

# Detección de hielo Frazil-Pancake en imágenes SAR

E. S. Mendoza<sup>1</sup>, G. González<sup>1</sup>, B. Escalante-Ramírez<sup>1</sup>, F. Parmiggiani<sup>2</sup>, J. Olveres<sup>1</sup>, E. Carbajal-Degante<sup>3</sup>

<sup>1</sup>Facultad de Ingeniería, Universidad Nacional Autónoma de México, Cd. de México, México; <sup>2</sup>Department of Satellite Meteorology, ISAC-CNR, Bologna, Italy;

<sup>3</sup>Posgrado en Ciencia e Ingeniería de la Computación, Universidad Nacional Autónoma de México, Cd. de México, México

## Introducción

Los cristales de hielo **frazil** bajo turbulencia se aglomeran en discos conocidos como **pancakes**[1]. Éstos son importantes por el proceso de expulsión de sal durante su formación, con ello la **densidad** del agua cercana aumenta causando su hundimiento, luego es remplazada por agua del fondo menos densa. El fenómeno se repite contribuyendo así a las **corrientes de convección**, y con ello a la **circulación termohalina** [2,3]. Nuestro objetivo es detectar al hielo FP, a partir de imágenes de **Radar de Apertura Sintética (SAR)**.

## Base de datos

La figura 2 muestra las imágenes adquiridas por el satélite **Sentinel 1-A (S1A)** de la **Agencia Espacial Europea (ESA)**. Su polarización es **HH** y **HV**, con un espaciado de píxel de aproximadamente 40x40 m. Las imágenes se **pre-procesan** con el **software SNAP 2.0**, se elimina el ruido térmico y se aplica una calibración radiométrica para pasar de números digitales a valores de retrodispersión en **dB**.

## Metodología

Para detectar el hielo FP utilizamos transferencia de aprendizaje con **Redes Neuronales Convolucionales (CNN) pre-entrenadas**, que aprovechan las características obtenidas en un entrenamiento anterior [4].

A partir de pruebas iniciales de clasificación elegimos trabajar con las imágenes **HH en dB**. Posteriormente, se aplicaron las siguientes arquitecturas de CNN para la clasificación del FP: **ResNet50** (figura 3), **ResNet101**, **Inception V3**, **Inception V4** y **NASNet**. Sin embargo, por el tipo de datos de **ImageNet (uint8)** no es posible emplear los pesos pre-calculados, debido a que nuestras imágenes están en **dB**, por lo que todas las arquitecturas tuvieron que reajustarse. Para el entrenamiento con estas CNN, replicamos a las imágenes HH para recrear 3 canales, y seleccionamos aleatoriamente 2000 ventanas cuadradas de 224 píxeles para cada una de las 4 clases. Al final de cada arquitectura se colocó una etapa de **redes neuronales densas** de dos capas de 1024 neuronas; la capa final tiene cuatro neuronas.




Figura 1. Hielo Pancake.

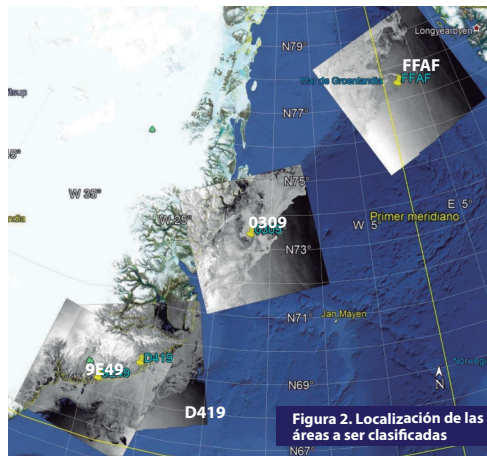


Figura 2. Localización de las áreas a ser clasificadas




Figura 4. En rojo las áreas de FP detectadas por la CNN, y en amarillo el contorno anotado por el experto.

Nombre de la capa	ResNet 50 capas
Conv1	7x7,64; stride 2
Conv2_x	3x3 max pool; stride 2
Conv3_x	1x1,64 3x3,64 x3 1x1,256
Conv4_x	1x1,128 3x3,128 x4 1x1,512
Conv5_x	1x1,256 3x3,256 x6 1x1,1024
Conv5_x	1x1,512 3x3,512 x3 1x1,2048
	average pool/ Flatten/ Dense


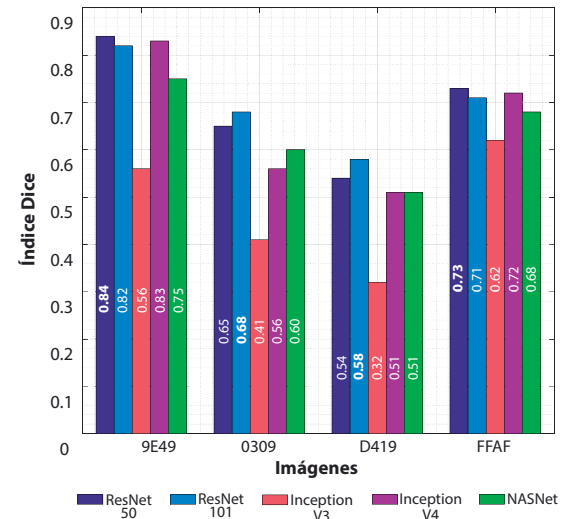


Figura 3. Izquierda: Arquitectura ResNet-50; Derecha: un bloque de ResNet

## Resultados

La validación se realizó con un esquema **Leave-one-out**. Se dividió a la imagen de prueba en ventanas cuadradas de 224 píxeles para su clasificación con el modelo obtenido en la etapa de entrenamiento. La **figura 4** muestra en rojo sólo las mejores segmentaciones de FP detectadas por la CNN, los contornos amarillos son los anotados por el experto. La **gráfica 1** contiene los índices **Dice** de las zonas segmentadas, los **mejores resultados** se muestran **resaltados** para cada imagen.

Gráfica 1. Índice Dice para las diferentes arquitecturas



## Conclusiones

Los resultados muestran que al usar una arquitectura **ResNet** pre-entrenada es posible hacer una detección acertada de las zonas de FP. Observamos que las **zonas marcadas** por el **experto coinciden** con las detectadas por las CNN; sin embargo, por el gran parecido de ciertas áreas con el FP, la red detecta más zonas de FP que las detectadas por el experto. Como **trabajo futuro** se propone realizar pruebas agregando la información de la imagen **HV** a este tipo de **arquitecturas pre-entrenadas**.

## Agradecimientos

Los autores agradecen el apoyo de los proyectos UNAM PAPIIT IA103119, y IN116917

## Referencias

- [1] P. Wadhams, G. Aulicino, F. Parmiggiani, et al. "Pancake ice thickness mapping in the Beaufort Sea from wave dispersion observed in SAR imagery", *Journal of Geophysical Research: Oceans*, 123, 3, 2213–2237 (2018).
- [2] NOAA, National Oceanic and Atmospheric Administration, "Currents Thermohaline Circulation" National Ocean Service website, [https://oceanservice.noaa.gov/education/tutorial\\_currents/05conveyor1.html](https://oceanservice.noaa.gov/education/tutorial_currents/05conveyor1.html).
- [3] L. A. Roach, M. M. Smith y S. M. Dean, "Quantifying Growth of Pancake Sea Ice Floes Using Images From Drifting Buoys" *Journal of Geophysical Research: Oceans*, 123, 4, 2851–2866, (2018).
- [4] Marmaris, D., Datcu, M., Esch, T., & Stilla, U. "Deep learning earth observation classification using ImageNet pretrained networks." *IEEE Geoscience and Remote Sensing Letters*, 13(1), 105–109, (2015).
- [5] Imagen de fondo: <https://beyondpenguins.ehe.osu.edu> de Vicky Lytle.
- [6] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition" 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016, pp. 770–778.