

Enfoques no invasivos para la evaluación y el monitoreo de enfermedades vegetales*

Non-Invasive Approaches for Oil Palm Disease Assessment and Monitoring



SIVA K. BALASUNDRAM

Departamento de Tecnología
Agropecuaria, Facultad de Agricultura,
Technology
Agricultural Department, Faculty of
Agriculture, Universiti Putra Malaysia

AUTORES: Siva K. Balasundram, Kamlesh Golhani, Redmond R. Shamshiri, Departamento de Tecnología Agropecuaria, Facultad de Agricultura, Universiti Putra Malaysia.

CITACIÓN: Balasundram, S K., Golhani, K., & Shamshiri, R. R. (2019). Enfoques no invasivos para la evaluación y el monitoreo de enfermedades vegetales. *Palmas*, 40 (Especial Tomo I), 204-219.

PALABRAS CLAVE: protección vegetal de precisión, detección temprana, espectroscopia sin imágenes, espectroscopia de imágenes, índice espectral de enfermedades.

KEYWORDS: Precision plant protection, early detection, spectroscopy without images, image spectroscopy, disease spectral index.

*Artículo original recibido en inglés y traducido por Carlos Arenas París.

Resumen

La evaluación de enfermedades vegetales se realiza para analizar las mediciones de enfermedades/patógenos (fitopatometría), siendo fundamental para estimar la intensidad y las pérdidas de cultivos. Ayuda a los investigadores y agricultores a determinar la causa de la enfermedad y el grado del daño (físico y económico). Se requiere de un enfoque preciso y confiable para validar su identificación y estimar su gravedad. Las técnicas contemporáneas desarrolladas para la detección de enfermedades vegetales giran en torno al concepto de métodos de muestreo no destructivos. Estos pueden llevarse a cabo rápida y rigurosamente, sin afectar el crecimiento del cultivo. Se han estudiado varias técnicas espectroscópicas y de imagen para detectar los organismos dañinos que las causan. Las enfermedades que se evalúan, según sus síntomas visuales en el cultivo, son llamadas sintomáticas. Es importante analizar el tipo de daño, la causa del síntoma, el efecto y las maneras de prevenir una mayor propagación. Generalmente, se sabe que la mayoría de las enfermedades que atacan los cultivos tienen efectos adversos sobre el rendimiento. A continuación, se describe el uso de herramientas de la agricultura de precisión, tales como la espectroscopia de reflectancia y redes neuronales artificiales, para evaluar y monitorear enfermedades vegetales.

Introducción

Típicamente, las enfermedades vegetales atacan el aparato fotosintético y afectan el crecimiento de la planta (Lichtenthaler, 1996). La mayoría (aproximadamente el 85 %) son causadas por organismos fúngicos o similares a los hongos. Otras, por bacterias, virus y viroides, y unas pocas por ciertos nematodos (Isleib, 2012). Los microorganismos patógenos son de naturaleza ubicua. Caracterizan los síntomas y producen enfermedades debido a la susceptibilidad de la planta a sus impactos adversos. Gran parte de los patógenos desempeñan actividades esenciales en la naturaleza, obtienen nutrientes de su hospedador y se asocian con las plantas mediante relaciones simbióticas o no simbióticas. Las plantas sospechosas deben identificarse por sus síntomas foliares y en los frutos externos, antes de realizar investigaciones en el laboratorio. En la mayoría de los casos, estos síntomas visibles suelen manifestarse en las etapas media a tardía de la infección (Strange, 2005). No obstante, la identificación morfológica de las enfermedades no es confiable. Se requiere un método apropiado para detectar el agente causal.

Tradicionalmente, los hongos se reconocían morfológicamente, seguido de su aislamiento y cultivo. Por otra parte, se realizaban pruebas biológicas para detectar las bacterias, y los virus eran identificados con base en su material genético, ensayos de transmisión y su rango de hospedadores (Sharma y Sharma, 2016). Recientemente, los avances en la biotecnología y la biología molecular han revolucionado el campo de la detección de enfermedades vegetales. Se han desarrollado varias técnicas invasivas de diagnóstico, tales como el *Western blot*, el ensayo por inmunoadsorción ligado a enzimas (ELISA), la reacción en cadena de la polimerasa con transcriptasa inversa (RT-PCR, en inglés) y chips de ADN (Sharma y Sharma, 2016). Con estas técnicas de laboratorio es posible detectar una enfermedad vegetal tan pronto como aparecen los síntomas. Son conocidas también como destructivas o de marcador molecular, e implican el muestreo destructivo de hojas, seguido de un tratamiento químico.

Cada técnica tiene sus propias ventajas y limitaciones. Los investigadores prefieren adoptar las invasivas debido a su velocidad y precisión en la detección de enfermedades. Sin embargo, plantean inconsisten-

cia e insensibilidad debido a diferentes razones, como la interacción y la concentración hospedador-patógeno. Por ejemplo, el viroide cadang cocotero (Cocunut cadang-cadang, cccvd) es un agente causal de la enfermedad de manchas color naranja en la palma de aceite (*Elaeis guineensis* Jacq.), que se puede detectar utilizando RT-PCR (Wu *et al.*, 2013; Vadamalai *et al.*, 2016), el ensayo de protección de ribonucleasas (RPA, por su sigla en inglés) (Vadamalai *et al.*, 2009), y amplificación isotérmica mediada por LOOP (LAMP, por su sigla en inglés) (Thanarajoo *et al.*, 2014). Un estudio reciente encontró que estas técnicas no eran ni consistentes ni sensibles, y que no lograban cuantificar las concentraciones del viroide (Thanarajoo, 2014). Así mismo, Sakudo *et al.* (2006) descubrieron que las técnicas invasivas (ELISA, RT-PCR y *Western blot*) eran efectivas para el diagnóstico de infecciones virales, pero ninguna de ellas era ideal en términos de rentabilidad, rapidez y precisión. Recientemente, Cui *et al.* (2018) revisaron las ventajas y desventajas de las técnicas invasivas y no invasivas.

Hay algunas más que también se usan con frecuencia, como por ejemplo la reacción en cadena de la polimerasa (PCR, por su sigla en inglés) y la hibridación fluorescente in situ (FISH, por su sigla en inglés). La PCR es fácil de operar y es portátil, pero ha sido sometida a extracción de ADN, inhibidores y actividad de la polimerasa (Eun *et al.*, 2002a; Eun *et al.*, 2002b). FISH es altamente sensible y permite la visualización, identificación, enumeración y conteo simultáneo de células microbiales individuales, pero la autofluorescencia del microorganismo es un obstáculo importante (Perera *et al.*, 2002).

En la última década se han desarrollado varias técnicas no invasivas, que son sensibles, consistentes, de alto rendimiento, rápidas y rentables. Su aplicación ha aumentado constantemente, siendo las más populares: espectroscopia de fluorescencia, espectroscopia visible/infrarrojo cercano (VNIR, por su sigla en inglés), imágenes de fluorescencia e imágenes hiperespectrales (Sankaran *et al.*, 2010).

Antecedentes

Las imágenes hiperespectrales son una técnica importante en la teledetección. Los sensores hiperes-

pectrales capturan datos desde el rango visible al infrarrojo cercano del espectro electromagnético, y adquieren información espectral de cientos de bandas estrechas (Ghamisi *et al.*, 2017). Es una de las técnicas más eficientes y de rápido desarrollo, con la que se puede extraer información precisa y detallada sobre un objeto (Ortenberg *et al.*, 2011). Por ejemplo, se han utilizado sensores hiperes-

pectrales como una herramienta para la espectroscopia de campo en aplicaciones geológicas (Goetz *et al.*, 2009; Thompson *et al.*, 1999) y agrícolas (Liu *et al.*, 2018; Silva-Perez *et al.*, 2017). Las imágenes hiperespectrales han sido usadas en varias secuencias de la resolución de problemas, como en la detección, clasificación, discriminación, identificación y caracterización (Chang, 2007; Chang, 2003). Sus ventajas hacen que la precisión de la protección vegetal sea aún más alcanzable. Varios estudios recientes (Lu *et al.*, 2018; Whetton *et al.*, 2018a; Whetton *et al.*, 2018b; Heim *et al.*, 2018; Dhau, *et al.*, 2018; Kong *et al.*, 2018) han intentado explicar el papel de las bandas hiperespectrales en la distinción entre plantas sanas y enfermas. La literatura destaca una interpretación más completa y dinámica de los datos hiperespectrales, que puede llevar a una detección temprana de las enfermedades vegetales. Por ejemplo, Moghadam *et al.* (2017) describieron la importancia de las imágenes hiperespectrales de rango completo y las técnicas de aprendizaje automático, para diferenciar entre plantas de capsicum sanas e infectadas con el virus del bronceado del tomate (TSWV, por su sigla en inglés). Se utilizaron varios índices de vegetación (VI, por su sigla en inglés) y modelos probabilísticos basados en datos para entrenar los clasificadores para la detección de TSWV. Ahmadi *et al.* (2017) hallaron la enfermedad de la Pudrición basal del estípite por *Ganoderma* en la palma de aceite en sus etapas tempranas, a partir de datos espectroscópicos y de imágenes, utilizando una red neuronal artificial.

La mayoría de las veces, las firmas espectrales de una planta enferma no se pueden analizar correctamente usando enfoques paramétricos, tales como re-

La mayoría de las veces, las firmas espectrales de una planta enferma no se pueden analizar correctamente usando enfoques paramétricos, tales como regresión simple o múltiple y estadísticas funcionales.

gresión simple o múltiple y estadísticas funcionales. Por lo tanto, los enfoques no paramétricos, tales como el análisis de componentes principales (ACP), la lógica difusa, las máquinas de vectores de soporte (SVM, por su sigla en inglés), el análisis de grupos (CA), los mínimos cuadrados parciales (PLS, por su sigla en inglés), y las redes neuronales (RN), han sido utilizados en el área de la espectroscopia hiperespectral. Por ejemplo, la técnica del análisis discriminante lineal de Fisher (ADL) se utiliza para clasificar datos hiperespectrales con y sin imágenes de dos o más clases.

Básicamente, los datos hiperespectrales son de naturaleza multivariante. El ACP es un método estadístico multivariado que elimina la redundancia en los análisis univariados, y ayuda a identificar patrones de los datos espectrales. Básicamente, el ACP transforma grandes números de variables correlacionadas en números más pequeños de variables no correlacionadas, llamados componentes principales (CP) (Zhao *et al.*, 2011). El ACP y el PLS fueron utilizados recientemente para la detección de enfermedades fúngicas (moho amarillo y fusariosis de la espiga) en el trigo y la cebada (Whetton *et al.*, 2018a; Whetton *et al.*, 2018b). Whetton *et al.* (2018a) realizaron un ACP en cultivos de cereal infectados con moho amarillo y fusariosis de la espiga, en diferentes etapas del crecimiento, y estudiaron su patrón temporal y su autocorrelación serial. Los resultados sugirieron usar PLS para cada etapa con el fin de obtener una predicción precisa. En la segunda parte del estudio, Whetton *et al.* (2018b) utilizaron la regresión PLS con validación cruzada dejando uno afuera para ambas enfermedades. Los resultados mostraron que el modelo de regresión desarrollado para la fusariosis de la espiga y el moho amarillo en

el trigo puede aplicarse para predecir estas enfermedades en la cebada.

Recientemente, Lu *et al.* (2018) también realizaron un ACP para evaluar 57 VI diferentes y obtuvieron seis CP para detectar hojas de tomate infectadas con varias enfermedades en distintas etapas. Se empleó el método de k vecinos más cercanos para clasificar cada CP con coeficientes de peso que van de 1 a 30. Se logró la mayor precisión de clasificación (100 %) para las hojas de tomate sanas entre las sanas y enfermas que se probaron. Utilizando el concepto de la teoría de conjuntos difusos, Kole *et al.* (2014) propusieron operaciones de procesamiento digital de imágenes con k-medias para la detección de la enfermedad del moho vellosa en hojas de uva. En total, se procesaron 31 imágenes digitales de plantas enfermas y sanas. La precisión de detección fue del 87 %.

El CA es una de las técnicas más empleadas. Para organizar los datos hiperespectrales, el CA permite agrupar píxeles dentro de valores espectrales similares y en clústeres (Leeser *et al.*, 2002). Krezhova *et al.* (2015) aplicaron el CA y la prueba t de Student, para determinar la significancia estadística de la diferencia entre las medias de los valores de reflectancia de control y manzanos infectados. La SVM es una técnica popular de aprendizaje automático, apropiada para el análisis de datos espectrales de alta dimensión (Zou *et al.*, 2006). Nagasubramanian *et al.* (2017) usaron un algoritmo genético (AG) y un optimizador con SVM para la selección de bandas espectrales óptimas para la identificación temprana de la podredumbre carbonosa en la soya. El enfoque AG-SVM la reconoció dentro de los tres días siguientes a la inoculación, con una precisión de clasificación del 97 %.

Las técnicas de aprendizaje automático tienen grandes desventajas, son altamente dependientes de los patrones en las variables, así como de las características que se van a extraer.

Las técnicas de aprendizaje automático tienen dos grandes desventajas. Primero, son altamente dependientes de los patrones en las variables, así como de las características que se van a extraer. Segundo, es necesario entrenar los clasificadores muchas veces antes de utilizarlos en aplicaciones del mundo real (Zhang *et al.*, 2015).

Las RN son las herramientas más prometedoras para el análisis de datos hiperespectrales. Típicamente, su mecanismo está basado en el sistema nervioso humano. Son muy útiles para reconocer patrones, independientemente de cualquier regla de reconocimiento explícito (Bishop, 1995). Según Cui *et al.* (2018), las RN requieren menos estadística formal y son capaces de modelar relaciones no lineales complejas. Existe un interés creciente en la aplicación de RN, para lograr el objetivo mayor de la protección vegetal de precisión utilizando datos hiperespectrales. Esta protección ofrece un medio holístico para controlar las enfermedades vegetales con base en el concepto de variabilidad espaciotemporal. Anteriormente, las RN han sido utilizadas para la minería de datos, pero sus varias aplicaciones con datos hiperespectrales han demostrado ser prometedoras para la detección temprana de enfermedades. Tienen capacidades únicas, tales como aprendizaje, generalización e imaginación para facilitar un diagnóstico confiable. Su grado de capacidad de diagnóstico es mayor que el de otras técnicas de aprendizaje automático.

Hoy en día, uno de los principales problemas es procesar grandes volúmenes de datos de imágenes hiperespectrales de alta dimensión (Ettabaa y Salem, 2018). La reducción de la dimensionalidad de los datos es una aplicación importante y eficiente para el manejo de datos hiperespectrales. Se ha reportado que se puede lograr un alto grado de reducción de la dimensionalidad de los datos al conservar una buena precisión de clasificación en los datos hiperespectrales (Goetz *et al.*, 1985). Es bien sabido que estos datos contienen información espectral aparente e inherente, de manera que sus logros y capacidades deben ser deliberados utilizando RN.

Las RN respaldan la capacidad de discriminación más poderosa para las enfermedades vegetales, porque combinan los mejores conjuntos de entrenadores para una clasificación precisa. Marini *et al.* (2008) describieron un tipo particular de técnica de reconocimiento de patrones basada en RN, llamada modelado de clase. Sus herramientas más populares fueron desarrolladas con base en la red neuronal artificial de Kohonen (Marini *et al.*, 2005) y una red de avance de múltiples capas (Marini *et al.*, 2007).

Al Bashish *et al.* (2010) utilizaron una infraestructura basada en el procesamiento de imágenes para la detección de cinco enfermedades: tizón temprano, moho blanco, moho ceniciento, tizón tardío y pequeña blancura de hojas y tallos de arroz. Se utilizaron las k-medias para agrupar las imágenes de las hojas enfermas. Luego, estas imágenes son pasadas por un clasificador de RN. El resultado describe que la RN detectó las enfermedades foliares con una precisión del 93 %.

Zhu *et al.* (2017) investigaron el potencial de las imágenes hiperespectrales como una técnica no invasiva de detección rápida. Hallaron el virus del mosaico del tabaco (TMV, por su sigla en inglés) en poco tiempo, utilizando imágenes hiperespectrales junto con el método de selección variable y con clasificadores de aprendizaje automático. Las precisiones subieron hasta el 95 % para los modelos con redes neuronales de propagación inversa (BPNN, por su sigla en inglés), máquinas de aprendizaje extremo (ELM, por su sigla en inglés), máquinas de vectores de soporte de mínimos cuadrados (LS-SVM), y hasta el 80 % para modelos quimiométricos con fusión de datos. En un estudio similar, Zhu *et al.* (2016) probaron BPNN junto con SVM, ELM, LS-VM, análisis de discriminación de mínimos cuadrados parciales (PLS-DA), LDA y bosques aleatorios (RF, por su sigla en inglés) para procesar imágenes hiperespectrales para la detección presintomática y la clasificación de TMV en las hojas de tabaco.

Un nuevo enfoque, llamado nariz con inteligencia artificial (nariz electrónica) es una técnica rápida y no invasiva para diagnosticar enfermedades vegetales

Un nuevo enfoque, llamado nariz con inteligencia artificial (nariz electrónica) es una técnica rápida y no invasiva para diagnosticar enfermedades vegetales

(Cui *et al.*, 2018). Con esta se pueden aplicar otras como RF, AC, SVM y regresión lineal para el reconocimiento de patrones. A pesar del amplio rango de aplicaciones de las RN, incluyendo la reducción de dimensionalidad y clasificación de datos, garantizan información espectral no adulterada de alta calidad para el análisis de datos hiperespectrales.

Una proporción de diferentes longitudes de onda de espectros de enfermedad pura, llamada índice espectral de enfermedad (SDI, por su sigla en inglés), también requiere estos algoritmos específicos de aprendizaje automático, que podrían ayudar a simplificar y, posiblemente, agilizar la detección de enfermedades vegetales. Ashourloo *et al.* (2016) describieron que los SDI son muy efectivos para reducir la dimensionalidad. Además, aumentan la tasa de estimación de enfermedades. Sin embargo, hasta el momento solo se ha desarrollado un pequeño número de SDI a partir de datos de teledetección hiperespectral con y sin imágenes, y no han sido procesados utilizando RN.

Los objetivos de este artículo son: i) discutir la aplicabilidad de RN al análisis de datos hiperespectrales para la detección temprana de enfermedades, y ii) revisar los nuevos SDI que podrían utilizarse para detectar enfermedades vegetales utilizando clasificadores de RN.

Detección temprana de enfermedades

La detección temprana de enfermedades vegetales utilizando métodos no destructivos puede minimizar la intervención humana directa en la protección vegetal. El diagnóstico rápido y preciso en etapas tempranas

nas es esencial para el control efectivo de las mismas. En los últimos años ha sido posible detectar y diagnosticar enfermedades vegetales en etapas iniciales utilizando datos hiperespectrales, en conjunto con modelos de RN. Sin embargo, la exploración visual continúa siendo una manera de inspección temprana para buscar síntomas de enfermedades.

Para lograr una detección y diagnóstico temprano confiable de las enfermedades vegetales, es necesario introducir e incorporar nuevos enfoques (espectroscopia con y sin imágenes) a una escala de laboratorio para complementar las técnicas moleculares, serológicas y microbiológicas, como ELISA Y RT-PCR. Estas técnicas enfrentan los desafíos del consumo de recursos en términos de tiempo, costo y mano de obra calificada. Por otro lado, se debe mantener un entorno altamente controlado y libre de contaminación al interior del laboratorio. No obstante, aún existe una amplia brecha entre el diagnóstico destructivo y no destructivo. La literatura reciente sugiere la aplicación de RN (Pu, 2017) con datos hiperespectrales (Moghadam *et al.*, 2017) como una medida para cerrar esta brecha. En particular, un enfoque de RN-hiperespectral mejora los resultados de clasificación en el diagnóstico no destructivo de enfermedades vegetales.

Los diversos patógenos microbianos causan una amplia gama de enfermedades en las plantas, como el moteado, mosaico, anillos y necrosis sistémica causada por virus (Wood, 1998); manchas foliares, tizón, podredumbre, marchitamiento, transmisión bacteriana, canchales, agallas, crecimientos excesivos, motas y costras, ocasionadas por bacterias (Raid, 2011); y antracnosis, roya, podredumbre de raíces y marchitamiento, principalmente por hongos (Koike *et al.*, 2017). No obstante, a menudo algunas enfermedades no manifiestan sus síntomas, permanecen asintomáticas, como por ejemplo la de las manchas color naranja en la palma de aceite, causada por viroides (Vadamalai *et al.*, 2016).

Los sensores hiperespectrales miden la reflectancia de las plantas enfermas. Luego, estos datos son utilizados para diseñar un modelo de RN y producir un sistema de soporte a la toma de decisiones. Los modelos hiperespectrales basados en RN actúan significativamente en la detección temprana de enfermedades. El principio básico de este enfoque es el

modelado de los datos de reflectancia del cultivo, que se miden utilizando técnicas hiperespectrales con y/o sin imágenes. Luego, se extraen las características de longitud de onda óptima (bandas espectrales) y se procesan usando técnicas multivariadas o de RN. Los VI se desarrollan a partir de estas bandas espectrales, que son de gran ayuda para caracterizar el estado del cultivo. Sin embargo, mientras tanto, la RN puede utilizar bandas espectrales o VI para modelar los datos.

Detección temprana utilizando espectroscopia sin imágenes

Típicamente, los datos hiperespectrales consisten en un gran número (<100) de bandas espectrales estrechas y contiguas. Es necesario preprocesarlas para analizar y modelar datos espectrales. Thenkabil *et al.* (2002) mencionaron los beneficios de utilizar un enfoque generoso de procesamiento de datos, tal como la red neuronal artificial, para seleccionar las mejores bandas espectrales. Los algoritmos de RN han sido implementados con éxito para identificar variables atípicas y características espectrales. Adicionalmente, también son un método de reducción de dimensionalidad. Los datos hiperespectrales se pueden procesar mucho más rápido con la técnica de RN que con otras. Las RN transforman los datos hiperespectrales en una forma de datos muy razonable (Qi *et al.*, 2011). Estos datos ofrecen una capacidad elevada de diagnóstico para la detección temprana de enfermedades. Las bandas espectrales con una absorción alta son más sensibles a varios pigmentos foliares, incluyendo clorofila a, clorofila b, violaxantina, β -caroteno, neoxantina y carotenoides. La patogenicidad en las plantas afecta directamente las concentraciones bioquímicas.

Tradicionalmente, un método de química húmeda implica la extracción de la hoja con solventes orgánicos para estimar el contenido de clorofila utilizando cromatografía líquida de alta eficacia (HPLC, por su sigla en inglés). En estos días, la estimación de clorofila se realiza con métodos no destructivos, mediante el espectrorradiómetro sin imágenes y un medidor portátil del desarrollo de análisis de suelos y plantas (SPAD, por su sigla en inglés). Las técnicas no destructivas miden el contenido de clorofila en tiempo real, y proporcionan ahorros valiosos en costos, mano de obra y tiempo. No obstante, se requieren mayores

esfuerzos para estimar otros pigmentos de las plantas usando un espectrorradiómetro sin imágenes.

Durante la patogénesis, las toxinas o enzimas específicas de patógenos inducen los tejidos de las plantas e influyen en sus propiedades ópticas. Los cambios en el patrón de reflectancia, debido a la interacción planta-patógeno, pueden verse afectados por alteraciones en la estructura y en la composición química de la hoja (Mahlein, 2016). Los datos hiperespectrales pueden evaluarse con una RN entrenada y representativa (Hill *et al.*, 2010). Los VI también pueden categorizarse utilizando clasificadores de RN. Wu *et al.* (2008) detectaron *Botrytis cinerea* en hojas de berenjena con un enfoque de RN-hiperespectral. Aplicaron clasificadores de RN y ACP a firmas hiperespectrales e identificaron con precisión pequeños síntomas de moho gris. En otro estudio, Le Maire *et al.* (2008) estudiaron VI derivados del borde rojo con RN.

Investigaciones recientes han demostrado el gran valor de usarla espectroscopia VNIR para la detección temprana de enfermedades en varias aplicaciones. Pydipati *et al.* (2006) encontraron que una BPNN de múltiples capas tiene las mayores capacidades de corrección y discriminación de longitud de onda de reflectancia, siendo entre 460 nm y 1130 nm, en incrementos de 10 nm. Así mismo, Miller *et al.* (1998) utilizaron una BPNN de múltiples capas con un algoritmo de reconocimiento de patrones para clasificar manchas superficiales en múltiples variedades de manzano.

Los datos hiperespectrales sin imágenes son los más interesantes y desafiantes. La medición espectral en tiempo real utilizando un espectrorradiómetro de campo produce una gran cantidad de datos, que requieren de preprocesamiento espectral. En este proceso se reducen muchas bandas espectrales; por lo tanto, la selección de bandas de onda óptimas es muy importante (Bulanon *et al.*, 2013). Se observa que el procesamiento espectral con el algoritmo de RN ha aumentado la accesibilidad de datos sin imagen en la detección de enfermedades. La aplicación de BPNN (Pydipati *et al.*, 2006; Miller *et al.*, 1998) para diferenciar entre los espectros de plantas sanas y enfermas, se ha convertido en una de las redes más eficientes y de más rápido desarrollo en la protección vegetal de precisión.

Detección temprana utilizando espectroscopia con imágenes

En los últimos años, y dado que las imágenes de teledetección se volvieron más fáciles de archivar, se han realizado varios estudios sobre el procesamiento de imágenes hiperespectrales. Igualmente, se han desarrollado técnicas de RN altamente flexibles para investigar las características espectrales de los cultivos. Sin embargo, el uso de sistemas innovadores de imágenes espectrales para la detección temprana de enfermedades y la evaluación de la gravedad de enfermedades continúa en etapa de investigación (Bajwa *et al.*, 2004; Delalieux *et al.*, 2007).

A nuestro conocimiento, hasta el momento no se han evaluado clasificadores con RN puramente no paramétricos para la detección temprana de enfermedades, utilizando imágenes hiperespectrales. Se han desplegado espectrorradiómetros hiperespectrales de imágenes espaciales, tales como el sistema Eagle de espectrómetro de imágenes aéreas para aplicaciones (AISA), AVIRIS Hyperion, el espectrómetro de imagen con sistema de imágenes ópticas reflectivas (ROSIS) y el espectrómetro de imágenes de mapeo hiperespectral (HyMap), para detectar enfermedades sin aplicaciones de RN.

Las RN son apropiadas para la clasificación de imágenes hiperespectrales. Estas generan un clasificador usando insumos de entrenamiento. Básicamente, las RN son empleadas para extraer características de imágenes como insumos de entrenamiento, y sus clasificadores mejoran la precisión de la clasificación y reducen los efectos generales del ruido en las imágenes.

Las RN ofrecen un rango dinámico de algoritmos para el análisis de imágenes hiperespectrales. En su mayoría, se utiliza uno bidimensional para detectar enfermedades a partir de las características de estas imágenes. Los algoritmos básicos sirven para la reducción de datos, la extracción de características, la segmentación, el reconocimiento de objetos y la optimización de imágenes. Los avanzados, para la abstracción a nivel de píxel, característica, estructura y conjunto de objetos, y para la caracterización de la escena (Egmont-Petersen *et al.*, 2002; Gautam y Panigrahi, 2003; Min *et al.*, 2012).

Tabla 1. Uso de sensor hiperespectral para detectar y diagnosticar enfermedades de cultivos en etapas tempranas.

Sensor	Cultivo	Enfermedad	Referencias
Espectrorradiómetros de campo ASD (350-2500 nm)	Arroz	Infecciones fúngicas	Liu <i>et al.</i> (2010)
	Arroz	Mancha parda del arroz	Liu <i>et al.</i> (2008)
	Berenjena	Moho gris	Wu <i>et al.</i> (2008)
GER-2600 (400-2500 nm)	Tomate	Tizón tardío	Wang <i>et al.</i> (2008)
ImSpector V10E (400-1000 nm)	Trigo	Roya amarilla	Moshou <i>et al.</i> (2004)
	Semilla oleaginosa	Infecciones fúngicas	Baraowski <i>et al.</i> (2015)
AISA	Cítricos	<i>Greening</i> (Huanglongbing)	Lee & Ehsani (2015)
	Palma de aceite	<i>Ganoderma</i> Putridión basal del estípote	Shafri & Hamdan (2009)
Imágenes hiperespectrales (HIS)	Remolacha azucarera	Manchas foliares, moho polvoriento y roja de la hoja	Mahlein <i>et al.</i> (2012)
Hyperion	Remolacha azucarera	Roya anaranjada	Apan <i>et al.</i> (2004)
Escáner hiperespectral de imágenes	Trigo	<i>Fusarium</i> del trigo	Baurieguel & Herppich (2014)
Sistema portátil de imágenes hiperespectrales	Cítricos	Cancro cítrico	Oin <i>et al.</i> (2009)
	Maíz	Infecciones fúngicas	Del Fiore <i>et al.</i> (2010)
Hiperespectrómetro (350-1050 nm)	Trigo	Moho polvoriento	Shen <i>et al.</i> (2015)

Las RN superan significativamente las limitaciones del análisis de datos hiperespectrales. Las imágenes hiperespectrales contienen información de alta dimensión en cubos de datos multidimensionales. La red neuronal convolucional (RNC) es un nuevo concepto, que ha demostrado ser muy efectivo para clasificar imágenes hiperespectrales de alta dimensión. Está compuesta de un conjunto de bloques que pueden aplicarse tanto en el espacio como en el tiempo (Paoletti *et al.* 2017). Paoletti *et al.* (2017) desarrollaron una nueva arquitectura profunda de RNC en 3-D para la clasificación espacial-espectral de imágenes hiperespectrales. Requiere, para una mejor clasificación de los resultados, una consideración conjunta de la información espectral junto con la espacial.

Mutanga y Skidmore (2004) integraron características espectrales en todo el rango espectral (400-2500 nm) de datos HyMap con una RN. Vale la pena mencionar que las imágenes hiperespectrales AVIRIS son útiles para caracterizar y estimar varias enfermedades fúngicas y bacterianas (Muhammed, 2005; Jones *et al.*,

2010). Por lo tanto, se recomienda el uso de RN para el análisis de datos AVIRIS, especialmente para enfermedades vegetales. La Tabla 1 resume algunos estudios importantes sobre el uso de datos hiperespectrales para la detección temprana de enfermedades.

Desafíos de las RN

El principal desafío de las RN en el procesamiento de datos hiperespectrales es el entrenamiento de una gran cantidad de insumos espectrales y la definición de sus objetivos. Esto se vuelve incluso más difícil con la aplicación de clasificadores de RN para la clasificación de VI y SDI. En general, el efecto Hughes, o la “maldición de la dimensión”, es el problema más complejo para los datos hiperespectrales, que trata con la diversidad y distorsiones en bandas espectrales. El efecto Hughes puede afectar el modelado de RN. Por lo general, esto sucede cuando la proporción del número de píxeles de entrenamiento o el de bandas espectrales está por encima del valor mínimo para lograr el ajuste estadístico

(Camps-Valls y Bruzzone, 2005). En particular, uno de los aspectos más desafiantes es el uso de clasificadores de RN para el análisis de mezclas espectrales (SMA, por su sigla en inglés), que es un buen modelo lineal. Se requieren RN no lineales para entrenar un gran conjunto de datos de espectros de enfermedades vegetales. Adicionalmente, las RN suelen ser consideradas como una caja negra, dado que no contienen información a priori, lo que es complejo en sí.

Por lo general, los clasificadores de RN catalogan diferentes enfermedades vegetales con base en la combinación de parámetros óptimos como textura, color y forma en la imagen de una cámara común (Ghaiwat y Arora, 2014). Los parámetros óptimos pueden entrenarse con facilidad, dado que las imágenes normales son separables linealmente. Por otro lado, la imagen hiperespectral es diferente a la de una cámara común. Los datos hiperespectrales no pueden entrenarse linealmente mientras contengan más de

cient bandas espectrales contiguas. Las arquitecturas de perceptrón multicapa, normalmente tratan con tales características no lineales. Adicionalmente, las bandas espectrales adyacentes en diferentes regiones espectrales son muy redundantes al extraer información para una RN. Las bandas espectrales se encuentran altamente interconectadas entre sí.

Índice espectral de enfermedad (SDI)

La mayoría de VI comunes fueron calculados a partir de longitudes de onda roja y del infrarrojo cercano (NIR, por su sigla en inglés). El índice de vegetación de diferencia normalizada (NDVI, por su sigla en inglés) (Rouse *et al.*, 1973) es uno de los VI más populares y usados para monitorear la salud de la vegetación. Balasundram *et al.* (2013) lo utilizaron para la evaluación preliminar de la enfermedad de la Marchitez roja en

Tabla 2. SDI bien establecidos para la detección temprana de enfermedades utilizando datos hiperespectrales.

Sensor	SDI	Fórmulas	Referencias
Hyperion	Índice de estrés hídrico enfermedad 1 (DSWI-1)	$R800/R1660$	Apan <i>et al.</i> (2004)
	DSWI-2	$R1660/R550$	
	DSWI-3	$R1660/R680$	
	DSWI-4	$R550/R680$	
	DSWI-5	$(R800+R550)/(R1660+R680)$	
ASD Field Spec (Espectrorradiómetro)	Índice de salud (HI, en inglés)	$\frac{R534 - R698}{R534 + R698} - \frac{1}{2} \cdot R704$	Mahlein <i>et al.</i> (2013)
	Índice de manchas foliares Cercospora (CLSI, en inglés)	$\frac{R698 - R570}{R570 + R513} - R734$	
	Índice de Roya en remolacha azucarera (SBRI, en inglés)	$\frac{R520 - R513}{R570 + R513} - \frac{1}{2} \cdot R704$	
	Índice de moho polvoriento (PMI, en inglés)	$\frac{R520 - R584}{R520 + R584} - R724$	
	Índice de gravedad de la enfermedad de la roya foliar (LRDSI_1, en inglés)	$6.9 \frac{\rho_{605}}{\rho_{455}} - 1.2$	Ashourloo <i>et al.</i> (2014)
	Índice de gravedad de la enfermedad de la roya Foliar 2 (LRDSI_2, en inglés)	$4.2 \frac{\rho_{695}}{\rho_{455}} - 0.38$	
	Índice normalizado saludable de la roya foliar (NLRHI)	$\frac{DS - \left(\frac{\rho_{675}}{\rho_{755}}\right)}{DS + \left(\frac{\rho_{675}}{\rho_{775}}\right)}$	Ashourloo <i>et al.</i> (2016)

la piña (*Ananas comosus*). Demostraron e infirieron que el NDVI es un método confiable para predecir la gravedad de la enfermedad. No obstante, no se ha demostrado que el NDVI sea adecuado para identificar el agente causal de las enfermedades vegetales. Peñuelas *et al.* (1994) encontraron que no sigue bandas de onda específicas que representen los cambios fisiológicos causados por los patógenos. Por lo tanto, es necesario extraer las características espectrales sensibles a la enfermedad para desarrollar un SDI. Por lo general, este es una proporción de las diferentes bandas espectrales sensibles a la enfermedad que se extraen con base en las respuestas espectrales de la vegetación enferma.

La detección temprana de una enfermedad con base en la teledetección hiperespectral es más precisa y significativa. Es así como se están desarrollando nuevos SDI utilizando datos hiperespectrales. Varios valores de SDI representan especificidad, sensibilidad y gravedad de la vegetación en las diferentes etapas de la infección. Se han usado para proporcionar un entendimiento único, científico y detallado de la patógenesis. En contraste con los VI comunes, los SDI tienen el potencial de discriminar y diferenciar una enfermedad vegetal de otra. Aunque cada una puede afectar el espectro de reflectancia foliar de una forma específica (Mahlein *et al.* 2013).

Es importante desarrollar índices específicos a una enfermedad con base en la progresión de sus síntomas. Ashourloo *et al.* (2014) generaron dos SDI utilizando datos hiperespectrales con base en el avance de la enfermedad para la detección de la roya de la hoja de trigo. Mediante estudios comparativos, Rumpf (2012) mostró que los SDI son superiores a los VI comunes para la identificación temprana de enfermedades. Los SDI desarrollados a partir de un espectrorradiómetro de imágenes pueden correlacionarse con los de espectrorradiómetros de campo sin imágenes. La capacidad de generalización de los SDI mejora mediante la correlación y validación cruzada. Por lo general, los espectrorradiómetros de campo sin imágenes calculan los SDI en un tiempo muy corto. En comparación, los de imágenes tardan más tiempo en seleccionar miembros finales sensibles (píxeles) de las imágenes hiperespectrales. Los datos hiperespectrales pueden detectar enfermedades a diferentes escalas, en una planta individual o hasta en campos enteros. La Tabla 2 resume los

diferentes SDI aplicados para la detección temprana de enfermedades utilizando datos hiperespectrales.

Tendencias hacia el futuro: aprendizaje profundo de datos hiperespectrales

El aprendizaje profundo es una técnica avanzada para el análisis de big data. Un modelo de este contiene muchas capas (generalmente, más de tres). Las neuronas de cada capa se encuentran conectadas intensamente con las características de los datos, permitiendo la obtención de información más compleja. Los modelos de aprendizaje profundo pueden aprender características de los datos de entrada a partir de una red de neuronas organizada jerárquicamente (Lowe *et al.*, 2017). Existe literatura reciente (Sladojevic *et al.*, 2016; Gomez-Chova *et al.*, 2015; Wang *et al.*, 2017) sobre la evaluación de estos modelos que utilizan el aprendizaje profundo y el análisis de imagen e imágenes hiperespectrales para la detección de enfermedades vegetales.

Se cree que el aprendizaje profundo es el futuro de la teledetección hiperespectral. La RNC es su modelo más popular que funciona en un dominio de imagen. Puede ser utilizada para la creación de imágenes hiperespectrales con el fin de detectar y clasificar enfermedades vegetales en un inicio temprano. Actualmente, la visión multimedia (Gomez-Chova *et al.*, 2015) y de computadora, y el procesamiento de lenguaje natural (Ghamisi *et al.*, 2017) son las áreas más prometedoras de aplicación del aprendizaje profundo (Sladojevic *et al.*, 2016).

Las arquitecturas de computación en la nube identificadas en la literatura reciente (Haut, *et al.*, 2017; Quirita *et al.*, 2017), fueron revisadas junto con el alcance futuro del enfoque hiperespectral de RN. Haut *et al.* (2017) exploraron por primera vez la posibilidad de utilizar una plataforma distribuida para agrupar un gran volumen de imágenes hiperespectrales, con base en las arquitecturas de computación en la nube. Quirita *et al.* (2017) propusieron una arquitectura, llamada *InterCloud Data Mining Architecture*, para los entornos de computación en la nube. Esta permite a los usuarios asignar poder de procesamiento y espacio de almacenamiento para administrar conjuntos de datos muy grandes, tales como las imágenes hiperespectrales.

Referencias

- Ahmadi, P., Muharam, F. M., Ahmad, K., Mansor, S., & Abu-Seman, I. (2017). Early detection of *Ganoderma* basal stem rot of oil palms using artificial neural network spectral analysis. *Plant Disease*, 101(6), 1009-1016.
- Al Bashish, D., Braik, M., & Bani-Ahmad, S. (2010). A framework for detection and classification of plant leaf and stem diseases. In: International Conference on Signal and Image Processing IEEE. Chennai, India.
- Apan, A., Held, A., Phinn, S., & Markley, J. (2004). Detecting sugarcane "orange rust" disease using EO-1 hyperion hyperspectral imagery. *International Journal of Remote Sensing*, 25(2), 489-498.
- Ashourloo, D., Mobasheri, M., & Huete, A. (2014). Developing two spectral disease indices for detection of wheat leaf rust. *Remote Sensing of Environment*, 6(6), 4723-4740.
- Ashourloo, D., Matkan, A.A., Huete, A., Aghighi, H., and Mobasheri, M.R. (2016). Developing an index for detection and identification of disease stages. *IEEE Geoscience and Remote Sensing Letters* 13(6):851-855.
- Bajwa, S. G., Bajcsy, P., Groves, P., & Tian, L. F. (2004). Hyperspectral image data mining for band selection in agricultural applications. *ASAE*, 47(3), 895-907.
- Balasundram, S. K., Kassim, F. A., Vadamalai, G., & Hanif, A. H. M. (2013) Estimation of red tip disease severity in pineapple using a non-contact sensor approach. *Journal of Agriculture Science*, 4(4), 206-208.
- Baranowski, P., Jedryczka, M., Mazurek, W., Babula-Skowronska, D., Siedliska, A., & Kaczmarek, J. (2015). Hyperspectral and thermal imaging of oilseed rape (*Brassica napus*) response to fungal species of the genus *alternaria*. *PLoS One*, 10(3), e0122913.
- Bauriegel, E., & Herppich, W. (2014). Hyperspectral and chlorophyll fluorescence imaging for early detection of plant diseases, with special reference to *fusarium* sp. infections on wheat. *Agriculture*, 4(1), 32-57.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. USA: Oxford University Press.
- Bulanon, D. M., Burks, T. F., Kim, D. G., & Ritenour, M. A. (2013). Citrus black spot detection using hyperspectral image analysis. *Agricultural Engineering International: CIGR Journal*, 15(3), 171-180.
- Camps-Valls, G., & Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6), 1351-1362.
- Chang, C. I. (2007). *Hyperspectral data exploitation: Theory and applications*. John Wiley & Sons.
- Chang, C. I. (2003). *Hyperspectral imaging: Techniques for spectral detection and classification*. New York: Kluwer Academic Publishers.
- Cui, S., Ling, P., Zhu, H., & Keener, H. (2018). Plant pest detection using an artificial nose system: A review. *Sensors*, 18(2), 378.
- Delalieux, S., Aardt, J., Keulemans, W., Schrevens, E., & Coppin, P. (2007). Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications. *European Journal of Agronomy*, 27(1), 130-43.
- Del Fiore, A., Reverberi, M., Ricelli, A., Pinzari, F., Serranti, S., Fabbri, A.A., et al. (2010). Early detection of toxigenic fungi on maize by hyperspectral imaging analysis. *International Journal of Food Microbiology*, 144(1), 64-71.

- Dhau, I., Adam, E., Mutanga, O., & Ayisi, K. K. (2018). Detecting the severity of maize streak virus infestations in maize crop using in situ hyperspectral data. *Transactions of the Royal Society of South Africa*, 73, 8-15.
- Egmont-Petersen, M., De Ridder, D., & Handels, H. (2002). Image processing with neural networks - A review. *Pattern Recognition*, 35(10), 2279-2301.
- Ettabaa, K. S., & Salem, M. B. (2018). Adaptive progressive band selection for dimensionality reduction in hyperspectral images. *Journal of the Indian Society of Remote Sensing*, 46(2), 157-167.
- Eun, A. J. C., Huang, L., Chew, F. T., Fong-Yau, S., & Wong, S. M. (2002a). Detection of two orchid viruses using quartz crystal microbalance-based DNA biosensors. *Phytopathology*, 92(6), 654-658.
- Eun, A. J. C., Huang, L., Chew, F. T., Li, S. F. Y., & Wong, S. M. (2002b). Detection of two orchid viruses using quartz crystal microbalance (QCM) immunosensors. *Journal of Virological Methods*, 99(1-2), 71-79.
- Gautam, R. K., & Panigrahi, S. (2003). Image processing techniques and neural network models for predicting plant nitrate using aerial images. In: *International Joint Conference on Neural Networks IEEE*. Portland, OR, USA.
- Ghaiwat, S. N., & Arora, P. (2014). Detection and classification of plant leaf diseases using image processing techniques: A review. *International Journal of Recent Advances in Engineering and Technology*, 2, 2347-2812.
- Ghamisi, P., Plaza, J., Chen, Y., Li, J., & Plaza, A. J. (2017). Advanced spectral classifiers for hyperspectral images: A review. *IEEE Geoscience and Remote Sensing Magazine*, 5(1), 8-32.
- Goetz, A. F. H., Vane, G., Solomon, J. E., & Rock, B. N. (1985). Imaging spectrometry for earth remote sensing. *Science*, 228(4704), 1147-1153.
- Goetz, A. F. H., Curtiss, B., & Shiley, D. A. (2009). Rapid gangue mineral concentration measurement over conveyors by NIR reflectance spectroscopy. *Minerals Engineering* 22(5), 490-499.
- Gomez-Chova, L., Tuia, D., Moser, G., & Camps-Valls, G. (2015). Multimodal classification of remote sensing images: a review and future directions. *Proceedings of the IEEE*, 103(9), 1560-15084.
- Haut, J. M., Paoletti, M., Plaza, J., & Plaza, A. (2017). Cloud implementation of the K-means algorithm for hyperspectral image analysis. *Journal of Supercomputing*, 73(1), 514-529.
- Heim, R. H. J., Wright, I. J., Chang, H. C., Carnegie, A. J., Pegg, G. S., Lancaster, E. K., et al. (2018). Detecting myrtle rust on lemon myrtle trees using spectral signatures and machine learning. *Plant Pathology* 67, 1114-1121.
- Hill, J., Udelhoven, T., Vohland, M., & Stevens, A. (2010). The use of laboratory spectroscopy and optical remote sensing for estimating soil properties. In: Oerke, E. C., Gerhards, R., Menz, G., Sikora, R.A. (Ed.). *Precision crop protection - The challenge and use of heterogeneity*. Dordrecht: Springer Netherlands.
- Isleib, J. (2012). *Signs and symptoms of plant disease: Is it fungal, viral or bacterial?* Detroit: Michigan State University Extension.
- Jones, C. D., Jones, J. B., & Lee, W. S. (2010). Diagnosis of bacterial spot of tomato using spectral signatures. *Computers and Electronics in Agriculture*, 74(2), 329-35.
- Koike, S. T., Gladders, P., & Paulus, A. O. (2017). *Causes of disease. In: Vegetable diseases: a color handbook*. London: Manson Publishing Limited.
- Kole, D. K., Ghosh, A., & Mitra, S. (2014). Detection of downy mildew disease present in the grape leaves based on fuzzy set theory. In: Kundu, M. K., Mohapatra, D. P., Konar, A., Chakraborty, A. (Ed.). *Advanced computing, Networking and Informatics 1*. Switzerland: Springer, 377-384.

- Kong, W., Zhang, C., Huang, W., Liu, F., & He, Y. (2018). Application of hyperspectral imaging to detect *Sclerotinia sclerotiorum* on oilseed rape stems. *Sensors*, 18(1), 123.
- Krezhova, D., Stoev, A., & Maneva, S. (2015). Detection of biotic stress caused by apple stem grooving virus in apple trees using hyperspectral reflectance analysis. *Comptes Rendus l'Académie Bulgare des Sciences*, 68(2), 175-182.
- Lee, W. S., & Ehsani, R. (2015). Sensing systems for precision agriculture in Florida. *Computers and Electronics in Agriculture*, 112, 2-9.
- Leeser, M. E., Belanovic, P., Estlick, M., Gokhale, M., Szymanski, J. J., & Theiler, J. P. (2002). Applying reconfigurable hardware to the analysis of multispectral and hyperspectral imagery. In: *Proceeding 4480, Imaging Spectrometry VII*, 100-108.
- Le Maire, G., Francois, C., Soudani, K., Berveiller, D., Pontailier, J. Y., Bréda, N., et al. (2008). Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment*, 112, 3846-3864.
- Lichtenthaler, H. K. (1996). Vegetation stress: An introduction to the stress concept in plants. *Journal of Plant Physiol.*, 148(1-2), 4-14.
- Liu, J., Dong, Z., & Chen, X. (2018). Study on hyperspectral estimation model of total nitrogen content in soil of shaanxi province. *IOP Conference Series: Earth and Environmental Science*, 108(4), 42025.
- Liu, Z., Huang, J., Tao, R., & Zhang, H. (2008). Estimating the severity of rice brown spot disease based on principal component analysis and radial basis function neural network. *Spectrosc Spectr Anal*, 28(9), 2156-2160.
- Liu, Z. Y., Wu, H. F., & Huang, J. F. (2010). Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Computers and Electronics in Agriculture*, 72(2), 99-106.
- Lowe, A., Harrison, N., & French, A. P. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. *Plant Methods*, 13(1), 80.
- Lu, J., Ehsani, R., Shi, Y., De Castro A. I., & Wang, S. (2018). Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Science Reports*, 8, 2793.
- Mahlein, A. K. (2016). Plant disease detection by imaging sensors - parallels and specific demands for precision agriculture and plant phenotyping. *Plant Disease*, 100(2), 241-251.
- Mahlein, A. K., Steiner, U., Hillnhütter, C., Dehne, H. W., & Oerke, E. C. (2012). Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. *Plant Methods*, 8(1), 3.
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., et al. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21-30.
- Marini, F., Bucci, R., Magrì, A. L., & Magrì, A. D. (2008). Artificial neural networks in chemometrics: History, examples and perspectives. *Microchemical Journal*, 88(2), 178-185.
- Marini, F., Zupan, J., & Magrì, A. L. (2005). Class-modeling using kohonen artificial neural networks. *Analytica Chimica Acta*, 544(1-2), 306-314.
- Marini, F., Magrì, A.L., & Bucci, R. (2007). Multilayer feed-forward artificial neural networks for class modeling. *Chemometrics and Intelligent Laboratory Systems*, 88(1), 118-124.

- Miller, W. M., Throop, J. A., & Upchurch, B. L. (1998). Pattern recognition models for spectral reflectance evaluation of apple blemishes. *Postharvest Biology Technology*, 14(1), 11-20.
- Min, H., Lei, C., & Hua, M. (2012). *Classification of aerial photograph using neural network*. In: *International Conference on Systems, Man and Cybernetics IEEE*. Yasmine Hammamet, Tunisia.
- Moghadam, P., Ward, D., Goan, E., Jayawardena, S., Sikka, P., & Hernández, E. (2017). Plant disease detection using hyperspectral imaging. In: *International Conference on Digital Image Computing: Techniques and Applications IEEE*. Sydney, NSW, Australia, 1-8.
- Mutanga, O., & Skidmore, A. K. (2004). Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International Journal of Remote Sensing*, 25(19), 3999-40014.
- Muhammed, H. H. (2005). Hyperspectral crop reflectance data for characterising and estimating fungal disease severity in wheat. *Biosystems Engineering*, 91(1), 9-20.
- Moshou, D., Bravo, C., West, J., Wahlen, S., McCartney, A., & Ramon, H. (2004). Automatic detection of "yellow rust" in wheat using reflectance measurements and neural networks. *Computers and Electronics in Agriculture*, 44(3), 173-188.
- Nagasubramanian, K., Jones, S., Sarkar, S., Singh, A. K., Singh, A., & Ganapathysubramanian, B. (2017). Hyperspectral band selection using genetic algorithm and support vector machines for early identification of charcoal rot disease in soybean. *Plant Methods*, 14, 1-20.
- Ortenberg, F., Thenkabail, P. S., Lyon, J. G., & Huete, A. (2011). Hyperspectral sensor characteristics: Airborne, spaceborne, hand-held, and truck-mounted; Integration of hyperspectral data with Lidar. In: Thenkabail, P. S., Lyon, J. G., Huete, A. (Ed.). *Hyperspectral remote sensing of vegetation*. USA: CRC Press, 39-67.
- Paoletti, M. E., Haut, J. M., Plaza, J., & Plaza, A. (2017). A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS Journal and Photogrammetry and Remote Sensing*.
- Peñuelas, J., Gamon, J. A., Fredeen, A. L., Merino, J., & Field, C. B. (1994) Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves. *Remote Sensing of Environment*, 48(2), 135-146.
- Perera, R. M. M., Marriott, P. J., & Galbally, I. E. (2002). Headspace solid-phase microextraction-Comprehensive two-dimensional gas chromatography of wound induced plant volatile organic compound emissions. *Analyst*, 127(12), 1601-1607.
- Pu, R. (2017). *Hyperspectral remote sensing: Fundamentals and practices*. USA: CRC Press.
- Pydipati, R., Burks, T. F., & Lee, W. S. (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture* 52(1-2), 49-59.
- Qi, J., Inoue, Y., & Wiangwang, N. (2011). Hyperspectral remote sensing in global change studies. In: Thenkabail, P. S., Lyon, J. G., Huete, A. (Ed.). *Hyperspectral remote sensing of vegetation*. USA: CRC Press.
- Qin, J., Burks, T. F., Ritenour, M. A., & Bonn, W.G. (2009). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of Food Engineering*, 93(2), 183-191.
- Quirita, V. A. A., Da Costa, G. A. O. P., Happ, P. N., Feitosa R. Q., Ferreira, R. Q., Oliveira, D. A. B., et al. (2017). A new cloud computing architecture for the classification of remote sensing data. *IEEE Journal of Select Topics in Applied Earth Observations and Remote Sensing*, 10(2), 409-416.
- Raid, R. (2011). *Specific symptoms & signs of bacterial diseases. Plant pathology guidelines for master gardeners*. University of Florida.

- Rouse, J. W., Haas, R. H., Deering, D. W., & Harlan, J. C. (1973). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation*. NASA Scientific and Technical Information Program.
- Rumpf, T. (2012). *Finding spectral features for the early identification of biotic stress in plants*. Doctoral thesis. Rheinische Friedrich-Wilhelms-Universität Bonn.
- Sakudo, A., Suganuma, Y., Kobayashi, T., Onodera, T., & Ikuta, K. (2006). Near-infrared spectroscopy: Promising diagnostic tool for viral infections. *Biochemical & Biophysical Research Communications*, 341(2), 279-284.
- Sankaran, S., Mishra, A., Ehsani, R., & Davis, C. A. (2010). Review of advanced techniques for detecting plant diseases. *Computers Electronics in Agriculture*, 72(1), 1-13.
- Shafri, H. Z. M., & Hamdan, N. (2009). Hyperspectral imagery for mapping disease infection in oil palm plantation using vegetation indices and red edge techniques. *American Journal of Applied Sciences*, 6(6), 1031-1035.
- Sharma, P., & Sharma, S. (2016). Paradigm shift in plant disease diagnostics: a journey from conventional diagnostics to nano-diagnostics. In: Kumar, P., Gupta, K. V., Tiwari, K. A., Kamle, M. (Ed). *Current trends in plant disease diagnostics and management practices*. Switzerland: Springer International Publishing AG, 237-264.
- Shen, W., Li, Y., Feng, W., Zhang, H., Zhang, Y., Xie, Y., et al. (2015). Inversion model for severity of powdery mildew in wheat leaves based on factor analysis-BP neural network. *Chinese Society of Agriculture Engineering*, 31(22), 183-90.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks-based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 2016, 1-11.
- Silva-Perez, V., Molero, G., Serbin, S. P. Condon, A. G., Reynolds, M. P., Furbank, R. T., & Evans, J. (2017). Hyperspectral reflectance as a tool to measure biochemical and physiological traits in wheat. *Journal of Experimental Botany*, 69(3), 483-496.
- Strange, R. N., & Scott, P. R. (2005). Plant disease: A threat to global food security. *Annual Review Phytopathology*, 43(1), 83-116.
- Thanarajoo, S. S., Kong, L. L., Kadir, J., Lau, W. H., & Vadamalai, G. (2014). Detection of Coconut cadang-cadang viroid (CCCVd) in oil palm by reverse transcription loop-mediated isothermal amplification (RT-LAMP). *Journal of Virological Methods*, 202, 19-23.
- Thanarajoo, S. S. (2014). *Rapid detection, accumulation and translocation of Coconut cadang-cadang viroid variants in oil palm*. Doctoral thesis. Universiti Putra Malaysia, Serdang.
- Thenkabail, P. S., Smith, R. B., & De Pauw, E. (2002). Evaluation of narrowband and broadband vegetation indices for determining optimal hyperspectral wavebands for agricultural crop characterization. *Photogrammetric Engineering and Remote Sensing*, 68(6), 607-622.
- Thompson, A. J. B, Hauff, P. L., & Robitaille, A. J. (1999). Alteration mapping in exploration: application of short-wave infrared (SWIR) spectroscopy. *Society of Economic Geologist News*, 39, 16-27.
- Vadamalai, G., Hanold, D., Rezaian, M. A., & Randles, J. W. (2016). Variants of Coconut cadang-cadang viroid isolated from an African oil palm (*Elaeis guineensis* Jacq.) in Malaysia. *Archives of Virology*, 151(7), 1447-1456.
- Vadamalai, G., Perera, A., Hanold, D., Rezaian, M. A., & Randles, J. W. (2009) Detection of Coconut cadang-cadang viroid sequences in oil and coconut palm by ribonuclease protection assay. *Annals of Applied Biology*, 154(10), 117-125.

- Wang, G., Sun, Y., & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep learning. *Computational Intelligence and Neuroscience*, 2917536, 1-8.
- Wang, X., Zhang, M., Zhu, J., & Geng, S. (2008). Spectral prediction of *Phytophthora infestans* infection on tomatoes using artificial neural network (ANN). *International Journal of Remote Sensing*, 29(6), 1693-1706.
- Whetton, R. L., Hassall, K. L., Waine, T. W., & Mouazen, A. M. (2018a). Hyperspectral measurements of yellow rust and fusarium head blight in cereal crops: Part 1: Laboratory study. *Biosystems Engineering*, 166,101-115.
- Whetton, R. L., Waine, T. W., & Mouazen, A. M. (2018b). Hyperspectral measurements of yellow rust and fusarium head blight in cereal crops: Part 2: On-line field measurement. *Biosystems Engineering*, 167, 144-158.
- Wood, K. R. (1998). Nepovirus isolation and RNA extraction. In: Foster, G. D., Taylor, S. C. (Ed.). *Plant virology protocols*. USA: Humana Press.
- Wu, D., Feng, L., Zhang, C., & He, Y. (2008). Early detection of *Botrytis cinerea* on eggplant leaves based on visible and near-infrared spectroscopy. *Transaction of the ASABE*, 51, 1133-1139.
- Wu, Y. H., Cheong, L. C., Meon, S., Lau, W. H., Kong, L. L., Joseph, H., & Vadamalai, G. (2013). Characterization of Coconut cadang-cadang viroid variants from oil palm affected by orange spotting disease in Malaysia. *Archives of Virology*, 158(6),1407-1410.
- Zhao, Y., Chen, P., Lin, L., Harnly, J. M., Yu, L., & Li, Z. (2011). Tentative identification, quantitation, and principal component analysis of green pu-erh, green, and white teas using UPLC/DAD/MS. *Food Chemistry*, 126(3), 1269-1277.
- Zhu, H., Chu, B., Zhang, C., Liu, F., Jiang, L., & He, Y. (2017). Hyperspectral imaging for presymptomatic detection of tobacco disease with successive projections algorithm and machine-learning Classifiers. *Scientific Reports*, 7(1), 4125.
- Zhu, H., Cen, H., Zhang, C., & He, Y. (2016). Early detection and classification of tobacco leaves inoculated with tobacco mosaic virus based on hyperspectral imaging technique. In: ASABE Annual Internation Meeting.
- Zhang, B., Huang, W., Wang, C., Gong, L., Zhao, C., Liu, C., & Huang, D. (2015). Computer vision recognition of stem and calyx in apples using near-infrared linear-array structured light and 3D reconstruction. *Biosystem Engineering*, 139, 25-34.
- Zou, T., Dou, Y., Mi, H., Zou, J., & Ren, Y. (2006). Support vector regression for determination of component of compound oxytetracycline powder on near-infrared spectroscopy. *Analytical Biochemistry*, 355, 1-7.