

Métodos de Inteligencia Artificial para la Predicción de Componentes Químicos a partir de Imágenes Hiperespectrales

Alberto Velasco-Mata, Noelia Vallez, Jesus Ruiz-Santaquiteria, Anibal Pedraza, Gloria Bueno, Oscar Deniz VISILAB, ETS Ingeniería Industrial, Avda. Camilo José Cela 3, 13071, Ciudad Real. email: Alberto.Velasco@uclm.es

Resumen

La automatización del análisis de los parámetros del suelo puede optimizar los procesos de fertilización, reduciendo el tiempo y los costes de la producción alimentaria, contribuyendo al objetivo de conseguir una agricultura sostenible. El trabajo que se presenta en este artículo es parte del HYPERVIEW Challenge: Seeing Beyond the Visible, en el cual se proporcionan imágenes hiperespectrales de varios terrenos y se pretende lograr una estimación de varios parámetros característicos de los mismos a partir de ellas. Se propone la utilización de métodos basados tanto en enfoques tradicionales (SVR, k-NN), como en técnicas modernas como las redes neuronales. Además, se propone la combinación de ambos para aprovechar todas las ventajas de cada uno. Adicionalmente, se aplica una fase de preprocesado parametrizada para tratar la variabilidad del tamaño de los datos de entrada, dado que las imágenes del terreno no tienen las mismas dimensiones en todos los casos. Finalmente, la mejor estimación se ha conseguido aplicando un modelo basado en k-NN.

Palabras clave: Hiperespectral, inteligencia artificial, aprendizaje profundo.

1. INTRODUCCIÓN

En los últimos años, el análisis del terreno mediante su observación desde el espacio se ha convertido en un tema de gran relevancia en la agricultura sostenible [8]. La información acerca del estado del suelo y sus parámetros (concentración de alguna sustancia) ayuda a los agricultores a conseguir una mejora en su trabajo, optimizando los procesos relacionados con la fertilización mediante la correcta elección del tipo y de la cantidad de fertilizante que deben utilizar. Esto permite una reducción en los costes de la producción de alimentos y la cantidad de fertilizantes químicos utilizados, avanzando hacia una agricultura más respetuosa con el planeta.

La cuantificación de los parámetros del suelo suele ser un proceso manual, complejo e ineficiente en

términos de tiempo, ya que requiere la recogida y el análisis de varias muestras del terreno. Sin embargo, los satélites actuales disponen de tecnología basada en imagen hiperespectral que puede ser combinada con técnicas de análisis de datos para automatizar el proceso de extracción de parámetros del suelo [4, 6, 1]. El trabajo presentado en este artículo propone la utilización de algunos algoritmos que podrían conseguir una mejora en el análisis automático de dichos parámetros respecto a los métodos existentes en el estado del arte que han sido aplicados a este ámbito. Este trabajo se encuentra enmarcado en el *HYPERVIEW Challenge* creado por KP Labs, la Agencia Espacial Europea y QZ Solutions.

La idea de medir los parámetros del suelo a través de imagen de espectrografía no es nueva. Ya en 2006 hubo otro concurso con un objetivo similar [5]. En ese caso los parámetros a estimar fueron la cantidad de nitrógeno, la capacidad de intercambio catiónico y el porcentaje de carbono del suelo. Se seleccionaron 618 bandas espectrales entre 1100 y 2498 nm con un intervalo de 2 nm. Los resultados del concurso no fueron muy buenos. Los organizadores argumentaron que el problema era bastante difícil y que el dataset no era lo suficientemente grande. Entre las técnicas empleadas por los participantes se encontraban máquinas de vectores de soporte, redes neuronales artificiales y regresión local.

En el trabajo presentado en [2] se utilizó una red neuronal para estimar 30 parámetros incluyendo la cantidad de carbono orgánico, el pH y las trazas de varios minerales entre otros. Los resultados de los modelos predijeron con gran precisión el contenido de materia orgánica, Mg, Ca, Ni, saturación total de cationes y pH, entre otros.

En [7] los autores estudian la predicción de ciertos parámetros del suelo utilizando las bandas entre 350 y 15000 nm. El estudio se llevó a cabo en Alemania y el análisis químico proporcionó información sobre el contenido total de carbono orgánico del suelo (CTC) y el valor de pH, así como las concentraciones de elementos (Al, As, Ca, Cu, Fe, K, Mn, Na, Ni, Pb, Zn). El método de regresión empleado fue la regresión de mínimos cuadrados

parciales (en inglés PLSR). Se obtuvieron resultados prometedores del modelo para CTC, Al, Fe, K y Ni con valores de R^2 entre 0,70 y 0,88 pero no fueron tan buenos para el resto.

En la misma línea de trabajo se utilizaron clasificadores de bosques aleatorios para cuantificar los parámetros del suelo a través de espectrografía tanto visible como en el infrarrojo cercano [3]. Los resultados demostraron ser mejores que el empleo de la regresión de mínimos cuadrados.

2. CONJUNTO DE DATOS

Los métodos propuestos se han aplicado sobre los datos proporcionados por los organizadores de *HYPERVIEW Challenge*. El conjunto de datos consta de un total de 2886 imágenes hiperespectrales de terrenos en regiones agrícolas de Polonia. Cada imagen contiene 150 bandas hiperespectrales contiguas que van desde los 462nm hasta los 942nm, correspondientes al rango espectral del sensor desplegado a bordo del satélite Intuition-1. Cada recorte del terreno incluye una máscara con la región de interés cuyos parámetros deben ser analizados. Un ejemplo de las imágenes proporcionadas puede verse en la Figura 1. En cada imagen, cada píxel corresponde a una región de $2 \times 2m^2$ del suelo capturado.




Figura 1: Banda número 100 de una de las imágenes. Izquierda: imagen completa, derecha: máscara.

Un subconjunto de 1732 regiones está etiquetado con sus correspondientes parámetros del terreno: potasio (K), pentóxido de fósforo (P_2O_5), magnesio (Mg) y pH . Las etiquetas asociadas al resto de las regiones del conjunto de datos están reservadas para obtener la clasificación final del reto en el que se enmarca este trabajo, siendo solo accesibles por los organizadores.

En la Tabla 1 puede verse el rango de valores que toma cada uno de los parámetros utilizados para caracterizar las regiones del terreno, teniendo en cuenta únicamente las etiquetas proporcionadas a los participantes.

Cuadro 1: Rango de valores de los parámetros

Param.	Media	Dev. Est.	Mín	Máx
P_2O_5	70,303	29,505	20,3	325
K	227,989	61,892	21,1	625
Mg	159,281	39,872	26,8	400
pH	6,783	0,26	5,6	7,8

2.1. PREPROCESADO DE LOS DATOS

El tamaño de las imágenes varía entre 11×11 y 132×284 píxeles. Por ello, ha sido necesario implementar algoritmos de preprocesado que manejen las diversas dimensiones de entrada de las imágenes y las normalice a una matriz numérica de un tamaño fijo determinado. El método aplicado para ello se basa en la fusión de bloques de datos aplicando una combinación de funciones específicas como la media, el máximo o el mínimo. De esta manera, la imagen original es dividida por filas, columnas o en cuadrícula, obteniendo bloques o secciones de la región hiperespectral. Seguidamente, se aplican una o varias funciones para combinar todos los píxeles correspondientes a cada bloque en un solo vector de 150 dimensiones, que contiene la información de las 150 longitudes de onda en dicho bloque. Por tanto, la aplicación de este preproceso da lugar a una matriz con esta forma: $N_{filas} \times M_{columnas} \times P_{funciones\ aplicadas} \times 150_{bandas\ hiperespectrales}$. Por ejemplo, el preprocesado de una imagen con 1 fila, 1 columna y solo la *media* como función de combinación, genera como resultado un vector de 150 elementos representando la media de todos los píxeles a lo largo de cada banda hiperespectral. El preprocesado de una imagen con 11 filas, 11 columnas y las funciones de media, máximo y mínimo da como resultado una matriz de $11 \times 11 \times 3 \times 150$.

De esta forma, los datos originales han sido normalizados antes de aplicar los métodos propuestos, consiguiendo una dimensionalidad uniforme para todo el conjunto de datos, extrayendo información útil de las regiones del terreno, lo que permite descartar valores atípicos que hayan podido aparecer debido al ruido del proceso de captura de las mismas, o incluso a irregularidades del terreno que sean irrelevantes de cara a su análisis. Dado que esta etapa de preprocesado viene parametrizada por las filas, columnas y funciones de combinación aplicadas, los métodos propuestos han sido probados con distintas variaciones del preprocesado.

2.2. TÉCNICAS DE AUMENTO DE DATOS

Como el problema que se aborda en este trabajo es una regresión, sólo hay una región hiperespectral

por cada combinación específica de parámetros del terreno. Por lo tanto, aplicar técnicas de aumento de datos es útil y necesario para obtener variaciones de las regiones durante la fase de entrenamiento del modelo, evitando que acabe resultando en un sobreajuste a las imágenes disponibles. Debido a la alta variabilidad en el tamaño de las imágenes y a que parte de ellas tienen un tamaño muy grande respecto a la imagen más pequeña (11×11), pueden generarse subregiones de las mismas para conseguir un volumen de datos mayor. Para ello, se asume que los parámetros globales de una región del terreno son similares a los parámetros que caracterizan una subregión de la misma. Por tanto, las imágenes originales han sido divididas en imágenes de menor tamaño, aplicando una ventana deslizante y consiguiendo múltiples subregiones de la imagen. En este punto es necesario recordar que las imágenes originales tienen una máscara asociada que descarta algunos píxeles de la imagen. Para evitar que la aplicación de esta técnica genere imágenes no válidas, se han descartado todas aquellas subregiones que contengan más de un 40% de píxeles enmascarados.

Este proceso de aumento de datos permite mejorar la robustez de los métodos propuestos, consiguiendo que generalicen el resultado proporcionado en lugar de sobreajustarse a los datos del entrenamiento. Por otro lado, la aplicación de la ventana deslizante evita que los métodos se centren en píxeles o subregiones concretas que tengan valores atípicos en alguna banda hiperespectral.

3. MÉTODOS PROPUESTOS

Se han propuesto diversos métodos, considerando tanto las técnicas clásicas y tradicionales de regresión numérica como modelos más actuales basados en redes neuronales.

3.1. MÉTODOS CLÁSICOS

Se han implementado dos modelos basados en técnicas tradicionales para obtener los parámetros del terreno deseados. Ambos han sido probados con diferentes configuraciones de la fase de preprocesado, cambiando las funciones de combinación aplicadas, así como los tamaños y formas de los bloques.

3.1.1. Regresión de Vectores de Soporte

Regresión de Vectores de Soporte ó SVR (Support Vector Regression) es una variante de las clásicas Máquinas de Vectores de Soporte (Support Vector Machines), adaptadas como un modelo de regresión para predecir valores con una determinada tolerancia al error en lugar de realizar una clasifi-

cación de los datos. En este caso, se ha entrenado un modelo basado en SVR para cada parámetro del terreno, considerando como entrada el vector aplanado obtenido de la fase de preprocesado.

3.1.2. k Vecinos más Cercanos (k-NN)

De forma similar a la propuesta anterior, se ha entrenado un modelo por parámetro. En este caso, el valor resultante se obtiene interpolando las muestras más cercanas en el espacio latente representado por los vectores preprocesados. La distancia afecta al resultado obtenido, de manera que las muestras más cercanas tienen mayor influencia sobre el parámetro de salida que aquellas que están más alejadas.

3.2. MÉTODOS BASADOS EN REDES NEURONALES

3.2.1. Redes Neuronales Convolucionales


Se ha entrenado una red neuronal convolucional (CNN, Convolutional Neural Network) con las imágenes hiperespectrales proporcionadas. En este caso, en lugar de aplicar el preproceso mencionado anteriormente, las imágenes originales han sido redimensionadas a un tamaño de 128×128 aplicando un método de remuestreo según el píxel más cercano para evitar introducir valores que no estaban presentes en la imagen. Además, el tamaño elegido permite mantener en mayor medida la información de las imágenes originales, a pesar de duplicar los valores en el caso de las imágenes de menor tamaño. La salida de la red es un vector con los 4 parámetros de suelo que fueron etiquetados para cada región. Los parámetros de entrenamiento utilizados fueron: tasa de aprendizaje = $1e^{-3}$, tamaño del lote = 32 y función de pérdida = "porcentaje de Error Medio Absoluto". En la Tabla 2 se muestra la arquitectura de la red.

3.2.2. Redes Neuronales Completamente Conectadas

Se ha implementado una arquitectura neuronal basada en capas completamente conectadas, de manera que se obtengan los parámetros del terreno convergiendo previamente a una representación intermedia para cada bloque preprocesado. Teniendo en cuenta las matrices procesadas detalladas en la Sección 2.1, el modelo reduce en primer lugar los 150 canales a cuatro valores, manteniendo la forma de los bloques con la subregiones, como se muestra en la Figura 2. Si la matriz procesada consta de 11 filas, 11 columnas y 150 valores por bloque, el modelo trata de obtener 4 valores por bloque, resultando en una matriz intermedia de $11 \times 11 \times 4$. Esta representación intermedia es

Cuadro 2: Arquitectura CNN

Capa	Tamaño
input_1	(128, 128, 150)
conv2d	(128, 128, 16)
activation	(128, 128, 16)
batch_normalization	(128, 128, 16)
max_pooling2d	(64, 64, 16)
conv2d_1	(64, 64, 32)
activation_1	(64, 64, 32)
batch_normalization_1	(64, 64, 32)
max_pooling2d_1	(32, 32, 32)
conv2d_2	(32, 32, 64)
activation_2	(32, 32, 64)
batch_normalization_2	(32, 32, 64)
max_pooling2d_2	(16, 16, 64)
flatten	(16384)
dense	(16)
activation_3	(16)
batch_normalization_3	(16)
dropout	(16)
dense_1	(8)
activation_4	(8)
dense_2	(4)



posteriormente aplanada y procesada por más capas completamente conectadas que resultan en la estimación de los 4 parámetros del terreno.

Esta arquitectura ha sido entrenada de dos formas distintas. En el primer caso, la representación intermedia es libre, delegando la extracción del espacio latente representativo al propio proceso de entrenamiento de la red. Los únicos datos que se le proporcionan durante el entrenamiento son las imágenes preprocesadas como entrada, y los parámetros del terreno como salida. En el segundo caso, para tratar de forzar un espacio latente representativo de cara a la extracción de características relevantes para la estimación de los parámetros finales, se ha optado por proporcionar los etiquetados en dos puntos de la red: tanto en la representación intermedia, como en la salida final. Este proceso se ha implementado replicando el vector de parámetros tantas veces como bloques hay en la representación intermedia, de forma que la red puede contemplarse como la integración de dos subredes: la primera se encarga de la extracción de los 4 parámetros a nivel de bloque (según se haya realizado la agrupación en cuadrícula del preprocesado), y la segunda es responsable de la combinación de los parámetros estimados para todos los sub-bloques en un único vector final.

Figura 2: Esquema conceptual de la arquitectura propuesta basada en capas completamente conectadas

3.3. COMBINACIÓN DE MÉTODOS CLÁSICOS Y REDES NEURONALES

Por último, se propone otra arquitectura que combina los conceptos fundamentales de los dos métodos anteriores. Teniendo en cuenta que los modelos clásicos usan la matriz preprocesada para obtener los valores resultantes dependiendo de la distancia a las muestras del conjunto de entrenamiento, y que los modelos basados en redes neuronales obtienen una representación latente intermedia de los datos, se ha propuesto una arquitectura que aprovecha esta representación latente utilizándola como datos de entrada para los métodos clásicos. Así, la información útil de las imágenes que ha sido proyectada en el espacio latente debería dar lugar a un resultado mejor que con los modelos tradicionales basados en la distancia. Conceptual-

mente, se está utilizando la red neuronal como un codificador, y seguidamente se aplican los métodos clásicos de forma similar a como se hacía con las matrices preprocesadas.

4. RESULTADOS

Dado que solo se dispone de las etiquetas de un subconjunto de datos proporcionado por los organizadores del reto, ha sido necesario volver a dividir ese subconjunto para reservar un pequeño porcentaje de imágenes que permitan obtener algunas métricas de rendimiento de los modelos propuestos de forma local. Esto da lugar a que se disponga de dos mediciones del funcionamiento de los modelos, una de ellas correspondiente a esa partición de los datos disponibles, y otra correspondiente al resultado proporcionado por la plataforma del reto que utiliza los datos que solo los organizadores conocen.

Además, es importante destacar que las métricas obtenidas no son absolutas sino que, debido a las condiciones del reto, se calculan respecto a un algoritmo de referencia proporcionado por los organizadores, el cual simplemente calcula la media de los parámetros de suelo de todas las imágenes, y devuelve ese valor independientemente de las nuevas imágenes que se utilicen en la fase de predicción. Por tanto, la puntuación de cada método es un valor relativo a ese algoritmo base, de manera que aquellos valores menores que 1 suponen una mejora respecto al mismo, y se considera que los métodos propuestos son mejores cuanto más se acercan a 0.

En la Tabla 3 se muestra una comparativa con los resultados obtenidos con distintas variaciones de los modelos aplicados. Durante el desarrollo del reto, se han considerado dos puntuaciones estimadas, así como la puntuación oficial obtenida según la plataforma del reto, la cual solo se ha obtenido para aquellos modelos suficientemente buenos, debido a las limitaciones definidas por los organizadores en cuanto al número de envíos (intentos) por día. La primera puntuación estimada se ha calculado utilizando la partición de datos reservada localmente. Sin embargo, y dado que las diferencias entre métodos no se correspondían con la puntuación oficial, se ha calculado otra estimación utilizando todos los datos disponibles, incluyendo los utilizados durante la fase de entrenamiento. Esta segunda estimación sí que se aproxima más a la puntuación oficial, lo cual denota que el conjunto reservado por los organizadores podría ser similar al que proporcionan etiquetado.

La tabla muestra la progresión que se ha conseguido, condicionada por los resultados previos. De es-

ta manera, con la aplicación inicial del SVR se observó que la división en cuadrícula de la imágenes del terreno daba lugar a un error menor al estimar los parámetros. La división en bloques horizontales o verticales (Grid-11x1 y Grid-1x11, respectivamente) obtenía un peor resultado. Esto podría deberse a la constitución del terreno, dando lugar a que valores atípicos afectasen al vector obtenido para cada fila o columna. Debido a esto, el preproceso en cuadrícula se determinó como predominante, dado que conserva mejor las propiedades espaciales de la imagen.

Seguidamente, en la aplicación del k-NN se realizaron pruebas con un número variado de vecinos más cercanos. En este caso, se utilizó un preproceso en cuadrícula de 11×11 bloques, debido a que este es el tamaño más pequeño de las imágenes de entrada, por lo que un tamaño de cuadrícula superior daría lugar a bloques vacíos que no aportarían información. Con la exploración de este método, se determinó que los parámetros del terreno se estimaban mejor cuando se utilizan los 20 vecinos más cercanos para calcularlos. Además, la adición del mínimo y máximo a las funciones de combinación de los bloques provocó una ligera mejora en la estimación.

En el caso de la red neuronal convolucional, el resultado obtenido quedaba lejos de mejorar a los métodos clásicos. Esto podría deberse al tamaño de los píxeles respecto al terreno, ya que representan $4m^2$ del mismo. Las imágenes por tanto no aparentan tener una información espacial que sea muy relevante en cuanto a bordes, formas y gradientes que sirvan para determinar los parámetros del terreno, provocando que las convoluciones no sean de gran utilidad.

Las redes neuronales completamente conectadas tampoco proporcionan un resultado óptimo, aunque sí es destacable el hecho de que la estimación mejora cuando se fuerza al modelo a aprender los parámetros para cada bloque, en lugar de delegar el aprendizaje del espacio latente al modelo. Al forzar que el espacio latente aprendido tenga relación con la estimación de los parámetros, se consigue que ese vector intermedio junto con el k vecino más cercano superen a algunos de los métodos tradicionales. Sin embargo, la combinación de ambos no consigue superar al método basado en k-NN por sí solo. A pesar de ello, el método híbrido consigue una mejor estimación partiendo de un preproceso que utiliza solamente la media como función de agregación, a diferencia del k-NN que lograba una mejora cuando se incluían el mínimo y el máximo.

Teniendo en cuenta todo lo anterior, el método basado en k-NN ha resultado ser el que consigue una

Cuadro 3: Puntuación obtenida por método

Método	Preprocesado	Función de combinación	Puntuación		
			Part. test (local)	Conjunto completo	Part. test (reto)
SVR	Grid-1x1	Media	1.012737	0.994871	0.99141
SVR	Grid-11x1	Media	1.008944	0.962363	0.96588
SVR	Grid-1x11	Media	0.993541	0.961091	0.96954
SVR	Grid-9x9	Media	1.011967	0.914991	0.95455
kNN, k=10	Grid-11x11	Media	1.080482	0.179420	0.92319
kNN, k=20	Grid-11x11	Media	1.025952	0.177902	0.90786
kNN, k=50	Grid-11x11	Media	0.986291	0.181755	-
kNN, k=100	Grid-11x11	Media	0.964530	0.182047	0.92968
kNN, k=20	Grid-11x11	Media,Mín,Máy	1.026861	0.177184	0.90547
kNN, k=30	Grid-11x11	Media,Mín,Máy	1.016878	0.178141	0.90547
CNN	Escala-128x128	-	2.924941	2.764689	3.29994
FC-NN (salida final)	Grid-11x11	Media	2.962418	2.994949	-
FC-NN (salida interm.)	Grid-11x11	Media	1.018477	1.008206	-
FC-NN (salida interm.)	Grid-4x4	Media	0.997953	0.997499	-
Híbrido (FC-NN+kNN)	Grid-4x4	Media	0.990773	0.192141	0.96096
Híbrido (FC-NN+kNN)	Grid-11x11	Media	0.939714	0.182374	0.93331
Híbrido (FC-NN+kNN)	Grid-11x11	Media,Mín,Máy	0.946566	0.183845	-
kNN, k=20	Grid-64x64	Media	0.912257	0.176980	0.89316
kNN, k=20	Grid-128x128	Media	0.914167	0.177347	0.89422

- SVR → Regresión de Vectores de Soporte (Sección 3.1.1)
- kNN → k Vecinos más Cercanos (Sección 3.1.2)
- CNN → Red Neuronal Convolutiva (Sección 3.2.1)
- FC-NN → Red Neuronal Completamente Conectada (Sección 3.2.2)
- Híbrido (FC-NN+kNN) → Combinación de red neuronal y k-NN (Sección 3.3)
- Grid-NxN → Preprocesado propuesto en la Sección 2.1
- Part. test (local) → Puntuación sobre la partición de test reservada de los datos disponibles
- Conjunto completo → Puntuación respecto a todo el conjunto de datos disponible
- Part. test (reto) → Puntuación obtenida por el método en la plataforma del reto

estimación más fiable de los parámetros. Por tanto, se ha decidido aplicarlo con un preproceso en cuadrícula con un tamaño superior al de la imagen más pequeña (provocando, por tanto, bloques vacíos en el preprocesado). Nuevamente, esto ha dado lugar a una mejora en la puntuación, debido probablemente a que al aplicar el preproceso de esta manera apenas se descarta información de las imágenes de entrada. Esto, además, parece denotar que el conjunto de datos reservado por la organización es muy similar al que proporcionan como entrenamiento, favoreciendo aquellos métodos que tienden al sobreajuste, como es el caso del k-NN con un vector latente de tal tamaño.

5. CONCLUSIONES

Los resultados que se han detallado en la sección anterior denotan que la mejor estimación de los parámetros del terreno se consigue utilizando los métodos tradicionales. Sin embargo, los métodos basados en redes neuronales artificiales parecen ser

capaces de evitar el sobreajuste y, en algunos casos, conseguir converger hacia una buena estimación utilizando la media.

A pesar de lo que demuestran las métricas experimentales que se han obtenido, es importante destacar que estos resultados se ven enormemente condicionados a los datos que han sido proporcionados. La diferencia entre las puntuaciones estimadas con el conjunto reservado que no se utilizó durante el entrenamiento y la puntuación obtenida en la plataforma del reto, así como el hecho de que un método que se fundamenta en la distancia hacia las muestras vistas durante el entrenamiento, dan lugar a pensar que un sobreajuste es la mejor opción para este caso y que, por tanto, el conjunto de datos no es el adecuado. Además, también cabe mencionar que la relación entre las imágenes hiperespectrales y los parámetros propuestos no está clara, teniendo en cuenta que no se proporciona ninguna información sobre cómo se han obtenido los mismos.

Agradecimientos

Este trabajo ha sido financiado por el proyecto HIPERDEEP de la Junta de Comunidades de Castilla-La Mancha (referencia SBPLY/19/180501/000273) y por la UCLM con financiación de la Unión Europea a través del Fondo Social Europeo Plus (FSE+) para la tesis doctoral de Alberto Velasco.

English summary

Artificial Intelligence Methods for the Prediction of Chemical Components from Hyperspectral Images

Abstract

Automating the analysis of soil parameters can optimize the fertilization process, saving time and reducing the costs of food production, leading to a more sustainable agriculture. The work presented in this paper is part of the HYPERVIEW Challenge: Seeing Beyond the Visible, which aims to estimate soil parameters from hyperspectral images. Several methods are proposed, based both on traditional approaches such as SVR and k-NN, as well as modern neural networks. A combination of both approaches is considered as well. In addition, a parameterized preprocessing stage has been proposed to deal with the varying size of the input data. The best results have been obtained with a model based on k-NN.

Keywords: Hyperspectral imaging, artificial intelligence, deep learning.

Referencias

- [1] Intuition-1: Processing of hyperspectral images in orbit. kplabs.space/intuition-1.
- [2] Aitkenhead, M., Coull, M., Towers, W., Hudson, G., and Black, H. (2012). Predicting soil chemical composition and other soil parameters from field observations using a neural network. *Computers and Electronics in Agriculture*, 82:108–116.
- [3] de Santana, F. B., de Souza, A. M., and Poppi, R. J. (2018). Visible and near infrared spectroscopy coupled to random forest to quantify some soil quality parameters. *Spectrochimica Acta*

Part A: Molecular and Biomolecular Spectroscopy, 191:454–462.

- [4] Esposito, M., Vercruyssen, N., Dijk, C., Conticello, S., Carnicero Domínguez, B., Pastena, M., Martimort, P., and Silvestrin, P. (2019). Hyperscout 2 highly integration of hyperspectral and thermal infrared technologies for a miniaturized EO imager.
- [5] Fernández Pierna, J. A. and Dardenne, P. (2008). Soil parameter quantification by nirs as a chemometric challenge at ‘chimométrie 2006’. *Chemometrics and Intelligent Laboratory Systems*, 91(1):94–98. Selected papers presented at the Chemometrics Congress “CHIMIOMETRIE 2006” Paris, France, 30 November - 1 December 2006.
- [6] Marshall, M., Belgiu, M., Boschetti, M., Pepe, M., Stein, A., and Nelson, A. (2022). Field-level crop yield estimation with prisma and sentinel-2. *ISPRS Journal of Photogrammetry and Remote Sensing*, 187:191–210.
- [7] Riedel, F., Denk, M., Müller, I., Barth, N., and Gläßer, C. (2018). Prediction of soil parameters using the spectral range between 350 and 15,000nm: A case study based on the permanent soil monitoring program in saxony, germany. *Geoderma*, 315:188–198.
- [8] Yang, Y., Anderson, M., Gao, F., Xue, J., Knipper, K., and Hain, C. (2022). Improved daily evapotranspiration estimation using remotely sensed data in a data fusion system. *Remote Sensing*, 14(8):1772.



© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).