

# Detector de ondas gravitacionales fenomenológicas de supernovas basado en aprendizaje supervisado

César Eduardo Tiznado Alonso<sup>1</sup>, Claudia Moreno<sup>2</sup>,  
Manuel D. Morales<sup>2</sup>, Mauricio Antelis<sup>1</sup>

<sup>1</sup> Instituto Tecnológico y de Estudios Superiores de Monterrey,  
Escuela de Ciencias e Ingenierías,  
México

<sup>2</sup> Universidad de Guadalajara,  
Centro Universitario de Ciencias Exactas e Ingeniería,  
México

{A00838226, mauricio.antelis}@tec.mx,  
claudia.moreno@academico.udg.mx,  
manueld.morales@academicos.udg.mx

**Resumen.** Debido a que la detección de Ondas Gravitacionales (OG) provenientes de supernovas es una tarea que no se ha llegado a concretar dada a la falta de modelos para su caracterización gracias a la naturaleza estocástica de la señal, se propone una alternativa, un modelo de Machine Learning de aprendizaje supervisado, el cual, utilizando señales sintéticas generadas por un modelo fenomenológico de supernovas y Ruido proveniente de los detectores de OG, generar un clasificador binario que nos indique la presencia de una OG. Para la generación del set de datos de entrenamiento y prueba de nuestro modelo, se procedió a la inyección de las señales sintéticas sobre una muestra de 4096s del ruido obtenido de los detectores de OG. Al separar los datos inyectados en ventanas de tiempo, y caracterizar la presencia de una OG o solo ruido, se procedió a la extracción de las características principales del modelo, siendo el rango tiempo-frecuencia de la señal, la cual nos caracterizará la clasificación de nuestro modelo. Con el set de datos preparado, se procede a utilizar un algoritmo de K-vecinos más cercanos, debido a la simplicidad del modelo de aprendizaje. Al hacer las predicciones, obtenemos que el modelo es capaz de distinguir entre el ruido y la señal gravitacional.

**Palabras clave:** Onda gravitacional, supernova, fenomenológica, KNN, métricas

## Detector of Phenomenological Gravitational Waves from Supernovae based on Supervised Learning

**Abstract.** Due to the difficulty in detecting Gravitational Waves (GW) from supernovae due to the lack of models for their characterization, given the stochastic nature of the signal, an alternative is proposed: a supervised

Machine Learning model. This model uses synthetic signals generated by a phenomenological model of supernovae and noise from GW detectors to create a binary classifier that indicates the presence of a GW. To generate the training and testing dataset for our model, the synthetic signals were injected into a 4096s sample of noise obtained from the GW detectors. By separating the injected data into time windows and characterizing the presence of a GW or just noise, the main features of the model were extracted, focusing on the time-frequency range of the signal, which characterizes the classification of our model. With the prepared dataset, a K-nearest neighbors algorithm was used due to the simplicity of the learning model. The predictions show that the model is capable of distinguishing between noise and gravitational signal.

**Keywords:** Gravitational wave, supernova, phenomenological, KNN, metrics.

## 1. Introducción

Las ondas gravitacionales son perturbaciones en el espacio-tiempo producidas por masas en movimiento, los productores astrofísicos de estas ondas abarcan desde: La colisión de agujeros negros, fusiones de estrellas de neutrones, Cuásares, Pulsares y Supernovas.

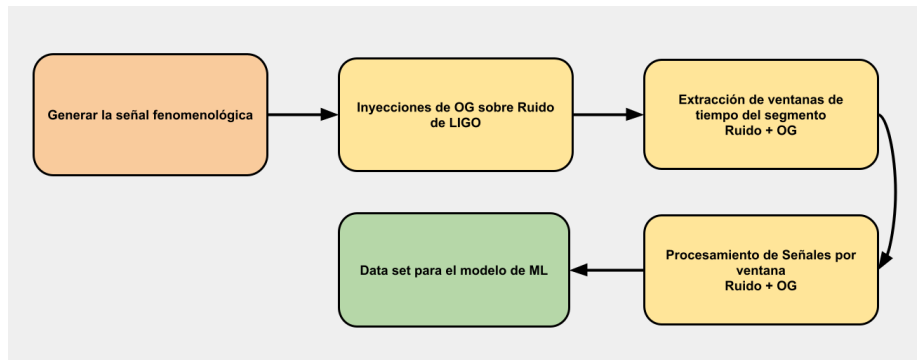
La importancia de la detección de este tipo de señales astronómicas es que nos permite compilar información desde otra perspectiva de los fenómenos astrofísicos que suceden en el universo, los cuales no son posibles de obtener por métodos convencionales, siendo la astronomía de Ondas Gravitacionales una parte fundamental de la llamada Astronomía de Multimensajeros.

El campo nuevo de Astronomía de Multimensajeros apunta hacia el estudio de las fuentes astronómicas mediante diferentes tipos de “Mensajeros”: Fotones, Neutrinos, Rayos Gamma y Ondas Gravitacionales [14].

La detección de este tipo de OG ha sido nuevo para el campo de la Física, esto debido a que a pesar de que son una consecuencia directa de la Teoría de la Relatividad General de Einstein publicada en 1915 [6], no fue hasta la primera detección de este tipo de onda el 14 de mayo del 2015 [2], confirmando su existencia.

Uno de los problemas al hacer este tipo de detecciones recae en el tipo de emisor que genera la OG, siendo las colisiones de objetos compactos(CBC's): Agujeros negros y estrellas de neutrones, las que se encuentran modeladas por métodos numéricos y postnewtonianos los cuales nos permiten tener una gran cantidad de modelos con los cuales podemos detectar una señal mediante matched filtering, pero, ¿Qué es lo que pasa si nosotros deseamos obtener un modelo para emisores como lo son las supernovas?

Las Supernovas se caracterizan por ser procesos estocásticos a diferencia de las CBC's que son deterministas, siendo bastante complicadas de modelar mediante relatividad numérica, que, para conseguir el modelo de una señal multidimensional, pueden tardar en un procesamiento cerca de  $3 \times 10^5$  horas-núcleo (core-hours) [15] debido a la complejidad de procesos físicos que ocurren dentro y sobre las inmediaciones de la explosión de la estrella, así como la falta de certidumbre en la evolución y desarrollo de los mismos.



**Fig. 1.** Diagrama de la estructura de las tareas a realizar para la construcción del dataset para el entrenamiento del modelo de aprendizaje automático. Se inicia con la generación de las señales fenomenológicas, se prosigue con las inyecciones de las señales en ruido de los detectores, se continúa con la extracción de las ventanas imbuidas en ruido y se procesan las ventanas para obtener las características importantes para así obtener el dataset.

En este trabajo se propone utilizar un algoritmo de aprendizaje automático, para reconocer o discriminar entre una señal gravitacional emitida por una supernova imbuida en ruido y ruido de los detectores.

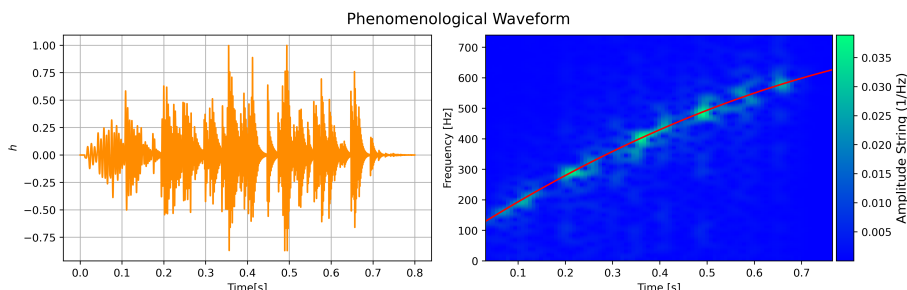
A partir de aquí, se propone utilizar un modelo fenomenológico, que aprovechando la morfología de las OG producidas por supernovas se pueden generar un gran número de formas de onda, teniendo así disponibles la capacidad para crear un set de datos que se podrá utilizar para la construcción de un modelo de aprendizaje supervisado para generar un detector de Ondas Gravitacionales producidas por supernovas.

La importancia de este trabajo radica en el entrenamiento de un clasificador de OG con señales fenomenológicas de supernovas, el cual puede ser utilizado para próximas detecciones de OG provenientes de supernovas.

La estructura del artículo consta de una introducción a la problemática en la primera sección, la segunda sección consta de la generación del dataset a partir del preprocesamiento de las señales fenomenológicas y el ruido de los detectores de OG, la tercera sección se centra en la clasificación llevada a cabo mediante el modelo de aprendizaje, la cuarta sección en los resultados obtenidos por el clasificador y las métricas obtenidas, y por último, en la quinta sección se hacen las disertaciones necesarias a partir de los resultados obtenidos del proceso de aprendizaje y se contemplan las perspectivas futuras a seguir en próximos trabajos.

## 2. Construcción del dataset

Las modelaciones multidimensionales de este tipo de señales producidas por resolución de ecuaciones de estado [3], tienden a tener grandes tiempos de procesamiento para solo generar una sola señal de onda, es por eso por lo que los datos que se utilizarán provienen desde una aproximación fenomenológica. En esta sección nos centraremos en el preprocesamiento de datos para la generación de nuestro dataset, siguiendo el diagrama de la Fig. 1.



**Fig. 2.** Ejemplo de una forma de onda Fenomenológica generado con el modelo sintético. En la izquierda podemos observar la señal gravitacional correspondiente con una amplitud normalizada, mientras que en la parte derecha observamos la misma señal, pero descrita en tiempo-frecuencia, en donde se observa el modo de oscilación que será la característica principal para la clasificación de estas señales estocásticas.

## 2.1. Generación de ondas gravitacionales fenomenológicas

Desarrollando un modelo fenomenológico, el cual genera una forma de onda, la cual imite a los modelos recuperados de las simulaciones multidimensionales ([16, 13, 12, 9, 4]), intentando que tome el mayor número de características, todo para no estar lejos del rigor científico que requieren este tipo de detecciones.

Dentro de este tipo de simulaciones es posible recopilar uno de los rasgos principales en la evolución de las supernovas, modos de oscilación. Dentro de estos procesos astrofísicos, los modos de oscilación tienden a ser caracterizados por tener un aumento monótonico en una ventana de tiempo comenzado a frecuencias de  $100Hz$  [5].

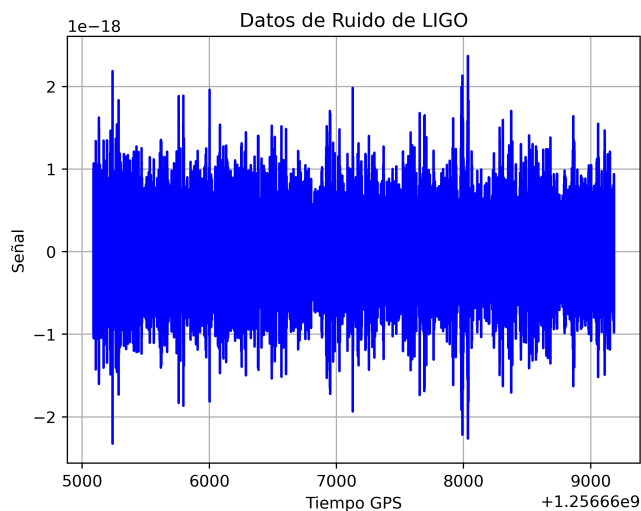
Partiendo de este punto, se propone usar un modelo físico que imite a las perturbaciones esperadas, por lo cual se opta por el uso de un oscilador armónico agregando un forzamiento aleatorio, el cual será responsable de la dinámica estocástica de la forma de onda, este forzamiento aleatorio está definido como  $s(t)$ .

Debido a la necesidad de un factor de amortiguamiento, y siendo este modelo una aproximación fenomenológica de la problemática, se opta por utilizar factor de calidad  $Q$  para controlar que tipo de amortiguamiento va a gobernar nuestro oscilador. Utilizando la relación del *factor-Q* y el factor de amortiguamiento  $\beta$ , tenemos la relación final de nuestro oscilador armónico sub amortiguado:

$$\frac{dh(t)}{dt^2} + \frac{\omega(t)}{Q} \frac{dh(t)}{dt} + \omega(t)^2 h(t) = s(t). \quad (1)$$

Se da paso a su resolución aplicando el método de Euler [7]. Se define un arreglo para la función  $h(t)$ , la cual tiene la misma longitud que la ventana de tiempo  $t$  y cada intervalo está definido por una diferencia finita de tiempo, la cual se define como el inverso de la Frecuencia de muestreo ( $Fm$ ).

Con el fin de tener la mayor cantidad posible de información producida por nuestro modelo, se opta por utilizar una  $Fm = 200KHz$ . La resolución de esta perturbación puede ser escrita mediante la relación en nodos computacionales, tal que satisfacen:



**Fig. 3.** Ruido proveniente del Detector H1 de LIGO, con una duración de 4096s y una frecuencia de muestreo de 16Khz.


$$\begin{aligned}
 F[i] &= s[i] - (w[i]/Q)(dh[i]) - w[i]^2, \\
 dh[i] &= dh[i - 1] + (F[i - 1])dt, \\
 h[i] &= h[i - 1] + (dh[i - 1])dt.
 \end{aligned}
 \tag{2}$$

Ya con las formas de onda producidas, se procede a un preprocesamiento de las señales con un remuestreo de la señal a una frecuencia de muestreo de 16Khz, con el fin de tener la señal dentro de los rangos de muestreo utilizados por los detectores de ondas gravitacionales para así tener un modelo escalable.

Ya con la señal fenomenológica dentro de las características adecuadas (Fig.2), es necesario para la construcción del data set que se utilizará para entrenar el modelo, la consideración de que este tipo de señales en la naturaleza están acompañadas de ruido cuando son percibidas por los detectores, debido a esto, se necesita “inyectar” nuestra señal fenomenológica en ruido el cual, es percibido dentro de los detectores bajo condiciones normales (cuando no existe ninguna detección de OG).

## 2.2. Descripción del ruido

Una de las partes importantes para la identificación y caracterización de las ondas gravitacionales por los grupos de investigación es el uso de los datos obtenidos por los detectores de Ondas Gravitacionales. Estos observatorios son denominados LIGO (Observatorio de Ondas Gravitacionales con Interferómetro Láser) por sus siglas en inglés.



**Fig. 4.** Inyección de la señal fenomenológica en una muestra de 250s, en la cual podemos observar en la parte roja las 16 inyecciones realizadas, mientras que en la parte azul se encuentra la señal de ruido correspondiente al detector H1 de LIGO.

Los detectores de ondas gravitacionales de escala de varios kilómetros de LIGO utilizan interferometría láser para medir las ondas diminutas en el espacio-tiempo causadas por el paso de ondas gravitacionales de eventos cósmicos cataclísmicos.

LIGO consta de dos interferómetros ampliamente separados dentro de los Estados Unidos, uno en Hanford, Washington y el otro en Livingston, Louisiana, que funcionan al unísono para detectar ondas gravitacionales [10].

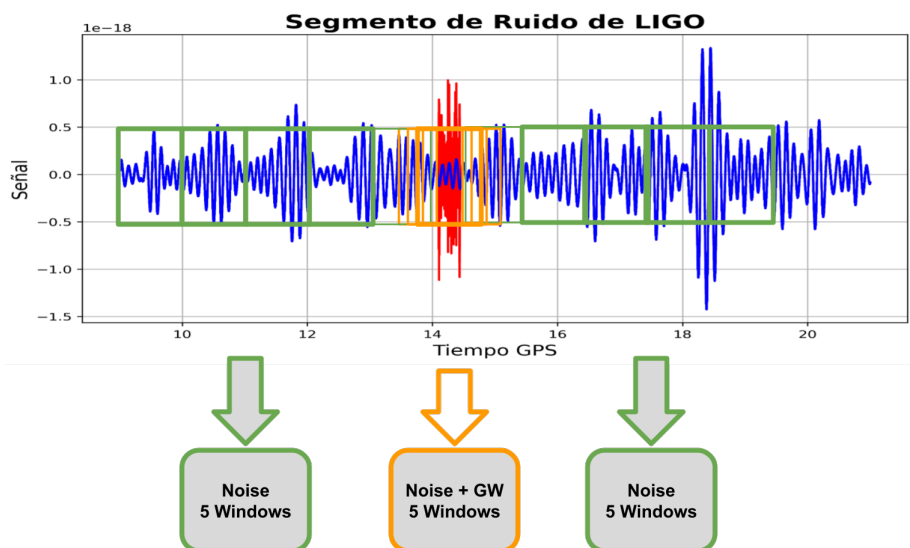
Muchas señales no gravitacionales pueden mover los espejos o afectar la luz láser de una manera que puede imitar o enmascarar una señal de onda gravitatoria. Estos ruidos son generados por muchos fenómenos físicos diferentes.

Los detectores han sido diseñados para que estos ruidos sean extremadamente silenciosos, pero las señales de ondas gravitacionales son igualmente pequeñas, e incluso las fuerzas más imperceptibles en los espejos son suficientes para estropear la medición [1].

Dentro de las fuentes se pueden encontrar: *Ruido sísmico, ruido térmico, Ruido por cargas eléctricas, así como el ruido provocado por los láseres, entre otros. Sobre esta muestra de ruido es donde realizaremos las inyecciones de nuestras señales fenomenológicas.*

Tomando estos aspectos en cuenta, es predecible que en los datos recabados en los sets de observaciones se encuentren señales que son atribuidas a todas estas fuentes de ruido, por lo cual es necesario que las señales fenomenológicas estén concatenadas en este tipo de ruido para así poder generar un set de datos de entrenamiento que se encuentre en condiciones naturales del fenómeno.

El set de datos de ruido proveniente de LIGO utilizados en este trabajo (Fig. 3) son recopilados desde el *Gravitational Waves Open Science Center (GWOSC)* y sus características corresponden a una frecuencia de muestreo de  $16\text{Khz}$ , duración de  $4096\text{s}$ , perteneciente al detector *Livingston* y integra al set de datos *03b*.



**Fig. 5.** Representación gráfica de la segmentación de los datos, en la cual la señal roja representa la inyección de la señal sintética, mientras en azul el ruido del detector. Se puede observar que se toman 5 ventanas de tiempo antes y después de la señal que corresponden a información correspondiente a solo el ruido, mientras que sobre la señal se toman 5 ventanas diferentes que corresponden a la señal sintética imbuida en el ruido.

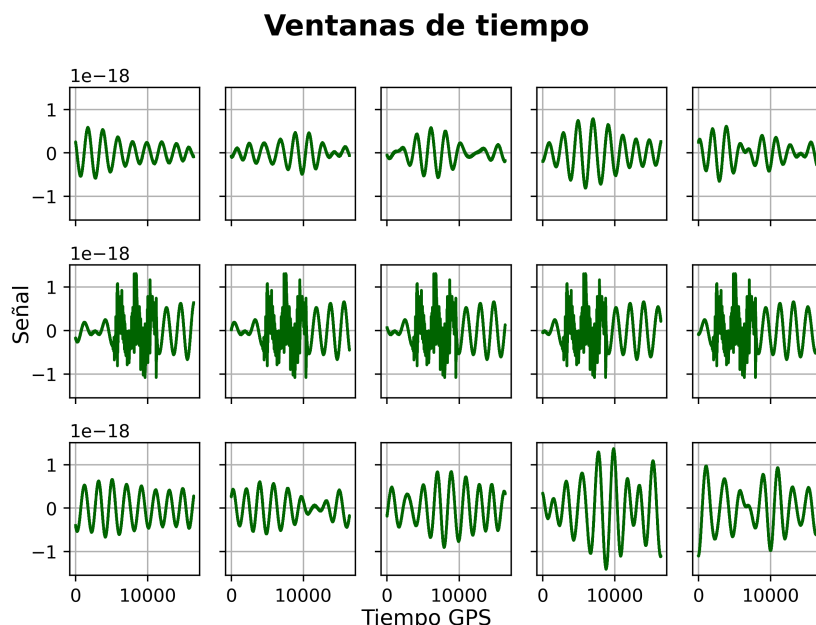
### 2.3. Inyecciones

Con los datos del ruido sobre los cuales se trabajará, se procede a las inyecciones de las señales sintéticas. Este proceso es usualmente llevado a cabo mediante software especializado, pero uno de los problemas por los cuales no es posible utilizar herramientas ya construidas para este proceso recae en que las señales deben contener información de la distancia, los cuales reflejan la intensidad de la señal y la cantidad de energía que pueden emitir estos fenómenos.

Para este trabajo, en el cual se usa una señal fenomenológica que cuenta con la ventaja de generación a un bajo coste, pero que su amplitud está normalizada para poder usarse para los parámetros que sean convenientes, se procederá a utilizar la relación señal a ruido (SNR), el cual al seleccionar un parámetro obtendremos una relación directa entre la señal inyectada y el ruido que se está utilizando, dentro de estos valores es posible calcular cuál es el factor para que la amplitud de la señal seleccionada este bajo las condiciones deseadas.

Se procede a inyectar la señal varias veces la señal con una respectiva ventana de tiempo de 16 *segundos*, marcando el inicio de la inyección en el tiempo  $t_i$  pero que se encontrara variado por la inclusión de un jitter con valores entre (-2,2)s de la señal.

Un ejemplo sería tener el tiempo  $t_1 = 16s$  del ruido sobre el cual se efectuara la primera inyección, pero con un jitter de  $-1s$ , el cual nos daría nuestra inyección en el tiempo  $t_1 = 15s$ .



**Fig. 6.** Ventanas de tiempo tomadas para un segmento de las inyecciones. (Superior) Ventanas previas a la inyección con solo ruido, (Central) Ventanas las cuales contienen la inyección de la señal sintética, (Inferior) Ventanas posteriores a la inyección, solo contienen ruido.

Ya con los parámetros de cada ventana de tiempo y un jitter que va cambiando entre sus rangos predefinidos, procedemos a efectuar las inyecciones sobre la señal de ruido, como lo mostramos en la Fig. 4, en los cuales tomamos solo un rango de 250s de la señal para mostrar las inyecciones en rojo, mientras en azul se encuentra solo la señal inherente al ruido. Al final se logran obtener alrededor de 255 inyecciones sobre toda la ventana de tiempo perteneciente al ruido.

#### 2.4. Extracción de ventanas de tiempo

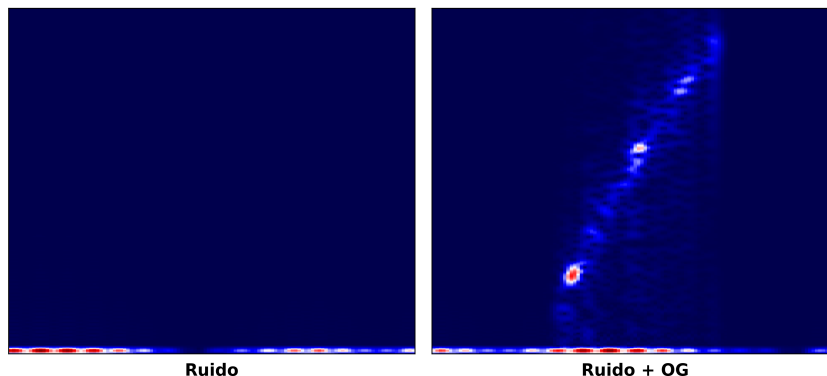
Con nuestra señal de tiempo ya inyectada, uno de los procesos seguidos para la generación de nuestro data set, es segmentar esta información a partir de pequeñas ventanas de tiempo [11] (Fig. 5), sobre las cuales será mucho más fácil manejar la información debido a la gran extensión de recursos que se requiere para procesar cerca de  $6 \times 10^6$  segmentos de datos.

Teniendo esto en cuenta, haremos una segmentación alrededor de la señal que consta de 5s antes de la inyección y 5s posteriores al terminar la inyección de la forma de onda.

Si consideramos que las ventanas que tomaremos tiene la longitud de 1s y procederemos a tomar 15 ventanas del problema, 10 correspondientes a obtener muestras del ruido, mientras 5 se centraran en la obtención de la señal inyectada sobre el ruido, una muestra de esto es la Fig. 6.



### Espectrograma Ventanas del Dataset



**Fig. 7.** Espectrogramas de las ventanas de tiempo, (Izquierda) Corresponde a la relación tiempo-frecuencia de la señal perturbativa del detector de OG, (Derecha) Relación tiempo frecuencia de la inyección de la señal fenomenológica en el ruido del detector, mostrando la característica principal de esta señal, el modo de oscilación de la OG de supernovas.

## 2.5. Procesamiento de datos


Al extraer las ventanas de las 255 inyecciones, se logran obtener alrededor de 3825 señales, las cuales constan del 67 % pertenecientes a ruido de los detectores y el otro 33 % corresponden a una señal gravitacional imbuída en ruido.

Debido a que nuestro interés recae sobre la clasificación de estas señales utilizando un modo de oscilación, se necesita ejecutar de un análisis de tiempo-frecuencia de cada ventana de tiempo, por lo tanto calculando el espectrograma para cada una de las ventanas obtenidas, se adquieren las ventanas necesarias para la creación de nuestro data set, el cual alimentara nuestro modelo de aprendizaje (Fig. 7).

Para poder continuar con el trabajo, se necesitan extraer las componentes principales que se encuentran en cada espectrograma obtenido, por lo cual, adoptando una estrategia de extracción de la componente espectral de cada una de las imágenes, se lleva a cabo mediante los valores pertenecientes a cada pixel de cada una de estas gráficas de relación tiempo-frecuencia.

Además, si reducimos la información que proviene de un formato 3-dimensional como lo es él *RGB* a una interpretación 1-dimensional *B/N* lograremos atenuar la cantidad de datos a procesar y complementando podemos reducir la cantidad de píxeles con los que contará cada una de las ventanas, logrando una reducción importante de datos sobre los cuales ninguna característica principal recibirá una potencial penalización por el modelo. Para cada una de las imágenes que será utilizada para este trabajo consta de una dimensión de  $28 \times 28$  píxeles (Fig. 8).

Debido a la estrategia de clasificación que utilizaremos, se requiere el procesamiento de los datos, el cual consta de una vectorización de los datos de entrada, por lo tanto, realizando un ajuste dimensional de los datos obtenidos por cada imagen, reducimos de una matriz de  $28 \times 28$  a un vector de  $1 \times 784$  tendremos un vector de 784 valores por cada ventana, creando así el set de datos para el entrenamiento y test de nuestro modelo de aprendizaje.



**Fig. 8.** Comparación de los elementos en el set de entrenamiento. Al extraer las componentes principales de las ventanas de tiempo (espectrograma), corresponde a una extracción de la información de los píxeles de estas imágenes. (Izquierda) ventana de  $28 \times 28$  píxeles correspondiente a ruido del detector, (Derecha) ventana de  $28 \times 28$  píxeles correspondiente a la señal sintética inyectada.

### 3. Clasificación

Debido a que el objetivo de nuestro trabajo es diseñar un clasificador el cual nos muestre si existe una señal gravitacional dentro del ruido de los detectores, es imperante utilizar un algoritmo de Machine Learning en este caso, uno de aprendizaje supervisado el cual consta de una clasificación binaria: Existe o no la presencia de una onda gravitacional.

Por lo tanto, se opta por un algoritmo, el cual sea de fácil implementación y que no necesite una gran cantidad de hiperparámetros, es natural la selección del clasificador por K-Vecinos-más Cercanos (KNN).

#### 3.1. KNN: K vecinos más cercanos

El algoritmo de  $k$  vecinos más cercanos, también conocido como  $KNN$  o  $k - NN$ , es un clasificador de aprendizaje supervisado no paramétrico, que utiliza la proximidad para hacer clasificaciones o predicciones sobre la agrupación de un punto de datos individual.

Para los problemas de clasificación, se asigna una etiqueta de clase sobre la base de un voto mayoritario, es decir, se utiliza la etiqueta que se representa con más frecuencia alrededor de un punto de datos determinado. Si bien esto técnicamente se considera “voto por mayoría”, el término “voto por mayoría” se usa más comúnmente en la literatura.

El objetivo del algoritmo del vecino más cercano es identificar los vecinos más cercanos de un punto de consulta dado, de modo que podamos asignar una etiqueta de clase a ese punto.

**Tabla 1.** Métricas del modelo de aprendizaje.

Métrica	Valor
Accuracy	0.970
Precisión	0.993
Recuperación	0.911

Para determinar qué puntos de datos están más cerca de un punto de consulta determinado, será necesario calcular la distancia entre el punto de consulta y los otros puntos de datos. Estas métricas de distancia ayudan a formar límites de decisión, que dividen los puntos de consulta en diferentes regiones [8].

Para este caso se utiliza la distancia euclidiana:

$$d(x, y) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2}. \quad (3)$$

En donde la distancia entre los puntos  $x_i$  y  $y_i$  está denotada por  $d(x, y)$ .

Tomando esto en cuenta, primero se divide el set de datos en dos partes, entrenamiento y prueba, los cuales con 70% y 30% correspondiente del set de datos. Después se complementa con un set de etiquetas las cuales corresponden a cada una de las señales y nos indican la presencia de la OG y se dividen de misma manera.

Ya con el set de datos de entrenamiento comenzamos con el desarrollo del modelo, el cual utilizando de IDE: Python = 3.8.5 y las paqueterías especializadas de Scikit-learn procedemos a entrenar nuestro modelo con los datos de entrenamiento utilizando un hiperparámetro de vecinos  $k = 3$ . Con el modelo ya entrenado, se procede a efectuar una predicción con los datos de prueba.

## 4. Resultados


Las predicciones efectuadas por el modelo son evaluadas con el set de etiquetas de prueba, los resultados de las predicciones pueden ser observadas a través de una matriz de confusión la cual nos muestra las señales que fueron clasificadas satisfactoriamente, así como las que no a través de una comparativa entre señales reales y las predichas, esto puede observarse en la Fig. 9.

Así mismo, para la evaluación del modelo de aprendizaje es necesario utilizar las métricas utilizadas para valorar el rendimiento de las predicciones que puede generar.

Las utilizadas, las podemos observar en la Tab. 1 en la que obtenemos los valores de Exactitud (Accuracy), el cual representa el porcentaje total de los valores correctamente clasificados, la precisión, la cual determina el porcentaje de valores clasificados como correctos, la recuperación (Recall), la cual nos muestra el porcentaje de los valores que han sido clasificados como verdaderos positivos. Para el caso de la clasificación de la clase: Ruido, se identificaron satisfactoriamente 783, de las 785 ventanas.

Es decir, se clasificaron correctamente el 99% de las ventanas de ruido, mientras que 1% de las ventanas de ruido resultan en una clasificación errónea.

Para el caso de la clasificación de la señal sintética de OG se identificaron correctamente 331, de 363 ventanas de señales de OG.



**Fig. 9.** Matriz de Confusión del modelo de aprendizaje. El rendimiento de clasificación contó con 97 % de predicciones y un 3 % a clasificaciones erróneas.

Es decir, se clasifican correctamente el 91 % de las ventanas de señal fenomenológica, mientras que el 9 % resulta en una clasificación errónea.

## 5. Conclusiones

Dentro de las clasificaciones efectuadas por el modelo de aprendizaje obtenidas mediante las métricas, se logra apreciar que las predicciones son satisfactorias, casi generando una clasificación perfecta, este fenómeno nos muestra que se cumple el objetivo del clasificador, lograr distinguir entre una OG y el ruido.

Es sumamente importante el notar que, aunque las clasificaciones suelen ser muy buenas, estas son atribuidas en partes porque el modelo de aprendizaje clasifica mejor el ruido que la señal gravitacional.

Una de las razones por las cuales se puede atribuir este comportamiento se puede observar la Fig. 7, los datos de la OG sintética, que son inyectados en el ruido, son totalmente distinguibles en el ruido, cosas que no ocurre en la naturaleza.

La razón por la cual la amplitud de estas señales sintéticas es debido a que el valor del SNR dado para cada una es bastante grande.

La realización de este detector nos muestra una alternativa para la detección de este tipo de señales, que a pesar de que no han sido detectadas, ya se pueden emplear estrategias para que las próximas detecciones sean exitosas.

En trabajos futuros se planteará la utilización de modelos de Deep learning como redes neuronales convolucionales para realizar un detector más preciso y que se adapte a las condiciones de los detectores de OG.

## Referencias

1. La sensibilidad de los detectores LIGO avanzado en los albores de la astronomía de ondas gravitacionales (2023)
2. Abbott, B. P., Abbott, R., Abbott, T. D., Abernathy, M. R., Acernese, F., Ackley, K., Adams, C., Adams, T., Addesso, P., Adhikari, R. X., Adya, V. B., Affeldt, C., Agathos, M., Agatsuma, K., Aggarwal, N., Aguiar, O. D., Aiello, L., Ain, A., Ajith, P., Allen, B., Allocca, A., et al.: Observation of gravitational waves from a binary black hole merger. *Physical Review Letters*, vol. 116, no. 6, pp. 1–16 (2016) doi: 10.1103/PhysRevLett.116.061102
3. Andersen, O. E., Zha, S., da Silva Schneider, A., Betranhandy, A., Couch, S. M., O'Connor, E. P.: Equation-of-state dependence of gravitational waves in core-collapse supernovae. *The Astrophysical Journal*, vol. 923, no. 2, pp. 1–18 (2021) doi: 10.3847/1538-4357/ac294c
4. Andresen, H., Müller, B., Müller, E., Janka, H. T.: Gravitational wave signals from 3D neutrino hydrodynamics simulations of core-collapse supernovae. *Monthly Notices of the Royal Astronomical Society*, vol. 468, no. 2, pp. 2032–2051 (2017) doi: 10.1093/mnras/stx618
5. Astone, P., Cerdá-Durán, P., Di Palma, I., Drago, M., Muciaccia, F., Palomba, C., Ricci, F.: New method to observe gravitational waves emitted by core collapse supernovae. *Physical Review D*, vol. 98, no. 122002, pp. 1–11 (2018) doi: 10.1103/PhysRevD.98.122002
6. Einstein, A.: *Kosmologische Betrachtungen zur allgemeinen Relativitätstheorie* (1922)
7. Greenspan, D.: *Numerical solution of ordinary differential equations: For classical, relativistic and nano systems*. John Wiley and Sons (2008)
8. IBM: Algoritmo de K vecinos más cercanos (2023) <https://www.ibm.com/es-es/topics/knn>
9. Kuroda, T., Kotake, K., Takiwaki, T.: A new gravitational-wave signature from standing accretion shock instability in supernovae. *The Astrophysical Journal Letters*, vol. 829, no. 1, pp. 1–6 (2016) doi: 10.3847/2041-8205/829/1/L14
10. Laser Interferometer Gravitational-Wave Observatory: About (2023) <https://www.ligo.caltech.edu/page/about?highlight=LIGO%27s+multi-kilometer-scale+gravitational+wave+detectors+use+laser+interferometry>
11. 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. 3174, pp. 1–38 (2021) doi: 10.3390/s21093174
12. Müller, B., Janka, H. T., Marek, A.: A new multi-dimensional general relativistic neutrino hydrodynamics code of core-collapse supernovae. III. Gravitational wave signals from supernova explosion models. *The Astrophysical Journal*, vol. 766, no. 43, pp. 1–21 (2013) doi: 10.1088/0004-637X/766/1/43
13. Murphy, J. W., Ott, C. D., Burrows, A.: A model for gravitational wave emission from neutrino-driven core-collapse supernovae. *The Astrophysical Journal*, vol. 707, no. 2, pp. 1173–1190 (2009) doi: 10.1088/0004-637X/707/2/1173
14. Neronov, A.: Introduction to multi-messenger astronomy. In: *Journal of Physics: Conference Series*, vol. 1263, pp. 1–44 (2019) doi: 10.1088/1742-6596/1263/1/012001
15. Reichert, M., Obergaulinger, M., Aloy, M. Á., Gabler, M., Arcones, A., Thielemann, F. K.: Magnetorotational supernovae: A nucleosynthetic analysis of sophisticated 3D models. *Monthly Notices of the Royal Astronomical Society*, vol. 518, no. 1, pp. 1557–1583 (2023) doi: 10.1093/mnras/stac3185
16. Yakunin, K. N., Mezzacappa, A., Marronetti, P., Yoshida, S., Bruenn, S. W., Hix, W. R., Lentz, E. J., Bronson Messer, O. E., Harris, J. A., Endeve, E., Blondin, J. M., Lingerfelt, E. J.: Gravitational wave signatures of ab initio two-dimensional core collapse supernova explosion models for 12–25 M stars. *Physical Review D*, vol. 92, no. 084040, pp. 1–13 (2015) doi: 10.1103/PhysRevD.92.084040