



**Instituto
de Ecología
& Biodiversidad**



Universidad Austral de Chile
Conocimiento y Naturaleza

**Informe JNCC
No: 635**

Un Enfoque de Capital Natural para la Planificación Territorial: Un Proyecto piloto en la Valle Colchagua- Informe Técnico

Autores

Olga Barbosa, Daniel Colson, A. Paz Durán, Karina Godoy, Alun Jones, Gwawr Jones, Maddie Harris, Sarah Harrison, Megan Tierney, Becky Trippier, Matt Smith & Emma Wright

© JNCC, Peterborough 2019

ISSN 0963-8091

Para más información contactar con:

Joint Nature Conservation Committee
Monkstone House
City Road
Peterborough PE1 1JY
www.jncc.defra.gov.uk

Programa Vino, Cambio Climático y Biodiversidad
Instituto de Ecología y Biodiversidad
Universidad Austral de Chile
Independencia 631
Valdivia
Chile
<http://www.vccb.cl>
info@vccb.cl

Este informe debe citarse como:

Barbosa, O., Colson, D., Duran, A.P., Godoy, K., Jones, A., Jones, G., Harris, M., Harrison, S., Tierney, M., Trippier, B., Smith, M. & Wright, E. A Natural Capital Approach to Landscape Planning: a Pilot Project in Colchagua Valley – Technical Report, Chile. JNCC Report No. 635, JNCC, Peterborough, ISSN 0963-8091.

Este informe cumple con la política de evidencia de garantía de calidad de JNCC
<http://jncc.Defra.gov.uk/default.aspx?page=6675>.

Contenidos

Contenidos.....	2
Síntesis.....	1
Un enfoque de capital natural para la planificación territorial:Un proyecto piloto en la Valle Colchagua, Chile.....	1
Cartografía de Hábitats	2
Introducción.....	2
El valle de Colchagua.....	3
Datos de teledetección	3
Datos de identificación de <i>Sentinel-2</i>	4
Datos de identificación de <i>Sentinel-1</i>	4
Pre-procesado de datos de <i>Sentinel</i>	4
Clasificación del mapa de hábitats	5
Recopilación de datos de campo.....	5
Resultados de la cartografía de hábitats.....	6
Mapas de hábitats.....	6
Mapa de probabilidades.....	8
Precisión.....	8
Pérdida de suelo	10
Introducción.....	10
Fuentes de datos.....	10
Datos climáticos.....	10
Datos de predicción del clima	11
Erosividad de la lluvia (R)	11
Erosionabilidad del suelo (K).....	11
Factor de longitud de pendiente (L) y Factor del gradiente de pendiente (S)	12
Factor de uso y gestión del suelo (LC).....	12
Tabla biofísica.....	12
Cuencas fluviales.....	13
Resultados	13
Utilizando el Índice de Entrega de Sedimento (SDR) para dar información a la Red Bayesiana (<i>Bayesian Belief Network - BBN</i>).....	15
Gestión de escenarios	15
Escenarios de clima.....	15
Escenario buffer.....	15
Pérdida de la capa fértil del suelo dentro del viñedo.	16
Erosión del suelo en pendiente descendente.....	16
Riesgo de incendio	16
Introducción.....	16
Fuentes de datos.....	16

Datos topográficos	17
Datos climáticos.....	17
Variables biológicas	17
Mapas de hábitats.....	18
Variables antropogénicas.....	18
Datos de áreas quemadas	18
Modelo de riesgo de incendio	19
Dando información a la BBN	20
Resultados	21
Calidad y suministro del agua	23
Introducción.....	23
Modelo de Herramienta de Evaluación de Suelo y Aguas (SWAT)	23
Fuentes de datos.....	26
El paisaje	26
El clima	26
Configuración del modelo	27
Delineación de cuencas	27
Creación de Unidades de Respuesta Hidrológica (HRU)	28
Datos de la estación meteorológica y del generador de clima.....	29
Modelado base o de referencia	30
Escenarios de cambio climático.....	39
Manejo de escenarios para informar la BBN.....	41
Franjas de amortiguamiento (Buffer).....	41
Uso de fertilizantes y pesticidas	41
Pastoreo de ganado en invierno	43
Modelando la Red de Creencias Bayesiana.....	44
Introducción.....	44
Modelo Ecológico Conceptual	44
Desarrollo de Redes de Creencias Bayesianas.....	45
Relaciones de Evidencia	48
Datos medidos y modelados	48
Revisión bibliográfica y talleres de trabajo con los socios del proyecto.	50
Construcción de las Tablas de Probabilidad Condicional (CPTs).....	52
Aplicación de la BBN	52
Conclusiones y próximos pasos	55
Pasos potenciales para la mejora del modelo	56
Referencias.....	57
Apéndice 1 – Establecimiento del Metodo del Mapa Vivo (<i>Living Maps Method</i> (LMM)) en el valle de Colchagua	64
Conjunto de datos.....	64

<i>Sentinel-1</i>	64
<i>Sentinel-2</i>	65
Modelo Digital de Elevación (DEM)	66
El bioclima.....	67
Datos del <i>Open Street Map</i>	67
Datos de construcción del modelo	67
Método.....	67
Segmentación	68
Variables más significativas en la clasificación de Bosques Aleatorios (<i>Random Forest</i>)	68
Apéndice 2 – Parámetros de las HRU para el modelo SWAT	70
Definiciones de crecimiento de las plantas.....	71
Parámetros de nieve	71
Apéndice 3 – Talleres con los socios del proyecto	74

Síntesis

Este informe técnico desarrolla las metodologías y productos resultantes de una investigación piloto de cartografía en el valle de Colchagua, en el centro de Chile. El objetivo de este proyecto fue demostrar que la cuantificación de servicios ecosistémicos mediante la integración de teledetección y conocimiento local, pueden ayudar a mejorar el manejo del capital natural en la región, como apoyo a la producción vinícola y su rol en la protección y entrega de servicio ecosistémicos.

El proyecto colaborativo reunió a tres grupos de actores: Joint Nature Conservation Committee (JNCC), el Programa Vino, Cambio Climático y Biodiversidad (VCCB) y viticultores locales del valle de Colchagua. Junto a los viticultores se identificó a través de talleres participativos aquellos servicios ecosistémicos relevantes para la producción de vino. Como suministro básico para la cuantificación de servicios ecosistémicos se generó un mapa de cobertura de suelo o hábitats con técnicas de teledetección de alta resolución (imágenes satelitales *Sentinel*). Luego se utilizaron diferentes modelos para cuantificar y mapear los siguientes servicios: suministro y calidad del agua, erosión del suelo y riesgo de incendio. Los modelos se ejecutaron bajo varios escenarios climáticos y de prácticas de manejo para estimar cómo varía la entrega de servicios bajo diferentes manejos productivos en estados distintos del clima. Los resultados de esta modelización se utilizaron para preparar un modelo de red bayesiana que, junto con el conocimiento de las partes interesadas, permitió analizar de forma detallada cómo cambian los servicios ecosistémicos a nivel de viña según distintas intensidades de manejo. Los resultados se presentaron de manera interactiva y práctica mediante la aplicación online de *R Sino*, donde los interesados pueden consultar los resultados de los modelos y explorar los impactos que tienen los cambios de manejo en cada una de sus viñas.

Un enfoque de capital natural para la planificación territorial: Un proyecto piloto en la Valle Colchagua, Chile

El Programa Vino Cambio Climático y Biodiversidad (VCCB) es una iniciativa científica del Instituto de Ecología y Biodiversidad y la Universidad Austral de Chile, que busca desarrollar investigación para implementar soluciones innovadoras para la gestión del capital natural, a través de un proceso de involucramiento y colaboración entre diversos actores y tomadores de decisiones.

Después de 10 años de trabajo y aprendizaje conjunto con el sector vitivinícola, se ha avanzado en la incorporación de la naturaleza al manejo vitícola, enfocándonos en objetivos que nos permitan fomentar una producción más sostenible.

Entendiendo que los ecosistemas naturales juegan un rol elemental en el bien estar humano y nuestro desarrollo socioeconómico, promover planificación territorial que incorpore un enfoque de capital natural, permite integrar de forma sistemática el rol de los ecosistemas en nuestras decisiones, y así promover prácticas sostenibles en el largo plazo.

En este contexto, el Programa VCCB se asocia con Joint Nature Conservation Committee - (JNCC), institución del gobierno del Reino Unido dentro del Departamento de Medio Ambiente, Alimentación y Asuntos Rurales del Reino Unido (DEFRA). Esta asociación está bajo el programa de 'Divulgación e investigación en el Cono Sur' (JNCC, 2019), decidió implementar un portafolio de proyectos pilotos en Latinoamérica, los cuales buscan generar conocimiento y herramientas para apoyar planificación territorial integrando capital natural.

El proyecto ***“Enfoque de capital natural para la planificación del territorio: Mapeo y cuantificación de servicios ecosistémicos para una viticultura sustentable en el Valle de Colchagua, Chile”***, tiene como objetivo promover prácticas responsables con el ambiente y la biodiversidad dentro de sistemas productivos. La incorporación estratégica y sistemática de tales prácticas, es lo que se conoce como Manejo Basado en Ecosistemas (MBE). MBE reconoce la dependencia entre la sostenibilidad de sistemas productivos y el funcionamiento de los ecosistemas, por ende, éste último debe ser comprendido en el manejo de los campos. Entender el alcance de tal dependencia, entre el funcionamiento ecosistémico y productividad, no es posible sin

el conocimiento y experiencia de los propios productores. Es por eso que, el proyecto se basa en una larga trayectoria entre VCCB y sus socios, las viñas, la cual provee una plataforma única para entender el sistema vitícola y sus necesidades. Así, integrando ciencia en servicios ecosistémicos y conocimiento de la industria vitivinícola, el proyecto busca aportar mayor entendimiento sobre las interacciones entre las prácticas de manejo agrícola, factores ambientales, y aquellos beneficios relevantes para la producción del vino.

Finalmente, es importante resaltar que el desarrollo de conocimiento aplicado bajo este tipo de proyecto se enmarca en una estrategia de largo plazo. Para el Reino Unido, asegurar la sustentabilidad de sus colaboraciones comerciales ha devenido prioridad en su agenda actual. De esta forma, proyectos que busquen respaldar y promover relaciones comerciales sustentables en base a la integración de ciencia y tecnología emergente, son una pieza clave para escenarios futuros. En 2017, Chile exportó 9% de su vino al Reino Unido, con un valor de USD \$203m, el cual se espera seguir incrementando en los siguientes años. Explorar cómo esta relación comercial entre ambos países puede sustentarse en prácticas resilientes y responsables con el medio ambiente, presenta una oportunidad de alto valor.

El proyecto fue financiado por el Departamento del Medio Ambiente, Alimentación y Asuntos Rurales (DEFRA) del Reino Unido y el Instituto de Ecología y Biodiversidad.

Cartografía de Hábitats

Introducción

El mapeo de hábitats es un componente clave para entender la distribución y el alcance de las características del paisaje, así como un requisito para facilitar mejores prácticas de manejo, servicio de digitalización de ecosistemas, la interpretación e identificación de biodiversidad y en la elaboración de políticas ambientales, como son las relacionadas con los Objetivos de Desarrollo Sostenible de Naciones Unidas. Existen muchos productos globales de mapas de cobertura y de usos del suelo, pero no suelen proporcionar suficiente detalle para la realización de un análisis a nivel regional. Se encontraba disponible un mapa de cobertura del suelo del valle de Colchagua (O'Higgins, 2013), pero no se encontraba actualizada, y no incluía los cambios recientes en los usos del suelo, como pueden ser los del sector forestal y del sector vinícola, por lo que era necesario un mapa de hábitats actualizado que sirviera para llevar a cabo una modelización de los servicios ecosistémicos de forma espacialmente explícita.

La teledetección ha sido utilizada ampliamente para proporcionar una visión gráfica de los usos del suelo, de la cubierta vegetal y sus cambios a diversas escalas. Cada vez, a un ritmo mayor, se están desarrollando y poniendo en marcha nuevos sensores de satélites, con algunas misiones que generan datos accesibles al público, a través de licencias de código abierto (como los datos de Sentinel del Programa Copernicus)¹. La teledetección es un recurso valioso cuando no hay otros datos disponibles, pero es mucho más potente cuando se combina con datos de campo y con otras fuentes de información que, en conjunto, pueden servir para la creación de productos que proporcionen una información crítica, particularmente para la toma de decisiones basada en evidencias.

¹ Copernicus es un programa de observación de la tierra encabezado por la Comisión Europea (CE) en asociación con la Agencia Espacial Europea (ESA). Copernicus proporciona un sistema unificado a través del cual se alimentan grandes cantidades de datos en una gama de servicios de información temática diseñados para beneficiar el medio ambiente, la forma en que vivimos, las necesidades humanitarias y apoyar una formulación de políticas efectiva para un futuro más sostenible <https://www.esa.int/Nuestras_Actividades/Observando_La_Tierra/Copernico/Descripción3>. https://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview3>.

El valle de Colchagua

El valle de Colchagua se localiza en el centro de Chile, en la Región del General Libertador Bernardo O'Higgins, a 130 km al sur de la capital, Santiago. El valle está esculpido por el río Tinguiririca que fluye desde las cabeceras de las montañas glaciares andinas hacia el este, hasta las praderas de las tierras bajas de la costa del Pacífico en el oeste. Como resultado, el valle experimenta un clima mediterráneo bordeado por cordilleras y el derretimiento de los glaciares es una importante fuente de agua durante todo el año (Bravo et al. 2017). El valle de Colchagua se encuentra entre 34° 15'S y 34° 50'S y 72° 00'W y 70° 15'W, con una fuerte economía basada en la agricultura, famosa por su viticultura, que se remonta a los años 1542 (Viñas de Colchagua A. G, 2012). El área de interés para el mapeo de hábitats cubrió un área de aproximadamente 6.900,8 km², definida por las principales cuencas hidrográficas de interés (ver sección 5) y que abarca todos los viñedos de las partes interesadas de VCCB.



Figura 2.1. Área de interés para la cartografía del valle de Colchagua.

Datos de teledetección

Copernicus se ha identificado como una fuente de datos clave para este proyecto debido a su acceso abierto y a su resolución espacial de 10 metros. En comparación con otros conjuntos de datos de teledetección de acceso abierto, *Sentinel-2* cubre el globo terráqueo con más frecuencia que otros sistemas de observación y además se trata de una misión operativa, al contrario de las que son de investigación. La misión *Sentinel-2* también se esfuerza por continuar proporcionando conjuntos de datos abiertos para el futuro, con otros dos satélites en proyecto de lanzamiento que se unirán a la constelación. Para el trabajo de mapeo, tanto *Sentinel-1*, en misión de radar, como

Sentinel-2, en misión óptica, se utilizaron para capturar tantas características del paisaje como fuera posible. En el Apéndice 1 se puede encontrar más información sobre Sentinel.

Datos de identificación de Sentinel-2

Al tratarse de una constelación óptica de satélites, las imágenes de Sentinel-2 están limitadas por la cubierta de nubes. Para asegurar datos sin nubes del área de interés en Colchagua, se requirió una investigación para identificar las imágenes adecuadas. Se consideraron los cambios estacionales y las diferencias creadas, ya que estas variaciones pueden ser críticas para la identificación del hábitat y la separación de clases. Por ejemplo, factores como la aparición de hojas y la cubierta de nieve, varían según las estaciones. Se examinaron todas las imágenes tomadas por el satélite en 2018 y se identificaron imágenes sin nubes a partir de las siguientes fechas para su uso en el análisis:

- 25 de marzo de 2018
- 28 de julio de 2018
- 21 de octubre de 2018
- 10 de diciembre de 2018

Esto proporcionó imágenes en periodos trimestrales aproximadamente, lo que se consideró suficiente para identificar los cambios estacionales más significativos.

Datos de identificación de Sentinel-1

Sentinel-1 no está restringido a las mismas limitaciones que Sentinel-2, ya que esta herramienta de detección remota por radar puede captar imágenes de la superficie terrestre a través de la cubierta de nubes y durante los períodos de oscuridad. Esto significa que todas las imágenes son potencialmente utilizables para capturar los cambios estacionales y las diferencias que se puedan producir. Se eligieron cuatro imágenes con fechas que se corresponden lo más cercano posible con las imágenes de Sentinel-2. Las fechas de estas imágenes fueron:

- 25 de marzo de 2018
- 23 de julio de 2018
- 27 de octubre de 2018
- 14 de diciembre de 2018

Pre-procesado de datos de Sentinel

Una vez identificadas las localidades necesarias, las imágenes de Sentinel fueron pre-procesadas utilizando cadenas de procesamiento, previamente establecidas a partir de un proyecto desarrollado por JNCC (*Sentinel-2*: Jones et al., 2017; y *Sentinel-1*: Minchella, 2018). Para aprovechar al máximo la valiosa información contenida en los datos de Sentinel, los usuarios deben realizar una serie de pasos complejos de pre-procesamiento que conviertan los datos de un formato crudo "sin procesar" a uno que se pueda analizar. Para permitir un uso y aprovechamiento más amplio de los datos de teledetección, JNCC está promoviendo la provisión sistemática y regular de los datos ya preparados para el análisis (*Analysis Ready Data*, ARD). Esto se suma con el trabajo del *Committee on Earth Observation Satellites* (CEOS) para facilitar el acceso a los datos satelitales a través del proyecto internacional *CEOS Analysis Ready Data for Land* (CARD4L). Esta idea de estándares aceptados es reconocida por JNCC y por la gran parte de CEOS, como un paso vital para un trabajo analítico repetible y comparable. El uso de ARD permite un análisis inmediato para los usuarios finales y elimina el preprocesamiento complejo. El procesamiento de Sentinel-2 se llevó a cabo utilizando las instalaciones de procesamiento de datos en la nube disponibles en *Amazon Web Services* (AWS). Los pasos de la cadena de procesamiento incluyen:

- Corrección geométrica
- Corrección atmosférica.
- Corrección radiométrica.

Los datos de *Sentinel-1* se transforman en imágenes de retrodispersión a partir de los datos recopilados en el modo de barrido de Interferometric Wide (IW) y se procesan a partir de la versión *Ground Range Detected* (GRD) de los datos disponibles por la Agencia Espacial Europea (ESA). Estos datos de *Sentinel-1* contienen datos en polarizaciones VV y VH. Las imágenes sin procesar se corrigieron en el terreno, se normalizaron radiométricamente y se procesaron a un coeficiente de retrodispersión Gamma-0 en decibelios (dB) utilizando el software de análisis de imágenes de código abierto SNAP Toolbox (ESA SNAP).

Clasificación del mapa de hábitats

El método de clasificación elegido para generar la cartografía de hábitats fue el *Living Map Method* (LMM) (Kilcoyne et al., 2017). Las clases de hábitat mapeados se definen en la sección 1.6.1. El LMM desarrolló un código de base que permitía a los usuarios implementar un enfoque de aprendizaje automático para la clasificación de hábitats, con la flexibilidad de integrar numerosos tipos de datos diferentes, incluidos los datos de teledetección. La disponibilidad de un código de base ya hecho, que es fácil de adaptar, proporciona una ventaja sobre otras herramientas de código abierto similares, ya que elimina el tiempo necesario de codificación para su implementación. Otras razones para elegir el método LMM incluyen:

- Utiliza algoritmos de aprendizaje automático que se utilizan cada vez más en aplicaciones de cartografía, que utilizan datos de teledetección;
- Se puede llevar a cabo el análisis basado en píxeles y en formas;
- Todos los pasos pueden llevarse a cabo utilizando software de código abierto;
- El código está disponible bajo Licencia Libre (*Open Government License*);
- JNCC participo en el desarrollo del código y, por lo tanto, estaba familiarizado con el método;
- Se puede repetir en diferentes áreas y una variedad de conjuntos de datos con poca adaptación al código;
- Las iteraciones de los mapas se pueden generar de manera rápida, eficiente y es altamente repetible.

Para obtener más detalles sobre los conjuntos de datos, las clases y el método, incluida la preparación de datos, la segmentación, la creación de conjuntos de datos de capacitación y los resultados, consulte el Apéndice 1 de este informe.

Recopilación de datos de campo

Una vez completado el primer borrador de cartografía general de hábitats (ver Apéndice 1), se requirieron más datos para validar los resultados y por si fuese necesario volver a repetir el proceso de clasificación. Para el trabajo de campo, se generó al azar un conjunto de puntos de cada clase de cobertura. La Figura 2.2 muestra la ubicación de estos puntos, que se verificaron manualmente para garantizar que ningún punto de recopilación de datos de campo propuesto, se superpusiera con los puntos de entrenamiento utilizados, para generar el algoritmo de clasificación. Debido a limitaciones de tiempo y accesibilidad en la zona alta de la región Andina del área de interés, solo se visitaron y registraron los puntos considerados dentro de un área de interés más pequeña (o tantos de ellos como fue posible) según lo acordado por los socios del proyecto de la Universidad Austral de Chile. La Figura 2.2 muestra los puntos generados aleatoriamente y aquellos que el equipo de campo pudo visitar durante la campaña de campo realizada en enero de 2019. Esto introduce cierto sesgo y correlación espacial en el conjunto de validación, que se hace más evidente y se discute en detalle en la Sección 2.6.3.




Figura 2.2. Distribución de los puntos a visitar durante la visita de campo. A) Puntos a visitar. B) Puntos visitados.

Resultados de la cartografía de hábitats


Mapas de hábitats

La Tabla 2.1 muestra las clases presentes en los mapas de hábitats. Estas clases se eligieron en base al mapa de cobertura del suelo de 2013, para proporcionar continuidad y están definidas según los hábitats de interés para la cartografía de servicios ecosistémicos.

Tabla 2.1. Nombres de las clases y sus descripciones.

Nombre de la Clase	Descripción de la Clase
Terrenos agrícolas	Todas las zonas utilizadas como viñedos y de producción frutícola.
Llanura aluvial	Forma de relieve creada por deposición de material erosionado en la parte alta de la cuenca.
Estepa Andina Central	Ecorregión de montaña con pastizales y matorrales, en las zonas altas de la cordillera sur de los Andes.
Cereales-Áreas de Pastoreo	Todas las zonas utilizadas para cultivos rotativos como el maíz (es decir, que no son cultivos permanentes) y las áreas utilizadas para el pastoreo.
Glaciares	Masas de nieve o ríos helados, formados por la acumulación y compactación de nieve en las montañas o cerca de los polos, que se mueven lentamente.
Lagos	Áreas de acumulaciones de agua, incluyendo lagos y embalses formados naturalmente.
Bosque nativo o autóctono	Bosques compuestos por árboles autóctonos y no clasificados como plantación forestal.
Replantación	Bosque establecido por plantación y/o siembra en el proceso de forestación o reforestación. Se compone de especies introducidas en la mayoría de los casos.

Ríos	Cauce fluvial que incluye un flujo permanente de agua.
Afloramientos rocosos	Área de base de roca que está expuesta al exterior. Cubre diferentes tipos de roca.
Matorral	Área cubierta por vegetación de matorral.
Pastizales estacionales	Área que consiste en pastizales que aparecen de forma estacional.
Cubiertas de nieve	Área permanentemente cubierta de nieve.
Árboles y matorrales	Áreas de árboles, bosques y matorrales que se crean en las franjas de los límites de los campos, las orillas de los ríos y en las zonas urbanas.
Urbano	Infraestructura construida, incluidas casas, edificios agrícolas, carreteras y cualquier otra estructura construida, asfalto, hormigón o grava.



Leyenda




Figura 2.3. Representación grafica de los resultados de una cartografía de hábitat.

Mapa de probabilidades




Figura 2.4. Probabilidades separadas en clases, resultantes del algoritmo bosque aleatorio cuando predicamentos de árboles individuales son agregados en base a un sistema de votos. Mapa las probabilidades de que las clases de cobertura identificadas sean las observadas.

La Figura 2.4 muestra la probabilidad de clasificación, atribuida a cada objeto. Estas cifras sugieren que existe una mayor confianza en las clases forestales y en las acuáticas, como lagos y ríos. Es probable que las clases dentro de las regiones agrícolas del valle tengan una menor probabilidad debido a la variedad de hábitats que pueden aparecer similares en los datos de teledetección. Por ejemplo, un objeto clasificado como cereal –tendrá características similares a los de áreas de pastoreo, prados estacionales, tierras agrícolas y matorrales, en los datos obtenidos por teledetección, lo que significa que se reduce la probabilidad de que el objeto pertenezca a una sola clase. La presencia de hábitats en mosaico también reducirá el valor de probabilidad, por lo que la Figura 2.4 se puede usar para interpretar la uniformidad y la variedad del paisaje, además de proporcionar un nivel de confianza espacial de la clasificación realizada.

Precisión

Para analizar la precisión de los resultados, los datos recopilados durante la visita de campo se utilizaron para generar una matriz de errores del mapa de hábitats. La precisión global estimada del mapa nos da una indicación de la cantidad de datos de campo que fueron clasificados correctamente, ésta fue del 78%.




Figura 2.5. Gráfico resultante de la precisión del usuario desde la matriz de errores, donde "n" es el número de puntos de validación de campo disponibles por clase. La precisión total estimada del mapa es del 78%.

Para interpretar estos resultados, se requiere una evaluación de la matriz de errores (Figura 2.5). Cabe señalar que estas estimaciones de precisión tienen una certeza variable asociada, debido a los diferentes números de datos de campo muestreados. Por ejemplo, no se recopilaban puntos de validación para varias clases, por lo que la precisión estimada para estas clases es desconocida. Por lo tanto, la precisión general no proporciona ninguna indicación de la precisión para las clases sin datos de campo y debe interpretarse como tal y utilizarse con precaución. Para las clases con puntos de validación es importante tener en cuenta que la distribución espacial de los datos se centra en la región noroeste del área de interés, lo que significa que la precisión en otras áreas dentro del mapa es menor. Las tierras agrícolas, la rotación de cultivos / pastizales y los matorrales muestran precisiones precisas del usuario a pesar del algoritmo forestal aleatorio que proporciona bajas probabilidades para estas clases en la Figura 2.4. Esto significa que el algoritmo de clasificación se ha desempeñado mejor de lo esperado al identificar clases que tienen características similares con varias otras clases, como la rotación de tierras agrícolas y cultivos / pastizales.

Pérdida de suelo

Introducción

Los actores participantes del sector de viticultura dentro de la región del proyecto identificaron qué servicios ecosistémicos son prioritaria para su producción y qué otros podrían verse afectados con ésta misma. La capa superficial del suelo fue identificada como el mayor servicio ecosistémico necesario para el crecimiento de las vides, mientras que la erosión de esta capa superficial podría suponer una pérdida significativa del servicio ecosistémico suelo. Asimismo, la sobre introducción de nutrientes debida a la erosión de los suelos en viñedos situados en pendiente fue considerada otro factor perjudicial para el cultivo de la uva. Para evaluar el movimiento del suelo tanto desde dentro como desde arriba de los viñedos, se ha utilizado el modelo *Sediment Delivery Ratio* (SDR) de *Invest* 3.5.0 (Stanford University, 2019) para calcular la ecuación universal de pérdida de suelo revisada (RUSLE). Se utilizó esto sobre el módulo de sedimentos incorporado en el modelo SWAT (usado para evaluar el suministro de agua y su calidad en la Sección 4) ya que los resultados tienen una resolución más alta (10 m píxeles, en lugar de las Unidades de Respuesta Hidrológica de SWAT) más apropiada para la gestión del suelo en los viñedos y bien adaptada para cambiar los parámetros de gestión; dichos resultados se utilizaron para informar el seguimiento de la Red de Creencias Bayesiana (ver Capítulo 6).

El modelo SDR está diseñado para cartografiar la generación de sedimentos en el terreno y su posterior descarga a los cauces de agua, sin embargo, como parte de esto, el modelo produce la pérdida de suelo potencial por píxel calculada a partir del RUSLE:

$$A=RKLSCP$$

Donde A es el factor de pérdida de suelo por unidad de superficie ($\text{ton ha}^{-1} \text{yr}^{-1}$), R es el factor anual de erosividad de la lluvia ($\text{MJ mm ha}^{-1} \text{h}^{-1} \text{yr}^{-1}$), K es el factor de erosionabilidad del suelo ($\text{t ha yr ha}^{-1} \text{MJ}^{-1} \text{mm}^{-1}$), L es el factor de longitud de la pendiente, S es el factor del gradiente de la pendiente, C es el factor de uso y gestión del suelo, y P es el factor de práctica mecánica de apoyo.

Fuentes de datos

Las entradas de datos para el modelo se describen a continuación. Todos los datos espaciales fueron georreferenciados a WGS84 UTM zona 19S (ESPG: 32719) y recortados al área de interés. El procesamiento de datos y las transformaciones se realizaron en la versión 3.4.4 de R (R Core Team 2018). Para las entradas no espaciales adicionales², los valores predeterminados se mantuvieron. Para más detalles sobre el modelo SDR y los valores predeterminados, se puede consultar la documentación de *The Natural Capital Project* (2019).

Datos climáticos

Las capas globales mensuales de temperaturas máximas, mínimas y medias, de velocidad media del viento y de precipitaciones totales, fueron descargadas de *WorldClim* v2.0 ([%20">http://worldclim.org/version2](http://worldclim.org/version2)) con una resolución de 30 arcos por segundo.

La capa global *WorldClim* se utilizó como ráster continuo para toda la región. Los datos de la estación meteorológica local del valle de Colchagua estaban solo disponibles como puntos de partida y en intervalos inconsistentes de tiempo. Sin embargo, optamos por

² Umbral de acumulación de flujo, parámetro de Borselli k, parámetro de Borselli IC_0 parameter y SDR_{max} .

volver a hacer las capas globales basadas en datos locales para garantizar que las capas fueran: i) más precisas para las condiciones locales; ii) más actualizadas (los rásteres *WorldClim* representan las condiciones del año 2000), y iii) consistentes con los datos de puntos utilizados en el modelado SWAT (Sección 4.2.2). Para esto, los datos diarios de las estaciones meteorológicas desde finales de 2017 hasta finales de 2018 (principios de 2015 hasta finales de 2018 para precipitación) se promediaron por mes. Para cada mes completo de datos meteorológicos por estación, se extrajeron los valores de *WorldClim* correspondientes a la ubicación de esa estación. Los valores de la estación se dividieron por los valores extraídos de *WorldClim* para lograr un factor de escala para cada combinación estación-mes. Todos los factores de escala se promediaron para producir un solo factor de escala, y las capas ráster *WorldClim* originales se multiplicaron por este factor para producir una nueva capa a escala para los datos locales. Este proceso fue repetido independientemente para cada variable de interés.

Datos de predicción del clima

Las capas ráster globales mensuales con la predicción de temperaturas mínimas y máximas y de la precipitación total para el año 2070 se descargaron de *WorldClim* v1.4 (<http://www.worldclim.org/CMIP5v1>) para el modelo HadGEM2-ES y las vías de concentración representativa 4.5 y 8.5, para representar una tendencia de concentración de gases de efecto invernadero, moderado y alto (ver también la sección 2.4.2). Se utilizó *WorldClim* v1.4, ya que los datos de pronóstico, en relación con el cambio climático, aún no están disponibles para *WorldClim* v2.0. Estas capas se sometieron a escala de la misma forma que las variables climáticas actuales, utilizando valores mensuales promedio de 20 años (2061-2080) de temperaturas mínimas y máximas y de precipitación, derivados de datos de estaciones modelados.

Erosividad de la lluvia (R)

El factor de erosividad de la lluvia es el índice utilizado para describir el poder de erosividad de la lluvia y del impacto de las gotas de lluvia en la escorrentía. Se deriva, idealmente, de forma proporcional al parámetro de tormentas, basado en la energía de la tormenta de lluvia y al máximo de intensidad dentro de un periodo de 30 minutos, que además se valida con los datos de erosión local para verificar la idoneidad para la región. Como esto requiere datos de intensidad de lluvia y de erosión que no suelen estar disponibles, hay ecuaciones basadas en la correlación entre la erosividad de la lluvia (R) y el total de precipitaciones. Aquí hemos seguido a Renard & Freimund (1994) utilizando la siguiente ecuación:

$$R = 0.04830 P^{1.61}$$

donde P es la precipitación anual por debajo de 850mm, y

$$R = 587.8 - 1.219 P + 0.004105 P^2$$

Donde P es la precipitación anual de 850mm y la que está por encima de esta. Se trata de un método estandarizado y apropiado en el caso de que no haya datos disponibles. Estas ecuaciones se aplicaron a los rásteres de precipitación generados en la sección 3.2.1 para producir un ráster de erosividad de lluvia con resolución de 30 arcos por segundo en MJ mm ha⁻¹ h⁻¹ yr⁻¹.

Erosionabilidad del suelo (K)

La erosionabilidad del suelo es la medida de la susceptibilidad de las partículas del suelo para ser disgregadas y transportadas por la lluvia y la escorrentía, está relacionada mayormente con la textura del suelo. Los datos de perfiles del suelo se tomaron de la base de datos de *Harmonized continental SOTER* (SOTWIS) (ISRIC, 2019) con una resolución de 30 arcos por segundo, lo que da la proporción de arcilla, limo y sal en el suelo. Se utilizó

el paquete “*soiltexture*” de R (Moeys, 2018) para clasificar los tipos de suelo de la FAO (2006) basado en la proporción de tamaño y textura.

El factor de erosionabilidad del suelo (K) ($\text{ton ha h (ha MJ mm)}^{-1}$) se obtuvo entonces para la clasificación de suelos basada en la hoja de datos OMAFRA (2015), tal y como está recomendado por la documentación del SDR (*The Natural Capital Project* 2019). Dentro de la región, el factor K se encuentra en un rango de 0.45 – 0.67, con una media de 0.45 para ambos, el total de la región y de los viñedos.

Factor de longitud de pendiente (L) y Factor del gradiente de pendiente (S)

Ambos factores, de longitud (L) y de gradiente (S) de pendiente derivan del modelo *InVest* SDR del DEM (Apéndice 1). La altitud en la región se encuentra dentro del rango de 54 – 4971 m, y la altitud en el área de viñedos es de 302 m (± 209 m). La pendiente media fue de 13.5° ($\pm 12.9^\circ$) y de 9.8° ($\pm 10.0^\circ$) para la región y para la zona de los viñedos respectivamente.

Factor de uso y gestión del suelo (LC)

El mapa de hábitats obtenido de los datos de *Sentinel-2* por JNCC para este proyecto (Figura 2.3) no diferenciaba los viñedos de otros tipos similares de agricultura como huertos o plantaciones de uvas de mesa, por lo que se tuvieron que añadir manualmente al mapa, utilizando los límites de las propiedades de los viñedos entregados por los propietarios al VCCB. Todas las zonas incluidas dentro de estos límites, clasificadas como “terrenos agrícolas” se reclasificaron como “viñedos”, con la clase 16 asignada de forma independiente, con esto se rasterizó el mapa a una resolución de 10 m.

Tabla biofísica

La tabla atribuye unos valores para el factor C y el factor P por clase de cobertura del suelo, que se reflejan espacialmente al unirlos al mapa de cobertura del suelo. El factor de uso y gestión del suelo se utiliza en RUSLE (Ecuación Universal de Pérdida de Suelo) para reflejar el efecto de los cultivos y de las prácticas de manejo, en la pérdida anual de suelo y con mayor frecuencia, se utiliza para comparar los impactos relativos de los diferentes planes de manejo del suelo. Para calcularlo específicamente, se requieren datos detallados sobre los usos previos del suelo, la rugosidad de la superficie, la humedad del suelo y los parámetros de la propia vegetación. Se trata de información difícil de obtener fuera de condiciones experimentales y a un nivel de paisaje, por lo que el factor C para Colchagua se ha estimado basándose en la metodología de Panagos et al. (2015). Los resultados de la revisión bibliográfica dan un rango del factor C para las clases de cobertura del suelo, que puede ser corregido basándose en condiciones locales de cobertura de vegetación, utilizando la siguiente formula:

$$C_{LC} = \min(C_{LClit}) + \text{range}(C_{LClit}) \times (1 - F_{cover})$$

donde $\min(C_{LClit})$ y $\text{range}(C_{LClit})$ son el valor mínimo y de rango respectivamente, de los valores del factor C, obtenidos de la bibliografía de clases de cobertura del suelo y F_{cover} es el porcentaje de cobertura del suelo, para cada tipo de vegetación, de los datos de *Copernicus Global Land Service* (2019). F_{cover} se extrajo utilizando el archivo *shape* del mapa de cobertura del suelo y el valor medio para la clase de cobertura del suelo fue aplicado a la formula anterior.

La bibliografía revisada Panagos et al. (2015) tiene un enfoque europeo pero dada la carencia de datos locales, los datos europeos se consideraron más apropiados que las medias globales, debido a las similitudes del clima. De la misma forma, la inclusión del F_{cover} local mejora la especificidad del área de interés.

El factor de práctica mecánica de apoyo (P) especifica la relación entre la pérdida de suelo en comparación con el tipo de cultivo, en pendiente ascendente y descendente y se ve afectado principalmente por los usos de contornos y terrazas (y no por el sistema de cultivo en sí mismo, que se incorpora con el factor C) ya que con el factor C, el valor se aplica según la clase de cobertura del suelo. Dentro de los objetivos de este estudio, el factor P se definió como 1, sin asumir prácticas de manejo del suelo especiales y, por lo tanto, los efectos de manejo solo fueron capturados por el factor C.

Cuencas fluviales

La delimitación de las cuencas fluviales se basó en *HydroBASINS* (Lehner & Grill, 2013) con 12 niveles de subcuencas para la región; la extensión del modelo de suelos se basó en todas las subcuencas que intersectaban con el mapa de cobertura del suelo. Sin embargo, los resultados se presentan en el nivel de máxima resolución en lugar de a nivel de subcuenta para una mejor representación de la erosión del suelo a nivel de los viñedos.

Resultados

El mapa de estimación de pérdida de suelo se muestra en la Figura 3.1. Aunque los resultados del modelo se entregan en $\text{ton ha}^{-1} \text{yr}^{-1}$, no hay datos disponibles para validar los resultados, por lo que estos resultados son cartografiados cualitativamente basándose en la Tabla 3.1.

Tabla 0.1. Rangos de tolerancia de pérdida del suelo (Ficha de OMAFRA, 2015).

Tipo de erosión del suelo	Pérdida potencial de suelo ($\text{ton ha}^{-1} \text{yr}^{-1}$)
Muy baja (tolerable)	<6.7
Baja	6.7 –11.2
Moderada	11.2 –22.4
Alta	22.4 –33.6
Severa	>33.6




Figura 0.1. Estimación de pérdida de suelo en el valle de Colchagua

Utilizando el Índice de Entrega de Sedimento (SDR) para dar información a la Red Bayesiana (*Bayesian Belief Network - BBN*)

La Red Bayesiana de los viñedos como servicios ecosistémicos muestra cómo las prácticas de manejo y el clima futuro, pueden afectar la pérdida de suelo a nivel del terreno (sección 5). Para dar información la BBN, el modelo SDR se volvió a ejecutar después de cambiar los parámetros para el factor C, para la clase de cobertura del suelo del viñedo (para poder representar cambios en la gestión dentro de los viñedos), proyecciones de cambio climático y con franjas buffer nativas adicionales dentro de los viñedos.

Gestión de escenarios

Los cambios en el factor C se basaron nuevamente en Panagos et al. (2015), y se utilizó la siguiente ecuación:

$$C = C_{LC} \times C_{tillage} \times C_{cover}$$

La C_{LC} se calcula como se indicó anteriormente (ver 2.2.7), y se aplica un factor de manejo de la siembra y del tipo de cultivo de cobertura, para cuantificar el efecto de diferentes prácticas sobre la pérdida de suelo. La labranza convencional asume que un $C_{tillage}$ de 1, y una $C_{tillage}$ de 0.35 o 0.25 es apropiada para la conservación en labranza en camellón y no labranza, respectivamente (OMAFRA *Factsheet*, 2015). Un total del 83% de los campos de viñedos gestionados por los interesados en este proyecto (n=18) informaron que utilizaban prácticas de labranza de algún tipo. Como las vides son cultivos permanentes, la labranza no puede ser en el 100% del de la superficie y, por lo tanto, los valores de 0,35 se utilizaron por defecto, pero se cambiaron a 0,25 para medir el impacto en los resultados del modelo, eliminando las prácticas de labranza. El valor predeterminado para C_{cover} fue 1, suponiendo que no se usaron cultivos de cobertura, pero también se usó una iteración donde $C_{cover} = 0,8$, para representar la reducción en la erosión del suelo debido al uso de cultivos de cobertura (Panagos, et al. 2015).

Escenarios de clima

Los viñedos son interesantes para comprender cómo los servicios ecosistémicos pueden responder al cambio climático futuro, particularmente en relación con la gestión del agua. Para analizar las implicaciones del cambio climático a futuro en la región, se seleccionaron dos escenarios de las evaluaciones de la Fase 5 del Proyecto de Intercomparación de Modelos Acoplados (CMIP5) utilizadas en el Quinto Informe de Evaluación del Panel Intergubernamental sobre el Cambio Climático (IPCC). Estas fueron las vías de concentración representativas (PCR) 4.5 y 8.5; que representan dos escenarios diferentes y proporcionan un rango de predicciones. RCP4.5 representa un escenario de cambio climático de estabilización moderada, mientras que RCP8.5 representa un escenario de referencia de emisiones muy alto (van Vuuren, et al. 2011). Los datos para estos escenarios se tomaron de WorldClim y se graduaron como se explicó anteriormente (sección 3.2.2) y se utilizaron para calcular nuevos valores de R para el modelo, de la forma que ya se indicó.

Escenario buffer

En la guía publicada anteriormente para los administradores de viñedos, VCCB fomenta la creación de corredores biológicos de vegetación autóctona alrededor de las tierras agrícolas trabajadas, con al menos 9 m de ancho y conectadas entre ellas, para así estimular la biodiversidad, prevenir la erosión del suelo y mejorar la calidad del agua (Barbosa y Godoy 2014). Para demostrar esto, se agregaron franjas de protección (buffer) de 9 m de bosque autóctono en los campos de los propietarios de los viñedos, usando para ello las tierras de los viñedos dispersos, los cultivos de rotación y las praderas estacionales, ya que éstas eran las clases de tierra dentro de los viñedos a las que era más probable agregar

una franja de protección de árboles autóctonos. La adición de buffers no afecta el escenario de gestión 'Factor C' para la clase de cobertura del suelo 'Viñedo', pero afectará la proporción de clases de cobertura del suelo 'Viñedo' y 'Árboles autóctonos' dentro de las áreas de viñedos, y, por lo tanto, afectará al RUSLE total por viñedo. Debido a esto, todos los escenarios anteriores se ejecutaron utilizando también la capa de cobertura del suelo con el buffer.

Pérdida de la capa fértil del suelo dentro del viñedo.

Los resultados para todos los nodos de la BBN se extrajeron para informar la BBN a nivel del terreno (los límites de las propiedades de los viñedos de los propietarios interesados en el proyecto): el valor medio de los resultados dentro de cada límite de campo se utilizó para las variables continuas y la mediana se usó para las variables categóricas. Los viñedos en el valle de Colchagua se siembran en su mayoría sobre terrenos llanos, sin embargo, RUSLE está fuertemente influenciada por la pendiente. Para capturar mejor el riesgo de pérdida de suelo, se tomaron las medias de todos los píxeles donde la pendiente era mayor que 2°. Se extrajeron los resultados para cada combinación de escenario de gestión, clima y cobertura de tierra protegida. Como antes, la pérdida de suelo fue tipificada usando la Tabla 3.1. *Tasas de tolerancia de pérdida del suelo (Ficha de OMAFRA, 2015).*

Erosión del suelo en pendiente descendente

Para cuantificar la cantidad de suelo que se está erosionando en pendiente, es decir, potencialmente trasladándose cuesta abajo y contribuyendo a la nitrificación de las vides, se calculó la suma de la pérdida de suelo en pendiente para cada viñedo. Se crearon buffers de 50 m para todas las regiones clasificadas como 'Viñedo' (ver también la Sección 6.4.1). Estos se utilizaron para extraer la proporción de cada clase de suelo, más los valores medios de precipitación, pendiente, tipo de suelo y la suma total de la pérdida de suelo dentro del buffer, para usar en la BBN. Los resultados se derivaron de cada combinación de escenario del clima y cobertura del buffer. La exploración de las zonas de "Labranza" a través del paisaje estaba fuera del alcance del proyecto, esto se consideró sólo a nivel de viñedos para usarlo en el modelo Bayesiano (ver Sección 6).

Riesgo de incendio

Introducción

Los fuegos espontáneos han incrementado en frecuencia y tamaño en los últimos años en la zona central de Chile (Gómez-González et al. 2019), generando una amenaza tanto para la producción de los viñedos, como para sus infraestructuras. Aquí se ha empleado el marco del modelo de distribución de especies (SDM), siguiendo estudios previos realizados en Chile y en otros lugares (Gómez-González et al. 2019, McWethy et al. 2018, Duane et al. 2015). Se utilizaron datos históricos de incendios e ignición como puntos análogos a los registros de especies, para identificar predictores ambientales y antropogénicos de incendios forestales. Estos modelos se usan para predecir y cartografiar el riesgo actual de ignición del paisaje y evitar incendios (la no susceptibilidad de incendio del hábitat) e igualmente evitar incendios a través del manejo; específicamente a partir de zonas buffer o de amortiguamiento.

Fuentes de datos

A menos que se especifique de otra forma, todos los datos fueron georreferenciados para WGS84 (EPSG: 4326) y se recortó el área de interés para la cartografía de hábitats. Los datos, a menudo tenían una resolución más baja que la cartografía de hábitats (ver Sección 2) pero se requería que fueran de la misma resolución para el marco de trabajo de la

modelización. Por lo tanto, los datos se volvieron a muestrear a la resolución más alta, de 10 m, de la cartografía de hábitats, cuando fue necesario. La transformación y el re-muestreo se realizaron mediante interpolación bilineal en el caso de variables continuas y de los valores más cercanos, en el caso de variables categóricas, en QGIS 3.4 (QGIS Development Team 2019) y R 3.4.4 (R Core Team 2018).

Las variables predictivas ambientales y antropogénicas consideradas relevantes para el riesgo de incendio del hábitat y su prevención, se seleccionaron principalmente en base a trabajos previos en Chile y otras áreas mediterráneas (Gómez-González et al. 2019, McWethy et al. 2018, Duane et al. 2015). Estas capas de variables fueron en su mayoría índices de clima (temperatura y precipitación), topografía o tipo de vegetación y productividad que, en conjunto, apuntaron a tener en cuenta factores como el material combustible presente y la inflamabilidad de este material. Cuando las capas relacionadas estaban altamente correlacionadas (coeficiente de correlación de Pearson $\geq 0,75$), se utilizó el conjunto de datos más relevante ecológicamente, basal o de alta resolución. Por ejemplo, se consideró la evapotranspiración potencial (PET), pero finalmente no se incluyó como una variable predictiva, dado que está altamente correlacionada con la precipitación y los datos de precipitación en cuestión, eran de mayor resolución y más basales (la precipitación se utiliza para calcular la PET). Las variables de proximidad a poblaciones y carreteras también se incluyeron, ya que más del 99% de las igniciones en Chile central son de origen antropogénico (CONAF 2018, Urrutia-Jalabert et al. 2018).

Datos topográficos

Se incluyeron la pendiente y la elevación, que potencialmente influyen en el comportamiento de los incendios condicionados por la topografía del terreno (Duane et al. 2015), donde la pendiente se calculó a partir del DEM (Modelo Digital de Elevación) utilizando QGIS 3.4.

Datos climáticos

Las temperaturas mínima, máxima y media, la media anual de velocidad del viento y el total anual de precipitación, se calcularon redimensionando las capas de WorldClim, tal y como se describe en la Sección 3.2.1.

La estacionalidad de la temperatura y de la precipitación (la variabilidad estacional de temperatura y precipitación) fueron calculadas utilizando las capas redimensionadas de las temperaturas mínimas y máximas mensuales y de las precipitaciones mensuales, así como el paquete *dismo* de R (Hijmans et al. 2017).

Las capas ráster para el Índice de Sequía de Palmer (PDSI) se descargaron de TerraClimate (<http://www.climatologylab.org/terraclimate.html>) en la resolución más alta disponible (~4 km) para los 10 años más recientes, para los que los datos disponibles eran de 2008-2017 y se calculó la media para crear una sola capa anual PDSI. Este índice describe la humedad y la aridez en relación con la normal local (Palmer 1965) y proporciona información sobre la aridez y la inflamabilidad potenciales del hábitat.

Variables biológicas

El producto del Índice de Vegetación de Diferencia Normalizada MODIS MOD13A1 (NDVI, Didan et al. 2015) se utilizó para informar sobre el modelo de productividad de la vegetación y su condición y fue descargado y procesado utilizando el paquete de R, MODIS (Mattiuzzi and Detsch 2018) para el área de estudio en el periodo 2008-2017 con una resolución de 500 m. La media anual NDVI se calculó desde este producto.

Mapas de hábitats

El mapa de hábitats resultante en la Sección 2, adaptado para incluir la clase viñedo como se describe en la sección 3.2.6, se incluyó para informar el modelo de asociación entre los tipos de vegetación y las áreas quemadas.

Variables antropogénicas

Las capas antropogénicas con la información de densidad de población y distancias de áreas quemadas y no quemadas a carreteras principales, se incluyeron para explicar el hecho de que los incendios forestales chilenos son, casi exclusivamente, el resultado de igniciones antropogénicas (CONAF 2018, Urrutia-Jalabert et al. 2018).

Se descargó un archivo shape de las vías de comunicación chilenas desde *OpenStreetMap* (<https://www.openstreetmap.org>), que se editó para incluir sólo carreteras principales (identificadas como "Autopista", "Primaria", "Secundaria", "Terciaria" y sus respectivas carreteras "Enlace"). Esta capa se rasterizó a una resolución de 0,0001 grados decimales (~ 10 m) y posteriormente se estimó una capa rasterizada de distancia a estas carreteras principales. La rasterización y los cálculos de las distancias se realizaron en QGIS 2.14.5.

Los datos modelizados de la densidad de población por hectárea, redimensionados para que coincidan con las estimaciones de población de la ONU a nivel de país, se descargaron de *WorldPop* (WorldPop 2016).

Datos de áreas quemadas

El producto MCD64A1 (Giglio et al. 2015) del área quemada mensual de MODIS se descargó y se procesó utilizando R y el paquete MODIS a una resolución de ~500 m. Los datos utilizados en el análisis final abarcaron el período 2008-2017. Para cada mes, las áreas separadas de píxeles contiguos quemados (considerando incendios individuales) se hicieron polígonos y se usaron como una máscara para identificar los píxeles quemados en una versión de los datos del mes redimensionados a 10 m, con los valores de latitud y longitud del centroide de píxeles, combinados de cada mes, que se convierten en la capa de puntos de 'localizaciones quemadas' para el análisis de prevención de incendios.

Para cada incendio, también se identificaron el primer píxel o píxeles quemados y se tomaron para representar la localidad de los eventos de ignición en cada incendio. Debido a que las fechas de registro estimadas de los datos del MODIS MCD64A1 tienen una incertidumbre inherente (es decir, la fecha inicial del incendio no siempre se detecta con el 100% de precisión) se consideró que las igniciones que ocurren cerca, en el espacio y tiempo, son un mismo evento. Cuando los píxeles estaban dentro de ~10.4 km uno del otro (la distancia recorrida por un incendio de tamaño mediano en un día (Johnston et al. 2018) según los consejos del Sistema Canadiense de Predicción de Comportamiento de Incendios Forestales (Alexander et al. 1984), se consideró que representaban el mismo evento de ignición. De esta manera, la agregación de todos los puntos de inicio del fuego, de los distintos incendios, dio lugar a 165 posibles "eventos de ignición" únicos, asociados estos eventos con los incendios experimentado en el área de interés en el período 2008-2017. Los píxeles asociados con cada uno de los 165 eventos se poligonizaron a su vez y se usaron como una máscara para extraer la latitud y longitud del centroide de píxeles de una versión redimensionada de 10 m, de los datos de MODIS, de la misma forma que para las localidades quemadas. Esto creó una capa de 814,604 puntos de ignición potenciales. Un punto que se encuentra dentro del área de cada "evento de ignición" fue muestreado aleatoriamente para producir una capa de 165 puntos aleatorios únicos que fueron utilizados como ubicaciones de ignición durante el desarrollo del modelo. Tanto para la quema como para la ignición, todos los puntos ubicados en las clases de hábitat de cubierta de nieve, glaciar, río o lago se eliminaron del conjunto de datos de puntos potenciales para el modelo. Todo el procesamiento se realizó en R.

Modelo de riesgo de incendio

El nivel de riesgo de incendio de un paisaje y la capacidad de prevenir el incendio se incluyeron en el proceso de modelización utilizando el marco del modelo de distribución de especies (SDM). En este contexto, los centroides de las celdas quemadas para el ejemplo de 165 puntos de ignición muestreados al azar, actúan como puntos de presencia análogos a los registros de presencia de especies, y todas las demás capas actúan como predictores ambientales o antropogénicos, que definen dónde se producen los incendios o las igniciones. Aquí implementamos un método de enfoque de regresión de bosques aleatorios (RF) utilizando el paquete *JNCCsdms* (*Joint Nature Conservation Committee*, 2018), que demostró ser, con consistencia, el más exitoso de una serie de modelos de distribución de especies (incluidos *Boosted Regression Trees*, GLM, GAM y *MaxEnt*) implementados en las primeras pruebas.

Se utilizó un enfoque de regresión en lugar de un enfoque de clasificación, para permitir cartografiar los niveles relativos de idoneidad (en lugar de presencia-ausencia) y porque tal y como se había observado anteriormente, las técnicas de regresión tienen más éxito en contextos de SDM (Hijmans y Elith 2019). Los mapas resultantes se crearon promediando los resultados de una serie de ejecuciones del modelo, en este caso se usaron 10 ejecuciones, ya que este valor había sido sugerido por un trabajo anterior que examinaba la implementación de SDM (Barbet-Massin et al. 2012).

Los puntos potenciales de ignición se muestrearon aleatoriamente para cada una de las ejecuciones del modelo descrito en el párrafo anterior, uno para cada “evento de ignición”. El número exacto de puntos varía de una ejecución del modelo a otra (media= 158.6) ya que, al realizarse aleatoriamente, algunos puntos de ignición podían caer fuera del área de interés y no existía mapa de hábitats para estos. Cabe resaltar que, debido a la incapacidad de identificar los puntos exactos de ignición, la cartografía de riesgo de incendio del hábitat debería considerarse significativamente más incierta que la de prevención de incendio para el hábitat. Para el análisis de prevención de incendios se utilizó un conjunto de 10,000 puntos que representaban los píxeles de zonas quemadas en lugar de utilizar la capa completa de píxeles de zonas quemadas, para evitar las limitaciones computacionales o el excesivo tiempo de procesado.

Partiendo de que el incendio e ignición representan un solo dato de presencia y de que el marco del modelo requiere información de las ausencias (ej. donde los fuegos no han tenido lugar) se generaron puntos aleatorios de pseudo-ausencia para cada modelo ejecutado, donde el número de puntos generados era igual al número de puntos de presencia utilizados en esa misma ejecución. Los puntos de pseudo-ausencia se generaron, por lo tanto, en igual número a los de presencia (aunque típicamente las muestras no eran exactamente iguales) siguiendo sugerencias de trabajos previos sobre modelos de distribución de especies (Barbet-Massin et al. 2012), lo que sugiere una ponderación igual de las presencias y ausencias e igual número de cada uno de ellos en la realización del modelo aleatorio de bosques (aunque en ese caso considerando la clasificación). Adicionalmente, en el caso de riesgo de incendio, el valor típicamente utilizado de 10.000 puntos de pseudo-ausencia no fue usado para el modelo ya que resultó demasiado ajustado y se evitó utilizando un número menor de puntos de ausencia.

Se ajustaron y utilizaron diez modelos para producir diez rásteres (promediados posteriormente) de prevención de incendios esperados (Figura 4.1) y riesgo de incendio (Figura 4.2) y diez más para evitar incendios en el escenario de gestión de las zonas búfer (utilizado para rellenar la BBN, ver apartado 3.4). Esta gestión de las predicciones fue creada de la misma forma y usando los mismos parámetros que los modelos ejecutados sin incluir la gestión, sin embargo, la capa de

entrada de cartografía de hábitats se reemplazó por una cartografía de hábitats modificada, donde se agregaron 9 m de áreas buffer forestales a las áreas de vides, prados y los cultivos dentro de los viñedos, para simular efectos de gestión (ver sección 3.4.3). Los resultados promediados se categorizaron como 'Pobre', 'Moderado' y 'Bueno' para prevención de incendios, representando valores de <33%, 33-66% y >66% respectivamente, y 'Bajo', 'Moderado' y 'Alto' para riesgo de incendio, representando valores de <33%, 33-66% y >66% respectivamente. El AUC (área bajo la curva ROC) también es considerado como un indicador de la calidad del funcionamiento del modelo, donde un AUC de 1 indica una predicción del modelo altamente exitoso, y 0 indica una predicción altamente infructuosa (Hijmans y Elith 2019).

Dando información a la BBN

El valor medio de prevención de incendio tanto para el modelo sin gestión como para el que se desarrolla bajo gestión se calculó para cada combinación de viñedo y se usó para informar a la BBN (Sección 6)

Hay que tener en cuenta que el cambio climático no se incluyó en el modelo de escenario de incendio, ya que estos modelos no produjeron una prevención de incendios esperados realista. Hay varias razones posibles y probables para esto. Los valores de estacionalidad de la precipitación y de la temperatura bajo cambio climático, a menudo se encuentran fuera del rango de valores con los que se preparó el modelo de fuego. Además, los datos de precipitación de WorldClim demostraron incrementos con el cambio climático, en contraste con lo que se espera de la región (Urrutia-Jalabert et al. 2018). Igualmente, las relaciones no lineales entre el fuego observado y las variables climáticas pueden dar lugar a interacciones inesperadas entre el clima previsto y el fuego. Debido a la falta de confianza en los resultados del modelo de escenario, no se incluyeron en el producto final y las predicciones bajo el cambio climático no se consideraron para la prevención de incendios en la BBN.

Resultados




Figura 0.1. Capacidad del hábitat de evitar el incendio, categorizado como Bueno (>66% capacidad, menos probabilidad de incendio), Moderado (33-66%) y Pobre (<33% de capacidad, mayor probabilidad de incendio). Lo que significa AUC = 0.994.




Figura 0.2. Riesgo de incendio del hábitat, categorizado como Bajo (<33% de riesgo, menor probabilidad de incendio), Moderado (33-66% de riesgo) y Alto (>66% de riesgo, mayor probabilidad de incendio). Lo que significa AUC = 0.835.

Calidad y suministro del agua

Introducción

El suministro y la calidad del agua fueron destacados como una prioridad por los participantes del proyecto, considerándose esenciales para la producción de la uva y una preocupación clave en términos de gestión de los recursos hídricos en futuros escenarios climáticos. VCCB enfatizó los deseos de las partes interesadas de entender cómo las estrategias de manejo que involucran la aplicación de fertilizantes y pesticidas, la labranza del suelo, la creación y el mantenimiento de corredores biológicos y coberteras podrían afectar los recursos hídricos actualmente y en escenarios futuros.

Para entender los procesos que hay detrás de estos servicios ecosistémicos, se utilizó la Herramienta de Evaluación de Suelos y Aguas (SWAT)³ para modelar y cartografiar las mediciones de agua dentro del valle. El SWAT es un modelo complejo semidistribuido, desarrollado por el Servicio de Investigación Agrícola (USDA-ARS) del Departamento de Agricultura de los Estados Unidos y se ha aplicado a nivel mundial, para evaluar el movimiento de agua y los sedimentos dentro de las cuencas. El SWAT es considerado como una herramienta sólida e interdisciplinaria de modelado de cuencas hidrográficas, con una base de datos online de casos estudio, aplicada a nivel mundial (Gassman, et al. 2007). Su flexibilidad permite a los usuarios modificar los usos de la tierra y las operaciones de gestión dentro de parcelas, tales como rotaciones de cultivos, uso de fertilizantes y labranza.

Los estudios han aplicado SWAT para examinar los escenarios de cambio climático, las evaluaciones de la calidad del agua y su intercambio en las diferentes prácticas de manejo del suelo. Esta versatilidad y la solidez de la herramienta de modelado, lo hacen muy adecuado para producir mapas de servicios ecosistémicos y explorar cómo diferentes prácticas de manejo, pueden modificar sus resultados. SWAT se usó sobre otras herramientas de cartografía de servicios ecosistémicos, ya que produce mediciones intermedias hidrológicas adicionales, como la percolación, que son relevantes para los viñedos. Los algoritmos incorporados de SWAT para determinar el rol de la nieve en el suministro de agua, favorecen su uso sobre otros modelos similares en cuencas hidrográficas, y debido a esto se han aplicado en estudios previos de los Andes chilenos (Stehr et al., 2008; Omani et al., 2017).

Modelo de Herramienta de Evaluación de Suelo y Aguas (SWAT)

SWAT es un modelo ambiental de libre acceso para evaluar la dinámica hidrológica y sedimentaria, diaria, mensual y anual a nivel cuenca. Está disponible a través de la interfaz QGIS como un complemento QSWAT de *Python* y utiliza entradas de datos de altitud, usos y cartografía del suelo, para delinear una cuenca hidrológica en subcuencas y determinar Unidades de Respuesta Hidrológica (HRU). Estas HRU son parcelas con características topográficas y cobertura de suelo homogénea, que se incorporan a las ecuaciones de escorrentía y erosión del suelo, para generar las estadísticas de producción de agua y rendimiento de sedimentos. Se pueden aplicar diferentes condiciones de manejo a cada HRU y se puede medir su respuesta cambiante en todo el paisaje. En la Figura 5.1 se muestra un diagrama de flujo del desarrollo del modelo SWAT.

³ La herramienta para evaluación de agua y suelo (SWAT) (2019) is una software de libre acceso mediante la Universidad Texas A&M en: <https://swat.tamu.edu/> .




Figura 0.1. Diagrama de flujo con la metodología de desarrollo del modelo SWAT.

Para pronosticar con precisión los movimientos de nutrientes, sedimentos y agua, SWAT modela el ciclo hidrológico simulando lo que ocurre en toda la cuenca. En primer lugar, se simula el equilibrio hidrológico para cada HRU dentro de una subcuenca; esto se calcula a través de la ecuación del balance hídrico (Neitsch et al. 2011):

$$SW_t = SW_0 + \sum_{i=1}^t (R_{day} - Q_{surf} - E_a - w_{seep} - Q_{gw})$$

donde SW_t es el contenido final de agua en el suelo (mm H₂O), SW_0 es el contenido inicial de agua en el suelo en el día i , t es el tiempo (días), R_{day} es la cantidad de precipitación en el día i (mm H₂O), Q_{surf} escorrentía superficial (mm H₂O), E_a es la cantidad de evapotranspiración en el día i (mm H₂O), w_{seep} es la cantidad de agua acumulada en la zona no saturada del suelo en el día i (mm H₂O), and Q_{gw} es la cantidad de agua subterránea que retorna hacia los ríos como flujo base o caudal de base en el día i (mm H₂O).

El cálculo de las variables de entrada a la ecuación sobre la base de HRU permite que factores de entrada, como la evapotranspiración y la escorrentía, reflejen las diferencias entre los cultivos y los tipos de suelo (Neitsch, et al. 2011). Este cálculo determina la fase terrestre del ciclo hidrológico y la cantidad de agua depositada en la tierra e ingresando a los canales principales, dentro de cada división de sub-cuenca.

Las entradas y procesos en esta etapa incluyen variables climáticas de precipitación diaria, temperatura mínima y máxima del aire, velocidad del viento, radiación solar y humedad relativa. SWAT utiliza métodos de computación basados en índices de temperatura para modelar sus procesos hidrológicos y de deshielo, descritos en Neitsch et al. (2002). SWAT clasifica la entrada de precipitación como lluvia o nieve determinada por la temperatura media diaria y los umbrales de temperatura de nevada. El deshielo se rige entonces por un conjunto de parámetros que pueden asignarse a la totalidad de la cuenca o dentro de las franjas de altitud de las subcuencas individuales, lo que permite flexibilidad al trabajar en cuencas hidrográficas glaciares montañosos.

El almacenamiento, la infiltración y la evapotranspiración de la cubierta se calculan a partir de los tipos de suelo y de vegetación, determinados por las clases de uso del suelo. SWAT utiliza un método de número de curva del Servicio de Conservación de Suelo (SCS) modificado para calcular el volumen de escorrentía superficial:

$$Q_{surf} = \frac{(R_{day} - I_a)^2}{(R_{day} - I_a + S)}$$

Donde Q_{surf} es la escorrentía acumulada o el exceso de lluvia (mm H₂O), R_{day} es la cantidad de precipitación del día (mm H₂O), I_a es la abstracción inicial que incluye el almacenamiento, la interceptación y la infiltración en la superficie antes de la escorrentía (mm

H₂O), y S es el parámetro de retención (mm H₂O) que varía según los cambios en los suelos, el uso del suelo, la pendiente y el manejo.

La erosión del suelo se determina mediante el uso de la Ecuación Universal de Pérdida de Suelo Modificada (MUSLE), que está bien establecida en modelos de erosión del suelo (Dile et al. 2018; Williams, 1975):

$$sed = 11.8 \cdot (Q_{surf} \cdot q_{peak} \cdot area_{hru})^{0.56} \cdot K_{USLE} \cdot C_{USLE} \cdot P_{USLE} \cdot LS_{USLE} \cdot CFRG$$

Donde *sed* es el rendimiento de sedimento en un día determinado (toneladas métricas), Q_{surf} es el volumen de escorrentía superficial (mm H₂O/ha), q_{peak} es la tasa de escorrentía máxima (m³/s), $area_{hru}$ es el área de la HRU (ha), K_{USLE} es el factor de erosionabilidad del suelo de la USLE (0.013 ton métrica m² hr/m³ – ton métrica cm), C_{USLE} es la cobertura de la USLE y el factor de gestión, P_{USLE} es el factor de la práctica de soporte de la USLE, LS_{USLE} es el factor topográfico de la USLE y CFRG es el factor de fragmento grueso.

La ecuación MUSLE utiliza la cantidad de escorrentía para simular la erosión del suelo, proporcionada por el modelo hidrológico, junto con los factores de manejo del cultivo y el factor C (C_{USLE}), que es un valor que cuenta el grado de pérdida de suelo según el tipo de cultivo, el manejo y la cobertura del suelo. Otros factores utilizados en la ecuación de pérdida de suelo se derivan de Wischmeier y Smith (1978). SWAT utiliza la ecuación MUSLE, ya que puede proporcionar una resolución temporal más detallada, que genera resultados diarios y utiliza el factor de escorrentía para calcular la erosión, a diferencia de la Ecuación de Pérdida de Suelo Universal Revisada (RUSLE) utilizada en el modelo de distribución de sedimentos INVEST, que utiliza, a su vez, la precipitación anual para calcular la erosión bruta anual utilizando el factor de energía de la precipitación (ver sección 2).

El ciclo del nitrógeno también se simula en SWAT a través del monitoreo de cinco pozos de nitrógeno; NH₄ y NO₃ almacenados en el suelo afectado por los cálculos de la absorción, lixiviación, volatilización, desnitrificación y erosión de la planta, y tres grupos de nitrógeno orgánico asociado con el humus del suelo, detallados en Neitsch et al. (2002). De manera similar, el ciclo del fósforo se equipará a través del monitoreo de las reservas almacenadas de fósforo soluble y orgánico en el suelo. Los insumos adicionales de fertilizantes y pesticidas se derivan de las funciones de carga y se aplican a través de las operaciones de manejo a la tierra.

La segunda fase del modelo controla como el agua, los nutrientes y los sedimentos se mueven a través de la red de afluentes y hacia al cauce principal (ej. el río Tinguiririca). Los sedimentos, el flujo de agua, los nutrientes y las rutas químicas se equiparán en toda la red de afluentes, teniendo en cuenta las operaciones de gestión de la tierra dentro de cada subcuenca e influyendo en las condiciones aguas abajo.

El modelo SWAT utiliza todos estos algoritmos para generar varias medidas intermedias en cada etapa del ciclo hidrológico, así como para cuantificar la cantidad de escorrentía de cada HRU y las concentraciones de flujo, sedimentos y nutrientes dentro de la red de flujo de aguas. Esta información se puede mostrar espacialmente para cartografiar la variación de estas medidas a lo largo del paisaje. El modelo se puede ejecutar bajo diferentes condiciones climáticas modeladas y de operaciones de manejo, para comparar cómo estos impactan en los ciclos hidrológicos modelados.

Fuentes de datos

Todos los datos fueron georreferenciados a WGS84 UTM zona 19S (ESPG: 32719) y recortados al área de interés detallada en la Sección 2.2.1. El modelo SWAT se creó utilizando la versión 1.7 de QSWAT bajo la versión 2.18.27 de QGIS de 32 bits. El procesamiento de datos y las transformaciones también se realizaron en esta versión de QGIS (QGIS *Development Team* 2019) y en R versión 3.4.4 (R *Core Team* 2018).

El paisaje

La cuenca modelada en el valle de Colchagua, en el centro de Chile, tiene una superficie total de 6.163,95 km² y abarca todos los viñedos asociados al VCCB paratípicos del proyecto. La cuenca transcurre desde una elevación mínima de 55 m hasta un máximo de 4.971 m en las montañas andinas. Para delinear la cuenca hidrográfica y crear capas topográficas, se volvió a proyectar una capa ráster DEM de 30 m (ver Apéndice 1) en la proyección regional ESPG: 32719 y se recortó sobre el límite extendido de la cuenca hidrográfica (toda el área de interés que se muestra en la Figura 5.2). Los límites de la delineación de cuencas hidrográficas de alto nivel se obtuvieron a partir de datos hidrológicos y mapas basados en Derivados de Elevación *SHuttle* en escalas múltiples (*HydroSHEDS*) desarrollados por el Programa de Ciencias de la Conservación del Fondo Mundial para la Vida Silvestre (WWF, 2019). La capa vectorial estaba disponible en una escala global desarrollada a partir de modelos digitales de elevación SRTM, de alta resolución y desglosada en diferentes escalas de delineación. Estas escalas, son diferentes subdivisiones del terreno según las cuencas hidrográficas, determinadas por la elevación y se encuentran disponibles a diferentes escalas, según el concepto topológico del sistema de codificación *Pfafstetter*, que varía de 1 a 12 y aumenta a medida que las cuencas hidrográficas se dividen en subunidades más pequeñas. Se utilizó una capa de polígonos *HydroBASIN*, un subconjunto de la base de datos *HydroSHEDS* en la resolución de arco de 15 segundos (Lehner & Grill, 2013), en el Nivel 7 de *Pfafstetter* para determinar las principales cuencas hidrográficas que cubren el área de interés y la red de cauces fluviales. El área de interés utilizada para el proceso de modelado SWAT difiere ligeramente de los otros mapas producidos en este proyecto, ya que está recortada por el límite de la delineación de la cuenca hidrográfica principal, por lo que da como resultado una región modelada ligeramente más pequeña.

La cobertura del suelo se basó en el mapa de 16 clases adaptado, desarrollado para este proyecto (ver sección 3.2.6). Se obtuvo una loseta de suelo sudamericana de *Waterbase* (UNU-INWEH, 2019) basada en el Mapa Mundial de Suelos del Mundo (2003) de la Organización de las Naciones Unidas para la Agricultura y la Alimentación. El mapa de suelo (v.3.6) se preparó a una escala nominal de 1: 5000000 (resolución de 65 km²) y se recortó sobre el límite de la cuenca hidrográfica.

El clima

Se proporcionaron datos locales de cinco estaciones meteorológicas de las partes interesadas para 2018, con registros diarios incompletos para variables que incluían; Temperatura diaria del aire, precipitación, humedad relativa, radiación solar y velocidad del viento. Para mejorar las estimaciones hidrológicas, se agregaron datos de estaciones adicionales de la red hidrométrica Dirección General de Aguas (DAG, 2019) del Ministerio de Obras Públicas.

Los escenarios de cambio climático se desarrollaron con proyecciones climáticas de las evaluaciones de la Fase 5 del Proyecto de Intercomparación del Modelo Acoplado (CMIP5) utilizadas en el Quinto Informe de Evaluación por el Panel Intergubernamental sobre el Cambio Climático (IPCC). Los datos del modelo CMIP5 HadGEM2-ES se utilizaron junto con los datos climáticos históricos de referencia de 1979-2005 a una resolución de 38 km.

Estos se obtuvieron como registros diarios de temperatura y de precipitación de 2W2E (2019) que extrajeron datos del proyecto ISI-MIP, que desarrollaron un Conjunto de herramientas de Cambio Climático para proyectar y extraer datos predictivos bajo los escenarios CMIP5 (Vaghefi et al. 2017) utilizando datos históricos CRUTS3.1 de la Unidad de Investigación del Clima de East Anglia (Harris et al. 2014). Para suministrar todas las variables requeridas en SWAT (datos diarios de radiación solar, la humedad relativa y la velocidad del viento) estos datos se extrajeron durante el mismo período del conjunto de datos meteorológicos globales del Centro de Predicción Ambiental Nacional (NCEP-CFSR) a través de la herramienta de datos meteorológicos de SWAT (2019).

La cuenca hidrográfica dentro del área de interés incluye una región glaciaria de las montañas andinas y, por consiguiente, el deshielo es un recurso hídrico clave en la región (Valdés-Pineda, 2014). Los conjuntos de datos de *Global Land Ice Measurements from Space* (GLIMS, 2018) se utilizaron para hacer comparaciones con los perfiles de glaciares y los datos de profundidad de nieve que se obtuvieron de las estaciones de estudio en el documento complementario de Stehr & Aguayo (2017)

Configuración del modelo

Delineación de cuencas

Las redes de flujo se definieron mediante el uso de la metodología de "burn-in" disponible a través de la interfaz QSWAT. Para este método, se extrajeron las alturas de los datos de elevación digital dentro del DEM y posteriormente se superpuso una red de flujo definida digitalmente (*HydroBASIN*, 2010) sobre el DEM, para proporcionar una definición hidrográfica de los flujos y la delineación de las cuencas. Las subcuencas se delinearon utilizando técnicas analíticas estándar de la suite *TauDEM*, contenidas en la interfaz SWAT QGIS (Dile, et. Al. 2018). Se utilizó un área de curso alto mínima de 50 km² para el valor de umbral de la cuenca de drenaje, al definir las celdas de la corriente. Este es el área mínima que drena en una corriente, por lo tanto, ayuda a definir el tamaño de la subcuenca. Este valor de umbral se basa en un modelo SWAT para una cuenca en la región cercana de Biobío, que cubría una cuenca de tamaño similar (Stehr et al. 2008).

El área de estudio contiene dos cuencas hidrográficas (de la delineación Pfafstetter de nivel 7), la cuenca hidrográfica principal de interés y una subsección adicional de la cuenca hidrográfica hacia el suroeste, donde se ubicaron algunos viñedos interesados fuera de la cuenca hidrográfica principal. Las salidas principales del río, las ubicaciones de los embalses y la entrada de la subcuenca se basaron en comparaciones con el complemento de mapas base "QuickOSM" disponible en QGIS (Trimaille, 2019) y se ajustaron a 300 m. El área total modelada fue de 6163,95 km², con un tamaño de cuenca principal de 5055,60 km². Este se dividió en 68 subcuencas, como se muestra en la Figura 5.2.




Figura 0.2. Cuenca delineada superpuesta al modelo digital de elevación del terreno.

Creación de Unidades de Respuesta Hidrológica (HRU)

Las subcuencas se dividieron entonces en Unidades de Respuesta Hidrológica (HRUs) definidas por un único uso del suelo y combinaciones de tipo de suelo para cada subcuenta. Estas Unidades se definieron a partir de la cartografía de hábitats derivada de las imágenes del satélite *Sentinel-2* (ver Capítulo 2) y de la capa de suelos global de la FAO a través de *Waterbase*. SWAT contiene bases de datos predeterminadas de suelos agrícolas y urbanos, definidas por una variedad de características como la profundidad máxima de enraizamiento y el índice de área foliar, usadas en las ecuaciones hidrológicas, de suelo y de nutrientes.

Como los datos locales no se encontraban disponibles para cada parámetro de los tipos de hábitats de la zona, las clases de hábitats de la cartografía se equipararon con las clases de suelos agrícolas/urbanos de la base de datos de referencia de SWAT (mostrado en el Apéndice 2). Estas equivalencias pudieron crear imprecisiones en la modelización de cada planta con SWAT, ya que las clases se basan en usos del suelo de Norteamérica (donde se desarrolló SWAT). Si se pudiese acceder a una mayor cantidad de datos locales sobre las tierras agrícolas, el modelo sería mucho más preciso al refinarse los resultados basados en parámetros locales.

Debido a esta falta de datos locales, la base de datos global de la FAO (ONU) se utilizó para definir las características del suelo, lo que era más compatible con la creación de la base de datos de referencia QSWAT (*global_soils_and_usersoil*). Dentro de cada subcuenta, se utilizó una única combinación de usos del suelo y cobertura, para generar 1036 HRUs, que se pueden ver en la Figura 5.3. Para cada única HRU se aplicaron parámetros de operaciones de manejo y de nieve para definir los ciclos de crecimiento y de deshielo. Los parámetros del modelo de las HRU se explican en el Apéndice 2.




Figura 0.3. Cartografía de las actuales HRUs derivada de los mapas de usos y tipos de suelo.

Datos de la estación meteorológica y del generador de clima

Los datos de la estación meteorológica local se prepararon con el formato de SWAT, convirtiendo las unidades de medidas utilizando la versión 1.2.2 (Anderson, et al. 2016) y Allen et al. (1998) de *'weathermetrics'* (medidas meteorológicas) de R, con una conversión de factores por unidad de radiación solar de vatios por metro cuadrado por día ($W/m^2 \text{ day}^{-1}$) a mega julios por metro cuadrado por día $MJ/m^2 \text{ day}^{-1}$. Cuando se utiliza el modelo SWAT se sugiere utilizar, al menos, entre 3 y 5 periodos de calentamiento para darle al proceso de simulación tiempo suficiente para establecer las condiciones básicas de flujo y de proceso hidrológico, particularmente para establecer los niveles de reserva de agua necesarios para asegurar la precisión del modelo (Almendinger 2016). Para ayudar en las conversiones de las carpetas diarias de textos emitidas por la estación y añadir datos de simulación para el periodo de pre-calentamiento se creó una herramienta de escritura de datos climáticos *'weathergen.R'* en R para acelerar el proceso.

Para realizar las dos simulaciones de cambio climático RCP4.5 and RCP.8.5, solo estaban disponibles los datos registrados de precipitación y temperatura diarios del aire y para mantener la consistencia del modelo de base, estos datos fueron modelados utilizando también un periodo de pre calentamiento de 3 años.

Adicionalmente a los datos de la estación meteorológica, SWAT necesita un “generador de clima”, que es una tabla de estaciones con variables medias mensuales a la que se puede hacer referencia cuando no existen datos locales y las condiciones deben ser simuladas. Para cada sub-cuenca el modelo busca la estación más cercana con datos disponibles, por lo que, si no existen datos para ese periodo, SWAT utilizara los datos simulados de la estación. Para mantener la consistencia, a la hora de construir el “generador de tiempo”, se utilizaron los datos diarios históricos, que sirvieron para generar la simulación de valores de

cambio climático. Se encontraron datos diarios máximos y mínimos de temperatura del aire y de precipitaciones en RCP4.5 y RCP.8.5 para el periodo 1979-2005. Para el resto de las variables que necesita SWAT, radiación solar, velocidad del viento y humedad relativa los datos

Las estaciones CRUTS se compararon con la estación CFSR más cercana, para poder obtener las variables climáticas que no se tenían (QGIS *processing*). Para calcular los 169 valores climáticos estadísticos que requiere el modelo generador del clima, se desarrolló otra herramienta de R, 'swat_wgen.R', que sigue el mismo modelo utilizado ampliamente por "WGN Excel macro", desarrollada por Dr. Gabrielle Boisrame y disponible a través de las páginas del software en SWAT (2019). Las estadísticas climáticas de la media hora de máxima intensidad de lluvia se asumieron como el valor equivalente a un tercio de la cantidad total diaria de precipitación.

Modelado base o de referencia

El modelo SWAT se ejecutó con los datos preparados de la estación meteorológica y el generador de clima a partir de las estadísticas meteorológicas históricas a largo plazo. El modelo SWAT se ejecutó en primer lugar para mostrar las condiciones de referencia, los aportes de los servicios ecosistémicos, donde no se había aplicado ninguna medida de gestión del suelo. Para el modelo de base, se aplicó un período de pre-calentamiento de 3 años utilizando datos simulados, luego se ejecutó el modelo durante 3 años desde 2016 a 2018, utilizando datos de la estación meteorológica cuando estaban disponibles e imprimiendo los resultados anualmente, utilizando una medida tiempo anual. Los valores medios a lo largo del período de ejecución se utilizaron para producir los gráficos finales del flujo de agua y las medidas de calidad del agua desde las HRU hasta el cauce, tal y como se muestra en las Figura 5.4 - 5.9.

Los resultados obtenidos se presentaron en categorías con valores alto, moderado y bajo. Los límites de las categorías para la cartografía generada se determinaron a partir de los rangos del modelo de referencia, y de la bibliografía consultada para las variables de los rangos meteorológicos en Chile Central (Boisier, et al. 2018, Alvarez-Garretón, et al. 2018). El rendimiento estimado de agua, se define como la cantidad total de agua que abandona el HRU hacia el canal principal y su valor se calcula a partir del agua de superficie perdida, el flujo lateral, subterráneo y las ecuaciones de pérdida de transmisión. De forma similar, los días de estrés hídrico es un valor calculado en SWAT por la siguiente ecuación:

$$wstrs = 1 - \frac{E_{t,act}}{E_t} = 1 - \frac{W_{actualup}}{E_t}$$

Donde $wstrs$ es el estrés hídrico para un día específico, E_t es la máxima transpiración de las plantas en ese día (mm H₂O), $E_{t,act}$ es la cantidad real de transpiración en un día determinado (mm H₂O) y $W_{actualup}$ es la absorción total de agua de la planta durante el día (mm H₂O). Otros cálculos del estrés hídrico que experimenta una planta pueden variar al usar diferentes medidas, como la escorrentía anual o los indicadores del estrés hídrico (Alcamo et al. 2007).

El aspecto cuadriculado de los mapas resultantes refleja la baja resolución de la capa de datos de suelos de la FAO utilizada en el modelo, lo que no refleja de forma precisa como varía la composición del suelo en el espacio a lo largo del paisaje. Debido al poco tiempo que se tenía para el proyecto no fue posible llevar a cabo un análisis de sensibilidad que sirviese para evaluar la influencia relativa de la capa de datos, incluida la capa de suelos.

Como los datos de los niveles actuales de fosfatos y nitratos, presentes en los cursos de agua no estaban disponibles fue difícil determinar el estado actual de calidad del agua en la región. Para dar una idea de las áreas que deberían, naturalmente, tener niveles altos de nitratos y de fosfatos y por lo tanto, un alto potencial de riesgo de baja calidad del agua se cartografiaron las tasas de carga de nitrógeno orgánico y de fósforo. Estas, fueron calculadas a partir de un número de ecuaciones utilizadas para establecer el modelo del ciclo del nitrógeno y del fósforo basados en las clases de usos del suelo y las características de este, obtenidas de Neitsch et al. (2011). La categorización de los niveles de nitratos y fosfatos presentes en el agua se basa en la clasificación de concentraciones de ADAS reportada por DEFRA y obtenida de la evaluación hecha para la Directiva de nitratos en Inglaterra (2007) y el UKTAG WFD de estándares europeos (2008), que puede verse a continuación en la Tabla 5.1

Tabla 0.1. Clasificación por niveles de nitratos y fosfatos presentes en el agua (ADAS, 2007, UKTAG WFD, 2008).

Concentración media de nitratos		
Clasificaciones por grado de nitratos	Grado limite (mg NO ₃ /l) Media	Descripción
1	<5	Muy bajo
2	>5 to 10	Bajo
3	>10 to 20	Moderadamente bajo
4	>20 to 30	Moderado
5	>30 to 40	Alto
6	>40	Muy alto

Media anual de fósforo reactivo soluble	
Estado	Grado limite (µg/l)
Alto	<30
Bueno	>50 to 30
Moderado	>150 to 30
Pobre	>500 to 150




Figura 0.4. Cartografía de referencia con el rendimiento anual del agua y del flujo de corriente medio diario durante el período modelado, dividido entre las Unidades de Respuesta Hidrológica. La apariencia cuadriculada de la cartografía resultante refleja la baja resolución de la capa de datos de suelos de la FAO utilizada en el modelo.




Figura 0.5. Cartografía de referencia con la filtración media anual que pasa la profundidad de enraizamiento del cultivo.




Figura 0.6. Cartografía anual de días de estrés hídrico durante el período modelado, enfocado en la zona suroeste de la región, la zona principal más poblada del valle, donde predominan los viñedos de los interesados.




Figura 0.7. Cartografía del contenido diario promedio de agua en el suelo para el período, ampliado a la mayor región poblada en el suroeste del valle donde predominan los viñedos de las partes interesadas.




Figura 0.8. Cartografía de tasas de carga de nitrógeno orgánico, donde los nutrientes abandonan las Unidades de Respuesta Hidrológica y entran a la corriente. Se ha cartografiado a partir de los niveles naturales de nitrato presentes en el agua de cada cauce. Se trata de estimaciones de niveles naturales sin ningún tipo de manejo adicional aplicado al paisaje.




Figura 0.9. Cartografía de las tasas de carga de fósforo orgánico, donde los nutrientes abandonan las Unidades de Respuesta Hidrológica y entran en la corriente. Esto se cartografía a partir de los niveles naturales de fósforo soluble presentes en el agua. Se trata de estimaciones de niveles naturales, sin ningún tipo de manejo adicional aplicado al terreno.

Tabla 0.2. Resumen de cartografía base producida a partir con los datos resultantes extraídos de la documentación SWAT (Arnold, et al. 2012; Neitsch et al. 2012,). Los rangos categóricos se indican como: Muy bajo = VL, Bajo = L, Bajo-Moderado = LM, Moderado = M, Moderado-Alto = MH, Alto = H, Muy alto = VH.

	Variable SWAT	Medida	Descripción	Limites Categóricos
Servicio ecosistémico de suministro de agua	WYLD	Rendimiento de agua	Cantidad total de agua que sale de la HRU e ingresa al canal principal. Calculado a partir de la escorrentía de las aguas superficiales, el flujo lateral, el flujo de agua subterránea, las pérdidas de transmisión a través de canales tributarios y las extracciones de agua.	(mm H ₂ O) VL:0-200, L:200-350, M:350-500, H:>500
	(Calculado)	Flujo medio diario	Cantidad media de flujo de agua dentro de un cauce (la extensión continua del agua dentro de una subcuenta) calculada a partir del promedio del flujo de agua diario hacia y desde ese mismo cauce.	(m ³ /s) L:0-10, M:10-20, H: 20-30, VH:>30
	PERC	Filtración	Agua que se filtra más allá de la zona radicular. Esto se basa en la profundidad de enraizamiento asociada con el tipo de cultivo y se calcula el valor anual promedio por HRU.	(mm H ₂ O) VL: 0-50, L:50-150, M:150-250, H:250-350, VH:>350
	SW_INIT	Contenido de agua en suelo-comienzo del día	Contenido de agua en suelo, tomado como la cantidad de agua en el perfil del suelo al comienzo del día, promediado a lo largo del período de tiempo.	(mm H ₂ O) VL: 0-30, L:30-60, M:60-90, H:>90
	SW_END	Contenido de agua en suelo-final del día	Contenido de agua en el suelo tomado como la cantidad de agua en el perfil del suelo al final del día, promediado en todo el período de tiempo. La pérdida de agua del suelo desde el comienzo del día es una función a partir del contenido inicial de agua del suelo, el tiempo, la precipitación, la escorrentía superficial, la evapotranspiración, las características del perfil del suelo y el flujo de retorno.	(mm H ₂ O) VL: 0-30, L:30-60, M:60-90, H:>90
	(Calculado)	Media diaria de contenido de agua en suelo	Contenido diario promedio de agua en el suelo calculado a partir de los valores promedio al comienzo y al final del día (SW_INIT & SW_END).	(mm H ₂ O) VL: 0-30, L:30-60, M:60-90, H:>90
	W_STRS	Días de estrés hídrico	Número de días que la planta experimenta estrés hídrico. El estrés hídrico se considera 0 si está en condiciones óptimas de agua para el cultivo y se acerca a 1, cuando las condiciones del agua del suelo difieren de las óptimas. Esto se determina mediante comparaciones de la transpiración real y potencial de la planta, descritas en Neitsch et al. 2012	(días) 0-50 , 50-100 , 100-150 , 150-200
Calidad del agua	ORGN	Rendimientos según la cantidad de nitrógeno orgánico	Cantidad de nitrógeno orgánico transportado fuera de la HRU y hacia el cauce de estudio durante el periodo de tiempo. En el escenario base, estos son valores de nutrientes basados en el uso y el tipo de suelo, sin ningún aporte adicional debido al tipo de manejo.	(kg N/ha) VL:0-10, L: 10-25, M: 25-35, H: >35
	ORGP	Rendimientos según la cantidad de fósforo orgánico	Fósforo orgánico transportado junto con el sedimento fuera de la HRU y al cauce de estudio, durante el periodo de tiempo. Se trata de valores de nutrientes modelados, basados en los usos y el tipo de suelo, sin ningún aporte adicional debido al tipo de manejo.	(kg N/ha) VL:0-1.5, L:1.5-3.0, M:3.0-4.5, H: >4.5
	NO3_OUT	Concentración de nitratos	Media diaria de concentración de nitratos que abandona el cauce.	(mg N/L) VL: 0-5, L: >5
	SOLP_OUT	Concentración de fósforo soluble	La concentración media anual de fósforo soluble que sale del cauce.	(ug P/L) VL:0-30, L:30-50, M:>50

Escenarios de cambio climático

Con el mismo generador de clima y utilizando el modelo de base, se ejecutaron dos posibles escenarios de cambio climático (ver sección 5.4). Las precipitaciones diarias y las temperaturas mínimas y máximas, se utilizaron bajo las simulaciones de HadGEM2-ES RCP 4.5 y 8.5 (ver sección 3.4.2). Los escenarios se ejecutaron para un período de pre-calentamiento de tres años, de 2066 a 2068 y luego se modelaron para tres años de 2069 a 2071.

La Figura 5.11 muestra las descargas mensuales para un cauce estudio (cauce 63) en el escenario base de referencia, y la Figura 5.11 compara las descargas entre las dos simulaciones de cambio climático. El cauce 63, se seleccionó debido a que estaba ubicado dentro del valle central, cerca de varios viñedos participantes del proyecto y localizado río arriba con respecto a la salida de la cuenca principal.




Figura 0.10. Descarga del río para el cauce 63, partiendo del modelo de base.




Figura 0.11. Descarga del río en el cauce 63 para los escenarios futuros, aplicando los escenarios de cambio climático RCP4.5 y RCP8.5 (abajo).

La Figura 5.12 muestra cómo los días de estrés hídrico en la vegetación, varían según los dos escenarios de cambio climático, en la región de las tierras bajas, donde se localizan los viñedos de los propietarios interesados. Estos datos fueron producidos para ayudar a informar a estos propietarios sobre cómo la disponibilidad de agua puede cambiar en el futuro y de la misma forma, evaluar el impacto potencial que esto puede tener sobre las vides. El estrés hídrico se utiliza en viticultura para aumentar la calidad del fruto en las vides, sin embargo, si los cultivos tienen un déficit de riego, esto puede reducir significativamente el rendimiento de la producción (Jara, et al. 2017)




Figura 0.12. La cartografía muestra los días de estrés hídrico experimentados en los escenarios de cambio climático RCP4.5 (arriba) y RCP 8.5 (abajo). El estrés hídrico se calcula en función de la cantidad de absorción de agua por parte de la planta, durante el día y la cantidad máxima de transpiración.

Manejo de escenarios para informar la BBN

VCCB alienta a sus viñas asociadas a utilizar una serie de prácticas de manejo sostenible, para mejorar el abastecimiento de los servicios ecosistémicos de sus tierras y minimizar así, los impactos negativos que prácticas como el uso de fertilizantes y pesticidas, pueden tener sobre el medio ambiente (Barbosa y Godoy, 2014). De las prácticas de gestión sugeridas, con el modelo SWAT se evaluó la creación de las siguientes prácticas: franjas buffer o corredores biológicos, aplicación de fertilizantes orgánicos, aplicación de fertilizantes químicos, de herbicidas y de fungicidas, así como el pastoreo de ganado de invierno en los viñedos. Cada práctica de manejo se aplicó a los viñedos y se modeló tanto de manera individual como la combinación entre ellas, para ver como las diferentes estrategias de manejo podían influir en la calidad del agua. Para disminuir el tiempo de cálculo, debido a las restricciones de tiempo del proyecto, se reconstruyeron las HRU del modelo, aplicando valores umbrales para filtrar las HRU consideradas, que pudieran cubrir un mínimo del 2% de la subcuenta (2% tipo de suelo, 2% de uso del suelo), lo que generó 615 HRU, las cuales fueron utilizadas para ejecutar los escenarios. Los resultados del modelado de las diferentes combinaciones de manejo, se utilizaron para informar la Red de Creencia Bayesiana, que analiza la relación entre prácticas y la calidad del agua corriente abajo (ver Sección 6).

Franjas de amortiguamiento (Buffer)

Se realizaron escenarios de manejo para explorar cómo plantar franjas de amortiguamiento (buffer) de vegetación autóctona dentro de los viñedos, lo que podría hacer aumentar la absorción de nutrientes por parte de las plantas y ayudar así a mejorar la calidad del agua, tal y como se sugiere en la guía para los propietarios interesados de VCCB (Barbosa y Godoy, 2014). Como se detalla en la sección 3.4.3, esto se evaluó a través de la modificación de la capa de usos del suelo, para crear franjas buffer de 9 millones de árboles autóctonos dentro de los hábitats del viñedo. Para aplicar esto en el modelo SWAT, las HRU se reconstruyeron utilizando la capa modificada de usos del suelo, con los mismos parámetros que el modelo de base y se volvieron a ejecutar para simular el efecto de la creación de las bandas buffer.

Uso de fertilizantes y pesticidas

El uso de pesticidas y fertilizantes agrícolas puede tener un gran impacto en la calidad del agua y por lo tanto, supone una gran preocupación en países donde se aplica en grandes cantidades. En 2016, Chile utilizó 152,7 kg /ha de fertilizantes a base de nitrógeno y 5,69 kg /ha de pesticidas por área de cultivo anualmente, cantidades relativamente altas en comparación con su uso en otros países (FAO, 2017).

Los escenarios para la aplicación de pesticidas y fertilizantes se basaron en las medias nacionales de fertilizantes y pesticidas por área de cultivo en 2016 (FAO, 2017). Obtenido de los cuestionarios a los propietarios interesados, los fertilizantes utilizados en las prácticas de manejo actuales incluían fuentes orgánicas: compost, humus y algas y fuentes químicas: urea, nitrógeno, potasio y fertilizantes a base de fósforo. Los tipos de pesticidas utilizados por los interesados tendían a centrarse en los herbicidas como una forma de control de malezas y fungicidas para controlar la propagación del hongo o moho común en las vides. En los escenarios, '*Basta*', un herbicida, Glufosinato de amonio y un fungicida DCNA (*Dicloran*), '*Botran*', se aplicaron a los viñedos, pesticidas comúnmente utilizados en la producción de uva (Bayer, 2019, *Washington State University Extension*, 2019). Cada tratamiento se aplicó a los viñedos, una vez al año, después de la época de cosecha, con las cantidades resumidas en la Tabla 4.3. Para evaluar el impacto de la aplicación en los viñedos, el herbicida y el fungicida solo se aplicaron a las clases de suelo de viñedo dentro de la cuenca y los resultados se compararon con el modelo de base de referencia. Para informar a la BBN, el modelo se ejecutó en diferentes escenarios altos, moderados y bajos,

de cada tipo de fertilizante y pesticida aplicado a los campos. Para informar el nodo de concentración química de la BBN (consulte la sección 6), todas las combinaciones posibles de herbicida y fungicida se realizaron con y sin franjas amortiguadoras, que se aplicaron a los campos en los escenarios base de referencia y de cambio climático. Para informar el nodo de concentración de nutrientes, se realizaron combinaciones de fertilizante orgánico, fertilizante químico, herbicida, pastoreo de invierno por el ganado y franjas buffer de siembra, para generar productos que abarcan todas las combinaciones posibles de insumos en el BBN.

Para evaluar los tratamientos con fertilizantes, el porcentaje de fertilizante aplicado a cada viñedo que se filtró en el cauce de trabajo se calculó a nivel de HRU mediante la ecuación:

$$PFLeach = \frac{NO_3L_{(sim)} - NO_3L_{(base)}}{N_APP} \times 100$$

donde *PFLeach* es el porcentaje del fertilizante total de N que se aplicó y se lixivió por debajo del perfil del suelo, $NO_3L_{(sim)}$ es la cantidad de nitrato lixiviado por HRU en el escenario de gestión, $NO_3L_{(base)}$ es la cantidad de nitrato lixiviado por HRU en el escenario de referencia y N_APP es la cantidad de fertilizante nitrogenado aplicado en kg N / ha. La cantidad de nitrato lixiviado del perfil del suelo se calcula en SWAT utilizando numerosos algoritmos (descritos en Neitsch et al. 2011) y simultáneamente iguala las pérdidas de nitrato a través del agua superficial y el flujo lateral.

Tabla 5.3. Escenarios de gestión modelados con el modelo SWAT de referencia, repetidos anualmente.

Tipo de manejo	Compuesto químico Nombre	Id	Escenario	Cantidad aplicada (kg/ha)	Cantidad aplicada N/ha	Día	Mes
Fertilizante orgánico	Estiércol de ganado vacuno de carne		Bajo	625	25	10	4
			Moderado	1250	50	10	4
			Alto	2500	100	10	4
Fertilizante químico	Urea		Bajo	54.35	25	10	4
			Moderado	108.70	50	10	4
			Alto	217.40	100	10	4
Herbicida	Glufosinato de amonio		Bajo	1	-	10	4
			Moderado	3	-	10	4
			Alto	6	-	10	4
Pesticida/fungicida	DCNA (Dicloran)		Bajo	1	-	10	4
			Moderado	3	-	10	4
			Alto	6	-	10	4

Para estos escenarios, tal y como se muestra en la Figura 5.13, el cambio porcentual en la carga de nitrato en la corriente de agua (PNO_3Load) también se calculó a partir de la diferencia entre la carga de nitrato simulada y la transportada fuera del cauce:

$$PNO_3Load = (NO_3_OUT_{(sim)} - NO_3_{OUT_{(base)}}) / NO_3_{OUT_{(base)}} \times 100$$

Para evaluar los escenarios de pesticidas, el porcentaje de producto químico aplicado que entró en el cauce se calculó a nivel de sub-cuenca de la siguiente manera:

$$PPLeach = \frac{SOLPST_OUT_{(sim)}}{\sum PST_APP} \times 100$$

donde PPL_{each} es el porcentaje de la cantidad total de pesticida aplicada a la subcuenta, que se encuentra presente como pesticida disuelto en el cauce durante el periodo de tiempo, $SOLPST_OUT$ es la cantidad de pesticida soluble en ese cauce y $\sum PST_APP$ es la suma de la cantidad de pesticida aplicada en la subcuenta.




Figura 5.13. Cartografía de la cantidad de nitrógeno aplicado a los viñedos que se ha lixiviado por debajo del perfil del suelo y el cambio en la carga de nitrato dentro del cauce, en un escenario con alta cantidad de fertilizante orgánico.

Pastoreo de ganado en invierno

El pastoreo de invierno realizado por el ganado se sugiere como una medida de manejo sostenible dentro de los viñedos para mantener la biodiversidad, la fertilización del suelo y el control de malezas. Chile tiene una tasa de ganado baja en comparación con otros países sudamericanos, con 0.19 LSU (activo de ganado) por hectárea (FAO 2019). Para evaluar el impacto del manejo del ganado, las estimaciones de la deposición de estiércol, se calcularon a partir de las estadísticas de la FAO del estiércol total excretado por el ganado no lechero, dividido por el área de tierras agrícolas. Las estadísticas de Chile en 2006 se usaron en el escenario de presión moderada de ganado y las estadísticas de Nueva Zelanda se usaron en la simulación de ganado intensivo, donde la densidad de ganado se encuentra entre las más altas a nivel mundial, con 0.82 LSU / ha. Las estadísticas de cantidad de estiércol se calcularon para cada país usando las siguientes ecuaciones:

$$TOTH = \frac{\text{Total Cattle stock (LSU)}}{\text{LSU conversion coefficient}}$$

$$\text{Daily manure excreted (kg ha}^{-1} \text{ day}^{-1}) = \frac{TOTH}{\text{AREA(ha)}} \times \left(\frac{TOTM(\text{kg})}{TOTH} \times 365 \right)$$

donde $TOTH$ es el número total de cabezas de ganado y $TOTM$ es el abono total anual de N a nivel nacional.

Las estimaciones de consumo de materia seca se obtuvieron a partir de las directrices del IPCC basadas en las estimaciones mínimas y máximas de consumo de forraje de baja calidad (Dong et al. 2006). Se supuso que el pastoreo se daba en viñedos solo durante el

período de invierno en Chile (del 19 de junio al 10 de septiembre) (Ruiz-Albarrán et al. 2016). Los parámetros utilizados en las simulaciones se muestran en la Tabla 5.4, donde el día y el mes indican cuándo empezó el modelo a funcionar.

Tabla 0.4. Escenarios de pastoreo de ganado modelados con el modelo de referencia SWAT

Manejo	Escenario	Biomasa consumida (kg/ha/día)	Estiércol depositado (kg/ha/día)	Días de pastoreo	Día	Mes
Pastoreo de invierno	Moderado	3.5	0.94	83	19	6
	Intensivo	5.5	4.60	83	19	6

Modelando la Red de Creencias Bayesiana

Introducción

Para demostrar gráficamente cómo responde un ecosistema a diferentes prácticas de manejo y a otras variables ambientales, se adoptó la aproximación “Red de Creencias Bayesiana” (BBN), la cual relaciona las prácticas de manejo con los de los servicios ecosistémicos. Esto se desarrolló integrando una amplia diversidad de información: resultados de la modelización del servicio de ecosistémico en los diferentes escenarios de manejo y clima (secciones 3-5), revisiones bibliográficas y el conocimiento local de las viñas, obtenido de encuestas y talleres con los interesados del sector.

Se eligió la aproximación BBN ya que permite un enfoque flexible para integrar el conocimiento de los diferentes resultados del modelo. El BBN permite explicar la incertidumbre que surge de las relaciones entre las prácticas de manejo, los componentes ambientales y los servicios ecosistémicos. Esta incertidumbre se calcula a partir de una “tabla de probabilidades condicional” que permite a inferir el tipo de relación y las condiciones necesarias para que la relación exista. Una vez completada la BBN con las tablas de probabilidad condicional, se puede consultar al modelo para evaluar cómo los cambios en el manejo, afectaron la probabilidad de entrega de los servicios ecosistémicos considerados clave y de interés para los socios del proyecto.

Para comunicar la información resultante del BBN a los socios de una manera interactiva y fácil de usar, se desarrolló una aplicación *R-shiny*, utilizando el panel de control de *R-shiny*. Esto permite a los usuarios seleccionar prácticas de manejo y ver cómo estas prácticas afectan a los resultados de los servicios ecosistémicos de sus viñedos. Esto les permite explorar las relaciones entre el tipo de manejo y la entrega de los servicios ecosistémicos, y las diferentes compensaciones que podrían afectar a sus negocios a una escala relevante para sus operaciones y futuras decisiones de gestión.

Modelo Ecológico Conceptual

Las reuniones con el equipo de VCCB y la tesis de maestría de su estudiante Journet (2016) proporcionaron información clave para entender los diferentes enfoques de manejo realizados en los viñedos y los tipos de prácticas sostenibles que los propietarios de tierras podrían considerar. Esto, también proporcionó una idea de cómo los viticultores de la región ven las relaciones entre el manejo y los servicios ecosistémicos (Figura 6.1). A través de reuniones y talleres, las partes interesadas identificaron los siguientes servicios ecosistémicos como los más relevantes para su negocio:

- Control biológico natural de especies plagas
- Belleza escénica
- Reducción en la pérdida de suelo (superficial)
- Prevención de saturación de nutrientes naturales
- Prevención de incendios
- Suministro de agua y calidad del agua

Se desarrolló un modelo conceptual para integrar estos factores y proporcionar la estructura para el Grafo Acíclico Dirigido (GAD), que muestra esquemáticamente cómo las interacciones entre las prácticas y el medio ambiente causaron cambios en los aportes de los servicios ecosistémicos. (Figura 6.3)




Figura 0.1. Los cuadros reflejan las intervenciones en el manejo de los viñedos, que tienen interacciones directas e indirectas, con los ecosistemas naturales que rodean las áreas de producción. También se identifican los servicios ecosistémicos aportados por los ecosistemas autóctonos y la forma de interactuar de las áreas naturales y las gestionadas. Visiones comparadas de la bibliografía y los viticultores (Journet, 2016).

Desarrollo de Redes de Creencias Bayesianas

La BBN constituyen una metodología de modelado estadístico utilizada para inferir relaciones probables entre elementos, utilizando relaciones conocidas con intermediarios. En la Figura 6.2 se muestra un diagrama de BBN sencilla.




Figura 0.2. Ejemplo de un diagrama sencillo de BBN (Morgan et al. 2012)

Cada componente de la red se enumera como un "nodo" individual en el diagrama y la relación entre los nodos se denomina "borde". La dirección del borde indica la causalidad de la relación, donde un nodo "padre" puede causar un cambio en el estado del nodo "hijo". En la Figura 6.2, esto se ilustra por los nodos de estación del año y de elevación, que determinan la temperatura. Se desarrolló una red diferente asignando a cada nodo con posibles "estados", que clasifican los datos en bandas de valores (por ejemplo, alto, moderado o bajo). La BBN está conformada por modelos probabilísticos en los que cada estado posible de un nodo está determinado por una probabilidad de ocurrencia, agrupados en una sola tabla de probabilidad condicional (CPT). El estado probable de un nodo hijo estará determinado por los estados de los nodos padres. Usando esta lógica podemos inferir resultados probables dados los estados conocidos de los nodos padres y sus relaciones con los nodos hijos y podemos desarrollar redes más grandes, para informar problemas más complejos.

En este proyecto se utilizaron modelos BBN para ayudar a inferir las relaciones entre las prácticas de gestión y los servicios ecosistémicos. Las prácticas de gestión sugeridas por VCCB (Barbosa y Godoy, 2014) y los servicios clave del ecosistema destacados por los participantes fueron asignados a un nodo. Esto se desarrolló en un gráfico acíclico dirigido (DAG) que se muestra en la Figura 6.3, agregando nodos adicionales para componentes y bordes del entorno intermedio para denotar las relaciones entre los nodos, informados por las variables clave requeridas para los modelos de provisión de servicios del ecosistema utilizados en las secciones 3- 5 y la opinión de expertos de nosotros mismos y las partes interesadas. La información sobre los estados de cada nodo y sus tablas de probabilidad condicional se basaron en una combinación de datos medidos y modelados, revisiones de literatura y opiniones de expertos, detalladas en la sección 6.4. El paquete R 'bnlearn' (Scutari & Ness, 2019) se utilizó para construir y ajustar el BBN en R y luego se consultó con el paquete 'gRain' (Højsgaard, 2016).

Relaciones de Evidencia

Datos medidos y modelados

Las entradas de datos y los resultados modelados de los modelos de los servicios ecosistémicos descritos en las secciones 3-5 se utilizaron para informar las relaciones de BBN, que se resumen en la Tabla 5.1.

Tabla 6.1 Resumen de los nodos informados por las fuentes de datos de entrada utilizados en los modelos de provisión de servicios ecosistémicos o por los datos de salida producidos por los modelos, que se detallan en las Secciones 3-5.

Modelo	Descrito en la Sección	Escenarios modelados	BBN nodo informado	Entrada de datos medida o Resultado de datos modelado
Modelo INVEST del Coeficiente de Aporte de Sedimentos (SDR)	3	Escenarios de referencia de cambio climático, Cultivos de cobertura, Labranza, Franjas Buffer	Identificación del campo	Medido
			Cobertura del suelo del viñedo	Medido
			Temperatura del aire	Medido
			Precipitación	Medido
			Pendiente	Medido
			Cobertura del suelo	Medido
			Tipo de suelo	Medido
			Pendiente del viñedo	Medido
			Precipitación en la zona alta	Medido
			Erosionabilidad del suelo del viñedo	Modelado
			Erosionabilidad del suelo en la zona alta	Modelado
Modelo de susceptibilidad al fuego	4	Franjas Buffer	Identificación del campo	Medido
			Cobertura del suelo del viñedo	Medido
			Exposición al viento	Medido
			Precipitación	Medido
			Temperatura del aire	Medido
			Prevención de las quemaduras	Modelado
Modelo SWAT	5	Escenarios de cambios climáticos, Franjas Buffer, Fertilizantes orgánicos, Fertilizantes químicos, Fungicidas, Herbicidas, Pastoreo de invierno por bovinos	Identificación del campo	Medido
			Cobertura del suelo del viñedo	Medido
			Subcuenca	Medido
			Tipo de suelo	Medido
			Precipitación de la HRU	Medido
			Temperatura del aire	Medido
			Descarga del río	Modelado
			Entrada Artificial de nutrientes	Modelado
			Carga de nutrientes	Modelado
			Concentración de Nutrientes	Modelado
			Contaminantes Químicos	Modelado
			Concentración Química	Modelado

Debido a la falta de datos disponibles sobre las prácticas de manejo actuales en los viñedos de los socios interesados en el proyecto, se modelaron las condiciones sin considerar las prácticas que ya existen. Cada viñedo se analizó de forma aislada y se supuso que el manejo de un viñedo no afectaba el manejo de otro. Como este es un proyecto piloto, se diseñó para dar una indicación de los impactos potenciales que cierto manejo podría tener sobre el paisaje. Proporcionando más datos sobre el paisaje actual y trabajando más estrechamente con los socios, se podría refinar aún más el modelo y así proporcionar resultados más precisos.

Los datos se extrajeron de los modelos en tres escalas diferentes, como se describe a continuación:

- **Escala de viñedos** – los archivos shape de los límites de viñedos de los socios interesados fueron suministrados por VCCB y fueron utilizados para extraer información específica de cada campo individual, como la proporción de la cobertura del suelo, la pendiente y las variables climáticas.
- **Captación aguas arriba** – la captación de aguas arriba se definió como el área de flujo descendente que contribuye al movimiento del agua en el suelo hacia los hábitats de viñedos, dentro de los límites del terreno. Fue calculada a partir de las aplicaciones *TauDEM* (Análisis del terreno a partir de modelos digitales de altitud) Python, que utilizan datos de altitud para calcular las direcciones de flujo en el suelo y el movimiento del agua a través del paisaje. Al evaluar las rutas de flujo frente a los límites del terreno, las aplicaciones se pueden usar para calcular el área de contribución del flujo ascendente del terreno. La Figura 6.4 muestra el área calculada de contribución ascendente para un de viñedo uno de los socios del proyecto. Estos fueron recortados a una distancia de 50 m para representar el área contribuyente del suelo que ingresa a los viñedos, como se describe en la documentación del *Natural Capital Project's* (2019) *InVest Sediment Delivery Ratio*. El área de captación ascendente se usó para extraer datos del modelo de pérdida de suelo, para informar al nodo de la BBN "Supresión del enriquecimiento de nutrientes naturales"




Figura 0.4. Área de contribución ascendente en el viñedo de un socio del proyecto, calculada utilizando las funciones *TauDem*.

- **Nivel de subcuenca** – los datos se extrajeron a nivel de subcuenca para informar a los nodos relacionados con la calidad del agua, ya que los niveles de químicos y nutrientes en un tramo del río dependen del uso y manejo de la tierra dentro del área de drenaje de toda la subcuenca. Podrían obtenerse valores contribuyentes por viñedo y, por lo tanto, su contribución a la calidad del agua podría extrapolarse.

Revisión bibliográfica y talleres de trabajo con los socios del proyecto.

Para los nodos que no pudieron ser informados directamente por los modelos, se utilizó la información de los talleres con los socios y los estudios realizados por el equipo de investigación de VCCB.

La tesis de Journet (2016), investigación del grupo VCCB, exploró el impacto de las prácticas de manejo de viñedos sobre los servicios de ecosistémicos mediante entrevistas a los socios del proyecto en la región y revisiones bibliográficas. Esto proporcionó una visión general de las medidas sugeridas y promovidas por VCCB, además su impacto sobre la vegetación del viñedo. Junto con las imágenes satelitales de Google Earth y la opinión de expertos, pudimos informar ciertos nodos, como por ejemplo el nodo "Proporción de tipos de vegetación" y sus relaciones con el manejo del suelo. Este nodo simplifica la cobertura del suelo dentro de un predio, utilizando la clasificación de cobertura del suelo de alto nivel de la FAO (Di Gregorio, 2005). La tabla de conversión para estas clases se muestra en la Tabla 6.2. Esta simplificación reduce las dimensiones requeridas en los nodos hijos y obtiene las diferencias en la biomasa de la vegetación entre hábitats.

Journet (2016) destacó los cultivos de cobertura (o coberteras) y la siembra entre las viñas, como un método para mejorar la fertilidad del suelo y reducir la pérdida de la capa superficial del mismo, así como para fomentar la biodiversidad natural dentro del viñedo. Los cultivos de cobertura mencionados en la región fueron en su mayoría de especies exóticas, tales como guisantes, tréboles y mostazas, cultivos herbáceos, capturados en el BBN por el aumento de las proporciones del tipo de vegetación "pasto". El manejo del ganado también fue destacado por Journet como una práctica clave utilizada para enriquecer el suelo y controlar las plagas y enfermedades.

Tabla 6.2. Tabla de conversión de clases de cobertura del suelo, desde las clases de la cartografía de hábitats, a estados de tipo de vegetación.

Clases de cobertura del suelo en viñedos	Descubierto	Suelo desnudo	Pasto	Matorral	Árboles autóctonos	Árboles no autóctonos
Tierras Agrícolas	-	50%	5%	15%	30%	-
Llanura Aluvial	80%	10%	10%	-	-	-
Estepa Andina Central	-	34%	33%	33%	-	-
Pastos Cultivados	-	-	100%	-	-	-
Glaciares	100%	-	-	-	-	-
Lagos	100%	-	-	-	-	-
Bosque Autóctono	-	-	-	-	100%	-
Repoblaciones	-	50%	-	-	-	50%
Ríos	100%	-	-	-	-	-
Afloramientos Rocosos	80%	20%	-	-	-	-
Matorral	-	-	-	100%	-	-
Praderas Estacionales	-	-	100%	-	-	-
Superficies Nevadas	100%	-	-	-	-	-
Árboles y Matorrales	-	-	-	50%	50%	-
Urbano	100%	-	-	-	-	-
Viñedo	-	40%	10%	50%	-	-

De manera similar, el nodo "hábitat seminatural" se usó para simplificar la red, reduciendo los estados de la "Cobertura del suelo viñedo" al clasificar la información en tres categorías en lugar de dieciséis. Estos se denominaron en los siguientes tipos de hábitats: agricultura, seminatural y urbano, y se clasificaron utilizando la opinión de expertos junto con la clasificación que se muestra en la Tabla 6.3

Tabla 6.3. Tabla de conversión de clases de cobertura del suelo, desde las clases de la cartografía de hábitats a estados de hábitat seminaturales

Categorías	Clases de Hábitat
Agricultura	Tierras agrícolas, pastos cultivados, repoblaciones, pastizales estacionales y viñedos
Seminatural	Llanuras aluviales, Estepas centrales andinas, Glaciares, Lagos, Bosque autóctono, Ríos, Afloramientos rocosos, Matorral, Superficies nevadas y Árboles y Matorral.
Urbano	Urbano

La biodiversidad dentro de los viñedos se ha explorado en varios estudios, y se ha demostrado que aumenta con la proximidad al hábitat natural, de forma opuesta a lo que sucede con los terrenos alterados, como los urbanos o agrícolas (Grashof-Bokdam y van Langevelde, 2005, Márquez-García et al. 2018). La biodiversidad es clave para las funciones del ecosistema dentro de un viñedo, como el mantenimiento de la diversidad de hongos y el control de plagas dentro de los campos. Es clave para fomentar la diversidad de levaduras naturales y especies de hongos como parte de la característica de "terroir" en los vinos biodinámicos en crecimiento. La diversidad de hongos y el mantenimiento de un correcto equilibrio de las especies de levaduras en el medio ambiente es importante para el

sabor y la calidad del vino producido y se ha relacionado con la diversidad de plantas y la distancia de las vides al hábitat seminatural circundante (Castañeda, et al. 2018).

Las especies de plagas son preocupaciones claves para los viñedos, los socios del proyecto identifican a los conejos, las falsas arañas rojas de vid, el oídio y los hongos de madera de la vid, como especies de plagas específicas en la región. La guía de VCCB (Barbosa y Godoy, 2014) destaca cómo la creación de corredores ecológicos, mediante el uso de franjas buffer y cultivos de cobertura, puede ayudar a reducir la presión de las plagas al favorecer a los depredadores naturales, mientras que los monocultivos de viñedos son más susceptibles a las plagas y enfermedades.

También se ha considerado el manejo del ganado como una ayuda en la prevención de plagas, además de la prevención de incendios; a medida que se mantienen los pastos más cortos, se reduce el potencial de ignición y la disponibilidad de combustible (Journet 2016, Márquez-García 2018). La aplicación de pesticidas y fertilizantes ha demostrado tener un impacto negativo en la biodiversidad de los viñedos, especialmente cuando el uso es excesivo, así como también el impacto sobre las aguas río abajo, en lagos y arroyos (Puig-Montserrat, et al. 2017). Otro beneficio de fomentar la biodiversidad en los viñedos es el valor estético que las especies agregan al paisaje, aumentando los valores asociados con la identidad de la comunidad y el bienestar humano (Tribot, et al. 2018).

Construcción de las Tablas de Probabilidad Condicional (CPTs)

Los datos recopilados para cada nodo detallados en la sección 6.4.1 se utilizaron junto con los dos nodos de simplificación "proporción de tipos de vegetación" y "hábitats seminaturales" (descrito en la sección 6.4.2) para crear datos de capacitación para cuatro de los servicios ecosistémicos: reducción de la pérdida de la capa superficial del suelo, pérdida de capacidad de enriquecimiento del suelo con nutrientes naturales, prevención de incendios y calidad del agua. Estos datos de aprendizaje se utilizaron para ajustar secciones más pequeñas de la BBN en la Figura 6.3. Esto se fragmentó para reducir la potencia de procesamiento y el tiempo de cálculo. Estas BBNs más pequeñas generaron las tablas de probabilidad condicional para la mayoría de los nodos, informando sus relaciones basadas en los datos de simulación. El CPT para el nodo de servicio final para la calidad del agua se calculó como una combinación de los nodos de concentración de nutrientes y químicos, donde ambos tenían un estado alto, la calidad del agua se calificó como pobre. Los CPT de nodos restantes para la biodiversidad, la diversidad de hongos, el atractivo estético y el control natural de plagas se equipararon utilizando el conocimiento de las revisiones bibliográficas detalladas en la sección 6.4.2 y la opinión de expertos. Todos los CPT se recopilaron para crear una Red de Creencias Bayesiana mayor, vinculando todos los servicios ecosistémicos modelados con las decisiones de gestión.

Aplicación de la BBN

Los datos extraídos fueron cotejados y la BBN se ajustó con las tablas de probabilidad condicional informadas. Esto permitió que se consultara en los diferentes escenarios con funciones en el paquete "*bnlearn*".




Figura 0.5. Diagrama de la BBN ajustada, que muestra las tablas de probabilidad condicional en gráficos de barras para cada nodo.

Para hacer esto más accesible a los socios del proyecto, se desarrolló una aplicación R shiny que utiliza un tablero R shiny para permitir a los usuarios ver los resultados de las decisiones de manejo en una pantalla fácil de usar (consulte la Figura 6.6-6.8). La aplicación **Viticultura e Integración De Servicios ecosistémicos**. (VIDES) fue desarrollada para mostrar viñas manejadas por los socios, mostrando un mapa con la ubicación de sus viñas, en relación con el paisaje circundante, utilizando representaciones 3D de sus predios y áreas circundantes.

La aplicación consta de tres pestañas que se muestran en las capturas de pantalla en la Figura 6.6-6.9. La página de inicio de la aplicación (Figura 6.8) muestra una imagen en 3D del valle de Colchagua, desarrollada utilizando el paquete R 'rayshader' (Morgan-Wall 2019). En esta página, el usuario debe seleccionar su viña y predio. Esta información luego se alimenta en la segunda pestaña "*Manejo*", que permite a los socios ver y consultar los datos de su terreno seleccionado, pudiendo ver la entrega de servicios ecosistémicos en una gráfica de barras de color (Figura 6.7). Aquí, pueden seleccionar diferentes opciones de manejo y escenarios de cambio climático, y para ver cómo la combinación de opciones cambia los servicios ecosistémicos y sus probabilidades relativas de ser "Bueno", "Moderado" o "Pobre". Esto se visualiza mediante cambios proporcionales en el gráfico de barras, donde el estado que tiene el área más grande representa el estado más probable del servicio ecosistémico. Esta gráfica es interactiva, lo que permite a los usuarios desplazarse sobre áreas del gráfico para ver valores de probabilidad, así como mostrar y ocultar las entradas de leyenda haciendo clic en ellos. También hay una opción para descargar un archivo .csv con los datos del gráfico y restablecer todas las opciones de administración a las predeterminadas. La pestaña final "*Diagrama*" muestra el BBN GAD, que muestra al usuario los mecanismos por los cuales cada escenario afecta a los servicios ecosistémicos y les permite visualizar la BBN subyacente.




Figura 0.5. Página de inicio de la aplicación




Figura 0.6. Ejemplo de gráfica emitida por la aplicación con las opciones, por defecto, de manejo y cambio climático.




Figura 0.8. Visualización del GAD de la BBN.

Conclusiones y próximos pasos

El presente proyecto combina el conocimiento de la industria del vino con las ciencias ecosistémicas y busca esclarecer y cuantificar las interacciones entre el manejo del territorio, los factores bióticos y abióticos, y el efecto en los servicios ecosistémicos críticos para el

negocio. El proyecto se ejecutó durante cinco meses, y dentro de ese tiempo se desarrollaron las iteraciones iniciales, mostrando cómo se pueden establecer modelos en línea con los requisitos de los usuarios, proporcionando herramientas que ayudan a incorporar los datos ambientales en los procesos de toma de decisiones. El uso de la Red de Creencias Bayesiana (BBN) ayuda a aclarar los equilibrios asociados en la planificación y gestión del uso de la tierra.

Pasos potenciales para la mejora del modelo

Trabajar más estrechamente con los viñedos para recopilar y aplicar datos locales y obtener un conocimiento más detallado de los vínculos entre las decisiones de manejo, las respuestas de los ecosistemas, las variables abióticas y los impactos, mejoraría la BBN y proporcionaría información más detallada, permitiendo refinar los modelos para su implementación más específica.

Una mejor comprensión de las intervenciones actuales dentro de cada viñedo proporcionaría un mejor entendimiento de las interacciones entre diferentes actividades; identificando así oportunidades potenciales para el manejo cooperativo, para maximizar los servicios ecosistémicos y minimizar los impactos ambientales.

El uso de imágenes satelitales de alta resolución mejoraría el mapeo de hábitats, al igual que la realización de una validación adicional del terreno en un área más amplia, lo que mejoraría la precisión de la clasificación de los diferentes usos del suelo y hábitats regionales; ayudando así a identificar más elementos que brinden servicios ecosistémicos, mejorando el modelado a nivel local y de paisaje, y detectando cambios a lo largo del tiempo.

Debido a la falta de datos locales sobre el suelo, se ha utilizado una capa de datos de suelos de baja resolución de la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO), que no refleja con precisión cómo la composición del suelo puede variar espacialmente en todo el paisaje. Los datos del suelo podrían mejorarse con la provisión de datos locales o de muestreo, especialmente en términos de características biofísicas y tasas de pérdida de suelo.

Las características y medidas de los cultivos locales no estaban disponibles y se compararon con el tipo de cultivo más cercano en las bases de datos de cultivos de los modelos, que se basan en los tipos de cultivos de EE.UU. La información sobre las características de los cultivos locales mejoraría la precisión de los factores de evaluación, como pueden ser la demanda de agua, el estrés hídrico y la permeabilidad del suelo.

Con más tiempo, un análisis de sensibilidad podría evaluar la influencia relativa que las capas de datos tienen en las respuestas en los modelos de la Herramienta de Evaluación de Suelos y Aguas (SWAT).

Los datos de la estación meteorológica local del valle de Colchagua solo estaban disponibles como datos puntuales y en intervalos de tiempo inconsistentes. Sería valioso explorar cómo podrían recopilarse mejor los datos meteorológicos locales para mejorar la precisión local de los modelos.

Debido a las limitaciones de tiempo y recursos, no fue posible cubrir todos los servicios ecosistémicos identificados como "importantes" por los socios. El trabajo futuro podría explorar el biocontrol natural de las especies de plagas, e incluso los valores culturales asociados con los viñedos y el paisaje.

La biodiversidad es de suma importancia para el territorio de la región vitivinícola. La investigación de organismos como las levaduras silvestres y las comunidades microbianas

del suelo podrían explorarse, en relación con el manejo del suelo y la planificación espacial, para mantener o restaurar características particulares del paisaje.

Los modelos y las BBN se pueden utilizar para informar a los esquemas de monitoreo, evaluar los resultados en términos reales (por ejemplo, si la densidad reducida de la población de ganado afecta a los suelos o la calidad del agua), también existe la posibilidad de explorar cómo las compañías pueden cuantificar y utilizar este tipo de información para mejorar e informar sobre el desempeño ambiental.

Los enfoques desarrollados pueden adaptarse a otros escenarios, servicios ecosistémicos y uso de la tierra. La principal condición es la disponibilidad de datos.

Referencias

- 2W2E – Weather Water Energy Ecosystem. 2019. Climate Change Data for SWAT model (CRU). Available from: <https://www.2w2e.com/home/CRU> [Accessed 04/02/2019].
- ADAS. 2007. Nitrates in water – the current status in England. ADAS report to Defra – supporting paper D1 for the consultation on implementation of the Nitrates Directive in England. July 2007.
- Abatzoglou, J.T., S.Z. Dobrowski, S.A. Parks, K.C. Hegewisch, 2018, Terraclimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958-2015, Scientific Data,
- Alcamo, J., Flörke, M. & Märker, M. 2007. Future long-term changes in global water resources driven by socio-economic and climatic changes. *Hydrological Sciences Journal* 52(2): 247-275. DOI: 10.1623/hysj.52.2.247
- Alexander, M.E., Lawson, B.D., Stocks, B.J. & van Wagner, C.E. 1984. User Guide to the Canadian Forest Fire Behaviour Prediction System: Rate of Spread Relationships; (Interim Edition). Environment Canada, Canadian Forestry Service, Northern Forest Research Centre, Edmonton, Alberta
- Allen, R.G., Pereira, L.S., Raes, D. & Smith, M. 1998. Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56: Chapter 3 Meteorological data. Available from: <http://www.fao.org/3/X0490E/x0490e07.htm> [Accessed 20/01/2019].
- Almendinger, J. 2016. Google Groups. ArcSWAT topic: How to set up warm-up period in SWAT. Available from: <https://groups.google.com/forum/#!msg/arcsWat/c19Li5ATNvY/1QM8gnvZAwAJ> [Accessed 14/02/2019]
- Alvarez-Garretón, C., Mendoza, P.A., Boisier, J.P., Addor, N., Galleguillos, M., Zambrano-Bigiarini, M., Lara, A. Puelma, C., Cortes, G., Garreaud, R, McPhee, J. & Ayala, A. 2018. The CAMELS-CL dataset: catchment attributes and meteorology for large sample studies – Chile dataset. *Hydrology and Earth System Sciences* 22: 5817-5846. <https://doi.org/10.5194/hess-22-5817-2018>
- Anderson, B., Peng, R. & Ferreri, J. 2016. Package ‘weathermetrics’ : Functions to Convert Between Weather Metrics. Version 1.2.2. Available from: <https://cran.r-project.org/web/packages/weathermetrics/weathermetrics.pdf> [Accessed 29/01/2019].

- Arnold, J.G., Kiniry, J.R., Srinivasan, R., Williams, J.R., Haney, E.B., Neitsch, S.L. 2012. SWAT Water Assessment Tool: Input/Output Documentation Version 2012. Texas Water Resources Institute TR-439. Available from: <https://swat.tamu.edu/media/69296/swat-io-documentation-2012.pdf> [Accessed 07/01/2019].
- Barbet-Massin, M., Jiguet, F., Albert, C.H. & Thuiller, W. 2012. Selecting pseudo-absences for species distribution models: how, where and how many? *Methods in Ecology and Evolution* 3: 327-338.
- Barbosa, O. & Godoy, K. 2014. Conservación biológica en viñedos: conceptos claves y actividades prácticas. Programa Vino Cambio Climático y Biodiversidad Chile. *Universidad Austral de Chile* 2014
- Bayer (Pty) Ltd. 2019. Basta®. Available from: <https://www.cropscience.bayer.co.za/en/Products/Herbicides/Basta.aspx> [Accessed:11/03/2019].
- Boisier, J.P., Alvarez-Garreton, C., Cordero, R.P., Damiani, A., Gallardo, L., Garreaud, R.D., Lambert, F., Ramallo, C., Rojas, M., Rondanelli, R. 2018. Anthropogenic drying in central-southern Chile evidenced by long-term observations and climate model simulations. *Elementa Science of the Anthropocene* 6: 74. DOI: <https://doi.org/10.1525/elementa.328>
- Braithwaite, R. J. 2008. Temperature and Precipitation Climate at the Equilibrium-Line Altitude of Glaciers Expressed by the Degree-Day Factor for Melting Snow. *Journal of Glaciology* 54 (186): 437-444.
- Bravo, C., Loriaux, T., Rivera, A. & Brock, B.W. 2017. Assessing glacier melt contribution to streamflow at Universidad Glacier, central Andes of Chile. *Hydrology and Earth System Sciences* 21(7):3249-3266.
- Castañeda, L.E., Miura, T., Sánchez, R. & Barbosa, O. 2018. Effects of agricultural management on phyllosphere fungal diversity in vineyards and the association with adjacent native forests. *Peer J* 6: e5715; DOI 10.7717/peerj.5715
- CONAF, 2018. Estadísticas históricas. Available from: <http://www.conaf.cl/incendios-forestales/incendios-forestales-en-chile/estadisticas-historicas/> [Accessed 11/02/2019].
- Copernicus Global Land Service 2019. Fraction of green Vegetation Cover. Available from: <https://land.copernicus.eu/global/products/fcover> [Accessed 10/01/2019].
- Di Gregorio, A. 2005. Land Cover Classification System: Classification concepts and user manual. Software version (2). Food and Agriculture Organization of the United Nations. Available from: <http://www.fao.org/3/y7220e/y7220e00.htm#Contents> [Accessed 28/02/19].
- Didan, K, A Huete & MODAPS SIPS. 2015. MOD13A3 MODIS/Terra Vegetation Indices Monthly L3 Global 1km SIN Grid. NASA LP DAAC. <http://doi.org/10.5067/MODIS/MOD13A3.006>
- Dile, Y., Srinivasan, R. & George, C. 2018. QGIS Interface for SWAT(QSWAT) Version 1.7 October 2018 User Manual. Available from: https://swat.tamu.edu/media/116095/qswat-manual_v17.pdf [Accessed 06/01/2019]
- Dirección General de Aguas (DAG), Ministerio de Obras Públicas. 2019. Información Oficial Hidrometeorológica y de Calidad de Aguas en Línea. Available from: <http://snia.dga.cl/BNAConsultas/reportes> 2015-2018 [Accessed 13/01/2019].

- Duane, A, Piqué, M., Castelnou, M. & Brotons, L. 2015. Predictive modelling of fire occurrences from different fire spread patterns in Mediterranean landscapes. *International Journal of Wildland Fire* 24: 407-418
- FAO 2006. Guidelines for soil description, Fourth edition. Food and Agriculture Organization of the United Nations, Rome. Available from: <http://www.fao.org/3/a0541e/a0541e.pdf> [Accessed 03/01/2019]
- FAO/UNESCO. 2003. The Digital Soil Map of the World. Available from: http://www.waterbase.org/data/Global_Soil_Data/readme.pdf [Accessed 06/01/2019].
- Fick, S.E. and R.J. Hijmans, 2017. Worldclim 2: New 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*.
- Food and Agriculture Organization of the United Nations (FAO). 2017. FAOSTAT: Fertilizers. Available from: <http://www.fao.org/faostat/en/?#data/EF> [Accessed 25/02/2019].
- Gassman, P.M., Reyes, M.R., Green, C.H. & Arnold, J.G. 2007. The Soil and Water Assessment Tool: Historical development, applications and future research directions. *American Society of Agricultural and Biological Engineers*. 50(4): 1211-1250.
- Gharibdousti, S.R., Kharel, G. & Stoecker, A. 2018. Modelling the impacts of agricultural best management practices on runoff, sediment, and crop yield in an agriculture-pasture intensive watershed. *Peer J Preprints* (Not peer-reviewed). Available from: <https://doi.org/10.7287/peerj.preprints.27452v1> [Accessed 06/01/2019].
- Giglio, L., Justice, C., Boschetti, L. & Roy, D. 2015. MCD64A1 MODIS/Terra+Aqua Burned Area Monthly L3 Global 500 m SIN Grid V006. 2015, distributed by NASA EOSDIS Land Processes DAAC. Available from: <https://doi.org/10.5067/MODIS/MCD64A1.006> [Accessed 06/01/2019].
- GLIMS. 2018. Global Land Ice Measurements from Space glacier database. Compiled and made available by the international GLIMS community and the National Snow and Ice Data Center, Boulder CO, U.S.A. DOI:10.7265/N5V98602
- Gómez-González, S., González, M.E., Paula, S., Díaz-Hormazábal, I., Lara, A. & Delgado-Baquerizo, M. 2019. Temperature and agriculture are largely associated with fire activity in Central Chile across different temporal periods. *Forest Ecology and Management* 433: 535-543.
- Grashof-Bokdam, C. J. & van Langevelde, F. 2005. Green veining: landscape determinants of biodiversity in European agricultural landscapes. *Landscape Ecology* 20: 417-439.
- Hajek, E.R. & Gutiérrez, J.R. Growing seasons in Chile: Observation and prediction. *International Journal of Biometeorology* 23(4): 311-329.
- Harris, I., Jones, P.D., Osborn, T.J., Lister, D.H., 2013. Updated high-resolution grids of monthly climatic observations - the CRU TS3.10 Dataset. *International Journal of Climatology* 34(3): 623e642
- Hijmans, R.J. & Elith, J. 2019. Spatial Distribution Models. Available from: <https://rspatial.org/sdm/SDM.pdf> [Accessed 07/01/2019].

- Hijmans, R.J., Phillips, S., Leathwick, J. & Elith, J. 2017. dismo: Species Distribution Modelling. R package version 1.1-4. Available from: <https://CRAN.Rproject.org/package=dismo> [Accessed 07/01/2019].
- Hijmans, R.J., S.E. Cameron, J.L. Parra, P.G. Jones and A. Jarvis, 2005. Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology* 25: 1965-1978.
- Højsgaard, S. 2016. Package 'gRain': Graphical Independence Networks. Version 1.3-0. Available from: <https://cran.r-project.org/web/packages/gRain/gRain.pdf> [Accessed 03/01/2019].
- ISRIC. 2019. Harmonized continental SOTER-derived database (SOTWIS). Available from: <https://www.isric.org/index.php/projects/harmonized-continental-soter-derived-database-sotwis> [Accessed 03/01/2019].
- Jara, J., Holzapfel, E.A., Billib, M., Arumi, J.L., Lagos, O., Rivera, D. 2017. Effect of water application on wine quality and yield in 'Carménère' under the presence of a shallow water table in Central Chile. *Chilean Journal of agricultural research* 77(2): <http://dx.doi.org/10.4067/S0718-58392017000200171>
- Johnston, J.M., Wheatley, M.J., Wooster, M.J., Paugam, R., Davies, G.M. & DeBoer, K.A. 2018. Flame-front rate of spread estimates for moderate scale experimental fires are strongly influenced by measurement approach. *Fire* 1: 16.
- Joint Nature Conservation Committee. 2018. JNCCsdms: Functions to Generate Species Distribution Models using the JNCC SDM Framework. R package version 0.1.0. <https://github.com/jncc/sdms>
- Jones, T., Wicks, D., Agass, S., Bunting, P. 2017. Developing standards and automated production for Sentinel-2 Analysis Ready Data. Evidence Project SD1707
- Journet, G. 2016. Viticulture and ecosystem services: from myths to reality with Chilean vine growers. Master's Thesis 2016 30 ECTS. Department of Plant Sciences, Norges Milje-of biovitenskapelige universitet.
- Kilcoyne, A.M. Alexander, R., Cox, P. & Brownnett, J. 2017. Living Maps: Satellite based Habitat Classification. Evidence Project SD1705
- Lehner, B., Grill G. 2013. Global river hydrography and network routing: baseline data and new approaches to study the world's large river systems. *Hydrological Processes*, 27(15): 2171–2186.
- Márquez-García, M., Jacobson, S.K., Barbosa, O. 2018. Wine with a Bouquet of Biodiversity: Assessing Agricultural Adoption of Conservation Practices in Chile. *Environmental Conservation* page 1 of 9. doi:10.1017/S0376892918000206
- Martínez E. 2014. Proyecto Monitoreo de cambios, corrección cartográfica y actualización del catastro de bosque native en las regions de valparaíso, Metropolitana y Libertador Bernardo O'Higgins. Ciren Informe Técnico Final Diciembre 2013.
- Mattiuzzi, M. & Detsch, F. 2018. MODIS: Acquisition and Processing of MODIS Products. R package version 1.1.4. Available from: <https://CRAN.R-project.org/package=MODIS> [Accessed 07/01/2019].

- McWethy, D.B., Pauchard, A., García, R.A., Holz, A., Veblen, T.T., Stahl, J. & Currey, B. 2018. Landscape drivers of recent fire activity (2001-2017) in south- central Chile. *PLoS ONE* 13: e0201195.
- Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., Chang, C.C., Lin, C.C. 2019. Package 'e1071' Version 1.7-0.1: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. Available from: <https://cran.r-project.org/web/packages/e1071/e1071.pdf> [Accessed 14/02/2019].
- Minchella, A. 2018. JNCC Sentinel-1 Backscatter Data Provision Service. SAR processing Methodology
- Moeys, J. 2018. soiltexture: Functions for Soil Texture Plot, Classification and Transformation. R package. Available from: <https://cran.r-project.org/web/packages/soiltexture/index.html> [Accessed 11/02/2019].
- Morgan, J.D., Hutchins, M.W., Fox, J. & Rogers, K.R. 2012. A Methodological Framework focused on integrating GIS and BBN Data for Probabilistic Map Algebra Analysis. 7th *International Conference, GIScience, Columnus, OH*.
- Morgan-Wall, T. 2019. Package 'rayshader': Create and Visualize Hillshaded Maps from Elevation Matrices. Version 0.10.1. Available from: <https://cran.r-project.org/web/packages/rayshader/rayshader.pdf> [Accessed 10/03/2019].
- National Center for Atmospheric Research Staff (Eds)(NCEP-CFSR). 2017. The Climate Data Guide: Climate Forecast System Reanalysis (CFSR). Available from: <https://climatedataguide.ucar.edu/climate-data/climate-forecast-system-reanalysis-cfsr> [Accessed 14/01/2019].
- Neitsch, S.L., Arnold, J.G., Kiniry, J.R., Williams, J.R., King, K.W. 2002. Soil and water assessment tool theoretical documentation. Version 2000. Texas Water Resources Institute, College Station, Texas. TWRI Report TR-191. Available from: <https://swat.tamu.edu/media/1290/swat2000theory.pdf> [Accessed 11/02/2019].
- Neitsch, S.L., Arnold, J.G., Kiniry, J.R., Williams, J.R. 2011. Soil and Water Assessment Tool Theoretical Documentation Version 2009. *Texas Water Resources Institute Technical Report* No.406. September 2011.
- OMAFRA Factsheet. 2015. Universal Soil Loss Equation (USLE). Available at: <http://www.omafra.gov.on.ca/english/engineer/facts/12-051.htm> [Accessed 03/01/2019].
- Omani, N. 2014. Impact Assessment of Climate Change on Glaciers and Runoff Using SWAT. A Dissertation. Doctor of Philosophy: Biological and Agricultural Engineering. Graduate and Professional Studies of Texas A&M University.
- Omani, N. Srinivasan, R., Karthikeyan, R. & Smith, P.K. 2017. Hydrological modelling of highly glacierized basins (Andes, Alps, and Central Asia). *Water* 9 (111): doi:10.3390/w9020111.
- Palmer, W.C. 1965. Meteorological Drought. Research Paper No. 45. Office of Climatology, US Weather Bureau, Washington DC.
- Panagos, P., Borrelli, P., Meusburger, K., Alewell, C., Lugato, E. & Montanarella, L. 2015. Estimating the soil erosion cover-management factor at the European scale. *Land Use Policy* 48: 38-50.

- Puig-Montserrat, X. Stefanescu, C., Torre, I., Palat, J., Fábregas, E., Dantart, J., Arrizabalaga, A. & Flaquer, C. 2017. Effects of organic and conventional crop management on vineyard biodiversity Agriculture, Ecosystems and Environment. *Agriculture, Ecosystems and Environment* 243: 19–26.
- QGIS Development Team. 2019. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Available from: <http://qgis.osgeo.org>
- R Core Team. 2018. R: A Language and Environment for Statistical Computing. Vienna, Austria. Available from: <https://www.R-project.org/>
- Renard, K.G. & Freimund, J.R. 1994. Using monthly precipitation data to estimate the R-factor in the revised USLE. *Journal of Hydrology* 157: 287-306 Available from: <https://eurekamag.com/pdf/002/002728247.pdf> [Accessed 14/01/2019].
- Renard, K.G., Foster, G.R., Weesies, G.A., McCool, D.K., & Yoder, D.C. 1997. Predicting soil erosion by water: a guide to conservation planning with the Revised Universal Soil Loss Equation (RUSLE). United States Department of Agriculture, Agricultural Research Service. Agriculture Handbook Number 703. Available from: https://www.ars.usda.gov/ARSUserFiles/64080530/rusle/ah_703.pdf [Accessed 10/01/2019].
- Ruiz-Albarrán, M., Balocchi, O., Wittwer, F. & Pulido, R. 2016. Milk production, grazing behaviour and nutritional status of dairy cows grazing two herbage allowances during winter. *Chilean Journal of Agricultural Research* 76(1): <http://dx.doi.org/10.4067/S0718-58392016000100005>
- Scutari, M & Ness, R. 2019. Package ‘bnlearn’: Bayesian Network Structure Learning, Parameter Learning and Inference. Version 4.4.1. Available from: <https://cran.r-project.org/web/packages/bnlearn/bnlearn.pdf> [Accessed 04/01/2019].
- Srinivasan, R. 2013. Google Group: SWAT-user: Custom Weather Generator: RAINHHMX (Maximum 0.5 h rainfall) Problem, Available from: <https://groups.google.com/forum/#!topic/swatuser/kpZMCke3BvU> [Accessed 4/02/2019].
- Stanford University. 2019. Integrated Valuation of Ecosystem Services and Tradeoffs. Available from: <https://naturalcapitalproject.stanford.edu/invest/> [Accessed 14/01/2019].
- Stehr, A. & Aguayo, M. 2017. Snow cover dynamics in Andean watersheds of Chile (32.0-39.5 S) during the years 2000-2016. *Hydrology and Earth System Sciences* 21:5111-5126.
- Stehr, A., Debels, P., Romero, F. & Alcayaga, H. 2008. Hydrological modelling with SWAT under conditions of limited data availability: evaluation of results from a Chilean case study. *Hydrological Sciences- Journal – des Sciences Hydrologiques* 53(3):588-600
- Strauch, M. & Volk, M. 2013. SWAT plant growth modification for improved modelling of perennial vegetation in the tropics. *Ecological Modelling* 269: 98-112.
- SWAT. 2019. Global Weather Data for SWAT. Available from: <https://globalweather.tamu.edu/> [Accessed: 25/2/2019]
- The Natural Capital Project. 2019. InVest Sediment Deliver Ratio (SDR) model documentation. Available from: <http://releases.naturalcapitalproject.org/invest-userguide/latest/sdr.html> [Accessed 2/1/19]

- Tribot, A.S., Deter, J. & Mouquet, N. 2018. Integrating the aesthetic value of landscapes and biological diversity. *Proc Biol Sci.* 285(1886):2018.0971.
- Trimaille, E. 2019. QuickOSM QGIS Plugin Version 1.4.15. Available from: <https://plugins.qgis.org/plugins/QuickOSM/> [Accessed 4/2/2019]
- UK Technical Advisory Group (UKTAG) on the Water Framework Directive (WFD). 2008. UK Environmental Standards and Conditions (Phase 1) Final report April 2008 (SR1 – 2006). Available from: http://www.wfduk.org/sites/default/files/Media/Environmental%20standards/Environmental%20standards%20phase%201_Finalv2_010408.pdf [Accessed 09/04/2019]
- UNU-INWEH. 2019. WaterBase: World Data Grids. Available from: http://www.waterbase.org/download_data.html. [Accessed: 14.12.2018]
- Urrutia-Jalabert, R., González, M.E., González-Reyes, Á., Lara, A. & Garreaud, R. 2018. Climate variability and forest fires in central and south-central Chile. *Ecosphere* 9: e02171.
- Vaghefi, S.A., Abbaspour, N., Kamali, B., Abbaspour, K.C. 2017. A toolkit for climate change analysis and pattern recognition for extreme weather conditions – Case study: California-Baja California Peninsula. *Environmental Modelling & Software*. 96: 181-198. ISSN 1364-8152. <https://doi.org/10.1016/j.envsoft.2017.06.033>.
- Valdés-Pineda, R., Pizarro, R., García-Chevesich, P., Valdés, J.B., Olivares, C., Vera, M., Balocchi, F., Pérez, F., Vallejos, C., Fuentes, R., Abarza, A. & Helwig, B. 2014. Water governance in Chile: Availability, management and climate change. *Journal of Hydrology* 519: 2538-2567.
- Van Vuuren, D.P., Edmonds, J., Kainuma, M., Riahi, K., Thomson, A., Hibbard, K., Hurtt, G.C., Kram, T., Krey, V., Lamarque, J.F., Masui, T., Meinshausen, M., Nakicenovic, N., Smith, S.J., Rose, S.K. 2011. The representative concentration pathways: an overview. *Climate Change* 109: 5-31. DOI 10.1007/s10584-011-0148-z.
- Viñas de Colchagua A. G. 2012. Colchagua Vina & Ruta: Colchagua Wineries. <http://www.colchaguavalley.cl/en/> [Accessed 21/05/2019].
- Washington State University Extension. 2019. Pest Management Guide for Grapes in Washington—2019 EB0762. Available from: http://cru.cahe.wsu.edu/CEPublications/-EB0762/EB0762_19.pdf [Accessed 11/03/2019].
- Williams, J.R. 1975. Sediment routing for agricultural watersheds. *Journal of the American Water Resources Association* 11(5): 965-975.
- Wischmeier, W.H. & Smith, D.D. 1978. Predicting rainfall losses: A guide to conservation planning. USDA Agricultural Handbook No 537. U.S. Gov. Print. Office, Washington, D.C.
- WorldPop. 2016. Chile 100 m Population. Alpha version 2010, 2015 and 2010 estimates of numbers of people per pixel (ppp) and people per hectare (pph), with national totals adjusted to match UN population division estimates (<http://esa.un.org/wpp/>) and remaining unadjusted. www.worldpop.org, School of Geography and Environmental Science, University of Southampton
- World Wildlife Fund (WWF). 2019. HydroSHEDS Available from: <https://www.worldwildlife.org/pages/hydrosheds>. [Accessed:12.12.2018]

Apéndice 1 – Establecimiento del Metodo del Mapa Vivo (*Living Maps Method* (LMM)) en el valle de Colchagua

Conjunto de datos

En este apéndice se realiza un resumen de cada uno de los conjuntos de datos utilizados para la clasificación de hábitats. Todos los datos fueron georeferenciados a la proyección del mapa más adecuada para la región, que es WGS 84 / UTM zona 19S (EPSG: 32719) y se volvieron a muestrear a 10 m, a menos que se especifique lo contrario.

Sentinel-1

Sentinel-1 es una misión radar en órbita polar, tanto diurno como nocturno, con servicios terrestres y marinos, que sirve para todo tipo de clima. La misión forma parte del Programa *Copernicus* de la Unión Europea (UE) y es operada por la Agencia Espacial Europea (ESA). La misión consiste en una constelación de dos satélites que proporciona tiempos de revisitación de cada punto de la tierra cada seis días. El radar transmite y recibe en banda C (5.405 GHz) a una resolución de 5 x 20 metros, en modo interferométrico de banda ancha. Este es el modo más común que se utiliza sobre las masas terrestres. Los datos se procesan y almacenan como productos de Nivel 1 *Single Look Complex* (SLC) y Nivel 1 *Ground Range Detected* (GRD) por parte del segmento de tierra de ESA. El producto SLC contiene la intensidad de los retornos y la información de la fase, mientras que el producto GRD no contiene la información de la fase, debido al procesamiento mejorado que recibe. Estos datos de GRD son de aspecto múltiple y se proyectan al rango del terreno utilizando el modelo elipsoide terrestre.

Los datos de *Sentinel-1* se transforman en productos de retrodispersión a partir de los datos recopilados en el modo de barrido de *Interferometric Wide* (IW) y se procesan a partir de la versión de *Ground Range Detected* (GRD). Estos datos de *Sentinel-1* contienen información polarizada VV y VH. Las imágenes en bruto se corrigen en el terreno, se normalizan radiométricamente y se procesan a un coeficiente de retrodispersión Gamma-0 en decibelios (dB), utilizando la caja de herramientas SNAP (<http://step.esa.int/main/toolboxes/snap/>). En la figura A1.1 se muestra un ejemplo de producto ARD de *Sentinel-1*.




Figura A1.1. Producto ARD de Sentinel-1 ARD, captura del 25 de marzo de 2018, para el valle de Colchagua.

Sentinel-2

Sentinel-2 es una misión de imágenes de alta resolución multiespectral, de órbita polar para el monitoreo de la Tierra. La misión también forma parte del Programa *Copernicus* de la UE y es operada por la ESA. La misión consiste en una constelación de dos satélites que proporciona una revisitación de la órbita cada 10 días con un satélite y cinco días con dos satélites en condiciones sin nubes, lo que da como resultado 2-3 días en las latitudes medias. La carga útil del instrumento óptico muestra 13 bandas espectrales: cuatro bandas a 10 metros, seis bandas a 20 metros y tres bandas a 60 metros de resolución espacial. El ancho de la franja orbital es de 290 kilómetros.

Los datos de *Sentinel-2* se transforman para crear un producto corregido topográficamente de la reflectancia de la superficie con una máscara topográfica de nube y que se puede aplicar a las imágenes proporcionadas por separado. El software de Corrección Radiométrica y Atmosférica de Imágenes Satelitales (ARCSI) (<http://www.rsgislib.org/arcsi>) se utilizó para generar este producto, ya que es el software que se usó durante el proceso de automatización en el Reino Unido (Jones et al., 2017). Este proceso, aunque desarrollado para el procesamiento en el Reino Unido, se puede implementar globalmente, y ahorra tiempo y costo al implementar la cadena de procesamiento en otras áreas globalmente. Durante el procesamiento, las bandas de imagen de 20 m se mejoran a 10 m mediante la aplicación de modelos de regresión lineal. Las bandas de 60 m se utilizan principalmente para la corrección de aerosoles atmosféricos y los procesos y, por lo tanto, se eliminan del producto final de reflectancia de la superficie.

La caja de herramientas SNAP de la ESA se utiliza para crear capas de Descomposición espectral lineal (*Linear Spectral Unmixing*, LSU) para la vegetación productiva, la vegetación no productiva, la sombra y las superficies de agua, para las cuatro imágenes de Sentinel-2. Se necesita utilizar esta herramienta ya que la señal detectada por Sentinel-2 en un píxel es con frecuencia una combinación de numerosas señales dispares. La figura A1.2 muestra una visualización de esta combinación mixta en un píxel. Para superar los píxeles mixtos, el modelado se implementa en la caja de herramientas de SNAP (<http://step.esa.int/main/toolboxes/snap/>) para identificar el porcentaje de cada material




Figura A1.2. Ejemplo de un diagrama con un píxel mixto copuesto de pastizales, arboles y suelo (Kilcoyne et al., 2017)

presente por píxel. El usuario define píxeles "puros" para la vegetación productiva, la vegetación no productiva, la sombra y las capas de agua. La abundancia relativa de estos materiales es entonces diferenciada en base a las características espectrales de cada uno de los materiales. Al identificar los píxeles puros de los criterios deseados, cada píxel se atribuye con afinidad a los píxeles de entrenamiento. Para obtener más detalles sobre el proceso de LSU, consulte el Informe del Método del Mapa Vivo (*Living Map Method Report*, Kilcoyne et al., 2017).

Modelo Digital de Elevación (DEM)

En el proceso de clasificación se utilizó un DEM generado por la Misión *Shuttle Radar Topography* (SRTM) de la NASA en 2000. Los datos SRTM son de código abierto y están disponibles a una resolución de 1 arco por segundo, aproximadamente 30 metros. Los datos se descargaron del sitio web del Centro *Earth Resources Observation and Science* (EROS) (<https://www.usgs.gov/centers/eros>). También se crearon capas de pendiente, forma y sombra, y todas las capas se volvieron a muestrear a una resolución espacial de 10 metros.

El bioclima

Las capas ráster de libre acceso con las temperaturas máximas y mínimas y la precipitación anual, se descargaron como a una resolución espacial de ~ 1 km (30 segundos de arco) de *WorldClim*. (<http://worldclim.org/bioclim>).

Datos del Open Street Map

Los datos *OpenStreetMap*® son datos abiertos, bajo la licencia de *Open Database Commons Open Database* (ODbL) de la Fundación *OpenStreetMap* (OSMF). Los datos se descargaron a través de un complemento de QGIS (https://wiki.openstreetmap.org/wiki/QGIS_OSM_Plugin) e incluyeron capas de edificaciones y carreteras.

Datos de construcción del modelo

Los datos de campo disponibles en este proyecto, para la realización de la cartografía de hábitats, eran limitados. Se disponía de una cartografía de cobertura del suelo de 2013, que se usó como referencia. Los datos de entrenamiento se crearon en función de la ubicación y distribución de las clases, según lo cartografiado en 2013; aunque en una escala más gruesa. Dentro de cada distribución de clase, se generó un número igual de puntos por clase, de forma aleatoria. Todos estos puntos se usaron únicamente para formar el algoritmo del *Random Forest*.

Método

Un resumen de los distintos pasos llevados a cabo en el proyecto para el proceso de clasificación, se puede ver en el siguiente diagrama de flujo en la Figura A1.3.




Figura A1.3. Diagrama de flujo del proceso de clasificación (Kilcoyne *et al.*, 2017).

El método sigue los pasos del Método *Living Maps*. Se pueden ver más detalles sobre los pasos en el informe técnico (Kilcoyne *et al.*, 2017). La única diferencia con el método descrito en este informe es el proceso de segmentación y la cantidad de variables significativas

identificadas, para mejorar el ajuste del modelo de *Random Forest*, que se describe a continuación en la sección 3.1.

Segmentación

La segmentación se aplicó en el paquete de software de análisis de imagen comercial, en la versión 9.2.1 del *Trimble eCognition*. En el momento de escribir, *eCognition* produce una caracterización mejor de las formas del paisaje, que las alternativas de software de código abierto. El procesamiento de la segmentación utilizó las imágenes de Sentinel-2 de diciembre. El algoritmo de segmentación utilizado fue una combinación de la segmentación multispectral y el algoritmo de diferencias espectrales. El algoritmo de segmentación multispectral se utilizó por primera vez para generar objetos, mientras que el algoritmo de diferencia espectral se utilizó para eliminar objetos pequeños combinando objetos espectralmente similares en uno solo. Los parámetros utilizados se resumen en la Tabla A1.1.

Tabla A1.1. Parámetros utilizados para la creación de objetos.

Segmentación de multiresolución	Parámetros
Banda de las imágenes	Azul = 1; Verde = 1; Rojo = 2; Borde Rojo 5 = 1; Borde Rojo 6 = 1; Borde Rojo 7 = 1; Borde Rojo 8A = 1; NIR = 3; SWIR1 = 4; SWIR2 = 4
Escala de parámetros	18
Forma	0.6
Compacidad	0.4

Variables más significativas en la clasificación de Bosques Aleatorios (*Random Forest*)

Se seleccionó el método de *Random Forest* como el más exitoso para hacer la clasificación estadística. Al tratarse de un clasificador multinomial, *Random Forest* es un algoritmo rápido y que se puede hacer de forma paralela (en comparación con otros métodos de clasificación estadística, como las máquinas de vectores de soporte). *Random Forest* tiene un bajo requerimiento de cálculo y, por lo tanto, se puede volver a ejecutar sin una gran inversión de tiempo. El método es extremadamente flexible, capaz de lidiar con variables continuas y categóricas, y capaz de discernir las interacciones entre variables (Kilcoyne et al., 2017).

Un *Random Forest* se construye a partir de una gran cantidad de árboles de decisión, que se han entrenado en un subconjunto de los datos de entrenamiento y un subconjunto de las variables de entrenamiento. Los árboles se construyen haciendo una serie de particiones secuenciales de los datos de entrenamiento, cada una basada en el valor de una sola variable, hasta que los datos se han separado en grupos con clases idénticas, o se alcanza un número máximo de particiones. Los nuevos puntos de datos se pueden alimentar a través de cada árbol para producir una predicción. Las predicciones de cada árbol se agregan y la clase con la mayoría de los "votos" se considera la mejor predicción general. Cada uno de los árboles individuales es un predictor débil de clase, pero juntos el bosque tiene un poder predictivo más fuerte (Kilcoyne et al., 2017).

El número de variables necesarias para producir una clasificación precisa varía según el proyecto, el número final se determina cuando la precisión general del mapa no aumenta con las variables adicionales. La lista final de variables está disponible en la Tabla A1.2

Tabla A1.2. Lista final de las variables utilizadas para la cartografía y sus valores más significativos determinados por el algoritmo del *Random Forest*.

Variable	Valores significativos
Pendiente – Promedio	72.54760129
Vías de agua – <i>Open Street Map</i> – Promedio	71.24787397
Altura – Promedio	59.63962917
Carreteras – <i>Open Street Map</i> – Promedio	55.58142176
Sentinel-2 – Marzo – Aspereza – Promedio	49.51739453
Índice de Diferencia – Sentinel-2 – Octubre –Banda Verde – SWIR1 Band	46.80663597
Sentinel-2 – Octubre–Banda Azul – Promedio	40.00953466
Sentinel-2 – Diciembre –Banda Azul – Mediano	39.42202805
Sentinel-2 – Diciembre –Borde[8A] Rojo – Mediano	36.3874349
Sentinel-2 – Diciembre – Banda Azul – Promedio	36.28038398
Sentinel-1 – Julio – Retrodispersion – VH – Promedio	35.75198425
Índice de Diferencia – Sentinel-2 – Diciembre – Banda Verde– Banda SWIR1– Promedio	35.20160931
Índice de Diferencia – Sentinel-2 – Marzo –Banda Verde– Banda SWIR1 – Promedio	35.18408674
Sentinel-1 – Julio – Retrodispersion – VV – Promedio	34.48999362
Índice de Diferencia – Sentinel-2 – Octubre –Banda Roja– SWIR2 Banda – Promedio	33.71149407
Sentinel-2 – Diciembre –Banda Borde[8A] Rojo – Desviación Estándar	32.86976039
Índice de Diferencia – Espectro linear sin mezclar – Marzo – Vegetación no fotosintética – Espectro linear sin mezclar – Octubre – Vegetación no fotosintética – Promedio	32.59380616
Sentinel-2 – Octubre –Banda Azul – Mediano	32.47969091
Sentinel-1 – Julio – Retrodispersion – VV – Mediano	32.19519016
Espectro linear sin mezclar – Octubre – Agua/sombra – Promedio	32.11183534
Sentinel-2 – Julio – NDWI (Verde) – Promedio	32.05935048
Índice de Diferencia – Sentinel-2 – Octubre –Banda Roja– Banda SWIR1 - Promedio	32.02550816
Sentinel-2 – Marzo –Banda Azul – Mediano	31.87871294
Índice de Diferencia – Sentinel-2 – Diciembre –Banda Roja – Banda Borde [5] Rojo– Promedio	31.60258527
Sentinel-1 – Octubre – Retrodispersion – VV – Promedio	31.15906736
Sentinel-2 – Octubre –Banda Verde – Promedio	30.70047368
Sentinel-1 – Julio – Retrodispersion – VH - Mediano	30.22784791
Sentinel-2 – Octubre – Banda Borde [8A]Rojo – Mediano	29.94324594
Sentinel-2 – Marzo –Azul – Promedio	29.84671631
Sentinel-2 – Octubre – Banda Azul – Desviación Estándar	29.53510312
Sentinel-2 – Octubre – NIR – Mediana	28.75321749
Sentinel-2 – Octubre –Banda Roja – Promedio	28.1821866
Sentinel-2 – Octubre – Banda Borde [7] Rojo– Promedio	28.11684533
Sentinel-2 – Octubre – Banda SWIR2 – Promedio	28.08480935
Índice de Diferencia – Sentinel-2 – Diciembre –Banda Roja – Banda Borde[5] Rojo – Promedio	28.08058611
Repoblaciones – O’Higgins 2013 – Promedio	27.03271549

Sentinel-2 – Octubre – Banda Verde – Mediana	26.78671136
Sentinel-2 – Diciembre – Green Banda Verde – Promedio	26.67012603
Sentinel-2 – Octubre –Banda Borde[5] Rojo – Promedio	24.49036896
Sentinel-2 – Diciembre –Banda Borde[6] Rojo – Desviación Estándar	24.1995114
Sentinel-2 – Diciembre – Banda NIR– Desviación Estándar	23.50938571
Sentinel-2 – Diciembre – Banda Borde[7] Rojo – Desviación Estándar	22.76341942

Apéndice 2 – Parámetros de las HRU para el modelo SWAT

Se necesitaron varios parámetros del modelo para crear las Unidades de Respuesta Hidrológica (HRU) del modelo SWAT. Para crear una combinación única de suelo y usos del suelo y a partir de las capas de datos, se creó una tabla de búsqueda para relacionar las clases de suelo de la cartografía de hábitats (Capítulo 2), con las bases de datos de tipos de cultivos dentro de SWAT (Tabla A2.1). Los glaciares y la cubierta de nieve se clasificaron como agua, con los parámetros de deshielo, que determinan su estado físico cuando se ejecuta el SWAT. Como se explicó en la Sección 4, como las características y mediciones descritas de los cultivos no estaban disponibles, las clases de hábitat se ajustaron al tipo de cultivo más cercano en las bases de datos de cultivos incorporadas del SWAT, que se basan en los tipos de cultivos de los EE. UU. La gestión de hábitats agrícolas y de pastizales cultivados, así como las repoblaciones, se clasificaron como mosaico de cultivo/pastizales y mosaico de cultivos/bosques, respectivamente, capturando las diferencias en su estructura vegetativa.

Sin embargo, esto causó algunas inexactitudes en el proceso de modelado en donde, por ejemplo, aunque la estepa andina central y la zona suroeste de los EE. UU. (Árido) pueden compartir algunas características de las regiones herbáceas/arbustivas, mezcladas con roca expuesta y desnuda, las especies de cultivos presentes variarán y, por lo tanto, no representa con precisión las características de la vegetación, como puede ser la profundidad media de enraizamiento.

Tabla A2.1. Tabla de búsqueda de uso de suelo que compara las clases de hábitat de la cartografía de hábitats generada (ver Capítulo 2), con las clases dentro de las bases de datos urbanas y de cultivos SWAT. Otras descripciones de las clases de SWAT se indican en el Apéndice A de la documentación de SWAT en Arnold et al. (2012)

Id del Raster	Clase de Hábitat	Clase de SWAT	Nombre de la clase SWAT
1	Tierras agrícolas	AGRL	Tierras agrícolas - Genérico
2	Llanuras aluviales	WEHB	Humedal herbáceo
3	Estepa central andina	SWRN	Rango Suroeste EEUU (Árido)
4	Pastos cultivados	CRGR	Mosaico de Cultivos/ Pastizales
5	Glaciares	WATR	Agua
6	Lagos	WATR	Agua
7	Bosque autóctono	FRST	Bosque – Mezcla
8	Repoblaciones	CRWO	Mosaico de Cultivos/Bosque
9	Ríos	WATR	Agua
10	Afloramientos rocosos	BSVG	Zonas áridas- vegetación escasa
11	Matorral	SHRB	Matorral
12	Praderas estacionales	GRAS	Pastizales
13	Cubierta de nieve	WATR	Agua
14	Arboles & Matorrales	SHRB	Matorrales
15	Urbano	URBN	Zonas residenciales
16	Viñedo	GRPE	Viñedo

Definiciones de crecimiento de las plantas

Una vez que se definieron las HRU en el modelo, se utilizaron los parámetros de operación de gestión para establecer ciclos en el crecimiento de la planta. Estos parámetros se determinaron en SWAT a través de las características del cultivo, la clase de usos del suelo y de las operaciones aplicadas a cada HRU. Estas operaciones definen el período de inicio, cuando comienza el crecimiento y el final del período de crecimiento, para hábitats naturales o cuando se produce la cosecha, para la tierra trabajada.

Como SWAT se desarrolló para regiones templadas, las operaciones generalmente se programaron en unidades de días de calor y los algoritmos se basaron en un período de inactividad, que está ausente en las regiones de los trópicos y del hemisferio sur (Strauch y Volk, 2013). Para superar esto, las operaciones de manejo, para todas las clases de usos del suelo se programaron según el inicio y el final de la temporada de crecimiento, en septiembre y abril, tal y como se señala en Curico en Hajek y Gutiérrez (1979), en lugar de hacerlo por fecha. Los hábitats agrícolas gestionados y los viñedos, se programaron de acuerdo con la información proporcionada por los socios interesados, en un taller previo al proyecto; se fijó que la temporada de cosecha del viñedo tenía lugar en marzo.

Parámetros de nieve

Los límites de los glaciares fueron indicados en la cartografía de hábitats. Al usar la base de datos GLIMS *Glacier*, las comparaciones visuales con la cartografía de hábitats (descrito en la Sección 1) mostraron que seguían un esquema similar con las mismas subcuencas afectadas, por ambos conjuntos de datos. Siguiendo el enfoque de Omani et al. (2017), estos límites se utilizaron para ayudar a determinar la altitud de la línea de equilibrio (ELA), una línea teórica que separa la zona de acumulación y ablación de un glaciar, y se asignaron diferentes parámetros de fusión de nieve a las áreas de hielo y nieve presentes en las zonas relevantes. El ELA se estimó mediante comparaciones de la cartografía de hábitats y DEM, para extraer la elevación mínima para hábitats glaciares dentro de cada sub-cuenca, suponiendo que por debajo de esta, la cubierta de nieve sería estacional. Las subcuencas que exceden un umbral de elevación de 2000 m se subdividieron en 10 bandas de elevación, con bandas espaciadas uniformemente a lo largo de las elevaciones mínima y máxima de cada subcuenca (ver Tabla 3). Las bandas glaciares se indicaron como aquellas en las que al menos el 50% de la banda de elevación excedía el ELA.

La base de datos GLIMS tenía pocos registros completos en nuestra región de estudio y carecía de datos estacionales de la línea de nieve, por lo que se consideró que la línea de nieve estacional era equivalente a la elevación mínima de la cubierta de nieve indicada por la cartografía de hábitats. Esto conlleva una menor precisión, ya que la estacionalidad completa de la cubierta de nieve no se evaluó con la generación de la cartografía de hábitats, pero proporcionó una indicación de las áreas que experimentaron una cierta cubierta de nieve durante todo el año.

La bibliografía aporta factores de fusión más altos para el hielo (6-8 mm por día) que para la nieve (3-5 mm por día) (Braithwaite, 2008). Los parámetros de fusión de la nieve se extrajeron de la Tabla 1.15 en el estudio de disertación de Omani (2014), en el que se utilizó SWAT para modelar una región de estudio similar, de cuencas glaciares en el centro de Chile. Los parámetros medios de nieve derretida en la cuenca total, se aplicaron en las 10 bandas de altitud, con los factores de fusión máximos y los tiempos de demora mínimos, aplicados donde las elevaciones eran más altas, tal y como se muestra en la Tabla 2.

El almacenamiento de nieve inicial fue requerido para cada banda individual, indicada con el parámetro "SNOEB" en SWAT, como el contenido de agua equivalente dentro de la banda. Los registros locales de la profundidad de la nieve y las observaciones del espesor medio del hielo dentro de la región de captación del Libertador Bernardo O'Higgins, no estaban disponibles en el Inventario Mundial de Glaciares (WGI, 2019). Como resultado, las profundidades de nieve para las bandas de altitud, se estimaron a partir de experimentos glaciares realizados en los Andes chilenos por Stehr & Aguayo (2017). Los datos obtenidos de la sección complementaria de su estudio de 2017, contenían registros de profundidad media de nieve para tres estaciones instaladas en diferentes alturas en la región del Biobío en Chile central, una región al sur de la del Libertador Bernardo O'Higgins, con un clima similar, que se ha estudiado en mayor detalle que la región de interés de Colchagua. Sus estaciones experimentales proporcionaron una indicación de la profundidad variable de la nieve y se aplicaron a las bandas de altitud en el modelo de cuencas, donde las elevaciones superaron las de la estación meteorológica (Portillo alt. 3005 m, profundidad media: 473.5091 mm, Laguna Negra alt. 2709 m, media profundidad: 376.3265 mm, Volcán Chilan alt.1964 m, profundidad media: 262.366 mm)

Tabla A2.2. Los parámetros de deshielo utilizados en las bandas de elevación definidas, extraídos de Omani (2014).

Parámetro de deshielo	Parámetro SWAT	Banda de altitud menor (Por debajo de la cobertura de nieve)	Banda de nieve	Banda glaciar (med)	Banda glaciar (máx.)
Tasa de lapso de temperatura (°C / km)	TLAPSE	-4.3	-4.3	-4.3	-4.3
Tasa de lapso de precipitación (mm H ₂ O / km)	PLAPSE	-17	-17	-17	-17
Temperatura de las nevadas (°C)	SFTMP	0.77	1.01	1.14	1.14
Temperatura base de nieve derretida (°C)	SMTMP	0.42	0.90	1.66	5
Factor de fusión de la nieve el 21 de junio (°C)	SMFMX	4.68	4.64	5.38	7
Factor de fusión de la nieve el 21 de diciembre (°C)	SMFMN	4.07	4.06	4.93	8
Factor de retraso de la temperatura del paquete de nieve (°C)	TIMP	0.78	0.74	0.50	0.01

Tabla A2.3. Las subcuencas que excedían un umbral de altitud de 2000 m se dividieron en 10 bandas de altitud, con las altitudes de umbral anotadas para cada banda (ELEV1-10). La altitud mínima de la capa de nieve y la altitud del glaciar se extrajeron de las comparaciones con el Modelo de Elevación Digital y las capas de la cartografía de hábitats, junto con la altitud máxima para cada subcuenca. Donde no hubo superposición entre la nieve y los hábitats glaciares dentro de un límite de subcuenca, se denota como n / a *.

Subcuenca	Altitud máxima (m)	Altitud minia de cobertura de nieve (m)	Altitud mínima de glaciar (m)	ELEV1 (m)	ELEV2 (m)	ELEV3 (m)	ELEV4 (m)	ELEV5 (m)	ELEV6 (m)	ELEV7 (m)	ELEV8 (m)	ELEV9 (m)	ELEV10 (m)
13	3567	2443	2655	1466.55	1687.65	1908.75	2129.85	2350.95	2572.05	2793.15	3014.25	3235.35	3456.45
14	4971	2495	2542	1690.65	2035.95	2381.25	2726.55	3071.85	3417.15	3762.45	4107.75	4453.05	4798.35
15	3752	2385	2416	1475.8	1715.4	1955	2194.6	2434.2	2673.8	2913.4	3153	3392.6	3632.2
18	3918	2657	2860	1121.2	1415.6	1710	2004.4	2298.8	2593.2	2887.6	3182	3476.4	3770.8
19	4971	2379	2474	1686.85	2032.55	2378.25	2723.95	3069.65	3415.35	3761.05	4106.75	4452.45	4798.15
22	2059	n/a*	n/a*	374.65	551.95	729.25	906.55	1083.85	1261.15	1438.45	1615.75	1793.05	1970.35
26	2535	n/a*	n/a*	754.7	942.1	1129.5	1316.9	1504.3	1691.7	1879.1	2066.5	2253.9	2441.3
27	4686	2717	3037	1602.3	1926.9	2251.5	2576.1	2900.7	3225.3	3549.9	3874.5	4199.1	4523.7
28	4207	2781	2991	1578.35	1855.05	2131.75	2408.45	2685.15	2961.85	3238.55	3515.25	3791.95	4068.65
30	4676	2439	2426	1253.15	1613.45	1973.75	2334.05	2694.35	3054.65	3414.95	3775.25	4135.55	4495.85
32	2062	n/a*	n/a*	375.75	553.25	730.75	908.25	1085.75	1263.25	1440.75	1618.25	1795.75	1973.25
33	3056	2410	2480	779.8	1019.4	1259	1498.6	1738.2	1977.8	2217.4	2457	2696.6	2936.2
38	3028	2499	2579	1079.55	1284.65	1489.75	1694.85	1899.95	2105.05	2310.15	2515.25	2720.35	2925.45
40	2939	2489	2663	793.9	1019.7	1245.5	1471.3	1697.1	1922.9	2148.7	2374.5	2600.3	2826.1
43	3838	2513	2939	1458.25	1708.75	1959.25	2209.75	2460.25	2710.75	2961.25	3211.75	3462.25	3712.75
47	3706	2778	2994	1208.45	1471.35	1734.25	1997.15	2260.05	2522.95	2785.85	3048.75	3311.65	3574.55
52	2057	n/a*	n/a*	552.2	710.6	869	1027.4	1185.8	1344.2	1502.6	1661	1819.4	1977.8
54	3911	2717	2837	840.6	1163.8	1487	1810.2	2133.4	2456.6	2779.8	3103	3426.2	3749.4
60	2243	n/a*	n/a*	568.15	744.45	920.75	1097.05	1273.35	1449.65	1625.95	1802.25	1978.55	2154.85

Apéndice 3 – Talleres con los socios del proyecto

Los viñedos de las partes interesadas proporcionaron datos de la estación meteorológica de 2018 junto con información sobre las prácticas de manejo que utilizan en sus campos, que se muestran en las tablas a continuación: Winery=viñedo; Field=nombre del campo; Insects=insectos; Fungus=hongos; Rabbits=conejos; Birds=pájaros; Others=otros; None=ninguno; Type of treatment=tipo de tratamiento; Chemical=químico; Biocontrol=control biológico; Mite=ácaros

Tabla A3.1. Cuestionario sobre pesticidas

Field	Type of treatment	Insects	Fungus	Rabbits	Birds	Others	None
a	Chemical	Insects	Fungus				
a	Biocontrol	Insects					
b	Chemical	Insects	Fungus				
b	Biocontrol	Insects					
c	Chemical	Insects	Fungus			Mite	
c	Biocontrol			Rabbits			
d	Chemical	Insects	Fungus				
d	Biocontrol	Insects					
e	Chemical	Insects	Fungus				
e	Biocontrol	Insects	Fungus				
f	Chemical	Insects	Fungus				
f	Biocontrol	Insects	Fungus				
g	Chemical	Insects	Fungus			Mite	
g	Biocontrol						None
h	Chemical	Insects	Fungus				
h	Biocontrol						None
i	Chemical	Insects	Fungus				
i	Biocontrol						None
j	Chemical		Fungus				
j	Biocontrol						None
k	Chemical	Insects	Fungus				
k	Biocontrol			Rabbits	Birds		
l	Chemical	Insects	Fungus			Mite	
l	Biocontrol	Insects					
m	Chemical	Insects	Fungus				
m	Biocontrol	Insects					
n	Chemical	Insects	Fungus				
n	Biocontrol						None
o	Chemical	Insects	Fungus			Mite	
o	Biocontrol						None
p	Chemical	Insects	Fungus				
p	Biocontrol	Insects					
q	Chemical	Insects	Fungus				
q	Biocontrol	Insects					
r	Chemical	Insects	Fungus				
r	Biocontrol	Insects		Rabbits			

Tabla A3.2. Gestión de malas hierbas.

Donde: Field=nombre del campo; Most damaging weeds= hierbas más dañinas; Scientific name= nombre científico; Where the weed grows= Donde crece la hierba; Type of management (Chemical, Mechanical, Both, Cover crop) = Tipo de manejo (Químico, Mecánico, Ambos tipos, cobertura). Frequency (times per year) = Frecuencia (veces al año); Information to decide frequency=Información para decidir la frecuencia. Inter-row= entre raíces; under-vine=bajo la vid; Everywhere=en todos sitios; top-vine=encima de la vid.

Field	Most damaging weeds	Scientific name	Where the weed grows	Type of management (Chemical, Mechanical, Both, Cover crop)	Frequency (times per year)	Information used to decide frequency
a	Chepica	Paspalum paspalodes	Inter-row, under-vine	C	2	Monitoring
a	Correhuela	Convolvulus arvensis	Inter-row, under-vine	C	2	Monitoring
b	Chepica	Paspalum paspalodes	Inter-row, under-vine	C	2	Monitoring
b	Correhuela	Convolvulus arvensis	Inter-row, under-vine	C	2	Monitoring
c	Conyza	Conyza bonariensis	Inter-row, top-vine	B	2	Monitoring
c	Correhuela	Convolvulus arvensis	Inter-row, top-vine	B	2	Monitoring
c	Acacia caven	Acacia caven	Inter-row, under-vine	M	1	Monitoring
d	Chepica	Paspalum paspalodes	Under-row	B	12	Monitoring
d	Zanahoria silvestre	Daucus carota	Under-row	B	4	Monitoring
d	Falso te	Bidens aurea	Under-row	B	4	Monitoring
e	Chepica	Paspalum paspalodes	Everywhere	M	12	Monitoring
e	Galega	<i>Galega officinalis</i>	Everywhere	M	12	Monitoring
e	Maicillo	Sorghum halepense	Everywhere	M	12	Monitoring
f	Chepica	Paspalum paspalodes	Everywhere	M	12	Monitoring
f	Galega	<i>Galega officinalis</i>	Everywhere	M	12	Monitoring
f	Maicillo	Sorghum halepense	Everywhere	M	12	Monitoring
g	Correhuela	Convolvulus arvensis	Everywhere	B	12	Monitoring
g	Ballica	Lolium sp.	Everywhere	C	4	Monitoring
g	Malva	Malva nicaensis	Everywhere	B	12	Monitoring
h	Conyza	Conyza bonariensis	Inter-row, top-vine	B	2	Monitoring
h	Loteria	Lotus corniculatus	Inter-row, top-vine	M		Monitoring
h	Meloza	Madia sativa	Inter-row, top-vine	C	3	Monitoring
i	Conyza	Conyza bonariensis	Everywhere	C	3	Monitoring
i	Meloza	Madia sativa	Everywhere	C	3	Monitoring
j	Chepica	Paspalum paspalodes	Inter-row, under-vine	C	1	Calendar
j	Galega	<i>Galega officinalis</i>	Inter-row, under-vine	M	1	Monitoring
j	Correhuela	Convolvulus arvensis	Inter-row, top-vine	C	1	Monitoring
k	Grass		Inter-row, under-vine	M	1	Monitoring
k	Correhuela	Convolvulus arvensis	Everywhere	C	12	Monitoring
k	Chepica	Paspalum paspalodes	Inter-row, under-vine	C	1	Monitoring
l	Correhuela	Convolvulus arvensis	Inter-row	M	1	Monitoring
l	Qinguilla	Chenopodium album	Inter-row	M	1	Monitoring
l	Yuyo	Brassica campestris	Inter-row, top-vine	B	1	Monitoring
m	Correhuela	Convolvulus arvensis	Everywhere	B		Monitoring
m	Epilodyum	Epilobium sp	Everywhere	B		Monitoring
m	Qinguilla	Chenopodium album	Everywhere	B		Monitoring
n	Chepica	Paspalum paspalodes	Inter-row	M, Cover crop	12	Monitoring
n	Meloza	Madia sativa	Inter-row, under-vine	M, Cover crop	12	Monitoring
o	Correhuela	Convolvulus arvensis	Under-vine	C	12	Monitoring
o	Ballica	Lolium sp.	Under-vine	M	12	Monitoring
p	Conyza	Conyza bonariensis	Inter-row, under-vine	M	8	Monitoring
p	Ballica	Lolium sp.	Inter-row, under-vine	C	8	Monitoring
p	Malva	Malva nicaensis	Under-vine	C	8	Monitoring
q	Conyza	Conyza bonariensis	Inter-row, under-vine	M	8	Monitoring
q	Ballica	Lolium sp.	Inter-row, under-vine	C	8	Monitoring
q	Malva	Malva nicaensis	Under-vine	C	8	Monitoring
r	Conyza	Conyza bonariensis	Inter-row, under-vine	M	8	Monitoring
r	Ballica	Lolium sp.	Inter-row, under-vine	C	8	Monitoring
r	Malva	Malva nicaensis	Under-vine	C	8	Monitoring

Tabla A3.3. Prácticas de cultivo

Dónde: Winery=viñedo; Field=nombre del campo; Type of interrow management (Tillage, Covercrop, Both) = Tipo de gestión entre filas (labranza, cultivo de cobertura, ambos); When tillage present (Mechanical, Animal, Both, Other)= Cuando hay labranza (Mecánica, Animal, Ambas, Otras)

Field	Type of interrow management (Tillage, Covercrop, Both)	When tillage present (Mechanical, Animal, Both, Other)
a	Both	Mechanical
b	Both	Mechanical
c	Tillage	Mechanical
d	Tillage	Mechanical
e	Covercrop	
f	Covercrop	
g	Both	Both
h	Tillage	Both
i	Covercrop	
j	Tillage	Both
k	Tillage	Mechanical
l	Both	Mechanical
m	Both	Mechanical
n	Tillage	Mechanical
o	Both	Mechanical
p	Both	Mechanical
q	Both	Both
r	Both	Both

Tabla A3.4. Prácticas de aplicación de fertilizantes.

Donde: Winery=viñedo, Field=nombre del campo; Type of fertilizer=tipo de fertilizante; Frequency (Times per year) = Frecuencia (Número de veces al año); Name=nombre. Chemical=químico; Organic=orgánico; Urea=urea; Muriate of potassium= Muriato de Potasio; Compost=compost; Monoammonium phosphate= Fosfato de monoamonio; Nitrogen=nitrógeno; Phosphorus= Fósforo; Magnesium=magnesio; Boron=boro

Field	Type of fertilizer	Frequency (Times per year)	Name	Field	Type of fertilizer	Frequency (Times per year)	Name
a	Chemical	2	Urea	i	Organic	0	
a	Chemical	2	Muriate of potassium	j	Chemical	2	Urea
a	Organic	1	Compost	j	Chemical	2	UAN 32
b	Chemical		Urea	j	Chemical	2	Nitrato K
b	Chemical	2	Muriate of potassium	j	Chemical	1	Muriato K
b	Organic	1	Compost	j	Organic	0	
c	Chemical	2	Urea	k	Chemical	2	
c	Chemical	2	Muriate of potassium	k	Chemical	2	
c	Chemical	1	monoammonium phosphate	k	Chemical	2	
c	Organic	1	Compost	k	Organic	0	
c	Organic	1	Fontsoil	l	Chemical	28	Not specified
c	Organic	1	Iberhumus	l	Chemical	28	Foliasa
d	Chemical	1	Nitrogen	l	Organic	12	Seaweed
d	Chemical	1	Potassium	m	Chemical	2	Not specified
d	Chemical	1	Phosphorus	m	Chemical	28	Not specified
d	Chemical	2	Magnesium	m	Organic	12	Not specified
d	Chemical	1	Boron	n	Organic	28	Humus
d	Organic	0	NA	n	Organic	1	Compost
e	Chemical	0	NA	n	Organic	12	Seaweed
f	Chemical	0	NA	o	Chemical	Not specific	Nitrogen
e	Organica	1	Compost	o	Chemical	Not specific	Magnesium
f	Organica	1	Compost	o	Chemical	Not specific	Potassium
g	Chemical	12	Urea	o	Chemical	Not specific	Boron and Zinc
g	Chemical	12	Cloruro de	o	Chemical	Not specific	Phosphorus
g	Chemical	24	Potasio	o	Organic	Not specific	Compost
g	Chemical	24	Nitrato de	o	Organic	Not specific	Guano
g	Chemical	24	Potasio	p	Chemical	20	Nitrogen
g	Chemical	24	Sulfato de Mg	p	Chemical	20	Potassium
g	Chemical	1	Zin, Boro	p	Chemical	32	Magnesium
g	Organic	1	Guano	p	Chemical	4	Boron
g	Organic	12	Cal	p	Chemical	4	Zinc
g	Organic	24	Magnesium	p	Chemical	4	Phosphorus
h	Chemical	2	Nitrogen	q	Chemical	20	Nitrogen
h	Chemical	2	Potassium	q	Chemical	20	Potassium
h	Chemical	1	Phosphorus	q	Chemical	32	Magnesium
h	Chemical	2	Boron	q	Chemical	4	Boron
h	Chemical	2	Zinc	q	Chemical	4	Zinc
h	Organic	0		q	Chemical	4	Phosphorus
i	Chemical	3	Uaal 32	r	Chemical	20	Nitrogen
i	Chemical	2	Muriato Potasio	r	Chemical	20	Potassium
i	Chemical	2	Sulfato Potasio	r	Chemical	32	Magnesium
i	Chemical	4	Acido Fosforico	r	Chemical	4	Boron
i	Chemical	4	Acido Borico	r	Chemical	4	Zinc
i	Chemical	2	Sulfato de Mg	r	Chemical	4	Phosphorus

Tabla A3.5. Prácticas de manejo orgánico

Field	Other organic practices (Yes/No)	Number of additional organic practices	Practice 1	Practice 2	Practice 3
a	Yes	3	Protection of fauna that controls rabbits	Controlled hunt of rabbits	Vinegar traps of wasps
b	Yes	3	Protection of fauna that controls rabbits	Controlled hunt of rabbits	Vinegar traps of wasps
c	Yes	2	Mecanical control of weeds	Pheromons for pests	
d	Yes	2	Biological corridors	Hummus application in soil	
e	Yes	3	Biodynamic products	Covercrops	Biological corridors
f	Yes	3	Biodynamic products	Covercrops	Biological corridors
g	Yes	1	Organic control of pests		
h	Yes	2	Use of livestock to control weeds in winter	Use of guano as fertilization	
i	Yes	1	Compost		
j	No	0			
k	No	0			
l	Yes	3	Use of livestock to control weeds in winter	Hummus application in soil	Seaweed
m	Yes	3	Use of livestock to control weeds in winter	Covercrops	Seaweed
n	Yes	3	Compost	Control of pest with organic products	Control of weed mechanically
o	Yes	2	Pheromons for pests	Compost	
p	Yes	3	Pheromons for pests	Compost	Use of livestock to control weeds in winter
q	Yes	3	Pheromons for pests	Compost	Use of livestock to control weeds in winter
r	Yes	3	Pheromons for pests	Compost	Use of livestock to control weeds in winter