

Mejora de modelos predictivos para el manejo de plagas y enfermedades en la vid (*Vitis vinifera* L.) mediante nuevas metodologías: revisión bibliográfica

*Improvement of predictive models for pest and diseases management in grapevine (*Vitis vinifera* L.) using new methodologies: literature review*

Joaquín Balduque-Gil^{1,2}, Ana Garcés-Claver^{2,3}, Juan J. Barriuso-Vargas^{2,4} y Oreto Fayos^{2,3}

¹ Instituto Agronómico Mediterráneo de Zaragoza, Centro Internacional de Altos Estudios Agronómicos Mediterráneos (CIHEAM Zaragoza). Av. Montañana 1005, 50059 Zaragoza, España.

² Instituto Agroalimentario de Aragón - IA2, CITA - Universidad de Zaragoza. 50013 Zaragoza, España.

³ Departamento de Ciencia Vegetal, Centro de Investigación y Tecnología Agroalimentaria de Aragón (CITA). Avda. Montañana 930, 50059 Zaragoza, España.

⁴ Departamento de Ciencias Agrarias y del Medio Natural, Universidad de Zaragoza. Avenida Miguel Servet 177, 50013 Zaragoza, España.

RESUMEN

Las plagas y enfermedades marcan la rentabilidad de las explotaciones de la vid (*Vitis vinifera* L.), uno de los cultivos leñosos más importantes del mundo. Los modelos predictivos son un recurso de gran utilidad para los sistemas de apoyo a la toma de decisiones, un pilar de la gestión integrada de plagas. Esta revisión repasa la aplicabilidad de nuevas metodologías en el desarrollo de estos modelos predictivos. El uso de sistemas cognitivos para desarrollar modelos permite combinar datos heterogéneos de múltiples fuentes y realizar clasificaciones y predicciones con alta precisión gracias a su gran capacidad de aprendizaje. Entre estos datos, los relativos a la identificación de patógenos a partir de inóculo aéreo mediante técnicas moleculares pueden resultar de gran valor para predecir el riesgo de enfermedades con mayor precisión y así evitar los calendarios arbitrarios de pulverizaciones preventivas. Mejorar los modelos predictivos para la gestión de plagas y enfermedades de la vid, frente a versiones clásicas que no reflejan el efecto de diversas variables, permitiría discernir relaciones entre la afección por patógenos y condicionantes no utilizados por los modelos clásicos.

Palabras clave: Gestión integrada de plagas, sistemas de apoyo a la toma de decisiones, aprendizaje automático, redes neuronales artificiales, inóculo aéreo, detección molecular.

*Autor para correspondencia: joaquin.balduque@iamz.ciheam.org

Recibido: 30/07/2025 Aceptado: 14/01/2026 1ª publicación online: 19/03/2026 Publicación en Vol.: 19/03/2026

Cita del artículo: Balduque-Gil J., Garcés-Claver A., Barriuso-Vargas J.J., Fayos O. (2026). Mejora de modelos predictivos para el manejo de plagas y enfermedades en la vid (*Vitis vinifera* L.) mediante nuevas metodologías: revisión bibliográfica. ITEA-Información Técnica Económica Agraria 122(1): 2-19. <https://doi.org/10.12706/itea.2026.001>



Copyright: © 2026 de los autores. Este es un artículo de acceso abierto distribuido bajo los términos de la licencia de uso y distribución Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional (CC BY NC SA 4.0)

ABSTRACT

Pests affect the profitability of grapevine (*Vitis vinifera* L.), one of the most important woody crops worldwide. Predictive models are a useful resource for decision support systems, a pillar of integrated pest management. This review examines the applicability of new methodologies in the development of these predictive models. The use of cognitive systems to develop models allows heterogeneous data from multiple sources to be combined and classifications and predictions to be made with high accuracy, thanks to their great learning capacity. Among these data, those relating to the identification of pathogens based on airborne inoculum using molecular techniques can be of great value in predicting the risk of diseases more accurately and thus avoiding arbitrary preventive spraying schedules. Improving these predictive models for managing grapevine pests, as opposed to the inaccurate classic versions, which do not reflect the effect of several variables, would make it possible to find significant relationships between pathogen infection and factors not used by classic models.

Keywords: Integrated pest management, decision support systems, machine learning, artificial neural networks, airborne inoculum, molecular detection.

INTRODUCCIÓN

Los sistemas agrícolas se ven afectados por diferentes riesgos, como las condiciones ambientales cambiantes, la degradación de la calidad y salud del suelo, la escasez de agua, la afeción de plagas y enfermedades o la presencia de malas hierbas, entre otros. Estos inconvenientes han sido gestionados tradicionalmente mediante los conocimientos y la experiencia de los propios agricultores (Ip et al., 2018).

El aumento de la población y del consumo mundial está imponiendo exigencias sin precedentes a la agricultura y los recursos naturales, por lo que es necesario encontrar vías de intensificación más sostenibles que aumenten la producción de cultivos y reduzcan los usos insostenibles de productos químicos agrícolas (Foley et al., 2011). De esta forma, la agricultura se ve desafiada a mejorar su productividad, reduciendo al mismo tiempo su impacto medioambiental (Kamilaris y Prenafeta-Boldú, 2018). El actual sistema agroalimentario puede llegar a causar diferentes problemas medioambientales debido al uso inadecuado de fitosanitarios. Además de provocar la contaminación del suelo, el agua y el aire, la persistencia de los residuos de estos productos en los alimentos y el medio ambiente plantea riesgos crónicos para la salud humana, como cáncer, alteraciones endocrinas y trastornos neurológicos (Zhou et al., 2025). La creciente sensibilidad social basada en la relación entre la ciudadanía y la naturaleza, especialmente en Europa, genera preocupación sobre el posible aumento en el uso de productos fitosanitarios por parte de los agricultores. El Reglamento sobre la Restauración de la Naturaleza, adoptado por el Consejo de la Unión Europea el 24 de junio de 2024, refleja el interés por reducir paulatinamente el uso de productos fitosanitarios en nuestro entorno.

La vid (*Vitis vinifera* L.) es uno de los cultivos leñosos más importantes del mundo por su superficie cultivada y su elevado valor económico, así como por su aportación cultural como elemento del patrimonio, influyendo en la identidad regional, y por la vertebración del territorio a través de la conservación de paisajes vitícolas tradicionales (OIV, 2023). Según el in-

forme ‘Estadísticas de Agricultura y Pesca’ de Eurostat del año 2021, alrededor del 45 % de la superficie total de viña en el mundo está en Europa. España, junto con Francia e Italia, representan casi tres las cuartas partes (74,9 %) de la superficie vitícola de la UE (Eurostat, 2020). Las plagas y enfermedades de la vid, como ocurre en otros cultivos, afectan considerablemente a la rentabilidad de una explotación agraria, por lo que surge la necesidad de desarrollar métodos de protección eficientes llevando a cabo sistemas de producción sostenibles. Por tanto, es necesario evaluar la sostenibilidad de la viticultura en condiciones futuras, tanto desde el punto de vista medioambiental como del económico y social (Santos et al., 2020).

Se ha demostrado experimentalmente cómo la Gestión Integrada de Plagas (GIP) (Stern et al., 1959) es más eficaz que los métodos basados únicamente en el control biológico o químico (van Lenteren, 2000). La GIP se define como una estrategia de control a largo plazo que combina métodos biológicos, culturales y químicos para reducir las poblaciones de patógenos a niveles tolerables, de modo que las plagas no alcancen un umbral económico de daños (Tang y Cheke, 2008). En este sentido, las estrategias de control se basan en el monitoreo y la vigilancia de los niveles de presencia de plagas y enfermedades, así como en la programación de medidas de control para evitar que se alcance dicho umbral (Sáenz-de-Cabezón et al., 2011).

Cabe señalar que este tipo de seguimiento y control basado en la vigilancia tiene aspectos delicados, como su elevado coste en tiempo y mano de obra, así como el alto nivel de conocimientos técnicos necesarios para llevarlo a cabo. Además, una frecuencia de controles insuficiente puede suponer una pérdida significativa de información (Rossini et al., 2022).

Dentro de las estrategias de protección de cultivos, la introducción de modelos predictivos posibilita focalizar los tratamientos únicamente en los momentos precisos y necesarios. De esta forma, el uso de dichos modelos permite reducir tanto la cantidad de productos fitosanitarios utilizados, como el número de tratamientos, contribuyendo, por lo tanto, a una mayor sostenibilidad en la producción agrícola. Por un lado, reduce el impacto de las explotaciones en su entorno, y por otro, permite reducir los gastos en los que incurre el agricultor para tratar de garantizar una producción de calidad (Lee y Yun, 2023).

En este sentido, el potencial de los modelos predictivos sobre el comportamiento de plagas y enfermedades hace de la modelización una herramienta valiosa para complementar el monitoreo. Asimismo, teniendo en cuenta que uno de los objetivos de la GIP no es sólo controlar las plagas, sino predecir y mitigar su aparición, los modelos predictivos se consideran esenciales por su utilidad para decidir si es necesario un tratamiento y en qué momento hacerlo (Olatinwo y Hoogenboom, 2014). De este modo, los modelos predictivos representan un poderoso recurso para complementar la gestión de monitoreo, seguimiento y control de la GIP, además de ser especialmente útiles para los sistemas de apoyo a la toma de decisiones (en inglés *Decision Support Systems, DSS*) (Zhai et al., 2020). Estas herramientas están diseñadas para ayudar a los usuarios finales proporcionando alertas tempranas, facilitando la vigilancia de las plagas, el diagnóstico precoz, las previsiones sobre la dinámica de las plagas y niveles adecuados de umbrales económicos de daño para la aplicación de fitosanitarios (Rossi et al., 2019; Michels et al., 2020). Se ha demostrado que la aplicación de este tipo de sistemas puede suponer una reducción del 50 % de las pulverizaciones de fungicidas en viticultura, manteniendo un bajo impacto en el rendimiento en años con una presión media de enfermedades (Delière et al., 2014).

El incremento en la precisión de las herramientas de apoyo a la toma de decisiones puede mejorar la gestión de las explotaciones, su productividad y reducir su impacto medioambiental (Foley et al., 2011). Los modelos clásicos de plagas y enfermedades pueden no resultar lo suficientemente precisos, ya que analizan estadísticamente la influencia de los factores ambientales, buscando correlaciones entre ellos. Sin embargo, debido a las dificultades para integrar un elevado número de variables en los cálculos realizados (Taylor y White, 2020), los modelos suelen basarse en funciones lineales de sólo una o dos variables climáticas, como temperatura y precipitación (Rodríguez-Galiano et al., 2016), simplificando los procesos reales y no reflejando el efecto de otros factores.

En términos de fitopatología, al igual que en cualquier proceso infeccioso o parasitario, es fundamental la interacción entre 4 factores: i) condiciones ambientales favorables, ii) huésped susceptible, iii) tiempo necesario para el desarrollo del proceso infectivo, y iv) presencia del patógeno capaz de producir enfermedad.

Los hongos son los principales responsables de las enfermedades que pueden afectar a la vid. Los métodos convencionales para identificar y clasificar los hongos se basan en la observación microscópica de los caracteres morfológicos de las estructuras fúngicas, como las esporas y el micelio, así como en el crecimiento posterior de las colonias (Falacy et al., 2007; Crespo-Michel et al., 2023). Sin embargo, estas técnicas consumen una elevada cantidad de tiempo, son susceptibles a errores humanos y requieren personal cualificado con un alto nivel de experiencia en el reconocimiento morfológico de los hongos (Zieliński et al., 2020; Crespo-Michel et al., 2023). En este sentido, las herramientas moleculares podrían ser útiles para sortear algunas de las limitaciones e inconvenientes que presenta la microscopía, especialmente si hacen uso de las técnicas basadas en la reacción en cadena de la polimerasa o PCR (del inglés *Polimerase Chain Reaction*) (Mullis y Faloona, 1987).

En esta revisión, se pretende repasar el estado del arte de la aplicabilidad de nuevas metodologías en modelos predictivos de plagas y enfermedades de la viña, con el objetivo de revisar las posibilidades de mejora de modelos clásicos mediante la implementación de técnicas de Inteligencia Artificial (IA) y la detección de inóculo aéreo, de cara a su potencial utilidad en programas de protección fitosanitaria basados en GIP (Figura 1). La bibliografía ha sido recopilada utilizando los buscadores Scopus y Web of Science. Durante la búsqueda bibliográfica se ha realizado un proceso riguroso de recopilación de literatura científica. La compilación bibliográfica se ha llevado a cabo mediante búsquedas entre enero de 2023 y enero de 2025.

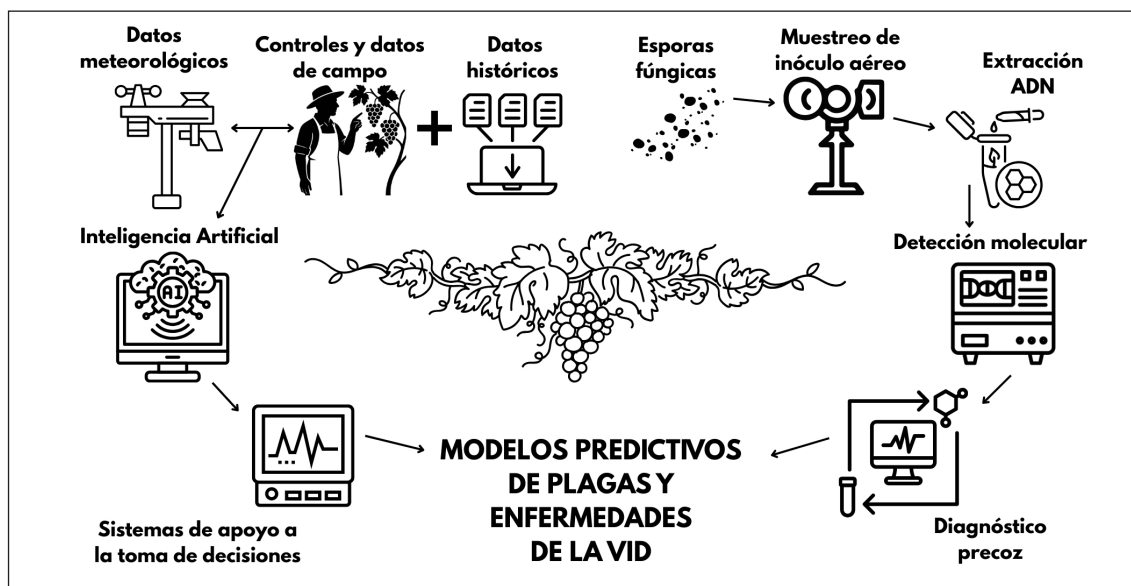


Figura 1. Figura conceptual sobre nuevas tecnologías de modelización del riesgo de plagas y enfermedades de la vid

Figure 1. Conceptual diagram of new technologies for modelling the risk of pest and diseases affecting grapevine

SISTEMAS COGNITIVOS APLICADOS A LA PROTECCIÓN DE CULTIVOS

La agricultura está experimentando una enorme transformación en la recopilación y el uso de datos para tomar decisiones más inteligentes. Así mismo, se espera que la economía basada en los datos, con su énfasis en el desarrollo de sensores, instrumentos y máquinas inteligentes, desempeñe un papel transformador en el sector. La aparición de nuevas tendencias, como el Internet de las Cosas o IoT (del inglés *Internet of Things*), permite a los agricultores y técnicos adoptar un enfoque basado en la recopilación de grandes cantidades de datos procedentes de sensores en sus explotaciones (suelo, agua, cultivos, etc.) con el fin de mejorar la eficiencia de la explotación agrícola y mitigar los riesgos derivados del uso inadecuado de insumos y la incidencia de plagas y enfermedades (Ip et al., 2018).

Los desarrollos relativos al acceso abierto a datos, junto con el crecimiento sin precedentes de su volumen, denominado como *Big Data* (BD), han desembocado en métodos para manejar eficazmente tales datos para su uso en investigación agrícola (Lokers et al., 2016). Tanto las técnicas estadísticas tradicionales, como las técnicas de aprendizaje automático o *Machine Learning* (ML), pueden utilizarse para convertir el BD en información oportuna y valiosa. Dentro de los márgenes de mejora que proporcionan los sistemas cognitivos, sistemas basados en tecnologías de inteligencia artificial (IA) que los dotan de una capacidad de aprendizaje y entendimiento simulando el comportamiento del cerebro humano, se encuentra, principalmente, la posibilidad de combinar datos de múltiples fuentes, con diferentes formatos, producidos a diferente velocidad y frecuencia (De Mauro et al., 2016). Los datos están

en el centro de las decisiones agrícolas y su potencial es enorme, por lo que se espera que el ML sea una fuente de mayor eficiencia en la utilización sostenible de los recursos y un facilitador de enormes beneficios medioambientales. Sin embargo, aunque actualmente se está investigando a gran escala sobre soluciones inteligentes para la agricultura, la implementación práctica de sistemas de toma de decisiones autónoma y predictiva orientados a la resolución de problemas reales del sector agrícola aún se encuentra en una fase incipiente (Shaikh et al., 2022). El análisis y una clasificación de los modelos de previsión de enfermedades de plantas y cultivos realizados entre 2010 y 2020 por Fenu y Mallocci (2021) puso de manifiesto la complejidad de este problema debido a la interacción de varios factores ambientales y climáticos. En su trabajo, concluyeron que el procedimiento de preprocesamiento más común es la normalización de los datos, transformándolos en una escala similar para mejorar el rendimiento y la estabilidad del entrenamiento de los modelos. Estos autores, además, demostraron que las tecnologías de BD permiten mejorar la calidad de la información utilizada para entrenar los modelos de IA, equilibrando los conjuntos de datos sesgados y reduciendo así el riesgo de sobreajuste. Este es uno de los defectos a los que pueden ser propensos estos modelos en ausencia de conjuntos de datos de entrenamiento grandes y bien etiquetados, lo que conduce a que el modelo aprenda demasiado de los datos disponibles en lugar de las tendencias generales (Sarker, 2021).

El ML puede definirse como un conjunto de técnicas de modelado o algoritmos que pueden aprender de los datos y hacer determinaciones sin intervención humana. Se trata de técnicas de aprendizaje automático, de gran utilidad en situaciones en las que se dispone de grandes cantidades de datos, proporcionando una estrategia escalable y modular para su análisis (Ip et al., 2018). El *Random forest* (RF), o bosque aleatorio en español, es un algoritmo de ML de conjunto propuesto por Breiman (2001), se basa en una combinación de predictores que permite crear árboles de decisión para analizar y detectar el peso de las distintas variables que integran un proceso. Los RF permiten identificar y modelar relaciones no lineales, y son capaces de trabajar con un gran número de predictores y determinar su importancia, así como utilizar escalas de tiempo relativo, lo que resulta complicado para modelos físicos o clásicos basados en regresión lineal (Rodríguez-Galiano et al., 2016). Entre las técnicas de ML se tiende al uso del aprendizaje profundo o *Deep Learning* (DL) dentro de los modelos discriminativos cuando se dispone de una gran cantidad de datos para el entrenamiento (Ip et al., 2018). El DL dota al ML de mayor profundidad, es decir, mayor complejidad, transformando los datos mediante diversas funciones que permiten la representación de los datos de forma jerárquica a través de varios niveles de abstracción. Una gran ventaja del DL es el aprendizaje de características, es decir, la extracción automática de características a partir de datos brutos, con niveles superiores de jerarquía formados por la composición de características de niveles inferiores. Así, los modelos de DL permiten aumentar la precisión de la clasificación o reducir el error en los problemas de regresión, siempre que se disponga de conjuntos de datos suficientemente grandes que describan el problema. El DL consta de varios componentes diferentes, uno de ellos, según la arquitectura de red utilizada, pueden ser las redes neuronales artificiales o ANNs (en inglés *Artificial Neural Networks*). La estructura altamente jerárquica y la gran capacidad de aprendizaje de los modelos de ANNs les permite realizar clasificaciones y predicciones particularmente bien, siendo flexibles y adaptables para una amplia variedad de desafíos altamente complejos desde la perspectiva del

análisis de datos (Kamilaris y Prenafeta-Boldú, 2018), además de ser una opción adecuada para predecir la aparición de plagas (Yang et al., 2009).

Inteligencia artificial para detectar plagas y enfermedades

Los sistemas cognitivos y los modelos impulsados por datos en agricultura pueden aplicarse mediante diferentes enfoques. En este sentido, existe literatura que va desde la previsión de cosechas (Paudel et al., 2021), hasta la evaluación de las características del suelo (Yang et al., 2019), la clasificación de semillas (Huang et al., 2022) o la predicción de las diferentes fases fenológicas de un cultivo (duración y ocurrencia) (Lacueva-Pérez et al., 2020). En su revisión sobre el uso de DL en agricultura, Kamilaris y Prenafeta-Boldú (2018) enumeraron diversas aplicaciones existentes de procesamiento de imágenes en agricultura en las que el DL es de gran utilidad, como la clasificación de cubiertas, tanto vegetales como no, estimación del tipo de cultivo, fenología del cultivo, detección de malas hierbas y clasificación de frutos. Por otro lado, estos autores plantearon el interés de examinar la aplicabilidad de DL también en otros problemas relacionados con la agricultura, como la detección de plagas y enfermedades, entre otros. Así mismo, Zhai et al. (2020), realizaron una revisión de los retos que plantea el empleo de DSS en la Agricultura 4.0, resaltando el desafío de posibilitar la detección temprana de plagas y enfermedades, que puede ayudar a los agricultores a tomar ciertas precauciones para evitar pérdidas en sus producciones.

En este sentido, la creación de ANNs permitiría a los modelos identificar relaciones significativas entre la afección de patógenos y una multitud de parámetros que no han sido utilizados hasta el momento debido a los desafíos que implica la construcción de un sistema capaz de integrar grandes volúmenes de datos, como observaciones y previsiones climáticas, y su utilización para ajustar los modelos, hacer predicciones, y difundir los resultados de forma interpretable (Taylor y White, 2020). La complejidad de la investigación en gestión de plagas y enfermedades se intensifica al centrarse en el aumento de datos, la interpretabilidad de modelos y la cooperación interdisciplinar. Esto requiere un enfoque integral para desarrollar soluciones prácticas y sostenibles (Mittal et al., 2024).

Respecto al uso de estas tecnologías para la detección de plagas y enfermedades, la tendencia principal es el análisis de imágenes de patógenos y/o de los síntomas que inducen en las plantas. Se ha utilizado la arquitectura de ANNs para entrenar un modelo que permita clasificar tanto las especies de cultivos como la presencia e identidad de enfermedades a partir de imágenes de hojas sanas y afectadas (Mohanty et al., 2016). Asimismo, se ha aplicado un enfoque de ML basado en ANNs para clasificar imágenes de patógenos y/o de los síntomas que inducen en las plantas (Zieliński et al., 2020; Crespo-Michel et al., 2023), demostrando el potencial de los algoritmos de DL para su clasificación. Igualmente, se han entrenado modelos basados en conjuntos de datos de imágenes de plagas que permiten que los modelos entrenados puedan identificarlas (Durai y Shamili, 2022). Recientemente, se ha descrito que el cultivo en invernadero potenciado por IA, por un lado, permite una gestión y un control precisos de los cultivos para combatir con éxito y de manera eficiente las amenazas de plagas y, por otro lado, ofrece una alternativa viable a sistemas que pueden representar un elevado coste de implantación (Mittal et al., 2024). Debe tenerse en cuenta que los dispositivos como

cámaras de alta resolución, cámaras térmicas, softwares y herramientas de hardware tienen un precio elevado, lo cual puede suponer un obstáculo para muchos agricultores (Shaikh et al., 2022). Por otro lado, Skawsang et al. (2019) aplicaron y compararon análisis de ANNs, RF y regresión lineal clásica para predecir el nivel de presencia de plaga utilizando factores meteorológicos y de fenología de la planta huésped. Al comparar el rendimiento de los modelos mediante R^2 , el modelo de ANNs superó a la regresión lineal clásica en 0,125 puntos y al de RF en 0,016 puntos. Así mismo, la raíz del error cuadrático medio del modelo de ANNs fue 0,329 unidades inferior al de regresión lineal clásica y 0,051 unidades inferior al de RF. Este trabajo concluyó que el uso de registros meteorológicos, series temporales de índices de vegetación derivadas de observación terrestre por satélite y ANNs tiene el potencial de predecir la densidad de población de plaga para apoyar programas de GIP mediante un sistema eficaz de alerta temprana.

Predicción fitosanitaria en viña basada en IA

En el caso concreto del cultivo de la vid es bien conocido que los factores climáticos y ambientales juegan un papel fundamental en la predicción de enfermedades. Chen et al. (2020) utilizaron un conjunto de datos de observaciones de afección de mildiu en viña para desarrollar y comparar varios modelos lineales generalizados y algoritmos de ML para predecir la probabilidad de incidencia de esta enfermedad. Estos autores emplearon la fecha de aparición de la enfermedad y/o las temperaturas y precipitaciones medias mensuales como variables de entrada para los modelos. Varios de los trabajos de Lacueva-Pérez et al. (2020 y 2022) se centran en la aplicabilidad de tecnologías de BD e IA para la predicción de la fenología, enfocada a su utilidad para predicciones fitosanitarias por su relación con los momentos de vulnerabilidad de los cultivos frente a plagas y enfermedades. En uno de esos trabajos, Lacueva-Pérez et al. (2022) utiliza un algoritmo de RF para obtener modelos de predicción de fenología en viña, comparando la precisión de los modelos. Los modelos de ANNs de este trabajo, a diferencia de modelos físicos basados en acumulación de integral térmica, no dependen de la previsión meteorológica, por lo que no tenían esta limitación de cara a su precisión. En el trabajo Balduque-Gil et al. (2023), las tecnologías computacionales permitieron utilizar variables climáticas, como la temperatura máxima, la temperatura mínima, la humedad, la precipitación o la velocidad del viento, que son factores que influyen en las plagas, pero cuya influencia aún no se conoce bien (Fenu y Mallocci, 2021). De esta forma, se comparó el modelo clásico de Touzeau para la predicción de los picos de vuelo de las generaciones de *Lobesia botrana*, únicamente basado en la acumulación de temperatura, con modelos basados en ANNs. De los modelos entrenados mediante ANNs, el que obtuvo mejores resultados identificó como variables más relevantes tanto el índice Touzeau, como el índice de acumulación de frío, la pluviometría (en este caso, calculada a partir de datos diarios o acumulando las muestras semihorarias, considerando la fecha de inicio de la latencia como fecha de inicio para la acumulación) y la longitud geográfica de la parcela en campo. Este estudio utilizó la métrica F1 (Sitarz, 2022) para calcular las diferencias entre los valores observados en campo y los predichos por los modelos, ya que proporciona una información más adecuada que R^2 sobre el rendimiento de los modelos cuando estos se utilizan para hacer clasificaciones.

TOMA DE DECISIONES BASADA EN LA DETECCIÓN DE INÓCULO AÉREO

La mayoría de los sistemas de predicción de enfermedades se basan en condiciones meteorológicas óptimas que favorecen la producción y liberación de inóculo del patógeno o la infección del huésped, suponiendo que el inóculo esté presente. El inóculo aéreo de las enfermedades fúngicas puede detectarse en campo utilizando diferentes dispositivos de muestreo de aire (Lacey y West, 2006), permitiendo identificar los patógenos antes de que aparezcan síntomas visibles en los cultivos, lo que posibilita la aplicación oportuna de medidas de control (Thiessen, 2024), conduciendo a un uso más eficaz de los fitosanitarios y otros métodos de protección de cultivos. De este modo, los datos aerobiológicos pueden utilizarse tanto para modelizar el desarrollo de enfermedades, como dentro de los sistemas de previsión de riesgos fitosanitarios (Fall et al., 2014). En lugar de seguir calendarios arbitrarios de pulverizaciones preventivas, se podría conseguir un programa de control de enfermedades más preciso y rentable iniciando programas de tratamientos fungicidas cuando se detecte inóculo en el aire antes de la aparición de la enfermedad (Falacy et al., 2007; Bello et al., 2022). Esto también facilitaría dirigir las estrategias de gestión a las fases tempranas del desarrollo de los patógenos, cuando existe mayor oportunidad de reducir los posibles daños. El diagnóstico rápido y preciso de enfermedades y la detección de inóculo podrían ser esenciales para la rápida implementación de estrategias eficaces de protección de cultivos, pudiendo mejorar los sistemas de alerta existentes, como los DSS (Fall et al., 2014). La integración de los datos sobre el inóculo aéreo con la información meteorológica y los modelos predictivos puede permitir elaborar previsiones más precisas sobre los riesgos fitosanitarios (Newlands, 2018).

Técnicas de muestreo de inóculo aéreo

Varios autores han destacado la importancia del inóculo aéreo como la variable más importante para sus modelos predictivos (Cao et al., 2015; Carisse et al., 2018). En el caso de los viñedos, los sistemas de detección de inóculo aéreo son todavía novedosos. Sin embargo, su implantación en otros cultivos con patologías similares pone de manifiesto su potencial utilidad en viña. En cuanto a la detección de dicho inóculo, diferentes trabajos destacan la eficacia de las trampas de esporas para capturar la carga esporal transportada por el aire (Lacey y West, 2006; West y Kimber, 2015; Thiessen, 2024). Tal y como explica Thiessen (2024), el muestreo pasivo de inóculo en el aire puede realizarse con portaobjetos de vidrio, placas de agar o mediante captura de inóculo por gravedad. En cuanto a sistemas activos, esta autora destaca los muestreadores de varillas o brazos giratorios y los muestreadores volumétricos de esporas. Los brazos giratorios incluyen varillas recubiertas de material adhesivo que giran a una velocidad estándar, lo que permite el impacto de las partículas suspendidas en el aire sobre las varillas colectoras (Bello et al., 2022). Por otro lado, los muestreadores volumétricos de esporas tipo Hirst cuentan con una carcasa motorizada que aspira aire de manera constante, a razón de 10L/min, a través de una ranura de entrada capturando las partículas suspendidas en el aire. Este tipo de muestreadores cuenta con una veleta, que hace que dicha ranura de entrada esté orientada en la dirección del viento predominante (Hirst, 1952). La corriente de aire incide en un tambor que está cubierto por una cinta de plástico trans-

parente, recubierta de una película de silicona en la que quedan atrapadas las partículas suspendidas en el aire (Lacey y West, 2006).

Las trampas de esporas pueden utilizarse con distintos objetivos (Tabla 1). Por ejemplo, pueden ser útiles para el estudio de la biodiversidad fúngica, como demostraron Magyar et al. (2009), que identificaron un total de 189 taxones diferentes en muestras de aire en un viñedo italiano utilizando un muestreador volumétrico. Por otro lado, Carisse et al. (2005) demostraron una relación lineal entre la concentración de conidios en el aire y el desarrollo de lesiones causadas por *Botrytis squamosa* J.C. Walker en hojas de cebolla utilizando un muestreador de brazos giratorios. Algunos autores han comparado en sus estudios distintos sistemas de trapeo de esporas. Razmovski et al. (1998) compararon cintas adhesivas pasivas sensibles a la presión frente a un adhesivo estándar a base de vaselina colocado en un muestreador volumétrico activo. El estudio descubrió que las cintas pasivas pueden ser más eficaces que el adhesivo de vaselina estándar para capturar pequeñas partículas, pero son menos eficaces para capturar partículas más grandes, como algunos granos de polen y esporas de hongos. Martínez-Bracero et al. (2019) compararon un muestreador volumétrico activo con trampas pasivas de esporas para controlar esporas fúngicas transportadas por el aire en viñedos de sur de España. El muestreador volumétrico arrojó datos de esporas representativos de toda la zona de estudio, siendo el muestreador más recomendado para zonas extensas. Por otro lado, las trampas pasivas mostraron diferencias en las concentraciones de esporas entre los sitios de muestreo. Bello et al. (2022), por su parte, compararon dos sistemas activos para la gestión de mildiu en cucurbitáceas, concluyendo que un muestreador volumétrico fue más sensible que el de brazos giratorios para detectar concentraciones bajas de esporangios en muestras de campo.

Tabla 1. Sistemas de muestreo de inóculo aéreo, uso y resultados obtenidos
Table 1. Airborne inoculum sampling systems, use and results obtained

Autor	Uso	Organismo objetivo	Cultivo / Ambiente	Tipo de muestreo	Sistema	Resultado
Magyar et al. (2009)	Biodiversidad fúngica	Esporas aéreas	Vid	Activo	Volumétrico	Identificación de taxones
Carisse et al. (2005)	Relación entre conidios y lesiones	<i>Botrytis squamosa</i>	Cebolla	Activo	Brazos giratorios	Relación lineal
Razmovski et al. (1998)	Recolección de partículas	Partículas orgánicas e inorgánicas	Núcleo urbano	Pasivo	Cintas adhesivas	Partículas pequeñas
				Activo	Volumétrico	Partículas grandes
Martínez-Bracero et al. (2019)	Concentración de esporas	Esporas fúngicas aéreas	Vid	Pasivo	Trampas pasivas	Variabilidad
				Activo	Volumétrico	Representatividad
Bello et al. (2022)	Detección de esporangios	<i>Pseudoperonospora</i> spp.	Cucurbitáceas	Activo	Brazos giratorios	Menor sensibilidad
				Activo	Volumétrico	Mayor sensibilidad

Otros autores han combinado el muestreo de inóculo aéreo mediante muestreadores activos con datos meteorológicos, trabajando con distintos cultivos y patógenos. Newlands (2018) empleó datos climáticos con diferentes resoluciones espaciales para desarrollar un modelo para roya amarilla en trigo (*Puccinia striiformis* f. sp. *tritici*), integrando datos de inóculo aéreo. También trabajando con trigo, Cao et al. (2015) desarrollaron un modelo basado en datos de temperatura, humedad relativa, precipitación, radiación solar, dirección del viento, presión e inóculo aéreo para describir la gravedad de la incidencia de oídio. Los autores concluyeron que, de todas las variables, la más importante fue la densidad de conidios en el aire y que la adición de variables meteorológicas, aunque estadísticamente significativa, sólo aumentó ligeramente el rendimiento del modelo. Fall et al. (2014) combinaron el muestreo de concentraciones de esporangios en el aire con registros de temperatura, precipitación y humedad relativa en busca de mejorar la estimación de riesgo de mildiu en patata. Trabajando con DSS y curvas de riesgo, estos autores observaron que se subestimaba el riesgo en algunos años, indicando la necesidad de una red de muestreo de esporas para controlar con precisión los niveles de inóculo. Carisse et al. (2018) estudiaron la asociación entre las variables meteorológicas, la concentración de inóculo aéreo y los daños causados por *Botrytis cinerea* Pers.: Fr. en frambuesa. Su trabajo no observó correlaciones entre las pérdidas del cultivo y la temperatura, el déficit de presión de vapor, el viento, la radiación solar o la probabilidad de infección. Sin embargo, sí encontraron correlaciones significativas entre las pérdidas del cultivo y la concentración de inóculo aéreo, así como con las variables relacionadas con la humedad relativa del aire. Trabajando con viña, Fernández-González et al. (2011) combinaron el recuento de esporas de *Plasmopara viticola* (Berk. & M.A. Curtis) Berl. & De Toni con el registro de precipitaciones para desarrollar un modelo que pudo predecir el rendimiento de la variedad de uva Loureira con un mes de antelación y una precisión del 98,3 %, utilizando como predictores las precipitaciones de los primeros diez días de agosto y el recuento de esporas de *P. viticola* en la segunda mitad de julio.

Técnicas de identificación de patógenos

A pesar de las posibilidades que ofrece el muestreo de inóculo aéreo debe tenerse en cuenta que una de las limitaciones de los colectores de partículas es que pueden verse saturados por polvo u otras partículas, impidiendo la identificación por microscopía de los organismos objeto (Thiessen, 2024). Estas limitaciones pueden solventarse a través de la combinación de diagnósticos moleculares con el muestreo de inóculo aéreo, pudiendo resultar de gran valor para predecir el riesgo de enfermedades con mayor precisión (Thiessen, 2024).

En este sentido, varios autores han utilizado técnicas moleculares basadas en PCR para la identificación de patógenos, obtenidos a partir de muestras de inóculo aéreo, responsables de las enfermedades más comunes de la vid en todo el mundo. Falacy et al. (2007) desarrollaron un ensayo PCR capaz de detectar y distinguir con precisión *Erysiphe necator* [Sin. *Uncinula necator* (Schwein.) Burril] Schwein de otros hongos a partir de muestras de aire recolectadas en viñedos. Estos autores combinaron el uso de distintos muestreadores de partículas en su trabajo. Por un lado, utilizaron un muestreador ciclónico de superficie para la recogida de propágulos fúngicos de hojas de uva infectadas y de otras plantas huésped para

su validación en laboratorio. El material recogido se utilizó para la extracción de ADN mediante el kit comercial FastDNA (Fisher Scientific S.L.) y la posterior prueba de PCR para desarrollar y validar los cebadores específicos de la especie, Uncin 144 (5'-CCGCCAGAGACCTCAT CCAA-3') y Uncin 511 (5'-TGGCTGATCACGAGCGTCAC-3'). Por otro lado, los autores recogieron esporas en campo para probar la eficacia del ensayo PCR en la detección de *E. necator in situ* utilizando un muestreador de brazos giratorios, equipado con varillas de vidrio recubiertas de silicona. Por último, recolectaron esporas aéreas en cintas adhesivas mediante un muestreador volumétrico para el seguimiento cuantitativo de las concentraciones de esporas en el aire y la validación de los resultados de la PCR. De esta manera, estos autores obtuvieron un perfil temporal de los eventos de liberación de esporas, lo que les sirvió como referencia para interpretar las detecciones basadas en PCR del muestreador de brazos giratorios y validó los resultados obtenidos por PCR en laboratorio.

Por su parte, Thiessen et al. (2016) desarrollaron un ensayo de amplificación isotérmica mediada por bucle, en inglés *loop-mediated isothermal amplification* (LAMP), para la detección de inóculo aéreo de *E. necator* con el objetivo de que fuese una herramienta rápida, económica y fácil de usar *in situ* para los viticultores, requiriendo un equipo mínimo y proporcionando resultados visuales claros. Para comprobar la precisión de su metodología, los autores compararon los resultados de un ensayo LAMP en campo, llevado a cabo por un viticultor (G-LAMP), con los obtenidos en laboratorio, tanto por un ensayo LAMP (L-LAMP) como por una PCR cuantitativa a tiempo real (qPCR). Para la recolección de esporas, los autores utilizaron en campo tres muestreadores de brazos giratorios con varillas de vidrio recubiertas de silicona. Un muestreador fue utilizado por un viticultor para el ensayo G-LAMP, y los otros dos se utilizaron para el L-LAMP y la qPCR. Para la qPCR se empleó el kit comercial PowerSoil (Hangzhou Bigfish Bio-tech Co., Ltd.) para la extracción de ADN, y se utilizaron los cebadores Uncin144 y Uncin511 y una sonda TaqMan (5'-6FAM-ACGTTGTCATGTAGTCTAA-MGBNFQ-3'). Por otro lado, para el diseño de los LAMP se utilizó un método sencillo de ebullición utilizando un tampón TE (Tris-EDTA), resultando en un sobrenadante que se utilizó como molde de ADN. Para la reacción LAMP, se utilizaron un conjunto de seis cebadores diseñados para dirigirse a la región ITS2 (espaciador transcrito interno, en inglés *internal transcribed spacer*) del ADN ribosómico de *E. necator*, que es altamente específica para este patógeno, FIP, BIP, F3, B3, FL y RL. Los resultados obtenidos por el L-LAMP fueron comparables a los de la qPCR en ambos años del estudio. Por otro lado, los resultados del G-LAMP fueron comparables con la qPCR únicamente en el segundo año del estudio. Esto sugiere que la sensibilidad y la especificidad del ensayo pueden verse afectadas por la experiencia del operador y que la variabilidad en el manejo de las muestras, la extracción de ADN y la configuración de la reacción podía dar lugar a resultados inconsistentes. Basha et al. (2021) diseñaron una trampa de esporas por succión alimentada con energía solar utilizando un tubo de PVC, placas de muestreo de acero inoxidable recubiertas con silicona y un ventilador accionado por un motor de corriente continua. La trampa fue utilizada para recoger inóculos de *E. necator* y *P. viticola*, con el objetivo de desarrollar ensayos PCR y LAMP. Las muestras se examinaron con un microscopio de contraste de fase para identificar las esporas y el ADN se extrajo mediante una modificación del método CTAB (Bromuro de cetiltrimetilamonio). Para la PCR los autores demostraron la especificidad de los cebadores cytb-F (5'-TGTTGTAATATTTATTTAATG-3') y cytb-R (5'-TGGGTTAGCCATAATATAA-3') para *E. necator*, así como NAD9&COB-F (5'-GTA-TAATTTATTTAAAATAAG-3') y NAD9&COB-R (5'-CCAAACATATCCCAAATTC-3') para *P. viticola*.

Para el ensayo LAMP, utilizaron para *E. necator* el mismo conjunto de seis cebadores que Thiessen et al. (2016) diseñados para la región ITS2 y, de manera similar, seis conjuntos de cebadores para *P. viticola* dirigidos al gen de la celulosa sintasa 4 (*Ces A4*). En este trabajo, el ensayo LAMP arrojó mejores resultados que la PCR y la observación microscópica en términos de velocidad, sensibilidad y facilidad de uso. Recientemente, estos cebadores, Nad9 cob-F/Nad9 cob-R (Basha et al., 2021) y los cebadores Uncin144/Uncin511 (Falacy et al., 2007) fueron validados para la identificación de *P. viticola* y *E. necator*, respectivamente, a partir de cintas de muestreadores volumétricos inoculadas artificialmente (Balduque-Gil et al. 2024).

CONCLUSIONES

Los modelos predictivos de plagas y enfermedades son un recurso de gran utilidad para los DSS, considerados uno de los pilares fundamentales de la implementación de los programas de GIP.

Esta revisión muestra las posibilidades de mejora de los modelos predictivos clásicos, que pueden resultar poco precisos. El uso de sistemas basados en IA permite combinar datos heterogéneos de múltiples fuentes, con diferentes formatos, producidos a diferente velocidad y frecuencia, lo que permite encontrar relaciones demasiado complejas como para ser halladas por modelos clásicos. Asimismo, las clasificaciones y predicciones que realizan estos sistemas son altamente precisas, gracias a su gran capacidad de aprendizaje. Al mismo tiempo, el desarrollo de protocolos para la detección molecular rápida de especies fúngicas resulta de gran ayuda para relacionar la medición directa del inóculo aéreo con el riesgo de enfermedad y la detección de patógenos, pudiendo integrarse en el diagnóstico precoz de patógenos de la vid, y, por tanto, mejorando los sistemas de alerta existentes.

CONTRIBUCIÓN DE AUTORÍA

- Joaquín Balduque-Gil: Conceptualización, redacción del borrador original, redacción: revisión y edición, y visualización.
- Ana Garcés-Claver: Conceptualización, recursos, redacción del borrador original, redacción: revisión y edición, supervisión, administración del proyecto y obtención de fondos.
- Juan J. Barriuso Vargas: Conceptualización, recursos, redacción del borrador original, redacción: revisión y edición, supervisión, administración del proyecto y obtención de fondos
- Oreto Fayos: Conceptualización, redacción del borrador original, redacción: revisión y edición, y visualización

AGRADECIMIENTOS

Este trabajo ha sido cofinanciado por los proyectos: INEA/CEF/ICT/A2018/1837816 del “Mecanismo Conectar Europa” (Connecting Europe Facility - CEF) de la Unión Europea, proyecto GRAPEVINE (hiGH pErformAnce comPUting sERvices for preVentlon and coNtrol of pEsts in

fruit crops); A11-23R PROVESOS y A08-23R financiados por Gobierno de Aragón; programa AGROALNEXT financiado por el MCIN con fondos de la Unión Europea NextGenerationEU y (PRTR C 17 I 1) y Gobierno de Aragón; y el P25_064 subvencionado por el Gobierno de España y el Gobierno de Aragón con cargo al Fondo de Inversiones de Teruel.

REFERENCIAS BIBLIOGRÁFICAS

- Balduque-Gil J., Lacueva-Pérez F.J., Labata-Lezaun G., Del-Hoyo-Alonso R., Ilarri S., Sánchez-Hernández E., Martín-Ramos P., Barriuso-Vargas J.J. (2023). Big data and machine learning to improve European grapevine moth (*Lobesia botrana*) predictions. *Plants* 12(3): 633. <https://doi.org/10.3390/plants12030633>.
- Balduque-Gil J., Garcés-Claver A., Pérez-Lamuella I., Barriuso-Vargas J.J., Fayos O. (2024). Molecular detection of the grapevine pathogens *Plasmopara viticola* and *Erysiphe necator* from airborne inoculum collector cyclones. *Agronomy* 14(11): 2619. <https://doi.org/10.3390/agronomy14112619>.
- Basha J.S., Kamalakannan A., Saraswathy S., Johnson I., Ganapati P.S., Lakshmi K.R.S. (2021). Rapid detection of airborne inocula of grapevine mildews using PCR and LAMP assay. *International Journal of Plant & Soil Science* 33(22): 12-21. <https://doi.org/10.9734/ijpss/2021/v33i2230677>.
- Bello J.C., Higgins D.S., Sakalidis M.L., Quesada-Ocampo L.M., Martin F., Hausbeck M.K. (2022). Clade-specific monitoring of airborne *Pseudoperonospora* spp. sporangia using mitochondrial DNA markers for disease management of cucurbit downy mildew. *Phytopathology* 112(10): 2110-2125. <https://doi.org/10.1094/phyto-12-21-0500-r>.
- Breiman L. (2001). Random forests. *Machine Learning* 45: 5-32. <https://doi.org/10.1023/A:1010933404324>.
- Cao X., Yao D., Xu X., Zhou Y., Ding K., Duan X., Fan J., Luo Y. (2015). Development of weather- and airborne inoculum-based models to describe disease severity of wheat powdery mildew. *Plant Disease* 99(3): 395-400. <https://doi.org/10.1094/pdis-02-14-0201-re>.
- Carisse O., McCartney H.A., Gagnon J.A., Brodeur L. (2005). Quantification of airborne inoculum as an aid in the management of leaf blight of onion caused by *Botrytis squamosa*. *Plant Disease* 89(7): 726-733. <https://doi.org/10.1094/pd-89-0726>.
- Carisse O., McNealis V., Kriss A. (2018). Association between weather variables, airborne inoculum concentration, and raspberry fruit rot caused by *Botrytis cinerea*. *Phytopathology* 108(1): 70-82. <https://doi.org/10.1094/phyto-09-16-0350-r>.
- Chen M., Brun F., Raynal M., Makowski D. (2020). Forecasting severe grape downy mildew attacks using machine learning. *PLoS ONE* 15(3): e0230254. <https://doi.org/10.1371/journal.pone.0230254>.
- Crespo-Michel A., Alonso-Arévalo M.A., Hernández-Martínez R. (2023). Developing a microscope image dataset for fungal spore classification in grapevine using deep learning. *Journal of Agriculture and Food Research* 14: 100805. <https://doi.org/10.1016/j.jafr.2023.100805>.
- De Mauro A., Greco M., Grimaldi M. (2016). A formal definition of Big Data based on its essential features. *Library Review* 65(3): 122-135. <https://doi.org/10.1108/lr-06-2015-0061>.

- Delière L., Cartolaro P., Léger B., Naud O. (2014). Field evaluation of an expertise-based formal decision system for fungicide management of grapevine downy and powdery mildews. *Pest Management Science* 71(9): 1247-1257. <https://doi.org/10.1002/ps.3917>.
- Durai S.K.S., Shamili M.D. (2022). Smart farming using machine learning and deep learning techniques. *Decision Analytics Journal* 3: 100041. <https://doi.org/10.1016/j.dajour.2022.100041>.
- Eurostat (2020). Agriculture, forestry and fishery statistics: 2020 edition. Publications Office of the European Union. <https://data.europa.eu/doi/10.2785/143455>.
- Falacy J.S., Grove G.G., Mahaffee W.F., Galloway H., Glawe D.A., Larsen R.C., Vandemark G.J. (2007). Detection of *Erysiphe necator* in air samples using the polymerase chain reaction and species-specific primers. *Phytopathology* 97(10): 1290-1297. <https://doi.org/10.1094/phyto-97-10-1290>.
- Fall M.L., Van Der Heyden H., Brodeur L., Leclerc Y., Moreau G., Carisse O. (2014). Spatiotemporal variation in airborne sporangia of *Phytophthora infestans*: characterization and initiatives towards improving potato late blight risk estimation. *Plant Pathology* 64(1): 178-190. <https://doi.org/10.1111/ppa.12235>.
- Fenu G., Mallocci F.M. (2021). Forecasting plant and crop disease: an explorative study on current algorithms. *Big Data and Cognitive Computing* 5(1): 2. <https://doi.org/10.3390/bdcc5010002>.
- Fernández-González M., Rodríguez-Rajo F.J., Jato V., Escuredo O., Aira M.J. (2011). Estimation of yield 'Loureira' variety with an aerobiological and phenological model. *Grana* 50(1): 63-72. <https://doi.org/10.1080/00173134.2011.561871>.
- Foley J.A., Ramankutty N., Brauman K.A., Cassidy E.S., Gerber J.S., Johnston M., Mueller N.D., O'Connell C., Ray D.K., West P.C., Balzer C., Bennett E.M., Carpenter S.R., Hill J., Monfreda C., Polasky S., Rockström J., Sheehan J., Siebert S., Tilman D., Zaks D.P.M. (2011). Solutions for a cultivated planet. *Nature* 478(7369): 337-342. <https://doi.org/10.1038/nature10452>.
- Hirst J. M. (1952). An automatic volumetric spore trap. *Annals of Applied Biology* 39(2): 257-265. <https://doi.org/10.1111/j.1744-7348.1952.tb00904.x>.
- Huang Z., Wang R., Cao Y., Zheng S., Teng Y., Wang F., Wang L., Du J. (2022). Deep learning based soybean seed classification. *Computers and Electronics in Agriculture* 202: 107393. <https://doi.org/10.1016/j.compag.2022.107393>.
- Ip R.H., Ang L., Seng K.P., Broster J.C., Pratley J.E. (2018). Big data and machine learning for crop protection. *Computers and Electronics in Agriculture* 151: 376-383. <https://doi.org/10.1016/j.compag.2018.06.008>.
- Kamilaris A., Prenafeta-Boldú F.X. (2018). Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture* 147: 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>.
- Lacey M.E., West J.S. (2006). Air sampling techniques. En: *The Air Spora* (Ed. Lacey, M.E., West, J.S.), pp. 35-47. Springer, Boston, MA. https://doi.org/10.1007/978-0-387-30253-9_3.
- Lacueva-Pérez F., Artigas S., Vargas J., Lezaun G., Alonso R. (2020). Multifactorial evolutionary prediction of phenology and pests: Can machine learning help? *Proceedings of the 16th International Conference on Web Information Systems and Technologies*, 2-5 de noviembre, online, pp. 75-82. <http://dx.doi.org/10.5220/0010132900750082>.

- Lacueva-Pérez F.J., Ilarri S., Barriuso J.J., Balduque J., Labata G., Del-Hoyo R. (2022). Grapevine phenology prediction: A comparison of physical and machine learning models. En: Big Data Analytics and Knowledge Discovery. DaWaK 2022. Lecture notes in computer science (Ed. Wrembel, R., Gamper, J., Kotsis, G., Tjoa, A.M., Khalil, I.), pp. 263-269. Springer, Cham. https://doi.org/10.1007/978-3-031-12670-3_24.
- Lee S., Yun C.M. (2023). A deep learning model for predicting risks of crop pests and diseases from sequential environmental data. *Plant Methods* 19(1): 145. <https://doi.org/10.1186/s13007-023-01122-x>.
- Lokers R., Knapen R., Janssen S., Van Randen Y., Jansen J. (2016). Analysis of Big Data technologies for use in agro-environmental science. *Environmental Modelling & Software* 84: 494-504. <https://doi.org/10.1016/j.envsoft.2016.07.017>.
- Magyar D., Frenguelli G., Bricchi E., Tedeschini E., Csontos P., Li D., Bobvos J. (2009). The biodiversity of air spora in an Italian vineyard. *Aerobiologia* 25(2): 99-109. <https://doi.org/10.1007/s10453-009-9115-9>.
- Martínez-Bracero M., Alcázar P., Velasco-Jiménez M.J., Galán C. (2019). Fungal spores affecting vineyards in Montilla-Moriles Southern Spain. *European Journal of Plant Pathology* 153(1): 1-13. <https://doi.org/10.1007/s10658-018-1532-6>.
- Michels M., Bonke V., Musshoff O. (2020). Understanding the adoption of smartphone apps in crop protection. *Precision Agriculture* 21(6): 1209-1226. <https://doi.org/10.1007/s11119-020-09715-5>.
- Mittal M., Gupta V., Aamash M., Upadhyay T. (2024). Machine learning for pest detection and infestation prediction: A comprehensive review. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 14(5): e1551 <https://doi.org/10.1002/widm.1551>.
- Mohanty S.P., Hughes D.P., Salathé M. (2016). Using deep learning for image-based plant disease detection. *Frontiers In Plant Science* 7. <https://doi.org/10.3389/fpls.2016.01419>.
- Mullis K.B., Faloona F.A. (1987). Specific synthesis of DNA *in vitro* via a polymerase-catalyzed chain reaction. *Methods in Enzymology* 155: 335-350. [https://doi.org/10.1016/0076-6879\(87\)55023-6](https://doi.org/10.1016/0076-6879(87)55023-6).
- Newlands N.K. (2018). Model-based forecasting of agricultural crop disease risk at the regional scale, integrating airborne inoculum, environmental, and satellite-based monitoring data. *Frontiers in Environmental Science* 6: 63. <https://doi.org/10.3389/fenvs.2018.00063>.
- OIV (2023). Annual assessment of the world vine and wine sector in 2022. International Organisation of Vine and Wine. Disponible en: https://www.oiv.int/sites/default/files/documents/OIV_Annual_Assessment-2023.pdf (Consultado: 31/01/2025)
- Olatinwo R., Hoogenboom G. (2014). Weather-based pest forecasting for efficient crop protection. En: *Integrated Pest Management* (Ed. Abrolpp D.P.), pp. 59-78. Academic Press. <https://doi.org/10.1016/b978-0-12-398529-3.00005-1>.
- Paudel D., Boogaard H., De Wit A., Janssen S., Osinga S., Pylaniadis C., Athanasiadis I.N. (2021). Machine learning for large-scale crop yield forecasting. *Agricultural Systems* 187: 103016. <https://doi.org/10.1016/j.agsy.2020.103016>.
- Razmovski V., O'meara T., Hjelmroos M., Marks G., Tovey E. (1998). Adhesive tapes as capturing surfaces in Burkard sampling. *Grana* 37(5): 305-310. <https://doi.org/10.1080/00173139809362683>.

- Rodriguez-Galiano V.F., Sanchez-Castillo M., Dash J., Atkinson P.M., Ojeda-Zujar J. (2016). Modelling interannual variation in the spring and autumn land surface phenology of the European forest. *Bio-geosciences* 13(11): 3305-3317. <https://doi.org/10.5194/bg-13-3305-2016>.
- Rossi V., Sperandio G., Caffi T., Simonetto A., Gilioli G. (2019). Critical success factors for the adoption of decision tools in IPM. *Agronomy* 9(11): 710. <https://doi.org/10.3390/agronomy9110710>.
- Rossini L., Bruzzone O. A., Contarini M., Bufacchi L., Speranza S. (2022). A physiologically based ODE model for an old pest: Modeling life cycle and population dynamics of *Bactrocera oleae* (Rossi). *Agronomy* 12(10): 2298. <https://doi.org/10.3390/agronomy12102298>.
- Sáenz-de-Cabezón E., Hernández L.J., Rivas M.T., García-Ruiz E., Marco V., Pérez-Moreno I., Sáenz-De-Cabezón F.J. (2011). A computer implementation of the partition of the unity procedure and its application to arthropod population dynamics. A case study on the European grape berry moth. *Mathematics and Computers in Simulation* 82(1): 2-14. <https://doi.org/10.1016/j.matcom.2010.06.019>.
- Santos J.A., Fraga H., Malheiro A.C., Moutinho-Pereira J., Dinis L., Correia C., Moriondo M., Leolini L., Dibari C., Costafreda-Aumedes S., Kartschall T., Menz C., Molitor D., Junk J., Beyer M., Schultz H.R. (2020). A review of the potential climate change impacts and adaptation options for European viticulture. *Applied Sciences* 10(9): 3092. <https://doi.org/10.3390/app10093092>.
- Sarker I.H. (2021). Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science* 2(6): 420. <https://doi.org/10.1007/s42979-021-00815-1>.
- Shaikh T.A., Rasool T., Lone F.R. (2022). Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. *Computers and Electronics in Agriculture* 198: 107119. <https://doi.org/10.1016/j.compag.2022.107119>.
- Sitarz M. (2022). Extending F1 metric, probabilistic approach. arXiv :2210.11997 [cs.LG]. <https://doi.org/10.48550/ARXIV.2210.11997>.
- Skawsang S., Nagai M., Tripathi N.K., Soni P. (2019). Predicting rice pest population occurrence with satellite-derived crop phenology, ground meteorological observation, and machine learning: a case study for the central plain of Thailand. *Applied Sciences* 9(22): 4846. <https://doi.org/10.3390/app9224846>.
- Stern V.M., Smith R.F., Van Den Bosch R., Hagen K.S. (1959). The integration of chemical and biological control of the spotted alfalfa aphid: The integrated control concept. *Hilgardia* 29(2): 81-101. <https://doi.org/10.3733/hilg.v29n02p081>.
- Tang S., Cheke R.A. (2008). Models for integrated pest control and their biological implications. *Mathematical Biosciences* 215(1): 115-125. <https://doi.org/10.1016/j.mbs.2008.06.008>.
- Taylor S.D., White E.P. (2020). Automated data-intensive forecasting of plant phenology throughout the United States. *Ecological Applications* 30(1): e02025. <https://doi.org/10.1002/eap.2025>.
- Thiessen L.D., Keune J.A., Neill T.M., Turechek W.W., Grove G.G., Mahaffee W.F. (2016). Development of a grower-conducted inoculum detection assay for management of grape powdery mildew. *Plant Pathology* 65(2): 238-249. <https://doi.org/10.1111/ppa.12421>.
- Thiessen L.D. (2024). Follow that spore! Airborne inoculum detection as a decision aid. *PhytoFrontiers* 4(1): 5-13. <https://doi.org/10.1094/phytofr-06-23-0077-fi>.

- van Lenteren, J.C. (2000). Success in biological control of arthropods by augmentation of natural enemies. En: *Biological Control: Measures of Success*. (Ed. Gurr, G., Wratten, S.9, pp. 77-103. Springer, Dordrecht. https://doi.org/10.1007/978-94-011-4014-0_3.
- West J., Kimber R. (2015). Innovations in air sampling to detect plant pathogens. *Annals of Applied Biology* 166(1): 4-17. <https://doi.org/10.1111/aab.12191>.
- Yang L., Peng L., Zhang L., Zhang L., Yang S. (2009). A prediction model for population occurrence of paddy stem borer (*Scirpophaga incertulas*), based on back propagation artificial neural network and principal components analysis. *Computers and Electronics in Agriculture* 68(2): 200-206. <https://doi.org/10.1016/j.compag.2009.06.003>.
- Yang M., Xu D., Chen S., Li H., Shi Z. (2019). Evaluation of machine learning approaches to predict soil organic matter and pH Using vis-NIR spectra. *Sensors* 19(2): 263. <https://doi.org/10.3390/s19020263>.
- Zhai Z., Martínez J.F., Beltran V., Martínez N.L. (2020). Decision support systems for agriculture 4.0: Survey and challenges. *Computers and Electronics in Agriculture* 170: 105256. <https://doi.org/10.1016/j.compag.2020.105256>.
- Zhou W., Li M., Achal V. (2025). A comprehensive review on environmental and human health impacts of chemical pesticide usage. *Emerging Contaminants* 11(1): 100410. <https://doi.org/10.1016/j.emcon.2024.100410>.
- Zieliński B., Sroka-Oleksiak A., Rymarczyk D., Piekarczyk A., Brzychczy-Włoch M. (2020). Deep learning approach to describe and classify fungi microscopic images. *PLoS ONE* 15(6): e0234806. <https://doi.org/10.1371/journal.pone.0234806>.