



Cambio de uso de la tierra en la Amazonía peruana mediante algoritmos de inteligencia artificial

Ethel Rubin de Celis^{a*}, Zoila A. Cruz-Burga^a, Nelson Carlos Rosot^b,
Ana Paula Dalla Corte^b, Hideo Araki^b

^a Universidad Nacional Agraria La Molina, Facultad de Ciencias Forestales, Perú

^b Universidade Federal do Paraná, Brasil

* Autor correspondente (erubin@lamolina.edu.pe)

INFO

Keywords

support vector machine
Boosting
Ucayali
Sentinel
PeruSat 1

ABSTRACT

Land use change in the Peruvian Amazon through artificial intelligence algorithms

The research aims to analyze the best supervised satellite image classification model to determine the change in land use between the Support Vector Machine (SVM) and Boosting algorithms for the Peruvian Amazon. Nueva Requena district and different areas of the Amazon basin are currently facing an alarming change in forest cover and land use change, generating important changes in environmental processes. Sentinel-2A satellite images were used, with wavelengths in the visible spectral range and two robust algorithms: Support Vector Machine (SVM) and the Boosting algorithm or decision trees. Twenty-five supervised classifications were made with the algorithms and different inputs from satellite images. The best model of land use change resulted from the classification of the year 2016 with the Boosting algorithm and for the year 2018 it was made with the Support Vector Machine (SVM) algorithm, then through the map algebra the change of use of the Earth. This model presented the lowest classification error of 22,7%, the validation was performed with high-resolution PERUSAT-1 images for the year 2018 and Google Earth images for the year 2016, providing a Kappa index of 0,606 and the percentage correctly classified (PCC) 86,10% for the year 2016 and the Kappa index of 0,560 and the correctly classified percentage (PCC) of 82,30% for the year 2018 demonstrating the considerable and moderate concordance strength respectively.

RESUMEN

La investigación tiene como objetivo analizar el mejor modelo de clasificación supervisada de imágenes satelitales para determinar el cambio de uso de la tierra entre los algoritmos *Support Vector Machine* (SVM) y *Boosting* para la Amazonía peruana. El distrito de Nueva Requena y diferentes zonas de la cuenca amazónica enfrentan en la actualidad un alarmante cambio de cobertura forestal y cambio de uso de la tierra, generándose importantes cambios en los procesos ambientales. Se utilizó imágenes satelitales de Sentinel-2A, con longitudes de onda en el rango espectral del visible y dos algoritmos robustos: *Support Vector Machine* (SVM) y el algoritmo *Boosting* o árboles de decisión. Se realizaron 25 clasificaciones supervisadas con dichos algoritmos y diferentes insumos de las imágenes satelitales. El mejor modelo de cambio de uso de la tierra resultó de la clasificación del año 2016 con el algoritmo *Boosting* y para el año 2018 se realizó con algoritmo *Support Vector Machine* (SVM), luego mediante el algebra de mapa resultó el cambio de uso de la tierra. Este modelo presentó el menor error de clasificación de 22,7%, la validación se realizó con imágenes de alta resolución PERUSAT-1 para el año 2018 e imágenes Google Earth para el año 2016 proporcionando un índice Kappa de 0,606 y el porcentaje correctamente clasificado (PCC) de 86,10% para el año 2016 y el índice Kappa de 0,560 y el porcentaje correctamente clasificado (PCC) de 82,30% para el año 2018 demostrando la fuerza de concordancia considerable y moderada respectivamente.

Received 13 August 2020; Received in revised from 01 September 2020; Accepted 25 January 2021

INTRODUCCIÓN

La Amazonía es una de las regiones del mundo que mantienen los paisajes forestales menos intervenidos (Potapov et al., 2017). Se estima que al 2018, la Amazonía mantiene el 83,4% de su cobertura vegetal original, de las cuales aproximadamente 639 millones de hectáreas es cobertura forestal (Mapbiomas Amazonía, 2020). A pesar de esto, en las últimas décadas el cambio de uso del suelo aumentó y entre el periodo 1985 y 2018 se perdió 69 millones de hectáreas de bosques y hubo un aumento del 172 % en áreas destinadas al sector agropecuario (Mapbiomas Amazonía, 2020). Esta conversión en la cobertura forestal amenaza a la biodiversidad existente en la región y aumenta las emisiones de gases de efecto invernadero (Schielein y Börner, 2018; Vijay et al., 2016; IPCC, 2013).

En ciertas regiones de la Amazonía, la agricultura a gran escala es para la producción de biocombustibles y aceite de palma, expandiéndose de forma muy extensa y visible, la agricultura migratoria sigue muy vigente entre unidades familiares del sector agropecuario, particularmente migrantes o colonos, no solo en diversas regiones tropicales de América Latina, sino también en África y en Asia (Brondizio, 2009; Perz, 2002).

La Amazonía peruana, representa el 11,4 % de toda la Amazonía (Mapbiomas Amazonía, 2020), este porcentaje representa el 53,9 % de la superficie del país (MINAM, 2016). Los bosques húmedos amazónicos en Perú se ubican en la zona oriental del país, se distribuyen desde los 100 hasta los 2800 m.s.n.m. y se caracterizan por tener una cobertura vegetal mayormente arbórea y siempre verde (FAO, 2016; SERFOR, 2017).

En Perú, la pérdida de cobertura forestal sigue los mismos patrones que en el resto de la región amazónica, siendo la mayor conversión de bosque a áreas agropecuarias (Mapbiomas Amazonía, 2020; MINAM, 2014). La deforestación y degradación son las principales amenazas que afrontan los bosques húmedos amazónicos peruanos, más del 80% de la deforestación ocurrió sobre tierras de capacidad de uso mayor forestal y de protección (MINAGRI, 2016); a pesar de que la normativa nacional prohíbe el cambio de uso de estas tierras a fines agropecuarios de acuerdo a la Ley Forestal y de Fauna Silvestre N°29763 y sus reglamentos (SERFOR, 2015).

La deforestación y el cambio de uso de la tierra continúan ocurriendo en el país, no solo por la agricultura a pequeña escala, sino también, por el aumento de la agricultura a gran escala. La pérdida acumulada de cobertura de bosques entre los años 2001 y 2017 fue de 2 130 123 ha teniendo como año base el año 2000. El departamento de Ucayali,

área de estudio del presente artículo, tuvo una pérdida acumulada para el mismo período de 358 483 ha (Geobosques, 2019) siendo el tercer departamento con mayor pérdida de cobertura de bosques en la Amazonía peruana.

El cambio de uso de la tierra de bosque a cultivos tales como palma aceitera y cacao en el departamento de Ucayali viene provocando: (i) pérdida del patrimonio forestal y de fauna silvestre como producto de la deforestación; (ii) contaminación ambiental por un manejo inadecuado de los insumos químicos utilizados para la producción de dichos cultivos; y, (iii) situaciones de conflictividad en torno a la posesión y propiedad de predios privados y territorios indígenas (Defensoría del Pueblo, 2019).

La cobertura del suelo comprende los aspectos que recubren la superficie terrestre de origen natural o cultural, que son observables y pueden ser medidos utilizando fotografías aéreas o sensores remotos. Mientras que el uso de suelo puede definirse como las funciones que se desarrollan sobre aquella cubierta, con el objetivo de modificarla o preservarla para obtener un beneficio, como por ejemplo la agricultura (Peña, 2007).

Los cambios en el uso de la tierra tienen un origen multifactorial, deben ser analizados en distintas escalas temporales y espaciales que permitan conocer de manera espacial y a través del tiempo los cambios ocurridos en la dinámica de las coberturas (Geist y Lambin, 2002). Entender el efecto de las interacciones entre las causas que inducen el cambio de uso del suelo (procesos de decisión humana) y la cobertura boscosa (patrones de distribución espacial) es considerado clave para analizar las consecuencias sobre la biodiversidad y pronosticar cambios futuros (Haines-Young, 2009).

Debido a que la pérdida cobertura forestal sigue ocurriendo en toda la Amazonía, existe una necesidad urgente de desarrollar metodologías que simplifiquen la evaluación y monitoreo del cambio de uso de la cobertura forestal. Este trabajo analiza mediante la tasa de error de clasificación el mejor modelo de clasificación supervisada para determinar el cambio de uso de la tierra, entre los algoritmos *Support Vector Machine* (SVM) y *Boosting* o árboles de decisión en imágenes satelitales Sentinel-2A así como en los diferentes insumos de las imágenes.

MATERIAL Y MÉTODOS

El área de estudio es el distrito de Nueva Requena, provincia de Coronel Portillo, departamento de Ucayali, Perú. El distrito de Nueva Requena fue

creado por el Decreto Ley N ° 23416 y tiene una superficie de 206 185 ha (INEI, 2015). En la figura

1 se detalla el área estudiada.

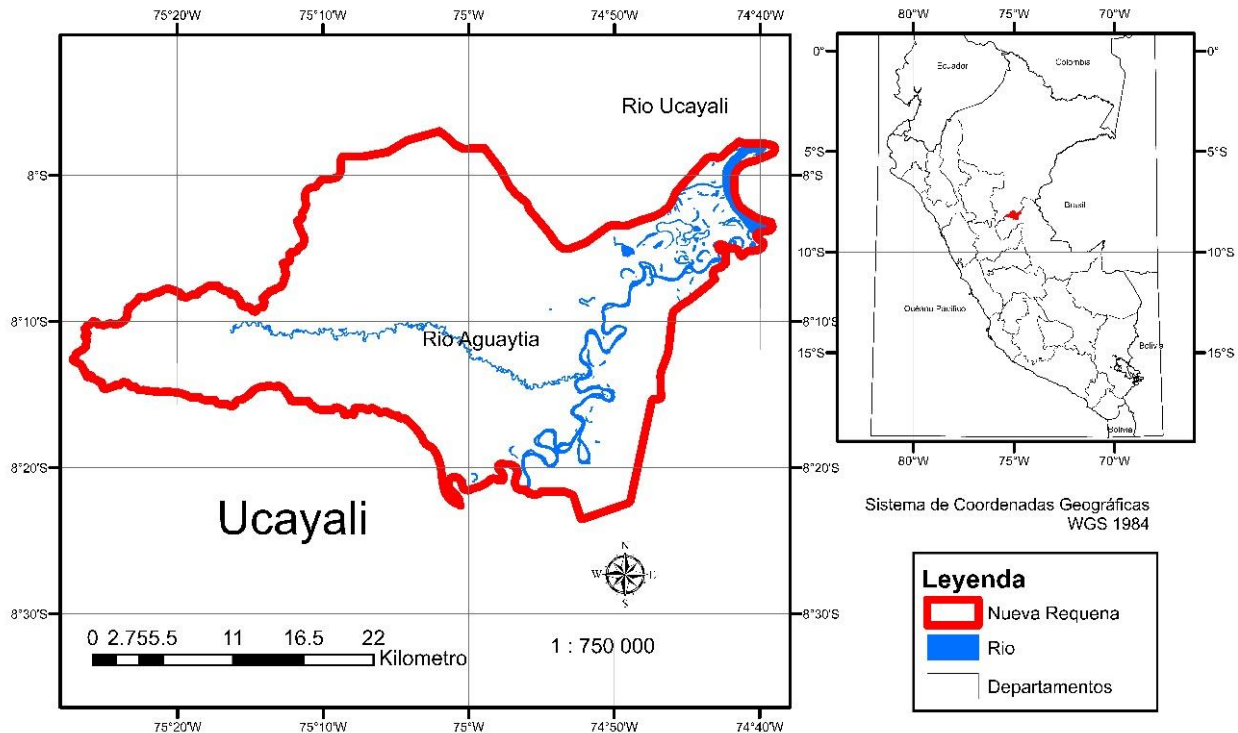


Figura 1 - Mapa de ubicación del área de estudio.

Se adquirió de imágenes satelitales Sentinel-2A accesadas en forma gratuita. Se requirieron cuatro imágenes satelitales que cubrieron el distrito de Nueva Requena para el año 2016 (Figura 2) y año 2018 (Figura 3). Según Olaya (2014), los procesamientos son necesarios realizarlos por las distorsiones provocadas por los movimientos y oscilaciones del sensor o por el relieve del terreno, entre otros factores. Para este estudio se realizaron cuatro pasos de preprocesamiento; tres pasos con el programa PCI Geomática 2018 y solo uno con el programa Erdas Imagine 9.2, siendo estos: unión de bandas (tres bandas visibles por cada imagen); generación del mosaico; georeferenciación y corte de mosaicos.

Para el procesamiento de imágenes satelitales con el fin de determinar el cambio de uso de la tierra se necesitó de una clave de identificación, esta se adaptó de la leyenda del Grupo Intergubernamental de expertos sobre el cambio climático (IPCC). El código de cambio de uso de la tierra se expresó con cuatro dígitos; siendo los dos primeros dígitos del año 2016 y los dos segundos dígitos del año 2018 (Tabla 1); ejemplo: 1020 significa que en el año 2016 se registró tierras forestales y en el año 2018 tierras agrícolas

En la clasificación supervisada el usuario selecciona zonas representativas de la clase en la imagen satelital, esta información utiliza la clasificación

(pasto, bosque, cultivo, etc.). Posteriormente el algoritmo de clasificación crea datos estadísticos para estas áreas y utiliza los resultados para clasificar el resto de la imagen. El analista necesita del conocimiento de la zona de estudio, lo que permite seleccionar áreas de entrenamiento, que son la base para que el programa y algoritmo a usarse pueda definir las clases deseadas, y luego asigne los píxeles de la imagen a las categorías establecidas. Este proceso presenta las siguientes etapas: entrenamiento, selección del algoritmo de clasificación, operaciones de posclasificación (Basterra, 2011).

El procesamiento de clasificación supervisada de imágenes satelitales se efectuó con dos algoritmos *Support Vector Machine* (en el programa PCI Geomática 2018 con la función Kernel y Radial-basis) y *Boosting* (en el programa ERDAS IMAGINE 9.2 y See5/C5). Para realizar la clasificación se segmentó por escala, forma y compacidad. Algunos de los segmentos se seleccionaron para ser áreas de entrenamiento con la asignación de los códigos por medio de la interpretación visual en los mosaicos Sentinel-2A de cada año.

Se realizaron 25 clasificaciones supervisadas a cada mosaico de sensor pasivo para los años 2016 y 2018 para mediante un álgebra de mapas obtener el cambio de uso de la tierra en el período. Las clasificaciones fueron diferentes por los insumos usados siendo estos: mediana de cada banda visible del

sensor pasivo, mediana de los índices de proporción verde (GRVI), índice de verdor (GI) y saturación (SAT), bandas visibles y partición de muestras. Los

resultados de las clasificaciones se transformaron en vector en el programa ArcMap 10.5.

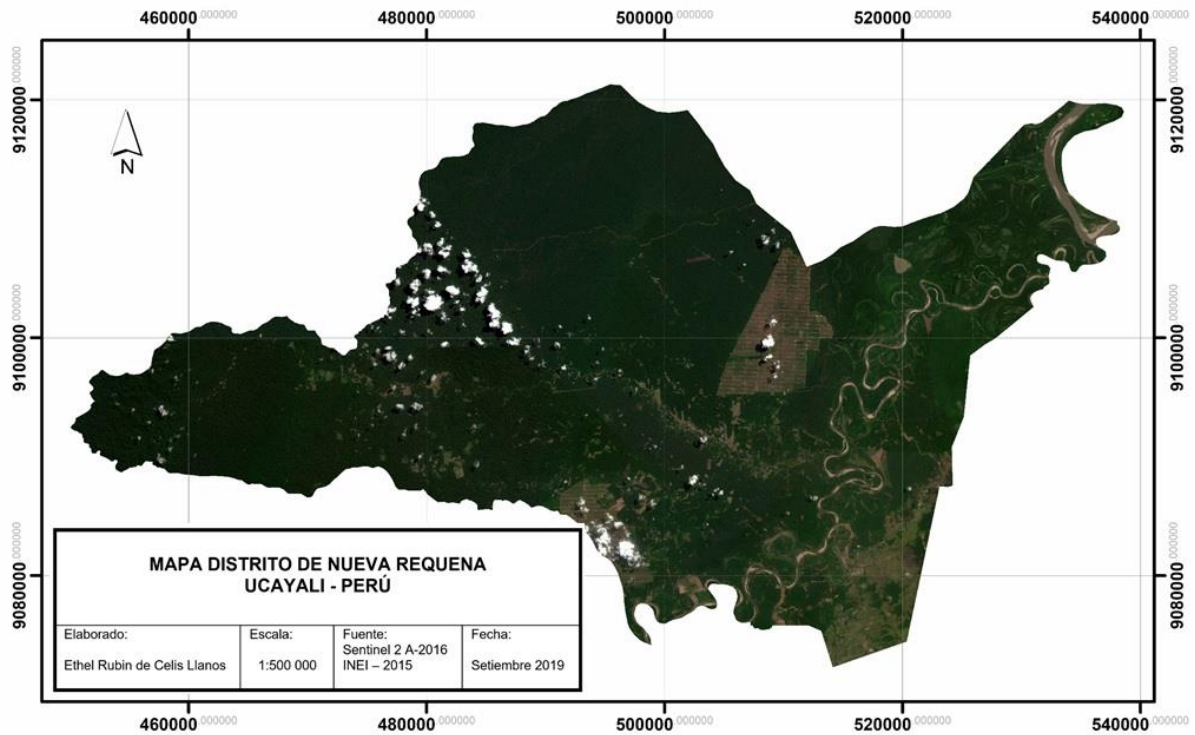


Figura 2 - Mapa mosaico Sentinel-2A año 2016.

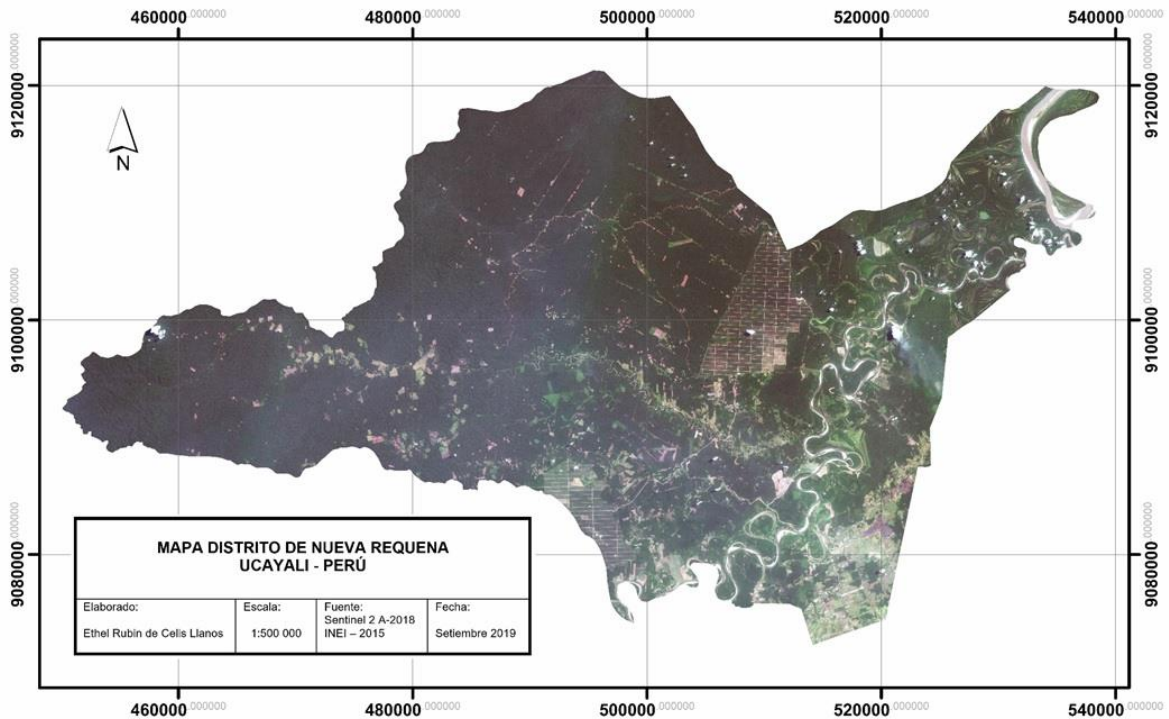


Figura 3 - Mapa mosaico Sentinel-2A año 2018.

Tabla 1 – Clave de identificación de cambio de uso de la tierra.

Código	Descripción cambio de uso de la tierra	Código	Descripción cambio de uso de la tierra
1010	Tierras Forestales – Tierras Forestales	4030	Humedales-Pradera
1020	Tierras Forestales – Tierras Agrícolas	4040	Humedales – Humedales
1030	Tierras Forestales – Praderas	4050	Humedales – Asentamientos
1040	Tierras Forestales – Humedales	4060	Humedales – Otras tierras
1050	Tierras Forestales – Asentamientos	4070	Humedales – Nubes sombra
1060	Tierras Forestales – Otras tierras	5010	Asentamientos – Tierras Forestales
1070	Tierras Forestales – Nubes sombra	5020	Asentamientos – Tierras Agrícolas
2010	Tierras Agrícolas – Tierras Forestales	5030	Asentamientos – Praderas
2020	Tierras Agrícolas – Tierras Agrícolas	5040	Asentamientos – Humedales
2030	Tierras Agrícolas – Praderas	5050	Asentamientos – Asentamientos
2040	Tierras Agrícolas – Humedales	5060	Asentamientos – Otras tierras
2050	Tierras Agrícolas – Asentamientos	5070	Asentamientos – Nubes sombra
2060	Tierras Agrícolas – Otras tierras	6010	Otras tierras – Tierras Forestales
2070	Tierras Agrícolas – Nubes sombra	6020	Otras tierras – Tierras Agrícolas
3010	Praderas – Tierras Forestales	6030	Otras tierras – Praderas
3020	Praderas – Tierras Agrícolas	6040	Otras tierras – Humedales
3030	Praderas – Praderas	6050	Otras tierras – Asentamientos
3040	Praderas – Humedales	6060	Otras tierras – Otras tierras
3050	Praderas – Asentamientos	7020	Nubes sombra-Tierras Agrícolas
3060	Praderas – Otras tierras	7030	Nubes sombra-Asentamiento
3070	Praderas – Nubes sombra	7040	Nubes sombra-Humedales
4010	Humedales – Tierras Forestales	7050	Nubes sombra- Asentamientos
4020	Humedales-Tierras Agrícolas		

Fuente: Rubin de Celis (2019).

El posprocesamiento realizado a las clasificaciones fue agregar características en diferentes atributos de la leyenda con el programa ArcMap 10.5; posterior a ello, se realizó el análisis estadístico buscando cuantificar la tasa de error de clasificaciones de las diferentes clases o categorías. El mejor modelo para la clasificación de cambio de uso de la tierra fue el que presentó una tasa de error de clasificación menor de 30%.

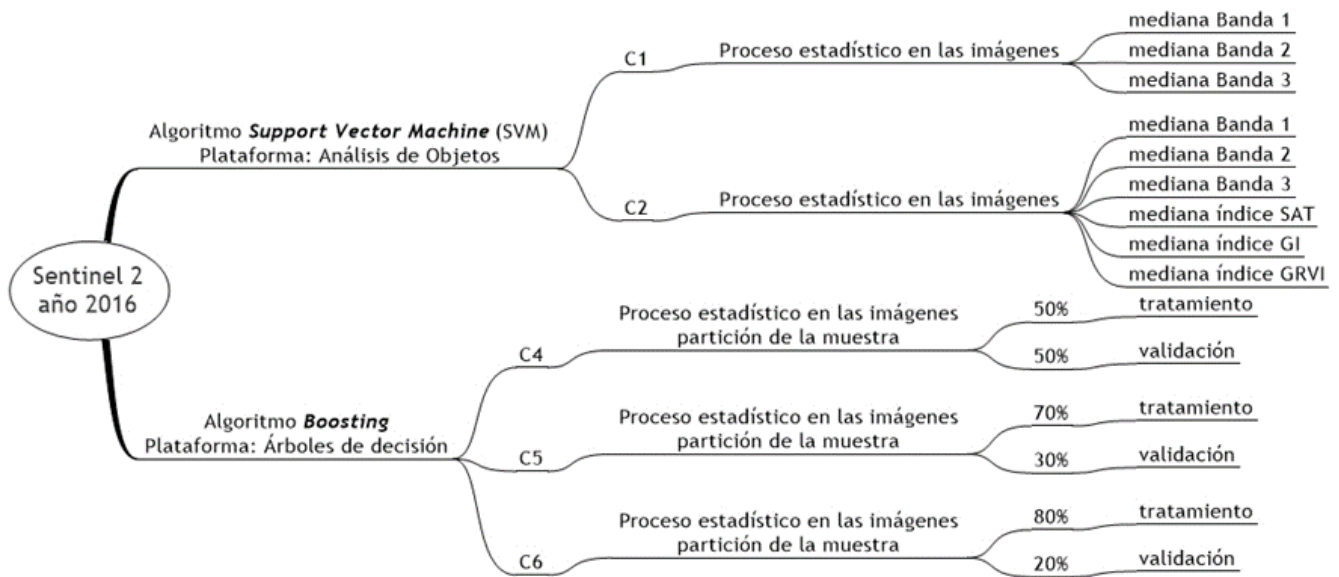
La validación de los mapas según Olofsson et al. (2013) indican que mediante la estimación de la precisión y la incertidumbre de los mapas elaborados con sensores remotos nunca es perfecto. Es por esto la necesidad de valorar un mapa mediante un diseño e implementación de una evaluación de la precisión, determinando las verdaderas categorías mediante una imagen de referencia (comparar el mapa frente a una referencia permite una matriz de error pudiendo ser esta por omisión y comisión). La validación de la clasificación se hizo con ocho imágenes satelitales de PeruSat-1 y una imagen PLANET del año 2018 y con Google Earth del año 2016, las imágenes no cubrían el total del distrito es por esto se generaron 5 095 puntos las que cubrieron todas las imágenes de alta resolución espacial

del año 2018. Con el programa ArcMap 2015 se le asignó a cada punto el atributo o clase de la referencia con las imágenes de alta resolución. Para concluir con la validación se aplicó el Índice Kappa y el Porcentaje Correctamente Clasificado (PCC) mediante el algoritmo Random Forest del programa R. Con este resultado y la tasa de error de clasificación se definió el mejor modelo para el cambio de uso de la tierra.

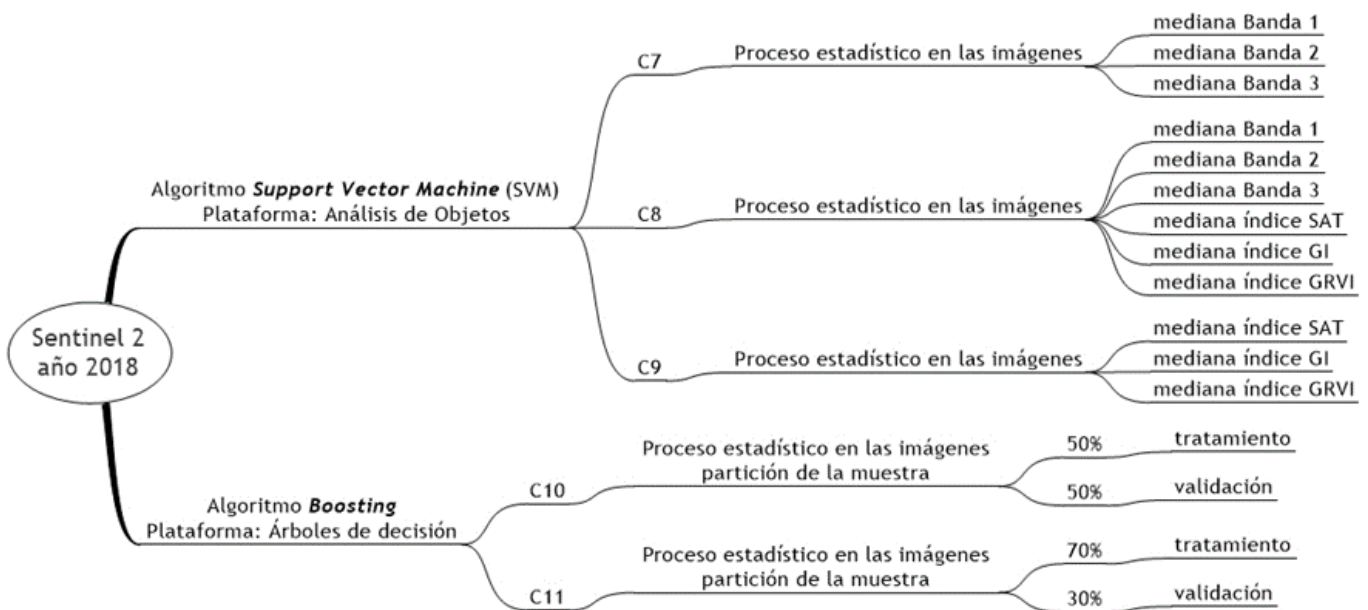
RESULTADOS Y DISCUSIONES

La selección del mejor modelo de clasificación supervisada para determinar el cambio de uso de la tierra se realizó con diferentes insumos como se muestra en la Figura 4 para el año 2016 y en la Figura 5 para el año 2018 luego determinar el cambio de uso de la tierra mediante álgebra de mapas.

La tasa de errores de clasificación del cambio de uso de la tierra del modelo 1 se muestra en la Tabla 2, las clasificaciones con menor tasa de error (menor a 30 %) son las que se seleccionaron para determinar el mejor modelo; y los resultados de validación de la clasificación del cambio de uso de la tierra se observa en la Tabla 3.



Fuente: Rubin de Celis (2019).
Figura 4 – Metodología usada año 2016.



Fuente: Rubin de Celis (2019).
Figura 5 – Metodología usada año 2018.

Tabla 2 – Tasa de error de clasificación del cambio de uso de la tierra del Modelo 1.

	Clasificación Cambio de uso de la tierra	Algoritmos usado *	Tasa de Error	Clasificación Cambio de uso de la tierra	Algoritmos usado *	Tasa de Error
Imágenes satelitales Sentinel-2 A (2016-2018)	C1C7	SVM y SVM	81,50%	C4C10	Boosting y Boosting	23,30%
	C1C8	SVM y SVM	82,60%	C4C11	Boosting y Boosting	23,50%
	C1C9	SVM y SVM	84,00%	C5C7	Boosting y SVM	25,30%
	C1C10	SVM y Boosting	99,90%	C5C8	Boosting y SVM	25,10%
	C1C11	SVM y Boosting	99,80%	C5C9	Boosting y SVM	25,10%
	C2C7	SVM y SVM	81,60%	C5C10	Boosting y Boosting	23,60%
	C2C8	SVM y SVM	80,00%	C5C11	Boosting y Boosting	23,90%
	C2C9	SVM y SVM	81,70%	C6C7	Boosting y SVM	22,70%
	C2C10	SVM y Boosting	34,50%	C6C8	Boosting y SVM	26,10%
	C2C11	SVM y Boosting	31,70%	C6C9	Boosting y SVM	26,40%
	C4C7	Boosting y SVM	23,60%	C6C10	Boosting y Boosting	23,70%
	C4C8	Boosting y SVM	24,00%	C6C11	Boosting y Boosting	24,1%
	C4C9	Boosting y SVM	24,10%			

*=primer algoritmo para el año 2016, segundo algoritmo para el año 2018

Fuente: Rubin de Celis (2019)

Tabla 3 – Validación de la Clasificación del cambio de uso de la tierra del Modelo 1.

Análisis Estadístico/Clasificación		C1C7	C1C8	C1C9	C1C10	C1C11	C2C7	C2C8	C2C9	C2C10	C2C11
2016	Kappa	0,537	0,53	0,538	0,53	0,53	0,606	0,511	0,534	0,515	0,513
	Z	52,40	51,70	52,50	52,20	52,20	56,30	52,70	51,50	53,00	52,80
	PCC	0,820	0,817	0,820	0,816	0,816	0,861	0,799	0,811	0,800	0,800
2018	Kappa	0,547	0,577	0,499	0,504	0,516	0,56	0,577	0,551	0,533	0,514
	Z	51,400	53,700	48,400	47,100	47,600	51,900	53,700	51,500	48,700	47,500
	PCC	0,815	0,826	0,788	0,792	0,801	0,822	0,826	0,816	0,808	0,799

Análisis Estadístico/Clasificación		C4C7	C4C8	C4C9	C4C10	C4C11	C5C7	C5C8	C5C9	C5C10	C5C11
2016	Kappa	0,607	0,606	0,607	0,612	0,608	0,576	0,492	0,514	0,593	0,492
	Z	56,500	56,200	56,400	56,800	56,300	54,000	48,500	50,100	55,700	48,500
	P	0,861	0,861	0,861	0,863	0,862	0,846	0,797	0,812	0,855	0,797
2018	Kappa	0,349	0,576	0,551	0,528	0,523	0,561	0,577	0,541	0,516	0,516
	Z	52,200	53,700	51,400	48,500	48,500	51,900	53,800	50,600	47,400	47,900
	P	0,717	0,825	0,816	0,807	0,805	0,823	0,826	0,812	0,801	0,801

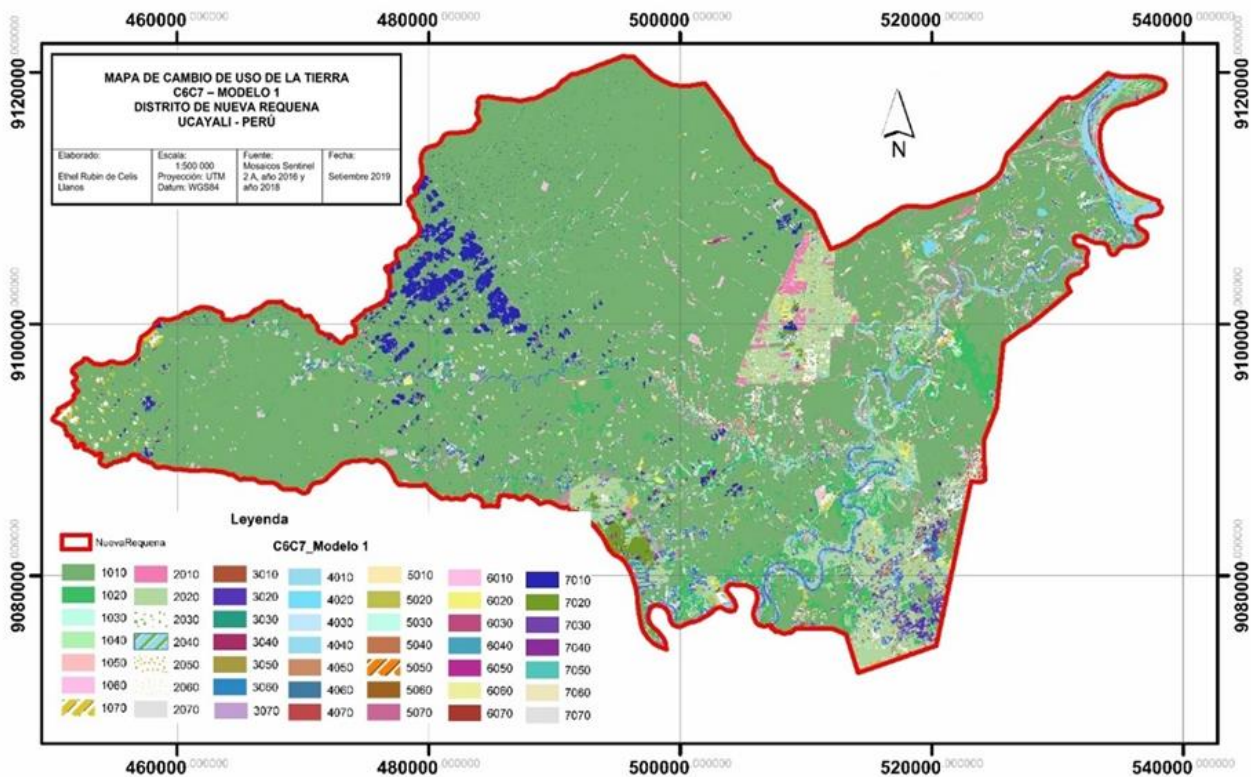
Análisis Estadístico / Clasificación		C6C7	C6C8	C6C9	C6C10	C6C11
2016	Kappa	0,607	0,569	0,607	0,597	0,488
	Z	56,100	53,500	56,000	55,700	48,500
	P	0,861	0,842	0,861	0,856	0,795
2018	Kappa	0,562	0,577	0,551	0,52	0,514
	Z	51,900	53,800	51,400	48,000	47,400
	P	0,823	0,826	0,816	0,802	0,801

Fuente: Rubin de Celis (2019)

Las validaciones del modelo muestran una fuerza de concordancia según el índice Kappa: Moderado (100%) del año 2016; Moderado (96%) y Aceptable (4%) del año 2018. Siendo la mejor, la clasificación C6C7 (C6: algoritmo *Boosting* con partición de la muestra 80% entrenamiento y 20% de prueba en tres bandas espectrales del año 2016; C7: algoritmo *Support Vector Machine* (SVM) con insumos de las medianas de las tres bandas del año 2018), además presenta el menor error de clasificación para todo el modelo 1 siendo este de 22,7% como se muestra en la Figura 6; con el mejor índice Kappa 0,607 para el año 2016 y 0,562 para el año 2018; teniendo una fuerza de concordancia moderada, una tasa de error de clasificación de 22,7% y

un PCC de 86,10% para el año 2016 y 82,30% para el 2018 demostrando la fuerza de concordancia considerable y moderada respectivamente.

De acuerdo con el modelo de clasificación C6C7 se muestra un total de 3 9389,99 ha han cambiado de clases representando un 19,11 % del total del distrito de Nueva Requena. Este modelo evidencia que las tierras forestales presentan una superficie de 164 085,34 ha (79,59 % de la superficie del distrito) en el año 2016 y en el año 2018; 54 837,729 ha pasaron a ser tierras agrícolas, asentamientos, otras tierras, praderas, entre otros representando el 26,60% de la superficie del distrito (Tabla 4).



Fuente: Rubin de Celis (2019)

Figura 6 – Mapa del mejor modelo de cambio de uso de la tierra 2016-2018.

Tabla 4 - Superficie del cambio de uso de la tierra C6C7.

Código	Clase de Cambio de uso de la tierra	Superficie (ha)	Porcentaje (%)	Código	Clase de Cambio de uso de la tierra	Superficie (ha)	Porcentaje (%)
1010	Tierras Forestales – Tierras Forestales	145163,63	70,42	4030	Humedales-Pradera	96,10	0,05
1020	Tierras Forestales – Tierras Agrícolas	13041,75	6,33	4040	Humedales – Humedales	2204,42	1,07
1030	Tierras Forestales – Praderas	495,09	0,24	4050	Humedales – Asentamientos	355,35	0,17
1040	Tierras Forestales – Humedales	1208,09	0,59	4060	Humedales – Otras tierras	131,05	0,06

Tabla 4 - Superficie del cambio de uso de la tierra C6C7.

Código	Clase de Cambio de uso de la tierra	Superficie (ha)	Porcentaje (%)	Código	Clase de Cambio de uso de la tierra	Superficie (ha)	Porcentaje (%)
1050	Tierras Forestales – Asentamientos	635,74	0,31	4070	Humedales – Nubes sombra	248,32	0,12
1060	Tierras Forestales – Otras tierras	1861,10	0,90	5010	Asentamientos – Tierras Forestales	64,79	0,03
1070	Tierras Forestales-Nubes sombra	1679,94	0,81	5020	Asentamientos – Tierras Agrícolas	830,15	0,40
2010	Tierras Agrícolas-Tierras Forestales	4822,93	2,34	5030	Asentamientos – Praderas	19,46	0,01
2020	Tierras Agrícolas-Tierras Agrícolas	18717,95	9,08	5040	Asentamientos – Humedales	118,92	0,06
2030	Tierras Agrícolas-Praderas	818,75	0,40	5050	Asentamientos – Asentamientos	469,57	0,23
2040	Tierras Agrícolas-Humedales	1527,96	0,74	5060	Asentamientos – Otras tierras	104,04	0,05
2050	Tierras Agrícolas-Asentamientos	1770,75	0,86	5070	Asentamientos – Nubes sombra	67,29	0,03
2060	Tierras Agrícolas-Otras tierras	779,94	0,38	6010	Otras tierras – Tierras Forestales	321,08	0,16
2070	Tierras Agrícolas-Nubes sombra	317,9	0,15	6020	Otras tierras – Tierras Agrícolas	1314,63	0,64
3010	Praderas – Tierras Forestales	113,45	0,06	6030	Otras tierras – Praderas	104,98	0,05
3020	Praderas – Tierras Agrícolas	1305,78	0,63	6040	Otras tierras – Humedales	142,69	0,07
3030	Praderas – Praderas	50,87	0,02	6050	Otras tierras – Asentamientos	268,63	0,13
3040	Praderas – Humedales	72,38	0,04	6060	Otras tierras – Otras tierras	156,37	0,085
3050	Praderas – Asentamientos	164,74	0,08	7020	Nubes sombra-Tierras Agrícolas	1229,87	0,60
3060	Praderas – Otras tierras	87,57	0,04	7030	Nubes sombra-Asentamiento	15,60	0,01
3070	Praderas – Nubes sombra	32,09	0,02	7040	Nubes sombra-Humedales	108,52	0,05
4010	Humedales – Tierras Forestales	829,19	0,40	7050	Nubes sombra-Asentamientos	57,69	0,028
4020	Humedales-Tierras Agrícolas	2225,69	1,08				

Fuente: Rubin de Celis (2019).

Las matrices de confusión de las diferentes clasificaciones muestran los errores resultantes de las clasificaciones asignándose una clase en lugar de otra categoría, esta matriz es generada en la validación de los mapas. En la tabla 5 y 6 se muestra que

la clase que tiene mayor error en la clasificación C6 del año 2016 código 2010 y C7 código 1020 del año 2018 son las tierras agrícolas seguido de la clase pradera. Otro cambio de cobertura que se muestra es de otras tierras a tierras forestales.

Tabla 5 - Matriz de confusión C6 del año 2016.

Clase de uso de la tierra	1	2	3	4	5	6	Total	Exactitud	Error Omisión
								%	%
1	3799	115	4	28	1	13	3960	95,93	4,07
2	145	518	19	33	41	37	793	18,28	81,72
3	99	45	3	6	1	2	156	63,46	36,54
4	20	51	0	62	7	1	141	14,18	85,82
5	10	5	0	2	2	0	19	52,63	47,37
6	10	12	0	1	0	3	26	38,46	61,54
Total	4083	746	26	132	52	56	5095		
Exactitud %	93,04	69,44	11,54	46,97	3,85	5,36	Precisión global del mapa	86,10 %	
%Error Comisión	6,96	30,56	88,46	53,03	96,15	94,64			

Fuente: Rubin de Celis (2019).

Tabla 6 - Matriz de confusión C7 del año 2018.

Clase de uso de la tierra	1	2	3	4	5	6	Total	Exactitud	Error Omisión
								%	%
1	3526	249	4	13	10	25	3827	92,13	7,87
2	202	570	24	16	60	35	907	22,27	77,73
3	53	70	3	6	2	13	147	36,05	63,95
4	3	41	0	67	8	2	121	2,48	97,52
5	10	7	0	2	7	0	26	38,46	61,54
6	14	18	1	8	7	19	67	20,90	79,10
Total	3808	955	32	112	94	94	5095		
Exactitud %	92,59	59,69	9,38	59,82	7,45	20,21	Precisión global del mapa		82,30%
%Error Comisión	7,41	40,31	90,63	40,18	92,55	79,79			

Fuente: Rubin de Celis (2019)

El cambio de uso de la tierra mediante clasificaciones supervisadas muestra que, en un período de dos años, Nueva Requena, ha pasado por un proceso de cambio de cobertura de tierras forestales (bosques) a tierras agrícolas, cultivos principalmente. Este cambio de cobertura en corto tiempo responde a una dinámica compleja que tiene como principal agente de deforestación a la agricultura a gran escala, principalmente al monocultivo de palma aceitera. El cultivo de palma aceitera sobre bosques naturales ha venido creciendo notablemente no solo en los países de la cuenca amazónica, si no también, en otros países ubicados en Asia y África. Investigaciones señalan que el crecimiento de este monocultivo seguirá expandiéndose, ocasionando, más deforestación por lo que se enfatiza la necesidad de aumentar el monitoreo en los diferentes países donde viene ocurriendo este cambio de uso de la tierra en forma más acelerada como por ejemplo Perú, Ecuador y Brasil en Sudamérica (Vijay et al., 2016).

Por esta dinámica social se hace necesario buscar un modelo de clasificación adecuado para el monitoreo del cambio de uso del suelo. El uso de algoritmos potentes como Support Vector Machine (SVM) y Boosting han resultado ser útiles en esta tarea; no obstante, hay que considerar ciertos criterios para definir el mejor modelo de clasificación para determinar el cambio de uso de la tierra como: una tasa de error de clasificación menor al 30% y realizar la validación con el índice Kappa con fuerza de concordancia moderada como mínimo, con estos dos criterios se puede determinar el mejor modelo para este fin.

La clasificación con mejor índice Kappa es C6C7 (C6: algoritmo Boosting con partición de la muestra de 80% entrenamiento y 20% en tres bandas del año 2016 y C7: algoritmo Support Vector Machine (SVM) con insumos de las medianas de las tres bandas del año 2018) con 22,7 %, la validación se realizó con imágenes de alta resolución PE-RUSAT-1 para el año 2018 e imágenes Google

Earth para el año 2016 proporcionando un índice Kappa de 0,606 y el porcentaje correctamente clasificado (PCC) de 86,10% para el año 2016 y el índice Kappa de 0,560 y el porcentaje correctamente clasificado (PCC) de 82,30% para el año 2018 demostrando la fuerza de concordancia considerable y moderada respectivamente, siendo el mejor modelo de 25 modelos evaluados. Por otro lado, la matriz de confusión de esta clasificación muestra la existencia de errores de omisión y comisión siendo la clase tierras agrícolas la que más errores presenta, siguiéndole la clase suelo desnudo, pudiéndose evitar esta confusión de clases con áreas de entrenamiento que se ajusten a la clase deseada para mejorar la exactitud del mapa y tener un nivel de concordancia real y la precisión de la misma característica como lo indica Zamora et al. (2016).

El cambio de uso de la tierra para Nueva Requena muestra aproximadamente 12% de cambio en la superficie de este distrito en un período corto de dos años, los cambios en este distrito demuestran la pérdida de la cobertura boscosa. Sin embargo, también muestra con bajo porcentaje, el cambio uso de otras tierras a tierras forestales, esto nos sugiere poner atención al uso de sensores remotos con mayor resolución espacial y espectral para determinar el cambio de uso de la tierra.

CONCLUSIONES

Para tener una clasificación supervisada con menor tasa de error de clasificación y una validación se requiere de interpretar las imágenes satelitales pasivas independientemente para cada año. Asimismo, se encontró que los mejores insumos que aportan a una mejor clasificación supervisada son las bandas visibles del sensor pasivo; y ambos algoritmos Boosting o árboles de decisión y Support Vector Machine brindan el modelo adecuado para realizar la clasificación supervisada para el cambio de uso de la tierra para el distrito de Nueva Requena o zonas amazónicas

similares.

El mejor modelo de clasificación supervisada de cambio de uso de la tierra, fue el que resultó al utilizar imágenes pasivas clasificadas con el algoritmo Boosting con partición de la muestra 80% entrenamiento y 20% de prueba en tres bandas espectrales del año 2016; C7: algoritmo Support Vector Machine (SVM) con insumos de las medianas de las tres bandas del año 2018, los insumos son las bandas espectrales del visible de las imágenes pasivas, el índice Kappa debe ubicarse en el rango de moderado y PCC mayor al 60 % con una tasa de error de clasificación menor al 25 %.

Por otro lado, se identifica que la validación de los modelos es conveniente y necesario para el análisis de imágenes, puesto que la tasa de error de clasificación es un indicador que cuantifica la frecuencia de mala clasificación en la muestra, y no determina por sí solo, cual es el mejor modelo para el clasificador supervisado. Siendo el índice de validación Kappa con una fuerza de concordancia moderado y un PCC mayor al 60 % necesarios para determinar el mejor modelo.

Mediante el uso de estos algoritmos se puede desarrollar una herramienta para monitorear el cambio de uso de la tierra analizando imágenes satelitales con clasificación supervisada.

Se recomienda para próximos trabajos de análisis de cambio de uso de la tierra se incluyan las variables de bandas infrarrojas, imágenes activas, índices relacionados con la vegetación, entre otros. La asignación de las áreas de entrenamiento, en especial de tierras agrícolas, porque es la que presentó mayor error en la validación, puesto que es la parte sensible de la clasificación supervisada con sensores remotos, en particular cuando se usan algoritmos de inteligencia artificial.

AGRADECIMENTOS

KENÉ - Instituto de Estudios Forestales y Ambientales Perú, especialmente a la Ing. Lucila Pautrat por su apoyo con la información.

REFERENCIAS BIBLIOGRÁFICAS

Basterra I. Teledetección - imágenes satelitales - procesamiento digital de imágenes. Cátedra de fotointerpretación - Departamento de Geociencias Facultad de Ingeniería de la Universidad Nacional del Nordeste. Argentina. 2011.

Brondízio E. Agriculture intensification, economic identity, and shared invisibility in Amazonian peasantry: Caboclos and colonists in comparative perspective. *Classical Antiquity* v. 26, p. 181–214, 2009. https://doi.org/10.1007/978-1-4020-9283-1_9.

Defensoría del Pueblo. Adjuntía para la Prevención de Conflictos Sociales y la Gobernabilidad. Lima, Perú. 109 p. 2019.

Geist HJ, Lambin EF. Proximate causes and underlying driving forces of tropical deforestation. *BioScience* v. 52, n. 2, p. 143 – 150, 2002. [https://doi.org/10.1641/0006-3568\(2002\)052\[0143:pcaudf\]2.0.co;2](https://doi.org/10.1641/0006-3568(2002)052[0143:pcaudf]2.0.co;2).

Haines-Young R. Land use and biodiversity relationships. *Land Use Policy*, v. 26, p. 178 – 286, 2009. <https://doi.org/10.1016/j.landusepol.2009.08.009>.

Instituto Nacional de Estadística e Informática del Perú (INEI). Shape político del distrito de Nueva Requena, provincia de Coronel Portillo, departamento de Ucayali. Lima-Perú, 2015.

Intergovernmental Panel on Climate Change (IPCC). The Physical Science Basis. Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, United Kingdom and New York, USA. 1585 p. 2013.

Decreto Ley 23416. Creación de distrito de Nueva Requena, Perú. 1982.

Mapbiomas Amazonía. Colección 2.0. RAISG, 2020. <https://amazonia.mapbiomas.org/>

Ministerio del Ambiente (MINAM). Decreto Supremo Ministerial. N°007-2016-Minam. Lima Perú. 2016.

Ministerio del Ambiente MINAM). Mapa de pérdida de los bosques húmedos amazónicos del Perú 2000 - 2011 - Memoria Descriptiva. Lima Perú. 120 p. 2014.

Olaya V. Sistemas de Información Geográfica. 852 p. 2014. https://www.icog.es/TyT/files/Libro_SIG.pdf

Olofsson P, Foody GM, Stehman SV, Woodcock CE. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, v. 129, p. 122–131, 2013. <https://doi.org/10.1016/j.rse.2012.10.031>.

Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). State of the world's forests 2016. El estado de los bosques del mundo 2016. Los bosques y la agricultura: desafíos y oportunidades en relación con el uso de la tierra. Roma, Italia, 2016. 119 p.

Peña J. Efectos ecológicos de los cambios de coberturas y usos del suelo en la Marina Baixa (ALICANTE). Año de publicación 2007. 558 p. Disertación (Doctorado en Biología) - Universidad de Alicante. España.

Perz SG. The changing social contexts of deforestation in the Brazilian Amazon. *Social Science Quarterly*, v. 83, n. 1, p. 35–52, 2002. <https://doi.org/10.1111/1540-6237.00069>.

Potapov P, Hansen MC, Laestadius L, Turbanova S, Yaroshenko A, Thies C, Smith W, Zhuravleva I, Komarova A, Minnemeyer S, Esipova E. The last frontiers of wilderness: Tracking loss of intact forest landscapes from 2000 to 2013. *Science Advances*, v. 3, n. 1, p 1-14, 2017. <https://doi.org/10.1126/sciadv.1600821>

Rubin de Celis E. Modelos de clasificación para detección del cambio de uso de la tierra en la Amazonia peruana. Año de publicación: 2019. 153 p. Disertación (Doctorado em Ingeniería Forestal) - Universidad Federal do Paraná. Curitiba.

Schielein J y Börner J. Recent transformations of land-use and land-cover dynamics across different deforestation frontiers in the Brazilian Amazon. *Land Use Policy* v. 76, p. 81–94, 2018.

Servicio Nacional Forestal y de Fauna Silvestre (SERFOR). Ley Forestal y Fauna Silvestre N°20763 y sus reglamentos. Bosques productivos para la vida. Lima, Perú, p. 345, 2015.

Servicio Nacional Forestal y de Fauna Silvestre (SERFOR). Cobertura y deforestación en los Bosques Húmedos Amazónicos al 2017. Lima, Perú, p. 14, 2017.

Vijay V, Pimm Sl, Jenkins Cn, Smith Sj. The impacts of oil palm on recent deforestation and biodiversity loss. *PLoS ONE* 11(7): e0159668. Doi: 10.1371/journal.pone.0159668, 2016.

Zamora S, López T, Rodríguez J, Blanco M. Metodología de validación de los mapas de usos de la tierra de Nicaragua. Ministerio del Ambiente y los Recursos Naturales de MARENA. Nicaragua, p. 17, 2016