



DINÁMICAS Y ESCENARIOS PROSPECTIVOS DE LAS COBERTURAS NATURALES EN SUBREGIONES DEL MACIZO COLOMBIANO A TRAVÉS DEL ANÁLISIS ESPACIOTEMPORAL DE SERIES MODIS EN EL CONTEXTO DEL CAMBIO CLIMÁTICO

Camila Andrea Segura Ocampo



ISO 9001: 2015 SC-CER450832



IONet: CO-SC-CER450832

Una Acreditación con
Rostro Humano



Dinámicas y Escenarios Prospectivos de las Coberturas Naturales en Subregiones del Macizo Colombiano a Través del Análisis Espaciotemporal de Series MODIS en el Contexto del Cambio Climático



Universidad
del Cauca

Camila Andrea Segura Ocampo

Este texto es el resultado del Trabajo de Grado, modalidad trabajo de investigación, como requisito parcial para optar al título de Magister en Ingeniería Física

Director:

PhD(c). Edgar Leonairo Pencue Fierro

Grupo Óptica y Laser (GOL)

Codirector:

PhD(c). Julián Fernando Muñoz Ordóñez

Grupo de Investigación en Computación e Informática Aplicada (MIND)

Universidad del Cauca

Facultad de Ciencias Naturales, Exactas y de la Educación

Maestría en Ingeniería Física

Popayán, 2023

Nota de Aceptación

Aprobado por el comité de grado en cumplimiento de los requisitos exigidos por la Universidad del Cauca para optar al título de Magister en Ingeniería Física.

PhD(c). Edgar Leonairo Pencue Fierro
Director

Juham Fdo. Muñoz O

PhD(c). Julián Fernando Muñoz Ordóñez
Codirector

PhD(c). Mario Milver Patiño
Jurado

PhD. Cristian Valencia Payán
Jurado

Fecha de sustentación: 23 de febrero del 2023

Agradecimientos

En primer lugar, quiero agradecer al Magister Julián Fernando Muñoz Ordoñez, quien con sus conocimientos y apoyo me guio a través de cada una de las etapas de este proyecto para alcanzar los resultados que buscaba sin el este proyecto no hubiera sido posible.

Expreso mis más sinceros agradecimientos a la comunidad educativa de la Universidad del Cauca, por haberme dado la oportunidad de compartir su sabiduría y con ello enriquecer mi conocimiento, por haber despertado ese sentimiento de crítica y superación constructiva, aquella que todo egresado debe adquirir en su continua preparación profesional.

Dedicatoria

A mi hija Alana Giraldo, es el mejor regalo que haya podido recibir de parte de Dios. Eres mi mayor tesoro, la fuente más pura de mi inspiración y motivación. Te doy las gracias, hija mía, por darle sentido a mi vida y permitirme ser cada día mejor madre junto a ti.

A mi madre Ximena Ocampo y abuela Maricela Smith por su apoyo y colaboración en todo momento, sin ellas no hubiera sido posible.

A mis hermanos Juan Fernando y Luis Mauricio que el día a día con su presencia, respaldo y cariño me impulsan a salir adelante, además de saber que mis logros también son los suyos.

Contenido

Resumen	1
Abstract	2
Capítulo 1: Introducción	3
1.1 Formulación del Problema	3
1.2 Justificación	7
1.3 Objetivos.....	9
Capítulo 2: Referentes Teóricos y Estado del Arte	11
2.1 Marco Teórico	11
2.1.1 Modelos Estadísticos.....	11
2.1.2 Ambiental.....	15
2.1.3 Percepción Remota Satelital	18
2.2 Estado del Arte	23
Capítulo 3: Metodología	48
Capítulo 4: Resultados y Discusión	54
4.1 Construcción del conjunto de datos.....	56
4.2 Análisis espacio temporal y escenarios prospectivos con métricas de precisión.....	64

4.3 Divulgación de los Resultados en Evento Científico	82
Conclusiones	84
Bibliografía	86
Anexos.....	95

Tabla de Figuras

Figura 1. Proceso de búsqueda.....	36
Figura 2. Proceso construcción base de datos.....	48
Figura 3. LAADS DAAC Level-1 and Atmosphere Archive & Distribution System Distributed Active Archive Center	49
Figura 4. Zona de Interés en donde se encuentra contenida el área de estudio Macizo Colombiano	50
Figura 5. Episodios cálidos y fríos por temporadas National Weather Service	50
Figura 6. Área de Estudio departamentos que conforman el Macizo Colombiano.	51
Figura 7. Imagen Satelital AQUA MOD13Q1 año 2000 día 353	53
Figura 8. Imagen Satelital AQUA MYD13Q1 año 2000 día 361	53
Figura 9. Diagrama de clases del Framework para la creación de escenarios prospectivos utilizando imágenes satelitales MODIS y modelos estadísticos.	54
Figura 10. Fragmento código Python implementado para la extracción banda NDVI paquete de imágenes HDF MODIS	57
Figura 11. Selección de los productos MODIS: índice de vegetación de diferencia normalizada (NDVI) y máscara de confiabilidad de píxeles.....	58
Figura 12. Producto mensual MODIS sin corrección radiométrica correspondiente al índice de vegetación de diferencia normalizada (NDVI).	59

Figura 13. Histograma de frecuencias del contenido espectral de los productos MODIS sin corrección radiométrica.....	60
Figura 14. Corrección radiométrica de la imagen satelital MODIS aplicando el modelo propuesto desde el servidor de descarga.....	61
Figura 15. Archivo vectorial correspondiente a los parques naturales ubicados sobre el Macizo Colombiano, el archivo vectorial de parques se muestra sobre una imagen satelital MODIS – NDVI.	62
Figura 16. Parques naturales ubicados sobre el Macizo Colombiano, los pixeles mostrados corresponden al índice de vegetación NDVI del compuesto mensual MODIS.....	63
Figura 17. Estructura del conjunto de datos construido a partir de la serie temporal MODIS del índice de vegetación de diferencia normalizada relacionado con parques naturales ubicados sobre el Macizo Colombiano.....	64
Figura 18. Fragmento código Python implementado para la obtención del dataset que alimenta al software R.....	65
Figura 19. Fragmento dataset obtenido que alimentara al software R a partir de las imágenes NDVI – MODIS.....	65
Figura 20. Código implementado modelo ARIMA función auto.arima para predicción de escenario futuros.	66

Figura 21. Fragmento full_forecast escenarios prospectivos obtenido a partir del Modelo ARIMA.....	67
Figura 22. Fragmento código Python implementado en la reconstrucción de las imágenes MODIS.....	68
Figura 23. Diferencia entre imágenes año y mes 201812 y 201901.....	69
Figura 24. Imagen Forecast_m01 la cual indica el mes 1 de predicción – Enero 2019.....	70
Figura 25. Imagen Forecast_m02 la cual indica el mes 2 de predicción – Febrero 2019.....	71
Figura 26. Imagen Forecast_m03 la cual indica el mes 3 de predicción – Marzo 2019.....	72
Figura 27. Imagen Forecast_m04 la cual indica el mes 4 de predicción – Abril 2019.....	73
Figura 28. Imagen Forecast_m05 la cual indica el mes 5 de predicción – Mayo 2019.....	74
Figura 29. Imagen Forecast_m06 la cual indica el mes 6 de predicción – Junio 2019.....	75
Figura 30. Imagen MODIS - Enero 2019	77
Figura 31. Precisión mes 01- enero 2019	78
Figura 32. Precisión mes 06 - junio 2019	79

Lista de Tablas

Tabla 1. Preguntas de Investigación.	34
Tabla 2. Cadena de búsqueda usada en bases de datos.....	¡Error! Marcador no definido.
Tabla 3. Proceso de búsqueda.....	¡Error! Marcador no definido.
Tabla 4. Nombre de archivos TERRA y Aqua en la ventana de tiempo seleccionada	52
Tabla 5. Valores ONI periodo 2010 – 2019.....	81

Resumen

El Macizo Colombiano hace parte de las riquezas naturales más grandes que posee Colombia en términos de agua, vegetación y fauna. Genera el 70% del agua dulce del país, lo que hace que su cuidado y preservación sean de vital importancia. Este trabajo pretende realizar un análisis espacio - temporal de series satelitales MODIS para la evaluación de los factores de cambio ambiental del macizo colombiano en el contexto del cambio climático.

Utilizando las técnicas de percepción remota, específicamente sobre los datos provenientes de los satélites Aqua y Terra del sensor MODIS, se desarrolló un análisis de la evolución temporal de los índices de vegetación a través del software R modelo ARIMA y función auto.arima, obteniendo con un pronóstico de 6 meses comprendido entre enero y junio del año 2019, el cual permitió determinar la fiabilidad del modelo implementado con un porcentaje del 80% al 95%.

Finalmente, los resultados obtenidos durante la ejecución del proyecto se enfocaron en el contexto de la importancia de la conservación natural como factor determinante en el equilibrio ecológico, proporcionando información relevante que busca apoyar a los tomadores de decisiones para generar políticas que impacten de forma positiva en la región del Macizo Colombiano.

Palabras Clave: Cambio Climático, Coberturas Vegetales, Escenarios, Índices de Vegetación, MODIS, Prospectivos, Series de Tiempo.

Abstract

The Colombian Massif is part of the greatest natural wealth that Colombia has in terms of water, vegetation and fauna. It generates 70% of the country's fresh water, which makes its care and preservation vitally important. This work aims to perform a spatio-temporal analysis of MODIS satellite series for the evaluation of the factors of environmental change of the Colombian massif in the context of climate change.

Using remote sensing techniques, specifically on the data from the Aqua and Terra satellites of the MODIS sensor, an analysis of the temporal evolution of vegetation indices was developed through the R software ARIMA model and auto.arima function, obtaining with a forecast of 6 months between January and June 2019, which allowed to determine the reliability of the implemented model with a percentage of 80% to 95%.

Finally, the results obtained during the execution of the project focused on the context of the importance of natural conservation as a determining factor in the ecological balance, providing relevant information that seeks to support decision makers to generate policies that positively impact the region of the Colombian Massif.

Keywords: Climate Change, Vegetation Cover, Scenarios, Vegetation Indices, MODIS, Prospective, Time Series.

Capítulo 1: Introducción

Los avances tecnológicos en el campo de la teledetección han permitido la vigilancia de los ecosistemas gracias a la disponibilidad de datos con resoluciones espaciales, temporales y espectrales cada vez mejores. En este capítulo se plantea la problemática, justificación y objetivos de la investigación con la finalidad de entender las dinámicas de las coberturas naturales para generar escenarios prospectivos en el Macizo Colombiano dentro del contexto climático.

1.1 Formulación del Problema

Las variaciones climáticas globales han estado ocurriendo a lo largo de la historia, sin embargo, en las últimas décadas la actividad humana ha influenciado en gran medida al aumento de esta problemática propiciando que este sea un tema de carácter obligatorio en las preocupaciones de la sociedad actual. Este tema es considerado a nivel mundial como una de las mega tendencias en la sociedad moderna (Asociación Internacional de la Seguridad Social, 2014), de acuerdo con lo mencionado, si se mantiene una degradación continua del ambiente, con el consecuente cambio climático, el ser humano podría desaparecer de la tierra como especie (Díaz Cordero, 2016).

América Latina, que es una región cuatro veces más grande que Europa, se enfrenta a varios problemas como el deterioro de los recursos renovables y la pérdida de los hábitats naturales, esto asociado al cambio climático y a sus factores de

cambio ambiental que se han venido acrecentando a través de las últimas décadas. Por otra parte, América del Sur, presenta problemas de desertificación y actualmente busca mitigar los efectos de sequía, dicha situación se asocia con el calentamiento global y los cambiantes indicadores climáticos como temperatura, precipitación y evaporación, ya que se ha establecido que esto afecta en todos los niveles a la degradación de la capa vegetal, por lo que, si esta tendencia continúa, la capa vegetal se verá rápidamente afectada en un mayor proporción, por lo cual es de vital importancia encontrar garantías de seguridad a largo plazo (Gallego Álvarez, García Rubio, & Martínez Ferrero, 2018).

Colombia y el Macizo Colombiano, conocido como el Nudo de Almaguer, es la estrella hídrica más importante, y la principal productora de agua dulce en Colombia, con un área de 32.682 km². Esta ecorregión la comparten los departamentos del Cauca, Huila, Tolima, Putumayo, Valle del Cauca, Nariño y Caquetá. El Macizo Colombiano se destaca por ser una región donde se originan las cordilleras Central y Oriental, confluyen los ecosistemas andino, amazónico y pacífico, es el lugar donde nacen las cinco arterias fluviales más importantes del país: los ríos Magdalena, Cauca, Putumayo, Caquetá y Patía, (Tiempo, 2019). Por lo tanto, el desarrollo regional sostenible del Macizo Colombiano es vital para el país, sin embargo, existen problemáticas que ponen en riesgo su sostenibilidad las cuales están asociadas al deterioro de su capital natural y el aumento de la vulnerabilidad

ante riesgos de desastres naturales y el cambio climático (Gallego Álvarez, García Rubio, & Martínez Ferrero, 2018).

Debido a la gran extensión del Macizo y de algunas de sus zonas con difícil acceso hace que los protocolos para su monitoreo en algunos casos sean inciertos. Las metodologías de campo para medir el cambio de vegetación suelen ser limitadas, costosas y requieren mucho tiempo. Por lo tanto, el uso de sensores remotos de resolución baja y media (imágenes satelitales) son una herramienta idónea para realizar este tipo de estudio (Tsalyuk, Kelly, & Wayne , 2017). El Macizo colombiano es una zona que se caracteriza por la alta presencia de nubosidad debido a la orografía, imágenes satelitales como Landsat y Sentinel-2 debido a su tasa de revisita tienen una alta probabilidad de que sus imágenes se vean afectadas por las coberturas nubosas. Los productos del satélite MODIS están conformados por compuestos de imágenes que reducen la presencia de cobertura nubosa facilitando los procesos de captura de diversas coberturas vegetales. Las técnicas de teledetección proporcionan un sistema eficaz para monitorear la dinámica de la vegetación en múltiples escalas utilizando índices de vegetación, que se basan en la comparación de reflectancia espectral del infrarrojo cercano (NIR) y del rojo visible (R), así como en otras bandas. El índice de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) es el más utilizado porque permite cuantificar la salud de la vegetación midiendo la diferencia entre el infrarrojo cercano (muy

reflejado) y la luz roja (absorbida). Además, cuestiones importantes, como la predicción de la respuesta de la vegetación inducida por factores climáticos, se basan en modelos de predicción del NDVI (Carreño Conde, Sipols, Simón de Blas, & Mostaza Colado, 2021).

El Macizo es catalogado como una región estratégica para el país. La convergencia orográfica, la riqueza ecosistémica y su tipo de suelo generan condiciones especiales que favorecen la regulación hídrica y el mantenimiento de una alta riqueza biológica, paisajística y cultural (Consejo Nacional de Política Económica y Social, 2018). De acuerdo con lo expuesto en este proyecto se plantea la siguiente pregunta de investigación: **¿Cómo entender las dinámicas de las coberturas naturales para generar escenarios prospectivos en el Macizo Colombiano dentro de un contexto del cambio climático?** Para responder a esta pregunta de investigación se propone la siguiente hipótesis: **La correlación entre el procesamiento de series temporales de imágenes satelitales MODIS y serie temporal ENSO proporcionará información relacionada con los cambios entre coberturas naturales creando insumos para la generación de escenarios prospectivos para las subregiones del Macizo Colombiano.**

1. 2 Justificación

La UNESCO mediante el Acuerdo 56 de 1978, declaró un total de 8.550 Km² del Macizo Colombiano como reserva de la Biósfera Constelación Cinturón Andino, debido a su importante función en la regulación hídrica, control de la erosión, captura de carbono y biodiversidad (Consejo Nacional de Política Económica y Social, 2018). Esta área se encuentra conformada por los departamentos Huila, Cauca, Caquetá y Tolima, encontrándose tres importantes Parques Nacionales Naturales como la Cueva de los Guácharos, Puracé y Nevado del Huila. Las reservas de la biósfera son áreas extensas y representativas del paisaje natural y cultural, las cuales deben ser resguardadas a largo plazo, ya que estas representan un reservorio de recursos genéticos, ecosistemas y son también áreas de uso sustentable del suelo e investigación (Borsdorf, Mergili, & Alfonso Ortega, 2013).

El CONPES (Consejo Nacional de Política Económica y Social) 3915, establece un conjunto de estrategias y acciones a ser desarrolladas por entidades del orden nacional y regional, dirigidas a impulsar el desarrollo integral de la ecorregión del Macizo colombiano dada su relevancia ambiental para el país. De acuerdo con esto se establece el objetivo de preservar el potencial hídrico del macizo, proteger y asegurar el uso sostenible del capital natural y de los servicios de los ecosistemas; promover un crecimiento económico resiliente ante los desastres y el Cambio Climático; y asegurar la inclusión social y el bienestar de la población. En este

mismo sentido, se logra establecer que dicho territorio cuenta con un capital natural de gran importancia no solo para el país sino para el mundo como gran reservorio de ecosistemas y fuentes hídricas, así como, es de gran relevancia para las regiones hidrográficamente interconectadas que dependen de los servicios ecosistémicos que allí se generan (Consejo Nacional de Política Económica y Social, 2018).

En el país, se expresa la necesidad de disponer de un análisis espaciotemporal que permita ver los factores de cambio ambiental respecto al Macizo Colombiano entorno al marco del Cambio Climático, con el cual finalmente se evidenciarán las afectaciones antrópicas sobre esta región. En este sentido, partiendo de la premisa que las expectativas de crecimiento y bienestar deben ser sostenibles, es imperativo que los territorios conozcan y utilicen la información climática evidenciada y proyectada como una de las variables para la planificación del desarrollo de los territorios ya que con esto se puede mitigar, minimizar o eliminar los impactos ambientales generados en la región (Corporación Autónoma Regional del Valle del Cauca, 2015).

De acuerdo con lo expuesto anteriormente, esta investigación proporcionará un apoyo a las investigaciones que realiza el IDEAM e IGAC en lo que respecta sobre estudios nacionales en aras de la conservación de coberturas vegetales (IDEAM, 2021) (IGAC, 2021). Es de resaltar que gracias a este proyecto se podrá disponer de un estudio complementario que permita al cubo de datos de imágenes satelitales de

Colombia (CDCOL) del IDEAM y Banco Nacional de Imágenes del IGAC complementar sus bases de datos a través del MODIS disponiendo de un estudio conformado por compuestos de imágenes que reducen la presencia de cobertura nubosa facilitando los procesos de captura de diversas coberturas vegetales permitiendo realizar un mejor análisis a dichos estudios.

1.3 Objetivos

Objetivo General

Elaborar un análisis espaciotemporal de series satelitales MODIS, para la caracterización dinámica y la construcción de escenarios prospectivos relacionados con cambios de coberturas naturales (bosques naturales) en subregiones del Macizo Colombiano bajo el contexto del cambio climático.

Objetivos Específicos

- Construir un conjunto de datos relacionado con información meteorológica e índices de vegetación utilizando series temporales satelitales obtenidas a partir del sensor MODIS, enfocándose en zonas de bosques naturales ubicados en áreas correspondientes al Macizo Colombiano.
- Desarrollar un análisis espaciotemporal con el conjunto de datos adquiridos sobre el Macizo Colombiano (bosques naturales) relacionado con la evolución de

índices de vegetación que permitan explicar los efectos y causas del cambio de coberturas de bosques naturales en el contexto del cambio climático.

- Validar los escenarios prospectivos para las subregiones del Macizo Colombiano relacionados con el análisis espacio temporal de los bosques naturales, además, de su validación a través de métricas de precisión.

El resto del documento se encuentra estructurado de la siguiente manera: Capítulo 2 Referentes Teóricos y Estado del Arte, donde se presentan los conceptos requeridos para el desarrollo de la investigación, además, se realiza una exploración cronológica del Estado del Arte desde el año 2011 a 2016 y posteriormente un artículo con el nombre *Análisis de la degradación en coberturas vegetales asociados a la teledetección MODIS: Un Mapeo Sistemático* obtenido de la investigación con una ventana de tiempo de 5 años (2017-2021), en las áreas de sensado remoto y ciencias ambientales reportando a partir de estos los mejores resultados de acuerdo a las variables consideradas para la degradación como: coberturas vegetales, coberturas vegetales más usadas, softwares más implementados, métricas para evaluar la precisión e índices de vegetación más usados. Capítulo 3 metodología y el Capítulo 4 donde se encuentra plasmado los resultados obtenidos de los 3 ciclos establecidos para cumplir con el objetivo de la investigación.

Capítulo 2: Referentes Teóricos y Estado del Arte

El presente capítulo hace referencia al marco teórico y estado del arte, donde se recopilan definiciones de varios autores sobre el objeto de estudio, dividiéndose en 3 temáticas, modelos estadísticos, ambiental y percepción remota satelital, de la misma manera se realiza la revisión de literatura contenida en fuentes documentales presentándose de manera cronológica, permitiendo de esta manera caracterizar las ideas dirigiéndolas hacia el objeto de investigación.

2.1 Marco Teórico

2.1.1 Modelos Estadísticos

Series de Tiempo

Una serie temporal es una secuencia de observaciones tomadas secuencialmente en el tiempo. El primero y el más importante de los pasos en el análisis de una serie de tiempo, y en el consecuente desarrollo de un modelo de pronóstico, es la recolección de datos confiables y válidos. La exactitud y validez del análisis de las series de tiempo y de los pronósticos depende de la calidad y veracidad de los datos. En las series de tiempo se estudia cómo una variable cambia a través del tiempo para identificar la relación entre estos y poder predecir comportamientos en el futuro. Los datos históricos se analizan y se descomponen para identificar los componentes que influyen a la variable a pronosticar (Gaynor & Kirkpatrick, 1994) (Box, Jenkins, Reinsel, & Ljung, 2016).

Componentes de las series de tiempo

Los datos de las series de tiempo generalmente consisten en una combinación de uno o más de los siguientes componentes:

Tendencia

Es un movimiento lineal ascendente o descendente de los datos a lo largo de un gran periodo de tiempo. Identifica la tasa de crecimiento o descenso de una serie a través del tiempo (Gaynor & Kirkpatrick, 1994) (Box, Jenkins, Reinsel, & Ljung, 2016) (Borsdorf, Mergili, & Alfonso Ortega, 2013).

Estacionalidad

Las variaciones estacionales consisten en movimientos recurrentes por encima y por debajo de la línea de tendencia y su patrón es repetitivo (Gaynor & Kirkpatrick, 1994)

Ciclicidad

Son las variaciones oscilatorias alrededor de la línea de tendencia que ocurren durante largos periodos de tiempo (Gaynor & Kirkpatrick, 1994) (Box, Jenkins, Reinsel, & Ljung, 2016)

Variaciones aleatorias

También conocidas como ruido, son las variaciones que no tiene patrones definidos y sus causas no son identificables. Están presentes en todas las series de

tiempo y sus efectos forman parte de las desviaciones no explicadas de los datos (Gaynor & Kirkpatrick, 1994) (Box, Jenkins, Reinsel, & Ljung, 2016).

Escenarios Prospectivos o futuros

Un escenario de futuro se presenta como una posible realidad, como un posible o incluso probable presente del mañana. Si se fundamenta en métodos muy cuantificados, en análisis de datos esto permite tomar acciones rápidas y acertadas, brindando una orientación de hacia dónde deben dirigirse (Gómez Delgado & Rodríguez Espinosa, 2012).

Modelo ARIMA

Box y Jenkins han desarrollado modelos estadísticos para series temporales que tienen en cuenta la dependencia existente entre los datos, esto es, cada observación en un momento dado es modelada en función de los valores anteriores. Los análisis se basan en un modelo explícito. Los modelos se conocen con el nombre genérico de ARIMA (AutoRegresive Integrated Moving Average), que deriva de sus tres componentes AR (Autoregresivo), I(Integrado) y MA (Medias Móviles) (Edward & Meirion Jenkins, n.d.).

El modelo ARIMA permite describir un valor como una función lineal de datos anteriores y errores debidos al azar, además, puede incluir un componente cíclico o estacional. Es decir, debe contener todos los elementos necesarios para

describir el fenómeno(Edward & Meirion Jenkins, n.d.). Box y Jenkins recomiendan como mínimo 50 observaciones en la serie temporal. La metodología de Box y Jenkins se resume en cuatro fases:

La primera fase consiste en identificar el posible modelo ARIMA que sigue la serie, lo que requiere:

- Decidir qué transformaciones aplicar para convertir la serie observada en una serie estacionaria.
- Determinar un modelo ARMA para la serie estacionaria, es decir, los órdenes p y q de su estructura autorregresiva y de media móvil.

La segunda fase: Seleccionado provisionalmente un modelo para la serie estacionaria, se pasa a la segunda etapa de estimación, donde los parámetros AR y MA del modelo se estiman por máxima verosimilitud y se obtienen sus errores estándar y los residuos del modelo(Edward & Meirion Jenkins, n.d.).

La tercera fase es el diagnostico, donde se comprueba que los residuos no tienen estructura de dependencia y siguen un proceso de ruido blanco. Si los residuos muestran estructura se modifica el modelo para incorporarla y se repiten las etapas anteriores hasta obtener un modelo adecuado(Edward & Meirion Jenkins, n.d.).

La cuarta fase es la predicción, una vez que se ha obtenido un modelo adecuado se realizan predicciones con el mismo (Edward & Meirion Jenkins, n.d.).

2.1.2 Ambiental

Clima

El clima es el conjunto fluctuante de las condiciones atmosféricas, caracterizado por los estados y evoluciones del estado del tiempo, durante un periodo de tiempo y un lugar o región dados, y controlado por los denominados factores forzantes, factores determinantes y por la interacción entre los diferentes componentes del denominado sistema climático (atmósfera, hidrósfera, litósfera, criósfera, biósfera y antropósfera). Debido a que el clima se relaciona generalmente con las condiciones predominantes en la atmósfera, este se describe a partir de variables atmosféricas como la temperatura y la precipitación, denominados elementos climáticos; sin embargo, se podría identificar también con las variables de otros de los componentes del sistema climático (IDEAM, 2019) (NASA, 2017).

Cambio Climático

De acuerdo con la Convención Marco de las Naciones Unidas sobre Cambio Climático (CMNUCC), éste se entiende como un cambio de clima atribuido directa o indirectamente a la actividad humana que altera la composición de la atmósfera mundial y que se suma a la variabilidad natural del clima observada durante períodos de tiempo comparables. Por otro lado, el Panel Intergubernamental de Expertos sobre Cambio Climático (IPCC) lo define como cualquier cambio en el clima con el

tiempo debido a la variabilidad natural o como resultado de actividades humanas (IDEAM, 2019) (NASA, 2021).

Desde el punto de vista meteorológico, se llama cambio climático a la alteración de las condiciones predominantes. Los procesos externos tales como la variación de la radiación solar, variaciones de los parámetros orbitales de la tierra (la excentricidad, la inclinación del eje de la tierra con respecto a la eclíptica), los movimientos de la corteza terrestre y la actividad volcánica son factores que tienen gran importancia en el cambio climático (IDEAM, 2019) (NASA, 2021).

Meteorología

La Meteorología es la ciencia encargada del estudio de la atmósfera, de sus propiedades y de los fenómenos que en ella tienen lugar. El estudio de la atmósfera se basa en el conocimiento de una serie de magnitudes, o variables meteorológicas, como la temperatura, la presión atmosférica o la humedad, las cuales varían tanto en el espacio como en el tiempo (Rodríguez Jiménez, Benito Capa, & Portela Lozano, 2004) (Ahrens & Henson, 2021).

Índices de Vegetación

Al hablar de índices nos referimos a un conjunto de operaciones algebraicas efectuadas sobre los valores numéricos de los píxeles, usando dos o más bandas pertenecientes a la misma escena. Un índice de vegetación puede ser definido como un parámetro calculado a partir de los valores de la reflectancia a distintas longitudes

de onda, y que es particularmente sensible a la cubierta vegetal (Gilabert, Gonzalez Piqueras, & García Haro, 1997). También, corresponde a un número generado por alguna combinación de bandas espectrales y que puede tener alguna relación con la cantidad de la vegetación presente en un píxel dado. Estos índices, son utilizados para mejorar la discriminación entre el suelo y la vegetación, reduciendo el efecto del relieve en la caracterización espectral de las diferentes cubiertas. Los valores bajos de los índices de vegetación usualmente indican vegetación poco vigorosa, mientras que los valores altos, indican vegetación muy vigorosa (Muñoz Aguayo, 2013) (Didan, Barreto Munoz, Solano, & Huete, 2015).

Índice de Vegetación de Diferencial Normalizada (NDVI)

El índice NDVI (Índice de Vegetación de Diferencia Normalizada) representa la cantidad y el vigor de la vegetación (actividad fotosintética). Está estrechamente relacionado con el tipo de vegetación y con las condiciones climáticas, así como con el patrón predominante de uso de las tierras. Este índice es sensible a la clorofila (NASA, 2021).

$$NDVI = \frac{(NRI - RED)}{(NRI + RED)}$$

NRI: Banda Infrarroja Cercano

RED: Banda Roja

índice de Vegetación Mejorado (EVI)

El EVI (índice de vegetación mejorado) obtiene respuesta de las variaciones estructurales del dosel vegetal incluyendo el índice de área foliar LAI (leaf area index), tipo y arquitectura del dosel y fisonomía de la planta. EVI fue desarrollado para optimizar la señal de la vegetación con sensibilidad mejorada para altas densidades de biomasa, lográndose esto al separar la señal proveniente de la vegetación y la influencia atmosférica (NASA, 2021).

$$NDVI = \frac{(NRI - RED)}{(NRI + C1 * RED - C2 * BLUE + L)}$$

NRI: Banda Infrarroja Cercano

RED: Banda Roja

BLUE: Banda Azul

L: 1, C1 = 6, C2 = 7.5 (Valores Estándar NASA Sensor MODIS)

2.1.3 Percepción Remota Satelital

MODIS

El sensor MODIS (Moderate Resolution Imaging Spectroradiometer) es un instrumento que viaja a bordo de los satélites de Terra (EOS a.m.) y del Aqua (EOS p.m.). La órbita de Terra alrededor de la tierra viaja del norte al sur cruzando el Ecuador por la mañana, mientras que el Aqua viaja del sur al norte cruzando el Ecuador por la tarde (CREPAD, 2019) (NASA, 2020).

Terra-MODIS y Aqua-MODIS cubren la superficie de la tierra cada 1 a 2 días, adquiriendo datos en 36 bandas espectrales. Con resolución espacial de 250 m para las bandas espectrales 1 – 2, 500 m para las bandas 4 – 7 y 1 km bandas 8 - 36. Estos datos ayudan a comprender la dinámica global de la Tierra; el comportamiento en la superficie terrestre, en los océanos y en la atmósfera. MODIS está desempeñando un papel vital en el desarrollo de modelos validados y globales capaces de predecir el cambio global que está sufriendo el planeta Tierra y así tomar decisiones oportunas referentes a la protección del ambiente, MODIS mide:

- Temperatura de superficie (suelo y océano), detección de incendios.
- Color del océano (sedimentos, fitoplancton).
- Cartografía de la vegetación global, detección de cambios (*Se usará en la investigación*)
- Características de la nubosidad.
- Concentraciones de aerosoles.

MOD13Q1 v006

Índices de vegetación MODIS/Terra 16 días L3 Global 250 m SIN Grid, Los datos de la versión 6 de los índices de vegetación (MOD13Q1) del espectrorradiómetro de imágenes de resolución moderada Terra (MODIS) se

generan cada 16 días a una resolución espacial de 250 metros (m) como un producto de nivel 3 (Producto global diario MODIS Atmosphere de nivel 3 que contiene aproximadamente 600 conjuntos de datos estadísticos que se derivan de aproximadamente 80 parámetros científicos de cuatro productos MODIS Atmosphere de nivel 2: aerosol, vapor de agua, nube y perfil atmosférico). El producto MOD13Q1 proporciona dos capas de vegetación primaria. El primero es el índice de vegetación de diferencia normalizada (NDVI), que se conoce como el índice de continuidad del NDVI derivado del radiómetro avanzado de muy alta resolución (NOAA-AVHRR) existente de la Administración Nacional Oceánica y Atmosférica. La segunda capa de vegetación es el Índice de Vegetación Mejorado (EVI), que ha mejorado la sensibilidad en las regiones de alta biomasa. El algoritmo elige el mejor valor de píxel disponible de todas las adquisiciones del período de 16 días. Los criterios utilizados son nubes bajas, ángulo de visión bajo y el valor más alto de NDVI/EVI. Junto con las capas de vegetación y las dos capas de calidad, el archivo HDF tendrá bandas de reflectancia MODIS 1 (rojo), 2 (infrarrojo cercano), 3 (azul) y 7 (infrarrojo medio), así como cuatro capas de observación (LP DAAC, 2015).

Mejoras/Cambios de Versiones Anteriores

- El VI compuesto de 16 días se genera usando los dos gránulos de reflectancia de superficie compuesta de 8 días (MOD09A1) en el período de 16 días.

- Esta entrada de reflectancia superficial se basa en el enfoque de composición azul mínimo utilizado para generar el producto de reflectancia superficial de 8 días (LP DAAC, 2015).
- El formato del producto es consistente con el producto de la Versión 5 generado utilizando el producto de reflectancia de superficie diaria cuadrículada de Nivel 2(LP DAAC, 2015).
- Se utiliza una base de datos de producto del índice de vegetación promedio de la cuadrícula de modelado climático (CMG) global a largo plazo que se actualiza con frecuencia para llenar los vacíos en el conjunto de productos CMG(LP DAAC, 2015).

MYD13Q1 v006

Índices MODIS/Aqua Vegetation 16 días L3 Global 250 m SIN Grid, Los datos de la versión 6 de los índices de vegetación (MYD13Q1) del espectrorradiómetro de imágenes de resolución moderada Aqua (MODIS) se generan cada 16 días a una resolución espacial de 250 metros (m) como un producto de nivel 3. El producto MYD13Q1 proporciona dos capas de vegetación primaria. El primero es el índice de vegetación de diferencia normalizada (NDVI), que se conoce como el índice de continuidad del NDVI derivado del radiómetro avanzado de muy alta resolución (NOAA-AVHRR) existente de la Administración Nacional Oceánica y Atmosférica. La segunda capa de vegetación es el Índice de Vegetación

Mejorado (EVI), que ha mejorado la sensibilidad en las regiones de alta biomasa. El algoritmo elige el mejor valor de píxel disponible de todas las adquisiciones del período de 16 días. Los criterios utilizados son nubes bajas, ángulo de visión bajo y el valor más alto de NDVI/EVI. Junto con las capas de vegetación y las dos capas de calidad, el archivo HDF tendrá bandas de reflectancia MODIS 1 (rojo), 2 (infrarrojo cercano), 3 (azul) y 7 (infrarrojo medio), así como cuatro capas de observación(LP DAAC, 2015).

Mejoras/Cambios de Versiones Anteriores

- El VI compuesto de 16 días se genera usando los dos gránulos de reflectancia de superficie compuesta de 8 días (MOD09A1) en el período de 16 días (LP DAAC, 2015).
- Esta entrada de reflectancia superficial se basa en el enfoque de composición azul mínimo utilizado para generar el producto de reflectancia superficial de 8 días.
- El formato del producto es consistente con el producto de la Versión 5 generado utilizando el producto de reflectancia de superficie diaria cuadrículada de Nivel 2(LP DAAC, 2015).
- Se utiliza una base de datos de producto del índice de vegetación promedio de la cuadrícula de modelado climático (CMG) global a largo plazo que se

actualiza con frecuencia para llenar los vacíos en el conjunto de productos CMG(LP DAAC, 2015).

2.2 Estado del Arte

En 2011 Salmon *et al* (2011), plantearon un nuevo método de detección de cambios en la cobertura del suelo que emplea una ventana deslizante sobre imágenes multiespectrales hipertemporales adquiridas de las 7 bandas del producto de reflectancia de la superficie terrestre del espectrorradiómetro de imágenes de resolución moderada (MODIS). El cambio de cobertura terrestre simulado se compone de series de tiempo concatenadas que se producen al combinar series de tiempo reales de píxeles de asentamientos humanos con aquellos de áreas adyacentes cubiertas por vegetación natural. En este estudio se logra una precisión general de detección de cambios entre el 83 % y el 90 %. Se muestra que una ventana móvil de 6 meses usando las 7 bandas de datos MODIS es suficiente para detectar cambios en la cobertura del suelo de manera confiable. Los tamaños de ventana de 18 meses y más brindan mejoras menores en la precisión de clasificación y el rendimiento de detección de cambios a costa de retrasos de tiempo más prolongados (B.P, y otros, 2011).

Wang *et al* (2012), en su estudio “Impact of sensor degradation on the MODIS NDVI time series”, presentan como las series temporales de datos satelitales brindan información sin precedentes sobre la respuesta de la vegetación a la variabilidad

climática y como la detección de cambios sutiles en la vegetación a lo largo del tiempo requiere mediciones satelitales consistentes. Aquí, el impacto de la degradación del sensor en la detección de tendencias se evaluó utilizando los datos de la Colección 5 de los sensores del espectroradiómetro de imágenes de resolución moderada (MODIS) en las plataformas Terra y Aqua. Para Terra MODIS, el impacto de la degradación de la banda azul (Banda 3, 470 nm) en la reflectancia de la superficie simulada fue más pronunciado en los ángulos de visión cercanos al nadir, lo que llevó a un 0.001–0.004 año⁻¹ disminución en el índice de vegetación de diferencia normalizada (NDVI) bajo un rango de condiciones de aerosol simuladas y tipos de superficie. Las tendencias observadas en MODIS NDVI en América del Norte fueron consistentes con los resultados simulados, con casi una diferencia de tres veces en las tendencias negativas de NDVI derivadas de los sensores MODIS Terra (17,4 %) y Aqua (6,7 %) durante 2002–2010. Los ajustes planificados a la calibración de Terra MODIS para el reprocesamiento de datos de la Colección 6 eliminarán en gran medida este sesgo negativo en la detección de tendencias de NDVI (Wang, y otros, 2012).

De acuerdo con Brunsell & Lin (2013), la deconstrucción de los impulsores del cambio de vegetación a gran escala es fundamental para predecir y gestionar los cambios climáticos y de uso de la tierra proyectados que afectarán la cubierta vegetal regional en ecosistemas degradados o amenazados, El objetivo de este estudio fue

evaluar los impactos potenciales del cambio de la cobertura terrestre en la cuenca del río Kansas (KRB) comparando los impactos microclimáticos locales y las influencias climáticas a escala regional. Esto se hizo utilizando una serie de tiempo de 25 años de índice de vegetación de diferencia normalizada (NDVI) y datos de precipitación (PPT) analizados utilizando métricas de teoría de la información de resolución múltiple. Los resultados mostraron que la entropía de PPT y NDVI varió a lo largo de un gradiente de PPT pronunciado. La entropía relativa a escala de NDVI fue la más informativa a escala anual, mientras que para PPT la entropía relativa a escala varió temporalmente y según el tipo de cobertura terrestre. La entropía relativa de NDVI y PPT en función de la cobertura del suelo mostró la mayor cantidad de información en la escala de 512 días para todos los tipos de cobertura del suelo, lo que implica que diferentes tipos de cobertura del suelo tuvieron la misma respuesta en todo el KRB. Esto implica que las decisiones sobre el uso de la tierra pueden alterar drásticamente las escalas de tiempo locales de las respuestas al cambio climático global. Además, la alteración de la cobertura terrestre (p. ej., para la producción de biocombustibles) puede afectar el funcionamiento del ecosistema a escala local y regional y estos impactos deben considerarse para evaluar con precisión las implicaciones futuras del cambio climático. También se encontró que la relación entre NDVI y PPT varió con los diferentes tipos de cobertura del suelo. A pesar de la falta de resultados significativos de otros análisis estadísticos

tradicionales, como el coeficiente de correlación y los análisis de regresión lineal, nuestro método propuesto ha mostrado resultados notables en la entropía relativa entre NDVI y PPT (Brunsell & Lin , 2013).

Hilker *et al* (2014), en su estudio sobre el aumento de la temperatura de la superficie del mar ecuatorial ha generado preocupaciones de que la intensificación de los eventos de oscilación del sur de El Niño (ENOS) y el desplazamiento de la zona de convergencia intertropical podrían alterar los patrones de precipitación en la Amazonía, lo que resultaría en una mayor duración de la sequía. estacional y sequías severas más frecuentes. Las reacciones de tal sequía sobre el cambio climático global podrían ser sustanciales; la selva amazónica almacena aproximadamente 120 mil millones de toneladas de carbono. La pérdida de productividad forestal en la Amazonía claramente exacerbaría los niveles atmosféricos de CO₂; sin embargo, actualmente se desconoce hasta qué punto el secado afecta la vegetación terrestre. La teledetección satelital es la única forma práctica de observar los impactos potenciales que estos cambios pueden tener en la vegetación a escalas espaciales y temporales útiles, pero en los últimos años, se han informado resultados contradictorios sobre si la productividad de los bosques tropicales está limitada por la luz solar. o precipitación. Varios estudios han indicado que la productividad primaria bruta aumenta inicialmente durante la sequía como resultado de un aumento en la radiación fotosintéticamente activa (PAR), pero la

sensibilidad a las sequías prolongadas y los umbrales de muerte regresiva de. Un trabajo reciente sugiere una incertidumbre sustancial de la reflectancia de la superficie de MODIS en la cuenca del Amazonas como una causa probable de estas discrepancias en la interpretación. La reflectancia de la superficie se deriva de forma rutinaria de las mediciones de la parte superior de la atmósfera utilizando la corrección atmosférica basada en píxeles y la detección de nubes. Estimación deficiente de las cargas de aerosoles atmosféricos y las deficiencias en la detección de nubes pueden, por lo tanto, introducir errores en los índices de vegetación. Para este estudio se utilizó el análisis de series temporales de NDVI para obtener tendencias en la vegetación a lo largo del tiempo. Existen varios métodos para evaluar los cambios en las series temporales del NDVI, incluidos los basados en umbrales simples o modelos de series temporales más completos. Aquí, el ajuste de series de tiempo se basa en el enfoque TIMESAT. Desarrollada originalmente para la serie NDVI del espectrorradiómetro de imágenes de muy alta resolución avanzada, la técnica se ha adaptado para MODIS. Se utilizó el método de filtro de Savitzky-Golay para ajustar splines a una ventana de observaciones satelitales que se mueve temporalmente. El uso de este método de filtrado adaptativo permite el ajuste de series temporales de observaciones sin suponer que los datos son estacionarios. Para tener en cuenta que la mayor parte del ruido en el NDVI está sesgado negativamente, el algoritmo se ajustó a la envolvente superior del NDVI

observado. Los cambios netos en NDVI se obtuvieron de forma análoga a los cambios en la precipitación. Los datos MODIS antes de finales de febrero de 2000 se sustituyeron por los promedios mensuales correspondientes de 2001 a 2002 para obtener un conjunto completo de observaciones para el año 2000 (Hilker, y otros, 2014).

Quanqin *et al* (2015), en su estudio muestran como la deforestación a gran escala puede afectar el balance energético de la superficie y, en consecuencia, el clima al cambiar las propiedades físicas de la superficie terrestre, es decir, los efectos biofísicos. Este estudio presenta el cambio potencial en el presupuesto de energía causado por la deforestación en el noreste de China y sus implicaciones climáticas, que se evaluó cuantificando las diferencias en las propiedades físicas de la superficie observadas por MODIS entre las tierras de cultivo y los bosques. Se usa los productos terrestres de MODIS para el período 2001-2010 en 112 celdas de $0,75^\circ \times 0,75^\circ$ cada una, dentro de las cuales solo se seleccionan píxeles satelitales de la mejor calidad sobre los píxeles de bosques puros y tierras de cultivo para comparar. En este estudio, se utilizaron datos MODIS, datos de cobertura terrestre y datos de forzamiento meteorológico para evaluar los cambios en el presupuesto de energía causados por la posible conversión de bosques a tierras de cultivo en el noreste de China. Los resultados sugieren que la deforestación tiende a causar enfriamiento en invierno y calentamiento en verano. Además, presentamos el patrón espacial del

cambio en el presupuesto de energía asociado con la conversión de la tierra. Las temperaturas superficiales terrestres alteradas muestran la misma variación estacional y dependencia espacial, lo que indica que el desequilibrio energético debido a la deforestación tiende a aumentar y disminuir las temperaturas superficiales y eventualmente afectará el clima. Todavía vale la pena investigar la relación entre el balance de energía, la temperatura de radiación y la temperatura del aire (Quanqin , Wei, Lin , Lulú , & Tian, 2015)

Johnson (2016), llevó a cabo una evaluación exploratoria para determinar la fuerza de la correlación y el momento óptimo de varios productos de imágenes compuestas del espectrorradiómetro de imágenes de resolución moderada (MODIS) de uso común contra el rendimiento de los cultivos para 10 productos agrícolas de importancia mundial. Los cultivos analizados incluyeron cebada, canola, maíz, algodón, patatas, arroz, sorgo, soja, remolacha azucarera y trigo. Los datos MODIS investigados incluyeron el índice de vegetación de diferencia normalizada (NDVI), la fracción de radiación fotosintéticamente activa (FPAR), el índice de área foliar (LAI) y la producción primaria bruta (GPP), además de la temperatura de la superficie terrestre diurna (DLST) y la temperatura nocturna. LST (NLST). Todas las imágenes utilizadas tenían intervalos de tiempo de 8 días, pero NDVI tenía una resolución espacial de 250 m mientras que los otros productos tenían 1000 metro. Estos conjuntos de datos MODIS también se evaluaron desde los satélites Terra y

Aqua, con sus diferentes tiempos de sobrevuelo, para documentar cualquier diferencia. Un análisis de seguimiento, utilizando los datos de NDVI de Terra 250 m como punto de referencia, analizó la utilidad de predicción de rendimiento de NDVI en dos escalas espaciales (250 m frente a 1000 m), dos precisiones de tiempo (8 días frente a 16 días), y también evaluó el Índice de Vegetación Mejorado (EVI, en 250 m, 16 días). Los análisis abarcaron las principales áreas agrícolas de los Estados Unidos (EE. UU.) desde los veranos de 2008 a 2013 y utilizaron como base los datos anuales de rendimiento de cultivos promedio a nivel de condado del Departamento de Agricultura de EE. UU. Todos los cultivos, excepto el arroz, mostraron al menos algunas correlaciones positivas con cada uno de los índices relacionados con la vegetación en la mitad de la temporada de crecimiento, y el NDVI se desempeñó ligeramente mejor que el FPAR. LAI estuvo menos fuertemente correlacionado y el GPP fue débil en general. Por el contrario, algunos de los cultivos, en particular la canola, el maíz y la soja, también mostraron correlaciones negativas con el DLST a mediados del verano. Sin embargo, NLST nunca se correlacionó con el rendimiento del cultivo, independientemente del cultivo o del momento estacional. Se encontró que las diferencias entre los resultados de Terra y Aqua eran mínimas. El NDVI de resolución de 1000 m mostró un rendimiento algo más pobre que el de 250 m y sugiere que la resolución espacial es útil pero no una necesidad. Las relaciones entre el NDVI de 8 días y el de 16 días

con los rendimientos fueron muy similares, excepto por la precisión temporal. Finalmente, el EVI a menudo mostró el mejor desempeño de todas las variables, considerando todas las cosas (Johnson, 2016).

En segunda instancia se muestra el resultado obtenido de la investigación del artículo llamado *Análisis de la degradación en coberturas vegetales asociados a la teledetección MODIS: Un Mapeo Sistemático*, a continuación, se presentan los resultados de una revisión sistemática, donde se usó el repositorio Scopus y Web of Science para obtener la metadata e información de todos los artículos relacionados con las palabras clave Coberturas Vegetales, Cambio Climático, Índices de Vegetación, Series de Tiempo, MODIS; con el objetivo de identificar el enfoque que se le está dando al desarrollo de este tipo de proyectos. Teniendo en cuenta la revisión realizada, a continuación, se presentan los artículos más relevantes en los cuales se utiliza la percepción remota satelital a través de MODIS como el principal enfoque para la solución del problema de investigación.

Introducción

Las variaciones climáticas globales han estado ocurriendo a lo largo de la historia, sin embargo, en las últimas décadas la actividad humana ha influenciado en gran medida al aumento de esta problemática propiciando que este sea un tema de carácter obligatorio en las preocupaciones de la sociedad actual. El deterioro del

capital natural, el aumento de la vulnerabilidad ante riesgos de desastres naturales y el cambio climático es trascendental debido al reto inaplazable para la humanidad de definir las estrategias para afrontarlo. El calentamiento del sistema climático ha puesto en entredicho las formas modernas de organización de la sociedad, en función del bienestar comunitario, el crecimiento económico y la conservación de los ecosistemas por lo tanto es de vital importancia realizar investigaciones y estudios que permitan mitigar, advertir y evitar la continua degradación de las coberturas vegetales.

El presente documento muestra una revisión de 12 artículos reportados en Scopus y Web of Science relacionados con la degradación en coberturas vegetales y teledetección MODIS. Para el análisis de estos documentos se realiza una agrupación con base a una antigüedad no mayor a 5 años, en las áreas de investigación censado remoto y ciencias ambientales y como se reportan a partir de estos los mejores resultados, siendo: variables consideradas para la degradación en coberturas vegetales, las coberturas vegetales mas usadas, softwares más implementados, métricas para evaluar la precisión de los estudios y los índices de vegetación más usados. El resto de este documento está organizado así: en la parte 2 se describe el protocolo de investigación llevado a cabo para realizar la revisión sistemática. La parte 3 muestra los resultados obtenidos de dicha revisión asociados a las preguntas de investigación formuladas y finalmente, en la parte 4 se presentan

las conclusiones recomendaciones y trabajo futuro que espera sean tenidas en cuenta como punto de partida en otras investigaciones

Metodología

Los documentos relacionados con la temática de investigación se buscaron en Scopus y Web of Science. Posterior a esto, se aplicó la clasificación por rango de tiempo seguido de los criterios de inclusión/exclusión para la selección de los y seguidamente se realizó una lectura completa de ellos artículos para poder finalmente se realizar una evaluación de la calidad de los estudios incluidos.

Las preguntas de investigación de esta revisión buscan recopilar la información existente acerca del análisis y Construcción de Escenarios Prospectivos en Coberturas Naturales Bajo el Contexto del Cambio Climático, con el fin de realizar una revisión general del tema (ver Tabla 1).

Pregunta de Investigación	Motivación
RQ1. ¿Cuáles variables son consideradas para el análisis de degradación de coberturas vegetales bajo el contexto del cambio climático?	Determinar cuáles son los factores más influyentes en una degradación de coberturas vegetales.
RQ2. ¿Cuáles son las coberturas vegetales más estudiadas en el análisis	Establecer la dinámica temporal del comportamiento de las coberturas vegetales.

de series temporales bajo el contexto del cambio climático?

RQ3. ¿Cuáles son los softwares más usados para un análisis temporal en coberturas vegetales con imágenes MODIS?	Determinar los algoritmos con mejor adaptabilidad.
-----------------------------------------------------------------------------------------------------------------	----------------------------------------------------

RQ4. ¿Cuáles son las métricas para precisión de los estudios en el análisis de degradación en coberturas vegetales?	Identificar los métodos o modelos más usados con el fin de estimar la precisión del estudio.
---------------------------------------------------------------------------------------------------------------------	----------------------------------------------------------------------------------------------

RQ5. ¿Cuáles son los índices de vegetación utilizados para medir la degradación de cobertura vegetal con imágenes satelitales?	Determinar el estado general de las coberturas vegetales.
--------------------------------------------------------------------------------------------------------------------------------	-----------------------------------------------------------

Tabla 1. Preguntas de Investigación.

Los términos de la cadena de búsqueda fueron construidos a través de un proceso iterativo de mejora con el análisis de los resultados de acuerdo con la cadena de búsqueda más idónea. Se hizo uso de la estrategia planteada la cual consiste en derivar los términos de las preguntas de investigación, identificando y sinónimos. Los operadores booleanos OR incorporan palabras alternativas y sinónimos en cada una de las partes, y los operadores AND para vincular los términos principales entre sí. A continuación, se presenta un conjunto de palabras claves agrupadas por sinónimos forest cover change, land cover change, estimation of change cover, forest

coverage, tree cover, time series, forecasting, MODIS, Moderate Resolution Imaging Spectroradiometer, climate change, Southern Oscillation, enso, oni, prospective scenarios, future scenarios, scenario prediction, vegetation indices, vegetation indexes, ndvi, vegetation index, Normalized Difference Vegetation Index

Las búsquedas se realizaron sobre Scopus y Web of Science. Siguiendo el proceso propuesto en (Petersen, Vakkalanka, & Kuzniarz, 2015), la búsqueda se organizó en fases; en la primera se identificaron los estudios candidatos derivados de las palabras claves de la cadena de búsqueda, una vez esto que se procedió a aplicar el rango de tiempo y quitar los artículos 2017 posteriormente se aplican los criterios de inclusión/exclusión sobre el abstract de cada uno de ellos, subsiguientemente los mismos criterios fueron aplicados a la lectura de todo el documento de los estudios resultantes de la fase previa, finalmente se aplicó la técnica “evaluación de calidad”, la cual consiste en revisar los estudios de acuerdo a las preguntas que responden a evaluación de calidad la Tabla 3 resume el proceso de búsqueda realizado a igual que la figura 1.

Actividad	Resultados
Aplicación búsqueda en base de datos	372
Quitar artículos antes del 2017	150
Aplicar criterios de inclusión/exclusión	44

Lectura de texto de completo	27
Evaluación de calidad	20

Tabla 2. Proceso de búsqueda

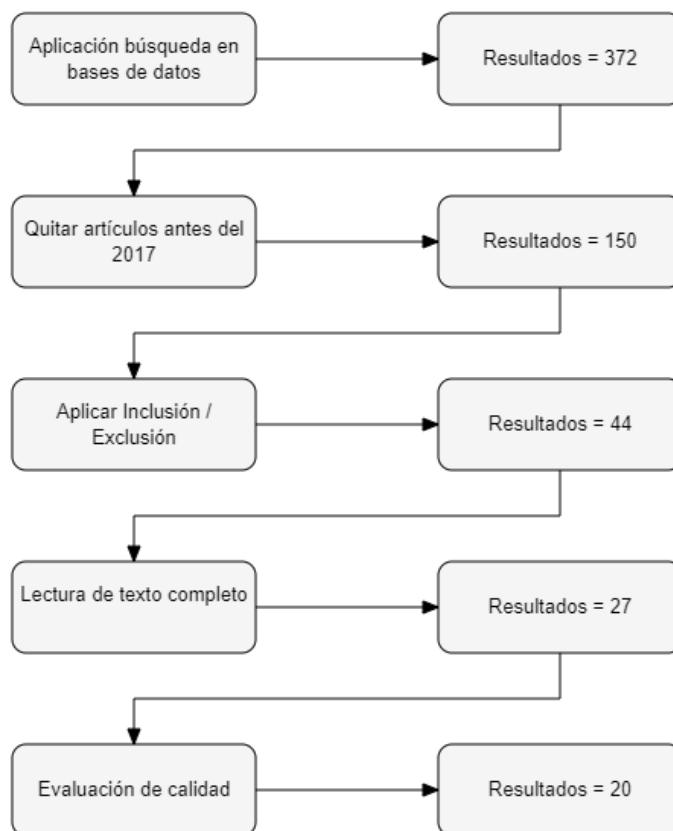


Figura 1. Proceso de búsqueda

De acuerdo al proceso de búsqueda establecido, en la Fig. 1 se logra establecer que de acuerdo a la aplicación de búsqueda en bases de datos y la cadena de búsqueda aplicada se encontraron 364 resultados de los cuales al quitar los artículos del período de tiempo antes del 2017 se obtiene un resultado de 150 documentos

perdiendo en el proceso 222, subsiguientemente se aplican criterios de inclusión y exclusión con los cuales se obtienen 36 resultados perdiéndose en el proceso 106 documentos seguidamente se hace una lectura de texto completo aplicando criterios de inclusión y exclusión nuevamente obteniendo un resultado de 19 documentos con lo cual en el proceso se pierden 17, finalmente en lo que se refiere a la evaluación de calidad se obtienen 20 resultados para la investigación con lo cual se pierden 7 artículos en este proceso.

Una vez obtenidos los resultados de la búsqueda se procede a hacer una clasificación de publicación por año en donde se puede establecer que de acuerdo a la Grafica 1, se observa que en el año 2021 hay 7 publicaciones, año 2020 4 publicaciones, año 2019 4 publicaciones, 2018 2 publicaciones y año 2017 1 publicación es de resaltar que en el año 2019, 2020 y 2021 están consignados la mayoría de publicaciones y también se resalta que a través de los años se ha venido estableciendo un auge en este tema de investigación en relación a los años 2017 y 2018.

En este mismo sentido de ideas se procede a realizar una clasificación de acuerdo con la ubicación geográfica de los resultados obtenidos se puede establecer que en el Sur de Asia, Sudáfrica, Rusia Grecia, África Asia tan sólo tienen 1 solo documento asociado a la investigación es de resaltar que Canadá y estado unidos tienen 2 documentos, Brasil 4 y China una mayor proporción con 6 documentos. No

se encuentra ningún estudio asociado a Colombia de manera oficial en las bases de datos utilizadas. En ese mismo orden de ideas se procede a clasificar los resultados obtenidos a partir de su área de estudio por lo cual en la Gráfica 3, se puede observar cómo en la categoría Remote Sensing se obtienen 8 estudios, Environmental Sciences 8 resultados y 4 resultados para la combinación de Remote Sensing / Environmental Sciences.

Criterios de inclusión y exclusión: Los criterios para incluir un estudio fueron los siguientes: 1) Los estudios se publicaron en línea en el marco temporal de 2017-2021 Scopus and Web of Science.; 2) Los estudios son en el área de Environmental Sciences and Earth and Planetary Sciences para la base Scopus; y 3) Los estudios son en las categorías Environmental Sciences and Remote Sensing para la base Web of Science. Los criterios para excluir un estudio fueron los siguientes: 1) Estudios que presentan resúmenes de conferencias/editoriales o directrices/plantillas para la realización de estudios cartográficos; 2) Estudios que presentan material no revisado por pares; 3) Estudios no presentados en inglés. 4) Estudios no accesibles en texto completo; 5) Libros y literatura gris; 6) Estudios que son duplicados de otros estudios; 7) Estudios de satélites pagos; 8) Estudios que no hablen de series temporales, 9) Estudios que no hablen sobre MODIS; y 10) Estudios que no presenten un análisis temporal.

Evaluación de calidad de los estudios: Adicional a la selección (criterios de inclusión y exclusión) se realizó una evaluación de la calidad de los estudios (Petersen et al., 2015) para ponderar la importancia de cada estudio seleccionado. Esta evaluación permitió comprender mejor las posibles comparaciones entre los estudios y guiar la interpretación de los hallazgos. Con este objetivo se desarrolló 4 preguntas 1) ¿Se encuentra disponible el algoritmo y/o software?; 2) ¿Está claramente definido el proceso de realización del estudio (extracción de datos, conjunto de datos, clasificación) ?; 3) ¿Existe una serie temporal con un periodo de tiempo mayor a 5 años? Es decir, se excluyen los estudios que no tengan este periodo de tiempo asociado a sus resultados, 4) ¿Existe una métrica de validación para la precisión en los resultados obtenidos?

Resultados

Variables Consideradas (RQ1)

De acuerdo con Xiang *et al* (2019), en su estudio logran establecer variables determinantes para la degradación de las coberturas vegetales tales como el carbono, el nitrógeno y el agua estos como factores importantes que influyen en las huellas ambientales, en este mismo sentido nombran la evotranspiración lo cual deja huella hídrica en diferentes escenarios de suministro de agua (Xiang et al., 2019), Bezerra, Aguiar, Alvala, Giarolla, Bezerra, Lima, Nascimento, Arai (2020) del mismo modo establecen como la precipitación y la evotranspiración impactan en la desertificación

(Bezerra et al., 2020). Swain, Abeysundara, Hayhoe y Stoner (2017), Jing *et al* (2018), establecen como factores importantes la precipitación y la temperatura diarias (Ge et al., 2018; Swain et al., 2017), así como Ima y Baoxin (2021), la temperatura superficial terrestre (Ituen & Hu, 2021). En este orden de ideas los autores como Gemitzi (2021) y Dawen, Guangmin, Yangong, Quian & Xiaowei (2019) y Levers, Schneider, Prishchepov, Estel, Kuemmerle (2018) consideran la temperatura y precipitación como factores determinantes (Gemitzi, 2021; Levers et al., 2018; Qian et al., 2019) Mei & Qiong (2020), además de la temperatura y precipitación consideran una variable adicional como lo es el carbono (Yu & Gao, 2020).

Cushman, Macdonald, Landguth, Yadvinder & Macdonald (2017), proponen varias variables ambientales y antropogénicas como predictores de la pérdida reciente de coberturas vegetales en este caso adicional a temperatura y precipitación se establece como un factor determinante la distancia a grandes centros de población, sin lugar a dudas no solo el cambio climático relacionado directamente con los cambios de temperatura y cambiantes condiciones atmosféricas junto a la desmedida producción de dióxido de carbono generada por la actividad humana es el principal responsable del calentamiento global y el cambio climático actual (Cushman Ewan A Macdonald Erin L Landguth Yadvinder Malhi David W Macdonald et al., 2017).

Coberturas Vegetales (RQ2)

Mingtao, Qiangyi & Wenbin (2019) y Xingwen *et al* (2020), en su estudio establecen las tierras de cultivos como su eje principal de estudio (Lin *et al.*, 2020; Xiang *et al.*, 2019), en este mismo sentido de ideas los autores Jing *et al* (2018), instauran que los datos de estudio son coberturas de pastizales con terrenos relativamente planos (Ge *et al.*, 2018), y bosques así Mardian, Berg & Daneshfar (2021), los cuales generalizan estableciendo a los pastizales como zona de estudio (Mardian *et al.*, 2021). En este mismo contexto los autores Magnússon *et al* (2021), usan vegetación de tundra y taiga como eje principal de su estudio (Magnússon *et al.*, 2021), Shahzad *et al* (2020), usan la clasificación de bosques, matorrales, sabanas, pastizales y tierras de cultivo (Ali *et al.*, 2020), así como Ima & Baoxin (2021), los cuales emplean bosques mixtos y bosques de coníferas (Ituen & Hu, 2021), Gemitzi (2021), asimismo utilizan en su estudio en general bosques (Gemitzi, 2021)

Similarmente Dawen, Guangmin, Yangong, Qian & Xiaowei (2019), establecen en su estudio pastizales, matorrales y bosques como zona de estudio (Qian *et al.*, 2019), mientras tanto Ibrahim, Sa'ad , Balzter, Tansey, Mathieu, & Tsutsumida (2019), emplean la cobertura de suelo leñoso, herbáceo y desnudo (Ibrahim *et al.*, 2019). Mei Yu & Qiong Gao (2020), bosques y pastizales (Yu & Gao, 2020), no obstante Garcia *et al* (2019), instauran en su estudio como zona la

selva amazónica y pastizales (Garcia et al., 2019) para finalizar Cushman, Macdonald, Landguth, Yadvinder & Macdonald (2017), emplean bosques a partir de esto es necesario resaltar como las coberturas vegetales como pastizales y bosques son las zonas de estudio más representativas en estudios de investigación enfocados en las series temporales ya que es un factor determinante establecer el comportamiento de esta a través del tiempo (Cushman Ewan A Macdonald Erin L Landguth Yadvinder Malhi David W Macdonald et al., 2017).

Software Implementados (RQ3)

Jing *et al* (2018), aplican modelos de regresión, modelos de regresión multivariante y un modelo de máquina de vectores de apoyo, trabajando en el software SPSS 16.0 implementado en Matlab basado en el paquete LIBSVM (Ge et al., 2018). Mientras tanto Mardian, Berg & Daneshfar (2021), Garcia *et al* (2019), usan el software estadístico R el cual es un entorno y lenguaje de programación con un enfoque al análisis estadístico, del mismo modo en este estudio se emplea el suavizador Whittaker modificado empleando series de tiempo uniformemente espaciadas con una relación señal-ruido mejorada (Garcia et al., 2019; Mardian et al., 2021). En tal sentido Magnússon *et al* (2021), usan a R en una implementación espaciotemporal del modelo de Potts (Magnússon et al., 2021) así como Mei & Qiong (2020), usan a R en conjunto con las series temporales de tiempo (Yu & Gao, 2020). Kato, Carlson & Miura (2021), de acuerdo a su publicación implementan las

series de tiempo aplicando el filtro de Savitzky–Golay el cual es un filtro que se basa en el cálculo de una regresión polinomial local (de grado k), el resultado será una función similar a los datos de entrada, pero suavizada, la principal ventaja de esta aproximación es que tiende a preservar características de la distribución inicial tales como los máximos y mínimos relativos, así como el ancho de los picos, que normalmente desaparecen con otras técnicas de promediado (Kato et al., 2021).

Gemitzi (2021), en su estudio usa el modelo oculto de Márkov el cuales es un modelo estadístico en el que se asume que el sistema a modelar, el objetivo de este es determinar los parámetros desconocidos de dicha cadena a partir de los parámetros observables, en este mismo sentido se implementa una red de neuronas (Gemitzi, 2021). En este mismo contexto Cushman, Macdonald, Landguth, Yadvinder & Macdonald (2017), implementan FRAGSTATS programa de software diseñado para calcular una amplia variedad de métricas de paisaje para patrones de mapas categóricos el cual se adapta a ArcGIS (Cushman Ewan A Macdonald Erin L Landguth Yadvinder Malhi David W Macdonald et al., 2017) asimismo Ituen & Baoxin (2021), usan los softwares ArcMap y Matlab (Ituen & Hu, 2021).

Lo anteriormente expuesto muestra cómo el software R es uno de los lenguajes de programación más usados en los estudios ya que es muy implementado en Sistemas de Información Geográfica para geoprocesos (junto con Python) ya que cuenta con muchas cualidades permitiendo realizar cálculos estadísticos y espaciales

con capas tanto vectoriales como ráster cómodamente mediante scripts, haciendo uso de distintos paquetes específicos para tal fin entonces podemos decir que los software nombrados en los estudios de investigación son fácilmente adaptable a las imágenes MODIS a usar en los estudios.

Métricas de precisión (RQ4)

Mingtao, Qiangyi & Wenbin (2019), Dawen, Guangmin, Yangong, Qian & Xiaowei (2019), aplican el enfoque de matriz de confusión para validar la información obtenida en el proceso de análisis espacio temporal de coberturas vegetales (Qian et al., 2019; Xiang et al., 2019), en este mismo sentido los autores Garcia *et al* (2019), Magnússon *et al* (2021), determinaron a partir de matrices de confusión de detección de cambios la evaluación de cambios de la presión (Garcia et al., 2019; Magnússon et al., 2021). Shahzad *et al* (2020), en este mismo sentido como la calidad de y las posibles fuentes de errores identificadas pueden proporcionar información a través de la evaluación de la precisión implementando la matriz de error o matriz de confusión la cual ha surgido como un método consistente para indicar la precisión de los resultados de clasificación resultantes de los datos de teledetección (Ali et al., 2020)

En tal sentido Mardian, Berg & Daneshfar (2021), implementan una forma de validez basado en los ráster de inventario anual de cultivos, como también una

inspección visual de la zona de estudio en DigitalGlobe disponibles a través de imágenes históricas de Google Earth Pro (Mardian et al., 2021). Gemitzi (2021) y Boubacar, Aruna, Ebrima, Sidat & Mamma (2021), para ambos estudios usan como parámetro de validación el software en línea globeland30 así como el TerrSet 2020 Geospatial Monitoring and Modeling Software (Gemitzi, 2021; Solly et al., 2021). Lo anteriormente expuesto establece como las métricas de evaluación no solo se hacen a través de matrices de confusión para establecer la precisión de un estudio si no también la gran importancia de la verificación visual y de inspección a las zonas de estudio las cuales pueden ser corroboradas a través del tiempo con archivos.

Índices de vegetación (RQ5)

Mingtao, Qiangyi & Wenbin (2019), aplica en su estudio NDVI (Índice de Vegetación Diferencial Normalizado) resolución 250 m, del mismo modo establecen que el índice de área foliar es otra opción de trabajo (Xiang et al., 2019), en este mismo sentido los autores Dawen, Guangmin, Yangong, Qian & Xiaowei (2019), (Sa'ad , Balzter, Tansey, Mathieu, & Tsutsumida (2019), emplean el NDVI con resolución espacial 250 m y resolución temporal de 16 días (Ibrahim et al., 2019; Qian et al., 2019). Similarmente Jing *et al* (2018), Mardian, Berg y Daneshfar (2021), aplican en su estudio los productos NDVI Y EVI (Índice de Vegetación Mejorado) con resolución espacial 250 m y resolución temporal de 16 días (Ge et al., 2018; Mardian et al., 2021)

Ima & Baoxin (2021), en paralelo implementan el NDVI con resolución espacial 250 m y resolución temporal 16 días, pero sugieren otros productos como EVI e Índice de Área Foliar (LAI) (Ituen & Hu, 2021). Pero por otra parte Magnússon *et al* (2021), Mei & Qiong (2020), solamente hacen uso del EVI (Magnússon *et al.*, 2021; Yu & Gao, 2020) como Shahzad *et al* (2020), usando exclusivamente el NDVI en paralelo (Ali *et al.*, 2020) Gemitzi (2021), aplica e NDVI, pero con una resolución espacial de 500 m (Gemitzi, 2021). Por otro lado, Garcia *et al* (2019) y Zhang, Abrahao, Cohn, Campolo y Thompson (2021), usan el EVI con una resolución espacial de 250 m y una resolución temporal del 8 días y EVI compuesto de 16 días (Garcia *et al.*, 2019; Zhang *et al.*, 2021). Sin lugar a dudar es de resaltar que los índices más utilizados son el NDVI y el EVI en estudios de degradación de las coberturas vegetales los cuales entregan una información completa y con una mayor precisión.

Conclusiones

Los resultados obtenidos de esta revisión sistemática demuestran como china es el país que más dedica inversión en estudios de coberturas vegetales a través de teledetección, así mismo se logra establecer como América Latina no cuenta con estudios de carácter oficial en esta área, en este mismo sentido de ideas se pueden evidenciar como softwares de tipo estadístico son de gran apoyo en este tipo de estudios y como su libre de acceso hace fácil su implementación, de igual manera

como son consideradas las variables que afectan una degradación de las coberturas vegetales como precipitación, temperatura y asentamientos cerca de las zonas de estudio. En ese mismo contexto se establece como las coberturas vegetales más implementadas son los pastizales, cultivos y bosques, en lo que respecta a los índices de vegetación los estudios demuestran que el rendimiento de MODIS NDVI y EVI es casi idéntico con la misma precisión pero acuerdo con el consenso en la teledetección agrícola el EVI ocasionalmente se desempeña mejor que NDVI debido a las correcciones atmosféricas y de fondo en su fórmula y una mayor sensibilidad en regiones de alta biomasa.

Respecto al trabajo futuro, se sugiere lo siguiente: 1) El desarrollo de investigaciones de carácter oficial asociadas a la degradación de coberturas vegetales en Latino América específicamente Colombia debido a que este es segundo país más rico en recursos naturales a nivel mundial lo cual establece la gran importancia en este tipo de investigaciones y 2) Establecer el estudio realizado como un punto de partida en orientación a trabajos futuros enfocados en la teledetección asociados a degradación de coberturas vegetales

Capítulo 3: Metodología

EL proyecto se desarrolló con una metodología del patrón de investigación iterativo, usando conceptos relacionados con el análisis de series temporales basándose en imágenes satelitales MODIS y datos meteorológicos. Dicho lo anterior, se construyó un conjunto de datos mediante la recolección de información meteorológica e índices de vegetación obtenidas a partir del sensor MODIS, enfocándose en zonas de bosques naturales ubicados en áreas correspondientes al Macizo Colombiano.

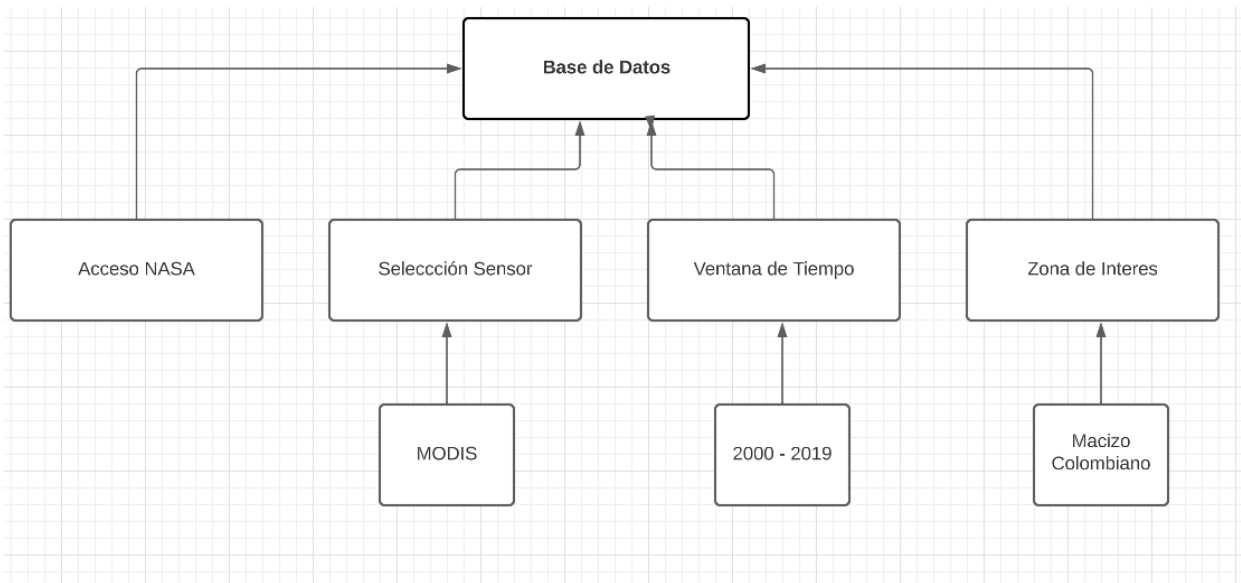


Figura 2. Proceso construcción base de datos.

Se procedió a realizar la búsqueda de la información correspondiente meteorología e índices de vegetación. En este caso para los índices de vegetación

(NDVI), se ingresa a la página de la NASA (<https://ladsweb.modaps.eosdis.nasa.gov/view-data/#@0.0,0.0,3z>).



Figura 3. LAADS DAAC Level-1 and Atmosphere Archive & Distribution System Distributed Active Archive Center

Una vez se realiza el ingreso en la página se procedió a realizar la selección del sensor (TERRA y AQUA) y producto de interés (Índices de Vegetación - NDVI), posteriormente se procede a seleccionar la ventana de tiempo y zona de interés, a descargar donde se encuentra contenido el area de estudio Macizo Colombiano.

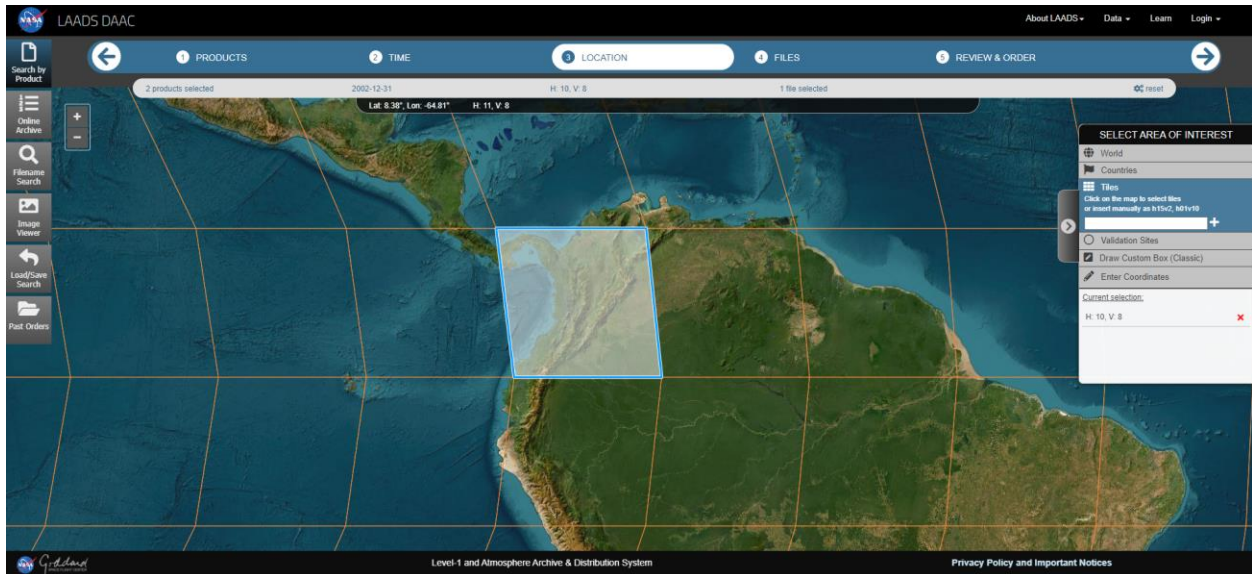


Figura 4. Zona de Interés en donde se encuentra contenida el área de estudio Macizo Colombiano

Por último, en el caso que hace referencia a meteorología, el proyecto se apoyó de la serie temporal presentada en la National Weather Service, realizado con la Cold & Warm Episodes by Season por temporadas (https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php).

Year	DJF	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ
2010	1.5	1.2	0.8	0.4	-0.2	-0.7	-1.0	-1.3	-1.6	-1.6	-1.6	-1.6
2011	-1.4	-1.2	-0.9	-0.7	-0.6	-0.4	-0.5	-0.6	-0.8	-1.0	-1.1	-1.0
2012	-0.9	-0.7	-0.6	-0.5	-0.3	0.0	0.2	0.4	0.4	0.3	0.1	-0.2
2013	-0.4	-0.4	-0.3	-0.3	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.3
2014	-0.4	-0.5	-0.3	0.0	0.2	0.2	0.0	0.1	0.2	0.5	0.6	0.7
2015	0.5	0.5	0.5	0.7	0.9	1.2	1.5	1.9	2.2	2.4	2.6	2.6
2016	2.5	2.1	1.6	0.9	0.4	-0.1	-0.4	-0.5	-0.6	-0.7	-0.7	-0.6
2017	-0.3	-0.2	0.1	0.2	0.3	0.3	0.1	-0.1	-0.4	-0.7	-0.8	-1.0
2018	-0.9	-0.9	-0.7	-0.5	-0.2	0.0	0.1	0.2	0.5	0.8	0.9	0.8
2019	0.7	0.7	0.7	0.7	0.5	0.5	0.3	0.1	0.2	0.3	0.5	0.5

Figura 5. Episodios cálidos y fríos por temporadas National Weather Service

A partir de la información brindado por el grupo Grupo de óptica y Laser (GOL), de la Universidad el Cauca, se obtuvieron los archivos shape de departamentos y parques naturales, identificándose los departamentos que conforman al Macizo Colombiano: Cauca, Huila, Nariño, Caquetá, Putumayo y Tolima y posteriormente las zonas que fueron de interés.




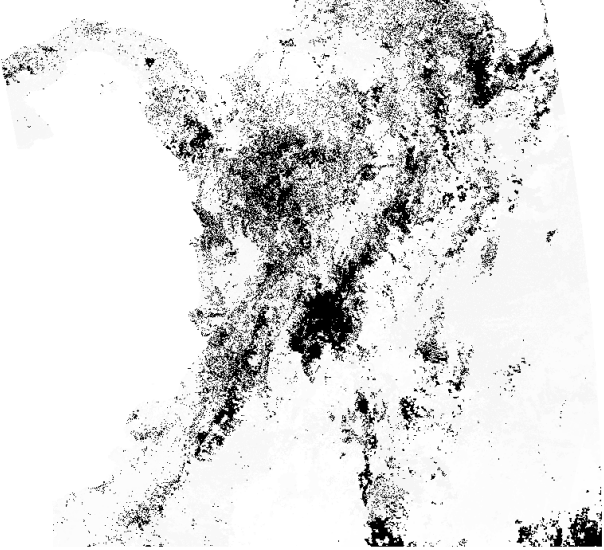

Figura 6. Área de Estudio departamentos que conforman el Macizo Colombiano

Una vez descargadas las imágenes satelitales MODIS se procedió a realizar la organización de acuerdo a la ventana de tiempo sobre el área de estudio y de la misma manera la identificación en la base de datos meteorológicos correspondiente a la ventana de tiempo seleccionada.

Año	Terra	Aqua
2000	MYD13Q1.A2000361	MOD13Q1.A2000361
2001	MYD13Q1.A2001361	MOD13Q1.A2001361
2002	MYD13Q1.A2002361	MOD13Q1.A2002361
2003	MYD13Q1.A2003361	MOD13Q1.A2003361
2004	MYD13Q1.A2004361	MOD13Q1.A2004361
2004	MYD13Q1.A2005361	MOD13Q1.A2005361
2005	MYD13Q1.A2006361	MOD13Q1.A2006361
2006	MYD13Q1.A2007361	MOD13Q1.A2007361
2008	MYD13Q1.A2008361	MOD13Q1.A2008361
2009	MYD13Q1.A2009361	MOD13Q1.A2009361
2010	MYD13Q1.A20010361	MOD13Q1.A20010361
2011	MYD13Q1.A20011361	MOD13Q1.A20011361
2012	MYD13Q1.A20012361	MOD13Q1.A20012361
2013	MYD13Q1.A20013361	MOD13Q1.A20013361
2014	MYD13Q1.A20014361	MOD13Q1.A20014361
2015	MYD13Q1.A20015361	MOD13Q1.A20015361
2016	MYD13Q1.A20016361	MOD13Q1.A20016361
2017	MYD13Q1.A20017361	MOD13Q1.A20017361
2018	MYD13Q1.A20018361	MOD13Q1.A20018361
2019	MYD13Q1.A20019361	MOD13Q1.A20019361

Tabla 3. Nombre de archivos TERRA y Aqua en la ventana de tiempo seleccionada

En la Tabla 3, se presenta una muestra de los nombres imágenes descargadas para el desarrollo de proyecto, en este mismo orden de ideas se presenta en la Figura 7 y 8 una muestra de los archivos descargados para el desarrollo del proyecto de investigación.

	
<p>Figura 7. Imagen Satelital AQUA MOD13Q1 año 2000 día 353</p>	<p>Figura 8. Imagen Satelital AQUA MYD13Q1 año 2000 día 361</p>

En la Figura 7 y 8, se muestra los datos de la versión 6 de los índices de vegetación MOD13Q1 y MYD13Q1 del espectrorradiómetro de imágenes de resolución moderada Terra y Aqua (MODIS) del día 353 del año 2000. Una vez consolidada se consolidó la información obtenida se construyó la base de datos para el desarrollo del análisis espacio temporal.

Capítulo 4: Resultados y Discusión

El principal insumo del proyecto consiste en imágenes satelitales MODIS de las plataformas TERRA y AQUA, la base de datos está conformada por compuestos mensuales comprendidos desde los años 2000 hasta 2019. Inicialmente se crea un framework que abarca las herramientas requeridas para el pre-procesamiento de la información, el análisis de los datos, la extracción del conjunto de datos final, la creación del modelo estadístico ARIMA y el desarrollo de los escenarios prospectivos, el diagrama de clases del Framework se muestra a continuación:

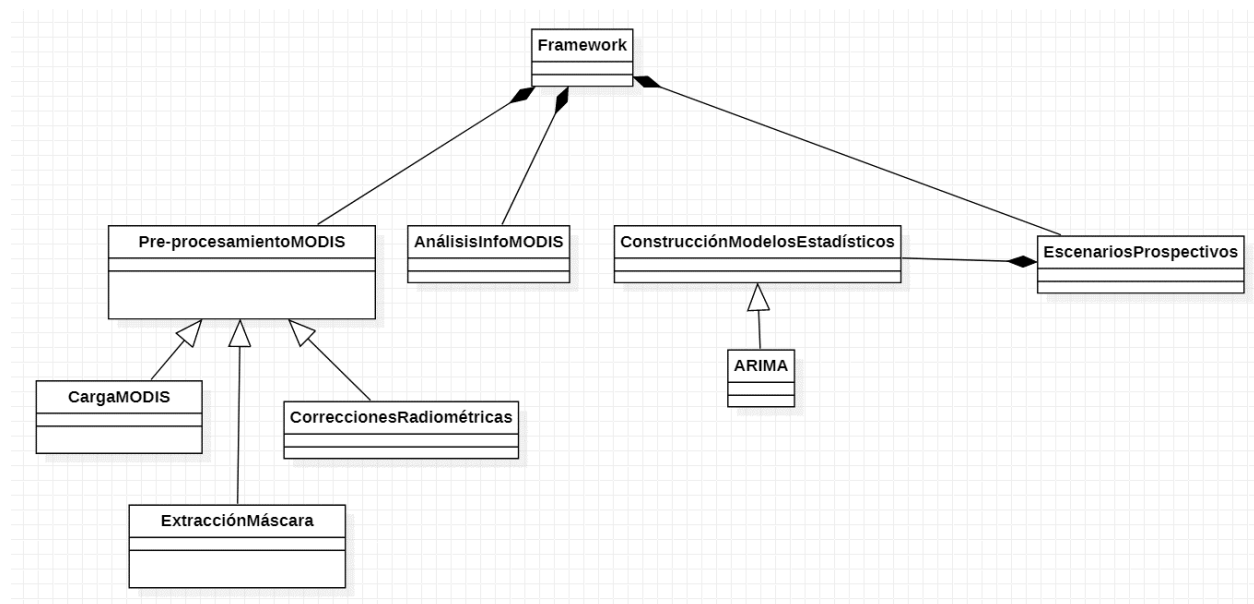


Figura 9. Diagrama de clases del Framework para la creación de escenarios prospectivos utilizando imágenes satelitales MODIS y modelos estadísticos.

La Figura 9, muestra el framework construido y encargado del proceso de creación de escenarios prospectivos utilizando imágenes satelitales MODIS y un

modelo estadístico ARIMA, 4 módulos principales conforman el framework, los módulos se detallan a continuación:

Pre-procesamiento: módulo encargado de incluir mediante la propiedad de la herencia de la programación orientada a objetos las tareas de cargar las imágenes MODIS en formato HDF, extracción de máscaras de nubes y las correcciones radiométricas.

Carga MODIS: módulo encargado de cargar las imágenes en formato HDF, así como, de la extracción del índice de vegetación de diferencia normalizada (NDVI) requerido para el proceso de creación de escenarios prospectivos.

Extracción Máscara: módulo para la extracción de confiabilidad de los píxeles y la creación de máscaras de nubes presentes en las escenas satelitales.

Correcciones Radiométricas: módulo para la corrección radiométrica de las imágenes satelitales MODIS. Los productos satelitales AQUA y TERRA son corregidos mediante el modelo matemático recomendado por el proveedor de las imágenes, la ecuación se muestra a continuación:

$$MODIS_{TOA} = \sum_{i,j} \frac{MODIS(i,j)}{factorConversion}, factorConversion = 10000$$

Análisis MODIS: módulo para la creación de las escenas de interés del proyecto: parques naturales sobre la región del Macizo Colombiano.

Construcción Modelos Estadísticos: módulo que implementa mediante la propiedad de la Herencia de la programación orientada a objetos el modelo estadístico ARIMA, este módulo tiene la posibilidad de incluir en futuros proyectos nuevos modelos de análisis de series temporales.

Escenarios Prospectivos: módulo encargado de cargar el modelo ARIMA y crear los escenarios prospectivos utilizando el índice de vegetación NDVI.

4.1 Construcción del conjunto de datos

En esta primera parte se realiza la descarga y obtención del paquete de imágenes satelitales MODIS, este proceso fue descrito en el capítulo 3 análisis espacio temporal de series satelitales MODIS. Una vez obtenido el paquete de imágenes satelitales MODIS se procedió a realizar la extracción de capa del NDVI través del código de Python `extract_modis` mostrado a continuación.

```

from fnmatch import fnmatch
import cv2 as cv
import netCDF4 as nc
import numpy as np
from os import system
import os
import glob
from osgeo import gdal
from pyhdf.SD import SD, SDC

def leap_year(year):
    return ( year % 4 == 0 and year % 100 !=0 ) or year % 400 == 0

def juliano2date(julianoDay,_year):
    year = int(_year)
    leap = leap_year(year)
    days = [31, 28, 31, 30, 31, 30, 31, 31, 30, 31, 30, 31]
    if leap == True:
        days[1] = 29
    day = int(julianoDay)
    sum = 0
    for k, item in enumerate(days):
        sum += item
        if sum >= day:
            dd = item - (sum - day)
            if k+1 < 10 or dd < 10:
                mm = str(k+1).zfill(2)
                dd = str(dd).zfill(2)
            else:
                mm = str(k+1)
                dd = str(dd)
            formatted_day = str(year) + "-" + mm + "-" + dd
            break
    return formatted_day

```

Figura 10. Fragmento código Python implementado para la extracción banda NDVI paquete de imágenes HDF MODIS

Las imágenes satelitales están almacenadas en formatos HDF por lo que un proceso de selección de la información es realizado, los productos escogidos para el trabajo son resaltados en color gris en la siguiente figura:

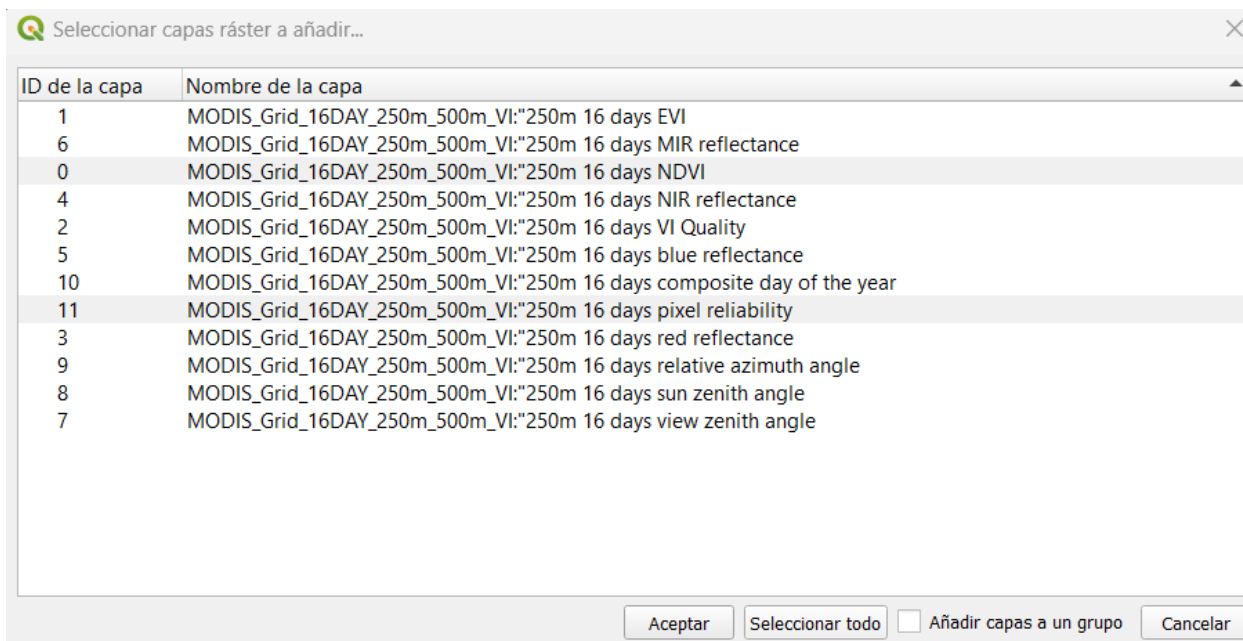


Figura 11. Selección de los productos MODIS: índice de vegetación de diferencia normalizada (NDVI) y máscara de confiabilidad de píxeles.

Un ejemplo de producto MODIS relacionado con el compuesto mensual NDVI sin corrección radiométrica es mostrado a continuación:




Figura 12. Producto mensual MODIS sin corrección radiométrica correspondiente al índice de vegetación de diferencia normalizada (NDVI).

Para verificar que los productos MODIS iniciales no tiene la corrección radiométrica se construye un análisis mediante histograma para ver de manera generalizada el componente espectral de la imagen satelital. El siguiente histograma presentado en la figura muestra el contenido espectral y su distribución en el índice de vegetación:

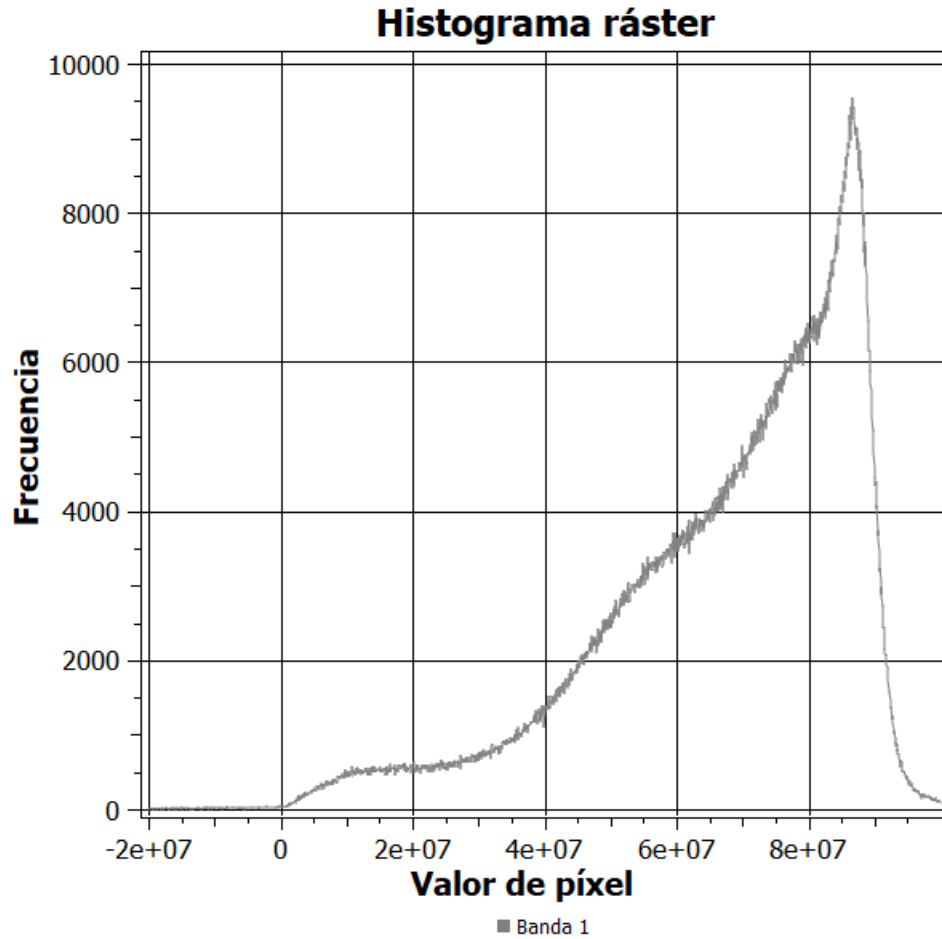


Figura 13. Histograma de frecuencias del contenido espectral de los productos MODIS sin corrección radiométrica.

Se observa en la Figura 16 que los valores de los píxeles no se encuentran normalizados razón por la cual el índice de vegetación no tiene validez, un proceso de corrección radiométrica es realizado, su histograma se muestra en la siguiente figura:

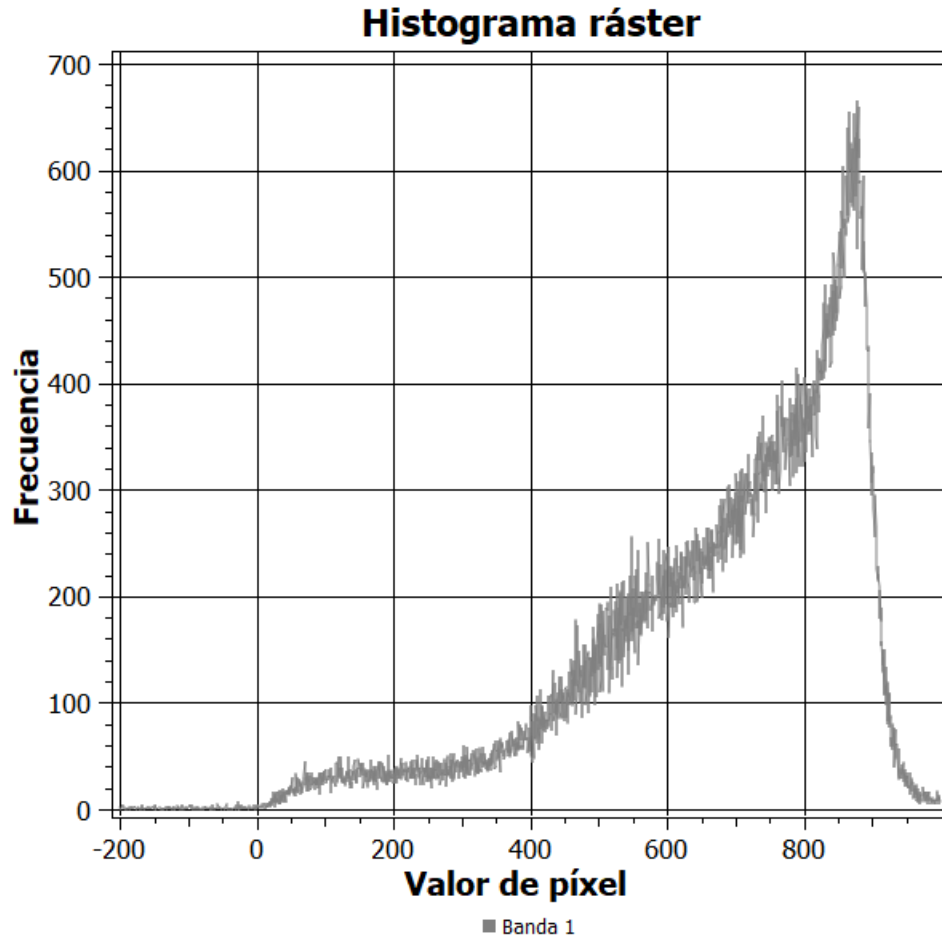


Figura 14. Corrección radiométrica de la imagen satelital MODIS aplicando el modelo propuesto desde el servidor de descarga.

La zona de interés para el proyecto está comprendida sobre el Macizo Colombiano y los parques naturales, razón por la cual un recorte del área de interés se realiza sobre toda la serie temporal MODIS del producto de índice de vegetación de diferencia normalizada, el archivo vectorial correspondiente a los parques naturales ubicados sobre el Macizo Colombiano se muestra a continuación:




Figura 15. Archivo vectorial correspondiente a los parques naturales ubicados sobre el Macizo Colombiano, el archivo vectorial de parques se muestra sobre una imagen satelital MODIS – NDVI.



Figura 16. Parques naturales ubicados sobre el Macizo Colombiano, los pixeles mostrados corresponden al índice de vegetación NDVI del compuesto mensual MODIS

Aplicando la herramienta de recorte se observa en la siguiente imagen la zona trabajada en el proyecto y para la cual se construyen los escenarios prospectivos. Finalmente, para la implementación de un modelo estadístico ARIMA es requerido un conjunto de datos correspondientes a los valores espectrales del índice de

vegetación de diferencia normalizada, la estructura del conjunto de datos se muestra en la siguiente figura:

Conjunto de datos		Meses											
		Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
Año 2000	Px[0,0]	value	value	value	value	value	value	value	value	value	value	value	value
	Px[0,1]	value	value	value	value	value	value	value	value	value	value	value	value
	.	value	value	value	value	value	value	value	value	value	value	value	value
	.	value	value	value	value	value	value	value	value	value	value	value	value
	Px[100,100]	value	value	value	value	value	value	value	value	value	value	value	value
Año 2001	Px[0,0]	value	value	value	value	value	value	value	value	value	value	value	value
	Px[0,1]	value	value	value	value	value	value	value	value	value	value	value	value
	.	value	value	value	value	value	value	value	value	value	value	value	value
	.	value	value	value	value	value	value	value	value	value	value	value	value
	Px[100,100]	value	value	value	value	value	value	value	value	value	value	value	value
Año 2019	.	value	value	value	value	value	value	value	value	value	value	value	value
	.	value	value	value	value	value	value	value	value	value	value	value	value
	Px[0,0]	value	value	value	value	value	value	value	value	value	value	value	value
	Px[0,1]	value	value	value	value	value	value	value	value	value	value	value	value
	.	value	value	value	value	value	value	value	value	value	value	value	value

Figura 17. Estructura del conjunto de datos construido a partir de la serie temporal MODIS del índice de vegetación de diferencia normalizada relacionado con parques naturales ubicados sobre el Macizo Colombiano.

4.2 Análisis espacio temporal y escenarios prospectivos con métricas de precisión

Una vez obtenidas las imágenes satelitales MODIS, extraída la banda NDVI realizada la corrección radiométrica y aplicada la máscara de nubes se procedió a ejecutar el código Python `buil_dataset`, donde se cargan estas imágenes y se procede a obtener como resultado el dataset que alimento a software R.

```

from fnmatch import fnmatch
import cv2 as cv
import netCDF4 as nc
import numpy as np
from os import system
import os
import glob
from osgeo import gdal
from pyhdf.SD import SD, SDC

def leap_year(year):
    return ( year % 4 == 0 and year % 100 != 0 ) or year % 400 == 0

def juliano2date(julianoDay,_year):
    year = int(_year)
    leap = leap_year(year)
    days = [31, 28, 31, 30, 31, 30, 31, 31, 30, 31, 30, 31]
    if leap == True:
        days[1] = 29
    day = int(julianoDay)
    sum = 0
    for k, item in enumerate(days):
        sum += item
        if sum >= day:
            dd = item - (sum - day)
            if k+1 < 10 or dd < 10:
                mm = str(k+1).zfill(2)
                dd = str(dd).zfill(2)
            else:
                mm = str(k+1)
                dd = str(dd)
            formatted_day = str(year) + "-" + mm + "-" + dd
            break
    return formatted_day

```

Figura 18. Fragmento código Python implementado para la obtención del dataset que alimenta al software R

```

2912.0, 2126.0, 2018.0, 1.0, 1.0, 8069.0
2912.0, 2126.0, 2018.0, 1.0, 17.0, 7297.0
2912.0, 2126.0, 2018.0, 2.0, 2.0, 1969.0
2912.0, 2126.0, 2018.0, 2.0, 18.0, 2254.0
2912.0, 2126.0, 2018.0, 3.0, 6.0, 1572.0
2912.0, 2126.0, 2018.0, 3.0, 22.0, 2192.0
2912.0, 2126.0, 2018.0, 4.0, 7.0, 774.0
2912.0, 2126.0, 2018.0, 4.0, 23.0, 8071.0
2912.0, 2126.0, 2018.0, 5.0, 9.0, 7355.0
2912.0, 2126.0, 2018.0, 5.0, 25.0, 8215.0
2912.0, 2126.0, 2018.0, 6.0, 10.0, 7486.0
2912.0, 2126.0, 2018.0, 6.0, 26.0, 8019.0
2912.0, 2126.0, 2018.0, 7.0, 12.0, 1821.0
2912.0, 2126.0, 2018.0, 7.0, 28.0, 8148.0
2912.0, 2126.0, 2018.0, 8.0, 13.0, 9563.0
2912.0, 2126.0, 2018.0, 8.0, 29.0, 8189.0
2912.0, 2126.0, 2018.0, 9.0, 14.0, 6029.0
2912.0, 2126.0, 2018.0, 9.0, 30.0, 7716.0
2912.0, 2126.0, 2018.0, 10.0, 16.0, 7697.0
2912.0, 2126.0, 2018.0, 11.0, 1.0, 2422.0
2912.0, 2126.0, 2018.0, 11.0, 17.0, 8047.0
2912.0, 2126.0, 2018.0, 12.0, 3.0, 1521.0
2912.0, 2126.0, 2018.0, 12.0, 19.0, 3956.0
2913.0, 2126.0, 2018.0, 1.0, 1.0, 8158.0
2913.0, 2126.0, 2018.0, 1.0, 17.0, 7251.0
2913.0, 2126.0, 2018.0, 2.0, 2.0, 2335.0
2913.0, 2126.0, 2018.0, 2.0, 18.0, 2254.0
2913.0, 2126.0, 2018.0, 3.0, 6.0, 1951.0
2913.0, 2126.0, 2018.0, 3.0, 22.0, 3018.0
2913.0, 2126.0, 2018.0, 4.0, 7.0, 779.0
2913.0, 2126.0, 2018.0, 4.0, 23.0, 5599.0
2913.0, 2126.0, 2018.0, 5.0, 9.0, 7355.0
2913.0, 2126.0, 2018.0, 5.0, 25.0, 7999.0

```

Figura 19. Fragmento dataset obtenido que alimentara al software R a partir de las imágenes NDVI – MODIS

A partir del dataset obtenido se procedió a alimentar al Software R, en el cual se implementó el Modelo Arima; este es un modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción hacia el futuro. Dentro del modelo se empleó la función `auto.arima` la cual está incluida en la librería `forecast` y proporciona una opción rápida para construir modelos y pronósticos con series temporales, debido a que evalúa entre todos los posibles modelos, al mejor, considerando diversos criterios: estacionariedad, estacionalidad, diferencias, entre otras.

```
spl_datos <- split(datos,paste(datos$x,datos$y))

# Solo un ejemplo
#
# onets <- spl_datos[[2]]
#
# onets <- ts(onets$value, frequency = 24, start = c(2019, 1))
#
# autoarima <- auto.arima(onets)
#
# forecast <- forecast(autoarima,h=10)
#
# plot(forecast)
#
# tran_f

# transversal

transv_autoArim <- function(onets,longfore=5){
  autoarima <- auto.arima(onets[,6])
  as.data.frame(forecast(autoarima,h=longfore))
}

spl_datos_ts <- lapply(spl_datos,ts)

forecast <- lapply(spl_datos_ts,transv_autoArim,longfore=6)

nam_forecast <- names(forecast)
```

Figura 20. Código implementado modelo ARIMA función `auto.arima` para predicción de escenario futuros.

	pixel	Point,Foreca	Lo,80	Hi,80	Lo,95	Hi,95	
24	2912	2126	5581,82609	1741,26061	9422,39156	-291,811938	11455,4641
25	2912	2126	5581,82609	1741,26061	9422,39156	-291,811938	11455,4641
26	2912	2126	5581,82609	1741,26061	9422,39156	-291,811938	11455,4641
27	2912	2126	5581,82609	1741,26061	9422,39156	-291,811938	11455,4641
28	2912	2126	5581,82609	1741,26061	9422,39156	-291,811938	11455,4641
29	2912	2126	5581,82609	1741,26061	9422,39156	-291,811938	11455,4641
241	2913	2126	5557	2106,76043	9007,23957	280,313922	10833,6861
251	2913	2126	5557	2106,76043	9007,23957	280,313922	10833,6861
261	2913	2126	5557	2106,76043	9007,23957	280,313922	10833,6861
271	2913	2126	5557	2106,76043	9007,23957	280,313922	10833,6861
281	2913	2126	5557	2106,76043	9007,23957	280,313922	10833,6861
291	2913	2126	5557	2106,76043	9007,23957	280,313922	10833,6861
242	2913	2127	4202,47683	1185,58486	7219,3688	-411,461283	8816,41493
252	2913	2127	4935,50433	1600,00604	8271,00262	-165,700094	10036,7088
262	2913	2127	5281,17003	1878,87643	8683,46364	77,8109891	10484,5291
272	2913	2127	5444,1718	2027,20252	8861,14108	218,368241	10669,9754
282	2913	2127	5521,03674	2100,81262	8941,26087	290,255337	10751,8182
292	2913	2127	5557,2831	2136,33562	8978,23057	325,395422	10789,1708
243	2913	2128	4955,13118	1907,05171	8003,21066	293,495897	9616,76647
253	2913	2128	5458,56596	2161,21927	8755,91265	415,709375	10501,4225
263	2913	2128	5666,28672	2328,35739	9004,21605	561,364337	10771,2091
273	2913	2128	5751,99378	2407,20452	9096,78303	636,580041	10867,4075
283	2913	2128	5787,35712	2441,40139	9133,31284	670,159427	10904,5548

Figura 21. Fragmento full_forecast escenarios prospectivos obtenido a partir del Modelo ARIMA

De acuerdo con el proceso realizado anteriormente se obtiene la base de datos nombrada full_forecast, la cual contiene los valores de los cuartiles de precisión del modelo ARIMA, en donde estos se encuentran entre el 80 y 95% así como también los valores del NDVI para los escenarios prospectivos con rango de pronóstico de 6 meses.

A partir de dataset full_forecast se procedió a la reconstrucción de las imágenes con el fin de lograr evidenciar y determinar los escenarios prospectivos a

continuación se muestra un fragmento del código Python utilizado para dicha reconstrucción.

```
import csv
from fnmatch import fnmatch
import cv2 as cv
import netCDF4 as nc
import numpy as np
from os import system
import os
import glob
from osgeo import gdal

list_images=[]

raster = gdal.Open("ref.tif")
image1 = raster.ReadAsArray()
image2 = raster.ReadAsArray()
image3 = raster.ReadAsArray()
image4 = raster.ReadAsArray()
image5 = raster.ReadAsArray()
image6 = raster.ReadAsArray()

list_images.append(image1)
list_images.append(image2)
list_images.append(image3)
list_images.append(image4)
list_images.append(image5)
list_images.append(image6)

dataset=None
with open('full_forecast_modificado.csv', 'r') as file:
    reader = csv.reader(file)
    dataset=list(reader)

step=0
for log in range(len(dataset)):
    if step <= 5:
        fila=int(dataset[log][1])
        columna=int(dataset[log][2])
        list_images[step][fila][columna]=float(dataset[log][3])
    else:
        step=0
```

Figura 22. Fragmento código Python implementado en la reconstrucción de las imágenes MODIS

Una vez se obtuvieron las imágenes reconstruidas, se procedió en primera instancia a corroborar que el modelo se encontraba en óptimo funcionamiento mediante la diferencia de dos imágenes, la primera 201812 la cual indicaba el mes de diciembre del 2018 y segunda la imagen 201901 mes de enero del 2019, esto con el fin de demostrar que existe un cambio en el pronóstico mes a mes. El forecast de la serie temporal nos indicó, que en las zonas rojas hubo más cambio y el color azul en donde casi no lo hubo.




Figura 23. Diferencia entre imágenes año y mes 201812 y 201901

Para realizar el análisis de los escenarios prospectivos se realizó una proyección de 6 meses del año 2019 entre los meses de enero a junio. A continuación, se evidencia las 6 imágenes forecast obtenidas a través de modelo implementado.




Figura 24. Imagen Forecast_m01 la cual indica el mes 1 de predicción – Enero 2019




Figura 25. Imagen Forecast_m02 la cual indica el mes 2 de predicción – Febrero 2019

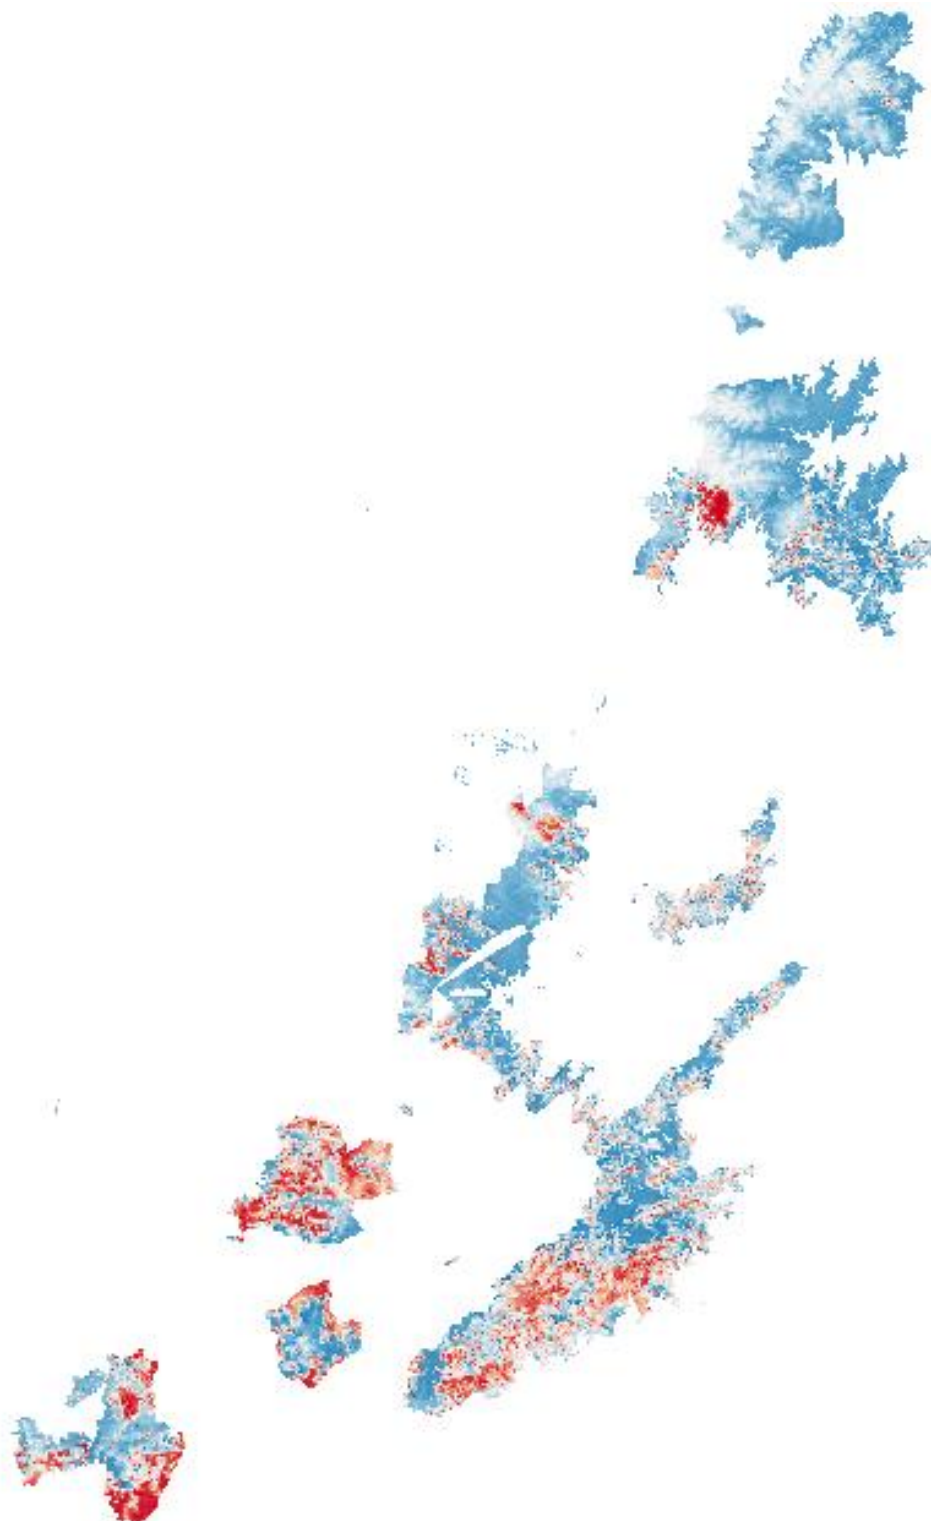


Figura 26. Imagen Forecast_m03 la cual indica el mes 3 de predicción – Marzo 2019

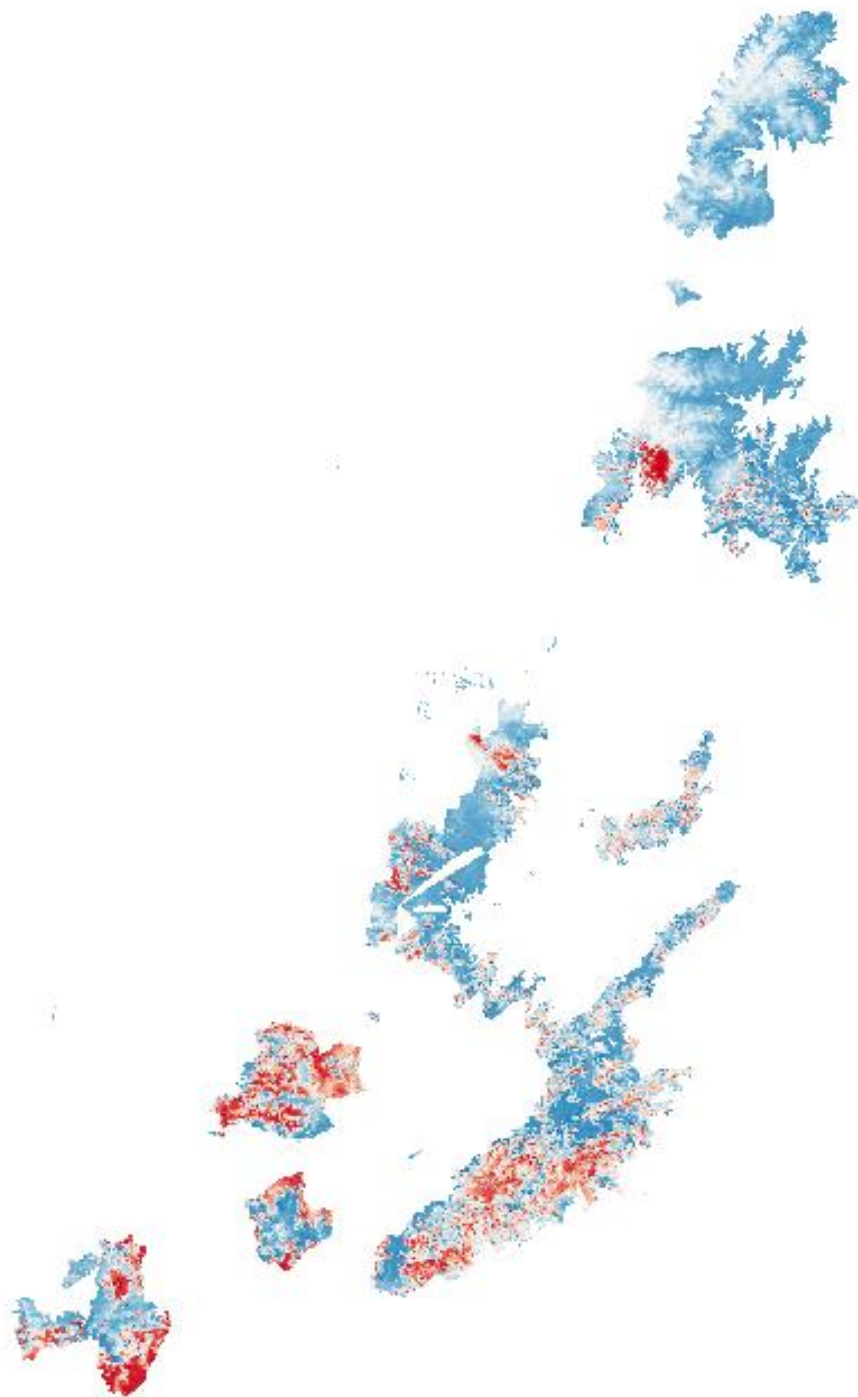


Figura 27. Imagen Forecast_m04 la cual indica el mes 4 de predicción – Abril 2019

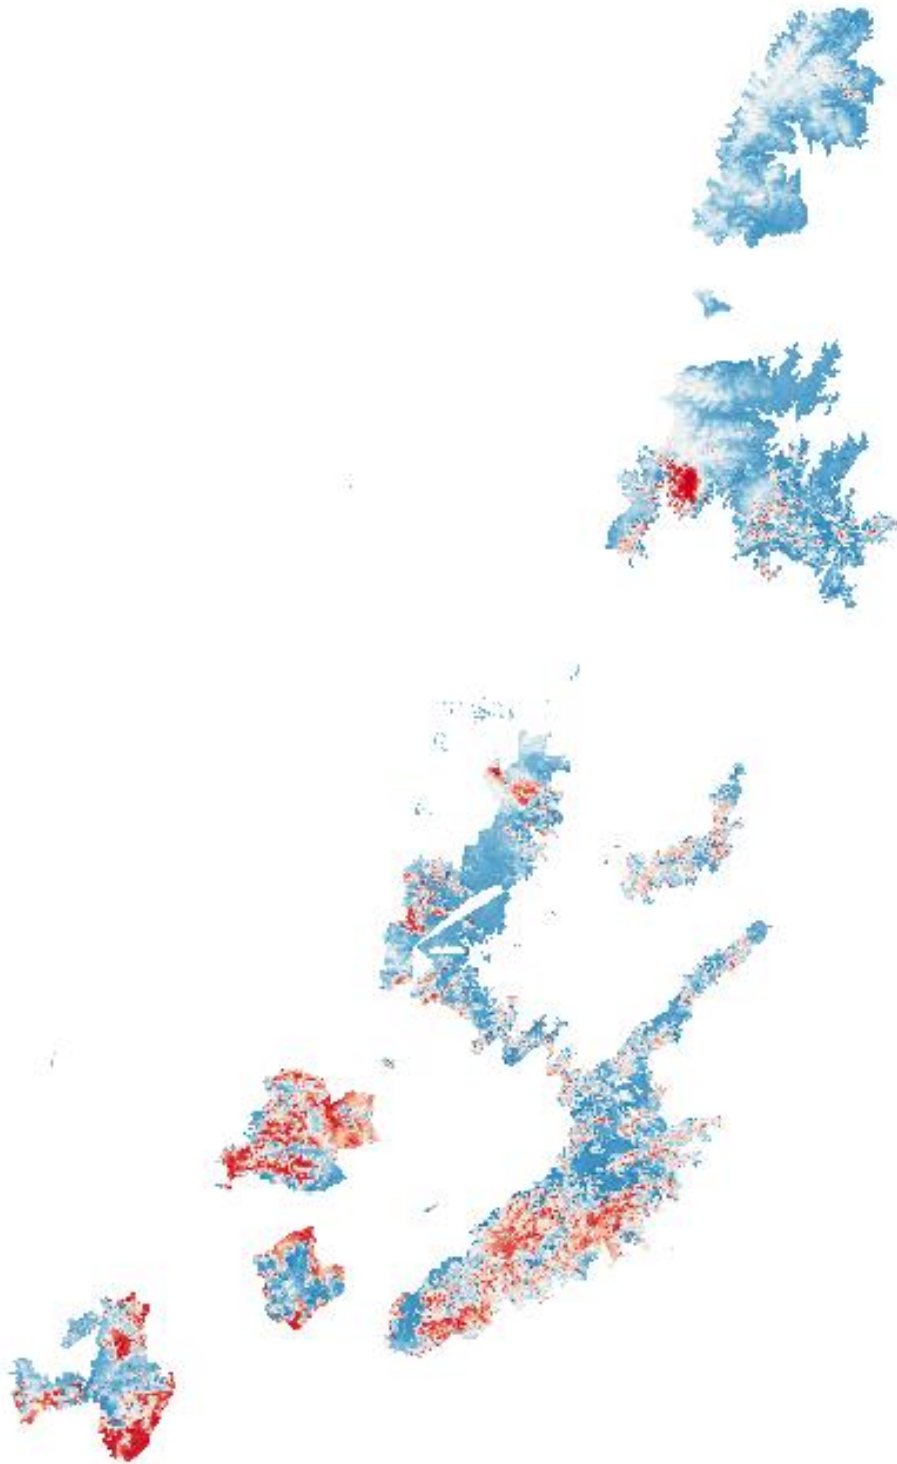


Figura 28. Imagen Forecast_m05 la cual indica el mes 5 de predicción – Mayo 2019

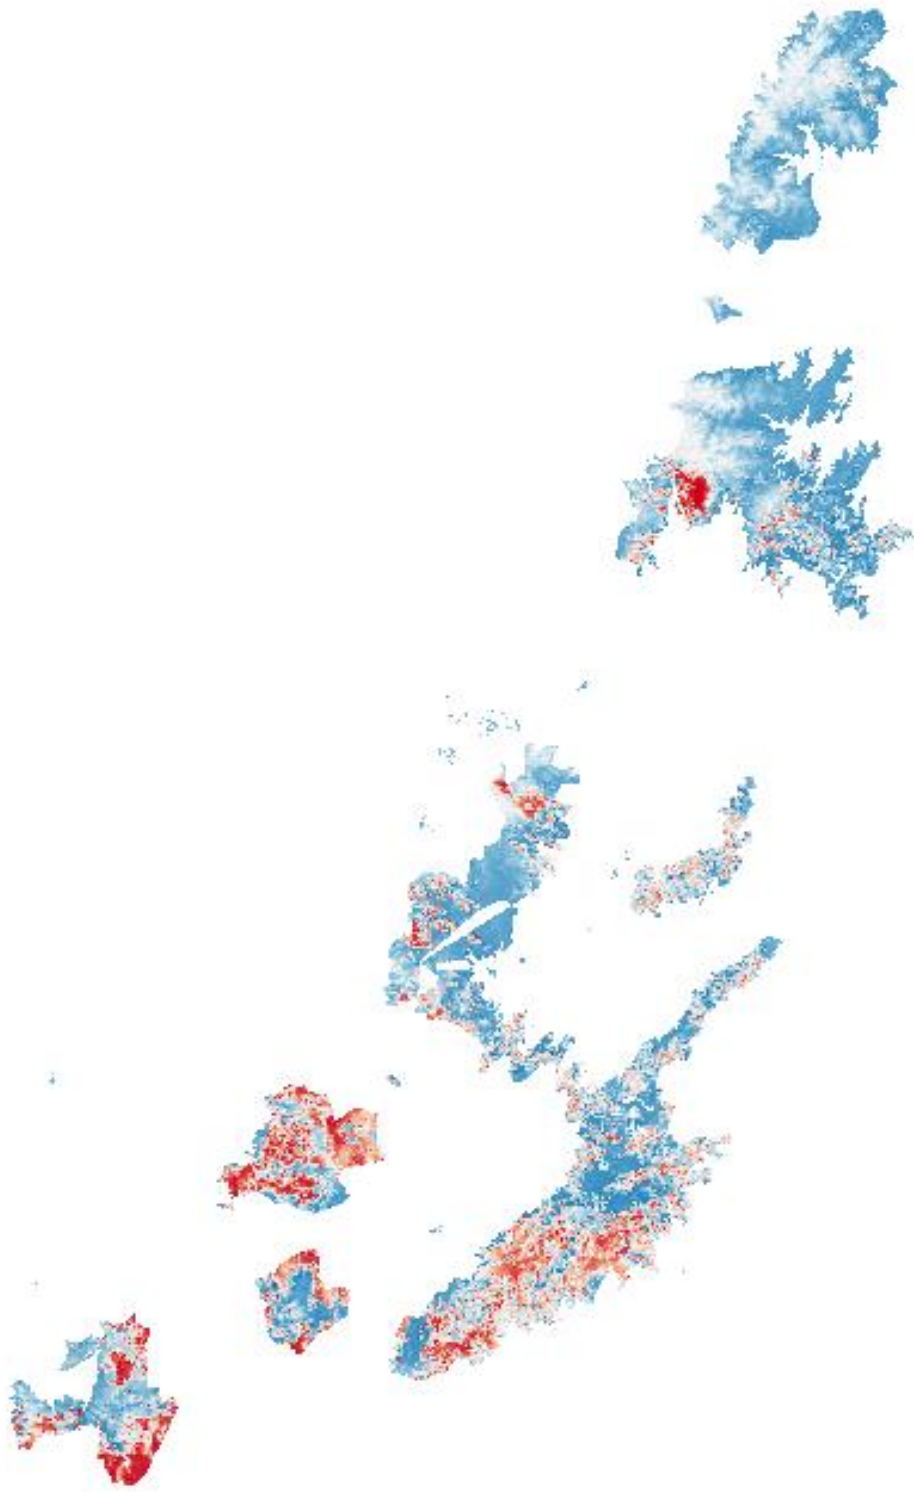


Figura 29. Imagen Forecast_m06 la cual indica el mes 6 de predicción – Junio 2019

De acuerdo con las figuras 24 a 29, se evidencia la diferencia del forecast del mes 1 enero y mes 6 junio, donde las zonas con mayor concentración de color rojo son las que más cambiaron, esto comprueba que el modelo entre más lejano se encuentre de su predicción inicial menos preciso será, es de resaltar que el modelo ARIMA tiene una presión de entre el 80% y 95% de fiabilidad.

Ahora conforme se evidencio el cambio en las zonas mes a mes se procedió a realizar la precisión para lo cual en la figura 33 se muestra la imagen MODIS 201901 la cual representa al mes de enero del 2019, en este mismo sentido en la figura 34 se encuentra la imagen de precisión la cual representa que tan cercano estuvo el modelo basado en la diferencia de la Figura 27. Imagen Forecast_m01 la cual indica el mes 1 de predicción – Enero 2019 y la Figura 33. Imagen MODIS - Enero 2019.

De esta misma manera se procedió a realizar la precisión del mes 6 el cual representa a mes de junio del 2019 en este mismo sentido en la figura 35 se encuentra la imagen de precisión la cual representa que tan cercano estuvo el modelo basado en la diferencia entre el mes de junio imagen MODIS y la Figura 32. Imagen Forecast_m01 la cual indica el mes 1 de predicción – Enero 2019




Figura 30. Imagen MODIS - Enero 2019




Figura 31. Precisión mes 01- enero 2019

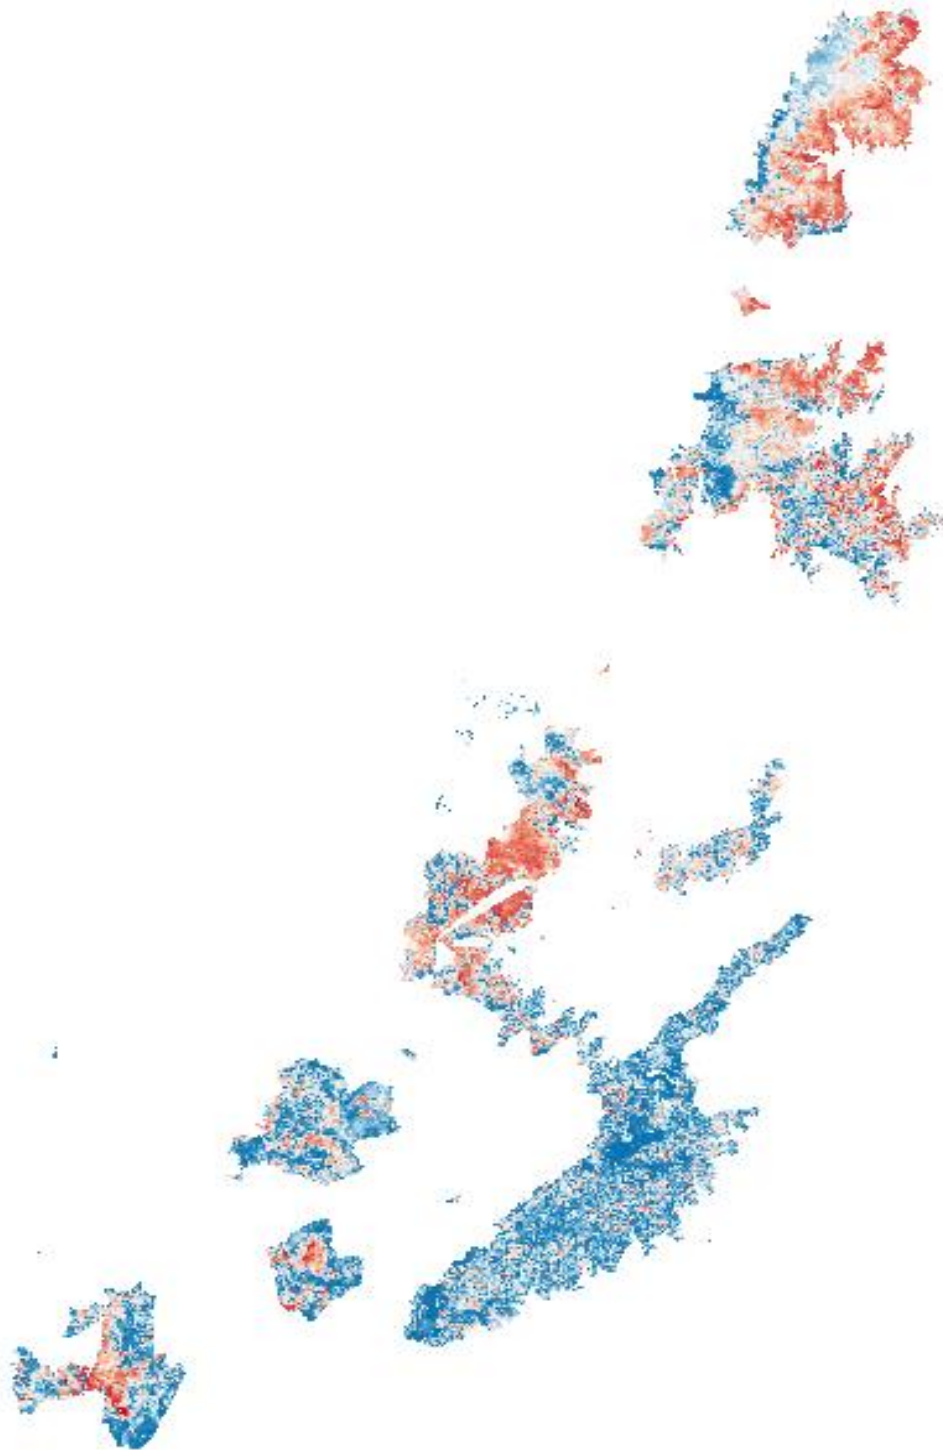


Figura 32. Precisión mes 06 - junio 2019

De acuerdo con las figuras 31 y 32 se evidencia como la precisión tiene un error dicho esto de manera general se evidencia que los cambios fueron pocos, sin embargo, estos pueden corresponder a que donde se presenta mucho cambio puede deberse a la nubosidad. Es de resaltar nuevamente que este modelo de predicción conforme a más se aleje más error se tendrá gráficamente; se observa el error que se tiene a la hora del pronosticar ya que como se nombró en las figuras 31 y 32 se puede notar las zonas de menor error es en donde menos cambio hubo.

En el color rojo se puede observar donde está el mayor error del pronóstico, notamos que estos valores de color rojo por ejemplo que en el mes 1 enero 2019 hubo nubes, por lo tanto, el pronóstico de alguna manera con la misma zona teniendo en cuenta la máscara de nubes que veníamos trabajando genera ese cambio mayor en la imagen forecast 01 y de esta misma manera para los demás pronósticos.

En el mes 06 se nota el cambio en medida del mes 01 y como el pronóstico se ve más afectado es decir que entre más se aleja a la hora de realizar un pronóstico más problemas vamos a tener, sin embargo, es de resaltar que se mejora la precisión en zonas no nubosas presentando una mayor concentración del color azul y confiabilidad del modelo se encuentra entre el 80% y 95%.

En este mismo orden de ideas se procedió a relacionar la información obtenida con los valores del ONI (Cold & Warm Episodes by Season).

Year	DJF	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ
2010	1.5	1.2	0.8	0.4	-0.2	-0.7	-1.0	-1.3	-1.6	-1.6	-1.6	-1.6
2011	-1.4	-1.2	-0.9	-0.7	-0.6	-0.4	-0.5	-0.6	-0.8	-1.0	-1.1	-1.0
2012	-0.9	-0.7	-0.6	-0.5	-0.3	0.0	0.2	0.4	0.4	0.3	0.1	-0.2
2013	-0.4	-0.4	-0.3	-0.3	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.3
2014	-0.4	-0.5	-0.3	0.0	0.2	0.2	0.0	0.1	0.2	0.5	0.6	0.7
2015	0.5	0.5	0.5	0.7	0.9	1.2	1.5	1.9	2.2	2.4	2.6	2.6
2016	2.5	2.1	1.6	0.9	0.4	-0.1	-0.4	-0.5	-0.6	-0.7	-0.7	-0.6
2017	-0.3	-0.2	0.1	0.2	0.3	0.3	0.1	-0.1	-0.4	-0.7	-0.8	-1.0
2018	-0.9	-0.9	-0.7	-0.5	-0.2	0.0	0.1	0.2	0.5	0.8	0.9	0.8
2019	0.7	0.7	0.7	0.7	0.5	0.5	0.3	0.1	0.2	0.3	0.5	0.5

Tabla 4. Valores ONI periodo 2010 – 2019

De acuerdo a la Tabla 4, se evidencia que para el periodo 201901 que indica el mes de enero del años 2019 había un fenómeno del niño existiendo oleadas de alto calor por lo tanto al ser mucho calor el NDVI se afecta de manera negativa; es de resaltar que el periodo de enero a junio, donde se encuentra establecido el periodo de tiempo de interés, se presentó un fenómeno del niño constante con el valor de 0.7, afectando directamente a los bosques naturales, lo cual también se logra comprobar a través de los forecast del mes de enero a junio.

4.3 Divulgación de los Resultados en Evento Científico

Por último, como se resultado se evidencia la ponencia en el I Simposio SoPhIC 2022 "Ciencia en las regiones" que se llevó a cabo los pasados 28 y 29 de julio de 2022. En este evento se expuso y conoció la variedad de proyectos e investigaciones que se están llevando a cabo en el país en distintas áreas del conocimiento (Ver Anexo 1 Certificado de ponencia).

Título de la ponencia: Dinámicas y Escenarios Prospectivos de las Coberturas Naturales en Subregiones del Macizo Colombiano a Través del Análisis Espaciotemporal de Series MODIS en el Contexto del Cambio Climático.

Autores: Camila Andrea Segura Ocampo, Leonairo Pencue Fierro, Julián Fernando Muñoz Ordóñez

Presentadora: Camila Andrea Segura Ocampo

Área del conocimiento: Ingeniería y tecnología

Región o departamento: Macizo Colombiano

Resumen:

El Macizo Colombiano hace parte de las riquezas naturales más grandes que posee Colombia en términos de agua, vegetación y fauna. Genera el 70% del agua dulce del país, lo que hace que su cuidado y preservación sean de vital importancia. Este trabajo pretende realizar un análisis espacio - temporal de series satelitales

MODIS para la evaluación de los factores de cambio ambiental del macizo colombiano en el contexto del cambio climático en un período 2000 y 2019. El Macizo es catalogado como una región estratégica para el país, la convergencia orográfica, la riqueza ecosistémica y su tipo de suelo generan condiciones especiales que favorecen la regulación hídrica y el mantenimiento de una alta riqueza biológica, paisajística y cultural. Las técnicas de teledetección proporcionan un sistema eficaz para monitorear la dinámica de la vegetación en múltiples escalas utilizando índices de vegetación, que se basan en la comparación de reflectancia espectral del infrarrojo cercano (NIR) y del rojo visible (R), así como en otras bandas. El índice de vegetación de diferencia normalizada (NDVI) es el más utilizado porque permite cuantificar la salud de la vegetación midiendo la diferencia entre el infrarrojo cercano (muy reflejado) y la luz roja (absorbida). Utilizando las técnicas de percepción remota, específicamente sobre los datos provenientes de los satélites Aqua y Terra del sensor MODIS, se desarrolla un análisis de la evolución temporal de los índices de vegetación obteniendo un índice de correlación con los factores de coberturas, clima y condiciones meteorológicas ONI, especificando las zonas con factores de degradación y permitiendo elaborar posibles escenarios futuros relacionados con el cambio de las coberturas de bosques naturales para las subregiones del Macizo Colombiano.

Conclusiones

La construcción de un conjunto de datos basado en imágenes satelitales MODIS, permitió en análisis espacio temporal de las coberturas boscosas correlacionadas con los episodios fríos y cálidos por temporada (ONI), además el NDVI brinda información sobre el poder vegetativo que está altamente correlacionado con los episodios de calor y frío visualizándose a través del tiempo; gracias a la construcción del conjunto de datos se facilitó el análisis y como lo demostró el estado del arte, el índice de vegetación es uno de los principales indicadores que permite evidenciar la afectación que tiene el clima sobre las coberturas.

La construcción del framework facilitó el análisis espacio temporal a través de la extracción de patrones relacionados con series temporales y analizados con el modelo estadístico ARIMA, además el framework se convierte en una herramienta para el preprocesamiento y procesamiento de la información lo que permite crear conjunto de datos que van a estar disponibles para ser aplicados en modelos estadísticos o en trabajo a futuro como en modelos de aprendizaje de máquina.

Se realizó un análisis espacio temporal que permitió evidenciar con el ONI (Cold & Warm Episodes by Season), el fenómeno que afectó el periodo de tiempo del estudio en este caso el fenómeno del niño el cual incidió negativamente el NDVI en los 6 meses pronosticados, lo que concordó con los resultados obtenidos ya que en

estos meses de análisis las zonas a través del tiempo tendieron a tornarse de un color más rojo.

Se logró evidenciar que el software R es uno de los lenguajes de programación más usados en los estudios ya que es muy implementado en sistemas de Información geográfica para geoprocursos (junto con Python), en este mismo sentido su implementación con la función `auto.arima` permite tener una fiabilidad del modelo entre el 80% y 95% pero se recomienda utilizarlo cuando no es más de 6 secuencias próximas ya que ARIMA a través del tiempo va a tender a la media y sus resultados no serán efectivos a largo plazo.

La implementación de modelo ARIMA presenta alta fiabilidad en sus resultados sin embargo evidencia que los cambios fueron pocos, y esto puede corresponder a que donde se presenta mucho cambio existe nubosidad.

Recomendaciones

Como trabajos a futuro se propone utilizar el framework construido con imágenes satelitales Sentinel-2 con el objetivo de mejorar la resolución espacial de los escenarios prospectivos y finalmente realizar un nuevo mapeo que permita establecer otros tipos de software que permitan realizar estudios con la misma fiabilidad a un largo mucho más extenso.

Bibliografía

- Ahrens, D., & Henson, R. (2021). *Meteorology Today: An Introduction to Weather, Climate, and the Environment*.
- Gómez Delgado, M., & Rodríguez Espinosa, V. (2012). *Análisis de la dinámica urbana y simulación de escenarios de desarrollo futuro con Tecnologías de la Información Geográfica*.
- Hilker, T., Lyapustin, A., Compton, T., Forrest, H., Ranga, M., Yujie, W., . . . Piers, S. (2014). Vegetation dynamics and rainfall sensitivity of the Amazon. doi:<https://doi.org/10.1073/pnas.1404870111>
- Quanqin, S., Wei, C., Lin, H., Lulú, L., & Tian, E. (2015). Satellite-Observed Energy Budget Change of Deforestation in Northeastern China and its Climate Implications. *Remote Sens*. doi:<https://doi.org/10.3390/rs70911586>
- B.P, S., J.C, O., W, K., K.J, W., F, V., & K.C, S. (2011). The use of a Multilayer Perceptron for detecting new human settlements from a time series of MODIS images. *International Journal of Applied Earth Observation and Geoinformation*, 873-883. doi:<https://doi.org/10.1016/j.jag.2011.06.007>.
- Borsdorf, A., Mergili, M., & Alfonso Ortega, L. (2013). La Reserva de la Biósfera Cinturón Andino, Colombia. ¿Una región modelo de estrategias de adaptación al cambio climático y el desarrollo regional sustentable? *Revista*

de Geografia Norte Grande, 12. Recuperado el 28 de Mayo de 2019, de <http://search.ebscohost.com/login.aspx?direct=true&db=edselc&AN=edselc.2-52.0-84899978458&lang=es&site=eds-live>

Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2016). *Time Series Analysis: Forecasting and Control*.

Brunsell, N., & Lin, P.-L. (2013). Assessing Regional Climate and Local Landcover Impacts on Vegetation with Remote Sensing. *Remote Sens*, 4347-4369. doi:<https://doi.org/10.3390/rs5094347>

Carreño Conde, F., Sipols, A., Simón de Blas, C., & Mostaza Colado, D. (2021). A Forecast Model Applied to Monitor Crops Dynamics Using Vegetation Indices (NDVI). doi:<https://doi.org/10.3390/app11041859>

Consejo Nacional de Política Económica y Social. (2018). *Lineamientos de Política y Estrategias para el Desarrollo Regional Sostenible del Macizo Colombiano*. Bogotá.

Corporación Autónoma Regional del Valle del Cauca. (2015). Plan integral de adaptación y mitigación al cambio climático.

CREPAD. (28 de Mayo de 2019). *CrepadWeb*. Obtenido de <http://crepadweb.cec.inta.es/es/plataformas/modis.html>

- Díaz Cordero, G. (2016). El cambio climático. *Ciencia y Sociedad República Dominicana*, XXXVII(2), 15. Obtenido de <https://www.redalyc.org/pdf/870/87024179004.pdf>
- Didan, K., Barreto Munoz, A., Solano, R., & Huete, A. (2015). MODIS Vegetation Index User's Guide.
- Gallego Álvarez, I., García Rubio, R., & Martínez Ferrero, J. (2018). Environmental performance concerns in Latin America: Determinant factors and multivariate analysis. *Revista de Contabilidad-Spanish Accounting Review*, 21(2), 206-221. doi:10.1016 / j.rcsar.2018.05.003
- Gaynor, P., & Kirkpatrick, R. (1994). *Introduction to Time-Series Modeling and Forecasting in Business and Economics*. McGraw-Hill College.
- Hilker, T., Natsagdorj, E., Waring, R., Lyapustin, A., & Wang, Y. (2014). Satellite observed widespread decline in Mongolian grasslands largely due to overgrazing. *Glob Change Biol*, 418-428.
- IDEAM. (29 de Mayo de 2019). Obtenido de <http://www.ideam.gov.co/web/atencion-y-participacion-ciudadana/cambio-climatico>
- IDEAM. (2021). *Cubo de Datos imágenes de satélite de Colombia*. Obtenido de <http://cdcol.ideam.gov.co/>

IGAC. (2021). *Banco Nacional de Imagenes*. Obtenido de

<http://bni.igac.gov.co:81/home/srv/es/main.busqueda>

Johnson, D. (2016). A comprehensive assessment of the correlations between field crop yields and commonly used MODIS products. 65-81.

doi:<https://doi.org/10.1016/j.jag.2016.05.010>

Muñoz Aguayo, P. (2013). *Apuntes de Teledetección: Índices de Vegetación*.

NASA. (2017). *What Climate Means*. Obtenido de

https://www.nasa.gov/mission_pages/noaa-n/climate/climate_weather.html

NASA. (2020). *Moderate resolution imaging spectroradiometer*. Obtenido de

<https://modis.gsfc.nasa.gov/about/>

NASA. (2021). *Globla Climate Change*. Obtenido de <https://climate.nasa.gov/>

NASA. (2021). *Moderate Resolution Imaging Spectroradiometer (MODIS)*.

Obtenido de <https://modis.gsfc.nasa.gov/data/dataprod/mod13.php>

Rodríguez Jiménez, R., Benito Capa, A., & Portela Lozano, A. (2004).

Meteorología y Climatología.

Tsalyuk, M., Kelly, M., & Wayne, G. (2017). Improving the prediction of African savanna vegetation variables using. 15.

doi:<http://dx.doi.org/10.1016/j.isprsjprs.2017.07.012>

Wang, D., Morton, D., Masek, J., Wu, A., Nagol, J., Xiong, X., . . . Wolfe, R.

(2012). Impact of sensor degradation on the MODIS NDVI time series. *119*, 55-61. doi:<https://doi.org/10.1016/j.rse.2011.12.001>.

Ali, S., Henchiri, M., Sha, Z., Wilson, K., Yun, B., Yao, F., & Zhang, J. (2020). A time series of land cover maps of South Asia from 2001 to 2015 generated using AVHRR GIMMS NDVI3g data. *Environmental Science and Pollution Research*, *27*(16). <https://doi.org/10.1007/s11356-020-08433-9>

Bezerra, F. G. S., Aguiar, A. P. D., Alvalá, R. C. S., Giarolla, A., Bezerra, K. R. A., Lima, P. V. P. S., do Nascimento, F. R., & Arai, E. (2020). Analysis of areas undergoing desertification, using EVI2 multi-temporal data based on MODIS imagery as indicator. *Ecological Indicators*, *117*, 106579. <https://doi.org/10.1016/J.ECOLIND.2020.106579>

Cushman Ewan A Macdonald Erin L Landguth Yadvinder Malhi David W Macdonald, S. A., Cushman, S. A., Macdonald, E. A., Cushman, S. A., Macdonald, E. A., Malhi, Á. Y., Landguth, E. L., & Macdonald Á D W Macdonald, E. A. (2017). Multiple-scale prediction of forest loss risk across Borneo. *Landscape Ecol*, *32*, 1581–1598. <https://doi.org/10.1007/s10980-017-0520-0>

Edward, G., & Meirion Jenkins, G. (n.d.). *SERIES TEMPORALES, MODELO ARIMA METODOLOGÍA DE BOX-JENKINS*.

Garcia, A. S., De, V. M., Vilela, F. N., Rizzo, R., West, P., Gerber, J. S., Engstrom, P. M., & Ballester, M. V. R. (2019). *Assessing land use/cover dynamics and exploring drivers in the Amazon's arc of deforestation through a hierarchical, multi-scale and multi-temporal classification approach*.
<https://doi.org/10.1016/j.rsase.2019.05.002>

Ge, J., Meng, B., Liang, T., Feng, Q., Gao, J., Yang, S., Huang, X., & Xie, H. (2018). *Modeling alpine grassland cover based on MODIS data and support vector machine regression in the headwater region of the Huanghe River, China*.
<https://doi.org/10.1016/j.rse.2018.09.019>

Gemitzi, A. (2021). *Predicting land cover changes using a CA Markov model under different shared socioeconomic pathways in Greece*.
<https://doi.org/10.1080/15481603.2021.1885235>

Ibrahim, S., Balzter, H., Tansey, K., Mathieu, R., & Tsutsumida, N. (2019). Impact of soil reflectance variation correction on woody cover estimation in Kruger National Park using MODIS data. *Remote Sensing*, 11(8).
<https://doi.org/10.3390/rs11080985>

Ituen, I., & Hu, B. (2021). *Geo-Information An Automatic and Operational Method for Land Cover Change Detection Using Spatiotemporal Analysis of MODIS Data: A Northern Ontario (Canada) Case Study Automatic and Operational Method for Land Cover Change Detection Using Spatiotemporal Analysis of*.
<https://doi.org/10.3390/ijgi10050325>

Kato, A., Carlson, K. M., & Miura, T. (2021). Assessing the inter-annual variability of vegetation phenological events observed from satellite vegetation index time series in dryland sites. *Ecological Indicators*, *130*, 108042.
<https://doi.org/10.1016/J.ECOLIND.2021.108042>

Levers, C., Schneider, M., Prishchepov, A. v., Estel, S., & Kuemmerle, T. (2018). Spatial variation in determinants of agricultural land abandonment in Europe. *The Science of the Total Environment*, *644*, 95–111.
<https://doi.org/10.1016/J.SCITOTENV.2018.06.326>

Lin, X., Wen, J., Liu, Q., You, D., Wu, S., Hao, D., Xiao, Q., Zhang, Z., & Zhang, Z. (2020). Spatiotemporal variability of land surface Albedo over the Tibet Plateau from 2001 to 2019. *Remote Sensing*, *12*(7).
<https://doi.org/10.3390/RS12071188>

LP DAAC. (2015). Global 250 m SIN Grid V006. *NASA Land Data Products and Services*. <https://doi.org/10.5067/MODIS/MOD13Q1.006>

- Magnússon, R. Í., Limpens, J., Kleijn, D., van Huissteden, K., Maximov, T. C., Lobry, S., & Heijmans, M. M. P. D. (2021). Shrub decline and expansion of wetland vegetation revealed by very high resolution land cover change detection in the Siberian lowland tundra. *Science of the Total Environment*, 782, 146877. <https://doi.org/10.1016/j.scitotenv.2021.146877>
- Mardian, J., Berg, A., & Daneshfar, B. (2021). Evaluating the temporal accuracy of grassland to cropland change detection using multitemporal image analysis. *Remote Sensing of Environment*, 255. <https://doi.org/10.1016/j.rse.2021.112292>
- Petersen, K., Vakkalanka, S., & Kuzniarz, L. (2015). Guidelines for conducting systematic mapping studies in software engineering: An update. *Information and Software Technology*, 64. <https://doi.org/10.1016/j.infsof.2015.03.007>
- Qian, D., Cao, G., Du, Y., Li, Q., Guo, & X., Cao, G., Du, Y., Li, Q., & Guo, X. (2019). *Impacts of climate change and human factors on land cover change in inland mountain protected areas: a case study of the Qilian Mountain National Nature Reserve in China*. <https://doi.org/10.1007/s10661-019-7619-5>
- Solly, B., Jarju, A. M., Sonko, E., Yaffa, S., & Sawaneh, M. (2021). Detection of recent changes in Gambia vegetation cover using time series modis ndvi. *Http://Journals.Openedition.Org/Belgeo*, 1. <https://doi.org/10.4000/BELGEO.47995>

- Swain, S., Abeysundara, S., Hayhoe, K., & Stoner, A. M. K. (2017). Future changes in summer MODIS-based enhanced vegetation index for the South-Central United States. *Ecological Informatics*, 41, 64–73. <https://doi.org/10.1016/J.ECOINF.2017.07.007>
- Xiang, M., Yu, Q., & Wu, W. (2019). From multiple cropping index to multiple cropping frequency: Observing cropland use intensity at a finer scale. *Ecological Indicators*, 101. <https://doi.org/10.1016/j.ecolind.2019.01.081>
- Yu, M., & Gao, Q. (2020). Increasing summer rainfall and asymmetrical diurnal and seasonal warming enhanced vegetation greenness in temperate deciduous forests and grasslands of Northern China. *Remote Sensing*, 12(16). <https://doi.org/10.3390/RS12162569>
- Zhang, M., Abrahao, G., Cohn, A., Campolo, J., & Thompson, S. (2021). A MODIS-based scalable remote sensing method to estimate sowing and harvest dates of soybean crops in Mato Grosso, Brazil. *Heliyon*, 7(7). <https://doi.org/10.1016/J.HELIYON.2021.E07436>

Anexos

Anexo 1. Certificado Ponencia I Simposio Ciencia en las Regiones.



La Sociedad de Doctores e Investigadores de Colombia
Certifica que

*Camila Segura, Leonairo Fierro,
Julián Muñoz*

Participaron como ponentes con el trabajo titulado "Dinámicas y escenarios prospectivos de las coberturas naturales en subregiones del Macizo Colombiano a través del análisis espaciotemporal de series MODIS en el contexto del cambio climático" en el I Simposio Ciencia en las Regiones.

Evento científico realizado entre el 28 y 29 de julio de 2022

Se expide el presente certificado a los 11 días del mes de agosto de 2022.

En constancia firma:

SANDRA MILENA
CHINGATE LOPEZ

Firmado digitalmente por SANDRA
MILENA CHINGATE LOPEZ
Fecha: 2022.08.18 07:26:54 -05'00'

Sandra Milena Chingaté López
Presidenta y Representante Legal
Sociedad de Doctores e Investigadores de Colombia

