AXENCIA GALEGA DA CALIDADE ALIMENTARIA

Proyecto piloto de optimización de la fertilización del viñedo

FERTISOST

(AC-2021-01)

INFORME FINAL

Noviembre 2023

Indice

1 INTRODUCCIÓN 3

2 OBJETIVOS DEL PROYECTO 6

3 METODOLOGÍA 6

3.1 Establecimiento de niveles de referencia para la fertilización 6

3.2 Estudio de la microbiota en suelos 9

3.3 Aplicación Aplicación Web-GIS - FERTISOST 11

3.3.1. Recopilación de datos 11

3.3.2. Aplicación Web-GIS - FERTISOST 14

3.3.3. Metodología Deep Learning 15

4 RESULTADOS 23

4.1 Establecimiento de niveles de referencia para la fertilización 23

4.2 Estudio de la microbiota en suelos 46

4.3 Aplicación Web-GIS - FERTISOST 56

5 ACTIVIDADES DE DIVULGACIÓN 67

6 REFERENCIAS BIBLIOGRÁFICAS 69

1 INTRODUCCIÓN

La obtención de una cosecha de calidad viene determinada fundamentalmente por la consecución de un equilibrio vegetativo-productivo de las plantas, en el cual influyen numerosos factores, siendo uno de los más importantes su estado nutricional. Las necesidades en nutrientes de las plantas en el viñedo varían en función de su estado fenológico, edad, técnicas de cultivo empleadas y el tipo de cultivar. Una correcta fertilización del viñedo supone la aplicación de fertilizantes en el momento oportuno y en función de las condiciones edafoclimáticas de la parcela. Ello requiere conocer la demanda de nutrientes de los cultivos, el momento de aportar los fertilizantes y los parámetros exógenos que influyen en su correcta asimilación.

El principal sistema de abonado de la viña en Galicia es la aplicación de abono orgánico y/o químico en profundidad o en superficie, así como a través de la fertirrigación en los viñedos de mayor extensión. La implantación de cubierta vegetal también se está imponiendo como método de mantenimiento de suelo, que permite además la incorporación de materia orgánica vegetal. En muchos casos los abonados se aplican por tradición, y en otros, cuando se cuenta con mayor profesionalización, se aplican en base a los resultados de analíticas de suelo, con recomendaciones basadas en patrones genéricos establecidos para regiones vitivinícolas muy diferentes a las de la región gallega, y que no tienen en cuenta la demanda real de la planta. Las analíticas de suelo indican la disponibilidad de nutrientes, pero no siempre son indicativas de que éstos se encuentren en la planta a un nivel óptimo. En este sentido, diferentes estudios han mostrado que el diagnóstico foliar permite conocer el nivel de nutrientes dentro de la planta y detectar carencias y desequilibrios nutricionales de una manera más fiable que mediante las analíticas de suelo.

La absorción de nutrientes en la vid se produce mayoritariamente entre la brotación y el envero. En el periodo de floración y envero es cuando se produce la mayor demanda de nitrógeno, fósforo, calcio y magnesio por los racimos, posteriormente se reduce en gran medida. Sin embargo, el potasio se acumula de forma importante en el racimo en la etapa de maduración. Las bayas se abastecen de este catión a través de las reservas almacenadas en los brotes y las hojas durante el crecimiento, y/o a través de la absorción del suelo. La incorrecta aplicación de abonados acarrea, además de un desequilibrio en la producción, contaminaciones medioambientales, que incluyen niveles de nitratos y fosfatos, o la presencia en los suelos de metales pesados, que por escorrentía e infiltración terminan por contaminar

los cauces de agua. El exceso de nitrógeno aumenta el vigor y eleva el rendimiento, conduciendo a un deterioro del microclima de hojas y racimos, dificultando la maduración de la uva y potenciando el desarrollo de la podredumbre del racimo; además puede llevar aparejado el riesgo de carencia de potasio, una mayor necesidad de agua, la presencia en vinos de compuestos perjudiciales para la salud, riesgos de contaminación de acuíferos y la emisión de gases de efecto invernadero. Defectos de abonado nitrogenado determinan problemas para la alimentación de las levaduras fermentativas por carencia de nitrógeno fácilmente asimilable en el mosto. El nitrógeno, en cantidad y en calidad suficientes, participa en la formación de aromas positivos, limitando la formación de compuestos de olores desagradables, sobre todo de ciertos compuestos azufrados. Un exceso de fertilización potásica, asociado a otros factores relacionados con su absorción por la planta, influye en la obtención de vinos poco ácidos y con pH elevado, con el consiguiente descenso en la calidad y problemas de conservación, problema muy en auge hoy en día. La carencia de magnesio disminuye el rendimiento y la síntesis de azúcares, y puede provocar desecamiento del raspón.

Recientemente se está poniendo de manifiesto la importancia del estudio de las comunidades microbianas presentes en los viñedos, ya que juegan un papel importante en la productividad del suelo y en la resistencia de la planta a enfermedades. Además, pueden afectar a los procesos fermentativos y de crianza del vino. La riqueza y diversidad de estas comunidades depende del lugar geográfico, manejo agronómico, aspectos edáficos y el cultivar, entre otros parámetros.

A pesar de la importancia de una correcta fertilización, hasta hace poco tiempo no existía ninguna aplicación en Galicia que indicara a los viticultores cual era la fertilización más adecuada para sus viñedos en función del lugar geográfico y la variedad, resultante del conocimiento previo de las necesidades reales de las plantas.En el marco de un proyecto previo (FERVIÑA), se llevó a cabo en las D.O. Rías Baixas y Ribeiro el establecimiento de los niveles de referencia para hacer un diagnóstico nutricional y establecer patrones de abonado para la correcta fertilización de sus variedades emblemáticas (Albariño y Treixadura), desarrollando una aplicación para la fertilización sostenible del viñedo en esas zonas, resultante del conocimiento previo de las necesidades reales de las plantas. Para ello se establecieron los niveles de referencia de nutrientes para una correcta fertilización a través del establecimiento de correlaciones entre las características físico-químicas de los suelos de viñedo, el análisis de macro y micronutrientes en las hojas, así como las técnicas de cultivo desarrolladas en las parcelas, junto con el

análisis de parámetros de calidad de la uva. Esto redundó en una reducción de fertilizantes y la mejora de las producciones.

En el presente proyecto piloto se ha desarrollado un trabajo similar en las D.O. Valdeorras, Monterrei y Ribeira Sacra. La D.O. Ribeira Sacra es una zona de producción vinícola con una extensión de 2500 ha de viñedo, con dos zonas de claro contraste: el valle del Miño, con una pluviometría de 900 mm anuales, temperatura media de 14ºC y suelos arenosos y limosos, frescos y permeables; y los valles del Sil, con 700 mm de pluviometría, una temperatura media de 13 ºC y abundancia de arcillas. La D.O. Valdeorras tiene una extensión de 1300 ha de viñedo, pluviometría anual entre 850 y 1000 mm, temperatura media de 11ºC, y suelos variados. La D.O. Monterrei tiene una superficie de 691 ha, una pluviometría anual de 680 mm, grandes oscilaciones térmicas en vendimia, y suelos diversos. En las tres D.O. sus variedades insignia son el Godello en blancas y la Mencía en tintas.

Para establecer los niveles de referencia para el diagnóstico nutricional de las variedades emblemáticas de estas D.O. se han realizado analíticas en suelo, hoja y mosto cuyos datos han sido utilizados como base de datos a partir de la cual se alimenta una aplicación web, que permitirá a los viticultores la evaluación del estado de sus suelos y, en consecuencia, proceder a una fertilización más racional del viñedo. Para ello se ha contado con los siguientes participantes:

- Axencia Galega da Calidade Alimentaria, a través de la Estación de Viticultura e Enoloxía de Galicia (EVEGA-AGACAL) como coordinadora del proyecto, participando además en la recogida de muestras, su análisis y el establecimiento de niveles de referencia de fertilización para cada D.O.

- Universidad de Santiago de Compostela (Departamentos de Ingeniería Agroforestal y de Algoritmos y Modelización Geoespacial), como cooperante, con experiencia en nutrición del viñedo y aplicaciones geoinformáticas, para desarrollar una aplicación que permita incorporar los resultados obtenidos.

- Bodegas colaboradoras de las D.O. Valdeorras (Bodegas Godeval S.L. y Terriña S.L.), Monterrei (Martín Codax S.C. -Terras do Cigarrón- y Gargalo S.L.) y Ribeira Sacra (Bodegas Regina Viarum S.L., Ponte da Boga S.L., Vía Romana S.L. y Currio-Trasmonte). Han colaborado en la selección de parcelas, proporcionado información y permitido la toma de muestras en los viñedos.

2 OBJETIVOS DEL PROYECTO

El objetivo fundamental del proyecto fue la puesta en marcha de un sistema de control integrado de la gestión de la fertilización en la viticultura para las variedades insignia (Mencía y Godello) de las DO Ribeira Sacra, Valdeorras y Monterrei. Para ello es necesario:

1. Establecer protocolos en base a la interrelación suelo-clima planta a partir de niveles de referencia de la fertilidad del suelo, y de los macro y micronutrientes en la planta y de los parámetros de calidad del mosto

2. Testar los resultados en función de las campañas

3. Ofrecer herramientas TIC y transferencia de conocimiento informando y formando al colectivo de viticultores y otros profesionales en el empleo sostenible de abonados, con la finalidad de disminuir el impacto negativo de la actividad vitivinícola

3 METODOLOGÍA

3.1 Establecimiento de niveles de referencia para la fertilización

La metodología que se ha seguido para el establecimiento de los niveles de referencia para el diagnóstico nutricional de los viñedos de cada D.O. ha sido la siguiente:

- Selección de un número mínimo de parcelas en cada D.O. que por sus características productivas y la calidad de sus cosechas son representativas del manejo cultural y la calidad de los mostos buscada. Se priorizó además el incluir la mayor variabilidad posible en cuanto a técnicas de cultivo y localización (fondo de valle, ladera, secano, regadío, presencia o no de cubierta, pendiente o llano). En cada parcela se establecieron bloques de un mínimo de 20 plantas cada uno. En concreto, se marcaron 30 parcelas en la D.O. Ribeira Sacra, 23 en la D.O. Valdeorras y 14 en la D.O. Monterrei. Las bodegas colaboradoras en cada zona/subzona fueron las siguientes (Figura 1):

D.O. Valdeorras: Godeval y Terriña.

D.O. Monterrei: Martín Códax y Gargalo.

D.O. Ribeira Sacra: Ponte da Boga (Ribeiras do Sil), Currio-Trasmonte (Quiroga-Bibei), Vía Romana (Chantada) y Regina Viarum (Amandi).

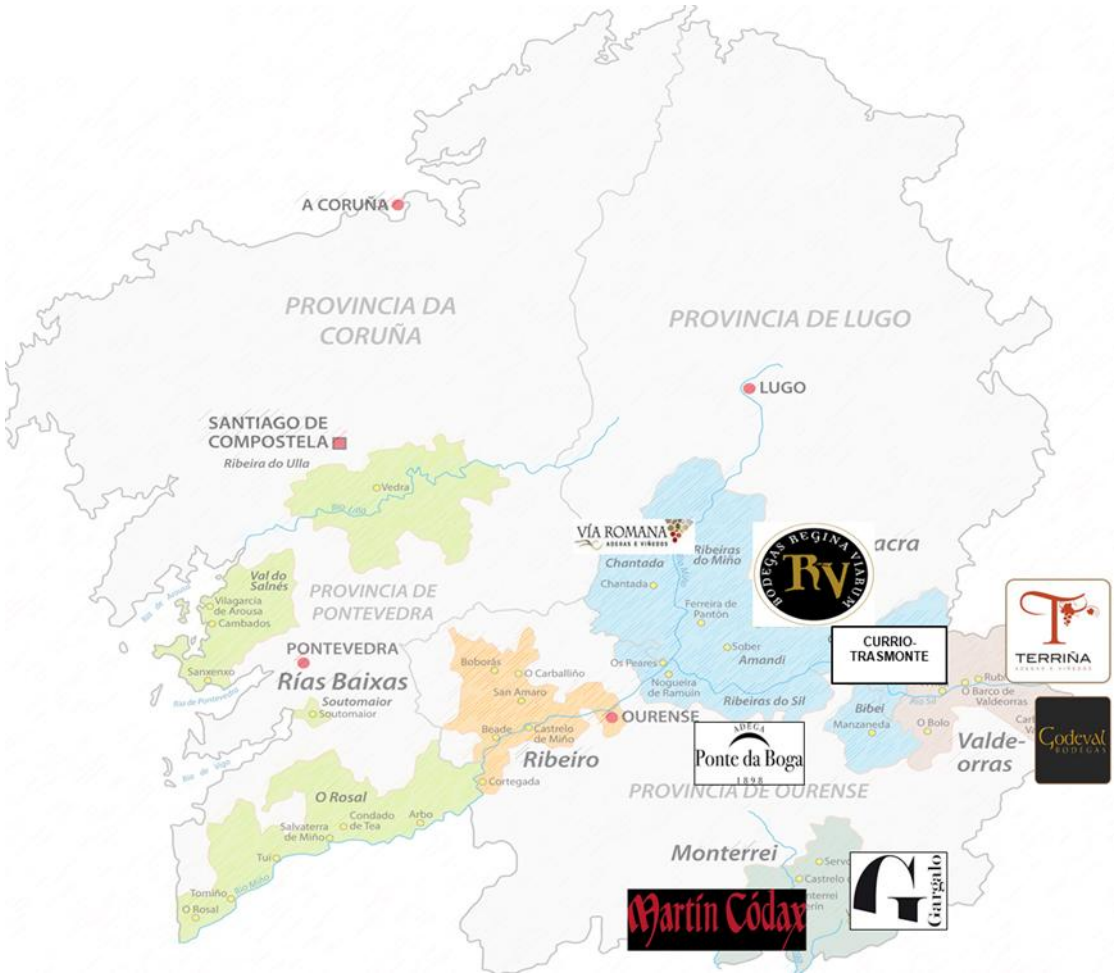

Figura 1. Bodegas colaboradoras en cada Denominación de Origen.

Se realizó un seguimiento del cultivo en cada parcela mediante la toma de los siguientes datos:

- <u>Parámetros agronómicos</u>: Carga de yemas en poda. Número de racimos, producción de uva, peso de uva y racimo y peso de madera de poda.

- Analíticas de suelo para fertilidad en cada bloque/parcela, para lo cual se tomaron muestras en los primeros 20 cm del perfil de suelo que se enviaron a un laboratorio especializado para su análisis. Los parámetros analizados fueron los siguientes: pH, Materia orgánica, Carbono (C), Nitrógeno (N), Fósforo disponible (P), Potasio asimilable (K), Magnesio cambiable (Mg), Calcio (Ca), Sodio, Capacidad efectiva de intercambio catiónico (CiCe). Se calcularon las relaciones C/N, Ca/Mg, K/Mg, Ca:Mg:K.

- Muestras de peciolos y limbo en envero, para lo que se recogieron hojas en cada bloque/parcela para el análisis de macro y micronutrientes. En peciolo se analizaron: Boro (B), Calcio (Ca), Cobre (Cu), Fósforo (P), Magnesio (Mg), Manganeso (Mn), Potasio (K), Sodio (Na), Zinc (Zn), Nitrógeno (N), Hierro (Fe). En limbo, los anteriores excepto Sodio y Nitrógeno.

- Parámetros enológicos básicos en vendimia: pH, Acidez total, Ácido málico, Ácido tartárico, Ácido glucónico, Nitrógeno amínico, Nitrógeno amoniacal, Grado alcohólico probable. Se calcularon las relaciones Nitrógeno total y Grado alcohólico probable/Acidez total. Además, el equipo de la USC ha realizado el análisis elemental de mostos congelados de las tres D.O. en los años 2021 y 2022. Los análisis han sido realizados en la Unidad de Análisis Instrumental de la RIAIDT-USC en el Campus de Lugo. se analizaron en mosto los siguientes elementos: Aluminio, Boro, Calcio, Cobre, Hierro, Potasio, Magnesio, Manganeso, Sodio, Fósforo, Zinc.

- Se recogieron datos climatológicos en las estaciones de Meteogalicia próximas a las zonas de viñedo para correlacionar dichos datos con los datos agronómicos y enológicos. Las estaciones seleccionadas fueron Vilamartín (Valdeorras), Verín Vilela (Monterrei), Ponte Boga Castro Caldelas (Ribeiras do Sil), San Clodio Ribas do Sil (Quiroga-Bibei), Xabrega Sober (Amandi) y San Fiz (Chantada).

Teniendo en cuenta todos los resultados obtenidos, se han establecido niveles de referencia para el diagnóstico nutricional. Estos resultados han permitido crear una aplicación TIC, que podrá ser incorporada en la gestión del viñedo, inicialmente aplicable a las fincas colaboradoras, y que a posteriori podrá ser transferida e implementada como una herramienta en la gestión de viñedos al sector en general. La aplicación se caracteriza por su fácil manejo por los usuarios, y permitirá controlar las variables que proporcionen información para una fertilización sostenible del viñedo.

3.2 Estudio de la microbiota en suelos

El muestreo de suelos para extracción de ADN microbiano (fúngico y bacteriano) se correspondió con los puntos de muestreo para análisis de fertilidad. Se recogieron muestras a los 5 cm y 10 cm de profundidad, en la calle, que se congelaron inmediatamente a -80º C hasta su procesado. Por otra parte, también se recogieron muestras de la rizosfera y de la raíz de las plantas que estaban situadas en los mismos puntos de muestreo de suelo, para posteriores análisis. Si bien en el marco de este proyecto nos hemos centrado en los muestreos realizados en la calle para poder compararlos a posteriori con los de fertilidad del suelo, se realizaron extracciones de ADN y análisis metagenómico de muestras de uva en vendimia con la finalidad de poder evaluar en posteriores estudios la correlación de la microbiota del suelo con la presente en las bayas, que supera las expectativas de este proyecto.

- Procesado de ADN, análisis metagenómico y análisis bioinformático

1. Extracción y cuantificación de ADN

La extracción de ADN se realizó por separado para los distintos puntos muestreados. Para ello se utilizó el kit Power Soil de Quiagen siguiendo estrictamente las directrices del fabricante. El ADN se eluyó en un volumen final de 50 µL de tampón de elución. Una vez extraído y determinada su calidad, se mezclan en una misma muestra el ADN de los 5 puntos de muestreo de cada bloque, obteniendo un total de 3 muestras de ADN de cada parcela, lo mismo que en el muestreo realizado para la fertilidad del suelo.

Se cuantificó la concentración de ADN en cada extracto utilizando el ensayo Qubit High Sensitivity dsDNA Assay (Thermo Fisher Scientific).

2. Preparación de la biblioteca de ADN y secuenciación

Se construyó un tipo de biblioteca diferente para cada taxón de interés con los siguientes pares de cebadores y condiciones:

Para la preparación de la biblioteca bacteriana, se amplificó un fragmento del gen 16S rRNA (región V4) de unos 300 pb utilizando los siguientes cebadores:

Forward - 515F-Y (5' GTG YCA GCM GCC GCG GTA A 3') (Parada, Needham y Fuhrman 2016)

Reverse - 806R (5' GGA CTA CNV GGG TWT CTA AT 3') (Apprill et al. 2015)

Las secuencias de cebadores de secuenciación de Illumina se unieron a estos cebadores en sus extremos 5'.

En el primer paso de amplificación, la PCR se llevó a cabo en un volumen final de 12,5 µL, que contenía 1,25 µL de ADN molde, 0,5 µM de los cebadores, 3,13 µL de Supreme NZYTaq 2x Green Master Mix (NZYTech) y agua ultrapura hasta 12,5 µL. La mezcla de reacción se incubó de la siguiente manera: un paso de desnaturalización inicial a 95 ºC durante 5 min, seguido de 25 ciclos de 95 ºC durante 30 s, 47 ºC durante 45 s, 72 ºC durante 45 s, y un paso de extensión final a 72 ºC durante 7 min.

Para la preparación de la biblioteca de hongos, se amplificó un fragmento de la región ITS2 de unos 300 pb utilizando los siguientes cebadores:

Forward - ITS86F (5' GTG AAT CAT CGA ATC TTT GAA 3') (Turenne et al. 1999)

Reverse - ITS4R (5' TCC TCC GCT TAT TGA TAT GC 3') (White et al. 1990)

Las secuencias de cebadores de secuenciación de Illumina se unieron a estos cebadores en sus extremos 5'.

En el primer paso de amplificación, la PCR se llevó a cabo en un volumen final de 12,5 µL, que contenía 1,25 µL de ADN molde, 0,5 µM de los cebadores, 3,13 µL de Supreme NZYTaq 2x Green Master Mix (NZYTech) y agua ultrapura hasta 12,5 µL. La mezcla de reacción se incubó de la siguiente manera: un paso de desnaturalización inicial a 95 ºC durante 5 min, seguido de 30 ciclos de 95 ºC durante 30 s, 49 ºC durante 45 s, 72 ºC durante 45 s, y un paso de extensión final a 72 ºC durante 7 min.

Los índices de oligonucleótidos necesarios para multiplexar diferentes bibliotecas en el mismo pool de secuenciación se unieron en un segundo paso de amplificación con idénticas condiciones, pero sólo 5 ciclos y 60 ºC. Una visión general esquemática del proceso de preparación de bibliotecas se puede ver en la Figura 1 en Vierna et al. (2017).

Se incluyó un control negativo que no contenía ADN (BPCR) en cada ronda de PCR para comprobar si había contaminación durante la preparación de la biblioteca.

Se verificó el tamaño de las bibliotecas ejecutando las bibliotecas en geles de agarosa al 2 % teñidos con GreenSafe (NZYTech) y obteniendo imágenes bajo luz UV. A continuación, purificamos las bibliotecas utilizando las perlas magnéticas Mag-Bind RXNPure Plus (Omega Biotek), siguiendo las instrucciones proporcionadas por el fabricante.

Las bibliotecas terminadas se agruparon en cantidades equimolares de acuerdo con los resultados de una cuantificación Qubit dsDNA HS Assay (Thermo Fisher Scientific).

El pool se secuenció en una fracción de una celda de flujo NovaSeq PE250 (Illumina) con el objetivo de obtener una producción total de 16 Gigabases.

3. Análisis bioinformático

El análisis bioinformático consistió en la determinación de la abundancia, cálculo de alfa-diversidad (Índice de Chao e índice de Shanon) y beta-diversidad. Análisis discriminante para determinación de patrones de diversidad y análisis de componentes para relacionar fertilidad y diversidad microbiana, para lo que se utilizó la aplicación estadística XLSTAT.

3.3 Aplicación Aplicación Web-GIS - FERTISOST

3.3.1. Recopilación de datos

Toda la información ha sido estructurada en plantillas de introducción de datos, que faciliten la incorporación en la aplicación WebGIS.

La estructura de los campos introducidos en la plantilla de introducción de datos se resume en las siguientes tablas:

Datos relativos al Suelo:

	-	cmol/kg						mg Kg-1	%				-	%			-	mg Kg-1		-
Muestra	pH (H2O)	Ca	Mg	Na	K	Al	CICe	% Sat. Al	P olsen	Carbono	M.O	Nitrogeno	C/N	Arena	Limo	Arcilla	pH KCl-su	K mg/Kg-su	Mg mg/Kg-su	Ca:Mg:K-su

Datos relativos al análisis foliar:

Muestra	Repetición	Boro (B) mg/kg	Calcio (Ca) g/100g	Cobre (Cu) mg/kg	Fosforo (P) g/100g	Magnesio (Mg) g/100g	Manganeso (Mn) mg/kg	Potasio (k) g/100g	Sodio (Na) mg/kg	Zinc (Zn) mg/kg	Nitrogeno total (N) g/100g	Hierro (Fe) mg/kg

Datos relativos a mostos:

Muestra	Ref. Mostra	Repetición	Fecha	ACIDEZ (g/L Ac. Tart.)	Ác. Málico (g/L)	Ác. Tartárico(g/L)	Calcio (mg/L)	Cobre (mg/L)	Magnesio (mg/L)	Nitrógeno Amínico(mg/L)	Nitrógeno Amoniacal (mg/L)	Nitrógeno total	pH	Potasio (mg/L)	º Brix	:. Glucónico-u	GP %v/v	GP/AT

Por otra parte, el equipo de la USC, ha llevado a cabo la generación de la cartografía de base de las parcelas de estudio. Para ello se ha recibido información de AGACAL (EVEGA) de las referencias catastrales en las que se ha realizado la toma de muestras de suelo y uva, así como fichas esquemáticas de la subdivisión interna de las parcelas para obtener una, dos o tres submuestras por parcela de estudio, según el caso.

Esta información ha sido procesada partiendo de la capa del parcelario de catastro empleando el software QGis (v. 3.28.5).

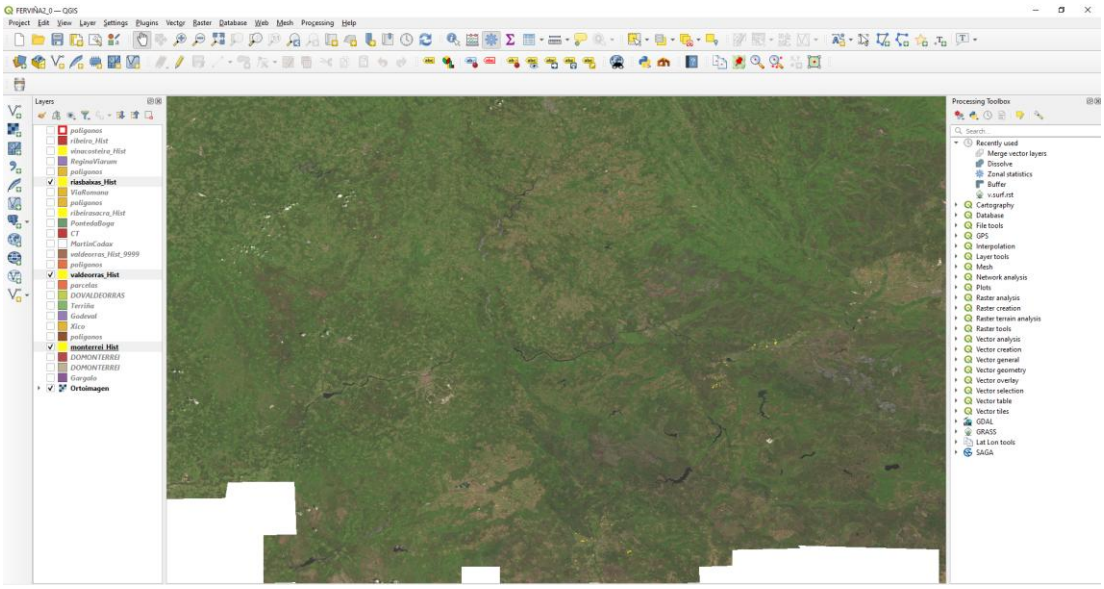

Una vez generada la cartografía con las divisiones requeridas en cada caso, se ha procedido a la codificación de cada elemento de tal forma que se corresponda de forma unívoca con el código de parcela y zona interna recogida en la plantilla de introducción de datos alfanuméricos.

Destacar que la información incorporada en cada una de las tres DOs procede de diferentes bodegas/propietarios:

- DO Ribeira Sacra: Via Romana, Regina Viarum, CT, Ponte da Boga
- DO Monterrei: Martin Codax, Gargalo, Xico
- DO Valdeorras: Terriña, Godeval

Este aspecto ha generado la opción de poder separar la información por Bodega/Viticultor en cada una de las plataformas, o bien mantener la información de forma integral para cada una de la DOs. Tras un análisis al respecto, se llegó a la conclusión de que todos los datos de cada DO estarían disponibles para las bodegas que han participado en el proyecto. Este aspecto debe ser analizado en detalle a futuro, puesto que el acceso de forma individualizada a FERTISOST a priori parece que animára a las bodegas a introducir más datos, al ser estos tratados de forma privada.

A pesar de que a futuro se realice está modificación de la aplicación, el modulo de fertilización y de predicción de requerimientos nutricionales debe de partir del análisis del conjunto de datos de cada DO, para incrementar la base de datos de estudio, facilitando la aplicación de técnicas de Deep learning, las cuales requieren de una gran cantidad de datos para que sean de utilidad.

3.3.2. Aplicación Web-GIS - FERTISOST

La herramienta web se desarrolló utilizando las siguientes tecnologías: HTML/CSS, Python y Javascript:

- HTML (Lenguaje de Marcado de Hipertexto) y CSS (Cascading Style Sheets) son dos tecnologías fundamentales para la construcción de páginas web. Ambas desempeñan roles específicos en la presentación y estructura de un sitio web. HTML es el lenguaje de marcado utilizado para definir la estructura y el contenido de una página web. Utiliza etiquetas para describir diferentes elementos en la página, como encabezados, párrafos, imágenes, enlaces, formularios, etc. CSS, por otro lado, es un lenguaje de estilos que se utiliza para definir la apariencia y el formato de los elementos HTML en una página web. Permite separar la presentación del contenido, facilitando así el mantenimiento y la consistencia visual.
- JavaScript es un lenguaje de programación de alto nivel, interpretado y orientado a objetos, ampliamente utilizado para desarrollar aplicaciones web interactivas. Es una parte fundamental de

la triada tecnológica junto con HTML y CSS que permite crear y manejar contenido dinámico en los navegadores web. JavaScript tiene la capacidad de interactuar con el DOM (Document Object Model) de una página web, permitiendo modificar elementos HTML, responder a eventos del usuario y actualizar contenido sin necesidad de recargar la página. Además, con JavaScript, se pueden realizar llamadas asíncronas al servidor y trabajar con datos en formato JSON. En este proyecto utilizamos, además, Leaflet, que es una biblioteca de JavaScript de código abierto que se utiliza para crear mapas interactivos en línea. Es especialmente popular por su sencillez y facilidad de uso, permitiendo incorporar mapas interactivos en sitios web de manera adecuada y eficiente.

- El lenguaje de programación Python es un lenguaje interpretado, orientado a objetos y de alto nivel. Fue creado por el programador Guido van Rossum y su filosofía de diseño prioriza la legibilidad del código, facilitando la comprensión y mantenimiento del mismo. Una de las características que hizo que seleccionáramos este lenguaje para este proyecto es su amplia biblioteca estándar, que incluye módulos y paquetes para realizar tareas comunes, como manipulación de archivos, acceso a bases de datos, análisis de datos, creación de interfaces gráficas y mucho más. Una de las bibliotecas empleadas en Python es TensorFlow, junto con otras bibliotecas (Keras, Tensorflow.js, NumPy, Pandas y Scikit-Learn). TensorFlow es una biblioteca de código abierto de aprendizaje profundo desarrollada por Google. Es especialmente conocida por su potencial en el campo del aprendizaje profundo y la construcción de modelos de inteligencia artificial. TensorFlow proporciona una infraestructura flexible y escalable para la creación y entrenamiento de modelos de aprendizaje profundo. En este proyecto, utilizamos TensorFlow para construir una red neuronal como modelo de aprendizaje profundo de manera eficiente.

3.3.3. Metodología Deep Learning

El carácter abierto de la herramienta (KNIME) hace posible su extensión mediante la creación de nuevos nodos que implementen algoritmos a la medida del usuario. Además, existe la posibilidad de utilizar de llamar directa y transparentemente a Weka y TensorFlow (plataforma Java de Inteligencia Artificial, desarrollado por la Universidad de Nueva Zelanda), o de incorporar de manera sencilla código desarrollado en R o python/jython.

Esto hace que el software KNIME se utilice en numerosos trabajos de investigación en los que se requiera la exploración y visualización de datos, el análisis de texto, la minería de datos, el aprendizaje automático y la analítica en general.

Antes de decantarnos por un algoritmo definitivo para la construcción del sistema inteligente, es esencial comprender los requisitos del problema, investigar los algoritmos disponibles y evaluar su rendimiento utilizando diversas métricas estadísticas. En este sentido, una primera fase del trabajo consistirá en la configuración de los diferentes algoritmos para su entrenamiento y ejecución con todos los datos disponibles.

A. Decission Tree. Utiliza la división recursiva basada en características para construir un árbol que divide el conjunto de datos en subconjuntos más pequeños y homogéneos. El árbol se utiliza posteriormente para hacer predicciones sobre nuevos datos siguiendo las ramas del árbol hasta llegar a una hoja que representa la clase predicha.

Este método es ampliamente empleado en el ámbito de la teledetección y, generalmente, contribuye a reducir los errores en las clasificaciones (Laliberte y Rango, 2009; Chuvieco, 1990). Es una técnica que ha ganado popularidad en diversos campos, como la agricultura de precisión, y los estudios forestales entre otros (de Castro, et al., 2020). También se ha aplicado en la identificación y clasificación de daños causados por terremotos (Li y Tang, 2020), así como en la clasificación de la cobertura vegetal mediante el enfoque basado en objetos (OBIA), considerando las texturas (Laliberte y Rango, 2009), por citar algunos ejemplos.

B. Random Forest. Es un modelo de aprendizaje automático supervisado que combina múltiples árboles de decisión para realizar predicciones (Colomina y Molina, 2014). Cada árbol individual se construye utilizando una muestra aleatoria de datos y características del conjunto de entrenamiento (Rodríguez-Galiano et al., 2012; Kleinberg, 1996).

Este método ha sido utilizado en diversos escenarios, como por ejemplo en la clasificación de imágenes provenientes de diferentes sensores de satélites, incluso para imágenes con resolución espacial moderada (DeFries y Chan, 2000). También ha sido empleado en el mapeo de coberturas vegetales en islas (Hamylton et al., 2019) y en el análisis de pavimentos (Reyes-Ortiz et al., 2019), por mencionar algunos ejemplos.

C. Gradient Boosted Trees. Es un método de aprendizaje automático que combina múltiples árboles de decisión débiles para crear un modelo más robusto y preciso. A diferencia del algoritmo anterior, donde los árboles se construyen de forma independiente, en Gradient Boosted Trees, los árboles se construyen secuencialmente, y cada nuevo árbol se ajusta en función de los errores del modelo anterior. El proceso comienza con la construcción de un árbol de decisión inicial, que se llama árbol base o árbol débil. Luego, se calculan los errores residuales entre las predicciones del árbol base y los valores reales del conjunto de entrenamiento. Estos errores residuales se utilizan para ajustar el siguiente árbol, que se agrega al modelo para corregir los errores del modelo anterior. Este proceso se repite iterativamente, construyendo y agregando árboles al modelo, hasta que se alcanza un criterio de parada, como un número máximo de árboles o cuando los errores se han reducido lo suficiente (Ye, 2009).

El algoritmo Gradient Boosted Trees es especialmente efectivo en problemas de regresión y clasificación, ya que puede manejar conjuntos de datos complejos y capturar relaciones no lineales entre variables predictoras y variables objetivo. También es resistente al sobreajuste y puede manejar datos faltantes.

D. Probabilistic Neural Network. Es un tipo de red neuronal basada en los principios de la teoría de probabilidad bayesiana y utiliza un enfoque no paramétrico para modelar los datos. Esta red neuronal consta de cuatro capas: una capa de entrada, una capa de patrones, una capa de sumación y una capa de salida. La capa de patrones almacena los patrones de entrenamiento, y la capa de sumación calcula la suma ponderada de los patrones de entrada en función de su similitud con los patrones almacenados. La capa de salida aplica una función softmax para producir una distribución de probabilidad sobre las posibles clases o valores.

E. Multilayer Perceptron. En este modelo las neuronas están organizadas en capas: una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona en una capa está conectada a todas las neuronas de la capa siguiente mediante conexiones ponderadas. Cada neurona realiza una función de activación no lineal en base a la suma ponderada de las salidas de las neuronas en la capa anterior.

A partir del algoritmo que mejor desempeño arroje en la fase anterior, se construirá un sistema inteligente que permita simular la producción anual de una parcela de viñedo, en base a diferentes configuraciones de abonado, partiendo de los requerimientos definidos a partir del algoritmo de nutrición implementado en la plataforma FERVIÑA, desarrollado por AGACAL y USC, en colaboración con Viña Costeira y Paco&Lola.

Con ese propósito, en primer lugar, se analizarán las variables a considerar en el sistema, para posteriormente construir el sistema y realizar su entrenamiento.

En la siguiente fase de este estudio se pretende desarrollar un sistema inteligente, basado en uno de los algoritmos: red neuronal perceptrón multicapa para predecir la producción anual de una parcela de viñedo. El resultado de esta fase será un sistema inteligente listo para poder realizar simulaciones en viñedo específico. En el ámbito de la informática, una máquina inteligente se refiere a un agente adaptable que puede percibir su entorno y llevar a cabo acciones que maximicen sus posibilidades de alcanzar algún objetivo o completar una tarea exitosamente (Poole, 2018). Sin embargo, el término inteligencia artificial (IA) es objeto de controversia y cuenta con diversas definiciones. En términos coloquiales, se aplica cuando una máquina imita las funciones cognitivas que los seres humanos asocian con la mente humana, y también se define como la capacidad de un sistema para interpretar datos externos de manera precisa, aprender de esos datos y utilizar ese conocimiento para realizar tareas y alcanzar metas específicas a través de la adaptación flexible (Kaplan y Haenlein, 2018).

En la actualidad, los sistemas de IA forman parte de la rutina en diversos campos como la economía, la medicina, la ingeniería, el transporte, las comunicaciones y la milicia, y se han utilizado en una amplia variedad de aplicaciones de software, incluyendo juegos de estrategia, procesamiento de imágenes, reconocimiento de escritura y mucho más.

La investigación sobre la aplicación de métodos de inteligencia artificial en la identificación y clasificación de coberturas, tanto naturales como humanas, continúa en aumento. Por ejemplo, se han utilizado redes neuronales convolucionales en imágenes de vehículos aéreos no tripulados (UAS) para clasificar la hierba en los cultivos (Veeranampalayam, et al., 2020). También se han empleado métodos como random forest (RF) y support vector machine (SVM) en la clasificación de cultivos utilizando imágenes

de RPAS (Kwak y Park, 2019). Además, el método de árboles de decisiones, conocido como Decision Tree, se utiliza ampliamente en diversas aplicaciones de teledetección.

Árbol de decisión

El enfoque conocido como Decision Tree es uno de los métodos más simples en su concepción (Chuvieco, 1990). Se trata de una técnica estadística no paramétrica que no se ve afectada por valores atípicos y correlaciones. Este método implica dividir los datos sucesivamente en subconjuntos hasta obtener clases cada vez más homogéneas (Laliberte y Rango, 2009).

El proceso involucra un análisis detallado de las respuestas espectrales de las clases y del conjunto de datos disponible. En términos simples, consiste en formular una serie de preguntas a cada píxel, cuya respuesta afirmativa o negativa guiará hacia nuevas preguntas, y así sucesivamente, hasta obtener la clase a la que pertenece. Es decir, se busca discriminar secuencialmente cada una de las categorías, basándose en las bandas espectrales que permitan una separación más clara del resto.

En la siguiente imagen se muestra un diagrama típico que ilustra cómo se desarrolla un árbol de decisiones. La clasificación de una variable se estima en función de respuestas booleanas a preguntas establecidas, lo que conduce a la asignación de una etiqueta final.

Este método es ampliamente empleado en el ámbito de la teledetección y, generalmente, contribuye a reducir los errores en las clasificaciones (Laliberte y Rango, 2009). Es una técnica que ha ganado popularidad en diversos campos, como la agricultura de precisión, y los estudios forestales entre otros. Por ejemplo, se ha utilizado para mapear de manera cartográfica los cultivos afectados por la presencia de Cynodon Dactylon (grama común) en viticultura, en un proyecto llevado a cabo por el Instituto de Agricultura Sostenible y la Universitat de Lleida (de Castro, et al., 2020). También se ha aplicado en la identificación y clasificación de daños causados por terremotos (Li y Tang, 2020), así como en la clasificación de la cobertura vegetal mediante el enfoque basado en objetos (OBIA), considerando las texturas (Laliberte y Rango, 2009), por citar algunos ejemplos.

Random Forest y Gradient Boosted Trees

El algoritmo de Bosques Aleatorios (RF), también conocido como Random Forest, es una técnica que combina múltiples árboles predictores, donde cada árbol depende de los valores de un vector aleatorio probado de forma independiente y con la misma distribución para cada uno (Colomina y Molina, 2014). Fue desarrollado por Leo Breinman y Adele Cuttler. La selección aleatoria de un subconjunto de atributos es un ejemplo del enfoque de Bosques Aleatorios, que es una forma de realizar la discriminación estocástica propuesta por Eugenio Kleinberg (Kleinberg, 1996).

El clasificador RF se compone de una combinación de clasificadores, donde cada clasificador contribuye con un voto único para asignar la clase más frecuente al vector de entrada (x). Esta expresión se define como:

La técnica del clasificador RF se caracteriza por aumentar la diversidad de los árboles, ya que cada árbol se desarrolla a partir de conjuntos de datos de entrenamiento diferentes obtenidos al reemplazar aleatoriamente el conjunto de datos original (Rodríguez-Galiano et al., 2012).

Los Bosques Aleatorios son una colección o conjunto de árboles de decisión individuales, donde cada árbol se genera utilizando muestras y subconjuntos distintos de los datos de entrenamiento (ESRI, 2019). El término "aleatorios" se refiere a que se clasifica la imagen múltiples veces utilizando una selección aleatoria de píxeles de entrenamiento, lo que resulta en la creación de numerosos árboles de decisión. Para tomar la decisión final, cada árbol contribuye con un peso o voto, y el proceso de toma de decisiones en cada nodo se optimiza mediante un enfoque aleatorio (Ilustración 29).

Es un algoritmo ampliamente aplicado en el ámbito de la teledetección, así como en el campo de la medicina, debido a su largo historial y probada efectividad como algoritmo de inteligencia artificial.

Este método ha sido utilizado en diversos escenarios, como por ejemplo en la clasificación de imágenes provenientes de diferentes sensores de satélites, incluso para imágenes con resolución espacial moderada (DeFries y Chan, 2000). También ha sido empleado en el mapeo de coberturas vegetales en islas (Hamylton et al., 2019) y en el análisis de pavimentos (Reyes-Ortiz, Mejia y Useche-Castelblanco, 2019), por mencionar algunos ejemplos.

El algoritmo Gradient Boosted Trees, también conocido como Gradient Boosting Machine (GBM), es un método de aprendizaje automático que combina múltiples árboles de decisión débiles para crear un

modelo más robusto y preciso. A diferencia de los algoritmos de Bagging como Random Forest, donde los árboles se construyen de forma independiente, en Gradient Boosted Trees, los árboles se construyen secuencialmente, y cada nuevo árbol se ajusta en función de los errores del modelo anterior.

El proceso comienza con la construcción de un árbol de decisión inicial, que se llama árbol base o árbol débil. Luego, se calculan los errores residuales entre las predicciones del árbol base y los valores reales del conjunto de entrenamiento. Estos errores residuales se utilizan para ajustar el siguiente árbol, que se agrega al modelo para corregir los errores del modelo anterior. Este proceso se repite iterativamente, construyendo y agregando árboles al modelo, hasta que se alcanza un criterio de parada, como un número máximo de árboles o cuando los errores se han reducido lo suficiente (Ye, 2009).

En cada iteración, se asigna un peso a cada instancia del conjunto de entrenamiento según la importancia del error residual asociado. Esto permite que el algoritmo se enfoque más en las instancias que se están clasificando incorrectamente. Además, cada nuevo árbol se ajusta en función de la información residual que queda después de las iteraciones anteriores, lo que ayuda a mejorar gradualmente la precisión del modelo.

El algoritmo Gradient Boosted Trees es especialmente efectivo en problemas de regresión y clasificación, ya que puede manejar conjuntos de datos complejos y capturar relaciones no lineales entre variables predictoras y variables objetivo. También es resistente al sobreajuste y puede manejar datos faltantes.

Artificial Neural Network

Las redes neuronales artificiales, buscan imitar el comportamiento del cerebro, el cual está constituido por neuronas que almacenan y procesan una gran cantidad de información. Estas redes permiten crear sistemas complejos utilizando elementos simples, con el objetivo de generar estructuras que simulan el funcionamiento cerebral (Mejia y Useche-Castelblanco, 2019).

Las redes neuronales multicapas (MPL) están compuestas por neuronas organizadas en capas interconectadas. Estas redes son capaces de imitar el comportamiento de cualquier sistema utilizando entradas y salidas conocidas, lo que les permite clasificar elementos o emular el funcionamiento de una estructura determinada (Hekayati y Rahimpour, 2017).

Por otro lado, las redes neuronales convolucionales (CNN) han sido ampliamente utilizadas en el análisis de imágenes, especialmente en tareas de clasificación y reconocimiento (Veeranampalayam et al., 2020). Estas redes se inspiran en el sistema de aprendizaje biológico y buscan extraer características distintivas de los elementos, tal como lo hacen los seres humanos con la vista. Las CNN son especialmente adecuadas para el procesamiento de imágenes debido a su capacidad para manejar grandes estructuras de datos (Reyes-Ortiz et al., 2019).

En el contexto de la clasificación de elementos en imágenes, la arquitectura más aplicada es la desarrollada por Rickmond Alake (Alake, 2020). Esta red está compuesta por múltiples capas, comenzando con una fase de extracción de características mediante neuronas convolucionales y de reducción. A medida que se avanza en la red, las dimensiones se reducen y se activan características cada vez más complejas. Finalmente, se utilizan neuronas sencillas para realizar la clasificación.

Planteamiento metodológico del sistema de inteligencia artificial

Antes de decantarnos por un algoritmo definitivo para la construcción del sistema inteligente, es esencial comprender los requisitos del problema, investigar los algoritmos disponibles y evaluar su rendimiento utilizando diversas métricas estadísticas.

En este sentido, esta una primera fase del trabajo consistirá en la configuración de los diferentes algoritmos anteriores para su entrenamiento y ejecución con todos los datos disponibles. A partir de ahí, evaluando diferentes estadísticos se realizará la selección de la arquitectura que se empleará en las fases posteriores de esta investigación.

Selección de variables a considerar y entrenamiento del sistema inteligente

A partir del algoritmo que mejor desempeño arroje en la fase anterior, se construirá un sistema inteligente que permita simular los efectos sobre la producción anual de una parcela de viñedo, con diferentes combinaciones de abonado.

Con ese propósito, en primer lugar, se analizarán las variables a considerar en el sistema, para posteriormente construir el sistema y realizar su entrenamiento.

En la siguiente fase de este estudio se pretende desarrollar un sistema inteligente, basado en uno de los algoritmos: la red neuronal perceptrón multicapa para simular los efectos del abonado sobre la producción anual de una parcela de viñedo.

4 RESULTADOS

4.1 Establecimiento de niveles de referencia para la fertilización

Las parcelas de Valdeorras y Monterrei estaban plantadas con la variedad Godello, y las de Ribeira Sacra con Mencía. En primer lugar, se establecieron las temperaturas medias y precipitación en los años de estudio durante el ciclo vegetativo a partir de los datos de las estaciones meteorológicas de Meteogalicia. En las Figuras 2 y 3 se pueden ver las temperaturas medias y precipitación de marzo a septiembre en las tres D.O. Comparando Monterrei y Valdeorras, ambas con Godello, se puede ver que las temperaturas medias en Valdeorras son superiores todos los años, y la precipitación bastante menor excepto en 2021. En Ribeira Sacra se observan diferencias entre las subzonas, presentando Chantada menor temperatura media y Quiroga-Bibei la mayor los tres años de estudio. Respecto a la precipitación, Quiroga-Bibei presentó la menor excepto en 2021 y Amandi presentó la mayor precipitación todos los años.

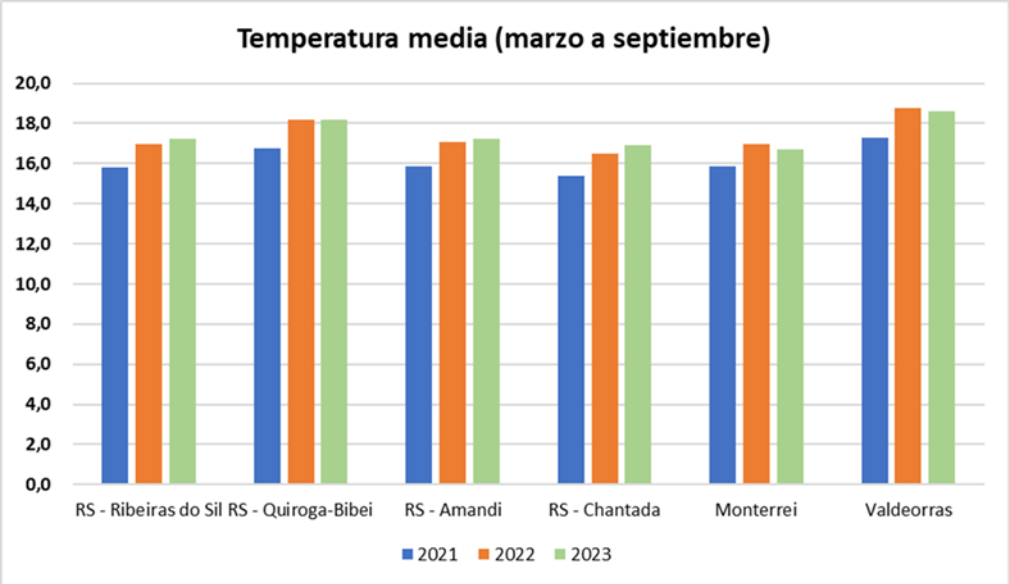

Figura 2. Temperatura media para las distintas D.O. y para las subzonas de Ribeira Sacra

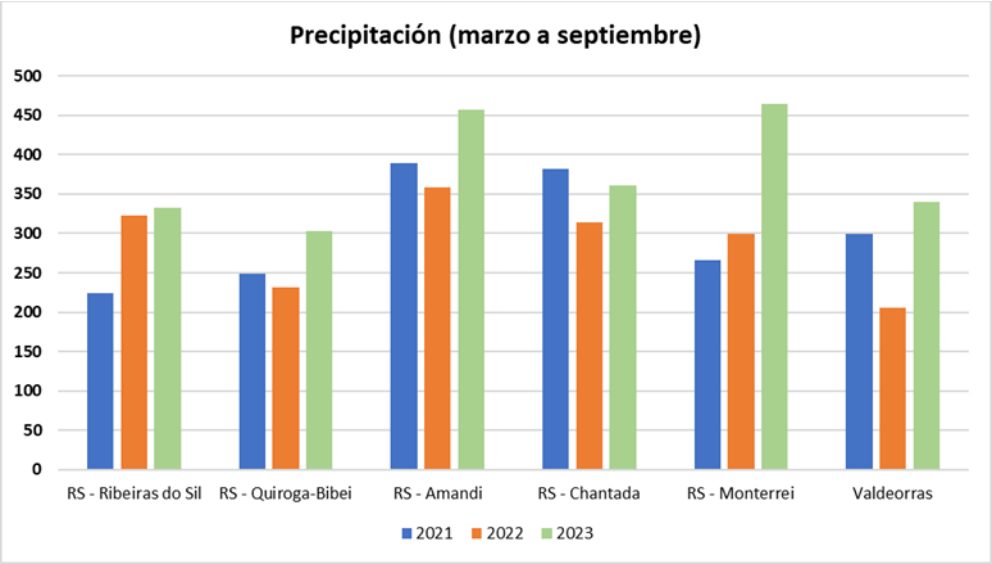

Figura 3. Precipitación para las distintas D.O. y para las subzonas de Ribeira Sacra

D.O. VALDEORRAS

En un primer screening, se observó la variabilidad existente en cada D.O. Los suelos promedio para los tres años de estudio de la D.O Valdeorras (Tabla 1) se caracterizaron por valores ligeramente ácidos de pH, y bajos de calcio y capacidad de intercambio catiónico. Algunas parcelas presentaron valores anormalmente altos de fósforo, potasio y magnesio, lo que indica un fuerte sobreabonado.

Tabla 1. Valores promedio de todos los años de análisis de suelo en la D.O. Valdeorras.

	VALORES PROMEDIO EN SUELOS DE LA D.O. VALDEORRAS													
	pH H2O	M.O (%)	C (%)	N (%)	C/N	Ca (cmol(+)/Kg)	Na (cmol(+)/Kg)	Al (cmol(+)/Kg)	CiCe (cmol(+)/Kg)	Ca/Mg	K/Mg	P (ppm)	K (ppm)	Mg (ppm)
Promedio	5,90	3,20	1,86	0,16	11,81	5,05	0,09	0,50	6,95	6,35	0,68	27	182	107
Máximo	7,90	6,12	3,55	0,41	19,21	19,00	0,24	2,20	21,01	20,00	3,06	127	528	376
Mínimo	4,60	1,18	0,68	0,06	6,91	0,30	0,03	0,10	2,41	2,00	0,15	2	60	10

En cuanto a las analíticas en peciolo y limbo, si se comparan los valores obtenidos con los citados en la Guía practica de la fertilización racional de los cultivos en España (https://www.mapa.gob.es/es/agricultura/publicaciones/Publicaciones-fertilizantes.aspx) podemos observar, en peciolo, valores altos de nitrógeno y fósforo, muy altos de manganeso, y bajos de calcio. En limbo hay valores bajos de calcio y magnesio, altos de potasio y muy altos de manganeso (Tablas 2 y 3).

Tabla 2. Valores promedio de todos los años del análisis de peciolo en la D.O. Valdeorras.

	Peciolo									
	Nitrógeno (%)	Fósforo (%)	Potasio (%)	Calcio (%)	Magnesio (%)	Hierro (ppm)	Boro (ppm)	Cobre (ppm)	Manganeso (ppm)	Zinc (ppm)
Media	0,60	0,19	1,89	1,63	0,87	20,26	28,18	61,99	468	62
Máximo	0,94	0,66	4,14	3,36	1,92	30,00	49,00	150,00	1271	168
Mínimo	0,45	0,06	0,48	0,91	0,26	10,00	18,00	3,00	36	21

Tabla 3. Valores promedio de todos los años del análisis de limbo en la D.O. Valdeorras.

	Limbo								
	Fósforo (%)	Potasio (%)	Calcio (%)	Magnesio (%)	Hierro (ppm)	Boro (ppm)	Cobre (ppm)	Manganeso (ppm)	Zinc (ppm)
Media	0,15	1,27	1,90	0,30	110	27,79	340	310	33
Máximo	0,20	1,97	3,46	0,64	309	55,00	776	597	147
Mínimo	0,11	0,67	0,85	0,10	0	18,00	4	48	12

Respecto a los mostos, presentaron en promedio un grado alcohólico probable adecuado y una acidez promedio ligeramente baja. En alguna parcela se obtuvieron datos muy altos de pH en mosto que dificultarán la obtención de un vino equilibrado (Tabla 4). Respecto a los elementos en mosto (Tabla 5), el potasio y magnesio se encuentran en mayor y el calcio en menor concentración con respecto a los valores reportados para el Godello en la D.O. Ribeiro por Freijido et al (2012).

Tabla 4. Valores promedio de todos los años de parámetros enológicos básicos de mosto en la D.O. Valdeorras.

MOSTOS DE LA D.O. VALDEORRAS									
	Grado alcohólico probable (%v/v)	Acidez total (g/l)	GP/AT	pH	Ác. Málico (g/l)	Ác. Tartárico (g/l)	Nitrógeno amínico (mg/l)	Nitrógeno Amoniacal (mg/l)	Nitrógeno total (mg/l)
Promedio	12,31	6,05	2,09	3,27	2,13	6,80	100	76	176
Máximo	14,55	10,00	3,17	3,74	6,20	8,56	236	149	323
Mínimo	8,74	3,80	0,87	2,87	0,80	4,80	24	2	27

Tabla 5. Valores promedio de todos los años de elementos de mostos en la D.O. Valdeorras.

	ELEMENTOS DEL MOSTO DE LA D.O. VALDEORRAS (mg/L)										
	Fósforo	Potasio	Calcio	Magnesio	Hierro	Boro	Cobre	Manganeso	Zinc	Aluminio	Sodio
Media	130	1594	53	64	0,04	1,35	1,47	1,24	0,43	0,04	3,06
Máximo	251	2096	93	103	0,24	4,74	3,73	7,22	1,47	0,12	6,22
Mínimo	59	822	31	39	0,01	0,11	0,25	0,12	0,24	0,02	1,49

Con los datos obtenidos, se hizo un análisis de correlaciones para cada año, con el fin de dilucidar qué parámetros tenían influencia significativa entre sí. En la Tabla 6 se puede ver la tabla de correlaciones completa para los parámetros de suelo y mosto de la D.O. Valdeorras en el año 2021.

Tabla 6. Correlaciones entre parámetros de suelo y mosto. Valdeorras. Año 2021

VALDEORRAS 2021 SUELO MOSTO

Variables	pH H2O-su	pH KCl-su	M.O. %-su	C %-su	N %-su	C/N-su	P mg/Kg-su	K mg/Kg-su	Mg mg/Kg-su	Ca cmol(+)/Kg-su	Mg cmol(+)/Kg-su	K cmol(+)/Kg-su	Na cmol(+)/Kg-su	Al cmol(+)/Kg-su	CiCe cmol(+)/Kg-su	Ca/Mg-su
pH H2O-su	1	0,871	0,103	0,103	0,176	-0,147	-0,104	0,144	0,466	0,699	0,466	0,144	0,124	-0,837	0,599	0,261
pH KCl-su	0,871	1	0,190	0,190	0,264	-0,206	-0,151	0,171	0,498	0,785	0,498	0,171	0,209	-0,870	0,685	0,261
M.O. %-su	0,103	0,190	1	1,000	0,660	-0,015	-0,065	0,007	0,152	0,290	0,152	0,007	0,272	-0,120	0,310	0,203
C %-su	0,103	0,190	1,000	1	0,660	-0,015	-0,065	0,007	0,152	0,290	0,152	0,007	0,272	-0,120	0,310	0,203
N %-su	0,176	0,264	0,660	0,660	1	-0,360	-0,035	0,145	0,328	0,354	0,328	0,145	0,397	-0,206	0,403	0,055
C/N-su	-0,147	-0,206	-0,015	-0,015	-0,360	1	0,034	-0,204	-0,301	-0,195	-0,301	-0,204	-0,330	0,225	-0,225	0,172
P mg/Kg-s	-0,104	-0,151	-0,065	-0,065	-0,035	0,034	1	0,301	-0,118	-0,118	-0,118	0,301	-0,134	0,176	-0,145	0,025
K mg/Kg-s	0,144	0,171	0,007	0,007	0,145	-0,204	0,301	1	0,374	0,237	0,374	1,000	0,274	-0,205	0,264	-0,192
Mg mg/Kg	0,466	0,498	0,152	0,152	0,328	-0,301	-0,118	0,374	1	0,550	1,000	0,374	0,467	-0,548	0,627	-0,209
Ca cmol(+	0,699	0,785	0,290	0,290	0,354	-0,195	-0,118	0,237	0,550	1	0,550	0,237	0,317	-0,753	0,861	0,275
Mg cmol(+	0,466	0,498	0,152	0,152	0,328	-0,301	-0,118	0,374	1,000	0,550	1	0,374	0,467	-0,548	0,627	-0,209
K cmol(+)/	0,144	0,171	0,007	0,007	0,145	-0,204	0,301	1,000	0,374	0,237	0,374	1	0,274	-0,205	0,264	-0,192
Na cmol(+	0,124	0,209	0,272	0,272	0,397	-0,330	-0,134	0,274	0,467	0,317	0,467	0,274	1	-0,226	0,377	-0,153
Al cmol(+	-0,837	-0,870	-0,120	-0,120	-0,206	0,225	0,176	-0,205	-0,548	-0,753	-0,548	-0,205	-0,226	1	-0,658	-0,207
CiCe cmol	0,599	0,685	0,310	0,310	0,403	-0,225	-0,145	0,264	0,627	0,861	0,627	0,264	0,377	-0,658	1	0,169
Ca/Mg-su	0,261	0,261	0,203	0,203	0,055	0,172	0,025	-0,192	-0,209	0,275	-0,209	-0,192	-0,153	-0,207	0,169	1
K/Mg-su	-0,424	-0,448	-0,141	-0,141	-0,227	0,194	0,414	0,137	-0,498	-0,432	-0,498	0,137	-0,287	0,462	-0,450	0,077
ACIDEZ-uv	-0,114	-0,136	0,028	0,028	0,031	-0,069	-0,037	-0,183	-0,120	-0,127	-0,120	-0,183	-0,098	0,172	-0,103	0,043
Ac. Glucón	0,042	0,027	-0,011	-0,011	-0,069	0,103	-0,088	0,011	-0,056	0,048	-0,056	0,011	-0,007	0,028	0,045	0,066
Ác. Málico	-0,056	-0,094	-0,047	-0,047	-0,044	0,053	0,102	-0,034	-0,164	-0,105	-0,164	-0,034	-0,294	0,149	-0,111	0,090
Ác. Tartár	0,013	0,084	0,158	0,158	0,212	-0,205	-0,134	-0,063	0,085	0,073	0,085	-0,063	0,152	-0,070	0,075	-0,036
GP %v/v	-0,035	0,046	0,144	0,144	0,111	0,008	-0,250	-0,062	0,071	0,050	0,071	-0,062	0,189	-0,065	0,055	-0,112
Nitrógeno	0,344	0,391	-0,078	-0,078	0,053	-0,149	-0,104	0,100	0,231	0,336	0,231	0,100	0,082	-0,400	0,287	0,073
Nitrógeno	0,329	0,352	-0,037	-0,037	0,082	-0,214	-0,187	-0,028	0,187	0,289	0,187	-0,028	0,080	-0,360	0,245	0,079
pH-uva	0,202	0,222	-0,085	-0,085	-0,034	-0,029	0,027	0,229	0,187	0,198	0,187	0,229	0,075	-0,257	0,154	-0,045
º Brix	-0,035	0,046	0,144	0,144	0,111	0,008	-0,250	-0,062	0,071	0,050	0,071	-0,062	0,189	-0,065	0,055	-0,112
GP/AT	0,067	0,110	0,041	0,041	0,018	0,043	-0,089	0,098	0,112	0,113	0,112	0,098	0,159	-0,148	0,104	-0,080
Nitrógeno	0,346	0,389	-0,060	-0,060	0,070	-0,195	-0,163	0,052	0,238	0,330	0,238	0,052	0,083	-0,402	0,285	0,072
em_Al	-0,281	-0,324	-0,121	-0,121	-0,140	0,050	0,114	-0,112	-0,333	-0,305	-0,333	-0,112	-0,147	0,335	-0,321	0,028
em_B	-0,021	-0,032	-0,187	-0,187	-0,122	-0,048	0,364	0,262	0,046	-0,005	0,046	0,262	-0,039	0,032	0,021	-0,043
em_Ca	-0,016	-0,093	-0,129	-0,129	-0,208	0,132	0,086	-0,091	-0,068	-0,090	-0,068	-0,091	-0,116	0,086	-0,052	-0,024
em_Cu	0,039	0,098	-0,037	-0,037	0,129	-0,363	-0,125	0,125	0,138	0,124	0,138	0,125	0,205	-0,135	0,093	-0,022
em_Fe	-0,233	-0,332	-0,199	-0,199	-0,207	0,126	0,287	-0,002	-0,162	-0,306	-0,162	-0,002	-0,114	0,334	-0,251	-0,115
em_k	-0,126	-0,091	-0,184	-0,184	-0,150	0,041	0,070	0,189	0,063	-0,063	0,063	0,189	0,101	0,074	-0,018	-0,191
em_Mg	-0,278	-0,386	-0,181	-0,181	-0,186	0,111	0,240	-0,036	-0,093	-0,360	-0,093	-0,036	-0,112	0,377	-0,287	-0,323
em_Mn	-0,406	-0,502	-0,257	-0,257	-0,325	0,207	0,255	-0,008	-0,330	-0,525	-0,330	-0,008	-0,175	0,459	-0,521	-0,218
em_Na	-0,104	-0,121	-0,020	-0,020	0,033	0,002	0,041	-0,082	0,010	-0,086	0,010	-0,082	0,035	0,130	-0,047	-0,093
em_P	-0,010	-0,011	-0,025	-0,025	0,020	-0,038	0,153	0,166	0,106	0,059	0,106	0,166	0,038	0,018	0,109	-0,063
em_Zn	-0,242	-0,306	-0,186	-0,186	-0,186	0,099	0,315	0,092	-0,186	-0,240	-0,186	0,092	-0,126	0,289	-0,206	-0,035
índice (1-5	0,261	0,157	-0,185	-0,185	-0,142	-0,025	0,286	0,081	0,052	0,132	0,052	0,081	-0,169	-0,161	0,117	0,238
Rega (0=N	0,294	0,323	0,231	0,231	0,158	0,094	-0,476	-0,339	0,139	0,206	0,139	-0,339	0,014	-0,312	0,189	0,045
Pdte (0=0-	-0,153	-0,096	0,168	0,168	0,069	0,114	-0,277	-0,209	-0,115	-0,057	-0,115	-0,209	0,048	0,128	-0,085	-0,079
Kg/ha	-0,002	-0,058	-0,191	-0,191	-0,157	-0,004	0,346	0,105	-0,112	-0,093	-0,112	0,105	-0,209	0,069	-0,085	0,110

Variables	K/Mg-su	ACIDEZ-uva	Ac. Glucónico-uva	Ác. Málico-uva	Ác. Tartárico-uva	GP %v/v	Nitrógeno Amínico	Nitrógeno amoniacal	pH-uva	º Brix	GP/AT	Nitrógeno total-uva
pH H2O-su	-0,424	-0,114	0,042	-0,056	0,013	-0,035	0,344	0,329	0,202	-0,035	0,067	0,346
pH KCl-su	-0,448	-0,136	0,027	-0,094	0,084	0,046	0,391	0,352	0,222	0,046	0,110	0,389
M.O. %-su	-0,141	0,028	-0,011	-0,047	0,158	0,144	-0,078	-0,037	-0,085	0,144	0,041	-0,060
C %-su	-0,141	0,028	-0,011	-0,047	0,158	0,144	-0,078	-0,037	-0,085	0,144	0,041	-0,060
N %-su	-0,227	0,031	-0,069	-0,044	0,212	0,111	0,053	0,082	-0,034	0,111	0,018	0,070
C/N-su	0,194	-0,069	0,103	0,053	-0,205	0,008	-0,149	-0,214	-0,029	0,008	0,043	-0,195
P mg/Kg-s	0,414	-0,037	-0,088	0,102	-0,134	-0,250	-0,104	-0,187	0,027	-0,250	-0,089	-0,163
K mg/Kg-s	0,137	-0,183	0,011	-0,034	-0,063	-0,062	0,100	-0,028	0,229	-0,062	0,098	0,052
Mg mg/Kg	-0,498	-0,120	-0,056	-0,164	0,085	0,071	0,231	0,187	0,187	0,071	0,112	0,238
Ca cmol(+	-0,432	-0,127	0,048	-0,105	0,073	0,050	0,336	0,289	0,198	0,050	0,113	0,330
Mg cmol(+	-0,498	-0,120	-0,056	-0,164	0,085	0,071	0,231	0,187	0,187	0,071	0,112	0,238
K cmol(+)/	0,137	-0,183	0,011	-0,034	-0,063	-0,062	0,100	-0,028	0,229	-0,062	0,098	0,052
Na cmol(+	-0,287	-0,098	-0,007	-0,294	0,152	0,189	0,082	0,080	0,075	0,189	0,159	0,083
Al cmol(+	0,462	0,172	0,028	0,149	-0,070	-0,065	-0,400	-0,360	-0,257	-0,065	-0,148	-0,402
CiCe cmol	-0,450	-0,103	0,045	-0,111	0,075	0,055	0,287	0,245	0,154	0,055	0,104	0,285
Ca/Mg-su	0,077	0,043	0,066	0,090	-0,036	-0,112	0,073	0,079	-0,045	-0,112	-0,080	0,072
K/Mg-su	1	0,000	0,075	0,120	-0,162	-0,163	-0,223	-0,314	-0,029	-0,163	-0,072	-0,281
ACIDEZ-uv	0,000	1	0,145	0,597	0,252	-0,377	-0,086	0,187	-0,766	-0,377	-0,805	0,048
Ac. Glucón	0,075	0,145	1	0,147	0,038	-0,117	-0,011	0,043	-0,120	-0,117	-0,152	0,005
Ác. Málico	0,120	0,597	0,147	1	-0,079	-0,466	0,008	0,146	-0,420	-0,466	-0,653	0,070
Ác. Tartár	-0,162	0,252	0,038	-0,079	1	0,156	0,105	0,294	-0,218	0,156	-0,137	0,211
GP %v/v	-0,163	-0,377	-0,117	-0,466	0,156	1	0,067	0,009	0,277	1,000	0,577	0,057
Nitrógeno	-0,223	-0,086	-0,011	0,008	0,105	0,067	1	0,642	0,248	0,067	0,087	0,817
Nitrógeno	-0,314	0,187	0,043	0,146	0,294	0,009	0,642	1	-0,040	0,009	-0,144	0,806
pH-uva	-0,029	-0,766	-0,120	-0,420	-0,218	0,277	0,248	-0,040	1	0,277	0,643	0,116
º Brix	-0,163	-0,377	-0,117	-0,466	0,156	1,000	0,067	0,009	0,277	1	0,577	0,057
GP/AT	-0,072	-0,805	-0,152	-0,653	-0,137	0,577	0,087	-0,144	0,643	0,577	1	-0,030
Nitrógeno	-0,281	0,048	0,005	0,070	0,211	0,057	0,817	0,806	0,116	0,057	-0,030	1
em_Al	0,285	0,231	0,096	0,280	-0,118	-0,193	-0,152	-0,094	-0,269	-0,193	-0,245	-0,142
em_B	0,205	-0,069	-0,023	0,085	-0,165	-0,205	0,056	-0,045	0,098	-0,205	-0,021	-0,004
em_Ca	0,030	0,084	0,035	0,096	-0,300	-0,310	-0,188	-0,140	-0,147	-0,310	-0,171	-0,185
em_Cu	-0,052	0,032	-0,063	-0,134	0,290	0,085	0,219	0,194	0,046	0,085	0,009	0,226
em_Fe	0,246	0,073	0,086	0,168	-0,250	-0,258	-0,226	-0,202	-0,127	-0,258	-0,158	-0,235
em_k	0,137	-0,278	0,069	-0,172	-0,017	0,094	0,070	-0,096	0,338	0,094	0,242	-0,001
em_Mg	0,142	0,027	-0,023	0,055	-0,210	-0,219	-0,345	-0,323	-0,100	-0,219	-0,115	-0,356
em_Mn	0,356	-0,029	-0,097	0,072	-0,276	-0,146	-0,256	-0,338	-0,031	-0,146	-0,045	-0,323
em_Na	-0,054	-0,058	0,106	-0,043	-0,047	-0,001	0,060	0,021	0,046	-0,001	0,038	0,046
em_P	0,050	0,017	0,011	0,089	-0,212	-0,172	-0,039	-0,065	0,004	-0,172	-0,081	-0,045
em_Zn	0,325	-0,018	0,026	0,082	-0,235	-0,324	-0,167	-0,239	0,024	-0,324	-0,126	-0,218
índice (1-5	0,036	0,149	-0,023	0,259	-0,217	-0,470	0,041	0,087	-0,129	-0,470	-0,301	0,066
Rega (0=N	-0,487	-0,082	0,000	-0,156	0,233	0,414	0,280	0,321	0,113	0,414	0,221	0,314
Pdte (0=0-	-0,060	-0,160	0,172	-0,209	0,152	0,327	-0,050	-0,117	0,170	0,327	0,236	-0,068
Kg/ha	0,195	0,326	-0,005	0,406	-0,071	-0,438	-0,055	0,057	-0,302	-0,438	-0,425	-0,027

Variables	em_Al	em_B	em_Ca	em_Cu	em_Fe	em_k	em_Mg	em_Mn	em_Na	em_P	em_Zn	índice (1-5)	Rega (0=NO/1=SI)	Pdte (0=0-5%/1=5-10%/2=>10%)	Kg/ha
pH H2O-su	-0,281	-0,021	-0,016	0,039	-0,233	-0,126	-0,278	-0,406	-0,104	-0,010	-0,242	0,261	0,294	-0,153	-0,002
pH KCl-su	-0,324	-0,032	-0,093	0,098	-0,332	-0,091	-0,386	-0,502	-0,121	-0,011	-0,306	0,157	0,323	-0,096	-0,058
M.O. %-su	-0,121	-0,187	-0,129	-0,037	-0,199	-0,184	-0,181	-0,257	-0,020	-0,025	-0,186	-0,185	0,231	0,168	-0,191
C %-su	-0,121	-0,187	-0,129	-0,037	-0,199	-0,184	-0,181	-0,257	-0,020	-0,025	-0,186	-0,185	0,231	0,168	-0,191
N %-su	-0,140	-0,122	-0,208	0,129	-0,207	-0,150	-0,186	-0,325	0,033	0,020	-0,186	-0,142	0,158	0,069	-0,157
C/N-su	0,050	-0,048	0,132	-0,363	0,126	0,041	0,111	0,207	0,002	-0,038	0,099	-0,025	0,094	0,114	-0,004
P mg/Kg-s	0,114	0,364	0,086	-0,125	0,287	0,070	0,240	0,255	0,041	0,153	0,315	0,286	-0,476	-0,277	0,346
K mg/Kg-s	-0,112	0,262	-0,091	0,125	-0,002	0,189	-0,036	-0,008	-0,082	0,166	0,092	0,081	-0,339	-0,209	0,105
Mg mg/Kg	-0,333	0,046	-0,068	0,138	-0,162	0,063	-0,093	-0,330	0,010	0,106	-0,186	0,052	0,139	-0,115	-0,112
Ca cmol(+	-0,305	-0,005	-0,090	0,124	-0,306	-0,063	-0,360	-0,525	-0,086	0,059	-0,240	0,132	0,206	-0,057	-0,093
Mg cmol(+	-0,333	0,046	-0,068	0,138	-0,162	0,063	-0,093	-0,330	0,010	0,106	-0,186	0,052	0,139	-0,115	-0,112
K cmol(+)/	-0,112	0,262	-0,091	0,125	-0,002	0,189	-0,036	-0,008	-0,082	0,166	0,092	0,081	-0,339	-0,209	0,105
Na cmol(+	-0,147	-0,039	-0,116	0,205	-0,114	0,101	-0,112	-0,175	0,035	0,038	-0,126	-0,169	0,014	0,048	-0,209
Al cmol(+	0,335	0,032	0,086	-0,135	0,334	0,074	0,377	0,459	0,130	0,018	0,289	-0,161	-0,312	0,128	0,069
CiCe cmol	-0,321	0,021	-0,052	0,093	-0,251	-0,018	-0,287	-0,521	-0,047	0,109	-0,206	0,117	0,189	-0,085	-0,085
Ca/Mg-su	0,028	-0,043	-0,024	-0,022	-0,115	-0,191	-0,323	-0,218	-0,093	-0,063	-0,035	0,238	0,045	-0,079	0,110
K/Mg-su	0,285	0,205	0,030	-0,052	0,246	0,137	0,142	0,356	-0,054	0,050	0,325	0,036	-0,487	-0,060	0,195
ACIDEZ-uv	0,231	-0,069	0,084	0,032	0,073	-0,278	0,027	-0,029	-0,058	0,017	-0,018	0,149	-0,082	-0,160	0,326
Ac. Glucón	0,096	-0,023	0,035	-0,063	0,086	0,069	-0,023	-0,097	0,106	0,011	0,026	-0,023	0,000	0,172	-0,005
Ác. Málico	0,280	0,085	0,096	-0,134	0,168	-0,172	0,055	0,072	-0,043	0,089	0,082	0,259	-0,156	-0,209	0,406
Ác. Tartár	-0,118	-0,165	-0,300	0,290	-0,250	-0,017	-0,210	-0,276	-0,047	-0,212	-0,235	-0,217	0,233	0,152	-0,071
GP %v/v	-0,193	-0,205	-0,310	0,085	-0,258	0,094	-0,219	-0,146	-0,001	-0,172	-0,324	-0,470	0,414	0,327	-0,438
Nitrógeno	-0,152	0,056	-0,188	0,219	-0,226	0,070	-0,345	-0,256	0,060	-0,039	-0,167	0,041	0,280	-0,050	-0,055
Nitrógeno	-0,094	-0,045	-0,140	0,194	-0,202	-0,096	-0,323	-0,338	0,021	-0,065	-0,239	0,087	0,321	-0,117	0,057
pH-uva	-0,269	0,098	-0,147	0,046	-0,127	0,338	-0,100	-0,031	0,046	0,004	0,024	-0,129	0,113	0,170	-0,302
º Brix	-0,193	-0,205	-0,310	0,085	-0,258	0,094	-0,219	-0,146	-0,001	-0,172	-0,324	-0,470	0,414	0,327	-0,438
GP/AT	-0,245	-0,021	-0,171	0,009	-0,158	0,242	-0,115	-0,045	0,038	-0,081	-0,126	-0,301	0,221	0,236	-0,425
Nitrógeno	-0,142	-0,004	-0,185	0,226	-0,235	-0,001	-0,356	-0,323	0,046	-0,045	-0,218	0,066	0,314	-0,068	-0,027
em_Al	1	0,075	0,140	-0,025	0,448	-0,030	0,200	0,390	0,218	0,049	0,206	0,047	-0,243	0,021	0,142
em_B	0,075	1	0,254	-0,100	0,289	0,367	0,178	0,073	0,015	0,308	0,360	0,394	-0,444	-0,315	0,202
em_Ca	0,140	0,254	1	-0,237	0,402	0,004	0,487	0,144	0,042	0,240	0,385	0,318	-0,233	-0,241	0,290
em_Cu	-0,025	-0,100	-0,237	1	-0,250	-0,026	-0,233	-0,159	-0,009	-0,041	-0,212	-0,130	-0,085	0,072	-0,042
em_Fe	0,448	0,289	0,402	-0,250	1	0,169	0,517	0,412	0,343	0,214	0,335	0,194	-0,339	-0,146	0,226
em_k	-0,030	0,367	0,004	-0,026	0,169	1	0,165	0,081	0,176	0,272	0,248	-0,059	-0,100	0,141	-0,152
em_Mg	0,200	0,178	0,487	-0,233	0,517	0,165	1	0,416	0,141	0,224	0,403	0,057	-0,285	-0,045	0,176
em_Mn	0,390	0,073	0,144	-0,159	0,412	0,081	0,416	1	0,128	0,049	0,328	-0,046	-0,313	-0,031	0,095
em_Na	0,218	0,015	0,042	-0,009	0,343	0,176	0,141	0,128	1	0,021	0,116	-0,062	0,134	0,212	-0,088
em_P	0,049	0,308	0,240	-0,041	0,214	0,272	0,224	0,049	0,021	1	0,242	0,186	-0,285	-0,138	0,043
em_Zn	0,206	0,360	0,385	-0,212	0,335	0,248	0,403	0,328	0,116	0,242	1	0,201	-0,440	-0,064	0,208
índice (1-5	0,047	0,394	0,318	-0,130	0,194	-0,059	0,057	-0,046	-0,062	0,186	0,201	1	-0,340	-0,689	0,455
Rega (0=N	-0,243	-0,444	-0,233	-0,085	-0,339	-0,100	-0,285	-0,313	0,134	-0,285	-0,440	-0,340	1	0,373	-0,388
Pdte (0=0-	0,021	-0,315	-0,241	0,072	-0,146	0,141	-0,045	-0,031	0,212	-0,138	-0,064	-0,689	0,373	1	-0,506
Kg/ha	0,142	0,202	0,290	-0,042	0,226	-0,152	0,176	0,095	-0,088	0,043	0,208	0,455	-0,388	-0,506	1

Con el fin de centrar el estudio en los parámetros más demandados por las bodegas, el grado alcohólico probable y la acidez total, se evaluaron los parámetros que estaban significativamente correlacionados con ambas variables, centrándonos especialmente en los parámetros de suelo (Tabla 7).

Tabla 7. Parámetros de suelo y mosto correlacionados con el grado alcohólico probable, la acidez total y la relación entre ambas.

VALDEORRAS 2021

	Variables	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GP/AT
Suelo	P (mg/Kg)		-0,250	
	K (mg/Kg)	-0,183		
	Na cmol(+)/Kg		0,189	
Mosto	Acidez total (g/l)		-0,377	-0,805
	Ác. Málico (g/l)	0,597	-0,466	-0,653
	Ác. Tartárico (g/l)	0,252		
	GAP (%v/v)	-0,377		0,577
	Nitrógeno amoniacal	0,187		
	pH	-0,766	0,277	0,643
	Relación GP/AT	-0,805	0,577	
	Aluminio	0,231	-0,193	-0,245
	Boro		-0,205	
	Calcio		-0,310	
	Hierro		-0,258	
	Potasio	-0,278		0,242
	Magnesio		-0,219	
	Zinc		-0,324	

VALDEORRAS 2022

	Variables	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GP/AT
Suelo	pH (H2O)	-0,234		
	pH (KCl)	-0,206		
	M.O. (%)	0,209		-0,213
	C (%)	0,209		-0,213
	N (%)	0,189		-0,191
	P (mg/Kg)		-0,189	
	K (mg/Kg)	-0,223		0,183
	Mg (mg/Kg)	-0,273		0,209
	Ca cmol(+)/Kg-su			
	Al cmol(+)/Kg-su	0,233		
Mosto	Acidez total (g/l)		-0,246	-0,812
	Ác. Málico (g/l)	0,347	-0,257	-0,393
	Ác. Tartárico (g/l)	0,262		-0,201
	GAP (%v/v)	-0,246		0,445
	Nitrógeno amínico	-0,308		0,209
	pH	-0,749		0,603
	Relación GAP/AT	-0,812	0,445	
	Nitrógeno total	-0,286		0,212
	Boro	-0,187		
	Potasio	-0,577		0,511
	Sodio	-0,184		0,201
	Fósforo	-0,336		0,289

VALDEORRAS 2023

	Variables	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GP/AT
Suelo	P (mg/Kg)		-0,234	-0,223
	Al cmol(+)/Kg	0,229		-0,184
	Relación K/Mg			-0,181
Mosto	Acidez total (g/l)		-0,458	-0,794
	Ác. Málico (g/l)	0,558	-0,387	-0,524
	Ác. Tartárico (g/l)	0,535	-0,336	-0,494
	GAP (%v/v)	-0,458		0,671
	Nitrógeno Amínico	-0,194		
	pH	-0,708	0,352	0,608
	GAP/AT	-0,794	0,671	

En la Tabla 7 se puede ver que la acidez total se correlaciona negativamente con el potasio en 2021 y 2022. Esa correlación se mantiene con valores aún mayores en el mosto, es decir, a más potasio en suelo y mosto, menor acidez total en mosto (Figuras 4 y 5). Hay además una correlación positiva con el aluminio en el complejo de cambio, lo que indica que en suelos más ácidos la acidez total es mayor.

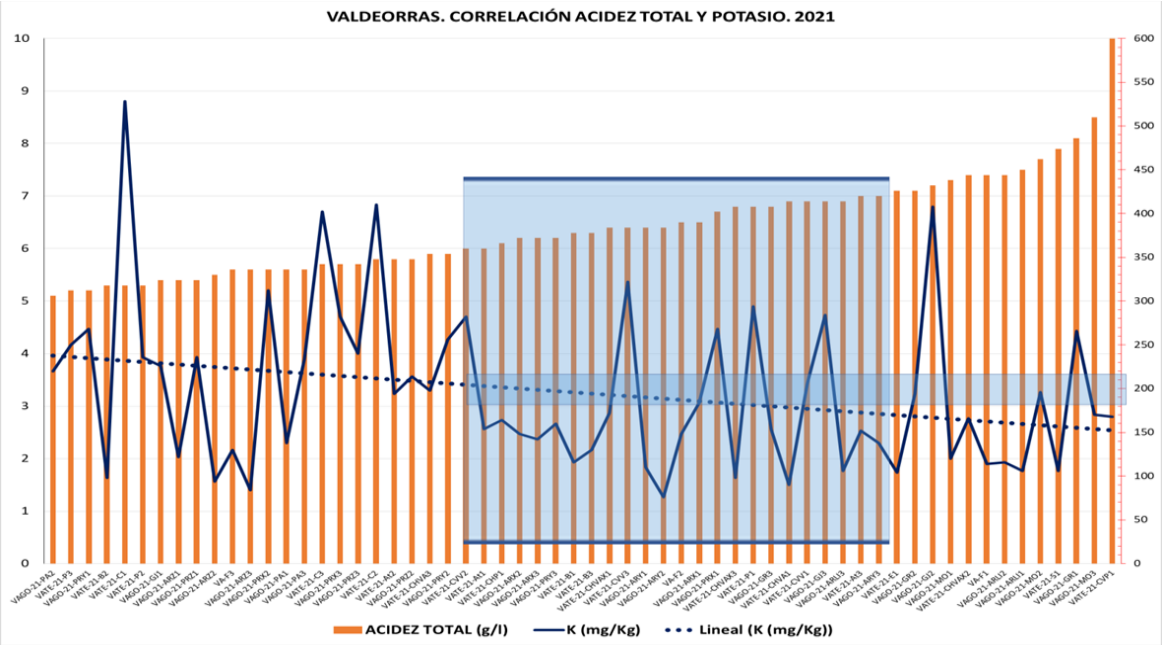

Figura 4. Acidez total en mosto y potasio en suelo. Valdeorras, 2021

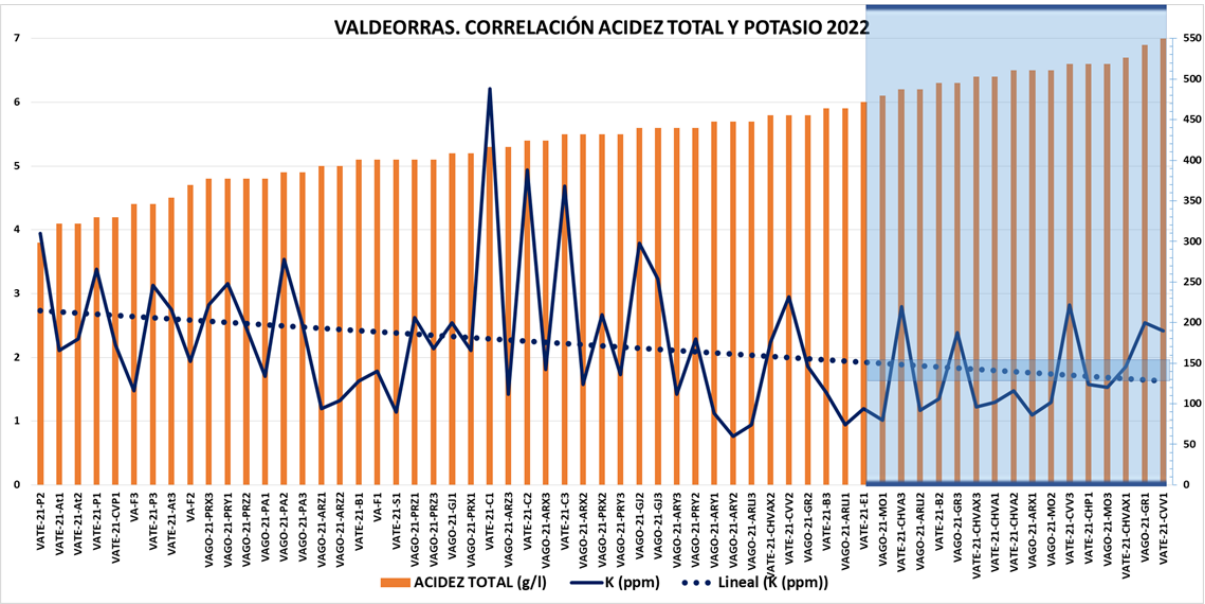

Figura 5. Acidez total en mosto y potasio en suelo. Valdeorras, 2022

Respecto al grado alcohólico probable, está correlacionado negativamente con el fósforo en suelo los tres años, lo que indica que suelos con exceso de este elemento darán lugar a mostos con un menor grado alcohólico (Figuras 6 y 7).

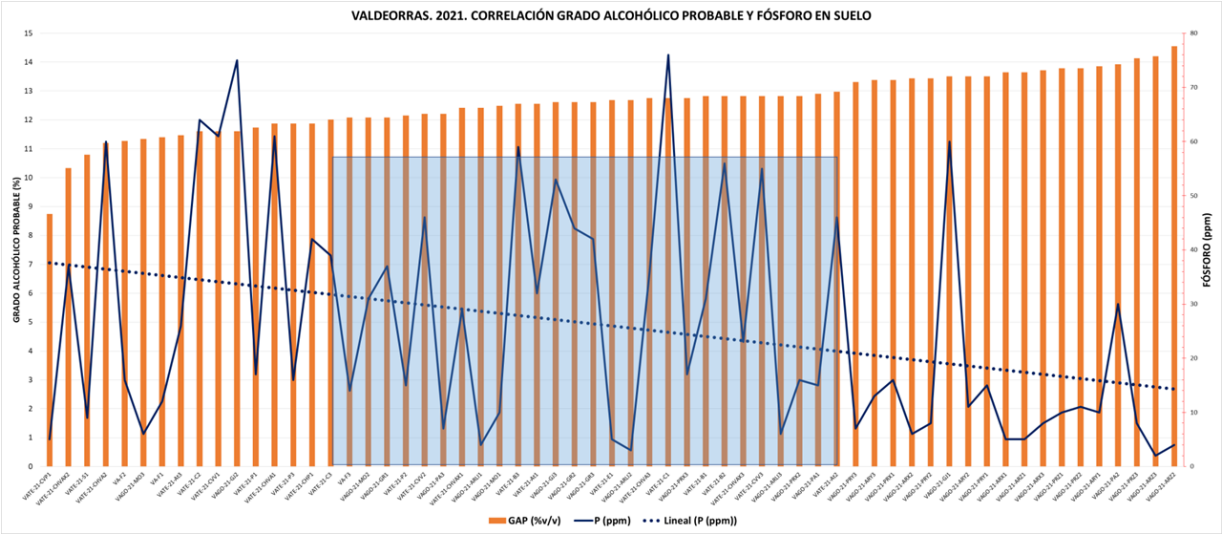

Figura 6. Grado alcohólico probable en mosto y fósforo en suelo. Valdeorras, 2021

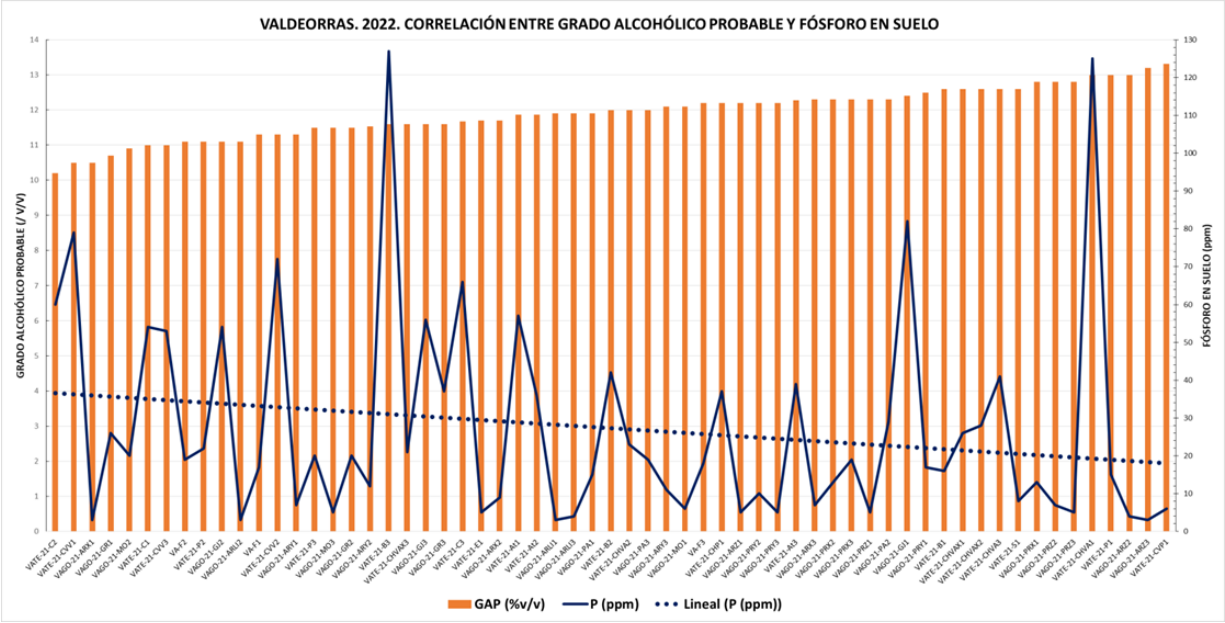

Figura 7. Grado alcohólico probable en mosto y fósforo en suelo. Valdeorras, 2022

Teniendo en cuenta las líneas de tendencia para cada parámetro, se establecieron los valores en suelo adecuados para alcanzar un grado alcohólico probable en mosto entre 12,0% y 13,0% v/v y una acidez total entre 6 y 7 g/L expresado en ácido tartárico (Tabla 8).

Tabla 8. Niveles de referencia en suelo recomendados para la D.O. Valdeorras

pH (H2O)	Materia orgánica (%)	Nitrógeno (%)	Relación C/N	Fósforo disponible (ppm)	Potasio asimilable (ppm)	Magnesio cambiable (ppm)	Calcio (cmol(+)/Kg)	Relación Ca/Mg	Relación K/Mg
5,8-6,0	3,0-3,5	0,16-0,19	11,4-12,5	22-32	150-200	80-110	5,0-7,0	5,8-7,2	0,6-0,75

Si bien estos valores son los indicados por el estudio, se aconseja aumentar ligeramente el pH del suelo (hasta 6,0-6,5) mediante encalado con el fin de aumentar la capacidad de intercambio catiónico y eliminar los iones de aluminio presentes en el complejo de cambio.

D.O. MONTERREI

Los suelos promedio de la D.O Monterrei para los tres años de estudio (Tabla 9) se caracterizaron por valores ácidos de pH, y muy bajos de calcio y capacidad de intercambio catiónico. Por la contra, se observaron valores promedio muy altos de fósforo y potasio en suelo, lo que indica fuertes sobreabonados de manera generalizada. De hecho, en alguna parcela el fósforo y el potasio son hasta 10 veces superiores a los valores indicados en bibliografía. En alguna parcela se detectó también un sobreabonado con magnesio.

Tabla 9. Valores promedio de los años de estudio de suelos en la D.O. Monterrei

SUELOS DE LA D.O. MONTERREI														
	pH (H2O)	M.O. (%)	C (%)	N (%)	C/N	Ca (cmol(+)/ Kg)	Na (cmol(+)/ Kg)	Al (cmol(+)/ Kg)	CiCe (cmol(+)/ Kg)	Ca/Mg	K/Mg	P (mg/Kg)	K (mg/Kg)	Mg (mg/Kg)
Promedio	5,44	3,70	2,14	0,18	11,67	3,57	0,08	0,52	5,71	5,65	1,45	55	326	91
Máximo	6,70	9,78	5,67	0,34	19,17	8,10	0,23	2,50	16,86	12,00	5,31	190	1552	568
Mínimo	4,40	1,30	0,75	0,08	7,18	0,60	0,02	0,10	2,41	2,00	0,44	4	106	18

En cuanto a las analíticas en peciolo y limbo, si se comparan los valores obtenidos con los citados en la *Guía practica de la fertilización racional de los cultivos en España* (https://www.mapa.gob.es/es/agricultura/publicaciones/Publicaciones-fertilizantes.aspx) podemos observar, en peciolo, valores altos de nitrógeno, fósforo y potasio y bajos de calcio y boro. Los valores de manganeso son extremadamente altos. En limbo hay valores muy bajos en calcio, magnesio y altos en fósforo, potasio y boro. El manganeso es también alto; una explicación podría ser que los altos valores de potasio en suelo aumentan su disponibilidad para la planta; además, puede ser incorporado al suelo a través de los fertilizantes y estiércoles (Tablas 10 y 11).

Tabla 10. Valores promedio de todos los años del análisis de peciolo en la D.O. Monterrei

	Peciolo									
	Nitrogeno (%)	Fosforo (%)	Potasio (%)	Calcio (%)	Magnesio (%)	Hierro (ppm)	Boro (ppm)	Cobre (ppm)	Manganeso (ppm)	Zinc (ppm)
Media	0,83	0,36	3,30	1,34	0,69	21	29	22	703	70
Máximo	1,76	0,85	6,95	2,06	1,82	30	50	89	1070	109
Mínimo	0,55	0,07	0,66	0,95	0,20	10	21	2	436	30

Tabla 11. Valores promedio de todos los años del análisis de limbo en la D.O. Monterrei

	Limbo								
	Fosforo (%)	Potasio (%)	Calcio (%)	Magnesio (%)	Hierro (ppm)	Boro (ppm)	Cobre (ppm)	Manganeso (ppm)	Zinc (ppm)
Media	0,28	1,63	1,71	0,28	118	52	113	513	28
Máximo	0,60	2,38	2,72	1,27	275	208	534	885	76
Mínimo	0,14	0,99	1,07	0,12	78	23	6	191	16

En cuanto a los mostos, tienen un grado ligeramente inferior a los de Valdeorras, una acidez total similar, y el málico un poco mayor y el tartárico menor (Tabla 12). El mayor ácido málico se puede deber a las condiciones climáticas, con menor temperatura media. El ácido tartárico menor es posible que se deba al sobreabonado con potasio, que pasa al mosto y hace precipitar dicho ácido. De hecho, se

observaron acideces totales extremadamente bajas y pH muy alto que no son habituales de la variedad Godello y que dificultarán la obtención de un vino equilibrado.

Tabla 12. Valores promedio de todos los años de parámetros enológicos básicos de mosto en la D.O. Monterrei

MOSTOS DE LA D.O. MONTERREI									
	Grado alcohólico probable (%v/v)	Acidez total (g/l)	GP/AT	pH	Ác. Málico (g/l)	Ác. Tartárico (g/l)	Nitrógeno amínico (mg/l)	Nitrógeno amoniacal (mg/l)	Nitrógeno total (mg/l)
Promedio	11,94	6,16	2,06	3,33	2,72	6,19	132	84	216
Máximo	14,10	11,10	4,60	4,35	6,73	9,02	285	167	438
Mínimo	9,34	2,50	0,87	2,84	0,90	4,20	56	18	82

Respecto a los elementos en mosto, son similares a los de Valdeorras, salvo en el caso del manganeso, que es superior, y el cobre, que es inferior (Tabla 13).

Tabla 13. Valores promedio de todos los años de elementos de mosto en la D.O. Monterrei.

	Elementos del mosto (mg/L)										
	Fósforo	Potasio	Calcio	Magnesio	Hierro	Boro	Cobre	Manganeso	Zinc	Aluminio	Sodio
Media	112	1639	48	63	0,08	1,77	0,95	2,16	0,46	0,06	3,00
Máximo	214	3532	79	101	0,27	5,24	3,58	5,88	0,95	0,13	4,24
Mínimo	35	941	29	44	0,01	0,08	0,30	0,57	0,30	0,02	2,04

Se hizo el análisis de correlaciones al igual que en el caso de la D.O. Valdeorras. Se puede ver que la acidez total en uva está correlacionada con la materia orgánica, el carbono, el nitrógeno y el fósforo los tres años de estudio, y en el 22 y el 23 con los niveles de potasio. Respecto al grado alcohólico, no hay ninguna correlación con los parámetros de suelo que se repita dos años (Tabla 14).

Tabla 14. Parámetros de suelo y mosto correlacionados con el grado alcohólico probable, la acidez total y la relación entre ambas.

	Variables	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GP/AT
Suelo	M.O. (%)	0,245		
	C (%)	0,245		
	N (%)	0,244		
	P (mg/Kg)	-0,274		
Mosto	Acidez total (g/l)		-0,551	-0,887
	Ac. Málico (g/l)	0,464	-0,424	-0,469
	Ac. Tartárico (g/l)	0,456	-0,315	-0,432
	GAP (%v/v)	-0,551		0,671
	Nitrógeno Aminico		-0,254	
	Nitrógeno amoniacal	0,458	-0,466	-0,483
	pH	-0,739	0,403	0,681
	GAP/AT	-0,887	0,671	
	Nitrógeno total	0,295	-0,361	-0,325
	Boro	-0,383		0,361
	Calcio	0,280	-0,327	-0,317
	Cobre		-0,278	
	Hierro		0,277	
	Potasio	-0,296		0,288
	Sodio	0,356	-0,435	-0,382
	Fósforo	-0,325		0,275

	Variables	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GP/AT
Suelo	M.O. (%)	0,327		-0,271
	C (%)	0,327		-0,271
	N (%)	0,242		
	C/N	0,293		-0,245
	P (mg/Kg)	-0,344		0,311
	K (mg/Kg)	-0,303		0,309
	K/Mg		0,256	
Mosto	Acidez total (g/l)		-0,413	-0,863
	Ac. Tartárico	0,599	-0,333	-0,486
	GAP (%v/v)	-0,413		0,560
	Nitrógeno Aminico	-0,356		0,351
	Nitrógeno amoniacal		-0,257	
	pH	-0,767	0,326	0,717
	GAP/AT	-0,863	0,560	
	Boro	-0,435		0,404
	Calcio			-0,261
	Hierro	-0,354		0,343
	Potasio	-0,586	0,237	0,553
	Sodio	-0,358		0,350
	Fósforo	-0,564		0,509
	Zinc	-0,268		

	Variables	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GP/AT
Suelo	pH (H2O)			0,250
	M.O. (%)	0,370	-0,278	-0,321
	C (%)	0,370	-0,278	-0,321
	N (%)	0,333		-0,272
	C/N	0,232	-0,355	-0,314
	P (mg/Kg)	-0,295	0,245	0,301
	K (mg/Kg)	-0,266		0,278
Mosto	Acidez total (g/l)		-0,596	-0,821
	Ac. Málico (g/l)	0,573	-0,426	-0,502
	Ac. Tartárico (g/l)	0,453	-0,326	-0,429
	GAP (%v/v)	-0,596		0,778
	Nitrógeno aminico	0,426	-0,334	-0,392
	pH	-0,649	0,493	0,623
	Relación GAP/AT	-0,821	0,778	

Cuando enfrentamos los valores de acidez total con los valores de potasio en suelo, se vuelve a observar la misma tendencia que en el caso de la D.O. Valdeorras, cayendo la acidez cuando aumenta el potasio. Lo mismo pasa con el fósforo (Figuras 8 a 11). Respecto a la materia orgánica, la tendencia es contraria, ambos aumentan a la par.

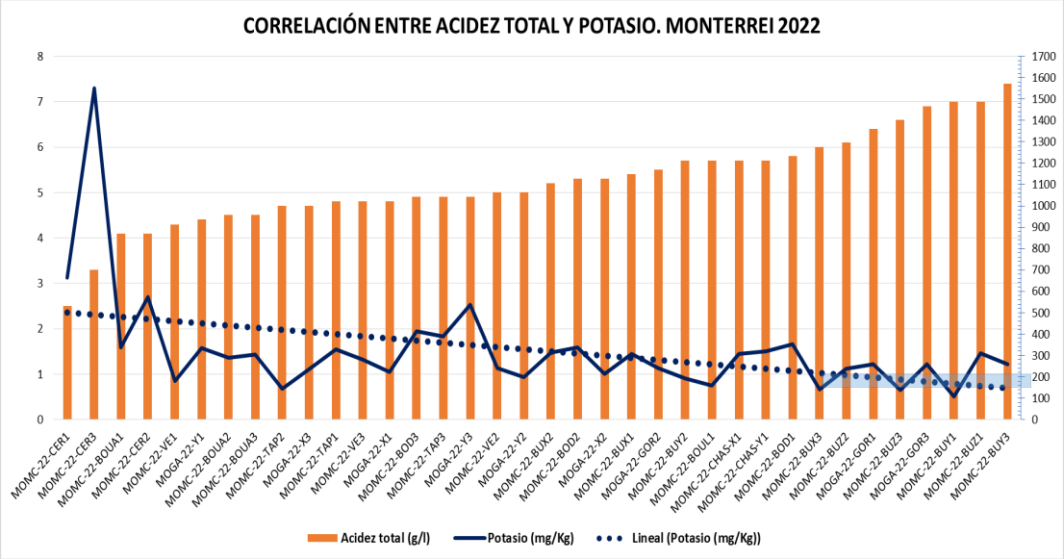

Figura 8. Acidez total en mosto y potasio en suelo. Monterrei, 2022

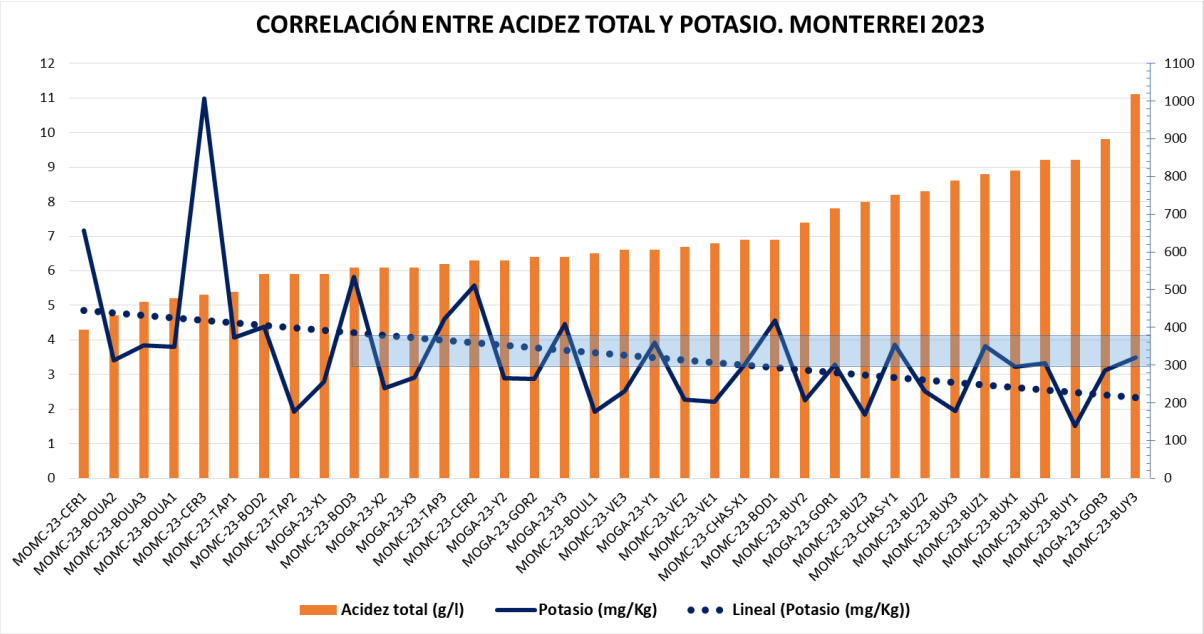

Figura 9. Acidez total en mosto y potasio en suelo. Monterrei, 2023

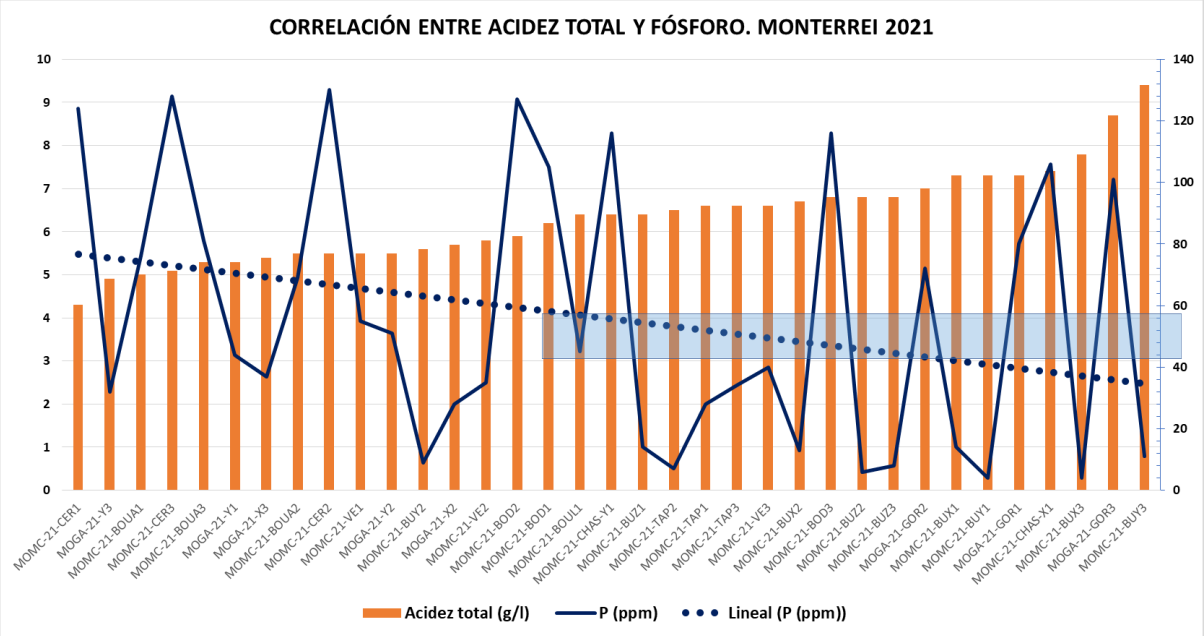

Figura 10. Acidez total en mosto y fósforo en suelo. Monterrei, 2021

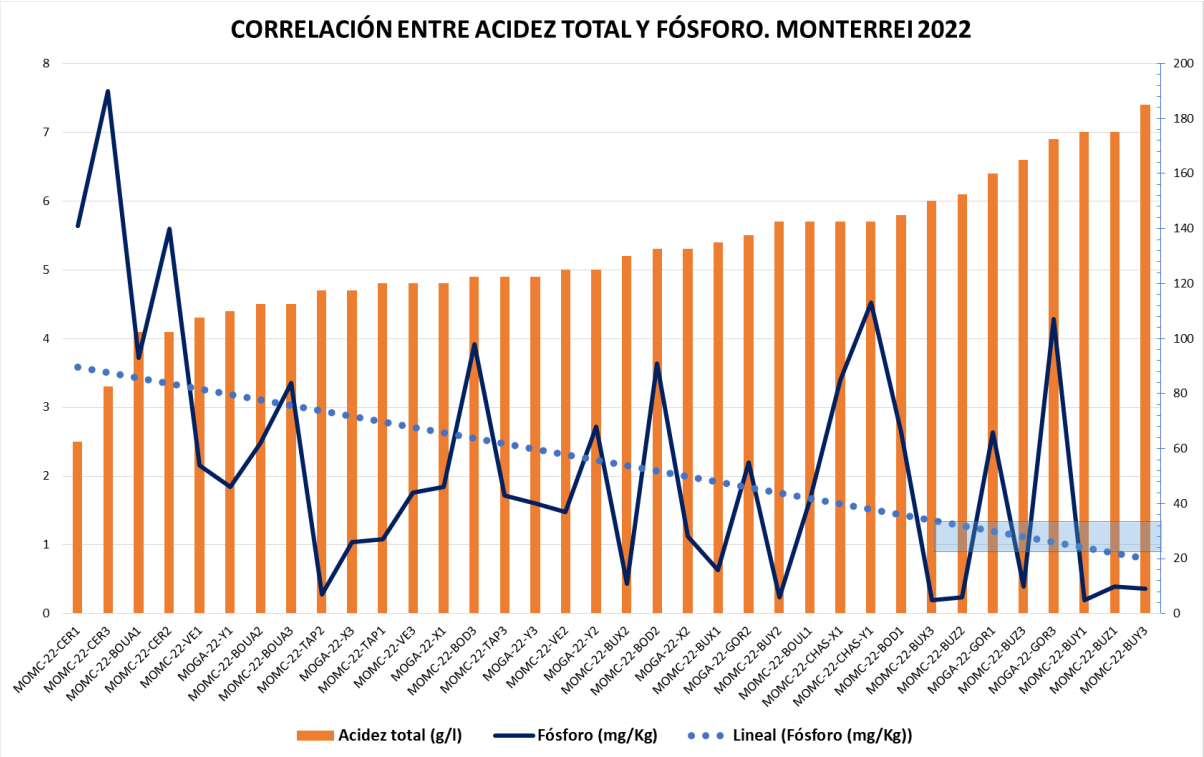

Figura 11. Acidez total en mosto y fósforo en suelo. Monterrei, 2022

Puesto que había muchas parcelas con valores elevados de potasio, se compararon los valores de todos los parámetros para las fincas más abonadas para este elemento en el año 2022, con el fin de ver como afectaba a los parámetros de mosto el exceso de abonado. En las Tablas 15 y 16 se han marcado en verde los 5 valores más altos de todas las muestras analizadas para cada parámetro en suelo, mosto, peciolo y limbo, y en azul los más bajos. Se puede ver que las 5 fincas con mayor nivel de potasio también eran de las que tenían los valores mayores de fósforo, magnesio, calcio, y capacidad de intercambio catiónico. Tres de esas fincas mantienen esos valores de potasio elevados en peciolo y limbo, lo que indica su absorción por la planta. Sin embargo, el magnesio fue muy poco absorbido; de hecho, esas fincas, a pesar de tener altos valores de magnesio en suelo en cuatro de ellas, tuvieron valores muy bajos en peciolo. Esto se explica por el antagonismo existente entre potasio y magnesio, reduciéndose la absorción del último en presencia de grandes cantidades de potasio. En el mosto, tres de esas cinco fincas con valores muy altos de potasio presentaron los valores más bajos de acidez total y más altos de

pH. De lo expuesto se indica la necesidad de controlar los abonados excesivos con potasio para tener unos mostos adecuados para la vinificación.

Tabla 15. Valores de parámetros de suelo y mosto en las cinco fincas con más potasio en suelo. Monterrei, año 2022

	SUELO						MOSTO					
	Fósforo (mg/Kg)	Potasio (mg/Kg)	Magnesio (mg/Kg)	Calcio cmol(+)/Kg	CiCe cmol(+)/Kg	% saturación CC	Acidez total (g/l)	pH	GAP/AT	Potasio	Magnesio	Fósforo
MC-22-C	190	1552	568	8,1	16,9	99,4	3,3	3,99	3,24	2656	44	166
MC-22-C	141	664	212	6,6	10,2	99,0	2,5	4,35	4,60	3532	52	214
MC-22-C	140	572	258	7,5	11,2	99,1	4,1	3,66	2,73	1925	50	109
OGA-22-Y	40	538	174	6	9,0	97,8	4,9	3,49	2,65	1762	54	103
MC-22-B(	98	412	94	3,5	5,9	91,5	4,9	3,62	2,88	1804	55	88

Tabla 16. Valores de macroelementos en peciolo y limbo en las cinco fincas con más potasio en suelo. Monterrei, año 2022

	PECIOLO			LIMBO	
	Fosforo	Potasio	Magnesio	Potasio	Magnesio
MC-22-C	0,2	5,07	0,29	1,84	0,19
MC-22-C	0,37	5,5	0,36	2,38	0,23
MC-22-C	0,42	3,7	0,55	1,74	0,26
OGA-22-Y	0,52	3,34	0,62	1,68	0,24
MC-22-B(	0,17	5,3	0,31	1,79	0,23

En Monterrei se eliminaron diversas parcelas que tenían exceso de abonado, con el fin de que no distorsionaran los resultados del cálculo de niveles de referencia de nutrientes. Para la eliminación se siguieron estos criterios: Fósforo disponible mayor de 50 mg/kg, Potasio asimilable mayor de 300 mg/kg, y Magnesio cambiable mayor de 200 mg/kg. Los resultados obtenidos para alcanzar un grado alcohólico probable de 12,0%-13,0% v/v fueron los siguientes (Tabla 17):

Tabla 17. Niveles de referencia en suelo recomendados para la D.O. Monterrei

DO	Materia orgánica (%)	Nitrógeno (%)	Relación C/N	Fósforo disponible (ppm)	Potasio asimilable (ppm)	Magnesio cambiable (ppm)	Calcio (cmol(+)/Kg)	Relación Ca/Mg
MONTERREI	2,7-4,3	0,14-0,19	11 a 13	20-28	210-245	53-80	2,0-3,2	4,5-5,6

Esas fincas con grado alcohólico probable entre 12,0%-13,0 % v/v tuvieron en promedio unas acideces totales de 6'5, 5'7 y 7,2 g/L de ácido tartárico en mosto en los años 2021, 2022 y 2023, respectivamente.

El estudio mostró unos valores para determinados parámetros que se apartan grandemente de la bibliografía. La relación potasio/magnesio (calculada con los iones del complejo de cambio, expresados en cmol(+)/kg) es mucho mayor de la estipulada en diversos estudios. Recomendamos encarecidamente encalar en el caso de pH ácido en suelo para tener un pH mínimo de 6,0-6,5, y de esta manera aumentar el calcio, el porcentaje de saturación del complejo de cambio y la capacidad de intercambio catiónico, y reducir el aluminio en el complejo de cambio, que es fitotóxico y desplaza al calcio (Tabla 18). Es importante reseñar que, a pH ácido, gran parte de los elementos del suelo se bloquean y no son absorbidos, con lo cual en muchos casos con un simple encalado se produce una gran mejora en la planta, ya que ésta puede absorber muchos nutrientes que estaban inmovilizados en el suelo por el pH ácido (Figura 12). También hay que reseñar que es importante no sobreabonar en exceso, ya que existen muchas sinergias y/o bloqueos de unos elementos con otros cuando están en exceso (Figura 13).

Tabla 18. Niveles de referencia en suelo obtenidos pero que deberían corregirse. D.O. Monterrei

VALORES A CORREGIR						
	pH (H2O)	**Calcio (cmol(+)/Kg)**	**% saturación CC**	**Al (cmol(+)/Kg)**	**Capacidad de intercambio catiónico (cmol(+)/Kg)**	**Relación K/Mg**
Obtenido	5,2-5,4	2,0-3,2	78-90	0,32-0,8	3,5-5,3	1,1-1,6
DESEABLE	6,0-6,5	mínimo 5	> 95%	0	mínimo 10-12	0,4-0,8

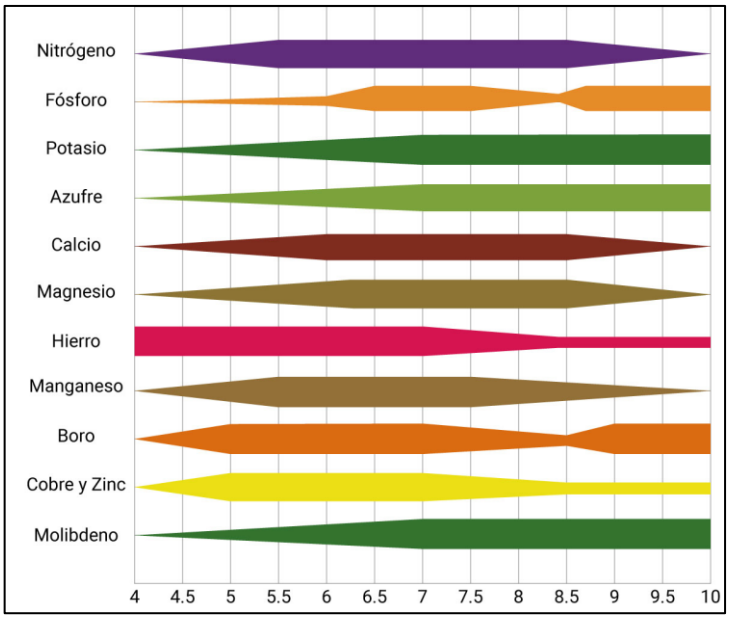

Figura 12. Absorción de elementos según el pH del suelo.

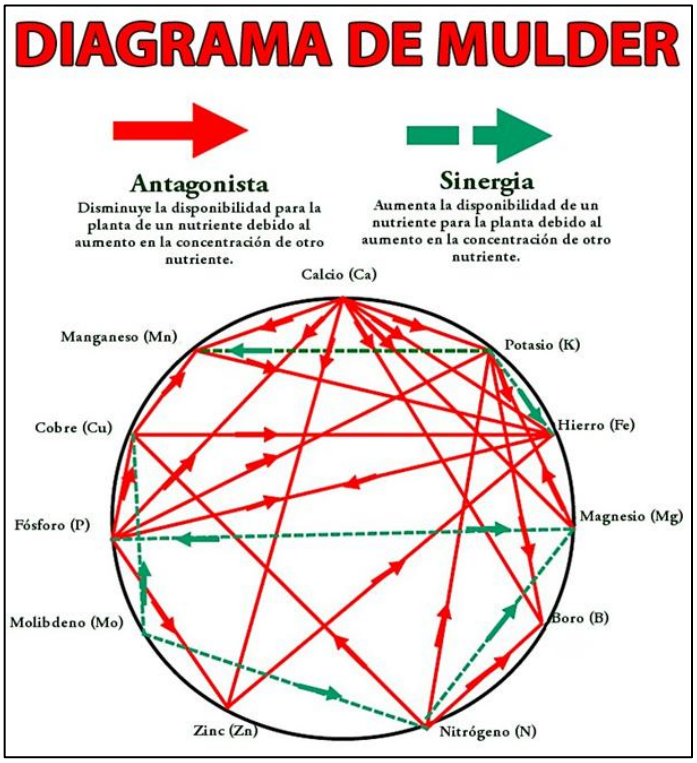

Figura 13. Antagonismos y sinergias entre elementos en suelo

D.O. RIBEIRA SACRA

Respecto a los suelos de la Ribeira Sacra, los valores promedio son un poco altos en fósforo, potasio y magnesio. Desglosando los datos por subzonas, podemos ver que en Quiroga-Bibei y en Ribeiras do Sil el pH del suelo es bastante ácido y con aluminio en el complejo de cambio. En Ribeiras do Sil, en las fincas estudiadas había sobreabonado de fósforo, potasio y magnesio. Los suelos de Amandi presentaron más calcio y capacidad de intercambio catiónico (Tabla 19, Figuras 14 y 15).

Tabla 19. Valores promedio de todos los años de análisis de suelo en la D.O. Ribeira Sacra y sus subzonas

D.O. RIBEIRA SACRA														
	pH (H2O)	M.O. (%)	C (%)	N (%)	C/N	Ca (cmol(+)/ Kg)	Na (cmol(+)/ Kg)	Al (cmol(+)/ Kg)	CiCe (cmol(+)/ Kg)	Ca/Mg	K/Mg	P (mg/Kg)	K (mg/Kg)	Mg (mg/Kg)
Ribeira Sacra (promedio)	6,12	4,91	2,85	0,23	13,38	8,22	0,07	0,58	10,63	7,61	0,69	41	267	136
Máximo	7,70	12,02	5,30	2,31	18,74	22,70	0,16	3,70	24,78	19,00	1,56	119	694	336
Mínimo	4,50	1,12	0,65	0,08	1,26	0,70	0,02	0,10	2,98	2,00	0,18	5	82	26
Amandi	6,47	5,32	3,08	0,23	13,27	10,43	0,06	0,61	12,95	8,56	0,66	20	271	147
Chantada	6,37	4,69	2,73	0,24	13,65	8,49	0,07	0,45	10,61	8,77	0,70	42	244	124
Quiroga-Bibei	5,31	5,49	3,18	0,22	14,49	5,34	0,07	1,00	8,11	4,70	0,56	40	213	146
Ribeiras do Sil	5,75	4,24	2,46	0,20	11,93	6,86	0,07	0,46	9,37	6,27	0,83	68	358	137

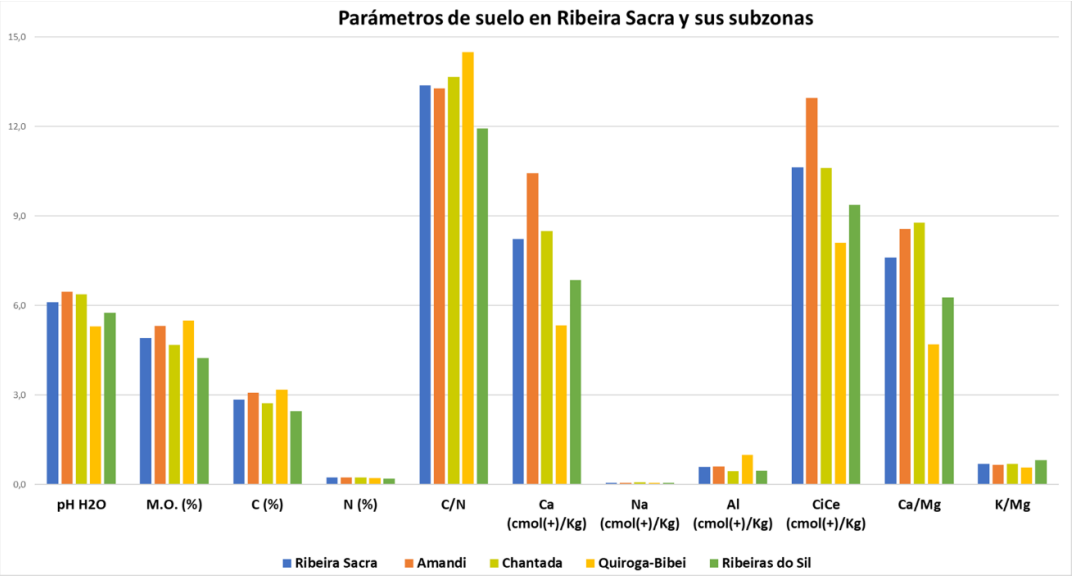

Figura 14. Valores promedio de todos los años de análisis de suelo en la D.O. Ribeira Sacra y sus subzonas

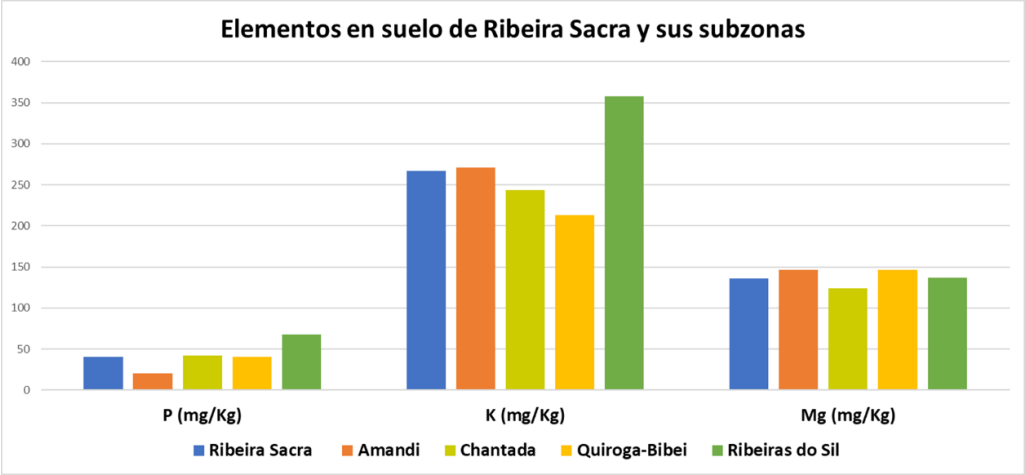

Figura 15. Valores promedio de todos los años de macroelementos en suelo en la D.O. Ribeira Sacra y sus subzonas

En cuanto a las analíticas en peciolo y limbo, la comparación con los valores citados en la *Guía practica de la fertilización racional de los cultivos en España*

(https://www.mapa.gob.es/es/agricultura/publicaciones/Publicaciones-fertilizantes.aspx) indica, en peciolo, valores altos de nitrógeno, muy altos de fósforo y bajos de calcio y boro. Los valores de manganeso son de nuevo extremadamente altos. En limbo hay valores bajos en calcio, magnesio y boro, altos en potasio y muy altos en manganeso (Tablas 20 y 21).

Tabla 20. Valores promedio de todos los años de elementos en peciolo en la D.O. Ribeira Sacra

	Peciolo									
	Nitrogeno (%)	Fósforo (%)	Potasio (%)	Calcio (%)	Magnesio (%)	Hierro (ppm)	Boro (ppm)	Cobre (ppm)	Manganeso (ppm)	Zinc (ppm)
Media	0,60	0,29	1,85	1,80	1,01	19	27	26	563	67
Máximo	1,14	0,65	4,54	3,09	2,17	122	35	166	1373	157
Mínimo	0,39	0,06	0,58	0,94	0,37	9	17	4	96	28

Tabla 21. Valores promedio de todos los años de elementos en limbo en la D.O. Ribeira Sacra

	Limbo								
	Fósforo (%)	Potasio (%)	Calcio (%)	Magnesio (%)	Hierro (ppm)	Boro (ppm)	Cobre (ppm)	Manganeso (ppm)	Zinc (ppm)
Media	0,18	1,22	2,15	0,24	70	22	103	340	30
Máximo	0,32	1,77	3,51	0,49	110	44	444	663	76
Mínimo	0,13	0,84	1,11	0,06	42	13	5	104	13

En mosto, se observan valores muy bajos de acidez total y muy altos de pH en alguna finca, problemático de cara a la vinificación. Algunas fincas también tenían muy bajos valores de nitrógeno en mosto. Por subzonas, se puede observar que en Quiroga los valores de grado alcohólico probable y pH son mayores, y los de acidez total y ácido málico menores, lo que se puede correlacionar con su mayor temperatura media y menor precipitación respecto a las otras subzonas, como ya se indicó anteriormente (Tabla 22).

Tabla 22. Valores promedio de todos los años de parámetros enológicos básicos de mosto en la D.O. Ribeira Sacra y sus subzonas

MOSTOS DE LA D.O. RIBEIRA SACRA (PROMEDIO, MÁXIMOS Y MÍNIMOS 2021-2023)										
		Grado alcohólico probable (%v/v)	Acidez total (g/l)	GP/AT	pH	Ác. Málico (g/l)	Ác. Tartárico (g/l)	Nitrógeno amínico (mg/l)	Nitrógeno amoniacal (mg/l)	Nitrógeno total (mg/l)
Ribeira Sacra (todas)	Promedio	12,28	4,85	2,71	3,57	2,17	4,58	107	70	177
	Máximo	16,84	11,90	6,24	4,17	5,00	5,70	267	139	398
	Mínimo	9,21	2,70	0,86	2,97	0,50	3,66	24	10	34
Promedio Subzonas	Amandi	12,51	4,77	2,81	3,61	2,10	4,47	115	71	186
	Chantada	11,82	5,12	2,38	3,47	2,36	4,63	91	66	157
	Quiroga-Bibei	13,51	3,92	3,64	3,70	1,63	4,62	85	63	148
	Ribeiras do Sil	11,77	5,20	2,42	3,61	2,34	4,59	151	86	237

Respecto a los elementos en mosto, los valores de potasio exceden ampliamente a los reportados por Freijido et al (2012) para la Mencía en el Ribeiro (Tabla 23).

Tabla 23. Valores promedio de todos los años de elementos en mostos en la D.O. Ribeira Sacra

	Elementos del mosto (mg/L)										
	Fósforo	Potasio	Calcio	Magnesio	Hierro	Boro	Cobre	Manganeso	Zinc	Aluminio	Sodio
Media	144	2115	42	54	0,07	1,56	1,13	1,00	0,36	0,06	3,15
Máximo	403	3837	100	115	0,41	3,52	5,86	4,72	1,23	0,42	8,59
Mínimo	82	1195	19	37	0,02	0,11	0,41	0,22	0,21	0,02	1,13

Se hizo, al igual que con las otras D.O., un análisis de correlaciones entre parámetros. Para la Ribeira Sacra en conjunto no se encontraron correlaciones significativas entre los parámetros de suelo y mosto. Se hizo por subzonas, y tampoco se observó correlación en ninguna de ellas que se repitiera entre años (Tablas 24 a 27).

Tabla 24. Parámetros de suelo y mosto correlacionados con el grado alcohólico probable, la acidez total y la relación entre ambas. Subzona Chantada.

	Chantada 2021	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	K (mg/Kg)	0,311		-0,335
Mosto	Acidez total (g/l)		-0,312	-0,830
	Ác. Málico (g/l)	0,553	-0,431	-0,579
	GAP (%v/v)	-0,312		0,500
	GAP/AT	-0,830	0,500	

	Chantada 2022	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	Ca/Mg		-0,356	
	K/Mg		-0,353	
Mosto	Acidez total (g/l)			-0,776
	Ác. Málico (g/l)	0,721	-0,338	-0,704
	GAP (%v/v)			0,508
	Nitrógeno Amínico	0,540	-0,421	-0,633
	Nitrógeno amoniacal	0,550	-0,382	-0,508
	GAP/AT	-0,776	0,508	
	Nitrógeno total	0,572	-0,437	-0,628
	Boro	0,329		-0,297
	Calcio	-0,358	0,390	0,442
	Hierro	0,630		-0,585
	Potasio	0,538	-0,353	-0,580
	Manganeso		0,531	
	Fósforo	0,470		-0,341

	Chantada 2023	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Mosto	Acidez total (g/l)		-0,567	-0,830
	Ác. Málico (g/l)	0,511	-0,350	-0,471
	GAP (%v/v)	-0,567		0,745
	Nitrógeno Amínico	0,319		-0,301
	Nitrógeno amoniacal	0,322	-0,332	-0,352
	pH-uva	-0,383	0,433	0,429
	GP/AT	-0,830	0,745	
	Nitrógeno total	0,387	-0,366	-0,407

Tabla 25. Parámetros de suelo y mosto correlacionados con el grado alcohólico probable, la acidez total y la relación entre ambas. Subzona Amandi.

	Amandi 2022	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	Mg (mg/Kg)		-0,455	
	Ca cmol(+)/Kg-su		-0,440	-0,435
	CiCe cmol(+)/Kg-su		-0,445	-0,426
	K/Mg-su		0,385	
Mosto	Acidez total (g/l)			-0,672
	GAP %v/v			0,385
	Nitrógeno Amínico			0,456
	Nitrógeno amoniacal		0,515	
	pH	-0,595		0,602
	GAP/AT	-0,672	0,385	
	Nitrógeno total		0,415	0,485
	Magnesio		0,717	0,368
	Sodio	-0,536		0,500

	Amandi 2023	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	M.O. (%)		-0,370	
	C (%)		-0,370	
Mosto	Acidez total (g/l)			-0,602
	pH-uva	-0,481		0,500
	GP/AT	-0,602		

Tabla 26. Parámetros de suelo y mosto correlacionados con el grado alcohólico probable, la acidez total y la relación entre ambas. Subzona Quiroga-Bibei.

	Quiroga-Bibei 2021	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	pH (H2O)	-0,552		0,523
	N (%)	0,674		-0,600
	Al (cmol(+)/Kg)			-0,552
Mosto	Acidez total (g/l)			-0,944
	Ác. Málico (g/l)	0,523		-0,539
	Ác. Tartárico (g/l)	0,821		-0,740
	GAP/AT	-0,944		
	Cobre	0,629		-0,644
	Manganeso		-0,568	-0,556

	Quiroga-Bibei 2022	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Mosto	Acidez total (g/l)		-0,739	-0,943
	GAP %v/v	-0,739		0,809
	pH	-0,660		0,556
	GAP/AT	-0,943	0,809	1
	Potasio	-0,660		0,556
	Fósforo	-0,613	0,629	0,600

	Quiroga-Bibei 2023	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	Sodio (cmol(+)/Kg)	-0,764	0,556	0,733
Mosto	Acidez total (g/l)		-0,584	-0,944
	GAP %v/v	-0,584		0,644
	Nitrógeno amoniacal		-0,584	
	pH	-0,705		0,674
	GAP/AT	-0,944	0,644	

Tabla 27. Parámetros de suelo y mosto correlacionados con el grado alcohólico probable, la acidez total y la relación entre ambas. Subzona Ribeiras do Sil.

	Ribeiras do Sil 2021	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Suelo	C/N		-0,491	
	Aluminio (cmol(+)/Kg)		-0,486	
Mosto	ACIDEZ-uva			-0,881
	Ác. Málico-uva	0,636		-0,574
	GP %v/v			0,600
	GP/AT	-0,881	0,600	
	Calcio	0,550		-0,600
	Cobre		0,564	
	Magnesio	0,587	-0,491	-0,600
	Sodio		0,564	
	Fósforo	0,514		

	Ribeiras do Sil 2021	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Mosto	Acidez total (g/l)			-0,833
	GAP %v/v			0,624
	Nitrógeno amoniacal	0,574		-0,527
	GAP/AT	-0,833	0,624	
	Calcio		0,550	

	Ribeiras do Sil 2021	Acidez total uva (g/l)	Grado alcohólico probable (%v/v)	GAP/AT
Mosto	Acidez total (g/l)			-0,833
	Ác. Tartárico /g/l)		-0,685	-0,527
	GAP %v/v			0,648
	GAP/AT	-0,833	0,648	

Al igual que en el caso de la D.O. Monterrei, se eliminaron aquellas parcelas con Fósforo disponible mayor de 50 mg/kg, Potasio asimilable mayor de 300 mg/kg, y Magnesio cambiable mayor de 200 mg/kg para detectar los niveles recomendados de cada parámetro para la fertilización en esta D.O. Los resultados obtenidos para alcanzar un grado alcohólico probable en mosto entre 12,5% y 13,5% v/v (valores establecidos previamente para la Mencía) fueron los siguientes (Tabla 28):

Tabla 28. Niveles de referencia en suelo recomendados para la D.O. Ribeira Sacra

DO	Materia orgánica (%)	Nitrógeno (%)	Relación C/N	Fósforo disponible (ppm)	Potasio asimilable (ppm)	Magnesio cambiable (ppm)	Relación Ca/Mg	Relación K/Mg
RIBEIRA SACRA	4,0-5,5	0,17-0,19	13,0-14,5	20-26	170-230	70-120	4,8-7,0	0,7-0,85

Al igual que en los anteriores casos, se recomienda encalar para alcanzar un pH, calcio y capacidad de intercambio catiónico adecuados, y eliminar el aluminio del complejo de cambio (Tabla 29).

Tabla 29. Niveles de referencia en suelo obtenidos pero que deberían corregirse. D.O. Ribeira Sacra

VALORES A CORREGIR					
	pH (H2O)	Calcio (cmol(+)/Kg)	Aluminio (cmol(+)/Kg)	Capacidad de intercambio catiónico (cmol(+)/Kg)	% saturación complejo cambio
Obtenido	5,3-6,0	3,0-7,0	0,15-1,2	5,7-8,0	74-82
DESEABLE	6,0-6,5	mínimo 5	0	mínimo 10-12	> 95%

4.2 Estudio de la microbiota en suelos

En los gráficos que a continuación se indican, en primer lugar para el reino de los hongos, por una parte la prevalencia y la abundancia teniendo en cuenta todas las fincas evaluadas a nivel del rango taxonómico más general filum (Figura 16), la abundancia por denominación de origen a nivel de familia (Figura 17), y la diversidad α expresada por el Índice de Chao1, e índice de Shanon, y la β diversidad (Figura 18) teniendo en cuenta los géneros identificados; los patrones de diversidad se indican a nivel de familia (Figura 19) y de género (Figura 20). Se han incluido en los gráficos resultados previos de los que se disponía de otras Denominaciones de Origen (D.O. Ribeiro y D.O. Rías Baixas), si bien de la D.O. Rías Baixas solamente se disponía de 3 muestras.

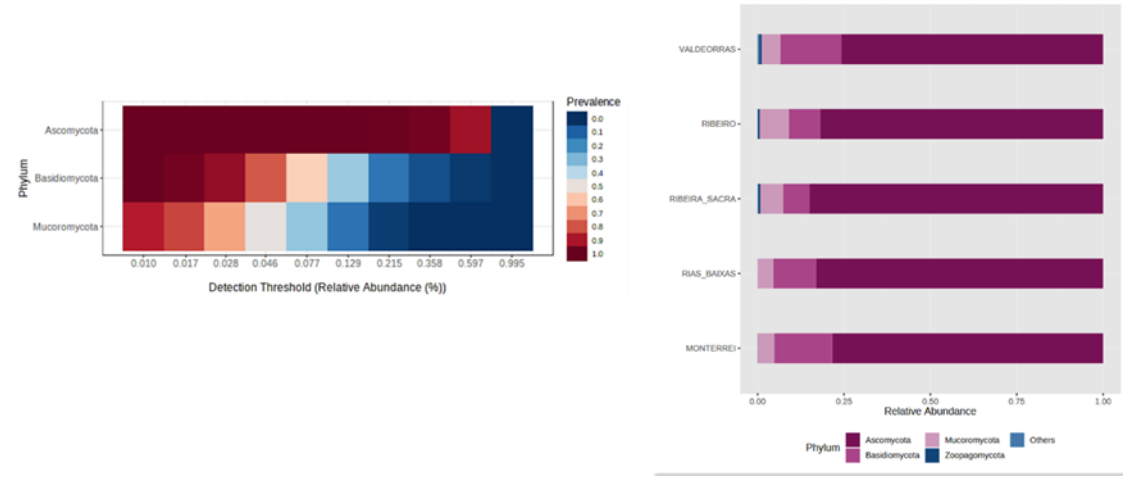

Figura 16. Prevalencia de los filum de hongos en las distintas de D.O. y abundancia de los mismos en función de las D.O.

Los filum más prevalentes son Ascomycota y Basidiomycota y por último Mucoromycota. Los dos primeros son muy habituales en todos los viñedos. A nivel de abundacia, Ascomycota es muy abundante en todas las D.O. y Basidiomycota es muy abundante sobre todo en Monterrei y Valdeorras.

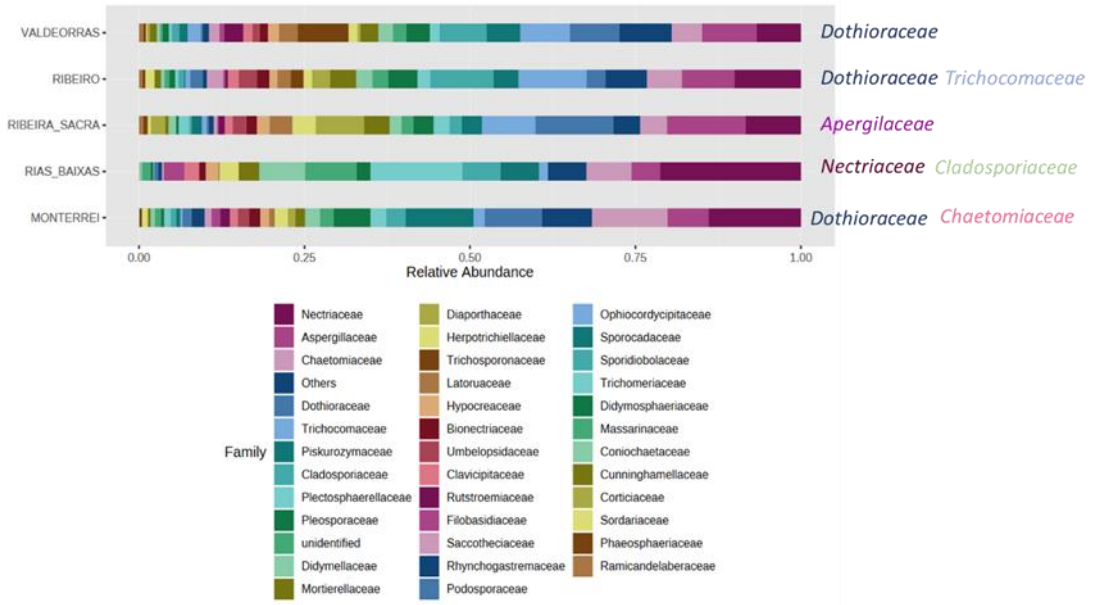

Figura 17. Abundancia de familias de hongos para las distintas D.O.

En 3 de las D.O. (Valdeorras, Ribeiro y Monterrei), la familia Dothioracea es la más abundante, destacan en Ribeiro además la familia Trichomaceae, en Ribeira Sacra Aspergillaceae, y en Rías Baixas Nectriaceae y Cladosporaceae.

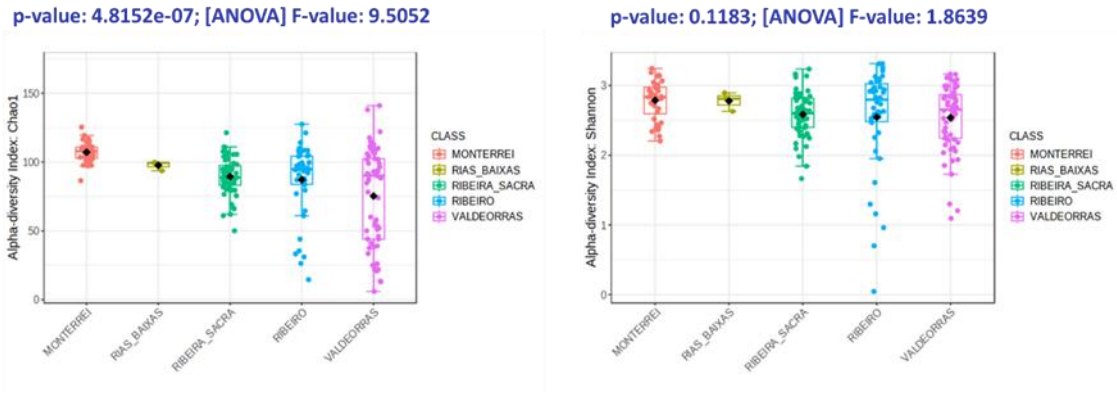

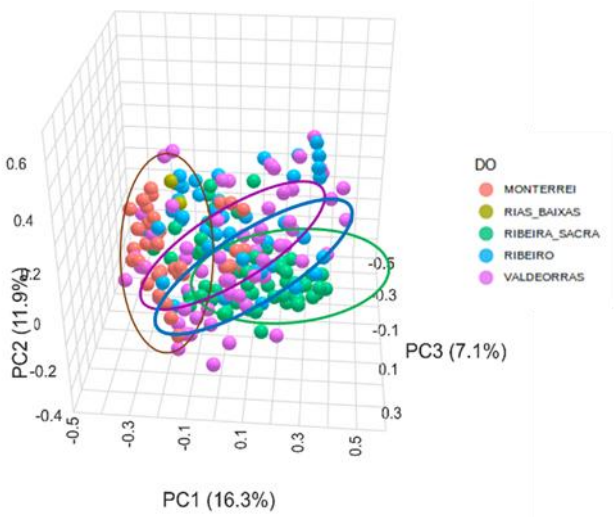

Figura 18. Diversidad α y β de géneros de hongos identificados en las distintas D.O.

La diversidad α, evaluada a través del índice de Chao1, muestra diferencias significativas entre la diversidad encontrada en las distintas D.O. Siendo Valdeorras la de menor diversidad y Monterrei la de mayor. La diversidad β se muestra como una variable diferenciadora entre D.O., las DO más similares son Ribeiro y Valdeorras, frente a Monterrei y Ribeira Sacra (Figura 18).

Por lo que se refiere a los patrones de diversidad a nivel de familia (Figura 19), dentro de las más abundantes, Monterrei se caracteriza por Chaetomiacea, Nectriaceae, Pleosporaceae; Ribeira Sacra por Trichomaceae, Doithioraceae, Diaportaceae, Aspergillaceae, Latouraceae, Mortierallaceae, Corticiaceae, y Ribeiro por Trichosporaceae, Cladosporiaceae, Podosporaceae. Valdeorras solamente tiene una familia más prevalente.

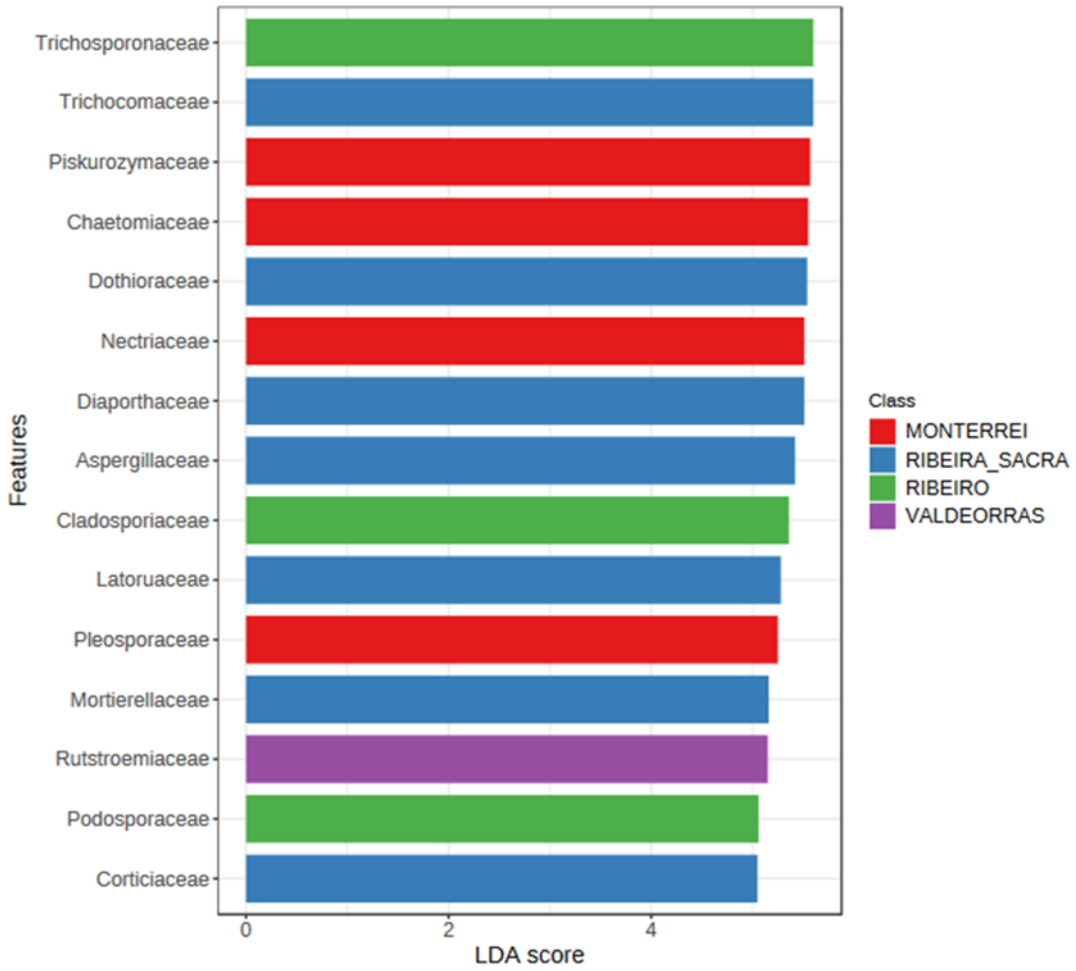

Figura 19. Patrones de diversidad de familias de hongos en función de las diferentes DOs.

A nivel de género (Figura 20), la diferenciación entre la diversidad entre D.O. viene dada fundamentalmente por la abundancia en Monterrei de Solicizima, Fusarium, Alternaria y Chaetomiu; en Ribeira Sacra por Talaromyces, Dothiora, Penicillum, Diaporthe, Polyschema, Alternaria, Sistotrema; en Ribeiro por Cladosporium y Cladorrhinum y en Valdeorras por Neotrichoporum y Clarieedia.

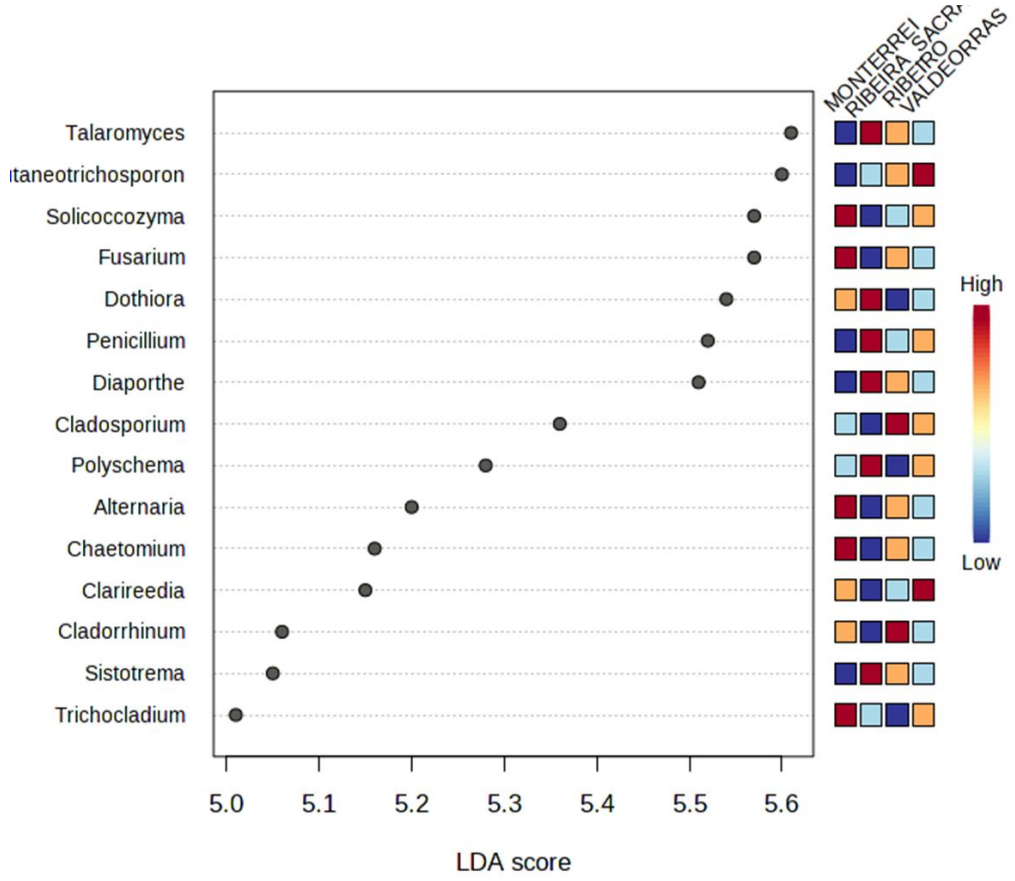

Figura 20. Patrones de diversidad de géneros de hongos en función de las diferentes D.O.

En relación a las bacterias, se muestra por una parte la prevalencia y la abundancia teniendo en cuenta todas la fincas evaluadas a nivel del rango taxonómico más general filum (Figura 21), la abundancia por D.O. a nivel de familia (Figura 22), y la diversidad α expresada por el Índice de Chao1, e índice de Shanon, y la β diversidad (Figura 23) teniendo en cuenta los géneros identificados; los patrones de diversidad se indican a nivel de familia (Figura 24) y de género (Figura 25). Se han incluido en los gráficos resultados previos de los que se disponía de otras Denominaciiones de Origen (D.O. Ribeiro y D.O. Rías Baixas), si bien de la D.O. Rías Baixas solamente se disponía de 3 muestras.

La diversidad de bacterias es mayor que la de los hongos, sin embargo, los hongos representan el 70% de la biomasa del suelo, debido a su mayor tamaño.

Vemos que, independiente de la D.O, la prevalencia y abundancia de las bacterias pertenecen a 3 filum Actinomycetota, Pseudomonadota y Bacillota; en cuarto lugar se encuentran Acidobacteriota, muy relacionado con el pH del suelo. Predomina en Monterrei y Valdeorras Actinomycetota. Menor contenido en Ribeira Sacra, y mayor de Acidobacteriota en Ribeiro.

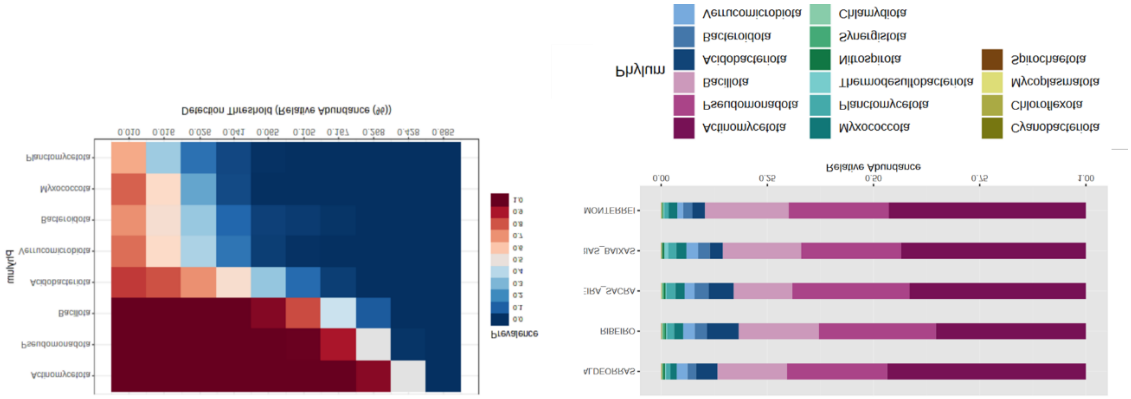

Figura 21. Prevalencia de los filum de bacterias en las distintas de D.O.; y abundancia de los mismos en función de las D.O.

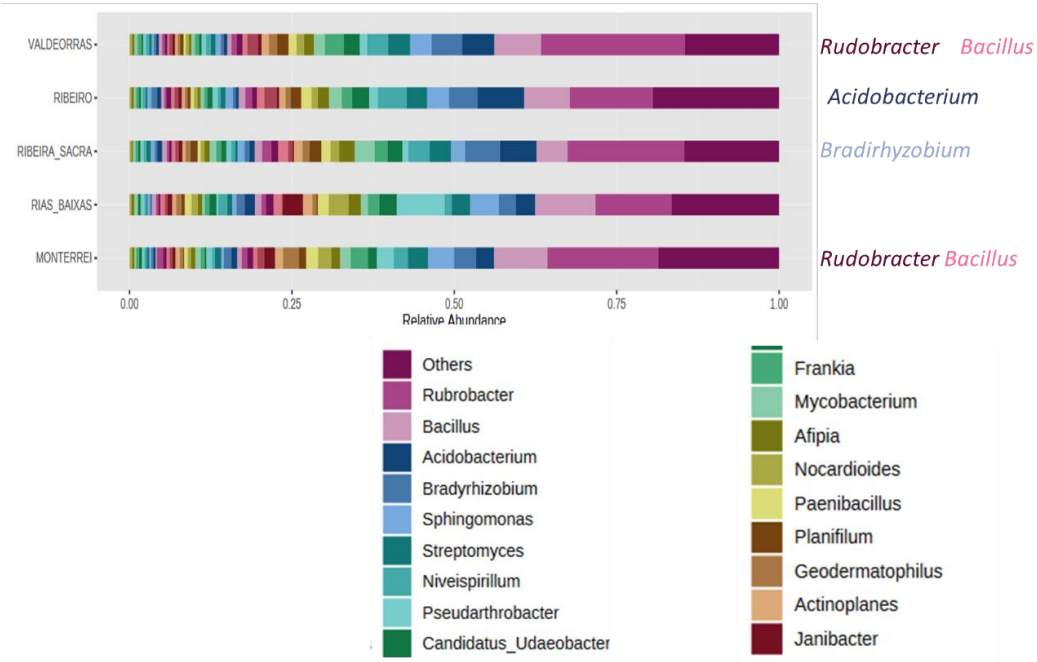

Figura 22. Abundancia de familias de bacterias para las distintas D.O.

A nivel de género, los más abundantes han sido Rudobracter, Bacillus, Acidobacterium, Bradirhizobim Sphingomonas; Rudrobacte es el más abundante en Valdeorras y Monterrei; Bacillus es abundante en la mayoría de las D.O., a excepción de Ribeira Sacra; Acidobacterium destaca en Ribeiro y Bradirhyzobium en Ribeira Sacra.

En bacterias existe una buena correlación tanto para la riqueza (Índice de Chao 1) como la abundancia de la diversidad (Índice de Shanon), pero sobre todo el índice de Shanon sería un buena variable de diferenciación. Monterrei y Valdeorras son las más diferentes en cuanto a riqueza de bacterias (índice de Chao 1), y teniendo en cuenta la abundancia dentro de la riqueza siguen siendo las más diferentes (índice de Shanon). La diversidad β muestra una mayor diferenciación entre D.O. Tal como se observa en el análisis de componentes principales, las 3 componente explican un 48%, lo cual era de esperar por la mayor diversidad de la que hablamos inicialmente de este phylum, por lo que la diversidad β la podemos considerar como una variable de diferenciación de la D.O. Monterrei frente a todas las demás y sobre todo a Ribeira Sacra y Ribeiro.

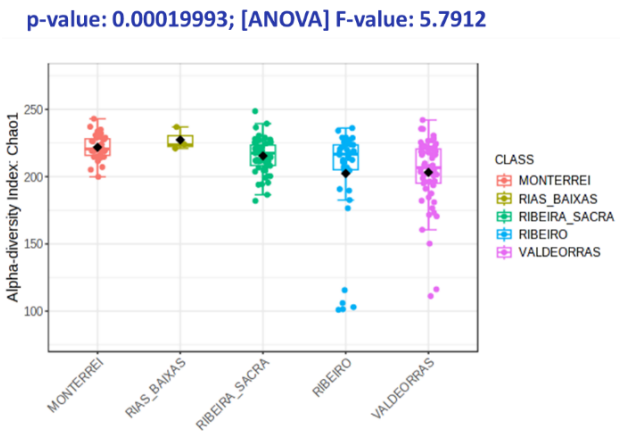

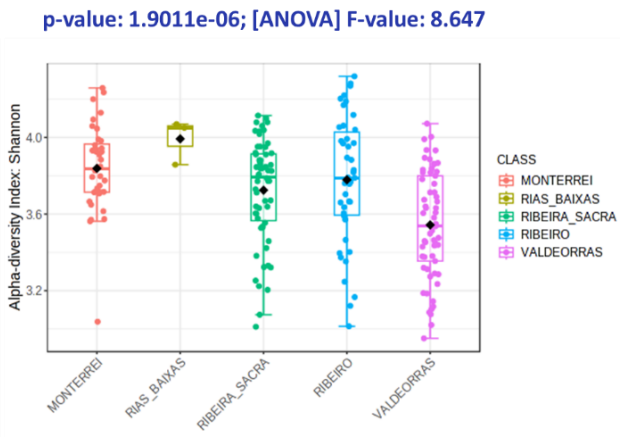

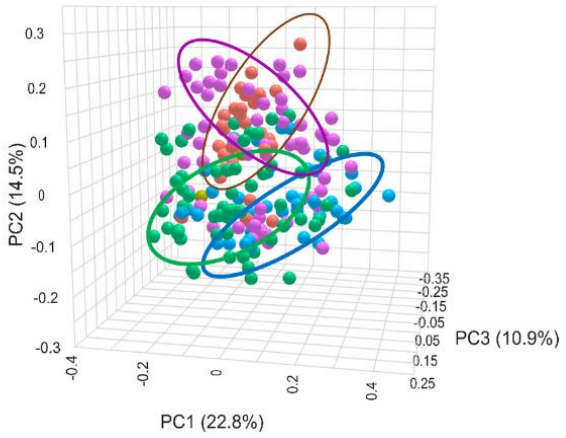

Figura 23. Diversidad α y β de géneros de bacterias identificados en las distintas D.O.

El perfil de bacterias se presenta a nivel de órden y de género. Teniendo en cuenta los órdenes más abundantes, Ribeira Sacra se caracteriza por un mayor número de ordenes, concretamente 6; en Ribeiro 5 y en Monterrei 2. No observándose dentro de los órdenes más abundantes ninguno en Valdeorras.

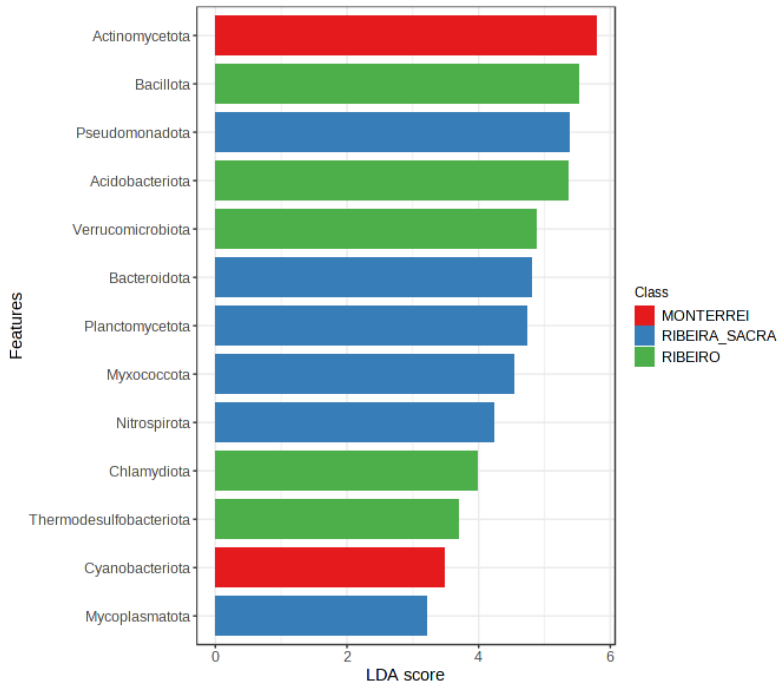

Figura 24. Patrones de diversidad de familias de bacterias en función de las diferentes D.O.

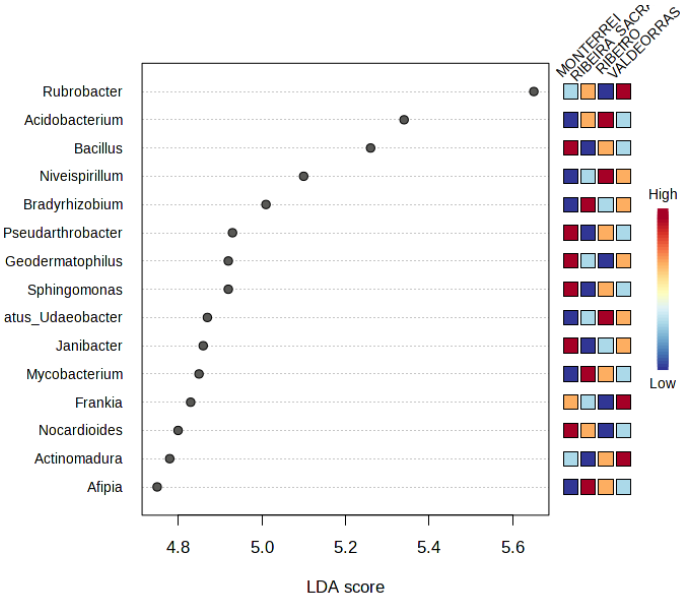

Figura 25. Patrones de diversidad de géneros de bacterias en función de las diferentes D.O.

El perfil de la diversidad de las D.O. a nivel de género viene determinada por Pseudodarthrobacter, Geodermathophilus, Sphingomonas, Janibacter, Neocardioles en Monterrei; Bradirhizobium, Mycobacterium, Afipia en Ribeira Sacra; y por Acidobacterium, Niveispirilum, Janibacter, Rubrobacter, Frankia, Actinomadura en Ribeiro.

En las Figuras 26 y 27 se muestran los resultados del análisis de componentes principales, en el que se incluyen como variables dependientes los valores medios de los parámetros analíticos de la fertilidad de suelo para cada parcela de cada D.O. y la abundancia de la diversidad encontrada a nivel de familia en hongos (Figura 26) y bacterias (Figura 27) para cada parcela.

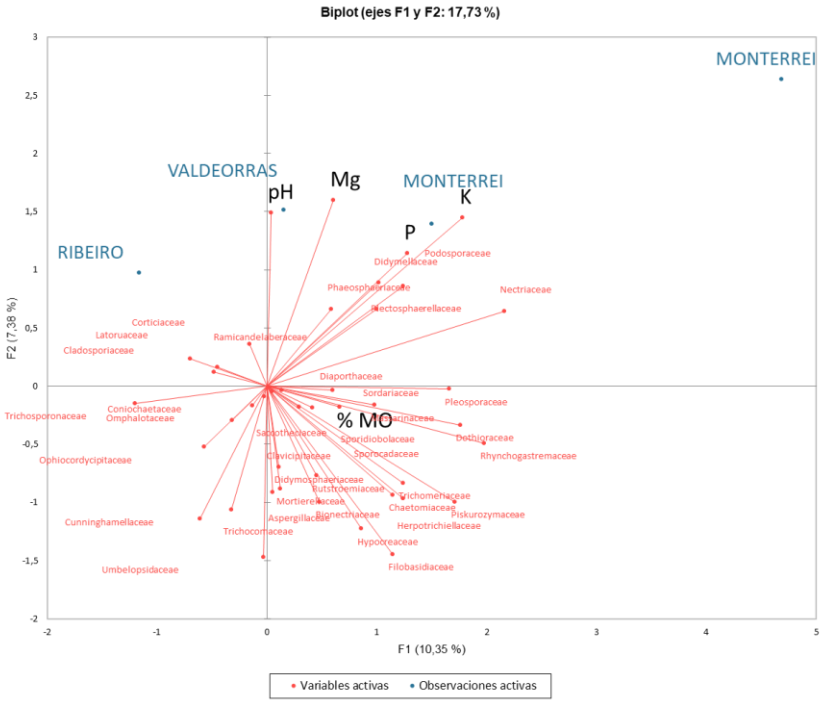

Figura 26. Análisis de componentes principales para las variables de fertilidad del suelo y la diversidad de hongos, a nivel de familia, asociada a cada D.O.

Las componentes extraídas explican muy poco la diferenciación entre D.O. en el caso de los hongos. La mayoría de la diversidad se agrupa con una mayor abundancia de materia orgánica, independientemente de la D.O. En el agrupamiento de algunas familias influyen los altos contenidos de fósforo, potasio y magnesio y un pH más elevado.

En el caso de las bacterias, las componentes extraídas explican una mayor diferenciación entre D.O. por la diversidad de familias de bacterias. Solo un pequeño grupo de familias está relacionado con los parámetros de fertilización del suelo. El mayor contenido en materia orgánica no parece determinante de la diversidad de bacterias.

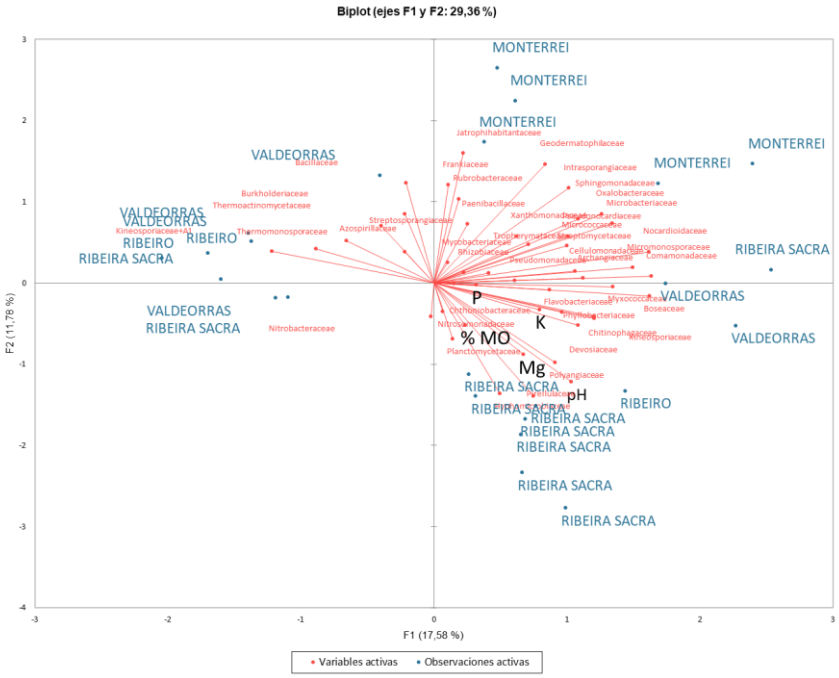

Figura 27. Análisis de componentes principales para las variables de la fertilidad del suelo y la diversidad de hongos, a nivel de familia, asociada a cada D.O.

4.3 Aplicación Web-GIS - FERTISOST

Los resultados obtenidos han contemplado la localización catastral de las parcelas de estudio, a partir de la información suministrada por las bodegas involucradas en el estudio, así como por AGACAL (EVEGA). En total se ha incorporado información de 23 parcelas en la D.O. Ribeiro, 16 parcelas en la D.O. Monterrei, y 30 parcelas en la D.O. Ribeira Sacra.

Como ejemplo se exponen los niveles recomendados por AGACAL (EVEGA) para la D.O. Valdeorras, límites que han sido incorporados en el visualizador de análisis de cada parcela individual, en el apartado de suelos.

DO		pH H2O-su	M.O. %-su	N %-su	C/N-su	P mg/Kg-su	K mg/Kg-su	Mg mg/Kg-su	Ca cmol(+)/Kg-su	CiCe cmol(+)/Kg-su	Ca/Mg-su	K/Mg-su
VALDEORRAS	rango adecuado	5,8-6,0	3,0-3,5	0,16-0,19	11,4-12,5	22-32	150-200	80-110	5,0-7,0	6,0-7,5	5,8-7,2	0,6-0,75

Cabe destacar la elevada variabildad de los datos obtenidos en cada una de las D.O. lo que ha dificultado el análisis de la información, en la busca de una solución única para el conjunto de la D.O., como ejemplo se expone a seguir las diferencias en pH en suelo de las muestras de la D.O. Ribeira Sacra.

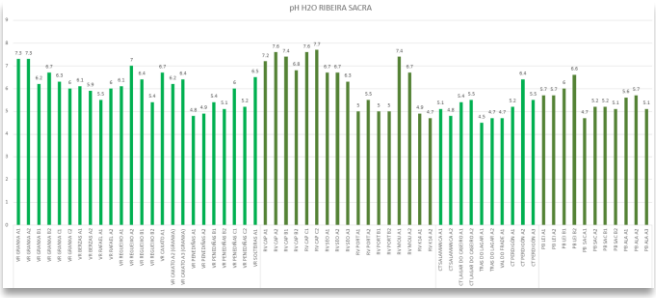

ALGORITMO Y PLATAFORMA

Como resultado final del servicio prestado, se desarrolló una aplicación web, accesible desde cualquier navegador con conexión a internet, en la que cada una de las Denominaciones de Origen tiene un acceso privado que permite visualizar los datos del conjunto de parcelas de la DO. La ubicación de la aplicación web es https://amgeo.es/fertisost/

El sistema de acceso permite que tanto las D.O. como AGACAL (EVEGA) y el equipo de la USC, como administrador de la aplicación accedan a la visualización de los datos. Para ello se ha generado un gestor de usuarios donde los accesos están ligados a una contraseña única por usuario (D.O., AGACAL y EVEGA). Estos datos serán trasladados a AGACAL (EVEGA) de forma segura para garantizar que no exista una usurpación de los mismos por terceros, siendo previsible su entrega empleando el correo electrónico directamente a los responsables del proyecto piloto en AGACAL (EVEGA), para que sean estos a posteriori quienes gestionen la información de acceso a las bodegas involucradas en el proyecto piloto.

DESCRIPCIÓN DEL SISTEMA

El sistema cuenta con un frame principal basado en un mapa, sobre el que se representan las parcelas de cada bodega utilizando como fondo del mapa una ortoimagen. Se dispone de 4 capas de visualización (rendimiento, análisis de suelo, análisis de mosto y análisis de peciolos). En función de la capa seleccionada se colorean las parcelas con una paleta tipo semáforo (rojo, amarillo, verde), mediante el que se indica si la parcela correspondiente está por debajo o por encima de lo esperable en cuanto a la variable representada. En el caso de la producción, se coloreará de verde la parcela que tiene un rendimiento productivo por encima del umbral fijado, mientras que el rojo indicará que su producción es más baja de lo esperable. En el caso de las otras capas, por ejemplo, el suelo, se coloreará verde si no tiene ningún parámetro de los analizados en las muestras de suelo fuera del umbral de tolerancia, y el color rojo si tiene muchos parámetros de análisis fuera de rango.

Se puede interactuar con el mapa, señalando cualquier parcela y, de ese modo, abrir un desplegable en el que se muestra información detallada de esa parcela en relación con la capa seleccionada: características productivas, análisis de suelo, análisis de mosto o análisis de peciolos.

Parcela nº 20 – D.O. Valdeorras

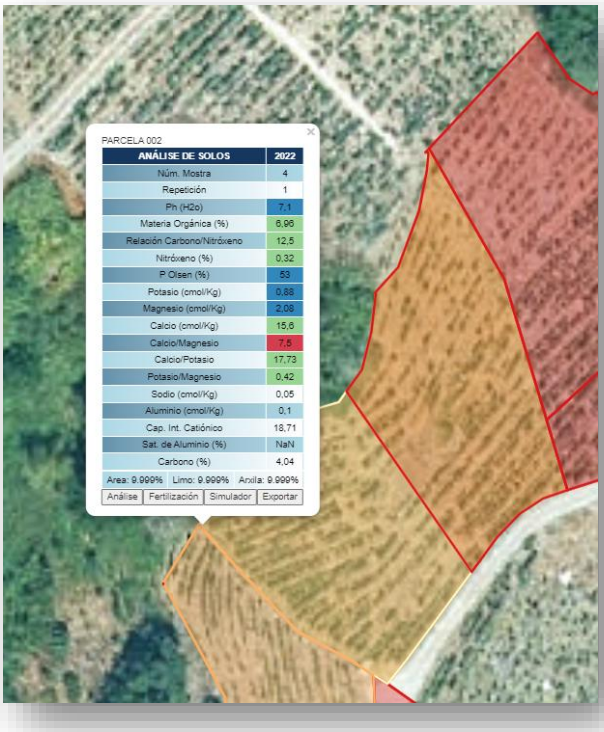

Parcela nº 02 – D.O. Ribeira Sacra

Parcela nº 12 – D.O. Monterrei

Mediante un selector de campaña situado en la parte inferior del mapa, se pueden ver de forma dinámica las variaciones en los parámetros de cada capa en cada uno de los años cargados en el sistema. En cualquier momento se puede realizar una exportación, mediante la cual se recopilan todos los datos de cada parcela y se guardan en formato Excel para su posterior manipulación en un ordenador.

PARCELA 020

ANÁLISE DE SOLOS	2021
Núm. Mostra	60
Repetición	3
Ph (H2o)	5,5
Materia Orgánica (%)	3,62
Relación Carbono/Nitróxeno	10,99
Nitróxeno (%)	0,19
P Olsen (%)	13
Potasio (cmol/Kg)	0,35
Magnesio (cmol/Kg)	0,8
Calcio (cmol/Kg)	2,7
Calcio/Magnesio	3,38
Calcio/Potasio	7,71
Potasio/Magnesio	0,44
Sodio (cmol/Kg)	0,08
Aluminio (cmol/Kg)	0,6
Cap. Int. Catiónico	4,52
Sat. de Aluminio (%)	NaN
Carbono (%)	2,1
Area: 9.999% Limo: 9.999% Arxila: 9.999%	

Análise | Fertilización | Simulador | Exportar

Fertilización recomendada en función das características do solo

PARCELA 020

ANO 2021

Valores de fertilización estimados pola EVEGA en función da analítica de solo do ano correspondente.

APORTACIÓN	CANTIDADE
Materia Orgánica	30 UF
Calcio	2153 UF
Nitróxeno	55 UF
Fósforo	45 UF
Potasio	92 UF
Magnesio	30 UF

También se puede mostrar una visión de análisis, en forma de panel de control, mediante la que se representan gráficamente todos los parámetros registrados para cada parcela en las diferentes campañas.

A continuación, se exponen ejemplos de este aspecto, para una parcela en cada D.O., en el caso de Valdeorras se ha subdividido la imagen disponible en dos, para facilitar su visualización en el presente informe, mientras que en las D.O. Monterrei y Ribeira Sacra se añade la figura tal cual se visualiza en la aplicación, donde cabe señalar que es posible interactuar en la misma seleccionando los parámetros de interés en los apartados de rendimiento, suelo, mosto y peciolos.

Parcela nº 20 – D.O. Valdeorras

Parcela nº 20 – D.O. Valdeorras

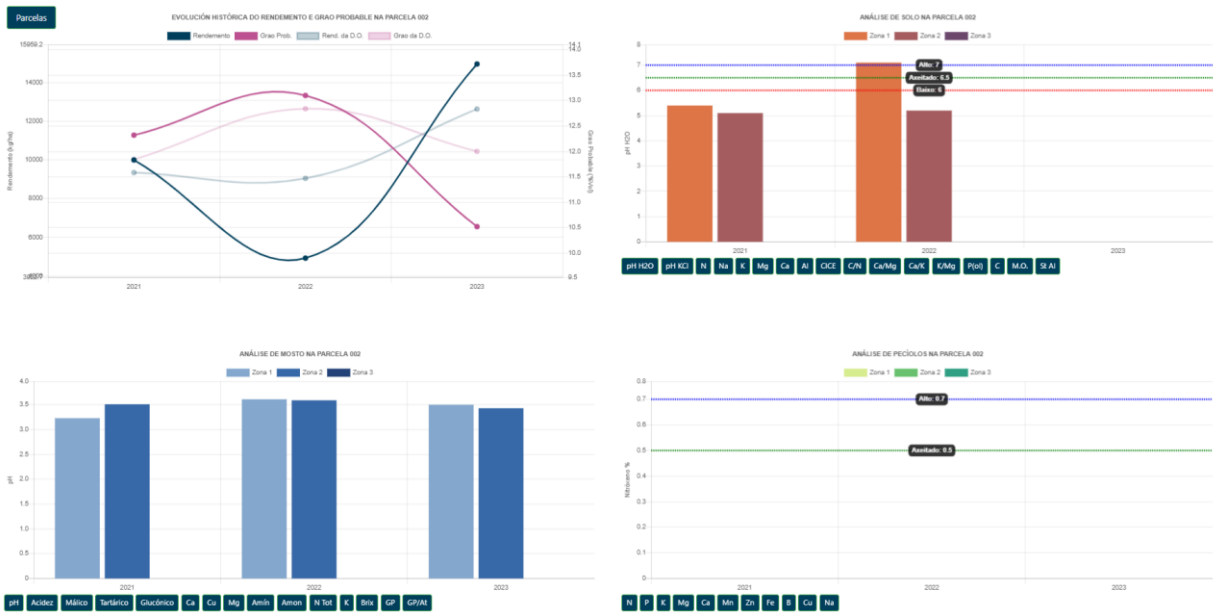

Parcela nº 02 – D.O. Ribeira Sacra

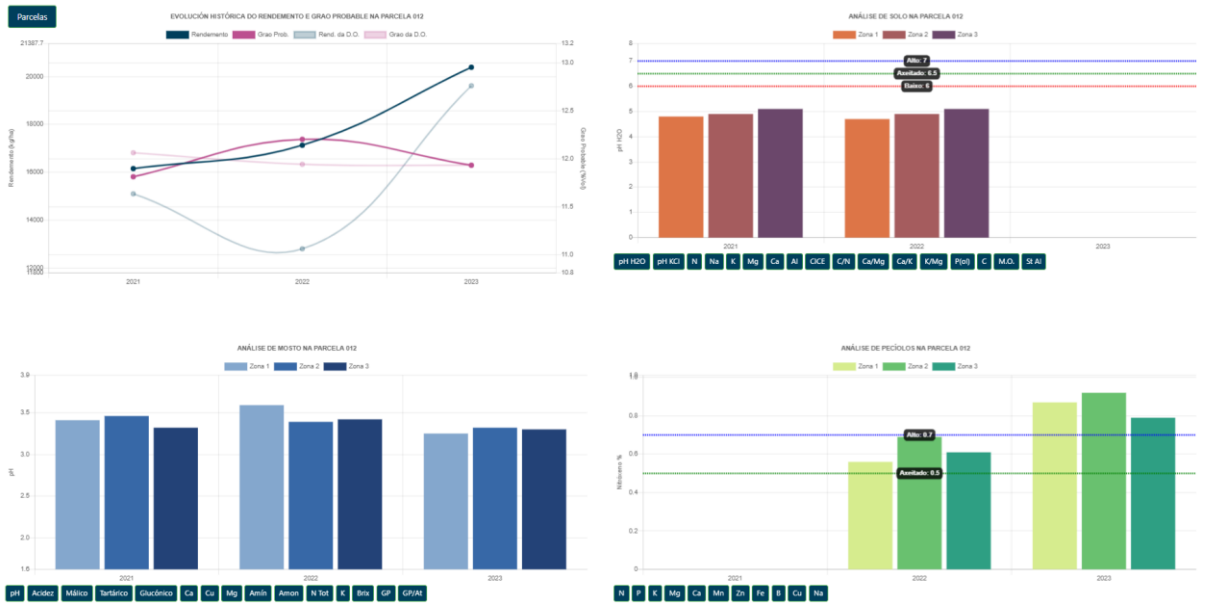

Parcela nº 12 – D.O. Monterrei

ALGORITMO DE OPTIMIZACIÓN DE LA FERTILIZACIÓN

Si se activa la capa de visualización de "suelo" se dispondrá de dos herramientas para optimizar la fertilización:

Fertilización recomendada: aplicación mediante la cual se calculan a través de unas ecuaciones, las UF necesarias para cada parcela, a partir de los resultados de las analíticas de suelo de cada año.

Simulador: se trata de una aplicación interactiva que permite estimar cual será la producción estimada de la parcela en función de los parámetros analizados en las muestras tomadas en suelo, junto con la previsión de fertilización que se prevé aplicar. Para esta aplicación se desarrolló un algoritmo basado en inteligencia artificial, que se describe a continuación.

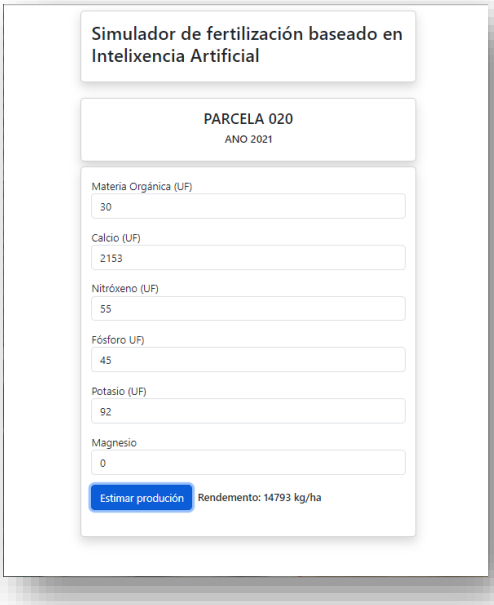

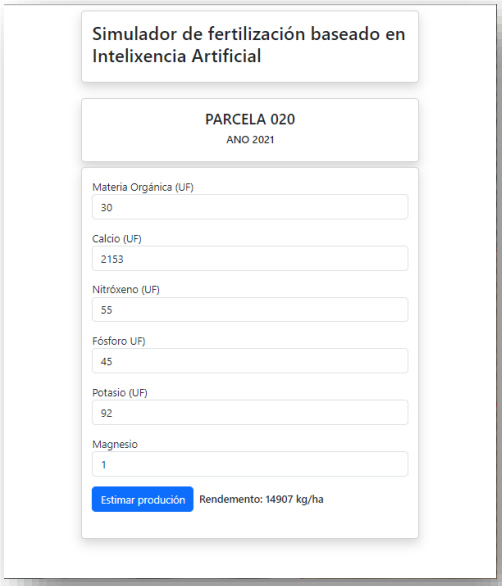

Se ha desarrollado un sistema basado en inteligencia artificial con el objetivo de anticipar la producción de cada parcela de viñedo, considerando las particularidades de su suelo y la fertilización aplicada. La arquitectura se basa en redes neuronales artificiales, en donde la red neuronal se compone de múltiples capas, destacando una capa de entrada, una capa oculta con 8 neuronas y una capa de salida con una única neurona, y se ha optado por emplear el algoritmo de optimización Adam, una técnica de optimización eficiente para el aprendizaje de modelos de redes neuronales simples. Además, la función

de pérdida (loss) se ha ajustado a un valor de 0.1, buscando optimizar la precisión del modelo. Con todo eso, la estimación de producción tiene una imprecisión en torno a 2500 kg/ha, dependiendo de la Denominación de Origen en la que se aplique.

En el proceso de construcción de la red neuronal, se ha trabajado con conjuntos de datos recopilados durante tres campañas agrícolas diferentes: 2021, 2022 y 2023. Esa colección de datos está formada tanto por los análisis de suelo realizados, datos productivos históricos de las parcelas y fertilizaciones necesarias. Es importante destacar que cada red neuronal se ha entrenado de manera independiente para cada Denominación de Origen, lo que permitió obtener modelos específicos y adaptados a las características únicas de cada región vitivinícola.

El desarrollo de este sistema se ha llevado a cabo utilizando TensorFlow, una biblioteca de código abierto especializada en aprendizaje profundo. TensorFlow, con su versatilidad y robustez, proporciona una infraestructura sólida para construir y entrenar modelos de redes neuronales. En el contexto de la integración del sistema como una aplicación web, se ha aprovechado TensorFlow.js, una extensión de TensorFlow diseñada para ejecutar modelos de aprendizaje profundo directamente en navegadores web. Este enfoque no solo garantiza una interactividad rápida y fluida para los usuarios, sino que también descarga la carga computacional del servidor, mejorando así la eficiencia del sistema.

CONSIDERACIONES FINALES DE CARÁCTER GENERAL

El sistema permite gestionar grandes volúmenes de información de forma más eficiente. La información relacionada con la producción, analíticas de muestras de suelo, analíticas de mostos y analíticas de peciolos constituye una colección elevada de datos (miles de datos) de diferente naturaleza, unidades, etc. Además, lo habitual es recopilarla en diferentes formatos (word, excel, etc). Mediante este sistema se dispone de un repositorio centralizado, con datos revisados y homogenizados, con todas las reservas de privacidad necesarias, y que, si fuese necesario, en cualquier momento se pueda exportar a un formato excel para realizar posteriores análisis por parte de la bodega.

Se dispone de un panel de control mediante el que se muestran gráficamente todos los datos mecionados anteriormente, pero de una forma visual que permita al viticultor analizarlos y detectar

anomalías en algún parámetro, valorar tendencias, comparar, etc. Mención especial se hace a la posibilidad de visualizar gráficamente parámetros analizados de suelo, peciolo y mosto; pudiendo valorar en un simple vistazo si hay correlación entre un elemento cualquiera, por ejemplo, Calcio, en suelo, peciolo y mosto y de ese modo ver si la asimilación de la fertilización es la prevista. Otro ejemplo es poder ver gráficamente y en un simple vistazo si hay interacción entre determinados elementos del suelo y la asimilación que la planta hace de un nutriente concreto.

Mediante el simulador de fertilización desarrollado, el viticultor puede ver qué efecto tiene en la producción aumentar unos fertilizantes frente a otros, pudiendo con un simple click estimar la producción que se espera tener aplicando una cantidad mayor o menor de cada fertilizante.

Por último, cabe mencionar que mediante este sistema el viticultor puede tomar decisiones más inteligentes, detectando tendencias, encontrando interacciones entre elementos y simulando diferentes escenarios de fertilización, para de ese modo poder estimar una monetización (de ingresos y gastos) y tomar en cada caso la decisión que más le convenga.

5 ACTIVIDADES DE DIVULGACIÓN

Jornada final de difusión del proyecto, realizada el 23/11/2023 en el Pazo de Toubes (Ourense), con 60 asistentes de diversas Denominaciones de Origen. Dicha jornada fue publicitada en el Jornal Digital Agrario Campo Galego (https://www.campogalego.es/jornada-sobre-fertilizacion-sostenible-y-estado-nutricional-de-los-suelos-viticolas-gallegos/). Las ponencias de difusión de los resultados del proyecto fueron impartidas por Emilia Díaz Losada y María Dolores Loureiro y por Javier Cancela y Xesús Pablo González.

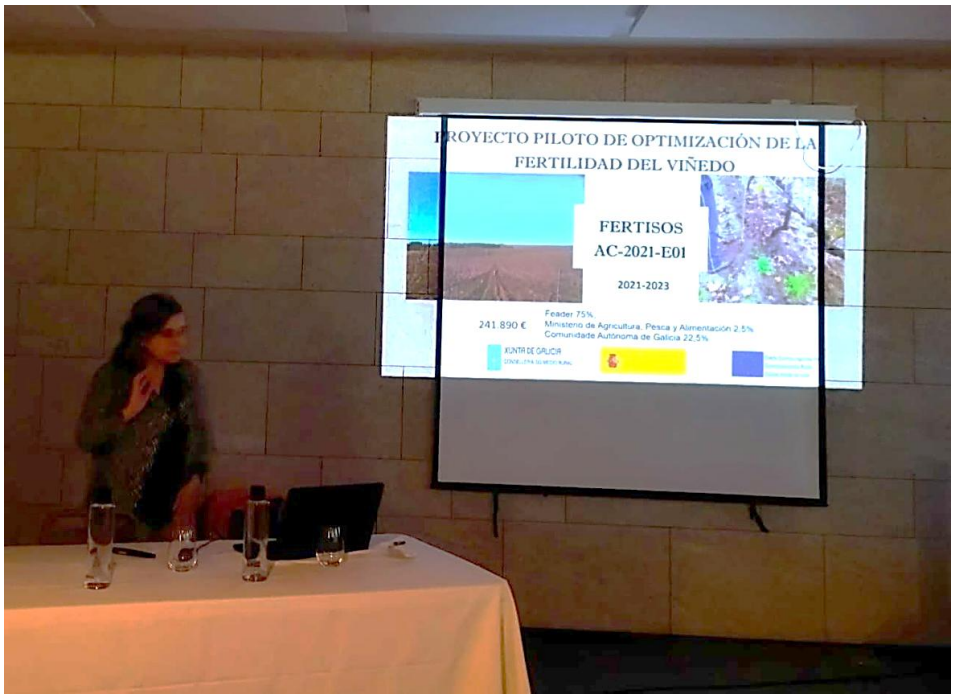

Emilia Díaz Losada impartiendo la charla FERTISOS: Proyecto piloto de optimización de la fertilización del viñedo (ACE-2021-E01).

Javier Cancela impartiendo la charla Herramienta tecnológica de fertilización sostenible del viñedo.

PONENCIAS EN CONGRESOS:

- Variación de la fertilidad de suelos y calidad del mosto en el viñedo gallego. M.D. Loureiro Rodríguez; M.J. Graña Caneiro; A. Díaz-Fernández; E. Díaz Losada. IV Jornadas del Grupo de Viticultura: Acta de Horticultura: Comunicaciones Técnicas Sociedad Española de Ciencias Hortícolas: 26-28 de octubre 2022, Pamplona/Iruña, ISBN 978-84-09-38456-3, págs. 428-431 (ANEXO con la comunicación)

6 REFERENCIAS BIBLIOGRÁFICAS

- Alake, R. (25 de junio de 2020). Understanding and Implementing LeNet-5 CNN Architecture (Deep Learning). Obtenido de Towards DataScience: https://towardsdatascience.com/understanding-and-implementing-lenet-5-cnn-architecture-deep-learning-a2d531ebc342
- Arrobas, M., Ferreira, I. Q., Freitas, S., Verdial, J., Rodrigues, M. A. (2014). Guidelines for fertilizer use in vineyards based on nutrient content of grapevine parts. Sci. Hortic. 172, 191-198.
- Benito, A., Romero, I., Domínguez, N., García-Escudero, E., Martín, I. (2013). Leaf blade and petiole analysis for nutrient diagnosis in Vitis vinifera L. cv. Garnacha tinta. Aus. J. Grape Wine Res. 19, 285-298.
- Blouin, J.; Guimberteau, G. (2004). Maduración y madurez de la uva. Ed. Mundi Prensa.
- Champagnol, F. (1990). Rajeunir le diagnostic foliaire. Prog. Agric. Vitic. 107, 343-351.
- Christensen, P. (1969). Seasonal changes and distribution of nutritional elements in Thompson Seedless grapevines. Am. J. Enol. Vitic. 20, 176-190.
- Chuvieco, E. (1990). Fundamentos de la Teledetección Espacial (Primera ed.). Madrid: Ediciones Rialp, S.A.
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing, 79-97. doi:http://dx.doi.org/10.1016/j.isprsjprs.2014.02.013
- de Castro, A., Peña, J., Torres-Sánchez, J., Jiménez-Brenes, F., Valencia-Gredilla, F., Recasens, J., & López-Granados, F. (2020). Mapping Cynodon Dactylon Infesting Cover Crops with an Automatic Decision Tree-OBIA Procedure and UAV Imagery for Precision Viticulture. Remote Sensing (12 (1) 56). doi:https://doi.org/10.3390/rs12010056
- DeFries, R. S., & Chan, J. C.-W. (2000). Multiple Criteria for Evaluating Machine Learning Algorithms for Land Cover Classification from Satellite Data. University of Maryland. New York: Remote Sens. Environ.
- Delas, J. (2000). La connaissance de la plante, in Lemay, M.H. (ed.): Fertilisation de la Vigne. Éditions Féret, Bordeaux, France, pp. 21-44.

- Dominguez, N., Garcia-Escudero, E., Romero, I., Benito, A., Martin, I. (2015). Leaf blade and petiole nutritional evolution and variability throughout the crop season for Vitis vinifera L. cv. Graciano. Span. J. Agric. Res. 13(3), e0801. doi:583 10.5424/sjar/2015133-5142.
- Freijido R., J.M. García-Queijeiro, M. Santalla, M. Vilanova. Composición química y contenido en minerales del mosto en cinco variedades de la D.O. Ribeiro: 'Mencía', 'Godello', 'Treixadura', 'Loureira' y 'Torrontés'. XIII Congreso Nacional de Ciencias Hortícolas. Actas de Horticultura nº 60: 666-670.
- García-Escudero, E., Romero, I., Benito, A., Domínguez, N., Martín, I. (2013). Reference levels for leaf nutrient diagnosis of cv. Tempranillo grapevine in the Rioja Appellation. Comm. Soil Sci. Plant Anal. 44, 645-654.
- García-Escudero, E. (2010). Abonado del viñedo. Guía práctica de la fertilización racional de los cultivos en España. Ministerio de Medio Ambiente y Medio Rural y Marino, 213-221.
- Hamylton, S., Morris, R., Carvalho, R., Roder, N., Barlow, P., Milld, K., & Wang, L. (2019). Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. New South Wales, Australia. doi:https://doi.org/10.1016/j.jag.2020.102085
- Hekayati, J., & Rahimpour, M. (2017). Estimation of the saturaion pressure of pure ionic liquids using MLP artificial neural networks and the revides isofugacity criterion. Journal of Molecular Liquids, 85-95.
- Kaplan, A., & Haenlein, M. (2018). On the interpretationes, illustrations and implications of artificial intelligence. Business Horizons, 15-25.
- Kleinberg, E. (1996). An Overtraining-Resistant Stochastic Modeling Method for Pattern Recognition. Annals of Statistics, 24(6), 2319-2349.
- Kwak, G.-H., & Park, N.-W. (2019). Impact of Texture Information on Crop Classification with Machine Learning and UAV Images. Inha University, Department of Geoinformation Engineering, Incheon, Korea. doi:https://doi.org/10.3390/app9040643
- Laliberte, A. S., & Rango, A. (2009). Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery. IEEE Transactions on Geoscience and Remote Sensing, 47(03), 761-770.
- Li, S., & Tang, H. (2020). Classification of Building Damage Triggered by Earthquakes Using Decision Tree. (Hindawi, Ed.) Mathematical Problems in Engineering, 2020. doi:https://doi.org/10.1155/2020/2930515
- Likar, M., Vogel-Mikuš, K., Potisek, M, Hančević, K., Radić, T., Nečemer, M., Reguar, M. (2015). Importance of soil and vineyard management in the determination of grapevine mineral composition. Sci. Total Environ. 505, 724-731.
- Ministerio de Medio Ambiente y Medio Rural y Marino (2010). Guía Práctica de la Fertilización Racional de los Cultivos en España. Disponible vía web: https://www.mapa.gob.es/es/agricultura/publicaciones/02_FERTILIZACI%C3%93N(BAJA)_tcm30-57891.pdf
- Navarro, S., Leon, M., Roca-Perez, L., Boluda, R., Garcia-Ferriz, L., Perez-Bermudez, P., Gavidia, I. (2008). Characterisation of Bobal and Crujidera grape cultivars, in comparison with Tempranillo and Cabernet Sauvignon: evolution of leaf macronutrients and berry composition during grape ripening. Food Chem. 108 (1), 182-190.
- Oyueka, M.M. (2019). Análisis de la microbiota de la vid de distintas regiones vitivinícolas y sus propiedades promotoras del crecimiento vegetal. Tesis Doctoral. Facultad de Ciencias Exactas. Universidad Nacional de La Plata, República Argentina.

- Pellegrini, E., Rovere, N., Zaninotti, S., Franco, I., De Nobili, M., Contin, M. (2021). Artificial neural network (ANN) modelling for the estimation of soil microbial biomass in vineyard soils. Biology and Fertility of Soils, 57(1), 145-151.
- Perez-Bermudez, P., Olmo, M., Gil, J., Garcia-Ferriz, L., Olmo, C., Boluda, R., Gavidia, I. (2016). Cover crops and pruning in Bobal and Tempranillo vineyards have little influence on grapevine nutrition. Sci. Agric. 73(3), 260-265.
- Poole, D. (2018). Computational Intelligence: A Logical Approach. Oxford University Press
- Reyes-Ortiz, O. J., Mejia, M., & Useche-Castelblanco, J. S. (2019). Técnicas de Inteligencia Artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos. Revista EIA, 16(31), 189-207. doi:https://doi.org/10.24050/reia.v16i31.1215
- Rodríguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sánchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS Journal of Photogrammetry and Remote Sensing, 67, 93-104.
- Rodríguez-Lovelle, B., García-Rodeja Gayoso, E. (1995). Mineral vine nutrition in Galicia (NW Spain). J. Int. Sci. Vigne Vin 29, 55-62.
- Romero, I., García-Escudero, E., Martín, I. (2013). Leaf blade vs. petiole analysis for nutritional diagnosis of Vitis vinifera L. cv. Tempranillo. Am. J. Enol. Vitic. 64, 50- 64.
- Romero, I., Benito, A., Domínguez, N., García-Escudero, E., Martín, I. (2014). Leaf blade and petiole nutritional diagnosis for Vitis vinifera L. cv. Tempranillo by deviation from optimum percentage method. Span. J. Agric. Res. 12(1), 206-214.
- Severa, W., Vineyard, C. M., Dellana, R., Verzi, S. J., Aimone, J. B. (2019). Training deep neural networks for binary communication with the whetstone method. Nature Machine Inte
- Tardaguila, J.; Failla, O. & Porro, D. (1992). Necesidades nutricionales del viñedo. Utilización del análisis foliar para su determinación. Vitivinicultura, 3:41-45.
- Veeranampalayam, A., Li, J., Scott, S., Psota, E., Jhala, A., Luck, J., & Shi, Y. (2020). Comparison of Object Detection and Patch Based Classification Deep Learning Models on Mid-to Late-Season Weed Detection in UAV Imagery. Remote Sensing, 12(13) 2136. doi:https://doi.org/10.3390/rs12132136
- Ye, J., Chow, J. H., Chen, J., & Zheng, Z. (2009, November). Stochastic gradient boosted distributed decision trees. In Proceedings of the 18th ACM conference on Information and knowledge management (pp. 2061-2064).