



# **COLEGIO DE POSTGRADUADOS**

INSTITUCIÓN DE ENSEÑANZA E INVESTIGACION EN CIENCIAS AGRÍCOLAS

**CAMPUS MONTECILLO**

**POSTGRADO EN HIDROCIENCIAS**

## **DETECCIÓN DE SALINIDAD DE SUELOS AGRÍCOLAS DEL EX LAGO DE TEXCOCO, MEDIANTE EL USO DE DRONES**

**MARIO FRANCISCO SANTOYO DE LA CRUZ**

**T E S I S:**

**PRESENTADA COMO REQUISITO PARCIAL  
PARA OBTENER EL GRADO DE:**

**DOCTOR EN CIENCIAS**

**MONTECILLO, TEXCOCO, ESTADO DE MÉXICO**

**2021**

La presente tesis titulada: DETECCIÓN DE SALINIDAD DE SUELOS AGRÍCOLAS DEL EX LAGO DE TEXCOCO, MEDIANTE EL USO DE DRONES. Realizada por el alumno: MARIO FRANCISCO SANTOYO DE LA CRUZ. Bajo la dirección del consejo particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

DOCTOR EN CIENCIAS

HIDROCIENCIAS

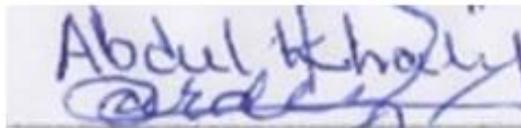
CONSEJO PARTICULAR



CONSEJERO

---

DR. HÉCTOR FLORES MAGDALENO



ASESOR

---

DR. ABDUL KHALIL GARDEZI



ASESOR

---

DR. OSCAR RAÚL MANCILLA VILLA



ASESOR

---

DR. JUAN ENRIQUE RUBIÑOS PANTA

Montecillo, Texcoco, estado de México, febrero de 2021

# **DETECCIÓN DE SALINIDAD DE SUELOS AGRÍCOLAS DEL EX LAGO DE TEXCOCO, MEDIANTE EL USO DE DRONES**

**Mario Francisco Santoyo de la Cruz, D.C.**

**Colegio de Postgraduados, 2021**

## **RESUMEN**

La salinidad del lago de Texcoco se debe a que fue una cuenca endorreica, no tenía forma de lavar las sales de las desgastadas elevaciones montañosas formadas por roca ígnea y tobas volcánicas. Los suelos del ex lago de Texcoco presentan horizontes de carbonato de calcio que forman horizontes cálcicos y petrocalcicos. Los Vehículos aéreos no tripulados (VANT) son aviones propulsados operados de forma remota. Los datos de teledetección tienen la capacidad de capturar información en suelos afectados por la sal. Varios algoritmos y modelos han sido desarrollado para procesar datos de teledetección de salinidad. El objetivo de este trabajo es analizar y comparar la composición iónica y la relación de adsorción de sodio – porcentaje de sodio intercambiable explícita y ajustada de un terreno agrícola con lo anterior se relacionó con las reflectancias de las imágenes multiespectrales y con los índices de salinidad, para estimar variables de salinidad utilizando redes neuronales y arboles de decisión. El objetivo principal es la detección y clasificación de la salinidad del suelo. El catión más dominante es el sodio. El predio es salino – sódico. Las imágenes interpoladas y las curvas de nivel dan una visión artificial de la relación de adsorción de sodio y el porcentaje de sodio intercambiable La red neuronal presento una precisión de 69.56% en RAS, 76.12% PSI y 71.88% en sodio, mientras que el árbol de decisión 67% RAS, 61% PSI y 56% en sodio. La simplicidad de los modelos y el grado de precisión los convierten en una herramienta prometedora.

**Palabras clave:** Arboles de decisión, drones, índices de salinidad, redes neuronales, reflectancias, sodio, Salinidad y Sodicidad.

# **DETECTION OF SALINITY OF AGRICULTURAL SOILS OF THE EX LAKE OF TEXCOCO, THROUGH THE USE OF DRONES**

**Mario Francisco Santoyo de la Cruz, D.C.**

**Postgraduate College, 2021**

## **ABSTRACT**

The salinity of Lake Texcoco is due to the fact that it was an endorheic basin, it had no way of washing the salts from the worn mountainous elevations formed by igneous rock and volcanic tuffs. The soils of the former lake of Texcoco present calcium carbonate horizons that form calcium and petrocalcic horizons. Unmanned Aerial Vehicles (UAVs) are remotely operated propelled aircraft. Remote sensing data has the ability to capture information on salt-affected soils. Various algorithms and models have been developed to process salinity remote sensing data. The objective of this work is to analyze and compare the ionic composition and the sodium adsorption ratio-explicit and adjusted exchangeable sodium percentage of an agricultural land with the above related to the reflectances of the multispectral images and the salinity index, to estimate salinity variables using neural networks and decision trees. The main objective is the detection and classification of soil salinity. The most dominant cation is sodium. The property is saline - sodium. The interpolated images and the contour lines give an artificial vision of the sodium adsorption ratio and the exchangeable sodium percentage. The neural network presented an accuracy of 69.56% in SAR, 76.12% ESP and 71.88% in sodium, while the tree decision 67% SAR, 61% ESP and 56% in sodium. The simplicity of the models and the degree of precision make them a promising tool.

**Key words:** Decision trees, drones, salinity index, neural networks, reflectances, sodium, Salinity and Sodicity.

## **DEDICATORIA Y AGRADECIMIENTOS**

En especial a mi familia: A mis padres Teresa de la Cruz Flores e Ignacio Santoyo Ibarra. A mis hermanos Adriana, Gustavo y Alejandro. Que me apoyaron en el transcurso de mis estudios en el Colegio de Postgraduados y a lo largo de mi vida.

Al Consejo Nacional de Ciencia y Tecnología de México (CONACYT), por el apoyo de la beca de manutención y viaje de estancia al extranjero.

Al Colegio de Postgraduados por brindarme los conocimientos y habilidades para el desarrollo de mi formación profesional.

A los profesores del Colegio de Postgraduados por asesorarme en todo momento: Dr. Héctor Flores Magdaleno, Dr. Abdul Khalil Gardezi, Dr. Oscar Raúl Mancilla Villa, Dr. Juan Enrique Rubiños Panta, Dr. Roberto Ascencio Hernández y al Dr. Víctor Manuel Gordillo Salinas.

Al Centro de Tecnología Biomédica de la Universidad Politécnica de Madrid, a la Dra. Consuelo Gonzalo Martín y al Dr. Mario Lillo. Por sus recomendaciones de investigación que hicieron para mi proyecto.

Al laboratorista Sr. Cruz Frutero por brindarme sus conocimientos y experiencia.

A todas las personas que ya conocía y a las nuevas que conocí y con las cuales conviví buenos momentos y recibí su apoyo en el Colpos.

## CONTENIDO

RESUMEN.....	2
ABSTRACT.....	3
LISTA DE CUADROS.....	8
LISTA DE FIGURAS.....	9
INTRODUCCIÓN GENERAL.....	11
REVISIÓN DE LA LITERATURA.....	14
Recurso suelo.....	14
Propiedades del suelo.....	15
Solución del suelo.....	24
Salinidad de suelos.....	25
Sodicidad en suelos.....	26
Relación de adsorción de sodio.....	28
Porcentaje de sodio intercambiable.....	31
Clasificación de suelos ensalitrados.....	31
Coeficientes de selectividad.....	32
Consecuencias de la salinidad.....	32
Efecto de las plantas en las sales solubles del suelo.....	33
Plantas halófitas y glicófitas.....	34
Tolerancia a la salinidad de los cultivos.....	36
Los suelos del ex lago de Texcoco.....	37
Desecación de los lagos del valle de México.....	39
Agricultura de precisión.....	45
Aplicaciones de los drones.....	49
Vehículos aéreos no tripulados en el entorno del aprendizaje automático.....	52
Teledetección.....	55
Sensores.....	58
Espectro electromagnético.....	60
Teledetección de la salinidad del suelo.....	63
Índices de teledetección de la salinidad del suelo.....	64
Multiespectral e hiperespectral en la detección de salinidad.....	69
Regresión lineal simple.....	71

Regresión lineal múltiple .....	72
Redes neuronales .....	72
Clasificador de redes neuronales de Statgraphics .....	81
Árboles de decisión .....	83
Árboles de decisión univariados.....	83
Árboles de decisión multivariados .....	84
Árboles de decisión omnivariados.....	85
Árboles de decisión frugales y rápidos (ADFR) .....	85
CAPITULO 1. ANÁLISIS IÓNICO DE SUELOS SALINOS .....	87
1.1.    RESUMEN.....	87
1.2.    ABSTRACT .....	88
1.3.    INTRODUCCIÓN .....	89
1.4.    OBJETIVOS.....	91
<i>Objetivos generales</i> .....	91
<i>Objetivos particulares</i> .....	91
1.5.    HIPÓTESIS.....	92
1.6.    MATERIALES Y MÉTODO.....	92
1.7.    RESULTADOS Y DISCUSIÓN .....	95
1.8.    CONCLUSIONES.....	102
1.9.    RECOMENDACIONES.....	102
1.10.   REFERENCIAS .....	103
CAPÍTULO 2. MODELOS DE CLASIFICACIÓN DE SALINIDAD DEL SUELO, UTILIZANDO BANDAS MULTIESPECTRALES, ÁRBOLES DE DECISIÓN Y REDES NEURONALES .....	107
2.1.    RESUMEN.....	107
2.2.    ABSTRACT .....	109
2.3.    INTRODUCCIÓN .....	110
2.4.    OBJETIVOS.....	112
<i>Objetivo general</i> .....	112
<i>Objetivos particulares</i> .....	112
2.5.    HIPÓTESIS.....	112
2.6.    MATERIALES Y MÉTODOS.....	113
<i>Funcionamiento de la red neuronal</i> .....	119
<i>Funcionamiento del árbol de clasificación</i> .....	121

2.7.	RESULTADOS Y DISCUSIÓN .....	124
	<i>FFTrees de cuatro bandas espectrales y varios índices de salinidad para realizar la estimación del nivel de RAS</i> .....	125
	<i>Redes neuronales utilizando NDVI y SAVI para realizar la estimación del nivel de RAS</i> .....	129
	<i>FFTrees de cuatro bandas espectrales y la estimación del nivel del PSI</i> .....	134
	<i>Redes neuronales utilizando NDVI y SAVI en la estimación del nivel del PSI.</i>	139
	<i>FFTrees de cuatro bandas espectrales y varios índices de salinidad para realizar la estimación del nivel de sodio</i> .....	143
	<i>Redes neuronales utilizando los índices NDSI y Red/Near infrared en la estimación del nivel del sodio</i> .....	147
	<i>Comparación de los modelos de árboles de decisión y redes neuronales en la estimación de los niveles de PSI, RAS y Sodio</i> .....	151
	<i>Comparación de trabajos enfocados a la detección y clasificación de salinidad</i> .....	153
2.8.	CONCLUSIÓN .....	154
2.9.	RECOMENDACIONES.....	155
2.10.	REFERENCIAS .....	156
	CONCLUSIONES GENERALES .....	160

## LISTA DE CUADROS

Cuadro 1. Clasificación de suelos salino-sódicos .....	31
Cuadro 4. Sensores más utilizados y su rango de la banda espectral en nanómetros. ....	59
Cuadro 5. Fases de la propagación en las redes neuronales. ....	73
Cuadro 6. Función de pérdida. ....	74
Cuadro 7. Proceso de aprendizaje hacia atrás. ....	76
Cuadro 8. Secuencia de activaciones de la red neuronal. ....	77
Cuadro 2. Análisis físico químicos aplicados a las muestras de suelo. ....	93
Cuadro 3. Estadística descriptiva de los iones y variables de salinidad de suelos. ....	95
Cuadro 9. Longitudes de las regiones de las bandas multiespectrales de la cámara Parrot sequoia. ....	115
Cuadro 10. Índices de salinidad y vegetación propuestos y utilizados para la detección de salinidad. ....	117
Cuadro 11. Clasificación y validación de la red neuronal para estimar RAS. ....	130
Cuadro 12. Clasificación y validación de la red neuronal para estimar PSI. ....	140
Cuadro 13. Clasificación y validación de la red neuronal para estimar sodio. ....	148
Cuadro 14. Resultados de porcentajes de precisión de detección y clasificación de salinidad y el método empleado. ....	153

## LISTA DE FIGURAS

Figura 1. Mapa de la cuenca del valle de México en 1519. ....	40
Figura 2. Mapa de la situación actual de los lagos del valle de México. ....	44
Figura 7. Ingresos comerciales de los VANT en todo el mundo desde 2016 hasta 2025. ....	53
Figura 8. Espectro electromagnético. ....	62
Figura 9. Ecuación básica de red neuronal. ....	73
Figura 10. Ecuación básica de red neuronal. ....	74
Figura 11. Representación de red neuronal de estimación de pérdida. ....	75
Figura 3. Distribución de medias de aniones y cationes en unidades mEq. ....	96
Figura 4. Distribución de la CE en tres intervalos de medición. ....	97
Figura 5. Interpolaciones y curvas nivel de las variables involucradas del terreno de estudio. ....	100
Figura 6. Relaciones funcionales de PSI-RAS explícito Y PSI-RAS ajustado. ....	101
Figura 12. Mapa de la zona de estudio. ....	113
Figura 13. VANT SenseFly eBee plus. ....	114
Figura 14. Cámara multispectral Parrot Sequoia (Pix4D, Lausanne, Suiza). ....	115
Figura 15. GPS-GNSS marca Hi Target. ....	116
Figura 16. Diagrama de flujo de los pasos a seguir de la red neuronal Statgraphics. ....	120
Figura 17. Curva ROC. ....	121
Figura 18. Diagrama de flujo del proceso de decisión de FFTrees. ....	123
Figura 19. Mapa de reflectancias: a) Green, b) Near infrared, c) Red y d) Red edge. ....	124
Figura 20. FFTree creado en entrenamiento para clasificación de RAS. En donde 0 decide medio y 1 decide elevado. ....	127
Figura 21. FFTree creado en prueba para clasificación de RAS. En donde 0 decide medio y 1 decide elevado. ....	127
Figura 22. Visualización de las cinco mejores señales con mayor wacc de entrenamiento para la estimación de RAS. ....	128
Figura 23. Diagrama de dispersión 2d entre SAVI vs NDVI y la clasificación RAS. ....	133
Figura 24. Regiones de la clasificación de elevado y medio de RAS. ....	134
Figura 25. FFTree creado en entrenamiento para clasificación de PSI. En donde 0 decide medio y 1 decide elevado. ....	137
Figura 26. FFTree creado en prueba para clasificación de PSI. En donde 0 decide medio y 1 decide elevado. ....	137
Figura 27. Visualización de las cuatro mejores señales con mayor wacc de entrenamiento para la estimación de PSI. ....	138
Figura 28. Diagrama de dispersión 2d entre SAVI vs NDVI y la clasificación PSI. ....	142
Figura 29. Regiones de la clasificación de elevado y medio de PSI. ....	142

Figura 30. FFTree creado en entrenamiento para clasificación de sodio. En donde 0 decide medio y 1 decide elevado.....	145
Figura 31. FFTree creado en prueba para clasificación de sodio. En donde 0 decide medio y 1 decide elevado.....	145
Figura 32. Visualización de las cinco mejores señales con mayor wacc de entrenamiento para la estimación de sodio. ....	146
Figura 33. Diagrama de dispersión 2d entre SAVI vs NDVI y la clasificación sodio. ....	150
Figura 34. Regiones de la clasificación de elevado y medio de sodio.....	150
Figura 35. Comparación de las precisiones entre el modélelo FFTrees y las redes neuronales.....	152

## **INTRODUCCIÓN GENERAL**

Este trabajo de investigación se refiere al tema de salinidad de suelos de un predio agrícola. Se pueden citar la definición de suelo como aquellas que considera al suelo como la continuación de espacio-tiempo que forma la parte superior de la corteza terrestre, con un espesor de pocos centímetros, donde se desarrollan las raíces de las plantas y en donde crecen los cultivos. Para analizar esta problemática es necesario mencionar sus causas. Una de ellas es la salinidad, la característica principal de los suelos salinos es la presencia elevada de concentraciones de sales solubles que perjudican a las plantas por su efecto tóxico y la disminución del potencial osmótico del suelo. Estos procesos en los suelos, se pueden determinar con base en su porcentaje de sodio intercambiable (PSI) y la relación de adsorción de sodio (RAS). En la segunda sección de la tesis se analiza la detección y clasificación de la salinidad del suelo utilizando imágenes de drones, redes neuronales y árboles de decisión. Como parte de estas tecnologías la agricultura de precisión tiene como objetivo adaptar el manejo de una manera coherente y holística, especialmente explotando la alta variabilidad espacial y temporal de los rasgos del cultivo y ambientales. Las herramientas de diagnóstico recopilan información utilizando técnicas de detección o muestreo a lo largo de varias escalas. Los Vehículos Aéreos No Tripulados (VANT) son aviones propulsados operados de forma remota o autónoma con planificación de vuelo preprogramada. Los datos de teledetección tienen la capacidad de capturar información en suelos afectados por la sal tanto en extensión espacial como temporal. El desarrollo de métodos para mapear la salinidad utilizando datos de detección remota en combinación con datos de campo han sido el objetivo de varios estudios durante las últimas dos décadas. Varios algoritmos y modelos han sido desarrollado para procesar datos de teledetección satelital. Investigaciones pasadas muestran el mapeo y la evaluación de la salinidad del suelo usando

fotografía aérea, videografía, termometría infrarroja y otros. Aprovechando estas propiedades, una gama de índices se han desarrollado para detectar y mapear la salinidad del suelo con el uso sensores remotos multiespectrales e hiperespectrales. Las mediciones de imágenes de drones combinadas con datos terrestres, han mostrado potencial para el mapeo de salinidad. Una manera para clasificar y detectar salinidad en el suelo son las redes neuronales que están formadas por neuronas conectadas entre sí; a su vez, cada conexión de una red neuronal es asociada con un peso que dicta la importancia de esta relación en la neurona cuando se multiplica por el valor de entrada. Otro método de clasificación son los árboles de decisión, son una clase de métodos de clasificación clásicos, se han aplicado en varios dominios, como el diagnóstico médico, la detección de intrusos y el procesamiento de señales. Los árboles de decisión también pueden denominarse clasificadores jerárquicos porque necesitan una discriminación multinivel para determinar a qué clase pertenece un patrón específico. Son flexibles para hacer frente a la clasificación de múltiples clases y binarios. Esta investigación se realizó con el interés de conocer las condiciones iónicas del terreno analizado, la alta salinidad de este predio es de interés para el estudio de la salinidad, la problemática principal para los cultivos es la pérdida en el rendimiento en una amplia variedad de cultivos alrededor del mundo. Este problema es más severo en las regiones semiáridas. La salinidad puede inhibir el crecimiento de la planta y reducir la productividad, principalmente por tres factores: el déficit hídrico, la toxicidad por iones y el desbalance nutricional. La primera parte del trabajo fue recolectar las muestras debidamente en el predio agrícola perteneciente al Colegio de Postgraduados en el municipio de Texcoco, que antiguamente era el lago de Texcoco. Posteriormente las muestras se tamizaron y secaron en invernadero y se analizaron en laboratorio. Los objetivos generales son el análisis iónico de los suelos, la relación de adsorción de sodio, el porcentaje de sodio intercambiable, así como el mapeo de las curvas de nivel e interpolación. Además de relacionar lo anterior con, las reflectancias de las

imágenes multiespectrales y con los índices de salinidad, para estimar variables de salinidad utilizando redes neuronales y árboles de decisión. El objetivo principal es la detección y clasificación de la salinidad del suelo mediante el uso de imágenes multiespectrales capturadas mediante un VANT y utilizando árboles de decisión y redes neuronales. El uso de reflectancias obtenidas a partir de imágenes multiespectrales obtenidas con un VANT permite estimar la salinidad del suelo utilizando los métodos de clasificación de árboles de decisión y redes neuronales.

## **REVISIÓN DE LA LITERATURA**

### **Recurso suelo**

El suelo es uno de los recursos naturales más significativos en la vida del hombre por su relación directa con el desarrollo de los bosques, la producción de alimentos y fibras. Existen diferentes definiciones de los suelos, en función del enfoque, basadas en diversas propiedades: físicas, químicas, de nutrición, microbiológicas, de fertilidad, de génesis y de clasificación. Se puede tomar en cuenta la génesis y la clasificación de suelos. Así, entre ellas se pueden citar aquellas que considera al suelo como el continuo de espacio-tiempo que forma la parte superior de la corteza terrestre, con un espesor de pocos centímetros y donde se desarrollan las raíces de las plantas (Fitzpatrick, 1987, Fitzpatrick, 1996).

El Soil Survey Staff, (1992; 1994) establecen que el suelo es una colección de cuerpos naturales, formados a partir de materiales minerales y orgánicos, que cubren gran parte de la superficie terrestre, contienen materia viva y pueden soportar vegetación en forma natural y, en algunos lugares, han sido transformados por la actividad humana.

Es el medio natural para el crecimiento de las plantas, puede tener o no horizontes discernibles. El suelo es un cuerpo natural integrado por sólidos (minerales y materia orgánica), líquidos y gases que ocurren sobre la superficie de la tierra, ocupan un lugar en el espacio y se caracterizan por tener horizontes o capas, que se distinguen del material inicial por ser el resultado de adiciones, pérdidas, transferencias y transformación de energía y materia; además poseen la habilidad de soportar raíces de plantas en un ambiente natural (Soil Survey Staff, 1994).

La Clasificación de la FAO define a los suelos como la combinación vertical de horizontes presentes dentro de una profundidad específica y por la

organización lateral (secuencia) de horizontes o por su ausencia, a una escala que se refleja en el relieve o lo conceptualizan como un cuerpo natural continuo, el cual tiene tres dimensiones espaciales y una temporal. Las tres principales propiedades de un suelo son: 1) están formados por minerales y elementos orgánicos e incluye las fases sólida, líquida y gaseosa; 2) los materiales están organizados en estructuras específicas en el medio pedológico. Estas forman el aspecto morfológico de la cobertura del suelo, equivalente a la anatomía de un ser vivo. Su estudio facilita el entendimiento de las propiedades físicas, químicas y biológicas, que, a su vez, permite explicar el pasado, presente y futuro del suelo y 3) el suelo está en constante evolución, tiene una cuarta dimensión: el tiempo (Sotelo *et al.*, 2011).

### **Propiedades del suelo**

La calidad del suelo es variable y los suelos responden de forma distinta conforme las prácticas implementadas sobre él. Se incluyen los elementos de la calidad del suelo; las propiedades físicas, químicas y biológicas inherentes y dinámicas. La calidad del suelo se define como “la capacidad del suelo de funcionar, dentro de las fronteras del ecosistema y el uso de la tierra, manteniendo la calidad ambiental y fomentando las plantas, los animales y el ser humano” (FAO, 2020).

#### *Propiedades físicas:*

Estructura del suelo: Las partículas texturales del suelo como arena, limo y arcilla se asocian para formar agregados y unidades de mayor tamaño nombrados por peds. La estructura del suelo afecta directamente la aireación, el movimiento del agua en el suelo, la conducción térmica, el crecimiento radicular y la resistencia a la erosión. El agua es el componente elemental que afecta la estructura del suelo con mayor importancia debido

a su solución y precipitación de minerales y sus efectos en el crecimiento de las plantas (FAO, 2020).

La Profundidad del suelo: La definición original del solum se denominaba como la capa superficial del suelo (horizonte A) junto con el subsuelo (E y B). El horizonte C se definía como estratos con poca formación edafogenética. De este modo la profundidad efectiva del suelo fue considerada como la espesura del suelo. Sin embargo, la presencia de raíces y la actividad biológica que frecuenta a menudo en horizonte C realza la importancia de incluir este horizonte en la definición de profundidad del suelo. En la práctica los estudios con levantamiento de suelos utilizan límites de profundidad arbitrarios (200 cm) (FAO, 2020).

Características del agua en el suelo: El agua almacenada o fluyente en el suelo afecta la formación del suelo, su estructura, estabilidad y erosión. El agua almacenada es el factor principal para satisfacer la demanda hídrica de las plantas (FAO, 2020).

La textura del suelo: La disponibilidad del agua en el suelo: Cuando un campo se encuentra encharcado, el espacio de aire en el suelo se desplaza por el agua. Se denomina Capacidad de Campo (CC) a la cantidad de agua que el suelo es capaz de retener luego de ser saturado y dejado drenar libremente evitando evapotranspiración y hasta que el potencial hídrico se estabilice (después de 24 a 48 horas de lluvia o riego). El agua ocupa el espacio de los poros más grandes (macroporos) drena hacia capas inferiores bajo la fuerza de gravedad. Los poros más pequeños (microporos) se llenan de agua y los más grandes de aire y agua. El punto capacidad de campo corresponde a una succión de 1/3 bar. Las plantas deben producir una succión hasta 15 bares como máximo. A los 15 bares de succión la cantidad de agua en el suelo se denomina por el punto de marchitez permanente. A ese punto las plantas pierden la capacidad de succión y siguen perdiendo agua mediante la transpiración. Se pierde la turgencia de la planta

resultando en su marchitez. Gráficamente la diferencia entre el punto de capacidad de campo y el punto de marchitez permanente resulta en el agua disponible para cultivo en mm o expresado porcentualmente. La textura del suelo influencia en la cantidad de agua en un suelo drenado hasta el punto de capacidad de campo y la cantidad que está disponible para las plantas. La humedad del suelo que se encuentra disponible se puede determinar en el laboratorio como se ilustra en las curvas de retención de humedad del suelo (FAO, 2020).

**La textura del suelo:** La textura del suelo se refiere a la proporción de componentes inorgánicos de diferentes formas y tamaños como arena, limo y arcilla. La textura es una propiedad importante ya que influye como factor de fertilidad y en la habilidad de retener agua, aireación, drenaje, contenido de materia orgánica y otras propiedades. El triángulo de textura de suelos según la FAO se usa como una herramienta para clasificar la textura. Partículas del suelo que superan tamaño de 2.0 mm se definen como piedra y grava y también se incluyen en la clase de textura. Por ejemplo, un suelo arenoso con 20% de grava se clasifica como franco arenoso con presencia de gravas. Cuando predominan componentes orgánicos se forman suelos orgánicos en vez de minerales (FAO, 2020).

**Consistencia del suelo:** La consistencia es la propiedad que define la resistencia del suelo a la deformación o ruptura que pueden aplicar sobre él. Según su contenido de humedad la consistencia del suelo puede ser dura, muy dura o suave. Se mide mediante tres niveles de humedad; aire-seco, húmedo y mojado. Para la construcción sobre él se requiere medidas más precisas de resistencia del suelo antes de la obra (FAO, 2020).

**Porosidad del suelo:** El espacio poroso del suelo se refiere al porcentaje del volumen del suelo no ocupado por sólidos. En general el volumen del suelo está constituido por 50% materiales sólidos (45% minerales y 5% materia orgánica) y 50% de espacio poroso. Dentro del espacio poroso se pueden

distinguir macro poros y micro poros donde agua, nutrientes, aire y gases pueden circular o retenerse. Los macro poros no retienen agua contra la fuerza de la gravedad, son responsables del drenaje, aireación del suelo y constituyen el espacio donde se forman las raíces. Los micro poros retienen agua y parte de la cual es disponible para las plantas (FAO, 2020).

Densidad del suelo: Mediante la determinación de la densidad se puede obtener la porosidad total del suelo. Se refiere al peso por volumen del suelo. Existen dos tipos de densidad, real y aparente. La densidad real, de las partículas densas del suelo, varía con la proporción de elementos constituyendo el suelo y en general está alrededor de 2,65. Una densidad aparente alta indica un suelo compacto o tenor elevado de partículas granulares como la arena. Una densidad aparente baja no indica necesariamente un ambiente favorecido para el crecimiento de las plantas (FAO, 2020).

Movimiento del agua en el suelo: El agua fluye en el suelo debido a varios tipos de fuerzas como de gravedad, ascenso capilar y osmosis. Entre fuerzas de succión 0 y 1/3 bar el agua fluye en el suelo por las fuerzas de gravedad, este fenómeno se nombra por flujo saturado. Fuerzas de succión más elevadas se nombran flujos no saturados. Los flujos de agua se pueden medir en campo mediante la conductividad hidráulica. Se puede obtener información fundamental en la circulación del agua en el suelo mediante la descripción de suelos de las clases de drenaje y sus características asociadas (propiedades gléyicas y stágnicas) (FAO, 2020).

### *Propiedades químicas*

Capacidad de Intercambio Catiónico (CIC): Es una medida de cantidad de cargas negativas presentes en las superficies de los minerales y componentes orgánicos del suelo (arcilla, materia orgánica o sustancias húmicas) y representa la cantidad de cationes que las superficies pueden retener (Ca, Mg, Na, K, NH<sub>4</sub> etc.). Estos serán intercambiados por otros

cationes o iones de hidrogeno presentes en la solución del suelo y liberados por las raíces. El nivel de CIC indica la habilidad de suelos a retener cationes, disponibilidad y cantidad de nutrientes a la planta, su pH potencial entre otras. Un suelo con bajo CIC indica baja habilidad de retener nutrientes, arenoso o pobre en materia orgánica. La unidad de medición de CIC es en centimoles de carga por kg de suelo  $\text{cmolc/kg}$  o  $\text{mEq/ 100 g}$  de suelo (FAO, 2020).

El pH del suelo (potencial de hidrógeno): Determina el grado de adsorción de iones ( $\text{H}^+$ ) por las partículas del suelo e indica si un suelo está ácido o alcalino. Es el indicador principal en la disponibilidad de nutrientes para las plantas, influyendo en la solubilidad, movilidad, disponibilidad y de otros constituyentes y contaminantes inorgánicos presentes en el suelo. El valor del pH en el suelo oscila entre 3,5 (muy ácido) a 9,5 (muy alcalino). Los suelos muy ácidos ( $<5,5$ ) tienden presentar cantidades elevadas y tóxicas de aluminio y manganeso. Los suelos muy alcalinos ( $>8,5$ ) tienden a dispersarse. La actividad de los organismos del suelo es inhibida en suelos muy ácidos y para los cultivos agrícolas el valor del pH ideal se encuentra en 6,5 (FAO, 2020).

Porcentaje de saturación de bases: En el suelo se encuentran los cationes ácidos (hidrógeno y aluminio) y los cationes básicos (calcio, magnesio, potasio y sodio). La fracción de los cationes básicos que ocupan posiciones en los coloides del suelo se refiere al porcentaje de saturación de bases. Cuando el pH del suelo indica 7 (estado neutral) su saturación de bases llega a un 100 por ciento y significa que no se encuentran iones de hidrógeno en los coloides. La saturación de bases se relaciona con el pH del suelo. Se utiliza únicamente para calcular la cantidad de limo requerida en un suelo ácido para neutralizarlo (FAO, 2020).

Nutrientes para las plantas: La cantidad de nutrientes presente en el suelo determina su potencial para alimentar organismos vivos. Los 16 nutrientes

esenciales para el desarrollo y crecimiento de las plantas se suelen clasificar entre macro y micro nutrientes dependiendo de su requerimiento para el desarrollo de las plantas. Los macronutrientes se requieren en grandes cantidades e incluyen Carbono(C), Hidrógeno (H), Nitrógeno(N), Fósforo (P), Potasio (K), Calcio (Ca), Magnesio (Mg), Azufre(S). Los micronutrientes por otro lado se requieren en pequeñas cantidades, su insuficiencia puede dar lugar a carencia y su exceso a toxicidad, se refieren a Hierro (Fe), Zinc (Zn), Manganeso (Mn), Boro (B), Cobre (Cu), Molibdeno (Mo), Cloro (Cl) (FAO, 2020).

Carbono orgánico del suelo: La vegetación fija el carbono de la atmosfera por fotosíntesis transportándolo a materia viva y muerta de las plantas. Los organismos del suelo descomponen esta materia transformándola a Materia Orgánica del Suelo (MOS). El carbono se libera de la biomasa para la MOS, en organismos vivos por un cierto tiempo o se vuelve a emitir para la atmosfera por respiración de los organismos (organismos del suelo y raíces) en forma de dióxido de carbono,  $\text{CO}_2$ , o metano  $\text{CH}_4$ , en condiciones de encharcamiento en el suelo. La MOS se encuentra en diferentes grados de descomposición y se distingue en distintas fracciones como lábiles (compuestas de hidratos de carbono, ligninas, proteínas, taninos, ácidos grasos) o fracciones húmicas (ácidos fúlvicos, ácidos húmicos y huminas). Las fracciones lábiles resultan más rápidas en digerir para los microorganismos resultando en respiración de carbono y plazo de permanencia más corto en el suelo. Las fracciones húmicas se encapsulan en los agregados del suelo y son más difíciles para acceder. Además, su composición es más estable con químicos más complejos de descomponer y permanecen por periodos muy largos en el suelo. El carbono orgánico del suelo mejora las propiedades físicas del suelo, aumenta la CIC, la retención de humedad y contribuye con estabilidad de suelos arcillosos al ayudar a aglutinar las partículas para formar agregados. La MOS está compuesta en su mayoría de carbono, tiene una capacidad de retener una gran proporción

de nutrientes, cationes y oligoelementos esenciales para el crecimiento de las plantas. Gracias a la MOS la lixiviación de nutrientes se inhibe y es integral a los ácidos orgánicos que disponibilizan los minerales para las plantas y regulador del pH del suelo. Se reconoce globalmente que el tenor de carbono orgánico en el suelo sea un factor fundamental para la salud del suelo, forma parte fundamental del ciclo de carbono y tiene gran importancia en la mitigación a los efectos del cambio climático (FAO, 2020).

**Nitrógeno del suelo:** El nitrógeno del suelo es uno de los elementos de mayor importancia para la nutrición de las plantas y más ampliamente distribuido en la naturaleza. Se asimila por las plantas en forma catiónica de amonio  $\text{NH}_4^+$  o aniónica de nitrato  $\text{NO}_3^-$ . A pesar de su amplia distribución en la naturaleza se encuentra en forma inorgánica por lo que no se pueden asimilar directamente. Además, existen las formas gaseosas del N pero son muy pequeñas y difíciles de detectar como óxido nitroso ( $\text{N}_2\text{O}$ ), óxido nítrico ( $\text{NO}$ ), dióxido de nitrógeno ( $\text{NO}_2$ ), amoníaco ( $\text{NH}_3$ ) y nitrógeno molecular presente en la atmósfera del suelo ( $\text{N}_2$ ). La salinización del suelo se refiere a la acumulación de sales solubles en agua en el suelo. Las sales que se pueden encontrar en un nivel freático salino se transportan con el agua a la superficie del suelo mediante ascenso capilar y una vez que el agua se evapora se acumulan en la superficie del suelo (FAO, 2020).

**Contenido de carbonato de calcio en el suelo:** El carbonato de calcio,  $\text{CaCO}_3$ , es una sal poco soluble que se encuentra naturalmente en varias formas y en varios grados de concentración en el suelo. Su presencia juega un papel fundamental en la estructura del suelo si se encuentra en concentraciones moderadas. Se utiliza como enmienda para neutralizar el pH de suelos ácidos y para suministrar el nivel de Calcio (Ca) para la nutrición de las plantas. Sin embargo, puede resultar problemático si su concentración llega a exceder la capacidad de adsorción en el suelo formando complejos insolubles con otros elementos. Estos componentes son difíciles de asimilar por las plantas llevando a su acumulación. Cantidades excesivas de calcio

puede por ello restringir la disponibilidad de fósforo, boro y hierro para las plantas (FAO, 2020).

Contenido de sulfato de calcio (yeso) en el suelo: En los suelos puede ocurrir la presencia de la acumulación secundaria de yeso ( $\text{CaSO}_4 \cdot 2\text{H}_2\text{O}$ ) extendiéndose principalmente en regiones muy áridas o donde el lavado del suelo esté restringido a causa de baja permeabilidad. Los suelos afectados por concentraciones elevadas de yeso se han desarrollado en gran mayoría en depósitos no consolidados aluviales, coluviales y eólicos de material meteorizado con alto contenido de bases. Existe una vaga vegetación natural que cubre los suelos con alto contenido de yeso (FAO, 2020).

### *Propiedades biológicas*

Se relaciona con la actividad microbiana y fauna del suelo como las lombrices, nematodos, protozoarios, hongos, bacterias y artrópodos. La biología del suelo juega un papel fundamental en la composición del suelo y sus características. Sin embargo, al ser una ciencia recién descubierta permanece mucho por investigar y como afecta la naturaleza de los suelos. Los organismos del suelo descomponen la materia orgánica proveniente de restos vegetales y animales liberando a su vez nutrientes para ser asimilados por las plantas. Los nutrientes que se encuentran almacenados dentro de los organismos del suelo impiden su pérdida por lixiviación. Los microorganismos del suelo mantienen la estructura mientras las lombrices remueven el suelo. Las bacterias juegan un papel crucial en el ciclo del nitrógeno mediante varios procesos: La mineralización del nitrógeno en el suelo se define como la impregnación con amoníaco o componente de amoníaco ( $\text{NH}_3$ ). Un proceso donde las formas puras de nitrógeno se transforman en amonio ( $\text{NH}_4^+$ ) con la ayuda de descomponedores o bacterias. Cuando una planta o animal muere, o un animal desecha el nitrógeno se encuentra en forma inorgánica. Las bacterias, o en algunos casos los hongos, transforman el nitrógeno orgánico en los restos de vuelta

a amonio, un proceso denominado la mineralización o amonificación. La nitrificación incluye un proceso en que se divide en tres etapas. En la primera etapa las bacterias transforman el nitrógeno en forma de amonio ( $\text{NH}_4^+$ ) por lo que pueden ser absorbidos por las raíces de las plantas. En la segunda etapa el amonio se oxida y se forma nitrito  $\text{NO}_2$ . En la tercera etapa mediante oxidación se forma nitrato,  $\text{NO}_3$ . La fijación de nitrógeno ocurre con bacterias en el suelo o algas capaces de fijar el nitrógeno atmosférico incorporándolo a su organismo y depositado al suelo una vez muertos. Las bacterias *Azobacter* y *Clostridium* se nombran como las fijadoras de nitrógeno en manera no simbiótica. Las bacterias que llevan a cabo fijación simbiótica incluyen *Rhizobia*. Su hábitat se encuentra alrededor de las raíces leguminosas formando nódulos en las células corticales habitadas por las bacterias. La desnitrificación devuelve el nitrógeno a la atmósfera. Las bacterias anaeróbicas *Achromobacter* y *Pseudomonas* llevan al proceso la conversión de nitratos y nitritos como óxido de nitrógeno  $\text{N}_2\text{O}$  o  $\text{N}$  molecular  $\text{N}_2$ . En exceso el proceso tiende a conducir a pérdidas totales de nitrógeno disponible en el suelo y en consecuencia su fertilidad (FAO, 2020).

El ciclo de carbono: El diagrama del ciclo de carbono ilustra el proceso donde el elemento de carbono se intercambia entre la biosfera, pedosfera, geosfera, hidrósfera y atmósfera de la tierra. Se designa como el proceso más importante del planeta al reciclar y reutilizar el elemento más abundante del planeta. Los flujos anuales del carbono y sus intercambios entre las distintas reservas ocurren debido a los procesos químicos, físicos, geológicos y biológicos. Los organismos que viven en el suelo son factores determinantes para la circulación de nutrientes y del carbono en el suelo. Una gran parte de la materia orgánica originada por la descomposición anual de los residuos vegetales se acumula en la superficie del suelo o en la zona radicular y se consume casi por completo por los organismos del suelo creando así una reserva de carbono con una rápida tasa de renovación, en muchos casos, entre 1 a 3 años. Los subproductos de este consumo

microbiano resultan en emisiones de dióxido de carbono, CO<sub>2</sub>, y agua, H<sub>2</sub>O, y una variedad de compuestos orgánicos designados como humus. El humus está compuesto por sustancias difíciles de degradar y por ello resulta lenta su descomposición. Al ser formado en horizontes superficiales del suelo generalmente una parte se precipita hacia perfiles inferiores como complejos arcillo-húmicos. En los perfiles más profundos del suelo el tenor de oxígeno suele ser menor por lo que dificulta la descomposición del humus por los organismos. Pero con el tiempo, debido a varios procesos naturales que remueven el suelo el humus se vuelve a aportar hacia horizontes superiores donde se podrá descomponer y liberar más CO<sub>2</sub>. Es por ello que el humus constituye una reserva más estable para el carbono del suelo con duración de centenas a miles de años. En la mayoría de los suelos, la descomposición del humus rápida y lenta lleva a un tiempo de residencia de alrededor de 20 a 30 años. Los microorganismos del suelo (considerando en términos de sus emisiones de respiración) disponen alta sensibilidad al contenido de carbono orgánico en el suelo tal como a la temperatura y tenor de agua por lo que aumentan la respiración en tenores elevados de carbono, temperaturas elevadas y condiciones más húmedas en el suelo (FAO, 2020).

### **Solución del suelo**

La solución del suelo consiste en toda el agua líquida en el suelo y los materiales disueltos en éste, en la proximidad inmediata de la superficie sólida, corresponde al agua contenida en la doble capa eléctrica de la superficie coloidal. En sistemas floculados, la doble capa eléctrica será normalmente solo unas pocas moléculas de espesor, sin embargo, en sistemas dispersos, la solución del suelo puede ser de 2 o más moléculas de extensión. El proceso de excreción asociado con la actividad de las raíces de las plantas, dirige el ajuste correspondiente en la concentración de cationes en la superficie. En la solución de suelo afectada por una alta concentración

de iones disueltos se ejerce un efecto perjudicial en la concentración interna del vegetal por la influencia del efecto osmótico. El transporte o retención de los cationes adsorbidos, así como de otras sustancias, entre ellas los contaminantes del suelo, dependen de cómo está relacionado la superficie sólida cargada de los suelos y los iones disueltos en la solución acuosa, puesto que los procesos de intercambio iónico están regidos por fenómenos de adsorción y desorción. La importancia del intercambio de cationes en relación con la nutrición de las plantas es obvia a partir del hecho de que la solución del suelo contiene menos del 1% del potasio requerido para una cosecha, siendo suplido el resto por compensación del potasio desde los coloides del suelo. El movimiento lateral de la solución del suelo, puede ser causa de la variabilidad espacial de la respuesta de la producción del cultivo. En suelos no salinos, los aniones dominantes en la solución del suelo, son normalmente nitratos y bicarbonatos, mientras que en áreas áridas y semiáridas son importantes los cloruros y sulfatos. Estos iones tienden a ser débilmente adsorbidos por la superficie de la arcilla y en la mayoría de las condiciones del suelo, donde la carga superficial dominante es negativa, ellos pueden ser excluidos desde la capa de la superficie (negativamente adsorbido). El fosfato y el silicato, los cuales están normalmente presentes a baja concentración, intercambian más fácilmente con otros grupos aniónicos en la superficie. La asociación de un anión con la fase superficial después del intercambio, puede provenir de precipitación de un complejo insoluble sobre la superficie, o por intercambio del anión con el ligando de un catión en la superficie o en la superficie en sí (Otero *et al.*, 2007).

### **Salinidad de suelos**

La sequía es mayor en las regiones secas y calientes, en donde la concentración de sales se incrementa en la capa superior del suelo debido a la evapotranspiración, que excede a la precipitación. El incremento de los

suelos salinos en todo el mundo limita la producción de cultivos para la alimentación humana y animal, estas áreas se consideran marginales, en un mundo donde el espacio y la alimentación constituyen grandes limitaciones (Martínez *et al.*, 2011).

El término salinidad se refiere a la presencia en el suelo de una elevada concentración de sales solubles 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<sup>+</sup>, Ca<sup>2+</sup>, Mg<sup>2+</sup> (Lamz & González, 2013).

El origen de la salinidad puede ser explicado por dos vías: La primera es natural, ya sea por la cercanía y la altura sobre el nivel del mar, la intemperización y la existencia de sales también son causas primarias de salinidad que se agudizan en condiciones heterogéneas de microtopografía y las propiedades físico-químicas del perfil del suelo, como son: la textura, la estructura, la porosidad, la permeabilidad, la capacidad de retención de humedad y de intercambio catiónico juegan un papel importante. Otros factores 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 y bóvedas salinas. La segunda causa, es el resultado de las incorrectas prácticas agrícolas del suelo y el mal manejo del agua para el riego, lo cual permite la movilidad de las sales dentro del suelo y el transporte de las mismas a nuevos sitios. Esto es conocido como proceso de salinidad antrópica (Lamz & González, 2013).

### **Sodicidad en suelos**

La sodicidad o alcalinización se desarrolla cuando en la solución del suelo existe una concentración elevada de sales sódicas capaces de sufrir

hidrólisis alcalina, de tipo carbonato y bicarbonato de sodio. Los suelos sódicos son aquellos que se originan cuando el ion monovalente sodio desplaza otras bases del complejo de adsorción y se fija a esta estructura superficial, en un nivel de concurrencia que sobrepasa el 15 % entre los cationes intercambiables. Las altas concentraciones de sodio en los suelos no sólo perjudican las plantas directamente, sino también degradan la estructura del suelo, disminuyendo la porosidad y la permeabilidad del agua (Lamz & González, 2013).

Cuando el  $\text{Na}^+$  es el catión dominante se produce la dispersión de las arcillas, lo que lleva a una destrucción de la estructura. Además de que la hidrólisis de las arcillas sódicas, conduce a la alcalinización del perfil, y estas provocan una intensa alteración mineral, reflejándose en un perfil bien diferenciado desde el punto de vista morfológico. A estos suelos se les llama suelos sódicos o en ocasiones alcalinos y su clase representativa es el solonetz, que son suelos con un horizonte subsuperficial arcilloso denso, fuertemente compactado, que tiene una proporción elevada de iones  $\text{Na}^+$  y/o  $\text{Mg}^{2+}$  adsorbidos (IUSS, 2007).

Los suelos normalmente toman las sales de mantos freáticos superficiales, los cuales suelen poseer sales disueltas en menor o mayor proporción. La existencia de estos mantos freáticos es frecuente en las depresiones y tierras bajas. En las regiones áridas, las sales pueden ascender por capilaridad. El viento, en las zonas, áridas arrastra gran cantidad de partículas en suspensión, tales como, carbonatos, sulfatos y cloruros, depositándose en los suelos. No obstante, las aguas subterráneas empleadas para la irrigación contienen sales solubles como el sodio, calcio, magnesio, potasio, sulfatos y cloruros disueltos de las rocas y minerales. La evapotranspiración del agua de riego, finalmente hacen que se acumulen en los suelos cantidades excesivas de sales, salvo que exista una lixiviación y un drenaje adecuados. Este proceso se denomina salinización por irrigación (Smith & Smith, 2007).

La sodicidad, tiene que ver con un incremento del contenido de sales en los suelos, que provoca, entre otras cosas, la disminución del rendimiento de los cultivos. Estos procesos en los suelos, se pueden determinar con base en su porcentaje de sodio intercambiable (PSI), midiendo la conductividad eléctrica en el extracto de saturación y evaluando su basicidad mediante su pH (SEMARNAT, 2009). En los suelos ocurre cuando el complejo coloidal está ocupado principalmente con sodio ( $\text{Na}^+$ ), provocando una dispersión de los coloides del suelo, que lo hacen mucho menos permeable y se determina, cuando el porcentaje de sodio intercambiable es mayor de 15 y la conductividad del extracto de saturación es menor de  $4 \text{ dSm}^{-1}$  a  $25^\circ\text{C}$  (Richards, 1982).

Los suelos sódicos tienen un porcentaje de sodio intercambiable mayor a 1.2 este sodio no es dañino para las plantas, pero causa que los suelos de textura fina sean extremadamente impermeables al agua y dificulta la penetración de las raíces. Además, los suelos son muy compactos, húmedos y pegajosos; formando columnas de suelo con capas redondeadas (Basurto *et al.*, 2008).

### **Relación de adsorción de sodio**

#### *explícito*

La relación de adsorción de sodio (RAS) es una variable que indica la proporción de sodio sobre el calcio contenido en la solución del suelo, y permite estimar el porcentaje de sodio intercambiable del suelo, así como el riesgo de sodificación del suelo por la aplicación del agua al riego (Richards, 1982). Si la CE es mayor de  $0.750 \text{ dS m}^{-1}$  y la RAS es mayor de  $3 \text{ mmol L}^{-1}$ , se considera que este suelo tiene riesgo de salinidad y sodicidad esto representaría bajo rendimiento para los cultivos (Pérez *et al.*, 2019).

$$\text{RAS} = \frac{\text{Na}}{\sqrt{\frac{\text{Ca} + \text{Mg}}{2}}}$$

Dónde:

RAS: es la relación de adsorción de sodio, en todos los casos (mEq L<sup>-1</sup>)

Na<sup>+</sup>, Ca<sup>2+</sup> y Mg<sup>2+</sup>: corresponde a la concentración (mEq L<sup>-1</sup>).

#### *Ajustado*

Mediante la ecuación propuesta por Bower *et al.*, (1968) se estimó la RAS en el agua de drenaje (RASaj), esta fórmula considera únicamente la precipitación de Ca<sup>2+</sup>; es decir, esta ecuación no tiene en cuenta la disolución de cationes de los minerales del suelo:

$$\text{RASaj} = \frac{\text{Na}}{\sqrt{\frac{\text{Ca} + \text{Mg}}{2}}} [1 + (8.4 - \text{pHc})]$$

Dónde:

RASaj: es la relación de adsorción de sodio ajustado, bajo condiciones de alcalinidad.

pHc: es el pH calculado a partir de la fuerza iónica y la concentración de Ca<sup>2+</sup> y (CO<sub>3</sub><sup>2-</sup> + HCO<sub>3</sub><sup>-</sup>).

Para estimar la precipitación del carbonato de calcio (CaCO<sub>3</sub>) cuando alcanza su límite de saturación en presencia de iones bicarbonato, se utiliza el índice de saturación propuesto por (Langelier, 1936):

$$IS = pH_a - pH_c$$

Donde:

$pH_a$  = es el pH actual del agua

$pH_c$  = del agua en equilibrio con  $CaCO_3$

IS = (+) el agua precipita  $CaCO_3$

IS = (-) el agua disuelve  $CaCO_3$

El  $pH_c$  se calcula como sigue (Bower *et al.*, 1968):

$$pH_c = (pk_2' - pk_c') + pCa + pAlk$$

Donde:

$pk_2'$  -  $pk_c'$  = son los logaritmos negativos de segunda constante de disociación del ácido carbónico ( $H_2CO_3$ ) y la constante de solubilidad del carbonato de calcio ( $CaCO_3$ ), ambos corregidos por su fuerza iónica (I).

$pCa$ : es el logaritmo negativo de la concentración molar de calcio.

$p(Alk)$ : corresponde al logaritmo negativo de la concentración equivalente de  $CO_3^{2-}$  y  $HCO_3^-$

El  $(pk_2' - pk_c')$  se obtiene mediante la siguiente ecuación matemática:

$$pK_2 - pK_c = 2.0269 + \left[ 0.5092 \left( \frac{4.0\sqrt{\mu}}{1 + 2.0\sqrt{\mu}} + \frac{\sqrt{\mu}}{1.0 + 1.45\sqrt{\mu}} \right) \right]$$

Dónde:

2.0269 es la diferencia entre  $(pK_2' - pK_c')$ :  $K_2 = 4.7 \times 10^{-11}$  y  $K_c = 5.0 \times 10^{-9}$

$\mu$ : es la fuerza iónica y está relacionada con la concentración total de cationes (C en meq  $L^{-1}$ ), la ecuación de regresión es la siguiente:

$$1000\mu = 1.3477C + 0.5355$$

## Porcentaje de sodio intercambiable

El porcentaje de sodio intercambiable expresa el porcentaje de  $\text{Na}^+$  respecto a los demás cationes adsorbidos en el complejo de cambio. Se considera que un suelo puede sufrir problemas de sodificación y dispersión de su fracción arcilla cuando el PSI es superior al 15% (Marin *et al.*, 2013).

Cualquier posible evaluación del peligro potencial de la sodicidad deberá relacionarse con el PSI, que tendrá que encontrarse en el suelo derivado del uso de las aguas de riego (Can, 2011). El PSI significa el porcentaje de cargas negativas utilizadas u ocupadas con iones de sodio mediante la ecuación propuesta por (Richards, 1982):

$$PSI = \frac{100(-0.0126 + 0.01475 \text{ RAS})}{1 + (-0.0126 + 0.01475 \text{ RAS})}$$

## Clasificación de suelos ensalitrados

En el (cuadro 1) se aprecia la clasificación con base en las sales solubles presentes en la solución y el porcentaje de la capacidad de intercambio catiónico ocupada por iones de sodio ósea el porcentaje de sodio intercambiable (Aceves, 2011).

Cuadro 1. Clasificación de suelos salino-sódicos

	Salino	Sódico	Salino-Sódico
dS/m	>4	<4	>4
PSI	<15	>15	>15
pH	<8.5	8.5-10	<8.5

## **Coefficientes de selectividad**

Los coeficientes de selectividad se pueden usar para predecir el PSI que potencialmente se presentará en los suelos durante el uso del agua en condiciones de equilibrio con datos variables de RAS en sus concentraciones iniciales de  $C_{Na^+}$ ,  $C_{Ca^{2+}}$  y  $C_{Mg^{2+}}$  RAS y con valores de RAS modificados debido a la precipitación y/o solubilización del  $CaCO_3$  (RASaj y RAS), y con la finalidad de conocer valores de PSI mín y PSI máx, se utiliza la ecuación:

$$PSI = \frac{K_G RAS100}{1 + K_G RAS}$$

Se deben representar los coeficientes de selectividad de Gapon para texturas de suelos, en los suelos de ex lago de Texcoco son arcillosos-limosos y arcillosos. Se considera importante la relación y variación del PSI en los suelos agrícolas por ser regados con aguas de distintos valores de RAS (López *et al.*, 2016). Las variaciones en los coeficientes de selectividad bajo condiciones de equilibrio en el suelo, se explican por la no homogeneidad de carga, cambio en los coeficientes de actividad de los cationes con el incremento del grado de saturación y presencia de mezclas de distintos tipos de materiales intercambiadores de cationes en el suelo (Aceves, 2011).

## **Consecuencias de la salinidad**

La alta salinidad en el suelo causa considerables pérdidas en el rendimiento en una amplia variedad de cultivos alrededor del mundo. Este problema es más severo en las regiones semiáridas. La salinidad puede inhibir el crecimiento de la planta y reducir la productividad, principalmente por tres

factores: el déficit hídrico, la toxicidad por iones y el desbalance nutricional. El efecto general de la salinidad es reducir la tasa de crecimiento obteniendo hojas más pequeñas, menor altura, y a veces menos hojas. El efecto inicial y primario de la salinidad, especialmente de bajas a moderadas concentraciones, se debe a sus efectos osmóticos (Carranza *et al.*, 2009).

### **Efecto de las plantas en las sales solubles del suelo**

Otra respuesta fisiológica de las plantas a la salinidad se da disminuyendo la conductancia estomática; de esta forma se reduce la transpiración evitando la sequía fisiológica para mantener la turgencia de las células. La reducción de la conductancia estomática implica el cierre de las estomas y se relaciona, entre otros factores (luz, humedad, CO<sub>2</sub>, temperatura y corrientes de aire), con la disminución del potencial de agua foliar, incluso por encima de la luz intensa. El cierre de las estomas reduce el ingreso de CO<sub>2</sub> inhibiendo la fotosíntesis, dando como resultado la reducción en la síntesis de fotosintatos. En general, la consecuencia es la disminución en la producción de biomasa, como raíces, hojas, tallos y semillas, relacionados con el área foliar y la longitud de plantas (Carranza *et al.*, 2009).

Además, se produce disminución del potencial hídrico del medio, que reduce la absorción de agua durante la germinación y en las otras etapas de la ontogenia de las plantas, y/o por la absorción de iones como sodio y cloruros que producen problemas de toxicidad y nutricionales. Se estima que ~800×10<sup>6</sup> ha en el planeta están afectadas por sales, de éstas 397×10<sup>6</sup> ha lo son por problemas de salinidad y 434×10<sup>6</sup> ha por condiciones asociadas a sodicidad (Goykovic *et al.*, 2014).

## **Plantas halófitas y glicófitas**

El término halófito (halos= sal; phyta= planta de) se utiliza hace más de 200 años para definir a aquellas especies de plantas que han hecho de los ecosistemas salinos su hábitat. Sin embargo, la gran diversidad de ambientes en los que existen y la gran cantidad de estrategias que usan para tolerar o evadir el exceso de salinidad en el sustrato, ha derivado en la proliferación de variadas definiciones. Esto crea una fuente de incertidumbre a la hora de clasificar una especie como halófito, tanto a nivel regional como global. A pesar de ello, en la literatura actual se ha llegado a un consenso con respecto al uso de la concentración de cloruro de sodio (NaCl) como el parámetro que permite discriminar a las especies halófitas de aquellas sensibles a la salinidad. Sobre la base de esta definición se han creado los primeros listados de especies halófitas a nivel. En la actualidad, perturbaciones tales como la degradación y salinización de los suelos devuelven el interés hacia este grupo de especies. Sus principales usos están enfocados en el desarrollo de la agricultura, la rehabilitación de suelos degradados y contaminados con residuos mineros, la generación de biomasa para forraje y como biofiltro de residuos municipales y aguas residuales. A pesar del gran valor de estas especies, su identificación y clasificación sigue siendo un desafío a nivel local y regional (Orrego *et al.*, 2018).

Hace más de un siglo, los halófitos se definían de manera simple pero útil. como especies adaptadas a condiciones perpetuamente salinas. Se definen como plantas que pueden completar sus ciclos de vida a NaCl 300 mM, o posterior, 200 mM. Otros han establecido el límite como tan bajo como 70 mM a 85 mM. Lo que esto significa en términos de números de halófitos no está perfectamente claro. Se ha sugerido un número tan alto como 6000 especies, mientras que actualmente especialistas identifica más de 1500 especies como tolerantes a la sal, aunque sin etiquetarlas como "halófitas". A pesar de diferencia en estos dos últimos conteos, las listas más detalladas

representan Sólo el 0.5% de todas las angiospermas. Esto puede significar que la evolución de la halofilia es difícil, por lo tanto, rara, pero también puede reflejar el hecho que una porción relativamente pequeña de la superficie de la tierra tiene naturalmente suelos salinos. Los halófitos ocurren en 37 de los 65 órdenes de plantas. Sin embargo, ninguna familia es estrictamente halófito, por razones que no están claras, algunas tienen desproporcionadamente altos números (por ejemplo, las *Chenopodiaceae*, ahora incluidas en las *Amaranthaceae*). A nivel de género, tanto los halófitos como los no halófitos coexisten con frecuencia, ejemplos conocidos son *Aster*, *Glicina*, *Plantago* y *Solanum* (Cheesman, 2015).

Las glicófitas se definen como cualquier planta que solo crecerá saludablemente en suelos con un bajo contenido de sales de sodio. Ni saludable ni bajo contenido de sal es inequívoco El Oxford English Dictionary define a las glicófitas como una planta cuyo crecimiento es inhibido por el suelo salino. Otra definición más útil y precisa sería esto: una glicófito es una especie que ha evolucionado por adaptación bajo presiones selectivas naturales en ecosistemas con bajos niveles de sodio en el suelo y que mantiene bajos niveles de sodio en sus tejidos superficiales, especialmente en sus hojas (Cheesman, 2015).

Comprender la evolución de estas plantas, es posiblemente más difícil que comprender la evolución de halófitas, y gran parte es por hipótesis incompleta y no probada. Una de las principales razones para esto es que la mera definición de glicófito es vaga. Por lo tanto, si hay 350 699 especies de angiospermas, 349 100 son glicófitas. De eso, lo absurdo de esto la definición es obvia. Curiosamente, no hay glicófitas términos para describir plantas que no son, por ejemplo, criófitos, termófilos, xerófitos o hidrófitos. En general, el término que es más apropiado para todas estas especies de "no algo", es decir, no especialistas en un ecosistema en específico, podría ser mesófito. Pero incluso "normal" es más apropiado que glicófitas (Cheesman, 2015).

## **Tolerancia a la salinidad de los cultivos**

La salinidad se está volviendo más extensa como resultado del desmonte e insostenibles prácticas de riego y agricultura extensiva. Las soluciones agronómicas y de ingeniería limitadas, para minimizar el impacto de la tierra salina en el mundo. En la producción de alimentos el camino a seguir es generar una mayor tolerancia a la sal en cultivos actuales e introducir nuevas especies para el cultivo. La mayoría de la energía adquirida por la fotosíntesis y fijación en los compuestos de carbono son utilizados por las plantas en el mantenimiento general. Solo una pequeña proporción (10–40%) se usa directamente para la acumulación de sal. En general, las especies tolerantes a la sal tienen concentraciones altas de  $\text{Na}^+$  y  $\text{Cl}^-$  en las hojas, más altas que la solución externa. Esto es particularmente cierto para halófitas y las plantas más tolerantes a la sal no halófitas, como la cebada, donde el rasgo de tolerancia tisular es claramente evidente. Dichas plantas deben compartimentar  $\text{Na}^+$  y  $\text{Cl}^-$  en la mayor parte de la hoja, en vacuolas para mantener la presión osmótica adecuada. No está claro si la concentración de  $\text{Na}^+$  y  $\text{Cl}^-$  se vuelve tóxica en el citoplasma, es un tema prioritario para la investigación (Munns & Gilliam, 2015).

Los nuevos conocimientos sobre los mecanismos de tolerancia a la salinidad se realizan predominantemente en sistemas modelo. Existen muy pocos hallazgos fundamentales de investigación relevantes para la salinidad. Una excepción es la aplicación de AtNHX1 ( $\text{Na}^+$  /  $\text{H}^+$  antiporter 1 proteínas) para mejorar compartimentación de sal en las vacuolas de tejido vegetativo de tomate, que mejoró el rendimiento sin aumentar la sal en la fruta de tomate. Más recientemente la quinasa (AtCIPK16) relacionada con (SNF1/ proteína) interactúa con (CBL) para la exclusión de  $\text{Na}^+$  (en *Arabidopsis thaliana*). La población de mapeo de Bay-0 9 Shahadara, se expresó en cebada y se descubrió que mejora la exclusión de  $\text{Na}^+$  y la biomasa en un campo salino (Munns & Gilliam, 2015).

¿Qué depara el futuro para la tolerancia al estrés salino? Esta idea ha resaltado mecanismos con potencial para mejorar la tolerancia al estrés del cultivo. También se carece de información básica sobre los costos de energía de la tolerancia a la salinidad. El desafío es tener datos cuantitativos para los mecanismos específicos de tolerancia a la sal a nivel genético a través de células individuales y plantas enteras, para que podamos desarrollar modelos de predicción de vías de ganancias de energía. El resultado deseado será los cultivos con menores costos de energía y mayores rendimientos, así como la comprensión rigurosa de la economía de las plantas cuando se enfrenta a la sal y a la variación natural que existe. Una alternativa es proporcionar germoplasma a los productores esto aumenta el rendimiento en ambientes estresantes. Por ejemplo, la investigación sobre *Arabidopsis* ha llevado a ideas interesantes sobre los mecanismos de tolerancia a la sal. La secuenciación genética de última generación son técnicas que permiten realizar investigaciones novedosas sobre cultivos con estrés salino. Estas investigaciones conducirán a un mayor rendimiento, mejoras que ha sido posible con plantas modelo, proporcionando impactos tangibles de la investigación hacia objetivos de seguridad alimentaria (Munns & Gilliam, 2015).

### **Los suelos del ex lago de Texcoco**

Los suelos del ex lago de Texcoco están compuestos por arcillas del Tipo 2:1 (esmectitas), que se caracterizan por ser expansivas, es decir, aumentan o disminuyen en volumen conforme a su contenido de agua. Existe la presencia de estratos endurecidos cementados naturalmente por carbonato de calcio y sílice amorfa en la ribera del ex lago de Texcoco, formándose cristales de silicato de sodio. El silicato de calcio es la composición química más importante del cemento Pórtland y cuando se comparó con la composición química del jaboncillo se encontró que son similares en óxidos

(Si, Al, Fe, Mg, K y Na) y difieren en el contenido de óxido de calcio (CaO) (concentración baja) y óxido de silicio SiO<sub>2</sub> (concentración alta) (62.5% y 22.5% en el cemento y 4.68% y 59.43% en el sedimento, respectivamente) (López *et al.*, 2004).

Las formaciones que limitan a la cuenca de México están constituidas por rocas ígneas extrusivas compuestas por tobas, brechas, andesitas, basaltos y riolitas, correspondientes a depósitos del Cuaternario (Mooser, 1961). La región se considera como una planicie aluvial-lacustre, que se formó por sedimentos, producto de la alteración de las rocas ígneas presentes en la zona circundante al Valle de México. El suelo dominante en esta área es un fluvaquentic endoaquolls, que significa que es un mollisol, debido a la acumulación de materia orgánica promovida por el pasto salado (*Distichlis spicata*); con un régimen de humedad áquico (influencia del manto freático) y con propiedades flúvicas. Debajo de la capa de suelo se encuentra una capa de ceniza volcánica, seguido del sedimento lacustre o “jaboncillo”, denominado así localmente por su sensación jabonosa. En el ex lago pueden distinguirse varias comunidades vegetales: pirul (*Schinus molle*), lentejilla (*Lemma gibba*), pasto salado (*Distichlis spicata*), romerito (*Suaeda nigra*) y eucalipto (*Eucalyptus spp.*) (López *et al.*, 2004).

Los suelos del ex lago de Texcoco presentan horizontes enriquecidos con carbonato de calcio compuestos por diferentes rasgos calcíticos, en las laderas es más intenso el grado de acumulación de los horizontes cálcicos y petrocálcicos, no obstante, los procesos involucrados en su formación no están claramente identificados. La acumulación del carbonato está relacionada con lechos de aguas salinas, por lo que los procesos de acumulación pueden tener analogías con los que se presentan en ambientes marinos ricos en calcio, más que en aquellas áreas donde influye la escasa precipitación (Gutiérrez *et al.*, 1998).

Sobre las tobas existe un material localmente denominado tepetate blanco, el cual se caracteriza por presentar altos contenidos de carbonato de calcio. Siendo muy probable que los escurrimientos superficiales que atravesaban al tepetate blanco desprendieran y transportaran al calcio en forma de catión o como bicarbonato y lo depositaran en el lago, donde adquirieron rasgos específicos de acuerdo con las condiciones ambientales (Gutiérrez *et al.*, 1998).

Los suelos del ex lago de Texcoco son de origen aluvial-lacustre y se desarrollaron a partir de sedimentos, producto de la alteración de rocas ígneas. Este hecho puede hacer posible la diferenciación entre los rasgos que tienen un origen sedimentario de los pedogenéticos, sin que esté de por medio una acumulación de carbonato a partir de rocas calizas que haría todavía más difícil su diferenciación (Gutiérrez *et al.*, 1998).

### **Desecación de los lagos del valle de México**

En la (figura 1) se aprecian el mapa de los lagos de Xochimilco, Chalco, Texcoco, Zumpango y Xaltocan en 1519, que sufrieron modificaciones perpetradas por naturales y extranjeros, que construyeron diques y albarradas según sus respectivos proyectos de urbanización, ambos estaban separados únicamente por la isla de Tláhuac y, a diferencia del lago de Texcoco, cuya localización se encuentra más al norte, se volvieron populares porque sus aguas no eran salobres, sino dulces. Durante muchos años los dos lograron satisfacer la sed de los vecinos y de los viajeros. Debido a la gran cantidad de sus afluentes (el lago de Xochimilco recibía aportaciones desde el cerro de Teutli y en el de Chalco desembocaban los ríos Acuautla, Tlalmanalco y Tenango), tanto el uno como el otro mantuvieron una considerable tendencia a los desbordamientos en el pasado. Las primeras obras de ingeniería que le hicieron frente al problema, lejos de solucionarlo,

lo volvieron más severo: si bien es cierto que el dique de Nezahualcóyotl había trazado con éxito la separación de los lagos de Texcoco y de México, prolongando su resistente estructura de mampostería a través de más de dieciséis kilómetros, desde Atzacualco hasta las faldas del cerro de la Estrella, el que dividía a los lagos de México y de Xochimilco, llamado de Mexicaltzingo, había represado tales concentraciones de agua a los costados que en el año de 1489, cuando el emperador Ahuizotl intentó darle algún uso a esas reservas, la ciudad sufrió una inundación sin precedentes (Gallardo, 2017).

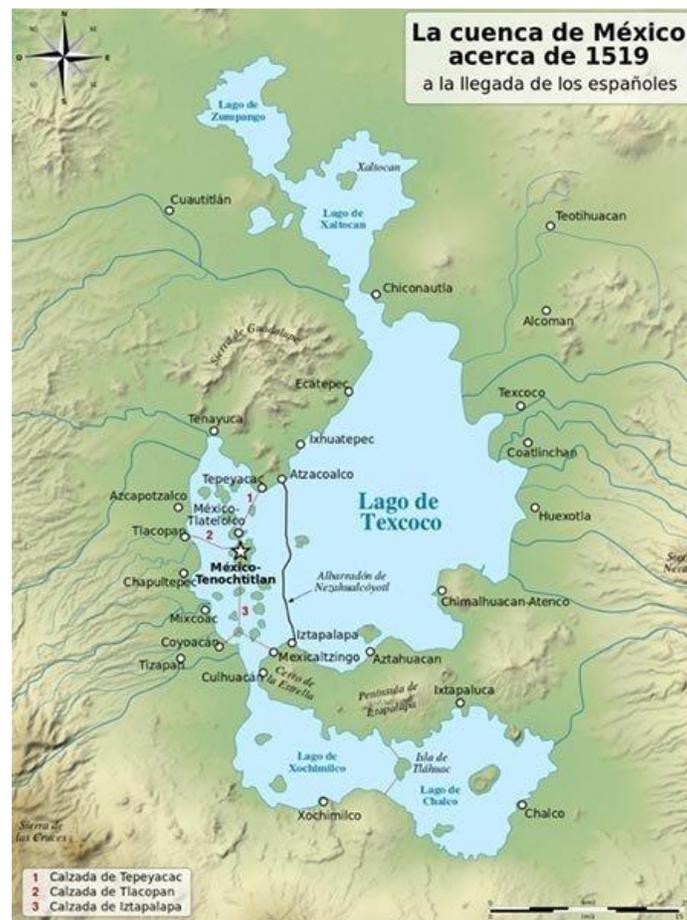


Figura 1. Mapa de la cuenca del valle de México en 1519.

(Imagen adquirida de Gallardo, 2017).

Las inundaciones eran provocadas por errores de planeación y, sobre todo, por lluvias que se consideraban fuera de lo ordinario. Al parecer, durante la administración del gobierno virreinal, hubo fuertes anegamientos en 1604 y luego, tres años más tarde, en 1607. El lago de Chalco, de mayor volumen que el de Xochimilco, era especialmente proclive a estas catástrofes. Es difícil establecer con exactitud cuáles eran las profundidades de los lagos de Xochimilco y de Chalco. No obstante, con motivo de su ubicación, se sabe que éstas fueron las más hondas de toda la zona lacustre. Al pie de la Cordillera del Sur, donde se elevan los picos principales, el terreno está más deprimido en la parte correspondiente al fondo de los lagos de Xochimilco y de Chalco”. En los siglos XVI y XVII las empresas de desagüe se concentraron en el lago de Texcoco, puesto que como era más ancho y menos profundo que sus homólogos del sur, representaba un riesgo todavía mayor. En 1607 comenzó la construcción del tajo de Nochistongo, que llevó a cabo Enrico Martínez, después de una serie de altibajos profesionales y personales, quien ya había señalado las dificultades de la obra. Respecto a los lagos de Chalco y de Xochimilco, éstos no fueron desecados al principio, sino solamente contenidos por los diques de Tláhuac y de Mexicaltzingo. En las orillas, sin embargo, hubo una labor de deforestación bastante considerable; las crónicas de la época indican que los colonizadores pretendían limpiar los alrededores en busca de dos objetivos: 1) fincar casas habitación y 2) aprovechar las tierras fértiles. Los procesos de evaporación se vieron alterados gradualmente y, ya que los árboles no protegían más al agua de las inclemencias de los rayos del sol, inició una lenta desecación cuyos resultados se volvieron observables en un período no mayor a cien años. La desecación, aunque violenta en el norte y más natural en el sur, mantuvo las profundidades de los lagos del Valle de México con una cierta proporcionalidad aún en el siglo XIX, cuando se planteó el desagüe del lago de Chalco. Una vez lograda la independencia y zanjada la fase imperial, el gobierno republicano hizo énfasis en la necesidad de proteger a los habitantes del Valle de México de aquellos males recurrentes. Era preciso

coadyuvar al tajo de Nochistongo con una vía de desagüe alterna: la de Huehuetoca. Por otra parte, se propuso que sería prudente propiciar la desecación de los lagos de manera directa. Los avances en estos proyectos fueron lentos por culpa del ambiente de inestabilidad política que vivía el país, y en 1846, se ordenó inundar los terrenos situados al oriente, y para obtenerlo se abrieron zanjas y sangrías por Mexicaltzingo, que vaciaron gran caudal de agua en las llanuras del Peñón. Las lluvias registradas en las décadas de los cincuenta y los sesenta provocaron otra vez importantes inundaciones. Entonces el gobierno federal ordenó la realización del desagüe directo de los lagos de Xochimilco y de Chalco. El lago de Xochimilco se extendía hasta el dique de Culhuacán, cubriendo sus aguas las fincas de la orilla con todos sus bordos. Ante todo, fue preciso proceder a aislar los vasos de las haciendas, levantando su bordo frente al lago, cincuenta centímetros, en una extensión de dos leguas. Esta sección fue la primera que se desaguó, sangrando el dique bajo el puente de Culhuacán. Los desagües directos surtieron efecto rápidamente y agudizaron el problema de la evaporación. En ambos lagos el nivel del agua descendió y la superficie se cubrió por una capa de hierba pantanosa. La capa de suelo flotante que se encuentra en los lagos de Chalco y Xochimilco, impiden la evaporación del agua (Gallardo, 2017). En la (figura 2) se observa la situación en la que se encuentran actualmente los lagos del valle de México (Gallardo, 2017).

El nivel de este par de lagos continuó disminuyendo de manera paulatina en el período finisecular. El fango de las laderas arrastrado por las aguas, los ha hecho menos profundos de lo que eran en tiempos prehispánicos. A la postre, en el umbral del siglo XX, el ex presidente Porfirio Díaz incluyó en su agenda política, en el apartado de infraestructura, un estímulo especial para el desagüe efectivo del Valle de México. Más tarde, la modernización posrevolucionaria hizo que la mancha urbana creciera paso a paso en franco detrimento de los lagos de Xochimilco y de Chalco. A partir de diciembre de 2014, la aprobación del proyecto denominado “Nuevo Aeropuerto

Internacional de las Ciudad de México, S. A. de C. V.” por la Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT) en general, y por la Dirección General de Impacto y Riesgo Ambiental en particular, puso en alerta a algunas organizaciones de la sociedad civil porque, según los entendidos en la materia, supone una amenaza de proporciones apocalípticas: el colapso del sistema hídrico del Valle de México, por exceso de consumo regular de agua 23.6 millones de metros cúbicos más cada año, y la desecación casi absoluta del lago de Texcoco, por la acelerada expansión de la mancha urbana. Dicho proyecto es incierto, pero su realización sin cambios sustanciales de planeación y estrategia representaría, en un horizonte hipotético, la destrucción definitiva de esas hermosas aguas interiores (Gallardo, 2017).

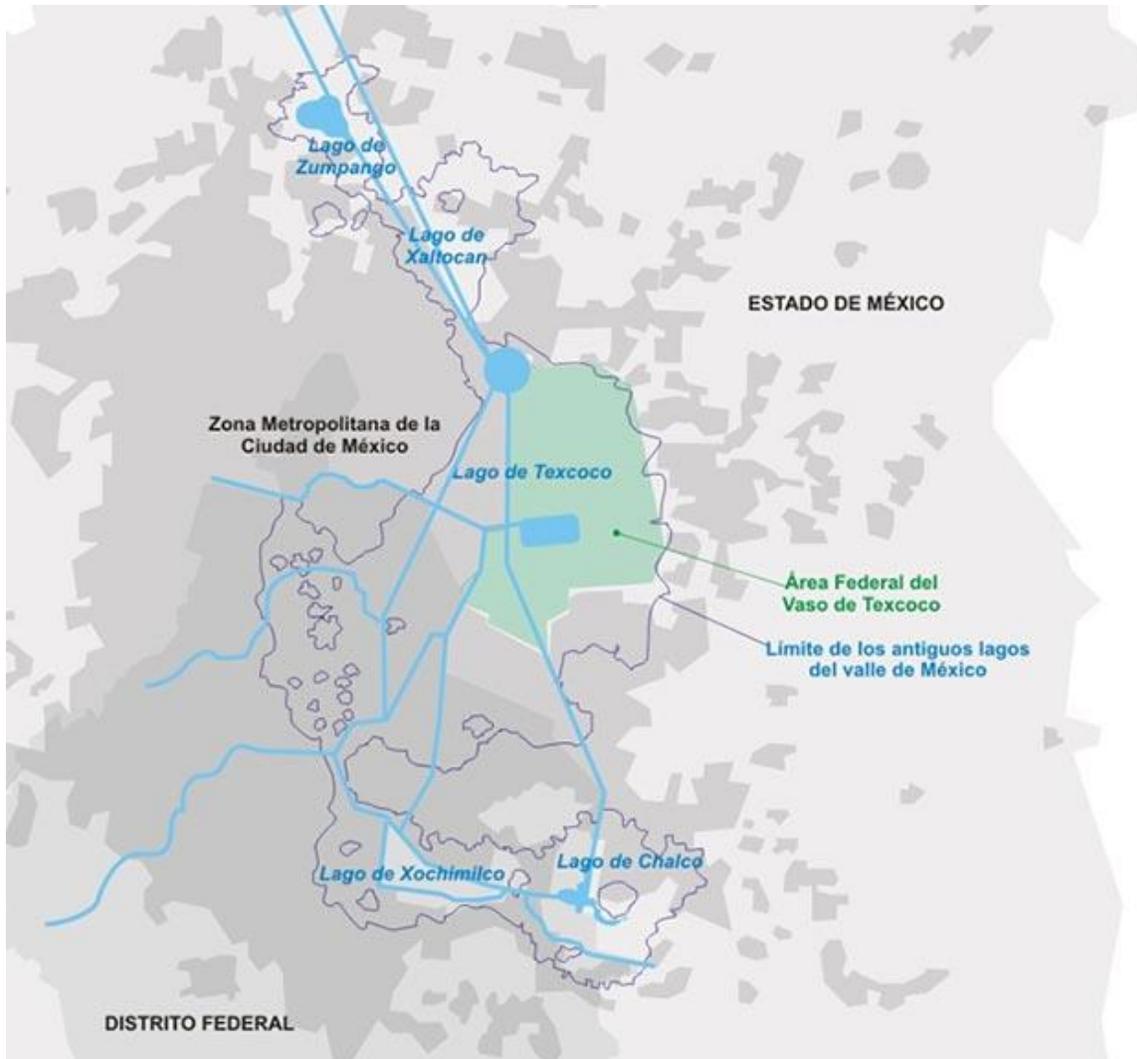


Figura 2. Mapa de la situación actual de los lagos del valle de México.

(Imagen adquirida de Gallardo, 2017).

## **Agricultura de precisión**

La agricultura de precisión tiene como objetivo adaptar el manejo de una manera coherente y holística, especialmente explotando la alta variabilidad espacial y temporal de los rasgos del cultivo y ambientales. Se abordan las variaciones en los potenciales de rendimiento, la topografía, las características del suelo, la demanda de nutrientes y los estresores abióticos. Es una tecnología que permite a un agricultor hacer lo correcto, en el lugar correcto, en el momento correcto y de la manera correcta. Para este fin, los agricultores pueden usar diferentes combinaciones de tecnologías. Distinguimos especialmente las herramientas de diagnóstico (recopilación o generación de información) y aplicativas (que implican acciones de gestión ajustadas) en tecnologías de agricultura de precisión. La recopilación y estructuración de datos son la base, pero en última instancia, el alto potencial de la agricultura de precisión resulta de la combinación de diferentes tecnologías aplicadas a derivar prácticas de gestión de los datos recopilados (Finger *et al.*, 2019).

Las tecnologías de georreferenciación, como el sistema de posicionamiento global (GPS) y el mapeo a través de sistemas de información geográfica (SIG), son elementos clave de muchas aplicaciones de la agricultura de precisión. Estas tecnologías permiten el uso de sistemas de guía y tráfico controlado durante las operaciones de campo, como la labranza, la cosecha y la aplicación de insumos como nitrógeno, semillas y pesticidas. Debido a que no se necesitan más habilidades ni maquinaria nueva para utilizar las tecnologías de georreferenciación, se refieren a ellos como tecnologías de conocimiento incorporado. Sin embargo, la información de georreferenciación es especialmente poderosa para alcanzar ganancias de eficiencia si se usa junto con otros sensores para proporcionar mapas georreferenciados de rendimiento, salinidad u otros rasgos ambientales

medibles, pero también simplemente reduciendo la superposición durante las operaciones de campo (Finger *et al.*, 2019).

Las herramientas de diagnóstico recopilan información utilizando técnicas de detección o muestreo a lo largo de varias escalas. Las herramientas de detección más importantes utilizan índices espectrales que se toman de las imágenes y proporcionan información sobre la coloración de la vegetación observada. Con frecuencia, los sensores y escáneres montados en tractores se utilizan para proporcionar información sobre el estado de los nutrientes. Los enfoques de detección iniciales han establecido el índice de diferencia de vegetación normalizado (NDVI) como una medida para el suelo cubierto con tejido foliar funcional. NDVI se ha calculado a partir de datos en el infrarrojo cercano y en el rango de longitud de onda roja desde la década de 1970 (Mulla, 2013).

Las imágenes tomadas de los satélites se han utilizado desde la década de 1970 para extraer información agrícola relevante. El primero de esos satélites, Landsat 1, recopiló información en cuatro bandas espectrales (rojo, verde y dos bandas infrarrojas) a una resolución espacial de 80 m y una frecuencia de retorno de 18 días. Mientras tanto, los satélites como QuickBird y RapidEye que están equipados con tecnología de sensor más sofisticada pueden proporcionar tiempos de revisión entre uno y tres días, resoluciones de píxeles espaciales de menos de 1 m y un mayor número de bandas espectrales. Los datos de estos satélites no son fáciles de procesar y son costosos. Desde 2017, los datos de Sentinel 2 están disponibles públicamente, con una resolución espacial de 10 m en 13 bandas espectrales posiblemente relevantes, lo que lleva a opciones más baratas y más precisas para el diagnóstico del estado de la vegetación y los nutrientes de lo que era posible anteriormente. Además, la detección casi remota se basa en vehículos aéreos no tripulados (VANT) como los drones. Dentro de un campo pequeño, los VANT se han utilizado cada vez más para proporcionar imágenes con resoluciones en el rango de centímetros y

permiten la detección de una gran cantidad de rasgos relevantes, como la biomasa del cultivo, la etapa de desarrollo, la eficiencia fotosintética, el estado nutricional del nitrógeno o las propiedades del suelo sin la molestia de las nubes que posiblemente cubran la información, como suele ser el caso de los satélites. Además, la exploración de malezas, por ejemplo, se puede facilitar con VANT. Para monitorear los rasgos del cultivo y ciertas otras condiciones ambientales, otros sensores como las imágenes térmicas, conductividad eléctrica del suelo y técnicas de muestreo de suelo basado en GPS con respecto a nutrientes disponibles, nivel de pH, humedad del suelo, etc.) son de uso frecuente. Además, los sensores *in situ* capaces de monitorear en tiempo real el nitrógeno del suelo pueden mejorar el manejo de los fertilizantes, las tasas de siembra y el uso de reguladores de crecimiento que explotan la variación espacial del nitrógeno del suelo. Finalmente, también se utilizan dispositivos de mano para medir el estado nutricional de las plantas. (Shaw *et al.*, 2016).

La adopción de la agricultura de precisión, de acuerdo con las expectativas de modelos económicos, las tecnologías de diagnóstico de la agricultura de precisión se están adoptando más ampliamente en comparación con las tecnologías de aplicación. El número de dispositivos agrícolas para recopilar datos en todo el mundo se estimó en 30 millones en 2015 y se espera que aumente a 75 millones en 2020. Los sistemas de guía, GPS y mapeo GIS son comunes en la maquinaria nueva en muchos países, por ejemplo, informa que las tasas de adopción en Kansas están por encima del 80%. Los sistemas de monitoreo de rendimiento también se utilizan ampliamente y se incorporan a la mayoría de las cosechadoras nuevas a gran escala en América del Norte. El 46% del maíz, el 36% de la soya y el 15% del trigo en los Estados Unidos se cosechan mediante una cosechadora que permite el monitoreo del rendimiento. Sin embargo, se encontró que la proporción de granjas que también utiliza el software de mapeo SIG para almacenar, administrar y analizar los datos de tecnologías específicas del sitio es menor

que la proporción equipada con monitores de rendimiento. La detección remota con imágenes satelitales o los enfoques de detección de plantas se adoptan con menos frecuencia que las tecnologías de diagnóstico en el campo. Por ejemplo, el 25% de las granjas de Nebraska utilizan imágenes satelitales en comparación con una captación del 80% de los monitores de rendimiento y los sistemas de guía GPS (Finger *et al.*, 2019).

Los efectos ambientales de la agricultura de precisión. Se ha esperado ampliamente que la agricultura de precisión muestre beneficios ambientales. La aplicación más específica de insumos con menos pérdidas de fertilizantes y pesticidas para el medio ambiente, el consumo reducido de agua y las emisiones reducidas de gases de efecto invernadero proporcionan un amplio espectro de beneficios ambientales. Sin embargo, la magnitud de estos efectos a menudo no se conoce bien o es muy variable. Además, la mayoría de los estudios no informan los impactos observados, sino los posibles impactos basados en datos experimentales o predicciones del modelo. Solo unos pocos estudios muestran una inferencia causal sobre el desempeño ambiental de la agricultura de precisión en aplicaciones agrícolas del mundo real. Con estas advertencias, sintetizamos algunas áreas clave de los beneficios ambientales derivados de la agricultura de precisión con base a los estudios disponibles. En general, agricultura de precisión reduce las emisiones de gases de efecto invernadero. Primero, la guía de máquinas y la agricultura de tráfico controlada reducen el consumo de combustible debido a una menor superposición en las operaciones agrícolas. Se ha encontrado que los sistemas de guía causan una reducción del 6% en el uso de combustible y una reducción del 25% en los gastos de combustible. Estas reducciones son mayores para los campos a gran escala, y vienen con varios beneficios cobeneficiosos, incluidas las reducciones en la compactación del suelo, la escorrentía y la erosión. En segundo lugar, la reducción de los efluentes implica, por ejemplo, la reducción de las pérdidas de nitrógeno como el amoníaco y los óxidos de nitrógeno (Finger *et al.*, 2019).

Al aumentar la eficiencia de la aplicación, las pérdidas de insumos críticos para el medio ambiente generalmente se reducen. Por ejemplo, para la producción de cítricos de Texas, comparan el análisis multiespectral en el aire con la inspección humana para identificar problemas de salud de los árboles y guiar la aplicación de pesticidas. La técnica multiespectral en el aire combinada con VRT condujo a reducciones en el uso de pesticidas en más del 90%. En este sentido, muestran que, en varios estudios, el uso de herbicidas podría reducirse entre un 11% y un 90% mediante la aplicación de precisión en diferentes cultivos herbáceos (Finger *et al.*, 2019).

En un sitio experimental en Alemania, muestran que el control de precisión de los pulgones basado en sensores, en comparación con la pulverización uniforme, podría reducir el uso de insecticidas en la producción de trigo en más del 13%. Sin embargo, los hallazgos sobre el uso de agricultura de precisión en el riego varían ampliamente, por ejemplo, dependiendo de la tecnología de referencia y las condiciones del suelo y el clima (Balafoutis *et al.*, 2017).

### **Aplicaciones de los drones**

Los VANT son aviones propulsados operados de forma remota o autónoma con planificación de vuelo preprogramada. Los dos tipos principales de configuraciones de VANT son ala fija (avión) y ala giratoria (helicóptero). Los VANT, a veces conocidos como drones, ofrecen una alternativa viable a las plataformas convencionales para adquirir datos de teledetección de alta resolución a menor costo, mayor flexibilidad operativa y mayor versatilidad. La capacidad de los VANT para capturar imágenes concurrentes con observaciones de campo resuelve un problema común de teledetección resultante de las diferencias en la adquisición de datos de tierra y teledetección. Las aplicaciones militares de la tecnología VANT se han

transferido constantemente a aplicaciones civiles y de investigación. Las mejoras en el diseño de los sistemas de control de vuelo han transformado estas plataformas en herramientas de grado de investigación capaces de adquirir imágenes de alta calidad y mediciones geofísicas y biológicas. También ha habido avances en el desarrollo de sensores miniaturizados, específicamente diseñados o adaptados para cargas útiles de VANT, incluidos los sensores de imágenes hiperespectrales, LIDAR, radar de apertura sintética y sensores térmicos y otros. Se han volado VANT de ala fija sobre ciudades y humedales para evaluar los daños después de huracanes, inundaciones y terremotos. La Administración Federal de Aviación ha dividido los tipos de vehículos aéreos no tripulados en cinco categorías por peso, que van desde micro (<0.9 kg) a mini a táctico a resistencia larga a media altitud y resistencia larga a gran altitud (> 13,636 kg) artesanales. También hay una categoría de pequeños vehículos aéreos no tripulados (PVANT) que pesan menos de 25 kg, que se pone a disposición para la operación civil en el sistema nacional de espacio aéreo. Dado su bajo costo, los proyectos de investigación de teledetección han utilizado principalmente PVANT en esta categoría (Klemas, 2015).

Estos PVANT tienen diseños avanzados para transportar pequeñas cargas útiles y sistemas de control de vuelo integrados, dándoles capacidades de vuelo semiautónomas o totalmente autónomas. En los VANT autónomos, la adquisición de datos de teledetección está reprogramada con un software de planificación de vuelo que puede calcular puntos de referencia para la adquisición de imágenes en función de la resolución de terreno deseada, la cantidad de superposición de imágenes y el área a estudiar. Las cámaras digitales son comúnmente parte de la carga útil. Durante el vuelo, el piloto automático de los VANT puede comunicarse a través de un enlace de telemetría a una estación terrestre con software de control de vuelo (Hugenholtz *et al.*, 2012). Por ejemplo, el AeroVironment RQ-14A "Dragon Eye" tiene una envergadura de 110 cm y pesa alrededor de 2.5 kg. Lanzado

a mano o con un cable elástico, el pequeño avión se controla mediante coordenadas GPS ingresadas en su sistema de guía con una computadora portátil estándar. Una vez en el aire, puede transmitir imágenes de video del paisaje costero en tiempo real (Klemas, 2015).

Los vehículos aéreos no tripulados amplían nuestra capacidad de observar eventos dinámicos que alteran el paisaje y realizar encuestas en áreas logísticamente desafiantes. Por ejemplo, los VANT están reemplazando a las aeronaves tripuladas en estudios de áreas remotas y peligrosas, como las regiones polares. Todavía hay obstáculos técnicos y legales que se interponen en el camino del uso más amplio de los VANT. Uno de los desafíos más difíciles que enfrenta la operación de los VANT se refiere a la inserción de estos sistemas en el espacio aéreo no segregado. Esto se deriva de los estrictos requisitos de seguridad para el transporte aéreo tripulado (Klemas, 2015).

Drones de ala rotatoria: Los aparatos con ala rotatoria son aquellos en los cuales, las fuerzas de sustentación se logran mediante el giro de las hélices en el aire, siendo estos aparatos también conocidos como multirrotores o helicópteros, las características más importantes de estos son (Oñate, 2015):

- Despegue y aterrizaje vertical, reduciendo las necesidades de espacio para las maniobras de aterrizaje y despegue.
- Posibilidad de volar a puntos fijos Vuelo estacionario, muy útil para aplicaciones de inspección.
- Mayor maniobrabilidad y precisión de vuelo, ya que los sistemas de ala fija siguen trayectorias curvilíneas, con radios de giro relativamente grandes y velocidades de ascenso y descenso bastantes estrictas, sin embargo, los multirrotores pueden volar siguiendo cualquier trayectoria en las tres dimensiones.

- El diseño de los multirrotores permite embarcar cargas de pago más voluminosas.

Drones de ala fija: Los aparatos de ala fija, son los considerados como aviones, y sus principales características son (Oñate, 2015):

- Son más eficientes que los multirrotores, ya que, a igualdad de tamaño, tienen mayor autonomía.
- Vuelan a mayor velocidad, por lo que al tener además mayor autonomía recubren más superficie, siendo más útiles en tareas de cartografía o teledetección.
- Tienen menor huella sonora, siendo más indicados para operaciones de vigilancia.
- Tienen mayor rango meteorológico, en términos de temperatura, viento y lluvia.

### **Vehículos aéreos no tripulados en el entorno del aprendizaje automático**

Los enfoques tradicionales de sensores remotos también tienen una serie de inconvenientes: las imágenes satelitales a menudo tienen problemas con la cobertura de nubes, sin embargo, en los últimos años, el uso de vehículos aéreos no tripulados VANT aumentó gracias a los avances tecnológicos, la reducción de costos y el tamaño de sensores. En la (figura 7) se aprecia el incremento de los ingresos anuales en millones de dólares desde 2016 hasta los esperados en 2025. Los VANT podrían ser operados por los propios agricultores para diagnosticar características del cultivo, como el estrés hídrico. Las tecnologías de imágenes se basan principalmente en las reflectancias de la longitud de onda visibles, como el rojo, el verde y el azul, y el rango no visible del espectro, como el infrarrojo cercano a (NIR). El monitoreo remoto de estas reflectancias específicas se realiza comúnmente

utilizando cámaras visibles, multiespectrales e hiperespectrales (Romero *et al.*, 2016).

Los VANT y el aprendizaje automático son útiles en la minería de datos a partir de mapas multidimensionales, desarrollo de infraestructura y agricultura de precisión. Por ejemplo, los modelos de redes neuronales artificiales se utilizan en el proceso de lluvia-escorrentía, predicción de la evaporación, estimación de la absorción de agua de la planta, clasificación de la planta basada en hojas, predicción del rendimiento del cultivo y mitigación de humedales para el manejo de carreteras. Los datos de la imagen de los VANT se utilizan para el proceso ecológico y el modelado estructural (Islam & Al-Mulla, 2019).

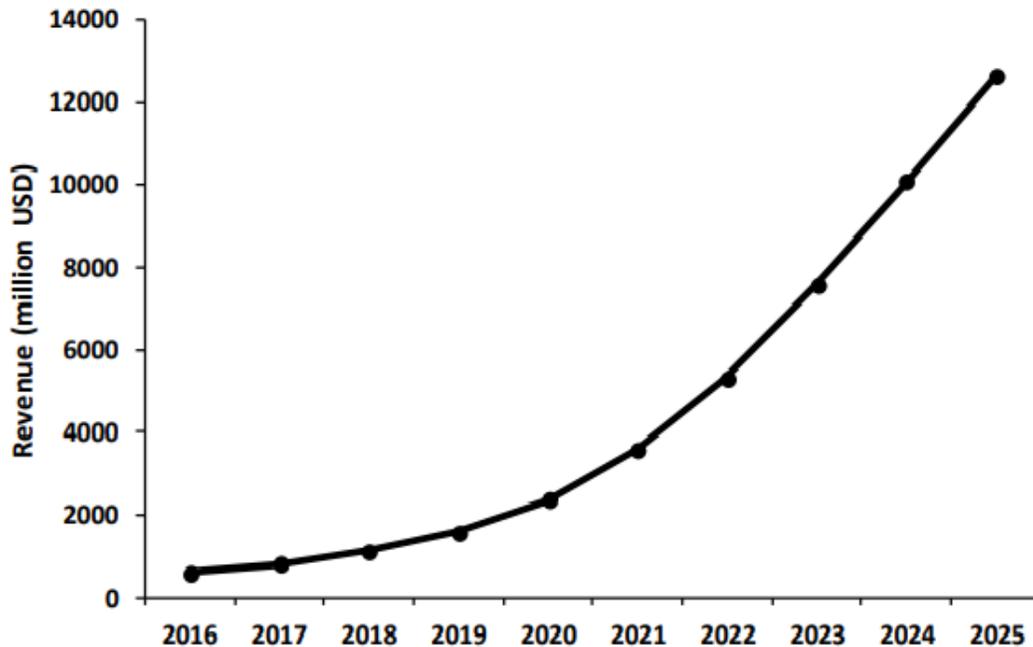


Figura 3. Ingresos comerciales de los VANT en todo el mundo desde 2016 hasta 2025.

(Gráfica adquirida de Islam & Al-Mulla, 2019).

Los VANT tiene la capacidad de grabar fotografías multiespectrales, y su operador puede controlar las resoluciones de imágenes volando a diferentes alturas. Sin embargo, es difícil interpretar imágenes de alta resolución sin algoritmos de aprendizaje automático. El bosque aleatorio es una técnica de aprendizaje agrupada, que utiliza la agregación de arranque para las clasificaciones de imágenes. Con este método se pueden proporcionar estimaciones espectrales. El modelado aleatorio basado en el bosque tiene un mejor rendimiento que las redes neuronales artificiales y admite máquinas de vectores. Los algoritmos de máquinas de aprendizaje extremo se utilizan en problemas de regresión y clasificación en datos cuantitativos de teledetección (Islam & Al-Mulla, 2019).

Los VANT en el entorno de aprendizaje automático: El avance en algoritmos de aprendizaje automático, sensores y tecnologías, ha abierto las puertas para aplicaciones de los VANT en muchos sectores. Sin embargo, los principales sectores son la red informática inalámbrica, las ciudades inteligentes, el ejército, la agricultura y la minería (Islam & Al-Mulla, 2019).

Red informática inalámbrica: Varios investigadores han implementado con éxito a los VANT en la red informática inalámbrica. La máquina de estado líquido se utilizó como un algoritmo de aprendizaje automático para la gestión de recursos en la red basada en los VANT, se implementó una red los VANT en diferentes entornos de control, Q-learning multiagente y Echo State Network se aplicaron en el control y gestión de redes inalámbricas asistidas por VANT (Islam & Al-Mulla, 2019).

En la agricultura: La combinación de aprendizaje automático e imágenes de los VANT ha demostrado su utilidad para predecir el contenido de humedad del suelo, el riego y la gestión del agua. Asimismo, en bosques aleatorios, en vectores de soporte y la regresión lineal múltiple se han utilizado para predecir la producción de vegetación, así como para la clasificación de cultivos (Islam & Al-Mulla, 2019).

Las otras aplicaciones incluyen la creación de registros estadísticos para la vida silvestre, la geología y la industria minera. Los algoritmos de aprendizaje automático con VANT se han utilizado para la detección de animales. La clasificación del modelo de minería geológica basada en la detección de características de superficie a través de algoritmos de aprendizaje automático. Los VANT tiene las ventajas de volar a baja altitud, tamaño pequeño, alta resolución, peso ligero y portabilidad. Los VANT y el aprendizaje automático tienen un alcance inmenso en la investigación científica. La investigación combinada de VANT y aprendizaje automático aún no ha alcanzado la madurez. Estados Unidos y Asia pacífico representan la mayor parte de la investigación de VANT. Existen problemas de seguridad y privacidad debido a la proliferación de VANT comerciales no registrados. Actualmente existen modelos entrenados de aprendizaje automático para reconocer objetos desde los VANT y las imágenes satelitales (Islam & Al-Mulla, 2019).

## **Teledetección**

La Teledetección de recursos naturales se basa en un sistema de adquisición de datos a distancia sobre la biosfera, que está basado en las propiedades de la radiación electromagnética y en su interacción con los materiales de la superficie terrestre. Todos los elementos de la naturaleza tienen una respuesta espectral propia que se denomina signatura espectral. La Teledetección estudia las variaciones espectrales, espaciales y temporales de las ondas electromagnéticas, y pone de manifiesto las correlaciones existentes entre éstas y las características de los diferentes materiales terrestres. Su objetivo esencial se centra en la identificación de los materiales de la superficie terrestre y los fenómenos que en ella se operan a través de su signatura espectral. La información se recoge desde plataformas de observación que pueden ser aéreas o espaciales, pues los

datos adquiridos a partir de sistemas situados en la tierra constituyen un estadio preparatorio de la teledetección (Sacristán, 2006).

Las plataformas de observación portan los captosres, es decir, aquellos instrumentos que son susceptibles de recibir y medir la intensidad de la radiación que procede del suelo en una cierta gama de longitudes de onda, y para transformarla en una señal que permita localizar, registrar y digitalizar la información en forma de fotografías o imágenes numéricas grabadas en cinta magnética compatibles con un ordenador (CCT). Los captosres pueden ser cámaras fotográficas, radiómetros de barrido multiespectral (MSS), radares y láseres. Estos aparatos generan imágenes analizando la radiación emitida o reflejada por las formas y objetos de la superficie terrestre en las longitudes de onda en las cuales son sensibles (ultravioleta, visible, infrarrojo próximo, infrarrojo técnico, hiperfrecuencias) con el fin de reconocer la variada gama de formas y objetos. Características de los datos de teledetección El conjunto de los datos adquiridos mediante procedimientos de teledetección de aviones o naves espaciales comprenden siempre tres tipos de información (Sacristán, 2006):

1. Una información espacial que representa la organización en el espacio físico de los elementos que constituyen la imagen.
2. Una información espectral que caracteriza y puede conducir al conocimiento de la naturaleza de la superficie terrestre.
3. Una información temporal que permite la detección de los cambios operados en la superficie de la tierra con el transcurso del tiempo.

En definitiva, los datos adquiridos a través de teledetección se caracterizan por las siguientes propiedades:

1. Posibilidad de obtener información sobre aspectos del medio natural que escapan totalmente a nuestros sentidos (ondas de radar, infrarrojo de LANDSAT, etc.).

2. Estas informaciones que son registradas por los sensores, y que miden la cantidad de energía reflejada o emitida por los objetos naturales que componen el paisaje son de tipo numérico, y se prestan al tratamiento matemático. Por otro lado, su extremada abundancia obliga al empleo de grandes ordenadores y métodos de tratamiento de datos muy sofisticados y potentes.

3. Los datos extraídos de los servicios de teledetección nos revelan ciertos aspectos de los ecosistemas difíciles de estudiar, prácticamente desconocidos, contribuyendo de una forma eficaz al conocimiento de los mismos y de su funcionamiento (detección de enfermedades en las plantas, efectos del estrés debido a la falta de agua, transpiración, régimen térmico, etc.).

4. La teledetección permite seguir la evolución de las grandes extensiones forestales que persisten en la superficie del globo, tener una visión de conjunto sobre los efectos producidos por las grandes catástrofes (como, por ejemplo, las sequías de las regiones saharianas de África) y reconocer ciertos fenómenos de polución a gran escala en el cielo y en el mar.

La clasificación automática de los datos digitales de teledetección es una gran ayuda para el investigador en la interpretación de imágenes multiespectrales. El objetivo de toda clasificación es el reconocimiento de clases o grupos cuyos miembros tengan ciertas características en común. El resultado ideal sería la obtención de clases mutuamente excluyentes y exhaustivas. En teledetección, las clases obtenidas cuando se realiza una clasificación deben ser espectralmente diferentes unas de otras, y además deben contener un valor informativo de interés para la investigación de que se trate. Tradicionalmente, se han seguido dos enfoques en la realización de las clasificaciones: uno de tipo supervisado y otro de tipo no supervisado. El enfoque de tipo supervisado supone un entrenamiento de clasificador a través de un conocimiento a priori de la verdad del terreno que se ha

seleccionado como representativa de las clases informacionales que se quieran reconocer en la imagen. El enfoque no supervisado no precisa el conocimiento previo de una verdad del terreno, y tiene la pretensión de segmentar la imagen en una serie de clases por procedimientos exclusivamente numéricos, basándose sólo en la estructura que posean los datos espectrales. En las clasificaciones supervisadas, normalmente se parte de la hipótesis de que la distribución de los datos espectrales es normal multivariante, lo que permite la utilización de procedimientos paramétricos, tales como los clasificadores bayesianos (Sacristán, 2006).

## **Sensores**

En los últimos años se ha producido un gran avance en el desarrollo de nuevos sensores de imagen de alta resolución, promovido especialmente por la electrónica de consumo. También, gracias al desarrollo de sensores de imagen térmica, actualmente existen en el mercado cámaras térmicas comerciales sin necesidad de refrigeración a precios asequibles para ciertas aplicaciones. De igual modo, se ha conseguido desarrollar sensores multiespectrales e hiperespectrales miniaturizados (Yuste *et al.*, 2013). En el (cuadro 4) se aprecian los sensores que más se utilizan en la fotografía aérea para la detección de diferentes parámetros.

Cuadro 2. Sensores más utilizados y su rango de la banda espectral en nanómetros.

<b>SENSOR</b>	<b>BANDA ESPECTRAL</b>
Visible RGB (cámara fotográfica)	380-780 nm
Visible (cámara de video)	380-780 nm
Infrarrojo cercano	3 bandas 500-950 nm
Multiespectral	18 bandas 500-950 nm
Hiperespectral	400 bandas 450-950 nm
Térmico	8-12 micrómetros

*Sensor Multiespectral:* Existen sensores multiespectrales miniaturizados para embarcar en vehículos aéreos no tripulados. Estos sensores pueden llegar a tomar valores de hasta 6 bandas espectrales, siendo posible seleccionar diferentes bandas mediante el empleo de filtros. Por regla general, estos sensores están diseñados para el estudio de parámetros relativos a la vegetación, por lo que las bandas están seleccionadas en los rangos del verde, rojo e infrarrojo cercano, donde la vegetación presenta su mayor respuesta de absorbanza y reflectancia. El proceso para la toma de las imágenes es similar al vuelo fotogramétrico, en cuanto a los aspectos relativos a la posterior corrección geométrica de las imágenes y generación de mosaicos. Además, el tratamiento de estas imágenes no solo precisa de corrección geométrica, sino que son necesarias operaciones de calibración radiométrica, así como las correcciones atmosféricas necesarias para la obtención de datos validados de reflectancia y temperatura de superficie (Yuste *et al.*, 2013).

*Sensor Hiperespectral:* Es el sensor más avanzado en la toma de datos espectrales. En los últimos años se han desarrollado sensores con un peso inferior a 1 kg, lo cual ha permitido su empleo mediante VANT. La mayoría de las soluciones existentes capturan la información comprendida entre 400

nm y 1.000 nm, tomando datos de hasta 300 bandas. Con ello, se consigue la máxima información espectral en el rango correspondiente a la vegetación. Al igual que en el sensor multiespectral, es precisa la corrección geométrica, calibración radiométrica y corrección atmosférica. Como resultado, se obtiene el denominado “cubo hiperespectral”, donde cada píxel de la imagen cuenta con tantos datos como bandas se han recogido. En el caso óptimo, cada píxel cuenta con 300 valores correspondientes a las bandas de 2 nm de ancho en el rango (400 – 1000) nm (Yuste *et al.*, 2013).

*Sensor térmico:* La solución pasa por la integración de un núcleo de sensor térmico, cuyo peso puede ser inferior a los 100 g, en un VANT. Dicha integración consiste en la captura de las imágenes tomadas por el núcleo, para su almacenamiento junto con los datos de telemetría del VANT, de manera que pueda procederse posteriormente a su corrección geométrica y formar el mosaico. De igual modo, es necesaria la calibración radiométrica y corrección atmosférica. El sensor térmico captura la información correspondiente al infrarrojo lejano, en el rango de 8-14  $\mu\text{m}$ , donde se observa la temperatura emitida por los elementos presentes en el área de estudio. Esta información puede advertir sobre situaciones de estrés hídrico en las plantas, permitiendo detectar ciertos problemas fitosanitarios, y facilita la detección de otro tipo de situaciones de interés a nivel forestal, tales como localización de fauna, detección de vertidos en cauces, etc (Yuste *et al.*, 2013).

## **Espectro electromagnético**

El espectro electromagnético es el sistema que clasifica, según las longitudes de onda, toda la energía desde onda corta cósmica hasta onda larga de radio que se mueve, armónicamente, a la velocidad constante de la luz. Los sensores pasivos miden la energía en la región óptica del espectro

electromagnético, que incluye el visible, infrarrojo cercano, infrarrojo medio SWIR, y el infrarrojo térmico (NASA, 2013). En la (figura 8) se puede observar las longitudes de onda y frecuencia correspondientes.

La interacción entre la energía solar y los materiales depende de la longitud de onda. La energía llega desde el sol hasta la tierra y de ahí hacia el sensor. A lo largo de esta trayectoria, la energía solar atraviesa varios medios y puede ser (NASA, 2013):

- Transmitida: La energía atraviesa de un medio a otro con un cambio en su velocidad determinado por el índice de refracción de los dos medios.
- Absorbida: La energía se incorpora a la estructura molecular del material.
- Reflejada: La energía regresar sin cambio con un ángulo de reflexión igual al ángulo de incidencia. La reflectancia es la proporción de energía reflejada con respecto a la energía incidente en un cuerpo. La longitud de onda reflejada (no la absorbida) determina el color de un objeto.
- Dispersada: La dirección de propagación de la energía cambia aleatoriamente. La dispersión de Rayleigh y la de dispersión de Mie son los dos tipos más importantes de dispersión que ocurren en la atmósfera.
- Emitida: La energía es primero absorbida y luego re-emitida, generalmente con una longitud de onda mayor. El objeto se calienta.

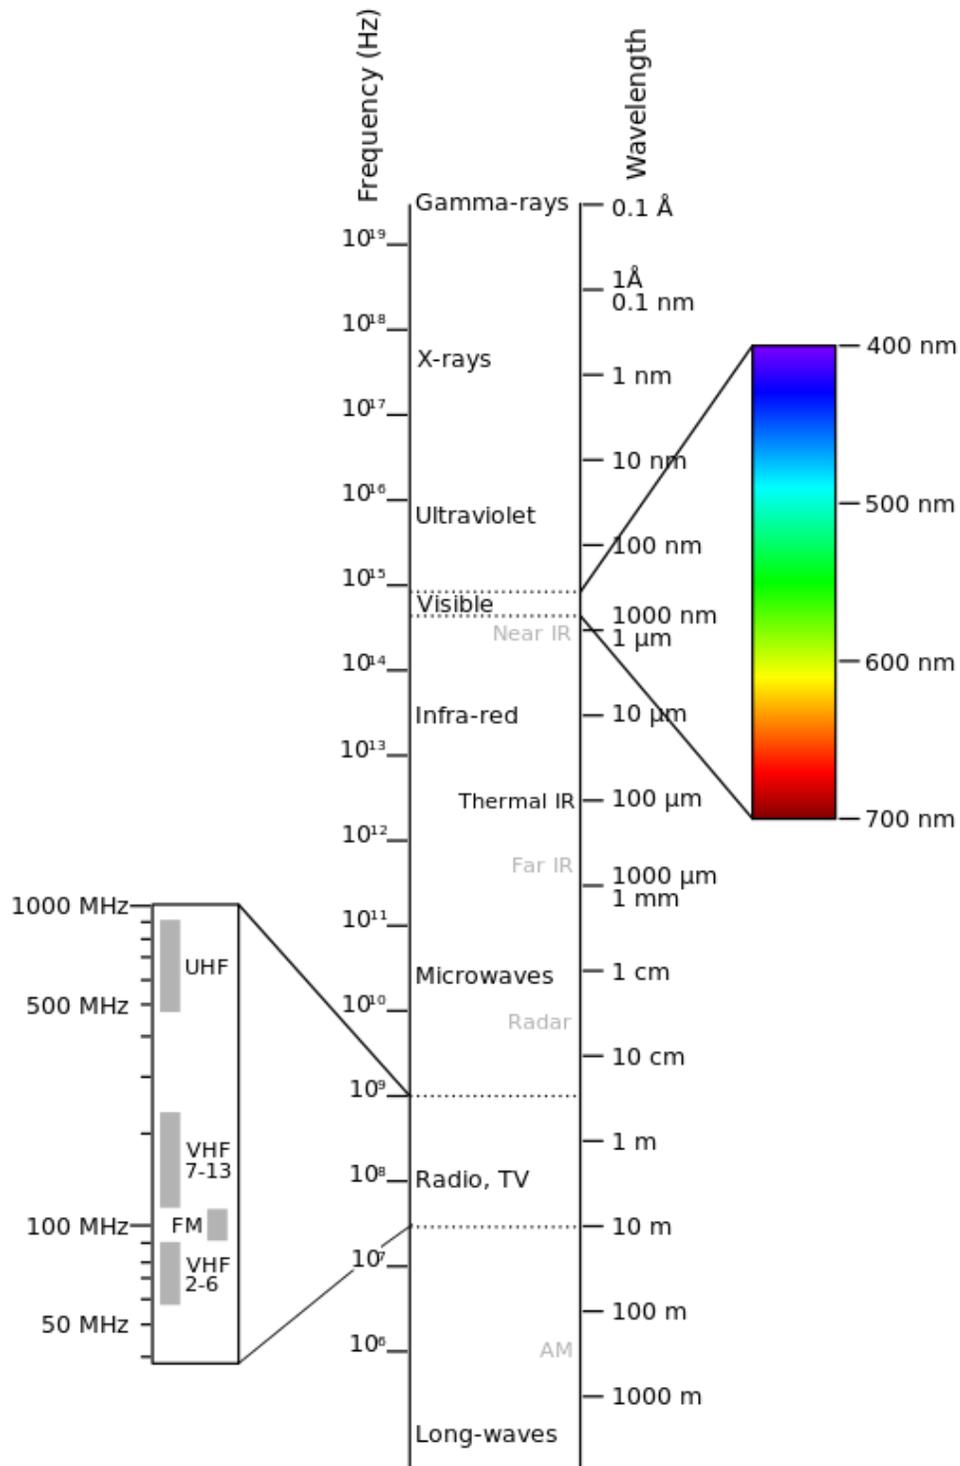


Figura 4. Espectro electromagnético.

(Imagen de Victor Blacus. Versión de archivo SVG: Electromagnetic-Spectrum.png. Tomada de Wikimedia Commons).

## **Teledetección de la salinidad del suelo**

En México las áreas de producción agrícola que presentan mayores problemas de salinidad y drenaje se localizan principalmente en los distritos de riego del norte del país. Debido a que los distritos de riego son las áreas agrícolas más productivas, la salinidad es considerada un problema serio ya que aproximadamente entre el 26 y el 30% del área está afectada por exceso de sales en diferente grado y por manto freático superficial. Debido a la dinámica de la salinización y su distribución en los terrenos, se requiere de métodos que proporcionen resultados a corto plazo y que ayuden a dar seguimiento a la efectividad de las medidas aplicadas para la rehabilitación de los suelos. Tradicionalmente para realizar estudios de salinidad se obtienen muestras de suelo y se analizan en laboratorio; esta labor representa mucho tiempo y costo, lo cual limita su actualización (Pulido *et al.*, 2010).

Los datos de teledetección tienen la capacidad de capturar información en suelos afectados por la sal tanto en extensión espacial como temporal. Sin embargo, los enfoques basados en la teledetección de la salinidad han tenido un éxito limitado en comparación con las otras aplicaciones de agricultura. El desarrollo de métodos para mapear la salinidad utilizando datos de detección remota en combinación con datos de campo han sido el objetivo de varios estudios durante las últimas dos décadas. Varios algoritmos y modelos han sido desarrollado para procesar datos de teledetección satelital. Investigaciones pasadas muestran el mapeo y la evaluación de la salinidad del suelo usando fotografía aérea, videografía, termometría infrarroja y escáneres multiespectrales, imágenes RADAR y LIDAR (Abbas *et al.*; 2013). La salinidad del suelo está relacionada con diferentes bandas espectrales, proporciones y parámetros extraídos de imágenes satelitales de suelo y vegetación. (Aldabaa *et al.*, 2015). Un gran desafío de la teledetección es detectar diferentes niveles de salinidad y sodicidad del suelo. El potencial

de estas técnicas es la capacidad de estudiar problemas de salinidad en una gran escala. Varios autores demostraron la ventaja de combinar datos de teledetección y su relación con las mediciones de laboratorio (Bouaziz *et al.*, 2011).

### **Índices de teledetección de la salinidad del suelo**

Los índices de teledetección de la vegetación, como la reflectancia de las bandas de longitud de onda NIR (Near Infrared) y varios tipos de índices de Vegetación de Diferencia Normalizada o estrés hídrico como las bandas de absorción de agua, las bandas de longitud de onda (infrarrojo de onda corta) se pueden usar como un proxy para la estimación de la salinidad del suelo agrícola. Las altas concentraciones de sal también se pueden inferir a través de la detección de firmas espectrales con plantas tolerantes a la sal que muestran crecimientos irregulares (Alexakis *et al.*, 2018).

Ciertos patrones también pueden ser indicativos de salinización del suelo, como el secado tardío o la presencia de color no natural, la formación de costras en el suelo (blanco u oscuro) es más complejo de determinar mediante la teledetección. Algunas propiedades del suelo reflejan su firma espectral en los minerales, por ejemplo, el hierro exhibe una mayor reflectancia sobre lo visible a near-infrared y la materia orgánica absorbe fuertemente en longitudes de onda más cortas como el Infra rojo. Se puede presentar dispersión geométrica óptica, por ejemplo, la reflectancia disminuye proporcionalmente al contenido de suelo limoso y a las condiciones de humedad. El agua del suelo presenta picos de absorción aproximadamente 1450, 1880 y 2660 nm) (Alexakis *et al.*, 2018).

Aprovechando estas propiedades, una gama de índices se han desarrollado para detectar y mapear la salinidad del suelo con el uso sensores remotos multiespectrales e hiperespectrales. La detección remota por infrarrojo

cercano puede contribuir significativamente a la detección de cambios temporales relacionados con las características de la superficie, tales como costras o manchas de color no natural (blanco u oscuro) y cambios de textura debido a las grietas. Las mediciones de imágenes satelitales combinadas con datos terrestres, han mostrado potencial para el mapeo de salinidad (Yang *et al.*, 2016). Sin embargo, estos índices no han dado resultados consistentes, el seleccionar un solo índice puede no ser adecuado para todos los casos (Alexakis *et al.*, 2018).

La teledetección utiliza la energía electromagnética que se refleja de objetivos de interés para obtener información sobre la superficie de la tierra. La reflectancia de la vegetación se puede utilizar como un indicador indirecto de la salinidad del suelo. La vegetación saludable tiene una baja reflectancia en la región visible debido a la absorción de clorofila, que se usa para la fotosíntesis y una alta reflectancia en la región del infrarrojo cercano debido a la estructura celular de las hojas de las plantas. En contraste, la vegetación poco saludable tiene menos clorofila y por lo tanto muestra una mayor reflectancia en la región visible y reflectancia reducida en la región near infrared. La baja resolución espacial son una de las razones principales de la débil correlación entre los datos de salinidad del suelo y datos de teledetección. Las altas resoluciones espaciales tienen un significativo efecto sobre la capacidad para identificar la salinidad del suelo (Allbed *et al.*, 2014).

Los procesos dinámicos en la superficie del suelo salino limitan el monitoreo y la evaluación del proceso de salinización porque influyen en el comportamiento espectral, espacial y temporal de las características de la sal. A través de las propiedades fisicoquímicas del suelo, como el contenido de humedad del suelo, la materia orgánica, la textura del suelo, los tipos de color de la arcilla y la rugosidad de la superficie, se determina la reflectancia espectral del suelo. Debido a la salinidad, estas propiedades del suelo cambian y afectan la reflectancia espectral de las características que se producen en la superficie del suelo, incluidas las costras de sal, además de

las variaciones en la textura y estructura de la superficie. El suelo salino con costra se refleja fuertemente en las bandas visibles y near infrared. Una superficie de suelo salino con costra es generalmente más lisa que una superficie no salina y exhibe una alta reflectancia en las bandas visibles y near infrared. La reflectancia en las bandas visibles y near infrared se ve muy afectada tanto por el color de la corteza como por los factores de rugosidad de la superficie (Allbed & Kumar, 2013).

El mapeo directo de la salinidad del suelo con imágenes multiespectrales tiene limitaciones importantes, especialmente cuando no hay características de sal en la superficie del suelo y donde los suelos salinos están dominados por plantas halófitas. Además, (Furby *et al.*, 1995) declaró que los sensores de satélite multiespectrales causaron una reflectancia confusa, ya que descubrieron que los suelos no salinos se confundían con áreas desnudas y extremadamente salinas.

El uso de sensores para la detección de salinidad es restrictivo, ya que su resolución espectral influye en la calidad y cantidad de la información que proporcionan. Los sensores hiperespectrales ofrecen una gran cantidad de bandas espectrales con alta resolución espacial que permiten la discriminación de las plantas halófitas de las plantas no halófitas, así como la identificación de las características de la sal superficial en mayor detalle que los sensores multiespectrales. Se han propuesto tres índices de salinidad espectral: el índice de brillo (BI), el índice de salinidad de diferencia normalizada (NDSI) y el índice de salinidad (SI). Entre estos índices, encontraron que (NDSI) arrojó los resultados más aceptables en la identificación de diferentes clases de sal. Además, (Bannari *et al.*, 2008) han propuesto tres índices de salinidad diferentes, SI-1, SI-2 y SI-3, para discriminar la salinidad del suelo leve y moderada y la sodicidad. Aunque los resultados mostraron que SI-3 tuvo la mayor correlación (Allbed & Kumar, 2013).

La variabilidad espacial, temporal y vertical en el perfil del suelo son los factores limitantes en la evaluación y el mapeo de la salinidad del suelo utilizando datos de detección remota, porque la reflectancia espectral no puede proporcionar información sobre todo el perfil del suelo, ya que solo observa la superficie del suelo. Además, las características de la superficie en muchos casos pueden no ser representativas del perfil más profundo del suelo. Sin embargo, combinar datos de teledetección con estudios geofísicos y modelos de simulación puede ser una opción alternativa. La detección directa de la salinidad del suelo se vuelve aplicable y mucho más fácil para suelos desnudos, cuando los síntomas relacionados con la salinidad, por ejemplo, costras y la vegetación dispersa son visibles en la superficie, en estos casos, se puede proporcionar información como los tipos y la cantidad de sal, así como el grosor de la corteza, en función de las firmas espectrales de la superficie del suelo. Sin embargo, la deducción directa de la salinidad del suelo en regiones áridas y semiáridas que se caracterizan por una cubierta vegetal densa sería difícil, ya que la vegetación causará una mezcla espectral (Allbed & Kumar, 2013).

En general, estos métodos suponen que la salinidad del suelo es el único factor estresante que disminuye y daña la condición del cultivo, mientras que otros factores como el manejo inapropiado del suelo y la calidad del agua se descuidan. Además, las diferentes plantas generalmente crecen en diferentes niveles de salinidad, por lo que el NDVI se considera un indicador incierto para el monitoreo y mapeo de la salinidad del suelo. La existencia de plantas halófitas puede confundir la detección de salinidad del suelo basada en el NDVI debido a la mezcla con la firma espectral de la sal, lo que conducirá a errores de clasificación. Por lo tanto, para superar este problema y eliminar los errores de clasificación hasta cierto punto, el índice Soil Adjusted Vegetation Index (SAVI) y otros índices y modelos han ayudado a separar las señales del suelo y la vegetación. Las imágenes satelitales de baja resolución espectral limitan la detección directa y el mapeo de la

salinidad del suelo, principalmente debido a su incapacidad para detectar bandas particulares de absorción de algunos tipos de sal y la frecuente aparición de problemas con firmas espectrales mixtas que provienen de una variedad de componentes de la superficie. La detección y el mapeo de la salinidad del suelo en regiones áridas y semiáridas mediante detección remota es un desafío. Esto se atribuye principalmente a la debilidad de las señales espectrales de los suelos salinos en comparación con el ruido causado por otros factores. Obviamente, no existe un mejor enfoque acordado para esta tecnología para monitorear y mapear la salinidad del suelo, ya que muchos investigadores han usado y aplicado diferentes herramientas y técnicas para mapear y monitorear suelos salinos con diversos grados de éxito (Allbed & Kumar, 2013).

Anteriormente, la salinidad del suelo se medía mediante la recolección de muestras de suelo en la región de interés, y luego las muestras se analizaron en el laboratorio para determinar la cantidad de conductividad eléctrica en el suelo, pero este método consume mucho tiempo y dinero. Sin embargo, los datos de teledetección ofrecen medios y técnicas más eficientes y económicamente rápidos para monitorear y mapear la salinidad del suelo. Hay muchos satélites y sensores que son útiles para detectar y monitorear el suelo salino. Los datos multiespectrales, como LANDSAT, SPOT, IKONOS, EO-1, IRS y Terra-ASTER con la resolución, pueden variar de medianos a altos, así como sensores hiperespectrales. Los sensores escanean solo la superficie del suelo, mientras que todo el perfil del suelo está involucrado y debe considerarse. Esta limitación destaca la necesidad de utilizar otros datos y técnicas, en combinación con la teledetección (Azabdaftari & Sunar, 2016).

## **Multiespectral e hiperespectral en la detección de salinidad**

Los sensores satelitales multiespectrales han sido y siguen siendo el método preferido para mapear y monitorear la salinidad del suelo. Esto se debe principalmente al bajo costo de las imágenes tienen la capacidad de mapear expresiones extremas de salinidad en la superficie. Sin embargo, los datos multiespectrales tienen una capacidad de diagnóstico limitada debido a sus resoluciones espaciales y espectrales gruesas. El mapeo directo de la salinidad del suelo con imágenes multiespectrales tiene limitaciones importantes que surgen, especialmente cuando no hay características de sal en la superficie del suelo y donde los suelos salinos están dominados por plantas halófitas. Los sensores de satélite multiespectrales pueden causar una reflectancia confusa, ya que los suelos no salinos se confundían con áreas desnudas y extremadamente salinas. La resolución espectral también puede ser insuficiente debido a que la diferencia entre los espectros de tierra salina y la tierra anegada no es suficiente para permitir la separación de espectros, así como la variable respuesta espectral del suelo salino (Allbed & Kumar, 2013).

Los sensores satelitales multiespectrales para mapeo y monitoreo de salinidad del suelo en las últimas tres décadas, han llevado a cabo una amplia investigación utilizando imágenes satelitales para mapear y monitorear la salinidad del suelo, principalmente con los siguientes sensores: Landsat Thematic Mapper (TM), Landsat Multispectral Scanner System (MSS), Landsat Enhanced Thematic Mapper Plus (ETM +), SPOT, Advanced Spaceborne Thermal Emission and Reflection Radiometer (Terra-ASTER), Sensor de auto-escaneo de imágenes lineales ( LISS-III) e IKONOS. La resolución espectral influye en la calidad y cantidad de la información que proporcionan. El desarrollo de sensores hiperespectrales ha superado algunas de las limitaciones espaciales y espectrales de las imágenes de satélite multiespectrales para monitorear y mapear la salinidad del suelo,

tanto regional como localmente. Los sensores hiperespectrales ofrecen una gran cantidad de bandas espectrales con alta resolución espacial que permiten la discriminación de las plantas halófitas de las plantas no halófitas, así como la identificación de las características de la sal superficial en mayor detalle que los sensores multiespectrales (Coimbra *et al.*, 2017).

A pesar del uso potencial de sensores hiperespectrales para detectar la salinización del suelo, no hay estudios que evalúen los efectos del ancho de banda y el posicionamiento de banda de los sensores. Los datos hiperespectrales son adecuados para este propósito, ya que permiten la simulación de resolución espectral de distintos sensores multiespectrales utilizando sus funciones de filtro. Una forma de medir la salinidad del suelo es medir la conductividad eléctrica (CE), ya sea en el campo o en el laboratorio. Dado que la mayoría de las sales reflejan fuertemente la energía solar incidente en la superficie del suelo hacia los sensores satelitales, existe una relación directa entre la reflectancia registrada en las imágenes y la concentración de sal, especialmente para NaCl. Por otro lado, hay una relación indirecta de causa y efecto, generalmente se observa entre la reflectancia del suelo y la CE de los suelos salinos. Por lo tanto, los datos de reflectancia en ciertas longitudes de onda están correlacionados con los datos de la CE, aunque no hay relación física de causa y efecto. Por lo tanto, los modelos computacionales calibrados en el laboratorio pueden generarse y aplicarse a los datos de reflectancia de las imágenes para estimar la (CE) (Coimbra *et al.*, 2017).

Hay factores que no se pueden ignorar en los estudios hiperespectrales. Estos factores incluyen la necesidad de suficiente memoria de computadora para el procesamiento rápido de datos, y la capacidad limitada de estos algoritmos funcionan con una gran cantidad de bandas. En consecuencia, para facilitar el análisis, interpretación de los resultados y aplicación de los modelos discutidos, uno de los recomendados enfoques ha sido una reducción en la dimensionalidad del conjunto de datos. Además de reducir

datos también proporcionan datos de entrada adicionales a la reflectancia espectral para usar en estos modelos, ya que pueden destacar las variaciones en las curvas espectrales asociadas con los suelos salinos (Coimbra *et al.*, 2017).

### **Regresión lineal simple**

Discutimos la correlación como un tipo de asociación en la que los valores más grandes de Y están asociados con valores más grandes de X (tendencia creciente) o valores más pequeños de X (tendencia decreciente). Si sospechamos una tendencia, podemos intentar predecir los valores de una variable usando los valores de la otra. Uno de los métodos de predicción más simples es la regresión lineal, en la que intentamos encontrar una mejor línea a través de los puntos de datos. La correlación y la regresión lineal están estrechamente relacionadas: ambas cuantifican las tendencias. Típicamente, en la correlación, tomamos muestras de ambas variables al azar de una población (por ejemplo, altura y peso), y en la regresión fijamos el valor de la variable independiente (por ejemplo, dosis) y observamos la respuesta. La variable predictora también puede seleccionarse aleatoriamente, pero la tratamos como fija cuando hacemos predicciones (por ejemplo, peso predicho para alguien de una altura determinada). Decimos que hay una relación de regresión entre X e Y cuando la media de Y varía con X. En la regresión simple, hay una variable independiente, X, y una variable dependiente Y. (Altman & Krzywinski, 2015).

## **Regresión lineal múltiple**

También conocida simplemente como regresión múltiple, es una técnica estadística que utiliza varias variables explicativas para predecir el resultado de una variable de respuesta. El objetivo de la regresión lineal múltiple (MLR) es modelar la relación lineal entre las variables explicativas (independientes) y la variable de respuesta (dependiente). En esencia, la regresión múltiple es la extensión de la regresión de mínimos cuadrados ordinarios (MCO) que involucra más de una variable explicativa (Investopedia, 2020). Es de las más utilizadas técnicas para determinar la correlación entre una variable de respuesta y alguna combinación de dos o más variables predictoras (Bouaziz *et al.*, 2011).

## **Redes neuronales**

Una red neuronal está formada por neuronas conectadas entre sí; a su vez, cada conexión de una red neuronal es asociada con un peso que dicta la importancia de esta relación en la neurona cuando se multiplica por el valor de entrada. Cada neurona tiene una función de activación que define la salida de la neurona. La función de activación se utiliza para introducir la no linealidad en la red de conexiones. En la (figura 9) se ve el proceso de aprendizaje: Ajustar los sesgos y pesos de las conexiones entre las neuronas. Objetivo: Aprender los valores de la red, parámetros (pesos  $w_{ij}$  y sesgos  $b_j$ ). (Torres, 2018).

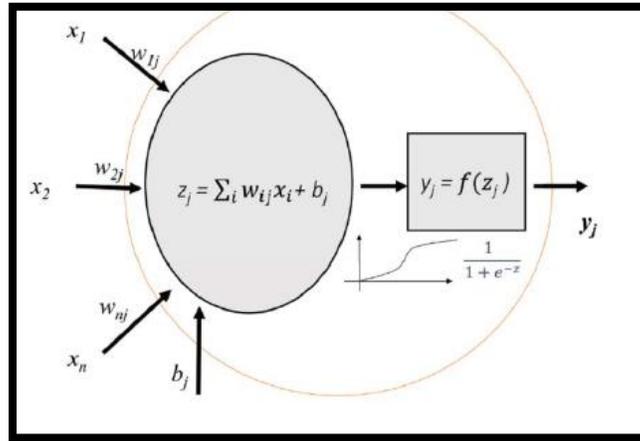
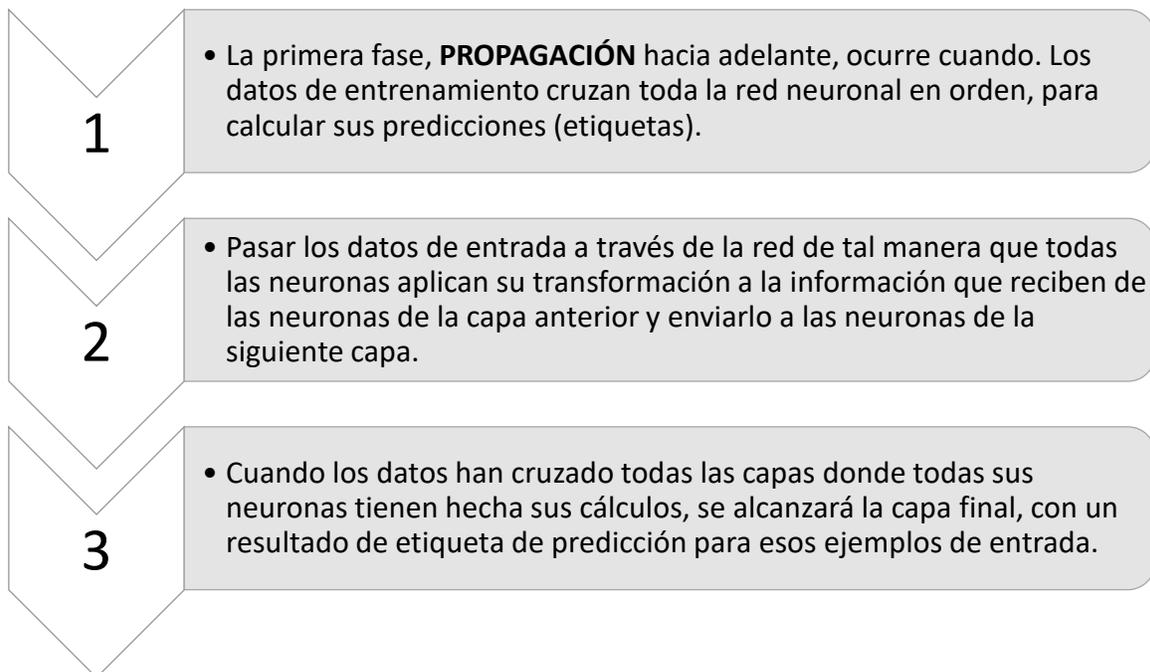


Figura 5. Ecuación básica de red neuronal.

Un proceso iterativo de dos fases (cuadro 5) y (figura 10):

- Forwardpropagation.
- Backpropagation (Torres, 2018).

Cuadro 3. Fases de la propagación en las redes neuronales.



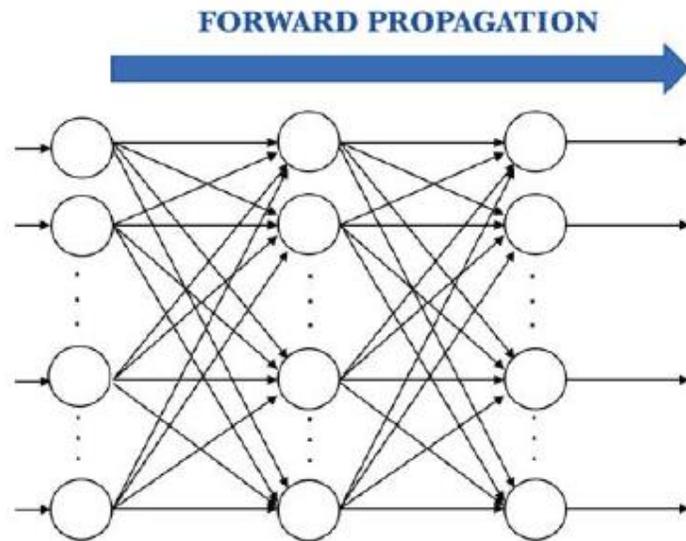
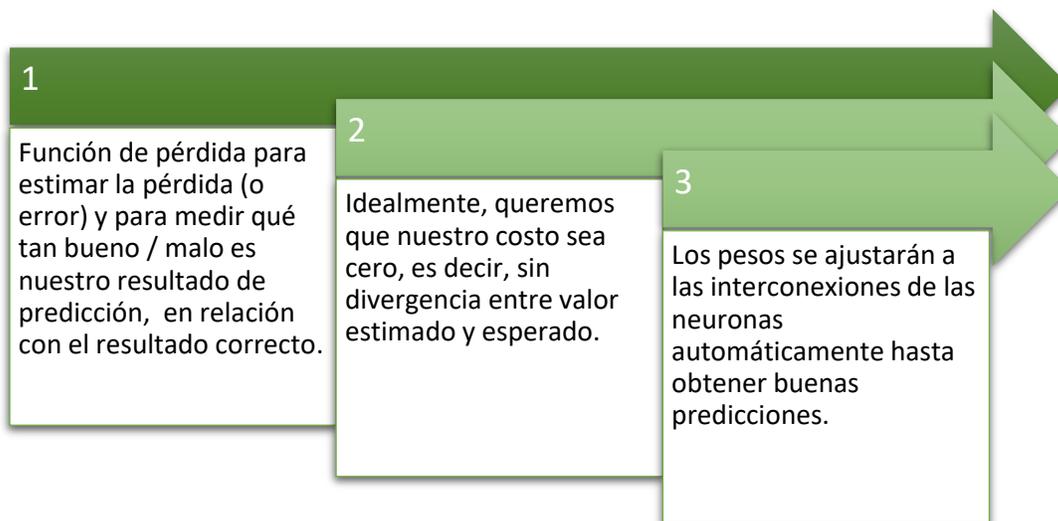


Figura 6. Ecuación básica de red neuronal.

En el (cuadro 6) y (figura 11) se analiza la secuencia que sigue la función neuronal de pérdida (Torres, 2018).

Cuadro 4. Función de pérdida.



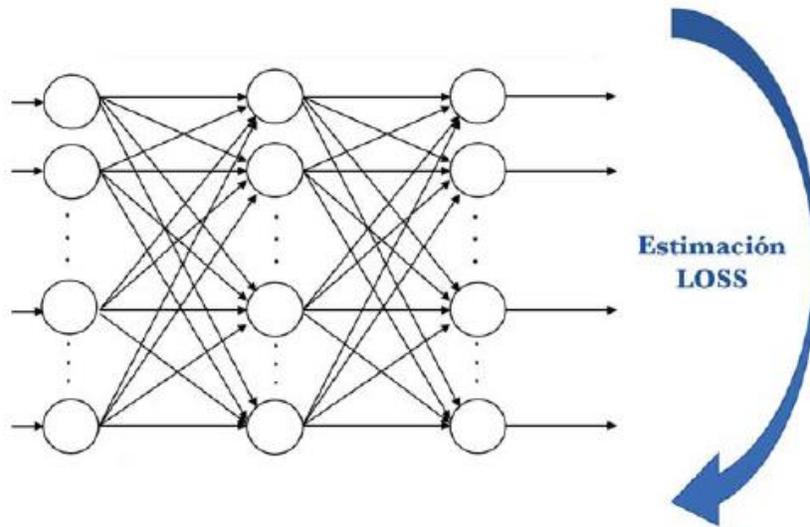


Figura 7. Representación de red neuronal de estimación de pérdida.

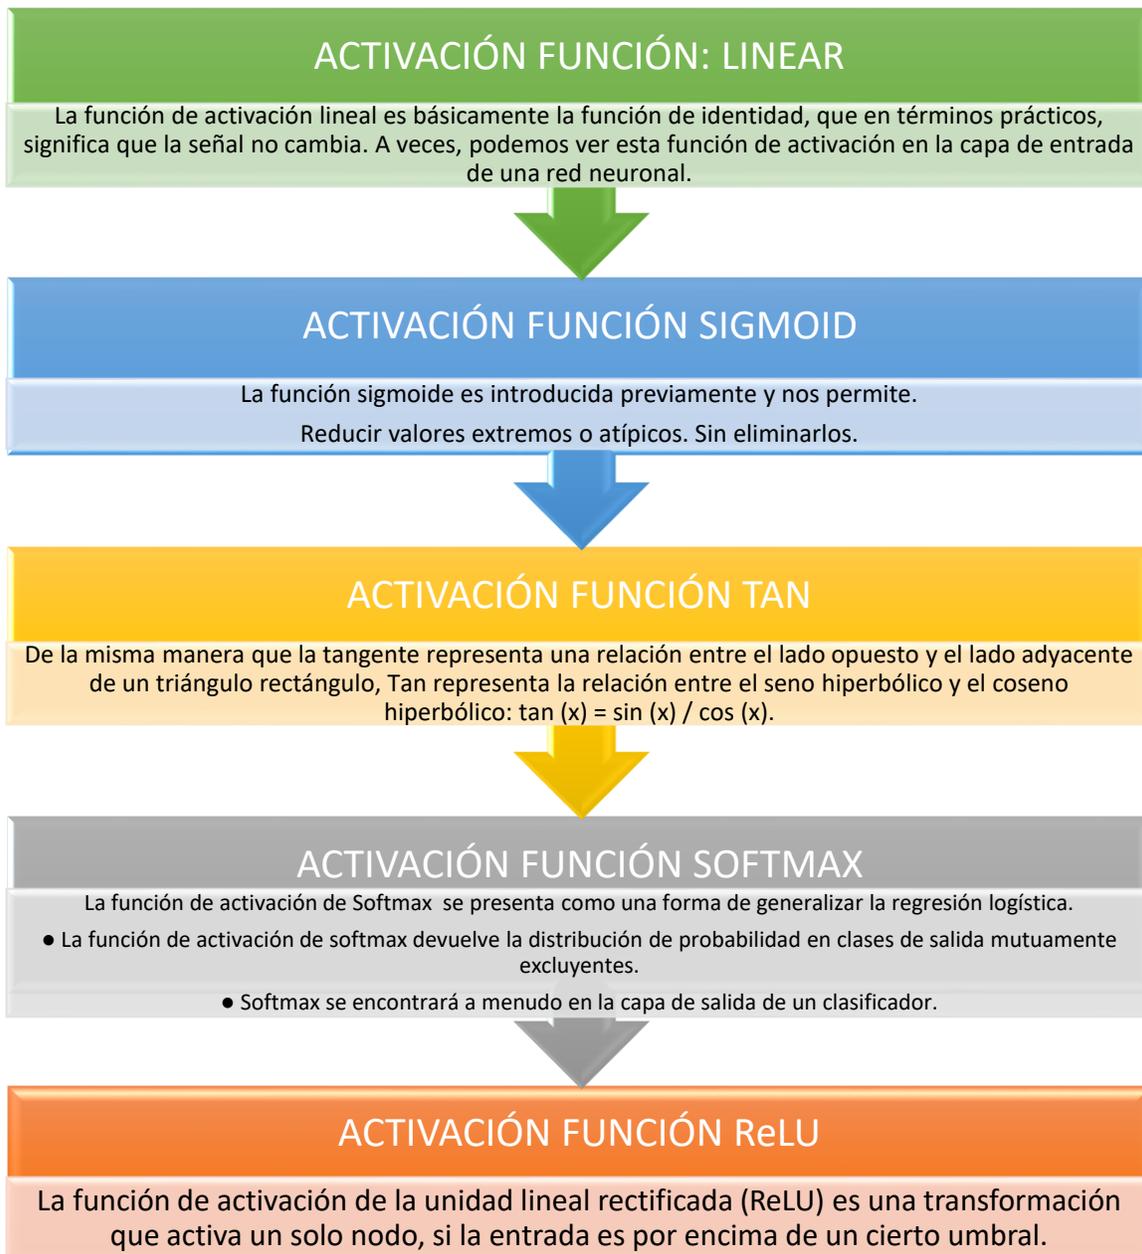
En el (cuadro 7) se representa el proceso de aprendizaje de propagación hacia atrás (Torres, 2018).

Cuadro 5. Proceso de aprendizaje hacia atrás.



Finalmente, en el (cuadro 8) se sigue la secuencia y se explican las fases de activación de la red neuronal (Torres, 2018).

Cuadro 6. Secuencia de activaciones de la red neuronal.



Las redes neuronales (también conocidas como sistemas conexionistas) son un modelo computacional basado en un gran conjunto de unidades neuronales simples (neuronas artificiales) de forma aproximadamente análoga al comportamiento observado en los axones de las neuronas en los cerebros biológicos. La información de entrada atraviesa la red neuronal (donde se somete a diversas operaciones) produciendo unos valores de salida. Cada neurona está conectada con otras a través de unos enlaces. En estos enlaces el valor de salida de la neurona anterior es multiplicado por un valor de peso. Estos pesos en los enlaces pueden incrementar o inhibir el estado de activación de las neuronas adyacentes. Del mismo modo, a la salida de la neurona, puede existir una función limitadora o umbral, que modifica el valor resultado o impone un límite que se debe sobrepasar antes de propagarse a otra neurona. Esta función se conoce como función de activación (Wikipedia redes neuronales, 2020).

*Algoritmos:* El entrenamiento de un modelo de red neuronal en esencia significa seleccionar un modelo de la serie de modelos permitidos (o, en un bayesiano marco, la determinación de una distribución en el conjunto de modelos permitidos) que minimiza el criterio de costo. Hay numerosos algoritmos disponibles para la formación de los modelos de redes neuronales; la mayoría de ellos puede ser vista como una aplicación directa de la teoría de optimización y la estimación estadística. La mayoría de los algoritmos utilizados en las redes neuronales artificiales de formación emplean alguna forma de descenso de gradiente, utilizando propagación hacia atrás para calcular los gradientes reales. Esto se hace simplemente tomando la derivada de la función de coste con respecto a los parámetros de la red y a continuación, cambiando los parámetros en una dirección relacionada al gradiente. Los algoritmos de entrenamiento de propagación hacia atrás generalmente se clasifican en tres categorías (Wikipedia redes neuronales, 2020):

- 1.- Descenso del gradiente (con tasa variable de aprendizaje y momentum, retropropagación elástica (Rprop)).
- 2.- Cuasi-Newton (Broyden-Fletcher-Goldfarb-Shannon, método de la secante).
- 3.- Levenberg-Marquardt y Gradiente conjugado (actualización Fletcher-Reeves, actualización Polak-Ribiere, Powell-Beale reinicio, gradiente conjugado escalado). Otros métodos usados son: Métodos evolutivos, programación de la expresión génica, de recocido simulado, de esperanza-maximización, los métodos no paramétricos y la optimización por enjambre de partícula.

Los algoritmos dedicados al problema de la clasificación supervisada operan usualmente sobre la información suministrada por un conjunto de muestras, patrones, ejemplos o prototipos de entrenamiento que son asumidos como representantes de las clases, y los mismos poseen una etiqueta de clase correcta. A este conjunto de prototipos correctamente etiquetados se le llama conjunto de entrenamiento (TS, training set), y es el conocimiento empleado para la clasificación de nuevas muestras. Estos algoritmos tienen como objetivo determinar cuál es la clase, de las que ya se tiene conocimiento, a la que debe pertenecer una nueva muestra, teniendo en cuenta la información que se puede extraer del conjunto de entrenamiento. La clasificación se lleva a cabo de forma diferente según el método utilizado, sin embargo, todos parten de lo que es un mismo conjunto de datos, terminando en lo que es la predicción correspondiente al porcentaje de acierto. Algunos clasificadores utilizados que se encuentra en (Wikipedia redes neuronales, 2020) son:

*Bayesiano*: Expresa la probabilidad condicional de un evento aleatorio. Para la evaluación de esta regla se requiere un conocimiento a priori de la probabilidad y de la densidad de las clases.

*Kstar*: Este algoritmo determina cuáles son las instancias más parecidas, puede utilizar la entropía, o contenido de información de las instancias, como medida de distancia entre ellas.

*Multilayer Perceptron*: Los perceptrones multicapa son redes compuestas por multitud de unidades llamadas neuronas e interconectadas entre sí. Las neuronas no son más que elementos que proporcionan una salida en función de sus entradas, a las que se le aplican una función predeterminada para la obtención de dicha salida.

*REPTree*: Funcionamiento en dos fases (datos de aprendizaje y datos de poda). Primero se crea un conjunto de reglas que se sobreajusta a los datos usados para el aprendizaje, después se poda el conjunto de reglas usando ejemplares que no participaron en el aprendizaje.

La red neuronal artificial incluye los diversos enfoques y se ha utilizado en tareas de clasificación. Algunos investigadores utilizan el perceptrón de una sola capa, que comprende solo una entrada y una capa de salida. Las entradas se conectan directamente a la capa de salida. Es un tipo de red de alimentación directa más simple. El perceptrón multicapa contiene una capa de entrada y salida, pero una o más capas ocultas entre las capas de entrada y salida. El perceptrón multicapa es un método más sofisticado y ampliamente utilizado en tareas de clasificación. En los modelos de categorización de texto utilizados en redes de propagación hacia atrás y de propagación hacia atrás modificada, porque este modelo mejora la precisión del rendimiento y la reducción de la dimensionalidad. En el método híbrido combina la red de propagación de evolución de retroceso de la fase (LPEBP) y la descomposición del valor singular (SVD). La versión mejorada de la red neuronal de propagación hacia atrás tradicional (BPNN) es LPEBP y es mucho más rápida que BPNN. La descomposición del valor singular aumenta la alta reducción de dimensionalidad y rendimiento (Kaveri *et al.*, 2016).

Una de las tantas aplicaciones de las redes neuronales es la clasificación estadística de objetos o unidades experimentales. En donde se implementa un método no paramétrico de clasificar observaciones en uno de  $g$  grupos sobre la base de  $p$  variables cuantitativas observadas. Bajo el supuesto que las variables de estudio tienen un comportamiento normal, se puede construir una estimación no paramétrica de la función de densidad de cada grupo. La estimación es construida usando el método de Parzen donde se ponderan las observaciones de cada grupo de acuerdo a las distancias de las localizaciones específicas (Statgraphics, 2020).

### **Clasificador de redes neuronales de Statgraphics**

Implementa un método no paramétrico para clasificar las observaciones en uno de  $g$  grupos basados en  $p$  variables cuantitativas observadas. Construye una estimación no paramétrica de la función de densidad de cada grupo en uno deseado. Basado en observaciones vecinas de ese grupo. La estimación se construye utilizando una ventana de Parzen que pondera las observaciones de cada grupo de acuerdo con su distancia de la ubicación especificada. Las observaciones se asignan a grupos en función del producto de tres factores:

- 1.- La función de densidad estimada en la vecindad del punto.
- 2.- Las probabilidades previas de pertenencia a cada grupo.
- 3.- Los costos de clasificar erróneamente los casos que pertenecen a un grupo determinado.

La esfera de influencia de la función de ponderación Parzen puede ser especificada por el usuario u optimizada a través de jackknifing.

La red consta de cuatro capas:

1. Una capa de entrada con  $p$  neuronas, una para cada una de las variables de entrada.
2. Una capa de patrón con  $n$  neuronas, una para cada caso que se utilizará para entrenar la red.
3. Una capa de suma con  $g$  neuronas, una para cada clase de salida.
4. Una capa de salida, que también tiene una neurona binaria para cada clase de salida que se enciende o apaga, dependiendo de si se asigna o no un caso al grupo correspondiente.

Conceptualmente, la capa de entrada proporciona la información de las  $p$  variables predictoras alimentando sus valores (estandarizados restando la media y dividiendo por la desviación estándar) a la neurona en la capa patrón. La capa patrón pasa los valores a través de una función de activación, que utiliza los valores de entrada para estimar la función de densidad de probabilidad para cada grupo en una determinada localización. Las estimaciones de densidad se pasan luego a la capa de suma, que combina la información de los  $n$  casos de capacitación con probabilidades previas y costos de clasificación errónea para obtener una puntuación para cada grupo. Luego, las puntuaciones se utilizan para activar la neurona binaria en la salida correspondiente al grupo con la puntuación más alta y se apagan todas las demás neuronas de salida (Statgraphics, 2020).

## **Árboles de decisión**

Los árboles de decisión, son una clase de métodos de clasificación clásicos, se han aplicado en varios dominios, como el diagnóstico médico, la detección de intrusos y el procesamiento de señales. Los árboles de decisión también pueden denominarse clasificadores jerárquicos porque necesitan una discriminación multinivel para determinar a qué clase pertenece un patrón específico. Son flexibles para hacer frente a la clasificación de múltiples clases y binarios. En términos generales, según los diferentes medios de división de nodos, los árboles de decisión se pueden clasificar en árboles de decisión univariados, árboles de decisión multivariados y árboles de decisión omnivariados (Wang *et al.*, 2020).

### **Árboles de decisión univariados**

Se refieren a aquellos en los que solo un atributo único (también denominado característica o variable) participa en la división de nodos. Los árboles de decisión univariados más representativos utilizan la ganancia de información, el índice de Gini y la relación de ganancia como criterios de división (o digamos, criterios de selección de atributos) respectivamente, que son medidas heurísticas basadas en frecuencia. Se desarrolla una medida heurística basada en frecuencia y segmento para reemplazar las medidas heurísticas basadas solo en frecuencia para dividir los nodos del árbol de decisión. A pesar de la buena capacidad de interpretación, la división paralela al eje en los árboles de decisión univariados puede ser inapropiada cuando los conjuntos de datos tienen variables numéricamente correlacionadas, ya que los límites de las escaleras se producen en este caso donde un límite oblicuo podría tener mejores instancias separadas. Además, la selección de puntos de corte en estos árboles de decisión univariantes

implica una búsqueda codiciosa de los candidatos ordenados, lo que lleva mucho tiempo cuando todos los atributos son continuos (Wang *et al.*, 2020).

### **Árboles de decisión multivariados**

Son aquellos en los que múltiples atributos participan en la división de nodos. Estos atributos construyen constantemente una combinación lineal o no lineal que presenta un límite lineal u oblicuo o no lineal en cada nodo dividido en los árboles. Se emplea un algoritmo de adaptación iterativo. Combina la escalada determinista con procedimientos aleatorios para buscar una buena división. El árbol de decisión geométrica se propone para el aprendizaje al encontrar los dos hiperplanos agrupados y elegir una de sus bisectrices de ángulo como la regla de división. En lugar de la división binaria, la división multidireccional utiliza un algoritmo iterativo para ajustar los parámetros de las ramas para minimizar el número de clasificaciones erróneas, en lugar de una medida de impureza como entropía o Índice de Gini. Se han estudiado varios árboles de clasificación basados en análisis discriminantes. Algunos son multidireccionales, mientras que otros son binarios. Los árboles binarios son más populares que los de múltiples vías porque los árboles con un factor de ramificación bajo pueden ser interpretables y se adaptan mejor a la metodología subyacente de dividir. Los árboles de decisión multivariados no lineales son más susceptibles a los riesgos de sobreajuste debido al modelo de división de nodos altamente complejo, por lo tanto, menos utilizado que los lineales (Wang *et al.*, 2020).

## **Árboles de decisión omnivariados**

Son árboles de decisión en los que la división en cada nodo es univariante, multivariada lineal o multivariada no lineal. El árbol de decisión univariante se propone por primera vez en la división de nodos, se selecciona automáticamente entre univariante, lineal o no lineal, según algunas pruebas estadísticas. Posteriormente, se propone una nueva medida de clasificabilidad que captura las posibles fuentes de clasificación errónea para la selección del modelo en cada nodo dividido, formando finalmente los árboles de decisión omnivariados basados en la clasificabilidad (Wang *et al.*, 2020).

## **Árboles de decisión frugales y rápidos (ADFR)**

Permiten a las personas tomar decisiones rápidas y precisas basadas en información limitada sin necesidad de formación estadística o un dispositivo de cálculo. A pesar de su probada eficacia, los ADFR todavía no se utilizan tan a menudo como otros algoritmos de decisión, porque hay muchas herramientas en paquetes de software populares para crear modelos de regresión y árboles de decisión no frugal y porque se perciben como algoritmos de predicción obsoletos e inferiores (Phillips *et al.*, 2017b).

Los ADFR son algoritmos de aprendizaje supervisado que se utilizan para resolver tareas de clasificación. En una tarea de clasificación binaria, se busca predecir un valor de criterio binario para cada uno de un conjunto de casos individuales sobre la base de cada caso, también conocido como características predictoras (Phillips *et al.*, 2017b).

Los árboles rápidos y frugales se definen como árboles de decisión con exactamente dos ramas que se extienden en cada nodo, donde una o ambas

ramas es una salida. En otras palabras, en una respuesta o en el caso del nodo, ambas respuestas a cada pregunta planteada por un nodo desencadenan una decisión inmediata. Porque los (ADFR) tienen salida de rama en cada nodo, normalmente toman decisiones más rápido que los árboles de decisión estándar. Siendo más fácil de entender y usar (Phillips *et al.*, 2017b).

## **CAPITULO 1. ANÁLISIS IÓNICO DE SUELOS SALINOS**

### **1.1. RESUMEN**

La salinidad del lago de Texcoco se debe a que fue una cuenca endorreica, no tenía forma de lavar las sales de las desgastadas elevaciones montañosas formadas por roca ígnea y tobas volcánicas. Los suelos del ex lago de Texcoco presentan horizontes de carbonato de calcio que forman horizontes cálcicos y petrocalcicos. Las causas de salinización de los suelos agrícolas en estas parcelas son: filtración en la red de canales de tierra, manejo deficiente del riego, conservación deficiente de la red de drenaje, uso de aguas de baja calidad para riego y uso de fertilizantes. El objetivo de este trabajo es analizar y comparar la composición iónica y la relación de adsorción de sodio – porcentaje de sodio intercambiable explícita y ajustada de un terreno agrícola. Se hizo pasta y extracto de saturación, conductividad eléctrica, calcio, magnesio, sodio, potasio, carbonato, bicarbonato, cloruro y sulfato. Mapas de interpolaciones y curvas de nivel. El catión más dominante es el sodio. El predio es salino – sódico. Las imágenes interpoladas y las curvas de nivel dan una visión artificial de la relación de adsorción de sodio y el porcentaje de sodio intercambiable. En casi todo el predio existe riesgo de sodicidad. Se utilizaron los coeficientes de selectividad de 0.0118614 y 0.0168999.

Palabras clave: Calcio, catión, interpolación, iones, salinidad, sodicidad, sodio, suelo.

## 1.2. ABSTRACT

Lake Texcoco's salinity is because it was an endorheic basin. It had no way of washing the salts of the worn mountainous elevations formed by igneous rock and volcanic tuffs. The soils of the former lake of Texcoco have calcium carbonate horizons that form calcium and petrocalcic horizons. The causes of salinization of agricultural soils in these plots are: filtration in the land channels network, poor irrigation management, low conservation of the drainage network, low quality water for irrigation and use of fertilizers. This work aims to analyze and compare the ionic composition and sodium adsorption ratio - exchangeable sodium percent explicit and adjusted for agricultural land. Which was made paste and saturation extract, electrical conductivity, calcium, magnesium, sodium, potassium, carbonate, bicarbonate, chloride and sulfate. Interpolation maps and contour lines were made. The most dominant cation is sodium. The property is saline - sodium. Interpolated images and contours give an artificial vision sodium adsorption ratio and the percent of exchangeable sodium. In almost all the property there is a risk of sodicity. The selectivity coefficients of 0.0118614 and 0.0168999 were used.

Keywords: Calcium, cation, interpolation, ions, salinity, sodicity sodium, soil.

### 1.3. INTRODUCCIÓN

Este trabajo de investigación se refiere al tema de salinidad de suelos de un predio agrícola. Se pueden citar la definición de suelo como aquellas que considera al suelo como la continuación de espacio-tiempo que forma la parte superior de la corteza terrestre, con un espesor de pocos centímetros, donde se desarrollan las raíces de las plantas y en donde crecen los cultivos. Para analizar esta problemática es necesario mencionar sus causas. Una de ellas es la salinidad, la característica principal de los suelos salinos es la presencia elevada de concentraciones de sales solubles 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. La sodicidad, tiene que ver con un incremento del contenido de sales sódicas en los suelos, que provoca, entre otras cosas, la disminución del rendimiento de los cultivos e hidrólisis alcalina, de tipo carbonato y bicarbonato de sodio. Estos procesos en los suelos, se pueden determinar con base en su porcentaje de sodio intercambiable (PSI) y la relación de adsorción de sodio (RAS). Esta investigación se realizó con el interés de conocer las condiciones iónicas del terreno analizado, la alta salinidad de este predio es de interés para el estudio de la salinidad, la problemática principal para los cultivos es la pérdida en el rendimiento en una amplia variedad de cultivos alrededor del mundo. Este problema es más severo en las regiones semiáridas. La salinidad puede inhibir el crecimiento de la planta y reducir la productividad, principalmente por tres factores: el déficit hídrico, la toxicidad por iones y el desbalance nutricional. La primera parte del trabajo fue recolectar las muestras debidamente en el predio agrícola perteneciente al Colegio de Postgraduados en el municipio de Texcoco, que antiguamente era el lago de Texcoco. Enseguida se obtuvieron las coordenadas de precisión. Posteriormente las muestras se tamizaron y secaron en

invernadero. En la segunda parte de laboratorio se obtuvo el extracto de saturación para analizar las muestras, usando los métodos recomendados para salinidad y sodicidad de suelos del manual 60 (Richards, 1982). Con los datos obtenidos se calcularon las concentraciones de aniones y cationes, conductividad eléctrica, pH, RAS, PSI. Y con las coordenadas de alta precisión se realizó la interpolación (TIN) así como las curvas de nivel en un mapa, en el programa QGIS. Los objetivos generales son el análisis iónico de los suelos, la relación de adsorción de sodio, el porcentaje de sodio intercambiable, así como el mapeo de las curvas de nivel e interpolación. A partir de lo anterior se pretende conocer los niveles de salinidad y sodicidad de la parcela muestreada con el fin de hacer las recomendaciones y conclusiones pertinentes. Conociendo las concentraciones de los principales iones de la solución del suelo se pueden determinar los índices de salinidad de suelos, así como la elaboración de los mapas en donde se representan las curvas de nivel e interpolaciones, de esta manera se podrán conocer los niveles de salinidad y sodicidad de la zona muestreada y así emitir las recomendaciones correspondientes.

## 1.4. OBJETIVOS

### ***Objetivos generales***

Realizar el análisis iónico de salinidad del suelo a través de la determinación de laboratorio de los principales iones involucrados en el análisis de suelos ensalitrados.

### ***Objetivos particulares***

- Determinar el potencial de hidrógeno (pH) y conductividad eléctrica (CE) presentes en el suelo.
- Analizar la composición iónica de los siguientes iones del suelo de estudio: calcio ( $\text{Ca}^{2+}$ ), magnesio ( $\text{Mg}^{2+}$ ), sodio ( $\text{Na}^+$ ), potasio ( $\text{K}^+$ ), carbonato ( $\text{CO}_3^{2-}$ ), bicarbonato ( $\text{HCO}_3^-$ ), cloruro ( $\text{Cl}^-$ ), sulfato ( $\text{SO}_4^{2-}$ ).
- Determinar la Relación de Adsorción de Sodio (explícito y ajustado) y el Porcentaje de Sodio Intercambiable.
- Determinar las relaciones funcionales del terreno analizado.
- Elaborar las curvas de nivel e interpolación del mapa de salinidad del suelo y realizar los cálculos de cuartiles estadísticos y estadística descriptiva de los datos obtenidos.

## **1.5. HIPÓTESIS**

Conociendo las concentraciones de los principales iones de la solución del suelo se pueden determinar los índices de salinidad de suelos, así como la elaboración de los mapas de las curvas de nivel e interpolación, se podrán conocer los niveles de salinidad de la zona muestreada y así emitir las recomendaciones correspondientes.

## **1.6. MATERIALES Y MÉTODO**

Se obtuvieron 156 muestras de suelo de acuerdo a la NOM-021-RECNAT-2000. Es la norma oficial mexicana, que establece las especificaciones de fertilidad, salinidad, clasificación de suelos y muestreo. En cuadrículas de 15 x 15 metros. La superficie de estudio es de 4 Ha y es un terreno de uso agrícola, ubicado en las instalaciones del Colegio de Postgraduados, campus Montecillo, Texcoco. Coordenadas geográficas 19°27'52" N y 98°54'44" O y altitud de 2239 m. (el mapa se encuentra en la figura 12) Posteriormente se midió las coordenadas geográficas de alta precisión con el uso de la estación receptora GPS-GNSS. Marca Hi Target. La fecha de estudio fue en febrero del 2018.

Se utilizó el proceso analítico de laboratorio de (Clesceri *et al.*, 1998) y (Richards, 1982) para salinidad de suelos (pH, conductividad eléctrica, calcio, magnesio, sodio, potasio, carbonato, bicarbonato, cloruro y sulfato) se aprecia en el (cuadro 2).

Cuadro 7. Análisis físico químicos aplicados a las muestras de suelo.

<b>Método</b>	<b>Equipos y materiales</b>	<b>Referencia</b>
pH → Potenciométrico	Potenciómetro marca Beckman, modelo Hoffman.	Clesceri <i>et al.</i> , 1998. 4500-H+B.
CE → Conductimetría	Conductímetro. Marca Beckman.	Clesceri <i>et al.</i> , 1998. 25108.
Na <sup>+</sup> y K <sup>+</sup> → Flamometría	Flamómetro IL Autocal Flame Photometer 643	Clesceri <i>et al.</i> , 1998. 3500-Na <sup>+</sup> y K <sup>+</sup> . D
Ca <sup>+2</sup> y Mg <sup>+2</sup> → Volumetría	EDTA y Eriocromo Negro T como indicador, para Ca y Mg y Murexida para Ca.	Clesceri <i>et al.</i> , 1998. 3500 Ca <sup>2+</sup> , D
CO <sub>3</sub> <sup>2-</sup> → Volumetría	Ácido sulfúrico y Fenolftaleína como indicador.	Clesceri <i>et al.</i> , 1998. 2320 B.
HCO <sup>-</sup> → Volumetría	Ácido sulfúrico y Anaranjado de Metilo como indicador.	Clesceri <i>et al.</i> , 1998. 2320. B.
Cl <sup>-</sup> → Volumetría	Nitrato de Plata y Cromáto de Potasio al 5% como indicador.	Clesceri <i>et al.</i> , 1998. 4500-C-IB.
SO <sub>4</sub> <sup>-2</sup> → Turbidimetría	Espectrofotómetro modelo Perkin Elmer 35 a 420 nm.	Clesceri <i>et al.</i> , 1998. 4500-SO <sub>4</sub> <sup>2-</sup> - E

En la verificación de la exactitud de los datos obtenidos se utilizaron los procedimientos del balance anión-cación; conductividad eléctrica medida y la suma de cationes y aniones.

Se calculó la RAS y RAS ajustada, el PSI y el PSI ajustado. Con estos datos se elaboraron mapas de curvas de nivel e interpolación, utilizando el programa QGIS usando TIN (Red Irregular triangulada), con este método se

pueden crear superficies formadas por triángulos de puntos vecinos más cercanos (QGIS, 2019).

Cálculos de cuartiles estadísticos a los datos y estadística descriptiva a los datos de la composición iónica.

## 1.7. RESULTADOS Y DISCUSIÓN

Cuadro 8. Estadística descriptiva de los iones y variables de salinidad de suelos.

	CE	pH	Na <sup>+1</sup>	K <sup>+1</sup>	Ca <sup>+2</sup>	Mg <sup>+2</sup>	CO <sup>-3</sup>	HCO <sub>3</sub> <sup>-</sup>	Cl <sup>-</sup>	SO <sub>4</sub> <sup>-2</sup>	RAS aj	RAS	PSI aj	PSI
	dS/m		mEq L <sup>-1</sup>											
Media	65,47	8,20	49,03	9,76	6,28	9,76	0,59	6,88	18,19	53,75	40,42	20,00	35,51	21,42
Mediana	61,40	8,19	44,05	9,26	5,50	8,80	0,60	6,66	17,02	51,25	34,39	16,61	33,09	18,85
Moda	42,10	8,05	46,60	9,40	4,00	6,00	0,40	6,00	12,80	31,28	N/A	N/A	N/A	N/A
Desv. Est.	25,69	0,25	16,68	4,10	2,26	2,97	0,19	1,70	4,70	17,36	16,51	8,01	8,89	6,67
Varianza	659,83	0,06	278,31	16,78	5,12	8,81	0,04	2,87	22,12	301,39	272,58	64,19	79,04	44,53
Rango	107,90	1,21	64,63	17,29	8,35	9,80	0,70	8,04	15,22	70,20	62,86	31,77	32,40	24,99
Mínimo	28,00	7,58	27,87	3,01	3,65	6,00	0,30	3,14	12,58	30,67	20,55	11,36	22,51	13,41
Máximo	135,90	8,79	92,50	20,30	12,00	15,80	1,00	11,18	27,80	100,87	83,41	43,13	54,91	38,41

En el (cuadro 3) se observa la estadística descriptiva de los cationes en donde el Na<sup>+1</sup> es más predominante en el sitio con promedio 37.25 mEq, en aniones el SO<sub>4</sub><sup>-2</sup> es el más representativo, el promedio es 40.08 mEq. La secuencia de representación que se sigue de acuerdo a la (figura 3) es cationes Na<sup>+1</sup> > K<sup>+1</sup> > Mg<sup>+2</sup> > Ca<sup>+2</sup> y para aniones SO<sub>4</sub><sup>-2</sup> > Cl<sup>-</sup> > HCO<sub>3</sub><sup>-</sup> > CO<sub>3</sub><sup>-2</sup>.

Cuando el catión dominante es el sodio como en este caso, los coloides tendrán a absorber una proporción alta del mismo y dado que el efecto del sodio es el contrario al del calcio, habrá dispersión y no floculación. En este caso no se forman agregados y el suelo se mantiene disperso, siendo su permeabilidad baja y su aireación muy pobre (Navarro & Navarro, 2014). Eso explicaría la dispersión observada del suelo.

El anión sulfato es el más abundante en la zona de estudio, puede explicarse a su abundancia a procesos de intemperismo de minerales sulfatados con la subsecuente oxidación a sulfato y a la precipitación de yeso y anhidrita en evaporitas (Pacheco & Cabrera, 1996). Otro motivo racional es por los procesos de salinización provocados por actividades antropogénicas ya que este predio es agrícola y se riega constantemente con aguas de baja calidad agronómica.

El pH (8.20) y CE (65.47 dS/m) muestran valores estadísticos que reflejan las condiciones de suelos salinos-sódicos, y que es conocido del ex lago de Texcoco. En la (figura 4) se aprecia la clasificación en tres intervalos de CE, en donde el intervalo más frecuente es de 28 – 63.9 dS/m. En suelos sódicos el sodio y el pH elevado da lugar a la precipitación del calcio y magnesio como carbonatos y la pérdida de la estructura, sin embargo, el suelo salino sódico presenta altas cantidades de sales solubles en el suelo (CE mayor a 4 ds/m) pero el pH no sobrepasa el valor de 8.5 por lo tanto las partículas están floculadas, en algunas muestras si existen valores de pH mayores y menores de 8.5. No se recomienda el lavado de sales ya que el calcio podría ser removido y ser remplazado por el sodio dando características de suelo sódico (Coras *et al*; 2014). Por lo que el crecimiento de cultivos es limitado en este terreno. Algunos cultivos tolerantes a estas concentraciones de salinidad son la alfalfa, cebada, trigo y girasol (Aceves, 2011).

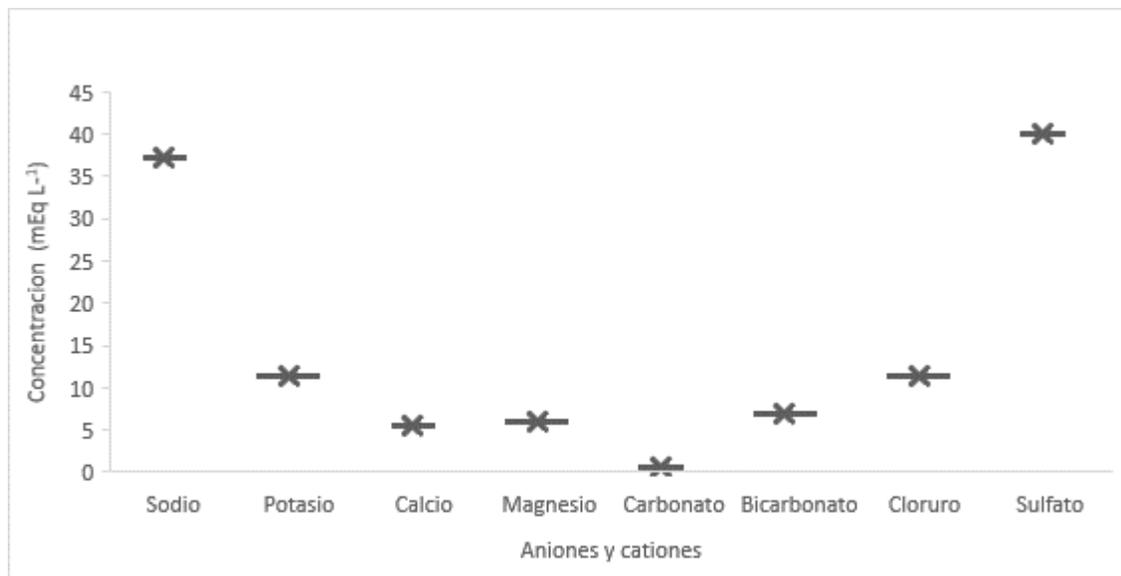


Figura 8. Distribución de medias de aniones y cationes en unidades mEq.

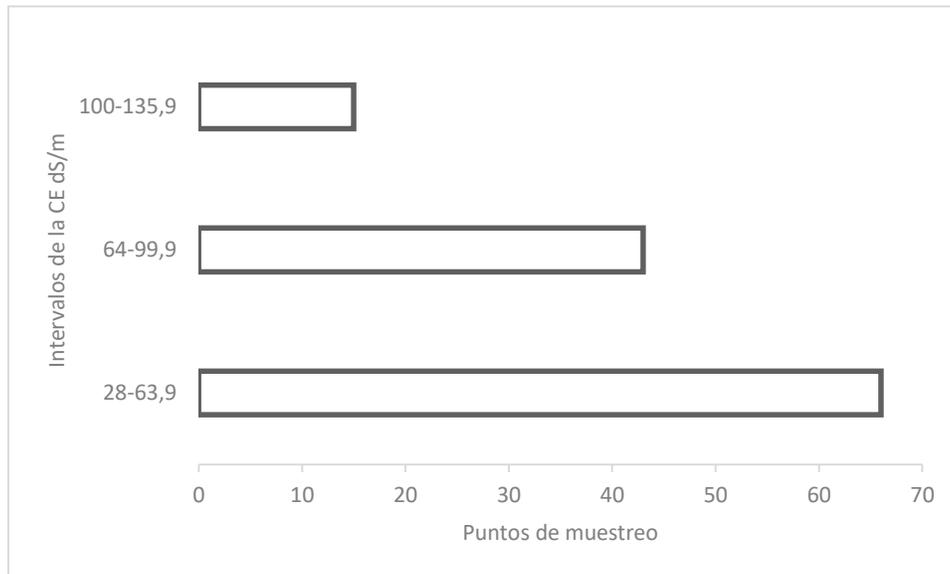


Figura 9. Distribución de la CE en tres intervalos de medición.

Los problemas salinos y sódicos no se limitan a zonas semiáridas o áridas, pueden también presentarse aún en regiones subhúmedas y húmedas en condiciones propicias (Gasca *et al.*, 1982), sino también en lagos secos de cuencas cerradas. Cuando el  $\text{Na}^{+1}$  es el catión dominante se produce la dispersión de las arcillas, lo que lleva a una destrucción de la estructura. Además de que la hidrólisis de las arcillas sódicas, conduce a la alcalinización del perfil, y estas provocan una intensa alteración mineral, reflejándose en un perfil bien diferenciado desde el punto de vista morfológico (IUSS, 2007). La RAS de una determinada agua de riego, puede ser usada como medida de peligro de sodicidad de esta agua, cuando se tuviesen condiciones ideales de equilibrio (Amrhein & Suarez, 1991).

Existe diferencia notable en este estudio entre la RAS y la RAS ajustada, el valor mínimo de la RAS es de 11 y de RAS ajustada es 21 y valores máximos de 43 y 83 respectivamente, en cuanto a los rangos de cada una se nota un aumento significativo en la RAS ajustada. Los mayores factores que afectan los valores de la RAS del suelo, es la pérdida o ganancia en contenidos de calcio y de magnesio debido a la precipitación o disolución de carbonatos

alcalino-térreos (Amrhein & Suarez, 1991). Mientras que la RAS ajustada, adecua la concentración de calcio en el agua, al valor de equilibrio esperado después del riego, e incluye, además, los efectos del bióxido de carbono, el bicarbonato y la salinidad sobre el calcio originalmente contenidos en el suelo (Bower *et al.*, 1968). Lo que se espera es un efecto protector de los minerales carbonatados sobre la estructura del suelo (Agrosal, 2019).

En el caso de PSI presenta valor mínimo de 13 y máximo de 38 mientras que el PSI ajustado es de 23 valor mínimo y máximo de 55, en este sentido la diferencia entre los rangos de valores es poco significativo. La concentración en  $\text{Na}^{+1}$  se puede medir bien en la disolución del suelo o bien en el complejo de cambio. En los suelos es muy importante determinar qué tipo de cationes predominan en el complejo adsorbente si es el  $\text{Ca}^{+2}$  o por el contrario el  $\text{Na}^{+1}$ . Se considera que un suelo puede empezar a sufrir problemas de sodificación y dispersión de la arcilla cuando el  $\text{PSI} > 15\%$ . (Edafología, 2019).

En la (figura 5) se analizan las interpolaciones y curvas de nivel en donde se ven reflejadas las distribuciones de PSI-RAS explícito con mayor intensidad en tres zonas blancas RAS 33-43 y PSI 30-38 y RAS ajustada 64-83 y PSI ajustada 46-55, en donde hay más concentración del ion sodio. Lo que denota el riesgo potencial de sodicidad de estos suelos. Mientras que las zonas oscurecidas muestran menor concentración de sales solubles. En los suelos sódicos, las partículas de arcilla tienden a separarse. Este proceso de disociación técnicamente se denomina dispersión. Las fuerzas que mantienen unidas a las partículas de arcilla se interrumpen por los iones de Sodio (Smart-fertilizer, 2019). Las imágenes dan una visión artificial de las concentraciones de RAS y PSI del predio.

En general el terreno analizado presenta valores elevados de RAS-PSI, debido a las condiciones del ex lago de Texcoco y también en menor medida por el agua de riego, por lo que pueden dejar de ser productivos y se

convierten en eriales cuyo abandono genera salinización, lo que conlleva un daño ambiental, económico y social (Sánchez *et al.*, 2012).

Los valores más bajos de sodio y de la RAS corresponden al rango de CE de 28 a 63.9 dS/m y los más elevados al rango de CE de 100 a 135.9. dS/m, caso similar al reportado por (Bosch *et al.*, 2012) que encontró al ion sodio y la RAS en los valores bajos, correspondientes al rango bajo de CE.

Analizando las medias de CE, PSI y pH, se puede definir el predio como salino sódico (CE dS/m > 4; PSI >15 y pH < 8.5) (Aceves, 2011).

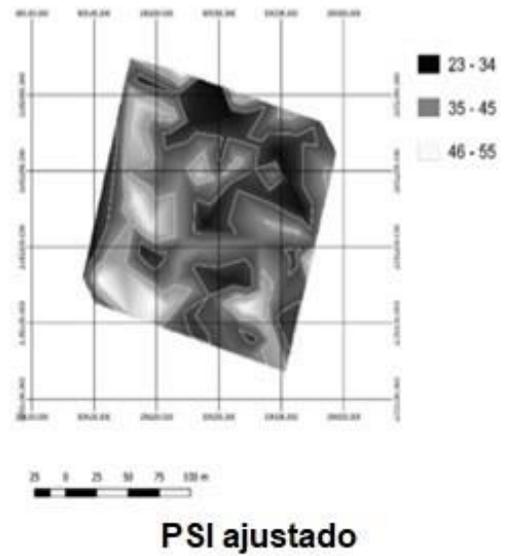
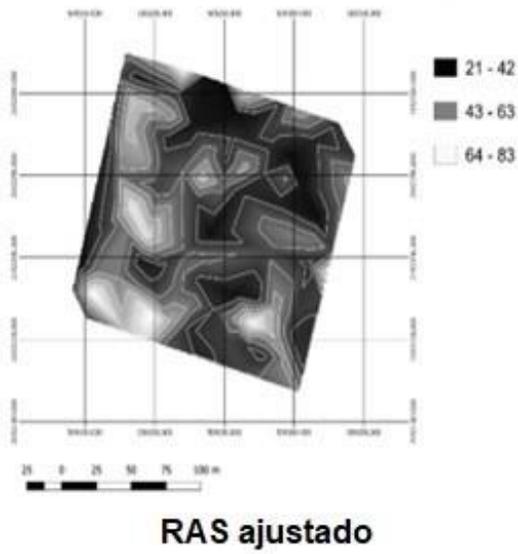
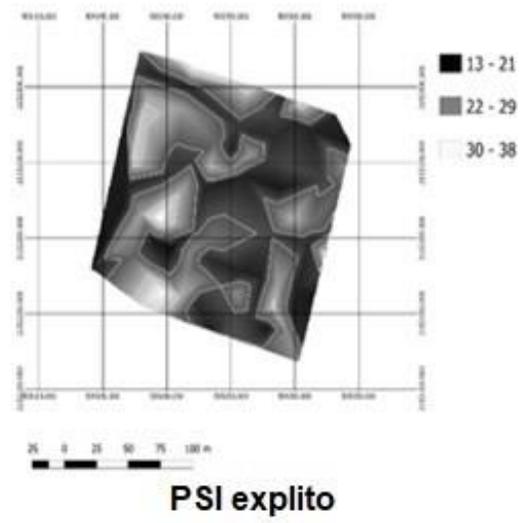
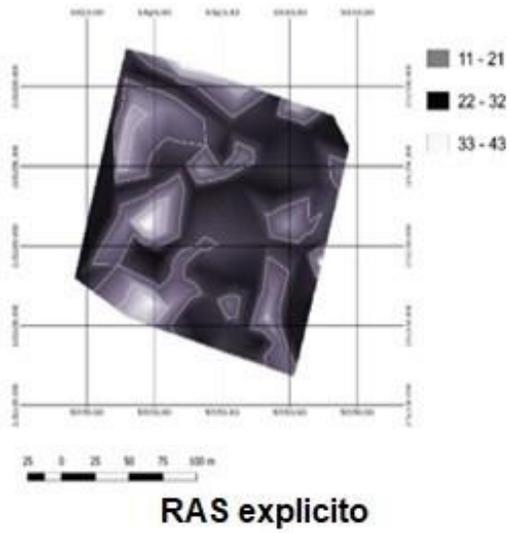


Figura 10. Interpolaciones y curvas nivel de las variables involucradas del terreno de estudio.

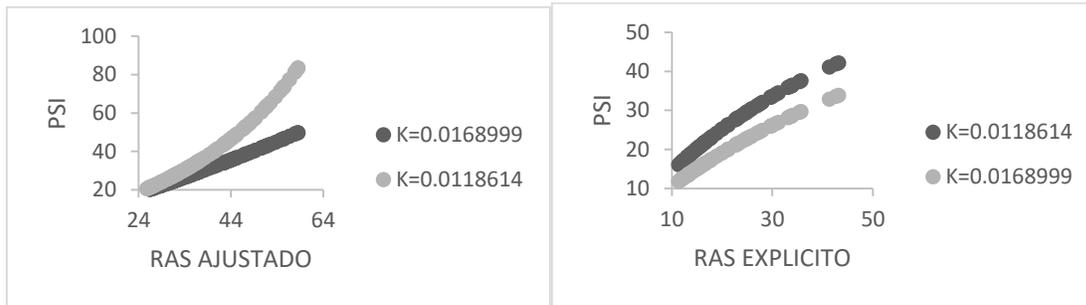


Figura 11. Relaciones funcionales de PSI-RAS explícito Y PSI-RAS ajustado.

En la (figura 6) se presentan las relaciones funcionales entre el porcentaje de sodio intercambiable y la relación de adsorción de sodio explícita y ajustada. Con valores de  $K=0.0118614$  y  $K=0.0168999$  que representan los coeficientes de selectividad de Gapon para textura de suelos arcillosos-limosos y arcillosos característicos de la zona de estudio. Se considera importante la relación y variación del PSI en los suelos agrícolas por ser regados con aguas de distintos valores de RAS (López *et al.*, 2016). Las variaciones en los coeficientes de selectividad bajo condiciones de equilibrio en el suelo, se explican por la no homogeneidad de carga, cambio en los coeficientes de actividad de los cationes con el incremento del grado de saturación y presencia de mezclas de distintos tipos de materiales intercambiadores de cationes en el suelo (Aceves, 2011).

## **1.8. CONCLUSIONES**

El catión más dominante es el sodio y el anión más dominante es el sulfato.

De acuerdo a los datos de composición iónica y a los cálculos realizados este predio es salino – sódico.

Existen diferencias significativas entre RAS y RAS ajustado, sin embargo, no existe diferencia de importancia entre el PSI y el PSI calculado con RAS ajustado.

Las imágenes interpoladas y las curvas de nivel dan una visión artificial del RAS, PSI, RAS ajustado y PSI calculado con RAS ajustado en el terreno.

En general el predio presenta valores elevados de RAS y PSI. Por lo que en casi todo el predio existe riesgo de sodicidad.

La zona de estudio del ex lago de Texcoco presenta suelos de textura arcillosos-limosos y arcillosos y sus coeficientes de selectividad de Gapon respectivos son  $K_G=0.0118614$  y  $K_G= 0.0168999$ .

## **1.9. RECOMENDACIONES**

Para evitar problemas de compactación o de adsorción de sodio en pequeñas cantidades, se requiere labranza profunda seguida de rastreo bianual.

Incorporación de yeso ( $\text{CaSO}_4$ )- $2\text{H}_2\text{O}$  en suelos sódicos degradados o en agua directamente.

Hacer estudios de calidad de agua, antes regar los cultivos agrícolas.

Realizar mapeos con otras plataformas de sistemas de información geográfica en 3D.

## 1.10. REFERENCIAS

Aceves N. E. 2011. El ensalitramiento de los suelos bajo riego. Biblioteca Básica de Agricultura. Cd de México.

Agrosal (La salinidad en la agricultura) Consultado el 17 de mayo 2019. <http://agrosal.ivia.es/>

Amrhein, C. & D. L. Suarez. 1991. Sodium-calcium exchange with anion exclusion and weathering corrections. *Soil Science Society of America Journal*. 55:698-706.

Basurto, S. M, Núñez, B. A., Pérez, L. R. y Hernández, R. A. 2008. Fisiología del estrés ambiental en plantas. *Aventuras de pensamiento*. Ed. Facultad de Ciencias Agrotecnológicas. Universidad Autónoma de Chihuahua, México. 45:1-5.

Bosch M. M., Costa J. L., Cabria N. F. & Aparicio V. C. 2012. Relación entre la variabilidad espacial de la conductividad eléctrica y el contenido de sodio del suelo. *Ciencia del suelo de Argentina*. 30 (2): 95-105.

Bower, C. A., Ogata, G., & Tucker, J. M. 1968. Sodium hazard of irrigation waters as influenced by leaching fraction and by precipitation or solution of calcium carbonate. *Soil Science*, 106(1), 29-34.

Can, C. A. 2011. Calidad de las aguas para riego en la cuenca del oriental y sierra norte, estados de Puebla, Tlaxcala y Veracruz. Tesis de doctorado. Colegio de Postgraduados, campus Montecillo.

Carranza E. A. 2018. Correlación litológica del subsuelo del lago de Texcoco. *Hidrobiológica* 28 (1): 93-101.

Cheeseman J. M. 2015. The evolution of halophytes, glycophytes and crops, and its implications for food security under saline condition. *New Phytologist*. 206:557-570.

Clesceri L. S., A. E. Greenberg & A. D. Eaton. 1998. Estandar methods for examination of water and wastewater. 20 ed. American Public Health Association (APHA), American Water Works Association. Water Pollution Control Federation. Washington, D. C. U.S.A. 1325 pag.

Coras M. P. M, Ontiveros C. R., Diakite D. L. 2014. Movimiento de agua freática y concentración de sales en suelos agrícolas. *Revista mexicana de ciencias agrícolas*. 5: 4. Pp.537-548.

Edafología. (Tema 12. Contaminación por sales solubles). Consultado 15 de mayo 2019. <http://www.edafologia.net/conta/tema12/medida.htm>

FAO 2020. Food and Agriculture Organization. Consultado el 10 de septiembre del 2020. <http://www.fao.org/soils-portal/soil-survey/propiedades-del-suelo/propiedades-fisicas/es/>

Fitzpatrick, E. A. 1987. Suelos su formación, clasificación y distribución. Compañía Editorial Continental, S. A. de C. V. México, D. F. México. pp. 229-345.

Fitzpatrick, E. A. 1996. Introducción a la ciencia de los suelos. Editoriales trillas. México, D. F. México. pp. 179-247.

Gallardo N. F. 2017. Breve historia de la desecación de los lagos del Valle de México: desde Tenochtitlan hasta el nuevo aeropuerto internacional. Revista Nexos. Consultado 1 de septiembre 2020. <https://labrujula.nexos.com.mx/?p=1363>

Gasca D.A. 1982. Génesis de los lagos cráter de la cuenca de Oriental. Colec. Cient. Inst. Nal. Antropol. Hist. 98 México. 45 pp.

Goykovic, C. V., Nina, A. P., & Calle, V. M. 2014. Efecto de la salinidad en la germinación y crecimiento vegetativo de plantas de tomate silvestres y cultivadas. Interciencia, 39(7), 511-517.

Gutiérrez C. M. C., Stoops G. y Ortiz S. C. 1998. Carbonato de calcio en los suelos del ex lago de Texcoco. Terra 16(1):11-19.

IUSS (International Union of Soil Sciences). 2007. Base referencial mundial del recurso suelo. Primera actualización. Grupo de trabajo WRB. Informes sobre recursos mundiales de suelos. No. 103. FAO, Roma. Italia. <http://www.fao.org/3/a0510s/a0510s00.pdf>

Lanz A. P. y González M. C. 2013. La salinidad como problema en la agricultura: la mejora vegetal una solución inmediata. Review Salinity as a problem in agriculture: Plant breeding an immediate solution. Cultivos Tropicales. 34: 4. pp. 31-42.

Langelier, W. F. 1936. The analytical control of anti-corrosion water treatment. Journal of the American Water Works Association, 28(10), 1500-1521.

López G. A. D., Ortega E. H. M., Ramírez A. C., Sánchez B. E. I., Can C. A., Gómez M. D. J., Vázquez A. R. E. 2016. Caracterización fisicoquímica del agua residual urbano-industrial y su importancia en la agricultura. Tecnología y Ciencias del Agua. 7(6): 139-157.

López G. A., Gutiérrez C. M. C., Ortiz S. C. A., Flores R. D., Segura C. M. A. 2004. Sedimentos del ex lago de Texcoco y su comportamiento con la aplicación de materiales calcáreos y compactación. Terra 22:1-10.

Marín P. M., Romero A. D., Sánchez A. S. 2013. Influencia del porcentaje de sodio intercambiable en los procesos de erosión subsuperficiales. 2: 17.13. Revista de la sociedad española de mineralogía.

Martínez R. B., Nebot E., Moral, A., Porres, J., Talbi, C., López J. M. 2011. Posible aplicación de halomonas mauro S30 como bioinoculante agrícola de la legumbre *Medicago sativa* L. XXIII Congreso Nacional de Microbiología. SEM - Salamanca.

Mooser, F. 1961. Informe sobre la geología de la Cuenca del Valle de México. Secretaría de Recursos Hidráulicos. Comisión Hidrológica de la cuenca del Valle de México. México D.F.

Munns R. M. and Gilliam T. 2015. Salinity tolerance of crops – what is the cost? New Phytologist 208: 3. P.p 668-673.

Navarro G. G., Navarro G. S. 2014. Fertilizantes: química y acción. Ediciones Paraninfo, S.A. 241 p.

Orrego F. F. M., Gómez M. y Ginocchio R. 2018. Diversidad de halófitas chilenas: distribución, origen y hábito. Gayana Bot. 75:2. pp.555-567.

Otero L., Alden F., Gálvez V., Morales R., Sánchez I., Labaut M., Vento M., Cintra M. y Rivero L. 2007. Caracterización y evaluación de la salinidad. Cenda, Cuba. 1689-2007. Ministerio de la agricultura.

Pacheco J. & Cabrera A. 1996. Efecto del uso de fertilizantes en la calidad del agua subterránea en el estado de Yucatán. Universidad Autónoma de Yucatán. Ingeniería hidráulica en México, 10 (1).

Pérez D., J. P., Ortega E. H. M., Ramírez A. C., Flores M. H., Sánchez B. E. I., Can C. A., & Mancilla V. O. R. 2019. Evaluación de la calidad del agua residual para el riego agrícola en Valle del Mezquital, Hidalgo. Acta Universitaria. 29, E2117.

QGIS. Complementos de interpolación. Consultado el 4 de septiembre de 2019.

[https://docs.qgis.org/2.18/es/docs/user\\_manual/plugins/plugins\\_interpolation.html](https://docs.qgis.org/2.18/es/docs/user_manual/plugins/plugins_interpolation.html)

Richards, L. A. 1982. Suelos Salinos y Sódicos. Personal del Laboratorio de Salinidad de los Estados Unidos de América. Manual de Agricultura No. 60. p. 172.

Sánchez B. E. I., Ortega E. H. M., Sandoval O. G. T., Hernández V. R. A. & Estrada V. C. 2012. Lavado de sales en suelos aluviales costeros de Oaxaca, México, con aguas residuales municipales tratadas. Revista Internacional de Contaminación Ambiental. 28 (4).

SEMARNAT. 2009. Secretaria de Medio Ambiente y Recursos Naturales. El medio ambiente en México: En resumen. México. Gobierno Federal. pp. 20-23. [www.semarnat.gob.mx](http://www.semarnat.gob.mx).

Smart-fertilizer. Suelos Sódicos y Su Manejo. Consultado 15 de mayo 2019. <https://www.smart-fertilizer.com/es/articles/sodic-soils>

Smith T.M y Smith, R. L. 2007. Ecología. Ed. Pearson Addison. Wesley. Madrid. España. 776 p.

Soil Survey Staff. 1992. Keys to soil taxonomy. Technical Monograph No. 19, 5th ed. Pocahontas Press, Inc. Blacksburg, VI. USA. 541 p.

Soil Survey Staff. 1994. Keys to soil taxonomy. 6th ed. USDA-SCS. U. S. Government Printing Office. Washington, DC. USA. 306 p.

Sotelo R., Domingo E. 2011. Los suelos del estado de México y su actualización a la base referencial mundial del recurso suelo. Rev. mex. de cienc. Forestales. 2: 8, pp.71-84.

## **CAPÍTULO 2. MODELOS DE CLASIFICACIÓN DE SALINIDAD DEL SUELO, UTILIZANDO BANDAS MULTIESPECTRALES, ÁRBOLES DE DECISIÓN Y REDES NEURONALES**

### **2.1. RESUMEN**

Los Vehículos aéreos no tripulados (VANT) son aviones propulsados operados de forma remota. Los datos de teledetección tienen la capacidad de capturar información en suelos afectados por la sal. Varios algoritmos y modelos han sido desarrollado para procesar datos de teledetección de salinidad. Una gama de índices se ha desarrollado para detectar y mapear la salinidad del suelo con el uso sensores remotos. Las mediciones de imágenes de drones combinadas con datos terrestres, han mostrado potencial para el mapeo de salinidad. Una manera para clasificar y detectar salinidad en el suelo son las redes neuronales que están formadas por neuronas conectadas entre sí. Los árboles de decisión son clasificadores jerárquicos porque necesitan una discriminación multinivel para determinar a qué clase pertenece un patrón específico. En este apartado se trabajó con los datos de las variables de salinidad obtenidos del laboratorio del primer capítulo, las reflectancias de las imágenes multiespectrales y con los índices de salinidad, para estimar variables de salinidad utilizando redes neuronales y arboles de decisión. El objetivo principal es la detección y clasificación de la salinidad del suelo. La red neuronal presento una precisión de 69.56% en RAS, 76.12% PSI y 71.88% en sodio, mientras que el árbol de decisión 67% RAS, 61% PSI y 56% en sodio. La simplicidad de los modelos y el grado de precisión los convierten en una herramienta prometedora.

Palabras clave: Árboles de decisión, Índices de salinidad, Porcentaje de Sodio Intercambiable, red neuronal, reflectancias, Relación de Adsorción de Sodio, sodio.

## 2.2. ABSTRACT

Unmanned Aerial Vehicles (UAVs) are remotely operated propelled aircraft. Remote sensing data has the ability to capture information on salt-affected soils. Various algorithms and models have been developed to process salinity remote sensing data. A range of indices have been developed to detect and map soil salinity with the use of remote sensing. Drone image measurements combined with ground data have shown potential for salinity mapping. One way to classify and detect salinity in soil is through neural networks that are made up of neurons connected to each other. Decision trees are hierarchical classifiers because they require multilevel discrimination to determine which class a specific pattern belongs to. In this section we worked with the data of the salinity variables obtained from the laboratory of the first chapter, the reflectances of the multispectral images and with the salinity indices, to estimate salinity variables using neural networks and decision trees. The main objective is the detection and classification of soil salinity. The neural network presented a precision of 69.56% in SAR, 76.12% ESP and 71.88%, while the decision tree 67% SAR, 61% ESP and 56%. The simplicity of the models and the degree of precision make them a promising tool.

Keywords: Decision trees, Salinity indices, Exchangeable sodium percentage, neural network, reflectances, Sodium Adsorption Ratio, sodium.

## 2.3. INTRODUCCIÓN

En esta sección de la tesis se analiza la detección y clasificación de la salinidad del suelo utilizando imágenes de drones, redes neuronales y árboles de decisión. Como parte de estas tecnologías la agricultura de precisión tiene como objetivo adaptar el manejo de una manera coherente y holística, especialmente explotando la alta variabilidad espacial y temporal de los rasgos del cultivo y ambientales. Las herramientas de diagnóstico recopilan información utilizando técnicas de detección o muestreo a lo largo de varias escalas. Los Vehículos aéreos no tripulados (VANT) son aviones propulsados operados de forma remota o autónoma con planificación de vuelo preprogramada. Los dos tipos principales de configuraciones de VANT son ala fija (avión) y ala giratoria (helicóptero). Los VANT o drones ofrecen una alternativa viable a las plataformas convencionales para adquirir datos de teledetección de alta resolución a menor costo, mayor flexibilidad operativa y mayor versatilidad. La capacidad de los VANT para capturar imágenes concurrentes con observaciones de campo resuelve un problema común de teledetección. La Teledetección de recursos naturales se basa en un sistema de adquisición de datos a distancia sobre la biosfera, que está basado en las propiedades de la radiación electromagnética y en su interacción con los materiales de la superficie terrestre. Los datos de teledetección tienen la capacidad de capturar información en suelos afectados por la sal tanto en extensión espacial como temporal. El desarrollo de métodos para mapear la salinidad utilizando datos de detección remota en combinación con datos de campo han sido el objetivo de varios estudios durante las últimas dos décadas. Varios algoritmos y modelos han sido desarrollado para procesar datos de teledetección satelital. Investigaciones pasadas muestran el mapeo y la evaluación de la salinidad del suelo usando fotografía aérea, videografía, termometría infrarroja y otros. Aprovechando estas propiedades, una gama de índices se han desarrollado para detectar y

mapear la salinidad del suelo con el uso sensores remotos multiespectrales e hiperespectrales. Las mediciones de imágenes de drones combinadas con datos terrestres, han mostrado potencial para el mapeo de salinidad. Una manera para clasificar y detectar salinidad en el suelo son las redes neuronales que están formadas por neuronas conectadas entre sí; a su vez, cada conexión de una red neuronal es asociada con un peso que dicta la importancia de esta relación en la neurona cuando se multiplica por el valor de entrada. Cada neurona tiene una función de activación que define la salida de la neurona. Otro método de clasificación son los árboles de decisión, son una clase de métodos de clasificación clásicos, se han aplicado en varios dominios, como el diagnóstico médico, la detección de intrusos y el procesamiento de señales. Los árboles de decisión también pueden denominarse clasificadores jerárquicos porque necesitan una discriminación multinivel para determinar a qué clase pertenece un patrón específico. Son flexibles para hacer frente a la clasificación de múltiples clases y binarios. En términos generales, según los diferentes medios de división de nodos, los árboles de decisión se pueden clasificar en árboles de decisión univariados, árboles de decisión multivariados y árboles de decisión omnivariados. En este apartado se trabajó con los datos de las variables de salinidad obtenidos del laboratorio del primer capítulo, las reflectancias de las imágenes multiespectrales y con los índices de salinidad, para estimar variables de salinidad utilizando redes neuronales y árboles de decisión. El objetivo principal es la detección y clasificación de la salinidad del suelo mediante el uso de imágenes multiespectrales capturadas mediante un VANT y utilizando árboles de decisión y redes neuronales. El uso de reflectancias obtenidas a partir de imágenes multiespectrales obtenidas con un VANT permite estimar la salinidad del suelo utilizando los métodos de clasificación de árboles de decisión y redes neuronales.

## **2.4. OBJETIVOS**

### ***Objetivo general***

Detectar y clasificar de la salinidad del suelo mediante el uso de imágenes multiespectrales capturadas mediante un VANT y utilizando árboles de decisión y redes neuronales.

### ***Objetivos particulares***

Obtener las reflectancias de imágenes multiespectrales obtenidas utilizando un VANT.

Estimar la salinidad de muestras de suelo a través de análisis de laboratorio

Estimar la salinidad del suelo a partir de las reflectancias de imágenes multiespectrales.

Evaluar la precisión en la determinación de la salinidad del suelo utilizando los métodos de las redes neuronales y los árboles de decisión.

## **2.5. HIPÓTESIS**

El uso de reflectancias obtenidas a partir de imágenes multiespectrales obtenidas con un VANT permite estimar la salinidad del suelo utilizando los métodos de clasificación de árboles de decisión y redes neuronales.

## 2.6. MATERIALES Y MÉTODOS

Se seleccionó el área A3 del Colegio de Postgraduados campus montecillo, coordenadas geográficas 19°27'52" N y 98°54'44" O y altitud de 2239 m, el mapa del área de estudio se observa en la (figura 12). El terreno tiene área de 4 Ha. Se realizó el sobrevuelo con el dron marca SenseFly eBee plus (figura 13), cubre hasta 12 km<sup>2</sup>. Adquiere imágenes de hasta 1.5 cm de distancia por píxel. Pesa 700 g y es muy eficiente.

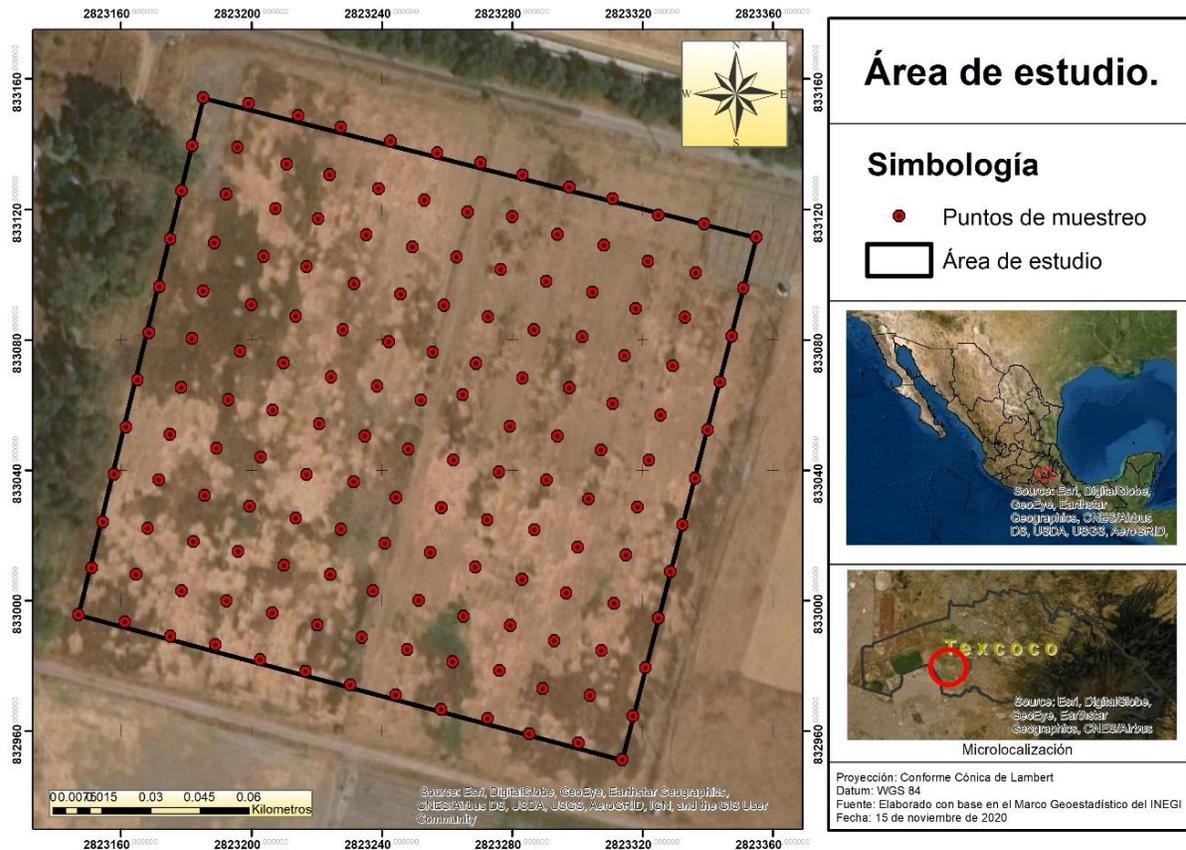


Figura 12. Mapa de la zona de estudio.



Figura 13. VANT SenseFly eBee plus.

Este dron trae desmontable la cámara Parrot Sequoia la cual tiene un sensor que detecta la cantidad de luz que absorbe y refleja el suelo gracias a sus dos sensores, multiespectral y de luz solar. Esta cámara multiespectral consta de cuatro sensores monocromáticos sincronizados de banda estrecha de 1,2 millones de píxeles (cuadro 9) además de una cámara RGB, se muestra en la (figura 14).

Cuadro 9. Longitudes de las regiones de las bandas multispectrales de la cámara Parrot sequoia.

	Longitud de onda en nm	Ancho de banda en nm	Definición en MP
Green	550	40	1.2
Red	660	40	1.2
Red-edge	735	10	1.2
Near infrared	790	40	1.2



Figura 14. Cámara multispectral Parrot Sequoia (Pix4D, Lausanne, Suiza).

Se diseñó una cuadrícula de 15 metros por 15 metros, colocando estacas para su identificación. En estos puntos se registraron las coordenadas geográficas de alta precisión usando la estación receptora GPS-GNSS marca Hi Target la cual se muestra en la (figura 15).



Figura 15. GPS-GNSS marca Hi Target.

Posteriormente las imágenes y la creación de ortomosaico se generaron con el software Pix4Dmapper (Pix4D SA, Lausanne, Suiza). Primeramente, se hace una calibración geométrica de la cámara, enseguida se hace la extracción de puntos comunes entre imágenes, geolocalización y generación de informe de calidad. En el segundo paso se procesa la nube de puntos y malla para la creación del ortomosaico y modelo digital de superficie (MDS), se emplean los puntos extraídos para cada imagen y se trasponen con los puntos en común de las imágenes de mayor precisión. En el tercer paso se genera el MDS, ortomosaicos e índices con cada una de las imágenes calibradas y proyectadas en puntos en común en las imágenes en los pasos anteriores. El resultado de estos tres pasos es un MDS y ortomosaico que se guarda en formato \*.tiff para su empleo en el análisis de este estudio. Las resoluciones obtenidas se encuentran en el rango de 0.75 – 0.80 cm por

pixel en los ortomosaicos. Después se extraen los valores de reflectancia con el uso del programa de sistemas de información geográfica QGIS.

Con los valores de las reflectancias se desarrollaron varios índices espectrales de salinidad del suelo para detectar y mapear depósitos de sales. Se destacan varias combinaciones espectrales en el mapeo de regiones con problemas de salinidad (Bouaziz, 2011). El (cuadro 10) contiene algunos de los índices espectrales más utilizados que fueron encontrados en la literatura y que se usaron en este trabajo.

Cuadro 10. Índices de salinidad y vegetación propuestos y utilizados para la detección de salinidad.

	<b>Índices</b>	<b>Ecuación</b>	<b>Referencia</b>
1	Normalized Differential Salinity Index	$NDSI = \frac{(R-NIR)}{(R+NIR)}$	Allbed & Kumar, 2013
2	Salinity Index 2	$SI2 = \sqrt{G * R}$	Allbed & Kumar, 2013
3	Salinity Index 4	$SI4 = \sqrt{G^2 + R^2}$	Allbed & Kumar, 2013
4	Salinity Index 14	$SI14 = \frac{R * NIR}{G}$	Allbed & Kumar, 2013
5	Normalized Differential Vegetation Index	$NDVI = \frac{(NIR-R)}{(NIR+R)}$	Allbed & Kumar, 2013
6	Soil Adjusted Vegetation Index	$SAVI = \frac{(NIR-R)}{(NIR+R+L*(1+L))}$	Allbed & Kumar, 2013
7	Red-Near infrared (NIR)	$RNIR = \frac{R}{NIR}$	Propuesto por el autor de este trabajo.

Se realizaron cuartiles estadísticos a las reflectancias y las variables de laboratorio para evitar datos atípicos siendo  $n$  el número total de valores, usando las siguientes formulas (Ayala, 2020):

$$Q1 = \frac{n + 1}{4} = 0.25 (n + 1)$$

$$Q2 = \frac{2(n + 1)}{4} = 0.50 (n + 1)$$

$$Q3 = \frac{3(n + 1)}{4} = 0.75 (n + 1)$$

A partir de las reflectancias obtenidas con las bandas red, near infrared, red edge, green se calcularon los índices descritos en el (cuadro 9). Se entrenaron y validaron modelos de árboles de decisión y redes neuronales para clasificar la RAS (Relación de Adsorción de Sodio); PSI (Porciento de Sodio Intercambiable) y  $\text{Na}^+$  (Sodio). Se probaron numerosos modelos con los índices y las cuatro bandas mencionadas, el propósito fue encontrar los mejores porcentajes de clasificación.

Todas las variables (RAS, PSI y sodio) pertenecen a la categoría de elevada salinidad de acuerdo a (Richards; 1982) por lo que dentro de esta categoría se decidió utilizar un rango que divide en dos partes iguales el conjunto de datos de cada variable (del medio rango al valor mínimo es clasificación media y del medio rango al dato máximo es clasificación elevada).

## ***Funcionamiento de la red neuronal***

Se utilizaron las redes neuronales en el programa (Statgraphics centurión 19, Statgraphics Technologies, Inc ©. The Plains, Virginia, EUA) en la (figura 16) se aprecia la secuencia de pasos a seguir del modelo de la red neuronal, las cuales trabajan de la siguiente manera:

El único parámetro en la formulación de la red que se puede variar es el parámetro de escala  $\sigma$ , que afecta la rapidez con la que la influencia de una observación sobre la densidad en el punto X decae a medida que la distancia desde X aumenta. El procedimiento proporciona 3 opciones para determinar  $\sigma$ :

1.  $\sigma$  puede ser especificado por el usuario. El valor predeterminado es  $\sigma = 1$ , lo cual no es irrazonable ya que las variables de entrada se han estandarizado.
2.  $\sigma$  puede ignorarse y una observación en el punto X siempre se corresponde con el grupo correspondiente a su vecino más cercano.
3. Se pueden probar diferentes valores de  $\sigma$  y elegir el valor que maximice el porcentaje de las  $n$  observaciones en el conjunto de entrenamiento que están correctamente clasificadas.

Cuando se selecciona el tercer caso, la red se entrena mediante un procedimiento llamado Jackknifing que elimina un punto a la vez del conjunto de entrenamiento y determina la frecuencia clasificada correctamente cuando no se utiliza para estimar las puntuaciones del grupo. El valor de  $\sigma$  correctamente clasifica el porcentaje más alto de los puntos eliminados y se convierte en el valor seleccionado.

En la clasificación de salida se usó (medio y elevado) según la variable. Ya que el terreno agrícola presenta salinidad. Los resultados mostrados son los mejores modelos encontrados.

Incluidos en la tabla están:

- Variables de entrada: identificación de las variables de entrada.
- Número de casos en el conjunto de entrenamiento: el número de observaciones  $n$  en el conjunto de entrenamiento.
- Número de casos en el conjunto de validación: el número de casos retenidos del conjunto de formación. Los casos se pueden retener usando el campo *Seleccionar* en el cuadro de diálogo de entrada de datos.
- Parámetro de espaciado utilizado: método para determinar la función de densidad de probabilidad. Si  $\sigma$  es especificado por el usuario o estimado por jackknifing, se mostrará su valor. Si cada punto coincide con su vecino más cercano, que se indicará.
- Conjunto de entrenamiento: el número y porcentaje de observaciones en el conjunto de entrenamiento que fueron correctamente clasificado.
- Conjunto de clasificación: el número y porcentaje de observaciones retenidas del entrenamiento que fueron clasificados correctamente.



Figura 16. Diagrama de flujo de los pasos a seguir de la red neuronal Statgraphics.

## Funcionamiento del árbol de clasificación

En la (figura 17) se presenta una curva de característica operativa del receptor (ROC) ilustrando la compensación entre sensibilidad (sens) y especificidad (spec) en algoritmos de clasificación. A medida que aumenta la sensibilidad, la especificidad disminuye. Equilibrado la exactitud (bacc) es el promedio de sensibilidad y especificidad. El rendimiento ideal (bacc = 1.0), está representado por la cruz en la esquina superior izquierda. El círculo numerado en la gráfica representa la precisión de 7 algoritmos diferentes con diferentes compensaciones entre sensibilidad y especificidad. Los números representan el orden de clasificación del rendimiento del algoritmo en términos de sus valores de bacc (Phillips *et al.*, 2017b).

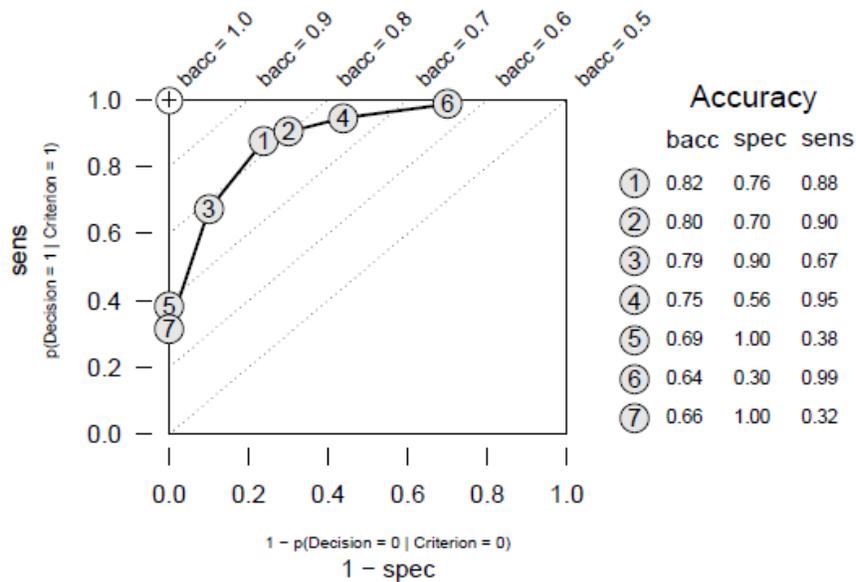


Figura 17. Curva ROC.

La velocidad y la frugalidad se miden con dos medidas distintas: la rapidez en que un algoritmo llega a una conclusión (su velocidad) y cuánta información ignora (su frugalidad).

Un algoritmo ADFR debe resolver cuatro tareas (pero no necesariamente en este orden):

1. Seleccionar señales.
2. Determinar un umbral de decisión para cada señal.
3. Determinar el orden de las señales.
4. Determinar la salida (positiva o negativo) para cada señal.

Los algoritmos que incorporan de forma rutinaria las interacciones de señales pueden cometer falsas alarmas en la detección y son poco confiables. Por esta razón, los ADFR ignoran explícitamente las interacciones de señales para reducir tanto el tiempo de procesamiento como el riesgo de sobreajuste (Phillips *et al.*, 2017b).

Los árboles de clasificación binaria se organizan como una combinación de casos (variables de salinidad) y los valores de cada caso en varias señales (índices de salinidad y las cuatro bandas espectrales). La precisión de la clasificación se evalúa comparando las decisiones del algoritmo con los valores de criterio. El objetivo del algoritmo es maximizar las decisiones correctas (aciertos y rechazos correctos), mientras minimiza errores (fallos y falsas alarmas). En este método de ADFR se utilizó el software FFTrees versión 1. 3. 2. disponible en versiones 2.1.0 de R o mayor (Phillips *et al.*, 2017a). El mejor modelo de clasificación es el que presenta los valores más elevados de equilibrio de exactitud *bacc*, *sens* y *spec*. El objetivo del algoritmo es maximizar las decisiones correctas (aciertos y rechazos correctos), mientras minimiza errores (fallos y falsas alarmas). En la (figura 18) se prestan los pasos a seguir del modelo de FFTrees.

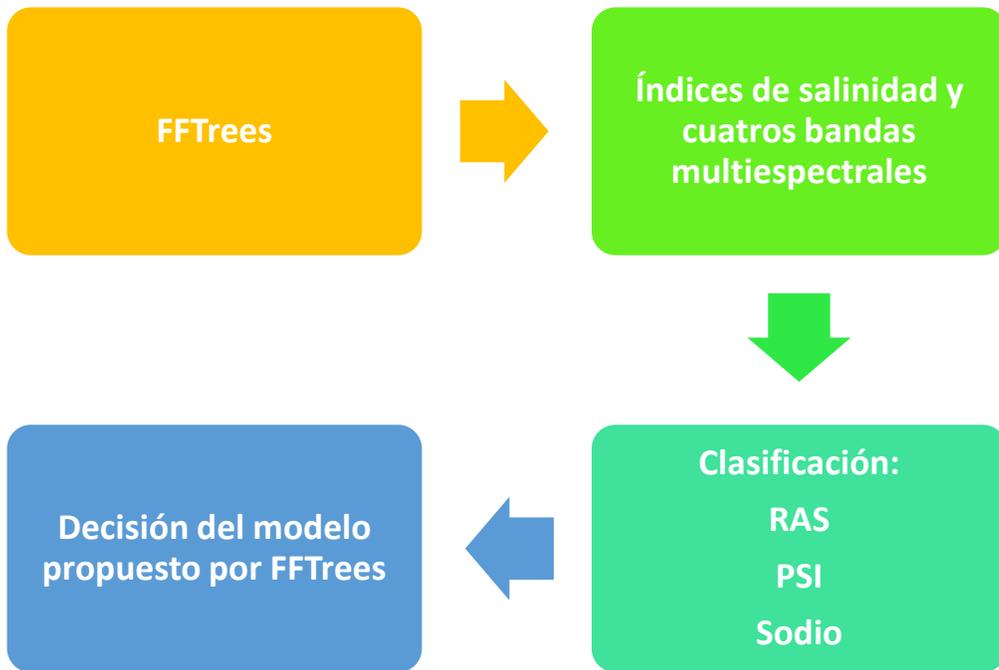


Figura 18. Diagrama de flujo del proceso de decisión de FFtrees.

## 2.7. RESULTADOS Y DISCUSIÓN

En la (figura 19) se aprecian los mapas de reflectancia de cada canal del sensor multiespectral, adquiridas de la cámara Parrot Sequoia de la zona de estudio, con los puntos de análisis. Las cuatro imágenes corresponden a un solo vuelo del VANT.

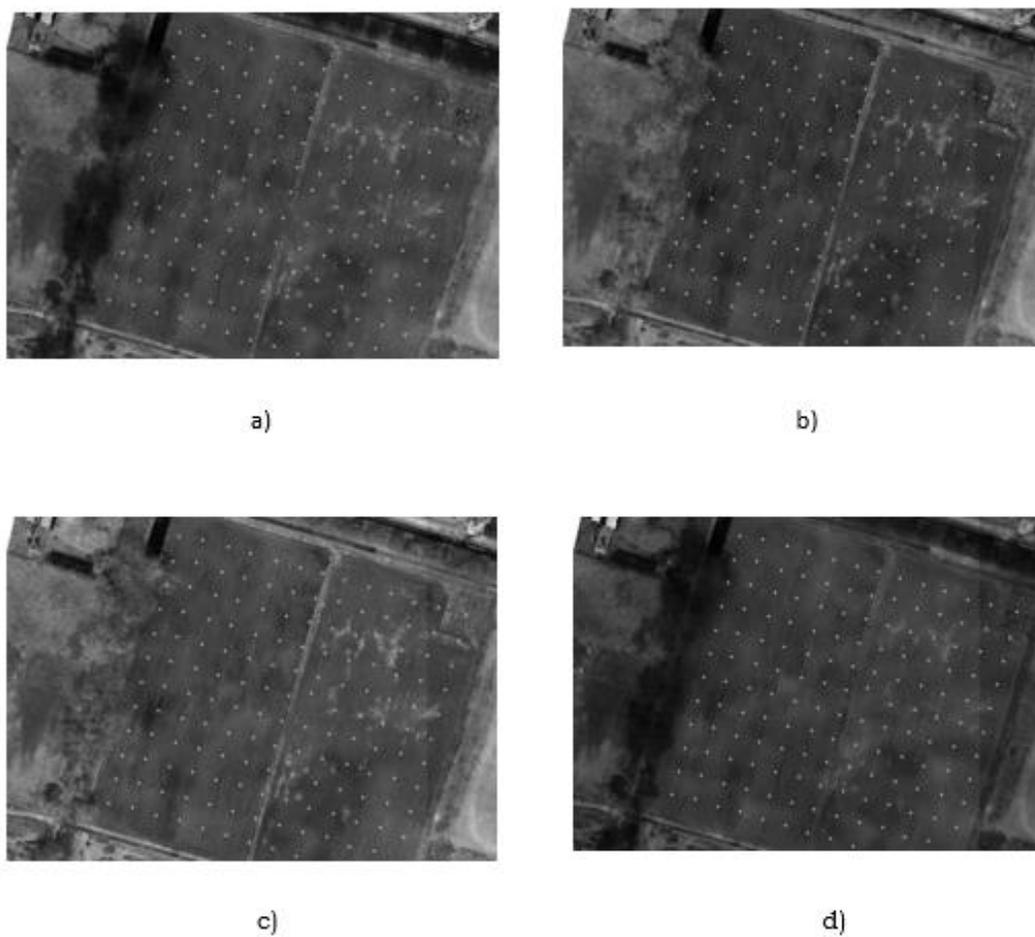


Figura 19. Mapa de reflectancias: a) Green, b) Near infrared, c) Red y d) Red edge.

En la presente sección se describen los mejores modelos de árboles de decisión y de redes neuronales que permiten estimar el nivel de salinidad, de acuerdo a la RAS, al PSI y al Sodio. Se analizaron todas las posibles variables que permitieron estimar el nivel de salinidad a partir de los índices de salinidad estimados y las cuatro bandas de reflectancia obtenidas, estas variables son descritas con mayor detalle en los siguientes apartados.

### ***FFTrees de cuatro bandas espectrales y varios índices de salinidad para realizar la estimación del nivel de RAS***

Los resultados de los FFTrees son binarios por lo que usan solo un subconjunto parcial de toda la información de características, porque el valor de 1 o 2 características no puede ser superado por ningún valor de otras características. Una vez que se toma una decisión, no hay información adicional que pueda cambiar la decisión.

El conjunto de datos de entrenamiento consto de 67 datos, de los cuales 50 decidieron RAS medio y 17 decidieron RAS elevado para el terreno estudiado. Esto quiere decir que 75% de los datos decidió que es medio y el 25% que es elevado. En este caso el umbral fue la señal red edge, que indica menor o igual a 0.1453 decide a RAS elevado y la segunda señal near infrared mayor a 0.1471 decide que es RAS medio (figura 20). En la prueba se corrieron 23 datos, de los cuales el 61% decidió por RAS medio y el 39% por RAS elevado, la frugalidad del árbol ignora las demás señales, seleccionando el umbral de red edge menor o igual a 0.1453 decide RAS medio y near infrared mayor a 0.1471 decide RAS medio (figura 21).

En la prueba el rendimiento fue de  $bacc = 67$ . Las ramas representan respuestas a preguntas basadas en características. Las celdas con elecciones correctas y rechazos correctos se refieren a decisiones correctas,

mientras que las celdas con falsas alarmas y los errores se refieren a errores de diferentes tipos.

Las bandas de longitud infrarroja de onda corta que el árbol selecciono (near infrared y red edge) pueden utilizarse como aproximación para la estimación de la salinidad del suelo agrícola. Se ha encontrado que elevadas concentraciones de sal pueden inferirse mediante la detección de firmas espectrales a través de malezas y plantas (por ejemplo, halófitas). Algunos minerales como el hierro exhiben una mayor reflectancia sobre el espectro visible a near infrared y la materia orgánica se absorbe fuertemente en longitudes de onda más cortas de infrarojo, la reflectancia puede disminuir proporcionalmente al contenido de limo y condiciones de humedad. La teledetección del near infrared puede contribuir significativamente a detectar cambios temporales de la sal y características de la superficie tales como costras o manchas del suelo de color no natural (blanco u oscuro) y cambios de textura debido al agrietamiento (Alexakis *et al.*, 2018), como el terreno de estudio, que presenta en algunas zonas agrietamientos y costras blancas.

La (figura 22) muestra las cinco mejores señales que arrojó el FFTrees en el entrenamiento. (Red edge, near infrared, SI14, NDVI y NDSI). Esta información puede ser útil para guiar un proceso descendente de futura construcción FFT. Por ejemplo, si esas señales fueran de particular interés, se podría construir una nueva FFT con estas señales.

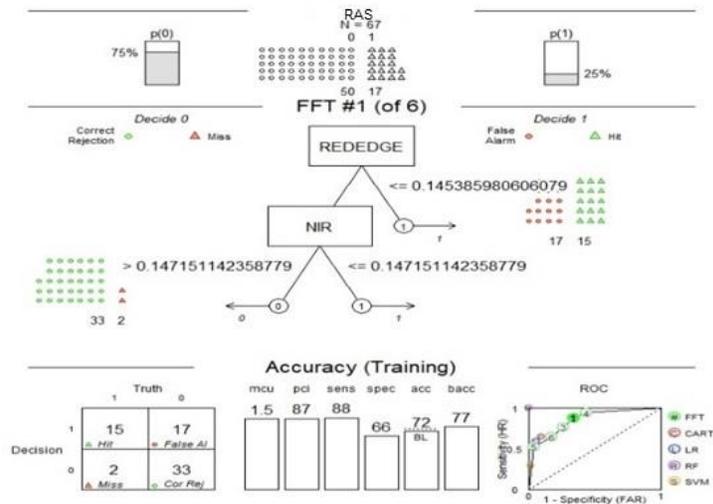


Figura 20. FFTree creado en entrenamiento para clasificación de RAS. En donde 0 decide medio y 1 decide elevado.

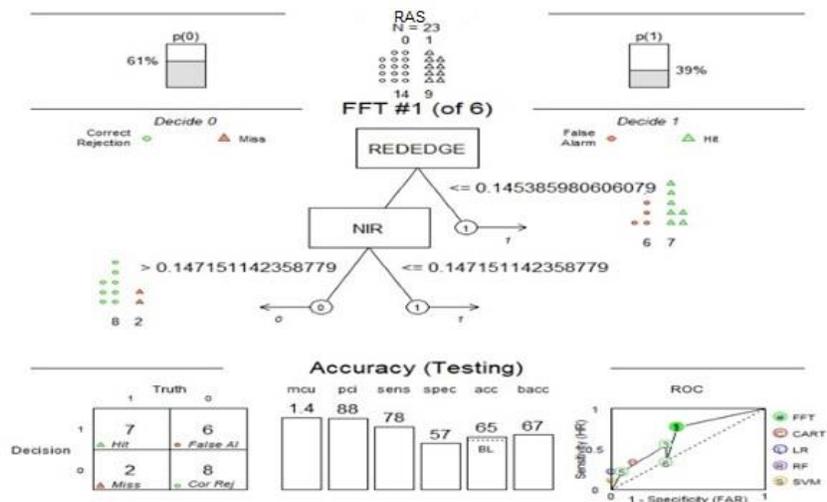


Figura 21. FFTree creado en prueba para clasificación de RAS. En donde 0 decide medio y 1 decide elevado.

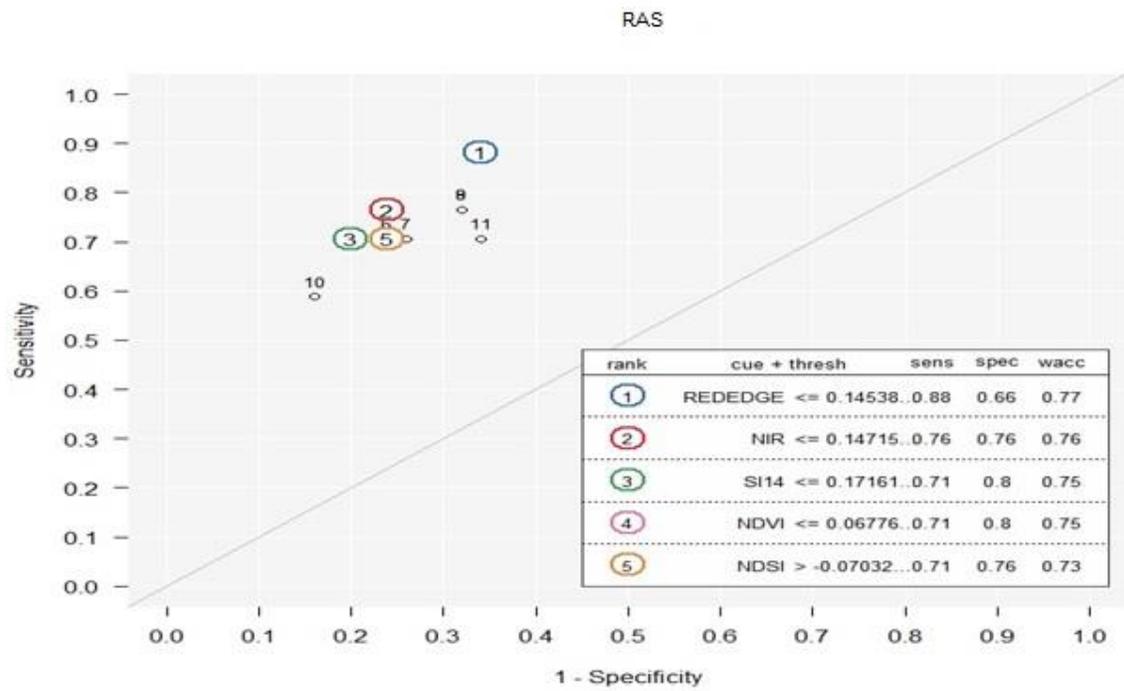


Figura 22. Visualización de las cinco mejores señales con mayor wacc de entrenamiento para la estimación de RAS.

## ***Redes neuronales utilizando NDVI y SAVI para realizar la estimación del nivel de RAS***

Uno de los pasos más importantes en el proceso de desarrollo de modelo de red neuronal es determinar las variables de entrada. En este clasificador bayesiano se estimó el nivel de la RAS a partir de los índices de salinidad NDVI y SAVI.

El experimento consto de 67 datos de entrenamiento de los cuales se clasificaron 17 elevados y 50 medios (47.05% y 92%), por lo tanto, el porcentaje de casos correctamente clasificados fue de 80.6% Este procedimiento utiliza una red probabilística neural para clasificar, basándose en 2 variables de entrada.

Se valido el modelo con 23 datos de prueba de los cuales se clasificaron correctamente 16 (69.56%) e incorrectamente 7 (30.43%), esto es derivado de usar la regla de clasificación para asignar tanto casos observados y casos nuevos a grupos.

Rhyma *et al* (2020) demostró que los índices NDVI y SAVI son adecuados para distinguir las áreas con vegetación y sin vegetación del suelo con problemas de ensalitramiento, tienen un alto grado de precisión en la clasificación de áreas de cobertura vegetal y suelo desnudo. El NDVI es uno de los métodos más populares empleados para el monitoreo de la vegetación, mientras que SAVI se desarrolló para mejorar el NDVI. De acuerdo a lo anterior, el índice SAVI y NDVI que la red neuronal propuso son una herramienta analítica útil para modelar la transferencia radiante de near infrared para áreas sin vegetación o suelo desnudo, en este caso con problemas de salinidad y sodicidad. Las variaciones del sustrato del suelo están efectivamente normalizadas y no influyen en la medición de la vegetación, ya que los índices espectrales se refinarán o calibrarán con SAVI. SAVI se puede aplicar para resolver los efectos del ruido de fondo del suelo

mediante la introducción de un factor de corrección del brillo del suelo que pudieran presentar algunas costras blancas de sal (Rhyma *et al.*, 2020).

El (cuadro 11) muestra los resultados de utilizar la red neuronal entrenada para clasificar y validar las observaciones. Lista las clasificaciones correspondientes a los dos vecinos más cercanos para cada caso. Por ejemplo, el vecino más cercano para la fila 1 fue clasificación = medio y el segundo vecino más cercano fue clasificación = elevado. De hecho, el valor verdadero de clasificación fue medio.

Cuadro 11. Clasificación y validación de la red neuronal para estimar RAS.

<b>Fila</b>	<b>Grupo Actual</b>	<b>Mayor (Grupo)</b>	<b>Mayor (valor)</b>	<b>2° Mayor (Grupo)</b>	<b>2° Mayor (valor)</b>
<b>1</b>	Medio	Medio	0.408861	Elevado	0.591139
<b>2</b>	Medio	Medio	0.305285	Elevado	0.694715
<b>3</b>	Medio	Medio	0.243267	Elevado	0.756733
<b>4</b>	Medio	Medio	0.381813	Elevado	0.618187
<b>5</b>	Medio	Elevado*	0.454041	Medio	0.545959
<b>6</b>	Medio	Medio	0.113739	Elevado	0.886261
<b>7</b>	Medio	Medio	0.405873	Elevado	0.594127
<b>8</b>	Medio	Medio	0.377652	Elevado	0.622348
<b>9</b>	Medio	Medio	0.0984851	Elevado	0.901515
<b>10</b>	Medio	Medio	0.207647	Elevado	0.792353
<b>11</b>	Medio	Medio	0.177898	Elevado	0.822102
<b>12</b>	Medio	Elevado*	0.3333	Medio	0.6667
<b>13</b>	Medio	Medio	0.358651	Elevado	0.641349
<b>14</b>	Medio	Medio	0.389842	Elevado	0.610158
<b>15</b>	Medio	Medio	0.464122	Elevado	0.535878
<b>16</b>	Medio	Medio	0.205848	Elevado	0.794152
<b>17</b>	Medio	Medio	0.444576	Elevado	0.555424
<b>18</b>	Medio	Medio	0.350298	Elevado	0.649702
<b>19</b>	Medio	Medio	0.474327	Elevado	0.525673
<b>20</b>	Medio	Medio	0.0632849	Elevado	0.936715
<b>21</b>	Medio	Medio	0.182018	Elevado	0.817982

<b>22</b>	Medio	Medio	0.313406	Elevado	0.686594
<b>23</b>	Medio	Medio	0.433082	Elevado	0.566918
<b>24</b>	Medio	Medio	0.0907692	Elevado	0.909231
<b>25</b>	Medio	Medio	0.0675057	Elevado	0.932494
<b>26</b>	Medio	Medio	0.195704	Elevado	0.804296
<b>27</b>	Medio	Elevado*	0.41593	Medio	0.58407
<b>28</b>	Medio	Medio	0.42536	Elevado	0.57464
<b>29</b>	Medio	Medio	0.215854	Elevado	0.784146
<b>30</b>	Medio	Medio	0.351191	Elevado	0.648809
<b>31</b>	Medio	Medio	0.165848	Elevado	0.834152
<b>32</b>	Medio	Medio	0.0875329	Elevado	0.912467
<b>33</b>	Medio	Medio	0.303514	Elevado	0.696486
<b>34</b>	Medio	Medio	0.332628	Elevado	0.667372
<b>35</b>	Medio	Medio	0.215235	Elevado	0.784765
<b>36</b>	Medio	Elevado*	0.482814	Medio	0.517186
<b>37</b>	Medio	Medio	0.329034	Elevado	0.670966
<b>38</b>	Medio	Medio	0.0896229	Elevado	0.910377
<b>39</b>	Medio	Medio	0.109065	Elevado	0.890935
<b>40</b>	Medio	Medio	0.222459	Elevado	0.777541
<b>41</b>	Medio	Medio	0.127044	Elevado	0.872956
<b>42</b>	Medio	Medio	0.113079	Elevado	0.886921
<b>43</b>	Medio	Medio	0.398855	Elevado	0.601145
<b>44</b>	Medio	Medio	0.0823448	Elevado	0.917655
<b>45</b>	Medio	Medio	0.188889	Elevado	0.811111
<b>46</b>	Medio	Medio	0.178994	Elevado	0.821006
<b>47</b>	Medio	Medio	0.358151	Elevado	0.641849
<b>48</b>	Medio	Medio	0.170905	Elevado	0.829095
<b>49</b>	Medio	Medio	0.308141	Elevado	0.691859
<b>50</b>	Medio	Medio	0.114283	Elevado	0.885717
<b>51</b>	Elevado	Medio*	0.247596	Elevado	0.752404
<b>52</b>	Elevado	Elevado	0.351855	Medio	0.648145
<b>53</b>	Elevado	Elevado	0.322237	Medio	0.677763
<b>54</b>	Elevado	Medio*	0.33848	Elevado	0.66152
<b>55</b>	Elevado	Elevado	0.356209	Medio	0.643791
<b>56</b>	Elevado	Medio*	0.454137	Elevado	0.545863
<b>57</b>	Elevado	Medio*	0.259596	Elevado	0.740404

<b>58</b>	Elevado	Elevado	0.367931	Medio	0.632069
<b>59</b>	Elevado	Elevado	0.167345	Medio	0.832655
<b>60</b>	Elevado	Medio*	0.251856	Elevado	0.748144
<b>61</b>	Elevado	Medio*	0.351574	Elevado	0.648426
<b>62</b>	Elevado	Medio*	0.0991552	Elevado	0.900845
<b>63</b>	Elevado	Medio*	0.316331	Elevado	0.683669
<b>64</b>	Elevado	Elevado	0.477171	Medio	0.522829
<b>65</b>	Elevado	Medio*	0.411197	Elevado	0.588803
<b>66</b>	Elevado	Elevado	0.323177	Medio	0.676823
<b>67</b>	Elevado	Elevado	0.145549	Medio	0.854451
<b>68</b>		Medio	0.144226	Elevado	0.855774
<b>69</b>		Medio	0.160305	Elevado	0.839695
<b>70</b>		Medio	0.329714	Elevado	0.670286
<b>71</b>		Medio	0.0925179	Elevado	0.907482
<b>72</b>		Medio	0.495405	Elevado	0.504595
<b>73</b>		Medio	0.374447	Elevado	0.625553
<b>74</b>		Medio	0.15593	Elevado	0.84407
<b>75</b>		Medio	0.188669	Elevado	0.811331
<b>76</b>		Medio	0.468174	Elevado	0.531826
<b>77</b>		Medio	0.0393496	Elevado	0.96065
<b>78</b>		Medio	0.30659	Elevado	0.69341
<b>79</b>		Medio	0.185875	Elevado	0.814125
<b>80</b>		Medio	0.266622	Elevado	0.733378
<b>81</b>		Medio	0.401531	Elevado	0.598469
<b>82</b>		Medio	0.371456	Elevado	0.628544
<b>83</b>		Medio	0.375447	Elevado	0.624553
<b>84</b>		Medio	0.483193	Elevado	0.516807
<b>85</b>		Medio	0.162072	Elevado	0.837928
<b>86</b>		Medio	0.225056	Elevado	0.774944
<b>87</b>		Elevado	0.161161	Medio	0.838839
<b>88</b>		Medio	0.252932	Elevado	0.747068
<b>89</b>		Medio	0.416544	Elevado	0.583456
<b>90</b>		Elevado	0.320876	Medio	0.679124

---

\* = incorrectamente clasificado.

Las (figuras 23) se presentan los diagramas de dispersión 2D que traza los datos de dos de las variables (SAVI y NDVI) las cuales produjo el modelo de red neuronal. Visualizándose la clasificación elevado y medio.

Las (figuras 24) se aprecia la clasificación del modelo para comprender mejor cómo la región definida por la clasificación (elevado y medio) se dividen en áreas que darían lugar a que las muestras se clasifiquen como pertenecientes a diferentes grupos. Cada región codificada por colores sombríos corresponde a un grupo diferente. Dos de las variables se utilizan para definir los ejes horizontal y vertical, mientras que las otras variables se mantienen en valores fijos.

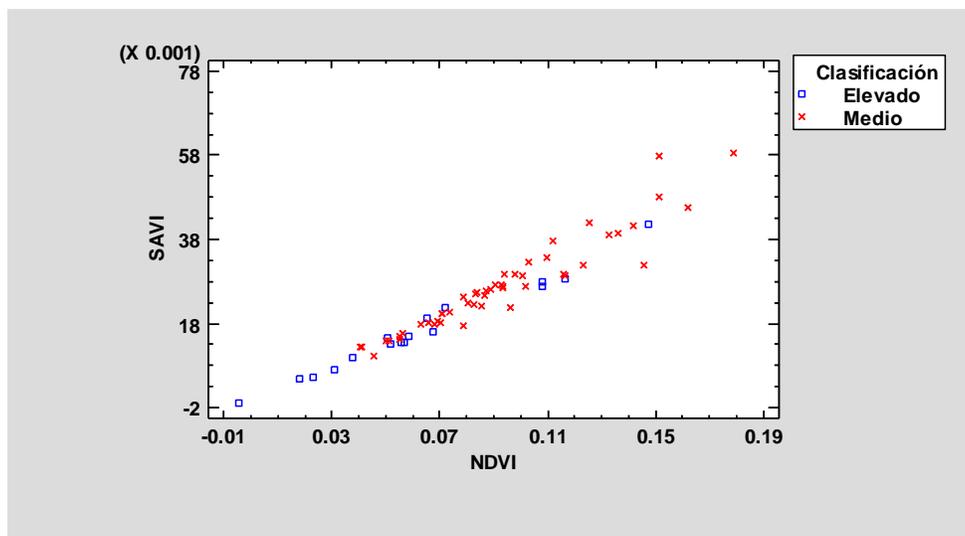


Figura 23. Diagrama de dispersión 2d entre SAVI vs NDVI y la clasificación RAS.

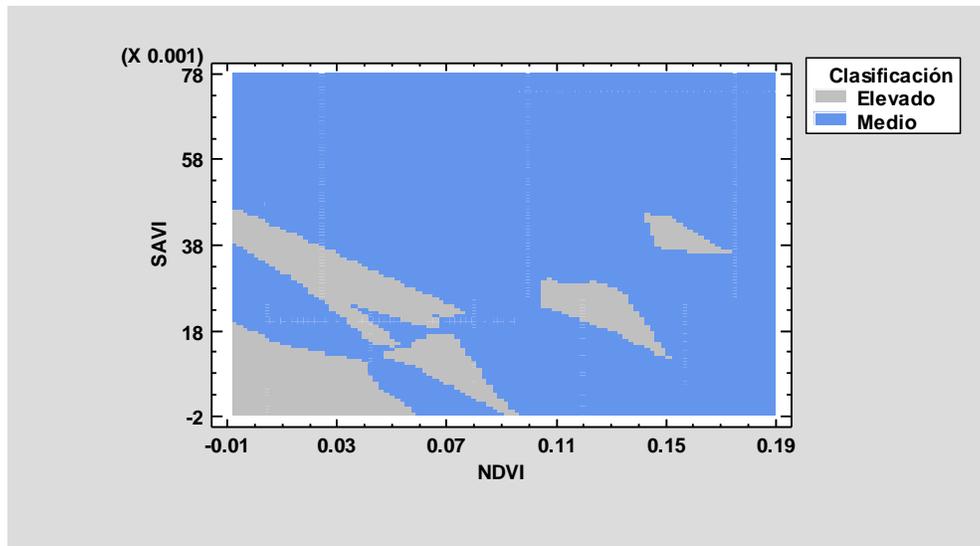


Figura 24. Regiones de la clasificación de elevado y medio de RAS.

### ***FFTrees de cuatro bandas espectrales y la estimación del nivel del PSI***

Se dividió aleatoriamente el conjunto de datos en dos partes: el entrenamiento y la prueba (figuras 25 y 26) que contienen información resultante del árbol creado, sobre las cuatro bandas espectrales y el PSI. Se aplicó el FFTrees cuyo objetivo es lograr la compensación de mejor rendimiento entre el porcentaje de casos con aciertos correctos y el porcentaje de casos que rechazan falsas alarmas. La principal señal de entrenamiento se refiere a la banda red edge, el procedimiento sugiere que si es mayor a 0.1453 es del porcentaje de sodio intercambiable medio. Los datos de prueba muestran que, de las 23 muestras, 12 son de PSI medio y 11 de PSI elevado.

Se proporcionan estadísticas de precisión acumulativas. La matriz de confusión muestra la precisión general del modelo en los datos de prueba equivalen al 65% de las señales de PSI medio y 35% de la señal de PSI elevado. Adicionalmente, las precisiones de cuatro árboles generados por el *ifan* del algoritmo son visibles en la parte inferior derecha del gráfico y son

los siguientes: decisión estándar tree (CART), regresión logística (LR), algoritmo de bosque aleatorio (RF), y algoritmo Support Vector Machine (SVM). El mejor modelo de predicción es la banda red edge la sensibilidad obtenida es de 62 mientras que la especificidad es de 60, el promedio de estas anteriores es bacc 61. La (figura 27) representa la especificidad contra la sensibilidad del modelo creado por FFTrees que indica la señal umbral Red edge y otras tres (near infrared, red y green).

Comparando el método utilizado por (Taghizadeh *et al.*, 2021) que utilizo los siguientes modelos: support vector regression (SVR) y support vector regression ondicular (W-SVR) con el uso de varios índices de salinidad, para predecir salinidad de suelos, encontró que (W-SVR) se desempeñó mejor  $R=0.91$  que (SVR)  $R=0.77$ , en donde también se combinó una alta gama de covariables ambientales. Lo que infiere resultados similares de porcentajes de clasificación de PSI de este trabajo. Estos hallazgos revelan que las covariables basadas en índices de salinidad en sensores remotos y en el terreno son predictores útiles para modelar la salinidad del suelo.

La idea era generar un marco probabilístico bayesiano de incertidumbre con respecto a las predicciones realizadas por el árbol de decisión con el fin de proporcionar una estimación de probabilidad para cada decisión binaria tomada. Se entiende entonces que si la señal umbral red edge en las clasificaciones de las muestras, es mayor a 0.1453 en este tipo de terrenos salinos, será de PSI medio. Las heurísticas y en particular los árboles rápidos y frugales, son metodologías que son simples y pueden lograr la misma precisión que más métodos complejos basadas en big data (Gadzinski & Castello, 2020). En esta sección proponemos una familia de heurística rápida y frugal para la clasificación de PSI. Las heurísticas son frugales en el sentido de que no utilizan toda la información disponible y rápido porque integran la información de forma sencilla para decidir. Y así tener un panorama claro de la condición del terreno (Durbach *et al.*, 2020).

Esto tiene sentido porque el árbol ignora las demás señales proporcionadas y solo seleccionó dos (near infrared y red).

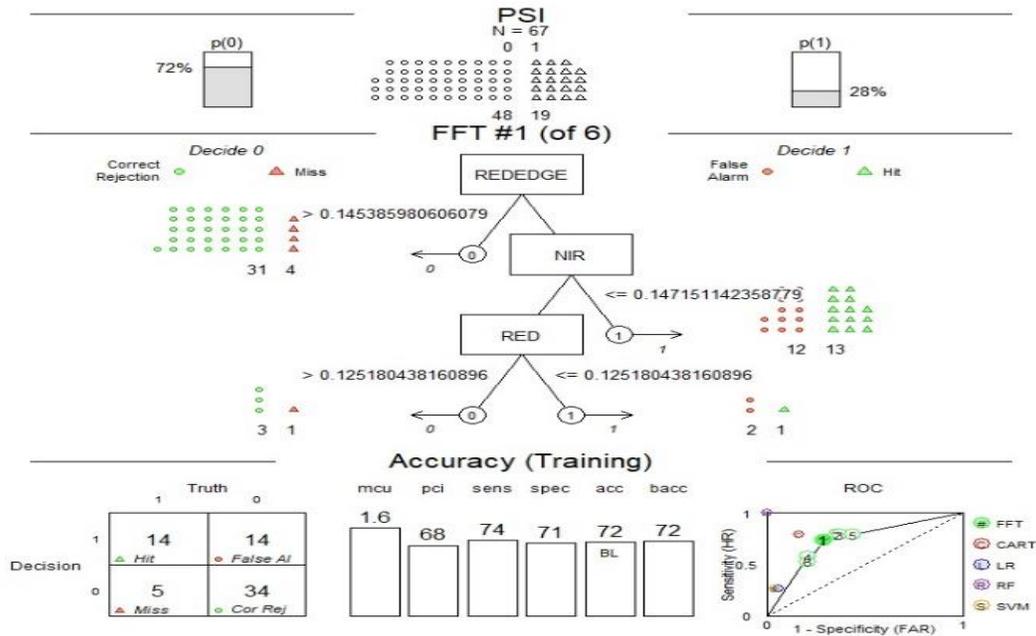


Figura 25. FFTree creado en entrenamiento para clasificación de PSI. En donde 0 decide medio y 1 decide elevado.

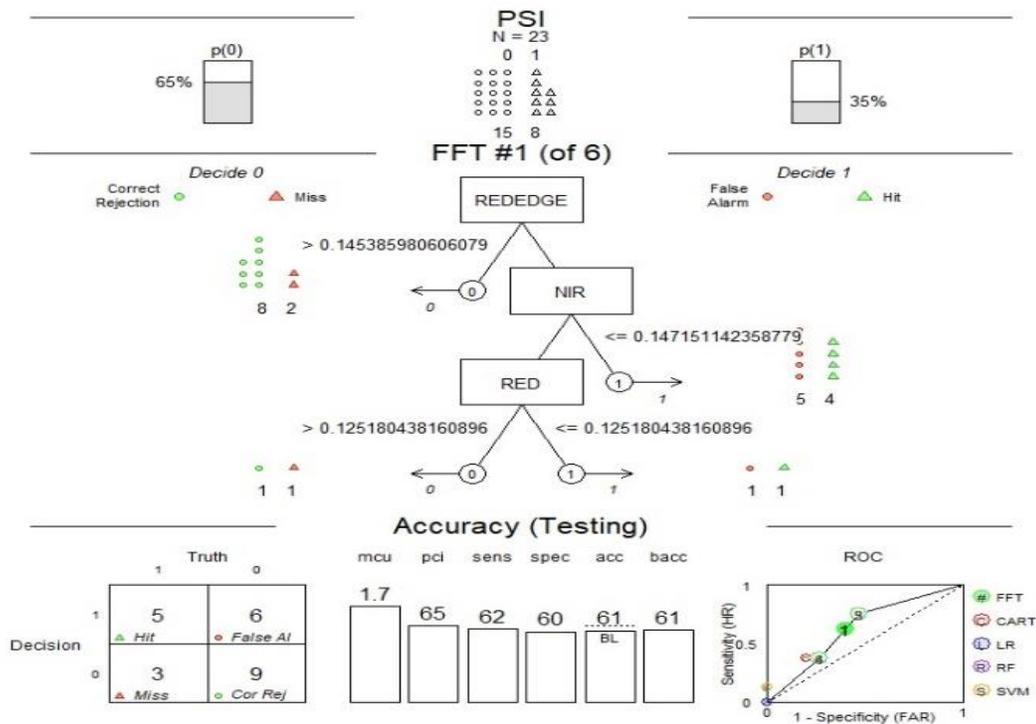


Figura 26. FFTree creado en prueba para clasificación de PSI. En donde 0 decide medio y 1 decide elevado.

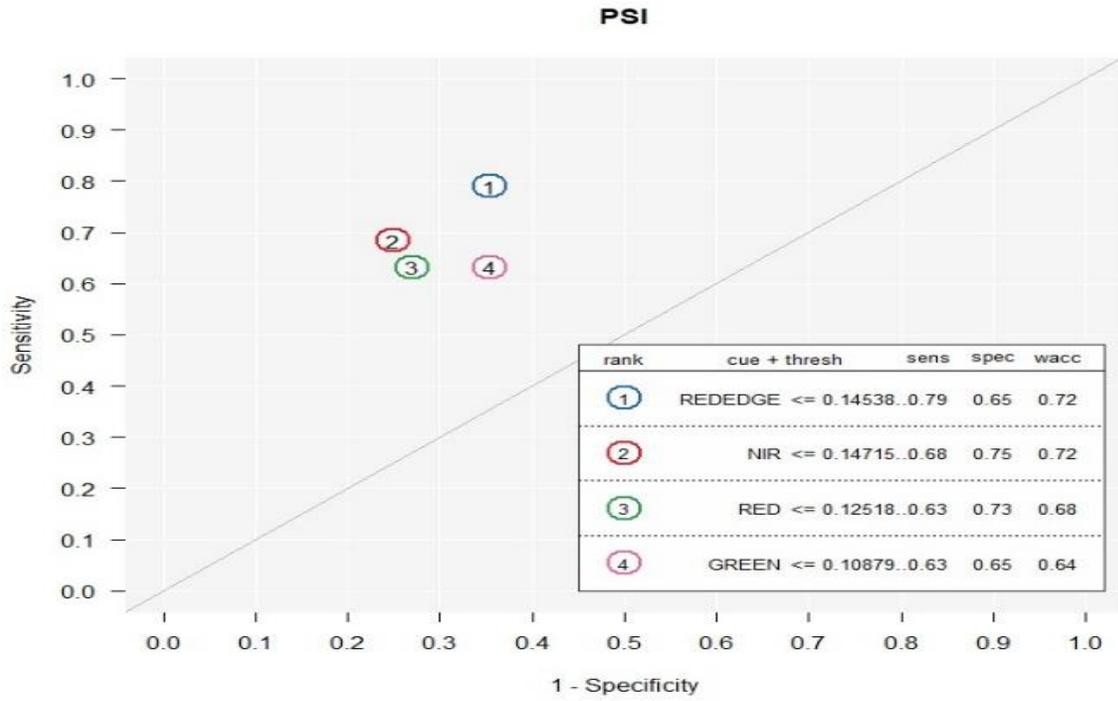


Figura 27. Visualización de las cuatro mejores señales con mayor wacc de entrenamiento para la estimación de PSI.

## ***Redes neuronales utilizando NDVI y SAVI en la estimación del nivel del PSI***

Esta sección se analiza los resultados obtenidos del clasificador bayesiano propuesto, con el conjunto de datos del estudio de NDVI y SAVI que al mismo tiempo la red neuronal se basa en dos variables de entrada con relación al PSI, siendo este proceso el de mejor rendimiento 76.12% de casos correctos. De los 67 casos analizados de entrenamiento, 19 fueron clasificados como PSI elevado y 48 como PSI medio. El conjunto de datos de prueba se consideraron 23 datos, de estos 17 casos son correctos (14 de PSI medio y 3 de PSI elevado), el algoritmo fallo en seis casos, lo que corresponde a el 73.91% de casos clasificados correctamente y 26.08% de casos clasificados incorrectamente respectivamente. En el (cuadro 12) se presenta el resultado de clasificación y validación del proceso por ejemplo la fila cinco obtuvo el valor más alto para la clasificación elevado y el segundo más alto para la clasificación medio, además se observa el resultado de la prueba de 23 casos analizados. En este paquete de Statgraphics es posible predecirse observaciones adicionales agregando nuevas filas al archivo de datos actual, llenando los valores para cada una de las variables de captura, pero dejando las celdas de clasificación en blanco.

Es importante señalar que se encontró en los numerosos ensayos experimentales que los índices NDVI y SAVI tienen los mayores porcentajes de clasificación y son los mismos índices en la red neuronal de RAS y PSI, por lo que asumimos que puede ser debido a que el PSI procede necesariamente del RAS en los cálculos. Sin embargo, el acomodo de clasificación es diferente.

Cuadro 12. Clasificación y validación de la red neuronal para estimar PSI.

<b>Fila</b>	<b>Grupo Actual</b>	<b>Mayor (Grupo)</b>	<b>Mayor (valor)</b>	<b>2° Mayor (Grupo)</b>	<b>2° Mayor (valor)</b>
5	Medio	Elevado*	1.0	Medio	3.88581E-11
6	Medio	Elevado*	0.990486	Medio	0.00951374
12	Medio	Elevado*	0.999978	Medio	0.0000222622
18	Medio	Elevado*	-1.#IND	Medio	-1.#IND
27	Medio	Elevado*	1.0	Medio	5.21463E-19
36	Medio	Elevado*	0.999998	Medio	0.00000219984
50	Elevado	Medio*	1.0	Elevado	7.84201E-214
51	Elevado	Medio*	1.0	Elevado	8.01196E-54
54	Elevado	Medio*	1.0	Elevado	3.66691E-46
56	Elevado	Medio*	0.995271	Elevado	0.00472895
57	Elevado	Medio*	1.0	Elevado	3.25795E-40
60	Elevado	Medio*	1.0	Elevado	1.5958E-53
61	Elevado	Medio*	0.999998	Elevado	0.00000218937
62	Elevado	Medio*	1.0	Elevado	0.0
63	Elevado	Medio*	1.0	Elevado	1.90105E-7
65	Elevado	Medio*	1.0	Elevado	9.24676E-38
68		Medio	1.0	Elevado	6.07971E-45
69		Medio	1.0	Elevado	1.03082E-46
70		Medio	1.0	Elevado	1.71021E-44
71		Medio	0.999947	Elevado	0.0000525359
72		Medio	0.864188	Elevado	0.135812
73		Medio	0.999863	Elevado	0.000136884
74		Medio	1.0	Elevado	1.73273E-32
75		Medio	1.0	Elevado	2.27468E-32
76		Medio	0.992961	Elevado	0.00703921
77		Elevado	0.999982	Medio	0.0000178479
78		Medio	1.0	Elevado	0.0
79		Medio	1.0	Elevado	4.13909E-305
80		Medio	1.0	Elevado	2.58569E-95
81		Medio	0.999851	Elevado	0.000148994
82		Medio	1.0	Elevado	1.78622E-13
83		Medio	1.0	Elevado	4.554E-35
84		Elevado	0.595736	Medio	0.404264

<b>85</b>	Medio	1.0	Elevado	2.70249E-126
<b>86</b>	Medio	0.998965	Elevado	0.0010354
<b>87</b>	Elevado	1.0	Medio	1.34446E-37
<b>88</b>	Medio	1.0	Elevado	0.0
<b>89</b>	Medio	0.995183	Elevado	0.00481659
<b>90</b>	Elevado	0.999964	Medio	0.0000363542

---

\* = *incorrectamente clasificado.*

En la (figuras 28) se presentan los diagramas de dispersión 2D que traza los datos de dos de las variables (SAVI y NDVI) las cuales produjo el modelo de red neuronal. Visualizándose la clasificación elevado y medio.

Las (figuras 29) se aprecia la clasificación del modelo para comprender mejor cómo la región definida por la clasificación (elevado y medio) se dividen en áreas que darían lugar a que las muestras se clasifiquen como pertenecientes a diferentes grupos. Cada región codificada por colores sombríos corresponde a un grupo diferente. Dos de las variables se utilizan para definir los ejes horizontal y vertical, mientras que las otras variables se mantienen en valores fijos.

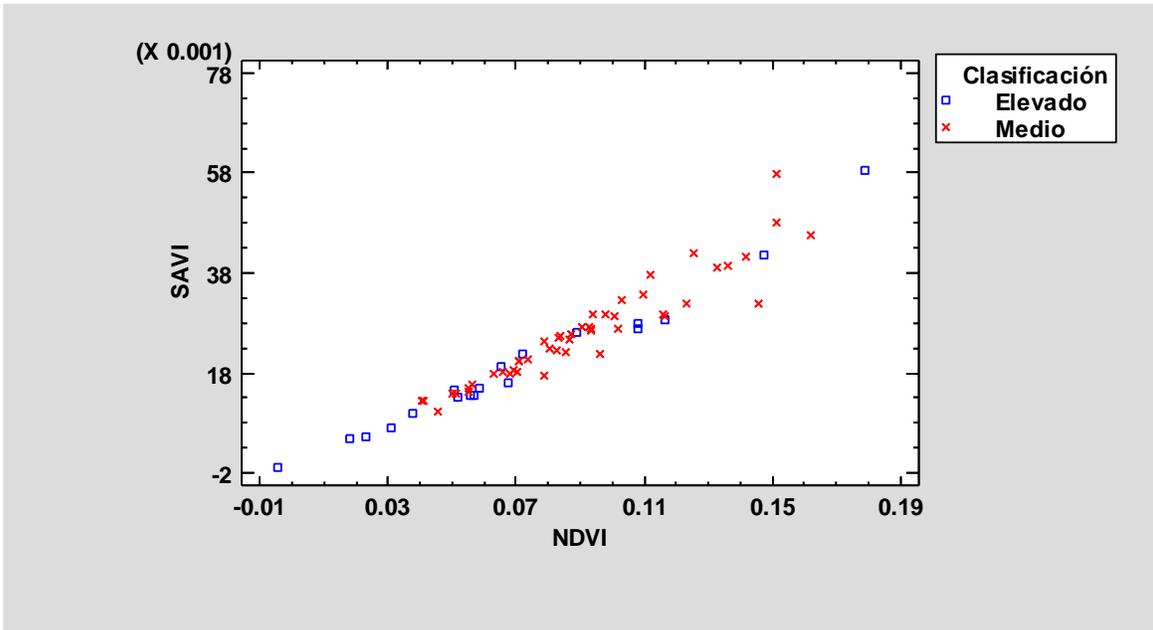


Figura 28. Diagrama de dispersión 2d entre SAVI vs NDVI y la clasificación PSI.

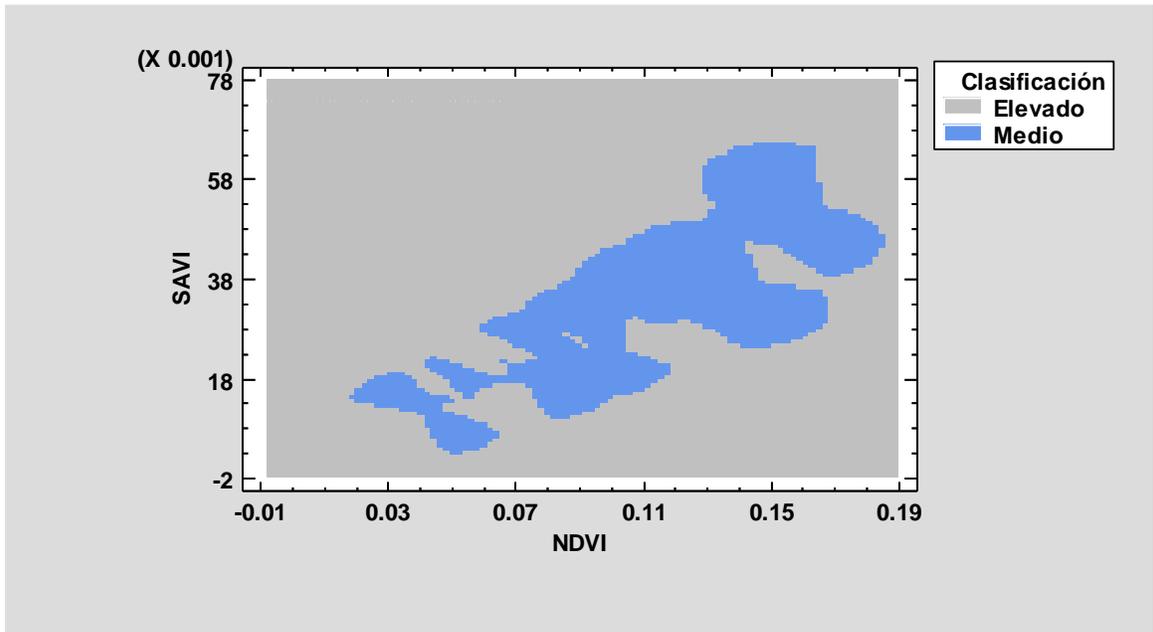


Figura 29. Regiones de la clasificación de elevado y medio de PSI.

### ***FFTrees de cuatro bandas espectrales y varios índices de salinidad para realizar la estimación del nivel de sodio***

El entrenamiento de FFTrees para la predicción de resultados de clasificación de sodio muestra la precisión de las señales y se resaltan dos con los valores de precisión ponderados más altos en el entrenamiento (figura 30) que fueron las siguientes: el índice NDSI con sensibilidad 56, especificidad 83, bacc 69. En la prueba las señales con los dos valores más altos de WACC se seleccionaron como nodos para la predicción de resultados de clasificación de sodio, 59% de muestras son de clasificación elevada de sodio (6 correctos aciertos y 3 falsas alarmas) (figura 31). El 41% de las muestras son clasificación media de sodio (6 aciertos y 7 fallos). El umbral NDSI decidió que si es mayor a -0.0786 es clasificación elevada y la segunda señal red- near infrared expreso que si es menor o igual a 0.8542 es de clasificación de sodio media. Es de destacar que, aunque el modelo FFT es simple, su precisión era comparable a la de otros algoritmos de clasificación de otras variables de salinidad, por lo tanto, nuestros hallazgos sugieren que el modelo FFT no solo es rápido y frugal, si no también útil para predecir los resultados de clasificación de sodio a pesar de BACC no es tan cercano a 1. El acomodo de señales que proporciono el modelo se presenta en la (figura 32) además indica las señales menos favorables en puntos negros. El NDSI que es un inverso del NDVI, mostro mejor porcentaje de clasificación en los árboles frugales y rápidos. Según lo reportado por (Allbed & Kumar; 2013) este índice ha mostrado buenos resultados en otros trabajos de teledetección de diferentes clases de sales, normalmente la vegetación insalubre tiene una actividad fotosintética más baja, lo que provoca un aumento de la reflectancia visible y una reducción de la reflectancia de los espectros infrarrojos como el índice NDSI del suelo. Este patrón se ha encontrado en varias plantas sometidas a estrés por salinidad. Por lo tanto, con base en este hallazgo, se han utilizado varios índices de

vegetación como el NDVI, SAVI, NDSI y SI, como indicadores indirectos para evaluar y mapear la salinidad del suelo (Allbed & Kumar; 2013).

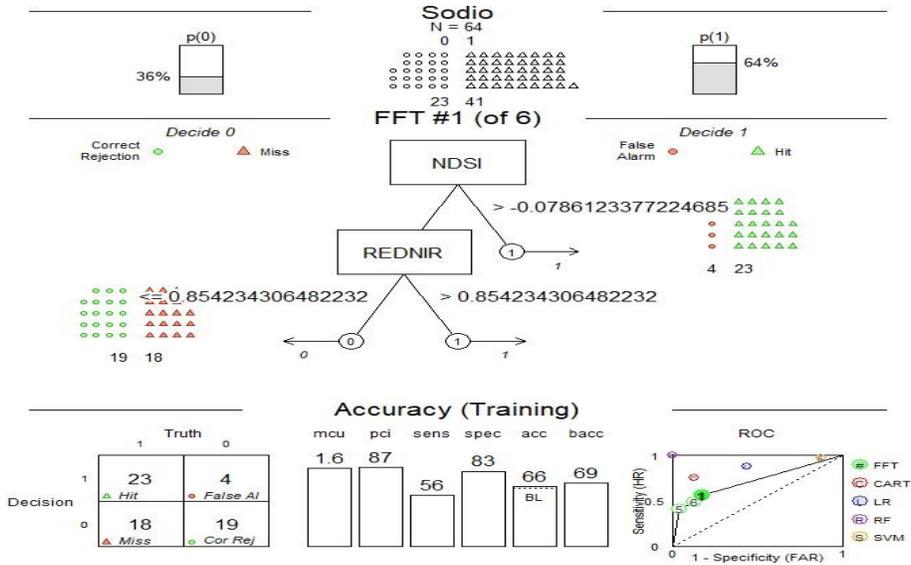


Figura 30. FFTree creado en entrenamiento para clasificación de sodio. En donde 0 decide medio y 1 decide elevado.

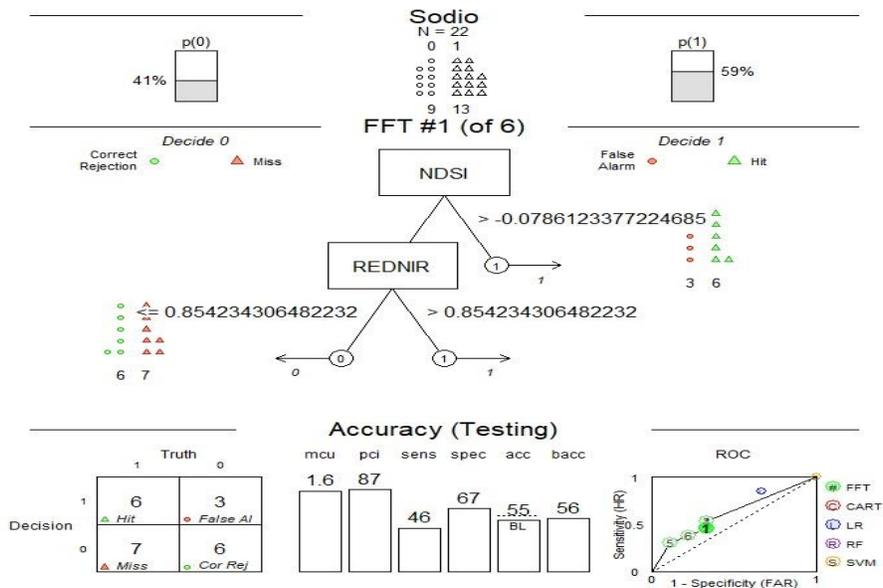


Figura 31. FFTree creado en prueba para clasificación de sodio. En donde 0 decide medio y 1 decide elevado.

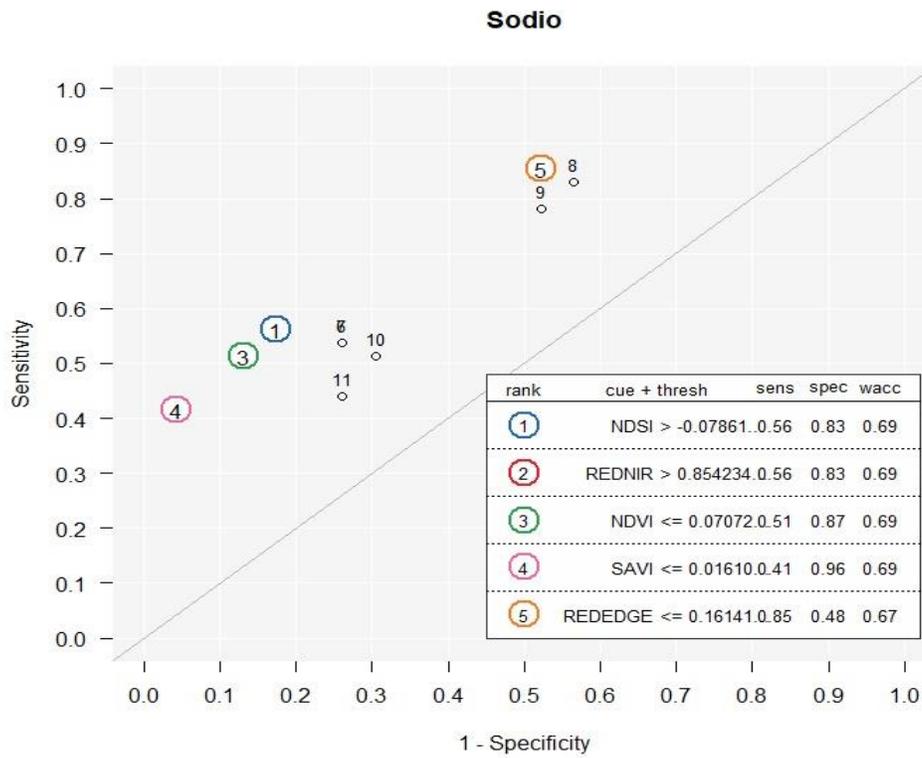


Figura 32. Visualización de las cinco mejores señales con mayor wacc de entrenamiento para la estimación de sodio.

### ***Redes neuronales utilizando los índices NDSI y Red/Near infrared en la estimación del nivel del sodio***

Como es conocido, los modelos no deben ser validados con los mismos datos usados para el entrenamiento. En este método se divide en el entrenamiento 80% de los datos y la validación 20% de los datos. Los datos de entrenamiento tienen 71.88 % de clasificación correcta mientras que los de prueba 54.54 %. Las clasificaciones de entrenamiento correcto mostraron 21 miembros de concentración de sodio elevada y 43 media. En el set de prueba 8 de clasificación de concentración de sodio media y 4 para elevada. La utilización del algoritmo backpropagation es un método de aprendizaje supervisado, una aplicación de la regla Delta. Es el más usado para redes feed-forward (redes que no tienen información, o simplemente, que no tienen ningún lazo de conexiones). En el (cuadro 13) se observa las clasificaciones del set de entrenamiento y el de prueba con opción de mayor grupo y mayor valor. Además de las predicciones erróneas del caso, es un índice ampliamente usado para la detección de salinidad de suelos a partir de vegetación afectada y suelos desnudos, esto tiene sentido según (Zewdu *et al.*, 2017) que ha encontrado varias clases de salinidad (suelos no salinos; ligeramente salinos, moderadamente salinos y fuertemente salinos) utilizando modelos de clasificación supervisada de NDSI, como es el caso de este trabajo. La índice red/ near infrared fue propuesto por los autores y ha mostrado buen desempeño de redes neuronales con relación a sodio. Ya que utiliza las bandas infrarrojas que se sabe son de reflectancias apropiadas para la detección de salinidad de suelos.

Cuadro 13. Clasificación y validación de la red neuronal para estimar sodio.

<b>Fila</b>	<b>Grupo Actual</b>	<b>Mayor (Grupo)</b>	<b>Mayor (valor)</b>	<b>2° Mayor (Grupo)</b>	<b>2° Mayor (valor)</b>
<b>2</b>	Medio	Elevado*	0.61656	Medio	0.38344
<b>3</b>	Medio	Elevado*	0.613672	Medio	0.386328
<b>6</b>	Medio	Elevado*	0.691282	Medio	0.308718
<b>7</b>	Medio	Elevado*	0.681813	Medio	0.318187
<b>10</b>	Medio	Elevado*	0.54655	Medio	0.45345
<b>28</b>	Medio	Elevado*	0.785838	Medio	0.214162
<b>29</b>	Medio	Elevado*	0.685478	Medio	0.314522
<b>30</b>	Medio	Elevado*	0.68288	Medio	0.31712
<b>38</b>	Medio	Elevado*	0.690578	Medio	0.309422
<b>42</b>	Medio	Elevado*	0.583529	Medio	0.416471
<b>45</b>	Elevado	Medio*	0.93664	Elevado	0.0633596
<b>46</b>	Elevado	Medio*	0.559937	Elevado	0.440063
<b>49</b>	Elevado	Medio*	0.62071	Elevado	0.37929
<b>52</b>	Elevado	Medio*	0.520613	Elevado	0.479387
<b>55</b>	Elevado	Medio*	0.732486	Elevado	0.267514
<b>56</b>	Elevado	Medio*	0.513038	Elevado	0.486962
<b>57</b>	Elevado	Medio*	0.876878	Elevado	0.123122
<b>59</b>	Elevado	Medio*	0.547279	Elevado	0.452721
<b>65</b>		Elevado	0.689309	Medio	0.310691
<b>66</b>		Elevado	0.655518	Medio	0.344482
<b>67</b>		Medio	0.849302	Elevado	0.150698
<b>68</b>		Medio	0.634569	Elevado	0.365431
<b>69</b>		Elevado	0.624711	Medio	0.375289
<b>70</b>		Medio	0.793519	Elevado	0.206481
<b>71</b>		Medio	0.930576	Elevado	0.069424
<b>72</b>		Medio	0.535882	Elevado	0.464118
<b>73</b>		Medio	0.548045	Elevado	0.451955
<b>74</b>		Medio	0.566787	Elevado	0.433213
<b>75</b>		Medio	0.77027	Elevado	0.22973
<b>76</b>		Medio	0.531751	Elevado	0.468249
<b>77</b>		Elevado	0.613147	Medio	0.386853
<b>78</b>		Elevado	0.699249	Medio	0.300751
<b>79</b>		Medio	0.75063	Elevado	0.24937

<b>80</b>	Medio	0.555151	Elevado	0.444849
<b>81</b>	Medio	0.796889	Elevado	0.203111
<b>82</b>	Medio	0.811606	Elevado	0.188394
<b>83</b>	Medio	0.517077	Elevado	0.482923
<b>84</b>	Medio	0.833584	Elevado	0.166416
<b>85</b>	Elevado	1.0	Medio	0.0
<b>86</b>	Elevado	1.0	Medio	0.0

\* = *incorrectamente clasificado.*

Las (figuras 33) se presentan los diagramas de dispersión 2D que traza los datos de dos de las variables (red- near infrared y NDSI) las cuales produjo el modelo de red neuronal. Visualizándose la clasificación elevado y medio.

Las (figuras 34) se aprecia la clasificación del modelo para comprender mejor cómo la región definida por las variables (red- near infrared y NDSI) se dividen en áreas que darían lugar a que las muestras se clasifiquen como pertenecientes a diferentes grupos. Cada región codificada por colores sombríos corresponde a un grupo diferente. Dos de las variables se utilizan para definir los ejes horizontal y vertical, mientras que las otras variables se mantienen en valores fijos.

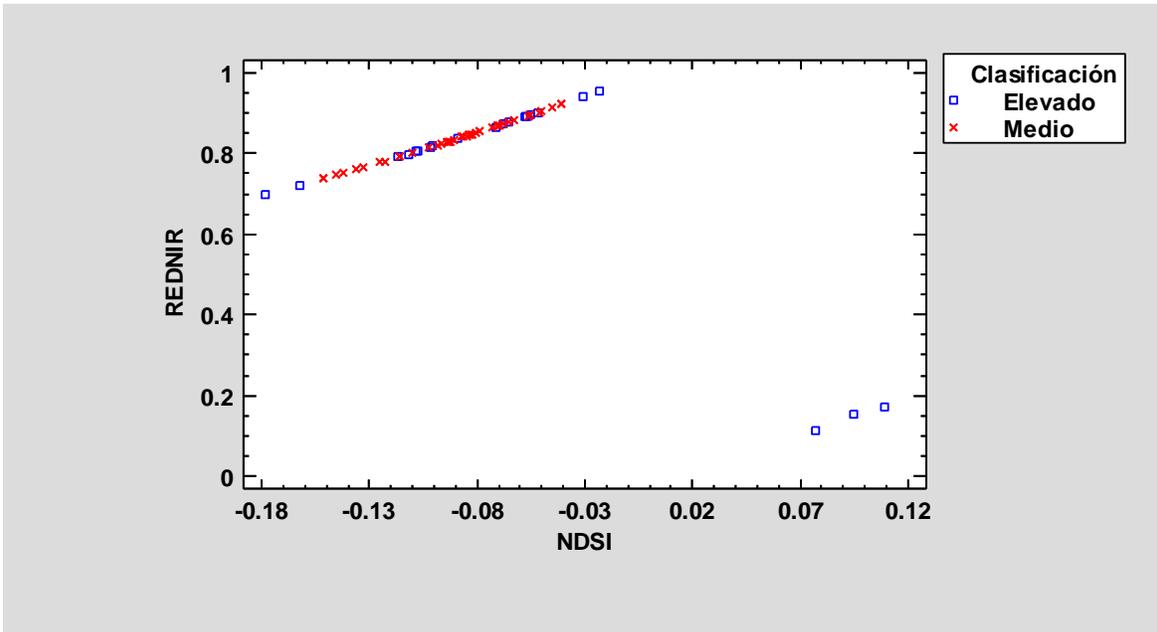


Figura 33. Diagrama de dispersión 2d entre SAVI vs NDVI y la clasificación sodio.

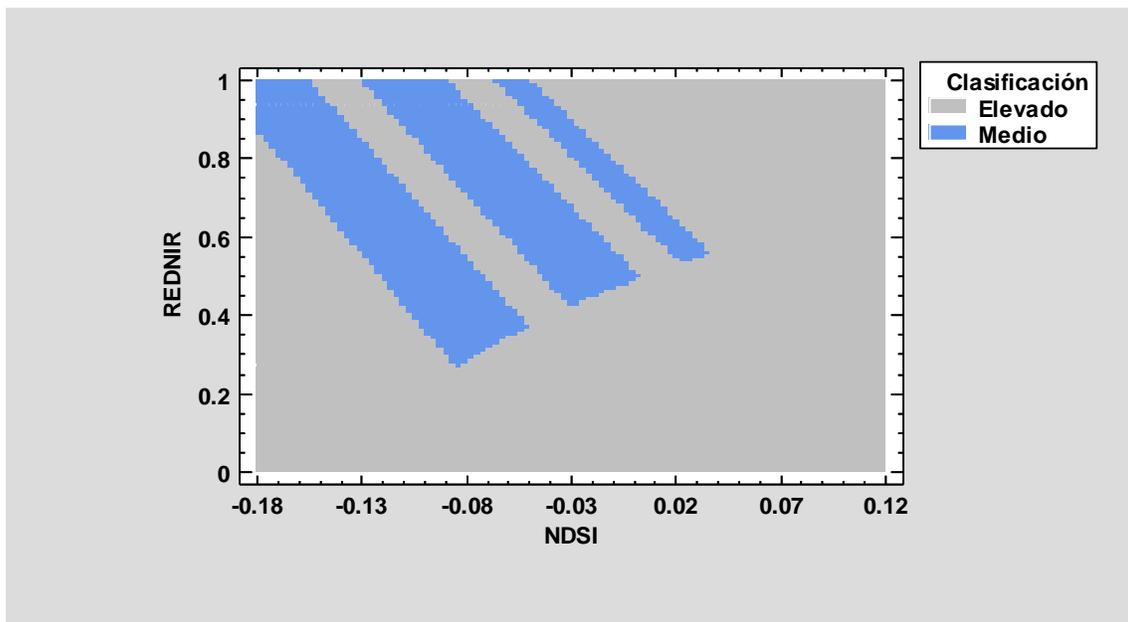


Figura 34. Regiones de la clasificación de elevado y medio de sodio.

### ***Comparación de los modelos de árboles de decisión y redes neuronales en la estimación de los niveles de PSI, RAS y Sodio***

En la estimación del nivel de la relación de absorción de sodio, RAS, se encontró que el modelo de red neuronal presentó una precisión del 69.56 %, mientras que los modelos de árboles de decisión, FFTrees, presentaron una precisión de 67%. El modelo de red neuronal clasificó al 91.3% de las muestras en la categoría de nivel medio, mientras que el modelo de árboles de decisión clasificó al 61% de las muestras en la misma categoría de nivel medio. En este caso ambos algoritmos logran adecuados porcentajes de clasificación correcta.

Otra característica a destacar son los vectores de entrada o señales que mejor precisión mostraron en la estimación del nivel del RAS, para el caso de los modelos de árboles de decisión, FFTrees, las reflectancias de las bandas red edge y near infrared fueron las que mejor estimaron este indicador de salinidad. Mientras que para el caso del modelo de red neuronal las variables de entrada que mejor estimaron el nivel de RAS fueron los índices de reflectancia, NDVI y SAVI.

En la segunda variable, el porcentaje de sodio intercambiable PSI, los árboles de decisión, FFTrees, presentaron una precisión del 61% en la estimación del nivel del PSI; mientras que el modelo de la red neuronal presentó una precisión del 76.12 %. En este sentido los FFTrees clasificaron al 65% de las muestras en la categoría de nivel media, mientras que las redes neuronales clasificaron al 82.6% de las muestras en la categoría de nivel media. En el caso de los árboles de decisión, las señales que mejor estimaron el nivel de PSI fueron las reflectancias en las bandas red edge, near infrared y red. Mientras que en el modelo de red neuronal las señales que mejor estimaron el nivel de PSI fueron los índices de reflectancia NDVI y SAVI.

En el caso de la clasificación de concentración del ion sodio, el modelo de red neuronal fue el que presentó los mejores resultados en la estimación con una precisión del 71.88 %; mientras que el modelo de árboles de decisión presentó una precisión de 56 %. En este sentido los FFTrees clasificaron al 59% de las muestras en la categoría de nivel elevada, mientras que las redes neuronales clasificaron al 68% de las muestras en la categoría de nivel media. También se encontró en este caso que los índices de salinidad NDSI y red/ near infrared fueron las mejores variables de entrada para estimar el nivel de sodio con una mejor precisión. En la (figura 35) se muestra la precisión encontrada en la determinación de los niveles de RAS, PSI, y sodio para los modelos de árboles de decisión y los modelos de redes neuronales. Se puede apreciar que los modelos de redes neuronales presentaron la mejor precisión para los tres indicadores de salinidad estudiados en el presente trabajo de investigación.

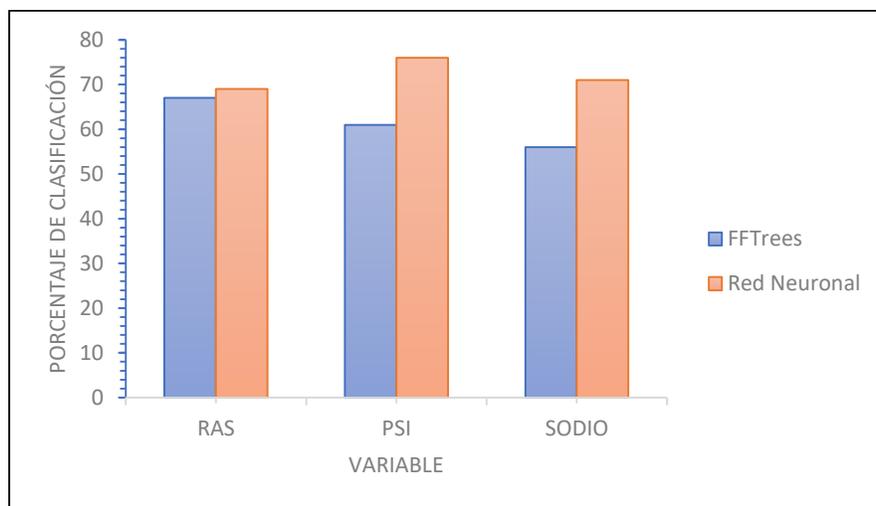


Figura 35. Comparación de las precisiones entre el modelo FFTrees y las redes neuronales.

## **Comparación de trabajos enfocados a la detección y clasificación de salinidad**

En el siguiente (cuadro 14) se observan los métodos empleados, el porcentaje de precisión de varios autores que han experimentado clasificar y detectar salinidad del suelo con diferentes resultados.

Cuadro 14. Resultados de porcentajes de precisión de detección y clasificación de salinidad y el método empleado.

<b>Método empleado</b>	<b>Porcentaje de precisión del modelo</b>	<b>Referencia</b>
Support Vector Regression Wavelet (SVR-W)	91	Taghizadeh <i>et al.</i> , 2021
Algoritmo de clasificación de máxima verosimilitud (MLC),	90	Abbas <i>et al.</i> , 2013
Transformación PCA 3D lineal utilizando Imagen WorldView-2	65	Alexakis <i>et al.</i> , 2018
Artificial multi-layered neural network-genetic algorithm model (ANN-GA)	94	Amir <i>et al.</i> , 2020
Landsat y coeficiente Kappa (KC) con clasificador de Distancia Máxima (MD) y PCA (1-5)	84	Hamzeh <i>et al.</i> , 2016
Regresión múltiple (validación cruzada K-fold)	63	Ramos <i>et al.</i> , 2020

## 2.8. CONCLUSIÓN

Se presentan los resultados del trabajo de investigación en el cual se evaluaron y validaron modelos de árboles de decisión y redes neuronales para estimar el nivel de salinidad de acuerdo a los indicadores PSI, RAS y Sodio utilizando imágenes capturadas mediante el uso de vehículos aéreos no tripulados. El trabajo de investigación demostró que es posible clasificar la salinidad del suelo con aceptable precisión a partir de las imágenes capturadas con vehículos aéreos no tripulados. Los modelos de redes neuronales mostraron una mejor precisión en la estimación de los tres indicadores de salinidad utilizados en este estudio (PSI, RAS, Sodio) con respecto a los árboles de decisión. Los rangos de precisión encontrados para los modelos de redes neuronales fluctuaron entre el 69 y 76% mientras que los árboles de decisión mostraron precisiones entre 56 y 67%. El uso de datos de teledetección, seguido de muestreos del sitio son una herramienta poderosa para detectar áreas afectadas por la salinidad. Las señales de entrada para los modelos de clasificación de la salinidad del suelo son las reflectancias en las bandas red, near infrared, green y red-edge, así como índices de reflectancia calculados a partir de las reflectancias mencionadas anteriormente. La simplicidad del modelo propuesto y el grado de precisión obtenido, lo convierten en una herramienta prometedora para su uso en la predicción de la salinidad del suelo.

## **2.9. RECOMENDACIONES**

Se sugiere realizar pruebas con sensores hiperespectrales, los cuales son más avanzados y diseñados para VANT, según la literatura especializada estos sensores tienen más afinidad para detectar la salinidad del suelo, consiguiéndose así una máxima información espectral del terreno de estudio. Además de realizar un muestreo de suelo menor de 15 a 20 muestras para 4 Ha.

Con los datos obtenido se recomienda utilizar otras herramientas de aprendizaje como: decisión estándar tree (CART), regresión logística (LR), algoritmo de bosque aleatorio (RF) y arboles de decisión WEKA.

## 2.10. REFERENCIAS

- Abbas A., Khan S., Hussai N., Hanjra M. A., Akbar S. 2013. Characterizing soil salinity in irrigated agriculture using a remote sensing approach. *Physics and Chemistry of the Earth*. 55-57. 43-52.
- Aldabaa A. A., David C. Weindorf, Chakraborty C., Sharma A., Bin L. 2015. Combination of proximal and remote sensing methods for rapid soil salinity quantification. *Geoderma*. 239-240 (34-46). <https://doi.org/10.1016/j.geoderma.2014.09.011>.
- Alexakis D. D., I. N. Daliakopoulos, I. S. Panagea & I. K. Tsanis. 2018. Assessing soil salinity using WorldView-2 multispectral images in Timpaki, Crete, Greece. *Geocarto International*. 33: 4 (321-338). DOI: 10.1080/10106049.2016.1250826.
- Allbed A., Kumar L. 2013. Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: A review. *Advances in remote sensing*. 2: 373-385.
- Allbed A., Kumar L., Aldakheel Y. Y. 2014. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: Applications in a date palm dominated region. *Geoderma* 230-231: 1-8.
- Altman, N. & Krzywinski M. 2015. Simple linear regression. *Nat Methods* 12, 999-1000.
- Amir D. M., Naderi A., Ghorbani Y., Mehrpouyan A. & Bakhshi A. 2020. Soil salinity mapping by remote sensing south of Urmia Lake, Iran. *Geoderma Regional*. 22: e00317.
- Ayala H. S. 2020. Estadística, cuartiles, deciles, percentiles. Universidad Autónoma de Hidalgo. División académica media superior. Escuela Superior Tepeji del Río. Consultado 7 de octubre de 2020. [www.uaeh.edu.mx /cuartiles-deciles-y-percentiles](http://www.uaeh.edu.mx/cuartiles-deciles-y-percentiles)
- Azabdaftari A. & Sunar F. 2016. Soil salinity mapping using multitemporal landsat data. *soil salinity mapping using multitemporal landsat data. Remote sensing and spatial information sciences*. XLI-B7. doi:10.5194/isprsarchives-XLI-B7-3-2016. 3.
- Balafoutis A., Beck B., Fountas S., Vangeyte J., Wal T. V. 2017. Precision agriculture technologies positively contributing to GHG emissions mitigation, farm productivity and economics. *Sustainability* 9(8). 1339. <https://doi.org/10.3390/su9081339>.

Bannari A., Guedona A. M., El-Hartib A., Cherkaouic F. Z. y El-Ghmari A. 2008. Characterization of slightly and moderately saline and sodic soils in irrigated agricultural land using simulated data of advanced land imaging (EO-1) sensor. *Communications in Soil Science and Plant Analysis*. 39: 19-20. pp. 2795-2811.

Bouaziz M., Matschullat J. R., Gloaguen R. 2011. Improved remote sensing detection of soil salinity from a semi-arid climate in Northeast Brazil. *Comptes Rendus Geoscience*. 343. (795-803). <https://doi.org/10.1016/j.crte.2011.09.003>.

Coimbra O. R. N., Dos Santos A. T., Alípio R. O., Moreira L. C., Soares L. G. 2017. Hyperspectral remote sensing for detecting soil salinization using ProSpec TIR-VS aerial imagery and sensor simulation. *Remote Sens*. 9 (1), 42. <https://doi.org/10.3390/rs9010042>.

Durbach I. N., Algorta S., Kabongo D. K., Katsikopoulos K. V., Simsek ö. 2020. Fast and frugal heuristics for portfolio decisions with positive project interactions. *Decision support systems*. 138: 113399. <https://doi.org/10.1016/j.dss.2020.113399>.

Finger R. Scott M. S., Benni N. L. and Walter A. 2019. Precision Farming at the nexus of agricultural production and the environment. *Annual Review of Resource Economics*. 1:313-335.

Furby S. L., Wallace J. F., Caccetta P., Wheaton G.A. 1995. Detecting and monitoring salt affected land: A report from the LWRRDC project detecting and monitoring changes in land condition through time using remotely sensed data. CSIRO, Division Mathematics & Statistics. Western Australia.

Gadzinski G., Castello A. 2020. Fast and frugal heuristics augmented: when machine learning quantifies bayesian uncertainty. *Journal of behavioral and experimental finance*. 26: 100293. [10.1016/j.jbef.2020.100293](https://doi.org/10.1016/j.jbef.2020.100293).

Hamzeh S., Naseri A. A., Kazem A. S., Bartholomeus H. & Herold M. 2016. Assessing the accuracy of hyperspectral and multispectral satellite imagery for categorical and quantitative mapping of salinity stress in sugarcane fields. *International Journal of Applied Earth Observation and Geoinformation*. 52: 412-421.

Hughenoltz C. H., Moorman B. J., Riddelland K., Whitehead K. 2012. Small unmanned aircraft systems for remote sensing and earth science research. *Eos, Transactions of the American Geophysical Union*, 93 (25), 236. <https://doi.org/10.1029/2012EO250005>

Islam A. K. and Al-Mulla Y. 2019. Unmanned aerial vehicle in the machine learning environment. *Procedia Computer Science*. 160: Pp. 46-53. <https://doi.org/10.1016/j.procs.2019.09.442Get>.

Kaveri E., Chakravarthy T., Arivoli P. V. 2016. Feed forward with back propagation (ffbp) classification for find melanocytes in the skin. Recent advances in big data analysis (ABDA). ISSN: 0976-3104

Klemas V. V. 2015. Coastal and environmental remote sensing from unmanned aerial vehicles: An Overview. *J. of Coastal Research*, 31(5):1260-1267. <https://doi.org/10.2112/JCOASTRES-D-15-00005.1>.

Mulla, D.J. 2013. Twenty-five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. *Biosyst. Eng.* 114. Pp. 358-371.

NASA, 2013. National Aeronautics and Space Administration. Landsat 7 Science data user's handbook. Consultado el 29 de agosto del 2020. <http://landsathandbook.gsfc.nasa.gov>

Oñate M. M. 2015. Los drones y sus aplicaciones en la ingeniería civil. Capítulo 3: Tipología de aeronaves pilotadas por control remoto. USOL. - Unmanned solutions.

Phillips N. D, Neth H., Woike J. K., Gaissmaier W. 2017b. FFTrees: A toolbox to create, visualize, and evaluate fast-and-frugal decision trees. *Judgment and Decision Making*. 12: 4. pp. 344–368.

Phillips, N. D., Neth, H., Woike, J. K., & Gaissmaier, W. 2017a. FFTrees: A toolbox to create, visualize and evaluate fast-and-frugal decision trees. *Open Science Framework*. Retrieved from [osf.io/m726x](https://osf.io/m726x).

Pulido M. L., González L. M., Wiegand J. C., Infante R. J. & Delgado, J. 2010. Monitoreo de la salinidad mediante sensores remotos. *Terra Latinoam.* 28:1.

Ramos T. B. Castanheira N., Oliveira A. R., Paz A. M., Darouich H., Simionesei L., Farzaman M. & Goncalvez M. C. 2020. Soil salinity assessment using vegetation indices derived from Sentinel-2 multispectral data. application to Lezíria Grande, Portugal. *Agricultural Water Management*. 241: 106387.

Rhyman P.P., Norizah K., Hamdan O., Faridah I. H., Zulfa A. W. 2020. Integration of normalised different vegetation index and Soil-Adjusted Vegetation Index for mangrove vegetation delineation. *Remote sensing applications: Society and environment*. 17: 100280.

Richards, L. A. 1982. Suelos Salinos y Sódicos. Personal del Laboratorio de Salinidad de los Estados Unidos de América. *Manual de Agricultura No. 60*. p. 172.

Romero T.C. Nortesa P. A., Alarcón J. J., Johannes J., Huninkb E., Parra M., Contreras S., Drooger P., Nicolás E. .2016. Effects of saline reclaimed waters and deficit irrigation on Citrus physiology assessed by UAV remote

sensing. *Agricultural Water Management*. 183: 31. Pp. 60-66. DOI: 10.1016/j.agwat.2016.09.014.

Sacristan F. R. 2006. La tecnología al servicio del medio ambiente. *Rev Fac Nac. Salud Pública*. 24: 1.

Shaw R. R.M., William L. A. P., Chadwick D. R., Jones D. L. 2016. Characterizing the within-field scale spatial variation of nitrogen in a grassland soil to inform the efficient design of in-situ nitrogen sensor networks for precision agriculture. *Agriculture, Ecosystems & Environment*. 230, Pp. 294-306.

Statgraphics, Neural network classifier. Consultado el 12 de agosto de 2020. [Classifier neuralclassifier.sgp](#)

Taghizadeh M. R., Schmitdt K., Toomanian N., Heung B., Behrens T., Mosavi A., Band S. S., Amirian C. A., Fathabadi A. & Scholten T. 2021. Improving the spatial prediction of soil salinity in arid regions using wavelet transformation and support vector regression models. *Geoderma* 383: 114793.

Torres J. A. I. 2018. Deep learnig. Introducción practicas con Keras (primera parte). Ed. What this space. ISBN 978-1-687-47399-8

Wang F., F. Nie, Li Z., Yu W., Ren F. 2020. A linear multivariate binary decision tree classifier based on K-means splitting. *Pattern Recognition*. 107: 107521.

Wikipedia. Redes neuronales. Consultado el 12 de septiembre de 2020. [https://es.wikipedia.org/wiki/Red\\_neuronal\\_artificial](https://es.wikipedia.org/wiki/Red_neuronal_artificial)

Yuste M. R., Vargas V. N. y Moya H. J. 2013. Teledetección ambiental de alta resolución mediante aplicación de vehículos aéreos no tripulados. Congreso forestal español. Ed. Sociedad española de ciencias forestales. ISBN: 978-84-937964-9-5.

Zewdu S, Suryabhagavan K. V., Balakrishnan M. 2017. Geo-spatial approach for soil salinity mapping in sego irrigation farm, South Ethiopia J. *Saudi Soc. Agric. Sci.* 16 (1), pp. 16-24. <https://doi.org/10.1016/j.jssas.2014.12.003>.

## **CONCLUSIONES GENERALES**

Este trabajo se encontró que el catión más dominante es el sodio y el anión más dominante es el sulfato. El predio tiene problemas de ensalitramiento debido a las condiciones naturales del terreno es salino sódico, y a los valores elevados de RAS y PSI encontrados. La zona de estudio del ex lago de Texcoco presenta suelos de textura arcillosos-limosos y arcillosos. Este trabajo de tesis demostró que es posible clasificar la salinidad del suelo con aceptable precisión a partir de las imágenes capturadas con vehículos aéreos no tripulados. Los modelos de redes neuronales mostraron una mejor precisión en la estimación de los tres indicadores de salinidad utilizados en este estudio (PSI, RAS, Sodio) con respecto a los árboles de decisión. La simplicidad del modelo propuesto y el grado de precisión obtenido, lo convierten en una herramienta prometedora para su uso en la predicción de la salinidad del suelo. El presente trabajo se puede tomar como referencia para futuros desarrollos de investigaciones con el empleo de sensores y vehículos aéreos no tripulados usando técnicas de teledetección en el monitoreo de suelos afectados por la salinidad.