Laboratorio de Ecología Funcional

Departamento de Ecología, Genética y Evolución

Facultad de Ciencias Exactas y Naturales

Universidad de Buenos Aires

Evaluación de la sequía en los bosques nativos del norte de Misiones mediante técnicas de sensoramiento remoto

Tesis para optar por el título de Licenciada en Ciencias Biológicas

Autora

Rocío Martina de Lellis

Directora

Dra. Piedad María Cristiano

Diciembre 2024

AGRADECIMIENTOS

A mi familia, por festejar cada logro conmigo y acompañarme en los momentos difíciles.

A mi mamá y a mi papá, gracias por todo lo que hicieron por mí siempre, por dejarme amar la naturaleza libremente y fomentar mi curiosidad. Gracias por impulsarme a ser eso que quiero ser y por nunca dejarme bajar los brazos.

A Chiari, gracias por escucharme y aconsejarme con tanto cariño, y a Joaco, por siempre sacarme una sonrisa. Son mis cómplices y mi sostén de todos los días.

A mi abuela, por los abrazos y por estar presente a pesar de la distancia.

A Pie, por guiarme en cada paso de este proceso, y a Vir, por responder mis repetidas preguntas. Este trabajo fue todo un desafío y ustedes me ayudaron a poder transitarlo. Gracias por la paciencia y la dedicación para explicarme, por compartirme sus conocimientos y brindarme las herramientas. Aprendí mucho.

A todos los que forman parte del laboratorio de Ecología Funcional, por recibirme con cariño. Agradezco sus consejos y el apoyo en mi aprendizaje. A Juli, Valen y Fran, por la campaña compartida y los recuerdos.

A mis amigas de la facu, Emi, Loli, Aldi, Juli, Kar, Lu, Luni, Miru, Pau, Vicky, Yae, Cami y Cate, por andar este camino juntas y nunca soltarnos la mano. No hay palabras para describir lo mucho que significaron en este recorrido. No habría sido lo mismo sin ustedes.

A Juli, Facu, Juan y todos los amigos y amigas de exactas con quienes nos hicimos compañía en las largas horas de cursada, de estudio, viajes y siestas en el pastito.

A Cami y Dana, amigas de la vida, que estuvieron conmigo desde que elegí e inicié este camino, gracias por ser refugio en tantos momentos. A Anita, por tu incondicional compañía en la última etapa. A todas, gracias por bancar cada una de mis versiones y por sus palabras de aliento constantes.

A la FCEN, mi segunda casa todos estos años, por tantos momentos de felicidad y a los profes que forman parte de ella por enseñar con tanta pasión y calidez.

A los jurados de esta tesis, gracias por aceptar y tomarse el tiempo para leer este trabajo.

A la educación pública, sin la cual nada de esto habría sido posible, un derecho que debemos valorar, reivindicar y defender. Gracias por permitirme elegir la carrera más linda del mundo.

ÍNDICE

Resumen……4
Abstract……6
1. Introducción……8
1.1. Bosques y sequías……8
1.2. Sensores remotos y vegetación……11
1.3. Índices de vegetación……15
1.4. Variables e índices climáticos……16
1.5. Series temporales……17
2. Objetivos e hipótesis……20
3. Materiales y métodos……21
3.1. Área de estudio……21
3.2. Obtención de datos……24
3.2.1. Datos climáticos……25
3.2.2. Índices de vegetación……25
3.3. Procesamiento de datos……27
3.4. Análisis de datos……28
3.4.1. Caracterización temporal del clima en el área de estudio……28
3.4.2. Caracterización temporal de los índices de vegetación……29
3.4.3. Relación entre el índice de sequía con los índices de vegetación……30
4. Resultados……33
4.1. Caracterización temporal del clima en el área de estudio……33
4.2. Caracterización temporal de los índices de vegetación……39
4.3. Relación entre el índice de sequía con los índices de vegetación……48
5. Discusión……50
5.1. Caracterización temporal del clima en el área de estudio……50
5.2. Caracterización temporal de los índices de vegetación y relación con el índice de sequía……54
6. Conclusiones……60
7. Anexo……61
8. Referencias bibliográficas……73

RESUMEN

La sequía es un fenómeno que genera múltiples consecuencias en los ecosistemas, y que afecta procesos fundamentales de la vegetación como la fotosíntesis. En los últimos tiempos, los eventos de sequía han aumentado en frecuencia e intensidad debido al cambio climático. Sin embargo, los impactos de estos eventos han sido poco estudiados en regiones con abundante disponibilidad de agua, como los bosques subtropicales. El Parque Nacional Iguazú (PNI), un área protegida ubicada al norte de la provincia de Misiones, es uno de los pocos remanentes del Bosque Atlántico, caracterizado por su alta biodiversidad y capacidad de regulación del sistema climático. El objetivo de este trabajo fue analizar la relación entre la sequía y la vegetación de los bosques subtropicales húmedos del PNI. Para ello se utilizaron series temporales de 22 años (2001-2023) de los índices espectrales de vegetación EVI, NDWI, NMDI, NDII6, NDII7, VCI, TCI y VHI (asociados a distintas características de la vegetación como la productividad primaria, el contenido de agua, la humedad, la temperatura y la salud), y el Índice de Sequía de Palmer (PDSI). Se estudió la relación entre cada uno de los índices de vegetación y el PDSI mediante modelos autorregresivos (AR) y modelos de retardos distribuidos (DLM), considerando el retraso en la respuesta de la vegetación frente a los cambios en el índice de sequía. Se observó una relación lineal entre el PDSI y los índices NDWI, NMDI, NDII7, VCI y VHI, con distintos desfasajes temporales. La magnitud de dichas relaciones y la variabilidad de cada índice explicada por el PDSI fueron bajas. En cuanto al EVI y NDII6, no se obtuvo una relación significativa con el PDSI. Estos resultados sugieren que las sequías ocurridas en el PNI desde el 2001 no afectaron de forma significativa la vegetación del dosel del parque, manteniéndose la tasa fotosintética estable durante el período estudiado. Sin embargo, para una comprensión más detallada de la respuesta de los distintos estratos y/o tipos funcionales de plantas, sería útil complementar el estudio con análisis espaciales y mediciones de campo. Los resultados de este trabajo aportan a una mejor comprensión acerca de la resiliencia y funcionalidad de los bosques subtropicales de Misiones frente a condiciones climáticas de déficit hídrico, aportando información valiosa para futuros estudios.

Palabras clave: clima - índices espectrales de vegetación - PDSI - teledetección - modelos autorregresivos - modelos de retardos distribuidos - MODIS - TerraClimate - déficit hídrico - ENSO - cambio climático - productividad

ABSTRACT

Drought is a phenomenon that generates multiple consequences in ecosystems, affecting fundamental vegetation processes such as photosynthesis. Recently, due to climate change, drought events have increased in frequency and intensity. However, these impacts have been little studied in regions with abundant water availability, such as subtropical forests. Iguazú National Park (PNI), a protected area located in the northern province of Misiones, is one of the few remaining fragments of the Atlantic Forest, characterized by its high biodiversity and capacity for climate regulation. The aim of this study was to analyze the relationship between drought and vegetation in the humid subtropical forests of PNI. To achieve this, 22-year time series (2001-2023) of vegetation spectral indices EVI, NDWI, NMDI, NDII6, NDII7, VCI, TCI, and VHI (associated with vegetation characteristics such as primary productivity, water content, humidity, temperature, and health), and the Palmer Drought Severity Index (PDSI) were used. The relationship between each vegetation index and the PDSI was studied using autoregressive models (AR) and distributed lag models (DLM), considering the delayed response of vegetation to changes in the drought index. A linear relationship was observed between the PDSI and the indices NDWI, NMDI, NDII7, VCI, and VHI, with different temporal lags. The strength of these relationships and the variability explained by the PDSI for each index were low. Regarding EVI and NDII6, no significant relationship was found with the PDSI. These results suggest that droughts occurring in PNI since 2001 have not significantly affected the canopy vegetation of the park, with photosynthetic rate remaining stable during the study period. For a more detailed understanding of the response of different vegetation strata and/or functional types, it would be useful to complement the study with spatial analyses and field measurements. The findings of this study contribute to a better understanding of the resilience and functionality of the subtropical forests of Misiones in response to water deficit climatic conditions, providing valuable information for future studies.

Keywords: climate - spectral vegetation indices - PDSI - remote sensing - autoregressive models - distributed lag models - MODIS - TerraClimate - water deficit - ENSO - climate change - productivity

1. INTRODUCCIÓN

1.1. Bosques y sequías

Los bosques desempeñan un papel fundamental en la regulación del sistema climático a través de procesos como la fotosíntesis y la evapotranspiración (Balandier et al., 2022). A su vez estos procesos están influenciados por las condiciones climáticas, como las precipitaciones, la temperatura y la radiación solar (Díaz Villa et al., 2022b; Qin et al., 2022). Las variaciones en la precipitación pueden modificar la disponibilidad de agua y nutrientes en el suelo para las plantas, mientras que la temperatura puede afectar de forma directa procesos como la fotosíntesis y la respiración (Long et al., 2023). Además, la radiación solar, que actúa como una fuente de energía para la fotosíntesis, influye en la morfología, el crecimiento y el desarrollo de las plantas mediante la intensidad, duración y composición espectral de la luz (Long et al., 2023). Estos factores climáticos se ven modificados tanto por el cambio climático, caracterizado por el aumento de la frecuencia e intensidad de los eventos climáticos extremos, como por fenómenos globales naturales como El Niño - Oscilación del Sur (ENSO, por sus siglas en inglés), que afecta la distribución de las precipitaciones y los extremos de temperatura (Herera, 2023).

Los bosques subtropicales húmedos de Argentina contribuyen fuertemente a la regulación del sistema climático almacenando CO_2, ya que presentan una elevada actividad fotosintética durante todo el año, reduciendo así el efecto invernadero (Cristiano et al., 2014, 2020; Zhang et al., 2016). También contribuyen a la regulación del ciclo hidrológico, debido a que mantienen altos niveles de evapotranspiración desde el dosel, y generan y regulan las precipitaciones. De esta manera previenen y mitigan sequías e inundaciones y moderan temperaturas extremas (Cristiano et al., 2015; FVSA y WWF, 2017). Estos bosques forman parte del extremo sur del bioma del Bosque Atlántico, el cual se extiende a lo largo de la costa atlántica de Brasil, el sudeste de Paraguay y el noreste de Argentina (Campanello et al., 2021). Hasta hace dos siglos, el Bosque Atlántico era el segundo ecosistema boscoso más extenso de Sudamérica después del bosque amazónico, pero debido a los procesos de

colonización y explotación forestal durante las últimas décadas, se ha perdido alrededor del 93% de la superficie original (Campanello et al., 2021) (Figura 1). En la actualidad, la mayor cobertura continua de este bosque se encuentra en la provincia de Misiones, donde ocupa una superficie de 16.000 km^2 (aproximadamente el 58% de la cobertura original) (Campanello et al., 2021). En la provincia, los bosques mejor conservados se hallan principalmente en parques nacionales, provinciales y reservas privadas (Cristiano et al., 2020; Díaz Villa et al., 2022a, 2022b).

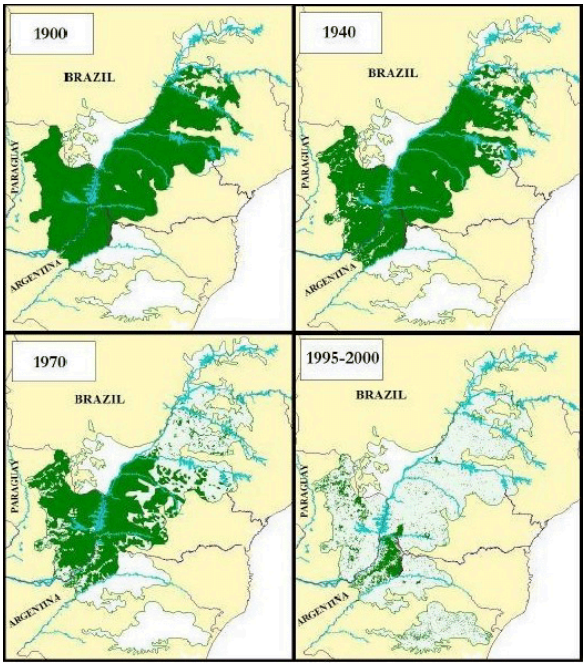

Figura 1: Área remanente del Bosque Atlántico (en verde) debido a la deforestación, desde el año 1900 hasta el año 2000. Adaptado de Laino Guanes et al. (2005).

Las sequías constituyen uno de los fenómenos climáticos que inciden en la dinámica de los bosques. Este fenómeno ocurre virtualmente en todas las zonas climáticas, tanto en regiones húmedas como secas y en cualquier época del año. Se percibe como uno de los desastres naturales más costosos y menos entendidos, dada la dificultad para definir su comienzo y fin, su lento desarrollo y las múltiples facetas que posee a nivel regional. (Rivera, 2014). Sin embargo, no existe una definición precisa y objetiva de la sequía, ya que su caracterización varía según la perspectiva y las variables consideradas. En términos

generales, se entiende como un período de tiempo en el que se produce un déficit de precipitación respecto a los valores promedio históricos, lo que genera una reducción en la disponibilidad de agua y afecta los recursos hídricos, los ecosistemas y los servicios que estos brindan (Wilhite & Glantz, 1985; McKee et al., 1993; Chang et al., 2018; Zulu et al., 2018; Zou et al., 2020). Usualmente se considera únicamente a la precipitación cuando se reconocen y analizan las condiciones de sequía, dado que es el factor principal que controla la formación y persistencia de condiciones de sequía. No obstante, otras variables como la temperatura, el viento, la humedad del aire, la evapotranspiración, la cobertura nubosa y una mayor insolación pueden reforzar la escasez de agua, agravando la severidad de las sequías (Rivera, 2014).

Las sequías e inundaciones en Argentina están relacionadas con el ENSO (IGN, s.f.2), un fenómeno natural que implica la fluctuación de las temperaturas superficiales oceánicas en la región central y oriental del Pacífico ecuatorial, asociada a cambios en la atmósfera (SMN, s.f.), influyendo en las condiciones climáticas de diversas partes del mundo (Yeh et al., 2018). El ENSO presenta dos fases opuestas: una de calentamiento del océano, conocida como "El Niño", que está asociada a precipitaciones muy abundantes e inundaciones en la región sudeste de América del Sur (sur de Brasil, nordeste de Argentina, Uruguay y sur de Paraguay); y una de enfriamiento del océano, denominada "La Niña", que provoca una disminución de las precipitaciones y sequías en la misma región (Berri, 2002; Codromaz de Rojas, 2000; Ferrelli, 2016; IGN, s.f.2). El monitoreo del fenómeno se puede realizar a través del índice ONI (del inglés, *Oceanic Niño Index*), que se calcula a partir de la media móvil de tres meses de las anomalías de la temperatura superficial del mar para la región Niño 3.4 que comprende las latitudes 5°N-5°S y longitudes 120°-170°O (Meis, 2019) (Figura 2). Desde la década de 1950, el fenómeno de La Niña se ha registrado en Argentina en ocho ocasiones, siendo el evento ocurrido entre 2020 y 2023 responsable de una de las sequías más intensas de los últimos 60 años (NOAA, s.f.; Leiva, 2023; Rosana & Rafaelli, 2023; Risaro, 2024). Estos impactos ya habían sido anticipados por los modelos globales de cambio climático, que pronosticaron períodos de sequía más prolongados para los bosques del noreste de Argentina, un incremento de las precipitaciones concentradas en menos días por año, cambios en su

estacionalidad, un aumento en la frecuencia de olas de calor y temperaturas extremas (SAyDS, 2014; Barros et al., 2015; Camilloni, 2018; Cristiano et al., 2020). La prolongada escasez de lluvias, junto con temperaturas más elevadas que lo habitual, genera una disminución en la disponibilidad de agua y, como resultado, un déficit hídrico en las plantas (Millar & Stephenson, 2015). En los bosques, estas alteraciones en la humedad y temperatura afectan negativamente la salud de los árboles (Xulu et al., 2018) así como a la capacidad fotosintética de las hojas (Zhang et al., 2016). Además, han contribuido, en parte, a la propagación de plagas y a la ocurrencia de incendios forestales (Caccamo et al., 2011; Xulu et al., 2018).

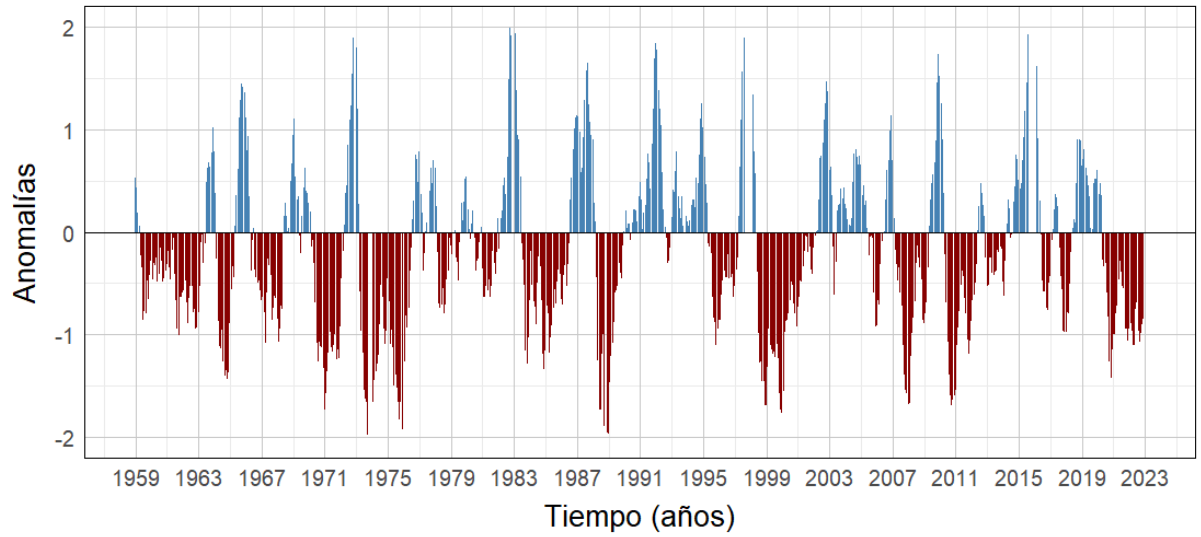

Figura 2: Gráfico de anomalías mensuales estandarizadas de El Niño-Oscilación del Sur (ENSO) desde enero de 1959 hasta diciembre del 2023, mostrando las fases cálidas asociadas a El Niño (azul) y las fases frías asociadas a La Niña (rojo) de las temperaturas anómalas de la superficie del mar en el Océano Pacífico Tropical (índice Niño 3.4). Elaboración propia a partir de datos tomados de la Administración Nacional Oceánica y Atmosférica (NOAA, por sus siglas en inglés).

1.2. Sensores remotos y vegetación

Desde finales del siglo XX, la información obtenida mediante sensoramiento remoto se ha convertido en una herramienta valiosa para estudiar las dinámicas espaciales y temporales

de la vegetación (Iverson et al., 1989; Lechner et al., 2020). Estos datos pueden ser obtenidos de forma remota a partir de sensores a bordo de satélites (Yang et al., 2013). Gracias a su capacidad de observación a gran escala, las tecnologías satelitales pueden adquirir rápidamente información espectral de áreas regionales e incluso globales, especialmente en regiones de difícil acceso (Paruelo, 2008; Li et al., 2020). Los sensores pasivos en particular, pueden proporcionar información sobre el porcentaje de energía del sol que es reflejada por diferentes tipos de cobertura terrestre en distintas longitudes de onda del espectro electromagnético (Manning, 2012).

Cada tipo de cobertura presenta un patrón de reflectancia particular, conocido como firma espectral (Govender et al., 2007), que suele servir de base para caracterizar funcionalmente a los ecosistemas (Paruelo, 2008). En el caso de la vegetación, su capacidad de absorber y reflejar la luz de distintas longitudes de onda es consecuencia de la estructura celular de la hoja (Roman & Ursu, 2016), su forma, su estado fenológico y el contenido de humedad, entre otros factores (Chuvieco, 1991). El comportamiento espectral típico de la vegetación sana muestra una reducida reflectividad en las bandas del espectro visible, con un máximo relativo en la porción verde (Alonso et al., 1999). Por el contrario, en el infrarrojo cercano (NIR, del inglés *near infrared*) presenta una elevada reflectividad, que decrece paulatinamente hacia el infrarrojo medio (SWIR, del inglés *short-wave infrared*) (Chuvieco, 1991) (Figura 3).

Este comportamiento espectral característico de la vegetación está principalmente relacionado con los pigmentos fotosintéticos y el contenido de agua en las hojas (Hernández & Montaner, 2009). La baja reflectividad en el espectro visible se debe en gran medida al efecto de absorción de los pigmentos, especialmente de la clorofila (Peñuelas & Filella, 1998). Estos pigmentos absorben en mayor proporción en las longitudes de onda azul y roja del espectro (centradas en 450 nm y 670 nm respectivamente), lo que resulta en una menor reflectancia en estas zonas (Hoffer & Johannsen, 1969). En contraste, en la porción verde del espectro visible (centrada en 550 nm) la absorción de luz es menos intensa, por lo que se observa un pico relativo de reflectividad (Knipling, 1970; Zarco Tejada et al., 2000). En el infrarrojo cercano, la elevada reflectividad se debe principalmente a la capa esponjosa del

mesófilo, cuyas cavidades de aire internas dispersan y difunden la mayor parte de la radiación incidente (Rock et al., 1986). A partir de los 1,4 µm, el efecto absorbente del agua se vuelve significativo, reduciendo drásticamente la reflectividad de la vegetación sana en el infrarrojo medio, especialmente notable en las longitudes de onda alrededor de 1,45, 1,92 y 2,7 µm (Chuvieco, 1991) (Figura 3).

La ocurrencia de cambios significativos en los factores ambientales, como sequías o temperaturas extremas, puede inducir el estrés en las plantas, desencadenando cambios bioquímicos y morfológicos (Behmann et al., 2014). El déficit hídrico prolongado, en particular, provoca inicialmente el cierre de los estomas para regular la pérdida de agua, lo que reduce la concentración de CO_2 dentro de la célula, disminuyendo a su vez la tasa fotosintética (Tapia, 2020). Además, si se prolonga el cierre estomático se deteriora la estructura celular y se induce a la senescencia (Neuman, 2008). Dependiendo de la intensidad de estos procesos se modifica la energía electromagnética absorbida por la célula, y por consiguiente se altera la firma espectral de la vegetación (Katsoulas et al., 2016).

En las hojas bajo estrés se ha observado una disminución en el contenido total de clorofila (Zarco Tejada et al., 2000; Behmann et al., 2014; Maimaitiyiming et al., 2017), lo que resulta en una menor absorción en las bandas azul y roja del espectro visible, eliminando el máximo relativo antes situado en el verde (Chuvieco, 1991). En tanto que en el infrarrojo cercano se produce una reducción de la reflectividad debido al deterioro de la estructura celular y a la pérdida de turgencia en las hojas (Gausman, 1974). En consecuencia, en condiciones de estrés, la curva espectral tiende a aplanarse, minimizando las diferencias de reflectancia entre las distintas longitudes de onda (Chuvieco, 1991) (Figura 3).

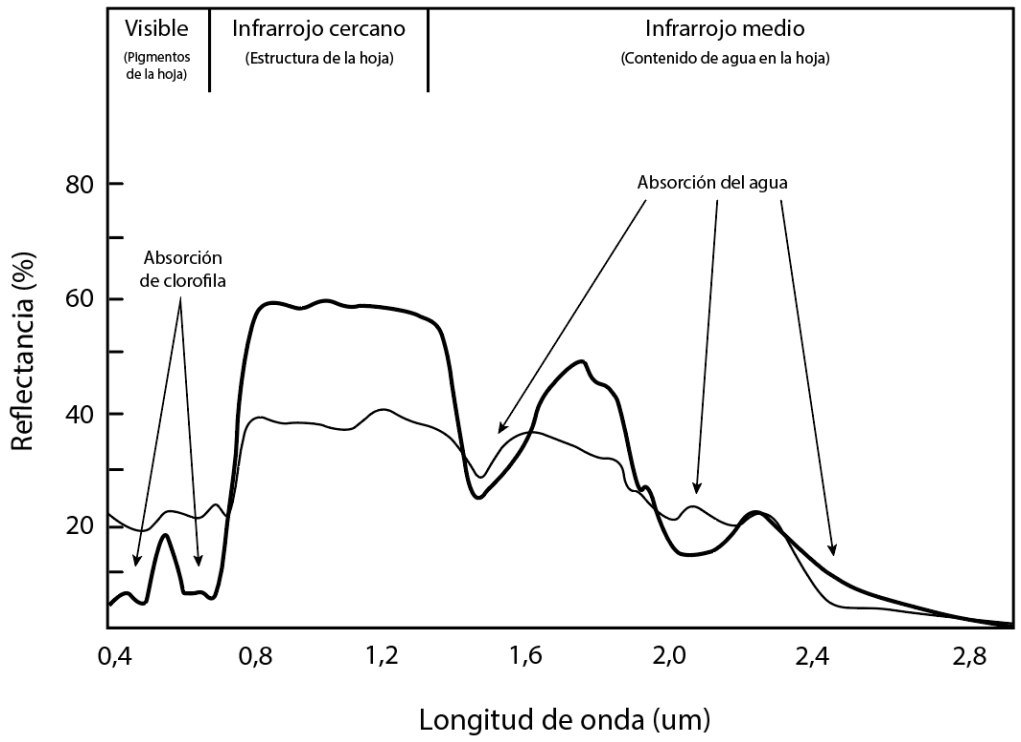

Figura 3: Firma espectral típica de la vegetación. La línea gruesa corresponde a una vegetación sana y la línea delgada a una vegetación bajo estrés. Adaptado de Chuvieco (1991).

La mayoría de los enfoques de la teledetección utilizados en el monitoreo del estado de la vegetación se basa en la marcada diferencia en las propiedades de reflectancia entre las longitudes de onda a lo largo del espectro electromagnético (Pinter et al., 2003). El sensor MODIS (del inglés *Moderate Resolution Imaging Spectroradiometer*) es un sensor pasivo a bordo de los satélites Terra y Aqua, que capta la radiación reflejada y emitida por la superficie terrestre en 36 bandas espectrales, incluyendo el espectro visible, el NIR y el SWIR (Justice et al. 2002; NASA, s.f.) (Figura 4). Es una herramienta efectiva para monitorear cambios a gran escala, ya que debido a su trayectoria ofrece datos de casi toda la superficie del planeta cada 1 a 2 días, lo que facilita un seguimiento frecuente y continuo (NASA, s.f.).

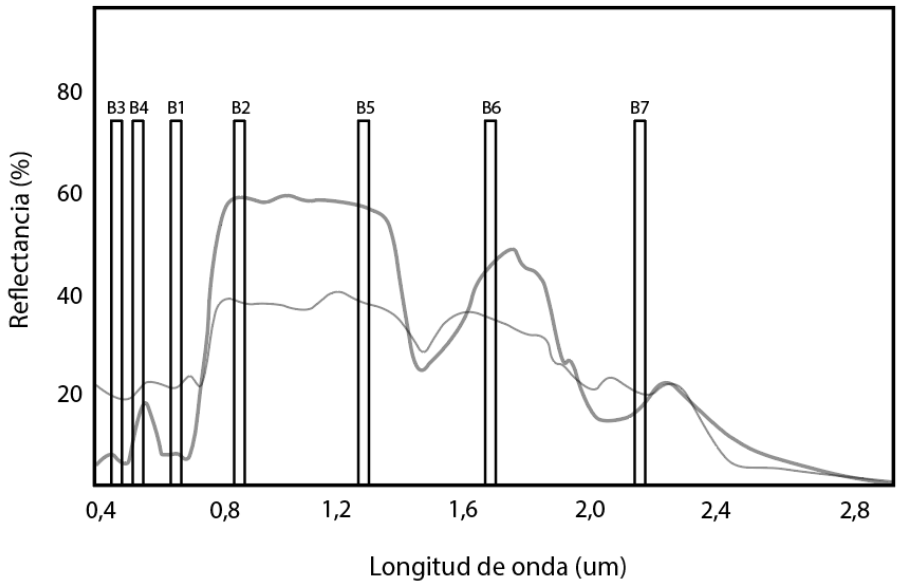

Figura 4: Posiciones de 7 (de las 36) bandas del sensor MODIS en la región óptica del espectro electromagnético. Elaboración propia con datos tomados de MODIS Terra (NASA, s.f.).

1.3. Índices de vegetación

Los datos de reflectancia registrados por los sensores remotos se pueden utilizar para calcular índices espectrales, que son expresiones matemáticas que combinan diferentes bandas espectrales. Los índices espectrales de vegetación en particular, permiten evaluar distintos aspectos de la vegetación (DeJonge et al., 2016; Maimaitiyiming et al., 2017).

El NDVI (del inglés, *Normalized Difference Vegetation Index*) es uno de los índices de vegetación más utilizados, ya que está estrechamente relacionado con la cantidad de radiación fotosintéticamente activa interceptada por la vegetación, así como con la cantidad de biomasa verde y el contenido de clorofila en las hojas (Ichii et al., 2002; Cristiano et al., 2014). El EVI (*Enhanced Vegetation Index*) es un índice similar, pero que funciona mejor en zonas con alto índice de área foliar y alta productividad, como los bosques húmedos (Huete et al., 2002). Ambos índices utilizan bandas del espectro visible y del NIR, y toman valores más altos cuando la vegetación es más saludable y densa (Liu et al., 2023) (Anexo 1).

Además, existen otros índices de vegetación utilizados para detectar y monitorear cambios en el contenido de agua en la vegetación, como el NDWI (*Normalized Difference*

Water Index) (Gao, 1996), el NMDI (*Normalized Multi-band Drought Index*) (Wang & Qu, 2007), el NDII6 (*Normalized Difference Infrared Index-band 6*) y el NDII7 (*Normalized Difference Infrared Index-band 7*) (Hunt & Rock, 1989). Estos son índices similares entre sí, ya que los valores positivos se correlacionan con una vegetación turgente, pero utilizan distintas bandas del espectro electromagnético donde es marcado el efecto de la absorción del agua (Hunt & Rock, 1989; Gao, 1996; Wang & Qu, 2007) (Anexo 1).

Para el monitoreo de la sequía en la vegetación, se han desarrollado índices de vegetación específicos como el VCI (*Vegetation Condition Index*), el TCI (*Temperature Condition Index*) y el VHI (*Vegetation Health Index*) (Zou et al., 2020). Estos índices son capaces de reflejar indirectamente las condiciones de sequía meteorológica al considerar las condiciones de humedad de la vegetación (VCI), de temperatura de la superficie (TCI) y de la salud de la vegetación (VHI) (Kogan, 2001). Valores más altos de estos índices indican condiciones óptimas para la vegetación, mientras que valores cercanos a cero señalan estrés (Chang et al., 2018) (Anexo 1).

1.4. Variables e índices climáticos

Las precipitaciones son la principal fuente de agua para la mayoría de los ecosistemas del mundo, siendo esenciales para mantener su funcionalidad (Wang et al., 2017). Se prevé que las alteraciones en los patrones de circulación atmosférica global y en los procesos hidrológicos modifiquen la precipitación media anual y aumenten la variabilidad interanual e intraanual (Knapp et al., 2008). De esta forma, una disminución en los eventos de precipitación, aunque sean más intensos, puede aumentar la severidad de las sequías estacionales (Knapp et al., 2008). En las regiones subtropicales húmedas, muchos bosques han experimentado sequías en las últimas décadas como consecuencia del calentamiento global (Fu, 2015). Sin embargo, existen pocos estudios que analicen estos impactos en dichas regiones, principalmente debido a la noción de que estas zonas presentan alta humedad y una elevada precipitación media anual (Chang et al., 2018).

El déficit de presión de vapor (VPD, por sus siglas en inglés *vapor pressure déficit*) es una variable climática muy utilizada para evaluar las condiciones de humedad atmosférica, ya que se calcula como la diferencia entre la presión de vapor de saturación y la presión de vapor real del aire (Lambers et al., 2008). Valores más altos de VPD implican un mayor déficit hídrico atmosférico (Massmann et al., 2019), y están asociados a un aumento lineal en la tasa de transpiración de las plantas, hasta alcanzar un punto de saturación. A partir de este punto, la transpiración puede disminuir debido al cierre estomático para evitar la deshidratación y el daño fisiológico (Lambers et al., 2008). Esta reducción de la conductancia estomática frente a altos valores de VPD puede disminuir la tasa fotosintética y, en consecuencia, la productividad (López et al., 2021).

Una de las formas más comunes de estudiar el impacto de las sequías en la vegetación es relacionar las variaciones de los índices espectrales de vegetación con índices de sequía (Ji & Peters, 2003; Jain et al., 2010; Li et al., 2018; Bushra et al., 2019; Xu et al., 2023). Los índices de sequía son criterios numéricos que caracterizan la intensidad, escala y duración de la sequía (Xulu et al., 2018). Uno de ellos es el PDSI (del inglés, *Palmer Drought Severity Index*) (Palmer, 1965), utilizado para cuantificar y comparar la sequía en diferentes regiones del mundo (Jacobi et al., 2013). El PDSI está basado en el concepto de oferta y demanda de la ecuación de balance hídrico (Zhai et al,. 2010), calculada a partir de datos de escorrentía, déficit hídrico, evapotranspiración, humedad de suelo y de nieve (Abatzoglou et al., 2018). Valores negativos del PDSI indican períodos secos, valores positivos señalan períodos húmedos, y valores cercanos a cero sugieren condiciones cercanas al promedio (Mika et al., 2005).

1.5. Series temporales

El análisis estadístico de series temporales puede utilizarse para comprender la dinámica de la interacción entre un conjunto de variables (Ewing et al., 2007). Diversos estudios mostraron que las respuestas de la vegetación al clima presentan un cierto retraso temporal que a su vez es diferente entre los distintos tipos de ecosistemas (Wu et al. 2015).

La respuesta de la vegetación puede retrasarse con respecto a cambios en los factores climáticos, ya que estos pueden tener efectos crónicos y acumulativos en un período de tiempo (Wen et al., 2019). Estos efectos acumulativos se refieren al impacto prolongado de condiciones climáticas previas, que influyen en los procesos de la vegetación, como el crecimiento y la fotosíntesis (Díaz Villa et al., 2022b). En bosques subtropicales particularmente, se ha observado un retraso temporal en la respuesta de hasta seis meses (Qin et al., 2022). Por lo tanto, es importante incorporar esta complejidad en el análisis para predecir con mayor precisión cómo la vegetación responderá a futuras condiciones climáticas (Zhan et al., 2022). En este contexto, los métodos de análisis de series temporales, como por ejemplo los modelos autorregresivos (Zivot & Wang, 2006), son útiles para comprender los patrones temporales de los índices de vegetación, donde el valor que toma el índice depende tanto de sus valores anteriores como de alguna perturbación externa, como son los cambios en las variables climáticas (Bruzzone & Easdale, 2021).

El análisis de series temporales requiere diferenciar entre series estacionarias y no estacionarias, ya que esto determina el tipo de modelo aplicable. Una serie temporal estacionaria es aquella cuyas propiedades estadísticas (media y varianza) permanecen constantes a lo largo del tiempo (Shumway & Stoffer, 2005). Por ejemplo, una serie de ruido blanco es estacionaria ya que es totalmente aleatoria, y siempre mantiene un comportamiento similar, independientemente del momento en que se la observe (Hyndman 2018). En cambio, las series temporales que presentan tendencias o estacionalidad no son estacionarias, ya que la tendencia y la estacionalidad afectarán el valor de la serie en distintos momentos (Shumway & Stoffer, 2005). En general, la series temporales de los índices de vegetación muestran un fuerte componente estacional asociado a los ciclos anuales de crecimiento (Xulu et al., 2018). Sin embargo, estos ciclos no siempre tienen una duración fija, lo que puede llevar a que estas series sean estacionarias (Hyndman 2018). Para aislar patrones de la serie que dependen del tiempo, como la tendencia y la estacionalidad, y facilitar la detección de patrones subyacentes en la serie temporal (por ejemplo la respuesta a un evento climático) se puede aplicar la diferenciación de los datos (Zivot & Wang, 2006). Esta técnica consiste en calcular la diferencia entre observaciones separadas por un cierto intervalo temporal. En

particular, la diferenciación de primer orden (entre observaciones consecutivas) elimina la tendencia, mientras que la diferenciación estacional (por ejemplo, entre el valor actual y el de doce meses atrás) permite remover la estacionalidad (Hyndman & Athanasopoulos, 2018a).

La sequía es considerada uno de los principales factores que impulsan la pérdida de productividad de los ecosistemas así como la mortalidad de la vegetación, tanto en el presente como en el futuro (Zheng et al., 2015). Es por eso que, el monitoreo y análisis de estos eventos en los bosques subtropicales misioneros es fundamental para comprender su incidencia en la vegetación. Hasta el momento no se han evaluado índices de sequía en este ecosistema, por lo que este trabajo constituye el primer acercamiento.

2. OBJETIVOS E HIPÓTESIS

El **objetivo** general de este trabajo fue estudiar la relación entre la sequía y la vegetación de los bosques nativos del norte de Misiones. Para ello se analizó la relación entre los índices espectrales verdes (EVI), de agua (NDWI, NMDI, NDII6, NDII7) y de sequía (VCI, TCI, VHI), con el Índice de Sequía de Palmer (PDSI).

Con base en los antecedentes y la información previa del área de estudio, se planteó la **hipótesis** de que los índices espectrales de vegetación son sensibles a los cambios en las condiciones hídricas de la vegetación en el PNI (Parque Nacional Iguazú), y que por lo tanto existe una correlación significativa entre ellos y el PDSI en los bosques nativos del norte de Misiones.

Las preguntas que guiaron este trabajo fueron:

1. ¿El PDSI detecta períodos de sequía en los bosques subtropicales húmedos del Parque Nacional Iguazú?
2. ¿Los índices espectrales de vegetación responden a los periodos de sequía detectados por el PDSI y las variables meteorológicas?
3. ¿Cómo es la forma y magnitud de la relación entre los índices de vegetación y el PDSI? ¿Existe un retardo temporal, de cuánto?

Se espera que en el lapso de tiempo estudiado:

1. Las variables climáticas muestren desviaciones de su patrón de variación normal, asociados a condiciones climáticas de sequía.
2. El PDSI sea capaz de detectar períodos de sequía.
3. Los índices de vegetación presenten distorsiones en sus patrones de variación normal, mostrando disminuciones asociadas a condiciones de estrés hídrico.
4. La relación entre los índices de vegetación y el PDSI sea lineal y esté caracterizada por un retraso temporal.

3. MATERIALES Y MÉTODOS

3.1. Área de estudio

El estudio se llevó a cabo en los bosques subtropicales húmedos del Parque Nacional Iguazú (PNI; -25.68 S, -54.45 W), ubicado al norte de la provincia de Misiones (Figura 5). Estos bosques son parte del Bosque Atlántico, que se extiende a lo largo de la costa atlántica de Brasil, el sudeste de Paraguay y el noreste de Argentina (FVSA y WWF, 2017). En la actualidad, solo quedan pequeños fragmentos en Brasil y Paraguay, mientras que en la provincia de Misiones se encuentra la mayor cobertura continua (Galindo-Leal & Gusmão-Câmara, 2003).

El Parque Nacional Iguazú fue creado en 1934 y declarado patrimonio natural de la humanidad por la UNESCO en 1984. Abarca una superficie de 67.620 ha y es considerado el bosque nativo mejor conservado de la provincia de Misiones (Díaz Villa et al., 2020, 2022a; Cristiano et al., 2020). Los bosques de Misiones tienen en general tres estratos arbóreos y numerosas lianas (con predominancia de Bignoniaceae, Apocynaceae, y Fabaceae), epífitas (Orquidaceae, Bromeliaceae) y hemiepífitas (*Ficus* spp., *Phylodendron* sp.), con un sotobosque dominado por helechos, por especies de Rubiaceae, Piperaceae, y por bambúceas herbáceas (*Olyra* spp.) y bambúceas leñosas de pequeño porte (*Chusquea ramosissima, Chusquea tenella, Merostachys claussenii*), estas últimas muy abundantes principalmente en ambientes disturbados (Campanello et al., 2021).

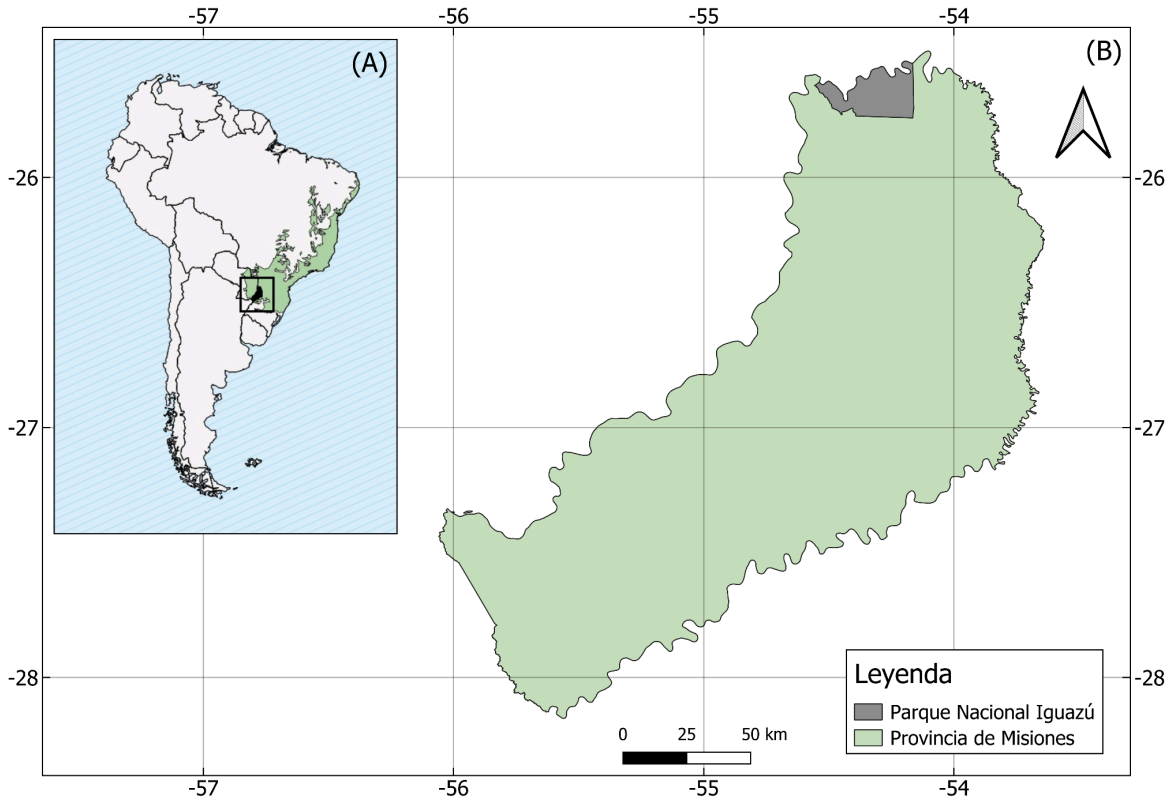

Figura 5: (A) Ubicación y cobertura original del Bosque Atlántico. (B) Ubicación del Parque Nacional Iguazú en la provincia de Misiones, Argentina. Elaboración propia con datos tomados del Ministerio de Cambio Climático de Misiones (MCCM, Figura A) y del Instituto Geográfico Nacional (IGN, Figura B) (MCCM, s.f.; IGN, s.f.1).

La precipitación media anual varía entre 1800 y 2000 mm, con leves diferencias mensuales (Campanello et al., 2021; Cristiano et al., 2020; Díaz Villa et al., 2022a). Aunque no existe una estación seca definida, pueden producirse algunas anomalías climáticas, como una disminución de las precipitaciones durante algunas semanas consecutivas, que desencadenan efectos de sequía a corto plazo. La temperatura media anual es de 21° C, con medias mensuales de 25° C en enero y 15° C en julio, que representan los meses más cálidos y fríos del año, respectivamente (Díaz Villa et al., 2020, 2022a, 2022b; Cristiano et al., 2020) (Figura 6). El número de días con temperaturas inferiores a 0° C oscila entre 0 y 9 en invierno, por lo que rara vez se producen heladas, manteniéndose temperaturas favorables para el crecimiento durante la mayor parte del año. La temperatura del aire por debajo de 0° C se da sobre todo en depresiones topográficas donde pueden producirse inversiones de aire

(Díaz Villa et al., 2020). La humedad relativa del aire es alta durante todo el año, con valores medios mensuales que oscilan entre 73 y 85%. El balance hídrico es positivo durante todos los meses del año (Figura 7). Los suelos, derivados de rocas basálticas, contienen altas concentraciones de hierro, aluminio y sílice, e incluyen ultisoles, alfisoles, molisoles e inceptisoles (Díaz Villa et al., 2020, 2022a, 2022b., Cristiano et al., 2020).

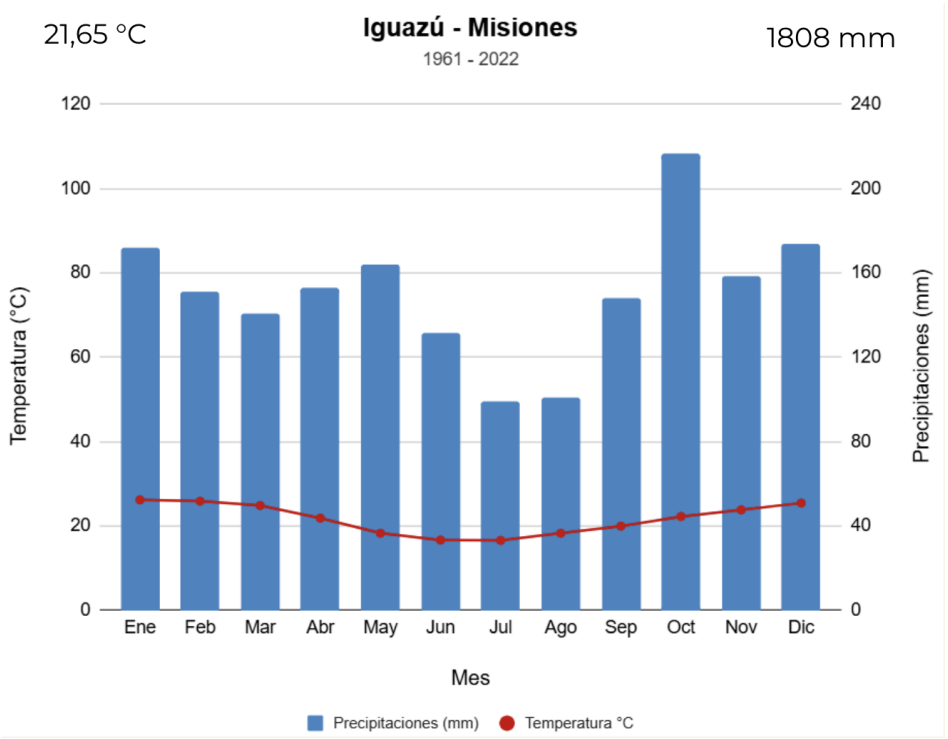

Figura 6: Climograma de Iguazú, Misiones, correspondiente al período 1961-2022. Se muestran las precipitaciones medias mensuales y las temperaturas medias mensuales. Elaboración propia con datos tomados del Servicio Meteorológico Nacional (SMN).

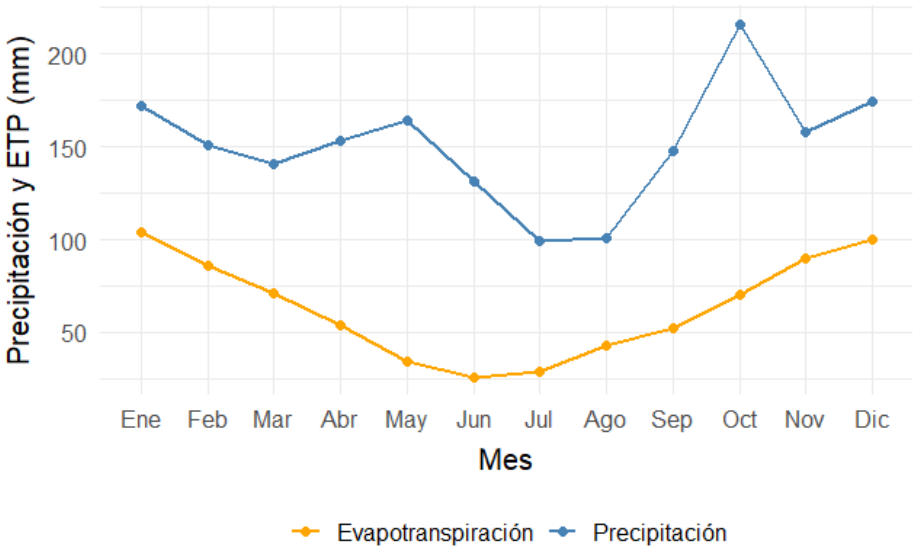

Figura 7: Variación mensual de la precipitación y la evapotranspiración potencial (ETP) en Iguazú, Misiones, para el período de 1961 a 2023. Elaboración propia con datos tomados del Servicio Meteorológico Nacional (SMN).

3.2. Obtención de datos

La adquisición de los datos satelitales se realizó a través de la plataforma Google Earth Engine, que permite el acceso libre y el análisis de información geoespacial de múltiples satélites y sensores (Gorelick et al. 2017). Mediante esta plataforma, se accedió a diversas colecciones de imágenes satelitales del sensor MODIS (MOD13Q1 V6.1, MOD09A1 V6.1 y MOD11A2 V6.1), de las cuales se obtuvieron los índices de vegetación, y al dataset TerraClimate, del cual se obtuvieron las variables climáticas y el índice de sequía. Debido a la diferencia en la escala espacial entre las colecciones de imágenes, las mismas fueron recortadas por el área de estudio y se realizó un promedio de todos los píxeles que se encontrasen dentro del Parque Nacional Iguazú.

3.2.1. Datos climáticos

Para la base de datos climáticos, se utilizó el dataset TerraClimate desde el año 1959 hasta el 2023. TerraClimate es un conjunto de datos de clima y de balance hídrico mensual para las superficies terrestres globales (Abatzoglou et al., 2018). El PDSI (*Palmer Drought Severity Index*) (Palmer 1965) y variables climáticas como la precipitación acumulada y el déficit de presión de vapor se obtuvieron de TerraClimate, con una resolución temporal de 1 mes y espacial de 4,6 kilómetros. También se utilizó información diaria sobre precipitaciones suministrada por el Servicio Meteorológico Nacional (SMN) de la estación meteorológica Puerto Iguazú-Aero (NH-0353). Los datos de precipitación del SMN fueron utilizados para validar los datos de precipitación de TerraClimate mediante un gráfico de correlación. La relación lineal entre ambos conjuntos de datos dio un coeficiente de determinación (R^2) de 0,899, lo que indica una correlación significativa entre los datos y, por lo tanto, respalda la confiabilidad del modelo de TerraClimate (Anexo 2).

3.2.2. Índices de vegetación

Para los índices de vegetación, se utilizaron productos MODIS desde el año 2001 hasta el 2023. El índice verde EVI (*Enhanced Vegetation Index*) se obtuvo del producto MOD13Q1, que proporciona una estimación directa de este índice con una resolución temporal de 16 días y espacial de 250 metros (Didan, 2021) (Tabla 1). Además, se calcularon los índices de sequía, como el VCI (*Vegetation Condition Index*), el TCI (*Temperature Condition Index*) y el VHI (*Vegetation Health Index*), y los índices de agua, como el NDWI (*Normalized Difference Water Index*), el NDMI (*Normalized Multiband Drought Index*), el NDII6 (*Normalized Difference Infrared Index-band 6*) y el NDII7 (*Normalized Difference Infrared Index-band 7*). Para calcular estos índices se utilizaron bandas de reflectancia, obtenidas del producto MOD09A1, con una resolución temporal de 8 días y espacial de 500 metros (Vermote, 2021), y datos de temperatura de la superficie terrestre, obtenidos del producto MOD11A2, con una resolución temporal de 8 días y espacial de 1 kilómetro (Wan et al., 2021) (Tabla 1). También se obtuvieron estimaciones directas del NDVI (*Normalized*

Difference Vegetation Index) a partir del producto MOD13Q1, utilizadas exclusivamente para el cálculo del VCI. Para el monitoreo de la biomasa se utilizará el EVI, ya que resulta más eficaz en áreas con alta densidad de vegetación.

Tabla 1: Índices de vegetación utilizados, con sus respectivas fórmulas y referencias bibliográficas. Para su cálculo se utilizan las bandas de reflectancia (ρ) o térmicas del producto MODIS. Los subíndices indican la banda MODIS: 1 = 620-670 nm, 2 = 841-876 nm, 3 = 459-479 nm, 5 = 1230-1250 nm, 6 = 1628-1652 nm, y 7 = 2105–2155 nm. LST corresponde al producto de temperatura de la superficie terrestre de MODIS.

Índice de vegetación	Fórmula	Referencias
NDVI (Normalized Difference Vegetation Index)	$\rho_2 - \rho_1/\rho_2 + \rho_1$	Rouse et al. (1974)
EVI (Enhanced Vegetation Index)	$2,5 \times (\rho_2 - \rho_1)/(\rho_2 + 6 \times \rho_1 - 7,5 \times \rho_3 + 1)$	Huete et al. (2002)
VCI (Vegetation Condition Index)	$100(NDVI - NDVI_{min})/(NDVI_{max} - NDVI_{min})$	Kogan (1994)
TCI (Temperature Condition Index)	$100(LST_{max} - LST)/(LST_{max} - LST_{min})$	Kogan (1994, 1997)
VHI (Vegetation Health Index)	$0,5 \times VCI + 0,5 \times TCI$	Kogan (1994, 1997)
NMDI (Normalized Multiband Drought Index)	$(\rho_2 - (\rho_6 - \rho_7))/(\rho_2 + (\rho_6 - \rho_7))$	Wang & Qu (2007), Wang et al. (2008)
NDWI (Normalized Difference Water Index)	$(\rho_2 - \rho_5)/(\rho_2 + \rho_5)$	Gao (1996)
NDII6 (Normalized Difference Infrared Index-band 6)	$(\rho_2 - \rho_6)/(\rho_2 + \rho_6)$	Caccamo et al. (2011)
NDII7 (Normalized Difference Infrared Index-band 7)	$(\rho_2 - \rho_7)/(\rho_2 + \rho_7)$	Caccamo et al. (2011)

Las colecciones de imágenes MODIS fueron filtradas para extraer únicamente los píxeles de buena calidad y minimizar el efecto de la presencia de vapor de agua, aerosoles, nubes, sombras, y otros factores que puedan afectar el valor de reflectancia y, en

consecuencia, el valor del índice de vegetación en el área de estudio. Para ello los productos MODIS incluyen una capa de evaluación de calidad llamada QA (por sus siglas en inglés, *Quality Assessment*). Esta capa contiene información codificada en bits a nivel del píxel, relacionada con diversos aspectos de la calidad de los datos. En el producto MOD13Q1, la capa DetailedQA Bitmask está codificada en 16 bits. Para el filtrado, se utilizaron los bits 0 al 1, que indican si el índice de vegetación se ha producido con buena calidad o presenta incertidumbre; los bits 2 al 5 que reflejan la calidad general del píxel; el bit 8, que señala si se aplicaron o no correcciones atmosféricas por la presencia de nubes adyacentes; y los bits 10 y 15, que indican la presencia de nubes mixtas y sombras, respectivamente. En el caso del producto MOD09A1, la capa QA Bitmask contiene información codificada en 32 bits por píxel. Para el filtrado, se utilizaron los bits 6 al 9, 18 al 21, 22 al 25 y 26 al 29, que corresponden a calidad de los datos de reflectancia de la banda 2, banda 5, banda 6 y banda 7, respectivamente.

3.3. Procesamiento de datos

El procesamiento de datos se realizó utilizando el software de distribución libre R (R CoreTeam, 2023) en el programa RStudio (RStudio Team, 2023). Los datos obtenidos fueron reescalados a una frecuencia mensual, calculando el promedio de los valores correspondientes a cada mes, excepto en el caso de las precipitaciones, para las cuales se obtuvo el valor acumulado mensual. Para suavizar la variabilidad en las series temporales se aplicó una media móvil desplazada hacia la derecha, utilizando una ventana temporal de tres meses (es decir, el valor de cada mes corresponde al promedio de ese mes y de los dos meses anteriores).

Se graficó la función de autocorrelación (ACF, por sus siglas en inglés) y de autocorrelación parcial (PACF, por sus siglas en inglés) para todas las series temporales (Anexo 3 y 4). Los gráficos ACF muestran la correlación entre los valores de una serie temporal y sus retardos a diferentes intervalos de tiempo. Los gráficos PACF muestran la correlación entre los valores de una serie temporal y sus retardos a diferentes intervalos de

tiempo, pero eliminando el efecto de los retardos intermedios. A las series temporales que mostraron un patrón estacional marcado en los gráficos ACF (índices de vegetación y VPD), se les aplicó una diferenciación estacional con el objetivo de reducir este efecto y poder detectar gráficamente y de forma exploratoria la presencia de patrones subyacentes a la estacionalidad. La diferenciación consistió en restar a cada valor de la serie, el valor correspondiente a la misma fecha pero del ciclo estacional anterior (doce meses atrás).

Se obtuvieron las anomalías anuales para todas las series temporales, definidas como la diferencia entre el valor anual y la media general. Para ello, los datos fueron reescalados a una frecuencia anual, promediando los valores de cada año, excepto en el caso de las precipitaciones, para las cuales se obtuvo el valor acumulado anual.

3.4. Análisis de datos

3.4.1. Caracterización temporal del clima en el área de estudio

Con el objetivo de describir la variación climática del área de estudio, se obtuvo el rango, la media, los mínimos y máximos y el coeficiente de variación (CV) intraanual e interanual de las series temporales de las precipitaciones, del déficit de presión de vapor y del PDSI. El CV intraanual se calculó como el cociente entre el desvío estándar de cada año y la media de ese año. El CV interanual se calculó como el cociente entre el desvío estándar de los promedios anuales y el promedio de los promedios anuales. Se multiplicaron los CV por 100 para expresar el resultado en porcentaje.

Se realizaron gráficos de las precipitaciones, del déficit de presión de vapor y del PDSI, que muestran la variación mensual de los datos observados, la variación mensual de los datos diferenciados (para el VPD) y las anomalías anuales. En estos gráficos se añadió una línea de suavizado de las series temporales para reducir las fluctuaciones a corto plazo y marcar la tendencia general. Esta técnica de suavizado corresponde a un ajuste mediante regresión local usando la función `geom_smooth` del paquete `ggplot2` (Wickham, 2016) en RStudio. Se identificaron los mínimos y máximos con la función `stat_peaks` y `stat_valleys` del paquete `ggpmisc` (Aphalo, 2025).

Se buscaron períodos de sequía de acuerdo a las categorías del PDSI propuestas por Palmer (1965) (Tabla 2), agrupandolas de la siguiente manera: sequía incipiente a leve de -0,50 a -1,99, sequía moderada de -2,00 a -2,99 y sequía severa a extrema valores menores a -3,00. Se realizó un gráfico del balance hídrico para uno de los períodos de sequía extrema detectados por el PDSI (2019 a 2023).

Para evaluar la relación entre las precipitaciones y el PDSI se realizó un análisis de correlación entre ambas variables mediante una regresión lineal.

Tabla 2: Estado del clima según los valores del PDSI (Palmer 1965).

Categoría	**PDSI**
Extremadamente húmedo	≥ 4,00
Muy húmedo	3,00 a 3,99
Moderadamente húmedo	2,00 a 2,99
Ligeramente húmedo	1,00 a 1,99
Humedad incipiente	0,50 a 0,99
Cercano a lo normal	0,49 a -0,49
Sequía incipiente	-0,50 a -0,99
Sequía leve	-1,00 a -1,99
Sequía moderada	-2,00 a -2,99
Sequía severa	-3,00 a -3,99
Sequía extrema	≤ -4,00

3.4.2. Caracterización temporal de los índices de vegetación

Con el objetivo de describir los patrones de variación de los índices de vegetación se obtuvo el rango, la media, los mínimos y máximos y el coeficiente de variación intraanual e interanual de las series temporales. También se realizaron gráficos que muestran la variación mensual de los datos observados, la variación mensual de los datos diferenciados y las anomalías anuales. En estos gráficos también se añadió una línea de suavizado de las series temporales usando la función `geom_smooth` del paquete `ggplot2` en RStudio. Se identificaron los mínimos y máximos con la función `stat_peaks` y `stat_valleys` del paquete `ggpmisc`.

Para los índices VCI, TCI y VHI se buscaron períodos de sequía de acuerdo a las categorías propuestas por Kogan (1994) (Tabla 3), agrupándolas en sequía severa a extrema (0 a 20), sequía moderada (20 a 30) y sequía leve (30 a 40).

Tabla 3: Estado del clima según los valores del VCI, TCI y VHI (Kogan, 1994).

Categoría	VCI	TCI	VHI
Sequía extrema	0 - 10	0 - 10	0 - 10
Sequía severa	10 - 20	10 - 20	10 - 20
Sequía moderada	20 - 30	20 - 30	20 - 30
Sequía leve	30 - 40	30 - 40	30 - 40
Anormalmente seco	40 - 50	40 - 50	
Sin sequía	50 - 100	50 - 100	40 - 100

3.4.3. Relación entre el índice de sequía con los índices espectrales de vegetación

Se analizaron las relaciones entre el PDSI y los índices de vegetación mediante un análisis de sus series temporales, utilizando modelos autorregresivos (AR, del inglés *Autoregressive*) y modelos de retardos distribuidos (DLM, del inglés *Distributed Lag Models*). Dado que los datos de los índices de vegetación están disponibles desde 2001 hasta 2023, se utilizó este período temporal para el análisis.

Un modelo AR de orden p predice la variable dependiente a partir de una combinación lineal de sus propios valores pasados. La ecuación tiene la forma:

$$Y_t = a + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \ldots + \phi_p Y_{t-p} + \varepsilon_t$$

donde Y es la variable dependiente, a la constante, ϕ los coeficientes que indican el peso de los valores pasados de Y y ε el error.

Un DLM de orden q en cambio, predice la variable dependiente utilizando una o más variables independientes y los valores pasados de las mismas. La ecuación tiene la forma:

$$Y_t = a + \phi_1 X_t + \phi_2 X_{t-1} + \phi_3 X_{t-2} + \ldots + \phi_q X_{t-q} + \varepsilon_t$$

donde Y es la variable dependiente, X la variable independiente, a la constante, ϕ los coeficientes que indican el peso de los valores pasados de X y ε el error.

Dado que los modelos AR suponen que la serie temporal es estacionaria, en primer lugar se evaluó la estacionariedad de las series mediante las pruebas de Phillips-Perron (PP) y de Kwiatkowski, Phillips, Schmidt y Shin (KPSS). En la prueba PP, la hipótesis nula sostiene que la serie no es estacionaria, mientras que la hipótesis alternativa indica que sí lo es. En cambio, en la prueba KPSS, la hipótesis nula propone que la serie es estacionaria, y la hipótesis alternativa, lo contrario. Para aquellas series temporales que resultaron ser no estacionarias (p-valor < 0,05) en alguna de las dos pruebas, se aplicó una diferenciación estacional, y, tras este ajuste, se volvió a verificar la estacionariedad de la serie.

Para cada índice de vegetación, se ajustó un modelo autorregresivo AR(p) con el objetivo de quitar la variación debida al propio índice. El orden del componente autorregresivo (p), es decir, el número de retardos de la variable utilizados como predictores en el modelo, se determinó para cada índice de acuerdo con el patrón observado en el gráfico PACF (Anexo 4). Se estableció como orden máximo de la regresión el mes en que se observó el último pico de correlación significativo. La cantidad de modelos ajustados para cada índice fue equivalente a ese (p) máximo, comenzando con el modelo de ruido blanco AR(0), y aumentando un orden en cada modelo.

Para el EVI, a partir del patrón observado en el gráfico PACF (Anexo 4) se estableció el mes 22 como orden máximo de la regresión (p), que resultó ser el modelo óptimo. En el caso de los índices VCI, NMDI y VHI también se propuso inicialmente el mes 22 como valor de p; sin embargo, los modelos óptimos correspondieron a valores de p de 10, 16 y 18, respectivamente. Para los índices NDII6 y NDII7 se determinó un p de 24, que resultó ser también el óptimo. Por último, para los índices NDWI y TCI se propusieron los valores 14 y 18, respectivamente, los cuales coincidieron con los modelos ajustados.

Para el diagnóstico de los modelos se utilizaron gráficos de los residuos contra los valores predichos, Q-Q Plots y la prueba estadística Box-Ljung (Hyndman & Athanasopoulos, 2018b) (con la hipótesis nula de que los datos considerados se distribuyen de forma independiente). Para la selección del modelo se tuvo en cuenta además el criterio de

información de Akaike (AIC). Una vez que se seleccionó el mejor modelo AR(p) para cada uno de los índices, se obtuvo la serie temporal de los residuos del ajuste de cada modelo.

Posteriormente, se utilizó la serie temporal de los residuos de cada modelo AR(p) para ajustar un DLM, utilizando dichos residuos como variable respuesta y el PDSI como variable explicativa, con el objetivo de analizar la relación entre la variación de cada índice (no explicada por el propio índice) y el PDSI. Cada DLM se planteó considerando un retraso en la respuesta de la vegetación a la sequía de hasta seis meses, comenzando con el modelo que incluye el PDSI actual ($PDSI_t$), incorporando un retardo en cada modelo hasta llegar a seis meses ($PDSI_{t-6}$). Para el diagnóstico de los modelos se utilizaron gráficos de los residuos contra los valores predichos, Q-Q Plots y la prueba de Box-Ljung. Para la selección del mejor modelo entre los seis candidatos se tuvo en cuenta además el criterio de información de Akaike (AIC).

4. RESULTADOS

4.1. Caracterización temporal del clima en el área de estudio

En el período de enero de 1959 a diciembre de 2023, la precipitación mensual varió entre 41 y 285 mm, con una media mensual de 141 mm y una media anual de 1719 mm (Figura 8(A)). Los máximos se registraron entre los meses de noviembre y marzo (con algunos casos aislados en los meses de julio, mayo y agosto), con un promedio de 239 mm. Los mínimos se registraron entre los meses de mayo y octubre (con algunos casos aislados en los meses de marzo, noviembre y diciembre), con un promedio de 61 mm.

Se identificaron tres períodos con precipitaciones inferiores a la media del período completo, que se destacaron por la presencia de anomalías anuales negativas más intensas y prolongadas en comparación con el resto de la serie temporal (Figura 8(B)). El primero, entre 1960 y 1964, presentó una media de 129,9 mm, es decir, 13,4 mm por debajo del promedio del período total. El segundo, desde 1976 hasta 1981 registró una media de 122,6 mm (20,7 mm menos), mientras que el tercero, del 2019 a 2023 alcanzó una media de 112 mm, lo que implica una disminución de 31,3 mm respecto de la media general. El coeficiente de variación interanual fue de 29,97 %.

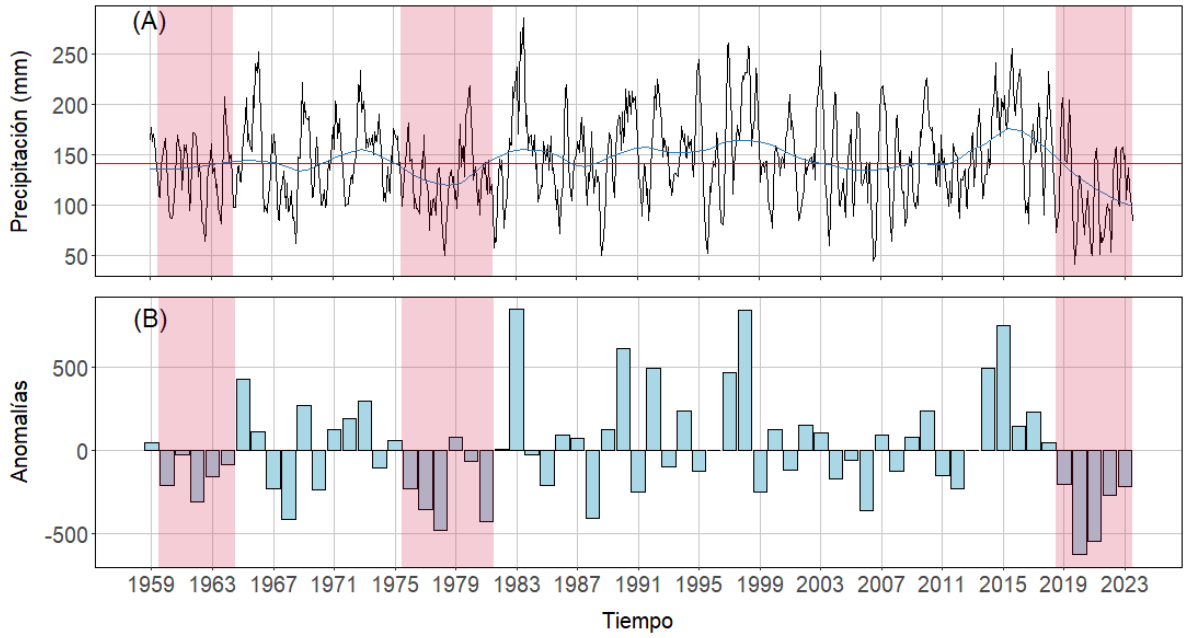

Figura 8: Variación temporal de la precipitación acumulada para el período de enero de 1959 a diciembre de 2023 en el Parque Nacional Iguazú, Misiones. En (A) se muestra la serie mensual observada, con la línea roja representando la precipitación media y la línea azul indicando un suavizado de la serie. En (B) se muestran las anomalías anuales. Los períodos con menor cantidad de precipitaciones se encuentran resaltados en color rojo.

El déficit de la presión de vapor mensual (VPD) varió entre 0,393 y 1,785 kPa, con los máximos siendo en los meses de noviembre a febrero, con un promedio de 1,146 kPa y los mínimos en los meses de junio a agosto, con un promedio de 0,499 kPa (Figura 9(A)). El déficit de presión de vapor medio para todo el período fue de 0,823 kPa.

Se identificaron dos períodos con valores del VPD superiores al promedio general, que se destacaron por la presencia de anomalías positivas de mayor intensidad y duración en comparación con el resto de la serie temporal (Figura 9(C)). El primero, desde 1961 hasta 1970, con una media de 0,85 kPa, es decir, 0,03 kPa más que el promedio del período completo. El segundo entre 2019 y 2023, con un promedio de 0,92 kPa (0,10 kPa por encima de la media general). El coeficiente de variación interanual fue de 27,39 %.

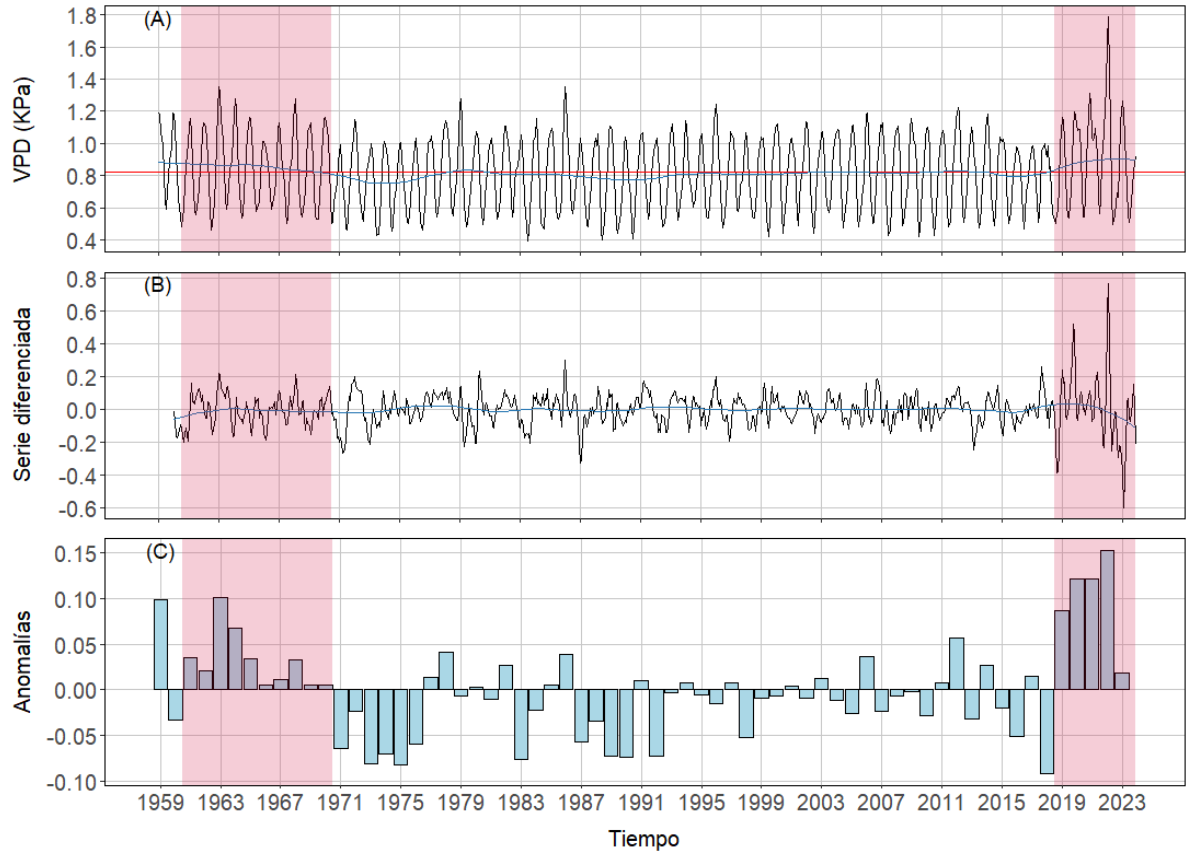

Figura 9: Variación temporal del déficit de presión de vapor para el período de enero de 1959 a diciembre de 2023, en el Parque Nacional Iguazú, Misiones. En (A) se muestra la serie mensual observada, en (B) la serie diferenciada y en (C) las anomalías anuales. La línea roja (A) representa la media y la línea azul (A y B) indica un suavizado de las series. Los períodos con mayor VPD se encuentran resaltados en color rojo.

El coeficiente de variación intraanual de las precipitaciones varió entre 8,77 % y 44,58 % mientras que para el VPD varió entre 19,44 % y 45,40 %. Las variaciones intraanuales de las precipitaciones presentaron una mayor amplitud y fluctuaciones más marcadas a lo largo del tiempo, con una tendencia creciente en los últimos años. En cambio, las variaciones intraanuales del VPD fueron más estables, aunque también presentaron un aumento hacia el final del período (Figura 10).

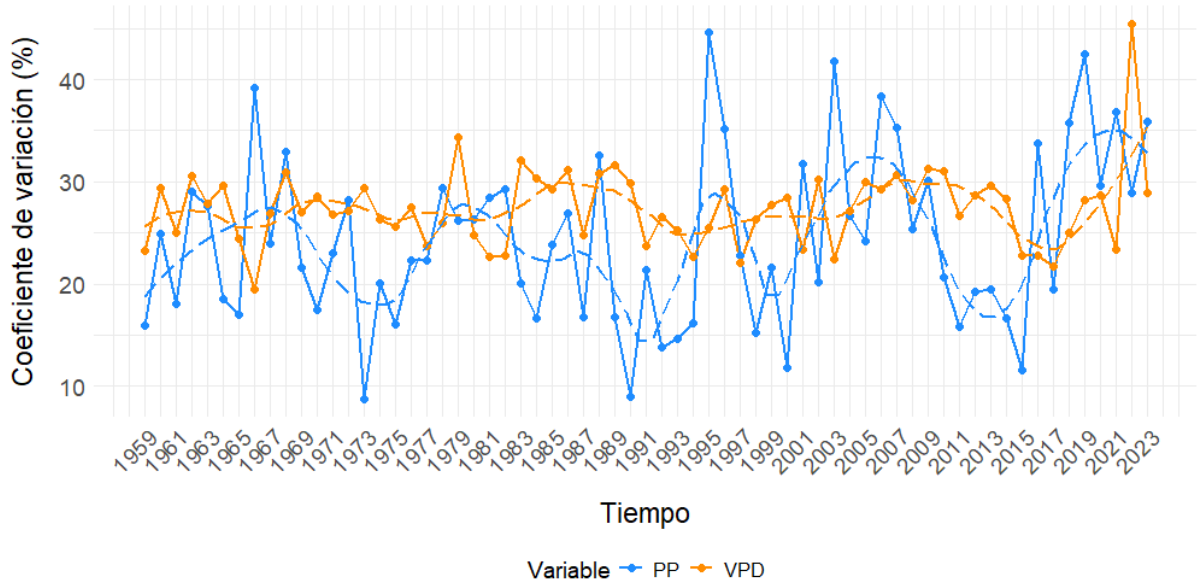

Figura 10: Coeficientes de variación intraanual de las precipitaciones (PP) y del déficit de presión de vapor (VPD) para el período de enero de 1959 a diciembre de 2023, en el Parque Nacional Iguazú. Las líneas discontinuas corresponden a un suavizado de las series.

El índice de sequía de Palmer mensual varió entre -7,99 y 7,83, con una media de 0,072. A lo largo del intervalo estudiado, el PDSI registró de manera recurrente, valores correspondientes a sequías incipientes a leves (-0,5 a -1,99), moderadas (-2 a -2,99) y severas a extremas (menores a -3), alternando con períodos de condiciones normales o de mayor humedad (valores superiores a -0,49) (Figura 11(A)). Se destacan dos períodos de sequía más prolongados que los del resto de la serie temporal: el primero, de mayo de 1976 a septiembre de 1979 y el segundo, de octubre de 2019 a noviembre de 2023. Durante estos intervalos las anomalías negativas fueron más intensas y prolongadas en comparación con el resto de la serie (Figura 11(B)).

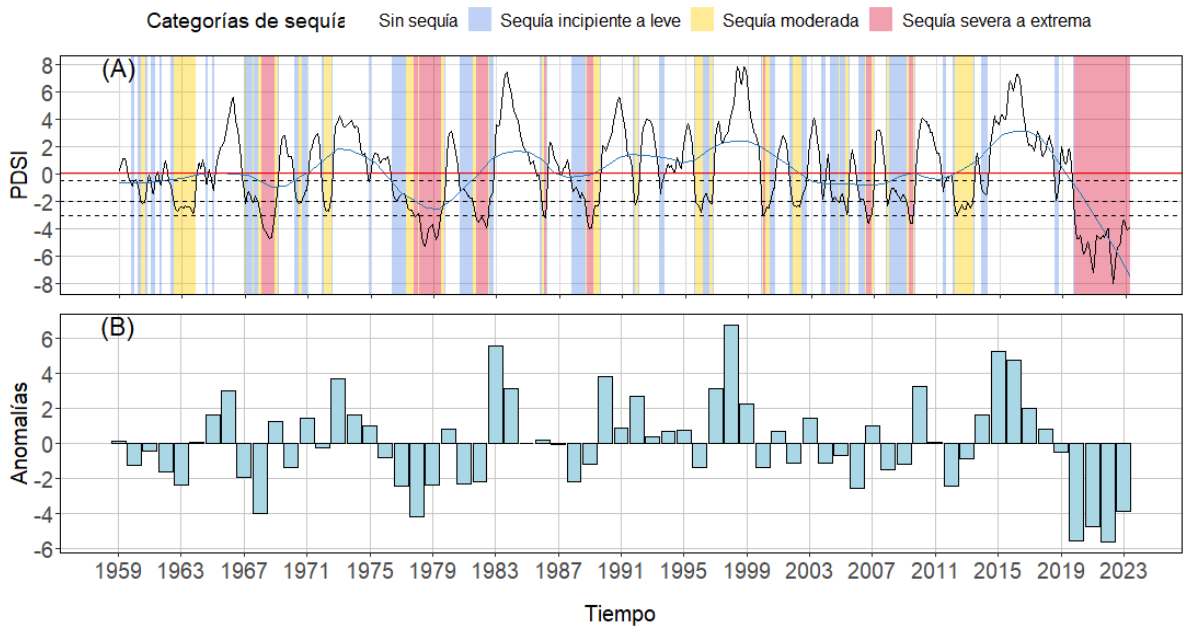

Figura 11: Variación temporal del Índice de sequía de Palmer para el período de enero de 1959 a diciembre de 2023 en el Parque Nacional Iguazú, Misiones. En (A) se muestra la serie mensual, con la línea roja representando la media, la línea azul indicando un suavizado de la serie y las líneas punteadas los valores límite de las distintas categorías de sequía definidas por el PDSI (-0,5, -2 y -3). En (B) se muestran las anomalías anuales del índice.

El balance hídrico para el período de 2019 a 2023 (Figura 12) mostró condiciones de déficit hídrico en febrero, de julio a septiembre y de noviembre a diciembre, momentos en los que la evapotranspiración potencial superó a las precipitaciones.

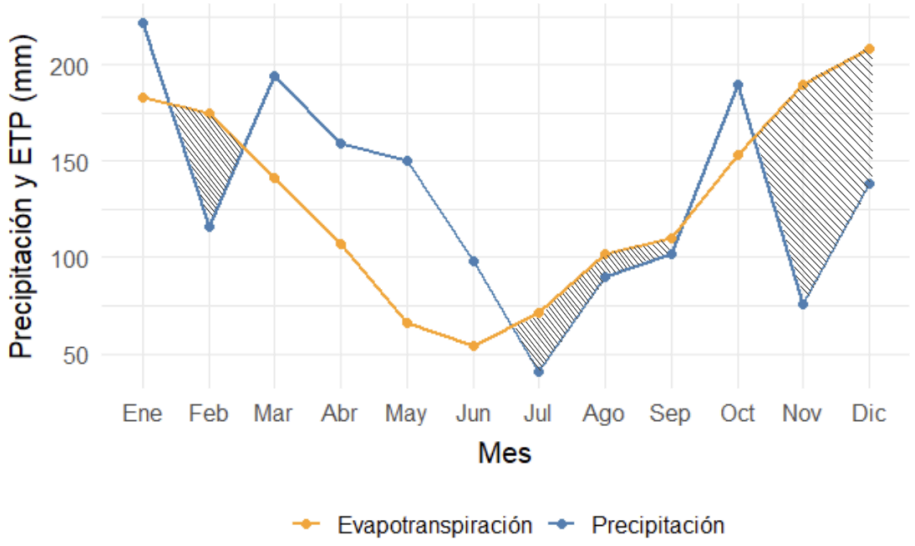

Figura 12: Variación mensual de la precipitación y la evapotranspiración potencial (ETP) en Iguazú, Misiones, para el período de 2019 a 2023. Elaboración propia con datos tomados del Servicio Meteorológico Nacional (SMN). Las áreas sombreadas representan períodos de déficit hídrico.

La relación lineal entre las precipitaciones mensuales y el PDSI mensual tuvo un coeficiente de determinación (R^2) de 0,407 (Figura 13(A)), mientras que la relación entre las anomalías de las precipitaciones y las anomalías del PDSI tuvo un R^2 de 0,647 (Figura 13(B)).

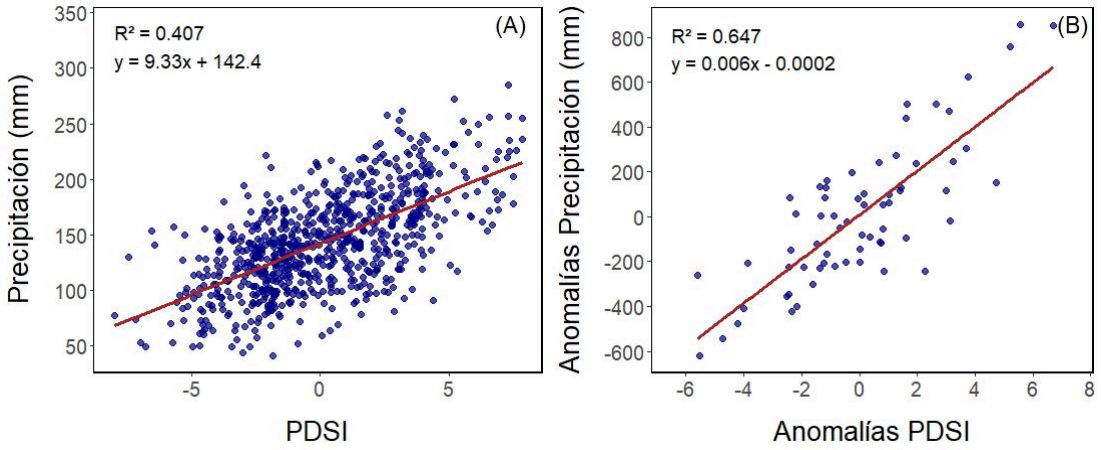

Figura 13: Relación lineal entre (A) los datos mensuales de precipitación y del PDSI y (B) las anomalías anuales de la precipitación y del PDSI.

4.2. Caracterización temporal de los índices de vegetación

En el período desde marzo del 2001 a diciembre del 2023, el EVI mensual varió entre 0,384 y 0,607, con un promedio de 0,496, mientras que el anual varió entre 0,465 y 0,517. Este índice mostró un patrón estacional en donde los máximos se registraron entre los meses de noviembre a marzo (verano), con un promedio de 0,569, mientras que los mínimos se registraron entre los meses de julio a septiembre (invierno), con un promedio de 0,423 (Figura 14).

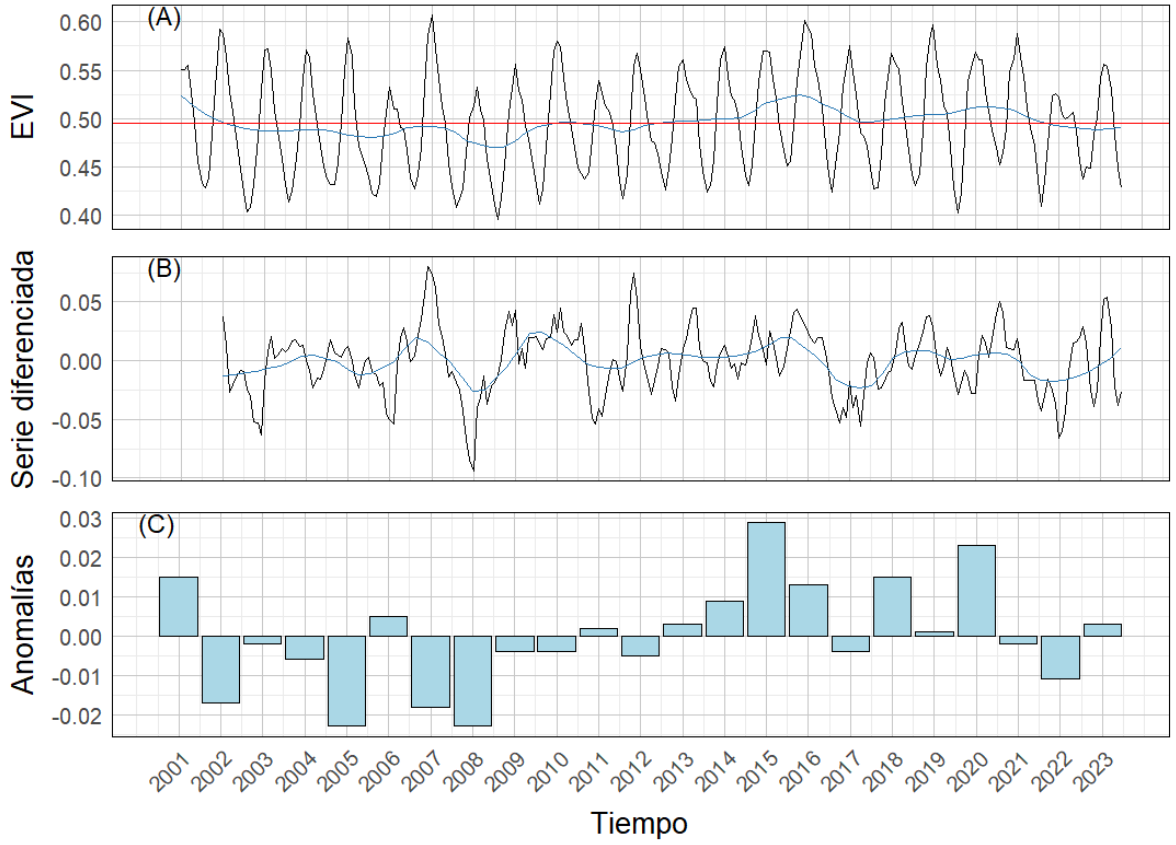

Figura 14: Variación temporal del EVI. Se muestra la serie mensual observada (A), la serie diferenciada (B), y las anomalías anuales (C) para el período de marzo del 2001 a diciembre del 2023 en el Parque Nacional Iguazú, Misiones. Se incluye la media (línea roja) y el suavizado de la serie (línea azul).

El NDWI mensual varió entre -0,029 y 0,062, con una media de 0,027, mientras que el anual varió entre 0,0185 y 0,0428. El índice mostró un patrón estacional, en donde los máximos se

registraron entre los meses de noviembre y marzo (verano), con un promedio de 0,049, mientras que los mínimos se registraron entre los meses de julio a septiembre (invierno), con un promedio de -0,0054 (Figura 15).

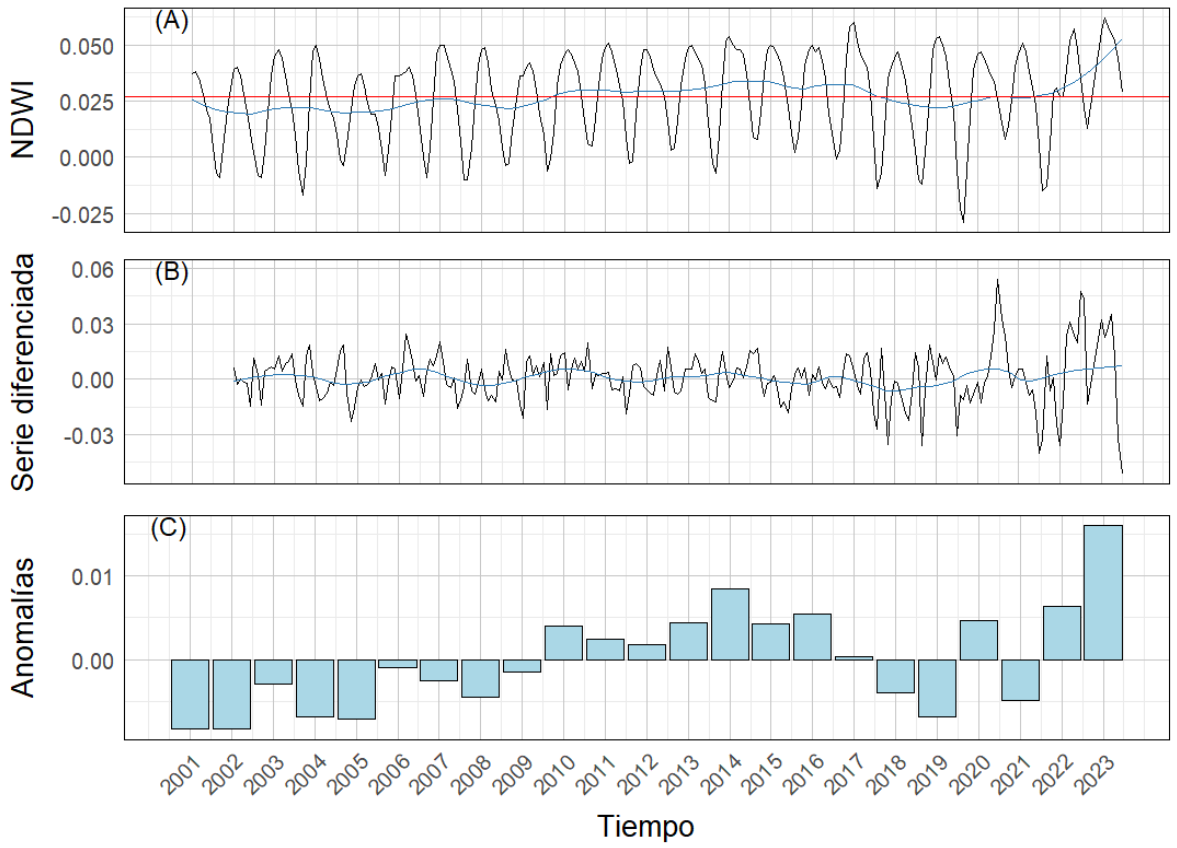

Figura 15: Variación temporal del NDWI. Se muestra la serie mensual observada (A), la serie diferenciada (B), y las anomalías anuales (C) para el período de enero del 2001 a diciembre del 2023 en el Parque Nacional Iguazú, Misiones. Se incluye la media (línea roja) y el suavizado de la serie (línea azul).

El NMDI mensual varió entre 0,454 y 0,545, con una media de 0,510, mientras que el anual varió entre 0,501 y 0,525. El índice mostró un patrón estacional en donde los máximos se registraron entre los meses de noviembre y mayo (verano-otoño), con un promedio de 0,532, mientras que los mínimos se registraron entre los meses de julio a septiembre (invierno), con un promedio de 0,476 (Figura 16).

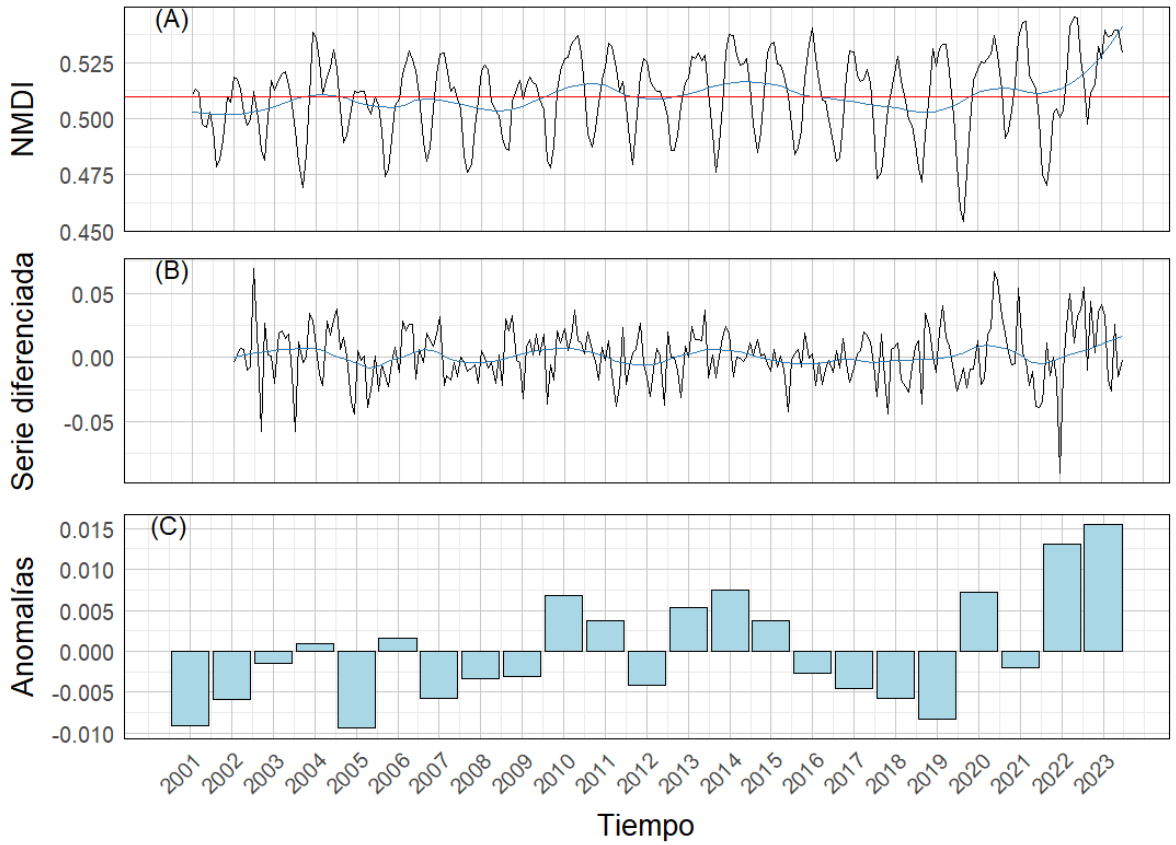

Figura 16: Variación temporal del NMDI. Se muestra la serie mensual observada (A), la serie diferenciada (B), y las anomalías anuales (C) para el período de enero del 2001 a diciembre del 2023 en el Parque Nacional Iguazú, Misiones. Se incluye la media (línea roja) y el suavizado de la serie (línea azul).

El NDII6 mensual varió entre 0,202 y 0,380, con una media de 0,31, mientras que el anual varió entre 0,284 y 0,331. El índice mostró un patrón estacional en donde los máximos se registraron entre los meses de diciembre a mayo (verano-otoño), con un promedio de 0,361, mientras que los mínimos se registraron entre los meses de julio a septiembre (invierno), con un promedio de 0,241 (Figura 17).

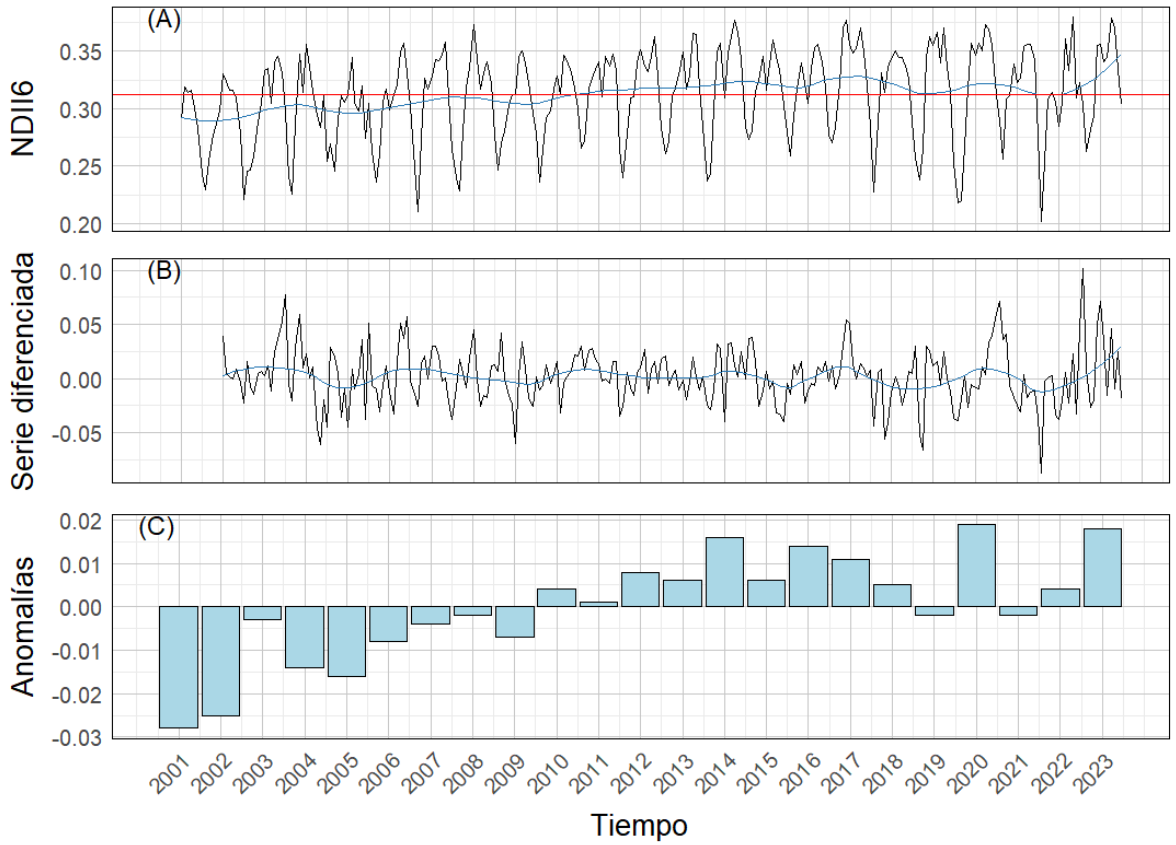

Figura 17: Variación temporal del NDII6. Se muestra la serie mensual observada (A), la serie diferenciada (B), y las anomalías anuales (C) para el período de enero del 2001 a diciembre del 2023 en el Parque Nacional Iguazú, Misiones. Se incluye la media (línea roja) y el suavizado de la serie (línea azul).

El NDII7 mensual varió entre 0,511 y 0,753, con una media de 0,67, mientras que el anual varió entre 0,636 y 0,691. Este índice presentó un patrón estacional, en el cual los máximos se registraron entre los meses de enero a mayo (verano-otoño), con un promedio de 0,730, mientras que los mínimos se registraron entre los meses de julio a octubre (invierno-primavera), con un promedio de 0,587 (Figura 18).

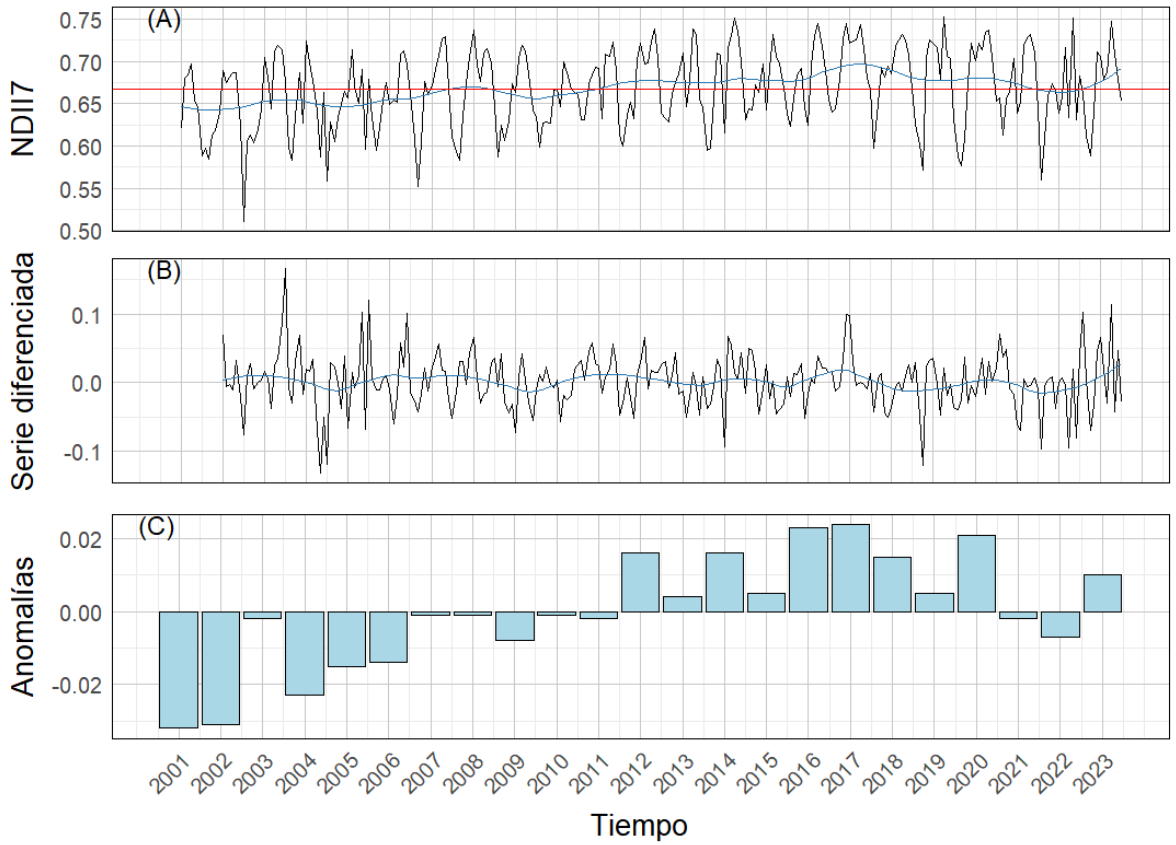

Figura 18: Variación temporal del NDII7. Se muestra la serie mensual observada (A), la serie diferenciada (B), y las anomalías anuales (C) para el período de enero del 2001 a diciembre del 2023 en el Parque Nacional Iguazú, Misiones. Se incluye la media (línea roja) y el suavizado de la serie (línea azul).

El VCI mensual varió entre 21,38 y 89,31, con un promedio de 62,69, mientras que el anual varió entre 56,81 y 68,71. El índice mostró un patrón estacional con máximos registrados entre los meses de enero a mayo (verano-otoño), con un promedio de 80,47, mientras que los mínimos se registraron entre los meses de septiembre a octubre (primavera) con un promedio de 36,39. No se registraron valores correspondientes a sequía severa a extrema (0-20); sin embargo, sí se detectaron períodos de sequía leve (30-40) y sequía moderada (20-30) (Figura 19).

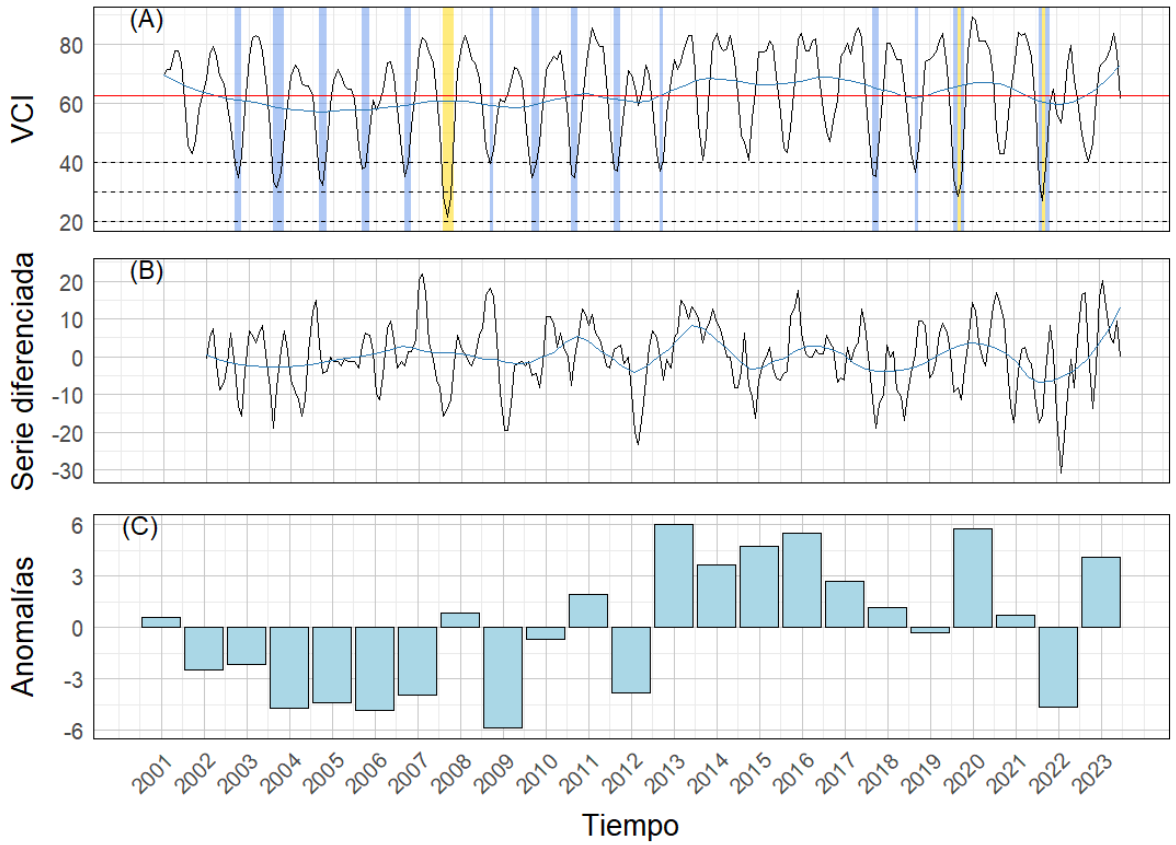

Figura 19: Variación temporal del VCI en el Parque Nacional Iguazú, Misiones, entre enero de 2001 y diciembre de 2023. Se muestra la serie mensual observada (A), la serie mensual diferenciada (B) y las anomalías anuales (C). La línea roja (A) indica la media y la línea azul (A y B) el suavizado de la serie. En (A) se destacan los períodos correspondientes a sequía leve (azul) y sequía moderada (amarillo), según los valores del VCI. Las líneas punteadas indican los umbrales de cada categoría (20, 30 y 40).

El TCI mensual varió entre 6,05 y 86,28, con un promedio de 43,39, mientras que el anual varió entre 36,74 y 48,07. Este índice mostró un patrón estacional con máximos registrados entre los meses de julio a agosto (invierno), con un promedio de 76,22 mientras que los mínimos se registraron entre los meses de noviembre a marzo (verano), con un promedio de 19,09. El índice alcanzó valores que indican sequía leve (30-40), sequía moderada (20-30) y sequía severa a extrema (0-20) (Figura 20).

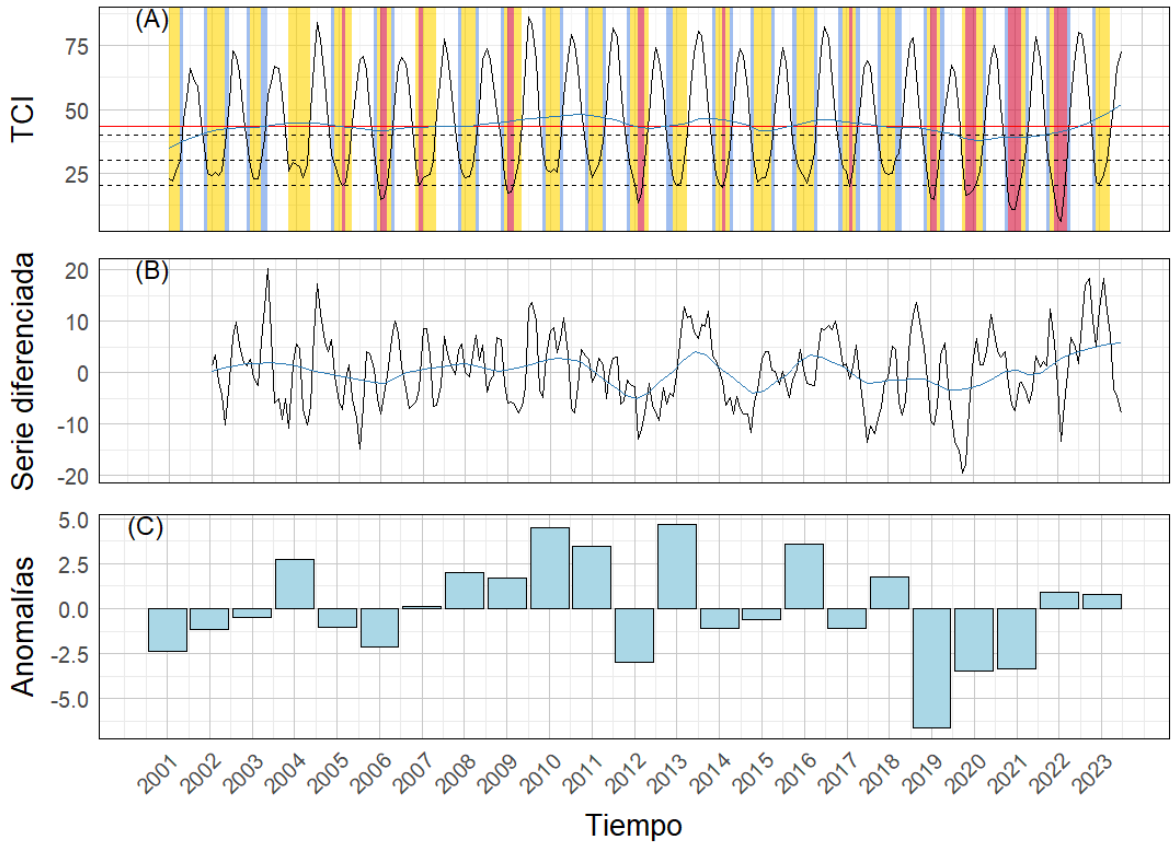

Figura 20: Variación temporal del TCI en el Parque Nacional Iguazú, Misiones, entre enero de 2001 y diciembre de 2023. Se muestra la serie mensual observada (A), la serie mensual diferenciada (B) y las anomalías anuales (C). La línea roja (A) indica la media y la línea azul (A y B) el suavizado de la serie. En (A) se destacan los períodos correspondientes a sequía leve (azul), sequía moderada (amarillo) y sequía severa a extrema (rojo), según los valores del TCI. Las líneas punteadas indican los umbrales de cada categoría (20, 30 y 40).

El VHI mensual varió entre 29,76 y 77,62, con una media de 53,04, mientras que el anual varió entre 49,56 y 58,39. El índice mostró un patrón estacional con los máximos registrados entre los meses de mayo a julio (otoño-invierno), con un promedio de 69,55, mientras que los mínimos se registraron entre los meses de octubre a marzo (primavera-verano), con un promedio de 39,68. No se registraron valores correspondientes a sequía severa a extrema (0-20); sin embargo, se detectaron períodos de sequía leve (30-40), y sequía moderada (20-30) (Figura 21).

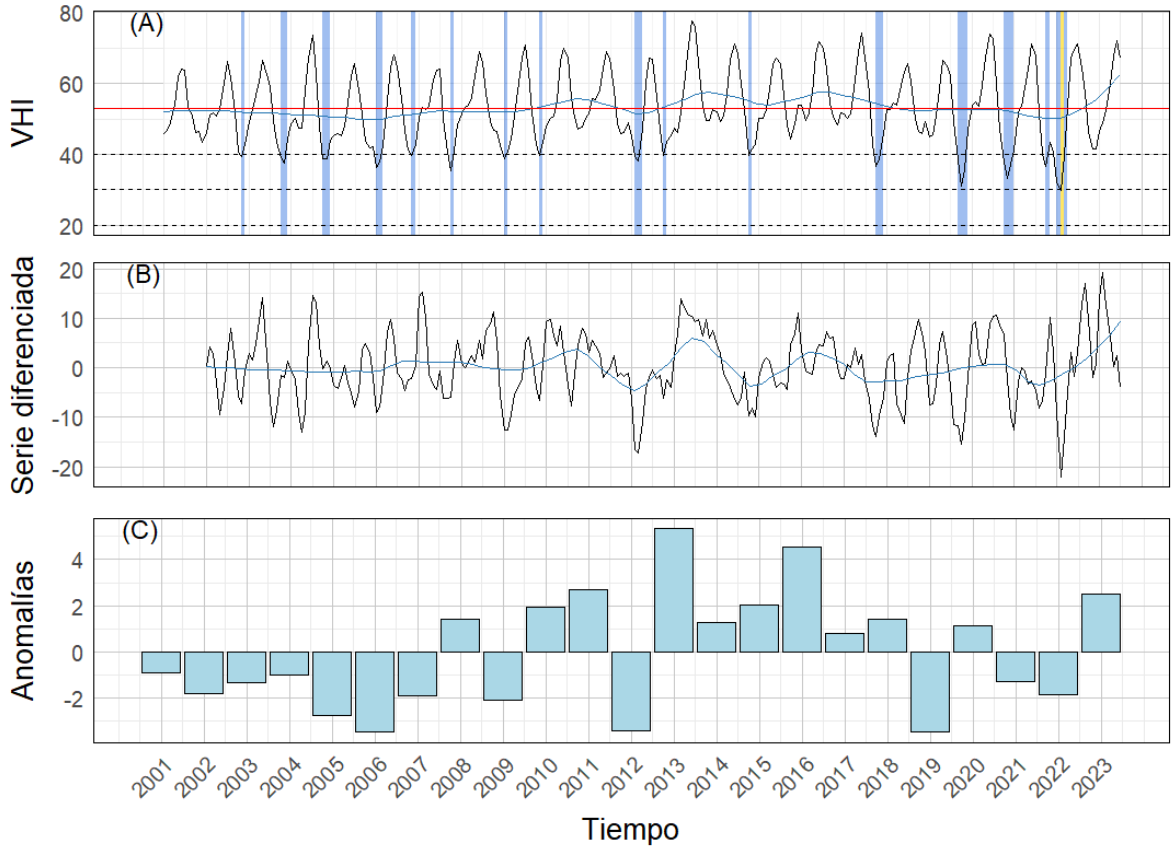

Figura 21: Variación temporal del VHI en el Parque Nacional Iguazú, Misiones, entre enero de 2001 y diciembre de 2023. Se muestra la serie mensual observada (A), la serie mensual diferenciada (B) y las anomalías anuales (C). La línea roja (A) indica la media y la línea azul (A y B) el suavizado de la serie. En (A) se destacan los períodos correspondientes a sequía leve (azul), según los valores del VHI. Las líneas punteadas indican los umbrales de cada categoría (20, 30 y 40).

El coeficiente de variación (CV) intraanual del NDWI mostró mayores fluctuaciones a lo largo del tiempo que el CV de los otros índices, con valores que oscilaron entre 41,43 % y 144,20 %, alcanzando picos máximos en 2019 y 2021. El CV intraanual del TCI también presentó una alta variabilidad durante todo el período, aunque más estable que el NDWI, con valores entre 39,97 % y 65,76 %. En contraste, los índices VCI y VHI mostraron un CV intraanual más constante, con valores entre 18,85 % y 38,26 % para el VCI y entre 11,81 % y 30,02 % para el VHI. Los CV intraanuales de los índices EVI, NDII6, NDII7 y NMDI tomaron los valores más pequeños y fueron más homogéneos durante el período analizado. El CV intraanual del EVI varió entre 6,08 % y 13,17 %; el del NDII6 entre 8,05 % y 18,09 %; el del NDII7 entre 3,39 % y 8,69 %; y el del NMDI entre 2,34 % y 5,73 % (Figura 22).

En cuanto a los CV interanuales, todos los índices mostraron valores muy bajos, excepto el NDWI. Este índice presentó el valor más alto, superando a los demás en un orden de magnitud (Tabla 4).

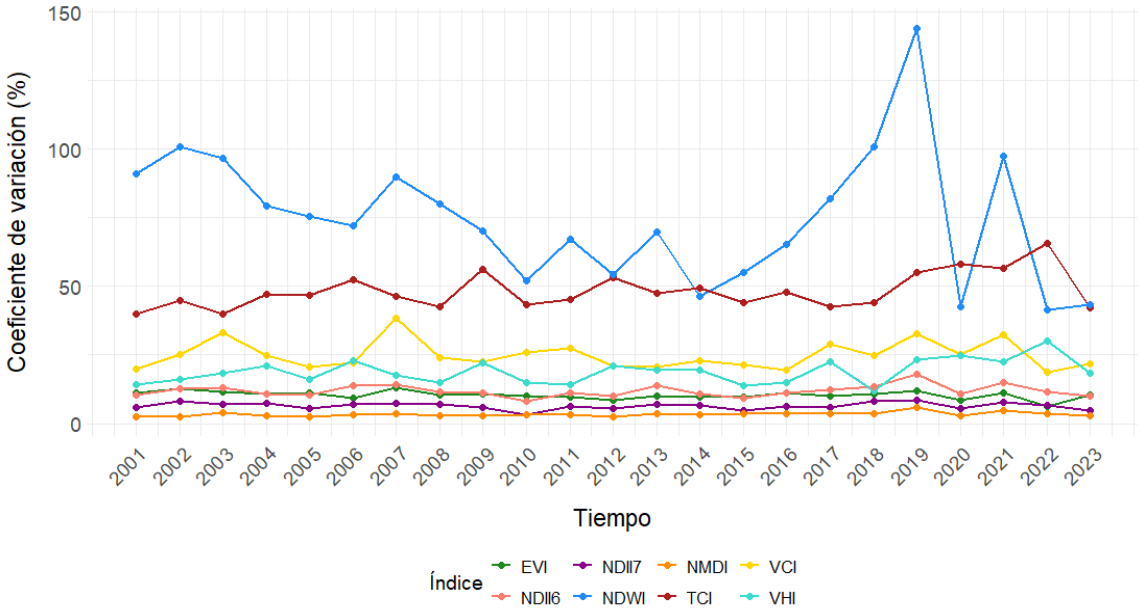

Figura 22: Coeficientes de variación intraanual de cada índice de vegetación para el período de enero de 2001 a diciembre de 2023, en el Parque Nacional Iguazú.

Tabla 4: Rango de valores (mensuales) y coeficientes de variación (CV) interanual de cada índice de vegetación para el período de enero de 2001 a diciembre de 2023, en el Parque Nacional Iguazú.

Índice de vegetación	Rango (Min;Max)	CV interanual (%)
EVI	0,223 (0,384; 0,607)	2,45
VCI	67,93 (21,38; 89,31)	5,95
TCI	80,23 (6,05 y 86,28)	6,82
VHI	47,86 (29,76; 77,62)	4,79
NMDI	0,091 (0,454; 0,545)	1,37
NDWI	0,091 (-0,029; 0,062)	23,03
NDII6	0,178 (0,202; 0,380)	4,08
NDII7	0,242 (0,511; 0,753)	2,38

4.3. Relación entre el índice de sequía con los índices de vegetación

Los resultados de las pruebas de estacionariedad PP y KPSS indicaron que las series temporales de los índices EVI, TCI, VCI y VHI son estacionarias (Anexo 5). Las series temporales de los índices NDWI, NMDI, NDII6 y NDII7 en cambio, alcanzaron la estacionariedad luego de una diferenciación estacional (Anexo 6).

Se obtuvo el DLM para cada uno de los índices de vegetación (Figuras 23 y 24). Dado que se eligió el mejor modelo entre los seis evaluados, éste no necesariamente incluye el PDSI en todos los retardos evaluados (hasta seis meses previos). Para el EVI, el modelo óptimo incluyó el PDSI del mes actual; sin embargo, la relación entre ambos índices no fue significativa ($p > 0,05$) (Figura 23). Para el NDWI, se seleccionó el modelo que considera el PDSI de hasta dos meses antes, mostrando una relación significativa en ambos meses ($p < 0,05$) (Figura 23). En cuanto al NMDI, el modelo óptimo incluyó el PDSI de hasta tres meses atrás, con una relación significativa en todos los meses ($p < 0,05$) (Figura 23). Para los índices NDII6 y NDII7, el modelo adecuado incorporó el PDSI de hasta tres meses previos. Aunque la relación entre el NDII6 y el PDSI no fue significativa ($p > 0,05$), se observó una relación significativa entre el NDII7 y el PDSI del mes actual, así como con el de uno y dos meses atrás ($p < 0,05$) (Figura 23). En el caso del VCI, el modelo más adecuado consideró el PDSI de hasta cuatro meses previos, encontrando una relación significativa con el PDSI del mes actual y del mes anterior ($p < 0,05$) (Figura 24). Por último, el modelo seleccionado para el VHI incluyó el PDSI de hasta cinco meses atrás, mostrando una relación significativa con el PDSI del mes actual, así como con el de uno, tres y cuatro meses previos ($p < 0,05$) (Figura 24). La relación entre el TCI y el PDSI no pudo ser evaluada, ya que el modelo no cumplió con el supuesto de independencia de las observaciones.

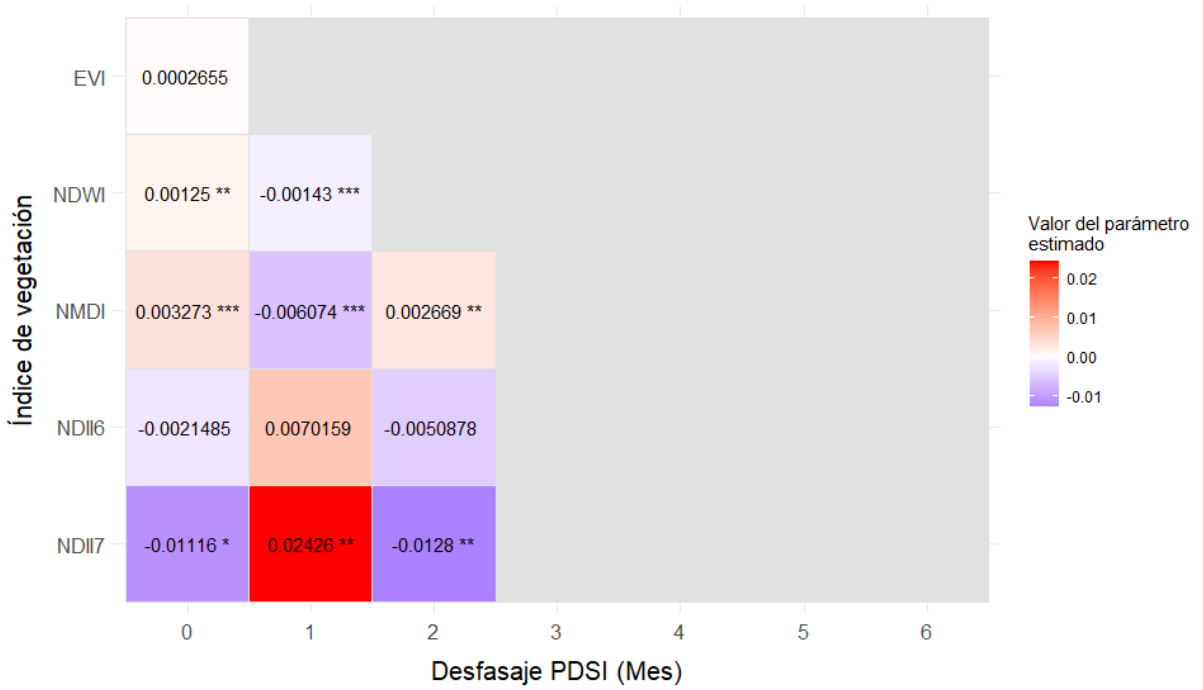

Figura 23: Gráfico de calor con los coeficientes estimados para los índices de vegetación EVI, NDWI, NMDI, NDII6 Y NDII7, en relación con el PDSI y su desfasaje en meses. Los asteriscos indican el nivel de significancia estadística de los coeficientes (***: p-valor < 0.001; **: p-valor < 0.01; *: p-valor < 0.05).

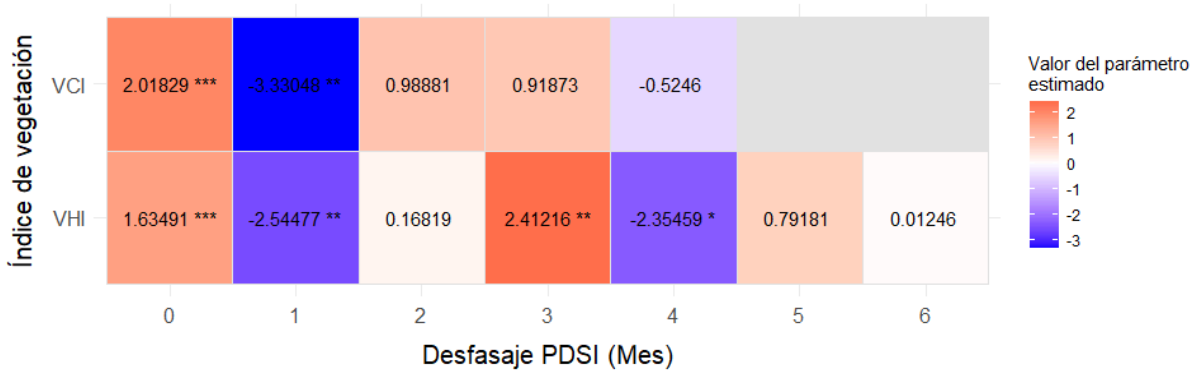

Figura 24: Gráfico de calor con los coeficientes estimados para los índices de vegetación VCI y VHI, en relación con el PDSI y su desfasaje en meses. Los asteriscos indican el nivel de significancia estadística de los coeficientes (***: p-valor < 0.001; **: p-valor < 0.01; *: p-valor < 0.05).

5. DISCUSIÓN

Este trabajo permitió caracterizar y analizar la variación temporal del clima y de la vegetación en los bosques misioneros del Parque Nacional Iguazú (PNI) a partir de información proveniente de sensores remotos. Se analizó la relación entre el índice de sequía PDSI y diversos índices espectrales de la vegetación utilizando modelos autorregresivos, desde el 2001 al 2023. En las siguientes secciones se discuten los resultados hallados, en función de las hipótesis y predicciones propuestas.

5.1. Caracterización temporal del clima en el área de estudio

A lo largo del período analizado las precipitaciones variaron notablemente, alternando entre años inusualmente húmedos, secos y normales, con cambios marcados de un año a otro. Se identificaron tres períodos prolongados con precipitaciones anuales por debajo del promedio, cada uno compuesto por cinco años consecutivos de anomalías negativas, con excepción del segundo período (1976 a 1981), que incluyó un año (1979) con precipitaciones superiores a la media. La intensidad de las anomalías negativas fue en incremento en cada período, destacándose las anomalías de los años 2020 y 2021. El déficit de presión de vapor (VPD) mostró un patrón estacional, dentro del cual se identificaron dos períodos con varios años consecutivos de anomalías positivas. El primero, entre 1961 y 1970 fue más extenso, aunque con anomalías de menor intensidad. En contraste, el segundo período, de 2019 a 2023 fue de menor duración, pero se caracterizó por anomalías más intensas en casi todos los años. El comportamiento de las variables climáticas durante estos tres períodos refleja una menor disponibilidad de agua y un aumento en la demanda atmosférica de agua durante un tiempo prolongado, lo que sugiere condiciones de sequía en el PNI, de acuerdo a lo esperado por la primera predicción (*que las variables climáticas muestren desviaciones de su patrón de variación normal, asociados a condiciones climáticas de sequía*).

La capacidad de detección de los índices climáticos varía según la zona climática, el tipo de ecosistema y la cobertura del suelo, por lo que es importante evaluar la efectividad en diferentes condiciones ambientales (Zou et al., 2020). El Índice de Sequía de Palmer (PDSI)

ha sido utilizado como indicador de sequía en regiones subtropicales con una estación seca bien definida, caracterizada por precipitaciones muy reducidas (Xulu et al., 2018; Zou et al., 2020). Sin embargo, no se han encontrado muchos estudios que utilicen este índice en regiones con elevadas precipitaciones a lo largo del año, como sucede en los bosques misioneros. En este estudio, conforme a lo esperado por la segunda predicción (*que el PDSI sea capaz de detectar períodos de sequía*), el índice identificó distintos eventos de sequía en el PNI, a lo largo del período analizado. Estos eventos de sequía variaron en intensidad, desde incipientes a leves, moderados, hasta severos a extremos. También mostraron distintas duraciones, ya que abarcaron desde meses hasta varios años, y estuvieron intercalados por períodos de condiciones normales o de mayor humedad. En coincidencia con lo observado para las precipitaciones, en la serie temporal del PDSI también se destacaron dos períodos de sequía más intensos y duraderos que en el resto de la serie. El primero, de 1976 a 1979, con cuatro años de anomalías negativas, reflejó condiciones climáticas de sequía incipiente a leve, moderada y severa a extrema. El segundo período, de 2019 a 2023, mostró valores del PDSI que indican condiciones de sequía severa a extrema y fue el de mayor duración e intensidad registrado en el período de estudio, con cinco años de anomalías negativas.

Existen registros que señalan sequías y disminución en el caudal del agua en el PNI en 1978 y 2019 (Clarín, 2019; Portal de América, 2020; Misiones Journal, 2022). Sin embargo, la sequía iniciada en 2019 se destaca por su mayor impacto y gravedad (Rosana & Rafaelli, 2023), vinculándose con el fenómeno de La Niña, que comenzó en agosto de 2020 y duró hasta enero de 2023 (NOAA, s.f.; Primera Edición, 2024; Leiva, 2023) (Figura 2). Cabe destacar que el VPD mostró un aumento en la demanda atmosférica de agua solo durante el segundo período de sequía mencionado (2019), mientras que se mantuvo en valores cercanos a la media durante el primer período (1978). Un período de cinco años de anomalías negativas para las precipitaciones y positivas para el VPD, no se observó simultáneamente para ambas variables en años anteriores, lo que reflejaría la gravedad de la última sequía.

Durante este segundo período de sequía también aumentó el coeficiente de variación (CV) intraanual de las precipitaciones y el VPD, lo que indica una mayor variabilidad de las condiciones climáticas a lo largo del año. Penalba y Rivera (2016) analizaron la relación entre

las precipitaciones y los eventos de El Niño y La Niña en el sur de Sudamérica, encontrando que estos fenómenos impactan significativamente en las precipitaciones, tanto a nivel intraanual (estacional) como interanual. En escala intraanual, identificaron que en períodos de La Niña, la región NE de Argentina presenta anomalías significativas, tanto positivas como negativas, siendo las negativas más intensas que las positivas. Además el Centro de Investigaciones del Mar y la Atmósfera (CIMA, 2015) informó que, para un escenario de cambio climático moderado, el número máximo anual de días consecutivos secos tendería a incrementarse para la región. Estos hallazgos podrían explicar el aumento del CV intraanual que se observó en las variables climáticas los últimos años.

El análisis de las sequías a una escala estacional es más adecuado para analizar impactos en la agricultura, mientras que a una escala anual se pueden reflejar cambios que son relevantes para estudiar las sequías hidrológicas (Penalba & Rivera, 2016). Estas se refieren a una escasez de agua en el sistema hidrológico y se manifiestan en caudales anormalmente bajos en los ríos y niveles bajos en lagos, embalses y aguas subterráneas (Van Loon, 2015). Los eventos de sequía de menor duración e intensidad detectados por el PDSI podrían estar relacionados con la variabilidad natural de los patrones estacionales de precipitación (como una disminución de las precipitaciones durante algunas semanas consecutivas, que desencadenan efectos de sequía a corto plazo), que no siempre son evidentes en sus series temporales y que, al no afectar el sistema hidrológico, podrían no tener un impacto significativo en el ecosistema. En cambio, los eventos de mayor duración y/o intensidad podrían asociarse a sequías hidrológicas, con un impacto más significativo en el ecosistema, ya que se asume que cualquier degradación ecológica está estrechamente relacionada con el estrés ambiental acumulado, más que con un estrés aislado o no consecutivo (Zheng et al., 2014).

Las sequías han recibido poca atención en los bosques subtropicales, ya que generalmente no se consideran un factor de gran impacto en estos ecosistemas, dado que las precipitaciones no suelen ser limitantes (Covich et al. 2003). Sin embargo, los resultados de este trabajo sugieren que, aunque los bosques del PNI reciben un alto aporte de agua durante todo el año, pueden experimentar períodos de déficit hídrico climático que podrían afectar a

los procesos de la vegetación. Esto se evidencia en el balance hídrico correspondiente al período 2019 a 2023 (Figura 12), en el cual se identifican meses, principalmente entre fines del verano y el invierno, en los que la evapotranspiración potencial supera a la precipitación, reflejando condiciones de déficit hídrico. Beard y colaboradores (2005) estudiaron la influencia de las sequías en la vegetación de los bosques subtropicales húmedos de Puerto Rico (con 3500 a 4800 mm de precipitaciones anuales), y observaron una disminución en el crecimiento del diámetro de los árboles y en la producción de hojarasca durante las sequías. Además, los eventos de sequía también pueden crear condiciones favorables para la ocurrencia de incendios en estos ecosistemas. Por ejemplo, durante 2019 a 2023, en la provincia de Misiones se han reportado numerosos incendios (Revista Chacra, 2020; FM Santa María de las Misiones, 2020; Ámbito, 2021; La Voz de Cataratas, 2021, 2022; Izquierda Socialista, 2022; Primera Edición, 2022) que coinciden con el período de La Niña, mientras que ningún incendio se ha reportado en condiciones de El Niño (Figura 25). Tanto el PDSI, como las precipitaciones y el VPD mostraron un patrón similar de una tendencia a condiciones anormalmente secas a partir del 2019, lo que demuestra la capacidad del PDSI para monitorear sequías a largo plazo en los bosques subtropicales húmedos de Misiones.

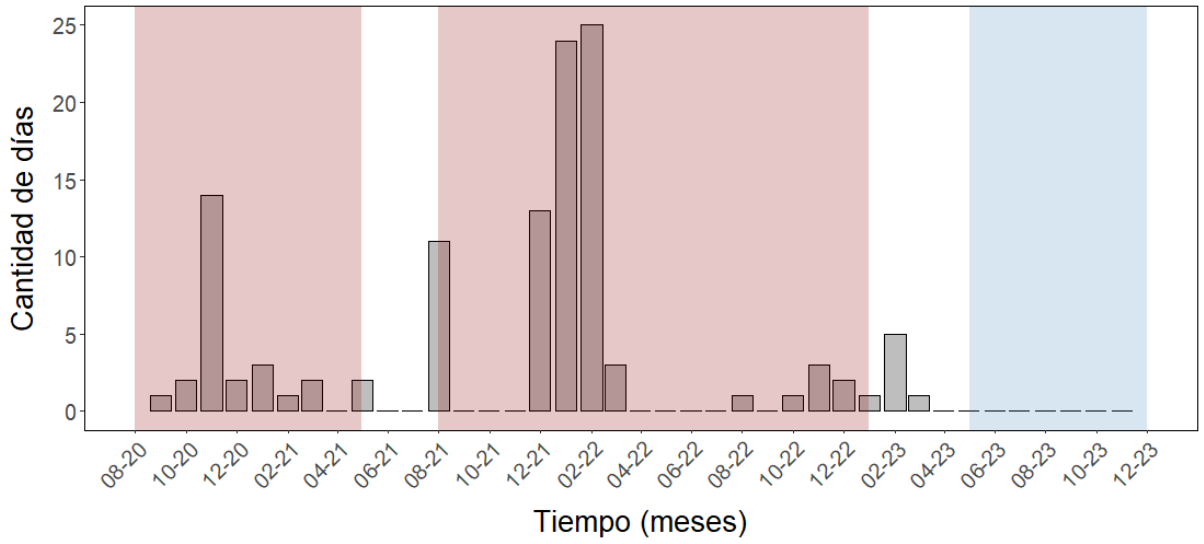

Figura 25: Cantidad de días por mes con al menos un foco de incendio en la provincia de Misiones. Los períodos sombreados en rojo corresponden a fases de La Niña, los sombreados en azul a fases de El Niño, y los no sombreados a períodos con condiciones normales. Datos tomados de la

Administración Nacional Oceánica y Atmosférica (NOAA, por sus siglas en inglés) y del Servicio Nacional de Manejo del Fuego (SNMF).

5.2. Caracterización temporal de los índices de vegetación y relación con el índice de sequía

Con respecto a lo esperado por la tercera predicción (*que los índices de vegetación presenten distorsiones en sus patrones de variación normal, mostrando disminuciones asociadas a condiciones de estrés hídrico*), en general no se observó una respuesta marcada en las dinámicas mensuales de los índices de vegetación ante los períodos de sequía. En cuanto a lo esperado por la cuarta predicción (*que la relación entre los índices de vegetación y el PDSI sea lineal y esté caracterizada por un retraso temporal*), sí se obtuvo una relación significativa con el PDSI para algunos índices.

La serie temporal del EVI (*Enhanced Vegetation Index*) mostró un patrón estacional constante, sin marcadas desviaciones de la media ni largos períodos de anomalías negativas significativas. El CV interanual fue relativamente bajo, lo que indicaría que no existen diferencias pronunciadas en el EVI a lo largo de los años durante el período estudiado. Tampoco se observó un aumento en la variabilidad intraanual, ya que el CV se mantuvo relativamente bajo y constante. Xulu y colaboradores (2018) estudiaron la influencia de las sequías en plantaciones forestales en una región subtropical de Sudáfrica, encontrando que el NDVI varió entre 0,74 y 0,78 en condiciones climáticas normales, y que disminuyó a 0,64 en un período de condiciones climáticas más secas. Cambios de dicha magnitud no se observaron en la serie temporal del EVI para el PNI, donde el valor varió entre 0,48 y 0,52 aproximadamente para todo el período estudiado.

No se obtuvo una relación significativa entre el EVI y el PDSI, lo que sugiere que la tasa fotosintética del dosel de la vegetación no se vió afectada por las sequías durante el período estudiado. Díaz Villa y colaboradores (2022b) estudiaron la relación entre el EVI y variables climáticas en los bosques nativos de Misiones mediante sensoramiento remoto, encontrando que las variaciones en este índice de vegetación respondieron a una combinación

de temperatura y evapotranspiración potencial, mientras que las precipitaciones no parecen influir. Estos hallazgos remarcan la resistencia de la vegetación del dosel del PNI frente a la variación en el aporte de agua por parte de las precipitaciones.

Los índices espectrales de agua NDWI (*Normalized Difference Water Index*), NMDI (*Normalized Multi-band Drought Index*), NDII6 (*Normalized Difference Infrared Index-band 6*) y NDII7 (*Normalized Difference Infrared Index-band 7*), también mostraron un patrón estacional constante, sin importantes desviaciones de la media ni prolongados períodos de anomalías negativas significativas. A partir del 2017 hasta el 2021 aproximadamente, se observó una disminución en los valores mínimos de todos los índices de agua, lo que podría estar relacionado con el último período de sequía, ya que valores más bajos de estos índices indican un menor contenido de agua en la vegetación. Además, dado que los mínimos se registraron entre los meses de julio y septiembre/octubre, es posible que el impacto de la sequía en el contenido de agua de la vegetación sea más marcado en esta época debido a un menor aporte estacional de precipitaciones.

La relación entre el NDII6 y el PDSI no fue significativa, mientras que sí se observó una relación significativa entre el PDSI y los índices NDWI, NMDI y NDII7. Sin embargo, la magnitud de estas relaciones fue baja: la pendiente de la relación entre el PDSI y el NDII7 es un orden de magnitud menor que los valores que toma el NDII7; entre el PDSI y el NDWI sucede lo mismo, y entre el PDSI y el NMDI, la pendiente es dos órdenes de magnitud menor que los valores del NMDI. Además, los valores del R^2 de los modelos ajustados para cada índice son notablemente bajos (Anexo 7), lo que indica que la variabilidad en los índices explicada por el PDSI es muy limitada.

El NDWI fue el único de los índices que tuvo un CV interanual relativamente alto, y cuyo CV intraanual también varió a lo largo de los años, mientras que el de los demás índices se mantuvo constante. Esto podría deberse a diferencias en las bandas del espectro electromagnético que se utilizan para calcular los índices de agua. El NDWI utiliza la banda 5 (1230-1250 nm), mientras que el NDII6 utiliza la banda 6 (1628-1652 nm), el NDII7 la banda 7 (2105–2155 nm) y el NMDI combina las bandas 6 y 7. Trabajos previos encontraron que la reflectancia en la región del espectro comprendida entre 1500 y 2500 nm satura cuando el

índice de área foliar (IAF) es mayor a 4 y 5 (Lillesaeter, 1982; Wang & Qu, 2007). Cristiano y colaboradores (2015) realizaron mediciones del IAF en los bosques nativos del PNI, encontrando que los datos tomados a campo variaron entre 4 y 7,5, siendo más bajos en julio que en marzo, probablemente por la caída de las hojas de las especies deciduas. Además encontraron que la media de IAF estimada satelitalmente fue de 5,59. Estos resultados podrían explicar por qué los índices NDII6, NDII7 y NMDI no reflejaron variabilidad a lo largo del período estudiado, y que no serían adecuados para evaluar los cambios en el contenido de agua en la vegetación y la humedad del suelo en el PNI.

Caccamo y colaboradores (2011) evaluaron el potencial de los índices EVI, NDWI, NDII6 y NDII7 para detectar la sequía en ecosistemas con alta biomasa, encontrando que los índices que utilizan bandas del SWIR, como el NDII6 y el NDII7, mostraron un mejor desempeño en la detección de la sequía. En este trabajo, se observó que el índice NDII7 fue el que obtuvo una mayor relación con el PDSI. Sin embargo, ninguno de los índices de agua se destacó por reflejar cambios en la vegetación asociados a condiciones de estrés hídrico, lo que implicaría que la vegetación del dosel mantuvo un estado saludable.

Los índices espectrales de sequía VCI (*Vegetation Condition Index*), TCI (*Temperature Condition Index*) y VHI (*Vegetation Health Index*) también mostraron un patrón estacional constante, sin desviaciones importantes respecto a la media ni períodos prolongados de anomalías negativas significativas. Se observó una disminución en los valores mínimos para los tres índices hacia el final del período estudiado, donde tanto el VCI como el VHI alcanzaron valores correspondientes a una sequía moderada en las mismas fechas, mientras que el TCI mostró valores asociados a una sequía severa.

Zou y colaboradores (2020) evaluaron el uso de estos índices en bosques tropicales secos con alta estacionalidad en Costa Rica, encontrando que los tres índices pudieron reflejar eficazmente el déficit hídrico durante la temporada de pocas lluvias, y de manera moderada en temporada de muchas lluvias. Sin embargo, los resultados obtenidos para el PNI difieren parcialmente de lo observado por estos autores. Para el período estudiado en el PNI, se observó que el TCI presentó valores asociados a una sequía moderada de forma repetida durante toda la serie temporal, debido a que sus valores mínimos normales coinciden con los

valores de esta clasificación. Dado que el TCI se basa en datos de la temperatura superficial, es importante considerar el rango térmico para el cual fue desarrollado. En el contexto climático del PNI, sus valores mínimos coinciden habitualmente con los meses más cálidos del año, lo que conduce a clasificar sistemáticamente como sequía moderada situaciones que en realidad corresponden al comportamiento estacional normal. Por lo tanto, la escala de categorías de sequía asociada al TCI podría no ser adecuada para esta región, ya que tiende a identificar sequías todos los veranos sin que exista necesariamente una anomalía hídrica real. De manera similar, el VHI presentó valores asociados a la categoría de sequía leve de forma recurrente a lo largo de la serie temporal. Esto podría deberse a que el índice se calcula a partir de la combinación del VCI y el TCI en proporciones iguales, por lo que las limitaciones observadas se trasladan al VHI.

Por otro lado, Seiler y colaboradores (1998) utilizaron el TCI y el VCI para evaluar las condiciones de sequía en la provincia de Córdoba, encontrando una estrecha relación entre estos índices con los patrones de precipitación. En este trabajo se encontró una relación significativa entre el PDSI y los índices VCI y VHI. Sin embargo, al igual que con los índices de agua, la magnitud de esta relación fue muy baja, mostrando una diferencia de un orden de magnitud entre las pendientes y los valores que toman el VCI y el VHI. Los valores del R^2 de los modelos ajustados para cada índice también resultaron bajos (Anexo 7), lo que indica que la variabilidad en los índices explicada por el PDSI es muy limitada. La relación entre el TCI y el PDSI no pudo ser evaluada, ya que el modelo no cumplió con el supuesto de independencia de las observaciones.

Nuestros resultados sugieren que, durante el período analizado, aunque se observó una relación entre la sequía y la cantidad de agua en la vegetación, la tasa fotosintética del dosel no se vio afectada. Una posible explicación es que los cambios en el contenido de agua no hayan sido lo suficientemente relevantes como para alterar el proceso de fotosíntesis, lo que permitió que la actividad fotosintética de la vegetación se mantuviera estable. Otra posible explicación es que la metodología utilizada en este trabajo no haya sido la adecuada para detectar cambios en los procesos de toda la vegetación de este ecosistema.

El ecosistema de los bosques húmedos del PNI posee una estructura compleja, compuesta por múltiples capas de vegetación, que incluyen plantas de diferentes tipos funcionales, como leñosas, lianas, cañas, helechos, epífitas y hemiepífitas, entre otras. Esta diversidad estructural y funcional implica que cada tipo de planta responde al estrés hídrico de manera distinta, tanto en intensidad como en el tiempo de respuesta (Mitchell et al., 2008). Por ejemplo, los árboles más altos, gracias a sus sistemas radiculares profundos, pueden acceder tanto a fuentes de agua subterránea relativamente superficiales, como a aquellas de mayor profundidad. En cambio, para las plantas del sotobosque, con raíces menos profundas, el acceso a reservas de agua subterráneas es limitado y dependen en mayor medida de las precipitaciones como fuente de agua. En períodos de sequía prolongada, el suelo tiende a perder humedad progresivamente, desde la superficie hacia las capas más profundas. Esto significa que las plantas con raíces más profundas tendrían la ventaja de acceder a la humedad del suelo durante un período más largo en comparación con las plantas del sotobosque, que se verían afectadas por la escasez de agua de manera más inmediata.

Durante temporadas de sequía, las plantas son capaces de redistribuir el agua almacenada en capas subterráneas profundas hacia capas superficiales secas, a través de sus raíces (Scholz et al., 2002). Este fenómeno, conocido como redistribución hidráulica, se ha observado en árboles del Amazonas, donde contribuye significativamente al aumento de la fotosíntesis y la evapotranspiración en períodos de sequía (Lambers et al., 2008). Por lo tanto, en épocas de menor precipitación, también podría suceder que las plantas de mayor altura del PNI estén suministrando agua de fuentes subterráneas a las plantas con raíces más superficiales. A su vez, la gran diversidad de especies estabiliza los procesos ecosistémicos frente a variaciones ambientales anuales, y ofrece un seguro contra cambios drásticos en la estructura o procesos del ecosistema en respuesta a eventos extremos (Chapin et al., 2002). En un estudio sobre pastizales templados, por ejemplo, una sequía extrema eliminó o redujo el crecimiento de numerosas especies de plantas; sin embargo, la productividad fue menos afectada en las parcelas con mayor diversidad de especies (Tilman & Downing, 1994).

La explicación relacionada con las limitaciones metodológicas utilizadas radica en que, al utilizar sensores remotos para monitorear el estado de la vegetación, la información

obtenida corresponde al dosel, es decir, la capa superior del bosque. Esto resulta en una respuesta integrada de toda la vegetación (o principalmente de las plantas de mayor altura) que enmascara los efectos diferenciados de la sequía sobre cada tipo funcional específico, lo que hace más difícil detectar cómo responde individualmente cada grupo de plantas a la falta de agua (Lu, 2006). Como se mencionó previamente, los árboles que forman parte del dosel pueden acceder más fácilmente a las fuentes de agua alternativas durante períodos de sequía, lo que les permite mantener su suministro hídrico por más tiempo. Esta diferencia en el acceso al agua subterránea entre los distintos estratos vegetales genera variabilidad en las respuestas al estrés hídrico. Cristiano y colaboradores (2020) midieron el porcentaje de cobertura del sotobosque en parcelas del PNI, encontrando un 83,7% de cobertura en un año húmedo (2017). En cambio, Paronetto (2024) observó que, en un año seco (2023), la cobertura del sotobosque del mismo sitio fue del 59%. Estos resultados sugieren que las variaciones en la estructura del sotobosque pueden ser difíciles de detectar mediante la información proporcionada por los sensores remotos, que se centra en el dosel.

Además, el método de análisis utilizado, basado en un promedio de los índices de vegetación para todo el PNI, ofrece una visión general del comportamiento del ecosistema frente al estrés hídrico. Sin embargo, este enfoque puede haber limitado la obtención de resultados, ya que no se consideró la variabilidad espacial ni las diferencias estructurales del parque, como la pendiente del terreno, la presencia de microhábitats y las zonas con distintos grados de conservación. Estas variaciones dentro del PNI pueden influir en la respuesta de la vegetación al estrés hídrico y en la capacidad de las distintas áreas del parque para acceder a diferentes fuentes de agua.

Considerando estas limitaciones, sería útil incorporar un análisis espacial que permita comprender mejor las dinámicas y ofrecer una perspectiva más detallada sobre la respuesta al estrés hídrico en todo el parque. Además, combinar los datos de sensores remotos con mediciones de campo podría proporcionar una visión más precisa de cómo responde el ecosistema a la sequía, teniendo en cuenta las particularidades de cada tipo funcional de planta.

6. CONCLUSIONES

En este trabajo se planteó la hipótesis de que los índices de vegetación provenientes del sensor remoto MODIS son capaces de detectar condiciones de estrés hídrico en la vegetación, y que por lo tanto existe una correlación significativa entre los índices de vegetación con el índice climático de sequía PDSI en los bosques nativos del Parque Nacional Iguazú en el norte de Misiones. El análisis de esta relación para el período 2001-2023 mostró distintos resultados para los índices de vegetación: el EVI y el NDII6 no mostraron una relación significativa con el PDSI, mientras que los índices NDWI, NMDI, NDII7, VCI y VHI sí presentaron una relación significativa, aunque de baja magnitud, con un efecto de retraso de hasta dos meses (NDWI, VCI), tres meses (NMDI, NDII7) y cuatro meses (VHI) atrás. Resultados previos en el área de estudio muestran que la estructura del sotobosque se vió afectada con los años, en coincidencia con eventos de sequía, e incluso se llegaron a producir numerosos incendios en estos años secos. A pesar de ello, los resultados de este trabajo permiten suponer que, si bien existe una relación entre el contenido de agua en la vegetación y las condiciones climáticas de sequía, esta relación no sería lo suficientemente fuerte como para impactar de forma significativa la funcionalidad de la vegetación del dosel del PNI, manteniendo el proceso de fotosíntesis estable.

7. ANEXO

Anexo 1: Descripción de los índices de vegetación utilizados.

Índice de vegetación	Rango de valores	Descripción	Referencias
EVI (Enhanced Vegetation Index)	-1 a 1	Contenido de clorofila en las hojas y biomasa. Correlaciona positivamente con la productividad.	Huete et al. (2002)
VCI (Vegetation Condition Index)	0 a 100	Contenido de humedad en la vegetación en relación con sus condiciones históricas (relativo al valor mínimo y máximo del NDVI del período). Valores altos indican condiciones de humedad favorables, mientras que valores bajos reflejan falta de humedad.	Kogan (1994)
TCI (Temperature Condition Index)	0 a 100	Estrés térmico de la vegetación en relación con sus condiciones históricas. Valores altos indican condiciones térmicas favorables para la vegetación, mientras que valores bajos reflejan un mayor estrés térmico.	Kogan (1994, 1997)
VHI (Vegetation Health Index)	0 a 100	Salud de la vegetación, considerando tanto la humedad de la vegetación como el estrés térmico (combina el VCI y el TCI). Valores altos indican una vegetación saludable, mientras que valores bajos una vegetación bajo estrés.	Kogan (1994, 1997)
NMDI (Normalized Multiband Drought Index)	-1 a 1	Correlaciona positivamente con el contenido de agua en la vegetación y la humedad del suelo.	Wang & Qu (2007), Wang et al. (2008)
NDWI (Normalized Difference Water Index)	-1 a 1	Correlaciona positivamente con el contenido de agua en la vegetación.	Gao (1996)
NDII6 (Normalized Difference Infrared Index-band 6)			Caccamo et al. (2011)
NDII7 (Normalized Difference Infrared Index-band 7)			Caccamo et al. (2011)

Anexo 2: Gráfico de correlación entre los datos de precipitación acumulada obtenidos a partir del producto Terra Climate y los obtenidos del Servicio Meteorológico Nacional (SMN). La línea representa la regresión lineal ($y = 0,83x$; $R^2 = 0,899$).

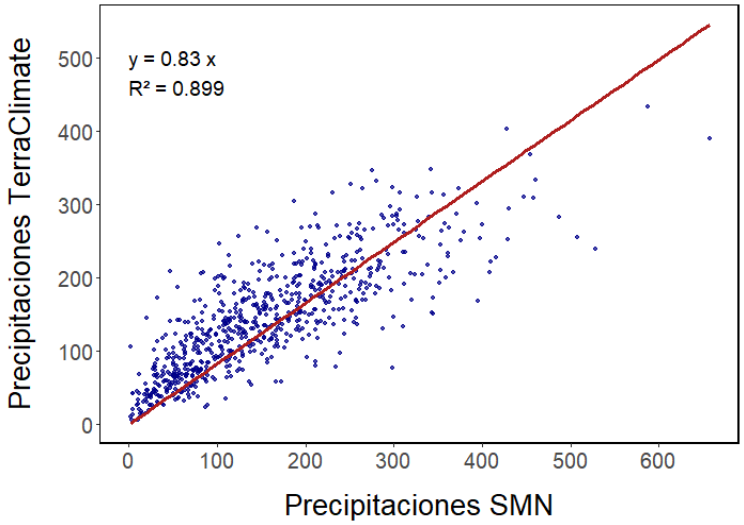

Anexo 3: Gráficos de la función de autocorrelación (ACF) para las variables climáticas (precipitación acumulada, déficit de presión de vapor o VPD), el índice de sequía de Palmer (PDSI) y los índices de vegetación (EVI, VCI, TCI, VHI NDWI, NMDI, NDII6, NDII7). Las líneas punteadas representan los límites de significancia estadística (p-valor < 0,05).

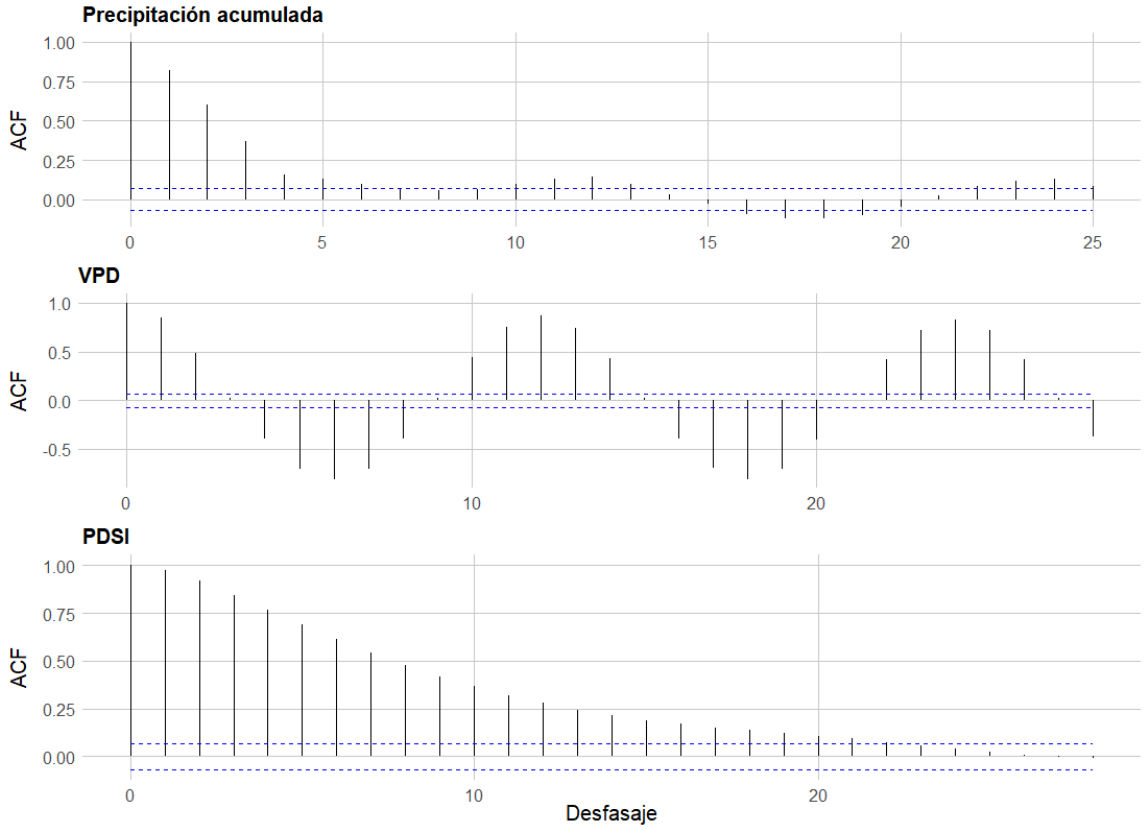

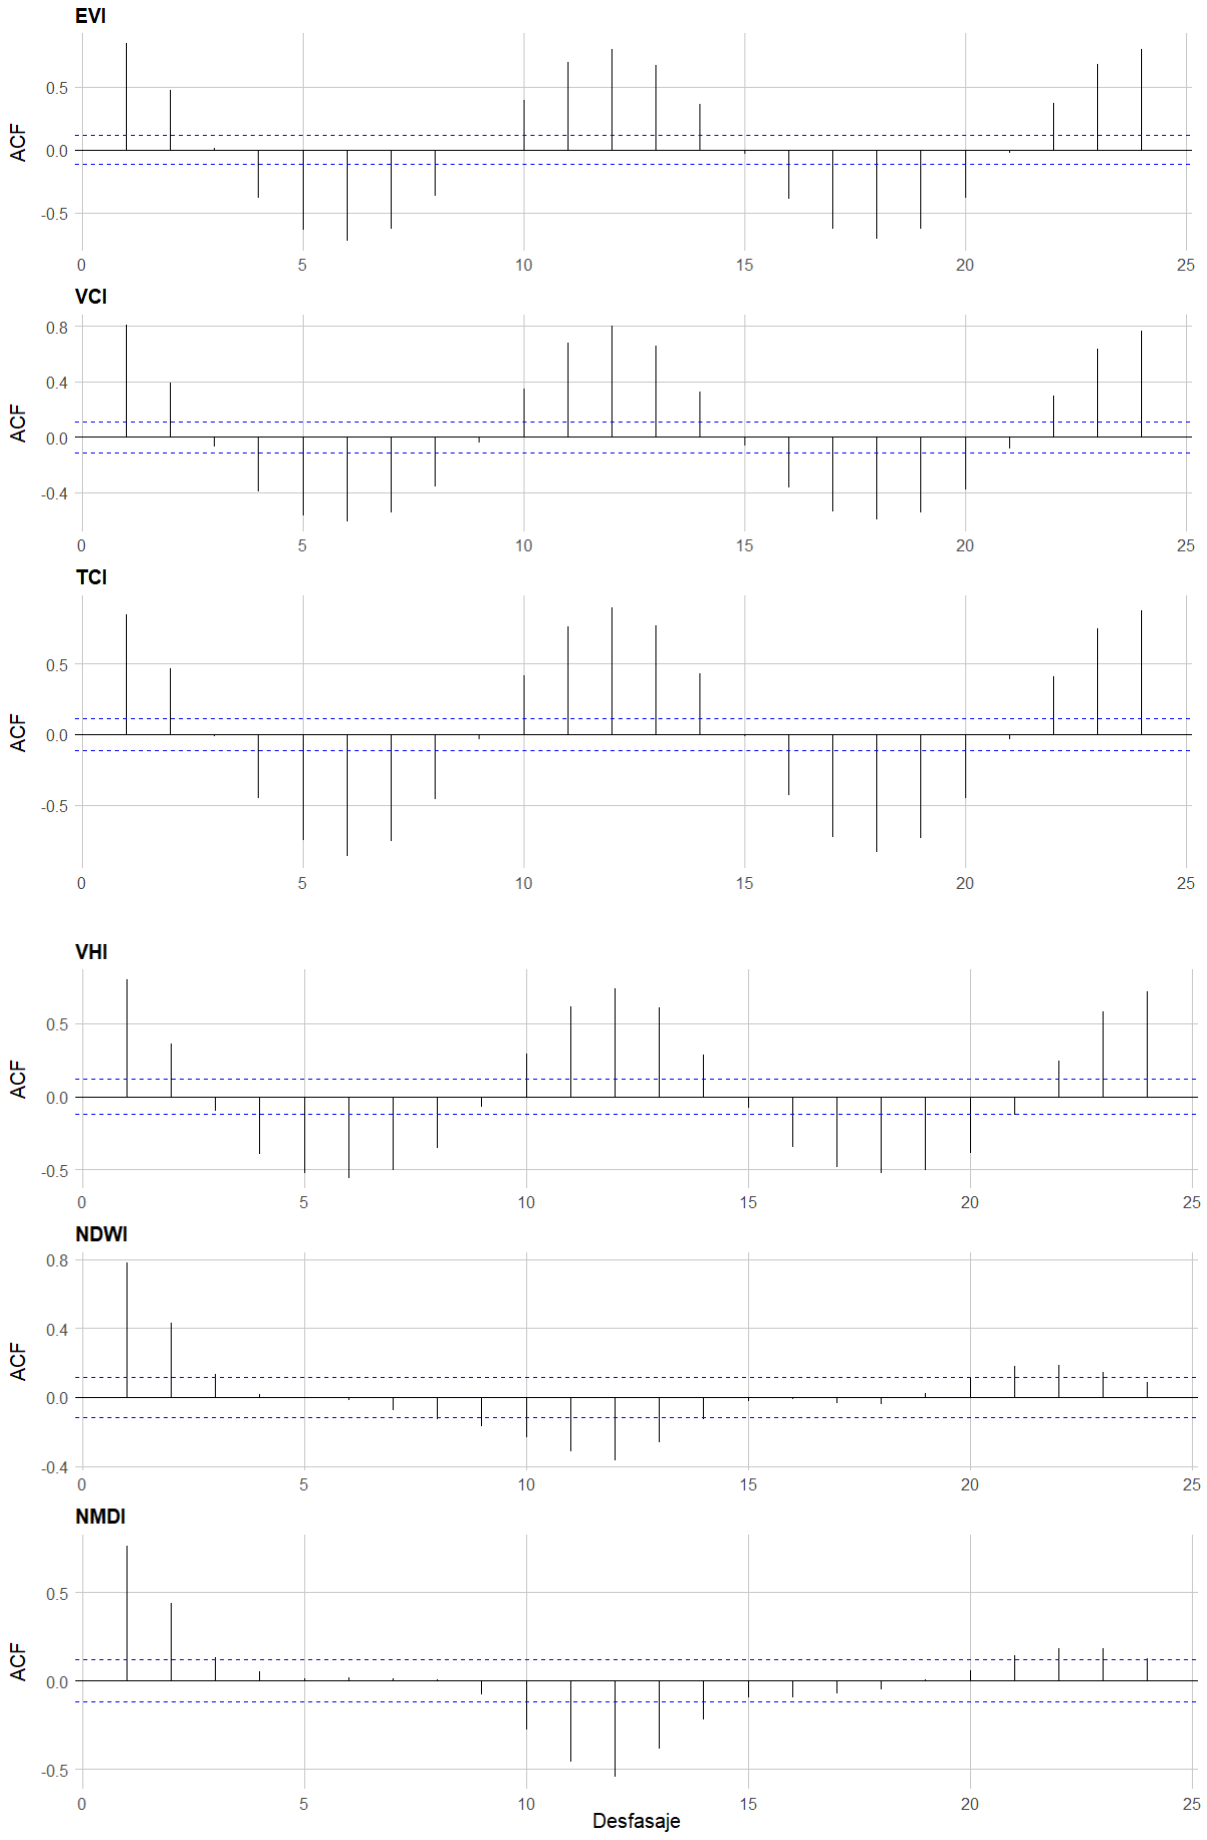
EVI
VCI
TCI
VHI
NDWI
NMDI
ACF
Desfasaje

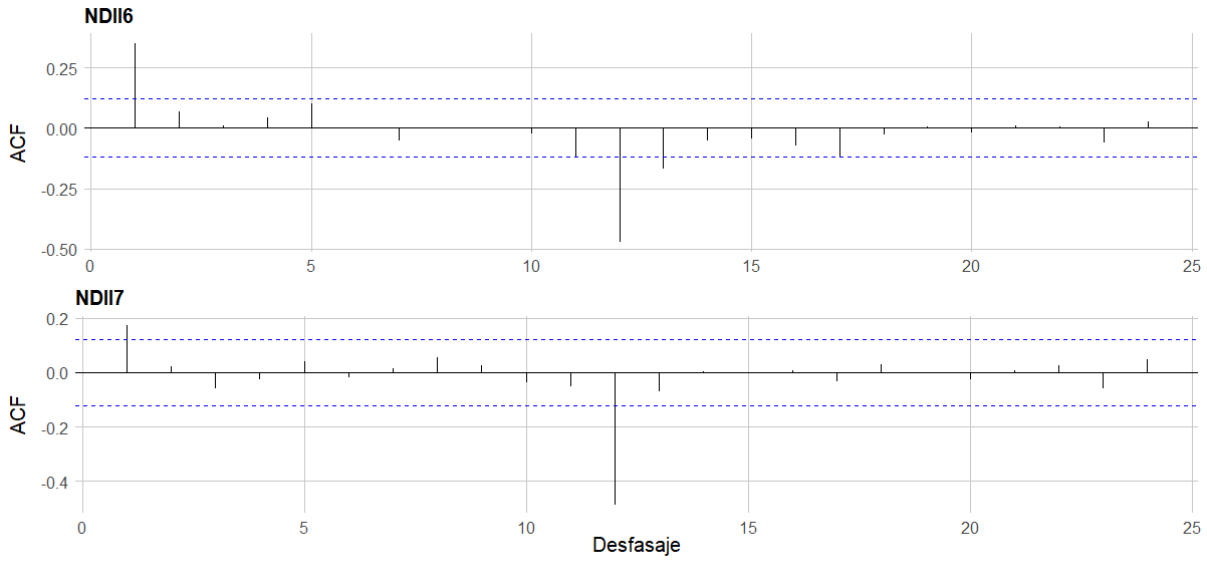

Anexo 4: Gráficos de la función de autocorrelación parcial (PACF) para las variables climáticas (precipitación acumulada, déficit de presión de vapor o VPD), el índice de sequía de Palmer (PDSI) y los índices de vegetación (EVI, VCI, TCI, VHI NDWI, NMDI, NDII6, NDII7). Las líneas punteadas representan los límites de significancia estadística (p-valor < 0,05).

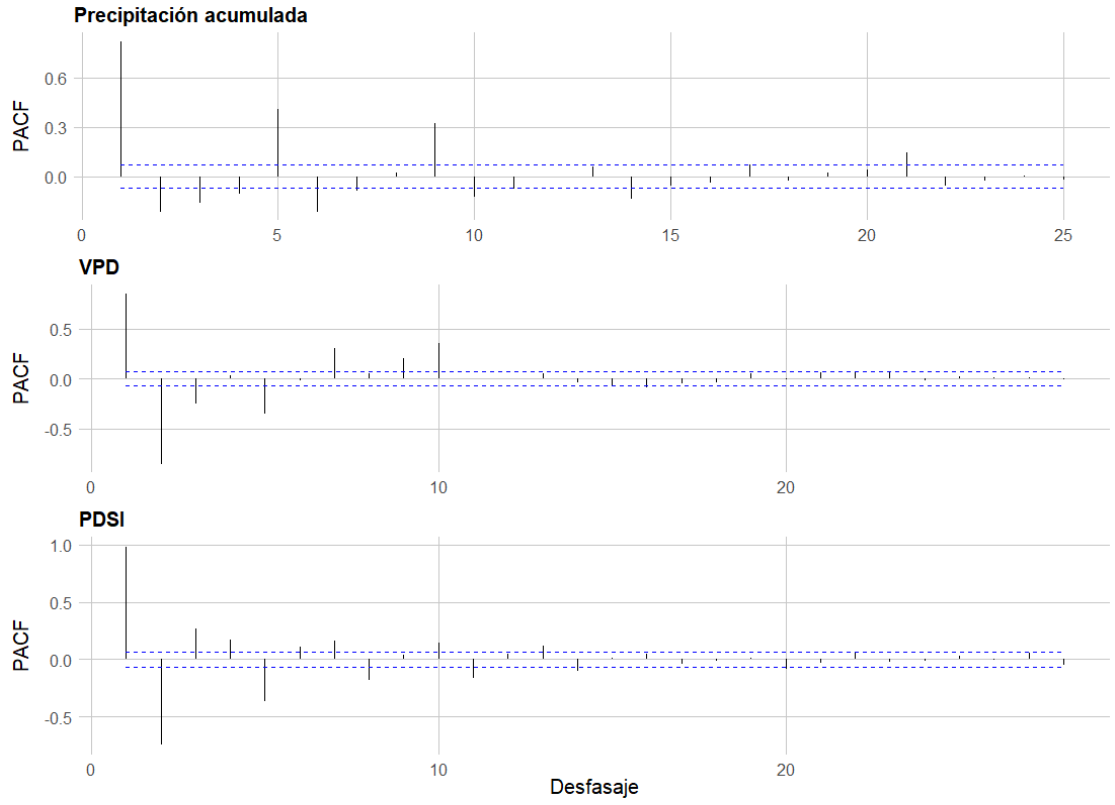

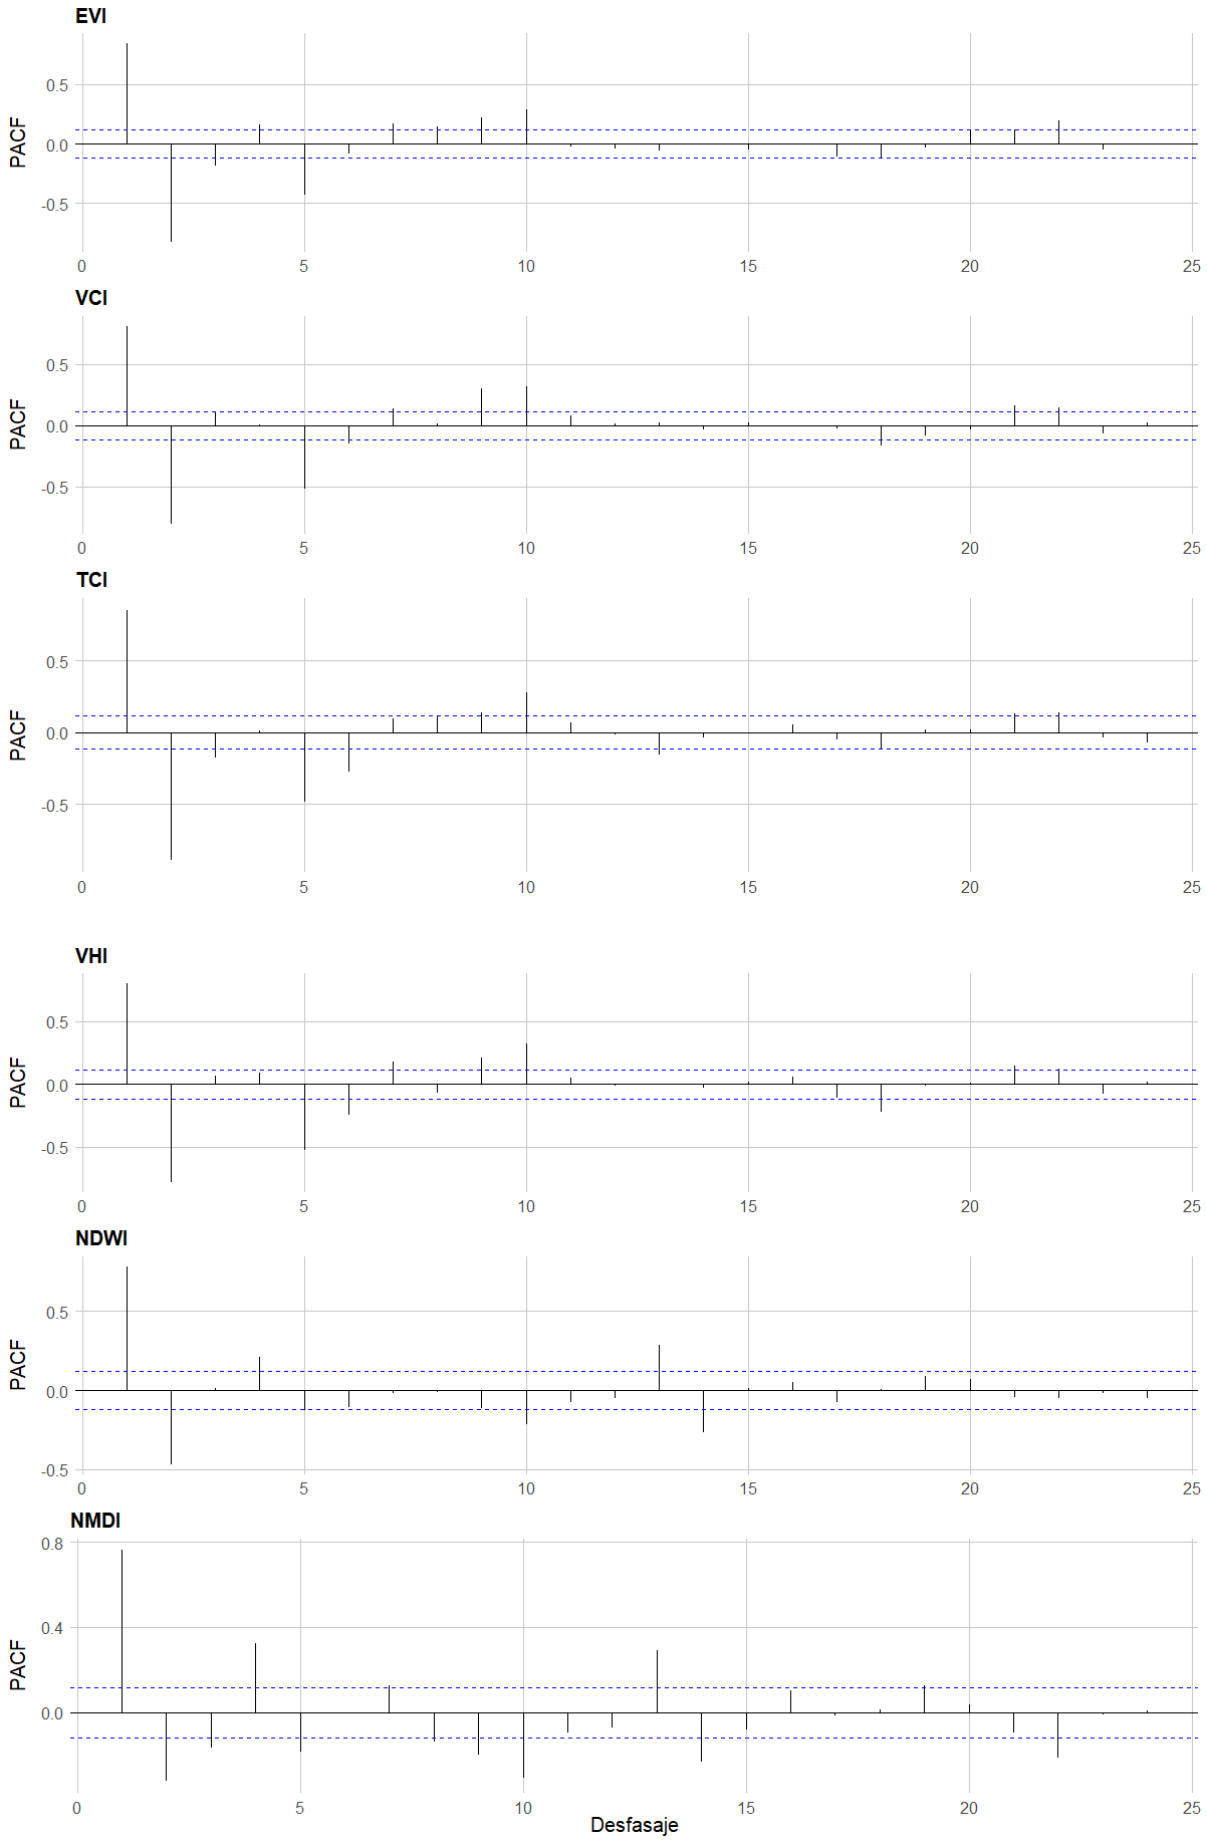
EVI
VCI
TCI
VHI
NDWI
NMDI
PACF
Desfasaje

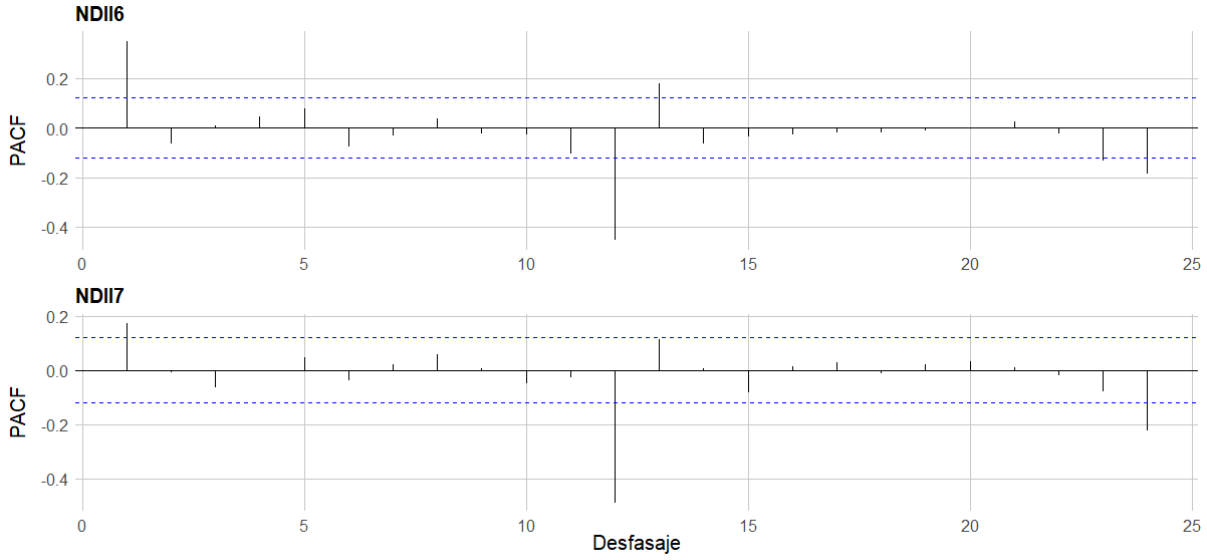

Anexo 5: Resultados de las pruebas de estacionariedad de Phillips-Perron (PP) y de Kwiatkowski, Phillips, Schmidt y Shin (KPSS) para los distintos índices de vegetación y el índice de sequía de Palmer (PDSI).

Variables	Estadístico PP-Test	p-valor	Estadístico KPSS-Test	p-valor
PDSI	-5.00	0.01	0.239	>0.1
EVI	-6.48	0.01	0.233	>0.1
NDWI	-6.23	0.01	0.523	0.0365
NMDI	-6.39	0.01	0.477	0.0469
TCI	-6.76	0.01	0.0197	>0.1
VCI	-6.58	0.01	0.292	>0.1
VHI	-6.36	0.01	0.116	>0.1
NDII6	-6.95	0.01	0.752	0.01
NDII7	-8.36	0.01	0.863	0.01

Anexo 6: Resultados de las pruebas de estacionariedad de Phillips-Perron (PP) y de Kwiatkowski, Phillips, Schmidt y Shin (KPSS) luego de la diferenciación estacional para los distintos índices de vegetación.

Variables	Estadístico PP-Test	p-valor	Estadístico KPSS-Test	p-valor
NDWI	-5.85	0.01	0.0678	>0.1
NMDI	-6.33	0.01	0.0444	>0.1
NDII6	-11.2	0.01	0.0475	>0.1
NDII7	-13.5	0.01	0.0609	>0.1

Anexo 7: Resultados de la estimación de los parámetros de los modelos de retardos distribuidos (DLM) para los distintos índices de vegetación. Los asteriscos indican el nivel de significancia estadística de los coeficientes (***: p-valor < 0.001; **: p-valor < 0.01; *: p-valor < 0.05). El subíndice "res" se refiere a los residuos del modelo autorregresivo de cada índice, y el subíndice "t" indica el desfasaje en meses del PDSI.

VR	Parámetro	Coeficiente estimado	Error estándar	t-valor	p-valor	R^2
EVI_{res}	Constante	0.00007919	0.0005876	0.135	0.893	0.007272
	$PDSI_t$	0.0002655	0.0001847	1.437	0.152	
$NDWI_{res}$	Constante	-0.0000507	0.000297	-0.171	0.865	0.04928
	$PDSI_t$	0.00125	0.000431	2.909	0.003928**	
	$PDSI_{t-1}$	-0.00143	0.000430	-3.336	0.000972***	
$NMDI_{res}$	Constante	0.000001291	0.0003738	0.003	0.99725	0.07595
	$PDSI_t$	0.003273	0.0008116	4.033	0.000072***	
	$PDSI_{t-1}$	-0.006074	0.001488	-4.082	0.000059***	
	$PDSI_{t-2}$	0.002669	0.0008143	3.277	0.00119**	
TCI_{res}	Constante	0.02021	0.17540	0.115	0.90837	0.05351
	$PDSI_t$	1.50432	0.45884	3.278	0.00118**	
	$PDSI_{t-1}$	-2.73481	1.03697	-2.637	0.00884**	
	$PDSI_{t-2}$	0.80930	1.13944	0.710	0.47815	
	$PDSI_{t-3}$	1.92724	1.04060	1.852	0.06511	
	$PDSI_{t-4}$	-2.45308	1.13929	-2.153	0.03219*	
	$PDSI_{t-5}$	1.47468	1.03804	1.421	0.15657	
	$PDSI_{t-6}$	-0.42039	0.46060	-0.913	0.36221	
VCI_{res}	Constante	0.04431	0.22045	0.201	0.840837	0.05711
	$PDSI_t$	2.01892	0.52148	3.871	0.000135***	
	$PDSI_{t-1}$	-3.33048	1.10271	-3.020	0.002764**	
	$PDSI_{t-2}$	0.98881	1.23240	0.802	0.423050	
	$PDSI_{t-3}$	0.91873	1.12099	0.820	0.413172	
	$PDSI_{t-4}$	-0.52460	0.53083	-0-988	0.323890	
VHI_{res}	Constante	0.05273	0.15184	0.347	0.72868	0.08578
	$PDSI_t$	1.63491	0.38786	4.215	0.0000344***	
	$PDSI_{t-1}$	-2.54477	0.87051	-2.923	0.00377**	

	$PDSI_{t-2}$	0.16819	0.96402	0.174	0.86164	
	$PDSI_{t-3}$	2.41216	0.90531	2.664	0.00819**	
	$PDSI_{t-4}$	-2.35459	0.98551	-2.389	0.01760*	
	$PDSI_{t-5}$	0.79181	0.89453	0.885	0.37688	
	$PDSI_{t-6}$	0.01246	0.39745	0.031	0.97502	
$NDII6_{res}$	Constante	-0.0001837	0.0013053	-0.141	0.8882	0.01523
	$PDSI_t$	-0.0021485	0.0028047	-0.766	0.4444	
	$PDSI_{t-1}$	0.0070159	0.0051363	1.366	0.1732	
	$PDSI_{t-2}$	-0.0050878	0.0028183	-1.805	0.0722	
$NDII7_{res}$	Constante	-0.00001971	0.002078	-0.009	0.99244	0.03828
	$PDSI_t$	-0.01116	0.004464	-2.501	0.01300*	
	$PDSI_{t-1}$	0.02426	0.008175	2.967	0.00329**	
	$PDSI_{t-2}$	-0.01280	0.004486	-2.854	0.00467**	

Anexo 8: Gráficos de residuos vs valores predichos del modelo de retardos distribuidos (DLM) de los distintos índices de vegetación.

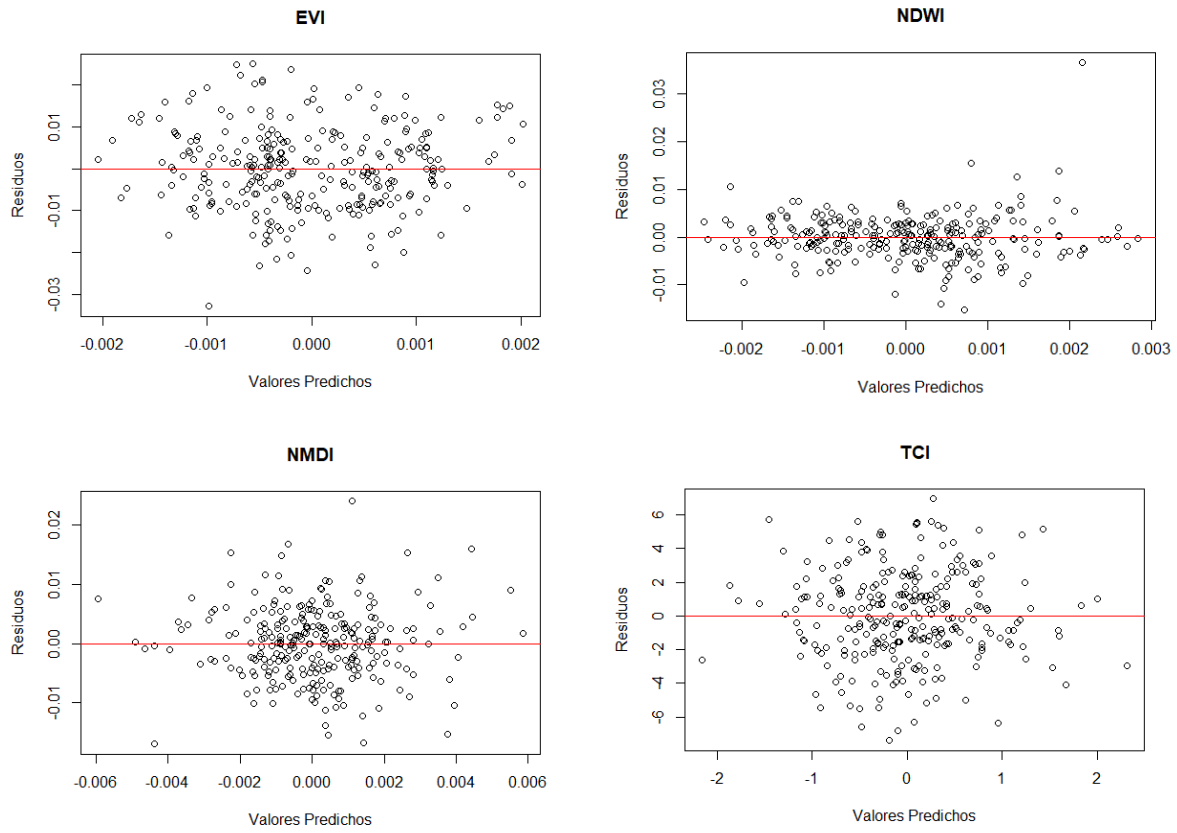

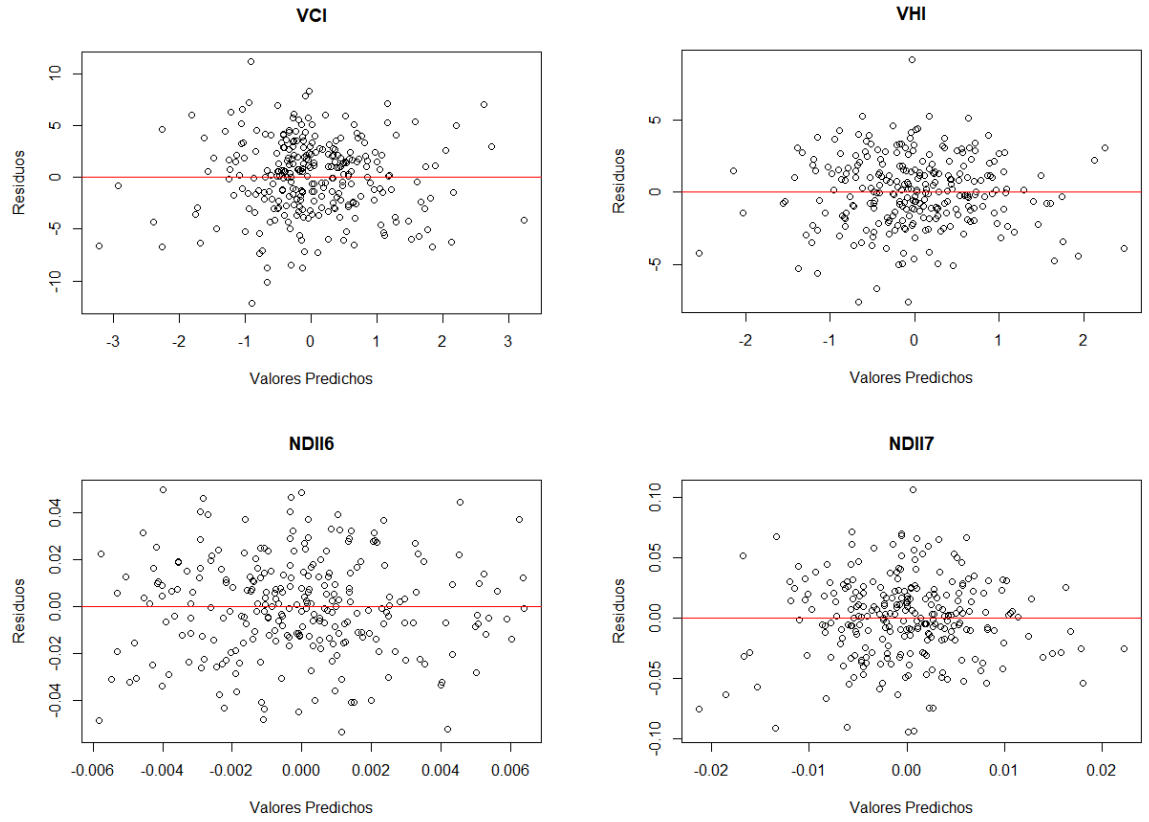

Anexo 9: Gráficos Q-Q Plot del modelo de retardos distribuidos (DLM) de los distintos índices de vegetación.

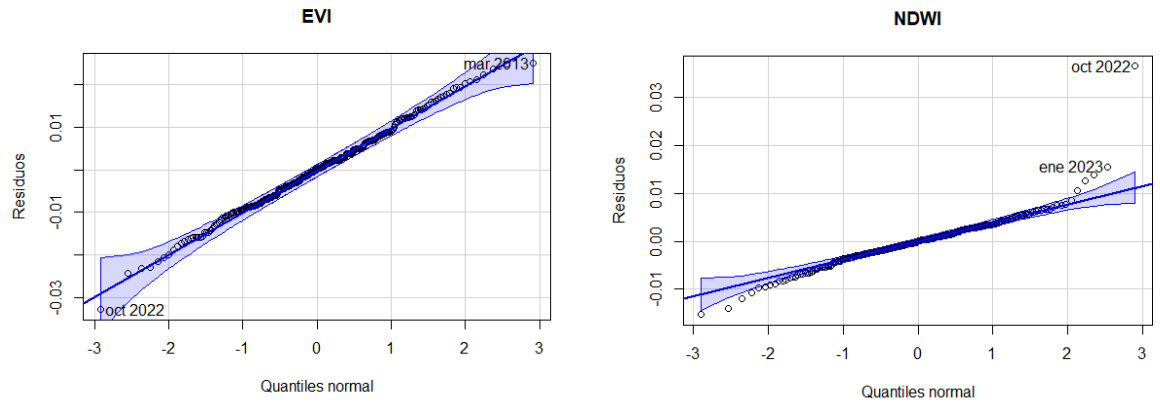

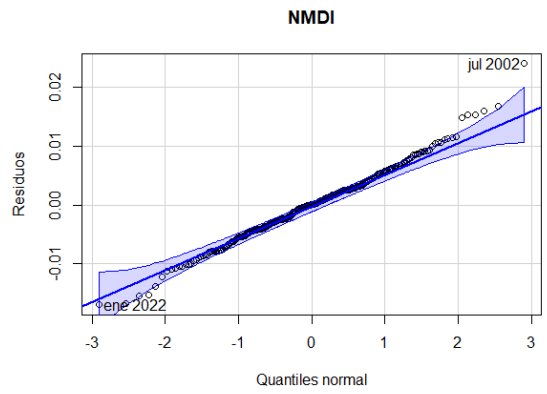
NMDI
jul 2002
ene 2022
Residuos
Quantiles normal

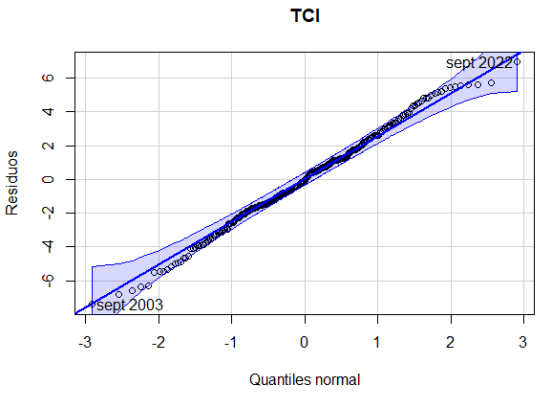
TCI
sept 2022
sept 2003
Residuos
Quantiles normal

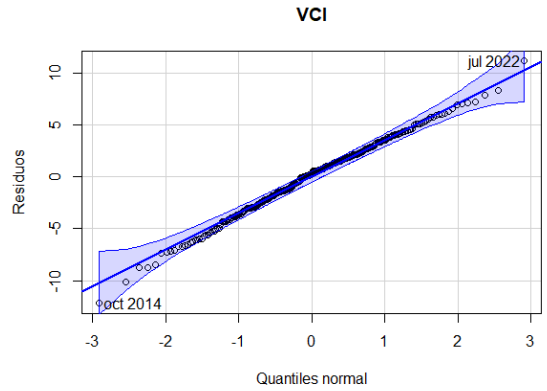
VCI
jul 2022
oct 2014
Residuos
Quantiles normal

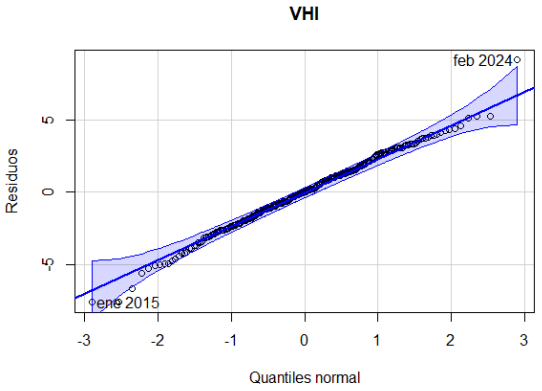
VHI
feb 2024
ene 2015
Residuos
Quantiles normal

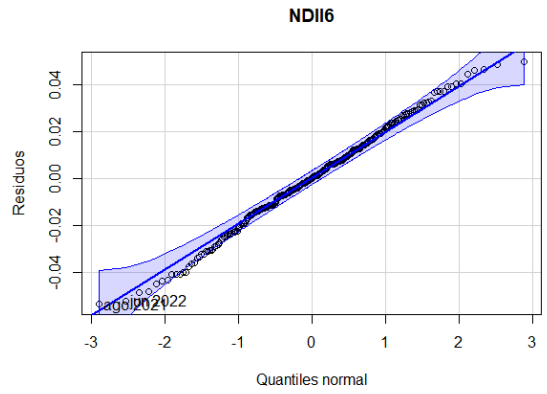
NDII6
ago 2021
ago 2022
Residuos
Quantiles normal

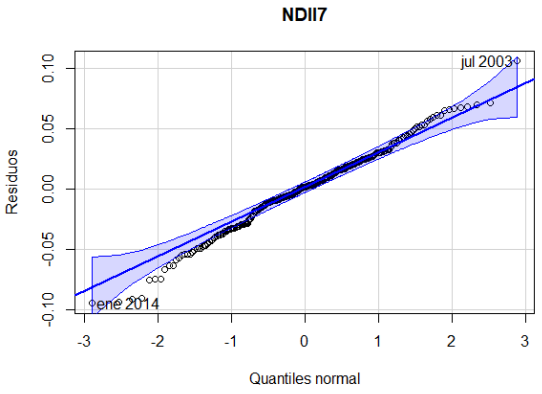
NDII7
jul 2003
ene 2014
Residuos
Quantiles normal

Anexo 10: Resultados de la prueba de Box-Ljung para evaluar la autocorrelación de los residuos del modelo de retardos distribuidos (DLM) de los distintos índices de vegetación.

VR	Estadístico	p-valor
EVI_{res}	11.603	0.9291
$NDWI_{res}$	13.614	0.8495
$NMDI_{res}$	28.797	0.09184
TCI_{res}	40.946	0.003785
VCI_{res}	31.014	0.05501
VHI_{res}	24.547	0.2193
$NDII6_{res}$	10.617	0.9556
$NDII7_{res}$	9.7857	0.9719

8. REFERENCIAS BIBLIOGRÁFICAS

Abatzoglou, J.T., S.Z. Dobrowski, S.A. Parks, K.C. Hegewisch, 2018, Terraclimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958-2015, *Scientific Data* 5:170191.

Alonso, C., Moreno, V., & Rodríguez, E. (1999). Determinación experimental de la firma espectral de la vegetación: Una sencilla práctica de introducción a la teledetección. En TELEDETECCIÓN: Avances y aplicaciones. VIII Congreso Nacional de Teledetección (pp. 429-443). Albacete, España.

Ámbito. (2021, diciembre 30). Situación crítica por los incendios forestales en Misiones. Recuperado el 23 de octubre del 2024 de https://www.ambito.com/misiones/situacion-critica-los-incendios-forestales-n5344388.

Aphalo P (2025). ggpmisc: Miscellaneous Extensions to 'ggplot2'. R package version 0.6.1.9002, https://docs.r4photobiology.info/ggpmisc/.

Balandier, P., Gobin, R., Prévosto, B., & Korboulewsky, N. (2022). The contribution of understorey vegetation to ecosystem evapotranspiration in boreal and temperate forests: a literature review and analysis. *European Journal of Forest Research*, 141(6), 979-997.

Barros et al. (2015). Cambio Climático en Argentina; tendencias y proyecciones. 3° Comunicación Nacional de la República Argentina a la Convención Marco de las Naciones Unidas sobre Cambio Climático. *Centro de Investigaciones del Mar y la Atmósfera*. Anexo II.

Beard, K. H., Vogt, K. A., Vogt, D. J., Scatena, F. N., Covich, A. P., Sigurdardottir, R., Siccama, T. G. & Crowl, T. A. (2005). Structural and functional responses of a subtropical forest to 10 years of hurricanes and droughts. *Ecological Monographs*, 75(3), 345-361.

Behmann, J., Steinrücken, J., & Plümer, L. (2014). Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 98-111.

Berri, G. J., Flamenco, E. A., Spescha, L., Tanco, R. A., & Hurtado, R. (2002). Some effects of La Nina on summer rainfall, water resources and crops in Argentina. La Nina and its Societal Impacts: Facts and Speculation.

Bruzzone & Easdale (2021) Archetypal temporal dynamics of arid and semi-arid rangelands. *Remote Sensing of Environment*, 254, 112279.

Bushra, N., Rohli, R. V., Lam, N. S., Zou, L., Mostafiz, R. B., & Mihunov, V. (2019). The relationship between the normalized difference vegetation index and drought indices in the South Central United States. *Natural Hazards*, 96, 791-808.

Caccamo, G., Chisholm, L. A., Bradstock, R. A., & Puotinen, M. L. (2011). Assessing the sensitivity of MODIS to monitor drought in high biomass ecosystems. *Remote Sensing of Environment*, 115(10), 2626-2639.

Camilloni. (2018). Argentina y el cambio climático. Asociación Argentina para el Progreso de las Ciencias. *Ciencia e Investigación*, 68, 5, 11-2018, 5-10.

Campanello, P. I., Hilgert, N. I., Pinazo, M., Barth, S., Di Bitetti, M., von Below, J., Arturi, M., Goya, J., Cockle, K., Giombini, M., Villagra, M., Cristiano, P., di Francescantonio, D., García, D., Trentini, C., Díaz Villa, V., Rodríguez, S., Medina, M., Ritter, L., Graciano, C., Crechi, E., Moretti, A. P., Olguín, F., Goldstein, G., & Fassola, H. (2021). Capítulo 6: Selvas en Misiones. En P. L. Peri, G. J. Martinez Pastur, & T. M. Schlichter (Eds.), Uso sostenible del bosque: Aportes desde la silvicultura argentina (pp. 223-227). Ministro de Ambiente y Desarrollo Sostenible de la Nación.

CIMA (Centro de Investigaciones del Mar y la Atmósfera). (2015). Cambios climáticos en la región húmeda. En Cambio climático en Argentina; tendencias y proyecciones (pp. 114-149).

Chang, C. T., Wang, H. C., & Huang, C. Y. (2018). Assessment of MODIS-derived indices (2001–2013) to drought across Taiwan's forests. *International journal of biometeorology*, 62, 809-822.

Chapin, F. S., Matson, P. A., & Mooney, H. A. (2002). Principles of Terrestrial Ecosystem Ecology. In *Springer eBooks*. https://doi.org/10.1007/b97397

Chuvieco, E. (1991). Principios Físicos de la Teledetección. En *Fundamentos de teledetección espacial* (3° ed.). Ediciones Rialp S.A.

Clarín. (2023, noviembre 13). Las Cataratas del Iguazú, sin turistas y con una sequía histórica. *Clarín*. Recuperado el 9 de noviembre del 2024 de https://www.clarin.com/sociedad/cataratas-iguazu-turistas-sequia-historica_0_MhLkOAycT.html

Codromaz de Rojas, A. E. (2000). The climatic impact of La Niña-related droughts in Entre Ríos (Argentina). *Drought Network News* (1994-2001), 15.

Covich, A. P., Crowl, T. A., & Scatena, F. N. (2003). Effects of extreme low flows on freshwater shrimps in a perennial tropical stream. *Freshwater Biology*, 48(7).

Cristiano, P. M., Madanes, N., Campanello, P. I., Di Francescantonio, D., Rodriguez, S. A., Zhang, J-Y., Oliva Carrasco, L. & Goldstein, G. (2014). High NDVI and Potential Canopy Photosynthesis of South American Subtropical Forests despite Seasonal Changes in Leaf Area Index and Air Temperature. *Forests*, 5(2): 287-308.

Cristiano, P. M., Campanello, P. I., Bucci, S. J., Rodriguez, S. A., Lezcano, O. A., Scholz, F. G., Madanes, N., Di Francescantonio, D., Oliva Carrasco, L., Zhang, Y-J. & Goldstein, G. (2015). Evapotranspiration of subtropical forests and tree plantations: A comparative analysis at different temporal and spatial scales. *Agricultural and Forest Meteorology*, 203, 96-106.

Cristiano, P. M., Diaz Villa, M. V. E., De Diego, M. S., Lacoretz, M. V., Madanes, N., & Goldstein, G. (2020). Carbon assimilation, water consumption and water use efficiency under different land use types in subtropical ecosystems: from native forests to pine plantations. *Agricultural and Forest Meteorology*, 291, 108094.

DeJonge, K. C., Mefford, B. S., & Chávez, J. L. (2016). Assessing corn water stress using spectral reflectance. *International Journal of Remote Sensing*, 37(10), 2294-2312.

Díaz Villa, M. V. E., Cristiano, P. M., De Diego, M. S., Rodríguez, S. A., Bucci, S. J., Scholz, F., & Goldstein, G. (2020). Primary productivity determinants of different land uses in humid subtropical ecosystems: from native forests to tree plantations. *Ecosystems*, 24, 489-501.

Díaz Villa, M. V. E., Cristiano, P. M., De Diego, M. S., Rodríguez, S. A., Efron, S. T., Bucci, S. J., Scholz, F. & Goldstein, G. (2022a). Do selective logging and pine plantations in humid subtropical forests affect aboveground primary productivity as well as carbon and nutrients transfer to soil?. *Forest Ecology and Management*, 503, 119736.

Díaz Villa, M. V. E., Bruzzone, O. A., Goldstein, G., & Cristiano, P. M. (2022b). Climatic determinants of photosynthetic activity in humid subtropical forests under different forestry activities. *Remote Sensing Applications: Society and Environment*, 26, 100735.

Didan, K. (2021). MODIS/Terra Vegetation Indices 16-Day L3 Global 500m SIN Grid V061 [Data set]. NASA EOSDIS Land Processes Distributed Active Archive Center. Accessed 2024-05-09 from https://doi.org/10.5067/MODIS/MOD13A1.061

Ewing, B. T., Riggs, K., & Ewing, K. L. (2007). Time series analysis of a predator–prey system: Application of VAR and generalized impulse response function. *Ecological Economics*, 60(3), 605-612.

Fei, X., Song, Q., Zhang, Y., Liu, Y., Sha, L., Yu, G., ... & Grace, J. (2018). Carbon exchanges and their responses to temperature and precipitation in forest ecosystems in Yunnan, Southwest China. *Science of the Total Environment*, 616, 824-840.

Ferrelli, F. (2016). Efectos de eventos El Niño y La Niña sobre las lagunas del sur de la Región Pampeana (Argentina).

Fu, R. (2015). Global warming-accelerated drying in the tropics. *Proceedings of the National Academy of Sciences*, 112(12), 3593-3594.

FVSA (Fundación Vida Silvestre Argentina) y WWF (Fondo Mundial para la Naturaleza). (2017). El Estado del Bosque Atlántico: tres países, 148 millones de personas, uno de los bosques más ricos del Planeta. Puerto Iguazú, Argentina. 5, 20-21.

Galindo-Leal, C. & Gusmão-Câmara, I. (2003). The Status of the Atlantic Forest Hotspot: The Dynamics of Biodiversity Loss. *Island Press*, Washington, DC, USA, pp. p3–11.

Gao, B. C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3), 257-266.

Gausman, H. W. (1974). Leaf reflectance of near-infrared. *Photogrammetric Engineering*, 40(2), 183-191.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. & Moore, R. (2017) Google Earth Engine: Planetary- scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202: 18-27.

Govender, M., Chetty, K., & Bulcock, H. (2007). A review of hyperspectral remote sensing and its application in vegetation and water resource studies. *Water Sa* 33(2), 145-151.

Herera, L. M. Z. (2023). Consequences of global warming. *SCT Proceedings in Interdisciplinary Insights and Innovations*, 1, 74-74.

Hernández, J., & Montaner, D. (2009). Patrones de respuesta espectral. Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio. Carlos Mena (Ed.) ISBN, 978-956.

Hoffer, R. M., & Johannsen, C. J. (1969). Ecological potentials in spectral signature analysis. *Remote sensing in ecology*, 1-16.

Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. Remote sensing of environment, 83(1-2), 195-213.

Hunt Jr, E. R., & Rock, B. N. (1989). Detection of changes in leaf water content using near-and middle-infrared reflectances. *Remote sensing of environment*, 30(1), 43-54.

Hyndman, R. J., & Athanasopoulos, G. (2018a). Chapter 8: ARIMA models. En Forecasting: principles and practice (2nd ed.). OTexts. Disponible en: https://otexts.com/fpp2/

Hyndman, R. J., & Athanasopoulos, G. (2018b). Chapter 3: The forecaster's toolbox. En Forecasting: principles and practice (2nd ed.). OTexts. Disponible en: https://otexts.com/fpp2/

Ichii, K., Kawabata, A., & Yamaguchi, Y. (2002). Global correlation analysis for NDVI and climatic variables and NDVI trends: 1982-1990. *International journal of remote sensing*, 23(18), 3873-3878.

IGN (Instituto Geográfico Nacional). (s.f.1). Capas SIG. Recuperado el 29 de octubre del 2025 de https://www.ign.gob.ar/NuestrasActividades/InformacionGeoespacial/CapasSIG

IGN (Instituto Geográfico Nacional). (s.f.2). Efectos de El Niño y La Niña en Argentina. Recuperado el 5 de octubre del 2024 de https://www.ign.gob.ar/content/efectos-el-ninio-y-la-ninia-en-argentina/

Iverson, L. R., Graham, R. L., & Cook, E. A. (1989). Applications of satellite remote sensing to forested ecosystems. *Landscape ecology*, 3, 131-143.

Izquierda Socialista. (2022, febrero 9). Incendios forestales: Toda Misiones está en llamas. Recuperado el 23 de octubre del 2024 de https://izquierdasocialista.org.ar/2020/index.php/blog/elsocialista/item/20161-incendios-forestales-todo-misiones-esta-en-llamas

Jacobi, J., Perrone, D., Duncan, L. L., & Hornberger, G. (2013). A tool for calculating the Palmer drought indices. *Water Resources Research*, 49(9), 6086-6089.

Jain, S. K., Keshri, R., Goswami, A., & Sarkar, A. (2010). Application of meteorological and vegetation indices for evaluation of drought impact: a case study for Rajasthan, India. *Natural hazards*, 54, 643-656.

Ji, L., & Peters, A. J. (2003). Assessing vegetation response to drought in the northern Great Plains using vegetation and drought indices. *Remote sensing of Environment*, 87(1), 85-98.

Justice, C. O., Townshend, J. R. G., Vermote, E. F., Masuoka, E., Wolfe, R. E., Saleous, N., Roy, D. P. & Morisette, J. T. (2002). An overview of MODIS Land data processing and product status. *Remote sensing of Environment*, 83(1-2), 3-15.

Katsoulas, N., Elvanidi, A., Ferentinos, K. P., Kacira, M., Bartzanas, T., & Kittas, C. (2016). Crop reflectance monitoring as a tool for water stress detection in greenhouses: A review. *Biosystems Engineering*, 151, 374-398.

Knapp, A. K., Beier, C., Briske, D. D., Classen, A. T., Luo, Y., Reichstein, M., Smith, M. D., Smith, S. D., Bell, J. E., Fay, P. A., Heisler, J. L., Leavitt, S. W., Sherry, R., Smith, B. & Weng, E. (2008). Consequences of more extreme precipitation regimes for terrestrial ecosystems. *Bioscience*, 58(9), 811-821.

Knipling, E. B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote sensing of environment*, 1(3), 155-159.

Kogan F. N. (1994) Application of vegetation index and brightness temperature for drought detection. *Adv Space Res* 15:91–100

Kogan, F. N. (1997). Global drought watch from space. *Bulletin of the American meteorological society*, 78(4), 621-636.

Kogan, F. N. (2001). Operational space technology for global vegetation assessment. *Bulletin of the American meteorological society*, 82(9), 1949-1964.

Laino Guanes, R. M. (2005). Manejo del recurso hídrico en la cuenca del Arroyo Capiibary: implicaciones para la gestión ambiental del acuífero Guaraní.

Lambers, H., Chapin, F. S., & Pons, T. L. (2008). Plant Physiological Ecology. *In Springer eBooks*. 183, 202, 589.

La Voz de Cataratas. (2021, agosto 20). Principio de incendio en el Parque Nacional Iguazú. Recuperado el 23 de octubre del 2024 de https://lavozdecataratas.com/2021/08/20/principio-de-incendio-en-el-parque-nacional-iguazu/

La Voz de Cataratas. (2022, enero 15). La sequía y la ola de calor complican la situación de los incendios forestales. Recuperado el 23 de octubre del 2024 de https://lavozdecataratas.com/2022/01/15/la-sequia-y-la-ola-de-calor-complican-la-situacion-de-los-incendios-forestales-2/

Lechner, A. M., Foody, G. M., & Boyd, D. S. (2020). Applications in remote sensing to forest ecology and management. *One Earth*, 2(5), 405-412.

Leiva, M. (2023, mayo 9). Sequía histórica en la Argentina: qué dicen los datos disponibles. *Chequeado*. Recuperado el 10 de noviembre del 2024 de https://chequeado.com/el-explicador/sequia-historica-en-la-argentina-que-dicen-los-datos-disponibles/

Li, C., Leal Filho, W., Yin, J., Hu, R., Wang, J., Yang, C., Yin, S., Bao, Y., & Ayal, D. Y. (2018). Assessing vegetation response to multi-time-scale drought across inner Mongolia plateau. *Journal of cleaner production*, 179, 210-216.

Li, J., Pei, Y., Zhao, S., Xiao, R., Sang, X., & Zhang, C. (2020). A review of remote sensing for environmental monitoring in China. *Remote Sensing*, 12(7), 1130.

Lillesaeter, O. (1982), Spectral reflectance of partly transmitting leaves: laboratory measurements and mathematical modeling. Remote Sens. Environ. 12:247-254.

Liu, Z., Chen, Y., & Chen, C. (2023). Analysis of the Spatiotemporal Characteristics and Influencing Factors of the NDVI Based on the GEE Cloud Platform and Landsat Images. *Remote Sensing*, 15(20), 4980.

Long, Q., Wang, F., Ge, W., Jiao, F., Han, J., Chen, H., Roig, F. A., Abraham, E. M., Xie, Mengxia & Cai, L. (2023). Temporal and spatial change in vegetation and its interaction with climate change in Argentina from 1982 to 2015. *Remote Sensing*, 15(7), 1926.

López, J., Way, D. A., & Sadok, W. (2021). Systemic effects of rising atmospheric vapor pressure deficit on plant physiology and productivity. *Global Change Biology*, 27(9), 1704-1720.

Lu, D. (2006). The potential and challenge of remote sensing‐based biomass estimation. *International journal of remote sensing*, 27(7), 1297-1328.

Maimaitiyiming, M., Ghulam, A., Bozzolo, A., Wilkins, J. L., & Kwasniewski, M. T. (2017). Early detection of plant physiological responses to different levels of water stress using reflectance spectroscopy. *Remote Sensing*, 9(7), 745.

Manning, C. G. (2012, octubre 12). What are passive and active sensors? *NASA*. Recuperado el 28 de septiembre del 2024 de https://www.nasa.gov/general/what-are-passive-and-active-sensors/

Massmann, A., Gentine, P., & Lin, C. (2019). When does vapor pressure deficit drive or reduce evapotranspiration? *Journal of Advances in Modeling Earth Systems* 11(10), 3305-3320.

MCCM (Ministerio de Cambio Climático de Misiones). (s.f.). Bosque Atlántico. Recuperado el 29 de octubre de 2025 de https://cambioclimatico.misiones.gob.ar/bosque-atlantico/

McKee, T. B., Doesken, N. J., & Kleist, J. (1993, January). The relationship of drought frequency and duration to time scales. In Proceedings of the 8th Conference on Applied Climatology (Vol. 17, No. 22, pp. 179-183).

Meis, Melanie. (2019). Coherencia regional entre el clima y el régimen hidrológico en distintas cuencas hídricas de la Argentina : implementación y comparación de pronósticos estadísticos de caudal. (Tesis Doctoral. Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales). Recuperado el 14 de noviembre de 2024 de http://hdl.handle.net/20.500.12110/tesis_n6941_Meis

Mika, J., Horvath, S. Z., Makra, L., & Dunkel, Z. (2005). The Palmer Drought Severity Index (PDSI) as an indicator of soil moisture. *Physics and Chemistry of the Earth*, Parts A/B/C, 30(1-3), 223-230.

Millar, C. I., & Stephenson, N. L. (2015). Temperate forest health in an era of emerging megadisturbance. *Science*, 349(6250), 823-826.

Misiones Journal. (2022, junio 19). Del recuerdo: 1978, el año que las Cataratas del Iguazú quedaron sin agua. *Misiones Journal*. Recuperado el 9 de noviembre del 2024 de

https://misionesjournal.com.ar/del-recuerdo-1978-el-ano-que-las-cataratas-del-iguazu-quedaron-sin-agua/#google_vignette

Mitchell, P. J., Veneklaas, E. J., Lambers, H., & Burgess, S. S. (2008). Leaf water relations during summer water deficit: differential responses in turgor maintenance and variation in leaf structure among different plant communities in south‐western Australia. *Plant, Cell & Environment*, 31(12), 1791-1802.

NASA (National Aeronautics and Space Administration) (s.f.). About MODIS. *MODIS*. Recuperado el 29 de octubre de 2024 de https://modis.gsfc.nasa.gov/about/

Neumann, P. M. (2008). Coping mechanisms for crop plants in drought-prone environments. *Annals of Botany*, 101(7), 901-907.

NOAA (Administración Nacional Oceánica y Atmosférica). (s.f.). Oceanic Niño Index (ONI). Climate Prediction Center. Recuperado el 8 de septiembre del 2024 de https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php

Palmer, W. C. (1965). Meteorological drought, Research paper no. 45. *US Weather Bureau, Washington, DC*, 58.

Paronetto, J. S. (2024). Datos pertenecientes a la tesis doctoral Procesos ecosistémicos vinculados al ciclo hidrológico en bosques subtropicales de la provincia de Misiones: consecuencias asociadas al uso del suelo y al cambio climático, aún no publicados.

Paruelo, J. M. (2008). La caracterización funcional de ecosistemas mediante sensores remotos. *Ecosistemas* 17(3) 4-22.

Penalba, O. C., & Rivera, J. A. (2016). Precipitation response to El Niño/La Niña events in Southern South America–emphasis in regional drought occurrences. *Advances in Geosciences*, 42, 1-14.

Peñuelas, J., & Filella, I. (1998). Visible and near-infrared reflectance techniques for diagnosing plant physiological status. *Trends in plant science*, 3(4), 151-156.

Pinter Jr, P. J., Hatfield, J. L., Schepers, J. S., Barnes, E. M., Moran, M. S., Daughtry, C. S., & Upchurch, D. R. (2003). Remote sensing for crop management. *Photogrammetric Engineering & Remote Sensing*, 69(6), 647-664.

Portal de América. (2020, abril 20). Cataratas del Iguazú con menos del 20% de su caudal de agua. *Portal de América*. Recuperado el 9 de noviembre del 2024 de https://www.portaldeamerica.com/index.php/pda/entrevistas-y-reportajes/item/29377-cataratas-del-iguazu-con-menos-del-20-de-su-caudal-de-agua

Primera Edición. (2022, octubre 17). En cuatro meses, casi 20 mil hectáreas de Misiones fueron afectadas por los incendios. *Primera Edición*. Recuperado el 23 de octubre del 2024 de https://www.primeraedicion.com.ar/nota/100643932/en-cuatro-meses-casi-20-mil-hectareas-de-misiones-fueron-afectadas-por-los-incendios/

Primera Edición. (2024, junio 6) Advierten que el fenómeno La Niña puede volver a afectar a Misiones y provocar una sequía. *Primera Edición*. Recuperado el 4 de abril del 2024 de https://www.primeraedicion.com.ar/nota/100888127/advierten-que-el-fenomeno-la-nina-puede-volver-a-afectar-a-misiones-y-provocar-una-sequia/

Qin, J., Ma, M., Shi, J., Ma, S., Wu, B., & Su, X. (2023). The time-lag effect of climate factors on the forest enhanced vegetation index for subtropical humid areas in China. *International Journal of Environmental Research and Public Health*, 20(1), 799.

R Core Team (2023) R: A language and environment for statistical computing. R v.4.3.2. R Foundation for Statistical Computing, Vienna, Austria. https://www.R-project.org/.

Revista Chacra. (2020, noviembre 24). Se multiplican los incendios en Misiones. *Revista Chacra*. Recuperado el 4 de abril del 2024 de https://www.revistachacra.com.ar/nota/38637-se-multiplican-los-incendios-en-misiones/

Risaro, D. B. (2024, octubre 2). Esperando a La Niña. *ElDiarioAR*. Recuperado el 5 de octubre del 2024 de https://www.eldiarioar.com/opinion/esperando-nina_129_11697974.html

Rivera, Juan Antonio. (2014). Aspectos climatológicos de las sequías meteorológicas en el sur de Sudamérica. Análisis regional y proyecciones futuras. Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires.

Rock, B. N., Vogelmann, J. E., Williams, D. L., Vogelmann, A. F., & Hoshizaki, T. (1986). Remote Detection of Forest Damage: Plant responses to stress may have spectral "signatures" that could be used to map, monitor, and measure forest damage. *Bioscience*, 36(7), 439-445.

Roman, A., & Ursu, T. (2016). Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. Landscape archaeology on the northern frontier of the roman empire at porolissum: an interdisciplinary research project. *Cluj-Napoca: Mega Publishing House*, 141-152.

Rosana, M., & Rafaelli, S. (2023). Impactos generados por la sequía 2019-2023 en la Región del Litoral argentino. *Cuadernos Del CURIHAM*. Recuperado el 10 de noviembre del 2024 de https://doi.org/10.35305/curiham.vi.219

Rouse, J. W., R. H. Haas, J. A. Scell, D. W. Deering and J. C. Harlan, Monitoring the Vernal Advancement of Retrogradiation of Natural Vegetation, NASA/GSFC, Type III, 371(1974).

RStudio Team (2023). RStudio: Integrated Development for R. RStudio, Inc., Boston, MA URL http://www.rstudio.com/.

Santa María de las Misiones (2020, octubre 4). El índice de peligrosidad extremo de incendios sigue latente en toda Misiones. FM 89.3 Santa María de las Misiones. Recuperado el 23 de octubre del 2024 de https://www.fm893.com.ar/2020/10/04/el-indice-de-peligrosidad-extremo-de-incendios-sigue-latente-en-toda-misiones/

SAyDS (Secretaría de Ambiente y Desarrollo Sustentable de la Nación). (2014). Tercera Comunicación Nacional sobre Cambio Climático. "Cambio Climático en Argentina; Tendencias y Proyecciones" (Centro de Investigaciones del Mar y la Atmósfera). Buenos Aires, Argentina.

Scholz, F. G., Bucci, S. J., Goldstein, G., Meinzer, F. C., & Franco, A. C. (2002). Hydraulic redistribution of soil water by neotropical savanna trees. *Tree Physiology*, 22(9), 603-612.

Seiler, R. A., Kogan, F., & Sullivan, J. (1998). AVHRR-based vegetation and temperature condition indices for drought detection in Argentina. *Advances in Space Research*, 21(3), 481-484.

SMN (Servicio Meteorológico Nacional). (s.f.). ¿Qué es el ENOS?. Recuperado el 5 de octubre del 2024 de https://www.smn.gob.ar/enos_que_es

Servicio Nacional de Manejo del Fuego (SNMF). (s.f.). Reporte técnico de ocurrencia. Recuperado el 4 de abril del 2024 de https://www.argentina.gob.ar/interior/ambiente/fuego/alertatemprana/reporte-ocurrencia

Shumway, R. H., & Stoffer, D. S. (2005). Time Series analysis and its applications (Springer Texts in Statistics). *In Springer eBooks*. https://dl.acm.org/citation.cfm?id=1088844

Tapia, K. J. M. (2020). Caracterización espectral de estrés hídrico en el cultivo de pepino dulce (Solanum muricatum). *Revista Geoespacial*, 17(1), 14–24.

Tilman, D., & Downing, J. A. (1994). Biodiversity and stability in grasslands. *Nature*, 367(6461), 363-365.

Van Loon, A. F. (2015). Hydrological drought explained. *Wiley Interdisciplinary Reviews: Water*, 2(4), 359-392.

Vermote, E. (2021). MODIS/Terra Surface Reflectance 8-Day L3 Global 500m SIN Grid V061 [Data set]. NASA EOSDIS Land Processes Distributed Active Archive Center. Accessed 2024-05-09 from https://doi.org/10.5067/MODIS/MOD09A1.061

Wan, Z., Hook, S., Hulley, G. (2021). MODIS/Terra Land Surface Temperature/Emissivity 8-Day L3 Global 1km SIN Grid V061 [Data set]. NASA EOSDIS Land Processes Distributed Active Archive Center. Accessed 2024-05-09 from https://doi.org/10.5067/MODIS/MOD11A2.061

Wang, L. & Qu, J. J. (2007). NMDI: a normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. Geophys Res Lett 34(20):L20405.

Wang, L., Qu, J. J., Hao, X., Zhu, Q. (2008). Sensitivity studies of the moisture effects on MODIS SWIR reflectance and vegetation water indices. Int J Remote Sens 29(24):7065–7075.

Wang, L., Kaseke, K. F., & Seely, M. K. (2017). Effects of non‐rainfall water inputs on ecosystem functions. *Wiley Interdisciplinary Reviews: Water*, 4(1), e1179.

Wen, Y., Liu, X., Xin, Q., Wu, J., Xu, X., Pei, F., Li, X., Du, G., Cai, Y., Lin, K., Yang, J. & Wang, Y. (2019). Cumulative effects of climatic factors on terrestrial vegetation growth. *Journal of Geophysical Research: Biogeosciences*, 124(4), 789-806.

Wickham, H. (2016). Data analysis. ggplot2 (pp. 189-201). Springer, Cham.

Wilhite, D. A., & Glantz, M. H. (1985). Understanding: the drought phenomenon: the role of definitions. Water international, 10(3), 111-120.

Wu, D., Zhao, X., Liang, S., Zhou, T., Huang, K., Tang, B., & Zhao, W. (2015). Time‐lag effects of global vegetation responses to climate change. *Global change biology*, 21(9), 3520-3531.

Xu, S., Wang, Y., Liu, Y., Li, J., Qian, K., Yang, X., & Ma, X. (2023). Evaluating the cumulative and time-lag effects of vegetation response to drought in Central Asia under changing environments. *Journal of Hydrology*, 627, 130455.

Xulu, S., Peerbhay, K., Gebreslasie, M., & Ismail, R. (2018). Drought influence on forest plantations in Zululand, South Africa, using MODIS time series and climate data. *Forests*, 9(9), 528.

Yang, J., Gong, P., Fu, R., Zhang, M., Chen, J., Liang, S., Xu, B., Shi, J. & Dickinson, R. (2013). The role of satellite remote sensing in climate change studies. *Nature climate change*, 3(10), 875-883.

Yeh, S. W., Cai, W., Min, S. K., McPhaden, M. J., Dommenget, D., Dewitte, B., Collins, M., Ashok, K., An, S-I., Yim, B-Y. & Kug, J. S. (2018). ENSO atmospheric teleconnections and their response to greenhouse gas forcing. *Reviews of Geophysics*, 56(1), 185-206.

Zarco-Tejada, P. J. (2000). Hyperspectral remote sensing of closed forest canopies: estimation of chlorophyll fluorescence and pigment content.

Zhai, J., Su, B., Krysanova, V., Vetter, T., Gao, C., & Jiang, T. (2010). Spatial variation and trends in PDSI and SPI indices and their relation to streamflow in 10 large regions of China. *Journal of Climate*, 23(3), 649-663.

Zhan, C., Liang, C., Zhao, L., Jiang, S., Niu, K., & Zhang, Y. (2022). Drought-related cumulative and time-lag effects on vegetation dynamics across the Yellow River Basin, China. Ecological Indicators, 143, 109409.

Zhang, Y. J., Cristiano, P. M., Zhang, Y. F., Campanello, P. I., Tan, Z. H., Zhang, Y. P., Cao, K-F. & Goldstein, G. (2016). Carbon economy of subtropical forests. *Tropical Tree Physiology: Adaptations and Responses in a Changing Environment*, 337-355.

Zheng, H., Shen, G., He, X., Yu, X., Ren, Z., & Zhang, D. (2015). Spatial assessment of vegetation vulnerability to accumulated drought in Northeast China. *Regional environmental change*, 15, 1639-1650.

Zivot, E., & Wang, J. (2006). Capítulos 3: Time Series Concepts y 4: Unit Root Tests. En *Modeling financial time series with S-PLUS®*. Springer eBooks. https://doi.org/10.1007/0-387-32348-1

Zou, L., Cao, S., & Sanchez-Azofeifa, A. (2020). Evaluating the utility of various drought indices to monitor meteorological drought in Tropical Dry Forests. *International Journal of Biometeorology*, 64, 701-711.