

# Aplicación de técnicas de Deep Learning en modelamiento y observación de la fotosfera solar

## Application of Deep Learning techniques in modelling and observation of the solar photosphere

Germain Nicolás Morales Suárez<sup>1</sup>, Juan Esteban Agudelo Ortiz<sup>2</sup>, Santiago Vargas Domínguez<sup>1</sup>, Sergiy Shelyag<sup>3</sup>

<sup>1</sup>Universidad Nacional de Colombia, Observatorio Astronómico Nacional, Colombia

<sup>2</sup>Universidad Nacional de Colombia, Departamento de Física, Colombia

<sup>3</sup>Universidad Deakin, Australia

<sup>1</sup>gemoraleless@unal.edu.co

### Resumen

Este trabajo se enmarca en las aplicaciones de las redes neuronales en el estudio y modelamiento de los fenómenos presentes en la fotosfera solar. La investigación propuesta se basa en el modelo de redes adversarias generativas haciendo uso de los módulos de inteligencia artificial de Pytorch. Se busca entrenar una red neuronal capaz de generar grupos de imágenes de una alta similitud con imágenes de entrenamiento, dichas imágenes corresponden a magnitudes físicas de la fotosfera solar tales como densidad, campo magnético, velocidad del plasma, temperatura, entre otras, obtenidas del código de simulación MURaM, aunque la red neuronal puede entrenarse para generar imágenes de cualquier magnitud física. El trabajo se enfoca en la generación de imágenes de campo magnético en la fotosfera solar. Se presentan los resultados de entrenamiento de la red neuronal, la comparativa entre las imágenes de entrenamiento y las imágenes generadas, y se proponen los retos para usar estas herramientas en el estudio de la fotosfera solar, se logra evidenciar que las redes tipo GAN logran recrear de forma parcial estructuras físicas de la fotosfera solar, con valores de divergencia cercanos a cero lo cual permite afirmar de manera conclusiva que la estructura creada por la red es en términos técnicos, físicamente correcta para las leyes del magnetismo, el siguiente paso en la investigación debe enfocarse en el mejoramiento de la red de modo que logre recrear de forma total estructuras de la fotosfera solar que a su vez permitan evidenciar una consistencia física con las ecuaciones MHD y tengan una resolución mayor que la generada en el proyecto actual.

**Palabras clave:** GAN, DCGAN, Pytorch, fotosfera, MHD, Aprendizaje profundo.

## **Abstract**

This work is part of the applications of neural networks in the study and modeling of the phenomena present in the solar photosphere. The proposed research is based on the network model generative adversaries making use of Pytorch's artificial intelligence modules. Wanted to train a neural network capable of generating groups of images of a high similarity with training images, These images correspond to physical magnitudes of the solar photosphere such as density, field magnetic, plasma speed, temperature, among others, obtained from the MURaM simulation code, although the neural network can be trained to generate images of any physical magnitude. work will focuses on magnetic field imaging in the solar photosphere. The results are presented training of the neural network, the comparison between the training images and the images generated, and the challenges to use these tools in the study of the solar photosphere are proposed, it is achieved demonstrate that GAN-type networks manage to partially recreate physical structures of the solar photosphere, with divergence values close to zero, which allows us to conclusively state that the structure created by the network is in technical terms, physically correct for the laws of magnetism, the following step in the investigation should focus on improving the network so that it can accurately recreate total structures of the solar photosphere that in turn allow evidence of a physical consistency with the MHD equations and have a higher resolution than the one generated in the current project.

**Key words:** GAN, DCGAN, Pytorch, Photosphere, MHD, Deep Learning.

## 1. Introducción

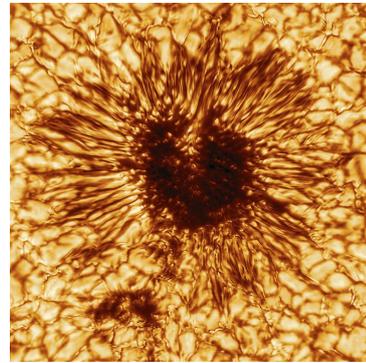
El estudio de la zona convectiva del Sol ha sido de gran interés para los físicos a lo largo del tiempo. Sin embargo su teorización y experimentación se han visto limitadas por ser una zona inaccesible para la observación directa con instrumentos como sondas o telescopios, siendo la capa superior (fotosfera) la primera en la cual la radiación escapa y puede ser detectada. Simulaciones computacionales con métodos numéricos han sido desarrolladas para la modelación de la fotosfera y la zona conectiva bajo la superficie solar; infortunadamente estas simulaciones requieren de una gran capacidad computacional al igual que numerosas horas de computo, algo que solo es posible en centros de investigación avanzados. Teniendo en cuenta que en muchos casos se deben realizar gran cantidad de experimentos numéricos para refinar los resultados de las simulaciones, se hace dispendioso obtener resultados inmediatos. Las redes neuronales aplicadas en el nuevo ámbito del Deep Learning pueden ser una gran herramienta para solucionar las barreras del poder computacional, el tiempo de simulación y la ausencia de elementos de observación para la zona convectiva del Sol.

Este proyecto busca hacer uso de redes neuronales tipo DCGAN para la generación de imágenes de campo magnético en la fotosfera solar basadas en imágenes producidas por simulaciones realizadas con el código MURaM, conteniendo entonces características físicas óptimas para poder ser tenidas en cuenta para una posible aplicación posterior en la generación de otras características físicas de la fotosfera.

## 2. Zona conectiva y fotosfera solar

La superficie del Sol o fotosfera, es una fina capa que se encuentra posterior a la zona convectiva de nuestra estrella. Su estudio es de vital importancia para el entendimiento de los procesos físicos al interior solar dado que la fenomenología que aparece con mayor frecuencia en la cúspide de cada ciclo solar obedece a interacciones internas entre los campos magnéticos y el plasma solar. Entre algunas de las características visibles más destacadas de la fotosfera se encuentran las fáculas y las manchas solares (Figura 1), con gran actividad a lo largo del ciclo solar.

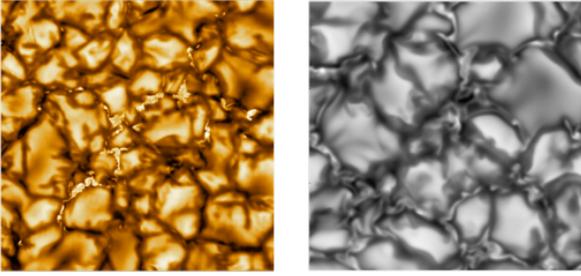
A su vez, el campo magnético en las manchas solares es crucial para el profundizar en el conocimiento de los procesos que ocurren en capas más altas de la atmósfera solar, donde tienen lugar fenómenos de gran liberación de energía.



*Figura 1.* Mancha solar observada con el telescopio DKIST.

En general, modelar y explicar el funcionamiento interno de la fotosfera solar es un proceso complejo que involucra la teoría electromagnética, mecánica de fluidos y termodinámica, en lo que se denomina magnetohidrodinámica (MHD). A partir de las ecuaciones de la MHD (entre las que se encuentra la de momento, continuidad, energía e inducción), se puede explicar la interacción de los campos magnéticos con el plasma solar, estudiar la dinámica del plasma y su transporte dentro de la zona convectiva, justo bajo la superficie solar. La solución analítica de estas ecuaciones no es posible, de forma que hay que recurrir a métodos numéricos apoyados en métodos computacionales para lograr solucionar y modelar el interior solar junto con la fotosfera. Desde hace casi dos décadas el código MURaM [1] se usa de forma extendida para simular el interior y superficie solar, y sus resultados contrastados con observaciones de la fotosfera.

El Daniel K. Inouye Solar Telescope [3, DKIST] es actualmente el telescopio solar de mayor potencia en el mundo. Instalado en la isla hawaiana de Maui, este telescopio ha logrado obtener imágenes de alta resolución de la fotosfera solar permitiendo estudiar en detalle la fenomenología a pequeña escala. La Figura 2 muestra la comparación entre imágenes de la fotosfera obtenidas con DKIST y con simulaciones MURaM.



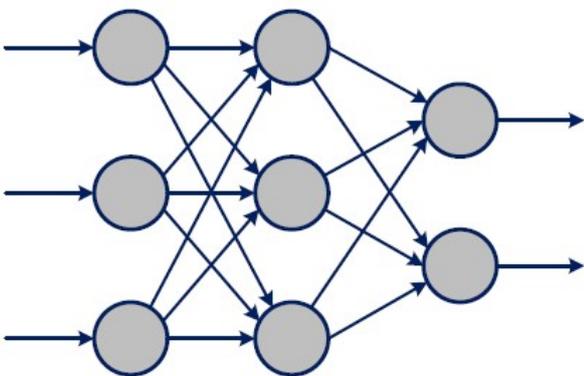
**Figura 2.** Región de la fotosfera solar observada con el telescopio DKIST (izquierda) y simulada con el código MURaM (derecha).

Este trabajo utiliza resultados del código MURaM para lograr generar imágenes y parámetros físicos, haciendo uso de redes neuronales sin utilizar directamente las ecuaciones MHD, requiriendo así un menor poder computacional y las ventajas que anteriormente se describieron.

Aunque MURaM provee varias magnitudes físicas el presente trabajo se centra en la generación de magnitudes de campo magnético basados totalmente en los valores generados por la simulación.

### 3. Aprendizaje automático

*"La idea común detrás de todas las técnicas basadas en redes neuronales artificiales es intentar expresar la solución de problemas complejos no como un algoritmo secuencial que resuelve un problema aplicando una secuencia de pasos concreta, sino como el resultado de combinar, en paralelo, las pequeñas contribuciones realizadas por un gran número de elementos simples de procesamiento que se hallan interconectados entre sí."*[5]



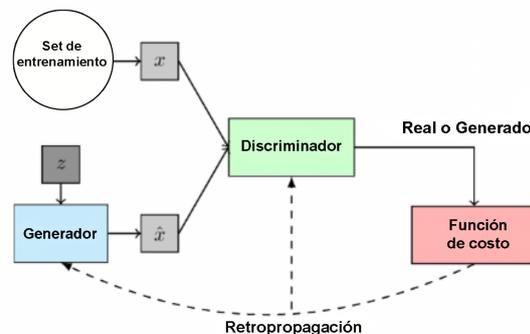
**Figura 3.** Una red neuronal artificial con múltiples capas de neuronas [5].

Cada elemento circular representa una neurona, un elemento que puede ejecutar una tarea simple como clasificación o delimitación. La unión de varias neuronas se entienden como una red neuronal, la primera columna se denomina capa. Su funcionamiento requiere un estímulo de entrada que al pasar por la capa de la derecha se convierte en una salida que a su vez será la entrada para la segunda capa y así hasta que la capa final presente un resultado que se entiende como salida (Figura 3).

### 4. La red convolucional adversaria

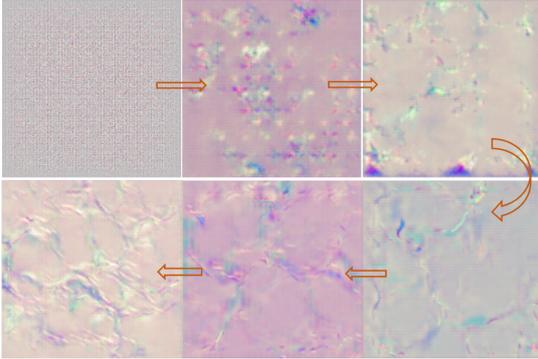
Las redes neuronales adversarias generativas (GAN por sus siglas en inglés) fueron propuestas por Ian Goodfellow en 2014 [6] basadas en las redes neuronales clasificatorias, en un intento de usar la inteligencia artificial para la generación de imágenes con una semilla y un objetivo final. Una de las aplicaciones más famosas, propuestas también por Goodfellow, es la generación de rostros a partir de una red convolucional.

Una red neuronal adversaria buscará ajustar sus valores de entrada comparándolos con un valores discriminadores, estos valores se entienden como entradas y los valores a ajustar se conocen como pesos. La red marcará entonces a los valores generados como falsos (0) y las imágenes reales que actuando como discriminadores los marcará como verdaderos (1). La red tomará entonces una imagen de ruido (la semilla) y buscará ir ajustando sus valores a partir de multiplicar unos pesos por sus valores, de modo tal que vaya obteniendo las características de la imagen que funciona como discriminador a medida que el entrenamiento avanza [2].



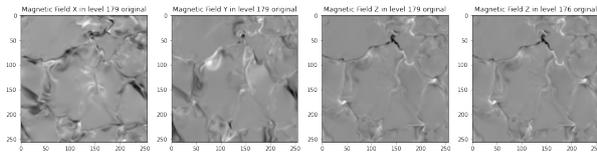
**Figura 4.** Diagrama de flujo de una red tipo GAN [4]

Al finalizar cada iteración del bucle de la red, el discriminador indicará si la imagen que ha recibido es real o falsa. En realidad el discriminador es un clasificador muy bien entrenado que interpreta resultados de 1 o 0 dependiendo del método de entrenamiento; el objetivo es medir el error de la imagen generada para saber que tan lejos esta de ser una imagen real y de esta forma la red puede ir ajustando los pesos.



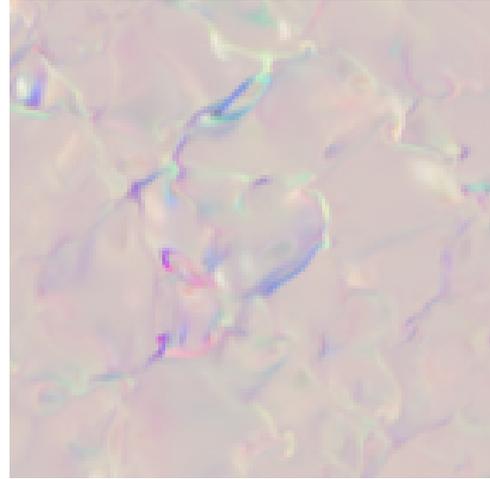
**Figura 5.** Evolución de la imagen de ruido por el entrenamiento.

Las imágenes reales usadas para entrenar la red discriminadora son el resultado de la simulación computacional MURaM, que brinda características físicas como densidad, presión, temperatura, velocidad y campo magnético. En particular, se genera un lote completo de imágenes de entrenamiento de campo magnético (magnetogramas) para lograr que el discriminador sea capaz de reconocer la mayor cantidad de formas y características.



**Figura 6.** Muestra de las imágenes de entrenamiento (magnetogramas).

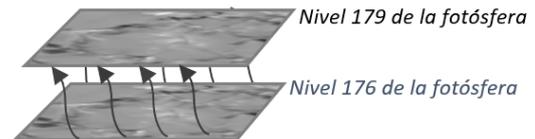
Las imágenes de entrenamiento tiene un tamaño de  $256 \times 256$  píxeles, lo cual implica que las imágenes generadas tendrán este mismo tamaño. Las redes neuronales convolucionales buscan entrenar imágenes aprendiendo características de los píxeles de cada canal, motivo por el cual en este trabajo las coordenadas  $X$ ,  $Y$ ,  $Z$  son combinadas en una sola imagen, obtenido así las imágenes de entrenamiento.



**Figura 7.** Combinación de las coordenadas en una sola imagen en 4 canales.

## 5. El cuarto canal y la medida de la divergencia

La red neuronal genera imágenes a partir de la información brindada por cada canal. Algunas de las imágenes generadas puede ser en apariencia muy similares a las imágenes de entrenamiento, sin embargo, estas imágenes pueden carecer de un sentido físico. Con el fin de generar imágenes que cumplan con ambas características se hace necesario medir la divergencia del campo magnético en las coordenadas  $X$ ,  $Y$ ,  $Z$  de una capa y la magnitud  $Z$  de una capa inferior (a la que denominaremos  $Z_2$ ). En la Figura 5 se muestra la imagen de campo magnético en las capas 179 y 176; la divergencia entre estos niveles debe ser aproximadamente cero ( $\nabla \cdot \vec{B} = 0$ ).

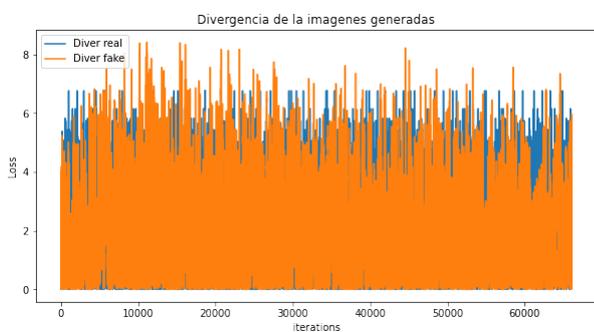


**Figura 8.** Representación gráfica del uso del cuarto canal para considerar diferentes alturas (componente  $Z$ ).

## 6. Discusión y resultados

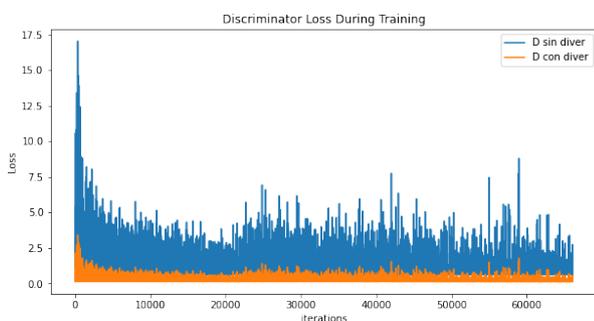
Después de aplicar el algoritmo, se obtienen imágenes compuestas de cuatro canales, siendo estos  $X$ ,  $Y$ ,  $Z$  y  $Z_2$  respectivamente. Al realizar un reescalamiento de las imágenes generadas que pasan de tener valores desde 0 a 255 a valores de campo magnéti-

co similares a los datos de la simulación MURaM, dichos datos obtenidos deben arrojar valores de divergencia cercanos a cero. Para la red neuronal los valores de pérdida del generador y del discriminador deben acercarse lo mayor posible a cero, de esta manera y con una configuración específica de valores de la red neuronal obtenemos resultados como los mostrados en la Figura 9. En el fondo de la gráfica se aprecia en color azul los valores de divergencia para las imágenes originales la cual se muestra con un valor máximo estable, para la imágenes generadas se muestra como inicialmente los valores de divergencia son demasiado altos y a medida que el entrenamiento avanza la divergencia inicia un descenso.

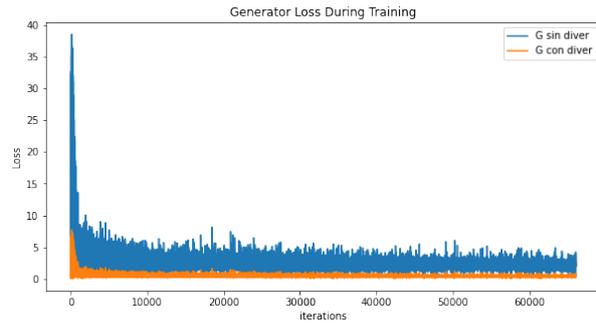


**Figura 9.** Valores de divergencia de las imágenes reales comparados con los de las imágenes generadas.

Con respecto a los valores de pérdida para el generador y el discriminador, se evidencia su decrecimiento, sin embargo en el presente artículo nos permitimos hacer un ajuste a los valores de pérdida definidos por la ecuaciones de los modelos deep learning. Por este motivo comparamos los valores de pérdida sin edición de la función de pérdida (azul) y con la edición (naranja).



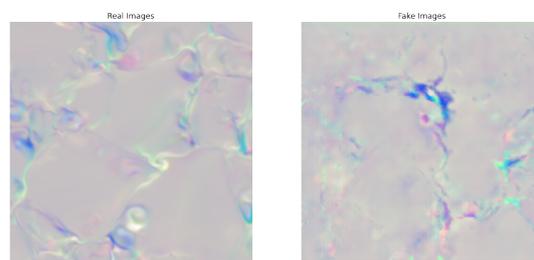
**Figura 10.** Pérdida del discriminador versus pérdida del discriminador editada.



**Figura 11.** Pérdida del generador versus pérdida del generador editada.

La edición propuesta a los valores brindados por la función de pérdida, pretender usar la divergencia como un factor dependiente del ajuste de los pesos; es por este motivo que se logra evidenciar que cuando la divergencia juega un papel principal para afectar los valores de pérdida, tal pérdida no solo es menor sino que también se ajusta de manera mas eficiente.

Finalmente, después de un proceso de entrenamiento podemos obtener una imagen que cumple con las condiciones propuestas inicialmente y que presenta una gran similitud con las imágenes de entrenamiento (Figura 12).



**Figura 12.** Imagen real versus imagen generada.

## 7. Conclusiones

Las principales conclusiones de esta investigación se describen a continuación:

- En los resultados podemos evidenciar dos tipos de resultados, los datos de la red neuronal sin influencia del cálculo de la divergencia, que obliga a la red a actualizar los pesos función sin tener en cuenta la divergencia y los segundos son en lo que la función debe obtener valores de divergencia cada vez menores con la actualización de los pesos, mostrando que la

influencia de la divergencia a la hora de actualizar los pesos mejora la eficiencia de la red neuronal.

- Se evidencia una similitud en un nivel visual entre las imágenes generadas y las imágenes de entrenamiento, en un análisis de funciones de distribución pueden diferenciarse en niveles máximos, mínimos y de media.
- La resolución de la imagen generada es bastante menor en comparativa a la imagen de entrenamiento, lo cual puede provocar errores para un análisis estadístico y/o numérico.
- Las imágenes entrenadas pueden ser mejoradas en los aspectos físicos y de resolución con apoyo de una red mas densa y un poder computacional mayor.

## Referencias

- [1] A. Voegler, M. Schussler, F. Cattaneo T., E. S. Shelyag, Linde, T. Simulations of magneto-convection in the solar photosphere equations, methods, and results of the MURaM code. *Astronomy & Astrophysics II* (2004), S. 8–10.
- [2] C. M. Bishop. Neural networks for pattern recognition. *Astronomy & Astrophysics II* (1996), S. 0–498.
- [3] T. R. Rimmele et al. The Daniel K. Inouye Solar Telescope - Observatory Overview. *Solar Physics*, Volume 295, Issue 12, article id.172 (2020).
- [4] Ponti, Moacir, Ribeiro, Leonardo, Nazare, Tiago, Bui, Tu, Collomosse, John. (2017). Everything You Wanted to Know about Deep Learning for Computer Vision but Were Afraid to Ask. 17-41. 10.1109/SIBGRAPI-T.2017.12.
- [5] Berzal, F. (2018). Redes neuronales & deep learning: Volumen I. Independently published.
- [6] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.