

REVISIÓN BIBLIOMÉTRICA DE LAS PRINCIPALES METODOLOGÍAS PARA LA EVALUACIÓN DEL USO Y COBERTURA DEL SUELO

Edison Fabian Vargas Becerra

Facultad de Ingeniería Ambiental, Universidad Santo Tomás seccional Tunja,

edisonf.vargasb@usantoto.edu.co

Resumen

Esta investigación presenta una revisión bibliométrica centrada en examinar las metodologías empleadas en la clasificación supervisada y no supervisada del uso y cobertura del suelo. Se realizaron búsquedas en Google Scholar, Science Direct y Scopus para seleccionar 31 artículos entre 2018 y 2024. Los artículos analizados utilizan metodologías de teledetección o sistemas de información geográfica (SIG) y presentan resultados relacionados con la precisión de las metodologías de evaluación de LULC. Se observó que la clasificación supervisada fue la más utilizada, mientras que las técnicas de clasificación más empleadas fueron el índice NDVI, seguido por el algoritmo de máxima verosimilitud. Estos hallazgos contribuyen a aumentar la precisión y fiabilidad de los análisis de uso y cobertura del suelo para abordar los desafíos ambientales y sociales asociados con el desarrollo urbano y rural.

Abstract

This research presents a bibliometric review focused on examining the methodologies used in the supervised and unsupervised classification of land use and land cover. Google Scholar, Science Direct, and Scopus were searched to select 31 articles between 2018 and 2024. The articles analyzed use remote sensing or geographic information systems (GIS) methodologies and present results related to the accuracy of LULC assessment methodologies. It was observed that supervised classification was the most used, while the most used classification techniques were the NDVI index, followed by the maximum likelihood algorithm. These findings contribute to improving the accuracy and reliability of land use and land cover analyzes to address environmental and social challenges associated with urban and rural development.

Palabras clave: Uso del suelo, Clasificación supervisada, revisión sistemática

Keywords: Land use, Supervised classification, systematic review

Introducción

Desde las últimas décadas, se ha generado una amplia necesidad de analizar de qué manera se comporta la cobertura de la tierra, especialmente debido a los cambios en el uso del suelo y la cobertura del mismo. Esto se debe a que, a medida que crece la población, se genera un aumento significativo de las actividades antropogénicas a causa del desarrollo de las ciudades, así como de eventos naturales como incendios forestales y terremotos. Este desarrollo desmedido de las zonas urbanas puede llevar a una sobrecapacidad del territorio, limitando la posibilidad de conservación de recursos naturales que prestan diversos servicios ecosistémicos (Chughtai y otros, 2021).

El uso y la cobertura del suelo (LULC por sus siglas en inglés) son conceptos generalmente relacionados. Las clasificaciones de uso del suelo están relacionados a las actividades humanas, como áreas residenciales, uso industrial, cultivo de cosechas y transporte. Por otra parte, la cobertura terrestre se refiere a las características naturales continuas de la superficie de la Tierra, como el suelo, la vegetación, los cuerpos de agua y las rocas. Los cambios en LULC pueden clasificarse como reemplazos integrales, tal como la conversión de pastizales en tierras de cultivo, o transformaciones parciales, como cambios en el tipo de bosque. Estos cambios se deben en gran parte debido a la urgencia de proporcionar alimentos a una población en constante crecimiento. (Rash y otros, 2023) (Edosa & Nagasa, 2024).

El análisis del LULC se puede realizar por medio de sensores remotos satelitales y a partir de herramientas SIG, las imágenes multispectrales adquiridas por los satélites Landsat, disponibles desde principios de la década de 1970, se han empleado de manera extensa para el análisis de LULC con diferentes grados de éxito. Sin embargo, el despliegue de los satélites Sentinel-2A y 2B de la ESA en 2015 y 2017, respectivamente, marca un hito significativo en la investigación de la clasificación de LULC (Edosa & Nagasa, 2024).

Estas nuevas incorporaciones han revolucionado la disponibilidad de imágenes satelitales, ofreciendo una resolución espacial más detallada de 10 y 20 metros, intervalos de revisión más frecuentes de solo 5 días y una mayor riqueza espectral. Este avance tecnológico ha democratizado el acceso a datos de alta calidad, especialmente diseñados para analizar la vegetación. Este desarrollo ha llevado a la comunidad científica a lograr una mayor precisión en la clasificación global de LULC, incluso en la diferenciación de cultivos. Sin embargo, este progreso ha generado el desafío adicional del incremento en el volumen de datos y la demanda de capacidad computacional necesaria (Jing y otros, 2024).

El empleo de análisis históricos de imágenes satelitales, matrices de transición y enfoques estadísticos representa un conjunto diverso de metodologías para evaluar el estado actual del territorio y generar mapas precisos de la clasificación LULC. Estos mapas proporcionan una herramienta invaluable para categorizar las distintas áreas de la tierra en clases principales, lo que facilita la revisión de los recursos y su influencia en el progreso socioeconómico del área circundante. Esta información es crucial para fomentar prácticas de planificación sostenible, gestión de recursos y conservación ambiental, fundamentales para el equilibrio a largo plazo de los ecosistemas y el bienestar de las comunidades locales (Zhao y otros, 2024) (Velasco Montoya y otros, 2023)

La clasificación de LULC en teledetección implica la agrupación de los píxeles de una imagen en un conjunto de clases, donde los píxeles dentro de la misma clase comparten propiedades similares. Este proceso se basa principalmente en la detección de patrones espectrales en la cobertura terrestre. La clasificación depende de firmas espectrales distintivas para cada clase de cobertura terrestre en el conjunto de bandas utilizado, así como de la capacidad para distinguir de manera fiable estas firmas de otros patrones espectrales presentes. Existen diversos enfoques para la clasificación de datos teledetectados, siendo los principales la clasificación no supervisada y supervisada (Hasnadi y otros, 2009).

Inicialmente, la técnica predominante para la clasificación de LULC fue la interpretación visual, basada en la experiencia del intérprete. Esta metodología ofrecía una alta precisión, superando generalmente a la clasificación por computadora, lo que la convertía en una opción viable para el análisis de imágenes de teledetección de alta resolución. No obstante, su desventaja principal radicaba en su falta de repetibilidad y consistencia. Con el avance tecnológico, el aprendizaje automático ha ganado terreno en la clasificación LULC (Hasmadi y otros, 2009).

En la clasificación no supervisada, como K-Means y Expectation Maximization, se pueden diferenciar las categorías de datos, aunque con cierta incertidumbre en los resultados, usualmente emplean un algoritmo para identificar un número predefinido de grupos estadísticos en un espacio multiespectral o hiperespectral, aunque estos grupos no siempre coinciden con las clases reales de cobertura del suelo (Hasmadi y otros, 2009) (Zhao y otros, 2023).

Por otro lado, la clasificación supervisada, representada por algoritmos como máquina de vectores de soporte (SVM) y árbol de decisiones, se requiere un conocimiento previo de la cobertura del suelo en el área de estudio. Se utilizan datos espectrales de los píxeles en áreas de muestra o firmas espectrales de una biblioteca para entrenar el algoritmo de clasificación. Una vez entrenado, este algoritmo se aplica a toda la imagen para generar el mapa de clasificación. Aunque estas técnicas ofrecen una alta repetibilidad y consistencia en comparación con la interpretación visual, la precisión puede disminuir significativamente al modificar los datos o el área de estudio (Hasmadi y otros, 2009) (Zhao y otros, 2023).

Es fundamental evaluar la precisión del producto final de teledetección en el estudio cartográfico de la cobertura terrestre. Esta evaluación garantiza la calidad de la clasificación y la confianza del usuario en el producto resultante. Normalmente, los resultados de precisión se derivan de técnicas tanto supervisadas como no supervisadas, aunque muestran niveles de precisión relativamente diferentes después de la evaluación (Zhao y otros, 2023).

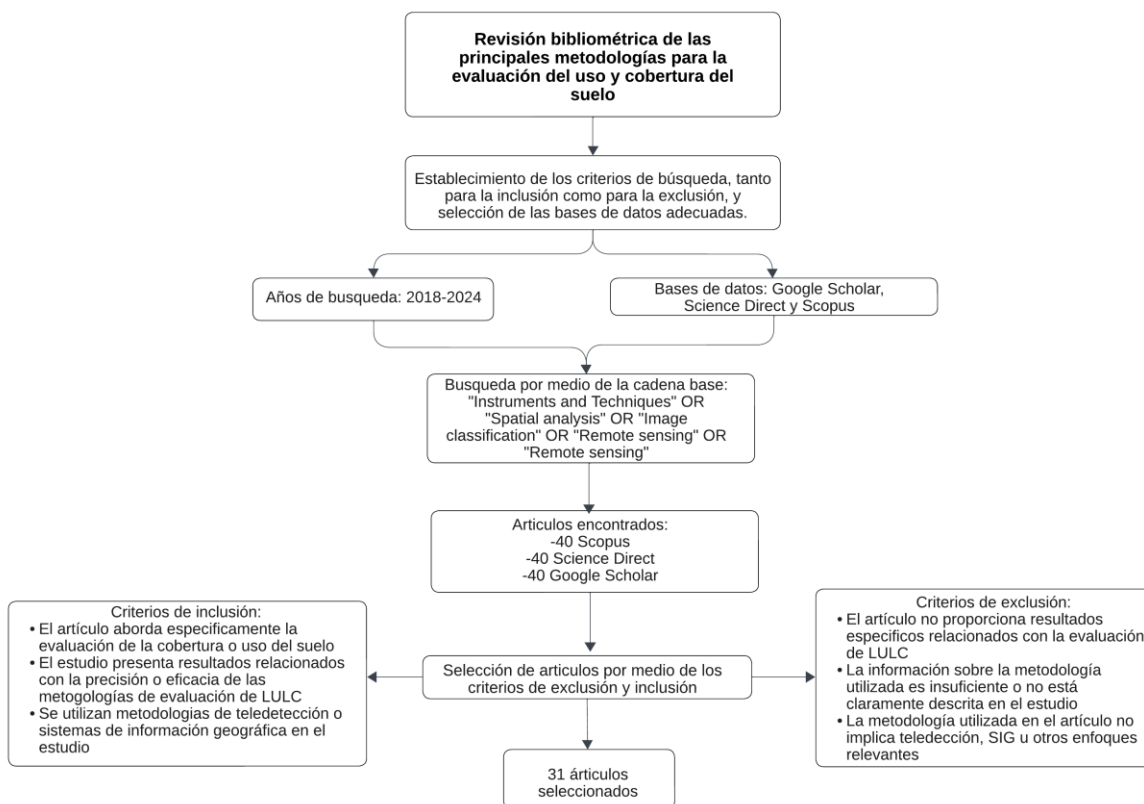
En este contexto de crecimiento poblacional y expansión urbana, la evaluación precisa del uso y cobertura del suelo se ha vuelto fundamental para comprender y abordar los desafíos asociados con el desarrollo sostenible y la conservación de recursos naturales. Este estudio se propone realizar una revisión bibliométrica de las metodologías utilizadas en la clasificación supervisada y no supervisada de LULC, con el objetivo de analizar y sintetizar los hallazgos de una variedad de artículos científicos, se buscará identificar las metodologías más apropiadas para diferentes contextos y tipos de investigación, contribuyendo así a la mejora de la precisión y confiabilidad de los análisis de uso y cobertura del suelo a nivel global.

Metodología

La presente investigación tal como se describe en la figura 1, consiste en una revisión bibliométrica enfocada en examinar las metodologías empleadas en la clasificación supervisada y no supervisada del uso y cobertura del suelo, con el propósito de sintetizar los hallazgos de una variedad de artículos científicos. Se llevaron a cabo búsquedas en Google Scholar, Science Direct y Scopus, abarcando el período de 2018 a 2024, utilizando una cadena de búsqueda específica. Tras aplicar criterios de inclusión y exclusión, se seleccionaron 31 artículos que abordan específicamente la evaluación de la cobertura o uso del suelo, presentan resultados relacionados con la precisión o

eficacia de las metodologías de evaluación de LULC, y emplean metodologías de teledetección o sistemas de información geográfica (SIG). Estos artículos fueron analizados para identificar las metodologías más aplicadas y las técnicas de clasificación predominantes, con el objetivo de contribuir a mejorar la precisión y confiabilidad de los análisis de LULC.

Figura 1 Descripción de la fase metodológica



Fuente: Autor

Desarrollo del artículo

Análisis de revisión de la literatura

Autor y Año	Metodología empleada	Técnica de clasificación	Objetivo de análisis
(Tnag y otros, 2021)	Supervisado	Algoritmo de clasificación y detección de cambios continuos	Cambio LULC cuenca
(Chopade y otros, 2023)	Supervisado	Índice de vegetación de diferencia normalizada (NDVI)	Cambio LULC cuenca manglares
(Matsa y otros, 2020)	Supervisado con observaciones en campo	NDVI	Cambio LULC en un Distrito
(Purwanto y otros, 2023)	Supervisado	Algoritmo de aprendizaje automático (ML)	Cambio LULC en bosque

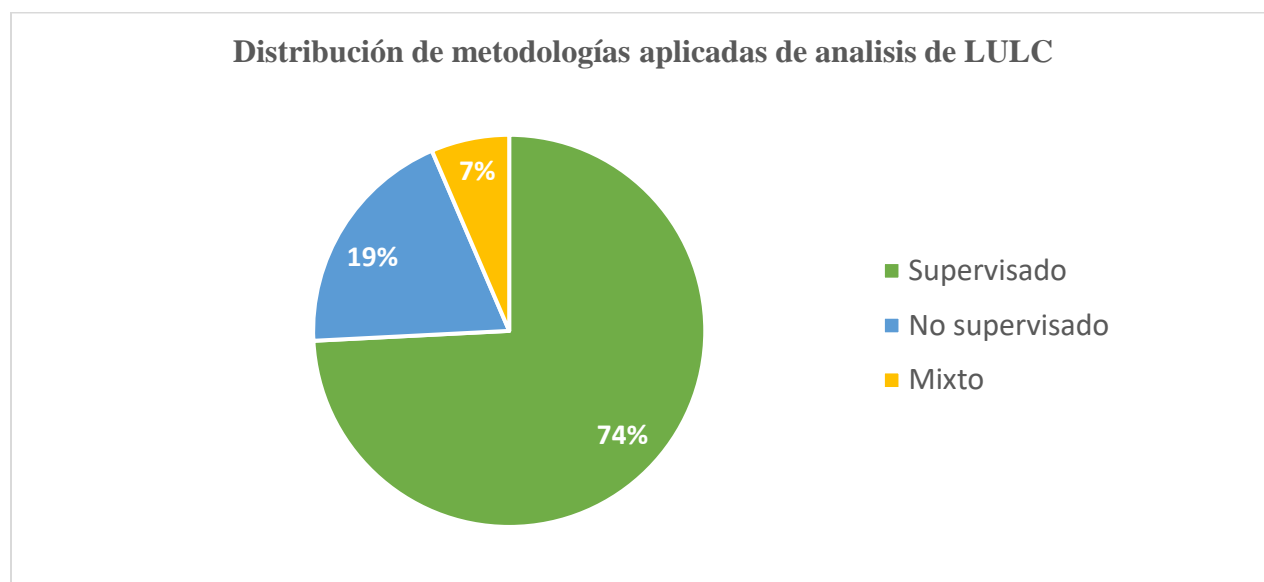
(Rash y otros, 2023)	Supervisado	ML	Cambio LULC
(Chowdhury, 2024)	Supervisado	ML	LULC en suelo urbano
(Haque & Basak, 2017)	Supervisado	CVA, NDVI y Índice Diferencial Normalizado de Agua (NDWI)	Cambio LULC en humedales
(Jung & Chang, 2019)	Supervisado	NDVI	Cambio LULC
(da Silva y otros, 2020)	Supervisado	NDVI, SAVI, LAI, EVI, NDWI	LULC
(Long Feng y otros, 2018)	Supervisado	Algoritmo bosque aleatorio (Random Forest)	Análisis de riesgo de inundaciones
(Sobhani y otros, 2021)	Supervisado	Algoritmos: Bosque aleatorio (RF), árboles de clasificación y regresión (CART)	Cambios LULC en zonas protegidas
(Dargains & Cabral, 2021)	Supervisado	Algoritmo supervisado de máxima verosimilitud	Cambios LULC en finca
(Sisay y otros, 2021)	Supervisado	Algoritmo de máxima verosimilitud	Cambios LULC en cuenca
(Du y otros, 2023)	Supervisado	Algoritmo: Support Vector Machine (SVM)	Cambios LULC en las reservas de carbono
(Traore y otros, 2021)	Supervisado	NDVI, NDBI y NDLI	LULC en área urbana
(Darvishi y otros, 2020)	Supervisado	Clasificación Suave Bayesiana (BSC)	LULC en área metropolitana
(Davis & Balaji Bhaskar, 2022)	Supervisado	NDVI, algoritmo de máxima verosimilitud	Cambio de LULC
(Purwanto y otros, 2023)	Supervisado	Algoritmo bosque aleatorio de aprendizaje automática	Cambio de LULC en suelo forestal
(Tolessa y otros, 2021)	Mixto	Algoritmo de clasificación de máxima verosimilitud (MLC)	Cambio de LULC en cuenca
(Meng y otros, 2021)	Supervisado	Algoritmo bosque aleatorio	Cambio LULC
(Ruggeri y otros, 2021)	No supervisado	ISODATA + OBIA y LSMA + OBIA	Análisis LULC en páramo
(Ngadi Scarpetta y otros, 2023)	No supervisado	Algoritmos de detección de cambios estadísticos	Cambios en LULC
(Chen y otros, 2023)	No supervisado	Algoritmo de detección de cambios	Cambios LULC área urbana
(Demarchi y otros, 2018)	No supervisado	Algoritmo de red neuronal	Mapeo de LULC en zona urbana
(Geta Bihonegn &	Supervisado	Algoritmo de clasificación de máxima verosimilitud	Cambio LULC en cuenca

Gebeyehu Awoke , 2023)			
(Tola & Deyassa, 2024)	Mixto	Algoritmo de clasificación de máxima verosimilitud	Cambios LULC
(Kumar & Kumar Gorai, 2023)	No supervisado	Algoritmo de modelos de redes neuronales convolucionales profundas	Uso de LULC
(Espinoza Guzmán y otros, 2023)	Supervisado	Algoritmos de: máxima verosimilitud, matriz de confusión, distancia mínima, distancia de Mahalanobis, máquina de vectores de soporte	Cambios LULC en montañas
(Long y otros, 2022)	Supervisado	NDVI, NDWI, NDBI, EVI, Algoritmos: máquina de vectores de soporte, bosque aleatorio y árbol de calificación	Evaluación de servicios ecosistémicos ofrecidos debido a LULC
(Prasad y otros, 2022)	Supervisado	Algoritmos: bosque aleatorio (RF), impulso logit (LB), impulso de gradiente estocástico (SGB), redes neuronales artificiales (ANN) y modelos de K-vecino más cercano (KNN)	Uso de LULC
(Paradis, 2022)	No supervisado	Algoritmo: K-medias	Uso de LULC

Análisis de las principales metodologías de evaluación de LULC

Después de analizar las metodologías utilizadas en 31 artículos seleccionados, se observó que la mayoría de los estudios optaron por la clasificación supervisada en 23 casos, mientras que 6 emplearon métodos no supervisados y 2 utilizaron un enfoque mixto.

Figura 2 Distribución de metodologías aplicadas de análisis de LULC



Fuente: Autor

Entre las técnicas de clasificación supervisada, el algoritmo de máxima verosimilitud fue el más comúnmente empleado, especialmente en estudios de caracterización y seguimiento de áreas forestales y agrícolas. Por ejemplo, un estudio realizado por (Dargains & Cabral, 2021)) en una finca en Brasil utilizó este enfoque supervisado para analizar los cambios LULC y la dinámica del carbono a nivel de finca, además de estimar los cambios futuros. En situaciones donde no se contaba con imágenes satelitales, se complementaba la metodología mediante la interpretación visual de los habitantes locales, quienes señalaban los cambios en el paisaje. Este estudio resalta la importancia de la clasificación supervisada en la medición precisa de los cambios en LULC y su impacto en la dinámica espaciotemporal del carbono, evidenciando cómo la elección del método puede influir en las ventajas a corto y largo plazo de la gestión ambiental.

En el ámbito de la clasificación no supervisada, se destaca el uso de algoritmos como el de red neuronal, especialmente en estudios que abarcan extensiones amplias de terreno. Este tipo de clasificación resulta fundamental para el eficaz procesamiento de grandes cantidades de información en un lapso reducido de tiempo. Uno de los enfoques más prometedores dentro de esta clasificación es el algoritmo k-medias, como lo indica (Paradis, 2022), quien presenta el nuevo algoritmo de k-medias probabilísticas para abordar la clasificación no supervisada de datos de imágenes espectrales a gran escala. El método supera las limitaciones del enfoque estándar de k-medias al considerar la heterogeneidad de la varianza entre grupos, siendo efectivo en entornos con datos ruidosos. Destaca debido a su habilidad para gestionar altas cantidades de datos en tiempos razonables, siendo ideal para análisis a gran escala. Ofrece mayor precisión, identificación automática del número óptimo de grupos y manejo de conjuntos de datos de gran magnitud. Su eficiencia se evidencia al analizar imágenes completas con millones de píxeles en minutos, demostrando mejoras significativas en la precisión de la clasificación.

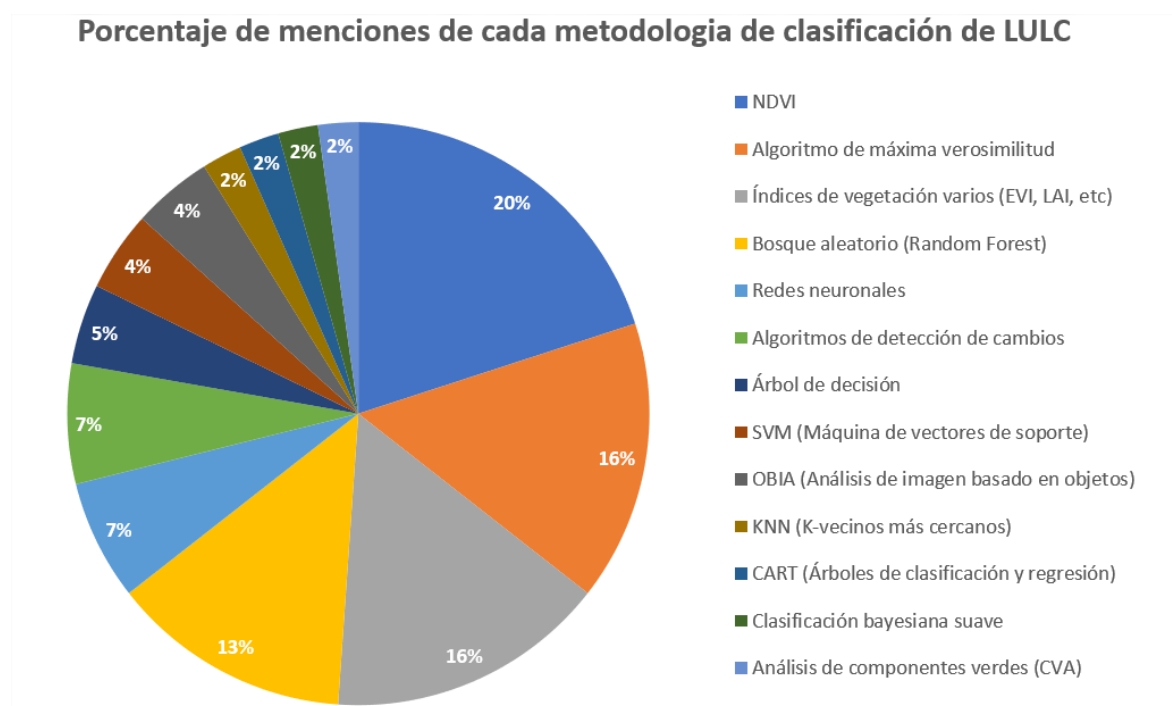
El análisis comparativo de los dos métodos especialmente en la detección de cambios es relevante para justificar el mejor método a través de resultados de evaluación de precisión, como lo precisa la investigación realizada por (Hasmadi y otros, 2009), en la cual evaluó las técnicas de clasificación supervisada y no supervisada para el mapeo de cobertura terrestre utilizando datos de teledetección, centrándose específicamente en el área de la reserva forestal Ayer Hitam. Utilizaron imágenes de satélite SPOT 5 junto con mapas topográficos y de cobertura terrestre, se implementaron técnicas de clasificación supervisada (clasificación de máxima verosimilitud) y no supervisada (ISODATA), luego realizaron una verificación en el terreno para medir la exactitud de la clasificación. Los resultados mostraron que la clasificación supervisada tuvo una precisión general del 90.28%, mientras que la no supervisada fue del 80.56%, se concluyó que la clasificación supervisada fue más precisa que la no supervisada y se sugirió explorar técnicas mixtas con el fin de aumentar la precisión de la clasificación en futuras ocasiones.

Descripción de las principales técnicas de clasificación de LULC

Técnica de clasificación	Descripción
Redes neuronales artificiales (ANN)	<p>La Red Neuronal Artificial se posiciona como un clasificador supervisado dentro del ámbito del aprendizaje profundo. A diferencia de los enfoques de aprendizaje automático tradicionales, la ANN se caracteriza por contar con una cantidad significativa de capas ocultas.</p> <p>Este algoritmo se basa en redes neuronales convencionales, pero se distingue por su estructura multicapa, lo que le permite aprender de los datos de entrada mediante técnicas de retro propagación y generar múltiples capas ocultas para identificar patrones inherentes en los datos. Varios estudios han corroborado la eficacia de los algoritmos ANN en la clasificación de imágenes de teledetección, siendo aplicados exitosamente en diversas regiones especialmente para el análisis de entorno urbano (Chowdhury, 2024).</p>
Bosque aleatorio	<p>El bosque aleatorio es un clasificador de conjunto que incluye una extensa cantidad de árboles de decisión . Estos árboles son construidos a partir de predictores seleccionados de manera aleatoria de un subconjunto de los datos de entrenamiento, y la decisión final de clasificación o predicción se realiza mediante un voto mayoritario. Reconocido como uno de los clasificadores más destacados y poderosos en el ámbito del aprendizaje automático, ha demostrado su eficacia en una variedad de aplicaciones (Adugna y otros, 2022)</p>
Máquina de vectores de soporte	<p>Se destaca como un conjunto de algoritmos de aprendizaje automático teóricamente poderosos. Su principio fundamental reside en la construcción de un hiperplano óptimo, también</p>

	<p>conocido como límite de decisión, que maximiza la distancia entre las muestras más cercanas (llamadas vectores de soporte) y efectivamente separa las clases.</p> <p>Este modelo se enfoca en identificar el hiperplano de separación óptimo entre las clases, priorizando los casos de entrenamiento ubicados en los extremos de las distribuciones de clases, conocidos como vectores de soporte, mientras descarta los demás casos de entrenamiento (Aduña y otros, 2022).</p>
<p>Algoritmo de máxima verosimilitud</p>	<p>Este algoritmo clásico es frecuentemente seleccionado por numerosos investigadores como punto de referencia para comparar la precisión de otros métodos de clasificación. Evalúa la distribución gaussiana de cada clase espectral basándose en los datos de entrada, utilizando una matriz de covarianza para ponderar las discrepancias entre los grupos espectrales y los píxeles de la imagen. (Chowdhury, 2024).</p>
<p>NDVI</p>	<p>Este índice se destaca como el más utilizado en la investigación de la vegetación. Se obtiene mediante la relación de la reflectancia en el espectro rojo y el infrarrojo cercano, lo que posibilita la estimación de la vegetación al medir la reflectancia de la superficie en el píxel del suelo. Por ejemplo, cuando un árbol está saludable, refleja una mayor cantidad de radiación solar en el infrarrojo cercano y menos en el rojo, lo que resulta en un NDVI elevado. En contraste, cuando un árbol está enfermo, ocurre lo contrario. (Jung & Chang, 2019).</p>

Figura 3 Descripción de menciones de técnicas de clasificación de LULC



Fuente: Autor

LA principal técnica de clasificación empleada en los artículos analizados con 9 menciones fue el índice NDVI, este se destaca como el índice más comúnmente empleado en la investigación de la vegetación debido a su simplicidad y precisión. Esta metodología de clasificación se apoya en el entendimiento de las particularidades del área de estudio y está influenciada por la composición del suelo presente en la región. El NDVI, un índice de vegetación ampliamente utilizado, se encarga de calcular tanto la cantidad como el vigor de la vegetación utilizando datos del espectro electromagnético en el infrarrojo cercano (NIR) y las bandas visibles en rojo (Long y otros, 2022) (Chopade y otros, 2023).

Este método se ha empleado extensamente especialmente para la determinación de cambios en la vegetación como en el estudio realizado por (Chopade y otros, 2023), en el cual se aplicó un enfoque de umbral de NDVI para clasificar el NDVI en cinco categorías distintas, lo que permitió observar una evolución gradual en la cobertura de manglares a lo largo del periodo estudiado. Estos hallazgos respaldan la utilidad del enfoque NDVI en la detección de cambios en los manglares en la costa de Ghogha, Bhavnagar, Golfo de Khambat. En resumen, este estudio subraya la efectividad del método de umbralización del NDVI para para la valoración de alteraciones en la vegetación y su relevancia en la cartografía de la cobertura de manglares.

En cuanto al uso de algoritmos se han generado diversas técnicas tal como lo menciona (Chowdhury, 2024) las cuales van desde clasificadores paramétricos hasta algoritmos de aprendizaje automático y profundo. Entre los clasificadores paramétricos se destacan los de máxima verosimilitud, paralelepípedo, distancia mínima y discriminante lineal, además de los bayesianos. Por otro lado, los clasificadores de aprendizaje automático comprenden máquinas de

vectores de soporte, bosques aleatorios y k vecinos más cercanos, mientras que los algoritmos de aprendizaje profundo engloban desde redes neuronales artificiales hasta redes neuronales convolucionales.

Los algoritmos de aprendizaje automático y profundo superan a otras técnicas de clasificación en términos de precisión y eficiencia computacional. En particular, se ha notado un incremento notable en la aplicación de máquinas de vectores de soporte, bosques aleatorios y redes neuronales artificiales en la clasificación de uso y cobertura de la tierra (LULC), debido a su mayor precisión y menor tiempo de procesamiento (Chowdhury, 2024).

Es importante conocer las diferencias de aplicabilidad y ventajas de cada uno de estos algoritmos para el análisis de LULC como lo menciona (Chowdhury, 2024) en su estudio en el cual se pretendía evaluar y comparar la precisión de tres algoritmos de aprendizaje automático en la clasificación de imágenes de satélite. Específicamente, se analizaron el desempeño del bosque aleatorio (RF), SVM y las redes neuronales artificiales (ANN), en contraste con el método tradicional de clasificación de máxima verosimilitud (MaxL). El enfoque se centró en determinar cuál de estos métodos ofrece resultados más precisos en la clasificación de diferentes clases de uso y cobertura de la tierra en la región de interés, con lo cual se encontró que el modelo de redes neuronales artificiales (ANN) superan los resultados de estudios anteriores realizados en áreas urbanas similares seguido por los métodos de bosque aleatorio (RF) y SVM

Los algoritmos de aprendizaje automático como el bosque aleatorio y la máquina de vectores de soporte, han ganado una amplia aceptación en la comunidad de teledetección debido a su eficacia en la clasificación de imágenes tal como lo menciona (Adugna y otros, 2022) quienes compararon estos dos algoritmos para investigar su rendimiento en la clasificación de cobertura terrestre en áreas extensas con conjuntos de datos de alta dimensión. Los resultados revelaron que el bosque aleatorio sobresale como el algoritmo superior, ofreciendo una mayor precisión en el mapeo de cobertura terrestre en áreas grandes o regionales que involucran imágenes de resolución gruesa. Específicamente, el bosque aleatorio se destaca en la clasificación de clases mixtas, como urbanizaciones, bosques, vegetación herbácea y arbustos, lo que resulta en un mapa de cobertura terrestre más coherente y con menos confusión entre las clases. Por otro lado, la SVM mostró ser menos efectiva, generando un producto con cierto ruido debido a una mayor confusión entre las clases. Además, la SVM se caracteriza por su alto costo computacional y de memoria, lo que puede limitar su capacidad para manejar grandes conjuntos de datos y generar productos de cobertura terrestre precisos debido a restricciones de memoria.

Principales aplicaciones del análisis de LULC

Los resultados revelan que la mayoría de los estudios se enfocan en el análisis de cambios en el LULC, representando el 70% del total con 21 temas identificados. Le siguen en menor medida temas relacionados con el uso del suelo, comprendiendo un 29% con 10 temas. Las áreas geográficas más mencionadas incluyen las cuencas hidrográficas, con 7 menciones, seguidas de cerca por las áreas urbanas y metropolitanas, con 5 menciones. Otros lugares destacados son los bosques y zonas protegidas, con 2 menciones cada uno, mientras que otros como fincas, manglares, distritos, páramos, montañas, reservas de carbono y humedales, recibieron una mención cada uno.

Se destaca la importancia de la evaluación de servicios ecosistémicos relacionados con LULC para la sostenibilidad ambiental, así como el análisis de cambio LULC, especialmente en reservas de carbono, debido a su relevancia en la mitigación del cambio climático global.

Tal como lo menciona (Jing y otros, 2024) en su estudio del análisis de los cambios espaciotemporales en la cobertura terrestre global de 2001 a 2020 el cual revela importantes tendencias relacionadas con el cambio climático y la ecología. Se observaron cambios significativos en diversos tipos de cobertura terrestre, como el aumento de los bosques mixtos, las sabanas leñosas y las áreas urbanizadas, y la disminución de las tierras de hoja perenne y las tierras áridas. Se identificaron cambios fluctuantes en la cobertura de hoja perenne, con dinámicas notables en bosques caducifolios latifoliados, matorrales densos, humedales permanentes y áreas de cultivo/vegetación natural.

Estas variaciones son más prominentes en regiones específicas, como los cambios en los bosques de hoja perenne en América del Norte y del Sur, y en las sabanas en África y Eurasia. El análisis de transición revela que muchos tipos de cobertura terrestre pasaron a sabanas leñosas, sabanas y pastizales, principalmente debido a la deforestación, los incendios forestales y el cambio climático. Estos hallazgos tienen implicaciones significativas para la formulación de políticas, la predicción geográfica y las evaluaciones ambientales, aunque se requieren más investigaciones para comprender completamente las causas y consecuencias del cambio de cobertura terrestre y mejorar la precisión de los datos de teledetección utilizados en estos análisis.

Análisis y comparación de metodologías en la evaluación de cambios en LULC

El análisis comparativo de las metodologías de evaluación de LULC destaca la amplia variedad de enfoques adoptados en la investigación científica. Aunque la clasificación supervisada sigue siendo predominante, los métodos no supervisados y mixtos están ganando popularidad gracias a su capacidad para procesar grandes conjuntos de datos y su eficiencia computacional. En términos de precisión y eficiencia, las redes neuronales artificiales y los bosques aleatorios han demostrado ser particularmente efectivos en la clasificación de imágenes de teledetección a gran escala. No obstante, se requiere realizar más investigaciones para comprender completamente las causas y consecuencias del cambio en la cobertura terrestre, así como para mejorar la precisión de los datos utilizados en estos análisis. En general, la selección del método adecuado debe basarse en las características específicas del área de estudio y los objetivos de la investigación, garantizando así resultados precisos y relevantes para la gestión ambiental y la planificación del uso del suelo. La continua exploración y evaluación de nuevas técnicas y algoritmos también son esenciales para avanzar en la comprensión y la capacidad predictiva de los modelos de cambio de cobertura terrestre en el futuro.

Conclusiones

Es crucial la selección de la metodología adecuada para alcanzar resultados precisos en la clasificación de LULC. La clasificación supervisada, especialmente con algoritmos como el de máxima verosimilitud, ha destacado por su eficacia en la caracterización y seguimiento de áreas forestales y agrícolas, brindando mediciones exactas de los cambios en el paisaje y su impacto en la dinámica del carbono. En contraposición, la clasificación no supervisada, utilizando algoritmos

como redes neuronales, sobresale por su capacidad para procesar grandes volúmenes de datos, siendo ideal para análisis a gran escala. El análisis comparativo de ambos métodos revela la superioridad de la clasificación supervisada en términos de precisión, según varios estudios, aunque la clasificación no supervisada, aunque eficiente para análisis a gran escala, puede presentar limitaciones en cuanto a precisión.

Por otra parte, se destaca que el índice NDVI fue el más utilizado en las investigaciones analizadas. Esta tendencia puede atribuirse al creciente interés de los investigadores en analizar el cambio de la vegetación en regiones específicas. El enfoque en la conservación de la cobertura vegetal refleja la creciente preocupación a nivel mundial por la pérdida de biodiversidad y los impactos del cambio climático, lo que ha impulsado una mayor atención hacia la monitorización y promoción de la conservación de la vegetación. Esta prevalencia del uso del índice NDVI resalta su papel crucial en la investigación ambiental y subraya la importancia de su aplicación en la identificación y seguimiento de los cambios en la cobertura vegetal para la gestión sostenible de los recursos

Los avances en técnicas de aprendizaje automático y profundo, como máquinas de vectores de soporte, bosques aleatorios y redes neuronales artificiales, están revolucionando los análisis de uso y cobertura del suelo al ofrecer mayor precisión y eficiencia computacional. La combinación de diversos enfoques metodológicos y el empleo de algoritmos avanzados son cruciales para mejorar la comprensión y gestión de los cambios en el paisaje, así como para abordar los desafíos ambientales y sociales asociados con el desarrollo urbano y rural. Estos descubrimientos establecen una base sólida para futuras investigaciones y políticas orientadas a promover prácticas de manejo sostenible del suelo y conservación del medio ambiente.

Referencias

- Adugna, T., Xu, W., & Fan, J. (2022). Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote sensing*, 14(3). <https://doi.org/https://doi.org/10.3390/rs14030574>
- Chen, H., Song, J., Wu, C., Du, B., & Yokoya, N. (2023). Exchange means change: An unsupervised single-temporal change detection framework based on intra- and inter-image patch exchange. *ISPRS Journal of Photogrammetry and Remote Sensing*, 206, 87-105. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2023.11.004>
- Chopade, M. R., Mahajan, S., & Chaube, N. (2023). Assessment of land use, land cover change in the mangrove forest of Ghogha area, Gulf of Khambhat, Gujarat. *Expert Systems with Applications*, 212. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.118839>
- Chowdhury, S. (2024). Comparison of accuracy and reliability of random forest, support vector machine, artificial neural network and maximum likelihood method in land use/cover classification of urban setting. *Environmental Challenges*, 14. <https://doi.org/https://doi.org/10.1016/j.envc.2023.100800>

- Chughtai, A. H., Abbasi, H., & Karas, I. R. (2021). A review on change detection method and accuracy assessment for land use land cover. *Remote Sensing Applications: Society and Environment*, 22.
- da Silva, V. S., Salami, G., da Silva, M. I., & Silva, E. A. (2020). Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification. *Geology, Ecology, and Landscapes*, 4(2). <https://doi.org/https://doi-org.crai-ustadigital.usantotomas.edu.co/10.1080/24749508.2019.1608409>
- Dargains, A., & Cabral, P. (2021). A GIS-based methodology for sustainable farming planning: Assessment of land use/cover changes and carbon dynamics at farm level. *Land Use Policy*, 111. <https://doi.org/https://doi.org/10.1016/j.landusepol.2021.105788>
- Darvishi, A., Yousefi, M., & Marullb, J. (2020). Modelling landscape ecological assessments of land use and cover change scenarios. Application to the Bojnourd Metropolitan Area (NE Iran). *Land Use Policy*, 99. <https://doi.org/https://doi.org/10.1016/j.landusepol.2020.105098>
- Davis, F., & Balaji Bhaskar, M. S. (2022). Assessment of water, soil contamination and land cover changes in Sims and Vince Bayou urban watersheds of Houston, Texas. *Watershed Ecology and the Environment*, 4, 73-85. <https://doi.org/https://doi-org.crai-ustadigital.usantotomas.edu.co/10.1016/j.wsee.2022.08.002>
- Demarchi, L., Canters, F., Cariou, C., Licciardi, G., & Cheung-Wai Chan, J. (2018). Assessing the performance of two unsupervised dimensionality reduction techniques on hyperspectral APEX data for high resolution urban land-cover mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 166-179. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2013.10.012>
- Du, L., Dong, C., Kang, X., Xinglong, Q., & Gu, L. (2023). Spatiotemporal evolution of land cover changes and landscape ecological risk assessment in the Yellow River Basin, 2015–2020. *Journal of Environmental Management*, 332. <https://doi.org/https://doi.org/10.1016/j.jenvman.2022.117149>
- Edosa, B., & Nagasa, M. (2024). Spatiotemporal assessment of land use land cover change, driving forces, and consequences using geospatial techniques: The case of Naqamte city and hinterland, western Ethiopia. *Environmental Challenges*, 14. <https://doi.org/https://doi.org/10.1016/j.envc.2023.100830>
- Espinoza Guzmán, M. A., Borrego, D. A., & Sahagún Sánchez, F. J. (2023). Evaluation of recent land-use and land-cover change in a mountain region. *Trees, Forests and People*, 11. <https://doi.org/https://doi.org/10.1016/j.tfp.2023.100370>
- Geta Bihonegn, B., & Gebeyehu Awoke, A. (2023). Evaluating the impact of land use and land cover changes on sediment yield dynamics in the upper Awash basin, Ethiopia the case of Koka reservoir. *Heliyon*, 12(9). <https://doi.org/https://doi.org/10.1016/j.heliyon.2023.e23049>
- Haque, I., & Basak, R. (2017). Land cover change detection using GIS and remote sensing techniques: A spatio-temporal study on Tanguar Haor, Sunamganj, Bang. *The Egyptian Journal of Remote Sensing and Space Science*. <https://doi.org/https://doi.org/10.1016/j.ejrs.2016.12.003>
- Hasmadi, M., HZ, P., & MF, S. (2009). Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Journal of Society and Space*, 5, 1-10.

- Jing, Q., He, J., Li, Y., Yang, X., Peng, Y., Wang, H., Zhang, X. (2024). Analysis of the spatiotemporal changes in global land cover from 2001 to 2020. *Science of The Total Environment*, 908.
- Jung, M., & Chang, E. (2019). NDVI-based land-cover change detection using harmonic analysis. *International Journal of Remote Sensing* (36). <https://doi.org/https://doi-org.crai-ustadigital.usantotomas.edu.co/10.1080/01431161.2015.1007252>
- Kumar, A., & Kumar Gorai, A. (2023). A comparative evaluation of deep convolutional neural network and deep neural network-based land use/land cover classifications of mining regions using fused multi-sensor satellite data. *Advances in Space Research*, 72(11). <https://doi.org/https://doi.org/10.1016/j.asr.2023.08.057>
- Long Feng, Q., Liu, J., & Gong, J. (2018). Urban Flood Mapping Based on Unmanned Aerial Vehicle Remote Sensing and Random Forest Classifier—A Case of Yuyao, China. *Water*, 74, 1437-1455. <https://doi.org/https://doi.org/10.3390/w7041437>
- Long, X., Lin, H., An, X., Chen, S., Qi, S., & Zhang, M. (2022). Evaluation and analysis of ecosystem service value based on land use/cover change in Dongting Lake wetland. *Ecological Indicators*, 136. <https://doi.org/https://doi.org/10.1016/j.ecolind.2022.108619>
- Matsa, M., Mupepi, O., Musasa, T., & Defe, R. (2020). A GIS and remote sensing aided assessment of land use/cover changes in resettlement areas; a case of ward 32 of Mazowe district, Zimbabwe. *Journal of Environmental Management*, 276. <https://doi.org/https://doi.org/10.1016/j.jenvman.2020.111312>
- Meng, Y., Yang, M., Liu, S., Mou, Y., Peng, C., & Zhou, X. (2021). Quantitative assessment of the importance of bio-physical drivers of land cover change based on a random forest method. *Ecological Informatics*, 61. <https://doi.org/https://doi.org/10.1016/j.ecoinf.2020.101204>
- Ngadi Scarpetta, Y., Lebourgeois, V., Laques, A. E., dieye, M., Bourgoïn, J., & Bégué, A. (2023). BFASTm-L2, an unsupervised LULCC detection based on seasonal change detection – An application to large-scale land acquisitions in Senegal. *International Journal of Applied Earth Observation and Geoinformation*, 121. <https://doi.org/https://doi.org/10.1016/j.jag.2023.103379>
- Paradis, E. (2022). Probabilistic unsupervised classification for large-scale analysis of spectral imaging data. *International Journal of Applied Earth Observation and Geoinformation*, 107. <https://doi.org/https://doi.org/10.1016/j.jag.2022.102675>
- Prasad, P., Loveson, V. J., Chandra, P., & Kotha, M. (2022). Evaluation and comparison of the earth observing sensors in land cover/land use studies using machine learning algorithms. *Ecological Informatics*, 68. <https://doi.org/https://doi.org/10.1016/j.ecoinf.2021.101522>
- Purwanto, Latifah, S., Yonariza, Akhsani, F., Sofiana, E. I., & Riski Ferdiansah, M. (2023). Land cover change assessment using random forest and CA markov from remote sensing images in the protected forest of South Malang, Indonesia. *Remote Sensing Applications: Society and Environment*, 32. <https://doi.org/https://doi.org/10.1016/j.rsase.2023.101061>
- Rash, A., Mustafa, Y., & Hamad, R. (2023). Quantitative assessment of Land use/land cover changes in a developing region using machine learning algorithms: A case study in the Kurdistan Region, Iraq. *Heliyon*, 9(11). <https://doi.org/https://doi.org/10.1016/j.heliyon.2023.e21253>

- Ruggeri, S., Henao Cespedes, V., Garcés Gómez, Y., & Parra Uzcátegui, A. (2021). Optimized unsupervised CORINE Land Cover mapping using linear spectral mixture analysis and object-based image analysis. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 1061-1069. <https://doi.org/https://doi.org/10.1016/j.ejrs.2021.10.009>
- Sisay, G., Gitima, G., Mersha, M., & Alemu, A. (2021). Assessment of land use land cover dynamics and its drivers in Bechet Watershed Upper Blue Nile Basin, Ethiopia. *Remote Sensing Applications: Society and Environment*, 24. <https://doi.org/https://doi.org/10.1016/j.rsase.2021.100648>
- Sobhani, P., Esmailzadeh, H., & Mostafavi, H. (2021). Simulation and impact assessment of future land use and land cover changes in two protected areas in Tehran, Iran. *Sustainable Cities and Society*, 75. <https://doi.org/https://doi-org.crai-ustadigital.usantotomas.edu.co/10.1016/j.scs.2021.103296>
- Tnag, X., Woodcock, C., Olofsson, P., & Hutyrá, L. (2021). Spatiotemporal assessment of land use/land cover change and associated carbon emissions and uptake in the Mekong River Basin. *Remote Sensing of Environment*, 256. <https://doi.org/https://doi.org/10.1016/j.rse.2021.112336>
- Tola, B., & Deyassa, G. (2024). A modeling approach for evaluating and predicting the impacts of land use land cover changes on groundwater recharge in Walga Watershed, Upper Omo Basin, Central Ethiopia. *Journal of Hydrology: Regional Studies*, 51. <https://doi.org/https://doi.org/10.1016/j.ejrh.2024.101659>
- Tolessa, T., Kidane, M., & Bezie, A. (2021). Assessment of the linkages between ecosystem service provision and land use/land cover change in Fincha watershed, North-Western Ethiopia. *Heliyon*, 7(7). <https://doi.org/https://doi.org/10.1016/j.heliyon.2021.e07673>
- Traore, M., Son Lee, M., Rasul, A., & Balew, A. (2021). Assessment of land use/land cover changes and their impacts on land surface temperature in Bangui (the capital of Central African Republic). *Environmental Challenges*, 4. <https://doi.org/https://doi.org/10.1016/j.envc.2021.100114>
- Trujillo-Jiménez, M., Liberoff, A. L., Pessacg, N., Pacheco, C., & Flaherty, S. (2020). Uso de Métodos de Aprendizaje Automático y teledetección para clasificación de uso y cobertura del suelo en un valle semiárido de la Patagonia.
- Velastegui Montoya, A., Escandón-Panchana, P., Peña-Villacreses, G., & Herrera-Franco, G. (2023). Land use/land cover of petroleum activities in the framework of sustainable development. *Cleaner Engineering and Technology*(15). <https://doi.org/https://doi.org/10.1016/j.clet.2023.100659>
- Zhao, S., Tu, K., Ye, S., Tang, H., Hu, Y., & Xie, C. (2023). Land Use and Land Cover Classification Meets Deep Learning: A Review. *Sensors*, 23(21). <https://doi.org/https://doi.org/10.3390/s23218966>
- Zhao, Z., Islam, F., Waseem, L. A., Tariq, A., Nawaz, M., Islam, I. U., Hatamleh, W. (2024). Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification. *Rangeland Ecology & Management*, 92, 129-137. <https://doi.org/https://doi.org/10.1016/j.rama.2023.10.007>