

REVISIÓN BIBLIOGRÁFICA

APLICACIÓN DE IMÁGENES HIPERESPECTRALES EN LA DETECCIÓN DE CONTAMINANTES EN ALIMENTOS: UNA REVISIÓN

Hyperspectral imaging approach for contaminant detection in food: A review

Aquino, Dominga C. ; **San Lorenzo, André L.**

Universidad Tecnológica Nacional, Facultad Regional Resistencia.
E-mail: andreleandrosanlorenzo@gmail.com

RESUMEN En los últimos años, las crecientes preocupaciones de salud han resaltado la necesidad urgente de métodos innovadores para garantizar la seguridad alimentaria. La tecnología de imágenes hiperespectrales (HSI, por sus siglas en inglés) ha surgido como una herramienta altamente prometedora y ampliamente reconocida, ofreciendo capacidades de detección no destructivas esenciales para identificar contaminantes en alimentos. Este artículo analiza las principales características de la HSI, su relevancia en la investigación científica y sus avances tecnológicos, en particular su integración con técnicas de aprendizaje automático para mejorar la precisión y eficiencia en la detección de contaminación. Queda claro que la HSI no solo tiene el potencial de revolucionar las prácticas de seguridad alimentaria, sino que también desempeña un papel crítico en la mejora de los procesos de toma de decisiones mediante un análisis de datos preciso. La creciente accesibilidad y aplicación global de esta tecnología, junto con métodos avanzados de procesamiento de datos, posicionan a la HSI como una herramienta clave para abordar los desafíos relacionados con la contaminación de alimentos, ofreciendo beneficios significativos tanto para la industria como para la salud pública.

Palabras clave: Detección de microorganismos; Toxinas; Técnica no destructiva; Inocuidad alimentaria.

ABSTRACT In recent years, growing health concerns have highlighted the urgent need for innovative detection methods in the field of food safety. Hyperspectral imaging (HSI) has emerged as a highly promising and widely recognized technology, offering non-destructive detection capabilities that are crucial for identifying food contamination. This paper explores the key characteristics of HSI, its significance in scientific research, and its technological advancements, particularly in its integration with machine learning techniques to enhance the accuracy and efficiency of contamination detection. It becomes evident that HSI not only has the potential to revolutionize food safety practices but also plays a critical role in improving decision-making processes through precise data analysis. The increasing accessibility and global application of HSI technology, combined with advanced data processing methods, position it as a vital tool in addressing the growing challenges related to food contamination. This offers significant benefits for both industry and public health.

Keywords: Detection of microorganisms; Toxins; Non-destructive technique; Food safety.





INTRODUCCIÓN

El aumento de toxinas y microorganismos presentes en los alimentos ha incrementado la necesidad de métodos de detección de microorganismos nuevos y más eficientes. Las HSI son una tecnología altamente prometedora, en constante crecimiento que cada vez se vuelve más accesible gracias al desarrollo de nuevas tecnologías. El uso de este método ha aumentado drásticamente en la última década, hasta el punto de convertirse en el enfoque preferido por la comunidad científica. Es de suma importancia discutir las tecnologías y técnicas relacionadas con HSI y su utilización en la detección de Enfermedades Transmitidas por Alimentos (ETA) (Alisaac et al., 2019).

Las infecciones por hongos en *Zea Mays* (maíz) y otros cereales presentan desafíos continuos para la producción agrícola global y la inocuidad alimentaria. Estas contaminaciones no solo impactan la calidad del maíz, sino que también representan riesgos para su valor nutricional. Las micotoxinas, como las Aflatoxinas y Ocratoxinas, son potentes cancerígenos conocidos por causar diferentes enfermedades como cáncer de pulmón e hígado en humanos y animales (Yao et al., 2013; Del Fiore et al., 2010). Las medidas regulatorias implementadas por las autoridades en muchos países enfatizan la gravedad del problema y la necesidad de métodos de detección confiables. Como resultado, las organizaciones privadas buscan activamente enfoques más rápidos y precisos para mitigar los riesgos de micotoxinas (Yao et al., 2013).

Las HSI han representado un cambio abrupto en la identificación de microorganismos en diversos productos alimenticios (Chu et al., 2017). Al combinar imágenes convencionales y espectroscopía, las HSI permiten la recolección de información espacial y espectral de objetos o muestras sin causarles daño. Esta técnica no destructiva captura un amplio rango de longitudes de onda, permitiendo la identificación de firmas espectrales distintivas asociadas con diferentes sustancias (Soni et al., 2022).

Para garantizar la imparcialidad de la información producida e incluir una amplia gama de perspectivas mediante la inclusión de la mayor cantidad posible de documentos relevantes, fue necesario leer y estudiar cuidadosamente un conjunto de artículos específicos relacionados con este tema. Este paso fue muy importante para comprender mejor el tema y proporcionar una base sólida sobre la cual seguir construyendo.

Tras la revisión inicial, se realizó una exploración exhaustiva para identificar artículos de investigación pertinentes sobre la aplicación de HSI en la detección de enfermedades relacionadas con alimentos. Esta estrategia de investigación detallada abarcó diversas bases de datos como revistas científicas y repositorios en línea. Específicamente, se seleccionaron Elsevier, Springer y MDPI por su alta idoneidad para recuperar documentación técnica y científica relevante para las aplicaciones de HSI. Como guía, se utilizaron palabras clave como "imagen hiperespectral", "HSI", "calidad alimentaria", "seguridad alimentaria", "detección de enfermedades" y "espectroscopía". Estas palabras clave se adaptaron según los requisitos específicos de cada base de datos. En ciertos casos, se empleó la búsqueda por encadenamiento de citas, para poder descubrir fuentes adicionales relevantes.

En definitiva, los objetivos de este estudio son fundamentalmente dos: por un lado, ofrecer un panorama detallado y actualizado de las tecnologías HSI, revelando sus potencialidades y alcances en la detección de contaminantes; y por otro, proporcionar una guía accesible que permita a investigadores, profesionales y estudiantes comprender los principios y aplicaciones prácticas de esta revolucionaria técnica de análisis.

Estado del arte

La búsqueda inicial arrojó un número considerable de artículos, y se aplicaron criterios de inclusión y exclusión para identificar los más adecuados para la revisión. Se dio prioridad a los artículos publicados en inglés entre 2010 y 2023 con el objetivo de captar los desarrollos más recientes en el tema. Además, se priorizaron estudios que abordaran específicamente la aplicación de las imágenes hiperespectrales para la detección de enfermedades en alimentos. La evolución de los artículos a lo largo del tiempo se ilustra en la Figura 1.

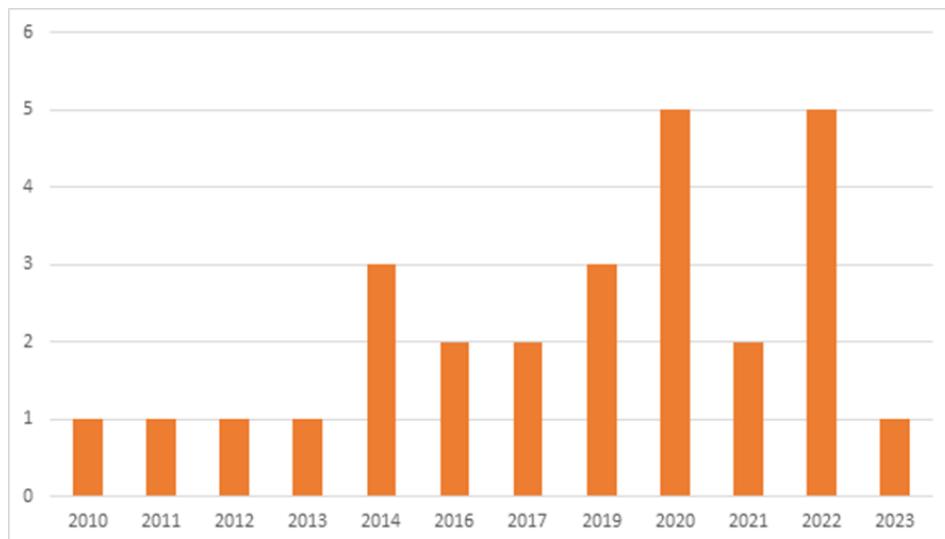


Figura 1. El gráfico de barras muestra la cantidad de artículos publicados cada año, desde 2010 hasta 2023, basándose en la fuente de información seleccionada para este estudio. El eje vertical indica la cantidad, mientras que el eje horizontal representa los años. Cada barra naranja corresponde a un año específico, y su altura refleja el número de artículos publicados en ese año.

Fundamentos de las HIS

Antes de analizar la aplicación de las HSI en la detección de microorganismos es fundamental establecer una comprensión básica de esta tecnología. HSI es una técnica que permite capturar información espectral detallada de una muestra, facilitando la detección de variaciones en su composición respecto a un patrón de referencia. Estas imágenes se recopilan en un hipercubo tridimensional, que consiste en un conjunto de imágenes espaciales bidimensionales obtenidas a diferentes longitudes de onda. Para adquirir el cubo de datos hiperespectrales, se emplean varios métodos comunes. Los más importantes son el patrón espacial punto a punto, también conocido como el método *whiskbroom*, la imagen de transformada de Fourier, el sistema de imágenes *pushbroom* o de escaneo lineal, y el sistema de imágenes de matriz fija o *staring array* (Ravikanth et al., 2016).

El sistema de imágenes *pushbroom* es ideal para el análisis de calidad de alimentos y materiales agrícolas (Huang et al., 2014). Recoge datos espectrales de una línea espacial a la vez, construyendo progresivamente el hipercubo. Una línea estrecha de la intensidad de luz de la muestra, abarcando todas las longitudes de onda, se proyecta en una fila del hipercubo utilizando un elemento dispersor bidimensional y un arreglo de detectores. Este sistema a menudo incluye una lente de imagen con una apertura en forma de rendija. Puede mover la muestra o dirigir el haz y el detector hacia la región de interés, proporcionando control sobre el registro espectral. Este método se destaca por su rapidez y adaptabilidad (Femenias et al., 2022; Huang et al., 2014; Ravikanth et al., 2016).

En contraste, el sistema de imágenes de matriz fija captura la imagen espacial completa de la muestra en una longitud de onda y luego avanza hacia las longitudes de onda siguientes. Esta técnica, también conocida como escaneo por longitud de onda o escaneo con filtro ajustable, emplea comúnmente filtros ajustables como ruedas de filtros, filtros ajustables de cristal líquido (LCTF) y filtros ajustables acusto-ópticos (AOTF) (Ma et al., 2019).

Los modos comunes de captura de imágenes difieren en la disposición de las fuentes de luz, los detectores ópticos y las muestras. En el modo de reflectancia, la fuente de luz y el detector óptico están en el mismo lado de la muestra para detectar atributos externos (Ma et al., 2019). El modo de transmitancia coloca las fuentes de luz y los detectores en lados opuestos de la muestra para evaluar atributos internos, aunque la fuerza de la señal puede verse afectada por el grosor de la muestra. En el modo de interactancia, las fuentes de luz y el detector están en el mismo lado, pero el campo de visión del detector no está iluminado, lo que permite detectar tanto información externa como interna mientras se minimizan los efectos de la reflexión especular y el grosor de la muestra (Ma et al., 2019).



Método de obtención de imágenes

Las imágenes hiperespectrales (HSI) forman una parte crucial del complejo proceso de detección de patógenos, más que un método independiente. Aunque el HSI se considera rápido y sencillo, requiere una investigación exhaustiva y la recopilación de datos para garantizar el correcto funcionamiento de las cámaras hiperespectrales. En primer lugar, se analizará el camino común empleado para identificar sustancias específicas en los alimentos. El número de etapas en el proceso y las herramientas utilizadas dependen de la escala del proyecto y los recursos disponibles. Los siguientes pasos ofrecen un esquema general, aunque los detalles específicos pueden variar según el contexto y las tecnologías empleadas para la identificación de patógenos.

Identificación de patógenos

Este paso inicial es fundamental, ya que los análisis posteriores se construyen a partir de él. La determinación de la presencia de patógenos implica el análisis en laboratorio de las muestras. Se pueden emplear diversas tecnologías, como el método basado en ácidos nucleicos o la reacción en cadena de la polimerasa (PCR), que permite detectar de manera rápida y eficaz una secuencia diana específica en el ADN de la muestra. Sin embargo, una desventaja es la destrucción de la muestra durante el proceso (Soni et al., 2022).

El método PCR es ampliamente utilizado en la detección de patógenos debido a su alta sensibilidad y especificidad (Ma et al., 2019). Funciona amplificando una región particular del ADN, conocida como la secuencia diana, que es seleccionada debido a su relevancia para el análisis. Primero, se extrae el ADN de la muestra y se somete a ciclos de calentamiento y enfriamiento, permitiendo su replicación repetida. Si está presente, se crean numerosas copias de la secuencia objetivo. Luego, se utiliza una sonda de ADN específica que se une a la secuencia objetivo y emite una señal detectable, indicando la presencia del patógeno en la muestra. Este método es altamente preciso y puede identificar patógenos incluso en cantidades muy pequeñas.

La principal desventaja del método PCR radica en su alteración irreversible de la muestra original, lo que impide realizar análisis posteriores. Además, su ejecución precisa requiere equipos especializados de laboratorio y personal capacitado. El proceso demanda precisión y experiencia para obtener resultados confiables.

Experimentación

Después de identificar el patógeno, el siguiente paso consiste en la inoculación de los microorganismos para generar muestras contaminadas bajo condiciones controladas. La introducción de contaminantes en estas muestras puede lograrse mediante diversos métodos, como la aplicación a través de un medio de seda o sumergiendo un palillo en una suspensión de esporas y utilizándolo posteriormente para contaminar el maíz (Parrag et al., 2020). Es fundamental destacar la importancia de crear muestras con diferentes niveles de patógenos. Esto permite observar cómo las distintas concentraciones de patógenos impactan en la firmapectral.

Aunque este enfoque pueda diferir de las muestras en condiciones reales, es una medida necesaria para evaluar la carga de patógenos sin comprometer la integridad de las muestras originales. Además, vale la pena señalar que las muestras desarrolladas no siempre estarán en condiciones óptimas, lo cual puede atribuirse a la calidad general del equipo o a las condiciones en las que fueron preparadas. Este aspecto está estrechamente relacionado con la calidad y el estado del equipo utilizado en el proceso.

Determinación de la firmapectral

En este paso, el objetivo es identificar el patrón único de radiación electromagnética emitido o reflejado por la muestra en diferentes longitudes de onda. Se emplean diversas técnicas espectroscópicas, incluyendo espectroscopía infrarroja, espectroscopía de fluorescencia y espectrometría de masas. La cámara hiperespectral captura múltiples imágenes, lo que requiere ajustes ambientales como la iluminación y elementos de referencia (Huang et al., 2014). En la mayoría de los casos, se utilizan lámparas halógenas debido a su alta estabilidad espectral y a su amplio rango de emisión en el espectro visible y cercano al infrarrojo (Teixido-Orries et al., 2023).

Si bien es posible realizar mediciones en el entorno natural de la sustancia, es importante reconocer que factores externos como el viento o el polvo pueden influir en los resultados, introduciendo potencialmente variabilidad (Bauriegel y Herppich, 2014). En algunos casos, se han implementado medidas adicionales para mitigar las variaciones espectrales inducidas por la humedad. Estas medidas, por ejemplo, en el caso del trigo, implican regular cuidadosamente los niveles de humedad en las muestras mediante técnicas como el secado al aire o la humidificación (Liang et al., 2020). Posteriormente, se aplican métodos estadísticos para normalizar los resultados y reducir el ruido en las imágenes.

Pruebas

Tras determinar las firmas espectrales de las muestras contaminadas, la fase de pruebas representa un paso crucial en el uso de HSI para la detección de patógenos. En esta etapa, se utiliza un conjunto más amplio de muestras, que incluye tanto especímenes contaminados como no contaminados. Estas muestras se analizan utilizando las firmas espectrales establecidas como puntos de referencia. El objetivo principal es identificar y clasificar la presencia de patógenos en muestras desconocidas, aprovechando sus características espectrales distintivas (Bauriegel y Herppich, 2014).

Para lograr esto, se emplean algoritmos avanzados de aprendizaje automático, que permiten la automatización y mejoran significativamente la precisión y eficiencia del proceso de pruebas. Estos algoritmos son fundamentales para manejar la complejidad de analizar la gran cantidad de datos espectrales en diversas longitudes de onda. Permiten al sistema discriminar entre muestras contaminadas y no contaminadas con un alto grado de precisión, incluso en escenarios donde el análisis humano podría ser impráctico o propenso a errores (Femenias et al., 2022).

Técnicas de aprendizaje automático, incluyendo redes neuronales profundas, máquinas de soporte vectorial y métodos de conjunto, se aplican comúnmente en este contexto. Estos algoritmos pueden identificar patrones sutiles y desviaciones en los datos hiperespectrales que podrían pasar desapercibidos para la observación humana. Además, tienen la capacidad de adaptarse y mejorar su rendimiento con el tiempo, lo que los convierte en herramientas indispensables para la detección de patógenos mediante HSI (Datta et al., 2022).

Implementación

Tras realizar con éxito las pruebas y la validación del sistema de identificación de patógenos, el siguiente paso es su implementación en entornos prácticos, fuera del laboratorio. Esto implica integrar la tecnología y las metodologías desarrolladas en aplicaciones reales. La implementación puede incluir el desarrollo de interfaces fáciles de usar, el establecimiento de protocolos y directrices, y garantizar la fiabilidad y escalabilidad del sistema (Parrag et al., 2020).

Contaminantes comunes

Los contaminantes más frecuentes en semillas, particularmente en granos, son las micotoxinas. Estas son compuestos tóxicos producidos por ciertos tipos de hongos que crecen en alimentos como cereales, frutas secas, nueces y especias. Algunas de las micotoxinas más comunes en los granos incluyen las aflatoxinas, las toxinas de *Fusarium* y las ocratoxinas.

Las aflatoxinas son producidas principalmente por especies de hongos del género *Aspergillus*, como *A. flavus*, *A. parasiticus* y *A. nomius*. Las aflatoxinas más conocidas son B1, B2, G1 y G2. Estas micotoxinas son altamente tóxicas y cancerígenas tanto para humanos como para animales (Wang et al., 2014). El consumo de granos contaminados puede tener graves consecuencias para la salud, incluyendo aflatoxicosis aguda o crónica.

La aflatoxicosis aguda ocurre tras consumir granos con altos niveles de aflatoxinas, causando daño hepático y potencialmente enfermedad o muerte. Por otro lado, la aflatoxicosis crónica resulta de una exposición prolongada a alimentos contaminados, aumentando el riesgo de cáncer de hígado y debilitando el sistema inmunológico. Para controlar las aflatoxinas, muchos países, como los Estados Unidos y la Unión Europea, han implementado regulaciones. El desarrollo de kits de detección rápida ha ofrecido alternativas, aunque el proceso aún implica la destrucción de muestras (Yao et al., 2013). El impacto de las aflatoxinas es más frecuente en climas cálidos (Senthilkumar et al., 2017).

Las toxinas de *Fusarium* pueden producir diversas micotoxinas, como fumonisinas, deoxinivalenol (DON) y zearalenona. Estas micotoxinas se encuentran en granos, especialmente en maíz, trigo, centeno, cebada, avena y otros cereales. Las fumonisinas se han asociado con problemas de salud en animales, incluyendo enfermedades del sistema nervioso y cáncer, mientras que el DON afecta tanto a humanos como a animales (Nadimi et al., 2021).

La ingestión de dosis elevadas de DON produce síntomas como dolor de cabeza, irritación de garganta, diarrea, náuseas, vómitos y hemorragias gastrointestinales. En casos de exposición excesiva, incluso puede ocurrir la muerte (Femenias et al., 2020). Estas infecciones también alteran las propiedades de los cereales, causando grandes pérdidas en las cosechas y reduciendo su calidad. Los granos contaminados suelen ser pequeños, livianos y encogidos, lo que disminuye el rendimiento y la calidad. Una detección temprana permitiría a los agricultores separar los granos infectados y, si es necesario, utilizarlos para generación de energía (Bauriegel et al., 2011).

La ocratoxina es producida por ciertas especies de hongos *Aspergillus* y *Penicillium*. Esta micotoxina se encuentra en granos, café, uvas y otros alimentos. La variante más común es la ocratoxina A (OTA), asociada con problemas renales, daño al ADN y efectos cancerígenos. La OTA es principalmente conocida por sus efectos nefrotóxicos en animales, excepto rumiantes. También se ha relacionado con hepatotoxicidad, teratogenicidad e inmunotoxicidad. Debido a la gravedad de su impacto, muchos países han implementado regulaciones para controlar su presencia, estableciendo límites máximos en alimentos y productos para animales (Senthilkumar et al., 2016). Su presencia se reporta con mayor frecuencia en regiones templadas (Senthilkumar et al., 2017).

El análisis de la distribución de micotoxinas en los artículos fue realizado para determinar el enfoque de las investigaciones. Al examinar esta distribución, se puede identificar cuáles micotoxinas recibieron mayor atención en los estudios. La representación detallada de esta distribución se muestra en la Figura 2.

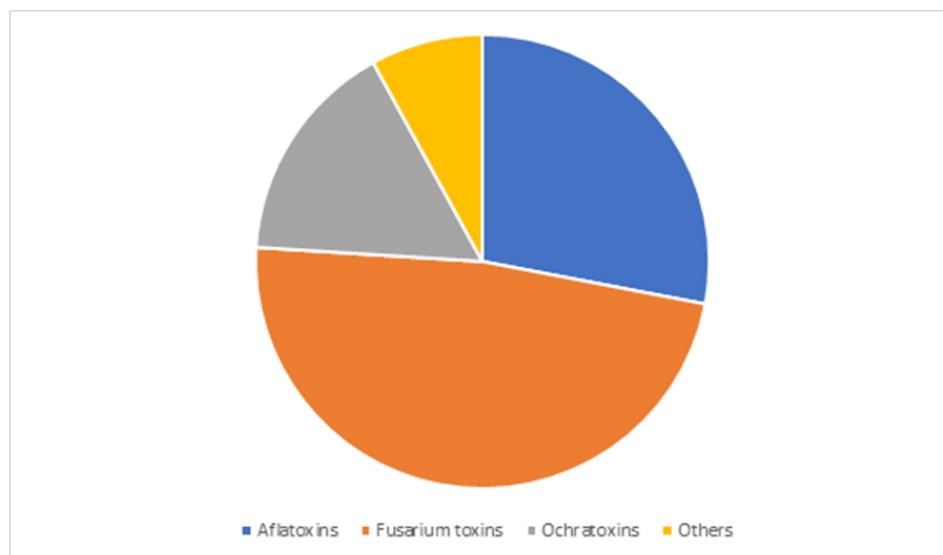


Figura 2. Distribución de contaminantes comunes en los artículos seleccionados: Aflatoxinas, toxinas de *Fusarium*, ocratoxinas y otros contaminantes. El gráfico de pastel representa la distribución de diferentes tipos de micotoxinas. Está dividido en cuatro secciones, cada una etiquetada con un color específico: Aflatoxinas en azul, toxinas de *Fusarium* en naranja, Ocratoxinas en gris y otras toxinas en amarillo.

Procesamiento y análisis

El proceso de recolección de datos en HSI es una tarea compleja, ya que implica capturar una gran cantidad de información de las muestras, susceptible a diversas fuentes de interferencia. Estas interferencias, derivadas de factores físicos, ambientales o instrumentales, pueden introducir variaciones indeseadas que afectan la robustez y precisión de los modelos de predicción. Para abordar estos desafíos y mejorar la relación señal-ruido, se emplean diversas técnicas de preprocesamiento destinadas a reducir las variaciones no deseadas.

Entre las técnicas de preprocesamiento comúnmente utilizadas se encuentran el Análisis de Componentes Principales (PCA), Mínimos Cuadrados Parciales (PLS), Análisis Discriminante Lineal (LDA), Análisis Discriminante de Fisher (FDA), Regresión Multilineal (MLR) y Redes Neuronales Artificiales (ANN). Estas herramientas desempeñan un papel crucial en la identificación de diferencias significativas entre las muestras analizadas. Contribuyen significativamente al desarrollo de modelos de predicción precisos, mejorando la comprensión y la toma de decisiones en la investigación científica.

La complejidad del análisis aumenta debido a que las diferencias observadas entre las muestras normales y contaminadas pueden variar según el tipo de semilla y sus propiedades espectrales específicas. En algunos casos, las semillas contaminadas muestran un desplazamiento hacia longitudes de onda más largas en comparación con las semillas de control. Este desplazamiento en los máximos de emisión se asocia con diversos fluoróforos presentes predominantemente en la pared celular de las plantas, como los polifenoles/lignina. Estas alteraciones en las características de fluorescencia sugieren cambios en los fluoróforos. El análisis de discriminación lineal LDA se ha aplicado a los datos de fluorescencia, logrando una notable precisión en la clasificación (Bartolić, 2022).

Por otro lado, PCA es valioso para reducir la dimensionalidad de las características espectrales y de textura, haciendo la información más manejable y facilitando el análisis subsiguiente (Weng et al., 2020). Independientemente de la técnica utilizada, la parte crucial es identificar la longitud de onda característica donde el grano infectado se diferencia del sano, permitiendo que los algoritmos utilicen esta diferencia para realizar la selección automática (Chu et al., 2020). En algunos casos, las diferencias entre muestras normales y contaminadas son más evidentes, simplificando la tarea de posprocesamiento. Por ejemplo, (Delwiche et al., 2019) observó una reflectancia significativamente mayor en toda la región de longitud de onda en los granos contaminados en comparación con los sanos.

La selección y sofisticación de las técnicas de análisis utilizadas dependen de la disponibilidad de herramientas y la experiencia del equipo de investigación. Diversos artículos emplean un espectro de estas técnicas para analizar los datos hiperespectrales y obtener información relevante, ilustrando los variados enfoques dentro de este campo de estudio. Esta diversidad resalta la naturaleza adaptable de HSI en la investigación científica.

Ventajas

La aplicación de HSI en la detección de microorganismos y sus toxinas en alimentos ofrece numerosas ventajas. En primer lugar, permite un análisis rápido y no destructivo, minimizando la necesidad de una preparación extensa de las muestras y reduciendo el tiempo total de análisis. Esto resulta especialmente beneficioso en industrias donde es esencial realizar un cribado eficiente de grandes volúmenes de muestras alimenticias. La naturaleza no destructiva de HSI también permite realizar pruebas o análisis adicionales si es necesario (Wang et al., 2014). Esto contrasta con los métodos tradicionales de detección en alimentos, que, aunque altamente precisos y con límites de detección bajos, eran complejos, lentos, destructivos para las muestras y requerían el uso de productos químicos y personal de laboratorio capacitado (Wang et al., 2014; Alisaac et al., 2019; Femenias et al., 2020).

HSI sobresale en la captura de información espectral altamente detallada de las muestras. Proporciona datos tanto espectrales como espaciales, lo que permite medir la totalidad de la muestra mientras incorpora atributos espaciales, como la ubicación de los contaminantes. Esta conciencia espacial facilita la eliminación selectiva de las porciones dañadas o contaminadas, preservando la integridad del resto de la muestra (da Conceição et al., 2021).

Además, HSI puede emplearse para el cribado y clasificación a gran escala de productos alimenticios. Su capacidad para analizar rápidamente un gran número de muestras ayuda en la identificación temprana de productos contaminados o infectados. Esta detección oportuna reduce el riesgo de una contaminación generalizada y minimiza los posibles riesgos para la salud asociados con alimentos en mal estado. Esto resulta particularmente valioso para garantizar la seguridad alimentaria en contextos de producción y distribución masiva.

Por último, en términos de evaluación de frescura, HSI proporciona información crítica sobre la calidad y vida útil de productos perecederos. Al monitorear continuamente los cambios en los patrones espectrales, puede detectar indicadores tempranos de deterioro, como el oscurecimiento, magulladuras o crecimiento microbiano.



Esta evaluación en tiempo real permite intervenciones proactivas y medidas rigurosas de control de calidad, asegurando que solo productos frescos y seguros lleguen a los consumidores. Por lo tanto, desempeña un papel crucial en el mantenimiento de la calidad e inocuidad de los alimentos a lo largo de toda la cadena de suministro (Alisaac et al., 2019).

Desafíos

A pesar de los beneficios potenciales, la integración de HSI en la detección de microorganismos y sus toxinas en alimentos no está exenta de desafíos. La naturaleza compleja de los datos requiere algoritmos sofisticados y modelos de calibración robustos para garantizar la clasificación e identificación precisa de microorganismos. El desarrollo y perfeccionamiento de estas herramientas analíticas es crucial para maximizar la efectividad de HSI en aplicaciones de inocuidad alimentaria (Ravikanth et al., 2016).

Uno de los principales inconvenientes de HSI es su costo y complejidad. Su implementación requiere computadoras rápidas, detectores sensibles y grandes capacidades de almacenamiento para analizar los datos hiperespectrales. La adquisición y el procesamiento de cubos hiperespectrales, que son conjuntos de datos multidimensionales de gran tamaño, pueden demandar recursos significativos y aumentar el costo total de la tecnología. Sin embargo, cabe destacar que, con los avances tecnológicos y el aumento en las capacidades de producción, los costos asociados con HSI están disminuyendo gradualmente. En los próximos años, se espera que HSI sea más accesible incluso en laboratorios menos sofisticados o grupos de investigación.

HSI genera un volumen sustancial de datos, lo que plantea desafíos logísticos en términos de manejo y gestión de la información. El procesamiento y análisis eficiente de datos requieren computadoras de alta velocidad e infraestructura computacional avanzada. El desafío de la alta dimensionalidad surge al trabajar con datos que contienen muchas características o canales, como ocurre con las imágenes de alta banda. La expansión del contenido de información en estos casos puede aumentar los errores en la estimación, lo que subraya la necesidad de estrategias cuidadosas de gestión y análisis de datos (Datta et al., 2022).

Además, las condiciones ambientales pueden influir en los resultados de HSI. Variaciones en las condiciones de iluminación, la dispersión de la luz y otros factores ambientales pueden afectar la calidad de los datos adquiridos, lo que podría resultar en una baja relación señal/ruido. Asimismo, la sensibilidad de los sensores HSI puede dificultar la captura de imágenes al trabajar con muestras líquidas, ya que estas presentan heterogeneidad inherente, lo que podría afectar la calidad y confiabilidad de los datos espectrales.

Machine learning

En los últimos años, el aprendizaje automático (Machine Learning, ML) ha emergido como una herramienta poderosa en diversos campos, y su impacto continúa creciendo y expandiéndose hacia nuevos dominios. El campo de las imágenes hiperespectrales no es una excepción, ya que las técnicas de ML se han convertido en una parte integral del proceso de análisis e interpretación. Esta tecnología ha contribuido significativamente a mejorar la precisión en la detección (Kim et al., 2022).

En los artículos analizados, los investigadores han complementado frecuentemente las imágenes hiperespectrales con diversos programas y algoritmos de ML. Los métodos de ML aplicados pueden dividirse en tres tipos: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje reforzado (Soni et al., 2022). Una de las principales ventajas del uso de ML en este ámbito es la capacidad de automatizar procesos y reducir la dependencia de la intervención humana. A través del desarrollo de algoritmos avanzados, el ML permite automatizar tareas como el preprocesamiento de datos, la extracción de características y la clasificación. Esta automatización no solo ahorra tiempo, sino que también garantiza consistencia y repetibilidad en el análisis, minimizando el riesgo de errores humanos. Los métodos más precisos y confiables de identificación y clasificación de muestras contribuyen a mejorar las evaluaciones de inocuidad alimentaria.

Por otro lado, el ML facilita la integración de las HSI con sistemas de monitoreo en tiempo real. Al analizar continuamente los datos hiperespectrales mediante algoritmos de ML, es posible detectar cambios y anomalías en las muestras de alimentos en tiempo real. Este enfoque proactivo permite intervenciones rápidas y la toma de decisiones oportuna, reduciendo el riesgo de contaminación o deterioro de la calidad. Además, estas técnicas

pueden emplearse durante el procesamiento y análisis para reducir el ruido de fondo y mejorar la relación señal-ruido (Soni et al., 2022).

Direcciones futuras

A pesar del rápido avance de esta tecnología, aún queda mucho por lograr. Se están llevando a cabo esfuerzos continuos para optimizar la integración de las imágenes hiperespectrales con otras modalidades y tecnologías de detección. La combinación con técnicas como la espectroscopía de infrarrojo cercano (NIRS), la imagen por rayos X u otras técnicas complementarias puede proporcionar una comprensión más integral de las muestras de alimentos. Esta sinergia permite extraer una gama más amplia de información, lo que potencialmente mejora la precisión y confiabilidad de las evaluaciones de inocuidad alimentaria. Por ejemplo, la fusión de datos de HSI y la espectroscopía en el infrarrojo cercano (NIRS) puede proporcionar información simultánea sobre la composición química y la estructura, enriqueciendo la profundidad del análisis y mejorando la detección de contaminantes (Fernández Pierna et al., 2012).

Otra tecnología clave emergente es la quimiometría, que implica la aplicación de métodos matemáticos y estadísticos para analizar datos químicos. Cuando se combina con imágenes hiperespectrales, permite una identificación y cuantificación más precisa de patógenos y contaminantes. Los investigadores están refinando continuamente los modelos quimiométricos para manejar mejor la complejidad de los datos hiperespectrales, mejorando la precisión de los algoritmos de detección y clasificación. Este desarrollo constante asegura que HSI sigan siendo una metodología analítica de vanguardia en la inocuidad alimentaria.

Los avances en miniaturización están haciendo que esta tecnología sea más portátil y rentable. Las cámaras hiperespectrales miniaturizadas son cada vez más accesibles, lo que permite realizar pruebas e inspecciones *in situ* en diversos entornos, incluidos campos, instalaciones de procesamiento y puntos de venta. La capacidad de realizar estas pruebas en el campo puede mejorar significativamente la velocidad y eficiencia de las evaluaciones de seguridad alimentaria (Soni et al., 2022).

Por otro lado, los desarrollos futuros en las HSI probablemente priorizarán la sostenibilidad y el impacto ambiental. Esto incluye la reducción del consumo de energía y la huella ambiental de los sistemas, así como la exploración de materiales ecológicos para las cámaras hiperespectrales. La industria alimentaria busca cada vez más soluciones sostenibles, y se espera que esta tecnología se alinee con estos objetivos de sostenibilidad. Esto está profundamente relacionado con lograr una mayor aceptación regulatoria en la inocuidad alimentaria. A medida que la tecnología madure y demuestre su confiabilidad, se espera que gane mayor reconocimiento y aceptación por parte de los organismos reguladores de inocuidad alimentaria a nivel mundial, facilitando aún más su adopción en la industria alimentaria.

CONCLUSIONES

La adopción de esta tecnología no es una coincidencia, sino una respuesta a la necesidad urgente de contar con soluciones efectivas y en tiempo real para abordar el problema crítico de la contaminación alimentaria. Este reconocimiento subraya la importancia de aprovechar los avances tecnológicos para proteger la salud pública y mejorar la integridad general de la cadena de suministro de alimentos.

El creciente uso de la tecnología HSI en la inocuidad alimentaria destaca su potencial y ventajas. Esta tecnología abre nuevas posibilidades para identificar y gestionar alimentos contaminados, permitiendo intervenciones oportunas y garantizando la seguridad de los consumidores. Los hallazgos presentados en este análisis no solo ofrecen una introducción, sino que también sirven como una hoja de ruta para una exploración y un avance más profundos en este campo.

Además, la creciente prevalencia de publicaciones de investigación en esta área refleja el interés y reconocimiento cada vez mayor de HSI como una herramienta práctica para mejorar la inocuidad alimentaria. El gráfico examinado ilustra un incremento notable en el número de publicaciones, lo que indica la expansión de la adopción y diseminación de esta tecnología. Asimismo, el acceso a esta tecnología se está volviendo más común en diferentes países, con una disponibilidad en constante aumento a nivel global.

Es importante enfatizar que las HSI no operan de manera aislada; más bien, trabajan en colaboración con técnicas avanzadas, como se discute en este documento. Esta asociación sinérgica mejora su capacidad para



analizar, categorizar y tomar decisiones. Al integrar estas herramientas avanzadas, el futuro de la inocuidad alimentaria está tomando forma para ser más preciso y eficiente, garantizando niveles sin precedentes de seguridad en la cadena de suministro de alimentos.

REFERENCIAS

- Alisaac, E., Behmann, J., Rathgeb, A., Karlovsky, P., Dehne, H.-W., y Mahlein, A.-K.** (2019). Assessment of *Fusarium* Infection and Mycotoxin Contamination of Wheat Kernels and Flour Using Hyperspectral Imaging. *Toxins*, 11(10), Article 556. <https://doi.org/10.3390/toxins11100556>
- Bartolić, D., Mutavdžić, D., Carstensen, J. M., Stanković, S., Nikolić, M., Krstović, S., y Radotić, K.** (2022). Fluorescence spectroscopy and multispectral imaging for fingerprinting of aflatoxin-B1 contaminated (*Zea mays L.*) seeds: a preliminary study. *Scientific Reports*, 12, Article 4849. <https://doi.org/10.1038/s41598-022-08352-4>
- Bauriegel, E., y Herppich, W.B.** (2014). Hyperspectral and Chlorophyll Fluorescence Imaging for Early Detection of Plant Diseases, with Special Reference to *Fusarium* spec. Infections on Wheat. *Agriculture*, 4(1), 32-57. <https://doi.org/10.3390/agriculture4010032>
- Bauriegel, E., Giebel, A., Geyer, M., Schmidt, U., y Herppich, W.B.** (2011). Early detection of *Fusarium* infection in wheat using hyper-spectral imaging. *Computers and Electronics in Agriculture*, 75(2), 304 -312. <https://doi.org/10.1016/j.compag.2010.12.006>
- Chu, X., Wang, W., Ni, X., Li, C., y Li, Y.** (2020). Classifying maize kernels naturally infected by fungi using near-infrared hyperspectral imaging. *Infrared Physics & Technology*, 105, 103242. <https://doi.org/10.1016/j.infrared.2020.103242>
- Chu, X., Wang, W., Yoon, S-C., Ni, X., y Heitschmidt, G. W.** (2017). Detection of aflatoxin b1 (AFB1) in individual maize kernels using short wave infrared (SWIR) hyperspectral imaging. *Biosystems Engineering*, 157, 13-23. <https://doi.org/10.1016/j.infrared.2020.103242>
- da Conceição, R. R. P., Simeone, M. L. F., Queiroz, V. A. V., de Medeiros, E. P., de Araújo, J. B., Coutinho, W. M., da Silva, D. D., de Araújo Miguel, R., de Paula Lana, U. G., y de Resende Stoiano, M. A.** (2021). Application of near-infrared hyperspectral (NIR) images combined with multivariate image analysis in the differentiation of two mycotoxicogenic fusarium species associated with maize. *Food Chemistry*, 344, Article 128615. <https://doi.org/10.1016/j.foodchem.2020.128615>
- Datta, D., Mallick, P. K., Bhoi, A. K., Ijaz, M. F., Shafi, J. y Choi, J.** (2022). Hyperspectral image classification: Potentials, challenges, and future directions. *Computational Intelligence and Neuroscience*, 2022, Article 3854635. <https://doi.org/10.1155/2022/3854635>
- Delwiche, S. R., Torres Rodriguez, I., Rausch, S. R., y Graybosch, R. A.** (2019). Estimating percentages of fusarium-damaged kernels in hard wheat by near infrared hyperspectral imaging. *Journal of Cereal Science*, 87, 18-24. <https://doi.org/10.1016/j.jcs.2019.02.008>
- Femenias, A., Gatius, F., Ramos, A. J., Sanchis, V., y Marín, S.** (2020). Use of hyperspectral imaging as a tool for fusarium and deoxynivalenol risk management in cereals: A review. *Food Control*, 108, Article 106819. <https://doi.org/10.1016/j.foodcont.2019.106819>
- Femenias, A., Gatius, F., Ramos, A. J., Teixido-Orries, I., y Marín, S.** (2022) Hyperspectral imaging for the classification of individual cereal kernels according to fungal and mycotoxins contamination: A review. *Food Research International*, 155, Article 111102. <https://doi.org/10.1016/j.foodres.2022.111102>
- Del Fiore, A., Reverberi, M., Ricelli, A., Pinzari, F., Serranti, S., Fabbri, A. A., Bonifazi, G., y Fanelli, C.** (2010). Early detection of toxicogenic fungi on maize by hyperspectral imaging analysis. *International Journal of Food Microbiology*, 144(1), 64-71. <https://doi.org/10.1016/j.ijfoodmicro.2010.08.001>
- Huang, H., Liu, L., y Ngadi, M.** (2014). Recent developments in hyperspectral imaging for assessment of food quality and safety. *Sensors*, 14(4), -7276. <https://doi.org/10.3390/s140407248>
- Kim, Y.-K., Baek, I., Lee, K.-M., Qin, J., Kim, G., Shin, B. K., Chan, D. E., Herman, T. J., Cho, S. k., y Kim, M S.** (2022). Investigation of reflectance, fluorescence, and raman hyperspectral imaging techniques for rapid detection of aflatoxins in ground maize. *Food Control*, 132, Article 108479. <https://doi.org/10.1016/j.foodcont.2021.108479>

-
- Liang, K., Huang, J., He, R., Wang, Q., Chai, Y., y Shen, M.** (2020). Comparison of vis-NIR and SWIR hyperspectral imaging for the non-destructive detection of DON levels in fusarium head blight wheat kernels and wheat flour. *Infrared Physics & Technology*, 106, Article 103281. <https://doi.org/10.1016/j.infrared.2020.103281>
- Ma, J., Sun, D.-W., Pu, H., Cheng, J.-H., y Wei, Q.** (2019). Advanced techniques for hyperspectral imaging in the food industry: Principles and recent applications. *Annual Review of Food Science and Technology*, 10(1), 197-220. <http://doi.org/10.1146/annurev-food-032818-121155>
- Nadimi, M., Brown, J.M., Morrison, J., y Paliwal, J.** (2021). Examination of wheat kernels for the presence of fusarium damage and mycotoxins using near-infrared hyperspectral imaging. *Measurement: Food*, 4, Article 10001. <https://doi.org/10.1016/j.meafoo.2021.100011>
- Parrag, V., Gillay, Z., Kovács, Z., Zitek, A., Böhm, K., Hinterstoisser, B., Krska, R., Sulyok, M., Felföldi, J., Firtha, F., y Baranyai, L.** (2020). Application of hyperspectral imaging to detect toxigenic fusarium infection on cornmeal. *Progress in Agricultural Engineering Sciences*, 16(1), 51-60. <https://doi.org/10.1556/446.2020.00009>
- Fernández Pierna, J.A., Vermeulen, P., Amand, O., Tossens, A., Dardenne, P., y Baeten, V.** (2012). NIR hyperspectral imaging spectroscopy and chemometrics for the detection of undesirable substances in food and feed. *Chemometrics and Intelligent Laboratory Systems*, 117, 233-239. <https://doi.org/10.1016/j.chemolab.2012.02.004>
- Ravikanth, L., Jayas, D.S., White, N.D.G., Fields, P. G., y Sun, D.-W.** (2016). Extraction of spectral information from hyperspectral data and application of hyperspectral imaging for food and agricultural products. *Food and Bioprocess Technology*, 10(1). <https://doi.org/10.1007/s11947-016-1817-8>
- Senthilkumar, T., Jayas, D.S., White, N.D.G., Fields, P.G., y Grafenhan, T.** (2017). Detection of ochratoxin a contamination in stored wheat using near-infrared hyperspectral imaging. *Infrared. Physics & Technology*, 81, 228-235. <https://doi.org/10.1016/j.infrared.2017.01.015>
- Senthilkumar, T., Jayas, D. S., White, N.D.G., Fields, P.G., y Grafenhan, T.** (2016). Detection of fungal infection and ochratoxin a contamination in stored barley using near-infrared hyperspectral imaging. *Biosystems Engineering*, 147, Article 162173. <https://doi.org/10.1016/j.biosystemseng.2016.03.010>
- Soni, A., Dixit, Y., Reis, M.M., y Brightwell, G.** (2022). Hyperspectral imaging and machine learning in food microbiology: Developments and challenges in detection of bacterial, fungal, and viral contaminants. *Comprehensive Reviews in Food Science and Food Safety*, 21(4), 3717-3745. <https://doi.org/10.1111/1541-4337.12983>
- Teixido-Orries, I., Molino, F., Gatius, F., Sanchis, V., y Marín, S.** (2023). Near-infrared hyperspectral imaging as a novel approach for t-2 and HT-2 toxins estimation in oat samples. *Food Control*, 153, Article 109952. <https://doi.org/10.1016/j.foodcont.2023.109952>
- Wang, W., Heitschmidt, G.W., Ni, X., Windham, W.R., Hawkins, S., y Chu, X.** (2014). Identification of aflatoxin b1 on maize kernel surfaces using hyperspectral imaging. *Food Control*, 42, 78-86. <https://doi.org/10.1016/j.foodcont.2014.01.038>
- Weng, S., Tang, P., Yuan, H., Guo, B., Yu, S., Huang, L., y Xu, C.** (2020). Hyperspectral imaging for accurate determination of rice variety using a deep learning network with multi-feature fusion. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 234, Article 118237. <https://doi.org/10.1016/j.saa.2020.118237>
- Yao, H., Hruska, Z., Kincaid, R., Brown, R.L., Bhatnagar, D., y Cleveland, T.E.** (2013). Detecting maize inoculated with toxigenic and atoxigenic fungal strains with fluorescence hyperspectral imagery. *Biosystems Engineering*, 115(2), 125-135. <https://doi.org/10.1016/j.biosystemseng.2013.03.006>

