



Universidad Internacional de La Rioja
Escuela Superior de Ingeniería y Tecnología

Máster Universitario en Astrofísica y Técnicas de Observación
en Astronomía

Detección de exoplanetas mediante transformaciones wavelet y CNNs.

Trabajo fin de estudio presentado por:	Diego Madruga Ramos
Tipo de trabajo:	Iniciación a la investigación en astronomía y astrofísica
Línea de trabajo:	Desarrollo software/matemático para el análisis de datos astronómicos
Director/a:	Roberto Baena Gallé
Fecha:	08-09-2025

Agradecimientos

Este trabajo se ha desarrollado en el marco del proyecto Astronomía no supervisada e interpretable con técnicas avanzadas (ANITA/PP-2024-08), que se financia mediante la convocatoria “Financiación de Proyectos Precompetitivos de Investigación UNIR 2024”.

Resumen

El presente estudio aborda la detección de exoplanetas mediante el análisis de las curvas de luz de la misión Kepler, empleando técnicas de aprendizaje profundo (*deep learning*) en combinación con transformaciones wavelet. Se han implementado diversas arquitecturas de redes neuronales convolucionales, incluyendo el modelo original propuesto por Shallue & Vanderburg (2018), una versión adaptada con convoluciones bidimensionales y una arquitectura propuesta en este estudio que integra convoluciones bidimensionales, capas de salto (*skip layers*) y un cuello de botella en las capas completamente conectadas. Los resultados obtenidos evidencian que la integración de transformaciones wavelet y modelos avanzados se traduce en una optimización sustancial del rendimiento en relación con la arquitectura original, lo que se manifiesta en mayores valores de precisión, recall y F1-score. El análisis comparativo de las diferentes familias wavelet analizadas demuestra que Meyer y Symlet ofrecen los mejores resultados, lo que destaca la importancia de la selección de la wavelet madre. En segundo lugar, se ha llevado a cabo un análisis de los candidatos exoplanetarios, en el cual se observaron diferencias notables entre grupos de distinta probabilidad. Estos hallazgos validan la capacidad del modelo para discriminar tránsitos genuinos de falsos positivos. En conclusión, el presente estudio evidencia que la integración de transformaciones wavelet con arquitecturas convolucionales modernas constituye una herramienta eficaz para la detección automática de exoplanetas y abre nuevas perspectivas para su aplicación en futuras misiones espaciales.

Palabras clave: Exoplanetas, Curvas de luz, redes neuronales convolucionales, transformada wavelet, detección automática.

Abstract

This study addresses the detection of exoplanets through the analysis of light curves from the Kepler mission, using deep learning techniques in combination with wavelet transformations. Various convolutional neural network architectures were implemented, including the original model proposed by Shallue & Vanderburg (2018), an adapted version with two-dimensional convolutions, and an architecture proposed in this study that integrates two-dimensional convolutions, skip layers, and a bottleneck in the fully connected layers. The results obtained show that the integration of wavelet transforms, and advanced models leads to a substantial optimisation of performance compared to the original architecture, which is reflected in higher accuracy, recall and F1-score values. The comparative analysis of different analysed wavelet families shows that Meyer and Symlet offer the best results, highlighting the importance of the selection of the mother wavelet. Secondly, an analysis of exoplanetary candidates was carried out, in which notable differences were observed between groups with different probabilities. These findings validate the model's ability to discriminate between genuine transits and false positives. In conclusion, this study shows that the integration of wavelet transformations with modern convolutional architectures is an effective tool for the automatic detection of exoplanets and opens new perspectives for its application in future space missions.

Keywords: Exoplanets, light curves, convolutional neural networks, wavelet transform, automatic detection.

Índice de contenidos

1.	Introducción	1
2.	Estado del arte	9
2.1.	Series temporales para la detección de tránsitos.....	9
2.2.	Transformada Wavelet	10
2.3.	Redes Neuronales Convoluciones para la identificación de exoplanetas	12
2.4.	Conclusiones	14
3.	Objetivos	15
3.1.	General	15
3.2.	Específicos	15
4.	Metodología	16
4.1.	Detección de tránsitos Planetarios.....	16
4.1.1.	Fundamentos del método de tránsitos	16
4.1.2.	Datos de estudio.....	16
4.2.	Series de tiempo	17
4.2.1.	Obtención y análisis de los datos de la misión Kepler	17
4.2.2.	Descarga de las series de tiempo	20
4.2.3.	Plegado de series temporales	20
4.2.4.	Generación de vista Global y Local.....	21
4.2.5.	Wavelets	23
4.3.	Arquitecturas implementadas	27
4.3.1.	Funciones de activación	29
4.3.2.	Tipos de capas	29
4.3.3.	Funciones de pérdida	30
4.3.4.	Modelos Propuestos.....	32

5. Resultados	37
5.1. búsqueda del modelo óptimo	37
5.1.1. Modelo de Shallue	38
5.1.2. Modelo de Shallue 2D	42
5.1.3. Modelo 2D con skip-layers	46
5.1.4. Resumen de los modelos	50
5.2. Evaluación del mejor modelo con las familias wavelets	51
5.2.1. Symlet	51
5.2.2. Daubechies	54
5.2.3. Meyer	58
5.2.4. Haar	62
5.2.5. Resumen de los resultados en función de las wavelets	66
5.2.6. Series de tránsitos a diferentes probabilidades	66
6. Discusión	68
7. Conclusiones	72
Referencias bibliográficas	74
Anexo A. Candidatos de alta probabilidad	79
Anexo B. Candidatos de baja probabilidad	80

Índice de figuras

Figura 1: Distribución de exoplanetas detectados en función de su masa y periodo orbital (NASA Exoplanet Archive).	1
Figura 2: Curva de luz de tránsito planetario (NASA Science, https://science.nasa.gov/resource/light-curve-of-a-planet-transiting-its-star/).	2
Figura 3: Telescopio espacial Kepler (Kepler/K2 - NASA Science).	3
Figura 4: Cámara de Kepler compuesta por 42 CCDs (NASA).	4
Figura 5: Página principal de NASA Exoplanet Archive.	17
Figura 6: Apartado de datos de la misión Kepler con las columnas de datos disponibles.	18
Figura 7: Distribución de los objetos respecto la columna ' <i>koi_disposition</i> '.	19
Figura 8: Serie de luminosidad plegada en fase.	21
Figura 9: Vista global de la serie par.	22
Figura 10: Vista global de la serie impar.	22
Figura 11: Vista local de la serie par.	22
Figura 12: Vista local de la serie impar.	23
Figura 13: Wavelets madre junto con la función de escalado.	24
Figura 14: Familias wavelets seleccionadas para el análisis.	25
Figura 15: Niveles Wavelets para la vista global par (izquierda) e impar (derecha).	26
Figura 16: Niveles Wavelet para la vista local par (izquierda) e impar (derecha).	26
Figura 17: Ejemplo de entrada para el modelo.	27
Figura 18: Arquitectura utilizada en el trabajo de (Shallue et al., 2018) para la clasificación de exoplanetas.	28
Figura 19: Arquitectura de Shallue modificada para convoluciones 2D.	34
Figura 20: Arquitectura propuesta basada en el modelo de Shallue.	36

Figura 21: Métricas de entrenamiento y validación, modelo de Shallue con series originales.	39
Figura 22: Matriz de confusión y métricas del conjunto de test, Shallue con series originales.	40
Figura 23: Métricas de entrenamiento y validación, modelo de Shallue con descomposición wavelet.	41
Figura 24: Matriz de confusión y métricas del conjunto de test, Shallue con descomposición wavelet.	42
Figura 25: Métricas de entrenamiento y validación, modelo de Shallue2D con series originales.	43
Figura 26: Matriz de confusión y métricas del conjunto de test, Shallue2D con series originales.	44
Figura 27: Métricas de entrenamiento y validación, modelo de Shallue2D con descomposición wavelet.	45
Figura 28: Matriz de confusión y métricas del conjunto de test, Shallue2D con descomposición wavelet.	46
Figura 29: Métricas de entrenamiento y validación, modelo de skip-layers con series originales.	47
Figura 30: Matriz de confusión y métricas del conjunto de test, modelo skip-layers con series originales.	48
Figura 31: Métricas de entrenamiento y validación, modelo de skip-layers con descomposición wavelet.	49
Figura 32: Matriz de confusión y métricas del conjunto de test, modelo skip-layers con descomposición wavelet.	50
Figura 33: Datos de entrada con wavelets tipo symlet 5.	52
Figura 34: Clasificación de candidatos con symlet 5.	53
Figura 35: Distribuciones de probabilidad de predicción con symlet 5.	53
Figura 36: Datos de entrada con wavelets tipo daubechies 5.	54

Figura 37: Métricas de entrenamiento y validación con daubechies 5.	55
Figura 38: Matriz de confusión y métricas de test con daubechies 5.	56
Figura 39: Clasificación de candidatos con daubechies 5.	57
Figura 40: Distribuciones de probabilidad de predicción con daubechies 5.	57
Figura 41: Datos de entrada con wavelets tipo meyer.	58
Figura 42: Métricas de entrenamiento y validación con meyer.	59
Figura 43: Matriz de confusión y métricas de test con meyer.	60
Figura 44: Clasificación de candidatos con meyer.	61
Figura 45: Distribuciones de probabilidad de predicción con meyer.	61
Figura 46: Datos de entrada con wavelets tipo Haar.	62
Figura 47: Métricas de entrenamiento y validación con haar.	63
Figura 48: Matriz de confusión y métricas de test con haar.	64
Figura 49: Clasificación de candidatos con haar.	65
Figura 50: Distribuciones de probabilidad de predicción con haar.....	65
Figura 51: Ejemplo vista global de tres candidatos con diferentes probabilidades.	67
Figura 52: Ejemplo de vista local de tres candidatos con diferentes probabilidades.....	68

Índice de tablas


Tabla 1: Resumen del rendimiento de los diferentes modelos.	51
Tabla 2: Resumen del rendimiento de las familias wavelets junto a la clasificación de los candidatos.	66

1. INTRODUCCIÓN

La búsqueda de exoplanetas es uno de los retos a los que se enfrenta la astrofísica moderna. En las últimas décadas, el descubrimiento de mundos fuera de nuestro sistema solar ha revolucionado la comprensión del universo y ha abierto nuevas vías de investigación en la exploración espacial. Las estimaciones más recientes sugieren que el número de exoplanetas supera con creces el número de estrellas presentes en el universo (Popinchalk, 2024), lo que, sin duda, lo convierte en uno de los campos de investigación astrofísica más populares. La información está traspasando el mero ámbito científico y es habitual que noticias sobre el descubrimiento de nuevos planetas habitables aparezcan en medios generalistas.


Los diferentes métodos que se usan comúnmente para la búsqueda de exoplanetas se pueden ver en la Figura 1, donde se muestra su distribución de masa y periodo orbital. Se puede apreciar que las técnicas más efectivas son el método de tránsito y la velocidad radial.

Figura 1: Distribución de exoplanetas detectados en función de su masa y periodo orbital (NASA Exoplanet Archive).



El método de tránsito, representado en la Figura 2, se basa en la medición continua y precisa de la intensidad de luz emitida por una estrella a intervalos regulares (Wright et al., 2012). Al analizar estas mediciones, es posible detectar reducciones fotométricas que se repiten de manera periódica, lo que sugiere la presencia de un objeto que transita frente a la estrella. Este método, que permite inferir la existencia de un cuerpo celeste a partir de la forma y periodicidad de las variaciones en la curva de luz, es el más utilizado en la actualidad para identificar exoplanetas y para estudiar sus características básicas. Sin embargo, uno de los principales desafíos que se presentan al utilizar la técnica de tránsito es la dificultad para determinar la verdadera naturaleza del objeto que ocasiona el eclipse, ya que existen otros fenómenos astrofísicos además de tránsitos planetarios, como la presencia de una estrella compañera en un sistema binario, que pueden provocar la disminución periódica de la curva de luz observada, fallos en la instrumentación o la propia variabilidad pulsante de la estrella. Esta ambigüedad en la interpretación de los datos complica la tarea de clasificar de forma precisa los eventos de tránsito, lo que subraya la necesidad de desarrollar métodos precisos para diferenciar entre los distintos orígenes de estas señales.

Figura 2: Curva de luz de tránsito planetario (NASA Science, <https://science.nasa.gov/resource/light-curve-of-a-planet-transiting-its-star/>).



El método de velocidad radial se basa en la interacción gravitatoria entre el exoplaneta y la estrella sobre la que orbita. A pesar de que la masa del exoplaneta es sustancialmente inferior a la de la estrella, es capaz de producir un pequeño bamboleo en la velocidad radial de la

estrella, lo que, debido al efecto Doppler, induce una oscilación en la longitud de onda de la luz recibida de la estrella.

Los otros métodos utilizados hasta el momento son la observación directa del exoplaneta, que habitualmente se consigue bloqueando artificialmente la luz de la estrella con un coronógrafo; las microlentes gravitacionales, en las que el exoplaneta es capaz de curvar momentáneamente la luz de una estrella distante; o la astrometría, en la que la posición relativa de la estrella en relación con estrellas cercanas varía ligeramente.

Figura 3: Telescopio espacial Kepler (Kepler/K2 - NASA Science).



Iniciativas como las misiones Kepler (Figura 3) o TESS han permitido recopilar grandes cantidades de datos utilizando el método de tránsito, habilitando la identificación de una cantidad de exoplanetas inimaginables hasta la fecha. En este contexto, la misión Kepler ha sido la iniciativa más exitosa hasta la fecha. Cuenta con más de 3000 planetas extrasolares encontrados (Rowe et al., 2014; Christiansen et al., 2025). Tanto NASA como ESA han continuado construyendo y lanzando telescopios avanzados que permitirán el estudio de exoplanetas. *James Webb Space Telescope*, poco después de su lanzamiento, ya fue capaz de detectar su primer exoplaneta con su espectrógrafo de infrarrojo cercano (Beichman et al. 2014) y recientemente, incluso parecía que podía haber encontrado biomarcadores en la atmósfera de K2-18b, aunque posteriormente fue desmentido (Tsai et al., 2024). Los datos fotométricos adquiridos por CHEOPS permitirán caracterizar masa, densidad y composición de exoplanetas y es probable que incluso permitan descubrir alguna exoluna (Simon et al.

2015). PLATO, en órbita alrededor de L2 (Punto de Lagrange 2), que es una región de equilibrio gravitacional situada a 1,5 millones de kilómetros de la Tierra en dirección opuesta al Sol, ideal para ubicar telescopios espaciales por su estabilidad y visión continua del cielo, se centrará en planetas terrestres en la zona de habitabilidad de estrellas similares al Sol; adquirirá tal cantidad de datos científicos que requerirá procesamiento autónomo de datos, seleccionando regiones de interés, calibración y reducción de imágenes y generación de curvas de luz a bordo (Rauer et al., 2014). ARIEL realizará fotometría bajo diferentes filtros, estudiando las atmósferas de planetas conocidos, detectando la presencia de nubes o cambios meteorológicos en el tiempo (Tinetti et al., 2018).

La misión Kepler, lanzada por la NASA en 2009 (Koch et al., 2010) en una órbita heliocéntrica, para una duración inicial de 3 años y medio, tenía como objetivo principal la detección de exoplanetas mediante el método del tránsito.

El telescopio incluía una lente correctora de 95cm y un espejo principal de 1.4m. La cámara estaba compuesta de 42 CCDs de 50x25mm de tamaño y 2200x1024 píxeles de resolución cada uno, lo que suponía la cámara más grande lanzada al espacio hasta el momento con 94.6 megapíxeles, ilustrada en la Figura 4.

Figura 4: Cámara de Kepler compuesta por 42 CCDs (NASA).



Los CCDs se configuraban con 6.5s de tiempo de exposición para evitar saturación y eran apilados a bordo para tomar medidas fotométricas con una frecuencia de 1 min (Gilliland et al., 2010) para los objetivos de corto plazo (*short cadence*) y 30 min para lo de largo plazo (*long cadence*). El ancho de banda de comunicación de datos a tierra no era suficiente para bajar todos los datos generados a bordo, de modo que el equipo científico había preseleccionado los píxeles relevantes alrededor de cada estrella de interés, un 6% del total. Los datos obtenidos por esos píxeles eran recuantificados, comprimidos y almacenados a bordo antes de su transmisión a tierra.

En su primera fase, Kepler monitoreó de manera continua alrededor de 150000 estrellas en una región en la constelación Cygnus. A pesar de un exceso de ruido en las medidas, que hizo necesario tiempo adicional para completar los objetivos iniciales de la misión, se obtuvieron mediciones de brillo con una precisión fotométrica sin precedentes.

La misión operativa estuvo a punto de ser cancelada debido al fallo de dos de las cuatro ruedas de reacción, lo que hacía imposible mantener el telescopio estabilizado en 3 ejes apuntando hacia el objetivo. Pero finalmente, para extender su vida útil bajo el nombre de K2, se propuso un nuevo sistema de control que utilizaba la presión solar en la estructura, junto con las 2 ruedas de reacción operativas y los propulsores para apuntar a diferentes zonas a lo largo del plano de la eclíptica de manera estable. El combustible restante permitió realizar 19 campañas de observación de 3 meses de duración cada una, aumentando el número de estrellas observadas por Kepler/K2 a más de quinientos mil.

Como ya se expuso al principio del apartado, la técnica de tránsito se basa en la medición continua y precisa de la intensidad de luz emitida por una estrella a intervalos regulares. Al analizar estas mediciones, es posible detectar reducciones fotométricas que se repiten de manera periódica, lo que sugiere la presencia de un objeto que transita frente a la estrella.

Las transformadas wavelets constituyen una de las herramientas más interesantes para el análisis de señales no estacionarias, como las series de tiempo fotométricas de exoplanetas. A diferencia de la transformada de Fourier, que representa una señal en términos de frecuencias globales, las wavelets permiten una descomposición localizada en el dominio del tiempo y la frecuencia. Esto es crucial en el análisis de tránsitos exoplanetarios, ya que los eventos de tránsito son de corta duración y pueden ser difíciles de distinguir en presencia de ruido y variaciones estelares intrínsecas.

Para ello su combinación con las nuevas tecnologías de clasificación como las redes neuronales artificiales (ANNs), que son modelos computacionales inspirados en la estructura del cerebro humano y han demostrado ser altamente eficaces en tareas de clasificación y reconocimiento de patrones.

Las redes neuronales están compuestas por neuronas artificiales, cada una de las cuales recibe un conjunto de entradas, las pondera mediante pesos sinápticos, aplica una función de activación y genera una salida. Dependiendo de su función dentro de la red, las neuronas pueden clasificarse en tres tipos:

- Neuronas de entrada: Representan la primera capa de la red y reciben los datos crudos (en nuestro caso, series de tiempo).
- Neuronas ocultas: Encargadas de extraer patrones complejos mediante combinaciones no lineales de las entradas. En algunas arquitecturas de aprendizaje profundo incluyen neuronas convolucionales y capas de pooling, para extraer características.
- Neuronas de salida: Producen la predicción final, en este caso, la clasificación de una curva de luz en "tránsito planetario" o "no tránsito".

Las redes neuronales funcionan gracias a la transmisión de información hacia adelante y atrás a través de sus diferentes capas, esto permite hacer predicciones o modificar sesgos en las neuronas para mejorar la salida (Ketkar et al., 2021).

La propagación hacia adelante es un proceso fundamental en el funcionamiento de las redes neuronales, mediante el cual se generan las salidas a partir de las entradas. En esta etapa, los datos de entrada son alimentados a la red y pasan a través de diversas capas de neuronas, donde se aplican funciones de activación no lineales y se consideran los pesos asociados a cada conexión. A medida que los datos se desplazan a través de la red, se calculan las activaciones de cada neurona, resultando en una salida final que puede ser comparada con la salida esperada. Este paso es crucial para la evaluación del rendimiento de la red, ya que permite determinar la función de pérdida que cuantifica el error en las predicciones.

En contraste, la propagación hacia atrás es el mecanismo que permite la optimización de los pesos de la red en función del error obtenido en la etapa de propagación hacia adelante. A través del algoritmo de retro propagación, se calculan los gradientes de la función de pérdida

respecto a los pesos y sesgos de la red, utilizando la regla de la cadena para propagar el error desde la salida hacia las capas anteriores. Estos gradientes son esenciales para actualizar los pesos mediante métodos de optimización, como el descenso por gradiente. De esta forma, la propagación hacia atrás no solo facilita el aprendizaje de la red neuronal, sino que también permite que la red refine sus predicciones a lo largo de múltiples iteraciones, mejorando su capacidad para generalizar en tareas futuras.

Con el objetivo de abordar esta problemática de la naturaleza variable de las señales, este trabajo de fin de máster se centra en el diseño y entrenamiento de Redes Neuronales Convolucionales (CNNs) para el análisis de la descomposición wavelet de las curvas de luz obtenidas por la misión Kepler. Las CNNs, reconocidas por su capacidad para procesar y extraer características relevantes de datos estructurados en forma matricial, se presentan como una herramienta prometedora en el campo de la clasificación de señales. La descomposición wavelet, por su parte, permite transformar las curvas de luz en representaciones que capturan tanto la información temporal como la frecuencial, lo que facilita la identificación de patrones característicos en los datos.

Actualmente, debido a varias investigaciones anteriores enfocadas en el uso de redes neuronales convolucionales para la detección de exoplanetas (Queupumil Faundez, 2023; López Carballal, 2024), se han desarrollado arquitecturas CNN adaptadas específicamente al análisis de curvas de luz. Estos trabajos introducen la aplicación de transformaciones wavelet como paso previo, junto con un preprocesamiento que incluye el plegado en fase y el binning a diferentes resoluciones, con el objetivo de resaltar patrones asociados a los tránsitos planetarios. Dichos avances constituyen un punto de partida relevante sobre el que se construye este trabajo, que busca evaluar en mayor profundidad el papel de las wavelets y explorar arquitecturas alternativas que optimicen la clasificación de candidatos exoplanetarios. Sin embargo, la detección y clasificación de estos eventos aún enfrentan desafíos, especialmente en situaciones donde se presentan falsos positivos, como en el caso de eclipses débiles u otros fenómenos que simulan la señal de un tránsito (Shallue et al., 2018). Debido a esto, este proyecto se orienta hacia el refinamiento del modelo existente, mediante el ajuste meticuloso de parámetros y la validación exhaustiva tanto en curvas de luz simuladas como en datos reales. La meta es establecer un criterio estadístico robusto que permita

caracterizar de manera inequívoca el objeto que produce el eclipse, diferenciando de forma efectiva entre un exoplaneta y otras posibles fuentes de la señal.

En conclusión, el trabajo propuesto intentará mejorar el rendimiento en la clasificación de eventos de tránsito realizando optimizaciones y modificaciones a la arquitectura de referencia, además de contribuir al avance en la integración de técnicas de inteligencia artificial en el análisis de datos astrofísicos. La combinación de la capacidad de las CNNs para el reconocimiento de patrones con el potencial de la descomposición wavelet promete ofrecer una herramienta innovadora y eficaz en la detección y caracterización de exoplanetas.

En primera instancia se buscará optimizar los resultados obtenidos en estudios anteriores, evaluando diferentes tipos de wavelets y usando diferentes combinaciones de niveles. En segunda instancia se propondrá una nueva arquitectura basada en la arquitectura original de Shallue (2018) combinándola con nuevas técnicas de *Deep Learning*, como pueden ser las capas de salto (*skip layers*) que aportan contexto semántico al modelo y actualmente son ampliamente usadas en numerosos modelos como puede ser el de ResNet (Targ et al., 2016).

2. ESTADO DEL ARTE

2.1. SERIES TEMPORALES SERIES TEMPORALES PARA LA DETECCIÓN DE TRÁNSITOS

El análisis de los tránsitos de exoplanetas se basa en el estudio de series de tiempo fotométricas, en las cuales se registra la variación del flujo estelar a lo largo del tiempo. Estas curvas de luz permiten detectar caídas periódicas en el brillo de una estrella, lo que indica el posible paso de un exoplaneta frente a su disco. Sin embargo, para lograr una detección confiable, es fundamental contar con datos de alta calidad y aplicar técnicas de preprocesamiento adecuadas, separando las señales que producen el posible exoplaneta de la variabilidad intrínseca de la estrella y de posibles efectos instrumentales.

Para la detección de tránsitos el método clásico es el algoritmo BLS (Box Fitting Least Squares) (Kovács et al., 2002) que modela el tránsito como una caída y recuperación abrupta del brillo. Esta “caja” se mueve a lo largo de la serie temporal buscando su forma óptima. La técnica TLS (Transit Least Squares) (Hippke et al., 2019) funciona de un modo similar, pero utiliza en un modelo de tránsito más realista, teniendo en cuenta efectos como el oscurecimiento del borde *estelar*, superando así los problemas de BLS cuando la relación señal/ruido es baja.

Los procesos gaussianos (Rajpaul et al., 2015) permiten modelar el ruido correlacionadas que procede de la variabilidad intrínseca de la estrella para separarlas de la señal del exoplaneta. Pueden adaptarse a distintos patrones de correlación de los datos seleccionando el “kernel” o función de covarianza más adecuados. En combinación con los procesos gaussianos, la inferencia bayesiana (Haywood et al., 2014) permite incorporar conocimientos previos sobre la señal o el ruido y facilita la cuantificación de incertidumbres en la detección la señal.

ARPS (Autoregressive Planetary Search) (Caceres et al., 2019) es una metodología prometedora que utiliza modelos ARIMA para modelizar la estrella, TCF (Transit Comb Filter) para modelizar el tránsito del exoplaneta y métodos clásicos de clasificación como Random Forest para reducir los falsos positivos procedentes de señales no planetarias.

El uso de redes neuronales para separar la señal del ruido en la detección de exoplanetas está menos extendido, pero es prometedor. En Morvan et al. (2020) se propone un método para eliminar las tendencias en las curvas de luz utilizando una red LSTM probabilística (Long Short

Term Memory)), que permite reconstruir la línea base estelar y facilita la extracción del tránsito.

Finalmente, citamos por su posible interés los Temporal Fusion Transformers (TFT) (Lima et al., 2020), un modelo de aprendizaje profundo diseñado específicamente para la predicción de series temporales que combina elementos de los grandes modelos de lenguaje (Large Language Models - LLM), como el mecanismo de atención que permite capturar dependencias a largo plazo, con redes neuronales recurrentes (RNN) que modelan patrones locales. No existen referencias de aplicación de los TFT a la detección de exoplanetas, aunque se ha aplicado con éxito en otras áreas como la predicción financiera, previsión de la demanda energética y pronósticos meteorológicos (Lim et al., 2021; Giacomazzi et al., 2023; Civitarese et al., 2021).

2.2. TRANSFORMADA WAVELET

La transformada wavelet ha demostrado ser una herramienta clave en el análisis de series temporales no estacionarias, como las obtenidas en la detección de exoplanetas mediante técnicas de tránsitos. A diferencia de otros métodos de procesamiento de señales, la wavelet permite analizar simultáneamente la localización temporal y la distribución espectral de las variaciones de luz estelar, lo que la hace especialmente útil para la identificación de señales débiles y la reducción de ruido en datos astronómicos (Del Ser & Fors, 2020):

- Cambios abruptos en el brillo estelar: Los tránsitos planetarios producen caídas bruscas y simétricas en la curva de luz, que pueden ser resaltadas mediante wavelets al eliminar variaciones más suaves debidas a la actividad estelar o al ruido instrumental.
- Eliminación de tendencias de bajo orden: Muchas estrellas presentan variaciones de brillo debido a fenómenos como la rotación estelar y la presencia de manchas en su superficie. La transformada wavelet permite separar estas variaciones de larga escala y centrarse en eventos de corta duración, como los tránsitos planetarios.

- Reducción del ruido en la señal: Mediante la selección adecuada de coeficientes wavelet, es posible filtrar ruido de alta frecuencia sin afectar la señal del tránsito, lo que mejora la relación señal-ruido del evento.

En este sentido, estudios recientes han explorado la combinación de la wavelet con redes neuronales convolucionales (CNNs) para mejorar la precisión en la detección de exoplanetas. Al transformar la serie temporal original en una representación multi-escala, la wavelet facilita la extracción de características relevantes que pueden ser aprovechadas por CNNs para clasificar eventos astrofísicos con mayor robustez y reducir la tasa de falsos positivos en grandes volúmenes de datos observacionales (Rhif et al., 2019).

Sin embargo, el uso de la wavelet en este contexto presenta varios desafíos metodológicos ya que no solo existe una única transformación wavelet, sino que una misma señal se puede procesar con diferentes familias de wavelets obteniendo resultados distintos. Cada una de estas familias wavelet están formadas por una onda principal distinta, la cual se denomina la wavelet madre, de la cual se derivan las diferentes escalas de resolución. La selección de la wavelet madre adecuada es un factor crítico, ya que diferentes funciones base pueden afectar la capacidad de detección de patrones específicos en las curvas de luz. Además, la elección de la escala óptima de descomposición influye directamente en la resolución temporal y en la sensibilidad del modelo ante tránsitos planetarios de distinta duración. Otro aspecto relevante es la integración eficiente entre la wavelet y las CNNs, donde se han explorado enfoques como la utilización de coeficientes wavelet como mapas de características o la aplicación de transformadas wavelets bidimensionales en imágenes generadas a partir de las series temporales. Estos enfoques han mostrado resultados prometedores en la detección automática de exoplanetas en datos de misiones espaciales como Kepler y TESS, lo que sugiere que el uso de wavelet en combinación con modelos de aprendizaje profundo continuará evolucionando como una metodología clave en la astrofísica computacional (Rhif et al., 2019).

También ha habido otros trabajos, como el de Masciadri y Raga (2004) que exploraron la aplicación del análisis wavelet en la detección de exoplanetas mediante imágenes obtenidas con telescopios terrestres equipados con óptica adaptativa. Su estudio propuso un método automático para el reconocimiento de planetas basado en la descomposición de imágenes en diferentes escalas espaciales utilizando la wavelet “Mexican Hat”. La técnica permite discriminar entre planetas y artefactos causados por el ruido speckle y otros efectos ópticos,

facilitando la identificación de planetas con masas entre 3 y 12 veces la de Júpiter en sistemas jóvenes y cercanos. La capacidad del método para identificar planetas en imágenes con un alto contraste de magnitud respecto a la estrella central lo posiciona como una herramienta prometedora para futuros estudios de detección directa de exoplanetas.

Por otro lado, Grziwa y Pätzold (2016) desarrollaron métodos de filtrado basados en wavelets, como VARLET y PHALET, diseñados para mejorar la detección de planetas pequeños en curvas de luz estelares con variaciones fuertes y ruido instrumental. Estas técnicas, integradas en la plataforma EXOTRANS, permiten eliminar variaciones estelares, discontinuidades generadas por errores técnicos y eventos espurios, lo que facilita la identificación de tránsitos planetarios incluso cuando su señal es débil. Los resultados han demostrado que el uso de transformadas wavelets en combinación con algoritmos de búsqueda de tránsitos, como el método Box-Least-Squares (BLS), incrementa la eficiencia en la detección de exoplanetas de pequeño tamaño.

Finalmente, el trabajo presentado en Liao et al. (2024) describe los resultados de la identificación de exoplanetas en base a curvas de luz de TESS usando una combinación de transformadas wavelet y red neuronal convolucional basada en Inception-v3. Este procesado es capaz de clasificar las curvas, con una precisión aproximada del 95%, en estrellas variables, exoplanetas, estrellas variables y ruido instrumental, demostrando que el uso de wavelet, junto con arquitecturas avanzadas de redes neuronales es capaz de conseguir muy buenos resultados.

2.3. REDES NEURONALES CONVOLUCIONES PARA LA IDENTIFICACIÓN DE EXOPLANETAS

Las Redes Neuronales Convolucionales, conocidas comúnmente como CNNs (por sus siglas en inglés *Convolutional Neural Networks*), constituyen un tipo muy específico y altamente especializado de red neuronal artificial. Estas redes han sido diseñadas y optimizadas para procesar datos que se encuentran organizados en estructuras matriciales, tales como imágenes o series temporales, lo que les permite manejar y analizar estos formatos de manera eficaz (Choudhry et al., 2023).

La capacidad de estas arquitecturas para detectar patrones y extraer características relevantes a partir de series temporales ha llevado a que su aplicación se extienda ampliamente en la detección de exoplanetas (Prithivraj et al., 2023). Este uso se fundamenta en que el método principal empleado para realizar estas detecciones es el estudio del tránsito, un proceso que se apoya en la identificación y análisis de las variaciones en la curva de luz de la estrella observada, ocasionadas por el paso de un planeta que órbita alrededor de ella (Agnes et al., 2022).

El proceso habitual para el análisis de dichas curvas de luz se desarrolla en varias etapas secuenciales. En primer lugar, la serie temporal de la curva de luz es sometida a un preprocesamiento que la transforma en una representación bidimensional en forma de imagen de Markov, la cual refleja las transiciones de la señal en el tiempo. Esta representación visual se emplea como entrada para la CNN, que a partir de ella es capaz de extraer las características fundamentales y proceder a la clasificación. Dicha clasificación puede ser positiva, es decir, cuando la variación se atribuye al tránsito de un exoplaneta, o negativa, cuando la variación está originada por otros fenómenos astrofísicos distintos al tránsito (Donnelly et al., 2024). Dentro de este marco, existen ciertas variaciones en el proceso que pueden influir en la capacidad del modelo para realizar clasificaciones satisfactorias de exoplanetas. Un ejemplo concreto de estas variaciones se encuentra en el trabajo expuesto en (Shallue et al., 2018), en el cual la arquitectura utilizada combina dos CNNs junto a una estructura de capas completamente conectadas. En esta configuración, cada una de las CNNs se encarga de procesar y reducir dos entradas distintas, las cuales se corresponden a dos vistas generadas para extraer información de diferentes contextos del tránsito, una visión general de la serie y otra centrada en el evento eclipsante, denominándose vista global y local respectivamente. Posteriormente, las características extraídas de ambas vistas se utilizan como entrada para la capa completamente conectada, que se encarga de efectuar la extracción final de características y de realizar la clasificación correspondiente.

Aunque el modelo propuesto logró clasificar el tránsito de exoplanetas con una efectividad del 98,8%, los investigadores responsables del estudio señalaron ciertas dificultades en la clasificación en situaciones de falsos positivos, como en el caso de eclipses débiles. Por ello, se reconoce que aún existe la necesidad de seguir perfeccionando tanto las arquitecturas

empleadas como los métodos utilizados en la detección de exoplanetas, a fin de superar estas limitaciones y optimizar los resultados en futuras investigaciones.

2.4.CONCLUSIONES

El análisis del estado del arte evidencia que la detección de exoplanetas a través del método de tránsitos ha evolucionado desde técnicas clásicas de búsqueda, como BLS y TLS, hasta el uso de modelos estadísticos avanzados, como los procesos gaussianos y ARPS, que permiten un modelado más robusto de la variabilidad estelar y del ruido instrumental. Estas metodologías han sido clave para establecer las bases de la detección automática, aunque presentan limitaciones en escenarios de bajo cociente señal-ruido y en la clasificación de falsos positivos.

La introducción de la transformada wavelet ha supuesto un avance significativo en el tratamiento de curvas de luz, al permitir una descomposición multiescalar que facilita tanto la eliminación de ruido como la identificación de señales transitorias. Los estudios revisados demuestran que el tipo de wavelet madre seleccionada y el nivel de descomposición constituyen factores determinantes en el rendimiento de los modelos, lo que subraya la necesidad de una adecuada optimización en cada aplicación concreta. Asimismo, la combinación de wavelets con arquitecturas de aprendizaje profundo ha mostrado resultados prometedores, mejorando la capacidad discriminatoria frente a métodos tradicionales.

Finalmente, las redes neuronales convolucionales se consolidan como una de las herramientas más potentes para la clasificación de curvas de luz, al ser capaces de extraer automáticamente patrones complejos sin necesidad de diseñar manualmente características. Modelos como el propuesto por Shallue y Vanderburg (2018) marcan un punto de inflexión en este campo, aunque persisten retos relacionados con la interpretación de falsos positivos y la necesidad de arquitecturas más flexibles y adaptadas a la naturaleza multiescala de las señales astrofísicas.

En conjunto, este recorrido bibliográfico muestra que el futuro de la detección de exoplanetas pasa por la integración de técnicas de procesamiento avanzado, como las transformadas wavelets, con arquitecturas de deep learning diseñadas específicamente para la naturaleza de los datos astronómicos. Estos avances constituyen el fundamento sobre el cual se apoya el presente trabajo, orientado a explorar y evaluar nuevas configuraciones de CNNs en

combinación con transformadas wavelets para optimizar la detección automática de exoplanetas.

3. OBJETIVOS

3.1. GENERAL

Evaluar el impacto del uso de transformaciones wavelet en el rendimiento de redes neuronales convolucionales (CNNs) para la detección de tránsitos de exoplanetas, mediante el análisis de un conjunto de datos específico procedente de la misión Kepler y el desarrollo de arquitecturas alternativas adaptadas a esta técnica.

3.2. ESPECÍFICOS

A continuación, se enumeran los objetivos específicos el proyecto:

- Analizar la estructura del conjunto de datos reales utilizado para la detección de tránsitos planetarios.
- Aplicar transformaciones wavelet a las series temporales del conjunto de datos, generando representaciones multiescala.
- Diseñar una arquitectura base de red neuronal convolucional (inspirada en Shallue (2018)) para la clasificación de tránsitos.
- Integrar las transformaciones wavelet en distintas versiones de la arquitectura base para evaluar su influencia en la precisión del modelo.
- Comparar el rendimiento de las redes con y sin transformaciones wavelet, utilizando métricas como accuracy, precisión, recall y F1-score.
- Proponer y evaluar arquitecturas alternativas de red neuronal que aprovechen de forma más eficiente las características extraídas mediante wavelets.
- Discutir las ventajas y limitaciones del uso de wavelets en este tipo de tareas y plantear posibles conclusiones y líneas futuras de investigación.

4. METODOLOGIA

4.1.DETECCIÓN DE TRÁNSITOS PLANETARIOS

El método de tránsitos planetarios es una de las técnicas más utilizadas para la detección de exoplanetas. Se basa en la observación de variaciones en la curva de luz de una estrella cuando un planeta pasa frente a ella, bloqueando una fracción de su luz. Este fenómeno se manifiesta como una disminución periódica y característica en la luminosidad estelar, lo que permite inferir propiedades del exoplaneta, como su tamaño y período orbital.

4.1.1. Fundamentos del método de tránsitos

Cuando un planeta transita frente a su estrella, la profundidad de la atenuación en el flujo luminoso (δ) está relacionada con el radio del planeta (R_p) y el radio de la estrella (R_*) a través de la ecuación (2) (Shallue & Vanderburg, 2018):

$$\delta = \left(\frac{R_p}{R_*}\right)^2 \quad (2)$$

Los parámetros clave que se pueden extraer del tránsito incluyen:

- Período orbital (P), determinado por la separación temporal entre tránsitos sucesivos.
- Duración del tránsito (T_d), dependiente del tamaño estelar y la geometría orbital.
- Forma del tránsito, útil para distinguir entre tránsitos planetarios y otros eventos astrofísicos, como binarias eclipsantes.

4.1.2. Datos de estudio


Para entrenar el modelo de redes neuronales en la detección de tránsitos, se han utilizado los datos provenientes del *NASA Exoplanet Archive* (Christiansen *et al.*, 2025), contienen curvas de luz de estrellas observadas por la misión Kepler, etiquetadas manualmente como tránsitos confirmados o eventos de falso positivo.

4.2.SERIES DE TIEMPO

4.2.1. Obtención y análisis de los datos de la misión Kepler

Los datos obtenidos por Kepler se encuentran disponibles en el *NASA Exoplanet Archive* (Christiansen et al., 2025), un repositorio que centraliza información sobre exoplanetas descubiertos y proporciona acceso a curvas de luz procesadas y metadatos relevantes (Figura 5). El acceso a estos datos permite seleccionar estrellas con tránsitos confirmados o candidatos y aplicar técnicas de preprocesamiento para mejorar la detección de eventos planetarios. Además, al contar con series de tiempo de larga duración, es posible estudiar propiedades orbitales de los exoplanetas, como su periodo y profundidad del tránsito, facilitando su caracterización.

Figura 5: Página principal de NASA Exoplanet Archive.



Dentro de la web es posible hacer búsquedas a objetos en concreto o acceder a los datos íntegros de las misiones disponibles seleccionando la opción de '*Objects of Interest*'. Dentro de este apartado (Figura 6) es posible navegar entre todos los datos disponibles, e incluso

poder visualizar las series temporales disponibles. En nuestro caso, se van a descargar los datos disponibles en formato tabular (csv) desde el apartado 'Data'.

Figura 6: Apartado de datos de la misión Kepler con las columnas de datos disponibles.

NASA EXOPLANET ARCHIVE

NASA EXOPLANET SCIENCE INSTITUTE

Home

About Us

Data

Tools

Support

Login

Select Columns

Download Table

Plot Table

Download Data Products

View Documentation

User Preferences

Cumulative KOI Data

KeplerID	KOI Name	Kepler Name	Exoplanet Archive Disposition	Orbital Period [days]	Transit Epoch [BJD]	Transit Duration [hrs]	Transit Depth [ppm]	Transit Signal-to-Noise	TCE Planet Number	TCE Delivery	RA [decimal degrees]	Dec [decimal degrees]	Kepler-band [mag]
10797460	K00752.01	Kepler-227 b	CONFIRMED	9.48803557±2.775e-05	170.53875±0.00216	2.9575±0.0819	615.8±19.5	35.80	1	q1_q17_dr25_291.934230	48.141651	15.347	
10797460	K00752.02	Kepler-227 c	CONFIRMED	54.4183827±0.0002475	162.51384±0.00352	4.507±0.116	874.8±35.5	25.80	2	q1_q17_dr25_291.934230	48.141651	15.347	
10811496	K00753.01		CANDIDATE	19.89913995±1.494e-01	175.850252±0.00058	1.7822±0.0341	10829±171	76.30	1	q1_q17_dr25_297.004820	48.134129	15.436	
10848459	K00754.01		FALSE POSITIVE	1.736952453±2.63e-07	170.307565±0.000111	2.40641±0.00537	8079.2±12.8	505.60	1	q1_q17_dr25_285.534610	48.285210	15.597	
10854555	K00755.01	Kepler-664 b	CONFIRMED	2.525591777±3.761e-01	171.59555±0.00113	1.6545±0.042	603.3±16.9	40.90	1	q1_q17_dr25_288.754880	48.226200	15.509	
10872983	K00756.01	Kepler-228 d	CONFIRMED	11.09432054±2.036e-01	171.20116±0.00141	4.5945±0.061	1517.5±24.2	66.50	1	q1_q17_dr25_296.286130	48.224670	15.714	
10872983	K00756.02	Kepler-228 c	CONFIRMED	4.13443512±1.046e-05	172.97937±0.0019	3.1402±0.0673	686±18.7	40.20	2	q1_q17_dr25_296.286130	48.224670	15.714	
10872983	K00756.03	Kepler-228 b	CONFIRMED	2.56658897±1.781e-05	179.55437±0.00461	2.429±0.165	226.5±16.8	15.00	3	q1_q17_dr25_296.286130	48.224670	15.714	
6721123	K00114.01		FALSE POSITIVE	7.36178958±2.128e-05	132.25053±0.00253	5.022±0.136	233.7±5.8	47.70	1	q1_q17_dr25_298.864350	42.151569	12.660	
10910878	K00757.01	Kepler-229 c	CONFIRMED	16.06864674±1.088e-01	173.621937±0.00051	3.5347±0.0241	4914.3±33.3	161.90	1	q1_q17_dr25_286.999480	48.375790	15.841	
11446443	K00001.01	Kepler-1 b	CONFIRMED	2.470613377±2.7e-08	122.763305±8.7e-06	1.74319±0.00107	14230.9±4.2	4304.30	1	q1_q17_dr25_286.808470	49.316399	11.338	
10666592	K00002.01	Kepler-2 b	CONFIRMED	2.204735417±4.3e-08	121.3585417±1.6e-05	3.88864±0.00203	6674.7±1.7	5945.90	1	q1_q17_dr25_292.247280	47.969521	10.463	
6922244	K00010.01	Kepler-8 b	CONFIRMED	3.522498429±1.98e-07	121.1194228±4.71e-03	3.19843±0.00653	9145.7±6.6	1741.50	1	q1_q17_dr25_281.288120	42.451080	13.563	
10984090	K00112.02	Kepler-466 c	CONFIRMED	3.709214104±6.536e-01	133.98318±0.00143	2.6302±0.0427	131.1±3	50.60	2	q1_q17_dr25_295.648710	48.495560	12.772	
10419211	K00742.01		FALSE POSITIVE	11.521446064±1.98e-01	170.839688±0.00013	3.6399±0.0114	17984.3±31.9	622.10	1	q1_q17_dr25_297.079930	47.597401	15.472	
10464078	K00743.01		FALSE POSITIVE	19.40393776±2.068e-01	172.484253±0.00084	12.215±0.0598	8918.7±53.3	214.70	1	q1_q17_dr25_289.258210	47.635319	15.487	
10480982	K00744.01		FALSE POSITIVE	19.22138894±2.123e-01	184.5521637±4.5e-05	4.79843±0.00235	74284±21.9	2317.00	1	q1_q17_dr25_295.814540	47.690350	15.341	
10485250	K00745.01		FALSE POSITIVE	16.46983774±1.361e-01	180.881761±0.00062	9.4378±0.06	10478.9±39.9	303.40	1	q1_q17_dr25_297.154420	47.668701	15.788	
10526549	K00746.01	Kepler-660 b	CONFIRMED	9.27358173±1.037e-05	173.258155±0.00087	3.2875±0.0309	1288.3±16.8	87.20	1	q1_q17_dr25_288.138240	47.724449	15.302	

Showing records 1 to 44 of 9564 (9564 total)

DOI 10.26133/NEA4

Clear Checked

Check All


Reset Filters

Una de las columnas más relevantes para este estudio es la nombrada 'koi_disposition' la cual indica el estado de validación de cada objeto tras distintos estudios realizados por el equipo de la misión Kepler. Esta clasificación permite conocer la naturaleza del objeto observado, y puede adoptar uno de los siguientes valores:

- *Confirmed*: El objeto ha sido confirmado como un exoplaneta mediante observaciones independientes y análisis complementarios. Se considera un planeta real y no una señal espuria o mal interpretada.
- *False Positive*: Se ha determinado que la señal no corresponde a un exoplaneta. Puede deberse a otros fenómenos astrofísicos como eclipses binarios, ruido instrumental o errores en el procesamiento de datos.
- *Candidate*: El objeto presenta una señal compatible con la de un posible exoplaneta, pero aún no se ha confirmado su naturaleza planetaria. Estos candidatos requieren análisis adicionales para ser clasificados como exoplanetas confirmados o descartados como falsos positivos.

En la Figura 7 se observa que la clase más numerosa es la de falsos positivos, con un total de 4839 objetos. Le siguen los exoplanetas confirmados, con 2743 casos, y finalmente los candidatos, que suman 1982. Esta distribución evidencia un claro desbalance de clases en el conjunto de datos, lo cual debe tenerse en cuenta durante el proceso de entrenamiento, ya que puede inducir sesgos hacia la clase mayoritaria.

Figura 7: Distribución de los objetos respecto la columna '*koi_disposition*'.



Es importante destacar que, dado que los candidatos aún no han sido confirmados ni descartados, no serán utilizados durante el entrenamiento del modelo. De esta forma, se evita introducir ruido en el proceso de aprendizaje y se garantiza que el modelo se entrene únicamente con ejemplos cuya clasificación es segura (confirmados o falsos positivos). No obstante, los candidatos podrían ser utilizados posteriormente para evaluar la capacidad del modelo de identificar posibles nuevos exoplanetas.

4.2.2. Descarga de las series de tiempo

La descarga de las curvas de luz se realiza de forma automatizada utilizando la biblioteca *Lightkurve*, una herramienta de código abierto diseñada específicamente para el análisis de series temporales provenientes de las misiones *Kepler* y *TESS* (Lightkurve Collaboration et al., 2018), y utilizando MAST para su disponibilidad. El MAST (*Mikulski Archive for Space Telescopes*) es el archivo científico de la NASA que almacena, gestiona y distribuye los datos obtenidos por misiones espaciales de observación, como *Kepler*, *TESS*, *Hubble* o *JWST*. Este repositorio centralizado permite a la comunidad científica acceder a curvas de luz, espectros e imágenes procesadas, garantizando la preservación y disponibilidad de los datos para investigaciones actuales y futuras. Para cada objeto listado en el archivo CSV, se construye su identificador oficial a partir del número de catálogo (*kepid*) con el formato *KIC XXXXXXXX*. A continuación, se realiza una búsqueda en el archivo *MAST* mediante la función '*search_lightcurve*', especificando tanto el identificador como la misión correspondiente. Esta búsqueda devuelve un conjunto de productos fotométricos que se descargan automáticamente mediante la función '*download_all*', la cual permite obtener y almacenar localmente toda la colección de curvas de luz disponibles para ese objeto. Este procedimiento asegura una recopilación completa y estructurada de los datos necesarios para el posterior análisis con redes neuronales.


4.2.3. Plegado de series temporales

Una vez descargadas las series temporales de los tránsitos, se procede al plegado en fase. Esta técnica se utiliza para superponer múltiples tránsitos de un mismo exoplaneta en una única curva de luz periódica, lo que permite reforzar la señal del tránsito y reducir el ruido, facilitando su detección y análisis. Para ello, primero se elige una época de referencia t_0 (*koi_time0bk*) y un periodo orbital P (*koi_period*), y para cada punto temporal t se calcula la fase:

$$\varphi = \frac{(t - t_0) \bmod(P)}{P} \quad (1)$$

A continuación, se normalizan todas las curvas (por ejemplo, dividiendo por la mediana fuera de tránsito) y se ordenan por φ , de modo que cada tránsito quede localizado sobre los demás. Al superponerlos, las variaciones periódicas (la profundidad causada por el objeto eclipsante) se refuerzan y el ruido aleatorio se atenúa, obteniendo una depresión de flujo mucho más nítida, como se muestra en la Figura 8.

Figura 8: Serie de luminosidad plegada en fase.



4.2.4. Generación de vista Global y Local

Siguiendo la metodología de Shallue & Vanderburg (2018), una vez plegada la curva en fase se emplean las máscaras “*odd_mask*” y “*even_mask*” para separar los puntos correspondientes a tránsitos pares e impares; a continuación, a cada uno de estos dos subconjuntos se le generan dos tipos de vistas mediante un bineado a diferente resolución:

- **Vista global (pares e impares):** se toma el rango completo de fase (por ejemplo, $-0,5$ a $+0,5$ ciclos alrededor del tránsito), se normaliza dividiendo por la mediana del flujo fuera de tránsito y se interpola a una longitud fija para conservar la forma completa del ciclo (Figura 9 y Figura 10).

Figura 9: Vista global de la serie par.





Figura 10: Vista global de la serie impar.



- **Vista local (pares e impares):** se recorta una ventana estrecha centrada en fase cero (por ejemplo, $\pm 2,5$ veces la duración estimada del tránsito), se aplica la misma normalización y se interpola a un número reducido de puntos para resaltar con mayor detalle la depresión del tránsito (Figura 11 y Figura 12).

Figura 11: Vista local de la serie par.





Figura 12: Vista local de la serie impar




De este modo, cada conjunto refleja la misma señal, pero aísla posibles sesgos sistemáticos propios de los subconjuntos par e impar y ofrece dos escalas de observación (fenómeno global vs. detalle local) para su análisis posterior.

4.2.5. Wavelets

En el postprocesado de las series temporales mediante transformaciones wavelet, las cuales se aplican a las curvas ya plegadas y bineadas, la elección de la familia wavelet o wavelet madre constituye un parámetro fundamental, ya que determina cómo se descompone la señal en distintas escalas temporales y frecuenciales, tal y como se puede observar en la Figura 13.

Figura 13: Wavelets madre junto con la función de escalado.




En este trabajo se han seleccionado cuatro familias representativas, que abarcan distintas propiedades matemáticas y comportamientos en el dominio tiempo-frecuencia. Estas familias, ilustradas en la Figura 14, son:

- **Symlet (sym5):** Wavelets ortonormales con simetría casi perfecta y soporte compacto. Diseñadas como una versión mejorada de las Daubechies clásicas, minimizan el desplazamiento de fase y conservan la forma temporal de la señal.
- **Haar (haar):** Wavelet discontinua y de forma escalonada, considerada la más simple de todas. Es especialmente sensible a transiciones bruscas en la señal y presenta una implementación computacionalmente eficiente.
- **Meyer (dmey):** Wavelet suave e infinitamente diferenciable, con soporte compacto en frecuencia. Su estructura evita artefactos como el efecto de Gibbs y permite una buena resolución en el análisis multiescala.

- **Daubechies (db5):** Wavelets ortonormales con cinco coeficientes y cinco momentos anulados. Ofrecen un equilibrio adecuado entre localización temporal y capacidad para representar señales suaves o polinómicas.

Figura 14: Familias wavelets seleccionadas para el análisis.



En una transformación wavelet discreta, cada nivel de descomposición separa la señal original en dos componentes: la curva de aproximación, que captura la evolución general de baja frecuencia, y la curva de detalle, que contiene las oscilaciones de alta frecuencia asociadas a cambios rápidos o ruido. Las aproximaciones representan la señal suavizada a distintas escalas, revelando la estructura global y los patrones persistentes a lo largo del tiempo. Por el contrario, los detalles están más influenciados por las fluctuaciones locales y el contenido de alta frecuencia, lo que puede incluir tanto información relevante como ruido instrumental o estelar. En este trabajo se ha optado por conservar exclusivamente las aproximaciones de los primeros niveles, ya que son las que mejor preservan la forma general del tránsito planetario

y reducen la sensibilidad al ruido, favoreciendo una representación más robusta para el posterior análisis con redes neuronales.

Además, se deberán seleccionar el número de niveles de procesamiento wavelet que se va a llevar a cabo para las series, en este caso se ha buscado un equilibrio entre la vista global (Figura 15) y local, observando que al llegar al nivel 4 en la vista local (Figura 16) ya se empieza a no diferenciar el tránsito, por lo que se ha seleccionado el nivel 4 como límite de transformación.

Figura 15: Niveles Wavelets para la vista global par (izquierda) e impar (derecha).






Figura 16: Niveles Wavelet para la vista local par (izquierda) e impar (derecha).



Para preparar los datos de entrada del modelo, las series temporales se transforman mediante wavelets y se reorganizan en una estructura matricial que puede interpretarse como una

imagen. Para cada vista, local y global, se aplica la descomposición wavelet por separado a las curvas de tránsitos pares e impares. De cada una se extraen las aproximaciones correspondientes a los cuatro primeros niveles de descomposición. Esto da lugar a un total de ocho curvas por vista (cuatro de pares y cuatro de impares), que se apilan para formar una matriz en la que cada fila representa una escala temporal distinta. Las columnas corresponden a los puntos de la serie temporal alineados en fase. Esta representación permite capturar de forma estructurada la evolución multiescala de los tránsitos y las posibles diferencias entre pares e impares, sirviendo como entrada enriquecida para el modelo convolucional (Figura 17).

Figura 17: Ejemplo de entrada para el modelo.




Estas familias se aplican de forma independiente para transformar las curvas de luz antes del análisis. Su comparación permitirá evaluar el impacto de cada una en la calidad de las representaciones obtenidas y, en última instancia, en el rendimiento del modelo de red neuronal entrenado posteriormente.

4.3.ARQUITECTURAS IMPLEMENTADAS

En este trabajo, se utilizan varias redes neuronales convolucionales (CNN) basadas en la arquitectura propuesta por Shallue et al. (2018), como se puede observar en la Figura 18 y

explicada en la sección 4.3.4.1, adaptada con técnicas más actuales para el análisis de series de tiempo, con el fin de detectar tránsitos exoplanetarios de manera eficiente.

Figura 18: Arquitectura utilizada en el trabajo de (Shallue et al., 2018) para la clasificación de exoplanetas.



4.3.1. Funciones de activación

Cada neurona aplica una función de activación para introducir no linealidad y mejorar la capacidad del modelo para detectar patrones complejos. En este caso, se han usado las siguientes funciones:

- ReLU (Rectified Linear Unit) (3): Ampliamente utilizada en capas ocultas debido a su estabilidad en el entrenamiento.

$$f(x) = \max(0, x) \quad (3)$$

- Sigmoide (4): Empleada en la capa de salida para clasificaciones binarias, debido a que tiende a saturarse en valores extremos al no estar centrada en cero.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

4.3.2. Tipos de capas

En el diseño de las redes implementadas, las diferentes capas desempeñan roles cruciales en el procesamiento y la interpretación de los datos. Cada tipo de capa contribuye de manera específica a las arquitecturas, facilitando la extracción de características, la reducción de dimensionalidad y la toma de decisiones finales. A continuación, se describen los tipos de capas utilizadas en este proyecto:

- Capas Convolucionales: Estas capas son fundamentales para la extracción de características en los datos de entrada. Aplican filtros convolucionales que detectan patrones locales, lo que permite a la red identificar características relevantes y significativas en las series de tiempo. La operación de convolución ayuda a mantener la relación espacial entre los datos, lo que es crucial para el análisis de secuencias.
- Capas de Pooling: Las capas de pooling se encargan de reducir la dimensionalidad de las representaciones generadas por las capas convolucionales. A través de técnicas como el max pooling o average pooling, estas capas resumen la información más

importante, lo que no solo disminuye la cantidad de parámetros a entrenar, sino que también mejora la invariancia de la red frente a pequeñas transformaciones y ruidos en los datos.

- Capas Completamente Conectadas (Fully Connected): Estas capas conectan cada neurona de una capa a todas las neuronas de la siguiente, lo que permite realizar combinaciones complejas de las características extraídas. Actúan como el clasificador final de la red, transformando las representaciones intermedias en salidas que pueden ser interpretadas para realizar predicciones. La capacidad de estas capas para aprender relaciones no lineales entre las características hace que sean cruciales en la toma de decisiones finales del modelo.
- Capas de salto de conexiones o Residuales (Skip Layers): Permiten crear atajos o caminos paralelos por los que la señal fluye sin pasar por todas las transformaciones intermedias, sumando la entrada original de un bloque con su salida procesada. De esta forma mitigan el desvanecimiento y la explosión del gradiente en redes muy profundas, mejoran la propagación de información y facilitan la convergencia. Al conservar simultáneamente características de niveles bajos y combinarlas con las de niveles altos, aportan un rico contexto semántico al modelo, ya que cada capa profunda puede contextualizar sus representaciones con rasgos primarios extraídos en etapas anteriores.

Además de las capas que conforman la red, es necesario definir el optimizador, encargado de ajustar los pesos y sesgos de las neuronas durante el entrenamiento. En este trabajo se ha empleado el algoritmo Adam (Adaptive Moment Estimation), uno de los más utilizados en el ámbito del aprendizaje profundo debido a su eficiencia y estabilidad. Adam combina las ventajas de AdaGrad y RMSProp, utilizando estimaciones de primer y segundo momento de los gradientes para adaptar de manera dinámica la tasa de aprendizaje de cada parámetro. Esto permite una convergencia más rápida y robusta incluso en problemas con datos ruidosos o de alta dimensionalidad, como es el caso de las curvas de luz astronómicas.

4.3.3. Funciones de pérdida

Las funciones de pérdida juegan un papel fundamental en el entrenamiento de redes neuronales, ya que cuantifican la discrepancia entre las predicciones del modelo y las

etiquetas reales, aplicando esta discrepancia para actualizar los pesos y sesgos de las neuronas durante la propagación hacia atrás. En este trabajo se ha utilizado Binary Cross Entropy with Logits (BCEWithLogitsLoss).

4.3.3.1. Binary Cross Entropy (BCEWithLogitsLoss).

Esta función de pérdida está especialmente diseñada para problemas de clasificación binaria. Combina en una sola operación la función de activación sigmoide y la entropía cruzada binaria, lo que evita problemas de estabilidad numérica derivados de aplicar ambas por separado. La sigmoide transforma la salida del modelo en una probabilidad en el rango $[0,1]$, mientras que la entropía cruzada mide la distancia entre dicha probabilidad y la etiqueta real (0 o 1). Matemáticamente, para una muestra con etiqueta real $y \in \{0,1\}$ y salida del modelo z , la pérdida se define como:

$$\mathcal{L}_{BCE}(z, y) = -[y \cdot \log(\sigma(z)) + (1 - y) \cdot \log(1 - \sigma(z))] \quad (5)$$

donde $\sigma(z)$ corresponde a la función sigmoide (4). Esta formulación asegura que el modelo penalice con mayor intensidad aquellas predicciones alejadas del valor correcto.

Además de las ventajas de integrar de forma estable la función sigmoide y la entropía cruzada binaria en una única operación, existe la posibilidad de ajustar el peso relativo de las clases mediante el parámetro `pos_weight`. Este hiperparámetro resulta especialmente útil cuando el conjunto de datos está desbalanceado, es decir, cuando la proporción de ejemplos positivos y negativos difiere significativamente. Al incrementar el valor de `pos_weight`, los errores cometidos en las predicciones de la clase positiva adquieren mayor relevancia en el cálculo de la pérdida, forzando al modelo a prestar más atención a los casos minoritarios. De esta forma, se mitiga el sesgo hacia la clase mayoritaria y se mejora la capacidad del modelo para detectar ejemplos poco representados, como ocurre con los tránsitos planetarios en grandes volúmenes de curvas de luz dominados por falsos positivos.

4.3.4. Modelos Propuestos

Con el fin de analizar el impacto de las transformaciones wavelet en la detección automática de tránsitos planetarios, se han desarrollado diferentes arquitecturas basadas en redes neuronales convolucionales. Todas ellas parten como referencia del modelo propuesto por Shallue et al. (2018), pero incorporan modificaciones estructurales orientadas a explotar la representación multiescala generada por la descomposición wavelet.

En concreto, se han implementado tres variantes principales: una adaptación del modelo original con convoluciones 1D y múltiples canales de entrada; una versión basada en convoluciones 2D sobre representaciones en formato imagen; y finalmente, una arquitectura extendida con convoluciones 2D y conexiones residuales (skip layers).

4.3.4.1. Modelo Shallue

El modelo base implementado en este trabajo se inspira en la arquitectura propuesta por Shallue et al. (2018) para la detección de exoplanetas en curvas de luz obtenidas por la misión Kepler. Esta red neuronal convolucional (CNN) fue diseñada originalmente para procesar una única curva de luz preprocesada, dividida en dos vistas: una vista global, que cubre todo el tránsito, y una vista local, centrada en la región del tránsito. Ambas vistas se procesan por separado mediante bloques de convolución 1D y capas de pooling, y sus salidas se concatenan antes de pasar a capas densas completamente conectadas que generan la predicción final.

En el presente trabajo, se ha modificado la entrada del modelo con el objetivo de evaluar el impacto de las transformaciones wavelet sobre el rendimiento de la red. En lugar de utilizar directamente las vistas global y local como entradas independientes, se ha propuesto una variante en la que cada nivel de descomposición wavelet se trata como un canal independiente. Esto permite conservar la estructura multiescala de la señal original, facilitando que la red aprenda características a diferentes resoluciones temporales. Las convoluciones 1D se aplican entonces sobre entradas multicanal, lo que requiere una adaptación en la capa de entrada y en la forma de procesar los datos, pero preserva la estructura general de la arquitectura original.


Esta modificación busca aprovechar las ventajas teóricas de las transformadas wavelets en la detección de señales localizadas y periódicas, como los tránsitos planetarios, manteniendo al mismo tiempo la robustez demostrada del modelo original.

4.3.4.2. Modelo de Shallue2D

Adicionalmente, se ha desarrollado una segunda variante de la arquitectura original de Shallue et al. (2018) en la que se adapta la red para procesar entradas en formato imagen mediante convoluciones bidimensionales (2D). En esta versión, las distintas representaciones temporales generadas por la descomposición wavelet no se introducen como canales independientes de una señal unidimensional, sino que se estructuran como una matriz multicanal que puede ser interpretada como una imagen 2D, en la que un eje representa el tiempo y el otro los diferentes niveles de descomposición o escalas.

Esta reorganización permite aplicar filtros convolucionales 2D que extraen patrones tanto en el dominio temporal como a lo largo de las distintas escalas, capturando relaciones cruzadas entre niveles que podrían resultar invisibles para una red puramente 1D. La arquitectura resultante conserva la estructura de bloques convolucionales seguida de capas densas, pero adapta la dimensionalidad de las capas de entrada, las operaciones de pooling y las convoluciones, para trabajar sobre tensores 2D, como se puede observar en la Figura 19. Esta variante explora la posibilidad de explotar mejor la naturaleza jerárquica y multiescalar de las transformaciones wavelet, utilizando técnicas estándar en el procesamiento de imágenes.

Figura 19: Arquitectura de Shallue modificada para convoluciones 2D.




4.3.4.3. Arquitectura propuesta

Finalmente, se ha implementado una tercera variante del modelo, basada también en convoluciones bidimensionales (Figura 20), pero incorporando conexiones residuales o skipplayers entre capas. Esta arquitectura está inspirada en principios de redes profundas como ResNet (Targ et al., 2016), en las que se introducen conexiones directas que saltan una o varias capas, facilitando el flujo de gradientes durante el entrenamiento y permitiendo que capas más profundas aprendan correcciones incrementales sobre representaciones previamente aprendidas.

En este diseño, la entrada del modelo sigue siendo una representación en formato imagen, en la que se combinan múltiples niveles de descomposición wavelet en una estructura 2D. Las convoluciones se aplican sobre esta entrada, y se insertan conexiones de salto a lo largo de la red, particularmente entre bloques convolucionales con igual dimensionalidad de salida. Estas conexiones residuales permiten conservar la información original a través de la red y mitigar problemas comunes en redes profundas como la desaparición del gradiente o el sobreajuste prematuro.

Este enfoque busca evaluar si una mayor profundidad estructural, junto con una mejor preservación de la información a lo largo de la red, puede beneficiar la tarea de detección de tránsitos en datos multiescala transformados mediante wavelets. Además, esta variante está pensada para generalizar mejor frente a ruido u observaciones parciales, al mantener una combinación activa entre características de bajo y alto nivel.

Figura 20: Arquitectura propuesta basada en el modelo de Shallue.



5. RESULTADOS

La ejecución de los modelos se ha llevado a cabo mediante las arquitecturas implementadas en Python, utilizando la librería PyTorch como marco principal de desarrollo. Todo el código correspondiente a este proyecto se encuentra disponible en un repositorio público de GitHub (<https://github.com/zmadru/ExoPlanet-Detection.git>), lo que garantiza su accesibilidad y reproducibilidad.

En el ámbito de la investigación en inteligencia artificial, se hace evidente la necesidad de examinar detalladamente los recursos de cómputo empleados en el entrenamiento y evaluación de redes neuronales profundas. Este análisis se torna particularmente relevante, dado que los tiempos de entrenamiento y evaluación dependen en gran medida de la capacidad de procesamiento de los equipos utilizados. En este caso, las pruebas se implementaron en un sistema equipado con un procesador AMD Ryzen 9 9950X, 64 GB de memoria RAM y una tarjeta gráfica AMD RX 9070XT con 16 GB de VRAM. Para contextualizar esta optimización, es pertinente señalar que la implementación del modelo más complejo en un dispositivo previo, equipado con una Nvidia RTX 3060 de 12 GB de VRAM, demandaba aproximadamente 40 minutos para completar el entrenamiento. En contraste, el nuevo hardware ha logrado reducir este tiempo a cerca de 12 minutos, lo que representa una aceleración significativa superior al 65 %.

En cuanto a la metodología de evaluación, en primer lugar, se presentan los resultados obtenidos por las distintas arquitecturas bajo las mismas condiciones de ejecución, lo que permite una comparación directa de su rendimiento. Posteriormente, se selecciona la mejor arquitectura identificada para analizar en detalle el impacto de las distintas familias wavelet en la clasificación de tránsitos.

5.1. BÚSQUEDA DEL MODELO ÓPTIMO

En este punto se van a evaluar los diferentes modelos implementados, tanto con las series de tiempo originales, así como con las series de tiempo descompuestas con las transformaciones wavelet.

Para evaluar todos los modelos desarrollados en este trabajo, se seleccionaron los siguientes hiperparámetros comunes, que fueron seleccionados tras realizar pruebas de rendimiento de los mismos de forma manual: un tamaño de lote (*batch size*) de 64 y un máximo de 100 épocas de entrenamiento, con una tasa de aprendizaje inicial de 0.0001 ajustable dinámicamente durante el proceso. Se aplicó regularización L2 con un valor de 10^{-4} para reducir el riesgo de sobreajuste, y se utilizó la función de pérdida *BCEWithLogitsLoss*, adecuada para tareas de clasificación binaria. Además, el parámetro *pos_weight*, que determina la penalización durante el entrenamiento para muestras desbalanceadas, se fijó en 1.74. Como técnica de preprocesamiento, se empleó la transformada wavelet *sym5* para facilitar la extracción de características multiescales antes de su ingreso en los modelos, siendo la utilizada en trabajos anteriores (Queupumil Faundez, 2023; López Carballal, 2024). Para la división del conjunto de datos, se ha optado por utilizar el 80% de la muestra para entrenamiento, 10% para validación y 10% para test, quedando los conjuntos con un tamaño de 5804, 726 y 726 respectivamente.

5.1.1. Modelo de Shallue


En este apartado se va a evaluar el modelo de Shallue original con, los hiperparámetros comunes seleccionados, evaluando el impacto de las descomposiciones wavelet en las métricas.

5.1.1.1. Resultados del entrenamiento y test

- Series originales


En el caso de las series originales, el modelo alcanzó una pérdida en entrenamiento (*Train Loss*) de 0.7174 y una precisión de entrenamiento (*Train Accuracy*) del 83.43 %. En el conjunto de validación, la pérdida fue de 0.7785 y la precisión (*Validation Accuracy*) del 77.96 %. En cuanto a las métricas de evaluación adicionales, se obtuvo un *F1 Score* de 0.7808, una precisión (*Precision*) de 0.7835 y una sensibilidad (*Recall*) de 0.7796, lo que indica un rendimiento equilibrado entre falsos positivos y falsos negativos en la tarea de clasificación.

Figura 21: Métricas de entrenamiento y validación, modelo de Shallue con series originales.



En el conjunto de prueba, el modelo entrenado con las series originales alcanzó una precisión del 79.34 %, con un *F1 Score* de 0.7933, una precisión (*Precision*) de 0.7932 y una sensibilidad (*Recall*) de 0.7934. Según la matriz de confusión, el modelo clasificó correctamente 359 de los 433 eventos etiquetados como *FALSE POSITIVE*, mientras que identificó correctamente 217 de los 293 eventos *CONFIRMED*. Estos resultados reflejan un rendimiento sólido y equilibrado, manteniendo una buena capacidad de generalización en datos no vistos.


Figura 22: Matriz de confusión y métricas del conjunto de test, Shallue con series originales.



- Wavelets de niveles 1, 2, 3, 4

Al incorporar la transformada wavelet *sym5* como preprocesamiento, el modelo obtuvo una pérdida en entrenamiento (*Train Loss*) de 0.7222 y una precisión de entrenamiento del 82.77 %. En el conjunto de validación, la pérdida fue de 0.7819 y la precisión alcanzó el 77.27 %. En cuanto a las métricas adicionales, el *F1 Score* fue de 0.7712, con una precisión (*Precision*) de 0.7709 y una sensibilidad (*Recall*) de 0.7727. Estos resultados indican un rendimiento comparable al obtenido con las series originales, con un ligero descenso en las métricas de validación, pero con una estructura de resultados igualmente equilibrada.


Figura 23: Métricas de entrenamiento y validación, modelo de Shallue con descomposición wavelet.



En el conjunto de prueba, el modelo entrenado con transformadas wavelets obtuvo una precisión del 76.86 %, con un *F1 Score* de 0.7668, una precisión (*Precision*) de 0.7667 y una sensibilidad (*Recall*) de 0.7686. La matriz de confusión revela un comportamiento equilibrado: de los 433 eventos clasificados como *FALSE POSITIVE*, 361 fueron correctamente identificados, mientras que de los 293 eventos *CONFIRMED*, 197 fueron clasificados correctamente. Estos resultados indican un rendimiento ligeramente inferior al obtenido con las series originales,

aunque el modelo mantiene una capacidad razonable de generalización frente a datos no vistos.

Figura 24: Matriz de confusión y métricas del conjunto de test, Shallue con descomposición wavelet.



5.1.2. Modelo de Shallue 2D

En este apartado se va a evaluar el modelo de Shallue con convoluciones en dos dimensiones con los hiperparámetros comunes seleccionados, evaluando el impacto de las descomposiciones wavelet en las métricas.


5.1.2.1. Resultados del entrenamiento y test

- Series originales

Para el modelo convolucional 2D entrenado con las series originales, se obtuvo una pérdida en entrenamiento (*Train Loss*) de 0.7255 y una precisión del 82.37 %. En el conjunto de validación, la pérdida fue de 0.7978 y la precisión alcanzó el 74.52 %. Las métricas adicionales mostraron un *F1 Score* de 0.7413, una precisión (*Precision*) de 0.7420 y una sensibilidad (*Recall*) de 0.7452. Estos resultados indican un rendimiento ligeramente inferior al observado

con el modelo 1D, especialmente en las métricas de validación, aunque el modelo mantiene una capacidad razonable para distinguir entre las clases.


Figura 25: Métricas de entrenamiento y validación, modelo de Shallue2D con series originales.



En el conjunto de prueba, el modelo convolucional 2D alcanzó una precisión del 74.10 %, con un F1 Score de 0.7365, una precisión (Precision) de 0.7383 y una sensibilidad (Recall) de 0.7410. La matriz de confusión muestra que se clasificaron correctamente 362 de los 433 eventos etiquetados como FALSE POSITIVE, y 176 de los 293 eventos CONFIRMED. Aunque el rendimiento general es algo inferior al del modelo 1D, especialmente en la capacidad para

identificar correctamente eventos CONFIRMED, el modelo 2D sigue ofreciendo resultados razonablemente estables y consistentes.

Figura 26: Matriz de confusión y métricas del conjunto de test, Shallue2D con series originales.




- Wavelets de niveles 1, 2, 3, 4

Al aplicar la transformada wavelet *sym5* como preprocesamiento en el modelo convolucional 2D, se obtuvo una pérdida en entrenamiento (*Train Loss*) de 0.7189 y una precisión del 83.36 %. En el conjunto de validación, la pérdida fue de 0.7893, con una precisión del 75.76 %. Las métricas adicionales reflejan un *F1 Score* de 0.7563, una precisión (*Precision*) de 0.7557 y una sensibilidad (*Recall*) de 0.7576. Estos resultados indican una mejora general respecto al entrenamiento del modelo 2D sin wavelets, especialmente en las métricas de validación, lo

que sugiere que el preprocesamiento con wavelets contribuye a una mejor capacidad de generalización.


Figura 27: Métricas de entrenamiento y validación, modelo de Shallue2D con descomposición wavelet.



En el conjunto de prueba, el modelo convolucional 2D alcanzó una precisión del 78.51%, con un F1 Score de 0.7827, una precisión (Precision) de 0.7836 y una sensibilidad (Recall) de 0.7851. La matriz de confusión muestra que se clasificaron correctamente 371 de los 433

eventos etiquetados como FALSE POSITIVE, y 199 de los 293 eventos CONFIRMED. En este caso si se ve una mejora respecto al modelo de Shallue original con las descomposiciones wavelet y respecto al uso único de las series originales en el mismo modelo.

Figura 28: Matriz de confusión y métricas del conjunto de test, Shallue2D con descomposición wavelet.



5.1.3. Modelo 2D con skip-layers

En este apartado se va a evaluar el modelo Shallue con convoluciones en dos dimensiones al que se ha añadido skip layers + bottleneck, con los hiperparámetros comunes seleccionados, evaluando el impacto de las descomposiciones wavelet en las métricas 5


5.1.3.1. Resultados del entrenamiento y test

- Series originales

Para el modelo convolucional 2D con skip layers + bottleneck entrenado con las series originales, se obtuvo una pérdida en entrenamiento (Train Loss) de 0.6607 y una precisión del 92.11 %. En el conjunto de validación, la pérdida fue de 0.7405 y la precisión alcanzó el 83.33 %. Las métricas adicionales mostraron un F1 Score de 0.8340, una precisión (Precision) de


0.8354 y una sensibilidad (Recall) de 0.833. Estos resultados indican un rendimiento muy superior a lo observado en los modelos anteriores.

Figura 29: Métricas de entrenamiento y validación, modelo de skip-layers con series originales.



En el conjunto de prueba, el modelo convolucional 2D con skip layers + bottleneck alcanzó una precisión del 84,57 %, con un F1 Score de 0,8456, una precisión (Precision) de 0,8456 y una sensibilidad (Recall) de 0,8457. La matriz de confusión muestra que se clasificaron correctamente 378 de los 433 eventos etiquetados como FALSE POSITIVE, y 236 de los 293 eventos CONFIRMED. El rendimiento general es muy superior al del modelo 2D, especialmente en la capacidad para identificar correctamente eventos CONFIRMED.


Figura 30: Matriz de confusión y métricas del conjunto de test, modelo skip-layers con series originales.



- Wavelets de niveles 1, 2, 3, 4


Al aplicar la transformada wavelet sym5 como preprocesamiento en el modelo convolucional 2D con skip layers + bottleneck, se obtuvo una pérdida en entrenamiento (Train Loss) de 0.6543 y una precisión del 93.11 %. En el conjunto de validación, la pérdida fue de 0.7414, con una precisión del 83.47%. Las métricas adicionales reflejan un F1 Score de 0.8352, una precisión (Precision) de 0.8360 y una sensibilidad (Recall) de 0.8347. Estos resultados indican una mejora general respecto al entrenamiento del modelo 2D con skip layers + bottleneck sin wavelets, lo que sugiere que el preprocesamiento con wavelets contribuye a una mejor capacidad de generalización.

Figura 31: Métricas de entrenamiento y validación, modelo de skip-layers con descomposición wavelet.



En el conjunto de prueba, el modelo convolucional 2D con skip layers + bottleneck con wavelets alcanzó una precisión del 86.09 %, con un F1 Score de 0,8608, una precisión (Precision) de 0,8607 y una sensibilidad (Recall) de 0,8609. La matriz de confusión muestra que se clasificaron correctamente 384 de los 433 eventos etiquetados como FALSE POSITIVE, y 241 de los 293 eventos CONFIRMED. El rendimiento general ligeramente superior al modelo sin wavelets, lo que indica que estos modelos más avanzados sí son capaces de obtener información de las transformadas wavelets y mejorar su rendimiento.

Figura 32: Matriz de confusión y métricas del conjunto de test, modelo skip-layers con descomposición wavelet.



5.1.4. Resumen de los modelos

La Tabla 1 recopila los resultados obtenidos con la métrica F1-score en los conjuntos de prueba para cada una de las arquitecturas implementadas. Se observa que, en el caso de la arquitectura original de Shallue, la incorporación de la descomposición wavelet no resulta beneficiosa, ya que el rendimiento disminuye respecto a las series originales. En contraste, las

arquitecturas adaptadas con convoluciones en dos dimensiones muestran una mejora significativa al emplear wavelets, lo que confirma la utilidad de esta representación en un contexto multicanal.

Finalmente, el modelo propuesto en este trabajo, basado en convoluciones 2D con capas de salto (skip layers), alcanza el mejor desempeño global, superando tanto a la arquitectura original como a la versión 2D sin conexiones residuales. Esto pone de manifiesto que la combinación de representaciones multiescala mediante wavelets y el uso de técnicas modernas de entrenamiento profundo proporciona una mejora sustancial en la detección de tránsitos.

Tabla 1: Resumen del rendimiento de los diferentes modelos.

Arquitectura	F1-score series originales	F1-score wavelets
Shallue original	0.7933	0.7668
Shallue 2D	0.7365	0.7827
Modelo 2D + skip layers	0.8456	0.8608


5.2. EVALUACIÓN DEL MEJOR MODELO CON LAS FAMILIAS WAVELETS

Una vez evaluado el mejor modelo implementado, la selección de la familia de wavelet apropiada es un punto clave en la extracción de características.

5.2.1. Symlet

Para el caso de la familia symlet, con la que se han hecho las pruebas de modelos, se puede observar como en los datos de entrada, representados en la Figura 33, para cada nivel de wavelet se observan diferente contenido de información extraído.

Figura 33: Datos de entrada con wavelets tipo symlet 5.



Después de haber evaluado con el conjunto de prueba (Figura 32), obteniendo un 86% de precisión, se procede a clasificar los objetos que en el *dataset* estaban catalogados como “*Candidates*”. Esta tarea es útil porque permite estimar la probabilidad de que dichos candidatos correspondan a exoplanetas reales o a falsos positivos, facilitando su priorización para futuros análisis y observaciones de seguimiento.

Se puede observar como la proporción de confirmados y falsos positivos se mantiene siguiendo la tendencia del dataset de la fracción de 1.47, además que la distribución de probabilidad de pertenencia a clase (Figura 29) muestra como en la mayoría de los casos no se encuentran muchas dudas en la predicción.

Figura 34: Clasificación de candidatos con symlet 5.






Figura 35: Distribuciones de probabilidad de predicción con symlet 5.



5.2.2. Daubechies


En los datos de entrada preprocesados con la familia daubechies, muestran una reducción significativa del ruido, tanto en la vista global como en la local, haciendo mucho más evidente la zona del tránsito.

Figura 36: Datos de entrada con wavelets tipo daubechies 5.




Respecto a las métricas de entrenamiento y validación se ven muy similares a las representadas por el entrenamiento con symlet, obteniendo valores cercanos al 0.85 en todas las métricas adicionales.

Figura 37: Métricas de entrenamiento y validación con daubechies 5.



En el caso de los datos de prueba, se observa una reducción en el acierto respecto a la familia symlet, en este caso no llegando al 85% de precisión, pero obteniendo aun así mejores resultados que los modelos básicos analizados.

Figura 38: Matriz de confusión y métricas de test con daubechies 5.



En el caso de la predicción de los candidatos, también se observa una variación en los resultados habiendo predicho menos confirmados y desplazado la proporción del dataset a 1.56, sobreestimando falsos positivos como se puede observar en la matriz de confusión (Figura 38). Además, se observa en las probabilidades (Figura 40) como se desplazan las probabilidades de los confirmados '1' hacia la izquierda indicando que el modelo no está siendo tan preciso en su discriminación.

Figura 39: Clasificación de candidatos con daubechies 5.






Figura 40: Distribuciones de probabilidad de predicción con daubechies 5.



5.2.3. Meyer


En los datos de entrada preprocesados con la familia meyer, muestran una reducción significativa del ruido, al igual que con la familia daubechies, tanto en la vista global como en la local, haciendo mucho más evidente la zona del tránsito, resaltando unas ondulaciones alrededor del tránsito durante la vista global en el nivel 4 de descomposición.

Figura 41: Datos de entrada con wavelets tipo meyer.




Respecto a las métricas de entrenamiento y validación se ven similares a las representadas por el entrenamiento con las familias anteriores, pero ligeramente superiores, obteniendo valores cercanos al 0.90 en todas las métricas adicionales.

Figura 42: Métricas de entrenamiento y validación con meyer.



Respecto al conjunto de datos de prueba se observa un rendimiento superior que los anteriores modelos obteniendo valores de 87.2% de precisión. Además de observar que se encuentran bastante balanceados los errores de comisión y omisión, habiéndose clasificado mal solo 45 falsos positivos y 40 confirmados.

Figura 43: Matriz de confusión y métricas de test con meyer.



Respecto a la clasificación de los candidatos con la familia Meyer, se observa una reducción en el número de objetos identificados como confirmados en comparación con otras familias. Al mismo tiempo, el reparto entre confirmados y rechazados resulta más equilibrado, lo que refleja un comportamiento diferenciado de esta wavelet en la separación de las clases.

Figura 44: Clasificación de candidatos con meyer.






Figura 45: Distribuciones de probabilidad de predicción con meyer.



5.2.4. Haar


En los datos de entrada preprocesados con la familia haar, muestran una reducción significativa del ruido, en este caso al ser un tipo de wavelet discreta. Tanto en la vista global como en la local se puede ver como no hay un salto continuo entre los valores, producido por la naturaleza del tipo de wavelet.

Figura 46: Datos de entrada con wavelets tipo Haar.




En las métricas de entrenamiento y validación no se encuentran variaciones considerables respecto al resto de familias wavelet. Los valores de perdida (Loss), precisión se ven muy homogéneos al del resto, mientras que en el F1-score y en el recall si se observa que no se aplanan del todo al final de las iteraciones.

Figura 47: Métricas de entrenamiento y validación con haar.



Respecto al conjunto de prueba, si se observa que con esta familia la red no es capaz de superar al resto de opciones, no superando el 83% en las métricas en general, con una ligera sobreestimación de los confirmados.

Figura 48: Matriz de confusión y métricas de test con haar.



Respecto a la clasificación de los candidatos, se observa cómo ha determinado aproximadamente los mismos números de confirmados y falsos positivos. Aunque sí que es más evidente que en la distribución de probabilidades de clase (Figura 50) se observan más variaciones de objetos clasificados con mayor incertidumbre.

Figura 49: Clasificación de candidatos con haar.





Figura 50: Distribuciones de probabilidad de predicción con haar.



5.2.5. Resumen de los resultados en función de las wavelets

La Tabla 2 presenta los resultados obtenidos al emplear la arquitectura con skip layers junto con distintas familias de wavelets. Se aprecia que la familia Haar ofrece el rendimiento más bajo en términos de F1-score, aunque aun así supera a los resultados alcanzados con otras arquitecturas más básicas. Por otro lado, se observa una tendencia general a la mejora del rendimiento conforme aumenta la complejidad de la wavelet, siempre que se conserve la simetría en la base utilizada. En este sentido, la familia Meyer obtiene el mejor desempeño global, alcanzando un F1-score de 0.8718 y proporcionando la clasificación más favorable de los candidatos.

Tabla 2: Resumen del rendimiento de las familias wavelets junto a la clasificación de los candidatos.

Familia Wavelet	F1-score	Candidatos confirmados	Candidatos rechazados
Symlet	0.8608	765	1126
Daubechies	0.8460	736	1155
Meyer	0.8718	700	1191
Haar	0.8372	739	1152

5.2.6. Series de tránsitos a diferentes probabilidades

Tras haber analizado los resultados obtenidos tanto con las diferentes arquitecturas, así como del rendimiento obtenido por el uso de diferentes familias wavelet, se han guardado en una tabla formato csv los tránsitos categorizados como candidatos, donde se especificaban su nombre de Kepler, su clasificación categórica y su probabilidad.

Se ha querido analizar si una vez la red neuronal hace su veredicto en la clasificación, si es posible observar a simple vista diferencias entre las series de los tránsitos analizados, para ello se han filtrado los resultados en tres grupos:

- Alta probabilidad: Son los tránsitos del dataset con una probabilidad mayor a 0.99.
- Baja probabilidad: Son los tránsitos del dataset con una probabilidad inferior a 0.01.

- Intermedia probabilidad: Son los tránsitos del dataset con una probabilidad comprendida entre 0.4 y 0.6.

Como se ha podido observar no se tienen en cuenta todos los umbrales de probabilidad, esto es debido a que se ha querido obtener las series de los tránsitos más representativos para analizar su dinámica.

A continuación, se pueden observar un ejemplo de cada uno de estos grupos, en su vista global (Figura 51) y en su vista local (Figura 52). Se puede ver como a simple vista se ven diferencias entre los ejemplos, observando como el candidato con alta probabilidad, tanto en la vista global como local se ve una depresión en la serie más profunda. En el ejemplo de baja probabilidad se observa como en la vista global no se aprecia un ocultamiento muy marcado, mientras que en la vista local se hace un poco más evidente, pero en general son series que se observan muchas fluctuaciones. Finalmente, en la serie de probabilidad intermedia se observa en la vista global como la serie en general tiene menos ruido, pero luego el ocultamiento no es tan profundo como en la de alta probabilidad, mientras que si observamos la vista local se ve como la serie parece una combinación entre la vista local de alta y baja probabilidad viendo el tránsito de forma clara pero rodeado de bastante ruido.

Figura 51: Ejemplo vista global de tres candidatos con diferentes probabilidades.





Figura 52: Ejemplo de vista local de tres candidatos con diferentes probabilidades.



6. DISCUSIÓN

Los resultados obtenidos muestran claramente que la incorporación de técnicas avanzadas de aprendizaje profundo, como son las redes convolucionales 2D con módulos residuales (Skip Layers) y el uso de transformaciones wavelet, mejora significativamente el rendimiento en la detección automática de tránsitos exoplanetarios frente al modelo original de Shallue & Vanderburg (2018). La comparación entre las arquitecturas indica que mientras el modelo base de Shallue, aunque efectivo, presenta ciertas limitaciones en la generalización de eventos ambiguos, las modificaciones introducidas proporcionan un aumento sustancial en precisión, recall y F1-score.

Un aspecto clave en este trabajo ha sido el diseño de un flujo de procesamiento bien estructurado, desde la descarga de los datos hasta el preprocesamiento y su incorporación a las arquitecturas propuestas. La correcta estandarización en estas fases iniciales es fundamental, ya que asegura que la información contenida en las curvas de luz se aproveche al máximo y que el modelo trabaje con datos homogéneos y comparables. De hecho, uno de los principales retos en problemas astrofísicos radica en la calidad y preparación de los datos, donde pequeñas diferencias en el filtrado o en la normalización pueden derivar en interpretaciones muy distintas. La implementación modular desarrollada en este trabajo permite llevar a cabo experimentos de manera sencilla, evitando duplicidad de código y facilitando la inclusión de nuevas pruebas, como el uso de diferentes familias wavelet o la

incorporación de variantes arquitectónicas. Esta flexibilidad representa una ventaja significativa para extender el estudio a futuras campañas de observación.

En relación con la comparación de arquitecturas (Tabla 1), los resultados ponen de manifiesto que la descomposición wavelet no resulta especialmente beneficiosa en el modelo original de Shallue, lo cual sugiere que dicho diseño no estaba optimizado para explotar información multiescalar. Sin embargo, al incorporar convoluciones 2D, se observa un cambio radical: el modelo es capaz de integrar de manera mucho más efectiva las representaciones de detalle y aproximación que proveen las wavelets. Este comportamiento indica que existe una sinergia entre la naturaleza jerárquica de las CNN 2D y la descomposición multiescalar de wavelets, lo que se traduce en una representación más rica y discriminativa de las curvas de luz. En particular, el modelo desarrollado en este trabajo con convoluciones 2D y Skip Layers ha alcanzado los mejores resultados, lo que confirma que la arquitectura propuesta es más adecuada para este tipo de datos que el enfoque base.

El análisis del impacto de las diferentes familias wavelet (Tabla 2) refuerza esta conclusión. La elección de la wavelet madre afecta directamente a la manera en que se descompone la señal, y por tanto a las características extraídas por la red. La wavelet Haar, aunque sencilla y computacionalmente eficiente, ofrece una descomposición demasiado brusca, lo que conduce a resultados aceptables pero inferiores a los obtenidos con familias más complejas. Las wavelets Symlet y Meyer, en cambio, logran un mejor balance entre suavidad y localización, proporcionando representaciones más precisas de los tránsitos y minimizando la pérdida de información contextual. La superioridad de Meyer, en particular, se debe a su capacidad de capturar estructuras suaves y oscilatorias propias de las curvas de luz estelares, lo que la convierte en una candidata muy adecuada para este tipo de aplicaciones.

La incorporación de convoluciones 2D ha permitido explotar de forma más completa las correlaciones entre los distintos niveles de detalle generados por la transformada wavelet. Esta capacidad es clave para diferenciar entre verdaderos tránsitos planetarios y falsos positivos producidos por fenómenos estelares, ruido instrumental o variabilidad intrínseca. Por su parte, los Skip Layers han contribuido a mitigar el problema del desvanecimiento del gradiente y han permitido entrenar arquitecturas más profundas, aumentando la capacidad predictiva y favoreciendo una mayor estabilidad en el entrenamiento. De hecho, la

preservación de información a lo largo de las capas no solo mejora las métricas de clasificación, sino que también aporta mayor robustez frente a señales atípicas.

El papel de las capas completamente conectadas con un cuello de botella también merece ser destacado. Esta estrategia ha resultado especialmente efectiva para reducir la dimensionalidad y concentrarse en las características más discriminativas. De este modo, se limita el riesgo de sobreajuste y se obtiene un modelo con mayor capacidad de generalización, algo fundamental en contextos donde el ruido y la variabilidad son inherentes a los datos, como ocurre en la fotometría estelar.

Es importante señalar que la mejora observada en las métricas no tiene la misma repercusión en todos los casos. Un aumento de la precisión implica que una mayor proporción de los candidatos identificados como exoplanetas son verdaderos positivos, lo que reduce el número de falsos positivos y aumenta la fiabilidad de los descubrimientos. Por otro lado, una mejora en el índice de recuperación refleja una mayor capacidad del modelo para detectar la mayoría de los tránsitos existentes, lo que evita que se pasen por alto planetas reales. En este contexto, la precisión es fundamental para minimizar las falsas alarmas que requieren verificación adicional, mientras que el recall es clave para no perder posibles descubrimientos. La métrica F1-score equilibra ambos aspectos, ofreciendo una visión global del rendimiento. Así, el incremento de estas métricas no solo supone un avance técnico, sino que también tiene un impacto directo en la eficiencia y la fiabilidad de la búsqueda de nuevos exoplanetas.

Un análisis complementario se ha realizado mediante la visualización de ejemplos de candidatos (Figuras 51 y 52). En estas ilustraciones se observa cómo las curvas de alta probabilidad presentan depresiones profundas y claras, mientras que las de baja probabilidad se caracterizan por un mayor nivel de fluctuaciones y ausencia de patrones evidentes a simple vista. Los candidatos de probabilidad intermedia muestran un escenario mixto, con tránsitos visibles pero rodeados de ruido significativo. El hecho de que estas diferencias se aprecien incluso en una inspección visual es una señal positiva, ya que sugiere que el modelo es capaz de aprender patrones consistentes que también son reconocibles para un observador humano. No obstante, debe subrayarse que muchos candidatos no son tan claros como los ejemplos mostrados: en la práctica, gran parte de las series presentan señales débiles, tránsitos poco marcados o ruido que dificulta la interpretación visual, como se puede observar en los anexos A y B. Precisamente en estos casos radica la verdadera fortaleza de los modelos

automáticos, que son capaces de detectar y generalizar patrones más allá de lo que se aprecia a simple vista.

Este doble enfoque, validación mediante métricas cuantitativas y análisis cualitativo de candidatos, permite concluir que los modelos desarrollados no solo alcanzan un buen rendimiento en términos estadísticos, sino que también producen salidas coherentes con lo que cabría esperar físicamente en curvas de luz con tránsitos planetarios. Este aspecto es relevante de cara a su aplicabilidad práctica en la búsqueda de exoplanetas, donde la clasificación automática debe combinar precisión, interpretabilidad y consistencia.

A pesar de estos avances, aún persisten desafíos importantes. En particular, se ha observado que la predicción sobre candidatos no confirmados muestra cierta incertidumbre reflejada en distribuciones de probabilidad intermedias, indicando que aún queda espacio para mejorar la discriminación entre tránsitos genuinos y falsos positivos, especialmente en casos de señales débiles o ruidosas. Una posible línea futura consiste en explorar técnicas de aumento de datos diseñadas específicamente para curvas de luz, como la inyección artificial de tránsitos simulados en curvas reales o la introducción de variabilidad estelar sintética, como ofrece también *NASA Exoplanet Archive*. Asimismo, sería interesante profundizar en el uso de técnicas de regularización avanzadas, como *dropout* variacional o el uso de modelos bayesianos, que podrían aportar estimaciones de incertidumbre más fiables y, por tanto, mejorar la interpretación científica de los resultados, así como realizar una búsqueda automática de hiperparámetros para extraer todo el rendimiento posible de los modelos.

En resumen, los resultados confirman que la combinación de wavelets, convoluciones 2D y *skip layers* constituye una estrategia prometedora para el análisis de curvas de luz y la detección de tránsitos. Al mismo tiempo, cabe destacar la importancia de un preprocesamiento adecuado, de una implementación flexible y modular, y de un análisis complementario tanto cuantitativo como cualitativo. Estas conclusiones abren la puerta a desarrollos futuros que podrían aumentar aún más la fiabilidad de los modelos y contribuir de manera significativa a la detección y caracterización de nuevos exoplanetas.

7. CONCLUSIONES

Este trabajo ha demostrado de manera clara la eficacia de combinar transformaciones wavelet con arquitecturas avanzadas de redes neuronales convolucionales en la detección de tránsitos exoplanetarios utilizando datos de la misión *Kepler*. La arquitectura propuesta, basada en convoluciones 2D, el uso de *Skip Layers* y la introducción de un cuello de botella en las capas completamente conectadas, ha superado de forma consistente a los modelos de referencia tanto en precisión como en recall y F1-score. Estos resultados reflejan que las modificaciones introducidas permiten extraer de manera más robusta y discriminativa las características de las curvas de luz, aumentando la capacidad de los modelos para identificar tránsitos incluso en condiciones de ruido o variabilidad estelar.

La evaluación sistemática de distintas familias wavelet ha puesto de manifiesto la importancia crítica de la elección de la wavelet madre. Mientras que opciones sencillas como la wavelet Haar ofrecen un rendimiento aceptable, las wavelets Meyer y Symlet han mostrado un comportamiento significativamente superior al capturar mejor las estructuras suaves y oscilatorias de las curvas de luz. Esto confirma que la descomposición multiescalar no solo aporta información adicional al modelo, sino que también puede optimizarse mediante la selección adecuada de la wavelet, lo que abre la puerta a futuros estudios en los que se explore un espacio más amplio de parámetros wavelet para maximizar el rendimiento del sistema.

Además, el análisis de candidatos visuales ha permitido validar cualitativamente los resultados. En los ejemplos de alta probabilidad se observan depresiones claras y profundas, en contraste con los de baja probabilidad, dominados por fluctuaciones y ruido. Los casos de probabilidad intermedia muestran un escenario mixto, donde los tránsitos son visibles pero rodeados de ruido. Que estas diferencias se aprecien a simple vista constituye una buena señal, ya que indica que el modelo está captando patrones consistentes. No obstante, también se ha puesto de relieve que no todas las series presentan señales tan evidentes, lo que resalta la importancia de los modelos automáticos para detectar patrones sutiles que resultan difíciles de identificar a simple vista.

En este sentido, los resultados no solo confirman la validez del enfoque adoptado, sino que también refuerzan la utilidad práctica de estas técnicas para mejorar los procesos de

clasificación automática en la búsqueda de exoplanetas. La combinación de métricas cuantitativas sólidas y análisis cualitativo de candidatos constituye un marco integral que permite confiar tanto en la eficacia estadística como en la coherencia física de las detecciones.

En definitiva, este trabajo aporta evidencias sólidas de que las técnicas modernas de procesamiento de señales y *deep learning* constituyen herramientas altamente efectivas y prometedoras para avanzar en la detección y caracterización automática de exoplanetas. La integración de transformaciones wavelet con arquitecturas convolucionales avanzadas ofrece un marco flexible y escalable que puede adaptarse a futuras misiones espaciales, como TESS o PLATO. Futuros trabajos podrán profundizar en la optimización de parámetros wavelet, en la incorporación de técnicas de aumento de datos adaptadas a curvas de luz, y en el uso de enfoques probabilísticos que aporten estimaciones de incertidumbre más robustas. Con ello, se abre el camino hacia sistemas más sofisticados y eficientes, capaces de incrementar la fiabilidad en la detección de exoplanetas y, al mismo tiempo, mejorar la caracterización de sus propiedades, aportando así una contribución significativa al avance de la astrofísica moderna.

Referencias bibliográficas

- Ananyeva, V. I., Ivanova, A. E., Shashkova, I. A., ... & Zakhozhay, V. A. (2022). The mass and orbital-period distributions of exoplanets accounting for the observational selection of the method for measuring radial velocities: A dominant (averaged) structure of planetary systems. *Astronomy Reports*, 66(9), 886–917. <https://doi.org/10.1134/S106377292210002X>
- Beichman, C., Benneke, B., Knutson, H., Smith, R., Lagage, P., Dressing, C., Latham, D., Lunine, J., Birkmann, S., Ferruit, P., Giardino, G., Kempton, E., Carey, S., Krick, J., Deroo, P. D., Mandell, A., Ressler, M. E., Shporer, A., Swain, M., ... Sing, D. (2014). Observations of transiting exoplanets with the James Webb Space Telescope (JWST). *Publications of the Astronomical Society of the Pacific*, 126(946), 1134–1173.
- Choudhry, N., Abawajy, J., Huda, S., & Razzak, I. (2023). A comprehensive survey of machine learning methods for surveillance videos anomaly detection. *IEEE Access*. <https://ieeexplore.ieee.org/document/10271300>
- Christiansen, J. L., McElroy, D. L., Harbut, M., Ciardi, D. R., Crane, M., Good, J., ... & Beichman, C. (2025). The NASA Exoplanet Archive and Exoplanet Follow-up Observing Program: Data, Tools, and Usage. *arXiv preprint arXiv:2506.03299*.
- Civitarese, D. S., Szwarcman, D., Zadrozny, B., & Watson, C. (2021). Extreme precipitation seasonal forecast using a transformer neural network. *arXiv preprint arXiv:2107.06846*.
- Del Ser, D., & Fors, O. (2020). TFAW survey – I. Wavelet-based denoising of K2 light curves: Discovery and validation of two new Earth-sized planets in K2 campaign 1. *Monthly Notices of the Royal Astronomical Society*, 498(2), 2778–2797.
- Donnelly, S., & Dutta, A. (2024). Kepler light curve classification using deep learning and Markov transition field (Student abstract). In *Proceedings of the AAAI Conference on Artificial Intelligence*. <https://ojs.aaai.org/index.php/AAAI/article/download/30435/32519>
- Gaudi, B. S., Meyer, M., & Christiansen, J. (2021). The demographics of exoplanets. In IOP Publishing eBooks. <https://doi.org/10.1088/2514-3433/abfa8fch2>

- Giacomazzi, E., Haag, F., & Hopf, K. (2023, June). Short-term electricity load forecasting using the temporal fusion transformer: Effect of grid hierarchies and data sources. In *Proceedings of the 14th ACM international conference on future energy systems* (pp. 353-360).
- Gilliland, R. L., Jenkins, J. M., Borucki, W. J., Bryson, S. T., Caldwell, D. A., Clarke, B. D., Dotson, J. L., Haas, M. R., Hall, J., Klaus, T., Koch, D., McCauliff, S., Quintana, E. V., Twicken, J. D., & Van Cleve, J. E. (2010). Initial characteristics of Kepler short cadence data. *The Astrophysical Journal Letters*, 713(2), L160–L163.
- Grziwa, S., & Pätzold, M. (2016). Wavelet-based filter methods to detect small transiting planets in stellar light curves. *arXiv preprint arXiv:1607.08417*.
- Haywood, R. D., Collier Cameron, A., Queloz, D., Barros, S. C. C., Deleuil, M., Fares, R., ... & Unruh, Y. C. (2014). Planets and stellar activity: hide and seek in the CoRoT-7 system. *Monthly notices of the royal astronomical society*, 443(3), 2517-2531.
- Ketkar, N., & Moolayil, J. (2021). Introduction to PyTorch. In *Deep Learning with Python: Learn best practices of deep learning models with PyTorch* (pp. 27–91).
- Koch, D. G., Borucki, W. J., Basri, G., Batalha, N. M., Brown, T. M., Caldwell, D., Christensen-Dalsgaard, J., Cochran, W. D., DeVore, E., & Dunham, E. W. (2010). Kepler mission design, realized photometric performance, and early science. *The Astrophysical Journal Letters*, 713(2), L79.
- Kovács, G., Zucker, S., & Mazeh, T. (2002). A box-fitting algorithm in the search for periodic transits. *Astronomy & Astrophysics*, 391(1), 369-377.
- Liao, H., Ren, G., Chen, X., Li, Y., & Li, G. (2024). Identifying exoplanet candidates using WaveCeptionNet. *The Astronomical Journal*, 167(4), 180.
- Lightkurve Collaboration, Cardoso, J. V. d. M., Hedges, C., Gully-Santiago, M., Saunders, N., Cody, A. M., Barclay, T., Hall, O., Sagar, S., Turtelboom, E., Zhang, J., Tzanidakis, A., Mighell, K., Coughlin, J., Bell, K., Berta-Thompson, Z., Williams, P., Dotson, J., & Barentsen, G. (2018). Lightkurve: Kepler and TESS time series analysis in Python [Software]. *Astrophysics Source Code Library*. <https://ascl.net/1812.013>
- Lim, B., Arik, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International journal of forecasting*, 37(4), 1748-1764.


- López Carballal, J. (2024). Identificando exoplanetas por tránsito con wavelets y redes convolucionales. [Trabajo de Fin de Máster, Universidad Internacional de La Rioja].
- Masciadri, E., & Raga, A. (2004). Exoplanet recognition using a wavelet analysis technique. *The Astrophysical Journal*, 611(2), L137.
- Melton, E. J., Feigelson, E. D., Montalto, M., Caceres, G. A., Rosenswie, A. W., & Abelson, C. S. (2024). DIAmante TESS autoregressive planet search (DTARPS). I. Analysis of 0.9 million light curves. *The Astronomical Journal*, 167(5), 202.
- Melton, E. J., Feigelson, E. D., Montalto, M., Caceres, G. A., Rosenswie, A. W., & Abelson, C. S. (2024b). DIAmante TESS autoregressive planet search (DTARPS). II. Hundreds of new TESS candidate exoplanets. *The Astronomical Journal*, 167(5), 203.
- Morvan, M., Nikolaou, N., Tsiaras, A., & Waldmann, I. P. (2020). Detrending Exoplanetary Transit Light Curves with Long Short-term Memory Networks. *The Astronomical Journal*, 159(3), 109.
- NASA Exoplanet Archive. (s. f.). *NASA Exoplanet Archive*. NASA. Recuperado el 15 de agosto de 2025 de <https://exoplanetarchive.ipac.caltech.edu/>
- NASA JPL Education. (s. f.). *Explorando exoplanetas con Kepler*. NASA Jet Propulsion Laboratory. Recuperado el 15 de agosto de 2025 de <https://www.jpl.nasa.gov/edu/resources/lesson-plan/exploring-exoplanets-with-kepler/>
- NASA Science. (s. f.). *Kepler / K2*. NASA. Recuperado el 15 de agosto de 2025 de <https://science.nasa.gov/mission/kepler/>
- Popinchalk, M. (2024). *How many planets are in the universe?* Live Science. Recuperado el 7 de septiembre de 2025 de <https://www.livescience.com/space/how-many-planets-are-in-the-universe>
- Prithivraj, G., & Kumari, A. (2023). Identification and classification of exoplanets using machine learning techniques. *arXiv preprint arXiv:2305.09596*.
- Queupumil Faundez, E. (2023). Clasificación de curvas de luz Kepler mediante el análisis de su descomposición wavelet con Redes Neuronales Convolucionales. [Trabajo de Fin de Máster, Universidad Internacional de La Rioja].

- Rajpaul, V., Aigrain, S., Osborne, M. A., Reece, S., & Roberts, S. (2015). A Gaussian process framework for modelling stellar activity signals in radial velocity data. *Monthly Notices of the Royal Astronomical Society*, 452(3), 2269-2291.
- Rauer, H., Catala, C., Aerts, C., Appourchaux, T., Benz, W., Brandeker, A., Christensen-Dalsgaard, J., Deleuil, M., Gizon, L., Goupil, M., Güdel, M., Janot-Pacheco, E., Mas-Hesse, M., Pagano, I., Piotto, G., Pollacco, D., Santos, C., Smith, A., Suárez, J., ... Zwintz, K. (2014). The PLATO 2.0 mission. *Experimental Astronomy*, 38(1-2), 249-330.
- Rhif, M., Ben Abbes, A., Farah, I. R., Martínez, B., & Sang, Y. (2019). Wavelet transform application for/in non-stationary time-series analysis: A review. *Applied Sciences*, 9(7), 1345.
- Rowe, J. F., Bryson, S. T., Marcy, G. W., Lissauer, J. J., Jontof-Hutter, D., Mullally, F., Gilliland, R. L., Isaacson, H., Ford, E., Howell, S. B., Borucki, W. J., Haas, M., Huber, D., Steffen, J. H., Thompson, S. E., Quintana, E., Barclay, T., Still, M., Fortney, J., ... Geary, J. (2014). Validation of Kepler's multiple planet candidates. III. Light curve analysis and announcement of hundreds of new multi-planet systems. *The Astrophysical Journal*, 784(1), 45.
- Shallue, C. J., & Vanderburg, A. (2018). Identifying exoplanets with deep learning: A five-planet resonant chain around Kepler-80 and an eighth planet around Kepler-90. *The Astronomical Journal*, 155(2), 94.
- Simon, A. E., Szabo, G. M., Kiss, L. L., Fortier, A., & Benz, W. (2015). CHEOPS performance for exomoons: The detectability of exomoons by using optimal decision algorithm. *Publications of the Astronomical Society of the Pacific*, 127(956), 1084-1095.
- Targ, S., Almeida, D., & Lyman, K. (2016). Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*.
- Tinetti, G., Drossart, P., Eccleston, P., Hartogh, P., Heske, A., Leconte, J., Micela, G., Ollivier, M., Pilbratt, G., Puig, L., Turrini, D., Vandenbussche, B., Wolkenberg, P., Beaulieu, J., Buchave, L. A., Ferus, M., Griffin, M., Guedel, M., Justtanont, K., ... Zwart, F. (2018). A chemical survey of exoplanets with ARIEL. *Experimental Astronomy*, 46(1), 135-209.
- Tsai, S., Innes, H., Wogan, N. F., & Schwieterman, E. W. (2024). Biogenic sulfur gases as biosignatures on temperate sub-Neptune waterworlds. *The Astrophysical Journal Letters*, 966(2), L24.

Wright, J., & Gaudi, B. (2012). Exoplanet detection methods. *arXiv preprint arXiv:1210.2471*.

Anexo A. Candidatos de alta probabilidad

Candidatos con alta probabilidad de ser exoplaneta



Anexo B. Candidatos de baja probabilidad

Candidatos con baja probabilidad de ser exoplaneta

