



Universidad
Zaragoza

Trabajo Fin de Grado

GRADO EN INGENIERÍA AGROALIMENTARIA Y DEL MEDIO
RURAL

EXPLOTACIONES AGROPECUARIAS

CORRELACIÓN ENTRE LAS PROPIEDADES FISICOQUÍMICAS DEL SUELO Y
LA MEDIDA DE SU CONDUCTIVIDAD ELÉCTRICA APARENTE. INFLUENCIA
EN EL CULTIVO DE CEREAL DE INVIERNO EN CONDICIONES DE SECANO

CORRELATION BETWEEN THE PHYSICOCHEMICAL PROPERTIES OF THE
SOIL AND THE MEASUREMENT OF ITS APPARENT ELECTRICAL
CONDUCTIVITY. INFLUENCE ON THE WINTER CEREAL CROP UNDER
RAINFED CONDITIONS

Autor

Manuel Sampériz Sarvisé

Directores

María Videgain Marco

José Antonio Martínez Casasnovas

Ponente

Francisco Javier García Ramos

ESCUELA POLITÉCNICA SUPERIOR

2022

AGRADECIMIENTOS

Agradecer a Francisco Javier García Ramos por proponerme la temática del actual Trabajo y por ofrecerme la posibilidad de participar en este proyecto.

También a José Antonio Martínez Casasnovas por acceder a dirigir el trabajo, así como por su ayuda y guiado.

De igual manera, a María Videgain Marco por su implicación en el desarrollo de la temática y por toda la información y comentarios proporcionados.

A Alba Vigo y Javier Zabalza por su ayuda durante la toma de muestras en campo.

Por último, agradecer el apoyo de mi familia, amigos, compañeros y profesores en todo lo acontecido durante estos cuatro años de estudios en la Escuela Politécnica Superior de Huesca.

RESUMEN

Las tecnologías de la denominada Agricultura de Precisión pueden orientarse al manejo sitio-específico a nivel de parcelas agrícolas, lo que contribuye a la reducción de insumos y a la mejora del rendimiento neto de las explotaciones.

Entre las metodologías más utilizadas se encuentra la caracterización de la variabilidad intraparcilaria a través de la medición de la conductividad eléctrica aparente (CEa) del suelo.

En este Trabajo Fin de Grado (TFG) se ha analizado estadísticamente la correlación entre la CEa y algunas de las principales propiedades fisicoquímicas del suelo, y su efecto sobre el desarrollo de un cultivo de cereal de secano.

El estudio se ha centrado en una parcela experimental en la localidad de Valsalada (Huesca). La parcela se caracterizó en base a la CEa en dos profundidades (0–30 cm o superficial) y (0–90 cm o profunda) y se tomaron 42 muestras de suelo en una zona concreta de la parcela para su análisis fisicoquímico. Los resultados se correlacionaron entre sí y con el índice de vegetación de la diferencia normalizada del cultivo (NDVI) calculado a partir de imágenes de la constelación PlanetScope, con resolución de 3 m/píxel. Se evaluó la distribución de los valores de estos parámetros en las distintas zonas de CEa y se estudió su capacidad para predecir las categorías de zonas a través de un modelo predictivo.

Los resultados indicaron altas correlaciones de la CEa con ciertas propiedades del suelo (textura, elementos gruesos, carbonato cálcico equivalente, capacidad de intercambio catiónico y punto de marchitez permanente). También, el estudio muestra el potencial de los modelos predictivos para mejorar la zonificación de parcelas agrícolas con fines de Agricultura de Precisión.

Palabras clave: Agricultura de Precisión, conductividad eléctrica aparente, NDVI, cereal, zonificación, suelo.

ABSTRACT

The technologies of the so-called Precision Agriculture can be oriented to a site-specific management at the level of agricultural plots, which contributes to the reduction of inputs and the improvement of the farms net yield.

Among the most used methodologies is the characterization of the variability within the plot through the measurement of the apparent electrical conductivity (CEa) of the soil.

In this final degree work, the correlation between CEa and some of the main physicochemical properties of the soil, and its effect on the development of a rainfed cereal crop, has been statistically analysed.

The study has focused on an experimental plot in the municipality of Valsalada (Huesca). The plot was characterized based on CEa at two depths (0–30 cm or shallow) and (0–90 cm or deep) and 42 soil samples were taken in a specific area for physicochemical analysis. The results were correlated with each other and the crop normalized difference vegetation index (NDVI) calculated from images of the PlanetScope constellation, with a resolution of 3 m/píxel. The distribution of the values of these parameters in the different CEa areas was evaluated and their capacity to predict the categories of areas through a predictive model was studied.

The results indicated high correlations of CEa with certain soil properties (texture, coarse elements, equivalent calcium carbonate, cation exchange capacity and permanent wilting point). Also, the study shows the potential of predictive models to improve the agricultural plots zoning for Precision Agriculture purposes.

Key words: Precision Agriculture, apparent electrical conductivity, NDVI, cereal, zoning, soil.

ÍNDICE DEL TRABAJO

ÍNDICE DE TABLAS.....	IV
ÍNDICE DE FIGURAS.....	V
ÍNDICE DE ECUACIONES.....	VI
1. INTRODUCCIÓN	1
1.1. AGRICULTURA DE LA ZONA.....	2
1.1.1. CULTIVOS.....	2
1.1.2. PRÁCTICAS AGRONÓMICAS	5
1.1.3. ROTACIÓN DE CULTIVOS.....	5
1.1.4. MANEJO DEL CULTIVO DE TRIGO.....	7
1.2. AGRICULTURA DE PRECISIÓN.....	9
1.2.1. CONCEPTO Y DEFINICIÓN	9
1.2.2. CONDUCTIVIDAD ELÉCTRICA APARENTE (CE _a)	10
1.2.3. TELEDETECCIÓN: IMÁGENES SATELITALES.....	12
1.2.4. APLICACIONES PRÁCTICAS DE LA AGRICULTURA DE PRECISIÓN A TRAVÉS DE LA TECNOLOGÍA DE LA MAQUINARIA AGRÍCOLA	15
2. OBJETIVOS	17
3. MATERIALES Y MÉTODOS	18
3.1. ÁREA DE ESTUDIO.....	18
3.1.1. LOCALIZACIÓN	18
3.1.2. CARACTERIZACIÓN CLIMÁTICA	19
3.1.3. GEOLOGÍA Y GEOMORFOLOGÍA LOCAL	22
3.2. MAPA DE CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO	23
3.3. MUESTREO DEL SUELO	26
3.4. ANÁLISIS FÍSICOQUÍMICO DE LAS MUESTRAS DE SUELO	27
3.5. OBTENCIÓN DE LOS VALORES DE CE _a EN LOS PUNTOS DE MUESTREO DE SUELO	29
3.6. OBTENCIÓN DE LOS ÍNDICES DE VEGETACIÓN (NDVI).....	30
3.7. ANÁLISIS ESTADÍSTICO DE LOS RESULTADOS.....	33
4. RESULTADOS Y DISCUSIÓN	36
4.1. RESULTADOS DEL PROCESADO DE DATOS A TRAVÉS DEL USO DE SIG.....	36
4.1.1. MAPAS DE LA CE _a	36
4.1.2. MAPA DEL NDVI.....	39
4.2. RESULTADOS DE LOS ANÁLISIS ESTADÍSTICOS	39

4.2.1.	PRUEBA DE NORMALIDAD DE KOLMOGOROV-SMIRNOV.....	39
4.2.2.	ESTUDIO DE CORRELACIÓN LINEAL.....	40
4.2.3.	EVALUACIÓN DE LA DISTRIBUCIÓN DE LOS VALORES DE LOS PARÁMETROS FISICOQUÍMICOS EN FUNCIÓN DE LAS ZONAS DE CEa	45
4.2.4.	MODELO PREDICTIVO DE REGRESIÓN LINEAL MÚLTIPLE.	49
5.	CONCLUSIONES.....	60
6.	LIMITACIONES DEL ESTUDIO Y LÍNEAS FUTURAS DE TRABAJO	61
7.	REFERENCIAS BIBLIOGRÁFICAS.....	62
ANEJO I. CÁLCULOS ESTADÍSTICOS COMPLEMENTARIOS		

ÍNDICE DE TABLAS

Tabla 1:	Extracciones medias de nutrientes de los cereales en las partes aéreas de la planta (grano y paja). Fuente: López-Bellido (2009). _____	8
Tabla 2:	Recomendaciones de abonado para el cultivo de trigo. Fuente: López-Bellido (2009). _____	8
Tabla 3:	Información detallada de la parcela objeto del actual TFG (parcela número 2). Fuente: elaboración propia a partir de los datos de SIGPAC. _____	19
Tabla 4:	Clases de CEa profunda en función de su rango de valores. Fuente: Elaboración propia. _____	25
Tabla 5:	Clasificación por zonas del NDVI en función de su rango de valores. Fuente: Elaboración propia. _____	32
Tabla 6:	p-valores obtenidos de la prueba de Kolmogorov-Smirnov aplicada a las variables analizadas. Fuente: Elaboración propia. _____	40
Tabla 7:	Mayores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa profunda. _____	41
Tabla 8:	Menores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa profunda. _____	41
Tabla 9:	Mayores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa superficial. _____	43
Tabla 10:	Menores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa superficial. _____	43
Tabla 11:	Estadísticos descriptivos de las variables analizadas. _____	45
Tabla 12:	Coefficientes R ² de la recta de regresión obtenida mediante Excel. _____	50
Tabla 13:	Primer modelo de regresión lineal múltiple. _____	51
Tabla 14:	Modelo de regresión lineal con mejor ajuste posible. _____	52
Tabla 15:	Comparación valores y zonas CEa real y predicha. _____	54
Tabla 16:	Predicción de la CEa de muestras adicionales con valores erróneos. _____	56
Tabla 17:	Modelo predictivo sin la variable % EG. _____	56
Tabla 18:	Predicción de valores y zonas de CEa en base al modelo sin % EG. _____	58
Tabla 19:	Predicciones con valores adicionales de CEa de las tres parcelas experimentales y de las muestras con valores elevadas de CEa de la propia parcela 2. _____	59

ÍNDICE DE FIGURAS

<i>Figura 1: Relación superficie de cereales respecto al resto de superficie cultivada en Aragón. Fuente: elaboración propia a partir de los datos de ESYRCE (2021).</i>	3
<i>Figura 2: Relación superficie sembrada de trigo respecto al resto de cereales en Aragón. Fuente: elaboración propia a partir de los datos de ESYRCE (2021).</i>	3
<i>Figura 3: Superficie cultivada de trigo blando respecto al total de trigo en Aragón. Fuente: elaboración propia a partir de los datos de ESYRCE (2021).</i>	4
<i>Figura 4: Etapas del proceso de Agricultura de Precisión. Fuente: Carrera (2020).</i>	10
<i>Figura 5: Principio de funcionamiento del VERIS 3100. Fuente: Oguri et al. (2009).</i>	11
<i>Figura 6: Receptor Trimble AgGPS332. Fuente: http://www.grap.udl.cat/es/equipamiento/material.html.</i>	12
<i>Figura 7: Reflexión de las bandas RGB y NIR por parte de las hojas según el estado de la vegetación. Fuente: Carrera (2020).</i>	14
<i>Figura 8: Logotipo ISOBUS. Recuperado de: https://es.kverneland.com/iM-FARMING/Acerca-de-ISOBUS.</i>	15
<i>Figura 9: Mapa de la localización de las parcelas de estudio a partir del Visor SigPac y PNOA. Fuente: elaboración propia a partir del SIGPAC.</i>	18
<i>Figura 10: Mapa detallado de la ubicación de las parcelas del primer ensayo de Valsalada durante el año 2021. Fuente: Minuesa (2021).</i>	19
<i>Figura 11: Diagrama ombrotérmico realizado mediante los datos de temperaturas medias y precipitaciones del municipio de Almudévar (1977-2022). Fuente: elaboración propia a partir de los datos del Gobierno de Aragón (2022).</i>	20
<i>Figura 12: Diagrama de temperaturas mensuales máximas, mínimas y media de medias realizado a partir de los datos de la estación meteorológica de Almudévar (1997-2022). Fuente: elaboración propia a partir de los datos del Gobierno de Aragón (2022).</i>	21
<i>Figura 13: Distribución climática de zonas de Aragón. Fuente: Gutiérrez y Aranda (2019).</i>	21
<i>Figura 14: Mapa de suelos de la provincia de Huesca. Fuente: Guerra et al. (1970).</i>	22
<i>Figura 15: Muestreo con el sensor VERIS 3100 en la parcela experimental 2 de Valsalada. Foto: M. Videgain.</i>	23
<i>Figura 16: Capa vectorial de los puntos de la parcela número 2 de Valsalada, tomados por el Veris 3100. Fuente: Elaboración propia.</i>	24
<i>Figura 17: Capa vectorial obtenida de los datos registrados por el Veris 3100 graduados por colores. Fuente: Elaboración propia.</i>	24
<i>Figura 18: Imagen del programa QGIS en la que se aprecia la capa ráster de CEa obtenida a partir de la capa vectorial. Fuente: Elaboración propia.</i>	25
<i>Figura 19: Imagen del programa QGIS donde se aprecia la silueta de la parcela de Valsalada y la capa vectorial con los 42 puntos de muestreo. Fuente: Elaboración propia.</i>	26
<i>Figura 20: Toma de muestras de suelo en la parcela de Valsalada. Foto: M. Videgain.</i>	27
<i>Figura 21: Procesado de las muestras para la determinación de elementos gruesos.</i>	28
<i>Figura 22: Bandeja metálica con la muestra de tierra tamizada, y separados los elementos gruesos</i>	28
<i>Figura 23: Imagen del programa QGIS con la capa ráster de CEa profunda categorizada y la nueva capa vectorial de puntos muestreados. Fuente: Elaboración propia.</i>	29
<i>Figura 24: Imagen del programa QGIS con la capa ráster de CEa superficial categorizada y la nueva capa vectorial de puntos muestreados. Fuente: Elaboración propia.</i>	30
<i>Figura 25: Imagen del programa QGIS en la que se aprecia la imagen descargada de PlanetScope y los bordes de la parcela de estudio. Fuente: elaboración propia.</i>	31
<i>Figura 26: Imagen del programa QGIS en la que se aprecia la imagen descargada de PlanetScope recortada por el límite de la parcela de estudio. Fuente: Elaboración propia.</i>	31
<i>Figura 27: Imagen del programa informático QGIS en la que se aprecia la capa categorizada del NDVI de la parcela 2 y los 42 puntos de muestreo. Fuente: elaboración propia.</i>	32

Figura 28: Imagen del programa QGIS de la capa ráster categorizada por colores en función de los valores profundos de CEa. Fuente: Elaboración propia.	36
Figura 29: Imagen del programa QGIS de la capa ráster categorizada por colores en función de los valores superficiales de CEa. Fuente: Elaboración propia.	37
Figura 30: Ortoimagen de la parcela entre los años 1956 y 1957. Fuente: Elaboración propia a partir de los datos del IGN (https://www.ign.es/web/ign/portal/ide-area-nodo-ide-ign).	38
Figura 31: Capa ráster del NDVI de la parcela 2 categorizada por colores. Fuente: Elaboración propia.	39
Figura 32: Valor medio e intervalo de confianza al 95% de los parámetros analizados en función de la CEa (CE extr 1:5), %EG, pH, %MO, CaCO ₃ , %Arcilla).	46
Figura 33: Valor medio e intervalo de confianza al 95% de los parámetros analizados en función de la CEa (%Limo, %Arena, %CC, %PMP, %CRAD, CIC).	47
Figura 34: Valor medio e intervalo de confianza al 95% del NDVI en función de la CEa. Letras diferentes muestran diferencias significativas en base al ANOVA de Kruskal-Wallis ($p < 0,05$)	48
Figura 35: Gráfico de filtrado de datos significativamente influyentes obtenido mediante el programa R.	51
Figura 36: Efecto de las variables predictoras sobre la CEa dentro del modelo predictivo (%Arena, CIC, %Limo, %MO, %EG).	55
Figura 37: Efecto de las variables predictoras sobre la CEa dentro del modelo predictivo (%Arena, CIC, %Limo, %MO).	57

ÍNDICE DE ECUACIONES

Ecuación 1: Fórmula para el cálculo del NDVI. Fuente: Rouse et al. (1974).	14
Ecuación 2: Cálculo del porcentaje en peso de elementos gruesos. Recuperado de: https://acortar.link/lrVzMd .	28
Ecuación 3: Cálculo del NDVI (Alonso, 2022).	32
Ecuación 4: Ecuación de la recta de regresión lineal múltiple.	34
Ecuación 5: Ecuación final modelo predictivo.	52

1. INTRODUCCIÓN

La variabilidad espacial inter e intraparcelsaria del suelo y su respectiva influencia en el desarrollo y rendimiento de los cultivos es conocida por la mayoría de los agricultores y técnicos, si bien, de forma tradicional siempre se ha tendido a aplicar un manejo uniforme y homogéneo con el objetivo de simplificar y acelerar las labores, sin tenerse en cuenta sustancialmente las distintas respuestas agronómicas en cada caso.

Desde las décadas de 1980 y 1990, los profundos cambios tecnológicos que se han desarrollado, como por ejemplo los avances en las tecnologías de la información y comunicación y de los sistemas satelitales de posicionamiento global (GNSS), entre otros, han favorecido el desarrollo de la denominada Agricultura de Precisión (IICA, 2014), que se postula como *“la aplicación de tecnologías y principios para el manejo de la variabilidad espacial y temporal asociada a todos los aspectos de la producción agrícola, con el fin de mejorar la productividad del cultivo y la calidad ambiental”* (Pierce y Nowak, 1999). Con la adopción de las técnicas de Agricultura de Precisión (AP) es posible analizar la variabilidad espacial de las propiedades del suelo y el consecuente desarrollo y rendimiento de los cultivos en cada una de las condiciones, lo que posibilita la prescripción y aplicación de manejos diferenciados. Para ello existen sensores como los medidores de la conductividad eléctrica aparente (CEa) del suelo, desarrollados a partir de la década de 1980; los monitores de rendimiento instalados en las cosechadoras desde 1990; o los sensores multispectrales en satélites para la adquisición de imágenes detalladas sobre el desarrollo de los cultivos, posibilitando todos ellos la aplicación conjunta de la Agricultura de Precisión (Minuesa, 2021).

Sin embargo, es cierto que todas estas tecnologías han sido aplicadas mayoritariamente en cultivos de alto valor, con altos márgenes económicos, como el maíz en regadío, cultivos hortofrutícolas como la viña, o en grandes fincas tecnificadas, dejando a un lado la agricultura cerealista de secano, la cual mantiene el histórico manejo homogéneo de las labores e insumos, con las dosis uniformes de siembra, de abonados de fondo y cobertera e incluso de agua de riego.

Con una superficie total en el año 2019 de 724,3 Mha, *“los cereales siguen siendo con gran diferencia la fuente de alimentos más importante del mundo, tanto para el consumo humano directo como, de una manera indirecta, para los insumos de la producción pecuaria”* (FAO, 2018). En España, se cultiva una media de 6 Mha de cereales, siendo el sector con mayor base territorial y distribución a lo largo de todo el territorio. De esta superficie sembrada, el 94% corresponde a cereales de invierno y el resto a maíz, y la mayor parte de estos cereales de invierno como el trigo o la cebada se cultivan en secano (MAPA, 2020). En concreto, esta superficie sembrada por cereal de invierno en secano es de 4,9 Mha.

La comunidad autónoma de Aragón, en la cual se ubica el municipio de Valsalada, provincia de Huesca, donde se realizan los ensayos correspondientes a este trabajo de fin de grado, es la cuarta a nivel nacional en superficie destinada a cereales de grano, con un 13,61%.

Una de las razones más significativas a la hora de plantear la aplicación de técnicas de Agricultura de Precisión es la posible reducción del impacto de la agricultura sobre el medio

ambiente. Las normativas europeas cada vez se endurecen más en este sentido y se impulsa la reducción en la aplicación de insumos como agua, productos fitosanitarios o fertilizantes, con el objetivo de evitar contaminaciones en el medio y de evitar el agotamiento de los recursos, por lo que todos los agricultores deben adaptarse y hacer uso de nuevas técnicas más respetuosas con el medio ambiente. Sin embargo, en el año 2022, el sector agrícola está pasando por escenarios nunca antes vividos, pues tanto los precios de los cereales como los de todos los insumos se han disparado, hasta desencadenar lo que muchos agricultores han denominado como “la campaña más cara de la historia”. Por ello, el profundizar en el conocimiento de la aplicación de las técnicas de Agricultura de Precisión en secano puede ser fundamental para maximizar los beneficios, minimizando igualmente todos los costes operativos y fomentando un mayor aprovechamiento de los recursos.

Este Trabajo de Fin de Grado, por tanto, se centra en el estudio de la variabilidad intraparcelaria del suelo y la relación entre sus propiedades y la productividad del cultivo, en un contexto de aplicación de técnicas de Agricultura de Precisión; y se encuentra dentro del grupo de cooperación de agentes del sector agrario “AP-Extensivos”, enmarcado en el Programa de Desarrollo Rural para Aragón 2014-2020, en el que participan distintas entidades del sector agrícola, entre ellas la Escuela Politécnica Superior como centro tecnológico colaborador.

1.1. AGRICULTURA DE LA ZONA

1.1.1. CULTIVOS

La zona de estudio se localiza en Valsalada (Almudévar, Huesca), que está situada en zona climática catalogada como secano semiárido, lo que influye en el sistema de rotaciones adoptado. Los cultivos que se implantan en esta zona se albergan dentro de un estrecho abanico de especies, siendo los de mayor importancia económica y territorial los **cereales de invierno**, con una superficie total de 700.000 ha, que respecto al total de superficie arable de secano de la que dispone nuestra comunidad autónoma, 4.348.782 ha, corresponde a un 16% (ESYRCE, 2021). Dentro de ellos podemos diferenciar los de mayor relevancia:

- **CEBADA (tanto de 2 como de 6 carreras)**

Es el cultivo de mayor base espacial dentro del grupo de los cereales de invierno destinados a la producción de grano, con un total cercano a las 700.000 ha. Más de un 97% corresponde a variedades de 2 carreras, estando prácticamente en desuso las de 6 y recogidas en variedades antiguas o dentro de las nuevas híbridas (ESYRCE, 2021).

- **TRIGO (tanto duro como blando)**

Con una superficie de 220.000 ha implantadas en sistemas agrícolas de secano, es el segundo en importancia, tras la cebada. La superficie destinada al trigo duro es de 56.000 ha, quedando prácticamente recogida en la provincia de Zaragoza, mientras que en Huesca es predominante el trigo blando, con un 73% de la superficie total destinada a este cultivo (ESYRCE, 2021).

Se trata del cultivo implantado durante la actual campaña en las parcelas objeto del estudio, particularmente la variedad Filón.

Las figuras 1, 2 y 3 muestran gráficamente la importancia a nivel superficial de los cultivos de cereales, trigo total y trigo blando, respectivamente, dentro de la comunidad autónoma de Aragón.

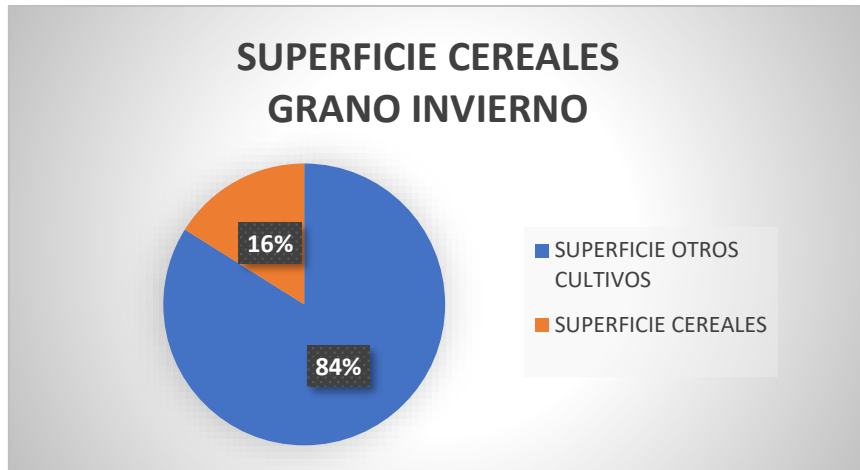


Figura 1: Relación superficie de cereales respecto al resto de superficie cultivada en Aragón. Fuente: elaboración propia a partir de los datos de ESYRCE (2021).

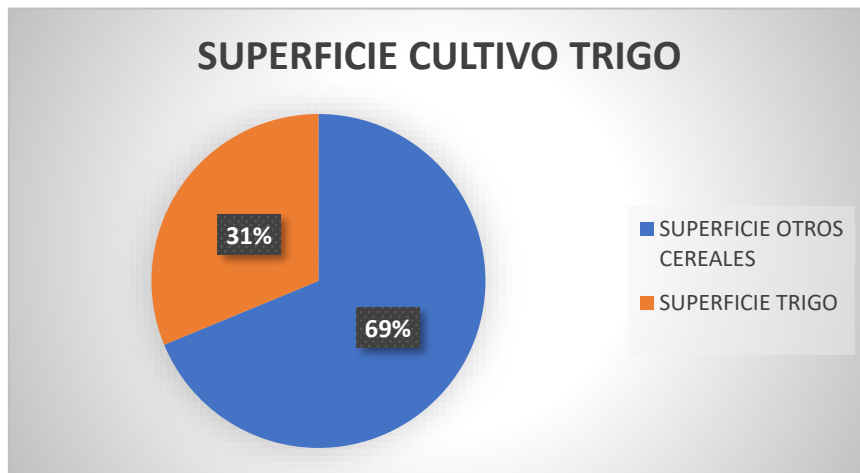


Figura 2: Relación superficie sembrada de trigo respecto al resto de cereales en Aragón. Fuente: elaboración propia a partir de los datos de ESYRCE (2021).




Figura 3: Superficie cultivada de trigo blando respecto al total de trigo en Aragón.
Fuente: elaboración propia a partir de los datos de ESYRCE (2021).

Adicionalmente a los cereales de invierno, también pueden encontrarse cultivos de otras familias y usos, como es el caso de las **leguminosas**, entre las cuales podemos diferenciar dos grupos:

- **LEGUMINOSAS GRANO**

Son aquellos cultivos proteicos incluidos en la rotación de cultivos con un objetivo similar a los cereales, la obtención de grano. Su importancia es inferior, con una superficie cultivada en el año 2021 de 11.000 ha, abarcadas principalmente por los guisantes (> 60%), veza (20%) y recientemente habas secas (14%) (ESYRCE, 2021).

- **LEGUMINOSAS FORRAJERAS**

Son igualmente cultivos proteicos, pero en este caso destinados a la obtención de forrajes, bien verdes o secos, principalmente para su aprovechamiento a nivel regional o nacional, pues la producción mayoritaria de forrajes para exportación se encuentra en superficie regable, dado su mayor potencial productivo. El principal cultivo bajo esta clasificación es la alfalfa, con casi 14.000 ha, aunque también se encuentra la veza, habitualmente en combinación con avena, aunque minorita en superficie (1.300 ha) (ESYRCE, 2021).

Por último, podemos hablar de un tercer grupo, como es el de las **Oleaginosas** o **cultivos oleicos**, con una ligera importancia, pues su superficie registrada durante la campaña 2021 fue de 11.309 ha, lo que representa un pequeño porcentaje del 0,26% respecto al total de superficie arable de secano. Dentro de este grupo se encuentran la colza, con algo más de 3.000 ha y el girasol, con unas 8.300 ha (ESYRCE, 2021).

1.1.2. PRÁCTICAS AGRONÓMICAS

En la provincia de Huesca se ha practicado el laboreo tradicional del suelo como práctica agronómica característica, sin embargo, desde comienzos de la década de los 90, se inició la implantación de la siembra directa, con el objetivo de disminuir los costes productivos y evitar las labores en los meses más cálidos del verano. Posteriormente, comenzó a difundirse y a ganar importancia el concepto de Agricultura de Conservación.

Según datos del Gobierno de Aragón, la siembra directa ya ocupaba el 14,43% de la superficie total destinada a los cereales (MAPA, 2020).

En las parcelas de la localidad de Valsalada, donde se están realizando los ensayos objeto de este Trabajo de Fin de Grado (TFG), se practica la siembra directa desde hace 3 años, momento en el cual hubo un cambio en el arrendatario, pasando su gestión a manos de la Cooperativa Comarcal del Campo Virgen de la Corona, de Almudévar.

Bajo este sistema de no laboreo es esencial el control de la flora arvense, tanto mediante medios mecánicos, como pueden ser las trituradoras o desbrozadoras, o mediante la aplicación de productos químicos, como son los herbicidas, los cuales pueden ser aplicados previamente a la siembra del cultivo, o durante su desarrollo vegetativo.

1.1.3. ROTACIÓN DE CULTIVOS

Se trata de una de las bases fundamentales de la agricultura, y más aún bajo los sistemas de agricultura de conservación y de no laboreo del suelo.

“La rotación de cultivos consiste en la siembra sucesiva de diferentes cultivos en un mismo terreno, siguiendo un orden definido. Este concepto se contrapone al monocultivo, consistente en la siembra repetida de una misma especie en el mismo campo, año tras año.”
(www.climagri.com)

La implementación de estas rotaciones permite alcanzar un incremento de la producción sumado a la disminución de los insumos gracias a distintas razones:

1. Se reduce la incidencia de plagas y enfermedades debido al cambio de hábitat, lo que interrumpe sus ciclos de vida.
2. Se mejora el control de la flora arvense gracias a los cultivos de cobertura, que se utilizan como abonos verdes, o debido al cambio de las familias de especies, que permiten utilizar distintos productos herbicidas y momentos de aplicación, evitando la aparición de resistencias.
3. Se consigue una mejor distribución de los nutrientes a lo largo del perfil del suelo, pues los cultivos con sistemas radiculares más potentes son capaces de extraerlos a mayor profundidad.
4. Se disminuyen los riesgos económicos ante posibles eventualidades que afecten a un cultivo en particular.
5. Se regula la cantidad de restos de cosecha, pues se alternan cultivos con mayor y menor producción de los mismos.

En las parcelas de secano de gran parte de la provincia de Huesca, la base de la rotación de cultivos es el grupo de aquellos con mayor margen económico, es decir, los cereales de invierno como el trigo o la cebada, los cuales deben alternarse principalmente con leguminosas.

El principal beneficio de este segundo grupo de cultivo es la fijación de nitrógeno gracias a los nódulos de sus raíces, que producen una simbiosis con bacterias fijadoras de nitrógeno que se encuentran en el suelo. El tipo de leguminosa elegida en la rotación depende de varios factores, como son la climatología, los medios del agricultor y su aprovechamiento. De esta forma es posible encontrar guisantes destinados a la producción de grano, o veza bien para grano (parte minoritaria) o forrajera (muy habitual en las explotaciones mixtas con ganado). Desde hace unos años se ha comenzado a introducir el cultivo de las habas secas, interesante desde el punto de vista agronómico por su mayor sistema radicular, capaz de fijar una mayor cantidad de nitrógeno, y por una mayor producción de grano, lo que reporta mayores ingresos económicos.

Existe un tercer grupo de especies también introducidas en las rotaciones de secano, con diferentes beneficios a las leguminosas, como son las oleaginosas. Dentro de este grupo se encuentran la colza y el girasol, como se ha explicado anteriormente en el apartado 1.2.1. *Cultivos*, sin embargo, cabe destacar la mínima presencia de girasol en la provincia de Huesca, primándose la colza, debido al similar ciclo a los cereales. Se trata de una planta de la familia de las crucíferas, con raíz pivotante, flor amarilla y fruto en silicua. Este cultivo ha sufrido un gran incremento en la superficie sembrada tanto a nivel local como nacional, con una superficie total en el corriente año 2022 de 119.500 ha, lo que supone un aumento del 170% respecto al año 2020; y lo hace por el interés de su potente sistema radicular, el cual es capaz de extraer nutrientes a mayor profundidad que los cereales, además de presentar una mayor resistencia al estrés hídrico.

De igual manera que las especies, el cronograma de la rotación depende de la climatología, medios de trabajo, utilización del producto etc., sin embargo, como rotación principal en suelos pobres, con poca cantidad de precipitación anual, se postula como predominante la siguiente:

TRIGO – CEBADA – LEGUMINOSA (GUI SANTES, VEZA, HABAS)

Otro factor determinante a la hora de modificar dicho cronograma es la disponibilidad de estiércoles, purines u otros fertilizantes orgánicos dentro de la propia explotación agrícola o agropecuaria, pues se hace necesaria una alta superficie agrícola para su aplicación, la cual queda reducida por las leguminosas, por lo que se alternan trigo y cebada, intentando no realizar dos siembras de cebada consecutivas en la misma parcela debido a problemas como los nemátodos o el menor control de la flora arvense por el menor abanico de fitosanitarios disponibles. Todos estos escenarios están desembocando en la mayor importancia de las oleaginosas, colza principalmente, dentro de las rotaciones de la provincia de Huesca, desplazando a las leguminosas a un espacio de menor superficie e interés.

1.1.4. MANEJO DEL CULTIVO DE TRIGO

En la parcela en la que se están desarrollando los ensayos de Agricultura de Precisión durante el año 2022, dentro de la campaña de cereal de invierno 2021-2022, está implantado el cultivo de trigo.

Se trata de un cereal de invierno de la familia de las gramíneas, cultivado en todo el mundo, aunque la zona templada del hemisferio norte es su principal área de cultivo. Se considera parte fundamental del desarrollo económico y cultural del hombre, siendo el cereal más cultivado a nivel mundial. Se utiliza como alimento para el hombre gracias a la capacidad de cocción de su harina debido a la elasticidad del gluten que contiene, aunque en gran parte se destina a la alimentación animal (MAPA, 2020).

Dentro de las variedades de trigo, se pueden encontrar tanto de primavera como de otoño/invierno, en función de la fecha en la que puede ser sembrado, sin embargo, dado que en nuestra región los trigos de primavera no tienen cabida en los sistemas de secano, este trabajo se centra en una variedad de otoño/invierno, las cuales destacan por una integral térmica de entre 1.900 y 2.400 °C, por lo que las siembras deberán ser tempranas, desde finales del mes de octubre hasta mediados de noviembre para la provincia de Huesca.

El cultivo destaca por un sistema radicular capaz de alcanzar más de 1 m de profundidad, si bien la mayoría de ellas se sitúan en los primeros 25 cm, y por una inflorescencia en forma de espiga compuesta.

“El rendimiento del cultivo de trigo en una región determinada es la resultante de la interacción entre factores ecológicos, tecnológicos y genéticos. La potencialidad del cultivo de trigo difiere entre las distintas regiones productivas debido a factores fundamentalmente climáticos. Sin embargo, en muchos casos, los rendimientos potenciales del cultivo no se alcanzan debido a la oferta reducida de recursos. La nutrición, y su manejo a través de la fertilización, constituye uno de los principales recursos que limitan la producción de trigo” (García, 2014).

Las producciones mundiales son muy variables, desde inferiores a 1 t ha⁻¹ en ciertos países en vías de desarrollo hasta las 6 t ha⁻¹ en Europa. Dentro de España, durante el año 2020 se observó una producción media de 4,23 t ha⁻¹ en las 1.661.700 ha sembradas de trigo blando, mientras que para la comunidad autónoma de Aragón esta fue de 3,87 t ha⁻¹, y particularmente para la provincia de Huesca de 4,81 t ha⁻¹ (MAPA, 2022).

Los requerimientos nutricionales para el cultivo de trigo son similares al resto de los cereales, como por ejemplo para la cebada, y dependen de las producciones esperadas, aunque “el **nitrógeno** es el principal elemento mineral y el de mayor influencia en el rendimiento de los cereales. Sin embargo, cada uno de los tres elementos principales (nitrógeno, fósforo y potasio) no produce su pleno efecto si no están presentes cantidades suficientes de los otros dos” (López-Bellido, 2009).

“De las interacciones entre estos tres elementos principales, la más importante se produce entre el nitrógeno y el potasio, pues dosis elevadas de nitrógeno en ausencia de potasio suficiente hace a los cereales sensibles a enfermedades y sobre todo al encamado, limitando los rendimientos” (López-Bellido, 2009). De esta forma, el potasio puede aumentar la producción del nitrógeno en más de un 50%. El **fósforo** mejora la precocidad de los cereales

y favorece su desarrollo radicular además de participar en la formación de espigas y granos; y el **potasio** influye esencialmente en las funciones que aseguran el crecimiento de la planta, además de aumentar tanto el peso específico como el peso de mil granos. La absorción de estos elementos minerales es intensa tras el ahijado, durante el encañado, y hasta la formación de la espiga.

Además de estos tres nutrientes esenciales, los cereales y especialmente el trigo absorben de igual manera, aunque en niveles inferiores, cantidades importantes de calcio, magnesio y azufre. La siguiente tabla explica las extracciones de nutrientes que realizan los cultivos de trigo y cebada por cada tonelada de grano producida.

La tabla 1 muestra las extracciones de los principales elementos por tonelada de producción de ciertos cereales, como es el caso del trigo.

Tabla 1: Extracciones medias de nutrientes de los cereales en las partes aéreas de la planta (grano y paja). Fuente: López-Bellido (2009).

Cereales de invierno	kg/000 kg de grano producido ⁽¹⁾					
	N	P ₂ O ₅	K ₂ O	CaO	MgO	S
Trigo	28-40	9-15	20-35	5-7	3,5-5	5,2
Cebada	24-28	10-12	19-35	10	5,2	4,1
Avena	24-30	10-14	23-35	-	-	6,1
Centeno	18-20	12-14	16-20	-	-	-

Según se aprecia en la tabla 1, y para los rendimientos promedio de la provincia de Huesca de entre 4 y 5 t ha⁻¹, se establecen unas necesidades de aportes totales de 120–150 kg de nitrógeno, 48–50 kg de fósforo y 112–140 kg de potasio (por hectárea y año).

En base a dichos datos, se han elaborado tablas con recomendaciones para abonados de fondo y cobertera, como la tabla 2, realizada por ANFFE (2010), la cual presenta una orientación para la aplicación de nutrientes en base a distintos niveles de producción esperada.

Tabla 2: Recomendaciones de abonado para el cultivo de trigo. Fuente: López-Bellido (2009).

Producción (kg/ha)	Abonado de fondo (kg/ha)			Cobertera (kg N/ha)
	N	P ₂ O ₅	K ₂ O	
Hasta 2.000	15-20	30-50	20-30	30-40
2.000-3.000	20-25	45-70	25-45	40-65
3.000-4.000	25-35	60-90	40-65	65-85
Más de 4.000	35-40	80-130	60-90	85-110

Respecto a la aplicación de otros nutrientes, se puede decir que las deficiencias de azufre pueden corregirse aplicando fertilizantes complejos que lo contengan, cuando estas carencias no son excesivas; y respecto al magnesio, las deficiencias se observan en suelos

lixiviados con poca capacidad de retención de agua, por lo cual es posible y recomendable aplicar en suelo igualmente abonos complejos que lo contengan, o en pulverización foliar.

De esta forma, se puede observar cómo los nutrientes esenciales deben ser aplicados en fondo, destinando la cobertera a efectuar el mayor aporte de nitrógeno o cualquier aplicación foliar de elementos en escasez o con necesidad de complementación.

1.2. AGRICULTURA DE PRECISIÓN

1.2.1. CONCEPTO Y DEFINICIÓN

La Agricultura de Precisión (AP) se define como una estrategia de gestión encargada de la recogida, análisis y procesado de datos temporales, espaciales e individuales relacionados con cualquier campo o parámetro que se busque determinar, así como de su combinación con otra información asimismo disponible, con el objetivo de respaldar las decisiones de manejo en base a la variabilidad estimada, y así incrementar la eficiencia de las explotaciones con su consiguiente ahorro de recursos, aumento de la productividad y calidad, traduciéndose en una mayor rentabilidad y sostenibilidad de la producción agrícola (ISPA, 2018).

Como se deriva de esta definición, para desempeñar las técnicas de AP se hace fundamental la recogida o toma de datos acerca de los parámetros que se quieren controlar, por lo que el primer paso para poner en práctica estas técnicas será la **adquisición de datos** como lecturas de sensores, imágenes satelitales, datos de campo etc.

Una vez los datos han sido recopilados, la siguiente etapa dentro del proceso de tecnificación de la agricultura consiste en **analizar y procesar** dichos **datos** para poder aplicar la tecnología disponible. Para ello, se hace indispensable el conocimiento de las técnicas disponibles como puede ser la elaboración de mapas de acuerdo a la variabilidad, así como de conocimiento acerca de la utilización de softwares y programas informáticos como los SIG (Sistemas de Información Geográfica). Si bien esta fase requería anteriormente un alto grado de conocimientos específicos, gracias a los nuevos avances en tecnología se han desarrollado plataformas de ciertas marcas comerciales destinadas a la automatización de ese procesado y análisis con los objetivos de abaratar los costes y facilitar el acceso a estas nuevas tecnologías a un mayor público.

La tercera etapa de este proceso de puesta en práctica de las técnicas disponibles de AP es la **toma de decisiones**, es decir, evaluar las distintas alternativas de operaciones de manejo agronómico que se tienen a disposición y declinarse por la opción más conveniente. Esta es la fase del proceso que requiere una mayor cualificación desde el punto de vista agronómico, pues es necesario evaluar la sanidad de los cultivos, así como los estados fisiológicos, estados del suelo, coste económico de los tratamientos, eficacias esperables etc., por lo que en el caso de no contar con dichos conocimientos es esencial un correcto asesoramiento por parte de personal cualificado y especializado.

El último paso es la **actuación en campo**, dando aplicación práctica a esos datos una vez procesados y expuestos en forma de prescripciones o demás formatos, enfocados a las fincas o zonas que se pretenda manejar.

Todo el proceso de agricultura de precisión se recoge en la figura 4.

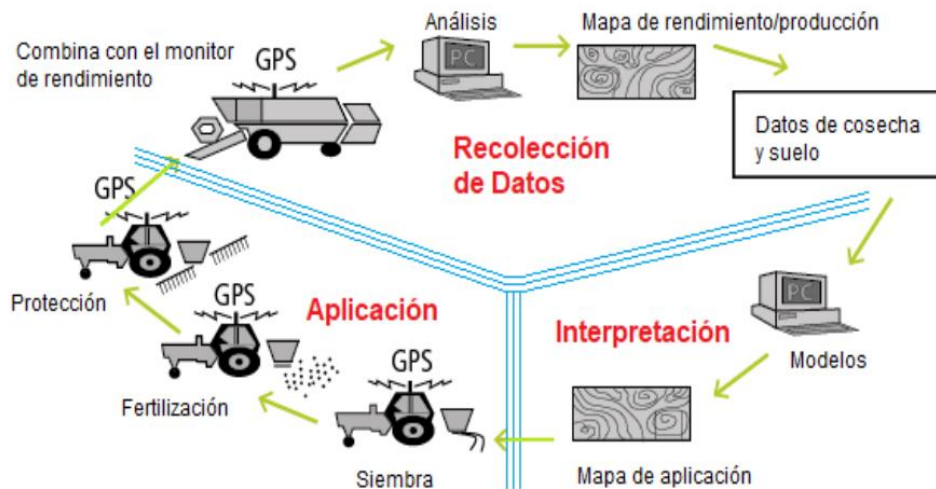


Figura 4: Etapas del proceso de Agricultura de Precisión. Fuente: Carrera (2020).

En el caso del presente Trabajo de Fin de Grado, se ha determinado la correlación existente entre la CEa del suelo y sus propiedades fisicoquímicas, analizando los efectos sobre el cultivo en condiciones de secano, por lo que se ha trabajado principalmente con las siguientes fuentes de información:

1. Mapa de la CEa del suelo de la parcela.

Con él se ha determinado la variabilidad intraparcelsaria y se han clasificado distintas zonas de trabajo de las que se ha obtenido una mayor información a través del muestreo del suelo.

2. Imágenes satelitales.

Obtenidas mediante la constelación de satélites *PlanetScope*. A partir de ellas se ha obtenido el índice de vegetación del cultivo (NDVI) con el objetivo de determinar los distintos estados de desarrollo del cultivo, para relacionarlo de dicha manera con el mapa de CEa y observar si igualmente existe una correlación directa que lo inflencie.

De esta forma, en los siguientes apartados se explican las tecnologías de Agricultura de Precisión que han sido aplicadas dentro de este TFG.

1.2.2. CONDUCTIVIDAD ELÉCTRICA APARENTE (CEa)

Se entiende por conductividad eléctrica aparente (CEa) del suelo aquella que se mide *in situ* en el suelo sin disturbarlo, y permite identificar valores de la salinidad, contenido de humedad, textura, capacidad de intercambio catiónico (CIC), densidad aparente o incluso contenido de materia orgánica (MO) (Rojas, 2015).

Dentro de las técnicas y tecnologías disponibles de la AP, los sensores que miden la **CEa** del suelo pueden ser una alternativa a tener en cuenta para poder determinar la variabilidad de las propiedades del suelo en cada punto de una parcela agrícola. (Martínez-Casasnovas et al., 2021). Estos sensores se utilizan cada vez más para comprender y evaluar cómo varía espacialmente el suelo (Corwin y Lesch, 2003), y también para definir zonas de manejo diferenciado en las parcelas agrícolas, cualquiera que sea el cultivo (Käthner y Zude-Sasse, 2015; Uribeetxebarria *et al.*, 2018a). Como la CEa varía en una escala espacial similar a la de muchas propiedades fisicoquímicas del suelo (Sudduth et al., 2003), esta tecnología está siendo ampliamente aceptada y utilizada. Específicamente, se han documentado buenas correlaciones con respecto a la salinidad del suelo, la capacidad de retención de humedad y su textura (Corwin y Lesch, 2005), o incluso con el contenido de materia orgánica (Sudduth et al., 2003; Martínez et al., 2009), la capacidad de intercambio catiónico (Sudduth et al., 2005), el contenido de CaCO₃ (Kühn et al., 2009; Uribeetxebarria et al., 2018a), o la profundidad del suelo (Uribeetxebarria et al., 2018a).

Para medirla se pueden emplear sensores de inducción electromagnética, o bien de resistividad eléctrica. En el caso de este trabajo, el sensor utilizado ha sido el sensor geoeléctrico Veris 3100 (www.veristech.com), que mide la CEa del suelo mediante el principio de resistividad eléctrica. Para tomar los valores, este sensor debe estar en contacto con el suelo, además de ser remolcado por un tractor o vehículo con potencia suficiente para arrastrarlo a lo largo de la parcela (Minuesa, 2021).

El Veris 3100 es un sensor de contacto que contiene 6 discos diferentes, los cuales entran en contacto con el suelo para tomar valores de manera continuada. Por tanto, estos discos trabajan como electrodos, unos de los cuales emiten una corriente eléctrica que es recibida por los otros. Estos discos se han designado con las letras M, N, A y B según sea su función, como puede observarse en la figura 5.




Figura 5: Principio de funcionamiento del VERIS 3100. Fuente: Oguri et al. (2009).

Los discos o electrodos A y B son de inyección, pues introducen en el suelo una corriente eléctrica dada mediante una fuente de alimentación, mientras que las parejas de discos M y N se encargan de recibir esa corriente y determinar la CEa en función de la tasa recibida.

La pareja de electrodos M y N situada entre los discos A y B son los que se encuentran a menor distancia, por lo que captan la corriente de electrones a baja profundidad, obteniendo valores de la CEa superficial, entre 0 y 30 cm; mientras que la pareja de electrodos M y N que se encuentra más alejada de los discos inyectoros puede captar las líneas de corriente más profundas, así como las superficiales, por lo que obtienen valores de CEa de capas superficiales y profundas, entre 0 y 90 cm.

La recopilación de información sobre el manejo y características de cada parcela se hace necesaria para decidir el nivel de profundidad de la CEa que mejor describe la variabilidad intraparcularia. Uno de los factores que hacen que se decline al uso de las medidas en profundidad es la mejor representación de las propiedades del suelo pues las capas superficiales se ven afectadas por las labores de trabajo del suelo, obteniendo en consecuencia lecturas variadas que no representan la variabilidad del suelo tal y como es.

Para representar gráficamente los valores tomados por los electrodos en forma de discos del Veris 3100, es necesaria una georreferenciación espacial, la cual no necesita ser altamente precisa, por lo que se puede llevar a cabo a través de diferentes receptores GPS, de amplio uso para todo tipo de labores en los actuales tractores y maquinaria agrícola. La figura 6 muestra un ejemplo de este tipo de receptores.



Figura 6: Receptor Trimble AgGPS332. Fuente: <http://www.grap.udl.cat/es/equipamiento/material.html>.

1.2.3. TELEDETECCIÓN: IMÁGENES SATELITALES

Para analizar la variabilidad espacial y temporal encontrada en una parcela y poder aplicar un manejo óptimo, la Agricultura de Precisión cuenta con distintos mecanismos y tecnologías con el objetivo de facilitar dicha recolección de datos y hacerla más correcta. Para ello, son utilizados mayoritariamente los sensores, pues nos permiten medir cualquier parámetro necesario y obtener una información específica. Existen diferentes sensores, como sondas para la medición de la humedad o temperatura del suelo y organizar calendarios o fechas concretas de riegos, sensores de cultivo para medir la radiación espectral reflejada y obtener valores del estado de desarrollo del cultivo etc.

Una forma de obtener información del cultivo muy utilizada hoy en día se basa en la **Teledetección**, la cual puede definirse como “*la ciencia y tecnología para adquirir información sobre la superficie de la Tierra sin estar realmente en contacto con ella. Esto se realiza mediante la detección y grabación de la radiación reflejada y/o emitida y su posterior procesamiento, análisis e interpretación de la información resultante*” (Martínez-Casasnovas, 2019).

Se puede explicar que la teledetección está enfocada a la toma y procesado de datos de radiancia espectral, es decir, luz de diferentes longitudes de ondas que son captadas por sensores multispectrales posicionados en plataformas móviles espaciales como son los satélites, aeronaves o recientemente en drones.

Una de la información espectral más ampliamente utilizada es la obtenida mediante imágenes de satélite, con el fin de facilitar y abaratar los costes operacionales, pues de esta forma solamente es necesario descargar la imagen satelital de la fecha deseada y procesarla mediante la aplicación de distintos filtros. Esto presenta un pequeño inconveniente como es la resolución de los píxeles, pues dependiendo de los satélites empleados esta medida puede variar, sin embargo, mediante el uso de un vehículo aéreo no tripulado (VANT) más conocidos como drones, se puede reducir consiguiendo una resolución mucho mayor. Uno de los inconvenientes que sin embargo presenta esta tecnología es la imposibilidad de obtener imágenes nítidas de la superficie terrestre cuando aparece algún obstáculo intermedio como son habitualmente las nubes.

Dentro de la Unión Europea, se creó el programa Copérnico, desarrollado por la Agencia Espacial Europea (ESA), que lanzó la misión Sentinel-2 en 2015 y 2017. Esta misión consta de dos satélites (Sentinel-2A y Sentinel-2B) con un tiempo de revisita entre los dos satélites de 5 días y una resolución espacial de 10 m de pixel en las bandas del visible (RGB) e infrarrojo próximo (NIR) para la caracterización de la vegetación, el suelo y la cubierta de agua (Minuesa, 2021).

También existen ciertas compañías privadas de observación terrestre como es el caso de *Planet Labs*, las cuales disponen de sus propios satélites, llamados en este caso *PlanetScope constellations*, y presentan la capacidad de obtener imágenes de alta resolución en lugar de mediana resolución, gracias a una constelación que consta de aproximadamente 180 nanosatélites capaces de obtener imágenes de 150 millones de km² por día en las bandas espectrales RGB y NIR, dando como resultado de ello la disponibilidad de imágenes diarias y de resolución de 3 m de pixel a lo largo de toda la superficie terrestre.

El NDVI (Normalized Difference Vegetation Index) o índice de vegetación de la diferencia normalizada es el más usado a la hora de determinar estados de desarrollo de la mayoría de los cultivos y obtener mapas georreferenciados con dicha información.

Su obtención se lleva a cabo mediante la información que se encuentra en ciertas bandas del espectro electromagnético que la vegetación emite o refleja, concretamente es necesaria la información contenida en las bandas roja (Red) en infrarroja (NIR), y para su cálculo, en el caso de imágenes obtenidas de la constelación *Planet Scope*, se debe hacer la diferencia entre la reflectancia de las bandas 4 (infrarrojo cercano) y 3 (visible – rojo) dividido por la suma de estas dos bandas de reflectancia (Alonso., 2022), tal y como se muestra en la ecuación 1.

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Ecuación 1: Fórmula para el cálculo del NDVI. Fuente: Rouse et al. (1974).

Los valores de este índice fluctúan entre -1 y +1, y para su interpretación es necesario conocer las siguientes premisas:

- **Valores negativos:** Indican la presencia de nubes o agua, y también de algunos suelos desnudos, por lo que dichos valores no son representativos en el análisis del estado de desarrollo de la vegetación.
- **Valores cercanos a 0:** Indican que el suelo se encuentra al descubierto, es decir, no existe vegetación en dicha zona.
- **Valores cercanos a 1:** Indican mayor índice de vegetación de la planta, es decir, un mayor desarrollo de la planta que puede apuntar a mayores rendimientos productivos.

La figura 7 muestra gráficamente las diferencias en la reflexión de las bandas RGB y NIR, en función del estado del cultivo.

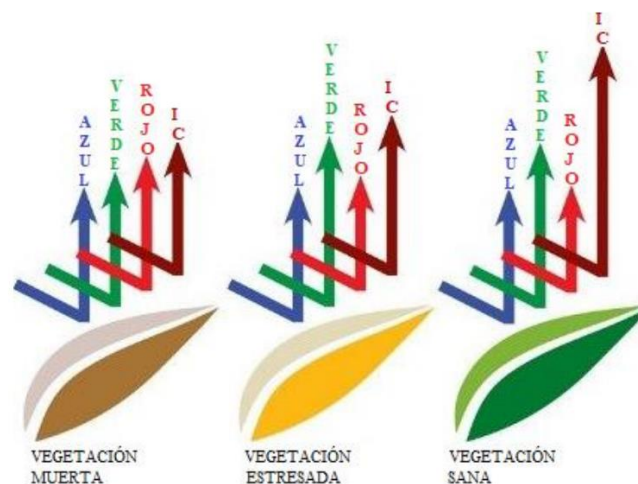


Figura 7: Reflexión de las bandas RGB y NIR por parte de las hojas según el estado de la vegetación. Fuente: Carrera (2020).

En el año 2005 se realizó un experimento en Chapingo (Méjico), en el que se realizó una estimación temprana del rendimiento de un cultivo de cebada en condiciones de regadío mediante el uso de sensores remotos, comprobándose como la relación existente entre el NDVI calculado a partir de valores de reflectancia de las bandas rojas e infrarrojas de la imagen del satélite Landsat 7 presentaba una alta correlación con el posterior rendimiento (Ruiz-Huanca et al., 2005).

Tal y como argumentaban Castro y Costa (2012), el mapa de CEa puede considerarse una fuente de información fiable para explicar la variabilidad espacial de ciertas propiedades fisicoquímicas del suelo como los contenidos de limo y arcilla, así como de la materia orgánica (MO) y el pH, y con todo ello poder efectuar un manejo sito específico ante la heterogeneidad de las zonas previamente evaluadas.

De esta forma, gracias al análisis y estudio del NDVI de forma simultánea a la CEa, en el presente trabajo se buscará determinar si esta variabilidad espacial ya asumida y conocida está directamente relacionada con la respuesta del cultivo en cada una de esas zonas diferentes y si ello influye significativamente en el rendimiento final del cultivo.

1.2.4. APLICACIONES PRÁCTICAS DE LA AGRICULTURA DE PRECISIÓN A TRAVÉS DE LA TECNOLOGÍA DE LA MAQUINARIA AGRÍCOLA

Una vez obtenidos los datos sobre variabilidad, estado de desarrollo, etc., se analizan y se toman decisiones en base a ellos. La información procesada, así como las prescripciones que a partir de ella se realizan, deben ser transformadas a un lenguaje que permita su manipulación; el paso final del proceso de aplicación de esta tecnología es su exportación a la maquinaria o instrumentación encargada de su lectura y puesta en práctica.

Para ello, existen diversidad de equipos (sembradoras, abonadoras, pulverizadores de fitosanitarios, etc.) capaces de recibir esa información en los formatos necesarios y de, por tanto, leer las prescripciones variables con el objetivo de trabajar en base a esa variabilidad previamente observada y esperada.

En este sentido, la tecnología ISO-BUS se postula como fuente de conexión más versátil, segura y extendida (figura 8). Esta tecnología es capaz de poner en contacto tractor y apero, leer la información, todo ello posicionado espacialmente mediante GPS para aplicar las dosis variables. La figura 8 muestra el logotipo de la marca registrada ISO-BUS, de amplia utilización en la maquinaria agrícola.



Figura 8: Logotipo ISOBUS. Recuperado de:
<https://es.kverneland.com/iM-FARMING/Acerca-de-ISOBUS>

Dentro de la agricultura cerealista de la provincia de Huesca, cabe destacar que la tecnificación de las explotaciones ha evolucionado a un ritmo mayor en las zonas de regadío,

donde los mayores rendimientos generan mayores márgenes de beneficios con los que poder soportar estas nuevas inversiones; sin embargo cabe destacar que, a medida que transcurren los años, las nuevas tecnologías también van siendo adoptadas en explotaciones de secano, en las que por el momento los equipos ISO-BUS aparecen en pulverizadores, sembradoras, abonadoras de precisión y en ciertas cosechadoras para la obtención de mapas de rendimiento.

2. OBJETIVOS

Los objetivos principales de este Trabajo de Fin de Grado son (I) analizar y determinar si existe una correlación entre las propiedades texturales del suelo de una zona de cultivo y su conductividad eléctrica aparente (CEa), y (II) evaluar su influencia sobre el índice de vegetación del cultivo.

Los objetivos principales se alcanzarán mediante la consecución de los siguientes objetivos específicos:

- 1- Caracterizar la variabilidad de la CEa del suelo de la parcela de estudio.
- 2- Caracterizar fisicoquímicamente la zona seleccionada de la parcela de estudio.
- 3- Analizar estadísticamente la correlación existente entre la CEa y las propiedades fisicoquímicas del suelo.
- 4- Evaluar el efecto de las propiedades del suelo sobre el desarrollo de un cultivo de cereal de invierno.

Todo ello estará destinado a la obtención de datos relevantes para la elaboración de protocolos de puesta en práctica de las técnicas disponibles de AP. El propósito final es el de aumentar el rendimiento neto de las explotaciones agrícolas mediante el incremento del rendimiento de los cereales, o la disminución de la aplicación de insumos, que irá asociada a un menor impacto medioambiental de la agricultura cerealista extensiva de secano.

3. MATERIALES Y MÉTODOS

3.1. ÁREA DE ESTUDIO

3.1.1. LOCALIZACIÓN

El área de estudio del presente trabajo se encuentra en la partida de Artaón Alto, ubicada en la localidad de Valsalada a 422 m sobre el nivel del mar, que pertenece al municipio de Almudévar, a 26 km al oeste de Huesca. Las parcelas están en la comarca de la Hoya de Huesca.

Por este municipio pasa el Canal de los Monegros, lo que hace que parte de su superficie agrícola sea regable, sin embargo, este estudio se centra en una parcela de secano, que se encuentra al noroeste de la propia localidad, con una superficie cercana a las 13 ha de tierra arable. La figura 9 muestra la localización de la parcela respecto al municipio de Almudévar.

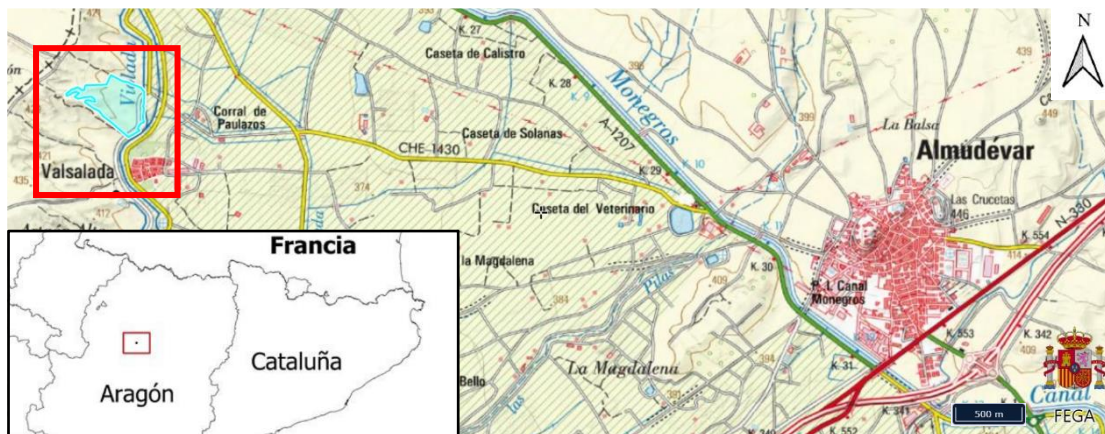


Figura 9: Mapa de la localización de las parcelas de estudio a partir del Visor SigPac y PNOA.
Fuente: elaboración propia a partir del SIGPAC.



Figura 10: Mapa detallado de la ubicación de las parcelas del primer ensayo de Valsalada durante el año 2021.
Fuente: Minuesa (2021).

En este municipio, los ensayos desarrollados dentro del Grupo de Cooperación AP-Extensivos abarcan tres parcelas con una superficie total de 31 ha, como se puede ver en la figura 10. En este trabajo se ha seleccionado una parte de la parcela 2 para realizar los muestreos y estudiar las propiedades del suelo. La tabla 3 muestra la referencia catastral de la parcela seleccionada y la superficie estudiada.

Tabla 3: Información detallada de la parcela objeto del actual TFG (parcela número 2). Fuente: elaboración propia a partir de los datos de SIGPAC.

Nº PARCELA	SUPERFICIE (ha)	SUPERFICIE MUESTREADA (ha)	REFERENCIA CATASTRAL	POLÍGONO Y PARCELA
2	12,77	2,9	22027A009000180000LJ	Pol. 9, Par. 18

3.1.2. CARACTERIZACIÓN CLIMÁTICA

Para el análisis de la climatología de la localidad de Valsalada se ha recurrido al estudio de los datos climáticos obtenidos del Gobierno de Aragón, referentes a precipitaciones acumuladas, temperaturas máximas, mínimas y medias recogidas mensualmente entre los años 1997 y 2021. Posteriormente los datos se han descargado y procesado mediante el programa informático Excel para su presentación en forma de gráficos de más fácil interpretación.

Para ello, y dado que Valsalada no cuenta con estación meteorológica propia dentro de la red de la Agencia Estatal de Meteorología, se han empleado los datos de la estación de Almodóvar, disponibles dentro del Instituto Aragonés de Estadística (Gobierno de Aragón, 2022).

Con esos datos ha sido posible realizar un climograma histórico (figura 11) donde se recogen temperaturas y precipitaciones medias mensuales recogidas desde el año 1997. De esta forma, se aprecia cómo se trata de un clima cálido con temperaturas máximas referidas al mes de julio que sobrepasan ligeramente los 33,0 °C, y las mínimas de -1,5 °C durante el mes de enero. Referente a la pluviometría, se trata de una región con precipitaciones escasas, pues el acumulado anual es de 442,0 mm, además de apreciarse un periodo de cinco meses en el que no se alcanzan los 30,0 mm. La época más lluviosa se encuentra en la primavera, concretamente en abril, con 56,7 mm, mientras que el mes más seco es agosto, con algo más de 20,0 mm.

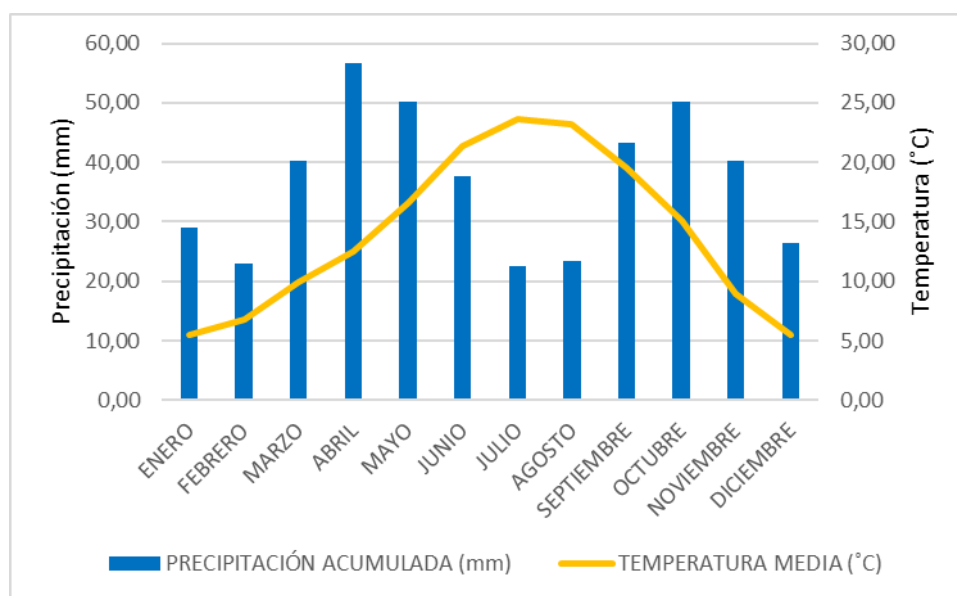


Figura 11: Diagrama ombrotérmico realizado mediante los datos de temperaturas medias y precipitaciones del municipio de Almodóvar (1977-2022). Fuente: elaboración propia a partir de los datos del Gobierno de Aragón (2022).

También se han analizado las temperaturas máximas, mínimas y medias registradas en dicha estación de Almodóvar en los últimos 25 años (figura 12), y se observa la amplitud térmica entre épocas distintas del año, e incluso dentro de los mismos meses, de hasta 18,0 °C, registrándose la temperatura máxima en 40,9 °C en el mes de junio de 2019, y la mínima en -11,4 °C en enero de 2021. Respecto a la temperatura media anual se puede decir que es de aproximadamente 14,0 °C.

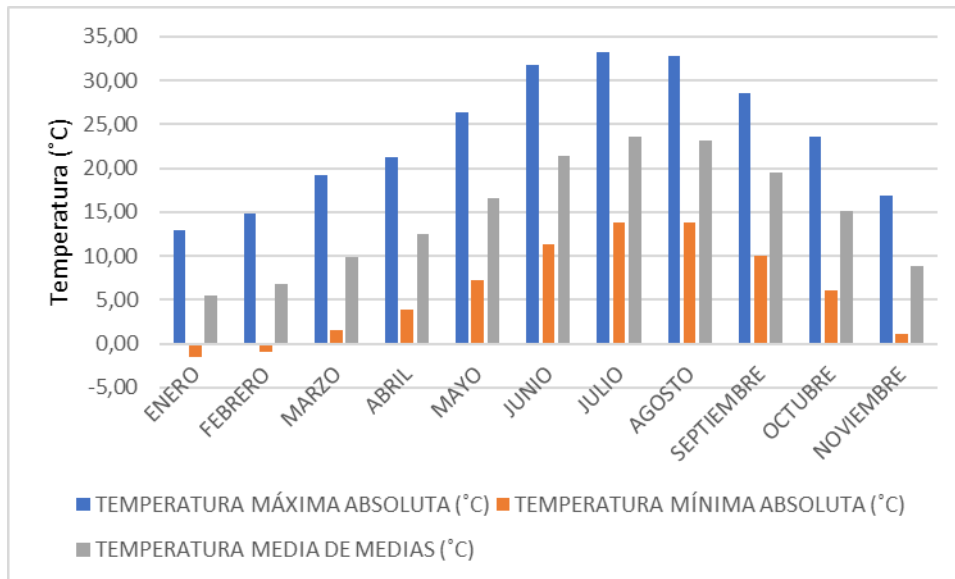


Figura 12: Diagrama de temperaturas mensuales máximas, mínimas y media de medias realizado a partir de los datos de la estación meteorológica de Almudévar (1997-2022). Fuente: elaboración propia a partir de los datos del Gobierno de Aragón (2022).

Por tanto, Valsalada se encuentra dentro de los secanos semiáridos del Valle del Ebro, bajo condiciones de clima Mediterráneo Continental, donde los veranos son cálidos y los inviernos fríos, con precipitaciones escasas en la mayoría de los meses del año. La figura 13 muestra un mapa de la distribución de las zonas climáticas de la comunidad autónoma de Aragón.

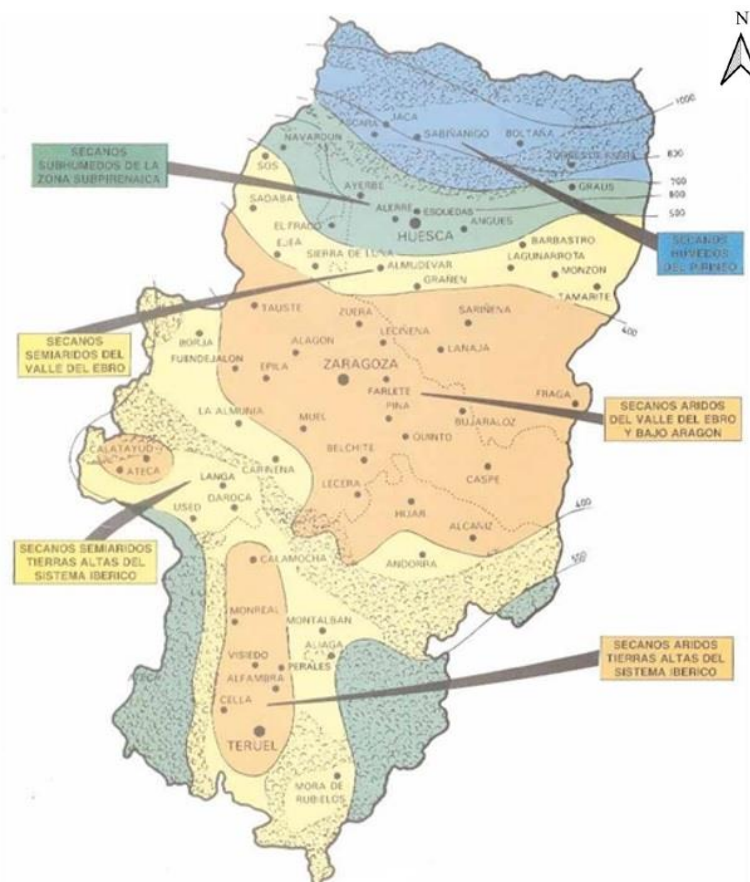


Figura 13: Distribución climática de zonas de Aragón. Fuente: Gutiérrez y Aranda (2019).

3.1.3. GEOLOGÍA Y GEOMORFOLOGÍA LOCAL

La provincia de Huesca se puede dividir en dos zonas fundamentales siguiendo la dirección norte-sur, como son la montañosa, que a su vez se subdivide en **Pirineo** y **sierras del pre-Pirineo**, caracterizadas por las cotas más altas; y en la **Llanura Ibérica**, cuyo límite se encuentra unos kilómetros al norte de la capital.

Los municipios de Almudévar y Valsalada se encuentran en una latitud inferior a la propia ciudad de Huesca, por lo cual están comprendidos dentro de la anteriormente definida Llanura Ibérica, la cual se caracteriza por su suave inclinación hacia el Valle del Ebro, con altitudes entre 200 y 600 m sobre el nivel del mar, además de estar sustentada por materiales terciarios similares a la provincia de Zaragoza como son principalmente oligocenos (margas, molasas, conglomerados y algunos niveles de yesos) y miocenos (margas, yesos y calizas poco compactas en forma de lajas) (Guerra, 1970).

El suelo de la parcela de estudio de Valsalada es referido por Guerra (1970) como *Xerorendzinas sobre margas y yesos*, probablemente los suelos más representativos de la aridez de algunas comarcas del valle del Ebro, los cuales “*corresponden a una alternancia de grandes bancos de yeso puro cristalizado, con niveles de marga gris yesífera, y pertenecen en su gran mayoría al Sarmatiense, es decir, un Mioceno superior*” (Guerra, 1970).

Más concretamente, se trata de *Xerorendzinas sobre calizas, margas yesíferas y yesos*, los cuales se observan mayoritariamente en la sierra de Alcubierre, a poco más de 10 km respecto a la parcela de estudio, y están caracterizados por ser Xerorendzinas muy secas de color blanco o blanco grisáceo, con un alto contenido en sulfato cálcico. Estos suelos han sido sometidos a una fuerte erosión, por lo que los horizontes no son muy profundos, lo cual no los hace demasiado productivos bajo el manejo agrícola del cereal de secano.

La figura 14 muestra los tipos de suelo en la zona de la parcela de estudio.

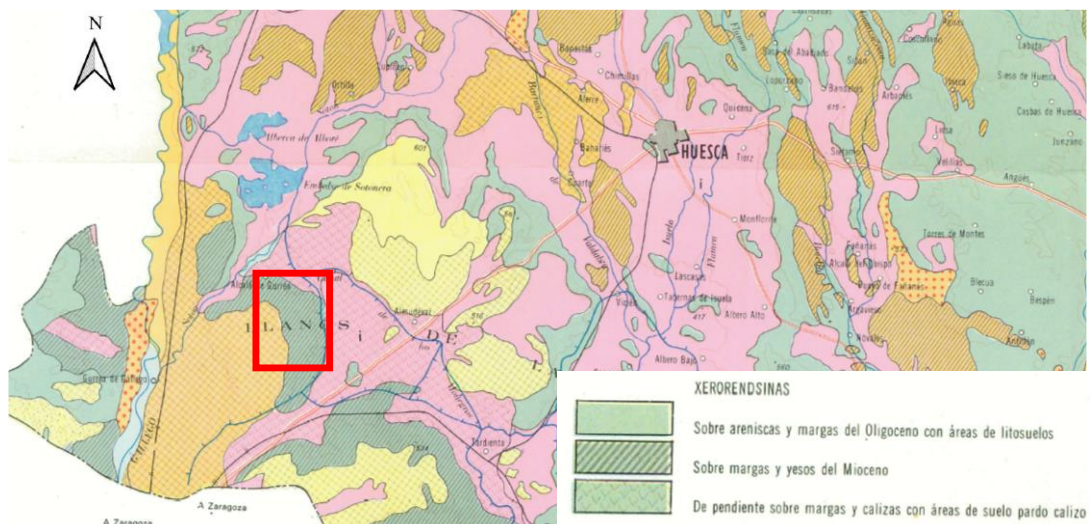


Figura 14: Mapa de suelos de la provincia de Huesca. Fuente: Guerra et al. (1970).

Para la realización de este trabajo, y como se ha comentado en los apartados anteriores, se han combinado métodos tradicionales para el muestreo del suelo, con nuevas herramientas tecnológicas para el estudio de la variabilidad del mismo, el procesado y la comparación de datos. A continuación, se detallan estos procedimientos.

3.2. MAPA DE CONDUCTIVIDAD ELÉCTRICA APARENTE DEL SUELO

Los objetivos de este TFG son los de correlacionar las propiedades texturales del suelo con su CEa y evaluar su influencia en el cultivo, por lo que el primer paso fue caracterizar la variabilidad del suelo objeto de estudio en base a su CEa mediante el sensor Veris 3100 del Grupo de Investigación en AgróTICa y Agricultura de Precisión de la Universidad de Lleida (UdL), con quien se ha trabajado en estrecha colaboración. La figura 15 muestra el sensor utilizado trabajando en la parcela de estudio.



Figura 15: Muestreo con el sensor VERIS 3100 en la parcela experimental 2 de Valsalada. Foto: M. Videgain.

Los resultados del análisis realizado a dos profundidades (0–30 y 0–90 cm) se recibieron en archivos vectoriales shapefile en forma de capa de puntos, los cuales representaban todas las lecturas del sensor Veris con sus respectivos valores de CEa, tanto superficial como profunda, en su recorrido a lo largo de las tres parcelas experimentales de Valsalada. El programa informático para procesar los datos de CEa fue el software QGIS V.3.16.4.

Una vez cargada la capa de puntos en QGIS, la zona de estudio se tuvo que acotar mediante una herramienta incorporada en el programa, usando de máscara la capa vectorial de los límites de la misma parcela 2. La figura 16 muestra la capa de puntos sin procesar, creada a partir de los datos tomados por el sensor en la parcela de estudio, en la que todavía no se distinguen las categorías de valores.

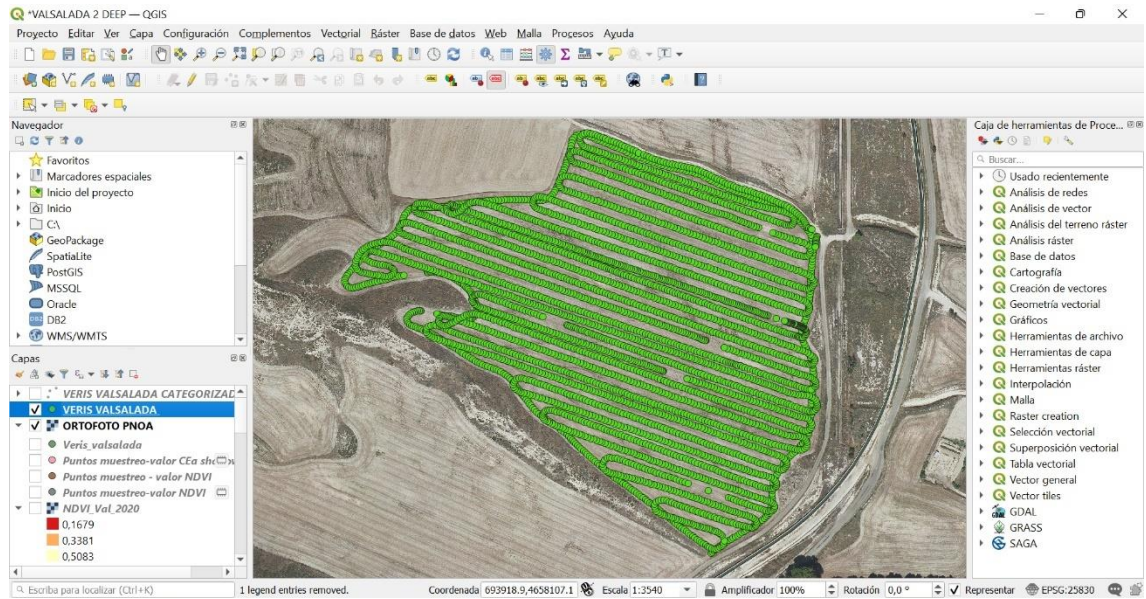


Figura 16: Capa vectorial de los puntos de la parcela número 2 de Valsalada, tomados por el Veris 3100. Fuente: elaboración propia.

Resultado de graduar los valores de la capa vectorial mostrada en la figura 16 y aplicar los filtros de colore correspondientes, se obtiene la siguiente capa vectorial (figura 17), la cual ya aporta información acerca de los valores de CEa. En ella los colores rojos se asocian a conductividades bajas y los azules a altas.

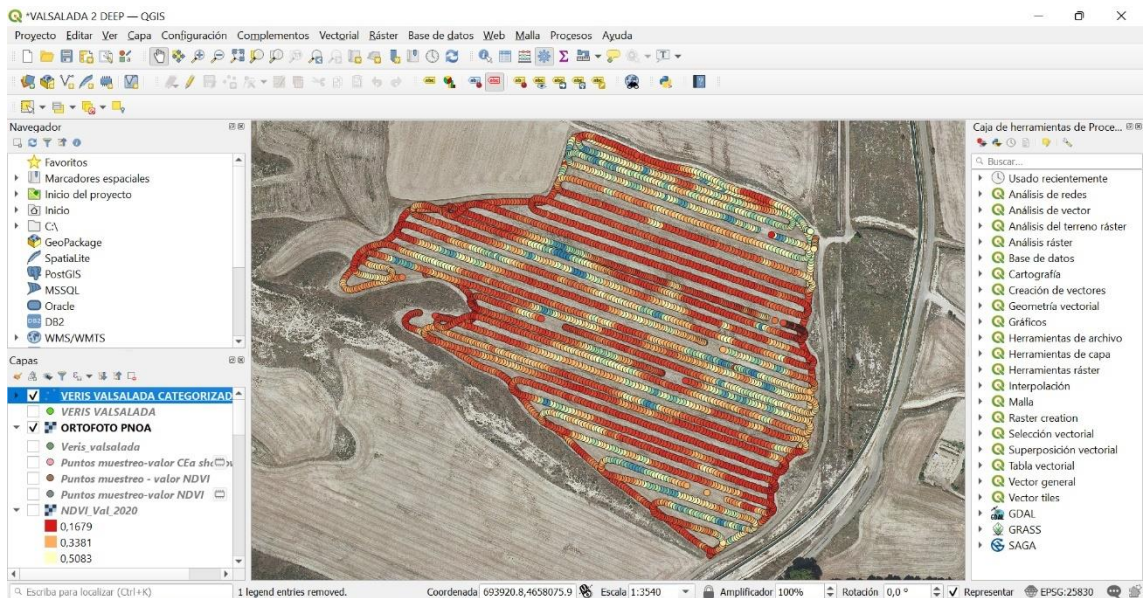


Figura 17: Capa vectorial obtenida de los datos registrados por el Veris 3100 graduados por colores. Fuente: elaboración propia.

La capa de puntos presentaba la información acerca de ambas conductividades (CEa superficial y CEa profunda), por lo que se sometió a un proceso de interpolación mediante la herramienta *PAT (Precision Agriculture Tools)*, complemento de QGIS, y el programa de análisis geoestadístico asociado “Variogram Estimation and Spatial Prediction with Error”(VESPER, Minasny et al., 2005). El objetivo de este proceso es obtener dos capas ráster con información de la CEa para toda la superficie de la parcela, a partir de los datos obtenidos de los puntos de medición.

La primera capa albergó valores de CEa en el intervalo 0,35 – 158,08 (mS/m) para la CEa profunda, y la segunda de 0,94 – 205,22 (mS/m) para la CEa superficial. El primer resultado de este proceso es una capa ráster (figura 18) en la que se pueden diferenciar los distintos valores de CEa en escala de grises, del negro (menores) al blanco (mayores).

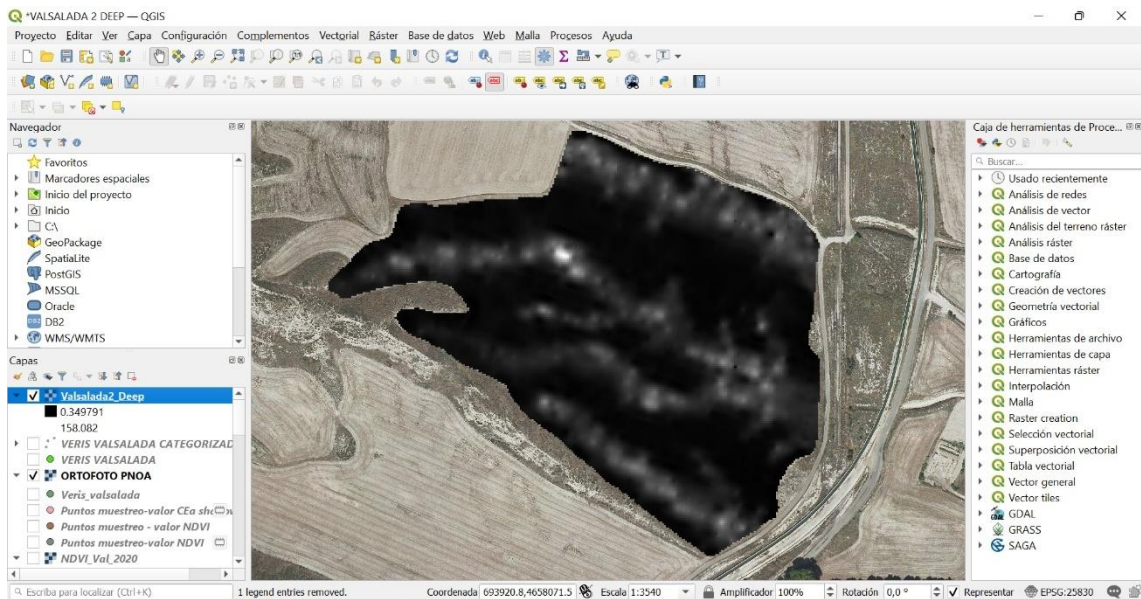


Figura 18: Imagen del programa QGIS en la que se aprecia la capa ráster de CEa obtenida a partir de la capa vectorial. Fuente: elaboración propia.

Esta capa ráster se visualizó en clases para su correcta interpretación, utilizando para ello el programa QGIS. Mediante ello se categorizó la capa en diferentes rangos de valores, agrupando los datos de la CEa en 5 clases diferentes, según los intervalos que se muestran en la tabla 4.

Tabla 4: Clases de CEa profunda en función de su rango de valores. Fuente: elaboración propia.

ZONA	COLOR	VALOR CEa (mS/m)
1	ROJO	0 -5
2	NARANJA	5 – 10
3	AMARILLO	10 – 20
4	VERDE	20 – 30
5	AZUL	30 – MÁX (158)

Para el caso de la CEa superficial se categorizó en base a los mismos intervalos, alcanzando el último de ellos un máximo de 206 (mS/m).

Como resultado final de este segundo proceso en QGIS se obtuvieron dos nuevas capas ráster que muestran los valores categorizados en diferentes rangos para la totalidad de la superficie de la parcela, agrupando las zonas de CEa tanto superficial como profunda por colores en base a su valor.

3.3. MUESTREO DEL SUELO

En base a la distribución de la CEa en la parcela, se estableció un patrón para la toma de muestras de suelo de forma sistemática en puntos específicos. Este patrón consistió en una cuadrícula que recogía zonas de distintas pero conocidas conductividades, integrando de igual manera algunos puntos dispuestos de forma aleatoria. El total de puntos de muestreo, que fueron digitalizados en una nueva capa vectorial de puntos, fue de 42. La figura 19 muestra la distribución de los puntos de muestreo en la parcela de estudio.

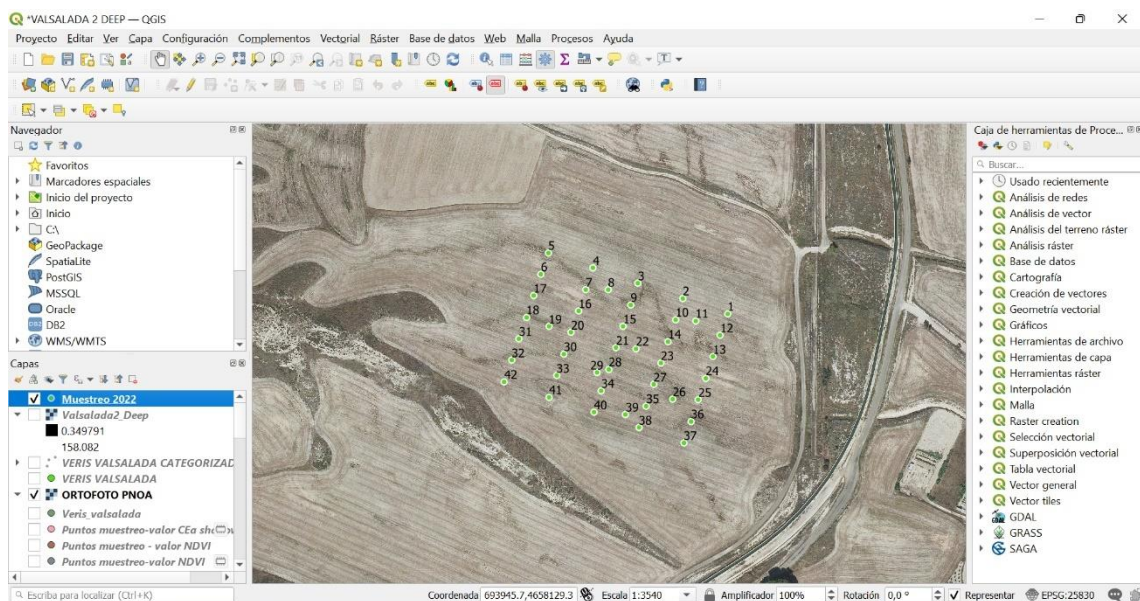


Figura 19: Imagen del programa QGIS donde se aprecia la silueta de la parcela de Valsalada y la capa vectorial con los 42 puntos de muestreo. Fuente: elaboración propia.

La localización de estos puntos se transfirió a un dispositivo GPS portátil para facilitar su búsqueda en campo y proceder a la toma de una muestra compuesta de suelo en cada uno de ellos. Las muestras fueron tomadas en el mes de marzo de 2022.

Las muestras de suelo se tomaron con una barrena de caña cilíndrica (Eijkelkamp, Holanda). Se tomaron tres muestras de suelo en cada punto dentro de un recinto de área 1 m², con el objetivo de aumentar la representatividad de cada muestra. Dichas muestras fueron introducidas en bolsas de plástico enumeradas con las designaciones desde VAL-1 hasta VAL-42 para conocer el punto exacto de muestreo y evitar posibles confusiones durante su

manipulación. La figura 20 muestra el método usado para la toma de cada una de las muestras individuales, el cual consistía en introducir la barrena cilíndrica hasta una profundidad aproximada de 40 cm (en la que se encontraba una capa de yeso difícil de atravesar) mediante su golpeo con una maza de cabezal de nailon.



Figura 20: Toma de muestras de suelo en la parcela de Valsalada. Foto: M. Videgain.

3.4. ANÁLISIS FÍSICOQUÍMICO DE LAS MUESTRAS DE SUELO

Una vez tomadas las 42 muestras del suelo de la parcela, se sometieron a un procesado inicial en las instalaciones de la Escuela Politécnica Superior de Huesca.

En primer lugar, las muestras se depositaron en bandejas para su secado al aire durante 7 días, posteriormente se desmenuzaron con ayuda de un rodillo y se tamizaron a 2 mm. El % de muestra que quedó por encima de esa medida se consideró como elementos gruesos y el % que quedó por debajo, como elementos finos.

Las dos fracciones obtenidas se pesaron en una balanza de precisión por separado. Para el cálculo del % de elementos gruesos (EG) se utilizó la ecuación 2:

$$\text{Elementos gruesos (\%)} = \frac{\text{Elementos gruesos (g)}}{\text{Elementos gruesos (g)} + \text{Elementos finos(g)}} * 100$$

Ecuación 2: Cálculo del porcentaje en peso de elementos gruesos. Recuperado de: <https://acortar.link/lrVzMd>.

Las figuras 21 y 22 muestran, en primer lugar, tanto el tamiz como el rodillo con la muestra sin procesar y, en segundo lugar, la muestra una vez tamizada, recogida dentro de la bandeja metálica, con todos los elementos gruesos mayores a 2 mm dentro de los pequeños recipientes plásticos.



Figura 21: Procesado de las muestras para la determinación de elementos gruesos.



Figura 22: Bandeja metálica con la muestra de tierra tamizada, y separados los elementos gruesos.

Posteriormente, las muestras se enviaron al laboratorio Agroambiental Eurofins, acreditado para completar su análisis fisicoquímico.

Para cada muestra se determinaron las siguientes propiedades:

- HUMEDAD (%): medida tras someter a las muestras a una temperatura de 105 °C.
- pH: por el método de potenciometría.
- CONDUCTIVIDAD ELÉCTRICA 25 °C (mS/m): por el método de conductimetría.
- MATERIA ORGÁNICA OXIDABLE (% s.m.s.): mediante potenciometría (W&B).
- CARBONATO CÁLCICO EQUIVALENTE (% s.m.s.): por el método interno de valoración potenciométrica.
- TEXTURA: determinando los porcentajes de arcilla, limo y arena por el método interno de gravimetría.
- CAPACIDAD DE CAMPO (%): obteniendo los valores de retención de agua a 0,3 bar.
- PUNTO DE MARCHITEZ PERMANENTE (%): obteniendo los valores de retención de agua a 15 bar.

- CAPACIDAD DE RETENCIÓN DE AGUA DISPONIBLE (%): mediante la diferencia entre los valores de humedad a 0.3 bar (capacidad de campo) y humedad a 15 bar (punto de marchitez permanente) por el método interno de gravimetría.
- CAPACIDAD DE INTERCAMBIO CATIÓNICO EFECTIVA (mEq/100g DM): con el método interno de espectrometría UV-VIS.

3.5. OBTENCIÓN DE LOS VALORES DE CEa EN LOS PUNTOS DE MUESTREO DE SUELO

El valor de la CEa medido en cada punto de muestreo de suelo se obtuvo mediante la herramienta *MUESTRA DE VALORES RÁSTER* del programa QGIS, a través de la cual se genera una nueva capa de puntos (cuya posición coincide con la de los puntos de muestreo de suelo) en cuya tabla de atributos están asociados los valores exactos de CEa profunda/superficial. Este análisis se realizó tanto para la capa de valores de CEa profunda como superficial.

Esta herramienta ofrece la posibilidad de elegir una capa vectorial de entrada, es decir, una capa de puntos que en este caso fue la capa con los 42 puntos de muestreo, y una capa ráster de la cual toma los valores en los anteriores puntos concretos, que en este caso fueron las capas ráster de la CEa profunda y superficial.

De esta forma, se consultaron los valores exactos de CEa en cada punto de muestreo mediante la búsqueda ordenada en su correspondiente tabla de atributos. Las figuras 23 y 24 muestran las capas de CEa profunda y superficial, respectivamente, y los 42 puntos de muestreo.

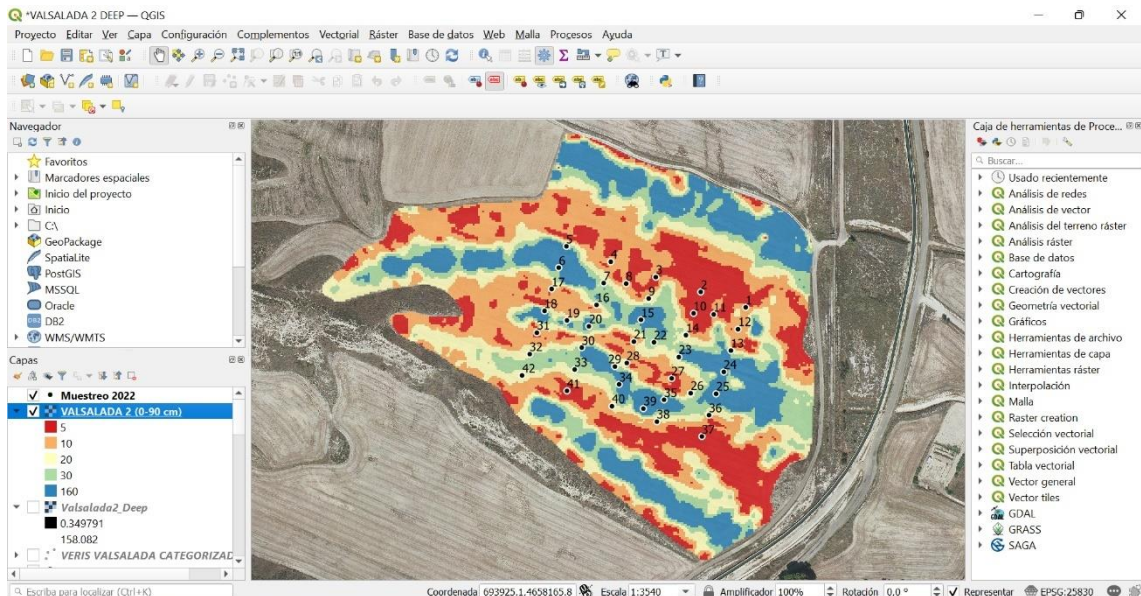


Figura 23: Imagen del programa QGIS con la capa ráster de CEa profunda categorizada y la nueva capa vectorial de puntos muestreados. Fuente: elaboración propia.

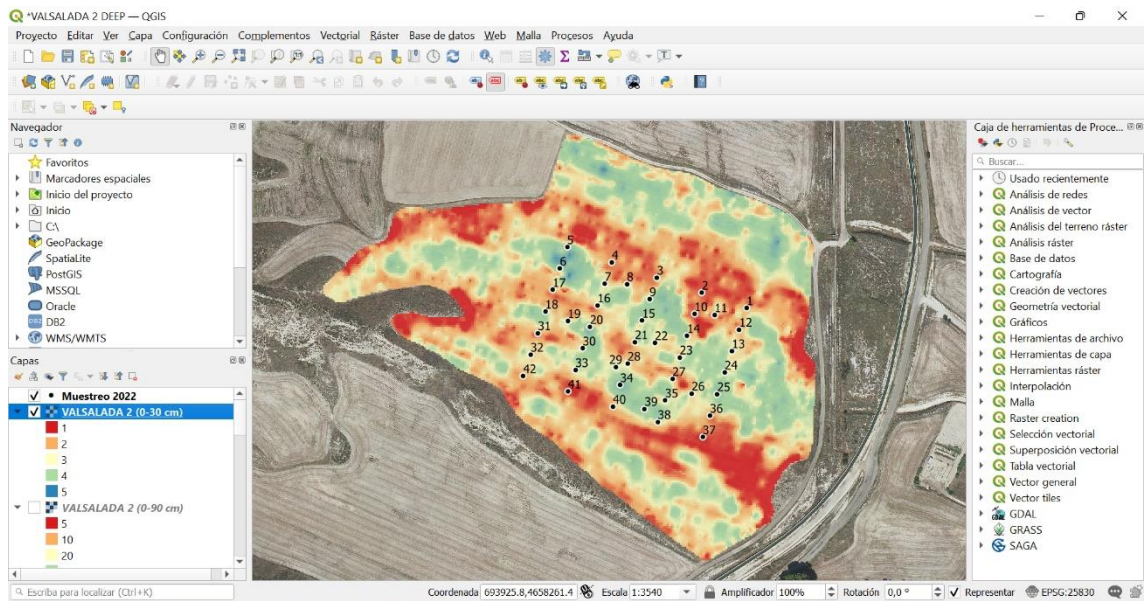


Figura 24: Imagen del programa QGIS con la capa ráster de CEa superficial categorizada y la nueva capa vectorial de puntos muestreados. Fuente: elaboración propia.

3.6. OBTENCIÓN DE LOS ÍNDICES DE VEGETACIÓN (NDVI)

Para llevar a cabo este análisis, se descargó una imagen del tipo Surface Reflectance (SR) ya que este tipo de imágenes presentan el efecto de dispersión atmosférica corregido, de la constelación de satélites *PlanetScope* a fecha 4 de abril del año 2020, última campaña agrícola en la que no se realizaron ensayos experimentales en esta parcela y, por lo tanto, las dosis de fertilizante tanto en fondo como en cobertera fueron fijas. A partir de la siguiente campaña comenzaron las aplicaciones variables, lo que puede condicionar los índices de vegetación, independientemente de la CEa del suelo. Por lo tanto, con dicha imagen se obtuvo información del estado de desarrollo del cultivo en una fecha crítica para su desarrollo y a partir de ella se obtuvo el índice NDVI correspondiente a la posición de cada punto de muestreo de suelo. La figura 25 muestra la imagen descargada de *PlanetScope* y los límites de la parcela de estudio.

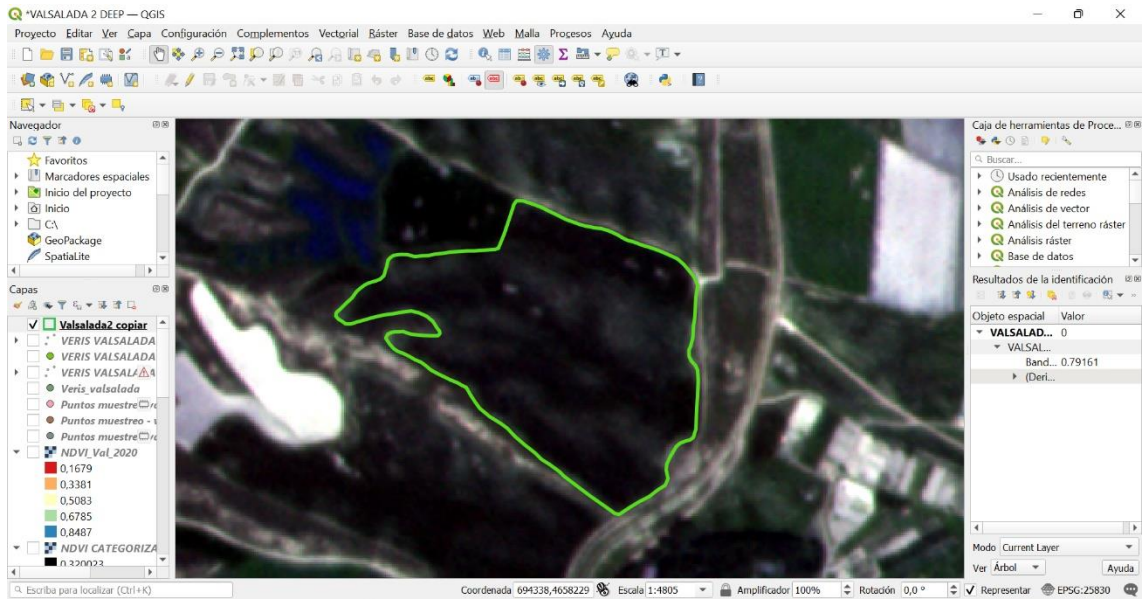


Figura 25: Imagen del programa QGIS en la que se aprecia la imagen descargada de PlanetScope y los bordes de la parcela de estudio. Fuente: elaboración propia.

La imagen descargada se procesó mediante QGIS en distintas etapas, la primera de las cuales fue acotar la imagen a los límites de la parcela 2, a través de la herramienta *CORTAR RÁSTER POR CAPA DE MÁSCARA*, tomando como capa de entrada la imagen descargada de PlanetScope, y como capa para hacer de máscara la capa ráster sencilla de los bordes de la parcela Valsalada 2. Como resultado, se obtuvo la imagen satelital recortada a los límites de la parcela, tal y como se aprecia en la figura 26.

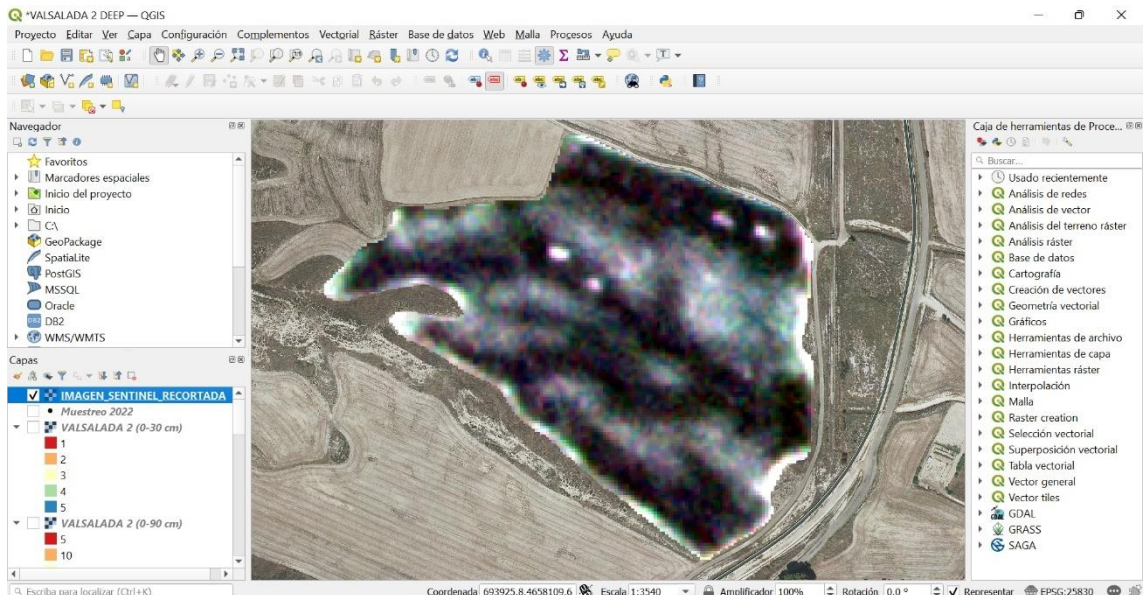


Figura 26: Imagen del programa QGIS en la que se aprecia la imagen descargada de PlanetScope recortada por el límite de la parcela de estudio. Fuente: elaboración propia.

El siguiente paso del proceso fue calcular el NDVI. Para ello, se empleó la herramienta *CALCULADORA RÁSTER* de QGIS, mediante la cual se aplicó la ecuación 3. Los valores obtenidos fluctuaron entre el mínimo de 0 para el suelo desnudo, y el máximo de 0,7943.

$$NDVI = \frac{Banda\ 4 - Banda\ 3}{Banda\ 4 + Banda\ 3}$$

Ecuación 3: Cálculo del NDVI (Alonso, 2022).

En dicha ecuación, la **Banda 3** se correspondía con la banda del rojo (Red) y la **Banda 4** con las longitudes de onda del infrarrojo (NIR).

Una vez obtenido el NDVI, la capa fue clasificada en 5 intervalos continuos y se aplicó la rampa de color *PSEUDOCOLOR MONOBANDA*.

Los colores aplicados fueron, por tanto, los mismos que los usados en los mapas de CEa, y los rangos de clasificación se detallan en la tabla 5:

Tabla 5: Clasificación por zonas del NDVI en función de su rango de valores. Fuente: elaboración propia.

ZONA	COLOR	VALOR NDVI
1	ROJO	0 - 0,3200
2	NARANJA	0,3200 – 0,4386
3	AMARILLO	0,4386 – 0,5571
4	VERDE	0,5571 – 0,6757
5	AZUL	0,6757 – 0,7943

Posteriormente, se aplicó la herramienta *MUESTRA DE VALORES RÁSTER* para generar una nueva capa vectorial a partir de los 42 puntos de muestreo (ver figura 27) y obtener los respectivos valores del índice de vegetación en dichos puntos. La tabla de atributos de esta nueva capa vectorial contenía los datos correspondientes al NDVI en cada punto de muestreo, que fueron los utilizados en el posterior análisis estadístico de resultados.

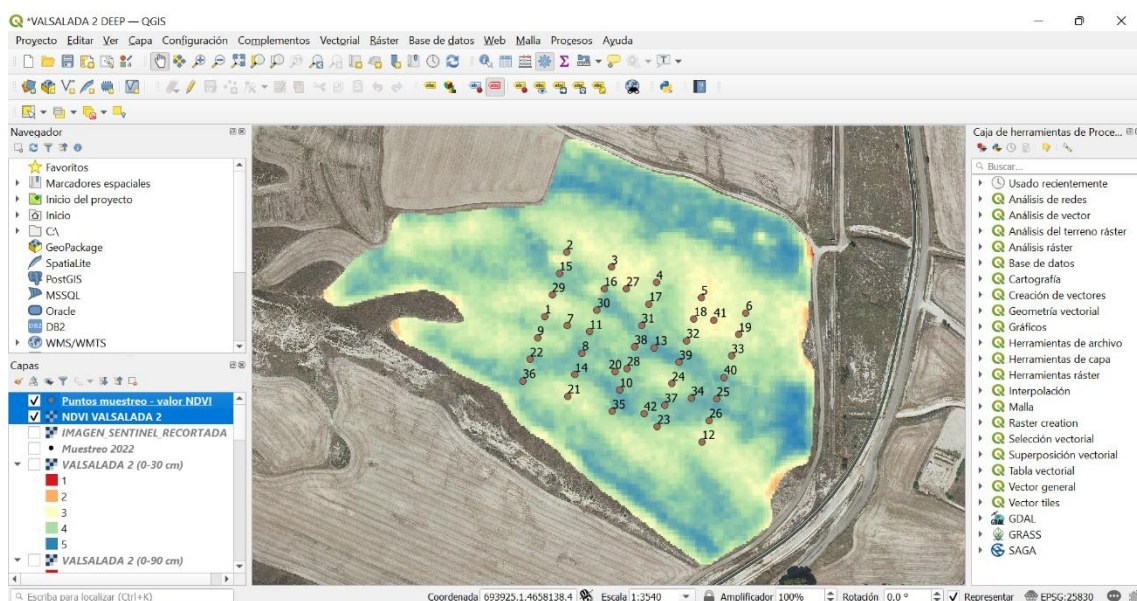


Figura 27: Imagen del programa informático QGIS en la que se aprecia la capa categorizada del NDVI de la parcela 2 y los 42 puntos de muestreo. Fuente: elaboración propia.

3.7. ANÁLISIS ESTADÍSTICO DE LOS RESULTADOS

Una vez se recibieron los datos del análisis de laboratorio referentes a cada una de las 42 muestras enviadas, se procedió a su primera interpretación, con el objetivo de detectar posibles resultados anómalos o errores de medida.

Mediante el programa informático **Excel** se procedió a su presentación en forma de tabla, con los datos agrupados por columnas en función de los parámetros analizados. De esta forma, fue posible realizar un primer análisis acerca de la distribución de cada parámetro en función de la CEa profunda, gracias a la opción de los gráficos de dispersión, obteniendo igualmente la recta de ajuste y la ecuación de dicha recta. En este apartado se obtuvieron los coeficientes R^2 para cada distribución estudiada.

A través del programa informático **IBM SPSS Statistics (V26)** se obtuvieron los principales estadísticos descriptivos y se realizaron las pruebas estadísticas siguientes, trabajando con un nivel de significación del 95 %:

- **PRUEBA DE NORMALIDAD DE KOLMOGOROV-SMIRNOV.**

Previamente a la realización de cualquier análisis estadístico, se procedió a evaluar la distribución de los datos mediante una prueba de normalidad de *Kolmogorov-Smirnov*, para conocer si la dispersión de los datos con los que se trabaja se ajusta o no a una distribución normal, pues esto condiciona la aplicabilidad de test paramétricos o no paramétricos.

- **ANÁLISIS DE CORRELACIÓN LINEAL.**

Se estudió el tipo de correlación existente entre la CEa (profunda y superficial) y los parámetros fisicoquímicos analizados.

El concepto de **relación** o **correlación lineal** hace referencia al grado de variación conjunta existente entre dos o más variables, para lo cual este análisis se centró en el estudio de un tipo particular de relación llamada lineal, considerando únicamente el caso de dos variables, es decir, una correlación simple.

El tipo de análisis se trató de la correlación bivariada de *Spearman*, ya que los datos no siguen una distribución normal.

El coeficiente de *Spearman* obtenido mostró distintos valores que fluctuaban entre -1 y 1 según los siguientes parámetros:

- Próximos a -1: mayor correlación inversa.
- Próximos a 0: ningún tipo de correlación.
- Próximos a 1: mayor correlación directa.

- **EVALUACIÓN DE LA DISTRIBUCIÓN DE LOS VALORES DE LOS PARÁMETROS EN FUNCIÓN DE LAS ZONAS DE CEa. ANOVA DE KRUSKAL-WALLIS.**

Para evaluar la distribución de los valores de los parámetros fisicoquímicos en función de las zonas establecidas de diferente CEa, se realizó un análisis de varianza de Kruskal-Wallis, ya que la distribución de los datos no cumplió con el criterio de normalidad. Se trata de un método no paramétrico para comprobar

estadísticamente si la distribución de la varianza de varios conjuntos de datos es la misma.

El siguiente análisis estadístico se realizó con el programa informático **R (V. 4.1.2.)** y en concreto con la librería R Studio.

- **APLICACIÓN DE UN MODELO DE REGRESIÓN LINEAL MÚLTIPLE.**

Se trata de un modelo de tipo lineal, a través del cual se quiere predecir una variable de salida continua, en función de un conjunto de variables predictoras. Para ello hay que determinar los coeficientes de la recta de regresión que mejor se ajuste a la distribución de datos obtenidos. El objetivo de este análisis fue el de obtener un modelo predictivo para explicar la CEa a partir de los parámetros fisicoquímicos del suelo y del NDVI.

La recta de regresión lineal posee una fórmula muy simple (ecuación 4), en la que Y_i representa la variable dependiente (en este caso CEa), X_n cada una de las variables independientes, y los coeficientes B_0 y B_n corresponden al punto en el que la recta corta al eje vertical y la pendiente de la recta, respectivamente.

$$Y_i = B_0 + B_n X_n$$

Ecuación 4: Ecuación de la recta de regresión lineal múltiple.

Mediante este proceso estadístico, por tanto, se pretenden determinar aquellos coeficientes de la recta de regresión de tal forma que el error que se produce entre los valores reales y los predichos por el modelo sea el mínimo posible.

En primer lugar, se quitaron los valores altos de CEa ya que son valores puntuales muy elevados y al integrarlos en el modelo las predicciones no se ajustarían.

Se realizó un ajuste de modelos mediante **regresión lineal**, considerando como variable explicada la CEa profunda y como variables explicativas las 13 restantes, obteniendo un primer modelo y los niveles de significación asociados a la influencia de cada variable explicativa sobre el modelo. A través de la **selección de modelo paso a paso** se seleccionó el modelo que presentó un mayor grado de ajuste, aplicando también modelos lineales de tipo polinómico que resultaron no mejorar el ajuste.

Tras el proceso, se obtuvo un modelo estadístico lineal con un menor número de variables y con un valor del coeficiente de determinación R^2 ajustado ligeramente mayor al inicial, por lo que se tomó como mejor modelo y se procedió a su **validación interna**, es decir, a evaluar la capacidad para predecir los valores de las variables en función de la variable tomada como predictora, es decir, la CEa profunda.

En primer lugar, dentro del apartado de validación del modelo obtenido, se procedió a la obtención de las siguientes gráficas, las cuales se encuentran recogidas en el apartado de resultados (gráficas de los efectos) y en el ANEJO I (gráficas de componentes + residuos):

1. GRÁFICAS DE COMPONENTES + RESIDUOS

Presentan el ajuste lineal en forma de recta azul, y el ajuste local en forma de recta rosa.

2. GRÁFICAS DE LOS EFECTOS

Aportan información acerca de la dependencia de cada una de las variables en la predicción.

Una vez se han analizado todas las anteriores gráficas y se determina que el modelo obtenido está correctamente ajustado a la distribución de los datos y que dicho ajuste no mejora utilizando polinomios de grado 2 o 3, se procede a los diagnósticos numéricos, para su confirmación, realizando los siguientes test:

1. FACTORES DE INFLACIÓN DE VARIANZA

Se trata de un análisis de colinealidad.

2. TEST DE *BREUSCH-PAGAN* PARA HETEROSCEDASTICIDAD

Valora si el modelo presenta heteroscedasticidad u homocedasticidad.

3. TEST DE *DURBIN-WATSON* PARA AUTOCORRELACIÓN

Verifica si los residuos presentan autocorrelación.

4. TEST RESET DE NO LINEALIDAD

Indica hasta qué punto es mejorable el modelo mediante otro tipo de dependencias cuadráticas o cúbicas.

5. TEST DE VALORES ATÍPICOS DE *BONFERRONI*

Indica si existen o no valores atípicos que se deberían excluir del análisis.

4. RESULTADOS Y DISCUSIÓN

4.1. RESULTADOS DEL PROCESADO DE DATOS A TRAVÉS DEL USO DE SIG

4.1.1. MAPAS DE LA CEa

Como resultado de los últimos procesos de categorización en base a los intervalos explicados en el apartado de MATERIALES Y MÉTODOS, se obtuvieron las dos capas ráster de la CEa tanto profunda como superficial, categorizadas en las 5 zonas explicadas, tal y como aparecen en las figuras 28 y 29.

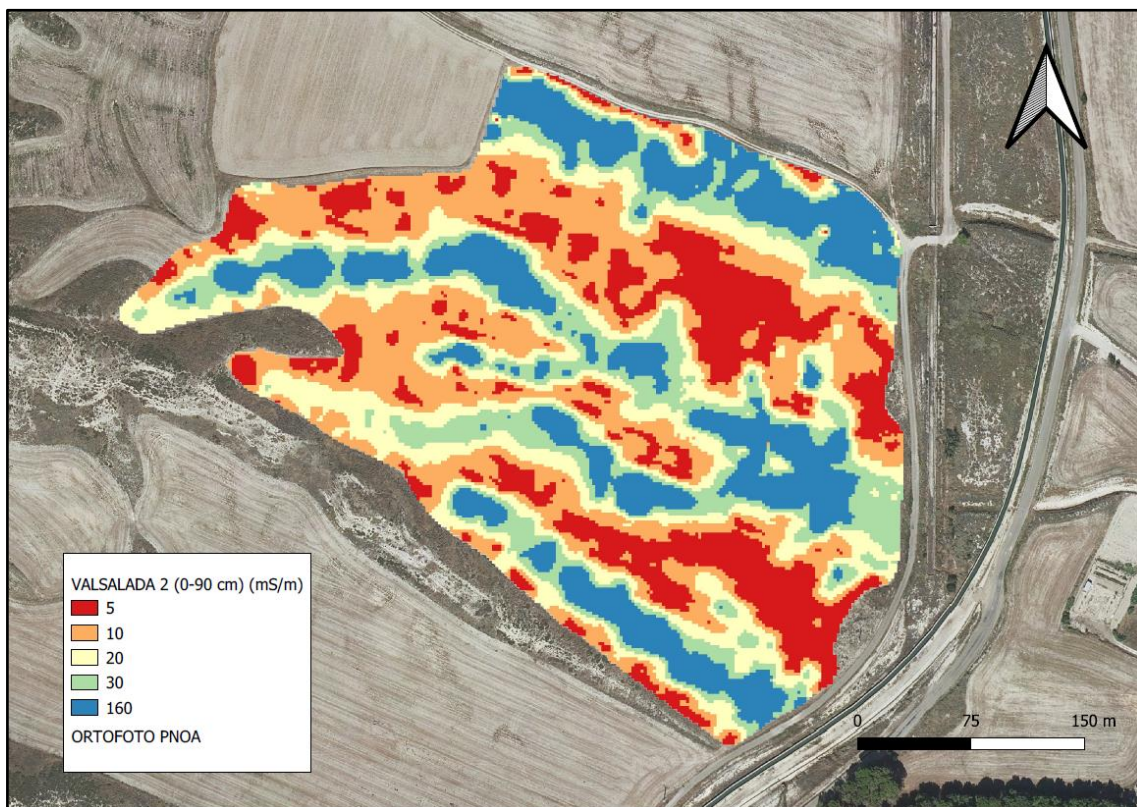


Figura 28: Imagen del programa QGIS de la capa ráster categorizada por colores en función de los valores profundos de CEa. Fuente: elaboración propia.

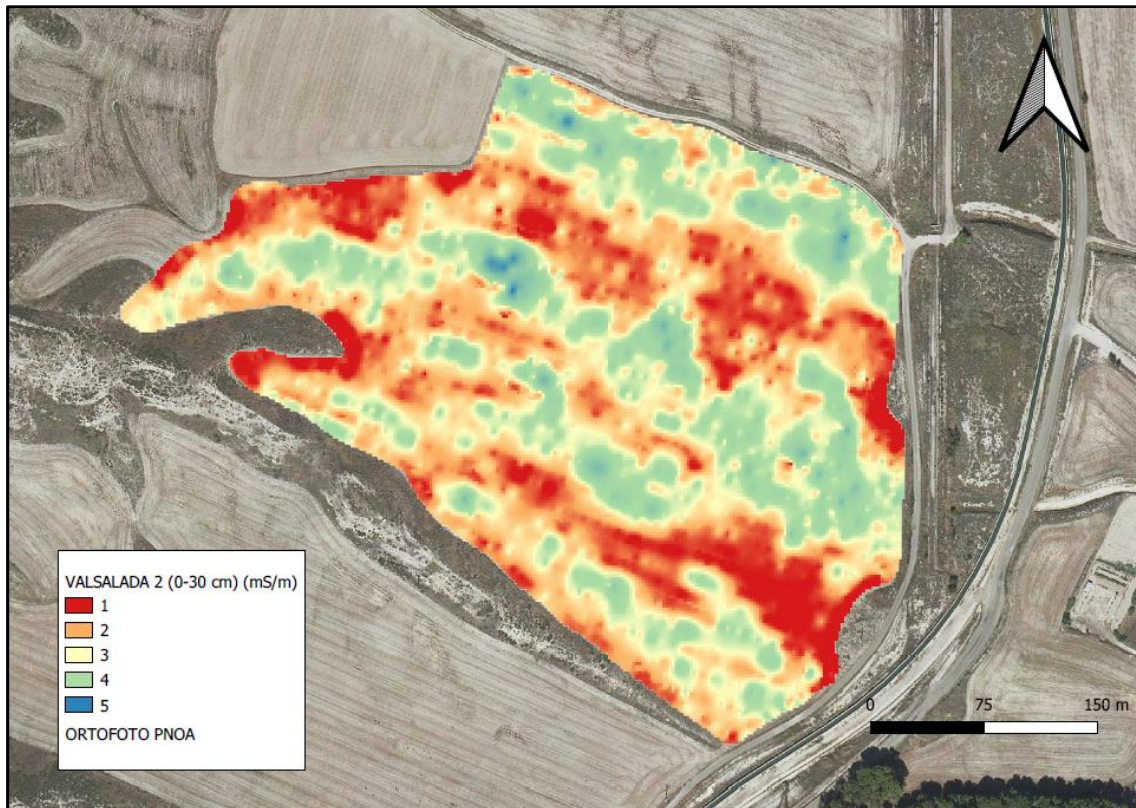


Figura 29: Imagen del programa QGIS de la capa ráster categorizada por colores en función de los valores superficiales de CEa. Fuente: elaboración propia.

Se aprecia una alta similitud entre los dos mapas de CEa, independientemente de las medidas profundas o superficiales, si bien las medidas tomadas entre 0 y 90 cm de profundidad presentan máximos superiores.

Esta similitud y los valores superiores para la CEa profunda se explican por la antigua conformación de la parcela, en la que se encontraban márgenes naturales donde ahora se reflejan valores menores de CEa, y las zona de valle centrales (pequeñas depresiones de la parcela), eran las zonas tradicionales cultivadas, que presentan en la actualidad unos mayores niveles de fertilidad, visibles en el incremento de la CEa. Se aprecia igualmente como el mapa de la CEa superficial (0-30 cm) se presenta como una versión ligeramente homogenizada del mapa de la CEa profunda (0-90 cm), lo que es consecuencia del laboreo y prácticas agronómicas referentes a esa pequeña parte superficial del suelo hasta los 30 cm de profundidad.

Esto es claramente visible en la ortoimagen obtenida del Instituto Geográfico Nacional (<https://www.ign.es/web/ign/portal/ide-area-nodo-ide-ign>) referente al vuelo realizado por el Army Map Service de EEUU entre enero de 1956 y noviembre de 1957 (figura 30), en la que las zonas oscuras se corresponden con las partes cultivadas de la parcela.




Figura 30: Ortoimagen de la parcela entre los años 1956 y 1957. Fuente: elaboración propia a partir de los datos del IGN (<https://www.ign.es/web/ign/portal/ide-area-nodo-ide-ign>).

4.1.2. MAPA DEL NDVI

La figura 31 muestra el mapa del NDVI de la parcela de estudio a fecha 4 de abril de 2020.

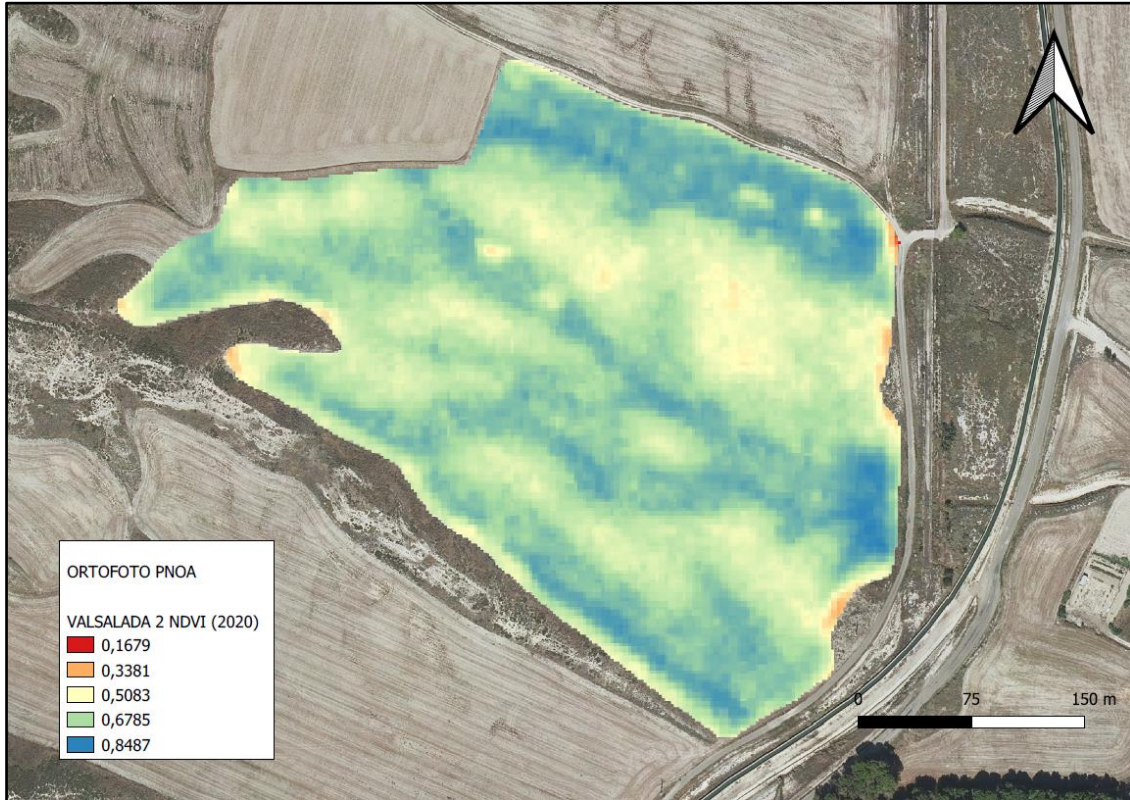


Figura 31: Capa ráster del NDVI de la parcela 2 categorizada por colores. Fuente: elaboración propia.

En este mapa se aprecia una alta similitud entre las zonas con valores altos de NDVI y de CEa, lo que ya se había comprobado previamente de forma estadística, en otro estudio realizado sobre estas parcelas experimentales (Minuesa, 2021).

4.2. RESULTADOS DE LOS ANÁLISIS ESTADÍSTICOS

4.2.1. PRUEBA DE NORMALIDAD DE KOLMOGOROV-SMIRNOV

La tabla 6 muestra los p-valores obtenidos en el análisis de normalidad de los datos a través de la prueba de Kolmogorov-Smirnov.

Los resultados completos de esta prueba se encuentran detallados en el ANEJO I.

Tabla 6: p-valores obtenidos de la prueba de Kolmogorov-Smirnov aplicada a las variables analizadas. Fuente: elaboración propia.

	CEa (0-90 cm)	CEa (0-30 cm)	CE (extr 1:5 H ₂ O)	E.G	pH	M.O	CaCO ₃	ARCILLA
Sig.asintótica (bilateral)	0,006	0,003	0,000	0,000	0,000	0,002	0,000	0,007

	LIMO	ARENA	CC (0,3 bar)	PMP (15 bar)	CRAD	CIC	NDVI
Sig.asintótica (bilateral)	0,016	0,052	0,049	0,001	0,088	0,001	0,198

De las 15 variables analizadas, solamente el contenido de **arena**, la **CRAD** y el **NDVI** presentan **p valores** superiores a **0,05**, es decir, solamente esas tres variables presentaron una distribución normal.

Por lo tanto, al determinarse que la mayoría del conjunto de los datos estudiados no cumple con el criterio de distribución normal, se procedió a trabajar en la línea de test no paramétricos.

4.2.2. ESTUDIO DE CORRELACIÓN LINEAL

Como se ha explicado en el apartado de MATERIALES Y MÉTODOS, este análisis se realizó para estudiar la correlación de la CEa profunda y la CEa superficial con el resto de parámetros fisicoquímicos y el NDVI.

4.2.2.1. ESTUDIO DE CORRELACIÓN DE LA CEa PROFUNDA (0 – 90 cm)

Las tablas 7 y 8 muestran los resultados más significativos obtenidos del análisis de correlación de *Spearman*.

Tabla 7: Mayores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa profunda.

		E.G	NDVI	CIC	ARCILLA
CEa (0-90 cm)	Coeficiente de correlación de Spearman	-0,81	0,805	0,801	0,778
	Sig. (bilateral)	0,000	0,000	0,000	0,000

		ARENA	CaCO ₃	M.O	PMP
CEa (0-90 cm)	Coeficiente de correlación de Spearman	-0,732	0,671	0,665	0,613
	Sig. (bilateral)	0,000	0,000	0,000	0,000

Tabla 8: Menores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa profunda.

		LIMO	pH	CE(extr 1:5 H ₂ O)	CRAD	CC
CEa (0-90 cm)	Coeficiente de correlación de Spearman	-0,535	0,49	-0,475	-0,221	0,093
	Sig. (bilateral)	0,000	0,001	0,001	-	-

- Las mayores correlaciones de la CEa se encuentran con el porcentaje de **elementos gruesos**, la **capacidad de intercambio catiónico**, contenido de **arcilla**, contenido de **materia orgánica**, **carbonato cálcico (CaCO₃) equivalente**, contenido de **arena** y **punto de marchitez permanente (PMP)**; todas ellas con niveles de significación inferiores a 0,0001, lo que se corresponde con intervalos de confianza superiores al 99 %, y con coeficientes de *Spearman* altos, comprendidos aproximadamente entre 0,7 y 0,8 (valores absolutos). Es decir, a mayor valor de CEa profunda, menor es el porcentaje de elementos gruesos presente, mayor CIC, contenido de arcilla, de carbonato cálcico, de materia orgánica, y CaCO₃ equivalente, y mayor el punto de marchitez permanente.
- Destaca la elevada correlación entre la CEa profunda y el **NDVI** del cultivo, pues su valor < 0,0001 y coeficiente de *Spearman* de 0,805 hacen visible el incremento en la sanidad y desarrollo del cultivo a mayores valores de CEa.
- Existe una correlación lineal negativa fuerte con el **contenido de arena**, lo que indica que a mayores valores de CEa en profundidad, menor es el contenido de arena.
- Se obtienen valores de correlación relativamente bajos para el contenido de **limo**, pues a pesar de que la correlación es significativa (p<0,0001), los valores de los coeficientes de *Spearman* son cercanos a 0,5 (en valor absoluto). Además, no existe correlación estadísticamente significativa (p<0,05) para la **capacidad de campo (CC)** y no la hay tampoco para la **capacidad de retención de agua disponible (CRAD)**.
- El **pH** presenta una correlación no muy alta, lo que difiere de los resultados del ensayo de Castro y Costa (2012), sin embargo, ellos obtuvieron coeficientes de variación del 10 %, mientras que en el caso de nuestro estudio hay un estrecho rango entre los valores mínimos (7,7) y máximos (8,0), lo cual es inferior al 4% de variación.

- Es particular el dato de la correlación **CEa – CE laboratorio** (conductividad eléctrica determinada por el método extracto suelo: agua 1:5), pues presenta un nivel de significación de 0,01 y un coeficiente de *Spearman* de -0,475. No era esperable una correlación negativa, es decir, que presenten una relación inversa. En el estudio de Jian-Hao (2013), se observó como la CEa estaba directamente relacionada con la CE real, sin embargo, las diferencias en nuestro estudio se producen por el procedimiento de análisis de laboratorio que, debido a la abundante presencia de yesos en el suelo de la parcela, provoca saturaciones y medidas erróneas.

Evaluando el conjunto del análisis, es decir, analizando las correlaciones obtenidas entre todas las variables entre sí, sin considerar la CEa, se obtienen resultados muy significativos acerca de la correlación lineal entre distintas parejas de variables, las cuales presentan niveles de significación mayores o iguales al 99 % y coeficientes de *Spearman* superiores a 0,7 (en valores absolutos):

- El contenido de **Arcilla** tiene una correlación directa muy fuerte con las siguientes variables:

Materia Orgánica, CaCO₃ equivalente, CIC, NDVI

Esto indica que la arcilla está fuertemente correlacionada con dichas propiedades fisicoquímicas del suelo, las cuales tienen una alta influencia en el cultivo, como se denota en el incremento del NDVI.

- El contenido de materia orgánica presenta una correlación directa muy fuerte con las siguientes variables:

CaCO₃ equivalente, Arcilla, CIC, NDVI

Este dato nos da información acerca de la correlación fuerte entre los contenidos de arcilla y de materia orgánica, pues están fuertemente ligados e influyen sobre los parámetros de desarrollo del cultivo (correlación igualmente fuerte y directa con el NDVI).

- La capacidad de campo (**CC**) está fuertemente correlacionada de forma directa con la capacidad de retención de agua disponible (**CRAD**), y esta correlación es mucho mayor que la del punto de marchitez permanente (**PMP**).
- La capacidad de intercambio catiónico (**CIC**) tiene una correlación directa muy fuerte con el índice de vegetación (NDVI), lo que indica que tiene una gran influencia sobre el ritmo de desarrollo del cultivo.
- El contenido de **arena** tiene una correlación inversa muy fuerte con el contenido de arcilla y, por tanto, con las mismas variables que ésta, es decir:

Materia orgánica, CaCO₃ equivalente, CIC, NDVI

Por tanto, se observa como los contenidos de arcilla y de arena son antagónicos dentro de las propiedades texturales del suelo; y la arena tiene influencias negativas sobre el cultivo en condiciones de secano, como se denota de los menores índices de vegetación.

- También se aprecia una correlación inversa importante entre el porcentaje de **elementos gruesos** y la **CIC**, lo que se explica debido al menor contenido de partículas finas, que son las responsables de la capacidad de intercambio catiónico.

Dentro del ANEJO I, aparece la tabla en la que se correlacionan todas las variables con sus niveles de significación y coeficientes de *Spearman* en base a la CEa profunda.

4.2.2.2. ESTUDIO DE CORRELACIÓN DE LA CEa SUPERFICIAL (0 – 30 cm)

Las tablas 9 y 10 muestran los resultados más significativos obtenidos del análisis de correlación de *Spearman*.

Tabla 9: Mayores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa superficial.

		CIC	E.G	ARCILLA	NDVI	M.O	PMP	ARENA
CEa (0-30 cm)	Coefficiente de correlación de Spearman	0,724	-0,72	0,665	0,652	0,64	0,638	-0,629
	Sig. (bilateral)	0,000	0,000	0,000	0,000	0,000	0,000	0,000

Tabla 10: Menores correlaciones tanto positivas como negativas entre las variables estudiadas y la CEa superficial.

		CaCO3	LIMO	CElab	pH	CC	CRAD
CEa (0-30 cm)	Coefficiente de correlación de Spearman	0,598	-0,442	-0,307	0,290	0,207	-0,116
	Sig. (bilateral)	0,000	0,003	0,048	-	-	-

- Las mayores correlaciones se encuentran entre la **capacidad de intercambio catiónico**, contenido de **arcilla**, **materia orgánica** y **punto de marchitez permanente**; todas ellas con niveles de significación inferiores a 0,0001, aunque con coeficientes de *Spearman* de entre 0,6 y poco más de 0,7 (en valores absolutos), por lo que todas ellas son correlaciones lineales fuertes, a pesar de que lo son en menor medida que respecto a la CEa profunda, pues en este caso todos los valores de los coeficientes de *Spearman* eran superiores a 0,7 (valor absoluto). Por tanto, se puede decir que a mayores medidas de CEa superficial, mayor es la CIC, el contenido de arcilla, se encuentran mayores contenidos de materia orgánica y mayor PMP.
- En este caso, la correlación entre la CEa superficial y el **NDVI** del cultivo es igualmente elevada (p valor < 0,0001 y coeficiente de *Spearman* de 0,652), sin embargo ligeramente inferior respecto a la CEa profunda.

- Existe una correlación lineal negativa fuerte entre el contenido de **arena** y porcentaje de **elementos gruesos**, lo que indica que a mayores valores de CEa menores son los contenidos de arena y de elementos gruesos.
- Por el contrario, aparecen correlaciones no tan elevadas, pero estadísticamente significativas, con respecto al **carbonato cálcico equivalente**, **pH** y **capacidad de campo**, con valores positivos; y con respecto al contenido de **limo** y **CRAD**, en valores negativos.
- Respecto a la relación con la **CE determinada en laboratorio**, ésta vuelve a tener una correlación lineal negativa, aunque en este caso no es tan fuerte, pues su nivel de significación es de 0,048, lo que se traduce en un intervalo de confianza próximo al 95 % y coeficiente de *Spearman* -0,307. Estos valores tienen una significación algo menor que en el caso de la CEa profunda, sin embargo, la explicación y el efecto práctico vuelve a estar influido por el contenido de yesos en el suelo.

Evaluando el conjunto del análisis, se obtienen los mismos resultados que en el apartado anterior, pues la medida de la CEa en una u otra profundidad no condiciona la relación preexistente entre el resto de variables analizadas.

Resumiendo, tras el análisis de los resultados, se puede llegar a las siguientes afirmaciones:

- Existe una relación directa del contenido de **arcilla** con el contenido de **materia orgánica**, influyendo sobre los mismos parámetros del suelo como son la **CIC** y la **CaCO₃** equivalente.
- La **CRAD** está condicionada en mucha mayor medida por la **CC** que por el **PMP**.
- La **CIC** influye en gran medida sobre el **NDVI** del cultivo.
- Los contenidos de **arena** y de **arcilla** vuelven a ser opuestos, y la influencia sobre las mismas propiedades es inversa.
- El porcentaje de **EG** influye inversamente sobre la **CIC** del suelo.

Al igual que en el apartado anterior, dentro del ANEJO I es posible encontrar la tabla del análisis de correlación de la CEa superficial con respecto a las otras 13 variables estudiadas, apareciendo los p valores y coeficientes de *Spearman*.

En definitiva, a excepción de pequeñas variaciones sobre todo en el valor de los coeficientes de *Spearman* y en algún nivel de significación, se obtienen los mismos resultados del análisis de correlación lineal bivariada con la CEa profunda y con la CEa superficial, sin embargo, los niveles de significación son más altos cuando se evalúan medidas de la CEa entre 0 y 90 cm.

De esta forma, todos los análisis estadísticos realizados a partir de este momento, a excepción del análisis descriptivo, se hicieron en base únicamente a la CEa profunda y a las 13 variables fisicoquímicas restantes.

4.2.3. EVALUACIÓN DE LA DISTRIBUCIÓN DE LOS VALORES DE LOS PARÁMETROS FÍSICOQUÍMICOS EN FUNCIÓN DE LAS ZONAS DE CEa

4.2.3.1. ESTADÍSTICOS DESCRIPTIVOS

La tabla 11 muestra los estadísticos descriptivos de las principales variables analizadas.

Tabla 11: Estadísticos descriptivos de las variables analizadas.

	CEa(0-90 cm)	CEa(0-30 cm)	CE (extr 1:5 H ₂ O)	E.G	pH	M.O	CaCO ₃
Media	20,39	21,33	2,16	4,24	7,84	1,70	35,27
Mediana	15,64	17,35	2,40	1,13	7,85	1,86	37,70
Mínimo	2,59	5,10	0,67	0,00	7,70	0,94	19,69
Máximo	78,80	86,50	2,60	31,65	8,00	2,41	48,70
Rango intercuartil	21,42	15,26	0,23	6,84	0,10	1,03	14,77

	ARCILLA	LIMO	ARENA	CC	PMP	CRAD	CIC	NDVI
Media	29,35	42,80	27,85	28,83	15,60	13,24	8,54	0,66
Mediana	28,70	41,45	23,90	29,00	16,00	13,00	9,35	0,67
Mínimo	8,00	20,50	0,60	21,00	11,00	9,00	4,90	0,55
Máximo	60,10	70,00	65,80	33,00	18,00	17,00	12,80	0,75
Rango intercuartil	33,50	5,95	25,93	3,25	2,00	3,00	4,73	0,08

Como resultado de este primer análisis, se obtienen valores medios muy próximos de CEa profunda y superficial, siendo los últimos ligeramente superiores.


Se refleja un valor medio del pH de 7,84, lo cual denota un suelo alcalino, común dentro de la región estudiada.

Respecto al contenido de materia orgánica, un valor medio de 1,70 % s.m.s. no resulta bajo dada la semiaridez del emplazamiento.

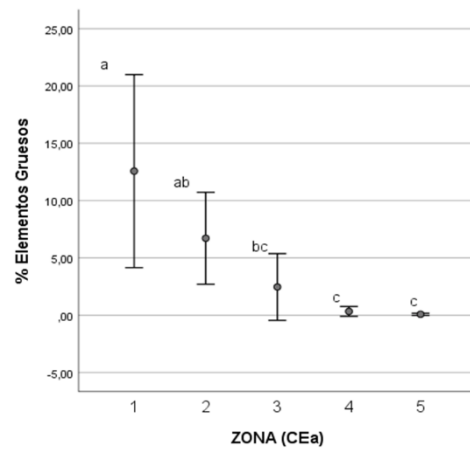
El contenido medio de limo es cercano al 43%, mientras que los de arcilla y arena no alcanzan el 30%.

4.2.3.2. ANOVA DE KRUSKAL-WALLIS


La distribución de los parámetros fisicoquímicos en función de las zonas establecidas de CEa profundas (zona 1: 0-5 mS/m; zona 2: 5-10 mS/m; zona 3: 10-20 mS/m; zona 4: 20-30 mS/m; zona 5: 30-158,08) está representada en las figuras 32 a 34.




(a)



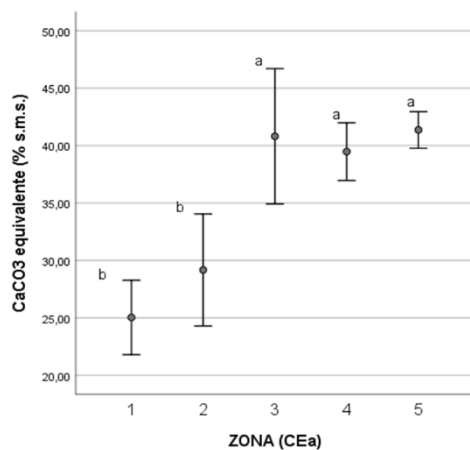
(b)




(c)



(d)




(e)

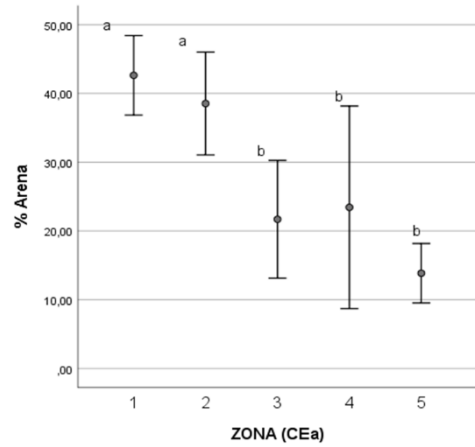


(f)


Figura 32: Valor medio e intervalo de confianza al 95% de los parámetros analizados en función de la CEa. (a)CE (extr 1:5), (b) %EG, (c) pH, (d) % MO, (e) CaCO₃, (f) % Arcilla. Letras distintas muestran diferencias significativas en base al Anova de Kruskal Wallis ($p < 0,05$).




(a)




(b)




(c)



(d)



(e)



(f)

Figura 33: Valor medio e intervalo de confianza al 95% de los parámetros analizados en función de la CEa. (a) %Limo, (b) %Arena, (c) % CC, (d) %PMP, (e) %CRAD, (f) CIC. Letras distintas muestran diferencias significativas en base al Anova de Kruskal Wallis ($p < 0,05$).




Figura 34: Valor medio e intervalo de confianza al 95% del NDVI en función de la CEa. Letras diferentes muestran diferencias significativas en base al ANOVA de Kruskal-Wallis ($p < 0,05$)

Los p valores obtenidos en el ANOVA de Kruskal-Wallis al comparar la distribución entre zonas de los parámetros fisicoquímicos son menores a 0,05 en todos los casos a excepción de la **capacidad de campo** y de la **CRAD**. Esto indica que se conserva la hipótesis nula de que la distribución entre zonas de estos parámetros es la misma. En todos los demás casos la distribución de cada una de las variables analizadas varía significativamente entre zonas de CEa, como se explica a continuación.

- Respecto a la **CE** determinada en **laboratorio**, los valores medios obtenidos en la zona 5 resultaron significativamente inferiores al del resto de zonas, si bien los datos reflejan una alta variabilidad y, como ya se ha comentado, los datos de CE determinada en laboratorio no se consideran concluyentes en este estudio por la alta cantidad de yesos presentes en el suelo de la parcela.
- En relación al porcentaje de **elementos gruesos**, se puede ver como la zona 1 de CEa comprende un amplio abanico, de valores medios, si bien a medida que aumenta esa CEa se acotan los elementos gruesos a porcentajes muy inferiores, alcanzando valores del 0 % para las zonas más altas, lo que coincide igualmente con los valores negativos del coeficiente de correlación de *Spearman*.
- Con respecto al **pH**, se refleja una pequeña tendencia ascendente a medida que lo hace la CEa, si bien es cierto que las variaciones en el pH del suelo están comprendidas entre 7,7 y 8,0, por lo que están en un rango muy pequeño de variación.
- En los apartados de la **materia orgánica**, **CaCO₃** equivalente, contenido de **arena** y **CIC** efectiva se aprecia una clara diferenciación entre dos zonas de valores diferentes (abarcando la primera de ellas las zonas 1 y 2; y la segunda las 3, 4 y 5) los cuales se explican caso por caso a continuación:
 - **% MO**: Las zonas 1 y 2 toman valores medios entre 1,0 y 1,5 %, y las zonas 3, 4 y 5 de alrededor del 2,0 %.
 - **CaCO₃**: Las zonas 1 y 2 toman valores medios del 25-30 %, mientras que las zonas 3, 4 y 5 se aproximan al 40 %.
 - **% Arena**: Las zonas 1 y 2 comprenden porcentajes medios del 40 al 45 %, los cuales descienden hasta el 10-30 % en las zonas 3, 4 y 5.

- **CIC efectiva:** Las zonas 1 y 2 abarcan valores medios cercanos a 6 (mEq/100g DM), mientras que son de 10 (mEq/100g DM) en las zonas 3, 4 y 5.

Esto nos indica la posibilidad de reducir a 2 el número de zonas categorizadas de CEa, atendiendo a la distribución de estos parámetros fisicoquímicos.

- En relación a las variables contenido de **limo**, **arcilla**, **PMP** y **NDVI**, se puede apreciar una clara clasificación en base a tres zonas de CEa con valores significativamente diferentes:
 - **% Limo:** Las zonas 2 y 3 se diferencian significativamente de las zonas 4 y 5.
 - **% Arcilla:** Las zonas 1 y 2 toman valores medios que oscilan entre el 10 y el 20 %, la zona 3 adopta aproximadamente un 30%, y las zonas 4 y 5 del 40 al 50 %.
 - **% PMP:** Las zonas 1 y 2 abarcan valores medios de un 13 a un 16 %, la zona 3 de un 14 a un 17 %, y para las zonas 4 y 5 el rango es mucho menor, del 16 al 17 %.
 - **NDVI:** La zona 1 toma valores medios de 0,6, la zona 2 de 0,65, y las zonas 3, 4 y 5 de 0,7. Esto indica una clara tendencia ascendente del vigor del cultivo a mayor valor de CEa.
- Referente a las variables **% CC** y **% CRAD**, no se aprecian tendencias ascendentes o descendentes en los valores medios para afirmar con un nivel de significación relevante que varían acorde a la CEa del suelo.

La información completa de este análisis puede consultarse en el ANEJO I.

De dicho análisis, se deduce la no necesidad de categorizar los valores de CEa en 5 zonas de cara a una prescripción variable de insumos, pues no se aprecian variaciones significativas entre las zonas 4 y 5 en la mayoría de los casos. De esta forma, resultaría más razonable a nivel práctico clasificar en base a dos o tres zonas, la primera de 0 a 10 mS/m, la segunda de 10 a 20 mS/m y la tercera de 20 mS/m en adelante. Adicionalmente, trabajar en base a zonificaciones muy pequeñas puede resultar más complicado a la hora de ajustar las anchuras de trabajo de la maquinaria agrícola, por lo que sería conveniente simplificar los mapas prescriptivos con una categorización en 3 zonas de CEa.

4.2.4. MODELO PREDICTIVO DE REGRESIÓN LINEAL MÚLTIPLE.

En primera instancia, gracias a los gráficos de dispersión realizados mediante el programa Excel, fue posible comparar cada una de las variables independientemente con la CEa profunda, obteniendo de esta forma la recta de regresión y el coeficiente R^2 en cada caso.

Estos coeficientes no tomaban valores muy altos, (mínimo de **0,0223** y máximo de **0,5120**) como se aprecia en la tabla 12, por lo que se decidió aplicar un modelo de regresión lineal múltiple, relacionando varias variables para predecir la CEa, lo que permitió obtener un coeficiente de regresión mayor.

Tabla 12: Coeficientes R² de la recta de regresión obtenida mediante Excel.

CORRELACIÓN	VALOR R ²
CEa - CE (extr 1:5)	0,3439
CEa - % el.gr.	0,2678
CEa - pH	0,2792
CEa - MO	0,3262
CEa - CaCO ₃	0,3676
CEa - Arcilla	0,0866
CEa - Limo	0,0431
CEa - Arena	0,3527
CEa - CC (0,3bar)	0,0358
CEa - PMP (15bar)	0,2115
CEa - CRAD	0,0223
CEa - CIC	0,5120
CEa - NDVI	0,4339

Las gráficas de regresión obtenidas para cada una de las variables pueden consultarse en el ANEJO I.

En primer lugar, como resultado del análisis de regresión lineal múltiple, realizado con la CEa profunda como variable explicada y las variables fisicoquímicas y NDVI como variables predictoras se obtuvo un coeficiente de determinación $R^2 = 0,8978$ y un **p valor** $< 0,0001$, lo que resulta un nivel de significación muy alto. Los resultados más detallados se presentan en la tabla 13.

Tabla 13: Primer modelo de regresión lineal múltiple.

	Coefficiente Estimado	Error Estándar	p valor
Intercepto	12,5732	86,4741	0,8859
% Arcilla	-0,0081	0,0922	0,9305
% Arena	-0,3206	0,1001	0,0047**
% CaCO3 eq	-0,4773	0,1940	0,0236*
CRAD	6,7652	3,2896	0,0537
CC (0,3 bar)	-7,0609	3,2473	0,0425*
CE (extr 1:5)	1,8286	3,2897	0,5848
CIC	3,1678	0,7608	0,0005***
% Limo	-0,2117	0,0771	0,0128*
% MO	-8,0818	3,0073	0,0146*
NDVI	36,6273	18,5522	0,0631
pH	-0,4266	10,3631	0,9676
PMP (15 bar)	7,3627	3,1596	0,0309*
% EG	-0,6671	0,2145	0,0058**

Teniendo en cuenta la ausencia de significación de algunas de las variables dentro del modelo (**CE (extr 1:5)**, **CaCO3** equivalente, **CC**, **PMP**, **CRAD**, **NDVI**, contenido de **arcilla** y **pH**), se obtuvo un gráfico de filtrado de variables que ayudó a detectar las más significativas dentro del modelo.




Figura 35: Gráfico de filtrado de datos significativamente influyentes obtenido mediante el programa R.

La figura 35 orienta sobre el nivel de influencia de las variables en el modelo, y de él se desprende que las variables arena, CIC, limo, materia orgánica y elementos gruesos, serían las más influyentes.

De esta forma, tras recurrir a la opción SELECCIÓN DE MODELO PASO A PASO, mediante paso atrás, se obtuvo un modelo con mejor ajuste, pues todas las variables finales

obtuvieron un p valor estadísticamente significativo y el coeficiente de determinación general del modelo fue de $R^2 = 0,8652$ con un **p valor < 0,0001**. Los resultados de la influencia de las variables en el modelo se muestra en la tabla 14.

Tabla 14: Modelo de regresión lineal con mejor ajuste posible.

	Coeficiente Estimado	Error Estándar	p valor
Intercepto	24,6234	6,1643	0,000449***
% Arena	-0,2458	0,0746	0,00276**
CIC	2,8866	0,5611	0,000021***
% Limo	-0,2491	0,0655	0,00075***
% MO	-8,9095	2,3238	0,00069***
% EG	-0,6375	0,2244	0,00844**

Los resultados que se reflejan de este segundo análisis son los siguientes:

- Las variables con mayor capacidad de predicción de los valores de CEa medida en el intervalo de 0 a 90 cm son el porcentaje de **elementos gruesos**, los contenidos de **arena**, **limo** y **materia orgánica**, y la **capacidad de intercambio catiónico**. Todos ellos con intervalo de confianza superior al 95 %.
- Son particulares dos casos:
 - **Materia Orgánica (%):** es de destacar que el valor de la MO debe entrar en el modelo con signo negativo, lo que no es coherente con los resultados obtenidos en las pruebas de correlación y análisis de varianza anteriores, sin embargo, no se trata de un análisis de regresión simple, sino que se está teniendo en cuenta como predecir lo mejor posible los valores de CEa.
 - **Limo (%):** no presenta valores altos para el test de correlación, y presenta una alta variabilidad para el Anova de Kruskal-Wallis (todo ello lo hace una variable poco fiable), sin embargo, el modelo predictivo la detecta como una variable con gran fuerza predictora.
- La fórmula final obtenida en el modelo predictivo se muestra como ecuación 5:

Ecuación 5: Ecuación final modelo predictivo.

$$\begin{aligned}
 \text{Valor CEa} = & \text{Intercepto} + (\text{Coef}(\% \text{Arena}) \times \text{Valor}(\% \text{Arena})) \\
 & + (\text{Coef}(\text{CIC}) \times \text{Valor}(\text{CIC})) + (\text{Coef}(\% \text{Limo}) \times \text{Valor}(\text{Limo})) \\
 & + (\text{Coef}(\% \text{MO}) \times \text{Valor}(\% \text{MO})) + (\text{Coef}(\% \text{EG}) \times \text{Valor}(\% \text{EG}))
 \end{aligned}$$

Respecto a la prueba de ajuste mediante ecuaciones cuadráticas o cúbicas gracias a las opciones de polinomio crudo y spline natural, no se observó mejora significativa en los p valores, por lo que se conservó el ajuste lineal, y se procedió a su validación.

Respecto al resultado de los análisis de validación con intervalo de confianza del 95 %, se obtuvieron los gráficos de los efectos (explicados en el apartado 4.2.4.1.) y los gráficos presentes en el ANEJO I, los cuales verificaban que el ajuste lineal resultaba el más adecuado para este modelo. Sobre los diagnósticos numéricos, se realizaron los test anteriormente explicados, obteniendo como resultado una ausencia de colinealidad de las variables mediante el test de **factores de inflación de varianza** ($vif > 0,05$ en todos los casos); se confirmó que la varianza de los residuos se distribuye homogéneamente a través del test de **Breusch-Pagan** ($p = 0,2071 > 0,05$); se confirmó la ausencia de autocorrelación de los residuos con el test de **Durbin-Watson** ($p = 0,3791 > 0,05$); y, por último se comprobó que no existían valores anormales o también conocidos como “outlayers” a través del test de **Bonferroni** ($p = 0,0213 < 0,05$).

Del modelo predictivo se obtuvo la tabla número 15, en la que se muestran los valores y zonas reales de la CEa, medidos por el sensor Veris, así como los valores y las zonas predichas por el programa informático. Se aprecia una pequeña variabilidad entre los valores de CEa reales y predichos, que sin embargo pertenecen a las mismas zonas.

Resultado de las predicciones de zona de CEa en base a los 5 parámetros introducidos en el modelo predictivo (% Arena, % Limo, % EG, % MO y CIC) se obtiene un error del 24 % con respecto a los 33 puntos evaluados.

Cabe destacar que este análisis se ha realizado en base a 4 zonas de CEa, por lo que el porcentaje de error esperado para un modelo categorizado en base a 3 zonas de CEa (como se observa que es más adecuado en el ANOVA de Kruskal-Wallis) podría ser inferior.

Tabla 15: Comparación valores y zonas CEa real y predicha.

PUNTO	Valor CEa (mS/m)	Zona CEa	Predicción CEa (mS/m)	Predicción Zona CEa
1	5.64	5-10	8,23	5-10
2	3.72	0-5	4,67	0-5
3	5.24	5-10	4,73	0-5
4	4.59	0-5	3,68	0-5
5	26.51	20-30	25,59	20-30
7	21.22	20-30	23,77	20-30
8	6.74	5-10	7,28	5-10
9	11.16	10-20	13,85	10-20
10	3.59	0-5	4,10	0-5
11	4.02	0-5	6,45	0-5
12	6.11	5-10	2,14	0-5
13	16.45	10-20	11,77	10-20
14	14.48	10-20	15,49	10-20
16	16.91	10-20	21,04	20-30
17	8.25	5-10	6,00	5-10
19	22.98	20-30	16,64	10-20
21	6.56	5-10	7,99	5-10
22	25.87	20-30	22,11	20-30
23	24.57	20-30	22,21	20-30
26	15.82	10-20	18,17	10-20
27	5.11	5-10	6,01	5-10
28	7.55	5-10	9,40	5-10
29	27.35	20-30	24,41	20-30
30	27.60	20-30	23,93	20-30
31	4.55	0-5	4,43	0-5
32	18.04	10-20	20,13	20-30
33	21.58	20-30	25,16	20-30
36	9.26	5-10	4,16	0-5
37	3.63	0-5	5,43	5-10
38	7.01	5-10	9,01	5-10
40	11.82	10-20	12,14	10-20
41	2.59	0-5	4,68	0-5
42	15.46	10-20	17,59	5-10

4.2.4.1. GRÁFICOS DE LOS EFECTOS

La figura 36 muestra cómo es el efecto de cada una de las variables en el modelo predictivo.

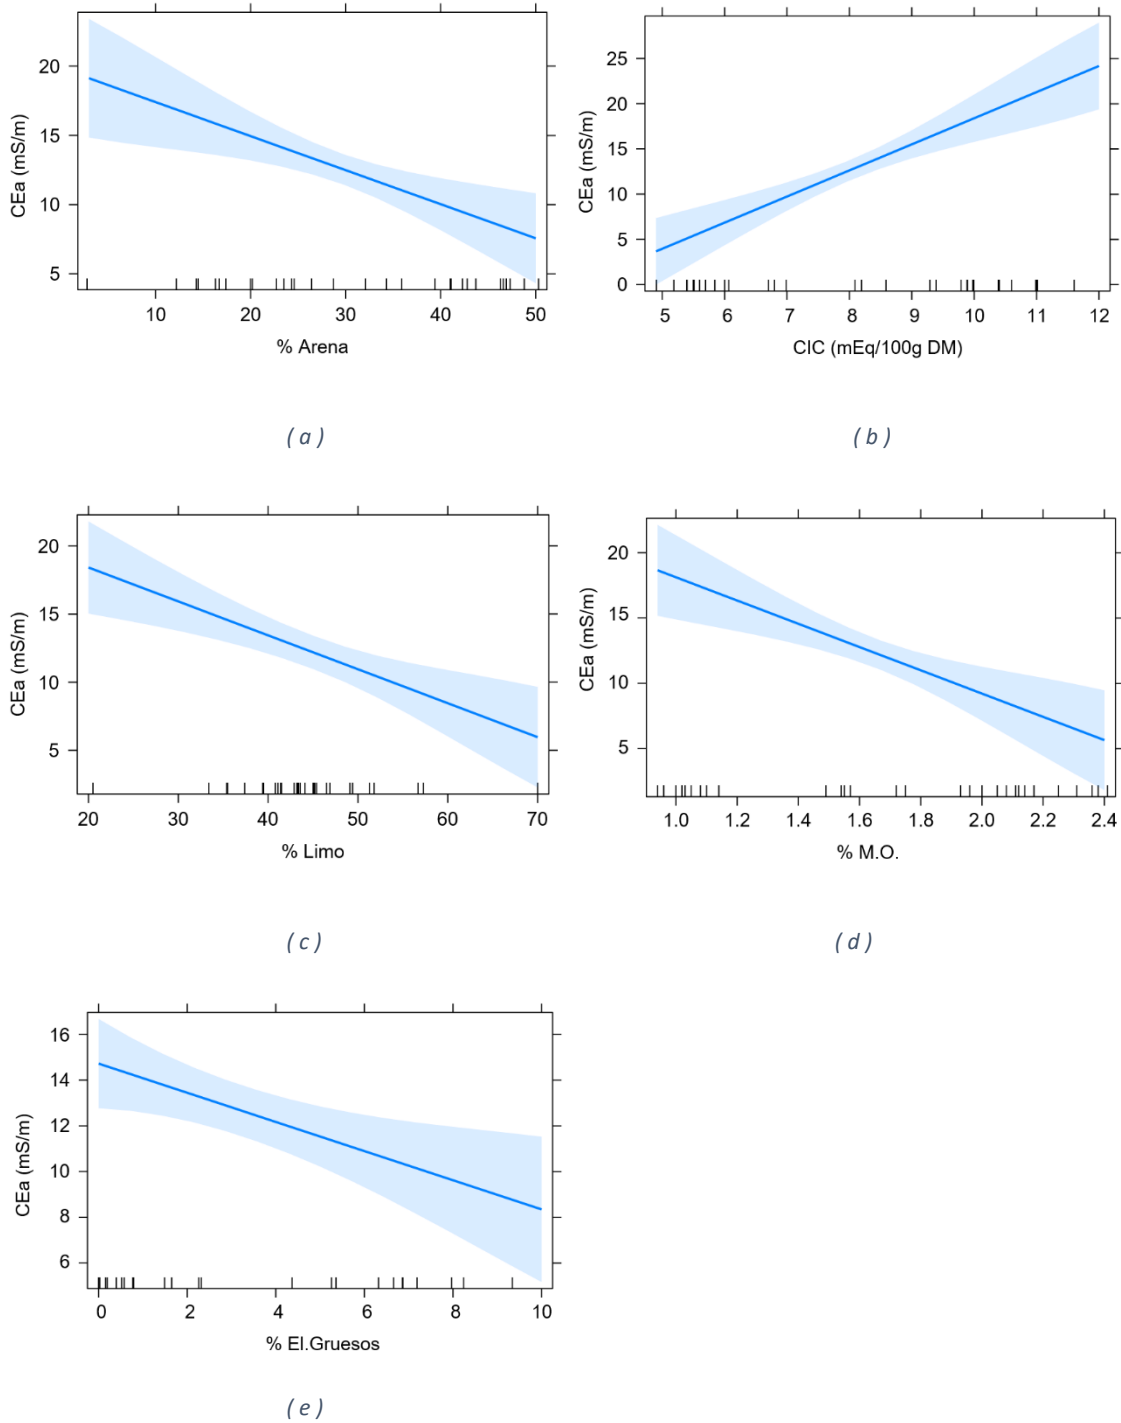


Figura 36: Efecto de las variables predictoras sobre la CEEa dentro del modelo predictivo.
 (a) % Arena, (b) CIC, (c) % Limo, (d) % MO, (e) % EG.

El efecto de las variables sigue una tendencia similar a la obtenida en el análisis de regresión lineal simple (ANEJO I), a excepción de la materia orgánica, que en este caso presenta pendiente negativa.

Esto es explicable debido a que, en la regresión simple, el R^2 obtenido tenía un valor bajo, de 0,3262, lo que indica una alta variabilidad de los valores. Si bien ya en su estudio, Castro

y Costa (2012) afirmaban que la materia orgánica es mayor a medida que aumenta la CEa, no quiere decir que en nuestro estudio el resultado obtenido sea opuesto, sino que, para predecir los valores de la CEa en base a las 13 variables analizadas, el contenido de materia orgánica debe entrar en el modelo con signo negativo

4.2.4.2. VALIDACIÓN DEL MODELO

Adicionalmente, y como procedimiento final de validación del modelo predictivo obtenido, se calcularon, a partir de la ecuación obtenida, seis valores de CEa a partir de datos no introducidos en el modelo previamente, y obtenidos de puntos de muestreo de las mismas parcelas experimentales. Los valores obtenidos no fueron adecuados para la CEa predicha (algunos resultaron incluso negativos), como se aprecia en la tabla 16, lo cual es debido al alto porcentaje de elementos gruesos presente en estas 6 muestras adicionales, con valores muy diferentes a los obtenidos en el muestreo realizado en este trabajo.

Tabla 16: Predicción de la CEa de muestras adicionales con valores erróneos.

PUNTO	ZONA	ARENA	CIC	LIMO	MO	EG	PREDICCIÓN VALOR CEa
1	10-20	39	5,5	37	0,92	37,2	-13,50834
2	20-30	16,3	10,4	43,2	1,9	31	-0,10757
3	10-20	37,8	6,3	48,1	0,86	29,1	-7,97079
4	20-30	8,5	9,7	43,5	1,8	26,4	3,53777
5	0-10	34	5,6	41,6	1,2	44,1	-20,02995
6	20-30	10,5	9,8	45,4	1,9	28,1	0,88684

Por lo tanto, al observarse que el porcentaje de EG estaba condicionando las predicciones del modelo, se procedió a eliminar dicha variable, obteniendo un nuevo modelo, con un $R^2=0,8522$ y un $p\text{-valor} < 0,0001$, el cual se presenta en la tabla 17.

Tabla 17: Modelo predictivo sin la variable % EG.

	Coeficiente Estimado	Error Estándar	p valor
Intercepto	21,3391	6,7769	0,003875**
% Arena	-0,3154	0,0789	0,000423***
CIC	3,3818	0,5969	0,00000452***
% Limo	-0,2524	0,0733	0,001838**
% MO	-9,3139	2,5959	0,001253**

Respecto a las gráficas de los efectos, tal y como se aprecia en la figura 37, la similitud respecto a los obtenidos con el anterior modelo es total. Las gráficas de componentes + residuos se encuentran recogidas en el ANEJO I.




Figura 37: Efecto de las variables predictoras sobre la CEEa dentro del modelo predictivo.
 (a) % Arena, (b) CIC, (c) % Limo, (d) % MO.

Por tanto, se volvieron a introducir los valores del análisis de muestras de suelo para obtener la predicción sobre la CEEa, obteniendo la tabla 18, en la que el ajuste de la predicción frente al valor real de la CEEa es del 60 % de acierto, con respecto a las 33 muestras cuyos valores de CEEa estaban en el rango de 0 a 30 mS/m, eliminados los valores >30 mS/m.

Teniendo en cuenta que dicha categorización se ha hecho en base a las 4 zonas de CEEa, en el caso de haberla hecho en base a las tres zonas, este ajuste sería superior.

Tabla 18: Predicción de valores y zonas de CEa en base al modelo sin % EG.

PUNTO	Valor CEa (mS/m)	Zona CEa	Predicción CEa (mS/m)	Predicción Zona CEa
1	5.64	5-10	6,59	5-10
2	3.72	0-5	5,27	5-10
3	5.24	5-10	4,98	0-5
4	4.59	0-5	6,31	5-10
5	26.51	20-30	24,18	20-30
7	21.22	20-30	22,70	20-30
8	6.74	5-10	4,26	0-5
9	11.16	10-20	13,02	10-20
10	3.59	0-5	3,80	0-5
11	4.02	0-5	6,38	5-10
12	6.11	5-10	2,97	0-5
13	16.45	10-20	10,83	10-20
14	14.48	10-20	17,30	10-20
16	16.91	10-20	20,67	20-30
17	8.25	5-10	5,04	5-10
19	22.98	20-30	15,09	10-20
21	6.56	5-10	13,00	10-20
22	25.87	20-30	22,55	20-30
23	24.57	20-30	22,56	20-30
26	15.82	10-20	17,56	10-20
27	5.11	5-10	4,91	5-10
28	7.55	5-10	7,51	5-10
29	27.35	20-30	24,82	20-30
30	27.60	20-30	23,39	20-30
31	4.55	0-5	6,88	5-10
32	18.04	10-20	19,39	10-20
33	21.58	20-30	26,04	20-30
36	9.26	5-10	4,86	5-10
37	3.63	0-5	6,05	5-10
38	7.01	5-10	8,07	5-10
40	11.82	10-20	10,54	10-20
41	2.59	0-5	6,55	5-10
42	15.46	10-20	17,93	10-20

Por último, se analizó la predicción en base a los valores de un muestreo de suelo realizado al inicio del proyecto en las tres parcelas experimentales de Valsalada, cuyos puntos se correspondían a muestras compuestas tomadas en zonas de valores similares de CEa, obteniendo una predicción acertada en el 83,33 % de los casos. La validación también se realizó en base a los 9 valores de CEa>30 mS/m pertenecientes a la zona 5, los cuales se habían retirado del modelo para evitar errores, obteniendo una predicción muy cercana (no pertenece a la misma zona, sin embargo, los valores son próximos) a pesar de no haber considerado esos valores altos a la hora de la elaboración del modelo predictivo. Esto es apreciable en la tabla 19.

Tabla 19: Predicciones con valores adicionales de CEa de las tres parcelas experimentales y de las muestras con valores elevadas de CEa de la propia parcela 2.

PUNTO	Valor CEa (mS/m)	Zona CEa	Predicción CEa (mS/m)	Predicción Zona CEa
PREDICCIONES VALORES EXTRAS DE MUESTRAS ANEJAS A LAS PARCELAS				
1	-	10-20	13,02	10-20
2	-	20-30	26,06	20-30
3	-	10-20	13,86	10-20
4	-	20-30	27,00	20-30
5	-	0-10	11,16	10-20
6	-	20-30	25,30	20-30
PREDICCIONES VALORES ALTOS CEa PARCELA 2				
6	57,27	>30	28,50	20-30
15	44,11	>30	29,72	20-30
18	30,52	>30	24,43	20-30
20	37,3	>30	24,31	20-30
24	46,16	>30	25,08	20-30
25	61,99	>30	22,74	20-30
34	41,58	>30	23,65	20-30
35	46,86	>30	4,85	0-5
39	78,8	>30	21,18	20-30

De esta forma, se confirma que el modelo alcanzado presenta una bondad de ajuste muy alta en la predicción de los valores y zonas de CEa a partir de únicamente 4 variables, aplicable a zonas y valores no considerados en su elaboración.

5. CONCLUSIONES

Del trabajo realizado se pueden extraer las siguientes conclusiones:

1. La medición de la CEa del suelo ha permitido caracterizar correctamente la variabilidad intraparcilaria de las propiedades del suelo, confirmándose la diferencia en la distribución de los valores de los parámetros fisicoquímicos en función de determinadas categorías de valores.
2. La CEa de 0 – 90 cm presenta una alta correlación con la medida de la CEa de 0 – 30 cm.
3. Los parámetros fisicoquímicos del suelo y el NDVI se correlacionan con ambas CEa, pero mayormente con la medida de 0 – 90 cm.
4. Existen diferencias en la distribución de los parámetros fisicoquímicos del suelo en función de las zonas de CEa. Para el caso concreto de este estudio, el punto de inflexión del cambio de categoría se sitúa en los 10 mS/m para las variables materia orgánica, textura, CIC y NDVI.
5. En base a los resultados obtenidos, sería factible simplificar el número de zonas en las que dividir la parcela para realizar un manejo sitio-específico, teniendo en cuenta las diferencias en la distribución de parámetros fisicoquímicos y agrupando aquellas de características similares.
6. En base a los análisis realizados, se ha obtenido un modelo predictivo para explicar la CEa a partir de algunos parámetros fisicoquímicos del suelo con un alto grado de ajuste. Una mayor recopilación de datos en las mismas condiciones edafoclimáticas permitirá hacer más robustos este tipo de modelos.

6. LIMITACIONES DEL ESTUDIO Y LÍNEAS FUTURAS DE TRABAJO

Como líneas futuras de trabajo se propone el poder contar con un área mayor de estudio, la cual abarque una mayor cantidad de puntos muestreados, con el objetivo de poder alcanzar un mejor ajuste de los modelos predictivos y, por tanto, una mejor caracterización del suelo en base a este parámetro.

En el actual TFG se contó inicialmente con 42 puntos de muestreo de suelos, los cuales tras retirar los valores demasiado elevados de CEa (que provocarían errores en el ajuste de los distintos modelos), conllevan un total de 33 puntos, los cuales pueden considerarse como insuficientes a la hora de predecir totalmente las propiedades del suelo en este tipo de parcelas en base a su CEa.

Adicionalmente, sería conveniente realizar pruebas y ensayos en suelos de distinta morfología, pues de esta forma sería posible alcanzar modelos y por tanto conclusiones generalizadas a la hora de trabajar en base a la variabilidad de los suelos caracterizados por su medida de CEa.

Si bien es conocida la relación existente entre el NDVI y el rendimiento del cultivo, tal y como explicaban Ruiz-Huanca et al. (2005) en su ensayo, habrían faltado los datos del rendimiento del cultivo, para poder contrastar los resultados con el potencial real del suelo según sus propiedades.

7. REFERENCIAS BIBLIOGRÁFICAS

- Alonso, D. (2022). *NDVI: QUÉ ES Y CÓMO CALCULARLO CON SAGA DESDE QGIS*. Obtenido de: <https://mappinggis.com/2015/06/ndvi-que-es-y-como-calcularlo-con-saga-desde-qgis/>.
- Badía, D.; Ortíz, O.; Martí, C. (2017). *EXPERIMENTOS DIDÁCTICOS CON EL SUELO PARA LA EDUCACIÓN PRE-UNIVERSITARIA*. Obtenido de: <https://acortar.link/lrVzMd>
- Carrera, E. M. (2020). *DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA ÓPTICO PARA CAPTACIÓN DE IMÁGENES MULTIESPECTRALES A SER USADO EN LA DETECCIÓN DE ÁREAS INFECTADAS POR HONGOS EN HOJAS DE PLANTAS*. Quito: Facultad de Ingeniería Eléctrica y Electrónica. Tesis Electrónica y Control (IEC). Obtenido de: <http://bibdigital.epn.edu.ec/handle/15000/20918>
- Castro, M. y Costa, J.L. (2012). *CONDUCTIVIDAD ELÉCTRICA APARENTE Y SU RELACIÓN CON PROPIEDADES DEL SUELO, PARA LA DELIMITACIÓN DE ZONAS PARA MANEJO SITIO ESPECÍFICO*. Buenos Aires: UNMdP- Facultad de Ciencias Agrarias; INTA- Balcarce. Proyecto: Remote Sensor and Soil Variability. Obtenido de: https://www.researchgate.net/publication/299388042_CONDUCTIVIDAD_ELECTRICA_APARENTE_Y_SU_RELACION_CON_PROPIEDADES_DEL_SUELO_PARA_LA_DELIMITACION_DE_ZONAS_PARA_MANEJO_SITIO_ESPECIFICO
- Climagri. (s.f.). *ROTACIÓN DE CULTIVOS*. Obtenido de: <http://www.climagri.eu/index.php/es/rotacion-de-cultivos#:~:text=La%20rotaci%C3%B3n%20de%20cultivos%20consiste,mismo%20campo%20a%C3%B1o%20tras%20a%C3%B1o>
- Corwin, D.L., Lesch, S.M. (2003). *APPLICATION OF SOIL ELECTRICAL CONDUCTIVITY TO PRECISION AGRICULTURE: THEORY, PRINCIPLES AND GUIDELINES*. *Agronomy Journal*, 95: 455–471. Obtenido de: <https://doi.org/10.2134/agronj2003.4550>
- Corwin, D.L., Lesch, S.M. (2005). *APPARENT SOIL ELECTRICAL CONDUCTIVITY MEASUREMENTS IN AGRICULTURE*. *Computers and Electronics in Agriculture*, 46: 11–43. Obtenido de: <https://doi.org/10.1016/j.compag.2004.10.005>
- Esaño, L. M. (2017). *INTRODUCCIÓN A R: UN LENGUAJE ORIENTADO A OBJETOS*. Apuntes curso Introducción a R. Escuela de Doctorado UNIZAR.
- FAO. (2018). *PERSPECTIVAS POR SECTORES PRINCIPALES. PRODUCCIÓN DE CULTIVOS*. Obtenido de: <https://www.fao.org/3/y3557s/y3557s04.pdf>.
- García, F. O. (2014). *AVANCES EN EL MANEJO NUTRICIONAL DE LOS CULTIVOS DE TRIGO*. Buenos Aires: INPOFOS Cono Sur. Trabajo presentado en el Congreso “A Todo Trigo”. Mar del Plata, Buenos Aires, Argentina. 13-14 Mayo 2004.
- Gobierno de Aragón. (2022). *PRECIPITACIONES, TEMPERATURAS Y SUS ANOMALÍAS EN VARIAS ESTACIONES METEOROLÓGICAS, POR MESES. ARAGÓN*. Obtenido de: <https://servicios3.aragon.es/iaeaxi/tabla.do?path=/14/05/02/&file=14050201.px&type=pcaxis&L=0>

- Guerra Delgado, A.; Monturiol, F.; Badorrey Peracho, T.; Gallardo Díaz, J.; Carlevaris Muñiz, J.J.; Horra Ruiz, J.L., Labradero, J.L. (1970). *MAPAS DE SUELOS DE LAS PROVINCIAS DE ZARAGOZA, HUESCA Y LOGROÑO*. Madrid. CSIC: Instituto Nacional de Edafología y Agrobiología. 66 pp.
- Gutiérrez, M. (2019). *ORIENTACIONES VARIETALES PARA LAS SIEMBRAS DE CEREALES EN ARAGÓN*. Dirección General de Desarrollo Rural. Centro de Transferencia Agroalimentaria.
- I.G.N. (s.f.). *INFRAESTRUCTURA DE DATOS ESPACIALES*. Obtenido de: <https://www.ign.es/web/ign/portal/ide-area-nodo-ide-ign>
- IICA. (2014). *MANUAL DE AGRICULTURA DE PRECISIÓN*. Montevideo: Programa Cooperativo para el Desarrollo Tecnológico Agroalimentario y Agroindustrial del Cono Sur. 175 pp.
- ISPA. (2018). *PRECISION AG DEFINITION*. Obtenido de: <https://www.ispag.org/about/definition>
- Jian-Hao, L.I. (2013). *INTEGRAL EQUATION OF RELATIONSHIP ON THE APPARENT CONDUCTIVITY AND TRUE CONDUCTIVITY IN INDUCTION LOGGING*. Sci. China Earth Sci. 57 pp. Obtenido de: <https://doi.org/10.1007/s11430-013-4809-9>
- Käthner, J., Zude-Sasse, M. (2015). *INTERACTION OF 3D SOIL ELECTRICAL CONDUCTIVITY AND GENERATIVE GROWTH IN PRUNUS DOMESTICA L.* European Journal of Horticultural Science, 80: 231–239. DOI: [10.17660/eJHS.2015/80.5.5](https://doi.org/10.17660/eJHS.2015/80.5.5)
- Kühn, J., Brenning, A., Wehrhan, M., Koszinski, S., Sommer, M. (2009). *INTERPRETATION OF ELECTRICAL CONDUCTIVITY PATTERNS BY SOIL PROPERTIES AND GEOLOGICAL MAPS FOR PRECISION AGRICULTURE*. Precision Agriculture, 10: 490–507. Obtenido de: <https://doi.org/10.1007/s11119-008-9103-z>
- Kverneland, G. (2022). *ACERCA DE ISOBUS*. Obtenido de: <https://es.kverneland.com/iM-FARMING/Acerca-de-ISOBUS>.
- López-Bellido, L. (2009). En: *GUÍA PRÁCTICA DE LA FERTILIZACIÓN RACIONAL DE LOS CULTIVOS EN ESPAÑA. PARTE II*. Madrid: Ministerio de Medio Ambiente y Medio Rural y Marino (Ed).
- MAPA. (2022). *AVANCES DE SUPERFICIES Y PRODUCCIONES AGRÍCOLAS. ENERO 2022*. Obtenido de: https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/cuaderno_enero2022_tcm30-615179.pdf
- MAPA. (2020). *CULTIVOS HERBÁCEOS E INDUSTRIALES. CEREALES*. Obtenido de: <https://www.mapa.gob.es/es/agricultura/temas/producciones-agricolas/cultivos-herbaceos/cereales/#:~:text=En%20Espa%C3%B1a%2C%20se%20cultiva%20una,largo%20de%20todo%20el%20territorio>.
- MAPA. (2021). *ESYRCE (ENCUESTA DE SUPERFICIES Y RENDIMIENTOS DE CULTIVOS)*. Obtenido de: https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/comentariosespana2021_tcm30-584074.pdf
- MAPA. (2020). *MATERIAL VEGETAL. TRIGO*. Obtenido de: <https://www.mapa.gob.es/app/MaterialVegetal/fichaMaterialVegetal.aspx?idFicha=1329>.

- MAPA. (2020). *SIEMBRA DIRECTA DE CULTIVOS HERBÁCEOS, POR TIPO DE CULTIVO. ARAGÓN Y ESPAÑA*. Obtenido de: <https://servicios3.aragon.es/iaeaxi/tabla.do?path=/14/13/09/&file=14130902.px&type=pcaxis&L=0>.
- Martínez-Casasnovas, J.A.; Arnó-Satorra, J., Escolà-Agustí, A. (2021). *SENSORES DE CONDUCTIVIDAD ELÉCTRICA APARENTE PARA EL ANÁLISIS DE LA VARIABILIDAD DEL SUELO EN AGRICULTURA DE PRECISIÓN*. Publicado en "Tecnología Hortícola Mediterránea. Evolución y futuro: viveros, frutales, hortalizas y ornamentales". Ed. A. Namesny, C. Conesa, L. Martín, P. Papasseit. Biblioteca de Horticultura, SPE3 S.L. Valencia, España. 837 pp. ISBN: 978-84-16909-46-9. Obtenido de: https://issuu.com/horticulturaposcosecha/docs/tecnologia_horticola_mediterranea
- Martínez-Casasnovas, J.A. (2019). *SISTEMAS DE INFORMACIÓN GEOGRÁFICA (SIG) Y TELEDETECCIÓN*. Lleida: Universitat de Lleida.
- Martinez, G., Vanderlinden, K., Ordóñez, R., Muriel, J.L. (2009). *CAN APPARENT ELECTRICAL CONDUCTIVITY IMPROVE THE SPATIAL CHARACTERIZATION OF SOIL ORGANIC CARBON?* Vadose Zone Journal, 8: 586–593. Obtenido de: <https://doi.org/10.2136/vzj2008.0123>
- Minasny, B.M.; McBratney, A.B. y Whelan, B.M. (2005). *VESPER version 1.62*. Obtenido de Australian centre for precision agriculture, The University of Sydney, NSW 2006. Obtenido de: <http://www.usyd.edu.au/su/agric/acpa>
- Minuesa, C. (2021). *ANÁLISIS DE LA OPORTUNIDAD DE APLICACIÓN DE TÉCNICAS DE AGRICULTURA DE PRECISIÓN EN CULTIVOS EXTENSIVOS DE SECANO DE LA HOYA DE HUESCA*. Lleida: Trabajo Fin de Grado Universitat de Lleida.
- Oguri, G.; Andrade-Sanchez, P.; Heun, J. (2009). *POTENTIAL USE OF THE VERIS APPARENT EC SENSOR TO PREDICT SOIL TEXTURE UNDER THE SEMI-ARID CONDITIONS OF CENTRAL ARIZONA*. Reno, Nevada: ASABE Annual International. Paper Number: 096488. 9 pp. DOI:[10.13031/2013.27450](https://doi.org/10.13031/2013.27450)
- Pierce, F.J. y Nowak, P. (1999). *ASPECTS OF PRECISION AGRICULTURE*. Michigan 48824: Department of Crop and Soil Sciences Michigan State University East Lansing. Obtenido de: [https://doi.org/10.1016/S0065-2113\(08\)60513-1](https://doi.org/10.1016/S0065-2113(08)60513-1)
- Rojas, J.R.; Guerra, A.F.; Arévalo, J.A.; Guerrero, L. y Leiva, F.R. (2015). *SENSOR DE CONDUCTIVIDAD ELÉCTRICA APARENTE PARA DEFINIR ZONAS HOMOGÉNEAS DE MANEJO EN SUELOS SALINOS*. Revista Colombiana de Ciencias Hortícolas. Vol 9. - No 1 - pp. 86-96. Obtenido de: <http://dx.doi.org/10.17584/rcch.2015v9i1.3748>
- Rouse, J. R., Jr.; Haas, R.H.; Deering, D.W.; Schell, J.A.; Harlan, J.C. (1974). *MONITORING THE VERNAL ADVANCEMENT AND RETROGRADATION (GREENWAVE EFFECT) OF NATURAL VEGETATION*. Texas 77843 : Texas A&M University, Remote Sensing Center, College Station Texas. Type II I Report for the Period September 1972-November 1974. Obtenido de: <https://ntrs.nasa.gov/citations/19750020419>
- Ruiz-Huanca, P.; Palacios-Vélez, E.; Bolaños-González, M.; Oropeza-Mota, J.L.; Exebio-García, A.; Mejía-Saenz, E. (2005). *ESTIMACIÓN TEMPRANA DEL RENDIMIENTO DE LA CEBADA MEDIANTE USO DE SENSORES REMOTOS*. Chapingo, México: Terra Latinoamericana, 23(2), 167-174. Obtenido de: <https://www.redalyc.org/articulo.oa?id=57323203>

- Sudduth, K.A., Kitchen, N.R., Bollero, G.A., Bullock, D.G., Wiebold, W.J. (2003). *COMPARISON OF ELECTROMAGNETIC INDUCTION AND DIRECT SENSING OF SOIL ELECTRICAL CONDUCTIVITY*. Agronomy Journal, 95: 472–482. Obtenido de: <https://doi.org/10.2134/agronj2003.4720>
- Sudduth, K.A., Kitchen, N.R., Wiebold, W.J., Batchelor, W.D., Bollero, G.A., Bullock, D.G., Clay, D.E., Palm, H.L., Pierce, F.J., Schuler, R.T., Thelen, K.D. (2005). *RELATING APPARENT ELECTRICAL CONDUCTIVITY TO SOIL PROPERTIES ACROSS THE NORTH-CENTRAL USA*. Computers and Electronics in Agriculture, 46: 263–283. Obtenido de: <https://doi.org/10.1016/j.compag.2004.11.010>
- UDL. (17 de Octubre de 2018). *EQUIPOS DE LOS QUE DISPONE EL GRAP*. Obtenido de: <http://www.grap.udl.cat/es/equipamiento/material.html>.
- Uribeetxebarria, A., Arnó, J., Escolà, A., Martínez-Casasnovas, J.A. (2018a). *APPARENT ELECTRICAL CONDUCTIVITY AND MULTIVARIATE ANALYSIS OF SOIL PROPERTIES TO ASSESS SOIL CONSTRAINTS IN ORCHARDS AFFECTED BY PREVIOUS PARCELLING*. Geoderma, 319:185–193. Obtenido de: <https://doi.org/10.1016/j.geoderma.2018.01.008>

ANEJO I:

CÁLCULOS ESTADÍSTICOS COMPLEMENTARIOS

ZONA (CEa)	PARÁMETROS		ARENA		CC (0,3 bar)		PMP (15 bar)		CRAD		CIC		NDVI	
			Estadístico	Error estándar	Estadístico	Error estándar	Estadístico	Error estándar	Estadístico	Error estándar	Estadístico	Error estándar	Estadístico	Error estándar
1	Media		42,6286	2,36288	27,86	1,370	14,14	0,634	13,71	0,837	5,9429	0,31837	0,58714	0,012289
	95% de intervalo	Límite	36,8468		24,50		12,59		11,67		5,1638		0,55707	
		Límite	48,4103		31,21		15,69		15,76		6,7219		0,61721	
	Media recortada al		42,6651		28,06		14,21		13,74		5,9143		0,58738	
	Mediana		41,1000		29,00		15,00		14,00		5,7000		0,60000	
	Varianza		39,082		13,143		2,810		4,905		0,710		0,001	
	Desviación estándar		6,25159		3,625		1,676		2,215		0,84233		0,032514	
	Mínimo		34,30		21		11		10		5,00		0,550	
	Máximo		50,30		31		16		17		7,40		0,620	
	Rango		16,00		10		5		7		2,40		0,070	
	Rango intercuartil		12,90		6		2		3		1,30		0,070	
	Asimetría		-0,119	0,794	-1,367	0,794	-1,201	0,794	-0,400	0,794	1,048	0,794	-0,254	0,794
	Curtosis		-1,697	1,587	1,294	1,587	1,268	1,587	0,774	1,587	0,090	1,587	-2,485	1,587
	2	Media		38,5300	3,30505	28,40	0,933	14,80	0,573	13,60	0,718	6,5200	0,55414	0,64200
95% de intervalo		Límite	31,0535		26,29		13,50		11,98		5,2665		0,61592	
		Límite	46,0065		30,51		16,10		15,22		7,7735		0,66808	
Media recortada al			39,3778		28,44		14,78		13,61		6,3944		0,64111	
Mediana			42,5500		28,50		15,00		13,00		5,8000		0,63500	
Varianza			109,233		8,711		3,289		5,156		3,071		0,001	
Desviación estándar			10,45148		2,951		1,814		2,271		1,75233		0,036454	
Mínimo			14,50		24		12		10		4,90		0,600	
Máximo			47,30		32		18		17		10,40		0,700	
Rango			32,80		8		6		7		5,50		0,100	
Rango intercuartil			15,13		5		3		4		2,05		0,068	
Asimetría			-1,598	0,687	-0,328	0,687	-0,190	0,687	0,122	0,687	1,478	0,687	0,402	0,687
Curtosis			2,238	1,334	-1,044	1,334	0,349	1,334	-1,123	1,334	1,662	1,334	-1,265	1,334
3		Media		21,7000	3,62132	29,13	0,934	15,63	0,680	13,50	0,463	9,2250	0,56687	0,68000
	95% de intervalo	Límite	13,1369		26,92		14,02		12,41		7,8846		0,65766	
		Límite	30,2631		31,33		17,23		14,59		10,5654		0,70234	
	Media recortada al		21,7667		29,19		15,69		13,44		9,3444		0,67944	
	Mediana		21,8500		29,50		16,00		13,50		9,8500		0,68000	
	Varianza		104,911		6,982		3,696		1,714		2,571		0,001	
	Desviación estándar		10,24263		2,642		1,923		1,309		1,60334		0,026726	
	Mínimo		2,80		24		12		12		5,70		0,650	
	Máximo		39,40		33		18		16		10,60		0,720	
	Rango		36,60		9		6		4		4,90		0,070	
	Rango intercuartil		8,43		3		3		2		1,80		0,052	
	Asimetría		-0,214	0,752	-0,737	0,752	-0,897	0,752	0,764	0,752	-1,842	0,752	0,299	0,752
	Curtosis		2,170	1,481	1,655	1,481	0,590	1,481	0,875	1,481	3,479	1,481	-1,419	1,481
	4	Media		23,4375	6,22913	29,25	0,701	16,75	0,366	12,50	0,926	10,0875	0,47937	0,69375
95% de intervalo		Límite	8,7079		27,59		15,88		10,31		8,9540		0,66772	
		Límite	38,1671		30,91		17,62		14,69		11,2210		0,71978	
Media recortada al			21,7083		29,22		16,78		12,50		10,1139		0,69250	
Mediana			16,8500		29,00		17,00		12,00		10,7000		0,68000	
Varianza			310,417		3,929		1,071		6,857		1,838		0,001	
Desviación estándar			17,61865		1,982		1,035		2,619		1,35587		0,031139	
Mínimo			12,20		27		15		9		8,10		0,660	
Máximo			65,80		32		18		16		11,60		0,750	
Rango			53,60		5		3		7		3,50		0,090	
Rango intercuartil			9,55		4		2		5		2,50		0,050	
Asimetría			2,527	0,752	0,422	0,752	-0,386	0,752	0,095	0,752	-0,698	0,752	1,049	0,752
Curtosis			6,677	1,481	-1,159	1,481	-0,448	1,481	-1,783	1,481	-1,264	1,481	0,009	1,481
5		Media		13,8556	1,87299	29,44	0,626	16,56	0,242	12,89	0,716	10,8222	0,27627	0,71000
	95% de intervalo	Límite	9,5364		28,00		16,00		11,24		10,1851		0,69281	
		Límite	18,1747		30,89		17,11		14,54		11,4593		0,72719	
	Media recortada al		14,2117		29,44		16,51		12,88		10,7636		0,71000	
	Mediana		14,3000		29,00		16,00		12,00		10,5000		0,71000	
	Varianza		31,573		3,528		0,528		4,611		0,687		0,001	
	Desviación estándar		5,61897		1,878		0,726		2,147		0,82882		0,022361	
	Mínimo		0,60		27		16		10		9,90		0,670	
	Máximo		20,70		32		18		16		12,80		0,750	
	Rango		20,10		5		2		6		2,90		0,080	
	Rango intercuartil		4,60		4		1		4		0,60		0,025	
	Asimetría		-1,746	0,717	0,329	0,717	1,014	0,717	0,184	0,717	1,894	0,717	-0,086	0,717
	Curtosis		4,400	1,400	-1,557	1,400	0,185	1,400	-1,658	1,400	4,586	1,400	1,129	1,400

2- PRUEBA DE NORMALIDAD DE KOLMOGOROV-SMIRNOV

Tabla A. 2: Resultado de la prueba de normalidad de Kolmogorov-Smirnov. Fuente: elaboración propia.

	CEa (0-90 cm)	CEa (0-30 cm)	CElab	E.G	pH	M.O	CaCO3	ARCILLA	LIMO	ARENA	CC	PMP	CRAD	CIC	NDVI
N	42	42	42	42	42	42	42	42	42	42	42	42	42	42	42
Parámetros normales ^o	Media 20,3945 Desv. Desviación 18,17068	21,3260 14,90977	2,1598 0,48935	4,2424 6,47219	7,836 0,0850	1,7026 0,50961	35,2743 8,20753	29,3524 16,03758	42,7952 7,61013	27,8452 15,03482	28,83 2,594	15,60 1,740	13,24 2,105	8,5405 2,34812	0,66452 0,05143
Máximas diferencias extremas	Absoluto 0,164 Positivo 0,147 Negativo -0,164	0,171 0,171 -0,138	0,351 0,220 -0,351	0,256 0,236 -0,256	0,275 0,177 -0,275	0,175 0,175 -0,172	0,197 0,160 -0,197	0,162 0,153 -0,162	0,152 0,152 -0,133	0,135 0,135 -0,119	0,136 0,087 -0,136	0,187 0,098 -0,187	0,127 0,127 -0,118	0,180 0,149 -0,180	0,114 0,069 -0,114
Estadístico de prueba	0,164	0,171	0,351	0,256	0,275	0,175	0,197	0,162	0,152	0,135	0,136	0,187	0,127	0,180	0,114
Sig. asintótica(bilateral)	,006°	,003°	,000°	,000°	,000°	,002°	,000°	,007°	,016°	,052°	,049°	,001°	,088°	,001°	,198°

3- ESTUDIO DE CORRELACIÓN LINEAL

Tabla A. 4: Resultados del análisis de correlación lineal respecto a la CEa profunda. Fuente: elaboración propia.

	CEa (0-90 cm)	CE (extr 1:5 H2O)	E.G	pH	M.O	CaCO3	ARCILLA	LIMO	ARENA	CC	PMP	CRAD	CIC	NDVI
CEa (0-90 cm) Coeficiente de correlación de Spearman	1,000	-0,475	-0,81	0,49	0,665	0,671	0,778	-0,535	-0,732	0,093	0,613	-0,221	0,801	0,805
Sig. (bilateral)		0,001	0,000	0,001	0,000	0,000	0,000	0,000	0,000	-	0,000	-	0,000	0,000
CE (extr 1:5 H2O) Coeficiente de correlación de Spearman		1,000	0,304	-0,547	-0,438	-0,418	-0,519	0,432	0,555	-0,184	-0,341	0,007	-0,564	-0,507
Sig. (bilateral)			-	0,000	0,004	0,006	0,000	0,004	0,000	-	0,027	-	0,000	0,001
E.G Coeficiente de correlación de Spearman			1,000	-0,240	-0,661	-0,67	-0,672	0,411	0,631	-0,363	-0,564	-0,080	-0,734	-0,55
Sig. (bilateral)				-	0,000	0,000	0,000	0,007	0,000	0,018	0,000	-	0,000	0,000
pH Coeficiente de correlación de Spearman				1,000	0,394	0,355	0,633	-0,64	-0,487	-0,315	0,201	-0,425	0,572	0,629
Sig. (bilateral)					0,010	0,021	0,000	0,000	0,001	0,042	-	0,005	0,000	0,000
M.O Coeficiente de correlación de Spearman					1,000	0,797	0,721	-0,348	-0,708	0,291	0,643	-0,035	0,906	0,682
Sig. (bilateral)						0,000	0,000	0,024	0,000	-	0,000	-	0,000	0,000
CaCO3 Coeficiente de correlación de Spearman						1,000	0,765	-0,198	-0,843	0,225	0,574	-0,088	0,787	0,64
Sig. (bilateral)							0,000	-	0,000	-	0,000	-	0,000	0,000
ARCILLA Coeficiente de correlación de Spearman							1,000	-0,605	-0,915	-0,005	0,555	-0,298	0,876	0,771
Sig. (bilateral)								0,000	0,000	-	0,000	-	0,000	0,000
LIMO Coeficiente de correlación de Spearman								1,000	0,324	0,043	-0,262	0,194	-0,528	-0,442
Sig. (bilateral)									0,037	-	-	-	0,000	0,003
ARENA Coeficiente de correlación de Spearman									1,000	-0,046	-0,577	0,261	-0,833	-0,747
Sig. (bilateral)										-	0,000	-	0,000	0,000
CC Coeficiente de correlación de Spearman										1,000	0,303	0,841	0,157	-0,108
Sig. (bilateral)											-	0,000	-	-
PMP Coeficiente de correlación de Spearman											1,000	-0,236	0,667	0,495
Sig. (bilateral)												-	0,000	0,001
CRAD Coeficiente de correlación de Spearman												1,000	-0,196	-0,375
Sig. (bilateral)													-	0,014
CIC Coeficiente de correlación de Spearman													1,000	0,793
Sig. (bilateral)														0,000
NDVI Coeficiente de correlación de Spearman														1,000
Sig. (bilateral)														

Tabla A. 5: Resultado del análisis de correlación lineal respecto a la CEa superficial. Fuente: elaboración propia.

		CEa (0-30 cm)	CE (extr 1:5 H2O)	E.G	pH	M.O	CaCO3	ARCILLA	LIMO	ARENA	CC	PMP	CRAD	CIC	NDVI
CEa (0-30 cm)	Coefficiente de correlación de Spearman	1,000	-0,307	-0,72	0,290	0,64	0,598	0,665	-0,442	-0,629	0,207	0,638	-0,116	0,724	0,652
	Sig. (bilateral)		0,048	0,000	-	0,000	0,000	0,000	0,003	0,000	-	0,000	-	0,000	0,000
CE (extr 1:5 H2O)	Coefficiente de correlación de Spearman		1,000	0,304	-0,547	-0,438	-0,418	-0,519	0,432	0,555	-0,184	-0,341	0,007	-0,564	-0,507
	Sig. (bilateral)			-	0,000	0,004	0,006	0,000	0,004	0,000	-	0,027	-	0,000	0,001
E.G	Coefficiente de correlación de Spearman			1,000	-0,240	-0,661	-0,67	-0,672	0,411	0,631	-0,363	-0,564	-0,080	-0,734	-0,55
	Sig. (bilateral)				-	0,000	0,000	0,000	0,007	0,000	0,018	0,000	-	0,000	0,000
pH	Coefficiente de correlación de Spearman				1,000	0,394	0,355	0,633	-0,64	-0,487	-0,315	0,201	-0,425	0,572	0,629
	Sig. (bilateral)					0,010	0,021	0,000	0,000	0,001	0,042	-	0,005	0,000	0,000
M.O	Coefficiente de correlación de Spearman					1,000	0,797	0,721	-0,348	-0,708	0,291	0,643	-0,035	0,906	0,682
	Sig. (bilateral)						0,000	0,000	0,024	0,000	-	0,000	-	0,000	0,000
CaCO3	Coefficiente de correlación de Spearman						1,000	0,765	-0,198	-0,843	0,225	0,574	-0,088	0,787	0,64
	Sig. (bilateral)							0,000	-	0,000	-	0,000	-	0,000	0,000
ARCILLA	Coefficiente de correlación de Spearman							1,000	-0,605	-0,915	-0,005	0,555	-0,298	0,876	0,771
	Sig. (bilateral)								0,000	0,000	-	0,000	-	0,000	0,000
LIMO	Coefficiente de correlación de Spearman								1,000	0,324	0,043	-0,262	0,194	-0,528	-0,442
	Sig. (bilateral)									0,037	-	-	-	0,000	0,003
ARENA	Coefficiente de correlación de Spearman									1,000	-0,046	-0,577	0,261	-0,833	-0,747
	Sig. (bilateral)										-	0,000	-	0,000	0,000
CC	Coefficiente de correlación de Spearman										1,000	0,303	0,841	0,157	-0,108
	Sig. (bilateral)											-	0,000	-	-
PMP	Coefficiente de correlación de Spearman											1,000	-0,236	0,667	0,495
	Sig. (bilateral)												-	0,000	0,001
CRAD	Coefficiente de correlación de Spearman												1,000	-0,196	-0,375
	Sig. (bilateral)													-	0,014
CIC	Coefficiente de correlación de Spearman													1,000	0,793
	Sig. (bilateral)														0,000
NDVI	Coefficiente de correlación de Spearman														1,000
	Sig. (bilateral)														

4- ANOVA DE KRUSKAL-WALLIS

Tabla A. 6: Resultado de la prueba de ANOVA de Kruskal-Wallis. Fuente: elaboración propia.

Resumen de contrastes de hipótesis				
	Hipótesis nula	Prueba	Sig.	Decisión
1	La distribución de CELab es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,034	Rechace la hipótesis nula.
2	La distribución de E.G es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.
3	La distribución de pH es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,028	Rechace la hipótesis nula.
4	La distribución de M.O es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.
5	La distribución de CaCO3 es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.
6	La distribución de ARCILLA es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.
7	La distribución de LIMO es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,001	Rechace la hipótesis nula.
8	La distribución de ARENA es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.
9	La distribución de CC es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,941	Conserve la hipótesis nula.
10	La distribución de PMP es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,004	Rechace la hipótesis nula.
11	La distribución de CRA es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,793	Conserve la hipótesis nula.
12	La distribución de CIC es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.
13	La distribución de NDVI es la misma entre categorías de ZONA.	Prueba de Kruskal-Wallis para muestras independientes	0,000	Rechace la hipótesis nula.

Se muestran significaciones asintóticas. El nivel de significación es de ,050.

Tabla A. 8: Clasificación zonas CEa profunda en función de su valor. Fuente: elaboración propia.

ZONA CEa	VALOR CEa (mS/m)
1	0 – 5
2	5 – 10
3	10 – 20
4	20 – 30
5	30 - 160

Tabla A. 9: Resultado de la prueba ANOVA de Kruskal-Wallis para la CE (extr 1:5). Fuente: elaboración propia.

KRUSKAL-WALLIS (CE (extr 1:5 H20))					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
5-4	6,438	5,615	1,147	0,252	1,000
5-1	12,643	5,823	2,171	0,030	0,299
5-3	13,688	5,615	2,438	0,015	0,148
5-2	14,950	5,309	2,816	0,005	0,049
4-1	6,205	5,980	1,038	0,299	1,000
4-3	7,250	5,778	1,255	0,210	1,000
4-2	8,513	5,481	1,553	0,120	1,000
1-3	-1,045	5,980	-0,175	0,861	1,000
1-2	-2,307	5,695	-0,405	0,685	1,000
3-2	1,263	5,481	0,230	0,818	1,000

Tabla A. 10: Resultado de la prueba ANOVA de Kruskal-Wallis para el % EG. Fuente: elaboración propia.

KRUSKAL-WALLIS (E.G)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
5-4	2,847	5,932	0,480	0,631	1,000
5-3	9,972	5,932	1,681	0,093	0,927
5-2	20,722	5,609	3,694	0,000	0,002
5-1	26,079	6,152	4,239	0,000	0,000
4-3	7,125	6,104	1,167	0,243	1,000
4-2	17,875	5,791	3,087	0,002	0,020
4-1	23,232	6,318	3,677	0,000	0,002
3-2	10,750	5,791	1,856	0,063	0,634
3-1	16,107	6,318	2,549	0,011	0,108
2-1	5,357	6,016	0,890	0,373	1,000

Tabla A. 11: Resultado de la prueba ANOVA de Kruskal-Wallis para el pH. Fuente: elaboración propia.

KRUSKAL-WALLIS (pH)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
2-3	-0,413	5,432	-0,076	0,939	1,000
2-1	1,421	5,643	0,252	0,801	1,000
2-4	-7,038	5,432	-1,296	0,195	1,000
2-5	-14,906	5,261	-2,833	0,005	0,046
3-1	1,009	5,926	0,170	0,865	1,000
3-4	-6,625	5,725	-1,157	0,247	1,000
3-5	-14,493	5,564	-2,605	0,009	0,092
1-4	-5,616	5,926	-0,948	0,343	1,000
1-5	-13,484	5,771	-2,337	0,019	0,195
4-5	-7,868	5,564	-1,414	0,157	1,000

Tabla A. 12: Resultado de la prueba ANOVA de Kruskal-Wallis para el % MO. Fuente: elaboración propia.

KRUSKAL-WALLIS (M.O)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
1-2	-3,686	6,044	-0,610	0,542	1,000
1-4	-19,536	6,347	-3,078	0,002	0,021
1-3	-19,598	6,347	-3,088	0,002	0,020
1-5	-20,786	6,181	-3,363	0,001	0,008
2-4	-15,850	5,817	-2,725	0,006	0,064
2-3	-15,913	5,817	-2,735	0,006	0,062
2-5	-17,100	5,635	-3,035	0,002	0,024
4-3	0,063	6,132	0,010	0,992	1,000
4-5	-1,250	5,959	-0,210	0,834	1,000
3-5	-1,188	5,959	-0,199	0,842	1,000

Tabla A. 13: Resultado de la prueba ANOVA de Kruskal-Wallis para el CaCO₃. Fuente: elaboración propia.

KRUSKAL-WALLIS (CaCO₃)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
1-2	-3,871	6,046	-0,640	0,522	1,000
1-4	-16,446	6,349	-2,590	0,010	0,096
1-5	-21,905	6,182	-3,543	0,000	0,004
1-3	-22,696	6,349	-3,575	0,000	0,004
2-4	-12,575	5,819	-2,161	0,031	0,307
2-5	-18,033	5,637	-3,199	0,001	0,014
2-3	-18,825	5,819	-3,235	0,001	0,012
4-5	-5,458	5,961	-0,916	0,360	1,000
4-3	6,250	6,134	1,019	0,308	1,000
5-3	0,792	5,961	0,133	0,894	1,000

Tabla A. 14: Resultado de la prueba ANOVA de Kruskal-Wallis para el % Arcilla. Fuente: elaboración propia.

KRUSKAL-WALLIS (ARCILLA)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
1-2	-2,800	6,044	-0,463	0,643	1,000
1-3	-11,500	6,347	-1,812	0,070	0,700
1-4	-20,313	6,347	-3,200	0,001	0,014
1-5	-24,611	6,181	-3,982	0,000	0,001
2-3	-8,700	5,817	-1,495	0,135	1,000
2-4	-17,513	5,817	-3,010	0,003	0,026
2-5	-21,811	5,635	-3,871	0,000	0,001
3-4	-8,813	6,132	-1,437	0,151	1,000
3-5	-13,111	5,959	-2,200	0,028	0,278
4-5	-4,299	5,959	-0,721	0,471	1,000

Tabla A. 15: Resultado de la prueba ANOVA de Kruskal-Wallis para el % Limo. Fuente: elaboración propia

KRUSKAL-WALLIS (LIMO)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
5-4	1,042	5,955	0,175	0,861	1,000
5-1	12,952	6,176	2,097	0,036	0,360
5-2	17,317	5,631	3,076	0,002	0,021
5-3	19,354	5,955	3,250	0,001	0,012
4-1	11,911	6,342	1,878	0,060	0,604
4-2	16,275	5,813	2,800	0,005	0,051
4-3	18,313	6,127	2,989	0,003	0,028
1-2	-4,364	6,039	-0,723	0,470	1,000
1-3	-6,402	6,342	-1,009	0,313	1,000
2-3	-2,038	5,813	-0,351	0,726	1,000

Tabla A. 16: Resultado de la prueba ANOVA de Kruskal-Wallis para el % Arena. Fuente: elaboración propia

KRUSKAL-WALLIS (ARENA)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
5-4	7,326	5,960	1,229	0,219	1,000
5-3	9,389	5,960	1,575	0,115	1,000
5-2	21,339	5,635	3,787	0,000	0,002
5-1	24,746	6,181	4,004	0,000	0,001
4-3	2,063	6,132	0,336	0,737	1,000
4-2	14,013	5,818	2,409	0,016	0,160
4-1	17,420	6,348	2,744	0,006	0,061
3-2	11,950	5,818	2,054	0,040	0,400
3-1	15,357	6,348	2,419	0,016	0,155
2-1	3,407	6,044	0,564	0,573	1,000

Tabla A. 17: Resultado de la prueba ANOVA de Kruskal-Wallis para el % PMP. Fuente: elaboración propia

KRUSKAL-WALLIS (PMP)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
1-2	-4,414	5,917	-0,746	0,456	1,000
1-3	-11,339	6,215	-1,825	0,068	0,681
1-5	-17,881	6,051	-2,955	0,003	0,031
1-4	-19,277	6,215	-3,102	0,002	0,019
2-3	-6,925	5,696	-1,216	0,224	1,000
2-5	-13,467	5,517	-2,441	0,015	0,147
2-4	-14,863	5,696	-2,609	0,009	0,091
3-5	-6,542	5,835	-1,121	0,262	1,000
3-4	-7,938	6,004	-1,322	0,186	1,000
5-4	1,396	5,835	0,239	0,811	1,000

Tabla A. 18: Resultado de la prueba ANOVA de Kruskal-Wallis para la CIC. Fuente: elaboración propia

KRUSKAL-WALLIS (CIC)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
1-2	-1,764	6,026	-0,293	0,770	1,000
1-3	-13,964	6,328	-2,207	0,027	0,273
1-4	-20,777	6,328	-3,283	0,001	0,010
1-5	-24,159	6,162	-3,921	0,000	0,001
2-3	-12,200	5,800	-2,103	0,035	0,354
2-4	-19,013	5,800	-3,278	0,001	0,010
2-5	-22,394	5,618	-3,986	0,000	0,001
3-4	-6,813	6,114	-1,114	0,265	1,000
3-5	-10,194	5,942	-1,716	0,086	0,862
4-5	-3,382	5,942	-0,569	0,569	1,000

Tabla A. 19: Resultado de la prueba ANOVA de Kruskal-Wallis para el NDVI. Fuente: elaboración propia

KRUSKAL-WALLIS (NDVI)					
Sample 1- Sample 2	Estadístico de prueba	Desv. Error	Desv. Estadístico de prueba	Sig.	Sig. ajustada ^a
1-2	-9,350	6,031	-1,550	0,121	1,000
1-3	-18,625	6,334	-2,940	0,003	0,033
1-4	-22,250	6,334	-3,513	0,000	0,004
1-5	-27,944	6,168	-4,531	0,000	0,000
2-3	-9,275	5,805	-1,598	0,110	1,000
2-4	-12,900	5,805	-2,222	0,026	0,263
2-5	-18,594	5,623	-3,307	0,001	0,009
3-4	-3,625	6,119	-0,592	0,554	1,000
3-5	-9,319	5,947	-1,567	0,117	1,000
4-5	-5,694	5,947	-0,958	0,338	1,000

5- MODELADO ESTADÍSTICO. MODELO DE REGRESIÓN LINEAL SIMPLE




Figura A. 1: Diagrama de dispersión de la CE (extr 1:5) en función de la CEa. Fuente: elaboración propia.




Figura A. 2: Diagrama de dispersión del % EG en función de la CEa. Fuente: elaboración propia.




Figura A. 3: Diagrama de dispersión del pH en función de la CEa. Fuente: elaboración propia.




Figura A. 4: Diagrama de dispersión del % MO en función de la CEa. Fuente: elaboración propia.




Figura A. 5: Diagrama de dispersión del CaCO3 en función de la CEa. Fuente: elaboración propia.




Figura A. 6: Diagrama de dispersión del % Arcilla en función de la CEa. Fuente: elaboración propia.




Figura A. 7: Diagrama de dispersión del % Limo en función de la CEa. Fuente: elaboración propia.




Figura A. 8: Diagrama de dispersión del % Arena en función de la CEa. Fuente: elaboración propia.




Figura A. 9: Diagrama de dispersión del % CC en función de la CEa. Fuente: elaboración propia.




Figura A. 10: Diagrama de dispersión del % PMP en función de la CEa. Fuente: elaboración propia.




Figura A. 11: Diagrama de dispersión del % CRAD en función de la CEa. Fuente: elaboración propia.




Figura A. 12: Diagrama de dispersión de la CIC en función de la CEa. Fuente: elaboración propia.




Figura A. 13: Diagrama de dispersión del NDVI en función de la CEa. Fuente: elaboración propia.

6- MODELO DE REGRESIÓN LINEAL MÚLTIPLE PREDICTIVO

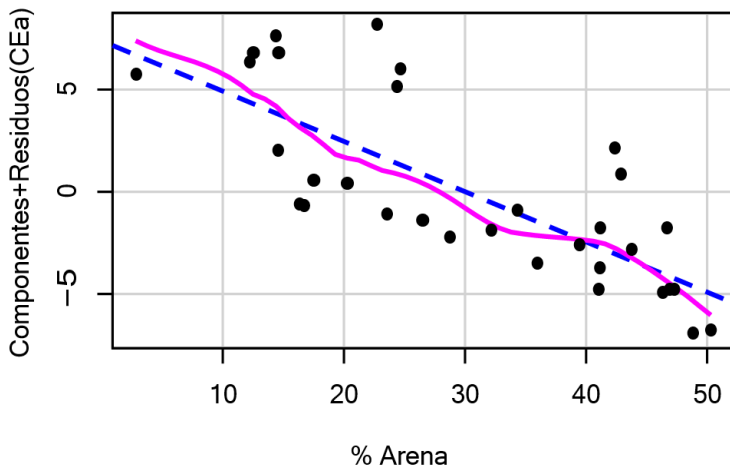


Figura A. 14: Gráfica de componentes + residuos para el % Arena en el primer modelo predictivo. Fuente: elaboración propia.




Figura A. 15: Gráfica de componentes + residuos para la CIC en el primer modelo predictivo. Fuente: elaboración propia.




Figura A. 16: Gráfica de componentes + residuos para el % Limo en el primer modelo predictivo. Fuente: elaboración propia.




Figura A. 17: Gráfica de componentes + residuos para el % MO en el primer modelo predictivo. Fuente: elaboración propia.

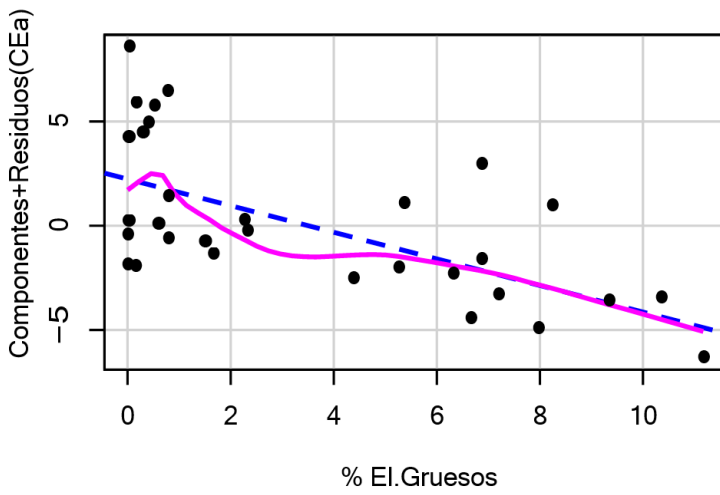


Figura A. 18: Gráfica de componentes + residuos para el % EG en el primer modelo predictivo. Fuente: elaboración propia.

6.1- VALIDACIÓN MODELO PREDICTIVO




Figura A. 19: Gráfica de componentes + residuos para el % Arena en el segundo modelo predictivo. Fuente: elaboración propia.




Figura A. 20: Gráfica de componentes + residuos para la CIC en el segundo modelo predictivo. Fuente: elaboración propia.




Figura A. 21: Gráfica de componentes + residuos para el % Limo en el segundo modelo predictivo. Fuente: elaboración propia.




Figura A. 22: Gráfica de componentes + residuos para el % MO en el segundo modelo predictivo. Fuente: elaboración propia.