

Comparación de algoritmos de clasificación en el reconocimiento en ondas gravitacionales del tipo lenta, moderada y rápida

Miguel A. Avendaño-Bernal, Cesar Tiznado,
Javier M. Antelis, Claudia Moreno

Tecnológico de Monterrey,
Escuela de Ingeniería y Ciencias,
México

Universidad de Guadalajara,
Centro Universitario de Ciencias Exactas e Ingeniería,
Departamento de Física,
México

{A01733793, A00838226, mauricio.antelis}@tec.mx,
claudia.moreno@academico.udg.mx

Resumen. El 14 de septiembre de 2015 se confirmó a todo el mundo la primera detección de Ondas Gravitacionales, hoy en día muchos de los científicos teóricos, computacionales y experimentales han estado trabajando sin descanso en el desarrollo y mejora de nuevas formas de detectarlas, el siguiente objetivo es la prueba de las Ondas Gravitacionales Core-Collapse Super Novae (CCSNe). En el presente trabajo construimos un algoritmo de Machine learning, que clasifica en tres tipos de Ondas Gravitacionales (OGs) sobre CCSNe a partir de un DataSet de Espectrogramas, partiendo de la generación de 1500 Formas de Onda (FO) y con las herramientas de ML obtenemos un porcentaje de clasificación cercano al 100 % en distinción de dos estudios de las clases que se van generando, esto por la única ambición de aplicar a nuevos métodos de detección que incluyan ruido.

Palabras clave: Gravitational waves core-collapse supernovae g-mode feature phenomenological signal generation machine learning deep learning.

Comparison of Classification Algorithms in Recognizing Slow, Moderate, and Fast Type Gravitational Waves

Abstract. On September 14, 2015, the first detection of Gravitational Waves was confirmed worldwide. Nowadays, many theoretical, computational, and experimental scientists have been tirelessly working on the development and improvement of new ways to detect them, the next goal being the testing of Core-Collapse Super Novae (CCSNe) Gravitational Waves. In this work, we construct a machine learning algorithm that classifies three types of Gravitational Waves (GWs) on CCSNe from a Spectrogram DataSet, starting from the

generation of 1500 Waveforms (WFs). With ML tools, we obtain a classification percentage close to 100% in distinction of two studies of the classes that are generated. This is driven by the sole ambition to apply to new detection methods that include noise.

Keywords: Gravitational waves core-collapse supernovae g-mode feature phenomenological signal generation machine learning deep learning.

1. Introducción

En el año 1915, Einstein publicó un artículo con una nueva perspectiva de la gravedad [3], la idea era que la gravedad en sí no es una fuerza, utilizando nuevas herramientas matemáticas conocidas como Tensores para describir el movimiento de los cuerpos dando así la “Teoría de la Relatividad General” [9] con una idea particular, “El Principio de Equivalencia”, llámese el pensamiento esencial que Einstein utiliza para construir su teoría [22]. En consecuencia se obtienen las Ecuaciones de Campo de Einstein o EFE (Einstein Field Equations por sus siglas en Inglés):

$$R_{\mu\nu} - \frac{1}{2}g_{\mu\nu}R = \frac{8\pi G}{c^4}T_{\mu\nu}. \quad (1)$$

Dando una solución particular conocida como Ondas Gravitacionales, que depende de la Deformación Espacio-Temporal [24]. Con la tecnología actual esta teoría se pone a prueba mediante la detección de Ondas Gravitacionales en base a la interferometría óptica que promete ser uno de las mejores herramientas a nuestra disposición [4].

Detectadas por primera vez el 14 de septiembre de 2015 por LIGO (Laser Interferometry Gravitational-Wave Observatory por sus siglas en Inglés) y Virgo [8], siendo la fuente el choque de 2 Agujeros Negros [11]. El presente trabajo exploraremos una nueva forma de detección de Ondas Gravitacionales generadas por CCSNe que se busca, sean aplicables a detectores más avanzados [7].

2. Marco teórico

Para comenzar con el análisis, necesitamos los conceptos básicos, la teoría de las supernovas de colapso del núcleo proviene de la muerte de estrellas masivas y el colapso gravitatorio que termina en una explosión de supernova, donde viene implicada la dinámica relativista del plasma en un fuerte campo gravitatorio que ambienta la ocasión [10]. La energía proviene de la masa que es superior de $M \geq 8M_{\odot}$, y el 99% se convierte en neutrinos [26].

¿Qué ocurre con el 1% restante de la energía gravitatoria? Esto se traduce como ondas gravitatorias, como mencionamos antes estas son deformaciones de energía que actúan sobre el espacio-tiempo propagándose a la velocidad de la luz [?]. En los casos de Estrellas de Neutrones, se trata de fusiones de sistemas binarios (SB) compactos (Pueden ser de Estrellas de Neutrones y/o Agujeros Negros) [13], en estos SB existe la probabilidad de detectar fuertes OGs emitidas durante un colapso gravitacional o una

explosión [6], añadiendo la búsqueda de modelos que puedan expresar el movimiento de las CCSNe, conocidos como "Modos-gz" "Modos-r"[2]. Los detectores de ondas gravitacionales de tercera generación se están preparando para la oscilación impulsada por neutrinos que se centra casi decenas de milisegundos después del rebote.

En consecuencia, la búsqueda de los OGs CCSNe en la nueva era del Detector Avanzado, debería tener un porcentaje de incertidumbre de 5% [23], mejorando la sensibilidad al eliminar el ruido procedente de OGs de CCSNe reales [7]. Para esto, las investigaciones numéricas buscan probar simulaciones de CCSNe, que dependen fuertemente en la frecuencia que modelan la gravedad superficial (modo-g) [23].

La comprensión de los conceptos "Modo gz sus frecuencias, aportan información útil. Ya que están extremadamente co-rrrelacionados, el Modo g está asociado a la excitación de la Proto-Estrella de Neutrones (PEN), mostrando las permutaciones en el espacio por medio de su oscilación [17, 18], visto por ejemplo en el modelo [16], las oscilaciones del Modo g son convectivamente estables ya que muestran el cambio sobre su superficie.

Con la frecuencia, el análisis se acerca más a la idea anterior, con frecuencias más bajas, el estudio es menos detallado durante el post-rebote [27], ya que no hay suficiente información que uno pueda llegar a obtener. En cambio las resoluciones de alta frecuencia son más reconocibles ya que permiten saber que tipo de fuente es y como evolucionó debido a su oscilación en ese momento [12].

El rango de frecuencias que vamos a estudiar lo tomamos de [21], siendo $f_{Lenta} = [100 \text{ Hz} - 500 \text{ Hz}]$ y $f_{Rapida} = [1000 \text{ Hz} - 2000 \text{ Hz}]$. Otro punto a tener en cuenta es la pendiente, que se calcula mediante la Ec: 2, en la que se consideran las frecuencias con el tiempo, y con una diferencia de 2 muestras tenemos la pendiente final que se desarrolla mediante los experimentos numéricos buscando valores pequeños y grandes [15]:

$$\text{Slope} = \frac{f_{\text{final}} - f_{\text{initial}}}{t_{\text{final}} - t_{\text{initial}}}. \quad (2)$$

La ecuación de la pendiente puede ser resuelta numéricamente o analíticamente en base a la complejidad del modelo utilizado [14]. Para los modelos Súper Nova la pendiente significa un resumen de la dinámica de la explosión y la información de fondo para el estudio OG [20]. La última herramienta que vamos a utilizar son los algoritmos de Machine Learning aplicados a OG, con la expectativa de mejora de las ejecuciones numéricas y disminución del ruido de las señales, analizando datos en el rango de tiempo y frecuencia [5].

Utilizando los datos de LIGO para buscar el comportamiento periódico o estocástico de los OGs y estudiarlos mediante métodos de Cross-Correlation con detecciones y eliminar las fluctuaciones y ruido que puedan aparecer y el análisis con arquitectura de Redes Neuronales de entrenamiento podría servir como ventaja de DeepClean de futuros detectores [19]. Hay algunos estudios modernos (Ver Referencia [1]), que presentan la idea de utilizar sets de datos de LIGO y ejecutarlo para reducir la tasa de falsa detección para así desarrollar la detectabilidad de CCSNe por el análisis de sensibilidad.

La búsqueda para la eliminación del ruido se ha incrementado sobre los acoplamientos no lineales y no estacionarios, incluyendo los supuestos de causalidad e invariancia temporal como fenómenos físicos que no pueden romperse [25].

3. Objetivos

Utilizando la información anterior nuestro objetivo será simular un algoritmo para generar y analizar un conjunto de muchas Formas de Onda, con esta información aplicar Herramientas de Aprendizaje Automático para clasificar en tres tipos de FO prestando atención al valor de la pendiente en el que esté, ya que esta determinará a que tipo pertenecerá dado su comportamiento.

Para lograr esto, debemos definir pasos metodológicos buscando la creación del algoritmo final, además de una base datos para los casos. Dichos definirán si el objetivo tendrá éxito en un período relativamente corto de tiempo, para esta investigación hay 5 pasos para cada época que se muestra a continuación:

1. Optimizar y automatizar un código precursor que nos da un colaborador, la idea es generar muchas forma de onda de manera automática.
2. Crear todos los espectrogramas de las formas de ondas.
3. Re-dimensionar la Matriz de Datos de todos los espectrogramas a un tamaño de 28×28 píxeles y aplanarla a un vector.
4. Obtener un conjunto de datos que guarden el vector y clasificar el tipo de forma de onda en tres casos.
5. Aplicar las herramientas de machine y deep learning para obtener la precisión de la clasificación.

4. Implementación

4.1. Matemáticas empleadas en el desarrollo analítico del modelo físico

La base para generar una forma de onda es una aproximación del oscilador armónico amortiguado, este modelo tiene que ser una forma exponencial que prediga el comportamiento real de una CCSNe real. Necesitamos un modelo como:

$$\ddot{x} + 2\beta\dot{x} + \omega_0^2x = 0, \quad (3)$$

En este caso $\beta = \alpha/2m$ es el factor de amortiguamiento, el modelo necesita este parámetro para simular un efecto similar de una vibración estocástica del CCSNe, coincidiendo con la frecuencia angular ω_0 que es pieza clave para la solución de la ecuación diferencial. Obviamente esta satisface:

$$x(t) = \exp(-\beta t) \left[A_1 \exp\left(\sqrt{\beta^2 - \omega_0^2}t\right) + A_2 \exp\left(-\sqrt{\beta^2 - \omega_0^2}t\right) \right], \quad (4)$$

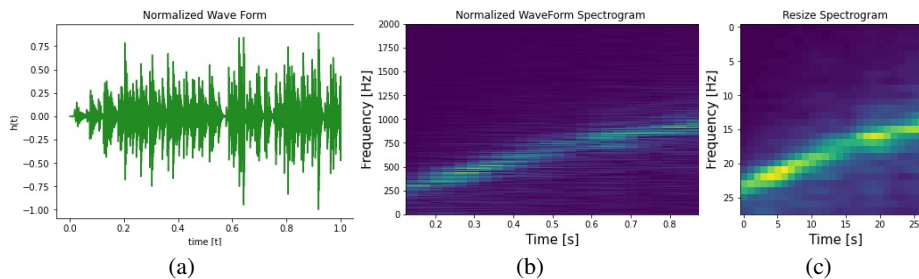


Fig. 1. Una forma de Onda junto a su espectrograma original y espectrograma resampleado.

donde A_1 y A_2 son constantes de amplitud, que necesitan ser definidas al principio de la solución numérica, el término \exp son soluciones analíticas directas de muchas ecuaciones diferenciales de segundo orden, el factor de amortiguamiento se basa en la Ecuación 3 y finalmente todo depende en la región temporal.

4.2. Generación de formas de onda

Es posible generar Formas de Onda personalizadas con Matemáticas aplicadas a un script numérico, similar a la figura 1, donde las condiciones iniciales son esenciales para la resolución de la Forma de Onda que se denomina como $h(t)$ y el rango de tiempo en el que se propagó la Onda Gravitacional.

Inicialmente el script solo era capaz de generar una sola OG, era vital automatizar y generar muchas de ellas, la idea clave fue un bucle que solucionara ese error, y aplicando esto, se obtuvieron 1500 Formas de Onda. Como decimos, no se exige la información de la FO base, necesitamos los Espectrogramas de la misma. Usando la función `sg.spectrogram()` y proponiendo una frecuencia de muestreo de 16384 que es la asociada a la frecuencia de LIGO para sus detectores obtenemos unas gráficas que se muestran en la figura 1 del lado izquierdo.

Para el paso final en esta sección de trabajo, la matriz del Espectrograma fue re-dimensionada y adaptada a una matriz de sólo 28x28 píxeles, la razón de esta idea es que el análisis y el mantenimiento de los Datos podría ser más fácil para el estudio de toda la idea detrás del ML. Consecuentemente, ajustamos esta matriz a solo un vector con solo 784 componentes y concatenamos los 1500 OGs iniciales. Este re-dimensionamiento se puede observar en la figura 1 en la parte central.

A continuación, la implementación de la librería Pandas podría rescatar el redimensionamiento del Espectrograma de Datos en un excel, aplicando una clave y una columna de Datos a la Organización DataFrame. Como nota, para los diferentes Tipos de Onda, cada uno de ellos necesita tener la misma longitud de Datos. Y para cada tipo nombramos de la siguiente manera (Como es obvio, los datos se pusieron en un nuevo .csv):

- 1 → Lenta \forall Pendiente $\in [100 - 1000]$
- 2 → Moderada \forall Pendiente $\in [1000 - 3000]$
- 3 → Rápida \forall Pendiente $\in [3000 - 5000]$

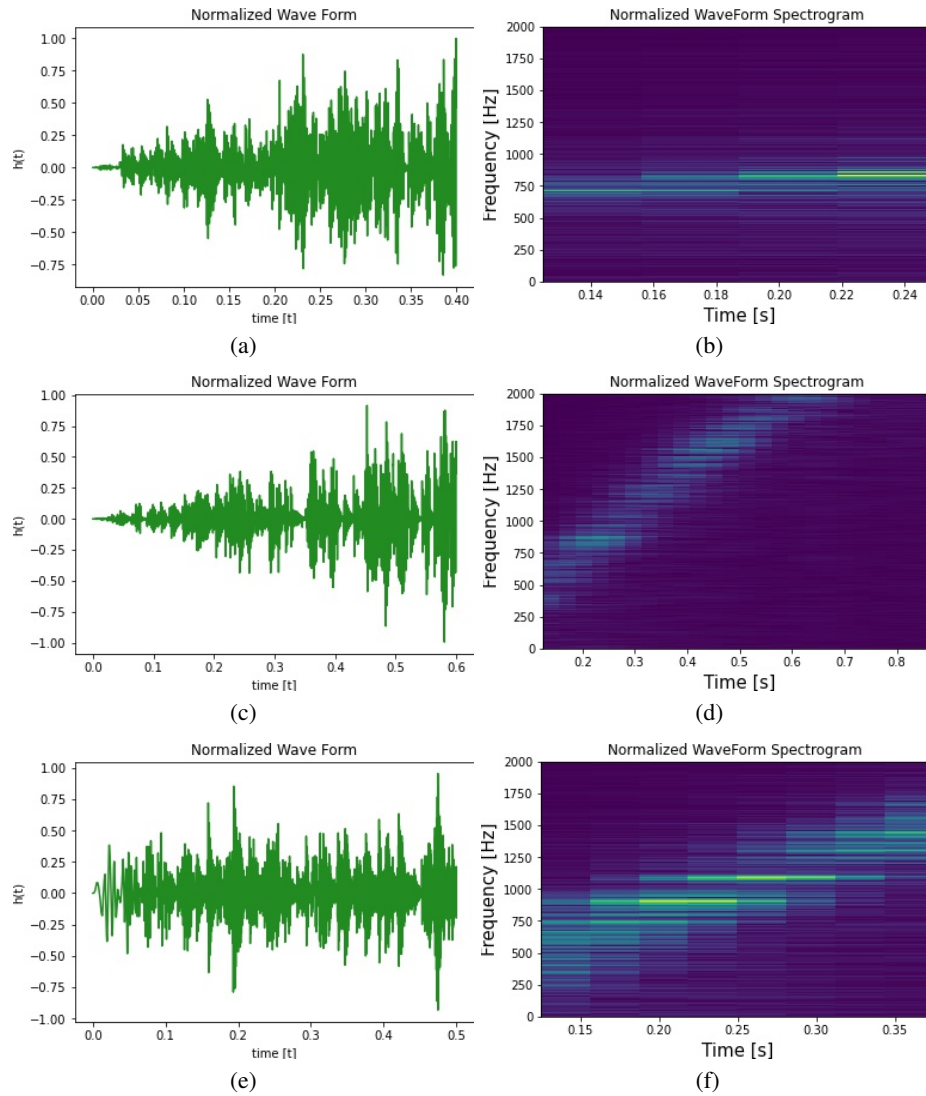


Fig. 2. Forma de onda de tipo lenta con espectrograma normal y redimensionado al valor su pendiente $\in [840, 2550, 3660]$ respectivamente.

4.3. Aplicación de algoritmos de clasificación

El estudio de las clasificaciones se dividió en dos estudios, uno para los datos entrenados y otro para datos puestos a prueba. observado en el gráfico 5:

$$\text{Div. Algoritmo} = \begin{cases} \text{DE} \in 80 \%, \\ \text{DP} \in 20 \%. \end{cases} \quad (5)$$

Tabla 1. Valores de los espectrogramas y su tipo.

	0	1	2	...	781	782	783	Type
1	30	30	30	...	38	39	40	1
2	30	30	30	...	38	40	42	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1499	37	36	35	...	36	35	34	2
1500	31	32	32	...	36	35	34	2

Siendo DE el conjunto de Datos de entrenamiento que permite un análisis basado en la cantidad de Datos, mientras que DP son los Datos de prueba que prueban las variables de entrenamiento para obtener un valor de predicción.

4.4. Modelos de clasificación

Utilizamos 2 tipos de estudios, uno para dos clases (Rápido y lento) y otro para tres clases (Rápido, Lento y moderado), entrenando esta información en 5 algoritmos de clasificación, ya que necesitamos comparar qué estudio es mejor que otro, ver la diferencia de cada uno de ellos y finalmente obtener una puntuación máxima en la puntuación de clasificación. Los modelos utilizados son los siguientes:

1. Logistic Regression (LR): Modelo estadístico usado para la clasificación y predicción de analíticas, ya que estima la probabilidad de que un evento ocurra dado un set de datos que mantiene las variables independientes en un rango entre [0:1].
2. Linear Discriminant Analysis (LDA): Modelo que permite la superposición de variables para la clasificación y reducción de la dimensionalidad de variables para la extracción de clasificación de patrones.
3. Support Vector Machine (SVM): Se basa en el encuentro de un hiperplano dentro de un espacio N-Dimensional que clasifica claramente los puntos de los datos encontrados dentro del hiperplano.
4. Decision Tree Classifier (DTC): Algoritmo usado para la clasificación y regresión de un conjunto de datos para crear un modelo que predice el valor de una variable que tenga como objetivo aprender decisiones simples sobre las características del modelo.
5. Random Forest Classifier (RFC): Algoritmo que combina la salida de múltiples árboles de decisión para alcanzar un resultado particular. Resolviendo los problemas de clasificación y regresión.

4.5. Métricas de clasificación

Mediante estos algoritmos la precisión era vital para saber realmente si el modelo funciona, como observamos en la ecuación 9, existen dos variables, siendo:

Tabla 2. Precisión de la clase Total, 1 y 2.

Precisión Total (2 clases)	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	96.0	0.0	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	99.7	0.0	0.9	0.9
RFC	100.0	0.0	1.0	1.0
Previsión de la clase 1	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	96.1	2.48	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	99.7	0.3	1.0	0.9
RFC	100.0	0.4	1.0	1.0
Previsión de la clase 2	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	96.0	2.69	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	99.7	0.3	0.9	0.9
RFC	100.0	0.0	1.0	1.0

$$TP = \text{Positivos Totales}, \quad (6)$$

$$TN = \text{Negativos Totales}, \quad (7)$$

$$n = \text{Iteraciones Totales}. \quad (8)$$

El análisis cambia para cada clase, para la precisión de una clase la ecuación 10, satisface este problema en base a la Matriz de Confusión, esta explica el rendimiento del algoritmo de una manera visual basado en la clasificación dada:

$$ACC = \frac{TP + TN}{n}, \quad (9)$$

$$ACC = \frac{TP_i + TN_i}{n_i}. \quad (10)$$

5. Resultados

5.1. Espectrogramas y formas de onda

En este apartado vamos a prestar especial atención a los resultados que se han generado. En primer lugar, se presentan tres ejemplos de todos los tipos de Onda-Forma que producimos, es necesario entender que la forma propia de cada onda va a ser variable con las otras dos, el comportamiento, como explicamos al principio es completamente estocástico, lo que significa que es realmente difícil de predecir de una manera exacta.

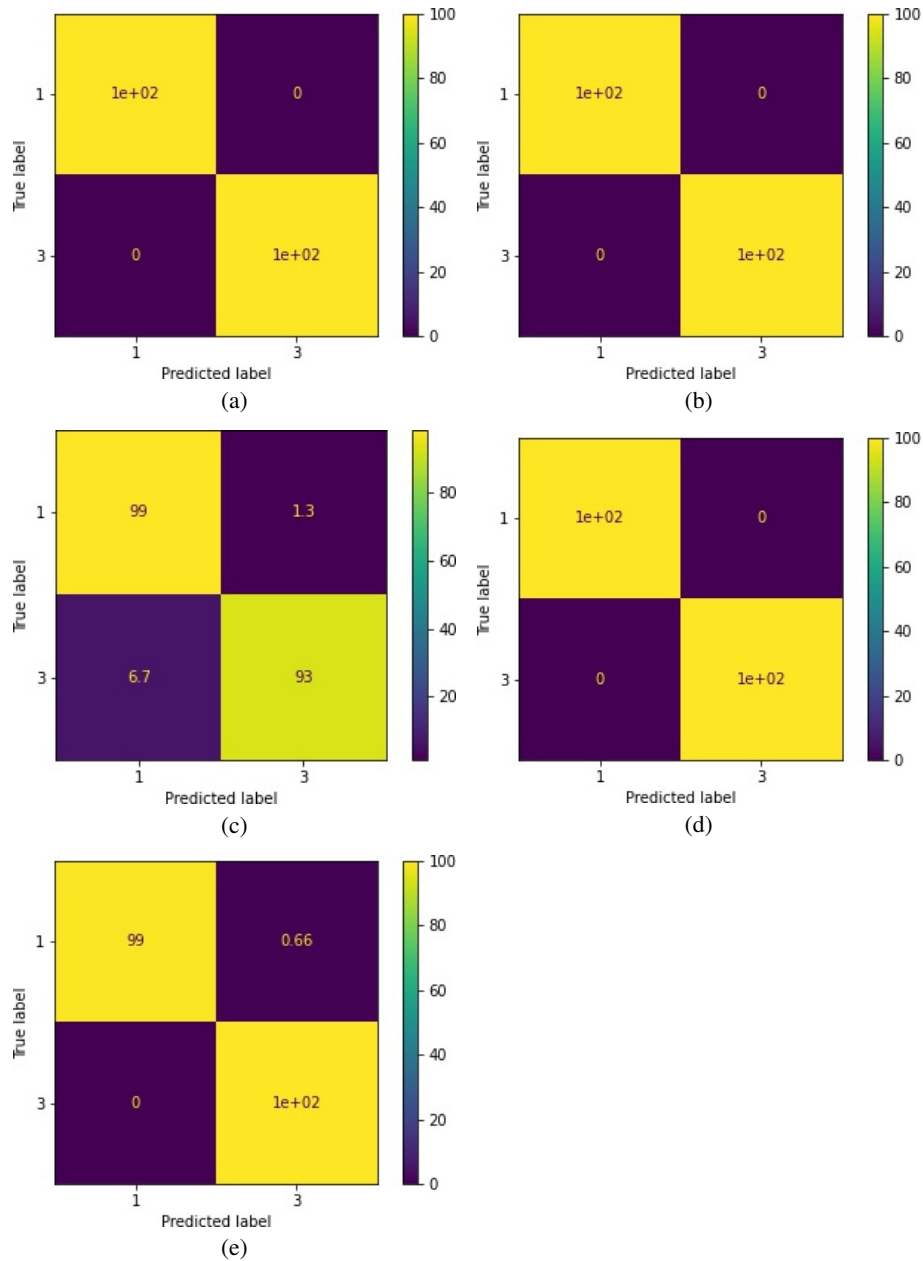


Fig. 3. Matriz de confusión para las métricas LR, LDA, SVC, DTC y RFC de izquierda a Derecha respectivamente para dos clases.

En la figura 2 presentamos un ejemplo del tipo lento donde la oscilación es más estocástica al final del recorrido, comienza lentamente y al final es completamente violenta (Imágenes superiores).

Tabla 3. Precisión de la clase Total, 1, 2 y 3.

Precisión Total (3 clases)	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	98.7	1.0	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	100.0	0.0	1.0	1.0
RFC	100.0	0.0	1.0	1.0
Precisión de la clase 1	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	98.6	1.0	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	100.0	0.0	1.0	1.0
RFC	100.0	0.0	1.0	1.0
Precisión clase 2	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	98.7	1.0	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	100.0	0.0	1.0	1.0
RFC	100.0	0.0	1.0	1.0
Precisión clase 3	Media	STD	Max	Min
LR	100.0	0.0	1.0	1.0
LDA	98.7	1.0	0.9	0.9
SVM	100.0	0.0	1.0	1.0
DTC	100.0	0.0	1.0	1.0
RFC	100.0	0.0	1.0	1.0

Siguiendo por otro ejemplo tipo moderado en la figura 2, observamos que son más lentas y pasivas, de hecho sólo hay un comportamiento estocástico sólo unos instantes al final, pero la mayor parte de la longitud de la trayectoria es completamente suave (Figuras de en medio). Y para terminar el tipo rápido con la figura 2, es claramente el tiene el comportamiento más violento y complejo es impredecible y completamente estocástico, incluso al principio (Imágenes Inferiores).

A continuación, cómo habíamos dicho el cálculo de los espectrogramas es el siguiente paso, de nuevo, vamos a mostrar las gráficas de las mismas formas de onda que están presentes en la misma figura distribuido de la misma forma previamente dicha en la figura 2. Para el primer caso (El tipo Lento), se ve claramente que el valor de la pendiente es pequeño, debido al tipo de FO, y por eso la intensidad que se representa con la línea verde en todo el espectrograma no aumenta mucho con un valor de pendiente de tipo lento.

A continuación está el tipo moderado, en este caso la pendiente crece en comparación con el tipo anterior, y de nuevo es debido al valor de la pendiente, los valores son más altos y tienen más cambio pero respectivamente el tiempo tiene una disminución en la evaluación del mismo mostrada en la Figura 2.

Por último, el tipo Rápido está relacionado con el valor de la pendiente, en este caso tenemos un equilibrio con los parámetros que se están evaluando respecto al tiempo y tiene los mayores valores de frecuencias, la pendiente (Representada con la línea verde) se mantiene sin ningún cambio drástico.

5.2. Data set de los espectrogramas redimensionados

No necesitamos las gráficas de los Espectrogramas, la matriz de información tiene que ser la clave para el análisis final, en este caso con la herramienta *save*, se generó el DataSet, como vemos en la tabla 1, hay un total de 1500 filas con 784 columnas, el primer elemento se anticipa al total de CCSNe WF generados y el segundo elemento es adecuado para la longitud de una matriz de tamaño 28x28 en un solo vector.

5.3. Estudio de 2 clases (algoritmos de clasificación)

Finalmente con todos los Datos recompilados, es hora de utilizar las herramientas de Machine Learning y aplicar las métricas que mencionamos anteriormente a este contexto, pero ¿Por qué necesitamos el estudio para 2 y 3 clases? La primera es que 2 clases nos permiten el análisis y clasificación en sólo 1000 Formas de onda con el tipo de carácter de rápido y lento, nos traen un estudio más rápido que ampliar la precisión efectiva de la clasificación, existen algunos puntos que es importante saber, como:

– Ventajas:

1. Bajo coste computacional: Debido a la poca cantidad de datos que se tienen que además, soporta la computadora para que su análisis sea eficiente.
2. Análisis profundo en las 2 formas de onda: Como solo se están tomando dos tipos de onda, se da un análisis más enfocado para estas formas de onda que permite un muestreo más profundo para cada tipo.

– Desventajas:

1. Con sólo 1000 formas de onda la clasificación esta podría estar sesgada o tener un aumento de porcentaje de error al agregarle ruido:

Ya que solo se están tomando 2 tipos de FO para su análisis, cuando se le añade ruido es posible que el porcentaje de error suba demasiado ya que no está considerando muchas variables de FO o diferentes condiciones iniciales que sí pueden afectar a un análisis más amplio, la solución a esto es tomar muchos más datos sobre tipos, formas de onda con una gran variedad de condiciones iniciales, peso de prueba y comportamiento de la onda.

Con estos puntos en mente, el análisis debe tener una buena puntuación en la clasificación, en la tabla 2, presentamos la Precisión total para las dos clases que estudiamos y de manera particular para cada una de ellas. Es importante notar que la puntuación media es realmente buena, casi cercana al 100 % en las cinco métricas, no tenemos desviación estándar y la información obtenida nos muestra que nuestro trabajo estuvo realmente cerca de un algoritmo eficiente.

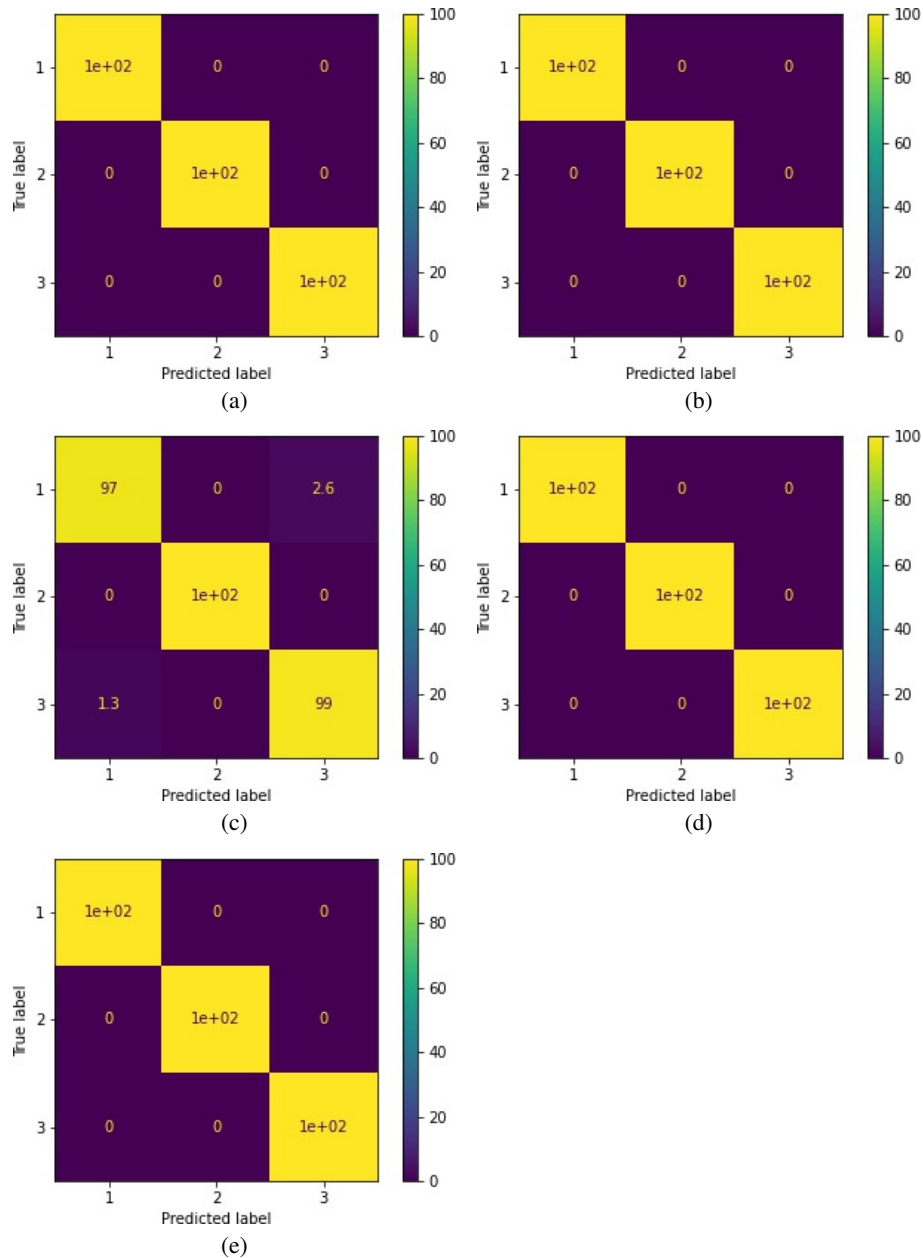


Fig. 4. Matriz de confusión para 3 clases con métricas LR, LDA, SVC, DTC y RFC.

La precisión total tiene que ser la media en la precisión de la clase 1 y clase 2, pero con la información separada podemos ver más profundo. Para la clase 1 (Véase el segundo cuadro de la tabla previa), se observa que para la mayoría de las métricas (Excepto las métricas DTC y LDA), los valores son relativamente más cercanos para

el 100 %, lo que significa que para la primera clase (Que depende del tipo Lento) su clasificación dará resultados mejores. Seguido por la Clase 2 (Tercer cuadro de la tabla previa), los resultados son inferiores a su contraparte excepto en la métrica DTC donde el STD tiene un valor más alto que la otra clase, al menos la clasificación se mantiene en una buena puntuación.

Ahora, necesitamos saber ¿Qué pasa con la matriz de confusión? Bueno, podemos anticipar que si las tablas muestran un buen puntaje de precisión, y están siendo evaluadas a partir de la matriz de confusión, el porcentaje de las mismas será el más cercano a este valor.

Y de hecho, el gráfico para la mayoría de la matriz de confusión es relativamente alta y tiene un montón de precisión, vemos en la figura que para la métrica LR y LDA (Visto en la figura 3), que el porcentaje de clases arroja valores iguales, esto representa que ambas métricas son lo suficientemente buenos para analizar los datos, mientras que para las métricas SVC, DTC y RFC los valores varían en un porcentaje relativamente bajo.

5.4. Estudio de 3 clases (algoritmos de clasificación)

Al finalizar el estudio para las dos clases nos preguntamos, ¿Podemos hacer un estudio de tres clases?, la diferencia será el trato con todos los tipos que generemos, incluyendo el tipo moderado, rápido y lento. De esta forma conseguimos un análisis más ambicioso, ahora los principales puntos a tener en cuenta son:

– Ventajas:

1. Un análisis más grande que toma todos las FOs: Al tener un análisis un poco más amplio, los algoritmos de clasificación tienen la posibilidad de realizar un muestreo más amplio para obtener mejores resultados al momento de su clasificación.
2. La espera a resultados similares: A partir del estudio de 2 clases, se obtuvieron buenos resultados, al agregar otro tipo se espera que los mismos algoritmos mejoren los resultados previos ya que tienen más datos que poner a prueba.

– Desventajas:

1. El mayor coste computacional: Por lo mismo que son muchos datos, el tiempo computacional aumenta, así mismo también las características de la computadora para que soporte la simulación, la solución a esto es primero encontrar una optimización del código base y obtener una computadora de mejor rendimiento en caso de no lograr una mejora.

Además de las otras puntuaciones Media y ETS añadidas páginas atrás, las estimamos pero para este estudio, con resultados similares, podemos ver que para la Precisión Total (Ver en la parte superior de la tabla 3), la media de las clases juntas obtiene un porcentaje mayor que para una sola clase. Ahora, en el análisis de cada clase podemos notar que los resultados son realmente similares o iguales a la precisión total, la clase 1 y la clase 2 (Ver en la parte media de la tabla 3) obtienen elevados de las 2 clases estudio.

Y la clase 3 (Ver en la parte inferior de la tabla 3) consiguen de igual forma un alto porcentaje, el único contraste se ve en las métricas LDA y STD que varían sólo en pocos valores. Con los cálculos de estimación se está calculando la matriz de confusión dando mejores resultados que el otro estudio, en este caso, la precisión para cada clase da valores más cercanos al 100 %, para las métricas LR y LDA los resultados se mantienen básicamente iguales al otro estudio (Visto en la figura 4). Pero para las métricas SVC, DTC y RFC, los porcentajes se elevan al 100 %, la mayoría de la matriz de confusión da este valor.

6. Conclusiones

Como se observó, el trabajo presentado da un algoritmo de clasificación que realiza el objetivo principal, el almacenamiento de los Datos del Espectrograma y la aplicación de herramientas de Machine Learning obtienen los resultados anteriores, de ellos podemos notar que la optimización del algoritmo fue un éxito, ya que puede generar más de 1500 Formas de Onda con el tiempo debido, este factor hace funcionar el código por aproximadamente 10 horas, si queremos hacer más, la paciencia será nuestra aliada. El proceso de entrenamiento es capaz de reconocer el tipo de Onda Gravitacional que estamos buscando. En este sistema, debido al bajo porcentaje de ruido, la clasificación es realmente buena, cabe mencionar que si trabajamos con más Datos el porcentaje puede disminuir con la adición de ruido.

Finalmente las Ondas Gravitacionales están alcanzando un auge nunca antes visto, la astronomía de por sí nos permite conocer su comportamiento y la evolución del universo. Para un trabajo futuro, este trabajo necesita optimizar y mejorar el modelo implementado en las simulaciones numéricas para obtener más OGS. Después es necesario añadir ruido real de LIGO+VIRGO a las señales entrenadas para probar la precisión del modelo. Esto debería guiarnos en un nuevo entendimiento de estos objetos.

Referencias

1. Antelis, J. M., Cavaglia, M., Hansen, T., Morales, M. D., Moreno, C., Mukherjee, S., Szczepańczyk, M. J., Zanolin, M.: Using supervised learning algorithms as a follow-up method in the search of gravitational waves from core-collapse supernovae. *Physical Review D*, vol. 105, no. 8 (2022) doi: 10.1103/physrevd.105.084054
2. Caride, S., Inta, R., Owen, B. J., Rajbhandari, B.: How to search for gravitational waves from r -modes of known pulsars. *Physical Review D*, vol. 100, no. 6 (2019) doi: 10.1103/physrevd.100.064013 <https://doi.org/10.1103/physrevd.100.064013>
3. Charles W. Misner, J. W., Kip S. Thorne: *Gravitation* (2017)
4. Corda, C.: Interferometric detection of gravitational waves: The definitive test for general relativity. *International Journal of Modern Physics D*, vol. 18, no. 14, pp. 2275–2282 (2009) doi: 10.1142/S0218271809015904
5. Cuoco, E., Powell, J., Cavaglia, M., Ackley, K., Beijer, M., Chatterjee, C., Coughlin, M., Coughlin, S., Easter, P., Essick, R., Gabbard, H., Gebhard, T., Ghosh, S., Haegel, L., Iess, A., Keitel, D., Márka, Z., Márka, S., Morawski, F., Nguyen, T., et al.: Enhancing gravitational-wave science with machine learning. *Machine Learning: Science and Technology*, vol. 2, no. 1, pp. 011002 (2020) doi: 10.1088/2632-2153/abb93a

6. Fryer, C. L., New, K. C. B.: Gravitational waves from gravitational collapse. *Living Reviews in Relativity*, vol. 6, no. 1 (2003) doi: 10.12942/lrr-2003-2
7. Gossan, S. E., Sutton, P., Stuver, A., Zanolin, M., Gill, K., Ott, C. D.: Observing gravitational waves from core-collapse supernovae in the advanced detector era. *Physical Review D*, vol. 93, no. 4 (2016) doi: 10.1103/physrevd.93.042002
8. Hajime Sotani, T. T.: Dimension dependence of numerical simulations on gravitational waves from protoneutron stars (2020)
9. Hartle, J. B., Dray, T.: Gravity: An introduction to Einstein's general relativity. *American Journal of Physics*, vol. 71, no. 10, pp. 1086–1087 (2003) doi: 10.1119/1.1604390
10. Janka, H. T., Langanke, K., Marek, A., Martinez-Pinedo, G., Muller, B.: Theory of core-collapse supernovae. *Physics Reports*, vol. 442, no. 1-6, pp. 38–74 (2007) doi: 10.1016/j.physrep.2007.02.002
11. Ju, L., Blair, D. G., Zhao, C.: Detection of gravitational waves. *Reports on Progress in Physics*, vol. 63, no. 9, pp. 1317–1427 (2000) doi: 10.1088/0034-4885/63/9/201
12. Kawahara, H., Kuroda, T., Takiwaki, T., Hayama, K., Kotake, K.: A linear and quadratic time–frequency analysis of gravitational waves from core-collapse supernovae. *The Astrophysical Journal*, vol. 867, no. 2, pp. 126 (2018) doi: 10.3847/1538-4357/aae57b
13. Lasky, P. D.: Gravitational waves from neutron stars: A review. *Publications of the Astronomical Society of Australia*, vol. 32 (2015) doi: 10.1017/pasa.2015.35
14. Manam, S. R., Kaligatla, R. B.: A mild-slope model for membrane-coupled gravity waves. *Journal of Fluids and Structures*, vol. 30, pp. 173–187 (2012) doi: 10.1016/j.jfluidstructs.2012.01.003
15. Martin Phillips, O.: Theoretical and experimental studies of gravity wave interactions. In: *Proceedings of the Royal Society of London, Series A, Mathematical and Physical Sciences*, vol. 299, pp. 104–119 (1967) doi: 10.1098/rspa.1967.0125
16. Mezzacappa, A., Marronetti, P., Landfield, R. E., Lentz, E. J., Yakunin, K. N., Bruenn, S. W., Hix, W. R., Messer, O. B., Endeve, E., Blondin, J. M., Harris, J. A.: Gravitational-wave signal of a core-collapse supernova explosion of a $15 M_{\odot}$. *Physical Review D*, vol. 102, no. 2 (2020) doi: 10.1103/physrevd.102.023027 <https://doi.org/10.1103/physrevd.102.023027>
17. Morozova, V., Radice, D., Burrows, A., Vartanyan, D.: The gravitational wave signal from core-collapse supernovae. *The Astrophysical Journal American Astronomical Society*, vol. 861, no. 1, pp. 10 (2018) doi: 10.3847/1538-4357/aac5f1
18. 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
19. Ormiston, R., Nguyen, T., Coughlin, M., Adhikari, R. X., Katsavounidis, E.: Noise reduction in gravitational-wave data via deep learning. *Physical Review Research American Physical Society*, vol. 2, no. 3, pp. 033066 (2020)
20. Powell, J., Müller, B.: Gravitational wave emission from 3d explosion models of core-collapse supernovae with low and normal explosion energies. *Monthly Notices of the Royal Astronomical Society*, vol. 487, no. 1, pp. 1178–1190 (2019) doi: 10.1093/mnras/stz1304
21. Radice, D., Morozova, V., Burrows, A., Vartanyan, D., Nagakura, H.: Characterizing the gravitational wave signal from core-collapse supernovae. *The Astrophysical Journal American Astronomical Society*, vol. 876, no. 1, pp. L9 (2019) doi: 10.3847/2041-8213/ab191a
22. Sciama, D. W.: The physical structure of general relativity. *Reviews of Modern Physics*, vol. 36, pp. 463–469 (1964) doi: 10.1103/RevModPhys.36.463
23. Srivastava, V., Ballmer, S., Brown, D. A., Afle, C., Burrows, A., Radice, D., Vartanyan, D.: Detection prospects of core-collapse supernovae with supernova-optimized third-generation

- gravitational-wave detectors. *Physical Review D*, vol. 100, pp. 043026 (2019) doi: 10.1103/PhysRevD.100.043026
24. Thorne, K. S.: *Gravitational waves* (1995) doi: 10.48550/ARXIV.GR-QC/9506086
 25. Vajente, G., Huang, Y., Isi, M., Driggers, J. C., Kissel, J. S., Szczepanczyk, M. J., Vitale, S.: Machine-learning nonstationary noise out of gravitational-wave detectors. *Physical Review D, American Physical Society*, vol. 101, pp. 042003 (2020) doi: 10.1103/PhysRevD.101.042003
 26. Warren, M. L., Couch, S. M., O'Connor, E. P., Morozova, V.: Constraining properties of the next nearby core-collapse supernova with multimessenger signals. *The Astrophysical Journal American Astronomical Society*, vol. 898, no. 2, pp. 139 (2020) doi: 10.3847/1538-4357/ab97b7
 27. Yakunin, K. N., Marronetti, P., Mezzacappa, A., Bruenn, S. W., Lee, C.-T., Chertkow, M. A., Hix, W. R., Blondin, J. M., Lentz, E. J., Messer, O. E. B., Yoshida, S.: Gravitational waves from core collapse supernovae. *Classical and Quantum Gravity*, vol. 27, no. 19, pp. 194005 (2010) doi: 10.1088/0264-9381/27/19/194005