

2025年臺灣國際科學展覽會

優勝作品專輯

作品編號	160003
參展科別	物理與天文學
作品名稱	運用機器學習強化探測重力波訊號
得獎獎項	三等獎 印尼世界創新科學作品奧林匹亞競賽

就讀學校	臺北市立第一女子高級中學
指導教師	簡麗賢 詹竣翔
作者姓名	陳知微

關鍵詞	<u>重力波觀測、機器學習、資料分析</u>
-----	------------------------

作者簡介



我從小就喜歡神秘的東西，而在這之中天文最能夠吸引我的注意力，我對嶄新的科技和有趣的知識都充滿興趣，追逐背後的原理讓我非常興奮。科展讓我能盡情探索天文的奧妙，並結識許多對科學有熱忱的朋友，也感謝所有在路上幫助我的人，我才能夠參與這個難得的活動。

2025年臺灣國際科學展覽會

研究報告書

組 別：高中職組

科 別：物理與天文學

作品名稱：運用機器學習強化探測重力波訊號

關鍵詞：重力波觀測、機器學習、資料分析

摘要

本研究欲利用機器學習演算法，透過觀察重力波訊號來判斷黑洞融合訊號的時間。本研究的數據來源於雷射干涉引力波天文台的開放資料庫，我從中獲取最被廣為認定的 64 筆原始數據，並生成具有不同黑洞質量與不同訊噪比的模擬信號。我將模擬信號與不同噪聲混合後，進行強度調整、Q 轉換和資料白化等數據處理，並提取資料的統計量，將其用於訓練三種決策樹演算法和兩種迴歸演算法中。最終研究結果顯示，決策樹演算法的判斷能力優於迴歸演算法，以及指出強度差值的標準差是最關鍵的特徵，重要性達全體特徵的 27%。我們的模型在重力波訊號判斷上表現出較高的效率，並成功降低了模型的複雜度，使其更適合實際應用。

This study aims to utilize machine learning algorithms to identify black hole merger signals by analyzing gravitational wave data. The data is from the Laser Interferometer Gravitational-Wave Observatory (LIGO). I selected 64 widely recognized samples and generated simulated signals with various of black hole masses and signal-to-noise ratios. The simulated signals were mixed with different types of noise and then processed through intensity adjustments, Q transform, and data whitening. Statistical features were extracted from the processed data and used to train three decision tree algorithms and two regression algorithms. Results indicate that the decision tree algorithms outperformed the regression algorithms in predictive accuracy, with the standard deviation of intensity difference identified as the most crucial feature, showing an importance score of 27%. Our model demonstrated high efficiency in gravitational wave signal identification and successfully reduced model complexity, making it more suitable for practical applications.

壹、研究動機與目的

2017年韋斯(Rainer Weiss)、巴瑞許(Barry C. Barish)、索恩(Kip S. Thorne)三名學者，因對雷射干涉重力波天文台(Laser Interferometer Gravitational-Wave Observatory, LIGO) [1]及重力波觀測，獲得當年諾貝爾物理學獎，當時在電視上看到重力波相關報導的我，立刻被宇宙的奧秘深深吸引。

在愛因斯坦的理論中，重力來自於時空扭曲，而天體質量會影響重力場，重力波即為時空扭曲產生的產物。日常中時空扭曲量都沒有達到能被觀測到的標準，導致人們難以察覺。然而當兩個高質量、高密度天體（如黑洞或中子星）互相糾結纏繞且越靠越近時，強烈的重力改變會使得時空扭曲變得更明顯、觀測也相對容易。此時的時空扭曲以重力波的形式傳至地球，被地球上的天文台接收與觀測

到。

現存的對重力波觀測資料的分析方法為了精確性的考量，主要以波形比對為主，然而進行此種分析方法耗費大量時間與算力，為了降低算力的負擔，許多研究者使用機器學習或者深度學習[2]，來增進重力波偵測的效率。


機器學習為人工智慧的一項分支，我們將機器學習的演算法稱作「模型」，設計為讓電腦根據取得的不同特徵，因不同的權重進行判斷，進而決定每筆資料的類別。機器學習可從大量資料中進行訓練以尋找規律，使其可對尚未接觸過的資料進行預測，因此大量應用於圖形辨識、資訊預測和文字產生中。常見的例如：決策樹模型（Decision Tree Classifier, DTC）[3]，透過節點分析的方式來進行分類；卷積神經網路（Convolutional Neural Network, CNN）[4]，通常用於影像辨識；循環神經網路（Recurrent Neural Network, RNN）[5]，用於時間相關或序列型的資料。

為了重力波判斷的效率考量，我決定以機器學習進行探究，使用計算速度快的特徵來簡化模型，使機器自行判斷偵測到的訊號是否為重力波。

貳、研究設備及器材

一、雷射干涉儀

雷射干涉儀使用干涉測量法來獲取資料。干涉測量法是透過分析波的疊加產生的干涉波紋，從而觀測出空間上的細微變化。以最標準的邁克生干涉儀為例，分光器會將原始光線拆分成兩道至兩條干涉臂上，這兩道光線會透過平面鏡反射回偵測器，光線路徑的不同會產生相位差，干涉條紋正是由此處產生的相位差產生，而偵測器可以透過干涉條紋精確判斷原始訊號的模樣。



(圖一) 邁克生干涉儀的原理示意圖 (圖片來源[6])

二、雷射干涉引力波天文台

本研究使用 LIGO 的開放資料進行分析，LIGO 為一探測重力波的天文觀測臺，位於美國華盛頓州漢福德區 (H1) 與路易斯安那州利文斯頓區 (L1)，相距超過 3000 公里。這是因為在相同時刻兩個探測器都接收到的訊號，才會是真正的訊號。LIGO 的特別之處相對於其他引力波天文台，它擁有兩個四公里的等長干涉臂，這極長的干涉臂的靈敏度高，可以讓微小的訊號變得清晰可見。

2016 年 LIGO 與另一室女座干涉儀 (Virgo) [7] 共同發表論文[8]，表示在 2015 年 9 月 14 日觀測到了重力波訊號，來源自距離地球 13 億光年處的兩個質量為 $36M_{\odot}$ 及 $29M_{\odot}$ 的黑洞融合，這項探測結果也更證實了廣義相對論。

三、軟體使用


於資料前處理、機器學習分析上使用的語言為 Python，我們的使用者介面為 Jupyter Notebook，以下 (表一) 為本研究所使用之 Python packages。

(表一) 本研究所使用之 Python packages

名稱	版本	功能
Matplot Lab	3.8.0	將數據化作圖片、將數據可視化
Numpy	1.26.4	將分析後的資料存成二維矩陣、儲存整理後的資料、機器學習使用的分析格式
Pycbc	2.4.0	重力波數據的二次處理，例如傅立葉轉換、過濾特定頻率訊號等
Pandas	2.1.4	將二維矩陣轉換為表格、給每一筆資料加上標籤以利機器學習

參、研究過程及方法

我們的研究流程圖如（圖二）所示。將收集來的資料進行功率譜密度計算，推得出較無雜訊的頻率區段；再進行白化處理，處理後的資料依頻率清楚程度進行過濾，將完成後的資料產製成頻譜圖。以此頻譜圖的資料加上模擬資料合併成數據集，並標註是否存在重力波訊號。將標籤後數據集交由機器學習進行模型訓練，最後利用訓練出的模型預測重力波訊號存在的時段、並估計正確率。



（圖二）資料轉換的流程圖（圖片來源：本研究作者繪製）


一、觀測資料

我們從 GWOSC (Gravitational Wave Open Science Center, GWOSC) 的開放資料集中，下載 LIGO 實驗室於黑洞合成時，干涉儀獲得到的訊號。

選用的數據格式如下：

1. 時間長度有 4096 秒和 32 秒。4096 秒的資料處理上會相對緩慢、在模型訓練時又會有資料量不平衡的狀況 (Data Imbalance)，為了避免這些問題，我們選擇使用 32 秒的時間長度。
2. 頻率間隔為 $1/16$ 赫茲、時間間隔為毫秒
3. 資料內容：強度(strain)、時間戳記(timestamp)
4. 強度的意義：干涉臂會因為時空扭曲而發生些微長度改變，而這份長度改變會反映在干涉儀上，可以利用投影在干涉儀上的結果推導出干涉臂改變量相對於原長的比例，這份改變的比例即為強度。


我們選用了三十二筆數據，其中包含漢福德干涉儀 (H1) 與利文斯頓干涉儀 (L1) 資料的數據。這些數據為在不同時間點干涉儀臂長變化的大小。為了展示重力波訊號是否存在，我們展示出 GW170104 這筆相對被完整觀測的數據，如下 (圖三)。從下圖我們可以觀察到兩筆資料的雜訊都相當的多且明顯，無法從這兩張圖直接看出訊號的存在，因此需進行後續的處理。



(圖三) GW170104 的原始資料橫軸是時間 (單位：秒)，縱軸為強度 (單位：無)，左邊為漢福德干涉儀 (H1) 的資料，右為利文斯頓干涉儀 (L1) 的資料
(圖片來源：本研究作者繪製)

二、模擬資料

目前我僅有 64 筆訊號用於訓練，然而這對於一個完整機器學習模型而言是不夠的，因此我選擇生成許多與觀測資料相似的模擬資料，以增加模型的訓練程度。我使用數學模型計算出重力波的訊號、雜訊、錐形餘弦窗（Tukey Window）以及雜訊的功率譜密度（Power Spectral Density, PSD）。我將訊號根據雜訊的 PSD 與訊雜比（Signal-to-Noise Ration, SNR）對訊號進行調整，為其疊上雜訊，並乘上 Tukey Window，即可完成一份模擬資料。下（圖四）為模擬資料的產製流程圖。



（圖四）模擬資料的產製流程圖（圖片來源：本研究作者繪製）

（一）生成模擬訊號

1. 設定黑洞質量

以最常觀測到的質量區間為主[9]，此處使用 5 到 50 倍太陽質量，以 1 個太陽質量為區間製造出 45 種質量選擇。


2. 生成黑洞合併產生的重力波波形

Pycbc 官方的模擬生成程式，需輸入黑洞質量、每個像素的時間間隔等等，而每個像素的時間間隔需要與觀測資料一致，皆使用1毫秒，生成完畢的如下（圖五）所示。

3. 合併所需時間與黑洞質量的關係

$$t = \frac{5}{256} \times \frac{c^5}{G^3} \times \frac{r^4}{(m_1 m_2)(m_1 + m_2)}$$


t ：合併所需時間； c ：光速； G ：重力常數； $m_1 m_2$ ：兩個黑洞質量。



（圖五）模擬訊號在時域（time domain）上的圖片，橫軸為時間（單位：毫秒）、縱軸為相對強度，此示意資料的黑洞質量為 10 倍太陽質量（圖片來源：本研究作者繪製）

（二）生成模擬雜訊

現實的訊號在每時每刻都有雜訊在作用的狀況，為了貼合觀測資料的環境，我選擇生成模擬雜訊，將其疊加在模擬訊號上。我觀察觀測資料，雜訊永遠比訊號來的長，因此將雜訊長度設定為觀測資料的兩倍。



(圖六) 模擬雜訊在時域上的圖片，橫軸為時間（毫秒）、縱軸為強度。(圖片來源：本研究作者繪製)


(三) 計算功率譜密度(Power Spectral Density, PSD)

本研究使用 Welch 法計算雜訊的功率譜密度。我將資料依時間分段，分別將各段資料進行 Q 轉換，並進行內差，把內差完的振幅平方相加取平均，得到雜訊的功率譜密度。

(四) 錐形餘弦窗 (Tukey Window)

當對長度有限的資料進行傅立葉轉換時，會出現頻域洩漏 (Spectral Leakage)，即是信號會擴展到鄰近頻域間，為了避免此事發生，會為其加窗處理。

在生成窗函式時需給出資料的長度與欲求的平緩值 (α 值)，(圖七) 為不同 α 值生成出來的 window，觀察得知 α 值越大，Tukey Window 就越平緩。為了使資料得以全覆蓋，我們在其中選擇了 $\alpha=10$ 的 window。



(圖七) α 值為 10、0.5、1 的 Tukey Window。(圖片來源：本研究作者繪製)

(五) 合併訊號與雜訊


1. 設定訊雜比 (Signal-to-noise Ratio, SNR)

$$SNR = \frac{P_{signal}}{P_{noise}}$$

現實中常見的訊雜比介於 2~20 倍之間，此處模擬使用 2~20 倍，以 1 倍為區間製造出 18 種 SNR 選擇。

2. 合併雜訊與調整過強度的訊號

根據 PSD 與 SNR 調整訊號的強度，將調整好的訊號注入雜訊的中後段 (隨機注入在後 1/2~後 1/3 的雜訊上)，合併成一份波形資料，並乘上窗函式，完成後如 (圖八) 所示。




(圖八) 合併後的資料，橫軸為時間、縱軸為強度，此處使用 SNR=25 倍，黑洞質量=10 倍太陽的組合。(圖片來源：本研究作者繪製)

三、資料轉換處理

(一) Q 轉換 (Q Transform) [10]

Q 轉換是一種時頻分析工具，進行後會將資料從時域 (time domain) 轉換到頻域 (frequency domain)，即是將訊號轉換為多個不同頻率正弦波的組合。與其他時頻分析工具相比，Q 轉換最大的特色為頻率刻度是在對數尺寸下。下 (圖九) 為進行 Q 轉換後的資料頻譜圖，可觀察到明顯的半月形上升趨勢在中段，此即呈現出在頻譜圖上的黑洞合併訊號。



(圖九) GW170104 在漢福德區 (H1) 的資料，經過傅立葉轉換後得到，此圖橫軸為時間 (單位：毫秒)、縱軸為頻率 (單位：赫茲)、顏色代表強度。

(圖片來源：本研究作者繪製)


(二) 資料白化

將資料進行白化轉換時，會調整權重，進而壓低高斯雜訊，使訊號更明顯。

四、標定重力波訊號

（一）觀測資料

LIGO 官方的資料有給定黑洞合併的時間點 t ，參考過往文獻我們判斷在 $(t - 0.15s) \sim t$ 這段時間內存在明顯重力波訊號。



（圖十）Q 轉換過後的資料，與其標定好的標籤示意圖，上圖橫軸為時間、縱軸為頻率、顏色為強度，下圖橫軸為項數、縱軸為被標為存在訊號（1）或不存在訊號（0）。（圖片來源：本研究作者繪製）

（二）模擬資料

我們在頻域上看每單位像素的強度，挑出高於 X 倍標準差的像素進行標定（ X 取 2、5、7 倍），在該時間下只要有一個頻域有被標定到，我們便認定當下存在重力波訊號。

五、資料特徵

（一）常見統計量

計算單一時間下各個頻率強度的常見統計量，並進行數據可視化，選擇使用人眼可以判斷的特徵來機器學習，我們使用的統計量有：最大值、最小值、平均值及標準差。

（二）時域與頻域差值


我使用偏自相關函式（Partial autocorrelation function, PACF）來驗證特徵

取用的可信性。我計算序列的當前值與過去值之間的相關程度，來決定時間或頻率軸上特徵取到幾位數有較高的參考價值。偏自相關函式的定義如下：


$$\phi_{n,n} = \frac{\rho(n) - \sum_{k=1}^{n-1} \phi_{n-1,k} \rho(n-k)}{1 - \sum_{k=1}^{n-1} \phi_{n-1,k} \rho(k)}$$

$\phi_{n,n}$ ：偏自相關函式、 $\rho(n)$ ：自相關函式

●時間上的PACF



●頻率上的PACF



(圖十一) 時間與頻率上的 PACF，橫軸是前 n 項，縱軸是和前 n 項的相關係數。(圖片來源：本研究作者繪製)

根據 PACF 計算出的結果，我觀察得知每個像素與上個像素為強相關，因此我們將每個單位像素與上個時間或頻率的像素計算差值，得到一個新的二位矩陣。後取用差值計算的常見統計量作為特徵，包含最大值、最小值、平均值、標準差。

六、機器學習模型

(一) 演算法

在模型的考量上，我希望可以使用時間效率較高的模型，因此以下演算法都較為輕量。而在許多輕量模型中，我根據重力波本身的特性挑選了兩種類型的模型。

1. 分類模型 (Classifier)

因為重力波訊號判斷有著二元性，我選用了分類性模型，如：Random Forest Classifier、XGBoost Classifier和Decision Tree Classifier，以便快速地為資料進行

二元分類。

2. 迴歸模型 (Regression)

重力波訊號在頻譜上是具有連續性的，因此我選用了迴歸性模型，如：Logistic Regression、Ridge Regression，以捕捉訊號的連續變化。

(二) 訓練集與測試集的拆分

在機器學習模型訓練中，僅會給模型看到訓練集的特徵與標籤，換言之模型無法看到測試集的特徵與標籤，這樣的操作能夠讓測試集的正確率能讓我們更準確的評估模型。我將原本的資料依照7:3的比例，隨機的分成訓練集和測試集。

七、模型評估

(一) 混淆矩陣 (Confusion Matrix)

混淆矩陣在分類中可以提供視覺化的數據分佈，通常用於二分法問題，判斷有無重力波即是一種二分法問題，故在結論中使用混淆矩陣描述各模型評估情況下（表二）呈現混淆矩陣的定義。

（表二）混淆矩陣的定義

	預測為陰性	預測為陽性
實際為陰性	真陰性 (True Negative)	偽陽性 (False Positive)
實際為陽性	偽陰性 (False Negative)	真陽性 (True Positive)

(二) 正確率指標

要判斷一個模型的精準度，除了單純判斷整體的正確率 (accuracy) 外，我們還需要一些可用且更細節的判斷方式，以下（表三）為四種可用的模型評估指標，表中的TP (True Positive), TN (True Negative), FP (False Positive), FN (False Negative) 分別為混淆矩陣中的真陽性、真陰性、偽陽性、偽陰性。

（表三）為機器學習模型的評估指標，精確率、召回率、F1 score 和正確率的定

義與意義。


	定義	意義
精確率 (Precision)	$\frac{TP}{TP + FP}$	被判斷成陽性的資料中，實際上也是陽性的比率
召回率 (Recall)	$\frac{TP}{TP + FN}$	實際上是陽性的資料中，也被判斷成陽性的比率
F1 score	$\frac{2}{\frac{1}{Precision} + \frac{1}{Recall}}$	精確率與召回率的調和平均
正確率 (Accuracy)	$\frac{TP + TN}{TP + TN + FP + FN}$	整體判斷的正確率

肆、研究結果

一、常見統計量視覺化結果

選用特徵時，需要尋找佐證此特徵是否可行的證據，因此我們可以將其圖像化，轉換成可用肉眼判斷特徵的形式，下（圖十二）為模擬資料的常見統計量、觀測資料的常見統計量與觀測資料差值的常見統計量。






（圖十二）模擬資料的常見統計量、觀測資料的常見統計量與觀測資料差值的常見統計量，橫軸為時間（單位：秒），縱軸為該項數值的大小。（圖片來源：本研究作者繪製）

二、不同標準差

標定訊號時使用高於不同的標準差來標定其為訊號，雖然對強度等特徵沒有影響，但如果使用的標準差無法使我們確定何處有偵測到重力波訊號，將此標定不完全的資料進行機器學習時，訓練出來的模型擬合方向會與觀測資料不符，進而影響最終模型的各項正確率指標。


下（圖十三）為同一份頻譜圖，分別使用兩倍、五倍與七倍標準差來標定後產生的結果，左方為根據單位像素的強度，將高於標準差的值顯示為黃色，其餘則顯示為藍色。而右方的標籤則是基於單位時間內，只要有一個頻域被判斷為過標準差，即將該單位時間的定義為有重力波訊號存在。根據（圖十三）可以觀察到標準差越小時標定範圍就越廣，因為我們給予模型的雜訊時間長度較短，範圍越廣時真實訊號被誤判的機率就越小，因此我選擇使用二倍的標準差來當作最終的定義標準。




(圖十三) 不同標準差(兩倍、五倍、七倍)下的頻域標定圖與標籤，頻域標定圖橫軸為時間項數、縱軸為頻率項數，淺色部分為 1 (有重力波訊號)、深色部分為 0 (無重力波訊號)，標籤部分橫軸為時間項數、縱軸為有無重力波訊號。(圖片來源：本研究作者繪製)

在(圖十三)中僅是列舉出最適宜用肉眼觀察的頻譜圖，無法僅憑單一資料判斷何種標準差較優，為了更全面的判斷標準差，下(表三)顯示較為多筆重力波資料，在不同標準差下的結果，希望透過更多筆資料來讓我們的統計更有整體性。


(表四) 不同標準差(兩倍、五倍、七倍)下的頻譜圖、頻域標定圖與標籤。頻譜圖的橫軸為時間像素、縱軸為在對數指標下的頻率、顏色為強度；頻域標定圖橫軸為時間像素、縱軸為頻率像素，淺色部分為 1 (有重力波訊號)、深色部分為 0 (無重力波訊號)；標籤部分橫軸為時間像素、縱軸為有無重力波訊號。(圖片來源：本研究作者繪製)



(表四之一) 兩倍標準差下的頻譜圖、頻域標定圖與標籤



(表四之二) 兩倍標準差下的頻譜圖、頻域標定圖與標籤



(表四之三) 兩倍標準差下的頻譜圖、頻域標定圖與標籤

三、模擬資料訓練結果

下（表五）為不同機器學習演算法在訓練資料與測試資料上的各項正確率，上面標著的是各機器學習模型簡稱。

我們觀察模型判斷結果，普遍訓練資料的正確率會比測試資料正確率高，因為模型已進行多次重複訓練，對常看到的訊號較為熟悉，故有部分模型在訓練資料上的正確率可以達到 1.0；而測試集的結果略遜於訓練集，測試集中 Classifier 大多比 Regression 優秀，所有 Classifier 中 F1-score 最高的是 XGBoost Classifier。

（表五）為不同機器學習演算法在模擬訓練資料與模擬測試資料上的各項正確率

	RFC(train)	DTC(train)	XGB(train)	logisR(train)	ridgeR(train)	SGD(train)
Precision	1.0000	1.0000	0.9985	0.9866	0.9968	0.9809
Recall	1.0000	1.0000	1.0000	0.9750	0.4552	0.9780
F1-score	1.0000	1.0000	0.9993	0.9808	0.6250	0.9794
Accuracy	1.0000	1.0000	1.0000	0.9998	0.9964	0.9997
	RFC(test)	DTC(test)	XGB(test)	logisR(test)	ridgeR(test)	SGD(test)
Precision	0.9840	0.9935	0.9904	0.9869	1.0000	0.9773
Recall	0.9872	0.9744	0.9904	0.9647	0.3654	0.9679
F1-score	0.9856	0.9838	0.9904	0.9757	0.5352	0.9726
Accuracy	0.9998	0.9998	0.9999	0.9997	0.9956	0.9996

然而在模擬資料訓練、真實資料測試的結果中，各模型的訓練正確率有明顯下降，其中表現最好的模型是 Ridge Regression，其次是 Random Forest Classifier 與 Decision Tree Classifier，（表六）為不同機器學習演算法在真實測試資料上的各項正確率。


（表六）為不同機器學習演算法在真實測試資料上的各項正確率

RFC	DTC	XGB	logisR	ridgeR	SGD
------------	------------	------------	---------------	---------------	------------

Precision	0.0088	0.0067	0.008	0.0081	0.0133	0.0106
Recall	0.033	0.3334	0.0233	0.1497	0.0152	0.0058
F1-score	0.0139	0.0131	0.0119	0.0153	0.0142	0.0075
Accuracy	0.9088	0.9088	0.4994	0.4734	0.9859	0.5012

四、訓練模型的特徵重要性


機器學習模型的特徵重要性如下（圖十四）所示，可以看到含有「標準差」的特徵普遍重要性都較高，含有「最大值」也有著一定的影響力，我猜測重力波訊號的強度變化非常顯著，靠標準差可以透過強度的劇烈變化來推測重力波位置。




（圖十四）機器學習模型的特徵重要性。（圖片來源：本研究作者繪製）

五、判斷錯誤資料的分佈

機器學習模型在處理不同黑洞質量、不同訊雜比的資料時，會有各自的正確率，根據（圖十五）與的結果，我們觀察得知當資料有著較低的質量與較低的訊雜比，被誤判的機率也會隨之增加。



(圖十五) 不同黑洞質量中，模型判斷錯誤資料數量 (圖片來源：本研究作者繪製)



(圖十六) 不同訊雜比中，模型判斷錯誤資料數量 (圖片來源：本研究作者繪製)

伍、討論

一、機器學習結果分析


根據各項正確率指標判斷，使用分類的演算法在各項正確率上普遍高於其餘演算法，估計是源於決策樹處理二元問題的先天優勢，以及其自帶可調節樹的分岔數量，這個特徵在處理複雜問題時兼具效率與正確性，未來這個專題可以朝這個方向繼續發展；而迴歸的演算法則是相對不出色，估計是因其過度簡單的擬合

邏輯無法適用在條件頗多的重力波訊號上，以及因為重力波訊號有明顯的資料不平衡（Data Imbalance）問題，以上使得迴歸演算法在重力波判斷上不合適。

這幾次的模型我觀察到資料不平衡的狀況，為了因應這個狀況，我們未來打算使用 SMOTE 法（Synthetic Minority Over-sampling Technique）來減緩。SMOTE 會將少數的樣本之間進行差值，進而增加少數樣本的數量。應用於重力波訊號上時，使用 SMOTE 可以平衡重力波訊號存在與不存在的資料數，以利模型的訓練。

二、凸波（Glitch）

模擬資料與觀測資料中有雜訊上的差異，目前階段考慮到方便性與運作效率，模擬資料僅使用未有凸波的時域資料作為其雜訊來源。然而根據相關已發表文獻，觀測資料中有時會出現短時間脈衝波型干擾（又稱為凸波），如（圖十七）所示[11]。現階段模型並不具備充分應對凸波的能力，這也是為何在模擬資料中可以運行的模型，在觀測資料中結果不佳的一個因素，未來會隨機增加各式凸波在模擬資料上，以期可以令模擬資料更貼近觀測資料。



（圖十七）凸波頻譜圖範例[12]

三、標準差

不同領域定義訊號的方式各有所不同，例如：粒子物理中將偏離五倍標準差的定為訊號；天文物理中使用的標準差為七倍。為了能在更早期發現重力波訊號的存在，我在定義標籤時使用的標準差是兩倍，因此會產生標準是否過度寬鬆的疑慮；因此考慮未來將資料的時間拉長，以避免被過大強度的數據影響中位數，進而影響標準差倍數的判斷，以及期望將標準差調整為七倍以減少判斷標準差倍數的疑慮。

四、單一探測器判斷的限制

LIGO 過往文獻表明訊號判斷需綜合不同偵測器的結果，然而偵測器之間的距離有時相當遠，例如 LIGO 與 VIRGO 便跨越了一個大西洋。已知地球半徑為 6371 公里，對比光速的 3×10^5 公里，有機會被重力波接收方位影響，造成最長可達 0.04 秒的誤差。這份誤差使不同偵測器數據上的波峰值產生位移，從而導致一筆資料無法完整概括 GPS 上的合併時間。在重力波訊號中這份誤差足以導致大量標籤的標定錯誤，進而導致最終結果的不準確，這便是本研究使用單一探測器進行預測的限制。

陸、結論

一、模型使用結論

目前為止我們將重力波的觀測訊號與模擬訊號進行各種處理後，以不同的標準差來標定模擬資料，並將其交給機器學習來嘗試偵測訊號的存在位置，我們使用了不同的機器學習演算法來判斷重力波訊號，得到了各個模型的正確率與模型評估，而模型之中決策樹演算法的結果較為優秀，迴歸演算法則較為遜色，未來會進一步研究透過調整決策樹演算法的不同參數，比如學習率、決策樹深度等，來提高模型的各項正確率。

二、未來展望

（一）為了將研究做得更好，我可以為模擬資料加長雜訊並增加凸波，以更貼近觀測資料中的雜訊環境。以及可加深研究決策樹系的演算法，透過調整模型各項常見參數來提升正確率。還可以嘗試使用深度學習判斷同一份資料，以得知複雜模型在處理重力波訊號上的效率。

（二）機器學習演算法作為簡單模型，在正確率與模型評估的結果卻也可以有不錯的結果，或許未來將正確率突破一定門檻後，可以加快目前主流方法——波形比對的效率，透過機器學習初步篩選資料，再將剩餘較難判斷的資料進行較精確的波形比對，可以成為未來重力波探測上的一項優化選擇。

柒、參考文獻資料

1. Abramovici, A., et al., *LIGO: The Laser Interferometer Gravitational-Wave Observatory*. Science, 1992. **256**(5055): p. 325-333.
2. Cuoco, E., et al., *Enhancing gravitational-wave science with machine learning*. Machine Learning: Science and Technology, 2021. **2**(1): p. 011002.
3. Yim, J., *Introducing a decision tree-based indoor positioning technique*. Expert Systems with Applications, 2008. **34**(2): p. 1296-1302.
4. Li, Z., et al., *A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects*. IEEE Transactions on Neural Networks and Learning Systems, 2022. **33**(12): p. 6999-7019.
5. Yu, Y., et al., *A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures*. Neural Computation, 2019. **31**(7): p. 1235-1270.
6. Lawall, J. and E. Kessler, *Michelson interferometry with 10 pm accuracy*. Review of Scientific Instruments, 2000. **71**(7): p. 2669-2676.
7. Acernese, F., et al., *Advanced Virgo: a second-generation interferometric gravitational wave detector*. Classical and Quantum Gravity, 2015. **32**(2): p. 024001.
8. Collaboration, L.S., et al., *GW150914: Implications for the Stochastic Gravitational-Wave Background from Binary Black Holes*. Physical Review Letters, 2016. **116**(13): p. 131102.
9. Collaboration, L.S., et al., *Observation of Gravitational Waves from a Binary Black Hole Merger*. Physical Review Letters, 2016. **116**(6): p. 061102.
10. Brown, J.C., *Calculation of a constant Q spectral transform*. The Journal of the Acoustical Society of America, 1991. **89**(1): p. 425-434.
11. Gebhard, T.D., et al., *Convolutional neural networks: A magic bullet for gravitational-wave detection?* Physical Review D, 2019. **100**(6): p. 063015.
12. Glanzer, J., et al., *Data quality up to the third observing run of advanced LIGO: Gravity Spy glitch classifications*. Classical and Quantum Gravity, 2023. **40**(6): p. 065004.

【評語】160003

本作品以機器學習的方法產生重力波事件數據的時間-頻率二維模板，協助未來重力波事件的偵測。目前這是一個熱門的題目，作者展現了良好的研究能力，也對主題背景做了很好的說明。惟對於本作品目前所獲致的結果，應多加說明其獨一性，或與其他類似研究結果做比較。