

Identificación de áreas erosionadas y en riesgo de erosión utilizando imágenes Landsat 8 OLI y Sentinel-2, procesamiento digital y SIG

Cristopher Edgar Camargo Roa

Docente

Universidad de Los Andes, Departamento de Ordenación de Cuencas Hidrográficas, Venezuela.

Carlos Eduardo Pacheco Angulo

Docente

Universidad de Los Andes, Escuela Técnica Superior Forestal, Departamento de Departamento de Bosques, Venezuela.

Tatiana Gómez-Orgulloso

Investigadora independiente.

Roberto López-Falcón

Docente

Universidad de Los Andes, Centro Interamericano de Desarrollo e Investigación Ambiental y Territorial, Venezuela.

Sergio Alberto Monjardín-Armenta

Docente

Universidad Autónoma de Sinaloa, Facultad de Ciencias de La Tierra y el Espacio, México.

Resumen

El objetivo de esta investigación fue identificar y comparar Áreas Erosionadas y en Riesgo De Erosión (EAER, por sus siglas en inglés) como indicadores de degradación de suelos por erosión hídrica en una cuenca hidrográfica empleando imágenes Landsat 8 OLI y Sentinel-2. Para ello, se emplearon técnicas de procesamiento digital y Sistemas de Información Geográfica (SIG), enfocándose en los datos espectrales de reflectancia de imágenes satelitales. El estudio implicó estimaciones del Riesgo Potencial de Erosión Hídrica (RPEH), y generación de cartografías EAER a partir del cálculo de distancia espectral euclidiana a suelos desnudos y de una técnica de percepción remota seleccionada mediante regresión lineal. Se determinaron curvas ROC (Características Operativas del Receptor) para definir umbrales de clasificación, los cuales fueron validados mediante clasificaciones supervisadas y asociados a valores de RPEH. Los resultados indican que los EAER1 identificaron más áreas erosionadas que los EAER2. De igual modo, se evidenció que los resultados

Citación sugerida:

Camargo Roa, C.E.; Pacheco Angulo, C.E.; Gómez-Orgulloso, T.; López-Falcón, R.; Monjardín-Armenta, S.A. (2024). Identificación de áreas erosionadas y en riesgo de erosión utilizando imágenes Landsat 8 OLI y Sentinel-2, rocesamiento digital y SIG. Revista De Ciencias, 27(2). <https://doi.org/10.25100/rc.v27i2.13572>

Recibido: 17-02-2024

Aceptado: 22-08-2024

ORCID Cristopher Edgar

Camargo

0000-0003-1867-4591

ORCID Carlos Eduardo

Pacheco

0000-0001-8724-9287

ORCID Tatiana Gómez-

Orgulloso

0000-0002-5336-9587

ORCID Roberto López-

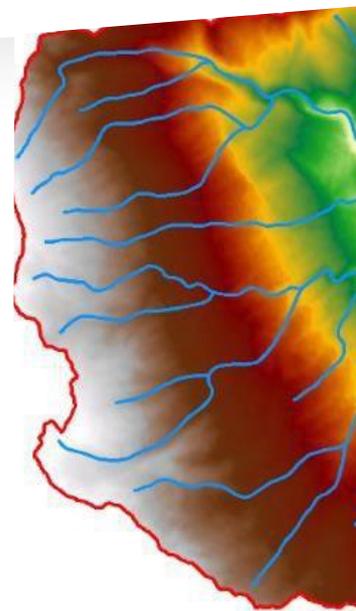
Falcón

0000-0001-9666-0377

Sergio Alberto

Monjardín-Armenta5

0000-0002-4890-6798



derivados de Sentinel-2 tuvieron mayores aciertos que los de Landsat 8. El análisis de RPEH, además de las cartografías EAER desarrolladas y otros datos y criterios, podrían ayudar a considerar medidas necesarias de conservación de suelos.

Palabras y frases clave: distancia espectral euclidiana; procesamiento digital de imágenes; máxima verosimilitud.

Identification of eroded and erosion risk areas using Landsat 8 and Sentinel 2 images, digital processing and GIS

Abstract

The aim of this research was to identify eroded areas and areas at risk of erosion (EAER) as indicators of soil degradation by water erosion in a watershed using Landsat 8 OLI and Sentinel-2 images. To this effect, digital processing techniques and geographic information systems (GIS) were used, focusing on spectral reflectance data from satellite imagery. This study involved estimating the potential water erosion risk (PWER) and mapping eroded, and erosion risk areas (EAER) based on calculating the spectral Euclidean distance to bare soils and a remote sensing technique, which was selected via linear regression. Receiver operating characteristics (ROC) curves were determined to define classification thresholds, validated using supervised classification and associated with PWER values. The results indicate that the EAER₁ identified more eroded areas than the EAER₂. Similarly, it was evident that the results derived from Sentinel-2 were more successful than Landsat 8. The PWER analysis, in addition to the EAER mapping, developed other data and criteria, such as minimum area size of interest, which could help to consider necessary soil conservation measures.

Keywords: spectral Euclidean distance; digital image processing; maximum likelihood.

1. Introducción

La erosión hídrica, proceso de degradación del suelo que también se considera un riesgo ambiental ⁽¹⁻²⁾, es ocasionada por las precipitaciones al caer sobre terrenos desnudos vulnerables, y que en su escurrimiento por las laderas arrastran el suelo para depositarlo en zonas bajas o enlodar y obstruir cuerpos de agua ⁽³⁻⁴⁾ (p. ej., se estima que la erosión hídrica transporta 23-42 Mg de N y entre 15-26 Mg de P fuera de las tierras agrícolas a nivel global) ⁽⁵⁾. Ello la convierte en el principal proceso de degradación de tierras, al afectar de forma cuantitativa y cualitativa el volumen enraizable de los suelos destinados a la agricultura ⁽⁶⁾ y al contribuir en el descenso de muchos otros servicios ecosistémicos fundamentales ⁽⁷⁻⁸⁾. Por ello, a la luz de la continua expansión de la población mundial, se ha vuelto cada vez más crucial comprender y abordar los peligros asociados a la erosión del suelo ⁽⁹⁾.

Una forma de observar la erosión hídrica es utilizar imágenes multiespectrales obtenidas por sensores remotos ⁽¹⁰⁾. Desde esta perspectiva, los suelos erosionados se singularizan por presentar una respuesta espectral similar a los suelos desnudos, es decir, mucho más uniforme que la de vegetación, que presenta una curva de reflectividad más plana ⁽¹¹⁾, lo que puede señalar la existencia de suelos o afloramientos de material parental desnudos, como un indicador efectivo de áreas sujetas a erosión ⁽¹²⁾. Debido a esto, se hacen necesarias las técnicas de procesamiento digital y procedimientos en Sistemas de Información Geográfica (SIG), los cuales permiten obtener la distribución espacial y temporal de los diversos factores involucrados y sus clasificaciones ⁽¹³⁾. Sobre estos resultados, también se requieren análisis visuales y estadísticos para comprender y validar la cartografía producida y cuyo objetivo es obtener indicadores más precisos y fiables ⁽¹⁰⁾.

Algunas técnicas de procesamiento digital (o percepción remota), se centran en la calidad visual, al tratar de mejorar la ubicación de los datos que se analizan, de tal forma que sean más evidentes los rasgos de interés, ejemplos de ello: expansión del contraste, composiciones coloreadas y filtraje ^(11, 14). Otras, buscan generar variables continuas, como los Índices de Vegetación (IV), que han probado ser útiles para evaluar degradación de tierras, y entre ellos erosión ⁽¹⁵⁾ a partir de su transformación a valores de Productividad Primaria Neta (PPN) ⁽¹⁶⁾, lo que ha conllevado a su uso más frecuente como indicador cuantitativo de la función de los ecosistemas ⁽¹⁷⁾. Asimismo, se han utilizado para monitorear vegetación en zonas áridas y semiáridas ⁽¹⁸⁾, y generar el factor “C” para modelos como USLE o RUSLE ⁽¹⁹⁻²⁰⁾.

De igual forma se han generado otras técnicas como: i) Índices de Suelos (IS) empleados para estimar tipos de degradación de suelos ^(15, 21), ii) Análisis de Componentes Principales (ACP) para discriminar tipos de suelos desnudos o deslizamientos ⁽²²⁻²³⁾, y iii) Análisis de Mezclas Espectrales (ALME) para cartografiar también factor “C” o determinar suelos desnudos y con ello, establecer indicadores de vulnerabilidad ⁽²⁴⁾. En este orden de ideas, todas estas técnicas pueden ser usadas como pasos previos para destacar erosión y permitir posteriormente su clasificación semiautomatizada para obtener cartografía de riesgos ⁽²⁾. Estas técnicas también buscan superar la tediosa tarea de interpretar visualmente imágenes satelitales y el considerable tiempo requerido para desarrollarla ⁽²⁵⁾.

Haciendo especial énfasis en cartografía de riesgos de erosión, donde usualmente se indica la probabilidad relativa de que esta ocurra en una cierta área en comparación a otras ⁽²⁶⁻²⁷⁾, esta puede dividirse en potencial, definido como la máxima pérdida de suelo posible en ausencia de cobertura vegetal y prácticas conservacionistas, es decir, considerando solamente la interacción de los factores físicos de la tierra: erosionabilidad del suelo, erosividad de la lluvia y topografía, y el actual, determinado a partir de la sumatoria del factor coberturas/ usos de la tierra a los previos ⁽²⁸⁾. De su comparación, el primero suele resultar sustancialmente más alto que el segundo ⁽²⁹⁾.

Por tales razones, ha resultado evidente la importancia de las técnicas de procesamiento digital para obtener cartografía de erosión y su riesgo, de igual modo, han sido valiosas para generar cartografía de degradación del suelo en estudios de cambio climático. Esto ha quedado demostrado en productos globales como la valoración de degradación de tierras (GLADA) ⁽³⁰⁾, en regionales, con el modelamiento del riesgo de erosión en Europa ⁽³¹⁾ y en nacionales, con el atlas de pérdida de suelos en Malawi ⁽⁴⁾. Igualmente, algunas de estas técnicas, han sido empleados para monitorear cambios de cobertura o PPN, planteados dentro del análisis de la Neutralidad de la Degradación de Tierras (NDT) ⁽¹⁷⁾, cuyo Objetivo de Desarrollo Sostenible (ODS) para el año 2030, es luchar contra la desertificación, rehabilitar tierras y suelos degradados y procurar un mundo con “degradación neutra” del suelo ⁽³²⁾.

Identificar áreas erosionadas y en riesgo de erosión, permite también, al cruzarse con mapas de densidad poblacional, acciones de los entes gubernamentales para

iniciar su rehabilitación y protección, realizar planificación del territorio para el desarrollo socioeconómico ambientalmente sostenible y determinar áreas susceptibles a procesos en ladera ^(15, 33). Aunado a ello, toda acción que se lleve a cabo para abordar la degradación de suelos puede contribuir simultáneamente a los objetivos de lucha contra el cambio climático, preservar la diversidad biológica y los ODS ⁽¹⁷⁾.

De acuerdo a las ideas expuestas anteriormente, el objetivo principal de este estudio fue obtener cartografía de áreas erosionadas y en riesgo empleando técnicas de percepción remota y procedimientos SIG sobre datos de imágenes Landsat 8 OLI y Sentinel-2, puesto que muchos de los modelos que se han desarrollado para estimarla, no pueden ejecutarse adecuadamente por falta de datos para completar sus parámetros; ejemplos: erosividad de la lluvia, que requiere registros pluviográficos continuos de lluvias diarias sobre períodos de varios años o erosionabilidad del suelo, que amerita propiedades como estructura y permeabilidad, entre otros, que, en la práctica, especialmente en muchas partes del mundo, suelen ser escasos o inexistentes ^(3, 34).

Todos los resultados se obtuvieron en una cuenca situada en un ambiente semiárido, espacio donde los suelos suelen destacar susceptibilidad a erosión hídrica ⁽³⁵⁾ y posteriormente fueron comparados entre sí, a fin de determinar los mejores resultados.

2. Materiales y métodos

Área de estudio

La cuenca Quebrada Parada se ubica entre 72° 14' 8,902" y 72° 19' 49,652" O y 7° 52' 1,798" y 7° 57' 28,386" N. Político-administrativamente pertenece al municipio Lobatera (estado Táchira, Venezuela), con una extensión de 68,03 km² y una altitud comprendida entre 891 y 2063 m. Su hidrología presenta una red de drenaje dendrítico al sureste y subdentrítico al noreste, este último patrón resultado del efecto de laderas excepcionalmente empinadas ⁽³⁶⁾; pertenece a la cuenca del río Lobaterita, el cual desemboca en el río Grita, formando parte a su vez de la vertiente del Lago de Maracaibo ⁽³⁷⁾ (Figura 1).

Según el modelo bioclimático de zonas de vida de Holdridge ^(38, 39), la cuenca en su mayoría es “Bosque Seco Tropical” (BST), propio de una provincia de humedad semiárida y “Bosque Húmedo Subtropical” (BHST), ajustado a una provincia de humedad subhúmeda, los cuales se ubican en el filo de Potrero Grande y el cerro La Mantellina, principalmente. Especies representativas de la primera zona de vida son; *Prosopis juliflora* (Sw.) DC. (Cují Yaque), *Tecoma stans* (L.) C. Juss. ex Kunth (Fresnillo), *Opuntia elatior* Mill (Cacto) y *Mammillaria mammillaris* (L.) H. Karst (Cacto) y de la segunda: *Cecropia peltata* L. (Yagrumo), *Cyathea* sp. (helecho arborescente), *Cedrela Psidium caudatum* Mc Vaugh (Cívaro), entre otras.

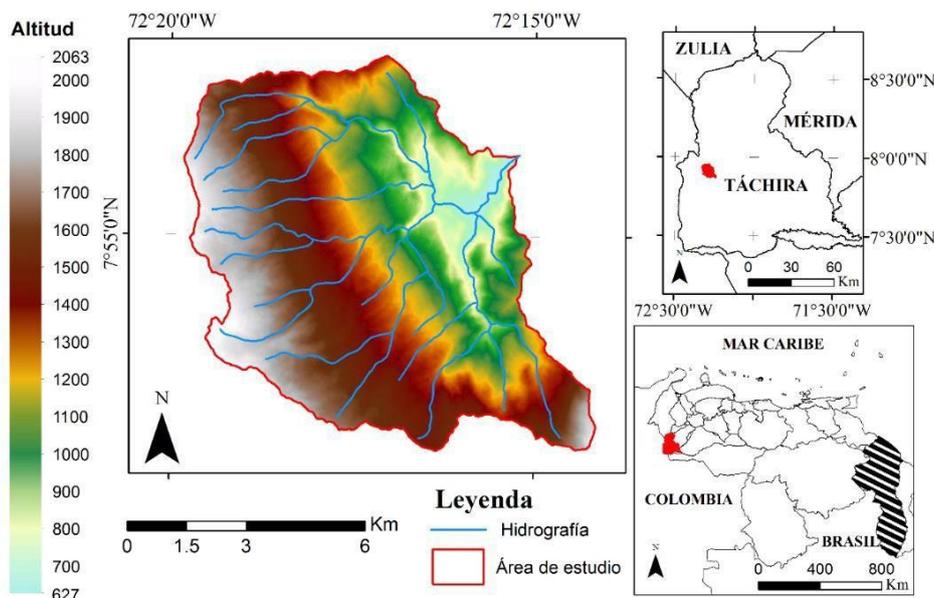


Figura 1. Cuenca Quebrada Parada; ubicación geográfica del área de estudio. **Fuente:** Elaboración propia con base en los archivos del IGVSb-SIGOT (Instituto Geográfico Venezolano Simón Bolívar - Sistema de Información para la Gestión y Ordenación del Territorio) y MDE Alos Palsar ⁽⁴⁰⁾.

Recursos

Los recursos usados para la generación de EAER y RPEH se muestran en la Tabla 1.

Tabla 1. Recursos usados para la generación de EAER (Áreas Erosionadas y en Riesgo De Erosión) y RPEH (Riesgo Potencial de Erosión Hídrica).

Datos de entrada	Denominación	Nivel de detalle	Fuente
Imagen satélite	Landsat 8* (L8)	Resolución espacial 30 m	USGS (U.S. Geological Survey)
Imagen satélite	Sentinel 2* (S2)	Resolución espacial 10 m	ESA (European Space Agency)
Imagen satélite	Digital Globe	Resolución espacial 0,5 m	Digital Globe
MDE	ASTGTM 2*	Resolución espacial 30 m	USGS (U.S. Geological Survey)
MDE	Alos Palsar*	Resolución espacial 12,5 m	JAXA (Japan Aerospace Exploration Agency), METI (Ministry of Economy Trade and Industry)
Registros de precipitación		Promedios mensual/anual	MARNR (Ministerio del Ambiente y de los Recursos Naturales Renovables)
Propiedades físicas del suelo	Textura y materia orgánica	Porcentaje	Laboratorio Bioambiental UNET
Distribución de los tipos de suelo	Sistemas Ambientales Venezolanos –SAV	1: 250 000	IGVSb (Instituto Geográfico Venezolano Simón Bolívar)
Vías	Vías	Resolución espacial 0,5 m	OSM (Open Street Map)

*Datos de acceso público, descargados de: <http://earthexplorer.usgs.gov/>, <https://dataspace.copernicus.eu/> y <https://asf.alaska.edu/> (elaboración propia).

Métodos generales

Se realizó una revisión sistemática de literatura científica para identificar un modelo determinístico de RPEH, técnicas de procesamiento digital y procedimientos SIG para estimar áreas erosionadas y en riesgo de erosión (EAER). Se ejecutaron cuatro etapas principales, la primera, desarrollo del modelo de RPEH, la segunda, obtención de EAER, la tercera, evaluación del grado de acierto de los EAER con una clasificación supervisada de máxima verosimilitud (CSMV) y la relación RPEH – EAER, y la cuarta, los análisis y comparación de los resultados (Figura 2).

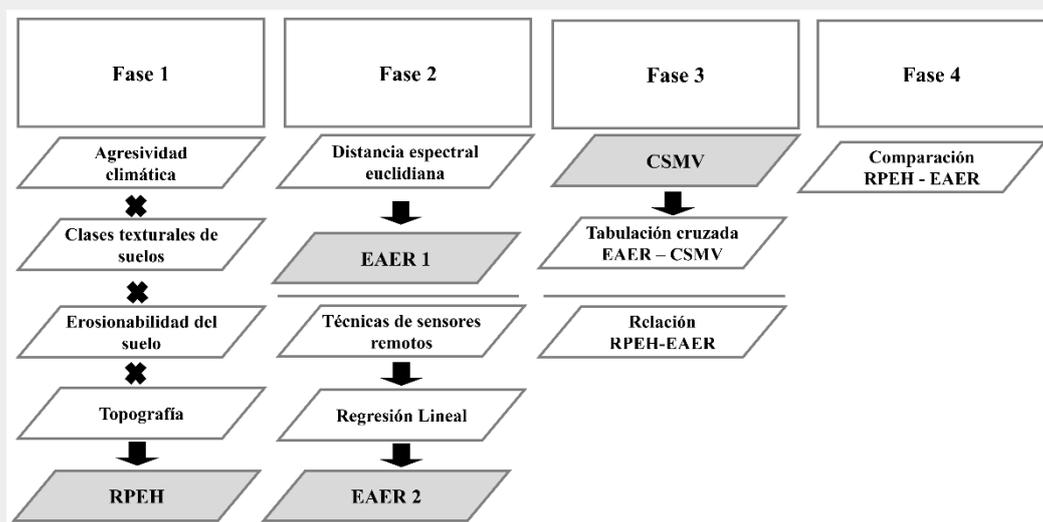


Figura 2. Fases metodológicas para la identificación de las áreas erosionadas y en riesgo de erosión (elaboración propia).

Procesamiento de imágenes Landsat 8 y Sentinel 2

Se descargó una imagen Landsat 8 OLI del 23 de diciembre de 2018 (LCo8_L1TP_007055_20181223_20190129_01_T1_sr) y una imagen Sentinel-2 del 17 de diciembre de 2018 (S2B_MSIL2A_20181217T151659_No211_R125_T18NYP_20181217T191635), ambas en valores de reflectancia de superficie, la primera con correcciones L1T⁽⁴¹⁾ y la segunda, con correcciones L2A^(42, 43, 44). Se emplearon estas imágenes por presentar poca o nula nubosidad en el área de estudio y por su proximidad temporal [es muy poco común tener imágenes claras de la misma área por dos satélites diferentes tan cercanas en el tiempo⁽⁴⁵⁾]. Sobre ambos productos se desarrollaron correcciones del sombreado topográfico, siguiendo los análisis y metodologías aplicadas por Camargo *et al.*⁽⁴⁶⁾, utilizando MDE ASTER para Landsat 8 OLI y Alos Palsar (remuestreado a 10 m) para Sentinel-2. Se definió el método C-Correction^(47, 48) como el más idóneo para ambas imágenes dado a que se obtuvieron las mejores preservaciones de los valores de reflectancia y las disminuciones de las desviaciones estándar con respecto a las imágenes originales usadas como referencia, resultados respaldados visualmente por el mantenimiento del color, textura, la no pérdida de píxeles y la no sobre corrección en las imágenes.

Imagen Digital Globe

Se empleó una imagen en color natural, del 05 de marzo de 2023, con resolución espacial de 0,50 m⁽⁴⁹⁾, soportada en Google Earth, que permite su utilización en investigaciones sin fines lucrativos⁽⁵⁰⁾; ésta apoyó la selección de muestras “verdad-terreno” para aumentar la confianza en las predicciones de suelos desnudos, sustentada en un enfoque cualitativo de clases de gravedad de erosión^(51, 52, 53). Dicha imagen fue descargada a partir

del software SAS Planet, diseñado en plan *Open Source* que posibilita la descarga de mosaicos de cartografía desde una lista de proveedores predeterminada, los cuales son guardados en la memoria caché local para luego poder exportarlos en una buena variedad de formatos ⁽⁵⁴⁾.

Método RPEH

Se basa en dos principios: el primero, de carácter fundamental, expresa que es la tierra la que sufre el ataque de las fuerzas del clima (agresividad climática) y que ésta, a su vez, ofrece grados variables de resistencia que plantea una relación que determina los riesgos de degradación en un área dada, y el segundo, indica, que la evaluación de los riesgos alcanza su máxima utilidad cuando se eliminan factores relativamente inestables o no permanentes (vegetación y usos de la tierra) ⁽⁵⁵⁾. Entre los estudios recientes que utilizan estos principios figuran Guerra *et al.* ⁽⁵⁶⁾, Allafta y Oop ⁽⁵⁷⁾ y Al-Mamari *et al.* ⁽⁵⁸⁾. *RPEH* se manifiesta a través de la ecuación 1:

$$RPEH=f(C,S,T) \text{ (Ecuación 1)}$$

Donde *RPEH* está expresada en Mg ha⁻¹ año⁻¹, *C* es el factor erosividad de la lluvia, *S* es el factor suelo, estimado a través de los subfactores Textura (*St*) y Erosionabilidad (*Se*), y *T* es el factor topográfico ^(55, 59).

El factor climático (*C*) fue evaluado a partir de la modificación del índice de Fournier (1960) ⁽⁶⁰⁾, que se correlaciona mucho mejor con el valor de EI30 (intensidad máxima de lluvia en mm hr⁻¹ de 30 min de duración), comprobado en varias partes del mundo y considerado válido para Venezuela ⁽⁶¹⁾. No se empleó índice de Fournier original, dado que no considera que existen zonas cuyo régimen pluvial pueda presentar más de un pico mensual de precipitación ⁽⁶²⁾. Posteriormente, se generaron superficies interpoladas de precipitación mensual, empleando IDW (Inverse Distance Weighting, por sus siglas en inglés) y no Kriging, debido a que no se cumple con todos los supuestos para su utilización ⁽⁶³⁾.

El factor *S* fue estimado con base a características *St* y *Se*, asociadas a información de los SAV ⁽⁶⁴⁾ dada la escasa disponibilidad de datos de suelo a nivel detallado, que conlleva por lo general, a considerar estudios de reconocimiento ⁽⁶⁵⁾. Partiendo de la primera, se conformaron las clases texturales ⁽⁶⁶⁾, reclasificadas luego a tres categorías generales reconocidas por FAO-UNESCO (1976) ⁽⁶⁷⁾, que permitieron a su vez, asignar valoraciones de acuerdo con FAO *et al.* ⁽⁵⁵⁾ necesarias para el modelo. En cuanto a la segunda, se resolvió utilizando el nomograma del factor *K* de USLE ⁽⁶⁸⁾, comprendido entre 0 y 0,09 Mg·ha·h / ha·MJ·mm, empleando porcentajes de materia orgánica y texturas, asociados luego a valores de erosionabilidad, y posteriormente clasificadas según FAO *et al.* ⁽⁵⁵⁾.

Finalmente, Factor *T* se obtuvo a partir del MDE ALOS Palsar sobre el cual se distinguieron 3 clases de pendiente: a) llana a suavemente ondulada (0 – 8%); b) fuertemente ondulada a colinosa (8 – 30%) y c) fuertemente socavada a montañosa (>30%) ⁽⁶⁷⁾, valoradas con: (a) 0,35; (b) 3,5 y (c) 11,0 ⁽⁵⁵⁾.

Método EAER

Se desarrollaron dos alternativas cartográficas, la primera basada en la distancia espectral euclidiana entre la reflectividad de cada píxel de la imagen satelital a la categoría suelos desnudos y la segunda, a partir de diversas técnicas de percepción

remota, con las cuales se establecieron regresiones lineales. Sobre ambos productos se aplicaron curvas ROC (Receiver Operating Characteristics) que permitieron definir umbrales de clasificación e incertidumbres asociadas, orientados a detectar zonas contiguas espectrales similares de áreas erosionadas y en riesgo ^(12, 69). Para los umbrales, se seleccionaron 100 muestras independientes (píxeles) que evidenciaron <10% de cobertura vegetal, distribuidas aleatoriamente y definidas con ayuda de la imagen Digital Globe, pues se considera el riesgo de erosión alto cuando esta es baja ⁽⁷⁰⁾.

Una curva ROC es un gráfico en el que se incorporan todos los pares de Sensibilidad/Especificidad resultantes de la variación continua de los puntos de corte en todo el rango de resultados observados, que ofrece una visión global de exactitud diagnóstica al proporcionar datos significativos acerca de la probabilidad de clasificar correctamente a un individuo mediante una variable determinada ⁽⁷¹⁾. Sus ecuaciones son (Ecuación 2 y Ecuación 3):

$$\text{Sensibilidad} = \frac{a}{a+c} \quad \text{—} \quad \text{(Ecuación 2)}$$

$$\text{Especificidad} = \frac{d}{b+d} \quad \text{—} \quad \text{(Ecuación 3)}$$

Donde *a* son verdaderos positivos, *b* verdaderos negativos, *c* falsos positivo y *d* falsos negativos. Sensibilidad expresa proporción de píxeles positivos correctamente predichos, y Especificidad, proporción de píxeles negativos correctamente predichos; valores de 1 en sensibilidad y 1 en especificidad representan probabilidades de cometer error de omisión (tipo II, o falso negativo) y de comisión (tipo I, o falso positivo) ⁽⁶⁹⁾. Para determinar áreas erosionadas, se fijó un valor de sensibilidad de 0,9 correspondiente a una probabilidad de error de omisión de 10%, y para áreas en riesgo, un valor de 0,8 (20% de error de omisión).

Se desarrollaron clasificaciones supervisadas de máxima verosimilitud (CSMV) de coberturas por ser más precisas que las no supervisadas dado que sus clases son previamente conocidas ⁽⁷²⁾, para evaluar posteriormente, el acierto de la cobertura suelos desnudos con los EAER mediante tabulaciones cruzadas. Para ello, se establecieron 4 categorías espectrales (vegetación alta y baja, suelos desnudos e infraestructura) con las cuales se escogieron una serie de muestras (con diferentes tamaños) requeridas por el clasificador. En el caso de la imagen Landsat 8 OLI significó la selección de 20 muestras para vegetación alta (1334 píxeles), 17 para vegetación baja (26 píxeles), 19 para suelos desnudos (124 píxeles) y 20 para Infraestructura (13 píxeles) y en la imagen Sentinel-2, implicó la selección de 32 muestras para vegetación alta (14237 píxeles), 51 para vegetación baja (3806 píxeles), 46 para suelos desnudos (2970 píxeles) y 30 para infraestructura (228 píxeles). Dichas muestras fueron escogidas con apoyo de la imagen de muy alta resolución (Digital Globe) para evitar incorrectas selecciones.

Elaboradas las CSMV, estas fueron actualizadas con la vialidad (OSM) y evaluadas sus precisiones mediante procesos de control de exactitud temática, para corroborar el grado de conformidad de cada categoría respecto a la verdad-terreno ⁽⁷³⁾, estas se fundamentaron en el uso de la imagen Digital Globe y en la generación de unidades de muestreo independientes que representaron entre el 5% y 10% del área mapeada, considerando para ello las proporciones de cada una de las coberturas, a fin de que fueran directamente comparables ⁽⁷⁴⁾.

Estas muestras fueron seleccionadas tomando en consideración el criterio de Olofsson *et al.* ⁽⁷⁵⁾, es decir, por medio de consulta a un experto en interpretación de imágenes de percepción remota, quien no participó en la elaboración del mapa. Posteriormente, se estimaron las exactitudes en las CSMV a través de matrices de confusión ejecutadas en el software libre System for Automated Geoscientific Analyses (SAGA) versión 7.8.2, que permitieron visualizarlas, estas entendidas como los resúmenes de los acuerdos y desacuerdos entre las categorías de los mapas y del terreno ⁽¹¹⁾, definidos como errores de omisión, comisión, precisión global ⁽¹¹⁻⁷⁶⁾ y el estadístico K (Kappa) ⁽⁷⁷⁾. El primero entendido como los elementos que sin pertenecer a una categoría aparecen en ella; el segundo, como los elementos que pertenecen a una categoría no aparecen en ella por estar erróneamente incluidos en otra y el tercero, que señala el número de unidades clasificadas correctamente, sobre el número total de unidades estimadas ⁽⁷⁸⁾, considerando para ello los valores límites establecidos (80 – 100%) por los científicos para diferenciar las categorías ⁽⁷⁹⁾. En cuanto al estadístico K ⁽⁷⁷⁾, estudia la proporción total de muestras que coinciden en ambas capas ⁽⁸⁰⁾ y debe presentar valores superiores a 0,61 para que sea aceptable la concordancia de la cartografía generada ⁽⁸¹⁾ y que se expresa con la ecuación siguiente:

$$\kappa = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n (G_i C_i)}{N^2 - \sum_{i=1}^n (G_i C_i)}$$

Dónde: i es el número de categorías; N es el número total de píxeles clasificados y comparados con la verdad terreno; $m_{i,j}$ es el número de píxeles que perteneciendo a la clase verdad terreno i , han sido también clasificados con una clase i (valores encontrados a lo largo de la diagonal de la matriz de confusión); C_i es el número total de píxeles clasificados pertenecientes a la clase i . G_i es el número de píxeles verdad-terreno pertenecientes a la clase i ⁽⁸²⁾.

Las técnicas de percepción remota desarrollados fueron: índices de vegetación basados en pendiente y distancia e índices de suelos (Tabla 2) y otros como análisis de componentes principales (ACP) ⁽⁸³⁾, análisis de mezclas espectrales (ALME) ⁽⁸⁴⁾, Índice de Proporción de Pigmentos de Clorofila Normalizado (NPCRI) ^(85, 86), Índice de Sombras (SI) ⁽⁸⁷⁾ y Tasseled Cap Brillo (Brillo) ⁽⁸⁸⁾ con los coeficientes derivados por Baig ⁽⁸⁹⁾ para Landsat 8 OLI (Ecuación 4) y por Shi y Xu ⁽⁹⁰⁾ para Sentinel-2 (Ecuación 5). Para calcular el Tasseled Cap Brillo S2, las bandas 11 y 12 (SWIR 1 y 2) con resolución espacial de 20 m, fueron remuestreadas a 10 m por el método de interpolación bilineal (en ND).

$$\text{Brillo L8} = b_2 \times 0,3029 + b_3 \times 0,2786 + b_4 \times 0,4733 + b_5 \times 0,5599 + b_6 \times 0,508 + b_7 \times 0,1872$$

(Ecuación 4)

$$\text{Brillo S2} = b_2 \times 0,3510 + b_3 \times 0,3813 + b_4 \times 0,3437 + b_8 \times 0,7196 + b_{11} \times 0,2396 + b_{12} \times 0,1949$$

(Ecuación 5)

Tabla 2. Índices aplicados sobre datos de sensores remotos Landsat 8 y Sentinel 2.

Autor	Índice de Vegetación (Basado en pendiente)
Jordan ⁽⁹¹⁾	<i>Difference Vegetation Index</i> $DVI = IRC - R$
Pearson y Miller ⁽⁹²⁾	<i>Ratio Vegetation Index</i> $RVI = R / IRC$
Rouse <i>et al.</i> ⁽⁹³⁾	<i>Normalized Diferential Vegetation Index</i> $NDVI = \frac{IRC - R}{IRC + R}$
Baret y Guyot ⁽⁹⁴⁾	<i>Normalized Ratio Vegetation Index</i> $NRVI = \frac{RVI - 1}{RVI + 1}$
Deering <i>et al.</i> ⁽⁹⁵⁾	<i>Transformed Vegetation Index</i> $TVI = \sqrt{NDVI}$
Thiam ⁽⁹⁶⁾	<i>Thiam's Transformed Vegetation Index</i> $TTVI = \sqrt{ABS NDVI + 0,5 }$
Perry y Lautenschlager ⁽⁹⁷⁾	<i>Corrected Transformed Vegetation Index</i> $CTVI = \frac{NDVI + 0,5}{ABS(NDVI + 0,5)} \times \sqrt{ABS(NDVI + 0,5)}$
Huete ⁽⁹⁸⁾	<i>Soil-Adjusted Vegetation Index</i> $SAVI = \frac{IRC - R}{IRC + R} (1 + L)$
Autor	Índice de Vegetación (Basado en distancia)
Richardson y Wiegand ⁽⁹⁹⁾ reescrito por Jackson <i>et al.</i> ⁽¹⁰⁰⁾	<i>Perpendicular Vegetation Index</i> $PVI_0 = \left(\frac{IRC - a \cdot R - b}{\sqrt{a^2 + 1}} \right)$
Perry y Lautenschlager ⁽⁹⁷⁾	<i>Perpendicular Vegetation Index</i> $PVI_1 = \frac{b \cdot IRC - R + a}{\sqrt{b^2 + 1}}$
Walther y Shabaani ⁽¹⁰¹⁾	<i>Perpendicular Vegetation Index</i> $PVI_2 = \frac{(IRC - a)(R + b)}{\sqrt{a^2 + 1}}$
Qi <i>et al.</i> ⁽¹⁰²⁾	<i>Perpendicular Vegetation Index</i> $PVI_3 = a \cdot IRC - b \cdot R$
Baret y Guyot ⁽⁹⁴⁾	<i>Adjusted Transformed Soil-Adjusted Vegetation Index</i> $ATSAVI = \frac{a \cdot IRC - a \cdot R - b}{(a \cdot IRC + R - a \cdot b + 0,08 (1 + a^2))}$
Autor	Índice de suelo
Nganfdam <i>et al.</i> ⁽¹⁵⁾	<i>Normalized Difference Bare Soil Index</i> $NDBSI = \frac{Swir1 - IRC}{Swir1 + IRC} + 0.001$

Celik ⁽¹⁰³⁾	<i>Bare Soil Index</i> $BSI = \frac{(R + Swir\ 1) - (NIR + A)}{(R + Swir\ 1) + (NIR + A)}$
Zhao y Chen ⁽¹⁰⁴⁾	<i>Normalized Difference Bareness Index</i> $NDBaI2 = \frac{Swir1 - Tirs1}{Swir1 + Tirs1}$
Autor	Otros índices
Peñuelas <i>et al.</i> ^(85, 86)	<i>Normalized Pigment Chlorophyll Ratio Index</i> $NPCRI = \frac{R - A}{R + A}$
Rikimaru <i>et al.</i> ⁽⁸⁷⁾	<i>Shadow Index</i> $SI = [(1 - R) * (1 - V) * (1 - A)]^{1/3}$

Posteriormente, se realizaron análisis de regresiones lineales para determinar el grado de dependencia existente entre dos variables ⁽¹⁰⁵⁾. Para ello, se consideró la distancia espectral euclidiana de suelos desnudos como independiente (*x*) y cada técnica como dependiente (*y*). Pruebas de correlación fueron calculadas para mostrar el nivel de la relación lineal. Finalmente, todos los valores de *P* generados fueron menores a 0,001, sabiendo que *P* menores a 0,05 debían ser considerados en el análisis.

Los mapas resultantes de EAER (elaborados con el software QGIS 3.34.8 'Prizren'), presentan tres categorías: i) áreas erosionadas (Ae), entendidas como aquellas que no presentan vegetación y denotan erosión activa, ii) áreas en riesgo (Re), aquellas que poseen poca vegetación y que están propensas a la erosión y iii) sin erosión (Se), áreas que presentan buena cobertura vegetal y que protegen «aparentemente» de la erosividad de la lluvia.

Obtenidos los resultados, fueron comparados a través de dos estrategias: la primera a partir de la selección de 20 muestras puntuales en la imagen Landsat 8 OLI y Sentinel-2, corroboradas con la imagen Digital Globe (de mayor resolución), para evaluar el performance de las metodologías EAER, asociados a valores de RPEH, como una manera de establecer una evaluación rápida en el área. La segunda, se estableció con la comparación de las áreas obtenidas por los métodos, dado que la resolución espacial de Landsat 8 OLI tiene serias limitaciones en áreas muy heterogéneas con alta fragmentación espacial, a diferencia de la imagen Sentinel-2 que, con una mayor resolución provee una solución a estas limitaciones ⁽¹⁰⁶⁾.

3. Resultados

Riesgo Potencial de Erosión Hídrica (RPEH)

El desarrollo de los factores (Figura 3), permitió definir un factor clima C, comprendido entre 70,47 y 96,57 (Figura 3a). El factor suelo S fue estimado a través del subfactor textura *St* (Figura 3b) como fina (0,1), media (0,3) y gruesa (0,2) y en términos del subfactor erosionabilidad *Se*, calificado como ligera (0,5) (Figura 3c y Tabla 3). El factor topografía T está comprendido entre 0,35 y 11 (Figura 3d). Definidas las variables, fueron multiplicadas en un algebra de mapas para obtener RPEH y luego reclasificado para establecer clases de degradación (Figura 4), obteniéndose “ninguna a ligera” en 396,92 ha (5,85%), “moderada” en 1920,16 ha (28,32%), “alta” en 4147,41 ha (61,17%) y “muy alta” con 316,13 ha (4,66%).

Tabla 3. Procesamiento de los sub-factores de suelo del RPEH.

Textura del suelo	Subfactor <i>St</i>		Subfactor <i>Se</i>	
	Textura clases ^{1 (67)}	Valoración textural clases ^{2 (55)}	K valores ^{3 (68)}	Valoración erosionabilidad clases ^{4 (55)}
Arenoso franco	Gruesa	0,2	0,008	Ligera (0,5)
arcilloso	Fina	0,1	0,008	Ligera (0,5)
Franco	Media	0,3	0,017	Ligera (0,5)
Franco arenoso	Gruesa	0,2	0,008	Ligera (0,5)
Franco arcilloso	Fina	0,1	0,013	Ligera (0,5)

¹ Clases texturales: Gruesa: <18% y arcilla >65% arena; media: <35% arcilla y < 65% arena o < 18% arcilla y <82% arena; fina: >35% arcilla

² Clasificación St: Gruesa: 0,2; media: 0,3; Fina: 0,1; Fase Pedregosa: 0,5

³ K-valores: ligera: <0,03; Moderada: 0,03-0,06; Alta: 0,06 >.

⁴ Valoración Se: Ligera: 0,5; moderada: 1,0; Alta: 2,0.

Fuente: Autores (muestras de suelo recolectadas para este estudio y procesadas por el laboratorio Bioambiental UNET).

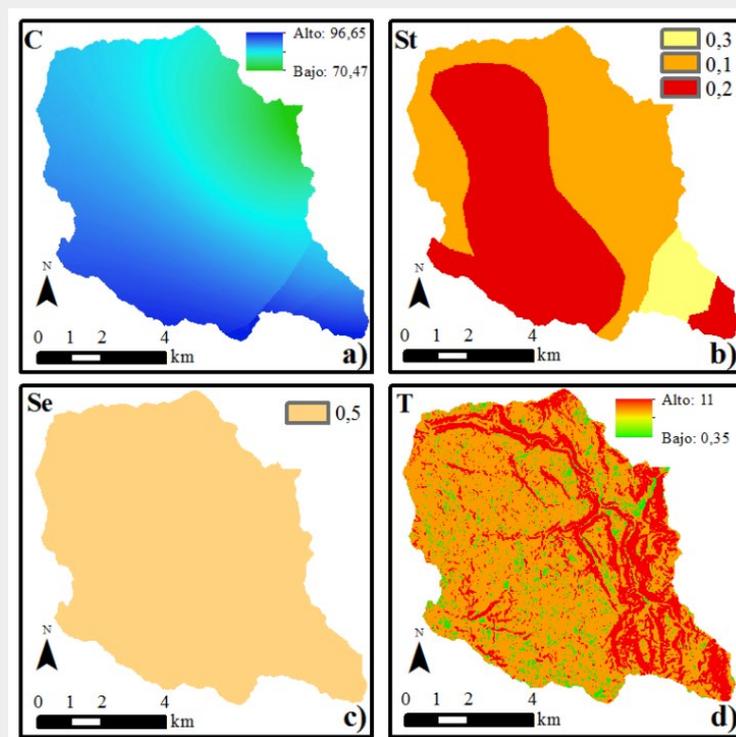


Figura 3. Factores y subfactores de RPEH donde a) es factor C b) subfactor St c) subfactor Se y d) Factor T (elaboración propia).

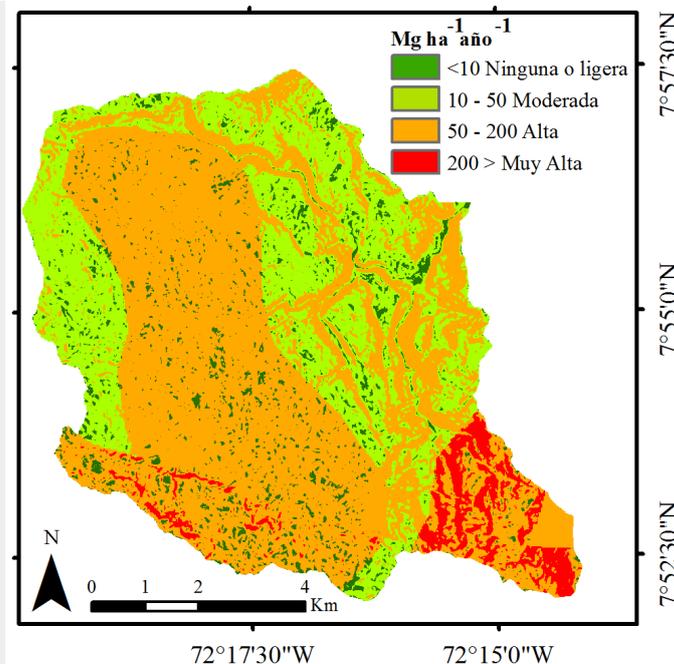


Figura 4. Mapa de riesgo de erosión de suelos de la Cuenca quebrada Parada (elaboración propia).

Clasificación supervisada de máxima verosimilitud (CSMV)

Se establecieron 5 categorías para ambas imágenes: vialidad, vegetación alta, vegetación baja, suelos desnudos (incluye afloramientos rocosos) e infraestructura (Figura 5), extrayéndose sus áreas (Tabla 4). El mapa obtenido a partir de la clasificación de la imagen Landsat 8 OLI tuvo una precisión global de 91,43% e índice Kappa de 0,82 (Figura 5a). Por su parte, la clasificación de la imagen Sentinel-2 obtuvo una precisión global de 95,67% y un índice de Kappa de 0,90 (Figura 5b).

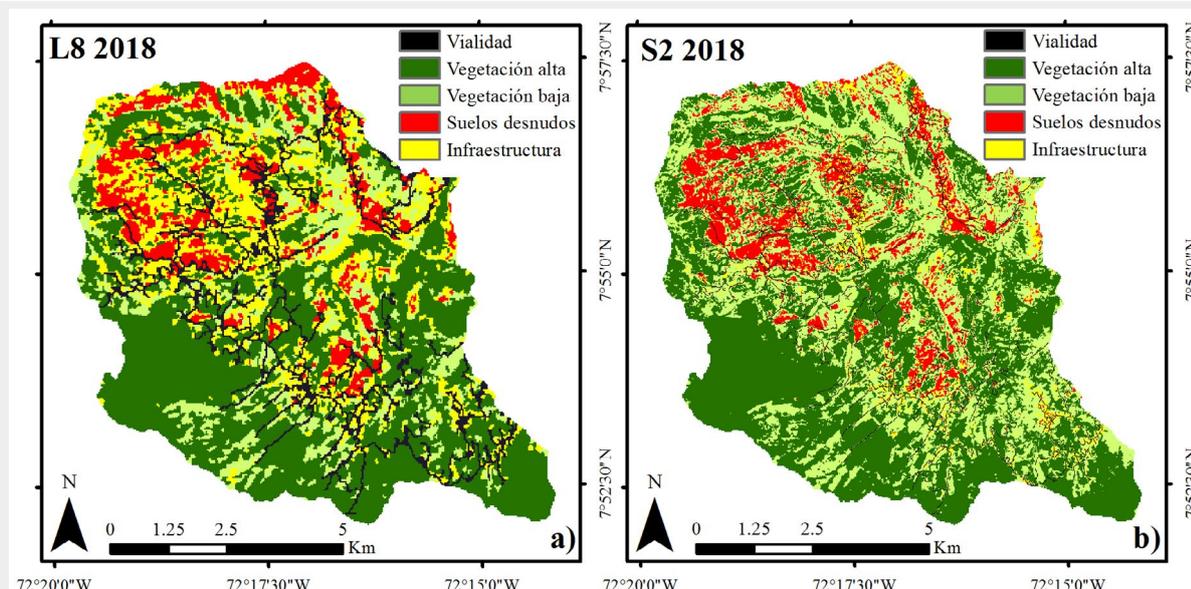


Figura 5. a) CSMV Landsat 8; b) CSMV Sentinel 2 (Elaboración propia).

Tabla 4. Área en hectáreas y porcentajes de CSMV de imágenes L8 y S2 obtenidas para la cuenca Quebrada Parada.

CLASE	Parada L8		Parada S2	
	Área (ha)	Porcentaje (%)	Área (ha)	Porcentaje (%)
Vialidad	592,38	8,73	206,58	3,04
Vegetación alta (Va)	3 062,88	45,12	3 209,24	47,27
Vegetación baja (Vb)	1 011,33	14,90	2 453,78	36,15
Suelos desnudos (Sd)	678,15	9,99	681,62	10,04
Infraestructura (Inf)	1 443,87	21,27	237,39	3,50

Validación de CSMV imagen Landsat 8 OLI

El análisis de la diagonal de la matriz de confusión arrojó como resultados que la vegetación alta tuvo un acierto de 99,67% (2141 píxeles – 192,69 ha), vegetación baja 58,69% (341 píxeles – 30,69 ha), suelos desnudos 95,14% (372 píxeles – 33,48 ha) e infraestructura 88,24% (30 píxeles – 2,70 ha) (Tabla 5).

En cuanto a los totales de las columnas, que expresan las clases que no se adecuaron a las muestras verdad – terreno, se obtuvo que el área de infraestructura fue de 34 píxeles (3,06 ha), de las cuales hubo un acuerdo de 88,24% (30 píxeles – 2,70 ha) y una subestimación de 11,76% (4 píxeles – 0,36 ha), que se confundieron con los suelos desnudos. De igual manera, el área estimada de suelos desnudos, en función de los datos de verdad – terreno fue de 391 píxeles (35,19 ha) de las cuales hubo una concordancia con las muestras de 95,14% (372 píxeles – 33,48 ha) y una subestimación de 4,86% (19 píxeles – 1,71 ha) resultado de la confusión con infraestructura (Tabla 5).

Respecto a la vegetación baja, partiendo de los datos de verdad – terreno, fue de 581 píxeles (52,29 ha), de los cuales hubo un acuerdo de 58,69% (341 píxeles – 30,69 ha) y una subestimación de 21,51 % (125 píxeles – 11,25 ha), 13,25% (77 píxeles – 76,93 ha) y 6,54% (38 píxeles – 3,42%), confundidas con las clases infraestructura, suelos desnudos y vegetación alta, correspondientemente. Finalmente, las muestras de la clase vegetación alta tuvieron un acuerdo de 99,67% (2148 píxeles – 193,32 ha) y una subestimación de 0,33% (7 píxeles – 0,63 ha) resultado de la confusión con la infraestructura (Tabla 5).

Tabla 5. Matriz de confusión en píxeles y hectáreas (en paréntesis) sobre datos obtenidos de Landsat 8 OLI.

	Clase	Áreas de entrenamiento				Total
		Inf	Sd	Va	Vb	
Clasificación supervisada	Inf	30 (2,70)	19 (1,71)	7 (0,63)	125 (11,25)	181
	Sd	4 (0,36)	372 (33,48)	0 (0,0)	77 (6,93)	453
	Va	0 (0,0)	0 (0,0)	2141 (192,69)	38 (3,42)	2179
	Vb	0 (0,0)	0 (0,0)	0 (0,0)	341 (30,69)	341
	Total	34 (3,06)	391 (35,19)	2148 (193,32)	581 (52,29)	

Tabla 6. Confiabilidad de la CSMV con los datos obtenidos de Landsat 8 OLI.

Clase	Suma Referencia	% Precisión del Productor (Omisión)	Suma Clasificada	% Precisión del usuario (Comisión)
Inf	34	88,23	181	16,57
Sd	391	95,15	453	82,12
Va	2148	99,67	2179	98,25
Vb	581	58,69	341	100

Por otro lado, se puede comentar que la clase infraestructura, fue la que reportó el mayor error del usuario (comisión), debido a que se incorporaron mayores áreas en estas clases (16,57%). De modo similar, ocurrió para los errores del productor (omisión), donde vegetación baja, reportó el mayor error, debido a que se incluyó esta clase en otras categorías, cuando no era cierta (58,69%) (Tabla 6).

Validación de CSMV imagen Sentinel-2

El análisis de la diagonal de la matriz de confusión arrojó como resultados que la vegetación alta tuvo un acierto de 99,80% (19298 píxeles – 192,98 ha), vegetación baja 90,20% (4611 píxeles – 46,11 ha), suelos desnudos 82,89% (2935 píxeles – 29,35 ha) e infraestructura 71,32% (194 píxeles – 1,94 ha) (Tabla 7).

En cuanto a los totales de las columnas, que expresan las clases que no se adecuaron a las muestras verdad – terreno, se obtuvo que el área de vegetación alta fue de 19336 píxeles (193,36 ha), de las cuales hubo un acuerdo de 99,80% (19298 píxeles – 192,98 ha) y una subestimación de 0,01% (1 píxel – 0,01 ha) y 0,19% (37 píxeles – 0,37 ha), que se confundieron con las clases suelos desnudos y vegetación baja, respectivamente. De igual manera, el área estimada de vegetación baja, en función de los datos de verdad – terreno fue de 5112 píxeles (46,11 ha) de las cuales hubo una concordancia con las muestras de 90,20% (4611 píxeles – 46,11 ha) y una subestimación de 1,58% (81 píxeles – 0,81 ha), 1,98% (101 píxeles – 1,01 ha) y 6,24% (319 píxeles – 3,19 ha) resultado de la confusión con infraestructura, suelos desnudos y vegetación alta, respectivamente (Tabla 7).

Respecto a la clase suelos desnudos, partiendo de los datos de verdad – terreno, fue de 3541 píxeles (35,41 ha), de los cuales hubo un acuerdo de 82,89% (2935 píxeles – 29,35 ha) y una subestimación de 15,45% (547 píxeles – 5,47 ha) y 1,67% (59 píxel – 0,59 ha), confundidas con la infraestructura y vegetación baja, correspondientemente. Finalmente, la clase infraestructura, conforme a la verdad terreno, 272 píxeles (2,72 ha), presentó un acuerdo de 71,32% (194 píxeles – 1,94 ha) y 16,18% (44 píxeles – 0,44 ha), 0,37% (1 píxel – 0,01 ha) y 12,13% (33 píxeles – 0,33 ha) de confusión con la clase suelos desnudos, vegetación alta y baja, respectivamente (Tabla 7).

Tabla 7. Matriz de confusión en píxeles y hectáreas (en paréntesis) sobre datos obtenidos de Sentinel-2.

	Clase	Áreas de entrenamiento				Total
		Inf	Sd	Va	Vb	
Clasificación supervisada	Inf	194 (1,94)	547 (5,47)	0 (0,0)	81 (0,81)	822
	Sd	44 (0,44)	2935 (29,35)	1 (0,01)	101 (1,01)	3081
	Va	1 (0,01)	0 (0,0)	19298 (192,98)	319 (3,19)	19618
	Vb	33 (0,33)	59 (0,59)	37 (0,37)	4611 (46,11)	4740
Total		272 (2,72)	3541 (35,41)	19336 (193,36)	5112 (51,12)	

Tabla 8. Confiabilidad de la CSMV con los datos obtenidos de Sentinel-2.

Clase	Suma Referencia	% Precisión del productor (Omisión)	Suma Clasificada	% Precisión del usuario (Comisión)
Inf	272	71,32	822	23,60
Sd	3541	82,89	3081	95,26
Va	19336	99,80	19618	98,37
Vb	5112	90,20	4740	97,28

Por otro lado, se puede comentar que la clase infraestructura, fue la que reportó el mayor error del usuario (comisión), debido a que se incorporaron mayores áreas en estas clases (23,60%). De igual modo, esta misma clase presentó un error del productor (omisión) elevado en comparación al resto de clases, debido a que se incluyó esta clase en otras categorías, cuando no era cierta (71,32%) (Tabla 8).

Áreas Erosionadas y en Riesgo de Erosión 1 (EAER1)

La aplicación de los umbrales 0,9 y 0,8 para definir las cartografías EAER1 basados en distancias espectrales euclidianas arrojaron resultados poco satisfactorios (excesivas inclusiones de píxeles como áreas erosionadas o en riesgo), debido principalmente a las diferentes distribuciones y rangos de los valores de las imágenes y, por tanto, de las 100 muestras seleccionadas en la construcción de las curvas ROC (Tabla 9). A modo de ilustración, un valor mínimo de 0,02583 para el caso de S2, constituye un valor considerablemente más bajo al mínimo presentado por L8, por cuanto la fijación del umbral 0,8 (0,1115) obtenido para esta imagen, lo situaría muy cerca del rango mínimo, en contraste a lo que sucedería con el umbral 0,8 (0,1345) en S2, el cual sí se halla más alejado de su valor mínimo. Igual análisis se puede plantear con los umbrales 0,9. Dichos resultados conllevaron al replanteo de los umbrales, esta vez definidos a partir de umbrales que reflejaron una mayor sensibilidad (puntos de corte más próximos a 1).

Tabla 9. Estadísticas descriptivas de las 100 muestras con valores ROC para cada una de las imágenes satelitales.

Imagen	Mínimo	Máximo	Media	Des. estándar
L8	0,01060	0,22019	0,11723	0,03741
S2	0,02583	0,25836	0,18706	0,05698

Los umbrales replanteados 0,8 (U_{1r}) y 0,75 (U_{2r}) a partir de la curva ROC para la imagen L8 (Figura 6a), indicaron 0,1115 y 0,1002 de distancia espectral, permitiendo así una buena capacidad para clasificar correctamente píxeles positivos (suelos desnudos). Ambos representan un balance entre sensibilidad y especificidad, es decir un acercamiento al más ideal (área bajo la curva - ABC= 100%), que permitieron generar el mapa (Figura 6b), arrojando como resultados: “áreas erosionadas” (2 069,91 ha), “riesgo de erosión” (239,67 ha) y “sin erosión” (3 886,65 ha). En lo que respecta a los nuevos umbrales de la curva ROC para S2 (Figura 6a), se definieron los valores 0,9 (U_{1r}) y 0,85 (U_{2r}), que indicaron 0,1839 y 0,1462 de distancia espectral, constituyendo también una buena clasificación de los píxeles positivos. En este caso ambos representan también un balance entre sensibilidad y especificidad, es decir un acercamiento al más ideal, que permitieron generar el mapa (Figura 6c), arrojando como resultados: “áreas erosionadas” (1 240,13 ha), “riesgo de erosión” (917,43 ha) y “sin erosión” (4 428,76 ha). Las ABC, fueron de 79,8% para L8 y de 97,4% para S2.

El cruce CSMV-EAER1 procedente de L8, señaló que las “áreas erosionadas” coincidieron en 642,24 ha con suelos desnudos, así mismo, esta categoría interceptó a vegetación alta en 34,65 ha, a baja en 466,20 ha y a infraestructura en 926,82 ha. Por su parte, la clase riesgo de erosión interceptó, principalmente, a vegetación baja con 109,80 ha, a suelos desnudos con 2,70 ha, a infraestructura con 69,93 ha y a vegetación alta con 57,24 ha. En cuanto a las clases sin erosión (asumiendo sólo las áreas con vegetación), se hallaron 3 406,32 ha; 33,21 ha fueron interceptadas con suelos desnudos y 447,12 ha con infraestructuras (Tabla 10).

De igual modo, el cruce CSMV-EAER1 derivado de S2, indicó que las “áreas erosionadas” coincidieron en 635,44 con suelos desnudos, de la misma manera, esta categoría interceptó a vegetación alta en 3,23 ha, a baja en 387,52 ha y a infraestructura en 214,18 ha. Por su parte, la clase riesgo de erosión interceptó, principalmente, a vegetación baja con 877,52 ha, a suelos desnudos con 29,17 ha, a infraestructura con 9,68 ha y a vegetación alta con 1,06 ha. Finalmente, en cuanto al total de áreas sin erosión (asumiendo sólo las áreas con vegetación), se hallaron 4 398,22 ha; solo 17,01 ha fueron interceptadas con suelos desnudos y otras 13,53 ha con infraestructuras (Tabla 10).

Por otro lado, la inclusión de vialidad, obtenida de OSM, ayudó a precisar aún más el mapa EAER 1 para S2, en este caso precisando 206,58 ha de esta clase para toda la cartografía, que hubieran sido clasificadas en las clases restantes, también en contraste a las 592,38 ha obtenidas en L8.

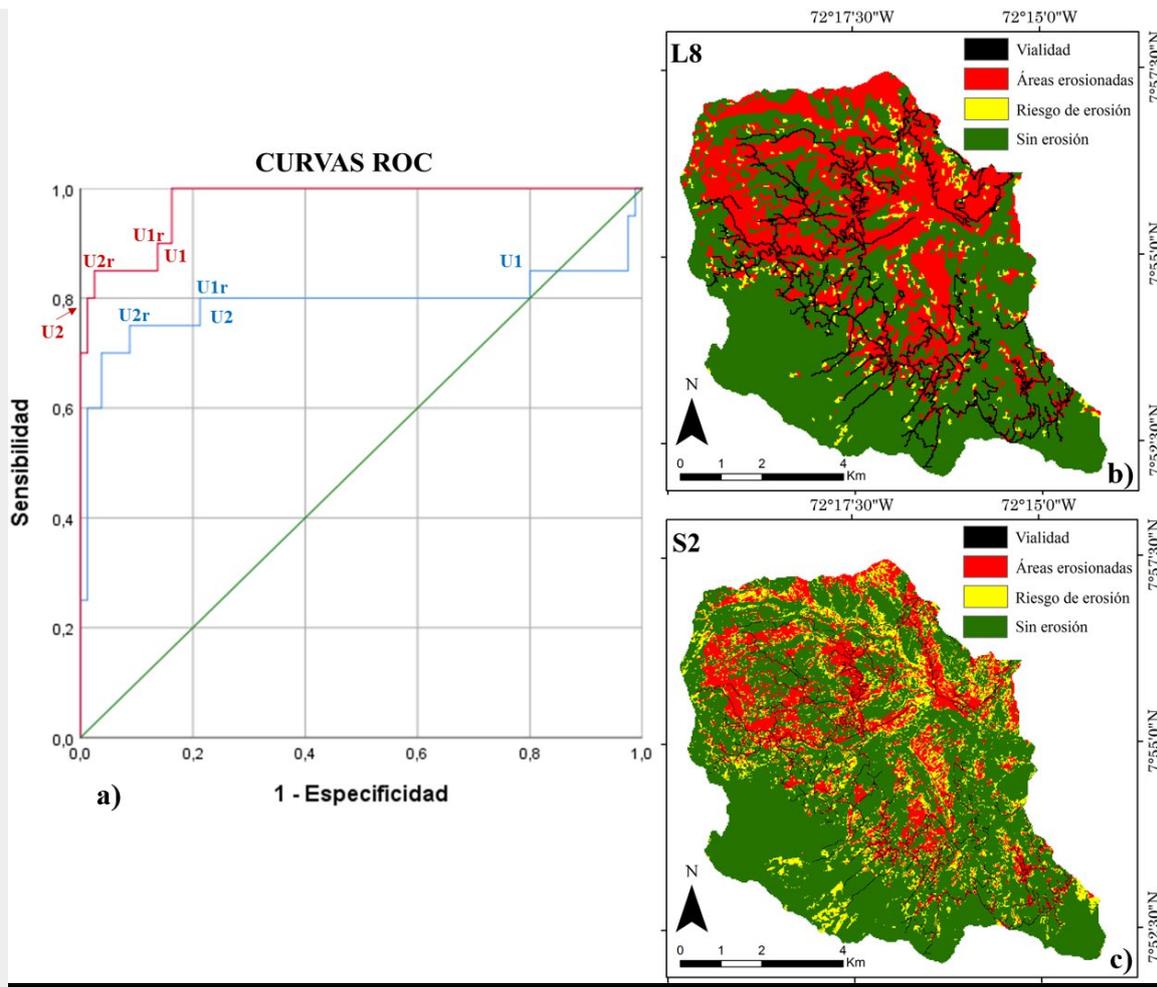


Figura 6. a): curvas ROC (U1 y U2= umbrales 0,9 y 0,8; U2r y U1r: umbrales replanteados); b): EAER 1 Landsat 8; c) EAER 1 Sentinel 2 (elaboración propia).

Tabla 10. Tabulaciones cruzadas entre las cartografías CSMV y EAER1 en hectáreas (elaboración propia).

		EAER1			
		Vialidad	Áreas erosionadas	Riesgo erosión	Sin erosión
Clasificación supervisada Landsat 8	Vialidad	592,38	0,00	0,00	0,00
	Vegetación alta	0,00	34,65	57,24	2 970,99
	Vegetación baja	0,00	466,20	109,80	435,33
	Suelos desnudos	0,00	642,24	2,70	33,21
	Infraestructura	0,00	926,82	69,93	447,12
Clasificación supervisada Sentinel 2	Vialidad	206,58	0,00	0,00	0,00
	Vegetación alta	0,00	3,23	1,06	3 209,24
	Vegetación baja	0,00	387,28	877,52	1 188,98
	Suelos desnudos	0,00	635,44	29,17	17,01
	Infraestructura	0,00	214,18	9,68	13,53

Áreas Erosionadas y en Riesgo de Erosión 2 (EAER2)

Derivados los productos por técnicas de percepción remota, se desarrollaron las regresiones lineales. En el caso de L8, el análisis arrojó que el valor de pendiente fue diferente a 0 en todos los casos, es decir que, existe dependencia entre las variables. Bajo este criterio, PVI_0 es el más dependiente (5,62) al presentar la línea más inclinada, con dependencia de tipo directa (positiva), resultado seguido por NDVI (4,38) y ATSAVI (2,82) (Tabla 11).

Estableciendo el análisis solo en coeficientes de correlación (R), los mayores resultados fueron definidos por NDVI (0,800), seguido muy de cerca por el grupo de TTVI, CTVI y TVI cada uno con 0,786. NDBSI presentó -0,808 es decir, el peor coeficiente. Los resultados restantes presentaron correlaciones negativas. En cuanto al R^2 , se encontró que NDBSI presentó el mejor valor con 0,653 seguido de NDVI y NRVI, ambos con 0,640. PVI_2 arrojó el peor R^2 (0,042).

Entre todas las técnicas realizadas, NDBSI es el que está más fuertemente determinado por la distancia espectral euclidiana del suelo con un R^2 de 0,653; sin embargo, también mostró la más alta correlación negativa con -0,808. Igual situación fue presentada por NRVI. De modo contrario, la técnica que presentó el mejor R^2 fue NDVI con 0,640, al presentar una correlación positiva (la más alta) de 0,800, lo que la convierte en la alternativa EAER2 para L8.

Posteriormente, se elaboró a partir de 100 muestras de valores de NDVI la curva ROC. Los umbrales 0,9 (U_1) y 0,8 (U_2) indicaron 0,3162 y 0,2646 de NDVI, respectivamente. Ambos umbrales representaron un buen balance entre sensibilidad y especificidad, es decir un acercamiento al más ideal ($ABC=100\%$), que permitieron generar el mapa (Figura 7b), arrojando como resultados: “áreas erosionadas” (321,48 ha), “riesgo de erosión” (47,61 ha) y “sin erosión” (5 827,14 ha). Las ABC para L8 y S2 fueron de 100%.

El cruce CSMV–EAER2 procedente de L8, señaló que la superficie ocupada por “áreas erosionadas” coincidió en 291,60 ha con suelos desnudos e interceptó a infraestructura en 29,88 ha (no hubo intercepciones con vegetación). Por su parte “riesgo de erosión”, interceptó a vegetación baja con 0,18 ha, a suelos desnudos con 43,56 ha, y a infraestructura con 3,87 ha. Finalmente, las áreas sin erosión sumaron 4 074,03 ha (vegetación alta y baja), solo 342,99 ha fueron interceptadas con suelos desnudos y 1 410,12 ha con infraestructuras (Tabla 13).

Tabla 11. Regresiones lineales Landsat 8.

PDI	R	R ²	Ecuación
Suma ACP	0,785	0,616	$y = -0,29 + 2,38X$
SAVI	0,706	0,499	$y = 0,12 + 2,27X$
NDVI	0,800	0,640	$y = 0,18 + 4,38X$
TTVI	0,786	0,618	$y = 0,84 + 2,12X$
CTVI	0,786	0,618	$y = 0,84 + 2,12X$
ACP ₁	0,689	0,475	$y = -0,19 - 1,84X$
TVI	0,786	0,618	$y = 0,84 + 2,12X$
ACP ₂	0,524	0,275	$y = -0,12 + 0,8X$
PVI ₁	0,670	0,449	$y = 0,1 + 0,87X$
NPCRI	-0,640	0,410	$y = 0,37 - 1,7X$
ACP ₃	-0,462	0,213	$y = 0,03 - 0,27X$
PVI ₃	0,756	0,571	$y = -0,1 + 0,7X$
DVI	0,639	0,409	$y = 0,0 + 1,2X$
PVI ₀	0,674	0,455	$y = 0,49 + 5,62X$
PVI ₂	0,205	0,042	$y = 0,1 + 0,26X$
RVI	-0,757	0,573	$y = 0,62 - 3,59x$
Tasseled Cap	-0,552	0,304	$y = -0,44 - 1,25X$
NRVI	-0,800	0,640	$y = -0,18 - 4,38X$
SI	0,715	0,511	$Y = 0,89 + 0,55X$
NDBSI	-0,808	0,653	$y = 0,25 - 4,05X$
ALME	-0,334	0,112	$y = 0,99 - 7,88X$
ATSAVI	0,664	0,440	$y = -0,03 + 2,82X$
BSI	-0,786	0,617	$y = 0,49 - 13X$
NDBIa2	-0,735	0,541	$y = 4,6E4 - 7,02E4X$

y = variable dependiente; x = variable independiente

En lo que respecta al análisis de la regresión lineal con los productos derivados de S2, el análisis arrojó que el valor de pendiente fue diferente a 0 en todos los casos, es decir que, existe dependencia entre las variables. Bajo este criterio, NDBSI es el más dependiente (83,72) al presentar la línea más inclinada, con dependencia de tipo directa (positiva), resultado seguido por NDVI (3,81) y SAVI (1,92) (Tabla 12).

Estableciendo el análisis solo en coeficientes de correlación (R), los mayores resultados fueron definidos por NDVI (0,840), seguido muy de cerca por el grupo de TTVI (0,836), CTVI (0,834), PVI₃ (0,829) y SI (0,829). Otras técnicas de PDI que presentaron altas correlaciones fueron PVI₀ (0,721), PVI₁ (0,719) y SAVI (0,697) respectivamente. En el mismo orden de ideas, índices como ACP₃, NDBSI, DVI Y ATSAVI presentaron correlaciones inferiores a 0,653. NRVI presentó -0,840 es decir, el peor coeficiente. Los resultados restantes presentaron correlaciones negativas.

En cuanto al valor de los R², se encontró que NDVI Y NRVI presentaron los mejores valores con 0,705 seguido de TTVI y CTVI con 0,699 y 0,695 respectivamente. TVI arrojó el peor R² (0,021).

Entre todos los procesamientos digitales realizados, el NDVI es el que está más fuertemente determinado por la distancia espectral euclidiana del suelo con el coeficiente de determinación de 0,705, y la más alta correlación positiva con 0,840, lo que la convierte en la segunda alternativa para la cartografía EAER para S2 (Figura 7c).

Posteriormente, se elaboró a partir de 100 muestras de valores de NDVI la curva ROC. Los umbrales 0,9 (U1) y 0,8 (U2) indicaron 0,3864 y 0,2377 de NDVI, respectivamente. Ambos umbrales representaron un buen balance entre sensibilidad y especificidad, es decir un acercamiento al más ideal (100%), que permitieron generar el mapa (Figura 7, inferior), arrojando como resultados: “áreas erosionadas” (495,80 ha), “riesgo de erosión” (379,99 ha) y “sin erosión” (5 706,24 ha).

El cruce CSMV–EAER2 procedente de S2, señaló que la superficie ocupada por “áreas erosionadas” coincidió en 403,85 ha con suelos desnudos e interceptó a infraestructura en 80,21 ha, a vegetación alta en 0,09 ha y a vegetación baja en 11,65 ha. Por su parte “riesgo de erosión”, interceptó a vegetación alta con 0,21 ha, a baja en 106,68 ha, a suelos desnudos con 222,30 ha, y a infraestructura con 50,80 ha. Finalmente, las áreas sin erosión sumaron 5 544,39 ha (vegetación alta y baja), solo 55,47 ha fueron intersectadas con suelos desnudos y 106,38 ha con infraestructuras (Tabla 13).

Tabla 12. Regresiones lineales Sentinel 2.

PDI	R	R ²	Ecuación
Suma ACP	-0,762	0,580	$y = 0,22 - 1,3X$
SAVI	0,697	0,485	$y = 0,03 + 1,92X$
NDVI	0,840	0,705	$y = 0,02 + 3,81X$
TTVI	0,836	0,699	$y = 0,73 + 1,89X$
CTVI	0,834	0,695	$y = 0,73 + 1,89X$
ACP₁	-0,789	0,623	$y = 0,21 - 1,04X$
TVI	-0,005	2,104E-5	$y = 1,7 - 5,66X$
ACP₂	-0,307	0,094	$y = 0,04 - 0,39X$
PVI₁	0,719	0,518	$y = 0,06 + 0,79X$
NPCRI	-0,199	0,039	$y = 0,31 - 0,31X$
ACP₃	0,653	0,426	$y = -0,02 + 0,12X$
PVI₃	0,829	0,687	$y = -0,09 + 0,52X$
DVI	0,596	0,356	$y = 0,03 + 0,98X$
PVI₀	0,721	0,521	$y = 0,11 + 1,55X$
PVI₂	-0,008	6,258E-5	$y = 0,08 - 6,21E-3X$
RVI	-0,816	0,666	$y = 0,84 - 3,35x$
Tasseled Cap	-0,600	0,360	$y = 4,92E3 - 9,55E3X$
NRVI	-0,840	0,705	$y = 0,02 - 3,81X$
SI	0,829	0,687	$Y = 0,84 + 0,62X$
NDBSI	0,636	0,405	$y = -4,79 + 83,72X$
ALME	-0,483	0,233	$y = 2,45 - 10,99X$
ATSAVI	0,535	0,287	$y = -0,08 + 1,76X$
BSI	-0,696	0,482	$y = 9,4E3 - 2,14E4X$

y = variable dependiente; x = variable independiente

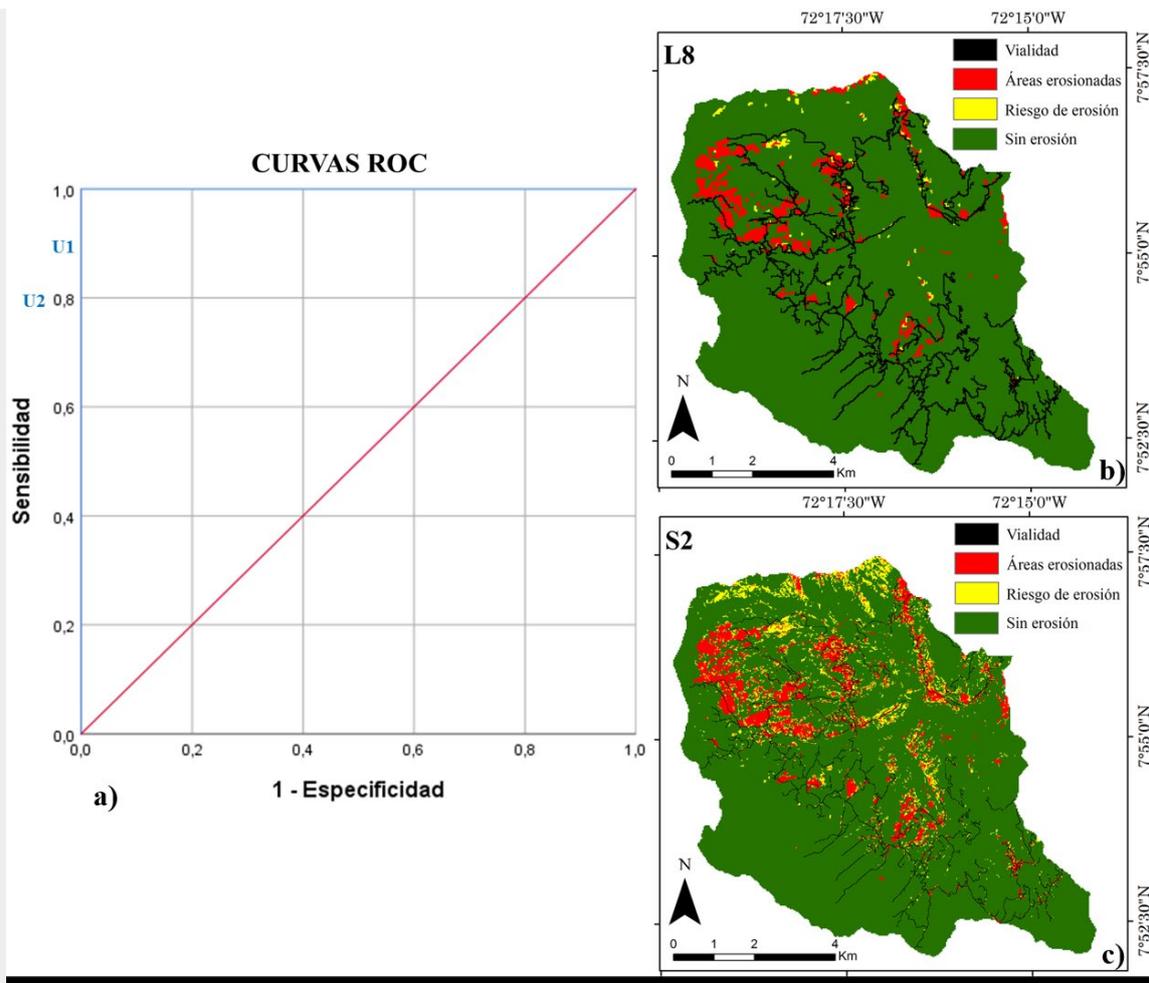


Figura 7. a) curvas ROC (U_1 y U_2 = umbrales 0,9 y 0,8; b) EAER 2 Landsat 8; c) EAER 2 Sentinel 2 (elaboración propia).

Tabla 13. Tabulaciones cruzadas de las cartografías CSMV–EAER2 en hectáreas (elaboración propia).

		EAER2			
		Vialidad	Áreas erosionadas	Riesgo erosión	Sin erosión
Clasificación supervisada Landsat 8	Vialidad	592,38	0,00	0,00	0,00
	Vegetación alta	0,00	0,00	0,00	3 062,88
	Vegetación baja	0,00	0,00	0,18	1 011,15
	Suelos desnudos	0,00	291,60	43,56	342,99
	Infraestructura	0,00	29,88	3,87	1 410,12
Clasificación supervisada Sentinel 2	Vialidad	206,58	0,00	0,00	0,00
	Vegetación alta	0,00	0,09	0,21	3 208,94
	Vegetación baja	0,00	11,65	106,68	2 335,45
	Suelos desnudos	0,00	403,85	222,30	55,47
	Infraestructura	0,00	80,21	50,80	106,38

Con el propósito de entender el RPEH como indicador de sensibilidad a erosión, en primer lugar, se analizaron 20 pixeles de suelos desnudos (muestras) (Figura 8), a partir de la relación de las categorizaciones temáticas definidas en los EAER, la clasificación FAO *et al.* ⁽⁵⁵⁾ y valores de RPEH (Tablas 14 y 15). Es necesario acotar que debido a que

las muestras de suelos desnudos y expuestos a erosión fueron identificadas a partir de una imagen de mayor resolución, por tanto, sólo deberían ser clasificados como “áreas erosionadas” o “en riesgo” en los EAER (sin erosión, sería una imprecisión generada por el cambio de resolución espacial o definición de umbrales). En segundo lugar, se totalizaron cantidades de posible pérdida de suelo para “áreas erosionadas” y “en riesgo” a fin de evidenciar el enfoque con más pérdidas.

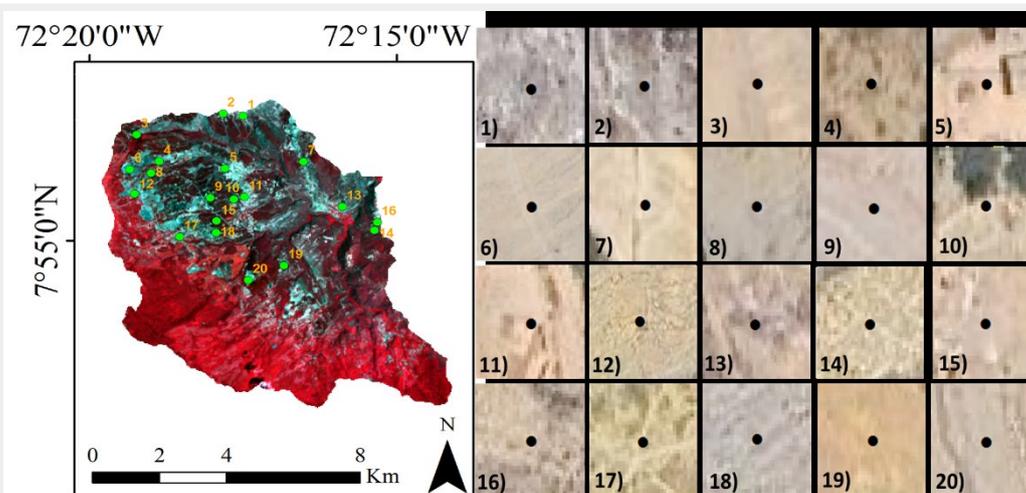


Figura 8. Muestras de suelos erosionados ubicados en composición falso color (elaboración propia).

Tabla 14. Comparación de muestras de suelos desnudos con RPEH y los mapas EAER (elaboración propia).

Muestra	Long.	Lat.	Landsat 8		Sentinel 2		RPEH Mg ha ⁻¹ año ⁻¹	FAO <i>et al.</i> (54)
			EAER1	EAER2	EAER1	EAER2		
1	-72,292	7,953	Ae	Ae	Ae	Ae	91,42	Alta
2	-72,297	7,954	Se	Ae	Ae	Ae	29,31	Moderada
3	-72,321	7,948	Ae	Se	Ae	Re	94,32	Alta
4	-72,315	7,940	Ae	Ae	Ae	Ae	5,99	Ligera
5	-72,297	7,938	Ae	Ae	Ae	Ae	58,47	Alta
6	-72,323	7,938	Ae	Ae	Ae	Ae	60,43	Alta
7	-72,276	7,939	Ae	Se	Ae	Ae	27,58	Moderada
8	-72,317	7,936	Ae	Ae	Ae	Ae	189,14	Alta
9	-72,322	7,930	Ae	Ae	Ae	Ae	30,36	Moderada
10	-72,301	7,929	Ae	Ae	Ae	Ae	59,28	Alta
11	-72,295	7,929	Ae	Se	Ae	Re	58,55	Alta
12	-72,292	7,929	Ae	Ae	Ae	Ae	58,16	Alta
13	-72,265	7,926	Ae	Ae	Ae	Ae	26,59	Moderada
14	-72,257	7,919	Se	Ae	Se	Ae	83,73	Alta
15	-72,299	7,922	Ae	Se	Ae	Se	59,59	Alta
16	-72,256	7,922	Ae	Ae	Ae	Ae	82,14	Alta
17	-72,309	7,918	Se	Ae	Ae	Ae	191,29	Alta
18	-72,299	7,919	Ae	Ae	Ae	Ae	59,89	Alta
19	-72,281	7,909	Ae	Se	Ae	Re	29,43	Moderada
20	-72,291	7,905	Ae	Ae	Ae	Ae	60,62	Alta

Ae: Áreas erosionadas; Re: Riesgo de erosión; Se: Sin erosión

Los resultados de dichos análisis permitieron definir en primer lugar, para L8 (Tabla 14), una mayor cantidad de aciertos de las clasificaciones en EAER1 (17 de las 20 evaluadas), a diferencia de la EAER2 (15 de 20 evaluadas). De modo más específico, se halló para EAER1, imprecisiones en las muestras 2, 14 y 17 las cuales fueron consideradas como “sin erosión”, pues como se observa en la imagen de muy alta resolución (Figura 8 – 2, 14 y 17), las mismas se encuentran totalmente descubiertas. Dichos resultados constituyeron incongruencias generadas en el cálculo de la imagen de distancia espectral euclidiana a suelos desnudos, por cuanto su categorización debió ser “áreas erosionadas” o en su defecto “áreas en riesgo”, es decir valores menores a 0,1115 de distancia espectral, umbral establecido por medio de la curva ROC (nuevo umbral). Similarmente, el EAER2, evidenció contradicciones al catalogar a las muestras 3, 7, 11, 15 y 19, en la categoría “sin erosión”, aun cuando están totalmente descubiertas (Figura 8 – 3, 7, 11, 15 y 19), dichos píxeles debieron ser menor al valor 0,3162 de NDVI, umbral definido por la curva ROC. En este caso es necesario acotar las pocas hectáreas “en riesgo” existentes en esta cartografía, que también influyó en la poca probabilidad de su aparición como clase detectada.

Teniendo en cuenta el desacierto de las muestras en ambos resultados EAER, se pudo observar la condición de riesgo potencial de los 20 sitios muestrales. Para el caso de la muestra 14 de EAER1, la degradación potencial considerada es alta con 83,73 Mg ha⁻¹ año⁻¹, de igual modo, la muestra 15 de la segunda cartografía, denotó 59,59 Mg ha⁻¹ año⁻¹ de posible pérdida, representativa de una degradación alta (de la misma forma se pueden interpretar las muestras restantes). En cuanto al resto de muestras que no tuvieron imprecisiones en sus clasificaciones cualitativas, se pudo observar diferentes valores de pérdida de suelos que va de potencial degradación ligera a alta, siendo la gran mayoría alta. Finalmente, las pérdidas de suelo de las áreas erosionadas y en riesgo de erosión en EAER1 fueron considerablemente mayores a EAER2 (tomando en cuenta todos los píxeles), debido principalmente a la gran sobrestimación de las áreas en riesgo en EAER1 en contraste a la baja superficie estimada de estas en EAER2 (Tabla 15).

Tabla 15. Comparación de áreas erosionadas y en riesgo en EAER 1 y 2 Landsat 8 OLI (elaboración propia).

Clase	hectáreas	Clase	hectáreas
Áreas erosionadas 1	2 068,91	Áreas erosionadas 2	321,48
Riesgo de erosión 1	239,67	Riesgo de erosión 2	47,61

En lo que respecta a este análisis sobre los resultados de S2 (Tabla 14), los mismos permitieron definir en primer lugar, un desacierto en EAER1 (19 de las 20 evaluadas) y la identificación de tres muestras en EAER2 como “riesgo de erosión” y una muestra “sin erosión”. De modo más específico, se halló para EAER1, imprecisión en la muestra 14 la cual fue considerada como “sin erosión”, pues como se observa en la imagen de muy alta resolución (Figura 8 – 14), la misma se encuentra totalmente descubierta. Dicho resultado constituyó una incongruencia generada en el cálculo de la imagen de distancia espectral euclidiana a suelos desnudos, por cuanto su categorización debió ser “área erosionada” o en su defecto “área en riesgo”, es decir valores menores a 0,1839 de distancia espectral, umbral establecido por medio de la curva ROC (nuevo umbral). Similarmente, el EAER2, evidenció contradicción al catalogar a la muestra 15, en la categoría “sin erosión”, aun cuando está totalmente descubierta (Figura 8 –15), dicho pixel debió ser menor al valor 0,3864 de NDVI, umbral definido por la curva ROC. En este caso es necesario acotar también, las pocas hectáreas “en riesgo” existentes en esta cartografía.

Teniendo en cuenta el desacierto de las muestras en ambos resultados EAER, se pudo observar la condición de riesgo potencial de los 20 sitios muestrales. Para el caso de la muestra 17 (Área erosionada), la degradación potencial considerada es alta con 191,29 Mg ha⁻¹ año⁻¹, de igual modo, la muestra 8 denotó 189,14 Mg ha⁻¹ año⁻¹ de posible pérdida, representativa también de una degradación alta (de la misma forma se pueden interpretar las muestras restantes). En cuanto al resto de muestras que no tuvieron imprecisiones en sus clasificaciones cualitativas, se pudo observar diferentes valores estimados de pérdida de suelo (Tabla 14) que va de potencial degradación ligera a alta, siendo la gran mayoría alta. Finalmente, las áreas erosionadas y en riesgo de erosión en EAER1 fueron considerablemente mayores al segundo mapa (considerando todos los píxeles), debido principalmente a la gran sobrestimación de las áreas en riesgo en EAER1 en contraste a la baja superficie estimada de estas en EAER2 (Tabla 16).

Tabla 16. Comparación de áreas erosionadas y en riesgo en EAER 1 y 2 Sentinel-2 (elaboración propia).

Clase	hectáreas	Clase	hectáreas
Áreas erosionadas 1	1 240,13	Áreas erosionadas 2	495,8
Riesgo de erosión 1	917,43	Riesgo de erosión 2	379,99

3. Discusión

Aunque la metodología RPEH data del año 1980, se mantiene vigente dado que resulta ideal su aplicación cuando no se dispone de información adecuada de precipitación, evapotranspiración, litología y suelos, requeridos, por ejemplo, en metodologías como USLE, la planteada por Pacheco ⁽⁶¹⁾ o más recientemente por Nasir *et al.* ⁽¹⁰⁷⁾. Por el contrario, disponibilidad de información mínima como precipitación mensual, MDE gratuitos, y cartografía de suelos a nivel de reconocimiento, le otorga plausibilidad en su ejecución, sencillez y robustez científica. Es importante destacar, además, que gran parte de los modelos empleados actualmente requieren la inclusión de variables poco prácticas ⁽¹⁰⁸⁾, lo que pone de manifiesto la necesidad de nuevos enfoques en la modelización de los procesos de erosión ⁽¹⁰⁷⁾.

Un caso que ilustra lo mencionado previamente es la comparación entre los resultados de erosión potencial obtenidos en este estudio y los de Condori-Tintaya *et al.* ⁽¹⁰⁹⁾ y Nasir *et al.* ⁽¹⁰⁷⁾. Mientras que los primeros utilizaron información sobre la estructura del suelo y calcularon un factor más complejo de longitud y pendiente basándose en ecuaciones, los segundos emplearon un enfoque de toma de decisiones multicriterio que implicaba la elaboración de 15 variables y un proceso de jerarquía analítica.

La accesibilidad a los SIG e imágenes de sensores remotos, han tenido un gran impacto en el modelado de la erosión. Los modelos ahora pueden ser aplicados a gran escala y de manera distribuida con relativa facilidad, pudiendo presentar resultados en píxeles que permiten identificar dónde ocurren, junto con su magnitud y a diferentes escalas temporales y espaciales ⁽⁵³⁾. No obstante, también se reconoce que la capacidad predictiva de los modelos de erosión a gran escala no es la mejor. Por ello, Alewell *et al.* ⁽¹¹⁰⁾ han argumentado que los mismos no deben esforzarse para que hagan predicciones precisas de pérdidas de suelo, sino para que exploren escenarios y se centren en comprender las diferencias relativas de las tasas de erosión, lo que ayudaría a identificar las áreas propensas a estos procesos de degradación, objetivo de este estudio.

De igual modo, imágenes de muy alta resolución pueden utilizarse para probar modelos de erosión, acción que no ha sido desarrollada de forma amplia con tal fin aún por los investigadores, siendo quizás Fischer *et al.* ⁽⁵²⁾, los primeros en basarse completamente en su interpretación, encontrando resultados alentadores, como alta correlación ($R^2 = 0,91$) de clases de erosión definidas visualmente con pérdidas de suelo modeladas, permitiéndoles definir un enfoque semicuantitativo de evaluación, mucho más sencillo que a partir del planteamiento de pruebas de hipótesis ⁽⁵³⁾.

Otras razones que reforzarían su empleo, es que excluye las especulaciones sobre la validez de las predicciones de los modelos, así como también, que permiten identificar escenarios que conducen a pérdidas de suelo altas o bajas ⁽⁵⁴⁾. En este estudio, no se realizó un enfoque semicuantitativo debido que a las muestras seleccionadas no les fue calculado valores de pérdida de suelo real de forma independiente con el cual poder determinar R^2 , lo que denota una evaluación eminentemente cualitativa para abordar análisis comparativos.

La clave para continuar con la identificación de EAER radica en la extracción precisa de la cobertura vegetal y usos de la tierra ⁽¹¹¹⁾. Siendo en este caso, la búsqueda de la mayor precisión posible de suelos desnudos con los cuales se desprendió la distancia espectral euclidiana para la posterior definición de umbrales en curvas ROC, ya que la presencia de cobertura vegetal refleja la habilidad de resistencia a la erosión o a su riesgo ⁽⁷⁰⁾.

En lo que respecta a las tabulaciones cruzadas CSMV-EAER, estas permitieron corroborar, iniciando con “áreas erosionadas” y su intersección con suelos desnudos, que hubo mayores intersecciones en los EAER1, (642,24 en L8 y 635,44 ha en S2), en contraste a EAER2, que presentaron 291,60 en L8 y 403,85 ha en S2, resultados que evidencian una mayor exhaustividad de los primeros, debido a su procedencia de la distancia espectral euclidiana, que tiende a englobar píxeles más similares a la categoría “áreas erosionadas”. En lo que respecta al cruce “áreas erosionadas” y vegetaciones baja y alta, los EAER2 arrojaron menores intersecciones, por lo que estos resultados suprimen la incongruencia de este cruce presentado en los EAER1 (no tiene sentido la existencia de cruces áreas erosionadas con vegetación alta, principalmente). No obstante, aunque existen diferencias en los cruces (resultados que se podrían afinar con la intersección con cartografía más detallada, elaborada por interpretación visual), ambas cartografías resultan complementarias para la comprensión del riesgo de erosión en un área.

En cuanto a la elección de umbrales en curvas ROC, dado a que la sensibilidad/especificidad varía, podrían seleccionarse otros con mayor o menor poder de discriminación, como los definidos en este estudio que permitieron corregir la excesiva inclusión de píxeles como áreas erosionadas y en riesgo (asumiéndose otros % de error de omisión). La escogencia de dos con alta sensibilidad recíprocamente permitiría obtener alta probabilidad de clasificar correctamente a un píxel cuya situación real sea definida como positiva. Por otro lado, la ventaja de la curva ROC radica en que emplea todos los posibles puntos de corte en la base de datos con lo que se determinan los mejores umbrales, lo que indica que esta prueba posee un poder de correcta clasificación muy útil ⁽¹¹²⁾.

La forma presentada de identificar EAER difiere, por tanto, de la postura de asociar valores más altos de pérdida ($Mg\ ha^{-1}\ año^{-1}$) arrojados por USLE y/o modelos afines, como una medida indirecta de diversos grados de riesgo de erosión, ejemplos: ^(1,7) sustentada en la lógica que valores bajos son menos vulnerables y altos están referidos a más sensibilidad a erosión ⁽¹¹³⁾. También contrasta con la idea de obtenerla a través de jerarquización y

posterior zonificación, resultante de intersectar diversos gradientes de pendiente provenientes de un MDE o usos de la tierra con pérdidas de suelos^(111, 113, 114).

La equivalencia entre técnicas de percepción remota, a través de regresión lineal, fue puesta de manifiesto por Ngandam *et al.*⁽¹⁵⁾, planteando como variable dependiente un índice de vegetación, lo que depositó en dicho producto, una exagerada confiabilidad como predictor. Caso contrario al diseñado en este estudio, el cual fue definido sobre distancia espectral de suelos desnudos y que fue probado por Camargo *et al.*⁽¹⁰⁾.

Las relaciones entre resultados cualitativos y cuantitativos, permite establecer una relación bidireccional de análisis complementario, en primer lugar, los EAER ayudan a identificar áreas que presentan áreas erosionadas o señalan aquellas en riesgo en las cuales se puede hacer la interpretación de pérdidas de suelo y, en segundo lugar, permite establecer la relación inversa, es decir, la observación de posibles pérdidas altas y moderadas identificadas por el RPEH, proporciona información de lo que sucede en dichas áreas desde una óptica cualitativa.

Para poder tener un panorama más amplio y determinar posible existencia de erosión o áreas que podrían estar sujetas a ella, se sugiere identificar “áreas erosionadas” y “en riesgo” con ambas cartografías, consideración sustentada en la identificación de posibles diferencias sustanciales en posibles puntos de interés y en los aspectos encontrados en este estudio a partir de las dos imágenes con diferente resolución espacial.

Partiendo del estudio de Batista *et al.*⁽⁵³⁾, sobre el hecho de que los diferentes modelos de erosión existentes en la actualidad no se superan sistemáticamente entre sí, se comparte la premisa de que es la calibración el único mecanismo para mejorar sus desempeños (mejora de la comprensión conceptual de sus funcionamientos). Por tanto, se rechaza la noción de que estos se puedan validar (sino por el contrario evaluar), enfatizándose la necesidad de definir pruebas de ajuste (o de grados de confianza), basado en las múltiples fuentes de datos, que permitan una investigación amplia de la utilidad y consistencia de las metodologías desarrolladas; teniendo presente que entre más rigurosas sean estas pruebas, más probable es que sean encontrados rendimientos deficientes (conciencia crítica sobre los métodos).

Este estudio pretende aportar una categorización de los riesgos de erosión basada en una estructura cualitativa con apoyo cuantitativo de riesgo potencial, ofreciendo los resultados en modelos distribuidos de celdas de 30 m² (L8) y 10 m² (S2), los cuales podrían servir para impulsar estudios con más detalle y/o medidas de planificación y conservación de suelos en áreas de interés. Previamente a ello, sobre las imágenes a emplear, deben realizarse análisis exploratorios de datos espaciales (ESDA), a fin de conocer sus histogramas, medidas de tendencia central, dispersión, existencia de datos atípicos o faltantes, y el correcto rango de valores de reflectancias.

Partiendo de análisis comparativos entre las ABC de cada una de los EAER, se puede corroborar la mayor precisión en los EAER2 sobre los EAER1. Así por ejemplo el EAER2 derivados del NDVI para S2 fue de 100% en contraste al 97,4% proveniente de la distancia espectral euclidiana. De igual modo aconteció con L8, donde el procedente del NDVI fue de 100% y el derivado de la distancia espectral euclidiana fue de 79,8%. Por otro lado, una comparación entre los R y R² posicionan al EAER2 procedente de S2 como un resultado más sólido a los restantes (incluido al EAER1

derivado de S2). Ahora bien, resulta necesario recordar que las distancias espectrales a suelos desnudos constituyen las variables independientes en cada una de las regresiones lineales para escoger la técnica PDI, por tanto, resulta lógico que las ABC de los EAER2 sean superiores a los primeros. De esto modo se configura a los EAER1 como productos exhaustivos con sus respectivos errores inherentes, los cuales estadísticamente son reducidos en EAER2, conformando así un producto complementario en el análisis de áreas con procesos de erosión y/o en riesgo.

Las diferencias presentadas entre las categorías EAER de ambas imágenes, obedecen a varios motivos, en primer lugar, la mejor resolución espacial de S2 permitió precisar el área destinada a vialidad, por cuanto áreas que formaban parte de esta categoría en L8 pudieron anexarse a las categorías restantes, aumentando la extensión de estas en S2. En segundo lugar, aunque la diferencia de fechas de captura entre una imagen y otra es de 6 días, y los valores de azimut, elevación solar y ángulo cenital son similares (analizados para este estudio), esas pequeñas diferencias se trasladaron a las imágenes con correcciones de sombreado topográfico y subsecuentemente a los EAER1, pues sus umbrales y valores de distancia espectral y NDVI asociados resultaron diferentes, 0,75 (0,1002) y 0,8 (0,1115) en L8 y 0,85 (0,1462) y 0,9 (0,1839) en S2. No obstante, al hacer revisiones visuales y cotejo de las ABC, se puede determinar al generado por S2 como un producto más preciso (97,4%). De igual manera aconteció con las diferencias en EAER2, pues sus umbrales y valores de distancia espectral y NDVI asociados también resultaron diferentes, 0,75 (0,1002) y 0,8 (0,1115) en L8 y 0,85 (0,1462) y 0,9 (0,1839) en S2. Sin embargo, al hacer revisiones visuales y cotejo de las ABC, se puede determinar al generado por S2 como un producto con mayor precisión (100%).

Finalmente, el NDVI, resultó ser la mejor opción, definidas por las regresiones lineales para establecer el EAER2, a diferencia de Camargo *et al.*⁽¹⁰⁾ en el que el mejor resultado fue la suma de ACP. Se corrobora por tanto el planteamiento de no utilizar algún índice en particular como una receta, sin antes realizar las comparaciones de los desenvolvimientos de cada uno de ellos en las áreas, pues las características de las reflectancias de las coberturas y sus distribuciones espaciales ejercen influencia en los resultados.

4. Conclusiones y recomendaciones

Dado que pueden existir limitaciones para comprender los riesgos de erosión y la escala a la que pueden aplicarse las técnicas de su evaluación, resulta perentorio realizar una revisión teórica sobre el suelo, su importancia y conservación, la erosión hídrica y los factores que contribuyen a ella, sus métodos de estudio, y el abordaje metodológico propuesto basado en sensores remotos y otros datos asequibles. La comprensión de dichos basamentos permitirá entender de mejor manera la erosión hídrica y abordar la identificación de las áreas erosionadas y su riesgo.

Usar imágenes satelitales permite realizar investigaciones sobre erosión tanto de forma cualitativa como cuantitativa; sin embargo, su utilización debe hacerse con cuidado, dado que un uso irreflexivo, puede conducir a sobreestimaciones o subestimaciones. También, se debe considerar el uso de imágenes de muy alta resolución, como mecanismo para evaluar el performance de los modelos.

Recurrir a imágenes de mayor resolución o cubrir extensiones más grandes, es un costo computacional mayor dado a que implican más cantidades de datos. Esta situación se podría superar utilizando plataformas de computación en nube como

Google Earth Engine (GEE), que pueden computar y procesar grandes volúmenes de datos geoespaciales en intervalos de tiempo muy cortos y que han sido aplicados recientemente a la preparación de variables requeridas por métodos como USLE y RUSLE ^(115; 116), por lo que su aplicación con los modelos desarrollados en este estudio también resulta plausible.

Aunque los avances tecnológicos son evidentes, no hay que olvidar que los modelos de erosión no son necesariamente infalibles ni están libres de defectos, reconocerlos mejora la actitud hacia la evaluación de los mismos y cambia la forma en que se caracterizan y comunican sus desempeños, lo que conduce en última instancia, a una mejor comprensión de la erosión del suelo.

Este estudio constituye una respuesta a la carencia de información de precipitación y suelos, necesaria en metodologías paramétricas, por lo que se asumió la premisa de resolverla basado sólo con insumos disponibles digitales gratuitos, constituyendo de esta forma, una solución que podría asociarse con variables derivadas de MDE (ejemplo: índices de humedad), o de otras cartografías categóricas o continuas. No obstante, independientemente de los métodos a emplearse, no debe descartarse el levantamiento de mediciones georreferenciadas en campo (cuando sea posible) de las características de la erosión, a fin de poder ampliar la evaluación de los modelos.

La asociación de los resultados hallados por medio del análisis de RPEH y las cartografías EAER y otros datos, podrían ayudar a considerar, a gran visión, medidas necesarias en cuanto a conservación de suelos, así como también su aplicación en la planificación del territorio para el desarrollo socioeconómico ambientalmente sostenible y la determinación de áreas susceptibles a procesos en laderas. Los resultados indican que existe una relación entre las diferentes técnicas de procesamiento digital, los umbrales de clasificación para la identificación precisa de áreas erosionadas y en riesgo de erosión y los valores de RPEH.

Ahora bien, en cuanto a la escogencia de la cartografía EAER a emplear o recomendar, los resultados obtenidos permiten indicar que deben ser usadas de forma complementaria en un área de interés, pues los EAER derivados de distancia espectral euclidiana, conllevan a incluir mayores extensiones de áreas erosionadas y en riesgo. Por su parte los EAER derivados de técnicas de procesamiento digital de imágenes, presentan menos extensiones de estas categorías, por lo que un uso complementario puede establecer un escenario extremo y otro más conservador. Dentro de este apartado también resulta necesario comentar que los resultados se pueden afinar a partir de la aplicación de máscaras (concepto SIG) que cubran las infraestructuras urbanas o la vialidad, por mencionar algunos casos.

Áreas provistas de vegetación, pero con riesgo de erosión identificadas en el área de estudio son importantes en términos de decisiones de gestión ambiental. Los resultados indican aquellas áreas que son intrínsecamente susceptibles a la erosión, pero que actualmente están protegidas por vegetación. Por tanto, es necesario diseñar estrategias adecuadas para estas con el fin de proteger la cubierta vegetal actual, conclusión extrapolable a otras áreas de interés.

El análisis relacional entre las muestras establecidas como verdad-terreno (seleccionadas por interpretación visual de imágenes de muy alta resolución), con las establecidas por los métodos cartográficos propuestos, permitió evaluar acuerdos y desacuerdos de las metodologías EAER. Estas se pueden usar de forma complementaria, asociada a mapas de coberturas por medio de tabulaciones cruzadas,

a un tamaño de área mínima de interés, o a un rango específico de pendiente o humedad, análisis que podría ayudar a definir la consideración o no, del establecimiento de medidas de conservación de suelos. También se podría asociar los resultados de las muestras a valoraciones de pendiente de la metodología RPEH, de esta forma se obtendrían mejores correlaciones.

Finalmente, podría ser útil determinar el impacto relativo de los distintos escenarios de uso y gestión del suelo, así como con fines comparativos con posibles escenarios en el marco del cambio climático, pues se argumenta que este aumentará las áreas erosionadas en el futuro, especialmente cuando se prevé un aumento de la intensidad de las precipitaciones y/o de la frecuencia de fenómenos extremos. Sin embargo, ciertos cambios en el uso del suelo que provocan reducción de la cubierta vegetal pueden tener un mayor impacto en el riesgo de erosión que cualquier cambio climático probable.

Si bien es cierto que los métodos para identificar EAER desarrollados son de carácter métrico-estático, aplicándolos sobre imágenes satelitales de diversas fechas, podrían ayudar a obtener series de tiempo que permitirían entender aún mejor la dinámica de los procesos de erosión y con ello, un mayor conocimiento para la conservación del suelo y la gestión de los ecosistemas (siempre que se tome en consideración aspectos como azimut, elevación solar, ángulo cenital y fecha de adquisición similares). También podrían ser replicables en otros espacios de forma semiautomatizada y fungir como primeros insumos para definir áreas a concentrar observaciones o establecer cartografía de tipos y grados de erosión.

Referencias

1. Mohammed S. Alsafadi K. Talukdar S. Kiwan S., Hennawi S., Alshihabi O., Sharaf M. y Harsanyie E. Estimation of soil erosion risk in southern part of Syria by using RUSLE integrating geo informatics approach. *Remote Sensing Applications: Society and Environment*. 2020 Nov; 20: 100375. <https://doi.org/10.1016/j.rsase.2020.100375>
2. Duguma TA. Soil erosion risk assessment and treatment priority classification: A Case Study on Guder Watersheds, Abay River Basin, Oromia, Ethiopia. *HELIYON*. 2022 Ago; 8(8): e10183. <https://doi.org/10.1016/j.heliyon.2022.e10183>
3. Ávila BD. y Ávila HF. Spatial and temporal estimation of the erosivity factor r based on daily rainfall data for the department of Atlántico, Colombia. *Ingeniería e Investigación*. 2015 May; 35 (2), 23-29. <https://revistas.unal.edu.co/index.php/ingainv/article/view/47773>
4. Omuto CT. y Vargas R. Soil loss atlas of Malawi. Food & Agriculture Organization. 2019. <https://openknowledge.fao.org/server/api/core/bitstreams/5fd68b91-a221-40fb-95cd-fe3d31f97394/content>
5. FAO y GTIS. Estado mundial del recurso suelo (EMRS). Resumen técnico. Roma. 2015. <https://openknowledge.fao.org/server/api/core/bitstreams/07a444e7-97a3-4e1f-b5d9-ddd84ad129c6/content>
6. Morales-Pavón J. Valdés-Rodríguez O. Servín-Martínez A. Hernández-Zárate J. Tejero-Andrade J. y Domínguez-Sánchez G. Plantas tropicales para contener suelo y evitar deslizamientos superficiales: estudio de caso *Ricinus communis* [Paper presentation]. II Reunión Internacional, Científica y Tecnológica; XXIX Reunión Científica y Tecnológica Forestal y Agropecuaria, Veracruz, México. 2016. https://www.researchgate.net/publication/309548349_Plantas_tropicales_para_contener_suelo_y_evitar_deslizamientos_superficiales_estudio_de_caso_Ricinus_communis

7. Chaudhary B. y Kumar S. Soil erosion estimation and prioritization of Koshalya-Jhajhara watershed in North India. *Indian Journal of Soil Conservation*. 2018; 46 (3): 305-311. https://www.researchgate.net/publication/330855428_Soil_erosion_estimation_and_prioritization_of_Koshalya-Jhajhara_watershed_in_North_India
8. Food and Agriculture Organization of the United Nations (FAO) (Ed.). Soil erosion: the greatest challenge to sustainable soil management. Food & Agriculture Organization. 2019. <https://openknowledge.fao.org/server/api/core/bitstreams/a268e967-a373-4a56-adac-ae1d7ab3567f/content>
9. Sestras P. Mircea S. Roșca S. Bilașco Ș. Sălăgean T. Dragomir L. Herbei M. Bruma S. Sabou C. Marković R. y Kader S. GIS based soil erosion assessment using the USLE model for efficient land management: a case study in an area with diverse pedo-geomorphological and bioclimatic characteristics. *Notulae Botanicae Horti Agrobotanici Cluj-Napoca*. 2023; 51(3): 13263. <https://doi.org/10.15835/nbha51313263>
10. Camargo-Roa CE. Pacheco-Angulo CE. Monjardin-Armenta SA. y López-Falcón R. Gómez- Orgulloso T. Identification of Eroded and Erosion Risk Areas Using Remote Sensing and GIS in the Quebrada Seca watershed. *Ingeniería e Investigación*. 2023 Ago; 43(3): e105003-e105003. <https://revistas.unal.edu.co/index.php/ingenv/article/view/105003>
11. Chuvieco E. Fundamentals of Satellite Remote Sensing an environmental Approach (2nd ed.). CRC Press Taylor and Francis Group. 2016 Mar. <https://doi.org/10.1111/phor.12184>
12. Beguería S. Identifying erosion areas at basin scale using remote sensing data and GIS: a case study in a geologically complex mountain basin in the Spanish Pyrenees. *International Journal of Remote Sensing*. 2006 Mar; 27(20): 4585-4598. <https://doi.org/10.1080/01431160600735640>
13. Rosales - Rodríguez CA. Hazard maps of shallow landslides associated with infiltration processes in the Sapuyes river basin. *Ingeniería e Investigación*. 2021 Abr; 41(1): e84611. <https://doi.org/10.15446/ing.investig.v41n1.84611>
14. Lillesand T. Kiefer RW. y Chipman J. Remote sensing and image interpretation (7th Ed). John Wiley & Sons. 2015. <https://www.wiley.com/en-sg/Remote+Sensing+and+Image+Interpretation%2C+7th+Edition-p-9781118343289>
15. Ngandam AH. Etouna J. Nongsi BK. Mvogo FA. y Noulaquape FG. Assessment of land degradation status and its impact in arid and semi-arid areas by correlating spectral and principal component analysis neo-bands. *International Journal of Advanced Remote Sensing and GIS*. 2016 Feb; 5(2): 1539 – 1560. <https://doi.org/10.23953/CLOUD.IJARSG.77>
16. Sartori A. Cano J. Montaner D. Mattar C. Moraga J. Alfaro W. Soto G. Morales L. Quintanilla O. Andrés E. Gavilán C. y Trujillo G. Reporte de Neutralidad en la Degradación de las Tierras (NDT) ante la Convención de las Naciones Unidas de Lucha Contra la Desertificación (CNULD) Estrategia Nacional de Cambio Climático y Recursos Vegetacionales (2017-2025) de Chile. Unidad de Cambio Climático y Servicios Ambientales (UCCSA), Gerencia de Desarrollo y Fomento Forestal (GEDEFF), Corporación Nacional Forestal (CONAF). 2018. https://redd.unfccc.int/uploads/4833_6_reporte_ldn__282ene2018_29_-_vfpc.pdf

17. Orr BJ. Cowie AL. Castillo VM. Chasek P. Crossman ND. Erlewein A. Louwagie G. Maron M. Metternicht GI. Minelli S. Tengberg AE. Walter S. y Welton S. Scientific Conceptual Framework for Land Degradation Neutrality. A Report of the Science-Policy Interface. United Nations Convention to Combat Desertification (UNCCD). 2017. https://www.unccd.int/sites/default/files/documents/2019-06/LDN_CF_report_web-english.pdf
18. Najafi M. Fakhireh A. Pahlavan A. Moradzadeh M. y Noori S. Determining the suitable indices for assessment of cover change in west of Karkheh river using satellite data. *Journal of Applied Science and Environmental Studies*. 2020 Ene; 3(1): 1-14. <https://doi.org/10.48393/IMIST.PRSM/jases-v3i1.18928>
19. Meinen BU. y Robinson DT. From hillslopes to watersheds: Variability in model outcomes with the USLE. *Environmental Modelling and Software*. 2021 Dic; 146: 105229. <https://doi.org/10.1016/j.envsoft.2021.105229>
20. Pal SC. y Chakraborty R. Modeling of water induced surface soil erosion and the potential risk zone prediction in a sub-tropical watershed of Eastern India. *Modeling Earth Systems and Environment*. 2019 Nov; 5: 369-393. <https://doi.org/10.1007/s40808-018-0540-z>
21. Li S. y Chen X. New bare-soil index for rapid mapping developing areas using landsat 8 data. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2014 Abr; 40(4): 139. <https://doi.org/10.5194/isprsarchives-XL-4-139-2014>
22. Romero W. Ramos R. Vázquez R. Arrogante P. y Arroyo R. Detección de deslizamientos de laderas por el método de regresión lineal utilizando imágenes Áster en la zona centro del estado de Guerrero, México [Paper presentation]. XXV Congreso de la Asociación de Geógrafos Españoles. Universidad Autónoma de Madrid, Madrid, Spain. 2017. https://www.age-geografia.es/downloads/Naturaleza_Territorio_y_Ciudad_AGE2017.pdf
23. Basu T. Das A. y Pal S. Application of geographically weighted principal component analysis and fuzzy approach for unsupervised landslide susceptibility mapping on Gish River Basin, India. *Geocarto International*. 2020 May; 37(5): 1294-1317. <https://doi.org/10.1080/10106049.2020.1778105>
24. Demaría MR. y Aguado I. Dinámica espacio-temporal del porcentaje de suelo desnudo en pastizales semi-áridos de Argentina. *GeoFocus*. 2013; 13(2), 133-157. <https://www.geofocus.org/index.php/geofocus/article/view/291>
25. Leal J. Pérez U. y Ortiz NE. Distribución espacial y temporal de deslizamientos (1999 – 2015) en la cuenca del río Combeima, Colombia. *Revista Geográfica Venezolana*. 2018 Ene; 59(2): 346 – 365. <https://www.redalyc.org/journal/3477/347760473008/html/>
26. Ganasri BP. y Ramesh H. (2016). Assessment of soil erosion by RUSLE model using remote sensing and GIS - A case study of Nethravathi Basin. *Geoscience Frontiers*. 2016 Nov; 7(6): 953 – 961. <http://dx.doi.org/10.1016/j.gsf.2015.10.007>
27. Opeyemi OA. Abidemi FH. y Otokiti V. (2019). Assessing the Impact of Soil Erosion on Residential Areas of Efon-Alaaye Ekiti, Ekiti-State, Nigeria. *International Journal of Environmental Planning and Management*. 2019; 5(1): 23–31. https://www.researchgate.net/publication/333532006_Assessing_the_Impact_of_Soil_Erosion_on_Residential_Areas_of_Efon-Alaaye_Ekiti_Ekiti-State_Nigeria

28. Plambeck NO. Reassessment of the potential risk of soil erosion by water on agricultural land in Germany: Setting the stage for site-appropriate decision-making in soil and water resources management. *Ecological Indicators*. 2020 Nov; 118: 106732. <https://doi.org/10.1016/j.ecolind.2020.106732>
29. Drzewiecki W. Wężyk P. Pierzchalski M. y Szafrńska B. Quantitative and qualitative assessment of soil erosion risk in Małopolska (Poland), supported by an object-based analysis of high-resolution satellite images. *Pure Appl. Geophys*. 2014 Abr; 171: 867-895. <https://doi.org/10.1007/s00024-013-0669-7>
30. Anderson W. y Jhonson T. Evaluating Global Land Degradation Using Ground-Based Measurements and Remote Sensing. In: E. Nkonya, V. Mirzabaev, A., J.Von Braun (Eds.), *Economics of Land Degradation and Improvement – A Global Assessment for Sustainable Development* (pp. 85 – 116). Cham, Switzerland: Springer Open. 2016. <https://doi.org/10.1007/978-3-319-19168-3>
31. Panagos P. Ballabio C. Borrelli P. Meusburger K. Klik A. Rousseva S. Tadic MP. Michaelides S. Hrabalíkova M. Olsen P. Aalto J. Lakatos M. Rymaszewicz A. Dumitrescu A. Begueria S. y Alewell C. Rainfall erosivity in Europe. *Science Total Environment*. 2015 Abr; 511: 801-14. <https://doi.org/10.1016/j.scitotenv.2015.01.008>
32. United Nations General Assembly (UNGA). (2015). Transforming Our World: the 2030 Agenda for Sustainable Development. Resolution adopted by the General Assembly on 25 September 2015. <https://sdgs.un.org/2030agenda>
33. Efiang J. Imoke D. Nwabueze J. y James S. Geo-spatial modelling of landslide susceptibility in Cross River State of Nigeria. *Scientific African*. 2021; 14: e01032. <https://doi.org/10.1016/j.sciaf.2021.e01032>
34. Naciones Unidas. Aplicación de datos del mes: Erosión del suelo. 2021 <https://www.un-spider.org/es/enlaces-y-recursos/fuentes-de-datos/daotm-erosion-suelo#USLE>
35. Tsegaye K. Addis HK. y Hassen EE. Soil Erosion Impact Assessment using USLE/GIS Approaches to Identify High Erosion Risk Areas in the Lowland Agricultural Watershed of Blue Nile Basin, Ethiopia. *International Annals of Science*. 2020 Nov; 8(1): 120-129. <https://doi.org/10.21467/ias.8.1.120-129>
36. Bastidas J. Nociones de hidrografía. Consejo de Publicaciones, Universidad de Los Andes. Mérida, Venezuela. 2007. 145 p. http://bdigital.ula.ve/storage/pdftesis/pregrado/tde_archivos/29/TDE-2010-05-20T05:09:40Z-1024/Publico/munoz_teran.pdf
37. Vivas L. Los Andes Venezolanos. Caracas: Academia Nacional de la Historia. 1992. <https://catalogosiidca.csuca.org/Record/CR.UNA01000086866/Similar>
38. Ewel, J. Madriz, A. y Tosi, J. Zonas de vida de Venezuela Memoria explicativa sobre el mapa ecológico. Caracas, Venezuela: Ediciones del Fondo Nacional de Investigaciones Agropecuarias. 1976. 270 pp.
39. La Marca, E. y Contreras, Y. Descubrimiento y reporte de las primeras estepas altiandinas en Venezuela. *Revista Ibero-Afro-Americana de Geografía Física e Ambiente* 2019; 1(1): 121-139. <https://dialnet.unirioja.es/servlet/articulo?codigo=9262239>

40. Alaska Satellite Facility. Terrain-Corrected (RTC). 2021 <https://www.asf.alaska.edu/sar-data/palsar/terrain-corrected-rtc/>
41. Instituto Geográfico Agustín Codazzi (IGAC). Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission) Versión 1.0. Bogotá: Instituto Geográfico Agustín Codazzi. 2013. <https://www.un-spider.org/sites/default/files/LDCM-L8.R1.pdf>
42. EUROPEAN SPACE AGENCY (ESA). Sentinel MSI, Product types, level 1C. 2014. <https://sentinels.copernicus.eu/web/sentinel/sentinel-data-access/sentinel-products/sentinel-2-data-products/collection-1-level-1c>
43. EUROPEAN SPACE AGENCY (ESA). Sentinel-2 user Handbook (2nd ed.). European Space Agency Standard Document. 2015. https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook
44. COPERNICUS. El programa Copernicus aplicado a la producción y gestión de la información geoespacial. Proyecto cofinanciado por la Comisión Europea mediante acuerdo 2018/SI2.810140/04. 2018. https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa_Marco_Copernicus_User_Uptake/12_Componente_InSitu.pdf
45. GIS AG MAPS. Landsat 8 & Sentinel-2 Rare Imagery Comparison. 2017. <https://www.gisagmaps.org/sentinel-2-landsat-8-cell-comp/#:~:text=Sentinel%2D2%20imagery%20cells%20differ,partial%20imagery%20within%20a%20cell>.
46. Camargo CE. Pacheco CE. y López R. Evaluación de métodos de corrección atmosférica y sombreado topográfico en imagen Landsat 8 OLI sobre un área montañosa semiárida. *UD y la Geomática*. 2021 Dic; 16: 23-39. <https://revistas.udistrital.edu.co/index.php/UDGeo/article/view/17040>
47. Teillet P. Guindon B. y Goodenough D. On the slope-aspect correction of multispectral scanner data. *Canadian Journal of Remote Sensing*. 1982; 8(2): 84-106. <https://doi.org/10.1080/07038992.1982.10855028>
48. Canty M. Image analysis, classification, and change detection in remote sensing with Algorithms for ENVI/IDL. CRC Press Taylor & Francis Group, LL. Boca Ratón, United States of America. 2009 Dic. 474 p. <https://doi.org/10.1201/9781420087147>
49. SIGIS. (2019). Digital Globe. <https://www.sigis.com.ve/>
50. Thenkabail PS. Remotely sensed data characterization, classification, and accuracies. CRC Press Taylor and Francis Group. 2015 Oct. 712p. <https://doi.org/10.1201/b19294>
51. Auerswald K. Fischer FK. Kistler M. Treisch M. Maier H. y Brandhuber R. Behavior of farmers in regard to erosion by water as reflected by their farming practices. *Science of the Total Environment*. 2018 Feb; 613-614: 1-9. <https://doi.org/10.1016/j.scitotenv.2017.09.003>
52. Fischer FK. Kistler M. Brandhuber R. Maier H. Treisch M. y Auerswald K. Validation of official erosion model-ing based on high-resolution radar rain data by aerial photo erosion classification. *Earth Surf. Process. Landforms*. 2017 Ago; 43(1): 187-194. <https://doi.org/10.1002/esp.4216>

53. Batista PVG. Davies J. Silva MLN. y Quinton JN. On the evaluation of soil erosion models: Are we doing enough? *Earth-Science Reviews*. 2019 Oct; 197: 102898. <https://doi.org/10.1016/j.earscirev.2019.102898>
54. Cardoza L. Aplicaciones de los sistemas de información geográfica en ingeniería civil utilizando el software GVSIG. Facultad De Ingeniería Y Arquitectura Escuela De Ingeniería Civil. Universidad de El Salvador. 2017. Trabajo Especial de Grado. 2017. 317 p. <https://catalogosiidca.csuca.org/Record/UES.157312>
55. Food and Agriculture Organization of the United Nations (FAO). Programa de Naciones Unidas para el Medio Ambiente (PNUMA), United Nations Educational, Scientific and Cultural Organization (UNESCO). (1980). Metodología provisional para la evaluación de la degradación de los suelos. Food & Agriculture Organization.
56. Guerra CA. Rosa IMD. Valentini E. Wolf F. Filipponi F. Karger DN. Nguyen Xuan A. Mathieu J. Lavelle P. y Eisenhauer N. Global vulnerability of soil ecosystems to erosion. *Landscape Ecology*. 2020 Mar; 35: 823-842. <https://doi.org/10.1007/s10980-020-00984-z>
57. Allafta H. y Opp C. Soil erosion assessment using the RUSLE model, remote sensing, and GIS in the Shatt Al-Arab Basin (Iraq-Iran). *Applied Sciences*. 2022 Jul; 12(15): 7776. <https://doi.org/10.3390/app12157776>
58. Al-Mamari M. Kantoush S. Al-Harrasi T. Al-Maktoumi A. Abdrabo K. Saber M. y Sumi T. Assessment of sediment yield and deposition in a dry reservoir using field observations, RUSLE and remote sensing: Wadi Assarin, Oman. *Journal of Hydrology*. 2023 Feb; 617(A): 128982. <https://doi.org/10.1016/j.jhydrol.2022.128982>
59. Rosales A. y García P. La cuenca hidrográfica y su gestión integral. In A. Gabaldón, A. Rosales, E. Buroz, J. Córdova, G. Uzcátegui y L. Iskandar (Eds.), Agua en Venezuela: una riqueza escasa. Fundación Polar, Caracas, Venezuela. 2015. 867-914 p. https://bibliofep.fundacionempresaspolar.org/media/1378185/agua_ti_o_indice.pdf
60. Arnoldus H. Methodology used to determine the maximum potential average annual soil loss due to sheet and rill erosion in Morocco. *Assessing Soil Degradation, FAO Soils Bulletin* (FAO). 1977; 34: 39-48.
61. Pacheco HA. El índice de erosión potencial en la vertiente norte del Waraira Repano, estado Vargas, Venezuela. *Cuadernos de geografía: revista colombiana de geografía*. 2012 Jul; 21(2): 85 – 97. <https://doi.org/10.15446/rcdg.v21n2.32215>
62. Muñoz JL. Morante J. y Miranda P. Erosión potencial por reconversión productiva en subcuenca Llay-Llay, Chile. aplicación de unidades de respuesta a la erosión. *Ciencia y Tecnología*. 2014; 7(2): 35-47. <https://dialnet.unirioja.es/servlet/articulo?codigo=5093737>
63. Hämmerly RC. Paris RC. y Paz-González A. Assessment of domain areas for precipitation and evapotranspiration on the left bank of the Paraná watershed at Argentine territory. I: Thiessen polygons and kriging. *Cadernos Lab. Xeolóxico de Laxe Coruña*. 2019 Dic; 41: 75 – 97. <https://doi.org/10.17979/cadlaxe.2019.41.1.5818>
64. Ministerio del Ambiente y de los Recursos Naturales Renovables (MARNR). Sistemas Ambientales Venezolanos. Regiones naturales: 7A Depresión del Táchira, Proyecto Ven/79/001, Código II-2-7A. Proyecto VEN/79/001. MARNR. 1983.

65. Quiñonez E. y Dal Pozzo F. Distribución espacial del riesgo de degradación de los suelos por erosión hídrica en el estado Lara, Venezuela. *Geoenseñanza*. 2008 Ene; 13(1): 59 – 70. <https://www.redalyc.org/articulo.oa?id=36014579006>
66. United States Department of Agriculture (USDA). Soil Texture Calculator. 2020. https://www.nrcs.usda.gov/wps/portal/nrcs/detail/soils/survey/?cid=nrcs142p2_054167
67. Food and Agriculture Organization of the United Nations (FAO), United Nations Educational, Scientific and Cultural Organization (UNESCO). Mapa mundial de suelos 1:5.000.0000. Food & Agriculture Organization. 1976.
68. Foster GR. McCool DK. Renard, KG. y Moldenhauer WC. Conversion of the universal soil loss equation to SI metric units. *J. Soil Water Conservation*. 1981 Nov; 36(6): 355 – 359. <https://www.jsowonline.org/content/36/6/355>
69. Alatorre LC. y Beguería S. (2009). Identification of eroded areas using remote sensing in a badlands landscape on marls in the central Spanish Pyrenees. *Catena*. 2009 Mar; 76(3): 182-190. <https://doi.org/10.1016/j.catena.2008.11.005>
70. Wang H. Zhao W. Li C. y Pereira P. Vegetation greening partly offsets the water erosion risk in China from 1999 to 2018. *Geoderma*. 2021 Nov; 401: 115319. <https://doi.org/10.1016/j.geoderma.2021.115319>
71. Ampudia A. Sánchez G. y Jiménez F. Precisión diagnóstica del MMPI-2 con la personalidad delictiva: un análisis con la curva ROC. *Revista de Psicología*. 2017, 35(1): 167-192. <http://dx.doi.org/http://doi.org/10.18800/psico.201701.006>
72. Liang S. y Wang J. *Advanced Remote Sensing: Terrestrial Information Extraction and Applications* (2nd ed.). Academic Press. 2020. <https://doi.org/10.1016/C2017-0-03489-4>
73. Sánchez JM. Análisis de Calidad Cartográfica mediante el estudio de la Matriz de Confusión. *Pensamiento matemático*. 2016; 6(2): 9-26. <https://dialnet.unirioja.es/servlet/articulo?codigo=5998855>
74. Congalton, R.G. y Green, K. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 2nd Edition, Lewis Publishers. 2020. <https://www.scirp.org/reference/referencespapers?referenceid=1278841>
75. Olofsson P, Foody G, Herold M, Stehman S, Woodcock C, Wulder M. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*. 2014 May; 148: 42-57. <https://doi.org/10.1016/j.rse.2014.02.015>
76. Jensen J. *Introductory Digital Image Processing: A Remote Sensing Perspective*. (Upper Saddle River, NY: Prentice Hall. 526. 2005.
77. Cohen J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*. 1960 Abr; 20(1): 37– 46. <https://doi.org/10.1177/001316446002000104>
78. Boca T, Rodríguez G. *Métodos estadísticos de la evaluación de la exactitud de productos derivados de sensores remotos*. Instituto de Clima y Agua, INTA Castelar. 2012.

79. GOF-C-GOLD. A sourcebook of methods and procedures for monitoring and reporting anthropogenic greenhouse gas emissions and removals associated with deforestation, gains and losses of carbon stocks in forests remaining forests, and forestation. GOF-C-GOLD Report version COP19-1. (GOF-C-GOLD Land Cover Project Office, Wageningen University, The Netherlands). 2013 Mar. <https://publications.jrc.ec.europa.eu/repository/handle/JRC76900>
80. Olaya V. Sistemas de Información Geográfica. 2014. 854. Disponible en: https://www.icog.es/TyT/files/Libro_SIG.pdf
81. Landis J, Koch G. The Measurement of Observer Agreement for Categorical Data. *Biometrics*. 1977 Mar; 33(1): 159-174. Disponible en: <https://www.jstor.org/stable/2529310>
82. HARRIS GEOESPATIAL SOLUTION. Radiance and Scale Factors Background, Calculate Confusion Matrices. 2018.
83. Pearson K. On Lines and Planes of Closest Fit to Systems of Points in Space. *Philosophical Magazine*. 1901; 2(11): 559–572. <https://doi.org/10.1080/14786440109462720>
84. Boardman JW. Sedimentary Facies Analysis Using Imaging Spectrometry: A Geophysical Inverse Problem [Doctoral dissertation, University of Colorado Boulder]. ProQuest. 1991. <https://www.proquest.com/openview/961236e78bc11bb7cd328ebee fd98484/1?pq-origsite=gscholar&cbl=18750&diss=y>
85. Peñuelas J. Gamon JA. Griffin KL. y Field CB. Assessing community type, plant biomass, pigment composition, and photosynthetic efficiency of aquatic vegetation from spectral reflectance. *Remote Sensing of Environment*. 1993 Nov; 46(2): 110-118. [https://doi.org/10.1016/0034-4257\(93\)90088-F](https://doi.org/10.1016/0034-4257(93)90088-F)
86. Peñuelas J. Gamon, JA. Fredeen AL. Merino J. y Field CB. Reflectance indices associated with physiological changes in nitrogen and water-limited sunflower leaves. *Remote sensing of Environment*. 1994 May; 48(2): 135-146. [https://doi.org/10.1016/0034-4257\(94\)90136-8](https://doi.org/10.1016/0034-4257(94)90136-8)
87. Rikimaru A. Roy PS. y Miyatake S. Tropical forest cover density mapping. *Tropical ecology*. 2002 Ene; 43(1): 39-47. https://www.researchgate.net/publication/228604101_Tropical_forest_cover_density_mapping
88. Kauth RJ. y Thomas GS. The Tasseled Cap — A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat [Paper presentation]. Symposium on Machine Processing of Remotely Sensed Data, West Lafayette, IN: Purdue. 1976. https://docs.lib.purdue.edu/lars_symp/159/
89. Baig MHA. Zhang L. Shuai T. y Tong Q. Derivation of a Tasseled Cap transformation based on Landsat 8 at-satellite reflectance. *Remote Sensing Letters*. 2014 Abr; 5(5): 423–431. <https://doi.org/10.1080/2150704X.2014.915434>
90. Shi T. y Xu H. Derivation of tasseled cap transformation coefficients for Sentinel-2 MSI at- sensor reflectance data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2019 Oct; 12(10): 4038-4048. <https://doi.org/10.1109/JSTARS.2019.2938388>

91. Jordan CF. Derivation of leaf-area index from quality of light on the forest floor. *Ecology*. 1969 Jul; 50(4): 663–666. <https://doi.org/10.2307/1936256>
92. Pearson RL. y Miller LD. Remote mapping of standing crop biomass for estimation of the productivity of the short-grass prairie, Pawnee National Grasslands, Colorado [Paper presentation]. Proceedings of the Eighth International Symposium on Remote Sensing of Environment, ERIM, Ann Arbor, United States. 1972.
93. Rouse J. Haas RH. Schell JA. y Deering DW. Monitoring vegetation systems in the Great Plains with ERTS [Paper presentation]. Proceeding of the Third ERTS Symposium, Washington DC, United States. 1973. <https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf>
94. Baret F. y Guyot G. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*. 1991 Feb; 35(2-3): 161-173. [https://doi.org/10.1016/0034-4257\(91\)90009-U](https://doi.org/10.1016/0034-4257(91)90009-U)
95. Deering DW. Rouse JW. Iiaa RH. y Schell JA. Measuring forage production of grazing units from landsat MSS Data [Paper presentation]. Proceedings of the Tenth International Symposium on Remote Sensing of Environment, ERIM, Ann Arbor, United States. 1975.
96. Thiam AK. Geographic Information System and Re-mote Sensing Methods for Assessing and Monitoring Land Degradation in the Shale: The Case of Southern Mauritania [Doctoral dissertation, Darks University]. ProQuest Dissertations and Theses. 1997. <https://ui.adsabs.harvard.edu/abs/1998PhDT.....94T/abstract>
97. Perry CR. y Lautenschlager LF. Functional Equivalence of Spectral Vegetation Indices. *Remote Sensing of Environment*. 1984 Ene; 14(1-3): 169-182. [https://doi.org/10.1016/0034-4257\(84\)90013-0](https://doi.org/10.1016/0034-4257(84)90013-0)
98. Huete AR. A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment* 1988 Ago; 25(3): 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
99. Richardson AJ. y Wiegand CL. Distinguishing Vegetation from Soil Background Information. *Photogrammetric Engineering and Remote Sensing*. 1977 Dic; 43(12): 1541-1552. https://www.asprs.org/wp-content/uploads/pers/1977journal/dec/1977_dec_1541-1552.pdf
100. Jackson RD. Slater PN. y Pinter P. Discrimination of growth and water stress in wheat by varius vegetation indices through clear and a turbid atmospheres. *Remote Sensing of Enviroment*. 1983 Jul; 13(3): 187 - 208. [https://doi.org/10.1016/0034-4257\(83\)90039-1](https://doi.org/10.1016/0034-4257(83)90039-1)
101. Walther D. y Shabaani S. Large scale monitoring of rangelands vegetation using NOAA/ AVHRR LAC data: application to the rainy seasons 1989/90 in northern Kenya. Range Management Handbook of Kenya; Ministry of Livestock Development: Nairobi, Kenya. 1991.
102. Qi J. Chehbouni A. Huete AR. Kerr YH. y Sorooshian S. A Modified Soil Adjusted Vegetation Index. *Remote Sensing of Environment*. 1994 May; 48(2): 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)

103. Celik N. Change Detection of Urban Areas in Ankara through Google Earth Engine [Paper presentation]. 41st Inter-national Conference on Telecommunications and Signal Processing (TSP), Athens, Greece. 2018 Jul. <https://doi.org/10.1109/TSP.2018.8441377>
104. Zhao H. y Chen X. Use of normalized difference bareness index in quickly mapping bare areas from TM/ETM+. In International geoscience and remote sensing symposium. 3: 1666-1668. 2005 Jul. <https://doi.org/10.1109/IGARSS.2005.1526319>
105. Shobha G. y Rangaswamy S. Machine Learning. In N, Venkat. C.R., Gudivada. Rao, C.R. (Eds), Computational Analysis and Understanding of Natural Languages: Principles, Methods and Applications. Print Book & E-Book. 2018 Ago. 197-228 p. <https://shop.elsevier.com/books/computational-analysis-and-understanding-of-natural-languages-principles-methods-and-applications/rao/978-0-444-64042-0>
106. Morell-Monzó S. Estornell j. y Sebastiá-Frasquet, MT. Comparison of Sentinel-2 and High- Resolution Imagery for Mapping Land Abandonment in Fragmented Areas. *Remote Sensing*. 2020 Jun; 12(12): 2062. <https://doi.org/10.3390/rs12122062>
107. Nasir NSB. Mustafa FB. y Muhammad Yusoff SY. Spatial prediction of soil erosion risk using knowledge-driven method in Malaysia's Steepland Agriculture Forested Valley. *Environment, Development and Sustainability*. 2024 Abr; 26: s10668-023-03251-8. <https://doi.org/10.1007/s10668-023-03251-8>
108. Demirel T. y Tüzün S. Multi criteria evaluation of the methods for preventing soil erosion using fuzzy ANP: The case of Turkey. [Conference presentation]. World Congress on Engineering, London, England. 2011 Jul; 2. https://www.iaeng.org/publication/WCE2011/WCE2011_pp1179-1183.pdf
109. Condori-Tintaya F. Pino-Vargas E. y Tacora-Villegas P. Pérdida de suelos por erosión hídrica en laderas semiáridas de la subcuenca Cairani-Camilaca, Perú. *Idesia*. 2022; 40(2): 7-15. <https://dx.doi.org/10.4067/S0718-34292022000200007>
110. Alewell C. Borrelli P. Meusburger K. y Panagos P. (2019). Using the USLE: chances, challenges and limitations of soil erosion modelling. *Int. Soil Water Conserv. Res.* 2019 Sep; 7(3): 203 – 225. <https://doi.org/10.1016/j.iswcr.2019.05.004>
111. Wang L. Huang J. Du Y. Hu Y. y Han P. Dynamic Assessment of Soil Erosion Risk Using Landsat TM and HJ Satellite Data in Danjiangkou Reservoir Area, China. *Remote Sensing*. 2023 Jul; 5(8): 3826-3848. <https://doi.org/10.3390/rs5083826>
112. Bernui G. Del Águila L. Sanes M. Prochazka R. y Bussalleu A. Evaluación de un test del aliento con carbono 13 para el diagnóstico de Helicobacter pylori. *Rev. de Gastroenterología del Perú*. 2022 Mar; 42(1): 13-9. <http://dx.doi.org/10.47892/rgp.2022.421.1341>
113. Meshesha DT. Tsunekawa A. Tsubo M. y Haregeweyn N. (2012). Dynamics and hotspots of soil erosion and management scenarios of the Central Rift Valley of Ethiopia. *International Journal of Sediment Research*, 27 (1), 84–99. [https://doi.org/10.1016/S1001-6279\(12\)60018-3](https://doi.org/10.1016/S1001-6279(12)60018-3)

114. Khosrokhani M. y Pradhan B. Spatio-temporal assessment of soil erosion at Kuala Lumpur metropolitan city using remote sensing data and GIS. *Geomatics, Natural Hazards and Risk*. 2012 Mar; 5(3): 252-270. <http://dx.doi.org/10.1080/19475705.2013.794164>
115. Papaiordanidis S. Gitas IZ. y Katagis T. Soil erosion prediction using the revised universal soil loss equation (RUSLE) in Google Earth Engine (GEE) cloud-based platform. *Dokuchaev Soil Bulletin*. 2019 ; 100: 36-52. <https://doi.org/10.19047/0136-1694-2019-100-36-52>
116. Kumar R. Deshmukh B. y Kumar A. (2022). Using Google Earth Engine and GIS for basin scale soil erosion risk assessment: A case study of Chambal river basin, central India. *Journal of Earth System Science*. 2022 Oct; 131(228). <https://doi.org/10.1007/s12040-022-01977-z>

Origen del artículo

Este artículo se originó a partir del interés de replicar una metodología diseñada para identificar áreas erosionadas y en riesgo de erosión utilizando imágenes Landsat 8 OLI y Sentinel-2 mediante procesamiento digital y SIG, publicada por Camargo et al. (10), aunado a recomendaciones dadas por un jurado evaluador en un seminario doctoral, del cual se generó dicho estudio, como lo fue su aplicación con imágenes óptico electrónicas y modelos digitales de elevación de diferentes resoluciones espaciales.

En el mismo orden de ideas, el artículo constituye un derivado de la tesis doctoral para optar al grado de Doctor en Ciencias Forestales ambientales, presentando en el Centro de Estudios Forestales y Ambientales De Postgrado de la Universidad de Los Andes (Mérida – Venezuela) por Christopher Edgar Camargo Roa, quien, como profesor e investigador, siempre ha evidenciado interés de realizar aportes al vacío de información existente en el estudio del riesgo de erosión en algunas cuencas hidrográficas andinas venezolanas. Finalmente, es necesario mencionar, que, esta investigación, no recibió financiamiento alguno para su ejecución.

Contribuciones de los autores

Camargo Roa Christopher Edgar ideó y desarrolló la investigación, recopiló los datos y ejecutó el flujo de trabajo. Pacheco Angulo Carlos Eduardo, Roberto López Falcón, Tatiana Gómez Orguloso y Sergio A. Monjardin-Armenta supervisaron y evaluaron la investigación y aportaron comentarios críticos. Todos los autores contribuyeron a la redacción del manuscrito final y aprobaron su versión definitiva para publicación.

Christopher Edgar Camargo Roa

Docente

Universidad de Los Andes, Departamento de Ordenación de Cuencas Hidrográficas Mérida, Venezuela.

Email: ccamargoroa@gmail.com

Carlos Eduardo Pacheco Angulo

Docente

Universidad de Los Andes, Escuela Técnica Superior Forestal, Departamento de Departamento de Bosque , Venezuela.

Email: carlosa@ula.ve

Tatiana Gómez-Orguloso

Investigadora independiente

Email: tatiana.orguloso@gmail.com

Roberto López-Falcón

Docente

Universidad de Los Andes, Centro Interamericano de Desarrollo e Investigación Ambiental y Territorio, Venezuela.

Email: rlopez@ula.ve

Sergio Alberto Monjardín-Armenta

Docente

Universidad Autónoma de Sinaloa, Facultad de Ciencias de La Tierra y el Espacio, México.

Email: sa.monjardin12@info.uas.edu.mx