



Análisis de máquinas de clasificación de imágenes utilizadas para la elaboración de cartografías en entornos urbanos y rurales

Javier Ricardo Trujillo Parra

Monografía presentada para optar al título de Especialista en Medio Ambiente y Geoinformática

Asesor

Juan José García Duque, Especialista (Esp) Medio Ambiente y Geoinformática

Universidad de Antioquia

Facultad de Ingeniería

Especialización en Medio Ambiente y Geoinformática

Medellín, Antioquia, Colombia

2022

Cita

(Javier Trujillo, P. 2022)

Referencia

Estilo APA 7 (2020)

Javier Trujillo, P. (2022). *Análisis de máquinas de clasificación de imágenes utilizadas para la elaboración de cartografías en entornos urbanos y rurales* [Trabajo de grado especialización]. Universidad de Antioquia, Medellín, Colombia.



Especialización en Medio Ambiente y Geoinformática, Cohorte XVIII.



Centro de Documentación Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes

Decano/director: Jesús Francisco Vargas Bonilla

Jefe departamento: Diana Catalina Rodríguez Loiza

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Con gratitud a las personas que desinteresadamente acompañaron este proceso desde los diferentes puntos de vista.

Agradecimientos

A cualquier persona que se haya cruzado en el camino durante el tiempo que se pensó, programó y elaboró esta investigación.

Tabla de contenido

Resumen	8
Abstract	9
Introducción	10
Objetivo General	12
Objetivos específicos	12
Marco teórico y antecedentes	13
1. Desarrollo histórico contemporáneo de las ciudades	14
1.1 Información disponible en los territorios	15
1.1.1 información no espacial	15
1.1.2 información espacial	16
<i>1.1.2.1 imágenes satelitales</i>	16
1.1.3 Preprocesamiento de imágenes	17
1.2 Insumos base de clasificación (imágenes ráster preprocesadas)	17
1.3 Procesamiento digital de imágenes	18
2. Procesamiento digital de imágenes	19
2.1 Máquinas de clasificación	19
Clasificación supervisada	19
Clasificación no supervisada	19
2.1.1 Clasificación por clusterización (CC)	20
2.1.2 Redes neuronal convoluciones (CNN)	21
3 Toma de puntos de control	22
4 Evaluación de clasificación	22
5 Conclusiones	22
Metodología	23

Análisis y resultados	25
Input	25
Sensores remotos	27
Clasificación por clusterización (CC)	28
Generalidades	28
Algoritmo	29
Output	30
Conclusiones	30
Clasificación por redes neuronales (NN)	34
Generalidades	34
Algoritmo	35
Output	36
Conclusiones	37
Conclusiones	42
Referencias	43

Lista de figuras

Figura 1 Estructura de marco teórico de la investigación	13
Figura 2 Estructura de clasificación básica de un sistema de clusterización no supervisada	20
Figura 3 Estructura de una red básica de una red neural de capas ocultas	21
Figura 4 Estructura del flujo de búsqueda de la información	24
Figura 5 esquema de un ráster multiespectrales e hiperespectrales	26
Figura 6 Imagen de la izquierda con resolución espacial media (HR) superior a 1 metro, imagen de la derecha con resolución espacial alta (VHR) inferior a 1 metro	27
Figura 7 Relación del tipo de ráster de entrada con la totalidad de los inputs usados en las investigaciones	31
Figura 8 Gráfico de dispersión, en el eje Y se aprecia del porcentaje (%) de precisión de la MCI en la clasificación objeto de estudio; en el eje X corresponder a cada una de las MCI que se dataron en la investigación	32
Figura 9 Relación del tipo de uso recomendado según las investigaciones seleccionadas de salida con la totalidad de los outputs usados en las investigaciones	33
Figura 10 Estructura de clasificación de una RN con etapa de preprocesamiento	35
Figura 11 Detalle de input de un archivo ráster a una red neuronal	36
Figura 12 Imagen de la izquierda, ráster con salida única con diferentes etiquetas; imagen de la derecha, ráster con clasificación de objetos	37
Figura 13 Relación del tipo de ráster de entrada con la totalidad de los inputs usados en las investigaciones	38
Figura 14 Gráfico de dispersión, en el eje Y se aprecia del porcentaje (%) de precisión de la MCI en la clasificación objeto de estudio; en el eje X corresponder a cada una de las MCI que se dataron en la investigación	39
Figura 15 Relación del tipo de ráster de salida con la totalidad de los outputs usados en las investigaciones recopiladas	40

Siglas, acrónimos y abreviaturas

SIG	Sistemas de información geográficos
MCI	Máquinas de clasificación de imágenes
SR	Sensores Remotos
CC	Clasificación clusterizada
CNN	Convolutional neural network (redes neuronales convolucionales)
VHR	Resolución alta (very high resolution)
HR	Resolución media (High resolution)
MSV	Máquinas de soporte vectorial
RN	Redes neuronales

Resumen

Los sistemas de información geográfica (SIG) y las máquinas de clasificación de imágenes (MCI) se han convertido en herramientas fundamentales y relevantes a lo largo de los últimos años. El desarrollo computacional y metodológico ha permitido a las MCI posicionarse como una herramienta práctica para analizar información espacial, accediendo a ser utilizadas de manera amplia en diferentes campos del conocimiento. La planeación urbana y el desarrollo territorial se han visto beneficiadas de los MCI que se aplican a los SIG, dado que estas herramientas facilitan el análisis consistente de los diferentes entornos que pueden presentarse dentro zonas urbanas, semiurbanas y rurales, esto con marcada precisión. Esta monografía buscará mostrar los aspectos más esenciales de las diferentes MCI para reconocimiento de entornos urbanos, semiurbanos y rurales que son usados en la actualidad, dando un mayor énfasis a los programas que analizan las zonas urbanas, dado que estas representan el mayor porcentaje de los entornos habitados por humanos. Dentro del análisis multidimensional de las diferentes MCI, se presentará una relación del tipo de inputs que aceptan, la metodología de las MCI y algunos de sus parámetros, los outputs que generan y los sensores remotos que permiten generar las entradas para estas MCI analizadas, permitiendo comprender de una manera más clara cuál metodología puede ser usada o no dentro de un contexto y entorno urbano específico.

Palabras clave: sistemas de información geográfica, sensores remotos, redes neuronales C45, clusterización C38, clasificación de imágenes

Abstract

Geographic Information Systems (GIS) and Image Classification Machines (ICM) have become fundamental and relevant tools in recent years. The computational and methodological development has allowed the MCI to position itself as a practical tool to analyze spatial information, and it agrees to be use in different fields of knowledge. Urban planning and territorial development have benefited from the ICMs applied to GIS, since these tools facilitate the consistent analysis of the different environments that can occur within urban, semi-urban and rural areas, with marked precision. This research will seek to show the most essential aspects of the different MCI for recognition of urban, semi-urban and rural environments that are currently used, giving greater emphasis to programs that analyze urban areas, since these represent the highest percentage of human-inhabited environments. Within the multidimensional analysis of the different ICMs, a relationship of the type of inputs that they accept, the methodology of the ICM and some of its parameters, the outputs that they generate and the remote sensors that allow generating the inputs for these ICMs analyzed. Allowing a clearer understanding of which methodology can or cannot be used within a specific urban context and environment.

Keywords: geographic information systems, remote sensing, neural networks C45, clustering C38, image classification

Introducción

Desde 1970 la población mundial pasó de 3.68 a 7.87 mil millones de personas, a su vez la población urbana global pasó de un 33% a un 56% en 2020 (<https://data.worldbank.org/>), lo cual crea la necesidad de acceso a insumos adecuados para la planeación territorial que cuenten con la misma velocidad de estas dinámicas poblacionales urbanas. Dicho crecimiento se explica por medio de varios factores. Uno de los más relevantes que genera el crecimiento urbano es la migración del campo a la ciudad, lo que se traduce en una presión socio territorial sobre las urbes y sus áreas de soporte (zonas rurales y de transición semiurbanas) (Niu, 2022), esta presión se aprecia en el área de los crecimientos urbanos, los cuales representan una huella física importante de la población mundial. Esto se aprecia con mayor notoriedad en las grandes ciudades y sus redes de conexión que comprenden sistemas de infraestructura, zonas de producción, zonas industriales y de transporte, incluyen también grandes extensiones de zonas residenciales formales e informales (Roy & Kasemi, 2021). Sumado a lo anterior, los entornos urbanos y semiurbanos presentan diferentes características, estas van desde variaciones topográficas, hasta las más complejas morfologías que se consolidan a través de mallas densas de vivienda e infraestructura (Liu et al., 2022).

Los anteriores desarrollos físicos son difíciles de medir y mapear con trabajo de campo tradicional (Chen et al., 2022) los cuales usan recorridos físicos en las zonas a analizar, es en este punto donde las nuevas herramientas de los sistemas de información geográfica (SIG), las máquinas de clasificación de imágenes (MCI) y sensores remotos (SR) se presentan como una alternativa necesaria para realizar un seguimiento al crecimiento urbanos (Owusu et al., 2021), y rurales los cuales son el objeto principal de estudio de éste trabajo.

Una de las herramientas que consideramos consta del uso de SR satelitales y la aplicación de MCI para su interpretación. Los SR realizan captura de datos periódicamente con lo que es posible construir una línea de tiempo de los cambios en las áreas objeto de estudio (Cao et al., 2020), (Boulila et al., 2021), esto a su vez genera grandes volúmenes de información, por lo cual, se requieren herramientas de interpretación ágiles y precisas, tales como los programas para análisis de esta información (Roy & Kasemi, 2021). En la actualidad existe variedad de MCI satelitales (Vijayalakshmi et al., 2021), lo que fabrica la necesidad de comprender cómo pueden ser aplicadas estas máquinas en diferentes entornos, tales como: ciudades de mediano formato, ciudades de baja

población, entornos suburbanos y rurales entre otros (Boulila et al., 2021). En particular estas herramientas nos ayudan a comprender de manera adecuada e integral las áreas urbanas, periurbanas y rurales del territorio, las cuales pueden abarcar con facilidad las decenas de kilómetros cuadrados, haciendo así útil y necesario el mapeo autónomo de la información capturada por la teledetección de los SR (Sonde et al., 2020).

Por lo anterior, es importante revisar cuáles MCI son usadas en entornos urbanos (Wang & Biljecki, 2022) y cuáles entornos rurales (H. Li et al., 2022) insumos usan para generar el análisis, esto con el fin de determinar cómo lograr un mapeo o cartografía cercana a la realidad (espacio físico de los entornos), permitiendo determinar el grado de confiabilidad de estas y logrando con esto también generar una comparativa entre las diferentes MCI.

Finalmente, este trabajo pretende realizar un compendio útil para disgregar de manera rápida qué MCI usar según el área del territorio a analizar y comprender las limitantes de estas a la hora de ser usada. Esto, como se dijo anteriormente, con el objetivo de comprender y acceder a insumos adecuados para la generación de planeación en el territorio.

Objetivo General

Analizar las máquinas de clasificación de imágenes para la elaboración de cartografías en el territorio.

Objetivos específicos

Identificar las máquinas de clasificación de imágenes utilizadas en los últimos 6 años para la elaboración de cartografías en entornos urbanos y rurales de los territorios.

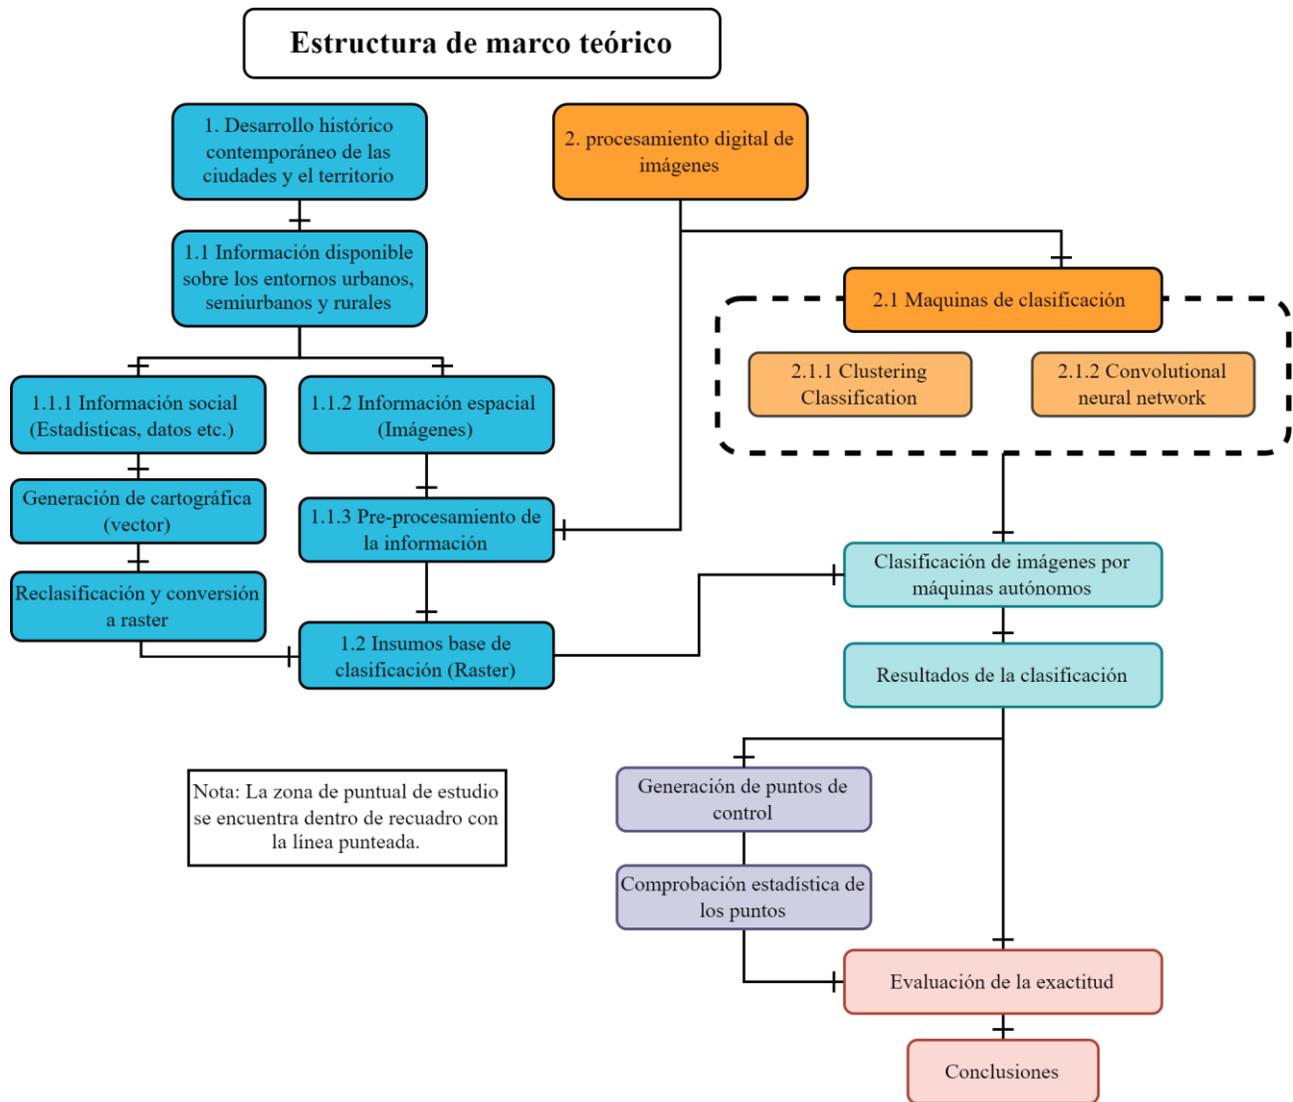
Describir el grado de implementación y las metodologías de las MCI en los entornos urbanos y rurales de los territorios.

Generar una comparativa de las máquinas de clasificación de imágenes seleccionadas para la clasificación de entornos urbanos y rurales.

Marco teórico y antecedentes

De manera inicial, se realiza la presentación del esquema del marco teórico y su desarrollo:

Figura 1
Estructura de marco teórico de la investigación



Nota. Fuente: diseño propio

1. Desarrollo histórico contemporáneo de las ciudades

La población urbana ha presentado un crecimiento continuo a una tasa de 0.5% anual durante las últimas 2 décadas (<https://data.worldbank.org/>), pasando de un 47 % a un 57 % del total de la población global. A su vez, los entornos urbanos también presentan una expansión continua de la actividad edificatoria, incluyendo sus crecimientos periféricos, terminando por modificar a su vez los entornos rurales circundantes (Cao et al., 2020). Estos desarrollos están caracterizados por presentar una mezcla de diferentes usos, los cuales van desde zonas industriales, zonas de transición agrícola, espacios verdes, infraestructuras, comercio hasta zonas residenciales entre muchos otros.

Los desarrollos urbanos y periurbanos se encuentran directamente relacionados con la migración poblacional a las aglomeraciones urbanas. Esta población migrante presenta una particularidad, dado que tres cuartas partes de esta población presenta una condición de vulnerabilidad (UN HABITAT, 2016) (Fan et al., 2022), lo cual influye notoriamente en la construcción física el territorio, dado que las poblaciones vulnerables generan habitualmente procesos informales de asentamientos (UN HABITAT, 2016), los cuales tienen mayores dificultades para ser monitoreados en campo por diferentes factores de seguridad, sociales y de infraestructura.

Las actividades relacionadas con las migraciones poblacionales alteran de forma integral a las ciudades y su entorno circundante (Cao et al., 2020), debido a la compleja forma que interactúan estas con los componentes del territorio tales como: infraestructura de transporte, saneamiento básico, instalaciones de comercio, zonas de servicios, espacios administrativos, zonas residenciales e invasiones... las cuales se encuentran dentro de la trama del territorio, siendo las ciudades, e incluyendo su radio de afectación un sistema complejo que interactúa de manera íntegra con todos los componentes que la agrupan (Roy & Kasemi, 2021).

Actualmente, los territorios sufren un constante cambio, los procesos de expansión urbana, densificación y redensificación, reducción de zonas de cultivo, pérdida de capas vegetales modifican el entorno físico y generan nuevas configuraciones, tanto internas (zonas consolidadas urbanas) como externas (zonas periféricas y rurales) (Cao et al., 2020), estas condiciones permanentes de cambio dificultan un monitoreo constante y eficiente dada la velocidad de los cambios (Sonde et al., 2020).

1.1 Información disponible en los territorios

Los entes territoriales (estados, municipios, provincias etc.), ONGs y corporaciones privadas, entre otras entidades han estado monitoreando desde diferentes ámbitos socioespaciales los entornos urbanos y rurales (UN HABITAT, 2016), esto se ha realizado de manera continua a lo largo de las últimas décadas. Los fines con los cuales se realizan estos monitoreos dependen de la naturaleza de la entidad, dado que la información recopilada puede tener fines administrativos y de control territorial (Yin et al., 2022), como también puede ser usada con fines comerciales e investigativos. La información recopilada de los entornos urbanos se clasificará para efectos de esta investigación en dos grandes grupos: el primero, se denominará información no espacial y el segundo, se denominará información espacial, los cuales serán descritos a continuación:

1.1.1 información no espacial

Se caracteriza por ser un insumo no georreferenciado, referenciado o cartografiado, estos pueden ser tablas, noticias, informes de campo, cifras o indicadores sociales entre otros (UN HABITAT, 2016), pueden ser recopiladas y/o generados por distintas fuentes tanto gubernamentales como privadas, un ejemplo de esto son las cifras globales que recopila World Bank y UN Habitat, se dejan los links de acceso respectivos para su visualización <https://data.worldbank.org/> y <https://data.unhabitat.org/>

Una característica particular de mayoría de los insumos que se encuentran en esta categoría es la posibilidad de transcribir su información sin dimensión espacial a cartografía, esto a través de diferentes herramientas digitales, las cuales permiten la elaboración planimétrica, la referenciación, clasificación y conversión a formatos ráster (Martínez et al., 2016). Lo anterior posibilita que el insumo resultante participe de los procesos de edición espacial, clasificación de imágenes, álgebras de mapas etc. permitiendo la interacción plena con la información recopilada por los sensores remotos.

Un ejemplo de lo anterior, son las estadísticas poblacionales que se llevan a cabo dentro las ciudades, esta información parte de un censo que se introduce en una base de datos, la cual con producción y transcripción adecuada puede referenciarse en un levantamiento cartográfico de

formato vector, el cual posteriormente es reclasificado y convertido en formato ráster, logrando con esto la compatibilidad para hacer análisis de imágenes.

1.1.2 información espacial

Se caracteriza por ser un insumo que se presenta dentro de una cartografía o imagen, a su vez este se encuentra referenciado y en algunos casos georreferenciado. Dentro de esta categoría se pueden encontrar mapas en formato vector, imágenes satelitales, ortofotografías, imágenes de drones y en general todo elemento en formato vector o ráster que tenga una referencia espacial (Chuvienco, 2008).

Una característica importante de estos insumos es que permite generar relaciones, correlaciones y operaciones espaciales, tales como álgebra de mapas, segmentaciones de imágenes, selección y clasificación de conjuntos de datos espaciales (Rees, 2012). Para poder realizar las operaciones mencionadas anteriormente es necesario seguir pasos previos, entre estos está la selección adecuada del insumo y el preprocesamiento de los datos, dado que de esto depende el resultado de la operación. Esta investigación se enfocará en los insumos entregados por los sensores remotos satelitales, los cuales de manera general son imágenes con múltiples bandas.

1.1.2.1 imágenes satelitales

Dentro de la información espacial se encuentra el subgrupo de imágenes captadas por sensores remotos los cuales se encuentran en el espacio (satélites), estas se presentan como imágenes de múltiples bandas, las cuales contienen diferentes niveles de resolución espacial, radiométrica, temporal, angular, espectral y polaridad (Rees, 2012), estas variedades de niveles de resolución dependen del tipo de sensor y las características del fenómeno a captar.

Las imágenes satelitales presentan una amplia gama de uso en la actualidad, algunos usos son la climatología, búsqueda de yacimientos minerales, monitoreo de las quemas globales, medición de niveles de calidad del aire y de humedad atmosféricos entre otros. En este caso de investigación nos enfocaremos en las imágenes que muestran los fenómenos asociados al desarrollo físico de los entornos urbanos y rurales.

1.1.3 Preprocesamiento de imágenes

Las imágenes tomadas por los sensores remotos satelitales deben surtir la etapa de preprocesamiento, en esta etapa la imagen es georreferenciada o referenciada, se clasifican los valores crudos entregados por el sensor, se analiza y ortogonaliza (ortorectificación) la imagen o se le reclasifican valores específicos con relaciones a las etiquetas o análisis a realizar (Chuvieco, 2008).

Si las imágenes no pasan por la etapa de preprocesamiento se van a generar errores al momento de la interpretación y clasificación, dado que las imágenes requieren correcciones atmosféricas, conversiones de valores crudos, ubicación específica de las bandas entre otros (Rees, 2012), estos ajustes previos dependen del tipo de procesamiento buscado. Lo anterior, busca evitar errores de referenciación por no tener el adecuado sistema de coordenadas, errores radiométricos por no generar las correcciones atmosféricas, errores geométricos por realizar las ortorectificaciones adecuadas. Los errores dependen del tipo de insumo base y el procesamiento buscado, la eficiencia y exactitud de los procesos que se apliquen a la imagen varían según la calidad del preprocesamiento realizado (Vijayalakshmi et al., 2021).

1.2 Insumos base de clasificación (imágenes ráster preprocesadas)

Las imágenes ráster que han pasado por las correcciones mencionadas en el anterior capítulo se encuentran listas para ser analizadas, en algunos casos se deben generar procesos adicionales tales como: reclasificar los valores obtenidos con el fin homogeneizar los rangos de operación, generar máscaras de recorte para determinar el área de interpretación o estudio puntual, incluyendo aplicar filtros si se requiere realizar algún tipo de operación particular, los anteriores procesos son opcionales (Rees, 2012). Una vez surtidas las etapas anteriores las imágenes se vuelven un insumo base adecuado para ser procesado y analizado de manera eficiente.

Los insumos bases pueden presentarse en formatos con gran contenido de información, estos volúmenes de información requieren metodologías y máquinas adecuadas que faciliten el análisis y procesamiento de los mismos datos (Zhou et al., 2020).

1.3 Procesamiento digital de imágenes

El procesamiento digital de las imágenes referenciadas comienza en la década de los sesenta (Chuvienco, 2008) con la invención de las computadoras digitales, durante esta primera generación se contaba poca información espacial, limitándose a las imágenes de vuelos, y no se presentaban aún los sensores remotos espaciales. Los primeros satélites para teledetección se pusieron en órbita entre los años 1970 y 1980 (Rees, 2012), estos presentaban una mínima capacidad de almacenamiento y resoluciones. Situación que evolucionaría con el desarrollo de nuevas tecnologías.

En la actualidad se presenta gran variedad de sistemas de teledetección remota, entre ellos los satélites, estos presentan diferentes tipos de sensores con una gran variedad de resoluciones espaciales, radiométricas, temporales, angulares, espectrales y de polaridad, permitiendo tener un material base abundante (Goodchild, 2011). Dentro de esta investigación no se tendrá en cuenta la información generada por los drones y sus sensores, dado que este campo de investigación es muy amplio, a su vez tampoco se tendrá en cuenta la información generada por sensores puestos en aviones, limitando así la investigación a los sensores remotos espaciales. Lo anterior no limita que los resultados y las características de las MCI analizadas dentro de la investigación no se puedan aplicar a las imágenes generadas por otros sensores.

La disponibilidad de imágenes y firmas espectro gráficas presentan limitaciones que van desde los componentes técnicos, económicos y de disponibilidad, por lo cual es importante determinar el insumo idóneo y el estado de preprocesamiento requerido con el fin de evitar reprocesos o errores.

En el momento de generar la clasificación de las imágenes sin los datos adecuados las máquinas de clasificación no podrán ejecutar de manera adecuada su función (Sonde et al., 2020). Como ejemplo de insumos inadecuados podemos mencionar las imágenes con alteraciones radiométricas, altos niveles de nubosidad, sistemas de coordenadas erróneas, niveles de resolución espacial insuficientes... lo anterior imposibilita una correcta clasificación de la imagen (Goodchild, 2011).

2. Procesamiento digital de imágenes

2.1 Máquinas de clasificación

Existe una variedad de MCI, dentro las cuales podemos encontrar las que detectan patrones geométricos, las que clasifican según el rango del valor de píxel individual, algunas máquinas usan redes neuronales entrenadas para la clasificación barrios completos (conjuntos de píxeles) (Sonde et al., 2020), estas máquinas permiten realizar clasificación a la información obtenida de todo tipo de sensores que generen una imagen, para el caso puntual de esta investigación se tomarán en cuenta las máquinas que realicen la clasificación de las imágenes satelitales monoespectrales (pancromáticas y RGB) multiespectrales e hiperespectrales.

Dentro de las máquinas de clasificación tenemos dos grandes grupos los cuales dependen de la interacción entre el analista y la computadora: el primero, son las máquinas de clasificación supervisada y el segundo, son las máquinas de clasificación no supervisada, las cuales serán descritas a continuación.

Clasificación supervisada

La clasificación supervisada es donde el analista decide a qué categorías de clase desea asignar píxeles o segmentos. Estas categorías de clase se conocen como su esquema de clasificación. Una vez generado todo el esquema de clasificación se inicia la clasificación de la imagen objetivo. Posterior, el analista tendrá que revisar el conjunto de datos clasificado resultante y reasignar cualquier clase o polígono de clase erróneo a la clase adecuada según su esquema (<https://pro.arcgis.com/>).

Clasificación no supervisada

Es donde la computadora decide qué clases están presentes en su imagen en función de las diferencias estadísticas en las características espectrales de los píxeles. El analista interactúa con algunos parámetros de la máquina, ejemplo de esto, se puede decidir la cantidad de clústeres en que se deben clasificar la imagen y el tipo de algoritmo que usará la máquina. Una vez completada

la clasificación no supervisada, debe asignar las clases resultantes a las categorías de clase dentro de su esquema esto lo realiza el analista en un proceso de posproducción (<https://pro.arcgis.com/>).

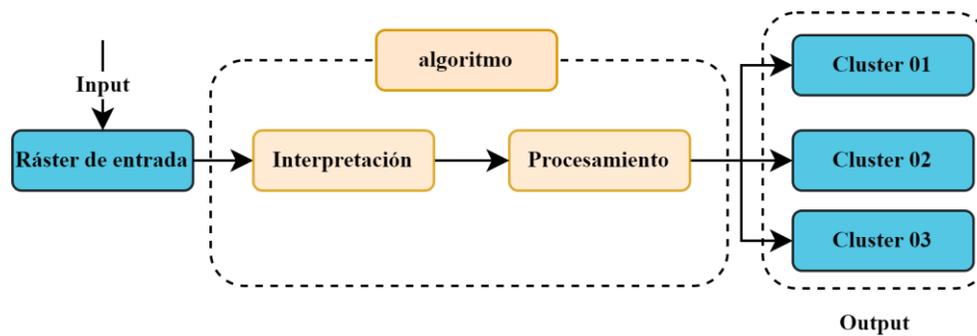
A continuación, se presentarán las MCI que serán tenidas en cuenta para esta investigación, estas máquinas no son los únicos que se usan en la actualidad, el listado se seleccionó a partir de dos criterios: el primero, se tienen en cuenta las metodologías y máquinas estandarizadas en los softwares para el tratamiento de datos geospaciales tales como ENVI, ArcGis, Qgis, SuperMap entre otros. El segundo criterio, fue la selección de las máquinas que se usan en las investigaciones que se encuentran cargadas en los repositorios académicos que se enfocan en ingeniería y en informática. Las máquinas seleccionadas para esta monografía son:

2.1.1 Clasificación por clusterización (CC)

La clusterización de datos se refiere a una amplia gama de algoritmos numéricos diseñados para encontrar grupos de datos homogéneos utilizando métodos numéricos sistemáticos (Tortora & Palumbo, 2022). En la clasificación de imágenes, es un proceso por el cual se divide un conjunto de datos (píxeles) en un conjunto de subclases significativas, conocidas como clústeres (<https://pro.arcgis.com/>). La clusterización es similar a la clasificación supervisada en la que se agrupan los datos. Aunque, a diferencia de la clasificación supervisada, los grupos no están definidos previamente por el analista. A continuación, se ubican algunos métodos: métodos de partición, Agrupación jerárquica, Agrupación difusa o Agrupación basada en modelos. En la **Figura 2** se puede apreciar un esquema de una MCI por clusterización.

Figura 2

Estructura de clasificación básica de un sistema de clusterización no supervisada



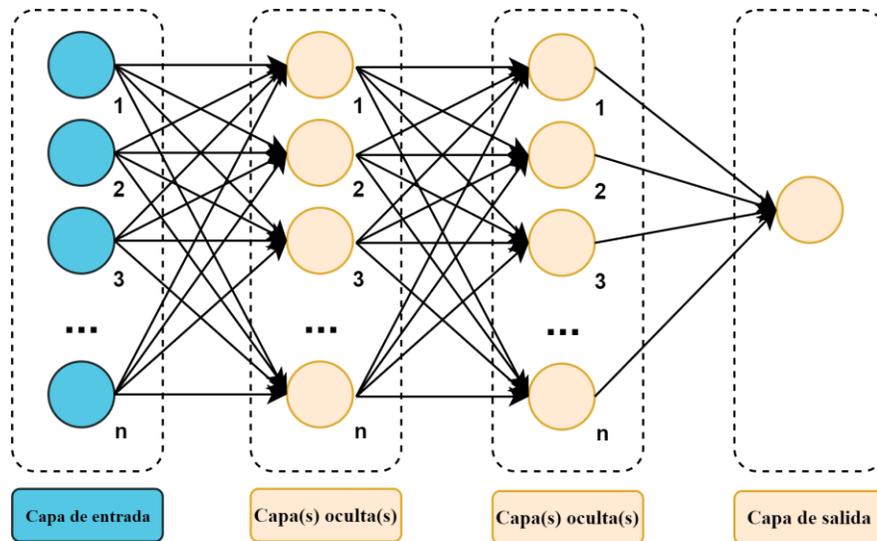
Nota. Fuente: diseño propio

2.1.2 Redes neuronal convoluciones (CNN)

Las redes neuronales convolucionales son un tipo especializado de redes neuronales artificiales que utilizan una operación matemática llamada convolución en lugar de la multiplicación de matriz general en al menos una de sus capas. Están diseñadas específicamente para procesar datos de píxeles y se utilizan en el reconocimiento y procesamiento de imágenes (Martins et al., 2021). Este modelo de aprendizaje profundo toma un ráster de entrada, asigna importancias (pesos y sesgos) a varios aspectos y condiciones del ráster. El preprocesamiento requerido en CNN es menor en comparación con otras MCI, mientras otros métodos tradicionales de clasificación de imágenes los filtros deben ser generados de manera manual, las CNN con suficiente entrenamiento pueden tener la capacidad de generar filtros y preprocesamientos (Shawky et al., 2020a).

Figura 3

Estructura de una red básica de una red neural de capas ocultas



Nota. Fuente: diseño propio

3 Toma de puntos de control

Para realizar la comprobación y validación de las clasificaciones que ha realizado la MCI, es necesario tener información de control, en el caso de las imágenes satelitales se obtienen de dos maneras estos puntos: La primera, es el muestreo en campo donde se genera una cantidad de puntos dentro de un espacio determinado, estos puntos deben ser los suficientes para que tenga una validación estadística (Londoño & Valdés, 2012), esta información debe caracterizar la misma que presentan las clases que la máquina clasificó; la segunda, se realiza a partir de una verificación visual de la imagen a clasificar y el análisis genera puntos de control dentro de la imagen, los cuales se usarán posteriormente para comprobación (Chuvienco, 1996).

4 Evaluación de clasificación

El analista debe hacer la verificación partiendo de los puntos de control que fueron tomados en campo o directamente sobre la imagen objeto de clasificación, estos deben tener una cantidad de puntos mínimos que permita hacer una validación estadística y que contenga un muestreo representativo (Londoño & Valdés, 2012). Posteriormente, se toma la imagen clasificada por la MCI y se genera la comparativa determinando la precisión de esta. A su vez, se debe verificar los errores por omisión o acción que haya tenido la máquina en el momento de generar la clasificación (Chuvienco, 1996), con el fin de determinar los ajustes que se deben efectuar en sus parámetros, permitiendo con esto mejorar la precisión de la máquina.

5 Conclusiones

Finalmente, las MCI que se presentaron anteriormente están en un constante cambio, generando nuevas etapas y variaciones de estas. El poder computacional, los sensores de captura y las metodologías de análisis de imágenes están en un crecimiento y diversificación continua (Masser, 2001), lo que permite entrever que en pocos años tendremos nuevas metodologías y MCI aplicadas a los desarrollos urbanos y rurales, permitiendo adaptarnos a los constantes y acelerados cambios de nuestro entorno físico-espacial.

Metodología

A continuación, se realiza la presentación de la propuesta metodológica realizada para esta monografía:

Como medio principal de búsqueda de esta monografía se usan las bases de datos académicas, para la selección de estas se analiza cuales se encuentran relacionadas con las siguientes áreas de conocimiento: teledetección, sensores remotos, clasificación de imágenes, inteligencia profunda, redes neuronales convolucionales, clusterización y planeación urbana. Por lo anterior, se han seleccionado los siguientes buscadores: SpringerLink, GoogleScholar, ScienceDirect.

Posteriormente a la selección del buscador, se genera el método de búsqueda, en el cual se utiliza una palabra clave fija la cual es **remote sensing** dado que la investigación se centra en su totalidad en los sensores remotos. A continuación, se genera una segunda palabra clave la cual debe seleccionar una de estas tres opciones: **urban**, **territory** o **urban planning**, estas series de palabras tiene como objetivo central la búsqueda en las áreas urbanas, semiurbanas y rurales. Finalmente, se genera una tercera palabra la cual se refiere a las máquinas de clasificación de imágenes en esta categoría se escoge una de las dos (2) que son objeto de estudio las cuales son: **Clustering Y Convolutional Neural Network (CNN)**.

Para cada una de las máquinas de clasificación de imágenes que serán tenidas en cuenta para esta investigación se toma un número mínimo de 13 artículos. Estos deben presentar características puntuales las cuales serán descritas a continuación:

- Tener una fecha de publicación inferior a seis (6) años. En algunos casos se permitirá el uso de publicaciones con mayor tiempo de publicación siempre y cuando su investigación siga teniendo repercusión en el presente.
- Tener como área de estudio las zonas urbanas, semiurbanas o rurales, incluyendo condiciones medioambientales de las mismas. Todas las investigaciones deben estar relacionadas con los procesos antropogénicos.
- Debe presentar una MCI que esté dentro del objeto de estudio de esta investigación.

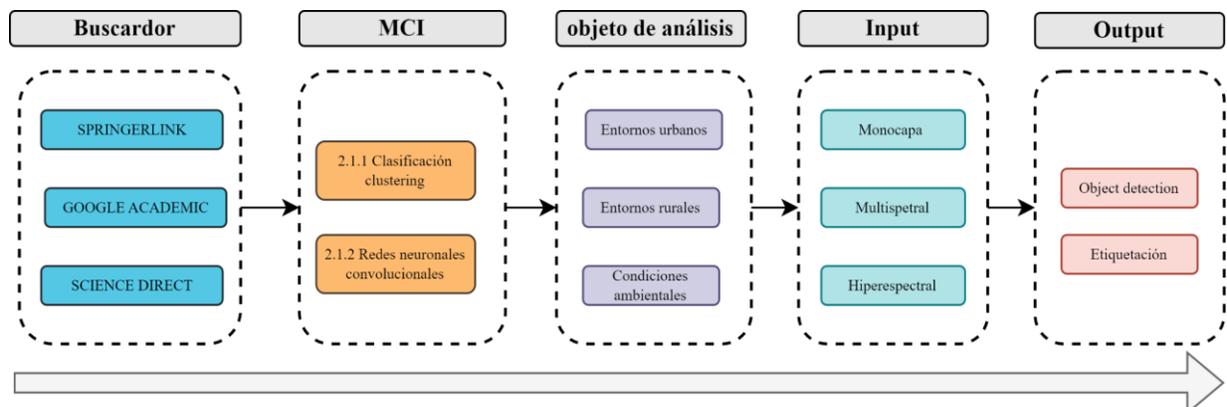
Posterior, a la recopilación de los artículos de revisión o artículos de investigación, se procede a la revisión de cada uno de estos artículos, en la cual se tomarán los siguientes datos:

- Tipo de algoritmo que usa la máquina de clasificación.
- Tipo de input, los datos de entrada que se usarán en esta investigación son imágenes RGB y sus subconjuntos, imágenes multiespectrales, imágenes hiperespectrales. No se tendrán en consideración imágenes de LIDAR o cualquier otro tipo de radar, imágenes de drones o aviones.
- Objeto de análisis, se analizarán las zonas de estudios en este caso se clasifican en tres, zonas urbanas, zonas rurales y condiciones medioambientales ligadas a condiciones antropogénicas.
- Tipo de sensor, se analiza qué sensor remoto toma captura la información que está siendo tratada en el artículo.
- Porcentaje (%) de precisión de la máquina, este porcentaje (%) estará directamente ligado al objeto de análisis de la investigación.

Con los anteriores datos se procederá a sacar las estadísticas cruzadas de cada una de las columnas, parametrizando aspectos y detalles importantes de cada una. A continuación, se mostrará la tabla del flujo de trabajo que se genera en esta investigación:

Figura 4

Estructura del flujo de búsqueda de la información



Nota. Fuente: diseño propio

Análisis y resultados

Como consideraciones generales encontradas en estas MCI revisadas para esta investigación tenemos que: los inputs y los sensores remotos, en su gran mayoría sirven de manera transversal a las MCI que se encuentran dentro de esta investigación.

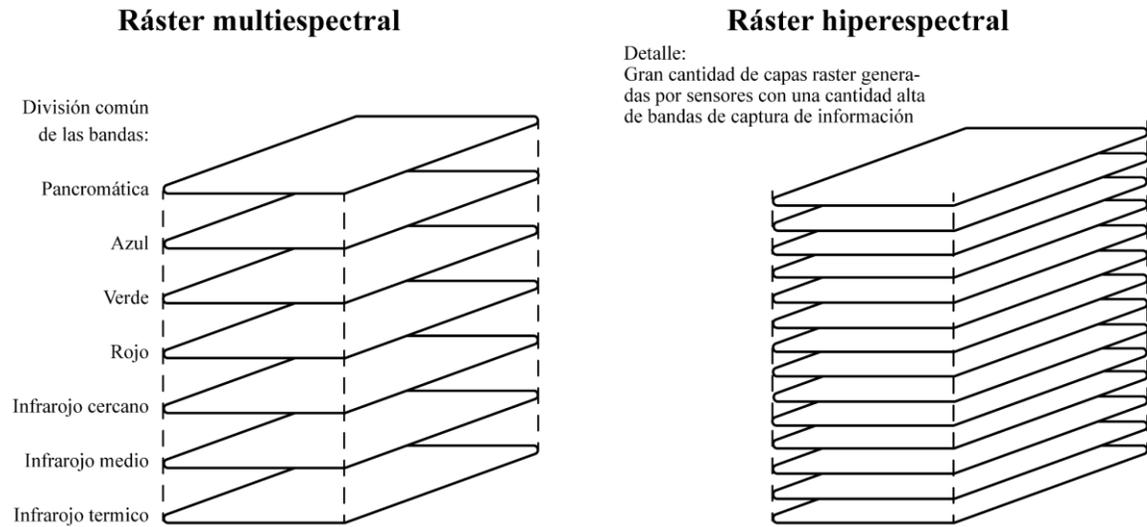
Input

Se usan diferentes entradas, tales como: Imágenes monoespectrales de formatos RGB en los cuales se encuentran imágenes de media resolución (HR) (Davydzenka et al., 2022) y las imágenes de alta resolución (VHR) (Fu et al., 2021), imágenes multiespectrales (inferiores a 30 bandas) (Su et al., 2021) ejemplo de esto las imágenes captadas por los sensores SPOT o LandSat, e imágenes hiperespectrales (superiores a 30 bandas) (Firat et al., 2022) ejemplo de esta, las imágenes del sensor MODIS.

Las MCI permiten la entrada de inputs multiespectrales, los cuales son comunes y la gran mayoría de los SR remotos capturan este tipo de dato, esta entrada permite generar un valor puntual sobre el píxel a clasificar, dependiendo del juego de bandas que use para construir la imagen objeto de estudio, esto facilita la clasificación generando conjuntos de píxeles con valores más homogéneos y diferenciables (Yao et al., 2022).

El tipo de entrada determina el algoritmo y los preajustes que se pueden realizar, si se usan imágenes hiperespectrales se puede realizar preprocesamientos en el cual se analizan la totalidad de las bandas para determinar cuales tienen una mayor incidencia en el proceso de clasificación puntual, esto a través de un modelo estadístico que determine el grado de impacto y eficiencia que puede tener una banda (Firat et al., 2022), lo anterior se puede lograr de manera eficiente con una validación cruzada.

Figura 5
esquema de un ráster multiespectrales e hiperespectrales



Nota. Fuente: diseño propio

Si se genera input con una imagen de formato RGB monocapa o un ráster pancromático, se analiza la resolución espacial, si esta presenta una resolución espacial con un tamaño de píxel de 1 metro o inferior, se puede determinar como una imagen de alta resolución espacial (VHR) lo cual permite realizar un preprocesamiento más específico (Goodchild, 2011), si presenta una resolución superior a 1 metro se considera una resolución espacial media (HR). En los entornos que presentan alta heterogeneidad en los valores de los píxeles, tales como: entornos residenciales de pequeño formato, viviendas unifamiliares aglomeradas o asentamientos informales, se puede dificultar el reconocimiento si la resolución espacial de SR es baja (Fan et al., 2022).

Figura 6

Imagen de la izquierda con resolución espacial media (HR) superior a 1 metro, imagen de la derecha con resolución espacial alta (VHR) inferior a 1 metro



Nota. Fuente de la imagen: <https://geomedellin-m-medellin.opendata.arcgis.com>

Es importante determinar el tipo de input a utilizar, dado que en todos los entornos geográficos no es posible la obtención de la totalidad de estos inputs, a su vez es necesario determinar la clase de entrada con relación al algoritmo a ejecutar para la clasificación de las imágenes.

Sensores remotos

Las MCI permiten una entrada amplia de tipos de inputs, generando la posibilidad de tomar información de diferentes SR, para este caso se pueden apreciar cómo se usan SR open source como el EyeBird de GoogleEarth (Yao et al., 2022); SR privados que venden información, pero el público en general tiene acceso como MODIS, IOT, Sentinel, SPOT o IRS (Kundu et al., 2021); a su vez, se denota el uso de SR completamente privados o de uso restringido, tal como AIR-FORCE de USA (Kaur et al., 2019). Esta condición se vuelve fundamental dado que no todos los sensores remotos pueden ser accedidos por el público en general.

Los SR varían en función de su objetivo y los sensores que presentan para la captura de información, en la actualidad existe gran cantidad de constelaciones lanzadas desde los estados u organizaciones privadas (Chuvieco, 2008), estas toman información permanentemente, pero no

adquieren información de todas las geografías, por lo cual se hace indispensable determinar el área de estudio previamente y verificar que tipo de SR se encuentra capturando información sobre ese territorio. A su vez, determinar las especificaciones de este, como se mencionó en el apartado de **Input** es necesario seleccionar una imagen de entrada con las condiciones necesaria para el procesamiento de la MCI seleccionada, por lo cual se debe elegir con precisión el SR requerido, comprendiendo que existen de múltiples niveles de resolución espacial, radiométrica, temporal, angular, espectral y polaridad en los mismos (Chuvieco, 2008) (Rees, 2012).

Clasificación por clusterización (CC)

Generalidades

En este tipo de MCI con CC se seleccionaron 15 artículos de investigación, los cuales presentan diversos usos en ámbito del análisis espacial de entornos urbanos y rurales, lo que muestra una amplia utilización en diferentes tareas de clasificación como: determinar las condiciones presentes en un cultivo (Ohana-Levi et al., 2022), clasificar infraestructuras viales (Fu et al., 2021), la identificación de zonas verdes o rurales (Kundu et al., 2021) o la clasificación de entornos urbanos (Kaur et al., 2019), Permitiendo a la clusterización tener un potencial en diversas áreas, incluyendo dentro estas los procesos de planificación territorial.

Estas investigaciones se enfocan en el uso de uno o múltiples algoritmos de clusterización para generar la clasificación no supervisada de las imágenes capturadas por los diferentes SR. Dentro de los artículos se tiene en cuenta: el porcentaje (%) de exactitud que llega el método principal y los métodos de referencia o comparativos; el tipo de inputs que permite; los SR que usa; El tipo de output que genera y el tipo de entorno y/o fenómeno que clasifica la MCI. El porcentaje de exactitud no puede ser comparativo en su totalidad con los otros métodos dado que este varía según la librería (algunos métodos presentan preprocesamientos), los preajustes realizados a la máquina e input usado entre otros parámetros alteran la homogeneidad de la muestra para realizar una comparativa adecuada.

Este método de clasificación por CC presenta una eficiencia para el analista al no tener que generar ningún tipo de etiqueta para el proceso de clasificación, dado que la máquina lo realiza de manera autónoma. Existen diferentes tipos algoritmos de clusterización, tales como, los K-Means

(Kundu et al., 2021) o C-mean (Kaur et al., 2019) los cuales son algoritmos básicos de clusterización. A su vez, hay MCI que usan preajustes a los datos para sesgar la clasificación y redireccionar la clasificación no supervisada con diferentes métodos, ejemplo de esto es el uso de máquinas de soporte vectorial (MSV) antes de la clusterización para realizar preajustes a los datos del ráster objeto de análisis (Kaur et al., 2019). Por lo anterior, se comprende en posibles variables de esta MCI.

Algoritmo

Se usan diferentes tipos de algoritmos para desarrollar la clasificación no supervisada a través del método de clusterización, algunos una clusterización directa sin un modelo de preajuste de la información y solo se determinan los parámetros de la máquina como, cantidad de clústeres a encontrar o el área de la imagen a analizar, estos se pueden apreciar encontrar en los programas de manejo de datos espaciales ArcGis (<https://pro.arcgis.com/>), Qgis o SuperMap.

Dentro de otra categoría se encuentran las máquinas de clusterización que usan preajustes avanzados, buscando generar dos elementos base:

Primero, la limpieza generalizada de los datos que se encuentran en la imagen de entrada, quitando los valores anómalos que se encuentran en la matriz de píxeles, permitiendo con esto tener un rango sin valores mínimo y máximos que se salgan de la media, eliminación de zonas que no presentan un valor dentro del píxel (zonas sin información), permitiendo con esto tener una entrada más limpia al proceso de clusterización (Kaur et al., 2019).

Segundo, definir patrones generales tales como: valores repetitivos o barrios de pixeles con iguales rangos, permitiendo con esto generar un insumo base al proceso de Clusterización que redireccionada la “aleatoriedad” inicial del centro del clúster y la redireccionada a valores definidos por el preprocesamiento. Ejemplo de lo anterior es, el caso del algoritmo FCGT (Kundu et al., 2021) el cual permite acelerar el tiempo de ejecución de la máquina y a su vez generar un mayor grado precisión con relación a otros métodos como el K-Mean simple, dado que encuentran rangos homogéneos de valores dentro de la imagen para iniciar como los clusterización y eliminar una cierta aleatoriedad de las etiquetas que saldrán (Sudha & Aji, 2022).

En algunos casos lo anteriormente descrito vuelve estas MCI no supervisadas en MCI semi-supervisadas, puesto que en los preprocesamientos de las imágenes objeto de análisis se

redireccionan de manera evidente los clústeres a encontrar. La cantidad de clústeres que el analista desee encontrar altera el nivel de precisión de la MCI, al no tener un patrón fijo (valor de píxel o valores promedios de barrios de pixeles) que buscar como en la clasificación supervisada que se verá en otro capítulo, Los valores que esta MCI con CC busca está directamente relacionados a método estadístico que la clusterización tenga y la cual varía con la cantidad de clústeres que deba clasificar.

Output

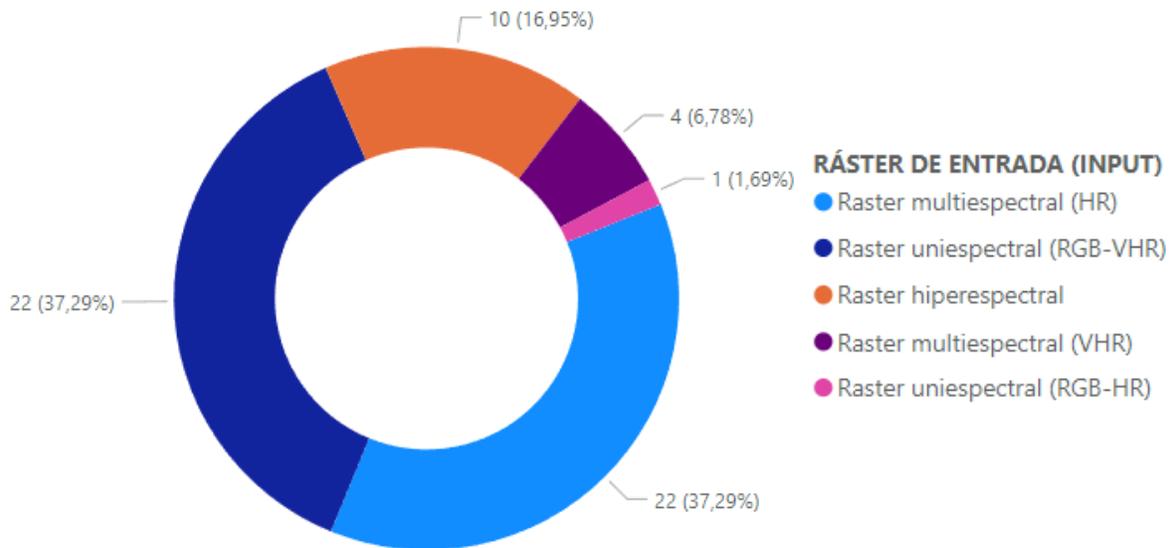
La salida de este método de clasificación es en su totalidad es un ráster único con diferentes etiquetas, este tipo de MCI no permite la salida de ráster con detección de objetos, dado que no se genera un proceso de clasificación supervisada. Esta salida permite al analista comprender de manera clara los diferentes entornos (clústeres) que puede presentar una imagen del territorio, es importante que el analista delimite de manera clara y bajo criterio la cantidad de clústeres a encontrar dentro del ráster seleccionado.

Conclusiones

Se genera inicialmente una tabla de compilación y comparativa la cual se denomina “Anexo 01 CC tabla de análisis”, en esta se discriminan los elementos a analizar de cada una de las MCI usadas en las investigaciones. A continuación, se presentan los diagramas y resultados de esta compilación bibliográfica de las investigaciones usadas para esta investigación.

Figura 7

Relación del tipo de ráster de entrada con la totalidad de los inputs usados en las investigaciones



Nota. Fuente: diseño propio

El 44.03% de la muestra de datos de entrada corresponde a rásteres multiespectrales, los cuales tienen una diversidad de usos que permiten la combinación de bandas para generar valores específicos de píxeles y generar imágenes de falso color (Sadeghi & Etemadfar, n.d.). También, se puede establecer que el 38.98% de los inputs corresponden a una entrada monoespectral, donde el formato RGB tiene un uso importante, siendo estas imágenes interpretables a la vista del analista y le permite comprender de manera ágil la entrada y características de la capa que están introduciendo, otro punto a favor de este tipo de entrada es que presenta imágenes VHR (Kaur et al., 2019).

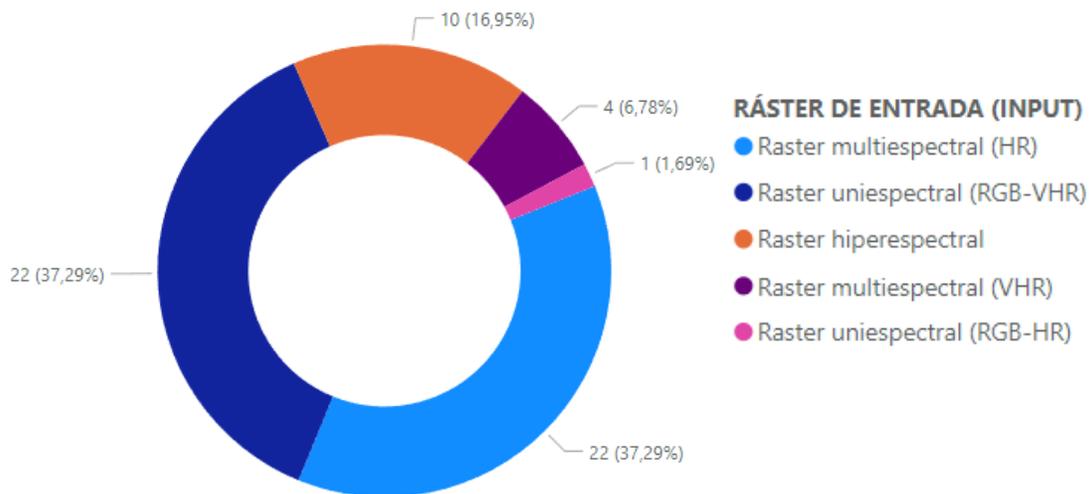
Los rásteres de resolución VHR cuentan con un 44.07% del total, esto muestra que su uso es el mayor dentro de las investigaciones analizadas, este tipo de resolución presenta un grado de detalle alto que permite diferenciar elementos de pequeño formato con niveles de contraste altos y gran resolución. los rásteres de resolución HR también presentan un número importante de representaciones con el 38.98% estos se encuentran relacionados al análisis general de grandes áreas rurales donde los niveles de detalle o resolución espacial no deben requerir ser altos dado que se pueden encontrar grandes zonas homogéneas para la interpretación (Sapucci et al., 2019). Por otro lado, los rásteres hiperspectrales presentan una cantidad limitada de interacciones en las

investigaciones revisadas, tuvo un uso principal para reconocer todo tipo de entornos rurales y urbanos (Sudha & Aji, 2022) dado que este permite tener una gran cantidad de información de un entorno determinado permitiendo una interpretación íntegra de las zonas analizadas.

Se aprecia el uso de diferentes entradas en relaciones similares, por lo cual se infiere que este tipo de MCI puede generar interpretación adecuada a diferentes inputs, esto dependerá en gran medida del entorno a analizar, dado que los entornos urbanos presentaron condiciones de entradas de alta resolución en comparativa de las investigaciones que se centraron en la ruralidad.

Figura 8

Gráfico de dispersión, en el eje Y se aprecia del porcentaje (%) de precisión de la MCI en la clasificación objeto de estudio; en el eje X corresponden a cada una de las MCI que se dataron en la investigación



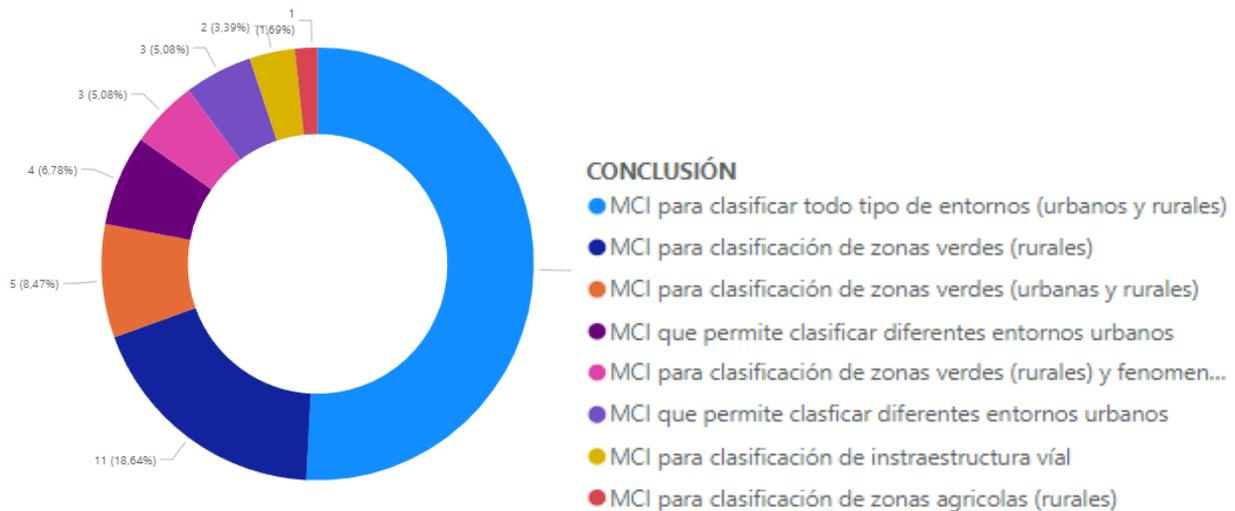
Nota. Fuente: diseño propio

Dentro del gráfico de dispersión, se aprecia como las MCI tienen un nivel alto de clasificación, con un valor promedio dentro de todas las investigaciones de 82.83% situando en un grado alto de interpretación correcta, de manera general el 79% de las MCI se encuentra en un porcentaje de precisión entre 70% y 95%, permitiendo con esto disponer de un rango de precisión considerablemente alto en los diferentes entornos que estas máquinas analizan. En algunas investigaciones estas máquinas tienen preprocesamientos que buscan eliminar los píxeles que no se encuentran dentro de la desviación estándar de los clústeres con el fin de no generar valores extremos en la clasificación (Sudha & Aji, 2022), pero esto implica también posible pérdida de información.

Estos márgenes de precisión están relacionados directamente a los sets de testeo (imágenes a clasificar) que se usaron en las investigaciones y pueden variar según el cambio de imagen a analizar y los parámetros incorporados.

Figura 9

Relación del tipo de uso recomendado según las investigaciones seleccionadas de salida con la totalidad de los outputs usados en las investigaciones



Nota. Fuente: diseño propio

La clusterización se usa de manera transversal para cualquier tipo de clasificación siendo este método no supervisado muy útil para análisis de territorio. Se aprecia como el 50.85% del MCI con clusterización se usaron para revisar y clasificar todo tipo de entornos dentro de las investigaciones, dado que es un método que busca patrones generales y homogéneos en los inputs que se den al momento de clasificar. Otro segmento importante, es el uso de la clusterización para la clasificación de aspectos rurales tales como: la agricultura, condiciones de suelo o bosques entre otros, a su vez, se ha usado este tipo de MCI para analizar los patrones de cambio y recambio que se han sufrido los entornos rurales en un periodo de tiempo definido.

Por lo anterior, se puede inferir que este tipo de MCI con CC son muy usadas en los entornos rurales como la agricultura y condiciones ambientales, pero también presentan una capacidad alta de analizar cualquier tipo de entorno dentro del territorio. Es importante comprender las limitaciones que presenta este tipo de clasificación a la hora de ser escogida, dado que la selección correcta de los parámetros de ajuste de las máquinas, la cantidad de clústeres a clasificar y los

preprocesamientos a que haya lugar pueden afectar la calidad de la clasificación de manera sustancial. El analista debe prever de manera adecuada esto antes de escoger la MCI con CC.

Clasificación por redes neuronales (NN)

Generalidades

En este tipo de MCI se seleccionaron 23 artículos de investigación, los cuales presentan gran variedad de aplicaciones en el ámbito urbano y rural, generando soluciones problemas de clasificación que se pueden encontrar de manera cotidiana como: el mapeo de entornos informales (Fan et al., 2022), distribuciones de masas verdes urbanas (Martins et al., 2021) o la clasificación de objetos como carros, aviones, edificios entre otros (Shawky et al., 2020b) esto permite acelerar proceso de interpretación de grandes áreas por medio de CNN, siendo este tipo de MCI muy útil en los procesos de planeación y desarrollo territorial (J. Li et al., 2022) (Yang et al., 2022).

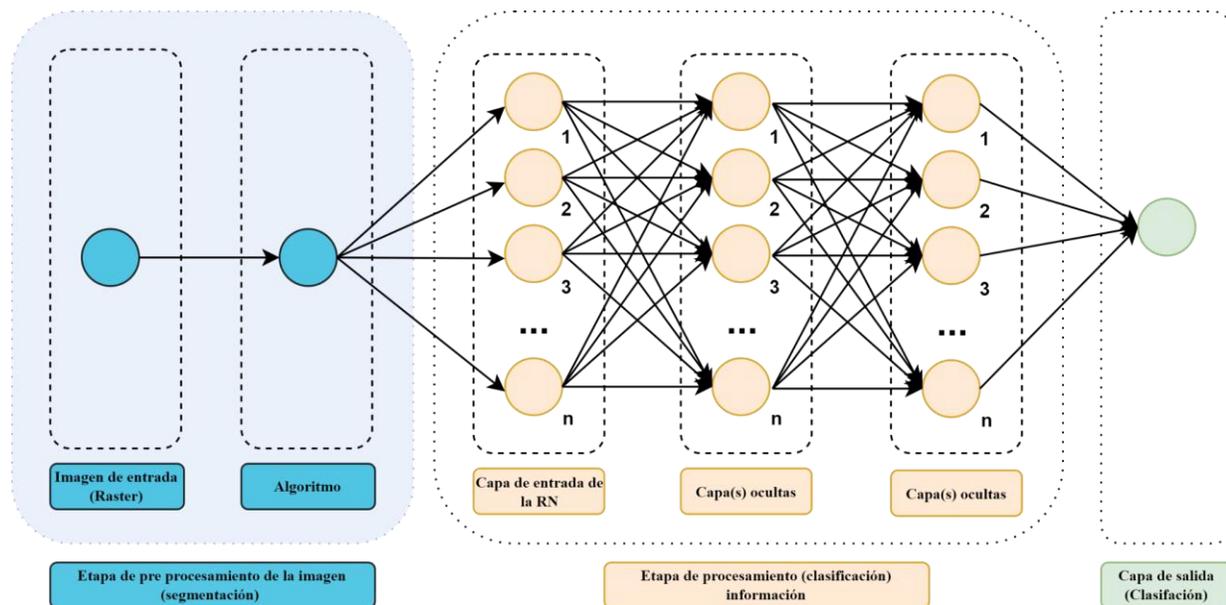
Las imágenes generadas por los SR y su clasificación a través de MCI con RN cada vez más autónomas y pre-entrenadas con porcentajes (%) de precisión altos se han vuelto cruciales en diferentes roles de la industria y los gobiernos (Davydzenka et al., 2022), evitando con esto márgenes altos de error en los análisis del territorio. Por lo anterior, se tendrán en cuenta diferentes aspectos durante el proceso de comparativa y desagregación de las características de cada MCI que presentan como genérico el uso de las RN, para la evaluación multicriterio se tendrán en cuenta el input de entrada, las variables de preajustes, los entornos que clasifican y los outputs que generen. A su vez, se tendrán en consideración los porcentajes (%) de precisión de las máquinas en el momento de clasificación.

Este método de clasificación por RN presenta dos grandes atributos a favor. Primero, permite la entrada de diversos tipos de inputs que van desde las entradas hiperespectrales (Firat et al., 2022) hasta entradas RGB o pancromático (Shawky et al., 2020b) dependiendo del tipo de metodología que desarrollen. Segundo, las máquinas pre-entrenadas con dataset específicos, presentan las etiquetas que el analista requiere para su clasificación, estos datasets permiten tener una gran cantidad de información o bigdata como aprendizaje para la correcta clasificación de imágenes (Zhou et al., 2020), lo cual permite mejores niveles de precisión en el momento de la clasificación como se presentará a continuación.

Algoritmo

Una red neuronal es un modelo que contiene un número elevado de unidades de procesamiento (nodos o neuronas) interconectados, estas unidades se encuentran disgregadas en capas, las cuales se dividen en tres: Capas de entrada, capas ocultas y capa de salida (ibm.com), en el caso del uso de estas redes para el procesamiento y clasificación de ráster se pueden dividir en dos grupos iniciales, las RN con entradas preprocesadas y RN de entrada directa, las redes que presentan preprocesamientos de los datos antes de pasar a la capa de entrada, utilizan algoritmos previos como las MSV (Konstantinidis et al., 2020), siendo estas un primer filtro que limita y segmenta la cantidad de inputs que puede presentar la red con el fin de ahorrar tiempo en el momento del procesamiento.

Figura 10
Estructura de clasificación de una RN con etapa de preprocesamiento



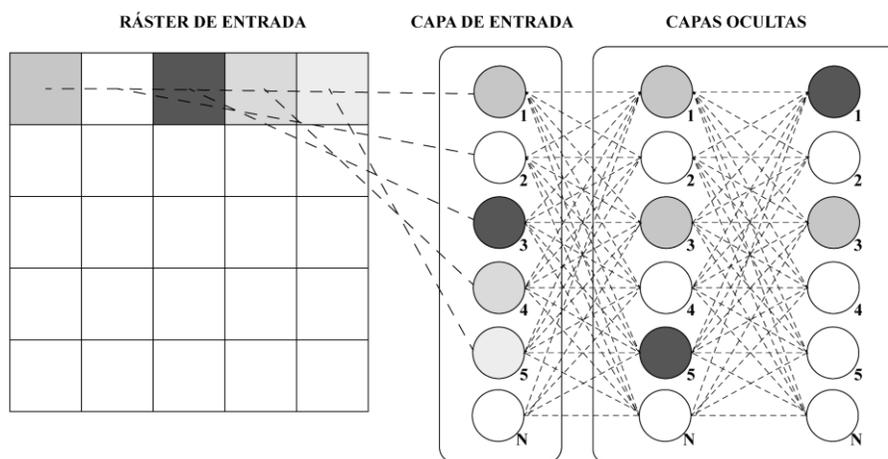
Nota. Fuente: diseño propio

Previo al proceso de clasificación de la imagen objeto de estudio, este tipo de MCI debe ser entrenada a través de set de entrenamiento que contengan ejemplos de las etiquetas que buscan ser encontradas y clasificadas, con el fin de que la red aprenda a reconocer los patrones que deben detectarse (Konstantinidis et al., 2020) (ibm.com).

El input o capa de entrada de la RN es igual a la cantidad de píxeles (unidad) que presenta la imagen, como ejemplo de esto una matriz de píxeles de 20X20 genera unos 400 datos de entrada a la RN, estos datos de entrada pasan a una serie de capas ocultas, estas presentan las unidades de procesamiento, que contienen pesos según su entrenamiento. A su vez, dependiendo de la función de activación que está presente darán la salida a la neurona que realizó el análisis (Soni et al., 2022). Lo anterior permite hacer la clasificación del ráster de entrada.

Figura 11

Detalle de input de un archivo ráster a una red neuronal



Nota. Fuente: diseño propio

Existen múltiples arquitecturas en las redes neuronales, las cuales varían en según la cantidad de neuronas, la cantidad de capas ocultas, el tipo de función de activación que presenten, las máscaras y tipo de posprocesamiento que la RN presenta (Kattenborn et al., 2021), lo cual genera una amplia gama de MCI, estas se entrenan para reconocer características específicas y preestablecidas por el entrenamiento que el analista introdujo. Es importante y necesario hacer la selección adecuada del tipo de MCI con RN reconociendo los aspectos esenciales de la misma.

Output

la salida de estas MCI varía según la metodología de posprocesamiento, dado que las MCI posterior a la clasificación pueden usar filtros para depurar los ruidos de que se puedan presentar en la clasificación (Soni et al., 2022) o retirar elementos que puedan generar errores topológicos,

como el repetir detecciones en el mismo espacio cuando se realiza clasificación de objetos (Shen et al., 2022). En un alto porcentaje las MCI que usan RN presentan filtros y posprocesamiento de los resultados con el fin de depurar y mejorar los niveles de precisión sobre los ráster analizados.

Los tipos de outputs que presentan estas MCI son monocapa con diferentes etiquetas (Martins et al., 2021) y archivos tipo vector con la de detección de objetos puntuales (Shen et al., 2022), incluyendo también MCI que pueden generar ambos tipos de salidas (Zhou et al., 2020). Cada una de las salidas puede tener finalidades diferentes, estas serán otorgadas por el analista y el objetivo de la clasificación inicial.

Figura 12

Imagen de la izquierda, ráster con salida única con diferentes etiquetas; imagen de la derecha, ráster con clasificación de objetos



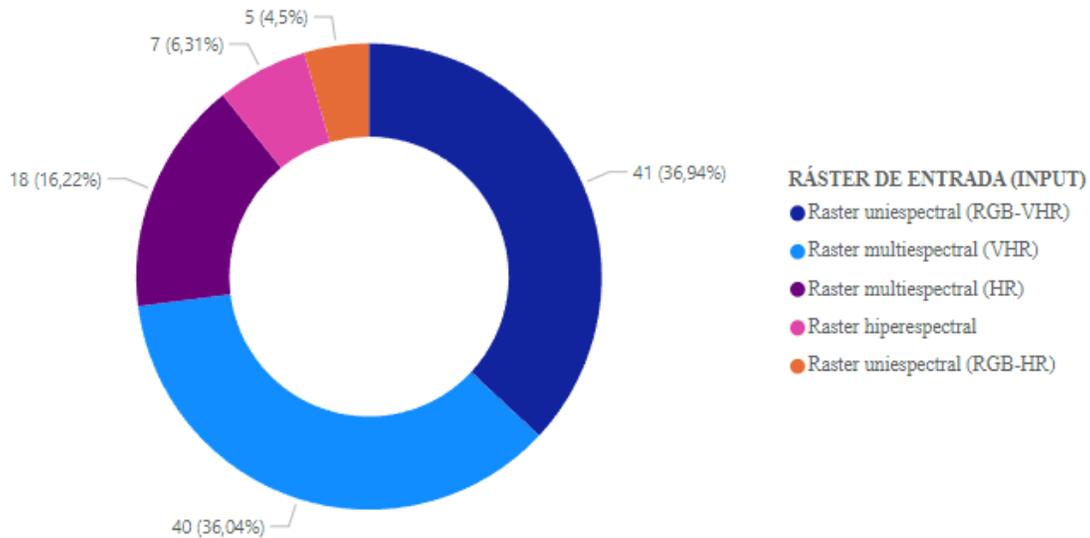
Nota. Diseño propio / Fuente de la imagen base: <https://geomedellin-m-medellin.opendata.arcgis.com>

Conclusiones

Se genera inicialmente una tabla de compilación y comparativa la cual se denomina “Anexo 02 CNN tabla de análisis”, en esta se discriminan los elementos a analizar de cada una de las MCI usadas en las investigaciones. A continuación, se presentan los diagramas y resultado de esta compilación bibliográfica de las investigaciones usadas para esta investigación.

Figura 13

Relación del tipo de ráster de entrada con la totalidad de los inputs usados en las investigaciones



Nota. Fuente: diseño propio

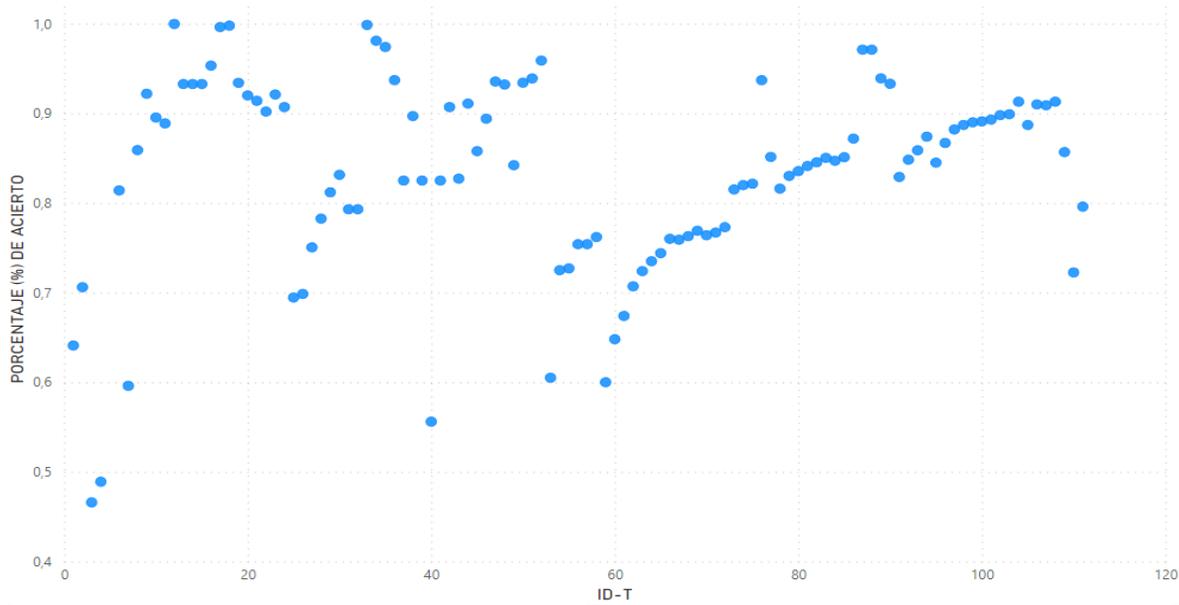
Se aprecia el uso de inputs multiespectrales con un total de un 53%, los cuales basan en una preselección de las bandas adecuadas para determinar cuáles deben ser usadas para el proceso de clasificación (Firat et al., 2022), Este input genera valores a los píxeles a través de la superposición de bandas, permitiendo con ello remarcar valores de elementos en el ráster. Ejemplo de lo anterior, el uso de las bandas infrarrojo cercano (NIR) y rojo, para resaltar la vegetación.

Los rústeres con resolución espacial más usados con el 81% del total, pertenecen al formato de alta resolución espacial (VHR) incluyendo ráster monoespectrales y multiespectrales, el nivel resolución espacial de estos inputs es igual o inferior a un (1) metro. Este tipo input permite hacer distinciones con un mayor grado de precisión dentro de los entornos analizados, dado que, algunos elementos de territorio como viviendas unifamiliares, vehículos y árboles o arbustos individuales no presentan áreas aferentes (huella) importantes que se puedan diferenciar con imágenes de menor resolución espacial (Goodchild, 2011).

En menor medida se encuentran los rústeres monoespectrales de resolución espacial HR y los hiperspectrales, dado que el primero no permite la correcta identificación de entornos urbanos y rurales de pequeña escala, y el segundo se usa con mayor frecuencia en la clasificación de elementos medioambientales.

Figura 14

Gráfico de dispersión, en el eje Y se aprecia del porcentaje (%) de precisión de la MCI en la clasificación objeto de estudio; en el eje X corresponder a cada una de las MCI que se dataron en la investigación



Nota. Fuente: propia

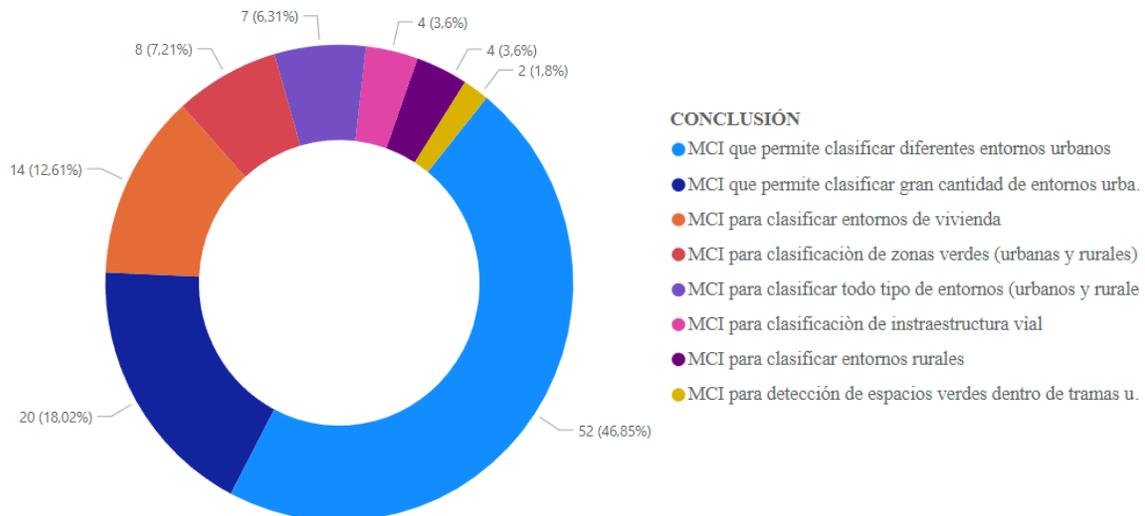
El gráfico anterior, muestra la precisión de cada una de las MCI que se recopilaron de los artículos de investigación. Las MCI con CNN presentan un nivel presión que varía entre el 46.60% y 99.97%. A su vez, teniendo como promedio en el nivel de precisión del 83.01%. El 89% de las MCI revisadas se encuentran en un rango de precisión entre el 70% al 90% lo anterior expresa un nivel de clasificación alto al momento de generar el análisis, permitiendo tener un output con buenas condiciones para la utilización de filtros de depuración (Soni et al., 2022) o permitiendo que al analista realice una depuración y corrección manual al ráster de salida.

Un porcentaje elevado de las investigaciones utilizan el índice Kappa de Cohen para hacer la validación de la clasificación utilizando un ráster de base que previamente ha sido generado y etiquetado de manera correcta (Fan et al., 2022) (Firat et al., 2022), también realizan validaciones con el Valor-F (Soni et al., 2022). Los porcentajes (%) de precisión de estas MCI, no pueden ser comparados de manera completa con otras MCI sin una previa estandarización de los datos de entrada, de los sets de entrenamiento y de los ajustes a los parámetros, a su vez algunas máquinas

presentan preentrenamientos (Konstantinidis et al., 2020) y posprocesamientos (Soni et al., 2022), lo que puede dificultar el proceso de comparativa.

Figura 15

Relación del tipo de ráster de salida con la totalidad de los outputs usados en las investigaciones recopiladas



Nota. Fuente: propia

Se aprecia cómo el 81% de las salidas que realizan las MCI son rásteres monocapa con múltiples etiquetas, este tipo de ráster es común en la aplicación de análisis espaciales que se usan de manera comercial como ArcGis, Qgis, ENVI entre otros; este tipo de ráster es usado para realizar álgebra de mapas (<https://pro.arcgis.com/>) dado que este permiten mantener la totalidad de la píxeles que se encontraba en la imagen objeto de clasificación, por lo cual no quedan valores nulos en ningún espacio de la matriz.

En una menor medida con el 28% están las salidas de clasificación de objetos, este tipo de salida no es muy usada en el análisis de elementos fijos y constantes en los entornos urbanos y rurales, dado que no permiten realizar un análisis multidimensional (álgebra de mapas), Pero esta condición no imposibilita que se usen para detectar objetos fijos tales como edificaciones o tipos de arbolado en el territorio (Cao et al., 2020) a su vez, si tiene un uso amplio en la detección de objetos móviles como: carros, aviones, barcos, camiones etc. (Shen et al., 2022) siendo esto importante para las investigaciones de movilidad y planeación urbana.

Finalmente, existen MCI que pueden generar estos dos tipos de salidas, dado que en los parámetros de salida de la máquina es posible discernir el tipo de output que se requiere según el analista (Zhou et al., 2020).

Conclusiones

Las máquinas de clasificación usadas para imágenes (ráster) obtenidas de los SR satelitales se han desarrollado con fuerza desde su aparición en la década de 1970, lo que ha permitido su diversificación en el tiempo, esto sumado a los avances computacionales, los cuales han logrado nuevos desarrollos en las metodologías de redes neuronales (RN) y máquinas Clusterización, estas metodologías que fueron seleccionadas para esta monografía, muestran un amplio uso en la clasificación de entornos urbanos y rurales, a su vez la posibilidad del uso de diferentes inputs, outputs y el nivel de precisión que presentan es considerablemente alto. Los tiempos de procesamiento de las máquinas y sus características han demostrado una clara ventaja frente a métodos más tradicionales, como la clasificación manual de los entornos o los procesos de clasificación supervisada simples.

Esta investigación da una introducción a un tema que está en una constante evolución tanto en metodologías como en implementaciones, lo que genera un futuro prometedor en sus posibles nuevos usos en la clasificación de entornos por medio de imágenes satelitales. Por otro lado, esta revisión da la posibilidad de tener una guía para la selección de una máquina de clasificación de imágenes adecuada según las necesidades y los insumos con los que pueda contar el analista, esto incluye: tipo de input, SR necesario, tipo de output, si se requiere entrenamientos de la máquina de clasificación, tipo de entorno recomendado a clasificar por la MCI y nivel de precisión al que se podría llegar con parámetros similares a los usados en las investigaciones. Por lo anterior, se concluye que este trabajo debe estar en una constante actualización según aparezcan nuevas MCI y SR.

Referencias

- Boulila, W., Ghandorh, H., Khan, M. A., Ahmed, F., & Ahmad, J. (2021). A novel CNN-LSTM-based approach to predict urban expansion. *Ecological Informatics*, *64*, 101325. <https://doi.org/10.1016/J.ECOINF.2021.101325>
- Cao, R., Tu, W., Yang, C., Li, Q., Liu, J., Zhu, J., Zhang, Q., Li, Q., & Qiu, G. (2020). Deep learning-based remote and social sensing data fusion for urban region function recognition. *ISPRS Journal of Photogrammetry and Remote Sensing*, *163*, 82–97. <https://doi.org/10.1016/J.ISPRSJPRS.2020.02.014>
- Chen, Y., Liu, Z., & Zhou, B.-B. (2022). Population-environment dynamics across world's top 100 urban agglomerations: With implications for transitioning toward global urban sustainability. *Journal of Environmental Management*, *319*, 115630. <https://doi.org/10.1016/J.JENVMAN.2022.115630>
- Chuvieco, E. (1996). *Fundamentos de teledetección Espacial (3ª Ed)*. 576. <https://www.casadellibro.com.co/libro-fundamentos-de-teledeteccion-espacial-3-ed/9788432131271/578712>
- Chuvieco, Emilio. (2008). *Earth observation of global change: the role of satellite remote sensing in monitoring global environment*. 223.
- Davydzenka, T., Tahmasebi, P., & Carroll, M. (2022). Improving remote sensing classification: A deep-learning-assisted model. *Computers & Geosciences*, *164*, 105123. <https://doi.org/10.1016/J.CAGEO.2022.105123>
- Fan, R., Li, J., Song, W., Han, W., Yan, J., & Wang, L. (2022). Urban informal settlements classification via a transformer-based spatial-temporal fusion network using multimodal remote sensing and time-series human activity data. *International Journal of Applied Earth Observation and Geoinformation*, *111*, 102831. <https://doi.org/10.1016/J.JAG.2022.102831>
- Firat, H., Asker, M. E., & Hanbay, D. (2022). Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN. *Remote Sensing Applications: Society and Environment*, *25*, 100694. <https://doi.org/10.1016/J.RSASE.2022.100694>
- Fu, H., Deng, F., Shao, Y., Liu, Y., & Zhang, J. (2021). Road Centreline Extraction of High-Resolution Remote Sensing Image with Improved Beamlet Transform and K-Means Clustering. *Arabian Journal for Science and Engineering*, *46*(3), 4153–4162. <https://doi.org/10.1007/s13369-021-05412-1>

- Goodchild, M. F. (2011). Scale in GIS: An overview. *Geomorphology*, 130(1–2), 5–9. <https://doi.org/10.1016/j.geomorph.2010.10.004>
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. <https://doi.org/10.1016/J.ISPRSJPRS.2020.12.010>
- Kaur, S., Bansal, R. K., Mittal, M., Lalit, Goyal, M., Kaur, I., Amit Verma, Le, & Son, H. (2019). Mixed Pixel Decomposition Based on Extended Fuzzy Clustering for Single Spectral Value Remote Sensing Images. *Journal of the Indian Society of Remote Sensing*, 47. <https://doi.org/10.1007/s12524-019-00946-2>
- Konstantinidis, D., Argyriou, V., Stathaki, T., & Grammalidis, N. (2020). A modular CNN-based building detector for remote sensing images. *Computer Networks*, 168, 107034. <https://doi.org/10.1016/J.COMNET.2019.107034>
- Kundu, S., Maulik, U., & Mukhopadhyay, Anirban. (2021). A game theory-based approach to fuzzy clustering for pixel classification in remote sensing imagery. *Soft Computing*, 25, 5121–5129. <https://doi.org/10.1007/s00500-020-05514-2>
- Li, H., Tian, Y., Zhang, C., Zhang, S., & Atkinson, P. M. (2022). Temporal Sequence Object-based CNN (TS-OCNN) for crop classification from fine resolution remote sensing image time-series. *The Crop Journal*, 10(5), 1507–1516. <https://doi.org/10.1016/J.CJ.2022.07.005>
- Li, J., Hong, D., Gao, L., Yao, J., Zheng, K., Zhang, B., & Chanussot, J. (2022). Deep learning in multimodal remote sensing data fusion: A comprehensive review. *International Journal of Applied Earth Observation and Geoinformation*, 112, 102926. <https://doi.org/10.1016/J.JAG.2022.102926>
- Liu, C. C., Lin, T. C., Yuan, K. Y., & Chiueh, P. te. (2022). Spatio-temporal prediction and factor identification of urban air quality using support vector machine. *Urban Climate*, 41, 101055. <https://doi.org/10.1016/J.UCLIM.2021.101055>
- Londoño, L. A., & Valdés, J. C. (2012). *Geoestadística aplicada*. https://books.google.com/books/about/Geoestad%C3%ADstica_Aplicada.html?hl=es&id=YYwwLgEACAAJ
- Martínez, J., Pfeffer, K., & Baud, I. (2016). Factors shaping cartographic representations of inequalities. Maps as products and processes. *Habitat International*, 51, 90–102. <https://doi.org/10.1016/J.HABITATINT.2015.10.010>

- Martins, G. B., la Rosa, L. E. C., Happ, P. N., Filho, L. C. T. C., Santos, C. J. F., Feitosa, R. Q., & Ferreira, M. P. (2021). Deep learning-based tree species mapping in a highly diverse tropical urban setting. *Urban Forestry & Urban Greening*, *64*, 127241. <https://doi.org/10.1016/J.UFUG.2021.127241>
- Masser, I. (2001). Managing our urban future: The role of remote sensing and geographic information systems. *Habitat International*, *25*(4), 503–512. [https://doi.org/10.1016/S0197-3975\(01\)00021-2](https://doi.org/10.1016/S0197-3975(01)00021-2)
- Niu, F. (2022). A push-pull model for inter-city migration simulation. *Cities*, *131*, 104005. <https://doi.org/10.1016/J.CITIES.2022.104005>
- Ohana-Levi, N., Gao, F., Knipper, · Kyle, William, ·, Kustas, P., Anderson, M. C., del Mar Alsina, M., Luis, ·, Sanchez, A., & Karnieli, · Arnon. (2022). *Time-series clustering of remote sensing retrievals for defining management zones in a vineyard*. *40*, 801–815. <https://doi.org/10.1007/s00271-021-00752-0>
- Owusu, M., Kuffer, M., Belgiu, M., Grippa, T., Lennert, M., Georganos, S., & Vanhuyse, S. (2021). Towards user-driven earth observation-based slum mapping. *Computers, Environment and Urban Systems*, *89*, 101681. <https://doi.org/10.1016/J.COMPENVURBSYS.2021.101681>
- Rees, W. G. (2012). *Physical Principles of Remote Sensing*. <https://doi.org/10.1017/CBO9781139017411>
- Roy, B., & Kasemi, N. (2021). Monitoring urban growth dynamics using remote sensing and GIS techniques of Raiganj Urban Agglomeration, India. *The Egyptian Journal of Remote Sensing and Space Science*, *24*(2), 221–230. <https://doi.org/10.1016/J.EJRS.2021.02.001>
- Sadeghi, V., & Etemadfard, H. (n.d.). *Optimal cluster number determination of FCM for unsupervised change detection in remote sensing images*. <https://doi.org/10.1007/s12145-021-00757-5>/Published
- Sapucci, G. R., Rogério, ·, & Negri, G. (2019). *Hierarchical clustering and stochastic distance for indirect semi-supervised remote sensing image classification*. *1*, 272. <https://doi.org/10.1007/s42452-019-0278-x>
- Shawky, O. A., Hagag, A., El-Dahshan, E. S. A., & Ismail, M. A. (2020a). Remote sensing image scene classification using CNN-MLP with data augmentation. *Optik*, *221*, 165356. <https://doi.org/10.1016/J.IJLEO.2020.165356>

- Shawky, O. A., Hagag, A., El-Dahshan, E. S. A., & Ismail, M. A. (2020b). Remote sensing image scene classification using CNN-MLP with data augmentation. *Optik*, *221*, 165356. <https://doi.org/10.1016/J.IJLEO.2020.165356>
- Shen, Y., Liu, D., Zhang, F., & Zhang, Q. (2022). Fast and accurate multi-class geospatial object detection with large-size remote sensing imagery using CNN and Truncated NMS. *ISPRS Journal of Photogrammetry and Remote Sensing*, *191*, 235–249. <https://doi.org/10.1016/J.ISPRSJPRS.2022.07.019>
- Sonde, P., Balamwar, S., & Ochawar, R. S. (2020). Urban sprawl detection and analysis using unsupervised classification of high-resolution image data of Jawaharlal Nehru Port Trust area in India. *Remote Sensing Applications: Society and Environment*, *17*, 100282. <https://doi.org/10.1016/J.RSASE.2019.100282>
- Soni, A., Koner, R., & Villuri, V. G. K. (2022). Fusion of Dual-Scale Convolution Neural Network for Urban Building Footprints. *Ain Shams Engineering Journal*, *13*(3), 101622. <https://doi.org/10.1016/J.ASEJ.2021.10.017>
- Su, Y., Zhong, Y., Zhu, Q., & Zhao, J. (2021). Urban scene understanding based on semantic and socioeconomic features: From high-resolution remote sensing imagery to multi-source geographic datasets. *ISPRS Journal of Photogrammetry and Remote Sensing*, *179*, 50–65. <https://doi.org/10.1016/J.ISPRSJPRS.2021.07.003>
- Sudha, S. K., & Aji, S. (2022). An active learning method with entropy weighting subspace clustering for remote sensing image retrieval. *Applied Soft Computing*, *125*, 109107. <https://doi.org/10.1016/J.ASOC.2022.109107>
- Tortora, C., & Palumbo, F. (2022). Clustering mixed-type data using a probabilistic distance algorithm. *Applied Soft Computing*, *130*, 109704. <https://doi.org/10.1016/J.ASOC.2022.109704>
- UN HABITAT. (2016). *TEMAS HABITAT III 22-ASENTAMIENTOS INFORMALES*. chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://habitat3.org/wp-content/uploads/Issue-Paper-22_ASENTAMIENTOS-INFORMALES-SP.pdf
- Vijayalakshmi, S., Kumar, M., & Arun, M. (2021). A study of various classification techniques used for very high-resolution remote sensing [VHRRS] images. *Materials Today: Proceedings*, *37*(Part 2), 2947–2951. <https://doi.org/10.1016/J.MATPR.2020.08.703>
- Wang, J., & Biljecki, F. (2022). Unsupervised machine learning in urban studies: A systematic review of applications. *Cities*, *129*, 103925. <https://doi.org/10.1016/J.CITIES.2022.103925>

- Yang, M., Kong, B., Dang, R., & Yan, X. (2022). Classifying urban functional regions by integrating buildings and points-of-interest using a stacking ensemble method. *International Journal of Applied Earth Observation and Geoinformation*, 108, 102753. <https://doi.org/10.1016/J.JAG.2022.102753>
- Yao, Y., Yan, X., Luo, P., Liang, Y., Ren, S., Hu, Y., Han, J., & Guan, Q. (2022). Classifying land-use patterns by integrating time-series electricity data and high-spatial resolution remote sensing imagery. *International Journal of Applied Earth Observation and Geoinformation*, 106, 102664. <https://doi.org/10.1016/J.JAG.2021.102664>
- Yin, C., Meng, F., Yang, X., Yang, F., Fu, P., Yao, G., & Chen, R. (2022). Spatio-temporal evolution of urban built-up areas and analysis of driving factors —A comparison of typical cities in north and south China. *Land Use Policy*, 117, 106114. <https://doi.org/10.1016/J.LANDUSEPOL.2022.106114>
- Zhou, W., Ming, D., Lv, X., Zhou, K., Bao, H., & Hong, Z. (2020). SO-CNN based urban functional zone fine division with VHR remote sensing image. *Remote Sensing of Environment*, 236, 111458. <https://doi.org/10.1016/J.RSE.2019.111458>