



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

EVALUACIÓN DEL RIESGO DE INCENDIOS FORESTALES EN LA INTERFAZ
URBANO RURAL DE CONCEPCIÓN, INTEGRANDO HERRAMIENTAS DE GIS,
MACHINE LEARNING Y SIMULACIÓN ESPACIAL

TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN GESTIÓN DE OPERACIONES

GABRIELA DOMINGA ALFARO ROJAS

PROFESOR GUÍA:
ANDRÉS WEINTRAUB POHORILLE
PROFESOR GUÍA 2:
JAIME CARRASCO BARRA

MIEMBROS DE LA COMISIÓN:
MIGUEL CASTILLO SOTO
RAFAEL EPSTEIN NUMHAUSER

SANTIAGO DE CHILE
2021

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE MAGÍSTER EN GESTIÓN DE OPERACIONES
POR: GABRIELA DOMINGA ALFARO ROJAS
FECHA: 2021
PROF. GUÍA: ANDRÉS WEINTRAUB POHORILLE JAIME CARRASCO BARRA

EVALUACIÓN DEL RIESGO DE INCENDIOS FORESTALES EN LA INTERFAZ URBANO RURAL DE CONCEPCIÓN, INTEGRANDO HERRAMIENTAS DE GIS, MACHINE LEARNING Y SIMULACIÓN ESPACIAL

El aumento de los incendios forestales ha puesto en riesgo zonas de gran interés, como son la interfaz urbano rural, zonas productivas, ecosistemas naturales, entre otros. Junto con esto, en los últimos años se han desarrollado herramientas y empleado modelos matemáticos de buenos resultados para estudiar el comportamiento de los incendios. Así es como surge la necesidad y la oportunidad de evaluar aquellas zonas que dadas las condiciones actuales, tienen un mayor riesgo de verse afectadas por incendios forestales y así aportar a la toma de decisiones futuras para disminuir o evitar los daños causados.

En este trabajo se evalúa el riesgo de incendios al que se enfrenta la zona urbano rural de Concepción, siguiendo la siguiente metodología: En una primera instancia se realiza un modelo de ocurrencia, utilizando Machine Learning (Bagged Decision Tree siguiendo la metodología de Miranda et al. (2020)), con el objetivo de aprender en qué zonas es más probable que se inicie un incendio. Se utilizaron 14 variables explicativas y una variable dependiente binaria de ocurrencia de incendio. Dada la resolución de los raster de las variables explicativas, se obtuvo como resultado un mapa de resolución 30 metros, donde cada celda tiene asignada una probabilidad de ocurrencia. El modelo se entrena con un 80 % de los datos y con el 20 % restante se prueba la efectividad del modelo. Para este caso se usó el estimador AUC para evaluar el modelo, obteniendo un $AUC=0,97$ (AUC tiene valor máximo 1 y mínimo 0) y un tiempo computacional muy bajo, lo que lo transforma en una muy buena herramienta de evaluación a la hora de realizar planificación urbana o productiva y así conocer como afectarían ciertos cambios a la probabilidad de ocurrencia de incendios.

Luego se utilizó un modelo de propagación de incendio (Cell2Fire (Pais et al., 2019)) para conocer aquellas zonas que son más propensas a quemarse. Para esto se tomaron 10.000 puntos de ignición aleatorios y se construyó un mapa de probabilidad de quema, donde cada celda indica la proporción de incendios que pasaron sobre ella. Este resultado, se cruzó con un mapa de densidad poblacional, para conocer el riesgo al que se ve enfrentada la población humana en la zona urbano rural de Concepción. Y se evidenció que las zonas de mayor riesgo son aquellas en torno a las grandes ciudades (Concepción y Talcahuano en gran medida), a pesar que las zonas de mayor probabilidad de quema están alejadas de éstas.

El trabajo que se presenta a continuación es una prueba de conceptos de una herramienta que busca ser útil para la toma de decisiones en la planificación urbana y productiva, de manera tal de lograr diseñar paisajes resistentes a incendios forestales. En el mismo contexto, se evidencian trabajos futuros para mejorar y ampliar dicha herramienta, como la integración de los modelos de ocurrencia y propagación, junto con construir y actualizar los datos necesarios para realizar estos análisis.

Tabla de Contenido

1. Introducción	1
1.1. Objetivos	2
1.1.1. Objetivo general	2
1.1.2. Objetivos específicos	2
2. Materiales	3
2.1. Antecedentes	3
2.1.1. Ocurrencia de incendios	3
2.1.2. Propagación de incendios	4
2.1.3. Mapa de probabilidad de quema	5
2.2. Área de estudio	5
2.3. Datos	6
2.3.1. Incendios históricos	7
2.3.2. Geografía, cobertura de suelo y actividad humana	8
2.3.3. Condiciones atmosféricas	9
3. Método	10
3.1. Modelo de ocurrencia	11
3.1.1. Modelo utilizado	11
3.1.2. Inputs para el modelo de ocurrencia	12
3.2. Modelo de propagación	13
3.2.1. Simulador: Cell2Fire	13
3.2.2. Cicatrices de incendio	17
3.2.3. Mapa de probabilidad de quema	18
4. Resultados y discusión	19
4.1. Modelo de ocurrencia	19
4.1.1. Selección variables	19
4.1.2. Indicadores del modelo	20
4.1.3. Mapa de ocurrencia de incendios	22
4.2. Modelo de propagación	24
4.2.1. Comparación con cicatriz de incendio	24
4.2.2. Mapa de probabilidad de quema	26
4.3. Riesgo de incendio	28
Conclusión	30

Bibliografia 33

Índice de Tablas

2.1. Características de las comunas del área de estudio	6
2.2. Descripción de las variables geográficas, cobertura de suelo y actividad humana	8
3.1. Conversión combustible chileno a canadiense	15
3.2. Ejemplo archivo de datos atmosféricos para simulador	16
4.1. Histograma probabilidad de ocurrencia	24
4.2. Histograma probabilidad de quema	27

Índice de Ilustraciones

2.1. Área de estudio	6
2.2. Resumen datos utilizados	7
3.1. Metodología	10
3.2. Ejemplo modelo bagging	12
3.3. Puntos de entrenamiento del modelo	13
3.4. Ejemplo de avance simulación de incendio.	14
3.5. Ejemplos metodología de construcción de cicatrices de incendios	18
4.1. A) Matriz de correlación variables iniciales. B) Importancia de las variables iniciales modelo de ocurrencia	20
4.2. Importancia de las variables finales modelo de ocurrencia	21
4.3. A) Curva ROC del modelo de ocurrencia. B)Matriz de confusión del modelo de ocurrencia	21
4.4. Mapa probabilidad de ocurrencia de incendios	22
4.5. Mapa de probabilidad de ocurrencia v/s Ocurrencia real	23
4.6. Análisis mapa de ocurrencia de incendios	24
4.7. Simulación cicatriz incendio 169143	25
4.8. Simulación cicatriz incendio 177026	25
4.9. Mapa probabilidad de quema	26
4.10. Mapa probabilidad de quema y cobertura suelo	27
4.11. Población en riesgo de incendio	28
4.12. Detalle población en riesgo de incendio	29
4.13. Ejemplos estrategia de prevención de incendios	31

Capítulo 1

Introducción

Los incendios forestales afectan anualmente a distintos ecosistemas a nivel mundial y se estima que el área quemada al año es en promedio entre 336,5 *Mha* y 422,5 *Mha* (Giglio et al., 2018). Es una situación que genera gran preocupación y más aún pues la influencia del cambio climático y la generación de paisajes propensos a incendios (provocados por ejemplo por los sistemas de producción forestal o agrícola), han provocado que en las últimas dos décadas empeoren los regímenes de incendios tanto en su frecuencia, duración, como intensidad (Moritz et al., 2014). Aún peor, los mega incendios forestales (incendios de gran tamaño) se han transformado en eventos cada vez más recurrente en distintos ecosistemas, afectando incluso a países con enormes capacidades de extinción de incendios (Williams, 2013).

De la misma manera, viendo la situación nacional, debido a la disminución de las precipitaciones y el aumento de las temperaturas, se ha generado un aumento significativo en el número de incendios forestales en Chile durante las últimas décadas, en particular en las regiones centro-sur del país (González et al., 2011). Según los incendios registrados por CONAF, en la Región del Biobío en el año 1985 hubo 1.314 incendios (afectando 4.912 ha) y para el año 2015 aumentó a 3.644 incendios (35.766 ha afectadas), es decir hubo un aumento del 270 % en la cantidad de incendios en esta región en 10 años, siendo esta región la que acumula la mayor cantidad de incendios a nivel nacional, acumulando cerca del 45 % de los ocurrencias registradas por CONAF para ese año.

Los mega incendios también han afectado al territorio nacional, un ejemplo de esto es lo ocurrido el año 2017, donde se estima que se quemaron 529.974 ha en un mega incendio que afectó a 5 regiones del país (De la Barrera et al., 2018).

Por otro lado, es necesario evidenciar que los incendios forestales tienen diversos efectos, tanto ambientales como sociales. Provocan pérdidas en ecosistemas naturales, como fue en el caso de Chile con los emblemáticos incendios del Parque Nacional Torres del Paine en 2011-2012 o los incendios en la reserva nacional Malleco y Tolhuaca en los años 2002 y 2015, generando pérdidas de fauna y flora silvestre. Por otro lado generan emisiones de CO₂ en grandes cantidades, por ejemplo la cantidad emitida en los incendios del año 2017 fueron equivalentes al 90 % de las emisiones de todo el país el año 2016 (González et al., 2020). Por otro lado, tienen un impacto socioeconómico de gran escala, solo en gasto en combate en la

temporada 2018-2019 en Chile se utilizaron cerca de USD 80 millones (González et al., 2020). Pero además generan una amenaza para la seguridad de la sociedad, pues generan pérdidas tanto de vidas humanas como de infraestructura necesario para el bienestar social.

En particular los incendios en la Interfaz Urbano Rural (Wildland-Urban Interface, WUI), que es el espacio en el que coexiste población humana y área silvestre, generan gran preocupación. Esto se debe a que los incendios en éstas zonas concentran la mayor cantidad de pérdida de vidas humanas, así como también el gasto en prevención y extinción de incendios en estas zonas es mayor (Kramer et al. (2018), Moritz et al. (2014), Chen and McAneney (2004)). En la medida en que los asentamientos humanos crecen y comienzan a acercarse cada vez más a zonas donde se concentra el combustible forestal, se hace más necesario conocer aquellas áreas que son más propensas al fuego, de manera tal de poder protegerlas y con esto entregar mayor seguridad a la población humana y a los ecosistemas que las rodean.

Con estos antecedentes, queda en evidencia que los incendios forestales representan un gran problema para la sociedad, afectando la seguridad tanto de las personas como de las edificaciones que ellas utilizan, generando gran impacto social y económico. Pero también significan un problema ambiental, al provocar pérdidas de ecosistemas, emisiones de gases, entre otros. Es por esto que para enfrentar este gran problema, se hace necesario el manejo del riesgo y de la propagación de los incendios a través de la planificación de un paisaje resistente (Calkin et al., 2014).

Lo que se busca con este trabajo, es evaluar el riesgo de incendios de una zona particular del sur de Chile. Para esto se evaluarán aquellas áreas donde es más probable que inicie un incendio (probabilidad de ocurrencia), aquellas donde es más probable que se queme (probabilidad de quema) y se evaluará el riesgo que esto representa para la población humana. Es una prueba de conceptos para lograr en trabajos futuros, generar un diseño de paisaje apropiado que genere mayor protección y disminuya las pérdidas causadas por incendios.

1.1. Objetivos

1.1.1. Objetivo general

Desarrollar un modelo de riesgo de incendios forestales, a través de la evaluación de modelos de ocurrencia y propagación para la zona urbano rural de Concepción, Chile.

1.1.2. Objetivos específicos

1. Generar un mapa de ocurrencia de incendios forestales para el área de estudio, utilizando un modelo de machine learning.
2. Analizar el comportamiento del fuego, a través de múltiples simulaciones espaciales de incendios forestales.
3. Desarrollar un mapa de riesgo de incendios forestales.

Capítulo 2

Materiales

2.1. Antecedentes

En búsqueda de disminuir el riesgo y peligro que significan los incendios forestales para las comunidad y los ecosistemas, se han desarrollado variados estudios y herramientas para apoyar el manejo y la prevención de éstas catástrofes (ver Martell (2015)).

2.1.1. Ocurrencia de incendios

Para conocer el comportamiento del fuego, se hace necesario estudiar el riesgo asociado a la ocurrencia de incendios que existente en cada terreno. Una definición generalizada de riesgo de incendio es: la posibilidad de que se inicie un incendio, según las características de la naturaleza y la incidencia de los agentes causales (naturales o provocados por el ser humano)(Hardy, 2005).

Los estudios realizados anteriormente revelan que los elementos relevantes asociados al riesgo de incendio, son aquellos que afectan las características del combustible, que segreguen el paisaje, que determinen la accesibilidad al bosque y que captan aspectos importantes del uso del terreno (Chas-Amil et al., 2015), por tanto las variables a la hora de construir un modelo de ocurrencia, deben considerarlos.

Además se ha evidenciado que los seres humanos y su distribución espacial tienen una relación positiva con el número de incendios, es decir en las zonas más cercanas a caminos y asentamientos urbanos aumenta la ocurrencia de incendios (Yang et al. (2007), Syphard et al. (2007), Syphard et al. (2008), Narayanaraj and Wimberly (2012)). Por otro lado, el uso del suelo genera también una diferencia, mientras los terrenos naturales concentran una menor cantidad de incendios, los de uso artificial presentan un mayor riesgo de incendios. (Ricotta et al., 2018).

Comúnmente la ocurrencia de incendios se modela representándola como una variable binaria que toma valor 1 cuando ha ocurrido un incendio y valor 0 cuando no (Moayedi et al., 2020). Debido a la complejidad de las variables asociadas al riesgo, es difícil lograr captar las interacciones de éstas utilizando enfoques de modelos estadísticos tradicionales. Los

modelos de Inteligencia Artificial logran capturar de mejor manera los múltiples factores que afectan estos fenómenos y las relaciones entre las variables (Elith et al., 2008). En particular los métodos de Machine Learning han entregado buenos resultados y han sido útiles para encontrar las interacciones complejas entre las variables (Olden et al., 2008).

Si bien el método más utilizado para modelar la ocurrencia es a través de la regresión logística binaria porque es fácil de usar y comprender (Costafreda-Aumedes et al., 2018), en las últimas dos décadas se han utilizado técnicas más complejas de Machine Learning, tales como Classification and Regression Trees (Aprendizaje basado e árboles de decisión), Support Vector Machines (separa las clases a 2 espacios lo más amplios posibles mediante un hiperplano), Artificial Neural Networks (las variables iniciales atraviesan la red neuronal, donde se aplican a diversas operaciones, produciendo valores de salida), Random Forests (combinación de árboles de decisión, cada árbol depende de los valores de un vector aleatorio y con la misma distribución para cada uno), Generalised Additive Models (variable respuesta depende de funciones suaves desconocidas de las variables predictoras, y el interés se centra en la inferencia sobre estas funciones suaves) y Convolution Neural Network (es un tipo de red neuronal artificial, con múltiples capas donde la aplicación es realizada en matrices bidimensionales) . (Carrasco et al., 2021)

2.1.2. Propagación de incendios

Generalmente el proceso de ignición se modela de forma separada a la propagación. La predicción del comportamiento de un incendio forestal y modelación de su posterior evolución es un problema muy complejo. La dispersión de un incendio, depende principalmente del combustible forestal presente (el grado de inflamabilidad, la carga, etc.) y su disposición espacial (el grado de continuidad, la conectividad, etc), de las condiciones ambientales (viento, humedad relativa, temperatura, etc) y de los aspectos topográficos del terreno (Flannigan et al. (2000), Scott et al. (2013)).

Los modelos de combustible forestal son un elemento clave para los modelos de propagación. Cada modelo de combustible tiene parámetros cualitativos y cuantitativos que lo identifican y entregan características particulares de los combustibles que son indispensables para modelar la propagación, como el ROS, altura de la flama y la intensidad calórica liberada por la combustión. No existe una clasificación única en el mundo, se han desarrollado algunos modelos para ciertos países y en otro se han adaptado (Scott et al., 2013). En Chile se desarrolló el sistema KITRAL (Julio et al., 1995), que ha mostrado muy buenos resultados en fuegos de superficie, sin embargo tiene como limitación que no considera fuego de copas.

Además de los modelos de combustibles, se han desarrollado herramientas para analizar el tratamientos de combustible y comportamiento del fuego en distintos países: En EEUU, BehavePlus (Andrews, 2005), FMAPlus (Carlton, 2004), FVS-FFE (Reinhardt, 2003) y NEXUS (Scott, 1999). En Canadá, el Canadian Forest Fire Behaviour Prediction (FBP) System (Taylor and Alexander, 2006). En Australia, CSIRO Fire Calculator (Cheney et al., 1998). El sistema KITRAL (Julio et al., 1995), incluye 34 modelos de combustibles con los que es posible recrear diversas condiciones de comportamiento potencial del fuego.

Incorporando estos modelos de comportamiento del fuego, junto con técnicas de simulación, se han desarrollado las siguientes herramientas que permiten representar el avance

de los incendios sobre el territorio: En EEUU, FlamMap (Finney et al., 1999) y FARSITE (Finney, 1998). En Canadá, PROMETHEUS (Tymstra et al., 2010) y Cell2Fire (desarrollado en Chile) (Pais et al., 2019). En España, Wildfire Analyst (Ramírez et al., 2011) y Cardin (Martinez-Millán and Saura, 1998). En nuestro país también se utiliza el simulador Kitral (Castillo et al., 2002).

2.1.3. Mapa de probabilidad de quema

Conocer la probabilidad de quema y por tanto el comportamiento del fuego y los impactos de éste en un cierto paisaje entrega información necesaria para mejorar la planificación, diseño y adaptación de paisajes en zonas más propensas a incendios (Miller and Ager, 2013). Es por esta necesidad que surgen los modelos de BP, por su sigla en inglés Burn Probability, que son modelos que entregan la probabilidad de quema de incendios calculada al simular la ignición y la propagación de una gran cantidad de incendios en un paisaje estático (Finney, 2005).

Actualmente para realizar los BPM (Burn Probability Map), se utilizan modelos de propagación como los mencionados anteriormente (aquellos que integran técnicas de simulación), con la lógica que si funcionan adecuadamente para simular un solo incendio, modelar miles de incendios representará la probabilidad de incendios en cualquier punto y entonces revelará los patrones de comportamiento del fuego a una mayor escala. En Parisien et al. (2020) se entrega una revisión de los análisis que es posible obtener del estudio de la Probabilidad de Quema (Burn Probability), dependiendo del propósito y del análisis que se realice de los resultados, categorizándolos en 4 clases: (i) examen directo, que puede ser tan simples como la evaluación visual de los resultados para determinar qué áreas son más propensas a incendios o pueden ser más complejos, requiriendo cálculos para comparar BP o patrones de comportamiento del fuego; (ii) procesos vecinales, ayudan a examinar los patrones de ignición de incendios y posterior propagación, para conocer cómo se comportan ciertos incendios en lugares particulares; (iii) peligro y riesgo, donde el primero combina la probabilidad de incendio y un análisis cuantitativo del comportamiento del fuego, y el segundo es producto de la probabilidad de quema y los posibles impactos de los incendios forestales (negativos o positivos); y (iv) integración con modelos secundarios, como por ejemplo con modelos de clima para evaluar el comportamiento de los incendios en el futuro.

2.2. Área de estudio

Este estudio se realizó en la zona urbano rural de ciudad de Concepción ($36,4^{\circ} - 37,2^{\circ}S$), ubicada en la región del BioBio, en el centro sur de Chile, tal como se muestra en la Figura 2.1. Él área tiene una extensión de 3.200 km^2 aproximadamente, compuesta por las comunas de Chiguayante, Coelemu, Concepción, Coronel, Florida, Hualpén, Hualqui, Lota, Penco, Ránquil, San Pedro de la Paz, Talcahuano y Tomé.

Estas comunas representa el 0,43% de la superficie del territorio nacional y acumulan el 5,71% de la población del país, según el Censo 2017 (ver Tabla 2.1).

En la Provincia de Concepción se presenta un clima templado, oscilado entre seco y lluvioso según la cercanía al mar y la altura, con precipitaciones que fluctúan entre 1.200 mm y 2.000 mm anuales. Además en ciudad de Concepción, en los meses de verano, la temperatura



Figura 2.1: Área de estudio

Comuna	Población (hab) INE, Censo 2017	Densidad (hab/ km^2)	Superficie (km^2)	Promedio incendios anuales (2013 - 2015)
CHIGUAYANTE	85.938	1.354,60	63,44	12,33
COELEMU	15.995	46,50	343,98	19,00
CONCEPCIÓN	223.574	1.033,60	216,31	35,33
CORONEL	116.262	424,90	273,62	79,00
FLORIDA	10.624	17,50	607,09	43,67
HUALPÉN	91.773	2.008,70	45,69	7,00
HUALQUI	24.333	45,50	534,79	58,33
LOTA	43.535	378,50	115,02	131,67
PENCO	47.367	440,00	107,65	83,67
RÁNQUIL	5.755	23,10	249,13	12,33
SAN PEDRO DE LA PAZ	131.808	1.435,30	91,83	49,00
TALCAHUANO	151.729	1.624,60	93,39	49,33
TOMÉ	54.946	110,60	496,80	169,33
Total	1.003.639		3.238,75	750,00

Tabla 2.1: Características de las comunas del área de estudio

máxima promedio es de $24^{\circ}C$ aproximadamente y la temperatura mínima promedio es de $10^{\circ}C$ aproximadamente

2.3. Datos

En la Figura 2.2, se muestra un resumen de los datos utilizados. La imagen A muestra el área de estudio completa y la ubicación de las estaciones meteorológicas. En la imagen B, se puede ver una porción de los incendios históricos informados por CONAF, cada punto rojo es una ignición. La imagen C muestra el raster de distancia a caminos, una de las variables de

actividad humana utilizadas. La imagen D, entrega un ejemplo de las variables de geografía y topografía, que en este caso es la pendiente. Y finalmente la imagen E, muestra el mapa de cobertura de suelo de Zhao et al. (2016), con sus distintas categorías.

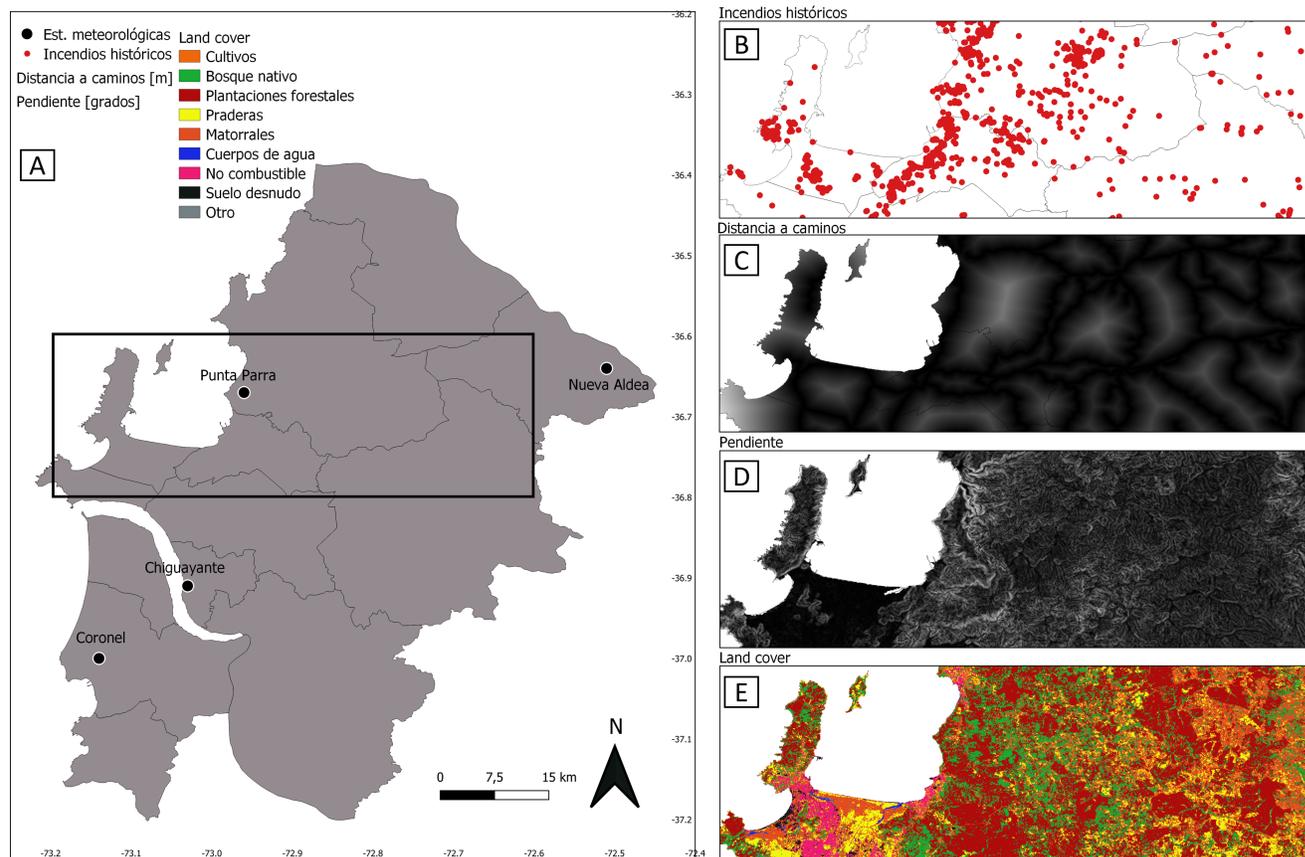


Figura 2.2: Resumen datos utilizados

2.3.1. Incendios históricos

Esta información se obtuvo de la base de datos de incendios históricos de la Corporación Nacional Forestal, CONAF (www.conaf.cl/conaf/seccion-stadisticas-historicas.html) y entrega información referente a los incendios ocurridos en el territorio nacional: coordenadas geográficas del punto de ignición, fecha de inicio, fecha de control, causa, hectáreas quemadas, entre otras características.

En particular para este estudio se tomaron los datos del periodo de enero 2013 a diciembre 2015. Se tomó esta ventana temporal, pues CONAF comenzó a registrar las coordenadas geográficas exactas de los incendios a partir del 2013 y por otro lado la información de cobertura de suelo disponible para el estudio fue desarrollada el 2014 (Zhao et al., 2016), por tanto la cobertura de suelo posterior al año 2015 es distinta a la que tomaremos como referencia.

En la Tabla 2.1 se detalla el promedio de incendios durante esta ventana temporal por comuna. Aproximadamente el 77 % de los incendios durante el periodo de estudios, iniciaron en los meses de verano, es decir diciembre (14,73 %), enero (22,29 %), febrero (19,92 %) o

marzo (20,55 %). Por otro lado un 24,04 % de los incendios tuvo una duración inferior a 1 hora y un 52,24 % inferior a 2 horas.

En la Figura 2.2.B, se puede ver la distribución espacial de los puntos de incendios, representada por puntos rojos.

2.3.2. Geografía, cobertura de suelo y actividad humana

Las variables utilizadas para el modelo de ocurrencia (algunas de ellas también utilizadas en el modelo de propagación), fueron seleccionadas pues representan factores relevantes en la ocurrencia de incendios tanto en Chile como en otras regiones (Miranda et al., 2020). Se dividen en 3 grupos: Actividad humana, geografía y topografía, y cobertura del suelo. El detalle se entrega en la Tabla 2.2.

Tipo	Variable	Descripción	Unidades	Fuente
Actividad humana	DistCam	Distancia desde el punto al camino más cercano	<i>m</i>	MOP(2018)
	DistCiu	Distancia desde el punto a la ciudad más cercana	<i>m</i>	INE (2018)
	DensViv	Densidad de viviendas	$\frac{viviendas}{km^2}$	INE(2018)
	DensPob	Densidad de población	$\frac{habitantes}{distritocensal}$	INE(2018)
Geografía y topografía	Elev	Promedio de elevación del buffer de 500 m	<i>m.s.n.m</i> ¹	SRTM
	Pend	Promedio de pendiente del buffer de 500 m	grados	SRTM
	Expos	Orientación del terreno	índice	SRTM
Cobertura del suelo ²	Cultivo	Proporción de cultivos	porcentaje	Zhao et al. (2016)
	Nativ	Proporción de bosque nativo	porcentaje	Zhao et al. (2016)
	Plant	Proporción de plantaciones forestales	porcentaje	Zhao et al. (2016)
	Imper	Proporción de terreno impermeable ³	porcentaje	Zhao et al. (2016)
	Mator	Proporción de matorrales	porcentaje	Zhao et al. (2016)
	Prade	Proporción de praderas	porcentaje	Zhao et al. (2016)
	SuelDesn	Proporción de suelo desnudo	porcentaje	Zhao et al. (2016)
	Lc	Cobertura de suelo en el punto	categorica	Zhao et al. (2016)

¹ Metros sobre el nivel del mar ; ² Proporción del terreno que ocupa la cobertura en un buffer de radio 500 m; ³ Estructuras artificiales.

Tabla 2.2: Descripción de las variables geográficas, cobertura de suelo y actividad humana

Cada una de ellas está espacialmente representada en un raster de resolución 30 metros, donde cada celda contiene información particular. Se muestra un ejemplo de algunas de éstas variables en la Figura 2.2.

2.3.3. Condiciones atmosféricas

Para conocer las condiciones atmosféricas que afectan el área de estudio, se utilizaron los datos que proporciona la Red Agroclimática Nacional (<https://www.agromet.cl/datos-historicos>). En particular los datos obtenidos fueron extraídos hora a hora de 4 estaciones meteorológicas:

- Chiguayante, ubicada en la comuna de Chiguayante.
- Coronel, ubicada en la comuna de Coronel.
- Punta Parra, ubicada en la comuna de Tomé.
- Nueva Aldea, ubicada en la comuna de Ránquil.

En la Figura 2.2.A se puede ver la localización de cada una de ellas.

Capítulo 3

Método

Siguiendo los pasos detallados en la Figura 3.1: En una primera instancia se realizó un modelo de ocurrencia, utilizando un modelo de Machine Learning, Bagged Decision Tree, que requiere como datos de entrada: los puntos de incendios históricos, las variables topográficas, de actividad humana y de cobertura de suelo, (todas explicadas en la Sección 2.3). Con este modelo, se obtuvo un mapa de probabilidad de ocurrencia.

Luego (actividad 2 en la Figura 3.1) se aplicó un modelo de propagación de incendios, utilizando el simulador Cell2Fire (Pais et al., 2019). Éste utiliza como inputs, algunas variables que ya se han utilizado para el modelo anterior como la topografía y cobertura de suelo y además otras variables nuevas como las condiciones atmosféricas, la duración de los incendios y los puntos de ignición. Al realizar N simulaciones en el área de estudio, se obtiene un mapa de probabilidad de quema.

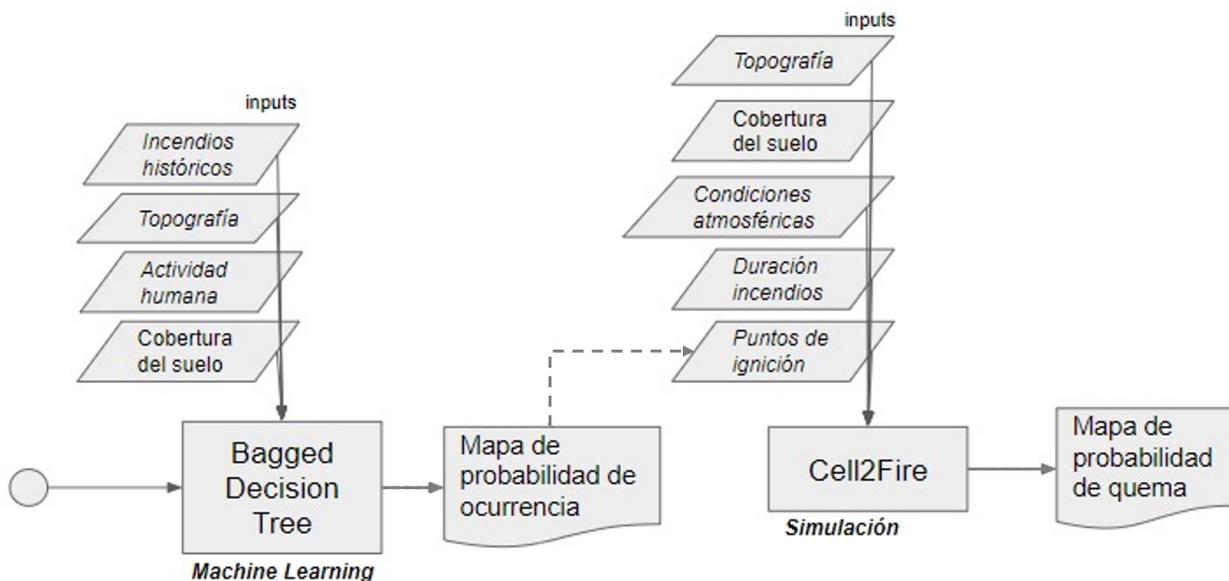


Figura 3.1: Metodología

Tal como se ve en la Figura 3.1, el resultado del modelo Bagged Decision Tree (modelo de ocurrencia), es decir el mapa de probabilidad de ocurrencia, se puede utilizar como input en el modelo de propagación (Cell2Fire), pues entrega una distribución particular de los puntos de ignición. Sin embargo como este trabajo es un primer acercamiento a una herramienta que permita realizar un diseño de paisaje resistente a incendios forestales, aún no están integrados todos los modelos que se pretenden utilizar en dicha metodología.

En los siguientes capítulos de detalla cada uno de éstos modelos.

3.1. Modelo de ocurrencia

Mediante un modelo de Machine Learning, se busca aprender los elementos que han incidido en el inicio del fuego en los incendios históricos. Así, evaluar qué factores generan mayor susceptibilidad para que ocurra un incendio. Con esto podremos conocer la probabilidad de ocurrencia de cada punto en el área de estudio.

3.1.1. Modelo utilizado

Para este modelo se implementó la metodología utilizada en Miranda et al. (2020), donde el modelo usado fue: Bagged Decision Tree, BDT (Breiman, 1996). Este es un método de Machine Learning llamado de ensamble, debido a que combina diferentes modelos de clasificación "débiles" para obtener uno "fuerte".

El Bagging (que es la abreviación de Bootstrap Aggregating) consiste en construir diferentes modelos usando muestras aleatorias, con reemplazo, y luego ensamblar los resultados. Se crean varios subconjuntos de los datos del conjunto de entrenamiento, con cada subconjunto se entrena un modelo y se promedian las predicciones de los diferentes modelos, lo que lo hace más robusto. En la Figura 3.2, se muestra un ejemplo de un modelo bagging. Esta técnica consiste en los siguientes pasos (Santana, 2014):

1. Se divide el conjunto de entrenamiento en distintos sub conjuntos de datos, que resultan ser diferentes muestras aleatorias que cumplen con lo siguiente:
 - Misma cantidad de individuos en cada conjunto
 - Con reemplazo, es decir los individuos pueden repetirse en el mismo conjunto.
 - El tamaño de la muestra y el tamaño del conjunto de entrenamiento son iguales, sin embargo no contienen los mismos individuos ya que algunos se repiten.
2. Luego se entrena un modelo con cada conjunto de datos, obteniendo diferentes predicciones en cada modelo.
3. Finalmente se construye un único modelo, que es el promedio de todas las predicciones.

Para este trabajo, usaremos el modelo Bagged Decision Tree, donde cada modelo es un árbol de decisión. Además el conjunto de entrenamiento se construyó con el 80 % de la base y el 20 % restante para testear los resultados.

Finalmente el modelo entrega como resultado la probabilidad de ocurrencia de incendios para cada punto deseado, en particular se aplicó para cuadrantes de 30m x 30m (píxeles de

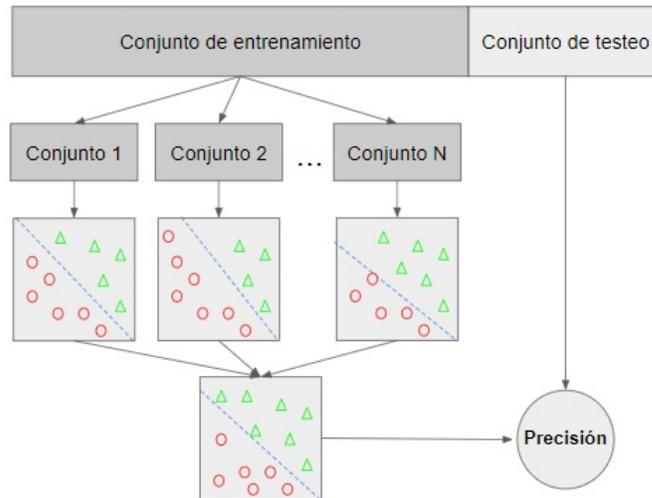


Figura 3.2: Ejemplo modelo bagging

un raster) y de esta manera se obtiene un mapa de ocurrencia de incendio para todo el área de estudio (ver Sección 4).

3.1.2. Inputs para el modelo de ocurrencia

Las variables seleccionadas para este modelo se basaron en las propuestas en Miranda et al. (2020) y entonces son aquellas que reúnen las características más representativas de la ocurrencia de incendios: actividad humana, geografía y topología y cobertura de suelo. La construcción de éstas consistió en: (i) generar puntos de la variable binaria de ocurrencia y (ii) extraer las variables explicativas de las características de cada punto.

La primera, variable dependiente, se construyó a partir de los datos de la base de CONAF (ver Sección 2.3), asignando valor 1 (uno) a los puntos históricos de incendios y valor 0 (cero) a los puntos donde no hubo ignición en la ventana temporal. Para estos últimos, se generaron puntos aleatorios a más de 500 metros de un incendio. Para esto se utilizó un Sistema de Información Geográfica de software libre y de código abierto llamado QGIS (versión 3.10. para Windows). Se determinó esta distancia entre incendios y no incendios, pues entrega un resultado más realista. Pues si bien a mayor distancia el modelo entrega un mejor resultado (lo que parece obvio, pues mientras más lejos estamos de los incendios históricos, menos probable es que se inicie un incendio y por tanto la predicción es más certera), estar a 500 metros de un incendio entrega mayor heterogeneidad en las características de los puntos de no incendio.

Finalmente se obtuvieron 4.508 puntos: 2.254 puntos donde ocurrió un incendio (1) y 2.254 puntos donde no ocurrió un incendio (0), como se muestra en la Figura 3.3, donde los puntos rojos son aquellos donde ocurrió un incendio en la ventana temporal 2013-2015 y los puntos azules es donde no ocurrió un incendio.

Las variables explicativas, se construyeron en base a los raster mencionados también en la Sección 2.3. Para obtener la información para cada punto, se extrajo el valor de la celda

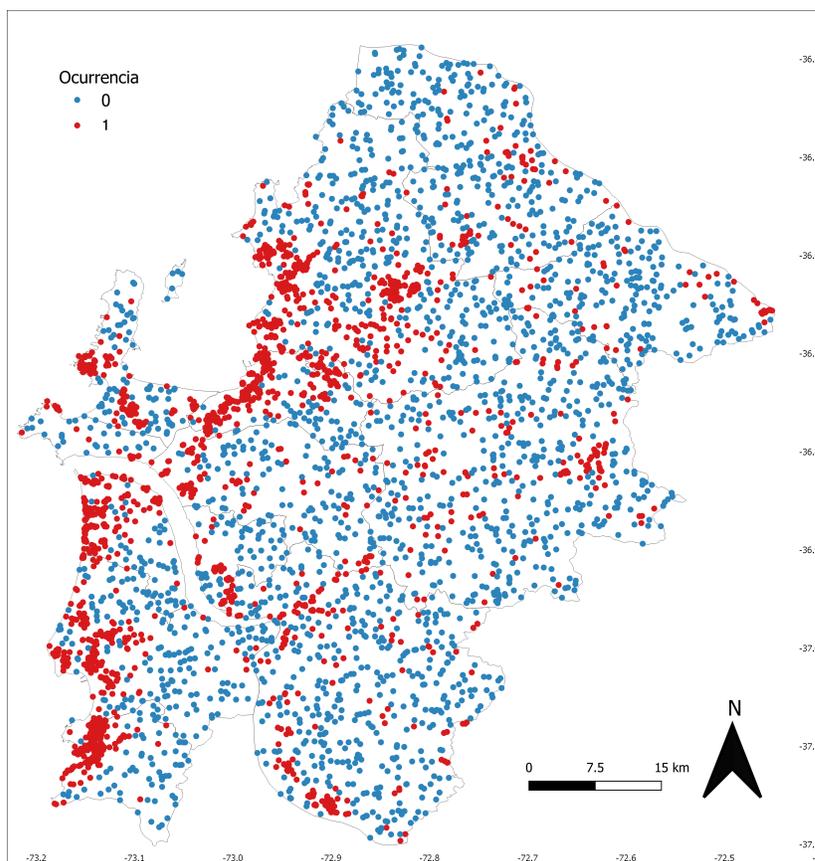


Figura 3.3: Puntos de entrenamiento del modelo

exacta en que se encuentra el punto y esto para cada una de las variable, también utilizando QGIS 3.10.

3.2. Modelo de propagación

El objetivo de este modelo, es conocer aquellas zonas que son más propensas a incendiarse, es decir, dado que se inicia un incendio en un punto, evaluar qué celdas se verán afectadas por el fuego.

En una primera instancia se compararán los resultados del simulador Cell2Fire (Pais et al., 2019) con cicatrices de incendios reales. Luego, se generan Mapas de Probabilidad de Quema (Burn Probability Map, BPM), realizando múltiples simulaciones de incendios tomando puntos de ignición aleatorios.

3.2.1. Simulador: Cell2Fire

Cell2Fire (Pais et al., 2019) es un sistema de código abierto desarrollado en Python y C++, que permite al usuario simular el crecimiento de un incendio a través de celdas que representan una porción de un bosque, usando variables de combustible, topográficas (elevación, pendiente y orientación del terreno) y características atmosféricas. Este simulador, es un modelo autómatas celular, es decir, utiliza cuadrículas de un raster de celdas cuadradas

para propagar el fuego desde el centro de una celda, al centro de otra celda adyacente y donde cada celda encendida se comporta como una fuente de ignición independiente de las otras celdas encendidas a su alrededor.

Funcionamiento

Los bosques se representan por regiones rectangulares de n filas por m columnas, con celdas de la misma dimensión, dependiendo de la resolución espacial que se utilice. Todas las variables (de combustible y topográficas) deben tener el mismo tamaño y resolución.

El algoritmo del Cell2Fire entrega el estado de todas las celdas en cada paso, que representa el avance del tiempo (cada paso tiene la misma duración). El estado del incendio y todas las celdas del paisaje se actualizan al final de cada paso. Los estados pueden ser uno de los siguientes:

- Disponible: Indica que la celda tiene contenido inflamable.
- Quemando: Indica que la celda contiene un incendio activo.
- Quemado: Indica que el incendio pasó a través de la celda.
- No Combustible: Indica que es una celda no inflamable.

El incendio inicia en el punto de ignición asignado y durante un paso el fuego puede extenderse a alguna celda vecina (existen 8 celdas posible para propagarse). El fuego se modela con un crecimiento elíptico dentro de cada celda, con el foco de la elipse en el centro de la celda.

En la Figura 3.4 se puede ver un ejemplo de una simulación en un bosque heterogéneo de 20 x 20 celdas, con una resolución de 100 m cada celda, con 8 horas de duración. El primer recuadro (arriba a la izquierda) muestra el punto de ignición y luego los siguientes 8 recuadros muestran el avance del incendio, mostrando las celdas quemadas al final de cada paso.

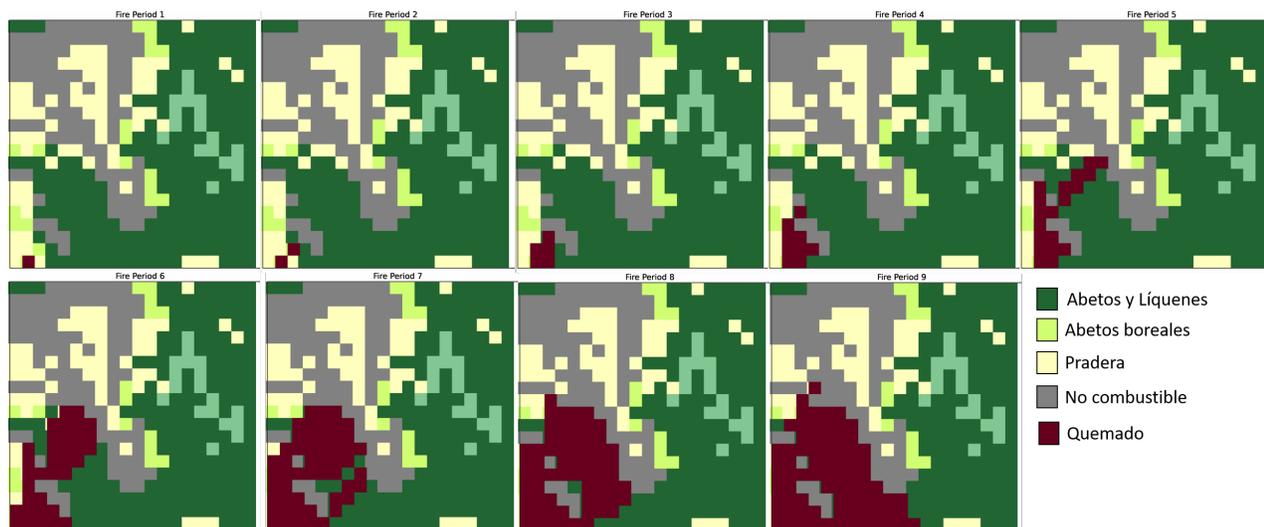


Figura 3.4: Ejemplo de avance simulación de incendio.

Los detalles del algoritmo y el modelo utilizado están descritos en el trabajo realizado por Pais et al. (2019).

Inputs

Tal como se menciona en la sección 3.5 de Pais et al. (2019), los inputs para el simulador Cell2Fire son:

1. Datos del bosque. Raster que especifican el número de celdas, las coordenadas geográficas y la información para cada celda. Los datos del bosque utilizados son:
 - Elevación: Representa la altitud, medida en metros sobre el nivel del mar.
 - Pendiente: Inclinación del terreno, medida en porcentaje.
 - Orientación del terreno: Medido en grados, de 0 a 360.
 - Cobertura de suelo: Tipo de combustible, representado en categorías.

Se utilizaron los raster descritos en la Sección de Datos (ver Sección 2.3).

Sin embargo, este simulador fue implementado para tipos de combustibles del Canadian FBP System y aún no está desarrollado para un modelo de combustibles chilenos, por tanto fue necesario hacer una conversión para poder utilizarlo con combustibles chilenos. Es decir, a cada valor de cobertura de suelo de Chile (Zhao et al., 2016) se le asignó un valor de los combustibles de Canadian FBP System, en base a la experiencia y juicio de expertos. El raster de cobertura de suelo de Chile, tiene 9 tipos de coberturas, descritos en la tabla 3.1 y a cada uno de ellos se le asignó un combustible canadiense.

Chile		Canadá	
1	Cultivos	31	O-1a Matted grass
2	Bosque nativo	80	M-4 Dead Balsam Fir Mixedwood - Green
3	Plantaciones	6	C-6 Conifer Plantation
4	Praderas	31/32	O-1a/O-1b Matted grass/Standing grass
5	Matorrales	21/22	S-1/S-2 Jack or Lodgepole Pine Slash/White Spruce - Balsam Slash
6	Humedales	105	Vegetated Non-Fuel Non-fuel
7	Cuerpos de agua	102	Water Non-fuel
8	Superficie impermeable	101	Non-Fuel Non-fuel
9	Suelo desnudo	101	Non-Fuel Non-fuel

Tabla 3.1: Conversión combustible chileno a canadiense

2. Diccionario de combustible: Es un archivo que detalla las características de cada combustible. Para este trabajo no se modificó el diccionario, ya que los combustibles utilizados se transformaron a los de Canadian FBP System.
3. Punto de ignición. Es posible indicar el punto de ignición de diferentes maneras:
 - Un punto específico: Se indica el número de la celda en la que inicia el fuego. Para simular los incendios reales (que luego serán comparados con las cicatrices), se utiliza el punto de ignición indicado por CONAF.
 - Puntos aleatorios: Es posible tomar puntos aleatorios en un radio en torno a un punto específico o también se puede tomar un punto aleatorio dentro de todo el

bosque (considerando una distribución uniforme de ocurrencia, misma probabilidad para cada punto).

- Siguiendo la distribución del Modelo de Ocurrencia: Se utiliza un raster como el generado en la Sección 3.1, donde cada celda del raster tiene asignada una probabilidad de ocurrencia. Para seguir la distribución espacial de la ocurrencia de incendios, se utilizó el método de Montecarlo. Es decir, se toma un punto aleatorio dentro del área de estudio y se compara el valor de la probabilidad de ocurrencia que hay en ese punto con un número aleatorio entre 0 y 1, si la probabilidad de ocurrencia es mayor que el número aleatorio entonces se inicia el fuego en esa celda, de lo contrario no se inicia y se busca otro punto. Esto permite que la distribución de igniciones siga la distribución de la probabilidad de ocurrencia. Esta manera aún no está implementada en el simulador.
4. Características atmosféricas: Aportan información tanto de las condiciones atmosféricas, como de la duración del incendio. Los datos se entregan hora a hora y para cada hora se debe entregar información de precipitaciones en *mm* (APCP), temperatura media en $^{\circ}C$ (TMP), humedad relativa en % (RH), velocidad del viento en *km/s* (WS), dirección del viento en $^{\circ}$ (WD) e índices del FWI (Fire Weather Index): FFMFC, DMC, DC, ISI, BUI, FWI. La Tabla 3.2, muestra un ejemplo de un archivo de características atmosféricas usado en el simulador.

Scenario	datetime	APCP	TMP	RH	WS	WD	FFMC	DMC	DC	ISI	BUI	FWI
PP2014	06-01-2014 13:00	0	25.4	42.5	21.6	234.5	89.66	269.62	1212.6	12.13	346.59	45.19
PP2014	06-01-2014 14:00	0	24.6	51.1	23.76	222.9	89.54	272.41	1220.73	13.29	349.72	47.88
PP2014	06-01-2014 15:00	0	22.6	57.1	24.48	257.1	88.34	274.66	1228.5	11.6	352.37	43.93
PP2014	06-01-2014 16:00	0	21.4	59.3	25.2	233.5	87.69	276.69	1236.06	10.96	354.82	42.36
PP2014	06-01-2014 17:00	0	20.8	60.3	23.4	230.8	87.37	278.62	1243.51	9.56	357.17	38.8
PP2014	06-01-2014 18:00	0	20.4	60.7	21.96	221	87.21	280.49	1250.88	8.69	359.47	36.46
PP2014	06-01-2014 19:00	0	19.1	65.3	21.96	233.9	86.34	282.04	1258.03	7.68	361.48	33.6
PP2014	06-01-2014 20:00	0	17	70.6	20.16	213	85.14	283.22	1264.79	5.93	363.15	28.23
PP2014	06-01-2014 21:00	0	15.8	74.2	11.88	184.7	84.24	284.19	1271.34	3.46	364.62	19.29
PP2014	06-01-2014 22:00	0	15.1	78	12.6	196.5	83.31	284.98	1277.76	3.17	365.93	18.11

Tabla 3.2: Ejemplo archivo de datos atmosféricos para simulador

El FWI entrega información respecto de la influencia que tienen las condiciones meteorológicas en la humedad del combustible y el comportamiento relativo del fuego en los combustibles a nivel del suelo. Este índice consta de seis componentes relacionados de manera jerárquica (Wotton, 2009):

- Primarios: aportan información de la humedad de los combustibles.
 1. FFMFC (Fine Fuel Moisture Code): Orientado a la hojarasca y los combustibles finos muertos en el suelo del bosque, 0 – 5 cm de profundidad.
 2. DMC (Duff Moisture Code): Orientado a la humedad de la materia orgánica bajo el suelo del bosque, entre 5 cm y 10 cm de profundidad.
 3. DC (Drought Code): Orientado a la humedad en la capa profunda de la materia orgánica, entre 10 cm y 20 cm de profundidad.
- Secundarios: Los anteriores tres índices integrados entre si.
 4. ISI (Initial Spread Index): Se construye con el FFMFC combinado con la velocidad del viento.
 5. BUI (Buildup Index): Se construye con la combinación de DMC y DC.

- Terciario

6. FWI: combina los dos índices anteriores.

Éstos índices se construyen de manera recursiva, con un algoritmo que toma en consideración los valores de los índices anterior y por tanto, es necesario entregar una semilla para iniciar el algoritmo ($ffmc_0$, dmc_0 y dc_0). En este trabajo se utiliza como inicio los índices promedio de los incendios ocurridos en la Región del Biobío durante la ventana temporal de estudio (2013-2015): $ffmc_0 = 82,24$, $dmc_0 = 40,57$, $dc_0 = 302,91$.

Para los propósitos de este trabajo, se construyeron archivos de datos meteorológicos de los meses de Enero-Febrero-Marzo 2013 - 2014 - 2015 para las 4 estaciones meteorológicas, indicadas en la Sección 2.3. Para realizar las cicatrices de incendio, se tomaron los datos correspondientes a las horas de la duración del incendio indicadas por CONAF. Por otro lado para hacer los BPM (Burn Probability Maps) se realizó un muestro aleatorio estratificado, considerando la distribución de las horas en las que inician los incendios históricos en la Región del Biobío (de sobre 10 ha quemadas) y sus duraciones. Se crearon 1000 archivos para cada estación meteorológica, con datos, horas de inicio y duraciones distintas.

Outputs

Los output del simulador pueden ser los descritos en la sección 3.6 de Pais et al. (2019). Para el presente estudio, teniendo en consideración el tiempo computacional, solo se generaron las grillas de quema (Burn-Grids):

- Final Grid: Grillas finales de quema, que representan la cicatriz del incendio. El píxel toma valor 1 si fue quemado y valor 0 si no.
- Output Messages: Información del avance del incendio. Las celda previa y a la que avanza el incendio, el periodo en el que ocurre el evento y el ROS

3.2.2. Cicatrices de incendio

Las cicatrices, se construyen con la extracción semi-automatizada del perímetro y severidad de cada incendio, a través de una rutina computacional en Google Earth Engine. Se utilizó la metodología de generación de cicatrices descrita en Pais et al. (2021), que consiste en:

1. Generar una imagen pre incendio (en la Figura 3.5, es la imagen A) y otra post incendio (B en la Figura 3.5), mediante el cálculo de un mosaico de las colecciones de imágenes de 3 meses antes y 3 meses después del incendio (la ventana temporal es modificable en el caso que no existan imágenes suficiente para realizar los mosaicos).
2. Al comparar ambas imágenes (pre y post), se detectan cambios del color de la cobertura y se calcula el Relative Differenced Normalized Burn Ratio (RdNBR), un índice diseñado para resaltar áreas quemadas en grandes zonas de incendio (Imagen C en la Figura 3.5).
3. Finalmente se genera (a través de la observación, es decir de forma manual) un umbral del ratio (RdNBR), que determina la existencia de cicatriz de incendio (D en la Figura 3.5).

En la Figura 3.5, las imágenes de 1 son de un incendio de febrero de 2015 en la región del Biobío, con 4516 ha quemadas y las imágenes de 2 son de un incendio de febrero de 2015, 1950 ha quemadas, también en la región del Biobío.

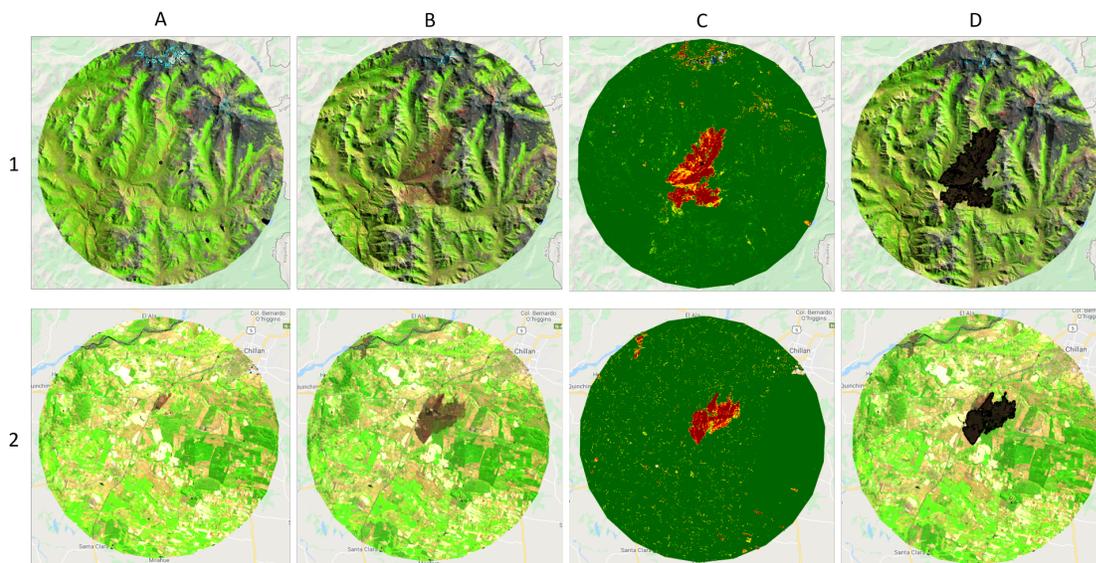


Figura 3.5: Ejemplos metodología de construcción de cicatrices de incendios

Una vez que se extrae la cicatriz, se realiza una simulación del mismo incendio, es decir se utiliza como punto de ignición la misma ubicación geográfica donde inició el incendio detallado por CONAF, además se utilizan las condiciones atmosféricas del día (tomada por la estación meteorológica más cercana), la hora y la duración indicadas también en la base de datos de CONAF.

Finalmente se comparan ambos incendios, el real representado por la cicatriz y el simulado.

3.2.3. Mapa de probabilidad de quema

Se utiliza para capturar la probabilidad de quema, considerando una probabilidad de ocurrencia homogénea en toda el área de estudio, es decir se tomaron puntos de ignición aleatorios.

Se realizaron 10.000 simulaciones en el área de estudio completa, un raster con resolución de 30 metros (descritos en la Sección 2.3). Un raster de 3.055 filas y 2.279 columnas, con un 48.9388% de celdas disponibles, es decir con cobertura combustible (un gran porcentaje de celdas son No-Data, pues están fuera del área de estudio). Para emplear el simulador se utilizó Python 3.8.5 en Ubuntu 20.04.2.

Capítulo 4

Resultados y discusión

4.1. Modelo de ocurrencia

El modelo Bagged Decision Tree se utilizó con 4.508 observaciones, de los cuales 2.254 eran unos (puntos de incendios históricos) y 2.254 ceros (puntos de no incendio).

4.1.1. Selección variables

Las variables utilizadas, son las 15 descritas en la Sección 2.3.2, es decir:

- Actividad humana: Distancia camino, Distancia ciudad, Densidad de vivienda y Densidad de población.
- Geografía y topografía: Elevación, Pendiente, Exposición.
- Cobertura del suelo: Porcentaje del tipo de combustible en un buffer (Cultivo, Bosque nativo, Plantaciones forestales, Superficie impermeable, Matorrales, Praderas y Suelo desnudo) y Tipo de cobertura de suelo en el punto

Se realizó un análisis de correlación y de importancia de las variables, donde se descartaron aquellas con alta correlación, dejando dentro del modelo las que tenía mayor importancia.

En la Figura 4.1 se muestra la matriz de correlación (imagen A) de las 15 variables iniciales y sus respectivas importancias dentro del modelo (imagen B). En la matriz de correlación vemos que los recuadros con un color amarillo tiene una alta correlación, mientras que los recuadros con un color más cercano al azul tienen menos correlación.

Con este análisis se decidió descartar la variable de Densidad Poblacional, pues tiene una alta correlación con la variable Densidad de Vivienda y una menor importancia que esta última (ver Figura 4.1).

Finalmente se utilizaron 14 variables independientes y una variable dependiente (variable binaria de ocurrencia). En la Figura 4.2, se muestra la importancia de cada una de las variables finales, donde podemos ver que las variables que más aportan a la predicción son: Bosque Nativo, lo que se podría explicar pues aquellas zonas con cobertura natural (no

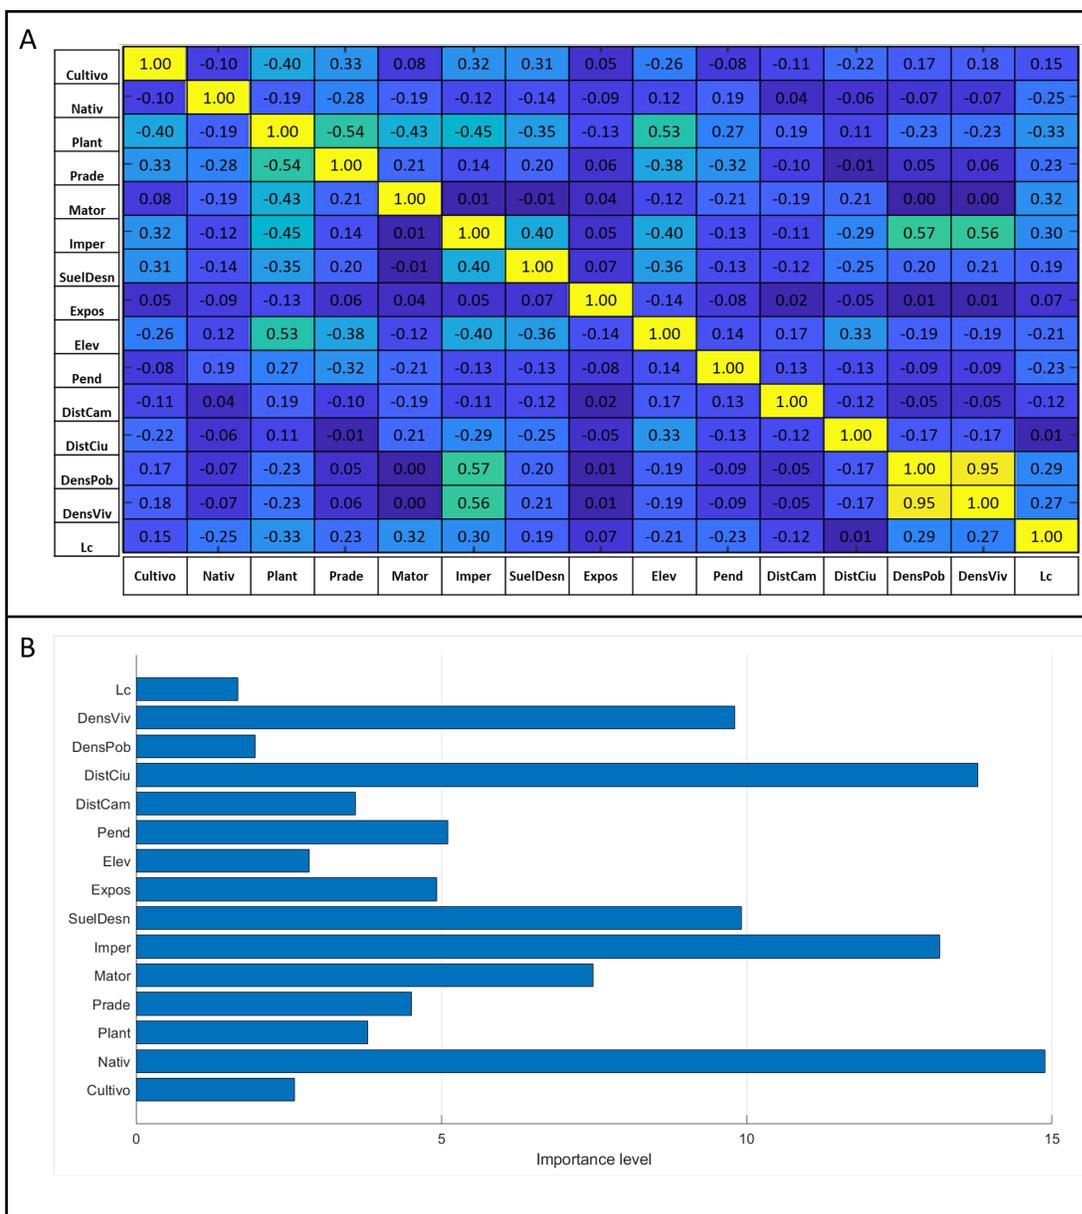


Figura 4.1: A) Matriz de correlación variables iniciales. B) Importancia de las variables iniciales modelo de ocurrencia

intervenidas por humanos) tienden a tener menor ocurrencia de incendio (Ricotta et al., 2018); Superficie Impermeable, pues son superficies no combustibles y por tanto es difícil que se inicien fuegos en ellas; y Distancia a Ciudad, lo que refleja la relevancia que tiene la actividad humana en las igniciones de incendio, tal como se indica en Syphard et al. (2008).

4.1.2. Indicadores del modelo

Para evaluar el rendimiento del modelo, se utiliza la curva ROC (Característica Operativa Relativa), que es la representación gráfica de la razón entre los verdaderos positivos (TPR, razón de verdaderos positivos) y los falsos positivos (FPR, razón de falsos positivos). El área bajo la curva (AUC) se utiliza para evaluar la efectividad del modelo, donde 1 representa un

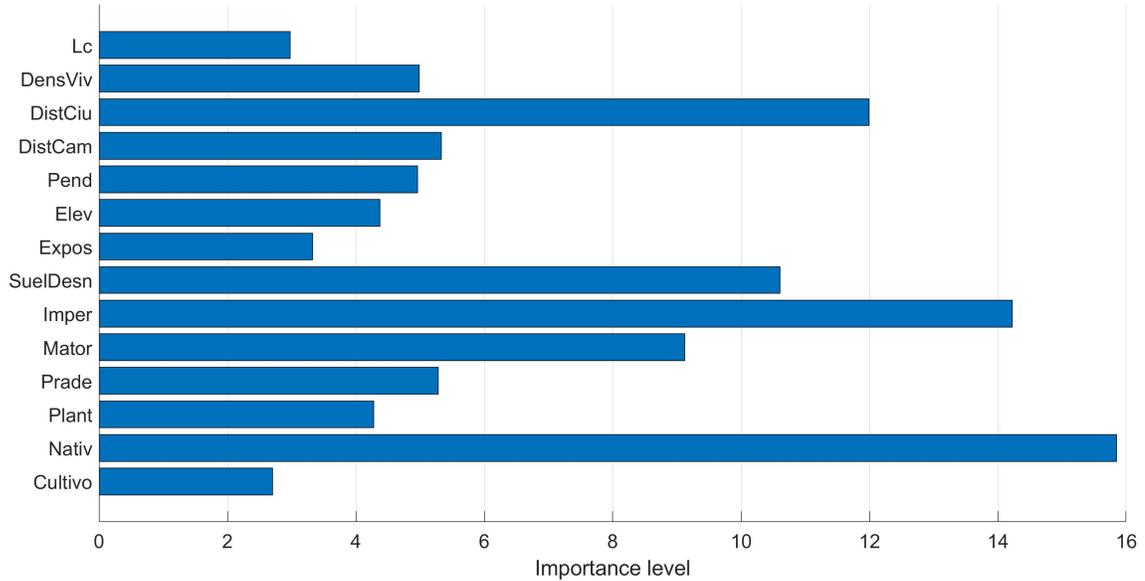


Figura 4.2: Importancia de las variables finales modelo de ocurrencia

valor perfecto y 0,5 es un modelo sin capacidad discriminatoria.

En la Figura 4.3, la imagen A muestra la curva ROC del modelo Bagged Decision Tree (BDT) utilizado en este trabajo y la imagen B, muestra su matriz de confusión.

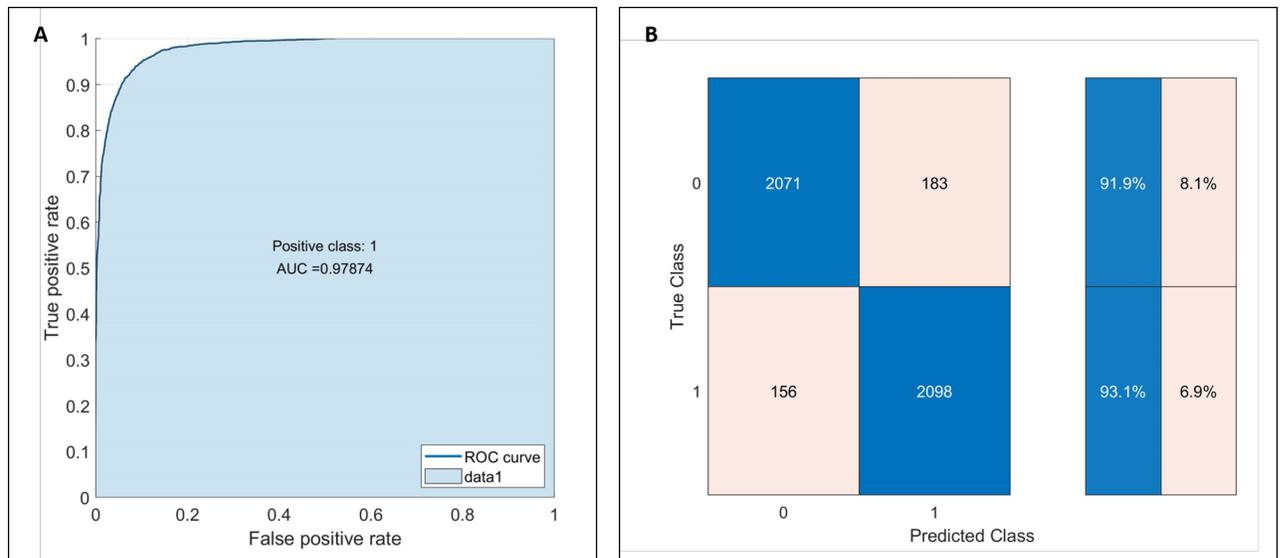


Figura 4.3: A) Curva ROC del modelo de ocurrencia. B) Matriz de confusión del modelo de ocurrencia

Como vemos en la Figura 4.3.A, el modelo utilizado tiene un $AUC = 0,9787$, lo que nos indica que el modelo es muy bueno, ya que está más cerca de la discriminación perfecta que de la no discriminación.

De igual manera, la matriz de confusión también nos permite visualizar el desempeño

del modelo. En Figura 4.3.B, las columnas de la tabla de la izquierda indican el número de predicciones de cada clase (0 o 1) y las filas representan los datos reales. La tabla de la derecha, indica que: Un 91,9 % de los valores reales 0, el modelo los predijo como 0; por otro lado un 93,1 % de los valores reales 1, el modelo los predijo correctamente como 1.

4.1.3. Mapa de ocurrencia de incendios

El modelo fue aplicado a toda el área de estudio, es decir a un raster de 3.055 filas y 2.279 columnas, con 3.565.447 celdas (de 30mx30m) con datos. Cada uno de estos puntos tiene asignadas las 14 variables con las que se entrenó el modelo BDT y por tanto el resultado arroja una probabilidad de ocurrencia de incendio para dicho punto. Con estos valores, se construye un mapa de ocurrencia, donde los valores serán representados con una escala de colores que va desde rojo para aquellos puntos cercanos a 1 (alta probabilidad de ocurrencia de incendios), hasta el azul para los cercanos a 0 (baja probabilidad de ocurrencia), tal como se puede ver en la Figura 4.4.

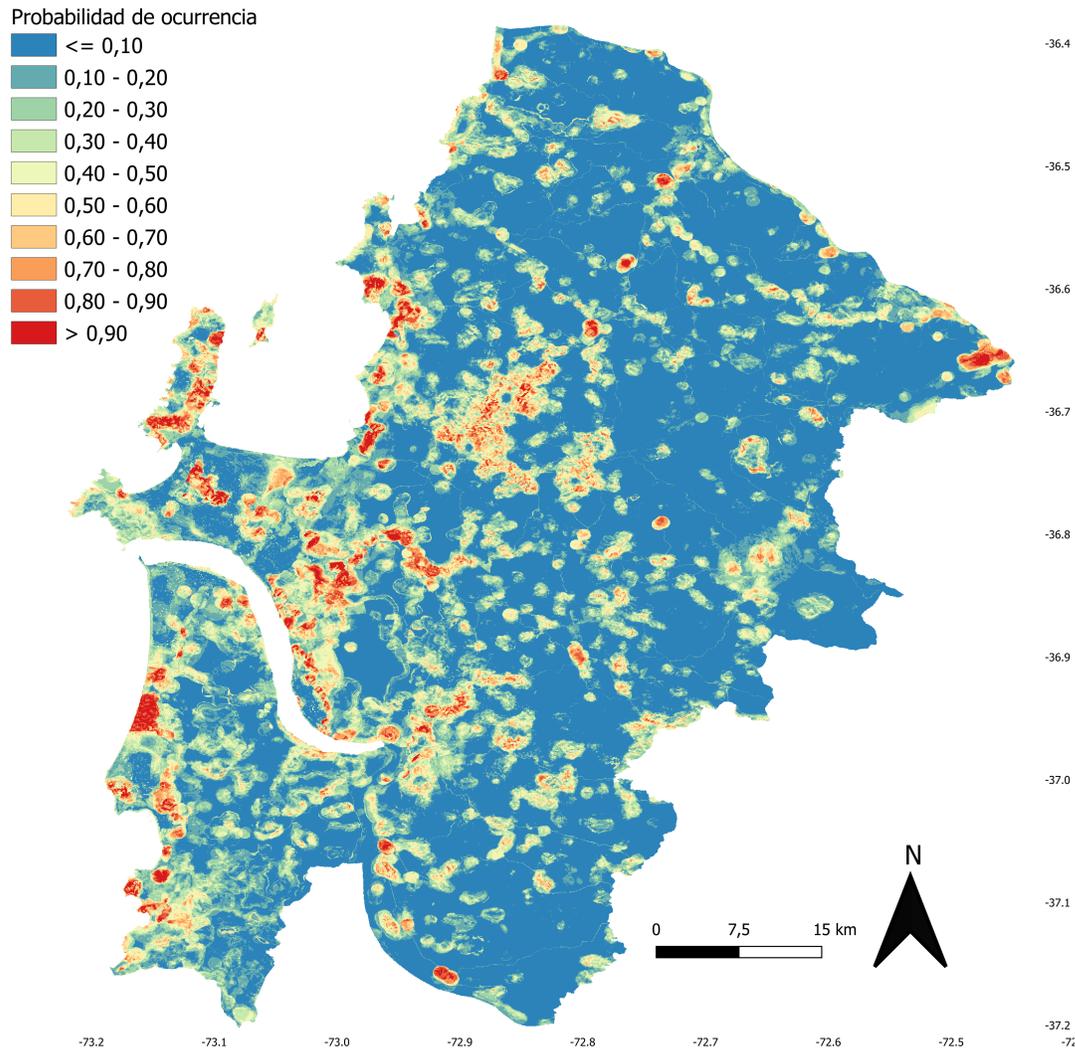


Figura 4.4: Mapa probabilidad de ocurrencia de incendios

Análisis mapa de ocurrencia

Tal como se ve en la Figura 4.5, el mapa de probabilidad de ocurrencia resultante del modelo (Imagen A, a la izquierda en la figura), concuerda en gran medida con la distribución de ocurrencia de los incendios reales (Imagen B, a la derecha de la imagen). Y por tanto, se cumple lo esperado, que aquellas zonas de mayor probabilidad de ocurrencia, concentren una mayor cantidad de igniciones de incendios reales.

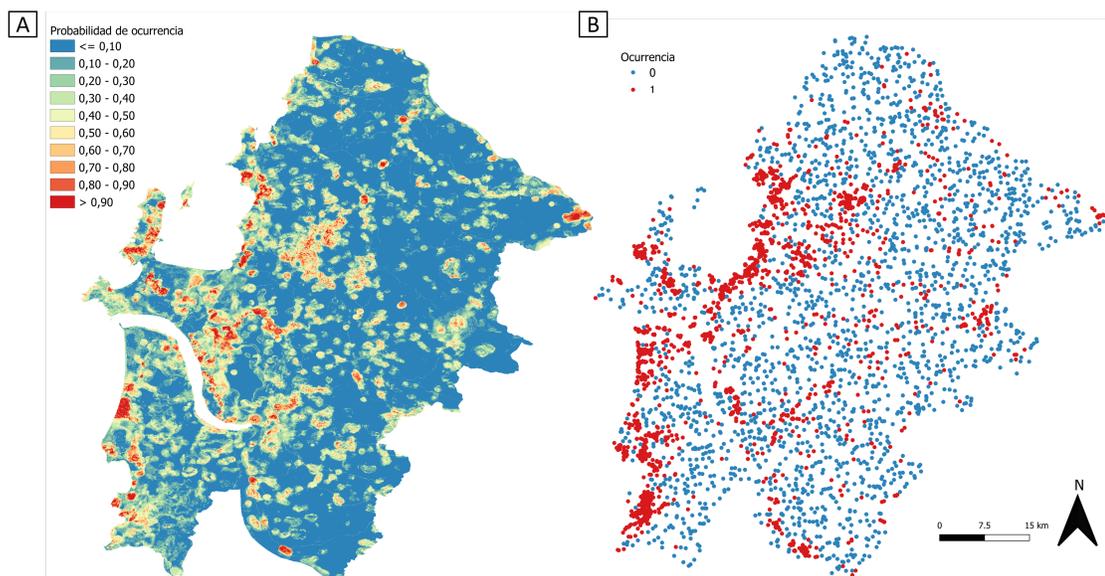


Figura 4.5: Mapa de probabilidad de ocurrencia v/s Ocurrencia real

Además, se puede ver en la Figura 4.6, que la probabilidad de ocurrencia es mayor (zonas más rojas) en las áreas en torno a ciudades, representadas en el mapa por manzanas (bloque urbano) de color gris oscuro y lo mismo ocurre en torno a la caminos (red vial), representado por líneas punteadas, tal como se menciona en el trabajo de Yang et al. (2007). Esto nos muestra que el modelo de ocurrencia desarrollado en este trabajo entrega resultados similares a los evidenciados en la literatura.

Por otro lados, si bien la mayoría de los puntos tienen una probabilidad de ocurrencia inferior al 10% (ver Tabla 4.1), un 3,67% del área de estudio tiene una probabilidad de ocurrencia de incendio superior al 70%, lo que significa un gran riesgo de ignición en más de 11.800 hectáreas de la zona urbano rural de Concepción.

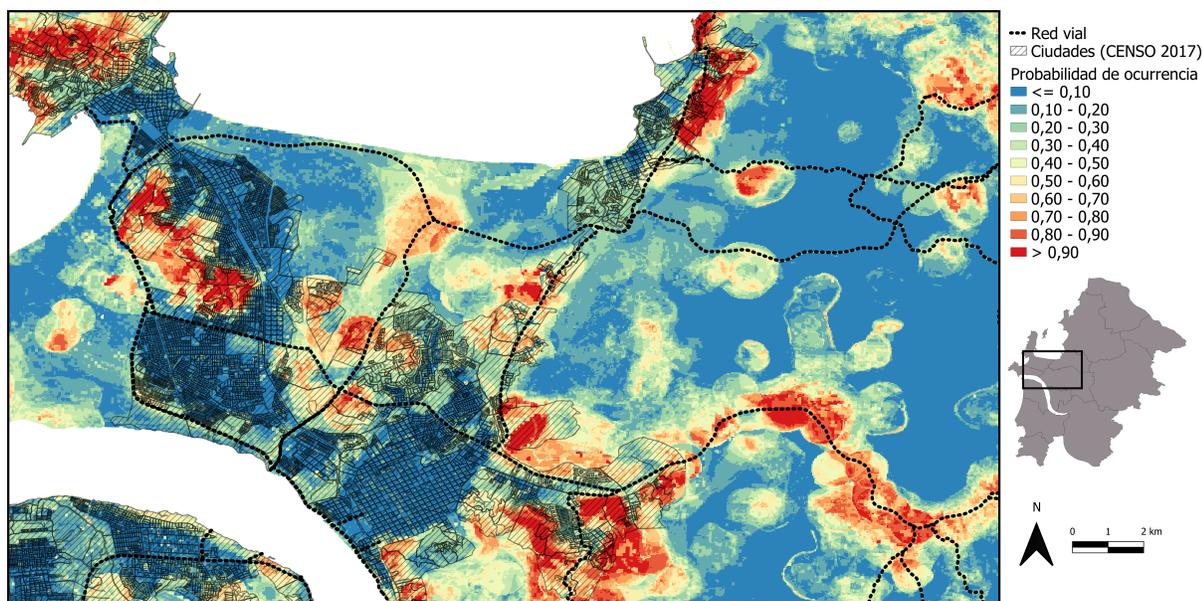


Figura 4.6: Análisis mapa de ocurrencia de incendios

Prob. ocur.	Cant. celdas	Cant. ha	Proporción
0 %-10 %	1.947.846	175.306	54,63 %
10 %-20 %	483.933	43.554	13,57 %
20 %-30 %	357.949	32.215	10,04 %
30 %-40 %	254.102	22.869	7,13 %
40 %-50 %	177.957	16.016	4,99 %
50 %-60 %	126.521	11.387	3,55 %
60 %-70 %	85.871	7.728	2,41 %
70 %-80 %	61.111	5.500	1,71 %
80 %-90 %	40.065	3.606	1,12 %
90 %-100 %	30.092	2.708	0,84 %
<i>Total</i>	<i>3.565.447</i>	<i>320.890</i>	<i>100,00 %</i>

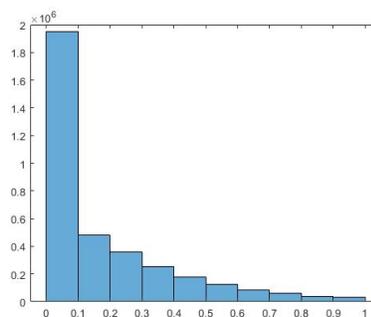


Tabla 4.1: Histograma probabilidad de ocurrencia

4.2. Modelo de propagación

4.2.1. Comparación con cicatriz de incendio

Para conocer el comportamiento del simulador en bosques chilenos, se realizaron simulaciones de incendios reales como por ejemplo el incendio de código 169143 de la base de CONAF (ver Figura 4.7, imagen A) que inició a 700 metros de la estación meteorológica Punta Parra el 06/01/2014 a las 13.21 hrs y fue controlado el 13/01/2014 a las 12.06 hrs, donde se quemaron 643 hectáreas.

Al simular usando el punto de ignición indicado por CONAF y las condiciones atmosféricas de Punta Parra en las horas indicadas también por CONAF, resultó la cicatriz mostrada en la imagen B de la Figura 4.7.

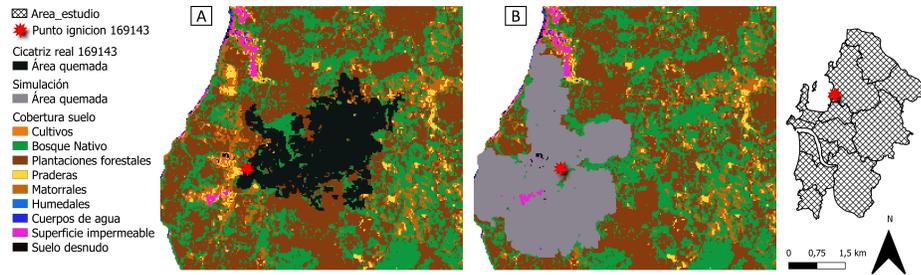


Figura 4.7: Simulación cicatriz incendio 169143

En la Figura 4.8.A, se muestra otro ejemplo de incendio real que es el incendio 177026. Inició el 11/03/2015 a las 14.17 hrs a 3.400 metros de la estación meteorológica de Nueva Aldea y fue controlado el mismo día 11/03/2015, sin embargo no se conoce la hora exacta (CONAF no la informó en su base de datos) y se quemaron 90 hectáreas.

Este incendio que se ve en la imagen B de la misma figura, es la simulación para la que se asume una duración de 9 horas, es decir hasta las 23.00 de ese mismo día.

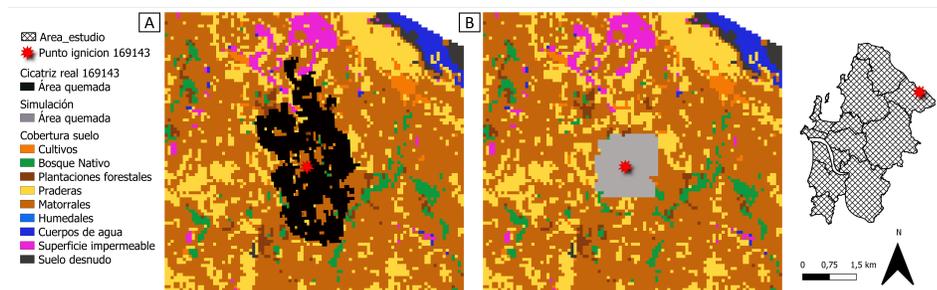


Figura 4.8: Simulación cicatriz incendio 177026

Como podemos ver, el simulador no entrega resultados óptimos en cuanto a similitud con las cicatrices reales de incendio, esto se puede deber a alguna de los siguientes inconvenientes:

- Al realizar la conversión de combustibles chilenos a canadienses, se pierde precisión. Esto debido a que el fuego se comporta de distintas maneras según el combustible que esté quemando y al no tener un mayor nivel de detalle para el tipo de combustible chileno, perdemos precisión en las características de estos combustibles. Por ejemplo, para el caso particular del incendio 169143, el incendio real quema lo que el land cover de Zhao et al. (2016) indica que es Bosque Nativo, sin embargo no tenemos información respecto a qué especie es y por tanto la conversión que hicimos a Abetos (ver Sección 3.2.1) no necesariamente es la más adecuada en términos de las características del combustible.
- Los datos atmosféricos vienen de la información proporcionada por las estaciones meteorológicas, que no siempre están cercanas al punto de ignición. Para el caso del incendio 177026, la estación más cercana es la estación Nueva Aldea, que se encuentra a 3.400 metros del punto de ignición indicado por CONAF y por tanto los datos pueden variar debido a la topografía, influencia del mar, entre otros elementos que afectan principalmente los datos de viento, que son muy relevante a la hora de simular un incendio.

- Tanto el punto de ignición, las hectáreas quemadas como las horas de inicio y control del incendio, son datos proporcionados por CONAF y no siempre son exactos. Por ejemplo, el incendio 177026 no tiene información exacta de la hora de control, por tanto es necesario suponerla y con esto perder información real que nos lleve a conocer cómo se comportó el incendio.
- No es posible simular el combate del incendio y por tanto es posible que las hectáreas quemadas en la simulación sean superiores y/o distintas a las quemadas en el incendio real.

4.2.2. Mapa de probabilidad de quema

Tal como se mencionó en la Sección 3.2.3, mediante un modelo de propagación, se realizó un mapa de probabilidad de quema con igniciones aleatorias, cada celda tiene la misma probabilidad de ocurrencia. El resultado de realizar 10.000 simulaciones es el mapa presentado en la Figura 4.9, donde las zonas rojas son aquellas con mayor probabilidad de quema, es decir una mayor cantidad de incendios quemaron esas celdas.

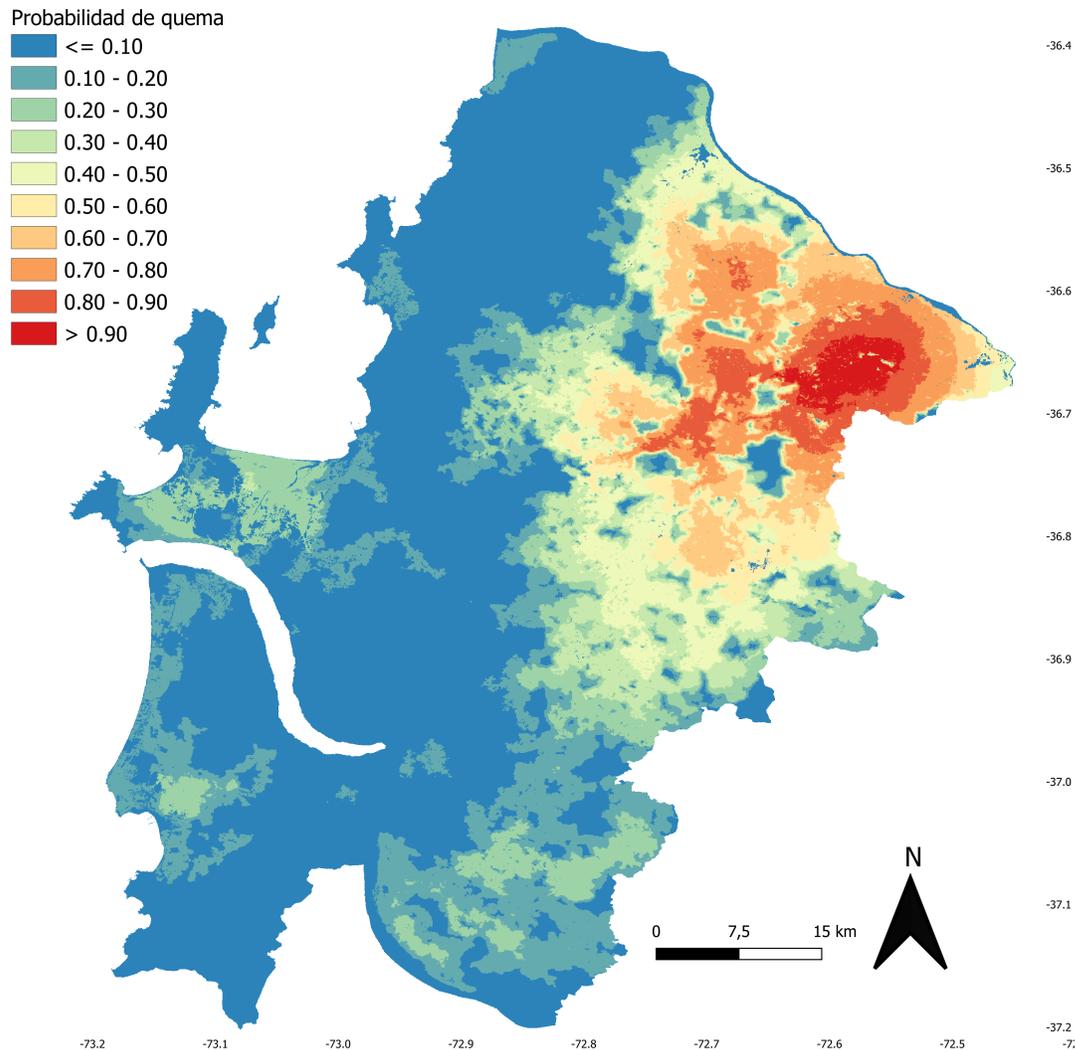


Figura 4.9: Mapa probabilidad de quema

De un total de 3.565.447 celdas que corresponde a alrededor de 320.800 hectáreas, un 7,84 % tienen una probabilidad de quema superior al 70 % (ver Tabla 4.2).

Prob. quema	Cant. celdas	Cant. ha	Proporción
0 % - 10 %	1.699.518	152.957	47,67 %
10 % - 20 %	584.210	52.579	16,39 %
20 % - 30 %	333.987	30.059	9,37 %
30 % - 40 %	195.611	17.605	5,49 %
40 % - 50 %	197.898	17.811	5,55 %
50 % - 60 %	134.605	12.114	3,78 %
60 % - 70 %	139.943	12.595	3,92 %
70 % - 80 %	143.544	12.919	4,03 %
80 % - 90 %	99.924	8.993	2,80 %
90 % - 100 %	36.207	3.259	1,02 %
<i>Total</i>	<i>3.565.447</i>	<i>320.890</i>	<i>100,00 %</i>

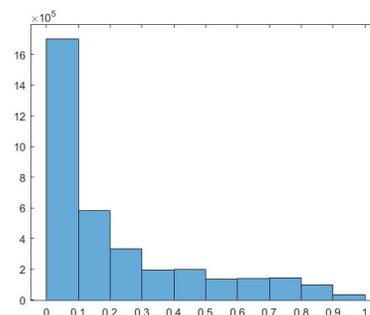


Tabla 4.2: Histograma probabilidad de quema

Estas celdas con mayor la probabilidad de quema, se concentran en la zona nororiente del área de estudio. Una de las razones por la que esta zona tiene una mayor probabilidad de quemarse, es debido a la continuidad y al tipo de combustible, lo que podemos evidenciar en la Figura 4.10 donde vemos que las zonas más rojas del mapa de probabilidad de quema, tienen una cobertura de suelo altamente combustible. Las celdas con probabilidad de quema superior al 70 %, son en mayor medida matorrales (59,16 %), plantaciones forestales (16,49 %), praderas (14,16 %) y en menor medida bosque nativo y cultivos.

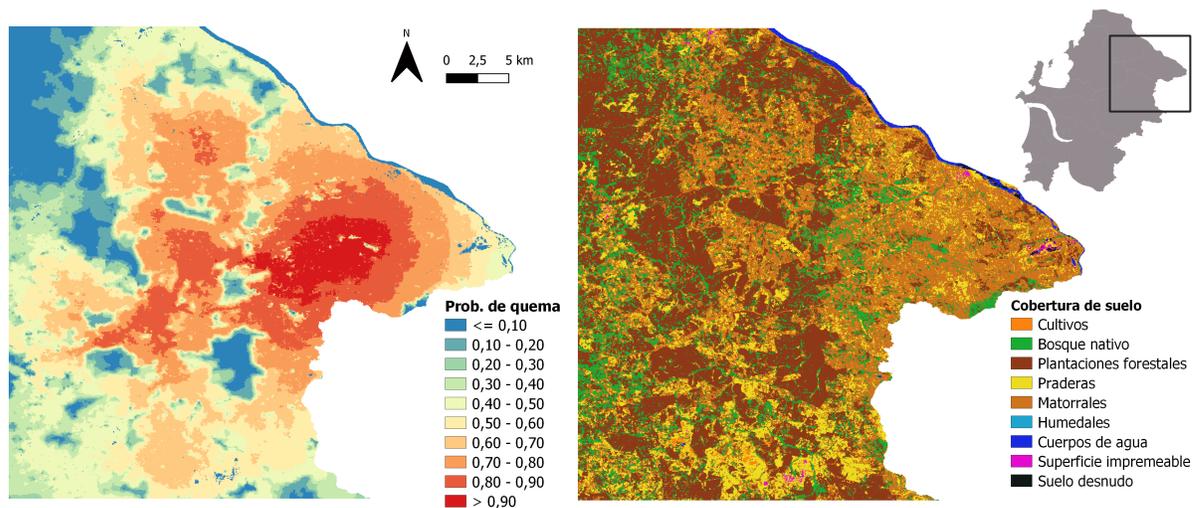


Figura 4.10: Mapa probabilidad de quema y cobertura suelo

Si bien el simulador no entrega buenos resultados al comparar con cicatrices de incendios reales, entrega buenos resultados para el Mapa de Probabilidad de Quema. Esto deja ver el error asociado a la simulación específica de un incendio, no se debe a que el simulador no representa la propagación del fuego, si no a los datos que estamos utilizando, en particular los de cobertura de suelo y meteorología.

4.3. Riesgo de incendio

Para conocer el riesgo que esto significa para la población humana, se cruzó la probabilidad de quema con información de densidad poblacional.

En la Figura 4.11, la imagen superior izquierda indica la distribución de población humana (medida en número de habitantes por cada 10.000 metros cuadrados) (Lloyd et al., 2019). En la imagen inferior izquierda vemos el mapa de probabilidad de quema (Burn Probability Map), explicado anteriormente. Y finalmente al lado derecho de la Figura 4.11, vemos el cruce de ambos mapas anteriores, es decir el mapa de riesgo de incendio, al que le quitamos las zonas urbanas declaradas por MINVU (Ministerio de Vivienda y Urbanismo, 2011), pues las zonas en las zonas urbanas no se generan incendios forestales y además aquellas celdas con alta concentración de población distorsiona el análisis de riesgo.

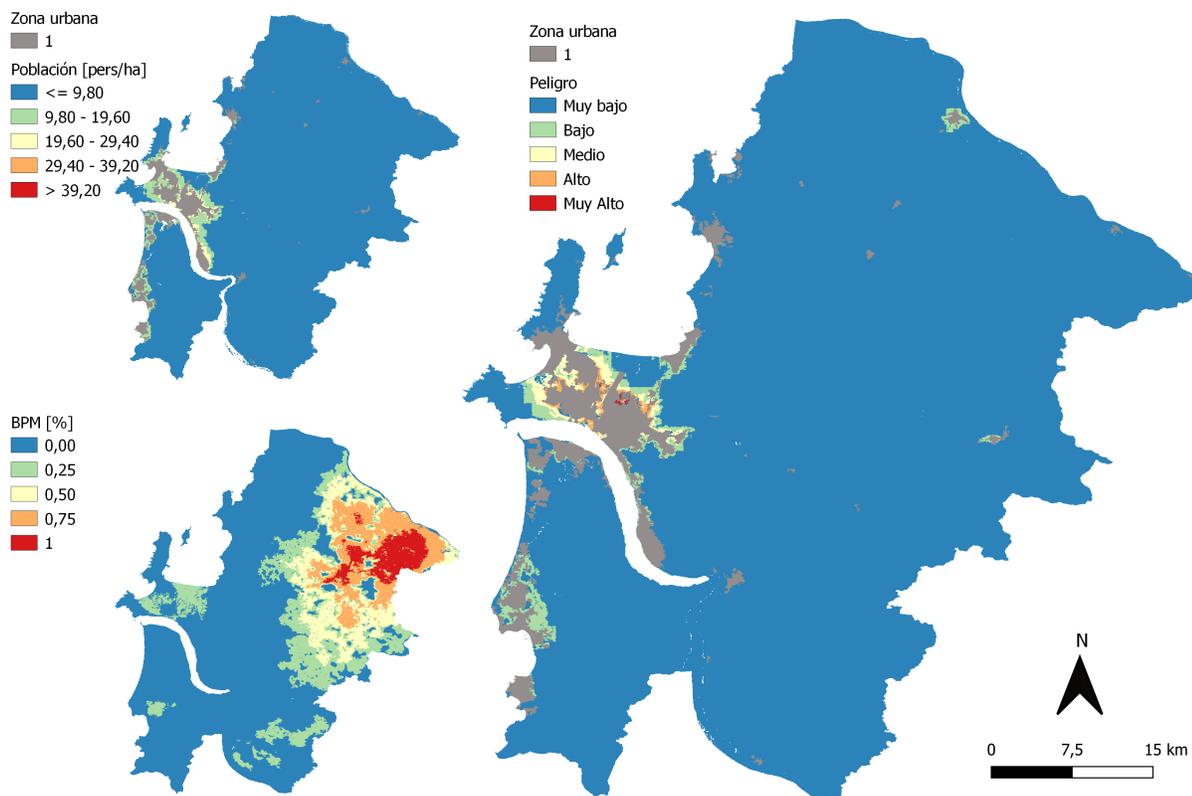


Figura 4.11: Población en riesgo de incendio

Para realizar el cruce, primero se llevaron ambas variables, probabilidad de quema y densidad población en este caso, a valores entre cero y uno. La probabilidad de quema ya tiene ese comportamiento, sin embargo para el caso de la densidad población se tomó como 100 % la celda con mayor densidad poblacional. Luego se realizó producto punto entre los dos raster del lado izquierdo de la Figura 4.11, que dio como resultado el raster de la derecha de la misma figura.

En la Figura 4.12 vemos el mapa de riesgo de incendio con mayor detalle (zoom a la zona de mayor riesgo) y queda en evidencia que las zonas cercanas a las ciudades tienen

gran riesgo, puesto que a pesar de no tener alta probabilidad de quema, concentran a gran cantidad de personas y por tanto el riesgo que significa que se quemen esas zonas es mayor. Y aquellas zonas con alta probabilidad de quema, pero con baja densidad poblacional, no representa un gran riesgo.

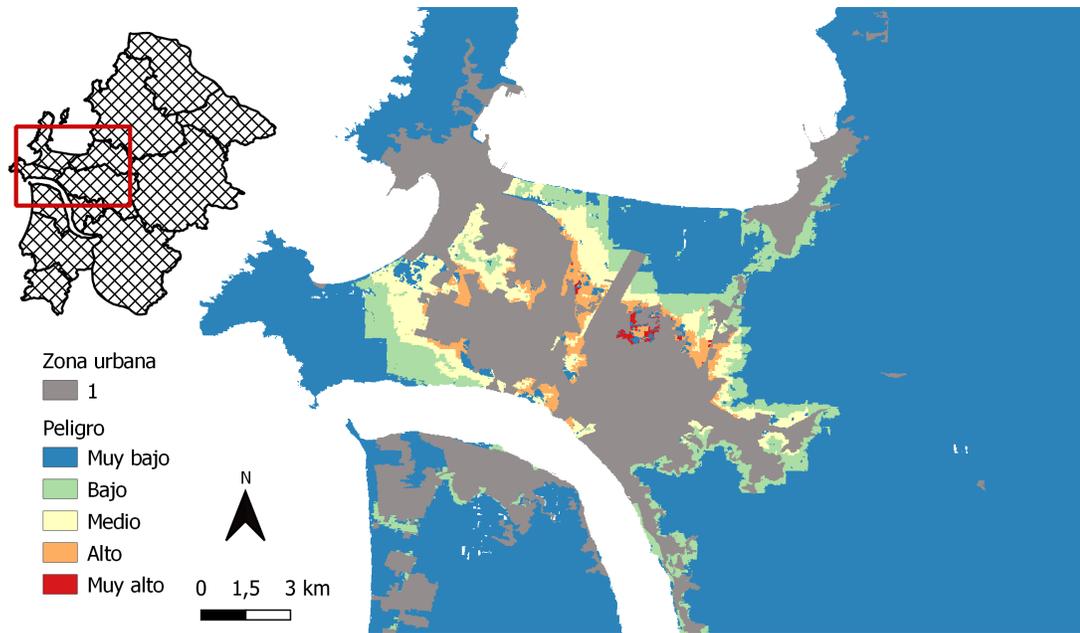


Figura 4.12: Detalle población en riesgo de incendio

Este mismo análisis es posible realizarlo evaluando otras variables a proteger, como por ejemplo zonas de gran biodiversidad, zonas productivas, distribución de electricidad, entre otros.

Conclusión

Es posible concluir, en un primera instancia, elementos generales que nos deja este estudio, así como también elementos de cada uno de los modelos utilizados y finalmente se vislumbran trabajos futuros a realizar utilizando esta investigación como base.

En términos generales, este trabajo permite conocer la disponibilidad de datos referentes a incendios forestales, meteorología, cobertura de suelo y topografía para Chile y en particular para el área de estudio (zona urbano rural de Concepción). Con respecto a esto, se encontró una deficiencia en datos meteorológicos, pues si bien las estaciones meteorológicas recopilan una gran cantidad de datos, existen pocas estaciones y para un país como Chile, donde la topografía es muy variable, estas estaciones no son representativas de áreas geográficas extensas. Además se evidenció una importante falta de datos de cobertura de suelo con resolución espacial apropiada para hacer esta clase de estudios, pues la información no está actualizada y la que existe, generada por Zhao et al. (2016), tiene una resolución temática baja y no es un modelo de combustible, en otras palabras no entrega características específicas del combustible sino solo indica el tipo de cobertura generalizado, por tanto reduce la exactitud en los estudios incendios forestales.

Del modelo de ocurrencia es posible concluir (i) en función de la eficiencia del modelo y (ii) posibles usos y aplicaciones del modelo: (i) Este modelo de machine learning (Bagged Decision Tree) entrega una eficiencia muy alta con bajo tiempo computacional y por tanto, teniendo datos precisos y actualizados, resulta sencillo aplicar el modelo y obtener resultados robustos para conocer aquellas zonas que presentan una mayor probabilidad de ocurrencia de incendio. (ii) Dado el punto anterior, este modelo es una buena herramienta para utilizar en la planificación urbana o productiva, pues entrega información adicional a los datos de ocurrencia en si mismos y permite evaluar cada punto del área de estudio, evaluando la probabilidad de ocurrencia a la que nos enfrentamos en una temporada o por ejemplo, el cambio que significaría (en cuanto a probabilidad de ocurrencia) el crecimiento de ciudades, construcción de nuevas carreteras o la implementación de nuevas plantaciones forestales, cultivos u otros cambio en las coberturas de suelo.

Con el modelo de propagación, vemos que dado que las zonas con mayor probabilidad de quema son aquellas con un mayor volumen y continuidad de combustible, una política acertada de prevención de propagación de incendios, es evitar que en esas zonas de alta probabilidad de quema se generen igniciones. Por tanto una buena forma de invertir los recursos de prevención, sería generar estrategias para evitar que el fuego transite entre las zonas de mayor probabilidad de ocurrencia y aquellas tienen una mayor probabilidad de

quemarse. Como, por ejemplo, en la Figura 4.13 se muestra con una línea negra la frontera que aislaría las zonas a proteger pues tienen una gran probabilidad de quema y el objetivo debiese ser evitar que dentro del área a proteger se generen efectivamente igniciones, realizando acciones a corto o mediano plazo como cortafuegos o modificaciones de coberturas de suelo, por ejemplo.

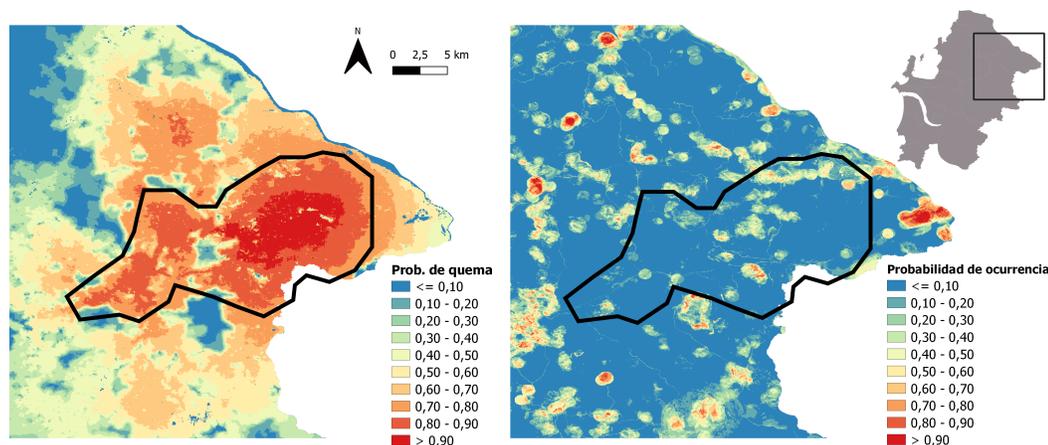


Figura 4.13: Ejemplos estrategia de prevención de incendios

Finalmente, se evidencian distintas aristas para enfocar los trabajos futuros y así mejorar la evaluación de riesgo de incendios forestales:

- En este trabajo se aplicaron modelos de ocurrencia de incendio y propagación de incendio de manera separada, sin embargo resulta indispensable integrar ambos modelos y así obtener mejores resultados. A la hora de aplicar el modelo de propagación de incendios y construir los mapas de probabilidad de quema, se utilizaron igniciones aleatorias. Se propone utilizar el mapa de probabilidad de ocurrencia como punto de partida de los incendios del modelo de propagación, de esta manera aquellas zonas con una mayor probabilidad de ocurrencia, tendrán mayor cantidad de igniciones y no se consideraría que todo punto tiene la misma probabilidad de ignición (tal como se asumió en el presente trabajo). En la Sección 3.2.1 se presenta una forma para integrar los modelos, integrando el raster resultante de ocurrencia en las igniciones del simulador.
- Por otro lado, tal como se mencionó al comienzo de esta sección, es necesario construir un mapa de cobertura de suelo actualizado y con mayor resolución temática (mayor detalle en los tipos de cobertura de suelo) e integrar las características de los combustibles chilenos al simulador Cell2Fire (con un modelo de combustible chileno, como KITRAL por ejemplo). Este desarrollo significaría tener mejores resultados a la hora de simular cicatrices de incendios reales, así como también mejorar y actualizar el mapa de probabilidad de ocurrencia.
- Finalmente existe la necesidad de generar un modelo meteorológico que entregue una aproximación más realista de las características atmosféricas en cada punto, puesto que actualmente se considera la información entregada por la estación meteorológica más cercana.

Todos estas aristas serán consideradas y desarrolladas en los trabajos realizados en el proyecto Fondef ID20I10137.

Bibliografía

- Andrews, P. L. (2005). Fire danger rating and fire behavior prediction in the united states. In *In: Proceedings of Fifth NRIFD Symposium: International Symposium on Forest Fire Protection; 2005 November 30-December 2; Mitaka, Tokyo, Japan. Tokyo, Japan: National Research Institute of Fire and Disaster. p. 106-117.*, pages 106–117.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2):123–140.
- Calkin, D. E., Cohen, J. D., Finney, M. A., and Thompson, M. P. (2014). How risk management can prevent future wildfire disasters in the wildland-urban interface. *Proceedings of the National Academy of Sciences*, 111(2):746–751.
- Carlton, D. (2004). Fuels management analyst plus software, version 3.8. 19. *Fire Program Solutions, LLC, Estacada, Oregon.*
- Carrasco, J., Acuna, M., Miranda, A., Alfaro, G., Pais, C., and Weintraub, A. (2021). Exploring the multidimensional effects of human activity and land cover on fire occurrence for territorial planning. *Manuscrito no publicado.*
- Castillo, M., Julio, G., and Pedernera, P. (2002). Procedimiento de validación para el simulador de expansión de incendios forestales del sistema kitral. *Laboratorio de incendios forestales. Facultad de Ciencias Forestales, Universidad de Chile.*
- Chas-Amil, M. L., Prestemon, J. P., McClean, C. J., and Touza, J. (2015). Human-ignited wildfire patterns and responses to policy shifts. *Applied Geography*, 56:164–176.
- Chen, K. and McAneney, J. (2004). Quantifying bushfire penetration into urban areas in australia. *Geophysical Research Letters*, 31(12).
- Cheney, N., Gould, J., and Catchpole, W. R. (1998). Prediction of fire spread in grasslands. *International Journal of Wildland Fire*, 8(1):1–13.
- Costafreda-Aumedes, S., Vega-Garcia, C., and Comas, C. (2018). Improving fire season definition by optimized temporal modelling of daily human-caused ignitions. *Journal of environmental management*, 217:90–99.
- De la Barrera, F., Barraza, F., Favier, P., Ruiz, V., and Quense, J. (2018). Megafires in chile 2017: Monitoring multiscale environmental impacts of burned ecosystems. *Science of the total environment*, 637:1526–1536.

- Elith, J., Leathwick, J. R., and Hastie, T. (2008). A working guide to boosted regression trees. *Journal of Animal Ecology*, 77(4):802–813.
- Finney, M., Brittain, S., and Seli, R. (1999). Flammap. *USDA For. Serv. Rocky Mountain Research-Missoula Fire Lab*.
- Finney, M. A. (1998). *FARSITE, Fire Area Simulator—model development and evaluation*. Number 4. US Department of Agriculture, Forest Service, Rocky Mountain Research Station.
- Finney, M. A. (2005). The challenge of quantitative risk analysis for wildland fire. *Forest Ecology and Management*, 211(1-2):97–108.
- Flannigan, M. D., Stocks, B. J., and Wotton, B. M. (2000). Climate change and forest fires. *Science of the total environment*, 262(3):221–229.
- Giglio, L., Boschetti, L., Roy, D. P., Humber, M. L., and Justice, C. O. (2018). The collection 6 modis burned area mapping algorithm and product. *Remote sensing of environment*, 217:72–85.
- González, M., Sapiains, R., Gómez-González, S., Garreaud, R., Miranda, A., Galleguillos, M., Jacques, M., Pauchard, A., Hoyos, J., Cordero, L., Vásquez, F., Lara, A., Aldunce, P., Delgado, V., Arriagada, Ugarte, A., Sepúlveda, A., Farías, L., García, R., Rondanelli, R., Ponce, R., Vargas, F., Rojas, M., Boisier, J. C., Carrasco, Little, C., Osses, M., Zamorano, C., Díaz-Hormazábal, I., Ceballos, A., Guerra, E., Moncada, M., and Castillo, I. . (2020). Incendios forestales en chile: causas, impactos y resiliencia. *Centro de Ciencia del Clima y la Resiliencia (CR)2, (ANID/FONDAP/15110009)*, page 84.
- González, M. E., Lara, A., Urrutia, R., and Bosnichd, J. (2011). Cambio climático y su impacto potencial en la ocurrencia de incendios forestales en la zona centro-sur de chile (33^o-42^o s). *BOSQUE*, 32(3):215–219.
- Hardy, C. C. (2005). Wildland fire hazard and risk: Problems, definitions, and context. *Forest Ecology and Management*, 211(1-2):73–82.
- Julio, G., Pedernera, P., and Castillo, M. E. (1995). Diseño funcional del simulador de incendios forestales. *Actas del Taller Internacional sobre Prognosis y Gestión en Control de Incendios Forestales*, pages 182–204.
- Kramer, H. A., Mockrin, M. H., Alexandre, P. M., Stewart, S. I., and Radeloff, V. C. (2018). Where wildfires destroy buildings in the us relative to the wildland–urban interface and national fire outreach programs. *International Journal of Wildland Fire*, 27(5):329–341.
- Lloyd, C., Chamberlain, H., Kerr, D., Yetman, G., Pistolesi, L., Stevens, F., Gaughan, A., Nieves, J., Hornby, G., Macmanus, K., et al. (2019). Global spatio-temporally harmonised datasets for producing high-resolution gridded population distribution datasets. *big earth data* 3 (2), 108–139.
- Martell, D. L. (2015). A review of recent forest and wildland fire management decision

- support systems research. *Current Forestry Reports*, 1(2):128–137.
- Martinez-Millán, J. and Saura, S. (1998). Cardin 3.2: forest fires spread and fighting simulation system. In *Proc. III Int. Conference on Forest Fire Research/14th Conference on Fire and Forest Meteorology*, volume 1.
- Miller, C. and Ager, A. A. (2013). A review of recent advances in risk analysis for wildfire management. *International journal of wildland fire*, 22(1):1–14.
- Ministerio de Vivienda y Urbanismo (2011). <https://www.ide.cl/index.php/planificacion-y-catastro/item/1845-area-urbana-consolidada>.
- Miranda, A., Carrasco, J., González, M., Pais, C., Lara, A., Altamirano, A., Weintraub, A., and Syphard, A. D. (2020). Evidence-based mapping of the wildland-urban interface to better identify human communities threatened by wildfires. *Environmental Research Letters*.
- Moayedi, H., Mehrabi, M., Bui, D. T., Pradhan, B., and Foong, L. K. (2020). Fuzzy-metaheuristic ensembles for spatial assessment of forest fire susceptibility. *Journal of environmental management*, 260:109867.
- Moritz, M. A., Batllori, E., Bradstock, R. A., Gill, A. M., Handmer, J., Hessburg, P. F., Leonard, J., McCaffrey, S., Odion, D. C., Schoennagel, T., et al. (2014). Learning to coexist with wildfire. *Nature*, 515(7525):58–66.
- Narayanaraj, G. and Wimberly, M. C. (2012). Influences of forest roads on the spatial patterns of human- and lightning-caused wildfire ignitions. *Applied Geography*, 32(2):878–888.
- Olden, J. D., Lawler, J. J., and Poff, N. L. (2008). Machine learning methods without tears: a primer for ecologists. *The Quarterly review of biology*, 83(2):171–193.
- Pais, C., Carrasco, J., Martell, D. L., Weintraub, A., and Woodruff, D. L. (2019). Cell2fire: A cell based forest fire growth model. *arXiv preprint arXiv:1905.09317*.
- Pais, C., Carrasco, J., Miranda, A., Weintraub, A., and Shen, Z.-J. M. (2021). Simulating global wildfires: Learning worldwide fire spread models from historical data. *Manuscrito no publicado*.
- Parisien, M.-A., Dawe, D. A., Miller, C., Stockdale, C. A., and Armitage, O. B. (2020). Applications of simulation-based burn probability modelling: a review. *International journal of wildland fire*, 28(12):913–926.
- Ramírez, J., Monedero, S., and Buckley, D. (2011). New approaches in fire simulations analysis with wildfire analyst. In *7th International Conference on Forest Fire Research*.
- Reinhardt, E. D. (2003). *The fire and fuels extension to the forest vegetation simulator*. United States Department of Agriculture, Forest Service, Rocky Mountain
- Ricotta, C., Bajocco, S., Guglietta, D., and Conedera, M. (2018). Assessing the Influence of

- Roads on Fire Ignition: Does Land Cover Matter? *Fire*, 1(2):24.
- Santana, E. (2014). <http://apuntes-r.blogspot.com/2014/12/bagging-para-mejorar-un-modelo.html>, 14 de diciembre de 2014.
- Scott, A. C., Bowman, D. M., Bond, W. J., Pyne, S. J., and Alexander, M. E. (2013). *Fire on earth: an introduction*. John Wiley & Sons.
- Scott, J. H. (1999). Nexus: a system for assessing crown fire hazard. *Fire Management Notes*.
- Syphard, A. D., Radeloff, V. C., Keeley, J. E., Hawbaker, T. J., Clayton, M. K., Stewart, S. I., and Hammer, R. B. (2007). Human influence on California fire regimes. *Ecological Applications*, 17(5):1388–1402.
- Syphard, A. D., Radeloff, V. C., Keuler, N. S., Taylor, R. S., Hawbaker, T. J., Stewart, S. I., and Clayton, M. K. (2008). Predicting spatial patterns of fire on a southern California landscape. *International Journal of Wildland Fire*, 17(5):602–613.
- Taylor, S. W. and Alexander, M. E. (2006). Science, technology, and human factors in fire danger rating: the canadian experience. *International Journal of Wildland Fire*, 15(1):121–135.
- Tymstra, C., Bryce, R., Wotton, B., Taylor, S., Armitage, O., et al. (2010). Development and structure of prometheus: the canadian wildland fire growth simulation model. *Natural Resources Canada, Canadian Forest Service, Northern Forestry Centre, Information Report NOR-X-417.(Edmonton, AB)*.
- Williams, J. (2013). Exploring the onset of high-impact mega-fires through a forest land management prism. *Forest Ecology and Management*, 294:4–10.
- Wotton, B. M. (2009). Interpreting and using outputs from the canadian forest fire danger rating system in research applications. *Environmental and Ecological Statistics*, 16(2):107–131.
- Yang, J., He, H. S., Shifley, S. R., and Gustafson, E. J. (2007). Spatial patterns of modern period human-caused fire occurrence in the Missouri Ozark Highlands. *Forest Science*, 53(1):1–15.
- Zhao, Y., Feng, D., Yu, L., Wang, X., Chen, Y., Bai, Y., Hernández, H. J., Galleguillos, M., Estades, C., Biging, G. S., Radke, J. D., and Gong, P. (2016). Detailed dynamic land cover mapping of Chile: Accuracy improvement by integrating multi-temporal data. *Remote Sensing of Environment*, 183:170–185.