



**UNIVERSIDAD NACIONAL
TORIBIO RODRÍGUEZ DE MENDOZA DE AMAZONAS**

**FACULTAD DE INGENIERÍA CIVIL Y AMBIENTAL
ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE
INGENIERO AMBIENTAL**

**ANÁLISIS DE LA DISTRIBUCIÓN ESPACIAL DE
PARÁMETROS FÍSICO-QUÍMICOS EN EL SUELO
APLICANDO SIG, UTCUBAMBA, AMAZONAS, PERÚ**

Autor: Bach. Gerson Meza Mori

Asesor: Ing. Rolando Salas López

Co-Asesor: Ing. Nilton Beltrán Rojas Briceño

Registro:

CHACHAPOYAS - PERÚ

2019



**UNIVERSIDAD NACIONAL
TORIBIO RODRÍGUEZ DE MENDOZA DE AMAZONAS**

**FACULTAD DE INGENIERÍA CIVIL Y AMBIENTAL
ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE
INGENIERO AMBIENTAL**

**ANÁLISIS DE LA DISTRIBUCIÓN ESPACIAL DE
PARÁMETROS FÍSICO-QUÍMICOS EN EL SUELO
APLICANDO SIG, UTCUBAMBA, AMAZONAS, PERÚ**

Autor: Bach. Gerson Meza Mori

Asesor : Ing. Rolando Salas López

Co-Asesor: Ing. Nilton Beltrán Rojas Briceño

Registro:

CHACHAPOYAS - PERÚ

2019

DEDICATORIA

A MI FAMILIA

Con amor para mis padres Hermegildo Meza Damacén y Victoria Mori Vergaray, porque son de los grandes ejemplos que tengo en mi vida, guiándome con sus consejos para ser una persona con valores morales y espirituales. Han influido significativamente en mi vida, con cada gesto de amor y paciencia me supieron apoyar hasta lograr esta meta. Y a mis hermanas Rosa E. Meza Mori y Anita L. Meza Mori, que gracias a su sacrificio, comprensión y consejos han hecho posible mi formación y realización profesional.

A MIS AMIGOS

A todas las personas, compañeros y docentes, que en el transcurso de mi carrera han aportado de diferentes maneras.

AGRADECIMIENTO

A Dios, porque día tras día me concede la vida, me da fuerzas para seguir adelante y con su inmensa sabiduría ha puesto las personas e instrucciones apropiadas en mi arduo camino para lograr mis metas. Y por darme una madre y un padre que, con su apoyo incondicional, llenos de principios y valores, han sabido guiarme por el buen sendero.

Al Instituto de Investigación para el Desarrollo Sustentable de Ceja de Selva (INDES-CES), que a través del proyecto SNIP 312235 “Creación del Servicio de un Laboratorio Geomática y Teledetección de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas” - GEOMÁTICA; hizo posible la financiación de la investigación.

Al asesor, el Ing. Rolando Salas López, y Co-Asesor, el Ing. Nilton Beltrán Rojas Briceño, porque me brindaron las facilidades para ejecutar esta tesis, su amistad, confianza, paciencia y tiempo para dotar del conocimiento práctico y científico en este asombroso campo de los Sistemas de Información Geográfica (SIG) aplicada a la gestión y manejo de recursos naturales.

A los docentes miembros del jurado, al M.Sc. Jaris Emmanuel Veneros Guevara, el M.Sc. Elí Pariente Mondragón y el M.Sc. Lenin Quiñones Huatangari, por sus aportes y recomendaciones al manuscrito inicial, dando la oportunidad de aclarar las ideas y presentarlas en un lenguaje fácil de comprensión para cualquier lector.

A mis amigos, el Ing. Elgar Barboza Castillo y el Ing. Nelson Yohel Rodríguez Calampa, quienes coadyuvaron en la elaboración y ejecución de esta tesis, por su apoyo en los trabajos de campo y orientación en la elaboración del informe.

AUTORIDADES UNIVERSITARIAS

Dr. Policarpio Chauca Valqui

Rector

Dr. Miguel Ángel Barrena Gurbillón

Vicerrector Académico

Dra. Flor Teresa García Huamán

Vicerrectora de Investigación

M.Sc. Edwin Adolfo Díaz Ortiz

Decano de la Facultad de Ingeniería Civil y Ambiental

VISTO BUENO DEL ASESOR DE LA TESIS

El docente de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas quien suscribe, hace constar que ha asesorado la tesis titulada “ANÁLISIS DE LA DISTRIBUCIÓN ESPACIAL DE PARÁMETROS FÍSICO-QUÍMICOS EN EL SUELO APLICANDO SIG, UTCUBAMBA, AMAZONAS, PERÚ”, del tesista egresado de la Facultad de Ingeniería Civil y Ambiental, Escuela Profesional de Ingeniería Ambiental:

Bach. Gerson Meza Mori

El suscrito da el visto bueno de la mencionada tesis dándole pase para que sea sometida a la revisión por el jurado evaluador comprometiéndose a supervisar el levantamiento de las observaciones que formulen para su posterior sustentación.

Chachapoyas, octubre de 2019.



Ing. Rolando Salas López
Asesor

VISTO BUENO DEL CO-ASESOR DE LA TESIS

El docente de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas quien suscribe, hace constar que ha asesorado la tesis titulada “ANÁLISIS DE LA DISTRIBUCIÓN ESPACIAL DE PARÁMETROS FÍSICO-QUÍMICOS EN EL SUELO APLICANDO SIG, UTCUBAMBA, AMAZONAS, PERÚ”, del tesista egresado de la Facultad de Ingeniería Civil y Ambiental, Escuela Profesional de Ingeniería Ambiental:

Bach. Gerson Meza Mori

El suscrito da el visto bueno de la mencionada tesis dándole pase para que sea sometida a la revisión por el jurado evaluador comprometiéndose a supervisar el levantamiento de las observaciones que formulen para su posterior sustentación.

Chachapoyas, octubre de 2019.



Ing. Nilton Beltrán Rojas Briceño
Co-Asesor

JURADO EVALUADOR



M. Sc. Jaris Emmanuel Veneros Guevara

Presidente



M. Sc. Elí Pariente Mondragón

Secretario



M. Sc. Lenin Quiñones Huatangari

Vocal



ANEXO 3-K

**DECLARACIÓN JURADA DE NO PLAGIO DE TESIS
PARA OBTENER EL TÍTULO PROFESIONAL**

Yo Gerson Meza Mori
identificado con DNI N° 71634466 Estudiante()/Egresado () de la Escuela Profesional de
Ingeniería Ambiental de la Facultad de:
Ingeniería Civil y Ambiental
de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas.

DECLARO BAJO JURAMENTO QUE:

1. Soy autor de la Tesis titulada: Análisis de la distribución espacial de
parámetros físico-químicos en el suelo aplicando SIG, Utebamba,
Amazonas, Perú

que presento para
obtener el Título Profesional de: Ingeniero Ambiental

2. La Tesis no ha sido plagiada ni total ni parcialmente, y para su realización se han respetado las normas internacionales de citas y referencias para las fuentes consultadas.
3. La Tesis presentada no atenta contra derechos de terceros.
4. La Tesis presentada no ha sido publicada ni presentada anteriormente para obtener algún grado académico previo o título profesional.
5. La información presentada es real y no ha sido falsificada, ni duplicada, ni copiada.

Por lo expuesto, mediante la presente asumo toda responsabilidad que pudiera derivarse por la autoría, originalidad y veracidad del contenido de la Tesis para obtener el Título Profesional, así como por los derechos sobre la obra y/o invención presentada. Asimismo, por la presente me comprometo a asumir además todas las cargas pecuniarias que pudieran derivarse para la UNTRM en favor de terceros por motivo de acciones, reclamaciones o conflictos derivados del incumplimiento de lo declarado o las que encontraren causa en el contenido de la Tesis.

De identificarse fraude, piratería, plagio, falsificación o que la Tesis para obtener el Título Profesional haya sido publicado anteriormente; asumo las consecuencias y sanciones civiles y penales que de mi acción se deriven.

Chachapoyas, 18 de Octubre de 2019

[Firma]
Firma del(a) tesista



ANEXO 2-N

ACTA DE EVALUACIÓN DE SUSTENTACIÓN DE LA TESIS

En la ciudad de Chachapoyas, el día 18 de octubre del año 2019, siendo las 3:00 pm horas, el aspirante: Meza Mori, Gerson

defiende públicamente la Tesis titulada: Análisis de la distribución espacial de parámetros físico-químicos en el suelo aplicando SIG, Utcubamba, Amazonas, Perú

para optar el Título Profesional en Ingeniería Ambiental

otorgado por la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas, ante el Jurado, constituido por:

Presidente: Ing. M.Sc. Jaris Emmanuel Guevara

Secretario: Ing. M.Sc. Eli Poriente Mondragón

Vocal: Lic. Mg. Lenin Quinones Huatangari

Procedió el (los) aspirante (s) a hacer la exposición de los antecedentes, contenido de la tesis y conclusiones obtenidas de la misma, haciendo especial mención de sus aportaciones originales. Terminada la defensa de la tesis presentada, los miembros del jurado pasaron a exponer su opinión sobre la misma, formulando cuantas cuestiones u objeciones consideran oportunas, las cuales fueron contestadas por el los aspirante (s).

Tras la intervención de los miembros del jurado y las oportunas contestaciones del aspirante, el Presidente abre un turno de intervenciones para los miembros del jurado presentes en el acto, a fin de que formulen las cuestiones u objeciones que consideren pertinentes.

Seguidamente, a puerta cerrada, el jurado determinará la calificación global concedida a la tesis, en términos de:

Notable o sobresaliente () Aprobado (X) No apto ()

Otorgada la calificación el presidente del Jurado comunica, en sesión pública, la calificación concedida. A continuación se levanta la sesión.

Siendo las horas 5:00 pm del mismo día, el jurado concluye el acto de sustentación del Trabajo de Investigación.


PRESIDENTE


SECRETARIO


VOCAL

OBSERVACIONES:

CONTENIDO

DEDICATORIA	iii
AGRADECIMIENTO	iv
AUTORIDADES UNIVERSITARIAS	v
VISTO BUENO DEL ASESOR DE LA TESIS	vi
VISTO BUENO DEL CO-ASESOR DE LA TESIS	vii
JURADO EVALUADOR	viii
DECLARACIÓN JURADA DE NO PLAGIO.....	ix
ACTA DE EVALUACIÓN DE SUSTENTACIÓN DE TESIS	x
CONTENIDO	xi
ÍNDICE DE TABLAS	xiii
ÍNDICE DE FIGURAS.....	xiv
RESUMEN.....	xv
ABSTRACT.....	xvi
I. INTRODUCCIÓN.....	17
II. MATERIALES Y MÉTODOS	19
2.1. Área de estudio	19
2.2. Población, muestra y muestreo.....	20
2.3. Materiales, equipos y software	20
2.4. Diseño metodológico.....	22
2.5. Determinación de parámetros físico-químicos del suelo.....	23
2.5.1. Recolección de muestras de suelo.....	23
2.5.2. Análisis de parámetros físico-químicos de la muestra de suelo.....	23
2.6. Modelado geoestadístico la distribución espacial de parámetros físico-químicos en el suelo..	24
2.6.1. Inclusión de datos de parámetros físico-químicos en un SIG.....	24
2.6.2. Variables cualitativas y cuantitativas para el modelado geoestadístico.....	24
2.6.3. Modelo geoestadístico.....	29
2.7. Determinación de la precisión de los mapas de la distribución de parámetros físico-químicos	32
III. RESULTADOS	33
3.1. Resultados de los parámetros físico-químicos.....	33

3.1.1. Análisis factorial que afecta los patrones espaciales del contenido de parámetros físico-químicos en suelos	34
3.2. Modelos geoestadísticos de la distribución espacial de los parámetros físico-químicos....	37
3.2.1. Análisis de la estructura espacial	37
3.2.2. Predicción de la distribución espacial de parámetros físico-químicos	39
3.3. Precisión de los mapas de la distribución de los parámetros físico-químicos	47
IV. DISCUSIÓN.....	50
4.1. Resultados de los parámetros físico-químicos	50
4.2. Modelos geoestadísticos de la distribución espacial de los parámetros físico-químicos ...	51
4.3. Precisión de los mapas de la distribución de los parámetros físico-químicos.....	53
V. CONCLUSIONES	54
VI. RECOMENDACIONES	55
VII. REFERENCIAS BIBLIOGRÁFICAS	57
ANEXOS	64
Anexo 1. Pruebas de normalidad de los métodos KO, Rk y GWRK.	64
Anexo 2. Relaciones del pH con las variables cualitativas y cuantitativas en RK.....	67
Anexo 3. Relaciones de la C.E. con las variables cualitativas y cuantitativas en RK.	71
Anexo 4. Variación espacial de cada variable con el método GWRK de pH.....	74
Anexo 5. Variación espacial de cada variable con el método GWRK de C.E.	77
Anexo 6. Diagramas del pH y clase textual del suelo.	79
Anexo 7. Panel fotográfico.	81

ÍNDICE DE TABLAS

Tabla 1. Materiales, equipos y software.....	20
Tabla 2. Uso del suelo en la provincia de Utcubamba.	26
Tabla 3. Tipo de suelo en la provincia de Utcubamba.....	26
Tabla 4. Geología en la provincia de Utcubamba.	27
Tabla 5. Estadística descriptiva de las propiedades físico-químicas.....	33
Tabla 6. Prueba post hoc en ANOVA con valores medios de pH, CE y tipos de uso de suelo.....	35
Tabla 7. Prueba post hoc en ANOVA con valores medios de pH, CE y tipos de suelo.	35
Tabla 8. Coeficientes de correlación de Pearson entre índices de terreno de pH y CE.	37
Tabla 9. Modelos de semivariogramas de KO mejor ajustados.....	38
Tabla 10. Superficie (km ²) según clase textural en la provincia de Utcubaba.....	44
Tabla 11. Correlación de Pearson entre los parámetros fisicoquímicos en diferentes usos de suelos.....	47
Tabla 12. Resultados de validación con KO, RK y GWRK.....	48

ÍNDICE DE FIGURAS

Figura 1. Ubicación de la provincia de Utcubamba en la región Amazonas (Perú).....	19
Figura 2. Ubicación de los puntos de muestreo de suelo en la provincia de Utcubamba	21
Figura 3. Diseño metodológico.....	22
Figura 4. Métodos de recolección de muestras de suelo.	23
Figura 5. Variables auxiliares formato ráster (cualitativas y cuantitativa).	28
Figura 6. Mapa de pH del suelo en la provincia de Utcubamba.....	41
Figura 7. Mapa de Conductividad Eléctrica (C.E.) del suelo en la provincia de Utcubamba.....	43
Figura 8. Mapa de contenido de arena, limo y arcilla del suelo en la provincia de Utcubamba.....	45
Figura 9. Mapa de clase textural del suelo en la provincia de Utcubamba.	46
Figura 10. Curva de regresión ajustada de pH v.s Temperatura	49
Figura 11. Constantes de regresiones de tipo de suelo vs. puntos de muestreo	49

RESUMEN

Ante los constantes cambios que se vienen suscitando en el mundo (cambio climático), naturales, cambios en el uso de tierras (antropogénico); una de las herramientas de evaluación son los sistemas de información geográfica, con la generación de modelos ambientales de distribución espacial a nivel mundial, país o región, para evaluar los cambios constantes; es así, que el objetivo de este estudio fue analizar la distribución espacial de parámetros físico-químicos en suelos aplicando SIG(sistema de información geográfica) en la provincia de Utcubamba, mediante el uso de métodos geoestadísticos combinados variables cualitativas y cuantitativas. Se realizaron correlaciones entre los parámetros físico-químicos, los más representativos. Las variables fueron en formato raster(pendiente, elevación, distancia al área residencial, distancia a vías, distancia a ríos, los tipos de uso de la tierra, los tipos de suelo, geología, índice de humedad topográfica, precipitación y temperatura) se analizaron de forma sistemática y cuantitativa. Sobre la base de 217 muestras distribuidas mediante un muestreo sistemático, en la provincia de Utcubamba, recolectadas a una profundidad de (0-20 cm) (región Amazonas, Perú), estimamos la distribución espacial de los parámetros físico-químicos en los suelos mediante interpolación espacial, se incluyó kriging ordinario (KO), donde se obtuvo para pH el modelo gaussiano, CE el esférico, para el contenido de arena, limo y arcilla fueron los modelos: exponencial, circular, exponencial respectivamente; con el fin de analizar si el modelo para pH y CE mejoraba se incluyó el método regresión kriging (RK) y regresión ponderada geográficamente kriging (GWRK) con cada variables cuantitativas y cualitativas. Los resultados (R^2), mostraron que el mapeo con RK fue más consistente con los datos de muestreo de la distribución espacial de pH y CE en el área de estudio que el mapeo con KO y GWRK. Los métodos KO y GWRK para pH fueron similares. Los indicadores de precisión (error medio, error absoluto medio, error cuadrático medio, tuvo una mejora con RK que con KO y GWRK) indicaron que la introducción de variables auxiliares puede mejorar la precisión de la predicción en suelos, mejora la estructura espacial, volviéndola más precisa, siempre y cuando sean elegidas correctamente. Según la estadística descriptiva el área de estudio presenta suelos ácidos a moderadamente alcalinos (3.45-8.91), suelos no salinos con una CE eléctrica (0.02 a 0.99mS/m) y el contenido promedio de arena, limo y arcilla fue 52.74%, 17.21%, 29.51% respectivamente. La textura del suelo del área de estudio es Franco Arcilloso Arenoso.

Palabras clave: Modelos geoestadísticos, interpolación espacial, semivariogramas.

ABSTRACT

Having given the constant changes that have been occurring in the world (climate change), natural, changes in land use (anthropogenic); one of the evaluation tools is geographic information systems, with the generation of environmental models of spatial distribution worldwide, country or region, to evaluate constant changes; thus, the objective of this study was to analyze the spatial distribution of physical-chemical parameters in soils by applying GIS (geographic information system) in the province of Utcubamba, through the use of geostatistical methods combined qualitative and quantitative variables. Correlations were made between the physical-chemical parameters, the most representative. The variables were in raster format (slope, elevation, distance to the residential area, distance to roads, distance to rivers, types of land use, soil types, geology, topographic humidity index, precipitation and temperature) were analyzed in a systematic and quantitative. Based on 217 samples distributed by systematic sampling, in the province of Utcubamba, collected at a depth of (0-20 cm) (Amazonas region, Peru), we estimate the spatial distribution of physical-chemical parameters in soils by Spatial interpolation, ordinary kriging (KO) was included, where the Gaussian model was obtained for pH, CE the spherical, for the sand, silt and clay content were the models: exponential, circular, exponential respectively. In order to analyze whether the model for pH and EC improved, the kriging regression (RK) and geographically weighted kriging regression (GWRK) method were included with each quantitative and qualitative variables. The results (R²) showed that the mapping with RK was more consistent with the sampling data of the spatial distribution of pH and EC in the study area than the mapping with KO and GWRK. The KO and GWRK methods for pH were similar. The precision indicators (mean error, mean absolute error, mean square error, had an improvement with RK than with KO and GWRK) indicated that the introduction of auxiliary variables can improve the prediction accuracy in soils, improve the spatial structure, turning it more precise, as long as they are chosen correctly. According to the descriptive statistics, the study area presents acidic to moderately alkaline soils (3.45-8.91), non-saline soils with an electric CE (0.02 to 0.99mS / m) and the average content of sand, silt and clay was 52,74%,17,21%, 29,51% respectively. The soil texture of the study area is Franco Arcilloso Arenoso.

Key words: Geostatistical models, spatial interpolation, semivariograms.

I. INTRODUCCIÓN

Si hay una propiedad medible del suelo que puede servir por encima de todas las demás como un indicador de la calidad, el funcionamiento y las consecuencias ambientales del suelo, es su pH. El pH de los suelos es un factor esencial, debido que la mayoría de los metales tienden a estar más disponibles en medios ácidos excepto As, Mo, Se y Cr, los cuales están disponibles en medios alcalinos. Por tanto, la adsorción de los metales pesados está fuertemente condicionada por el pH del suelo (Yarasca, 2015). Los metales pesados contribuyen fuertemente a la contaminación ambiental y la disponibilidad depende del pH, el contenido de arcillas, contenido de materia orgánica, capacidad de intercambio catiónico, entre otras propiedades (Sauve & Henderson, 2000). El pH del suelo es una variable dominante del suelo porque influye en muchas propiedades físicas, químicas y biológicas del suelo y en los procesos de crecimiento de las plantas (Zhang *et al.*, 2018, Hu *et al.*, 2019). Un pH promedio de 8.24 sugiere que los suelos son alcalinos, lo que comúnmente reduce la movilidad de los metales pesados (Alloway, 2013; citado por Lv, 2019).

La variación en el pH del suelo puede estar asociada con cambios en el clima, (balance de agua, temperatura). El carbono inorgánico del suelo, genera un pH neutro a alcalino, mientras que la deposición de nitrógeno antropogénicas genera acidez (Hong *et al.*, 2019). El gran exceso de iones de calcio (Ca^{2+}) puede inhibir la absorción del principal nutriente de plantas potasio (K) y varios elementos menores esenciales para el crecimiento de las plantas. El fósforo (P) tampoco está disponible en este pH. La mayoría de los cultivos agrícolas prosperan mejor en suelos con un pH en el rango de 6.5 a 7, aunque muchos crecerán bastante bien en suelos de pH 5.5 a 6.5 y 7-8 (Weil y Brady, 2017). Sin embargo, desde un punto de vista ambiental, el exceso de CaCO_3 libre es una ventaja, ya que hace que la mayoría de los metales pesados sean casi insolubles y no estén disponibles para las plantas.

Un suelo con pH neutro tiene saturada la fase de intercambio con cationes básicos (K^+ , Ca^+ , Mg^+ , Na^2). Estos cationes satisfacen la carga eléctrica de la superficie de los coloides del suelo. La acidificación se inicia con la pérdida de estos cationes debido en parte a la acción de las raíces. La planta, al absorber cationes, libera H^+ para mantener el equilibrio en su interior, lo que contribuye a la reducción del pH del suelo (Espinoisa y Molina, 1999). Un suelo inundado, húmedo, con un pH inicial <6.5 aumenta a 7.0, y para suelos con un pH inicial > 6.5 , el pH primero disminuye y luego aumenta aproximadamente a 7.0; cuando estos suelos drenan, el pH de los suelos ácidos disminuye la acidez, mientras que los suelos neutros a alcalinos suceden de manera opuesta (Ding *et al.*, 2019).

En los ecosistemas naturales, la acidificación y la salinización son procesos lentos, derivados de la meteorización de las rocas y la liberación de cationes. Cuando la lluvia supera la evapotranspiración, estos iones se lixivian, lo que lleva a la acidez. Sin embargo, estos suelos pueden llegar a un nivel de acidificación, por fuentes antropogénicas, por emisiones de tráfico, industrias, incineración de residuos, actividades de construcción, demolición, fertilizantes químicos, pesticidas, fungicidas y aplicación de aguas residuales (Pan *et al.*, 2017), incluido porcentajes de metales pesados; la influencia del viento local los dispersa hacia los ríos, la vegetación, y son transportados por la intemperie y hacia los suelos (Li *et al.*, 2017), alterando sus constituyentes heterogéneos minerales, materia orgánica, organismo vivo, acuosa y componentes gaseosos (Mihailović *et al.*, 2015). Las actividades humanas contribuyen de manera rápida a las alteraciones del suelo con la agricultura moderna, la disminución de pH y la salinización, debido a la expansión rápida de la población por la alta demanda de alimentos requeridos (Jiang *et al.*, 2016, Chen *et al.*, 2016).

Uno puede medir el pH del suelo en campos y granjas individuales, por supuesto, y los agricultores pueden tomar medidas correctivas aplicando cal al suelo para corregir la acidez y tal vez el yeso para mejorar el suelo alcalino. Eso no es factible a nivel nacional, regional o provincial, pero si evaluar el estado actual de todo un dominio y monitorear el cambio en respuesta, por ejemplo, al calentamiento global. Es probable que un gobierno también quiera saber dónde está el suelo demasiado ácido o demasiado alcalino y monitorear el cambio allí, especialmente si necesita reducir las consecuencias de los contaminantes a nivel regional. Necesita mapas del pH del suelo para esos propósitos y para su toma de decisiones.

El análisis del suelo puede proporcionar datos muy precisos de parámetros físico-químicos del suelo en los sitios de muestreo, sin embargo, existe una fuente limitada para su análisis y por ser laborioso (Shi *et al.*, 2014). Por lo tanto, en la actualidad se hace uso de la combinación de estadística multivariada y análisis geoestadístico se requieren para modelar mapas de distribución espacial de los parámetros físico-químicos del suelo a partir de puntos limitados (Li *et al.*, 2017), para desarrollar estrategias de manejo para mantener la fertilidad del suelo y evitar la degradación del suelo (Wu *et al.*, 2019).

Esta investigación tuvo por objetivo general analizar la distribución espacial de parámetros físico-químicos en el suelo aplicando SIG, Utcubamba, Amazonas, Perú. Y como objetivos específicos a) determinar los parámetros físico-químicos de muestras representativas de suelo; b) modelar geoestadísticamente la distribución espacial de parámetros físico-químicos en el suelo; y c) determinar la precisión de los mapas de la distribución de parámetros físico-químicos.

II. MATERIALES Y MÉTODOS

2.1. Área de estudio

La provincia de Utcubamba tiene una superficie aproximada de 3 993,23 km², que representa el 9,83% del territorio de la región Amazonas y se ubica entre las coordenadas 77°51'7" y 78°42'12" longitud Oeste y, 5°23'25" y 6°10'53" latitud Sur (Figura 1). Políticamente se encuentra dividida políticamente en 7 distritos: Bagua Grande, Cajaruro, Cumba, El Milagro, Jamalca, Lonya Grande y Yamón. Limita por el Norte con la provincia de Bagua y con la provincia de Condorcanqui; por el Este con la provincia de Bongará; por el Sur con la provincia de Luya; y por el Oeste con el Departamento de Cajamarca.

La provincia de Utcubamba está ubicada en la zona central del departamento de Amazonas y es la tercera provincia de mayor extensión territorial y la primera de mayor concentración poblacional. Su ubicación natural es la región Selva, y abarca las cuencas de los ríos Marañón y Utcubamba. La capital provincial es la ciudad de Bagua Grande, al Oeste del ámbito provincial, a una altitud de 440 m.s.n.m.

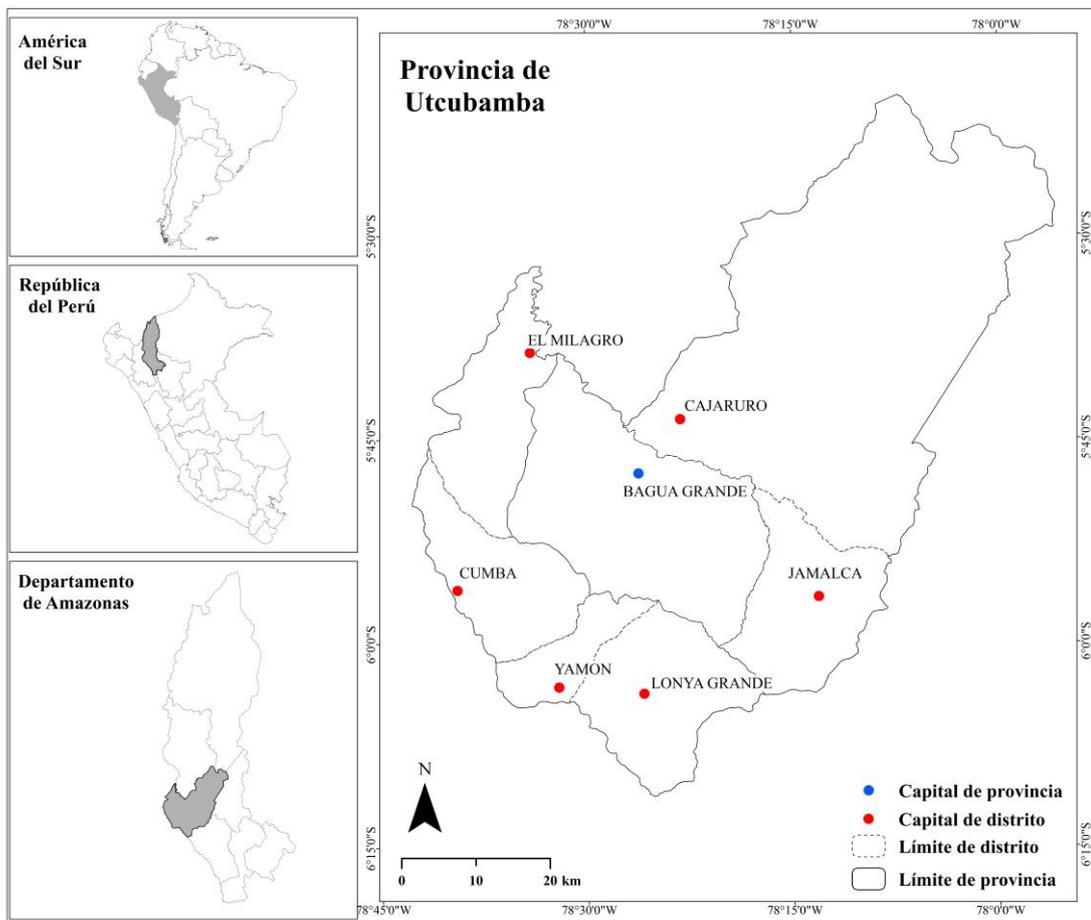


Figura 1. Ubicación de la provincia de Utcubamba en la región Amazonas (Perú).

2.2. Población, muestra y muestreo

La población está representada por el área de la provincia de Utcubamba, la cual abarca una superficie aproximada de 3 993.23 km². Se realizó un muestreo probabilístico sistemático, también conocido como muestreo regular, ampliamente utilizado en este tipo de estudios (Wang *et al.*, 2018; Li *et al.*, 2017; Tóth *et al.*, 2016; Cao *et al.* 2016; Lu *et al.*, 2012). En este tipo de muestreo, se reduce la variabilidad de las muestras debido a que su levantamiento sigue un patrón geométrico específico (retícula), tomando las muestras a intervalos regulares y cubren de forma uniforme el sitio a muestrear (MINAM, 2014). Por tanto, en base a una grilla de 3x3 km (Li *et al.*, 2017), se establecieron 217 puntos de muestreo (Figura 2). Se reubicaron los puntos que se superpusieron en zonas urbanas, redes hídricas y viales, a aproximadamente 200 metros de las mismas (Lu *et al.*, 2012).

2.3. Materiales, equipos y software

La Tabla 1 indica los materiales, equipos y software utilizados para la presente investigación.

Tabla 1. Materiales, equipos y software.

Categoría	Descripción
Data cartográfica y satelital	<ul style="list-style-type: none"> ▪ Red vial del Ministerio de Transportes y Comunicaciones (MTC). ▪ División política departamental, regional, provincial y distrital del Perú elaborada por el Instituto Nacional de Estadística e Informática (INEI). ▪ Modelo de Elevación Digital del Terreno (DEM) de 90 metros de resolución espacial de la Misión Topográfica Shuttle Radar (SRTM). ▪ Datos Espaciales de la ZEE-A (Uso actual del Suelo, Tipo de suelo, Geología, Red hídrica) (GRA & IIAP, 2013). ▪ Base de datos SIG del clima mundial de WorldClim con una resolución espacial de 30 segundos (≈ 1 km) (Fick & Hijmans, 2017).
Software	<ul style="list-style-type: none"> ▪ QGIS (<i>ver.</i> 3.0.0) ▪ ArcGIS (<i>ver.</i> 10.5) ▪ Google Earth Pro (<i>ver.</i> 7.3.0.3832) ▪ SAS Planet (<i>ver.</i> 160707). ▪ Windows de Microsoft Office 2016 ▪ IBM SPSS (<i>ver.</i> 24) ▪ Minitab (<i>ver.</i> 19)
Equipos y materiales adicionales	<ul style="list-style-type: none"> ▪ Laptops HP Core i5 - 12GB RAM ▪ GPS Garmin Montana 650 ▪ Cámara digital ▪ USB de 16 GB de capacidad de almacenamiento ▪ Libreta de campo ▪ Palana ▪ Bolsas plásticas ▪ Cinta masking 3" ▪ Plumón indeleble

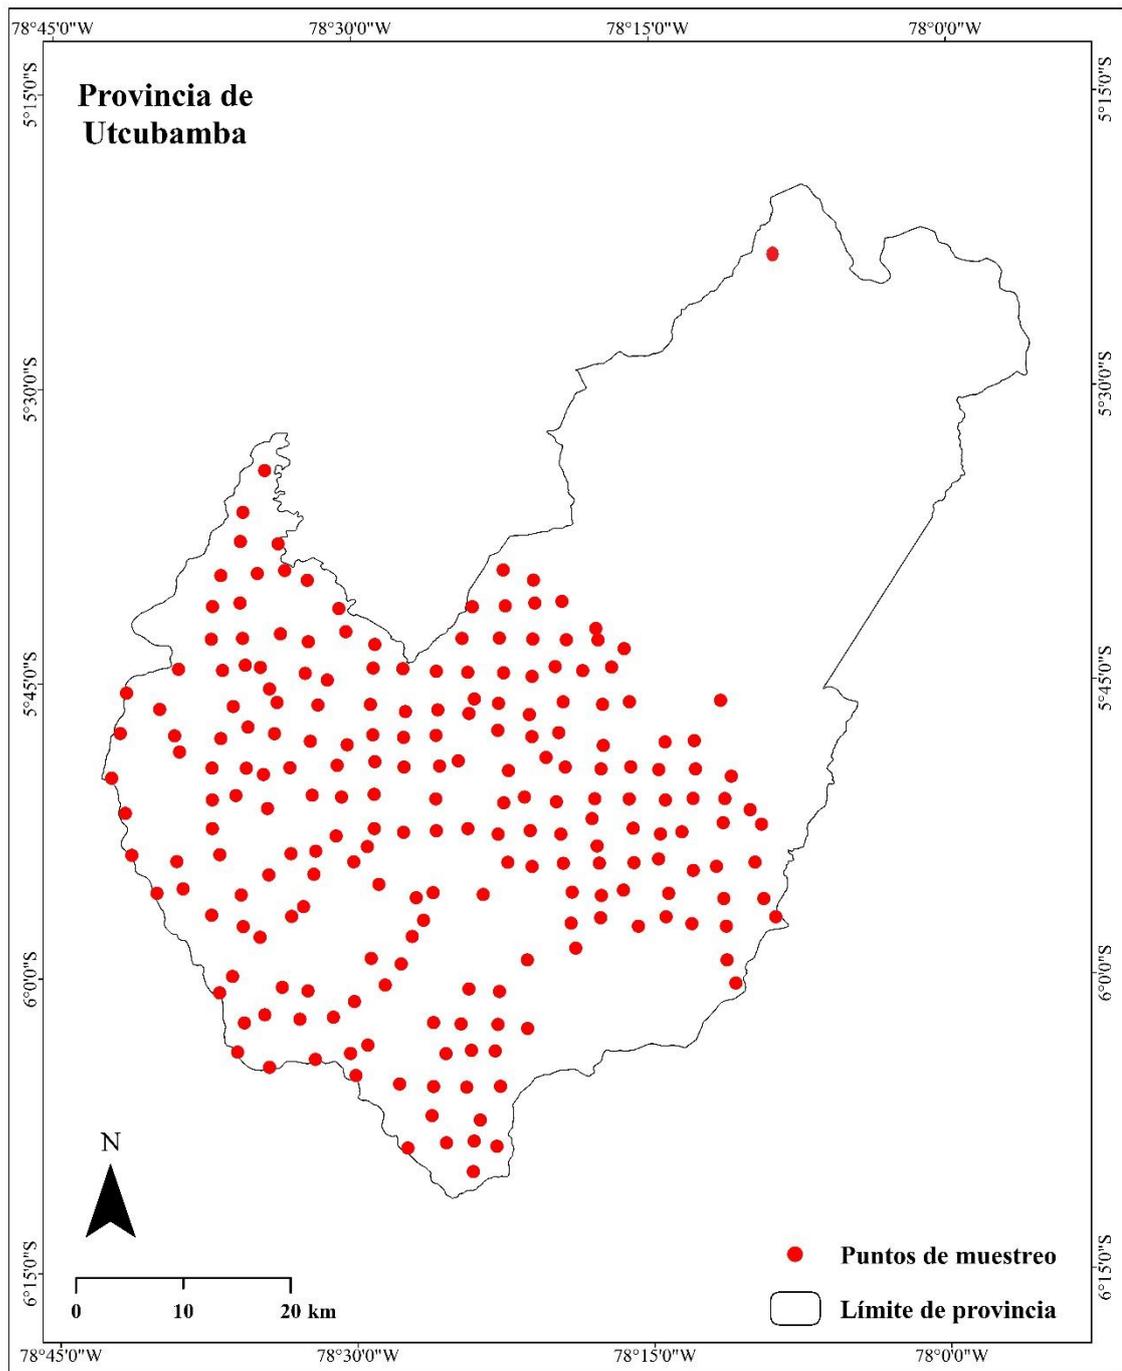


Figura 2. Ubicación de los puntos de muestreo de suelo en la provincia de Utcubamba

Los puntos se distribuyeron a una distancia aproximada de 3x3km, debido al método geoestadístico, la base fundamental es tener los puntos distribuidos de manera regular, además dependerá del trabajo del investigador, a más detalle, la distancia de distribución de los puntos a muestrear tiene que ser menor, pero requiere más inversión económica porque aumentaría la cantidad de puntos a muestrear. El área (Nor-Este) donde no presenta puntos de muestreo, es debido a la accesibilidad por la topografía, por presentar en esta área una amplia zona boscosa, ubicándose en áreas de conservación (Tabla 2)

2.4. Diseño metodológico

Para analizar la distribución espacial de parámetros físico-químicos en suelos aplicando Sistemas de Información Geográfica (SIG) en la provincia de Utcubamba, se siguió el diseño metodológico diagramado en la Figura 3. Más detalladamente se a) determinaron los parámetros físico-químicos de muestras representativas de suelo; b) modeló geostatísticamente la distribución espacial de parámetros físico-químicos en el suelo; y c) determinó la precisión de los mapas de la distribución de parámetros físico-químicos.

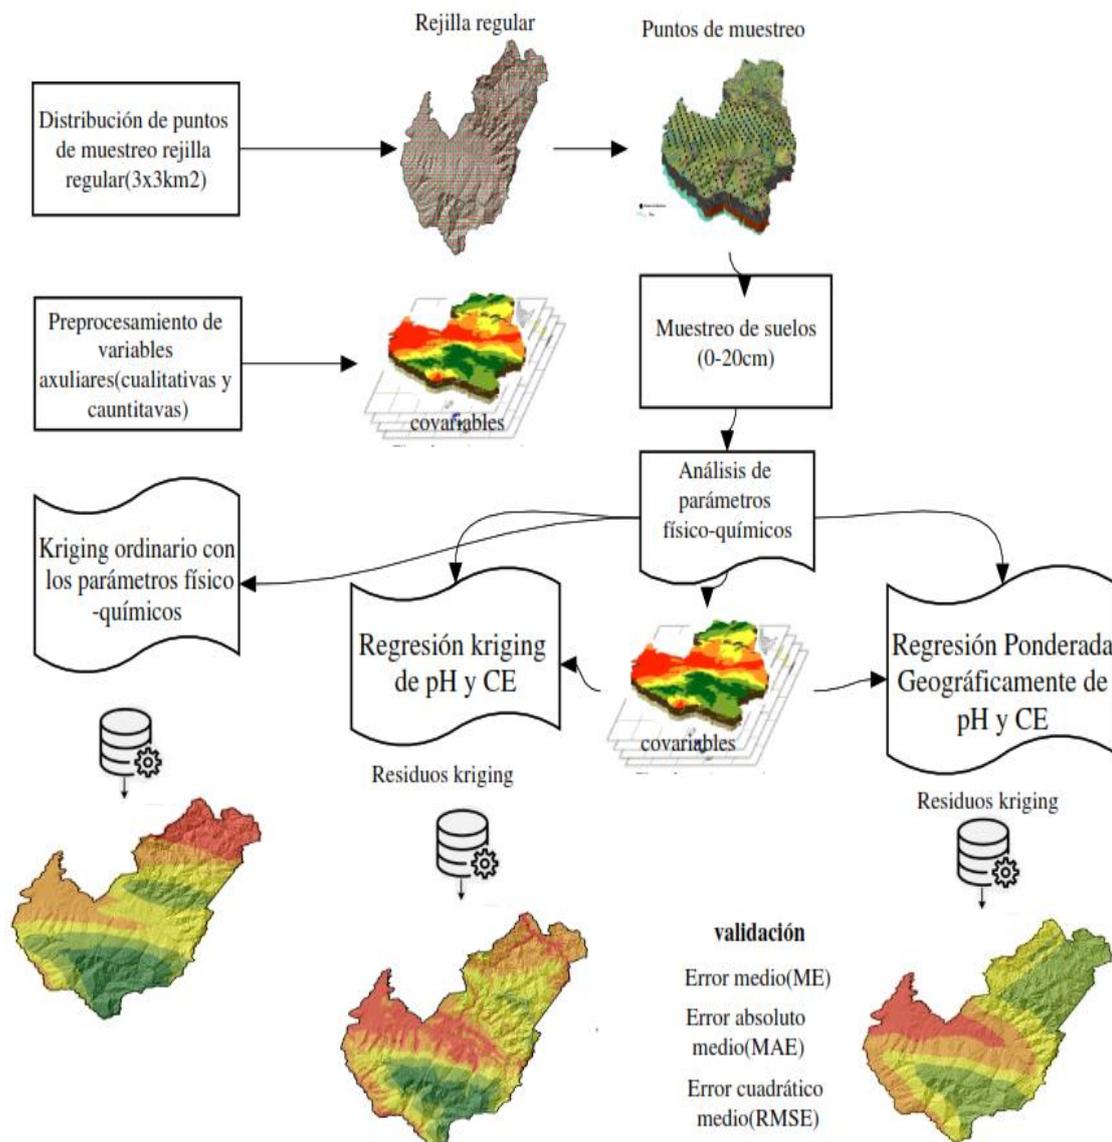


Figura 3. Diseño metodológico.

2.5. Determinación de parámetros físico-químicos del suelo

2.5.1. Recolección de muestras de suelo

Se recolectaron 217 muestras de suelo para determinar la distribución espacial de parámetros físico-químicos en el suelo del área de estudio (Figura 2 y 4; Anexo 7). La distancia media de los sitios de muestreo seleccionados fue de aproximadamente 3 km (lado de la rejilla regular). Las coordenadas geográficas de los sitios de muestreo se registraron utilizando un receptor de sistema de posicionamiento global (GPS). Se recogieron una muestra, dentro del rango de la ubicación de muestreo especificada a una profundidad de 0 a 20 cm (Li *et al.*, 2017), de tal forma que se pueda garantizar su extracción “no perturbada”, esto es, en la que se respeten los horizontes que configuran el perfil del suelo de que se trate, y la recuperación de toda la historia deposicional de las características físicas y químicas del suelo.

Para cada estación de muestreo se utilizó una pala inoxidable, se utilizaron bolsas rotuladas con denominación, transparentes, como contenedor de las muestras. Cada muestra estaba formada por las secciones de igual profundidad, debidamente mezcladas y homogeneizadas.

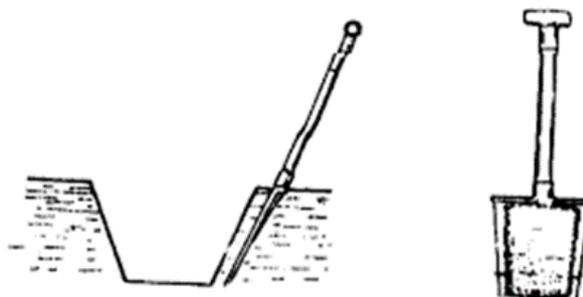


Figura 4. Métodos de recolección de muestras de suelo.

2.5.2. Análisis de parámetros físico-químicos de la muestra de suelo

Las muestras de suelo fueron analizadas en el Laboratorio de Investigación de Suelos y Aguas – LABISAG del Instituto de Investigación para el Desarrollo Sustentable de Ceja de Selva (INDES-CES) de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas (UNTRM).

Para determinar el pH se utilizó el pH-metro, la relación de muestra y agua destilada fue de (1:1) donde ambos se vertieron en un solo frasco rack (B-11), donde fue agitado en el agitador de muestras un tiempo aproximado de 10 minutos, luego se dejó reposar 5 minutos, para luego ser medido el pH. Para medir

la CE (mS/m) los frascos rack, fueron tapados después de medir el pH, aproximadamente 4 horas y luego se procedió a medir con el conductímetro.

Para la clase textural de arena, limo y arcilla, se utilizó principalmente el hidrómetro de suelos para medir la densidad de la suspensión, para lo cual se pesó 50g aproximadamente, de muestra colocado en un vaso de precipitados, donde se añadió hexametáfosfato de sodio al 10% y luego agua destilada, se agitó por 5 minutos en el agitador de muestras, luego se hizo un trasvase a una probeta, se agitó con una varilla, luego se lo dejó reposar 40 segundos. En el transcurso de los 40 segundos se registró la lectura con el hidrómetro, luego de 2 horas se registró nuevamente la lectura con el hidrómetro, las tomas de temperatura se realizaron en paralelo a la lectura inicial (40 segundos) y final (2 horas).

2.6. Modelado geoestadístico la distribución espacial de parámetros físico-químicos en el suelo

2.6.1. Inclusión de datos de parámetros físico-químicos en un SIG

Los resultados de los análisis de los parámetros físico-químicos, se implementaron en un Sistema de Información Geográfica junto con otras variables de carácter geográfico, que veremos a continuación. La superposición de distintos tipos de datos facilita el conocimiento de las distintas características de la zona de estudio y el análisis de la relación que guarda el parámetros físico-químicos con cada variable; distancia al área residencial (ciudad y caseríos), distancia a la red hídrica, uso a de suelo (actualizado con imágenes de satélite Sentinel 2A), tipo de suelo, geología, obtenidos de la ZEE-A (GRA & IIAP, 2013), topografía (pendiente y altitud) obtenida del DEM SRTM, distancia a la red vial obtenida a partir de datos espaciales del ministerio de transportes y comunicaciones (MTC), temperatura y precipitación de WorldClim (Fick & Hijmans, 2017).

2.6.2. Variables cualitativas y cuantitativas para el modelado geoestadístico

Los factores del terreno adoptados en este estudio fueron la elevación, la pendiente y el índice de humedad topográfico (WTI). La elevación y la pendiente se derivaron de un modelo de elevación digital de cuadrícula (DEM SRTM) de 90 m (<http://usgs.earthexplorer.org>) del área de estudio utilizando las herramientas analíticas espaciales de ArcGIS (ver. 10.5) directamente (Fig. 5). Es

probable que el WTI muestre una relación significativa con las propiedades del suelo porque se ha reconocido como una descripción precisa del cambio topográfico y su influencia en la escorrentía superficial (Beven y Kirkbj, 1979; Pei *et al.*, 2010) (Fig. 5). Las dos variables independientes utilizadas para calcular el WTI se obtuvieron del DEM y se aplicaron de la siguiente manera:

$$WTI = \ln \left(\frac{A_c}{\tan \beta} \right) \quad (1)$$

Donde A_c es el área de captación por unidad de longitud de contorno que fluye a través de la superficie del punto a calcular y β es el gradiente de pendiente. Ambas variables independientes que usaban para calcular el WTI se adquirieron del DEM.

La distancia al área residencial y distancia a vías refleja la intensidad de las actividades humanas (Cao *et al.*, 2017). Los terrenos que se encuentran cerca de las áreas residenciales tienen posibilidades de presentar suelos ácidos, causados por actividades humanas (Xie *et al.*, 2019). "Área residencial" en este estudio se refiere a la tierra residencial a gran escala (ciudad y caseríos). Distancia a ríos puede estar reflejado con la humedad de los terrenos que a mayor humedad hay mayor disolución de componentes fisicoquímicos y por ende se produce una acidificación (Hong *et al.*, 2019). Para la distancia al área residencial, vías y ríos se calculó por la distancia euclidiana entre los puntos de muestreo, para cada área más cercana utilizando los métodos de análisis espacial del Sistema de Información Geográfica (Figura 5).

Distancia a área residencial, vías y red hídrica

Se usó la metodología de la herramienta distancia euclidiana, que describe la relación de cada celda con un origen o un conjunto de orígenes basándose en la distancia de la línea recta (Booth & Bratt 2004). A continuación, se explica la metodología aplicada.

El origen: El origen identificó la ubicación de los objetos de interés, como son el área residencial, vías y red hídrica con respecto a los puntos de muestreo.

El algoritmo de distancia Euclidiana: La distancia euclidiana se calculó desde el centro de la celda de origen hasta el centro de cada una de las celdas circundantes. Conceptualmente, el algoritmo euclidiano funciona del siguiente modo: para cada celda,

la distancia a cada celda de origen se determina al calcular la hipotenusa con x_{max} y y_{max} como los otros dos lados del triángulo. Este cálculo derivó la verdadera distancia euclidiana, en vez de la distancia de la celda. Se determinó la distancia más corta a un origen, y si es menor que la distancia máxima especificada, el valor se asigna a la ubicación de la celda en el ráster de salida.

El ráster de salida de la distancia euclidiana: El ráster de salida de la distancia euclidiana incluyó la distancia medida desde cada celda hasta el origen más cercano. Las distancias se midieron en línea recta (Distancia euclidiana) en las unidades de proyección del ráster, como kilómetros, y se computaron desde el centro de la celda hasta el centro de la celda.

Tabla 2. Uso del suelo en la provincia de Utcubamba.

Código de Uso de suelo	Nombre	Superficie	
		Área Ha	%
US1	Agricultura de predominio arrocero	12378.84	3.10
US2	Agricultura de predominio cafetalero	30001.81	7.52
US4	Agricultura de subsistencia	154485.88	38.70
US6	Pastos y cultivos	32945.09	8.25
US8	Santuario Nacional Cordillera de Colan	39222.28	9.83
US11	Reserva Comunal Chayu Nain	10926.83	2.74
US16	Frente de conservación de tierras de protección	117687.79	29.49
US88	Centros de protección	518.29	0.13
US99	Cuerpos de agua	974.90	0.24
Total		399141.72	100.00

Tabla 3. Tipo de suelo en la provincia de Utcubamba.

Código de Tipo de suelo	Nombre	Superficie	
		Área Ha	%
TS1	Marañon	7447.93	1.87
TS4	Chiriyacu	160.33	0.04
TS6	Balsas	0.22	0.00
TS7	Calera I	34549.71	8.66
TS8	Nipón I	101.69	0.03
TS16	Marañon-Tamborapa	9203.49	2.31
TS17	Tamborapa-Cárcavas	8962.26	2.25
TS18	Tamborapa-Bagua	7899.36	1.98
TS21	Tamborapa-Misceláneos	19388.59	4.86

TS22	Piria-Pericos Rojos	68190.77	17.08
TS23	Pirias-Misceláneos	36612.74	9.17
TS24	Shushunga-Samaren	10686.35	2.68
TS27	Shushunga-Nipón I	122649.71	30.73
TS29	Calera I-Pillualla	45646.03	11.44
TS31	Santiago-Aguajal	1.09	0.00
TS34	Tamborapa-Cumba	23670.90	5.93
TS37	Cárcavas	2163.10	0.54
TS38	Misceláneos	314.24	0.08
TS88	Centros poblados	518.29	0.13
TS99	Cuerpos de agua	974.90	0.24
Total		399141.71	100.00

Tabla 4. Geología en la provincia de Utcubamba.

Código de geología	Nombre	Superficie	
		Área Ha	%
G1	Depositos fluviales recientes	8181.03	2.05
G4	Depositos aluviales Pleistocénicos	3314.32	0.83
G6	Formación Bellavista	948.69	0.24
G9	Formación EL Milagro	6917.85	1.73
G10	Formación Cajaruro	2033.43	0.51
G14	Formación Chota	14648.13	3.67
G17	Formación Celendín	33978.56	8.51
G18	Formación Cajamarca	10043.26	2.52
G19	Grupo Quiliquiñan	35288.88	8.84
G20	Grupo Pulluicana	51052.67	12.79
G21	Formación Chonta	4522.08	1.13
G22	Formación Chulec	15114.19	3.79
G23	Grupo Oriente	43004.65	10.77
G24	Grupo Goyllarisquizga	54706.18	13.71
G25	Formación Sarayaquillo	11448.61	2.87
G28	Grupo Pucará	16193.77	4.06
G29	Grupo Mitu	51129.28	12.81
G35	Complejo Marañon	35122.93	8.80
G88	Centros Poblados	518.29	0.13
G99	Cuerpos de Agua	974.90	0.24
Total		399141.71	100.00

Los datos de la Tabla 2, Tabla 3 y Tabla 4, fueron obtenidos de la ZEE-Amazonas, las cuales están adaptadas, tienen un código, nombre y superficie, estas tres variables en formato ráster (uso de suelo, tipo de suelo y geología) (Figura 5)

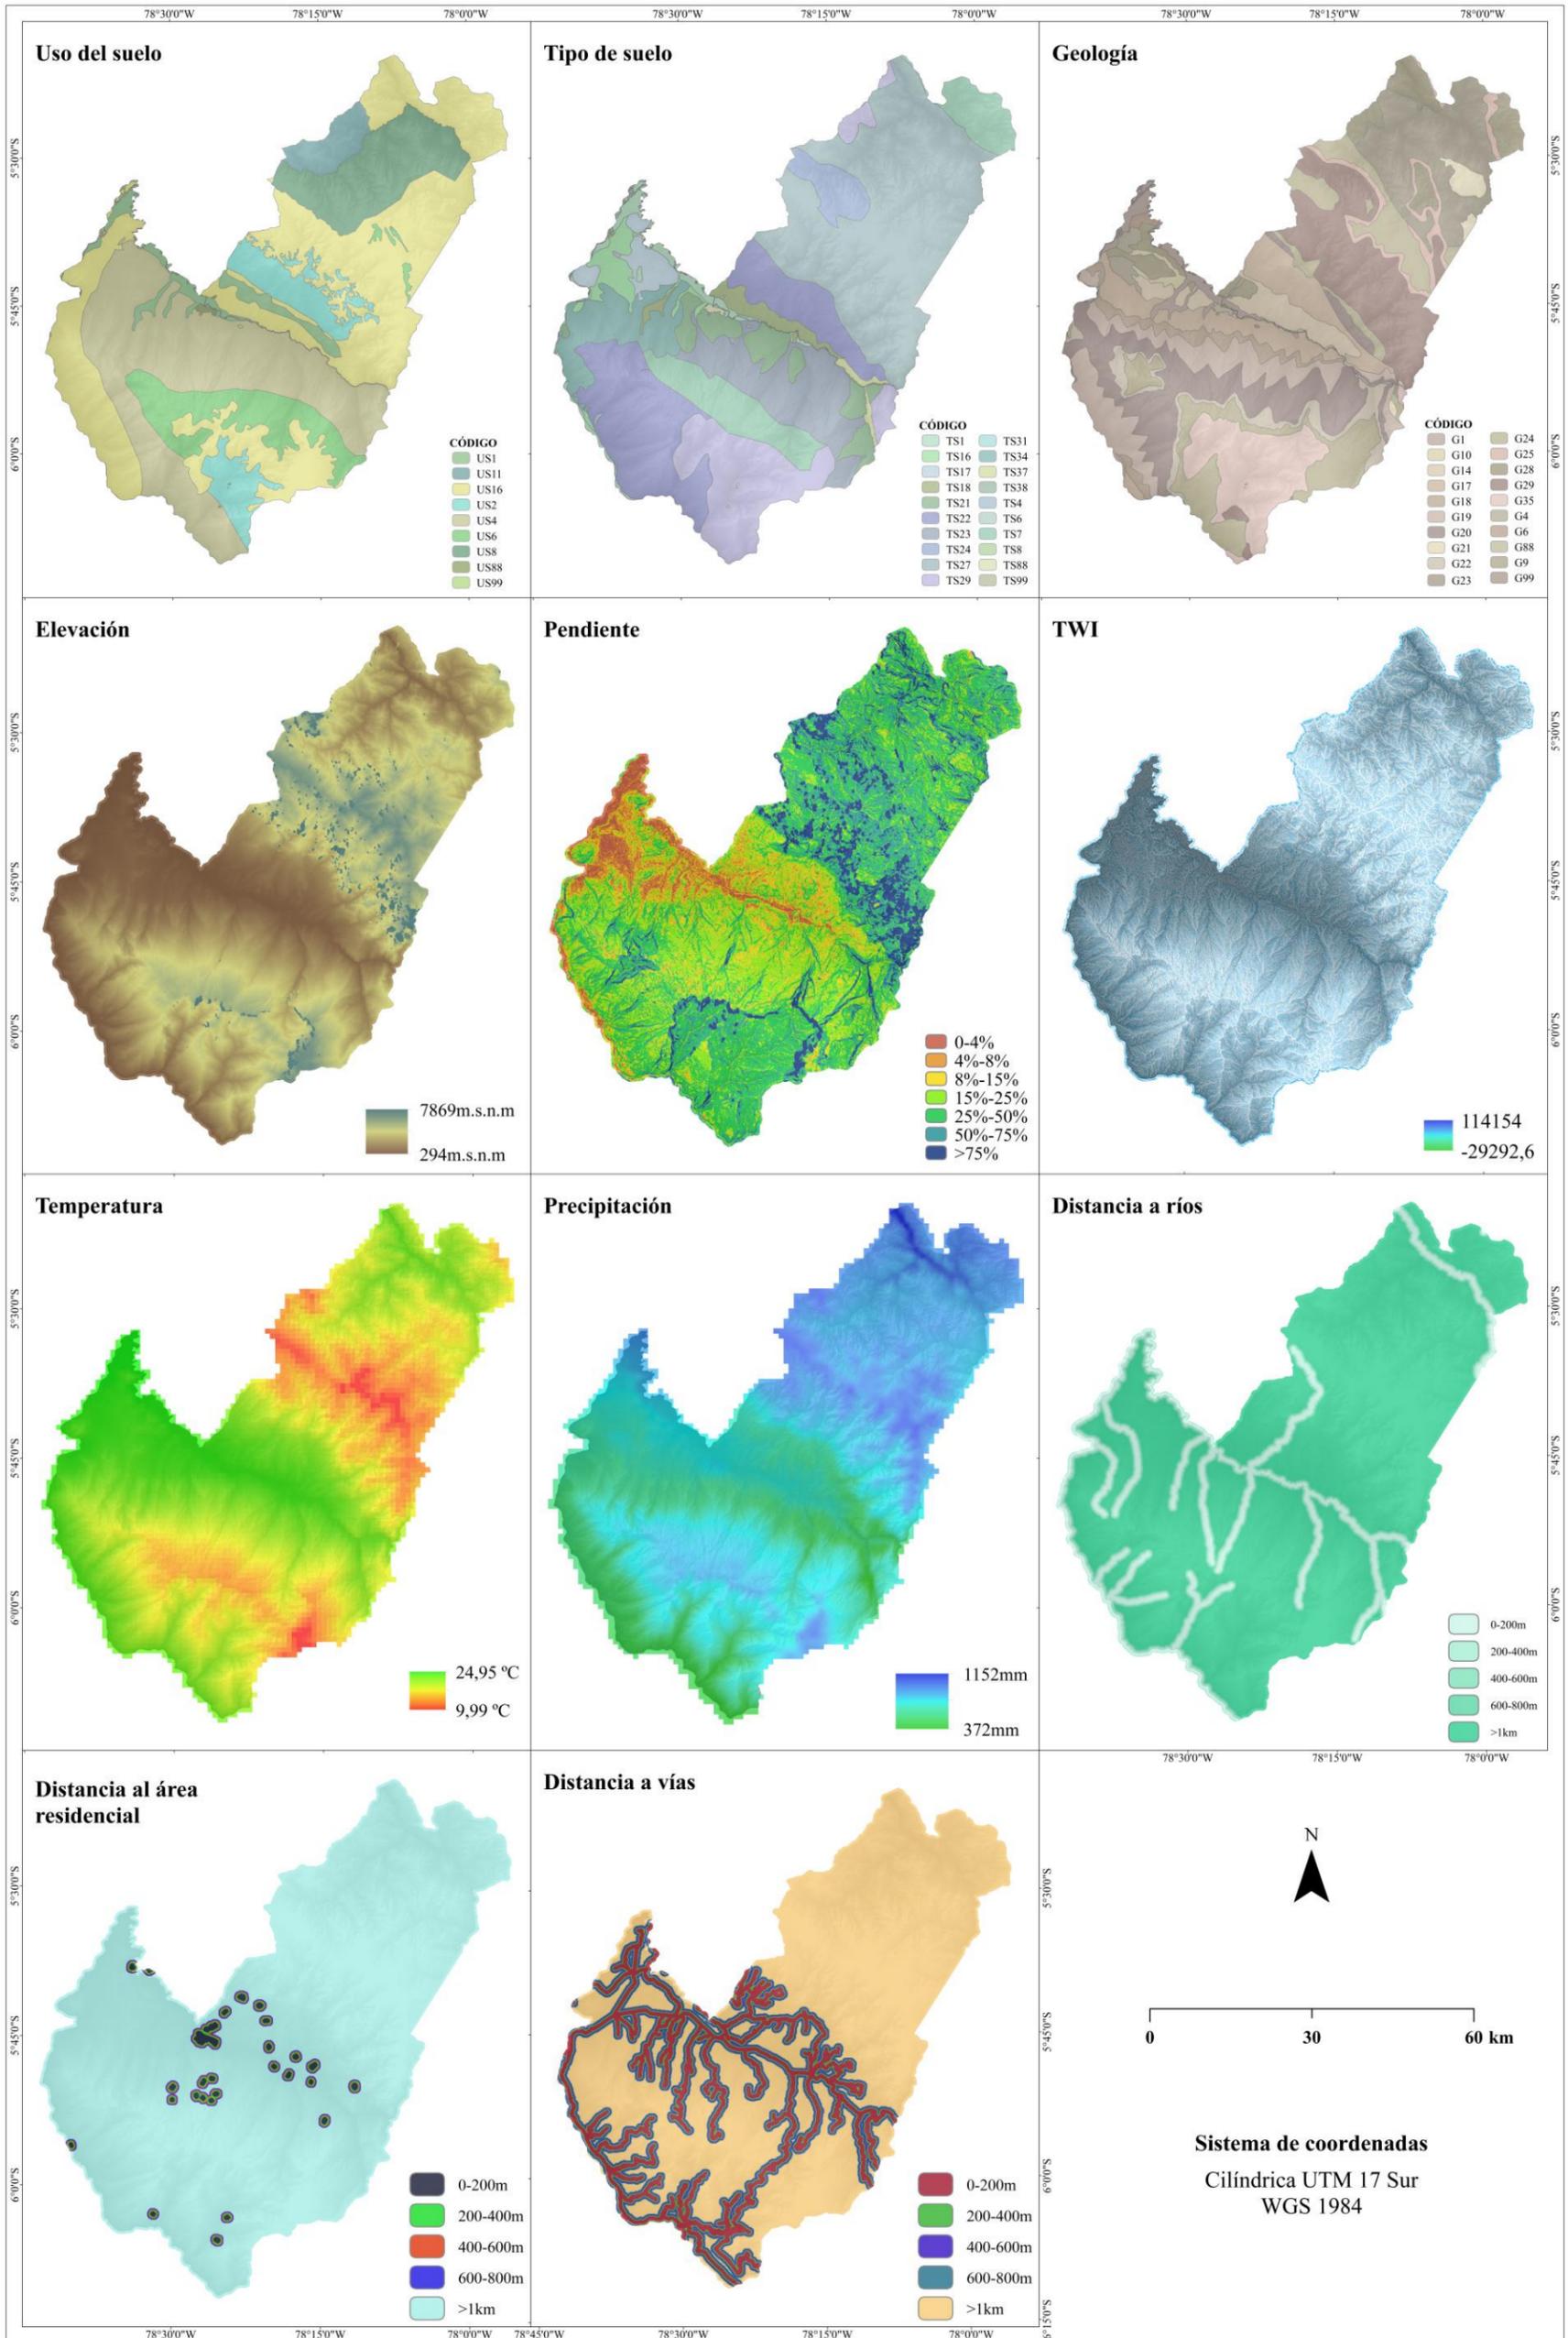


Figura 5. Variables auxiliares formato ráster (cualitativas y cuantitativa).

2.6.3. Modelo geoestadístico

El modelado de datos geoestadísticos se realizó en el software de cartografía ArcGIS (ver. 10.5), mediante su extensión Geostatistical Analyst. La base teórica de las geoestadísticas se originó a partir de la teoría de variables regionalizadas que tienen las características de azar y varianza espacial estructurada (Matheron, 1963). La interpolación geoestadística se construye mediante el ajuste de variogramas o cruzogramas y el cálculo del resultado de la interpolación en ubicaciones no muestreadas utilizando el modelo de variograma para definir los factores de ponderación. La función de semivariograma (Matheron, 1965), que representa la correlación espacial entre observaciones adyacentes, se define como la mitad de la varianza de la diferencia entre los valores de datos pareados separados por un intervalo de distancia:

$$\gamma_h = \frac{1}{2n} \sum_{i=1}^n [Z(X_i) - Z(X_i + h)]^2 \quad (2)$$

Donde γ_h es el semivariograma, n es el número de pares de observaciones, $Z(X_i)$ es el valor de la muestra medido en la ubicación X_i y $Z(X_i + h)$ es el valor de la muestra medido en la ubicación $X_i + h$, h es la distancia entre la muestra puntos, y X_i es la posición de las muestras.

Se eligió el método kriging debido a sus ventajas sobre otras técnicas de interpolación. Entre las técnicas de kriging, el método ordinario de kriging es el método más comúnmente utilizado para situaciones ambientales.

Con el fin de analizar si las predicciones de los mapas de pH Y CE mejoraban, se utilizó regresiones múltiples, con la variable dependiente y las independientes; para lo cual se realizó varias corridas de variables para analizar cuál de las variables aportaba más al modelo, que todo el proceso tuvo como resultado final el método de Rk. Se utilizaron catorce (14) variables auxiliares, incluidas de arena, limo y arcilla, estas se utilizaron en forma de mapas raster a una resolución de 90x90m. Así mismo, se utilizó regresión ponderada geográficamente kriging (GWRK) para permitir analizar entre el método KO, RK.

Kriging ordinario

El método KO es el método más utilizado en la interpolación espacial de la distribución de las propiedades del suelo.

$$\begin{cases} \hat{Z}(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \\ \sum_{i=1}^n \lambda_i = 1 \end{cases} \quad (3)$$

Donde $\hat{Z}(x_0)$ es el valor predicho de los puntos de interpolación en la ubicación x_0 , $Z(x_i)$ es el valor de la muestra medido en la ubicación X_i , λ_i es el peso asignado a $Z(x_i)$, y n es el número de observaciones adyacentes. Para garantizar que la estimación sea imparcial, la suma de los pesos λ_i debe ser igual a uno. Discusión detallada de KO se puede encontrar en muchos estudios.

Se utilizó kriging ordinario mediante el Software ArcGIS (ver. 10.5), en los cuales se corrieron diferentes modelos y la elección del mejor modelo, se determinó mediante el menor error cuadrático medio y los que presentaban un mayor R^2 , lo que significa que ese modelo se ajusta más a la realidad. Aunque no hubo mucha diferencia significativa entre los modelos, esto pudo ser contrastado con los errores.

Regresión kriging

La regresión Kriging (RK) es un método geoestadístico que se modela como una combinación del componente determinista de la variable objetivo mediante la regresión de la variable dependiente (parámetros físico-químicos), con variables auxiliares y la varianza espacial mediante el kriging ordinario de los residuales de la regresión (Bishop y McBratney, 2001; Hengl *et al.*, 2004). La ecuación básica utilizada en RK es la siguiente:

$$z(s_o) = \sum_{k=0}^p B_k q_k(s_o) + \sum_{i=1}^n w_i(s_o) e(s_i) \quad (4)$$

Donde B_k son los coeficientes del modelo de regresión estimado, $q_k(s_o)$ es la variable o predictor externo explicativo en la ubicación s_o , p es el número de predictores, $w_i(s_o)$ son ponderaciones determinadas por la función de covarianza y $e(s_i)$ son los residuos de regresión.

Regresión ponderada geográficamente kriging (GWRK)

Una versión evolutiva de RK es GWRK, que es una combinación de GWR y kriging (Benitez *et al.*, 2016, Kumar *et al.*, 2012). GWRK y RK comparten un procedimiento similar, es decir, la deriva y los residuos se estiman por separado y luego se suman. Dado que la diferencia principal entre RK y GWRK fue la parte de tendencia, por lo tanto, la parte de GWR se introduce primero en esta sección. MLR supone que las relaciones entre la variable objetivo y las covariables ambientales son espacialmente constantes, lo que se refiere al llamado efecto global. Sin embargo, las relaciones entre la variable dependiente y las variables independientes pueden variar a lo largo del espacio, por lo que se propuso GWR como modelo fijo local para modelar las relaciones que varían espacialmente entre la variable independiente y las variables dependientes. El proceso de GWR se resume por:

$$Z_{GWR}(s) = \beta_0(s) + \sum_{i=1}^p \beta_i(s) \cdot x_i(s) \quad (5)$$

Donde $Z_{GWR}(s)$ es el valor predicho de la variable objetivo Z en la ubicación s , usando GWR, $\beta_0(s)$ es la intersección predicha para la ubicación s , $\beta_i(s)$ es el coeficiente de correlación para la i -ésima variable explicativa x_i en la ubicación s , y p es el número total de variables explicativas.

Después de ajustar el modelo GWR, los procedimientos restantes de GWRK son los mismos que los de RK. El modelo GWRK utilizado para este estudio se puede escribir como:

$$Z_{GWRK}(s) = Z_{GWR}(s) + \varepsilon_{SK}(s) \quad (6)$$

Donde $Z_{GWRK}(s)$ es el valor predicho de la variable objetivo Z en la ubicación s , $\varepsilon_{SK}(s)$ representa los residuos producidos por el modelo GWR e interpolados con KO con una media de 0 asumida

Correlación de capas raster

Las correlaciones entre las concentraciones de metales pesados y los diferentes tipos de uso del suelo (capas ráster) se evaluaron utilizando la herramienta de estadísticas de recolección en ArcGIS 10.5. La matriz de correlación genera

coeficientes de correlación que describen la relación entre dos capas ráster. Esta correlación indica el grado de dependencia entre dos capas, que se puede calcular utilizando (Dai *et al.*, 2019):

$$Corr_{ij} = \frac{Cov_{ij}}{\delta_i \delta_j} \quad (7)$$

Donde Cov_{ij} es la covarianza entre las capas i y j , y δ_i y δ_j representan desviaciones estándar en las capas i y j , respectivamente. Una correlación positiva sugiere una relación directa, lo que significa que el valor de otra celda de capa aumenta con las celdas de capa correlacionadas. Un valor negativo indica que una variable cambia inversamente en relación con otra. Un valor cero sugiere que estas celdas de capa son independientes entre sí. Las correlaciones de los parámetros físico-químicos y los tipos de cobertura del suelo se calcularon utilizando estadísticas de recolección de banda basadas en los resultados geoestadísticos (Dai *et al.*, 2019).

2.7. Determinación de la precisión de los mapas de la distribución de parámetros físico-químicos

La precisión estimada de los parámetros físico-químicos en los suelos se evaluó mediante el error medio (ME), el error absoluto medio (MAE) y el error cuadrático medio (RMSE) (Issaks y Shrivastava, 1989). Estos fueron computados como:

$$ME = \frac{1}{n} \sum_{i=1}^n (Z_{obs(i)} - Z_{pred(i)}) \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z_{obs(i)} - Z_{pred(i)}| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_{obs(i)} - Z_{pred(i)})^2} \quad (10)$$

Donde n es el número de puntos de validación, $Z_{obs(i)}$ es el valor medido del i ésimo punto, y $Z_{pred(i)}$ es el valor predicho del i ésimo punto. En general, los valores más bajos de ME , MAE y $RMSE$ indican una mayor precisión de predicción (Zhang *et al.*, 2012)

III. RESULTADOS

3.1. Resultados de los parámetros físico-químicos

En la Tabla 5 se muestra las estadísticas descriptivas del contenido de los parámetros fisicoquímicos en los suelos de los 217 sitios de muestreo. El contenido de pH varió de 3.45 -8.91, con una desviación estándar (SD) de 1.42. Los suelos del área de estudio son ácidos a moderadamente alcalinos con un valor de pH promedio 7.28. Los valores de conductividad eléctrica variaron de 0.02 a 0.99 mS/m (media = 0.40).

Con respecto a los valores de los componentes de la textura del suelo, obtenidos de la determinación en laboratorio de las muestras recolectadas en campo, se apreció que, en promedio, la proporción de las partículas minerales en el área de estudio; para la arena la media es de 52.74%, para el limo de 17.21%, y la arcilla de 29.51% respectivamente; siendo el valor más bajo, de 10%, -2%, y 6%; y el más alto el valor de 90%, 50%, y 61% en el orden de arena, limo, y arcilla. El suelo del área de estudio es Franco Arcilloso Arenoso (USDA, 1999)

El coeficiente de variación de pH (CV = 19.37%), que se usa para medir la variación de la muestra, fue menor al 35%, lo que sugiere que las actividades humanas no tuvieron efectos profundos por la baja dispersión en la concentración de los parámetros fisicoquímicos en los suelos especialmente el pH y CE (Manta *et al.*, 2002).

Tabla 5. Estadística descriptiva de las propiedades físico-químicas.

	N	Mínimo	Máximo	Media	S.D	C.V (%)
pH	217	3.45	8.91	7.29	1.42	19.37
CE	217	0.02	0.99	0.4	0.24	61.54
ARENA	217	10	90	52.74	16.23	30.77
LIMO	217	2	50	17.21	7.16	41.6
ARCILLA	217	6	61	29.51	13.54	45.88

El máximo (8,91) presentado en los amplios rangos de pH exhibió claros signos de alcalinidad. La prueba de Kolmogorov-Smirnov (K – S) ($P > 0.05$) mostraron que la hipótesis nula de normalidad se rechazó para pH, CE y arena en suelos (Tabla 12). Para limo y arcilla eran distribuciones aproximadamente normales, pero no estrictamente normales, con valores de K-S de 0.150 ($p > 0.05$) en ambos casos; no se aplicó ninguna transformación (transformación de Box-Cox) para el posterior análisis geoestadístico como lo sugieren Webster y Oliver (2007) y Cao *et al.*, (2017).

3.1.1. Análisis factorial que afecta los patrones espaciales del contenido de parámetros físico-químicos en suelos

Las variaciones espaciales de los parámetros fisicoquímicos en los suelos superficiales se ven afectadas principalmente por los antecedentes geológicos naturales y la actividad humana (Lu *et al.*, 2012). Para examinar la correlación del contenido de los parámetros fisicoquímicos en los suelos y los factores de influencia seleccionados fáciles de obtener, utilizamos ANOVA para comparar el contenido total de muestras de suelo entre los diferentes tipos de uso de la tierra y los tipos de suelo y el análisis de correlación de Pearson para analizar la relación entre los contenidos de los parámetros fisicoquímicos y factores del terreno y distancia al área residencial.

Variables cualitativas

Tipos de uso del suelo

Los tipos de uso de la tierra pueden considerarse como una expresión completa de la influencia del tipo de suelo, la cubierta vegetal y las actividades humanas en la superficie de la tierra. Un cambio en el uso de la tierra de la agricultura al bosque generalmente aumenta la acidez del suelo. Sin embargo, sigue sin estar claro en qué medida los rasgos de la planta pueden mejorar o mitigar la acidificación del suelo causada por la deposición atmosférica (Hong *et al.*, 2019; Nickel *et al.*, 2014; Lv *et al.*, 2013; Zhao *et al.*, 2010). De acuerdo con el resultado de ANOVA que se muestra en la Tabla 6, las diferencias en el contenido promedio de pH entre los cuatro tipos de uso de la tierra fueron significativas, determinado por las pruebas de rango post hoc y las comparaciones múltiples por parejas que permitieron determinar qué medias difieren. La concentración media de pH en el área de agricultura de predominio arrocero (8.4) fue significativamente mayor que en otros tipos de uso de la tierra; alcanzando el valor máximo de 8.76 lo que sugiere que los pH en estos suelos son alcalinos. Además, la agricultura de subsistencia (7.6) también presentaron un contenido de pH mucho mayor que en la agricultura de predominio cafetalero (6.28), pastos y cultivos (5.9). Los que presentan un pH bajo, esto quizás debería atribuirse a la aplicación de fertilizantes, pesticidas y películas plásticas.

La concentración media de CE en el área de agricultura de predominio arrocero (0.64 mS/m) fue significativamente mayor que en otros tipos de uso de la tierra (agricultura de subsistencia, pastos y cultivos); alcanzando el valor máximo de 0.9 mS/m lo que sugiere

que no son considerados suelos salinos. Además, entre, la agricultura de subsistencia (0.40 mS/m), la agricultura de predominio cafetalero (0.43 mS/m), pastos y cultivos (0.28 mS/m), no existió diferencias significativas.

Tabla 6. Prueba post hoc en ANOVA con valores medios de pH, CE y tipos de uso de suelo.

Uso de suelo	N	pH			CE		
		Mín.	Máx.	Media	Mín.	Máx.	Media
Agricultura de predominio arrocero	9	8.14	8.76	8.40a	0.31	0.9	0.64a
Agricultura de subsistencia	152	4.35	8.91	7.66a	0.02	0.93	0.40b
Pastos y cultivos	28	4.24	8.27	5.92b	0.05	0.79	0.28b
Agricultura de predominio cafetalero	28	3.45	8.76	6.28b	0.15	0.99	0.43ab
Total	217	3.45	8.91	7.29	0.02	0.99	0.40

Nota: Los valores en cada columna de medias con la misma letra no son significativos ($p < 0.05$).

Tipos de suelo

Las propiedades físicas y químicas del suelo (pH, contenido de arcilla, contenido de materia orgánica, composición mecánica y química, etc.) determinan la acumulación y movilidad de los metales pesados en el suelo y representan algunos de los factores más importantes que conducen a la variación espacial de los metales pesados. (Doner, 1978; Micó *et al.*, 2006; Rodríguez Martín *et al.*, 2006). Las diferencias en las propiedades físicas y químicas son generalmente pequeñas en el mismo tipo de suelos, especialmente los del mismo material de origen del suelo. Sin embargo, existen diferencias significativas entre los diferentes tipos de suelo.

Los resultados del análisis de varianza mostraron que las propiedades de pH y CE no defirieron significativamente en cada tipo de suelo (Tabla 7). El contenido promedio de pH y CE del suelo Calera I-Pillualla fue significativamente con los otros tipos de suelos con un pH (5.56) y CE (0.26) valores adecuados para cultivos.

Tabla 7. Prueba post hoc en ANOVA con valores medios de pH, CE y tipos de suelo.

Tipo de suelo	N	pH			CE		
		Mín.	Máx.	Media	Mín.	Máx.	Media
Shushunga - Nipón I	5	3.45	6.87	5.55a	0.04	0.71	0.43a
Tamborapa - Bagua	8	4.97	8.61	7.89b	0.17	0.99	0.50a
Marañón - Tamborapa	12	8.30	8.91	8.63cb	0.32	0.93	0.56ad
Pirias - Pericos Rojos	62	4.35	8.76	7.40db	0.03	0.97	0.36a
Tamborapa – Cárcavas	7	7.67	8.65	8.31eb	0.33	0.93	0.56a
Marañón	7	8.14	8.76	8.40fb	0.24	0.90	0.53a

Calera I - Pillualla	29	3.79	8.27	5.56at	0.03	0.75	0.26ab
Tamborapa - Cumba	19	7.75	8.87	8.43gb	0.19	0.92	0.48a
Tamborapa -Misceláneos	23	4.58	8.80	8.02hb	0.02	0.90	0.49a
Pirias – Misceláneos	33	4.24	8.65	6.90ab	0.02	0.80	0.32a
Calera I	12	4.55	7.94	6.45ab	0.05	0.79	0.41a
Total	217	3.45	8.91	7.29	0.02	0.99	0.40

Nota: Los valores en cada columna de medias con la misma letra no son significativos ($p < 0.05$).

Variables cuantitativas

Las variables cuantitativas que se introdujeron en este estudio fueron los factores del terreno (elevación, pendiente y TWI) y la distancia al área residencial. Los factores del terreno están estrechamente relacionados con la migración de sustancias superficiales. La distancia al área residencial refleja la influencia de acidificación y la presencia de industrias debido a la importante vía de entrada de H^+ , por la deposición de N y S (Xie *et al.*, 2019; Zhu *et al.*, 2016). Los análisis de correlación de Pearson se utilizaron para evaluar la influencia de los atributos del terreno y la distancia al área residencial en el contenido de pH y CE (Tabla 8). Los coeficientes de correlación entre pH y elevación, pendiente, TWI y distancia al área residencial fueron -0.27 , -0.10 , -0.0008 y -0.007 , respectivamente y para la CE -0.05 , -0.02 , -0.0001 y -0.01 , respectivamente

La pendiente afecta la escorrentía superficial (Zhang *et al.*, 2012). A medida que aumentaba el gradiente topográfico, aumentaba la migración de sustancias. El resultado del análisis de correlación mostró que la pendiente no estaba significativamente correlacionada con el pH y del mismo modo la CE, lo que indicaría que esta variable no influye mucho para las características físicas y químicas de un suelo (Meul *et al.*, 2003).

La industrialización, la urbanización y la fertilización son factores humanos importantes que conducen alteraciones en el suelo, como la acidificación (Wuana y Okieimen, 2011). La distancia al área residencial tiene una gran influencia en la intensidad de la actividad humana. El análisis de correlación mostró que la distancia al área residencial no estaba significativamente correlacionada con pH y CE, como se esperaba. Por lo que se puede concluir que posiblemente es la razón del por qué los suelos cercanos y alejados a las áreas residenciales no presentan un pH muy ácido (< 4).

A sí mismo, la baja correlación negativa entre TWI y pH, CE refleja el hecho de que el alto TWI causado por la disminución de la pendiente y el aumento del área de captación conduciría al efecto de disolución de carbonatos (mayor

acidificación), lo que no sucedió con los resultados. Sin embargo, no hubo una correlación significativa del pH y CE en los suelos con la elevación porque hubo una variación limitada en la elevación dentro del área de estudio.

Tabla 8. Coeficientes de correlación de Pearson entre índices de terreno de pH y CE.

Variabes	Elevación	Pendiente	TWI	Dres
pH	-0.27	-0.10	-0.0008	-0.007
CE	-0.05	-0.02	-0.0001	-0.01

La variabilidad espacial de los factores topográficos (Elevación, pendiente y TWI) en el área de estudio fue limitada y, por lo tanto, el efecto de los factores topográficos en la distribución espacial de los parámetros físico-químicos en suelos era débil.

3.2. Modelos geoestadísticos de la distribución espacial de los parámetros físico-químicos

Se reconoce que la distribución espacial de parámetros fisicoquímicos en suelos tiene las propiedades de varianza estructural y aleatoria, incluida la autocorrelación espacial (Chen *et al.*, 2008). En la investigación actual, se utilizaron métodos geoestadísticos para describir la distribución espacial y analizar el patrón espacial y la variación de parámetros fisicoquímicos en los suelos. De acuerdo con la relación entre los parámetros fisicoquímicos y las variables auxiliares, las ecuaciones de regresión se construyeron usando un elemento de regresiones lineales, para mejorar el modelo de pH y CE se realizó múltiples regresiones lineales por pasos con todas las variables auxiliares (Cuantitativas y cualitativas). Variables utilizando regresión lineal múltiple. El valor de la prueba K – S mostró que los residuos de regresión de los parámetros fisicoquímicos para todas las muestras de limo y arcilla se distribuyeron normalmente ($P > 0.05$, Tabla 11).

Se consideraron los parámetros de anisotropía y tendencia al construir el modelo de semivariograma y durante el proceso de kriging. Los modelos de semivariogramas con la suma residual y sus residuales generales de los parámetros fisicoquímicos, se seleccionaron utilizando las herramientas de análisis geoestadístico de ArcGIS (ver. 10.5) y los modelos y parámetros de semivariogramas mejor ajustados se resumen en la Tabla 9.

3.2.1. Análisis de la estructura espacial

El análisis del semivariograma mostró que el modelo de variograma mejor ajustado para la transformación normal de los parámetros fisicoquímicos, de cada uno de ellos fue; para pH gaussiano, CE esférico, arena exponencial, limo circular, arcilla exponencial (Tabla 9).

Tabla 9. Modelos de semivariogramas de KO mejor ajustados.

Tipo	K-S	Modelo	Rango (m)	Nugget(C0)	Sill	C0/Sill
pH	0,139	Gaussiano	56784	0.946	2.749	0.34
CE	0,105	Esférico	42126	0.037	0.065	0.57
Arena	0,078	Exponencial	5331	7.942	248.676	0.03
Limo	0,044	Circular	5767	42.096	52.974	0.79
Arcilla	0,041	Exponencial	26819	90.587	221.569	0.41

Los parámetros proporcionados por el cálculo del semivariograma y los resultados del ajuste del modelo que se muestran en la Tabla 9 se usaron para describir la estructura espacial de los parámetros fisicoquímicos. Estos incluyen el valor de nugget (C0), el valor de rango y el umbral (Sill). El valor de rango presenta la distancia máxima de autocorrelación espacial y el valor de umbral (Sill) y nugget son medidas de la varianza general y aleatoria de la variable regional, respectivamente (Eastman, 2001).

El parámetro de cálculo, relación nugget a umbral (C0 / umbral), refleja la proporción de la parte aleatoria en total de la heterogeneidad espacial y se puede usar para medir la dependencia espacial (Cambardela *et al.*, 1994). En general, la variación de nugget de los parámetros obtenidos fue diferentes. Esto revela que la heterogeneidad espacial del componente aleatorio es causada por la variabilidad. Si bien la variación de nugget puede reflejar la variabilidad espacial de las variables ambientales, la sensibilidad y la robustez de este parámetro no es tan adecuada como el valor del rango (Chen *et al.*, 2008).

Todos los rangos de los parámetros fisicoquímicos, fueron mayores que el intervalo de muestreo promedio (3000 m), lo que indica que el intervalo de muestreo promedio es mucho menor que la longitud de la autocorrelación espacial. Por lo tanto, el diseño de muestreo es apropiado y esto garantiza que el mapa de interpolación pueda mostrar la estructura espacial de los parámetros fisicoquímicas en los suelos correctamente. Las relaciones C0 / umbral para la mayoría de los parámetros fisicoquímicos fueron entre 0.03 y 0.57 y más pequeñas que el parámetro limo (0.75), lo que indica una correlación espacial moderada. En contraste, las proporciones C0 /Sill para la revitalización, de limo fue >0.75, lo que indica una dependencia espacial débil.

Sin embargo, el rango principal de la CE (42 126m), arcilla (26 819 m) y limo (5 767) fue mayor que el rango de la arena (5 331m), y los valores de Nugget ($0.037 < 7.942 < 90.587$, y $42.096 > 7.942$) y C0 / umbral ($0.57; 0.41; 0.79 > 0.03$) fueron mayores. Este cambio fue especialmente en todos los parámetros fisicoquímicos. Sobre la base de la integración del análisis anterior, vimos conveniente introducir variables auxiliares (variables efectivas), debido a que no todas, puede mejorar la estructura espacial de residuos generales y esto sentó las bases para la mejora de la eficiencia de interpolación de Rk.

3.2.2. Predicción de la distribución espacial de parámetros físico-químicos

Los mapas de distribución espacial del contenido de parámetros físico-químicos en los suelos pronosticados por KO, RK y GWRK con diferentes combinaciones de variables auxiliares se muestran en la Figura 6 y Figura 7. Los valores pronosticados por el método geoestadístico KO de los parámetros físico-químicos se realizó con diferentes modelos de semivariogramas (circular, esférico, exponencial y gaussiano), según el análisis del R cuadrado mayor y el error más pequeño se obtuvo, para pH el modelo gaussiano, CE modelo esférico, arena modelo exponencial, limo modelo circular y arcilla el modelo exponencial (Tabla 12), aunque la estructura de distribución espacial y la tendencia de variación de los parámetros físico-químicos por este método, en los suelos por los diferentes modelos fueron similares, que puede ser contrastado por los valores de los errores.

Con el fin de analizar, si el modelo de la distribución de parámetros de pH y CE mejoraban, se utilizó dos métodos más Rk y GWRK lo cual utilizando Rk hubo mejoría para el modelo para ambos parámetros para pH con un R^2 de 0.55 y CE de 0.27, pero para el método GWRK (R^2 0.47) con variables auxiliares, tuvo características similares de distribución espacial con KO (R^2 0.47) para pH; pero para CE difirió para GWRK (R^2 0.25) y con KO (R^2 0.21); no se vio conveniente agregar variables para el contenido de arena, limo y arcilla, y no sugerido por Meul *et al.* (2003), debido a que las variables no generan ninguna ganancia real al modelo, por lo cual el análisis quedó tan solo con el método KO (Figura 8).

Las variables auxiliares consideradas para pH en Rk fueron: arena, limo, arcilla, elevación, pendiente, temperatura, precipitación, distancia a vías, distancia a área residencial, distancia a ríos, geología, tipo de suelos y uso de suelo; para CE en

Rk fueron: elevación, pendiente, temperatura, precipitación, distancia a vías, distancia al área residencial, distancia a ríos, geología, tipos de suelo y usos de suelo; para el método GWRK tanto para pH y CE, se utilizaron elevación, pendiente, TWI, distancia al área residencial, geología, tipos de suelo y usos de suelos. La selección de cada una de las variables fue al aporte que hacía a cada modelo, como un resultado de la correlación espacial más fuerte. Esto sugiere que las características de distribución espacial de parámetros físico-químicos en suelos estimados por RK son más sensibles a las variables auxiliares que las estimadas por KO y GWRK (Hengl *et al.*, 2007).

Distribución espacial de pH

Según los rangos de predicción, los resultados predictivos de KO para pH (5.39 – 10.40, Figura 6) en comparación con la muestra, tuvieron un rango más estrecho con el valor mínimo de la muestra y superando al valor máximo de la muestra (3.45– 8.91, Tabla 5) debido al efecto de suavizado (Odeha *et al.*, 1994). En contraste, los rangos de contenido de pH con RK y GWRK con diferentes variables auxiliares fueron más cercanos al rango de muestras, especialmente en los casos de GWRK (3.75-8.94, Fig. 6) y para RK (3.84-9.99, Figura 6).

Además, como se puede apreciar en los mapas (Figura 6), según las reclasificaciones de los valores de pH por rangos de coloraciones que se visualiza en los mapas; con el método KO el distrito de Bagua Grande, Jamalca y Yamón presentan suelos de acidez moderada a alcalinidad moderada; El Milagro y Cajaruro presentan suelos con una acidez ligera, alcalinidad moderada y alcalinidad fuerte; Cumba acidez ligera a una alcalinidad moderada y Lonya Grande acidez moderada y alcalinidad ligera. Por otra parte, con el método RK Bagua Grande presenta suelos fuertemente ácidos a una alcalinidad fuerte; El Milagro y Cajaruro una acidez ligera a una alcalinidad fuerte, Cumba acidez moderada a alcalinidad moderada; Yamón, Lonya Grande y Jamalca con una fuerte acidez a una alcalinidad moderada.

Mientras que, por el método GWRK Bagua Grande presenta suelos fuertemente ácidos a una alcalinidad moderada; El Milagro acidez ligera y una alcalinidad moderada; Cumba acidez moderada a alcalinidad ligera; Yamón, Lonya Grande y Jamalca fuertemente ácido a una alcalinidad ligera; Cajaruro acidez moderada a una alcalinidad moderada.

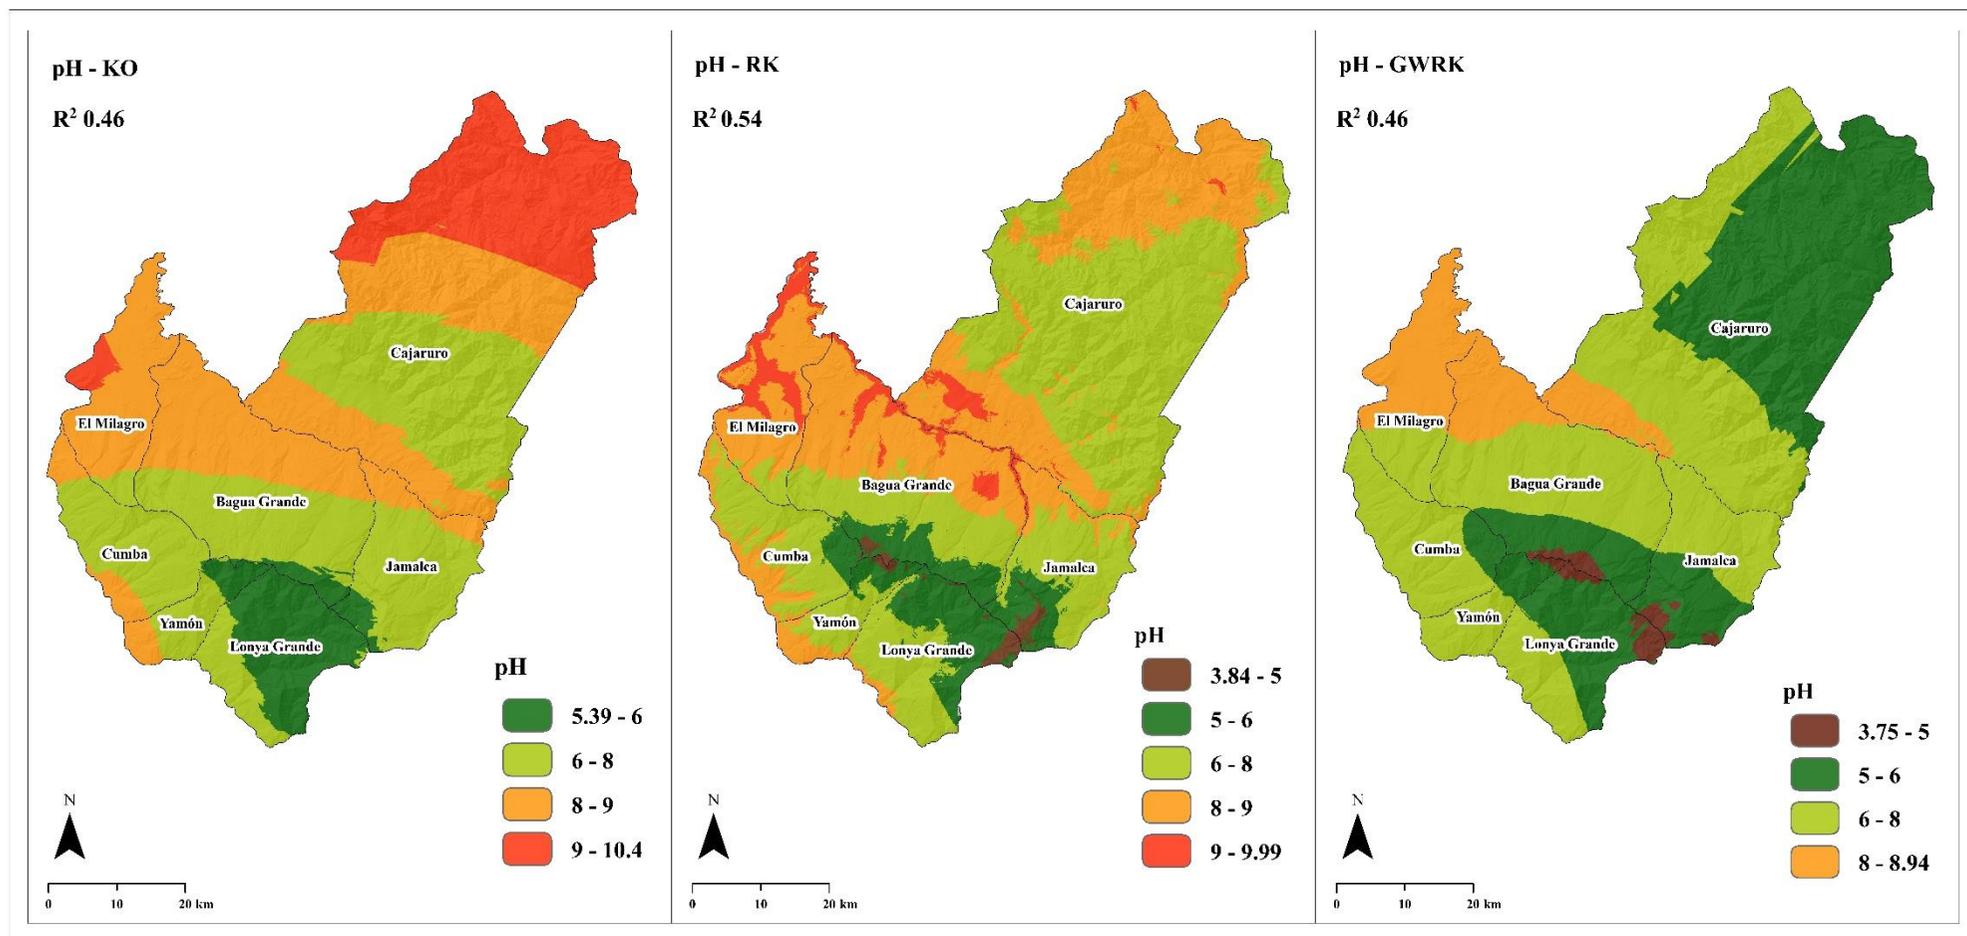


Figura 6. Mapa de pH del suelo en la provincia de Utcubamba.

Finalmente, de manera general teniendo en cuenta el mejor método RK, en este estudio la distribución espacial del pH, por el Norte presenta una acidez ligera a una alcalinidad fuerte, por el Sur suelos fuertemente ácidos a una alcalinidad moderada, por el Este suelo de acidez moderada a una alcalinidad moderada, por el Oeste con una acidez ligera a una alcalinidad fuerte. Pero, considerando que el método GWRK fue el segundo mejor modelo después de RK, la distribución que presenta por el Norte es de un pH con una acidez moderada y alcalinidad moderada, por el Sur una acidez fuerte a una alcalinidad ligera, por el Este una acidez moderada a una alcalinidad ligera; mientras por el Oeste una acidez moderada a una alcalinidad moderada (Figura 6).

Distribución espacial de CE

Para los rangos de predicción de CE con KO (0.29-0.88 mS/m, Fig. 7) tuvo un rango estrechado en comparación con la muestra, mientras que para RK (0.26-1.24 mS/m, Fig. 7) tuvo un rango más estrecho con el valor mínimo de la muestra y supero el valor máximo de la muestra, los valores más cercano lo tuvo GWRK (0.06-0.71 mS/m, Fig. 7) con respecto con la muestra(0.02-0.99 mS/m, Tabla 5)

Además, como se puede apreciar en los mapas (Figura 7), según las reclasificaciones de los valores de CE por rangos de coloraciones que se visualiza en los mapas; con el método KO el distrito de Cumba, Yamón, Lonya Grande, Jamalca presentan suelos no salinos (0.29-0.5mS/m); Bagua Grande y Cajaruro presentan suelos no salinos (0.3-0.88mS/m); El Milagro presenta valores de 0.3-0.8mS/m considerado suelo no salino. Por otra parte, con el método RK Cumba, Yamón, Lonya Grande, Jamalca presenta suelos no salinos (0.26-0.8mS/m); El Milagro suelo no salino (0.5-1.24 mS/m), Bagua Grande considerado un suelo no salino (0.3-1mS/m) y para Cajaruro valores de CE (0.3-1.24mS/m). Mientras que, por el método GWRK Cumba, Yamón y Lonya Grande presentan rangos de CE 0.06-0.5mS/m; El Milagro, Bagua Grande, Jamalca y Cajaruro presentan valores de una CE (0.06-0.71mS/m). Es importante recalcar que con los tres métodos de interpolación KO, RK y GWRK la distribución espacial del área de estudio de acuerdo a los valores de CE, es considerado un suelo no salino.

El método RK capturó las tendencias generales y la variabilidad local de parámetro pH y CE en los suelos, mientras que KO tomó en cuenta solo las variaciones espaciales

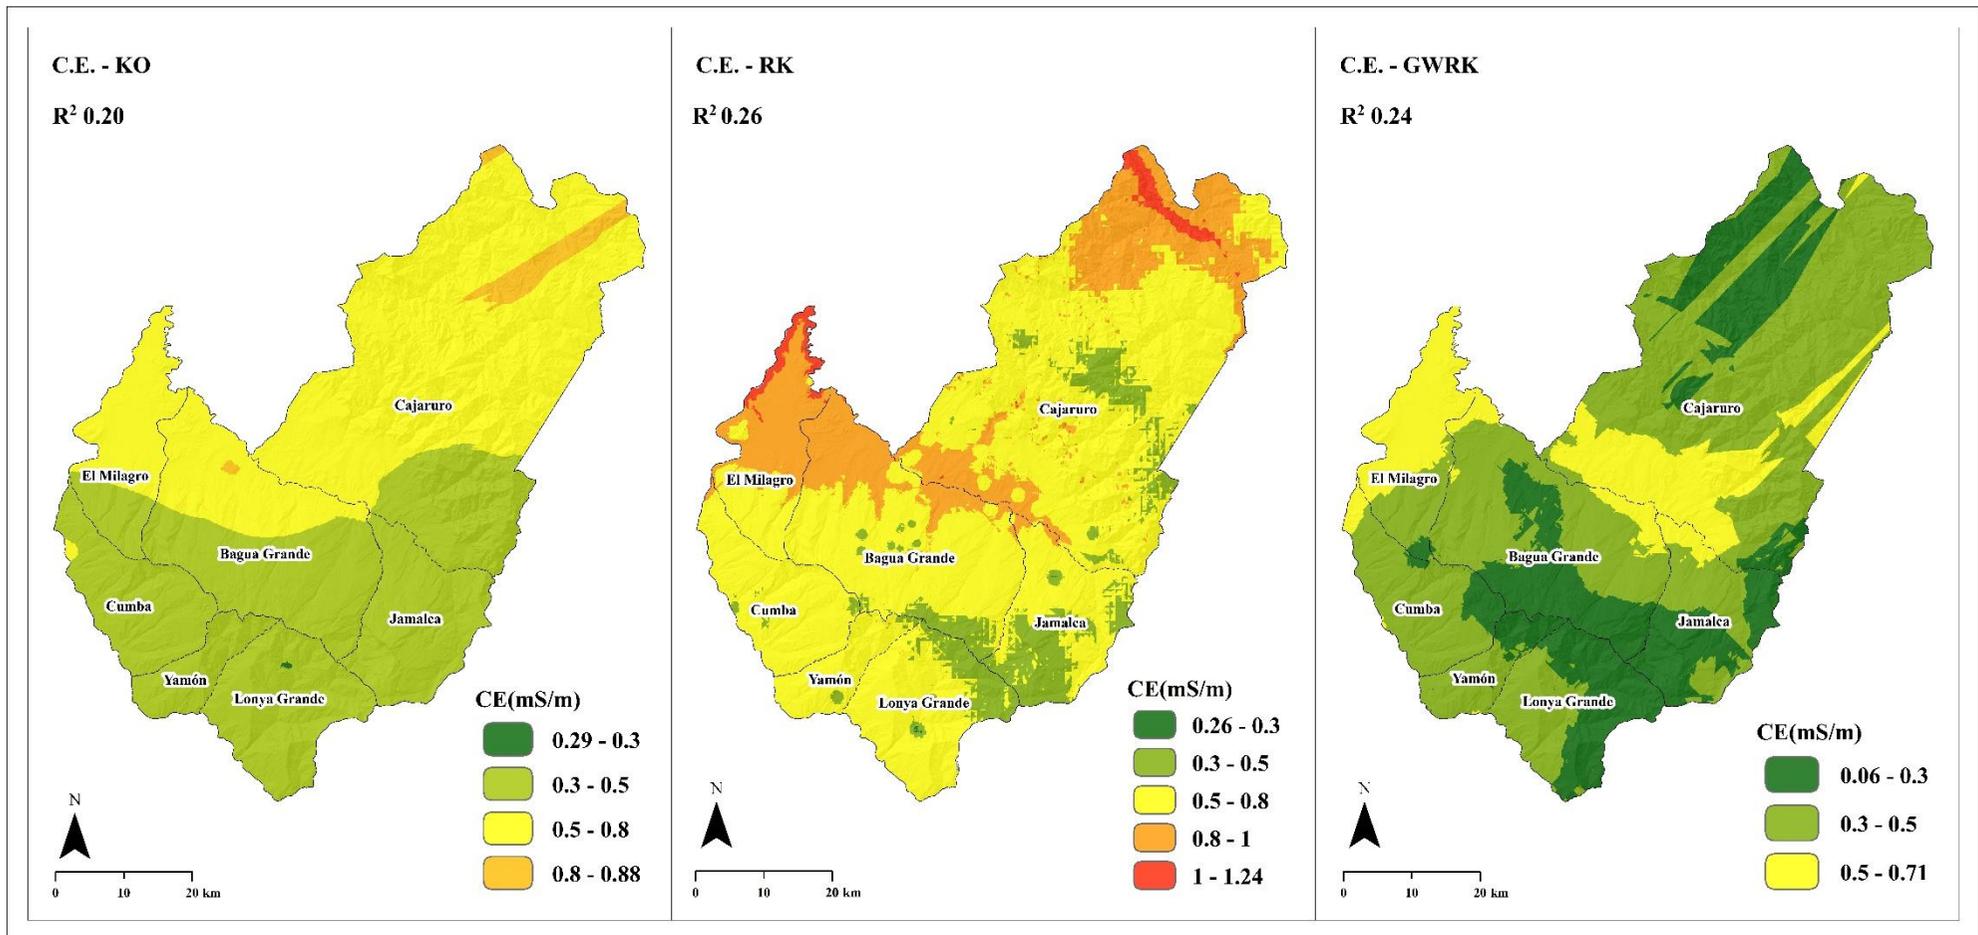


Figura 7. Mapa de Conductividad Eléctrica (C.E.) del suelo en la provincia de Utcubamba.

de los puntos de muestreo. Es evidente que RK con factores auxiliares logró un mapa de predicción más realista que KO. En general, RK fue un modelo de interpolación espacial más optimizado que KO para el mapeo predictivo de pH y CE en el suelo, cuando la estructura espacial no pudo ser capturada adecuadamente por puntos de muestreo o en casos en que se produjo una fuerte relación entre la variable objetivo y las variables auxiliares (Kravchenko y Robertson, 2007). Aunque los valores más cercanos con respecto con la muestra lo tuvieron los modelos GWRK, tanto para pH y CE, esto puede ser debido a que este método mide que variables son constantes y que variables varían espacialmente, lo que sucedió con la mayoría de las variables (Zeng *et al.*, 2016) (Anexo 4 y 5).

Distribución espacial de la clase textural

Para el contenido de arena con KO fue (2.10-89.30 %, Figura 8), para limo (7.55-30.87 %, Figura 8), para arcilla (9.16-48.63 %, Figura 8), todos los valores de predicción estuvieron estrechados en comparación con la muestra (10-90 %, Tabla 5), (2-50 %, Tabla 5), (6-61 %, Tabla 5) respectivamente. Según los datos anteriores tanto de los análisis descriptivos y predictivos y según la clasificación de clase textural de la USDA (1999) (Figura 9) el área de estudio presenta suelos franco arcilloso arenoso.

El área de estudio la clase textural que predominó fue Franco arcilloso, seguido por Franco arenoso, luego Franco arenoso arcilloso.

Tabla 10. Superficie (km²) según clase textural en la provincia de Utcubaba.

Clase textural	Área (km²)	%	Simbología
Arcilloso	135.13	3.23	A
Arcilloso arenoso	153.20	3.67	Aa
Arenoso franco	4.50	0.11	aF
Franco	79.23	1.90	F
Franco arcilloso	2655.81	63.54	FA
Franco arenoso	649.30	15.53	Fa
Franco arenoso arcilloso	481.35	11.52	FAa
Franco limoso	16.60	0.40	FL
Franco limoso arcilloso	4.58	0.11	FAL
Limoso	0.17	0.00	L

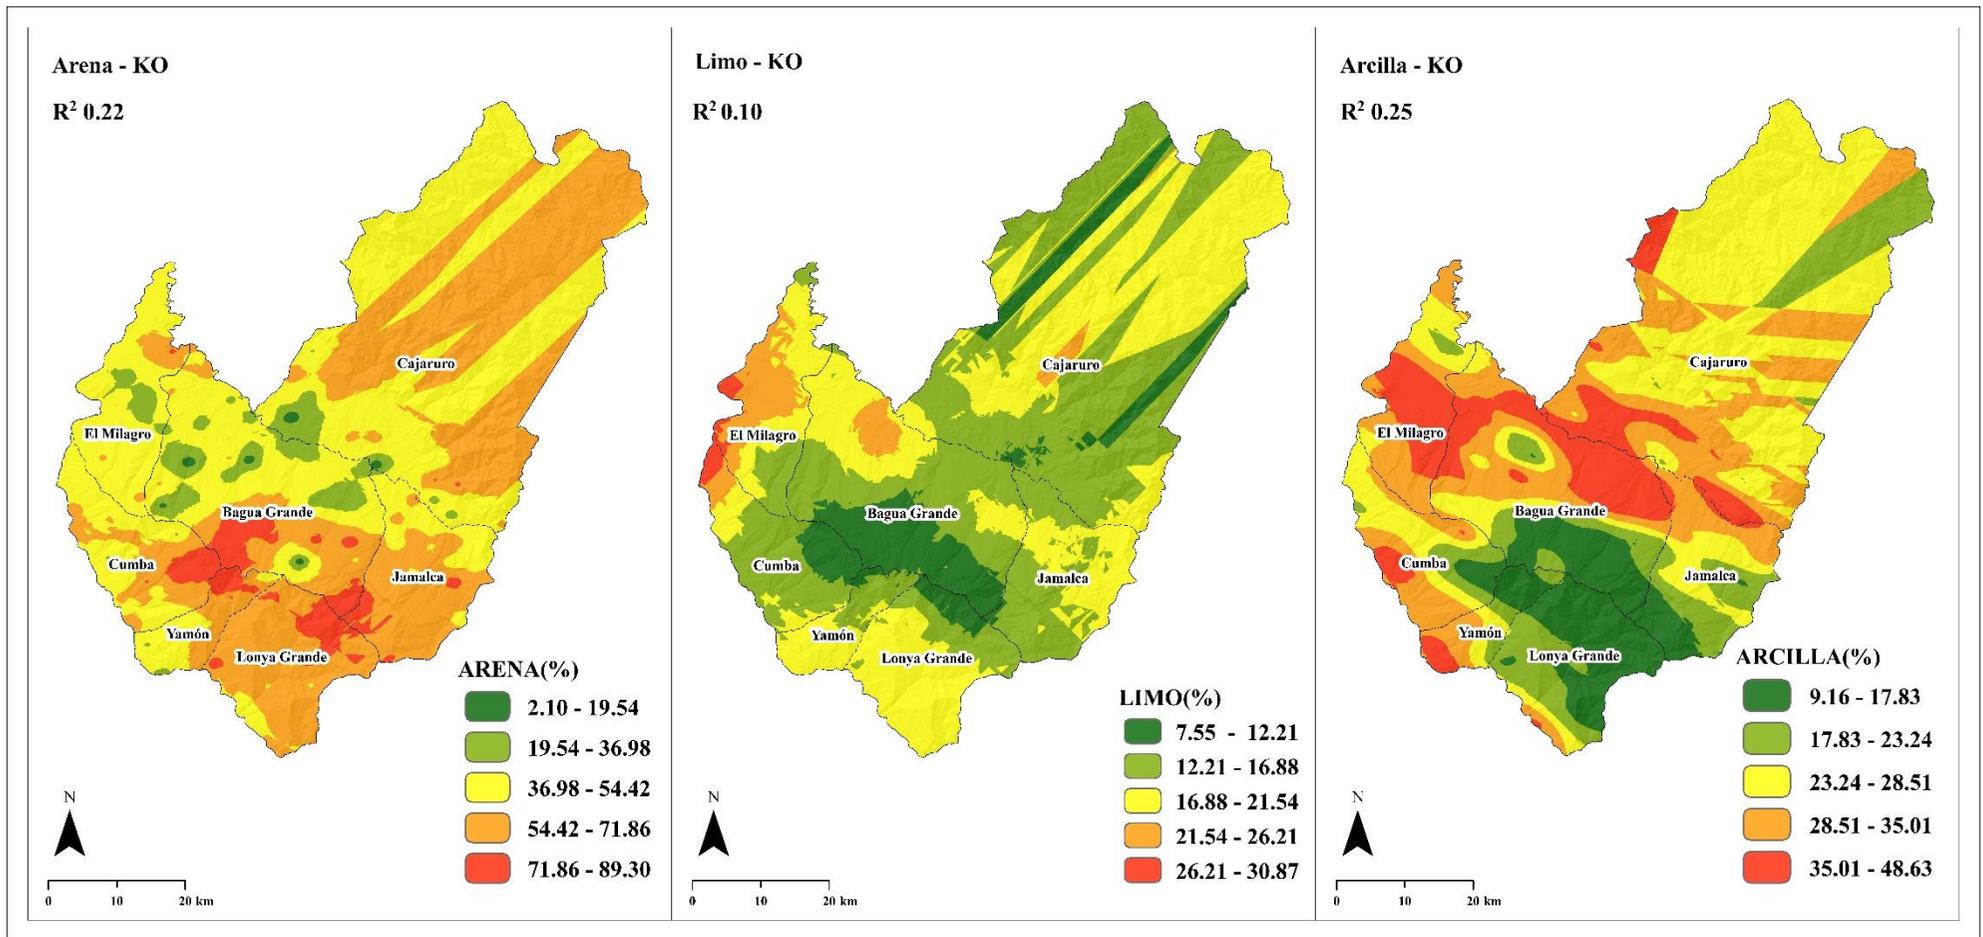


Figura 8. Mapa de contenido de arena, limo y arcilla del suelo en la provincia de Utcubamba.

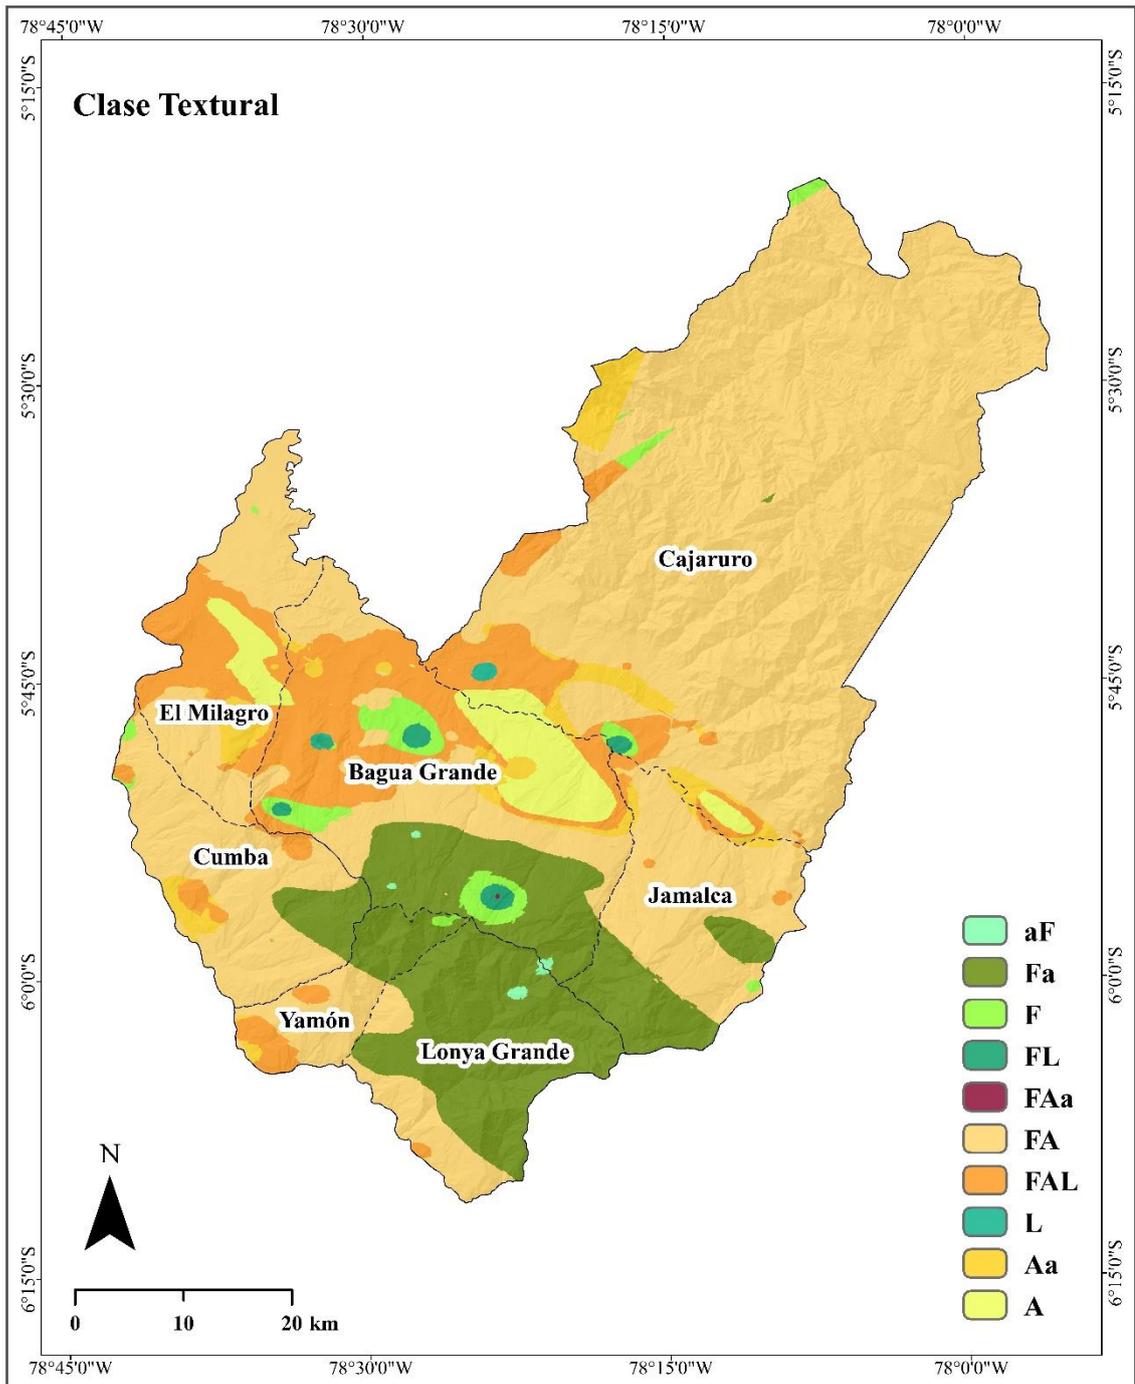


Figura 9. Mapa de clase textural del suelo en la provincia de Utcubamba.

Se realizó la correlación de Pearson con los diferentes usos de suelos para analizar el grado de correlación de cada parámetro medido; el pH y la CE fueron de las capas obtenidas de la regresión kriging, debido a que con este método se ajustaron mejor a la realidad, y para la clase textural (Arena, limo y arcilla) fueron las capas obtenidas de KO.

Tabla 11. Correlación de Pearson entre los parámetros fisicoquímicos en diferentes usos de suelos.

RK y KO	Profundidad: 0 - 20cm; N=217					
	pH	CE	Arena	Limo	Arcilla	
Agricultura de predomino arrocero	pH	1.00	0.77	-0.47	0.45	0.38
	CE		1.00	-0.72	0.46	0.52
	Arena			1.00	-0.09	-0.77
	Limo				1.00	-0.04
	Arcilla					1.00
Agricultura de predomino cafetalero	pH	1.00	0.94	-0.83	-0.20	0.90
	CE		1.00	-0.93	-0.05	0.87
	Arena			1.00	0.07	-0.79
	Limo				1.00	-0.31
	Arcilla					1.00
Agricultura de subsistencia	pH	1.00	0,66	-0.57	0.31	0.58
	CE		1,00	-0.86	0.27	0.66
	Arena			1.00	-0.20	-0.70
	Limo				1.00	0.13
	Arcilla					1.00
Pastos y Cultivos	pH	1.00	0.74	-0.50	0.58	0.60
	CE		1.00	-0.81	0.39	0.54
	Arena			1.00	-0.11	-0.30
	Limo				1.00	0.42
	Arcilla					1.00

Nota: Mapas predichos por el método RK para los parámetros de pH y CE y método KO para la clase textural.

3.3. Precisión de los mapas de la distribución de los parámetros físico-químicos

Los indicadores de rendimiento error medio (ME), el error absoluto medio (MAE) y el error cuadrático medio (RMSE), basados en los resultados del método de validación para los diferentes métodos de predicción espacial se resumen en la Tabla 11. En comparación con KO y GWRK, los valores absolutos de ME, MAE y RMSE de RK fueron todos más bajos para los parámetros estimados para pH y CE. Esto indica que la introducción de variables auxiliares (variables cuantitativas y cualitativas) puede mejorar la precisión de interpolación de la distribución espacial de todo tipo de datos cuantitativos en suelos.

Para la predicción de los parámetros arena, limo y arcilla solamente se utilizó el KO, para determinar cuál de los modelos se ajustaban mejor, se realizó el modelo circular, esférico, exponencial y gaussiano, los más utilizados en la geoestadística; según la validación de ME, MAE y RMSE y el R^2 se tomó la decisión de seleccionar cual modelo mejor se ajustaba a la realidad, obteniendo como resultado para arena el modelo exponencial, para limo el modelo circular y para la arcilla el modelo exponencial como se muestra en la Tabla 11. Cabe recalcar que entre modelo y modelo no hay mucha diferencia como se puede apreciar en los valores de los errores por la similitud.

Tabla 12. Resultados de validación con KO, RK y GWRK

Método	Parámetro	Modelo	R2	ME	MAE	RMSE	K-S	Valor de p
KO	pH	Circular	0.472	-0.004	0.716	1.079	0.141	0.010
		Esférico	0.395	0.053	0.790	1.212	0.110	0.010
		Exponencial	0.445	-0.004	0.729	1.245	0.131	0.010
		Gaussiano	0.465	-0.0006	0.729	1.085	0.139	0.010
	C.E	Circular	0.203	0.001	0.172	0.219	0.100	0.010
		Esférico	0.206	-0.0005	0.171	0.218	0.105	0.010
		Exponencial	0.188	0.00001	0.173	0.222	0.109	0.010
		Gaussiano	0.203	0.0013	0.173	0.219	0.091	0.010
	ARENA	Circular	0.228	-0.062	12.230	15.883	0.075	0.010
		Esférico	0.194	-0.124	12.543	16.327	0.085	0.010
		Exponencial	0.226	-0.040	12.215	15.919	0.078	0.010
		Gaussiano	0.224	-0.081	12.301	15.939	0.078	0.010
		Circular	0.108	-0.081	5.633	7.273	0.044	0.150
	LIMO	Esférico	0.107	-0.083	5.636	7.277	0.044	0.150
		Exponencial	0.097	-0.162	5.806	7.394	0.041	0.150
		Gaussiano	0.090	-0.163	5.828	7.434	0.043	0.150
	ARCILLA	Circular	0.208	-0.008	9.696	12.569	0.054	0.118
		Esférico	0.214	0.020	9.624	12.521	0.048	0.150
		Exponencial	0.259	0.029	9.286	12.141	0.041	0.150
		Gaussiano	0.192	-0.031	9.789	12.700	0.054	0.128
RK	pH	-	0.547	2.578E-15	0.715	0.998	0.074	0.010
	C.E	-	0.268	8.540E-16	0.167	0.209	0.085	0.010
GWRK	pH	-	0.467	-0.022	0.790	1.082	0.108	0.010
	C.E	-	0.249	0.001	0.169	0.212	0.102	0.010

Las inconsistentes correlaciones entre el pH y la temperatura del suelo probablemente se deben a los diferentes equilibrios entre la acumulación y descomposición de la materia orgánica del suelo. Insumos de materia orgánica del suelo provenientes de camadas vegetales puede aumentar con la temperatura debido al aumento de la biomasa (de Schrijver *et al.*, 2012). La acumulación de materia orgánica del suelo puede liberar más H⁺ en la solución de agua del suelo y, por lo tanto, conducir a valores de pH más bajos (Kirschbaum, 1995). El pH del suelo disminuye a medida que aumenta la temperatura en tales casos. Por otro lado, una temperatura más alta puede acelerar la descomposición de la materia orgánica del suelo (Conant *et al.*, 2011; Davidson y Janssens, 2006), por lo que la composición produce menos ácido orgánico. En este caso, el pH del suelo aumentaría a lo largo del gradiente de temperatura. La fuerza relativa de estos dos procesos determina la señal de correlación y la fuerza entre el pH y la temperatura del suelo. En conclusión, puede ser el motivo porque los suelos del área de estudio sean alcalinos, debido a la alta correlación que existe entre el pH y la temperatura (Figura 10). Del mismo modo se muestra

las gráficas de las correlaciones existentes con las demás variables con la regresión lineal múltiple, proceso para obtener el método de RK (Anexo 2 y 3) y además se muestra la variación espacial de la variable tipo de suelo (Figura 11) con el método de GWRK como ejemplo, las demás graficas ver (Anexo 4 y 5).

Variable cuantitativa de RK

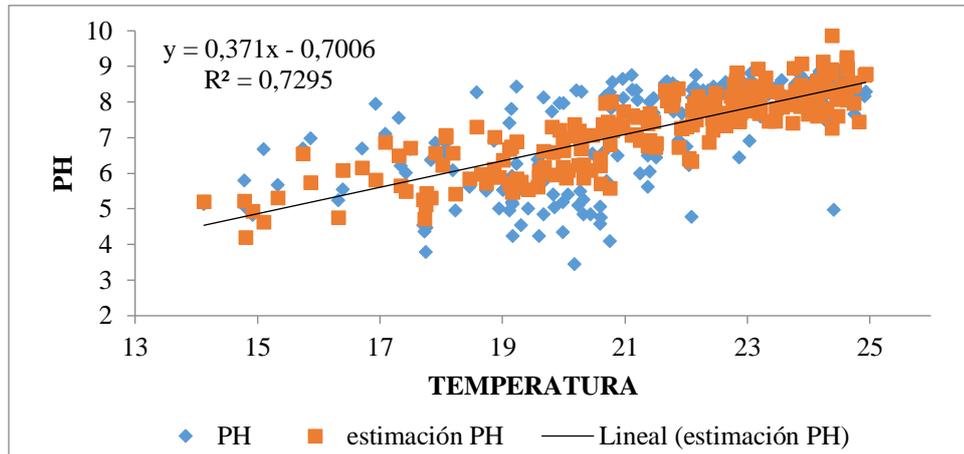


Figura 10. Curva de regresión ajustada de pH v.s Temperatura

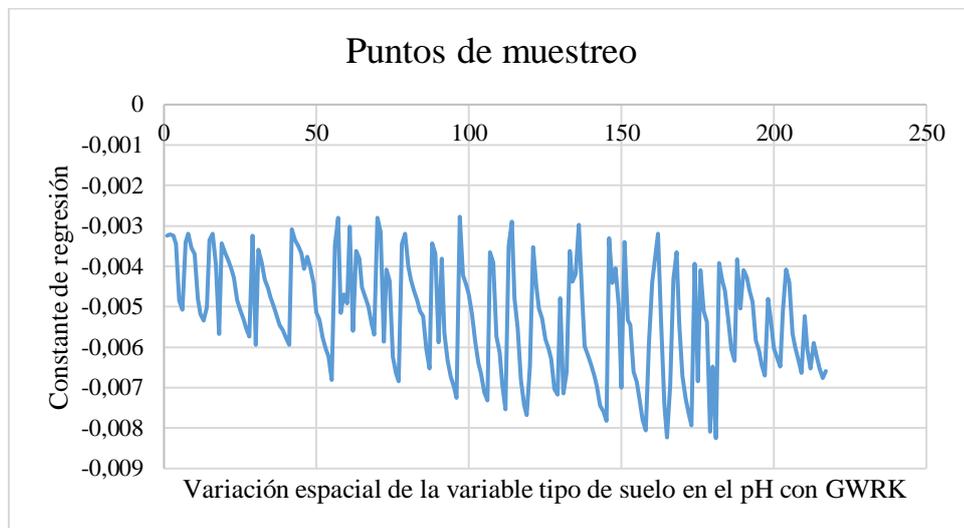


Figura 11. Constantes de regresiones de tipo de suelo vs. puntos de muestreo

IV. DISCUSIÓN

4.1. Resultados de los parámetros físico-químicos

El área de estudio presenta suelos, desde un pH ácido a modernamente alcalino ($3.45 < \text{pH} < 8.91$), esto puede indicar del por qué, estos suelos son productivos, debido a que se encuentran en los rangos ideales para la producción agrícola (Weil y Brady, 2017). A mejor detalle la acidez y alcalinidad se ve reflejado, en los suelos de agricultura de subsistencia ($4.35 > \text{pH} < 8.91$), pastos y cultivos ($4.24 > \text{pH} < 8.27$), agricultura de predominio cafetalero ($3.45 > \text{pH} < 8.76$), la acidez puede deberse por las prácticas de manejo agrícola, en particular la aplicación de fertilizantes químicos, que influyen significativamente en los niveles de pH en los suelos agrícolas (Goulding, 2016). Además el pH está sujeto a variaciones en suelos secos como en inundados, según Ding *et al.*, (2019) el pH para suelos inundado con un pH inicial < 6.5 aumentó a aproximadamente 7.0, y para suelos con un pH inicial > 6.5 , el pH primero disminuyó y luego aumentó a aproximadamente 7.0, y durante el periodo de drenaje los suelos ácidos disminuyeron y los suelos neutros a alcalinos se incrementaron. Otro de los factores de la acidificación, es por el uso excesivo de fertilizantes sintéticos N se ha identificado como un contribuyente dominante a la acidificación del suelo en las tierras de cultivo (Guo *et al.*, 2018). Una forma de mitigar es con el uso de aditivos que han producido un 54 % menos de volatilización del amoníaco como son en la caña de azúcar y un 79 % menos en cultivos trigo (FAO, 2011).

Por lo tanto, la aplicación adecuada de nitrógeno es una medida importante para mejorar el rendimiento de un cultivo, principalmente el arroz y promover la absorción de nutrientes en el arroz de suelos con alto contenido de CE, pero no de suelos con un pH alto, donde el pH es el principal factor limitante para la producción de arroz en suelos salinos-sódicos (Huang *et al.*, 2017). Lo que no sucede en nuestro caso debido a que los suelos del área de estudio no son salinos, pero si posiblemente sódicos por la alcalinidad que presentan; ya que según Huang *et al.* (2017) los suelos con un pH igual a 7 y 8, y con una conductividad eléctrica ($< 6 \text{dS/m}$), la aplicación adecuada de nitrógeno en estos suelos, es importante para mejorar el rendimiento del arroz y promover la absorción de nutrientes en el mismo.

La alcalinidad en la agricultura de predominio arrocero puede deberse a que estos suelos son jóvenes (Alfaro *et al.*, 2017), cabe recalcar que en los otros tipos de uso de suelo también presentaron alcalinidad. Aunque el número de muestra en la agricultura de predominio arrocero fue solo el 4% del total de muestra de las áreas de cultivo, lo cual no

es muy representativo. Por otra parte, la alcalinidad del área puede deberse a la existencia de carbonato de calcio pedogénico natural (CaCO_3), se asume que es responsable de gran parte de los altos niveles de pH del suelo que se encuentran en el área de estudio. Sin embargo, la presencia de algunas muestras muy alcalinas ($\text{pH} > 9.5$) en el subsuelo indica que esto también podría deberse a la presencia de otros carbonatos, como el carbonato de sodio (Na_2CO_3) y el bicarbonato de sodio (NaHCO_3). El carbonato de sodio en particular tiene un nivel de pH mucho más alto (11.26) que el carbonato de calcio ($\text{pH} 9.91$) y también es mucho más soluble en agua (Filippi *et al.*, 2018).

La conductividad eléctrica es la habilidad que tiene una sustancia para transmitir o conducir una corriente eléctrica; generalmente se expresa en unidades de milisiemens por metro (mS/m). En algunas ocasiones se reporta la CE en unidades de decisiemens por metro (dS/m), que equivalen al valor de mS/m dividido por 100. Los suelos del área de estudio fueron de 0.02 a 0.99 (mS/m), considerado en estos rangos un suelo no salino, en estos tipos de suelos encontramos pocos organismos afectados (USDA, 1999). Razón por la cual estos suelos son productivos, debido que un suelo salino causa un estrés fisiológico en las plantas convirtiéndolas en improductivas (Terrazas, 2018)

4.2. Modelos geoestadísticos de la distribución espacial de los parámetros físico-químicos

En cuanto a los rangos de los modelos de los semivariogramas geoestadísticos de los parámetros físicoquímicos, fueron mayores que el intervalo de muestreo promedio (3000m); lo que indica que el muestreo es apropiado y esto garantiza que el mapa de interpolación pueda mostrar la estructura espacial de los parámetros físicoquímicos correctamente (Cao *et al.*, 2017). El uso de la geoestadística dio buenos resultados, ya que hubo una alta correlación espacial de la arena con el modelo exponencial nugget/Sill (es decir, inferior al 25%), para pH, CE y arcilla tuvieron una correlación moderada (es decir, entre 25% y el 75%) y el limo se obtuvo una correlación débil (es decir superior al 75%) que también fue concluido por Zhu y Lin, (2010). Si bien la variación de nugget puede reflejar la variabilidad espacial de las variables ambientales, la sensibilidad y la robustez de este parámetro no es tan adecuada como el valor del rango (Chen *et al.*, 2008).

En cuanto para analizar si la predicción mejoraba con la integración de variables auxiliares (cuantitativas y cualitativas), se mejoró el modelo; solo se integraron estas variables para los parámetros pH Y CE para el método RK y GWRK , debido a que estos parámetros están más sujetos a cambios a condiciones climáticas y causas

antropogénicas, más que la textura del suelo, considerada como una propiedad física importante del suelo es relativamente estable en la formación, migración, deposición del suelo a largo plazo, proceso de descomposición que fue concluida por Zhang *et al.* (2013), razón por la cual la clase textural no se involucró más variables de estudio y no recomendada por Meul *et al.*, 2003, porque no generan ninguna ganancia al modelo. Para RK el pH se mejoró con un R^2 de 0.55; mientras que para KO 0.47 y de GWRK 0.47 no difirieron significativamente entre sí, simplemente la estimación del contenido de pH y CE puede ser obtenido mediante el método univariado (KO) y no con incorporar variables a GWRK, que no generaron ninguna ganancia real al modelo, como también lo da conocer Meul *et al.* (2003); estos resultados dan a conocer la importancia del uso de KO como interpolador geoestadístico en muchos estudios para la predicción de parámetros fisicoquímicos, materia orgánica, metales pesados, etc. (Piccini *et al.*, 2014; Jiang *et al.*; 2017; Pouladi *et al.*, 2019). Hengl *et al.* (2004) sugirió que una medida clave para decidir, sobre qué método usar puede ser la fuerza de correlación de la variable objetivo (pH y CE) con la información auxiliar; probablemente en este caso del método GWRK, la fuerza de la correlación no sea suficiente, y los resultados no respaldan la elección. A demás de esto se puede concluir que la introducción de variables efectivas, no todas, puede mejorar la estructura espacial de los residuos y esto sentó las bases para la mejora de la eficiencia de interpolación con RK (Cao *et al.*, 2017).

En el estudio realizado RK se diferenció de KO en la predicción del pH y la CE, por el R^2 y por el RMSE (error cuadrático medio), lo que no sucedió con Piccini *et al.* (2014) sus resultados no mejoraron significativamente mediante el uso de RK, pero si concuerda con estudios de Cao *et al.* (2017) que concluye que al hacer uso de variables auxiliares para RK el modelo de predicción suele acercarse más a la realidad, del mismo modo Zhang *et al.* (2018) menciona que las variables ambientales, el uso del suelo, la precipitación media anual y la temperatura media anual que introdujo a sus modelos fueron un fuerte predictor de pH, del mismo modo estas variables contribuyeron en nuestro estudio en el uso de RK para el pH y CE, ya que cada parámetro guardaron una fuerte correlación (Figura 10 y Anexo 4 y 5). Además el R^2 de RK 0.55 supero al 0.50 de Zhang *et al.* (2018), pero no al error cuadrático medio (RMSE) que fue mayor (0.99) y en su estudio fue de (0.30) en caso del pH; cabe recalcar también que en su estudio consideraron más variables ambientales, incluido el índice de vegetación de relación (RVI), el índice de vegetación de diferencia normalizada (NDVI), el índice de agua de diferencia normalizada (NDWI), Por otro lado Sevilla *et al.* (2013),

indica que las regresiones de la integración de variables pueden ser lógicas, pero si existe correlaciones bajas, esto puede afectar la veracidad de los mapas finales obtenidos, con referente a este estudio los resultados obtenidos de RK fueron mejores (R^2 0.55), ya que su R^2 para la arena estuvo entre (0.022 y 0.024) y arcilla (0.010 y 0.020), lo que indica que no siempre la integración de variables van a mejorar el modelo. Nuestros resultados de la distribución de pH con RK se asemejan al estudio Soil pH in Europe (2010) con un modelo bastante preciso ($R^2_{adj} = 0.56$) y en nuestro estudio ($R^2_{adj} = 0.52$).

La predicción de arena, limo y arcilla solo se utilizaron KO, y los resultados obtenidos fueron mejores que de Sevilla *et al.* (2013); en cuanto a los diferentes resultados obtenidos de estos parámetros con este método se asemejan a los de Shahriari *et al.* (2019).

4.3. Precisión de los mapas de la distribución de los parámetros físico-químicos

La precisión de los mapas estimados tanto por KO como por GWRK es más o menos la misma; las diferencias entre los valores de error no son estadísticamente significativas para los tres métodos. A demás con el uso de KO con los diferentes modelos (circular, esférico, exponencial y gaussiano) no existe mucha diferencia en sus valores, esto se ve reflejado en el cálculo de los errores (Tabla 11). El KO es método univariado que se interpola para todas las variables fisicoquímicas, que puede ser mejor en ocasiones que el método RK Sevilla *et al.* (2013) y Piccini *et al.* (2014). La importancia de regresión kriging en la predicción de resultados, es que este método ha sido popular debido a su bajo error de predicción, lo que es verificable con los resultados de este estudio. Mejora las predicciones de los modelos de regresión mediante la interpolación de los residuos mediante kriging (Yigini y Panagos, 2016); el método combina el Análisis de Regresión Lineal Múltiple para modelar la tendencia de la variable dependiente en variables auxiliares con la interpolación de los residuos de regresión por kriging ordinario (Hengl *et al.*, 2004; Hengl, 2009). En este contexto la regresión lineal Múltiple que forma parte de la RK, es considerada como un modelo de regresión global donde no se puede notar la variación espacial, porque todos sus coeficientes de regresión se mantienen fijos (Guo *et al.*, 2017; Kumar, 2015; Liu *et al.*, 2015), lo que no sucede con GWRK determina que variables son constantes y que variables varían espacialmente, en nuestro estudio la variable pendiente se mantuvo constante (Anexo 4) lo que discrepa a Zeng *et al.* (2016); pero las demás variables introducidas (elevación, índice de humedad topográfica, distancia a áreas residenciales, geología, tipo de suelo y uso de suelo) tanto para el pH y CE variaron espacialmente (Anexo 4 y 5).

V. CONCLUSIONES

- Se identificó suelos desde ácidos a moderadamente alcalinos ($3.45 < \text{pH} < 8.91$) con un valor promedio de 7.28 lo cual sugiere del porque estos suelos son productivos. De la misma forma el área de estudio presento una C.E de 0.02 a 0.99 mS/m estos valores indican que estos suelos no son salinos. Los análisis estadísticos descriptivos de medias del contenido de arena (53%), limo (17%), arcilla (30%) y la predicción con los modelos geoestadísticos arena (46%), limo (22%), arcilla (33%), en ambos análisis los valores indican que el suelo del área de estudio es Franco Arcillo Arenoso.
- Los modelos de la distribución espacial de los parámetros físico-químicos, que mejor se ajustaron utilizando el método geoestadístico kriging ordinario (KO) fueron para pH gaussiano (R^2 0.465), CE esférico (R^2 0.206), arena exponencial (R^2 0.226), limo circular (R^2 0.108), arcilla exponencial (R^2 0,259), entre las comparaciones de los semivariogramas (circular, esférico, gaussiano y exponencial). Además, el rango de valores de los semivariogramas que mejor se ajustaron, fueron mayor al del muestreo promedio (3000m), siendo los valores siguientes: para pH gaussiano (56784m), CE esférico (42126m), arena exponencial (5331m), limo circular (5767m), arcilla exponencial(26819m), estos valores garantizan que el mapa de interpolación de cada parámetro físico-químico evaluado, muestra la estructura espacial correctamente. Los modelos anteriores fueron mejorados para los parámetros pH (0.547) y CE (0.268) con el método regresión kriging (RK), indicador estadístico el R^2 , incluso supero al método GWRK en pH (0.467) y CE (0.249). De acuerdo a estos valores el método RK, fue mejor que los demás.
- La precisión de los mapas de distribución, se determinó mediante el cálculo de errores, se calculó el error medio (ME), el error absoluto medio (MAE) y el error cuadrático medio (RMSE), cuyos valores permitieron validar la confiabilidad de los mapas obtenidos. El error cuadrático medio (RMSE), es el más utilizado en los SIG; por lo que los resultados obtenidos son los siguientes: con el método KO, para pH gaussiano (1.085), CE esférico (0.218), arena exponencial (15.919), limo circular (7.273), arcilla exponencial (12.141), mientras, para RK fue el RMSE (0.998) y GWRK (1.082) para el pH y para la CE en RK fue (0.209) y GWRK (0.212); estos valores, indican que RK fue el modelo mejor ajustado en este estudio.

VI. RECOMENDACIONES

- Los resultados de la presente investigación, es un diagnóstico general de los parámetros físico-químicos de la provincia de Utcubamba, que sirve como base de datos para otras investigaciones, es por ello que para futuras investigaciones se sugiere utilizar softwares más sofisticados, con procesos sistematizados que permiten un mejor ajuste del modelo, procesos estadísticos con el fin de actualizar periódicamente las variables.
- El modelo geoestadístico es usado ampliamente en diversos estudios ambientales como modelo predictivo de contaminantes, usado mayormente en suelos y aire, mediante una interpolación; en este sentido el gobierno nacional y regional, deben de realizar estos tipos de estudios para monitorear la calidad del suelo multitemporalmente para la toma de decisiones, ante alteraciones que este puede sufrir por los diferentes cambios naturales, calentamiento global y actividades antropogénicas. Además, se sugiere a las instituciones competentes contar con una plataforma virtual de esta base de datos, para el acceso del público en general.
- Es importante que el gobierno regional empezar a trabajar en la recuperación de suelos degradados, suelos demasiados ácidos o demasiados alcalinos; con programas, proyectos, capacitaciones, ya que la región amazónica más del 50% del territorio es una zona agrícola, debido a que los suelos se han ido deteriorando y han ido perdiendo nutrientes. Es importante realizar otro tipo de análisis como la fertilidad de los suelos, análisis de metales pesados, tanto en suelos, como en granos de plantaciones de arroz, cacao, en áreas más específicas.
- El diagnóstico del suelo es importante, esto se realiza con los análisis de la recolecta de muestra, la mayoría de agricultores en la región no son conocedoras de esta información, como por ejemplo, de cuando un suelo esta empobrecido de nutrientes, salvo cooperativas que trabajan con personal técnico, he ahí la importancia de la intervención del gobierno nacional, regional, universidades, instituciones ambientales, profesionales, en generar y ejecutar proyectos en obras de conservación de suelos, prácticas agronómicas conservacionistas, respetar la legislaciones, el ordenamiento del territorio, y los mecanismos de control para que se hagan cultivos en base a las clases y subclases de suelos que son aptas para cada tipo, con lo cual se evitará el deterioro de los suelos por su uso inadecuado.

- La universidad, a través de las carreras de los últimos ciclos, como ingeniería ambiental, agronomía y forestal, y todas en general, dentro de sus planes de estudios se sugiere realizar trabajos de vivencia con una comunidad de la región Amazonas con el lema Aprender-Haciendo, para la realización de un diagnóstico de sus tierras y tratar de solucionar los problemas encontrados en dicha comunidad desde la formación recibida, que dicho sea de paso los problemas encontrados puedan ser temas de investigación.

VII. REFERENCIAS BIBLIOGRÁFICAS

- Alfaro, F. D., Manzano, M., Marquet, P. A., & Gaxiola, A. (2017). Microbial communities in soil chronosequences with distinct parent material: The effect of soil pH and litter quality. *Journal of Ecology*, *105*(6), 1709-1722.
- Benitez, F. L., Anderson, L. O., & Formaggio, A. R. (2016). Evaluation of geostatistical techniques to estimate the spatial distribution of aboveground biomass in the Amazon rainforest using high-resolution remote sensing data. *Acta Amazonica*, *46*(2), 151-160.
- Booth, B., & Bratt, S. (2004). Using ArcGIS 3D Analyst. Environmental Systems Research Institute (ESRI).
- Bishop, T.F.A., McBratney, A.B., (2001). A comparison of prediction methods for the creation of field-extent soil property maps. *Geoderma* *103*, 149–160.
- Cambardella, C. A., Moorman, T. B., Parkin, T. B., Karlen, D. L., Novak, J. M., Turco, R. F., & Konopka, A. E. (1994). Field-scale variability of soil properties in central Iowa soils. *Soil science society of America journal*, *58*(5), 1501-1511.
- Cao, S., Lu, A., Wang, J., & Huo, L. (2017). Modeling and mapping of cadmium in soils based on qualitative and quantitative auxiliary variables in a cadmium contaminated area. *Science of the Total Environment*, *580*, 430-439.
- Chen, L., Zhou, S., Shi, Y., Wang, C., Li, B., Li, Y., & Wu, S. (2018). Heavy metals in food crops, soil, and water in the Lihe River Watershed of the Taihu Region and their potential health risks when ingested. *Science of the Total Environment*, *615*, 141-149.
- Chen, T., Chang, Q., Liu, J., Clevers, J. G. P. W., & Kooistra, L. (2016). Identification of soil heavy metal sources and improvement in spatial mapping based on soil spectral information: A case study in northwest China. *Science of the total environment*, *565*, 155-164.
- Chen, T., Liu, X., Zhu, M., Zhao, K., Wu, J., Xu, J., et al., (2008). Identification of trace element sources and associated risk assessment in vegetable soils of the urban? Rural transitional area of Hangzhou, China. *Environ. Pollut.* *151*, 67–78.
- Ćujić, M., Dragović, S., Đorđević, M., Dragović, R., & Gajić, B. (2016). Environmental assessment of heavy metals around the largest coal fired power plant in Serbia. *Catena*, *139*, 44-52.

- Conant, R. T., Ryan, M. G., Ågren, G. I., Birge, H. E., Davidson, E. A., Eliasson, P. E., ... & Hyvönen, R. (2011). Temperature and soil organic matter decomposition rates—synthesis of current knowledge and a way forward. *Global Change Biology*, 17(11), 3392-3404.
- Dai, L., Wang, L., Liang, T., Zhang, Y., Li, J., Xiao, J., ... & Zhang, H. (2019). Geostatistical analyses and co-occurrence correlations of heavy metals distribution with various types of land use within a watershed in eastern Qinghai-Tibet Plateau, China. *Science of The Total Environment*, 653, 849-859.
- Ding, C., Du, S., Ma, Y., Li, X., Zhang, T., & Wang, X. (2019). Changes in the pH of paddy soils after flooding and drainage: Modeling and validation. *Geoderma*, 337, 511-513.
- de Schrijver, A., et al., (2012). Tree species traits cause divergence in soil acidification during four decades of postagricultural forest development. *Glob. Change Biol.* 18, 1127–1140.
- Davidson, E.A., Janssens, I.A., 2006. Temperature sensitivity of soil carbon decomposition and feedbacks to climate change. *Nature* 440, 165–173.
- Eastman, J.R. (2001). Guide to GIS and Image Processing. IDRISI32, Release 2. 2 p. 133e138.
- Espinosa, J; & Molina, E (1999). *Acidez y encalado de los suelos*. Primera edición. IPNI
- FAO. (2011). *El estado de los recursos de tierras y aguas del mundo para la alimentación y la agricultura. La gestión de los sistemas en situación de riesgo*. FAO, Roma y Mundi-Prensa, Madrid.
- Fernández, S., Cotos-Yáñez, T., Roca-Pardiñas, J., & Ordóñez, C. (2018). Geographically weighted principal components analysis to assess diffuse pollution sources of soil heavy metal: Application to rough mountain areas in Northwest Spain. *Geoderma*, 311, 120-129.
- Fick, S. E., & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International journal of climatology*, 37(12), 4302-4315. <https://doi.org/10.1002/joc.5086>.
- Filippi, P., Cattle, S. R., Bishop, T. F., Odeh, I. O., & Pringle, M. J. (2018). Digital soil monitoring of top-and sub-soil pH with bivariate linear mixed models. *Geoderma*, 322, 149-162.
- Finzgar, N., Jez, E., Voglar, D., & Lestan, D. (2014). Spatial distribution of metal contamination before and after remediation in the Meza Valley, Slovenia. *Geoderma*, 217, 135-143.
- GRA e IIAP. (2013). *Zonificación Ecológica y Económica (ZEE) de la Región de Amazonas*. Iquitos, Perú: Instituto de Investigaciones de la Amazonía Peruana.

- Guo, L., Zhao, C., Zhang, H., Chen, Y., Linderman, M., Zhang, Q., Liu, Y., (2017). Comparisons of spatial and non-spatial models for predicting soil carbon content based on visible and near-infrared spectral technology. *Geoderma* 285, 280–292
- Guo, X., Li, H., Yu, H., Li, W., Ye, Y., Biswas, A., (2018). Drivers of spatio-temporal changes in paddy soil pH in Jiangxi Province, China from 1980 to 2010. *Sci. Rep.* 8, 2702.
- Hengl, T., 2009. A Practical guide to Geostatistical Mapping. *Scientific and Technical Research series* [http://dx.doi.org/10.1016/0277-9390\(86\)90082-8](http://dx.doi.org/10.1016/0277-9390(86)90082-8)
- 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. <http://dx.doi.org/10.1016/j.geoderma.2003.08.018>.
- Hong, S., Gan, P., & Chen, A. (2019). Environmental controls on soil pH in planted forest and its response to nitrogen deposition. *Environmental research*, 172, 159-165.
- Hu, L., Zhang, L., & Wu, H. (2019). Experimental study of the effects of soil pH and ionic species on the electro-osmotic consolidation of kaolin. *Journal of hazardous materials*, 368, 885-893. <https://doi.org/10.1016/j.jhazmat.2018.09.015>
- Huang, L., Liu, X., Wang, Z., Liang, Z., Wang, M., Liu, M., & Suarez, D. L. (2017). Interactive effects of pH, EC and nitrogen on yields and nutrient absorption of rice (*Oryza sativa* L.). *Agricultural Water Management*, 194, 48–57. doi:10.1016/j.agwat.2017.08.012
- Jiang, Y., Chao, S., Liu, J., Yang, Y., Chen, Y., Zhang, A., & Cao, H. (2017). Source apportionment and health risk assessment of heavy metals in soil for a township in Jiangsu Province, China. *Chemosphere*, 168, 1658-1668.
- Kumar, S., (2015). Estimating spatial distribution of soil organic carbon for the Midwestern United States using historical database. *Chemosphere* 127, 49–57.
- Kumar, S., Lal, R., Liu, D., 2012. A geographically weighted regression kriging approach for mapping soil organic carbon stock. *Geoderma* 189–190, 627–634.
- Kirschbaum, M., (1995). The temperature dependence of soil organic matter decomposition, and the effect of global warming on soil organic C storage. *Soil Biol. Biochem.* 27, 753–760.

- Kravchenko, A.N., Robertson, G.P., (2007). Can topographical and yield data substantially improve total soil carbon mapping by regression kriging? *Agron. J.* 99, 12–17.
- Li, X., Yang, H., Zhang, C., Zeng, G., Liu, Y., Xu, W., ... & Lan, S. (2017). Spatial distribution and transport characteristics of heavy metals around an antimony mine area in central China. *Chemosphere*, 170, 17-24.
- Liu, B., Ai, S., Zhang, W., Huang, D., & Zhang, Y. (2017). Assessment of the bioavailability, bioaccessibility and transfer of heavy metals in the soil-grain-human systems near a mining and smelting area in NW China. *Science of the Total Environment*, 609, 822-829.
- Liu, Y.L., Guo, L., Jiang, Q.H., Zhang, H.T., Chen, Y.Y., (2015). Comparing geospatial techniques to predict SOC stocks. *Soil Till. Res.* 148, 46–58.
- Lü, J., Jiao, W. B., Qiu, H. Y., Chen, B., Huang, X. X., & Kang, B. (2018). Origin and spatial distribution of heavy metals and carcinogenic risk assessment in mining areas at You'xi County southeast China. *Geoderma*, 310, 99-106.
- Lv, J., Liu, Y., Zhang, Z., Dai, J., 2013. Factorial kriging and stepwise regression approach to identify environmental factors influencing spatial multi-scale variability of heavy metals in soils. *J. Hazard. Mater.* 261, 387–397.
- Map of Soil pH in Europe, (2010). Land Resources Management Unit, *Institute for Environment & Sustainability*, European Commission, Joint Research Centre
- Meul, M., & Van Meirvenne, m. (2003). Kriging soil texture under different types of nonstationarity. *Geoderma*, 112(3-4), 217–233.doi:10.1016/s0016-7061 (02) 00308-7
- Mihailović, A., Budinski-Petković, L., Popov, S., Ninkov, J., Vasin, J., Ralević, N. M., & Vasić, M. V. (2015). Spatial distribution of metals in urban soil of Novi Sad, Serbia: GIS based approach. *Journal of Geochemical Exploration*, 150, 104-114.
- Matheron, G., 1963. Principles of geostatistics. *Econ. Geol.* 58, 1246–1266.
- Matheron, G., 1965. Les variables régionalisées et leur estimation: une application de la théorie des fonctions aléatoires aux sciences de la nature. *Masson*, Paris, France.
- Odeha, I.O.A., McBratney, A.B., Chittleborough, D.J., (1994). Spatial prediction of soil properties from landform attributes derived from a digital elevation model. *Geoderma* 63, 197–214.

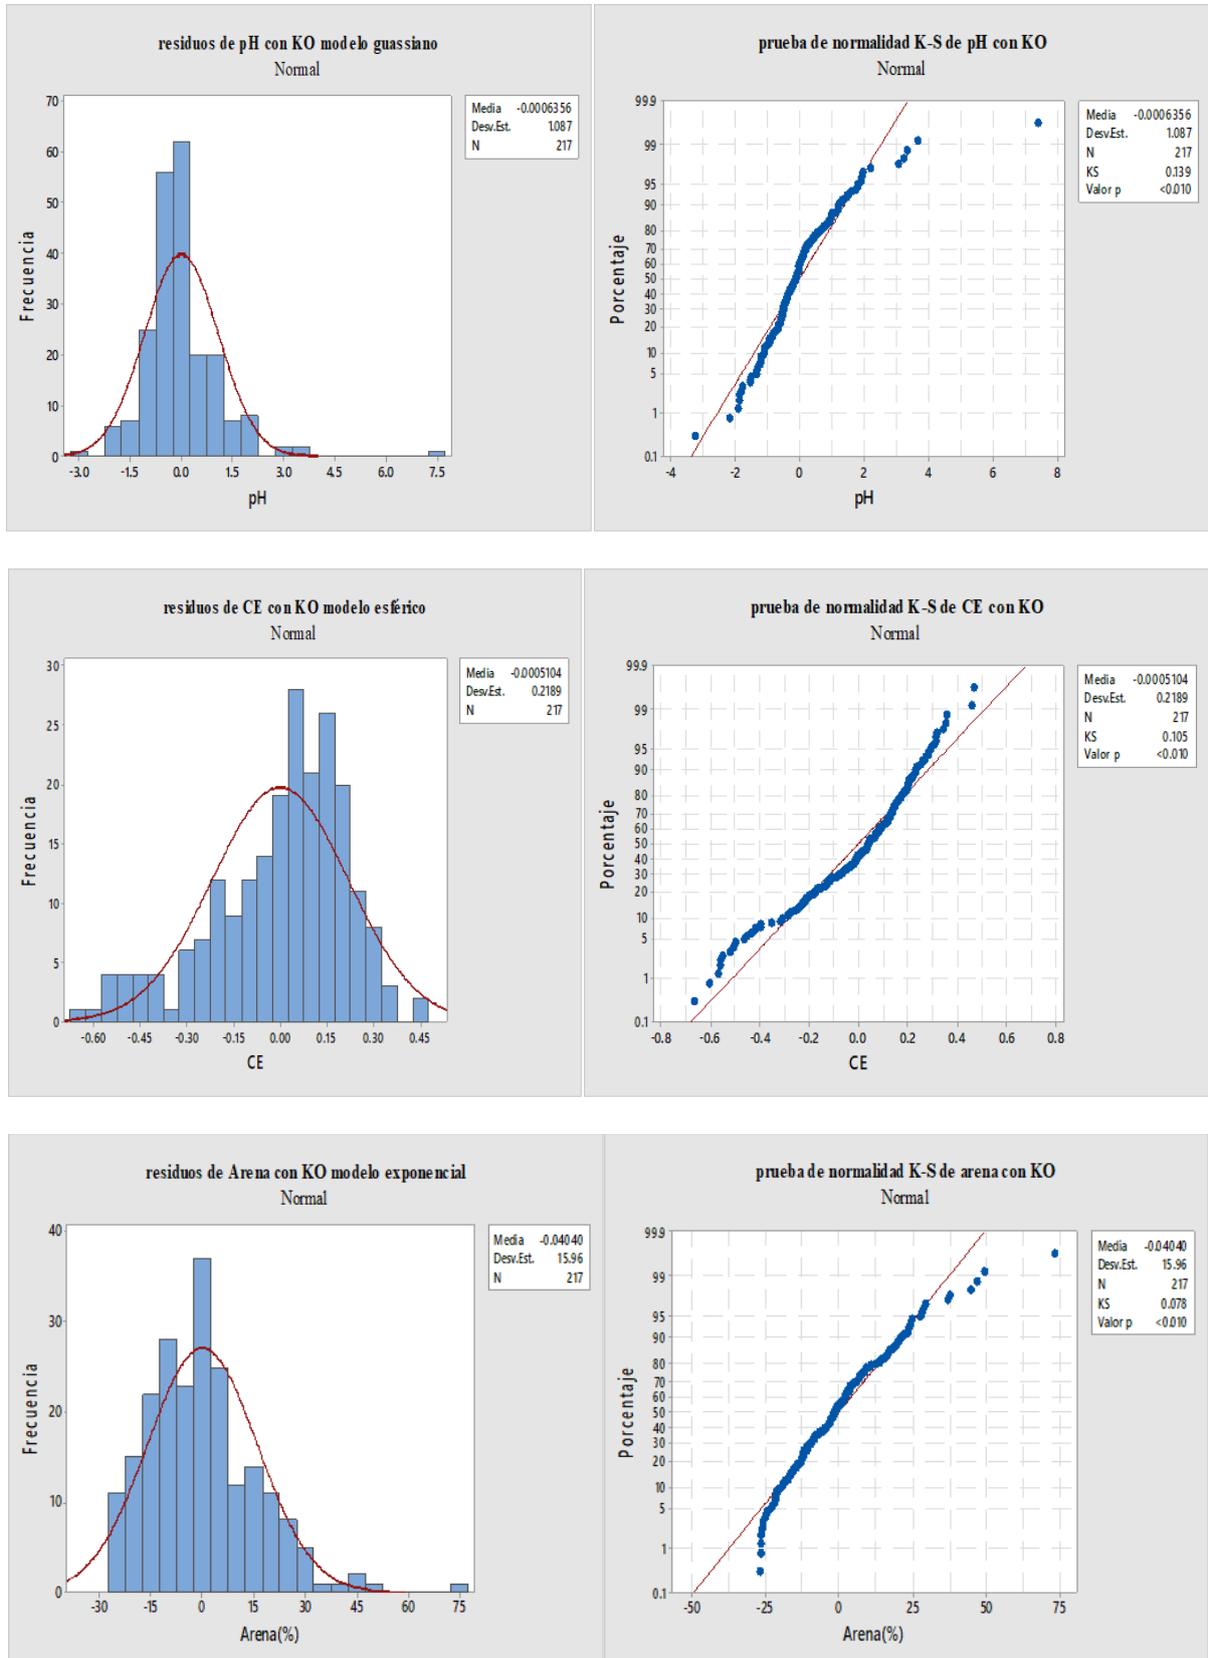
- Pan, H., Lu, X., & Lei, K. (2017). A comprehensive analysis of heavy metals in urban road dust of Xi'an, China: contamination, source apportionment and spatial distribution. *Science of the Total Environment*, *609*, 1361-1369.
- Piccini, C., Marchetti, A., & Francaviglia, R. (2014). Estimation of soil organic matter by geostatistical methods: Use of auxiliary information in agricultural and environmental assessment. *Ecological Indicators*, *36*, 301–314. doi:10.1016/j.ecolind.2013.08.009
- Pouladi, N., Møller, A. B., Tabatabai, S., & Greve, M. H. (2019). Mapping soil organic matter contents at field level with Cubist, Random Forest and kriging. *Geoderma*, *342*, 85–92. doi:10.1016/j.geoderma.2019.02.019
- Ran, J., Wang, D., Wang, C., Zhang, G., & Zhang, H. (2016). Heavy metal contents, distribution, and prediction in a regional soil–wheat system. *Science of the total environment*, *544*, 422-431.
- Sauve, S. W., & Henderson, a. H. (2000). Solid-Solution Partitioning of Metals in Contaminated Soils: Dependence on pH. Total Metal Burden, and Organic Matter, *Environ. Sci. Technol.*
- Sevilla, V., Valera, A., Rey, J. C., Vilorio, J & Comerma, J. (2013). Uso de la regresión kriging para elaborar mapas de propiedades de suelo en Venezuela. *XX congreso venezolano de la ciencia del suelo*. Universidad Central de Venezuela
- Shahriari, M., Delbari, M., Afrasiab, P., & Pahlavan-Rad, M. R. (2019). Predicting regional spatial distribution of soil texture in floodplains using remote sensing data: A case of southeastern Iran. *Catena*, *182*, 104149. doi:10.1016/j.catena.2019.104149
- Shokr, M. S., El Baroudy, A. A., Fullen, M. A., El-Beshbeshy, T. R., Ramadan, A. R., El Halim, A. A., ... & Jorge, M. C. (2016). Spatial distribution of heavy metals in the middle Nile delta of Egypt. *International Soil and Water Conservation Research*, *4*(4), 293-303.
- Terrazas Rueda, J. M. (2018). Efecto de tres niveles de salinidad en el crecimiento del pasto agropiro variedad Alkar (*Thinopyrum ponticum*) mediante reproducción sexual y vegetativa. *Apthapi*, *4*(3), 1295-1311.
- Tóth, G., Hermann, T., Szatmári, G., & Pásztor, L. (2016). Maps of heavy metals in the soils of the European Union and proposed priority areas for detailed assessment. *Science of The Total Environment*, *565*, 1054-1062.
- USDA, (1999). *Guía para la Evaluación de la Calidad y Salud del Suelo*, Departamento de Agricultura de los Estados Unidos de Norteamérica.

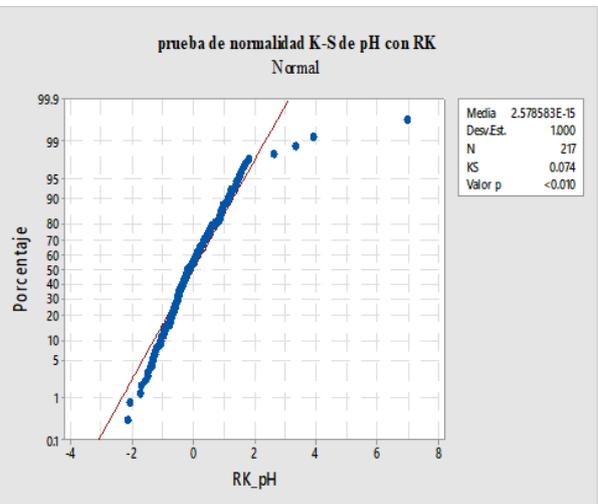
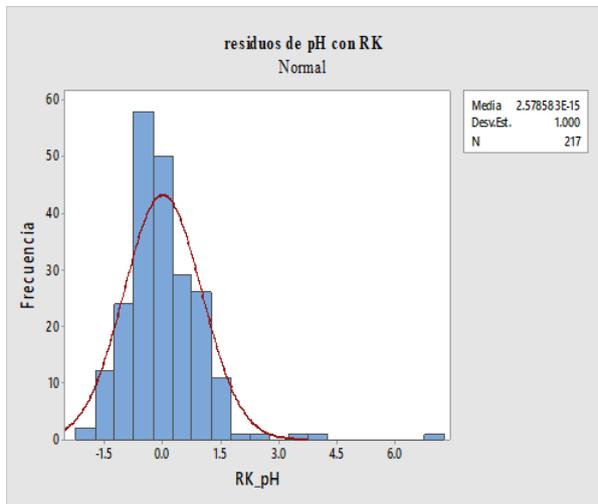
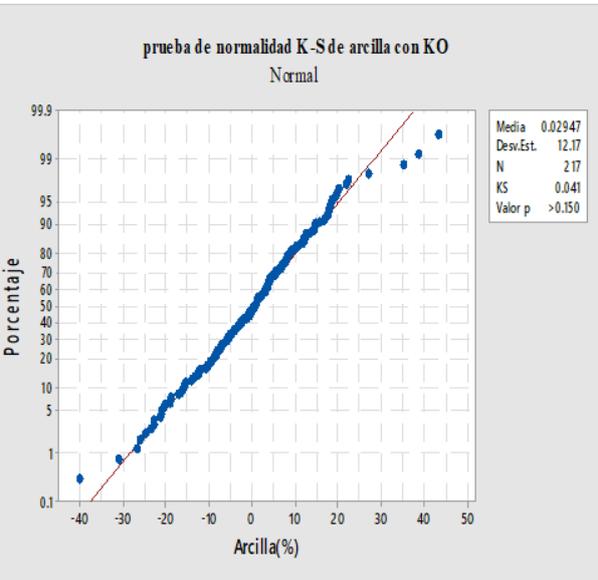
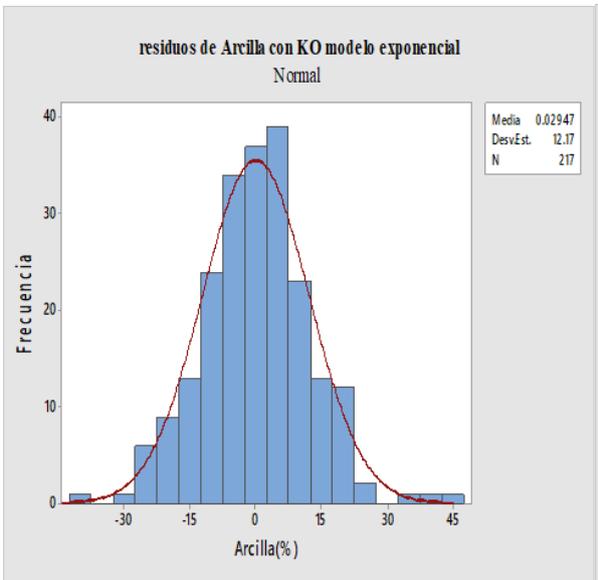
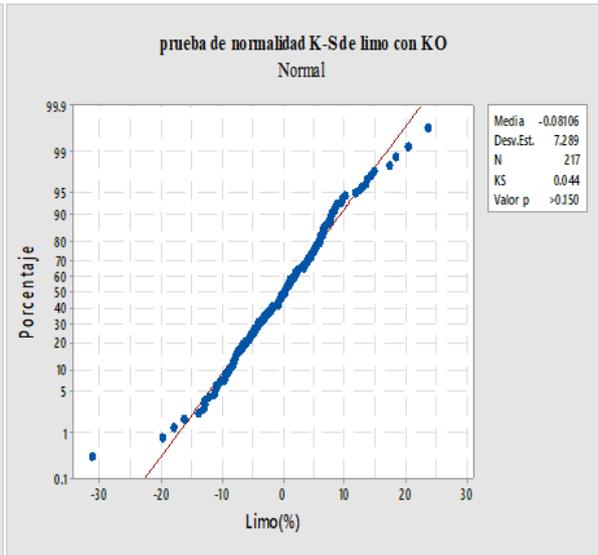
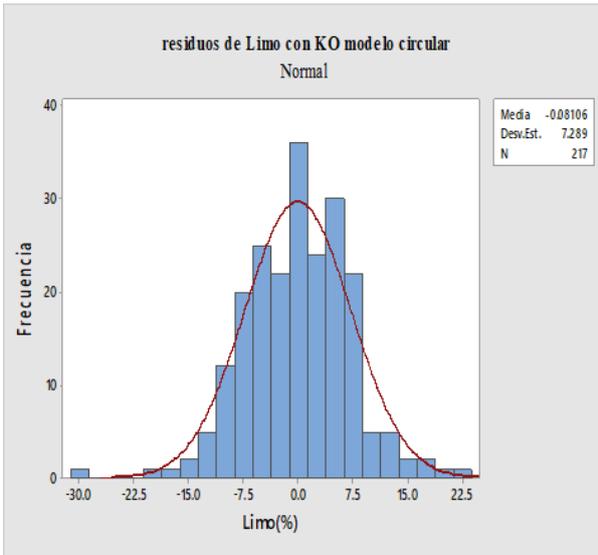
- Wang, Z., Hong, C., Xing, Y., Wang, K., Li, Y., Lihui Feng, L., et al. (2018). Spatial distribution and sources of heavy metals in natural pasture soil around copper-molybdenum mine in Northeast China. *Ecotoxicology and Environmental Safety*, 154 (2018), 329–336
- Webster, R., Oliver, M., (2007). *Geostatistics for Environmental Scientists*. John Wiley & Sons, New York.
- Wu, C., Huang, J., Zhu, H., Zhang, L., Minasny, B., Marchant, B. P., & McBratney, A. B. (2019). Spatial changes in soil chemical properties in an agricultural zone in southeastern China due to land consolidation. *Soil and Tillage Research*, 187, 152-160.
- Wuana, R.A., Okieimen, F.E., (2011). Heavy metals in contaminated soils: a review of sources, chemistry, risks and best available strategies for remediation. *International Scholarly Research Notices*, ISRN Ecology 1–20.
- Xiao, L., Guan, D., Peart, M. R., Chen, Y., Li, Q., & Dai, J. (2017). The influence of bioavailable heavy metals and microbial parameters of soil on the metal accumulation in rice grain. *Chemosphere*, 185, 868-878.
- Xie, E., Zhao, Y., Li, H., Shi, X., Lu, F., Zhang, X., & Peng, Y. (2019). Spatio-temporal changes of cropland soil pH in a rapidly industrializing region in the Yangtze River Delta of China, 1980–2015. *Agriculture, ecosystems & environment*, 272, 95-104.
- Yarasca, J.L. (2015). *Modelo sistémico para evaluar la recuperación de suelos contaminados por plomo en el distrito de concepción* (Tesis posgrado). Universidad nacional del Centro del Perú, Huancayo, Perú.
- Yigini, Y., Panagos, P., (2016). Assessment of soil organic carbon stocks under future climate and land cover changes in Europe. *Sci. Total Environ.* 557-558, 838–850
- Yong, L. I. U., Huifeng, W. A. N. G., Xiaoting, L. I., & Jinchang, L. I. (2015). Heavy metal contamination of agricultural soils in Taiyuan, China. *Pedosphere*, 25(6), 901-909.
- Zeng, C., Yang, L., Zhu, A.X., Rossiter, D.G., Liu, J., Liu, J., Qin, C., Wang, D., (2016). Mapping soil organic matter concentration at different scales using a mixed geographically weighted regression method. *Geoderma* 281, 69–82
- Zhang, S., Huang, Y., Shen, C., Ye, H., Du, Y., (2012). Spatial prediction of soil organic matter using terrain indices and categorical variables as auxiliary information. *Geoderma* 171–172, 35–43.

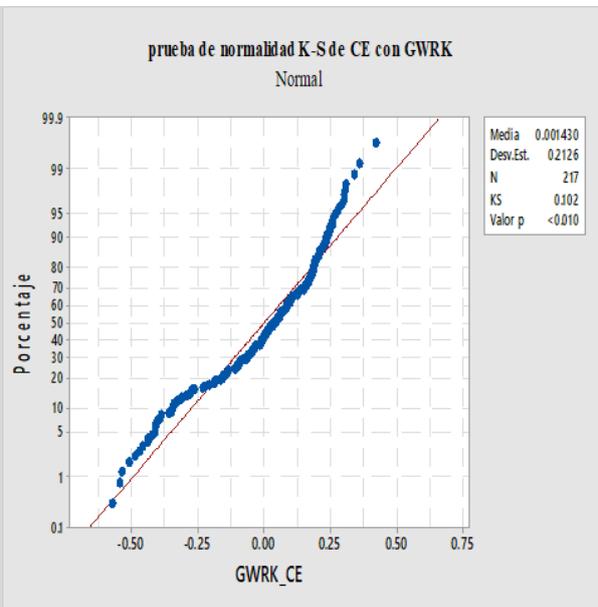
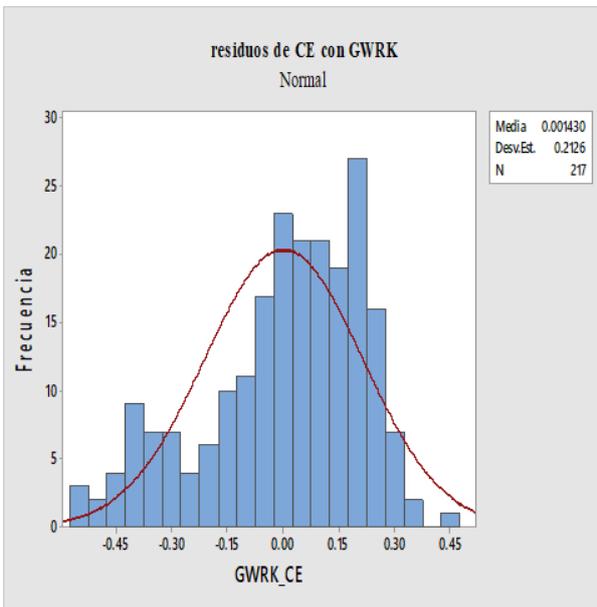
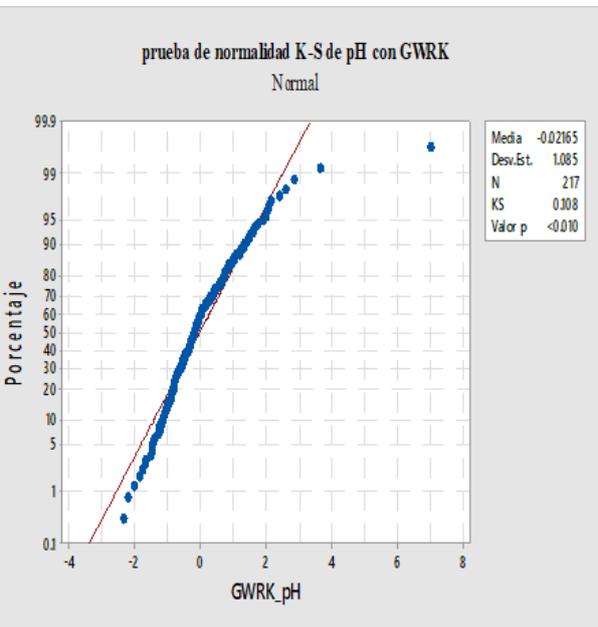
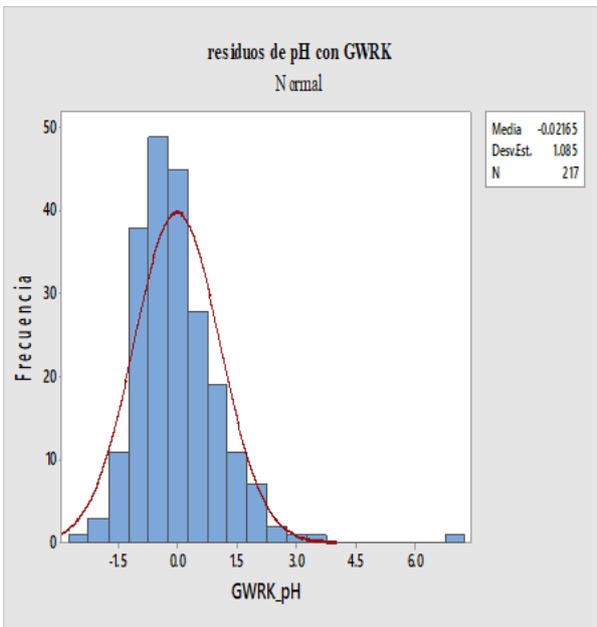
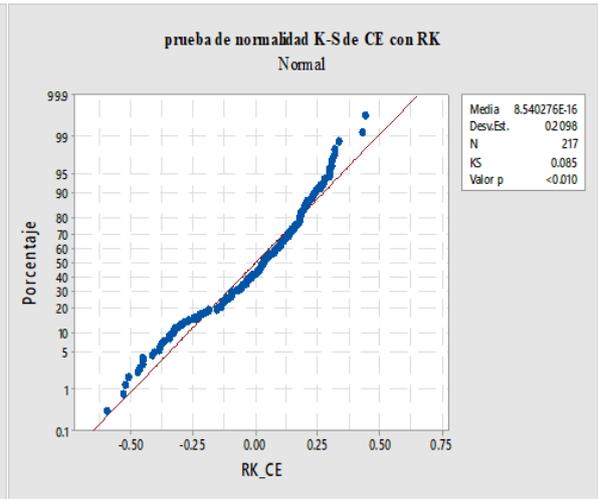
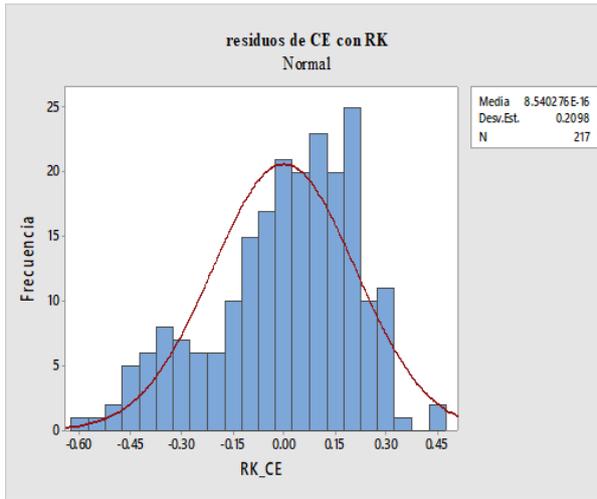
- Zhang, S., Shen, C., Chen, X., Ye, H., Huang, y., & Lai, S. (2013). Spatial Interpolation of Soil Texture Using Compositional Kriging and Regression Kriging with Consideration of the Characteristics of Compositional Data and Environment Variables. *Journal of Integrative Agriculture*, 12(9), 1673–1683. doi:10.1016/s2095-3119(13)60395-0
- Zhang, Y., Sui, B., Shen, H., & Wang, Z. (2018). Estimating temporal changes in soil pH in the black soil region of Northeast China using remote sensing. *Computers and Electronics in Agriculture*, 154, 204-212.
- Zhu, Q., De Vries, W., Liu, X., Zeng, M., Hao, T., Du, E., Zhang, F., Shen, J., (2016). The contribution of atmospheric deposition and forest harvesting to forest soil acidification in China since 1980. *Atmos. Environ.* 146, 215–222.
- Zhu, Q., Lin, H.S., (2010). Comparing ordinary kriging and regression kriging for soil properties in contrasting landscapes. *Pedosphere* 20, 594–606.

ANEXOS

Anexo 1. Pruebas de normalidad de los métodos KO, Rk y GWRK.







Anexo 2. Relaciones del pH con las variables cualitativas y cuantitativas en RK.

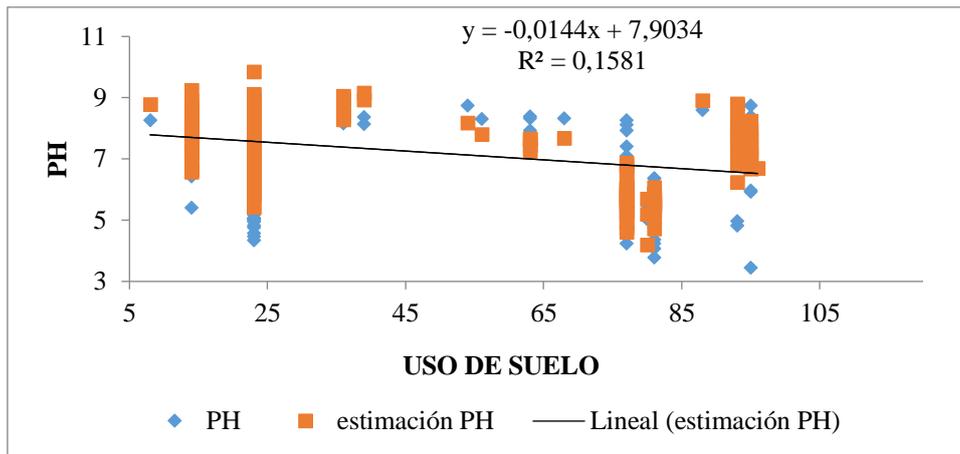


Figura 12. Curva de regresión ajustada de pH v.s usos de suelo

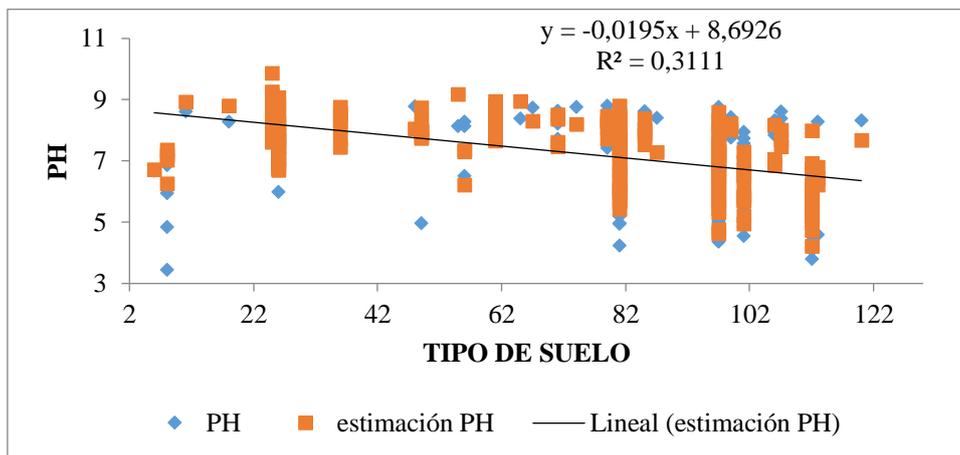


Figura 13. Curva de regresión ajustada de pH vs tipo de suelo

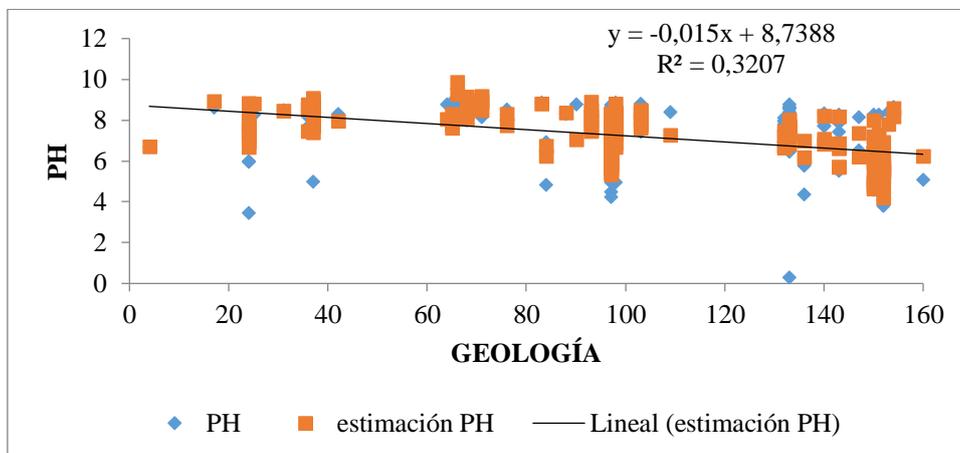


Figura 14. Curva de regresión ajustada pH v.s geología

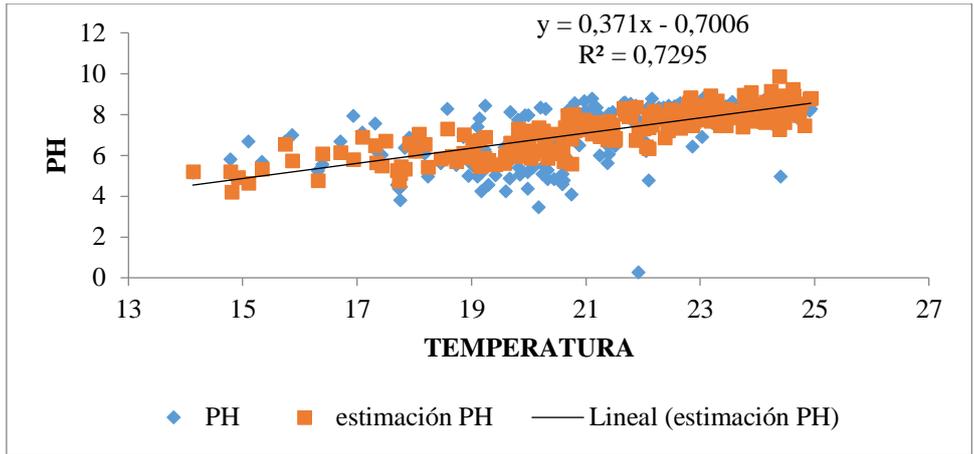


Figura 15. Curva de regresión ajustada de pH v.s Temperatura

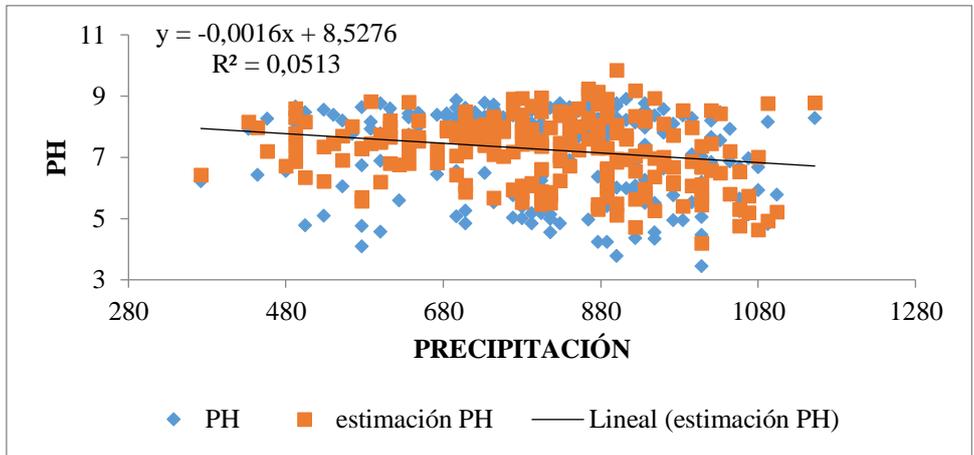


Figura 16. Curva de regresión ajustada de pH v.s precipitación

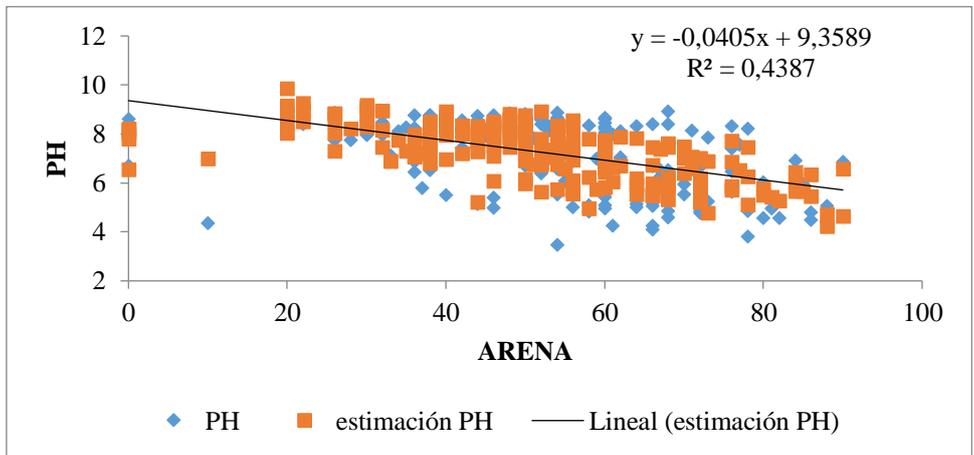


Figura 17. Curva de regresión ajustada de pH v.s arena

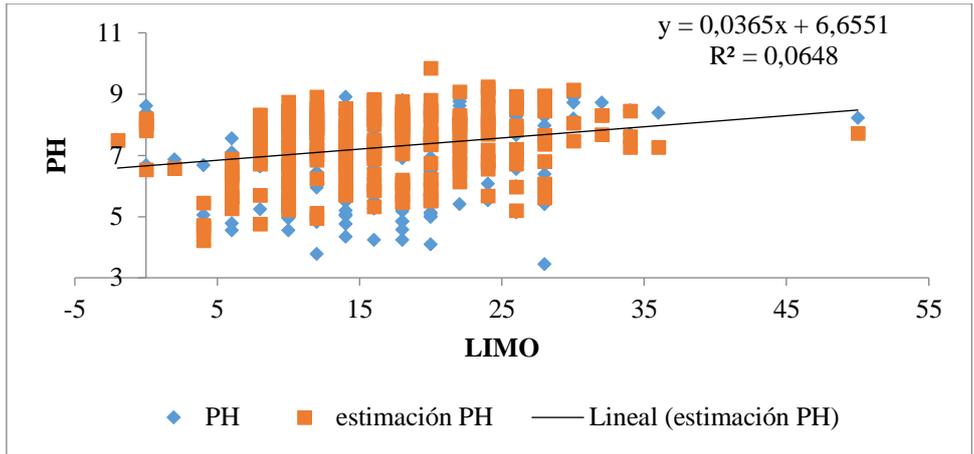


Figura 18. Curva de regresión ajustada de pH v.s limo

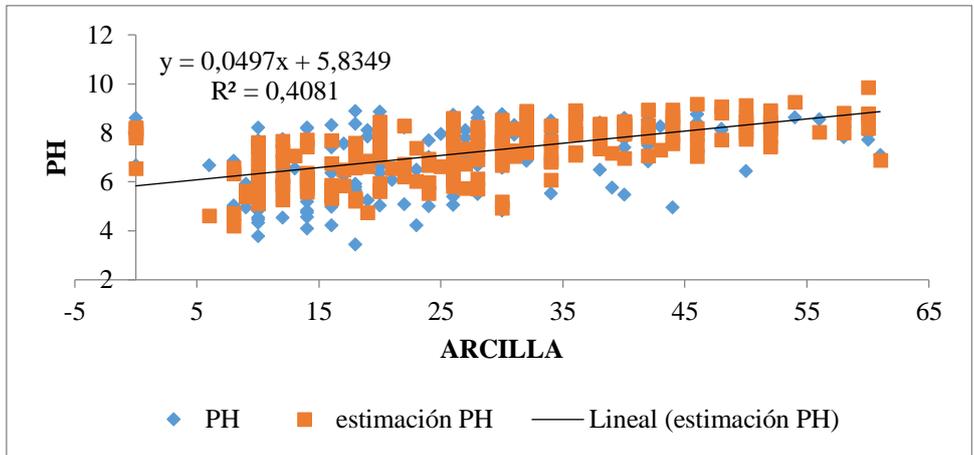


Figura 19. Curva de regresión ajustada de pH v.s arcilla

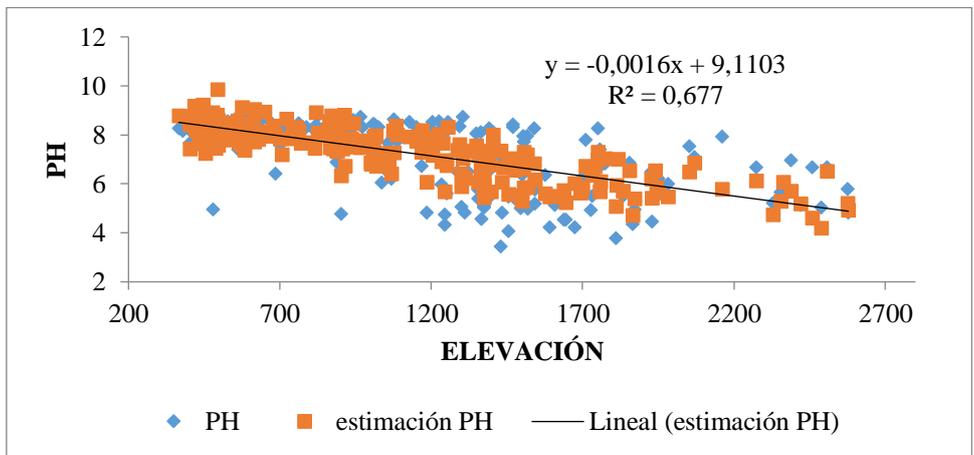


Figura 20. Curva de regresión ajustada de pH v.s elevación

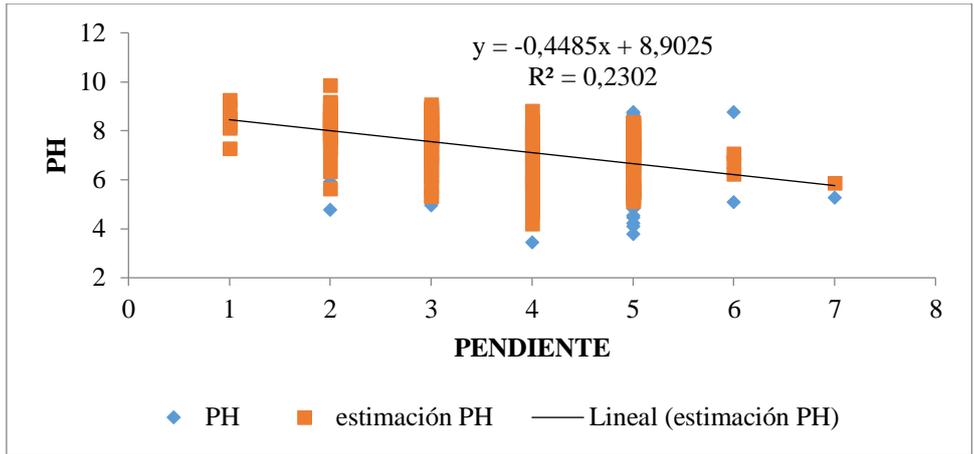


Figura 21. Curva de regresión ajustada de pH v.s pendiente

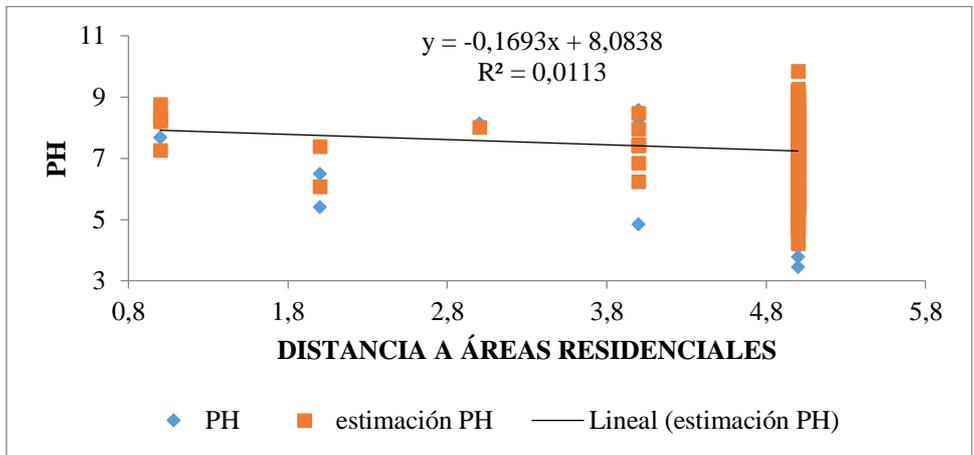


Figura 22. Curva de regresión ajustada de pH v.s distancia al área residencial

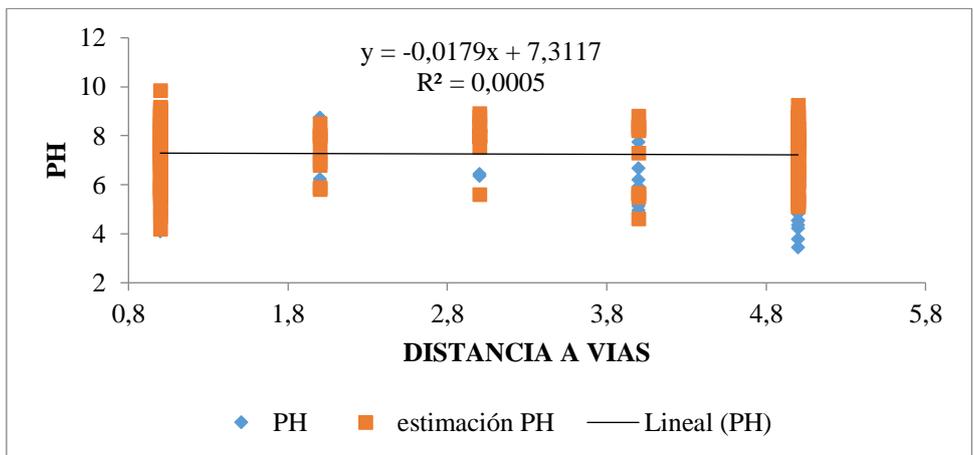


Figura 23. Curva de regresión ajustada de pH v.s distancia a vías

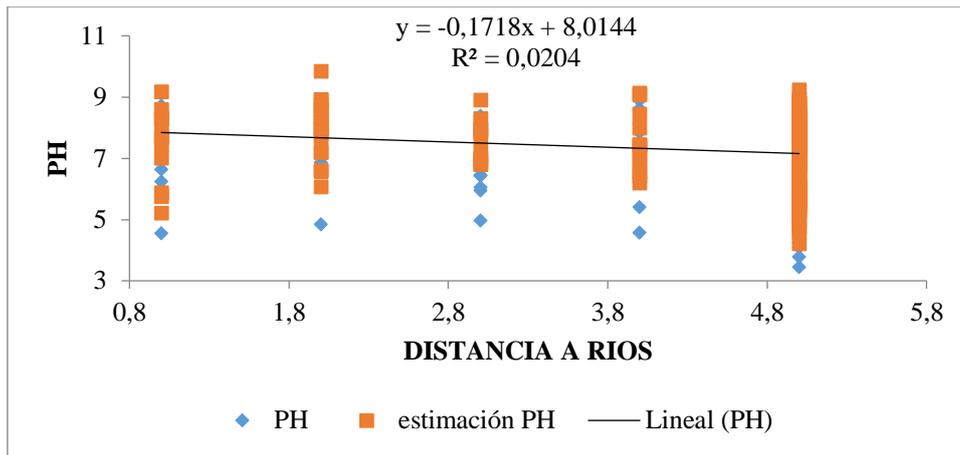


Figura 24. Curva de regresión ajustada de pH v.s distancia a ríos

Anexo 3. Relaciones de la C.E. con las variables cualitativas y cuantitativas en RK.

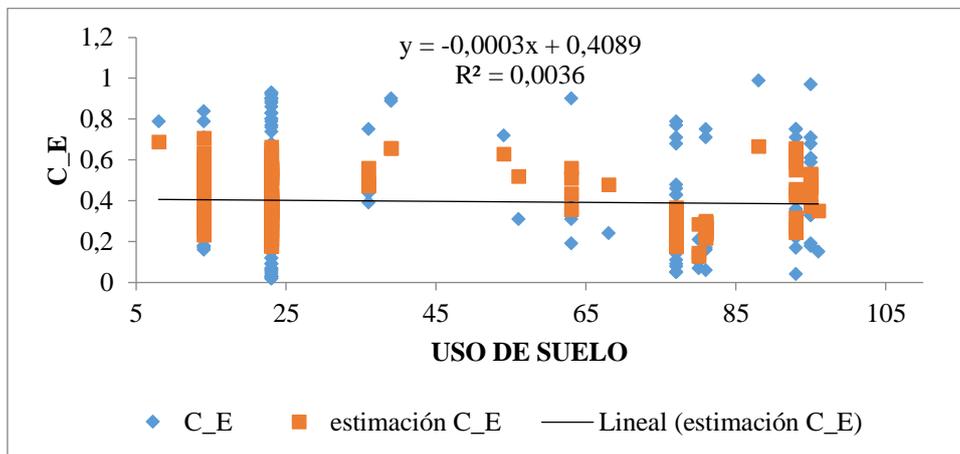


Figura 25. Curva de regresión ajustada de C.E v.s uso de suelos

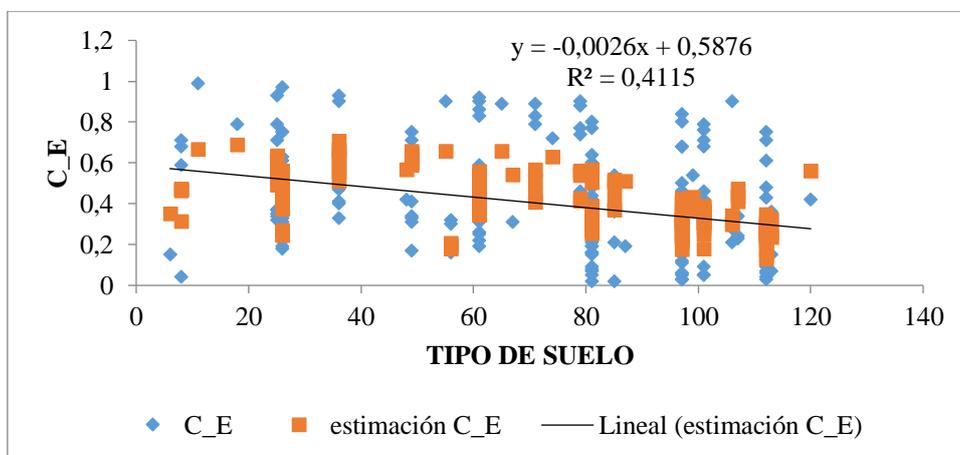


Figura 26. Curva de regresión ajustada de C.E v.s tipo de suelos

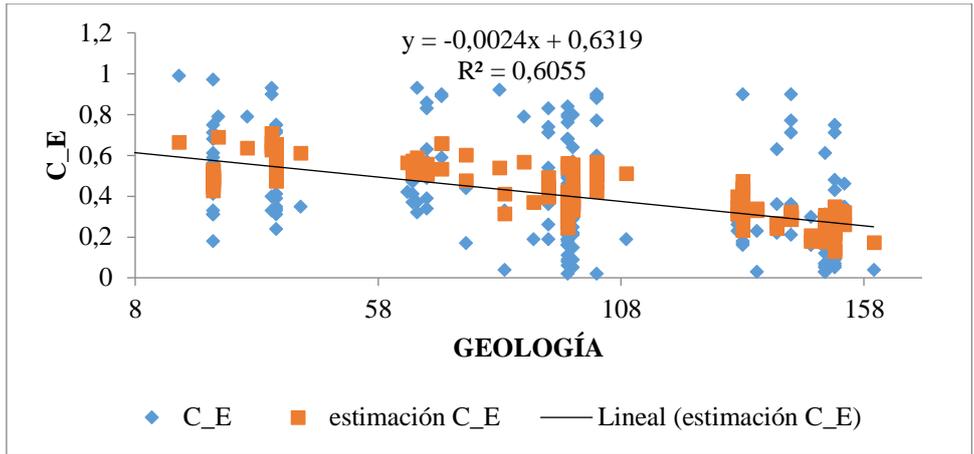


Figura 27. Curva de regresión ajustada de C.E v.s geología

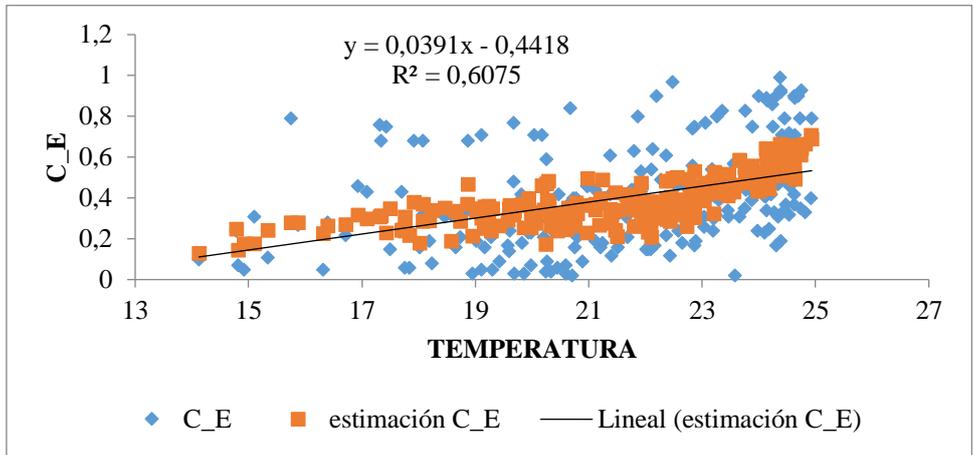


Figura 28. Curva de regresión ajustada de C.E v.s temperatura

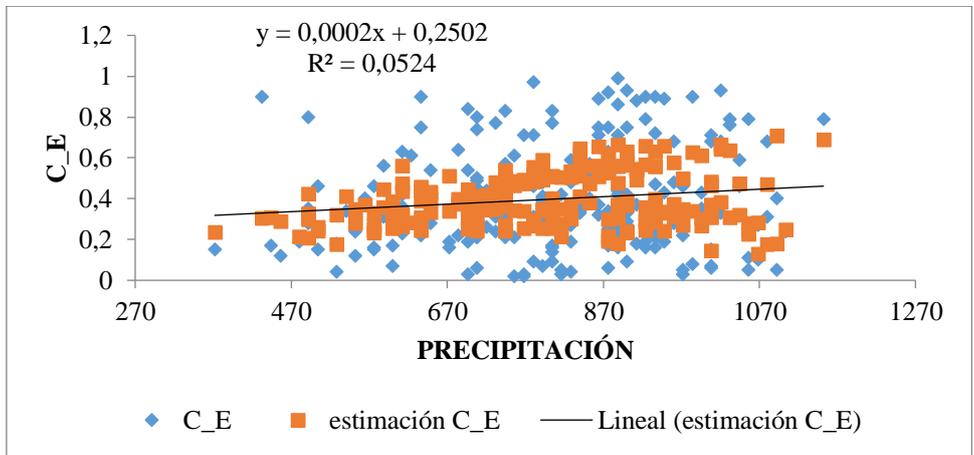


Figura 29. Curva de regresión ajustada de C.E v.s precipitación

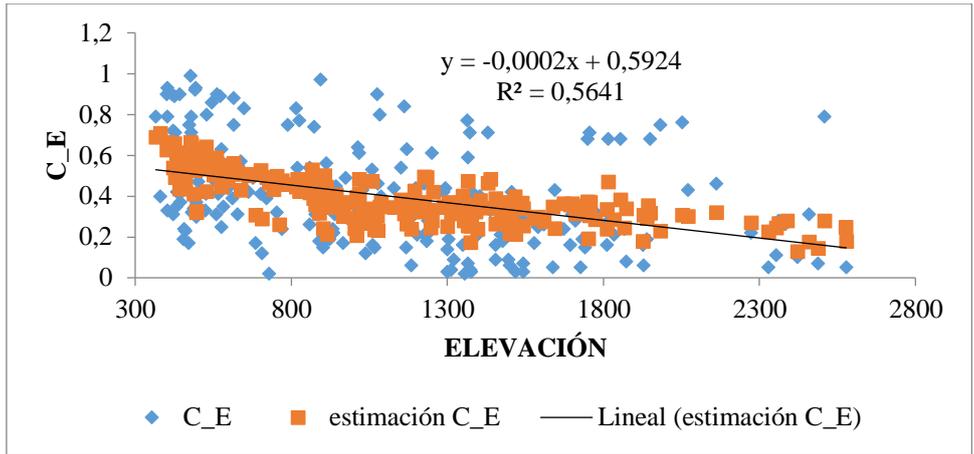


Figura 30. Curva de regresión ajustada de C.E v.s elevación

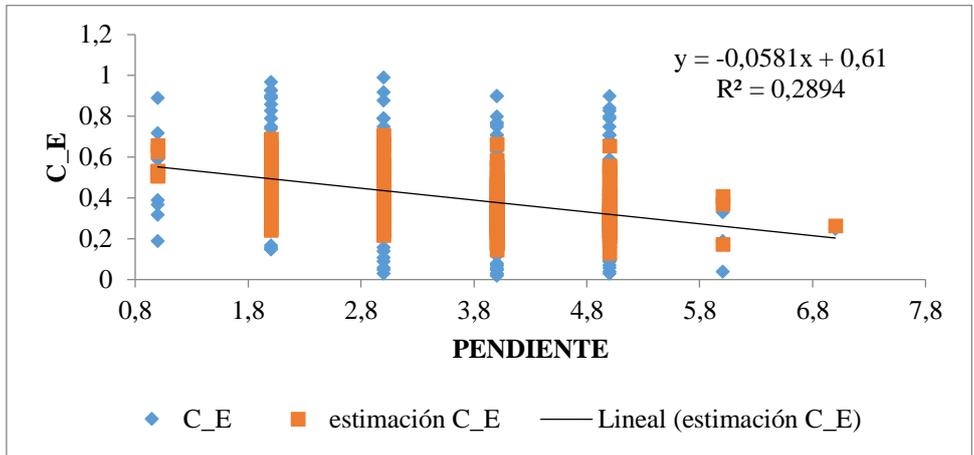


Figura 31. Curva de regresión ajustada de C.E v.s pendiente

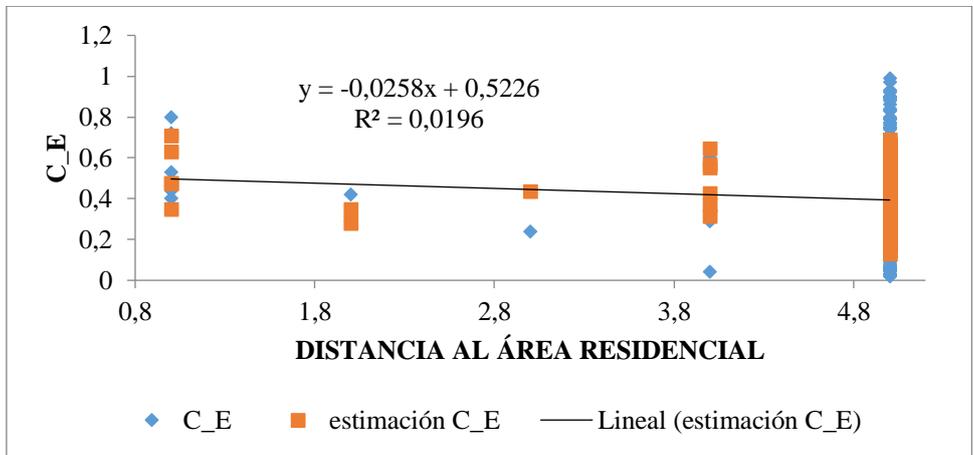


Figura 32. Curva de regresión ajustada de C.E v.s distancia al área residencial

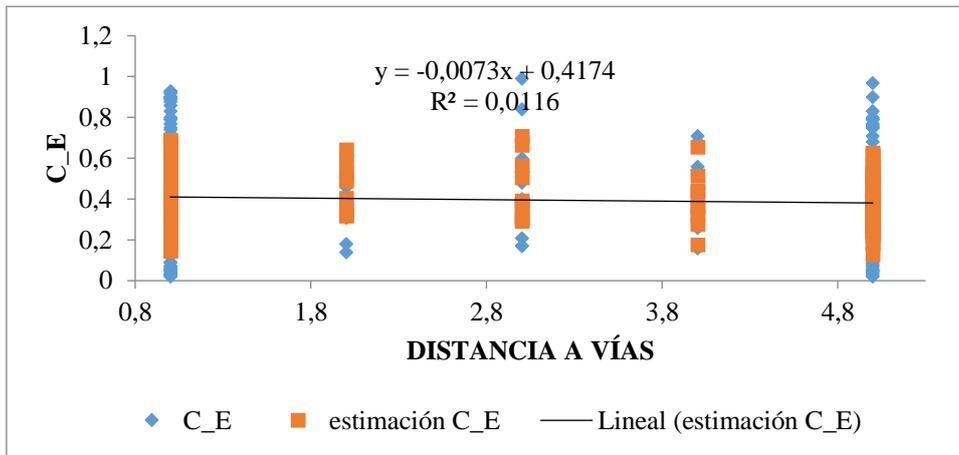


Figura 33. Curva de regresión ajustada de C.E v.s distancia a vías

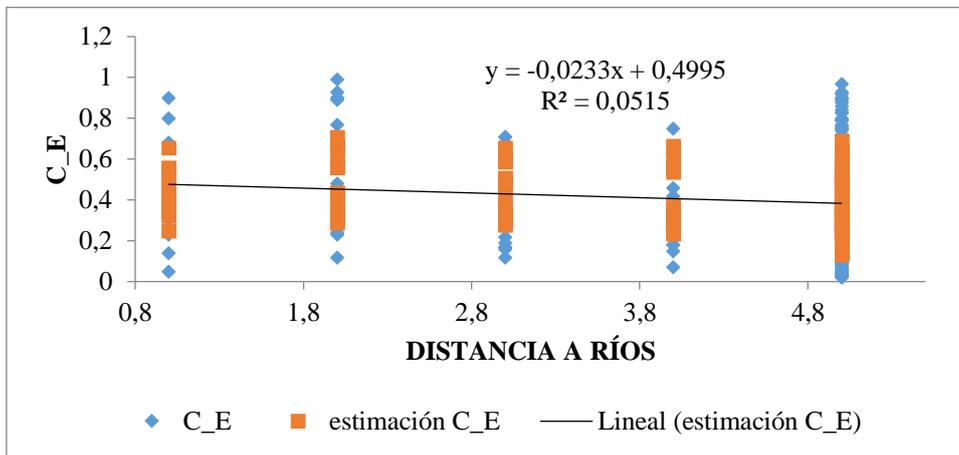


Figura 34. Curva de regresión ajustada de C.E v.s distancia a vías

Anexo 4. Variación espacial de cada variable con el método GWRK de pH

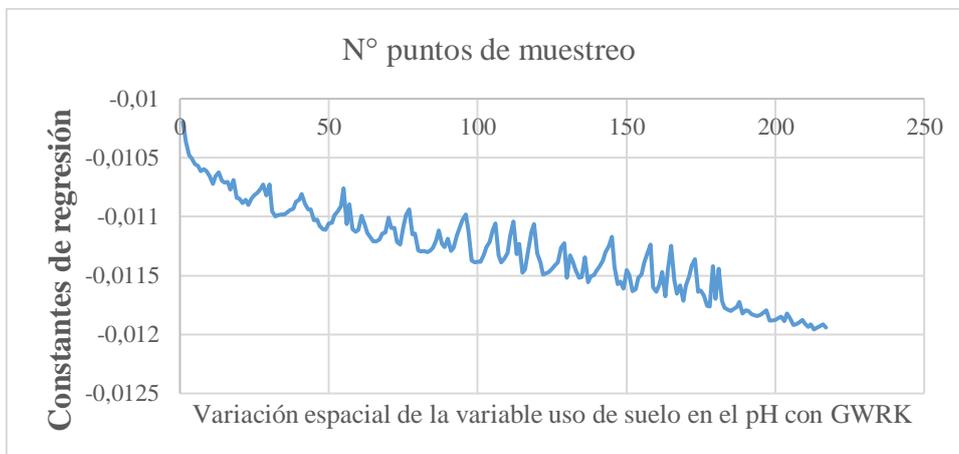


Figura 35. Constantes de regresiones de uso de suelo v.s puntos de muestreo

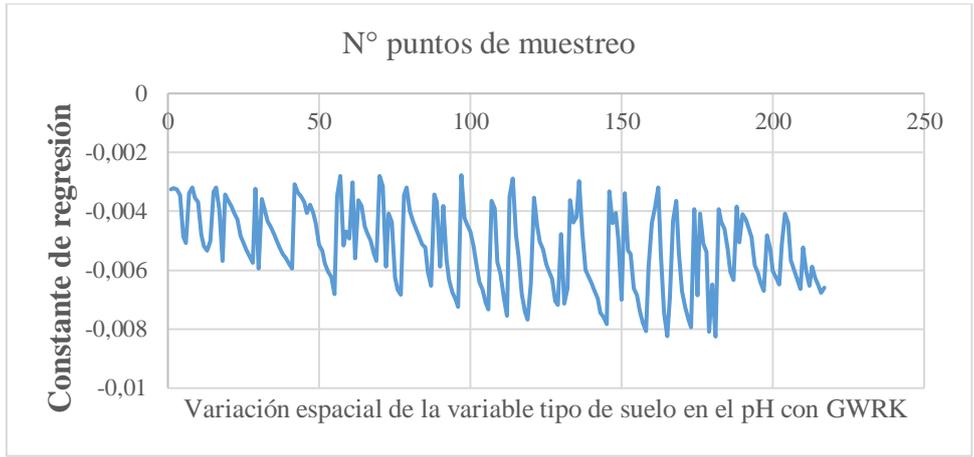


Figura 36. Constantes de regresiones de tipo de suelo v.s puntos de muestreo

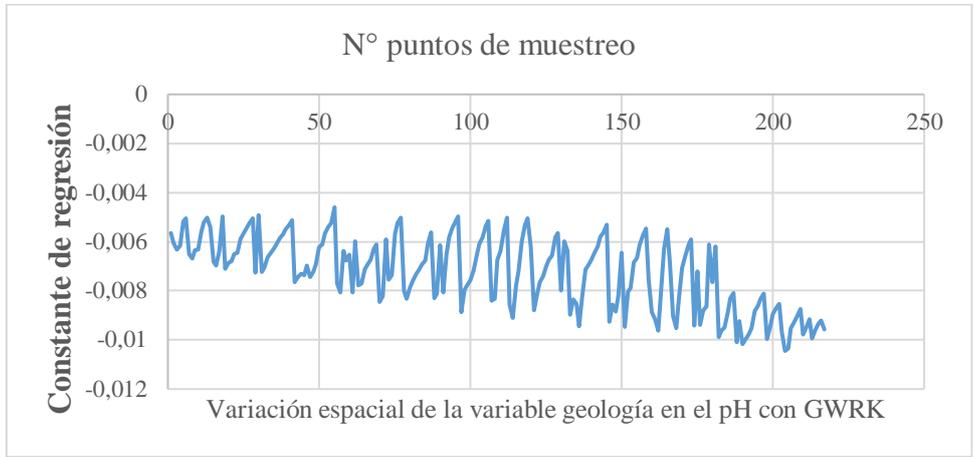


Figura 37. Constantes de regresiones de geología v.s puntos de muestreo

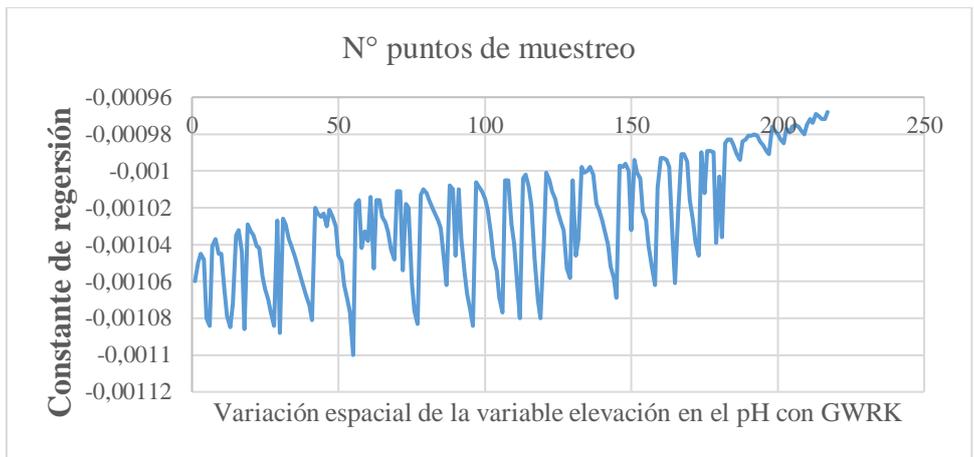


Figura 38. Constantes de regresiones de elevación v.s puntos de muestreo

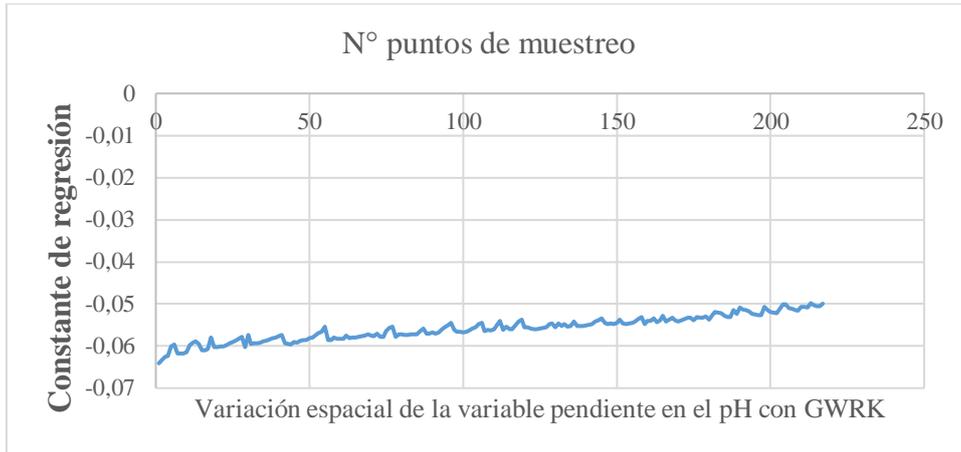


Figura 39. Constantes de regresiones de pendiente v.s puntos de muestreo

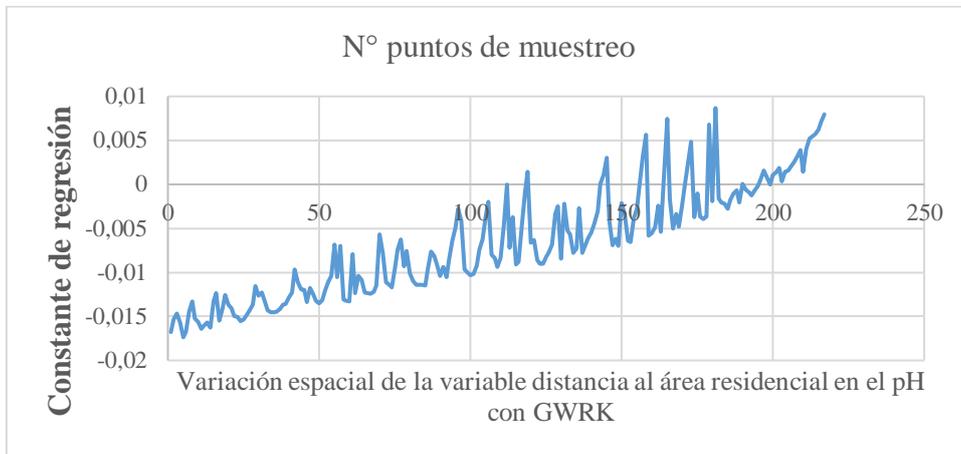


Figura 40. Constantes de regresiones del área residencial v.s puntos de muestreo

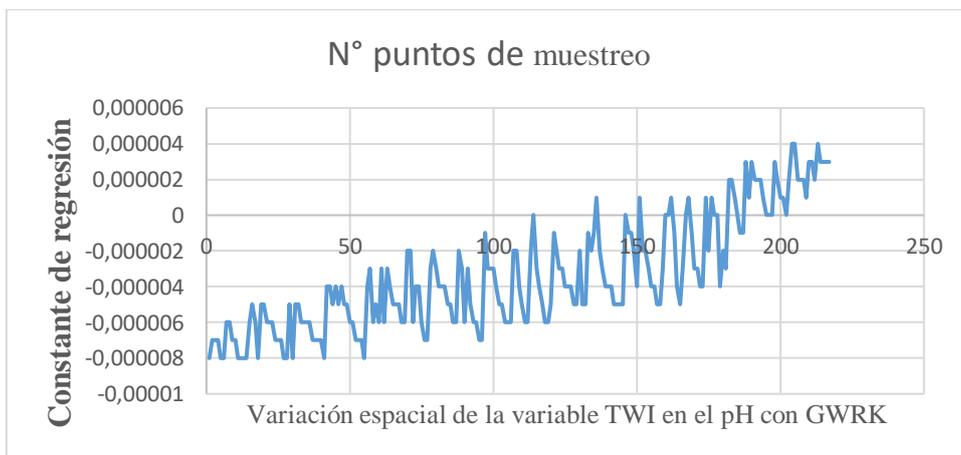


Figura 41. Constantes de regresiones de TWI v.s puntos de muestreo

Anexo 5. Variación espacial de cada variable con el método GWRK de C.E.

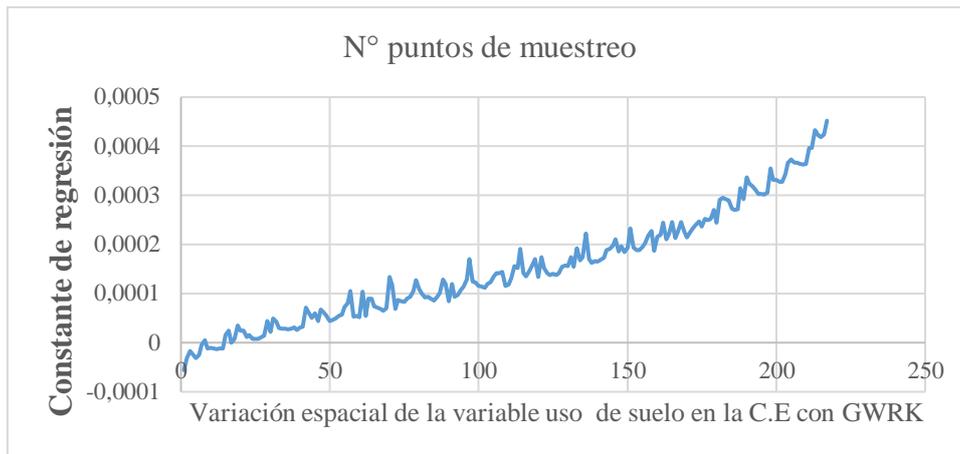


Figura 42. Constantes de regresiones de uso de suelo v.s puntos de muestreo

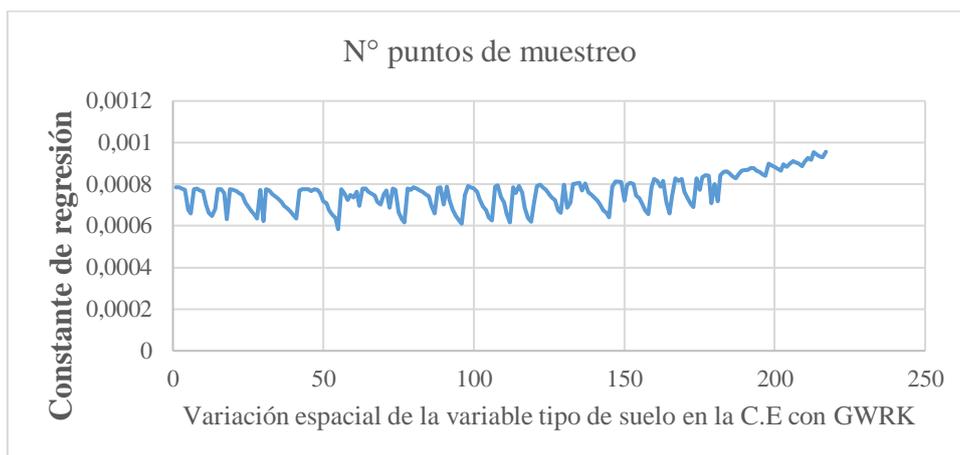


Figura 43. Constantes de regresiones de tipo de suelo v.s puntos de muestreo

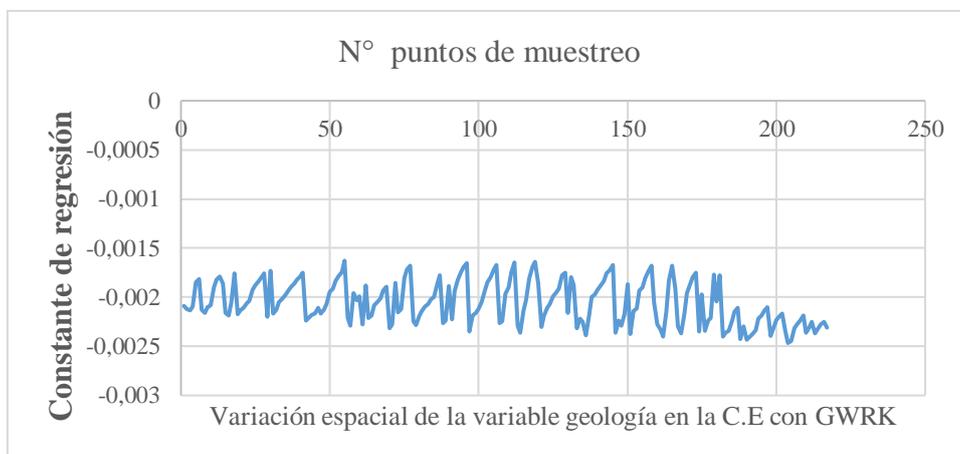


Figura 44. Constantes de regresiones de geología v.s puntos de muestreo

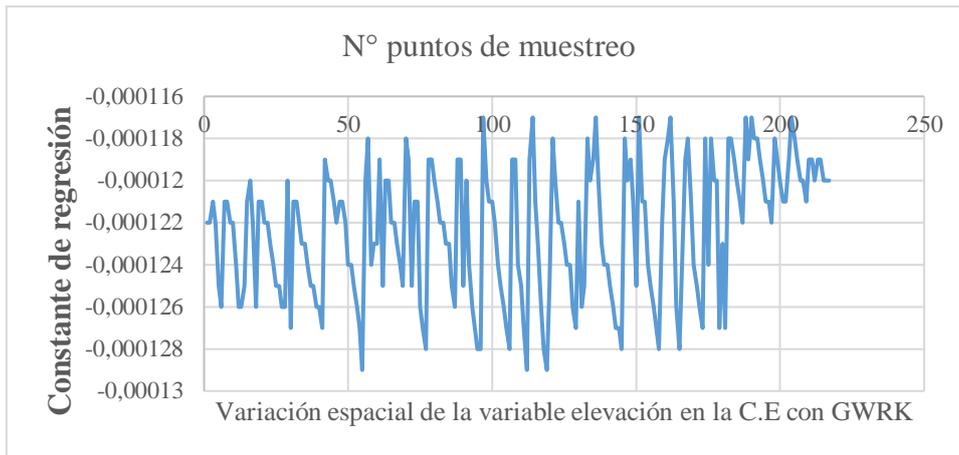


Figura 45. Constantes de regresiones de elevación v.s puntos de muestreo

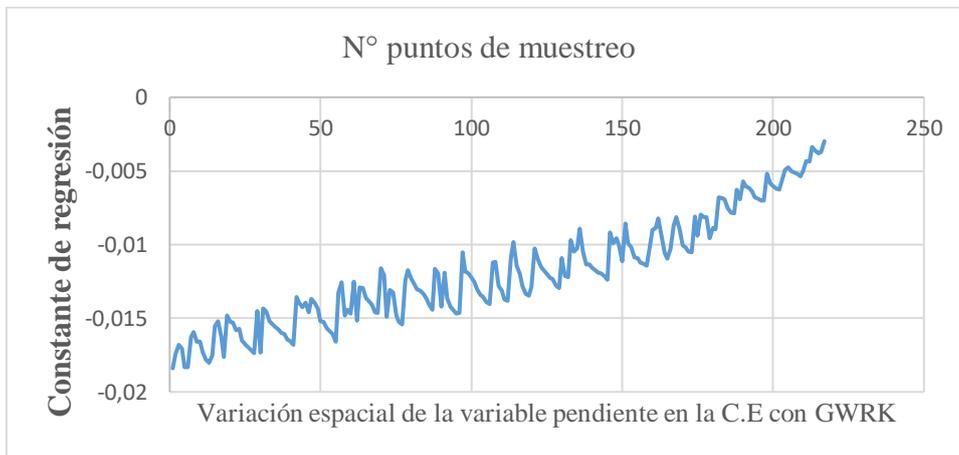


Figura 46. Constantes de regresiones de pendiente v.s puntos de muestreo

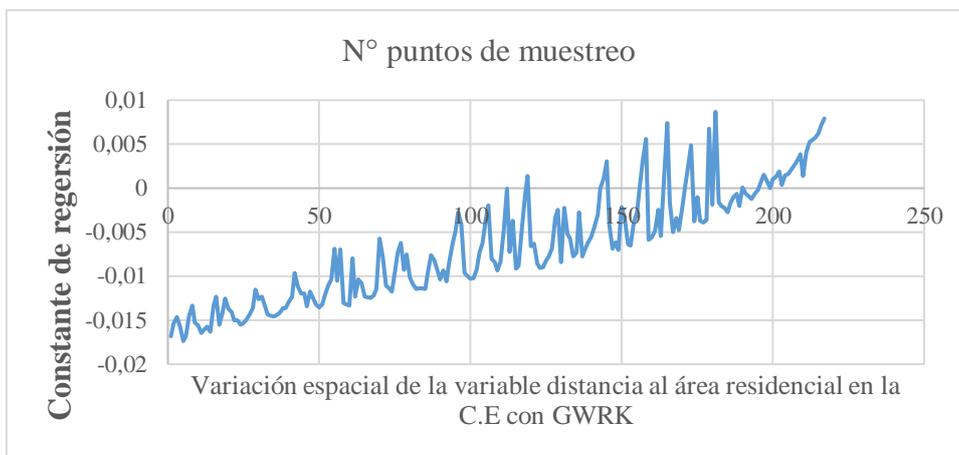


Figura 47. Constantes de regresiones del área residencial v.s puntos de muestreo

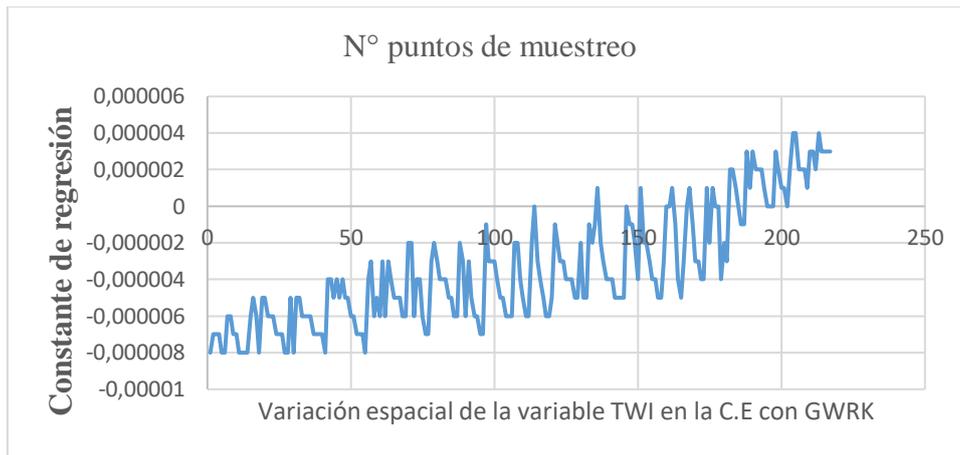


Figura 48. Constantes de regresiones de TWI v.s puntos de muestreo

Anexo 6. Diagramas del pH y clase textual del suelo.

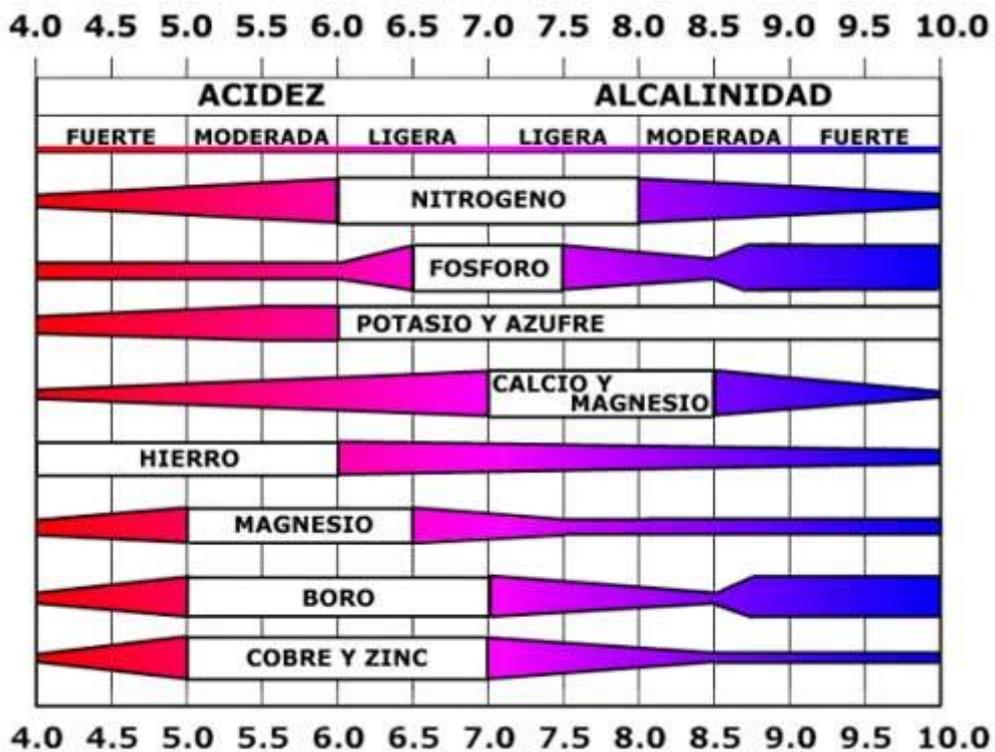


Figura 49. Diagrama Trough de pH de suelos

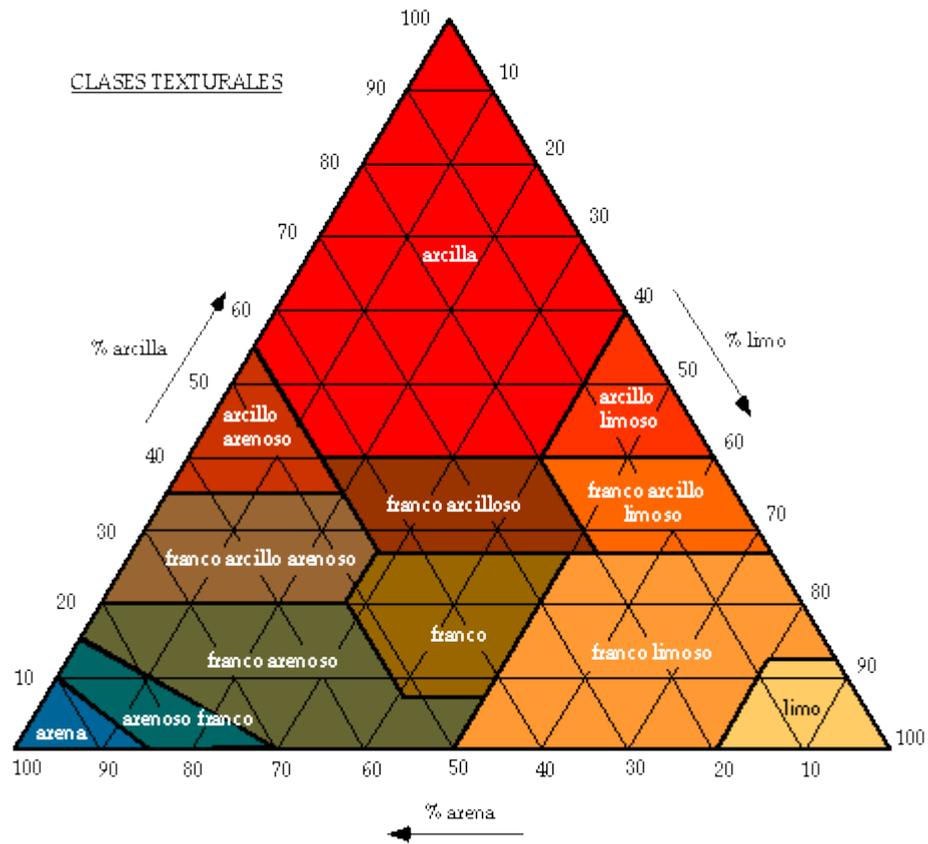
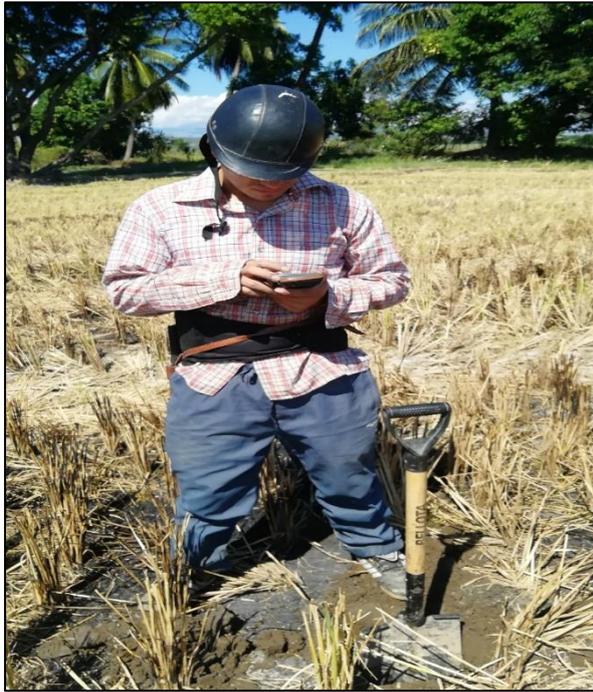


Figura 50. Triángulo de la clase textural del suelo (USDA, 1999)

Anexo 7. Panel fotográfico.



Fotografía 1 y 2. Recolección de muestras de suelo.



Fotografía 3. Ubicación del punto a muestrear.