

APRENDIZAJE PROFUNDO EN APLICACIONES DE TELEDETECCIÓN AGRÍCOLA

Jason Wolfe
L3Harris Geospatial



INTRODUCCIÓN

El monitoreo preciso y frecuente de la salud y productividad agrícolas es crítico para la seguridad alimentaria y la sostenibilidad económica. Cuando se usa la teledetección como una herramienta para monitorear la agricultura, los análisis deben ser confiables y precisos. La tecnología de aprendizaje profundo ha proporcionado soluciones altamente precisas a problemas geospaciales durante muchos años. Sin embargo, su uso en aplicaciones agrícolas es relativamente nuevo y continúa evolucionando a medida que se realizan más investigaciones. Este documento aborda la pregunta: "¿Qué tipos de problemas de teledetección agrícola se resolverían mejor mediante el aprendizaje profundo?" Describe cómo el aprendizaje profundo es superior a los métodos tradicionales de aprendizaje automático para encontrar patrones espaciales en el uso de la tierra y las regiones agrícolas, a expensas de una cantidad significativamente mayor de datos de capacitación. El documento explora aplicaciones comunes donde se utiliza el aprendizaje profundo en la agricultura. El enfoque aquí está en observaciones remotas desde imágenes satelitales y aéreas, en lugar de observaciones a nivel de hoja o fruta.

APRENDIZAJE PROFUNDO Y APRENDIZAJE AUTOMÁTICO EN LA TELEDETECCIÓN

Las imágenes teledetectadas son un recurso valioso para monitorear las prácticas agrícolas en todo el mundo. En la era de la "big data", los satélites de observación de la Tierra se están lanzando a un ritmo récord, y los consumidores tienen acceso a imágenes que abarcan todo el mundo con tasas de visitas más frecuentes. Para la clasificación del uso de la tierra y la extracción de entidades, el aprendizaje profundo ha recibido mucha atención en los últimos años por su potencial para producir resultados altamente precisos. Sin embargo, es importante comprender la naturaleza del aprendizaje profundo para determinar qué tipos de problemas puede resolver y dónde puede ser más útil.

El aprendizaje profundo es un subcampo del aprendizaje automático, en el que los sistemas informáticos aprenden tareas e identifican patrones por sí mismos con solo datos de capacitación limitados. Lo que diferencia el aprendizaje profundo del aprendizaje automático es su capacidad para mejorar continuamente una predicción por sí solo sin orientación o intervención externa. Los algoritmos de aprendizaje profundo aprenden patrones progresando a través de una serie de capas en una red neural para sacar conclusiones.

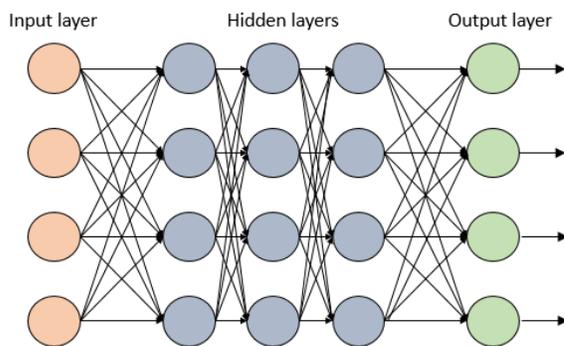
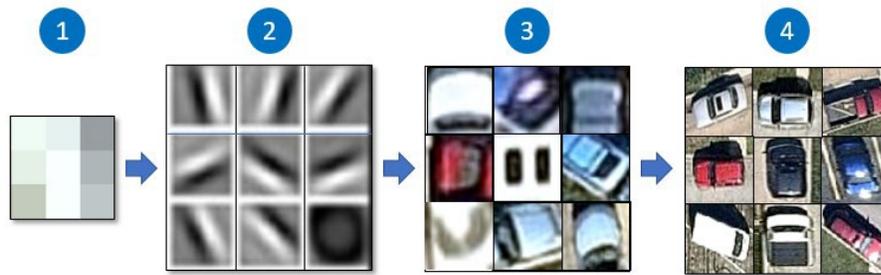


Diagrama de una profunda red neural.

El módulo ENVI Deep Learning funciona con TensorFlow, que se basa en una red neural convolucional (CNN). Una CNN utiliza una red neural "profunda" para extraer entidades complejas de los datos de manera jerárquica. Comienza aprendiendo patrones espaciales (como bordes) a un nivel bajo, luego extrae entidades más complejas a medida que el modelo avanza a través de capas más profundas de datos.

Aquí hay un ejemplo simple de cómo difieren el aprendizaje automático y el aprendizaje profundo: un algoritmo de aprendizaje automático puede identificar diferentes colores de vehículos en imágenes de alta resolución basado en los valores de píxeles. Sin embargo, un algoritmo de aprendizaje profundo va un paso más allá y no sólo identifica diferentes colores, sino también diferentes formas y tamaños de vehículos. Lo hace porque los datos de capacitación proporcionan información contextual, lo que significa que el algoritmo obtiene información espacial no sólo de cada píxel, sino también de sus píxeles vecinos. Por lo tanto, el aprendizaje profundo es ideal para resolver problemas espaciales.

La siguiente imagen muestra un ejemplo de cómo los algoritmos de aprendizaje profundo se presentan inicialmente con imágenes etiquetadas formadas por píxeles simples (Paso 1). Luego, descubren regularidades simples que están presentes en muchas o todas las imágenes (Paso 2). Descubren cómo se relacionan las regularidades para formar conceptos de nivel superior (Paso 3). Finalmente, el sistema obtiene una comprensión de alto nivel de la entidad objetivo (Paso 4).



Representación jerárquica de cómo los algoritmos de aprendizaje profundo aprenden entidades, utilizando los automóviles como ejemplo.

El aprendizaje profundo funciona mejor con imágenes de teledetección que tienen una alta resolución espacial porque proporcionan más detalles y entidades espaciales más ricas. Los algoritmos de aprendizaje profundo no tienden a funcionar tan bien con imágenes de resolución media (10 a 30 metros) debido a la falta de detalles finos (Ma et al., 2019). Los sensores de vehículos aéreos no tripulados (UAV) son ideales para aplicaciones de aprendizaje profundo debido a su alta resolución espacial (Oghaz et al., 2019).

Al mismo tiempo, una resolución demasiado alta puede generar tiempos de procesamiento más largos. Por ejemplo, los datos de 7,5 centímetros tardan cuatro veces más en procesarse que los datos de 15 centímetros, y tienen cuatro veces el volumen de datos. Determinar la mejor resolución implica un balance entre la velocidad de procesamiento y tener suficiente información contextual para ubicar las entidades. La siguiente sección explora casos de uso agrícola que pueden beneficiarse del aprendizaje profundo.

APLICACIONES EN AGRICULTURA

Aunque la tecnología de aprendizaje profundo ha existido durante décadas, su uso entre los usuarios novatos de teledetección aún es relativamente nuevo. Ma y col. (2019) completaron una extensa encuesta de estudios de aprendizaje profundo en teledetección y observaron que la comunidad se ha movido cada vez más hacia las aplicaciones de aprendizaje profundo desde 2014. Kamilaris y Prenafeta-Boldú (2018) completaron una encuesta similar de aplicaciones de aprendizaje profundo en la agricultura. De los muchos usos documentados del aprendizaje profundo en la agricultura, algunos parecen ser de particular interés para los consumidores de imágenes de teledetección. Estas aplicaciones se describen en las secciones que siguen.

Clasificación de las categorías de uso de la tierra y los tipos de cultivos

La clasificación del uso de la tierra y los tipos de cultivos puede beneficiarse del aprendizaje automático y los métodos de aprendizaje profundo. Debido a que los algoritmos del aprendizaje profundo pueden aprender patrones espaciales complejos en las imágenes teledetectadas, al tiempo que explican los cambios en la iluminación solar, la rotación y el tamaño, pueden potencialmente arrojar resultados de clasificación mucho más altos que los métodos tradicionales de aprendizaje automático. Su éxito depende del tamaño y la calidad del conjunto de datos de capacitación (Kamilaris y Prenafeta-Boldú, 2018). La precisión de los clasificadores de uso de suelo del aprendizaje profundo depende en gran medida del número de clases, así como de la distinción espectral y espacial entre las clases (Ma et al., 2018).

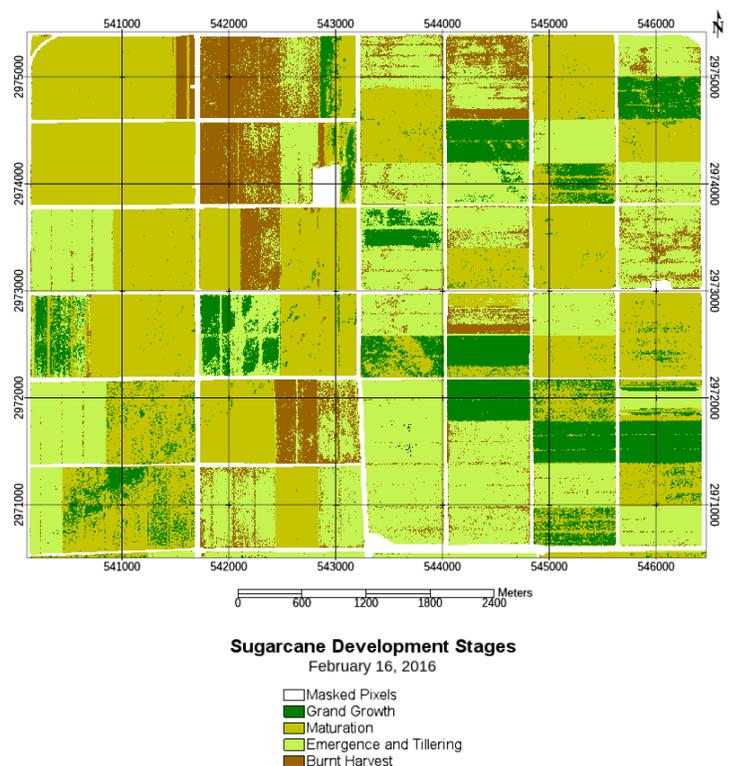
Mahdianpari y col. (2018) informaron precisiones de clasificación de 93.57% a 96.17% para tres algoritmos basados en CNN, y Ndikumana et al. (2019) informaron una puntuación F de 0,96 para una red neural recurrente profunda (RNN). Sin embargo, ambos estudios utilizaron una gran cantidad de datos de capacitación. Esta es la diferencia clave entre los clasificadores de aprendizaje automático y aprendizaje profundo: los clasificadores supervisados de aprendizaje profundo requieren docenas, o incluso cientos de imágenes de capacitación para obtener los mejores resultados.

Por el contrario, los clasificadores de aprendizaje automático como K Nearest Neighbour (KNN), Support Vector Machine (SVM) y Random Forest (RF) generalmente dependen de una o unas pocas imágenes de entrada y solo un puñado de regiones de interés (ROI) para datos de capacitación. Por lo tanto, son más rápidos de capacitar que los clasificadores de aprendizaje profundo, aunque se sabe que SVM consume mucha memoria del sistema con imágenes grandes (Kussel et al., 2017). Mientras que los clasificadores de aprendizaje automático a menudo producen resultados de clasificación precisos, se basan solo en información espectral e ignoran la información espacial y temporal (Castro et al., 2017; Ndikumana et al., 2018). No pueden identificar con eficacia patrones espaciales o trabajar con datos de series temporales.

La siguiente imagen muestra un ejemplo de una imagen de clasificación SVM de diferentes etapas del desarrollo de la caña de azúcar. El uso del aprendizaje profundo para esta investigación requeriría docenas de imágenes de capacitación durante una temporada de crecimiento.

Para discriminar especies de vegetación o tipos de cultivos, el consenso general es que se necesitan datos de capacitación durante la temporada de crecimiento (Castro et al., 2017; Kussel et al., 2017). Tener una serie temporal de imágenes consistente y frecuente puede proporcionar información sobre los ciclos fenológicos de las plantas, lo cual es esencial para discriminar entre ellas y monitorear sus tasas de crecimiento. Recopilar datos de múltiples fuentes, como el radar de apertura óptica y sintética (SAR) puede mejorar aún más la precisión de la clasificación.

En resumen, el aprendizaje profundo ha demostrado lograr resultados de clasificación de uso del suelo altamente precisos en algunos estudios como Mahdianpari et al. (2018) y Ndikumana et al. (2019) Sin embargo, esos estudios requirieron muchos más datos de capacitación en comparación con los clasificadores supervisados tradicionales. Con los tipos de cultivos en particular, las imágenes de capacitación deben abarcar múltiples fechas durante la temporada de crecimiento.



Mapa de clasificación SVM de las etapas de desarrollo de la caña de azúcar (Wolfe, 2017).

Finalmente, las imágenes de alta resolución a menudo producirán los resultados más precisos con clasificadores de aprendizaje profundo. Cuando se utilizan imágenes de capacitación de resolución media (10 a 30 metros), el proceso de identificación y etiquetado de entidades puede ser un desafío, ya que las entidades pueden ser difíciles de discernir. Esto introduce el riesgo de proporcionar datos de capacitación incorrectos, lo que puede resultar en píxeles mal clasificados y predicciones inexactas. El uso de imágenes de alta resolución para la capacitación revelará de manera más efectiva las entidades espaciales, que son esenciales para una clasificación precisa de los cultivos (Peña-Barragán et al., 2011).

Identificación y mapeo de malezas

La presencia de malezas puede contribuir a la disminución de los rendimientos de los cultivos, y se necesita un monitoreo regular para controlar su crecimiento. Aplicar la misma tasa de herbicida a un campo completo puede generar desechos y costarles más dinero a los agricultores, además de crear contaminación ambiental (Bah et al., 2018). La combinación de análisis de imágenes a partir de imágenes UAV con agricultura de precisión puede ayudar a los agrónomos a asesorar a los agricultores sobre dónde dirigir los herbicidas a ubicaciones específicas en el campo. La agricultura de precisión es una práctica que se basa en sistemas de posicionamiento global (GPS) y sensores remotos o in situ para proporcionar información detallada sobre la salud de los cultivos y el suelo, para que los productores puedan garantizar una productividad óptima dentro de los campos.

El aprendizaje profundo proporciona una solución práctica para identificar malezas en campos a partir de imágenes de UAV. Bah y col. (2018), Huang et al. (2018), y Sa et al. (2018) son ejemplos de estudios que siguieron este enfoque. Otros estudios como Dyrmann et al. (2016) y Olsen et al. (2018) utilizaron el aprendizaje profundo para clasificar las malezas a nivel de la hoja o del suelo. Esto puede ser útil para reconocer y prevenir el crecimiento de moho, podredumbre de las hojas y daño por insectos.

Los cultivos y las malezas son espectralmente similares, y a menudo se ven idénticos en color cuando se ven imágenes de color verdadero o falso (siguiente imagen). Los algoritmos de aprendizaje profundo pueden detectar diferencias sutiles en sus formas y patrones.

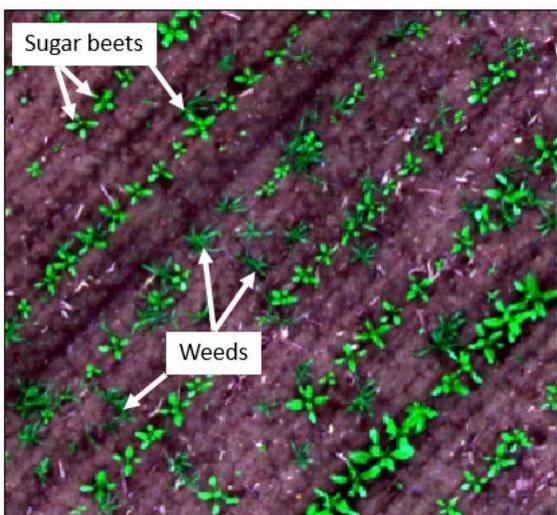


Imagen UAV de plantas y malezas de remolacha azucarera, de Sa et al. (2018) Conjunto de datos disponible en

<https://projects.asl.ethz.ch/datasets/doku.php?id=weedmap:re-motesensing2018weedmap>

Identificación de patrones de campo irregulares

Dado que las CNN aprenden a identificar diferentes patrones espaciales a partir de imágenes, proporcionan una solución ideal para ubicar campos agrícolas con formas irregulares, como campos de riego de pivote central, granjas pequeñas con bordes confusos y campos que contienen cultivos ilícitos de drogas.

Campos circulares

Los campos circulares que se riegan mediante sistemas de pivote central son populares en todo Estados Unidos, pero son especialmente frecuentes en el este de Colorado, Kansas y Nebraska. Aunque incurren en costos de mano de obra más bajos que los métodos de riego subterráneo, recurren al agua subterránea en acuíferos bajo la tierra. Los investigadores han estado monitoreando las tierras de cultivo irrigadas a partir de imágenes satelitales durante décadas, en parte para predecir los niveles de consumo de agua a lo largo del tiempo. Si bien las tierras de cultivo de regadío son fáciles de identificar en imágenes satelitales que contienen una banda de infrarrojo cercano, utilizando un índice de vegetación como NDVI, las formas distintas, como los campos circulares, son más difíciles de identificar utilizando herramientas automatizadas.

La siguiente imagen muestra un ejemplo del uso de ENVI Deep Learning para identificar campos circulares en una imagen multispectral.

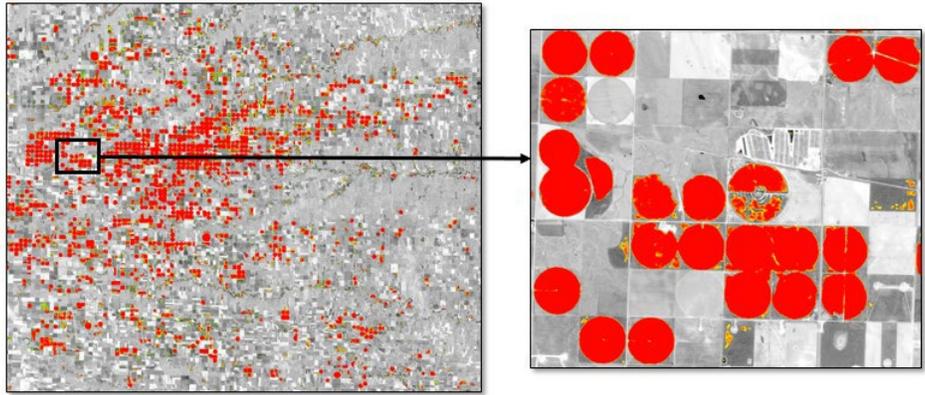


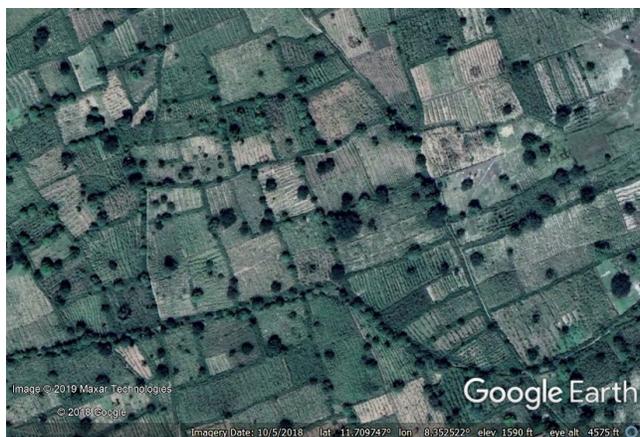
Imagen de clasificación de campos de riego circulares a partir de una imagen multispectral Sentinel-2 del oeste de Kansas, creada con ENVI Deep Learning.

Pequeñas granjas

El aprendizaje profundo puede ayudar a delimitar los campos agrícolas de los tipos de uso de tierra circundantes en imágenes satelitales, particularmente en países subtropicales cuyas prácticas agrícolas están menos reguladas por el gobierno. Tener mapas precisos de los tipos de cultivo y de la superficie es una parte importante de los sistemas de monitoreo agrícola. Son esenciales para garantizar la seguridad alimentaria en algunas regiones y países (Aguilar et al., 2018; Persello et al., 2019). En los Estados Unidos y algunos países de la Unión Europea, las actividades agrícolas están altamente reguladas por el gobierno. Esto incluye documentación de tipos de cultivos y producción bruta. El Departamento de Agricultura de los EE. UU. (USDA), por ejemplo, publica mapas de tipos de cultivos en todo EE. UU.

En algunas partes de África, sin embargo, gran parte de la información espacial sobre los campos agrícolas está incompleta o no está disponible. Esto se debe principalmente a la proliferación de pequeñas granjas, que se definen como parcelas de menos de 2 hectáreas. Dominan el paisaje agrícola en África y contribuyen a alrededor del 75% de la producción agrícola allí (Nyambo, Luhanga y Yonah, 2019).

El mapeo de las granjas pequeñas es un desafío porque tienen límites confusos, a menudo se mezclan con otros tipos de uso de tierra, y sus tamaños y tipos de cultivos pueden variar ampliamente dentro de una temporada determinada (siguiente imagen).



Granjas pequeñas al norte de Nigeria.

Persello y col. (2019) utilizaron métodos de segmentación de aprendizaje profundo para estimar los límites de las granjas pequeñas en dos áreas de estudio en África. Señalaron que los límites del campo no tenían bordes claramente visibles en las imágenes satelitales de alta resolución y que los límites debían extraerse mediante la detección de cambios sutiles en la textura y los patrones espectrales.

Finalmente, el aprendizaje profundo se puede utilizar para localizar campos donde se cultivan y cosechan cultivos ilícitos, como Cannabis salva. Un estudio de ejemplo es Ferreira et al. (2019) A menudo, estos cultivos se mezclan con cultivos legales para disfrazarlos.

CONCLUSIONES

Si bien el aprendizaje profundo aún está evolucionando en las aplicaciones de teledetección para la agricultura, algunos resultados consistentes han surgido de estudios recientes. Con respecto al uso de la tierra y la clasificación de los cultivos, se pueden lograr resultados precisos utilizando una gran cantidad de imágenes de capacitación de alta resolución, que preferiblemente abarquen varias fechas durante la temporada de crecimiento. Esto se debe a que los algoritmos de aprendizaje profundo consideran el elemento temporal de los datos, junto con el espacial y el espectral.

Si la aplicación agrícola solo considera información espectral de píxeles, los algoritmos de aprendizaje automático como Random Forest (RF) y Support Vector Machine (SVM) continuarán proporcionando una solución rápida y eficiente para la extracción o clasificación de entidades. El aprendizaje profundo no ofrecerá ningún beneficio adicional. Sin embargo, cuando la aplicación involucra un componente espacial, como ubicar campos con patrones irregulares o mapear malezas que son espectralmente similares a los cultivos, entonces el aprendizaje profundo indudablemente proporciona una solución precisa.

Finalmente, este documento sólo discutió el uso de imágenes ópticas; sin embargo, las imágenes de múltiples tipos de sensores (como LiDAR y SAR) pueden hacer que los algoritmos de aprendizaje profundo sean más robustos y adecuados para una gama más amplia de aplicaciones agrícolas.

Si te interesó esta información y deseas conocer más,

▶ Contáctanos

Telf: 208-0400 / 995-007-216 / 959-352-284

Pj. 4 Nro. 0127 Int. 303 Urb. Corpac Lima - San Isidro

www.telematica.com.pe / info@telematica.com.pe

   / [telematicaperu](https://www.facebook.com/telematicaperu)

