

# Mapa de coberturas del suelo utilizando imágenes satelitales Sentinel-2 y Landsat-8 del municipio de Covarachía – Colombia

*Land covers map using Sentinel-2 and Landsat-8 satellite images of the municipality of Covarachía - Colombia*

Jose Leon Leon



Rubén Javier Medina



Diana Marcela Ovalle



**Cómo citar:** León León, J., Medina, R y Ovalle, D. (2021). Mapa de coberturas del suelo utilizando imágenes satelitales Sentinel-2 y Landsat-8 del municipio de Covarachía – Colombia. *Hashtag*, (19), 8-27



## Resumen:

La agricultura es uno de los campos en donde el uso de los suelos es de importancia, ya que tener la información adecuada permite evidenciar la gestión de los agroecosistemas, que es de importancia para mitigar impactos climáticos y ambientales (Rega *et al.*, 2020). Dada la diversidad de aplicaciones que necesitan información actualizada de la cobertura del suelo, es complicado tener soluciones a la totalidad de las necesidades a causa de la gran variedad de usuarios (Szantoi *et al.*, 2020). En ese orden, en este artículo se utilizan imágenes satelitales Sentinel-2 y Landsat-8 a las cuales se les aplican algoritmos clasificadores supervisados y no supervisados para generar un mapa de la cobertura del suelo del municipio de Covarachía, Colombia.

## Palabras clave:

clasificadores no supervisados, clasificadores supervisados, cobertura del suelo, imágenes satelitales

## Abstract

Agriculture is one of the fields in which the use of soils is of importance, since having adequate information makes it possible to demonstrate the management of agroecosystems that is of importance in mitigating climatic and environmental impacts (Rega *et al.*, 2020). Given the different applications that need updated information on land cover, it is difficult to have solutions to all the needs due to the great variety of users (Szantoi *et al.*, 2020). In this article, Sentinel-2 and Landsat-8 satellite images are used to which supervised and unsupervised classifying algorithms are applied to generate a map of the land cover of the municipality of Covarachía Colombia.

## Keywords:

ground cover, satellite images, supervised classifiers, unsupervised classifiers

## Introducción

Dada la diversidad de problemas climáticos que se presentan a nivel mundial, es importante realizar una gestión ambiental, en donde es necesario disponer de mapas de cobertura del suelo actualizados (Saah *et al.*, 2020), la construcción de estos mapas utiliza procesamiento de imágenes satelitales y aprendizaje automático (Stéphane *et al.*, 2020). Al realizar un mapa de coberturas se presentan algunos retos, empezando con las imágenes de entrada (o insumo principal), pues la calidad y resolución espacial pueden llegar a influir en los resultados finales al generar dichos mapas (García *et al.*, 2019). Otro desafío alude a los datos de referencia utilizados para el entrenamiento y la validación de los clasificadores supervisados y no supervisados (Szantoi *et al.*, 2020).

Al tener información actualizada de la cobertura del suelo, pueden estimarse incendios forestales (Vilar *et al.*, 2019); conocer los estudios climatológicos donde es relevante la correlación atmósfera-tierra (He *et al.*, 2017); analizar las interacciones que hay entre los diversos ecosistemas con la gestión ambiental (Kiswanto *et al.*, 2018); identificar los estudios sobre la dinámica de la cubierta del suelo (Li *et al.*, 2017) y la detección de cambios en la vegetación (Renza *et al.*, 2017). Asimismo, permite detectar el déficit de la producción agrícola de una región o zona (Pérez-Hoyos *et al.*, 2020), entre otros.

Para generar los mapas de coberturas del suelo se compararon los algoritmos de clasificación supervisados y no supervisados. Dentro de los algoritmos supervisados están: máxima probabilidad, mínima distancia y distancia de mahalanobis. Por su parte, en cuanto a los algoritmos no supervisados, se consideran: k-means y isodata.

Para realizar el mapa de coberturas se selecciona el municipio de Covarachía, del departamento de Boyacá (Colombia), donde se pueden encontrar cultivos de trigo y tabaco, entre otros (Alcaldía Municipal de Covarachía en Boyacá, 2020). Primero, se procede a realizar la descarga de las imágenes satelitales Landsat-8 y Sentinel-2 en las coordenadas 6°33'49.8 N 72°45'15.3 W y se recortan los polígonos donde ambos grupos de imágenes se interceptan.

El objetivo de este artículo es comparar los resultados de algoritmos de clasificación supervisados y no supervisados, para la generación de mapas de coberturas del municipio de Covarachía, haciendo uso de imágenes satelitales Sentinel-2 y Landsat-8, entre el periodo 5 de enero y el 16 de enero de 2016.

## Clasificación

En este documento se realizará una comparación entre algoritmos de clasificación supervisada y no supervisada. Dentro de los primeros están: máxima probabilidad, mínima distancia, distancia de mahalanobis y máquinas de soporte vectorial; mientras que, entre los algoritmos no supervisados, consideramos: k-means y isodata.

### Algoritmos de clasificación supervisada

En los algoritmos de clasificación supervisada el usuario debe especificar los diversos valores de píxeles o firmas espectrales que deben asociarse con cada clase (Humboldt State University, 2019). Esto se hace seleccionando sitios de muestra representativos a un tipo de cobertura conocido, llamados ROI o región de interés. Los ROI se entregarán como un requisito para los algoritmos de clasificación (Misra *et al.*, 2020).

Dentro de los algoritmos de clasificación supervisados se implementarán los siguientes:

**Máxima probabilidad.** Asume que las estadísticas para cada clase en cada banda se distribuyen normalmente y calcula la probabilidad de que un píxel dado pertenezca a una clase específica. Cada píxel se asigna a la clase que tiene la mayor probabilidad (es decir, la máxima probabilidad). Este es el valor predeterminado (Humboldt State University, 2019).

**Mínima distancia.** Emplea los vectores medios para cada clase y calcula la distancia euclidiana desde cada píxel desconocido hasta el vector medio para cada clase. Los píxeles se clasifican de acuerdo a la clase más cercana (Humboldt State University, 2019).

**Distancia de mahalanobis.** Se trata de un clasificador de distancia sensible a la dirección que usa estadísticas para cada clase. Es similar a la clasificación de máxima verosimilitud, pero supone que todas las covarianzas de clase son iguales y, por lo tanto, es un método más rápido. Todos los píxeles se clasifican según los datos de entrenamiento más cercanos (Humboldt State University, 2019).

### **Algoritmos de clasificación no supervisada.**

La clasificación no supervisada permite al usuario definir el número de clases y estas clases espectrales son creadas a partir de información numérica en los datos. Los algoritmos de agrupamiento se utilizan para determinar la agrupación estadística natural de los datos. Los píxeles se agrupan en función de su similitud espectral. Dentro de los algoritmos de clasificación no supervisados se implementarán los siguientes:

**K-mean.** Utiliza los datos de la clase inicial calculando la media de los datos que se encuentran uniformemente distribuidos para, posteriormente, agrupar de forma iterativa los píxeles en la clase más cercana, utilizando una técnica de distancia mínima. Cada iteración recalcula las medias de la clase y clasifica nuevamente los píxeles con respecto a las nuevas medias. Todos los píxeles se clasifican respecto a la clase más cercana; puede darse el caso donde hay datos que no se clasifican por no cumplir con criterios establecidos por el usuario (NV5 Geospatial, 2020).

**Isodata (Iterative Self-Organizing Data Analysis Technique).** La clase de cómputo ISODATA significa que – antes de agrupar iterativamente los píxeles contiguos– circula constantemente en el espacio de datos, utilizando enfoques de menor distancia. Cada iteración recalcula las medias y vuelve a clasificar los píxeles con respecto a las nuevas medias, mientras que en el enfoque K-Means, el número de grupos K sigue siendo el mismo durante toda la iteración. El algoritmo isodata permite que el número de clústeres se ajuste automáticamente durante la iteración, mediante la fusión de clústeres similares y la división de clústeres con grandes desviaciones estándar (Abbas *et al.*, 2016).

### **Coefficiente de precisión y capa**

El coeficiente de precisión es una métrica que permite evaluar el desempeño del algoritmo de clasificación y su valor se puede encontrar dividiendo el número de predicciones correctas entre el total de predicciones realizadas. No hay una tabla de referencia donde se categoricen los intervalos de precisión, pero en este artículo se puede utilizar la siguiente métrica: 0%-60% (bajo), 60%-80% (bueno) y superior al 80 %, muy bueno.

El coeficiente capa está relacionado con las capas de la red neuronal teniendo en cuenta el número de capas, tamaño de las capas y la tasa de aprendizaje.

## Materiales

Para realizar el mapa de coberturas del municipio de Covarachía, Colombia, es necesario descargar las imágenes satelitales Landsat-8 y Sentinel-2 de las coordenadas 6°33'49.8 N 72°45'15.3 W. Estas imágenes son necesarias para extraer los datos de entrenamiento y generar los mapas de coberturas.


Para combinar las imágenes y sus diferentes bandas hay que utilizar el programa Erdas, pues este permite realizar un layer stack, mostrando de una forma rápida y sencilla el resultado. La selección de bandas a combinar y el orden dependerá de las coberturas que se deseen identificar y dependiendo de si la imagen es Landsat-8, o Sentinel-2.

Los algoritmos de clasificación se implementaron en el programa Envi. Este software dispone de herramientas que facilitan la ejecución de los algoritmos de clasificación supervisados y no supervisados. Adicional a esto, facilita la construcción de la matriz de confusión; dicha matriz es la que determinará la eficacia de cada algoritmo de clasificación.

## Metodología


Para generar el mapa de cobertura se utiliza la combinación de bandas, que permite generar la imagen de verdadero color. Esta representación es la que se asemeja a la imagen que se captura utilizando la vista de una persona. Para generar una imagen de verdadero color, tanto con las imágenes Landsat-8 como Sentinel-2, es imperativo asignar por los canales RGB las bandas 432. En otras palabras, en el canal rojo se debe enviar la banda 4; en el canal verde la banda 3 y en el canal azul la banda 2. En la Figura 1a y 1b se observan las imágenes del verdadero color Sentinel-2 y las correspondientes a Landsat-8, respectivamente

**Figura 1a.** Sentinel-2, bandas (4,3,2)



**Fuente:** Satélite Sentinel-2

**Figura 1b.** Landsat-8, bandas (4,3,2)



**Fuente:** Satélite Landsat-8

Una vez generados los recortes de la región de interés, el segundo paso es definir las clases de las coberturas y las clases de referencia requeridos por los algoritmos de clasificación. Para identificar las coberturas se utiliza un método visual en las imágenes de verdadero color, aprovechando el conocimiento de la zona que tiene el autor. Adicionalmente, se realiza la identificación de coberturas analizando las diferentes combinaciones de bandas multispectrales.


En Gisadminbeers (2017) se pueden identificar diferentes coberturas, combinando las bandas, tanto en Sentinel-2 como Landsat-8. La primera clase a identificar son las zonas urbanas presentes en la región de interés. Para poder identificar esta cobertura, se utiliza la combinación de bandas Landsat-8 (7,6,4) y en Sentinel-2 (12,11,4) resaltando estas zonas con un color morado. En las Figuras 2a y 2b no se identifican zonas urbanas

**Figura 2a.** Sentinel-2, bandas (12,11,4)



**Fuente:** Satélite Sentinel-2

**Figura 2b.** Landsat-8, bandas (7,6,4)




**Fuente:** Satélite Landsat-8




Para la identificación de zonas con vegetación se utiliza la combinación de bandas Landsat-8 (5,4,3) y en Sentinel-2 (8,4,3) resaltando estas zonas con un color rojo, como puede verse a continuación

**Figura 3a.** Sentinel-2, bandas (8,4,3)



**Fuente:** Satélite Sentinel-2


**Figura 3b.** Landsat-8, bandas (5,4,3)



**Fuente:** Satélite Landsat-8


Para la identificación de zonas para uso agrícola, se utiliza la combinación de bandas Landsat-8 (6,5,2) y en Sentinel-2 (11,8A,2), resaltando estas zonas con un verde brillante –como se observa en las Figuras 4a y 4b– tanto en Sentinel-2 como en Landsat-8, las cuales son comunes con las zonas de vegetación encontradas en las Figuras 5a y 5b

**Figura 4a.** Sentinel-2, bandas (11,8A,2)



**Fuente:** Satélite Sentinel-2

**Figura 4b.** Landsat-8, bandas (6,5,2)




**Fuente:** Satélite Landsat-8

Para diferenciar tierra y agua, se utiliza la combinación de bandas Landsat-8 (5,6,4) y en Sentinel-2 (8A,11,4) resaltando estas zonas de agua con un color rosado brillante (como lo muestran las Figuras 5a y 5b). Tanto en Sentinel-2 como en Landsat-8 se identifican zonas con agua; pero no hay presentes nubes en la imagen Landsat-8, debido a eso la clase de nubes se creará para la clasificación de las imágenes Sentinel-2




**Figura 5a.** Sentinel-2, bandas (8A,11,4)



**Fuente:** Satélite Sentinel-2

**Figura 5b.** Landsat-8, bandas (5,6,4)



**Fuente:** Satélite Landsat-8

En la Tabla 1 se relacionan las clases seleccionadas para generar el mapa de cobertura. La clase de zona urbana no se tendrá en cuenta, dado que no se encontró este tipo de coberturas en las Figuras 2a y 2b. Se tendrá una clase de vegetación de uso agrícola y suelo sin vegetación, que se visualiza en las Figuras 3 y 4. Posteriormente, se presentan dos clases más: cuerpo de agua, que se identifica en la Figura 5 con un color rosado, y nubes, en color blanco; cabe aclarar que las nubes solo están presentes en las imágenes Sentinel-2; en razón a eso, no se tendrán en cuenta esta clase en el mapa de cobertura para Landsat-8.




Tabla 1. *Definición de clases*

Nombre de la clase	Color
<i>Vegetacion</i>	Verde oscuro
<i>Ref_vegetacion</i>	Verde claro
<i>Suelo_descubierto</i>	Cafe
<i>Ref_suelo_descubierto</i>	Amarillo
<i>Agua</i>	Azul oscuro
<i>Ref_agua</i>	Azul claro
<i>Nubes</i>	Gris
<i>Ref_nubes</i>	Blanco

**Fuente:** Elaboración propia


En las Figuras 6a y 6b se pueden ver las clases definidas en la Tabla 1, para las imágenes satelitales Sentinel-2 y Landsat-8. Luego, se procede a realizar la clasificación y generar el mapa de coberturas, utilizando los algoritmos supervisados y no supervisados, realizando una comparación de eficiencia entre algoritmos, según los resultados de la matriz de confusión obtenida del mapa de cobertura con las clases definidas.

**Figura 6a.** ROI Sentinel-2



**Fuente:** Satélite Sentinel-2

**Figura 6b.** ROI Landsat-8, bandas



**Fuente:** Satélite Landsat-8


## **Resultados**

En esta sección se evidencian los mapas de coberturas resultantes de implementar los algoritmos de clasificación supervisados y no supervisados, con las clases seleccionadas en las imágenes satelitales Landsat-8 y Sentinel-2, para evaluar la eficacia de la clasificación. También se genera la matriz de confusión con la cual se mide la efectividad del mapa de coberturas resultante.

### **Mapa de cobertura Sentinel-2**

Se genera el mapa de cobertura implementando el algoritmo de clasificación supervisada a máxima probabilidad con la imagen Sentinel-2; las clases se pueden consultar en la Tabla 1 y los ROI se observan en la Figura 6a. En la Figura 7 se observa el mapa de cobertura resultante

**Figura 7.** Máxima probabilidad Sentinel-2



**Fuente:** Elaboración propia, a partir de Satélite Sentinel-2

La matriz de confusión del mapa de coberturas de la Figura 7 se observa en la Tabla 2. Hay que advertir que se obtuvo un coeficiente kappa 0.6992 con un porcentaje de precisión general de 92.82 %


**Tabla 2.** Matriz de confusión máxima probabilidad Sentinel-2

Clase	Ref_vegetacion	Ref_Agua	Ref_suelo_desnudo	Ref_nubes	Total
Vegetación	96.79	0	32.90	0	87.19
Agua	0	95.90	0	0.22	0.44
Suelo_descubierto	3.21	0	67.10	0	11.72
Nubes	0	4.10	0	99.78	0.64
Total	100	100	100	100	100

**Fuente:** Elaboración propia

Se genera el mapa de cobertura implementando el algoritmo de clasificación supervisada a mínima distancia con la imagen Sentinel-2. En la siguiente Figura se observa el mapa de cobertura resultante

**Figura 8.** Mínima distancia Sentinel-2



**Fuente:** Elaboración propia a partir de Satélite Sentinel-2

La matriz de confusión del mapa de coberturas de la Figura 8 se observa en la Tabla 3. Se obtuvo un coeficiente kappa 0.4551 con un porcentaje de precisión general de 89.82 %


Tabla 3. Matriz de confusión mínima distancia Sentinel-2

Clase	Ref_vegetacion	Ref_suelo_desnudo	Ref_agua	Ref_nubes	Total
Vegetacion	99.65	68.15	0	0	94.36
Suelo_cubierto	0.35	31.85	0	0.08	4.57
Agua	0	0	67.74	96.90	0.91
Nubes	0	0	32.26	3.02	0.17
Total	100	100	100	100	100

Fuente: Elaboración propia

Se genera el mapa de cobertura implementando el algoritmo de clasificación supervisada a distancia de mahalanobis con la imagen Sentinel-2. En la Figura 9 se observa el mapa de cobertura resultante

Figura 9. Distancia de mahalanobis Sentinel-2



Fuente: Elaboración propia a partir de Satélite Sentinel-2

La matriz de confusión del mapa de coberturas de la Figura 9 se observa en la Tabla 4. Se obtuvo un coeficiente kappa 0.3130 con un porcentaje de precisión general de 86.59 %

Tabla 4. Matriz de confusión distancia de mahalanobis Sentinel-2


Clase	Ref_vegetacion	Ref_suelo_desnudo	Ref_agua	Ref_nubes	Total
Vegetacion	96.66	78.54	0	0	93.19
Suelo_cubierto	3.34	21.46	0	0.08	5.73
Agua	0	0	91.96	0.11	0.42
Nubes	0	0	8.04	99.81	0.66
Total	100	100	100	100	100

Fuente: Elaboración propia



Para la clasificación no supervisada se implementó el clasificador k-means, dando como resultado el mapa de coberturas de la Figura 10. Se eligió trabajar con 4 clases en total, ya que estas son las que se identificaron en la Tabla 1. El número de iteraciones se delimitó como la mitad más 1 del número de clases, para este caso, 3.

**Figura 10.** K-means Sentinel-2



**Fuente:** Elaboración propia, a partir de Satélite Sentinel-2

La matriz de confusión del mapa de coberturas de la Figura 10 se observa en la Tabla 5 y se obtuvo un coeficiente kappa 0.75 con un porcentaje de precisión general de 94.21 %. Para este caso, el clasificador solo identificó la cobertura de vegetación en color verde claro, suelo descubierto en color azul oscuro y una clase de color amarillo para cuerpos de agua y nubes. La cuarta clase de color rojo no corresponde a ninguna cobertura, es por ello que, de las 4 clases que se configuraron, solo 3 corresponden a coberturas en el mapa.


Tabla 5. *Matriz de confusión K-means Sentinel-2*

<b>Clase</b>	<i>Ref_vegetacion</i>	<i>Ref_suelo_desnudo</i>	<i>Ref_nubes</i>	<i>Total</i>
<i>Vegetacion</i>	96.94	23.48	0	86.46
<i>Suelo_cubierto</i>	3.06	76.51	0	12.91
<i>Nubes</i>	0	0	100	0.63
<i>Total</i>	100	100	100	100

Fuente: Elaboración propia

El mapa de coberturas utilizando el clasificador isodata se observa en la Figura 11. El mínimo de clases se configuró en 3 y el máximo en 4. Tres para las iteraciones, como en el algoritmo k-means. En este caso, también detectó 3 clases para coberturas y la cuarta es una zona que no corresponde a una cobertura. Se tiene color verde para vegetación, color azul oscuro para suelo descubierto y amarillo para nubes y cuerpo de agua.

**Figura 11.** Isodata Sentinel-2



**Fuente:** Elaboración propia a partir de Satélite Sentinel-2

La matriz de confusión del mapa de coberturas de la Figura 11 se observa en la Tabla 6. Este clasificador obtuvo un coeficiente kappa 0.277 con un porcentaje de precisión general de 88.41 %.

**Tabla 6.** Matriz de confusión isodata Sentinel-2


Clase	Ref_vegetacion	Ref_suelo_desnudo	Ref_nubes	Total
Vegetacion	99.94	85.74	0	97.40
Suelo_cubierto	0.06	14.26	0	1.97
Nubes	0	0	100	0.63
Total	100	100	100	100

**Fuente:** Elaboración propia

### Mapa de cobertura Landsat-8

Se genera el mapa de cobertura implementando el algoritmo de clasificación supervisada a máxima probabilidad, con la imagen verdadero color Landsat-8. Las clases se pueden consultar en la Tabla 1 y los ROI se observan en la Figura 6b. En la Figura 12 se observa el mapa de cobertura resultante

**Figura 12.** Máxima probabilidad Landsat-8



**Fuente:** Elaboración propia a partir de Satélite Landsat-8

La matriz de confusión del mapa de coberturas de la Figura 12 se observa en la Tabla 7. Se obtuvo un coeficiente kappa 0.2193 con un porcentaje de precisión general de 43.55 %


**Tabla 7.** Matriz de confusión máxima probabilidad Landsat-8

Clase	Ref_vegetacion	Ref_Agua	Ref_suelo_desnudo	Total
Vegetacion	25.55	0	0.09	22.52
Agua	14.68	99.89	0.73	18.05
Suelo_descubierto	56.77	0.11	99.18	59.43
Total	100	100	100	100

Fuente: Elaboración propia

Se genera el mapa de cobertura implementando el algoritmo de clasificación supervisada de mínima distancia con la imagen Landsat-8. En la Figura 13 se observa el mapa de cobertura resultante.

**Figura 13.** Mínima distancia Landsat-8



Fuente: Elaboración propia a partir de Satélite Landsat-8

La matriz de confusión del mapa de coberturas de la Figura 13 se observa en la Tabla 8. Se obtuvo un coeficiente kappa 0.2468 con un porcentaje de precisión general de 74.78 %.


**Tabla 8.** Matriz de confusión mínima distancia Landsat-8

Clase	Ref_vegetacion	Ref_agua	Ref_suelo_desnudo	Total
Vegetacion	86.19	0	91.78	81.52
Agua	0	88.29	0	5.63
Suelo_cubierto	13.81	11.71	8.22	12.85
Total	100	100	100	100

Fuente: Elaboración propia

Se genera el mapa de cobertura implementando el algoritmo de clasificación supervisada de distancia de mahalanobis con la imagen Landsat-8. En la Figura 14 se observa el mapa de cobertura resultante.

**Figura 14.** Distancia de mahalanobis Landsat-8



**Fuente:** Elaboración propia a partir de Satélite Landsat-8

La matriz de confusión del mapa de coberturas de la Figura 14 se observa en la Tabla 9. Se obtuvo un coeficiente kappa 0.69 con un porcentaje de precisión general de 86.77 %.

**Tabla 9.** Matriz de confusión distancia de mahalanobis Landsat-8


Clase	<i>Ref_vegetacion</i>	<i>Ref_suelo_desnudo</i>	<i>Ref_agua</i>	<i>Total</i>
<i>Vegetacion</i>	84.56	0.99	2.89	66.99
<i>Suelo_cubierto</i>	15.44	99.01	11.40	27.55
<i>Agua</i>	0	0	85.71	5.46
<i>Total</i>	100	100	100	100

**Fuente:** Elaboración propia

Para la clasificación no supervisada se implementó el clasificador k-means, dando como resultado el mapa de coberturas de la Figura 15. Se eligió trabajar con 3 clases en total, que son las que se identificaron en la Tabla 1, a excepción de las clases de nubes. El número de iteraciones se delimitó como la mitad más 1 del número de clases, para este caso 2.



**Figura 15.** K-means Landsat-8



**Fuente:** Elaboración propia a partir de Satélite Landsat-8

La matriz de confusión del mapa de coberturas de la Figura 15 se observa en la Tabla 10. se obtuvo un coeficiente kappa 0.69 con un porcentaje de precisión general de 84.99 %. En este caso, el clasificador solo identificó la cobertura de vegetación en color verde claro y suelo descubierto en color azul oscuro. La tercera clase de color rojo no corresponde a ninguna cobertura, es por ello que de las 3 clases que se configuraron, solo 2 corresponden a coberturas en el mapa.


**Tabla 10.** Matriz de confusión K-means Landsat-8

Clase	Ref_vegetacion	Ref_suelo_desnudo	Total
Vegetacion	84.24	14.14	51.77
Suelo_cubierto	15.76	85.86	48.23
Total	100	100	100

**Fuente:** Elaboración propia

El mapa de coberturas utilizando el clasificador isodata se observa en la Figura 16. El mínimo de clases se configuró en 2 y el máximo en 3. En cuanto a las iteraciones, al igual que en el algoritmo k-means, se seleccionó el número 2. En este caso, también detectó 2 clases para coberturas y la tercera es una zona que no corresponde a una cobertura: color verde para vegetación, color azul oscuro para suelo descubierto.

Figura 16. Isodata Landsat-8



Fuente: Elaboración propia a partir de Satélite Landsat-8

La matriz de confusión del mapa de coberturas de la Figura 16 se observa en la Tabla 11. Este clasificador obtuvo un coeficiente kappa 0.12 con un porcentaje de precisión general de 77.31 %.

Tabla 11. Matriz de confusión isodata Landsat-8

Clase	Ref_vegetacion	Ref_suelo_desnudo	Total
Vegetacion	85.25	71.27	83.29
Suelo_cubier-to	14.75	28.73	16.71
Total	100	100	100

Fuente: Elaboración propia

## Conclusiones

Los algoritmos de clasificación supervisados facilitan tener un mejor resultado, permitiendo una selección de ROI detallada con ayuda de las diferentes combinaciones de bandas que, además, permiten una mejor identificación de coberturas. Respecto a los algoritmos no supervisados, no identifica ciertas coberturas identificadas en los clasificadores.

De los algoritmos supervisados, el que mejor porcentaje obtuvo en las imágenes Sentinel-2 fue Máxima probabilidad, con 92.82 % y, en el caso de Landsat-8, el clasificador Distancia de mahalanobis, con un 86.77 %. Dentro de los algoritmos no supervisados, el que mejor porcentaje obtuvo en las imágenes Sentinel-2 y Landsat-8 fue el clasificador K-means con 94.21 % y 84.99 %, respectivamente.

Según la clasificación de los coeficientes kappa encontrada en Fistera (2020), el algoritmo que presentó fuerza de concordancia pobre fue Isodata, con la imagen Landsat-8. Ningún algoritmo tuvo la fuerza de concordancia muy buena. Pero, K-means presentó una fuerza de concordancia buena con ambas imágenes, máxima probabilidad con la imagen sentinel 2 y mahalanobis con la imagen Landsat-8.

## Referencias

- Abbas, A., Minallh, N., Ahmad, N., Rehman, S., y Khan, M. (2016). K-Means and ISODATA Clustering Algorithms for Landcover Classification Using Remote Sensing. *ResearchGate*, 48, 315-318. [https://www.researchgate.net/publication/303971825\\_K-Means\\_and\\_ISODATA\\_Clustering\\_Algorithms\\_for\\_Landcover\\_Classification\\_Using\\_Remote\\_Sensing](https://www.researchgate.net/publication/303971825_K-Means_and_ISODATA_Clustering_Algorithms_for_Landcover_Classification_Using_Remote_Sensing)
- Fisterra. (2020). Medidas de concordancia: El índice Kappa. <https://www.fisterra.com/formacion/metodologia-investigacion/medidas-concordancia-indice-kappa/>
- García, D., Camacho, M., y Paegelow, M. (2019). Sensitivity of a common Land Use Cover Change (LUCC) model to the Minimum Mapping Unit (MMU) and Minimum Mapping Width (MMW) of input maps. *Computers, Environment and Urban Systems*, 78, 101389. <https://doi.org/10.1016/j.compenvurbsys.2019.101389>
- Gisadminbeers. (26 de marzo de 2017). Combinaciones RGB de imágenes satélite Landsat y Sentinel. *Gis&Beers*. <http://www.gisandbeers.com/combinacion-de-imagenes-satelite-landsat-sentinel-rgb/>
- He, Y., Lee, E., y Warner, T. A. (2017). A time series of annual land use and land cover maps of China from 1982 to 2013 generated using AVHRR GIMMS NDVI3g data. *Remote Sensing of Environment*, 199, 201-217. <https://doi.org/10.1016/j.rse.2017.07.010>
- Kiswanto, Tsuyuki, S., Mardiany, y Sumaryono. (2018). Completing yearly land cover maps for accurately describing annual changes of tropical landscapes. *Global Ecology and Conservation*, 13. <https://doi.org/10.1016/j.gecco.2018.e00384>
- NV5 Geospatial. (2020). *K-Means*. <https://www.harrisgeospatial.com/docs/KMeansClassification.html>
- Li, X., Ling, F., Foody, G., Ge, Y., Zhang, Y., y Du, Y. (2017). Generating a series of fine spatial and temporal resolution land cover maps by fusing coarse spatial resolution remotely sensed images and fine spatial resolution land cover maps. *Remote Sensing of Environment*, 196, 293-311. <https://doi.org/10.1016/j.rse.2017.05.011>
- Misra, M., Kumar, D., y Shekhar, S. (2020). Assessing Machine Learning Based Supervised Classifiers For Built-Up Impervious Surface Area Extraction From Sentinel-2 Images. *Urban Forestry & Urban Greening*, 53. <https://doi.org/10.1016/j.ufug.2020.126714>
- Nuestro municipio - Alcaldía Municipal de Covarachía en Boyacá. (2020). <http://www.covarachia-boyaca.gov.co/municipio/nuestro-municipio>
- Pérez, A., Udías, F., y Rembold, F. (2020). Integrating Multiple Land Cover Maps through a Multi-Criteria Analysis to Improve Agricultural Monitoring in Africa. *International Journal of Applied Earth Observation and Geoinformation*, 88. <https://doi.org/10.1016/j.jag.2020.102064>
- Rega, C., Short, C., Pérez, M., y Paracchini, M. (2020). A classification of European agricultural land using an energy-based intensity indicator and detailed crop description. *Landscape and Urban Planning*, 198. <https://doi.org/10.1016/j.landurbplan.2020.103793>

- Renza, D., Martinez, E., Molina, I., y Ballesteros, D. (2017). Unsupervised change detection in a particular vegetation land cover type using spectral angle mapper. *Advances in Space Research*, 59(8), 2019-2031. <https://doi.org/10.1016/j.asr.2017.01.027>
- Saah, D., Tenneson, K., Poortinga, A., Nguyen, Q., Chishtie, F., ... Ganz, D. (2020). Primitives as building blocks for constructing land cover maps. *International Journal of Applied Earth Observation and Geoinformation*, 85. <https://doi.org/10.1016/j.jag.2019.101979>
- Satélite Sentinel-2. Flota de satélites europeos de vigilancia medioambiental del programa Copernicus
- Satélite Landsat-8. Satélite estadounidense para estudios cartográficos y de características de temperatura de la superficie
- Stéphane, D., Laurence, D., Raffaele, G., Valérie, A., y Eloise, R. Land Cover Maps of Antananarivo (Capital of Madagascar) Produced by Processing Multisource Satellite Imagery and Geospatial Reference Data. Data in Brief, 31. <https://doi.org/10.1016/j.dib.2020.105952>
- Humboldt State University. (2019). Supervised Classification. [http://gsp.humboldt.edu/olm/Courses/GSP\\_216/lessons/Classification/supervised.html](http://gsp.humboldt.edu/olm/Courses/GSP_216/lessons/Classification/supervised.html)
- Szantoi, Z., Geller, G., Tsendbazar, N., See, L., Griffiths, P., Fritz, S., Gong, P., Herold, M., Mora, B., y Obregón, A. (2020). Addressing the need for improved land cover map products for policy support. *Environmental Science & Policy*, 112, 28-35. <https://doi.org/10.1016/j.envsci.2020.04.005>
- Vilar, L., Garrido, J., Echavarría, P., Martínez, J., y Martín, M. (2019). Comparative analysis of CORINE and climate change initiative land cover maps in Europe: Implications for wildfire occurrence estimation at regional and local scales. *International Journal of Applied Earth Observation and Geoinformation*, 78, 102-117. <https://doi.org/10.1016/j.jag.2019.01.019>