



INSTITUTO POLITÉCNICO NACIONAL



**CENTRO INTERDISCIPLINARIO DE INVESTIGACIÓN PARA EL
DESARROLLO INTEGRAL REGIONAL**

CIIDIR-MICHOACAN

**MODELADO DE LA SALINIDAD DEL SUELO EN
LOS NEGRITOS VILLAMAR, MICHOACÁN**

**T E S I S
QUE PARA OBTENER EL GRADO DE:**

**“MAESTRO EN CIENCIAS EN PRODUCCIÓN AGRÍCOLA
SUSTENTABLE”**

P R E S E N T A:

ANAYA FLORES RAQUEL


DIRECTORES DE TESIS:

DR. GUSTAVO CRUZ CÁRDENAS

DR. JOSÉ TEODORO SILVA GARCÍA

SEPTIEMBRE 2015

JIQUILPAN, MICH.



INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO
 ACTA DE REVISIÓN DE TESIS

SIP-14-BIS

En la Ciudad de Jiquilpan, Michoacán siendo las 12:00 horas del día 5 del mes de Noviembre del 2015 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación de CIIDIR Unidad Michoacán para examinar la tesis titulada:

“Modelado de la salinidad del suelo en los negritos Villamar, Michoacán”.

Presentada por el alumno:

Anaya

Flores

Raquel

Apellido paterno

Apellido materno

Nombre

Con registro:

B	1	3	1	0	1	7
---	---	---	---	---	---	---

aspirante de:

Maestría en Ciencias en Producción Agrícola Sustentable

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA
Directores de tesis

MS.

Dr. Gustavo Cruz Cárdenas

JTG

Dr. José Teodoro Silva García

SOE

M. en C. Salvador Ochoa Estrada

DA

Dra. Diosclina Álvarez Bernal

LFC

Dr. Luis Fernando Ceja Torres

HGM

Dr. Hortencia Gabriela Mena Violante
 PRESIDENTE DEL COLEGIO DE PROFESORES



SECRETARÍA DE EDUCACIÓN PÚBLICA
 Instituto Politécnico Nacional
 CENTRO INTERDISCIPLINARIO DE INVESTIGACIÓN PARA EL DESARROLLO INTEGRAL REGIONAL
 CIIDIR - IPN - U- MICH.



INSTITUTO POLITÉCNICO NACIONAL

SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESIÓN DE DERECHOS

En la Ciudad de Jiquilpan de Juárez, Michoacán, el día 23 del mes de noviembre del año 2015, el (la) que suscribe Anaya Flores Raquel alumno(a) del Programa de Maestría en Ciencias en Producción Agrícola Sustentable, con número de registro B131017, adscrito(a) al CIIDIR IPN - MICHOACÁN, manifiesto(a) que es el (la) autor(a) intelectual del presente trabajo de Tesis bajo la dirección del (de la, de los) Dr. Gustavo Cruz Cárdenas y Dr. José Teodoro Silva García y cede los derechos del trabajo titulado Modelado de la salinidad del Suelo en Los Negritos Villamar, Michoacán, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del (de la) autor(a) y/o director(es) del trabajo. Este puede ser obtenido escribiendo a las siguientes direcciones flores_0910@hotmail.com; gustavocruzcardenas@hotmail.com; tsilva09@hotmail.com. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.



Raquel Anaya Flores

Nombre y firma del alumno(a)

A G R A D E C I M I E N T O S

Al **Consejo Nacional de Ciencia y Tecnología** (Conacyt) por el apoyo económico para la realización de mis estudios.

Al **Instituto Politécnico Nacional** (IPN) por la oportunidad de superación académica y personal.

Al **CIIDIR-IPN-MICHOACÁN** por la oportunidad de realizar mis estudios y el apoyo brindado, así como el orgullo de ser parte de este centro.

A mis directores de tesis al Dr. Gustavo Cruz Cárdenas y Dr. José Teodoro Silva García por su asesoramiento, disponibilidad, dedicación y apoyo constante durante la realización de este presente trabajo.

A la Dra. Dioselina Álvarez Bernal, M. C. Salvador Ochoa Estrada y Dr. Luis Fernando Ceja Torres por sus consejos, orientación y acertadas sugerencias en la realización de esta investigación. Así como también su disposición de su tiempo para la revisión de la tesis.

DEDICATORIA

Con mucho cariño a mis padres:

José Francisco Anaya Magallón

y

Raquel Flores Magallón

Que me dieron la vida y la enseñanza del amor, la honestidad, respeto en el transcurso de mi vida, además también agradezco por brindarme herramientas que gracias a ellas estoy hasta esta etapa. Gracias por creer en mí, aun con mis errores y a pesar de cada obstáculo de la vida, siempre me apoyaron y motivaron para seguir adelante, dándome su amor incondicional. Por eso agradezco a Dios principalmente por permitir que estén a mi lado.

A mi hermana Yareni Anaya Flores y a mí primo Jesús Magallón Alcázar, por ofrecerme su apoyo y paciencia, por estar conmigo siempre trabajando hasta altas horas de la noche.

A Víctor Manuel Sánchez Ceja por su amistad y aprendizaje que me sirvió mucho a lo largo de este trayecto.

A Dios por darme salud y vida para terminar este ciclo y por cada persona que puso en este trascurso.

ÍNDICE

Contenido

ÍNDICE DE FIGURAS	III
ÍNDICE DE CUADROS	IV
RESUMEN.....	VI
ABSTRACT	VII
1. INTRODUCCIÓN.....	1
2. JUSTIFICACIÓN.....	4
3. OBJETIVOS.....	4
4. HIPÓTESIS	4
5. REVISIÓN BIBLIOGRÁFICA.....	5
5.1 El origen de las sales del suelo.....	5
5.2 Estado en que se encuentran las sales en el suelo.....	6
5.3 Efecto de las sales en el suelo y la planta.....	6
5.4 Variabilidad espacio- temporal de las sales.....	7
5.5 Cartografía de salinidad de suelos	8
5.6 Geoestadística.....	10
6. MATERIALES Y MÉTODOS.....	17
6.1 Área de estudio.....	17
6.2 Metodología.....	18
6.3 Análisis estadístico	19
7. RESULTADOS	21
7.1 Análisis de laboratorio.....	21

7.2 Análisis multivariado.....	24
7.3 Análisis clúster	26
7.4 Modelos Generalizados y efectos mixtos	27
7.5 Geoestadística: análisis exploratorio y estructural	27
8. DISCUSIÓN.....	34
9. CONCLUSIONES.....	38
Bibliografía.....	40
ANEXOS	53
ANEXO FOTOGRÁFICO	58

ÍNDICE DE FIGURAS

Figura 1.	Parámetros del semivariograma.....	13
Figura 2.	Modelos teóricos.....	14
Figura 3.	Área de estudio “Los Negritos, Villamar”.....	18
Figura 4.	Conductividad Eléctrica en cuatro periodos a profundidad de 0-30 cm.....	21
Figura 5.	Conductividad Eléctrica en cuatro periodos a profundidad de 30-60 cm.....	22
Figura 6.	Comparación de pH a dos profundidades (0-30 cm y 30-60 cm).....	23
Figura 7.	Comparación del % de materia orgánica a dos profundidades (0-30 cm y 30-60 cm).....	23
Figura 8.	Porcentaje de textura a dos profundidades (0-30 cm y 30-60 cm).....	23
Figura 9.	Agrupación jerárquica. Los números en el eje X representan el número de sitio de muestreo.....	26
	9.1. Mapas de la agrupación jerárquica.	26
Figura 10.	Graficas de dispersión de los cuatro periodos a la profundidad de 0-30 cm con su coeficiente de determinación (R^2).....	29
Figura 11.	Graficas de dispersión de los cuatro periodos a la profundidad de 30-60cm con su coeficiente de determinación (R^2).....	30
Figura 12.	Conductividad eléctrica del suelo a profundidad 0-30 cm de cuatro 4 periodos de muestreo.....	31
Figura 13.	Conductividad eléctrica del suelo a profundidad 30-60 cm de cuatro 4 periodos de muestreo.	32

ÍNDICE DE CUADROS

Cuadro 1.	Análisis de componentes principales de las variables del suelo a la profundidad de 0-30 cm del primer muestreo.....	24
Cuadro 2.	Análisis de componentes principales de las variables del suelo a la profundidad de 30-60 cm del primer muestreo	25
Cuadro 3.	Grupos del análisis clúster con la media de la CE a dos profundidades (0-30 y 30-60 cm) del primer muestreo.....	26
Cuadro 4.	Comparación entre R^2 del modelos Lineal generalizado (MGL) y modelo de Efecto Mixto (MEM) de las variables del suelo. Izquierda profundidad de 0-30 cm y derecha profundidad de 30-60 cm de los cuatro periodos de muestreo (M1, M2, M3 y M4).....	27
Cuadro 5.	Análisis de los modelos teóricos de las variables del suelo a la profundidad de 0-30 cm de los cuatro periodos de muestreo (M1, M2, M3 y M4).....	28
Cuadro 6.	Análisis de los modelos teóricos de las variables del suelo a la profundidad de 30-60 cm de los cuatro periodos de muestreo (M1, M2, M3 y M4).....	28
Cuadro 7.	Modelos Lineales generalizados (MGL) de las variables del suelo (0-30 cm) del primer muestreo	52
Cuadro 8.	Modelos Lineales generalizados (MGL) de las variables del suelo (30-60 cm) del primer muestreo	53
Cuadro 9.	Análisis exploratorio de las variables del suelo (0-30) del primer muestreo.....	53
Cuadro 10.	Análisis exploratorio de las variables del suelo (30-60) del primer muestreo.....	54
Cuadro 11.	Análisis Estructural de las variables del suelo (0-30) del primer muestreo.....	54
	• 11.1. Modelos Teóricos ajustados a los semivariogramas expuestos de las variables del suelo (0-30).....	55

Cuadro 12.	Análisis Estructural de las variables del suelo (30-60) del primer muestreo	54
	• 12.1. Modelos Teóricos ajustados a los semivariogramas expuestos de las variables del suelo (30-60).....	55

RESUMEN

La salinidad de los suelos es la concentración de sales con una conductividad eléctrica igual o mayor de 4 dS m^{-1} , ocasionando efectos muy nocivos para los cultivos, como pérdida del potencial productivo y fitotoxicidad para las plantas; además de que altera el metabolismo de los organismos del suelo. Es importante contar con información detallada sobre su distribución espacial de la salinidad para zonificar las áreas por el grado de afectación y con ello implementar propuesta de manejo. Con base a lo anterior, el objetivo de este trabajo fue modelar la salinidad de los suelos a dos profundidades y generar modelos para su predicción. Se obtuvieron escenas de Landsat 8, de mayo 2013 a mayo 2014, de las zonas aledañas al área geotérmica de “Los Negritos”, Villamar, que se encuentra dentro de la Ciénega de Chapala, Michoacán. Se les aplicó análisis de componentes principales y geoestadístico para determinar el intervalo óptimo de muestreo. El cual fue sistemático a una distancia de 400 m, el periodo de muestreo fue cada 48 días. En cada sitio se colectaron dos muestras a profundidades de 0-30 cm y 30-60 cm. En laboratorio se realizaron análisis de salinidad a las muestras de suelos. Se aplicaron métodos multivariados para generar grupos similares de suelos. Se ajustaron modelos lineales generalizados y modelos de efecto mixto eligiendo el modelo de mayor coeficiente de determinación (R^2). Los residuales de los modelos se emplearon para generar semivariogramas experimentales. Los cuales se ajustaron a modelos teóricos, en este caso, se probaron siete modelos. Los semivariogramas ajustados se combinaron con kriging y se obtuvieron los modelos de predicción de la conductividad eléctrica. Se generaron cuatro grupos de suelos con características similares. Los residuales de los modelos de efecto mixto se utilizaron para generar los semivariogramas experimentales debido a que estos modelos tuvieron mayor coeficiente de determinación. Los modelos teóricos esférico y Gaussiano obtuvieron un mayor ajuste a los semivariogramas experimentales de acuerdo a la suma de los cuadrados del error. Los resultados muestran que los suelos clasifican de manera general de ligeramente salino ($2.1-4 \text{ dS m}^{-1}$) a fuertemente salino ($8.1-16 \text{ dS m}^{-1}$). Además que a profundidades de 60 cm existe una mayor conductividad eléctrica comparada con el de 30 cm. Lo que nos llevó a determinar que este modelo tiene un alto coeficiente para la predicción en tiempo y espacio.

ABSTRACT

The soil salinity is the concentration of salts with an electrical conductivity equal to or greater than 4 dS m^{-1} , causing very harmful effects on crops such as loss of productive potential and phytotoxicity to plants; besides altering the metabolism of soil organisms. It is important to have detailed information on the spatial distribution of salinity for zoning areas by the degree of involvement and thereby implement management proposal. Based on the above, the objective of this work was to model the soil salinity at two depths and create models for prediction. Landsat 8 scenes from May 2013 to May 2014, areas surrounding the geothermal area of "Los Negritos" Villamar, located in the Cienega de Chapala, Michoacan were obtained. It was applied and geostatistical of principal components analysis to determine the optimum sampling interval. Which was systematic at a distance of 400 m, the sampling period was every 48 days. At each site two samples at depths of 0-30 cm and 30-60 cm were collected. Laboratory analysis of salinity soil samples were performed. Multivariate methods were applied to generate similar soil groups. Generalized linear models and models of mixed effect model choosing the highest coefficient of determination (R^2) were adjusted. The residuals of the models were used to generate experimental semivariogram. Which they were adjusted to theoretical models, in this case, seven models were tested. Adjusted semivariogram with kriging combined and predictive models of electrical conductivity were obtained. Four groups of soils with similar characteristics were generated. The residual mixed effect models were used to generate experimental semivariograms because these models had higher coefficient of determination. The spherical and Gaussian theoretical models obtained a better fit to the experimental semivariograms according to the sum of the squares of the error. The results show that soils classified generally slightly saline ($2.1-4 \text{ dS m}^{-1}$) to strongly saline ($8.1-16 \text{ dS m}^{-1}$). Also at a depth of 60 cm there is a higher electrical conductivity compared with 30 cm. What led us to determine that this model has a high coefficient for prediction in time and space.

1. INTRODUCCIÓN

Casi el 10% de la superficie total de la tierra (más de 1000 millones de ha) está cubierto con diferentes tipos de suelos afectados por la salinidad (Tanji, 2002; Shahid *et al.*, 2013). La mayor parte se localiza en Asia con 33%; 15% en el continente Americano; 8.5% en África; 37.5% en Australia y en Europa 6%. La salinidad que amenaza la calidad de los suelos agrícolas en todo el mundo, tan solo en América Latina 31, 000,000 ha presentan este tipo de degradación, destacando México, Perú, Colombia, Ecuador y Chile entre los más afectados (Rueda, 2009; Intagri, 2013).

En México, el problema de la salinidad se presenta fundamentalmente en las zonas áridas con riego y a lo largo de la costa. Los lugares donde se observa con más frecuencia son las cuencas cerradas, que a través de miles de años han acumulado paulatinamente sales en el perfil del suelo (Fernández, 1990; Rueda, 2009).

En el país los suelos afectados por salinidad, representan alrededor del 13% (372,675 ha) de la superficie regada en los distritos de riego (2.86 millones de ha) y la región noroeste ha sido la más afectada con el 7.6% (218,091 ha) (SERMANAT y SAGARPA, 2010).

El proceso de salinización de suelos es la acumulación de sales solubles que conlleva a la pérdida de potencial productivo, además repercute significativamente en aspectos ecológicos y socioeconómicos (Estrada, 2008).

La salinidad se puede desarrollar de forma natural o por causa de la intervención humana provocando la alteración de los ecosistemas naturales, ya que reducen la absorción de nutrientes de las plantas y disminuyen la calidad del agua, afectando el desarrollo vegetal. Además puede provocar fitotoxicidad por una concentración excesiva de ciertas sales minerales tales como el sodio, magnesio, potasio, fosfatos, sulfatos, nitratos entre otros (Ramalho, 1998).

También, alteran el metabolismo de los organismos del suelo, reduciendo la fertilidad del suelo. Además, de que hace más impermeables las capas profundas del suelo, lo que provoca

que las tierras no sean aptas para el cultivo, ya que este proceso lleva a la desertificación ocasionando un grave problema que pone en peligro la economía agrícola (SOCO, 2009).

Según Shahid *et al.* (2013) la principal razón para el aumento de la salinidad se debe a la intensificación de la agricultura para beneficios a corto plazo, haciendo caso omiso de las consecuencias a largo plazo, por la mala gestión de los recursos de suelo y agua. La salinización del suelo ha sido identificada como la causa principal de la degradación. Específicamente en regiones subhúmedas, semiáridas y áridas, especialmente en áreas con riego, por el uso inadecuado del agua y de tecnologías inapropiadas, causando daños ambientales (Bautista & Palacio, 2005; Saa *et al.*, 2010).

Se estima que la salinización del suelo aumente en escenarios futuros de cambios climáticos como el aumento del nivel del mar, el impacto en las zonas costeras, el aumento de la temperatura que posteriormente, se incrementará la evaporación provocando la salinización (Corwin y Lesch, 2003; Shahid *et al.*, 2013).

El caso de la Ciénega de Chapala (porción Michoacán) existen problemas de salinidad que repercuten en la productividad de los cultivos. Las áreas de mayor salinización de suelos corresponden a los lugares aledaños al área geotérmica de “Los Negritos” ocasionando significativas pérdidas económicas a los agricultores por la disminución de la productividad de sus tierras; como es el caso del trigo, cuyo rendimiento por hectárea reportado para el periodo 1992-2002, disminuyó hasta 60% (Silva *et al.*, 2006).

En estudios previos en la región se ha encontrado que se presentan elevados valores de conductividad eléctrica en los suelos de 1.5 hasta 40 dS m⁻¹ aspecto que ha influido en la productividad (Estrada, 2008). Sin embargo, este estudio se enfocó a evaluar la calidad de agua, dejando en segundo término el estudio de la salinidad en el suelo.

La medición en tiempo real y el seguimiento de la distribución espacial de la salinidad del suelo es crucial pieza de información para aplicaciones de agricultura de precisión. La agricultura utiliza la rápida evolución de las tecnologías de información para modificar la

gestión del suelo de sitio específico como las condiciones que cambian espacial y temporalmente (Schilfgaard, 1999).

Para optimizar la producción de cultivos y reducir al mínimo los efectos ambientales perjudiciales. Además, hay una comprensión de la variabilidad espacial y temporal que puede servir de marco para el desarrollo de planes de muestreo eficaces para la gestión futura y eficientes diseños experimentales para los enfoques de investigación, teniendo la comprensión de la dinámica, extensión y grado de salinización de los suelos (Schmid *et al.*, 2005).

Debido a la variabilidad espacial y temporal de la concentración de sales en el suelo, numerosas muestras deben tomarse y las mediciones deben repetirse para denotar que las condiciones cambian o si están cambiando. La salinidad del suelo se determina tradicionalmente en laboratorio a partir de muestras tomadas de campo. Sin embargo, este enfoque, es más preciso, pero consume más tiempo y es caro.

Es por esto que se tiene como alternativa, de manera fácil, rápida, y barata utilizar las nuevas tecnologías de cartografía de suelo como es el uso de datos auxiliares teniendo un inventario completo de los recursos. Por lo tanto, el suelo se puede medir en lugares de espacio limitado y sólo instantes de tiempo (Schmid *et al.*, 2005; Shahid *et al.*, 2013).

La geoestadística espacial es una opción porque es un método que comúnmente se utiliza para procedimientos de interpolación como el Kriging (Lin, 2002). Lo que permite ampliar la información analítica originada de puntos de muestreo a una superficie continua, elaborando mapas de conductividad eléctrica que se fundamenta en la variabilidad espacial.

2. JUSTIFICACIÓN

El monitoreo de la salinidad del suelo, contribuirá con el aumento de conocimientos acerca de la extensión e intensidad de la salinización de los suelos en la zona de estudio destacando la dinámica en espacio-tiempo, a través de modelos de predicción. Además de proporcionar la información adecuada para tomar las medidas necesarias para un uso sostenible del recurso.

3. OBJETIVOS

General:

- ✓ Generar modelos para predecir la salinidad de suelos en tiempo y espacio en “Los Negritos”, Villamar.

Específicos:

- ✓ Establecer el protocolo de muestreo en tiempo y espacio.
- ✓ Determinar las variables de la salinidad de suelo en laboratorio.
- ✓ Generar mapas de salinidad del suelo en diferentes periodos.
- ✓ Elaborar modelos predictivos de salinidad de suelos.

4. HIPÓTESIS

El empleo de datos de sensores remotos y modelos de inferencia espacial permitirá pronosticar la dinámica en tiempo y espacio de la salinidad en los suelos de “Los Negritos”, Villamar.

5. REVISIÓN BIBLIOGRÁFICA

5.1 El origen de las sales del suelo

El término salinidad se refiere a la presencia en el suelo de una elevada concentración de sales que perjudican a las plantas por su efecto tóxico y la disminución del potencial osmótico del suelo. La situación más frecuente de salinidad en los suelos es por NaCl pero los suelos salinos suelen presentar distintas combinaciones de sales, siendo comunes los cloruros y los sulfatos de Na^+ , Ca^{2+} , Mg^{2+} . Se dice que un suelo se considera salino cuando la conductividad eléctrica (CE) es igual o mayor de 4 dS m^{-1} (Rueda *et al.*, 2009; SERMANAT y SAGARPA, 2010).

La acumulación de sal en el suelo es el producto final de diferentes procesos. La salinidad se da por dos vías; una de origen natural (salinización primaria) y la antropogénica (salinización secundaria) (European Communities, 2009).

La acumulación primaria de sales es mediante procesos naturales debido al alto contenido propio del suelo o en las aguas subterráneas (Tanji, 2002; European Communities, 2009). Los suelos afectados por salinidad generalmente se encuentran en zonas bajas esto se debe por la cercanía y la altura sobre el nivel del mar, así como también la intemperización que da la descomposición de las rocas, bajo la influencia de factores, químicos, físicos y biológicos. Es decir, da una descomposición química, liberando sales solubles (Im-Erb y Pongwichian, 2003; Lamz y González, 2013).

La existencia de sales en el suelo influyen en las propiedades físico-químicas del perfil del suelo, como son: la estructura, la porosidad, la permeabilidad, la capacidad de retención de humedad y de intercambio catiónico. En regiones áridas y semiáridas esta situación es predominante donde las bajas precipitaciones no permiten la lixiviación de las sales de manera natural hacia estratos más profundos (SERMANAT y SAGARPA, 2010). Además las adversas condiciones climáticas, deben considerar otros factores, en la ocurrencia de salinidad, como son: las aguas salinas subterráneas, las tierras bajas cercanas a las costas, los pantanos y las lagunas litorales, así como en las áreas cercanas a minas.

La acumulación secundaria de sales es producida por las intervenciones del hombre, va asociada a la evolución de la agricultura, tanto a nivel de las técnicas de irrigación como a los cambios en el uso, distribución del agua o un drenaje insuficiente, residuos del abonado y de fertilizantes químicos (Tanji, 2002; Pitman y Läuchli, 2002).

La expansión de zonas agrícolas para hacer frente a la creciente necesidad de alimentos, ha causado el uso inadecuado de los recursos de tierra y agua. El aumento de riego con el uso de las aguas salinas para el riego, el aumento de estas en las capas del subsuelo en áreas de drenaje pobre y la aplicación de fertilizantes son las actividades humanas que en combinación con la naturaleza como es el clima, el suelo favorecen este proceso (Jiménez *et al.*, 2010).

5.2 Estado en que se encuentran las sales en el suelo

Las sales en el suelo se encuentran en asociadas formando compuesto y disociadas como iones que son positivos (cationes) y negativos (aniones), La forma asociada de las sales se presentan por combinación: NaCl, CaCl₂, MgCl₂, Na₂SO₄, MgSO₄, etcétera. En caso de estar presentes como iones, se pueden encontrar en tres diferentes disposiciones, formando el medio iónico ambiente (Rueda *et al.*, 2009).

- A) Iones solubles: en la solución de suelo.
- B) Iones hidratados: A presión en las arcillas o material orgánico muy fino.
- C) Iones intercambiables: Retenidos por cargas eléctricas en las arcillas o material orgánico muy fino.

Los cationes más abundantes son: Na⁺, Ca⁺⁺ y Mg⁺⁺, encontrándose en menor cantidad K⁺.

Los aniones más abundantes son los cloruros (Cl⁻) y sulfatos (SO₄⁼), existiendo en menor cantidad los carbonatos (CO₃⁼).

5.3 Efecto de las sales en el suelo y la planta

Un suelo salino se caracteriza por presentar propiedades físicas y químicas desfavorables para el crecimiento y desarrollo de los cultivos, poca vegetación que conduce a la degradación del suelo, lo que necesita prácticas especiales para su mejoramiento y manejo. La baja producción

conduce a pérdidas financieras, alto costo para la recuperación de suelos de buena calidad que requiere más insumos (Shahid *et al.*, 2013).

Según Russell y Wild (1992) las sales solubles pueden tener dos tipos de efectos sobre la planta en crecimiento:

- 1) Efecto osmótico. Esta se da alrededor de las raíces por la presencia de sales en la solución del suelo reduciendo la disponibilidad hídrica para la planta, al aumentar la presión osmótica de dicha solución. Hay una acumulación de sales que, a pesar de que el suelo contenga agua, la planta no podrá extraerla ya que se inhibe la captación de agua, sufriendo desequilibrios nutricionales, toxicidades y un estrés hídrico (Freitas y Castro 2010; Dagar, 2010). El desbalance iónico y la toxicidad iónica, estimula cambios en la estructura del suelo que afecta a la planta. Igualmente, la acumulación de cloruros en las hojas disminuye la tasa fotosintética la transpiración y la conductancia estomática además de activar la función antioxidante de la planta (Arbona, *et al.*, 2013; Iglesias *et al.*, 2004).
- 2) Efecto de ion específico. Este efecto puede ser debido a la toxicidad directa causada por la acumulación específica de iones, por la formación de productos tóxicos para la planta o alterar el equilibrio nutricional de la misma (Corwin y Lesch, 2003).

El efecto general de un alto contenido de sales en el suelo es dar una planta muy pequeña. Reduciendo los rendimientos desde un 20%, las hojas de los cultivos se vuelven de color opaco y a menudo verde azulado y se cubre con un depósito ceroso. Estos síntomas varían con los estados fenológicos de los cultivos, siendo más notable durante las primeras etapas de crecimiento, debido a que la mayoría de las plantas son más sensibles a la salinidad durante la germinación, que en las últimas etapas de su desarrollo (SERMANAT y SAGARPA, 2010).

5.4 Variabilidad espacio- temporal de las sales

Se presenta una gran variabilidad espacio-temporal debido a los efectos combinados de la física, química, y procesos biológicos que operan a diferentes escalas y con distintas

intensidades. Corwin *et al.* (2006) mencionan que puede variar la concentración de sales a poca distancia en los puntos de observación, tanto horizontal como vertical, por el hecho de que hay un patrón de variabilidad en la concentración de sales en función de la estación del año, función de prácticas de manejo utilizadas, profundidad del nivel freático, permeabilidad del suelo, salinidad del agua subterránea, procesos de evaporación y precipitación (Naidu, 1995; Mess, 2003 y D'Almeida *et al.*, 2005). Bajo condiciones de evaporación, la mayor concentración se registra en la parte superior del perfil; mientras que en el periodo de lluvias se produce un desplazamiento de las sales hacia el interior del perfil (Pal *et al.*, 2003).

5.5 Cartografía de salinidad de suelos

5.5.1 Teledetección y Sistemas de Información Geográfica

La teledetección es una técnica de evaluación rápida que estudia las variaciones espectrales, espaciales y temporales de las ondas electromagnéticas que es reflejada de los objetivos para obtener información sobre la superficie de la tierra, para el tratamiento y análisis de imágenes digitales tomadas desde el satélite (Khorram *et al.*, 2012).

Algunos de los satélites que se emplean para el monitoreo de los recursos naturales es el LANDSAT. Captan la información de la superficie terrestre a través de dispositivos conocidos como sensores remotos, con una mayor precisión o detalle para proporcionar información esencial de la superficie terrestre y así tomar decisiones adecuadas acerca del manejo de los recursos. Los satélites LANDSAT se localizan en una órbita casi polar y sincrónica con el Sol, a 920 Km de altura sobre la superficie de la Tierra. Tardan en efectuar una órbita completa 103 minutos, barren la superficie terrestre cada 18 días y obtienen información simultánea de zonas de la Tierra de 185 x 185 Km aproximadamente 34 000 Km² (NASA, 2014).

Los sensores remotos miden los distintos rasgos de absorbancia y reflectancia del suelo que corresponden a los rangos del espectro electromagnético (EM), (Viscarra *et al.*, 2006). Con el paso del tiempo se han dado varias mejoras radiométricas, geométricas y espaciales que se incorporaron a los sensores; el primero, conocido como Multispectral Scanner Sensor (MSS), seguido de Thematic Mapper (TM) que tiene mayor sensibilidad radiométrica que su antecesor

y por último, Enhanced Thematic Mapper Plus (ETM+) que entre sus mejoras técnicas destaca una banda espectral (pancromática) con resolución de 15 metros.

En este sentido EM es útil para detectar las oscilaciones de la salinización en el tiempo y espacio. Mostrando la presencia de manchas blancas irregulares de sales precipitadas que generalmente ocurre en zonas elevadas o sin vegetación, donde el agua se evapora y deja las partículas de sales sobre la superficie (Dehaan y Taylor, 2002; Khorram *et al.*, 2012; INEGI, 2014; NASA, 2014).

Los sensores de LANDSAT están compuestos por 7 u 8 bandas espectrales, que al combinarse producen una gama de imágenes de color que incrementan notablemente sus aplicaciones. Dependiendo del satélite y el sensor se incluye un canal pancromático o uno térmico; asimismo las resoluciones espaciales varían de 15, 30, 60 y 120 m. El LANDSAT cuenta con una capacidad para observar el uso del suelo a través de distintas escalas (INEGI, 2014). Tiene resolución espacial media, que permite detectar, eflorescencias salinas, que en gran parte corresponden a suelos salinos.

Por esto mismo es de gran utilidad para determinar las áreas susceptibles a sufrir la salinización, lo que reduce el trabajo de campo. Sin embargo, se requieren datos analíticos de los perfiles del suelo para confirmar los datos de los sensores. Un indicador indirecto de la salinidad del suelo es la reflectancia de la vegetación (Metternicht y Zinck, 2008; Zhang *et al.*, 2011; Pérez y García, 2013), por el hecho de que la vegetación sana tiene una baja reflectancia en la región visible debido a la absorción de clorofila, que se utiliza para la fotosíntesis, y una alta reflectancia en la infrarrojo cercano región (NIR) debido a la estructura celular de las hojas de plantas (Kumar *et al.*, 2002).

En cambio la vegetación poco saludable con menos clorofila, muestra un aumento de la reflectancia en la región visible y la reducción de la reflectancia en la región NIR. Estos cambios de reflectancia se observan en varias plantas durante el estrés de salinidad (Elmetwalli *et al.*, 2012; Peñuelas *et al.*, 1997).

Mientras los análisis multitemporales permiten estudiar los cambios que han sufrido los suelos salinos, tanto en su uso como en su calidad. Esto es mediante la comparación de escenas de distintas épocas mostrando que varios suelos que presentan salinidad ya no son cultivados (Pérez y García, 2013).

La cartografía de la salinidad y el monitoreo mediante el uso de la teledetección y los sistemas de información geográfica (SIG) han sido comunes en muchos países; como parte de los inventarios nacionales de suelos. (Sharma y Bhargawa 1988; Beare *et al* 1997).

Los SIG poseen beneficios importantes como es el análisis espacial, en particular el uso de las interpolaciones de diferentes tipos de variables. Esta herramienta es de gran importancia en la agricultura, permite analizar la variabilidad de diferentes características sobre el paisaje tales como suelo (Clay *et al.*, 2007).

Son utilizados los SIG para la integración de datos e información que se tenga disponible, para el diseño de un modelo. Un SIG tiene una serie de ventajas con respecto a los mapas con antiguo estilo, debido a que los datos se almacenan digitalmente, pueden ser analizadas fácilmente por un ordenador. En el caso de la salinidad, los científicos pueden utilizar los datos sobre las precipitaciones, la topografía y el tipo de suelo, cualquier información espacial que está disponible electrónicamente para determinar las zonas más susceptibles a la salinización y luego para predecir regiones similares que puede estar en riesgo (Spies y Woodgate, 2004).

5.6 Geoestadística

Según Matheron (1962), la Geoestadística es "la aplicación del formalismo de las funciones aleatorias al reconocimiento y estimación de fenómenos naturales". En sí, es una rama de la estadística aplicada que se especializa en el análisis y el modelado de la variabilidad espacial en ciencias de la tierra.

Su objeto de estudio es el análisis y la predicción de fenómenos en espacio y tiempo. Se utiliza para la asignación de los rasgos a partir de datos de la superficie limitada y para interpolación

en el espacio, así como la estimación de valores en ubicaciones no muestreadas. Sin embargo, también se utilizan en la hidrología, las aguas subterráneas, en la cartografía de la salinidad del suelo. Aborda el problema de la predicción espacial en una región con continuidad espacial. Los datos geoestadísticos pueden tener dependencia espacial, temporal o ambas. En muchos casos, este tipo de datos suelen ser multivariantes (Díaz, 2002; Maestre, 2008; Reyes, 2010; Shahid *et al.*, 2013).

La geoestadística es un conjunto de técnicas usadas para analizar y predecir valores de una propiedad distribuida en espacio o tiempo. A diferencia con la estadística convencional o descriptiva, donde tales valores no se consideran independientes, por el contrario se suponen de manera supuesta que están correlacionados unos con otros, es decir existe una dependencia espacial. Esto indica que mientras más cercanos estén situados dos puntos están más correlacionados y mientras más separados hay menos relación entre estos (Burrough y McDonnell 1998).

El proceso de valoración y modelación de la función que describe la correlación espacial es el “análisis estructural”. Una vez realizado el análisis estructural, la predicción de valores en puntos no muestrales se puede hacer aplicando la técnica de interpolación "kriging" o aplicar “simulaciones condicionales”.

5.6.1 Análisis exploratorio

La primera etapa, conocida como análisis exploratorio de datos, es la que se orienta hacia la investigación preliminar de aspectos espaciales comprobando la consistencia de los datos, eliminando los erróneos e identificándose las distribuciones de las que provienen para comprobar si las hipótesis formuladas por cualquier modelo provisional son satisfactorias, esta etapa se basa en técnicas estadísticas convencionales que nos permiten obtener todo un conjunto de información, desconocida sobre la muestra bajo estudio, que es imprescindible para realizar “correctamente” cualquier análisis estadístico y en particular un análisis geoestadístico (Díaz, 2002; Diggle y Ribeiro, 2007). El análisis exploratorio de los datos puede continuar por un resumen estadístico de la distribución.

5.6.2 Análisis estructural

El segundo paso, a partir de los datos recopilados se establece un pronóstico de los valores de un lugar a otro en el área de estudio, este análisis da como resultado un gráfico conocido como “semivariograma” que modela la diferencia entre la semivarianza de un punto con otro de acuerdo con la distancia y la dirección entre ellos (Díaz, 2002).

Tema más importante de la geoestadística que caracteriza la estructura espacial de una propiedad o fenómeno regionalizado. Es el proceso en el que se obtiene un modelo geoestadístico para la función aleatoria que se estudia. Es decir que consiste en estimar y modelar una función que refleja la correlación espacial de la variable regionalizada a partir de la adopción razonada de la hipótesis más adecuada acerca de su variabilidad.

El Semivariograma o variograma experimental, es el que modela la continuidad espacial de una variable que se calcula de los datos disponibles. Función que se usa con frecuencia para describir la variación espacial de una propiedad del suelo (Ginzo, 2014). Es una herramienta central de la geoestadística, que relaciona la semivarianza con el vector h conocido como "lag", el cual denota la separación en distancia y dirección de cualquier par de valores (Martins, *et al.*, 2007).

Deutsch y Journel (1998), definen al semivariograma como la mitad del promedio cuadrático entre las diferencias de dos valores separados aproximadamente por el vector “h”. Lo que expresa de manera matemática es el modo que la semivarianza de una propiedad cambia al variar el lag (h), este se incrementa al aumentar la distancia del lag; que corresponde a una correlación espacial que disminuye al aumentar la separación (Journel y Huijbregts, 1978; Sommer, *et al.*, 2000).

El semivariograma experimental tiene la necesidad de que se ajuste a un modelo teórico para obtener parámetros que serán usados posteriormente en la interpolación *kriging*. Para el ajuste del semivariograma experimental existen diferentes métodos pero el más utilizado es por mínimos cuadrados ponderados; a lo que Cressie (1989), menciona que con esta técnica se obtienen resultados aceptables.

Las partes constituyentes del semivariogramas son (Figura 1).

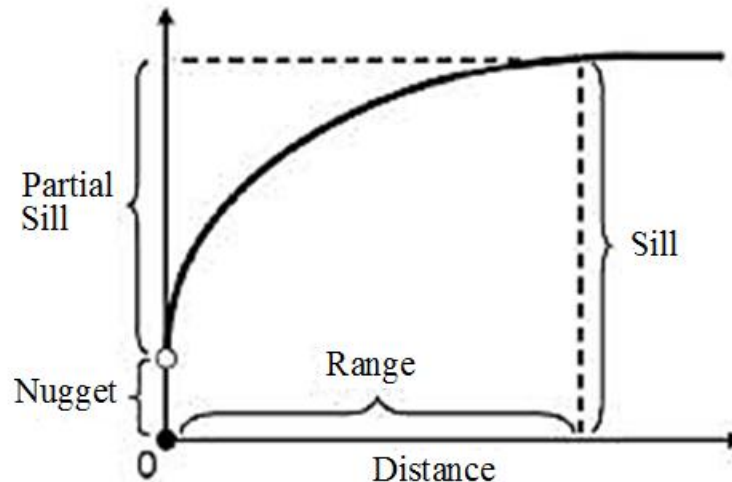


Figura 1. Parámetros del semivariograma.

Sill.- Conocido también como “meseta”, es el límite superior de cualquier modelo de variograma acotado, al que tiende asintóticamente para grandes distancias. A medida que h crece, la función (h) resulta más o menos estable alrededor del límite.

Rango.- Es la distancia de un proceso espacial a partir del cual ya no se considera que exista correlación entre los datos, siendo entonces, la distancia de confiabilidad de correlación, es decir de la distancia máxima de correlación.

Nugget.- el valor del semivariograma en cero, conocido como la varianza "nugget" o microvarianza. Es decir, es una discontinuidad puntual del semivariograma en el origen. Puede deberse a que la variabilidad espacial tiene una escala más pequeña que la mínima distancia considerada o a un error experimental (Niño, 2008).

Son varios los modelos para ajustar, que tienen que asegurar de no obtener varianzas negativas, por mencionar unos ellos (Figura 2)

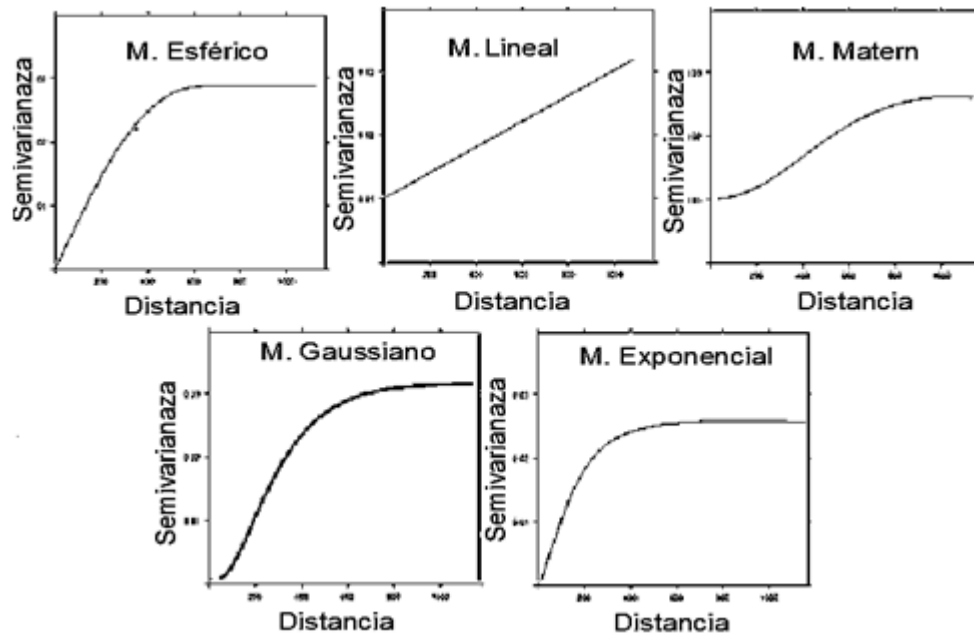


Figura 2. Modelos teóricos.

Los puntos que se toman en cuenta para la elección de un modelo dependen del objetivo del trabajo. Si el objetivo es comparar parámetros de los semivariogramas entre distintas variables, los cambios espacio-temporales en el semivariograma de una variable dada, la utilización de modelos diferentes resulta poco útil (Maestre, 2008).

Hay que tener en cuenta que, por ejemplo, los rangos de modelo esférico y el exponencial no son directamente comparables. El modelo esférico es el único que tiene un “sill” verdadero, porque alcanza una distancia finita; indica fenómenos con pocas discontinuidades y presenta un comportamiento lineal en el origen (Samper 1990).

Mientras que el modelo exponencial como el gussiano no alcanza nunca el “sill”, nombrados como modelos transaccionales porque en ellos se puede estimar el sill, sea verdadero o no, el modelo lineal al igual que otros modelos ni siquiera lo tienen, ya que no es un modelo transicional (Sommer, *et al.*, 2000; Maestre, 2008).

5.6.3 Kriging

El tercer, paso es estimar los valores de localidades no muestreadas. Este proceso se conoce como interpolación "kriging". La técnica básica, utiliza un promedio cuidadoso de las muestras de vecinos para estimar el valor "desconocido" dada la ubicación. Los pesos se optimizan usando el modelo semivariograma, la ubicación de las muestras. La técnica también proporciona un "error estándar" que puede ser utilizado para cuantificar los niveles de confianza (Díaz, 2002).

Aunque kriging proporciona un mecanismo para combinar la información global y local en las predicciones, la capacidad del semivariograma para describir la dependencia espacial es directamente una función de la cantidad y la calidad de los datos de la muestra (Miller *et al.*, 2007).

En varios estudios el método de interpolación Kriging ha mostrado ser eficiente en la discriminación de áreas con diferentes características de importancia agronómica. En la agricultura de precisión esto es de mucha utilidad para mejorar las prácticas de manejo, acordes con la variabilidad encontrada (Petersen *et al.*, 1995; Henríquez *et al.*, 2005).

5.6.4 Modelos auxiliares

Modelos lineales generalizados (MGL) propuesto por Nelder y Wedderburn, (1972). Surge de la necesidad de cuantificar las relaciones entre un conjunto de variables, en la que una de ellas se denomina variable respuesta o dependiente y las restantes son las variables explicativas o independientes.

Este modelo asume que la variable dependiente sigue una distribución normal y homocedasticidad (McCulloch y Searle, 2005), es decir amplía el lineal general, de manera que la variable dependiente está relacionada linealmente con los factores y las covariables mediante una determinada función de enlace. Además, permite que la variable dependiente tenga una distribución no normal. Por lo que el mismo permite unificar varios incluyendo la regresión lineal, regresión logística y la regresión de Poisson bajo un solo marco teórico (Camiña, *et al.*, 2014).

Los modelos de efectos mixtos son modelos estadísticos denominados de varias formas por sus características. Se conoce como modelos multinivel o jerárquicos porque cuenta con una estructura agregada de los datos en distintas clases que pueden estar ordenados o no jerárquicamente. Se denominan también mixtos o de efectos mixtos por el hecho de que combina tanto efectos fijos y efectos aleatorios.

Es útil en entornos en los que se realizan mediciones repetidas en las mismas unidades estadísticas, o cuando las mediciones se ejecutan en grupos relacionados.

Estos modelos mixtos son estratégicos de manera lógica comparados con otros modelos estadísticos, porque describen la relación entre una “variable respuesta” (dependiente) y una o varias “variables explicativas” (independientes, predictores). Debido a que tiene la ventaja de hacer frente a los valores perdidos, los modelos de efectos mixtos son a menudo preferibles a los enfoques más tradicionales como ANOVA de medidas repetidas (Seoane, 2014).

5.6.5 Regresión-Kriging

Es una técnica híbrida que combina la técnica de regresión (MLG o modelos de efecto mixto) con información auxiliar (variables ambientales o datos de sensores remotos) y después se usa un Kriging simple con media conocida (0) para interpolar los residuales del modelo de regresión (Hengl *et al.*, 2007). Con la técnica de RK se han obtenido mejores resultados en la generación de mapas de propiedades de suelos (Hengl *et al.*, 2004), tipos de vegetación (Miller *et al.*, 2007) y distribución de especies (Allouche *et al.*, 2008; Hengl *et al.*, 2009).

5.6.6 Muestreo de suelos

El muestreo es un procedimiento para obtener una o más muestras representativas de un terreno, que usualmente se emplea para evaluar sus características. La muestra consiste en una mezcla de porciones de suelo (submuestras) tomadas al azar de un terreno homogéneo (ICA, 1992 y NOM-021-SEMARNAT-2000). Hay diferentes técnicas de muestreo probabilístico más usuales como es el simple aleatorio, el sistemático, estratificado y el de conglomerados.

El método de muestreo simple aleatorio, conceptualmente es el más sencillo y el menos utilizable. Consiste en extraer todos los individuos al azar de una lista (marco de la encuesta).

En la práctica, a menos que se trate de poblaciones pequeñas o de estructura muy simple, es difícil de llevar a cabo de forma eficaz (Casall y Mateu, 2003).

Muestreo sistemático es un método que tiene las ventajas de que las muestras sean fácilmente seleccionadas y ubicadas en el campo, hay una cobertura uniforme de la población, provee de más información por unidad de costo, los resultados son fáciles de expresar en un mapa.

Los puntos de muestreo se ubican a intervalos regulares en una cuadrícula, las observaciones por lo general se toman en las intersecciones de la cuadrícula, pero también pueden tomarse en el centro de cada celda. La cuadrícula está formada por celdas de igual tamaño y forma, el primer punto se selecciona aleatoriamente, las observaciones siguientes se seleccionan a distancias fijas en ambas direcciones. Otra manera de hacerlo es ubicando aleatoriamente la cuadrícula tomando las muestras en el centro de las celdas o en las intersecciones (Ovalles, 1999; Casall y Mateu, 2003).

6. MATERIALES Y MÉTODOS

6.1 Área de estudio

La localización del área se encuentra al noroeste del estado de Michoacán, en las coordenadas 20°08' de latitud norte y 102°61' de longitud oeste (Figura 3), que está clasificada con mayor salinidad, con referencia a los estudios previos (Estrada, 2008). Cuenta con clima templado con lluvias en verano y una temperatura media anual de 18 a 22 °C. Esta zona se caracteriza por ser de agricultura de temporal y escasamente fértil. Son suelos de textura pesada con más de un 40% de arcilla, color oscuro, que se expanden con la humedad y se contraen (presentan muchas grietas) cuando están secos (Rosas, 1992; Álvarez, 2004; INAFED, 2010).



Figura 3. Área de estudio “Los Negritos, Villamar”

6.2 Metodología

6.2.1. Protocolo de muestreo

Se obtuvieron escenas de Landsat 8, de mayo 2013 a mayo 2014, en total fueron 15 debido a que existen escenas con mala calidad (nubosidad de más 90%). A cada una de las escenas se les aplicó un análisis de componentes principales (ACP) que es una técnica estadística de síntesis de la información, o reducción de la dimensión (número de variables) (Sánchez *et al.*, 2008; Hengl *et al.*, 2009).

El primer componente de cada escena tuvo un 80% de la varianza de los datos originales. A este componente principal se le aplicó un análisis de estructura espacial (semivariograma). Con base al rango del semivariograma se determina el intervalo de muestreo (Mulla y McBratney, 2002). Este proceso se le empleó en las 15 escenas con lo cual se obtuvieron 15 valores de rango, aplicando en cada una la prueba de *t* de student para obtener un intervalo de confianza del intervalo de muestreo en espacio.

El muestreo fue sistemático de 30 puntos a dos profundidades (0-30 cm y 30-60 cm), con una distancia de 400 metros. Para precisar la localización de las muestras de suelo se utilizó un equipo de geoposicionamiento global (GPS). El intervalo de muestreo en tiempo fue cada 48

días que corresponde a tres ciclos de retorno del satélite Landsat 8 para poder interpretar la variabilidad espacio-temporal (Allbeda *et al.*, 2014).

6.2.2 Análisis de laboratorio

Las muestras de suelo se secaron al aire y se pasaron a través de un tamiz de 1 mm. Se realizaron las siguientes determinaciones en laboratorio pH, conductividad eléctrica, cationes solubles; calcio (Ca), magnesio (Mg), sodio (Na) y potasio (K) y aniones solubles (carbonatos (CO_3^{2-}), bicarbonatos (HCO_3^-), cloruros (Cl^-) y sulfatos (SO_4^{2-}) en el extracto de saturación, además de materia orgánica y textura sólo en el primer muestreo (Norma Oficial Mexicana NOM-021-RECNAT-2000).

6.3 Análisis estadístico

6.3.1 Análisis multivariado

Se realizó un análisis de componentes principales a las variables de suelos (0-30 cm y 30-60 cm) para determinar los primeros que representen más del 75% de la varianza de las variables originales. Los principales componentes seleccionados se utilizaron en un análisis clúster para generar grupos con características de suelos similares. Estos grupos se utilizaron como efectos aleatorios en los modelos de efecto mixto (Omuto y Vargas, 2015).

6.3.2 Modelos Lineales generalizados y Modelos Mixtos

Se realizaron modelos lineales generalizados y de efecto mixto; la variable dependiente fue la conductividad eléctrica; las variables independientes fueron las bandas 2 (azul), 3 (verde), 4 (roja), 5 (infrarroja cercana), 6 (infrarroja de onda corta) y 7 (infrarroja de onda corta 2) del sensor OLI/TIRS del satélite LANDSAT 8. Los modelos con mayor coeficiente de determinación (R^2) fueron seleccionados para ser utilizados en la regresión-kriging.

6.3.3 Análisis geoestadísticos

El análisis geoestadístico para las variables de estudio constó de: a) se realizó un análisis exploratorio de los residuales de los modelos lineales generalizados o de efectos mixtos según sea el caso, que tiene como objeto principal valorar la distribución de los residuales, es decir si

se ajustan a una distribución normal, identificando características tales como: valores atípicos, discontinuidades, concentraciones de valores, forma de la distribución, etc. Si en dado caso si estos no se ajustan, se les aplicó una serie de transformaciones (logaritmo base 10, logaritmo +1, raíz cuadrada y raíz cuarta). b) se efectuó un análisis estructural, la generación de semivariogramas de los residuales, que es necesario ajustarlo a modelos teóricos (gaussiano, exponencial, esférico, lineal, matern, bassel y pentaesférico) ya que los experimentales carecen de una función matemática precisa, lo que los hace imposible de emplearlos para la predicción espacial (Nielsen y Wendroth, 2003). Se eligió el modelo teórico con menor sesgo de acuerdo a suma de cuadrados del error (Cressie, 1989).

6.3.4 Regresión-Kriging

Los residuales de los modelos de regresión (modelos lineales generalizados y modelos de efecto mixto) con mayor coeficiente de determinación ajustados al mejor modelo teórico y las bandas del satélite LANDSAT 8 se relacionan con las variables de suelo. Para realizar la predicción espacial se emplea la siguiente ecuación.

$$y=f(x,\beta)+e$$

Donde y es un vector de las variables de suelo, x es un vector de las bandas, f es una función de liga entre y y x , β es un vector de los coeficientes del modelo teórico ajustado, y e es un vector de los residuales de los modelos de regresión. Los modelos de regresión-kriging generados se emplearon para pronosticar la conductividad eléctrica en períodos posteriores, sustituyendo el vector x del modelo con las bandas del período correspondiente. La confiabilidad de los modelos fue calculada mediante el coeficiente de determinación.

6.3.5 Software

Los análisis estadísticos y geoestadísticos se llevaron a cabo con el software R (R Core Team, 2015). La edición y configuración de datos espaciales, de los sensores remotos y elaboración de mapas se realizaron en Quantum GIS 2.8 Wien (GIS Development Team, 2015).

7. RESULTADOS

7.1 Análisis de laboratorio

Los resultados de laboratorio un total de 240 muestras a dos profundidades de 0-30 y 30-60. Indican que a la profundidad de 0-30 cm hay un 53.33% de suelos con salinidad con una conductividad eléctrica es 1.0 a 13.7 dS m^{-1} . Mientras que en la profundidad de 30-60 cm el 80% de los suelos son salinos con una CE es de 1.7 a 19.89 dS m^{-1} (Figura 4 y 5).




Figura 4. Conductividad Eléctrica en cuatro periodos a profundidad de 0-30 cm.




Figura 5. Conductividad Eléctrica en cuatro periodos a profundidad de 30-60 cm.

El pH de suelos a la profundidad 0-30 cm es de 7.7 a 9.2 y en la de 30-60 cm de 7.9 a 9.5 (Figura 6). Así como también estos suelos cuentan con una concentración de materia orgánica de 2.47 a 5.5%, a la profundidad de 0-30 cm y de 2.03 a 6.62 % (Figura 7). El 88% de suelos son arcillosos (Figura 8).

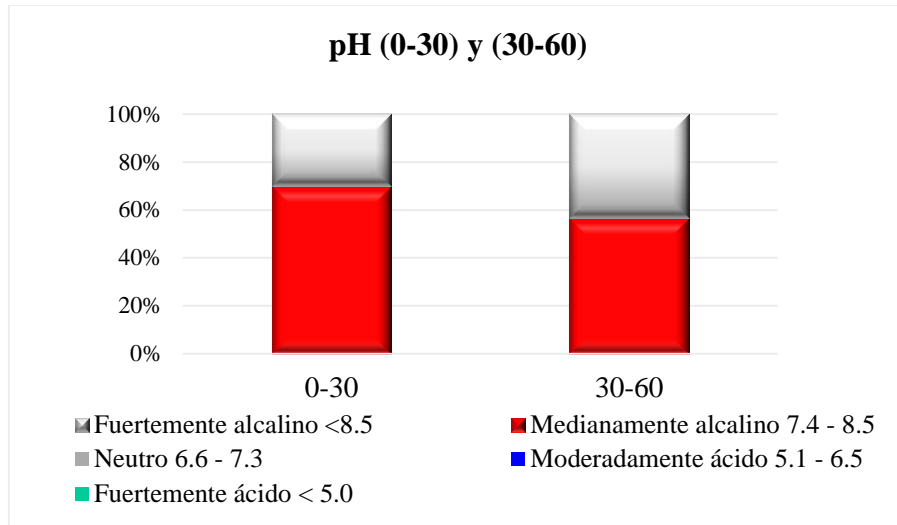


Figura 6. Comparación de pH a dos profundidades (0-30 cm y 30-60 cm)

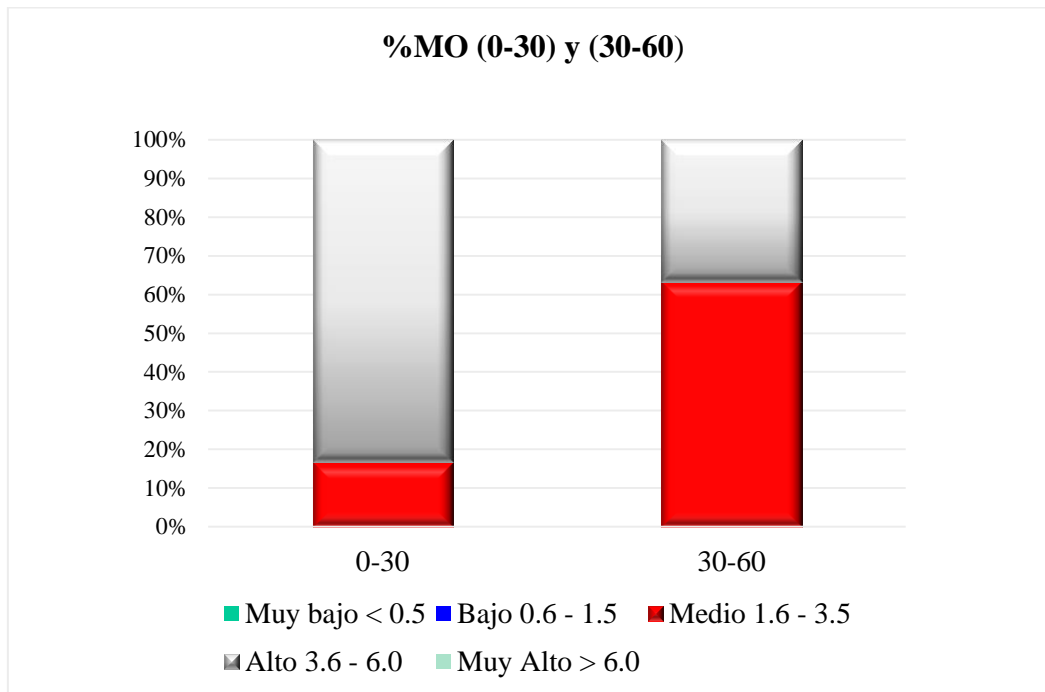


Figura 7. Comparación del % de materia orgánica a dos profundidades (0-30 cm y 30-60 cm)

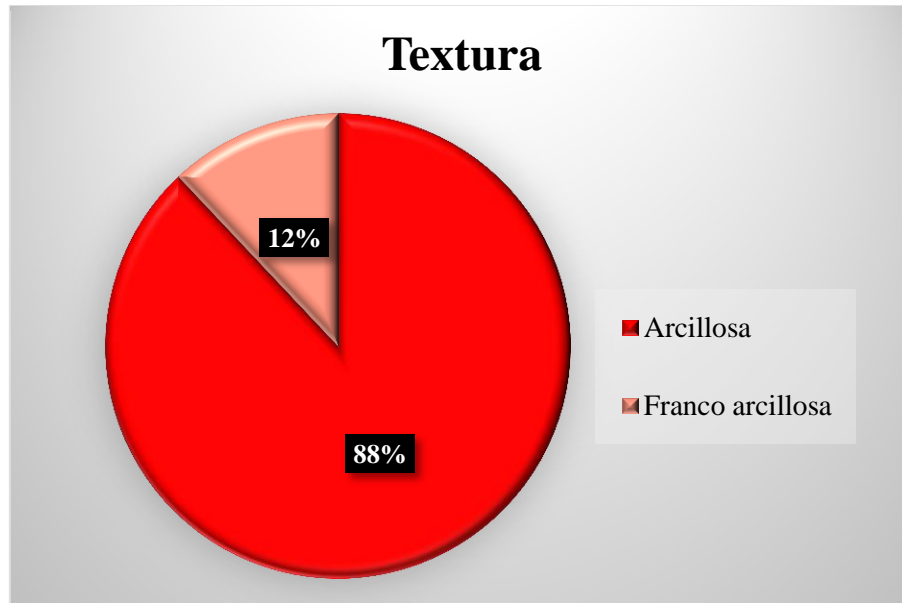


Figura 8. Porcentaje de textura a dos profundidades (0-30 cm y 30-60 cm)

7.2 Análisis multivariado

El análisis de componentes principales muestra que los primeros cuatro componentes principales representan el 78% de la varianza de los datos originales a la profundidad de 0 – 30 cm. Las variables más importantes de acuerdo a sus valores de carga son CE, Ca, pH, Carbonatos y Materia Orgánica (Cuadro 1). A la profundidad de 30-60 cm también los primeros cuatro componentes principales me representan el 79% de la varianza de los datos originales. Las variables que tienen mayor correlación con los componentes de acuerdo a sus valores de carga son CE, Cloruros, Materia orgánica, Carbonatos y Mg (Cuadro 2). Los primero cuatro componentes principales de cada profundidad se emplearon en el análisis clúster.

Cuadro 1. Análisis de componentes principales de las variables del suelo a la profundidad de 0-30 cm del primer muestreo.

	Comp. 1	Comp. 2	Comp. 3	Comp. 4
CE	0.403	-0.128	-0.194	0.139
pH	-0.271	-0.532	-0.159	

M.O	-0.119		0.442	0.824
Ca	0.406			
Mg	0.254	0.181	0.452	-0.153
Na	0.303	-0.395	0.113	0.13
K	0.385	0.201		0.222
CO₃²⁻		0.43	-0.657	0.338
HCO₃⁻	-0.274	-0.323	-0.13	0.284
Cl⁻	0.291	-0.415	-0.263	
SO₄²⁻	0.348			0.114

Cuadro 2. Análisis de componentes principales de las variables del suelo a la profundidad de 30-60 cm del primer muestreo.

	Comp. 1	Comp. 2	Comp. 3	Comp. 4
CE	0.379	-0.183		-0.111
pH	-0.238	-0.215	-0.389	-0.289
M.O	-0.104	0.561	0.291	0.299
Ca	0.356			
Mg	0.307	0.115		-0.489
Na	0.196	-0.558		
K	0.347	0.147	0.216	0.158
CO₃²⁻		0.211	-0.614	0.599
HCO₃⁻	-0.247	-0.347	-0.303	
Cl⁻	0.381		-0.157	

7.3 Análisis clúster

Se obtuvieron cuatro agrupaciones de suelos con características similares en las dos profundidades (0-30 y 30-60 cm) (Figura 9). En la profundidad 0-30 cm el promedio de la CE por grupo es; grupo 1 (1.21 dS m^{-1}), grupo 2 (5.15 dS m^{-1}), grupo 3 (6.15 dS m^{-1}) y grupo 4 (10.83 dS m^{-1}). Mientras que a la profundidad de 30-60 cm el promedio de la CE por grupo es; grupo 1 (4.69 dS m^{-1}), grupo 2 (1.83 dS m^{-1}), grupo 3 (9.62 dS m^{-1}) y grupo 4 (13.88 dS m^{-1}). Véase Cuadro 3.

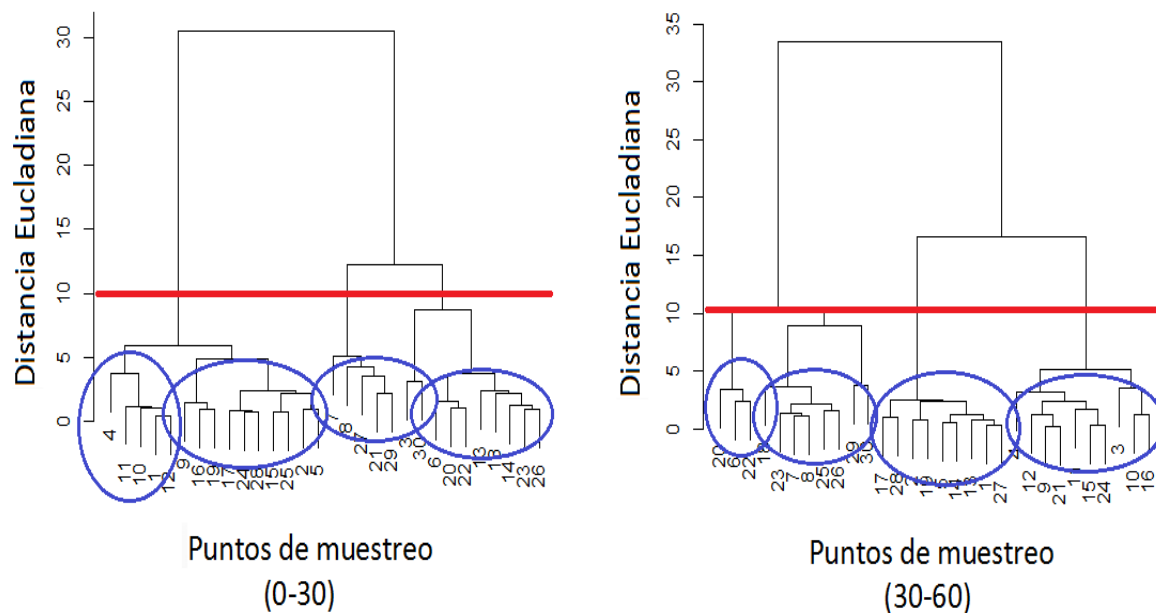


Figura 9. Agrupación jerárquica. Los números en el eje X representan el número de sitio de muestreo.

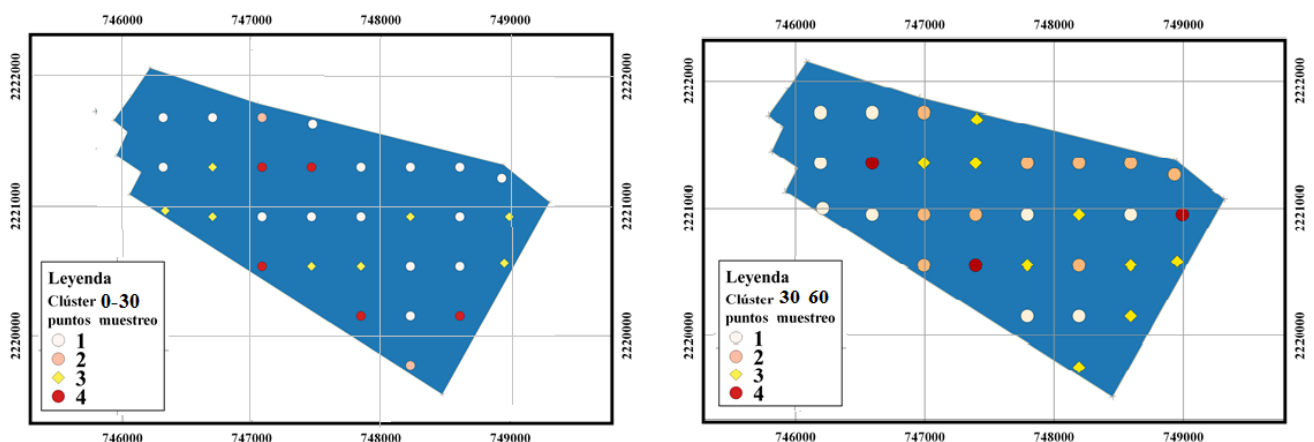


Figura 9.1. Mapas de la agrupación jerárquica

Cuadro 3. Grupos del análisis clúster con la media de la CE a dos profundidades (0-30 y 30-60 cm) del primer muestreo.

Grupos	\bar{X}CE 0-30 cm	\bar{X} CE 30-60 cm
1	1.21	4.69
2	5.15	1.83
3	6.15	9.62
4	10.83	13.88

7.4 Modelos Generalizados y efectos mixtos

Se realizó una comparación entre las R^2 de los modelos Lineales generalizado (GLM) y modelos de Efecto Mixto (MEM), donde se eligió el MEM que tiene un mayor coeficiente de determinación (R^2). Así como en cada uno de los muestreos analizados que determinó el mejor modelo el MEM (Cuadro 4).

Cuadro 4. Comparación entre R^2 del modelos Lineal generalizado (MGL) y modelo de Efecto Mixto (MEM) de las variables del suelo. Izquierda profundidad de 0-30 cm y derecha profundidad de 30-60 cm de los cuatro periodos de muestreo (M1, M2, M3 y M4).

Variable dependiente	R^2GLM	R^2MEM	Variable dependiente	R^2GLM	R^2MEM
CE M1	0.302	0.811	CE M1	0.223	0.802
CE M2	0.4	0.4	CE M2	0.121	0.32
CE M3	0.15	0.60	CE M3	0.41	0.41
CE M4	0.19	0.40	CE M4	0.32	0.53

M1=Muestreo 1, M2=Muestreo 2
M3=Muestreo 3, M4=Muestreo 4

7.5 Geoestadística: análisis exploratorio y estructural

El análisis exploratorio, determinó que la mejor transformación fue el “log10” en las dos profundidades (0-30 y 30-60 cm) mediante los datos del p-valúe de la prueba de normalidad

de Shapiro Wilk, lo que permitió que los datos tengan una distribución normal. Posteriormente se aplicó el análisis estructural eligiendo el modelo de menor sesgo de acuerdo a la suma de cuadrados del error para el ajuste del semivariograma, mostrando que el mejor modelo en la profundidad 0-30 cm fue el “Modelo Esférico” y en la profundidad 30-60 cm fue el “Modelo Gaussiano” (Cuadro 5 y 6). Proporcionando los parámetros del semivariograma ajustado por los modelos teóricos expuestos de las variables del suelo (Cuadro 11 y 12, Anexo).

Cuadro 5. Análisis de los modelos teóricos de las variables del suelo a la profundidad de 0-30 cm de los cuatro periodos de muestreo (M1, M2, M3 y M4).

Periodos de muestreo	Modelo teórico	SCE
CE M1	Esférico	0.0002
CE M2	Matern	0.0013
CE M3	Esférico	0.0001
CE M4	Esférico	0.0001

SCE= suma de cuadrados del error

Cuadro 6. Análisis de los modelos teóricos de las variables del suelo a la profundidad de 30-60 cm de los cuatro periodos de muestreo (M1, M2, M3 y M4).

Periodos de muestreo	Modelo teórico	SCE
CE M1	Esférico	9.41E-07
CE M2	Gaussiano	0.0017
CE M3	Gaussiano	0.0011
CE M4	Gaussiano	0.0007

SCE= suma de cuadrados del error

Con el fin de establecer el alcance de la dispersión de la CE total en la región de estudio se utilizó el modelo de regresión-kriging, debido a que esta técnica de interpolación proporciona una mejor predicción de la variable de interés. Lo que determinó las gráficas de dispersión, donde fue comparando la conductividad eléctrica predicha con la que fue medida obteniendo un alto coeficiente de determinación de ($R^2= 0.99$) en la mayoría de los muestreos (Figura 10 y 11).

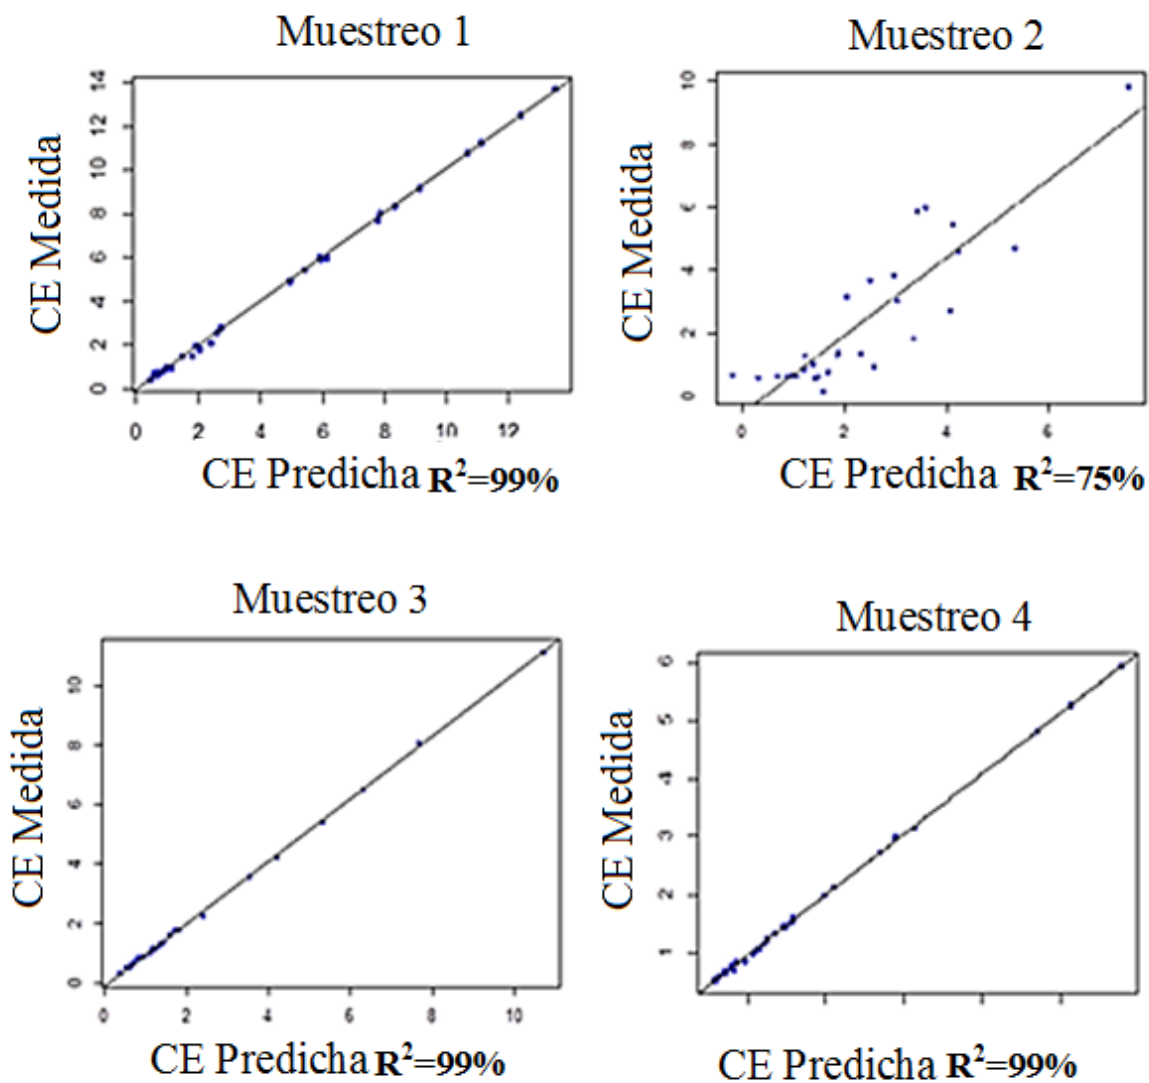


Figura 10. Graficas de dispersión de los cuatro periodos a la profundidad de 0- 30 cm con su coeficiente de determinación (R^2).

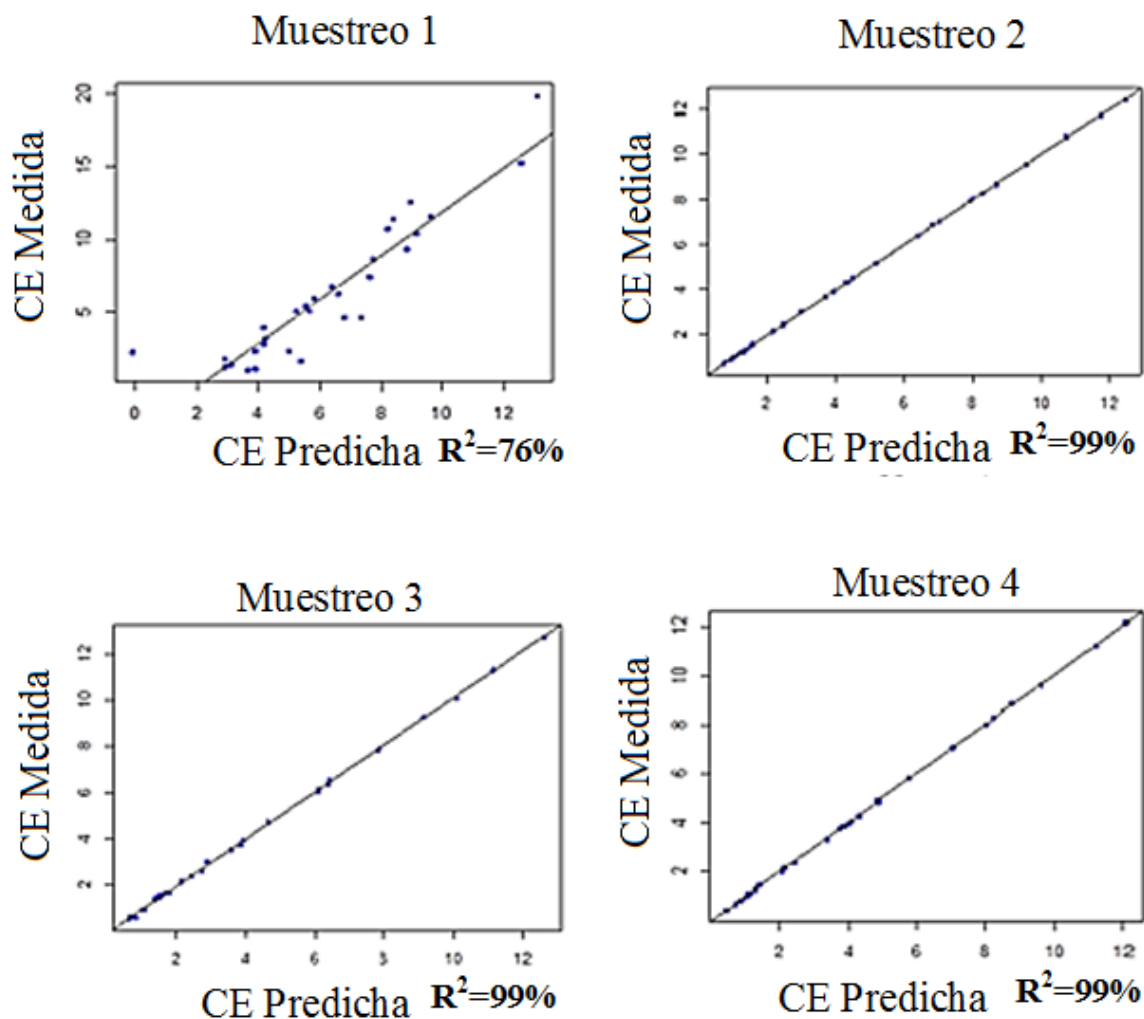


Figura 11. Graficas de dispersión de los cuatro periodos a la profundidad de 30- 60 cm con su coeficiente de determinación (R^2).

Los mapas de conductividad eléctrica generados con la regresión-kriging que se presentan en la Figura 12 y 13 muestran la distribución de los niveles de salinidad de suelos en el primer muestreo a la profundidad 0-30 cm. Existen varias áreas con una CE de moderadamente salino a extramente salino y son varios sitios que no presentan salinidad, conforme al tiempo se presenta una disminución en la CE. En el tercer y cuarto periodo se muestra una CE menor comparada con los otros periodos. A la profundidad 30-60 cm se observa un mayor porcentaje

de áreas salinas a fuertemente salinas. Un comportamiento similar a la profundidad de 0-30 cm, en el tercer y cuarto periodo se presenta una disminución de la CE.

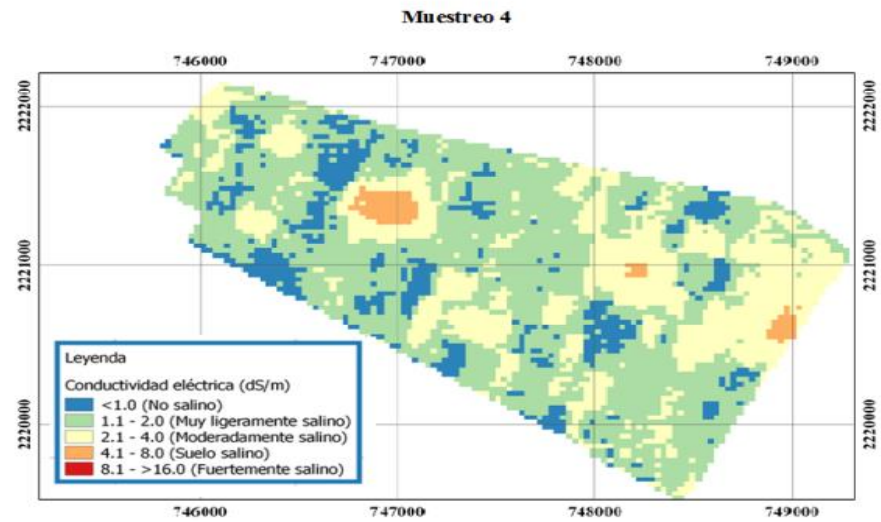
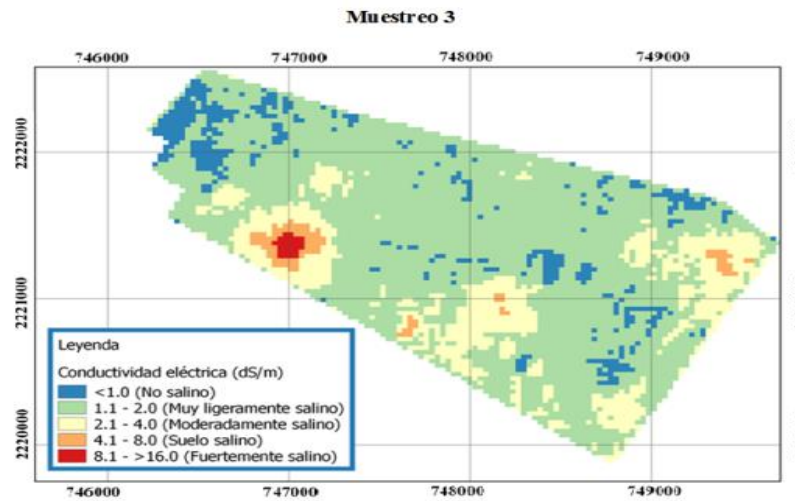
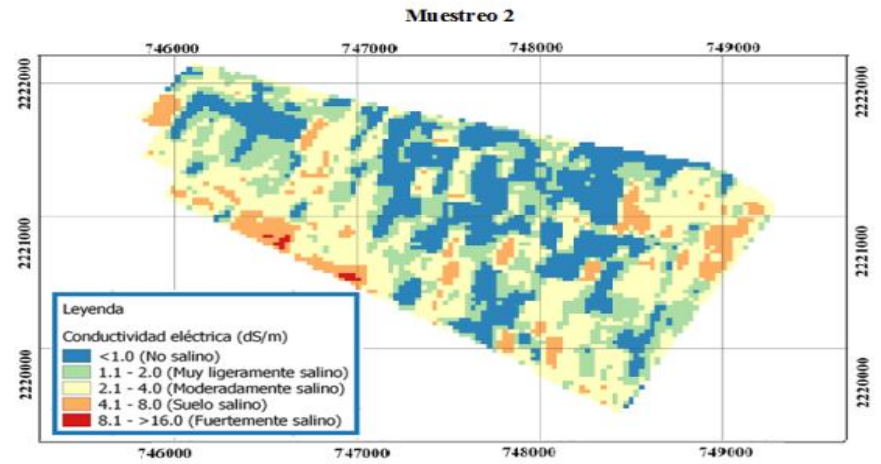
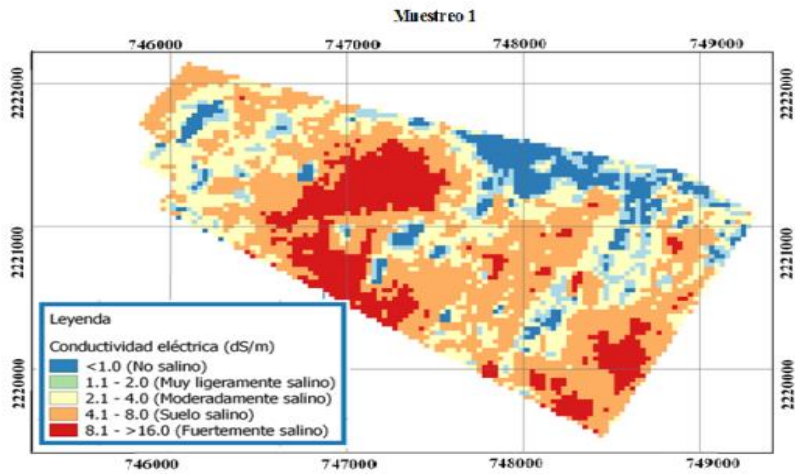


Figura 12. Conductividad eléctrica del suelo a profundidad 0-30 cm de cuatro 4 periodos de muestreo.

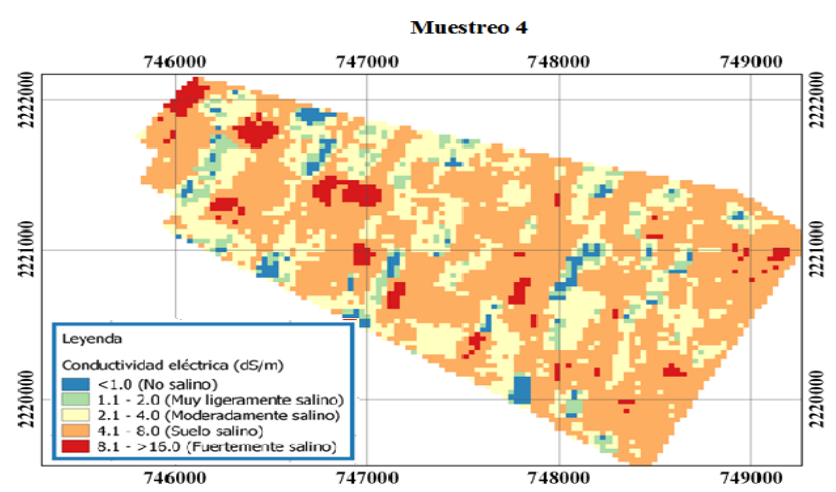
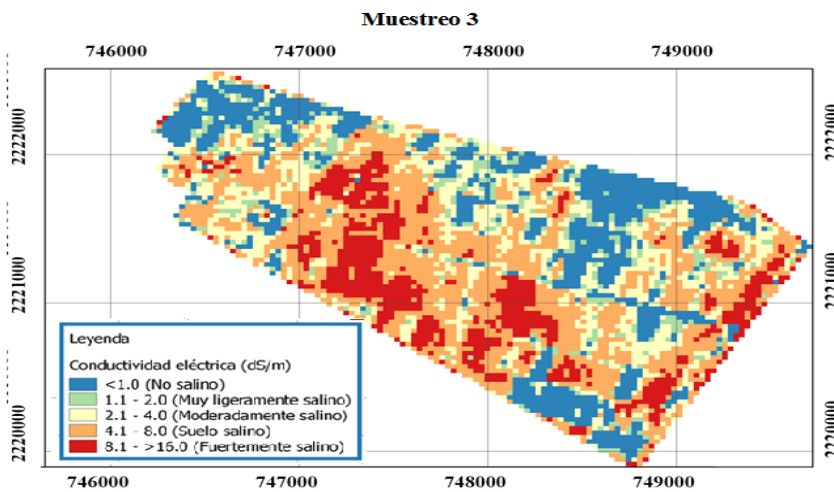
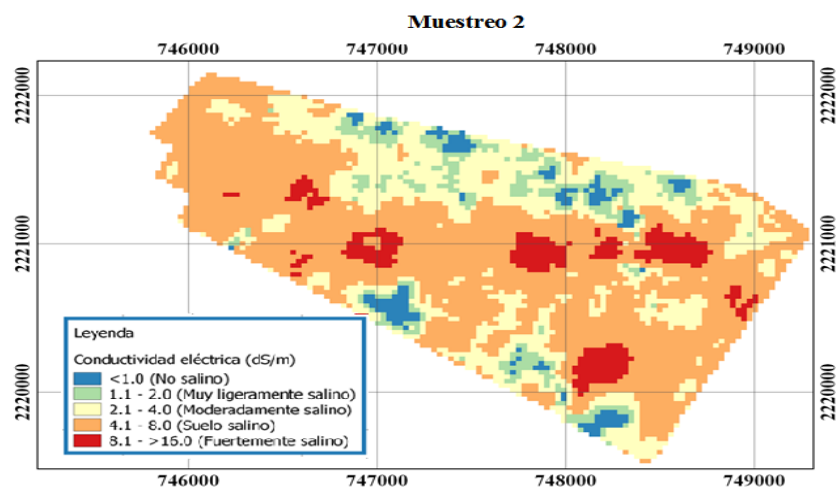
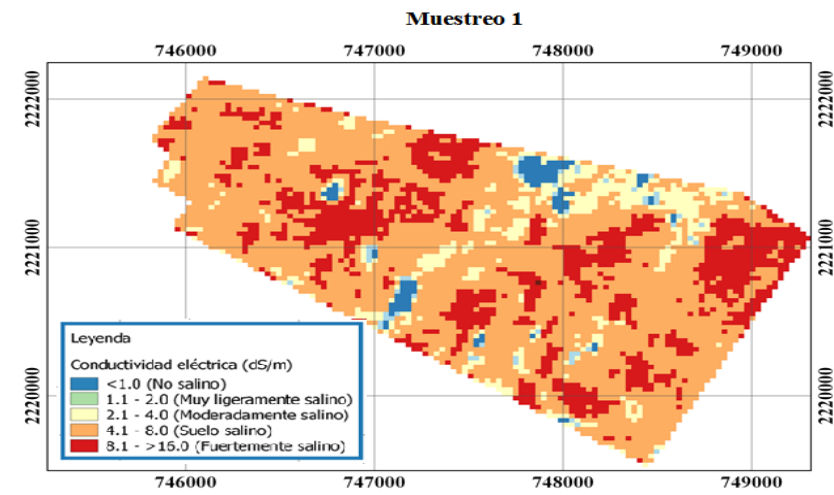


Figura 13. Conductividad eléctrica del suelo a profundidad 30-60 cm de cuatro periodos de muestreo.

8. DISCUSIÓN

Los resultados muestran que los suelos tienen más 40% de arcilla, el contenido de materia orgánica es medio, en cambio en suelos con más del 60% de arcilla el contenido de materia es alto, esto se debe que la zona de muestreo sus suelos son arcillosos. Con base a la CE se clasifican como de ligeramente salino ($1.1-2 \text{ dS m}^{-1}$) a fuertemente salino ($8.1-16 \text{ dS m}^{-1}$) de manera general. Además que a profundidades de 60 cm existe una mayor conductividad eléctrica comparada con el de 30 cm (Norma Oficial Mexicana NOM-021-RECNAT-2000).

El aumento de CE a mayor profundidad según Villafañe y Pla (1994), se debe a que las sales aumentan con la profundidad, que posiblemente proviene de la infiltración del agua por las grietas y el consecuente flujo horizontal y ascendente de agua y sales. Los registros que se obtuvieron de la humedad del suelo, esta penetra hasta los 50 cm de profundidad. Mientras que Kamphorst (1989) menciona que los Vertisoles tienen una alta capacidad expansiva cuando están húmedos reduciendo la tasa de infiltración, que al estar secos se presentan grietas anchas y profundas aumentando la infiltración inicial, pero dificulta el movimiento descendente de sales debido a que la penetración por las grietas contribuye con el desplazamiento lateral y el consiguiente movimiento ascendente de las sales.

Dada la alta solubilidad de las sales estas tienden a moverse bajo clima húmedo. Por esta razón se observa un cambio de conductividad eléctrica en cada periodo de muestreo. Los meses de agosto al mes de octubre se presenta el temporal de lluvias de la región, cuando se realizó el primer segundo y tercer muestreo.

En octubre de 2014 las lluvias resultaron por arriba de lo normal los principales estados afectados directamente según SMN fueron Jalisco, Nayarit, Baja California Sur, Sinaloa, Durango, Sonora, Michoacán. El huracán Simón (Categoría IV de la escala Saffir-Simpson, activo del 1 al 8 octubre), huracán que afecto días antes del muestreo que fue realizado el 11 y 12 de octubre del 2014, periodo donde puede observarse una menor conductividad por el nivel de humedad presente.

Según Friedman, (2005) el contenido de humedad del suelo es uno de los principales factores que influyen en la CE, dado que la conducción de la electricidad se realiza en la fase líquida presente en el suelo.

El pH de los suelos se clasifica de Neutro (6.6. a 7.3) a fuertemente alcalino (mayor a 8.5) (Norma Oficial Mexicana NOM-021-RECNAT-2000). Por lo general los suelos salinos se caracterizan por poseer un pH alto. Esto se puede deber a que las arcillas saturadas en Na tienen propiedades particulares, en presencia de agua de lluvia por tanto con CO₂ disuelto, se hidrolizan, liberando Na⁺ y OH⁻ que como consecuencia el medio se alcaliniza rápidamente, alcanzando valores de pH progresivamente cada vez más altos; que va de 9 a 10 o incluso más (Otero *et al.*, 2002).

Nolin *et al.* (1989) mencionan que, para determinar las interrelaciones entre varios atributos, son preferibles procedimientos estadísticos con enfoque multivariado, por lo que se considera más eficiente. Esta técnica multivariada comprende técnicas que producen clasificaciones a partir de datos que inicialmente no están clasificados (Johnson 1998). Por lo que Johnson y Wichern, (2007) y Rencher y Christensen, (2012), dicen que principalmente clúster y componentes principales, resultan ser más apropiados para la visualización y exploración simultánea de datos de variables regionalizadas.

Ya que en la mayoría de los estudios exploratorios, presentaron observaciones sobre un gran número de variables, sin saber inicialmente a ciencia cierta cuáles son las más importantes o más útiles para un trabajo científico, tratando de incluir todas las variables que se deducen que puedan tener alguna conexión con la investigación por lo que se tiene que reducir estos datos (trabajar con menos variables), para hacer menos complejo los cálculos y facilitar la interpretación de los resultados experimentales (Linares *et al.*, 1986).

El Modelo de Efecto Mixtos (MEM) tuvo mejores ajustes según Fang y Bailey (2001), permite un uso eficiente de los datos al controlar la variación aleatoria e individual desplazando los problemas de heterocedasticidad y autocorrelación; minimizando el cuadrado medio del error del modelo. Por lo que Bahadur (2006) menciona que el MEM es un método común y esencial para análisis de datos con una naturaleza longitudinal en donde se tienen mediciones repetidas sobre la misma unidad experimental a lo largo del tiempo y en donde la estructura de las observaciones es irregular.

Webster y Oliver (1990) han señalado que usando transformaciones como raíz del cuadrado y logaritmo, es posible conseguir una distribución de los datos normal o cercana a la normal, por

lo tanto estas son las transformaciones recomendadas con mayor frecuencia (Hair *et al.*, 1999; Osborne, 2002; Pett, 1997). Osborne (2002) sugiere con respecto a la transformación mediante la raíz cuadrada que es apta para variables continuas con valores ya sea inferior o superior a la unidad. Mientras que Cleveland (1984) y Osborne (2002) consideran un repertorio de bases (2, 10 y *exponencial* como mínimo), de modo que sea posible evaluar la eficacia de la transformación según la base y los datos a transformar. Por lo que concluye Rodríguez (2008) y Jaramillo, (2012) que las transformaciones logarítmica base 10 son las que mejores atenuando el sesgo; además, da una mejor explicación conforme a la relación entre muestras.

Se presentan varios modelos usados en geostatística, pero no todas las funciones matemáticas son apropiadas para este fin cuando se quieren realizar interpolaciones utilizando “kriging”. Para ello es necesario que la función a ajustar sea negativa semidefinida (Webster y Oliver 1990).

Para Chilés y Delfiner (1999) los principales modelos para ajustar semivariogramas son; modelo esférico, porque tiene un comportamiento lineal a distancias de separación pequeñas cerca del origen y a mayores distancias y alcanza el “sill” por lo que Webster y Oliver (2000) dicen que este modelo puede ser derivado de forma análoga al modelo lineal. Un modelo lineal tiene Nugget puro; este modelo describe un fenómeno puramente aleatorio, sin correlación entre las muestras, cualquiera que sea la distancia que las separe (Nielsen y Wendroth 2003). Modelo penta-esférico su curva es más gradual que la del modelo esférico, y en ocasiones permite ajustar los datos mejor que éste (Webster y Oliver 1997). Mientras que el modelo Gaussiano no lo es recomendable según Webster y Oliver (2001), porque su aplicación puede derivar en inestabilidades en las ecuaciones utilizadas a la hora de realizar estimaciones mediante “kriging”.

Por lo que Amador y Escobedo (2004) llevaron a cabo una estimación mediante kringing, teniendo como objetivo describir y elaborar mapas de la distribución de malezas y rendimiento de grano del maíz. Aplicando los modelos esférico, exponencial y lineal que fueron los que mejor describieron la estructura espacial de sus datos para su estudio, lo que los llevo a la conclusión de que el modelo exponencial proporcionó el mejor ajuste a los datos de población de malezas después de las escardas y del rendimiento de grano con un coeficientes de

determinación de 98%. Mientras que Zarazúa *et al.*, (2007) tuvo como objetivo analizar la variabilidad espacial del pH del suelo en tres parcelas agrícolas, correspondientes a las tres unidades de suelo más representativas en el estado de Jalisco, donde comparo en las tres parcelas los modelos esféricos y el gaussiano que los llevo a determinar obteniendo un coeficiente de determinación en el modelo gaussiano (99%) y en el esférico (61%), concordando con resultados de trabajos previos (Paz *et al.*, 1996; Solie *et al.*, 1999; Melchiori *et al.*, 2000; Brouder *et al.*, 2001; Gaston *et al.*, 2001; Hernández *et al.*, 2003) que los modelos teóricos de mejor ajuste son el Gaussiano y el esférico es decir, con mayor coeficiente de determinación.

Cruz-Cárdenas *et al.* (2013) evaluaron siete modelos en su investigación que tuvo como objetivo generar un mapa de superficie de la riqueza estimada de especies de plantas vasculares para México. Utilizaron una malla de celdas de 1° de latitud y 1° de longitud. Emplearon técnicas que les permitió, analizar la distribución espacial de los valores de riqueza conocidos, obteniendo como resultado que el mejor modelo fue el pentaesférico por un mejor ajuste a los datos riqueza total de especies.

Cortés *et al.* (2013) y Morales *et al.* (2009) reconocen que los modelos que presentan un mejor ajuste al pH son los esféricos. De igual manera, coincidió con Heil y Schmidhalter (2012) de que la CE también reflejó ajuste a un modelo esférico. Cuenta con dos características principales: que a la distancia finita el semivariograma encuentra la meseta y después de esta se mantiene de manera moderada y que tiene un comportamiento lineal cerca del origen. El modelo esférico es el único que tiene un origen verdadero, ya que tanto el modelo exponencial como el gaussiano alcanzan el origen de forma asintótica, es decir, no lo alcanzan nunca por lo que los modelos que más se utilizan para datos de suelo son las funciones espacial esférica, exponencial y gaussiana (Schabenberger y Gotway, 2004).

Según Shahid *et al.* (2013) respecto a la regresión kriging es el más apto para una estimación de valores de la salinidad del suelo, es recomendable porque es una forma de regresión lineal generalizado que surge de la formulación de una estimación óptima en un medio mínimo del error cuadrado, es decir es un predictor lineal no sesgado, lo que significa que minimiza la varianza del error de predicción (Matheron, 1962; Burgess y Webster, 1980).

Por su parte Villatoro *et al.* (2008) concluye que el método Kriging es más preciso y eficiente en el proceso de interpolación respecto a sus variables analizadas, mostrando que Kriging proporciona un análisis más elaborado y con un fundamento estadístico, por lo que este método puede ser el adecuado.

Otros autores están de acuerdo que Kriging es definido como el mejor predictor lineal no sesgado para datos espaciales (Matheron 1962, Hengl, 2009). Olmedo y Vallone (2014), en su estudio que tuvo como objetivo utilizar mediciones de sondas de conductividad eléctrica junto a estos modelos de interpolación para caracterizar la variabilidad intraparcelar de los suelos y brindar información para el manejo sitio-específico de viñedos, en prácticas de viticultura de precisión. Determinaron que el modelo de Regression-Kriging permite estimar la distribución espacial de diferentes variables edáficas. Estos modelos permiten generar superficies de distribución espacial con bajos errores de acuerdo a la validación del modelo, incluso cuando los modelos de regresión sólo pueden explicar porcentajes bajos de la variabilidad espacial.

9. CONCLUSIONES

Los resultados de la conductividad eléctrica de los suelos de Los negritos, Villamar, Michoacán, indican que se clasifican de muy ligeramente salino a extremadamente salino, conforme al modelo. Además, se puede observar que la salinidad presenta variaciones relacionadas con el clima.

Con base a la caracterización de los suelos de Los Negritos, Villamar, Michoacán se puede concluir que los valores de las propiedades estimadas presentan una tendencia similar a la realidad en cuanto a su distribución espacio-temporal. Como ejemplo los resultados demuestran que es posible generar mapas de conductividad eléctrica conforme a espacio y tiempo mediante distintas técnicas de modelado. Estas técnicas pueden llegar a generar modelos que pueden ser representados por medio de mapas con un adecuado poder predictivo (coeficientes de determinación de 99%). Es decir con un sesgo mínimo, que lleva a establecer que este modelo cuenta con un buen porcentaje de predicción.

Los modelos demostraron predecir la conductividad eléctrica en distintos periodos de tiempo en forma adecuada. Por lo tanto, se puede recomendar la aplicación de estas técnicas de modo eficaz para generar modelos de diversas variables y de gran interés en distintos periodos, lo que determina que estas herramientas son de gran utilidad. Además, estas técnicas tienen un gran potencial para diversos estudios, logrando disminuir los costos de muestreo sin perder información de la variabilidad espacial de los suelos.

Bibliografía

Allbeda, A; Kumar, L y Aldakheel Y. (2014). Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS highspatial resolution imageries: Applications in a date palm dominated region. *Geoderma*, 18: 230-231.

Allouche, O; Steinitz, D; Rotem, A; Rosenfeld y Kadmon R. (2008). Incorporating distance constraints into species distribution models. *Journal of Applied Ecology* 45: 599-609.

Álvarez, J. (1988). *Guarachita ayer... Villamar hoy: monografía municipal de Villamar, Michoacán*. México: Morelia, Michoacán de Ocampo México: H. Ayuntamiento de Villamar, Michoacán, Mexico.

Amador, M. y Escobedo, J. (2004). Distribuciones espaciales de maleza y rendimiento de maíz en labranza reducida y convencional. *Revista Fitotecnia Mexicana* 27: 223-231.

Arbona, V; Flores, V; Jacas, J; García, A. y Gómez, A. (2013). Enzymatic and non- enzymatic antioxidant responses of Carrizo cintrage, a saltsensitive citrus rootstock, to different levels of salinity. *Plant Cell Physiol Impact Factor*, 44: 388-394.

Bautista, F. y Palacio, A. (2005). Suelos, información y sociedad. En *Caracterización y Manejo de los Suelos de la Península de Yucatán: Implicaciones Agropecuarias, Forestales y Ambientales*. Instituto Nacional de Ecología. México. 9-19

Bahadur, B. (2006). Mixed-effects modeling of shortleaf pine (*pinus echinata* mil). Growth data. Thesis for doctor of philosophy. Oklahoma State University. Oklahoma, USA. 168.

Beare, M; Vikram, G; Tian y Srivastava, S. (1997). Agricultural intensification, soil biodiversity and agroecosystem function in the tropics: the role of decomposer biota. *Applied Soil Ecology* 6: 87-108.

Brouder, S; Hofmann, B. y Reetz Jr. (2001). Evaluating spatial variability of soil parameters for input management. *Better Crops Plant Food* 85: 8-11.

Burgess, T. y Webster, R. (1980) Optimal interpolation and isarithmic mapping of soil properties. I. The semi-variogram and punctual kriging. *Journal of Soil Science* 31:315-331.

Burrough, P. y McDonnell, R. (1998). *Principles of Geographical Information Systems*, Oxford University Press, Oxford, Reino Unido. 346.

Camiña, F. (2014). *GLM y modelos mixturados para el estudio de los efectos de la consanguinidad sobre la fertilidad en la dinastía real de los Habsburgo*. Santiago de Compostela: Universidad de Santiago de Compostela. Coruña, España.

Casall, J. y Mateu, E. (2003). Tipos de muestreo. *Revista Epidemic Preventive Medicine*.1:3-7.

Chilés, J. y Delfiner, P. (1999). *Geostatistics: Modeling spatial uncertainty*. John Wiley y Sons, Nueva York, USA. 695.

Clay, D; Kitchen, N; Carlson, C; Kleinjan J. y Chang, H. (2007). Using historical management to reduce soil sampling errors. In: D. Clay And F. Pierce. *Gis Application In Agriculture*. CRC Press. USA. 49- 64.

Cortés, D; Jhon, H; Pérez, B. y Camacho, J. (2013). Relación espacial entre la conductividad eléctrica y algunas propiedades químicas del suelo. *Revista U.D.C.A Actualidad y Divulgación Científica* 16: 401-408.

Corwin, L. y Lesch, M. (2003). Application of Soil Electrical Conductivity to Precision Agriculture: Theory, Principles, and Guidelines. *Agronomy Journal*, 95: 455-471.

Corwin, L; Lesh, M; Oster, D. y Kaffka, R. (2006). Monitoring management-induced spatio-temporal changes in soil quality through soil sampling directed by apparent electrical conductivity. *Geoderma*, 131: 369-387.

Cressie N. (1989). Geostatistics. *The American Statistician*, 43: 197-202.

Cruz-Cárdenas, G; Villaseñor, J; López, L. y Ortiz, E. (2013). Distribución espacial de la riqueza de especies de plantas vasculares en México. *Revista Mexicana de Biodiversidad*, 84: 1189-1199.

Dagar, J. (2010). Opportunities for sustainable utilization of salt-affected lands and poor quality waters for livelihood security and mitigating climate change through agroforestry systems. En proceedings of the global forum on salinization and climate change. Valencia: Food and Agriculture Organization of The United Nations. España. 189-193.

D'Almeida, D; Andrade, E; Meireles, A y Ness, R. (2005). Importancia relativa dos íons na salinidade de um Cambissolo na Chapada do Apodi, Ceará. *Associação Brasileira de Engenharia Agrícola*, 25: 615-621.

Dehaan, R y Taylor, R. (2002). Field-derived spectra of salinized soils and vegetation as indicators of irrigation-induced soil salinization. *Elsevier Science Inc*, 80: 406-417.

Deutsch, C y Journel, A. (1998). *GSLIB: Geostatistical Software Library and User's Guide*. USA: OUP. New York, USA.

Díaz, V. (2002). *Geoestadística aplicada*. Instituto de Geofísica, Universidad Nacional Autónoma de México. Recuperado (3 de febrero 2014), de (<http://mmc2.geofisica.unam.mx/cursos/geoest/GeoEstadistica.pdf>)

Diggle, P. y Ribeiro P. (2007). *Model-based Geostatistics*. Springer. New York, USA. 241.

Elmetwalli, A; Tyler, A; Hunter, P. y Salt, C. (2012). Detecting and distinguishing moisture- and salinity-induced stress in wheat and maize through in situ spectroradiometry measurements. *Remote Sensing Letters*, 4: 363-372.

Estrada, F. (2008). *Calidad química del agua subterránea como factor de degradación de los suelos de la Ciénega de Chapala*. Tesis Maestría: CIIDIR-Unidad Michoacán. Jiquilpan, Michoacán.

European Communities. (2009). *Salinization and sodification*. Sustainable Agricultural and Soil Conservation. Soil degradation processes. Recuperado (3 de febrero 2014), de (<http://www.eusoils.jrc.ec.europa.eu/projects/SOCO/FactSheets/ENFactSheet-04.pdf>)

Fang, Z. y Bailey, R. (2001). Nonlinear mixed effects modeling for slash pine dominant height growth following intensive silvicultural treatments. *Forest Science* 47(3): 287-300.

Fernández, R. (1990). Algunas experiencias y proposiciones sobre recuperación de suelos con problemas de sales en México. *Terra*. 8: 226-240.

Freitas, H y Castro, P. (2010). Salinity issues in Portugal: Coastal aquifers. En *Proceedings of the Global Forum on Salinization and Climate Change Valencia: Food and Agriculture Organization of The United Nations*. España. 156.

Friedman, S. (2005). Soil properties influencing apparent electrical conductivity: a review. *Computers and Electronics in Agriculture* 46: 45-70.

Gaston, L; Locke, M; Zablutowicz, y Reddy, K. (2001). Spatial variability of soil properties and weed populations in the Mississippi delta. *Soil Science Society of America Journal* 65: 449-459

Ginzo, M. (2014). Análisis Geoestadístico de datos funcionales. Tesis Maestría: B Universidad de Santiago de Compostela. Coruña, España

GIS Development Team. (2015). QGIS Un Sistema de Información Geográfica libre y de Código Abierto. Recuperado (23 de enero 2014), de (<http://www.qgis.org/es/site/>)

Hair, J; Anderson, R; Tatham, R. y Black, W. (1999). Análisis Multivariante. Prentice Hall. 4ª edición. España.

Hengl, T; Heuvelink, G. y Stein. A. (2004). A generic framework for spatial prediction of soil variables based on regression-Kriging. *Geoderma* 122: 75-93.

Hengl, T; Heuvelink, G. y Rossiter, D. (2007). About regression-Kriging: From equations to case studies. *Computers and Geosciences* 33: 1301-1315.

Hengl, T; Sierdsema, A; Radovi y Dilo, A. (2009). Spatial prediction of species' distributions from occurrence-only records: combining point pattern analysis, ENFA and regression-Kriging. *Ecological Modelling* 220: 3499–3511.

Henríquez, C; Killorn, R; Bertsch, F. y Sancho, F. (2005). La geostatística en el estudio de la variación espacial de la fertilidad del suelo mediante el uso del interpolador kriging. *Agronomía Costarricense* 29 (2):73-81.

Hernández, A; Lugo, A; Mora, J; Sánchez y Arends, E. (2003). Variabilidad espacial edáfica en el sistema tradicional de conucos en el Amazonas de Venezuela. *Investigación Agraria. Sistemas Recursos Forestales* 12: 43-54.

Heuvelink, D; Griffith, T. y Melles, S. (2012). Sampling design optimization for space-time kriging. En *Spatio-Temporal Design: Advances in Efficient Data Acquisition*. John Wiley y Sons. USA. 207-230

Iglesias, D; Levy, Y; Gómez, A; Tadeo, F; Primo, F. y Talon, M. (2004). Nitrate improves growth in salt-stressed citrus seedlings through effects on photosynthetic activity y chloride accumulation. *Tree Physiol.* 24: 1027-1034.

Im-Erb, R. y Pongwichian, P. (2003). Salt-affected Soils in Thailand. Workshop on the Management of Salt-affected Soil. Department of Agriculture. Bangkok Thailand. 13

INAFED. (2010). VILLAMAR. Recuperado (31 de enero 2014), de (<http://www.inafed.gob.mx/work/enciclopedia/EMM16michoacan/municipios/16104a.html>)

INEGI (2014). Imágenes de satélite. Recuperado (21 de febrero 2014) de (<http://www.inegi.org.mx/geo/contenidos/imgpercepcion/imgsatelite/landsat.aspx>)

INTAGRI. (2013). La salinidad de los suelos, un problema que amenaza su fertilidad. Recuperado (3 de febrero 2014), de (<http://www.engormix.com/MA-agricultura/articulos/salinidad-suelos-problema-amenaza-t5372/p0.htm>)

Jaramillo, D. (2012). Ariabilidad Espacial Del Suelo: Bases Para Su Estudio. *Revista De La Facultad De Ciencias Universidad Nacional de Colombia, Sede Medellín*, 1: 73 - 87.

Jiménez, H; Carvajal, Y; Calero, A y Romero, G. (2010). Salt-affected soils and climate change in the Valle del Cauca, Colombia. En *Proceedings of the Global Forum on Salinization and Climate Change*. Food and Agriculture Organization of the United Nations. Valencia, España. 34-40

Johnson, D. (1998). Métodos multivariados aplicados al análisis de datos. International Thomson Editores, D.F, México. 566.

Johnson, R. y Wichern, D. (1988). Applied Multivariate Statistics Analysis, 2nd Edition. Prentice-hall, New Jersey, USA. 607.

Journel, A. y Huijbregts, Ch. (1978). Mining Geostatistics. Academic Press. Published by London - New York, USA.

Khorram, S; Nelson, S; Koch, F. y van der Wiele, F. (2012). Remote Sensing. utg. Boston, MA: Springer USA.

Khorram, S; Nelson, S; Koch, F. H. y van der Wiele, C. F. (2012). Remote Sensing. 2012. International Space University, Springer. Boston, USA. 141

Kamphorst, A. (1989). Water and salt transport in the irrigated cracking clay soils of the Kachhi Plains, Pakistan. Part II: Horizontal transport. Soil Technology. Elsevier Science Inc, 2: 101-106.

Kumar, L; Schmidt, K; Dury, S. y Skidmore, A. (2001). Imaging Spectrometry: Basic Principles and Prospective Applications. Imaging spectrometry and vegetation science. Springer, Netherlans 4: 111-155.

Lamz, A y González, M. (2013). La salinidad como problema en la agricultura: la mejora vegetal una solución inmediata. *Revista "Cultivos Tropicales"* (cultrop). La Habana, Cuba. 34 (4): 31-42.

Lin, Y. (2002). Multivariate geostatistical methods to identify and map spatial variations of soilheavy metals. *Environmental Geology*. 42: 1-10.

Linares, G; Acosta, L y Vega, V. (1986). Estadistic multivariada. Universidad de la Habana. Facultad de matemáticas cibernética. Cuba. 31-51.

McCulloch, C y Shayle S. (2005). Generalized, Linear, and Mixed Models. John Wiley y Sons, Inc. New Jersey, USA.

Maestre, F; Escudero, A. y Bonet, A. (2008). Introducción al análisis espacial de datos en ecología y ciencias ambientales: Métodos y aplicaciones. Dykinson, S.L. Madrid, España.

Martins, N; da Silva, M; Rogério, C; Alves. M, y Mara. P. (2007). Métodos de ajuste e modelos de semivariograma aplicados ao estudo da variabilidade espacial de atributos físico-hídricos do solo. Revista Brasileira de Ciência do Solo, 31 (3): 435-443.

Matheron, G. (1962) “Traité de Géostatistique Appliquée”. Tome 1. Edit. Technip. París, Francia.

Melchiori, R; García, O y Echeverría, H. (2000). Variabilidad espacial en algunas propiedades del suelo. I. Asociación con las variaciones en el rendimiento del trigo. Recuperado (12 de noviembre 2014) de ([http:// www.agriculturadeprecision.org/articulos/articulos.htm](http://www.agriculturadeprecision.org/articulos/articulos.htm))

Mess, F. (2003). Salt mineral distribution patterns in soils of the Otjomongwa pan, Namibia. Catena 54: 425-437.

Metternicht, G. y Zinck, J. (2008). Remote Sensing of Soil Salinization: Impact on Land Management. CRC Press, Taylor and Francis. New York, USA

Miller, J. Franklin y Aspinall, R. (2007). Incorporating spatial dependence in predictive vegetation models. Ecological Modelling 202: 225–242.

Morales, L. Paz, F. (2009). Geostatistical analysis of pH and redox potential (Eh) variability over a rice field in successive crop stages. Estudios en la zona no saturada del suelo. Barcelona, España. 9: 9.

Mulla, D. y McBratney, A. (2002). Soil spatial variability. in Soil Physics Companion A.W. Warrick. New York, USA. 343-360.

NASA (2014). Landsat 8. Recuperado (21 de febrero 2014) de (http://landsat.gsfc.nasa.gov/?page_id=4071)

Naidu, R. Sumner, E. y Rengasamy, P. (1995). Australian sodic soils: distribution, properties and management. VIC: CSIRO East Melbourne, Australia.

Nelder, J y Wedderburn, J. (1972). Generalized Linear Models. Journal of the Royal Statistical Society. Londres. 135 (3): 370-384.

Nielsen, D. y Wendroth, O. (2003). Spatial and temporal statistics: sampling field soils and their vegetation. Reiskirchen: Catena Verlag GMBH. Alemania. 398.

Niño, L. (2008). Uso de la función semivariograma y estimación kriging en el análisis espacial de un indicador entomológico de *Aedes aegypti* (Diptera: Culicidae). Biomédica: Revista del Instituto Nacional de Salud. Colombia. 28 (4). 578-86

Nolin, M; Wang, C. y Caillier, M. (1989). Based on selected soil characteristics of the plow layer. Canadian Journal of Soil Science 69: 525-541.

Norma Oficial Mexicana NOM-021-RECNAT-2000. (2002). Que establece las especificaciones de fertilidad, salinidad y clasificación de suelos. Recuperado (21 de febrero 2014) de (http://dof.gob.mx/nota_detalle.php?codigo=717582&fecha=31/12/2002).

Olmedo, G. y Vallone, R. (2014). Caracterización de la variabilidad intraparcilaria de suelos mediante sensores proximales. Congreso Argentino de la Ciencia del Suelo II Reunión Nacional “Materia Orgánica y Sustancias Húmicas”. Recuperado (13 de marzo 2014), de (http://www.researchgate.net/publication/272507206_CHARACTERIZACION_DE_LA_VARIABILIDAD_INTRAPARCELARIA_DE_SUELOS_MEDIANTE_SENSORES_PROXIMALES)

Omuto, C. y Vargas, R. (2015). Re-tooling of regression kriging in R for improved digital mapping of soil properties. Geosciences Journal, 19: 157-165

Osborne, J. (2002). Notes on the use of data transformations. Practical Assessment, Research and Evaluation. Recuperado (5 de febrero 2005) de (<http://pareonline.net/getvn.asp?v=8&n>).

Otero, L; Cintra, M. y Curbelo, R. (2002): Parámetros de los indicadores más importantes que definen el mejoramiento de la productividad de los suelos salinos de Cuba. Instituto de Suelos. Ministerio de la agricultura. Cuba. 05:170.

Ovalles, F. (1999). Evaluación de tierras en zonas tropicales. Generación y análisis de la información. Muestreo. II curso de postgrado "Manejo de suelos tropicales". Centre Tecnològic Forestal de Catalunya. Universidad de Llerida. Solsona. España. 34.

Pal, D; Srivastara, P; Durge, S. y Bhattacharyya, T. (2003). Role of microtopography in the formation of sodic soils in the semiarid part of the Indo-Gangetic Plains, India. *Catena*51: 3-31.

Paz, A; Gómez y Taboada, M. (1996). Análisis geoestadístico de las propiedades generales de un suelo de cultivo. *Investigación Agraria: Producción y Protección Vegetal* 11: 133-160.

Pebesma, E y Graler, B. (2014). Spatio-temporal geostatistics using gstat. Institute for Geoinformatics University of Münster. Centre Tecnològic Forestal de Catalunya Universitat de Lleida. Recuperado (6 de enero 2014) de (<http://cran.rapporter.net/web/packages/gstat/vignettes/st.pdf>).

Peñuelas, J. Isla, I. Filella, J y Araus, J. (1997). Visible and near infrared reflectance assessment of salinity effects on barley. *Crop Sci.* 37:198-202.

Pérez, M. y García, M. (2013). Aplicaciones de la teledetección en degradación de suelos. *Boletín de la Asociación de Geógrafos Españoles.* 61:285-308.

Petersen, G; Bell, J; Mcsweeney, K; Nielsen, G. y Robert, P. (1995). Geographic information systems in agronomy. *Advances in Agronomy* 55:67-105.

Pett, M. (1997). *Nonparametric statistics for health care research.* Sage Publications. London, Thousand Oaks, New Delhi.

Pitman M. y Läuchli A. (2002). Global impact of salinity and agricultural ecosystems. En *Salinity: environment-plant-molecules.* Kluwer Academic Publishers. The Netherlands: 3-20.

R Core Team. (2015). The R Project for Statistical Computing. Recuperado (23 enero 2013), de (<https://www.r-project.org/>).

Rencher, A. y Christensen, W. (2012). *Methods of Multivariate Analysis*. 3rd ed. Hoboken, NJ: Wiley. USA.

Reyes, C. (2010). Estimación paramétrica y no paramétrica de la tendencias en datos con dependencia espacial. Un estudio de simulación. Recuperado (21 de febrero 2014) de (http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_401.pdf)

Romallo, R. (1998). *Tratamientos de aguas residuales*. Reverte, S.A de C.V. México.

Rosas, J y Urrutia J. (1992). Magneto estratigrafía volcánica de la zona geotérmica Ixtlan de los Hervores-Los Negritos, Michoacan. *Geofísica Internacional: México*. 31:(4), 431-442.

Saa Vidal; Santibáñez, F. y Orozco, P. (2010). *Informe País: Estado del Medio Ambiente en Chile*. Centro de Análisis de Políticas Públicas. Chile.

Sánchez, A; Álvarez, T; Sáenz, R; Ortiz, M; López, B. y Aguñiga, S. (2008). Distribución de parámetros texturales de los sedimentos superficiales en la Bahía de Chetumal: Implicaciones en la inferencia de transporte. *Revista Mexicana de Ciencias Geológicas*, 25: 523-532.

Samper F. y Carrera J. (1990). *Geoestadística. Aplicaciones a la hidrogeología subterránea*. Centro internacional de métodos numéricos en ingeniería. Centro Internacional de Métodos Numéricos en Ingeniería. Barcelona, España.

Seoane, J. (2014). *Análisis bioestadístico con modelos de regresión en R*. Universidad Autónoma de Madrid. Recuperado (5 de febrero 2014) de (https://www.uam.es/personal_pdi/ciencias/jspinill/CFCUAM2013/ModelosMixtos-01-Anidados_CFCUAM2013.html)

SERMANAT y SAGARPA. (2010). *Salinidad del suelo*. Recuperado (22 de febrero 2014) de (<http://www.cofupro.org.mx/cofupro/images/contenidoweb/indice/publicaciones-nayarit/FOLLETOS%20Y%20MANUALES/FOLLETOS%20IMTA%202009/folleto%206%20saliniddelsuelo.pdf>)

Shahid, S; Abdelfattah, M. y Taha, F. (2013). *Developments in Soil Salinity Assessment and Reclamation*. Springer. London New York.

Schabenberger, O y Gotway, C. (2004). *Statistical Methods for Spatial Data Analysis*. Texts in Statistical Science. Chapman and Hall/CRC. Boca raton, USA.

Sharma, C. y Bhargawa P. (1988). Landsat imagery for mappin saline soils and wet lands in North- West India, *Inter: Journal Remote Sensing*, 19: 39-44

Schilfgaarde, J. (1999). *American Journal of Alternative Agriculture*. *American Journal of Alternative Agriculture*, 14: 43-46.

Schmid, T; Koch, M. y Gumuzzio, J. (2005). Multisensor approach to determine changes of wetland characteristics in semiarid environments (central Spain). *Geoscience and Remote Sensing, IEEE Transactions*, 43: 2516 - 2525.

Silva, J; Ochoa, S y Estrada, F. (2006). Calidad química del agua subterránea de la ciénega de Chapala como factor de degradación del suelo. *Terra Latinoamericana*, 24(4): 503-513.

SOCO Sustainable agriculture and soil conservation Soil degradation processes (2009). Salinisation and sodification. Recuperado (18 de febrero 2014) de (<http://eusoiils.jrc.ec.europa.eu/Projects/SOCO/FactSheets/ENFactSheet-04.pdf>).

Solie, J; Raun, W y Stone, M. (1999). Submeter spatial variability of selected soil and bermudagrass production variables. *Soil Science Society of America Journal* 63: 1724-1733.

Sommer, R., Denich, M y Vlek, P. (2000). Carbon storage and root penetration in deep soils under small-farmer land-use systems in the Eastern Amazon region, Brazil. *Plant and Soil* 219: 231- 241.

Spadavecchia, L. y Williams, M. (2009) Can Spatio-Temporal Geostatistical Methods Improve High Resolution Regionalisation of Meteorological Variables? *Agricultural and Forest Meteorology*, 149: 1105-1117.

Spies, B. y Woodgate, P. (2004). Salinity Mapping in the Australian context. Technical Report. The Department of the Environment and Heritage; and Agriculture, Fisheries and Forestry Land and Water Australia. 153.

Rodríguez, M. y Ruiz, M. (2008). Atenuación de la asimetría y de la curtosis de las puntuaciones observadas mediante transformaciones de variables: Incidencia sobre la estructura factorial. *Psicológica*, 29: 205-227.

Rueda, E. (2009). La salinidad: ¿un problema o una opción para la agricultura?. Plaza y valdés. Sonora, Mexico.

Russell, E. y Wild, A. (1992). Condiciones del suelo y desarrollo de las plantas según Russell. Mundi-Prensa. London, Canada 1045

Tanji, K. (2002). Salinity in the soil environment. In: Salinity: environment-plantsmolecules. En Salinity: environment-plant-molecules. The Netherlands: Kluwer Academic Publishers. 21-51.

Villafañe, R. y Pla, I. (1994). Efectos del riego y la lluvia sobre el desplazamiento vertical de sales en un suelo arcilloso de Venezuela. *Agronomía Tropical* 44 (4): 707-729.

Villatoro, M. Henríquez, C. Sancho, F. (2008). Comparación de los interpoladores idw y kriging en la variación espacial de pH, Ca, CICE y P del suelo. *Agronomía Costarricense*, Costa Rica.32: 95-105.

Viscarra, R. Walvoort, J. McBratney, L. Janik, A y Skjemstad, O. (2006). Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma* 131: 59–75.

Webster, R. y Oliver, M. (1990). Statistical methods in Soil and Land Resources Survey. Oxford University Press. Oxford, Reino Unido. 316.

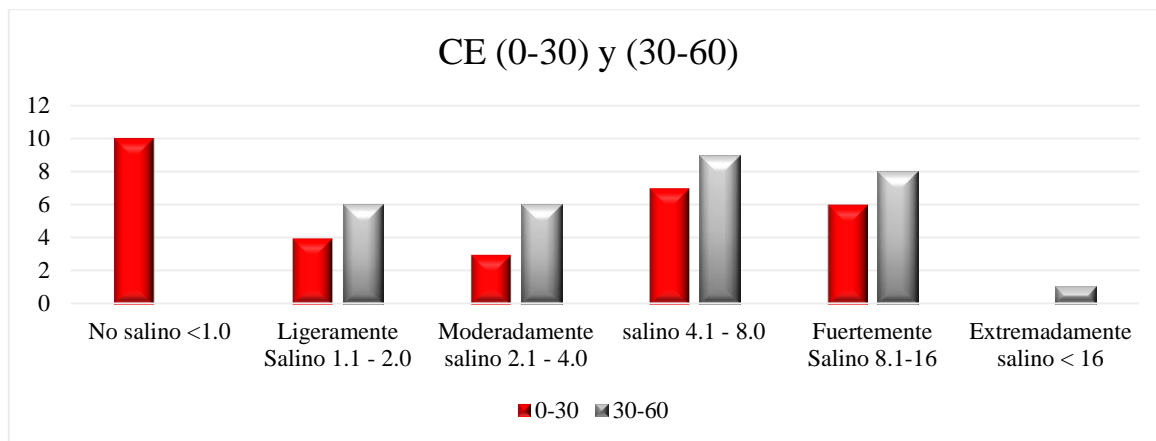
Webster, R. y Oliver, M (2000). Geostatistics for Environmental Sciences. John Wiley and Sons. Canada. 271.

Webster, R. y M. Oliver. (2001). *Geostatistics for environmental science*. John Wiley and Sons, Toronto, Canadá.

Zarazúa, P. González, D. Nuño, R. Ruiz, J. Torres, J. (2007). Variabilidad espacial del pH del suelo en tres parcelas agrícolas. *Terra Latinoamericana*, 25: 203-210.

Zhang, T. Zeng, S. Gao, Y. Ouyang, Z. Li, B. Fang, C. y Zhao, B. (2011). Using hyperspectral vegetation indices as a proxy to monitor soil salinity. *Ecological Indicators*, 11:(6), 1552–1562.

ANEXOS



Cuadro 7. Modelos Lineales generalizados (MGL) de las variables del suelo (0-30 cm) del primer muestreo

Variable dependiente	Variable independiente	R ² 1	R ² 2	P-valué
CE	2*,3*,4,5*,6,7	0.302	0.264	0.742
pH	2*,3*,4,5*,6*,7*	0.473	0.469	0.674
M.O	2,3,4*,5,6*,7	0.215	0.157	0.7789
Ca	2,3*,4,5*,6,7	0.2587	0.2006	0.1152
Mg	2,3*,4,5*,6,7	0.3024	0.299	0.946
Na	2*,3*,4,5*,6,7	0.2005	0.1144	0.7766
K	2*,3,4,5*,6,7	0.3291	0.3219	0.9688
CO ₃ ²⁻	2,3,4,5*,6,7*	0.2392	0.2256	0.8156
HCO ₃ ⁻	2,3,4,5,6,7	0.1592	0.06553	0.764
Cl ⁻	2*,3,4,5,6,7	0.1704	0.1704	0.8607
SO ₄ ²⁻	2,3,4*,5,6,7	0.2937	0.2746	0.8902

R²1= Modelo original

R²2= Modelo ajustado

*Variables seleccionadas con modelo ajustado

P-value de anova de varianza de la comparación del modelo original y el ajustado.

Cuadro 8. Modelos Lineales generalizados (MGL) de las variables del suelo (30-60 cm) del primer muestreo

Variable dependiente	Variable independiente	R ² 1	R ² 2	P-valué
CE	2,3*,4,5,6,7	0.223	0.156	0.583
pH	2,3*,4,5,6,7	0.284	0.217	0.710
M.O	2,3,4,5,6,7	0.094		0.872
Ca	2*,3*,4,5*,6,7	0.2068	0.1979	0.9668
Mg	2,3,4,5*,6,7	0.2079	0.1754	0.8147
Na	2,3,4,5,6,7	0.1826		0.541
K	2,3,4,5*,6,7	0.1899	0.1734	0.925
CO ₃ ²⁻	2,3,4,5,6,7	0.07149		0.933
HCO ₃ ⁻	2*,3,4,5,6,7	0.1997	0.19	0.9633
Cl ⁻	2,3,4,5*,6,7	0.232	0.175	0.6405
SO ₄ ²⁻	2*,3*,4,5*,6,7	0.2469	0.23	0.9142

R²1= Modelo original

R²2= Modelo ajustado

*Variables seleccionadas con modelo ajustado

P-value de anova de varianza de la comparación del modelo original y el ajustado

Cuadro 9. Análisis exploratorio de las variables del suelo (0-30 cm) del primer muestreo

Var.	D. Orig.	Log. 10	Log. +1	√ 2	√ 4
CE	0.00053	0.02656	0.00768	0.00636	0.01603
pH	0.1735	0.2578	0.2481	0.2136	0.2352
M.O	0.03489	0.00161	0.00314	0.00809	0.00365
Ca	7.86E-5	0.01057	0.01125	0.00866	0.0208
Mg	2.98E-7	0.00420	0.00030	1.51E-5	0.00026
Na	1.51E-5	0.00566	0.00253	3.54E-6	0.00015
K	0.00020	3.14E-6	6.71E-6	2.17E-5	7.39E-6
CO ₃ ²⁻	5.42E-8	0	0.00165	0.00089	0.00011
HCO ₃ ⁻	0.00195	0.3857	0.5113	0.00089	0.00011
Cl ⁻	3.77E-6	0.05504	0.3819	0.00892	0.3749
SO ₄ ²⁻	0.08826	0.6771	0.2132	0.509	0.677

Var= Variables

D. Orig= Datos originales

Cuadro 10. Análisis exploratorio de las variables del suelo (30-60 cm) del primer muestreo

Var.	D. Orig.	Log. 10	Log. +1	√ 2	√ 4
CE	0.007117	0.3656	0.3885	0.279	0.4915
pH	0.05815	0.09163	0.08757	0.07346	0.08218
M.O	0.004453	0.305	0.1451	0.04649	0.1304
Ca	3.18E-5	0.1071	0.0643	0.02644	0.2915
Mg	3.80E-6	0.1012	0.03646	0.000747	0.02404
Na	3.35E-9	0.00015	5.58E-5	1.55E-7	3.71E-6
K	0.003288	6.79E-8	8.76E-7	9.65E-6	6.30E-7
CO ₃ ²⁻	4.29E-9	0.05471	3.16E-5	2.35E-6	0.00033
HCO ₃ ⁻	0.001339	0	0.00	2.35E-6	0.00033
Cl ⁻	3.17E-5	0.09943	0.04731	0.00310	0.02608
SO ₄ ²⁻	0.1125	0.133	0.2125	0.2769	0.2348

Var= Variables

D. Orig= Datos originales

Cuadro 11. Análisis Estructural de las variables del suelo (0-30 cm) del primer muestreo

Modelo variograma	Esférico	Exp	Gauss	Lineal	Matern	Bassel	Pentaesf
CE	5.55E-7	2.47E-5	5.71E-7	5.74E-7	2.47E-5	2.47E-5	5.60E-7
pH	1.03E-11	6.23E-12	5.54E-12	5.29E-12	6.23E-12	1.21E-11	7.66E-12
M.O	1.21E-5	1.97E-5	0.000416	1.22E-5	1.97E-5	3.89E-5	1.22E-5
Ca	8.41E-7	1.99E-5	7.48E-7	6.84E-7	1.99E-5	1.99E-5	7.17E-7
Mg	3.86E-6	0.00029	3.97E-6	4.27E-6	0.000291	4.04E-6	3.92E-6
Na	2.15E-6	3.47E-5	2.17E-6	1.90E-6	3.47E-5	3.47E-5	2.19E-6
K	0.012827	0.00356	0.012312	0.0062078	0.003567	0.003556	5.193809
CO ₃ ²⁻	2.72E-7	2.97E-7	2.87E-7	2.48E-7	2.97E-7	1.34E-5	2.75E-7
HCO ₃ ⁻	1.97E-7	1.52E-7	1.43E-7	1.71E-7	1.52E-7	1.49E-7	2.65E-7
Cl ⁻	4.947E-5	4.617E-5	4.596E-5	3.995E-5	4.617E-5	4.546E-5	5.089E-5
SO ₄ ²⁻	2.24E-8	5.29E-7	2.91E-8	1.91E-8	5.29E-7	5.29E-7	1.62E-8

Cuadro 11.1. Modelos Teóricos ajustados a los semivariogramas expuestos de las variables del suelo (0-30 cm)

Variable	Nugget	Psill	Range
CE	0.000	0.205	423.262
pH	0.000	0.000	535.279
M.O	0.000	0.557	526.051
Ca	0.000	0.193	438.727
Mg	0.000	0.715	441.764
Na	0.000	0.269	506.902
K	13.964	0.000	525.365
CO ₃ ²⁻	0.000	0.158	429.783
HCO ₃ ⁻	0.000	0.077	298.554
Cl ⁻	0.000	1.194	426.766
SO ₄ ²⁻	0.030	0.000	685.012

Cuadro 12. Análisis Estructural de las variables del suelo (30-60 cm) del primer muestreo

Modelo variograma	Esférico	Exp	Gauss	Lineal	Matern	Bassel	Pentaesf
CE	1.45E-07	1.62E-07	1.37E-07	1.44E-07	1.62E-07	1.37E-07	2.01E-06
pH	7.90E-09	3.18E-11	2.57E-11	1.06E-09	3.18E-11	5.56E-11	2.72E-08
M.O	2.92E-09	2.99E-09	3.01E-09	3.14E-09	2.99E-09	8.91E-08	2.93E-09
Ca	3.02E-09	8.91E-08	3.09E-09	3.03E-09	8.91E-08	8.91E-08	2.91E-09
Mg	6.81E-06	7.48E-06	7.02E-06	6.18E-06	7.48E-06	0.000201	6.92E-06
Na	1.09E-05	7.13E-06	2.06E-04	2.34E-03	7.13E-06	6.99E-06	3.13E-03
K	0.001325	0.001344	0.001354	0.001376	0.001344	0.001308	0.001309
CO ₃ ²⁻	1.17E-06	1.18E-06	1.21E-06	1.14E-06	1.18E-06	1.89E-05	1.17E-06
HCO ₃ ⁻	0.000509	0.000505	0.000512	0.000510	0.000505	0.000504	0.000513
Cl ⁻	2.11E-06	2.76E-06	1.50E-06	1.87E-06	2.76E-06	1.77E-06	2.72E-06

SO_4^{2-}	0.000818	1.30E-05	1.30E-05	1.34E-05	1.30E-05	2.21E-05	1.96E-05
--------------------	----------	----------	----------	----------	----------	----------	----------

Cuadro 12.1. Modelos Teóricos ajustados a los semivariogramas expuestos de las variables del suelo (30-60 cm)

Variable	Nugget	Psill	Range
CE	0.0935	0.0000	685.0117
pH	0.0002	0.0003	815.1016
M.O	0.0000	0.0123	488.7354
Ca	0.0000	0.0122	462.1683
Mg	0.0000	0.6161	440.2778
Na	0.1593	7.9738	15069.9400
K	0.0000	9.9478	213.5773
CO₃²⁻	0.0000	0.1878	449.0373
HCO₃⁻	0.0000	4.4460	173.5501
Cl⁻	751.5170	0.0000	751.5170
SO₄²⁻	0.8799	0.0004	300.3520

ANEXO FOTOGRÁFICO





