

# A inteligência artificial sobe ao palco: ondas gravitacionais e aprendizagem automática

José A. Font

Departamento de Astronomía y Astrofísica, Universitat de València  
Observatori Astronòmic, Universitat de València

j.antonio.font@uv.es

*A observação de ondas gravitacionais pela rede de detectores LIGO-Virgo-KAGRA abriu uma nova janela para o estudo do Universo. Propriedades fundamentais de buracos negros e estrelas de neutrões são agora rotineiramente extraídas a partir da análise das ondas gravitacionais emitidas na coalescência e fusão de binários compactos. A aprendizagem automática tem vindo a assumir um papel cada vez mais relevante neste novo domínio, desde estratégias de deteção até à classificação de fontes e inferência astrofísica. Este artigo apresenta uma panorâmica do impacto significativo que a Inteligência Artificial e a Aprendizagem Automática já estão a ter na Astronomia de Ondas Gravitacionais. O nosso foco será o sistema astrofísico das coalescências de binários compactos, a única fonte de ondas gravitacionais detetada até ao momento.*

## 1. Introdução

A primeira deteção direta de ondas gravitacionais (OGs) em 2015 constituiu uma descoberta histórica [1]. Para além de confirmar uma previsão de longa data da teoria da Relatividade Geral de Einstein, marcou também o início da Astronomia de Ondas Gravitacionais (AOG), uma nova forma de estudar o cosmos complementar às observações eletromagnéticas. As OGs fornecem informação sobre o regime de campo forte da gravidade e podem revelar a natureza e as propriedades de objetos compactos astrofísicos, desvendar a essência clássica e quântica dos buracos negros, bem como o interior das estrelas de neutrões através da equação de estado da matéria densa. Desde 2015, foram reportados mais de 90 sinais de OGs pela Colaboração LIGO-Virgo-KAGRA (LVK) [2–5] durante os três primeiros ciclos de observação. No atual quarto ciclo (O4), já foram publicamente reportados mais de 200 candidatos a deteções significativas na Gravitational-Wave Candidate Event Database ([gracedb.ligo.org](http://gracedb.ligo.org)). Embora se trate de um feito notável, fica aquém do que se espera com a próxima geração de detetores de OGs. Espera-se que os novos detetores da próxima geração (nomeadamente o Einstein Telescope (ET) e o Cosmic Explorer (CE)) alcancem taxas de deteção da ordem de 100 000 fusões de buracos negros binários (BNB) por ano [6, 7]. Estas perspetivas permitirão, sem dúvida, avanços significativos na nossa compreensão do Universo. No entanto, a análise dos conjuntos de dados massivos que o ET e o CE irão recolher colocará também um desafio formidável. Os avanços

dependerão fortemente da capacidade de processar de forma eficiente e rápida esses dados, tornando a Inteligência Artificial (IA) e a Aprendizagem Automática (AA) abordagens metodológicas centrais para potenciar resultados. O uso destas técnicas, já hoje considerável e em crescimento contínuo, deverá alastrar a todas as subáreas da AOG — desde a mitigação do ruído dos detetores até à modelação das formas de onda de coalescências de binários compactos (CBCs), desde estratégias de deteção até à classificação de fontes e inferência astrofísica.

Neste artigo, fornecemos uma breve panorâmica do estado atual das abordagens baseadas em IA aplicadas à Astronomia de Ondas Gravitacionais. Existem vários artigos de revisão recentes sobre este tema, e.g. [8–11], aos quais remetemos o leitor interessado para maior aprofundamento. Em particular, o nosso foco será limitado às aplicações de IA em sistemas CBC. Aplicações de técnicas de AA a outras fontes de OG também incluídas no programa científico da colaboração LVK — como eventos transitórios não modelados (e.g., *bursts* ou supernovas de colapso do núcleo), fontes contínuas como estrelas de neutrões em rotação, ou fundos estocásticos de OG — não serão aqui abordadas. Leitores interessados nestes tópicos podem consultar [11] para uma revisão abrangente e atualizada dos esforços em curso com base em IA para esses sistemas. O objetivo deste artigo é demonstrar que a IA já subiu ao palco no domínio da AOG. Talvez ainda não esteja em destaque absoluto, mas pode-se razoavelmente afirmar que a transição da periferia para o centro do palco é apenas uma questão de tempo.

## 2. Impacto da IA na Astronomia de Ondas Gravitacionais

### 2.1. Mitigação de ruído

A sensibilidade de um detetor de ondas gravitacionais (OG) é, em última análise, limitada pelo ruído de fundo presente na sua banda de frequências. Em condições reais, esse ruído não é puramente gaussiano nem estacionário; pelo contrário, varia com o tempo devido a fontes ambientais e instrumentais. Estas variações geram ruído que pode reduzir o tempo útil de operação do detetor (ou *duty cycle*) e a sua sensibilidade em determinadas frequências

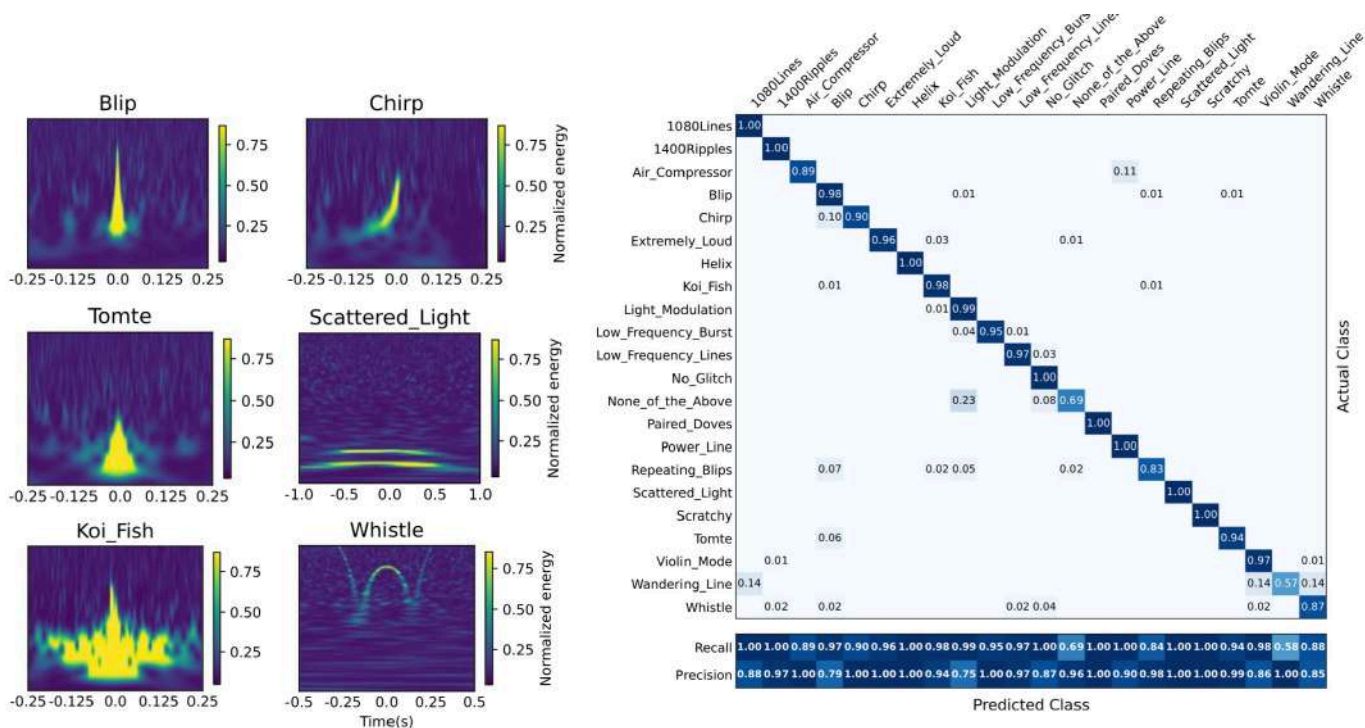


Figura 1 - Esquerda: Exemplos de algumas classes de glitches do conjunto de dados do Gravity Spy. A classe 'blip' é de longe a mais frequente nos detectores LIGO. Direita: Matriz de confusão normalizada com as previsões do modelo treinado de forma auto-supervisionada em [15], destacando os seus resultados notáveis.

ou períodos. Entre estes fenómenos de ruído transitório, destacam-se as perturbações de curta duração conhecidas como *glitches*, que são particularmente relevantes. Os *glitches* podem afetar significativamente o desempenho das buscas por OG, especialmente aquelas que visam sinais transitórios de curta duração e coalescências de CBCs, ao aumentarem a taxa de falsos alarmes nas análises. Assim, a identificação e mitigação de *glitches* é essencial para garantir que os sinais de OG possam ser distinguidos com confiança do ruído, maximizando o retorno científico de cada observação.

Os algoritmos de Aprendizagem Automática (AA) são ferramentas poderosas para identificar padrões em grandes volumes de dados, tornando-os especialmente adequados ao desenvolvimento de estratégias inovadoras para reduzir *glitches* nos detectores de OG. Um exemplo notável é o projeto de ciência cidadã Gravity Spy [12, 13]. Através da participação de voluntários do público, o Gravity Spy permite a classificação de glitches do LIGO, gerando um conjunto de dados rotulado e em constante crescimento que serve como base de treino valiosa para modelos de AA. Uma iniciativa semelhante, GwitchHunters, foi desenvolvida no âmbito da colaboração Virgo [14]. No contexto da mitigação de ruído, um exemplo envolvendo investigadores das Universidades do Minho (Portugal) e de Valência (Espanha) é o trabalho de [15], onde uma arquitetura de Residual Neural Network (ResNet) foi aplicada a imagens públicas do Gravity Spy usando a biblioteca Fastai. Numa variante não supervisionada deste modelo, a rede foi inicialmente pré-treinada com rótulos gerados automaticamente e posteriormente ajustada com os dados do Gravity Spy. Uma ilustração de várias classes de *glitches*, juntamente com uma matriz de confusão típica

obtida com os métodos ResNet de [15], é apresentada na Fig. 1. Salienta-se que estes métodos foram recentemente implementados como um pipeline de baixa latência no detector Virgo. Este classificador, denominado VIGILant, permite a classificação em tempo real de glitches do ciclo de observação O4 diretamente no fluxo de dados do detector.

## 2.2 Geração de formas de onda

Todos os sinais de OG reportados até à data pela Colaboração LVK são compatíveis com terem sido gerados em sistemas de CBC, incluindo as três classes de fusões: BNBs, de longe a mais frequente; estrelas de neutrões binárias (ENB); e sistemas mistos buraco negro–estrela de neutrões. Os sinais de CBC consistem em três fases: espiralamento (*inspiral*), fusão (*merger*) e relaxamento final (*ringdown*). Durante o espiralamento, o sinal apresenta um *chirp* (aumento simultâneo da frequência e da amplitude) ao longo da banda de sensibilidade do detector. Trata-se de um sinal universal para todos os sistemas binários coalescentes com órbitas quase circulares. Ou seja, pode ser modelado, quer através de métodos analíticos quer numéricos, o que facilita enormemente as estratégias de deteção. A ideia base é simples e designa-se por *matched filtering*. Essencialmente, a busca de OG com este tipo de sinal visa maximizar uma função de verosimilhança com base numa métrica de semelhança entre os dados recolhidos pelo detector e formas de onda simuladas (ou *templates*). Esta métrica atinge o máximo quando a forma de onda observada coincide com uma template existente.

Apesar da simplicidade conceptual, o problema prático reside na incompletude (e escassez) das bases de dados de formas de onda. Gerar formas de onda é dispendioso,

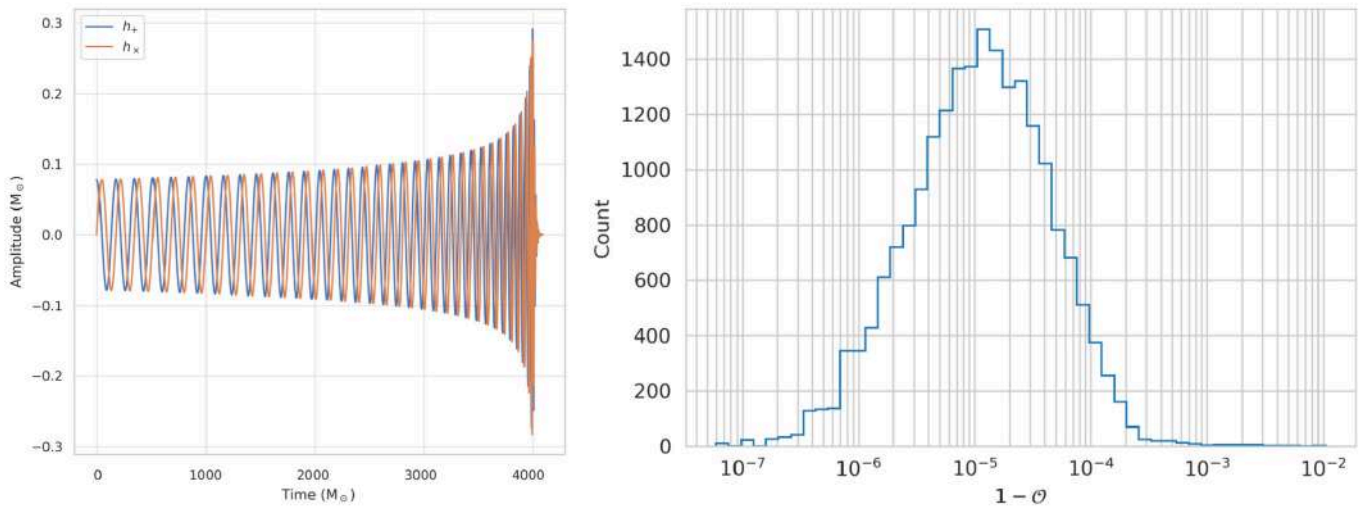


Figura 2 - Esquerda: Exemplo de forma de onda de BNBs gerada com o *approximant* NRSurNN3dq4 de [18], na representação com duas polarizações. Direita: Distribuição dos erros de validação do modelo treinado com dados de *approximants*. Ver [18] para a definição da métrica de erro (*mismatch*).

e esta é uma área onde a IA já está a ajudar. A principal dificuldade prende-se com a complexidade intrínseca de resolver as equações do movimento que descrevem o problema binário na Relatividade Geral, seja por métodos analíticos ou numéricos. As abordagens analíticas deixam de ser válidas quando os efeitos de maré dominam a dinâmica perto da fusão, sendo a única forma de obter formas de onda o recurso à Relatividade Numérica (RN), ou seja, à resolução das equações de Einstein em supercomputadores. Embora a RN tenha tido bastante sucesso, enfrenta limitações severas quando aplicada a sistemas CBC genéricos que envolvem razões de massa muito diferentes, rotações desalinhadas ou órbitas não circulares (excêntricas). Mesmo as situações mais simples requerem recursos computacionais avultados, o que limita as bases de dados de templates disponíveis a cerca de  $O(10^9)$  formas de onda para sistemas BNBs (e aproximadamente dez vezes menos para sistemas ENB). As deteções de BNBs pela LVK utilizam tipicamente entre  $O(10^6 - 10^7)$  formas de onda, sendo a maioria gerada através de *approximants*, rotinas computacionais que produzem aproximações rápidas da forma de onda esperada a partir de determinados parâmetros físicos. Estas aproximações são frequentemente calibradas com base em catálogos de formas de onda provenientes da RN, e têm permitido a análise de todos os sinais de CBC detetados até ao momento.

Um componente central no desenvolvimento de *approximants* de formas de onda envolve o uso de técnicas de regressão, que incluem métodos tradicionais de interpolação e ajustamento, como os mínimos quadrados, bem como abordagens mais modernas baseadas em AA, como processos gaussianos e redes neuronais. Entre estas técnicas modernas, destaca-se a família de modelos de formas de onda NRSurrogate [16]. Estes modelos utilizam diversas estratégias orientadas por dados para construir uma base reduzida, permitindo-lhes interpolar formas de onda inicialmente calculadas em pontos específicos do espaço de parâmetros, de modo a avaliá-las com pre-

cisão em quaisquer outros pontos dentro do domínio.

Por exemplo, no contexto da modelação de formas de onda, a regressão por processos gaussianos foi usada para construir modelos *surrogate* de formas de onda para sistemas BNBs com e sem precessão, em pontos do espaço de parâmetros não cobertos pela relatividade numérica [17]. Outro exemplo recente surge em [18], onde os autores propõem um modelo *surrogate* baseado em redes neuronais, concebido para gerar rapidamente e com precisão formas de onda não precessantes de BNBs, com erros da ordem de  $10^{-5}$  quando aplicadas a dados de *approximants* (ver Fig. 2) e da ordem de  $5 \times 10^{-3}$  quando aplicadas a dados da RN (devido, neste último caso, à escassez de dados numéricos disponíveis para treino da rede). Testes de desempenho demonstram que o modelo é capaz de gerar mais de um milhão de formas de onda em menos de um décimo de segundo quando implementado numa GPU.

Estudos recentes exploraram o potencial das redes neuronais para acelerar ainda mais o desempenho dos modelos *surrogate* de formas de onda. Por exemplo, [19] implementaram uma rede neuronal com quatro camadas para determinar os coeficientes de interpolação no esquema parametrizado originalmente introduzido por [20]. De forma semelhante, [21] basearam-se na mesma abordagem *surrogate*, mas utilizando autoencoders. O seu trabalho revelou um padrão em “espiral” no espaço latente, que reflete a forma como os coeficientes de ajustamento variam com a razão de massas — uma observação que os autores aproveitaram, tirando partido da capacidade do autoencoder em aprender transformações diferenciáveis entre os parâmetros de entrada e de saída. Isso permitiu uma regressão mais rápida e precisa dos coeficientes. Uma visão geral destes avanços pode ser encontrada em [10].

### 2.3 Detecção de sinais

Muito provavelmente, a área mais popular da investigação

em AA aplicada à AOG tem sido a detecção de CBCs, impulsionada em parte pela aceleração recente da tecnologia de AA através do uso de GPUs. Na maioria das abordagens, a tarefa de detecção do sinal é formulada como um problema de classificação: redes neuronais são treinadas por aprendizagem supervisionada para distinguir entre duas categorias principais de dados — segmentos contendo apenas ruído do detetor e segmentos contendo simultaneamente ruído e um sinal de CBC.

As redes neuronais convolucionais foram utilizadas em estudos pioneiros como os de [22, 23] para procurar sinais de BNBs, atingindo uma sensibilidade comparável à da técnica de *matched filtering*. Estes modelos usaram arquiteturas relativamente simples, mas eficazes: no estudo de [23], por exemplo, os autores utilizaram uma rede neuronal convolucional profunda composta por duas camadas convolucionais seguidas de duas camadas totalmente conectadas. No entanto, a necessidade de treinar redes distintas para diferentes razões sinal-ruído limitou a aplicabilidade prática desses estudos, uma vez que a intensidade de um novo sinal não é conhecida à partida, exigindo a avaliação separada de cada rede. Apesar destas limitações iniciais, estes trabalhos lançaram as bases dos *pipelines* modernos de detecção de sinais com AA atualmente em desenvolvimento.

Em 2021, foi lançado o primeiro desafio com dados simulados para detecção de sinais CBC com recurso a AA, através da plataforma Kaggle, seguido de um desafio mais realista dirigido à comunidade de OG. Este último, detalhado em [24], incluiu quatro conjuntos de dados com dificuldade crescente. A principal métrica de desempenho foi a distância sensível (*sensitive distance*). A distância sensível reflete até que ponto um método é capaz de detetar sinais. No caso mais difícil, o método tradicional PyCBC, utilizado pela Colaboração LVK, superou as abordagens de AA em todas as taxas de falsos alarmes. No entanto, em cenários mais simples e sem ruído, com dados de entrada de apenas 1 segundo, os modelos de aprendizagem profunda atingiram até 95 % do desempenho do PyCBC.

Destacamos ainda o código de fonte aberta AresGW [25, 26], que recentemente conseguiu identificar novos candidatos a eventos de OG nos dados da LVK — os primeiros a serem identificados através de métodos de AA. As melhorias introduzidas na versão mais recente do AresGW resultaram numa redução significativa da taxa de falsos alarmes, superando *pipelines* tradicionais baseados em *matched filtering* no número de eventos detetados dentro do seu intervalo de treino eficaz.

A principal vantagem das abordagens de AA nas buscas por OG de CBC reside na possibilidade de transferir grande parte da carga computacional para a fase de treino, permitindo uma detecção rápida e em tempo real. De facto, em [24], os modelos de AA funcionaram mais rapidamente do que em tempo real com apenas 16 núcleos de CPU,

superando o PyCBC. Esta velocidade é particularmente útil para a detecção de sinais durante a fase de espiralamento (antes da fusão), o que é crucial para a Astronomia Multimessageira. No entanto, a detecção precoce continua a ser um desafio em sinais de longa duração, como os provenientes de fusões BNS (ver discussão em [11]).

## 2.4 Classificação de fontes e inferência

A detecção de um sinal de OG é sempre seguida pela caracterização da fonte astrofísica que o gerou — ou seja, a sua classificação e a inferência das suas propriedades. Neste contexto, os métodos baseados em IA estão também a ganhar um papel cada vez mais relevante. Durante os dois primeiros ciclos de observação da LVK, a classificação de fontes em baixa latência baseava-se no formalismo de Fisher efetivo. Em ciclos mais recentes, foram introduzidos métodos de AA, oferecendo melhorias significativas em termos de velocidade. O atual pipeline de baixa latência da LVK para CBCs [27] utiliza dois algoritmos de aprendizagem supervisionada: um modelo *k*-nearest neighbor para identificar componentes de estrelas de neutrões e a possível existência de um remanescente pós-fusão; e um modelo de Random Forest para detetar objetos dentro da chamada “lacuna de massa inferior” — o intervalo de massas entre as estrelas de neutrões mais massivas e os buracos negros mais leves.

Os métodos baseados em simulação para cálculo de distribuições posteriores, como os métodos de Markov-chain Monte Carlo (MCMC), continuam a ser as técnicas principais para a inferência de parâmetros. A estimativa dos parâmetros dos sinais observados pela Colaboração LVK baseia-se frequentemente em inferência bayesiana [28]. Infelizmente, este tipo de inferência pode ser computacionalmente dispendioso, dado que a avaliação da função de verosimilhança para um conjunto alargado de parâmetros da fonte, usando técnicas estocásticas de amostragem [29], pode exigir a geração de milhões de formas de onda. Como tal, a inferência pode demorar dias até produzir um número suficiente de amostras da distribuição posterior para uma fusão de BNBs.

De facto, a amostragem estocástica enfrenta dois obstáculos principais: por um lado, a avaliação da verosimilhança para sinais CBC é intensiva em termos computacionais; por outro, a geração de novas amostras a partir de um prior condicionado exige frequentemente percursos aleatórios (*random walks*), que podem implicar milhares de passos — cada um exigindo uma nova avaliação da verosimilhança. O custo computacional torna-se ainda mais elevado no caso de fusões ENB, em que as análises podem demorar cerca de um mês. Isto deve-se sobretudo à menor disponibilidade de *templates* para as fases de fusão e pós-fusão de BNS, o que obriga ao recurso a simulações numéricas. Métodos para acelerar a convergência dos algoritmos MCMC serão particularmente importantes à medida que o número de detecções aumentar com os detetores da terceira geração.

A incorporação da AA no processo de amostragem tem demonstrado permitir acelerações significativas [31, 32]. Uma abordagem eficaz utiliza *normalizing flows*, um tipo de modelo generativo que aprende a distribuição das amostras dentro do prior condicionado pela verosimilhança, permitindo uma amostragem mais rápida e eficiente a partir dessa distribuição aprendida. Outra forma de acelerar o processo consiste em otimizar a própria computação da verosimilhança, quer treinando modelos que a aproximem, quer acelerando a geração das formas de onda CBC. A aplicação mais avançada da AA à estimativa bayesiana de parâmetros envolve atualmente a inferência posterior com redes neuronais [33, 34]. Um desses *pipelines*, o dingo, demonstrou excelente concordância com análises de referência quando aplicado a detecções reais do LIGO–Virgo. O dingo combina elevada precisão com eficiência, reduzindo o tempo necessário para a inferência de parâmetros de vários dias para apenas 20 segundos por evento, no caso de fusões BNBs. De forma semelhante, autoencoders variacionais condicionais, como os utilizados no pipeline Vitamin de [30], demonstraram um desempenho extremamente rápido, permitindo estimar distribuições posteriores completas de sinais de fusões BNBs cerca de 6 ordens de grandeza mais rapidamente do que as abordagens bayesianas.

Um exemplo da precisão desta abordagem na inferência de fontes encontra-se ilustrado na Fig. 3, que mostra as curvas de probabilidade–probabilidade para todos os parâmetros BNBs, comparando diversos amostradores do *pipeline* Bilby da LVK com o modelo baseado em AA Vitamin descrito em [30].

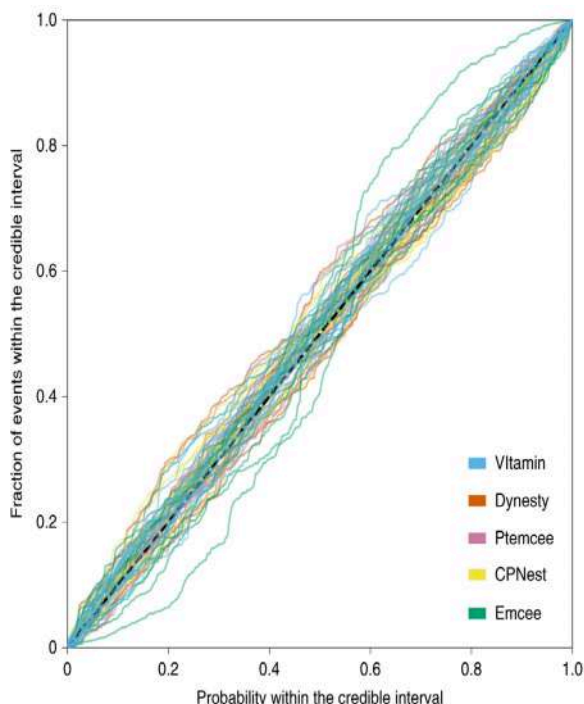


Figura 3 - Curvas de probabilidade–probabilidade para cada um dos 15 parâmetros de BNBs de uma binária quase circular, e para cada amostrador de referência do Bilby e do modelo baseado em AA Vitamin. A semelhança entre as funções de distribuição cumulativa do conjunto de dados e de cada um dos modelos (bayesiano ou baseado em AA) é evidenciada pela proximidade a uma linha reta. Figura adaptada de [30].

### 3. Conclusão

A detecção de ondas gravitacionais pela rede de detetores da Colaboração LVK abriu uma nova janela para o estudo do Universo e tem tido um impacto profundo na nossa compreensão dos objetos compactos de origem estelar. A Física Computacional e a Análise de Dados desempenharam papéis cruciais nestas detecções e na inferência das propriedades das fontes. Propriedades-chave de buracos negros e estrelas de neutrões são hoje rotineiramente extraídas a partir da análise das OG que estes emitem. Contudo, os desafios que se avizinham são substanciais. Apesar dos notáveis progressos já alcançados na modelação de fontes CBC com recurso à relatividade numérica, será necessário desenvolver novas ideias para produzir templates precisos de formas de onda com milhares de órbitas (ou mais), abrangidas pela banda de sensibilidade dos detetores da terceira geração. De igual modo, novas abordagens computacionais e de análise de dados serão certamente requeridas num futuro próximo para lidar com a vasta quantidade de dados que será recolhida quando esses detetores entrarem em funcionamento, nomeadamente no que diz respeito à inferência astrofísica.

Neste contexto entusiasmante, a Inteligência Artificial e a Aprendizagem Automática poderão desempenhar um papel determinante no desenvolvimento do novo campo da Astronomia de Ondas Gravitacionais, desde a modelação das formas de onda de CBCs até à detecção e inferência astrofísica. Como se procurou demonstrar nesta panorâmica, a IA já está a assumir um papel central e a impactar todas as subáreas da AOG. E não só isso: é bem possível que esteja a caminhar para ocupar um lugar de destaque no seu epicentro. O tempo o dirá.

### Agradecimentos

Expresso a minha sincera gratidão aos organizadores desta edição especial, em particular a Carlos Herdeiro, pelo amável convite para contribuir. Este trabalho é financiado pela Agencia Estatal de Investigación española (PID2021-125485NB-C21), através da MCIN/AEI/10.13039/501100011033 e do FEDER “Uma maneira de fazer Europa”; pela Generalitat Valenciana (bolsa CIPROM/2022/49); e pelo programa europeu de intercâmbio de pessoal Horizon Europe. HORIZON-MSCA-2021-SE-01 (NewFunFICO-101086251).

## Referências

- [1] B. P. Abbott et al. Observation of gravitational waves from a binary black hole merger. *Physical Review Letters*, 116:061102, Feb 2016.
- [2] B. P. Abbott et al. GWTC-1: A gravitational-wave transient catalog of compact binary mergers observed by LIGO and Virgo during the first and second observing runs. *Physical Review X*, 9(3), September 2019.
- [3] R. Abbott et al. GWTC-2: Compact Binary Coalescences Observed by LIGO and Virgo During the First Half of the Third Observing Run. *Phys. Rev. X*, 11:021053, 2021.
- [4] R. Abbott et al. GWTC-2.1: Deep Extended Catalog of Compact Binary Coalescences Observed by LIGO and Virgo During the First Half of the Third Observing Run. 8 2021.
- [5] R. Abbott et al. GWTC-3: Compact Binary Coalescences Observed by LIGO and Virgo During the Second Part of the Third Observing Run. arXiv e-prints, page arXiv:2111.03606, November 2021.
- [6] Marica Branchesi, Michele Maggiore, David Alonso, Charles Badger, Biswajit Banerjee, Freija Beirnaert, Enis Belgacem, Swetha Bhagwat, Guillaume Boileau, Sohrah Borhanian, Daniel David Brown, Man Leong Chan, Giulia Cusin, Stefan L. Danilishin, Jerome Degallaix, Valerio De Luca, Arnab Dhani, Tim Dietrich, Ulyana Dupletska, Stefano Foffa, Gabriele Franciolini, Andreas Freise, Gianluca Gemme, Boris Goncharov, Archisman Ghosh, Francesca Gulminelli, Ish Gupta, Pawan Kumar Gupta, Jan Harms, Nandini Hazra, Stefan Hild, Tanja Hinderer, Ik Siang Heng, Francesco Iacovelli, Justin Janquart, Kamiel Janssens, Alexander C. Jenkins, Chinmay Kalaghatgi, Xhesika Korovesii, Tjonnje G.F. Li, Yufeng Li, Eleonora Loffredo, Elisa Maggio, Michele Mancarella, Michela Mapelli, Katarina Martinovic, Andrea Maselli, Patrick Meyers, Andrew L. Miller, Chiranjib Mondal, Niccolò Muttoni, Harsh Narola, Micaela Oertel, Gor Oganeyan, Costantino Pacilio, Cristiano Palomba, Paolo Pani, Antonio Pasqualetti, Albino Perego, Carole Pèrigois, Mauro Pieroni, Ornella Juliana Piccinni, Anna Puecher, Paola Puppo, Angelo Ricciardone, Antonio Riotto, Samuele Ronchini, Mairi Sakellariadou, Anuradha Samajdar, Filippo Santoliquido, B.S. Sathyaprakash, Jessica Steinlechner, Sebastian Steinlechner, Andrei Utina, Chris Van Den Broeck, and Teng Zhang. Science with the Einstein telescope: a comparison of different designs. *Journal of Cosmology and Astroparticle Physics*, 2023(07):068, July 2023.
- [7] Evan D. Hall. Cosmic explorer: A next-generation ground-based gravitational-wave observatory. *Galaxies*, 10(4), 2022.
- [8] Elena Cuoco et al. Enhancing Gravitational-Wave Science with Machine Learning. *Mach. Learn. Sci. Tech.*, 2(1):011002, 2021.
- [9] V. Benedetto, F. Gissi, G. Ciaparrone, and L. Troiano. Applications of machine learning to gravitational wave detection. *Applied Sciences*, 13:9886, 2023.
- [10] N. Stergioulas. Artificial intelligence and machine learning in gravitational wave astronomy: A review. arXiv preprint, 2024.
- [11] Elena Cuoco, Marco Cavaglia, Ik Siang Heng, David Keitel, and Christopher Messenger. Applications of machine learning in gravitational-wave research with current interferometric detectors... *Living Reviews in Relativity*, 28(1):2, February 2025.
- [12] M. Zevin, S. Coughlin, S. Bahaadini, E. Besler, N. Rohani, S. Allen, M. Cabero, K. Crowston, A. K. Katsaggelos, S. L. Larson, T. K. Lee, C. Lintott, T. B. Littenberg, A. Lundgren, C. Österlund, J. R. Smith, L. Trouille, and V. Kalogera. Gravity Spy: integrating advanced LIGO detector characterization, machine learning, and citizen science. *Classical and Quantum Gravity*, 34(6):064003, March 2017.
- [13] Michael Zevin, Corey B. Jackson, Zoheyr Doctor, Yunan Wu, Carsten Österlund, L. Clifton Johnson, Christopher P. L. Berry, Kevin Crowston, Scott B. Coughlin, Vicky Kalogera, Sharan Banagiri, Derek Davis, Jane Glanzer, Renzhi Hao, Angelos K. Katsaggelos, Oli Patane, Jennifer Sanchez, Joshua Smith, Siddharth Soni, Laura Trouille, Marissa Walker, Irina Aerith, Wilfried Domainko, Victor-Georges Baranowski, Gerhard Niklasch, and Barbara Tégllás. Gravity Spy: lessons learned and a path forward. *European Physical Journal Plus*, 139(1):100, January 2024.
- [14] Massimiliano Razzano, Francesco Di Renzo, Francesco Fidecaro, Gary Hemming, and Stavros Katsanevas. GWitchHunters: Machine learning and citizen science to improve the performance of gravitational wave detector. *Nuclear Instruments and Methods in Physics Research A*, 1048:167959, March 2023.
- [15] Tiago Fernandes, Samuel Vieira, Antonio Onofre, Juan Calderón Bustillo, Alejandro Torres-Forné, and José A. Font. Convolutional neural networks for the classification of glitches in gravitational-wave data streams. *Classical and Quantum Gravity*, 40(19):195018, October 2023.
- [16] Vijay Varma, Scott E. Field, Mark A. Scheel, Jonathan Blackman, Davide Gerosa, Leo C. Stein, Lawrence E. Kidder, and Harald P. Pfeiffer. Surrogate models for precessing binary black hole simulations with unequal masses. *Phys. Rev. Res.*, 1:033015, Oct 2019.
- [17] D. Williams, I. S. Heng, J. A. Gair, J. A. Clark, and B. Khamesra. Precessing numerical relativity waveform surrogate model for binary black holes: A Gaussian process regression approach. *Phys. Rev. D*, 101(6):063011, March 2020.
- [18] Osvaldo Gramaxo Freitas, Anastasios Theodoropoulos, Nino Villanueva, Tiago Fernandes, Solange Nunes, José A. Font, Antonio Onofre, Alejandro Torres-Forné, and José D. Martín-Guerrero. NRSurNN3dq4: A Deep Learning Powered Numerical Relativity Surrogate for Binary Black Hole Waveforms. arXiv e-prints, page arXiv:2412.06946, December 2024.
- [19] Styliani-Christina Fragkouli, Paraskevi Nousi, Nikolaos Passalis, Panagiotis Iosif, Nikolaos Stergioulas, and Anastasios Tefas. Deep residual error and bag-of-tricks learning for gravitational wave surrogate modeling. *Applied Soft Computing*, 147:110746, 2023.
- [20] Scott E. Field, Chad R. Gallely, Jan S. Hesthaven, Jason Kaye, and Manuel Tiglio. Fast Prediction and Evaluation of Gravitational Waveforms Using Surrogate Models. *Physical Review X*, 4(3):031006, July 2014.
- [21] Paraskevi Nousi, Styliani-Christina Fragkouli, Nikolaos Passalis, Panagiotis Iosif, Theocharis Apostolatos, George Pappas, Nikolaos Stergioulas, and Anastasios Tefas. Autoencoder-driven Spiral Representation Learning for Gravitational Wave Surrogate Modelling. *Neurocomputing*, 491:67–77, June 2022.
- [22] Hunter Gabbard, Michael Williams, Fergus Hayes, and Chris Messenger. Matching matched filtering with deep networks for gravitational-wave astronomy. *Phys. Rev. Lett.*, 120(14):141103, 2018.
- [23] D. George and E. Huerta. Deep learning for real-time gravitational wave detection and parameter estimation: Results with advanced LIGO data. *Physics Letters B*, 778:64–70, 2018.
- [24] Marlin B. Schäfer, Ondřej Zelenka, Alexander H. Nitz, He Wang, Shichao Wu, Zong-Kuan Guo, Zhoujian Cao, Zhixiang Ren, Paraskevi Nousi, Nikolaos Stergioulas, Panagiotis Iosif, Alexandra E. Koloniari, Anastasios Tefas, Nikolaos Passalis, Francesco Salemi, Gabriele Vedovato, Sergey Klimenko, Tanmaya Mishra, Bernd Brügmann, Elena Cuoco, E. A. Huerta, Chris Messenger, and Frank Ohme. First machine learning gravitational-wave search mock data challenge. *Physical Review D*, 107(2):023021, January 2023.
- [25] Paraskevi Nousi, Alexandra E. Koloniari, Nikolaos Passalis, Panagiotis Iosif, Nikolaos Stergioulas, and Anastasios Tefas. Deep residual networks for gravitational wave detection. *Physical Review D*, 108(2):024022, July 2023.

- [26] Alexandra E. Koloniari, Evdokia C. Koursoumpa, Paraskevi Nousi, Paraskevas Lampropoulos, Nikolaos Passalis, Anastasios Tefas, and Nikolaos Stergioulas. New gravitational wave discoveries enabled by machine learning. *Machine Learning: Science and Technology*, 6(1):015054, March 2025.
- [27] Sushant Sharma Choudhary, Andrew Toivonen, Gaurav Waratkar, Geoffrey Mo, Deep Chatterjee, Sarah Antier, Patrick Brockhill, Michael W. Coughlin, Reed Essick, Shaon Ghosh, Soichiro Morisaki, Pratyusava Baral, Amanda Baylor, Naresh Adhikari, Patrick Brady, Gareth Cabourn Davies, Tito Dal Canton, Marco Cavaglia, Jolien Creighton, Sunil Choudhary, Yu-Kuang Chu, Patrick Clearwater, Luke Davis, Thomas Dent, Marco Drago, Becca Ewing, Patrick Godwin, Weichangfeng Guo, Chad Hanna, Rachael Huxford, Ian Harry, Erik Katsavouridis, Manoj Kovalam, Alvin K. Y. Li, Ryan Magee, Ethan Marx, Duncan Meacher, Cody Messick, Xan Morice-Atkinson, Alexander Pace, Roberto De Pietri, Brandon Piotrkowski, Soumen Roy, Surabhi Sachdev, Leo P. Singer, Divya Singh, Marek Szczepanczyk, Daniel Tang, Max Trevor, Leo Tsukada, Verónica Villa-Ortega, Linqing Wen, and Daniel Wysocki. Low-latency gravitational wave alert products and their performance at the time of the fourth LIGO-Virgo-KAGRA observing run. *Proceedings of the National Academy of Science*, 121(18):e2316474121, April 2024.
- [28] Benjamin P Abbott et al. A guide to LIGO-Virgo detector noise and extraction of transient gravitational-wave signals. *Class. Quant. Grav.*, 37(5):055002, 2020.
- [29] Gregory Ashton et al. BILBY: A user-friendly Bayesian inference library for gravitational-wave astronomy. *Astrophys. J. Suppl.*, 241(2):27, 2019.
- [30] Hunter Gabbard, Chris Messenger, Ik Siang Heng, Francesco Tonolini, and Roderick Murray-Smith. Bayesian parameter estimation using conditional variational autoencoders for gravitational-wave astronomy. *Nature Physics*, 18(1):112–117, January 2022.
- [31] Michael J. Williams, John Veitch, and Chris Messenger. Nested sampling with normalizing flows for gravitational-wave inference. *Physical Review D*, 103(10):103006, May 2021.
- [32] Michael J. Williams, John Veitch, and Chris Messenger. Importance nested sampling with normalising flows. *Machine Learning: Science and Technology*, 4(3):035011, September 2023.
- [33] Stephen R. Green, Christine Simpson, and Jonathan Gair. Gravitational-wave parameter estimation with autoregressive neural network flows. *Phys. Rev. D*, 102(10):104057, November 2020.
- [34] Maximilian Dax, Stephen R. Green, Jonathan Gair, Jakob H. Macke, Alessandra Buonanno, and Bernhard Schölkopf. Real-time gravitational wave science with neural posterior estimation. *Physical Review Letters*, 127(24), December 2021.



José Antonio Font é Professor Catedrático de Astronomia e Astrofísica na Universidade de Valência, em Espanha. Obteve o seu doutoramento em Física pela Universidade de Valência em 1994 e, posteriormente, realizou investigação pós-doutoral no Instituto Albert Einstein em Potsdam, Alemanha, e no Instituto Max Planck de Astrofísica em Garching, Alemanha. Com vasta experiência em aplicações de supercomputação para astrofísica relativista, o Prof. Font é especialista em hidrodinâmica relativista numérica e relatividade numérica. É um dos principais especialistas em modelação numérica de fontes astrofísicas de ondas gravitacionais e é coautor de cerca de 300 artigos em revistas internacionais de elevado impacto. O Prof. Font é membro da Colaboração Virgo, onde coordena as atividades do Grupo Virgo de Valência. Está também ativo em várias organizações profissionais, incluindo a Real Sociedade Espanhola de Física, a Sociedade Espanhola de Astronomia e a Divisão de Física da Sociedade Europeia de Física. Entre 2009 e 2013, foi presidente da Sociedade Espanhola de Relatividade Geral e Gravitacão.