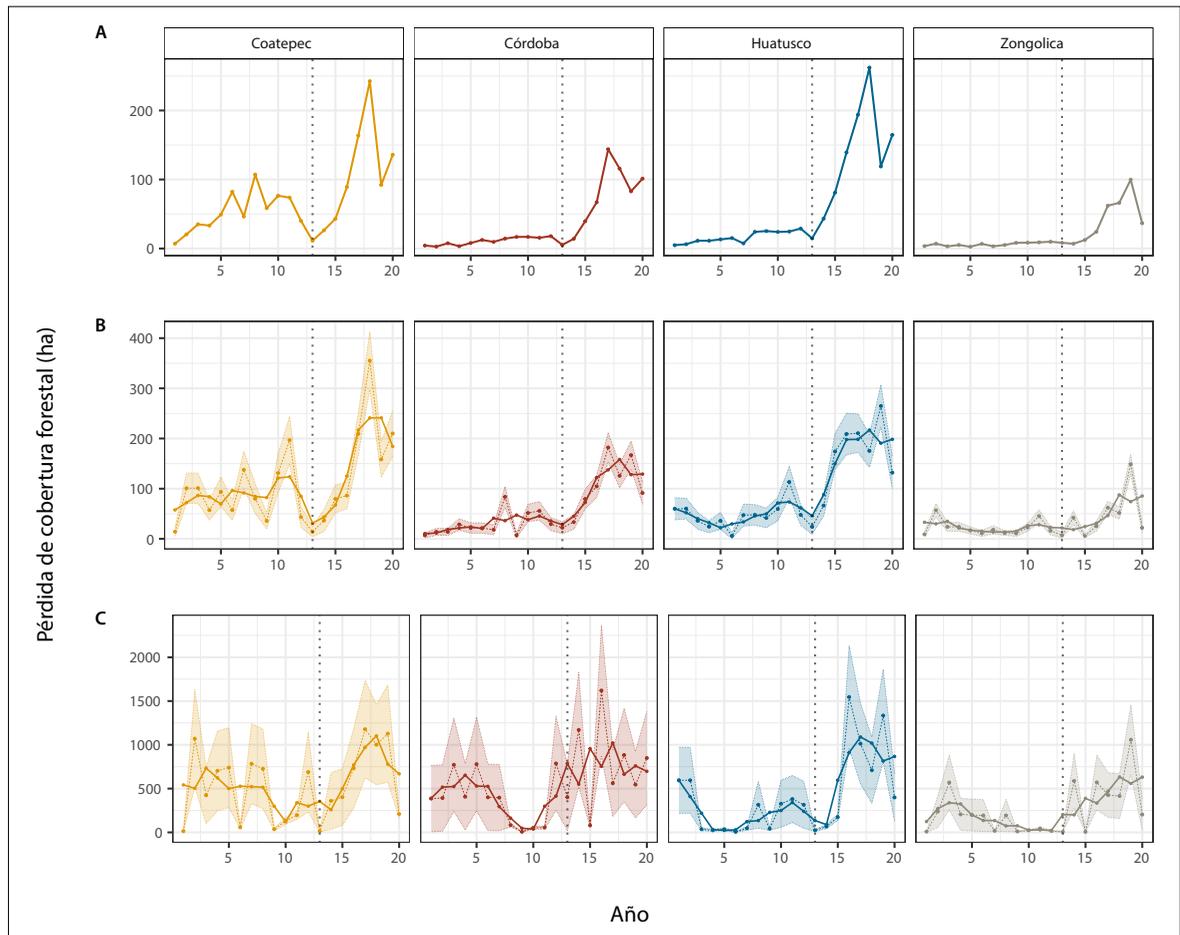


Figura 4. Estimaciones de área de pérdida de cobertura forestal (ha) para cada año para el periodo 2001-2020. A. Estimación basada en el mapa. B. Estimación por muestreo usando las categorías Pérdida y Posible Pérdida. C. Estimación por muestreo usando No pérdida, Pérdida y Posible Pérdida. La línea punteada vertical indica el año 2013, cuando hubo un cambio en el satélite usado para generar los datos de GFC. Para B y C, los puntos representan los valores estimados para cada año, la región sombreada el error estándar y la línea continua la media móvil calculada usando una ventana temporal de tres años. Nótese la diferencia en escalas para las tres estimaciones.

Cuadro 3. Porcentaje de puntos donde el año reportado en los datos de GFC coincidieron con el año observado en el muestreo o presentaron una diferencia temporal.

Región	Coincidencia	Coincidencia ±1 año	Detectado dos o más años después	Detectado dos o más años antes
Coatepec	57.5%	74.5%	15%	5.5%
Córdoba	63%	75.5%	16%	3%
Huatusco	64.5%	77.5%	19.5%	1%
Zongolica	49%	59.5%	28%	4.5%

cambio del suelo. Sin embargo, a causa de las metodologías usadas en la elaboración de estos datos (por ejemplo, la escala global oculta la heterogeneidad regional, las limitaciones de los datos de entrenamiento y el algoritmo utilizado), las estimaciones basadas en mapas pueden reportar tendencias de cambio imprecisas al ser usadas en paisajes tropicales complejos, donde el minifundismo es común. Al ser usadas en estos contextos, encontramos que las estimaciones basadas en mapas usando los datos de GFC pueden subestimar ampliamente el área de pérdida de cobertura forestal y los patrones temporales inferidos pueden estar sesgados.

La base de datos de GFC define la cobertura forestal como cualquier pixel con vegetación mayor a 5 m de altura, y la pérdida de bosque como la remoción de todos los árboles dentro de un pixel (Hansen *et al.*, 2013). Dada la importancia socioambiental de los agroecosistemas de café de sombra en nuestra área de estudio, consideramos como deforestación a la transición de agrobosque de café de sombra a otros cultivos (como en el caso de las plantaciones de plátano, cítricos, caña) y a la degradación forestal (por ejemplo, agroecosistemas de café degradados). Reconocemos que el incremento drástico en la pérdida de cobertura forestal que detectamos después de realizar las estimaciones por muestreo podría deberse a nuestra definición de deforestación. La definición, operacionalización y detección de la degradación forestal a través de técnicas de percepción remota representa un tema que ha sido pasado por alto en bases de datos globales, incluyendo el usado en nuestra evaluación (Hansen *et al.*, 2014; Tropek *et al.*, 2014; Ghazoul *et al.*, 2015; Gao *et al.*, 2020). Sin embargo, dado el predominio de este proceso en los paisajes tropicales (Ellis *et al.*, 2020; Matricardi *et al.*, 2020; Qin *et al.*, 2021), su omisión podría llevar a conclusiones erróneas con respecto a las dinámicas de cambio en la cobertura forestal.

La escala subnacional de nuestra evaluación podría explicar las grandes diferencias entre las estimaciones basadas en el mapa y las estimaciones por muestreo. La base de datos fue elaborada con una perspectiva global, y hay evidencia de que se desempeña mejor a escalas supranacionales o

nacionales (Hansen *et al.*, 2013; Tyukavina *et al.*, 2015; Turubanova *et al.*, 2018). Sin embargo, su implementación a escalas locales-regionales representa un reto importante (McRoberts *et al.*, 2016; Milodowski *et al.*, 2017; Galiatsatos *et al.*, 2020; Kinnebrew *et al.*, 2022). Por consiguiente, el uso de estimaciones por muestreo puede ayudar a superar esta problemática, especialmente en áreas donde es escasa la disponibilidad de mapas locales de cobertura del suelo o están desactualizados (McRoberts *et al.*, 2016).

El porcentaje de falsos positivos (puntos de muestreo que indicaron deforestación en lugares donde no ocurrió) fue similar (2% a 8%) a lo reportado para Latinoamérica (alrededor del 4%; Tyukavina *et al.*, 2015), Brasil (7.14%) e Indonesia (4.29%; Turubanova *et al.*, 2018), pero menor a lo informado para el bioma tropical (13%; Hansen *et al.*, 2013). Sin embargo, el número de puntos donde observamos pérdida en la categoría de Pérdida posible (pixeles adyacentes a aquellos reportados como Pérdida), fue mucho mayor que en otros estudios, con valores que oscilaron de 53% a 65%, en comparación con 25% a 39.9% en otros estudios (Turubanova *et al.*, 2018). Esto fue similar para el número de falsos negativos (puntos de muestreo que no reportaron pérdida forestal en lugares donde sí ocurrió) y, de hecho, fue mayor que lo observado en otros estudios: 23% a 26%, más alto que lo reportado en el bioma tropical (16.9%, de acuerdo con Hansen *et al.*, 2013) y en Latinoamérica (17%; Tyukavina *et al.*, 2015). Además, estos valores son drásticamente mayores que los reportados para Brasil (0.44%), la República Democrática del Congo (0.4%) e Indonesia (0.36%; Turubanova *et al.*, 2018). La gran proporción de falsos negativos encontrados en este estudio es probablemente el resultado de las características del paisaje. La complejidad topográfica y la presencia continua de nubes en el área de estudio, características típicas de muchos paisajes montañosos en México y Centroamérica (Karmalkar *et al.*, 2011; Cunningham *et al.*, 2019), podrían disminuir la capacidad de la base de datos de detectar la pérdida de cobertura forestal. Adicionalmente, el paisaje está compuesto de un mosaico de distintas coberturas creadas por

pequeñas unidades de producción cuyos cambios producen perturbaciones muy pequeñas para ser detectadas con precisión (Milodowski *et al.*, 2017; Turubanova *et al.*, 2018; Cunningham *et al.*, 2019).

La congruencia de la escala temporal (años) de pérdida de cobertura forestal predicha y observada fue de 49%-64.5% para coincidencias exactas y aumentó a 59.5%-77.5% para coincidencias dentro  $\pm 1$  año. Estos valores son notoriamente más bajos que lo reportado por Hansen *et al.* (2013), quien encontró que el 75.2% de los puntos de muestreo fue asignado correctamente, y el 96.7% conferido dentro de  $\pm 1$  de la pérdida observada. Asimismo, Linke *et al.* (2017) encontraron que en un bosque templado, 84.6% puntos fueron atribuidos correctamente para el año en que ocurrió la pérdida de cobertura, mientras que 92.1% fueron correctamente asignados dentro del rango de un año. Sin embargo, Milodowski *et al.* (2017) encontraron que los datos no lograron detectar perturbaciones pequeñas (<2 hectáreas), reportándolas como pérdida solo cuando las perturbaciones se habían expandido en años posteriores, sesgando por lo tanto la detección de pérdida de cobertura forestal a años posteriores. La mayoría de las imprecisiones temporales encontradas en nuestro estudio consistieron en la detección de pérdida más de dos años después de la pérdida observada. Por consiguiente, es posible que la presencia de pequeñas perturbaciones en la región, así como el uso de distintos satélites en los últimos años del periodo estudiado hayan inclinado los patrones temporales de pérdida forestal hacia años más recientes. Esto es visible en las series de tiempo, donde hay un cambio notable en el patrón de pérdida anual en el periodo 2001-2012, antes del cambio de satélites.

El muestreo probabilístico usado en este estudio permite reportar tendencias de pérdida de cobertura forestal más precisas; sin embargo, dicha metodología presenta algunos retos relacionados con el diseño muestral y la información espacial (Stehman y Foody, 2019). Si bien es recomendable calcular el tamaño muestral por medio de fórmulas pertinentes, en la práctica, el tamaño muestral está influido por elecciones subjetivas relacionadas con los objetivos buscados y las capacidades técnicas y

económicas del equipo de trabajo (Olofsson *et al.*, 2014; Boschetti *et al.*, 2016; Stehman y Foody, 2019). Por otra parte, la asignación de los puntos de muestreo a las distintas categorías de suelo presentes en el mapa depende de un compromiso entre los distintos objetivos buscados (Stehman, 2012; Wagner y Stehman, 2015; Stehman y Foody, 2019). Así, el uso del muestreo probabilístico estratificado será más apropiado cuando el objetivo principal del trabajo sea el cálculo de estimaciones no sesgadas de cambio de uso del suelo, pero menos apropiado para calcular la precisión general del mapa de referencia (Stehman y Foody, 2019). Por último, los análisis basados en muestreos probabilísticos implican la pérdida de la información espacial contenida en el mapa de referencia, lo que impide generar análisis espaciales a partir de las estimaciones calculadas (Turubanova *et al.*, 2018). Recomendamos tener en cuenta lo anterior al usar muestreos probabilísticos para el análisis de dinámicas de cobertura del suelo.

## RECOMENDACIONES

La base de datos de GFC brinda información sumamente valiosa y oportuna para el monitoreo de cambio de uso de suelo a grandes escalas. Sin embargo, para tendencias locales ponemos énfasis en la importancia de llevar a cabo estimaciones por muestreo de la pérdida de cobertura forestal utilizando la estratificación propuesta para la estimación apropiada de áreas. A pesar de que usamos dos distintas estimaciones por muestreo, recomendamos hacer uso exclusivamente de aquella que incluye todas las categorías, ya que la exclusión de la categoría de *No Pérdida* podría llevar a estimaciones sesgadas. Asimismo, en escalas subnacionales, es necesario considerar la posible incidencia de falsos negativos, particularmente en paisajes heterogéneos con una presencia dominante de minifundistas, como es el caso del presente estudio. Por otra parte, recomendamos realizar este tipo de estimación cuando se usen los datos integrados (v1.2 y posterior) para análisis temporales, pues una buena proporción de la pérdida de cobertura forestal ocurrió antes del año reportado. Estas es-

timaciones pueden servir para prevenir inferencias erróneas relacionadas con los patrones temporales de pérdida de cobertura forestal.

## REFERENCIAS

- Armenteras, D., Espelta, J. M., Rodríguez, N., y Retana, J. (2017). Deforestation dynamics and drivers in different forest types in Latin America: Three decades of studies (1980–2010). *Global Environmental Change*, 46, 139–147. <https://doi.org/10.1016/j.gloenvcha.2017.09.002>
- Blackman, A., y Villalobos, L. (2021). Use Forests or Lose Them? Regulated Timber Extraction and Tree Cover Loss in Mexico. *Journal of the Association of Environmental and Resource Economists*, 8(1), 125–163. <https://doi.org/10.1086/710837>
- Boschetti, L., Stehman, S. V. y Roy, D. (2016). A stratified random sampling design in space and time for regional to global scale burned area product validation. *Remote Sensing of Environment* 186, 465–478. <https://dx.doi.org/10.1016/j.rse.2016.09.016>
- Ceddia, M. G. (2019). The impact of income, land, and wealth inequality on agricultural expansion in Latin America. *Proceedings of the National Academy of Sciences*, 116(7), 2527–2532. <https://doi.org/10.1073/pnas.1814894116>
- Cho, K., Goldstein, B., Gounaridis, D., y Newell, J. P. (2021). Where does your guacamole come from? Detecting deforestation associated with the export of avocados from Mexico to the United States. *Journal of Environmental Management*, 278, 111482. <https://doi.org/10.1016/j.jenvman.2020.111482>
- Chowdhury, R. R. (2006). Driving forces of tropical deforestation: The role of remote sensing and spatial models. *Singapore Journal of Tropical Geography*, 27(1), 82–101. <https://doi.org/10.1111/j.1467-9493.2006.00241.x>
- Cunningham, D., Cunningham, P., y Fagan, M. E. (2019). Identifying Biases in Global Tree Cover Products: A Case Study in Costa Rica. *Forests*, 10(10), 10. <https://doi.org/10.3390/f10100853>
- Ellis, E. A., Romero Montero, J. A., y Hernández Gómez, I. U. (2017). Deforestation Processes in the State of Quintana Roo, Mexico: The Role of Land Use and Community Forestry. *Tropical Conservation Science*, 10, 1940082917697259. <https://doi.org/10.1177/1940082917697259>
- Ellis, E., Martínez, A., Ortega, M., Gómez, I., y Castillo, D. (2020). Forest cover dynamics in the Selva Maya of Central and Southern Quintana Roo, Mexico: Deforestation or degradation? *Journal of Land Use Science*, 15(1), 25–51. <https://doi.org/10.1080/1747423X.2020.1732489>
- Ellis, E., Sierra-Huelsz, J., Ceballos, G., Binnquist, C., y Cerdan, C. (2020). Mixed Effectiveness of REDD plus Subnational Initiatives after 10 Years of Interventions on the Yucatan Peninsula, Mexico. *FORESTS*, 11(9). <https://doi.org/10.3390/f11091005>
- Figueroa, D., Galeana-Pizana, J., Nunez, J., Gomez, C., Hernandez-Castro, J., Sanchez-Ramirez, M., y Garduno, A. (2021). Assessing drivers and deterrents of deforestation in Mexico through a public policy tool. The adequacy of the index of economic pressure for deforestation. *Forest Policy and Economics*, 133. <https://doi.org/10.1016/j.forpol.2021.102608>
- Foley, J. A., Ramankutty, N., Brauman, K. A., Cassidy, E. S., Gerber, J. S., Johnston, M., Mueller, N. D., O'Connell, C., Ray, D. K., West, P. C., Balzer, C., Bennett, E. M., Carpenter, S. R., Hill, J., Monfreda, C., Polasky, S., Rockström, J., Sheehan, J., Siebert, S., ... Zaks, D. P. M. (2011). Solutions for a cultivated planet. *Nature*, 478(7369), 7369. <https://doi.org/10.1038/nature10452>
- Friedl, M. A., McIver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., y Schaaf, C. (2002). Global land cover mapping from MODIS: Algorithms and early results. *Remote Sensing of Environment*, 83(1), 287–302. [https://doi.org/10.1016/S0034-4257\(02\)00078-0](https://doi.org/10.1016/S0034-4257(02)00078-0)
- Galiatsatos, N., Donoghue, D. N. M., Watt, P., Bholanath, P., Pickering, J., Hansen, M. C., y Mahmood, A. R. J. (2020). An Assessment of Global Forest Change Datasets for National Forest Monitoring and Reporting. *Remote Sensing*, 12(11), 11. <https://doi.org/10.3390/rs12111790>
- Gao, Y., Skutsch, M., Paneque-Gálvez, J., y Ghilardi, A. (2020). Remote sensing of forest degradation: A review. *Environmental Research Letters*, 15(10), 103001. <https://doi.org/10.1088/1748-9326/abaad7>
- Ghazoul, J., Burivalova, Z., Garcia-Ulloa, J., y King, L. A. (2015). Conceptualizing Forest Degradation. *Trends in Ecology y Evolution*, 30(10), 622–632. <https://doi.org/10.1016/j.tree.2015.08.001>
- González-Fernández, A., Segarra, J., Sunny, A., y Coururier, S. (2022). Forest cover loss in the Nevado de Toluca volcano protected area (Mexico) after the change to a less restrictive category in 2013. *Biodiversity and Conservation*, 31(3), 871–894. <https://doi.org/10.1007/s10531-022-02368-y>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., y Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone.

- Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Haines, K. (2021). Oaxaca and global forest governance: Indigenous autonomy, local institutions, and forest outcomes in Southern Mexico. *Journal of Political Ecology*, 28, 25–46.
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D., Stehman, S. V., Goetz, S. J., Loveland, T. R., Komareddy, A., Egorov, A., Chini, L., Justice, C. O., y Townshend, J. R. G. (2013). High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 342(6160), 850–853. <https://doi.org/10.1126/science.1244693>
- Hansen, M., Potapov, P., Margono, B., Stehman, S., Turubanova, S., y Tyukavina, A. (2014). Response to Comment on “High-resolution global maps of 21st-century forest cover change”. *Science*, 344(6187), 981–981. <https://doi.org/10.1126/science.1248817>
- Hijmans, R.J. y van Etten, J. (2012). raster: Geographic analysis and modeling with raster data. R package version 2.0-12. <https://CRAN.R-project.org/package=raster>
- Izquierdo-Tort, S., Ortiz-Rosas, F., y Vázquez-Cisneros, P. A. (2019). ‘Partial’ participation in Payments for Environmental Services (PES): Land enrolment and forest loss in the Mexican Lacandona Rainforest. *Land Use Policy*, 87, 103950. <https://doi.org/10.1016/j.landusepol.2019.04.011>
- Jun, C., Ban, Y., y Li, S. (2014). Open access to Earth land-cover map. *Nature*, 514(7523), 7523. <https://doi.org/10.1038/514434c>
- Karmalkar, A. V., Bradley, R. S., y Diaz, H. F. (2011). Climate change in Central America and Mexico: Regional climate model validation and climate change projections. *Climate Dynamics*, 37(3), 605. <https://doi.org/10.1007/s00382-011-1099-9>
- Kinnebrew, E., Ochoa-Brito, J. I., French, M., Mills-Novoa, M., Shoffner, E., y Siegel, K. (2022). Biases and limitations of Global Forest Change and author-generated land cover maps in detecting deforestation in the Amazon. *PLOS ONE*, 17(7), e0268970. <https://doi.org/10.1371/journal.pone.0268970>
- Klass, K., Belle, S. V., Campos-Villanueva, A., Malabet, F. M., y Estrada, A. (2020). Effects of variation in forest fragment habitat on black howler monkey demography in the unprotected landscape around Palenque National Park, Mexico. *PeerJ*, 8, e9694. <https://doi.org/10.7717/peerj.9694>
- Krylov, A., Steininger, M. K., Hansen, M. C., Potapov, P. V., Stehman, S. V., Gost, A., Noel, J., Talero Ramirez, Y., Tyukavina, A., Di Bella, C. M., Ellis, E. A., y Ellis, P. (2018). Contrasting tree-cover loss and subsequent land cover in two neotropical forest regions: Sample-based assessment of the Mexican Yucatán and Argentine Chaco. *Journal of Land Use Science*, 13(6), 549–564. <https://doi.org/10.1080/1747423X.2019.1569169>
- Lawrence, T. J., Stedman, R. C., Morreale, S. J., y Taylor, S. R. (2019). Rethinking Landscape Conservation: Linking Globalized Agriculture to Changes to Indigenous Community-Managed Landscapes. *Tropical Conservation Science*, 12, 1940082919889503. <https://doi.org/10.1177/1940082919889503>
- Linke, J., Fortin, M.-J., Courtenay, S., y Cormier, R. (2017). High-resolution global maps of 21st-century annual forest loss: Independent accuracy assessment and application in a temperate forest region of Atlantic Canada. *Remote Sensing of Environment*, 188, 164–176. <https://doi.org/10.1016/j.rse.2016.10.040>
- López-Arcadia, C.A. (2022). Después de la roya: red de cafecultura y cambios en la cobertura forestal del paisaje cafetalero del centro de Veracruz. [Tesis de Maestría]. Instituto de Ecología, A.C.
- Matricardi, E. A. T., Skole, D. L., Costa, O. B., Pedlowski, M. A., Samek, J. H., y Miguel, E. P. (2020). Long-term forest degradation surpasses deforestation in the Brazilian Amazon. *Science*, 369(6509), 1378–1382. <https://doi.org/10.1126/science.abb3021>
- McRoberts, R. E., Vibrans, A. C., Sannier, C., Næsset, E., Hansen, M. C., Walters, B. F., y Lingner, D. V. (2016). Methods for evaluating the utilities of local and global maps for increasing the precision of estimates of subtropical forest area. *Canadian Journal of Forest Research*, 46(7), 924–932. <https://doi.org/10.1139/cjfr-2016-0064>
- Milodowski, D. T., Mitchard, E. T. A., y Williams, M. (2017). Forest loss maps from regional satellite monitoring systematically underestimate deforestation in two rapidly changing parts of the Amazon. *Environmental Research Letters*, 12(9), 094003. <https://doi.org/10.1088/1748-9326/aa7e1e>
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., y Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>
- Pettorelli, N., Lurance, W. F., O’Brien, T. G., Wegmann, M., Nagendra, H., y Turner, W. (2014). Satellite remote sensing for applied ecologists: Opportunities and challenges. *Journal of Applied Ecology*, 51(4), 839–848. <https://doi.org/10.1111/1365-2664.12261>
- Portillo-Quintero, C., y Smith, V. (2018). Emerging trends of tropical dry forests loss in North y Central America during 2001–2013: The role of contextual and underlying drivers. *Applied Geography*, 94, 58–70. <https://doi.org/10.1016/j.apgeog.2018.03.011>

- Powlen, K. A., Gavin, M. C., y Jones, K. W. (2021). Management effectiveness positively influences forest conservation outcomes in protected areas. *Biological Conservation*, 260, 109192. <https://doi.org/10.1016/j.biocon.2021.109192>
- Qin, Y., Xiao, X., Wigneron, J.-P., Ciais, P., Brandt, M., Fan, L., Li, X., Crowell, S., Wu, X., Doughty, R., Zhang, Y., Liu, F., Sitch, S., y Moore, B. (2021). Carbon loss from forest degradation exceeds that from deforestation in the Brazilian Amazon. *Nature Climate Change*, 11(5), 5. <https://doi.org/10.1038/s41558-021-01026-5>
- Ramirez-Reyes, C., Sims, K. R. E., Potapov, P., y Radeloff, V. C. (2018). Payments for ecosystem services in Mexico reduce forest fragmentation. *Ecological Applications*, 28(8), 1982–1997. <https://doi.org/10.1002/eap.1753>
- Sandker, M., Carrillo, O., Leng, C., Lee, D., d'Annunzio, R., y Fox, J. (2021). The Importance of High-Quality Data for REDD+ Monitoring and Reporting. *Forests*, 12(1), 1. <https://doi.org/10.3390/f12010099>
- Sannier, C., McRoberts, R. E., y Fichet, L.-V. (2016). Suitability of Global Forest Change data to report forest cover estimates at national level in Gabon. *Remote Sensing of Environment*, 173, 326–338. <https://doi.org/10.1016/j.rse.2015.10.032>
- Seymour, F., y Harris, N. L. (2019). Reducing tropical deforestation. *Science*, 365(6455), 756–757. <https://doi.org/10.1126/science.aax8546>
- Sims, K. R. E., y Alix-Garcia, J. M. (2017). Parks versus PES: Evaluating direct and incentive-based land conservation in Mexico. *Journal of Environmental Economics and Management*, 86, 8–28. <https://doi.org/10.1016/j.jeem.2016.11.010>
- Stehman, S. V. (2013). Estimating area from an accuracy assessment error matrix. *Remote Sensing of Environment*, 132, 202–211. <https://doi.org/10.1016/j.rse.2013.01.016>
- Stehman, S.V. (2014). Impact of sample size allocation when using stratified random sampling to estimate accuracy and area of land-cover change. *Remote Sensing Letters* 3(2), 111–120. <https://dx.doi.org/10.1080/01431161.2010.541950>
- Stehman, S.V. y Foody, G.M. (2019). Key issues in rigorous accuracy assessment of land cover products. *Remote Sensing of Environment*, 231, 111199. <https://doi.org/10.1016/j.rse.2019.05.018>
- Tropek, R., Sedláček, O., Beck, J., Keil, P., Musilová, Z., Šimová, I., y Storch, D. (2014). Comment on “High-resolution global maps of 21st-century forest cover change”. *Science*. <https://doi.org/10.1126/science.1248753>
- Turubanova, S., Potapov, P. V., Tyukavina, A., y Hansen, M. C. (2018). Ongoing primary forest loss in Brazil, Democratic Republic of the Congo, and Indonesia. *Environmental Research Letters*, 13(7), 074028. <https://doi.org/10.1088/1748-9326/aacd1c>
- Tyukavina, A., Baccini, A., Hansen, M. C., Potapov, P. V., Stehman, S. V., Houghton, R. A., Krylov, A. M., Turubanova, S., y Goetz, S. J. (2015). Aboveground carbon loss in natural and managed tropical forests from 2000 to 2012. *Environmental Research Letters*, 10(7), 074002. <https://doi.org/10.1088/1748-9326/10/7/074002>
- Wagner, J.E. y Stehman, S.V. (2015). Optimizing sample size allocation to strata for estimating area and map accuracy. *Remote Sensing of Environment*, 168, 126–133. <https://dx.doi.org/10.1016/j.rse.2015.06.027>

Apéndice 1. Área de pérdida forestal (en hectáreas) para la estimación basada en mapa, la estimación por muestreo incluyendo las categorías Pérdida y Pérdida Posible, y la estimación incluyendo todas las categorías. P: Pérdida; PP: Posible Pérdida; NP: No Pérdida; EE: Error estándar.

Región	Año	Estimación basada en mapa	Estimación P+PP ± EE	Media móvil P+PP	Estimación P+PP+NP ± EE	Media móvil P+PP+NP
Coatepec	2001	7.0	14.3±10.1	57.7	14.3±10.1	542.3
	2002	20.5	101.1±30.3	72.2	1070.2±554.7	502.9
	2003	35.1	101.1±30.3	86.5	424.1±324.5	732.6
	2004	33.2	57.3±19.9	84.4	703.4±455.0	622.5
	2005	49.2	93.9±29.5	69.5	740±455.5	500.3
	2006	82.2	57.3±19.9	96.3	57.3±19.9	527
	2007	46.3	137.6±37.1	91.6	783.7±456.1	522.4
	2008	107.1	79.9±29.8	84.5	726±455.5	515.2
	2009	58.5	35.8±15.9	82.3	35.8±15.9	297.7
	2010	76.4	131.2±39.1	121.3	131.2±39.1	121.3
	2011	73.7	196.8±47.2	123.8	196.8±47.2	339.2
	2012	40.0	43.4±20.5	84.8	689.5±455.0	300.2
	2013	11.3	14.3±10.1	31.4	14.3±10.1	354.5
	2014	26.4	36.6±21.9	43.5	359.6±323.8	258.9
	2015	43.1	79.6±27.9	67.5	402.6±324.3	498.2
	2016	89.0	86.4±26.6	125.1	732.5±455.3	771.2
	2017	163.6	209.3±42.5	216.9	1178.4±555.5	970.7
	2018	242.4	355.2±57.8	240.9	1001.3±458.2	1102.4
	2019	92.2	158.4±35.7	241.2	1127.5±555.0	779.6
	2020	135.8	210±45.1	184.2	210.0±45.1	668.8
Córdoba	2001	4.3	7.0±4.9	10.5	358.9±378.9	389.3
	2002	2.7	14.0±6.9	11.6	392.8±378.9	516.8
	2003	7.6	14.0±6.9	18.9	771.7±533.1	524.0
	2004	3.3	28.6±11.4	21.4	407.5±379.0	652.9
	2005	8.0	21.6±10.3	24.0	779.4±533.2	529.1
	2006	12.4	21.6±10.3	20.5	400.5±379.0	525.6
	2007	9.6	18.1±9.7	41.2	397.0±379.0	293.8
	2008	14.3	83.7±20.8	36.3	83.7±20.8	162.6
	2009	16.8	7.0±4.9	47.5	7.0±4.9	47.5
	2010	16.8	51.6±17.3	38.1	51.6±17.3	38.1
	2011	15.6	55.8±18.5	45.6	55.8±18.5	298.1
	2012	17.9	29.3±12.8	35.8	787±533.2	414.7
	2013	5.3	22.3±11.9	28.4	401.2±379.0	786.1
	2014	14.1	33.5±14.5	45.1	1170.1±649.7	550.3

Región	Año	Estimación basada en mapa	Estimación P+PP ± EE	Media móvil P+PP	Estimación P+PP+NP ± EE	Media móvil P+PP+NP
Córdoba	2015	39.7	79.6±19.7	72.6	79.6±19.7	956.6
	2016	67.0	104.7±22.2	122.1	1620.2±746.5	753.6
	2017	143.8	182.1±29.6	137.5	561.0±380.0	1021.5
	2018	115.7	125.7±23.5	158.2	883.4±533.6	663.4
	2019	82.9	166.8±28.0	128.0	545.7±379.9	759.4
	2020	101.2	91.4±22.0	129.1	849.1±533.5	697.4
Huatusco	2001	4.8	59.9±22.1	60.1	594.7±376.9	594.9
	2002	6.2	60.3±20.6	52.1	595.1±376.8	408.6
	2003	11.2	36.0±16.8	40.2	36.0±16.8	218.5
	2004	11.2	24.3±12.0	32.1	24.3±12.0	32.1
	2005	13.2	36.0±16.8	22.1	36.0±16.8	22.1
	2006	15.1	6.1±6.1	6.1	6.1±29.8	29.8
	2007	7.4	47.4±21.9	33.8	47.4±21.9	122.9
	2008	24.1	47.8±20.5	45.6	315.2±268.2	134.8
	2009	25.2	41.7±19.6	49.7	41.7±19.6	228.0
	2010	24.0	59.6±23.5	71.6	327.0±268.4	249.8
	2011	24.6	113.4±31.3	73.6	380.8±269.2	341.0
	2012	28.9	47.8±20.5	61.7	315.2±268.2	240.0
	2013	14.7	23.9±14.5	46.0	23.9±14.5	135.2
	2014	43.3	66.4±21.4	88.1	66.4±21.4	88.1
	2015	81.1	174.1±36.1	149.8	174.1±36.1	595.5
	2016	139.3	209.0±41.5	191.9	1546.0±587.2	910.9
	2017	193.9	210.5±38.4	198.3	1012.7±460.0	1089.6
	2018	262.2	175.3±32.9	216.8	710.0±377.7	1019.0
	2019	119.0	264.8±42.2	190.7	1334.4±528.3	814.6
	2020	164.6	132.0±31.9	198.4	399.4±269.3	866.9
Zongolica	2001	3.5	9.1±5.9	33.0	9.1±5.9	123.9
	2002	7.0	57.0±13.6	30.0	238.8±182.4	272.5
	2003	3.1	23.9±8.9	34.9	569.6±311.9	338.1
	2004	5.1	23.9±8.9	21.6	205.8±182.1	324.7
	2005	2.6	16.8±7.0	17.3	198.7±182.0	199.1
	2006	6.7	11.0±6.2	15.3	192.9±182.0	136.6
	2007	3.2	18.1±8.2	13.6	18.1±8.2	134.8
	2008	5.1	11.6±4.7	13.6	193.5±181.9	74.2
	2009	8.2	11.0±6.2	15.1	11.0±6.2	75.7
	2010	8.4	22.6±7.7	26.3	22.6±7.7	26.3
	2011	8.9	45.3±12.8	28.0	45.3±12.8	28.0

Región	Año	Estimación basada en mapa	Estimación P+PP ± EE	Media móvil P+PP	Estimación P+PP+NP ± EE	Media móvil P+PP+NP
Zongolica	2012	9.8	16.2±8.0	22.9	16.2±8.0	22.9
	2013	8.3	7.1±5.5	21.8	7.1±5.5	203.7
	2014	6.9	42.1±13.7	18.4	587.7±312.1	200.2
	2015	12.3	5.8±3.3	24.4	5.8±3.3	388.1
	2016	24.2	25.3±9.9	31.1	570.9±312.0	334.2
	2017	62.0	62.1±12.6	46.4	425.8±256.2	470.7
	2018	66.2	51.8±12.6	87.6	415.5±256.2	633.2
	2019	99.8	148.8±19.7	74.2	1058.2±398.9	559.2
	2020	36.6	22.0±8.7	85.4	203.9±182.1	631.0

