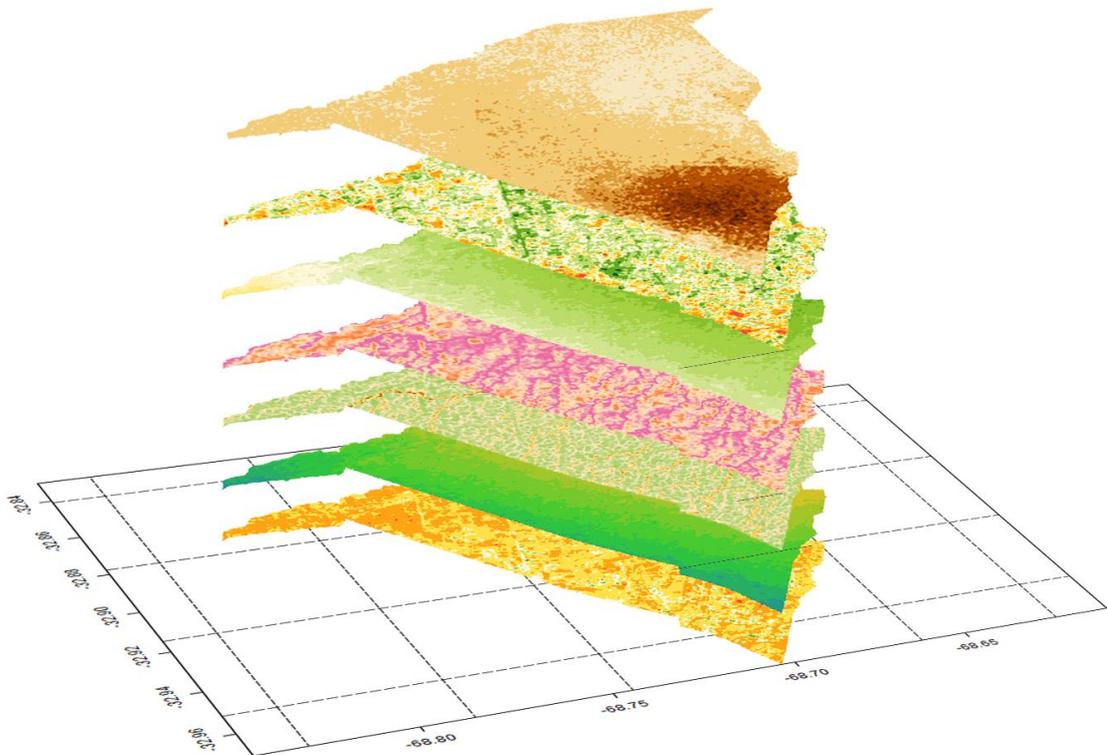


# Variación del contenido de materia orgánica en suelos agrícolas de Guaymallén desde 1963 a 2018, utilizando machine learning.



Francisco Martin Corvalán

INGENIERÍA EN RECURSOS NATURALES RENOVABLES



Facultad de Ciencias Agrarias  
Universidad Nacional de Cuyo  
Almirante Brown 500, Chacras de Coria, Mendoza  
M5528AHB- (54 261) 4135000

# *Variación del contenido de materia orgánica en suelos agrícolas de Guaymallén desde 1963 a 2018, utilizando machine learning.*

## **Autor**

Francisco Martín Corvalán

+549-2616246376

[francisco.corvalan6@gmail.com](mailto:francisco.corvalan6@gmail.com)

## **Director**

Guillermo Federico Olmedo

[guillermo.olmedo@gmail.com](mailto:guillermo.olmedo@gmail.com)

## **Miembros del Comité Evaluador**

Dra. Bárbara Civit.

Ingeniero Agrónomo Leandro Eloy Mastrantonio.

M.Sc. Luis Rodríguez Plaza.

## **Versión Digital de los Resultados:**



<https://drive.google.com/drive/folders/1Cj5z1bdYTOZc8rhjJSSa42AR57IKLCSN>

*"...Those with access to these resources — students, librarians, scientists — you have been given a privilege. You get to feed at this banquet of knowledge while the rest of the world is locked out. But you need not — indeed, morally, you cannot — keep this privilege for yourselves. You have a duty to share it with the world..."*

*"...A ustedes, con acceso a estos recursos –estudiantes, bibliotecarios, científicos– se les ha otorgado un privilegio. Ustedes pueden alimentarse en este banquete del conocimiento mientras el resto del mundo queda fuera. Pero no es necesario –de hecho, moralmente, no es posible– que se queden este privilegio para ustedes. Tienen el deber de compartirlo con el mundo..."*

Aaron Swartz (1986-2013).

## Resumen

El suelo presenta un gran servicio ecosistémico como sumidero de carbono orgánico, almacenando más carbono en el primer metro que toda la vegetación y la atmósfera en conjunto. Por este motivo el mapeo y monitoreo de las reservas de carbono orgánico en el suelo se ha convertido en un tema muy relevante de estudio en las últimas décadas.

El área de estudio comprende al cinturón verde del departamento de Guaymallén (11.000 ha), cuya principal actividad agrícola es la horticultura. Los suelos pertenecientes a esta zona se destacan de los suelos típicos de Mendoza por presentar altos contenidos de materia orgánica y por las modificaciones ecosistémicas que han sufrido en los últimos 200 años (Prieto, Abraham, & Dussel, 2008). Sin embargo, no existe ningún estudio sobre la variación en los contenidos de materia orgánica de estos suelos en el transcurso del tiempo.

Con el objetivo de analizar la variación del Stock de carbono en este sector, se utilizó un set de datos del suelo de 1963 con 509 perfiles y otro set de datos de 2018 con 29 perfiles, los cuales fueron estandarizados a una profundidad de 30 cm. Utilizando un conjunto de variables bioclimáticas, topográficas y variables representativas de vegetación, se elaboraron modelos predictivos del stock de carbono mediante el método de Random Forests adaptado a las técnicas del Mapeo Digital del Suelo. Finalmente se realizó una validación de los modelos predictivos utilizando 4-fold cross-validation.

Los resultados del análisis arrojan valores alarmantes, donde un 90% de la zona sufrió pérdidas de carbono y el stock disminuyó la mitad de sus valores iniciales. En términos netos, el stock de carbono de 1963 perdió 384,32 Gg de C respecto al stock de 2018. Suponiendo que esta disminución fue provocada por procesos de oxidación, estos valores equivalen a una emisión de 1409 Gg de CO<sub>2</sub> y a una tasa de emisión de 0,233 kg CO<sub>2</sub>·m<sup>-2</sup>·año<sup>-1</sup>.

Desde el punto de vista económico-productivo, estos suelos han perdido en gran parte el conjunto de propiedades que ofrece la materia orgánica. Por este motivo, es de esperar que la capacidad productiva de los suelos se haya visto afectada significativamente.

Los motivos por los cuales se han producido estas enormes pérdidas del carbono orgánico no han sido demostrados en el presente trabajo. Sin embargo, esto podría atribuirse a las malas prácticas de manejos de los suelos y a los cambios ecosistémicos que han sufrido los mismos en el transcurso de la historia.

Además, desde el punto de vista ambiental, es necesario tener en cuenta dos aspectos importantes. El primero de ellos es la gran capacidad de almacenamiento de carbono que poseen los suelos de esta zona. El segundo, es que esta cualidad puede convertirse en un potencial peligro si se considera al suelo como una fuente emisora de Gases de Efecto Invernadero como sucedió en los suelos estudiados.

Por último, la utilización de Random Forests como modelo predictivo presentó resultados óptimos, permitiendo incorporar los factores formadores de suelos en la distribución espacial del stock de carbono.

## Palabras Clave

Carbono Orgánico del Suelo, Mapeo Digital del Suelo, Random Forest, Variación del Stock de Carbono Edáfico.

## Agradecimientos

Quisiera agradecer todas las personas que me ayudaron en mi trayecto universitario, incluso desde antes de comenzar y a todos los que me acompañaron en los años de mi carrera:

En primer lugar, quisiera agradecer a todos aquellos que hicieron posible el sistema educativo público, sin el cual hubiese sido muy difícil acceder a mis estudios.

A mis padres por su apoyo incondicional, sobre todo durante este trayecto y por educarme desde pequeño la importancia del estudio, todo lo que soy es gracias a ustedes. Han sido un gran ejemplo de vida y me han inspirado en dejar lo mejor de mí en mi formación universitaria.

A mis hermanos Matías, Carolina y Manuel por acompañarme en esta etapa, en ayudarme en todo lo que fuese necesario y preocuparse tanto en mí. También quisiera agradecerles por haber comprendido la importancia del cuidado ambiental.

A Nicky por haberme acompañado en mi vida tanto tiempo, por haber sido un gran sostén, su gran paciencia y por todos los lindos historias compartidas, sin los cuales mi trayecto universitario no hubiese sido el mismo.

A mi director y ejemplo de vida Federico por haberme capacitado en el MDS y en el manejo de R. Fue una muy buena experiencia compartir esta etapa con una persona tan brillante y apasionada por su trabajo, a la cual admiro mucho.

A todo el equipo de Geomática y Agricultura de Precisión y sus pasantes, por haberme recibido como un integrante más del equipo de trabajo y ayudarme cuando lo necesitaba.

A mis amigos que siempre me apoyaron incondicionalmente, festejaron en conjunto mis logros, por confiar tanto en mí y estar presentes en todos los momentos de mi vida. Gracias infinitas por sus ayudas y consejos.

Por último, quisiera agradecer a todos aquellos que contribuyeron al desarrollo de los softwares libres, en especial a R y sus librerías, y también a Aaron Swartz y Alexandra Elbakyan por poner a disposición de la comunidad una inmensa cantidad de información científica. Agradezco invaluablemente a actividades como esta, ya que permiten disminuir inequidades y contribuir con mejor futuro como humanidad.

# Índice

<b>1. Introducción</b> .....	<b>6</b>
1.1 Presentación e importancia del problema en estudio.....	6
1.2 Hipótesis .....	7
1.3 Objetivos .....	7
1.4 Marco Conceptual .....	7
1.4.1 Definición de Términos Básicos: .....	7
1.4.2 Bases teóricas .....	10
<b>2. Metodología</b> .....	<b>12</b>
Etapa 1: Preparación de los datos.....	13
Etapa 2: Modelado .....	14
Etapa 3: Validación .....	15
Etapa 4: Análisis Comparativo .....	15
<b>3. Materiales</b> .....	<b>17</b>
3.1 Zona de Estudio y Muestras de Suelo. ....	17
3.2 Datos Climatológicos.....	18
3.3 Imágenes Satelitales: .....	18
3.4 Programas informáticos utilizados para el procesamiento de la información: .....	19
<b>4. Covariables Climáticas</b> .....	<b>21</b>
<b>5. Covariables Topográficas</b> .....	<b>24</b>
<b>6. Covariables Organismos</b> .....	<b>30</b>
<b>7. Resultados</b> .....	<b>32</b>
7.1 Preparación de los datos.....	32
7.2 Predicciones del Stock de Carbono.....	33
7.3 Validación de los modelos .....	36
7.4 Balance del stock de carbono y cuantificación del CO <sub>2</sub> emitido .....	37
<b>8. Discusión</b> .....	<b>39</b>
<b>9. Conclusión</b> .....	<b>41</b>
<b>10. Bibliografía</b> .....	<b>42</b>
<b>11. Anexo</b> .....	<b>49</b>
Validación de las interpolaciones climáticas.....	49
Propiedades de los modelos predictivos Random Forest. ....	50

# 1. Introducción

## 1.1 Presentación e importancia del problema en estudio.

El suelo presenta un gran servicio ecosistémico como sumidero de carbono orgánico, almacenando más carbono en el primer metro que toda la vegetación y la atmósfera en conjunto, sin embargo, esta propiedad no ha sido suficientemente valorada. En consecuencia de esto, en los últimos años el suelo se ha convertido en uno de los recursos más vulnerables del mundo frente al cambio climático, la pérdida de biodiversidad y otros impactos antrópicos (FAO, 2017). Por este motivo el mapeo y monitoreo de las reservas de carbono orgánico en el suelo se ha convertido en un tema muy relevante de estudio en las últimas décadas.

Los suelos de la provincia de Mendoza se encuentran catalogados en los órdenes aridisoles y entisoles principalmente. Los mismos son derivados de materiales originarios provenientes de la erosión de rocas cordilleranas, transportados por distintos agentes: aluvional, eólico, coluvial y glacio-lacustre. Las características regionales, distinguidas por la extrema escasez de precipitaciones, dificultan y aún inhiben los procesos edáficos de maduración y aportes de materia orgánica los suelos. Por estos motivos, y por sus orígenes aluvionales, en la escala geológica estos suelos son considerados como suelos “jóvenes”, donde no tiene lugar la diferenciación genésica del perfil (Vallone et al., 2009).

Desde el punto de vista textural, predominan los suelos franco-arenosos y arenosos, aunque existe una gran variabilidad en las clases texturales en pequeñas distancias, pudiéndose encontrar en suelos arenosos sectores con capas de limo-arcillas. Respecto al grado de estructura, el carácter aluvional y joven de estos suelos, hace que rara vez se encuentren estructuras diferenciadas salvo ciertas formas de arcillas salinas y alcalinas asociadas (Vallone et al., 2009).

Otra característica que destaca a los suelos de Mendoza, son sus bajos contenidos de materia orgánica y nutrientes disponibles, motivos por los cuales son catalogados como “pobres” (Venier et al., 2015). En determinados sectores de la provincia se han desarrollado variaciones intrazonales producto de drenajes dificultosos y cuencas sin salida. Un claro ejemplo son los suelos de los distritos Kilómetro 8 y Corralitos del departamento de Guaymallén, que se destacan de los suelos típicos de la provincia por sus elevados contenidos de materia orgánica (Vallone et al., 2009).

Estos suelos pertenecen al cinturón verde del departamento de Guaymallén, cuya principal actividad agrícola es la horticultura. En los últimos 200 años, el ecosistema de este sector ha sufrido importantes modificaciones, el cual era originalmente un sistema lacustre que luego fue alterado por labores de desecación (Prieto, Abraham, & Dussel, 2008).

A pesar de que los contenidos de carbono orgánico en los suelos son muy sensibles a las prácticas de manejo llevadas a cabo, no existe ningún estudio sobre la variación en los contenidos de materia orgánica de estos suelos en el transcurso del tiempo.

Ante la situación planteada, surge como necesidad, realizar un estudio sobre el balance del contenido de carbono orgánico edáfico en uno de los sitios que presenta mayores valores en Mendoza, realizando estimaciones sobre las cantidades de CO<sub>2</sub> que fueron secuestradas o emitidas desde o hacia la atmósfera de la zona de estudio en los últimos 50 años. De esta manera se podrá valorizar su servicio ecosistémico como sumidero de carbono, y a su vez se podrá determinar su potencialidad como fuente de Gases de Efecto Invernadero, lo cual sería de suma importancia para aplicar políticas hacia la lucha contra el cambio climático (Franzuebbers, 2005; Lal, 2004; Robert, 2001).

Así mismo, el estudio permitirá evaluar la modificación de la calidad edáfica y productiva de la zona, ya que el contenido de materia orgánica del suelo es un muy buen indicador de la calidad del suelo, permitiendo el aumento de la productividad primaria de la vegetación y el desarrollo de la fauna edáfica (Robert, 2001).

## 1.2 Hipótesis

Los suelos de Guaymallén, a pesar de presentar una gran capacidad de secuestro de carbono por sus características naturales, almacenando el mismo como materia orgánica edáfica, en los últimos 50 años han perdido gran parte del stock de carbono como consecuencia de las modificaciones ecosistémicas.

## 1.3 Objetivos

### Objetivo general

Analizar la dinámica espacial-temporal del contenido de carbono orgánico en suelos agrícolas irrigados del departamento de Guaymallén desde 1963 hasta el 2018, utilizando técnicas de machine learning para el mapeo digital de suelos.

### Objetivos específicos:

- Elaborar mapas digitales de suelos del stock de carbono a 30 cm. de profundidad para los años 1963 y 2018.
- Determinar los cambios de carbono orgánico de los suelos producidos en la zona de estudio en los últimos 50 años.
- Examinar la variación de las calidades edáficas de la zona, utilizando al contenido de materia orgánica como indicador.
- Cuantificar la cantidad de emisiones o secuestros de CO<sub>2</sub> del recurso edáfico.
- Evaluar el potencial de secuestro de carbono del suelo de la zona.

## 1.4 Marco Conceptual

### 1.4.1 Definición de Términos Básicos:

#### **Carbono Orgánico del Suelo: definición y servicios ecosistémicos.**

El término materia orgánica (MO) del suelo comprende a un grupo altamente heterogéneo que incluye numerosos compuestos de carbono presentes en los suelos. Estos van desde azúcares fácilmente mineralizables hasta productos complejos y recalcitrantes de transformaciones microbianas cuyos tiempos de residencia varían de unos pocos minutos a cientos de años (Buyanovsky, Aslam, & Wagner, 1994; Robert, 2001).

Los contenidos de MO están estrechamente condicionados por las condiciones climáticas de la zona, principalmente por los contenidos de humedad edáfica y las temperaturas. Las precipitaciones provocan un efecto importante sobre los contenidos de MO, ya que al aumentar los regímenes de precipitación se produce un estímulo al desarrollo vegetativo, lo cual se traduce en un incremento de aportes de MO al suelo. Respecto a la temperatura, la ley de Van't Hoff postula que la velocidad de reacciones químicas se duplica conforme

aumenta 10°C. Esto determina que la tasa de descomposición de la MO sea altamente influenciada por la temperatura, lo cual explica en parte la tendencia de acumulación de MO en suelos de climas fríos (Conti, 2000).

En un principio, la cantidad de MO almacenada en un suelo depende del equilibrio entre la cantidad de carbono que ingresa al suelo y la que sale del mismo. El secuestro de carbono orgánico del suelo es el proceso mediante el cual el carbono se fija desde la atmósfera a través de la vegetación y se almacena en el suelo por procesos de descomposiciones parciales.

Las pérdidas de MO edáficas son producidas mediante las emisiones de gases (CO<sub>2</sub> o CH<sub>4</sub> principalmente) procedentes de la mineralización microbiana mediante la respiración y, en menor medida en compuestos lixiviados y/o erosionados. Por consiguiente, la cantidad de Carbono Orgánico del Suelo (COS) puede ser controlada realizando una gestión entre los aportes de residuos orgánicos y mediante manejos del suelo que minimicen las pérdidas de MO del suelo y promoviendo la retención del mismo en reservas de carbono estables (FAO & ITPS, 2015).

En estudios de balance de carbono edáficos, se opta por utilizar el COS. El COS es un componente de la materia orgánica, y se define como la cantidad de carbono que posee la misma. Para realizar la conversión de MO a COS se utiliza el factor de Van Bemmelen (Van Bemmelen, 1890) que asume un contenido de 58% del contenido de Carbono en la masa de la MO.

Los contenidos de COS son muy dinámicos en el tiempo, viéndose afectados por múltiples factores. En el caso de la agricultura, diversos estudios han demostrado cómo la conversión de pastizales y tierras forestales en tierras de cultivo, pueden provocar la pérdida de entre un 20 y un 40% de las existencias originales de carbono del suelo (Davidson & Ackerman, 1993; Mann, 1986; Ogle, Breidt, & Paustian, 2005).

La materia orgánica (MO) en los suelos proporciona numerosos beneficios, mejorando la retención y biodisponibilidad de nutrientes, la disponibilidad de agua, la aireación y la estabilidad estructural del suelo mediante agregados, promoviendo el desarrollo vegetativo. En este sentido, el contenido de materia orgánica del suelo es el principal determinante de su actividad biológica (FAO, 2002).

Por estos motivos el contenido de materia orgánica en el suelo es un indicador clave de la calidad del suelo, tanto en sus funciones agrícolas, como ambientales. En Argentina diversos trabajos científicos han reportado la utilización de los contenidos de MO como atributos indicadores de la calidad edáfica (Andriulo & Irizar, 2012; Casanovas, Echeverria, & Studdert, 1995; Galantini & Suñer, 2008).

Además de estos beneficios nombrados altamente conocidos, el COS presenta otro servicio ecosistémico que tiene un estrecho vínculo con el cambio climático, pero sin embargo no tan valorado. Se estima que la reserva de Carbono Orgánico en el Suelo (COS) posee alrededor de 1.500 Petagramos de carbono (PgC)<sup>1</sup> en el primer metro de suelo, lo cual supone más carbono que el contenido en la atmósfera (aproximadamente 800 PgC) y la vegetación terrestre (500 PgC) combinados (FAO & ITPS, 2015).

## **Sumideros de Carbono y Cambio Climático**

Las existencias mundiales de COS presentan una distribución espacial y temporalmente variable (FAO, 2017). En este sentido, a nivel global se diferencian determinadas zonas respecto al almacenamiento de carbono, existiendo zonas donde el almacenamiento es

---

<sup>1</sup> PgC = mil millones de toneladas métricas de carbono = 3,7 mil millones de toneladas de CO<sub>2</sub> = 1 GtC (gigatonelada de carbono)

altamente efectivo como es el caso de las turberas o suelos negros (Gougoulias, Clark, & Shaw, 2014; Köchy, Hiederer, & Freibauer, 2015). Por otro lado, se encuentran extensas superficies que presentan bajos contenidos de COS, caracterizadas principalmente por las zonas áridas.

Debido a la relación entre el almacenamiento de carbono y las características climáticas de la zona, el COS posee un vínculo con el cambio climático que puede ser una espada de doble filo, pudiendo actuar tanto como fuente o como sumidero de Gases de Efecto Invernadero (GEI). Este comportamiento del suelo está estrechamente vinculado tanto a los impactos antropogénicos como a las modificaciones ambientales. Después de muchos años de aplicación de sistemas convencionales de labranza manual o mecánica, la mayoría de los suelos del mundo usados para la agricultura han sido esquilados de su materia orgánica (FAO, 2002).

En este contexto, el cambio climático juega un papel fundamental en el flujo del carbono edáfico, motivo por el cual el monitoreo y su respuesta ante el aumento de temperatura se ha convertido un importante objeto de estudio. Las predicciones futuras sobre las consecuencias del cambio climáticas y el aumento de la temperatura en las reservas de carbono son muy variables. Esto se debe a la naturaleza compleja de distribución del COS, la cual se ve afectada por múltiples variables (Cerri et al., 2007; Hengl et al., 2017; Huang, Minasny, McBratney, Padarian, & Triantafyllis, 2018; Kucharik et al., 2001; Luysaert et al., 2010). A pesar de ello se presume que el aumento de las temperaturas y de la frecuencia de eventos extremos conduzca a mayores pérdidas de COS (FAO, 2017).

Si bien el escenario futuro del cambio climático y su influencia en el stock de carbono es muy complejo, existen determinados suelos que por sus características propias desempeñan un papel indiscutible. Por un lado, se encuentran los suelos críticos (turberas, suelos negros y permafrost) los cuales presentan un alto riesgo de perder gran parte de sus contenidos de carbono antes futuros incrementos de temperatura. Estos suelos, si bien presentan una pequeña superficie terrestre, poseen las mayores reservas de COS (Crowther et al., 2016; FAO, 2017).

Y por el otro lado, se encuentran los suelos de las zonas áridas de los cuales forma parte la provincia de Mendoza. Estas tierras son consideradas como componentes fundamentales para la lucha del cambio climático por su potencialidad de secuestro de carbono. Las tierras áridas cubren aproximadamente 430 millones de ha, comprendiendo el 40% de la superficie de la Tierra. Si bien estos suelos se caracterizan por presentar bajo contenidos de MO, estas tierras poseen más de un tercio de la reserva mundial de COS (FAO, 2017). El gran potencial que poseen estos suelos para el secuestro de carbono se debe a que se encuentran lejos de los valores de saturación (United Nations, 2011).

En el caso concreto de Argentina, diversos estudios han demostrado grandes pérdidas de carbono edáfico en numerosos sitios por los cambios de uso del suelo y por las prácticas agrícolas llevadas a cabo (Berhongaray, Alvarez, De Paepe, Caride, & Cantet, 2013; Trossero, Cordone, & Donnet, 2012). En el caso de la región pampeana, la agricultura ha reducido en promedio el 24% de la MO respecto de los suelos prístinos, llegando a valores de 30 al 50% en determinados sitios (Hernán R Sainz Rozas, Hernán E. Echeverría, 2014).

Respecto a los suelos de Mendoza, debido a sus características naturales, los mismos deben ser fuertemente laboreados para poder sobrellevar la agricultura intensiva de cultivos (Venier et al., 2015). Estas prácticas contribuyen a las pérdidas de los escasos contenidos de materia orgánica que pueden contener los suelos. Sin embargo, es necesario recordar que estos suelos al pertenecer a las zonas áridas poseen una gran capacidad de secuestro de carbono. Si se gestionan adecuadamente, estos territorios poseerán la capacidad de contribuir a la mitigación y adaptación al cambio climático.

## 1.4.2 Bases teóricas

### Mapeo Digital del Suelo: SCORPAN

El mapeo digital del suelo (DSM) se basa en el desarrollo de funciones para la ampliación de los datos locales de muestras de suelo, hacia una extensión espacial completa. A diferencia de otros métodos de interpolación, en el DSM se explora la relación cuantitativa entre las variables ambientales y las propiedades del suelo, para predecir esta última con técnicas de predicción multivariada basadas en la correlación (FAO, 2018).

El desarrollo de modelos capaces de relacionar variables ambientales y las características del suelo, tienen sus orígenes en los postulados de Dokuchaev (1898). Él fue un científico ruso del suelo y el primero en relacionar los elementos ambientales en la formación de suelos, considerando al clima, los organismos, el relieve o la topografía, el material original y el tiempo como los principales factores intervinientes (Dobos & Hengl, 2009). Jenny (1941) tradujo la teoría de Dokuchaev al lenguaje de las matemáticas, donde luego McBratney et al. (2003) a partir de esta teoría, formuló el modelo de SCORPAN. El marco de referencia SCORPAN, es un enfoque empírico que se puede expresar como la siguiente ecuación:

$$S_{a[x;y;t]} = f(S_{[x;y;t]}, C_{[x;y;t]}, O_{[x;y;t]}, R_{[x;y;t]}, P_{[x;y;t]}, A_{[x;y;t]}) \quad \text{Ecuación 1}$$

*S<sub>a</sub>*: clase de suelo o atributo a ser modelado.

*S*: Suelo u otras propiedades del suelo o medidas previamente medidas en un punto.

*C*: Clima, propiedades climáticas del medio ambiente en un punto.

*O*: Organismos, incluida la cobertura terrestre y la vegetación; fauna o la actividad humana.

*R*: Relieve, topografía, atributos del paisaje.

*P*: material parental, litología.

*A*: edad, el factor tiempo.

$[x; y; z]$  = ubicación espacial de cada factor

Este enfoque postula que las características edáficas son dependientes de los factores formadores de suelos de la hipótesis de Dokuchaev y de la ecuación de Jenny (Florinsky, 2012) para un sitio y tiempo determinado.

A partir de este modelo, se puede estimar un atributo de suelo en función de su entorno de formación. En este sentido, contando con datos locales del suelo, y datos ambientales (covariables) representativos de los factores del modelo se puede realizar una extensión espacial predictiva de los datos locales.

Diversos estudios han implementado el enfoque del DSM para la predicción de los contenidos de COS, demostrando ser una metodología adecuada (Hengl, Heuvelink, et al., 2015; G. Olmedo, Angelini, Schulz, & Rodriguez, 2018; Ramifehiarivo et al., 2017; Viscarra Rossel, Webster, Bui, & Baldock, 2014).

### Random Forests como herramienta predictiva

Debido a que no existe un mejor método para el mapeo digital de suelos (Guevara et al., 2018), existen numerosas metodologías a seguir para analizar los datos espaciales y generar mapas. Uno de los métodos más utilizados para realizar mapas digitales de suelos es Random Forests (RF) (Breiman, 2001).

Esta técnica pertenece a lo que se conocen con el nombre de “aprendizaje automático” (machine learning en inglés) y es aplicable a diversos problemas de minería de datos,

reconocimiento de patrones, regresión y clasificación. Varios estudios (Hengl, Heuvelink, et al., 2015; Heung et al., 2016; Nussbaum et al., 2018; G. Olmedo et al., 2018; Prasad, Iverson, & Liaw, 2006; Vaysse & Lagacherie, 2015) ya han demostrado que RF es una técnica prometedora para la predicción espacial de propiedades edáficas.

RF es un conjunto de árboles de clasificación, donde cada árbol contribuye con un solo voto para la asignación de la clase más frecuente a los datos de entrada (Breiman, 2001). Este modelo utiliza un subconjunto aleatorio de características de entrada o variables predictivas en la división de cada nodo, en lugar de usar las mejores variables, lo que reduce el error de generalización. Además, para aumentar la diversidad de los árboles, una RF utiliza ensacado o agregación de arranque para hacer que los árboles crezcan a partir de diferentes datos de entrenamiento (Rodríguez-Galiano, Chica-Olmo, Abarca-Hernandez, Atkinson, & Jeganathan, 2012).

Esta técnica genera estimaciones de qué variables son importantes en la clasificación y estimaciones internas de los errores de predicción a medida que avanza la construcción forestal. Además, tiene un método efectivo para estimar los datos faltantes, manteniendo así la precisión cuando falta una gran parte de los datos (Moudani, W., Shahin, A., Chakik, F., & Rajab, 2017).

## 2. Metodología

El siguiente trabajo fue elaborado siguiendo la metodología propuesta en el libro Soil Organic Carbon Mapping Cookbook, 2nd edition (FAO, 2018). El mismo proporciona directrices técnicas para preparar y evaluar los conjuntos de datos espaciales del suelo, y de esta manera determinar las existencias de carbono orgánico del suelo en toda la extensión del área de estudio, a partir de muestras locales. La metodología incluye diversas etapas, comenzando con la preparación de los datos muestreados del suelo y datos ambientales. Luego mediante un modelado de datos espaciales considerando el modelo de SCORPAN, se elabora el mapa digital del contenido de carbono, el cual es finalmente validado realizando validación cruzada. Para ello se separaron los datos en 4 grupos aleatorios de igual tamaño y se realizaron 4 predicciones individuales sin utilizar un grupo de datos para cada una de ellas. Luego se efectuó la validación de las predicciones para cada uno de los modelos predictivos utilizando el set de datos que no fue tenido en cuenta para su generación.

En el presente trabajo, del marco de referencia SCORPAN se utilizaron los factores Organismos, Clima y Relieve del modelo debido a la calidad y a la facilidad de obtener los datos. Para cada factor se generaron diversas covariables, las mismas son variables representativas de cada factor. Trabajar con múltiples covariables para cada factor es de gran importancia ya que no siempre son las mismas las que mejor se ajustan al modelo, dependiendo del caso de estudio.

Debido a que no existe un mejor método para el mapeo de suelos digitales (Guevara et al., 2018), el libro ofrece numerosas metodologías a seguir para analizar los datos espaciales y la aplicación de diferentes modelos de interpolación para generar mapas digitales de suelo. En el presente trabajo se utilizó únicamente una metodología de las propuestas, conocida como Random Forest (RF) (Breiman, 2001).

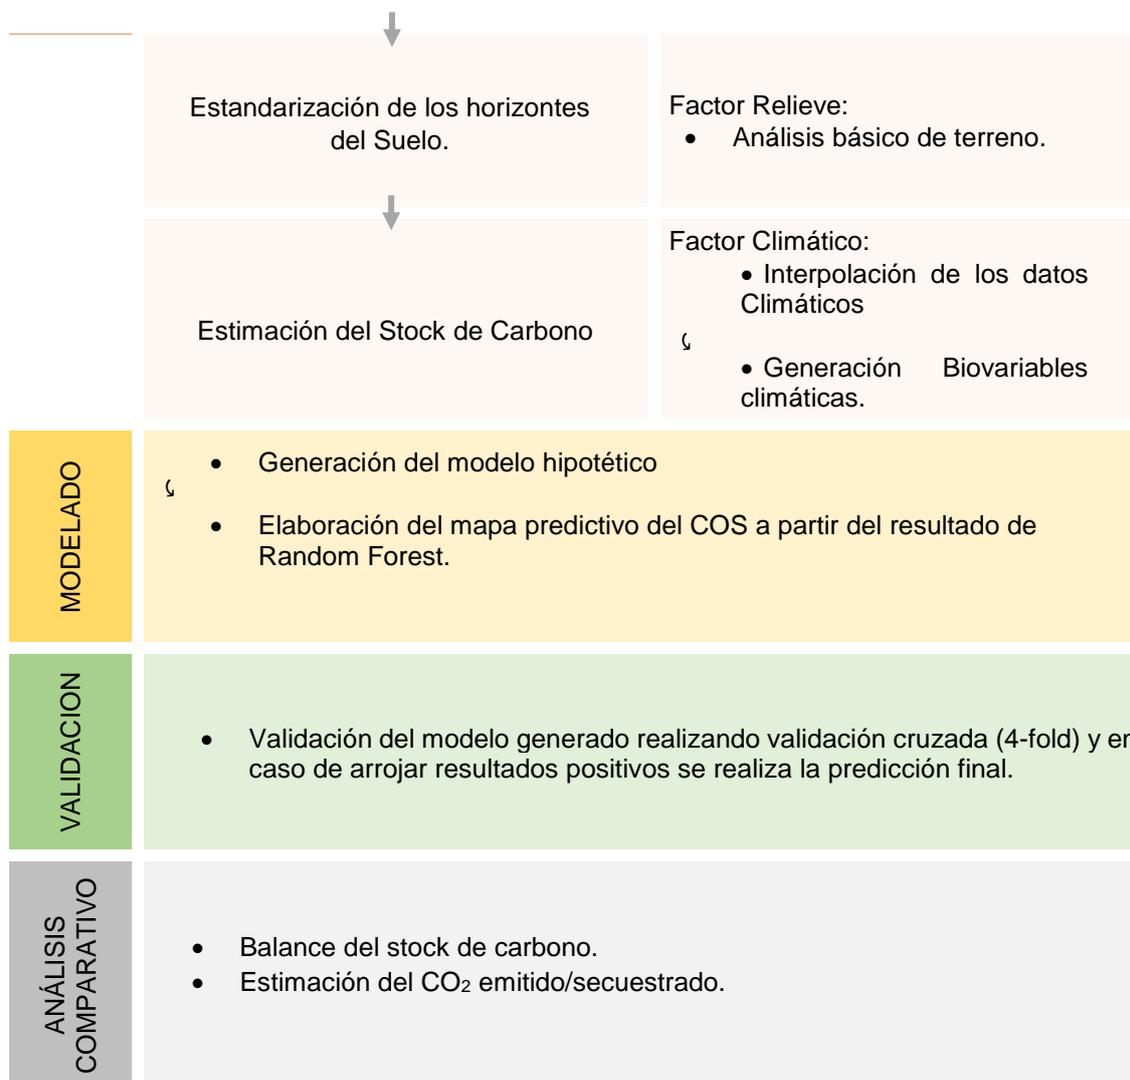
Al integrar el modelo de SCORPAN (Ecuación 1) (McBratney, Mendonça Santos, & Minasny, 2003) con la metodología de Random Forest como modelo predictivo, el modelo es transformado en el siguiente:

$$SOC_{(x,y,t)} \sim RandomForest(E_{x,y,t}) \quad \text{Ecuación 2}$$

donde las estimaciones del carbono orgánico del suelo (COS) para un sitio específico ( $x$  e  $y$ ) para un período específico de tiempo ( $t$ ) se pueden modelar como una función de bosque aleatorio (RandomForest) del entorno de formación del suelo ( $E_{x,y,t}$ ), que está representado por los factores de predicción COS del modelo de SCORPAN.

A continuación, se detalla un resumen de los pasos metodológicos empleados para realizar el análisis de los datos:

ETAPAS	PROCESOS	
PREPARACION DE LOS DATOS	Procesamiento de las muestras de Suelo	Elaboración de las Covariables
	Estandarización en la estructura de la base de datos.	Preparación de la base de datos Climáticos e Imágenes Satelitales
	Estimación de la densidad aparente del suelo	Factor Organismos: <ul style="list-style-type: none"> <li>• Calculo de NDVI</li> </ul>



## Etapa 1: Preparación de los datos

### Procesamiento de las muestras de Suelo

En los pasos iniciales de la preparación de las bases de datos de las muestras de suelo, se realiza una estimación de las densidades aparentes (DAp) de los suelos a partir del contenido de materia orgánica del mismo. Este valor es de suma importancia para poder obtener los valores del stock de carbono (g/cm<sup>3</sup>) a partir del contenido de Materia Orgánica (g%g), para ello se utiliza el método de Honeysett & Ratkowsky, 1989, donde:

$$DAp = \frac{1}{0,564 + 0,0556 * MO} \quad \text{Ecuación 3}$$

El COS al ser un componente del MOS, conociendo los valores de los contenidos de materia orgánica (g%g) del suelo se puede determinar el contenido del carbono orgánico del mismo utilizando el factor de Van Bemmelen (Van Bemmelen, 1890), donde :

$$COS = MO / 1,724 \quad \text{Ecuación 4}$$

Además se realizó un ajuste de los datos, utilizando el spline de áreas iguales (Ponce Hernandez, Marriott, & Beckett, 1986) desarrollado en el paquete de R GSIF (Hengl, 2019) con el objetivo de estandarizar los horizontes de suelo a 30 cm.

De esta manera, considerando el espesor de los primeros 30 cm de profundidad del suelo, se estimó los contenidos de stock de carbono sobre una superficie de 1 m<sup>2</sup> (kg de C / m<sup>2</sup>) a partir del contenido de carbono orgánico (COS) y de la densidad aparente del suelo, utilizando la siguiente ecuación (desarrollada en el Anexo):

$$Stock(kg/m^2) = 3\left(\frac{kg \cdot cm^3}{g \cdot m^2}\right) * DAp(g/cm^3) * COS(\%)$$

Ecuación 5

### Elaboración de las Covariables

Como se mencionó anteriormente, para poder realizar las predicciones de los contenidos del stock de carbono edáfico, utilizando el modelo expresado en la *Ecuación 2*, es necesario generar covariables ambientales ajustadas a cada uno de los factores considerados. En este sentido, se determinaron un conjunto de 27 covariables ambientales para cada set de datos del suelo.

Una descripción más detallada de cada una de estas covariables, su metodología de elaboración y su relación con la pedogénesis se encuentra en los próximos capítulos. En la tabla 1 se detallan las covariables que serán utilizadas para realizar las predicciones de los contenidos del Stock de Carbono edáfico.

**Tabla 1:** Factores y covariables a utilizar en el modelo de SCORPAN.

Factores	Covariables
<b>A. Organismos</b>	A.1 NDVI de Verano.
	A.2 NDVI de Invierno.
<b>B. Clima</b>	B.1 Temperatura media anual.
	B.2 Isotermia (BIO2 / BIO7) (* 100).
	B.3 Temperatura máxima del mes más cálido.
	B.4 Temperatura mínima del mes más frío.
	B.5 Rango anual de temperatura (B.5 – B.6).
	B.6 Temperatura media del trimestre más húmedo.
	B.7 Temperatura media del trimestre más seco.
	B.8 Temperatura media del trimestre más cálido.
	B.9 Temperatura media del cuarto más frío.
	B.10 Precipitación total (anual).
	B.11 Precipitación del mes más húmedo.
	B.12 Estacionalidad de la precipitación (coeficiente de variación).
	B.13 Precipitación del trimestre más húmedo.
	B.14 Precipitación del trimestre más cálido.
<b>C. Relieve</b>	C.1 Acumulación de flujo.
	C.2 Curvatura longitudinal.
	C.3 Curvatura seccional transversal.
	C.4 Distancia vertical a la red de canales.
	C.5 Factor LS.
	C.6 Humedad topográfica.
	C.7 Índice de convergencia.
	C.8 Pendiente.
	C.9 Posición relativa de la pendiente.

### Etapa 2: Modelado

A partir del modelo de la Ecuación 2, cada uno de los modelos predictivos del contenido del Stock de Carbono en el Suelo presentará la siguiente hipótesis:

$$SOC \left( \frac{kg}{m^2} \right) \sim NDVI \text{ Verano} + NDVI \text{ Invierno} + Temp. \text{ media anual}$$

- + Isotermia + Temp. máx. del mes más cálido
- + Temp. mín. del mes más frío
- + Rango anual de temp. + Temp. media del trim. más húmedo
- + Temp. media del trim. más seco
- + Temp. media del trim. más cálido
- + Temp. media del cuarto más frío + Precip. total (anual)
- + Precip. del mes más húmedo
- + Estacionalidad de la precip. + Precip. del trim. más húmedo
- + Precip. del trim. más cálido + Acumulación de flujo
- + Curvatura Longitudinal + Curvatura seccional transversal
- + Distancia vertical a la red de canales + Factor LS
- + Humedad topográfica + Índice de convergencia
- + Pendiente + Posición relativa de la pendiente
- + Profundidad del valle

Random Forests permite modificar el número de parámetros utilizados para la predicción que se utilizan aleatoriamente en cada árbol (conocido como “*mtry*”). Debido a que el ajuste de los parámetros principales de RF puede llevar mucho tiempo en términos computacionales, se realizó validación cruzada de 10 iteraciones (10-fold cross-validation) para determinar en cada modelo el valor de *mtry* más apropiado. Respecto al número de árboles utilizado en cada modelo (“*ntree*”) se utilizó una cantidad de 500.

### Etapa 3: Validación

Previo a la elaboración de las predicciones del stock de carbono, se realizó una validación de cada modelo (Ecuación 6) para determinar su eficiencia mediante una validación cruzada de 4 grupos sin reposición (4-fold cross-validation) (FAO, 2018; Hastie, 2017).

Esta metodología consiste en dividir el grupo de datos en *k* partes iguales, luego elaborar un modelo predictivo utilizando *k*-1 grupos y predecir los valores del grupo que no fue utilizado para el modelamiento. Este proceso se realiza una vez para cada grupo, y en cada iteración se analizan los valores predichos vs los observados. De esta manera, en cada iteración se obtienen diversos parámetros estadísticos que finalmente son promediados.

Los parámetros estadísticos utilizados para la evaluación de la certidumbre fueron el error medio (ME), el error medio absoluto (MAE), el error cuadrático medio (MSE), la raíz cuadrada del error cuadrático medio (RMSE) y la cantidad de varianza explicada (AVE) (Angelini, Heuvelink, Kempen, & Morrás, 2016). La metodología del cálculo y la interpretación de cada uno de estos parámetros estadísticos se encuentra en el capítulo 7 del libro *Soil Organic Carbon Mapping Cookbook, 2nd edition* (FAO, 2018).

### Etapa 4: Análisis Comparativo

A partir de los mapas de los stocks elaborados para cada set de datos, se realizó un análisis comparando los valores de los mismos sitios para distintos tiempos. Para realizar las conversiones de carbono a su estado oxidado CO<sub>2</sub> se utilizó la metodología propuesta por IPCC en *Guidelines for National Greenhouse Gas Inventories generic methodologies applicable to multiple landuse categories 2006*. Esta metodología supone que las disminuciones de los contenidos de carbono se deben exclusivamente a procesos oxidativos y se basa en la relación de pesos moleculares del carbono y del dióxido de carbono (12 y 44 respectivamente), donde:

$$Emisiones\ CO_2(kg/m^2) = -(Stock_{final} - Stock_{inicial}) \cdot (44/12) \quad \text{Ecuación 7}$$

De esta manera, los resultados negativos indican sitios donde se produjo un secuestro de carbono, contrariamente a los valores positivos. Utilizando la ecuación de Gases Ideales (Daivid E. Goldberg, 2007), en condiciones normales de presión y temperatura<sup>2</sup>(IUPAC, 2014), se puede determinar los volúmenes de CO<sub>2</sub> emitidos y secuestrados:

$$Vol.\ de\ CO_2\ Emitidos\ \left(\frac{m^3}{m^2}\right) = \frac{Emisiones\ \left(\frac{kg}{m^2}\right) \cdot 273,1K \cdot 8,31\ \left(\frac{m^3 \cdot Pa}{K \cdot mol}\right)}{10^5 Pa \cdot 44kg} \quad \text{Ecuación 8}$$

---

<sup>2</sup> Temperatura de 273,15 K , presión de 10<sup>5</sup> pascales y R = 8,3144.

### 3. Materiales

#### 3.1 Zona de Estudio y Muestras de Suelo.

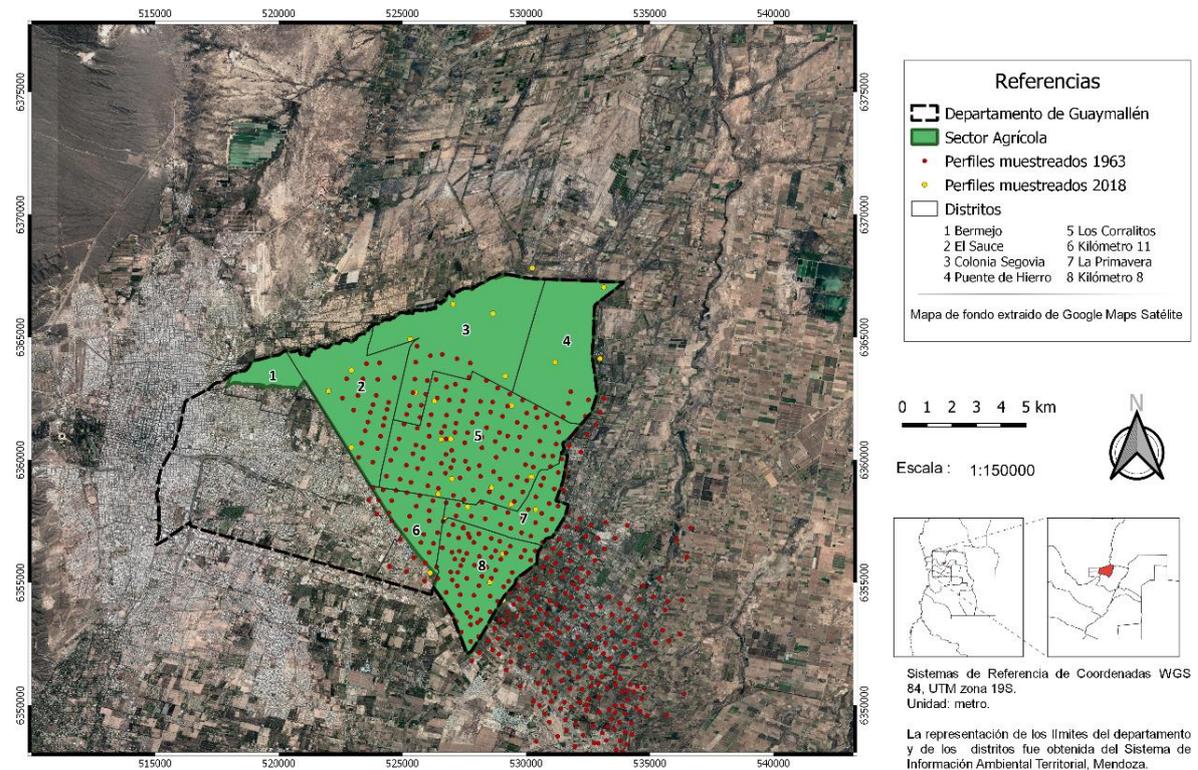
La zona de estudio comprende el sector agrícola del departamento de Guaymallén (Figura 1), cuyos límites fueron obtenidos a partir del informe técnico de aptitud de suelos realizado para el departamento (F. G. Olmedo & Cara, 2019). En la misma figura también se observan las distribuciones espaciales de las muestras de suelos y los límites distritales de la zona de estudio.

El estudio fue realizado a partir de 2 series de datos de suelos de distintos sitios ubicados en la zona de estudio, pertenecientes al Centro Regional Mendoza - San Juan, del Instituto Nacional de Tecnología Agropecuaria (INTA) (Figura 1). Los datos corresponden a muestreos llevados a cabo en los años 1963 y 2018.

En cuanto al muestreo del año 1963, el mismo comprende 1533 muestras de 511 sitios diferentes, a tres profundidades relativas según cada perfil, comprendidas desde la superficie hasta 135 cm de profundidad (Perez Valenzuela, Salcedo, De Cara, & Capuccino, 2000).

Respecto al muestreo del suelo realizado en el año 2018, el mismo estuvo a cargo de G. Olmedo y L. Cara para el cual se extrajeron un total de 69 muestras de 29 sitios del departamento de Guaymallén establecidos de antemano. Para su determinación, se utilizaron distintas variables climáticas, vegetativas, visuales y topográficas. Luego mediante un análisis estadístico se determinaron los sitios de máxima variabilidad del área para disminuir el error de muestreo.

En cuanto a la metodología empleada para analizar los contenidos de Materia Orgánica, en todas las series de datos se utilizó el método de Walkley & Black (Walkley & Black, 1934).

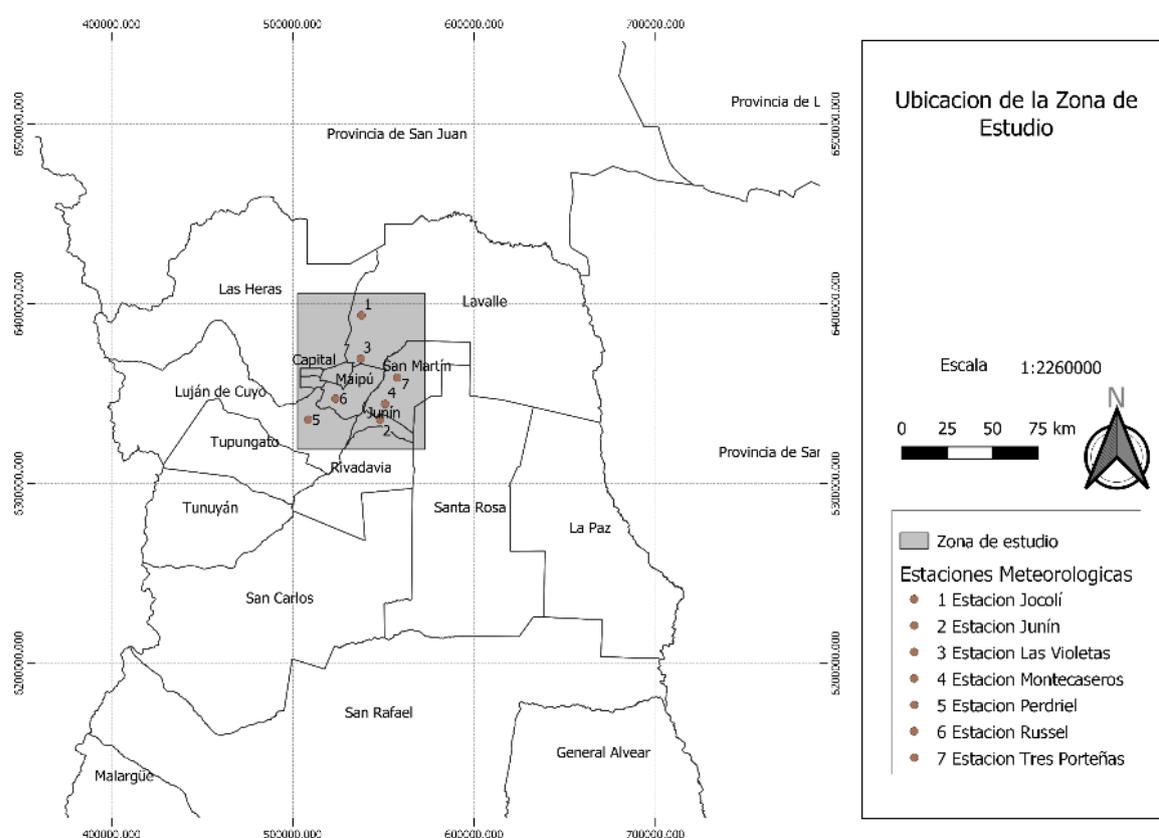


**Figura 1:** Mapa de la zona de estudio con la ubicación de las muestras utilizadas para cada modelo predictivo.

### 3.2 Datos Climatológicos

Los datos climatológicos que fueron utilizados, fueron obtenidos del sitio web de la Dirección de Agricultura y Contingencias Climáticas de Mendoza (D.A.C.C., 2018). Las estaciones meteorológicas que fueron tenidas en cuenta para realizar el análisis fueron aquellas que se encontraban localizadas en un radio menor de 30 km de la zona de estudio, el cual comprende las siguientes estaciones climatológicas: Junín, Jocolí, Russel, Tres Porteñas, Montecaseros, Las Violetas y Perdiel (Figura 2).

Para la elaboración de los mapas climatológicos, se consideraron todos los datos mensuales de precipitación, temperatura máxima y temperatura mínima disponibles de las estaciones meteorológicas. La serie temporal de datos disponibles depende de cada estación, por este motivo se utilizaron los datos de los años 1997 a 2018 para las estaciones de Junín y Tres Porteñas; 2006 a 2018 para las estaciones de Jocolí, Las violetas, Perdiel y Russel; y los años 2007 a 2018 para la estación de Montecaseros.



**Figura 2** Ubicación de las estaciones meteorológicas y de la zona de estudio

### 3.3 Imágenes Satelitales

Respecto a los Modelos Digitales de Elevación (DEM), se utilizaron imágenes de radar de la Misión Topográfica Shuttle (SRTM) que cuentan con una resolución espacial 1 arcosegundo. En la siguiente tabla se detallan las imágenes utilizadas:

**Tabla 2:** Modelos Digitales de Elevación utilizados

ID del producto	Fecha de Adquisición	Fecha de Publicación
SRTM1S34W070V3	11-FEB-00	23-SEP-14
SRTM1S34W069V3	11-FEB-00	23-SEP-14
SRTM1S33W070V3	11-FEB-00	23-SEP-14

En cuanto a las imágenes multiespectrales para el cálculo del NDVI, se utilizaron imágenes de los satélites Landsat 3, 5 y 8 comprendiendo distintos años desde el 1978 hasta 2018. Las unidades de las imágenes que con las que se realizaron los cálculos fueron Números Digitales (DN). Es importante aclarar que existe una pequeña discrepancia en el rango de longitud de onda de las bandas utilizadas para calcular el NDVI.

Debido al largo periodo de tiempo de estudio, se utilizaron las siguientes bandas de las imágenes satelitales comprendiendo distintos años desde el 1978 hasta la actualidad:

**Tabla 3:** Imágenes Satelitales utilizadas para la determinación del factor Organismos

Satélite	Sensor	Banda Rojo (µm)	Banda NIR (µm)	Landsat Scene ID	Fecha de adquisición
Landsat 3	(MSS) <sup>a</sup>	0,6 - 0,7	0,7 - 0,8	LM32490831979176AAA03	25/06/1979
Landsat 5	(TM) <sup>b</sup>	0,63 - 0,69	0,77 - 0,90	LT52320831988219CUB00 LT52320831988059CUB00	06/08/1988 28/02/1988
Landsat 8	(OLI) <sup>c</sup>	0,636 - 0,673	0,851 - 0,879	LC82320832018205LGN00 LC82320832018045LGN00	24/07/2018 14/02/2018

<sup>a</sup>MSS: Multispectral Scanner System

<sup>b</sup>TM: Thematic Mapper

<sup>c</sup>OLI: Operational Land Imager

Todas las imágenes fueron adquiridas del sitio web del Servicio Geológico de los Estados Unidos (United States Geological Survey, 2018).

### 3.4 Programas informáticos utilizados para el procesamiento de la información:

Se emplearon los siguientes softwares informáticos para el desarrollo de la investigación:

- System for Automated Geoscientific Analyses (SAGA) (Conrad et al., 2016). Es una plataforma eficaz y fácil para la puesta en práctica de métodos geocientíficos, se utiliza para realizar el procesamiento de datos de imágenes satelitales y realizar cálculos de diversas covariables.
- QGIS v.3.4 (QGIS Development Team, 2009) QGIS es un Sistema de Información Geográfica de código abierto, que permite el procesamiento de datos espaciales de diversos tipos.
- R (Team & R Development Core Team, 2019b): es un software y un lenguaje de programación con un enfoque al análisis estadístico. Se trata de uno de los lenguajes de programación más utilizados en investigación por la comunidad estadística; siendo además muy popular en el campo de la minería de datos. Los principales paquetes que fueron utilizados para el procesamiento de los datos, según el área de estudio fueron los siguientes:

#### Ciencias del suelo y pedometría

- aqp: Algoritmos para la pedología cuantitativa. Una colección de algoritmos relacionados con el modelado de los recursos del suelo, la clasificación del suelo, la agregación del perfil del suelo y la visualización (Beaudette, Roudier, & O'Geen, 2013).
- GSIF : Global Soil Information Facility (GSIF). Herramientas, funciones y conjuntos de datos de muestra para el mapeo digital de suelos. Herramientas GSIF (estándares y funciones) y conjuntos de datos de muestra para el mapeo global de suelos. (Hengl, 2019).

- Soiltexture: El Asistente de textura de suelos es un conjunto de funciones R diseñadas para producir triángulos de textura (también llamados diagramas de textura, diagramas de textura, gráficos de textura ternaria), clasificar y transformar datos de texturas del suelo (Moeys, 2018).

#### Análisis Espacial de los datos:

- raster: Lectura, escritura, manipulación, análisis y modelado de datos espaciales cuadrículados. El paquete implementa funciones básicas y de alto nivel, se admite el procesamiento de archivos muy grandes.(Hijmans, 2019).
- rgdal: proporciona enlaces a la Biblioteca de abstracción de datos geoespaciales de Frank Warmerdam (GDAL).(Bivand, Keitt, & Rowlingson, 2019).
- sf: El paquete proporciona una mejora en sp y rgdal para conjuntos de datos espaciales. Está utilizando el nuevo estándar Simple Features (SF) que se implementa ampliamente en bases de datos espaciales (PostGIS, ESRI ArcGIS) y forma la base de datos vectoriales para bibliotecas como GDAL y estándares web como GeoJSON ([http:// geojson. org /](http://geojson.org/)).(E. Pebesma, 2018).
- sp: El paquete proporciona clases y métodos para datos espaciales. Las clases documentan dónde reside la información de ubicación espacial, para datos 2D o 3D (E. J. Pebesma & Bivand, 2005).

#### Modelamiento:

- automap: este paquete realiza una interpolación automática al estimar automáticamente el variograma y luego llamar a gstat. (P. H. Hiemstra, Pebesma, Twenh"ofel, & Heuvelink, 2008)
- Caret: amplia gama de funciones para entrenar y trazar modelos de clasificación y regresión. (Jed Wing et al., 2018)
- randomForest: implementa el algoritmo de bosque aleatorio de Breiman (basado en el código Fortran original de Breiman y Cutler) para la clasificación y regresión. También se puede utilizar en modo no supervisado para evaluar las proximidades entre los puntos de datos.(Guevara et al., 2018)(Liaw & Wiener, 2002)
- gstat: modelado de variogramas con simulación o indicador (co) kriging simple, ordinario y universal, gaussiano secuencial o indicador (co). El paquete incluye funciones de utilidad de trazado de mapas de variogramas y variogramas (E. J. Pebesma, 2004)(Gräler, Pebesma, & Heuvelink, 2016).
- nnet: software para redes neuronales de alimentación directa con una sola capa oculta, y para modelos multinacionales de log lineales (Venables & Ripley, 2002).

#### Mapeo y trazado

- ggplot2: además de usar la funcionalidad de trazado base, este es otro paquete útil de trazado.(Wickham, 2016)
- plotKML: escribe objetos sp-class, spacetime-class, raster-class y spatial y spatiotemporal similares en KML siguiendo algunas reglas cartográficas básicas (Hengl, Roudier, Beaudette, & Pebesma, 2015).

## 4. Covariables Climáticas

El clima como factor formador de suelos (Conti, 2000) controla el tipo e intensidad de sus procesos formadores, por estos motivos el clima es considerado como uno de los factores activos con mayor influencia en el proceso edafogenético (Porta, López-Acevedo, & Roquero, 2003).

Los regímenes de temperaturas y de precipitaciones por un lado determinan diversas características edáficas como la evapotranspiración y el balance hídrico, y por el otro condicionan los procesos de meteorización (Conti, 2000). El clima al condicionar el desarrollo de organismos participa activamente en el ciclo de los componentes del suelo, principalmente del carbono orgánico, regulando las tasas de incorporación y degradación de la materia orgánica. Por estos motivos, el clima posee un papel indiscutible como componente del modelo SCORPAN (McBratney et al., 2003).

Un buen método para describir la relación entre el clima y el desarrollo de actividades de los organismos es mediante los índices bioclimáticos (O'Donnell & Ignizio, 2012). Los índices bioclimáticos son un conjunto de medidas que representan un conjunto de condiciones climáticas que están relacionadas con la fisiología de las especies. Las mismas representan tendencias anuales o estacionalidades y factores ambientales extremos o limitantes.

Para poder generar variables bioclimáticas, es necesario contar con mapas climatológicos mensuales de temperaturas mínimas, temperaturas máximas y precipitaciones. Por este motivo, se realizaron múltiples interpolaciones espaciales de los datos climatológicos utilizando el método conocido como Regresión-kriging (RK) (Hengl, 2009; Hengl, Heuvelink, & Rossiter, 2007). Para ello se utilizaron los datos climatológicos de la D.A.C.C. y el Modelo Digital de Elevación (DEM) del satélite SRTM como variable regresora del modelo. Las características del método se encuentran detalladas en Hengl et al., 2007.

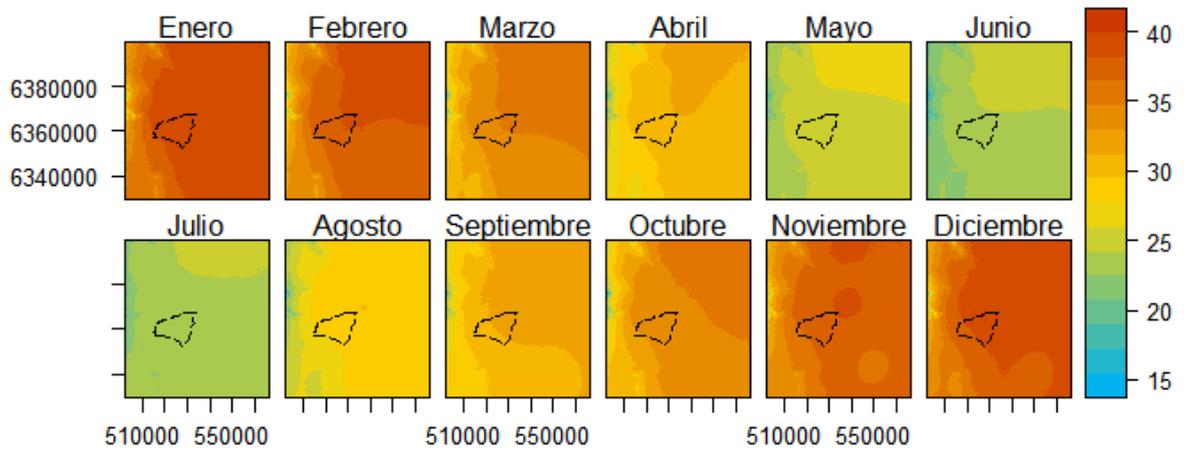
En este sentido, se elaboró un mapa climatológico para cada mes del año y para cada variable climatológica considerada: temperatura máxima, temperatura mínima y precipitación, elaborándose de esta manera un total de 36 mapas climatológicos. Los datos interpolados fueron validados utilizando la técnica de validación cruzada.

A partir de los mapas climatológicos elaborados, se elaboraron 14 mapas de los índices bioclimatológicos utilizando el paquete *dismo* (Hijmans, Phillips, Leathwick, & Elith, 2017). Se asumió que en el periodo de estudio los valores de estas variables no sufrieron modificaciones significativas; por este motivo se integraron a las mismas variables climáticas para todos los modelos predictivos.

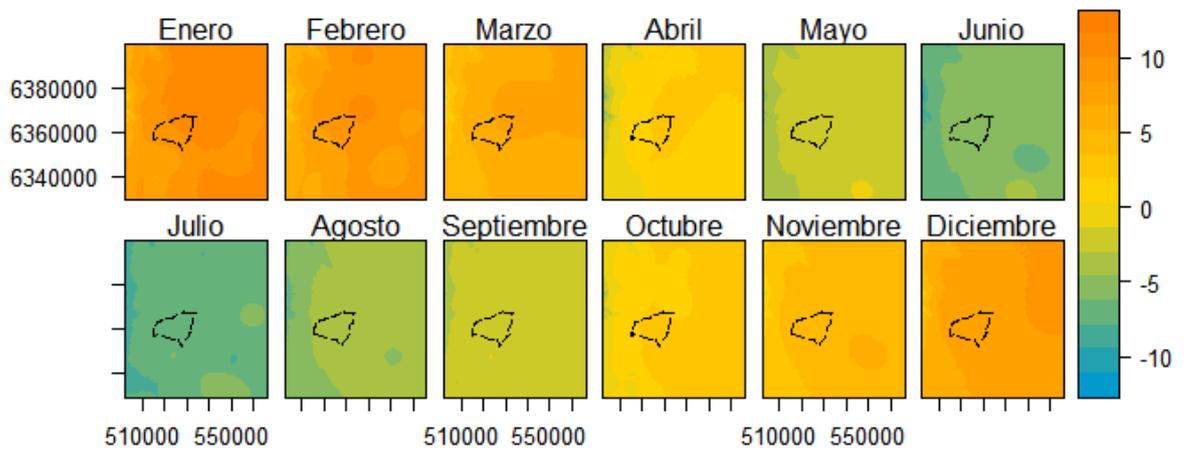
Para la interpolación espacial de los datos y su posterior validación se utilizaron los paquetes *automap* (P. Hiemstra, 2015), *gstat* (Gräler et al., 2016), *sp* (E. J. Pebesma & Bivand, 2005) y *Raster* (Hijmans, 2019) del software R v3.5.2 (Team & R Development Core Team, 2019a). El resultado de la validación espacial de los datos se encuentra en los anexos.

Se pueden observar en la Figura 3 los resultados de las interpolaciones espaciales climáticas y en la Figura 4 el resultado de variables bioclimáticas generadas a partir de las interpolaciones climáticas.

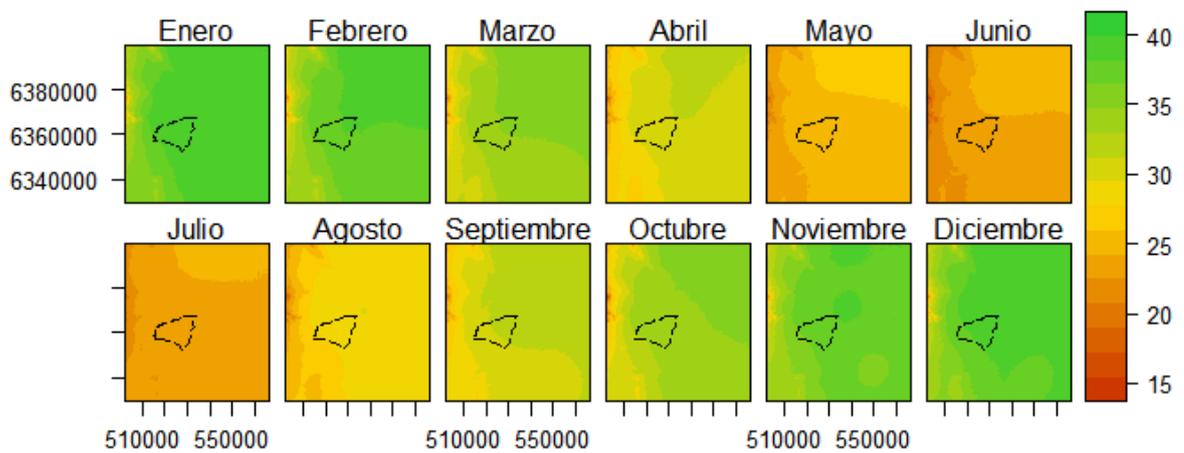
### Temperaturas Mensuales Máximas



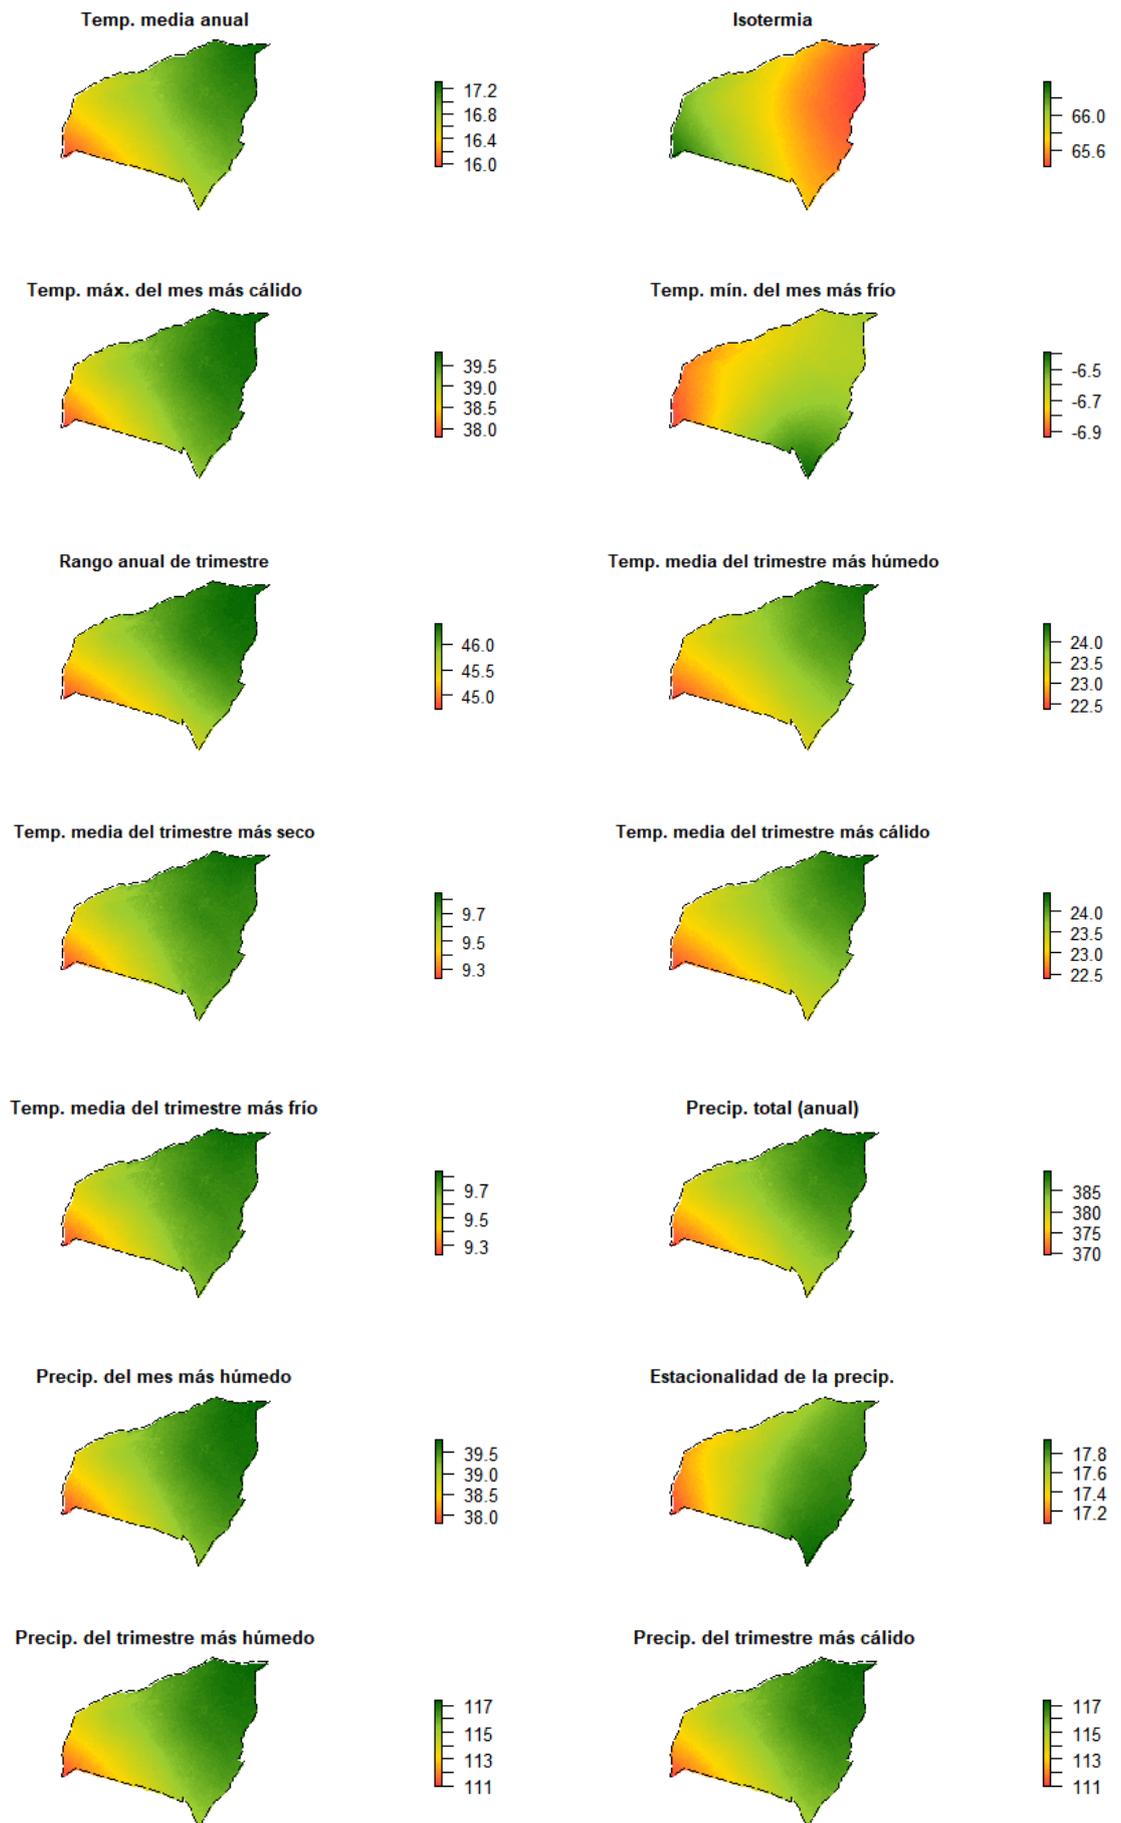
### Temperatura Mensuales Mínimas



### Precipitaciones Mensuales



**Figura 3:** Mapas climáticos elaborados utilizando *Regression-Kriging*, observándose el área de estudio en el polígono representado.



**Figura 4:** Mapas bioclimáticos elaborados para el área de estudio.

## 5. Covariables Topográficas.

El factor Relieve (R) como factor de formación de suelo, a diferencia de los factores organismos y clima, es considerado como un factor pasivo, ya que sobre él actúan otros factores que lo transforman (Conti, 2000). La topografía desempeña un papel muy importante en el desarrollo y modificación de los suelos influyendo principalmente en los procesos hidrológicos, erosivos y transporte de materiales.

Debido a esta estrecha relación entre la topografía y las propiedades del suelo, los modelos digitales de elevación (DEM) son comúnmente utilizados en los mapeos digitales de suelos para la elaboración de múltiples variables geomorfométricas (Dobos & Hengl, 2009).

Respecto a los atributos edáficos, existen numerosos parámetros topográficos que muestran una relación estrecha con las propiedades edáficas; sin embargo, considerados de manera individual poseen un bajo poder predictivo. No obstante, cuando estos parámetros son combinados, el valor predictivo puede mejorarse significativamente (Dobos & Hengl, 2009). Por estos motivos, es de gran importancia contar con múltiples parámetros topográficos para realizar predicciones de los atributos edáficos.

Actualmente, con el avance tecnológico existen múltiples herramientas que permiten generar numerosos parámetros topográficos descriptivos. Un grupo de estas variables es conocido como variables geomorfométricas básicas, las cuales son las que se derivan directamente del DEM, independientemente de sus procesos formadores. En este sentido, dichas variables son consideradas como un conjunto de medidas descriptivas de las formas superficiales, representando parámetros topográficos (por ejemplo, pendiente, índice de convergencia, índice topográfico de humedad) (Pike, Evans, & Hengl, 2009). De esta manera, cada variable tiene su estrecho vínculo con procesos relacionados con la pedogénesis, pudiendo actuar como mecanismo de acumulación, denudación, translocación y/o transformación de materia (Abarca, 2010).

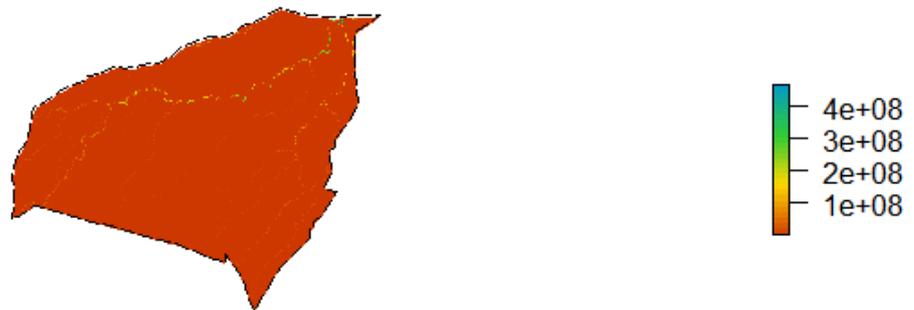
Estos parámetros pueden ser exitosamente utilizados en las predicciones de los contenidos de materia orgánica del suelo, ya que presentan un estrecho vínculo con el ciclo del carbono. De los parámetros topográficos, principalmente el índice topográfico de humedad, la curvatura, el gradiente de pendiente y las variables de acumulación de flujo, han demostrado tener una contribución significativa a la estimación del contenido de carbono del suelo (FAO, 2018; Gessler, Chadwick, Chamran, Althouse, & Holmes, 2000; McKenzie & Ryan, 1999; G. Olmedo et al., 2018).

Por estos motivos, la utilización del factor Relieve en el modelo SCORPAN (McBratney et al., 2003) desempeña un papel clave para la modelización de las propiedades edáficas. En el presente trabajo se determinaron múltiples covariables topográficas básicas representativas del factor relieve a partir del Modelo Digital de Elevación. Para la generación de las covariables topográficas, se utilizó el software SAGA 2.3.2 (O. Conrad, 2012).

Es necesario tener en cuenta que, debido a los grandes periodos de tiempo en los cuales actúan los procesos orográficos y tectónicos en la modificación del relieve, se consideró que las características topográficas han permanecido invariables en el periodo de estudio (1963 – 2018). Por este motivo se utilizaron las mismas variables topográficas generadas a partir del modelo digital de elevación para los dos años de estudio (1963 y 2018). En el siguiente apartado se describen las variables geomorfométricas utilizadas y su relación con los procesos pedogenéticos del suelo.

### **Acumulación de flujo.**

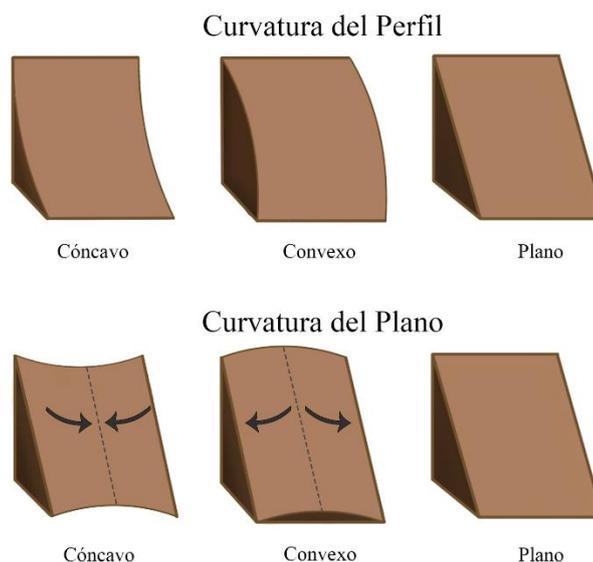
Este algoritmo está basado en el concepto de “cuenca hidrográfica” pero aplicado a los modelos digitales de elevación, que redefine este concepto como el conjunto de celdas (píxeles) donde el agua fluye hacia otra celda definida. En este sentido, el algoritmo procesa un DEM y el valor resultante para cada celda corresponde al área de todas las celdas situadas aguas arriba y que se encuentran interconectadas con ésta (V. Olaya, 2009). El valor resultante está estrechamente relacionado con la magnitud del flujo de materia (Abarca, 2010).



**Figura 5:** Covariables Índice de Acumulación de Flujo.

**Curvatura del Perfil y Curvatura del Plano:  
Índice de Curvatura longitudinal e Índice Curvatura Seccional transversal.**

La curvatura topográfica es considerada como el grado de concavidad o convexidad de una grilla, existiendo dos planos sobre los cuales se realiza el análisis, el perfil y el plano (Figura 6). La curvatura del perfil es aquella que es evaluada paralelamente a la dirección de la pendiente máxima, mientras que la curvatura del plano es perpendicular a la máxima pendiente. Según Abarca, 2010 y Moore, Grayson, & Ladson, 1991; estos parámetros actúan como mecanismos de acumulación y/o denudación de materiales, y como concentración y/o dispersión de las líneas del flujo en los procesos edafogénéticos.



**Figura 6:** Representación gráfica de la curvatura del perfil y del plano topográfico.

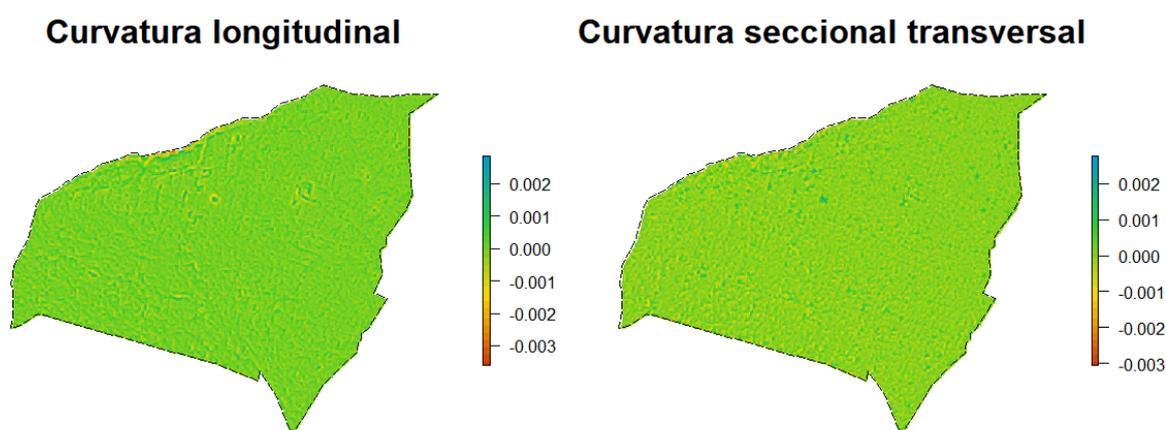
La curvatura del plano es un gran indicador del comportamiento del agua sobre el terreno. Una curvatura del plano cóncava indica la propensión del agua a converger sobre el sitio cuando fluye a través de la pendiente predominante, mientras que una curvatura convexa

indica la divergencia del flujo hacia los laterales. Por estos motivos, la curvatura del plano puede utilizarse como un indicador del contenido de agua en el suelo y características edáficas como la textura, estructura, fertilidad y contenidos de MO (Abarca, 2010).

Respecto a la curvatura del perfil, este parámetro indica los cambios de velocidad del flujo, regulando los procesos de transporte y deposición del sedimento productos de la erosión. Perfiles de curvatura convexa indican una aceleración del flujo, donde incrementa la energía cinética y por ende los procesos erosivos (V. Olaya, 2009).

Al trabajar con ambos parámetros de manera combinada, se pueden obtener diversas generalidades del perfil, como por ejemplo sobre la erosión neta del perfil edáfico. En zonas con curvaturas del plano cóncavas y curvaturas del perfil convexas, hay una gran probabilidad de que el suelo sufra una mayor erosión que en superficies con diferentes configuraciones.

La curvatura del plano y del perfil fueron obtenidas mediante el índice de curvatura seccional transversal y el índice de curvatura longitudinal respectivamente. El algoritmo que realiza estos cálculos arroja resultados positivos para aquellas zonas que describen una curvatura convexa, mientras que las zonas cóncavas son representadas por valores negativos (Olaya, V., 2004).



**Figura 7:** Covariables Índice de Curvatura longitudinal e Índice Curvatura Seccional transversal.

### **Distancia vertical a la red de canales**

La distancia vertical a la red de canales es definida como la diferencia de elevación de la celda con el nivel que surge de una interpolación de la red de canales ( covariable "Nivel Básico de la red de Canales") (Guo et al., 2019). Para su cálculo se genera en primera instancia una interpolación espacial utilizando las redes de canales y luego se realiza la diferencia de este modelo generado respecto al modelo digital de elevación.

Este parámetro tiene un vínculo con las características del flujo en la ladera, influyendo en la pedogénesis como un mecanismo de acumulación y/o denudación (Abarca, 2010). Sitios cuyos valores son bajos representan sectores sobre los cuales convergen materiales, y a mayores valores de las celdas vecinas mayores serán las cantidades de materiales aportados.

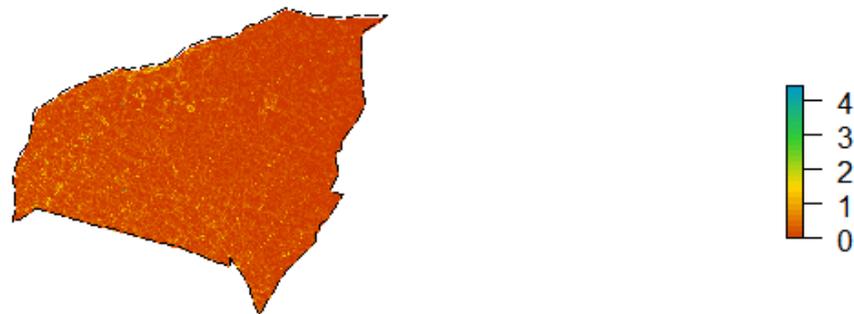


**Figura 8:** Covariable Distancia vertical a la red de canales, expresada en metros.

### Factor LS

Esta variable forma parte de la ecuación de pérdida de suelo universal (USLE) desarrollada por Wischmeier & Smith (1978). Es una medida que surge de la combinación del factor S (pendiente) el cual explica el efecto de la inclinación de la pendiente y del factor L (longitud) que representa el impacto de la longitud de la pendiente.

De manera combinada, el Factor LS está estrechamente vinculado con la capacidad de transporte de sedimentos del flujo terrestre, y por lo tanto tiene incidencia en los fenómenos de erosión y/o sedimentación (Abarca, 2010; Panagos, Borrelli, & Meusbürger, 2015).

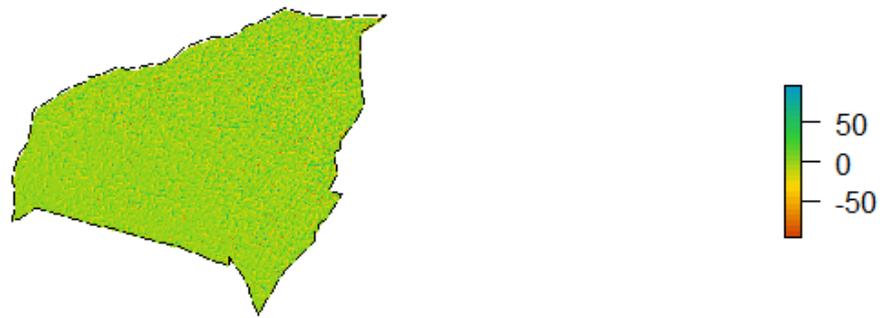


**Figura 9:** Covariable Longitud de la pendiente.

### Índice de convergencia:

Este índice, propuesto por Köthe, Gehrt, & Böhner (1996), utiliza los valores de aspecto de las celdas vecinas para parametrizar la convergencia y la divergencia del flujo respectivamente (V. Olaya & Conrad, 2009). Este parámetro es similar al índice de curvatura del plano, aunque no depende de las diferencias de altura absolutas.

El resultado se proporciona como porcentajes, donde los valores negativos corresponden a condiciones de flujo convergentes, mientras que los valores positivos, a divergentes (Olaf Conrad, 2011). Este comportamiento de convergencia / divergencia de las líneas de flujo condiciona procesos edáficos como la erosión y acumulación de agua principalmente.



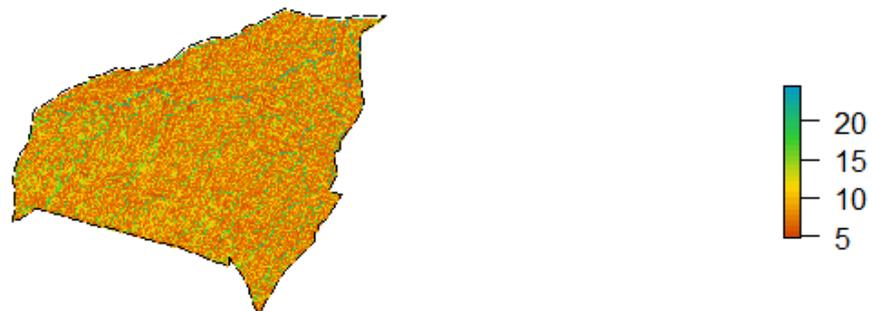
**Figura 10:** Covariable Índice de Convergencia.

### Índice topográfico de humedad (TWI).

Este índice puede ser utilizado para describir la distribución espacial de la humedad del suelo y otros procesos relacionados a la topografía. Es una variable que define la tendencia de una celda a acumular agua (Gruber & Peckham, 2009).

En zonas donde el área de captación aumente y la gradiente de pendiente disminuya, el índice topográfico de humedad aumentará. Asimismo, el índice refleja la tendencia de generar escorrentía, ya que áreas con mayores valores de este índice son más proclives a generar escorrentías derivadas de la precipitación (Abarca, 2010).

El parámetro contribuye en la pedogénesis, interviniendo en las tasas de flujo de materia, transformando y translocando materiales. Además, diversos parámetros edáficos están estrechamente vinculados con los valores del TWI como los contenidos de MO, la textura y la profundidad del suelo.



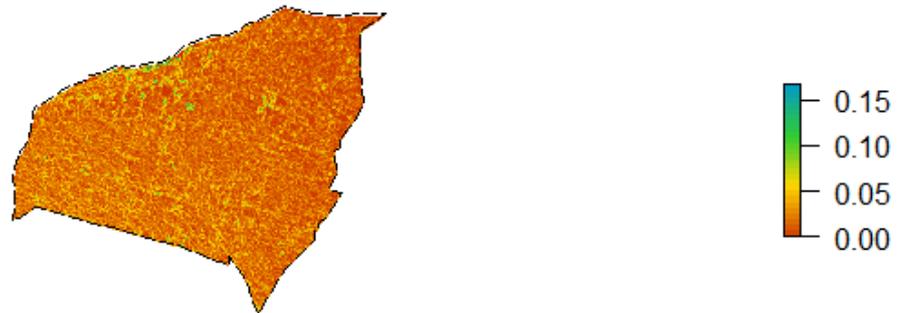
**Figura 11:** Covariable Índice topográfico de humedad.

### Pendiente:

La pendiente refleja la tasa máxima de cambio de los valores de elevación respecto a los valores adyacentes (V. Olaya, 2009). Si bien existen diversos métodos de calcular la pendiente, el algoritmo utilizado por el software SAGA corresponde a Zevenbergen & Thorne, (1987).

La pendiente está estrechamente asociada al espesor del suelo y a su susceptibilidad erosiva de las capas superficiales, encontrándose por lo general suelos de menor profundidad en zonas de mayor pendiente. Lo mismo ocurre con la fertilidad del suelo: los suelos en áreas de elevada pendiente son altamente erosionados y pueden presentar bajas fertilidades. Esto es particularmente notorio en suelos que han desarrollado un horizonte A que luego de sufrir procesos erosivos. La erosión sobre las capas superficiales también afecta el tiempo de

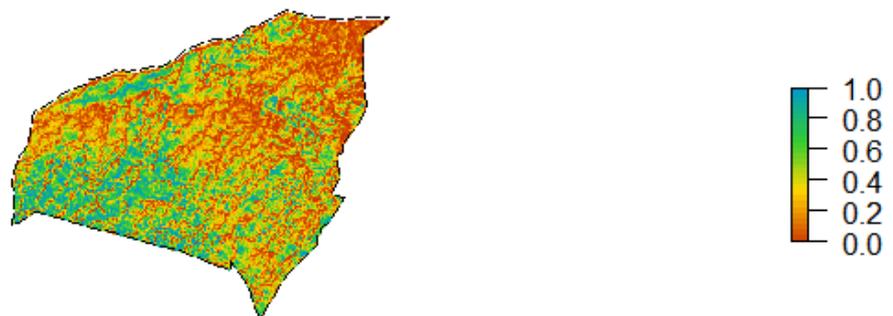
evolución del suelo, ya que las continuas remociones en partes altas y deposiciones en zonas bajas reinician los procesos pedogenéticos (Elizalde, Vilorio, & Jácome, 2000).



**Figura 12:** Covariable pendiente expresada en radianes.

### Posición relativa de la pendiente

La posición relativa de la pendiente se define como la posición de un punto en relación con la cresta y el valle de una pendiente. El parámetro toma valores de 0 en la parte inferior del valle y valores de 1 en la parte superior de la cresta (Guo et al., 2019).



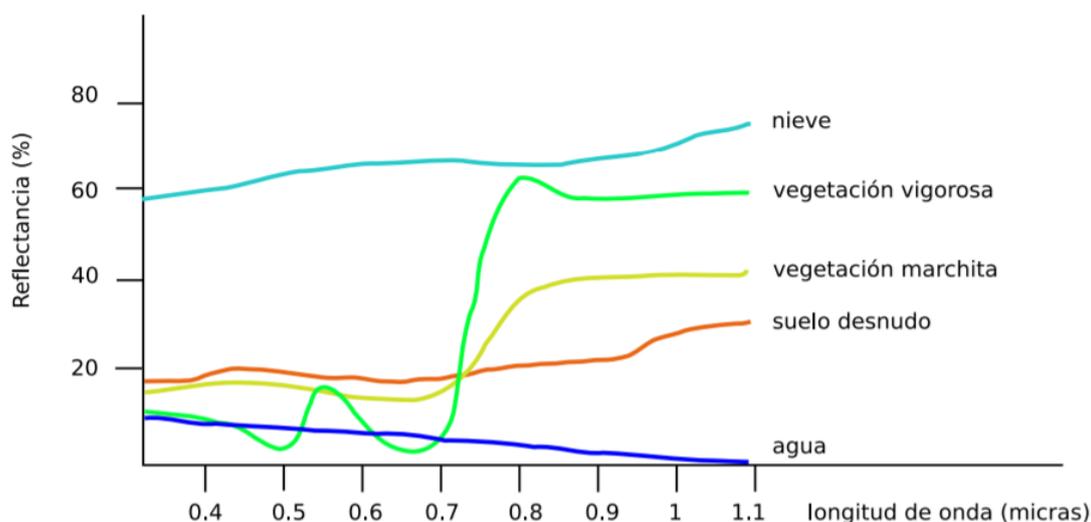
**Figura 13:** Covariable Posición relativa de la pendiente.

## 6. Covariables Organismos

El componente Organismos como factor formador de suelos (Conti, 2000; Florinsky, 2012), integra todas las comunidades bióticas presentes en los suelos, compuestas por la vegetación, los microorganismos, la micro y meso fauna. Si bien el concepto incluye a una gran diversidad de los organismos, son los vegetales los de mayor influencia en la pedogénesis ya que controlan la cantidad y tipo de MO aportada al suelo e influye en los procesos erosivos y microclimáticos (Conti, 2000; Jaramillo, Rodríguez, & Díaz, 2002). Además, la vegetación, al contar con características metabólicas autótrofas, condiciona el desarrollo de las demás formas de vida del suelo.

A su vez, el desarrollo de vegetación presenta una íntima relación con las propiedades del suelo. Por estas razones se utilizó a la vegetación como componente representativo de este factor.

La vegetación posee una gran particularidad en su comportamiento de radiométrico, presentando una baja reflectividad en el espectro rojo visible (R) (0,6~0,7  $\mu\text{m}$ ) y una alta reflectividad en el infrarrojo cercano (NIR) (0,7 ~ 1,3  $\mu\text{m}$ ) (Figura 14). Esta característica permite la utilización de imágenes de sensores remotos para la estimación de la superficie de cobertura vegetal.



**Figura 14:** Firma espectral de diferentes cuerpos, donde se observa el comportamiento particular de la reflectancia para una vegetación vigorosa en la región del rojo (Víctor Olaya, 2014)

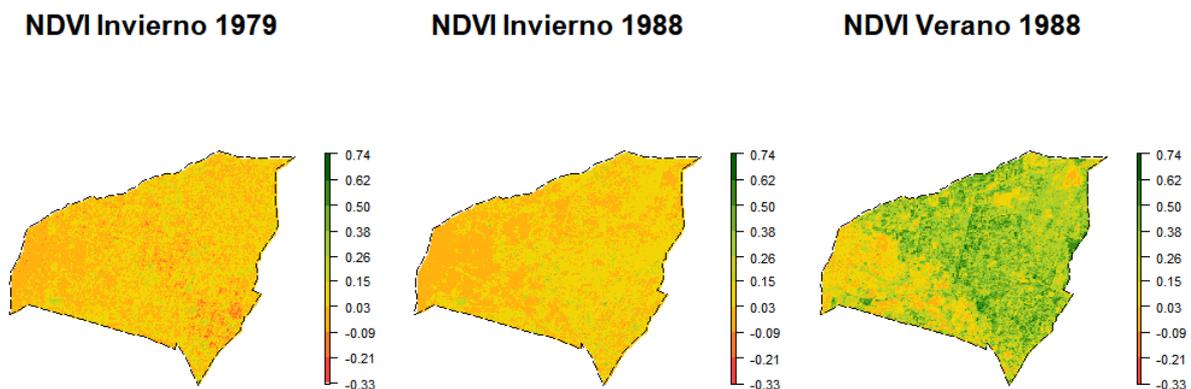
De esta manera se utilizó el índice de vegetación de diferencia normalizada (NDVI) (Ecuación 9) para los periodos de invierno y verano como covariables del factor organismos del modelo. Se ha demostrado que este índice presenta una adecuada correlación no sólo con la acumulación de biomasa del cultivo, sino también con los niveles de clorofila de la hoja, con los valores de área foliar y la radiación fotosintéticamente activa absorbida por el dosel del cultivo (Lillesand, Kiefer, & Chipman, 2015).

$$NDVI = \frac{NIR - R}{NIR + R} \quad \text{Ecuación 9}$$

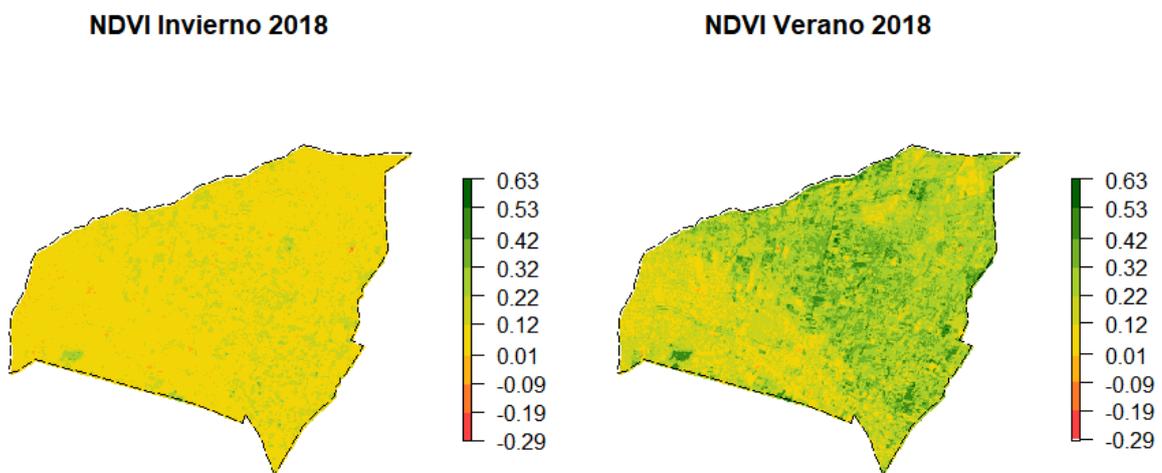
Debido al periodo de estudio y la disponibilidad de datos satelitales de adecuada calidad, para el año 1963 se utilizaron las imágenes más antiguas disponibles de la zona que presentaban una adecuada calidad. Por estos motivos, se emplearon imágenes de verano e invierno de

1988 y únicamente el invierno de 1979 como variables representativas de la vegetación de 1963 (la imagen de verano de 1979 presentaba una gran cobertura de nubes). Los índices fueron calculados mediante el software SAGA 2.3.2 (Conrad et al., 2016), a partir imágenes satelitales de los Satélites Landsat 3, 5 y 8 comprendiendo distintos años desde el 1978 hasta la actualidad.

Los resultados de los índices generados para cada año pueden ser observados en las siguientes figuras:



**Figura 15:** Índices de vegetación utilizados para el factor Organismos del modelo predictivo de COS del año 1963.



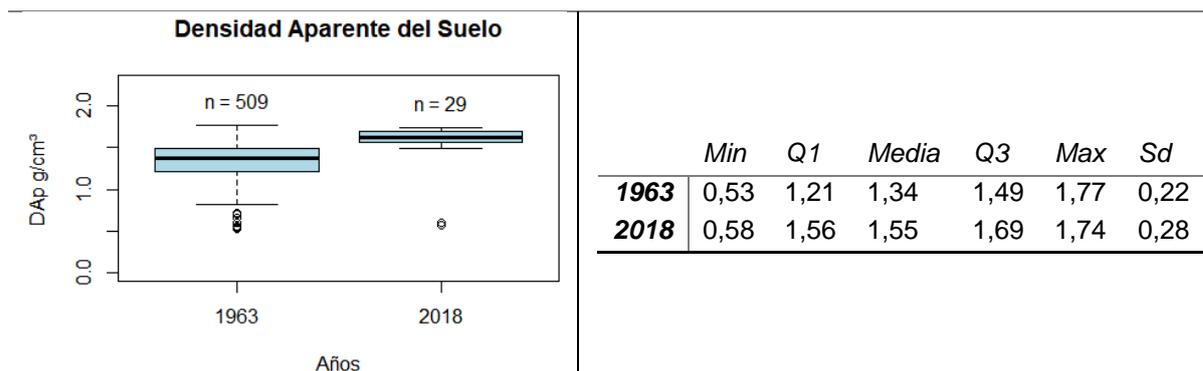
**Figura 16:** Índices de vegetación utilizados para el factor Organismos del modelo predictivo de COS del año 2018.

## 7. Resultados

### 7.1 Preparación de los datos

#### Densidad Aparente:

Luego de realizar los perfiles virtuales de 30 cm del suelo utilizando el método de áreas iguales (Ponce Hernandez et al., 1986), se realizó una estimación de las densidades aparentes de este horizonte de los suelos utilizando la Ecuación 3. Los resultados para cada set de datos pueden observarse en la siguiente tabla y gráfico correspondiente.

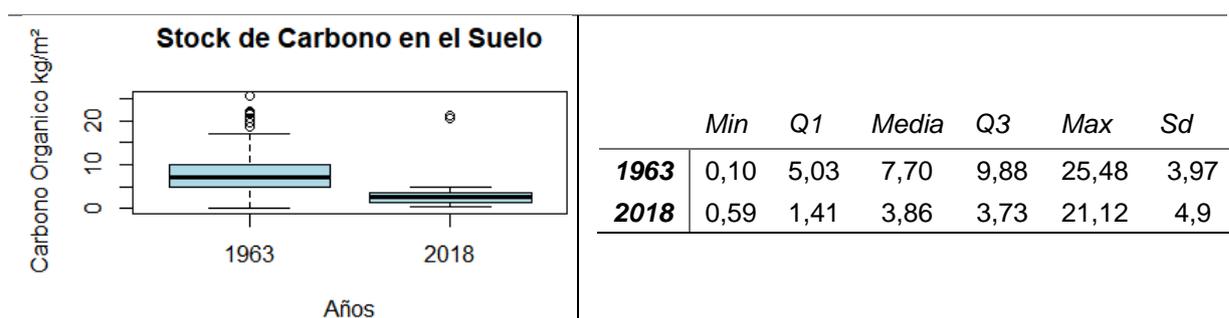


**Figura 17 y Tabla 4:** Densidades aparentes de los suelos estimadas para cada set de datos, expresadas en  $\text{g}\cdot\text{cm}^{-3}$  y resumen de sus principales parámetros estadísticos.

En términos generales se puede observar un incremento de la densidad aparente estimada y de la distribución de los datos con el transcurso del tiempo. Sin embargo, el rango de la distribución de los datos ha permanecido prácticamente invariable.

#### Estimación del Stock de Carbono:

A partir de la transformación de MOS a COS mediante el factor de *Van Bemmelen* (Ecuación 4), utilizando los valores de la densidad aparente del suelo se determinó el stock de carbono contenido en los primeros 30 cm del suelo para cada sitio muestreado (Ecuación 5).



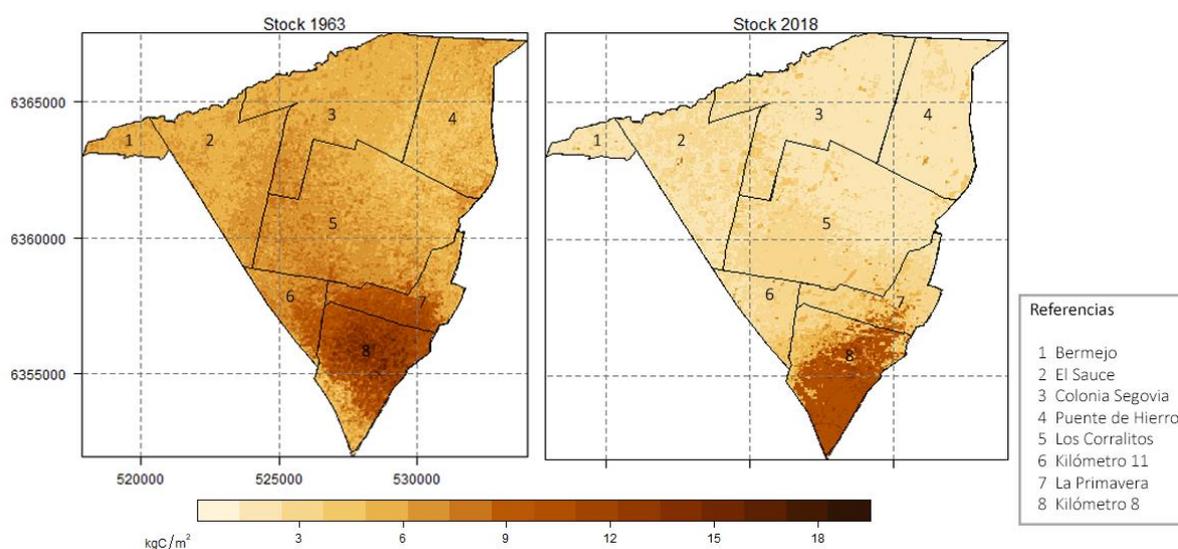
**Figura 17 y Tabla 5:** Stock de carbono en los suelos estimado para cada set de datos en  $\text{kgC}\cdot\text{m}^{-2}$  y resumen de sus principales parámetros estadísticos.

En el resultado del análisis se puede apreciar una disminución del contenido del stock de carbono edáfico y un incremento en la dispersión de los datos conforme transcurre el tiempo. Es de particular interés destacar que los contenidos medios del stock carbono han disminuido la mitad de sus valores desde 1963 hasta el año 2018.

## 7.2 Predicciones del Stock de Carbono

Los resultados de las predicciones del stock de carbono para cada año de estudio elaborados utilizando el modelo Ecuación 6, pueden ser observados en la Figura 18. Una versión digital de los resultados puede ser encontrada en [aquí](#), por otro lado los datos generados se encuentran disponibles [aquí](#).

A simple vista se puede observar una disminución generalizada en toda la superficie del stock de carbono en el transcurso del tiempo. Además, se observa una zona de gran acumulación de carbono orgánico en el suelo situada hacia el sur de la zona de estudio, correspondiente al distrito Kilómetro 8.



**Figura 19:** Densidad del Stock de carbono orgánico del suelo en  $\text{kgC}\cdot\text{m}^{-2}$  en los primeros 30 cm del suelo del sector agrícola del departamento de Guaymallén para los años 1963 y 2018 utilizando Random Forest como modelo predictivo. Sistema de Referencia de Coordenadas WGS 84, UTM zona 19S.

En la Tabla 6 se presentan los principales parámetros del resultado de las predicciones y modelos realizados. En la misma se observa una gran disminución de los valores del stock de carbono desde el año 1963 al 2018, donde el stock disminuyó aproximadamente un 50%.

En el anexo del presente trabajo se encuentra la variación del Error Cuadrático Medio conforme aumenta el número de árboles de decisión para cada modelo elaborado.

**Tabla 6:** Predicciones del Stock de carbono predichos para cada año de estudio

	<b>Resultado de las predicciones</b>			<b>Resultados del Modelo Random Forest</b>		
	<i>Min</i> ( $\text{kgC}\cdot\text{m}^{-2}$ )	<i>Media</i> ( $\text{kgC}\cdot\text{m}^{-2}$ )	<i>Max</i> ( $\text{kgC}\cdot\text{m}^{-2}$ )	<i>Stock de C</i> <sup>(a)</sup> (Gg de C)	<i>MSE</i> <sup>(b)</sup>	<i>Mtry</i>
<b>1963</b>	3,01	6,73	19,58	740	9,73	16
<b>2018</b>	1,26	3,24	15,73	356	20,11	16

(a) Stock de carbono en toda el área de estudio.

(b) Error Cuadrático Medio de los 500 árboles de decisión.

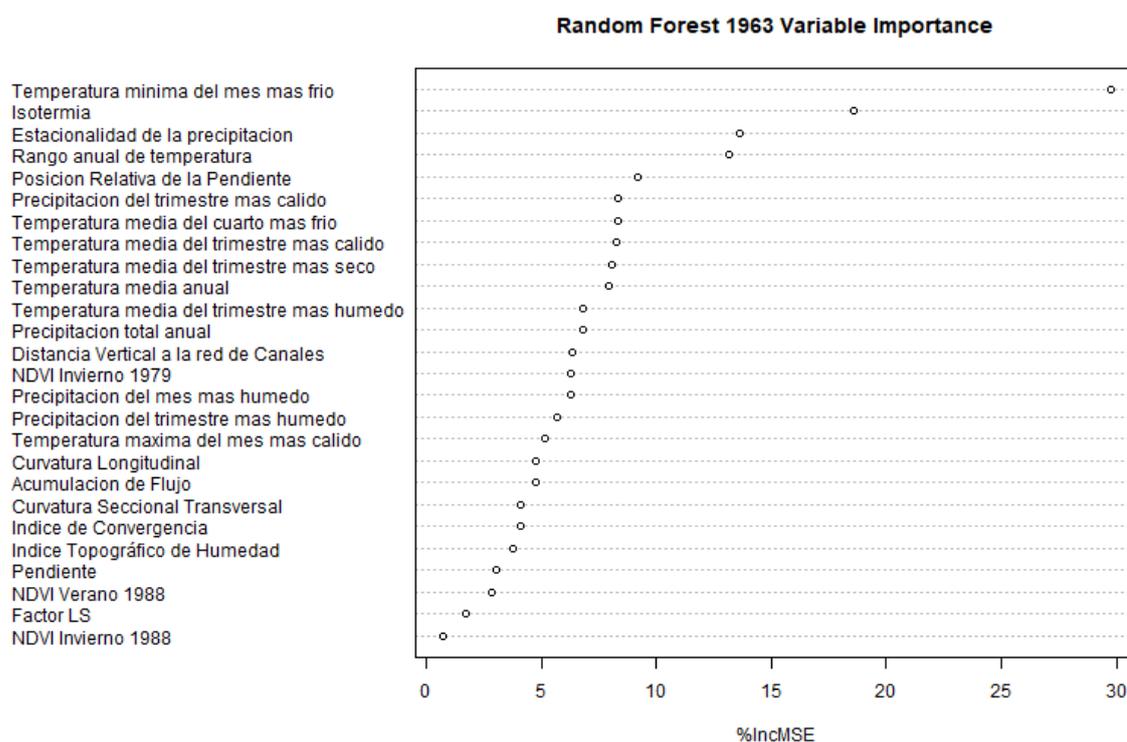
(c) Numero de variables elegidas aleatoriamente en cada árbol de decisión.

## Principales responsables de la distribución espacial de COS

Una de las propiedades de la metodología de Random Forest es que permite determinar las importancias de las variables en la predicción de los datos. Para determinar la importancia de las variables se analizó el incremento del Error Cuadrático Medio (MSE) y el incremento de la pureza del nodo cuando en las predicciones cuando se realizan permutaciones sobre los valores de cada variable. Una explicación más detallada sobre la medición de estas propiedades se encuentra en el libro *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (Hastie, 2017).

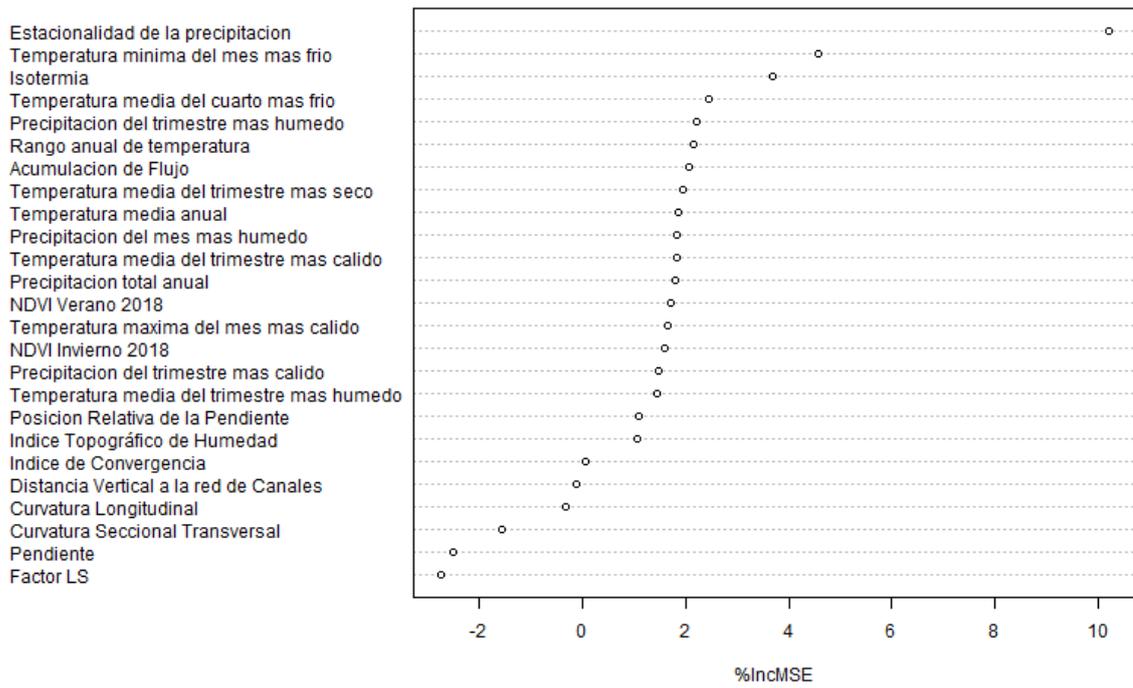
Las representaciones gráficas de las importancias de las variables mediante el análisis del incremento del MSE para cada modelo se encuentran en las Figuras 19 y 20. En el anexo del presente trabajo se encuentran los resultados de las importancias de las variables analizando el incremento de la pureza del nodo.

El análisis de estas variables indica que las importancias dependen de cada modelo, motivo por el cual se utilizaron múltiples variables para la elaboración de cada modelo. Sin embargo, las variables bioclimáticas temperatura del mes más frío, isotermia, estacionalidad de la precipitación, el rango anual de la temperatura, temperatura media del cuatrimestre más frío, junto con la posición relativa de la pendiente y la acumulación de flujo resultaron ser trascendentales en todos los modelos predictivos.



**Figura 20:** Importancia de las variables para el modelo predictivo del stock de carbono del año 1963 analizando el incremento del Error Cuadrático Medio.

Importancia de las Variables, Random Forest 2018



**Figura 21:** Importancia de las variables para el modelo predictivo del stock de carbono del año 2018 analizando el incremento del Error Cuadrático Medio.

### 7.3 Validación de los modelos

La Tabla 7 muestra los principales resultados estadísticos de validación cruzada para las predicciones realizadas en el año 1963 y 2018. Los resultados de las validaciones indican que ambos modelos resultan ser eficaces para realizar las predicciones del Stock de Carbono Orgánico. Sin embargo, el resultado de la validación para el modelo predictivo del año 1963 arroja resultados superiores respecto al del 2018.

**Tabla 7:** Parámetros estadísticos de la validación de los modelos para el año 1963 y 2018.

	1963	2018
<b>Coefficiente Spearman</b>	0,57	0,34
<b>ME<sup>(a)</sup></b>	0,75	1,01
<b>MAE<sup>(b)</sup></b>	2,44	2,32
<b>MSE<sup>(c)</sup></b>	10,59	21,82
<b>RMSE<sup>(d)</sup></b>	3,25	3,94
<b>AVE<sup>(e)</sup></b>	0,32	0,121

(a)Error Medio

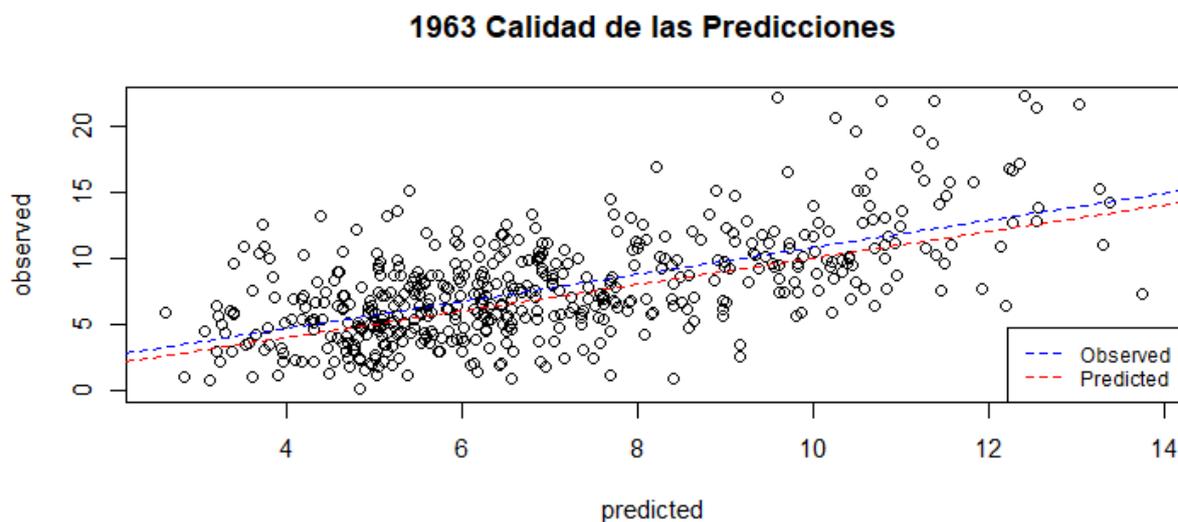
(b)Error medio absoluto

(c)Error cuadrático medio

(d)Raíz cuadrada del error cuadrático medio

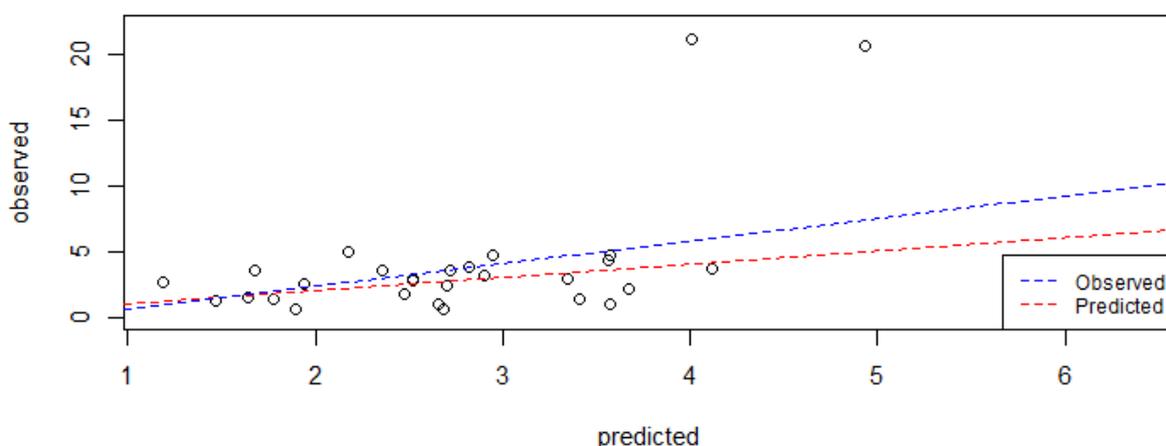
(e)Cantidad de varianza explicada

En las Figuras 22 y 23 se observa la correlación de los datos observados versus los valores predichos por los modelos. En las mismas se observa una correlación positiva, donde las líneas azules representan el ajuste lineal de la distribución de los puntos, mientras que las rojas representan el ajuste ideal 1:1.



**Figura 22:** Correlación entre los valores observados versus los predichos realizada en la validación del modelo del año 1963.

## 2018 Calidad de las Predicciones

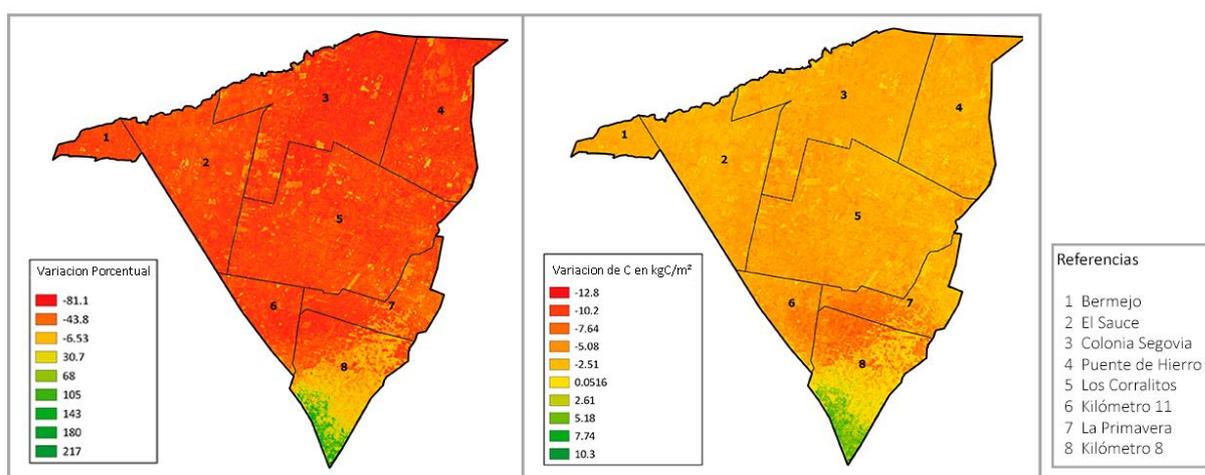


**Figura 23:** Correlación entre los valores observados versus los predichos realizada en la validación del modelo del año 2018.

### 7.4 Balance del stock de carbono y cuantificación del CO<sub>2</sub> emitido

El resultado de la variación del stock de carbono entre el año 1963 y 2018 se puede observar en la Figura 23, donde se observa la variación porcentual y cuantitativa del stock de carbono. Los resultados indican grandes pérdidas del stock de carbono en la mayoría del área de estudio, donde el índice disminuyó hasta 12 kg de Carbono por cada m<sup>2</sup> en algunos sectores. Por otro lado, un pequeño sector localizado en la parte sur del área agrícola presentó un balance positivo, donde los contenidos de carbono aumentaron considerablemente, llegando hasta cifras de 10 kg de C/m<sup>2</sup>.

Por otro lado, en el resultado de la variación porcentual del carbono, se puede apreciar que la mayor parte de la zona presentó pérdidas del stock. Estas pérdidas que varían entre el 50 al 80 % de sus contenidos de iniciales. Sin embargo, los incrementos son focalizados en parte sur del distrito kilómetro 8, pero presentaron incrementos porcentuales muy significativos (más del 200% en algunos sectores).



**Figura 24:** Variaciones del Stock de Carbono en los primeros 30 cm del suelo del año 2018 respecto al 1963.

En cuanto al balance general del Stock de Carbono, en la Tabla 8 se presentan los principales resultados. El resultado del balance indica que en la superficie de estudio se estima una pérdida total de 384,32 Gg (Gigagramos)<sup>3</sup>, en otros términos, una pérdida del 51,9% del stock de Carbono del año 1963. Lo mismo equivale a un volumen de 727 millones de m<sup>3</sup> de CO<sub>2</sub> (en condiciones normales de presión y temperatura según IUPAC, 2014 <sup>4</sup>) y a una masa de 1409 Gg de CO<sub>2</sub>.

Por otro lado, un 96,4 % del área de estudio (10.604 has) presentó pérdidas de carbono edáfico en el primer horizonte de 30 cm.

**Tabla 8:** Resumen del balance del Stock de Carbono entre 1963 y 2018.

<b>BALANCE</b>	
<b><i>Perdidas de Carbono</i></b>	384,32 Gg de C Pérdida del 51,9 % del Stock de 1963
<b><i>Emisiones Netas de CO<sub>2</sub></i></b>	1409,17 Gg de CO <sub>2</sub> 727 millones de m <sup>3</sup> de CO <sub>2</sub>
<b><i>Superficie con Balance Positivo</i></b>	3,6% (395 has)
<b><i>Superficie con Balance Negativo</i></b>	96,4% (10604 has)
<b><i>Tasa De Emisión</i></b>	0,233 kg CO <sub>2</sub> ·m <sup>2</sup> ·año <sup>-1</sup> 2,33 tn CO <sub>2</sub> ·ha <sup>-1</sup> ·año <sup>-1</sup> 0,233 Gg CO <sub>2</sub> ·km <sup>-2</sup> ·año <sup>-1</sup>

<sup>3</sup> 1 Gg equivale a 1000 toneladas o 1 ktn

<sup>4</sup> Temperatura de 273,15 K y presión de 100000 Pa.

## 8. Discusión

Los suelos de estudio han sufrido grandes cambios en el transcurso de la historia, por consecuencia sus propiedades se han visto considerablemente alteradas. El análisis de las muestras de suelos sugiere un incremento de la densidad aparente y una disminución de los contenidos de stock de carbono en el transcurso del tiempo. La razón de estas variaciones se debe a la pérdida de contenidos de materia orgánica en los suelos, la cual es inversamente proporcional a densidad del mismo según la ecuación utilizada para su determinación (Honeysett & Ratkowsky, 1989).

En el mismo sentido, los resultados de las predicciones espaciales del stock de carbono demuestran las mismas tendencias que fueron obtenidas a priori en las muestras de suelos. El stock de carbono disminuyó considerablemente afectando gran parte de la zona de estudio, donde el 96% del área presentó pérdidas de carbono edáfico. Por otro lado, la parte sur correspondiente al distrito Kilómetro 8 presentó un balance positivo del stock de carbono. Esta singularidad puede deberse a las condiciones topográficas deprimidas del sector y las variaciones en el nivel freático en el transcurso del tiempo, el cual está estrechamente vinculado con el contenido del COS (Aitkenhead, Hope, & Billett, 1999; Meersmans, De Ridder, Canters, De Baets, & Van Molle, 2008; Strack et al., 2008).

En términos netos, el stock de carbono de 1963 perdió cerca del 50%, pasando de 740 a 356 Gg de C en el área de estudio. Estas pérdidas equivalen a una emisión de 1409 Gg de CO<sub>2</sub>. Teniendo en cuenta la superficie continental y las emisiones anuales de CO<sub>2</sub> eq de la República Argentina para el sector de Agricultura, ganadería, silvicultura y otros usos de la tierra (Ministerio de Ambiente y Desarrollo Sustentable, 2017)<sup>5</sup>, la República tiene una tasa de emisión de 0,052 Gg CO<sub>2</sub> eq·año<sup>-1</sup>·km<sup>-2</sup>. Considerando este valor, la tasa de emisión de CO<sub>2</sub> en el área de estudio resulta ser ampliamente superior a la tasa de emisión de nacional, superándola por un 348 % (0,233 vs 0,052 Gg de CO<sub>2</sub> eq·año<sup>-1</sup> · km<sup>-2</sup>).

Los motivos por los cuales se han producido estas enormes pérdidas del carbono orgánico no han sido demostrados en el presente trabajo. Sin embargo esto podría atribuirse a las malas prácticas de manejos de los suelos y a los cambios hidrológicos y ecosistémicos que han sufrido los suelos en el transcurso de la historia anteriormente comentados (Prieto, Abraham, & Dussel 2008).

Los valores de las pérdidas del stock de carbono y las emisiones de CO<sub>2</sub> producidas en los suelos de la zona de estudio son alarmantes, ocasionando grandes perjuicios tanto agrícolas como ambientales. Considerando que una de las principales características de los suelos de Mendoza son sus faltas de contenidos de materia orgánica, la disminución de la mitad de sus contenidos supone un gran problema. Desde el punto de vista económico-productivo, estos suelos han perdido en gran parte el conjunto de propiedades que ofrece la materia orgánica. Por este motivo, es de esperar que la capacidad productiva de los suelos se haya visto afectada significativamente.

Desde un punto de vista ambiental, es necesario tener en cuenta dos aspectos importantes. El primero de ellos es la gran capacidad de almacenamiento de carbono que poseen los suelos de esta zona. El segundo, es que esta cualidad puede convertirse en un potencial peligro si se considera al suelo como una fuente emisora de Gases de Efecto Invernadero como sucedió en los suelos estudiados.

---

<sup>5</sup> Las emisiones por parte del sector de agricultura, ganadería, silvicultura y otros usos de la tierra son de 144.340 Gg de CO<sub>2</sub> eq año<sup>-1</sup> y la superficie continental de la República Argentina es de 2.791.810 km<sup>2</sup> según Ministerio de Ambiente y Desarrollo Sustentable, 2017.

Respecto a los modelos predictivos realizados, se puede observar que las variables climáticas desempeñan un papel muy importante en la predicción del stock de carbono. Esta característica se debe a la gran influencia del clima en el ciclo del carbono, condicionando tanto en el secuestro por parte de las plantas como su incorporación y estabilidad en el suelo. Por otro lado, los índices de organismos utilizados no presentaron una gran importancia en la predicción del stock de carbono orgánico. Esto último puede deberse a la gran variabilidad temporal de la vegetación a lo largo del año, lo cual no fue correctamente representado por las covariables utilizadas.

La utilización de Random Forests como modelo predictivo presentó resultados óptimos, permitiendo incorporar las variables ambientales en la distribución espacial del stock de carbono. En las validaciones realizadas, los valores de AVE fueron mayores a cero lo cual significa que las predicciones del modelo son una mejora sobre el uso de la media como predictor (FAO, 2018). Sin embargo, una gran proporción de la varianza observada no fue explicada por los modelos.

Esto podría atribuirse a múltiples razones que pueden afectar la capacidad de predicción del modelo, aunque generalmente la razón principal es la insuficiencia en la cantidad de observaciones para representar la varianza de la población (Somarathna, Minasny, & Malone, 2017). Esta característica resulta evidente al comparar los resultados de la validación de los modelos de 1963 (n=509) con el modelo de 2018 (n=29), donde los resultados más sólidos fueron obtenidos en el modelo de 1963. Otra razón que pudo haber afectado la capacidad predictiva es la falta de incorporación de covariables ambientales más precisas al modelado espacial como es el caso del nivel freático, otros índices representantes del factor organismos y de propiedades edáficas como la textura. Además, es importante destacar que los contenidos de materia orgánica en los suelos son muy sensibles a las prácticas de manejo llevadas a cabo (Aalde et al., 2006; Davidson & Ackerman, 1993; Mann, 1986; Ogle et al., 2005). Por insuficiencia de información, esta variable no fue tenida en cuenta en la realización de los modelos y podría explicar parte de los errores predictivos.

Finalmente, es de gran interés mencionar que el estudio deja en evidencia cómo el recurso edáfico desempeña un papel activo en el cambio climático, pudiendo actuar tanto como una fuente o bien como un sumidero de carbono. Esta cualidad debe ser considerada al momento de evaluar las prácticas de manejos agrícolas. Una buena opción para mitigar y revertir los daños ocasionados sería aplicar los conceptos propuestos en el libro *Soil Carbon Sequestration For Improved Land Management* (Robert, 2001). El mismo sugiere la aplicación de labranzas de conservación y de disminución de la erosión, el incremento en la incorporación de MO a los suelos (mediante la introducción de otras especies y/o variedades, incorporación de enmiendas orgánicas a los suelos, aumento en la cobertura del suelo y la reducción en el uso de herbicidas). Además, es necesario valorizar la capacidad de secuestro de carbono del suelo para combatir el continuo crecimiento de CO<sub>2</sub> en la atmósfera y de esta manera luchar contra el efecto invernadero.

## 9. Conclusión.

Los suelos de la zona agrícola del departamento de Guaymallén presentan una gran capacidad de sumidero de carbono. Sin embargo, se comprobó que el stock de carbono disminuyó considerablemente en los últimos 50 años, afectando gran parte de la zona de estudio, donde el 96% del área presentó pérdidas de carbono edáfico. En términos netos, el stock de 1963 perdió cerca del 50% de sus contenidos: pasó de 740 a 356 Gg de C en el área de estudio. Estas pérdidas equivalen a una emisión de 1409 Gg de CO<sub>2</sub>.

La aplicación de la metodología de Random Forests aplicada al mapeo digital de suelos permitió la elaboración de mapas del stock de carbono, los cuales presentaron resultados óptimos en la predicción. Esta metodología fue adecuada, ya que permitió incorporar múltiples variables ambientales en la distribución espacial del carbono orgánico, dejando en evidencia su estrecho vínculo con las dinámicas del CO y los procesos edafogénicos.

Se sugiere realizar posteriores trabajos incorporando nuevas covariables predictivas como el nivel freático, mapas de texturas de suelos e índices de vegetación acumulada a lo largo del año, para la predicción de COS en la zona de estudio.

Los resultados del estudio dejan en evidencia el papel activo del recurso edáfico que desempeña en el cambio climático, pudiendo actuar tanto como una fuente o bien como un sumidero de carbono. Debido a las pérdidas de carbono ocasionadas en la zona de estudio, es necesario valorizar el servicio ecosistémico que brinda el suelo como sumidero de carbono y tomar medidas para incrementar los contenidos, valiendo del gran potencial de secuestro que poseen las tierras de las zonas áridas.

## 10. Bibliografía.

- Aalde, H., Gonzalez, P., Gytarsky, M., Krug, T., Werner, A. K., Lasco, R. D., ... Verchot, L. (2006). *Chapter 2: Generic methodologies applicable to multiple land-use categories. Volume 4: Agriculture, Forestry and Other Land Use. 2006 IPCC Guidelines for National Greenhouse Gas Inventories.*
- Abarca, O. (2010). *Desarrollo de un modelo de geoprocesamiento para la valoración productiva y tributaria de tierras agrícolas en Venezuela.* Universidad Politécnica de Madrid.
- Aitkenhead, J. A., Hope, D., & Billett, M. F. (1999). The relationship between dissolved organic carbon in stream water and soil organic carbon pools at different spatial scales. *Hydrological Processes*. [https://doi.org/10.1002/\(SICI\)1099-1085\(19990615\)13:8<1289::AID-HYP766>3.0.CO;2-M](https://doi.org/10.1002/(SICI)1099-1085(19990615)13:8<1289::AID-HYP766>3.0.CO;2-M)
- Andriulo, A. E., & Irizar, A. (2012). *LA MATERIA ORGÁNICA COMO INDICADOR BASE DE CALIDAD DEL SUELO. Xix Congreso Latinoamericano De La Ciencia Del Suelo.*
- Angelini, M. E., Heuvelink, G. B. M., Kempen, B., & Morrás, H. J. M. (2016). Mapping the soils of an Argentine Pampas region using structural equation modelling. *Geoderma*. <https://doi.org/10.1016/j.geoderma.2016.06.031>
- Beaudette, D. E., Roudier, P., & O'Geen, A. T. (2013). Algorithms for quantitative pedology: A toolkit for soil scientists. *Computers & Geosciences*. Retrieved from <http://ncss-tech.github.io/AQP/>
- Berhongaray, G., Alvarez, R., De Paepe, J., Caride, C., & Cantet, R. (2013). Land use effects on soil carbon in the argentine pampas. *Geoderma*. <https://doi.org/10.1016/j.geoderma.2012.07.016>
- Bivand, R., Keitt, T., & Rowlingson, B. (2019). rgdal: Bindings for the "Geospatial" Data Abstraction Library. Retrieved from <https://cran.r-project.org/package=rgdal>
- Breiman, L. (2001). Random Forest. *Machine Learning*. <https://doi.org/10.1023/A:1010933404324>
- Buyanovsky, G. A., Aslam, M., & Wagner, G. H. (1994). Carbon Turnover in Soil Physical Fractions. *Soil Science Society of America Journal*, 58(4), 1167. <https://doi.org/10.2136/sssaj1994.03615995005800040023x>
- Casanovas, E. M., Echeverria, H. E., & Studdert, G. A. (1995). Materia organica del suelo bajo rotaciones de cultivos. I. Contenido total y de distintas fracciones. *Ciencia Del Suelo*.
- Cerri, C. E. P., Easter, M., Paustian, K., Killian, K., Coleman, K., Bernoux, M., ... Cerri, C. C. (2007). Predicted soil organic carbon stocks and changes in the Brazilian Amazon between 2000 and 2030. *Agriculture, Ecosystems and Environment*. <https://doi.org/10.1016/j.agee.2007.01.008>
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., ... Boehner, J. (2016). System for Automated Geoscientific Analyses (SAGA). <https://doi.org/doi:10.5194/gmd-8-1991-2015>
- Conti, M. E. (2000). *Principios de Edafología (2° Edición).*
- Crowther, T. W., Todd-Brown, K. E. O., Rowe, C. W., Wieder, W. R., Carey, J. C., MacHmuller, M. B., ... Bradford, M. A. (2016). Quantifying global soil carbon losses in response to warming. *Nature*. <https://doi.org/10.1038/nature20150>
- D.A.C.C. (2018). Dirección de Agricultura y Contingencias Climáticas. Retrieved January 28, 2019, from <http://www.contingencias.mendoza.gov.ar/web1/>

- Daivid E. Goldberg. (2007). *Fundamentals of Chemistry, 5th Edition. Fifth Edition.*
- Davidson, E. A., & Ackerman, I. L. (1993). Changes in soil carbon inventories following cultivation of previously untilled soils. *Biogeochemistry*. <https://doi.org/10.1007/BF00000786>
- Dobos, E., & Hengl, T. (2009). Chapter 20 Soil Mapping Applications (pp. 461–479). [https://doi.org/10.1016/S0166-2481\(08\)00020-2](https://doi.org/10.1016/S0166-2481(08)00020-2)
- Elizalde, G., Viloria, J., & Jácome, A. (2000). *Elementos de Agrología, Fundamentos teóricos para la Etapa I del Curso de Edafología Aplicada II.* (4th ed.).
- FAO. (2002). *Captura de carbono en los suelos para un mejor manejo de la tierra. Informes sobre recursos mundiales de suelos N° 96.*
- FAO. (2017). *Soil Organic Carbon the Hidden Potential.* FAO. <https://doi.org/10.1038/nrg2350>
- FAO. (2018). *Soil Organic Carbon Mapping Cookbook.* (K. Y. Y. G. F. O. S. R. Rainer Baritz & R. R. V. Viatkin, Eds.) (2 Edition). Rome.
- FAO & ITPS. (2015). World ' s Soil Resources. In *Status of the World's Soil Resources.* <https://doi.org/978-92-5-109004-6>
- Florinsky, I. V. (2012). The Dokuchaev hypothesis as a basis for predictive digital soil mapping (on the 125th anniversary of its publication). *Eurasian Soil Science*. <https://doi.org/10.1134/S1064229312040047>
- Franzluebbers, A. J. (2005). Soil organic carbon sequestration and agricultural greenhouse gas emissions in the southeastern USA. In *Soil and Tillage Research*. <https://doi.org/10.1016/j.still.2005.02.012>
- Galantini, J. A., & Suñer, J. A. L. (2008). Las fracciones orgánicas del suelo : análisis en los suelos de la Argentina. *Agriscientia*.
- Gessler, P. E., Chadwick, O. A., Chamran, F., Althouse, L., & Holmes, K. (2000). Modeling Soil–Landscape and Ecosystem Properties Using Terrain Attributes. *Soil Science Society of America Journal*, 64(6), 2046. <https://doi.org/10.2136/sssaj2000.6462046x>
- Gougoulas, C., Clark, J. M., & Shaw, L. J. (2014). The role of soil microbes in the global carbon cycle: Tracking the below-ground microbial processing of plant-derived carbon for manipulating carbon dynamics in agricultural systems. *Journal of the Science of Food and Agriculture*. <https://doi.org/10.1002/jsfa.6577>
- Gräler, B., Pebesma, E., & Heuvelink, G. (2016). Spatio-Temporal Interpolation using gstat. *The R Journal*, 8(1), 204–218. Retrieved from <https://journal.r-project.org/archive/2016-1/na-pebesma-heuvelink.pdf>
- Gruber, S., & Peckham, S. (2009). Chapter 7 Land-Surface Parameters and Objects in Hydrology (pp. 171–194). [https://doi.org/10.1016/S0166-2481\(08\)00007-X](https://doi.org/10.1016/S0166-2481(08)00007-X)
- Guevara, M., Federico Olmedo, G., Stell, E., Yigini, Y., Aguilar Duarte, Y., Arellano Hernández, C., ... Vargas, R. (2018). No silver bullet for digital soil mapping: Country-specific soil organic carbon estimates across Latin America. *SOIL*. <https://doi.org/10.5194/soil-4-173-2018>
- Guo, Z., Adhikari, K., Chellasamy, M., Greve, M. B., Owens, P. R., & Greve, M. H. (2019). Selection of terrain attributes and its scale dependency on soil organic carbon prediction. *Geoderma*, 340, 303–312. <https://doi.org/10.1016/j.geoderma.2019.01.023>
- Hastie, T. T. (2017). *The Elements of Statistical Learning Second Edition.* *Math. Intell.* <https://doi.org/111>
- Hengl, T. (2009). *A Practical Guide to Geostatistical Mapping of Environmental Variables.* Office. [https://doi.org/10.1016/0277-9390\(86\)90082-8](https://doi.org/10.1016/0277-9390(86)90082-8)

- Hengl, T. (2019). GSIF: Global Soil Information Facilities. Retrieved from <https://cran.r-project.org/package=GSIF>
- Hengl, T., De Jesus, J. M., Heuvelink, G. B. M., Gonzalez, M. R., Kilibarda, M., Blagotić, A., ... Kempen, B. (2017). SoilGrids250m: Global gridded soil information based on machine learning. *PLoS ONE*. <https://doi.org/10.1371/journal.pone.0169748>
- Hengl, T., Heuvelink, G. B. M., Kempen, B., Leenaars, J. G. B., Walsh, M. G., Shepherd, K. D., ... Tondoh, J. E. (2015). Mapping soil properties of Africa at 250 m resolution: Random forests significantly improve current predictions. *PLoS ONE*. <https://doi.org/10.1371/journal.pone.0125814>
- Hengl, T., Heuvelink, G. B. M., & Rossiter, D. G. (2007). About regression-kriging: From equations to case studies. *Computers and Geosciences*. <https://doi.org/10.1016/j.cageo.2007.05.001>
- Hengl, T., Roudier, P., Beaudette, D., & Pebesma, E. (2015). plotKML : Scientific Visualization of Spatio-Temporal Data . *Journal of Statistical Software*. <https://doi.org/10.18637/jss.v063.i05>
- Hernán R Sainz Rozas, Hernán E. Echeverría, P. A. B. y M. E. (2014). *Relevamiento y Mapeo de la fertilidad en suelos agrícolas de la región pampeana Argentina*.
- Heung, B., Ho, H. C., Zhang, J., Knudby, A., Bulmer, C. E., & Schmidt, M. G. (2016). An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. *Geoderma*. <https://doi.org/10.1016/j.geoderma.2015.11.014>
- Hiemstra, P. (2015). Package “automap.”
- Hiemstra, P. H., Pebesma, E. J., Twenh'ofel, C. J. W., & Heuvelink, G. B. M. (2008). Real-time automatic interpolation of ambient gamma dose rates from the Dutch Radioactivity Monitoring Network. *Computers & Geosciences*. <https://doi.org/http://dx.doi.org/10.1016/j.cageo.2008.10.011>
- Hijmans, R. J. (2019). raster: Geographic Data Analysis and Modeling. Retrieved from <https://cran.r-project.org/package=raster>
- Hijmans, R. J., Phillips, S., Leathwick, J. R., & Elith, J. (2017). Package ‘dismo.’ *October*. <https://doi.org/10.1016/j.jhydrol.2011.07.022>.
- Honeysett, J. L., & Ratkowsky, D. A. (1989). The use of ignition loss to estimate bulk density of forest soils. *Journal of Soil Science*. <https://doi.org/10.1111/j.1365-2389.1989.tb01275.x>
- Huang, J., Minasny, B., McBratney, A. B., Padarian, J., & Triantafyllis, J. (2018). The location- and scale- specific correlation between temperature and soil carbon sequestration across the globe. *Science of the Total Environment*. <https://doi.org/10.1016/j.scitotenv.2017.09.136>
- IUPAC. (2014). Compendium of Chemical Terminology 2nd ed. (the “Gold Book”). *Blackwell Scientific Publications, Oxford*. <https://doi.org/10.1351/goldbook.i03352>
- Jaramillo, D., Rodriguez, E., & Diaz, K. (2002). Introducción a la ciencia del suelo. *Facultad de Ciencias. Universidad Nacional de Colombia*. <https://doi.org/10.1017/CBO9781107415324.004>
- Jed Wing, M. K. C., Weston, S., Williams, A., Keefer, C., Engelhardt, A., Cooper, T., ... Hunt, T. (2018). caret: Classification and Regression Training. Retrieved from <https://cran.r-project.org/package=caret>
- Köchy, M., Hiederer, R., & Freibauer, A. (2015). Global distribution of soil organic carbon – Part 1: Masses and frequency distributions of SOC stocks for the tropics, permafrost regions, wetlands, and the world. *SOIL*. <https://doi.org/10.5194/soil-1-351-2015>

- Köthe, R., Gehrt, E., & Böhner, J. (1996). Automatische Reliefanalyse für geowissenschaftliche Anwendungen — derzeitiger Stand und Weiterentwicklungen des Programms SARA. *Arbeitshefte Geologie*, 1, 31–37.
- Kucharik, C. J., Brye, K. R., Norman, J. M., Foley, J. A., Gower, S. T., & Bundy, L. G. (2001). Measurements and modeling of carbon and nitrogen cycling in agroecosystems of southern wisconsin: Potential for SOC sequestration during the next 50 years. *Ecosystems*. <https://doi.org/10.1007/s10021-001-0007-2>
- Lal, R. (2004). Soil carbon sequestration impacts on global climate change and food security. *Science*. <https://doi.org/10.1126/science.1097396>
- Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 2(3), 18–22. Retrieved from <https://cran.r-project.org/doc/Rnews/>
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). *REMOTE SENSING AND IMAGE INTERPRETATION* (7th ed.).
- Luyssaert, S., Ciais, P., Piao, S. L., Schulze, E. D., Jung, M., Zaehle, S., ... Janssens, I. A. (2010). The European carbon balance. Part 3: Forests. *Global Change Biology*. <https://doi.org/10.1111/j.1365-2486.2009.02056.x>
- Mann, L. K. (1986). Changes in soil carbon storage after cultivation. *Soil Science*. <https://doi.org/10.1097/00010694-198611000-00006>
- McBratney, A. B., Mendonça Santos, M. L., & Minasny, B. (2003). On digital soil mapping. *Geoderma*. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)
- McKenzie, N. J., & Ryan, P. J. (1999). Spatial prediction of soil properties using environmental correlation. *Geoderma*, 89(1–2), 67–94. [https://doi.org/10.1016/S0016-7061\(98\)00137-](https://doi.org/10.1016/S0016-7061(98)00137-)
- Meersmans, J., De Ridder, F., Canters, F., De Baets, S., & Van Molle, M. (2008). A multiple regression approach to assess the spatial distribution of Soil Organic Carbon (SOC) at the regional scale (Flanders, Belgium). *Geoderma*. <https://doi.org/10.1016/j.geoderma.2007.08.025>
- Ministerio de Ambiente y Desarrollo Sustentable, A. (2017). *Segundo Informe Bienal De Actualización de la Republica Argentina a la Convencion Marco de las Naciones Unidas sobre el Cambio Climatico*.
- Moeys, J. (2018). soiltexture: Functions for Soil Texture Plot, Classification and Transformation. Retrieved from <https://cran.r-project.org/package=soiltexture>
- Moore, I. D., Grayson, R. B., & Ladson, A. R. (1991). Digital terrain modelling: A review of hydrological, geomorphological, and biological applications. *Hydrological Processes*, 5(1), 3–30. <https://doi.org/10.1002/hyp.3360050103>
- Moudani, W., Shahin, A., Chakik, F., & Rajab, D. (2017). Artificial Intelligence: Concepts, Methodologies, Tools and Applications (p. 1152). <https://doi.org/10.4018/978-1-5225-1759-7>
- Nussbaum, M., Spiess, K., Baltensweiler, A., Grob, U., Keller, A., Greiner, L., ... Papritz, A. (2018). Evaluation of digital soil mapping approaches with large sets of environmental covariates. *SOIL*. <https://doi.org/10.5194/soil-4-1-2018>
- O. Conrad. (2012). Module Valley Depth / SAGA-GIS Module Library Documentation (v2.1.4). Retrieved June 4, 2019, from [http://www.saga-gis.org/saga\\_tool\\_doc/2.1.4/ta\\_channels\\_7.html](http://www.saga-gis.org/saga_tool_doc/2.1.4/ta_channels_7.html)
- O'Donnell, M. S., & Ignizio, D. A. (2012). Bioclimatic Predictors for Supporting Ecological Applications in the Conterminous United States. *US Geological Survey Data Series*. <https://doi.org/10.1016/j.mimet.2011.04.001>

- Ogle, S. M., Breidt, F. J., & Paustian, K. (2005). Agricultural management impacts on soil organic carbon storage under moist and dry climatic conditions of temperate and tropical regions. *Biogeochemistry*. <https://doi.org/10.1007/s10533-004-0360-2>
- Olaf Conrad. (2011). SAGA GIS Convergence Index Wiki Documentation. Retrieved June 4, 2019, from [https://sourceforge.net/p/saga-gis/wiki/ta\\_morphometry\\_1/](https://sourceforge.net/p/saga-gis/wiki/ta_morphometry_1/)
- Olaya, V., 2004. (2004). *A gentle introduction to SAGA GIS*. (1.1).
- Olaya, V. (2009). Chapter 6 Basic Land-Surface Parameters (pp. 141–169). [https://doi.org/10.1016/S0166-2481\(08\)00006-8](https://doi.org/10.1016/S0166-2481(08)00006-8)
- Olaya, V., & Conrad, O. (2009). Chapter 12 Geomorphometry in SAGA (pp. 293–308). [https://doi.org/10.1016/S0166-2481\(08\)00012-3](https://doi.org/10.1016/S0166-2481(08)00012-3)
- Olaya, Víctor. (2014). *Sistemas de Información Geográfica*.
- Olmedo, F. G., & Cara, L. (2019). *Mapa de Aptitud de Suelos del Departamento de Guaymallén*.
- Olmedo, G., Angelini, M., Schulz, G., & Rodriguez, D. (2018). Temporal harmonization of a national dataset for spatial prediction of soil organic carbon. <https://doi.org/10.5281/ZENODO.2363738>
- Panagos, P., Borrelli, P., & Meusburger, K. (2015). A New European Slope Length and Steepness Factor (LS-Factor) for Modeling Soil Erosion by Water. *Geosciences*, 5(2), 117–126. <https://doi.org/10.3390/geosciences5020117>
- Pebesma, E. (2018). Simple Features for R: Standardized Support for Spatial Vector Data. *The R Journal*. Retrieved from <https://journal.r-project.org/archive/2018/RJ-2018-009/index.html>
- Pebesma, E. J. (2004). Multivariable geostatistics in {S}: the gstat package. *Computers & Geosciences*, 30, 683–691.
- Pebesma, E. J., & Bivand, R. S. (2005). Classes and methods for spatial data in {R}. *R News*, 5(2), 9–13. Retrieved from <https://cran.r-project.org/doc/Rnews/>
- Perez Valenzuela, B. R., Salcedo, C. E., De Cara, D. E., & Capuccino, S. N. (2000). Áreas de peligrosidad salina: Guaymallén (Mendoza, Argentina). *Revista de La Facultad de Ciencias Agrarias (Vol. 32, No. 1)*, 32(1), 95-104. Retrieved from <http://bdigital.uncu.edu.ar/11072>.
- Pike, R. J., Evans, I. S., & Hengl, T. (2009). Chapter 1 Geomorphometry: A Brief Guide (pp. 3–30). [https://doi.org/10.1016/S0166-2481\(08\)00001-9](https://doi.org/10.1016/S0166-2481(08)00001-9)
- Ponce Hernandez, R., Marriott, F. H. C., & Beckett, P. H. T. (1986). An improved method for reconstructing a soil profile from analyses of a small number of samples. *Journal of Soil Science*. <https://doi.org/10.1111/j.1365-2389.1986.tb00377.x>
- Porta, J., López-Acevedo, M., & Roquero, C. (2003). *Edafología para la agricultura y el medio ambiente*.
- Prasad, A. M., Iverson, L. R., & Liaw, A. (2006). Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. *Ecosystems*. <https://doi.org/10.1007/s10021-005-0054-1>
- Prieto, M. D. R., Abraham, E. M., & Dussel, P. (2008). Transformaciones de un ecosistema palustre. La gran ciénago del Bermejo - Mendoza, Siglos XVIII y XIX. *Multequina*.
- QGIS Development Team. (2009). QGIS Geographic Information System. *Open Source Geospatial Foundation Project*. <https://doi.org/10.1038/nrg1769>
- Ramifehiarivo, N., Brossard, M., Grinand, C., Andriamananjara, A., Razafimbelo, T.,

- Rasolohery, A., ... Razakamanarivo, H. (2017). Mapping soil organic carbon on a national scale: Towards an improved and updated map of Madagascar. *Geoderma Regional*, 9, 29–38. <https://doi.org/10.1016/j.geodrs.2016.12.002>
- Robert, M. (2001). *Soil carbon sequestration for improved land management. World Soil Resources Reports*.
- Rodriguez-Galiano, V. F., Chica-Olmo, M., Abarca-Hernandez, F., Atkinson, P. M., & Jeganathan, C. (2012). Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2011.12.003>
- Somarathna, P. D. S. N., Minasny, B., & Malone, B. P. (2017). More data or a better model? figuring out what matters most for the spatial prediction of soil carbon. *Soil Science Society of America Journal*. <https://doi.org/10.2136/sssaj2016.11.0376>
- Strack, M., Waddington, J. M., Bourbonniere, R. A., Buckton, E. L., Shaw, K., Whittington, P., & Price, J. S. (2008). Effect of water table drawdown on peatland dissolved organic carbon export and dynamics. *Hydrological Processes*. <https://doi.org/10.1002/hyp.6931>
- Team, R. D. C., & R Development Core Team, R. (2019a). R: A language and environment for statistical computing.
- Team, R. D. C., & R Development Core Team, R. (2019b). R: A Language and Environment for Statistical Computing. *R Foundation for Statistical Computing*. <https://doi.org/10.1007/978-3-540-74686-7>
- Trossero, M. E., Cordone, G. E., & Donnet, L. (2012). *¿Cuánto vale la pérdida de carbono orgánico del suelo?*
- United Nations. (2011). *Global drylands: A UN system-wide response*.
- United States Geological Survey. (2018). USGS. Retrieved February 4, 2019, from <https://www.usgs.gov/>
- Vallone, R. C., Maffei, J. A., Olmedo, G. F., Mastrantonio, L., Lipinski, V., & Morábito, J. (2009). *Mapa de Aptitud de Suelos con Fines de Riego y de Riesgo de Contaminación Edáfica de los Oasis Irrigados de la Provincia de Mendoza*.
- Van Bemmelen, J. M. (1890). Über die bestimmung des wassers, des humus, des schwefels, der in den colloïdalen silikaten gebundenen kieselsäure, des mangans u. s. w. im ackerboden, 37, 279–290.
- Vaysse, K., & Lagacherie, P. (2015). Evaluating Digital Soil Mapping approaches for mapping GlobalSoilMap soil properties from legacy data in Languedoc-Roussillon (France). *Geoderma Regional*. <https://doi.org/10.1016/j.geodrs.2014.11.003>
- Venables, W. N., & Ripley, B. D. (2002). *Modern Applied Statistics with S* (Fourth). New York: Springer. Retrieved from <http://www.stats.ox.ac.uk/pub/MASS4>
- Venier, M., Cónsoli, D., Mitre, M., Zuluaga, S., Filippini, M. F., Bermejillo, A., ... Abril, A. (2015). Revalorización del uso de abonos orgánicos en un agroecosistema hortícola de la Zona Acre, Mendoza, Argentina. In *V Congreso Latinoamericano de Agroecología-SOCLA (La Plata, 2015)*. Retrieved from <http://hdl.handle.net/10915/56260>
- Viscarra Rossel, R. A., Webster, R., Bui, E. N., & Baldock, J. A. (2014). Baseline map of organic carbon in Australian soil to support national carbon accounting and monitoring under climate change. *Global Change Biology*, 20(9), 2953–2970. <https://doi.org/10.1111/gcb.12569>
- Walkley, A., & Black, I. A. (1934). An examination of the degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Science*. <https://doi.org/10.1097/00010694-193401000-00003>

- Wickham, H. (2016). *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York. Retrieved from <http://ggplot2.org>
- Wischmeier, W. H., & Smith, D. D. (1978). Predicting Rainfall Erosion Losses : a guide to conservation planning. *Agriculture Handbook*.
- Zevenbergen, L. W., & Thorne, C. R. (1987). Quantitative analysis of land surface topography. *Earth Surface Processes and Landforms*, 12(1), 47–56. <https://doi.org/10.1002/esp.3290120107>

## 11. Anexo.

### Desarrollo de la ecuación para el cálculo del Stock de Carbono (Ecuación 5)

Partiendo de:

$$\text{Stock de Carbono (masa)} = \text{Densidad de Carbono} \left( \frac{\text{masa}}{\text{volumen}} \right) * \text{Volumen}$$

Teniendo en cuenta que:

$$\text{Densidad de C} \left( \frac{\text{g}}{\text{cm}^3} \right) = \frac{\text{COS} (\%)}{100} * \text{Densidad Aparente del Suelo (DAP)} \frac{\text{g}}{\text{cm}^3}$$

Realizando un cambio de unidades de g/cm<sup>3</sup> a kg/m<sup>3</sup>:

$$\text{Densidad de C} \left( \frac{\text{kg}}{\text{m}^3} \right) = \frac{\text{COS}(\%)}{100} * \text{DAP} \frac{\text{g}}{\text{cm}^3} * 1000 \left( \frac{\text{cm}^3 * \text{kg}}{\text{g} * \text{m}^3} \right)$$

Considerando un espesor de suelo de 0,3 m en 1 m<sup>2</sup> de área, de esta manera:

$$\text{Stock de Carbono kg} = \frac{\text{COS}}{100} * \text{DAP} \frac{\text{g}}{\text{cm}^3} * 1000 \left( \frac{\text{cm}^3 * \text{kg}}{\text{g} * \text{m}^3} \right) * 0,3\text{m} * 1\text{m}^2$$

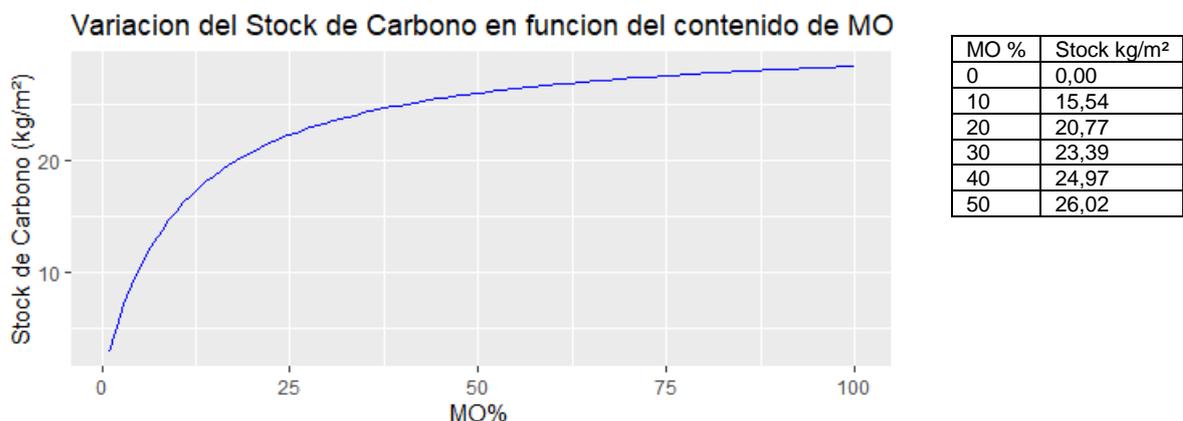
Dividiendo ambos términos por 1 m<sup>2</sup>

$$\text{Stock de Carbono} \frac{\text{kg}}{\text{m}^2} = \frac{\text{COS}}{100} * \text{DAP} \left( \frac{\text{g}}{\text{cm}^3} \right) * 1000 \left( \frac{\text{cm}^3 * \text{kg}}{\text{g} * \text{m}^3} \right) * 0,3\text{m}$$

Aplicando una simplificación, se obtiene la siguiente ecuación final:

$$\text{Stock de Carbono kg/m}^2 = \text{COS} * \text{DAP} * 3\text{kg/m}^2$$

Ecuación 5



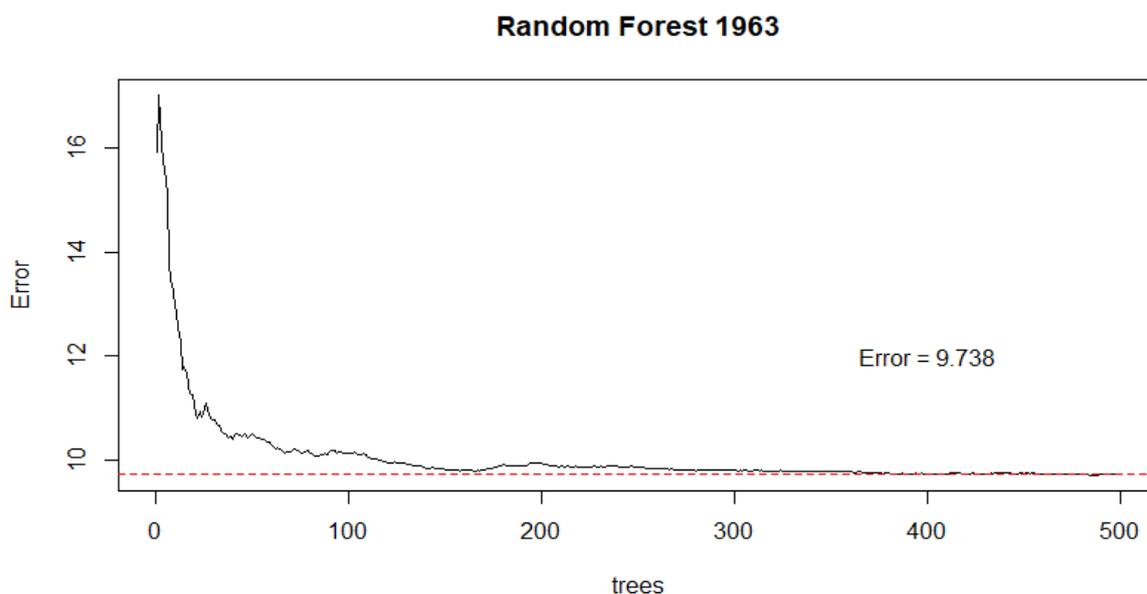
**Figura 25:** Representación gráfica del Stock de Carbono en función del contenido de materia orgánica, utilizando la ecuación 5 para su estimación.

### Validación de las interpolaciones climáticas

**Tabla 9** Resultados de la validación cruzada elaborada para cada mapa climático elaborado.

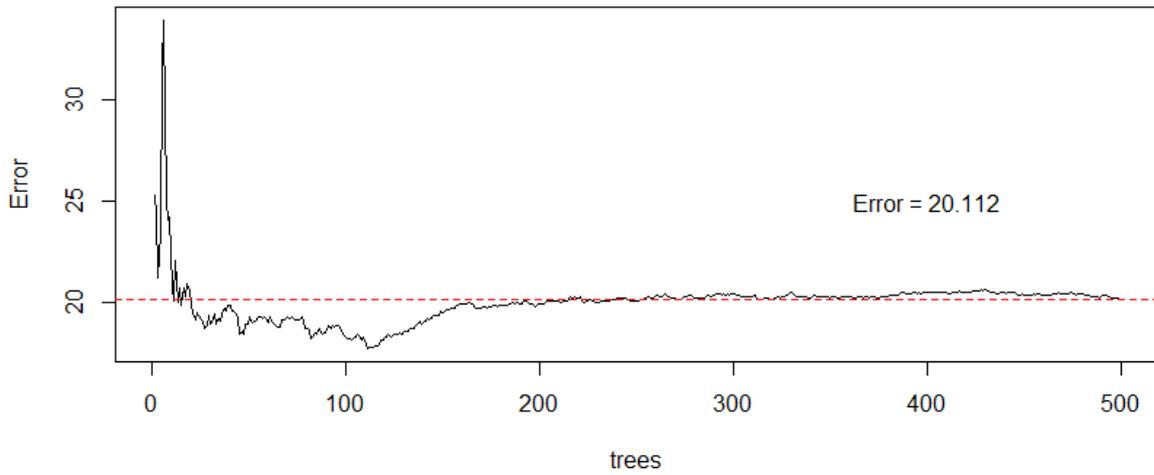
<b>Meses</b>	<b>Precipitaciones</b>		<b>Temperaturas Máximas</b>		<b>Temperaturas Mínimas</b>	
	Error Medio	Raíz del Error Cuadrático Medio	Error Medio	Raíz del Error Cuadrático Medio	Error Medio	Raíz del Error Cuadrático Medio
<i>Enero</i>	3,800	15,574	-0,231	0,940	0,512	2,069
<i>Febrero</i>	0,001	2,480	-0,165	0,929	0,263	1,378
<i>Marzo</i>	1,323	9,786	-0,025	0,520	0,109	1,130
<i>Abril</i>	-0,483	7,488	0,064	0,352	-0,338	1,360
<i>Mayo</i>	-0,276	4,965	0,277	1,036	-0,282	1,284
<i>Junio</i>	-1,313	4,642	0,426	1,526	-0,429	2,111
<i>Julio</i>	0,011	1,209	0,283	0,895	-0,424	2,017
<i>Agosto</i>	1,646	8,178	0,093	0,746	-0,431	1,640
<i>Septiembre</i>	-0,061	3,807	0,124	0,412	-0,416	1,503
<i>Octubre</i>	0,390	5,480	0,003	0,656	-0,294	1,168
<i>Noviembre</i>	2,130	8,778	0,133	0,833	-0,326	1,102
<i>Diciembre</i>	1,357	9,190	-0,038	0,442	-0,002	0,457

### Propiedades de los modelos predictivos Random Forest.



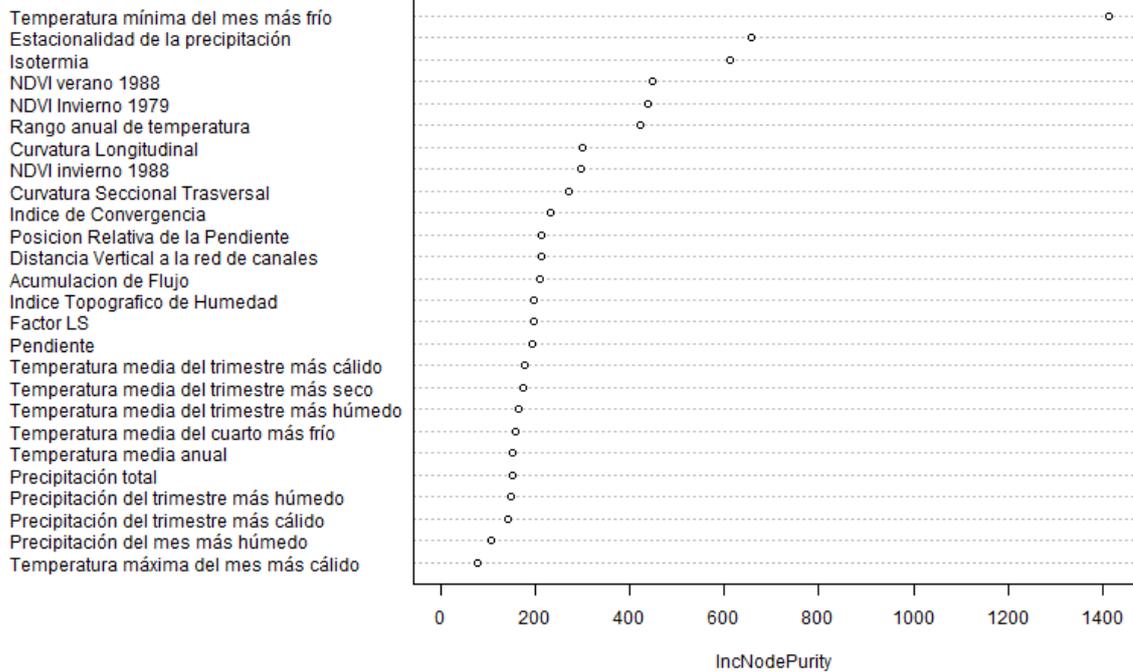
**Figura 26:** Evolución del Error cuadrático medio de las predicciones conforme incrementan los arboles de decisión para el modelo predictivo del Stock de carbono de 1963.

### Random Forest 2018

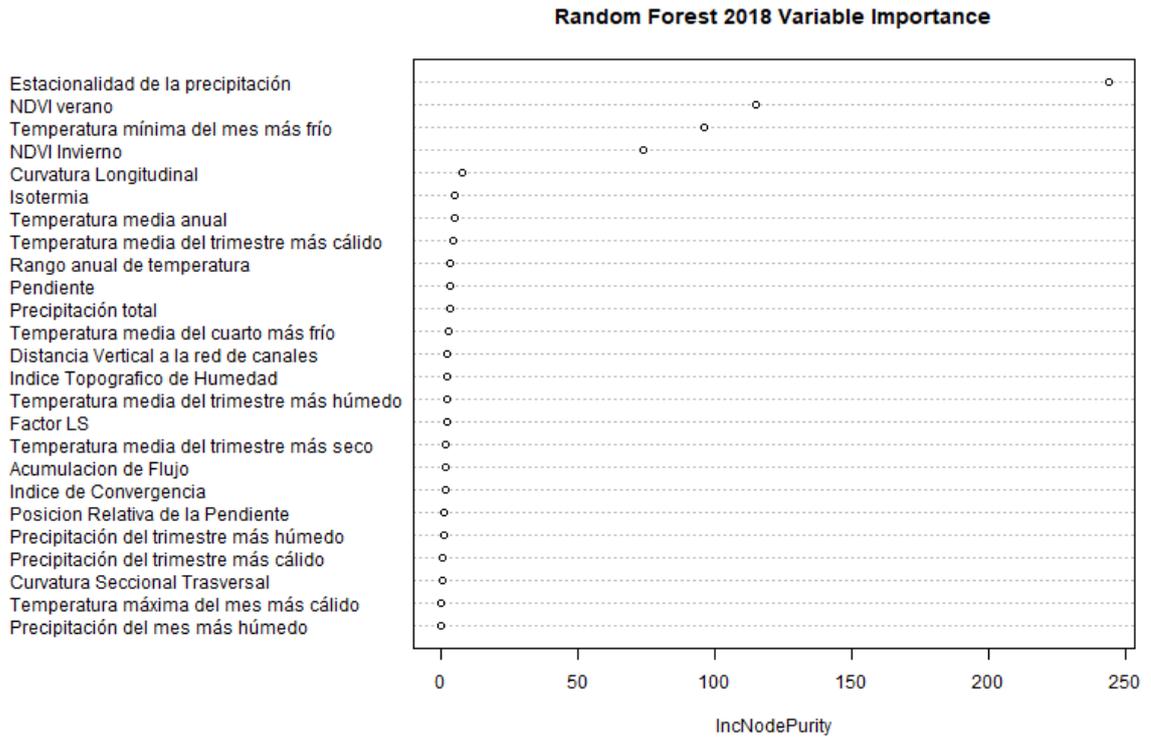


**Figura 27:** Evolución del Error cuadrático medio de las predicciones conforme incrementan los arboles de decisión para el modelo predictivo del Stock de carbono de 2018.

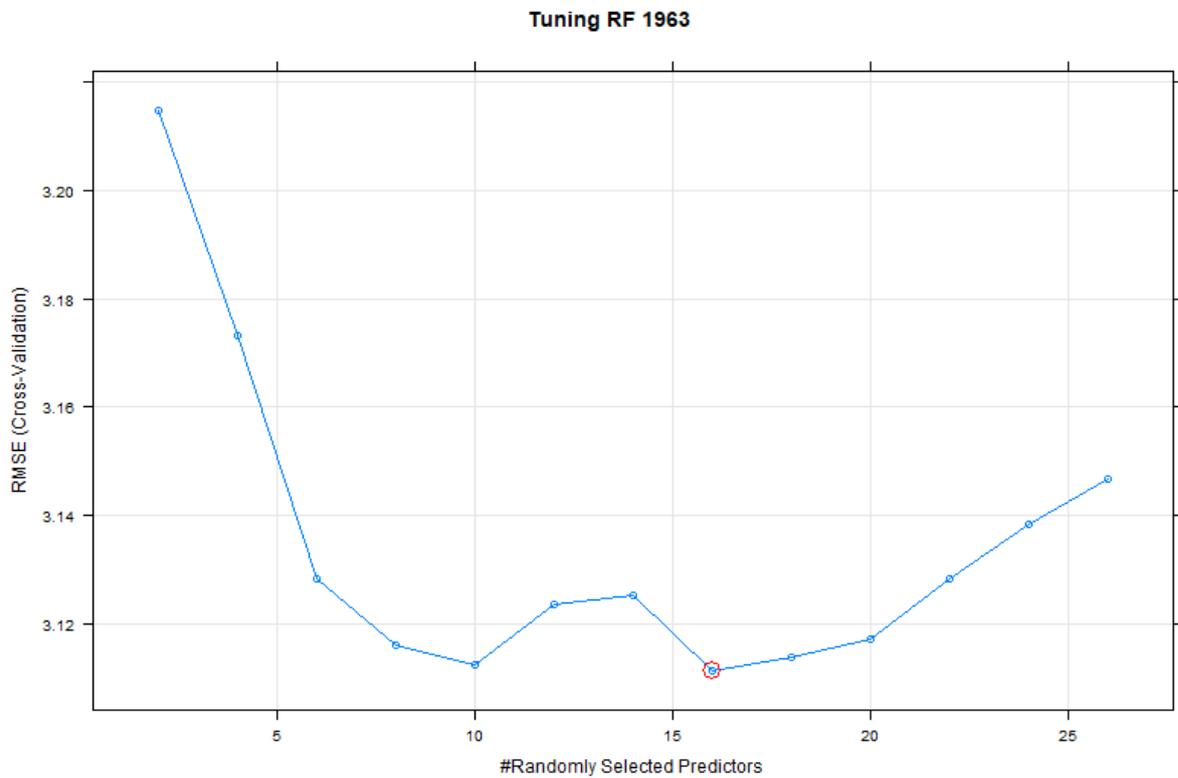
### Random Forest 1963 Variable Importance



**Figura 28:** Importancia de las variables evaluada según el incremento de la pureza del nodo para el modelo predictivo del Stock de carbono de 1963

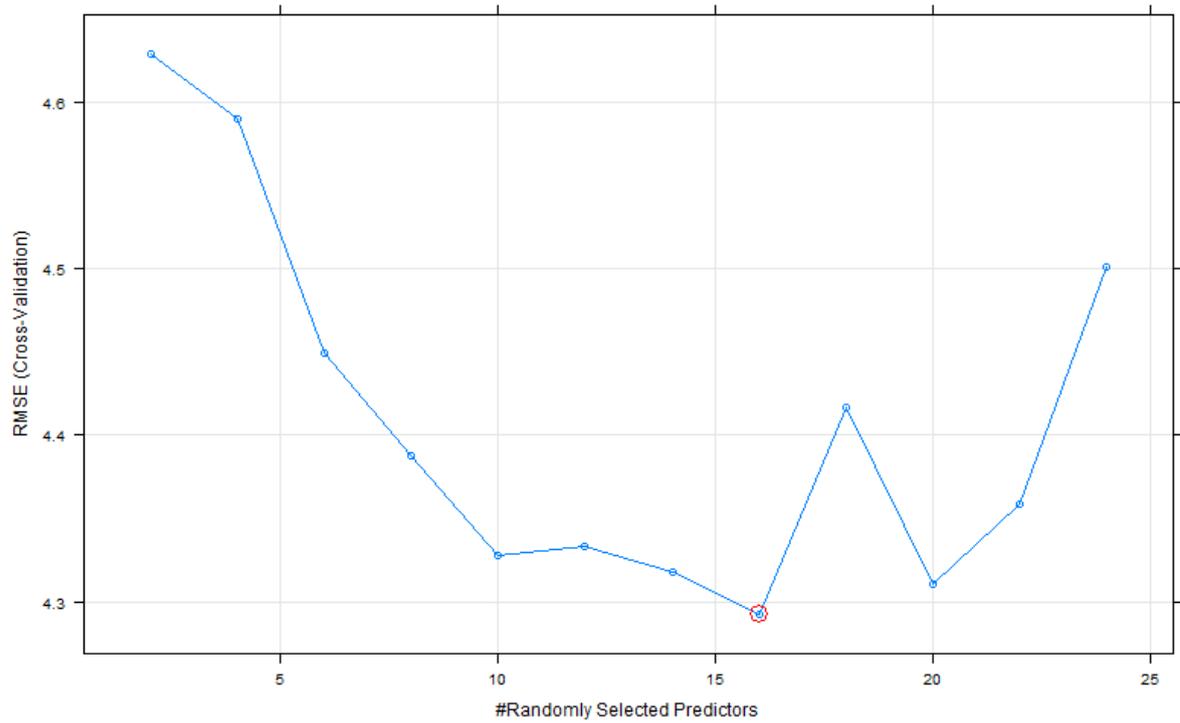


**Figura 29:** Importancia de las variables evaluada según el incremento de la pureza del nodo para el modelo predictivo del Stock de carbono de 2018.



**Figura 30:** Selección de la cantidad apropiada de variables escogidas al azar para la elaboración del modelo predictivo del Stock de carbono de 1963. ( $mtry=16$ )

Tuning RF 2018



**Figura 31:** Selección de la cantidad apropiada de variables escogidas al azar para la elaboración del modelo predictivo del Stock de carbono de 2018. (*mtry*= 16)