

PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES

PREDICTION OF MARS METEOROLOGICAL VARIABLES USING ARTIFICIAL NEURAL NETWORKS

Alejandro de-Cabo-García¹, Alfonso Delgado-Bonal², Belén Pérez-Lancho¹, Germán Martínez³
Jorge Pla-García^{4,5}

1 University of Salamanca, Faculty of Sciences, (Spain)

2 NASA Goddard Space Flight Center, Maryland, (USA)

3 Lunar and Planetary Institute, Texas, (USA)

4 Centro de Astrobiología (CSIC-INTA), (Spain)

5 Space Science Institute, Boulder, Colorado, (USA)

Recibido: 4/may/21 -- Revisando: 4/may/21 -- Aceptado: 2/dic/21 - DOI: <https://doi.org/10.6036/NT10369>

To cite this article:

DE CABO-GARCIA, Alejandro, DELGADO-BONAL, Alfonso, PEREZ-LANCHO, María-Belén et al. PREDICTION OF MARS METEOROLOGICAL VARIABLES USING ARTIFICIAL NEURAL NETWORKS. DYNA New Technologies, Enero-Diciembre 2022, vol. 9, no. 1, [15p.]. DOI: <https://doi.org/10.6036/NT10369>

ABSTRACT

Weather forecasting is the task of determining future states of the atmosphere for a given location and time. The techniques to carry out the prediction range from deterministic approaches using complex fluid dynamics models to data-driven approaches using artificial intelligence. While the former is mainly focused on the creation of General Circulation Models, the later are starting to replace them in many situations for Earth's meteorology and astrophysics. Here, we develop an artificial neural network to perform Mars' weather forecasting using environmental measurements from the Vikings and Mars Science Laboratory missions. The methodology followed in of this study is a data-driven approach; we make use of computer science expertise which has been long applied to Earth, but not on Mars yet. To do so, we create an artificial neuronal network that predicts the meteorological conditions of the following day using the previous day as input. We show that temperature and pressure are among the most important variables, and that ANN can perform with a 0.5 to 1% accuracy in forecasting diurnal changes in the selected variables.

Keywords: ANN, Mars, Weather, Forecast, Curiosity

RESUMEN

La predicción meteorológica es la tarea de determinar los estados futuros de la atmósfera para un lugar y un momento determinados. Las técnicas para llevar a cabo la predicción van desde enfoques deterministas que utilizan complejos modelos de dinámica de fluidos hasta enfoques basados en datos que utilizan la inteligencia artificial. Mientras que los primeros se centran principalmente en la creación de Modelos de Circulación General, los segundos están empezando a sustituirlos en muchas situaciones de la meteorología y la astrofísica terrestre. En este trabajo desarrollamos modelos basados en redes neuronales artificiales para realizar la predicción meteorológica en Marte a partir de las mediciones ambientales obtenidas por las misiones Vikings y Mars Science Laboratory. La metodología seguida en este estudio es un enfoque basado en los datos que hace uso de los conocimientos informáticos que se han aplicado durante mucho tiempo en la Tierra, pero todavía no en Marte. Hemos diseñado y entrenado modelos neuronales que predicen condiciones meteorológicas de un día utilizando como entrada las variables del día anterior. En concreto hemos analizado la temperatura y la presión como variables más importantes, y hemos entrenado RNA consiguiendo una precisión de entre el 0,5 y el 1% en la predicción de los cambios diarios de las variables seleccionadas.

Palabras clave: Redes neuronales artificiales, Marte, Climatología, Curiosity.

1. INTRODUCCIÓN

La previsión meteorológica es la aplicación de la ciencia y la tecnología para predecir el estado de la atmósfera en un lugar y momento determinados. Una previsión requiere generalmente la recogida de datos cuantitativos terrestres y orbitales sobre el estado actual de la atmósfera. A continuación, estos datos son procesados por modelos físicos con el fin de estudiar, comprender y determinar el estado futuro de la atmósfera. Sin embargo, la falta de datos, la naturaleza compleja de los fenómenos atmosféricos y la comprensión incompleta de los patrones atmosféricos hacen que sea menos fiable a medida que aumenta el rango temporal de la predicción. Para predecir características específicas de la atmósfera, los Modelos de Circulación General (MCG) incluyen una amplia gama de variables para afinar los resultados que son difíciles de entender y trabajar.

Para superar estos aspectos, se está incrementando el uso de estructuras de Redes Neuronales Artificiales (en adelante, RNA) para predecir la evolución meteorológica, la mayoría de las cuales dirigen sus investigaciones hacia la Tierra.

Las RNA podrían considerarse un accesorio de los complejos modelos matemáticos utilizados para predecir el tiempo y a su vez

	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García	0403.01: Inteligencia artificial y simulación

podrían utilizarse para validar dichos modelos. Los enfoques basados en datos proporcionan resultados más rápidos y con mayor sencillez, pero no dan información sobre por qué el sistema tiene un comportamiento determinado. Por otro lado, los modelos de dinámica de fluidos ayudan a comprender la física y la química de la situación, pero sólo tras largos y costosos tiempos de cálculo. La mayor parte de la investigación de Marte hasta la fecha se ha realizado utilizando MCG, y nuestro objetivo con este estudio es proporcionar un sistema de software de ayuda basado en RNA para el estudio del clima de Marte.

Las primeras estructuras de RNA se desarrollaron a partir de modelos conocidos de sistemas nerviosos biológicos y del propio cerebro humano. Las unidades de procesamiento, llamadas neuronas artificiales, son modelos simplificados de una neurona biológica. Estos modelos se inspiraron en cómo la membrana celular de una neurona genera y propaga los impulsos [1].

Las RNA forman parte del área conocida como inteligencia artificial (IA) o inteligencia computacional. La inteligencia computacional se refiere a la capacidad de un ordenador para aprender una tarea específica a partir de la observación. Los métodos utilizados son similares a la forma de razonar del ser humano. En concreto, las RNA permiten que el sistema aprenda de la experiencia operando como uno biológico con un enfoque puramente basado en datos.

Las neuronas artificiales utilizadas en las RNA pueden ser no lineales, suelen proporcionar salidas continuas y realizan funciones sencillas, como recoger las señales disponibles en sus entradas, ensamblarlas según sus funciones y producir una respuesta teniendo en cuenta sus funciones de activación innatas.

Los enfoques de las RNA se han utilizado para resolver problemas del mundo real en muchos campos diferentes. Se ha demostrado que son una poderosa técnica de aprendizaje automático, utilizada con éxito para el reconocimiento de patrones, la elaboración de mapas estadísticos o el modelado. Se han aplicado con éxito a diferentes campos, como los procesos industriales, la medicina, los negocios o el reconocimiento de imágenes, y específicamente a la predicción meteorológica [2].

Predecir las tormentas eléctricas es una de las tareas más difíciles en la predicción meteorológica, debido a su extensión espacial y temporal bastante reducida y a la no linealidad inherente a su dinámica y su física. En esas situaciones, los modelos numéricos basados en la física de los fluidos pueden no proporcionar resultados fiables o depender de muchas otras variables desconocidas. En esas circunstancias, las técnicas de IA pueden resultar útiles para rellenar las lagunas de conocimiento. Por ejemplo, Mislán et al. [3] utilizaron RNA para predecir las precipitaciones mensuales en Indonesia, y Litta et al. [4] desarrollaron diferentes RNA para predecir las tormentas eléctricas durante el premonzón en Calcuta, India.

Además de la aplicación a fenómenos puntuales, las RNA pueden utilizarse para modelar el entorno de lugares concretos, como el trabajo de Datta et al. [5] sobre un análisis meteorológico estadístico completo de Austin (Texas). En la misma línea, Al-Kahlout et al. [6] pronosticaron incendios forestales utilizando RNA y datos meteorológicos recogidos en la región noreste de Portugal, y Doğançan Ulutas et al. [7] utilizaron técnicas similares para predecir las precipitaciones atmosféricas en Estambul.

Los enfoques basados en RNA son cada vez más frecuentes y se expanden a otras áreas de la meteorología. Recientemente, Lucas Olivera et al. [8] estudiaron la estimación de la radiación solar global horaria en la localidad de Florencio Varela, Buenos Aires. Utilizando IA Wu, J. et al. [9] desarrollaron un modelo de previsión de precipitaciones en zonas costeras, basado en redes neuronales convolucionales con aprendizaje profundo. Además, en lugar de centrarse en eventos aislados o en pequeñas áreas regionales, enfoques como el de Anochi et al. [10] muestran que es posible utilizar la RNA para pronosticar la precipitación en grandes áreas como la de Sudamérica.

Aunque estos estudios se están convirtiendo en la corriente principal, la meteorología de Marte no se ha investigado de forma exhaustiva utilizando las RNA. Marte y su clima han sido objeto de curiosidad científica durante siglos. Desde el siglo XVII se pudo estudiar el planeta rojo mediante observaciones desde la Tierra, pero no fue posible una exploración cercana hasta el inicio de la carrera espacial a mediados de la década de los sesenta. Gracias al desarrollo de la tecnología espacial, disponemos de cierta información sobre las variables meteorológicas de Marte, ya que las naves espaciales orbitales y de sobrevuelo han proporcionado datos desde arriba, mientras que los aterrizadores y los rovers han medido las condiciones atmosféricas directamente desde el suelo. El conocimiento actual de la atmósfera marciana procede de esos datos de observación [11], y en este trabajo proponemos un modelo de previsión meteorológica de Marte utilizando esos datos y una RNA.

La gran ventaja que tienen las RNA sobre otros métodos de previsión meteorológica es que no requieren el conocimiento explícito de las dinámicas que rigen el comportamiento de la atmósfera marciana, puesto que no se basan en la resolución numérica de los complejos modelos físicos y matemáticos, solo necesitan datos. La creciente disponibilidad y cantidad de dichos datos nos permite ya realizar ciertas predicciones, aunque todavía pueden fallar a la hora de captar sucesos aislados, como los remolinos de polvo, para los que aún no se dispone de un gran conjunto de eventos de entrenamiento.

En la sección 2, repasamos las magnitudes fisicoquímicas más importantes que determinan la meteorología de Marte e introducimos las variables seleccionadas en nuestro estudio, y en la sección 3 desarrollamos un conjunto de RNAs para los Viking Landers (VL) 1 y 2, y para el Mars Science Laboratory, explorando la transportabilidad de las redes para el VL1 y el VL2. Por último, resumimos nuestros resultados en el apartado de conclusiones.

	<p>PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES</p>	<p>Industrias de la información y del conocimiento</p>
<p>ARTÍCULO INVESTIGACIÓN</p>	<p>Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García</p>	<p>0403.01: Inteligencia artificial y simulación</p>

2. EL TIEMPO EN MARTE

La atmósfera de Marte presenta muchos de los fenómenos meteorológicos que se dan en la Tierra, como las perturbaciones baroclínicas, los frentes, la formación de nubes de hielo de CO₂ y de agua, la precipitación de nubes de hielo de CO₂, las tormentas de polvo o los diablos de polvo. Sin embargo, existen importantes diferencias con la Tierra, como su menor densidad atmosférica, su composición atmosférica completamente diferente, su compleja topografía caracterizada por una dicotomía entre ambos hemisferios o la gran variabilidad de polvo y agua en la atmósfera.

El entorno marciano actual no permite la formación de agua líquida pura en la superficie debido a las temperaturas relativamente frías, la baja presión atmosférica y la modesta cantidad de vapor de agua atmosférico [12]. Esto significa que no hay un calentamiento latente significativo en la atmósfera marciana debido al vapor de agua y, lo que es más importante, no hay disparidad entre los océanos y los continentes. Esto provoca una diferencia importante entre los dos planetas: en la Tierra, los océanos actúan como grandes cuerpos con una gran inercia térmica y escalas de tiempo de transporte lentas, capaces de contribuir al forzamiento atmosférico en escalas de tiempo largas y de suprimir parte de la variabilidad de la atmósfera, mientras que en Marte no existe este "acoplamiento" entre dos sistemas. Estas diferencias imponen restricciones a la utilización directa con variables marcianas de las RNA desarrolladas para la Tierra. Dado que estas RNA habrían sido entrenadas para imitar la atmósfera de nuestro planeta, los resultados no serían una representación válida de la atmósfera marciana. Por lo tanto, en este trabajo, creamos, entrenamos y ejecutamos una RNA sólo con datos de Marte sin basarnos en las RNA anteriores desarrolladas para la Tierra.

Uno de los principales parámetros meteorológicos de cualquier planeta es la temperatura de su superficie y de su atmósfera. Dado que la velocidad de las reacciones químicas está modulada por la temperatura, es de esperar que ésta desempeñe un papel importante en el desarrollo de una RNA para Marte. En la actualidad, Marte es mucho más frío que la Tierra (la temperatura media del aire es de -63 °C) porque, además de estar situado a una distancia de 1,52 UA del Sol, su atmósfera más fina provoca una constante de tiempo radiativa pequeña y un menor calentamiento por efecto invernadero. La delgada atmósfera marciana, junto con la mencionada ausencia de grandes volúmenes de agua líquida y la baja inercia térmica del suelo marciano, produce una gran amplitud térmica diurna que debe ser tenida en cuenta.

Sin embargo, de todos los planetas del Sistema Solar, Marte es el que presenta mayores similitudes con la Tierra, ya que está compuesto por roca y metales de alta densidad, y gira aproximadamente al mismo ritmo y en la misma dirección que la Tierra. Por tanto, la consideración de un enfoque basado en datos para estudiar la atmósfera marciana no es descabellada dado el éxito de la RNA aplicada a los estudios meteorológicos de la Tierra. Un día marciano, llamado "sol", dura 24 horas y 39 minutos (88775,245 segundos), y su año tiene una duración de 668,59 soles (aproximadamente dos años terrestres), razón por la cual las estaciones en Marte son aproximadamente el doble de largas que en la Tierra. El eje de rotación de Marte es también muy similar al de la Tierra, con una inclinación de 25 °C (frente a los 23,5 °C de la Tierra), pero la excentricidad de su órbita alrededor del sol es mucho mayor (0,093, mientras que la de la Tierra es de 0,017), lo que produce una gran diferencia en la irradiación solar máxima recibida en el hemisferio norte respecto al sur. En consecuencia, las estaciones son más extremas en el hemisferio sur: las temperaturas del verano pueden ser hasta 30 °C más cálidas que las del norte.

Para tener en cuenta estos hechos, en nuestro estudio parametrizamos la posición orbital de Marte utilizando la longitud solar (Ls), es decir, el ángulo que forma el planeta Marte con el Sol medido desde el equinoccio de primavera, donde Ls es 0. Así, Ls 90 corresponde al solsticio de verano, Ls 180 al equinoccio de otoño y Ls 270 al solsticio de invierno, todos ellos relativos al hemisferio norte.

Marte tiene una atmósfera predominantemente de dióxido de carbono (~95%), parte del cual se condensa en los polos estacionalmente. La presión global media en la superficie es de ~6 mbar (~1% de la presión terrestre). La presión global nos da cierta información sobre los cambios estacionales. Ambos casquetes polares están compuestos principalmente por una capa permanente de hielo de agua con una capa superficial de hielo de CO₂ por encima. Una de las principales diferencias entre los casquetes, además de su tamaño, es la profundidad de esa capa superficial de hielo de CO₂. En el casquete polar norte tiene aproximadamente 1 m de profundidad, por lo que se sublima completamente durante el verano y se condensa durante el invierno, mientras que el sur, con unos ~8 m de profundidad, solo se sublima parcialmente durante el verano, y por eso la capa de hielo de agua subyacente no queda expuesta en ningún momento del año marciano. El ciclo anual de irradiación solar produce entonces un intercambio de CO₂ entre los casquetes. Se intercambia aproximadamente un tercio de la atmósfera. Este ciclo, por tanto, controla el contenido atmosférico global de CO₂ y regula la presión media diaria en una determinada estación.

El polvo es omnipresente en la atmósfera marciana y afecta al estado térmico, radiativo y dinámico de la atmósfera. Afecta al calentamiento de la atmósfera, sobre todo debido a su importante absorción y dispersión de la radiación de onda corta (solar), y a su absorción relativamente más débil de la radiación de onda larga. En general, el polvo tiene un efecto anti-efecto invernadero en las longitudes de onda visibles, pero ocurre lo contrario en el infrarrojo. Por lo tanto, un aumento de la cantidad de polvo atmosférico reduce el flujo solar entrante en la superficie, pero aumenta el flujo infrarrojo descendente. El resultado neto es una disminución de la señal de amplitud de la temperatura, aumentando las temperaturas nocturnas y disminuyendo las diurnas hasta 20°C. Los efectos radiativos del polvo atmosférico son entonces muy significativos para determinar la distribución del calentamiento atmosférico. Esta alteración de las temperaturas también tiene un efecto sobre la presión y los vientos, que modifican no sólo el transporte atmosférico del polvo sino también su inyección desde la superficie a la atmósfera, retroalimentando entonces el proceso. La temporada de polvo

	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García	0403.01: Inteligencia artificial y simulación

comienza cuando la radiación solar incidente en el hemisferio sur alcanza niveles importantes en el equinoccio de primavera austral (Ls 180) y termina cuando desciende en el equinoccio de otoño austral (Ls 0). Las tormentas de polvo globales son uno de los procesos más desconocidos de la atmósfera marciana. Estas tormentas, que hasta la fecha son imprevisibles, evolucionan a partir de tormentas de polvo locales en pocos soles.

Los fenómenos atmosféricos de mesoescala se clasifican dentro del dominio espacio-temporal entre sistemas de microescala de corta duración y sistemas sinópticos de larga duración (escala global). En la práctica, la división entre microescala y mesoescala, y entre mesoescala y escala sinóptica es bastante difusa. La revitalización de la exploración de Marte a principios de los años noventa, combinada con la maduración de la modelización de mesoescala para la Tierra, proporcionó un escenario ideal para la aplicación de esta última a la atmósfera de Marte. El uso de modelos de mesoescala se ha convertido en una parte integral de la interpretación de los datos devueltos por las misiones marcianas y en el suministro de restricciones y límites sobre las condiciones ambientales en apoyo de la planificación y las operaciones de las misiones. Los modelos de mesoescala son herramientas ideales para minimizar en gran medida el riesgo durante las fases de entrada, descenso y aterrizaje (en adelante EDL). Los vientos de ladera, los procesos de inyección de polvo y el transporte de volátiles atmosféricos son las principales circulaciones de mesoescala que afectan a la estructura y dinámica atmosférica en Marte. La evolución anual de las variables meteorológicas marcianas es hoy en día bien conocida debido al excepcional rendimiento de estos modelos [13] y, por tanto, la aplicación más valiosa de los modelos RNA sería la determinación basada en hechos de los ciclos diarios de los parámetros implicados.

Con todo esto en mente, este trabajo pretende proporcionar una representación y previsión precisa de la atmósfera marciana utilizando como variables de entrada la hora solar verdadera local, la temperatura del aire, la presión y la posición en la órbita (longitud solar).

3. PREDICCIÓN EN MARTE

3.1 Modelos de RNA

El objetivo de este estudio es desarrollar una RNA para predecir el valor de las principales variables climáticas en Marte utilizando datos *in situ*. Para ello, nos basamos únicamente en el conocimiento empírico de la atmósfera marciana siguiendo una aproximación probabilística mediante RNA sin ningún tipo de preentrenamiento terrestre ni modelización detrás.

Esta metodología es complementaria a los modelos numéricos, proporcionando nuevas herramientas para entender los procesos de la atmósfera marciana. La ventaja indudable de un modelo de dinámica de fluidos es que proporciona información sobre la física subyacente del proceso, pero con una complejidad extrema, mientras que el enfoque basado en datos proporciona resultados con mayor simplicidad, pero no da información sobre por qué el sistema tiene un comportamiento determinado.

Además de la previsión de las variables, nuestro enfoque puede utilizarse para rellenar los huecos en caso de falta de mediciones (por ejemplo, condiciones meteorológicas adversas o paradas programadas de la instrumentación para ajustar el software), o para validar otros códigos o nuevos datos, ya que el coste computacional es mucho menor que el requerido por los modelos de mesoescala para la atmósfera marciana.

En cuanto a la arquitectura, nuestro modelo es un perceptrón multicapa con un número de capas y de neuronas que es preciso determinar. Los pesos sinápticos de las neuronas son los parámetros que se ajustan durante el proceso de entrenamiento utilizando para el aprendizaje algoritmos de propagación de retroalimentación hacia delante (FFBP). El método FFBP para calcular los pesos de la red utiliza un algoritmo iterativo de Levenberg-Marquardt (LMA): a partir de un conjunto inicial de parámetros, el LMA calcula paso a paso un conjunto final minimizando un criterio de error cuadrático. Como el FFBP puede converger a mínimos locales y no hay evidencia de la existencia de un único mínimo global, los parámetros finales dependen de la elección de los iniciales. En este sentido, es conveniente entrenar varias veces considerando diferentes condiciones iniciales para obtener buenos resultados.

La red neuronal entrenada con retroalimentación es una estimación no paramétrica de modelos estadísticos para extraer relaciones no lineales de los datos de entrada. El algoritmo de aprendizaje es fácil de implementar y computacionalmente eficiente. Consta de dos fases (Rumelhart et al. [14]).

1. Fase de avance: Los parámetros libres de las redes se establecen y la señal de entrada se propaga a través de la red. Termina con el cálculo de una señal de error.

2. Fase de retroceso: Durante esta segunda fase, la señal de error se propaga hacia atrás a través de la red, de ahí el nombre del algoritmo. En esta fase, se recalculan los parámetros libres de la red para minimizar el error en sentido estadístico.

La herramienta Neural Network toolbox (disponible en MATLAB 9.6.0 ver R2019a) se utiliza para llevar a cabo el análisis de los datos meteorológicos utilizando redes neuronales artificiales.

Como juegos de ensayo y de test para el entrenamiento utilizamos datos meteorológicos obtenidos de las misiones Viking Lander 1 (VL1), Viking Lander 2 (VL2) y Mars Science Laboratory (MSL), que proporcionan la cobertura meteorológica más larga y completa de todas las misiones de superficie aterrizadas en Marte. Hemos creado una base de datos con las variables meteorológicas

	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García	0403.01: Inteligencia artificial y simulación

señaladas anteriormente para entrenar una RNA para cada una de esas misiones. Las siguientes secciones resumen las observaciones meteorológicas de estas misiones y describen la metodología de procesamiento aplicada a dichas observaciones. Para un estudio detallado de todos los paquetes meteorológicos enviados a Marte, se remite al lector a Martínez et al. [15] que es la fuente de los conjuntos de datos utilizados en este estudio.

3.2 Viking Landers (VL1 y VL2)

El VL1 aterrizó en 22,4°N en 1976 y operó durante 2245 soles, es decir, ~3,3 años marcianos (MY), mientras que el VL2 aterrizó en 47,9°N más tarde en ese año y operó durante 1281 soles. Aquí utilizamos las mediciones realizadas por el instrumento y la cámara del Sistema de Instrumentos de Meteorología Viking (VMIS) a bordo de VL1 y VL2. En concreto, examinamos la temperatura del aire cerca de la superficie (T_a) y la presión atmosférica de la superficie (P) medidas por VMIS, además de la opacidad del polvo (τ) a 670 nm recuperada de las imágenes del Sol tomadas por las cámaras.

VMIS midió nominalmente T_a en periodos de 9 min a 0,25 o 0,125 Hz, 20 min a 0,5 Hz, o 39 min a 0,25 Hz, espaciados 1,5 horas a lo largo del sol (día marciano), mientras que P se midió una vez cada 17 min (Hess et al., [16]). Más adelante en la misión, la frecuencia de adquisición de datos se redujo considerablemente. Por otro lado, las cámaras tomaron imágenes del Sol en 328 de los primeros 920 soles de VL1, y en 250 de los primeros 872 soles de VL2 (Colburn et al. [17]).

Utilizamos las mediciones de VMIS en soles con cobertura diurna completa para calcular valores medios diarios representativos de T_a y P en los sitios VL1 y VL2. Para T_a , esta estrategia resulta en 2245 soles en el sitio VL1 y 1050 soles en el sitio VL2, mientras que para P resulta en 1201 soles en el sitio VL1 y 830 soles en el sitio VL2. Además, utilizamos valores diarios de τ en cada sol con las mediciones *in situ* disponibles.

El enfoque seguido con los conjuntos de datos para cada problema es el siguiente. El conjunto de datos se divide en dos grandes grupos, el primero que se utilizará para alimentar la red neuronal, el segundo grupo se utilizará como conjunto desconocido, para revalidar los resultados. El primer grupo a su vez se dividirá en tres subgrupos, como suele hacerse al trabajar con redes neuronales, entrenamiento, validación y prueba. Se seleccionó una red *feedforward* de dos capas, con neuronas ocultas sigmoideas y función de activación lineal en la capa de salida, para ajustarse al problema meteorológico. La red se entrenó con el algoritmo de retropropagación de Levenberg-Marquardt. Se entrenaron cinco redes diferentes variando el número de neuronas en la capa oculta (5, 10, 15, 20 y 25 neuronas).

Para medir la precisión de la RNA utilizamos el error cuadrático medio (MSE), que representa la media de los cuadrados de los errores, siendo el error la diferencia entre el valor estimado y el valor real. También utilizamos el coeficiente de determinación (R^2), que es la proporción de la varianza de la variable dependiente que se puede predecir a partir de las variables independientes y mide lo bien que los valores observados son replicados por el modelo, de modo que cuanto más cerca esté el coeficiente del valor 1, mejor será el resultado predicho.

3.2.1. Viking Lander 1

Nuestro objetivo es desarrollar y entrenar dos redes que puedan predecir la temperatura media diaria del aire en los sitios VL1 y VL2 para un sol en particular utilizando las mediciones meteorológicas de la temperatura y la presión atmosférica durante el sol anterior. Para el VL1, tenemos un conjunto de datos de 1199 soles y las mediciones de cada sol son: longitud solar, opacidad, radiación en la superficie, radiación en la atmósfera, temperatura máxima de la superficie, temperatura mínima de la superficie, temperatura media de la superficie, presión atmosférica máxima, presión atmosférica mínima y presión atmosférica media. Este conjunto se dividirá, como ya se ha mencionado, en dos grandes grupos. Los datos de los primeros 898 alimentarán a la RNA y los de los otros 301 soles se reservan como conjunto desconocido, utilizado después del entrenamiento de la red para revalidar los resultados. El primer grupo (con 898 soles) también se subdivide distribuyendo un 70% como conjunto de entrenamiento (628 muestras), un 15% como muestras de validación (135 muestras) y otro 15% como prueba (135 muestras).

En nuestro análisis, tras realizar un estudio de las variables, optamos por utilizar como entradas la temperatura media del aire, la presión media y la longitud solar (es decir, la posición en la órbita alrededor del Sol). Los resultados del modelo para un número diferente de neuronas se muestran en la Tabla 1. Se puede observar que se prefiere un número bajo de neuronas para optimizar la RNA y obtener una mejor R^2 con el conjunto de incógnitas.

Neuronas	Entrenamiento MSE	Entrenamiento R^2	Validación MSE	Validación R^2	Test MSE	Test R^2	Set desconocido MSE	Set desconocido R^2
5	3.44529	0.966608	4.40219	0.960644	4.84870	0.955508	2.44669	0.961481
10	2.30202	0.976903	1.66325	0.984363	6.96840	0.944197	3.1750	0.955945

DYNA New Technologies	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García	0403.01: Inteligencia artificial y simulación

15	2.93266	0.971202	1.24373	0.989316	2.78628	0.975816	6.95638	0.889637
20	14.83581	0.867006	6.08082	0.940825	32.00879	0.760681	22.11552	0.721259
25	3.04406	0.971177	2.77620	0.966935	1.85559	0.985077	3.28129	0.954175

Tabla 1. Resultados de las RNA entrenadas con los datos del Viking Lander 1 (VL1)

La figura 1 muestra la temperatura media en K en función de la longitud solar. La línea roja indica la observación *in situ* de la temperatura, mientras que la curva azul muestra el resultado predicho por la RNA número 1 utilizando como entrada el conjunto reservado desconocido (de 301 soles). Se puede observar que, en general, la RNA proporciona una estimación precisa de la temperatura con menos del 0,5% de discrepancia con la observación real. Las posiciones orbitales específicas muestran una discrepancia mayor, de hasta el 1% (~2 K), lo que indica que podrían estar en juego parámetros externos no tenidos en cuenta en nuestro modelo. Una RNA más compleja que incluya algunos de los parámetros descritos anteriormente podría proporcionar mejores resultados para afinar el modelo en momentos concretos (por ejemplo, entre los soles 80 y 120).

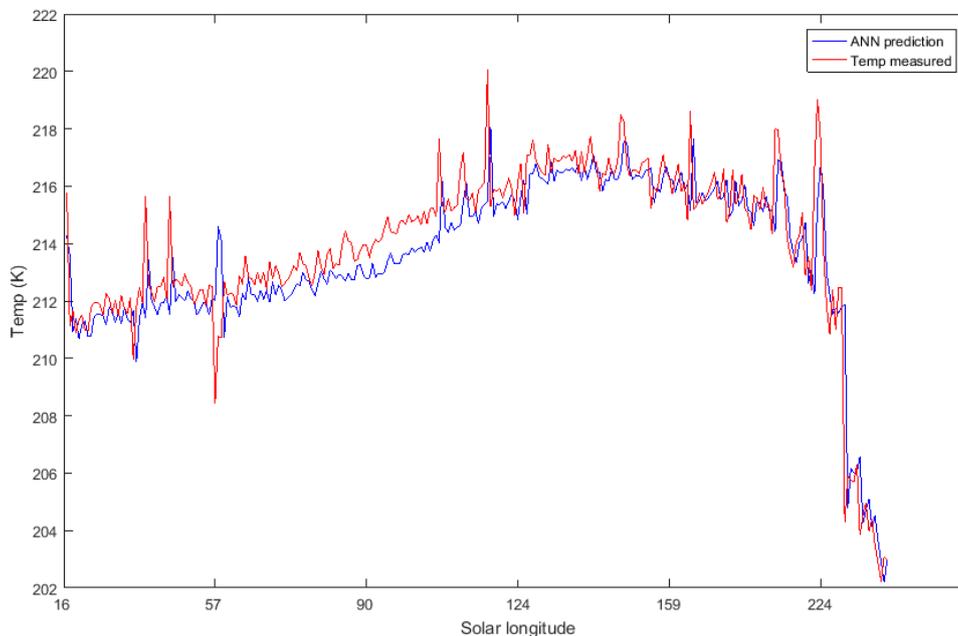


Fig. 1. Predicción de temperatura realizada por la red entrenada con los datos del VL1

3.2.2. Viking Lander 2

En este caso, disponemos del conjunto de datos correspondiente a 828 soles obtenidos por VL2 y de ellos utilizamos 611 como datos de entrenamiento para la RNA. Estos datos también se dividen en un 70% como conjunto de entrenamiento (427 muestras), un 15% para validación (92 muestras) y otro 15% para pruebas (92 muestras). Del mismo modo, reservamos los últimos 217 soles como conjunto desconocido utilizado posteriormente para revalidar los resultados.

Como en el caso de VL1, las variables seleccionadas como entradas a la red son la temperatura media del aire, la presión y la órbita (longitud solar). Destaca que tanto los valores de R^2 del conjunto de prueba como los del conjunto desconocido son superiores a los obtenidos para VL1 independientemente del número de neuronas utilizado. A diferencia del VL1 en el que el valor R^2 del conjunto desconocido mostraba una disminución hasta las 25 neuronas para aumentar después a costa de una mayor potencia computacional.

Neuronas	Entrenamiento MSE	Entrenamiento R ²	Validación MSE	Validación R ²	Test MSE	Test R ²	Set desconocido MSE	Set desconocido R ²
5	4.69236	0.994222	4.48763	0.994835	4.84966	0.994087	12.55534	0.986074
10	5.41114	0.993482	4.09797	0.995534	5.73779	0.993976	11.09182	0.984617
15	4.07411	0.994936	5.09595	0.993738	3.27621	0.996392	11.74683	0.984825
20	4.29535	0.994663	45.33154	0.943427	4.63965	0.994735	11.62279	0.983780
25	2.96438	0.996354	5.91211	0.992325	3.66295	0.995878	14.50912	0.980573

Tabla 2. Resultados de las RNA entrenadas con los datos del Viking Lander 2 (VL2)

Presentamos los resultados de nuestro análisis de VL2 en la figura 2. De nuevo la línea roja indica la observación *in situ* de la temperatura, mientras que la curva azul muestra el resultado de la RNA número 1 utilizando como entrada el conjunto reservado desconocido. En contraste con el VL1, el uso de sólo tres variables para la predicción de la temperatura sobreestima la observación para la mayor parte del conjunto de datos. En ciertas posiciones orbitales, la diferencia entre la RNA y las observaciones es de hasta un 3% y la variabilidad diurna se predice en mucha menor amplitud. Estos hechos sugieren que la meteorología de VL2 podría estar influenciada por otras variables que no desempeñan un papel significativo para VL1, como la opacidad, el viento o la temperatura del suelo.

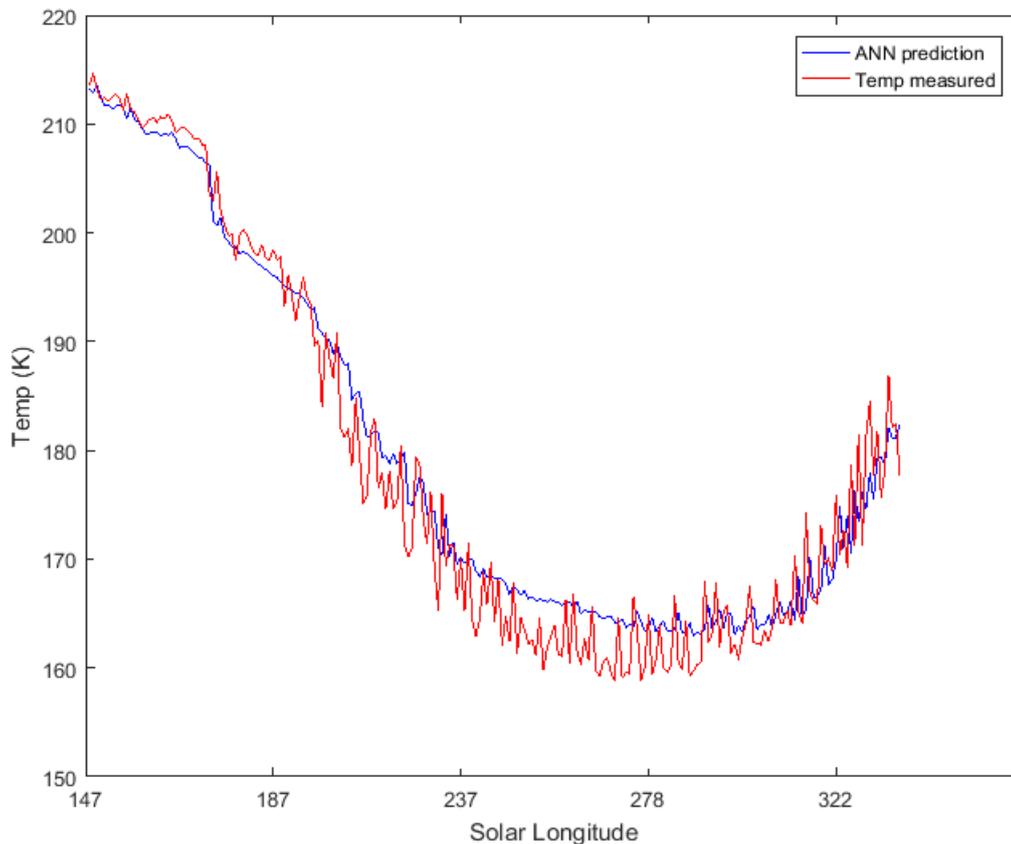


Fig. 2. Predicción de temperatura realizada por la red entrenada con los datos del VL2

	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García	0403.01: Inteligencia artificial y simulación

3.2.3. Portabilidad de la RNA

Una vez seleccionadas las redes neuronales para ambos Viking Landers, surgió la cuestión de la portabilidad. Como se ha comentado anteriormente, sería inviable aplicar una RNA entrenada con datos terrestres a la atmósfera marciana pero, ¿podríamos utilizar la red entrenada con los datos de VL1 para realizar predicciones a partir de los datos obtenidos del VL2, y viceversa? Para validar la idea, hemos obtenido la predicción que proporciona la primera red con los datos de VL2 (Figura 3), y los de la segunda red con los datos VL1 (Figura 4) para observar las diferencias.

En el primer caso (RNA de VL1 sobre datos de VL2), se obtiene un MSE de 64,57 y una R de 0,98316, con discrepancias de hasta el 10% en algunos casos, sobrestimando la temperatura observada en básicamente todas las situaciones. Como se ha comentado anteriormente, las condiciones meteorológicas durante algunas posiciones orbitales para VL2 parecen estar determinadas por variables distintas a la temperatura, la presión y la posición orbital. Por lo tanto, intentar pronosticar la temperatura usando sólo esas variables, y siendo esas variables exógenas a la posición, resulta en predicciones poco fiables en algunos momentos.

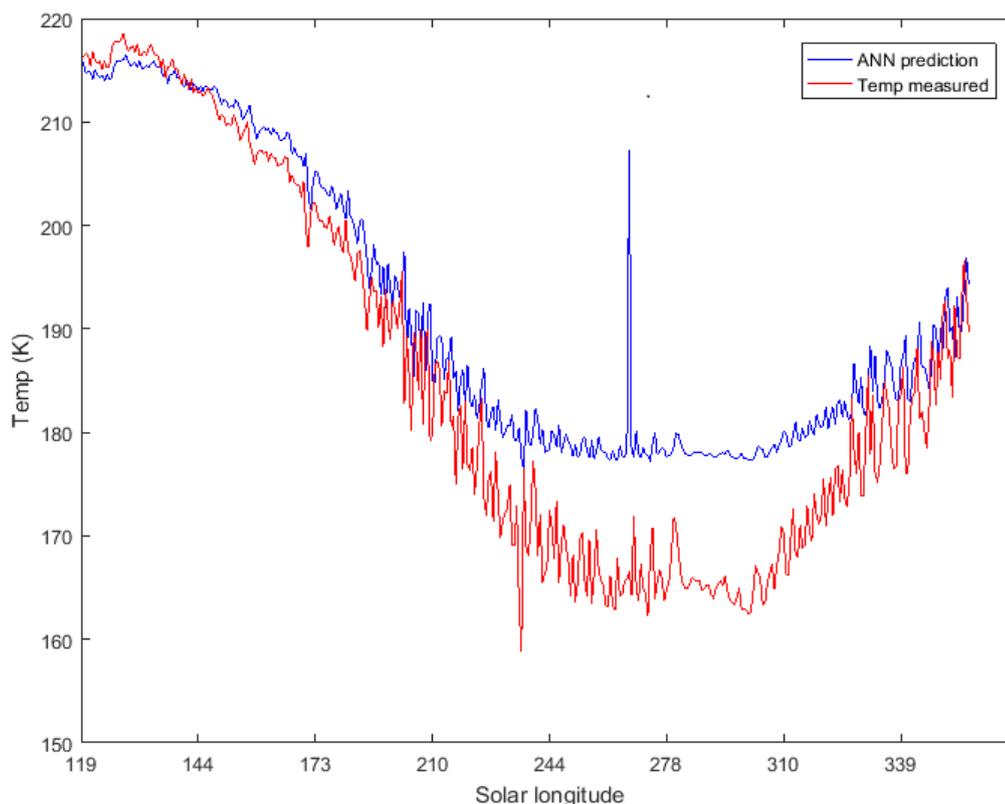


Fig. 3. Predicción de la red 1 (entrenada con VL1) para los datos del VL2

Los resultados de la utilización de la RNA VL2 sobre los datos de VL1 son más interesantes. En este caso, el valor del MSE fue de 256,19 y R^2 de 0,91714. Como se puede observar en la Figura 4, el pronóstico (línea azul) comienza a subestimar las observaciones y después de aproximadamente 50 soles se invierte con respecto a ellas (línea roja). Cuando las observaciones comienzan a disminuir drásticamente (alrededor del sol 200), la predicción cae también, capturando la tendencia correctamente. Sin embargo, las diferencias entre el comportamiento real y los valores predichos difieren excesivamente.

Estos dos ejemplos demuestran que las RNA son herramientas útiles para la predicción meteorológica marciana, pero la arquitectura y las ponderaciones específicas dependen en gran medida de la ubicación. Si alguien intentara extrapolar los resultados de un lugar a otro, los resultados no serían fiables. Aunque la atmósfera marciana se considera sencilla y predecible en comparación con la nuestra, la simplificación excesiva de las metodologías utilizadas para la previsión proporcionaría resultados inexactos.

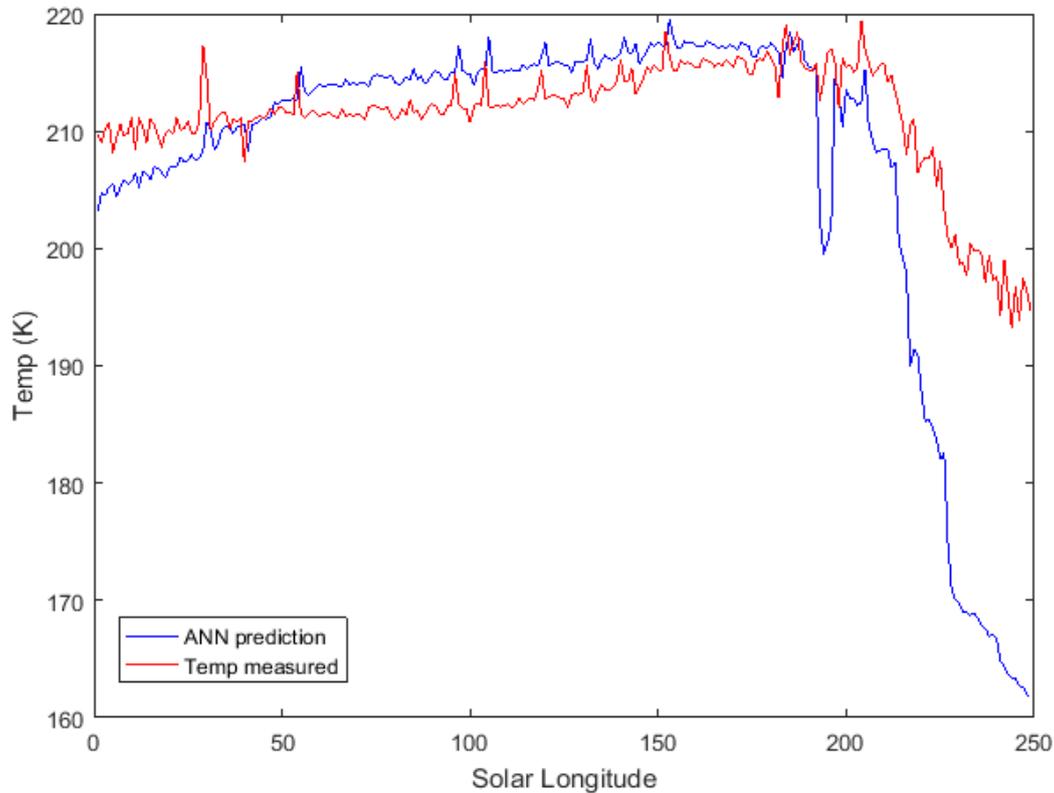


Fig. 4. Predicción para los datos de VL1 de la red entrenada con VL2

Observamos en ambos intercambios una R^2 muy buena con un gran error ($>30\%$). El resultado del experimento nos muestra que no hay transporte directo de una región a otra, resultado que era de esperar porque conviene recordar que VL1 está situado en $22,4^\circ\text{N}$ y VL2 en $47,9^\circ\text{N}$ y eso no lo tienen en cuenta estas RNA, que son modelos locales. Es lógico que al intercambiar se predigan comportamientos y tendencias, pero no son intercambiables porque se han entrenado en dos zonas diferentes del planeta con diferente latitud y altitud. Un modelo más general requeriría que esos factores fueran también introducidos como entradas a la red, ya que tienen una clara influencia en la temperatura. Por ello si se necesitara esa mayor generalidad la recomendación sería desarrollar una nueva red que lo tuviera en cuenta.

3.3 Mars Science Laboratory (MSL) Mission

En esta sección, pretendemos desarrollar una RNA más compleja para la variabilidad meteorológica en la ubicación del rover Curiosity. El MSL (*Mars Science Laboratory*) aterrizó en el cráter Gale ($4,59\text{S}, 137,44\text{E}$) en agosto de 2012 y, a partir de octubre de 2020, ha estado operando durante más de 2900 soles. Aquí utilizamos las medidas tomadas por la Estación de Monitorización Ambiental del Rover (REMS; Gómez-Elvira et al. [18]) y los instrumentos *Mastcam* a bordo del MSL durante los primeros 2000 soles de la misión. En particular, disponemos de la presión y la temperatura de la atmósfera (P y Ta), la temperatura del suelo (Tg) y la humedad relativa (RH) medidas por REMS, junto con la opacidad (τ) a 880 nm recuperada del instrumento *Mastcam*.

El objetivo es crear y entrenar una red que pueda predecir componentes meteorológicos individuales (temperatura, presión, humedad, etc.) para un sol concreto, dados los valores de las variables durante el sol anterior. En este caso de estudio concreto hemos planteado la predicción de la temperatura y la presión porque el objetivo principal es demostrar que el enfoque de la RNA es válido para la predicción del tiempo en Marte, pero se pueden obtener otras variables con la misma metodología. La temperatura es posiblemente el parámetro más importante de la atmósfera de Marte, ya que es uno de los principales impulsores de la química atmosférica y el factor determinante para las células solares [19].

El conjunto de datos de entrada se obtiene a partir de los registros realizados durante 2000 soles, es decir, casi dos años y medio marcianos. Cada sol consta de 24 mediciones. La estrategia de muestreo nominal de REMS consiste en mediciones tomadas a 1Hz durante los primeros 5 minutos de cada hora. Por otro lado, *Mastcam* recupera valores de τ con una cadencia típica de una vez cada seis o siete soles.

	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
	ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García

Dada la estrategia de medición nominal del REMS, en este estudio utilizamos las mediciones tomadas durante los primeros 5 minutos de cada hora para calcular las medias horarias y diarias de las variables Ta, Tg y P durante los primeros 2000 soles de la misión. Además, utilizamos los valores diarios de τ con mediciones disponibles. Tenemos una batería de 1637 muestras, 1227 se utilizaron para desarrollar la red y las otras 410 se reservaron para una revalidación final, como conjunto desconocido.

De las 1227 muestras, el 70% se utilizan como datos de entrenamiento para la red neuronal; el 15% de las muestras son datos de validación y el 15% restante son los datos de prueba y dan una medida independiente del rendimiento de la RNA en términos de MSE (error cuadrático medio).

Para la predicción de la temperatura y la presión, las variables seleccionadas como entradas son: la hora solar local, la temperatura del aire, la presión y la órbita (longitud solar) de cada sol. Esas cuatro magnitudes constituyen la cantidad mínima de variables que explicaban el 99% de los valores, dando como resultado una RNA de alta precisión. Incluir más variables sólo añadía complejidad y no ayudaba al modelo de predicción.

La tabla 3 muestra los resultados que proporcionaron los cinco modelos neuronales analizados, con diferentes números de neuronas en la capa oculta. Se pone de manifiesto una vez más que un mayor número de neuronas no se traduce en una predicción más precisa. Por ello, seleccionamos 5 como número óptimo de neuronas para crear la RNA. También es destacable que el MSE de prueba es mayor para 5 neuronas, pero el MSE para el conjunto desconocido es menor para este número de neuronas.

Neuronas	Entrenamiento MSE	Entrenamiento R ²	Validación MSE	Validación R ²	Test MSE	Test R ²	Set desconocido MSE	Set desconocido R ²
5	10.84709	0.999944	10.47866	0.999946	10.95767	0.999944	7.83929	0.990657
10	9.447385	0.999951	9.53764	0.999951	9.41453	0.999951	8.77725	0.990357
15	9.12516	0.999953	9.39396	0.999952	9.44041	0.999951	8.97762	0.989863
20	8.98696	0.999954	8.82985	0.999954	8.95814	0.999954	9.92400	0.989374
25	8.72240	0.999955	8.97163	0.999954	9.03682	0.999954	10.97657	0.989269

Tabla 3. Resultados de las RNA para predecir la temperatura en la ubicación de Curiosity

La figura 5 muestra la temperatura del aire medida y predicha frente a la posición orbital durante 5 soles obtenida para el conjunto de datos desconocidos. Como puede verse, el margen de error es inferior al 0,5% en la mayoría de las situaciones, encontrándose las mayores diferencias cuando la temperatura del aire es mínima durante la noche. Dado que las otras variables son parámetros completamente deterministas (hora solar verdadera local y longitud solar), concluimos que la estocasticidad encontrada para la temperatura del aire en el mínimo nocturno proviene de factores externos no disponibles para nuestra red. Estas variaciones podrían ser producidas por vientos descendentes imprevisibles que podrían enfriar el sensor momentáneamente. Estos vientos descendentes a través de los bordes del cráter podrían ser tormentas de viento inducidas dinámicamente y relacionadas con la actividad de las ondas de gravedad, o bien vientos catabáticos inducidos termodinámicamente (Rafkin et al. [20]). Lamentablemente, los sensores de viento de REMS no proporcionan datos con la suficiente precisión como para incluirlos como variable en nuestro análisis.

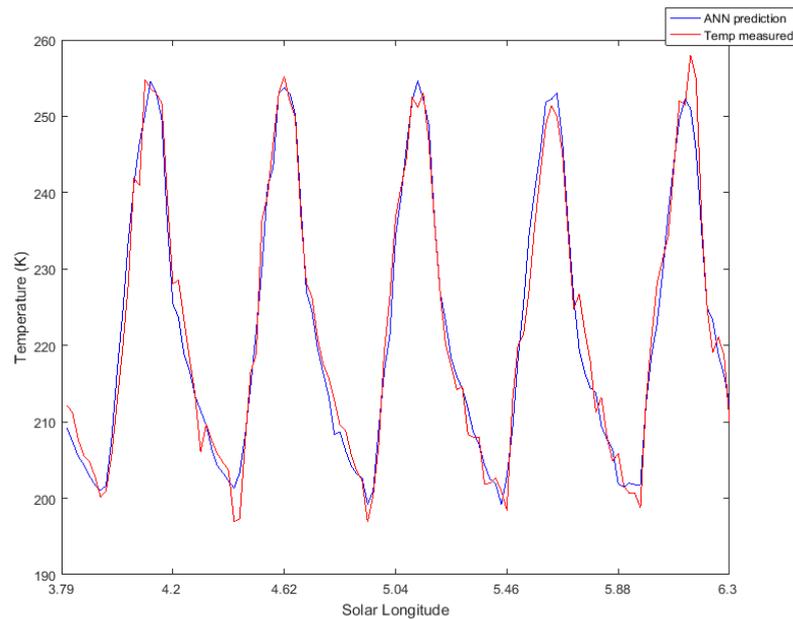


Fig. 5. Temperatura del aire medida por REMS y su predicción.

De forma similar, la figura 6 muestra la la presión medida y predicha frente a posición orbital para 5 soles del segundo conjunto de datos. Esta vez el error es generalmente inferior al 0,2%, y el mínimo nocturno se capta con precisión.

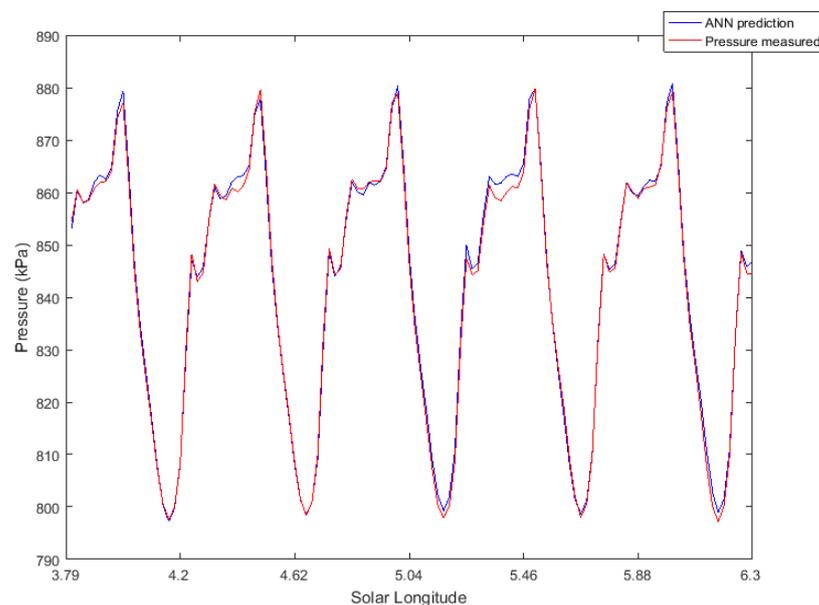


Fig. 6. Presión medida por REMS y su predicción.

4. CONCLUSIONES

Los análisis presentados en este trabajo demuestran que la aplicación de redes neuronales artificiales es un enfoque válido para predecir las variables meteorológicas marcianas, útil para complementar los modelos teóricos actuales, obtener información sobre la atmósfera de Marte y analizar los datos de las futuras estaciones meteorológicas en ese planeta.

Se han entrenado modelos neuronales de predicción con datos reales disponibles de las tres localizaciones estudiadas, es decir, los puntos del planeta en los que se encuentran las dos sondas espaciales del programa Viking de la NASA (VL1 y VL2) y la zona del cráter Gale en la que se sitúa la misión Curiosity (Mars Science Laboratory o MSL). Los modelos obtenidos proporcionan buenos

	PREDICCIÓN DE VARIABLES METEOROLÓGICAS DE MARTE MEDIANTE REDES NEURONALES ARTIFICIALES	Industrias de la información y del conocimiento
ARTÍCULO INVESTIGACIÓN	Alejandro de Cabo García, Alfonso Delgado-Bonal, Belén Pérez-Lancho, Germán Martínez, Jorge Pla-García	0403.01: Inteligencia artificial y simulación

resultados con márgenes de error muy bajos. Sin embargo, se ha comprobado que se trata de modelos de ámbito local, ya que cuando una red entrenada para una localización se pretende utilizar con datos de una zona diferente los errores en la predicción aumentan de forma apreciable.

En este trabajo, hemos logrado desarrollar la RNA mínima que proporciona una predicción realista de los datos meteorológicos sin invertir una gran cantidad de tiempo y recursos computacionales. Consideramos que este enfoque puede resultar muy útil para rellenar posibles lagunas de los conjuntos de datos producidas por fallos en la instrumentación y también para ayudar a los científicos a detectar y analizar el origen de comportamientos inesperados como las fluctuaciones diarias u horarias en torno a los valores predichos. Como ejemplo, si nos centramos en los cambios aleatorios de la temperatura del aire durante la noche, el modelo entrenado con los datos de MSL ha permitido comprobar que la presión no es responsable de esas variaciones y plantear la hipótesis de que la razón de esos cambios pueda ser la turbulencia nocturna impulsada por los vientos descendentes. Si la capacidad de los procesadores enviados a Marte sigue aumentando, será factible incluir estos algoritmos para procesar los datos *in situ* y optimizar las mediciones para proporcionar la mayor cantidad de información.

REFERENCIAS

- [1]. A. L. Hodgkin, A. F. Huxley. "A quantitative description of membrane current and its application to conduction and excitation in nerve". *The Journal of Physiology* (1952). DOI: <https://dx.doi.org/10.1113%2Fjphysiol.1952.sp004764>
- [2]. M.P. Singh Kumar Abhishek. "Weather Forecasting Model using Artificial Neural Network". *Procedia Technology* 4 (2012). DOI: <https://doi.org/10.1016/j.procty.2012.05.047>
- [3]. Haviluddin Mislan. "Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggara Station, East Kalimantan – Indonesia". *Procedia Computer Science* 59 (2015). DOI: <https://doi.org/10.1016/j.procs.2015.07.528>
- [4]. Sumam Mary Idicula A. J. Litta. "Artificial Neural Network Model in Prediction of Meteorological Parameters during Premonsoon Thunderstorms". *International Journal of Atmospheric Sciences* (2013). DOI <https://doi.org/10.1155/2013/525383>
- [5]. Datta, Anisha & Si, Shukrity & Biswas, Sanket. "Complete Statistical Analysis to Weather Forecasting". (2019). DOI: https://doi.org/10.1007/978-981-13-9042-5_65
- [6]. Al-Kahlout, M. M., et al. "Neural Network Approach to Predict Forest Fires using Meteorological Data." *International Journal of Academic Engineering Research* (2020). 4(9): 68-72.
- [7]. ULUTAS, Doğançan, Alaa Ali Hameed, and Erdal Alimovski. "Weather Forecasting Using Back Propagation Feed Forward Neural Network and Multiple Linear Regression.", *Manchester Journal of Artificial Intelligence & Applied Sciences*. (2021)
- [8]. Olivera, Lucas, et al. "Uso de redes neuronales artificiales para la estimación de la radiación solar horaria bajo diferentes condiciones de cielo". *Avances en Energías Renovables y Medio Ambiente*, (2020), vol. 24, p. 232-243.
- [9]. Wu, J., Xing, X. "Rainfall forecast and computer data algorithm optimization in coastal areas based on improved neural network". *Arabian Journal of Geosciences* (2021), 14, 1469. <https://doi.org/10.1007/s12517-021-07579-1>
- [10]. Anochi, J.A.; de Almeida, V.A.; de Campos Velho, H.F. Machine Learning for Climate Precipitation Prediction Modeling over South America. *Remote Sensing* (2021), 13, 2468. <https://doi.org/10.3390/rs13132468>
- [11]. Portree, D., "Humans to Mars: Fifty Years of Mission Planning, 1950-2000," *Tech. Rep. NASA-SP-2001-4521*, NASA, (Feb. 2001).
- [12]. Rivera-Valentín, Edgar G., Vincent F. Chevrier, Alejandro Soto, and Germán Martínez. "Distribution and habitability of (meta) stable brines on present-day Mars." *Nature Astronomy* (2020): 1-6. DOI: <https://doi.org/10.1038/s41550-020-1080-9>
- [13]. Pla-García, Jorge & Rafkin, Scot & Kahre, Melinda & Gomez-Elvira, Javier & Hamilton, Vicky & Navarro Lopez, Sara & Torres, Josefina & Marin, Mercedes & Vasavada, Ashwin.. "The Meteorology of Gale Crater as Determined from Rover Environmental Monitoring Station Observations and Numerical Modeling. Part I: Comparison of Model Simulations with Observations". *Icarus*. 280. (2016) DOI: <https://doi.org/10.1016/j.icarus.2016.03.013>
- [14]. Rumelhart, D., Hinton, G. & Williams, R. "Learning representations by back-propagating errors". *Nature* 323, 533–536 (1986) DOI: <https://doi.org/10.1038/323533a0>
- [15]. Martínez, G. M., et al. "The modern near-surface Martian climate: A review of in-situ meteorological data from Viking to Curiosity." *Space Science Reviews* 212.1-2 (2017): 295-338. <https://doi.org/10.1007/s11214-017-0360-x>
- [16]. Hess, S. L., et al. "Meteorological results from the surface of Mars: Viking 1 and 2." *Journal of Geophysical Research* 82.28 (1977): 4559-4574. <https://doi.org/10.1029/JS082i028p04559>
- [17]. Colburn, D. S., J. B. Pollack, and R. M. Haberle. "Diurnal variations in optical depth at Mars." *Icarus* 79.1 (1989): 159-189. DOI: [https://doi.org/10.1016/0019-1035\(89\)90114-0](https://doi.org/10.1016/0019-1035(89)90114-0)
- [18]. Gómez-Elvira, J., et al. "REMS: The environmental sensor suite for the Mars Science Laboratory rover." *Space science reviews* 170.1-4 (2012): 583-64 DOI: <https://doi.org/10.1007/s11214-012-9921-1>
- [19]. Delgado-Bonal, A. & Martín-Torres, F. J. "Solar cell temperature on Mars". *Solar Energy* 118, 74–79 (2015). <https://doi.org/10.1016/j.solener.2015.04.035>
- [20]. Rafkin, Scot & Pla-García, Jorge & Kahre, Melinda & Gomez-Elvira, Javier & Hamilton, Vicky & Marin, Mercedes & Navarro Lopez, Sara & Torres, Josefina & Vasavada, Ashwin. "The Meteorology of Gale Crater as Determined from Rover Environmental Monitoring Station Observations and Numerical Modeling. Part II: Interpretation". *Icarus*. 280. (2016). DOI: <https://doi.org/10.1016/j.icarus.2016.01.031>

