



**UNIVERSIDAD AGRARIA DEL ECUADOR
FACULTAD DE CIENCIAS AGRARIAS
CARRERA DE INGENIERÍA AGRONÓMICA**

**DETERMINACIÓN DE LA SALINIDAD DE SUELOS
ARROCEROS MEDIANTE EL USO DE SENSORES
REMOTOS EN EL CANTÓN DAULE - GUAYAS
INVESTIGACIÓN DESCRIPTIVA**

Trabajo de titulación presentado como requisito para la
obtención del título de
INGENIERO AGRÓNOMO

**AUTOR
MANRIQUE CENTENO JOE RENE**

**TUTOR
ING. GARCÍA ORTEGA YOANSY MSC.**

GUAYAQUIL – ECUADOR

2021



UNIVERSIDAD AGRARIA DEL ECUADOR
FACULTAD DE CIENCIAS AGRARIAS
CARRERA DE INGENIERÍA AGRONÓMICA

APROBACIÓN DEL TUTOR

Yo, GARCÍA ORTEGA YOANSY, docente de la Universidad Agraria del Ecuador, en mi calidad de Tutor, certifico que el presente trabajo de titulación: DETERMINACIÓN DE LA SALINIDAD DE SUELOS ARROCEROS MEDIANTE EL USO DE SENSORES REMOTOS EN EL CANTON DAULE - GUAYAS, realizado por el estudiante MANRIQUE CENTENO JOE RENE; con cédula de identidad N° 0930898325 de la carrera INGENIERIA AGRONOMICA, Unidad Académica Guayaquil, ha sido orientado y revisado durante su ejecución; y cumple con los requisitos técnicos exigidos por la Universidad Agraria del Ecuador; por lo tanto se aprueba la presentación del mismo.

Atentamente,

Ing. García Ortega Yoansy M.Sc.
Director de tesis

Guayaquil, 19 de julio del 2021



**UNIVERSIDAD AGRARIA DEL ECUADOR
FACULTAD DE CIENCIAS AGRARIAS
CARRERA DE INGENIERÍA AGRONÓMICA**

APROBACIÓN DEL TRIBUNAL DE SUSTENTACIÓN

Los abajo firmantes, docentes designados por el H. Consejo Directivo como miembros del Tribunal de Sustentación, aprobamos la defensa del trabajo de titulación: “DETERMINACIÓN DE LA SALINIDAD DE SUELOS ARROCEROS MEDIANTE EL USO DE SENSORES REMOTOS EN EL CANTON DAULE - GUAYAS”, realizado por el estudiante MANRIQUE CENTENO JOE RENE, el mismo que cumple con los requisitos exigidos por la Universidad Agraria del Ecuador.

Atentamente,

**BURGOS HERRERÍA TANNY, M.Sc.
PRESIDENTE**

**GARCÍA ORTEGA YOANSY, M.Sc.
EXAMINADOR PRINCIPAL**

**VELIZ PIGUAVE FREDDY, M.Sc.
EXAMINADOR PRINCIPAL**

Guayaquil, 18 de agosto de 2021

Dedicatoria

Dedico este trabajo a mis padres, mis hermanos,
familiares y amigos.

Agradecimiento

A mis padres por su apoyo durante la ardua tarea que fue ejecutar este trabajo.

A mi amigo Rodrigo por su tiempo y ayuda durante el desarrollo de la tesis.

Agradezco al Ing. Yoansy García por ser guía y un excelente orientador.

Autorización de Autoría Intelectual

Yo MANRIQUE CENTENO JOE RENE, en calidad de autor(a) del proyecto realizado, sobre “DETERMINACIÓN DE LA SALINIDAD DE SUELOS ARROCEROS MEDIANTE EL USO DE SENSORES REMOTOS EN EL CANTON DAULE - GUAYAS” para optar el título de INGENIERO AGRÓNOMO, por la presente autorizo a la UNIVERSIDAD AGRARIA DEL ECUADOR, hacer uso de todos los contenidos que me pertenecen o parte de los que contienen esta obra, con fines estrictamente académicos o de investigación.

Los derechos que como autor(a) me correspondan, con excepción de la presente autorización, seguirán vigentes a mi favor, de conformidad con lo establecido en los artículos 5, 6, 8; 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento.

Guayaquil, 29 de julio del 2021

MANRIQUE CENTENO JOE RENE
C.I. 0930898325

Índice general

APROBACIÓN DEL TUTOR.....	2
APROBACIÓN DEL TRIBUNAL DE SUSTENTACIÓN	3
Dedicatoria.....	4
Agradecimiento	5
Autorización de Autoría Intelectual	6
Índice general	7
Índice de tablas.....	13
índice de figuras	14
Resumen	16
Abstract.....	17
1. Introducción.....	18
1.1 Antecedentes del problema.....	18
1.2 Planteamiento y formulación del problema	19
1.2.1 Planteamiento del problema	19
1.2.2 Formulación del problema	19
1.3 Justificación de la investigación.....	20
1.4 Delimitación de la investigación	21
1.5 Objetivo general	21
1.6 Objetivos específicos.....	21
1.7 Hipótesis	21
2. Marco teórico	22
2.1 Estado del arte.....	22
2.2 Bases teóricas	24
2.2.1 Salinidad del Suelo	24

2.2.1.1. Concepto.....	24
2.2.1.2. Origen.....	26
2.2.1.3. Clasificación	28
2.2.1.4. Síntomas	28
2.2.1.5. Índices que determinan la salinidad de suelos	29
2.2.1.5.1. Conductividad eléctrica (CE)	29
2.2.1.5.2. Sales solubles totales (SST)	29
2.2.1.5.3. Porcentaje de sodio intercambiable (PSI).....	30
2.2.1.5.4. Relación de sodio adsorbido total activo (RAS)	30
2.2.1.5.5. Capacidad de Intercambio Catiónico (CIC).....	30
2.2.1.6. Características	31
2.2.1.7. Efectos en las plantas.....	32
2.2.1.7.1. Inducción de estrés hídrico.....	32
2.2.1.7.2. Toxicidad ion específica.....	32
2.2.1.7.3. Desbalance nutricional.....	32
2.2.1.7.4. Incremento de la producción de especies reactivas de oxígeno (ROS).....	33
2.2.2 Zona de Estudio – cantón Daule.....	33
2.2.2.1. Descripción de la zona	33
2.2.2.1.1. Fecha de creación.....	33
2.2.2.1.2. Nombre del GAD	33
2.2.2.1.3. Población	33
2.2.2.1.4. Rango altitudinal	33
2.2.2.1.5. División política.....	33
2.2.2.2. Producción de cultivos.....	34

2.2.2.3. Clima	35
2.2.2.4. Suelos	36
2.2.2.4.1. <i>Relieve</i>	36
2.2.2.4.2. <i>Textura</i>	36
2.2.2.4.3. <i>Geomorfología</i>	36
2.2.2.4.4. <i>Principales ordenes de suelo del sector</i>	37
2.2.2.4.4.1. Vertisoles	37
2.2.2.4.4.2. Inceptisoles	37
2.2.2.4.4.3. Entisoles	38
2.2.2.4.4.4. Alfisoles	39
2.2.2.4.5. <i>Uso de suelo</i>	40
2.2.3 Correcciones de imágenes.....	40
2.2.3.1. Preprocesamiento	40
2.2.3.2.1. <i>Generalidades</i>	40
2.2.3.2.2. <i>Corrección geométrica</i>	41
2.2.3.2.3. <i>Corrección radiométrica</i>	41
2.2.3.2.4. <i>Corrección atmosférica</i>	41
2.2.4 Índices de Vegetación (VI).....	42
2.2.4.1. Concepto.....	42
2.2.4.2. Relación de los índices de vegetación con la salinidad	43
2.2.4.3. Índices relacionados con la dinámica de la salinidad	43
2.2.4.3.1. <i>Índice de vegetación de diferencia normalizada (NDVI)</i>	43
2.2.4.3.2. <i>Índice de vegetación ajustado al suelo (SAVI)</i>	44
2.2.4.3.3. <i>Índice de salinidad vegetación – suelo (VSSI)</i>	45
2.2.4.3.4. <i>Índice de vegetación mejorado (EVI)</i>	45

2.2.4.3.5. Índice de vegetación resistente a la atmósfera (ARVI)	45
2.2.4.3.6. Índice de salinidad (SI)	46
2.2.4.3.7. Índice de brillo (BI)	47
2.2.4.3.8. Índice de salinidad de diferencia normalizada (NDSI)	47
2.3 Marco legal	48
3. Materiales y métodos	50
3.1 Enfoque de la investigación	50
3.1.1 Tipo de investigación	50
3.1.2 Diseño de investigación	50
3.2 Metodología	50
3.2.1 Variables	50
3.2.1.1. Variable dependiente	50
3.2.1.2. Variables independientes	50
3.2.2 Diseño experimental	51
3.2.3 Recolección de datos	52
3.2.3.1. Recursos	52
3.2.3.2. Métodos y técnicas	52
3.2.3.2.1. Muestreo del sector	52
3.2.3.2.2. Análisis de laboratorio	52
3.2.3.2.3. Elaboración de mapa de salinidad	53
3.2.3.2.4. Obtención de imágenes satelitales	54
3.2.3.2.5. Corrección y preprocesamiento de imágenes	55
3.2.3.2.6. Cálculo de índices de vegetación	55
3.2.3.2.7. Selección completa de subconjunto (Full Subset Selection)	56
3.2.3.2.8. Construcción de modelos de aprendizaje automatizado	57

3.2.3.2.8.1. Regresión lineal (RL)	57
3.2.3.2.8.2. Perceptrón multicapa de retropropagación (MLP)	57
3.2.3.2.8.3. Máquinas de vectores de soporte (SVM)	58
3.2.3.2.8.4. Bosques aleatorios (RF)	60
3.2.3.2.9. <i>Diagrama de flujo para la determinación de salinidad mediante sensores remotos</i>	61
3.2.3.2.10. <i>Índices de vegetación y bandas satelitales</i>	62
3.2.4 Análisis estadístico	64
4. Resultados	66
4.1 Elaboración de una línea base de los suelos arroceros mediante el uso de SIG y teledetección.	66
4.2 Detalle de los niveles la salinidad en las zonas arroceras del cantón Daule.....	73
4.2.1 Interpolación de datos	73
4.2.2 Resultados de modelos de aprendizaje automatizado	78
4.2.2.1 Regresión lineal	78
4.2.2.2. Perceptrón multicapa de retropropagación.....	80
4.2.2.3. Máquinas de vectores de soporte	82
4.2.2.4. Bosques aleatorios	84
4.2.3 Evaluación de modelos de aprendizaje automatizado	86
4.3 Establecimiento de recomendaciones para un buen uso del recurso suelo en la zona de estudio.	88
5. Discusión	90
6. Conclusiones	94
7. Recomendaciones	96

8. Bibliografía.....	99
9. Anexos.....	108
Anexo 1. Zona de estudio – División parroquial.....	108
Anexo 2. Zonas arroceras.....	109
Anexo 3. Puntos de muestreo	110
Anexo 4. Combinaciones óptimas de VI.....	111
Anexo 5. Toma de muestras de zona de estudio.....	112
Anexo 6. Toma de muestras de zona de estudio.....	112
Anexo 7. Fundas de muestras etiquetadas.....	112
Anexo 8. Visita y asesoramiento de tutor en la zona de estudio.....	113
Anexo 9. Procesado de muestras.....	113
Anexo 10. Secado y triturado de muestras de suelo.....	113
Anexo 11. Total de muestras tamizadas y molidas.....	114
Anexo 12. Mezclado de muestras.....	114
Anexo 13. Envasado e inicio de metodología de pasta saturada.....	114
Anexo 14. Centrifugado de muestras para medición de CE.....	114
Anexo 15. Ingreso de datos de CE para posterior procesado en software SIG.....	115

Índice de tablas

Tabla 1. Clasificación de suelos salinos de acuerdo a la conductividad eléctrica	28
Tabla 2. Diagnostico visual de suelos salinos.....	29
Tabla 3. Características de suelos salinos	31
Tabla 4. Producción agropecuaria del cantón Daule.	35
Tabla 5. Índices de salinidad y vegetación	62
Tabla 6. Parámetros de bandas Sentinel 2A.....	64
Tabla 7. Conductividad eléctrica de muestras de zona de estudio.....	67
Tabla 8. Datos de Interpolación lineal.....	70
Tabla 9. Datos de Interpolación exponencial.....	71
Tabla 10. Datos de Interpolación esférica.....	71
Tabla 11. Datos de Interpolación gaussiana	71
Tabla 12. Datos de Interpolación circular.....	72
Tabla 13. Características estadísticas de interpolaciones.....	73

Índice de figuras

Figura 1. Ordenes de suelo del cantón Daule	39
Figura 2. Uso de suelo del cantón Daule.....	41
Figura 3. Estructura del perceptrón multicapa de retropropagación.....	59
Figura 4. Estructura de los vectores de soporte.....	60
Figura 5. Estructura del clasificador “bosques aleatorios” (RF).....	61
Figura 6. Diagrama de flujo de la investigación	61
Figura 7. Interpolación con semivariograma exponencial.....	68
Figura 8. Interpolación con semivariograma esférico	68
Figura 9. Interpolación con semivariograma gaussiano	69
Figura 10. Interpolación con semivariograma circular	69
Figura 11. Interpolación con semivariograma lineal	70
Figura 12. Evaluador de correlación (R cuadrado).....	74
Figura 13. Selección completa de subconjunto para R cuadrado ajustado	75
Figura 14. Selección completa de subconjunto para R cuadrado	76
Figura 15. Selección completa de subconjunto para Mallows's Cp	76
Figura 16. Selección completa de subconjunto para suma residual de cuadrados	77
Figura 17. Selección completa de subconjunto para Criterio de información bayesiano	77
Figura 18. Modelo de regresión lineal para conductividad eléctrica.....	78
Figura 19. Visualización de errores clasificados del modelo de regresión lineal. .	79
Figura 20. Diseño de la red, con 3 capas ocultas.....	80
Figura 21. Datos estadísticos del modelo de MLP.	81
Figura 22. Visualización de errores clasificados del modelo de MLP	81

Figura 23. Modelo del algoritmo de SVM.	82
Figura 24. Datos estadísticos del modelo de SVM.	83
Figura 25. Visualización de errores clasificados del modelo de SVM.	83
Figura 26. Datos estadísticos del modelo de RF.	84
Figura 27. Visualización de errores clasificados del modelo de RF.	85
Figura 28. Criterios estadísticos para selección de modelo.	86
Figura 29. Salinidad de la zona de estudio.	87

Resumen

El sector de Daule es el principal sector arrocerero de Ecuador, y posee más de 20.000 hectáreas de este cultivo. Sin embargo, el sector presenta limitantes productivas, una limitante productiva es el factor suelo, específicamente, salinización, la cual presenta una limitada cuantificación a gran escala. La presente investigación tuvo como objetivo evaluar la dinámica de la salinidad de suelos mediante el uso de sensores remotos (imágenes satelitales) y 4 modelos de aprendizaje automatizado (regresión lineal, modelo de perceptrón multicapa de retropropagación, algoritmo de máquina de vectores de soporte y clasificador de bosques aleatorios). Para el levantamiento de línea base se realizó un muestreo de la zona, análisis de CE en laboratorio y una interpolación de estos datos usando la metodología de Kriging ordinario con un semivariograma Gaussiano para elaborar un mapa de salinidad, el cual explica las condiciones reales de salinidad del sector, detallando que alrededor del 30% del sector (5800 hectáreas) presentan una CE mayor a 2 mS/cm. Para la estimación de salinidad del sector mediante sensores remotos, el resultado de las SVM fue el algoritmo que mejor ajuste de datos ($ADJR^2=0,82$) y menor error ($MAE=0,31$) tuvo, usando una combinación de la selección del subconjunto de datos, para correlacionar la información de los índices de vegetación calculados, con las muestras de suelo de la zona de estudio.

Palabras Clave: Aprendizaje Automatizado, Imágenes Satelitales, Mapa de Suelo, Salinidad del Suelo, Sistema de Información Geográfica.

Abstract

Daule is the main rice producer in Ecuador, and has more than 20,000 hectares of this crop. However, the sector presents productive limitations, a productive limitation is the soil factor, specifically, salinization, which is difficult to quantify at a large scale. The present research aimed to evaluate the dynamics of soil salinity through the use of remote sensing (satellite images) and 4 machine learning models (linear regression, backpropagation multilayer perceptron model, support vector machine algorithm and random forest classifier). For the baseline survey, soil sampling of the area was carried out, an EC analysis of the samples in the laboratory was made, and an interpolation of the aforementioned data was done using the ordinary Kriging methodology with a Gaussian semivariogram to develop a soil salinity map, which explains soil real salinity condition of the study area. This map displays that around 30% of the sector (5800 hectares) has an EC greater than 2 mS / cm. For the estimation of soil salinity in the sector using remote sensing, the result of the SVMs was the algorithm with the best data fit (ADJR2 = 0.82) and the lowest error (MAE = 0.31). Using a combination of the full subset selection of data, to correlate the information of the calculated vegetation indices, with the soil samples of the study area.

Key Words: GIS, Machine Learning, Satellite Images, Soil Map, Soil Salinity.

1. Introducción

1.1 Antecedentes del problema

Los suelos salinos son suelos que poseen una cantidad suficiente de sales neutras solubles o iones de sodio que causan efectos adversos en el desarrollo normal y productivo de las plantas, estos suelos están presentes especialmente en zonas con condiciones de clima árido y semiárido, sin embargo, cualquier zona climática es susceptible a este proceso degradativo (Organización de las Naciones Unidas para la Alimentación y la Agricultura [FAO], 1988). La presencia de sales en el suelo afecta absorción de nutrientes de las plantas, reduce la actividad microbiana del suelo, y provoca estrés hídrico en los cultivos debido a la reducción del potencial osmótico del suelo (FAO, 1988). La reducción de productividad causada por la salinización puede llegar hasta a un 50% (Jaramillo y Arahana, 2015). La salinidad del suelo es una limitante del suelo que está presente en alrededor del 10% del área arable total a nivel mundial, es decir un total estimado de mil millones de hectáreas y un aproximado entre 25% y 30% de terrenos irrigados están afectados por procesos de salinización, volviéndose improductivos comercialmente (Shahid, Zaman y Heng, 2018).

A nivel regional, en Ecuador, la salinidad de los suelos se encuentra presente de manera natural, debido a la meteorización de rocas volcánicas (Jaramillo y Arahana, 2015), y antrópica, debido a las prácticas agrícolas deficientes que tienen efectos negativos en el suelo. Los cultivos son afectados seriamente, presentando una cantidad de follaje reducida, fitotoxicidad, crecimiento y desarrollo reducido, como resultado de los demás factores mencionados, una productividad reducida, afectando seriamente las actividades económicas del país (Navarrete, Alava, Villamar y Chumo, 2017).

1.2 Planteamiento y formulación del problema

1.2.1 Planteamiento del problema

El cultivo de arroz es considerado como una planta glicófito, es decir muy sensible a las sales presentes en el agua y suelo, por lo que la producción de este cultivo se ve afectado seriamente cuando existen niveles de salinidad elevados (Reddy, Kim, Yoon, Kim y Kwon, 2017).

Intriago (2015) menciona que las condiciones de suelo sembradas bajo el cultivo de arroz conducen a procesos de oxidación y reducción (Redox), por lo que las condiciones de suelo inicial y final sean muy variables. Por ejemplo, ciertos procesos pedogenéticos como compactación, incremento del pH, gleyzación, reducción del drenaje, salinidad y sodicidad, aparecen y se hacen más evidentes. La importancia de caracterizar y cuantificar los problemas que los suelos de la zona presentan (salinización, en el caso de la presente investigación) es trascendental, debido a la importancia económica que este cultivo tiene en la economía del cantón Daule.

La presencia de salinidad en el sector es evidente debido a las prácticas agrícolas incorrectas de fertilización, riego y de drenaje, sin embargo, un monitoreo y muestreo que indique la presencia y el nivel de salinidad no se ha llevado a cabo a gran escala, debido a factores como poca practicidad, recursos financieros, falta de personal, entre otros. Por lo que se tiene que tomar otra perspectiva y metodología para llevar a cabo una cuantificación de los procesos limitantes del suelo.

1.2.2 Formulación del problema

¿Con el uso de sensores remotos se podrá detectar la salinidad presente en los suelos del sector de Daule? ¿La dinámica de la salinidad de los suelos

determinada mediante teledetección representa las condiciones reales de salinidad del sector?

1.3 Justificación de la investigación

La presente investigación surge como respuesta a la necesidad de tener una metodología diferente que permita la cuantificación de la salinización presente en los suelos del sector de Daule de una manera más eficiente en el uso de recursos sin tener que recurrir a metodologías de medición tradicionales, como muestreos extensivos, que suelen ser costosos y ocupan una gran cantidad de recursos, como tiempo y personal, poca practicidad, factor humano, factor monetario, entre otras.

Un paso primordial para la mitigación de esta limitante, es la identificación y clasificación de las áreas con presencia de salinidad, todo esto para poder realizar agricultura de precisión y una correcta planificación agrícola. El uso de teledetección y sensores remotos cada vez se han vuelto más eficientes y económicos, por ello su uso ha crecido en los últimos años. Se usan herramientas contemporáneas, como modelos estadísticos, correcciones de imágenes, cálculo de índices de vegetación para poder desarrollar mediante el uso de SIG mapas que demuestren características de interés, en el caso de la presente investigación, la salinidad.

La metodología que se usará ha sido correctamente usada en diversas publicaciones de impacto en diversos países, sin embargo, esta metodología aún no ha sido usada en Ecuador, por lo que la elaboración de un mapa que indique la dinámica de la salinidad permite tener información de la condición del suelo de manera rápida, eficiente y de alta precisión, sin el uso elevado de recursos. Con la información de este mapa se buscará saber la condición de los procesos de

salinidad del suelo, con esta información se puede elaborar recomendaciones y soluciones a la presencia de estos procesos nocivos para la productividad de los cultivos.

1.4 Delimitación de la investigación

- **Espacio:** Cantón Daule, provincia del Guayas, Ecuador, Este posee una superficie de 466 Km² y un perímetro de 259 Km (Ver anexo 1). Las zonas arroceras, las zonas de donde se tomaron las muestras, tienen una superficie total de 187,77 Km² (Ver anexo 2). Coordenadas UTM: 9793644 – 613076.
- **Tiempo:** La investigación duró un aproximado de 10 meses, desde octubre de 2020 hasta julio de 2021.
- **Población:** Agricultores y productores del cantón Daule.

1.5 Objetivo general

Evaluar la dinámica de la salinidad del suelo mediante teledetección en el cantón Daule para realizar un mapa de salinidad de suelos.

1.6 Objetivos específicos

- Elaborar una línea base de los suelos arroceros mediante el uso de SIG y teledetección.
- Estimar los niveles la salinidad en las zonas arroceras del cantón Daule.
- Establecer recomendaciones para un buen uso del recurso suelo en la zona de estudio.

1.7 Hipótesis

Los resultados del mapa de salinidad calculados mediante teledetección reflejan con precisión las condiciones de salinidad reales del suelo del cantón Daule.

2. Marco teórico

2.1 Estado del arte

Para poder desarrollar un manejo sostenible de suelos afectados por procesos de salinidad y controlar la expansión de este nocivo proceso, la FAO en conjunto con GSP (Global Soil Partnership) están en el desarrollo de una iniciativa titulada, “Mapa de Salinidad de Suelos Global (Global Soil Salinity Map - GSSmap), que será de uso mundial y tendrá información a nivel nacional de los suelos de cada país que se encuentran afectados por procesos de salinidad y se espera realizar un adecuado monitoreo a largo plazo de estos suelos. Los objetivos de esta iniciativa es desarrollar mapas a nivel de país, sobre los suelos afectados por salinidad (SAS), levantar una línea base sobre su estado para su monitoreo y posterior manejo para su corrección. Para este proyecto se usan imágenes satelitales multiespectrales de los satélites Landsat, Sentinel y MODIS MODD009GA V6, mediante el uso de software de sistemas de información geográfica se realizan las respectivas correcciones de las imágenes y depuramiento de información, resultando en mapas de salinidad a nivel regional (FAO, 2020).

El uso de teledetección y sensores remotos para determinar el nivel de salinidad en el suelo ha sido exitoso en diferentes regiones a nivel mundial. Asfaw, Suryabhagavan y Argaw (2018) menciona que usando un manejo integrado de teledetección y métodos estadísticos se puede determinar los niveles de conductividad eléctrica y desarrollar modelos predictivos de salinidad de suelos. La metodología mencionada fue aplicada en una granja de caña de azúcar de 8000 hectáreas en la región de Wonji en Etiopía, donde se usaron imágenes satelitales de Landsat 8 OLI. La investigación resultó en un mapeo

extensivo de los niveles de salinidad del sector, y además se determinó la intensidad de los procesos, dando a conocer que el uso de la teledetección es una herramienta efectiva para conocer procesos degradativos del suelo.

De acuerdo con Azabdaftari y Sunar (2016), en un estudio realizado en la región de Seyhan – Turquía, usando imágenes del satélite Landsat 7 – EMT+ de 4 diferentes fechas, pudieron realizar un mapa de salinidad de suelos de la zona mencionada. Las imágenes satelitales fueron procesadas usando software de SIG, y se detectaron también diversos índices que muestran la presencia de procesos de salinidad, como: NDSI (Índice de salinidad normalizado diferenciado), BI (Índice de Brillo), SI (Índice de Salinidad) y NDVI (Índice de Vegetación de Diferencia Normalizada), entre otros. Se basaron en datos de conductividad eléctrica del suelo del año 2010 para la correlación de datos. Se realizaron los debidos análisis estadísticos para la correlación de datos, resultado en recomendación tales como: Usar información de suelo que este más cercana a la fecha de las imágenes satelitales para tener una mayor correlación de los datos reales del suelo y el mapa de salinidad. Por lo que el uso de teledetección para mapas de suelos es dependiente de las fechas de toma de muestras y de las imágenes satelitales a usar.

Elhag (2016) menciona que en la investigación realizada en Wadi Al Dawasir- Arabia Saudita, lograron diferenciar suelos con presencia de procesos de salinización de los que no lo tienen, mediante el uso de imágenes del satélite Landsat 8 usando diversas técnicas de clasificación y depuración de imágenes, fórmulas matemáticas para el cálculo de bandas e índices de salinidad. También se tomaron 150 muestras de suelo y se evaluó la conductividad eléctrica de estas para correlacionar la información de las imágenes satelitales y la condición real

del suelo. Se detalla en la investigación que la fórmula de imagen infrarroja multiplicado por la banda roja y dividido para la banda verde resulta en los datos más correlacionados con el muestreo del terreno realizado. Indicando la importancia de realizar diferentes fórmulas para el cálculo de índice de salinidad, que más se ajuste a las condiciones del medio.

En la investigación realizada en Iraq central por Wu et al. (2015) detalla que para la determinación de los índices de salinidad del suelo del sector se usaron imágenes satelitales multi temporales y multiespectrales desde el año 1983 – 2012, lo cual es una metodología innovativa y novedosa ya que se analizan las imágenes con mayor detalle, resultando en información más precisa y exacta. También se realizó muestreo de suelos durante el periodo 2011 – 2012 para poder correlacionar las imágenes satelitales con la información real del suelo. En la investigación se determinaron variables como Índice de salinidad e Índice de brillo. Las imágenes resultantes luego de ser procesadas tuvieron una precisión del 82,57% comparadas con las condiciones reales del terreno. Concluyendo que las metodologías de teledetección pueden ser usadas a gran escala para determinar condiciones de suelo como la salinidad, sin un excesivo muestreo y con un menor uso de recursos.

2.2 Bases teóricas

2.2.1 Salinidad del Suelo

2.2.1.1. Concepto

Lazara et al. (2007) Afirma que “Salinización es el resultado de procesos naturales y/o antrópicos presentes en todos los suelos que conducen en menor o mayor grado a una acumulación de sales, que pueden afectar la fertilidad del suelo”. Por su parte Piedra y Cepero (2013) comenta que el termino salinidad

acuña a la presencia en el medio suelo una concentración elevada de sales solubles que por sus efectos fitotóxicos perjudican al cultivo e disminuyen el potencial osmótico del suelo. La sal más común presente en el proceso de salinización es el cloruro de sodio (NaCl), sin embargo, los suelos salinos pueden tener distintas combinaciones de sales, como los cloruros y sulfatos de Sodio, Calcio, Magnesio, entre otros. Los iones más importantes que se encuentran presentes en el medio suelo-agua, en orden de importancia son el Sodio (Na^+), Cloro (Cl^-), Calcio (Ca^{2+}), Sulfato (SO_4^{2-}), Carbonato (CO_3^{2-}), Potasio (K^+), Magnesio (Mg^{2+}), Nitrato (NO_3^-) (Artiola, Walworth, Musil y Crimmins, 2019).

Otro factor importante a mencionar es la presencia de sodicidad del suelo, el cual Piedra y Cepero (2013) afirma:

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 (p.32).

La concentración elevada de iones de sodio en el suelo provoca un desbalance en la proporción de cationes monovalentes y cationes divalentes, el cual es medido por el porcentaje de sodio intercambiable (PSI) (Artiola et al., 2019). Esta elevada salinización y sodicidad no solo tiene efectos negativos en el cultivo sino también en la estructura física del suelo, produciendo cambios tales como reducción en la porosidad y permeabilidad del suelo, lo cual incrementa aún más las limitantes productivas del medio (Piedra y Cepero, 2013). También Artiola et al. (2019) indica que la presencia de salinidad en el suelo puede tener efectos profundos en movimiento de agua, actividad microbiana y diversidad de plantas en el suelo.

2.2.1.2. Origen

La presencia de un exceso de sales en la superficie del suelo es lo que caracteriza a los suelos salinos, sin embargo, una incógnita que se presenta es el origen de estos suelos, debido a que puede haber varias causas que los ocasionan. La principal fuente de sales de los suelos salinos es debido al mineral primario (roca madre) que está expuesto en la superficie del suelo. Durante procesos de meteorización química que incluye, hidrólisis, hidratación, reducción, oxidación, entre otros procesos químicos de meteorización más, las sales se desprenden de la roca madre y se solubilizan, estas sales son transportadas por los flujos de agua subterráneos y se concentran menos en zonas donde la humedad es alta y más donde las zonas áridas dominan (FAO, 1988).

Las sales se acumulan y se encuentran depositadas en perfiles bajos del suelo (especialmente en zonas de pluviometría reducida). La profundidad a la que las sales se depositan dependerá de la capacidad de retención de agua del suelo, intensidad de lluvias y humedad. Muchas veces si las sales se encuentran a profundidades mayores a 1,50 metros no suele haber problemas de salinidad de suelos, sin embargo, las sales presentes en el suelo pueden llegar a ser distribuidas por factores antrópicos hacia la superficie, y luego comenzar a producir efectos nocivos en el cultivo (FAO, 1988).

Cuando agua de riego es drenada, esta retorna a los cuerpos de agua más cercanos, subterráneos y superficiales y ocurre una recarga de agua, las sales más solubles (NaCl específicamente) son removidas y transportadas desde su sitio de origen, las cuales serán usada de nuevo como agua de riego y consecuentemente ocasionará una mayor concentración de sales en el suelo donde se regará, y así comienza un proceso degradativo del medio suelo. A pesar

que las concentraciones de sales originales eran mínimas, debido a la carga y recarga de los cuerpos afluentes con sales el problema se incrementa y se vuelve evidente (Bresler, McNeal y Carter, 2012).

El uso de agua con alta concentración de sales es un factor clave en el desarrollo de suelos salinos, principalmente por la explotación de pozos de agua cercanos a la costa de los océanos que por la filtración de agua salada ha ingresado a los pozos (Mateo-Sagasta y Burke, 2011) también por el mal drenaje de suelos que no permite la escorrentía del agua rica en sales que se alojan en una zona en específico (Aragüés, 2008).

Otro factor importante para la aparición de salinidad es la falta de criterio durante prácticas culturales, en este caso, aplicación de un riego excesivo en condiciones de drenaje deficiente. El agua de riego aplicada es tan excesiva que llega hasta la capa impermeable del suelo (en la cual hay grandes cantidades de sales), al tener un drenaje deficiente el agua no se retira de manera rápida y provoca la solubilización de las sales, al evaporarse esta agua o drenarse lentamente provoca que las sales se transloquen desde el horizonte impermeable hasta la superficie provocando el incremento de la salinidad (Aragüés, 2008).

La aplicación de fertilizantes nitrogenados en zonas áridas, en conjunto con sistemas de riego con eficiencia menor a un 50% provoca que la acumulación de sales en uno o dos ciclos de cultivo resulte en colapsos en la producción de la cosecha de hortalizas y frutales. La pérdida de nitratos por lixiviación y otros fenómenos de movimiento de solutos en el agua hacia el suelo causan procesos de sodificación y salinización (González, Mendoza, González, Etchevers, y Vázquez, 2011).

2.2.1.3. Clasificación

De acuerdo con Adhikari (2008) los suelos salinos pueden clasificarse en 2 tipos, estos son:

- Suelos afectados por sales de sodio neutras (Principalmente cloruro de sodio y sulfato de sodio), es decir suelos salinos.
- Suelos afectados por sales de sodio capaces de hidrólisis alcalina (Sales como bicarbonatos de sodio, carbonato de sodio, meta silicato de sodio) o suelos sódicos.

Sin embargo, ambas clasificaciones pueden ocurrir en un mismo suelo, y se refiere a ellos como suelos sódico-salinos. Los suelos salinos pueden clasificarse de acuerdo a la conductividad eléctrica que estos presentan, detallado en la siguiente tabla:

Tabla 1. Clasificación de suelos salinos de acuerdo a la conductividad eléctrica

Clase de Suelo Salino	Conductividad (dS/m)	Efecto en el cultivo
No Salino	0 - 2	Efectos negligibles.
Ligeramente salino	2 - 4	Cultivos sensibles afectados.
Moderadamente salino	4 - 8	Muchos cultivos afectados.
Salino	8 - 16	Solo los cultivos resistentes producen.
Muy salino	> 16	Muy pocos cultivos resistentes producen.

FAO, 1988.

2.2.1.4. Síntomas

Sonon, Saha y Kissel (2015) menciona que los diversos tipos de suelos salinos tienen características particulares que facilitan su identificación visual, y a través de estas características se puede saber el tipo de salinidad que se encuentra presente, los síntomas se detallan a continuación:

Tabla 2. Diagnostico visual de suelos salinos

Tipo de suelo salino	Síntomas
Suelos Salinos	Costras blancas en la superficie del suelo, plantas con estrés hídrico, punta de hoja quemadas.
Suelos Sódicos	Mal drenaje de suelo, residuos oscuros polvorientos en la superficie del suelo
Suelos Salino-Sódicos Sonon et al, 2015	Suelos grises, plantas con estrés hídrico

2.2.1.5. Índices que determinan la salinidad de suelos

2.2.1.5.1. Conductividad eléctrica (CE)

La conductividad eléctrica mide la capacidad del suelo de conducir electricidad, esta se mide en decisiemens por metro (dS/m) a 25°C (Sonon et al., 2015). Esta medición está basada en el principio que la cantidad de corriente eléctrica transmitida por una solución es mayor mientras mayor concentración de sales posee la solución (Bresler et al., 2012). De acuerdo con Sonon et al. (2015), un suelo salino tiene una conductividad eléctrica de 4 dS/m o mayor, cuando se lo mide en condición de pasta de saturación. Este valor corresponde aproximadamente a 40 mili moles (mmol) de sal por litro.

2.2.1.5.2. Sales solubles totales (SST)

Se refiere al total de sales solubles presentes en una pasta de suelo saturada. Esta se expresa en partes por millón (ppm) o en miligramos por litro (mg/l). Existe una relación linear entre la CE y los SST que puede ser usada para estimar la cantidad de sales en una muestra de suelo. La proporción de SST y CE de varias soluciones con sales tiene rangos entre 550 a 700 mg/l por cada dS/m. El cloruro

de sodio (La sal más común) tiene una proporción de SST de 640 mg/l por cada dS/m. Entonces si se sabe la conductividad eléctrica, se puede determinar los SST del suelo usando la siguiente formula: $SST=CE*640$ (Sonon et al., 2015).

2.2.1.5.3. Porcentaje de sodio intercambiable (PSI)

Otro índice que indica la incidencia de salinidad y sodicidad es el porcentaje de sodio intercambiable. El PSI es la cantidad de sodio respecto a los demás cationes absorbidos, o capacidad de intercambio catiónico (CIC) (Ramírez, 2016).

Los efectos del sodio en el suelo provocan pobre movimiento de agua debido a la destrucción de la estructura del suelo y por ende baja aireación del mismo. Por definición un suelo con más de 15% de sodio intercambiable presente se lo considera como suelo sódico (Sonon et al., 2015). El PSI se determina de acuerdo al cociente entre sodio total y la capacidad intercambio catiónico, multiplicado por 100 (Ramírez, 2016).

2.2.1.5.4. Relación de sodio adsorbido total activo (RAS)

Lazara et al. (2007) menciona que RAS es “La relación entre las concentraciones activas del sodio soluble respecto a los contenidos activos totales disueltos de calcio y magnesio” (p. 7).

Ramírez (2016) afirma que:

También, existe el índice de relación de adsorción de sodio (RAS), que permite evaluar a partir del sodio, calcio y magnesio contenidos en el agua de riego (expresados en meq/l), la cantidad de sodio que quedará adsorbido en el complejo de cambio y en equilibrio con el de la solución del suelo. Este análisis permite estimar el riesgo de que un agua de riego determinada vaya a generar con el tiempo el deterioro de la estructura del suelo (p. 15-16).

2.2.1.5.5. Capacidad de Intercambio Catiónico (CIC)

La CIC es un indicador acerca de la capacidad amortiguadora que tienen los suelos. Esta estima los sitios de carga de las arcillas, las cargas permanentes y

las cargas que son dependientes del pH (Rosales, Spínola, Montoya, Mendoza y Peña, 2017).

2.2.1.6. Características

Las características principales de los suelos salinos es que poseen una conductividad eléctrica mayor a 4 dS/m a 25 °C, las sales solubles presentes son cloruros y sulfatos de sodio, magnesio y calcio, nitratos raramente están presentes. Muchos suelos salinos poseen una cantidad apreciable de sulfato de calcio ($\text{CaSO}_4, 2\text{H}_2\text{O}$) en su perfil, mientras que carbonatos solubles siempre están ausentes (FAO, 1988).

Las características de pH de estos suelos suelen ser típicamente menor a 8,2, y se encuentran cercanos a la neutralidad en la escala de pH. Cuando estos suelos no poseen un eficiente sistema de drenaje el pH tiene una tendencia a incrementarse y se pueden volver suelos sódicos. Cuando son suelos con texturas arcillosas las partículas de arcillas se dispersan y tienen una permeabilidad y estructura reducida, reduciendo el paso de agua y aire (FAO, 1988). Las características de los suelos salinos en relación a su conductividad eléctrica, relación absorción de sodio, porcentaje de sodio intercambiable y estructura se detallan a continuación:

Tabla 3. Características de suelos salinos

Tipo	CE	RAS	PSI	Estructura
Normal	<4.0	<13	<15%	Floculada
Salino	>4.0	<13	<15%	Floculada
Sódico	<4.0	>13	>15%	Dispersa
Sódico-Salino	>4.0	>13	>15%	Floculada

Sonon et al, 2015

2.2.1.7. Efectos en las plantas

2.2.1.7.1. Inducción de estrés hídrico

Piedra y Cepero (2013) afirma:

La presencia en exceso de solutos en la solución del suelo produce una disminución del potencial osmótico y, consecuentemente, del potencial hídrico. Por tanto, el balance hídrico de la planta en general se encuentra afectado, ya que, para mantener un gradiente entre el suelo y las hojas, que permita continuar con la absorción de agua, se debe generar un potencial hídrico mucho más negativo que el de la solución del suelo. Este efecto que generan los solutos disueltos en agua es similar a una falta de agua en el suelo (p. 34.).

2.2.1.7.2. Toxicidad ion específica

La salinidad no solo reduce el uso de agua disponible para el cultivo, sino también incrementa la presencia de iones que son tóxicos para las plantas, como el boro, sodio y cloro (University of California, 2020). Esto ocurre debido a la captación y acumulación de ciertos iones disueltos en el agua y suelo en las plantas. Estos iones como el cloruro, sodio y sulfato son absorbidos por las plantas y causan diversos daños como: Inhibición de la fotosíntesis, daños en los mecanismos de transporte y selectividad de las plantas para sus distintos procesos de crecimiento y en el metabolismo, daños enzimáticos y alteraciones en la función de las membranas (Piedra y Cepero, 2013).

2.2.1.7.3. Desbalance nutricional

La alta presencia de iones de sodio en el suelo causa antagonismo con los demás iones necesarios, como potasio, calcio y magnesio en la absorción de las plantas. Mientras que la presencia de iones de cloro es antagonista de nitrato, fosfatos y sulfatos (Bloodnick y Peery, 2018). Esto resulta en la absorción anormal de estos elementos tóxicos.

2.2.1.7.4. Incremento de la producción de especies reactivas de oxígeno (ROS)

Los desequilibrios metabólicos, el estrés hídrico, el desbalance nutricional y demás efectos de la salinidad del suelo, causan un estrés oxidativo en el cultivo. Esto es la producción de sustancias fitotóxicas que se generan a partir de la peroxidación de lípidos y degradación de proteínas. Piedra y Cepero (2013) menciona que los daños provocados por alta salinidad están muy relacionados a una alta tasa de producción de ROS.

2.2.2 Zona de Estudio – cantón Daule

2.2.2.1. Descripción de la zona

2.2.2.1.1. Fecha de creación

26 de noviembre de 1820. (GAD Daule, 2015).

2.2.2.1.2. Nombre del GAD

Gobierno Autónomo Descentralizado de la Ilustre Municipalidad del cantón Daule – GAD I.M. del cantón Daule

2.2.2.1.3. Población

El cantón en el año 2010 contaba con una población de 120.300 habitantes (INEC, 2010). Sin embargo de acuerdo a información estadística de GAD Daule (2015) la población total aproximada asciende a 159.175 habitantes. La población rural del cantón representa aproximadamente un 45.9% del total, mientras que la población urbana es de 54.1% (INEC, 2010). Un aproximado de 36.7% del total de la población de Daule se dedica a actividades agrícolas (Tutiven, 2017).

2.2.2.1.4. Rango altitudinal

8 a 25 metros sobre el nivel del mar (GAD Daule, 2015).

2.2.2.1.5. División política

El cantón Daule tiene las siguientes divisiones políticas:

- 4 parroquias rurales: Juan Bautista Aguirre (Los Tintos), Enrique Baquerizo Moreno (Los Lojas), El Laurel y Limonal.
- 7 parroquias urbanas: Emiliano Caicedo, Vicente Piedrahíta, Magro, Banife, Juan Bautista Aguirre, Santa Clara, y La Aurora.
- 166 recintos (GAD Daule, 2015).

2.2.2.2. Producción de cultivos

El cantón Daule es el principal productor de arroz del país, cuenta con más de 30,000 hectáreas de cultivo, lo cual es alrededor del 75% de la superficie del cantón, también presenta una alta productividad de este cultivo, más que en los cantones aledaños, el cultivo suele darse de 2 a 3 ciclos productivos por año (Ramos, 2018).

Alrededor de 137.794 toneladas métricas de arroz son producidas por año, con una producción de 4,64 toneladas métricas por hectárea (Tutiven, 2017). Además de la producción de arroz, diversos cultivos como frutales, cultivos de ciclo corto como maíz, y pastos son producidos de manera intensiva en el sector. Se detalla a continuación la producción agropecuaria del cantón Daule:

Tabla 4. Producción agropecuaria del cantón Daule.

Cultivo	Superficie (Ha)	Producción (Tm/Ha/Año)
Arroz	29.720	4,64
Plátano	12,52	1,94
Mango	433,35	7,45
Banano	38	30,8
Melón	29	10,38
Maíz	123	1,49
Ciruela Costeña	210,97	0,78
Papaya	20,82	6,35
Ciruelo	10,62	1,08
Algodón	61	1,31

MAGAP, 2017

2.2.2.3. Clima

El cantón Daule presenta 2 zonas climáticas definidas uniformemente. El sur y oeste del cantón presenta un clima Tropical Megatermico Semihúmedo, las temperaturas varían entre 25 a 26 grados centígrados durante todo el año (Pourrut, 1995). Las parte este y norte del cantón presenta características de clima Tropical Megatermico Húmedo (GAD Daule, 2015).

Una humedad relativa de 88% de promedio. Una alta nubosidad, cercana a 7/8 de cobertura durante el año (GAD Daule, 2015). La precipitación del cantón tiene como promedio anual 1200 milímetros y un total de 81 días de lluvia al año (Instituto Nacional de Meteorología e Hidrología [INAMHI], 2017).

2.2.2.4. Suelos

2.2.2.4.1. Relieve

El relieve del cantón demuestra topográficamente dos sectores bien definidos, uno mayoritariamente plano, con pendientes que oscilan entre 0 a 3% que usualmente se asocian con valles indiferenciados, inundados parte del año y aprovechados en mayoritaria extensión para cultivos de arroz (zonas aluviales) y que representan aproximadamente el 80% de la extensión del cantón. El otro gran sector ubicado hacia el suroeste del territorio, en la parroquia rural Los Lojas aparecen un grupo de elevaciones (derivación de la cordillera Chongón - Colonche), esta zona alta ocupa aproximadamente el 10% del total del territorio cantonal en la cual la cota más alta está alrededor de los 300 m.s.n.m. (GAD Daule, 2015, p. 18).

2.2.2.4.2. Textura

La presencia de suelos con alto contenido de arcillas en el sector es evidente, aproximadamente un 44% de los suelos del sector presentan mal drenaje, con poca profundidad a medianamente profundos, contenido de materia orgánica alto y pH ligeramente ácido. También los suelos de textura franco-arcilloso son comunes en el sector. La superficie total de ambas texturas y características mencionadas representa un total del 86,20% de la superficie del cantón (GAD Daule, 2015).

2.2.2.4.3. Geomorfología

De manera general, la geomorfología predominante son los depósitos aluviales que van desde plano hasta ligeramente ondulado, diques, cauces secos y basines con una pendiente dominante del 0 – 2 % y un desnivel relativo de 0-5 m, ocupando estas características una extensión aproximada de 35.600 Ha. que representan el 65% del área del cantón.

La geomorfología deposicional, ligeramente disectada, valles fluviales, terrazas medias y terrazas indiferenciadas, con una pendiente dominante de 2-5%, desnivel relativo de 0-5 m que ocupan una extensión aproximada de 14.245 hectáreas., que representan el 26% del área del cantón.

Finalmente, el tectónico erosivo que va desde relieve ondulado a colinado bajo, medio y alto, con una pendiente natural del 12-40% con un desnivel relativo de 6-200 m con una extensión aproximada de 4.931 Ha. que representan aproximadamente el 9% de la extensión del cantón y que son las únicas colinas altas del cantón, ubicadas hacia el sur del área urbana La Aurora (GAD Daule, 2015, p. 22).

2.2.2.4.4. Principales ordenes de suelo del sector

2.2.2.4.4.1. Vertisoles

Los vertisoles son suelos que poseen una morfología específica que está fuertemente relacionada con una combinación de material de suelo de textura muy fina, presencia de arcillas expansivas, condiciones de drenaje deficiente y la alternancia entre temporadas húmedas y secas. Entre las características morfológicas principales que lo definen se puede detallar: Las grietas en las superficies del suelos, una estructura bien desarrollada, una estructura en la cual debido a la expansión-contracción de arcillas el material se mezcla entre sí, causando horizontes A con grandes profundidades, muchas veces sin horizonte B (Blokhuys, 1996).

Los vertisoles presentan entre un 30% hasta un 90% de arcillas en su perfil hasta los 50 centímetros de profundidad, además de presentar variaciones de volumen dependientes de las condiciones de humedad. También presentan una alta capacidad de intercambio catiónico, lo cual los caracteriza como suelos con gran fertilidad. Al ser suelos con drenajes deficientes en estado de saturación los vuelve muy adecuados para la siembra de cultivos como arroz (Sotelo et al., 2008). El cantón Daule presenta cerca del 60% de su superficie con suelos de orden vertisol, lo cual representa alrededor de 27.000 hectáreas de superficie.

2.2.2.4.4.2. Inceptisoles

Los Inceptisoles son suelos que se presentan en zonas húmedas y semihúmedas con clima cálido, que incluyen un horizonte cámbico o epipedón ócrico. La secuencia de horizontes más común suele ser un epipedón ócrico sobre un horizonte cámbico, con o sin la presencia de un Fragipan inferior.

Además, si el suelo presenta un epipedón de Plaggen es considerado como Inceptisol (Departamento de Agricultura de los Estados Unidos [USDA], 1999).

Una de las únicas propiedades de los Inceptisoles es la presencia de agua disponible para las plantas durante más de medio año, o 3 meses consecutivos o más durante la temporada cálida de disponibilidad hídrica. Además de lo mencionado estos suelos presentan epipedones u horizontes con baja cantidad de acumulación de materiales traslocados, que no sean carbonatos o dióxido de silicio (USDA, 1999). En el caso del sector Daule, la presencia de Inceptisoles representa una superficie aproximada de 9308 hectáreas, lo cual es equivalente a un 20.47% de la superficie total del cantón.

2.2.2.4.4.3. Entisoles

Los Entisoles presentan características únicas como la presencia de materiales minerales y la ausencia de horizontes pedogenéticos. La ausencia de procesos formadores de suelos es su mayor distinción (USDA, 1999). Los Entisoles son el orden de suelos que mayor superficie ocupa mundialmente, alrededor de 16% de la superficie mundial total que no está bajo hielo, mayoritariamente se encuentran en el continente africano (Ibáñez, Gisbert, y Moreno, 2014).

La ausencia de horizontes pedogenéticos se da como resultado del material parental, que puede ser arena de cuarzo en la cual no forma piedras de lenta solubilidad como limo, el cual deja poco residuos y debido a procesos de erosión no forma los horizontes (USDA, 1999). La zona de estudio presenta un área de 8433 hectáreas de suelos Entisoles, lo cual representa un 18,54% de superficie del área total del cantón.

2.2.2.4.4.4. Alfisoles

Los suelos Alfisoles tienen procesos que trasloca arcillas sin el agotamiento de las bases intercambiables, y sin la dominancia de procesos que conllevan al desarrollo de un epipedón Mólico. Una de las propiedades únicas de los Alfisoles es la combinación de epipedón úmbrico u ócrico, horizonte argílico o nátrico, porcentaje de bases intercambiables alto y presencia de agua para las plantas por más de la mitad del año o durante 3 meses consecutivos durante la temporada de calor. Debido a lo mencionado anteriormente estos suelos son intensamente usados para la agricultura (USDA, 1999). El cantón Daule presenta una superficie de 482 hectáreas de suelos Alfisoles, lo cual representa un total de 1.06% de la superficie total.

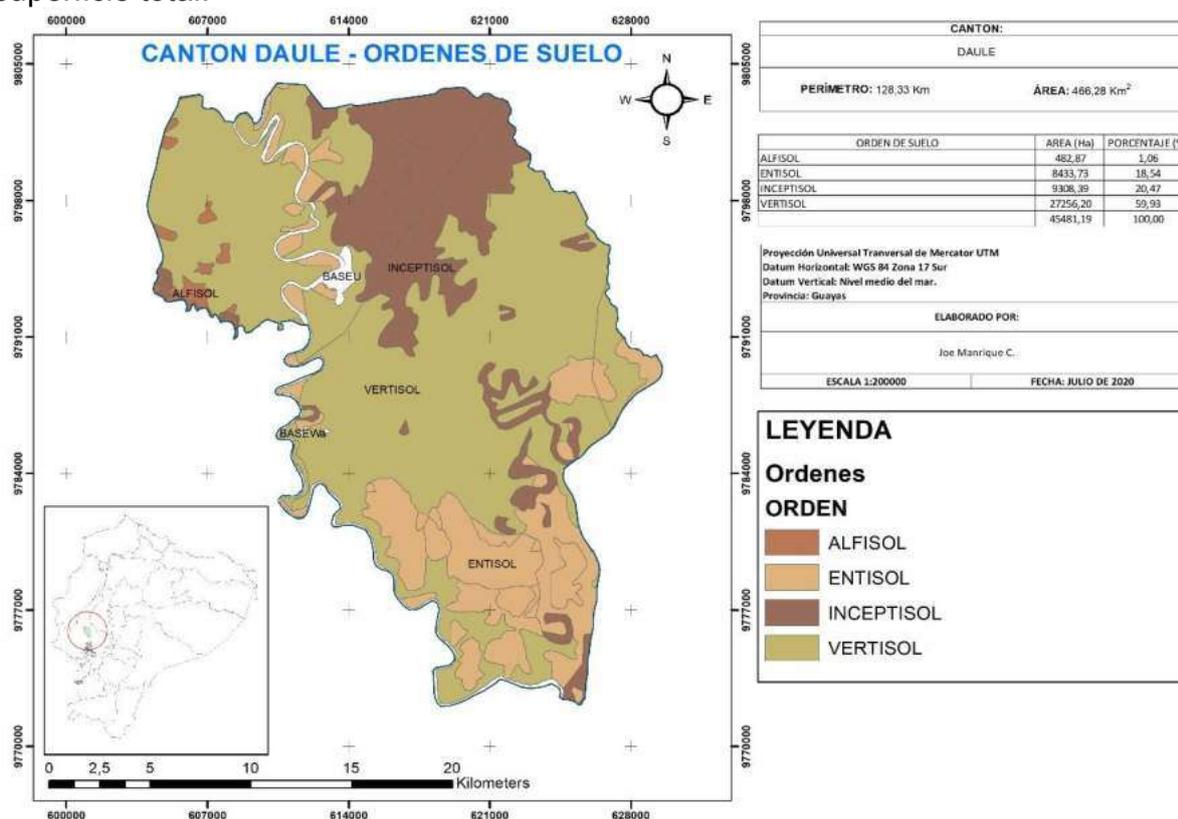


Figura 1. Ordenes de Suelo del cantón Daule Manrique, 2021

2.2.2.4.5. Uso de suelo

El principal uso de suelo del sector es para la agricultura, el principal cultivo producido es el arroz, también hay la presencia de pastos cultivados y naturales, maíz, frutales y bosques intervenidos.

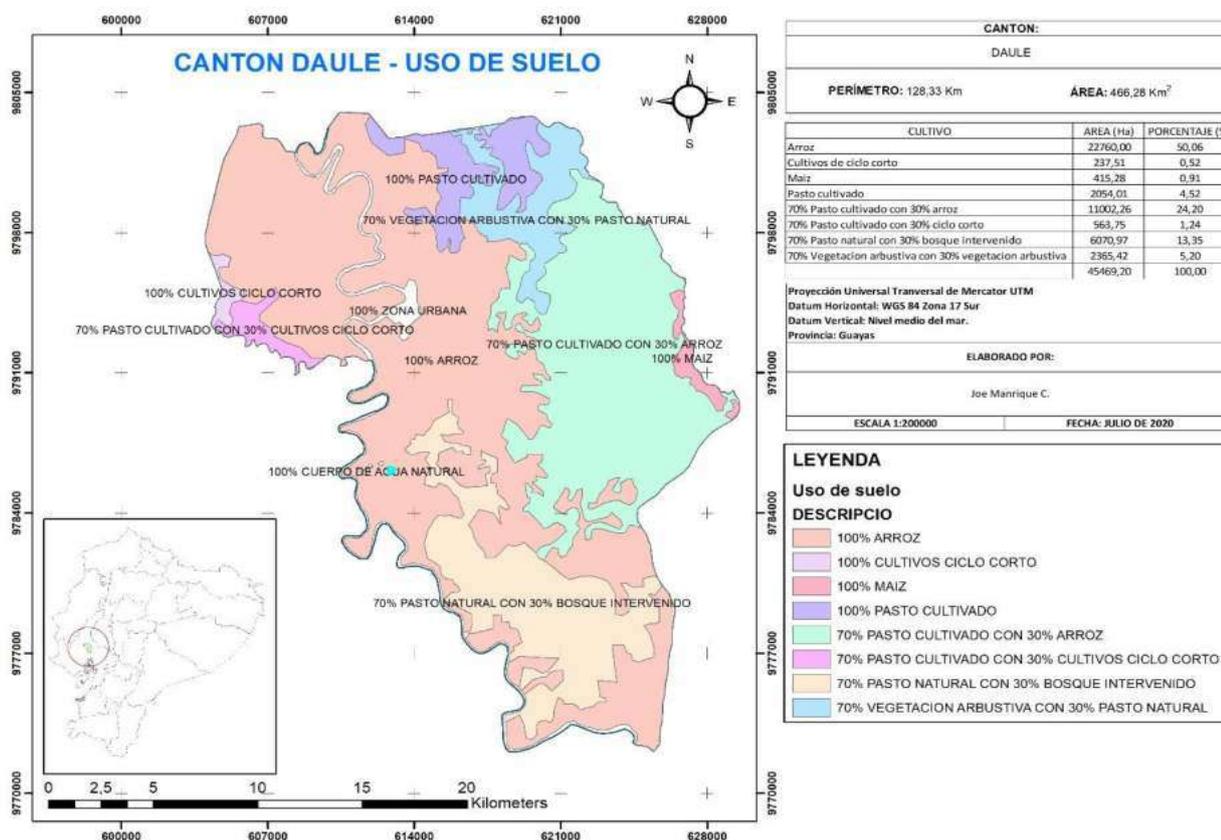


Figura 2. Uso de suelo del cantón Daule Manrique, 2021

2.2.3 Correcciones de imágenes

2.2.3.1. Preprocesamiento

2.2.3.2.1. Generalidades

El preprocesamiento de datos de imágenes es la rama del procesamiento de imágenes digitales. Es una técnica que mejora imágenes recibidas de sensores de cámara colocados en satélites, sondas espaciales y aviones, o imágenes tomadas en condiciones normales para diversas aplicaciones (Jain, 1989). El preprocesamiento es necesario cuando se trabaja con imágenes satelitales

liberadas de alteraciones atmosféricas o nubes. Por lo que para el análisis multitemporal y cálculo de índices de vegetación es necesario. Existen diversos tipos de preprocesamiento de imágenes y se realizan en de acuerdo con el tipo de trabajo a realizar (Casella, Barrionuevo, Pezzola y Winschel, 2018).

2.2.3.2.2. Corrección geométrica

La corrección geométrica es un método esencial para el preprocesamiento de las imágenes satelitales cuyo objetivo es eliminar la distorsión geométrica (Baboo, 2011). Este tipo de corrección sirve principalmente para posicionar la imagen en la zona territorial correcta y borrar las distorsiones en la imagen. Entre las técnicas usadas para la corrección geométrica se detalla: El manejo de efemérides, DEM, identificación de puntos de control y remuestreos de los píxeles, entre otros.

2.2.3.2.3. Corrección radiométrica

La reflectancia dada por un objeto medido por un instrumento de teledetección varía de acuerdo a diversas condiciones, como la iluminación del objeto, su reflectividad, transmisividad de la atmosfera, entre otros. También los resultados dados por un sensor pueden variar con el tiempo debido a su degradación, por lo que las condiciones radiométricas de los objetos son muy variables. Por lo cual, se han desarrollado diversas técnicas de corrección radiométrica, como correcciones de la distancia tierra-sol, corrección de la elevación del sol y compensación de niebla (DiBiase, Dutton y Sloan, 2009).

2.2.3.2.4. Corrección atmosférica

Durante el proceso de movimiento de luz desde el sol hasta la superficie del planeta, el flujo radiante es absorbido y esparcido por los aerosoles presentes en la atmosfera, lo cual termina siendo un factor importante que modifica las

condiciones de radiancia que son detectadas por los sensores. En la imagen detectada, estos cambios en la radiancia y el esparcimiento Rayleigh se vuelven más notorios. Los aerosoles atmosféricos de menor tamaño son los principales causantes de este esparcimiento debido a que estos redireccionan la energía de onda corta añadida a la radiancia de la imagen y de los píxeles. Estos suelen causar lo que se conoce como efecto niebla, lo cual reduce la calidad de la imagen, en detalles especialmente, debido a la pérdida de contraste (Araya, 2007).

2.2.4 Índices de Vegetación (VI)

2.2.4.1. Concepto

Los índices de vegetación son una de las herramientas más antiguas en el campo de la teledetección, estas miden la proporción de la reflexión de las ondas rojas e infrarrojas del espectro para separar y diferenciar el agua, suelo, cultivo y estructuras de un panorama (Glenn, Huete, Nagler y Nelson, 2008). Estos son considerados como indicadores explícitos que miden diversos procesos socio ecológicos como uso de suelo, crecimiento urbano y condiciones de cultivo. Estos son calculados usando información de imágenes multiespectrales, en donde 2 o más bandas de imágenes satelitales son relacionadas para resaltar las condiciones de cobertura vegetal, propiedades vegetales de interés, entre otros (Pasimeni, Valente, Semeraro, Petrosillo y Zurlini, 2019). Los VI proporcionan información cuantitativa que puede ser usada para el análisis del estado de cultivo y desarrollo, identificar tipo de cultivo y sus condiciones, debido a que los VI no solo están correlacionados a la actividad fotosintética de las plantas, sino también a características y el estado del suelo (Babiker, Abulgasim y Hamid, 2018).

La salinidad del suelo puede ser determinada de varias maneras; mediante teledetección directa, mediante la reflectancia del suelo, cuantificación de las sales presentes en la superficie e indirectamente por medio de las condiciones de estrés de las plantas. Para poder hacer un análisis cuantitativo de las condiciones del cultivo y del suelo, se usan los índices de vegetación que son usados de manera extendida y considerados una fuente de información única en su clase (Babiker et al., 2018).

2.2.4.2. Relación de los índices de vegetación con la salinidad

Varias metodologías para determinar la presencia de suelos salinos y sódicos existen, estas metodologías se basan en la máxima reflectancia (10.5 – 12.5 μm) y la mínima reflectancia (0.76 – 0.90 μm) que poseen los suelos salinos. Las sales presentes en los suelos son particularmente visibles en la banda azul. Por lo que los índices de salinidad y vegetación son usados para determinar las condiciones de salinidad del suelo, basados en la alta reflectancia que tienen las sales (Babiker et al., 2018).

2.2.4.3. Índices relacionados con la dinámica de la salinidad

2.2.4.3.1. Índice de vegetación de diferencia normalizada (NDVI)

El uso de índices de vegetación es importante para el monitoreo de la cubierta vegetal de la superficie terrestre, debido a que puede analizar los patrones temporales y espaciales de la actividad fotosintética de las plantas. El NDVI es la diferencia entre la banda infrarroja cercana y las bandas rojas divididas para su suma (Huete, 1997). Este índice sirve para vigilar procesos de sequías y desertificación, estimaciones de la producción agrícola, predicción de zonas de incendios, entre otras. En el campo agrícola sirve para identificar problemas fitosanitarios, aplicación correcta de fertilizantes, determinación del estado

fenológico del cultivo, necesidades de riego. Este índice indica la forma en que las plantas reflejan/absorben ciertas frecuencias de luz, y debido a esto pueden determinarse las condiciones en las que la planta se encuentra. Una planta saludable reflejara mucha mayor cantidad de ondas infrarrojas cercanas debido a la presencia de la clorofila, mientras que una planta en estado deficiente reflejara menos las ondas infrarrojas cercanas debido a la ausencia de clorofila (Earth Observing System [EOS], 2020). Los valores que presenta el NDVI están entre -1 y 1, y generalmente se los clasifica en 5 intervalos. Los valores negativos del NDVI representa cuerpos de agua, los valores bajos positivos representan el suelo, arena y rocas ($<0,1$), los valores desde 0.2 – 0.3 representa vegetación arbustiva y terreno escasamente cultivado y los valores desde 0.3 – 1 es indicativo de vegetación densa (Babiker et al., 2018).

2.2.4.3.2. Índice de vegetación ajustado al suelo (SAVI)

La influencia del brillo del suelo ha sido notada como un factor importante en el uso de diversos índices de vegetación, como el NDVI o RVI, donde los valores del NDVI resultan en valores mayores de acuerdo al brillo del suelo y cubierta de suelo no completa. Por lo que en áreas donde existen diferentes variaciones de brillo debido a condiciones de humedad, porcentaje de materia orgánica, sombras, entre otros, repercute en los valores de los índices de vegetación tradicionales (Huete, 1988). Por lo que SAVI es usado para corregir el NDVI por la influencia del brillo del suelo en zonas donde la cubierta vegetal sea parcial o baja (Vermote et al., 2006), con un máximo de un 15% de cubierta vegetal (EOS, 2019). Los valores de SAVI tienden a reducirse cuando la salinidad incrementa (Alhammadi y Glenn, 2008).

2.2.4.3.3. Índice de salinidad vegetación – suelo (VSSI)

El índice de salinidad vegetación – suelo es un índice desarrollado para poder discriminar entre el stress del suelo y de la vegetación (Dehni y Lounis, 2012). El índice relaciona las bandas 2,3,4,5 de satélite Landsat 7. Índices como NDSI, NDVI, SAVI y VSSI tienen una clara relación con las condiciones de salinidad (Nguyen, Liou, Tran, Hoang y Nguyen, 2020).

2.2.4.3.4. Índice de vegetación mejorado (EVI)

El EVI es similar al NDVI debido a que sirve para cuantificar las condiciones de las plantas basándose en el color verde que estas poseen. Sin embargo, el EVI funciona de manera diferente al NDVI basado en que corrige diversas condiciones atmosféricas, ruido causado por la cobertura y mayor sensibilidad a zonas con mayor densidad de vegetación. Posee un factor “L” que es el ajuste al ruido de la vegetación y un coeficiente “C” que está relacionado con la resistencia atmosférica, El cálculo del EVI permite reducir el ruido de fondo, el ruido atmosférico y la saturación en el mejor de los casos, también permite tener valores intermedios entre las bandas R y NIR para el cálculo de índices de vegetación (Vermote et al., 2006).

2.2.4.3.5. Índice de vegetación resistente a la atmósfera (ARVI).

El ARVI fue desarrollado con fines de ser usado en teledetección de la vegetación usando el sensor del “Sistema de Observación de la Tierra” (EOS - Earth Observing System) MODIS, sin embargo también puede ser usado mediante los sensores de satélite Landsat TM (Kaufman y Tanre, 1992). Este índice fue desarrollado como una corrección del NDVI ante los efectos de atmosféricos de dispersión (lluvia, polvo, humo, polución de aire) en el espectro de las bandas rojas. Este índice usa las bandas azules para la corrección (EOS,

2019). El ARVI tiene un rango dinámico similar al NDVI, sin embargo, es 4 veces menos sensibles a los efectos atmosféricos, y el efecto tiene mejores resultados cuando se usa en superficies con mayor cubierta vegetal. El índice funciona mejor cuando se trata de aerosoles y partículas de tamaños medianos y pequeños (humo, smog, polvo) más que cuando se trata de partículas de mayor tamaño (Arena, brisa marina) (Kaufman y Tanre, 1992). El ARVI es tolera más los efectos topográficos del terreno que otros índices de vegetación, por lo que funciona para identificar y monitorear zonas con montañas y presencia de agricultura de cosecha y quema (EOS, 2019).

2.2.4.3.6. Índice de salinidad (SI).

Los índices de salinidad de suelo han sido catalogados como útiles herramientas para identificar información de interés que está relacionada a patrones espectrales de los suelos salinos, los índices más empleados para determinar la dinámica son: Índice de brillo (BI) e índice de salinidad (SI) (Babiker et al., 2018). El SI está muy correlacionado con la conductividad eléctrica (CE) debido a la relación que hay entre la banda azul y demás bandas (Allbed, Kumar y Sinha, 2014). Debido a la expansión de la salinidad el crecimiento de los cultivos es reducido, lo cual es reflejado en la reducción de los valores de los VI, y son indicadores de la presencia de procesos degradativos del suelo, a diferencia del índice de salinidad que se incrementa cuando los procesos degradativos están presentes (Babiker et al., 2018). Autores como Tripathi, Rai y Dwivediore (2009) mencionan que la identificación de suelos bajo procesos de salinidad usando imágenes multiespectrales corregidas, mediante el uso de SI deriva en mejores resultados debido a la capacidad del índice de suprimir información de la vegetación y tomar en cuenta puntos donde la salinidad es evidente.

2.2.4.3.7. Índice de brillo (BI).

El índice de brillo está basado en la información calculada de las bandas R y NIR. El índice consiste en remover la influencia de los cambios en la iluminación y condiciones atmosféricas, debido a que estas influencias tienen efectos en la reflectancia del suelo. La normalización de los valores de los índices permiten estudiar los cambios de la condición de la superficie del suelo (Caloz, Abednego y Collet, 1988).

2.2.4.3.8. Índice de salinidad de diferencia normalizada (NDSI).

Vegetación bajo estrés es un indicador indirecto de la presencia de suelos salinos, estos suelos están caracterizados por zonas escasamente sembradas o con problemas de estrés hídrico. Para discriminar la presencia de suelos salinos se usan diversos tipos de índices, como lo son el SI, NDVI, NDSI, VSSI, entre otros. El NDSI es la diferencia de la banda R y NIR dividido para la suma de ambas bandas (Asfaw et al., 2018).

2.3 Marco legal

La investigación está relacionada con el manejo sustentable del recurso suelo, por lo que la constitución del Ecuador ampara el derecho a la preservación de los recursos naturales del país.

Art. 264.- Los gobiernos municipales tendrán las siguientes competencias exclusivas sin perjuicio de otras que determine la ley:

1. Planificar el desarrollo cantonal y formular los correspondientes planes de ordenamiento territorial, de manera articulada con la planificación nacional, regional, provincial y parroquial, con el fin de regular el uso y la ocupación del suelo urbano y rural.
2. Ejercer el control sobre el uso y ocupación del suelo en el cantón (p.86).

Art. 276.- El régimen de desarrollo tendrá los siguientes objetivos:

4. Recuperar y conservar la naturaleza y mantener un ambiente sano y sustentable que garantice a las personas y colectividades el acceso equitativo, permanente y de calidad al agua, aire y suelo, y a los beneficios de los recursos del subsuelo y del patrimonio natural (p.89).

Art. 375.- El Estado, en todos sus niveles de gobierno, garantizará el derecho al hábitat y a la vivienda digna, para lo cual:

1. Generará la información necesaria para el diseño de estrategias y programas que comprendan las relaciones entre vivienda, servicios, espacio y transporte públicos, equipamiento y gestión del suelo urbano.
2. Mantendrá un catastro nacional integrado georreferenciado, de hábitat y vivienda (p.114).

Art. 408.- Son de propiedad inalienable, imprescriptible e inembargable del Estado los recursos naturales no renovables y, en general, los productos del subsuelo, yacimientos minerales y de hidrocarburos, sustancias cuya naturaleza sea distinta de la del suelo, incluso los que se encuentren en las áreas cubiertas por las aguas del mar territorial y las zonas marítimas; así como la biodiversidad y su patrimonio genético y el espectro radioeléctrico. Estos bienes sólo podrán ser explotados en estricto cumplimiento de los principios ambientales establecidos en la Constitución (p.122).

Art. 409.- Es de interés público y prioridad nacional la conservación del suelo, en especial su capa fértil. Se establecerá un marco normativo para su protección y uso sustentable que prevenga su degradación, en particular la provocada por la contaminación, la desertificación y la erosión. En áreas afectadas por procesos de degradación y desertificación, el Estado desarrollará y estimulará proyectos de forestación, reforestación y revegetación que eviten el monocultivo y utilicen, de manera preferente, especies nativas y adaptadas a la zona (p.123).

Art. 410.- El Estado brindará a los agricultores y a las comunidades rurales apoyo para la conservación y restauración de los suelos, así como para el

desarrollo de prácticas agrícolas que los protejan y promuevan la soberanía alimentaria (p.123).

Art. 415.- El Estado central y los gobiernos autónomos descentralizados adoptarán políticas integrales y participativas de ordenamiento territorial urbano y de uso del suelo, que permitan regular el crecimiento urbano, el manejo de la fauna urbana e incentiven el establecimiento de zonas verdes. Los gobiernos autónomos descentralizados desarrollarán programas de uso racional del agua, y de reducción reciclaje y tratamiento adecuado de desechos sólidos y líquidos. Se incentivará y facilitará el transporte terrestre no motorizado, en especial mediante el establecimiento de ciclo vías (Constitución de la República del Ecuador, 2008, p.123).

El Código Orgánico del Ambiente también menciona la corrección de las condiciones de procesos degradativos del suelo, su preservación y las competencias de los GAD de su manejo adecuado.

Art. 5.- Derecho de la población a vivir en un ambiente sano. El derecho a vivir en un ambiente sano y ecológicamente equilibrado comprende:

5. La conservación y uso sostenible del suelo que prevenga la erosión, la degradación, la desertificación y permita su restauración;
8. Controlar el cumplimiento de los parámetros ambientales y la aplicación de normas técnicas de los componentes agua, suelo, aire y ruido (p. 5).

Art. 109.- Disposiciones generales para el manejo forestal sostenible. Las disposiciones generales deberán orientarse a:

7. Prevenir, evitar y detener la erosión o degradación del suelo (p. 38).

Art. 118.- Restauración ecológica. En las actividades de restauración ecológica de suelos o ecosistemas se priorizará la regeneración natural cuando esta sea posible técnica, económica y socialmente. Los Gobiernos Autónomos Descentralizados, en el marco de sus competencias, darán atención prioritaria a los suelos degradados o en proceso de desertificación, bajo lineamientos de la Autoridad Ambiental Nacional (p. 40).

Art. 191.- Del monitoreo de la calidad del aire, agua y suelo. La Autoridad Ambiental Nacional o el Gobierno Autónomo Descentralizado competente, en coordinación con las demás autoridades competentes, según corresponda, realizarán el monitoreo y seguimiento de la calidad del aire, agua y suelo, de conformidad con las normas reglamentarias y técnicas que se expidan para el efecto. Se dictarán y actualizarán periódicamente las normas técnicas, de conformidad con las reglas establecidas en este Código. Las instituciones competentes en la materia promoverán y fomentarán la generación de la información, así como la investigación sobre la contaminación atmosférica, a los cuerpos hídricos y al suelo, con el fin de determinar sus causas, efectos y alternativas para su

3. Materiales y métodos

3.1 Enfoque de la investigación

3.1.1 Tipo de investigación

- Investigación de campo y laboratorio
- Nivel de conocimiento: correlacional.

3.1.2 Diseño de investigación

La investigación es de campo y laboratorio, con un nivel de conocimiento correlacional. Tiene un diseño no experimental, debido a que las variables independientes no fueron controladas o manipuladas, sino solo observadas y se detallaron las relaciones que existen entre ellas sin la manipulación directa. Se observaron los hechos y variables que ya han ocurrido y se los describió, en el caso de la presente investigación fueron los índices de salinidad, combinación de bandas y muestras del sector Daule. El nivel de conocimiento es correlacional debido a que luego de ser elaborado el mapa de suelos usando las muestras de suelo tomadas en el campo y luego de ser analizadas en laboratorio, estas fueron correlacionadas con la información de los índices y las combinaciones de bandas satelitales.

3.2 Metodología

3.2.1 Variables

3.2.1.1. *Variable dependiente*

- Nivel de salinidad de suelos arroceros.

3.2.1.2. *Variables independientes*

- Combinación de bandas satelitales.
- Combinación de índices de vegetación.
- Índice de vegetación de diferencia normalizada (NDVI).

- Índice de vegetación ajustado al suelo (SAVI).
- Índice de modificado de vegetación ajustado al suelo (MSAVI).
- Índice de vegetación mejorado (EVI).
- Índice de vegetación resistente a la atmósfera (ARVI).
- Índices de salinidad 1 – 9 – T (SI).
- Índice de brillo 1 – 2 (BI).
- Índice de salinidad de diferencia normalizada (NDSI).
- Índice de salinidad vegetación – suelo (VSSI).
- Índice de intensidad 1 – 2 (INT).
- Índice de salinidad de respuesta de cobertura (CRSI).
- Índice de monitoreo de humedad del suelo (SMMI).
- Índice normalizado de humedad de suelo de diferencia de onda corta-infrarroja (NSDSI3).
- Índice de sequía multibanda normalizado (NMDI).
- Índice de agua de diferencia normalizada (NDWI).
- Índice de sequía visible y de onda corta (VSDI).
- Índice de stress por humedad (MSI).
- Muestras de suelo del sector.

3.2.2 Diseño experimental

El tipo de diseño es descriptivo, realizado en base a las imágenes multiespectrales obtenidas de recursos en línea y en base a las muestras obtenidas a nivel de campo. Además, es de tipo transversal o transeccional, debido a que únicamente se usaron datos e información del sector a tiempo presente, sin el uso de información de años anteriores.

3.2.3 Recolección de datos

3.2.3.1. Recursos

Conductímetro, multiparámetro, tubos falcón, mezcladores, centrifuga, balanza analítica, estufa, molino de suelo, papel filtro, tamiz, vaso de precipitado, agua destilada, computadora, programas de SIG, SNAP, ArcMap, QGIS, WEKA, R Studio, recursos en línea de consulta, imágenes multiespectrales, gestores bibliográficos, mapas sectoriales, vehículo de transporte, etiquetas, marcadores, bolsas de muestra, palas, botas.

3.2.3.2. Métodos y técnicas

3.2.3.2.1. Muestreo del sector

Para poder correlacionar la información determinada de las imágenes satelitales y levantar una línea base sobre la condición de la salinidad del suelo en las zonas arroceras de Daule, se realizó un muestreo en la zona de estudio. Se muestreo un total de 100 puntos de manera aleatoria en el cantón, la ubicación de los puntos fue dada por el software de SIG con el comando “puntos aleatorios”. La profundidad de la toma de muestra fue realizada en los primeros 10 – 20 centímetros de profundidad, cada muestra fue etiquetada y georreferenciada con GPS (Ver Anexo 3). Para la presente investigación se tomó en cuenta que el arroz se encontraba en etapa fisiológica de plántula, hasta antes del macollamiento para que el ingreso a la zona a muestrear sea más oportuno.

3.2.3.2.2. Análisis de laboratorio

En laboratorio se analizaron las muestras tomadas del sector. Cada muestra fue debidamente analizada, para esto se determinó la conductividad eléctrica que posee (CE) mediante el método de pasta saturada.

Se llevaron las muestras al laboratorio de Suelos, Plantas y Agua de la facultad de Ciencias Agrarias, se comenzó el proceso de secado de las muestras en la estufa durante 4 horas de secado a una temperatura de 95° centígrados en grupos de 15 muestras a la vez. Luego del secado las muestras se las trituraron en el molino de suelo durante 30 segundos, cada muestra se la tamizó y pesó, luego se las almacenó en fundas plásticas debidamente etiquetadas y pesadas.

Para el procedimiento de pasta saturada se preparó el extracto del suelo con agua destilada, hasta la obtención de una pasta que tenga una consistencia adecuada, sin la aparición de la separación de las fases por el exceso de agua. Se pesó la muestra seca en tubos falcón y luego la muestra ya mezclada con agua también se la peso para determinar la cantidad de agua que se aplicó. Esta pasta se la dejó reposando y en equilibrio durante 24 horas dentro de las instalaciones del laboratorio, cada tubo con la pasta saturada fue debidamente etiquetado para que pudiera ser identificado correctamente.

Luego se llevaron los tubos falcón con las muestras hacia la centrifugadora, en grupos de 6 se insertaron las muestras y se centrifugaron durante 5 minutos a 4000 rpm. Luego con un conductímetro o multiparámetro se midió la conductividad eléctrica que posee la pasta y el agua separada del suelo. Los datos de CE se anotaron e identificaron para cada muestra, este proceso se realizó para las demás muestras tomadas y se ingresaron como tabla de datos en Excel, junto con las coordenadas de donde pertenece la muestra, su número de identificación y la conductividad eléctrica en (dS/m).

3.2.3.2.3. Elaboración de mapa de salinidad

Usando el programa de sistema de información geográfica ArcMap se ingresaron los datos de conductividad eléctrica de la tabla de Excel con la

información de las coordenadas mediante inserción de datos X - Y. Estos se transformaron hacia un formato Shapefile y se realizó una interpolación de datos mediante el método de Kriging Ordinario (KO), los modelos de semivariograma implementados fueron esférico, linear, gaussiano, circular y exponencial. Para cada interpolación se dio un tamaño de celda de 5 y posterior se realizó una máscara para extracción de datos de la zona de interés.

Con los 5 raster interpolados se realizó una reclasificación de datos para ajustarlos a rangos que puedan visualizarse con facilidad. Los rangos fueron establecidos por la FAO y son rangos clasicatorios estandarizados, estos fueron: de 0,0 – 2,0 (dS/m), 2,0 – 4,0 (dS/m), 4,0 – 8,0 (dS/m) y 8,0 – 16,0 (dS/m) (Ver tabla 1). Luego se transformaron los rasters hacia formato shapefile para determinar el área y perímetro total de cada zona con presencia de salinidad, con esto se tuvo un mapa que indica el nivel de salinidad presente en las zonas arroceras del cantón Daule.

3.2.3.2.4. Obtención de imágenes satelitales

La información espectral se la obtuvo a partir de las imágenes satelitales provenientes del satélite Sentinel 2 (A y B) , las mismas que se obtuvieron desde las páginas de la USGS Earth Explorer (en el sitio web oficial <https://earthexplorer.usgs.gov/>) y de Copernicus Open Access Hub (<https://scihub.copernicus.eu/dhus/#/home>) la cual es la página oficial de la Agencia Espacial Europea, la cual permite obtener imágenes del satélite Sentinel 2 con un tratamiento de corrección geométrica y atmosférico, así como ortorectificación previo.

3.2.3.2.5. Corrección y preprocesamiento de imágenes

Las imágenes satelitales tienen menos del 10 % de nubosidad para incrementar la exactitud de los datos que se procesaron y extrajeron.

Para la corrección de imágenes multiespectrales se usó el software libre SNAP (Sentinel Applications Platform). Las imágenes se las modificó y fueron llevadas desde un nivel 1C hasta un nivel 2A mediante el uso del plugin Sen2Cor280 del software SNAP, además se realizó un remuestreo de cada banda para poder incrementar la resolución desde 20 y 60 metros hacia 10 metros respectivamente mediante un muestreo bilinear, para tener una resolución constante para cada banda. Así mismo se realizó una corrección radiométrica MERIS y corrección de Rayleigh. Para finalizar el proceso de preprocesamiento de las imágenes satelitales se realizó una transformación de reflectancia superficial a radiancia superficial, es decir desde Top of Atmosphere – Encima de la atmosfera (TOA) hacia Bottom of atmosphere o bajo la atmosfera (BOA) para poder calcular los índices con valores normalizados.

3.2.3.2.6. Cálculo de índices de vegetación

Usando el programa de SIG ArcMap se procesaron las imágenes satelitales ya corregidas. En este software se añadieron todas las bandas satelitales y se realizó una extracción mediante máscara de cada banda satelital de la zona de estudio para únicamente usar la información de la zona de interés.

Se aplicaron las fórmulas de los diversos índices de vegetación y salinidad que se han seleccionado para determinar la dinámica de la salinidad del sector (Ver Tabla 5). Se usó el comando “Map Algebra” para el cálculo de los diversos índices que se usaron.

Se aplicó el comando “puntos aleatorios” dentro la zona de interés, se realizaron un total de 200 puntos aleatorios con una separación mínima de 200 metros entre punto y se determinó las coordenadas UTM de estos puntos. Se extrajo de cada índice de vegetación calculado la información de los píxeles usando los puntos creados para cada índice, así como la información de los píxeles de las bandas satelitales 1,2,3,4,8,11,12 respectivamente. A partir de esto se creó una tabla de datos que muestra las coordenadas de los puntos, los datos de los índices de vegetación en estos puntos y el número de puntos. También se extrajo la información de los píxeles en los puntos creados de los raster que se interpolaron anteriormente. Esta tabla se la transformo y exportó hacia Excel para poder correlacionar los rasters interpolados y los índices de vegetación e imágenes satelitales.

3.2.3.2.7. Selección completa de subconjunto (Full Subset Selection)

De acuerdo con la metodología de los Mínimos Cuadrados Ordinarios (Ordinary Least Squares), la selección completa de subconjunto consiste en la selección óptima de todas las combinaciones posibles de todas las variables independientes (Índices de vegetación y bandas satelitales) que resulte en la variable dependiente (Conductividad eléctrica), para la presente investigación se usó todo el conjunto de datos que incluye 7 bandas satelitales 27 índices de vegetación. El número máximo de índices y bandas a usar para cada combinación fue establecido en un máximo de 5, y se usaron varios criterios estadísticos para determinar cuáles fueron las mejores combinaciones de VI, los criterios fueron: Criterio de información bayesiano (BIC), Mallows's Cp (CP), R cuadrado ajustado (R2ADJ), R cuadrado (R2) y Suma residual de cuadrados (RSS). Para la determinación de la selección completa de subconjunto se usó el software

RStudio, mediante el uso de las librerías “leaps” y “car” usando un criterio de búsqueda exhaustivo y las 3 mejores combinaciones para cada grupo de VI.

3.2.3.2.8. Construcción de modelos de aprendizaje automatizado

3.2.3.2.8.1. Regresión lineal (RL)

El modelo de regresión lineal es una de las herramientas más populares y simples para poder determinar las relaciones entre las variables dependientes e independientes (x-y). Todo esto bajo la suposición que esta relación es lineal y que la variable “y” puede expresarse como la suma ponderada de la variable “x”. También, los datos de ingreso deben contar con una distribución Gaussiana y bajo ruido en los datos (Zhang, Lipton, Li y Smola, 2021).

En el caso del aprendizaje automatizado (Machine Learning), se usa este algoritmo estadístico, principalmente para reducir el error del modelo predictivo, o tener las predicciones más exactas, para poder descubrir las relaciones entre los datos de ingreso mediante el ingreso de variables numéricas, por lo cual, en el campo del aprendizaje automatizado es una herramienta que se la presta de la estadística tradicional (Brownlee, 2016). Para la presente investigación se usó el modelo de regresión lineal con una validación cruzada de 10 iteraciones para la validación del modelo de regresión.

3.2.3.2.8.2. Perceptrón multicapa de retropropagación (MLP)

El perceptrón multicapa forma parte de las redes neuronales prealimentadas. Este consiste principalmente en 3 tipos de capas; la capa de ingreso, la capa de salida y la capa oculta, dentro del cual están los nodos y neuronas de la red.

En la capa de entrada esta recibe la señal de entrada que será procesada, mientras que los procesos de predicción y clasificación son resultantes de la capa de salida. Dentro de la capa oculta existe un número arbitrario de capas definidas

por el usuario y estas capas contienen las neuronas que son el corazón computacional del MLP. En el caso del MLP de retropropagación las neuronas son entrenadas mediante un algoritmo de retropropagación, con lo cual se reduce drásticamente el error resultante de la operación y está diseñado para aproximar una función continua y puede resolver problemas que no son separables linealmente. Los MLP son usados usualmente para clasificación de patrones, reconocimiento, aproximaciones y predicciones (Abirami y Chitra, 2020).

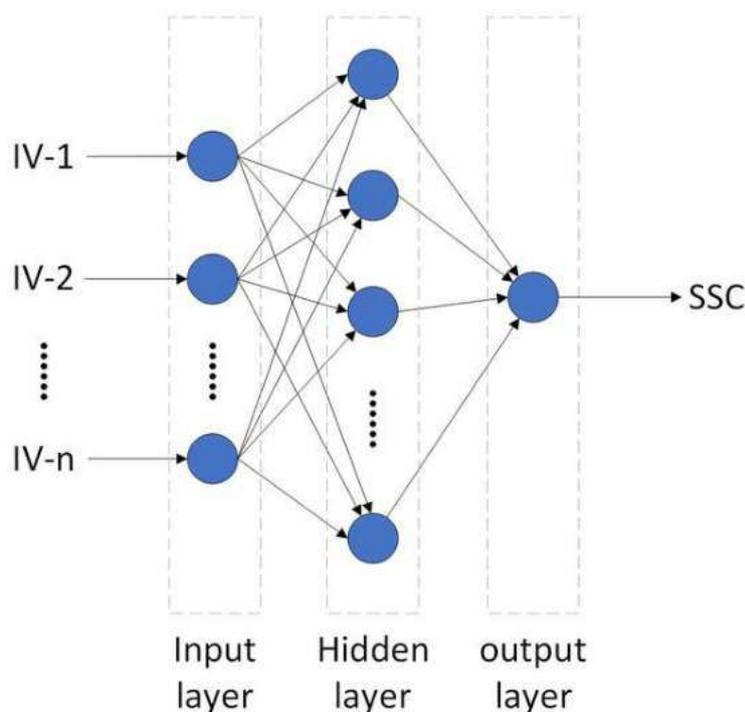


Figura 3. Estructura del perceptrón multicapa de retropropagación
Chen et al., 2020

3.2.3.2.8.3. Máquinas de vectores de soporte (SVM)

Las máquinas de vectores de soporte se originan en los trabajos de la teoría del aprendizaje estadístico que fue introducida en la década de los 90 por Vapnik. Los SVM fueron originalmente empleados para la resolución de problemas de clasificación binarios, sin embargo, hoy en día son usados para resolver problemas de multclasificación, regresión, asociación y agrupamiento (Mejía y Arboleda, 2019).

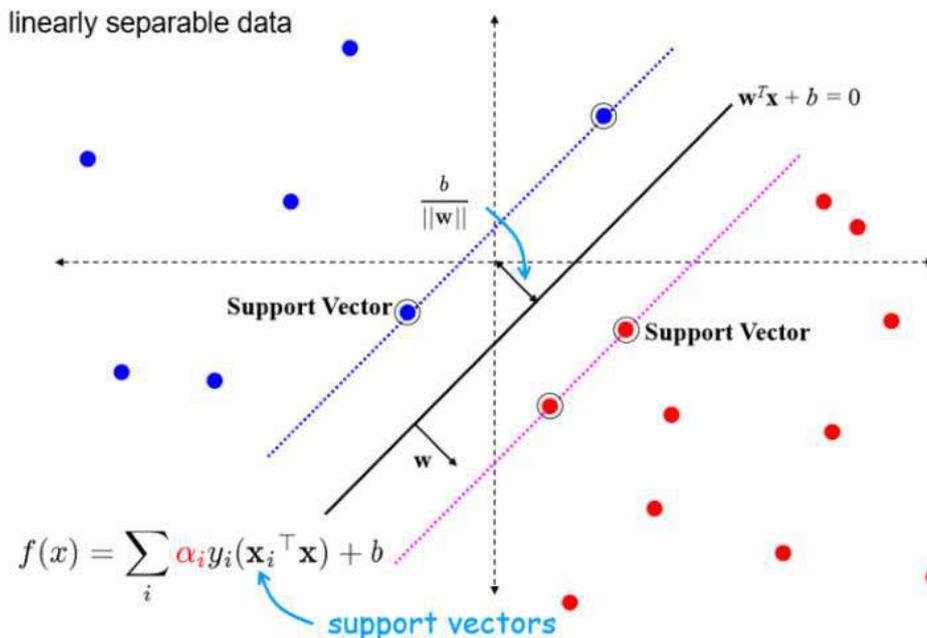


Figura 4. Estructura de los vectores de soporte
Duygulu, Moore, Zisserman y Tan, 2019

Las SVM se diferencian de las redes neuronales artificiales (ANN) en que estas no sufren del clásico problema multilocal de sobreajuste de datos y el efecto Hughes (Maldición de la dimensión). El sobreajuste ocurre cuando el modelo del aprendizaje automatizado produce un error de 0% en la información de entrenamiento, lo cual se traduce como un diseño de modelo erróneo. Debido a esto la minimización del riesgo estructural en lugar del riesgo empírico, como en el caso de las ANN, las SVM evitan el sobreajuste de datos (Awad y Khanna, 2015).

El enfoque de las SVM es la transformación de los datos de entrada en un espacio de características de alta dimensión, usando transformaciones no lineales para clasificación y regresión. Este algoritmo tiene ventajas como evitar valores discretos, reduciendo el sobreajuste y tiempo de computación reducido (Chen et al., 2020). Para la presente investigación se usó un núcleo de base radial (RBF) como la función núcleo del SVM, así como parámetros “c” y “g” optimizados. El algoritmo usado para la SVM fue el algoritmo de optimización

secuencial mínima (SMOReg) el cual es un método de aprendizaje supervisado que se basa en la regresión, el cual sirve para pronosticar nuevos datos usando datos de entrenamiento como entrada (Mejía y Arboleda, 2019).

3.2.3.2.8.4. Bosques aleatorios (RF)

El clasificador de bosques aleatorios es un método de conjuntos que entrena varios árboles de decisión en paralelo con bootstrapping seguido por agregación, los cuales se conocen como “bagging”. Bootstrapping indica que varios árboles de decisión son entrenados en paralelo sobre varios subconjuntos de los datos de entrenamiento usando diferentes subconjuntos de características disponibles. Esto es para asegurar que cada árbol de decisión en el RF sea único lo cual reduce la varianza de este clasificador. Para resultados finales este clasificador agrega las decisiones de cada árbol para dar una buena generalización sobre la clasificación de datos, sin caer en el sobreajuste que es muy común en las ANN (Misra y Li, 2020).

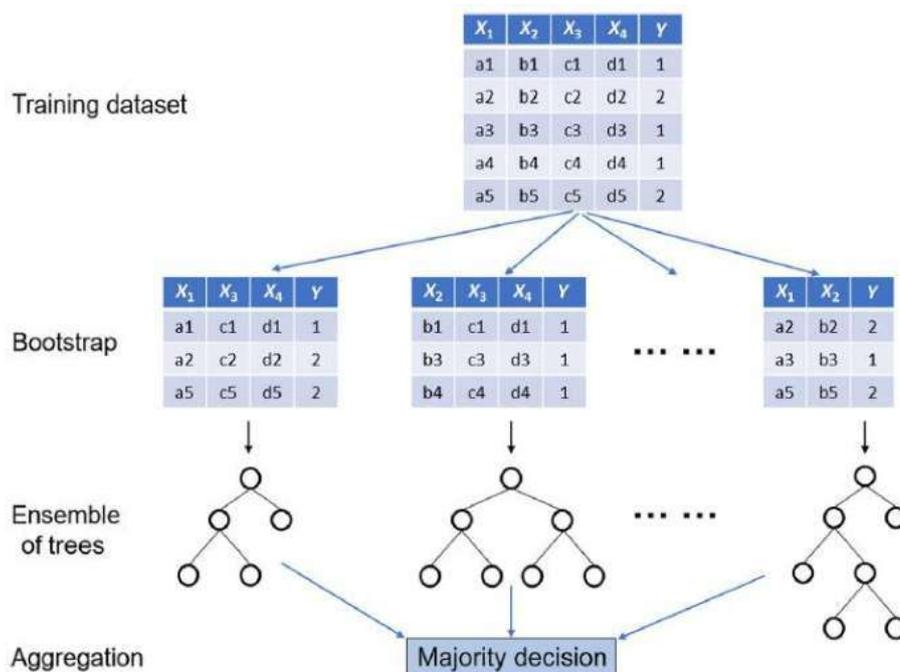


Figura 5. Estructura del clasificador “bosques aleatorios” (RF)
Chen et al., 2020

Basado en múltiples teorías de árboles de decisiones este algoritmo puede ser usado para clasificación de datos y regresión (Chen et al., 2020)

3.2.3.2.9. Diagrama de flujo para la determinación de salinidad mediante sensores remotos

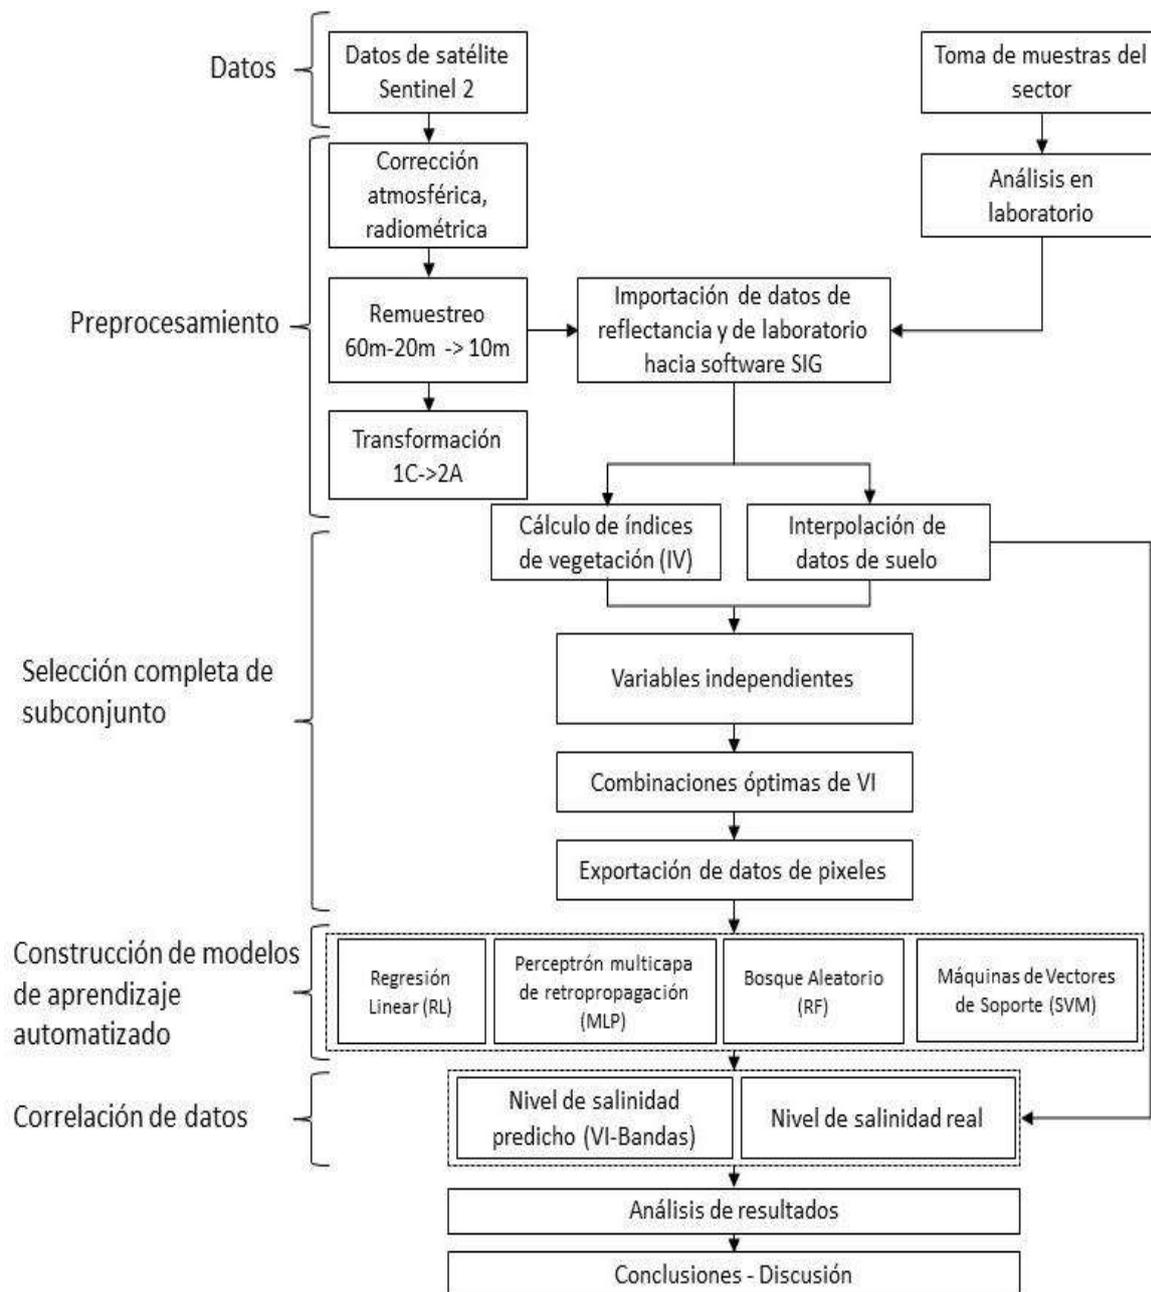


Figura 6. Diagrama de flujo de la investigación Manrique, 2021

3.2.3.2.10. Índices de vegetación y bandas satelitales

Tabla 5. Índices de salinidad y vegetación

Índice de vegetación (VI)	Formula	Fuente
NDVI (Normalized Difference Vegetation Index)	$NDVI = \frac{[NIR-R]}{[NIR+R]}$	(Huete, 1988)
SAVI (Soil Adjusted Vegetation Index)	$SAVI = (1 + L) * \frac{NIR-R}{NIR+R+L}$	(Alhammadi y Glenn, 2008)
VSSI (Vegetation Soil Salinity Index)	$VSSI = 2 * G - 5 * (B + R)$	(Dehni y Lounis, 2012)
EVI (Enhanced Vegetation Index)	$EVI = 2.5 * \left(\frac{NIR-R}{NIR+6*R-7.5*B+1} \right)$	(A. Huete et al., 2002)
ARVI (Atmospherically Resistant Vegetation Index)	$ARVI = \frac{[NIR - (2 * R) + B]}{[NIR + (2 * R) + B]}$	(EOS, 2019)
BI (Brightness Index)	$BI = \sqrt{R^2 + NIR^2}$	(Khan, Sato y Shiozawa, 2005)
BI2 (Brightness Index 2)	$BI2 = \frac{\sqrt{R^2+G^2}}{2}$	(Marques et al., 2020)
NDSI (Normalized difference salinity index)	$NDSI = \left[\frac{(R - NIR)}{(R + NIR)} \right]$	(Asfaw et al., 2018)
SI (Salinity Index)	$SI = \frac{(R-G)}{B}$	
SI1 (Salinity Index 1)	$SI1 = \sqrt{B * R}$	
SI2 (Salinity Index 2)	$SI2 = \sqrt{G * R}$	
SI3 (Salinity Index 3)	$SI3 = \sqrt{G^2 + R^2 + NIR^2}$	
SI4 (Salinity Index 4)	$SI4 = \sqrt{G^2 + R^2}$	(Elhag, 2016)
SI6 (Salinity Index 6)	$SI6 = \left[\frac{(B-R)}{(B+R)} \right]$	
SI7 (Salinity Index 7)	$SI7 = \frac{(G * R)}{B}$	
SI8 (Salinity Index 8)	$SI8 = \frac{(B * R)}{G}$	
SI9 (Salinity Index 9)	$SI9 = \frac{(NIR * R)}{G}$	

MSAVI (Modified Soil Adjusted Vegetation Index)	$MSAVI = \frac{2 * R + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - R)}}{2}$	
Salinity Index-T (SI-T)	$SIT = \frac{R}{\frac{NIR}{100}}$	
Canopy Response Salinity Index (CRSI)	$CRSI = \sqrt{\frac{NIR * R - G * B}{NIR * R + G * B}}$	
Intensity index 1 (INT1)	$INT1 = \frac{(G + R)}{2}$	
Intensity index 2 (INT2)	$INT2 = \frac{(G + R + NIR)}{2}$	(Chen et al., 2020)
Soil Moisture Monitoring Index (SMMI)	$SMMI = \frac{\sqrt{NIR^2 + SWIR11^2}}{\sqrt{2}}$	
Normalized Shortwave-infrared Difference SM Index 3 (NSDSI3)	$NSDSI3 = \left[\frac{(SWIR11 - SWIR12)}{(SWIR11 + SWIR12)} \right]$	
Normalized Multiband Drought Index (NMDI)	$NMDI = \frac{[NIR - (SWIR11 - SWIR12)]}{[NIR + (SWIR11 + SWIR12)]}$	
Normalized Difference Water Index (NDWI)	$NDWI = \left[\frac{(NIR - SWIR11)}{(NIR + SWIR11)} \right]$	
Visible and Shortwave Drought Index (VSDI)	$VSDI = 1 - (SWIR12 + R - B)$	

Manrique, 2021

Tabla 6. Parámetros de bandas Sentinel 2A

Banda	Centro de banda (mm)	Resolución espacial (m)
B1 (Aerosol costero)	443.9	60
B2 (Azul)	496.9	10
B3 (Verde)	560.0	10
B4 (Rojo)	664.5	10
B8 (Infrarrojo cercano)	835.1	10
B11 (SWIR11)	1613.7	20
B12 (SWIR12)	2202.4	20

Manrique, 2021

3.2.4 Análisis estadístico

Se usó un análisis estadístico descriptivo, para determinar si existe una correlación positiva entre la información tomada de las muestras de suelo del sector Daule y la información extraída de las imágenes satelitales multi espectrales.

Se usaron 4 modelos diferentes para identificar la relación entre las variables independiente y dependiente. Se usó un modelo de regresión lineal, un modelo de perceptrón multicapa de retropropagación (MLP), un algoritmo de máquina de vectores de soporte (SVM) y un clasificador de bosques aleatorios (RF) bajo parámetros optimizados para cada modelo establecido.

Los modelos cuentan con una validación cruzada estratificada de 10 iteraciones debido a que el ajuste de datos aplicado es elevado (PCA, selección de subconjunto de datos) y estos tienden a incrementar el sobreajuste de los modelos.

Además, se realizó un respectivo ajuste de datos que permitió una evaluación de los modelos más apto para ser procesados por el software.

Estos ajustes incluyen normalización y estandarización de los atributos establecidos, así como un ajuste mediante el uso de la regresión de mínimos cuadrados parciales (PLS) y análisis de componentes principales (PCA). Para este fin, fue usado el software de aprendizaje automatizado "WEKA" (Waikato Environment for Knowledge Analysis) y el software de programación "RStudio".

Los parámetros usados para evaluar los modelos de aprendizaje automatizado fueron el coeficiente de correlación de Pearson cuadrado ajustado (ADJR²), error absoluto medio (MAE) y raíz del error cuadrático medio (RMSE) y error relativo absoluto (RAE). Para AdjR², entre el valor está más cercano a 1 el modelo se

ajusta mejor a los datos, mientras que para los MAE y RMSE mientras el valor sea menor, menores desviaciones entre el valor de conductividad real y el predicho.

4. Resultados

4.1 Elaboración de una línea base de los suelos arroceros mediante el uso de SIG y teledetección.

El levantamiento de línea base de suelos del sector se realizó mediante la toma de 100 muestras del sector, en la tabla 7 se detallan los datos de conductividad eléctrica de las muestras tomadas, así como el peso seco de la muestra y peso húmedo.

Tabla 7. Conductividad eléctrica de muestras de zona de estudio

#M	PS (gr.)	PH (gr.)	CE (mS/cm)	#M	PS (gr.)	PH (gr.)	CE (mS/cm)
1	42,9	70,8	1,87	51	49,2	68,2	0,79
2	44,1	69,6	2,46	52	43	67,7	1,29
3	42,7	36,9	1,36	53	43,2	60,9	2,59
4	43,9	68,2	2,43	54	47,2	76,3	1,39
5	44,4	72	1,55	55	46,5	75,2	1,02
6	44,8	68,6	0,90	56	47	74,4	0,55
7	46,7	75,3	2,04	57	44,3	66,2	0,79
8	44,1	63,9	1,26	58	49,2	72,9	3,11
9	44,4	69,4	1,44	59	44	69,5	2,45
10	41,8	64,9	5,79	60	42,3	64,4	1,14
11	45,9	74,2	1,26	61	44,9	70,2	1,57
12	47,5	75,5	1,06	62	44,3	70,4	0,80
13	42	72,6	4,89	63	46,8	72,9	1,75
14	44,6	65,8	2,55	64	45,6	71,9	1,69
15	46,6	73,1	4,18	65	48,6	75,8	2,57
16	39,7	58,2	1,41	66	46,8	76,5	0,59
17	43	67,5	2,11	67	44,9	60	2,58
18	41,4	67,4	1,57	68	40	60,7	1,88
19	43,2	73,5	0,71	69	42,1	63	1,04
20	45,8	71,1	1,22	70	42,5	71,9	1,44
21	43,3	70,9	2,49	71	43,5	75,4	1,15
22	44,5	68,8	1,75	72	44,9	73,2	1,23
23	44,9	59,1	5,54	73	46,1	64,1	1,15
24	47,2	75,6	2,43	74	39,6	58,7	1,26
25	49,9	77,1	4,83	75	43	69,5	1,28
26	43,7	70,1	0,71	76	46,9	70,2	0,67
27	44,3	69,2	0,90	77	47,4	76	2,39
28	45,4	68,2	1,08	78	41,9	71,4	0,70

29	47,4	74,6	1,13	79	41,9	64,3	0,84
30	45,7	73,4	1,80	80	45,8	72,3	0,52
31	44	72,9	4,14	81	39,9	68,5	0,49
32	48,3	78,7	0,99	82	43,3	66,7	0,42
33	44,8	71,2	0,51	83	48	77	0,46
34	40,6	55,7	1,69	84	47,3	66,6	0,33
35	40,7	71,8	2,92	85	46,4	75,1	1,04
36	42,4	65,2	3,90	86	45,5	70,5	0,93
37	45,8	68,1	2,05	87	40,5	59,1	2,46
38	45,8	70,4	1,08	88	43,7	65,8	0,86
39	45	67,8	0,65	89	43,7	68,2	0,76
40	43,4	69,6	1,18	90	43,8	71,8	0,64
41	45,2	70	1,92	91	47,7	63,8	2,05
42	41,5	66	1,98	92	44,5	70	1,00
43	46,4	72	0,26	93	42,5	71,6	1,13
44	45,9	68,1	1,72	94	44,8	64	2,02
45	46,1	75,9	1,50	95	43,6	66,3	3,00
46	37,9	56	3,65	96	50,2	74,6	1,14
47	44,4	65,9	0,95	97	46	76	1,27
48	41,3	66,8	1,08	98	46,1	77,6	0,95
49	43,1	70,7	2,18	99	45	70,2	0,79
50	42,6	66,1	2,27	100	44,7	67,1	0,72

Donde “#M” es número de muestra, “PS (gr.)” es peso seco en gramos, “PH (gr.)” es peso húmedo en gramos y “CE (mS/cm)” es conductividad eléctrica en micro Siemens por centímetro.

Manrique, 2021

Con los datos de conductividad eléctrica del sector se realizó la respectiva interpolación de datos en el área de las zonas arroceras de Daule, en total se realizaron 5 interpolaciones basados en la metodología de Kriging Ordinario con 5 modelos de semivariograma de ajuste de datos, los modelos de semivariograma implementados fueron esférico, lineal, gaussiano, circular y exponencial. Los resultados de las interpolaciones se aprecian en las figuras 7 – 8 – 9 – 10 – 11, en los cuales se detallan las condiciones de salinidad en rangos establecidos para facilidad de lectura, se detalla la superficie de cada clasificación de salinidad en hectáreas, así como el perímetro de las áreas en kilómetros:

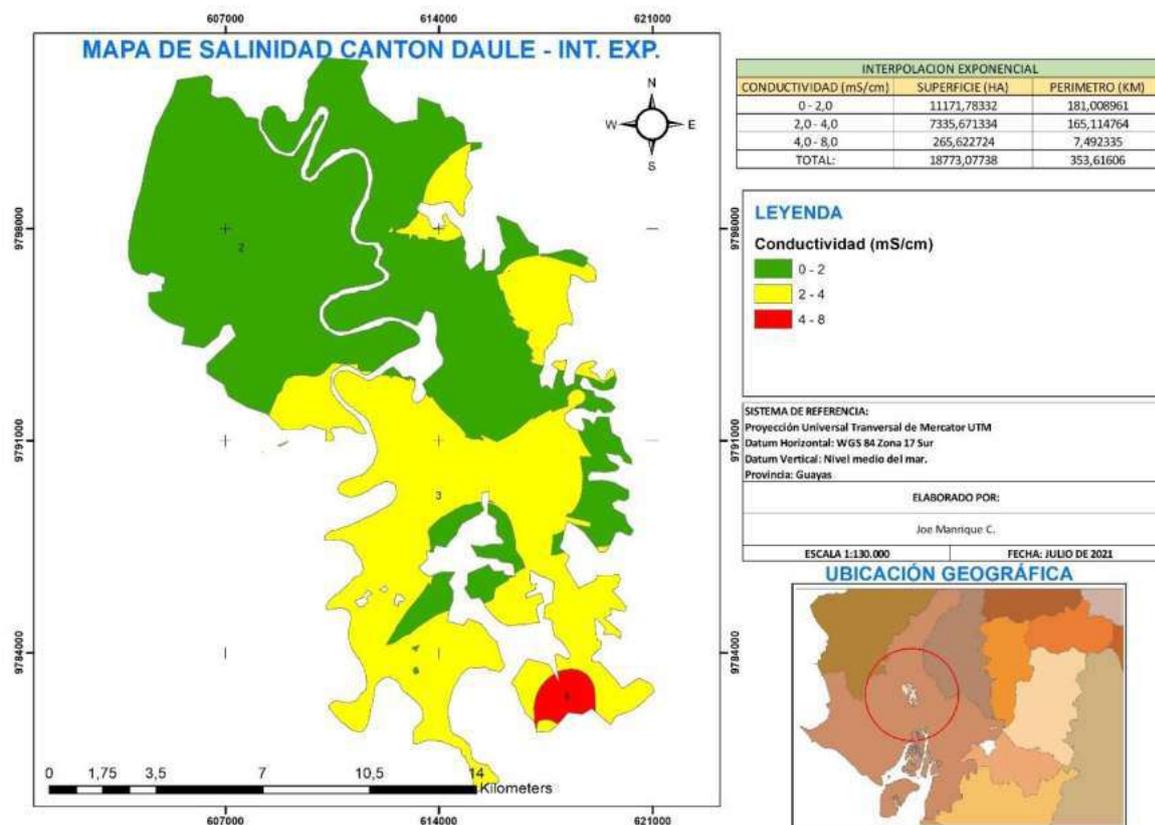


Figura 7. Resultados de interpolación con semivariograma exponencial Manrique, 2021

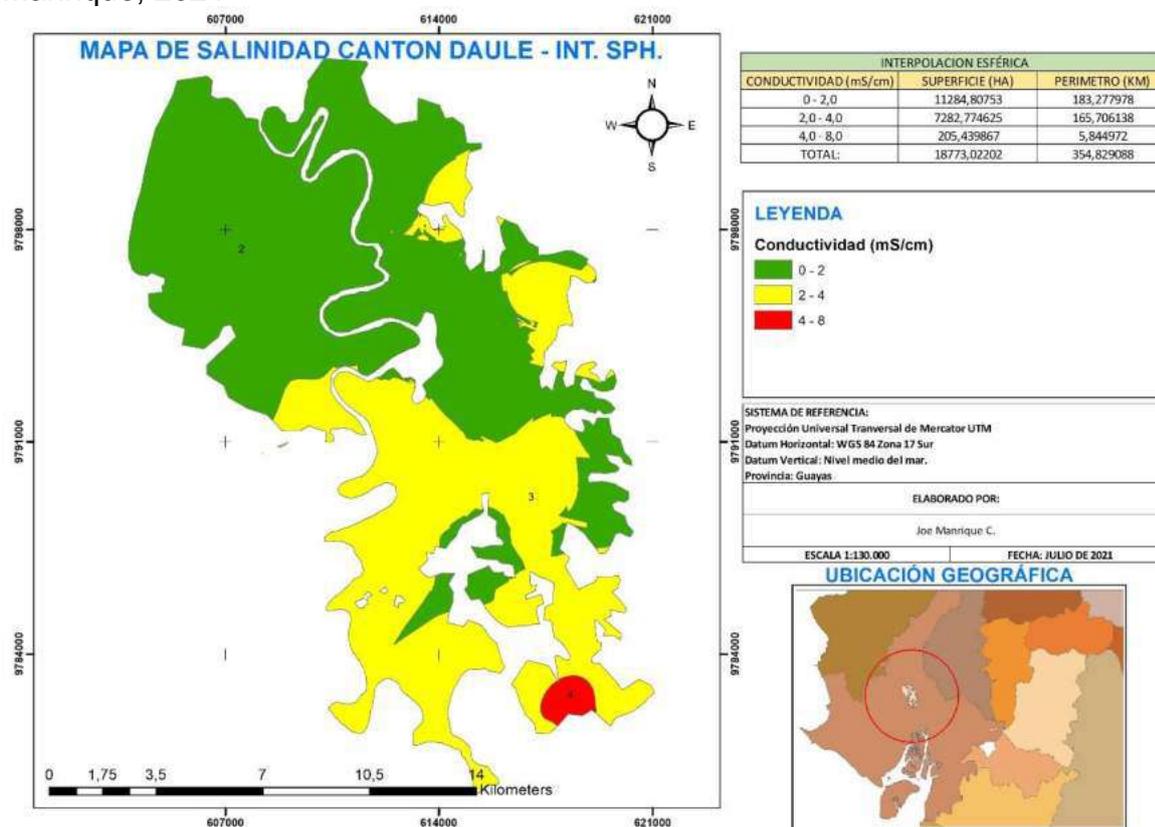


Figura 8. Resultados de interpolación con semivariograma esférico Manrique, 2021

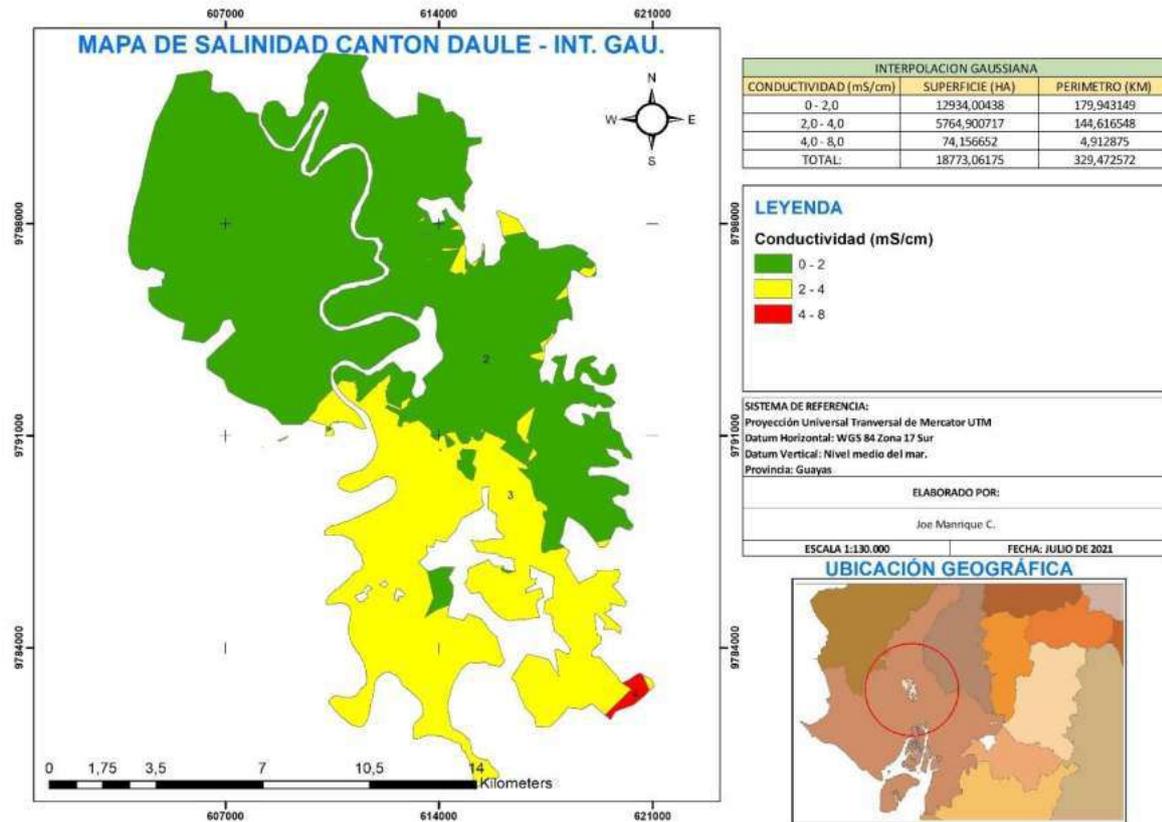


Figura 9. Resultados de interpolación con semivariograma gaussiano Manrique, 2021

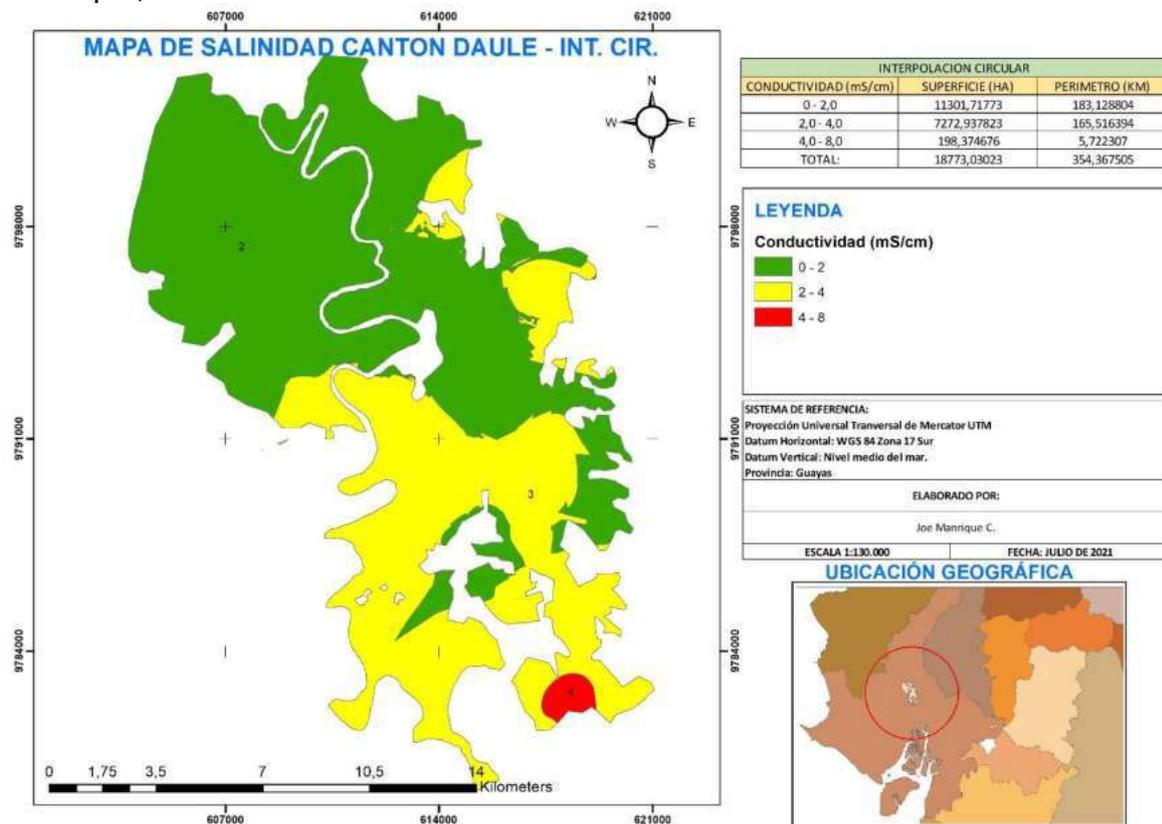


Figura 10. Resultados de interpolación con semivariograma circular Manrique, 2021

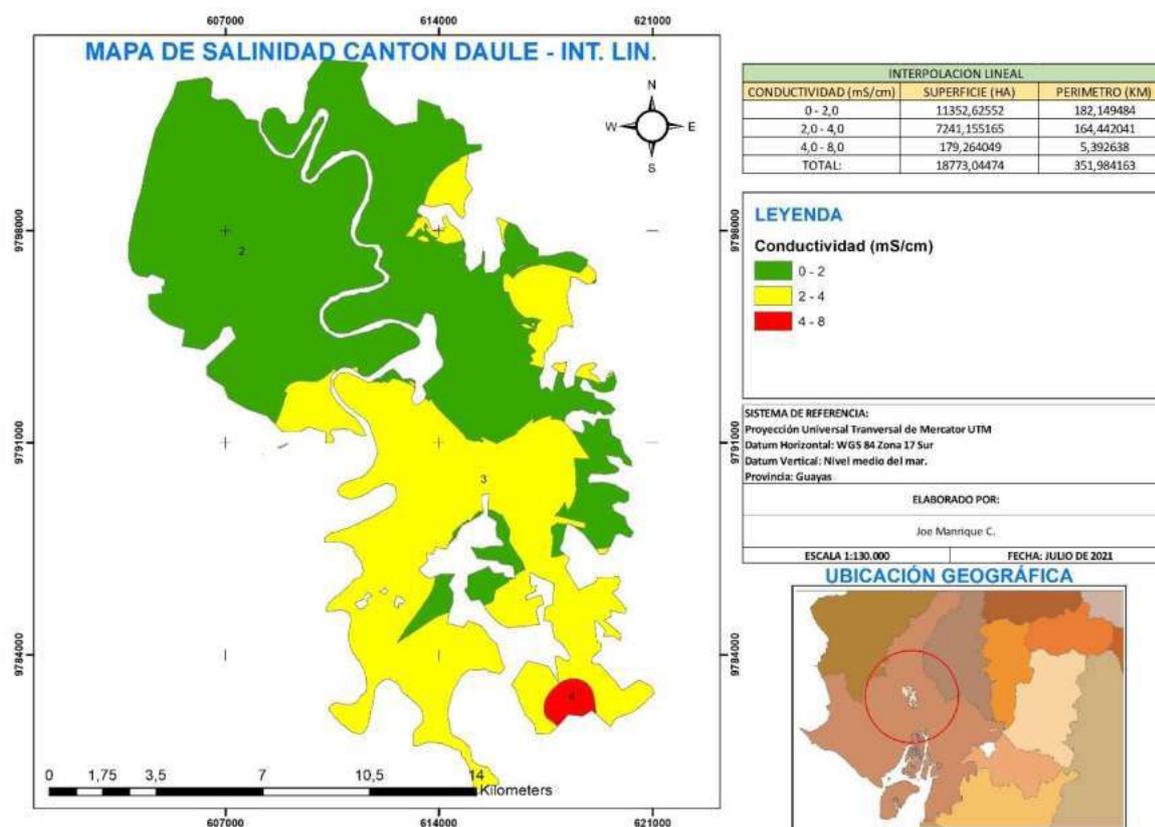


Figura 11. Resultados de interpolación con semivariograma lineal Manrique, 2021

Los datos de superficie y perímetro para los rangos de conductividad eléctrica de las interpolaciones se resumen en las siguientes tablas:

Tabla 8. Datos de Interpolación lineal

Rangos de CE	Superficie (Ha)	Perímetro (Km)
0,0 - 2,0	11352,62552	182,149484
2,0 - 4,0	7241,155165	164,442041
4,0 - 8,0	179,264049	5,392638

Manrique, 2021

Tabla 9. Datos de Interpolación exponencial

Rangos de CE	Superficie (Ha)	Perímetro (Km)
0 - 2,0	11171,78332	181,008961
2,0 - 4,0	7335,671334	165,114764
4,0 - 8,0	265,622724	7,492335

Manrique, 2021

Tabla 10. Datos de Interpolación esférica

Rangos de CE	Superficie (Ha)	Perímetro (Km)
0 - 2,0	11284,80753	183,277978
2,0 - 4,0	7282,774625	165,706138
4,0 - 8,0	205,439867	5,844972

Manrique, 2021

Tabla 11. Datos de Interpolación gaussiana

Rangos de CE	Superficie (Ha)	Perímetro (Km)
0 - 2,0	12934,00438	179,943149
2,0 - 4,0	5764,900717	144,616548
4,0 - 8,0	74,156652	4,912875

Manrique, 2021

Tabla 12. Datos de Interpolación circular

Rangos de CE	Superficie (Ha)	Perímetro (Km)
0 - 2,0	11301,71773	183,128804
2,0 - 4,0	7272,937823	165,516394
4,0 - 8,0	198,374676	5,722307

Manrique, 2021

4.2 Estimación de los niveles la salinidad en las zonas arroceras del cantón Daule.

4.2.1 Interpolación de datos

Para determinar cuál modelo de semivariograma de interpolación fue usado se extrajeron 200 puntos aleatorios de los rasters, y se determinaron sus características estadísticas como mínimo, máximo, media, desviación estándar y coeficiente de variación, de esta información se estableció que la interpolación con semivariograma de menor variabilidad de datos y más estabilidad (CV y STD.DEV.) será la usada para el modelo de salinidad a implementar.

Tabla 13. Características estadísticas de interpolaciones

INT.	DATOS	NUM	MIN (CE)	MAX (CE)	MED	STD.DEV.	CV (%)
Esférica	Total	197	0,589	3,818	1,697	0,636	37,478
	Calibración	130	0,589	3,818	1,918	0,629	32,795
	Validación	67	0,596	2,417	1,266	0,378	29,858
Circular	Total	197	0,593	3,82	1,697	0,634	37,360
	Calibración	130	0,593	3,82	1,918	0,627	32,690
	Validación	67	0,6	2,413	1,267	0,376	29,676
Gaussiana	Total	197	0,789	3,943	1,693	0,602	35,558
	Calibración	130	0,789	3,943	1,91	0,607	31,780
	Validación	67	0,806	2,157	1,273	0,293	23,016
Linear	Total	197	0,605	3,82	1,696	0,630	37,146
	Calibración	130	0,605	3,82	1,917	0,623	32,499
	Validación	67	0,614	2,402	1,267	0,369	29,124
Exponencial	Total	197	0,551	3,794	1,698	0,651	38,339
	Calibración	130	0,551	3,794	1,922	0,643	33,455
	Validación	67	0,556	2,434	1,265	0,400	31,621

Para establecer la relación entre las variables dependientes y la variable dependiente se usó el software de aprendizaje automatizado WEKA, se usó un evaluador de correlación de atributos para establecer el coeficiente de correlación entre VI y VD, así como un método de búsqueda mediante categorización. Los resultados se presentan en la siguiente figura:

```

=== Attribute Selection on all input data ===

Search Method:
    Attribute ranking.

Attribute Evaluator (supervised, Class (numeric): 1 GAU):
    Correlation Ranking Filter

Ranked attributes:
0.24077   26 VSDI           0.04414   21 INT2
0.22165   30 COASTAL AEROSOL  0.01307   9  SI1
0.17079   17 SI_T             0.00909   24 NMDI
0.16813   31 BLUE            -0.07214  11  SI3
0.15164   32 GREEN           -0.08864   8  SI
0.15137    4 MSAVI            -0.09564  29  MSI
0.14742   20 INT1           -0.10017  19  BI
0.14499   10 SI2         -0.12433  16  SI9
0.14495   15 SI8         -0.12524  36  SWIR12
0.14411   12 SI4         -0.12616  34  NIR
0.14104   27 BI2         -0.14695  22  SMMI
0.13432   33 RED         -0.15213   6  ARVI
0.12113   28 NDSI        -0.16094   3  SAVI
0.10284    5 VSSI        -0.17243  18  CRSI
0.1026    14 SI7         -0.17244   2  NDVI
0.09077   25 NDWI        -0.17318  35  SWIR11
0.08184   13 SI6

```

Figura 12. Evaluador de correlación (R cuadrado) entre variables independientes (índices de vegetación y bandas) y variable dependiente (Conductividad eléctrica). Manrique, 2021

Las VI que guardan más relación con la conductividad eléctrica son el índice de sequía visible y de onda corta (VSDI), la banda satelital 1 (Coastal Aerosol), el índice de salinidad T (SI-T) y la banda satelital 2 (Blue). Sin embargo, los valores de relación fueron muy bajos e inconcluyentes por lo que se prosiguió a tomar otra propuesta para el procesamiento de datos.

La metodología usada fue la selección completa de subconjunto de atributos mediante la metodología de los Mínimos Cuadrados Ordinarios, el cual, mediante diversos criterios estadísticos, se establecen las combinaciones óptimas de VI que resulten en la VD. Para la óptima selección completa de subconjunto de atributos se usaron 5 criterios estadísticos: Criterio de información bayesiano (BIC), Mallows's Cp (CP), R cuadrado ajustado (R2ADJ), R cuadrado (R2) y Suma residual de cuadrados (RSS). El total de combinación de VI se puede observar en el anexo 4.

Las combinaciones de variables independientes con mejores resultados se establecen en la siguiente figura:

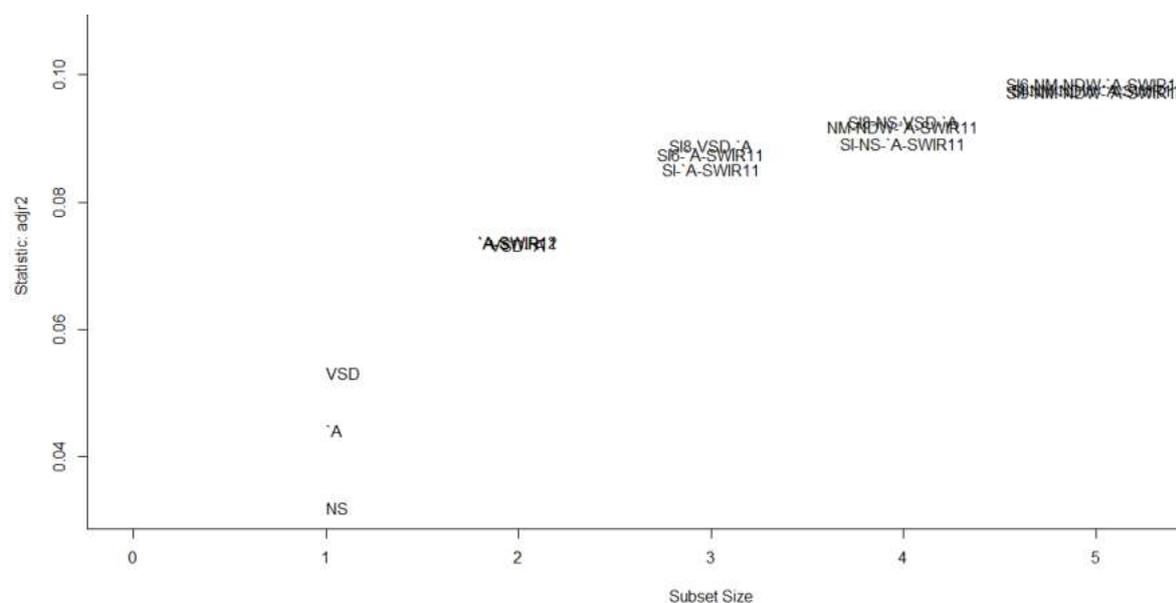


Figura 13. Selección completa de subconjunto para R cuadrado ajustado (R2ADJ) Manrique, 2021

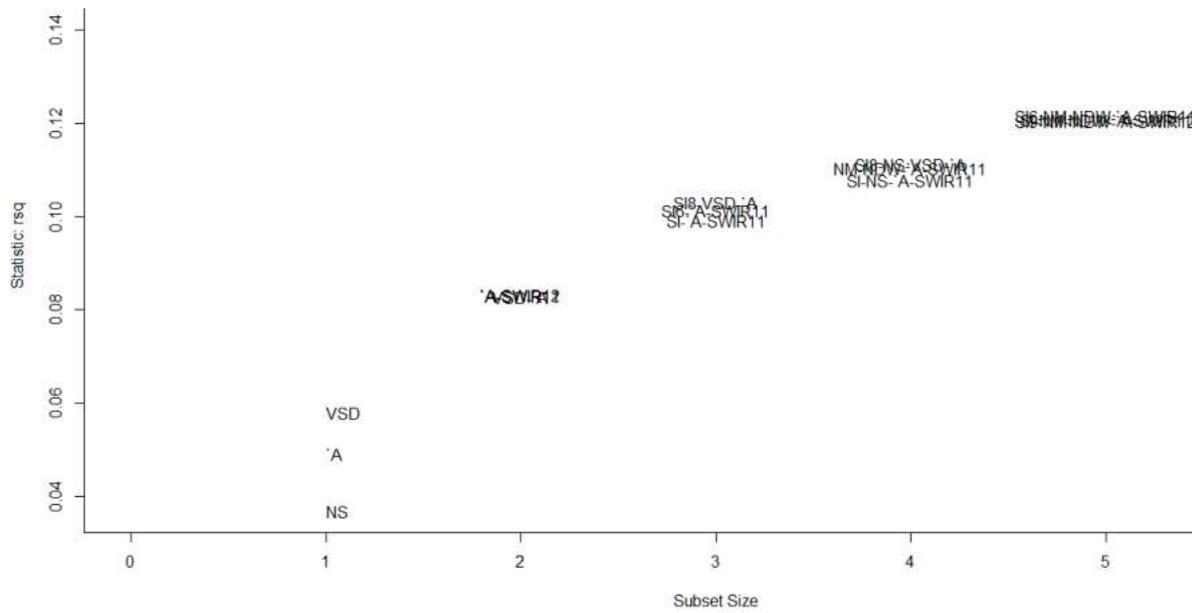


Figura 14. Selección completa de subconjunto para R cuadrado (R²) Manrique, 2021

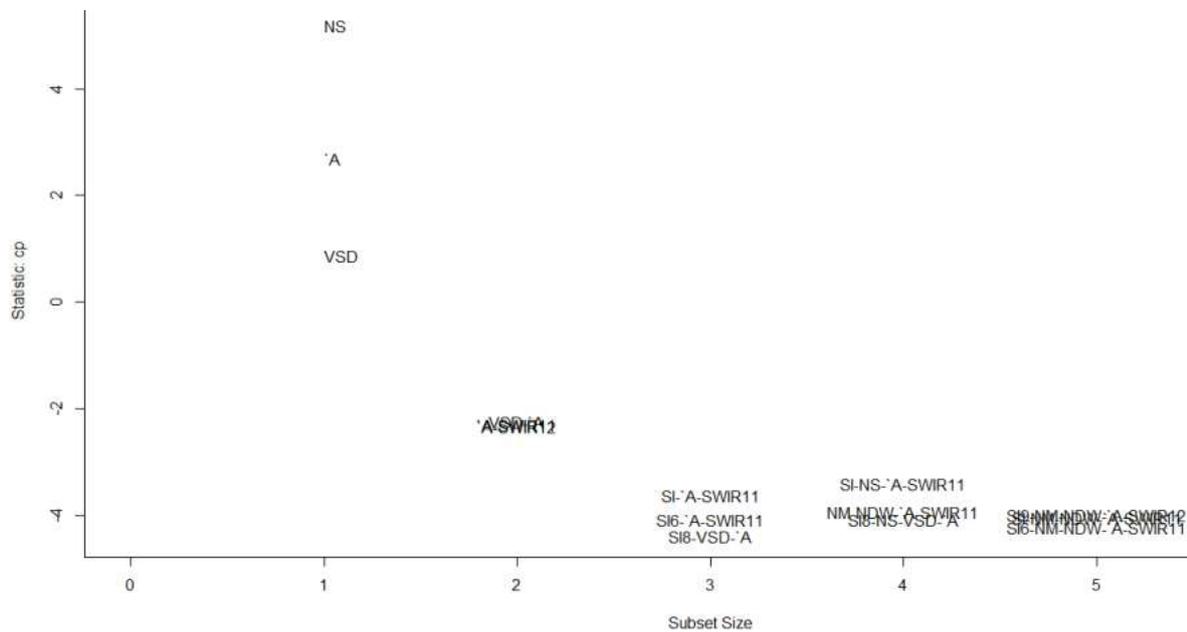


Figura 15. Selección completa de subconjunto para Mallows's Cp (CP), Manrique, 2021

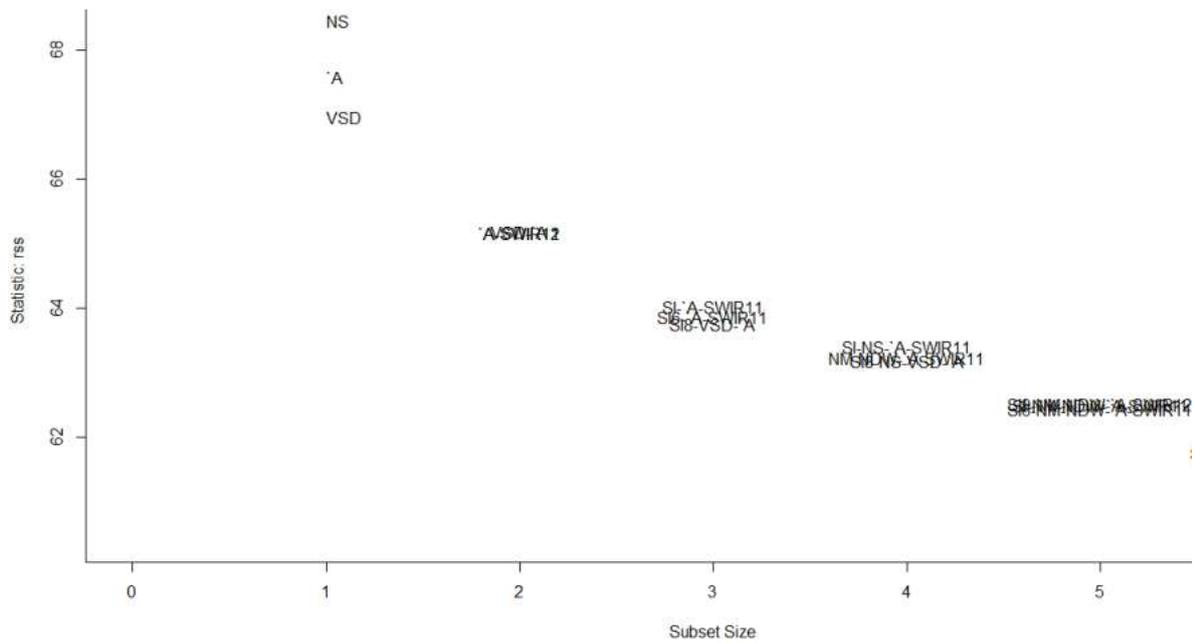


Figura 16. Selección completa de subconjunto para suma residual de cuadrados (RSS).

Manrique, 2021

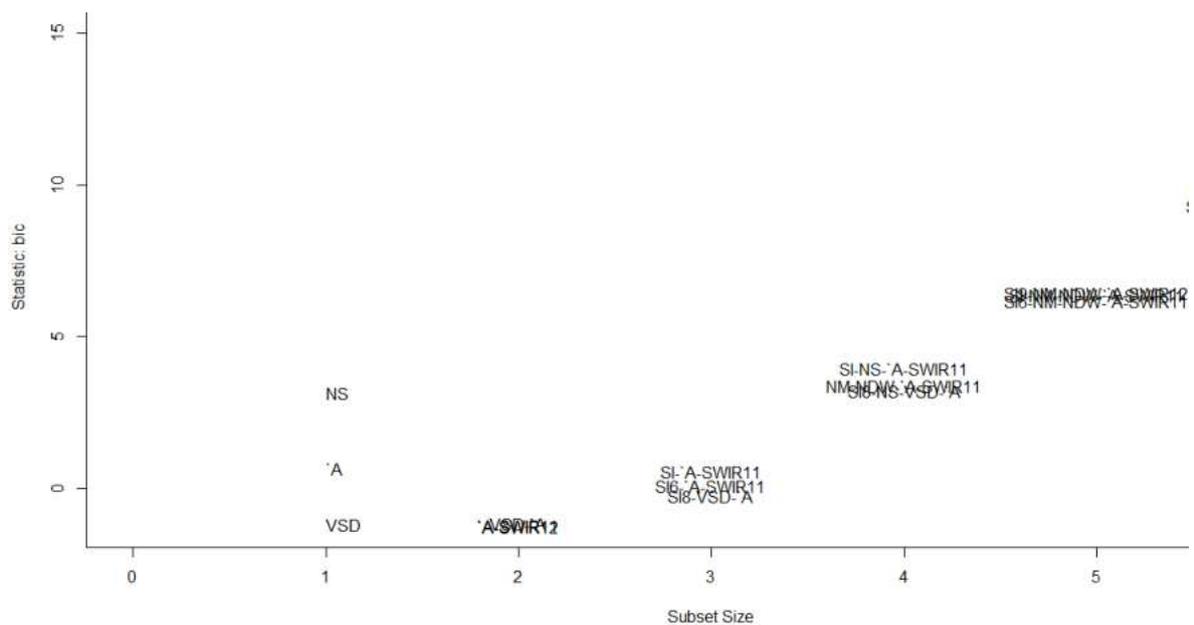


Figura 17. Selección completa de subconjunto para Criterio de información bayesiano (BIC).

Manrique, 2021

4.2.2 Resultados de modelos de aprendizaje automatizado

4.2.2.1 Regresión Linear

Para el modelo de regresión linear se usó el método de selección de atributos M5 (basado en el criterio de información Akaike), con eliminación de atributos colineales. Para este modelo se usó el subconjunto de datos ya calculado anteriormente. En la siguiente figura se puede observar el modelo de regresión linear resultante, así como los datos estadísticos necesarios para la validación de este modelo:

```

Linear Regression Model

CONDUCTIVIDAD =

-583.1783 * NMDI-NDWI-CA-SWIR11 +
 210.5155 * SI-NSDSI3-CA-SWIR11 +
-23.626 * SI-CA-SWIR11 +
 1.0006 * SI3-VSSI +
 2.3111 * NSDSI3-SI-VSDI +
-1325.9984 * SI3-SIT-VSSI-NSDSI3 +
 164.4276 * MSAVI-NDWI-NMDI-SI-B11 +
-32.6023 * B1-NSDSI3-NMDI +
 117.5619 * B1-NDVI-NDWI-NMDI +
 0.541 * Clase=Low Saline,Lightly Saline +
 1.0275 * Clase=Lightly Saline +
 1.2453

Time taken to build model: 0 seconds

=== Cross-validation ===
=== Summary ===

Correlation coefficient           0.8251
Mean absolute error              0.2647
Root mean squared error          0.3424
Relative absolute error          53.6314 %
Root relative squared error      56.7198 %
Total Number of Instances       197

```

Figura 18. Modelo de regresión linear para conductividad eléctrica (VD) Manrique, 2021

En la figura 19 se muestra los errores clasificados por el software, se tiene en el eje "X" la conductividad real tomada de las muestras de suelo y en el eje "Y" la conductividad resultante del modelo de regresión lineal calculado por el software.

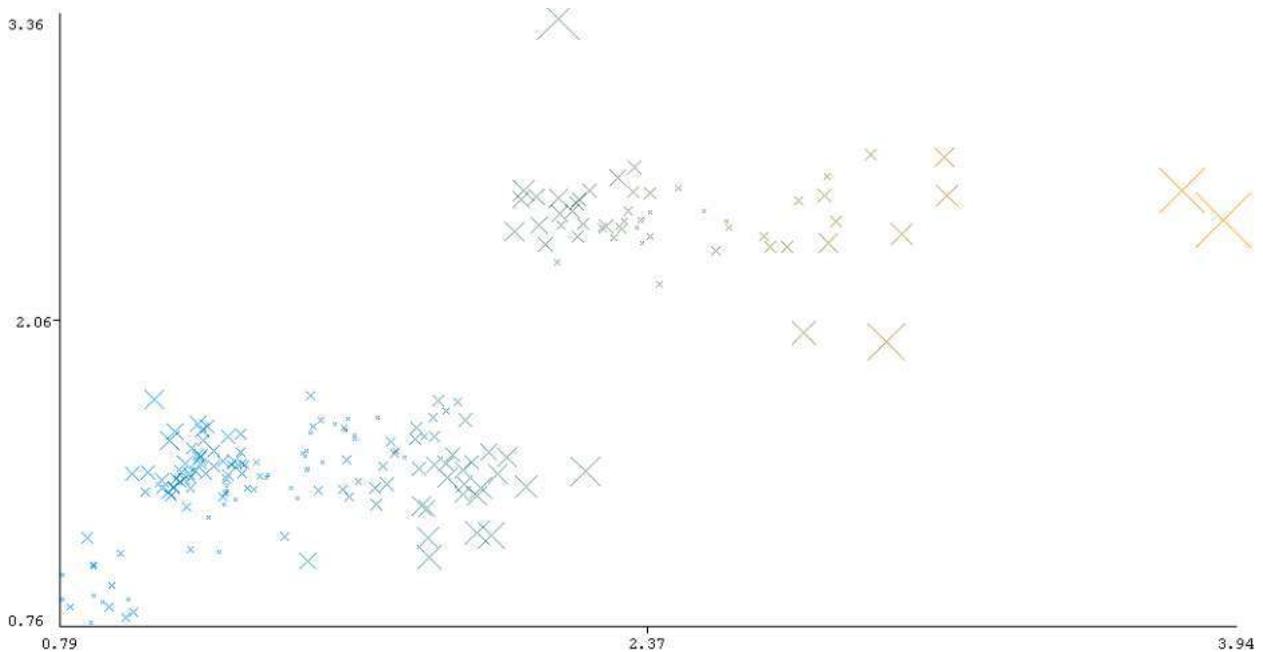


Figura 19. Visualización de errores clasificados del modelo de regresión lineal (Eje X, Conductividad real – Eje Y, conductividad predicha por el modelo).
Manrique, 2021

4.2.2.2. Perceptrón multicapa de retropropagación

Para el algoritmo de MLP, se usaron un total de 5 capas para el diseño de la red, una capa de entrada, una capa de salida y tres capas ocultas. Para la capa oculta se tuvo una configuración de 15 – 20 – 15 neuronas distribuidas en las 3 capas como se presenta en la figura 20.

Los parámetros del algoritmo fueron: para la tasa de aprendizaje de 0.5, un momento de 0.3, se aplicaron filtros de normalización para los atributos y clases, así como un filtro binario para la clase nominal y un tiempo de entrenamiento de 500. Las variables independientes son los datos de entrada y la conductividad eléctrica predicha es la de salida. Se uso una verificación cruzada de 10 iteraciones para la evaluación del modelo a implementar.

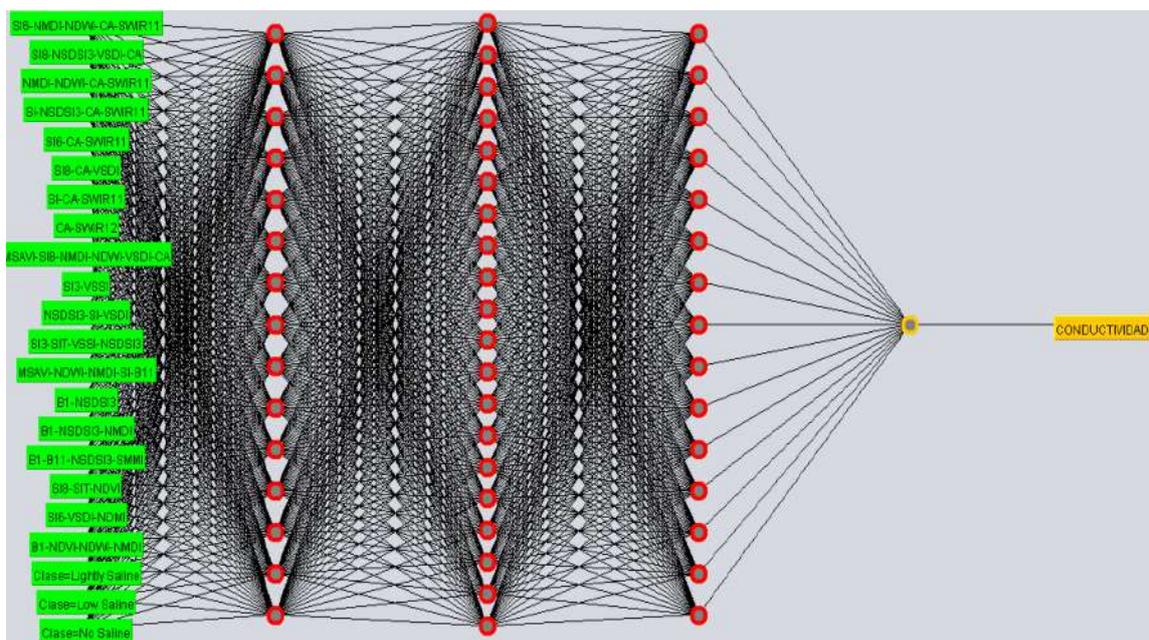


Figura 20. Diseño de la red, con 3 capas ocultas.
Manrique, 2021

En la figura 21 se pueden observar los datos estadísticos necesarios para la validación de este modelo:

```

=== Cross-validation ===
=== Summary ===

Correlation coefficient           0.7624
Mean absolute error              0.4303
Root mean squared error          0.5531
Relative absolute error          68.7445 %
Root relative squared error      72.2443 %
Total Number of Instances       197

```

Figura 21. Datos estadísticos del modelo de MLP.
Manrique, 2021

En la figura 22 se muestra los errores clasificados por el software, se tiene en el eje “X” la conductividad real tomada de las muestras de suelo y en el eje “Y” la conductividad resultante del modelo de MLP calculado por el software.

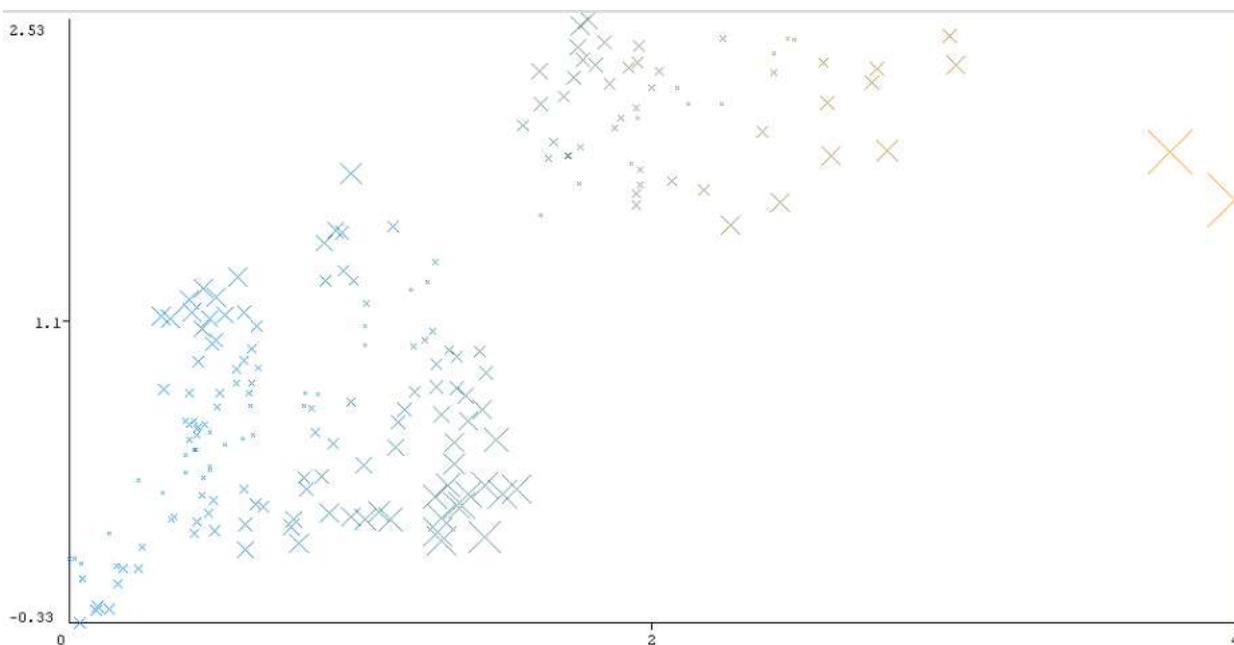


Figura 22. Visualización de errores clasificados del modelo de MLP (Eje X, Conductividad real – Eje Y, conductividad predicha por el modelo).
Manrique, 2021

4.2.2.3. Máquinas de vectores de soporte

Para el algoritmo de SVM, se usó un núcleo “Polykernel” con un exponente de 1.0, un parámetro de complejidad “C” de 1.5, estandarización de datos de entrada, y un optimizador “RegSMOimproved” con la variante 1 como parámetro de optimización del algoritmo. El modelo implementado se lo puede visualizar en la Figura 23, en el cual se puede detallar los factores de ponderación y las variables independientes.

```

=== Classifier model (full training set) ===

SMOreg

weights (not support vectors):
+ 0.004 * (standardized) SI6-NMDI-NDWI-CA-SWIR11
- 0.4799 * (standardized) SI8-NSDSI3-VSDI-CA
- 0.3534 * (standardized) NMDI-NDWI-CA-SWIR11
+ 0.1883 * (standardized) SI-NSDSI3-CA-SWIR11
- 0.0473 * (standardized) SI6-CA-SWIR11
+ 0.4611 * (standardized) SI8-CA-VSDI
+ 0.0879 * (standardized) SI-CA-SWIR11
+ 0.3167 * (standardized) CA-SWIR12
- 0.1054 * (standardized) MSAVI-SI8-NMDI-NDWI-VSDI-CA
+ 0.2098 * (standardized) SI3-VSSI
+ 0.1187 * (standardized) NSDSI3-SI-VSDI
- 0.2704 * (standardized) SI3-SIT-VSSI-NSDSI3
+ 0.2355 * (standardized) MSAVI-NDWI-NMDI-SI-B11
+ 0.2217 * (standardized) B1-NSDSI3
- 0.0314 * (standardized) B1-NSDSI3-NMDI
- 0.2831 * (standardized) B1-B11-NSDSI3-SMMI
- 0.0532 * (standardized) SI8-SIT-NDVI
+ 0.0445 * (standardized) SI6-VSDI-NDMI
+ 0.0899 * (standardized) B1-NDVI-NDWI-NMDI
+ 0.4826 * (standardized) Clase=Lightly Saline
- 0.2533 * (standardized) Clase=Low Saline
- 0.3623 * (standardized) Clase=No Saline
- 0.1169

```

Figura 23. Modelo del algoritmo de SVM.
Manrique, 2021

En la figura 24 se pueden observar los datos estadísticos necesarios para la validación de este modelo.

```

Number of kernel evaluations: 19503 (99.634% cached)

Time taken to build model: 0.13 seconds

=== Cross-validation ===
=== Summary ===

Correlation coefficient           0.8455
Mean absolute error              0.3128
Root mean squared error         0.4156
Relative absolute error         49.9728 %
Root relative squared error     54.2814 %
Total Number of Instances       197
  
```

Figura 24. Datos estadísticos del modelo de SVM.
Manrique, 2021

En la figura 25 se muestra los errores clasificados por el software, se tiene en el eje “X” la conductividad real tomada de las muestras de suelo y en el eje “Y” la conductividad resultante del modelo de SVM calculado por el software.

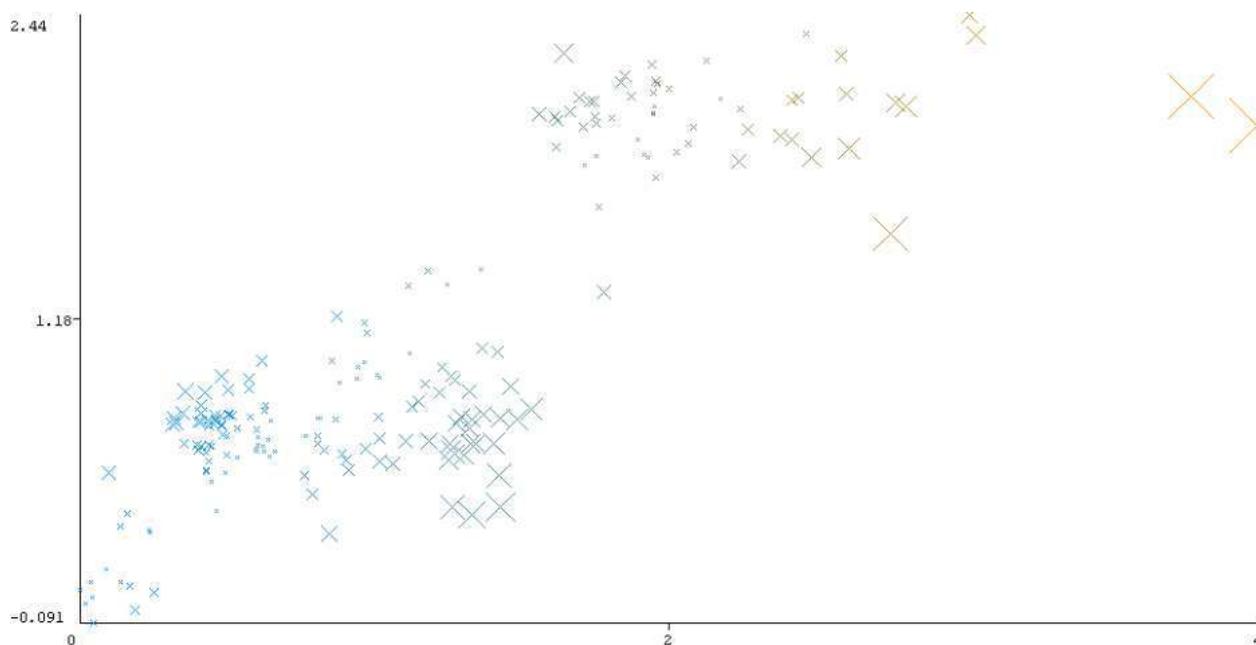


Figura 25. Visualización de errores clasificados del modelo de SVM (Eje X, Conductividad real – Eje Y, conductividad predicha por el modelo).
Manrique, 2021

4.2.2.4. Bosques Aleatorios

Para el algoritmo de clasificación de bosques aleatorios (RF) se usó una validación cruzada estratificada de 10 iteraciones, para los parámetros del algoritmo se estableció que se tienen que romper los lazos al azar, sin una profundidad de árboles establecida y un total de 100 iteraciones (100 árboles) en el bosque aleatorio. En la figura 26 se pueden observar los datos estadísticos necesarios para la validación de este modelo.

```
Bagging with 100 iterations and base learner
weka.classifiers.trees.RandomTree -K 0 -M 1.0 -V 0.001 -S 1 -do-not-check-capabilities
Time taken to build model: 0.07 seconds
=== Cross-validation ===
=== Summary ===
Correlation coefficient          0.8476
Mean absolute error             0.33
Root mean squared error        0.4183
Relative absolute error        52.7168 %
Root relative squared error    54.6333 %
Total Number of Instances      197
```

Figura 26. Datos estadísticos del modelo de RF.
Manrique, 2021

En la figura 27 se muestra los errores clasificados por el software, se tiene en el eje “X” la conductividad real tomada de las muestras de suelo y en el eje “Y” la conductividad resultante del modelo de RF calculado por el software.

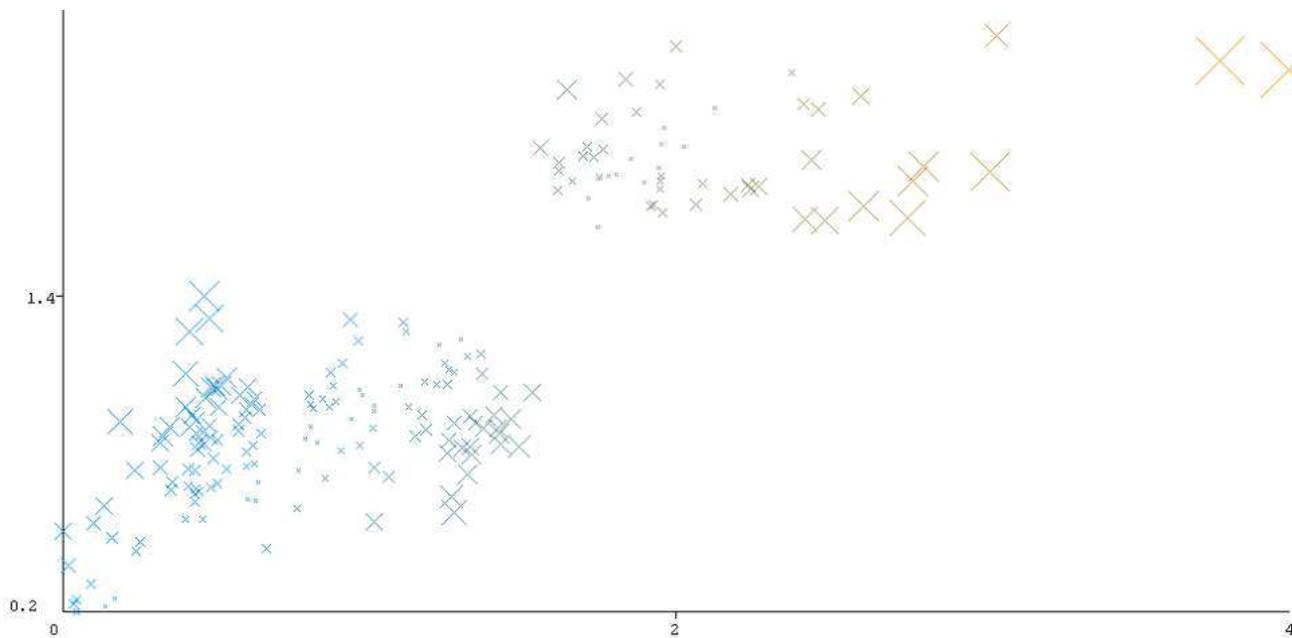


Figura 27. Visualización de errores clasificados del modelo de RF (Eje X, Conductividad real – Eje Y, conductividad predicha por el modelo). Manrique, 2021

4.2.3 Evaluación de modelos de aprendizaje automatizado

Para la evaluación se tomaron en cuenta 4 criterios estadísticos, estos fueron: coeficiente de correlación de Pearson cuadrado ajustado (ADJR2), error absoluto medio (MAE) y raíz del error cuadrático medio (RMSE) y error relativo absoluto (RAE), los cuales fueron evaluados en cada algoritmo de aprendizaje automatizado establecido. En el caso de ADJR2 valores más cercanos al número 1, indica que el modelo predice mejor los datos de salida, y existe un buen ajuste de datos y rendimiento del algoritmo. Para valores de MAE, RSME Y RAE, entre menores sean los valores indica que hubo un menor número de instancias clasificadas de manera errónea, así como un mejor desempeño y ajuste del algoritmo. En la figura 28 se detallan los valores estadísticos mencionados de cada modelo empleado:

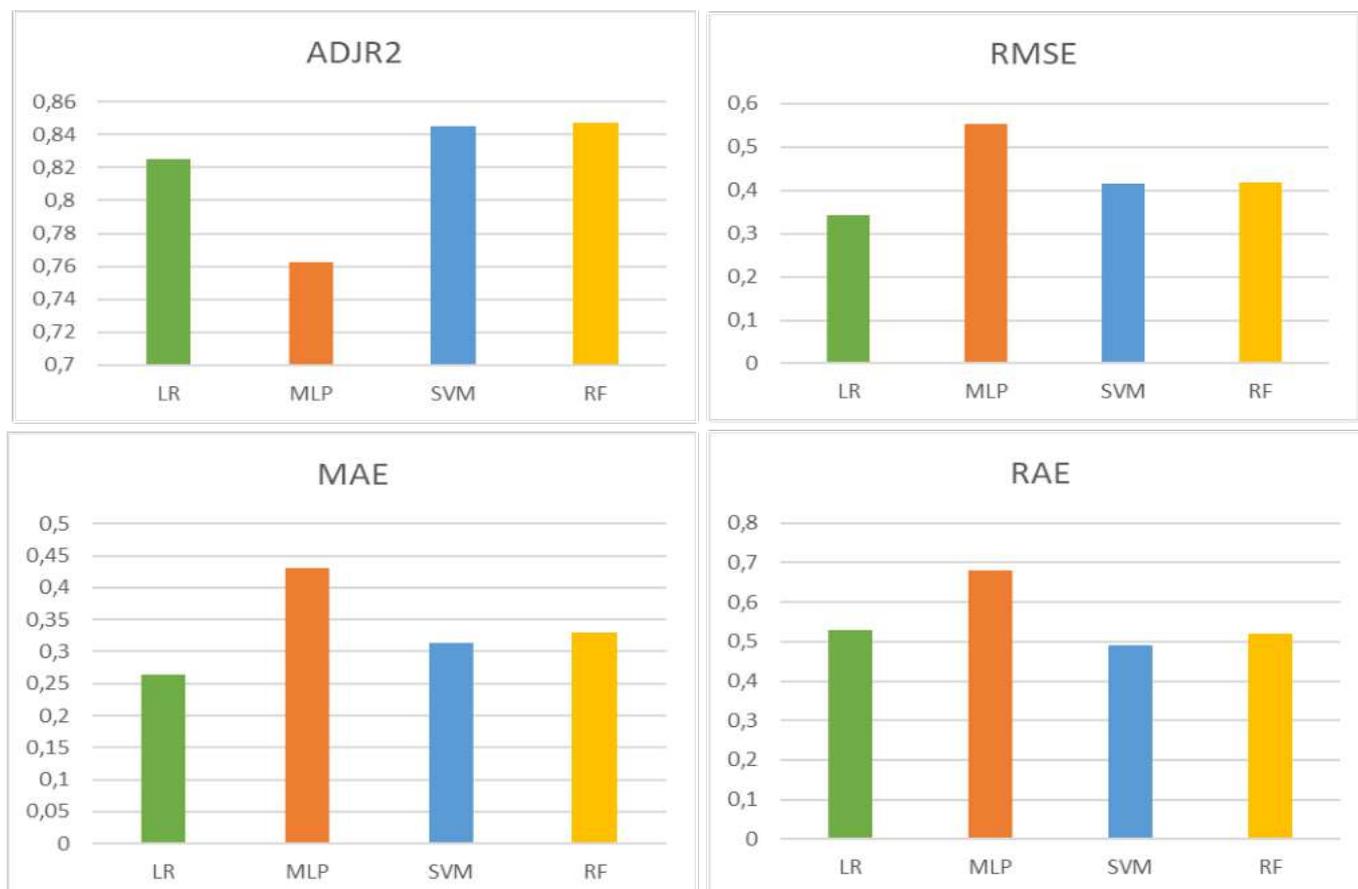


Figura 28. Criterios estadísticos para selección de modelo.
Manrique, 2021

4.3 Establecimiento de recomendaciones para un buen uso del recurso suelo en la zona de estudio.

Aproximadamente 5800 hectáreas del sector se encuentran con niveles de conductividad eléctrica mayores a 2 mS/cm, de estas, 1200 hectáreas presentan una conductividad eléctrica mayor a 3 mS/cm y cerca de 100 hectáreas tiene una CE mayor a 4 mS/cm, lo cual se puede observar en la siguiente figura:

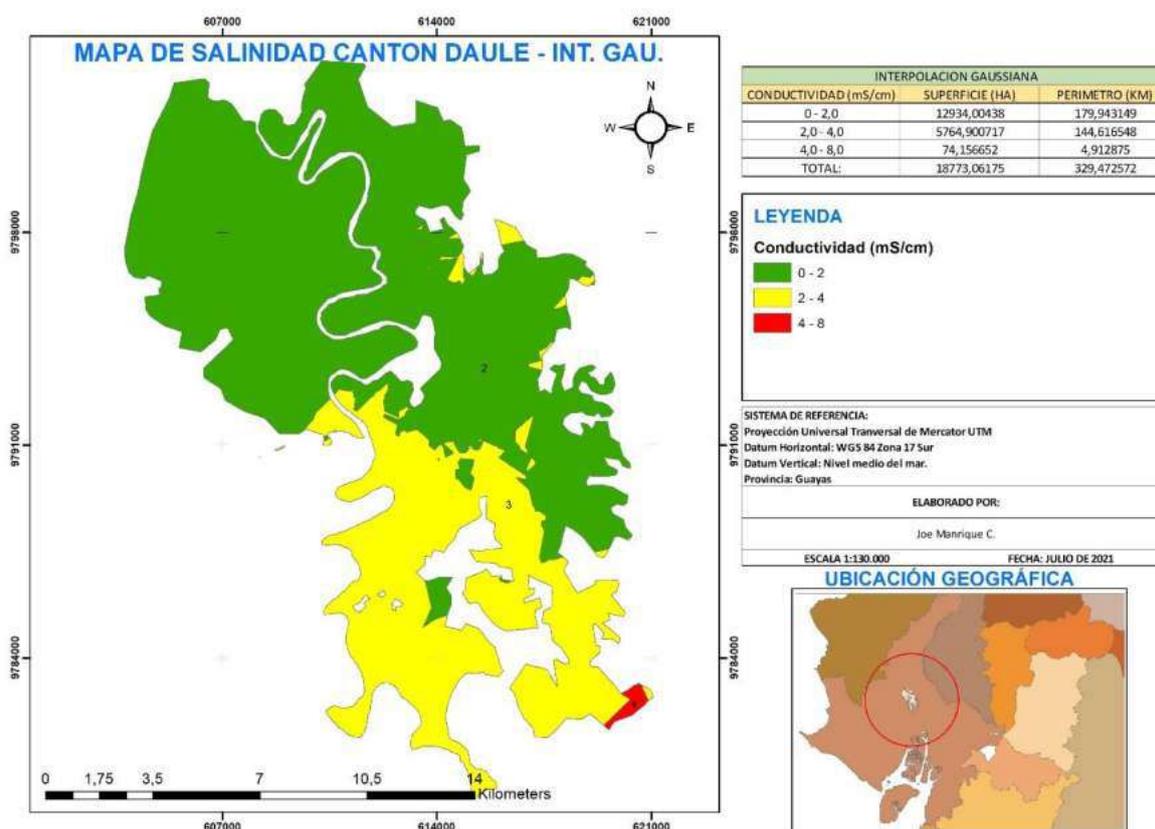


Figura 29. Salinidad de la zona de estudio Manrique, 2021

La condición de salinidad elevada en las zonas arroceras del cantón Daule está marcada por una tendencia en el sector sur del cantón, como se puede apreciar en la figura 29. El cultivo de arroz al ser una planta glicofita presenta ligeros problemas productivos cuando los rangos de conductividad de suelo son entre 2-3 mS/cm, especialmente si la condición del suelo no es la más óptima. Para los sectores donde la conductividad es mayor a 3 mS/cm, ya es suficiente razón para la reducción de la productividad del cultivo, por lo que se tiene que tener en

cuenta un plan de reducción de la salinidad de suelos en las zonas de mayor incidencia, adicionalmente, las condiciones continuas de reducción y oxidación del suelo bajo riego en el cultivo de arroz, no solo mantienen constante la dinámica de la salinidad, sino se empeoran.

Para el buen manejo de suelos salinos se tiene que generar conciencia a los productores y agricultores del sector sobre los daños que la salinidad provoca, esto es para generar cambios en las prácticas agrícolas que se realizan en el cultivo. En temas específicos como fertilización, se tiene que basar en una planificación adecuada que incluya la dosificación necesaria de fertilizante que el cultivo necesite y que el suelo no posea, evitando la sobre fertilización que induce al incremento de la salinidad.

Para temas como riego se tiene que tener en cuenta que las condiciones del cultivo se mantengan constantes, evitando la insuficiencia del agua de riego para mantener el cultivo en óptimas condiciones. Para el cultivo de arroz en seco se debe aplicar láminas de riego adecuadas considerando las necesidades del cultivo, así como las condiciones edafoclimáticas del sector.

La falta de drenajes naturales o artificiales, es una agravante de la salinidad, debido a que no hay una salida de agua constante, la cual es la manera en que las sales disueltas en el agua se transportan. Entonces estas sales se mantienen presentes en el agua y penetran las capas superficiales del suelo afectando negativamente la producción.

Las condiciones de barbecho o suelo desnudo deben ser contrarrestadas mediante el uso de cobertura vegetal, esto se debe a que las condiciones de evaporación alta y presencia de sales en estratos profundos provoca que las sales que emergen (debido a la evaporación) se sitúen en las partes superiores

del suelo, es decir la capa arable, incrementando la salinidad del suelo y reduciendo la productividad.

Se deben implementar políticas que gestionen correctamente el buen uso del recurso de suelo por parte de las agencias gubernamentales y cantonales. Estas políticas deben incluir medidas que delimiten y detallen las zonas donde la salinidad es mayor (como la presente investigación), la mitigación y reducción de la velocidad con la cual la salinidad se expande (reducción en la aplicación de fertilizantes, riego adecuado, labranza profunda, drenaje apropiado, conservación de la edafofauna), y cuando el caso de salinidad es mayor, directamente contrarrestar esta condición (aplicación de enmiendas químicas, aplicación de materia orgánica, drenaje profundo, aplicación de láminas de riego más altas, siembra de especies y variedades con más tolerancia a las condiciones de alta salinidad).

5. Discusión

Para la presente investigación se usó la selección del subconjunto de datos para establecer las combinaciones óptimas de variables independientes que se deben usar para elaborar un modelo de aprendizaje automatizado que indique las condiciones de salinidad de las zonas arroceras del cantón Daule mediante la extracción de datos de imágenes satelitales. Se usaron diversos criterios estadísticos para escoger el modelo que se ajustaba más a la información de entrada (ADJR2, MAE, RMSE y RAE) y mejor predictibilidad presentaba.

Para la interpolación de datos de conductividad eléctrica, se usó la metodología de Kriging Ordinario, bajo 5 modelos de semivariograma diferentes con igual tamaño de celda. El modelo de semivariograma Gaussiano fue escogido como el modelo que menor variabilidad de datos presentaba (CV y STD.DEV.) por lo que fue escogido como el óptimo para representar las condiciones de conductividad eléctrica del sector.

El estudio demostró que el modelo de máquinas de vectores de soporte es el algoritmo que lograba tener un valor de ADJR2 más elevado (0,82), y también un error relativo reducido (0,57), comparado con los demás modelos establecidos, por lo cual, para la zona de estudio y cultivo, es el algoritmo adecuado que logra indicar las condiciones de salinidad. Para este algoritmo no se presentaron vectores de soporte, sino en su lugar se aplicó una ponderación de datos similar al modelo de regresión lineal, debido a la facilidad con la cual esta información se puede presentar e interpretar.

Autores como Chen et al. (2020) indican que el modelo de bosques aleatorios (RF) es el modelo más adecuado para determinar la condición de salinidad (CE) del suelo durante diferentes estadios de cultivo y a diferentes profundidades de

toma de muestra, debido a que este algoritmo de clasificación es una colección de diversos árboles de decisión que cuenta con buena generalización y reducción del sobreajuste, sin embargo, en el modelo de SVM establecido en su investigación este algoritmo presenta muy buen ajuste de datos y valores de ADJR2 aceptables, así como un error relativo reducido, por lo que la zona de estudio, cultivo, condiciones climáticas, condiciones de suelo y demás son factores muy importantes, que se tienen que tomar en cuenta para elegir el modelo de aprendizaje automatizado adecuado.

La metodología de extracción de datos de puntos aleatorios (píxeles) fue usada para evitar la aparición de excesivos datos colineales debido a la interpolación, sin embargo, otros autores como Azabdaftari y Sunar (2016) lograron usar toda la información de las imágenes satelitales, para el preprocesamiento y correlación de datos, para lo cual es necesario un gran poder computacional para procesar esta información.

Elhag (2016) en su investigación indica que el índice de salinidad 9 (SI-9) tiene una significancia de R^2 de 0,98 con la condición de salinidad real, con lo cual refleja la importancia de las condiciones del suelo al momento de la ingestión de datos por medio de sensores remotos. Las condiciones de suelo de la investigación mencionada eran zonas áridas con suelo sin cobertura, por lo que la información espectral fue mucho más precisa y de mayor validez al momento de correlacionarla con los valores reales.

Para la presente investigación fue necesaria una selección de subconjunto de datos para poder relacionar las variables independientes con la variable dependiente (varias combinaciones de índices y bandas), no obstante, en investigación realizadas por Asfaw, Suryabhagavan y Argaw (2018) se halló que

un índice de vegetación (Índice de salinidad SI, en el caso de la investigación mencionada) contiene suficiente información que detalla las condiciones de salinidad de la zona de estudio, por lo cual, es muy importante considerar las condiciones de suelo, de cultivo, cobertura vegetal, entre otras, al momento de elegir los índices de vegetación que se usaran para desarrollar el modelo, ya que un índice puede contener una gran relación con las condiciones reales de conductividad eléctrica.

La aplicación de análisis de componentes principales para el ajuste de datos en la investigación no tuvo resultados óptimos, sin embargo Elhag (2016) logró la aplicación de 1 componente principal único que contenía la información necesaria para poder correlacionarla con los índices de vegetación determinados, posiblemente debido a las condiciones de suelo y de extracción de información espectral. Para el método de interpolación escogido, se tiene que tener en cuenta la variabilidad de datos de las interpolaciones, por lo que se pueden aplicar funciones de núcleo para suavizar la información y poder evaluar los datos respectivamente.

Babiker, Abulgasim y Hamid (2018) detallan que, para la interpolación de datos de conductividad eléctrica tomada de las muestras de suelo, el método de Co-Kriging fue el más adecuado para su investigación, posiblemente debido a las condiciones áridas de la zona de interés y reducido número de toma de muestras, también indican que cuando se toman 2 diferentes conjuntos de datos que representan 2 variables diferentes, la metodología de Co-Kriging es la adecuada para la interpolación de información. Una situación común en la aplicación de Co-Kriging es cuando para un conjunto de datos fue obtenido mediante muestreos

escasos (debido a tiempo, dinero) y la otra variable fue muestreada excesivamente.

Dehni y Lounis (2012) realizaron una categorización de las zonas salinas mediante una clasificación supervisada de datos, en los cuales los rangos establecidos de conductividad eléctrica fueron relacionados con las firmas espectrales de los píxeles de las imágenes satelitales y en base a esta categorización se las relaciono con los distintos índices de vegetación, lo cual indica una metodología para la correlación de imágenes con muestras de suelo, bastante diferente a la realizada por varios autores.

Wu et al. (2015) para su investigación realizó un análisis multitemporal de salinidad de suelos. El estudio tuvo un análisis de información que abarcó un periodo de 4 a 5 años, en el cual se usaron 2 fechas diferentes por año para la ingestión y procesamiento de las imágenes satelitales, esto fue para reducir la variabilidad de la reflectancia causada por el cultivo, su rotación y condiciones de humedad del suelo, lo cual puede ayudar a reducir la necesidad de la determinación de subconjunto de datos, esto ayuda a reducir el tipo de procesamiento que se le tiene que dar a la información de entrada y en general ayuda a tener un enfoque más simple para tener modelos de aprendizaje automatizado más exactos, con menor sobreajuste y errores reducidos, a cuesta de tener que realizar el respectivo análisis multitemporal de las imágenes satelitales.

6. Conclusiones

La línea base de suelos arroceros mediante la metodología de interpolación de datos a través de semivariograma Gaussiano posee menor variabilidad para el levantamiento de la dinámica de la salinidad en el área de estudio. Este método predictivo estimó las condiciones de conductividad eléctrica (CE) que se asemejan con mayor precisión a las condiciones de campo. Por lo tanto, se describe que 12934 hectáreas presentan condiciones favorables y baja conductividad (0-2 mS/cm) para producir la gramínea, seguido de 5764,90 hectáreas presentan suelos ligeramente salinos (2 y 4 mS/cm) y 74,15 hectáreas presentan condiciones de suelo moderadamente salinos (4 y 8 mS/cm).

Los modelos para estimar la salinidad del sector funcionaron de mejor manera en el siguiente orden: SVM > RF > LR > MLP. El algoritmo de máquinas de vectores de soporte tuvo el comportamiento más adecuado para la información que se le dio, también tuvo menor error en general que los demás algoritmos y su valor de ADJR2 se mantuvo constante. Para el modelo de bosques aleatorios (RF) se establece que también es un modelo muy apto de aplicación para el campo de la teledetección debido a la gran categorización de datos que puede llevar a cabo con error reducido. Alrededor del 31% de los suelos de la zona de estudio presentan una conductividad eléctrica entre 2-4 mS/cm y menos de 1% presenta condiciones mayores a 4 mS/cm.

Para la zona sur del sector (30% del área) que es la zona con mayor presencia de sales, se debe dar un manejo diferenciado para reducir la salinidad y mejora de los suelos y productividad del cultivo. Para esto se tiene que realizar un respectivo plan de manejo de salinidad, este plan debe incluir: uso de coberturas vegetales para suelos en barbecho, uso eficiente del agua para riego agrícola

plan de fertilización óptimo, aplicación de enmiendas orgánicas y aplicación de láminas de riego para lavado de sales y drenaje agrícola.

7. Recomendaciones

El proceso de toma de muestras se debe realizar de manera adecuada en la zona de interés, esto es mediante una metodología que logre cubrir la mayor cantidad de información con el menor gasto de recursos. Mediante puntos aleatorios con distancia mínimas es una manera adecuada de realizar el muestreo, sin embargo, para la cantidad de puntos de muestreo establecidos aún no existe una regla que dicte cuantos puntos se deben muestrear, por lo que se tiene que tener de referencia diversas publicaciones de impacto al momento de la elección total de punto de muestreo. Se tiene que tener en cuenta el tamaño de la zona, la variabilidad de datos que se presentan, condiciones de suelo, tipo de cultivo prevalente en la zona, condiciones climáticas y accesibilidad a la zona de estudio, para tener una mayor cantidad de datos representativos de las condiciones de conductividad del sector, ya que entre más variabilidad de datos mayor puntos de muestreo se tienen que tomar. Otro factor importante es la multitemporabilidad de datos y toma de muestras a diferentes profundidades para reducir aún más la variabilidad y complejidad de los datos que se tienen que procesar. Este tipo de enfoque ayuda a que la información que se ingrese a los modelos de aprendizaje automatizado pueda ser más eficaz y más veraz al momento de predecir datos. El tipo de interpolación a aplicar en los puntos de muestreo es otro factor a tener en cuenta, existen diferentes métodos de interpolación como Kriging (universal, ordinario), Spline, IDW, vecinos naturales, entre otros, además de diferentes métodos de suavizado mediante aplicaciones de kernels o núcleos y modelos de semivariograma a implementar, por lo que se tiene que evaluar cada factor de manera detallada para saber qué modelo se

elegirá, normalmente se elige el modelo con menor variabilidad de datos y mayor estabilidad.

Para la estimación de salinidad de suelos la elección de los modelos de aprendizaje automatizado es elección personal del investigador, pero se debe basar en criterios ya establecidos por publicaciones revisadas por pares, puesto que estas ya poseen credibilidad, verificabilidad y un intervalo de confianza ya testeado y establecido, con resultados tangibles. Sin embargo, la cantidad de algoritmos de ML disponibles es elevada, y existe la posibilidad que algoritmos aún no probados puedan tener una gran aceptación para el diseño de modelos, con errores reducidos y sin sobreajuste de datos, lo cual se presenta como una oportunidad para realizar investigación con otros algoritmos menos probados. La aplicación de algoritmos de “aprendizaje profundo” o “Deep learning” para la regresión de imágenes es una metodología que se está usando actualmente para encontrar patrones y relaciones entre imágenes directamente de manera no supervisada a diferencia de los modelos de ML que son supervisados, los cuales se muestran como una herramienta prometedora para el análisis de datos y por ende una herramienta más poderosa para el diseño de modelos de redes neuronales.

Para la zona de estudio se recomienda tener un plan de manejo de salinidad en las zonas con mayor presencia de salinidad, lo cual abarca cerca de 5800 hectáreas con cultivo de arroz. Existe un gran factor de riesgo para este sector, debido a que el cultivo ya establecido es sensible a la salinidad. Para el plan de manejo se recomienda una mejor preparación de suelos antes de la siembra, esto incluye labranza profunda para que las sales disueltas puedan bajar hacia capas menos importantes donde las raíces no lleguen, se debe tener en cuenta que

haya un drenaje de agua adecuado, ya que las sales disueltas en el agua si no se drenan se mantendrán la superficie del suelo, empeorando la salinidad. El uso indiscriminado de fertilizantes químicos se tiene que realizar mediante un criterio adecuado, siempre se deben realizar planes de fertilización que sean adecuados a las necesidades del cultivo y el tipo de suelo, basándose en análisis de suelos realizados en laboratorio. Otro factor importante es la elección de una variedad que presente mayor tolerancia a la salinidad, o como otra opción la implementación de otras especies de cultivos que, si presente tolerancia o resistencia a condiciones salinas adversas, además esto brindaría de un descanso al suelo del proceso típico de oxidación-reducción al que está sometido durante todo el año. Para las zonas con suelos ligeramente – moderadamente salinos se recomienda una toma de muestras más detallada para identificar con más precisión la dinámica de la salinidad.

8. Bibliografía

- Abirami, S., y Chitra, P. (2020). Energy-efficient edge based real-time healthcare support system. En *Advances in Computers* (Vol. 117, pp. 339-368). Elsevier. <https://doi.org/10.1016/bs.adcom.2019.09.007>
- Adhikari, K. (2008). *Updated map of salt affected soils in the European Union* (pp. 65-77).
- Alhammedi, M. S., y Glenn, E. P. (2008). Detecting date palm trees health and vegetation greenness change on the eastern coast of the United Arab Emirates using SAVI. *International Journal of Remote Sensing*, 29(6), 1745-1765. <https://doi.org/10.1080/01431160701395195>
- Allbed, A., Kumar, L., y Sinha, P. (2014). Mapping and Modelling Spatial Variation in Soil Salinity in the Al Hassa Oasis Based on Remote Sensing Indicators and Regression Techniques. *Remote Sensing*, 6(2), 1137-1157. <https://doi.org/10.3390/rs6021137>
- Aragüés, R. (2008, noviembre 19). *Riego, drenaje y salinidad*.
- Araya, M. (2007). Correcciones de una imagen satelital ASTER para estimar parámetros vegetacionales en la cuenca del río Mirta, Aisén. *Bosque (Valdivia)*, 28(2), 162-172. <https://doi.org/10.4067/S0717-92002007000200009>
- Artiola, J. F., Walworth, J. L., Musil, S. A., y Crimmins, M. A. (2019). Soil and Land Pollution. En: *Environmental and Pollution Science* (pp. 219-235). Elsevier. <https://doi.org/10.1016/B978-0-12-814719-1.00014-8>
- Asfaw, E., Suryabhagavan, K. V., y Argaw, M. (2018). Soil salinity modeling and mapping using remote sensing and GIS: The case of Wonji sugar cane

- irrigation farm, Ethiopia. *Journal of the Saudi Society of Agricultural Sciences*, 17(3), 250-258. <https://doi.org/10.1016/j.jssas.2016.05.003>
- Awad, M., y Khanna, R. (2015). *Support Vector Machines for Classification* (pp. 39-66). https://doi.org/10.1007/978-1-4302-5990-9_3
- Azabdaftari, A., y Sunar, F. (2016). Soil salinity mapping using multitemporal landsat data. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B7, 3-9. <https://doi.org/10.5194/isprsarchives-XLI-B7-3-2016>
- Babiker, S., Abulgasim, E., y Hamid, H. (2018). Enhancing the Spatial Variability of Soil Salinity Indicators by Remote Sensing Indices and Geo-Statistical Approach. *Journal of Earth Science y Climatic Change*, 9(4), 1-7. <https://doi.org/10.4172/2157-7617.1000462>
- Blokhuis, W. A. (1996). Chapter 3 Classification of vertisols. En N. Ahmad y A. Mermut (Eds.), *Developments in Soil Science* (Vol. 24, pp. 63-88). Elsevier. [https://doi.org/10.1016/S0166-2481\(96\)80005-5](https://doi.org/10.1016/S0166-2481(96)80005-5)
- Bloodnick, E., y Peery, J. (2018). *Role of Sodium and Chloride in Plant Culture | PRO-MIX Greenhouse Growing*. Obtenido de: <https://www.pthorticulture.com/en/training-center/role-of-sodium-and-chloride-in-plant-culture/>
- Bresler, E., McNeal, B. L., y Carter, D. L. (2012). *Saline and Sodic Soils: Principles-Dynamics-Modeling*. Springer Science y Business Media.
- Brownlee, J. (2016, marzo 24). Linear Regression for Machine Learning. *Machine Learning Mastery*. Obtenido de: <https://machinelearningmastery.com/linear-regression-for-machine-learning/>
- Caloz, R., Abednego, B., y Collet, C. (1988). The Normalisation of a Soil Brightness Index for the Study of Changes in Soil Conditions. *Spectral*

Signatures of Objects in Remote Sensing, Proceedings of the conference held 18-22 January, 1988 in Aussois (Modane), France. Edited by T.D. Guyenne and J.J. Hunt., 363.

Casella, A., Barrionuevo, N., Pezzola, A., y Winschel, C.(2018). *Preprocesamiento de imágenes satelitales del sensor Sentinel 2A y 2B con el software SNAP*
https://inta.gov.ar/sites/default/files/tutorial_snap_preproc_acasella_et_al_2018_inta.pdf

Chen, Y., Qiu, Y., Zhang, Z., Zhang, J., Chen, C., Han, J., y Liu, D. (2020). Estimating salt content of vegetated soil at different depths with Sentinel-2 data. *PeerJ*, 8, e10585. <https://doi.org/10.7717/peerj.10585>

Constitución de la República del Ecuador. (2008). *Constitución del ecuador.*
https://www.cancilleria.gob.ec/wpcontent/uploads/2013/06/constitucion_2008.pdf

Dehni, A., y Lounis, M. (2012). Remote Sensing Techniques for Salt Affected Soil Mapping: Application to the Oran Region of Algeria. *Procedia Engineering*, 33, 188-198. <https://doi.org/10.1016/j.proeng.2012.01.1193>

DiBiase, D., Dutton, J., y Sloan, j. (2009). 14. *Image Correction | The Nature of Geographic Information.* Obtenido de: https://www.e-education.psu.edu/natureofgeoinfo/c8_p15.html

Earth Observing System. (2020). *NDVI | Earth Observing System.*
<https://eos.com/ndvi/es/>

Elhag, M. (2016, enero 6). *Evaluation of Different Soil Salinity Mapping Using Remote Sensing Techniques in Arid Ecosystems, Saudi Arabia* [Research Article]. *Journal of Sensors; Hindawi.* <https://doi.org/10.1155/2016/7596175>

- EOS. (2019). *6 Spectral Indexes on Top of NDVI To Make Your Vegetation Analysis Complete – Earth Observing System*. Obtenido de: <https://eos.com/blog/6-spectral-indexes-on-top-of-ndvi-to-make-your-vegetation-analysis-complete/>
- FAO. (1988). 3. *Saline soils and their management*. <http://www.fao.org/3/x5871e/x5871e04.htm>
- FAO. (2020). *Suelos afectados por salinidad | Portal de Suelos de la FAO | Organización de las Naciones Unidas para la Alimentación y la Agricultura*. Obtenido de: <http://www.fao.org/soils-portal/soil-management/manejo-de-suelos-problematicos/suelos-afectados-por-salinidad/es/>
- Glenn, E. P., Huete, A. R., Nagler, P. L., y Nelson, S. G. (2008). Relationship Between Remotely-sensed Vegetation Indices, Canopy Attributes and Plant Physiological Processes: What Vegetation Indices Can and Cannot Tell Us About the Landscape. *Sensors*, 8(4), 2136-2160. <https://doi.org/10.3390/s8042136>
- Gobierno Autónomo Descentralizado e Ilustre Municipalidad del cantón Daule. (2015). *Plan de Desarrollo y Ordenamiento Territorial del Cantón Daule 2015-2025*.
- González, Z., Mendoza, N., González, G., Etchevers, J. D., y Vázquez, A. (2011). Pérdidas de nitratos y salinización del suelo por riego por goteo con nitrógeno. *Terra Latinoamericana*, 29(3), 239-248.
- Huete, A. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59(3), 440-451. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)

- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., y Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Ibáñez, A., Gisbert, J., y Moreno, H. (2014). *Entisoles*. 7.
- INEC. (2010). *Censo de Población y Vivienda 2010*. Obtenido de: https://www.ecuadorencifras.gob.ec/documentos/webinec/Poblacion_y_Demografia/CPV_aplicativos/datos_generales_cpv/09daule.pdf
- INEC. (2019). Encuesta de superficie y producción agropecuaria continua.
- Instituto Nacional de Meteorología e Hidrología. (2017). *Anuario Meteorológico 2013*. www.serviciometeorologico.gob.ec/docum_institucion/anuarios/meteorologicos/Am_2013.pdf
- Intriago Barreno. (2015). *Evaluación del Suelo Bajo Indicadores Agroecológicos de tres Fincas Arroceras del Cantón Daule, provincia del Guayas*. Obtenido de: <http://repositorio.ucsg.edu.ec/bitstream/3317/1550/1/T-UCSG-PRE-TEC-AGRO-27.pdf>
- Jaramillo, V., y Arahana, V. (2015). *Determination of the level of tolerance to salinity in in vitro conditions of the plants of tomate de árbol (Solanum betaceum) from different localities of the ecuatorian highlands*. *Determinación del nivel de tolerancia a salinidad en condiciones in vitro de plantas de tomate de árbol (Solanum betaceum) provenientes de distintas localidades de la Sierra ecuatoriana*. 6(1), 7.

- Kaufman, Y. J., y Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 261-270. <https://doi.org/10.1109/36.134076>
- Khan, N. M., Rastokuev, V. V., Sato, Y., y Shiozawa, S. (2005). Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agricultural Water Management*, 77(1-3), 96-109. <https://doi.org/10.1016/j.agwat.2004.09.038>
- Lazara, O., Alden, F., Gálvez, V., Morales, R., Sánchez, I., Labaut, M., y Cintra, M. (2007). *Caracterización y evaluación de la salinidad*. 9.
- Marqués, M. J., Alvarez, A., Carral, P., Sastre, B., y Bienes, R. (2020). The use of remote sensing to detect the consequences of erosion in gypsiferous soils. *International Soil and Water Conservation Research*, 8(4), 383-392. <https://doi.org/10.1016/j.iswcr.2020.10.001>
- Mateo-Sagasta, J., y Burke, J. (2011). *Agriculture and water quality interactions: A global overview*. 46.
- Mejía, J. H. M., y Arboleda, H. D. J. (2019). *Aplicación de un algoritmo de optimización secuencial mínima (SMOreg)*. 56.
- Misra, S., y Li, H. (2020). Noninvasive fracture characterization based on the classification of sonic wave travel times. En *Machine Learning for Subsurface Characterization* (pp. 243-287). Elsevier. <https://doi.org/10.1016/B978-0-12-817736-5.00009-0>
- Navarrete, P. C. F., Alava, J. M. N., Villamar, E. G. H., y Chumo, D. G. Á. (2017). *Consortios microbianos para la recuperación de muestras de suelo sódico-salinos del sitio Correagua-Manabí-Ecuador*. 25.

- Nguyen, K.-A., Liou, Y.-A., Tran, H.-P., Hoang, P.-P., y Nguyen, T.-H. (2020). Soil salinity assessment by using near-infrared channel and Vegetation Soil Salinity Index derived from Landsat 8 OLI data: A case study in the Tra Vinh Province, Mekong Delta, Vietnam. *Progress in Earth and Planetary Science*, 7(1), 1. <https://doi.org/10.1186/s40645-019-0311-0>
- Pasimeni, M. R., Valente, D., Semeraro, T., Petrosillo, I., y Zurlini, G. (2019). Anthropogenic Landscapes. En *Encyclopedia of Ecology* (pp. 472-481). Elsevier. <https://doi.org/10.1016/B978-0-12-409548-9.10602-5>
- Piedra, A. L., y Cepero, M. C. G. (2013). La Salinidad Como Problema En La Agricultura: La Mejora Vegetal Una Solución Inmediata. *Cultivos Tropicales*, 34(4), 31-42.
- Pourrut, P. (Ed.). (1995). *El agua en el Ecuador: Clima, precipitaciones, escorrentía*. Colegio de Geógrafos del Ecuador: Corporación Editora Nacional.
- Ramirez, P. (2016). *Condiciones de salinidad y recuperación de los suelos de la cancha pública de golf - San Bartolo, Lima*.
- Ramos, S. (2018). *Aporte de la producción arrocerá del cantón Daule en el sector agrícola de la provincia del Guayas. Periodo 2012-2016*. 75.
- Reddy, I. N. B. L., Kim, B.-K., Yoon, I.-S., Kim, K.-H., y Kwon, T.-R. (2017). Salt Tolerance in Rice: Focus on Mechanisms and Approaches. *Rice Science*, 24(3), 123-144. <https://doi.org/10.1016/j.rsci.2016.09.004>
- Rosales, A. P., Spínola, A. G., Montoya, R. B., Mendoza, T. M. H., y Peña, A. V. (2017). *Capacidad de intercambio catiónico: Descripción del método de la tiourea de plata (AgTU+n)* Cation exchange capacity: Description of the silver thiourea method (AgTU+n)*. 7.

- Shahid, S. A., Zaman, M., y Heng, L. (2018). Soil Salinity: Historical Perspectives and a World Overview of the Problem. En M. Zaman, S. A. Shahid, y L. Heng (Eds.), *Guideline for Salinity Assessment, Mitigation and Adaptation Using Nuclear and Related Techniques* (pp. 43-53). Springer International Publishing. https://doi.org/10.1007/978-3-319-96190-3_2
- Sonon, L. S., Saha, U., y Kissel, D. E. (2015). *Testing, Data Interpretation and Recommendations*. 6.
- Sotelo R., E., Gutiérrez C., M. del C., Cruz B., G., Ortiz S., C. A., y Segura C., M. A. (2008). Historia y desarrollo de la clasificación de vertisoles en el sistema FAO y la taxonomía. *Terra Latinoamericana*, 26(4), 325-332.
- Tripathi, N. K., Rai, B. K., y Dwivediore, P. (2009, septiembre 11). Spatial modelling of soil alkalinity in GIS environment using IRS data. *Geospatial World*. <https://www.geospatialworld.net/article/spatial-modelling-of-soil-alkalinity-in-gis-environment-using-irs-data/>
- Tutiven Torres. (2017). *Ingreso, ahorro y reinversión de los pequeños agricultores de arroz del cantón Daule, período 2010-2016*. 168.
- University of California. (2020). *Toxicity of specific ions*. Obtenido de: https://ucanr.edu/sites/Salinity/Salinity_Management/Effect_of_soil_salinity_on_crop_growth/Toxic_effects_of_specific_ions
- USDA. (1999). *Soil Taxonomy—A Basic System of Soil Classification for Making and Interpreting Soil Surveys*. Obtenido de: https://www.nrcs.usda.gov/Internet/FSE_DOCUMENTS/nrcs142p2_051232.pdf
- Vermote E.F, Wolfe, R., Hall, F.G., Lim, T.K., Huemmrich, F., Gao, F., Kutler, J., y Masek, J.G. (2006). *Landsat Surface Reflectance-Derived Spectral Indices*.

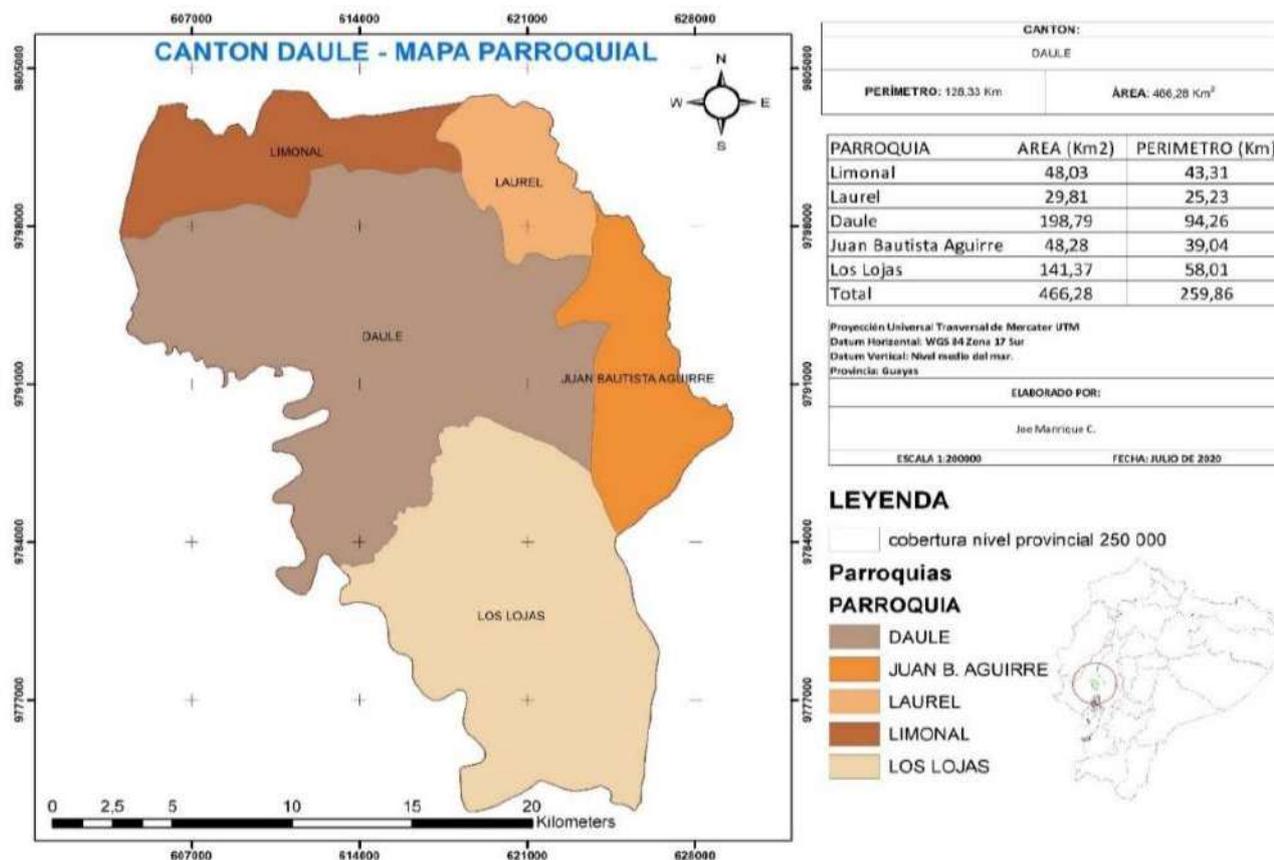
Obtenido de: https://www.usgs.gov/land-resources/nli/landsat/landsat-surfacereflectancederivedspectralindices?qtscience_support_page_related_con=0#qtscience_support_page_related_con

Wu, W., Mhaimed, A., Al-Shafie, W., Ziadat, F., Dhehibi, B., Nangia, V., y De Pauw, E. (2015). Mapping soil salinity changes using remote sensing in Central Iraq. *Geoderma Regional*, 2-3, 21-31. <https://doi.org/10.1016/j.geodrs.2014.09.002>

Zhang, A., Lipton, Z., Li, M., y Smola, A. (2021). *Dive into Deep Learning*. arXiv preprint arXiv:2106.11342.

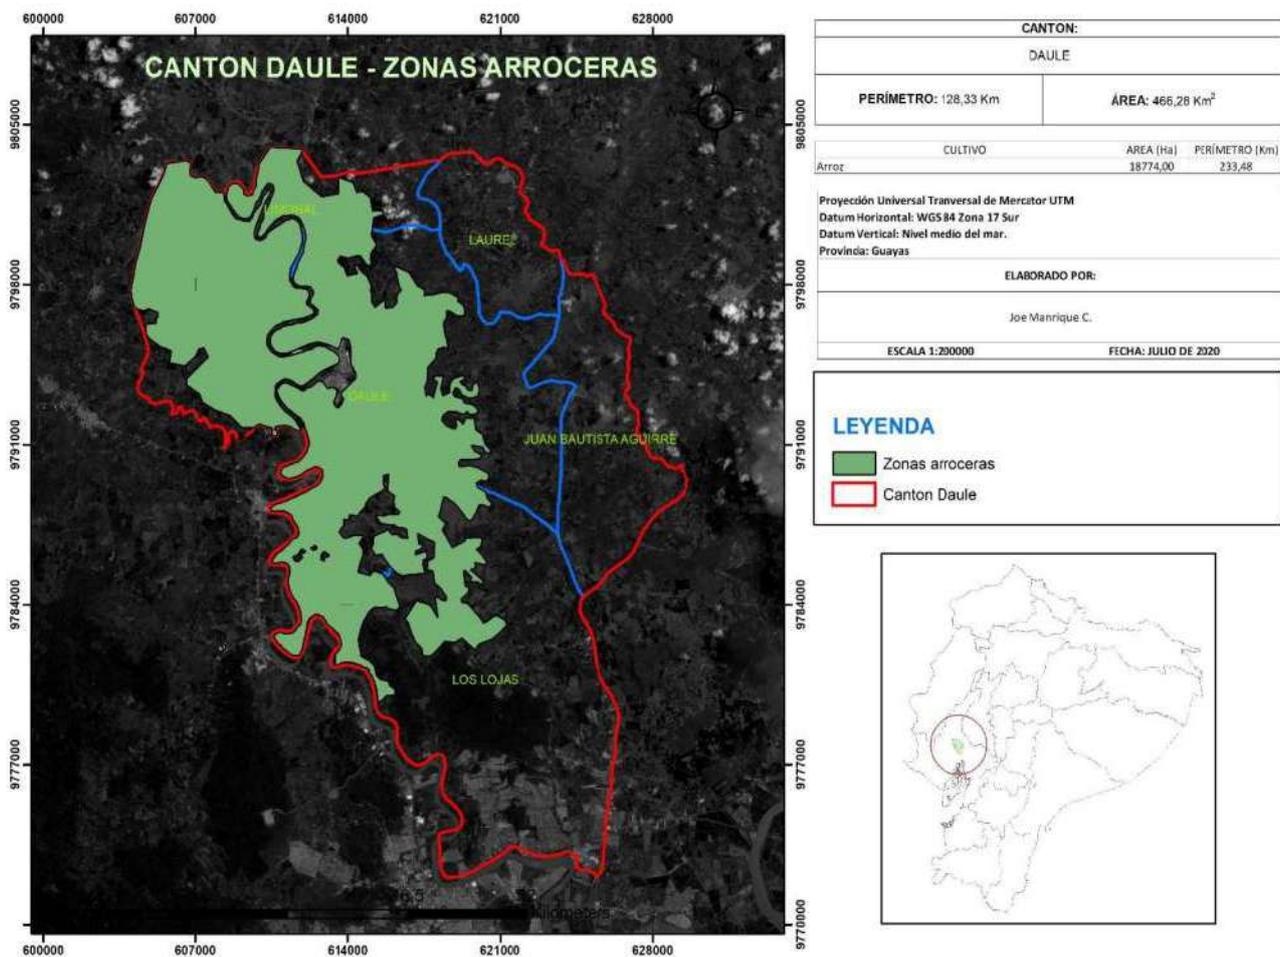
9. Anexos

Anexo 1. Zona de estudio – División parroquial



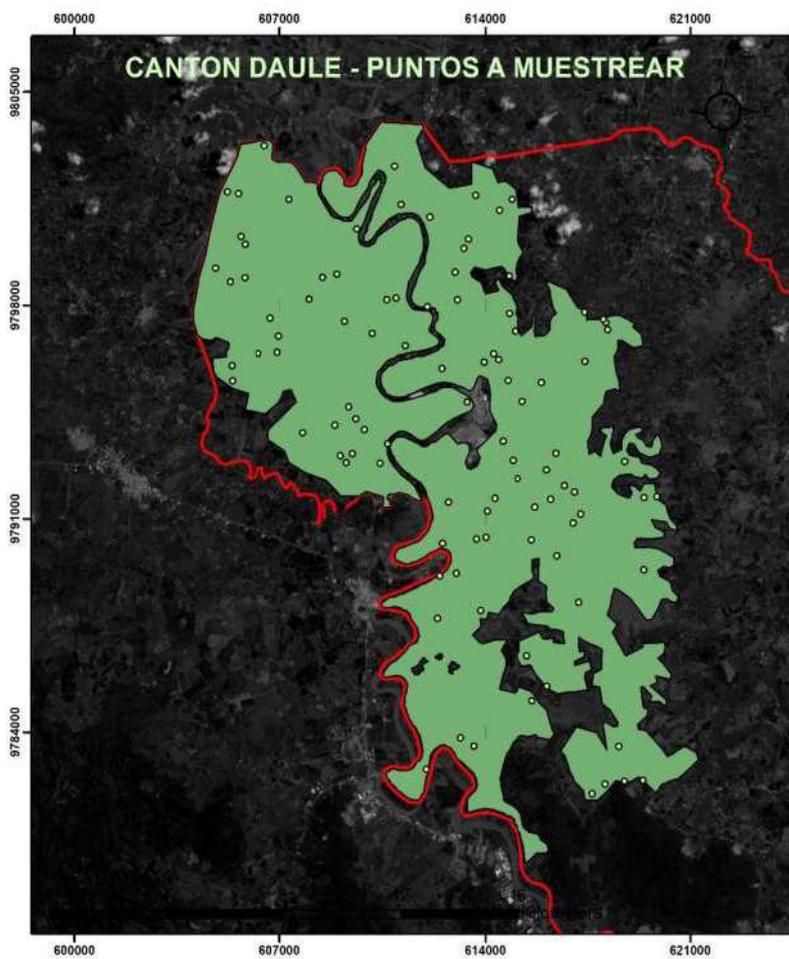
Manrique, 2021

Anexo 2. Zonas arroceras



Manrique, 2021

Anexo 3. Puntos de muestreo



CANTON:		
DAULE		
PERÍMETRO: 128,33 Km	ÁREA: 466,28 Km ²	
CULTIVO	AREA (Ha)	PERÍMETRO (Km)
Arroz	18774,00	233,48
SISTEMA DE REFERENCIA:		
Proyección Universal Transversal de Mercator UTM		
Datum Horizontal: WGS 84 Zona 17 Sur		
Datum Vertical: Nivel medio del mar.		
Provincia: Guayas		
ELABORADO POR:		
Joe Manrique C.		
ESCALA 1:150.000		FECHA: NOVIEMBRE DE 2020
LEYENDA		
	Zonas arroceras	
	Canton Daule	



Manrique, 2021



Anexo 5. Toma de muestras de zona de estudio
Manrique, 2021



Anexo 6. Toma de muestras de zona de estudio
Manrique, 2021



Anexo 7. Fundas de muestras etiquetadas
Manrique, 2021



Anexo 8. Visita y asesoramiento de tutor en la zona de estudio Manrique, 2021



Anexo 9. Procesado de muestras Manrique, 2021



Anexo 10. Secado y triturado de muestras de suelo Manrique, 2021



Anexo 11. Total de muestras tamizadas y molidas Manrique, 2021



Anexo 12. Mezclado de muestras Manrique, 2021



Anexo 13. Envasado e inicio de metodología de pasta saturada Manrique, 2021



Anexo 14. Centrifugado de muestras para posterior medición de CE Manrique, 2021



Anexo 15. Ingreso de datos de CE para posterior procesado en software SIG
Manrique, 2021