



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS AGRONÓMICAS

ESCUELA DE POSTGRADO

Tesis para optar al Título Profesional de Ingeniero Agrónomo y al Grado de
Magíster en Gestión Territorial de Recursos Naturales

Pedro Vicente Zúñiga Moraga

Guía de Tesis
Álvaro G. Gutiérrez Ilabaca

Co guía de Tesis
Roberto O. Chávez Oyanadel.

Profesores/as consejeros/as
Yasna Mariela Tapia Fernández
Luis José Alejandro Morales Salinas

Evaluador externo
Sebastián Vicuña Díaz

SANTIAGO - CHILE
2025

UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS AGRONÓMICAS
ESCUELA DE POSTGRADO

Influencia bioclimática en la configuración espacial del bosque nativo costero de la zona
semiárida central de Chile

Tesis presentada como parte de los requisitos para optar al Título Profesional de
Ingeniero Agrónomo y al Grado de Magíster en Gestión Territorial de Recursos.

Pedro Vicente Zúñiga Moraga

Calificaciones

GUÍAS DE TESIS

Álvaro G. Gutiérrez Ilabaca
Ingeniero Forestal, Ph.D.

5,7

Roberto O. Chávez Oyanadel
Ingeniero Forestal, Ph.D.

5,9



PROFESORES/AS CONSEJEROS/AS

Yasna Mariela Tapia Fernández
Ingeniero en Alimentos, Ph.D.

6,8

Luis José Alejandro Morales Salinas
Profesor de física y Cs. Naturales, Ph.D.

7,0

Santiago, Chile
2025

AGRADECIMIENTOS Y DEDICATORIA

A mi familia, por su amor incondicional y por creer en mí en cada etapa de este camino. A mi mamá y a mi abuela, quienes siempre me incentivaron a valorar la educación como una herramienta para crecer y transformar la realidad. A mis abuelos, quienes ya no me acompañan físicamente, pero cuya fortaleza, cariño y enseñanzas me han guiado siempre; este logro también les pertenece.

Al equipo del laboratorio Bosque Ciencia, por brindarme un espacio de aprendizaje, colaboración y amistad, y por inspirarme a seguir explorando con curiosidad y compromiso.

Agradezco especialmente a mi pareja, por su apoyo constante, sus sabios consejos y por recordarme siempre la importancia de mantener el equilibrio y la perspectiva.

Este trabajo fue posible gracias al financiamiento de los proyectos SACBAD ANID ATE220055 y Proyecto ANID PIA/BASAL FB210006 - IEB, cuyo respaldo permitió llevar a cabo la investigación que aquí presento.

A todos quienes, de una u otra forma, me acompañaron en este proceso, mi más sincero agradecimiento.

ÍNDICE

RESUMEN	
ABSTRACT	
INTRODUCCIÓN	1
La niebla: su importancia en la persistencia y configuración de los bosques costeros en la región semiárida.....	2
Indicadores bioclimáticos y la configuración espacial de los bosques	3
Propósito y Contribución de esta investigación.....	4
HIPÓTESIS	5
OBJETIVOS	5
MATERIALES Y MÉTODOS	6
Delimitar las áreas de bosque nativo a través de técnicas de percepción remota	8
Validación datos GOES	10
Análisis a escala de subcuenca	11
Métricas de paisaje y comparación entre subcuencas.....	11
Análisis a escala subregional	11
Determinar los predictores bioclimáticos de la distribución geográfica de bosque nativo costero.....	12
Analizar el vigor de la vegetación del bosque nativo costero con la ocurrencia de eventos climáticos.....	14
Influencia espacial de la precipitación y niebla nubes bajas sobre el NDVI.....	15
RESULTADOS	17
Delimitación del bosque nativo	17
Validación de Datos GOES	17
Análisis a escala de subcuenca	18
Índices de paisaje análisis a nivel de subcuenca.....	18
Análisis a escala subregional	21
Predictores bioclimáticos de la distribución geográfica de bosque nativo costero...	21
Análisis del vigor de la vegetación del bosque nativo costero con la ocurrencia de eventos climáticos.....	23

Modelos de regresión lineal robusto, relación NDVI aportes hídricos, relación espacial	25
El uso de datos satelitales GOES para estimar el aporte hídrico de la niebla.....	28
Los resultados de la clasificación supervisada del bosque	29
Los análisis sobre la estructura del paisaje	29
Los patrones de distribución modelados mediante MaxEnt	30
La relación entre vigor vegetal, niebla y precipitación.....	31
Limitaciones	32
CONCLUSIONES	32
LITERATURA CITADA	34

ÍNDICE DE FIGURAS

Figura 1 Delimitación de área de estudio, subcuencas de la zona semiárida ubicadas en la región de Coquimbo y Valparaíso.	7
Figura 2 Correlación de Spearman Agua recolectada vs Niebla y nubes bajas.....	18
Figura 3 Patrones de precipitación, niebla, nubes bajas, fragmentación del bosque y cobertura forestal por subcuenca.	20
Figura 4 Figura 4. Análisis Jackknife indicando la ganancia en solitario y caída de ganancia.	222
Figura 5 Precisión e índice de Kappa según umbral de probabilidad.....	23
Figura 6 Correlación entre NDVI y variables climáticas por períodos quinquenales (2000–2019).	24
Figura 7 Relación espacial entre el NDVI promedio de verano y la precipitación anual media (mm) y niebla nubes bajas (días al mes).....	27

ÍNDICE DE CUADROS

Cuadro 1 Descripción de los sets de datos a utilizar en el estudio	8
Cuadro 2 Criterio de selección de variables bioclimáticas	13

ÍNDICE APÉNDICE

Apéndice 1: Detalle de los códigos utilizados para cada subcuenca.	42
---	----

RESUMEN

Los bosques nativos de las cuencas costeras semiáridas de Chile central enfrentan crecientes presiones climáticas y antrópicas. En este contexto, se plantea que la niebla influye de manera decisiva en la distribución y el vigor del bosque costero, al compensar la escasez de precipitaciones estivales, frente a la hipótesis alternativa que atribuye un papel dominante al régimen de lluvias. Para evaluar esta idea, se analizó el efecto de 21 variables bioclimáticas —incluidas ocho asociadas a niebla y nubes bajas— sobre la distribución y el vigor del bosque entre Valparaíso y Coquimbo.

Se seleccionaron 10 subcuencas costeras semiáridas (4.067 km²), donde la distribución del bosque se determinó mediante clasificación supervisada con Random Forest. Se evaluó la disponibilidad bioclimática del bosque usando el algoritmo MaxEnt. Asimismo, se examinó la relación entre el vigor del bosque (NDVI) y los aportes hídricos de niebla y lluvia.

Los resultados indican que la niebla fue el predictor más relevante de la distribución del bosque según MaxEnt y presentó una correlación estival más alta con el NDVI que la precipitación, explicando hasta un 39 % de la variación espacial del vigor. Esto destaca su papel como fuente hídrica clave en periodos secos y su importancia para modelos y estrategias de conservación bajo cambio climático.

Palabras claves: bosques costeros, NDVI, land-cover, niebla costera.

ABSTRACT

Native forests in the semi-arid coastal basins of central Chile face increasing climatic and human pressures. In this context, it is proposed that fog plays a decisive role in shaping the spatial distribution and vigor of coastal forests by compensating for scarce summer rainfall or drought periods, in contrast to an alternative hypothesis that attributes a predominant role to precipitation regimes. To evaluate this, the influence of 21 bioclimatic variables — including eight related to fog and low clouds— was analyzed in relation to forest distribution and vigor between the Valparaíso and Coquimbo regions.

Ten semi-arid coastal sub-basins (4,067 km²) were selected, and forest distribution was mapped using supervised classification with the Random Forest algorithm. Bioclimatic suitability was then assessed using MaxEnt, and the relationship between forest vigor (NDVI) and water inputs from fog and rainfall was examined.

Results show that fog was the most important predictor of forest distribution according to MaxEnt and exhibited a stronger summer correlation with NDVI than precipitation, explaining up to 39% of the spatial variation in vegetative vigor. These findings highlight the ecological role of fog as a key water source during dry periods and its relevance in predictive modeling and conservation strategies under climate-change scenarios.

Keywords: coastal forests, NDVI, land cover, coastal fog

INTRODUCCIÓN

La zona semiárida central de Chile es un hotspot global de biodiversidad, es decir, es un área que combina una alta concentración de especies endémicas con un alto grado de pérdida de hábitat debido a actividades humanas (Mittermeier *et al.*, 2011). Estos ecosistemas con alta diversidad de especies endémicas tienen un rol clave en cuanto a relevancia como refugios para la conservación de la biodiversidad (Mardones y Scherson, 2023; Smith-Ramírez *et al.*, 2023). Los ecosistemas mediterráneos de la zona central de Chile enfrentan una alta vulnerabilidad, con un 22,9% clasificados en categorías de amenaza (Alaniz *et al.*, 2016). La pérdida histórica de distribución en algunos de estos ecosistemas alcanza hasta un 81,2%, principalmente debido a la expansión agrícola, las plantaciones de especies exóticas y la conversión de suelos para ganadería (Alaniz *et al.*, 2016). Adicionalmente, la zona semiárida chilena ha sido sometida a intensas presiones humanas: entre 1975 y 2011, el 64% de los cambios en el uso del suelo se atribuyeron a procesos naturales, mientras que el 36% se debió a actividades antropogénicas, intensificando la fragmentación y pérdida de hábitat (Hernández *et al.*, 2016). Adicionalmente, las sequías prolongadas y el aumento de temperaturas podrían alterarlos de manera irreversible (Liu *et al.*, 2023).

En las zonas semiáridas de Chile, los bosques esclerófilos no solo regulan la temperatura local, sino que también contribuyen al ciclo hídrico, facilitando la infiltración de agua y reduciendo la erosión del suelo (Smith-Ramírez *et al.*, 2023). Los bosques nativos costeros en particular cumplen funciones esenciales, como la regulación ecológica y climática, al actuar como importantes sumideros de carbono que contribuyen a mitigar el cambio climático mediante la absorción de dióxido de carbono de la atmósfera (Rotenberg y Yakir, 2010; Griebel *et al.*, 2020; Mardones y Scherson, 2023). Estos ecosistemas destacan por su alta diversidad de especies, muchas de ellas endémicas, lo que refuerza su relevancia como refugios para la conservación de la biodiversidad (Mardones y Scherson, 2023; Smith-Ramírez *et al.*, 2023).

La formación de la niebla depende de factores como la temperatura del mar, la altura de la inversión térmica y la proximidad a la costa, siendo constante en áreas cercanas al litoral de la zona semiárida chilena (Garreaud *et al.*, 2008; Espinoza *et al.*, 2024). El Niño reduce la frecuencia de niebla al debilitar la inversión atmosférica, mientras La Niña la incrementa al fortalecerla, lo cual puede impactar la disponibilidad hídrica en ecosistemas costeros semiáridos, con efectos opuestos en niebla y precipitaciones regionales (Garreaud *et al.*, 2008).

La niebla: su importancia en la persistencia y configuración de los bosques costeros en la región semiárida

En las zonas semiáridas costeras de Chile central se encuentran bosques que dependen en gran medida de la captura de agua proveniente de la niebla, lo que los convierte en un modelo ideal para estudiar interacciones bioclimáticas complejas (del Val *et al.*, 2006). Los bosques costeros dependientes de la niebla son ecosistemas singulares, considerados bosques relictos, por su permanencia en el tiempo. Cumplen un papel esencial en la provisión de servicios ecosistémicos y la conservación de la biodiversidad (del Val *et al.*, 2006; Barbosa *et al.*, 2010).

Un ejemplo notable en estos bosques que utilizan la niebla es el olivillo costero (*Aextoxicon punctatum* Ruiz y Pav.), una especie icónica en los bosques costeros del centro-norte de Chile (Armas *et al.*, 2016). El olivillo es capaz de interceptar la niebla costera, contribuyendo a la disponibilidad de agua en el suelo en un entorno con lluvias escasas (Gutiérrez *et al.*, 2008; Stanton *et al.*, 2014; Salgado *et al.*, 2015; Macek *et al.*, 2018). Además, los bosques de olivillo son considerados relictos, ya que sobreviven en refugios climáticos que les han permitido persistir a lo largo del tiempo, siendo testigos vivos de la historia climática y biogeográfica de la región (Villagrán y Armesto, 2005). Esto los convierte en elementos cruciales para la conservación de la biodiversidad y los servicios ecosistémicos (Armas *et al.*, 2016).

Gutiérrez *et al.* (2008) subrayaron que la interacción entre las precipitaciones y el aporte hídrico de la niebla ha sido crucial para la persistencia de *Aextoxicon punctatum* durante más de 250 años, incluso frente a fluctuaciones climáticas. Por otro lado, Barbosa *et al.* (2010) concluyeron que los parches más grandes de *Aextoxicon punctatum* son más efectivos en retener agua gracias a su mayor área basal y capacidad para interceptar la niebla.

Complementando estos hallazgos, del Val *et al.* (2006) identificaron que los parches de bosque con bordes más expuestos a la niebla presentan una regeneración más activa, atribuida a su mayor eficiencia en la captura de agua. Por su parte, Salgado *et al.* (2015) demostraron que los gradientes de humedad generados por la intercepción de la niebla influyen significativamente en los rasgos funcionales de las especies arbóreas dominantes. En particular, *Aextoxicon punctatum* adapta sus características foliares a microhábitats contrastantes, lo que le permite persistir bajo condiciones de estrés hídrico (Salgado *et al.*, 2013). Finalmente, del Río *et al.* (2021), estudió en el desierto de Atacama, cómo la topografía, la altitud de la capa de inversión y fenómenos globales como el ENSO influyen en la distribución estacional y diurna de la niebla, reduciendo la presencia de nubes bajas y niebla durante los ciclos de La Niña y aumentando su ocurrencia durante los ciclos de El Niño. Este efecto es contrario al observado en los bosques dependientes de niebla cercanos a la latitud 30°S, donde los años de El Niño se asocian con condiciones de menor niebla (Garreaud *et al.*, 2008). La niebla actúa como un recurso hídrico esencial para la persistencia de los bosques relictos costeros y constituye un factor determinante en su dinámica ecológica y espacial, al promover retroalimentaciones que favorecen la auto-organización y el desplazamiento direccional de los parches vegetacionales (Stanton *et al.* 2014).

En su conjunto, la literatura destaca consistentemente el rol de la niebla como un recurso hídrico fundamental para la persistencia, regeneración y organización espacial de los bosques relictos costeros (del Val *et al.*, 2006; Gutiérrez *et al.*, 2008; Barbosa *et al.*, 2010; Stanton *et al.* 2014; Salgado *et al.*, 2015). Sin embargo, la mayoría de las investigaciones se han centrado en el Parque Nacional Fray Jorge, lo que pone de manifiesto un vacío de información sobre la variabilidad espacial de estos bosques a lo largo de la región semiárida. Este sesgo limita una comprensión integral de los procesos ecológicos que afectan a estos ecosistemas en distintas áreas de la región.

Dado que los bosques relictos dependientes de neblina representan un tipo particular de bosque que ha logrado persistir en condiciones climáticas marginales, su estudio puede arrojar luz sobre los factores ambientales más relevantes para la distribución de bosques en general (Squeo *et al.*, 2016).

Indicadores bioclimáticos y la configuración espacial de los bosques

El bioclima se define como el conjunto de interacciones entre las condiciones climáticas predominantes, principalmente la temperatura y la disponibilidad hídrica, y su influencia en los organismos y ecosistemas (Hampe, 2004). El espacio bioclimático, se presenta como un marco clave para analizar la distribución espacial de los bosques (Guisan *et al.*, 2017) ya que permiten explorar cómo factores ambientales, como las fluctuaciones térmicas y la cantidad de agua disponible, moldean la persistencia de los ecosistemas forestales en el paisaje (Hampe, 2004; Q. Liu *et al.*, 2023).

Las condiciones bioclimáticas que permiten el desarrollo de comunidades vegetales son clave para comprender cómo las relaciones entre los organismos y su entorno influyen en su persistencia (Pocheville, 2015). Por ejemplo, Liu *et al.* (2022) demostraron que, en el noreste de China —una región con clima monzónico templado continental—, las variables climáticas relacionadas con la temperatura fueron determinantes para la distribución potencial de diversas especies arbóreas. De manera análoga, aunque bajo un clima diferente, esta aproximación también puede aplicarse al estudio de bosques costeros influenciados por la niebla. En este sentido, Ball y Tzanopoulos (2020) mostraron que, en las montañas del sur de Arabia —de clima semiárido—, la niebla cumple un rol crucial en la configuración de la vegetación, evidenciando su correlación con el vigor vegetal a partir de datos satelitales.

En este sentido, el análisis de los factores bioclimáticos en bosques costeros proporciona información valiosa para comprender la distribución de los bosques bajo condiciones climáticas cambiantes (Hampe, 2004; de la Maza *et al.*, 2009).

Propósito y Contribución de esta investigación

La presente investigación tiene como propósito principal evaluar el rol de la niebla costera como un factor bioclimático distintivo de las zonas litorales en la configuración espacial y el vigor vegetativo del bosque nativo costero en la zona semiárida central de Chile.

El análisis de la influencia de la niebla se aborda desde una perspectiva integral, evaluando no solo su papel en los bosques relictos, sino también en otras configuraciones de bosques costeros (por ejemplo bosques esclerófilos). Este enfoque busca identificar respuestas de los ecosistemas arbóreos frente a factores bioclimáticos, incluyendo la distribución espacial de la niebla. Esta investigación incorpora herramientas basadas en sensores remotos, como el NDVI (Índice de Vegetación de Diferencia Normalizada), un índice ampliamente utilizado para evaluar el vigor de la vegetación a través de la actividad fotosintética (Huete *et al.*, 2010), proporcionando un marco más amplio para entender cómo la interacción entre la niebla y otras variables bioclimáticas condiciona la distribución de estos bosques.

HIPÓTESIS

La niebla influye significativamente en la configuración espacial y el vigor del bosque nativo costero, ya que áreas más influenciadas por la niebla compensan la escasez de precipitaciones durante el período estival o en condiciones de sequía.

Hipótesis alternativa: La configuración espacial y el vigor del bosque nativo costero están determinados principalmente por el régimen de precipitaciones, ya que es el principal factor limitante para el vigor de la vegetación, independientemente del aporte de la niebla.

OBJETIVOS

Objetivo General

Evaluar la influencia bioclimática incluida la niebla costera en la configuración espacial y el vigor del bosque nativo costero de la zona semiárida central de Chile.

Objetivos específicos

- 1) Delimitar las áreas de bosque nativo a través de técnicas de percepción remota.
- 2) Determinar los predictores bioclimáticos de la distribución geográfica de bosque nativo costero.
- 3) Analizar el vigor de la vegetación del bosque nativo costero con la ocurrencia de eventos climáticos.

MATERIALES Y MÉTODOS

El área de estudio comprende 10 subcuencas costeras desde la ubicación 31°7'S hasta 32°5' S (Figura 1), incluyendo por el norte la subcuenca de Estero Pupío y cerrando en el sur en la subcuenca Costera Estero Ligua y Catapilco. Las subcuencas estudiadas están distribuidas a lo largo de un gradiente ambiental que se extiende tanto en sentido longitudinal (este-oeste) como latitudinal (norte-sur), reflejando variaciones en topografía, ubicación geográfica y condiciones climáticas. Los nombres y códigos de cada subcuenca, representadas en la Figura 1, se detallan en el Apéndice 1. Esta área de 4.067 km², tiene la ventaja de presentar formaciones boscosas del tipo esclerófilo mediterráneo y bosques de olivillos.

El clima de las subcuencas está marcado por bajas precipitaciones que varía en torno a los 200 mm anuales (Ministerio Medio Ambiente, 2014), influenciada por la corriente de Humboldt y el anticiclón del Pacífico Sur (Montecinos *et al.*, 2016). Esto provoca marcados contrastes entre la costa y el interior, donde en las zonas costeras, la disponibilidad de agua es significativamente mayor y un déficit hídrico anual que varía entre 800 y 1000 mm (Ministerio Medio Ambiente, 2014). La Cordillera de la Costa actúa como barrera orográfica, acentuando la aridez en sectores interiores mediante un efecto de sombra de lluvia (Rundel *et al.*, 1991).

En este contexto, la niebla costera constituye una fuente hídrica adicional. Su captación por parte de especies arbóreas contribuye a la disponibilidad hídrica durante periodos secos (del Val *et al.*, 2006; Barbosa *et al.*, 2010; Salgado *et al.*, 2015).

Los suelos presentes en el área de estudio se desarrollan sobre materiales sedimentarios y graníticos, distribuidos en terrazas marinas, lomajes costeros y valles interiores. En el valle del río Quilimarí se identifican suelos de la Serie Quilimarí (Typic Haplocambid), de origen sedimentario, con buen drenaje, textura franco arcillo arenosa en superficie y arcillosa en profundidad. Su capacidad de uso varía entre las clases III y VI, según pendiente y profundidad (Luzio, 2010).

En sectores costeros, los suelos se encuentran bajo un régimen de humedad árido y un régimen térmico isotérmico, influenciados por la proximidad oceánica. Se desarrollan sobre terrazas marinas y cerros del batolito costero, con suelos poco desarrollados, de textura gruesa y bajos contenidos de carbono orgánico. En terrazas más elevadas se observan horizontes cámbicos y argílicos, indicativos de mayor evolución pedogenética. Los suelos más frecuentes corresponden a Alfisoles, Mollisoles e Inceptisoles, con saturación de bases variable y pH entre 5,6 y 7,8 (Luzio, 2010).

La vegetación del área de estudio se enmarca dentro de las formaciones propias del clima mediterráneo semiárido de Chile central, conforme a la clasificación de pisos vegetacionales propuesta por Luebert y Pliscoff (2006). En función de la variabilidad climática y topográfica del territorio, se distinguen diversas unidades de vegetación, entre las que se incluyen matorrales desértico-mediterráneos interiores, matorrales espinosos, matorrales bajos andinos, y bosques esclerófilos presentes tanto en sectores costeros como interiores.




Figura 1 Delimitación de área de estudio, subcuencas de la zona semiárida ubicadas en la región de Coquimbo y Valparaíso.

Para el análisis se utilizaron imágenes satelitales de diversas fuentes, seleccionadas por su capacidad de captar información relevante para el estudio de la distribución de los bosques costeros. En el Cuadro 1 se detalla la información de los satélites empleados, incluyendo su resolución espacial, temporal y las variables climáticas derivadas de sus productos.

Cuadro 1 Descripción de los sets de datos a utilizar en el estudio

Set de datos	Propósito	Fechas / Período utilizado	Resolución	Procesamiento
Imágenes Satelitales (Landsat 5, 7 y MODIS)	Clasificación de coberturas de suelo y análisis fenológico mediante el índice NDVI.	1 de enero de 2000 a 31 de diciembre de 2000 (clasificación) y series temporales de 2000 a 2020	30 metros (Landsat) y 250 metros (MODIS)	Google Earth Engine (GEE)
Datos Climáticos (CR2MET)	Identificación y elaboración de predictores bioclimáticos para la distribución del bosque.	2000-2020	0,05 grados de latitud y longitud. (aproximadamente 5 km por celda)	Datos de precipitación y temperaturas máxima/mínima para Chile, basados en modelos estadísticos calibrados con observaciones. Usa datos de ERA5, parámetros topográficos y el sensor satelital MODIS (Boisier, 2023).
Datos de niebla y nubes bajas obtenidos a partir de los satélites GOES-8 al GOES-16 de la serie Geostationary Operational Environmental Satellite (GOES)	Integración de variables de niebla en el análisis bioclimático y de vigor de los bosques costeros.	2000-2021	2,2 km por píxel.	Datos generados por el Centro del Desierto de Atacama, categorizados con umbrales térmicos (Torregrosa <i>et al.</i> , 2016; del Río <i>et al.</i> , 2021; Espinoza <i>et al.</i> , 2024)
Modelo de Elevación Digital (DEM)	Incorporación de la topografía en el análisis de cobertura del suelo y distribución forestal.	2020	30 metros por píxel.	Incorporación de topografía mediante datos de NASA JPL, 2020

Delimitar las áreas de bosque nativo a través de técnicas de percepción remota

Con el objetivo de analizar la distribución y ubicación del bosque, se elaboró un mapa de cobertura correspondiente al año 2000. La elección de este año responde a la necesidad de contar con un periodo amplio de análisis, que permita examinar la evolución del bosque nativo durante 20 años, incluyendo una década de línea base previa al inicio de la megasequía que afecta a la zona central desde 2010 (Garreaud *et al.*, 2020). El año 2000 marca el inicio de la disponibilidad sistemática y continua de imágenes satelitales con resolución y calidad adecuadas para la extracción de variables espectrales consistentes en el tiempo, en

concordancia con el inicio de la serie MODIS (Gašparović et al., 2024). Asimismo, este periodo es congruente con la disponibilidad de registros históricos de niebla y cobertura de nubes bajas, elementos clave en la comprensión de los factores climáticos que inciden en la dinámica del bosque.

En el marco del análisis satelital de esta tesis, se definió bosque como toda área del territorio cuya cobertura es clasificada como tal a partir de la interpretación de píxeles Landsat, cada uno de $30\text{ m} \times 30\text{ m}$ (900 m^2) de resolución espacial. La categoría bosque corresponde a aquellos píxeles en los que la respuesta espectral, evaluada mediante algoritmos de clasificación supervisada, se asocia a formaciones vegetales arbóreas con una cobertura de copas suficiente para diferenciarlas de otros tipos de cobertura del suelo.

Para la correcta delimitación de los bosques, resulta necesario diferenciarlos de otras formas de vegetación y cobertura. Con este fin, se han establecido 14 clases de cobertura de suelo, entre las cuales se incluyen: cultivos, frutales de hoja caduca y perenne, arbustos esclerófilos y xerófitos, cuerpos de agua, arena, roca, grava, suelo desnudo, áreas urbanas, plantaciones forestales y bosque nativo.

La metodología empleada fue de clasificación supervisada utilizando el algoritmo Random Forest, que es un clasificador de aprendizaje automático (Breiman, 2001). Este algoritmo ha ampliado significativamente las capacidades de clasificación de imágenes satelitales y es capaz de distinguir categorías a nivel de píxel (Gislason et al., 2006; Shetty *et al.*, 2021; Dubertret *et al.*, 2022). Además, Random Forest ha demostrado ser eficaz en la clasificación según la cobertura del suelo, alcanzando una precisión del 96% en el bosque esclerófilo (Mellor *et al.*, 2013), lo que permite generar mapas de uso del suelo altamente fiables.

La capacidad del algoritmo para diferenciar coberturas de bosques de los matorrales se sustenta en la incorporación de variables espectrales y topográficas como predictores dentro del modelo, siguiendo el enfoque metodológico reportado por Mellor et al. (2013). Entre las variables destacadas en dicho estudio, se encuentra la banda 5 (SWIR), cuya sensibilidad a la humedad permite discriminar zonas con mayor biomasa, propias del bosque, frente a la vegetación más seca del matorral. Asimismo, la información derivada del NDVI y su variabilidad temporal resultó fundamental para diferenciar coberturas perennes, como el dosel forestal, de formaciones estacionales, como los matorrales. Del mismo modo, la elevación, incorporada como variable predictora, fue relevante para reflejar los patrones altitudinales característicos: con los bosques localizados en zonas más altas y los matorrales predominando en sectores más bajos.

Considerando estos antecedentes, el algoritmo fue alimentado con información proveniente de los satélites Landsat 5 y 7. Esto incluye todas sus bandas espectrales y cuatro índices normalizados: SAVI, NDVI (Tucker, 1979; Xu *et al.*, 2012), Normalized Difference Built-up Index (NDBI) Built-up Area Extraction Index (BAEI) (Dubertret *et al.*, 2022). Se compilieron los valores mínimo, máximo y promedio para cada banda e índice durante todo el periodo comprendido entre el 1 de enero y el 31 de diciembre del año 2000. Además, se integraron datos del Modelo Digital de Elevación (DEM) elaborado por la NASA (NASA JPL, 2020). Esto permitió generar un raster compilado, compuesto por 75 bandas. La

obtención y procesamiento del ráster compilado se realizó mediante Google Earth Engine, que permite manejar grandes volúmenes de datos de manera eficiente.

Con el ráster generado, se procedió a entrenar el algoritmo Random Forest utilizando puntos de entrenamiento y a evaluarlo con puntos de validación. Los puntos se distribuyeron a partir de las clases forestal siempreverde y esclerófilo del Catastro de Uso de Suelo y Vegetación de CONAF para las regiones de Valparaíso y Coquimbo, elaborado a partir de imágenes Landsat 7 ETM, vuelos fotogramétricos a color de los años 2000 y 2001, y cartografía base del Instituto Geográfico Militar (IGM) a escala 1:50.000 (CONAF, 2020).

Dado que este catastro posee una unidad mínima cartografiada de 6,25 hectáreas en los sectores costeros y centrales, lo que limita su capacidad para representar la heterogeneidad espacial a escalas menores, se complementó la identificación de coberturas con información del Catastro Agrícola de CIREN, el Catastro Vegetacional de CONAF y la fotointerpretación de imágenes satelitales de Google Earth.

A partir de esta base, se generaron puntos aleatorios de entrenamiento y validación, manteniendo una distancia mínima de 30 metros entre ellos. La veracidad de cada punto se verificó mediante el análisis de series temporales de NDVI de los satélites Landsat 5 y 7, evaluando su comportamiento fenológico mediante gráficos representativos para cada clase.

La cantidad de puntos destinados al entrenamiento y validación del algoritmo fue representativa de la totalidad del área de estudio de 4,066 km² con un total de 2.527 puntos divididos equitativamente entre entrenamiento y validación. Esto es similar a la metodología empleada por Dubertret *et al.* (2022), que utilizó 9,864 puntos para un área de 15,867 km². Para cada clase de cobertura se generaron los puntos de referencia permitiendo ajustar el modelo y estimar su precisión a partir de puntos de validación.

La operación de clasificación mediante Random Forest se llevó a cabo en el software R Studio, utilizando la librería "randomForest" (Liaw, 2022).

El resultado de esta clasificación se empleó en los análisis presentados a continuación, utilizando la clase de bosque nativo como única referencia para la localización de los bosques costeros

Validación datos GOES

Para analizar la ocurrencia de niebla, se utilizaron datos satelitales "Geostationary Operational Environmental Satellite (GOES)" procesados por el Centro del Desierto de Atacama (del Río *et al.*, 2021; Espinoza *et al.*, 2024). Aunque GOES no proporciona directamente la altura de la base de las nubes, permite identificar la cima de las formaciones nubosas, lo que posibilita aproximarse a la detección de niebla cuando estas interactúan con la orografía costera (Torregrosa *et al.*, 2016; del Río *et al.*, 2021). Se trabajó con datos mensuales, para el caso específico del área de estudio los píxeles representaron una resolución de 2,2 km (Tan *et al.*, 2020).

Para validar los datos del satélite GOES, se utilizaron 84 colectores distribuidos en seis parches del Parque Nacional Fray Jorge. En cada parche cuenta con seis colectores para medir el escurrimiento por tronco (stemflow) y ocho colectores para cuantificar la precipitación bajo el dosel (throughfall), con un periodo de datos mensuales del 2004 al 2022. Los datos fueron promediados considerando que los colectores coinciden espacialmente con las celdas de la grilla del satélite GOES, se obtuvo así un único valor mensual que se comparó con los datos mensuales provenientes del GOES.

El análisis se desarrolló utilizando dos enfoques complementarios: la correlación de Spearman (Spearman, 1904) y el suavizado LOWESS (Locally Weighted Scatterplot Smoothing) (Cleveland, 1979). La primera fue seleccionada por su adecuación a series temporales ambientales que pueden presentar no normalidad y relaciones no lineales. El método LOWESS, por su parte, permitió explorar visualmente tendencias locales en la frecuencia de niebla/nubes bajas, sin asumir una forma funcional predeterminada.

Análisis a escala de subcuenca

Métricas de paisaje y comparación entre subcuencas

En este estudio se utilizaron tres métricas de paisaje complementarias: la densidad de parches (Patch Density), que cuantifica el número de parches de bosque por cada 100 ha y refleja el grado de fragmentación del hábitat; la densidad de borde (Edge Density), que mide la longitud de los bordes del parche de bosque por hectárea y aporta información sobre la configuración espacial y la influencia de los márgenes (O'Neill *et al.*, 1988; Hesselbarth *et al.*, 2019); y el porcentaje de cobertura forestal, calculado como la proporción de área cubierta por bosque en cada subcuenca.

Tanto las métricas de paisaje como los datos climáticos (precipitaciones, niebla y nubes bajas) fueron agregados a nivel de unidad hidrográfica, mediante el promedio de los valores de cada celda contenida en dichas unidades. Sobre esta base, se realizó una prueba de normalidad de Shapiro-Wilk (Shapiro y Wilk, 1965) con el fin de verificar los supuestos del análisis estadístico. Al confirmarse la normalidad de los datos, se aplicó un análisis de varianza (ANOVA) para evaluar diferencias significativas entre subcuencas. Posteriormente, se utilizó la prueba post hoc de Tukey (Tukey, 1949) para identificar diferencias estadísticamente significativas entre grupos, lo que permitió representar gráficamente las medias y sus respectivas comparaciones.

Análisis a escala subregional

El análisis a escala subregional se realizó considerando la totalidad de las subcuencas incluidas en el área de estudio, aplicando de manera integrada las metodologías definidas para evaluar los patrones y relaciones presentes en el territorio.

Determinar los predictores bioclimáticos de la distribución geográfica de bosque nativo costero.

Las variables bioclimáticas se calcularon a partir de los datos grillados del CR2MET, utilizando 20 años de datos (2000-2020). Estos datos grillados han sido procesados a nivel nacional (Boisier, 2023), lo que asegura mayor precisión en el área de estudio (Bedia *et al.*, 2013). Estudios de distribución de especies han demostrado que resoluciones gruesas pueden ser útiles para modelar patrones generales de distribución, especialmente en escalas amplias (Guisan *et al.*, 2007, 2017).

Para el cómputo de las variables bioclimáticas se utilizaron los métodos de cálculo de 35 variables bioclimáticas descritas por Noce *et al.* (2020). Para seleccionar estas variables, en primer lugar, se priorizaron las variables relacionadas con la ecología del bosque y la vegetación, especialmente aquellas que afectan directamente procesos vitales como la fotosíntesis y la transpiración (Zomer *et al.*, 2014). En segundo lugar, se analizaron las interacciones bioclimáticas, evaluando cómo la combinación de las variables de temperatura y precipitación impacta la fisiología de los árboles y la dinámica del ecosistema, es decir, como podría ser las altas temperaturas combinadas con bajas precipitaciones la principal causa de la muerte de árboles (Allen *et al.*, 2015). Por último, se seleccionaron variables que reflejen la variabilidad estacional y anual del clima, fundamentales para comprender las adaptaciones del bosque a los cambios y fluctuaciones ambientales. Este proceso incluyó también variables que representen condiciones extremas, esenciales para garantizar la supervivencia del bosque (Keenan, 2015).

Además, se adaptaron las variables al contexto particular del ecosistema costero semiárido, donde la niebla desempeña un papel determinante en la dinámica del bosque (Gutiérrez *et al.* 2008). Para incorporar la niebla, se generaron ocho variables bioclimáticas basadas en datos de niebla y nubes bajas frecuentes en la costa central de Chile, empleando información procesada de los satélites GOES 8-16 (Torregrosa *et al.*, 2016; del Río *et al.*, 2021; Espinoza *et al.*, 2024). Las variables bioclimáticas seleccionadas se detallan en el Cuadro 2. Estas se ajustaron a la resolución espacial y temporal de los datos grillados del CR2 para asegurar la compatibilidad entre conjuntos de datos.

Cuadro 2 Criterio de selección de variables bioclimáticas

Filtro de selección	Variables Bioclimáticas Seleccionadas.
Relevancia Ecológica (Zomer <i>et al.</i> , 2014)	• Bio1 (Temperatura media anual) • Bio8 (Temperatura media del trimestre más húmedo) • Bio9 (Temperatura media del trimestre más seco) • Bio12 (Precipitación anual) • Bio16 (Precipitación del trimestre más húmedo) • Bio17 (Precipitación del trimestre más seco) • Bio34 (Evapotranspiración potencial Thornthwaite).
Interacciones Bioclimáticas (Allen <i>et al.</i> , 2015)	• Bio8 (Temperatura media del trimestre más húmedo) • Bio9 (Temperatura media del trimestre más seco) • Bio16 (Precipitación del trimestre más húmedo) • Bio17 (Precipitación del trimestre más seco) • Bio18 (Precipitación del trimestre más cálido).
Variabilidad y Extremos Climáticos (Keenan, 2015)	• Bio2 (Rango diurno medio) • Bio4 (Estacionalidad de la temperatura) • Bio7 (Rango anual de temperatura) • Bio5 (Temperatura máxima del mes más cálido) • Bio15 (Estacionalidad de la precipitación).
Contexto Específico del Ecosistema del Bosque Costero del semiárido.	• Días de niebla o nubes bajas a nivel anual, • Días de niebla o nubes bajas del mes más abundante, • Días de niebla o nubes bajas del mes más escaso, • Días de niebla o nubes bajas del trimestre más abundante, • Días de niebla o nubes bajas del trimestre más escaso, • Días de niebla o nubes bajas del trimestre más cálido, • Días de niebla o nubes bajas del trimestre más frío, • Estacionalidad de los días de niebla o nubes bajas.

Para identificar los mejores predictores bioclimáticos se empleó el algoritmo de aprendizaje automático máxima entropía (MaxEnt) (Elith *et al.*, 2011). MaxEnt utiliza datos de ocurrencia y variables ambientales para evaluar qué factores tienen mayor peso en el desarrollo del modelo que determina la configuración espacial del hábitat del bosque costero (Phillips *et al.*, 2006). A través de su enfoque basado en el principio de máxima entropía, se asignan probabilidades a cada variable, lo que permite determinar cuáles son los predictores más relevantes, es decir, aquellos que mejor explican la configuración espacial de la distribución del bosque (Elith *et al.*, 2011).

El uso del algoritmo de máxima entropía (MaxEnt) requiere ciertas precauciones para garantizar resultados precisos y confiables. Un error común es confiar únicamente en los parámetros predeterminados, lo cual puede no ser adecuado en todos los casos (Morales *et al.*, 2017). Para optimizar el desempeño de MaxEnt, es fundamental seleccionar correctamente los parámetros y métricas a modelar, ya que esto permite obtener resultados robustos incluso cuando se trabaja con un número limitado de puntos de presencia (Shcheglovitova y Anderson, 2013). Los tipos de características (*Feature Classes*) desempeñan un rol crucial, ya que definen cómo se establecen las relaciones entre las variables ambientales y los puntos de presencia de la especie. Estas características incluyen opciones como lineales, que modelan relaciones simples; cuadráticas, diseñadas para capturar relaciones no lineales; *hinge*, que representan cambios graduales; de umbral, que categorizan las condiciones ambientales; y de producto, que modelan interacciones entre

variables (Elith *et al.*, 2011). La selección adecuada de estas clases es esencial para evitar problemas como el sobreajuste o la excesiva simplificación del modelo (Morales *et al.*, 2017).

Para definir los parámetros de MaxEnt se compararon varios modelos que combinan los parámetros "feature class" y "regularization multiplier" (Warren y Seifert, 2011; Shcheglovitova y Anderson, 2013). La evaluación de estos modelos se realizó utilizando el criterio de información de Akaike corregido (AICc), disponible en el software ENMTOOLS versión 1.4.4 (Warren y Seifert, 2011). El modelo óptimo es aquel que tenga la combinación de "feature class" y "regularization multiplier" con el valor de AICc más bajo (Shcheglovitova y Anderson, 2013).

Los puntos de presencia que se utilizaron para alimentar el algoritmo MaxEnt fueron generados a partir de la ubicación de los bosques nativos en el mapa de bosques descrito en el objetivo anterior. El propósito fue identificar las variables bioclimáticas que determinan la presencia del bosque en la región. Se generaron 372 puntos de presencia de manera aleatoria sobre la capa vectorial ajustada, asegurando una distancia mínima de 5 km entre ellos para evitar el sobreajuste (Boria *et al.*, 2014) y garantizó que cada punto represente una celda climática específica. Además, se eliminaron aquellos puntos en los que la superficie de bosque fue inferior al 20% dentro de las celdas climáticas, con el objetivo de excluir áreas donde la cobertura del bosque nativo es insuficiente (Hansen *et al.*, 2013). Resultando 42 puntos de presencia que cumplieron este objetivo.

Dado que los valores predictivos altamente correlacionados pueden sesgar el modelo, se realizó un análisis de correlación y se seleccionaron variables que no estén altamente correlacionadas (Elith *et al.*, 2011), pero que aporten información relevante al modelo, con el fin de reducir la redundancia de variables que expliquen un mismo fenómeno.

Para identificar cuáles variables bioclimáticas proporcionaron más información sobre la distribución del bosque, se utilizó la prueba de Jackknife, que permite evaluar qué variables, explican mejor la distribución del bosque (Elith *et al.*, 2011). Se seleccionaron aleatoriamente el 10% de los puntos de presencia, los cuales no fueron usados para calibrar el modelo, usados para validar el resultado. Esta validación permitió calcular la precisión del modelo y se complementa con una matriz de confusión, con el cual se calculó el coeficiente Kappa (West *et al.*, 2016) como indicador de precisión global del modelo ajustado.

Analizar el vigor de la vegetación del bosque nativo costero con la ocurrencia de eventos climáticos.

Para analizar el vigor de la vegetación del bosque nativo costero en relación con eventos climáticos, se utilizaron datos MODIS (MOD13Q1 y MYD13Q1) obtenidos a través de Google Earth Engine, abarcando el período 2000-2021 con una resolución espacial de 250 m por píxel. El NDVI es un indicador clave para evaluar el vigor de la vegetación y su relación con la precipitaciones, nubes bajas y niebla (Huete *et al.*, 2010).

Se aislaron los píxeles más representativos del bosque nativo costero a partir del mapa de cobertura generado en el Objetivo 1, utilizando datos MODIS a 250 m de resolución. Se incluyeron únicamente aquellos píxeles con más del 50 % de cobertura arbórea (Hansen *et al.*, 2013), garantizando así que la muestra refleje fielmente la condición de los bosques en el área de estudio, excluyendo así áreas con vegetación dispersa o baja densidad. Como resultado, de un total de 32.303 píxeles MODIS con algún grado de cobertura forestal (valor > 0), solo 8.967 superaron el umbral, lo que representa una reducción del 72,2% en la superficie clasificada como bosque.

Se decidió utilizar únicamente las variables hídricas para el análisis del vigor de la vegetación, ya que el agua representa el principal factor limitante para el bosque nativo en la zona semiárida (Rotenberg y Yakir, 2010).

Los datos de precipitación y niebla/nubes bajas se analizó a nivel anual utilizando años hidrológicos, del 1 de abril hasta el 31 de marzo del año siguiente, lo que permitió capturar mejor los ciclos climáticos asociados a la disponibilidad hídrica (Hernandez *et al.*, 2022). Posteriormente, se aplicó una prueba de autocorrelación temporal para identificar dependencias estructurales, periodicidades significativas y patrones climáticos clave en estas variables (Tiao *et al.*, 1990). Este enfoque permite una comparación robusta entre los periodos anuales y las variaciones de precipitación y niebla/nubes bajas, facilitando el análisis de relaciones temporales y su impacto en los ecosistemas costeros. Para todo el bosque del área de estudio.

Para correlacionar el NDVI con las precipitaciones, nubes bajas y niebla, se calculó el NDVI medio correspondiente a los tres meses de verano (enero, febrero y marzo) posteriores a la temporada de lluvias (Van Leeuwen *et al.*, 2013). Este enfoque permitió evaluar el efecto de la disponibilidad hídrica sobre el vigor de la vegetación durante la temporada seca omitiendo el efecto que podrían tener las herbáceas (Asner *et al.*, 2003). Además, se calculó el NDVI de primavera que consta la señal de NDVI del conjunto de la vegetación posterior al invierno (octubre, noviembre, diciembre). Solo se utilizarán aquellas celdas climáticas (precipitaciones, nubes bajas y niebla) que contengan al menos un 20% de datos asociados a áreas de bosque, asegurando así la representatividad de las condiciones climáticas locales (Hansen *et al.*, 2013). Lo que resultan en 42 celda, previamente utilizados en el objetivo 2.

Dada la no normalidad en dos de las cuatro variables evaluadas y la ausencia de autocorrelación temporal significativa, se justifica el uso de un enfoque no paramétrico para el análisis de tendencias (Adhikari *et al.*, 2023). En particular, el estadístico τ de Kendall, que no asume distribución normal ni independencia estricta entre observaciones cercanas en el tiempo, es adecuado para evaluar cambios temporales en estas series (Kendall, 1938). Para dichas correlaciones se separaron en periodos cada 5 años para observar el efecto de la sequía en los valores.

Influencia espacial de la precipitación y niebla nubes bajas sobre el NDVI

Con el objetivo de evaluar la influencia espacial de la precipitación y las nubes bajas sobre la vegetación, se aplicaron modelos de regresión lineal simple robusta entre la media histórica del NDVI de verano y las medias históricas anuales de precipitación y niebla y nubes bajas

media para cada punto geográfico, donde cada punto representa el centro de una celda climática de 5 km de lado.

Para asegurar que los resultados fueran representativos del conjunto del territorio y evitar la influencia de celdas con cobertura forestal nula o residual, se consideraron únicamente aquellas con una cobertura de bosque igual o superior al 1 % dentro de la grilla climática. La cobertura se estimó a partir de píxeles MODIS, considerando como bosque únicamente aquellos píxeles con una cobertura arbórea mínima del 50 %. Este criterio se estableció para excluir unidades espaciales con cobertura irrelevante que pudieran introducir ruido estadístico y no reflejar procesos ecológicos asociados al bosque. Al mismo tiempo, permite conservar áreas altamente fragmentadas, pero con masa arbórea suficiente para interactuar con las variables climáticas de interés, evitando la pérdida de señal en zonas con baja densidad forestal. La elección de un umbral bajo también tuvo como objetivo maximizar la cobertura espacial del análisis y garantizar la generalización de los resultados a todo el territorio, manteniendo la comparabilidad con estudios previos que utilizan criterios similares para reducir sesgos de presencia ausente en paisajes heterogéneos.

La elección de modelos robustos responde a su capacidad para manejar posibles problemas de heterocedasticidad en los datos (White, 1980). Antes de implementar estos modelos, se evaluaron los supuestos estadísticos clásicos asociados a la regresión lineal. Se verificó la linealidad de la relación entre las variables mediante la inspección visual de los diagramas de dispersión, y se comprobó la normalidad de los residuos utilizando la prueba de Shapiro–Wilk (Shapiro y Wilk, 1965). Asimismo, la homocedasticidad fue evaluada a través de la prueba de Breusch–Pagan (Breusch y Pagan, 1979). En aquellos casos donde se detectó heterocedasticidad, se optó por el uso de errores estándar robustos tipo Huber–White, que permiten obtener estimaciones válidas aun cuando no se cumple el supuesto de varianza constante (White, 1980).

RESULTADOS

Delimitación del bosque nativo

El análisis de clasificación supervisada arrojó un total de 591 km² de bosque nativo, lo que representa aproximadamente el 14,5% del área de estudio. Las métricas generales del modelo reflejaron un buen desempeño, con una precisión global de 0,94 y un índice Kappa de 0,92, lo que indica un alto grado de acuerdo entre las clases predichas y las reales. El modelo demostró ser confiable en términos generales, y particularmente eficaz en la detección del bosque nativo, que constituye el foco principal de este estudio.

Para evaluar el desempeño específico del modelo en esta cobertura, se realizó un análisis de clasificación binaria considerando únicamente la clase bosque nativo frente al resto de las clases. Los resultados indicaron métricas sobresalientes: precisión = 99,1%, recall = 96,3% y F1-score = 97,7%. Estas cifras indicaron que el modelo identificó correctamente la gran mayoría de los píxeles que realmente corresponden a bosque nativo, y que los errores de clasificación hacia otras coberturas fueron mínimos. El alto valor de F1-score refleja un excelente equilibrio entre precisión (evitar falsos positivos) y recall (no omitir verdaderos positivos). Estas métricas son especialmente relevantes en escenarios con clases desbalanceadas, donde la precisión global puede no reflejar correctamente el rendimiento en clases específicas.

Adicionalmente, se evaluó la capacidad del modelo para distinguir entre bosque nativo y matorral, dos coberturas que comparten similitudes espectrales y espaciales. El análisis binario entre ambas clases arrojó también resultados destacados, con un F1-score de 0,98, una precisión de 99,1% y un recall de 96,3%. Estos resultados confirmaron que el modelo distingue con alta efectividad entre estas dos clases, lo que refuerza su utilidad para análisis territoriales y ecológicos más finos. En conjunto, se concluye que el modelo es altamente efectivo para representar espacialmente el bosque nativo y discriminarlo frente a otras coberturas.

Validación de Datos GOES

Los datos de la presencia de niebla y nubes bajas y la captación de agua en los colectores del Parque Nacional Bosque Fray Jorge tuvieron un coeficiente de Spearman de 0,36 al analizar la relación mes a mes, lo que indica una correlación moderada y estadísticamente significativa. Al aplicar un promedio móvil de tres meses a las series temporales, este coeficiente aumentó a 0,57 con un valor $p < 0,0001$, lo que refuerza la solidez estadística de la relación observada y sugiere que el suavizado temporal mejora la detección, posiblemente debido a una influencia acumulativa de las condiciones atmosféricas que generan niebla sobre la eficiencia de los colectores. Complementariamente, el gráfico obtenido (Figura 2) mediante el método de suavizado LOWESS reveló una tendencia creciente moderada entre

los días con niebla o nubes bajas y el volumen de agua recolectada, destacando una relación que, si bien no es perfectamente lineal, sí mostró una progresión coherente.




Figura 2 Correlación de Spearman Agua recolectada vs Niebla y nubes bajas. El gráfico muestra una relación positiva entre la frecuencia mensual de niebla y nubes bajas y el volumen de agua recolectada (media móvil de 3 meses). La línea azul representa un suavizado LOWESS que revela una tendencia creciente moderada. Esta relación está respaldada por un coeficiente de Spearman de 0,57 con un valor $p < 0,0001$, indicando una correlación significativa.

Análisis a escala de subcuenca

Índices de paisaje análisis a nivel de subcuenca

Todas las variables analizadas cumplieron con los supuestos de normalidad, según la prueba de Shapiro-Wilk (precipitación: $W = 0,96$, $p = 0,82$; niebla: $W = 0,93$, $p = 0,45$; densidad de parches: $W = 0,95$, $p = 0,67$; densidad de borde: $W = 0,96$, $p = 0,74$), por lo que se aplicó un análisis de varianza (ANOVA) seguido de la prueba post hoc de Tukey HSD ($\alpha = 0,05$) para identificar diferencias significativas entre subcuencas.

La subcuenca **LL** presentó el mayor porcentaje de cobertura forestal (25,5%), seguida por **LP** (21,3%) y **CQP** (20,8%), lo que sugiere una mayor conservación o regeneración del

bosque nativo en estas áreas (Figura 3). En contraste, **MP** registró la cobertura forestal más baja (3,3%), acompañada de valores bajos tanto en densidad de parches como en densidad de borde, lo que refleja un paisaje más abierto y posiblemente más degradado.

Se observaron diferencias marcadas en los patrones de fragmentación del bosque entre subcuencas con precipitaciones similares. Por ejemplo, aunque **EP** y **LL** presentaron niveles comparables de precipitación, ambas mostraron las mayores densidades de parches, lo que indica una mayor fragmentación del bosque en esas zonas.

Finalmente, la comparación entre precipitación y niebla reveló que ambas variables no siempre coinciden en magnitud. Subcuencas como **CEQ** y **CLC** presentan precipitaciones similares, pero difieren significativamente en la frecuencia de niebla y nubes bajas, lo que puede tener implicancias ecológicas relevantes, especialmente en términos de disponibilidad hídrica efectiva y condiciones para el desarrollo vegetal.




Figura 3 Patrones de precipitación, niebla, nubes bajas, fragmentación del bosque y cobertura forestal por subcuenca. Se presentan las medias por subcuenca de cuatro métricas climáticas y del paisaje: a) precipitación anual acumulada media por celda climática dentro de cada subcuenca, calculada para un periodo de 20 años (barras azules, mm; eje Y izquierdo), y número de días con niebla y nubes bajas al mes, promedio por celda climática en la subcuenca durante el mismo periodo (barras celestes; eje Y derecho); b) densidad de parches de bosque (barras verde claro, número de parches por 100 ha); c) densidad de borde de bosque (barras verde oscuro, metros de borde por hectárea); y d) porcentaje de superficie forestal (barras marrón, %, valores anotados sobre cada barra) en el cuarto panel. En el eje horizontal figuran los códigos de subcuenca (CEQ, CLC, CQP, LQ, LL, LP, EP, MQ, UQ, MP) y las letras sobre cada barra corresponde a los grupos homogéneos definidos mediante la prueba post hoc de Tukey HSD ($\alpha = 0,05$).

No se observó una relación entre la frecuencia de niebla y las métricas de paisaje. Subcuencas como CEQ y CLC presentaron una mayor proporción de días con niebla y nubes bajas, pero no registraron los valores más altos de cobertura forestal ni los más bajos en fragmentación. Por otro lado, subcuencas con alta cobertura forestal, como LL y LP, mostraron niveles intermedios de niebla. Las métricas de fragmentación, como la densidad de parches y la densidad de borde, también variaron entre subcuencas sin un patrón claro en relación con la niebla.

Análisis a escala subregional

Predictores bioclimáticos de la distribución geográfica de bosque nativo costero.

Para la elaboración de los datos de presencia, se aplicó un filtro que aseguran una cobertura boscosa >20%, obteniendo así un conjunto de datos más preciso y representativo. Como resultado, se identificaron 42 celdas climáticas que cumplen con el umbral establecido. Aunque esta cantidad puede parecer limitada, cada píxel corresponde a una superficie de 25 km² (resolución espacial de 5 km por lado), lo que se traduce en una cobertura boscosa relevante que abarca aproximadamente 1.050 km², una superficie significativa para los objetivos del análisis.

El preanálisis de optimización realizado con ENMeval, que identifica la combinación más parsimoniosa entre clases de funciones (*feature classes*) y multiplicadores de regularización (*regularization multiplier*), indicó que la mejor combinación correspondió al uso de funciones lineales y cuadráticas, con un multiplicador de regularización de 3. Esta selección se basó en el valor más bajo del Criterio de Información de Akaike corregido (AICc), que fue de 415,4.

En un primer análisis con MaxEnt, se utilizaron las 21 variables bioclimáticas disponibles. Posteriormente, se aplicó una agrupación jerárquica basada en la matriz de correlación entre variables, lo que permitió identificar seis grupos. De cada grupo se seleccionó la variable que presentó la mayor contribución al modelo final.

El análisis de Jackknife (Figura 4) realizado con las variables seleccionadas mostró que la estacionalidad de los días de niebla o nubes bajas (DNB_CV) fue la variable con mayor aporte individual al modelo, tanto por su ganancia en solitario, como por la caída de ganancia al ser excluida, lo que indica su alta relevancia para la predicción de la distribución. La precipitación anual (BIO12) también mostró una contribución importante, especialmente reflejada en la fuerte pérdida de ganancia al ser retirada del modelo. En contraste, variables como BIO 15 (Estacionalidad de la precipitación) y BIO 18 (Precipitación del trimestre más cálido) tuvieron baja y nula ganancia individual, pero su exclusión aún produjo una caída en la ganancia total, lo que sugiere que aportan información complementaria en combinación con otras variables.




Figura 4 Análisis Jackknife indicando la ganancia en solitario y caída de ganancia. Se presenta la ganancia obtenida al utilizar cada variable de forma independiente (barras azules) y la reducción de ganancia al excluirla del conjunto completo de predictores (barras naranjas).

La Figura 5 muestra la variación de las métricas de precisión y Kappa en función del umbral de probabilidad de presencia utilizado para convertir las predicciones continuas del modelo MaxEnt en clasificaciones binarias. Este análisis permite estimar la capacidad explicativa individual de cada variable y su contribución exclusiva al desempeño del modelo, ofreciendo una evaluación sólida de su relevancia en la modelación de la distribución potencial. El desempeño del modelo MaxEnt fue evaluado a través del comportamiento de las métricas de precisión y del índice de Kappa frente a distintos umbrales de probabilidad de presencia. Se observó una mejora sostenida en ambas métricas a medida que aumentaba el umbral, con

valores máximos registrados en torno a 0,95. En este rango, el modelo alcanza su mayor capacidad para discriminar correctamente entre presencias y ausencias, tanto en términos absolutos como ajustados por azar.




Figura 5 Precisión e índice de Kappa según umbral de probabilidad. El eje X representa el umbral de probabilidad de presencia (de 0 a 1), mientras que el eje Y muestra los valores de cada métrica de desempeño. La precisión aumenta progresivamente con el umbral, alcanzando su valor máximo (~0,9) en torno a 0,95, lo que indica una mayor proporción de clasificaciones correctas en ese rango. El índice de Kappa, que ajusta el acuerdo observado por el esperado por azar, también incrementa hasta un valor máximo aceptable (~0,6), para luego disminuir abruptamente.

Análisis del vigor de la vegetación del bosque nativo costero con la ocurrencia de eventos climáticos.

Las pruebas de normalidad indicaron que la precipitación y la niebla totales no presentaron desviaciones significativas respecto a la normalidad ($p = 0,46$ y $p = 0,35$, respectivamente), los valores de NDVI en primavera y verano mostraron distribuciones significativamente diferentes a la normal ($p = 0,008$ y $p = 0,03$, respectivamente), lo que sugiere una mayor asimetría en la respuesta estacional de la vegetación.

En cuanto a la autocorrelación temporal, se observó una persistencia moderada en la serie de niebla total (ACF lag 1 = 0,47), seguida por precipitaciones (ACF lag 1 = 0,12) y NDVI en verano (ACF lag 1 = 0,14). El NDVI primaveral mostró una autocorrelación más baja (ACF lag 1 = 0,04), lo que indica una mayor variabilidad interanual durante esa estación. La ACF representa el grado de correlación de una variable con sus propios valores en diferentes momentos del tiempo; en este caso, el *lag 1* refleja la relación entre valores anuales

consecutivos. En general, las variables mostraron una tendencia decreciente de autocorrelación a medida que aumentaba el desfase temporal, lo que sugiere una pérdida progresiva de dependencia temporal en sus fluctuaciones interanuales.




Figura 6 Correlación entre NDVI y variables climáticas por períodos quinquenales (2000–2019). La figura presenta los coeficientes de correlación de Kendall (τ) entre el NDVI de

verano y primavera, respectivamente, y dos variables climáticas, considerando 42 celdas con más de un 20 % de cobertura de bosque nativo. Las variables climáticas incluidas son— precipitación anual (mm) para el año hidrológico (barras amarillas) y días con niebla y nubes bajas anual (días al mes) año hidrológico (barras naranjas)— para las estaciones de verano (a) y primavera (b), divididas en cuatro periodos quinquenales. Todos los coeficientes reportados son estadísticamente significativos ($p < 0,05$).

El análisis de correlación reveló asociaciones significativas entre el NDVI y las variables climáticas evaluadas en distintos periodos. Estas asociaciones fueron calculadas por estación y agrupadas en bloques quinquenales para capturar su variación en el tiempo (Figura 6). El análisis de correlación de Kendall, aplicado por bloques quinquenales y diferenciando estaciones, revela patrones contrastantes en la influencia de la niebla y la precipitación sobre el vigor estacional de la vegetación nativa costera. Durante el verano, la niebla exhibe de manera consistente una mayor correlación con el NDVI en comparación con la precipitación, con coeficientes τ que aumentan progresivamente desde 0,27 (2000–2005) hasta 0,46 (2016–2019). En el mismo periodo, la correlación de la precipitación con el NDVI estival también muestra un incremento, aunque menos pronunciado (de 0,16 a 0,38). Este aumento sostenido sugiere que, con el paso del tiempo, la influencia climática —en particular la de la niebla— sobre la productividad estival de la vegetación se ha intensificado.

En primavera, en cambio, la relación entre el NDVI y las variables climáticas muestra una dinámica inversa: la precipitación tiende a presentar una correlación ligeramente superior (τ entre 0,24 y 0,44) respecto a la niebla (τ entre 0,17 y 0,42), con la excepción del periodo 2006–2010, donde la niebla supera marginalmente a la precipitación (0,23 vs. 0,22). Al igual que en verano, ambas variables climáticas incrementan su correlación con el NDVI en los bloques más recientes, alcanzando sus valores máximos en 2016–2019, todos estadísticamente significativos ($p < 0,05$). En conjunto, estos hallazgos indican que la sensibilidad de la vegetación al aporte hídrico —tanto por niebla como por precipitaciones— ha ido en aumento, consolidando a la niebla como un modulador más estable en verano, mientras que en primavera la precipitación mantiene un rol ligeramente más preponderante en la activación del crecimiento vegetal.

Modelos de regresión lineal robusto, relación NDVI aportes hídricos, relación espacial

Se analizaron modelos de regresión lineal simple entre el NDVI promedio de verano y dos variables climáticas: la frecuencia media de niebla y nubes bajas, y la precipitación total media mensual. En el caso de la niebla, se observó una relación positiva, mientras que para la precipitación no se identificó un patrón claro en los datos (Figura 7). La normalidad de los residuos fue evaluada mediante la prueba de Shapiro-Wilk, que no rechazó la hipótesis nula de normalidad en ninguno de los modelos ($p = 0,24$ para el modelo NDVI ~ niebla; $p = 0,28$ para NDVI ~ precipitación), lo cual respalda este supuesto.

Sin embargo, la prueba de Breusch-Pagan indicó la presencia de heterocedasticidad en el modelo NDVI ~ niebla ($p = 0,02$), mientras que no detectó varianza no constante en el modelo NDVI ~ precipitación ($p = 0,41$). Debido a esta violación del supuesto de homocedasticidad,

se optó por utilizar errores estándar robustos tipo Huber-White, lo que permitió mantener la validez de las inferencias estadísticas sin necesidad de transformar las variables.

Bajo estas condiciones, ambos modelos fueron ajustados utilizando regresión lineal robusta. El modelo NDVI ~ niebla presentó un mejor ajuste ($R^2 = 0,39$), en comparación con el modelo NDVI ~ precipitación, que no explicó la variabilidad observada ($R^2 = 0,01$). El análisis de la varianza (ANOVA) para el modelo con niebla indicó que la variable explicativa fue altamente significativa ($p < 0,001$), con una pendiente positiva de 0,03 y un intervalo de confianza que no incluye el cero, lo que respalda la solidez estadística del ajuste. En contraste, el modelo con precipitación mostró una pendiente negativa de -0,0002 y un valor p de 0,41, indicando ausencia de significancia estadística. Asimismo, el valor del estadístico F fue de 5,96 para el modelo con niebla, frente a 0,68 para el modelo con precipitación, confirmando que solo el primero explica una proporción significativa de la varianza total del NDVI de verano.




Figura 7 Relación espacial entre el NDVI promedio de verano y la precipitación anual media (mm) y niebla nubes bajas (días al mes). Cada punto corresponde a una celda espacial de la grilla climática que contiene bosque, en la cual se calcularon los promedios históricos de 20 años (2000-2020) de NDVI estival, precipitación anual y frecuencia de niebla/nubes bajas. En el panel a) se observa una asociación positiva con la frecuencia media de niebla y nubes bajas ($R^2 = 0,39$; $p < 0,001$), mientras que en el panel b) la relación con la precipitación total media mensual no es significativa ($R^2 = 0,008$; $p = 0,43$). Se emplearon modelos de regresión lineal robusta para reducir la influencia de valores atípicos.

DISCUSIÓN

Los resultados de esta investigación confirman que la niebla costera constituye un factor clave para entender la distribución y vigor del bosque nativo en zonas semiáridas. En particular, se observó que la frecuencia y persistencia de niebla detectadas con sensores satelitales se relacionan positivamente con el vigor estival de la vegetación y con la distribución espacial del bosque costero. Estos hallazgos adquieren especial relevancia en un contexto de cambio climático y disminución de precipitaciones, ya que revelan una creciente dependencia hacia fuentes hídricas no convencionales. En esta discusión, se abordan los principales hallazgos a partir de seis ejes: a) el uso de datos satelitales GOES para estimar el aporte hídrico de la niebla, b) los resultados de la clasificación supervisada del bosque, c) los análisis sobre la estructura del paisaje, d) los patrones de distribución modelados mediante MaxEnt, e) la relación entre vigor vegetal, niebla y precipitación; f) limitaciones.

El uso de datos satelitales GOES para estimar el aporte hídrico de la niebla

Existe una correlación positiva y significativa entre los litros de agua recolectada y el porcentaje mensual de días con niebla o nubes bajas obtenidos del GOES ($r = 0,57$; $p < 0,0001$, media móvil de 3 meses) en el Parque Nacional Fray Jorge se destaca el valor de este sensor como una aproximación confiable para el monitoreo indirecto de los aportes provenientes de la niebla costera. Este resultado es congruente con los estudios previos realizados en zonas costeras áridas y semiáridas del norte de Chile, como los de Del Río *et al.* (2021) y Espinoza *et al.* (2024), donde el índice de nubes bajas y niebla de GOES mostraron una buena relación con datos de captación de niebla y condiciones climáticas regionales.

Es importante reconocer las limitaciones inherentes al enfoque satelital. Como señalan Lobos *et al.* (2024), GOES no distingue de forma entre niebla (contacto con el suelo) y nubes bajas suspendidas, lo que provoca incertidumbre al interpretar los eventos de niebla y nubes bajas. La formación y advección de niebla depende de múltiples factores atmosféricos y geográficos, incluyendo la altitud local, la orientación topográfica, la temperatura de la superficie del mar, la intensidad de la inversión térmica, y la dinámica de capa límite (Cereceda *et al.*, 2008; del Río *et al.*, 2021). Estos procesos determinan si las nubes detectadas por satélites realmente se traducen en eventos de niebla capaces de generar recolección hídrica.

A pesar de estas limitaciones, los resultados obtenidos confirman que el porcentaje mensual de Nubes bajas y niebla observado por GOES es un proxy robusto y aplicable para evaluar tendencias en la presencia de niebla (Torregrosa *et al.*, 2016; del Río *et al.*, 2021). En esta misma línea, GOES permitió inferir que, en otros sectores de bosque, donde la niebla es captada por sistemas forestales, el uso del satélite representa una aproximación válida para presentar la disponibilidad hídrica asociada a estos eventos. Esto refuerza su potencial como herramienta para identificar zonas con aporte hídrico atmosférico, incluso en ausencia de mediciones directas.

Los resultados de la clasificación supervisada del bosque

Random Forest (RF) presentó buenos resultados para distinguir entre distintas coberturas de vegetación particularmente entre matorrales y formaciones arbóreas. Esta capacidad discriminación coincide con hallazgos de estudios previos que destacan la eficacia de los algoritmos de clasificación supervisada para identificar diferencias en la vegetación (Gislason *et al.*, 2006; Rodríguez *et al.*, 2012). La precisión obtenida refuerza el potencial del enfoque RF como una herramienta confiable para identificar espacialmente coberturas arbóreas en zonas de transición ecológica como los bosques costeros semiáridos (Mellor *et al.*, 2013).

La combinación de índices de paisaje con el catastro de vegetación nativa de CONAF demostró que el uso de clasificaciones supervisadas mejora la resolución espacial y temática del catastro oficial, pasando de 6,25 ha de unidad mínima cartografiada a 900 m² que representa un píxel de la serie Landsat (Wulder *et al.*, 2022). Esta resolución más fina permite una mayor precisión en la identificación de coberturas, omitiendo criterios administrativos inherentes del catastro de CONAF (CONAF, 2020).

El mapa de clasificación supervisada ofrece una ventaja significativa al momento de filtrar los píxeles de la serie MODIS, lo cual es fundamental para el análisis posterior del NDVI. Dado que la resolución espacial de MODIS es de 250 m, contar con un mapa de mayor resolución permite identificar con mayor precisión qué píxeles representan efectivamente el bosque costero. Además, este tipo de clasificación posibilita el análisis y cálculo de métricas espaciales relacionadas con la forma, tamaño y grado de fragmentación de los parches de vegetación (Hernández *et al.*, 2016).

En los ecosistemas esclerófilos semiáridos, la distinción entre matorral y bosque constituye un desafío debido a la alta solapabilidad de las firmas espectrales en las bandas visible e infrarrojo cercano (Jupp y Walker, 1997). No obstante, al incorporar de forma conjunta las seis bandas ópticas de Landsat 4, 5 y 7 (incluyendo SWIR1 y SWIR2, sensibles al contenido de humedad y estructura foliar) (Mellor *et al.*, 2013), el modelo Random Forest pudo explotar las sutiles diferencias en reflectancia y textura que separan ambos estratos.

El carácter no lineal y multivariado del algoritmo Random Forest permitió manejar adecuadamente la complejidad espectral del paisaje y la similitud entre clases como matorral y bosque, que representan un desafío frecuente en procesos de clasificación supervisada. A pesar del solapamiento en las firmas espectrales de ambas coberturas, el modelo logró una alta precisión, alcanzando un F1-score de 0,98. Este resultado confirma no solo la solidez técnica del enfoque utilizado, sino también su utilidad para apoyar el análisis territorial y ecológico en contextos de vegetación heterogénea.

Los análisis sobre la estructura del paisaje

La relación entre la niebla y las métricas de paisaje mostró una asociación débil, evidenciando poca correspondencia entre la frecuencia de niebla y la forma o configuración de los parches de bosque. Estas métricas resultaban pertinentes de evaluar porque permiten explorar si los

patrones espaciales de la cobertura boscosa —como la fragmentación, el borde o la cantidad de hábitat disponible— pueden influir sobre la presencia o persistencia de niebla, dado que la estructura del paisaje puede modular procesos atmosféricos locales y ciclos hidrológicos.

Sin embargo, los resultados sugieren que la influencia de la niebla opera probablemente a escalas espaciales o través de mecanismos ecológicos que no son capturados por las métricas geométricas consideradas. Aunque se esperaba una relación positiva entre el porcentaje de cobertura boscosa y la frecuencia de niebla, esta variable no fue explicativa en el análisis espacial (Gutiérrez et al., 2008; Barbosa et al., 2010).

Es posible que factores no incluidos en este modelo —como la complejidad topográfica, la exposición a vientos húmedos o las perturbaciones antrópicas— limiten la capacidad explicativa de las métricas del paisaje para reflejar la dinámica espacial de la niebla.

Sin embargo, como se evidenció en los análisis con MaxEnt, la niebla —y en particular el coeficiente de variación de su ocurrencia— resultó ser el predictor bioclimático más importante para explicar la distribución del bosque costero. Esto confirma que, aunque su influencia no se manifieste directamente en la forma o tamaño de los parches actuales, la niebla desempeña un rol clave en sostener y modelar la variabilidad espacial del bosque en condiciones climáticas limitantes.

Los patrones de distribución modelados mediante MaxEnt

El modelo MaxEnt indica que los factores bioclimáticos más relevantes para explicar la distribución del bosque nativo costero fueron el coeficiente de variación de nubes bajas y niebla. Este resultado es consistente con estudios anteriores que destacan la importancia de la niebla como factor climático clave en ecosistemas costeros semiáridos (del Val *et al.*, 2006; Garreaud *et al.*, 2008). Que esta variable sea la que más contribuye al modelo sugiere que la estabilidad y frecuencia de la niebla podría estar actuando como un modulador crítico de las condiciones para su persistencia del bosque (Gutiérrez *et al.*, 2008).

Cabe señalar que, si bien inicialmente se obtuvieron 372 puntos de presencia, este número elevado se relaciona principalmente con la resolución relativamente gruesa de las capas climáticas utilizadas, lo que generó un gran número de celdas potencialmente aptas. Posteriormente, al aplicar el criterio de una cobertura mínima del 20% de bosque nativo por celda, la cantidad de puntos se redujo sustancialmente a 42. Esta depuración fue necesaria para asegurar que cada punto representara condiciones bioclimáticas asociadas predominantemente a bosque nativo y evitar la inclusión de áreas con cobertura insuficiente. No obstante, reconocemos que esta reducción puede limitar la representación espacial del bosque en el modelo, lo cual deberá considerarse al interpretar los resultados.

En cuanto a las métricas de validación del modelo, se observó que una probabilidad de presencia cercana a 0,9 proporciona un valor de Kappa de aproximadamente 0,6. Aunque este valor representa una concordancia moderada, es coherente con lo esperado para modelos generados a partir de capas con resoluciones espaciales gruesas, donde las señales ecológicas finas pueden diluirse. La resolución espacial utilizada (5×5 km) contribuye a suavizar la

variabilidad espacial de pequeña escala, lo que reduce el contraste entre presencia y ausencia real de hábitat adecuado. Esta pérdida de resolución puede limitar la capacidad del modelo para detectar patrones locales precisos, tal como ha sido reportado por Zarzo-Arias *et al.* (2022), quienes señalan que resoluciones más amplias tienden a disminuir la precisión de métricas como el Kappa debido a la reducción del fondo de muestra y la homogeneización del paisaje.

Además, el modelo no incorpora información detallada sobre las características del microhábitat, tales como la topografía local, la estructura del dosel o la heterogeneidad del suelo, que pueden ser determinantes en la ocurrencia del bosque a escalas más finas (Guisan *et al.*, 2007). La omisión de estos factores puede limitar la capacidad del modelo para capturar adecuadamente la complejidad ecológica presente en áreas fragmentadas, donde condiciones muy locales pueden definir la presencia o ausencia de vegetación boscosa (Franklin, 1995).

No obstante, el modelo MaxEnt demuestra ser una herramienta robusta y útil para aproximarse al entendimiento de los patrones espaciales de los bosques costeros en ambientes semiáridos. Su capacidad para identificar el factor bioclimático clave que explique su distribución da pie de inicio a una comprensión global de los fenómenos climáticos que explican la distribución de los bosques costeros. Proporcionando un insumo clave para el desarrollo de planificación territorial desde una perspectiva de la ecología de los bosques costeros.

La relación entre vigor vegetal, niebla y precipitación

El análisis de la relación entre el vigor de la vegetación —medido mediante el índice NDVI— y los factores climáticos revela una fuerte dependencia del bosque nativo costero con la ocurrencia de niebla y nubes bajas, particularmente en el periodo estival. La correlación de Kendall (τ) entre NDVI y la cobertura estival de nubes bajas y niebla aumentó de 0,37 en el periodo 2000–2005 a 0,51 entre 2016 y 2019. Este incremento sugiere que, a pesar de la disminución de las precipitaciones asociada a la prolongada megasequía en Chile central (Garreaud *et al.*, 2020), la niebla ha cumplido un rol amortiguador al sostener el vigor vegetal durante los meses más secos del año.

En contraste, la correlación entre NDVI y la precipitación veraniega fue inicialmente muy débil ($\tau \approx 0,09$) y, aunque aumentó a $\tau \approx 0,30$ en el periodo 2016–2019, sigue siendo menos determinante que la niebla en la explicación del vigor vegetal estival. Este patrón es consistente con una dependencia ecológica de los bosques hacia fuentes hídricas no convencionales, como la captación pasiva de agua desde la niebla, en un contexto de aridización progresiva (Qiao *et al.*, 2020; Stanton *et al.*, 2014).

De forma complementaria, el análisis para la primavera muestra un comportamiento distinto: aunque la niebla sigue mostrando una correlación mayor que la precipitación en todos los periodos, los valores de τ son más bajos que en verano (con un máximo de 0,47 para niebla en 2015–2019 y 0,31 para precipitación). Esto podría atribuirse a la dinámica fenológica de especies herbáceas que responden rápidamente a las lluvias tempranas de primavera, lo que suaviza la dependencia exclusiva de la niebla en esta estación. La mayor diversidad funcional

y la capacidad de respuesta inmediata de las herbáceas a pulsos de humedad podrían explicar estas diferencias en la sensibilidad climática del NDVI primaveral (Fitts *et al.*, 2025).

Además, el análisis espacial muestra que la media anual de días con nubes bajas explica un 39% de la variación del NDVI estival media de 20 años ($R^2 = 0,39$), lo que refuerza la idea de que estos eventos atmosféricos cumplen un rol central en la dinámica ecológica de los bosques costeros. Esta capacidad predictiva es particularmente relevante para escalas regionales, ya que permite identificar zonas con mayor influencia de la niebla con efecto en el vigor de la vegetación.

En conjunto, estos resultados respaldan la hipótesis de que la niebla no solo actúa como un recurso hídrico suplementario, sino que puede constituir un regulador estacional relevante del vigor vegetal en ecosistemas donde la lluvia es insuficiente. No obstante, los hallazgos sugieren que el papel de la precipitación continúa siendo un insumo clave para la provisión hídrica, por lo que su influencia no debe ser subestimada.

Estas conclusiones tienen implicancias importantes para la conservación y gestión de los bosques costeros bajo escenarios futuros de cambio climático, ya que subrayan la necesidad de monitorear el comportamiento de la niebla como soporte funcional de estos sistemas ecológicos. Además, resaltan la importancia de considerar las variaciones estacionales y las respuestas diferenciales de tipos funcionales de vegetación (por ejemplo, herbáceas frente a leñosas) en el diseño de modelos y estrategias de conservación.

Limitaciones

Es importante reconocer que este estudio no consideró la variabilidad interanual asociada a eventos extremos, tales como los ciclos El Niño–Oscilación del Sur (ENSO) y la megasequía que afecta a la región desde comienzos de la década de 2010. La ausencia de años con déficit hídrico marcado o anomalías positivas de precipitación en la serie de análisis respondió al interés de caracterizar la relación basal entre la vegetación (NDVI) y la disponibilidad hídrica proveniente de la niebla y la precipitación, evitando respuestas transitorias o pulsos ecológicos excepcionales. No obstante, esta decisión metodológica limita la capacidad del estudio para interpretar la sensibilidad de los bosques costeros frente a escenarios de estrés climático, lo cual constituye una línea de investigación necesaria para futuras evaluaciones y modelos predictivos.

CONCLUSIONES

Los resultados obtenidos respaldan en gran medida la hipótesis de que la niebla influye significativamente en la configuración espacial y el vigor del bosque nativo costero, actuando como una fuente hídrica compensatoria en contextos de sequía prolongada. La evidencia empírica demuestra que la frecuencia y estabilidad de niebla y nubes bajas, detectadas mediante sensores satelitales como GOES, se correlacionan positivamente con la recolección de agua y con indicadores de vigor vegetal (NDVI), especialmente durante el verano, cuando

la precipitación es escasa. Este patrón se ha intensificado en las últimas décadas, lo que sugiere una creciente dependencia ecológica de los bosques costeros hacia aportes hídricos no convencionales.

Aunque no se observó una relación clara entre la niebla y las métricas de forma del paisaje, los modelos de distribución como MaxEnt confirmaron que la variabilidad de la niebla es uno de los predictores bioclimáticos más relevantes para explicar la distribución del bosque. Esto sugiere que, si bien la niebla no determina directamente la morfología de los parches actuales, sí se asocia a condiciones ambientales favorables para su presencia. Asimismo, la alta capacidad predictiva del porcentaje de días con niebla sobre el vigor estival promedio de 20 años de la vegetación refuerza su rol ecológico como modulador del funcionamiento ecosistémico en zonas semiáridas.

No obstante, las conclusiones aquí presentadas deben ser consideradas con la debida cautela, ya que se sustentan en insumos metodológicos sujetos a limitaciones. En particular, los registros satelitales de niebla derivados de GOES poseen restricciones espaciales que pueden conducir a una representación parcial de su variabilidad local, mientras que los modelos de distribución basados en MaxEnt se apoyan en supuestos estadísticos que simplifican la complejidad ecológica subyacente. En conjunto, estas limitaciones podrían incidir en la magnitud de los patrones detectados, por lo que se recomienda complementar investigaciones futuras con mediciones in situ de mayor resolución, así como con enfoques de modelación alternativos o multiescala que permitan validar y refinar las inferencias respecto del rol de la niebla en la configuración y el funcionamiento del bosque costero.

En suma, la niebla actúa como un factor ecológico relevante, cuya influencia aporta a la persistencia del bosque costero, especialmente en contextos donde la precipitación resulta limitada. Sin embargo, los resultados también sugieren que la lluvia continúa siendo un insumo hídrico relevante, por lo que su papel no debe ser subestimado. Este reconocimiento tiene implicancias importantes para la conservación de estos ecosistemas bajo escenarios de cambio climático, subrayando la necesidad de incorporar variables relacionadas con la niebla y la precipitación en estrategias de monitoreo, modelación y planificación territorial.

LITERATURA CITADA

- Adhikari, A., Mahato, R. C., Gorain, S. C., Subir Sen, D., y Scholar, R. (2023). A Review on Parametric and Non-Parametric Test in Education. *International Journal of Research and Analytical Reviews*, 796. www.ijrar.org
- Alaniz, A. J., Galleguillos, M., y Perez-Quezada, J. F. (2016). Assessment of quality of input data used to classify ecosystems according to the IUCN Red List methodology: The case of the central Chile hotspot. *Biological Conservation*, 204, 378–385. <https://doi.org/10.1016/j.biocon.2016.10.038>
- Allen, C. D., Breshears, D. D., y McDowell, N. G. (2015). On underestimation of global vulnerability to tree mortality and forest die-off from hotter drought in the Anthropocene. *Ecosphere*, 6(8). <https://doi.org/10.1890/ES15-00203.1>
- Armas, C., Gutiérrez, J. R., Kelt, D. A., y Meserve, P. L. (2016). Twenty-five years of research in the north-central Chilean semiarid zone: The Fray Jorge Long-Term Socio-Ecological Research (LTSER) site and Norte Chico. *Journal of Arid Environments*, 126, 1–6. <https://doi.org/10.1016/j.jaridenv.2015.12.008>
- Asner, G. P., Archer, S., Hughes, R. F., Ansley, R. J., y Wessman, C. A. (2003). Net changes in regional woody vegetation cover and carbon storage in Texas Drylands, 1937–1999. *Global Change Biology*, 9(3), 316–335. <https://doi.org/10.1046/j.1365-2486.2003.00594.x>
- Ball, L., y Tzanopoulos, J. (2020). Interplay between topography, fog and vegetation in the central South Arabian mountains revealed using a novel Landsat fog detection technique. *Remote Sensing in Ecology and Conservation*, 6(4), 498–513. <https://doi.org/10.1002/rse2.151>
- Barbosa, O., Marquet, P. A., Bacigalupe, L. D., Christie, D. A., Del-Val, E., Gutierrez, A. G., Jones, C. G., Weathers, K. C., y Armesto, J. J. (2010). Interactions among patch area, forest structure and water fluxes in a fog-inundated forest ecosystem in semi-arid Chile. *Functional Ecology*, 24(4), 909–917. <https://doi.org/10.1111/j.1365-2435.2010.01697.x>
- Bedia, J., Herrera, S., y Gutiérrez, J. M. (2013). Dangers of using global bioclimatic datasets for ecological niche modeling. Limitations for future climate projections. *Global and Planetary Change*, 107, 1–12. <https://doi.org/10.1016/j.gloplacha.2013.04.005>
- Boisier, J. P. (2023). CR2MET: A high-resolution precipitation and temperature dataset for the period 1960-2021 in continental Chile. *Zenodo*.

- Boria, R. A., Olson, L. E., Goodman, S. M., y Anderson, R. P. (2014). Spatial filtering to reduce sampling bias can improve the performance of ecological niche models. *Ecological Modelling*, 275, 73–77. <https://doi.org/10.1016/j.ecolmodel.2013.12.012>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breusch, T. S., y Pagan, A. R. (1979). A Simple Test for Heteroscedasticity and Random Coefficient Variation. *Econometrica*, 47(5), 1287. <https://doi.org/10.2307/1911963>
- Cereceda, P., Larrain, H., Osses, P., Farías, M., y Egaña, I. (2008). The climate of the coast and fog zone in the Tarapacá Region, Atacama Desert, Chile. *Atmospheric Research*, 87(3–4), 301–311. <https://doi.org/10.1016/j.atmosres.2007.11.011>
- Cleveland, W. S. (1979). Robust Locally Weighted Regression and Smoothing Scatterplots. *Journal of the American Statistical Association*, 74(368), 829–836. <https://doi.org/10.1080/01621459.1979.10481038>
- Contreras, R., Luna, I., y Ríos, C. (2010). Distribución de *Taxus globosa* (Taxaceae) en México: Modelos ecológicos de nicho, efectos del cambio del uso de suelo y conservación. *Revista Chilena de Historia Natural*, 83(3). <https://doi.org/10.4067/S0716-078X2010000300009>
- Corporación Nacional Forestal (CONAF). (2020). *Sistema de Información Territorial SIT CONAF*. <https://Sit.Conaf.cl/>.
- de la Maza, M., LIMA, M., MESERVE, P. L., GUTIÉRREZ, J. R., y JAKSIC, F. M. (2009). Primary production dynamics and climate variability: ecological consequences in semiarid Chile. *Global Change Biology*, 15(5), 1116–1126. <https://doi.org/10.1111/j.1365-2486.2008.01796.x>
- del-Val, E., Armesto, J. J., Barbosa, O., Christie, D. A., Gutiérrez, A. G., Jones, C. G., Marquet, P. A., y Weathers, K. C. (2006). Rain Forest Islands in the Chilean Semiarid Region: Fog-dependency, Ecosystem Persistence and Tree Regeneration. *Ecosystems*, 9(4), 598–608. <https://doi.org/10.1007/s10021-006-0065-6>
- Dubertret, F., Le Tourneau, F.-M., Villarreal, M. L., y Norman, L. M. (2022). Monitoring Annual Land Use/Land Cover Change in the Tucson Metropolitan Area with Google Earth Engine (1986–2020). *Remote Sensing*, 14(9), 2127. <https://doi.org/10.3390/rs14092127>
- Elith, J., Phillips, S. J., Hastie, T., Dudík, M., Chee, Y. E., y Yates, C. J. (2011). A statistical explanation of MaxEnt for ecologists. *Diversity and Distributions*, 17(1), 43–57. <https://doi.org/10.1111/j.1472-4642.2010.00725.x>
- Espinoza, V., Lobos-Roco, F., y del Río, C. (2024). Synoptic control of the spatiotemporal variability of fog and low clouds under ENSO phenomena along the

Chilean coast (17°–36° S). *Atmospheric Research*, 308, 107533. <https://doi.org/10.1016/j.atmosres.2024.107533>

Fitts, Y., Tucker, C., Hiernaux, P., Auda, Y., y Kergoat, L. (2025). Using PlanetScope NDVI time series to detect the phenology of individual trees in the Sahel. *Remote Sensing of Environment*, 321, 114650. <https://doi.org/10.1016/j.rse.2025.114650>

Franklin, J. (1995). Predictive vegetation mapping: geographic modelling of biospatial patterns in relation to environmental gradients. *Progress in Physical Geography: Earth and Environment*, 19(4), 474–499. <https://doi.org/10.1177/030913339501900403>

Garreaud, R., Barichivich, J., Christie, D. A., y Maldonado, A. (2008). Interannual variability of the coastal fog at Fray Jorge relict forests in semiarid Chile. *Journal of Geophysical Research: Biogeosciences*, 113(G4). <https://doi.org/10.1029/2008JG000709>

Garreaud, R., Boisier, J. P., Rondanelli, R., Montecinos, A., Sepúlveda, H. H., y Veloso-Aguila, D. (2020). The Central Chile Mega Drought (2010–2018): A climate dynamics perspective. *International Journal of Climatology*, 40(1), 421–439. <https://doi.org/10.1002/joc.6219>

Gašparović, M., Pilaš, I., Radočaj, D., y Dobrinić, D. (2024). Monitoring and Prediction of Land Surface Phenology Using Satellite Earth Observations—A Brief Review. *Applied Sciences*, 14(24), 12020. <https://doi.org/10.3390/app142412020>

Gislason, P. O., Benediktsson, J. A., y Sveinsson, J. R. (2006). Random Forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294–300. <https://doi.org/10.1016/j.patrec.2005.08.011>

Griebel, A., Metzen, D., Boer, M. M., Barton, C. V. M., Renchon, A. A., Andrews, H. M., y Pendall, E. (2020). Using a paired tower approach and remote sensing to assess carbon sequestration and energy distribution in a heterogeneous sclerophyll forest. *Science of The Total Environment*, 699, 133918. <https://doi.org/10.1016/j.scitotenv.2019.133918>

Guisan, A., Graham, C. H., Elith, J., y Huettmann, F. (2007). Sensitivity of predictive species distribution models to change in grain size. *Diversity and Distributions*, 13(3), 332–340. <https://doi.org/10.1111/j.1472-4642.2007.00342.x>

Guisan, A., Thuiller, W., y Zimmermann, N. E. (2017). *Habitat Suitability and Distribution Models*. Cambridge University Press. <https://doi.org/10.1017/9781139028271>

Gutiérrez, A. G., Barbosa, O., Christie, D. A., Del-Val, E., Ewing, H. A., Jones, C. G., Marquet, P. A., Weathers, K. C., y Armesto, J. J. (2008). Regeneration patterns and persistence of the fog-dependent Fray Jorge forest in semiarid Chile during the past two centuries. *Global Change Biology*, 14(1), 161–176. <https://doi.org/10.1111/j.1365-2486.2007.01482.x>

Hampe, A. (2004). Bioclimate Envelope Models: What They Detect and What They Hide. *Global Ecology and Biogeography*, 13(5), 469–471. <http://www.jstor.org/stable/3697578>

Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D., Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O., y Townshend, J. R. G. (2013). High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 342(6160), 850–853. <https://doi.org/10.1126/science.1244693>

Hernández, A., Miranda, M. D., Arellano, E. C., y Dobbs, C. (2016). Landscape trajectories and their effect on fragmentation for a Mediterranean semi-arid ecosystem in Central Chile. *Journal of Arid Environments*, 127, 74–81. <https://doi.org/10.1016/j.jaridenv.2015.10.004>

Hernandez, D., Mendoza, P. A., Boisier, J. P., y Ricchetti, F. (2022). Hydrologic Sensitivities and ENSO Variability Across Hydrological Regimes in Central Chile (28°–41°S). *Water Resources Research*, 58(9). <https://doi.org/10.1029/2021WR031860>

Hesselbarth, M. H. K., Sciaini, M., With, K. A., Wiegand, K., y Nowosad, J. (2019). landscapemetrics: an open-source R tool to calculate landscape metrics. *Ecography*, 42(10), 1648–1657. <https://doi.org/10.1111/ecog.04617>

Huete, A., Didan, K., van Leeuwen, W., Miura, T., y Glenn, E. (2010). *MODIS Vegetation Indices* (pp. 579–602). https://doi.org/10.1007/978-1-4419-6749-7_26

Jupp, D.L.B.; Walker, J. (1997). The Use of Remote Sensing in the Modeling of Forest Productivity (H. Shimoda, H. L. Gholz, y K. Nakane, Eds.; Vol. 50). Springer Netherlands. <https://doi.org/10.1007/978-94-011-5446-8>

Keenan, R. J. (2015). Climate change impacts and adaptation in forest management: a review. In *Annals of Forest Science* (Vol. 72, Issue 2, pp. 145–167). Springer-Verlag France. <https://doi.org/10.1007/s13595-014-0446-5>

Kendall, M. G. (1938). A New Measure of Rank Correlation. *Biometrika*, 30(1/2), 81. <https://doi.org/10.2307/2332226>

Liaw, A. (2022). *Breiman and Cutler's Random Forests for Classification and Regression* (R 4.2.1; x86_64-w64-mingw32; 2022-10-09 00:43:24 UTC; windows). <https://www.stat.berkeley.edu/~breiman/RandomForests/>

Liu, Q., Peng, C., Schneider, R., Cyr, D., Liu, Z., Zhou, X., Du, M., Li, P., Jiang, Z., McDowell, N. G., y Kneeshaw, D. (2023). Vegetation browning: global drivers, impacts, and feedbacks. *Trends in Plant Science*, 28(9), 1014–1032. <https://doi.org/10.1016/j.tplants.2023.03.024>

Luebert, F., y Pliscoff, P. (2006). *Sinopsis bioclimática y vegetacional de Chile* (Universitaria, S.A., Vol. 1).

https://books.google.cl/books?hl=es&lr=&id=Q6TQdlb6bEwC&oi=fnd&pg=PA167&dq=bosque+escler%C3%B3filo&ots=i6wqp_Jq63&sig=PiOoTEF78EAKbeOeJvsKdjT9U4Q#v=onepage&q=bosque%20escler%C3%B3filo&f=false

Luzio, W. (2010). *Suelos de Chile*. Universidad de Chile. <https://repositorio.uchile.cl/handle/2250/182305>

Macek, P., Schöb, C., Núñez-Ávila, M., Hernández Gentina, I. R., Pugnaire, F. I., y Armesto, J. J. (2018). Shrub facilitation drives tree establishment in a semiarid fog-dependent ecosystem. *Applied Vegetation Science*, 21(1), 113–120. <https://doi.org/10.1111/avsc.12301>

Mardones, D., y Scherson, R. A. (2023). Hotspots within a hotspot: evolutionary measures unveil interesting biogeographic patterns in threatened coastal forests in Chile. *Botanical Journal of the Linnean Society*, 202(4), 433–448. <https://doi.org/10.1093/botlinnean/boad002>

Mellor, A., Haywood, A., Stone, C., y Jones, S. (2013). The Performance of Random Forests in an Operational Setting for Large Area Sclerophyll Forest Classification. *Remote Sensing*, 5(6), 2838–2856. <https://doi.org/10.3390/rs5062838>

Ministerio Medio Ambiente. (2014). *Atlas de Cambio Climático de la Zona Semiárida de Chile* (ODEPA Oficina de Estudios y Políticas Agrícolas y F. de C. A. Universidad de Chile, Eds.). Ministerio del Medio Ambiente. <https://educacion.mma.gob.cl/wp-content/uploads/2015/09/Atlas-CC-ZonaAridas-Semiaridas-Chile.pdf>

Mittermeier, R. A., Turner, W. R., Larsen, F. W., Brooks, T. M., y Gascon, C. (2011). Global Biodiversity Conservation: The Critical Role of Hotspots. In *Biodiversity Hotspots* (pp. 3–22). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-20992-5_1

Montecinos, S., Gutiérrez, J. R., López-Cortés, F., y López, D. (2016). Climatic characteristics of the semi-arid Coquimbo Region in Chile. *Journal of Arid Environments*, 126, 7–11. <https://doi.org/10.1016/j.jaridenv.2015.09.018>

Morales, N. S., Fernández, I. C., y Baca-González, V. (2017). MaxEnt's parameter configuration and small samples: are we paying attention to recommendations? A systematic review. *PeerJ*, 5, e3093. <https://doi.org/10.7717/peerj.3093>

NASA JPL. (2020). *NASADEM Merged DEM Global 1 arc second V001 [Data set]*. NASA EOSDIS Land Processes Distributed Active Archive Center. https://doi.org/10.5067/MEaSUREs/NASADEM/NASADEM_HGT.001

Noce, S., Caporaso, L., y Santini, M. (2020). A new global dataset of bioclimatic indicators. *Scientific Data*, 7(1), 398. <https://doi.org/10.1038/s41597-020-00726-5>

O'Neill, R. V., Krummel, J. R., Gardner, R. H., Sugihara, G., Jackson, B., DeAngelis, D. L., Milne, B. T., Turner, M. G., Zygmunt, B., Christensen, S. W., Dale, V. H., y

Graham, R. L. (1988). Indices of landscape pattern. *Landscape Ecology*, 1(3), 153–162. <https://doi.org/10.1007/BF00162741>

Phillips, S. J., Anderson, R. P., y Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190(3–4), 231–259. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>

Pocheville, A. (2015). The Ecological Niche: History and Recent Controversies. In *Handbook of Evolutionary Thinking in the Sciences* (pp. 547–586). Springer Netherlands. https://doi.org/10.1007/978-94-017-9014-7_26

Qiao, N., Zhang, L., Huang, C., Jiao, W., Maggs-Kölling, G., Marais, E., y Wang, L. (2020). Satellite Observed Positive Impacts of Fog on Vegetation. *Geophysical Research Letters*, 47(12). <https://doi.org/10.1029/2020GL088428>

Rodriguez, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., y Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>

Rotenberg, E., y Yakir, D. (2010). Contribution of Semi-Arid Forests to the Climate System. *Science*, 327(5964), 451–454. <https://doi.org/10.1126/science.1179998>

Salgado, B., Canessa, R., Valladares, F., Armesto, J. J., y Pérez, F. (2015). Functional traits variation explains the distribution of *Aextoxicon punctatum* (Aextoxicaceae) in pronounced moisture gradients within fog-dependent forest fragments. *Frontiers in Plant Science*, 6. <https://doi.org/10.3389/fpls.2015.00511>

Salgado, B., Pérez, F., Markesteijn, L., Castillo, M. J., y Armesto, J. J. (2013). Diverging drought-tolerance strategies explain tree species distribution along a fog-dependent moisture gradient in a temperate rain forest. *Oecologia*, 173(3), 625–635. <https://doi.org/10.1007/s00442-013-2650-7>

Shapiro, S. S., y Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3–4), 591–611. <https://doi.org/10.1093/biomet/52.3-4.591>

Shcheglovitova, M., y Anderson, R. P. (2013). Estimating optimal complexity for ecological niche models: A jackknife approach for species with small sample sizes. *Ecological Modelling*, 269, 9–17. <https://doi.org/10.1016/j.ecolmodel.2013.08.011>

Shetty, S., Gupta, P. K., Belgiu, M., y Srivastav, S. K. (2021). Assessing the Effect of Training Sampling Design on the Performance of Machine Learning Classifiers for Land Cover Mapping Using Multi-Temporal Remote Sensing Data and Google Earth Engine. *Remote Sensing*, 13(8), 1433. <https://doi.org/10.3390/rs13081433>

Smith-Ramírez, C., Grez, A., Galleguillos, M., Cerda, C., Ocampo-Melgar, A., Miranda, M. D., Muñoz, A. A., Rendón-Funes, A., Díaz, I., Cifuentes, C., Alaniz, A.,

Seguel, O., Ovalle, J., Montenegro, G., Saldaña-Cortés, A., Martínez-Harms, M. J., Armesto, J. J., y Vita, A. (2023). Ecosystem services of Chilean sclerophyllous forests and shrublands on the verge of collapse: A review. *Journal of Arid Environments*, 211, 104927. <https://doi.org/10.1016/j.jaridenv.2022.104927>

Spearman, C. (1904). The Proof and Measurement of Association between Two Things. *The American Journal of Psychology*, 15(1), 72. <https://doi.org/10.2307/1412159>

Squeo, F. A., Loayza, A. P., López, R. P., y Gutiérrez, J. R. (2016). Vegetation of Bosque Fray Jorge National Park and its surrounding matrix in the Coastal Desert of north-central Chile. *Journal of Arid Environments*, 126, 12–22. <https://doi.org/10.1016/j.jaridenv.2015.10.013>

Stanton, D. E., Armesto, J. J., y Hedin, L. O. (2014). Ecosystem properties self-organize in response to a directional fog-vegetation interaction. In *Ecology* (Vol. 95, Issue 5).

Tan, B., Dellomo, J., Wolfe, R., y Reth, A. (2020). GOES-16 and GOES-17 ABI INR Assessment. *NASA Assessment*.

Tiao, G. C., Reinsel, G. C., Xu, D., Pedrick, J. H., Zhu, X., Miller, A. J., DeLuisi, J. J., Mateer, C. L., y Wuebbles, D. J. (1990). Effects of autocorrelation and temporal sampling schemes on estimates of trend and spatial correlation. *Journal of Geophysical Research: Atmospheres*, 95(D12), 20507–20517. <https://doi.org/10.1029/JD095iD12p20507>

Torregrosa, A., Combs, C., y Peters, J. (2016). GOES-derived fog and low cloud indices for coastal north and central California ecological analyses. *Earth and Space Science*, 3(2), 46–67. <https://doi.org/10.1002/2015EA000119>

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

Tukey, J. W. (1949). Comparing Individual Means in the Analysis of Variance. *Biometrics*, 5(2), 99. <https://doi.org/10.2307/3001913>

Van Leeuwen, W., Hartfield, K., Miranda, M., y Meza, F. (2013). Trends and ENSO/AAO Driven Variability in NDVI Derived Productivity and Phenology alongside the Andes Mountains. *Remote Sensing*, 5(3), 1177–1203. <https://doi.org/10.3390/rs5031177>

Villagrán, C., y Armesto, J. (2005). *Fitogeografía histórica de la Cordillera de la Costa de Chile*.

Warren, D. L., y Seifert, S. N. (2011). Ecological niche modeling in Maxent: the importance of model complexity and the performance of model selection criteria. *Ecological Applications*, 21(2), 335–342. <https://doi.org/10.1890/10-1171.1>

West, A. M., Kumar, S., Brown, C. S., Stohlgren, T. J., y Bromberg, J. (2016). Field validation of an invasive species Maxent model. *Ecological Informatics*, 36, 126–134. <https://doi.org/10.1016/j.ecoinf.2016.11.001>

White, H. (1980). A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity. *Econometrica*, 48(4), 817. <https://doi.org/10.2307/1912934>

Wulder, M. A., Roy, D. P., Radeloff, V. C., Loveland, T. R., Anderson, M. C., Johnson, D. M., Healey, S., Zhu, Z., Scambos, T. A., Pahlevan, N., Hansen, M., Gorelick, N., Crawford, C. J., Masek, J. G., Hermosilla, T., White, J. C., Belward, A. S., Schaaf, C., Woodcock, C. E., ... Cook, B. D. (2022). Fifty years of Landsat science and impacts. *Remote Sensing of Environment*, 280, 113195. <https://doi.org/10.1016/j.rse.2022.113195>

Xu, N. (2023). Impacts of the Major Drought in Chile and Mitigation Measures. *E3S Web of Conferences*, 424, 02002. <https://doi.org/10.1051/e3sconf/202342402002>

Zarzo-Arias, A., Penteriani, V., Gábor, L., Šímová, P., Grattarola, F., y Moudrý, V. (2022). Importance of data selection and filtering in species distribution models: A case study on the Cantabrian brown bear. *Ecosphere*, 13(12). <https://doi.org/10.1002/ecs2.4284>

Zomer, R. J., Trabucco, A., Metzger, M. J., Wang, M., Oli, K. P., y Xu, J. (2014). Projected climate change impacts on spatial distribution of bioclimatic zones and ecoregions within the Kailash Sacred Landscape of China, India, Nepal. *Climatic Change*, 125(3–4), 445–460. <https://doi.org/10.1007/s10584-014-1176-2>

APÉNDICE

Apéndice 1: Detalle de los códigos utilizados para cada subcuenca. La delimitación de subcuencas se realizó adoptando el enfoque propuesto por Vicuña et al. (en revisión)¹, que segmenta las cuencas en unidades superiores (U), medias (M) e inferiores (L), permitiendo una evaluación espacialmente explícita de variables hidroclimáticas, ecológicas y antrópicas a lo largo del gradiente altitudinal.

Nombre de La Subcuenca	Código utilizado
Rio Quilimari hasta Muro Embalse Culimo Media	MQ
Rio Quilimari hasta Muro Embalse Culimo Baja	LQ
Rio Quilimari hasta Muro Embalse Culimo Alta	UQ
Rio Petorca Bajo (Entre Las Palmas y Desembocadura)	LP
Rio Ligua Bajo (Entre Estero Los Angeles y Desembocadura)	LL
Petorca Medio	MP
Esteros Pupio	EP
Costeras entre Estero Ligua y Estero Catapilco	CLC
Costeras entre Estero Pupio y Rio Quilimari	CEQ

¹ Vicuña, S., Gomez, R., Bravo, V., Vargas, J., Gutierrez, A. G., Williams, M., Gaxiola, A., Leray, S., Melo, O., Gonzalez, D., Zúñiga, P., y Meza, F. (en revisión). *Assessing the complex nature of climate change risks in semi-arid coastal basins*. Manuscrito enviado a revisión.