

Pronóstico de tormentas severas a corto plazo utilizando productos satelitales

Jorge Eduardo Velasco Zavala

Egresado de Ingeniería Geomática, UNAM

Titulación Abril 2021

Tutora M.C. Maria Elena Osorio Tai



Introducción

Existe una necesidad constante de encontrar métodos que permitan pronosticar el desarrollo de posibles tormentas severas de forma precisa

Sin embargo, este tipo de fenómenos muestran una gran variabilidad de condiciones bajo las que se desarrollan, dificultando la generación de un modelo general que permita su pronóstico

En la actualidad, el método más eficiente para identificar estos fenómenos es el uso radar



Objetivos

- Identificar rasgos precursores a tormentas severas empleando productos satelitales.
- Automatizar la identificación de rasgos asociados a las tormentas severas para eventos futuros.
- Generar un modelo que tome en cuenta los factores observados que funcione como una sistema de *nowcasting*.

Pronóstico a corto plazo

- Llamado en inglés *Nowcasting*
- Pronóstico que considera la posibilidad de que ocurra un episodio de convección severa en cualquier momento de las próximas 24 horas. Giaiotti, D. B., & Stel, F. (2007)
- Este tipo de pronóstico se enfoca en observaciones y cómo se extrapolan linealmente a el futuro próximo.
- Pequeñas extensiones de terreno para permitir una mayor resolución espacial y temporal de los factores que intervienen en los procesos.

Tormentas severas

Fenómenos convectivos de sistemas climáticos a mesoescala que se producen por una distribución irregular de energía térmica en la atmósfera.

Las condiciones iniciales que preceden a este tipo de eventos son muy variables lo cual dificulta su extrapolación.

Su tamaño va de unas pocas kilómetros a unos 200 o 300 kilómetros

Existen dos medios de pronóstico principales para este tipo de eventos

- Observaciones de radar meteorológico
- Modelos numéricos de pronóstico

Tormentas severas

Este tipo de tormentas son responsables de inundaciones súbitas, granizo, vientos mayores a los 50 nudos, tormentas eléctricas y tornados.



Condiciones necesarias para su formación

- Una distribución inestable de energía térmica en la atmósfera que permita que las parcelas de aire tienda a desplazarse hacia arriba.
- Saturación de vapor de agua en la atmósfera que permita las parcelas de aire asciendan a mayor velocidad sobre la columna atmosférica.
- Una condición dinámica que obligue a las corriente de aire a ascender y converger permitiendo la formación de nubes.


GOES-R

Satellite de órbita geoestacionaria lanzado el 19 de noviembre de 2016

Equipado con varios instrumentos diseñados para el estudio del clima de la tierra y el espacio.

ABI Advanced Baseline Imager de 16 bandas visible e infrarrojo con resolución de 0.5 - 2 km.

GLM Geostationary Lightning Mapper con resolución temporal de 2 ms. y espacial de 2 km.



ABI TECHNICAL SUMMARY CHART


TABLE I. Summary of the wavelength, resolution, and sample use and heritage instrument(s) of the ABI bands. The minimum and maximum wavelength range represent the full width at half maximum (FWHM or 50%) points. [The Instantaneous Geometric Field Of View (IGFOV).]

ABI Band	Central Wavelength(μm)	Type	Nickname	Best Spatial Resolution
1	0.47	Visible	Blue	1
2	0.64	Visible	Red	0.5
3	0.86	Near-Infrared	Veggie	1
4	1.37	Near-Infrared	Cirrus	2
5	1.6	Near-Infrared	Snow/Ice	1
6	2.2	Near-Infrared	Cloud particle size	2
7	3.9	Infrared	Shortwave window	2
8	6.2	Infrared	Upper-level water vapor	2
9	6.9	Infrared	Midlevel water vapor	2
10	7.3	Infrared	Lower-level water vapor	2
11	8.4	Infrared	Cloud-top phase	2
12	9.6	Infrared	Ozone	2
13	10.3	Infrared	"Clean" longwave window	2
14	11.2	Infrared	Longwave window	2
15	12.3	Infrared	"Drity" longwave window	2
16	13.3	Infrared	CO ₂ longwave	2

Schmit, T. J., S. S. Lindstrom, J. J. Gerth, M. M. Gunshor, 2018. Applications of the 16 spectral bands on the Advanced Baseline Imager (ABI) J. Operational Meteor., 6 (4), 33-46.

Rasgos identificados en imágenes satelitales

- Enfriamiento muy rápido del tope de nubes durante el inicio de las tormentas.
- Presencia anómala de gotas de agua pequeñas o cristales de hielo dentro de las Cumulonimbus.
- Incremento de la presencia de rayos en el tope de nubes.
- *Overshooting tops*




Bedka, K. 2018

Redes Neuronales Artificiales

Tiene la propiedad de poder modelar de forma directa la relación entre una o más variables de entrada y de salida. Aprenden de forma automática dicha relación a partir de la repetición y optimización de parámetros.

Modelo de 3 partes:


- Capa de entrada
- Capas ocultas
- Capa de salida




<https://ai.plainenglish.io/my-notes-on-neural-networks-adf3e49657f8>

Entrenamiento


Cada una de las capas ocultas está compuesta por “neuronas” que se alimenta de la información de capa anterior, realiza una función de activación no lineal y pasa el resultado a la siguiente capa.



<https://medium.com/swlh/activation-functions-in-artificial-neural-networks-8aa6a5ddf832>



ReLU
 $\max(0, x)$




<https://ai.plainenglish.io/my-notes-on-neural-networks-adf3e49657f8>

Entrenamiento

Al llegar a la capa de salida se compara el valor obtenido por la red con el valor objetivo y se usa el gradiente de dicho error para ajustar los parámetros de de cada una de las neuronas para luego repetir la activación.

Lo que se pretende es obtener mediante este proceso es minimizar el error entre la salida del modelo y el valor objetivo.




Redes Neuronales Convolutivas


Variante de las redes neuronales que permiten al modelo imitar, en cierta forma, la capacidad de ver de los cerebros biológicos.

Tiene la capacidad de aprender a identificar formas y patrones en el espacio y/o en el tiempo.

Ideales para clasificar y segmentar imágenes de forma automática.



<https://medium.com/swlh/activation-functions-in-artificial-neural-network-s-8aa6a5ddf832>


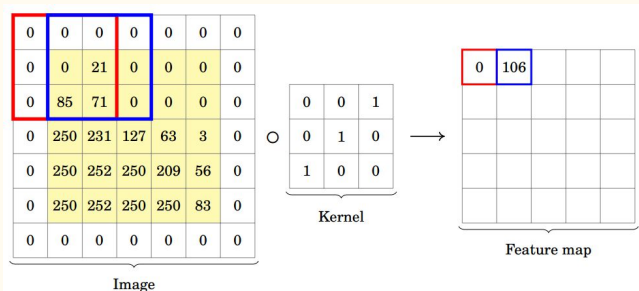


LeNail, (2019).

Redes Neuronales Convolutivas

Este proceso se realiza mediante el uso de filtros convolucionales o kernels seguido de una función de activación no lineales.

En cada capa se aplican una serie de filtros, los cuales, se encargan de distinguir diferentes patrones en las imágenes o volúmenes de entrenamiento.

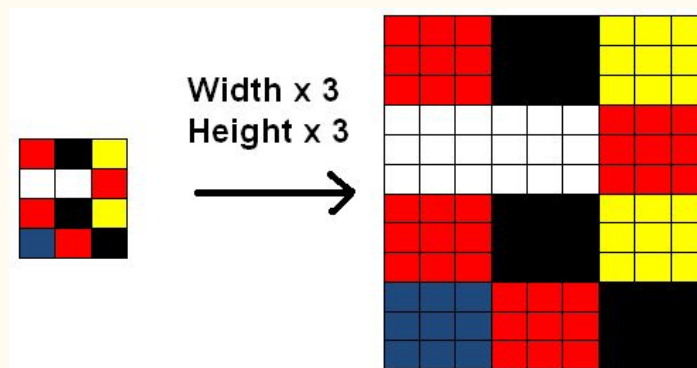




Redes Neuronales Convolutivas

Capas de muestreo, su función es la de reducir o aumentar el tamaño de los volúmenes que recibe

Capa reducción se pretende mantener únicamente el valor más representativo de cada sección preservando los canales

Capa aumentó su función es hacer aumentar el tamaño de la imagen usando alguna interpolación





Datos utilizados

Datos del GLM

Bandas ABI del GOES 16:

C08, C10, C11, C13,

C14, C15, C16

Latitud (18° 00' 35.14", 21° 26' 49.06")

Longitud (-100° 34' 6.03", -97° 07' 51.43")

Entrenamiento

- 21/03/2018
- 04/04/2018
- 15/03/2020
- 21/03/2020

Validación y prueba

- 14/02/2020
 - 18/03/2020
-

Metodología



Preprocesamiento

Tratamiento de los datos
GLM
Cálculo de gradientes de temperatura en el tope de nube
Enmascarado de los datos
Creación de los sets de entrenamiento, prueba y validación

Diseño de la red

Configuraciones probadas

Entrenamiento


Validación

Utilizando el set de validación se evaluó la precisión de la red después de cada iteración para comparar los resultados con los obtenidos en el set de entrenamiento.

Datos GLM

Se genera un archivo netcdf con datos de latitud, longitud, fecha, hora e intensidad, entre otros, cada 20 segundos

Se conjunto en un archivo hdf único todos los eventos observados durante el periodo sobre la zona de estudio para facilitar la consulta y mapeo de datos

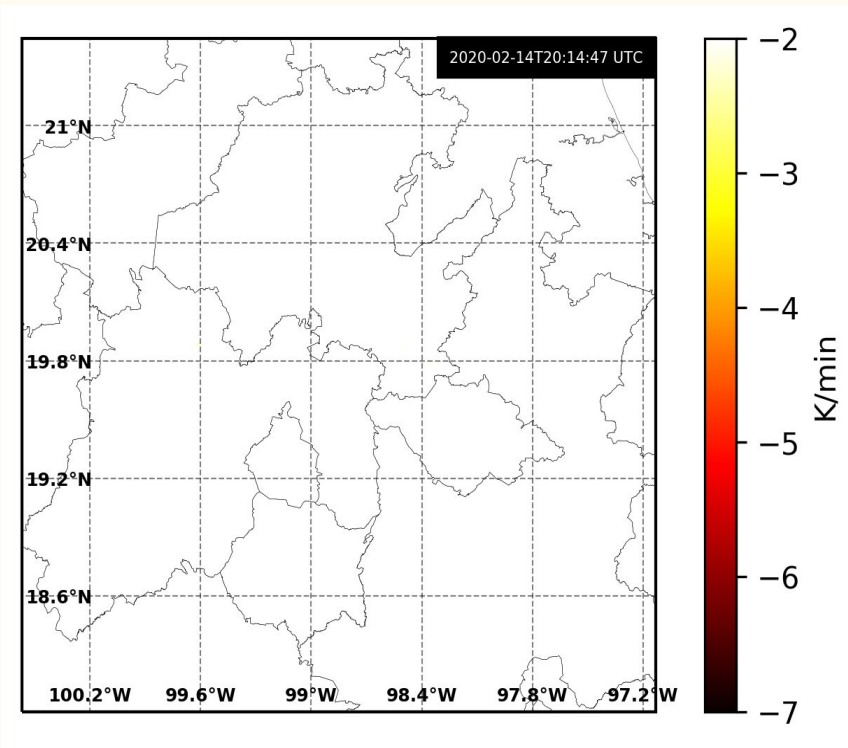


Gradientes de temperatura

A partir de los datos de la banda 14, se calculó la variación de la temperatura en el tope de nubes respecto al tiempo

$$(C14_t - C14_{t-1}) / dt$$

Se eliminó todos los datos cuyo gradiente sea mayor a -2 K/min con la intención de eliminar variaciones de temperatura muy pequeñas



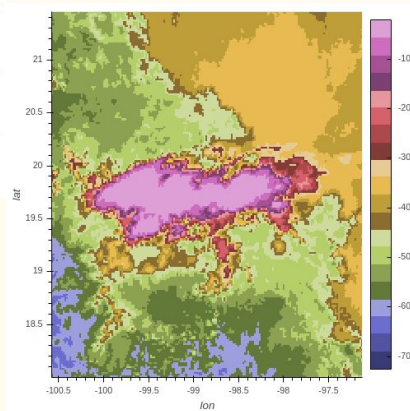




Enmascaramiento de los datos

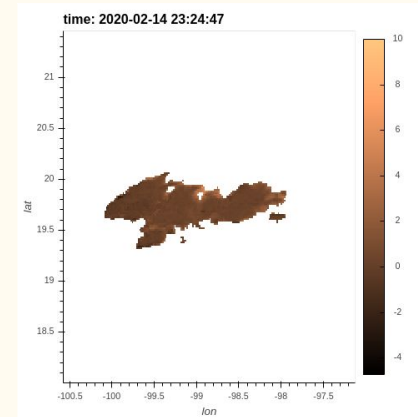


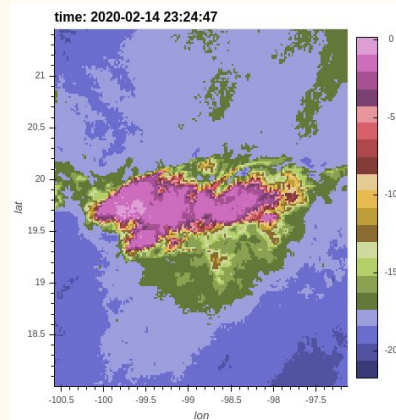

Variables de interés para la detección de convección en el tope de nubes	
C14	Temperatura del tope de nubes y velocidad de enfriamiento
C08 - C14 C08 - C10 C16 - C14	Altura relativa del tope de nubes a la tropopausa y su variación en el tiempo
C15 - C14 C11 - C14 (C15 - C14) - (C14 - C15)	Glaciación el tope de nubes

A partir de estas variables se establecieron umbrales de detección de nubes probablemente convectivas para generar las máscaras que se utilizaran para el entrenamiento de la red neuronal

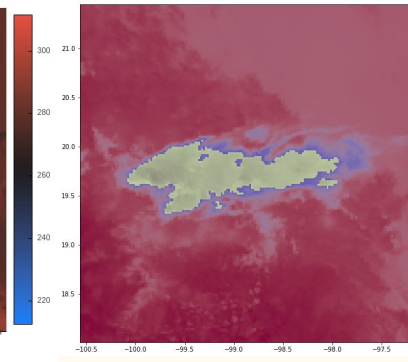

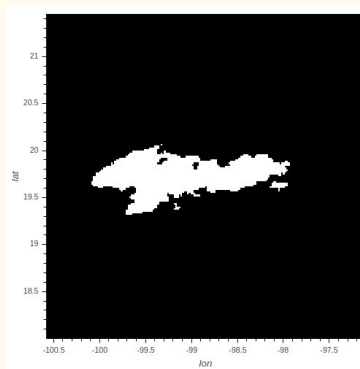


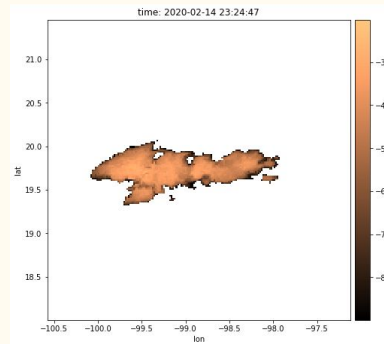

Enmascaramiento de los datos



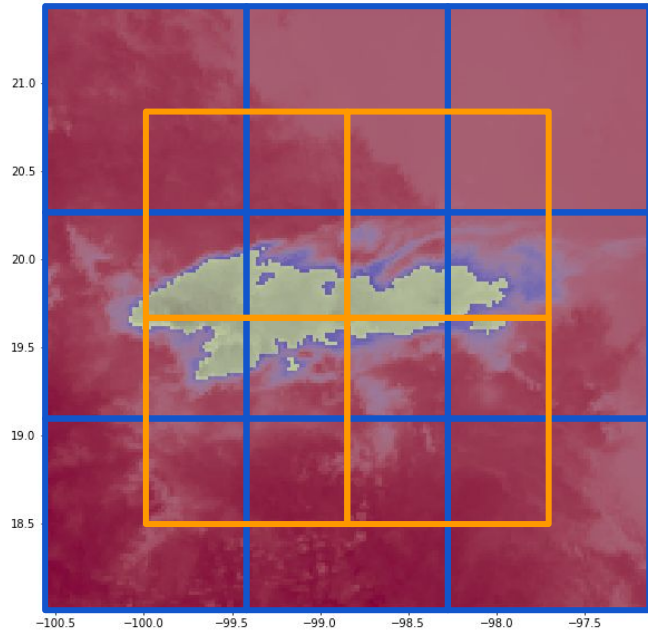
Enmascaramiento de los datos




Enmascarado de los datos



Creación de los set de entrenamiento y validación



(192 x 192 x 6)



(64 x 64 x 5)




(64 x 64 x 1)

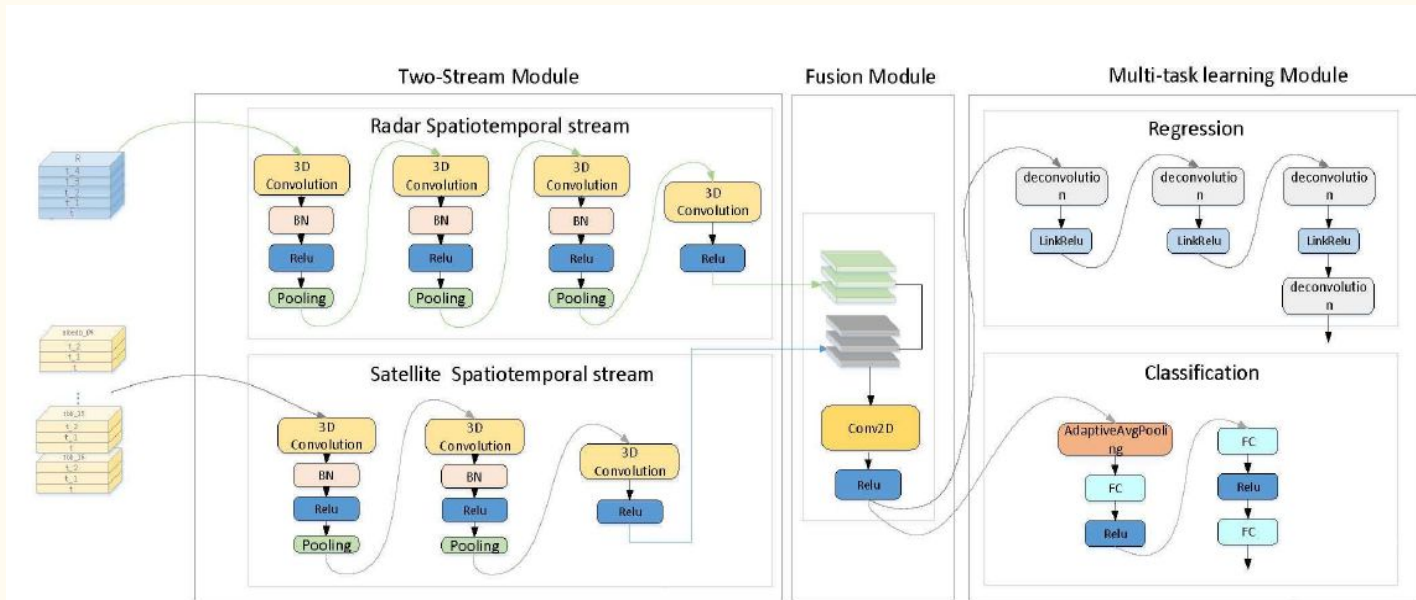
Total set de entrenamiento = 3520

Total set de validación = 1080

Arquitectura de la red neuronal



Arquitectura de la red neuronal

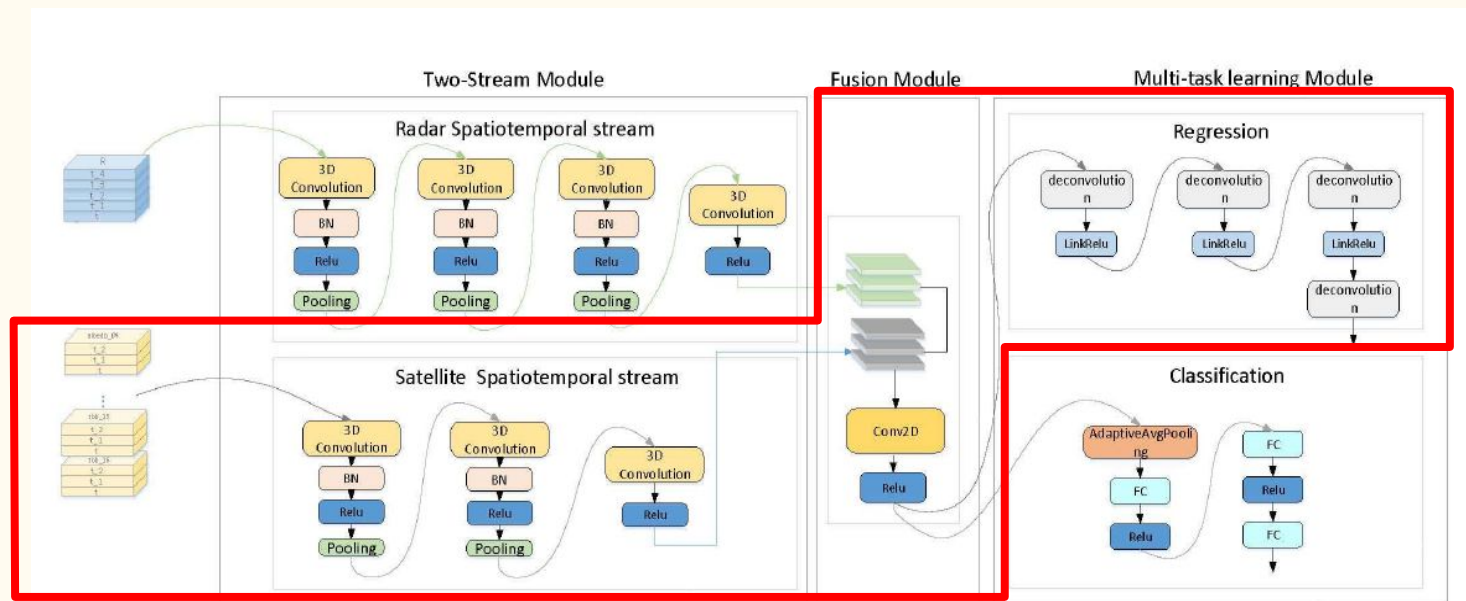


Volúmenes de entrenamiento
(banda x tiempo x latitud x longitud)

Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*.

<http://arxiv.org/abs/2010.14100>

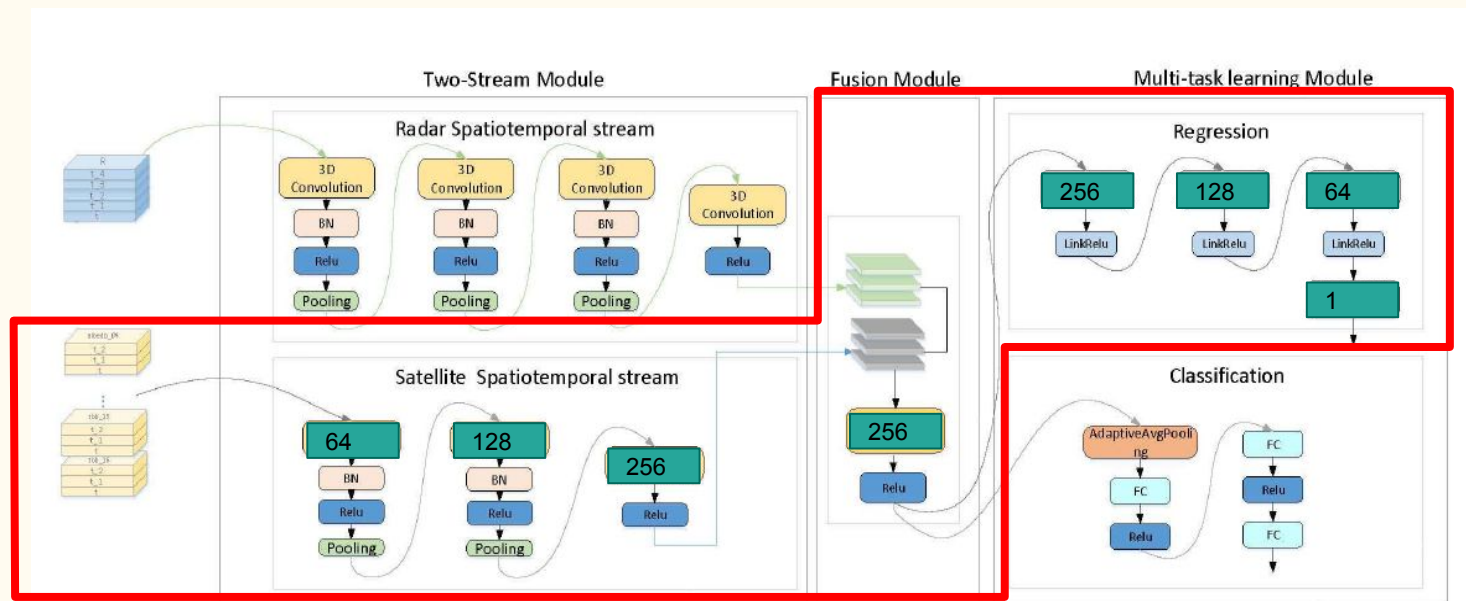
Arquitectura de la red neuronal



Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*.

<http://arxiv.org/abs/2010.14100>

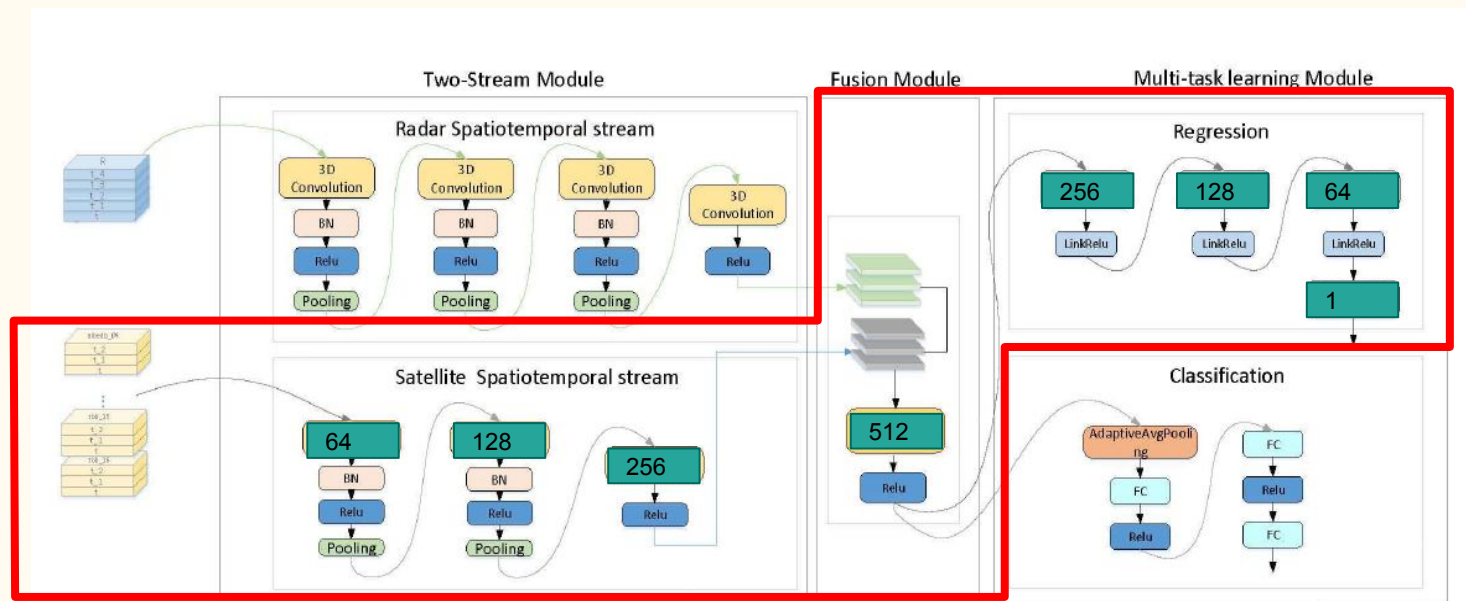
Arquitectura de la red neuronal



Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*.

<http://arxiv.org/abs/2010.14100>

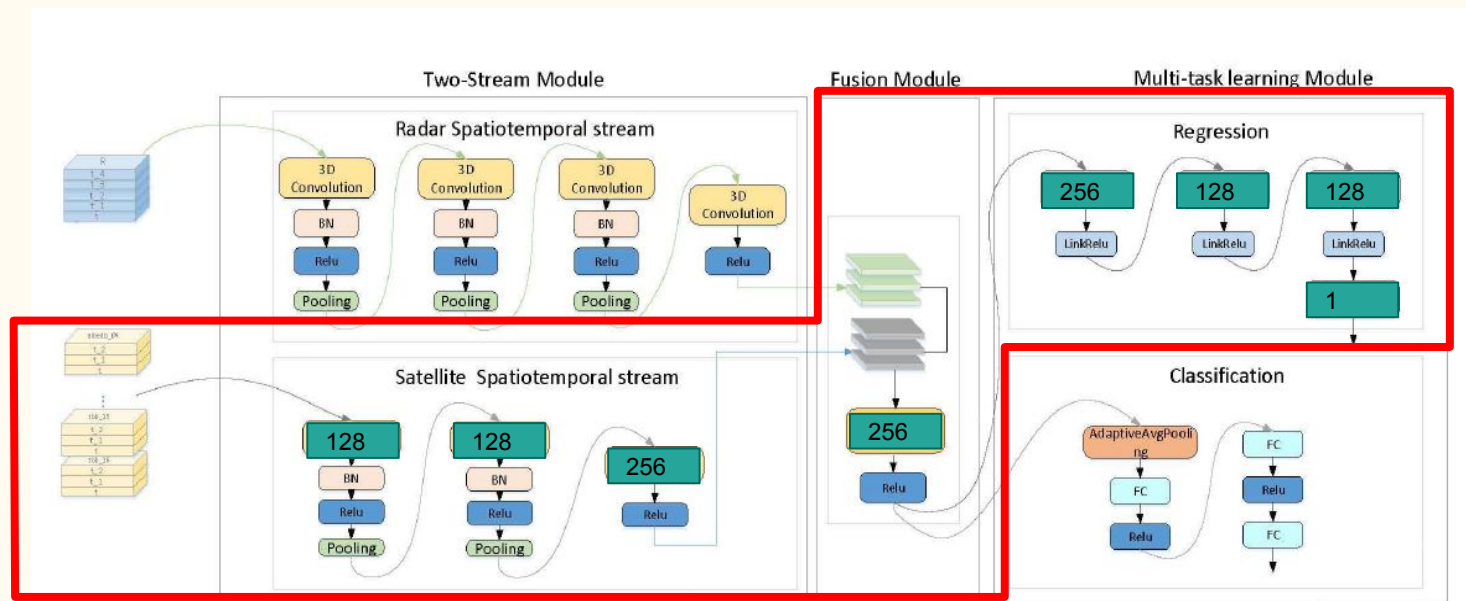
Arquitectura de la red neuronal



Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*.

<http://arxiv.org/abs/2010.14100>

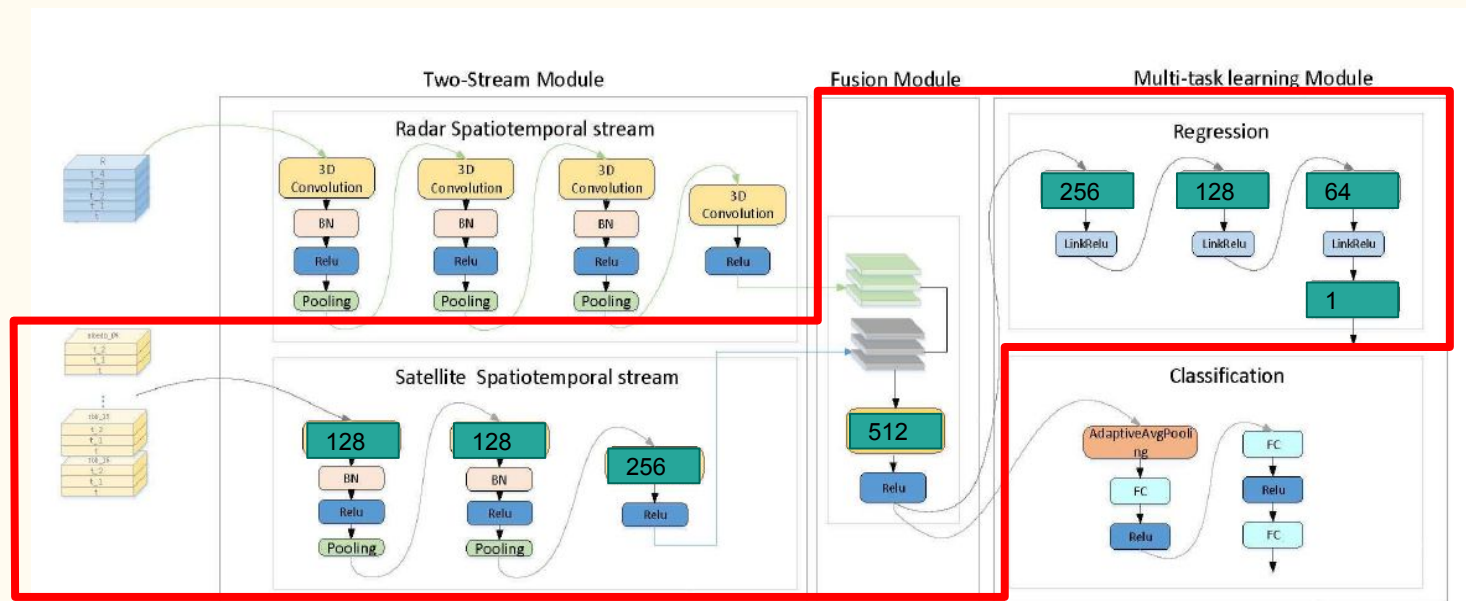
Arquitectura de la red neuronal



Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*.

<http://arxiv.org/abs/2010.14100>

Arquitectura de la red neuronal



Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*.

<http://arxiv.org/abs/2010.14100>

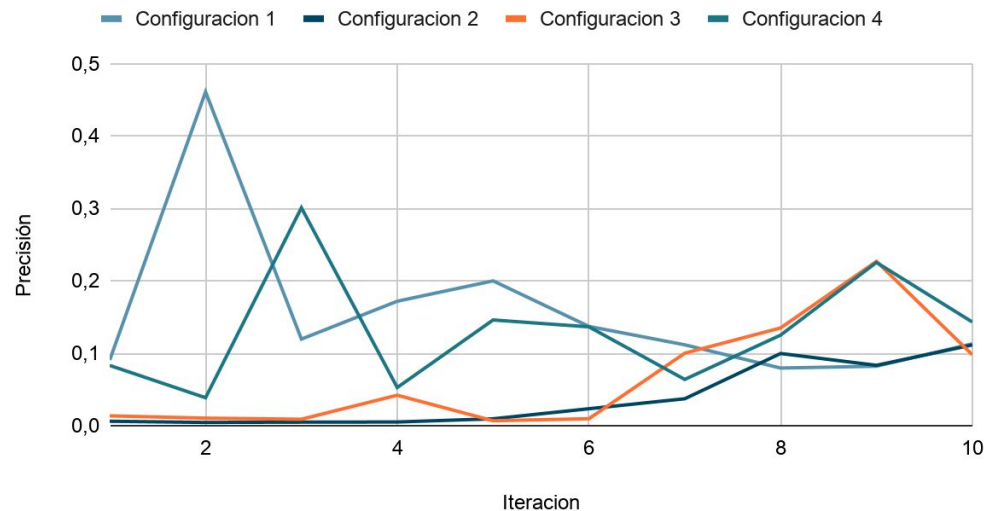
Resultados



Resultados de la red espaciotemporal


Tras 10 iteraciones no se observó un aprendizaje de la red para ninguna de las configuraciones probadas

Precisión




Resultados del entrenamiento Unet


Precisión tras 10 iteraciones
utilizando una velocidad de
aprendizaje de 0.001
Entrenamiento 0.9805
Validación 0.9726



Segmentacion de imagenes con la red




Máscara original




Máscara predicha

Segmentacion de imagenes con la red




Máscara original

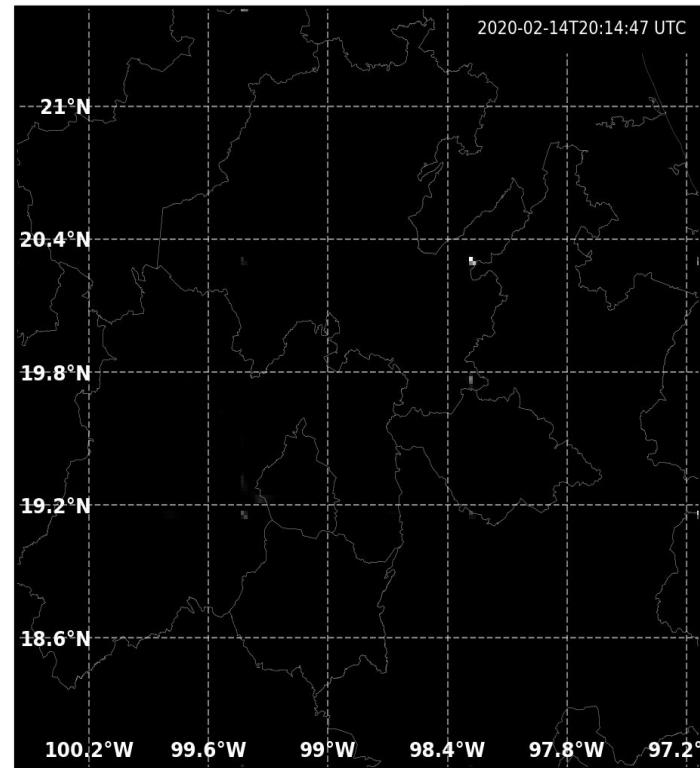



Máscara predicha

Resultados finales




Temperatura del tope de nubes

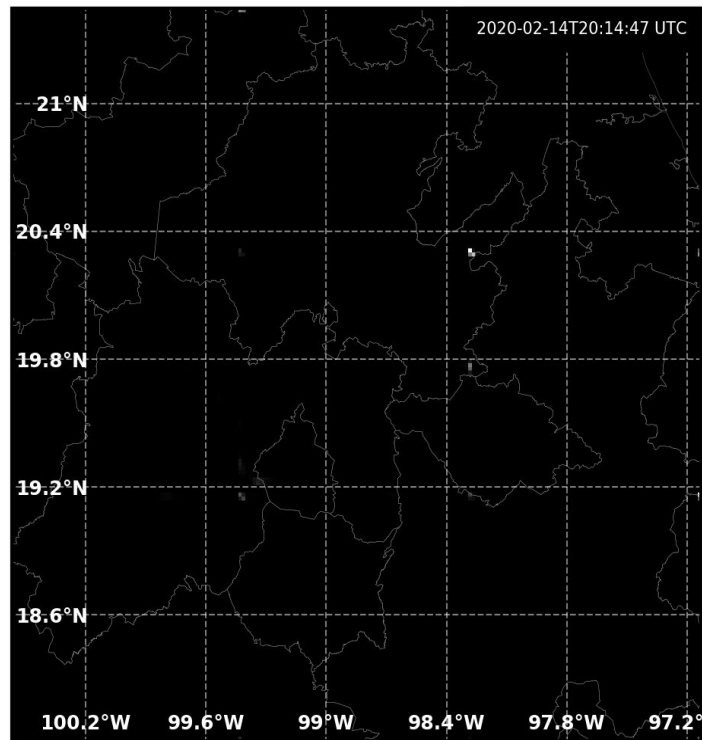



Máscaras predichas + datos del GLM

Resultados finales



Gradientes de temperatura en el tope de nube



Máscaras predichas + datos del GLM

Conclusiones

- Se logró obtener una máscara de nubes que posiblemente sean de origen convectivo utilizando una red neuronal convolucional.
- Sin embargo, debido a la poca información con la que se cuenta no es posible asegurar que siempre identificará de forma adecuada las nubes convectivas.
- El uso en conjunto de las máscaras y datos de otras variables asociados a la actividad convectiva en la atmósfera pueden llegar conjuntar un sistema que permita detectar el desarrollo de nubes convectivas de forma temprana.

Referencias

- Lee, S., Han, H., Im, J., Jang, E., & Lee, M.-I. (2017). Detection of deterministic and probabilistic convection initiation using Himawari-8 Advanced Himawari Imager data. *Atmospheric Measurement Techniques*, 10(5), 1859–1874. <https://doi.org/10.5194/amt-10-1859-2017>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv:1505.04597 [cs]*. <http://arxiv.org/abs/1505.04597>
- Zhang, W., Liu, H., Li, P., & Han, L. (2020). A Multi-task Two-stream Spatiotemporal Convolutional Neural Network for Convective Storm Nowcasting. *arXiv:2010.14100 [physics]*. <http://arxiv.org/abs/2010.14100>
- Wang, H., Chen, G., Lei, H., Wang, Y., & Tang, S. (2016, julio 19). *Improving the Predictability of Severe Convective Weather Processes by Using Wind Vectors and Potential Temperature Changes: A Case Study of a Severe Thunderstorm* [Research Article]. *Advances in Meteorology*. <https://doi.org/https://doi.org/10.1155/2016/8320189>
- Klein, B., Wolf, L., & Afek, Y. (2015). A dynamic convolutional layer for short range weather prediction. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4840-4848).
- Roesch, I., & Günther, T. (2019). Visualization of Neural Network Predictions for Weather Forecasting. *Computer Graphics Forum*, 38(1), 209–220. <https://doi.org/https://doi.org/10.1111/cgf.13453>
- Tran, D., Bourdev, L., Fergus, R., Torresani, L., & Paluri, M. (2015). *Learning Spatiotemporal Features With 3D Convolutional Networks*. 4489–4497. https://openaccess.thecvf.com/content_iccv_2015/html/Tran_Learning_Spatiotemporal_Features_ICCV_2015_paper.html
- A Probabilistic Multispectral Pattern Recognition Method for Detection of Overshooting Cloud Tops Using Passive Satellite Imager Observations in: Journal of Applied Meteorology and Climatology Volume 55 Issue 9 (2016)*. <https://journals.ametsoc.org/view/journals/apme/55/9/jamc-d-15-0249.1.xml>

Referencias

- Giaiotti, D. B., & Stel, F. (2007). General considerations on the operational forecasts of severe convective events: from short range to nowcasting. In *Atmospheric Convection: Research and Operational Forecasting Aspects* (pp. 177-194). Springer, Vienna.
- Bedka, K., Murillo, E. M., Homeyer, C. R., Scarino, B., & Mersiovsky, H. (2018). The above-anvil cirrus plume: An important severe weather indicator in visible and infrared satellite imagery. *Weather and Forecasting*, 33(5), 1159-1181.
- Markowski P. (2007) An Overview of Atmospheric Convection. In: Giaiotti D.B., Steinacker R., Stel F. (eds) *Atmospheric Convection: Research and Operational Forecasting Aspects*. CISM International Centre for Mechanical Sciences, vol 475. Springer, Vienna
- Markowski P. (2007) The Concept of Buoyancy and Its Application to Deep Moist Convection. In: Giaiotti D.B., Steinacker R., Stel F. (eds) *Atmospheric Convection: Research and Operational Forecasting Aspects*. CISM International Centre for Mechanical Sciences, vol 475. Springer, Vienna
- Markowski P. (2007) Convective Storm Initiation and Organization. In: Giaiotti D.B., Steinacker R., Stel F. (eds) *Atmospheric Convection: Research and Operational Forecasting Aspects*. CISM International Centre for Mechanical Sciences, vol 475. Springer, Vienna
- Markowski P. (2007) Supercell Thunderstorms. In: Giaiotti D.B., Steinacker R., Stel F. (eds) *Atmospheric Convection: Research and Operational Forecasting Aspects*. CISM International Centre for Mechanical Sciences, vol 475. Springer, Vienna
- Liu, Q., Li, Y., Yu, M., Chiu, L. S., Hao, X., Duffy, D. Q., & Yang, C. (2019). Daytime Rainy Cloud Detection and Convective Precipitation Delineation Based on a Deep Neural Network Method Using GOES-16 ABI Images. *Remote Sensing*, 11(21), 2555. <https://doi.org/10.3390/rs11212555>
- LeNail, (2019). NN-SVG: Publication-Ready Neural Network Architecture Schematics. *Journal of Open Source Software*, 4(33), 747, <https://doi.org/10.21105/joss.00747>