

# MODELAMIENTO ESPACIAL PARA LA ESTIMACIÓN DE RESERVAS DE CARBONO ORGÁNICO DEL SUELO EN EL ALTIPLANO PUNO – MICROCUENCA PACRAMAYO

**Daniel Canaza Mamani**

## RESUMEN

El suelo es un recurso natural, dinámico que satisface en mayor o menor medida las necesidades vitales de crecimiento de plantas u otros organismos; es un sistema heterogéneo, trifásico, conformado por elementos sólidos (orgánicos e inorgánicos), líquido y gaseoso, caracterizado por propiedades específicas adquiridas durante la edafogénesis. El carbono puede aparecer en el suelo bajo dos formas: inorgánica y orgánica, el carbono orgánico del suelo es el principal constituyente de la materia orgánica del suelo. A nivel mundial, los suelos almacenan la mayor reserva de carbono orgánico terrestre en comparación con las reservas de carbono combinadas en la atmósfera y la biosfera (Le Quere et al., 2015). El metro superior de suelo almacena aproximadamente 1408 Gt de carbono orgánico (Batjes, 2016) e intercambia 60 Gt Carbono/año con la atmósfera a nivel mundial (Le Quere et al., 2015). La información acumulada sobre la distribución espacial de carbono orgánico del suelo y sus funciones en suelos del Altiplano de Puno aún es limitada; En el presente estudio, se intenta predecir la heterogeneidad espacial de las existencias de carbono total del suelo superficial (0-30 cm de profundidad) en el altiplano de Puno a una resolución espacial de 90 m mediante el uso de técnicas GWRK y LRK que son relativamente inexploradas enfoques geoespaciales de las predicciones de carbono del suelo. Para el desarrollo de la presente investigación se han formulado como interrogantes ¿es viable identificar la distribución espacial del carbono orgánico en diferentes tipos de suelos utilizando técnicas GWRK y LRK como inexplorados enfoques geoespaciales y mapeo digital en el Altiplano de Puno?, se plantea como objetivo general: Predecir la distribución espacial de carbono orgánico de los suelos del Altiplano de Puno utilizando técnicas GWRK y LRK como inexplorados enfoques geoespaciales, los objetivos específicos son: 1) predecir la distribución espacial de las existencias de Carbono Total del suelo y sus incertidumbres a alta resolución espacial, y 2) comprender los controladores ambientales de las existencias de Carbono Total según el tipo de suelos. La investigación se realizará en el distrito de J. D. Choquehuanca-Azángaro, región Puno, sobre una extensión 5, 613.30 hectáreas en el periodo de marzo a noviembre del 2021. Al concluir la investigación nos permitirá aportar a las instituciones nacionales y regionales la predicción de carbono orgánico del suelo utilizando enfoques geoespaciales y mapeo digital.

**Palabras clave: modelamiento espacial, carbono orgánico, kriging, DEM**

## I. PLANTEAMIENTO DEL PROBLEMA

Debido al gran almacenamiento de carbono en los suelos, un pequeño cambio en las existencias de carbono del suelo puede alterar fuertemente el ciclo global del carbono (GCC), y una gestión juiciosa

del carbono del suelo puede compensar algunas de las emisiones antropogénicas. Conceptualmente, las existencias de carbono del suelo se han agrupado en varias fracciones que varían en grado de descomposición desde poco disponibles hasta lábil (Huang y Sun, 2006), y la magnitud de estas fracciones en relación con las características del perfil del suelo determina la capacidad de sumidero de carbono. La capacidad de sumidero de carbono del suelo también se ve afectada por el tipo de suelo (textura, minerales arcillosos, profundidad, etc.), el uso y manejo de la tierra y el clima (Burke et al., 1989; Baldock y Skjemstad, 1999). La vulnerabilidad del carbono del suelo a la descomposición y emisión de gases de efecto invernadero (GEI: CO<sub>2</sub>, CH<sub>4</sub> y N<sub>2</sub>O) también depende de la distribución espacial del carbono del suelo y del microclima específico del lugar. La heterogeneidad espacial y las diferencias en las fracciones de carbono del suelo dentro de una zona climática, el tipo de suelo o el tipo de uso/manejo de la tierra pueden proporcionar información importante sobre los mecanismos de secuestro de carbono. Por lo tanto, la evaluación de la distribución espacial de las existencias de carbono en el suelo con respecto al tipo de suelo, el uso de la tierra y el clima es fundamental para comprender la dinámica del carbono del suelo, el tiempo medio de resiliencia, el flujo gaseoso y la productividad agronómica. El conocimiento sobre la distribución espacial del carbono del suelo dentro del paisaje se obtiene típicamente a través de laboriosos y costosos estudios de campo. Tradicionalmente, este conocimiento se representa como mapas de suelos que se ajustan al modelo discreto de variación espacial, que muestran polígonos dentro de los cuales los suelos se consideran homogéneos y con límites donde los cambios en las propiedades del suelo son abruptos (Heuvelink y Webster, 2001). Sin embargo, la heterogeneidad espacial de las propiedades del suelo se puede representar mejor con un modelo continuo de variación espacial, en el que las propiedades del suelo varían continuamente en el espacio. El rápido desarrollo reciente de la tecnología geoespacial, como el Sistema de Información Geográfica y Percepción Remota (SIG), junto con la disponibilidad de conjuntos de datos ambientales de alta resolución, permiten enfoques más cuantitativos para predecir la heterogeneidad espacial del carbono del suelo en función de los factores de formación del suelo (Scull et al., 2003; Zhu et al., 2015; Yang et al., 2016). Además, estos métodos se pueden utilizar para generar distribuciones espaciales de la incertidumbre en las predicciones. Las técnicas de mapeo digital de suelos han capturado con éxito el efecto de diferentes factores ambientales como el uso de la tierra, el tipo de suelo, la litología, la topografía al tiempo que predicen las propiedades del suelo (por ejemplo, Florinsky et al., 2002; Rawlins et al., 2009; Schulp y Verburg, 2009; D'Acqui et al., 2010). Por todo ello como problema general se plantea: ¿Es viable identificar la distribución espacial del carbono orgánico en diferentes tipos de suelos utilizando técnicas GWRK y LRK como inexplorados enfoques geoespaciales y mapeo digital en el altiplano de Puno?, y como problemas específicos: 1. ¿Es viable predecir la distribución espacial de las existencias de Carbono Total del suelo y sus incertidumbres a alta resolución espacial? y 2. ¿Es factible comprender los controladores ambientales de las existencias de Carbono Total según el tipo de suelos.

## **II. JUSTIFICACIÓN**

El suelo como recurso natural del medio ambiente, donde la práctica de la agricultura y ganadería involucra aplicaciones de abonos orgánicos y fertilizantes químicos, que repercute de manera favorable y/o desfavorable en la conservación de este recurso, considerándose que siempre ha sido una alternativa para obtener mejores ingresos económicos, quedando de lado la importancia del uso y la sostenibilidad del recurso suelo bajo las condiciones de equilibrio ambiental y la práctica de la agricultura conservacionista.

El carbono puede aparecer en el suelo bajo dos formas: inorgánica y orgánica. El carbono inorgánico deriva de las rocas o del CO<sub>2</sub> atrapado en su forma mineral (carbonato de calcio); el carbono inorgánico es menos propenso a la pérdida que el carbono orgánico. El carbono orgánico del suelo es el principal constituyente de la materia orgánica del suelo. La materia orgánica del suelo está formada por la descomposición física, química y biológica de materiales orgánicos que entran al sistema suelo. Su composición elemental en promedio tiene 50 % de carbono según (Broadbert, 1953), 40 % de oxígeno y 3 % de nitrógeno, con pequeñas cantidades de fósforo, potasio, calcio, magnesio y otros elementos como micronutrientes. El carbono orgánico total del suelo tiene un rol importante en mejorar las propiedades físicas, químicas y biológicas, también es considerada como una variable ambiental importante, debido a su función de reservorio de carbono de la superficie de la Tierra.

La información acumulada sobre la distribución espacial de carbono orgánico del suelo y sus funciones en los suelos del Altiplano de Puno aún es limitada; especialmente en relación a su distribución, evolución en el tiempo, estabilidad y sus funciones en el suelo.

Conocer la distribución y la evolución de las fracciones de carbono orgánico lábil nos permite identificar el tipo de materia orgánica, definir su mayor concentración de estas que indican el buen manejo del suelo y en consecuencia la menor degradación del sistema productivo.

## **III. MARCO TEÓRICO**

El suelo es uno de los recursos naturales más importantes que se encuentran en el planeta Tierra, sustenta a todos los organismos terrestres, desde microbios hasta plantas y humanos, y proporciona el sustrato para la vida terrestre (Lin, 2013). El suelo proporciona un medio de transporte y almacenamiento para el agua y los gases (por ejemplo, el dióxido de carbono que influye en el clima global) (Strahler y Strahler, 2006). Además de la importancia del suelo desde un punto de vista ambiental, proporciona una base para la civilización humana y jugó un papel importante en su avance a través de los medios del desarrollo agrícola (Jenny, 1941). Comprender la formación y la distribución global del suelo (y sus propiedades funcionales) es importante en la búsqueda del uso sostenible de este recurso.

Si bien el mapeo espacial de las propiedades del suelo es importante, también es importante comprender la evolución de estas propiedades del suelo y los procesos responsables de la variabilidad espacial observada de las propiedades del suelo. Para cuantificar estos procesos y predecir la evolución de las características del suelo a lo largo del tiempo, se requieren modelos dinámicos basados en procesos (Hoosbeek y Bryant, 1992). Estos modelos de procesos mecanicistas predicen las propiedades del suelo utilizando atributos geomorfológicos y varios procesos físicos como meteorización, erosión y bioturbación (Minasny y McBratney, 1999). Para predecir correctamente los atributos del suelo distribuidos espacialmente y determinar los cambios en los atributos del suelo con el tiempo, es importante acoplar la evolución del perfil del suelo con la evolución del relieve.

El riesgo de la pérdida de suelo por diferentes factores ambientales y antrópicas al no estar evaluado en las cuencas del altiplano de Puno, genera mayor vulnerabilidad para los agricultores, ya que no tienen una percepción clara del problema ambiental al cual se pueden estar enfrentando, al no existir una cartografía clara de las posibles propiedades con información concreta como la Materia Orgánica del Suelo y el secuestro de carbono; además, en el país no se tiene clara una cultura de manejo y conservación de este recurso como por ejemplo el manejo a través del conocimiento del manejo de la materia orgánica como enmienda para mejorar las propiedades físicas y químicas del suelo, de tal forma se pueden adoptar como componentes estratégicos para la fertilidad de suelos y formular prácticas de fertilización, manejo y conservación.

En el Perú, los mapas de suelos se producen por métodos convencionales y establecidos por un ente rector que luego son digitalizados para ser utilizados en diferentes proyectos agrícolas y ambientales a través de sistemas de información geográfica asumiendo que las propiedades del suelo están en equilibrio con el paisaje donde se desarrollaron. Una propuesta que ayuda a mejorar estas limitaciones es el mapeo digital de suelos con enfoque de la influencia del paisaje en el porcentaje de materia orgánica del suelo. Por lo cual, se pretende evaluar la viabilidad de la predicción y distribución de distribución espacial carbono orgánico del suelo del altiplano a través del modelo de pedogénesis y mapeo digital de suelos de la zona de estudio e identificar covariables ambientales más significativas de mayor influencia en la captura de carbono de los suelos.

### **3.1. Suelos del Ecosistema Andino de Puno**

Los suelos del área en estudio, están dedicadas mayormente al pastoreo extensivo, debido a la existencia de abundante vegetación natural de altura, a base de gramíneas, entre las que se encuentran el Iru Ichu (*Festuca orthochyla*), la chiligua (*Festuca dolichaphyla*), el Ichu (*Stipa ichu*), el crepillo (*Clamagrostis vícunarum*), que sirven para el pastoreo del ganado vacuno, ovino y camélidos de la zona. También en se están introduciendo pastos mejorados como "alfalfa" (*Medicago sativa*), "tréboles" (*Trifolium repens*) y *Phabís tuberosa*, que se utilizan como forrajes de complementó para el ganado vacuno, sobre todo. También se pueden observar algunas especies de carácter arbustivo como el "Canlli" (*Margiricarpus pínatus*) y el "Pinco Pinco" (*Ephedra americana*) (ONERN, 1965).

Al contrario de lo que sucede con las tierras bajas, los suelos de páramos tienen una elevada concentración de materia orgánica y además son muy profundos, gracias a esto, la cantidad total de carbono almacenada por hectárea de páramo puede ser mayor que la de una selva tropical (Hofstede et al., 2014).

### **3.2. Carbono Orgánico del Suelo (COS)**

El carbono orgánico total (COT) tiene un rol importante en mejorar las propiedades físicas, químicas y biológicas del suelo. Más aún el COT del suelo es una variable ambiental importante, debido a su función de reservorio de carbono de la superficie de la Tierra. La adición de residuos de cultivos, junto con el mantenimiento de la estructura del suelo, resulta en el incremento de los minerales asociados al carbono orgánico, un parámetro que refleja la relación entre el carbono y la fracción de limo más arcilla. (Sá et al., 2011).

La MOS incluye restos de animales y plantas en varios estados de descomposición. En los bosques, proviene de las hojas caídas, troncos de árboles muertos y de raíces de árboles. En las praderas, gran cantidad de la materia orgánica viene de las raíces y de las hierbas. En las tierras de cultivo, los residuos de las cosechas se añaden a la materia orgánica (Porta et al., 2003).

De acuerdo a Baldock y Skjemstad (1999), la MOS son todos los materiales orgánicos que se encuentran en los suelos independientemente de su origen o estado de descomposición.

El COS es el carbono (C) que permanece en el suelo después de la descomposición parcial de cualquier material producido por organismos vivos. Constituye un elemento primordial del ciclo global del carbono a través de la atmósfera, vegetación, suelo, ríos y océano. El COS es el componente principal de la materia orgánica del suelo (MOS) y, como tal, constituye el combustible de cualquier suelo. La MOS contribuye a funciones clave del suelo, ya que es fundamental para la estabilización de la estructura del suelo, la retención y liberación de nutrientes vegetales, y permite la infiltración y almacenamiento de agua en el suelo. La pérdida de COS indica un cierto grado de degradación del suelo (FAO, 2017b).

### **3.3. Almacenamiento y Fijación de Carbono en Ecosistemas Andinos como Servicio Ecosistémico**

En los andes peruanos los ecosistemas de vegetación natural más importantes son los páramos y bosques naturales continuos o parches, según su aporte económico, social y ecológico (Mena, P y Hofstede, 2011). Los páramos se caracterizan por encontrarse sobre los 3 000 m.s.n.m. y poseen una vegetación herbácea en su mayoría dominada por gramíneas, arbustos o almohadillas (Medina, et al. 2000). Ecológicamente los páramos cumplen funciones ambientales como el almacenamiento y fijación de Carbono (Ordoñez 2001).

Este servicio ambiental es muy importante para el dinamismo o ciclo de ciertos nutrientes y también para mitigar efectos nocivos del Cambio Climático. El almacenamiento de Carbono se basa en la remoción del Dióxido de Carbono (CO<sub>2</sub>) atmosférico para almacenarlo en diferentes componentes del ecosistema, siendo el suelo uno de los más importantes por su alta capacidad de almacenamiento y retención (Ayala et al. 2017). Con un buen manejo y conservación de los páramos protegemos el suelo y mantenemos su Carbono orgánico. Contradictoriamente si se produce alguna alteración, entre ellas las labranzas como actividad de la agricultura, el Carbono se volatiliza (Martínez, et al., & Acevedo, 2008).

#### **3.4. Geología y Taxonomía del Suelo**

El Paleozoico Medio se encuentra muy Bien expuesto a lo largo de la carretera Cuzco-Puno, desde la localidad de Juliaca hasta la quebrada Colquemayo; entre Santiago de Pupuja y Azángaro; entre Taraco y las inmediaciones del pueblo de Arapa (INRENA, 2008). La geología de los suelos tiene que ver con su origen y evolución en el paso del tiempo.

Los Suelos Lacustres y Aluvio Locales de la Altiplanicie, se han formado a partir de sedimentos relativamente finos y profundos de origen lacustre y aluvio locales. Ocupan la mayor parte del Altiplano central y abarcan una superficie aproximada de 270,923 Has (INRENA, 2008). Generalmente se encuentran cubiertos por pastos naturales y cuando son cultivados, se conducen ciertos cultivos de altura como la papa amarga, papa dulce, cebada, quinua, avena forrajera, etc.

La taxonomía del suelo es un sistema de clasificación de suelos, en donde, se considera que el suelo es un cuerpo natural que comprende a sólidos (minerales y materia orgánica), líquidos y gases que ocurren en la superficie de las tierras, que ocupa un espacio y que se caracteriza por uno o ambos de los siguientes: horizontes o capas que se distinguen del material inicial como resultado de adiciones, pérdidas, transferencias y transformaciones de energía y materia o por la habilidad de soportar plantas en un ambiente natural (USDA & NRCS, 2014). La Taxonomía de Suelos de USDA es el sistema nacional de clasificación de los suelos de Estados Unidos y es reconocido en América Latina y Asia.

#### **3.5. Teledetección**

La teledetección es una técnica a través de la cual se obtiene información de un objeto sin tener contacto directo con él. Esto es posible debido a la relación sensor – cobertura (Martínez y Díaz 2005), basado en las propiedades de la radiación electromagnética y en su interacción con la superficie terrestre. (Suárez 2014)


#### **3.6. Espectro Electromagnético y su Relación con las Firmas Espectrales**

El espectro electromagnético se puede expresar como cualquier tipo de energía radiante en función de la longitud de onda o frecuencia, aunque la sucesión de valores de longitud de onda es continua,

se pueden establecer una serie de bandas en donde la radiación electromagnética presenta un comportamiento similar. La organización de bandas de longitudes de onda o frecuencia se denomina espectro electromagnético. En teledetección ambiental suele utilizarse mucho el espectro visible (0.4-0.7  $\mu\text{m}$ ) distinguiendo las bandas azul, verde y rojo; también el espectro correspondiente al infrarrojo cercano (0.7 - 1.3  $\mu\text{m}$ ) por su capacidad para discriminar masas vegetales y concentraciones de humedad; el infrarrojo medio (IRM) (3-5  $\mu\text{m}$ ) en la detección de focos de temperatura; también el espectro infrarrojo de onda corta (SWIR) (1.3-2.5  $\mu\text{m}$ ) usado para detectar humedad en los suelos y/o vegetación. (Chuvieco, 2008)

Las firmas espectrales vienen a ser la manera en la que se comportan las diferentes superficies a distintas longitudes de onda y de esta manera las superficies pueden ser estudiadas por su firma espectral en términos de reflectividad (ver Figura 1). La vegetación presenta un comportamiento cromático con baja reflectividad en el espectro visible, en el infrarrojo cercano se tienen valores más elevados y menores en el infrarrojo medio.

Figura 1. Espectro Electromagnético



Fuente: Firmas espectrales de distintas cubiertas, (Chuvieco, 2008)

### 3.7. Índices Espectrales

Las observaciones ambientales a través de sensores remotos pueden llegar a ser muy complejas dado que el comportamiento de una cubierta ya sea de origen vegetal u otra depende de otros factores externos que modifican el comportamiento espectral teórico, así es el caso de factores relacionados al relieve, ángulos de iluminación, variaciones ambientales, influencia atmosférica, condiciones fenológicas, características edáficas, entre otros (Chuvieco, 2008).

El ecosistema de estudio desde el punto de vista superficial es una cubierta de tipo vegetal en donde actividades antrópicas tales como la quema de cobertura podrían alterar su estructura y características en condiciones naturales.

Los índices de vegetación permiten discriminar el comportamiento reflectivo de la vegetación evaluándola de manera cualitativa y cuantitativa a través de los canales espectrales. Estos índices de vegetación disponibles son numerosos, existen varias comparaciones de los mismos que discuten su utilidad (Bannari et al., 1995). Con el fin de detectar índices de vegetación más adecuado para el Herbazal del Páramo, varios índices de vegetación fueron evaluados. También, es posible usar índices espectrales para otras cubiertas del suelo como es el caso del suelo desnudo a través del Bare Index (Li & Chen, 2014) o lugares quemados (López & Caselles, 1991).

### **3.8. Índices y Variables Topográficas**

Los índices y variables topográficas permiten conocer distintas cualidades del suelo basados en su topografía. El ecosistema de estudio se encuentra en zonas alto andinas, el uso de variables topográficas en forma aislada como es el caso de la elevación, pendiente y orientación, así como en forma conjunta a través de índices; permiten caracterizar el suelo desde este punto de vista y buscar una posible relación con cantidad de COS.

#### **3.8.1. Pendiente y Orientación**

Para cada punto del paisaje topográfico  $\{X, Y\}$  la tasa de cambio de la elevación en las direcciones X, Y puede usarse para identificar la magnitud y la dirección del gradiente más inclinado del campo de elevación topográfica,  $h(X, Y)$ . La pendiente local S se define como la magnitud del gradiente mientras que el aspecto u orientación ( $\alpha$ ) es su dirección (Vico & Porporato, 2009).

#### **3.8.2. Factor LS**

El Factor LS describe el efecto de la topografía en la erosión del suelo; el factor L da el impacto de la longitud de la pendiente mientras que el factor S explica el efecto de la inclinación de la pendiente (Panagos et al., 2015), que es muy útil a la hora de explicar la erosión del suelo en topografías complejas (Desmet & Govers, 1996).

### **3.9. Variables Climáticas**

La temperatura y la precipitación, son factores que determinan en alto grado a la distribución de la vegetación (MAE, 2012). El COS es cuantificado en función de la MO presente en los suelos (Van Bemmelen, 1891). A bajas temperaturas la actividad biológica se reduce, disminuyendo la mineralización de la materia orgánica; esto permite la acumulación de COS en grandes cantidades.



### **3.10. Covariables Ambientales**

los SIG son una herramienta que facilita el análisis multicriterio (Basildo-Martín y López, 1998) de diversas capas de información ambiental (covariables) para un tema geográfico de interés. Este análisis, a partir de una mezcla lineal de probabilidades ponderadas, permite identificar, según la aptitud de cada cobertura temática, la interdependencia entre estas covariables (Bagyaraj et al., 2013). Los análisis multicriterio, por ejemplo, son aplicables para analizar las covariables que influyen en la erosión (Tamene et al., 2006).

### **3.11. Información Generada Para la Clasificación**

La información generada para la clasificación tiene como objetivo incrementar la capacidad de clasificación, brindando al algoritmo de clasificación información que contribuye a aumentar las variables a tener en cuenta, para evaluar la información digital de los píxeles en el proceso de clasificación. Se emplea como información generada para la clasificación la información derivada del DEM (modelo digital de elevación), la curvatura y la pendiente. La selección de las capas a emplear está sujeta a la compatibilidad con el sensor empleado, la disponibilidad y accesibilidad a las capas, y el grado de contribución con el análisis. Es muy importante que todas las capas sean generadas con la misma extensión, tamaño de celda y proyección espacial, así mismo, deben estar almacenados en un mismo directorio. (MINAM 2014)

#### **a) DEM (Modelo Digital de Elevación)**

Un modelo digital de elevación es una representación visual y matemática de los valores de altura con respecto al nivel del mar, que permite caracterizar las formas del relieve y los elementos u objetos presentes en el mismo. Estos valores están contenidos en un archivo de tipo ráster con estructura regular, el cual se genera utilizando un equipo de cómputo y software especializados. En los modelos digitales de elevación existen dos cualidades esenciales que son la exactitud y la resolución horizontal o grado de detalle digital de representación en formato digital, las cuales varían dependiendo del método que se emplea para generarlos. (INEGI, 2016).

#### **b) Curvatura**

Según ESRI (2008) corresponde a la curvatura de una superficie de ráster e incluye, opcionalmente, la curvatura del perfil y el plano. A continuación, se explica estos conceptos.

- )] La salida principal del algoritmo es la curvatura de la superficie celda por celda, calculada usando los valores del DEM de esa celda y de sus vecinos circundantes. La curvatura es la derivada segunda de la superficie, o la pendiente de la pendiente.
- )] Hay dos tipos de curvatura de salida opcionales: la curvatura del perfil está en la dirección

de la pendiente máxima y la curvatura del plano es perpendicular a la dirección de la pendiente máxima.

- ) Una curvatura positiva indica que la superficie es convexa hacia arriba en esa celda. Una curvatura negativa indica que la superficie es cóncava hacia arriba en esa celda. Un valor 0 indica que la superficie es plana.
- ) En la salida del perfil, un valor negativo indica que la superficie es convexa hacia arriba en esa celda. Un perfil positivo indica que la superficie es cóncava hacia arriba en esa celda. Un valor 0 indica que la superficie es plana.
- ) En la salida del plano, un valor positivo indica que la superficie es convexa hacia arriba en esa celda. Un plano negativo indica que la superficie es cóncava hacia arriba en esa celda. Un valor 0 indica que la superficie es plana.
- ) Las unidades del raster de curvatura de salida, así como las unidades del raster de curvatura de perfil de salida opcional y el raster de curvatura plana de salida son una centésima parte (1/100) de una unidad z. Los valores esperados de los tres rasters de salida de un área accidentada pueden variar de -0.5 a 0.5; mientras que, para montañas empinadas accidentadas, los valores pueden variar entre -4 y 4. Tenga en cuenta que es posible exceder este rango para ciertas superficies de raster.

### c) Pendiente

Según ESRI (2008) identifica la pendiente (gradiente o tasa de cambio máximo en el valor z) desde cada celda de una superficie de raster. Los conceptos esenciales asociados al cálculo de esta característica del relieve son:

- ) Pendiente es la tasa de cambio máximo en el valor z desde cada celda.
- ) El uso de un factor z es esencial para corregir los cálculos de pendiente cuando las unidades z de la superficie se expresan en unidades diferentes de las unidades x,y del terreno.
- ) El rango de valores en la salida depende del tipo de unidades de medición.
- ) Para grados, el rango de valores de pendiente es de 0 a 90.
- ) Para aumentar el porcentaje, el rango es de 0 a esencialmente infinito. Una superficie plana es 0 por ciento, una superficie de 45 grados es 100 por ciento y, a medida que la superficie se vuelve más vertical, la elevación en porcentaje se vuelve cada vez mayor.
- ) Si las celdas vecinas son No\_Data, se les asigna el valor de la celda central; entonces se computa la pendiente.

### 3.12. Imágenes Satelitales

Las imágenes satelitales son representaciones visuales de la información capturada por un sensor montado en un satélite artificial, estos sensores recogen información valiosa, dentro de rangos específicos de longitud de onda del espectro electromagnético, que es registrada en distintos canales


o bandas espectrales, de las características de la superficie de la Tierra. (Canada Center for Remote Sensing, citado por Pérez 2012).

Estas imágenes son matrices de celdas llamadas píxeles, formadas por un determinado número de filas y columnas. Cada una de esas celdas representa un área geográfica indivisible, determinando así el detalle espacial mínimo que se puede distinguir dentro de la imagen. El tamaño del píxel varía dependiendo del satélite y de los sensores que tomen la imagen. Cada píxel contiene un valor numérico, que representa en promedio la cantidad de energía solar que esa superficie emite o refleja. Como la energía que refleja la superficie depende de lo que haya sobre ella, los sensores ubicados en los satélites captan distintos niveles y calidades de energía, que luego pasan a ser distintos colores en una imagen ya formada. (Chuvienco, citado por Pérez 2012). Para visualizar estas imágenes satelitales se combina las distintas bandas digitales mediante los tres colores primarios (azul, verde y rojo) que capta el ojo humano. (Canada Center for Remote Sensing, citado por Pérez 2012).

### **3.13. Sistema De Proyección**

Según (Biodamaz 2004) es el sistema que facilita la representación del mundo real (tridimensional), sobre una superficie plana (bidimensional). Es recomendable elegir el sistema de proyección oficial para la zona de trabajo, con el objeto de compatibilizar la información resultante con la información generada en el país. Por otro lado, deben definirse con claridad las necesidades de re-proyección de las imágenes a fin de garantizar la continuidad espacial de las imágenes.

Figura 2: Zonas UTM en el Perú



Fuente: Biodamaz 2004

### **3.14. Kriging**

**¿Cómo funciona Kriging?**

Kriging es un procedimiento geoestadístico avanzado que genera una superficie estimada a partir de un conjunto de puntos dispersados con valores  $z$ . A diferencia de otros métodos de interpolación del conjunto de herramientas Interpolación, utilizar la herramienta Kriging de forma efectiva implica una investigación interactiva del comportamiento espacial del fenómeno representado por los valores  $z$  antes de seleccionar el mejor método de estimación para generar la superficie de salida (Ma Oliver & R. Webster, 1990).

### **¿Qué es kriging?**

Las herramientas de interpolación IDW (distancia inversa ponderada) y Spline se conocen como métodos determinísticos de interpolación porque están basados directamente en los valores medidos o en fórmulas matemáticas específicas que determinan la suavidad de la superficie resultante. Hay una segunda familia de métodos de interpolación que consta de métodos geoestadísticos, como kriging, que está basado en modelos estadísticos que incluyen la autocorrelación, es decir, las relaciones estadísticas entre los puntos medidos. Gracias a esto, las técnicas de estadística geográfica no sólo tienen la capacidad de producir una superficie de predicción, sino que también proporcionan alguna medida de certeza o precisión de las predicciones (Ma Oliver & R. Webster, 1990).

Kriging presupone que la distancia o la dirección entre los puntos de muestra reflejan una correlación espacial que puede utilizarse para explicar la variación en la superficie. La herramienta Kriging ajusta una función matemática a un número específico de puntos o a todos los puntos dentro de un radio especificado, para determinar el valor de salida para cada ubicación. Kriging es un proceso que tiene varios pasos, entre los que se incluyen, el análisis estadístico exploratorio de los datos, el modelado de variogramas, la creación de la superficie y (opcionalmente) la exploración de la superficie de varianza. Este método es más adecuado cuando se sabe que hay una influencia direccional o de la distancia correlacionada espacialmente en los datos. Se utiliza a menudo en la ciencia del suelo y la geología.

### **La fórmula de kriging**

Como indica (Ma Oliver & R. Webster, 1990), El método kriging es similar al de distancia inversa ponderada IDW en que pondera los valores medidos circundantes para calcular una predicción de una ubicación sin mediciones. La fórmula general para ambos interpoladores se forma como una suma ponderada de los datos:

$$\hat{Z}(s_0) = \sum_{i=1}^N \lambda_i Z(s_i)$$

donde:

$Z(s_i)$  = el valor medido en la ubicación n.º  $i$

$w_i$  = un peso desconocido para el valor medido en la ubicación n.º  $i$

$s_0$  = la ubicación de la predicción

$N$  = el número de valores medidos

### **Crear un mapa de la superficie de predicción con el método kriging**

Para llevar a cabo una predicción con el método de interpolación de kriging, es necesario realizar dos tareas:

- ) Descubrir las reglas de dependencia.
- ) Realizar las predicciones.

A fin de completar estas dos tareas, kriging atraviesa un proceso de dos pasos:

1. Crea los variogramas y las funciones de covarianza para calcular los valores de dependencia estadística (denominada autocorrelación espacial) que dependen del modelo de autocorrelación (ajustar un modelo).
2. Prevé los valores desconocidos (hacer una predicción).

Es a causa de estas dos tareas diferenciadas que se ha dicho que el kriging utiliza los datos dos veces: la primera vez para estimar la autocorrelación espacial de los datos y la segunda para hacer predicciones.

## **IV. ANTECEDENTES**

A nivel mundial, los suelos almacenan la mayor reserva de carbono orgánico terrestre en comparación con las reservas de carbono combinadas en la atmósfera y la biosfera (Le Quere et al., 2015). El metro superior de suelo almacena aproximadamente 1408 Gt de Carbono orgánico (Batjes, 2016) e intercambia 60 Gt carbono/año con la atmósfera a nivel mundial (Le Quere et al., 2015). Debido al gran almacenamiento de carbono en los suelos, un pequeño cambio en las existencias de carbono del suelo puede alterar fuertemente el ciclo global del carbono (GCC), y una gestión juiciosa del carbono del suelo puede compensar algunas de las emisiones antropogénicas. Conceptualmente, las existencias de carbono del suelo se han agrupado en varias fracciones que varían en grado de descomposición desde rígido hasta lábil (Huang y Sun, 2006), y la magnitud de estas fracciones en relación con las características del perfil del suelo determina la capacidad de sumidero de carbono. La capacidad de sumidero de carbono del suelo también se ve afectada por el tipo de suelo (textura, minerales arcillosos, profundidad, etc.), el uso y manejo de la tierra y el clima (Burke et al., 1989; Baldock y Skjemstad, 1999). La vulnerabilidad del carbono del suelo a la descomposición y emisión de gases de efecto invernadero (GEI: CO<sub>2</sub>, CH<sub>4</sub> y N<sub>2</sub>O) también depende de la distribución espacial

del carbono del suelo y del microclima específico del lugar. La heterogeneidad espacial y las diferencias en las fracciones de carbono del suelo dentro de una zona climática, el tipo de suelo o el tipo de uso/manejo de la tierra pueden proporcionar información importante sobre los mecanismos de secuestro de carbono. Por lo tanto, la evaluación de la distribución espacial de las existencias de carbono en el suelo con respecto al tipo de suelo, el uso de la tierra y el clima es fundamental para comprender la dinámica del carbono del suelo, el tiempo medio de resiliencia, el flujo gaseoso y la productividad agronómica. El conocimiento sobre la distribución espacial del carbono del suelo dentro del paisaje se obtiene típicamente a través de laboriosos y costosos estudios de campo. Tradicionalmente, este conocimiento se representa como mapas de suelos que se ajustan al modelo discreto de variación espacial, que muestran polígonos dentro de los cuales los suelos se consideran homogéneos y con límites donde los cambios en las propiedades del suelo son abruptos (Heuvelink y Webster, 2001). Sin embargo, la heterogeneidad espacial de las propiedades del suelo se puede representar mejor con un modelo continuo de variación espacial, en el que las propiedades del suelo varían continuamente en el espacio. El rápido desarrollo reciente de la tecnología geoespacial, como el Sistema de Información Geográfica y Percepción Remota (SIG), junto con la disponibilidad de conjuntos de datos ambientales de alta resolución, permiten enfoques más cuantitativos para predecir la heterogeneidad espacial del carbono del suelo en función de los factores de formación del suelo (Scull et al., 2003; Zhu et al., 2015; Yang et al., 2016). Además, estos métodos se pueden utilizar para generar distribuciones espaciales de la incertidumbre en las predicciones. Las técnicas de mapeo digital de suelos han capturado con éxito el efecto de diferentes factores ambientales como el uso de la tierra, el tipo de suelo, la litología, la topografía al tiempo que predicen las propiedades del suelo (por ejemplo, Florinsky et al., 2002; Rawlins et al., 2009; Schulp y Verburg, 2009; D'Acqui et al., 2010).

Se han utilizado varios enfoques geoespaciales para la predicción espacial de carbono del suelo. Estas técnicas se pueden clasificar en: 1) enfoques que aprovechan la correlación ambiental entre el carbono del suelo y los factores ambientales (Lesch y Corwin, 2008; Yang et al., 2008; Martin et al., 2011; Amare et al., 2013), 2) enfoques que utilizan la autocorrelación espacial en las observaciones de carbono del suelo (Wu et al., 2009; Mishra et al., 2009; Mishra et al., 2010; Cambule et al., 2014), y 3) enfoques híbridos que capitalizan tanto la correlación ambiental como la autocorrelación espacial (Kumar et al., 2012; Dorji et al., 2014; Martin et al., 2014; Mondal et al., 2017).

Algunas técnicas utilizan relaciones no lineales entre el carbono del suelo y factores ambientales como el bosque aleatorio (Grimm et al., 2008; Sreenivas et al., 2016), redes neuronales (Malone et al., 2009; Jaber y Al-Qinna, 2011; Li et al., 2013) y modelos basados en reglas (Lacoste et al., 2014). Entre todos los enfoques utilizados para predecir la heterogeneidad espacial del carbono del suelo, las regresiones lineales múltiples y el Kriging ordinario son las técnicas más comúnmente utilizadas, principalmente debido a su simplicidad en la interpretación y facilidad de uso. De manera similar,

las predicciones más precisas (errores de validación más bajos) se lograron a través de enfoques híbridos como el kriging de regresión lineal (LRK).

Los resultados de los estudios que involucran regresión ponderada geográficamente (GWR) y regresión kriging ponderada geográficamente (GWRK) indican que estas son mejores opciones para representar la heterogeneidad del paisaje en las predicciones de carbono del suelo, ya que estos enfoques tienen en cuenta la no estacionariedad al cuantificar las relaciones locales entre el carbono del y variables ambientales que pueden diferir en diferentes lugares en un área de estudio grande (Kumar et al., 2012; Meng, 2014; Mishra y Riley, 2015; Mishra et al., 2017; Vitharana et al., 2019). Estos estudios han capturado mayores detalles espaciales en las predicciones de carbono del suelo. Se han realizado algunos estudios en India para mapear digitalmente el carbono del suelo, estos han utilizado principalmente bosques aleatorios (Sreenivas et al., 2014; Sreenivas et al., 2016; Dharumarajan et al., 2017), LRK (Mondal et al., 2017), árbol de regresión (Krishnan et al., 2009) y red neuronal artificial (Tiwary et al., 2015). Algunos investigadores también han utilizado estudios de suelos, inventarios y modelos basados en procesos para estimar las existencias de carbono del suelo en la India (Dadhwal y Nayak, 1993; Bhattacharyya et al., 2000; Ramachandran et al., 2007; Wani et al., 2010; Banger et al., 2015).

## **V. HIPÓTESIS**

### **Hipótesis general**

Es viable identificar la distribución del carbono orgánico mediante un modelamiento espacial en diferentes tipos de suelos, utilizando técnicas GWRK y LRK como inexplorados enfoques geoespaciales y mapeo digital del suelo en el altiplano de Puno.

### **Hipótesis específicas:**

1. Es posible predecir en suelos del altiplano de Puno la distribución espacial de las existencias de Carbono Total del suelo y sus incertidumbres a alta resolución espacial.
2. Es probable comprender los controladores ambientales de las existencias de Carbono Total según el tipo de suelos.
3. Es factible realizar la distribución espacial de la clasificación de suelos en función al Soil Survey Manual (USDA, 1993) y su clasificación taxonómica de acuerdo y nomenclatura establecidas en el texto de Claves para la taxonomía de suelos (USDA, 2014).

## **VI. OBJETIVOS**

### **Objetivo general:**

Determinar la distribución del carbono orgánico mediante el modelamiento espacial en diferentes tipos de suelos, utilizando técnicas GWRK y LRK y mapeo digital del suelo en el altiplano de Puno.

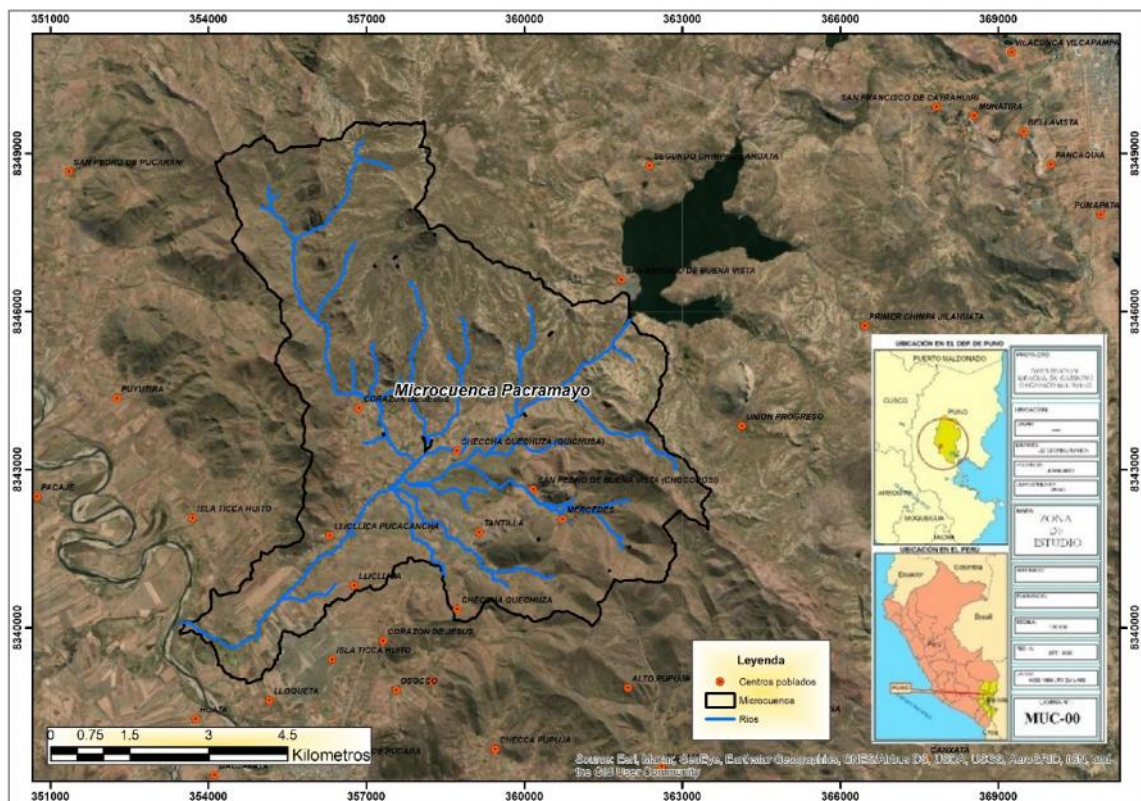
### Objetivos específicos:

- ) Predecir la distribución espacial del Carbono Total del suelo a través técnicas LRK y GWRK y sus incertidumbres a la alta resolución espacial.
- ) Identificar variables ambientales representativas en la existencia de carbono total según el tipo de suelos.
- ) Determinar la distribución espacial de la clasificación de suelos en función al Soil Survey Manual (USDA, 1993) y su clasificación taxonómica de acuerdo y nomenclatura establecidas en el texto de Claves para la taxonomía de suelos (USDA, 2014).

## VII. MATERIALES Y MÉTODOS

### 7.1. Ámbito de estudio

El estudio se realizará en la Microcuenca del río Pacramayo del distrito de J. D. Choquehuanca de la provincia de Azángaro, región Puno, sobre una extensión 5, 613.30 hectáreas, perímetro 51Km.con coordenadas UTM WGS84 19S N= 8343000 m, E= 360000 m.





## 7.2 Materiales

### Materiales de campo

- ) Cartilla de descripción de perfiles
- ) Cinta métrica
- ) Bolsas herméticas
- ) Picota y cuchillo
- ) GPS Garmin GPSMAP 64s
- ) Lupa 10X

### Equipo de gabinete y logística

1. Computador Lenovo: Intel(R) Core(TM) i7 (8ta generación) 12 GB RAM, video dedicado 4 GB.
2. Software ArcGIS versión 10.5
3. Software R version 3.5.1 (R Core Team, 2018)
4. Información cartográfica
5. Camioneta para traslado de personal de apoyo

## 7.3 Metodología

### 7.3.1 Planificación de muestreo, preparación de muestras y análisis químico

#### Muestreo y análisis químico

En la clasificación taxonómica de suelos las áreas de muestreo se establecerán en base al mapa de unidades homogéneas de factores de formación de suelo, utilizando el enfoque geopedológico adaptado a las geoformas de Perú y Fisiografía. La delimitación se realizará mediante fotointerpretación, combinación con el mapa geológico y zonas de vida, y reajuste de límites en base al modelo digital de elevaciones.

Tabla 2. Información cartográfica base para muestreo de campo para la clasificación de suelos y carbono del suelo

<b>MATERIAL</b>	<b>FORMATO</b>	<b>ESCALA</b>	<b>CELDA</b>
Modelo Digital de Elevaciones	Raster	--	12.5
Imágenes Landsat 8	Raster	--	--
Sentinel 2A	Raster	--	--
ASTER	Hdf	--	--
SENAMHI	Raster	--	--
WorldClim	Raster	--	--

Geología integrada	Shape	1:50000	--
--------------------	-------	---------	----

Las unidades del mapa geológico se clasificarán y actualizarán en base a su litología predominante utilizando la información descargada de INGEMMET (2018) para los cuadrángulos 30v y 31v, luego se procederán a agrupar por tipo de roca en rocas ígneas intrusivas, rocas ígneas extrusivas, rocas sedimentarias o rocas metamórficas. Y las zonas de vida se utilizarán en forma de clave de vida, se calculará el número mínimo de muestras según los lineamientos del D.S. N° 013-2010-AG.

El método de selección de muestras dentro de cada unidad homogénea de terreno será por mapeo libre, Los suelos serán clasificados utilizando la doceava llave del Soil Taxonomy (Soil Survey Staff 2014b) hasta nivel de subgrupo.

Para el análisis de Carbono de suelo se recolectarán muestras de los suelos superficiales (0-30 cm) en sitios previamente seleccionados al azar de la zona de estudio durante la etapa de campo. Las coordenadas correspondientes de la ubicación de muestreo se registrarán utilizando un dispositivo de mano GPS y también se recogerá un kilogramo de muestra de suelo mixto de cada sitio y se llevará al laboratorio para su análisis químico.

Durante la evaluación de campo se describirá las características internas y externas al pedón, siguiendo lo descrito por Schoeneberger et al. (2012). El análisis químico de suelo se realizarán en Laboratorio de Suelo y Agua de la Facultad de Ciencias Agrarias de la Universidad Nacional del Altiplano siguiendo el protocolo del Soil Survey Staff (2014a; 2014c).

Tabla 3: Análisis físico-químico a realizar según Protocolo de Laboratorio (Soil Survey Staff 2014b y Manual de Procedimientos de los Análisis de Suelos y Agua con Fines de Riego-UNALM)

<b>PROPIEDAD /CARACTERÍSTICA</b>	
)	Conductividad eléctrica
)	Carbonatos equivalentes
)	Materia orgánica
)	Capacidad de intercambio catiónico
)	Cationes cambiables
)	Acidez cambiabile
)	Color luego de ignición
)	Color en seco / Húmedo
)	Fraccionamiento de arenas

### **Muestreo de datos de entrenamiento para el mapeo de clasificación de suelos y carbono orgánico.**

El proceso de mapeo digital de suelos depende de la relación entre las variables predictoras (es decir covariables) y la característica del suelo (clase o propiedad de suelo) del modelo. Esta relación se

aplica tanto a los métodos de modelado basados en el conocimiento como a los basados en datos. Es importante seleccionar muestras de covariables que sean representativas de la distribución de la característica del suelo objetivo. Estas muestras, conocidas como datos de entrenamiento, proporcionan los datos que se usarán para entrenar el modelo para predecir ocurrencias similares. El muestreo aleatorio o estratificado es más sólido y menos propenso al sesgo. Para este caso y según el nivel de ejecución de levantamiento de información, el presente estudio corresponde al nivel semidetallado o de tercer orden que se realiza para el planeamiento del uso y manejo de pastos, bosques y áreas recreacionales; así como, para el planeamiento comunal, evaluación de impacto ambiental semidetallado, mesozonificación ecológica económica y usos similares extensivos de la tierra; ello según lo dispuesto en el artículo 19° del capítulo IV del Reglamento aprobado con Decreto Supremo N° 013-2010-AG.

### **Estimación de las reservas de carbono orgánico del suelo**

La reserva de carbono orgánico total del suelo de todas las muestras para cada ubicación se calculará según ecuación:

$$C_R = p * D * (C_T - C_M) * F_p$$

Donde:

- ) COS = reserva de carbono orgánico del suelo [kg/m<sup>2</sup>]
- ) C<sub>tot</sub> y C<sub>min</sub> = (contenido total y mineral (o inorgánico) de carbono [g/g], a considerar para suelos calcáreos, y si la combustión seca ocurre normalmente a altas temperaturas (de lo contrario C<sub>tot</sub> es igual a C<sub>min</sub>).
- ) p = profundidad del horizonte/orden de profundidad [m]
- ) DA = densidad aparente [kg/m<sup>3</sup>]
- ) FC<sub>pd</sub> = Factor de corrección de pedregosidad ((1 - % piedras)/100), incluyendo substracción de gravas y piedras.

La evaluación de la pedregosidad, debe desarrollarse para aumentar la exactitud de los cálculos (Lorenz y Lal, 2016), para evitar sobrestimaciones o subestimaciones de densidad aparente y pedregosidad y, por consiguiente, la cantidad de tierra fina, pueden tener un fuerte impacto en las estimaciones de la reserva de carbono orgánico. Para evitar la sobrestimación de las poblaciones de COS, especialmente en suelos pedregosos, recientemente se propuso un cálculo más simple (Poeplau et al., 2017): Este cálculo subraya que el volumen muestreado (volúmenes de muestra) no debe ser corregido en base a la pedregosidad, sino que la prioridad debe ser estimar de manera precisa la masa de tierra fina (masa<sub>tierra fina</sub>).

$$C_R = p * D * (C_T - C_M) * \frac{m_t f}{v m}$$

## Análisis exploratorio de datos

Este análisis consiste en obtener las estadísticas básicas de resumen como media, valor máximo, valor mínimo, desviación estándar, coeficiente de variación, y coeficiente de asimetría para detectar valores anormales en las variables y requerimientos de transformación con el fin de mejorar el modelamiento requerido. Por lo tanto, se graficarán los mapas de las variables para la exploración de su distribución espacial y se calcularán los coeficientes de correlación de Pearson para evaluar el grado de asociación lineal entre las mismas.

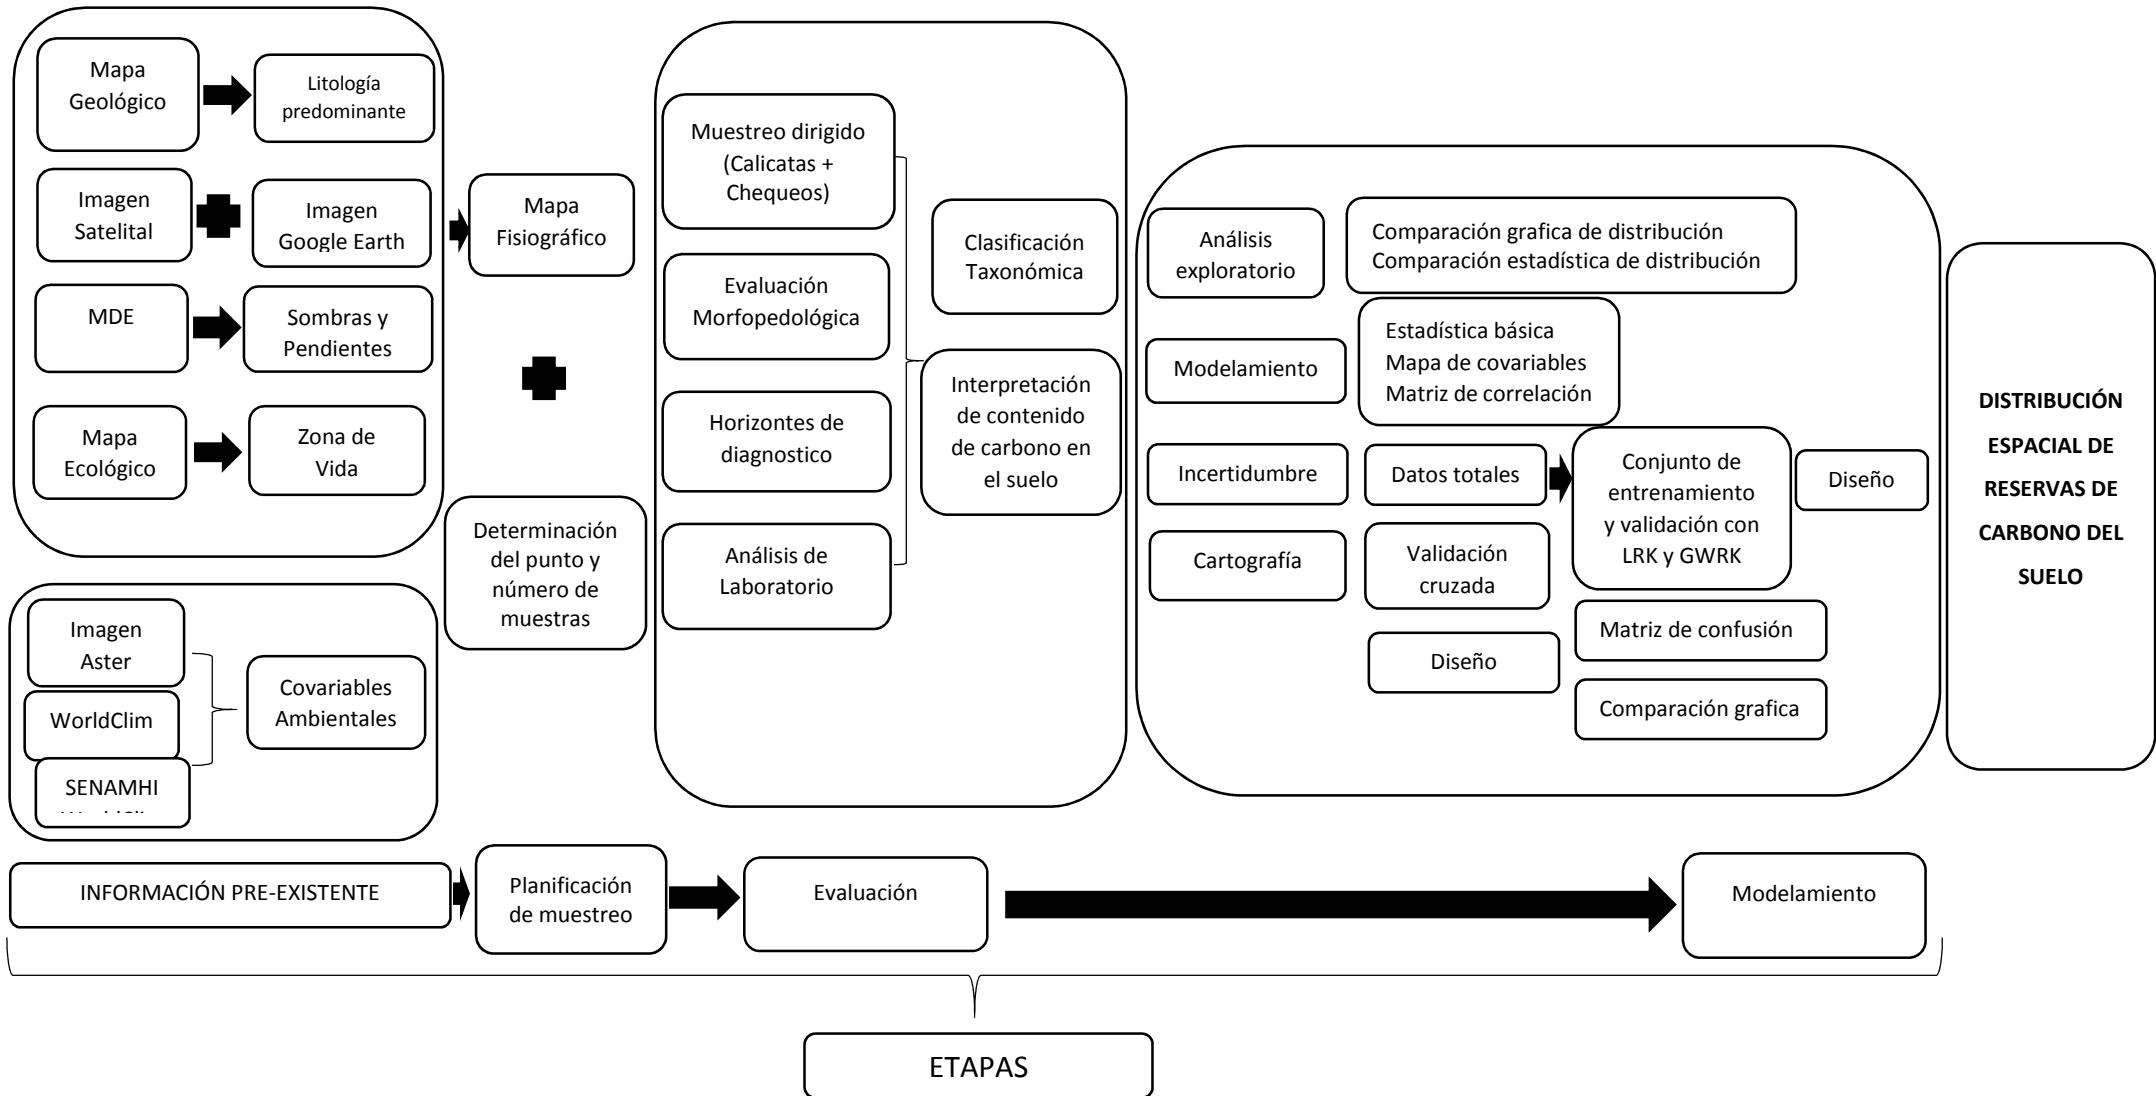
## Comparación mapeo digital de suelos y el mapa de la distribución del carbono orgánico del suelo

El modelamiento y comparación del mapeo de suelos se realizará de forma semicuantitativa superponiendo los mapas de unidades taxonómicas (mapeo digital) con el de unidades de la distribución del Carbono Orgánico del Suelo (COS) para visualizar coincidencia de los límites de cada uno. Además, se realizará una comparación entre el área por cada taxón de suelo (pureza de la unidad cartográfica) y el carbono orgánico estimado y calculada a través del mapa de unidades.

Tabla 4: Descripción general de covariables.

Nombre	Símbolo	Unidades	Factor de formación
Elevación	MDE	m.s.n.m.	Relieve
Pendiente	PD	Porcentaje	
Orientación	OR	Grados	
Índice de convergencia	ICO	Sin unidades	
Curvatura plana	CPP	Sin unidades	
Curvatura de perfil	CPL	Sin unidades	
Factor LS	LS	Sin unidades	
Posición relativa de la pendiente	RSP	Sin unidades	
Índice topográfico de humedad	TWI	M <sup>2</sup>	
Profundidad de los valles	VD	M	
Evapotranspiración anual acumulada	ET	mm	Clima
Precipitación anual acumulada	PPT	mm	
Temperatura Media anual	TM	°C	
Presión de vapor del agua	WVP	kPa	
Velocidad del viento	WS	m.s <sup>-1</sup>	
Radiación solar	RS	kJ.m <sup>-2</sup> dia <sup>-1</sup>	
Índice de cuarzos	QI	Sin unidades	Material parental
Índice de carbonatos	CI	Sin unidades	
Índice máfico	MI	Sin unidades	Organismos
Índice diferenciado de vegetación normalizada	NDVI	Sin unidades	
Costra biológica	CB	Sin unidades	

Figura 4. Procedimiento para el mapeo digital de carbono orgánico del suelo.



#### 7.4. Covariables ambientales

Las covariables ambientales utilizadas en este estudio incluyen: elevación, pendiente, índice de vegetación de diferencia normalizada (IVDN), productividad primaria neta (PPN), uso del suelo, temperatura media anual del aire y precipitación, temperatura de la superficie terrestre y tipos de lecho rocoso (Tabla 3).

El ángulo de la pendiente se calculará a partir del conjunto de datos del modelo de elevación digital (MED) (12.5 × 12.5 m) Alos palar, utilizando el módulo de análisis espacial del software ArcGIS versión 10.5 (ESRI, 2016). La información del tipo de roca del lecho del área de estudio se obtendrá del mapa de litología de INGEMENT. Los datos de la temperatura de la superficie terrestre (TST) (resolución espacial de 1 km) de los últimos 10 años se obtendrá de los conjuntos de datos compuestos de MODIS 8 días (<http://modis.gsfc.nasa.gov>). Los datos compuestos mensuales de temperatura media del aire y precipitación se recopilarán del Servicio Nacional de Meteorología e Hidrología (SENAMHI). El mapa de cobertura terrestre de uso actual de la tierra se procesará a través de imágenes satelitales y NDVI. Para obtener información sobre el tipo de suelo, se confeccionará el mapa de suelo con datos obtenidos en la etapa de campo representada a una escala determinada. La resolución espacial de todas las covariables ambientales se volvió a muestrear a 25 m utilizando el procedimiento de remuestreo de ArcGIS (ArcGIS versión 10.5, Environmental Systems Research Institute, Inc., Redlands, CA, EE. UU.).

Tabla 5. Variables ambientales requeridas para el estudio

VARIABLES	Datos	Resolución	Re-muestreo (m)	Fuente
LULC	Elaboración propia	5 m	5	
Orden del suelo	Mapa de suelos a escala 1: 100.000	Vector	-	<a href="http://geoservidorperu.minam.gob.pe/">http://geoservidorperu.minam.gob.pe/</a>
NDVI	MODIS NDVI 16 días Compuesto	250 m	25	<a href="http://modis.gsfc.nasa.gov">http://modis.gsfc.nasa.gov</a>
MDE	Alos palar	12.5m	-	<a href="http://earthexplorer.usgs.gov">http://earthexplorer.usgs.gov</a>
PPN	Productividad primaria neta anual de MODIS	1 km	25	<a href="http://modis.gsfc.nasa.gov">http://modis.gsfc.nasa.gov</a>
Lluvia	Datos de Worldclim	1 km	25	Fick and Hijmans (2017)
Temperatura media del aire	Datos de Worldclim	1 km	25	Fick and Hijmans (2017)
Tipo de Roca	INGEMMET	1:50000	25	<a href="https://geocatmin.ingemmet.gob.pe/geocatmin/">https://geocatmin.ingemmet.gob.pe/geocatmin/</a>
TST	MODIS 8 días Compuesto	1 km	25	<a href="http://modis.gsfc.nasa.gov">http://modis.gsfc.nasa.gov</a>

(LULC; Land Use Land Cover, IVDN; Índice de vegetación de diferencia normalizada, MDE; Modelo digital de elevación, PPN; Productividad primaria neta, TST; Temperatura de la superficie terrestre).

## 7.5. Enfoques de modelado predictivo

### 7.5.1. Regresión lineal kriging

Regresión lineal kriging (LRK) es una técnica de interpolación espacial que combina una regresión lineal de variable dependiente con variables auxiliares (Tabachnick y Fidell, 2007) con kriging de los residuos de regresión (Hengl et al., 2004). En este método, las reservas de carbono total del suelo en una ubicación sin muestrear se predicen sumando la deriva externa predicha con los residuos según la ecuación (1):

$$Z_{LRK}(S_0) = m_{MLR}(S_0) + e_{OK}(S_0) \dots\dots\dots (1)$$

Donde,  $Z_{LRK}(S_0)$  son las reservas estimadas de carbono total del suelo en la ubicación  $S_0$ ,  $m_{MLR}$  es el conjunto de deriva o valor predicho a partir de regresiones lineales múltiples (MLR) y  $e_{OK}$  son los valores kriged del MLR residual en el punto  $S_0$  utilizando kriging ordinario. En detalle, el kriging de regresión puede expresarse mediante la ecuación (2):

$$Z_{Li}(S_0) = \sum_{k=0}^p \beta_k \cdot Q_k(S_0) + \sum_{i=1}^n \lambda_i(S_0) \cdot e(S_i) Q_0(S_0) \dots\dots\dots (2)$$

Donde,  $\beta_k$  son los coeficientes del modelo determinista estimados ( $\beta_0$  es la intersección estimada),  $Q_k(S_0)$  es el k-ésimo predictor explicativo externo en la ubicación  $S_0$ ,  $p$  es el número de covariables,  $\lambda_i(S_0)$  es la ponderación de kriging determinada por la estructura de dependencia espacial del residuo, y  $e(S_i)$  es el residuo de regresión en la ubicación ( $S_i$ ). En el presente estudio,  $\beta_k$  se estima mediante un enfoque de regresión lineal múltiple tomando como variable dependiente los datos de reservas de carbono total del suelo transformados log-normales (transformados con Ln) y parámetros ambientales (NPP, NDVI, Elevación, etc.) como parámetros explicativos.

Las regresiones lineales múltiples escalonadas se llevaron a cabo utilizando el software SPSS (IBM, versión 24) para identificar los predictores estadísticamente significativos de carbono del suelo. Luego, se calcularon los residuos del modelo de reservas de carbono total del suelo transformados con Ln para las ubicaciones de las muestras y se ajustó la estructura de covarianza de los residuos del modelo de deriva utilizando un modelo de variograma. Los residuos de regresión se interpolaron luego usando kriging ordinario y se agregaron a la superficie estimada del modelo de deriva de las reservas de CT del suelo transformadas con Ln (Segunda parte de la Ec. (2)) (Odeh et al., 1995; Minasny y McBratney, 2007; Wang et al., 2012).

### 7.5.2. Regresión ponderada geográficamente kriging

GWR es una extensión de la regresión lineal múltiple destinada a capturar el componente no estacionario en los datos espaciales y donde los coeficientes de regresión ponderados localmente difieren de sus valores globales (Brunsdon et al., 2001; Fotheringham et al., 2002; Zhang et al., 2011). La principal diferencia entre la regresión lineal y el método GWR es que este último permite estimar

un parámetro local en lugar de un parámetro global teniendo en cuenta la ubicación del punto de datos espaciales (Kumar et al., 2012). GWRK es una técnica híbrida y una extensión adicional del método GWR para modelar procesos espacialmente heterogéneos (Kumar et al., 2012; Vitharana et al., 2019). El GWRK se expresó en el presente estudio según la Ec. (3):

$$Z_{\text{GWRK}}(S_0) = m_{\text{GWR}}(S_0) + e_{\text{OK}}(S_0) \dots \dots \dots (3)$$

donde,  $Z_{\text{GWRK}}(S_0)$  son las reservas de carbono total del suelo pronosticadas en la ubicación  $S_0$ ,  $m_{\text{GWR}}(S_0)$  es la deriva ajustada o el valor predicho usando el método GWR y  $e_{\text{OK}}(S_0)$  es el valor kriged del GWR residual en el punto  $S_0$  usando kriging ordinario. En el presente estudio, el mapa de stocks de carbono total del suelo predicho por GWR se generó utilizando el siguiente modelo de GWR (ecuación (4)):

$$Z_G(S_0) = \sum_{k=0}^p \beta_k(S_0) * \alpha_k(S_0) \dots \dots \dots (4)$$

donde,  $Z_{\text{GWRK}}(S_0)$  son las reservas de carbono total del suelo medidas en la ubicación  $S_0$ ,  $q_k(S_0)$  es el k-ésimo predictor explicativo externo con el valor  $q_k$  en la ubicación  $S_0$ ,  $p$  es el número total de variables predictoras y  $\beta_k$  es el coeficiente de regresión desconocido que es variante espacialmente. El GWR se llevó a cabo utilizando una caja de herramientas de estadística espacial del software ArcGIS versión 10.3 (Esri, 2014). Se usó un kernel espacial adaptativo para calcular los kernels de GWR (Zhang et al., 2011; Kumar et al., 2012; Wang et al., 2012). La selección del ancho de banda óptimo y la función de ponderación se obtuvo reduciendo el Criterio de información de Akaike (AIC) corregido (Fotheringham et al., 2002). El ancho de banda y los pesos aumentaron en la ubicación escasamente muestreada y disminuyeron en los lugares densamente muestreados en los modelos GWR (Jaimes et al., 2010). Los residuos de GWR espacialmente autocorrelacionados se interpolaron utilizando kriging ordinario ajustando el modelo de variograma exponencial utilizando el módulo de geoestadística en el software ArcGIS versión 10.3 (ESRI, 2014). Finalmente, el mapa GWRK se obtuvo agregando el mapa residual kriged con el mapa de reservas de carbono del suelo predicho por GWR.

### 7.6. Evaluación del modelo

La precisión de la predicción de los mapas de reservas de carbono total del suelo generados utilizando los métodos LRK y GWRK se evaluará utilizando conjuntos de datos de validación (que no se utilizaron para la predicción de reservas de carbono total del suelo). Los valores de las reservas de carbono total del suelo se extraerán de los mapas de reservas estimadas para los puntos de validación. Los valores predichos y observados en los puntos de validación se utilizarán para calcular el error medio de estimación (MEE), el error medio de estimación absoluto (MAEE), el error cuadrático medio (RMSE) y  $R^2$  utilizando las siguientes ecuaciones. (5, 6 y 7):



$$MEE = \frac{1}{n} \sum_{i=1}^n [C_s(S_i) - C_s(S_i)] \dots \dots \dots (5)$$

$$MAEE = \frac{1}{n} \sum_{i=1}^n [C_s(S_i) - C_s(S_i)] \dots \dots \dots (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [C_s(S_i) - C_s(S_i)]^2} \dots \dots \dots (7)$$

Donde,  $C_s(S_i)$  es el valor previsto de las reservas de carbono total del suelo mediante un método dado,  $C_s(S_i)$  son las reservas de carbono total del suelo observadas; y n es el número de puntos de validación. La mejora relativa (RI) del método GWRK sobre el método LRK se calculó usando la Ec. (8):

$$RI(\%) = \frac{R_L - R_G}{R_L} * 100 \dots \dots \dots (8)$$

Donde,  $RMSE_{RK}$  y  $RMSE_{GWRK}$  son el error cuadrático medio de raíz del método LRK y los métodos GWRK, respectivamente.

### 7.7 Análisis de incertidumbre

El mapeo digital de suelos implica el uso de observaciones de campo, modelos de predicción empíricos y una variedad de covariables ambientales para hacer predicciones espacialmente explícitas de las propiedades del suelo. Por lo tanto, las predicciones siempre están asociadas con incertidumbres que surgen de estas tres fuentes. Sin embargo, estas incertidumbres de diferentes fuentes serán representadas en los residuos del modelo. Por lo tanto, cuantificaremos la incertidumbre de las predicciones del stock de carbono orgánico del suelo utilizando los residuos del modelo normalmente distribuidos (Heuvelink, 2017; Mishra et al., 2017). Calculamos mapas de error estándar de predicción a partir de la varianza de kriging de los residuos de GWRK utilizando un enfoque de validación cruzada de la función Geostatistical Analyst de ArcGIS 10.5, generamos mapas de intervalos de confianza multiplicando los mapas de error estándar con el valor Z (1,96) que corresponde a un nivel de probabilidad del 95% (Malone et al., 2009; Mishra et al., 2017). El mapa de intervalo de confianza resultante se agregó y se restó de las predicciones de GWRK para calcular los límites de predicción superior e inferior del 95%, respectivamente.

## 7.8 Operacionalización de Variables

Tabla N° 6. Operacionalización de Variables

Categoría	Variable	Definición operacional	Indicador	Dimensión	Instrumentos
Dependiente	Suelo	Se puede realizar a partir de la organización del conocimiento de los diferentes factores formadores y de los procesos de génesis resultantes. Relacionado con; material originario, el clima, la actividad biológica, el relieve y el tiempo geológico transcurrido.	Tipo de suelo	Clasificación taxonómica	Soil Taxonomy
	Carbono orgánico del suelo	La cantidad de COS no solo depende de las condiciones ambientales locales, sino que es afectada fuertemente por el manejo del suelo.	Contenido de materia organica	% MO	) ) Calcinación Método de Walkley y Black
	Densidad aparente	La densidad aparente varía con la textura del suelo y el contenido de materia orgánica; puede variar estacionalmente por efecto de labranzas y con la humedad del suelo sobre todo en los suelos con arcillas expandibles.	Parametro fisico del suelo	Da g/cm <sup>3</sup>	) ) Cilindro muestreador Metodo de la Parafina
Independiente	Índice de Posición Topográfica (Relieve)	Permite describir aspectos morfológicos del territorio a través de mapas. El análisis de Modelos Digitales de Elevación nos ayuda a obtener mapas basados en el TPI discriminando si las zonas son llanas, presentan grados de pendientes, corresponden a crestas de montaña o por el contrario son zonas de valles.	MDE		Software ArcGIS versión 10.5
			Elevación	m.s.n.m.	
			Pendiente	Porcentaje (%)	
			Orientación	Grados	
			Índice de convergencia	Sin unidades	
			Curvatura plana	Sin unidades	
			Curvatura de perfil	Sin unidades	
			Factor LS	Sin unidades	
	Factores Climaticos	El clima influye directamente en la humedad y la temperatura del suelo, e indirectamente a través de la vegetación. La temperatura y la precipitación influyen en los procesos de alteración y transformación mineral, modificando la velocidad de muchas reacciones químicas que se dan en el suelo.	Evapotranspiración anual acumulada	mm	Datos de Worldclim
			Precipitación anual acumulada	mm	
Temperatura Media anual			°C		

		Presión de vapor del agua	kPa	
		Velocidad del viento	m/s	
		Radiación solar	kJ/m <sup>2</sup> /día	
Material parental	El material parental, o regolita, en ciencia del suelo, significa el material geológico inalterado (generalmente roca madre o de un depósito superficial o arrastrado) en donde se irán formando los horizontes del suelo.	Índice de cuarzos	Sin unidad	INGEMMET
		Índice de carbonatos	Sin unidad	
Vegetacion	El índice de vegetación diferencial normalizado o índice NDVI, responde a uno de los parámetros calculados mediante el juego de bandas para el estudio de cubiertas vegetales. Su fundamento radica en el análisis de los valores de reflectancia de longitudes de onda en diferentes secciones del espectro electromagnético.	Índice diferenciado de vegetación normalizada	Sin unidades	Software ArcGIS versión 10.5

## VIII. CRONOGRAMA DE ACTIVIDADES

Inicio: 01 de marzo 2021

Término: 28 de febrero 2022

Tabla 7. Cronograma de actividades

Actividad	Marzo 2021 – Febrero 2022											
	M	A	M	J	J	A	S	O	N	D	E	F
Planificación de la investigación	X											
Recopilación de datos cartográficos		X	X									
Muestreo y preparación para análisis químico				X	X							
Adquisición de datos meteorológicos					X							
Muestreo de datos para mapa de carbono orgánico					X							
Estimación de reserva de carbono						X						
Análisis exploratorio de datos							X					
Comparación de mapeo digital de suelos								X				
Mapa de distribución de carbono orgánico								X				
Análisis de regresión lineal de Kriging									X			
Análisis de regresión ponderada de Kriging									X			
Evaluación de modelo										X		
Análisis de incertidumbre										X		
Ajuste de parámetros evaluados											X	
Redacción e informe final												X

## IX. PRESUPUESTO

En el presupuesto de la investigación se consideran los siguientes rubros: 1. Personal, 2 Materiales y equipos, 3. Servicios, y 4. Imprevistos.

Tabla 8. Detalle de presupuesto para la investigación

Rubro	Cantidad	Unidad	Costo unitario Soles	Costo parcial Soles	Costo total Soles
<b>01.00 BIENES</b>					<b>15,650.00</b>
Materiales de escritorio	02	unidades	400.00	800.00	800.00
Materiales de impresión	15	millares	30.00	450.00	450.00
Materiales de campo	01	global	1,500.00	1,500.00	1,500.00
Datos meteorológicos	01	global	1,500.00	1,500.00	1,500.00
Análisis de suelo	60	muestra	120.00	7,200.00	7,200.00
Información cartográfica	01	global	3,200.00	3,200.00	3,200.00
Impresión de mapas	20	unidades	50.00	1,000.00	1,000.00
<b>02.00 SERVICIOS</b>					<b>6,500.00</b>
Responsable	10	pasaje	50.00	1,000.00	1,000.00
Patrocinador	05	pasaje	50.00	250.00	2,500.00
ayudantes	10	pasaje	50.00	1,000.00	1,000.00
impresiones	01	Global	2000.00	2,000.00	2,000.00
<b>Imprevistos (10%)</b>					<b>2,215.00</b>
<b>TOTAL</b>					<b>24,365.00</b>

## **X. BIBLIOGRAFÍA**

- Amare, T., Hergarten, C., Hurni, H., Wolfgramm, B., Yitaferu, B., Selassie, Y.G., 2013. Prediction of soil organic carbon for Ethiopian highlands using soil spectroscopy. *ISRN Soil Sci* 2013, 1–11.
- Arrouays, D; Lagacherie, P; Hartemink, AE. 2017. Digital soil mapping across the globe. *Geoderma Regional* 9:1-4.
- Ayala, J. E., Márquez, C. O., García, V. J., Recalde, C. G., Rodríguez, M.-V., & Damián, D. A. (2017). Land cover classification in an ecuadorian mountain geosystem using a random forest classifier, spectral vegetation indices, and ancillary geographic data. *Geosciences (Switzerland)*, 7(2). <https://doi.org/10.3390/geosciences7020034>
- Baldock, J.A., Skjemstad, J.O., 1999. SOC/soil organic matter. In: Peverill, K.I., Sparrow, L.A., Reuter, D.J. (Eds.), *Soil Analysis: an Interpretation Manual*. Collingwood, CSIRO Publishing, pp. 159–170.
- Banger, K., Tian, H., Tao, B., Lu, C., Ren, W., Yang, J., 2015. Magnitude, spatiotemporal patterns, and controls for SOC stocks in India during 1901–2010. *Soil Sci Soc Am J* 79, 864–875.
- Batjes, N.H., 2016. Harmonized soil property values for broad-scale modelling (WISE30sec) with estimates of global soil carbon stocks. *Geoderma* 269, 61–68.
- Bhattacharyya, T., Pal, D.K., Mandal, C., Velayutham, M., 2000. Organic carbon stock in Indian soils and their geographical distribution. *Curr Sci* 79, 655–660.
- Burke, C., Yonker, C.M.W., Parton, J., Cole, C.V., Flach, K., Schimel, D.S., 1989. Texture, climate, and cultivation effects on soil organic matter content in U.S. Grassland soils. *Soil Sci Soc Am J* 53, 800–805.
- Broadbent, F.E., 1953. The soil organic fraction. *Advan. Agron.* 5, 153-183.
- Brunsdon, C., McClatchey, J., Unwin, D.J., 2001. Spatial variations in the average rainfall–altitude relationship in Great Britain: an approach using geographically weighted regression. *Int J Climatol* 21 (4), 455–466.
- Brevik, EC; Calzolari, C; Miller, BA; Pereira, P; Kabala, C; Baumgarten, A; Jordán, A. 2016. Soil mapping, classification, and pedologic modeling: History and future directions. *Geoderma* 264: 256-274.
- Brungard, CW; Boettinger, JL; Duniway, MC; Wills, SA; Edwards, TC. 2015. Machine learning for predicting soil classes in three semi-arid landscapes. *Geoderma* 239-240(2015): 68-83.

- Burrough, PA; Van Gaans, PFM; Hootsmans, R. 1997. Continuous classification in soil survey: Spatial correlation, confusion and boundaries. *Geoderma* 77(2-4): 115-135.
- Cambule, A.H., Rossiter, D.G., Stoorvogel, J.J., Smaling, E.M.A., 2014. Soil organic carbon stocks in the Limpopo National Park, Mozambique: amount, spatial distribution and uncertainty. *Geoderma* 213, 46–56.
- Cheng, W; Zhu, A xing; Qin, C zhi; Qi, F. 2019. Updating conventional soil maps by mining soil–environment relationships from individual soil polygons. *Journal of Integrative Agriculture* 18(2): 265-278.
- Conrad, O; Bechtel, B; Bock, M; Dietrich, H; Fischer, E; Gerlitz, L; Wehberg, J; Wichmann, V; Böhner, J. 2015. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geoscientific Model Development* 8(7):1991-2007. DOI: <https://doi.org/10.5194/gmd-8-1991-2015>.
- Dadhwal, V.K., Nayak, S.R.I., 1993. A preliminary estimate of biogeochemical cycle of Carbon for India. *Sci Cult* 59, 9–13.
- D'Acqui, L.P.D., Pucci, A., Janik, L.J., 2010. Soil properties prediction of western Mediterranean islands with similar climatic environments by means of mid-infrared diffuse reflectance spectroscopy. *Eur J Soil Sci* 61, 865–876.
- Dharumarajan, S., Rajendra, H., Singh, S.K., 2017. Spatial prediction of major soil properties using Random Forest techniques-A case Study in Semi-arid tropics of South India. *Geoderma Reg* 10, 154–162.
- FAO. (2017b). Soil Organic Carbon: the hidden potential. Rome, Italy. <https://doi.org/10.1038/nrg2350>
- Dorji, T., Odeh, I.O.A., Field, D.J., Baillie, I.C., 2014. Digital soil mapping of soil organic carbon stocks under different land use and land cover types in montane ecosystems. *Eastern Himalayas Forest Ecol Manag* 318, 91–102.
- Florinsky, I.V., Eilers, R.G., Manning, G.R., Fuller, L.G., 2002. Prediction of soil properties by digital terrain modelling. *Environ Model Software* 17, 295–311.
- Fotheringham, A.S., Brunsdon, C., Charlton, M., 2002. *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*. Wiley, Chichester.
- Grimm, R., Behrens, T., Märker, M., Elsenbeer, H., 2008. Soil organic carbon concentrations and stocks on Barro Colorado Island—Digital soil mapping using Random Forests analysis. *Geoderma* 146, 102–113.

- Hengl, T., Heuvelink, G.B.M., Stein, A., 2004. A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma* 120, 75–93
- Heuvelink, G.B.M., 2017. Uncertainty. In: Yigini, Y., Baritz, R., Vargas, R. (Eds.), *Soil Organic Carbon Mapping : GSOC Map Cookbook Manual*. FAO, Rome, pp. 109–121.
- Heuvelink, G., Webster, R., 2001. Modelling soil variation: past, present and future. *Geoderma* 100, 269–301.
- Heuvelink, G.B.M., 2017. Uncertainty. In: Yigini, Y., Baritz, R., Vargas, R. (Eds.), *Soil Organic Carbon Mapping : GSOC Map Cookbook Manual*. FAO, Rome, pp. 109–121.
- Hoosbeek, M.R., Bryant, R.B., 1992. Towards the quantitative modeling of pedogenesis — a review. *Geoderma* 55, 183–210.
- Hofstede, R., Calles, J., López, V., Polanco, R., Torres, F., Ulloa, J., ... Cerra, M. (2014). Los páramos Andinos ¿Qué Sabemos? Estado de conocimiento sobre el impacto del cambio climático en el ecosistema páramo. UICN, Quito, Ecuador.
- Hofstede, R., Josse, C., Lasso, S., Medina, G., Ochoa, N., & Ortiz, D. (2011). Páramo. Paisaje habitado, manejado e institucionalizado. (EcoCiencia, Abya-Yala, & ECOBONA, Eds.).
- Huang, Y., Sun, W.J., 2006. Changes in top SOC of croplands in mainland China over the last two decades. *Chin Sci Bull* 51, 1785–1803.
- INRENA, “Estudio de Evaluación de los Recursos Hídricos en las Cuencas de los Ríos Cabanillas y Lampa”, Estudio de Hidrología, Intendencia de Recursos Hídricos. ATDR Juliaca. Juliaca, 2008.
- Jaimes, N.B.P., Sendra, J.B., Delgado, M.G., Plata, R.F., 2010. Exploring the driving forces behind deforestation in the state of Mexico (Mexico) using geographically weighted regression. *Appl Geogr* 30, 576–591.
- Jaber, S.M., Al-Qinna, M.I., 2011. Soil organic carbon modeling and mapping in a semi-arid environment using thematic mapper data. *Photogram Engg Remote Sensing* 77, 709–719.
- Jenny H. 1941. *Factors of Soil Formation. A System of Quantitative Pedology*. Ed. Mc. Graw-Hill, USA. 281 p.
- Krishan, G., Srivastav, S.K., Kumar, S., Saha, S.K., Dadhwal, V.K., 2009. Quantifying the underestimation of soil organic carbon by the Walkley and Black technique—examples from Himalayan and Central Indian soils. *Curr Sci* 96 (8), 1133–1136.

- Kumar, S., Rattan, L., Desheng, L., 2012. A geographically weighted regression kriging approach for mapping soil organic carbon stock. *Geoderma* 189, 627–634.
- Lacoste, M., Minasny, B., McBratney, A., Michot, D., Viaud, V., Walter, C., 2014. High resolution 3D mapping of soil organic carbon in a heterogeneous agricultural landscape. *Geoderma* 213, 296–311.
- Le Quere, C., et al., 2015. Global carbon budget 2014. *Earth Syst Sci Data* 7, 47–85.
- Lesch, S.M., Corwin, D.L., 2008. Prediction of spatial soil property information from ancillary sensor data using ordinary linear regression: Model derivations, residual assumptions and model validation tests. *Geoderma* 148, 130–140.
- Lin, C., Liu, J., Wang, R., Wang, Y., Huang, B. & Pan, X. 2013. Polycyclic Aromatic Hydrocarbons in Surface Soils of Kunming, China: Concentrations, Distribution, Sources, and Potential Risk. *Soil and Sediment Contamination: An International Journal*, 22(7): 753–766. <https://doi.org/10.1080/15320383.2013.768201>
- Lorenz, K. & Lal, R. 2016. Soil Organic Carbon - An appropriate Indicator to Monitor Trends of Land and Soil Degradation within the SDG Framework? Dessau-Roßlau: Umweltbundesamt.
- Ma Oliver & R. Webster (1990) Kriging: un método de interpolación para sistemas de información geográfica, *International Journal of Geographical Information Systems*, 4: 3, 313-332, DOI: 10.1080 / 02693799008941549
- Malone, B.P., McBratney, A.B., Minasny, B., Laslett, G.M., 2009. Mapping continuous Depth functions of soil carbon storage and available water capacity. *Geoderma* 154, 138–152.
- Martínez, E., Fuentes, J. P., & Acevedo, E. (2008). Carbono orgánico y propiedades del suelo. *Revista de La Ciencia Del Suelo y Nutrición Vegetal*, 8(1), 68–96. <https://doi.org/10.4067/S0718-27912008000100006>
- Martin, M.P., Orton, T.G., Lacarce, E., Meersmans, J., Saby, N.P.A., Paroissien, J.B., Jolivet, C., Boulonne, L., Arrouays, D., 2014. Evaluation of modelling approaches for predicting the spatial distribution of soil organic carbon stocks at the national scale. *Geoderma* 223, 97–107.
- Mena, P., Josse, C., & Medina, G. (2000). Los suelos de los Páramos del Ecuador. *Los Suelos Del Páramo*, 1–75. <https://doi.org/ISSN 1390-1222>
- Meng, Q., 2014. Regression kriging versus geographically weighted regression for spatial interpolation. *Int J Advance Remote Sens GIS* 3 (1), 606.
- Minasny, B., McBratney, A.B., 1999. A rudimentary mechanistic model for soil production and landscape development. *Geoderma* 90, 3–21.



- Minasny, B., McBratney, A.B., 2018. Limited effect of organic matter on soil available water capacity. *Eur. J. Soil Sci.* 69, 39–47.
- Mishra, U., Riley, W.J., 2012). Alaskan soil carbon stocks: spatial variability and dependence on environmental factors. *Biogeosciences* 9 (9), 3637–3645.
- Mishra, U., Drewniak, B., Jastrow, J.D., Matamala, R.M., Vitharana, U.W.A., 2017. Spatial representation of high latitude organic carbon and active-layer thickness in CMIP5 earth system models. *Geoderma* 300, 55–63.
- Mondal, A., Deepak, K., Sananda, K., Surajit, M., Sandip, M., Anirban, M., 2017. Spatial soil organic carbon (SOC) prediction by regression kriging using remote sensing data. *Egypt J Remote Sensing Space Sci* 20 (1), 61–70.
- Odeh, I.O.A., McBratney, A.B., Chittleborough, D.J., 1995. Further results on prediction of soil properties from terrain attributes-heterotropy cokriging and regression-kriging. *Geoderma* 67, 215–226.
- ONERN (Oficina Nacional de Evaluación de Recursos Naturales). 1965. Programa de inventario y evaluación de los recursos naturales del departamento de Puno. ONERN, Puno, Perú, 212 pp.
- Ordoñez, José (2001) Captura de carbono ante el cambio climático, instituto de ecología A.C. Xalapa, Mexico.
- Poepflau, C., Vos, C. & Don, A. 2017. Soil organic carbon stocks are systematically overestimated by misuse of the parameters bulk density and rock fragment content. *SOIL*, 3(1): 61–66. Disponible en: <https://doi.org/10.5194/soil-3-61-2017>
- Porta, J.; López-Acevedo, M. & Roquero, C. (2003). *Edafología para la Agricultura y el Medio Ambiente*. 3ª Edición. Mundi-Prensa. 929 pp.
- Ramachandran, A., Jayakumar, S., Haroon, R.M., Bhaskaran, A., Arockiasamy, D.I., 2007. Carbon sequestration: estimation of carbon stock in natural forests using geospatial technology in the Eastern Ghats of Tamil Nadu. *India Curr Sci* 92 (3), 323–331.
- Rawlins, M.A., Serreze, M.C., Schroeder, R., Zhang, X., McDonald, K.C., 2009. Diagnosis of the record discharge of Arctic-draining Eurasian Rivers in 2007. *Environ Res Lett* 4, 1–11.
- Sá et al., 2011., .M. Sá, S.X. Li, B. Faubert Faculties of education and institutional strategies for knowledge mobilization: an exploratory study *High Educ.*, 61 (5) (2011), pp. 501-512
- Sreenivas, K., Sujatha, G., Sudhir, K., Kiran, D.V., Fyzee, M.A., Ravisankar, T., Dadhwal, V.K., 2014. Spatial assessment of soil organic carbon density through randomforests based imputation. *J Indian Soc Remote Sensing* 42 (3), 577–587.

- Schulp, C.J.E., Verburg, P.H., 2009. Effect of land use history and site factors on spatial variation of soil organic carbon across a physiographic region. *Agric Ecosyst Environ* 133 (1), 86–97.
- Scull, P., Franklin, J., Chadwick, O.A., McArthur, D., 2003. Predictive soilmapping: a review. *Prog Phys Geogr* 27, 171–197.
- Sreenivas, K., Sujatha, G., Sudhir, K., Kiran, D.V., Fyzee, M.A., Ravisankar, T., Dadhwal, V.K., 2014. Spatial assessment of soil organic carbon density through randomforests based imputation. *J Indian Soc Remote Sensing* 42 (3), 577–587.
- Sreenivas, K., Dadhwal, V.K., Kumar, S., Harsha, G.S., Mitran, T., Sujatha, G., Suresh, G.J.R., Fyzee, M.A., Ravisankar, T., 2016. Digital mapping of soil organic and inorganic carbon status in India. *Geoderma* 269, 160–173.
- Soil Survey Staff, 2014; Keys to Soil Taxonomy. Natural Resources Conservation Service. USA. Department of Agriculture. Twelfth Edition. 305 pg.
- Soil Survey Division Staff, 1993; Soil Survey Manual. Soil Conservation Service. U.S. Department of Agriculture Handbook 18. 315 pg.
- Tabachnick, B.G., Fidell, L.S., 2007. *Multilevel Linear Modeling: Using Multivariate Statistics* pp. 781–857.
- Tiwari, S.K., Saha, S.K., Kumar, S., 2015. Prediction Modeling and mapping of soil carbon content using artificial neural network, hyperspectral satellite data and field spectroscopy. *Adv Remote Sens* 4 (01), 63–72.
- Van Looy, K., Bouma, J., Herbst, M., Koestel, J., Minasny, B., Mishra, U., et al., 2017. Pedotransfer functions in Earth system science: challenges and perspectives. *Rev. Geophys.* 55, 1199–1256.
- Vitharana, U.W.A., Mishra, U., Mapa, R.B., 2019. National soil organic carbon estimates can improve global estimates. *Geoderma* 337, 55–64.
- Wang, K., Zhang, C., Weidong, Li, 2012. Comparison of geographically weighted regression and regression kriging for estimating the spatial distribution of soil organic matter. *GISci Remote Sens* 49 (6), 915–932.
- Wani, N., Velmurugan, A., Dadhwal, V.K., 2010. Assessment of agricultural crop and soil carbon pools in Madhya Pradesh. *India Trop Ecol* 51 (1), 11–19
- Wu, C., Wu, J., Luo, Y., Zhang, L., Degloria, S.D., 2009. Spatial prediction of soil organic matter content using cokriging with remotely sensed data. *Soil Sci Soc Am J* 73, 1202–1208.

- Yang, Y., Fang, J., Tang, Y., Ji, C., Zheng, C., He, J., Zhu, B., 2008. Storage, patterns and controls of soil organic carbon in the Tibetan grasslands. *Glob Chang Biol* 14, 1592–1599.
- Yang, R.M., Zhang, G.L., Liu, F., Lu, Y.Y., Yang, F., Yang, F., Yang, M., Zhao, Y.G., Li, D.C., 2016. Comparison of boosted regression tree and random forest models for mapping topsoil organic carbon concentration in an alpine ecosystem. *Ecol Indic* 60, 870–878.
- Zhang, C., Tang, Y., Xu, X., Kiely, G., 2011. Towards spatial geochemical modelling: Use of geographically weighted regression for mapping soil organic carbon contents in Ireland. *Appl Geochem* 26, 1239–1248.
- Zhu, A.X., Liu, J., Du, F., Zhang, S.J., Qin, C.Z., Burt, J., Behrens, T., Scholten, T., 2015. Predictive soil mapping with limited sample data. *Eur J Soil Sci* 66, 535–547.

M. Sc. Daniel Canaza Mamani  
TESISTA

Dr. Elmer Calizaya Llatasi  
ASESOR