Un modelo basado en sensores remotos e inteligencia artificial para la estimación de la degradación del bosque

Maestría en Manejo Uso y Conservación del Bosque

Universidad Distrital Francisco José de Caldas

Autor

Jaime Andrés Unriza Vargas

Director

Heidy Soledad Rodríguez

Año 2021

Agradecimientos

Para el desarrollo de este trabajo agradezco a la Universidad Distrital Francisco José de Caldas por orientar los procesos investigativos, mi directora, Soledad Rodríguez por su orientación y a la profesora Ángela Parrado, por su paciencia y guía.

Por último, a Adriana Torres Martínez por su complicidad.

Tabla de contenido

Resumen 6
Abstract 6
1. Introducción 7
2. Metodología 10
3. Resultados 15
4. Discusión 17
5. Conclusiones y Recomendaciones 19
Bibliografía ..... **Error! Bookmark not defined.**

Lista de Tablas

Tabla 1. Fecha de las imágenes usadas para la identificación de la degradación y los cambios, con proporción de nubes menores al 10% en la zona de estudio 25

Tabla 2. Desempeño de los algoritmos de machine learning utilizados para el entrenamiento a partir de los datos obtenidos en el muestreo (10%) proporción entrenamiento 70%-30%. 26

Tabla 3. Desempeño de los algoritmos de machine learning utilizados para el entrenamiento en la clasificación de bosques, áreas deforestadas y áreas degradadas; a partir de los datos obtenidos en el muestreo (10%) proporción entrenamiento 45%-65%. 27

Tabla 4. Matriz de confusión, asociada para la validación de los datos del área de estudio a partir del algoritmo de Neural Network-Trilayered Neural Network. 27

Tabla de Figuras

Figura 1. Zona de estudio..... 28

Figura 2. Flujo propuesto Modelo SIG. 29

Figura 3. Resultado de la identificación de áreas con coberturas boscosas y no boscosas en el periodo 1991 – 2020..... 30

Figura 4. Resultado de la clasificación binaria en relación con las coberturas que cambiaron de bosque a no bosque-Áreas deforestadas, relación año a año..... 31

Figura 5. Resultado de la clasificación a partir del algoritmo de Neural Network-Trilayered Neural Network 32

Figura 6. Áreas clasificadas con el modelo Neural Network-Trilayered Neural Network. ..... **Error! Bookmark not defined.**

Resumen

La degradación de los bosques y la deforestación son problemáticas medioambientales que disminuyen la prestación de los servicios ecosistémicos. Una posible solución para la identificación y seguimiento de estas problemáticas son los sistemas de monitoreo a partir de sensores remotos, debido a la utilidad de la información generada a partir de los satelites activos y pasivos. A pesar de esto, existe limitación en las zonas tropicales debido a la alta presencia de nubes a lo largo del año, lo que consecuentemente limita la cantidad de información. De esta manera, el presente estudio plantea un modelo que hace uso de sensores remotos e inteligencia artificial para la identificación de la degradación del bosque con limitada información haciendo uso del NDVI, su variación entre ventanas de tiempo en el periodo de 1990 - 2019 y herramientas de *machine learning*. Este estudio se desarrolló en bosque húmedo tropical en el municipio de Mapiripán (Meta, Colombia), zona donde se han identificado problemáticas de cultivos ilícitos y deforestación. Para enfrentar tal problemática, se planteó un modelo a partir de sistemas de información geográfica para la identificación de la degradación que se encuentra relacionada con la deforestación, al comparar 7 algoritmos de *machine learning* se encontró que el algoritmo de redes neuronales de tres capas ocultas (modelo con mayor desempeño, precisión del 75,25%) y el segundo modelo corresponde al algoritmo de Discriminante lineal (precisión 73.25%) muestran mejores desempeños a pesar de su limitada información. Adicionalmente, se logró identificar que un 60% de las áreas deforestadas sufrieron algún grado de intervención que llevó a la deforestación, con lo cual, se pudo evitar este mediante un sistema de monitoreo y de alertas tempranas.

Palabras claves: *Machine learning*, NDVI, redes neuronales de tres capas ocultas.

Abstract

Forest degradation and deforestation are environmental problems that diminish the provision of ecosystem services. A possible solution for the identification and monitoring of these problems are monitoring systems based on remote sensing; information from active and passive satellites offers a great deal of useful information. Despite this, there is a limitation in tropical areas due to the high presence of clouds throughout the year, which consequently limits the amount of information. Thus, this study proposes a model that makes use of remote sensing and artificial intelligence for the identification of forest degradation with limited information using NDVI, its variation between time

windows in the period 1990 - 2019 and machine learning tools. This study was developed in tropical rainforest in the municipality of Mapiripán (Meta, Colombia), an area where problems of illicit crops and deforestation have been identified. To address this problem, a model was proposed based on geographic information systems for the identification of degradation related to deforestation. When comparing 7 machine learning algorithms, it was found that the neural network algorithm of three hidden layers (model with the best performance, 75.25% accuracy) and the second model corresponds to the linear discriminant algorithm (73.25% accuracy) show better performance despite its limited information. Additionally, it was possible to identify that 60% of the deforested areas suffered some degree of intervention that led to deforestation, which could be avoided through a monitoring and early warning system.

Keywords: Machine learning, NDVI, Trilayered neural network.

1. Introducción

La deforestación y la degradación en el mundo son problemas medioambientales que generan un impacto negativo sobre la diversidad y los servicios ecosistémico de los bosques, en los que se incluye la regulación hídrica y la regulación del cambio climático (Bologna & Aqino, 2020). En los bosques de la Amazonía se ha registrado un aumento de la tasa anual de deforestación llegando a 11,08 millones de hectáreas (INPE, 2020). La Amazonía colombiana no es ajena a esta tendencia, en donde 158.894 ha se han deforestado en el año, un 62% se localiza en esta zona del país (Ideam, 2019).

La degradación de los bosques húmedos tropicales en Latinoamérica se estima en 5.6 millones de ha (Armenteras et al., 2016), sin embargo, según INPE (2021) esta cifra puede estar altamente subestimada por las limitaciones en la definición y estimación de degradación de los bosques. Esto se debe a que la degradación no tiene una definición internacional aceptada (Hirschmugl et al., 2017). Generalmente se puede definir como una perturbación causada por una intervención humana en un paisaje forestal que da lugar a emisiones de carbono, pero no a un cambio de cobertura terrestre (GFOI, 2016). En comparación con los bosques intactos, los bosques degradados suelen tener menos biomasa, ser menos productivos y con menor cobertura de copas (Bullock et al., 2019).

A pesar de que la degradación forestal y la deforestación son procesos diferentes. La deforestación implica la conversión de bosques a otro tipo de cobertura terrestre, por otro lado, la degradación se produce cuando los bosques siguen teniendo cobertura boscosa, pero pierden en alguna medida su

capacidad para proporcionar servicios ecosistémicos (Evaluación de Ecosistemas del Milenio 2005). Según Bullock et al. (2019), en algunos casos se reconoce la degradación forestal como parte del proceso de deforestación, dándose casos en cuando la velocidad de pérdida de la cobertura forestal se da de manera paulatina, presentando disminuciones en su biomasa, y consecuente a esto un cambio de la cobertura forestal o deforestación. No obstante, esta relación no siempre se da y una degradación no siempre produce deforestación, pero en los procesos de deforestación donde se evidencia, la detección de la degradación es una alerta de que una zona va a ser deforestada (Bullock et al., 2019; Asner et al., 2009).

De hecho, se ha descrito en boques tropicales que dependiendo de la forma en la que se produce la deforestación, una zona antes de perder toda su cobertura boscosa tiene previas intervenciones, principalmente relacionadas con la tala selectiva de especies con mayor porte y mejor calidad de madera. Estas intervenciones se producen de manera paulatina siendo un indicador de que se producirá de manera posterior una tala rasa, quema o deforestación en la zona (Matricardi et al., 2020; Caballero et al., 2018).

Para la identificación de la degradación y la deforestación, se han planteado estrategias para su monitoreo a partir de la utilización de sensores remotos pasivos y activos, e índices que reflejan la respuesta de la realidad de las coberturas (Gao et al., 2020). A pesar de que actualmente se realizan monitoreos de las coberturas y que existe un libre acceso a herramientas satelitales como Landsat y Sentinel, existen limitaciones en cuanto a la cantidad de información; esto debido a la presencia de nubes en las zonas tropicales y algunos defectos en el satélite como el bandeo (Laborde et al., 2017; Doyle et al., 2021; Bullock et al., 2019; Xu et al., 2017; Jakimow et al., 2018).

En estudios realizados por Bullock et al. (2019), y Zhang et al. (2021), en bosques húmedos usan índices como GV (Vegetación verde), NPV (Vegetación no fotosintética), NDFI (Índice normalizado de vegetación fraccionada) y NDVI (Índice de vegetación de diferencia normalizada), y concluyen que estos índices son útiles para el monitoreo no solo de procesos con la deforestación sino también para la degradación de los bosques resaltando entre ellos NDFI y NDVI; este último se concluye tiene un buen desempeño no sólo en bosques húmedos tropicales sino también para el monitoreo de otras coberturas vegetales. A la par de los índices se complemente con metodologías como la de análisis de series de tiempo – perturbaciones que ha demostrado ser eficiente para el monitoreo de la detección de cambios en las coberturas boscosas, pero se reconoce que para las zonas tropicales como la

Amazonía debido a la alta nubosidad limita la cantidad de información lo que dificulta su uso para los procesos de monitoreo (Bullock et al., 2019; Jakimow et al., 2018).

Meyer et al. (2019), en estudios realizados en el Chocó colombiano, identifica el uso de sistemas de información geográfica para el monitoreo de las reservas de carbono y medición de la degradación de los bosques, así mismo identifica el problema en las zonas donde la información se ve limitada por la nubosidad; y concluye como los SIG pueden ser usados para la medición de la degradación de los bosques identificando la estrecha relación con la obtención de valores de biomasa y los valores digitales de los sensores remotos. De hecho, Neitzel et al. (2021), en su estudio realizado en la amazonia brasileña no sólo resalta el uso de SIG para el monitoreo de la deforestación, sino que también plantea el uso de técnicas de machine learning para su identificación llegando a precisiones en la identificación del 88%, pero a su vez resalta la importancia de la cantidad de datos para llegar a estos valores.

Adicionalmente, así como el concepto de degradación es difícil de definir, también lo es su medición (Ghazoul et al., 2015; Meyer et al., 2019). Una posibilidad es a través de índices como el NDVI, que se relaciona de manera proporcional con la productividad de la vegetación (Marques, et al., 2017). Pero debido a la gran heterogeneidad en los bosques esta tarea se complejiza para la identificación y estandarización de umbrales para la clasificación de la degradación (Devries et al., 2015; Bullock et al., 2019; Arévalo et al., 2020).

Por otro lado, la implementación de algoritmos capaces de identificar y clasificar la degradación de una manera eficiente es una necesidad que se tiene para el monitoreo de las coberturas boscosas (Hirschmugl et al., 2017). Existe una tendencia en la implementación de algoritmos de series de tiempo como el algoritmo BFAST (Breaks for additive seasonal and trend) (Gao et al., 2020; Bullock et al., 2019) el cual permite la detección de cambios abruptos a partir de análisis de series de tiempo. A pesar de su alta precisión en la identificación de la degradación y la deforestación, se presentan limitaciones debido a que la cantidad de datos es restringida, y esto puede provocar estimaciones erróneas y baja precisión en lo resultados (Eckert, 2015, Gao et al., 2020; Hirschmugl et al., 2017). Una posible alternativa es la implementación de algoritmos de *machine learning*, que ofrecen un potencial en relación con la clasificación eficaz y eficiente de información generada a partir de procesos de teledetección, esto por la capacidad de manejar datos de alta dimensionalidad y de asignar

clases con características muy complejas a pesar de contar con información limitada (Maxwell et al., 2018).

De esta manera y partiendo del hecho que existe una relación entre la deforestación y la degradación, se planteó la hipótesis relacionada con disminuir la deforestación, a partir del monitoreo e identificación de procesos de degradación previa, mediante la caracterización de cambios sobre el bosque principalmente relacionados con cambios en la biomasa aérea. El objetivo de este trabajo es la propuesta de un modelo basado en la utilización de sensores remotos y herramientas de machine learning para la identificación y clasificación de coberturas que han sido degradadas por intervenciones sobre biomasa aérea con el fin de generar de alertas tempranas para frenar las problemáticas de degradación avanzada y deforestación en los bosques húmedos de la Amazonía.

2. Metodología

2.1. Área de estudio

La zona de estudio se encuentra ubicada en el oriente de Colombia, departamento de Meta municipio de Mapiripán (Figura. 1). Según la clasificación de ecosistemas, la zona pertenece a bosque húmedo tropical y abarca alrededor de 15.000 ha de las cuales 70% son coberturas boscosas y 30% pastizales (Ideam, 2012). La zona según los reportes de alertas tempranas del Ideam 2012, 2014, 2017 y 2018, se identifica como foco de deforestación. Según el SIMCI (2018), en la zona se reporta un aumento de los cultivos ilícitos de coca, llegando a ser el departamento de Meta junto con Guaviare son los departamentos en producción a nivel nacional con 9.9 Tn/año.

2.2. Adquisición de información satelital

Para estimar el índice de vegetación con información de 30 m, se utilizaron imágenes Landsat-5, 7 y 8 Enhanced Thematic Mapper Plus (ETM+) de enero a diciembre de 1990 a 2019 (USGS, 2020). A cada una de las imágenes descargadas se procedió con la corrección de reflectancia de la superficie después de las correcciones radiométricas y atmosféricas por el método DOS1 (Sustracción de objetos oscuros 1). La normalización radiométrica relativa de las imágenes de satélite multitemporales fue también un proceso necesario para detectar el cambio forestal, esto se desarrolló con el plugin Semi-Automatic Clasification versión 6.4.0 para QGIS 3.8. Es importante aclarar que procesos como la fusión de imágenes con bandas como la pancromática no se usaron en este proceso debido a las limitaciones en las imágenes Landsat 5.

Se obtuvieron alrededor de 36 imágenes landsat con menos de 10% de nubes y 27 imágenes de 885 disponibles, en la zona de estudio en el periodo de 1990 – 2019 (Tabla 1), la mayoría de las imágenes son de los meses de Enero – febrero y de noviembre diciembre que corresponde a la estación seca en el área de estudio. En relación de las imágenes para e proceso de validación sólo se logró adquirir una imagen con cubrimiento superior sin presencia de nubes de 90%, correspondiente a una imagen Rapideye del año 2012 (resolución espacial 5m, 5 bandas)(www.planet.com).

2.3. Máscara boscosa de NDVI y perturbaciones forestales

Para la identificación y clasificación de las perturbaciones en el bosque, se utilizaron dos variables principalmente, el NDVI y la variación de este en el tiempo. El NDVI es un índice que aprovecha que la vegetación tiene una fuerte reflectancia en la banda del infrarrojo cercano y una débil reflectancia en la banda del rojo, de esta manera los valores positivos más altos del NDVI corresponden a una vegetación boscosa verde no perturbada, y tiene un rango de (-1 a 1). En relación con la variación en el NDVI, puede atribuirse a una perturbación como una deforestación o una degradación del bosque, tal como sucede con los incendios forestales donde la variación en la respuesta de un área boscosa antes del incendio puede disminuir hasta debajo de 0.3 en relación con el NDVI (Lin et al., 2017).

Para evitar la confusión entre las perturbaciones forestales y otras dinámicas de cambio de la cubierta terrestre (ejemplo: producción de cultivos), Zhu et al. (2012) y Ruiz-Ramos et al. (2020) proponen la generación de una máscara de cobertura forestal de referencia en el período evaluado. Esta máscara de coberturas boscosas se construye a partir de la clasificación del NDVI (agrupando en dos grupos las coberturas, los valores altos se relacionan con coberturas boscosas y los demás en otras coberturas o no bosque, $a = 0.05$) y con la utilización de la herramienta Cluster ISO de ArcGIS 10.7.1 (ESRI, Inc.).

2.5. Identificación y clasificación de cambios

La máscara de coberturas boscosas se usó para extraer la información de las dos variables, de tal forma por imagen se obtiene el dato de NDVI y de la variación del NDVI, así, las coberturas boscosas que se mantuvieron en el período evaluado son considerados como bosque patrón. En relación con las áreas en donde se percibió un cambio de coberturas (bosque a no bosque) son las áreas clasificadas como deforestadas. De las áreas deforestadas se realizó un muestreo aleatorio en el software matlab con la función randsample del 10%, esto para la identificación de áreas deforestadas que sufrieron

perturbaciones previas por fuera de los umbrales del NDVI y las variaciones del bosque patrón así también de las áreas deforestadas.

Para la clasificación de los cambios se realiza la superposición de las distribuciones de los valores donde fue identificado el bosque estable y área deforestada para las variables de NDVI y variación de NDVI, tomando como nivel de significancia de 0,05 para separar las áreas cuyo comportamiento para las variables analizadas se encuentren fuera del comportamiento de un bosque estable y área deforestada con un nivel de confianza del 95%.

Los umbrales de cambio son obtenidos a partir de la identificación de datos atípicos a partir de la distribución de en las diferentes ventanas de tiempo, con la librería rriskdistributions del software r para las variables de NDVI y la variación del NDVI entre imágenes. Los pixeles con valores fuera de estos umbrales que hacen referencia al nivel de significancia de 0.005 (en donde hace relación a la probabilidad de tomar un bosque que se considera estable es de 99.5% en las variables de NDVI y variación de NDVI) son clasificados como áreas degradadas siempre y cuando se cumplan las siguientes condiciones:

a. Se encuentre dentro del umbral de los valores del bosque estable en NDVI: este bosque estable hace relación aquellas coberturas boscosas que se identificaron en el periodo evaluado, en donde la cobertura boscosa se ha mantenido a través del tiempo sin variación en el tipo de cobertura.
b. El valor de la variación del NDVI esté por debajo del umbral de bosque estable. sin estar presente dentro del umbral de cambio de cobertura bosque/no bosque o de los píxeles clasificados como deforestados.

De esta manera estos son los conceptos

Bosques estable: Es aquella área boscosa sobre la cual su cobertura boscosa se mantiene a través del tiempo de estudio, esta área se encuentra dentro de los rangos determinados de NDVI ($p>0.005$) y variación de NDVI ($p >0.005$; probabilidad de pertinencia al NDVI clasificado como bosque).

Bosque degradado: Se definen cómo aquellas áreas de cobertura boscosa sobre la cual el valor de NDVI se encuentra por valores correspondientes de bosque pero sus variaciones de NDVI se

encuentran por encima de los valores del bosque estable ($p<0.005$) lo que produce que el valor pueda ser considerado como un atípico o un valor poco frecuente en el área boscosa evaluada.

Área deforestada: Se consideran aquellas áreas que por su valor de NDVI, están por debajo del considerado como bosque estable o bosque degradado, NDVI ($p<0.005$)

2.6. Validación clasificación de cambios

Se realiza el proceso de validación del modelo propuesto en el área clasificada como degradada, se evalúa la precisión mediante una matriz de confusión y la estimación del coeficiente kappa, mediante la comparación con imágenes de mayor resolución espacial rapideye disponible y realizando una clasificación supervisada en área boscosa, área deforestada y área boscosa intervenida. Esta revisión se realiza de manera visual para todas las áreas identificadas como deforestadas o degradadas clasificadas para el año 2012 (Olofsson et al., 2014). Este tipo de metodología es la más frecuente para realizar la validación debido a que otras fuentes como datos/monitorización in situ son insumos menos disponibles y de mayor costo para los estudios (Taylor et al., 2019; Shimabukuro et al., 2019). A partir de la consolidación de los resultados de la comparación entre la clasificación por el algoritmo propuesto y la revisión visual se realiza la estimación de la precisión y el error del algoritmo (Gao et al., 2020).

2.7. Entrenamiento

A partir de los resultados obtenidos en el proceso de la clasificación de cambios, se procedió al entrenamiento de los modelos de machine learning en el programa Matlab 2019a, a partir del 10% del total del área boscosa y 10% del total de las áreas deforestadas de estudio para cada una de las ventanas de tiempo y 1000 iteraciones. Como variables explicativas: fecha de adquisición de la imagen, el valor de NDVI y su variación y variable de respuesta la clasificación resultante de proceso de detección de cambios (bosque, área degradada y área deforestada). Para los algoritmos de machine learning evaluados se realizó la comparación a partir de la matriz de confusión y de las métricas de precisión general de la clasificación, sensibilidad especificidad y exactitud. Este proceso se realiza por píxel con una proporción de 70% de entrenamiento y 30% de test, a partir del área muestreada (10% del área donde se dio cambio de cobertura); a partir de la función de minimización lineal se disminuye el porcentaje de entrenamiento hasta alcanzar el mínimo de optimo en relación con la precisión; y se realiza para el área muestreada.

2.7.1. Neural Network

Las redes neuronales funcionan de manera similar a las redes neuronales biológicas se dividen en tres partes: la capa que recibe la información, la capa oculta que procesa las entradas y por último la capa de salida calculada. Para este estudio se utilizan las redes neuronales supervisadas en donde se realiza la comparación en la salida predicha y la salida real, en función del error se modifican los pesos de las neuronales y se introduce de nuevo (Hiregoudar et al., 2014).

2.7.2. Discriminante Lineal

El discriminante lineal es un algoritmo que clasifica en grupos en función de sus características haciendo uso del teorema de Bayes. Esta estima la probabilidad de que una observación pertenezca según la información de varios predictores. Como resultado se realiza la asignación de la observación a la clase en donde prediga es de probabilidad mayor (Kolukisa et al., 2018).

2.7.3. Naive Bayes

Es una técnica de machine learning basada en modelos de probabilidad del teorema bayesiana. La cuál analiza la relación entre cada característica y la clase de cada instancia, basándose en probabilidades conjuntas de características y clases para estimar las probabilidades de un determinado elemento pertenezca a una clase determinada, (Rish et al., 2001).

$$P\left(\frac{h_k}{x_j}\right) = P\left(\frac{hx_j}{h_k}\right)P(h_k)\sum n_i = x_j P\left(\frac{h_k}{x_j}\right); 0 < k < n + 1$$

Ecuación. 1.

En la ecuación 1. Se muestra el modelo en donde P(h/x) es la probabilidad posterior de hipótesis dado que la evidencia es verdadera, P(x/h) es la probabilidad de la evidencia dada que la hipótesis es verdadera, P(x) probabilidad previa de la hipótesis.

2.7.4. Weighted KNN (K vecinos más cercanos)

Este es una modificación del algoritmo de k- vecinos más cercanos, la clasificación se lleva a cabo basándose por la comparación de un vector de entrenamiento y aquellos que son similares a él en relación con la distancia euclidiana de los vectores vecinos, como resultado la observación se le asigna la clasificación al vector que más cerca esté de la observación (Rezapour et al., 2011).

2.7.5. Modelo lineal generalizado (GLM)

EL GLM permite formar una relación de regresión multivariada entre una variable dependiente y una serie de variables independientes. Se basa en generar distribuciones de funciones exponenciales de la variable repuesta y que la magnitud de la varianza de cada dato sea una función del valor estimado, este algoritmo permite usar no solo la distribución normal que supone una varianza constante (Dey et al., 2016).

2.7.6. Máquinas de soporte vectorial (SVM)

Las SVM funcionan según el cálculo de márgenes entre las clases; estas se dibujan de tal manera que maximizan la distancia entre las márgenes y las clases, de tal forma que se minimice el error de clasificación trazando cada dato en un espacio n-dimensional (donde n es el número de características que tiene) con el valor de cada característica siendo el valor de una coordenada particular (Dey et al., 2016).

2.8. Clasificación de la degradación

Con el algoritmo que muestra un óptimo desempeño, en relación con la precisión e información limitada en la fase de entrenamiento de las herramientas de machine learning para la clasificación en áreas según los umbrales y reglas planteadas para la clasificación de la degradación, se realiza la clasificación para el total del área de estudio. El producto de este resultado es la consolidación en el 100% del área de estudio para la clasificación en bosque, área degradada y área deforestada dependiendo el valor de NDVI, su variación y la fecha.

3. Resultados

Caracterización del Bosque y No bosque

En la clasificación de coberturas en cada una de las ventanas de tiempo, se identificó las áreas de bosque que permanecieron estables en el periodo (1991 - 2019) correspondientes a 8.964 ha (64%) y 2.654 ha (36%) de bosques no estables (Figura 2), estas últimas corresponden a las áreas deforestadas en donde se evidenció que, en los años 2000, 2008 y 2019 se identificaron las mayores pérdidas de cobertura boscosas con cifras superiores a los 300 ha/año y en los años 1994, 2006 y 2012, las menores cifras de áreas deforestadas (Figura 3).

En los bosques estables (1999-2019) muestreados, en términos de NDVI se caracterizó por una media 0,75 en el NDVI (Kolmogorov-Smirnov: $p>0.05$; 0.43) y una variación media por año en el NDVI de

0.21 (Kolmogorov-Smirnov: p>0.005; 0.35). Para las áreas deforestadas se identificó una media 0,25 en el NDVI (Kolmogorov-Smirnov: p>0.005; 0.29) y una variación media por año en el NDVI de -0.34 (Kolmogorov-Smirnov: p>0.005; 0.35), la caracterización año a año se muestra de una manera detallada anual en la Tabla 1.

Clasificación de cambios

Los valores de NDVI como umbral promedio de NDVI= 0.45 (p=0.005) y en términos de la variación de NDVI/Año se marca como umbral una variación promedio de –0.18 NDVI/año (p=0.005) en relación con los bosques estables, datos menores al umbral de variación de cambios son considerados como áreas degradadas, para la caracterización año a año se muestra de una manera detallada en la Tabla 2.

Validación de la clasificación

Las áreas clasificadas como deforestadas, bosque estable y degradadas en el muestreo en la ventana 2012 corresponden a 24 ha (6%), 352(92%) ha y 5 ha (2%) respectivamente; en contraste en la imagen RapidEye 2012 se identificó 26 ha (6%) de coberturas deforestadas, 349 ha (92%) de bosque estable y 7 ha (2%) de área considerada como bosque no estable. En la comparación de ambas salidas se estimó un coeficiente kappa de 0.856 que en un (378 ha) 97% de los casos clasificados como degradación se identifica afectaciones dentro del área evaluada, en el restante 3% de los casos no hay evidencias de variación de la cobertura. Esta comparación se hizo por píxel de las imágenes landsat y por grupo de píxeles correspondientes de 5X5 para la imagen de mayor resolución.

Entrenamiento de los modelos

A partir del 10% (381 ha) del área total de estudio muestreada y clasificada se realizó la comparación en el desempeño de los algoritmos con proporciones de entrenamiento, 70% de entrenamiento y 30% Se encontró que el algoritmo Neural Network – Trilayered Neural network tuvo un 88% precisión, 85% sensibilidad, 84% especificidad y 86% exactitud mayores a los otros algoritmos (Tabla 2), mientras en algoritmos como Arboles de decisión y SVM (máquinas de soporte de vectores) presentaron menores valores en desempeño en los indicadores usados para evaluar, este mismo orden se identifica al disminuir los valores de la proporción para los datos en el entrenamiento 45% en el entrenamiento y 55% de test (Tabla 3). Esto para identificar qué modelo a pesar de limitar la cantidad de información disponible muestra mejor desempeño.

Consolidación de los cambios

A partir del algoritmo Neural Network – Trilayered Neural network entrenado se realizó la clasificación en las categorías de bosque, no bosque y área degradada, en donde se clasificó con un valor de predicción positiva de 86% y un total de 12.548 ha (Tabla 4); de manera complementaria se realizó un consolidado de la clasificación en el período 1990-2019 de manera que se pueden identificar las áreas deforestadas donde previamente han sufrido degradación (Figura 5). De manera anual se identificó que, en los periodos de 2000, 2008 y 2015 se producen los mayores casos de degradación previa (70% del total de los casos identificados de color amarillo) (Figura 6).

4. Discusión

Este trabajo se propuso evaluar si, en los bosques húmedos de la Amazonía es posible detectar alertas tempranas de deforestación, a partir de la identificación de la degradación de los bosques, la utilización de herramientas de teledetección y de machine learning. Los resultados de este trabajo comprueban la hipótesis que en estos bosques hay una entre la deforestación y la degradación previa del bosque esto a partir, de encontrar la mayoría de áreas deforestadas con una previa perturbación. En el período de 1990 a 2019 en 60% de los casos clasificados como áreas deforestadas se detectaron cambios graduales en el NDVI que conllevaron a ser clasificados como áreas degradadas. Por otro lado, el 40% restante de las áreas clasificadas como deforestadas no presentaron evidencias de cambios graduales en el NDVI y su variación.

En los casos en los que se identificó una degradación previa a la deforestación, se relaciona con disturbios o perturbaciones que se dan de manera natural o antrópica afectando de manera directa la masa forestal esto se ve reflejado en un cambio en el NDVI (Hirschmugl et al. 2017). Al revisar el NDVI encontrado para la clasificación de área degradadas este oscila entre los valores de 0.45-0.6, que concuerda con Shimabukuro *et al.* (2019), Joshi *et al.* (2015) y *Asner et al.* (2009), en donde hallaron que las zonas con un índice de NDVI debajo de 0.6 pueden ser clasificadas como degradadas, esto acompaño a variaciones entre ventanas de tiempo del NDVI de 0.15 con un nivel de confianza de 99.5 de no estar tomando bosques estables.

En relación con las áreas degradadas previamente, el dato del presente estudio corresponde al 60% y es mayor al encontrado en el bosque húmedo de la Amazonía cercano a 50% por Bullock et al. (2018) y Asner et al. (2009). Esta diferencia puede ser atribuida a las causas que originan el disturbio, la alta

presencia de cultivos ilícitos reportados en la zona (UNODC, 2014) y el proceso de “sabanización” el cual está altamente relacionado con el proceso de deforestación en este bosque (Sales et al. 2020).

Según Chadid *et al.* (2015), los cultivos ilícitos son una de las principales causas de degradación debido a la utilización de los estratos bajos del bosque para el cultivo y los estratos superiores como protección para evitar la identificación en el monitoreo, lo que se conoce como dosel protector. Además, en reportes del SIMCI (2018), se ha identificado que en el departamento de Meta como la zona de mayor crecimiento y producción de cultivos de coca representando un 30% con 9.9 Tn/año de la producción identificada en el país.

Con respecto al proceso de “sabanización”, Sales et al. (2020), Lapola et al. (2019), Torres (2017), Armenteras & Rodríguez (2014), Gonzáles et al. (2011), describen este proceso de deforestación como un proceso no secuencializado, que afecta en gran medida los bosques de la Amazonía. En este proceso, donde se puede dar un aprovechamiento de la madera o no, en la zona seguido de la quema de la vegetación presente, el objetivo la obtención de pastizales, dicho proceso se desarrolla en diferentes escalas espaciales y temporales, lo cual confirma al detallar sobre las áreas deforestadas su uso actual que corresponde a pastos (SINCHI, 2018).

En relación con las áreas donde no se identificó degradación previa a la deforestación, estas se atribuyeron a dos razones principalmente. La primera razón hace relación al cambio de cobertura de manera acelerada esto haciendo referencia al proceso de deforestación (Lizundia *et al.* 2020; Shimabukuro *et al.* 2019; Bullock *et al*. 2018). Lo cual indica que, en la zona de estudio se evidenció una problemática por pérdida de bosques de 0.25% anual, que no pudo evitarse a través de un sistema de monitoreo por el proceso de “sabanización".

La segunda razón se asocia con las limitaciones del modelo de teledetección y machine learning planteado en relación con la resolución espacial y temporal, debido a la utilización de imágenes Landsat y el tamaño mínimo de detección que corresponden a una 1 ha en bosques tropicales y en ocasiones el proceso de degradación se da una manera más puntual con la tala selectiva (Gao *et al*. 2020; Mitchell *et al* 2017; GOFI 2016; Olander *et al.* 2008). Por otro lado, existe una gran limitación en relación con la presencia de nubes en la zona, de hecho, de las 885 imágenes landsat identificadas en la zona sólo se pudieron usar 27 por la presencia de problemas como bandeo o la presencia de nubes muy común en las zonas tropicales limitando la información que puede ser usada por un sistema de monitoreo en estas zonas (Bullock, 2018; Reiched et al. 2018)

Los resultados de este estudio nos muestran que se comprueba la hipótesis en relación con el algoritmo de aprendizaje automático de redes neuronales de tres capas, como el que mejor precisión mostró para la clasificación de coberturas boscosas degradadas. Más aun fue preciso en la proporción de entrenamiento de 45 – 55 (precisión 75.25%), reconociendo en este estudio que es la primera vez que se usa para la clasificación de bosques degradados. En estudios similares realizados para la clasificación de la degradación usando el algoritmo de series de tiempo se ha obtenido precisiones por encima del 70% en bosque húmedo (DeVries *et al*, 2016) y en algunos casos hasta por encima del 85% (Bullock, 2018. Arevalo et al., 2019). Dicho cambio se relaciona directamente con la homogeneidad de los bosques evaluados y con la cantidad de datos que se tienen en el período.

De acuerdo, a la cantidad de información y el efecto en la precisión de los resultados Gao et al., (2020) Mitchell et al., (2017), GOFI (2016) reconocen las limitaciones de los algoritmos como series de tiempo, con relación a la cantidad de información necesaria para su entrenamiento. Áreas en donde la cantidad de datos es limitada por presencia de nubes, sombras o problemas de bandeo en la imagen como en las zonas tropicales (DeVries *et al.* 2016). (Arevalo *et al*. (2019), las redes neuronales proporcionan una alternativa capaz de brindar altos valores de precisión con pocos datos de entrenamiento (Rezaee et al. 2018; Xu et al. 2017; Sharma et al, 2017).

5. Conclusiones y Recomendaciones

Se propone en este estudio el modelo basado sensores remotos para el monitoreo y la clasificación de áreas degradadas que conlleven a procesos de deforestación, con el algoritmo de redes neuronales con tres capas ocultas y la utilización de insumos landsat para el cálculo de NDVI y su variación. El modelo propuesto brinda resultados aceptables (precisión 76.25%) a pesar de contar con información limitada para su clasificación.

La importancia de estos resultados radica en la posibilidad de generar alertas tempranas de deforestación a partir del análisis de disturbios relacionado con la degradación de los boques, y de esta manera evitar hasta un 60% de la deforestación en la zona de estudio, pues estuvieron relacionadas con el proceso de degradación y fueron previamente identificadas.

Se demuestra que el modelo propuesto no sólo tiene una utilidad para el seguimiento de procesos de cambio de cobertura como la deforestación, sino también para la detección de pequeños cambios en el bosque que puedan estar afectando de manera negativa la prestación de servicios ecosistémicos y que

conlleven a la deforestación, resaltando la importancia de la implementación de monitoreo y vigilancia en las zonas tropicales, a pesar de las limitaciones.

Se propone para próximos estudios la utilización de técnicas como la fusión de imágenes para mejorar limitaciones en la información como la resolución espacial, haciendo uso de la banda pancromática o de otros sensores remotos como Spot y Sentinel para realizar técnicas más avanzadas como mixturas espectrales con información de radar que no tienen limitación en zonas con altas presencia de nubosidad.

Bibliografía

Arévalo, P., Olofsson, P., & Woodcock, C. E. (2020). Continuous monitoring of land change activities and post-disturbance dynamics from Landsat time series: A test methodology for REDD+ reporting. *Remote Sensing of Environment*, *238*, 111051.

Armenteras, D., González, TM., Retana, J., Espelta, JM. (eds). (2016) Degradación de bosques en Latinoamérica: Síntesis conceptual, metodologías de evaluación y casos de estudio nacionales.

Asner G.P. (2009). Automated mapping of tropical deforestation and forest degradation: CLASlite. Journal of Applied Remote Sensing 3(1) article 033543.

Bullock, E. L., Woodcock, C. E., & Olofsson, P. (2019). Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. *Remote sensing of Environment*, *238*, 110968.

Caballero Espejo, J., Messinger, M., Román-Dañobeytia, F., Ascorra, C., Fernandez, L. E., & Silman, M. (2018). Deforestation and forest degradation due to gold mining in the Peruvian Amazon: A 34-year perspective. *Remote Sensing*, *10*(12), 1903.

Dey, A. (2016). Machine learning algorithms: a review. International Journal of Computer Science and Information Technologies, 7(3), 1174-1179. Discriminant Analysis and a New Hybrid Feature Selection Methodology for the Diagnosis of Coronary Artery Disease.

Doyle, C., Beach, T., & Luzzadder-Beach, S. (2021). Tropical Forest and Wetland Losses and the Role of Protected Areas in Northwestern Belize, Revealed from Landsat and Machine Learning. *Remote Sensing*, *13*(3), 379.

DeVries, B., Verbesselt, J., Kooistra, L., & Herold, M. (2015). Robust monitoring of small-scale forest disturbances in a tropical montane forest using Landsat time series. *Remote Sensing of Environment*, *161*, 107-121.

Eckert, S., Hüsler, F., Liniger, H., & Hodel, E. (2015). Trend analysis of MODIS NDVI time series for detecting land degradation and regeneration in Mongolia. *Journal of Arid Environments*, *113*, 16-28.

Gao, Y., Skutsch, M., Paneque-Gálvez, J., & Ghilardi, A. (2020). Remote sensing of forest degradation: a review. *Environmental Research Letters*, *15*(10), 103001.

Ghazoul, J., Burivalova, Z., Garcia-Ulloa, J., & King, L. A. (2015). Conceptualizing forest degradation. *Trends in ecology & evolution*, *30*(10), 622-632.

GFOI. (2016). Integration of Remote-sensing and Ground-based Observations for Estimation of Emissions and Removals of Greenhouse Gases in Forests: Methods and Guidance from the Global Forest Observation Initiative 2.0 edn (Rome: Food and Agriculture Organization).

Hiregoudar, S., Manjunath, K., Patil, K. (2014) "A Survey: Research Summary on Neural Networks", International Journal of Research in Engineering and Technology, ISSN: 2319 1163, Volume 03, Special Issue 03, pages 385-389.

Hirschmugl, M., Gallaun, H., Dees, M., Datta, P., Deutscher, J., Koutsias, N., & Schardt, M. (2017). Methods for mapping forest disturbance and degradation from optical earth observation data: A review. *Current Forestry Reports*, *3*(1), 32-45.

Instituto de hidrología, meteorología y estudios ambientales (Ideam). (2012). Mapas de deforestación, Bosque No Bosque, Recuperado de: http://www.ideam.gov.co/web/ecosistemas/bosques-y-recurso-forestal.

Instituto de hidrología, meteorología y estudios ambientales (Ideam). (2019). Deforestación en Colombia, Recuperado de: http://www.ideam.gov.co/web/ecosistemas/bosques-y-recurso-forestal.

Instituto nacional de pesquisas espacias (INPE). (2020).Recuperado de: http://satelite.cptec.inpe.br/home/.

Instituto nacional de pesquisas espacias (INPE). (2021).Recuperado de: http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php.

Jakimow, B., Griffiths, P., van der Linden, S., & Hostert, P. (2018). Mapping pasture management in the Brazilian Amazon from dense Landsat time series. *Remote Sensing of Environment*, *205*, 453-468.

Joshi N, Mitchard ETA, Woo N, Torres J, Moll-Rocek J, Ehammer A, Collins M, Jepsen MR, Frensholt R. (2015). Mapping dynamics of deforestation and forest degradation in tropical forests using radar satellite data. Environmental Research Letters 10:034014. doi:10.1088/1748-9326/10/3/034014.

Kolukisa, B., Hacilar, H., Goy, G., Kus, M., Bakir-Gungor, B., Aral, A., Gungor, V. (2018). International Conference on Big Data (Big Data) - Evaluation of Classification Algorithms, Linear

Laborde, H., Douzal, V., Ruiz Piña, H. A., Morand, S., & Cornu, J. F. (2017). Landsat-8 cloud-free observations in wet tropical areas: A case study in South East Asia. *Remote Sensing Letters*, *8*(6), 537-546.

Lapola, D., Schaldach, R., Alcamo, J., Bondeau, A., Msangi, S., Priess, J., Silvestrini, R. & Filho, B. (2011). Impacts of Climate Change and the End of Deforestation on Land Use in the Brazilian Legal Amazon. Earth Interactions. 15. 1-29. 10.1175/2010EI333.1.

Lin, H., Chen, Y., Song, Q., Fu, P., Cleverly, J., Magliulo, V., ... & Fan, Z. (2017). Quantifying deforestation and forest degradation with thermal response. *Science of the Total Environment*, *607*, 1286-1292.

Lizundia-Loiola, J., Pettinari, M. L., & Chuvieco, E. (2020). Temporal anomalies in burned area trends: satellite estimations of the Amazonian 2019 fire crisis. Remote Sensing, 12(1), 151.

Marqués, H. O., Biudes, M. S., Pavão, V. M., Machado, N. G., Querino, C. A. S., & de Morais Danelichen, V. H. (2017). Estimated net radiation in an Amazon–Cerrado transition forest by Landsat 5 TM. *Journal of Applied Remote Sensing*, *11*(4), 046020.

Matricardi, E. A. T., Skole, D. L., Costa, O. B., Pedlowski, M. A., Samek, J. H., & Miguel, E. P. (2020). Long-term forest degradation surpasses deforestation in the Brazilian Amazon. *Science*, *369*(6509), 1378-1382.

Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, *39*(9), 2784-2817.

Meyer, V., Saatchi, S., Ferraz, A., Xu, L., Duque, A., García, M., & Chave, J. (2019). Forest degradation and biomass loss along the Chocó region of Colombia. *Carbon balance and management*, *14*(1), 1-15.

Mitchell, A. L., Rosenqvist, A., & Mora, B. (2017). Current remote sensing approaches to monitoring forest degradation in support of countries measurement, reporting and verification (MRV) systems for REDD+. Carbon balance and management, 12(1), 1-22.

Monitoreo integrado de cultivos ilícitos (SIMCI). 2018. Recuperado de: https://www.unodc.org.

Oficina de naciones unidas contra la droga y el delito (UNODC). 2014. Recuperado de: https://www.unodc.org.

Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, *148*, 42-57.

Portal TerraBrasilis (Instituto Nacional de Pesquisas Espaciais (INPE). (2020). Recuperado de: http://terrabrasilis.dpi.inpe.br.

Reiche, J., Hamunyela, E., Verbesselt, J., Hoekman, D., & Herold, M. (2018). Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2. *Remote Sensing of Environment*, *204*, 147-161.

Rezaee, M., Mahdianpari, M., Zhang, Y., & Salehi, B. (2018). Deep convolutional neural network for complex wetland classification using optical remote sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *11*(9), 3030-3039.

Rezapour, A. R., Fakhrahmad, S. M., & Sadreddini, M. H. (2011). Applying weighted KNN to word sense disambiguation. In *Proceedings of the world congress on engineering* (Vol. 3, pp. 6-8).

Rish, I. (2001). "An empirical study of the naive Bayes classifier." IJCAI 2001 workshop on empirical methods in artificial intelligence. Vol. 3. No. 22. IBM New York.

Ruiz-Ramos, J., Marino, A., Boardman, C., & Suarez, J. (2020). Continuous Forest Monitoring Using Cumulative Sums of Sentinel-1 Timeseries. *Remote Sensing*, *12*(18), 3061.

Sales LP, Galetti M, Pires MM. (2020). Climate and land-use change will lead to a faunal "savannization" on tropical rainforests. Glob Chang Biol 26:7036–7044.

Sharma, A., Liu, X., Yang, X., & Shi, D. (2017). A patch-based convolutional neural network for remote sensing image classification. *Neural Networks*, *95*, 19-28.

Shimabukuro, Y. E., Arai, E., Duarte, V., Jorge, A., Santos, E. G. D., Gasparini, K. A. C., & Dutra, A. C. (2019). Monitoring deforestation and forest degradation using multi-temporal fraction images derived from Landsat sensor data in the Brazilian Amazon. *International Journal of Remote Sensing*, *40*(14), 5475-5496.

Taylor, J., Auch, R., Sayler, K. L., Pengra, B., Horton, J., Smith, K., & Reker, R. R. (2019). LCMAP Land Cover Classification and Land Cover Change Metrics, 1985-2016 Based on the LCMAP Reference Data Set. In *AGU Fall Meeting Abstracts* (Vol. 2019, pp. B11I-2296).

Torres, Á. Y. L. (2017). Uso y manejo del suelo en la amazonia colombiana. *Revista CES Medicina Veterinaria y Zootecnia*, *12*(2), 151-163.

Vogelmann, J. E., Xian, G., Homer, C., & Tolk, B. (2012). Monitoring gradual ecosystem change using Landsat time series analyses: Case studies in selected forest and rangeland ecosystems. *Remote Sensing of Environment*, *122*, 92-105.

Xu, X., Li, W., Ran, Q., Du, Q., Gao, L., & Zhang, B. (2017). Multisource remote sensing data classification based on convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, *56*(2), 937-949.

Yu, T., Liu, P., Zhang, Q., Ren, Y., & Yao, J. (2021). Detecting Forest Degradation in the Three-North Forest Shelterbelt in China from Multi-Scale Satellite Images. *Remote Sensing*, *13*(6), 1131.

Zhang, Y., Ling, F., Wang, X., Foody, G. M., Boyd, D. S., Li, X., & Atkinson, P. M. (2021). Tracking small-scale tropical forest disturbances: Fusing the Landsat and Sentinel-2 data record. *Remote Sensing of Environment*, *261*, 112470.

Zhu, X., Liu, D., & Chen, J. (2012). A new geostatistical approach for filling gaps in Landsat ETM+ SLC-off images. Remote Sensing of Environment, 124, 49–60.10.1016/j.rse.2012.04.019.

Tabla 1. Fecha de las imágenes usadas para la identificación de la degradación y los cambios, con proporción de nubes menores al 10% en la zona de estudio

1991/01	1991/02	1994/02	1996/01	1998/08	1999/12	2000/01	2001/03	2002/12
2003/01	2004/01	2004/02	2006/02	2006/04	2007/07	2008/01	2008/04	2008/12
2009/02	2009/09	2009/12	2010/02	2010/03	2010/09	2012/02	2013/09	2014/02
2015/02	2016/01	2016/12	2017/02	2017/03	2017/07	2017/10	2018/08	2019/02

Tabla 2. Caracterización de las variables de NDVI, variación de NDVI en el período 1992-2019 e identificación de umbrales de cambio de bosque o bosque.

Año	**Media bosque estable**	**Variación media bosque estable**	**Media área deforestada**	**Variación media área deforestada**	**Umbral cambio de bosque a no bosque α=0,005**	**Umbral variación bosque estable α =0,005**
1992	0,64	0,17	0,19	-0,13	0,45	-0,04
1993	0,74	0,21	0,10	-0,32	0,43	0,01
1994	0,75	0,23	0,11	-0,26	0,5	-0,06
1995	0,65	-0,13	0,12	-0,24	0,45	-0,03
1996	0,92	0,24	0,25	-0,36	0,5	-0,03
1997	0,83	-0,09	0,31	-0,28	0,45	-0,03
1998	0,75	0,12	0,21	-0,16	0,54	0,01
1999	0,91	0,18	0,08	-0,34	0,47	-0,13
2000	0,70	0,09	0,21	-0,22	0,44	-0,08
2001	0,83	0,07	0,36	-0,28	0,48	-0,01
2002	0,69	-0,13	0,16	-0,39	0,49	-0,14
2003	0,84	0,12	0,06	-0,37	0,54	-0,1
2004	0,78	0,03	0,11	-0,30	0,44	-0,05
2005	0,80	0,05	0,31	-0,19	0,45	-0,1
2006	0,71	0,00	0,34	-0,32	0,48	-0,04
2007	0,74	0,06	0,35	-0,35	0,47	-0,06
2008	0,80	-0,13	0,06	-0,19	0,52	-0,05
2009	0,65	0,00	0,29	-0,21	0,43	0,01
2010	0,88	-0,07	0,15	-0,15	0,48	-0,07
2011	0,64	0,20	0,35	-0,26	0,5	-0,13

2012	0,65	-0,01	0,01	-0,32	0,43	-0,1
2013	0,76	0,18	0,26	-0,39	0,5	-0,14
2014	0,69	0,04	0,28	-0,33	0,51	-0,07
2015	0,88	0,07	0,08	-0,24	0,47	-0,04
2016	0,64	-0,10	0,02	-0,13	0,54	-0,01
2017	0,74	0,12	0,33	-0,38	0,48	-0,13
2018	0,70	-0,10	0,02	-0,30	0,48	-0,11
2019	0,69	-0,11	0,16	-0,39	0,51	0,01

Tabla 3. Desempeño de los algoritmos de machine learning utilizados para el entrenamiento a partir de los datos obtenidos en el muestreo (10%) proporción entrenamiento 70%-30%.

Modelo	Precisión %	Sensibilidad%	Especificidad%	Exactitud %
Neural Network - Trilayered Neural Network	87,50%	85.2%	84.45%	86.2%
Discriminante Lineal	85,30%	84,45	70,80	86.2%
Naive Bayes	73,50%	72,77	61,01	67,62
Weighted KNN (*k- Vecinos más cercanos*)	72,50%	71,78	60,18	66,70
Neural Networks	71,30%	70,59	59,18	65,60
GLM Modelo lineal Generalizado	69,85%	69,15	57,98	64,26
Árbol de decisión	69,66%	68,96	57,82	64,09
Support vector machines	59,40%	58,81	49,30	54,65

Tabla 4. Desempeño de los algoritmos de machine learning utilizados para el entrenamiento en la clasificación de bosques, áreas deforestadas y áreas degradadas; a partir de los datos obtenidos en el muestreo (10%) proporción entrenamiento 45%-65%.

Modelo	Precisión %	Sensibilidad%	Especificidad%	Exactitud %
Neural Network - Trilayered Neural Network	75,25%	73,27%	72,63%	74,13%
Discriminante Lineal	73,36%	72,62%	60,89%	74,13%
Naive Bayes	63,21%	62,58%	52,46%	58,15%
Weighted KNN (*k- Vecinos más cercanos*)	62,35%	61,73%	51,75%	57,36%
Neural Networks	61,32%	60,70%	50,89%	56,41%
GLM Modelo lineal Generalizado	60,07%	59,47%	49,86%	55,27%
Árbol de decisión	59,91%	59,31%	49,72%	55,11%
Support vector machines	51,08%	50,57%	42,40%	47,00%

Tabla 5. Matriz de confusión, asociada para la validación de los datos del área de estudio a partir del algoritmo de Neural Network-Trilayered Neural Network.

Métricas de evaluación estadística	Neural Network - Trilayered Neural Network
Verdadero – positivo (ha)	12.598
Verdadero – negativo (ha)	897
Falso – positivo (ha)	4.865
Falso - negativo (ha)	325
Valor de la predicción positiva	86,50%
Sensibilidad	81,31%
Precisión de clasificación	85,39%
Área bajo de la curva ROC curva (AUC)	82,00%

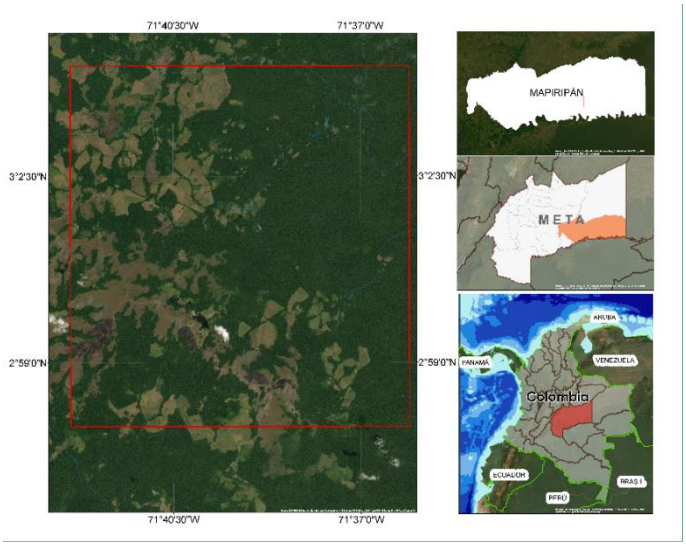

Figura 1. Zona de estudio, enmarcada en rojo perteneciente al municipio de Mapirián (Meta, Colombia). Área aproximada de 15.000 ha.

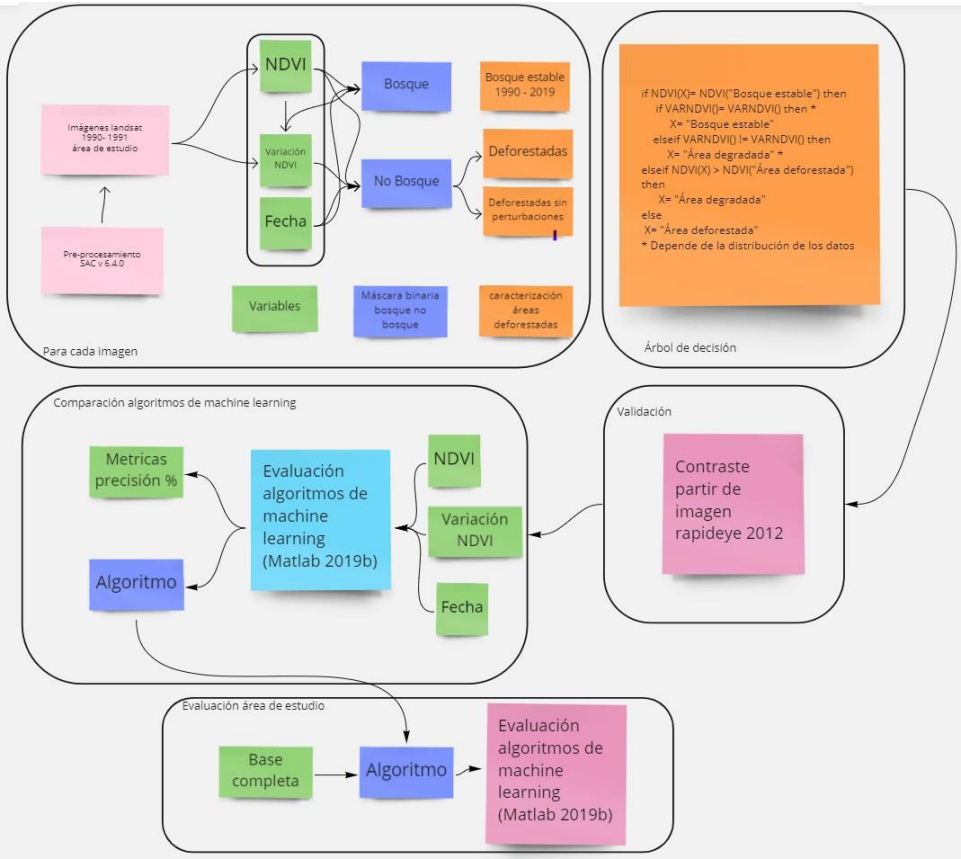

Figura 2. Flujo propuesto Modelo planteado para la identificación de la degradación del bosque.

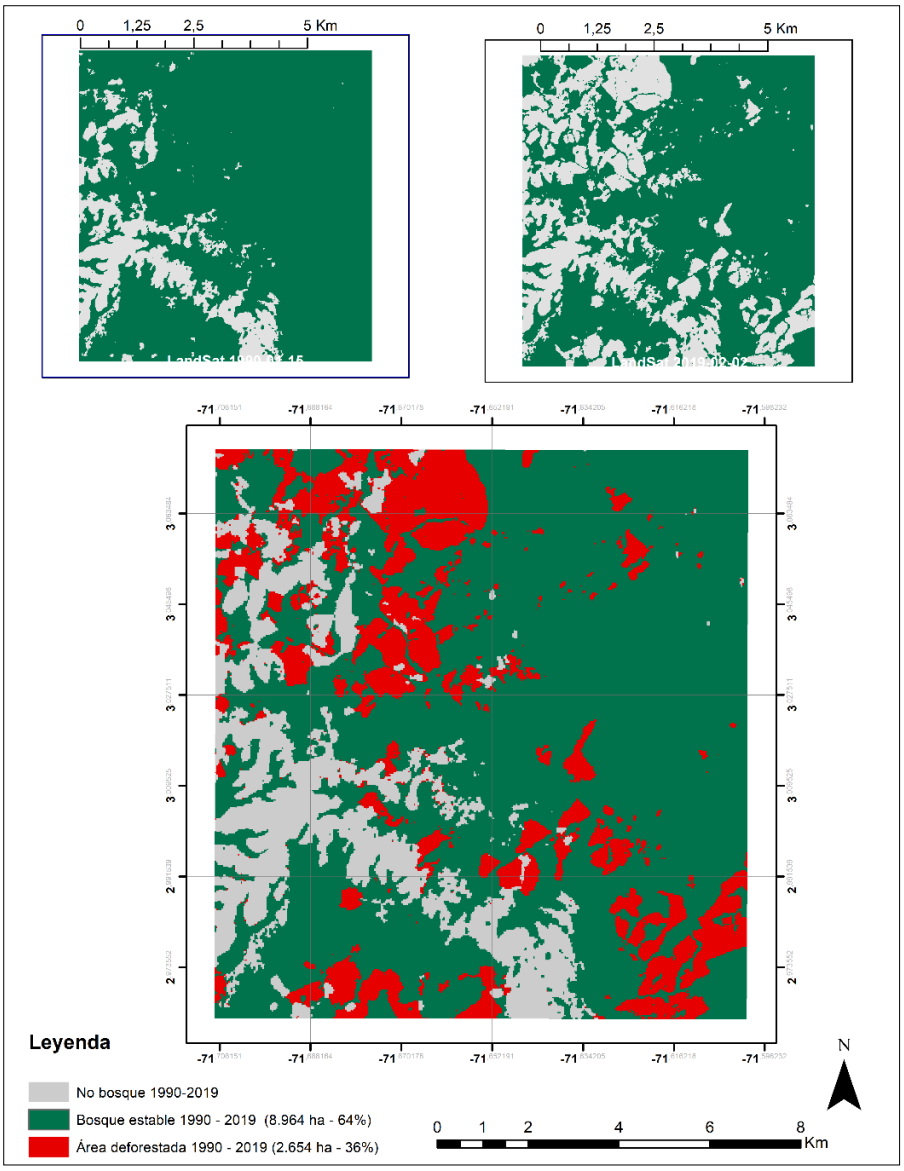

Figura 3. Resultado de la identificación de áreas con coberturas boscosas y no boscosas en el periodo 1991 – 2020. a. clasificación coberturas boscosas y no boscosas; b. clasificación de las coberturas boscosas y no boscosas; c. Diferencia entre ambas escenas identificando las áreas donde se presenta deforestación.

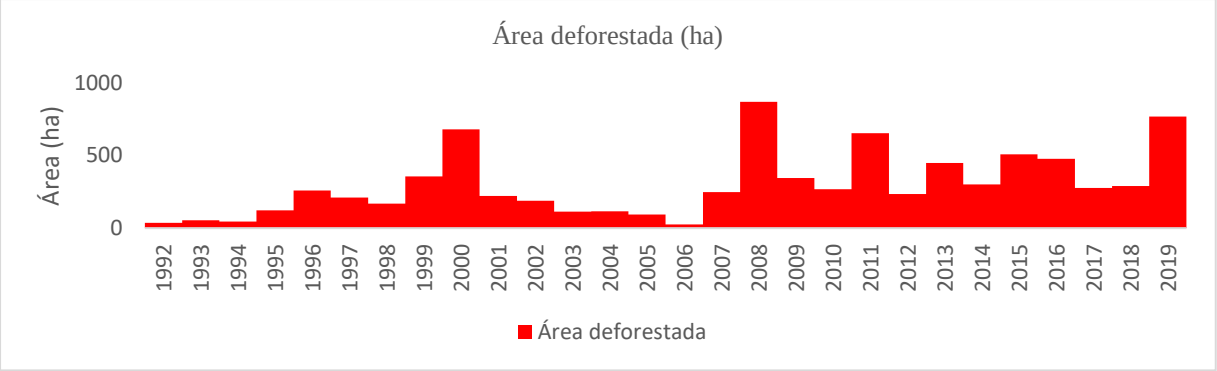

Figura 4. Resultado de la clasificación binaria en relación con las coberturas que cambiaron de bosque a no bosque-Áreas deforestadas, relación año a año.

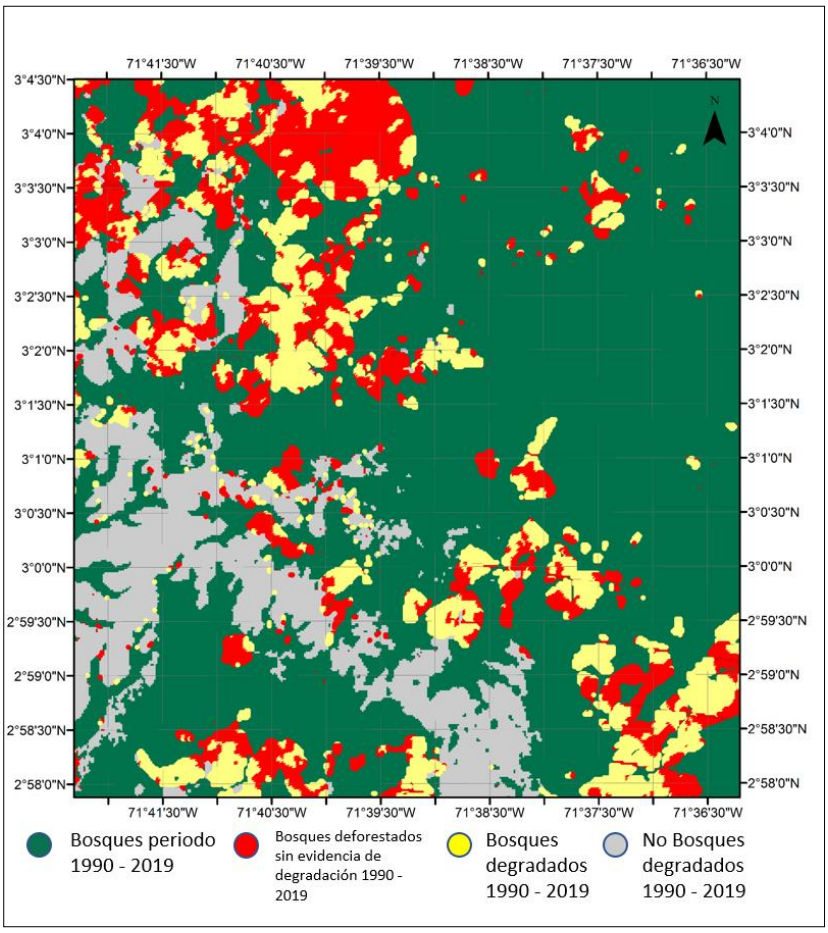

Figura 5. Áreas degradadas previa deforestación identificada con el modelo Neural Network-Trilayered Neural Network. (Verde) zonas clasificadas como bosques en todo el periodo 1990 - 2019. (Rojo) áreas clasificadas como deforestadas sin evidencia de degradación previa, (Amarillo) áreas clasificadas como degradadas previa a deforestación, (Gris) áreas deforestadas en periodo antes de la revisión.

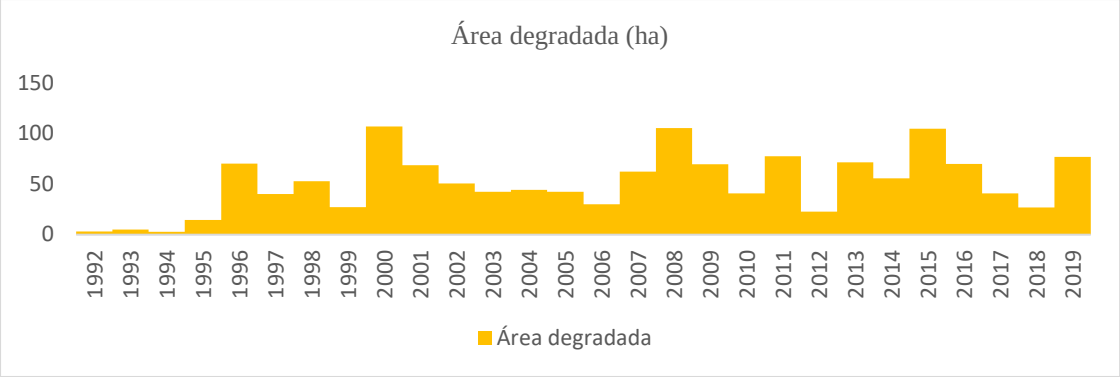

Figura 6. Resultado de la clasificación del área degradada a partir del algoritmo de Neural Network-Trilayered Neural Network, en el período evaluado 1990-2019.