

Inteligencia artificial aplicada a la meteorología del espacio: pronóstico usando “transfer learning” para Tucumán

NAMOUR, Jorge ¹ ; VILLEGAS, Atuel ^{1,2} ; MELENDI, Yamila ^{1,4,5} ; ARGÜELLES, Noelia ^{1,2} ; PAZ, Marcos ¹ ; ASAMOA, Eric ³ ; CESARONI, Claudio ³ ; MOLINA, María ^{1,2,3} 

¹, Universidad Nacional de Tucumán, Facultad de Ciencias Exactas y Tecnología (FACET-UNT), Tucumán Space Weather Center (TSWC). R. Argentina.

² Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), R. Argentina.

³ Instituto Nazionale di Geofisica e Vulcanologia (INGV). Italy.

⁴ Universidad Nacional del Sur (UNS), Departamento de Física, Bahía Blanca. R. Argentina.

⁵ Instituto de Física del Sur (CONICET-UNS), Bahía Blanca. R. Argentina.

Autor para correspondencia: NAMOUR, Jorge (jnamour@herrera.unt.edu.ar)

Resumen

El pronóstico de las condiciones de la ionosfera es crítico para aplicaciones de meteorología del espacio (ME, o en Inglés, Space Weather - SW) debido a la relación entre el estado de esta región de la alta atmósfera con numerosas tecnologías satelitales como pueden ser las telecomunicaciones. Como en casi todos los subdominios que integran el sistema Sol-Tierra, existen diferentes modelos físicos y empíricos y en los últimos años los métodos basados en inteligencia artificial (IA) han comenzado a tener resultados muy significativos en particular en lo referente a aplicaciones operativas. En general, entrenar adecuadamente modelos de IA requiere de un gran volumen de datos con suficientes casos representativos a partir de los cuales se pueda “aprender”. En la mayoría de los casos, tener un conjunto de datos suficientemente grande es crítico para desarrollar modelos adecuados. Sin embargo, en ME, como en otros campos, no siempre se cuenta con conjuntos de datos adecuados y es en este punto cuando técnicas como la transferencia de conocimiento o “transfer learning” es especialmente útil. En este trabajo proponemos el desarrollo de un modelo de IA basado en transferencia de conocimiento para “transferir” lo aprendido en un modelo global del contenido electrónico total (TEC, Total Electron Content) de la ionosfera a un modelo local para Tucumán. Se muestra como en condiciones calmas esta transferencia logra adaptar y re entrenar con pocos datos de manera adecuada (con errores similares) el modelo global al modelo para Tucumán. Sin embargo, para condiciones perturbadas el modelo no se adecua correctamente por lo que se propone a futuro realizar un mejor estudio de las características utilizadas, mejorar el conjunto de datos y ajustar mejor los hiperparámetros.

Palabras clave: Meteorología del espacio; Inteligencia artificial; Ionosfera

Ionospheric Forecasting and Transfer Learning for Space Weather Applications

Abstract

Forecasting ionospheric conditions is critical for Space Weather (SW) applications due to the relationship between the state of this upper atmospheric region and numerous satellite technologies such as telecommunications. As in nearly all subdomains that comprise the Sun-Earth system, there exist different physical and empirical models, and in recent years methods based on artificial intelligence (AI) have begun to yield highly significant results, particularly regarding operational applications. In general, properly training AI models requires a large volume of data with sufficient representative cases

from which to "learn." In most cases, having a sufficiently large dataset is critical for developing adequate models. However, in Space Weather, as in other fields, adequate datasets are not always available, and it is at this point when techniques such as transfer learning become especially useful.

In this work, we propose the development of an AI model based on transfer learning to "transfer" the knowledge learned from a global model of the ionospheric Total Electron Content (TEC) to a local model for Tucumán. We show how under quiet conditions this transfer successfully adapts and retrains the global model to the Tucumán model adequately with little data (with similar errors). However, under disturbed conditions the model does not adapt correctly, so we propose for future work to conduct a better study of the features used, improve the dataset, and better adjust the hyperparameters.

Keywords: Space weather; Artificial intelligence; Ionosphere.

© 2025 Los autores. Este artículo es de acceso abierto y se distribuye bajo los términos de la Licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0). Esta licencia permite el uso, la distribución y la reproducción no comercial en cualquier medio. Siempre que se cite adecuadamente la obra original, cualquier obra derivada debe publicarse bajo la misma licencia.

Introducción

La meteorología del espacio es un campo de estudio de gran complejidad que involucra múltiples dominios altamente acoplados del sistema Sol-Tierra, con escalas espaciales y temporales diversas. Estudia, por ejemplo, los eventos originados en el Sol que se propagan a través del medio interplanetario y que pueden afectar significativamente el geoespacio y en particular a la ionosfera terrestre debido a la interacción entre el viento solar, la magnetosfera y la alta atmósfera (Zolesi y Cander, 2014). Los efectos de la meteorología del espacio, debido a la dependencia de la sociedad actual respecto a las tecnologías, pueden impactar nocivamente en el desarrollo de las actividades humanas socio-económicas. Por ejemplo, perturbaciones en la ionosfera pueden tener un impacto directo en sistemas de navegación y telecomunicaciones basados en GNSS (Global Navigation Satelital System) (entre otras tecnologías) provocando, por ejemplo, errores en el posicionamiento preciso o produciendo la disrupción de señales en las señales de radio. En consecuencia, estos impactos nocivos de la meteorología del espacio pueden producir grandes pérdidas económicas o incluso afectar la salud humana, lo que ha impulsado la necesidad de desarrollar métodos de predicción confiables y eficientes (Camporeale et al., 2018). Para la meteorología del espacio, es fundamental entender y pronosticar las condiciones de la ionosfera.

Así, en los últimos años, los avances y disponibilidad de datos provenientes de instrumentos en tierra (como ser radares ionosféricos, receptores GNSS, etc.) y misiones

espaciales han permitido mejorar la capacidad de monitoreo y predicción de los efectos de la meteorología del espacio en la ionosfera. En general existen dos enfoques principales para la predicción ionosférica: (i) modelos físicos o semiempíricos con asimilación de datos y (ii) modelos completamente basados en datos, incluyendo técnicas de inteligencia artificial (IA) (Camporeale et al., 2018). Dentro de este último enfoque, las redes neuronales han sido ampliamente utilizadas desde finales de los años 90, y recientemente se ha explorado el uso de técnicas de aprendizaje profundo (Deep Learning, DL), como redes neuronales de memoria a largo corto plazo (LSTM), unidades recurrentes con compuertas (GRU) y redes neuronales convolucionales (CNN), entre otras. En este contexto, el presente trabajo tiene como objetivo validar los modelos de IA para predicción de Contenido Total de Electrones (TEC) de la ionosfera desarrollados en Molina et al. (2023) mediante datos obtenidos para la estación de baja latitud de Tucumán, Argentina (lat 26.9°, long 65.4°). El modelo original utiliza un esquema de redes neuronales no autorregresivas con variable exógena (NNARX) para la predicción en una grilla de datos a nivel mundial (a partir de 18 puntos iniciales) usando mapas ionosféricos globales o GIM (Global Ionospheric Maps) con una resolución temporal de 2 hs. El mencionado trabajo concluye que la arquitectura más adecuada es CNN utilizando además el índice geomagnético Kp como variable exógena con el objetivo de predecir las próximas 24 hs con un RMSE que varía entre 1 y 4.5 TECu con aprendizaje incremental, y entre 1 y 6 TECu en caso de no usar aprendizaje incremental, para estaciones

ubicadas en diferentes regiones geográficas. Es importante notar que para estaciones de baja latitud, como Tucumán, los errores son significativamente mayores que para las otras estaciones.

En este trabajo, se propone evaluar el desempeño del modelo propuesto en Molina et al. (2023) que se basa en redes CNN manteniendo un horizonte de predicción de 24 hs. La validación del modelo está basada en el concepto de “transfer learning” (aprendizaje por transferencia) que es una técnica de aprendizaje automático donde un modelo previamente entrenado en una tarea, se reutiliza (total o parcialmente) para otra tarea relacionada (Devlin et al., 2019).

A través de la implementación de transfer learning sobre el modelo basado en CNN y su validación, se espera contribuir a la mejora de las capacidades de predicción ionosférica en la región, fortaleciendo los servicios de meteorología del espacio en el Centro de Clima Espacial de Tucumán (TSWC - <https://spaceweather.facet.unt.edu.ar/>) de la FACET y su integración con plataformas operacionales de monitoreo de meteorología del espacio.

Datos y Metodología

A diferencia del modelo entrenado en Molina et al.(2023), donde se usan series temporales de TEC derivadas de mapas GIM a nivel global, en este trabajo proponemos transferir el conocimiento para pronosticar el TEC para la estación TUCU correspondiente a Tucumán (26°49'S, 65°13'O) derivado de datos obtenidos en la red RAMSAC (<https://www.ign.gob.ar/NuestrasActividades/Geodesia/Ramsac>). De este modo el objetivo es transferir el conocimiento adquirido en un modelo global a un modelo local. Respecto a la resolución de los datos, se mantuvo la misma resolución temporal de 2 hs. con una ventana de pronóstico a 24 hs.

En la Tabla 1 se muestran los nombres de las estaciones originales seleccionadas del modelo original que luego será transferido a la estación ionosférica Tucumán. A su vez, el mapa de la Figura 1 muestra la locación de estas estaciones con respecto a la estación Tucumán.

Tabla 1: Detalle de cada estación, su latitud y longitud geográfica y geomagnética consideradas.

Estación	Latitud geográfica	Longitud geográfica	Latitud geomagnética	Longitud geomagnética
Estación 1 (ST1)	-50°	-120°	-41.21°	19.38°
Estación 2 (ST2)	-50°	0°	-46.34°	63.22°
Estación 3 (ST3)	-20°	-120°	-11.35°	45.24°
Estación 4 (ST4)	-20°	0°	-16.92°	69.85°



Figura 1: Detalle de cada estación, su latitud y longitud geográfica y geomagnética consideradas.

Respecto a las series de datos utilizadas:

- Los datos de TEC globales (conjunto de datos 1) para el entrenamiento de los modelos utilizados para *transfer learning*, fueron obtenidos a partir de los denominados GIMs provistos por el International GNSS Service (IGS) (<https://igs.org/>). Se utilizaron las estaciones de la Tabla 1, alrededor de Tucumán.
- Los datos de TEC locales para la estación TUCU (conjunto de datos 2) fueron calibrados a partir de datos Global Navigation Satellite System (GNSS) usando el algoritmo desarrollado por Ciraolo et al. (2007).
- Los datos del índice Kp, que fueron utilizados como variables exógena tanto para el modelado como para la validación, fueron obtenidos de <https://kp.gfz-potsdam.de/en/>

Respecto a la metodología utilizada, en este trabajo se propone utilizar el modelo previamente entrenado y “transferir” ese modelo a un nuevo conjunto de datos. Existen muchas definiciones y terminologías respecto al concepto de transfer learning e incluso algunas inconsistencias respecto a las mismas (Weiss et al., 2016). En líneas generales, se puede definir transfer learning como el proceso de adaptar un modelo a uno o más dominios con el fin de transferir información para mejorar el aprendizaje de un determinado objetivo o *target*. Es decir, en lugar de entrenar un modelo desde cero, se aprovecha el conocimiento adquirido en un dominio para mejorar el aprendizaje en otro, lo que acelera el entrenamiento y mejora la precisión, especialmente cuando los datos son limitados. Esta estrategia fue especialmente relevante debido a que los datos calibrados para Tucumán son significativamente menores en volumen.

La Figura 2 muestra un esquema donde un primer modelo se obtiene mediante el proceso de aprendizaje sobre un ‘conjunto de datos 1’, dicho modelo constituye el conocimiento adquirido. El modelo final se obtendrá a partir de ese conocimiento generado y del aprendizaje sobre un nuevo conjunto de datos (conjunto de datos 2).




Figura 2: Esquema de transferencia de conocimiento. El conocimiento adquirido mediante el aprendizaje sobre el conjunto de datos 1 es reutilizado en combinación con el aprendizaje sobre el segundo conjunto.

En este caso, se utilizan los modelos pre entrenados, basados en CNN, para ser transferidos a la estación Tucumán. Además, se propone un esquema de actualización de los modelos con datos recientes para optimizar su desempeño en escenarios operacionales en tiempo real. Es decir, se utilizará el concepto de aprendizaje incremental que se basa en el re-entrenamiento de un modelo a medida que llegan datos nuevos. Este reentrenamiento no es sobre el total de las muestras, sino que los pesos del modelo son ajustados de acuerdo a los nuevos datos.

Los modelos previamente entrenados se basaron en datos de TEC y Kp que van desde el año 2005 al año 2016. Este rango de datos intersecta el rango de años del ciclo solar número 24, que se extiende desde el año 2008 al 2019, teniendo su máximo solar aproximadamente entre los años 2012 a 2015. La relación del rango seleccionado y su relación con el ciclo solar, permitió realizar un análisis estadístico, ingeniería de características, y búsqueda de patrones de comportamiento de las series de tiempo que posibilitaron entrenar

los modelos mediante diferentes configuraciones de hiper parámetros. El resultado fueron 18 modelos independientes (cada uno para una estación en las diferentes regiones del globo).

En términos generales, el objetivo del presente trabajo es el de a partir del modelo más adecuado, de entre los ya entrenados (corresponde al aprendizaje de la tarea 1 sobre el conjunto de datos 1 esquematizado en la Figura 2), transferir ese aprendizaje para un nuevo conjunto de datos para obtener un modelo más robusto y de menor costo de entrenamiento sobre el nuevo conjunto de datos correspondiente a Tucuman (conjunto de datos 2 en la Figura 2).

El siguiente algoritmo describe esta metodología:

ALGORITMO TransferTEC

1. Elegir 4 modelos ya entrenados sobre el conjunto de datos 1 para las estaciones más cercanas a Tucuman (estación TUCU, lat = -26.9°, long = -65.4°).
2. Dividir el conjunto de datos 2 de la estación TUCU en dos subconjuntos: 'train' y 'test'
3. Reentrenar los 4 modelos seleccionados sobre el subconjunto train del conjunto de datos 2
4. Elegir el mejor modelo de entre los 4
5. Validar usando el conjunto 'test' del conjunto de datos 2

El conjunto de datos 2 es utilizado para el reajuste de los 4 modelos descritos en la Tabla 1 para períodos pertenecientes al año 2017. Este segundo conjunto a su vez está dividido en dos conjuntos, un conjunto de entrenamiento y un conjunto de prueba en una relación 80/20 según los casos analizados.

Resultados

Una característica importante de los modelos CNN en comparación con LSTM y GRU es que el modelo CNN parece tener mayor estabilidad y es capaz de considerar mejor los cambios rápidos en las series temporales. Esto se debe a que CNN utiliza kernels para crear los denominados mapas de características, que suelen considerar la relación/ dependencias/ información espacial del entorno de una muestra dada (dependiendo del tamaño del kernel) (Lecun et al., 1998; O'Shea y Nash,

2015; Ajit et al., 2020). El tamaño del kernel es 2, lo que significa que se utiliza una ventana deslizante de 2x2 para construir el mapa de características. Cabe destacar que, para el caso de series temporales, el tamaño del kernel o filtro hace referencia a la relación temporal de las muestras y no a la relación espacial. Cada ventana se compone de 2 muestras de cada característica (TEC, Kp) y, para este método, el mapa de características considera la siguiente muestra inmediata (próximas 2 horas). Por lo tanto, CNN considera la relación a corto plazo, que no es considerada por los otros dos modelos de RNN (LSTM y GRU). Esta corta escala temporal es muy importante para la rápida variabilidad que se observa a menudo en la ionosfera desde la perspectiva de irregularidades debido a la meteorología del espacio.

Como se mencionó anteriormente, para el entrenamiento de los modelos originales se tuvo en cuenta los datos del año 2005 al año 2016, y para la validación de los mismos, se utilizaron los datos del año 2017 (año posterior al último año de datos utilizados para el entrenamiento de los modelos).

Sin embargo, la serie de datos de la estación TUCU no coincide con estas fechas. De hecho el conjunto de datos para TUCU es bastante pequeño y con un gran número de datos faltantes. Es por esto que se plantea el transfer learning, posibilitando tener un buen resultado a pesar de no tener un gran conjunto de datos. Retomando el algoritmo TransferTEC y adaptándolo a nuestro problema:

ALGORITMO TransferTEC

1. Probar los modelos ST1, ST2, ST3 y ST4 sobre los datos de la estación TUCU
2. Dividir el conjunto de datos de la estación TUCU en TUCU_train y TUCU_test
3. Reentrenar ST1, ST2, ST3 y ST4 sobre los datos TUCU_train
4. Elegir el mejor modelo reentrenado
5. Validar usando TUCU_test

Donde el conjunto de datos 2 denominado TUCU consta de las siguientes fechas/horas para los casos analizados:

1. Caso 1 - ionosfera tranquila (sin influencia de tormenta geomagnética): datos correspondientes a los primeros días del año 2017 sin datos faltantes, se seleccionaron dos rangos de fechas:

- Rango de 48 hs. con inicio y fin diferentes a la hora 00:00.
- Rango de 48 hs. con inicio y fin en hora 00:00

La elección de a) y b) se realizó de esta manera debido a la disponibilidad de los datos, particularmente para garantizar que no hayan gaps de datos. La característica ionosférica en ambos casos es que se trataron de periodos tranquilos ($Kp < 3$).

- Caso 2 - en condiciones perturbadas (con influencia de tormenta geomagnética): datos correspondiente al año 2017 durante la ocurrencia de una tormenta geomagnética fuerte alcanzando un valor de $Kp=7$ (<https://www.swpc.noaa.gov/noaa-scales-explanation>).

El primer paso del algoritmo es probar cada uno de los modelos sobre el conjunto de datos

TUCU. Es decir, se calcularon los errores de aplicar ST1(TUCU), ST2(TUCU), ST3(TUCU) y ST4(TUCU) para los dos casos, caso 1 (sin tormenta geomagnética o de condiciones calmas) y caso 2 (con tormenta geomagnética o de condiciones perturbadas).

De esta manera para el Caso 1, a) la Tabla 2 muestra el RMSE para datos desde 04-01-2017 14:00 al 06-01-2017 14:00 (UT).

Tabla 2: RMSE obtenido para cada modelo sobre el nuevo conjunto de datos TUCU.

Modelo/Estación	RMSE (TECU)
ST1/ TUCU	3.83
ST2/TUCU	3.84
ST3/ TUCU	3.80
ST4/TUCU	3.43




Figura 3: Predicción usando el modelo original sobre el conjunto TUCU. La línea azul representa las observaciones y la línea naranja la predicción.

Para el Caso 1, b) la Tabla 3 muestra el RMSE para datos en el rango que va desde el 05-01-2017 00:00 al 07-01-2017 00:00.

Tabla 3: RMSE obtenido para cada modelo sobre el nuevo conjunto de datos TUCU.

Modelo/Estación	RMSE (TECU)
ST1 /TUCU	2.04
ST2 /TUCU	2.14
ST3 /TUCU	1.99
ST4 /TUCU	2.15

Para el Caso 2, el periodo analizado, en el que ocurre una tormenta geomagnética ($K_p=7$) que impacta en la ionosfera de Tucuman, pertenece al rango del 27 al 31 de mayo de 2017. De la misma manera que en los casos anteriores, la principal restricción al momento de analizar nuevos conjuntos de datos es la poca disponibilidad sin datos erróneos y con pocos faltantes para la estación TUCU. Hay que tener en cuenta que, los datos de TEC de la estación Tucumán disponibles para el rango analizado, van desde el 26-05-2017 00:00 al 30-05-2017 04:00, no siendo posible disponer de la totalidad de valores para todo el rango de datos. Sin embargo, en próximos trabajos se espera poder ampliar el rango disponible a medida que se obtengan nuevos datos.

Como era esperado, en condiciones perturbadas la performance de los modelos decae significativamente.

Tabla 4: RMSE obtenido para cada modelo sobre el nuevo conjunto de datos TUCU, para condiciones perturbadas.

Modelo / Estación	RMSE (TECu)
ST1 / TUCU	4.32
ST2 / TUCU	4.85
ST3 / TUCU	4.29
ST4 / TUCU	4.53

Como se puede observar en las Figuras 3, 4 y 5, más allá de que los errores no crecen demasiado en comparación con los pronósticos globales, el pronóstico local parece no seguir adecuadamente la variabilidad de las observaciones. Este problema es más crítico en el caso de estudio de la ionosfera perturbada donde se observa, por ejemplo, que los valores extremos ocasionados por la tormenta geomagnética (pico más alto).

A continuación, el algoritmo TransferTEC indica el proceso de reentrenamiento de cada modelo de acuerdo al conjunto de datos TUCU_train. Durante este proceso se realizó también una puesta a punto o 'fine tuning' de los hiperparámetros de los modelos. En esta etapa se realiza efectivamente la transferencia del conocimiento adquirido durante el entrenamiento de los modelos globales.

Se reajustaron los siguientes hiperparámetros:

Cantidad de épocas: 2
Coeficiente de aprendizaje: 0.001
Tamaño de lote: 32

A partir de este nuevo reentrenamiento sobre TUCU_train se obtuvieron los siguientes resultados para el caso 1 a) (Tabla 5):

Tabla 5: Comparación entre los errores para los diferentes modelos sin y con reentrenamiento para la estación TUCU.

Modelo / Estación	RMSE (sin re entrenar)	RMSE (re entrenando)
ST1 / TUCU	3.83	3.77
ST2 / TUCU	3.84	3.72
ST3 / TUCU	3.80	3.69
ST4 / TUCU	3.43	3.31

De igual manera, los resultados para el caso 1 b) fueron (Tabla 6):

Tabla 6: Comparación entre los errores para los diferentes modelos sin y con reentrenamiento para la estación TUCU.

Modelo / Estación	RMSE (sin re entrenar)	RMSE (re entrenando)
ST1 / TUCU	2.04	2.12
ST2 / TUCU	2.14	2.22
ST3 / TUCU	1.99	2.11
ST4 / TUCU	2.15	2.24

De igual manera, los resultados obtenidos para el caso 2 son (Tabla 7):

Tabla 7: Comparación entre los errores para los diferentes modelos sin y con reentrenamiento para la estación TUCU.

Modelo / Estación	RMSE	RMSE (con re entrenamiento)
ST1 / TUCU	4.32	4.44
ST2 / TUCU	4.85	4.89
ST3 / TUCU	4.29	4.34
ST4 / TUCU	4.53	4.59




Figura 4: Predicción usando el modelo original sobre el conjunto TUCU. La línea azul representa las observaciones y la línea naranja la predicción.




Figura 5: Predicción usando el modelo original sobre el conjunto TUCU. La línea azul representa las observaciones y la línea naranja la predicción.




Figura 6: Comparación entre la observación (línea azul) y los pronósticos usando los modelos globales sin reentrenar (línea punteada en verde) y los pronósticos usando el conocimiento transferido con reentrenamiento (línea naranja).




Figura 7: Comparación entre la observación (línea azul) y los pronósticos usando los modelos globales sin reentrenar (línea punteada en verde) y los pronósticos usando el conocimiento transferido con reentrenamiento (línea naranja).




Figura 8: Comparación entre la observación y los pronósticos con y sin reentrenamiento.

Finalmente, a partir de los resultados obtenidos se selecciona el de mejor performance general.

Conclusiones

El principal objetivo de este trabajo es aplicar transferencia de conocimiento (*transfer learning*) de modelos globales de TEC a un modelo local para la estación de Tucumán.

En condiciones calmas (Caso 1a), el reentrenamiento sobre la estación TUCU permitió mejoras leves en el RMSE, con incrementos relativos entre ~1.6% y 3.5% según el modelo (ST1 a ST4). Para el Caso 1b, algunas estaciones muestran un ligero empeoramiento en RMSE con reentrenamiento, entre ~3.7% y 6.0%, indicando que la transferencia de conocimiento no siempre mejora la performance en todos los subconjuntos de datos.

En condiciones perturbadas (Caso 2), durante

la tormenta geomagnética, el reentrenamiento no produjo mejoras, y el RMSE aumentó levemente entre ~0.8% y 2.8%. Esto es consistente con la dificultad de predecir eventos extremos poco representados en los datos de entrenamiento. Futuras mejoras podrían lograrse incorporando más datos y variables externas adicionales (por ejemplo, índices Dst o SymH).

El resultado más significativo de este trabajo es el de haber realizado un primer modelo de pronóstico a 24 hs. de TEC para Tucumán usando transferencia de conocimiento a partir de un modelo global de TEC. Este nuevo modelo además, tiene la ventaja de no necesitar un gran conjunto de datos siendo especialmente relevante en el caso de TEC calibrado para una única estación donde muchas veces no se cuenta con grandes series de tiempo

REFERENCIAS

Ajit, A., Acharya, K. y Samanta, A. (2020) 'A review of convolutional neural networks', Proceedings of the 2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-

ETITE), Vellore, India, pp. 1–5. <https://doi.org/10.1109/ic-ETITE47903.2020.049>.

Camporeale, E., Wing, S. y Johnson, J. (2018) *Machine learning techniques for space weather*. Cambridge, MA: Elsevier. ISBN 978-0-12-811788-0

Cesaroni, C., Spogli, L., Aragon-Angel, A., Fiocca, M., Dear, V., De Franceschi, G. y Romano, V. (2020) 'Neural network based model for global Total Electron Content forecasting', *Journal of Space Weather and Space Climate*, 10, 11. Disponible en: <https://doi.org/10.1051/swsc/2020013>.

Ciraolo, L., Azpilicueta, F., Brunini, C., Meza, A. y Radicella, S. M. (2007) 'Calibration errors on experimental slant total electron content (TEC) determined with GPS', *Journal of Geodesy*, 81(2), pp. 111–120. Disponible en: <https://doi.org/10.1007/s00190-006-0093-1>

Devlin, J., Chang, M.-W., Lee, K. y Toutanova, K. (2019) 'BERT: Pre-training of deep bidirectional transformers for language understanding', *Proceedings of NAACL-HLT*.

LeCun, Y., Bottou, L., Bengio, Y. y Haffner, P. (1998), 'Gradient-based learning applied to document recognition', *Proceedings of the IEEE*, 86(11), pp. 2278–2324. Disponible en: <https://doi.org/10.1109/5.726791>

Molina, M. G., Namour, J. H., Cesaroni, C., Spogli, L., Argüelles, N. B. y Asamoah, E. N. (2023) 'Global TEC forecasting based on deep learning techniques: a comparative study and perspectives for a Space Weather operational service', *Journal of Atmospheric and Solar-Terrestrial Physics*. Disponible en: <https://doi.org/10.22541/essoar.168332189.94249853/v1>

O'Shea, K. y Nash, R. (2015), 'An introduction to convolutional neural networks', *arXiv preprint*, arXiv:1511.08458.

Weiss, K., Khoshgoftaar, T. M. y Wang, D. (2016) 'A survey of transfer learning', *Journal of Big Data*, 3, 9. Disponible en: <https://doi.org/10.1186/s40537-016-0043-6>

Zolesi, B. y Cander, L. R. (2014) *Ionospheric prediction and forecasting*. Springer.

AUTORES

NAMOUR, Jorge Habib

Jorge Namour es Licenciado en Informática. Docente del departamento de ciencias de la computación en la FACET-UNT. Es doctorando en Ciencias Exactas y Tecnología por la FACET-UNT. Su trabajo se centra en la aplicación de técnicas de inteligencia artificial y aprendizaje automático para la predicción y el análisis del Contenido Electrónico Total (TEC) ionosférico en el contexto de la meteorología del espacio. Sus líneas de investigación incluyen modelado de series temporales, redes neuronales profundas (LSTM, GRU y CNN), aprendizaje por transferencia y flujos de procesamiento de datos a gran escala. Además, participa en el desarrollo de infraestructuras de datos y pipelines de ciencia de datos orientados a aplicaciones científicas y operativas en el Tucumán Space Weather Center.

jnamour@herrera.unt.edu.ar

ORCID  0009-0004-7976-3701

VILLEGAS, Atuel

Atuel Villegas es estudiante de doctorado en el Tucumán Space Weather Center, donde investiga la aplicación de técnicas de inteligencia artificial (IA) al pronóstico y análisis de la ionosfera en el contexto de la meteorología del espacio. Es Licenciado en Física por la Universidad Nacional de Tucumán, durante la cual trabajó en el desarrollo de modelos sustitutos (surrogate models) para ondas gravitacionales.

aevillegas@herrera.unt.edu.ar

ORCID  0009-0000-4208-1345

MELENDI, Yamila D.

Yamila Melendi es estudiante de doctorado en Física y Licenciada en Geofísica por la Universidad Nacional del Sur (UNS). Su investigación se centra en estudiar y caracterizar distintas condiciones ionosféricas —tanto quietas como perturbadas— con énfasis en efectos asociados a la meteorología del espacio. Es miembro del Tucumán Space Weather Center, ayudante de docencia en la UNS, integrante del Programa de Mentoría AGATA y de ALAGE, y actualmente se desempeña como Secretaria de INTERALAGE. En 2024, durante el XIV COLAGE, recibió el Premio Roberto Manzano a la mejor contribución presentada donde un estudiante actúa como primer autor en la sesión de meteorología del espacio.

yamila.melendi@uns.edu.ar

ORCID  0009-0005-9817-7772

ARGÜELLES, Noelia B.

Egresada de la carrera de Licenciatura en Matemática por la Universidad Nacional de Tucumán, distinguida con un reconocimiento honorífico por alcanzar el promedio más alto de su cohorte en la Facultad de Ciencias Exactas y Tecnología (FACET) de la Universidad Nacional de Tucumán. Actualmente es estudiante de doctorado en Ciencias Exactas e Ingeniería en la FACET-UNT. Noelia también se desempeña como Profesora en matemática aplicada en FACET. Es miembro activo del Laboratorio Tucumán Space Weather Center en FACET; sus intereses de investigación incluyen el pronóstico en meteorología del espacio y la cuantificación de incertidumbre en métodos de machine learning.

arguellesnb@gmail.com

ORCID  0009-0003-9474-7868

PAZ, Marcos F

Marcos Fabián Paz es ingeniero electrónico, especializado en modelado electromagnético y ciencia de datos. Se desempeña como auxiliar docente en la Universidad Nacional de Tucumán (UNT) y en la Universidad Tecnológica Nacional (UTN), es profesor adjunto en la Universidad del Norte Santo Tomás de Aquino (UNSTA) e investigador en el Tucumán Space Weather Center (TSWC).

mfpaz@herrera.unt.edu.ar

ORCID  0000-0003-3272-2780

ASAMOAH, Eric Nana

El Dr. Eric Nana Asamoah es Investigador en etapa inicial (early-career Research Fellow) en el grupo de Física de la Alta Atmósfera y Radiopropagación del Istituto Nazionale di Geofisica e Vulcanologia (INGV) en Roma. Posee un doctorado en Ingeniería de Sistemas Complejos y se especializa en aprendizaje automático, con aplicaciones en ingeniería, meteorología del espacio y disciplinas afines. También posee una licenciatura en Matemática y una maestría en Modelado Matemático para Ingeniería.

ericnana.asamoah@ingv.it

ORCID  0009-0001-2060-2573

CESARONI, Claudio

El Dr. Claudio Cesaroni es Investigador Senior y Director del grupo “Física de la Alta Atmósfera y Radiopropagación” en el Istituto Nazionale di Geofisica e Vulcanologia (INGV) en Roma. Posee un doctorado en Geofísica y se especializa en dinámica ionosférica, meteorología del espacio y en la aplicación de Machine Learning a datos GNSS para modelos de nowcasting y pronóstico. Es titular de una patente internacional para el pronóstico a corto plazo de parámetros de centelleo. Recibió en 2023 la Medalla “Alexander Chizhevsky” por sus destacados logros en investigación ionosférica y en fortalecimiento de capacidades científicas. Actualmente es Investigador Principal de la contribución del INGV al Servicio de Meteorología del Espacio de la OACI y preside el grupo de trabajo sobre formación de la Comisión G de URSI. Es Editor Asociado de AGU Space Weather y AGU JGR Machine Learning and Computation, y ha publicado más de 80 artículos revisados por pares.

claudio.cesaroni@ingv.it

ORCID  0000-0003-2268-4389

MOLINA, María G.

La Dra. María Graciela Molina dirige el Tucumán Space Weather Center de FACET-UNT. Es profesora asociada en FACET-UNT, investigadora del CONICET e investigadora asociada del INGV. Actualmente se desempeña como presidenta de la Asociación Latinoamericana de Geofísica Espacial (ALAGE) y como officer en el próximo SCOSTEP/COURSE "Cross-scale cOUpling pRocesses in the Solar-tErrestrial system". Es experta en técnicas de Inteligencia Artificial y computación científica, así como en investigación ionosférica y de meteorología del espacio.

gmolina@herrera.unt.edu.ar

ORCID  0000-0003-2563-7457