


Inteligência Artificial, Machine Learning, Deep Learning e as Ondas Gravitacionais detectadas pelo LIGO




Tábata Aira Ferreira

Orientador: Dr. César Augusto Costa

8 de maio de 2018 - Workshop DIDAS







- Definição de transiente;
- OMICRON e atributos aos transientes;
- Glitches e canais auxiliares;
- A representação no espaço $\Delta t, \Delta f$ e energia normalizada (espectrograma);

Exemplos de Glitches

Whistle: causa conhecida



Blip: causa desconhecida



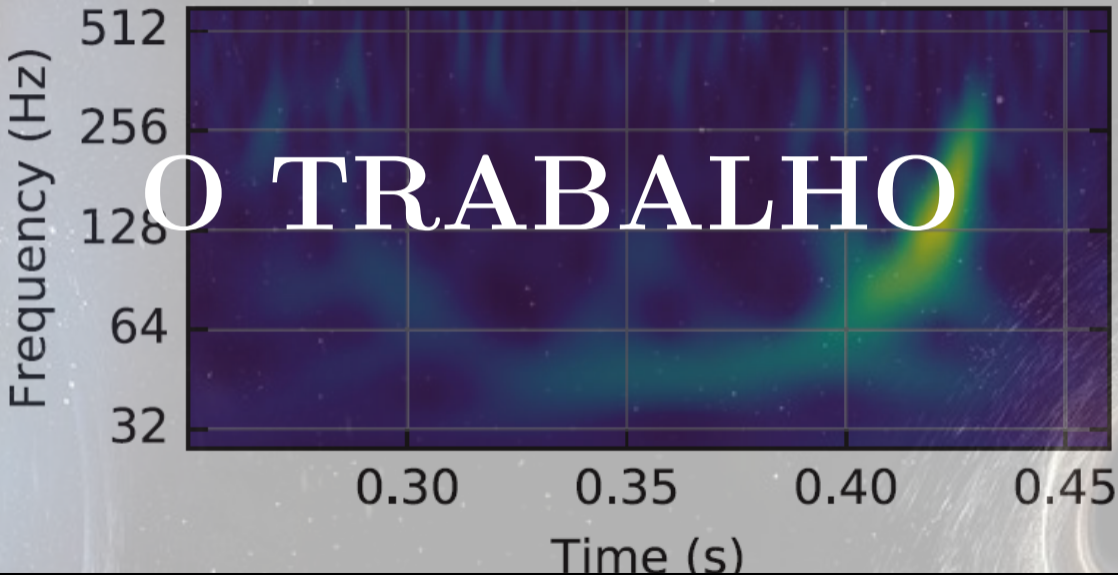
Tal representação permitiu verificar que, mesmo de forma independente, alguns ruídos acontecem com aparências semelhantes! O GS classifica e coloca uma legenda com o nome do ruído na tabela do OMICRON.

Tabela 1: Alguns glitches classificados durante a primeira corrida do aLIGO.

Grupo de ruído	Total	Livingston	Hanford
Blip	1869 (24.2%)	374 (12.7%)	1495 (31.4%)
Extremely loud	453 (5.9%)	187 (6.3%)	266 (5.6%)
Helix	279 (3.6%)	276 (9.4%)	3 (0.1%)
Koi Fish	829 (10.7%)	250 (8.5%)	579 (12.1%)
Light Modulation	573 (7.4%)	5 (0.2%)	568 (11.9%)
Low frequency line	452 (5.9%)	371 (12.6%)	81 (1.7%)
None of the above	189 (2.4%)	36 (1.2%)	153 (3.2%)
Power line	54 (0.7%)	0 (0.0%)	54 (1.1%)
Repeating blips	454 (5.9%)	180 (12.6%)	274 (1.7%)
Scattered light	453 (5.9%)	59 (2.0%)	394 (8.3%)
Violin mode harmonic	178 (2.3%)	0 (0.0%)	178 (3.7%)
Whistle	305 (4.0%)	303 (10.3%)	2 (0.0%)

Problemas envolvidos

- Os transientes precisam de uma avaliação humana para serem classificados;
- Mesmo sabendo que algumas classes de *glitches* acontecem nos dois observatórios (em tempos aleatórios), a grande dificuldade está em encontrar suas causas, suas origens;
- A classificação do GS acontece no canal gravitacional e trabalhos feitos até o momento relacionam até dois canais auxiliares de um mesmo sistema;






Objetivos

- Desenvolver uma metodologia capaz de classificar transientes tanto no canal gravitacional quanto nos canais auxiliares;
- Aplicar o método tentando relacionar determinado grupo de transiente não só a um sistema, mas também diferentes subsistemas;
- Automatizar o processo de classificação de transientes;

Teste de combinações de parâmetros

$$w = \sqrt{\left(\frac{2(bw)}{(DI)(SNR)^2}\right)^2 + \left(\frac{2}{(DB)(bw)(SNR)^2}\right)^2} \quad (1)$$






Machine Learning


Busca por padrões nos dados e apresenta previsões para determinadas situações.

t-SNE (t-distributed stochastic neighbor embedding)
Reduz a quantidade de variáveis em variáveis principais e agrupa pontos de dados semelhantes.

Pacote adaptado: *scikit-learn*, desenvolvido em Python.


- Seleccionamos o tempo em que o GS encontrou um *glitch*;
- Recriamos através desse tempo (em ± 2 s) o ruído em tempo, frequência e SNR;
- Dividimos essa recriação em 1200 caixas;
- Criamos o *Glitchgrama*






Foram construídos *glitchgramas* para quatro grupos: Blip, Koifish, Whistle e Power Line. Cada glitchgrama foi transformado numa matriz de dados 30×40 que serviu de entrada no algoritmo t-SNE que buscou por padrões nos dados e fez a classificação.


Trabalho - Resultado da aplicação do t-SNE utilizando *glitchgramas*



Trabalho - O algoritmo num canal auxiliar aleatório



Trabalho - O Diagrama de cordas



Considerações Finais e perspectivas

- O algoritmo t-SNE apresentou um resultado satisfatório para classificação de transientes nos detectores LIGO quando utilizou matrizes de dados da reconstrução morfológica do transiente;
- Um próximo passo será aplicar a metodologia para mais classes de transientes e definir regiões de probabilidades;
- Rodar o algoritmo em diferentes canais auxiliares (tanto de sistema e subsistemas) para descobrir quais são atingidos pelos ruídos, utilizando o auxílio de diagramas de corda;
- Organizar temporalmente os canais envolvidos com o transiente e encontrar o caminho que determinado grupo de ruído percorre até chegar ao canal gravitacional, isto é, encontrar sua origem

Considerações Finais e perspectivas

- Criar redes de conexões interligando *glitches*, causas, canais e possíveis consequências;
- Estudar possíveis aplicações da técnica de Deep Learning;
- Aplicar o Aprendizado de Máquina para ensinar o computador a fazer previsões de forma que, ao receber um sinal aleatório, a máquina saberá dizer a qual classe de ruído o sinal deve pertencer;
- Uma consequência do trabalho será diminuição da incidência de concordância entre os detectores que gera a curva que limita a detecção para uma determinada significância estatística;

Considerações Finais e perspectivas

- Uma vez conhecida a origem de uma classe de transientes, poderemos encontrar sua causa, descobrir se ela é proveniente de algum defeito instrumental e sugerir reparos ou trocas. Isso aumentará a confiabilidade dos dados que, consequentemente, possibilitará a confirmação de eventos menos energéticos no Universo.
- Para que seja melhor usufruído, o algoritmo está sendo implantado no ambiente *LAL* do LIGO de forma que, outros membros internos possam usá-lo.

Com a continuação desse projeto, colaboraremos com esse excitante período da Ciência contemporânea, onde a Astronomia de Ondas Gravitacionais se desenvolve e novos conhecimentos sobre o Universo começam a ser explorados.

A vintage-style robot with a red head and a blue body is sitting on a stack of colorful books. The robot is holding a blue book in its right hand. The background is a light blue gradient with a subtle pattern of white dots and a faint circular light effect on the right side. The word "OBRIGADA!" is written in large, white, serif capital letters across the center of the image.

OBRIGADA!