

COMPARACIÓN DE INDICADORES DE SOSTENIBILIDAD ENTRE ZONAS URBANAS DE ECUADOR Y ESPAÑA EMPLEANDO IMÁGENES SENTINEL 2 MSI

COMPARISON OF SUSTAINABILITY INDICATORS BETWEEN URBAN AREAS OF ECUADOR AND SPAIN USING SENTINEL 2 MSI IMAGERY

Lorena Caiza, Gabriella Zegarra, Estefanía Navarro, Flor Álvarez*

Grupo de investigación 202 (GEOINCA). Escuela de Ingeniería Agraria y Forestal, Universidad de León. Avenida de Astorga, s/n., 24400 Ponferrada, España. lcaizm00@estudiantes.unileon.es; azegas00@estudiantes.unileon.es; enavam02@estudiantes.unileon.es; flor.alvarez@unileon.es

Abstract:

The spatio-temporal variability of vegetation in urban areas is one of the current concerns about climate variability events such as extreme temperature changes and flooding, coupled with the forecast that 70% of the world's population will live in urban areas by 2050, threatening local ecosystems as well as associated flora and fauna. Given the close relationship of environmental and demographic changes to the emergence of infectious diseases such as COVID-19 and within the Sustainable Development Goals (SDG) framework of sustainable cities and communities, this study analysed through Sentinel-2 MSI satellite imagery and neural network (RN) and Support Vector Machine (SVM) classifiers the relationship between green areas and the built-up or vegetation-free areas of two urban centers, one located in Quito (Ecuador), with a high population density, and another in León (Spain), with a lower population density, this is intended to determine the values of various sustainability indicators by 2020. The results of the analyses showed that the two cities meet who thresholds for green areas per capita (10 m²/inhabitant), exceeding 20% of green areas recommended by the Sustainable Local Development Network, increasing these values as population density decreases. The use of satellite images made it possible to make these estimates of green areas with omission errors of less than 15% (at 1:20,000 scale), facilitating the obtaining of base indicators to be taken into account for the design of future urban projects and that allow to objectively compare urban centers of different locations.

Key words: vegetation, Sentinel-2 MSI, neural network, support vector machine, sustainability indicators

Resumen:

La variabilidad espacio-temporal de la vegetación en las áreas urbanas es una de las preocupaciones actuales ante eventos de variabilidad climática tales como cambios extremos de la temperatura e inundaciones, sumado a que se prevé que el 70% de la población mundial vivirá en áreas urbanas para el año 2050, lo que amenaza los ecosistemas locales así como la flora y fauna asociada. Dada la estrecha relación de los cambios ambientales y demográficos con la aparición de enfermedades infecciosas como el COVID-19 y en el marco de los Objetivos de Desarrollo Sostenible (ODS) de ciudades y comunidades sostenibles, en este estudio se analizó mediante imágenes satelitales Sentinel-2 MSI y los clasificadores de Redes Neuronales (RN) y Support Vector Machine (SVM) la relación entre las áreas verdes y las superficies construidas o sin vegetación de dos centros urbanos, uno localizado en Quito (Ecuador), con una elevada densidad de población, y otro en León (España), con una menor densidad poblacional, esto con el propósito de determinar los valores de varios indicadores de sostenibilidad para el año 2020. Los resultados de los análisis mostraron que las dos ciudades cumplen con los umbrales establecidos por la Organización Mundial de la Salud (OMS) respecto a áreas verdes por habitante (10 m²/habitante), superando el 20% de zonas verdes recomendado por la Red de Redes de Desarrollo Local Sostenible, aumentando estos valores según disminuye la densidad de población. El empleo de imágenes de satélite permitió hacer estas estimaciones de áreas verdes con errores de omisión inferiores al 15% a escala 1:20.000, facilitando la obtención de indicadores base que han de tenerse en cuenta para el diseño de futuros proyectos urbanísticos y que permiten comparar de forma objetiva centros urbanos de diferentes localizaciones.

Palabras clave: vegetación, Sentinel-2 MSI, redes neuronales, support vector machine, indicadores de sostenibilidad

1. Introducción

Los espacios verdes son esenciales en el desarrollo urbano dado los múltiples servicios ecosistémicos que brinda tales como regulación del microclima (Lehman *et al.* 2014, citado en Kopecká *et al.* 2017), calidad del aire, permeabilidad del suelo, belleza paisajística, salud

mental y física de los habitantes, y actúa como barrera para el sonido (Dole 1989, citado en Gupta 2012). Además, una buena distribución de la vegetación en un centro urbano funciona como corredor ecológico de especies de fauna como aves y reptiles, lo que garantiza una relación sostenible de los humanos con la naturaleza

* Corresponding Author: Flor Álvarez, flor.alvarez@unileon.es

y la continuidad espacial de procesos biológicos, ecológicos o evolutivos (Restrepo and Muñoz 2019).

La variabilidad espacio-temporal de la vegetación en las áreas urbanas es una de las preocupaciones actuales ante eventos de variabilidad climática tales como olas de calor e inundaciones, sumado a que se prevé que el 70% de la población mundial vivirá en áreas urbanas para el año 2050, lo que amenaza los ecosistemas locales así como la flora y fauna asociada (Luck *et al.* 2009). Las ciudades latinoamericanas se enfrentan a altas tasas de urbanización y creación de periferias urbanas mal controladas (Barrera and Enríquez 2017), por lo que los análisis de cubierta de suelo urbano constituyen un elemento decisivo para garantizar ciudades y comunidades sostenibles de acuerdo al ODS número 11 (ONU 2015).

Para determinar tipos de cubierta de suelo mediante imágenes satelitales se debe tener en cuenta la resolución espacial, radiométrica y espectral, principalmente, con la que cuenta cada sensor. Asimismo, el método de clasificación y los parámetros asociados. Kopecká *et al.* (2017) usaron imágenes Sentinel-2A para analizar espacios verdes urbanos e indicaron que la fragmentación y heterogeneidad del paisaje, ocasiona que un área en particular tienda a sobreestimarse, es decir, si la vegetación en un centro urbano está altamente fragmentada los píxeles de esta clase se contaminarán espectralmente por los píxeles adyacentes de la clase dominante, por lo que recomiendan usar resolución espacial de 5-10 m. En cuanto al rendimiento de los clasificadores, Thanh Noy and Kappas (2017) usaron imágenes satelitales Sentinel-2 para comparar la eficiencia de tres métodos no paramétricos para clasificar cobertura de suelo, mediante lo cual encontraron que la exactitud global de los tres clasificadores fue superior a 90% cuando el tamaño de muestra fue suficientemente grande.

Dada la estrecha relación de los cambios ambientales y demográficos con la aparición de enfermedades infecciosas como el COVID19 y en el marco del ODS de ciudades y comunidades sostenibles, el objetivo principal de este trabajo fue determinar la idoneidad de las imágenes de satélite Sentinel 2 MSI para estimar varios indicadores de sostenibilidad, relacionados con la existencia de zonas verdes, en dos centros urbanos, uno de Europa (León) y otro de Latinoamérica (Quito). Además, como objetivo secundario se planteó comparar la exactitud de dos clasificadores no paramétricos en la estimación de las variables que se emplean para el cálculo de estos indicadores, para poder recomendar el uso del algoritmo más adecuado.

2. Materiales y métodos

2.1. Área de estudio

2.1.1. Quito – Ecuador

Quito es una ciudad capital latinoamericana ubicada en la cordillera de los Andes con coordenadas $0^{\circ}13'07''S$ $78^{\circ}30'35''O$ (WGS84) a una altitud promedio de 2800 msnm. Tiene un área metropolitana de 370 Km² y cuenta con dos millones de habitantes, aproximadamente. De acuerdo a Metzger (2001), los perfiles de cobertura de suelo que lo caracterizan son: 1) urbano denso con un

área construida de 78,5% en promedio, dejando poco espacio para la vegetación; 2) fuerte dinámica urbana en zona de vegetación natural con una superficie construida de 31%; 3) muy fuerte crecimiento urbano con un porcentaje de construcción del 50% y vegetación natural inferior al 20%; 4) urbano en vía de densificación con un 38,5% de área construida y vegetación muy limitada; 5) zona natural en vías de urbanización donde las construcciones son de apenas 15% y predomina la vegetación natural con un 53%; y 6) zonas de sembríos en vías de urbanización que es una zona caracterizada por espacios cultivados y un 24% de construcciones. Si bien los perfiles descritos por Metzger (2001) son de hace 20 años, estos dan una idea de la evolución del desarrollo urbano de la ciudad de Quito y la relación con las zonas verdes. El área de estudio correspondiente a la ciudad de Quito se muestra en la Figura 1.

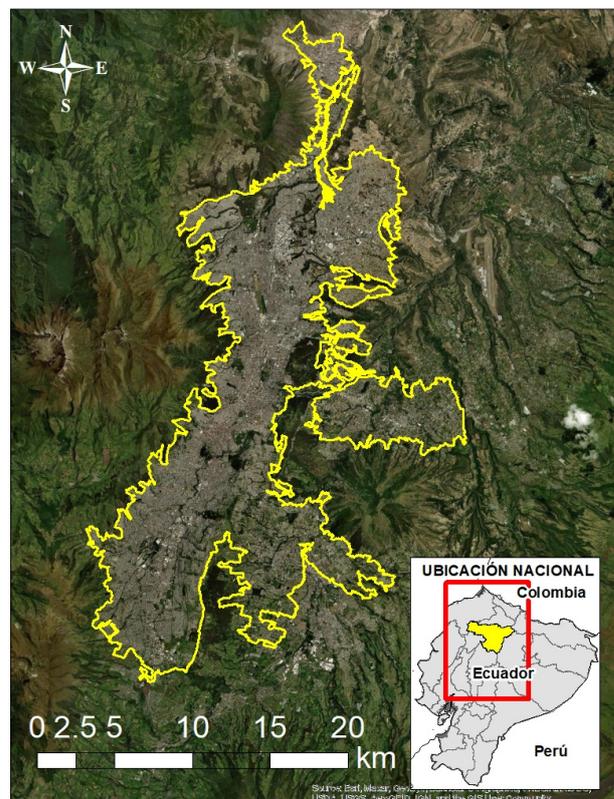


Figura 1: Ubicación del centro urbano de la ciudad de Quito – Ecuador.

2.1.2. León – España

León es una ciudad del norte de España con coordenadas $42^{\circ}36'20''N$ $5^{\circ}34'12''W$ (ETRS89) localizada a una altitud promedio de 837 msnm. Tiene un área urbana de aproximadamente 39 Km² y cuenta con una población de 124000 habitantes según el sitio web del Ayuntamiento de León (2021). De acuerdo con ortofotos y vistas satelitales de la ciudad, León está conformado por una zona urbana densa y baja vegetación en el centro-este, en tanto que en el centro-oeste la urbanización ocupa menor área y se mezcla con suelo descubierto y pastizales, lo que se puede categorizar como área de expansión. En el norte hay menor densidad urbana y mayor vegetación mezclada con pastizales. Finalmente, en el sur predominan las praderas y cultivos con muy poca urbanización.

La Figura 2 muestra el área de estudio del centro urbano de la ciudad de León, a partir del cual se determinaron las clases de cubierta agua, superficie impermeable y vegetación mediante el uso de imágenes de teledetección e índices de vegetación.

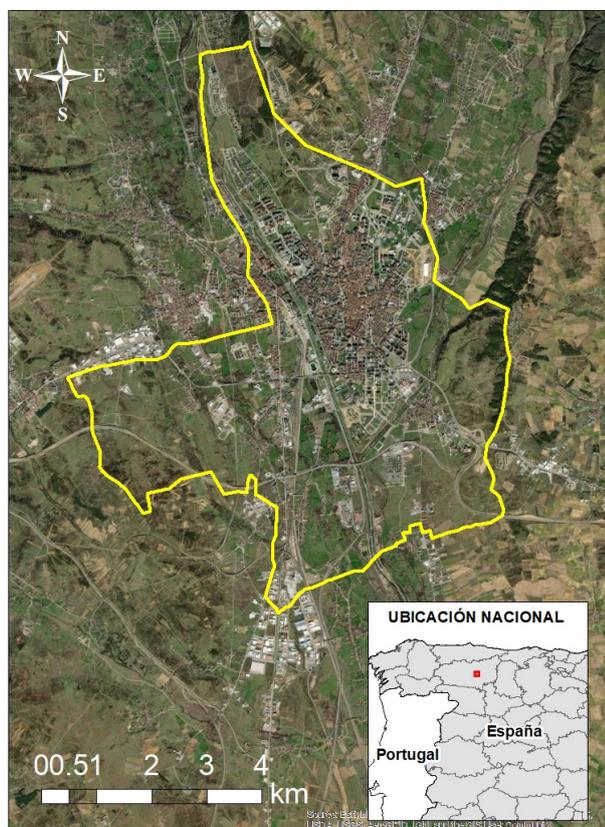


Figura 2: Ubicación del centros urbano de León – España.

2.2. Imágenes Sentinel-2

Posterior a un análisis visual sobre ortofotografías de ambas ciudades se determinó que el área mínima nominal cartografiada (AMC) en las zonas de estudio corresponde a 0,5 hectáreas, es decir, se identificaron zonas verdes pequeñas y fragmentadas con aproximadamente esa superficie, principalmente en parques. En este sentido, la escala nominal utilizada para este trabajo es de 1:25.000 donde la resolución espacial mínima del sensor a utilizar debe ser de 10 metros (Tobler 1987). Las bandas a usar del sensor MultiSpectral Instrument (MSI) del satélite Sentinel 2 cumplen con este requisito, por lo que fueron elegidas para estimar los indicadores de sostenibilidad y para comparar la exactitud de los dos clasificadores paramétricos.

Se trabajó con imágenes Sentinel Nivel 2A corregidas atmosféricamente a nivel del suelo (*Bottom of the Atmosphere* BOA, por su sigla en inglés), con cobertura nubosa máxima de 25%, resolución temporal de 5 días y resolución espacial de 10 m para las bandas empleadas (azul, verde, rojo e infrarrojo cercano). Para el caso de Quito se seleccionó una imagen con fecha del 24 de agosto de 2020, época de mayor vigorosidad vegetal para Ecuador. Y para el caso del Municipio León se utilizó una imagen del 5 de junio del 2020, que corresponde a la estación de primavera donde la vegetación es más vigorosa, para así tener resultados comparables con los

obtenidos para Quito. Se descargaron los datos de la página web de Sentinel HUB (<https://www.sentinel-hub.com/>) en formato .jp2, de 32 bits. Las características de las imágenes se resumen en la Tabla 1.

Tabla 1: Características de las imágenes de Quito y León.

	Quito	León
Fecha	24/07/2020	05/06/2020
Bandas	B2, B3, B4, B8	B2, B3, B4, B8
Res. Temporal	5 días	5 días
SRC	WGS 84 UTM H 17S	WGS 84 UTM H 29N
TILE	T17MQV, T17NQV	T29TQH

2.3. Recursos adicionales

Para este estudio se consideró la zona urbana de Quito y se utilizó la capa vectorial disponible en el geoportal DMQUITO, con sistema de coordenadas WGS 84 UTM Huso 17. En tanto que para el Municipio de León se consideró el límite administrativo disponible en la base de datos del CNIG Sistema de Coordenadas ETRS89 UTM Huso 30, ambos en formato vectorial. Adicionalmente se utilizaron ortofotografías provenientes de los servicios WMS de ambos países. Las fuentes de información están contenidas en la Tabla 2.

Tabla 2: Fuente de datos.

	Capa vectorial	Ortofoto
Quito	http://gobiernoabierto.quito.gob.ec/?pague_id=1114	http://www.geoportaligm.gob.ec/portal/index.php/descarga-de-servicios-wms-del-igm/
León	https://centrodedescargas.cnig.es/CentroDescargas/index.jsp	http://orto.wms.itacyl.es/Server/SgdWms.dll/WMS

2.4. Metodología

En la Figura 3 se representa el procedimiento para determinar la relación entre áreas de vegetación y superficie impermeable de los centros urbanos de Quito y León. La figura detalla las fuentes de procedencia de los datos junto con la escala, las bandas utilizadas, los clasificadores empleados, y la procedencia de los datos para los procesos de entrenamiento y validación, así como el orden en que se ejecutan.

En este apartado de metodología se explica el preprocesamiento, definición de espacios de entidades y los métodos de clasificación y validación.

2.4.1. Definición del espacio de entidades

En primer lugar, se definieron las tres clases principales a identificar de forma semi automática en la imagen:

- Vegetación (V): Parques, plazas con vegetación, zonas arboladas dentro de las zonas de estudio
- Superficies Impermeables (SI): edificaciones, suelo descubierto, rocas.
- Agua(A): Fuentes hídricas, ríos, embalses y lagunas

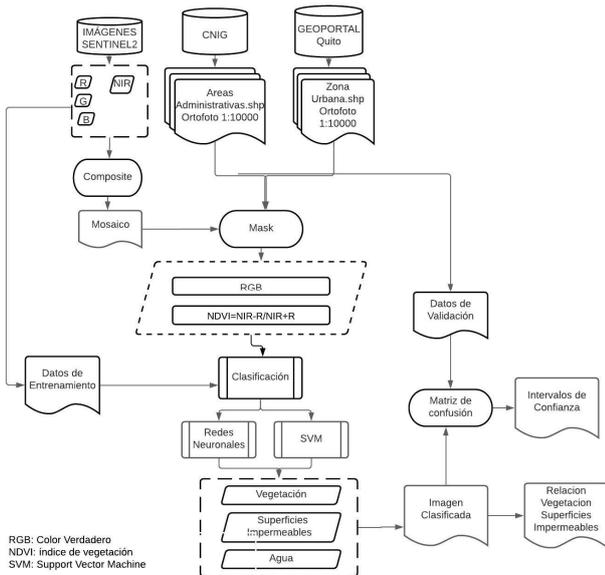


Figura 3: Flujo de trabajo de la clasificación y validación de la cobertura de suelo de Quito y León.

En segundo lugar, y para determinar la combinación de información espectral más adecuada para diferenciar esas clases (i.e. definición del espacio de entidades), A se calculó el Índice de Vegetación de Diferencia Normalizada (NDVI), el cual resalta el verdor de la vegetación y es útil para determinar la densidad de la vegetación y evaluar los cambios en la salud de las plantas. El NDVI se calcula como una relación entre los valores de reflectancia de rojo (R) e infrarrojo cercano (NIR) de manera tradicional (USGS 2021) de acuerdo con la Ec. (1).

$$NDVI = \frac{NIR-rojo}{NIR+rojo} \quad (1)$$

A partir de la interpretación visual de las imágenes Sentinel-2 con distintas combinaciones de bandas y las ortofotos se elaboraron las muestras de entrenamiento. Se empleó la combinación en Falso color (B8, B4, B3) y el índice NDVI para identificar la vegetación. En el caso de las zonas de superficies impermeables y agua se utilizó la combinación en color verdadero (B4, B3, B2), utilizando como referencia las ortofotos de Quito y León. La Tabla 3 muestra el número de píxeles de las áreas de entrenamiento usadas para la clasificación de cobertura de suelo de Quito y León.

Tabla 3: Número de píxeles usados para la clasificación de cada cobertura.

Clase	Quito (Polígonos/Pix.)	León (Polígonos/Pix.)
V	37/150	78/174
SI	31/147	15/25
A	7/21	75/322

Para saber qué tan adecuado es el espacio de entidades, se calculó la separabilidad Jeffries-Matusita de las clases A, SI y V utilizando el espacio de entidades B2 (azul), B3 (verde), B4 (rojo), B8 (NIR) y NDVI.

2.4.2. Clasificación

2.4.2.1. Redes Neuronales Artificiales (RNA)

Redes Neuronales Artificiales es un método de clasificación supervisado no paramétrico que está diseñado para emular la función de reconocimiento de patrones humanos a través del procesamiento paralelo de múltiples entradas, es decir, las RN tienen la capacidad de identificar datos en busca de patrones y se pueden usar para construir modelos no lineales (Debojit *et al.* 2011).

Los parámetros utilizados fueron los siguientes: Training Threshold Contribution 0.9, Training Rate 0.2, TM-Training Momentum 0.9, RMS Root Means Square 0, Number of Iteration 1000. El número de capas se limitó a 1 (Ndehedehe *et al.* 2013).

2.4.2.2. Support Vector Machine (SVM)

Support Vector Machine es un método de clasificación supervisado no paramétrico que a partir del producto escalar de los vectores multidimensionales de las muestras construye un hiperplano o conjunto de hiperplanos y un espacio de dimensionalidad muy alta que separa los grupos. Para la modelización de las SVM se requiere una fase inicial de entrenamiento y aprendizaje. Una vez conformada la modelización el sistema está listo para recibir nuevas entradas y buscar la correspondencia entre el modelo y las entradas para clasificarlas (Gil *et al.* 2019).

La clasificación de la imagen se realizó utilizando los parámetros predeterminados de base radial Kernel utilizado por Chukwukalo and Izuchukwu (2019) en su estudio sobre mapeo de características urbanas usando imágenes de satélite de alta resolución.

2.4.3. Validación

2.4.3.1. Diseño de muestreo

Se calculó el tamaño de la muestra para los puntos de validación estadística a partir de la Ec. (2) (Martínez *et al.* 2004).

$$N = \frac{Z^2 * P * Q}{E^2} = \frac{2^2 * 0,85 * 0,15}{0,08^2} = 80 \quad (2)$$

Donde:

Z = nivel de confianza

P = exactitud esperada para cada clase

Q = 1-P

E = error admisible en la clasificación

Para una exactitud esperada de 0,85 y error de 0,08, se determinó que el número de puntos/píxeles deber ser de 80 para cada clase. La exactitud esperada de 0,85 para cada clase se basa en valores probables indicados por Congalton and Green (1999). Como error admisible en la clasificación se fijó el 8% en la clasificación, para no aumentar más el tamaño de muestra y por considerarlo asumible.

2.4.3.2. Generación de puntos aleatorios

Para obtener una estimación insesgada se realizó un muestreo aleatorio con la herramienta *Create Random points* del software ArcGIS y se caracterizaron como cobertura de vegetación y superficie impermeable, utilizando como base las ortofotos de Quito y de León. La Figura 4 muestra la distribución de los puntos de validación de Quito, y la Figura 5 la distribución de los puntos de León.

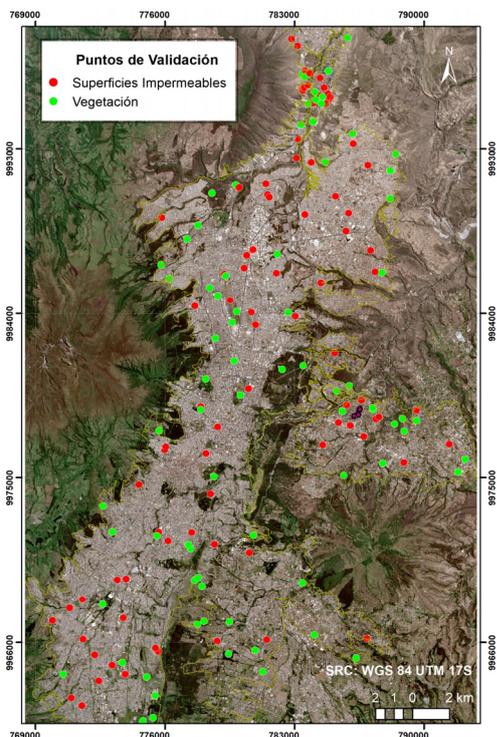


Figura 4: Mapa de distribución de los puntos de validación para la ciudad de Quito.

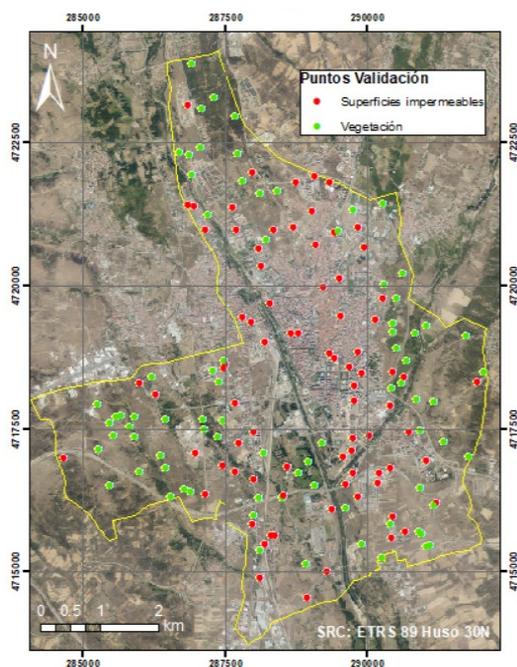


Figura 5: Mapa de distribución de los puntos de validación para la ciudad de León.

2.4.3.3. Cálculo de estadísticos de validación

Para el cálculo de estadísticos de validación se generó la matriz de confusión, utilizada para proporcionar una descripción básica de la precisión del mapa temático y para la comparación de precisiones, de la cual se obtiene la fiabilidad global que es el número de casos asignados correctamente versus el número de casos de referencia, y esto se puede dar de dos puntos de vista del usuario y del productor de acuerdo a Foody (2001):

- Exactitud del usuario: son casos acertados a la clase a la que pertenece y se complementa con el error de comisión que es asignar un caso a una clase a la que no pertenece.
- Exactitud del productor son los casos correctamente identificados en la referencia y es lo contrario del error de omisión que se comete cuando se excluye a un pixel de la clase correcta.

A partir de esta matriz se calcularon los intervalos de confianza al 95% utilizando el método de Wald Ajustado (Sauro and Lewis 2005) respaldándose en la calculadora en línea MeasuringU (<https://measuringu.com/ci-calc/>). Para elegir el método que mejor represente la realidad, se consideró la fiabilidad global y el error de omisión de la clase vegetación, ya que esto afectará directamente al cálculo del porcentaje de vegetación de las ciudades.

2.5. Cálculo de los indicadores de sostenibilidad

Se calcularon como indicadores de sostenibilidad: (i) la relación de la superficie de cubierta vegetal respecto a a las zonas impermeables, (ii) los m² de zonas verdes por habitante y (iii) porcentaje de vegetación respecto a la superficie total.

Para el cálculo de la relación de la superficie de cubierta vegetal respecto a a las zonas impermeables se empleará la Ec. (3):

$$RVS = \frac{SV}{SI} \quad (3)$$

Donde:

RVS = relación de vegetación respecto a las superficies impermeables

SV = superficie de vegetación en la zona de estudio

SI = superficie de zonas impermeables en la zona de estudio

Para el cálculo de zonas verdes en m² por habitante se empleó la Ec. (4):

$$SVhab = \frac{SV}{N^{\circ} hab} * \frac{m^2}{hab} \quad (4)$$

Donde:

SVhab = superficie de vegetación m² por habitante

SV = superficie de vegetación en la zona de estudio

N° hab = número de habitantes

Finalmente, el porcentaje de vegetación se obtiene aplicando la Ec. (5):

$$\%ZV = \frac{SV}{ST} \quad (5)$$

Donde:

$\%ZV$ = porcentaje de zonas de vegetación en la zona de estudio

SV = superficie de vegetación en la zona de estudio

ST = superficie total de la zona de estudio

3. Resultados

3.1. Separabilidad teórica de las cubiertas

En la Tabla 4 se observa que el valor de separabilidad es aproximadamente 2,0 en todos los casos, lo que indica que el espacio de entidades elegido es adecuado.

Tabla 4: Resultado del análisis de separabilidad Jeffries-Matusita.

Clase	Quito	León
A-SI	1,99997853	1,99866325
SI-V	1,99999801	2,00000000
A-V	1,99999984	1,99998865

3.2. Clasificación mediante RN y SVM de Quito

La Figura 6 muestra los resultados de la imagen clasificada mediante los métodos RN y SVM. La Figura 7 muestra una vista de detalle donde se observan las tres coberturas clasificadas por ambos métodos y la vista a falso color. La Figura 7a muestra que el método RN obtuvo mejores resultados, en la Figura 7c se observa que el método SVM presentó problemas para clasificar píxeles de la clase agua. En cuanto a las clases superficie impermeable y vegetación, visualmente RN es más eficiente que SVM.

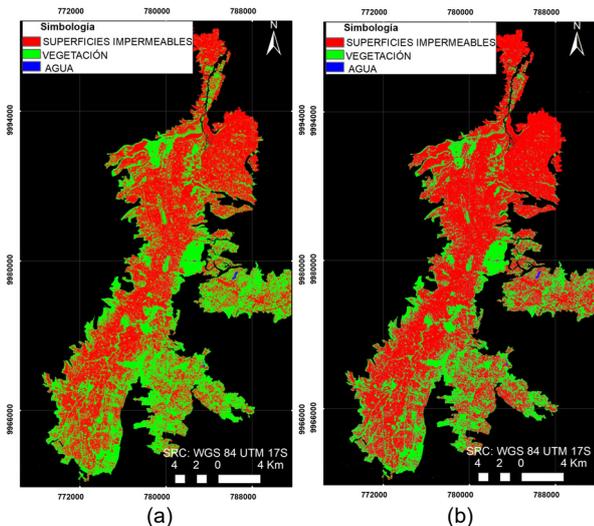


Figura 6: Resultados de la clasificación para la ciudad de Quito. Métodos utilizados: a) RN; b) SVM.

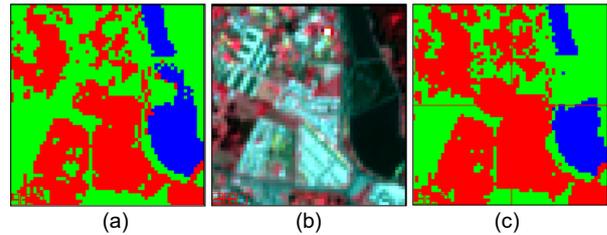


Figura 7: Resultados de la clasificación para la ciudad de Quito. Vista de detalle: a) RN; b) Falso color; c) SVM.

3.3. Clasificación mediante RN y SVM de León

La Figura 8 muestra los resultados de la clasificación por RN y SVM. La Figura 9 muestra un enfoque más detallado donde se diferencian las tres clases definidas y la misma vista en falso color. La Figura 9a muestra que el método RN identifica mejor los píxeles de la clase agua que el método SVM (Fig. 9c), dado que es capaz de diferenciar mejor los píxeles de agua cercanos a los de vegetación, lo que no ocurre con SVM, el cual clasifica estos como suelo impermeable. En cuanto a las clases vegetación y suelo impermeable, visualmente RN muestra más eficiencia para determinar los límites entre ambas clases y clasifica mejores píxeles borde.

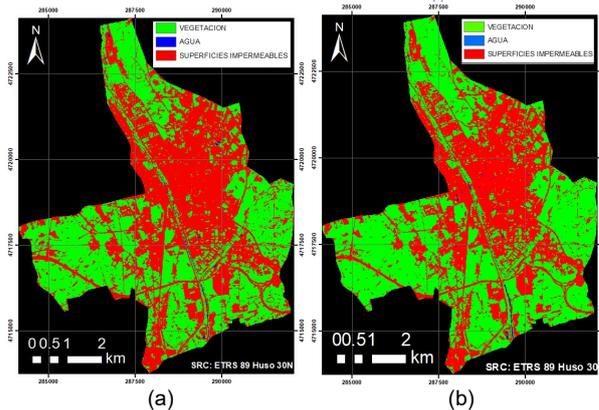


Figura 8: Resultados de la clasificación para la ciudad de León. Métodos utilizados: a) RN; b) SVM.

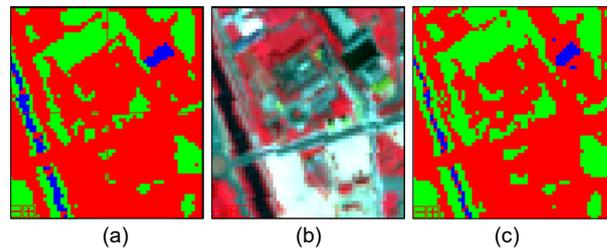


Figura 9: Resultados de la clasificación para la ciudad de León. Vista de detalle: a) RN; b) Falso color; c) SVM.

3.4. Validación de la clasificación de de Quito

La Tabla 5 muestra los resultados de los errores de omisión y comisión de los dos métodos de clasificación considerados. Para la clase vegetación el error de omisión es inferior al 14% con un intervalo de confianza entre 6,2-21,3 empleando RN y el error de comisión inferior al 6% con intervalo de confianza de 0,26-10,70,

Esto indica que más del 85% de los píxeles con vegetación se han identificado correctamente. Con SVM el error de omisión de esta clase está próximo al 43% (31,67-53,33), lo que quiere decir que el 57% de los píxeles clasificados han sido clasificados correctamente. Para la clase SI, el error de comisión es del 5% (0,22-9,78) y el de omisión es del 11,63 (4,85-18,40) en la clasificación de RN, lo que significa que el 88% de los píxeles pertenecientes a esta clase han sido clasificados correctamente. Con SVM el error de omisión es del 0% lo que indica su fortaleza al clasificar esta superficie pero el error de comisión es 29,82 (21,43-38,22), es decir, que el 30% de los píxeles de SI no han sido clasificados correctamente, esto se debe a que en las zonas con suelo desnudo y zonas próximas a vegetación SVM generaliza la superficie o extiende su límite adicionando píxeles a esta clase. (Ver Figuras 8 y 9). La Tabla 5 muestra que la fiabilidad global para la clasificación con RN es de 90% (86,11-95,14), lo que indica que el 90% de píxeles están bien clasificados mientras que para SVM es de 78,75 (71,74-84,41), es decir que el 79% de los píxeles están bien clasificados.

Tabla 5: Estadísticos de validación de la clasificación de Quito. Valores más probables e intervalos de confianza al 95% de probabilidad

Clases		Clasificación RN	Clasificación SVM
Exactitud global (%)		90,63 (86,11-95,14)	78,75 (71,74-84,41)
Error de Omisión (%)	V	13,75 (6,20-21,30)	42,50 (31,67-53,33)
	SI	5,00 (0,22-9,78)	0,00 (0,00-0,00)
Error de comisión (%)	V	5,48 (0,26-10,70)	0,00 (0,00-0,00)
	SI	11,63 (4,85-18,40)	29,82 (21,43-38,22)

La validación a partir de las imágenes complementaron la información obtenida con los intervalos de confianza, la clasificación con RN (Fig. 10b) es más fiable para la clase vegetación mientras la clasificación por SVM tiene un mayor error de comisión para la clase SI (Fig. 10c). Las zonas de conflicto son zonas con suelo desnudo, como se puede observar en la Figura 10d.

3.5. Validación de la clasificación de León

En la Tabla 6 se muestran los resultados de los errores de comisión y omisión de los métodos de clasificación RN y SVM para la ciudad de León. El error de omisión de la clase vegetación es inferior al 13% (6,74-21,69) empleando SVM y el error de comisión inferior al 11% (5,05-19,19). Esto quiere decir que más del 87% de los píxeles con vegetación se han identificado correctamente (Exactitud del productor). Por otro lado, el error de comisión de la vegetación, empleando RN, es inferior al 2% (0,00-8,52) pero el error de omisión es de un 15% (8,64-24,57), mediante lo cual se demuestra que más del 85% de los píxeles de vegetación hayan sido clasificados correctamente.

Para la clase de SI, el error de omisión con el método SVM es inferior al 11% (5,05-19,19) y el error de comisión es inferior al 13% (6,74-21,69). Esto quiere decir que más del 89% de los píxeles de SI fueron clasificados correctamente. Con el método de RN, el error de omisión para superficies impermeables es inferior al 2% (0,00-

7,41) y el error de comisión inferior al 14% (7,56-21,80) lo que indica que con este método más del 98% de píxeles fueron asignados a la clase correcta.

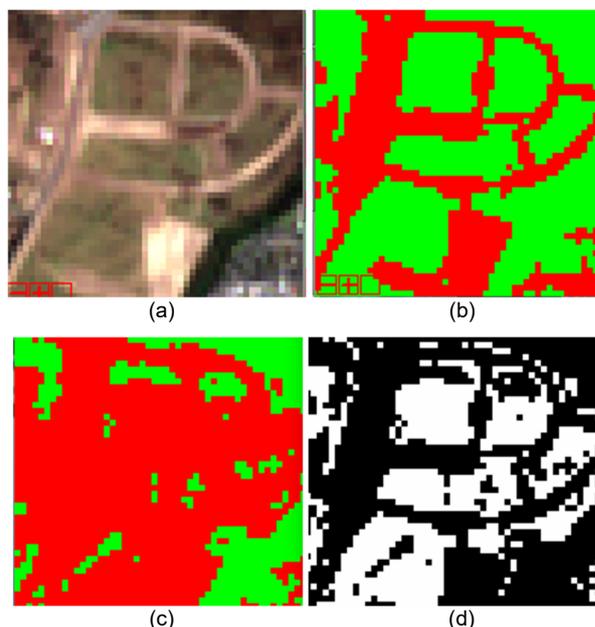


Figura 10: Validación visual de los métodos RN y SVM – Quito: a) Falso color; b) Resultado de clasificación con RN; c) Resultado de la clasificación con SVM; d) Diferencia entre RN vs SVM.

Tabla 6: Estadísticos de validación de la clasificación de León. Valores más probables e intervalos de confianza al 95% de probabilidad.

Clases		Clasificación RN	Clasificación SVM
Exactitud global (%)		91,87 (86,49-95,30)	88,61 (82,63-92,75)
Error de Omisión (%)	V	15,00 (8,64-24,57)	12,50 (6,74-21,69)
	SI	1,25 (0,00-7,41)	10,26 (5,05-19,19)
Error de comisión (%)	V	1,45 (0,00-8,52)	10,26 (5,05-19,19)
	SI	13,19 (7,56-21,80)	12,50 (6,74-21,69)

Analizando los estadísticos, no se puede llegar a una conclusión definitiva respecto al mejor método de clasificación debido a que los porcentajes de los errores de omisión y comisión de la clase vegetación son similares entre ambos métodos e invertidos para la clase de superficies impermeables. Por consiguiente, se complementa la evaluación con un análisis visual de ambas imágenes clasificadas.

3.6. Indicadores de sostenibilidad

Después de realizar los análisis estadísticos y visuales de ambos métodos de clasificación, se concluye que Redes Neuronales refleja de manera más fiable la realidad del terreno en las clases vegetación y superficies impermeables en ambas zonas de estudio, por lo que se calcularon las áreas con los resultados obtenidos por este método (ver Tabla 7).

Mediante un análisis visual se determinó que para Quito y León se excluyen zonas verdes de interés como lo son jardines, huertos urbanos y áreas menores a 0,05 ha. Lo

que afecta el resultado final. Sin embargo, el AMC real fue mayor a la media hectárea nominal inicial, esto debido a que la diferencia espectral entre ambas clases de estudio es grande.

Tabla 7: Indicadores de sostenibilidad calculados para Quito y León según la clasificación obtenida.

Indicador	Quito	León
Superficies de zonas impermeables (ha)	21220	1710
Superficie de vegetación (ha)	15530	2180
RVhab (m ² /habitante)	77,22	174,71
RVS	0,73	1,27
%ZV (%)	42,26	55,47

Los resultados de los indicadores mostraron que tanto Quito como León cumplen con los umbrales establecidos por la OMS respecto a áreas verdes por habitante (10 m²/habitante), con valores de 77 m²/hab tomando como base los 2 millones de habitantes que tiene el centro urbano de Quito, y 174 m²/hab considerando los 124000 habitantes de León. Además, ambas ciudades superan el 20% de zonas verdes recomendado por la Red de Redes de Desarrollo Local Sostenible, con un valor de 42,26 para Quito y 55,47 para León.

Un factor por considerar en el presente estudio es la diferencia morfológica de ambas ciudades ya que esta puede afectar a los resultados. En los datos derivados de la teledetección, las clases dominantes tienden a sobreestimarse, por consiguiente, ciudades con áreas verdes más fragmentados pueden subestimarse. (Kopecká *et al.* 2017). En este sentido, el centro urbano de Quito es más fraccionado que el de León pudiendo así tener más áreas verdes que lo estimado. Un análisis más detallado de la conformación de las áreas verdes junto con otras variables como datos demográficos zonales en cada ciudad permitiría a los planificadores urbanos una

mejor toma de decisiones con enfoque eficiente y sostenible.

Este trabajo, junto con otros desarrollados previamente con las imágenes del sensor del Sentinel-2A MSI (Zhou 2019; Kopecká *et al.* 2017), demuestran la capacidad de discriminar vegetación dentro de un contexto urbano complejo (Zhou 2019) y así poder desarrollar diferentes índices de base para futuras investigaciones.

4. Conclusiones

Los análisis realizados indican que las dos ciudades cumplen con los umbrales establecidos por la OMS respecto a áreas verdes por habitante, sin embargo el valor puede decaer para las próximas décadas si se cumple el hecho de que para el año 2050 el 70% de la población vivirá en áreas urbanas. Para mitigar el impacto de la densidad poblacional y mantener los umbrales es necesario que los planes de ordenamiento de ambos centros poblacionales implementen la reforestación y recuperación de zonas verdes.

El empleo de imágenes de satélite permitió hacer las estimaciones de áreas verdes con errores de omisión inferiores al 15% (a escala 1:20.000), facilitando la obtención de indicadores base que han de tenerse en cuenta para el diseño de futuros proyectos urbanísticos y que permiten comparar de forma objetiva centros urbanos de diferentes localizaciones. Respecto a los métodos de clasificación empleados, la validación mostró que el método RN fue más exacto globalmente en la clasificación de las cubiertas de superficie impermeable y vegetación. Además, de acuerdo con los resultados visuales de la clasificación, el método RN fue más eficiente para clasificar las zonas con píxeles borde. El suelo desnudo clasificado como superficie impermeable es un factor de sesgo de los resultados, por lo que en estudios posteriores se debe categorizar suelo desnudo como una de las clases.

References

- AYUNTAMIENTO DE LEÓN, 2021. Información General. Available: <http://www.aytoleon.es/es/ayuntamiento/areasmunicipales/turismo/Paginas/imaci%C3%B3ngeneral.aspx> [5/7, 2021].
- BARRERA, F. and ENRÍQUEZ, C., 2017. Vegetation cover change in growing urban agglomerations in Chile. *Ecological Indicators*, **81**, pp: 265-273. DOI: 10.1016/j.ecolind.2017.05.067
- CHUKWUKALO, I. and IZUCHUKWU, J., 2019. Mapping of Urban Features of Nnewi Metropolis Using High Resolution Satellite Image and Support Vector Machine Classifier. *Journal of Environment and Earth Science*, **6**(9), pp. 117-130. DOI: 10.7176/JEES/9-6-11
- CONGALTON, R.G. and GREEN, K., 1999. Assessing the Accuracy of Remotely Sensed Data Principles and Practices. Lewis Publishers, Boca Raton.
- DEBOJIT, B., HITESH, J., ARORA, M., and BALASUBRAMANIAN, R., 2011. Study and Implementation of a Non-Linear Support Vector Machine Classifier. *International Journal of Earth Sciences and Engineering*, **04**(64), pp. 338-341.
- DOLE, J., 1989. Greenscape 5: Green Citys. *Architects Journal*, **10**, pp: 61-69
- FOODY, G., 2001. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, **80**(1), pp.185-201. DOI: 10.1016/S0034-4257(01)00295-4
- GIL, I., DÍAZ, P. and RODRÍGUEZ, J., 2019. Técnicas y usos en la clasificación automática de imágenes. *14° Congreso Isco España*. Barcelona, España, pp. 1-14.
- GUPTA, K., KUMAR, P., PATHAN, S.K. and SHARMA K.P., 2012. Urban Neighborhood Green Index – A measure of green spaces in urban areas. *Landscape and Urban Planning*, **105**(2012), pp: 325-335. DOI: 10.1016/j.landurbplan.2012.01.003

- KOPECKÁ, M., SZATMÁRI, D. and ROSINA, K., 2017. Analysis of Urban Green Spaces Based on Sentinel-2A: Case Studies from Slovakia. *Land*, **6**(25), pp: 1-17. DOI: 10.3390/land6020025
- LEHMAN, I., MATHEY, J., RÖBLER, S., BRÄUER, A. and GOLDBERG, V., 2014. Urban vegetation structure types as a methodological approach for identifying ecosystem services-Application to the analysis of micro-climatic effects. *Ecological Indicators*, **42**, pp: 58-72. DOI: 10.1016/j.ecolind.2014.02.036
- LUCK, G., SMALLBONE, L. and O'BRIEN, R. 2009. Socio-Economics and Vegetation Change in Urban Ecosystems: Patterns in Space and Time. *Ecosystems*, **12**(4), pp: 604-620. DOI: 10.1007/s10021-009-9244-6
- MARTÍNEZ, A., MUÑOZ, J., and PASCUAL, A. (2004). Tamaño de muestra y Precisión estadística. *Ciencia y tecnología*, **23**, pp. 23.
- METZGER, P. 2001. Perfiles ambientales de Quito. Quito, Ecuador: AH.
- NDEHEDEHE, C., EKPA, A., SIRAEON, O. and NSE, O., 2013. Understanding the Neural Network Technique for Classification of Remote Sensing Data Sets. *New York Science Journal*, **6**(8), pp. 26-33.
- ONU, 2015. Objetivos de Desarrollo Sostenible. Available: <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/> [5/7, 2021].
- RESTREPO, Z. and MUÑOZ A., 2019. Conservación de la biodiversidad. Documento de trabajo, 14, pp. 1-56.
- SAURO, J., and LEWIS, J., 2005. Estimating Completion Rates from Small Samples using Binomial Confidence Intervals: Comparisons and Recommendations. *Oracle Denver*, **40**(24), pp. 2100-2103. DOI: 10.1177/154193120504902407
- THANH NOI, P. and KAPPAS, M., 2018. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, **18**(1), pp: 1-18. DOI: 10.3390/s18010018
- TOBLER, W., 1987. Measuring Spatial Resolution. *Land Resources Information Systems Conference*, Beijing, China, pp. 12-16.
- USGS, 2021. Landsat Normalized Difference Vegetation Index. Available: https://www.usgs.gov/core-science-systems/nli/landsat/landsat-normalized-difference-vegetation-index?qt-science_support_page_related_con=0#qt-science_support_page_related_con [5/7, 2021].
- ZHOU, X., LI, L., CHEN, L., LIU, Y., CUI, Y., ZHANG, Y., and ZHANG, T., 2019. Discriminating Urban Forest Types from Sentinel-2A Image Data through Linear Spectral Mixture Analysis: A Case Study of Xuzhou, East China. *Forests*, [online] **10**(6), p.478. DOI: 10.3390/f10060478