

Clasificación de ondas gravitacionales de supernovas usando redes neuronales convolucionales

Aldo A. Álvarez¹, Javier M. Antelis²,
Claudia Moreno González¹

¹ Universidad de Guadalajara,
Departamento de Física,
México

² Tecnológico de Monterrey,
Escuela de Ingeniería y Ciencias,
México

aldoa.alvarez@alumnos.udg.mx,
claudia.mgonzalez@academicos.udg.mx,
mauricio.antelis@tec.mx

Resumen. Las detecciones de Ondas Gravitacionales (OG) brindan información crucial para el estudio del comportamiento de diferentes fenómenos en el Universo. Hasta la fecha se han registrado más de cien detecciones de OG, pero todas ellas vienen de sistemas binarios de Agujeros Negros y Estrellas de Neutrones. Uno de los retos actuales en investigación de OG es encontrar señales provenientes de explosiones de colapso de núcleo de Supernovas (CCSNe). En este proyecto de investigación, se construye un clasificador de señales de OG usando Redes Neuronales Convolucionales. Se entrena el algoritmo con simulaciones de ondas generadas de forma computacional a partir de modelos 3D de eventos de CCSNe. El modelo final fue puesto a prueba para medir su nivel de precisión al clasificar nuevos datos aleatorios de señales de OG de CCSNe. Los resultados fueron satisfactorios para señales producidas por fuentes localizadas entre 0.10 y 0.58 Kpc de distancia del punto de detección.

Palabras clave: Redes neuronales convolucionales, deep learning, ondas gravitacionales.

Classification of Gravitational Wave Signals from Supernovae Using Convolutional Neural Networks

Abstract. Gravitational Wave (GW) detections provide crucial information for studying the behavior of different phenomena in the Universe. To this date, more than a hundred GW detections have been recorded, but all of them come from binary systems of Black Holes and Neutron Stars. One of the current challenges in GW research is to find signals coming from core-collapse Supernova explosions (CCSNe). In this research project, we built a GW signal classifier using Convolutional Neural Networks. We trained the algorithm with computationally

generated wave simulations from 3D models of CCSNe events. The final model was tested to measure its level of accuracy in classifying new random data of GW signals from CCSNe. The results were satisfactory for signals produced by sources located between 0.10 and 0.58 Kpc away from the detection point.

Keywords: Convolutional neural networks, deep learning, gravitational waves.

1. Introducción

De acuerdo con la teoría de Relatividad General (RG), las Ondas Gravitacionales (OG) son consideradas como fluctuaciones en el espacio-tiempo que pueden ser causadas por eventos cosmológicos extremadamente energéticos. Las OG inicialmente fueron predichas por Albert Einstein como una consecuencia de su teoría de RG en 1916 [1], pero fue hasta el año 2015 que la existencia de este fenómeno fue comprobada por medio de detecciones oficiales de una de estas señales cósmicas.

Desde entonces, muchas otras detecciones han sido registradas, lo cual ha permitido a los investigadores de esta rama de la Física seguir recopilando información sobre el comportamiento de varios cuerpos celestes que conforman el Universo. Las OG son perturbaciones débiles, y son tan pequeñas que solo eventos extremadamente energéticos pueden producir ondas que puedan ser medidas desde la Tierra con suficiente certeza.

Las OG detectables vienen de cuatro fuentes principales: sistemas binarios de estrellas, estrellas de neutrones giratorias, casos de colapso gravitacional y ondas producidas durante el Big Bang [2]. Este proyecto de investigación se limitó al análisis de OG de eventos de colapso gravitacional, específicamente de explosiones de Supernovas con Colapso de Núcleo (CCSNe).

Una de las mayores fuentes de datos de detección de OG son los interferómetros de LIGO (Laser Interferometry Gravitational-waves Observatory) [2]. Por esta razón, los métodos que se implementan en este proyecto de investigación fueron ajustados para trabajar con los estándares de procesamiento y análisis de señales propuestos por LIGO. La detección de OG ha sido un gran éxito para la ciencia, pero este campo aún está en sus primeras etapas.

Hasta la fecha, solo se han registrado detecciones confirmadas de OG que provienen de sistemas binarios de Agujeros Negros y Estrellas de Neutrones. La frontera de detección actualmente se encuentra en la búsqueda de OG generadas por CCSNe. En este proyecto se aborda este problema por medio de la implementación de herramientas de aprendizaje automático (Machine Learning). El objetivo principal de este trabajo es crear un clasificador de OG empleando técnicas de Machine Learning (ML).

Las OG de CCSNe son especialmente complicadas de detectar dado que se trata de eventos estocásticos que no se pueden predecir de manera exacta previo a la explosión. Por esta razón, existe un esfuerzo por hacer nuevos estudios sobre estos fenómenos para lograr comprender mejor su comportamiento, por ejemplo, por medio de simulaciones computacionales de este tipo de explosiones.

Las simulaciones son un elemento clave para el desarrollo de este proyecto, ya que son la fuente de datos que ayudarán a entrenar un algoritmo capaz de detectar un señal producida por una CCSNe dentro de una captura de datos de observación. Actualmente, se conoce la forma de las señales de OG de sistemas binarios, de modo que se tienen metodologías para encontrar este tipo de señales.

Sin embargo, estos procedimientos no pueden ser implementados para el caso de las señales de CCSNe, pues estas conllevan procesos estocásticos y la única manera de automatizar su detección es mediante búsquedas no-modeladas. La solución propuesta en este proyecto de investigación consiste en implementar algoritmos de ML que sean capaces de aprender patrones y rasgos generales de las simulaciones de OG de CCSNe para que en un futuro puedan utilizarse como una herramienta para encontrar señales dentro de datos reales de detección.

2. Ondas gravitacionales

Antes de alimentar un modelo de ML para hacer clasificaciones, es necesario entender la estructura y el significado de los datos que se desean analizar. Para este estudio, el clasificador trabajará con imágenes de señales de OG, de modo que el primer paso es entender la teoría básica que describe la generación de este tipo de ondas.

2.1. Relatividad general

La manera matemática de describir las OG es por medio de una solución linealizada de las ecuaciones de Einstein. En RG, las ecuaciones de Einstein relacionan la curvatura del espacio-tiempo con la distribución de masa contenida en este [1]. Estas ecuaciones se representan con el tensor de Einstein $G_{\mu\nu}$ (donde $\mu, \nu \in [0, 1, 2, 3] = [ct, x, y, z]$, y c es la velocidad de la luz en el vacío), el cual se define como:

$$G_{\mu\nu} = R_{\mu\nu} - \frac{1}{2}g_{\mu\nu}R \quad , \quad (1)$$

donde $R_{\mu\nu}$ es el tensor de Riemann, R es el escalar de Ricci, y $g_{\mu\nu}$ es la métrica del espacio-tiempo [5]. Esta expresión matemática da origen a una serie de ecuaciones que, al ser resueltas para el espacio asintóticamente plano, se obtiene una solución con forma de onda que describe la propagación de las OG en el espacio-tiempo.

2.2. Explosiones de supernova por colapso de núcleo

Las estrellas tienen su ciclo de vida, nacen y mueren después de un tiempo. Aquellas estrellas masivas que contienen más de ocho masas solares mueren en un proceso violento en forma de una explosión de Supernova por colapso de núcleo (CCSNe). Las partículas contenidas en la estrella que está por morir se mueven de manera turbulenta debido a los efectos de la explosión.

Esto da como resultado un sistema de procesos estocásticos que son complicados de modelar. De modo que esta clase de fenómeno físico es de particular interés en diversas ramas de investigación dentro de la Cosmología y la Astronomía [6].

Las explosiones de Supernovas son eventos altamente energéticos que producen OG que pueden ser detectadas desde la Tierra con los observatorios actuales. Las OG de CCSNe se forman cuando el campo gravitacional de una estrella masiva hace que la materia contenida en ella colapse hacia su propio núcleo.

Como resultado de este proceso se liberan enormes cantidades de energía, lo cual genera perturbaciones en forma de ondas que se propagan en el espacio-tiempo [1]. Estas ondas pueden ser analizadas para hacer deducciones importantes sobre la dinámica que ocurre en la CCSNe. Se espera que las observaciones de OG de CCSNe contribuyan a responder muchas de las preguntas que aún se tienen sobre el funcionamiento de este tipo de fenómenos cósmicos.

3. Detección y procesamiento de señales de ondas gravitacionales

Las OG pueden ser representadas como oscilaciones en la curvatura del espacio-tiempo, las cuales acarrearán información sobre los cambios en el campo gravitacional de un objeto en el Cosmos [7]. La información contenida en la OG puede ser analizada e interpretada con la ayuda de equipo especializado.

Durante los últimos años, diferentes grupos de investigación alrededor del mundo han hecho esfuerzos para crear nuevas técnicas que permitan detectar OG de manera más efectiva. Para este proyecto, se adaptó la metodología para trabajar con datos de detección de LIGO, que posee la mayor red de observatorios de OG hasta la fecha.

3.1. Interferómetros

La detección de OG de LIGO se hacen por medio de la implementación de un interferómetro Michelson modificado para funcionar a gran escala. Los interferómetros de LIGO se encuentran en las ciudades de Livingston, Louisiana (detector *L1*) y Hanford, Washington (detector *H1*), que además colaboran con el observatorio Virgo (detector *V1*) en Italia.

Esta red de interferómetros ayudan a que LIGO pueda corroborar con mayor certeza si una detección de OG es real o si se trata de una falsa alarma. De este modo, una OG detectada se puede confirmar si aparece en los tres observatorios en el tiempo correspondiente, además de que ayudan a seguir registrando datos aún cuando alguno de los interferómetros se encuentra fuera de servicio.

3.2. Procesamiento de señales

Una de las partes más importantes de la detección de OG es el pre-procesamiento de los datos de detección para que estos puedan ser interpretados. Los datos que se registran durante las corridas de detección están llenos de ruido que predomina sobre las señales de OG, de modo que no es posible observar directamente una señal de OG en una gráfica de datos sin pre-procesamiento. Los detectores de LIGO son capaces de registrar señales en un rango de frecuencias de 10 Hz - 7000 Hz [11].

Una señal de OG por lo general se encuentra en un orden de magnitud de 10^1 - 10^2 Hz, de modo que en cada detección existe un exceso de información que debe ser filtrada para poder observar la señal de OG.

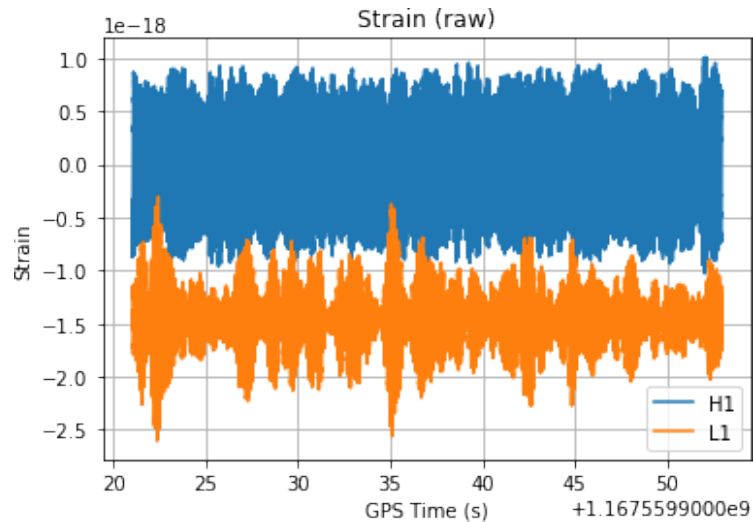


Fig. 1. Serie de tiempo de datos sin pre-procesar de una detección de LIGO hecha con los detectores H1 y L1 [10].

Además, LIGO genera datos en forma de series de tiempo que contienen registros de miles de segundos de observación. Esto añade una capa más de complejidad para las detecciones ya que una observación de OG tiene una duración de una fracción de segundo.

Por esta razón, existen grupos de investigación dedicados únicamente al desarrollo e implementación de algoritmos matemáticos que ayuden a filtrar las señales de OG que se esconden bajo todo el ruido de detección. Esta preparación de los datos de LIGO consiste en implementar técnicas como el análisis de densidad espectral de ruido (NSD), blanqueamiento de datos y transformaciones matemáticas, por nombrar algunas [12].

3.3. Datos de detección

Los datos de LIGO se registran en forma de series de tiempo, es decir, en sucesiones de puntos de medición tomados en un intervalo de tiempo y organizados de manera cronológica. Los datos de detección representan las variaciones en el patrón de interferencia del interferómetro a lo largo de un intervalo de tiempo específico.

Se muestra un ejemplo de los datos de observación de LIGO sin pre-procesar en la figura 1. Como se mencionó anteriormente, los datos de detección están repletos de ruido de diversas fuentes, por lo que es necesario pre-procesar las señales.

Generalmente, el ruido es demasiado denso comparado con las señales de OG, y normalmente es producto de fuentes como la actividad sísmica de la Tierra, vibraciones en el equipo de laboratorio, ruido térmico, perturbaciones eléctricas, entre muchas otras fuentes [10].




Fig. 2. Planos tiempo-frecuencia de una serie de tiempo de datos de detección de OG después de implementar la transformada Q [10].

3.4. Transformada Q

La transformada Q es una técnica matemática que tiene un uso muy importante en el análisis de datos de OG. Una manera eficaz de visualizar señales de OG es con una representación en el plano de tiempo-frecuencia que se obtiene a partir de la transformada Q. El resultado es similar a un espectrograma generado con transformadas de Fourier, con la ventaja adicional de que los intervalos de frecuencia se encuentran más espaciados para frecuencias mayores [10].

Esto da como resultado una mejor resolución para frecuencias altas, lo cual permite crear un espectrograma que muestra señales de OG de altas frecuencias con mayor claridad. En este sentido, la transformada Q proporciona una mejor representación para datos espectrales que la transformada de Fourier [17].

4. Metodología

Las OG producidas por CCSNe son un tema de estudio en la actualidad. Un ejemplo de estos esfuerzos por entender el comportamiento de dichos fenómenos estocásticos es el proyecto publicado por Scheideger [3], en el cual se generaron simulaciones computacionales tridimensionales de eventos de CCSNe. A partir de tales simulaciones se crearon plantillas que representan una señal de OG que cada explosión simulada hubiera producido en el espacio. Las plantillas de OG producidas por Scheideger son un recurso de libre acceso que aproximan el comportamiento de una CCSNe.

Estas simulaciones fueron el factor clave para el desarrollo de este proyecto de investigación, ya que se utilizaron para el proceso de entrenamiento del clasificador de OG. El proceso que se describe a continuación para la creación de un set de datos y su implementación para entrenar una Red Neuronal Convolutiva (CNN) fueron basados en la metodología propuesta por Manuel Morales en su proyecto de clasificación de OG para sistemas binarios de agujeros negros [21].

Tabla 1. Distancias de simulación de las plantillas de OG seleccionadas para construir el set de datos de entrenamiento de la CNN.

	Plantillas de OG									
Distancia (Kpc)	10.00	5.62	3.16	1.78	1.00	0.58	0.32	0.18	0.10	

4.1. Construcción del set de datos

El set de datos para entrenar la CNN necesita incluir imágenes de ejemplo de OG y ruido de detección correspondientes a las observaciones que produciría LIGO. Como se mencionó antes, hasta la fecha no se han logrado hacer detecciones de OG de CCSNe, por lo que no sería posible formar un set de datos con las detecciones disponibles en el repositorio de LIGO.

Por lo tanto, para crear el set de datos de entrenamiento se utilizaron las señales de OG de las simulaciones numéricas de Scheideger en conjunto con señales reales de ruido de detección de LIGO.

Los datos iniciales son series de tiempo que simulan detecciones de OG de LIGO producidas por eventos de CCSNe. Los datos se generan inyectando señales de CCSNe del repositorio de Scheideger dentro de detecciones de ruido de LIGO en formato de series de tiempo. Como parte de este procedimiento, se mantiene un registro de los intervalos de tiempo que contienen únicamente ruido o una combinación de ruido y señal de OG.

Los datos se dividen de acuerdo a las diferentes distancias de medición a las que fueron simulados, ya que la distancia es un factor que cambia la amplitud de la onda detectada. Los datos utilizados para este proyecto corresponden a las distancias que se muestran en el cuadro 1. Los conjunto de datos para cada distancia se dividen en cuatro sets. Cada set es una serie de tiempo que contiene 61 señales de OG distribuidas de manera uniforme sobre 1,200 segundos de datos de ruido de detección.

4.2. Pre-procesamiento de datos

Los datos iniciales están hechos para representar detecciones reales, de modo que deben ser pre-procesados según las recomendaciones de LIGO. Es necesario aplicar las técnicas de procesamiento de señales mencionadas en la sección 3.

La figura 2 muestran un ejemplo de cómo debería verse la señal después del pre-procesamiento. Esta figura muestra el espectrograma de la señal en el dominio de frecuencia, la cual se produce después de aplicar la transformada Q. En este estudio se utilizan las imágenes en el formato de espectrograma para entrenar la red neuronal.

Los espectrogramas son imágenes que muestran los datos a lo largo del tiempo, representados en términos de frecuencia y su densidad de frecuencia correspondiente. Se utilizaron datos de dos interferómetros de LIGO, H1 y L1, así que habrá una imagen del espectrograma por cada detector.

Como ajuste adicional, se redujo la resolución de las imágenes con el fin de disminuir los tiempos de procesamiento computacional. Cada imagen incluida en el set de datos es un array de 48×48 píxeles que representan 0.5 segundos de datos de detección. Un ejemplo de las imágenes que terminan guardándose en el set de datos se muestra en la figura 3.




Fig. 3. Ejemplos de imágenes con baja resolución que se usaron en el set de datos. La imagen de la izquierda representa una señal de Ruido y la imagen de la derecha representa una señal de OG+Ruido.

Por cada inyección de una plantilla de OG se crearon tres imágenes de la señal: una imagen centrada en el medio de la señal, una imagen centrada en el extremo derecho de la señal y otra centrada en el extremo izquierdo de la señal.

Además, por cada grupo de tres imágenes de señal de OG+Ruido, se crearon tres imágenes de Ruido de detección con el fin de mantener un balance de las dos categorías dentro del set de datos de entrenamiento. Todas las imágenes van acompañadas de una etiqueta que indica la categoría correspondiente, ya sea Ruido u OG+Ruido.

4.3. Estructura del set de datos

El set de datos final incluye imágenes representadas como matrices de píxeles, y cada entrada está acompañada de su etiqueta categórica correspondiente, y cada set de datos se dividió en cuatro sub sets diferentes.

Esta subdivisión se hizo para tener mayor control sobre los sets de entrenamiento y evaluación. Cada set contiene 61 inyecciones de plantillas de OG, de manera que su conjunto correspondiente tiene 366 entradas de datos; 183 entradas de señal de OG y 183 entradas de Ruido. Cada factor de distancia contiene cuatro sets, lo cual da un total de 1,464 entradas de datos que se usan para entrenar y evaluar la CNN.

4.4. Estructura de la red neuronal convolucional

Se implementaron tres variaciones distintas en la arquitectura de la CNN, las cuales se usaron para procesar los mismos datos por separado y así obtener una comparación de su desempeño. La primera CNN se compone de una sola capa convolucional, la segunda tiene dos capas convolucionales y la tercera red contiene tres capas convolucionales. Las CNNs que se usaron en este proyecto de investigación mantienen una arquitectura simple.

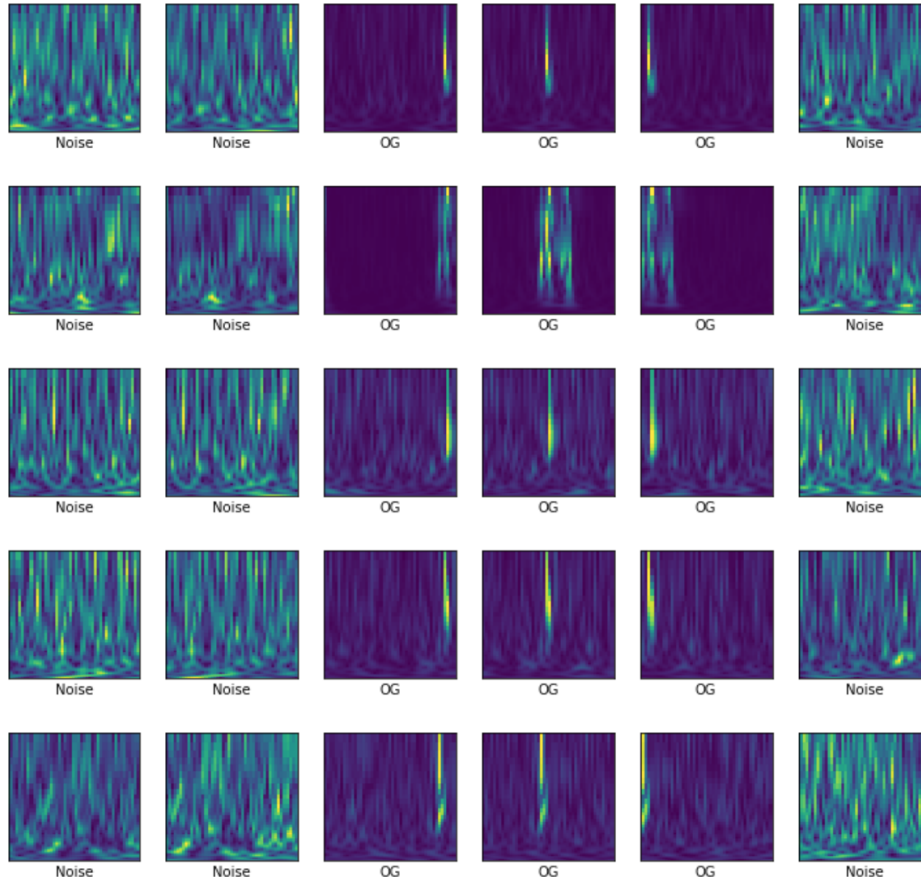


Fig. 4. Representación gráfica del set de datos final de imágenes de espectrogramas con su etiqueta categórica correspondiente.

Para el caso de la CNN de 3 capas, se construyó con dos bloques de capas convolucionales y de pooling, además de un tercer bloque con una capa convolucional y una de flattening para preparar los datos de salida. Al final de la estructura de la red se encuentran dos capas fully connected las cuales captan la salida de la red para asignarla a una de las dos categorías según corresponda la imagen que se analiza. En la figura 7 se muestra una descripción de la arquitectura del modelo. Para las otras dos variaciones de CNN se mantuvo la misma estructura, únicamente fueron ajustadas con una y dos capas convolucionales para satisfacer ambos casos.

4.5. Entrenamiento

Cada variación de CNN se entrenó por separado para cada uno de los factores de distancia del cuadro 1. Como se mencionó antes, a cada distancia le corresponde un grupo de datos divididos en cuatro sets, de modo que tres de estos sets se usaron para entrenar la CNN, y el último set se usó para evaluar el modelo.

```

Model: "sequential"

```

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 48, 48, 16)	304
max_pooling2d (MaxPooling2D)	(None, 24, 24, 16)	0
conv2d_1 (Conv2D)	(None, 22, 22, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 11, 11, 32)	0
conv2d_2 (Conv2D)	(None, 9, 9, 64)	18496
flatten (Flatten)	(None, 5184)	0
dense (Dense)	(None, 64)	331840
dense_1 (Dense)	(None, 2)	130

```

Total params: 355,410
Trainable params: 355,410
Non-trainable params: 0

```

Fig. 5. Arquitectura de la CNN de tres capas utilizada en este proyecto de investigación.

Se hicieron todas las combinaciones posibles de los cuatro sets para dividirlos en entrenamiento y evaluación, de modo que cada CNN se entrenó cuatro veces para cada distancia. Al final se hizo un promedio de los resultados obtenidos de las cuatro iteraciones para calcular la exactitud general de los modelos según las distancias de detección. Además, en cada iteración de las CNNs se hicieron tres arreglos diferentes de los datos de entrada: el primero incluyendo sólo imágenes del detector L1, el segundo sólo con imágenes del detector H1, y el tercero con imágenes de ambos detectores L1+H1 simultáneamente.

5. Resultados

Los resultados de exactitud de clasificación de las CNNs fueron muy parecidos para el caso donde se entrenó con imágenes de una sola fuente, es decir, usando sólo imágenes de L1 o de H1. Para el caso donde se usaron juntas las matrices de píxeles de ambos detectores, la exactitud de clasificación aumentó entre 1 % y 4 % comparado con los casos previos. Este cambio de resultados no fue drástico, no obstante, se observó que la CNN fue más consistente en su porcentaje de exactitud durante los diferentes experimentos de entrenamiento usando imágenes de ambos detectores H1 y L1 juntos.

Este resultado era de esperarse, ya que cada entrada del set de entrenamiento contiene dos imágenes en lugar de sólo una, de modo que hay más información que la CNN puede usar para aprender patrones de clasificación. Después de entrenar la CNN, esta se puso a prueba con el set de datos de evaluación para cuantificar su exactitud.

Tabla 2. Desempeño promedio de la CNN para el conjunto de todas las distancias de observación de acuerdo a los datos de entrada y su número de capas convolucionales.

Desempeño						
Capas	Input	Acc	TN	FP	TP	FN
3	H1+L1	86.38	81.58	8.79	91.21	18.42
	L1	84.54	80.68	11.57	88.43	19.32
	H1	84.17	80.68	12.29	87.71	19.32
2	H1+L1	85.68	81.27	9.89	90.11	18.73
	L1	83.75	80.52	12.99	87.01	19.48
	H1	84.34	80.59	11.85	88.15	19.41
1	H1+L1	84.61	80.79	11.51	88.49	19.21
	L1	83.74	78.47	12.06	87.94	21.53
	H1	83.14	80.36	14.09	85.91	19.64

Los resultados se dividen en cinco parámetros: Accuracy (Acc), True Positives (TP), False Positives (FP), True Negatives (TN), y False Negatives (FN). A continuación se enlista la descripción de lo que representa cada una de los parámetros:

- Acc: porcentaje de aciertos de la CNN al clasificar los datos de evaluación.
- TN: porcentaje de OG clasificadas como OG.
- FP: porcentaje de OG clasificadas como Ruido.
- TP: porcentaje de Ruido clasificado como Ruido.
- FN: porcentaje de Ruido clasificado como OG.

El cuadro 2 muestra los resultados del desempeño en la clasificación por medio de las tres diferentes versiones de la CNN después de ser entrenadas con datos de los detectores H1, L1 y H1+L1. Cabe destacar que estos resultados corresponden al promedio del desempeño de las CNN usando los datos de las 9 distancias distintas que se consideraron para el estudio (cuadro 1).

La primera columna del cuadro 2 se muestra la cantidad de capas convolucionales de la CNN implementada, en la segunda columna se indica la fuente de datos de entrada, y las columnas restantes contienen los resultados de la evaluación de los modelos. También se puede observar el desempeño de la red con cada distancia individual.

La figura 6 muestra cómo cambia la exactitud de la CNN en promedio para cada distancia de observación de los datos. En estas gráficas se puede ver la tendencia del cambio en Acc, TNR y TPR de acuerdo a las diferentes distancias. Estas figuras son una representación de la evolución del aprendizaje de la CNN conforme se aumenta la distancia de observación de las simulaciones utilizadas, ilustrando por separado los casos donde se entrena con datos de H1, L1 y H1+L1.

En la figura 6 se muestran únicamente los resultados correspondientes al desempeño de la CNN de 3 capas convolucionales debido a que estos fueron considerados como los datos más representativos. En general, los casos de las CNNs con una y dos capas convolucionales no mostraron cambios significativos en la exactitud de clasificación, por lo que los resultados son bastantes similares. Se propuso que la CNN con 3 capas es el caso representativo porque, comparada con las otras dos variaciones, su disminución de exactitud es más consistente y menos pronunciada conforme aumenta la distancia.

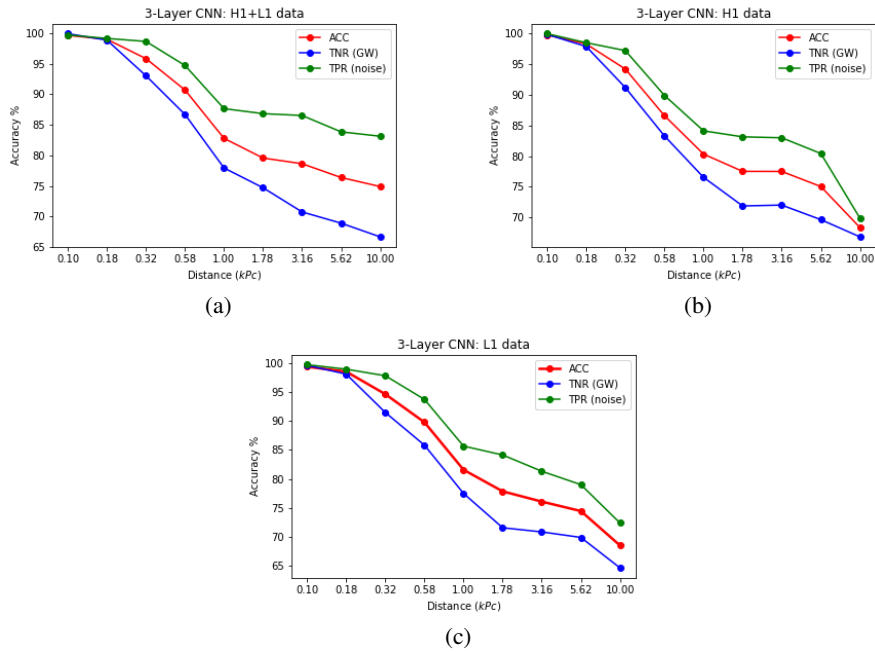


Fig. 6. Desempeño de la CNN de 3 capas de acuerdo a la distancia de detección de OGs. TPR representa el porcentaje de Ruido clasificado como Ruido, y TNR es el porcentaje de OG clasificadas como OG. Cada gráfica indica en el título si corresponde a la CNN entrenada con datos de H1, L1 o H1+L1.

6. Conclusiones

A pesar de que no se percibieron grandes diferencias en el desempeño de las CNN al variar su número de capas convolucionales, la CNN de tres capas fue la que mostró resultados de aprendizaje más consistentes comparada con las otras dos versiones. Por otro lado, los resultados indican que existe un notorio cambio en la exactitud del modelo de acuerdo a la distancia de observación de los datos.

Las clasificaciones para los datos a 10.00 Kpc de distancia tuvieron la exactitud general más baja del conjunto de datos con un Acc cerca de 70 %. El parámetro de Acc incrementa gradualmente para las distancias más cortas (0.18 y 0.10 Kpc), con un punto máximo que llega al 99 %.

Esto significa que las CNNs son considerablemente mejores para clasificar señales de OG en las distancias de detección más cortas (detecciones a 0.58 Kpc o menores). Estos resultados pueden deberse a que el ruido de detección tiende a incrementar su densidad con la distancia, haciendo que las señales de OG queden ocultas dentro de este.

Otro punto a destacar es que el porcentaje de TP es consistentemente mayor que el porcentaje de TN para todos los casos. Esto significa que las CNNs son mejores al clasificar correctamente el Ruido que las señales de OG. Este mismo resultado fue observado en el estudio de Morales (a partir del cual se basó la metodología de este trabajo) para el caso de OGs de sistemas binarios de agujeros negros [21].

Además, es bueno ver en los resultados que el porcentaje de FP en todos los casos es menor al porcentaje de FN, ya que esto indica que la CNN puede llegar a clasificar señales de Ruido como OG pero es menos propensa a confundir señales de OG con Ruido. Esto es relevante porque, si el algoritmo pre-entrenado clasifica señales de OG como Ruido, algunas señales de OG pasarían desapercibidas y no se podría confiar en la CNN como una herramienta de detección.

Los modelos de CNN proporcionaron resultados satisfactorios. Sin embargo, aún hay partes de la metodología implementada que pueden desarrollarse para obtener mejores resultados de clasificación. Se planea seguir trabajando en mejorar este clasificador de señales de OGs, pues se considera que podría llegar a convertirse en una poderosa herramienta de automatización para futuras detecciones de estos fenómenos físicos.

Referencias

1. McMahon D.: *Relativity demystified*. The McGraw-Hill Companies, Inc (2006) doi: 10.1036/0071455450
2. Schutz B.: *A first course in general relativity*. Cambridge University Press (2009) doi: 10.1017/9781108610865
3. Scheidegger, S., Käppeli, R., Whitehouse, S. C., Fischer, T., Liebig, M.: The influence of model parameters on the prediction of gravitational wave signals from stellar core collapse. *Astronomy and Astrophysics*, vol. 514, pp. A51 (2010) doi: 10.1051/0004-6361/200913220
4. Fesik, L.: Polarization states of gravitational waves detected by LIGO-Virgo antennas (2017) doi: 10.48550/ARXIV.1706.09505
5. Szczepańczyk, M. J.: *Multimessenger astronomy with gravitational waves from core-collapse supernovae*. Ph. D. Thesis, Embry-Riddle Aeronautical University (2018)
6. Burrows, A., Vartanyan, D.: Core-collapse supernova explosion theory. *Nature*, vol. 589, no. 7840. Springer Science and Business Media LLC, pp. 29–39 (2021) doi: 10.1038/s41586-020-03059-w.
7. Moore, T. A.: *A general relativity workbook*. University science Books (2013)
8. Torres M. R.: *Modos de polarización de ondas gravitacionales generadas por colapsos de núcleo de estrellas masivas*. Tesis de Licenciatura, Universidad de Guadalajara, México (2021)
9. Villalvazo J. A.: *Análisis del método de máxima verosimilitud en la detección de ondas gravitacionales emitidas por Supernovas tipo II*. Tesis de Licenciatura, Universidad de Guadalajara, México (2020)
10. LIGO Virgo Collaboration. *Gravitational-wave open data workshop #2*. Physics Department, Paris Diderot University (2019)
11. Aasi, J., Abbott, B. P., Abbott, R., Abbott, T., Abernathy, M. R., Ackley, K., Adams, C., Adams, T., Addesso, P., Adhikari, R. X., Adya, V., Affeldt, C., Aggarwal, N., Aguiar, O. D., Ain, A., Ajith, P., Alemic, A., Allen, B., Amariutei, D., Anderson, S. B.: Advanced LIGO. *Classical and Quantum Gravity*, vol. 32, no. 7, pp. 074001 (2015) doi: 10.1088/0264-9381/32/7/074001
12. Maggiore, M.: *Gravitational waves*. Oxford University Press Oxford (2007) doi: 10.1093/acprof:oso/9780198570745.001.0001
13. Gravitational Wave Open Science Center: Event portal (2019) <https://www.gw-openscience.org/eventapi/>

14. Koivunen, A. C., Kostinski, A. B.: The feasibility of data whitening to improve performance of weather radar. *Journal of Applied Meteorology and Climatology*, vol. 38, no. 6, pp. 741–749 (1999) doi: 10.1175/1520-0450(1999)038<0741:TFODWT>2.0.CO;2
15. Huelsman, L. P.: Analog electrical filters. *Encyclopedia of Physical Science and Technology*, Elsevier, pp. 519–530 (2003) doi: 10.1016/b0-12-227410-5/00023-5
16. Abbott, B. P., Abbott, R., Abbott, T. D., Abraham, S., Acernese, F., Ackley, K., Adams, C., Adya, V. B., Affeldt, C., Agathos, M., Agatsuma, K., Aggarwal, N., Aguiar, O. D., Aiello, L., Ain, A., Ajith, P., Alford, T., Allen, G., Allocca, A., Aloy, M. A.: A guide to LIGO–Virgo detector noise and extraction of transient gravitational-wave signals. *Classical and Quantum Gravity*, vol. 37, no. 5, pp. 055002 (2020) doi: 10.1088/1361-6382/ab685e
17. Brown J. C.: Calculation of a constant Q spectral transform. *Journal of the Acoustical Society of America*, vol. 89, no. 1, pp. 425–434 (1991)
18. Géron A.: *Hands-on machine learning with scikit-learn and tensorflow*. O’Reilly Media (2017)
19. Keim, R.: *All about circuits: How to train a basic perceptron neural network* (2019)
20. García-Ordás, M. T., Benítez-Andrades, J. A., García-Rodríguez, I., Benavides, C., Alaiz-Moretón, H.: Detecting respiratory pathologies using convolutional neural networks and variational autoencoders for unbalancing data. *Sensors*, vol. 20, no. 4, pp. 1214 (2020) doi: 10.3390/s20041214
21. Morales, M. D., Antelis, J. M., Moreno, C., Nesterov, A. I.: Deep learning for gravitational-wave data analysis: A resampling white-box approach. *Sensors*, vol. 21, no. 9, pp. 3174 (2021) doi: 10.3390/s21093174.
22. Sormani, C.: A two-part feature: The mathematics of gravitational waves. *Notices of the American Mathematical Society*, vol. 64, no. 7, pp. 684–685 (2017) doi: 10.1090/noti1551
23. d’Inverno, R.: *Introducing Einstein’s relativity*. EUA, Oxford University Press (1992)
24. Moore T. A.: *A general relativity workbook*. Gravitational wave polarization (2010)
25. LIGO Virgo Collaboration. Gravitational wave open science center: Tutorials (2017) www.gw-openscience.org/tutorials/