

**Imágenes hiperespectrales y sus aplicaciones en estudios de suelos, cultivos y bosques,  
en la era de la cuarta revolución industrial**

**Hyperspectral imaging and its applications in studies of soils, crops and forests, in the  
era of the fourth industrial revolution**

Jonás C. León Pérez<sup>1</sup>

**Para citar este artículo:** León-Perez, J.C. (2021). Imágenes hiperespectrales y sus aplicaciones en estudios de suelos, cultivos y bosques, en la era de la cuarta revolución industrial. *UD y la Geomática*, 16. 40-70

**Fecha de recepción:** 31 de agosto de 2020

**Fecha de aceptación:** 27 de noviembre de 2020

### Resumen

Para implementar una agricultura sostenible y un manejo racional del medio ambiente, es necesario tener un mejor conocimiento de los suelos, de los cultivos, de los bosques, del agua y de otros recursos relacionados. Esto implica utilizar tecnologías de última generación, como las imágenes hiperespectrales (HSI), que por su fina resolución espectral (cientos a miles de bandas estrechas y contiguas del espectro electromagnético), presentan soluciones prácticas para entender, modelar y mapear, con mayor precisión, las principales características de los recursos terrestres, además, para monitorear sus dinámicas en el tiempo y en el espacio. Sin embargo, ellos producen enormes volúmenes de datos que no se pueden procesar con las técnicas tradicionales. El objetivo principal de este artículo es hacer una revisión sobre el uso de los sensores hiperespectrales en naves aéreas no tripuladas, las particularidades de la integración de los datos hiperespectrales con las

---

<sup>1</sup>Maestría en Suelos, Universidad Nacional de Colombia, Bogotá. [jleonp@unal.edu.co](mailto:jleonp@unal.edu.co), [jocleonp@gmail.com](mailto:jocleonp@gmail.com)

tecnologías disruptivas, productos de la cuarta revolución industrial, en especial con los *big data*, internet de las cosas, minería de datos, computación en la nube e inteligencia artificial, y sus aplicaciones en los estudios de suelos, cultivos y bosques, buscando aportar al conocimiento de los beneficios de esa integración y el mejor aprovechamiento de las potencialidades de las HSI.

**Palabras clave:** UAV-HSI, *big data*-HSI, computación en la nube-HSI, internet de las cosas-HSI, minería de datos-HSI.

#### ABSTRACT

To implement sustainable agriculture and rational management of the environment, it is necessary to have a better knowledge of soils, crops, forests, water and other related resources. This implies, using state-of-the-art technologies, such as hyperspectral imaging (HSI), which, due to their fine spectral resolution (hundreds to thousands of narrow and contiguous bands of the electromagnetic spectrum), present practical solutions to understand, model and map, with greater precision, the main characteristics of terrestrial resources, in addition, to monitor their dynamics in time and space. However, they produce huge volumes of data, which cannot be processed with traditional techniques. The main objective of this article is to review the use of hyperspectral sensors in unmanned aerial craft, the particularities of the integration of hyperspectral data with disruptive technologies, products of the fourth industrial revolution, especially with big data, internet of things, data mining, cloud computing and artificial intelligence, and their applications in the studies of soils, crops and forests, seeking to contribute to the knowledge of the benefits of this integration and the best use of the potentialities of the to HSI.

**Keywords:** UAV-HSI, big data-HSI, cloud computing-HSI, internet of things-HSI, data mining-HIS.

## Introducción

Es evidente que la población global crece exponencialmente –según Sylvester (2018), en el año 2050 seremos nueve billones de habitantes–, con su correspondiente exigencia para satisfacer sus necesidades vitales; como consecuencia, la explotación de los recursos naturales se incrementa dramáticamente, lo que potencia sus efectos negativos sobre el

ecosistema terrestre. Entonces, es urgente tomar las medidas adecuadas para evitarlos o minimizarlos.

Para dar respuesta al panorama planteado, los científicos que estudian los suelos, los bosques, los cultivos, los recursos hídricos, entre otros, deben realizar investigaciones tendientes a proponer soluciones útiles dirigidas a los usuarios finales –caso agricultores–. En esa dirección, los científicos recurren cada vez con más frecuencia a las imágenes hiperespectrales (HSI, por su sigla en inglés), que por su fina resolución espectral se están convirtiendo rápidamente en una solución práctica para entender, modelar y mapear, de manera más precisa, las principales características y procesos de los recursos terrestres, además, para monitorear sus dinámicas en el tiempo y en el espacio. Sin embargo, en años y décadas pasadas, se convirtió en un desafío el manejo de grandes volúmenes de datos, producidos por las HSI (Thenkabail 2019).

Por otro lado, con el advenimiento de la cuarta revolución industrial (Schwab 2016), proclamada en el Foro Económico Mundial del año 2011, en Hannover (Alemania), se evidenció la emergencia de tecnologías disruptivas como: *big data*, internet de las cosas (IoT, por su sigla en inglés), inteligencia artificial, computación en la nube, minería de datos, robótica y biología sintética, todas ellas muy interconectadas y con capacidad para tratar con cantidades masivas de datos, que los métodos tradicionales no pueden procesar. Por todo lo anterior, esas tecnologías están impactando positivamente en la percepción remota en general (Wang, Yan y Ma, 2020; León-Pérez 2019) y en la percepción remota hiperespectral (HRS, por su sigla en inglés) en particular, potenciando sus capacidades para responder de manera eficiente y en tiempo (casi) real, a la demanda de información sobre los recursos naturales y del medio ambiente.

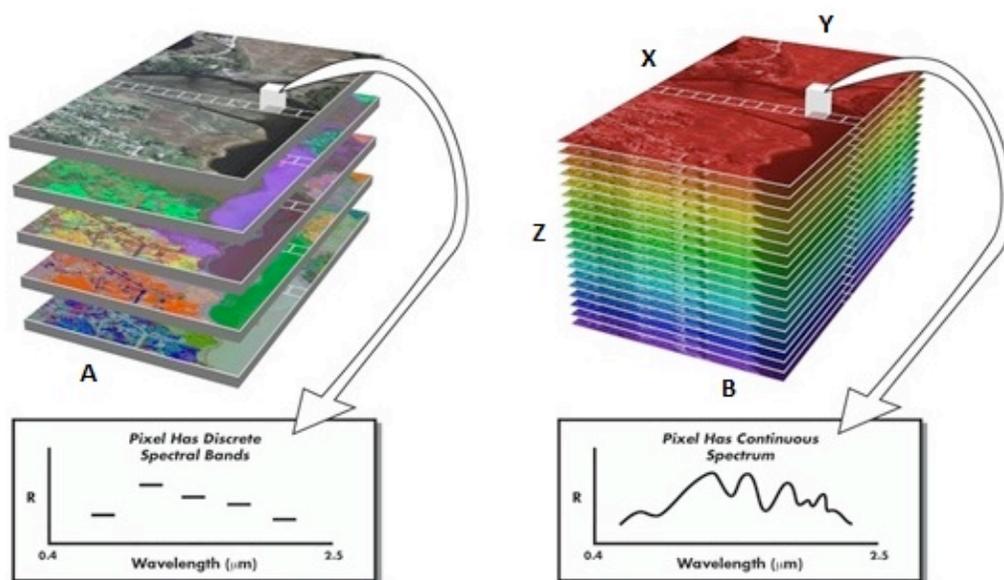
En el contexto antes mencionado, el objetivo principal de este artículo es hacer una revisión sobre el uso de los sensores hiperespectrales en naves aéreas no tripuladas (UAV, por su sigla en inglés); las particularidades de la integración de los datos hiperespectrales con las tecnologías disruptivas, productos de la cuarta revolución industrial, en especial con los *big data*, internet de las cosas, minería de datos, computación en la nube e inteligencia artificial, y sus aplicaciones en los estudios de suelos, cultivos y bosques, buscando aportar al conocimiento de los beneficios de esa integración y el mejor aprovechamiento de las potencialidades de las HSI.

## Generalidades sobre las imágenes hiperespectrales y la cuarta revolución industrial

### Imágenes hiperespectrales

Las imágenes hiperespectrales o imágenes hiperespectroscópicas están integradas por cientos o miles de bandas estrechas y contiguas, a lo largo del espectro electromagnético, obtenidas por sensores ubicados en plataformas aéreas o satelitales, situación que les permite caracterizar y diferenciar de manera más eficiente los objetos que se encuentran en la superficie terrestre (Qi, Inoue y Wiangwang, 2012). En consecuencia, la información detallada de las bandas contiguas de las HSI permite generar curvas espectrales continuas de cada píxel, que es una de las características que las distinguen de las imágenes multiespectrales, que poseen pocas bandas anchas, caso Landsat, Spot, Ikonos (Qi, Inoue y Wiangwang, 2012; Borengasser, Hungate y Watkins, 2008; Jensen 2005), como se observa en la figura 1.

Además, los datos producidos por las HSI, crean un cubo hiperespectral o hipercubo (figura 1B), con información espacial en los ejes X y Y de la escena, y la información espectral ( $\lambda$ ) en el eje Z. Este hecho permite analizar los datos ligando sus características espacial y espectral y generar, entre otras, las librerías espectrales (Ortenberg, 2012), útiles en la clasificación de los objetos en estudio.



**Figura 1.** Imágenes multispectral (A) e hiperespectral (B), con sus correspondientes curvas espectrales. **Fuente:** tomado de Rodríguez-Villamizar (2015).

Para la clasificación de los objetos presentes en la imagen hiperespectral, es necesario, como primer paso, seleccionar los píxeles representativos de cada objeto en estudio, con sus correspondientes firmas espectrales, para luego compararlos con las curvas presentes en la librería espectral (*endmembers*), que permitirá detectar e identificar el objeto (Borengasser, Hungate y Watkins, 2008). Los métodos de análisis espectral, para hacer las comparaciones mencionadas, hacen uso de algoritmos de análisis de imágenes (Jensen, 2005), de los cuales los más conocidos para el procesamiento de HSI, son: clasificador angular (SAM, *spectral angle mapper*), análisis subpíxel y análisis lineal de mezclas espectrales (ALME). La descripción detallada de los algoritmos citados, y de muchos otros, se pueden obtener en Borengasser, Hungate y Watkins (2008); Bajwa y Kulkarni (2012), León (2013) y Thenkabail, Lyon y Huete (2019).

Una característica relevante de las HSI es que, por su alta resolución espectral, producen grandes cantidades de datos que dificultan su transmisión, el almacenamiento y, con frecuencia, la clasificación. En consecuencia, es conveniente proceder con la reducción de la dimensionalidad de la imagen original, que permita encontrar el mínimo tamaño de datos

(bandas) para obtener resultados con la mejor precisión en la clasificación (Moreno *et al.*, 2014), o para detectar bandas óptimas que hacen posible determinar, en las plantas, los contenidos de clorofila, celulosa, lignina y nitrógeno, entre otros, y en el suelo, presencia de minerales arcillosos, sales, materia orgánica, carbonatos y sulfatos (Borengasser, Hungate y Watkins, 2008; Moreno, Huemrich, Chen y Margolis, 2014).

Pero, además, con la selección de bandas específicas se pueden obtener los *bioindicadores espectrales* (Middleton *et al.*, 2012), que implica el máximo aprovechamiento de las HSI orientado a evaluar y monitorear la salud de los ecosistemas, en un amplio rango de escalas, pues permite la conexión de las observaciones obtenidas por sensores ubicados en los satélites, aviones, incluyendo el uso de los vehículos aéreos no tripulados (UAV) y aquellos ubicados muy cerca a la superficie terrestre (< 2m), denominados sensores proximales o cercanos. Estos son temas que se están desarrollando en el presente (Mitran, Meena y Chakraborty, 2021).

Información actualizada sobre las características de las HSI, plataformas, sensores, misiones espaciales, manejo de datos a bordo, algoritmos, entre otros, se puede encontrar en Quian (2020). Aplicaciones para estudios de cultivos y vegetación, está bien documentada en Thenkabail, Lyon y Huete (2019), y Mitran *et al.* (2021), y para estudios de suelos, en Ben-Dor, Chabrillat y Dematte (2019).

#### **Cuarta revolución industria**

La revolución agraria fue seguida por una serie de revoluciones industriales que empezaron en la mitad del siglo XVIII. La primera (1760), por impacto de las máquinas de vapor; la segunda (1870), por impacto de la energía eléctrica, y la tercera (1960), impulsada por los avances de la electrónica, el desarrollo de los computadores e internet (Schwab 2016).

La cuarta revolución industrial (2011) se refiere al impacto de las máquinas y sistemas inteligentes y conectados. Es la fusión de tecnologías y sus interacciones a través de los dominios físico (impresión en 3D, robótica, vehículos autónomos, drones, etc.), digital (internet de las cosas, inteligencia artificial, *big data*, realidad virtual, *blockchain*, etc.) y

biológico (medicina de precisión, biología sintética, bioimpresión, etc.), situación que la hace muy diferente a las revoluciones precedentes (Schwab, 2016).

Además, según Schwab (2016), la cuarta revolución industrial (4Ri) tiene tres características específicas: 1) velocidad, implica el crecimiento exponencial de las tecnologías, gracias al mundo totalmente interconectado que vivimos; 2) alcance, significa que tiene su base en la revolución digital y en la combinación de múltiples tecnologías, que están llevando a cambios de paradigmas sin precedentes, y 3) impacto en los sistemas, que considera su capacidad para transformar sistemas completos a través en países, empresas, industrias y la sociedad como un conjunto.

A propósito de lo expresado en párrafos anteriores, es evidente la importancia de las tecnologías, sin ser exclusivas, entre las que se destacan tres: internet de las cosas (IoT), *big data* e inteligencia artificial (AI, por su sigla en inglés), razón por la cual son consideradas como los ejes de la 4Ri (Schwab, 2016; León-Pérez, 2019). Por su parte, la inteligencia artificial ha recibido un impulso especial, gracias al incremento exponencial de la capacidad de cómputo y la disponibilidad de enormes cantidades de datos, que posibilita, entre otros, el diseño de algoritmos inteligentes con capacidad de aprender, configurando nuevos tipos de aprendizaje automático. Estas y muchas otras tecnologías relacionadas son y deben ser aprovechadas, de manera crítica, para el estudio de los recursos naturales y el medio ambiente.

### **Las imágenes hiperespectrales y su relación con las UAV, *big data*, computación en la nube, internet de las cosas y minería de datos.**

Según muchos autores (Moreno *et al.*, 2014; Thenkabail, 2019; Plaza, Plaza, Martín y Sánchez, 2019; He, Li, Liu y Li, 2018), en años y décadas pasadas, el uso de los datos hiperespectrales tenía muchos desafíos, especialmente relacionados con el manejo de grandes volúmenes de datos y con la necesidad de integrar la información espacial y espectral, para aprovechar las ventajas de la complementariedad que ambas fuentes de información proporcionaban.



En la actualidad, el volumen de datos se ha incrementado exponencialmente, debido al desarrollo de nuevos sensores, nuevos programas espaciales, nuevas plataformas (drones) y nuevas técnicas, capaces de tomar en consideración las propiedades especiales de los datos hiperspectrales, que a su vez reflejan mejoras en las resoluciones espectral, temporal, espacial y radiométrica, de las HSI (Bajwa, Zhang y Shirzadifar, 2019; Thenkabail, Lyon y Huete, 2019; He *et al.*, 2018).

En ese contexto, los datos de los sensores remotos, en especial los de sensores remotos hiperspectrales (HRS), han sido aceptados como *enormes datos de sensores remotos (big RS data)*, no solamente por el gran volumen de datos que producen, sino también por su complejidad (Wang, Yan y Ma, 2020), cuyo procesamiento es considerado como un problema de big data (Wu, Sun y Zhang, 2019). Infortunadamente, esa extraordinaria cantidad de datos, útiles para aplicaciones existentes y otras nuevas, ofrece problemas en su transmisión, almacenamiento, procesamiento, análisis y visualización, para finalmente obtener información que sea útil en la toma de decisiones (Bioucas-Dias *et al.*, 2019; Bajwa, Zhang y Shirzadifar, 2019).

En consecuencia, ¿cómo superar esos desafíos? La respuesta es: integrar las potencialidades de las HSI con las tecnologías de última generación, productos de la cuarta revolución industrial, que incluyen la computación en la nube (*cloud computing*), internet de las cosas (*internet of things –IOT–*), inteligencia artificial (IA), aprendizaje automático (*machine learning*), aprendizaje profundo (*deep learning*), y conocimientos avanzados en el procesamiento y aplicación de los datos hiperspectrales (Thenkabail, 2019).

Entonces, en línea con lo manifestado en el párrafo anterior, a continuación, se hará una presentación de las plataformas, en especial de los UAV, por su relevancia actual, y de algunas tecnologías mencionadas, para terminar con la aplicación de ellas en estudio de suelos, cultivos y bosques, basadas en HSI.

### ***Plataformas y sensores***

En años recientes se han observado avances rápidos en tecnologías hiperspectrales. Así, se han desarrollado sensores que capturan simultáneamente información espectral y espacial,



utilizando un amplio rango del espectro electromagnético, desde el ultravioleta (UV) hasta el infrarrojo de onda larga (LWIR), pasando por el visible/infrarrojo cercano (VNIR), el infrarrojo de onda corta (SWIR) y el infrarrojo de onda media (MWIR) (Ortenberg, 2012), con el aprovechamiento cada vez más frecuente de estos dos últimos.

En cuanto a las plataformas, se puede afirmar que las satelitales son más consistentes, permanentes y de cobertura global; que las aéreas, incluyendo las UAV, desempeñan un gran papel en el estudio de la vegetación, cultivos, minerales y suelos, pero no son permanentes; las basadas en tierra (montadas en plataformas móviles o manejadas a mano, caso espectrorradiómetros) son más utilizadas para la caracterización espectral de los objetos de la superficie terrestre, además de servir como *verdad de campo* para ajustar información obtenida por los satélites y aviones, y ser utilizados también en el laboratorio (Ortemberg, 2012; Thenkabail, Lyon y Huete, 2019; Qi, Inoue y Wiangwang, 2012). Dependiendo de los requerimientos de un proyecto, se pueden obtener datos de una o más plataformas considerando, además, que cada una de ellas tiene sus ventajas y desventajas.

De todas las plataformas mencionadas, las de mayor proyección son las UAV y las satelitales, cuyos programas y principales características son sintetizados en la tabla 1. Cabe destacar que muchos de ellos fueron programados para ser lanzados después del año 2017, como son: PRISMA, EnMAP Hiperespectral Imagery, HISUI, Spaceborne Hyperspectral Infrared Imager (HypIRI) e Hyperspectral X IMagery (HypXIM), con número de bandas sobre los 200 y resolución espectral de aproximadamente 10 nm (Transon, D'Andrimont, Maignard y Defourny, 2018).

**Tabla 1.** Sensores hiperespectrales a bordo de satélites, actuales y futuros

Sensor/Misión	País	Organización	Año de lanzamiento	Resolución espacial(m)	Resolución temporal (días)	Bandas espectrales (No.)	Rango espectral (nm)
Hyperion/EO-1	EE UU.	NASA	2000	30	16	220	360-2600
PRISMA	Italia	ASI	2018	30	14-7	247	400-2600
HISUI	Japón	METI	2018	30	2-60	185	400-2500
CCRSS	China	CNSA	2018	30	110	328	400-2500
EnMAP	Alemania	DLR	2020	30	27	244	400-2500
SHALOM	Italia/Israel	ASI/ISA	2022	10	2	241	400-2500
HypIRI	EE UU.	JPL/NASA	2021/24	30-60	5-16	214	380-2510
HypXIM	Francia	CNES	2021/24	8	3-5	210	400-2500

NASA -National Aeronautics and Space Administration., ASI – Agenzia Spaziale Italiana, METI – Ministry of Economy Trade and Industry, CNSA – China National Space Administration, DLR – Deutchen Zemtrums Für Luft-Und Raumfahrt, ISA – Israel Space Agency, JPL – Jet Propulsion Laboratory, CNES – Centre National d’Estudes Spatiales.

**Fuente:** modificado de Transon *et al.* (2018).

### ***Sensores remotos hiperespectrales basados en vehículos aéreos no tripulados***

La ciencia de la percepción remota hiperespectral (HRS) se ha desarrollado enormemente gracias a la integración de sensores remotos hiperespectrales ligeros y de bajo costo, con los vehículos aéreos no tripulados (UAV), también llamados sistemas aéreos no tripulados (UAS) o sistemas aéreos remotamente pilotados (RPAS), comúnmente denominados drones. Como una alternativa a los aviones clásicos, los UAV tienen ventajas para los investigadores al proporcionar imágenes hiperespectrales para estudio, locales y regionales, con muy alta resolución espacial (centímetros), de manera pronta y flexible (Zhong *et al.*, 2017; Thenkabail, Lyon y Huete, 2019; Bioucas- Dias *et al.*, 2013).

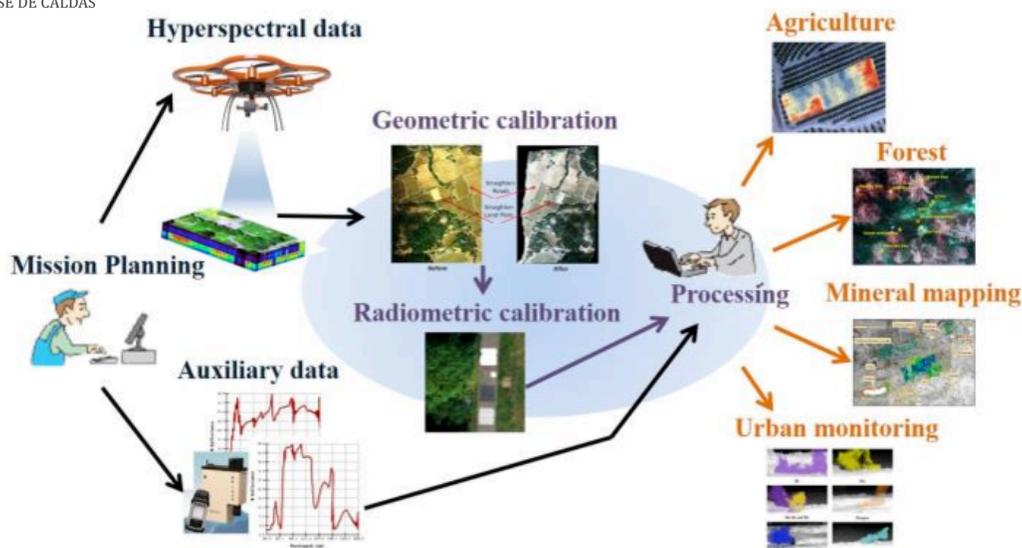
Las plataformas que cargan sensores hiperespectrales para usos civiles incluyen: sistemas pequeños de alas fijas y multirrotores (< 2 kg) y sistemas grandes de alas fijas y multirrotores (> 2 kg). Las especificaciones técnicas de los dos sistemas son muy variadas, resaltando solamente que los pequeños llevan como carga útil cámaras de menos de 1 kg,



mientras que los grandes llevan cámaras de aproximadamente entre 0,5-9 kg (Al-Amin y Phinn, 2019; Proctor, 2018).

En cuanto a los sensores hiperespectrales, estos son de dos tipos: sistemas que no producen imágenes y aquellos que sí. Los primeros implementan mediciones a bajas alturas sobre un determinado objeto (punto) o sobre un transecto (línea), utilizando generalmente las bandas VIS-NIR (400-1100 nm) con resolución espectral entre 1,5 a 10 nm. Los segundos operan, además del VIS-NIR, en la región infrarrojo de onda corta (Ben-Dor, Chabrilat y Dematte, 2019), aunque para ello se requiere de detectores más complejos y especializados (Al-Amin y Phinn 2019). Igual que las plataformas, los sensores hiperespectrales tienen características muy variadas, dependiendo de las casas comerciales que los producen.

Con la plataforma y el sensor seleccionados, el flujo de trabajo contempla, en términos generales, los siguientes pasos (figura 2): planeación de vuelo, incluyendo la ruta, la velocidad, altura sobre el terreno, traslape de imágenes; obtención de las imágenes; corrección (geométrica y radiométrica) de los datos crudos, centrado en el área de interés, teniendo en cuenta la inmensa cantidad de datos que tiene un cubo HS (*big data*); procesamiento de los datos, incluyendo el análisis con variadas técnicas emergentes como la minería de datos y la inteligencia artificial, apoyados, además, por los datos auxiliares (humedad y temperatura del suelo, PH, etc.) obtenidos por la red de sensores inalámbricos (*wireless sensor network* –WSN–) instalados en el campo y por las bibliotecas espectrales, y finalmente, presentación de resultados, con acceso en línea, para diferentes tipos de aplicaciones (agricultura, forestal, minería, urbana, etc.), en muchos casos en tiempo (casi) real (Zhong *et al.*, 2017; Sandino, Pegg, González y Smith, 2018).



**Figura 2.** Flujo de trabajo para desarrollar el sensoramiento remoto hiperespectral basado en vehículos aéreos no tripulados (UAV). **Fuente:** Zhong *et al.* (2017).

En la actualidad y para el futuro, hay desafíos relacionados con el desarrollo de protocolos estándar para coleccionar, corregir y procesar datos obtenidos por espectrorradiómetros de campo, drones y aviones e integrarlos directamente con los datos de los satélites (Al-Amin y Phinn, 2019).

### ***Big data e HSI***

Los datos masivos de observación de la Tierra (*big earth observing data*), son definidos en función de tres características principales: volumen, velocidad y variedad (Bhargavi y Jyothi 2018). Volumen se refiere a la cantidad de datos (*terabytes* (TB), *petabytes* (PB), *exabytes* (EB), etc.); velocidad, a la rata en que los datos son generados, procesados y entregados a los usuarios, y variedad, a los tipos de datos, que pueden ser estructurados, semiestructurados y no estructurados, producidos por cada vez más variadas fuentes (sensores remotos, sensores cercanos, sensores basados en tierra, red de sensores inalámbricos –*wireless sensor networks*–, redes sociales, la web, teléfonos móviles, etc.) y con diferentes frecuencias (Bhargavi y Jyothi, 2018; Wang, Yan y Ma, 2020).

En concreto, el gran volumen de información presente en la imagen hiperespectral es el producto integrado de las dimensiones espacial o píxeles y la espectral, que definen un *hipercubo* (Bioucas-Dias *et al.*, 2013). Si a esta relación se incorpora la variable tiempo (multitemporalidad), la cantidad de información aumentará considerablemente. Un ejemplo para este último caso es cómo el sensor hiperespectral Hyperion, con  $256 \times 6925$  píxeles, 242 bandas y resolución radiométrica de 12 bits en 30 segundos, recolecta 71,9 GB de datos en una hora o 1,6 TB en un día (Wu, Sun y Zhang, 2019).

Con las características mencionadas anteriormente (multiespectral, multisensor, multirresolución y multitemporal), es imposible realizar la analítica de los datos utilizando métodos computacionales convencionales. En consecuencia, se recurre a un nuevo paradigma de la computación denominado computación en la nube (*cloud computing*).

### ***Computación en la nube e HSI***

Según el Instituto Nacional de Estadísticas y Tecnologías Estadounidense (NIST, por sus siglas en inglés), citado por Wu, Sun y Zhang (2019), la computación en la nube es

[...] un modelo que permite el acceso bajo demanda a través de la red, a un conjunto compartido de recursos de computación configurable (como por ejemplo redes, servidores, almacenamiento, aplicaciones y servicios) que pueden ser rápidamente suministrados, con el mínimo esfuerzo de gestión o interacción del proveedor del servicio. (p. 105)

De la definición se deduce que el modelo tiene cinco características esenciales: a) servicio por demanda; b) amplio acceso a la red con diferentes dispositivos; c) gran disponibilidad de recursos físicos y virtuales, según demanda del usuario; d) rápida elasticidad, o sea rápida disponibilidad de servicios para adaptarse al tamaño de la demanda real, y e) monitoreo del uso de los recursos, para pagar solo por el tiempo usado (Wu, Sun y Zhang, 2019; Wang, Yan y Ma, 2020).

Una parte importante de la computación en la nube está relacionada con los servicios que proporciona, siendo tres los básicos: a) infraestructura como servicio (*IaaS: infrastructure as a service*); b) plataforma como servicio (*PaaS: platform as a service*), y c) *software como servicio (SaaS: software as a service)* (Wang, Yan y Ma, 2020). *IaaS* hace referencia



al hecho de ofrecer servicios de computación, almacenamiento, redes y otros recursos computacionales, donde el usuario será capaz de desplegar y correr virtualmente, el *software* seleccionado. *PaaS* considera la disponibilidad de lenguajes de programación, librerías, sistemas de manejo de bases de datos y otros, todos proporcionados por el proveedor. *SaaS* es un modelo donde el usuario accede al *software* a través de internet, para luego pagar exclusivamente por el tiempo de uso (Wang, Yan y Ma, 2020).

Existen otros tipos de servicios, entre ellos: datos como servicio (*DaaS*), bases de datos como servicio (*DBaaS*) y sensores como servicio (*SaaS*), cuya generalización se expresa como *XaaS*, donde X puede ser cualquier tipo de servicio (Zaslavsky, Perera y Georgakopoulos, 2012).

Además de los servicios mencionados, hay un sistema de servicios más específicamente relacionado con los sensores remotos, incluyendo los sensores hiperespectrales, denominado “servicios de información de sensores remotos basados en la nube” (CRSIS, por su sigla en inglés) integrado por cuatro servicios: a) datos de sensores remotos como servicios (*RSDaaS*); b) procesamiento de datos de sensores remotos como servicio (*RSDPaaS*); c) producción de productos de sensores remotos como servicio (*RSPPaaS*), y d) plataformas de cómputo para datos de sensores remotos como servicio (*RSCPaaS*). *RSDaaS* hace referencia a que el usuario puede contar con datos originales o con datos transformados. *RSDPaaS* considera el tratamiento de imágenes en línea, incluyendo mejoramiento, transformación y construcción de mosaicos, fusión y extracción de información. *RSPPaaS* incluye principalmente orden de análisis y producción de productos temáticos, y *RSCPaaS* proporciona máquinas virtuales que integran *software* comúnmente usados en percepción remota, librerías de algoritmos, entre otros (Wang, Yan y Ma, 2020).

En consecuencia, para hacer un buen análisis (analítica) de esos grandes volúmenes de datos de las imágenes hiperespectrales, se debe tomar ventaja de las capacidades de alto desempeño que ofrece la arquitectura y servicios de la computación en la nube. Uno de los modelos de programación distribuido más conocido y ampliamente usado para aprovechar esas ventajas es el denominado *MapReduce* (MR). Específicamente, en ese modelo el proceso de cómputo consiste en dos operaciones distribuidas: “Map” y “Reduce” (Wu, Sun

y Zhang, 2019). La función “Map” divide la tarea del procesamiento de datos de imágenes HS, en muchas subtarefas independientes que son ejecutadas en paralelo, utilizando simultáneamente múltiples recursos de computación, hasta producir resultados intermedios. Por otra parte, la función “Reduce” procesa los datos intermedios (Wu, Sun y Zhang, 2019). El resultado final se obtiene mediante la recopilación e interpretación de los resultados de las subtarefas, hasta llegar a obtener, por ejemplo, la clasificación de la cobertura de la tierra a nivel continental.

Otra tecnología de computación en la nube es *Google Earth Engine* (GEE), definido como una plataforma pública, con una enorme capacidad de cómputo distribuido y en paralelo, para el análisis científico y visualización de grandes volúmenes de datos, a grandes velocidades, especialmente en el campo de la geografía (*geo big data*) (Wu, Sun y Zhang, 2019). Para el tratamiento de datos de sensores remotos, combina catálogos de imágenes de múltiples satélites de observación de la tierra (*EO big data*), a nivel de *petabytes*, con datos geoespaciales a escala global (modelos digitales de elevación, datos meteorológicos, datos de cobertura de la tierra, etc.), permitiendo a los investigadores detectar cambios, tendencias y cuantificar diferencias multitemporales en la superficie de la tierra, relacionados con degradación de suelo, deglaciación, deforestación, uso de la tierra, salud de los cultivos, etc. (Anece *et al.*, 2019; Wu, Sun y Zhang, 2019).

Como se desprende de lo expresado líneas arriba, el procesamiento de *big data* hiperespectrales se realiza en tiempo (casi) real, gracias al aporte de la computación en la nube. Pero ¿cuáles son las principales fuentes de datos y cómo se relacionan ellas? Para dar respuesta, aparece otra tecnología disruptiva denominada *internet de las cosas*.

### ***Internet de las cosas y HSI***

Internet de las cosas (*internet of things* –IoT–) es una red de sensores y actuadores ubicados en objetos físicos, enlazados mediante cables o sin ellos, que a menudo utilizan el mismo protocolo de internet (Joyanes, 2013). Según Lyer (2018), hay dos tipos principales de sensores: los de percepción remota y los embebidos o incrustados en la superficie del suelo. Los primeros miden la radiación electromagnética, en diferentes longitudes de onda,



reflejadas o emitidas por los objetos de la superficie terrestre, denominados por ello como *IoT extrínsecos*. Los segundos son convertidores electrónicos (detectores) que miden una cantidad física o química (humedad y temperatura del suelo, estrés de las plantas por falta de agua, deficiencia de nutrientes, salinidad de suelos, etc.) y la convierten en una señal que puede ser leída por una persona (*M2P: machine to people*) o por otro instrumento (*M2M: machine to machine*), constituyéndose en *IoT intrínsecos*. Ellos son, en gran medida, los causantes de las cantidades masivas de datos (Bhargavi y Jyothi, 2019; León- Pérez, 2019). Por lo dicho, los sensores son una parte integral del IoT, donde los datos provenientes de diferentes dispositivos y conectados por internet son procesados en tiempo (casi) real, con el apoyo de la computación en la nube, para proporcionar una mejor respuesta a las condiciones cambiantes de un problema determinado. Además, en la actualidad existen nuevos sensores de imágenes hiperespectrales de bajo costo, para teléfonos inteligentes, que ayudan a detectar tempranamente, por ejemplo, enfermedades de los cultivos y comunicar a los tomadores de decisiones, para actuar oportunamente y así minimizar pérdidas económicas (Bhargavi y Jyothi 2019).

### ***Minería de datos e HSI***

Las imágenes hiperespectrales son usadas para encontrar objetos, identificar materiales y detectar procesos. En esa dirección, para que el aprovechamiento de la información que ellas proporcionan sea más eficiente, es necesario recurrir a métodos espectral-espaciales que puedan manejar grandes volúmenes de datos y encontrar, de manera automatizada, patrones espaciales, correlaciones espaciales y tendencias previamente desconocidas, como la que realiza la minería de datos (Bhargavi y Jyothi, 2018; Bajwa, Zhang y Shirzadifar, 2019).

La aplicación de la minería de datos en el estudio de suelos, vegetación, bosques y cultivos es determinante, porque ayuda a remover las bandas espectrales redundantes, causadas por la alta dimensionalidad de las HSI, y así obtener las bandas más útiles para estimar características muy específicas de cada recurso (tipos de clorofila, lignina, índices de vegetación, índices de suelo, etc.), además de considerar de manera consistente la

naturaleza espacio-espectral de este tipo de imágenes (Thenkabail *et al.*, 2019; Bajwa, Zhang y Shirzadifar, 2019; Aneece *et al.*, 2019). Para el análisis, la minería de datos utiliza técnicas de inteligencia artificial (IA), redes neuronales artificiales, aprendizaje automático (*machine learning*), aprendizaje profundo (*deep learning*), entre otros (Bajwa, Zhang y Shirzadifar, 2019).

En suma, el análisis de datos hiperespectrales es una tarea multidisciplinaria, con el apoyo de las tecnologías mencionadas (*big data*, computación en la nube, internet de las cosas y minería de datos), las que están fuertemente interconectadas (Zaslavsky, Perera y Georgakopoulos, 2012; Bioucas-Dias *et al.*, 2013; León-Pérez, 2019).

### *Aplicaciones*

#### *Estudio de suelos*

La comunidad científica de suelos está frente a una creciente demanda de datos, para apoyar la seguridad alimentaria de la sociedad, por lo que con más frecuencia recurre a la espectroscopia de suelos, considerada una técnica analítica rápida, rentable, ambientalmente amigable, no destructiva, reproducible y repetible (Nocita *et al.*, 2015). Además, porque ella permite obtener datos de manera sistemática y flexible, partiendo primero a escala de laboratorio y campo (*in situ*), como paso previo para analizar muestras de suelos y apoyar el mapeo digital de suelos, luego operar a escala de los sensores remotos hiperespectrales (aéreos y espaciales) y, finalmente, proceder con el mapeo cuantitativo de suelos, a nivel global, y su correspondiente monitoreo (Chabrilat *et al.*, 2019; Nocita *et al.*, 2015; Ben-Dor, Chabrilat y Dematte, 2019).

En coherencia con lo anterior, Carmon y Ben-Dor (2017) manifiestan que la combinación de la espectrometría y la quimiometría cumplen papel muy importante en el análisis de las propiedades químicas, físicas y mineralógicas del suelo, con continuidad espacial, pero que por la naturaleza multivariada de los datos espectrales, para su análisis se requiere de técnicas especiales, como la minería de datos. Los autores mencionados desarrollaron una máquina de minería de datos automática, denominada PARACUDA II, para calcular el



contenido de MO, CO, CaCo<sub>3</sub>, CEC, Fe<sup>++</sup> y área superficial específica de 91 muestras de suelos de Israel, logrando resultados con R<sup>2</sup> entre 0,862 y 0,946, comprobados con datos de librerías espectrales. Concluyen que, con el número de muestras y tratamientos utilizados, el proceso que duró aproximadamente cinco minutos, podría haber durado semanas con un *software* convencional.

Un trabajo novedoso es el que realizaron Xu *et al.* (2021), con el objetivo de mapear la concentración de varias fracciones de nitrógeno (N), en perfiles completos de tres suelos típicos de China, integrando la espectroscopía de HSI (basado en laboratorio) con diferentes técnicas de aprendizaje automático (ML). Ellos concluyen que la combinación de la espectroscopía de HSI con la técnica ML, denominada *regresión de la máquina de soporte vectorial* (SVMR, por su sigla en inglés), fue la más eficiente y que puede ser usada para lograr un mapeo rápido, de bajo costo y de alta resolución. Además, consideran que la visualización de las fracciones de N en el perfil completo puede aportar información para muchos propósitos, como caracterizar la heterogeneidad espacial de los perfiles de suelos, explorar los mecanismos de acumulación del N en diferentes profundidades y entender los procesos de formación del suelo.

Por su parte, Schmid *et al.* (2016) fueron capaces de identificar, definir y mapear propiedades del suelo que pueden ser usadas como indicadores de los diferentes grados de erosión, de un sector de Camarena (Madrid, España), utilizando espectrorradiómetros de campo, imágenes hiperespectrales aéreas (aisaEAGLE y aisaHAWK), modelos digitales del terreno (DTM), apoyados con datos morfológicos y físicoquímicos obtenidos en el campo. Al respecto, Transon *et al.* (2017) sostienen que el uso de imágenes HS para el mapeo de erosión, tiene limitaciones relacionadas con la resolución espacial (> 30 m), situación que será solucionada con la llegada de nuevos programas, como *SHALOM* y *SENTINEL-10*, que tendrán una resolución de entre 10 m a 30 m y una particular atención para el estudio de suelos (Ben-Dor, 2017; Ben-Dor, Chabrillat y Dematte, 2019).

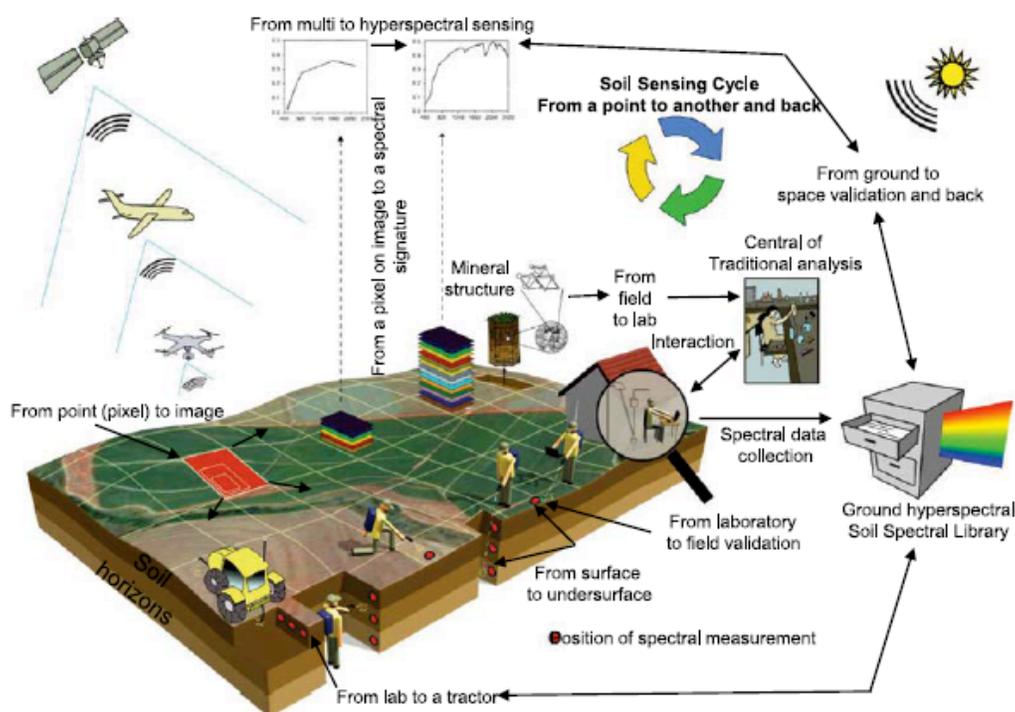
La salinización de suelos, de gran impacto en la agricultura, es también tema de estudio utilizando avances en el manejo de HSI. Así, Neto *et al.* (2017) realizaron una

investigación para determinar el grado de salinización de suelo de las regiones semiáridas de Brasil, en función de la conductividad eléctrica (CE), para lo cual correlacionaron la espectroscopia de suelos determinado en laboratorio, con datos de un sensor hiperespectral aéreo ProSpecTIR-VS. Aun cuando ellos manifiestan restricciones por no contar con suficiente memoria del computador para el procesamiento rápido de los datos y la limitada capacidad de los algoritmos para trabajar con un gran número de bandas espectrales, esencia del *big data* hiperespectral, utilizan un modelo computacional avanzado denominado *máquina de aprendizaje extremo (ELM: extreme learning machine)*, seleccionado por su alta tasa de aprendizaje y su buena capacidad de generalización, para estimar la CE de los suelos salinos, situación que se demuestra al presentar un coeficiente de determinación ( $R^2$ ) de 0,953.

En concordancia con lo expresado en párrafos anteriores, es viable afirmar que el progreso en el análisis cuantitativo de suelos desde el enfoque espectral-espacial y los recientes avances en nuevos sensores hiperespectrales, y de menor costo, crearán un ambiente propicio para estudios innovadores y aplicaciones prácticas, presentes y futuras, en la ciencia del suelo. En esa perspectiva, se investiga en la posibilidad de ampliar, a ambos lados, el rango espectral disponible (VIS-NIR\_SWIR), llegando al ultravioleta (UV) (< 300 nm) y al infrarrojo termal-TIR (2500-14 000 nm), este último de gran promesa para proporcionar más información cuantitativa sobre los suelos; en el uso más frecuente de las UAV con sensores hiperespectrales y , algo muy prometedor, en llegar al sensoramiento del perfil del suelo, utilizando otro tipo de sensor denominado *radar de penetración del suelo (GPR: ground penetrating radar)*, para superar la limitante de estudiar solo los primeros 5 mm con los métodos convencionales (Ben-Dor, Chabrillat y Dematte, 2019).

Finalmente, en la figura 3 se muestra el ciclo de sensoramiento del suelo (Ben-Dor, Chabrillat y Dematte, 2019), donde se resalta el hecho de cómo la gran cantidad de información sobre el suelo (*big soil data*), proveniente de diferentes sensores, pueden confluír para crear una nueva perspectiva de interpretación y análisis detallado de un mismo recurso, en este caso del suelo. Así, se observa el sensoramiento remoto desde los satélites hasta los drones; el sensoramiento cercano; el sensoramiento multiespectral al

hiperespectral; las mediciones en 3D de las características del suelo, tanto superficiales como del perfil; mediciones espectrales en el campo y su relación con los análisis en laboratorios tradicionales; la función importante de las librerías espectrales de suelos, para validar las mediciones satelitales y las obtenidas en el laboratorio, y el flujo de información del laboratorio a los tractores, como insumo básico para el desarrollo de la agricultura de precisión.



**Figura 3.** Ciclo del sensoramiento de suelos: desde la librería espectral de suelos y las mediciones en campo en 3D, hasta el sensoramiento remoto desde drones a satélites. **Fuente:** Ben-Dor, Chabrilat y Dematte (2019).

La figura 3 es muy dicente en cuanto a la obtención de los *big soil data*, pero no en relación con su tratamiento a través de tecnologías como la computación en la nube, la minería de datos, la inteligencia artificial y el IoT, que está potenciando la función de la red de sensores inalámbricos (WSN), para obtener información útil sobre el estado del suelo en

tiempo (casi) real. Los casos presentados en la sección de aplicaciones muestran claramente las ventajas de la integración HSI-tecnologías disruptivas y, al respecto, Ben-Dor (2017) plantea que en la actualidad se analizan los datos espectrales de suelos mediante la técnica de aprendizaje automático para minería de datos, pero que en el futuro se recurrirá a la aproximación de aprendizaje profundo automatizado (*automated deep learning*).

Un avance prometedor, en el presente y hacia el futuro es la miniaturización de los sensores HS con un amplio rango espectral (VIS-NIR-SWIR), facilitando la producción de cámaras de peso ligero, que pueden ser montados en UAV, para obtener información de altas resoluciones espectral y espacial, que formará parte de la llegada de la nueva era del sensoramiento espectral de suelos.

#### *Estudio de cultivos y bosques*

Los datos de HSI están emergiendo rápidamente como soluciones prácticas en la clasificación, modelamiento y mapeo de cultivos y vegetación. Así, los índices de vegetación hiperespectrales (HVI, por su sigla en inglés) tienen la fortaleza de generar índices específicos para cuantificar características biofísicas, bioquímicas y estructurales de las plantas, como: HVI para biomasa, HVI para humedad, entre otros, explicado por el hecho de que, al utilizar bandas estrechas, ellas son mejor centradas en las porciones de longitudes de onda sensibles y específicas del espectro. Además, con el advenimiento en los últimos tres o cuatro años, de algoritmos de aprendizaje automático (ML) utilizados en plataformas de computación en la nube (caso *GEE: Google Earth Engine*), entre otras técnicas, las precisiones en la clasificación (ejemplo: especies dentro de un conjunto de cultivos) han mejorado sustancialmente (Thenkabail, Lyon y Huete, 2019).

En línea con lo anteriormente expresado, Aneece y Thenkabail (2018) desarrollaron una investigación para diferenciar cinco cultivos importantes a nivel mundial (maíz, soya, trigo, arroz y algodón), en siete zonas agroecológicas de EE. UU., usando para ello 99 imágenes hiperespectrales Hyperion, de 30 m de resolución espacial, del periodo 2008-2015. La clasificación de los tipos de cultivo se realizó con técnicas de aprendizaje automático

(*SVM: support vector machine*), en la plataforma GEE, logrando a precisiones entre 75 % y 95 %, por lo que concluyen que el método garantiza el mapeo y monitoreo permanente de los cultivos, además de aportar a la implementación de una librería espectral de cultivos, a nivel global.

Por su parte, Gutiérrez, Tardaguila, Fernández-Navales y Diago (2016), y Gutiérrez, Fernández-Navales, Diago y Tardaguila (2018), implementaron dos trabajos con la finalidad de discriminar variedades de vid. El primero se realizó en Navarra, España, con técnicas de minería de datos, sobre datos de 10 variedades de vid adquiridos por un espectrofotómetro NIR portable, con rango espectral entre 1600 nm y 2400 nm, logrando una precisión entre 88,7 % y 92,5 %. El segundo se implementó en La Rioja, España, a través de técnicas de aprendizaje automático, para clasificar 30 variedades de vid, bajo condiciones de campo, usando imágenes obtenidas de sensores hiperespectrales montados en vehículos en movimiento (5 km/h), alcanzando precisiones entre 83 % y 97 %. Ambos grupos de investigadores concluyen que los resultados muestran el poder del uso combinado de técnicas de aprendizaje automático (ML) y el sensoramiento HS no invasivo, para apoyar la industria vinícola.

Un caso de estudio muy interesante es el desarrollado por Wu, Sun y Zhang (2019), con el objetivo de demostrar la aplicabilidad y eficiencia del uso de las tecnologías de computación en la nube, para realizar de manera eficiente el procesamiento distribuido y paralelo de *big data* hiperespectral, en la clasificación de la cobertura de la tierra de dos zonas de EE. UU. (Indian Pines e Indiana). Para tal fin utilizaron imágenes hiperespectrales AVIRIS (200 bandas, rango espectral de 0,4 nm-2,5 nm, resolución espectral de 10 nm y resolución espacial de 20 m) y tecnologías avanzadas de computación en la nube, entre ellas Map Reduce. Ellos lograron una precisión de 93,01 % en la clasificación y concluyen que la metodología propuesta, además de su alta precisión, acelera el proceso de computación de grandes volúmenes de datos.

Para las aplicaciones forestales, las HSI proporcionan abundante información, configurando el denominado *big data forestal*, por lo que las tradicionales tecnologías de almacenamiento y análisis de los datos no reúnen las condiciones para su tratamiento. En

consecuencia, se requiere de tecnologías propias de los *big data*, que pueden mejorar efectivamente la capacidad de almacenamiento, la velocidad de cómputo y análisis, y la eficiencia en la transmisión y visualización de resultados. Al respecto, Zou *et al.* (2019) hacen referencia a dos aplicaciones: la primera, relacionada con la clasificación y detección de cambios en la cobertura forestal, implementando la fusión de datos LIDAR con datos hiperspectrales, para cuyo proceso utilizan tecnologías de *big data* y aprendizaje profundo (*deep learning*) y máquina de soporte vectorial (SVM). La segunda trata sobre la prevención de incendios forestales y detección de pestes y enfermedades, integrando imágenes de sensores remotos con técnicas de computación en la nube e información de una red de sensores inalámbricos (WSN), para el caso de incendios, y con tecnologías de *big data* y visión por computador, para el segundo. En ambos casos se demostró el servicio eficiente y dinámico de las tecnologías, para el usuario final.

Por otro lado, Sandino *et al.* (2018) presentan un estudio específico de mapeo aéreo de bosques naturales y plantados de Australia, atacados por hongos patógenos, con una metodología que integra vehículos aéreos no tripulados (UAV), sensores de imágenes hiperspectrales e inteligencia artificial. La información espectral es obtenida usando una cámara hiperspectral (Headwal Nano-Hyperspec), montada en un UAV hexarotor DJI S800 EVO, cuyo sensor trabaja con 274 bandas, en un rango de longitudes de onda entre 385 nm y 1000 nm (VNIR), y una resolución espectral de 2,2 nm. Para el procesamiento de datos, expresados en hipercubos, se desarrolló un algoritmo usando aprendizaje automático (ML), lo que dio como resultado una precisión en la clasificación de 95 % para árboles sanos y 97 % para árboles afectados por hongos. Ellos concluyen que la metodología empleada es versátil porque permitirá, además, analizar daños en los árboles, procesando grandes volúmenes de datos provenientes de diferentes sensores.

Algunos desafíos para el futuro contemplan casos como investigar en sistemas eficientes de clasificación de vegetación y cultivos, basados en aprendizaje automático y aprendizaje profundo (ML/DL); en determinar índices espectrales de enfermedades (SDI, por sus siglas en inglés), con el apoyo de ML, para posibilitar una rápida detección de enfermedades de plantas; una mejor estimación cuantitativa de las características biofísicas, biogeoquímicas,



contenido de agua del follaje, para la cual se deben eliminar las bandas redundantes, recurriendo a la minería de datos; desarrollar métodos y protocolos bien establecidos, que permitan integrar de manera segura, información hiperespectral obtenidas en el campo, el laboratorio, por drones, aviones y satélites, para un mapeo eficiente de las propiedades biofísicas de la vegetación, con apoyo de la inteligencia artificial, y procesar grandes volúmenes de datos en tiempo real, buscando responder rápidamente en casos críticos como: presencia de enfermedades, plagas, déficit de agua, incendios, etc. (Al-Amin y Phinn, 2019; Ortenberg, 2012; Thenkabail, Lyon y Huete, 2019; Zou *et al.*, 2019).

Visto en conjunto, es conveniente profundizar en trabajos de integración de los datos hiperespectrales con otros tipos de sensores (LiDAR, radar, etc.), en el desarrollo de sistemas de procesamiento y manejo de grandes volúmenes de datos, recurriendo a las capacidades de las tecnologías disruptivas (León-Pérez, 2019) tales como computación en la nube, minería de datos, internet de las cosas (IoT) e inteligencia artificial, en la perspectiva de entender mejor el comportamiento de los suelos, bosques, cultivos, entre otros, y responder al gran desafío de producir alimentos de alta calidad, para toda la sociedad y de manera sostenida, protegiendo los ecosistemas físicos y preservando los recursos naturales.

### Conclusiones

- Las investigaciones sobre las HSI demuestran que, por su riqueza en datos, producto de sus cientos de bandas estrechas y contiguas, incidirán cada vez más en el mejoramiento de la calidad de los estudios de suelos, cultivos y bosques. Sin embargo, en años y décadas pasadas (antes de 2011), había dos limitaciones importantes: el manejo de grandes volúmenes de datos y el no aprovechamiento de la información espectral-espacial que ellas proporcionaban.
- La evolución de la percepción remota hiperespectral ha permitido mejoras sustanciales en el uso de plataformas basados en tierra, en el laboratorio, en los satélites y, especialmente, en los drones, aprovechando el desarrollo de sensores hiperespectrales livianos y de bajo costo y, además, en el uso más eficiente del espectro



electromagnético llegando a los rangos ultravioleta (UV) e infrarrojo lejano (LWIR), para obtener información más precisa sobre suelos, cultivos y bosques.

- El incremento exponencial de datos hiperespectrales, producto de mejoras en sus resoluciones espectral, espacial, temporal y radiométrica, difíciles de ser procesadas por métodos tradicionales, han hecho necesarias el uso de las tecnologías disruptivas, productos de la cuarta revolución industrial, tales como: *big data*, internet de las cosas, computación en la nube, minería de datos e inteligencia artificial, para almacenar, procesar, analizar y producir resultados en tiempo (casi) real, potenciando los servicios de las HSI.
- Hay evidencias claras de cómo la fusión de las HSI con las tecnologías disruptivas, incluyendo técnicas de aprendizaje automático y aprendizaje profundo, son eficientes para el tratamiento del *big data de suelos*, incidiendo en la determinación de sus principales características, su mapeo con base en la información espectral, la detección y seguimiento de la erosión y la salinidad; del *big data forestal*, para mejorar la clasificación y determinar cambios en la cobertura forestal, seguimiento a los incendios forestales, detección de plagas y enfermedades y, también, para el estudio de cultivos facilitando su mapeo, determinación de especies y variedades, a través del análisis de sus características biofísicas, bioquímicas y estructurales, utilizando índices de vegetación hiperespectrales.
- Los desafíos para el futuro contemplan casos como: desarrollar métodos y protocolos bien establecidos para integrar de manera segura información hiperespectral obtenidas en el campo, en el laboratorio, por drones, aviones y satélites; profundizar en trabajos de integración de datos hiperespectrales con otro tipo de sensores (casos LiDAR y radar), para conocer mejor la estructura de los bosques y cultivos y, especialmente, para *descubrir* el perfil del suelo; eficiencia en la obtención de datos con procesamiento a bordo y, aprovechamiento eficiente y de manera crítica de las tecnologías disruptivas, para dar soluciones en tiempo real a los diferentes problemas relacionados con los suelos, bosques y cultivos.

## Agradecimientos

A la ingeniera de sistemas Myriam Ortíz Osorio, por su apoyo en la estructuración del presente artículo.

## Referencias bibliográficas

- Al-Amin, M. y Phinn, S. (2019). Methods for linking drone and field hyperspectral data to satellite data. En P. S. Thenkabail, J. G. Lyon y A. Huete (eds.), *Fundamentals, sensor systems, spectral libraries and data mining for vegetation* (pp. 149-164). Boca Ratón: CRC Press.
- Aneece, I. P. y Thenkabail, P. S. (2018). Accuracies achieved in classifying five leading world crop types and their growth stages using optimal Earth-Observing-1 Hyperion hyperspectral narrow bands on Google Earth Engine. *Remote Sensing*, 10(2027). DOI: 10.3390/rs10122027 .
- Aneece, I. P., Thenkabail, P. S., Lyon, J. G., Huete, A. y Slonecker, T. (2019). Spaceborne hyperspectral EO-1 Hyperion data pre-processing methods, approaches and algorithms. En P. S. Thenkabail, L. G. Lyon y A. Huete (eds.), *Fundamentals, sensor systems, spectral libraries and data mining for vegetation* (pp. 251-272). Boca Ratón: CRC Press.
- Bajwa, S. G. y Kulkarni, S. S. (2012). Hyperspectral data mining. En P. S. Thenkabail, G. J. Lyon y A. Huete (eds.), *Hyperspectral remote sensing of vegetation* (pp. 93-120). Boca Ratón: CRC Press.
- Bajwa, S. G., Zhang, Y. y Shirzadifar, A. (2019). Hyperspectral image data mining. En P. S. Thenkabail, J. G. Lyon y A. Huete (eds.), *Fundamentals, sensor system, spectral libraries and data mining for vegetation* (pp. 273-302). Boca Ratón: CRC Press.
- Ben-Dor, E. (julio de 2017). *Spectral imaging of soils: past present and future*. 2<sup>nd</sup> International Conference on Airborne research for the Environment. DLR-the German Aerospace Research Center, Germany.
- Ben-Dor, E., Chabrillat, S. y Dematte, J. A. M. (2019). Characterization of soil properties using reflectance spectroscopy. En P. S. Thenkabail, J. G. Lyon y A. Huete (eds.),

- Fundamentals, sensor systems, spectral libraries, and data mining of vegetation* (pp. 187-247). Boca Raton, USA: CRC press.
- Bhargavi, P. y Jyothi, S. (2018). Big data and internet of things for analyzing and designing systems based on hyperspectral images. En K. Prasad (ed.), *Exploring the convergence of big data and the internet of things* (pp. 240-260). Hershey: IGI Global.
- Bioucas-Dias, J. M., Plaza, A., Camps-Valls, G., Scheunders, P., Nasrabadi, N. M. y Chanussot, J. (2013). Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2), 6-36. DOI: 10.1109/MGRS.2013.2244672.
- Borengasser, M., Hungate, W. S. y Watkins, R. (2008). *Hyperspectral remote sensing: principles and applications*. Londres: CRC Press.
- Carmon, N. Y Ben-Dor, E. (2017). An advanced analytical approach for spectral-based modelling of soil properties. *International Journal of Emerging Technology and Advanced Engineering*, 7(3), 90-97.
- Chabrillat, S., Ben-Dor, E., Cierniewski, J., Gómez, C., Schmid, T. y Van Wesemael, B. (2019). Imagen spectroscopy for soil mapping and monitoring. *Survey in Geophysics*, 40, 361-399. DOI: <https://doi.org/10.1007/s10712-019-09524-0>.
- Gutiérrez, S., Fernández-Novales, J., Diago, M. P. y Tardaguila, J. (2018). On-the-go hyperspectral imaging under field conditions and machine learning for the classification of grapevine varieties. *Frontiers in Plant Science*, 9(1102), 1-11. DOI: 10.3389/fpls.2018.01102
- Gutiérrez, S., Tardaguila, J., Fernández-Novales, J. y Diago, M.P. (2016). Data mining and NIR spectroscopy in viticulture: applications for plant phenotyping under field conditions. *Sensors*, 16(236), 1-15. DOI: 10.3390/s16020236.
- He, L., Li, J., Liu, Ch. y Li, Sh. (2018). Recent advances on spectral-spatial hyperspectral image classification: an overview and new guidelines. *IEEE Transactions on Geoscience and Remote Sensing*, 56(3), 1579-1597. DOI: 10.1109/TGRS.2017.2765364.



UNIVERSIDAD DISTRITAL  
FRANCISCO JOSÉ DE CALDAS



- Jensen, J. R. (2005). *Introductory digital imaging processing: a remote sensing perspective*. Nueva York: Pearson Prentice Hall.
- Joyanes, L. (2013). *Big data. Análisis de grandes volúmenes de datos en organizaciones*. Madrid: Alfaomega.
- León, J.C. (2013). Imágenes hiperespectrales (HSI): la nueva generación de los sensores remotos. *Análisis Geográficos*, 51, 49-68.
- León-Pérez, J. (2019). Impacto de las tecnologías disruptivas en la percepción remota: big data, internet de las cosas e inteligencia artificial. *UD y la Geomática*, 14, 54-61. DOI: <https://doi.org/10.14483/23448407.15658>
- Lyer, A. (2018). *The evolution of remote sensing: delivering on the promise of IoT*. Recuperado de <https://www.space-of-innovation.com>
- Middleton, E. M., Huemmrich, K. F., Chen, Y. B. y Margolis, H. A. (2012). Spectral bioindicators of photosynthetic efficiency and vegetation stress. En P. S. Thenkabail, G. J. Lyon y A. Huete (eds.), *Hyperspectral remote sensing of vegetation* (pp. 265-288). Boca Ratón: CRC Press.
- Mitran, T., Meena, R. S. y Chakraborty, A. (2021). *Geospatial technologies for crops and soils*. Singapur: Springer.
- Moreno, R., Corona, F., Lendasse, A., Graña, M. y Galvao, L. S. (2014). Extreme learning machines for soybean classification in remote sensing hyperspectral images. *Neurocomputing*, 128, 207-216.
- Neto, O. C. R., Teixeira, A. S., Leao, L. A. O., Moreira, L. C. J. y Galvao, L. S. (2017). Hyperspectral remote sensing for detecting soil salinization using ProSpectTIR-VS aerial imagery and sensor simulation. *Remote Sensing*, 9(42), 1-16. DOI: 10.3390/rs9010042.
- Nocita, M., Stevens, A., van Wesemael, B., Aitkenhead, M., Bachmann, M., Barthes, M. *et al.* (2015). Soil spectroscopy: an alternative to wet chemistry for soil monitoring. *Advances in Agronomy*, 132, 1-22. DOI: <http://dx.doi.org/10.1016/bs.agron.2015.02.002>.
- Ortenberg, F. (2012). Hyperspectral sensor characteristics: airborne, spaceborne, hand-held, and truck-mounted; integration of hyperspectral data with LIDAR. En P. S.



- Thenkabail, G. J. Lyon y A. Huete (eds.), *Hyperspectral remote sensing of vegetation* (pp. 39-68). Boca Ratón: CRC Press.
- Plaza, A., Plaza, J., Martín, G. y Sánchez, S. (2019). Hyperspectral data processing algorithms. En P. S. Thenkabail, G. J. Lyon y A. Huete (eds.), *Fundamentals, sensor systems, spectral libraries, and data mining for vegetation* (pp. 302-320). Boca Ratón: CRC Press.
- Proctor, C. (2018). Building UAV-hyperspectral system II. Hyperspectral sensor considerations and data processing. En Y. He y Q. Weng (eds.), *High spatial resolution remote sensing: data, analysis, and applications* (pp. 49-70). Boca Ratón: CRC Press.
- Qi, J., Inoue, Y. y Wiangwang, N. (2012). Hyperspectral remote sensing in global change studies. En P. S. Thenkabail, G. J. Lyon y A. Huete (eds.), *Hyperspectral remote sensing of vegetation* (pp. 69-89). Boca Ratón: CRC Press.
- Quian, S. E. (2020). *Hyperspectral satellites and system design*. Boca Ratón: CRC Press.
- Rodríguez-Villamizar, J. (2015). *Sistemas multiespectrales e hiperespectrales para la observación del territorio. Análisis y aplicación a la prospección de hidrocarburos*. [Tesis de pregrado]. Universidad Politécnica de Madrid, Madrid, España. Recuperado de [oa.upm.es/34812/1/PFG\\_JULIAN\\_RODRIGUEZ\\_VILLAMIZAR.pdf](http://oa.upm.es/34812/1/PFG_JULIAN_RODRIGUEZ_VILLAMIZAR.pdf)
- Sandino, J., Pegg, G., González, F. y Smith, G. (2018). Aerial mapping of forests affected by pathogens using UAVs, hyperspectral sensors, and artificial intelligence. *Sensor*, 18, 1-17. DOI: 10.3390/s18040944.
- Schmid, T., Rodríguez-Rastrero, M., Escribano, P., Palacios-Orueta, A., Ben-Dor, E., Plaza, A., Milewski, R., Huesca, M., Bracken, A., Cicuéndez, V., Pelayo, M. y Chabrillat, S. (2016). Characterization of soil erosion indicators using hyperspectral data from a Mediterranean rainfed cultivated region. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(2), 845-860. DOI: 10.1109/JSTARS.2015.2462125.
- Schwab, K. (2016). *The fourth industrial revolution*. Suiza: World Economic Forum.
- Sylvester, G. (2018). *E-Agriculture in action: drones for agriculture*. Bangkok: FAO-ITU.



- Thenkabail, P. S. (2019). Preface. En P. S. Thenkabail, J. G. Lyon y A. Huete (eds.), *Hyperspectral indices and image classification for agriculture and vegetation* (pp. xvii-xx). Boca Ratón: CRC Press.
- Thenkabail, P. S., Lyon, J. G. y Huete, A. (2019). Advances in hyperspectral remote sensing of vegetation and agriculture crops. En P. S. Thenkabail, J. G. Lyon y A. Huete (eds.), *Fundamentals, sensor systems, spectral libraries and data mining for vegetation* (pp. 3-37). Boca Ratón: CRC Press.
- Transon, J., D'Andrimont, R., Maignard, A. y Defourny, P. (2018). Survey of hyperspectral earth observation applications from space in the Sentinel-2 context. *Remote Sensing*, 10(2), 157. DOI: 10.3390/rs10020157.
- Wang, L., Yan, J. y Ma, Y. (2020). *Cloud computing in remote sensing*. Boca Ratón: CRC Press.
- Wu, Z., Sun, J. y Zhang, Y. (2019). Big data processing on cloud computing architecture for hyperspectral remote sensing. En P. S. Thenkabail, J. G. Lyon y A. Huete (eds.), *Hyperspectral indices and image classification for agriculture and vegetation* (pp. 105-132). Boca Raton: CRC Press.
- Xu, S., Wang, M., Shi, X., Yu, Q. y Zhang, Z. (2021). Integrating hyperspectral imaging with machine learning techniques for the high-resolution mapping of soil nitrogen fractions, in soil profiles. *Science of the Total Environment*, 754, 1-16.
- Zaslavsky, A., Perera, Ch. y Georgakopoulos, D. (2012). Sensing as a service and big data. (2012). *Proceeding of the International Conference on Advances in Cloud Computing (ACC)*, 8, 21-29. Recuperado de <https://arxiv.org/ftp/arxiv/papers/1301/1301.0159.pdf>
- Zhong, Y., Wang, X., Xu, Y., Jia, T., Cui, S., Wei, L., Ma, A. y Zhang, L. (2017). Mini UAV borne hyperspectral remote sensing: a review. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 23-28. Fort Worth. DOI: 10.1109/IGARSS.2017.8128354.
- Zou, W., Jiang, W., Chen, G., Lu, Y. y Son, H. (2019). A survey of big data analytics for smart forestry. *IEEE Access*, 7, 46621-46636. DOI: 10.1109/ACCESS.2019.2907999.