

# SÍNTESIS DE IMÁGENES DE RADAR METEOROLÓGICO A PARTIR DE IMÁGENES DE SATÉLITE USANDO REDES NEURONALES GENERATIVAS

Maximiliano A. SACCO<sup>1,2</sup>, Guillermo SCHEFFLER<sup>3</sup>, Juan RUIZ<sup>2,3,5</sup>, Yanina Garcia Skabar<sup>1,4,5</sup>  
[msacco@smn.gob.ar](mailto:msacco@smn.gob.ar), [guillermo.scheffler@cima.fcen.uba.ar](mailto:guillermo.scheffler@cima.fcen.uba.ar), [jruiz@cima.fcen.uba.ar](mailto:jruiz@cima.fcen.uba.ar)

<sup>1</sup>Servicio Meteorológico Nacional (SMN)

<sup>2</sup>Departamento de Ciencias de la Atmósfera y los Océanos (FCEyN, UBA)

<sup>3</sup>Centro de Investigaciones del Mar y la Atmósfera (CONICET-UBA)

<sup>4</sup>CONICET

<sup>5</sup>UMI-IFAEI, (CNRS-CONICET-UBA)

## RESUMEN

Los radares meteorológicos proporcionan información detallada acerca de la estructura de las nubes y permiten estimar variables tales como la intensidad instantánea de precipitación. No obstante la red actual de radares no cubre la totalidad del territorio nacional. Por otro lado, los satélites proporcionan información más limitada acerca de las características de las nubes (ej. la radiación solar reflejada o la emitida por el tope de las nubes pero con una cobertura casi mundial y una resolución espacial y temporal que se acerca cada vez más a la de los radares convencionales. En este trabajo presentamos una aplicación novedosa de aprendizaje automático para estimar el campo de reflectividad a partir de observaciones satelitales en el infrarrojo. En este trabajo estimamos la información proporcionada por una red de radar a partir de la radiación medida desde un satélite meteorológico lo cual permitiría mejorar la inferencia acerca de ciertas propiedades de las nubes en áreas donde la información de radar no está disponible. Para esto, se utilizaron redes neuronales generativas entrenadas con pares de imágenes radar / satelital. Los resultados son superiores a los obtenidos con los métodos estadísticos tradicionales.

## ABSTRACT

**Meteorological radars provide detailed information about the structure of the clouds and allow the estimation of variables such as the instantaneous intensity of precipitation. However, the current network of radars does not cover the entire national territory. On the other hand, satellites provide a more limited information about the characteristics of the clouds (e.g. reflected solar radiation or that emitted by the top of the clouds but with an almost global coverage and a spatial and temporal resolution approaching more and more to that of conventional radars). In this work, we present a novel application of automatic learning to estimate the field of reflectivity from satellite observations in the infrared. We estimate the information provided by a radar network from the measured radiation from a meteorological satellite, which would allow us to improve the inference about certain properties of the clouds in areas where radar information is not available, using generative neural networks trained with radar / satellite image pairs. The obtained results are superior to those obtained through traditional statistical methods.**

**Palabras clave:** imágenes sintéticas de radar, redes neuronales, generative adversarial network.

## 1. INTRODUCCIÓN

Es este trabajo se explora la posibilidad de llevar a cabo la reconstrucción del campo de reflectividad máxima en la vertical a partir de la radianza en el rango del infrarrojo medida por un satélite geoestacionario, utilizando GANs (Generative Adversarial Networks) [Goodfellow et al.(2014)]. Las GANs son una clase de algoritmo que utilizan aprendizaje semi-supervisado, implementadas por un sistema de dos redes neuronales que compiten mutuamente en una especie de juego de suma cero. En particular se utilizó una variante llamada cGAN (conditional GAN) que a diferencia de las GANs tradicionales toman un valor de entrada para generar la salida. Típicamente, la red generativa aprende a generar los datos de salida (imágenes de radar), mientras la red discriminativa diferencia entre elementos provistos como verdad (entrenamiento) y los datos producidos por el generador. El objetivo del aprendizaje de la red generativa es aumentar el índice de error de la red discriminativa, es decir, producir elementos sintéticos que parecen provenir de la distribución de datos auténticos.

## 2. DESCRIPCIÓN DE LOS EXPERIMENTOS

En primer lugar, se realizaron pruebas de concepto utilizando datos de entrenamiento generados sintéticamente. Para la generación de estas imágenes, se utilizaron datos obtenidos a partir de una integración de alta resolución del modelo WRF v3.8. Se utilizaron datos correspondientes al periodo Enero-Octubre de 2017, con una resolución temporal de 6 horas, en la región 20S-36S y 67O-52O a una resolución de 4km.

Por otro lado, se realizaron experimentos utilizando datos reales de radar provenientes de la red NEXRAD administrada por la National Oceanic and Atmospheric Administration (USA) y datos de radianza en el rango del infrarrojo de los satélites geoestacionarios de la serie GOES. Los datos utilizados corresponden a la región 30N-40N y 104O-92O, con una resolución de ~1km, durante el período 1/1/2010-31/12/2017. Se optó por elegir esta fuente debido a que sus datos han sido previamente validados y sometidos a un riguroso control de calidad




Figura 1: La imagen de la izquierda corresponde a la imagen satelital infrarroja a la entrada de la GAN, la imagen central corresponde a la reflectividad máxima en la vertical estimada por la GAN, y la imagen de la derecha corresponde a la reflectividad observada.

### 3. RESULTADOS Y CONCLUSIONES

Del análisis de las imágenes generadas sobre el conjunto de entrenamiento en varias arquitecturas de GANs, se observó que la morfología general se mantuvo y que el uso de redes generativas GAN para la estimación del campo de reflectividad produjo resultados satisfactorios. En términos generales y respecto a los patrones de mayor escala espacial, la reflectividad de radar estimada por la red fue en todos los casos bien posicionada en tiempo y espacio y no se identificó la presencia de ecos fantasmas generado por la red. Con respecto a los patrones de reflectividad de menor escala, se identificaron frecuentemente errores de ubicación (por ejemplo en la posición espacio-temporal de los máximos de reflectividad). También se identificó una tendencia a sobreestimar los máximos de reflectividad.

Estas limitaciones podrían ser reducidas a través de mejoras en el algoritmo de estimación tales como la incorporación de más características (features) tanto en el generador como el discriminador de las GANs.

Ante los resultados alentadores que se obtuvieron, se planea continuar explorando esta temática. En primer lugar, se buscará definir un criterio objetivo de evaluación que permite evaluar objetivamente las diferentes configuraciones de GAN. Esto además permitirá comparar los resultados obtenidos con otros métodos estadísticos para abordar la problemática de generación de imágenes de radar.

### 4. REFERENCIAS

- Goodfellow, I.** (2016). NIPS 2016 tutorial: Generative adversarial networks. arXiv preprint arXiv:1701.0016 **Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A.** (2016). Image-to-image translation with conditional adversarial networks. arXiv preprint arXiv:1611.07004.
- Smith, J.A. and W.F. Krajewski.** Estimation of the Mean Field Bias of Radar Rainfall Estimates.(1991). Journal of Applied Meteorology 30:4, 397-412