



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
PROGRAMA DE PÓS GRADUAÇÃO EM FÍSICA  
UNIDADE ACADÊMICA DE FÍSICA

Ana Rafaely Medeiros de Oliveira

# **Uso de redes neurais para busca de Transientes de rádio com o telescópio BINGO**

Campina Grande, Paraíba, Brasil

28 de fevereiro de 2024

Ana Rafaely Medeiros de Oliveira

**Uso de redes neurais para busca de Transientes de rádio  
com o telescópio BINGO.**

Dissertação realizada sob orientação do Prof. Dr. Amílcar Queiroz, apresentada à Unidade Acadêmica de Física em complementação aos requisitos para obtenção do título de Mestre em Física.

Orientador: Professor Dr. Amílcar Queiroz

Campina Grande, Paraíba, Brasil

28 de fevereiro de 2024

O48u

Oliveira, Ana Rafaely Medeiros de.

Uso de redes neurais para busca de transientes de rádio com o telescópio BINGO / Ana Rafaely Medeiros de Oliveira. – Campina Grande, 2024.

72 f.

Dissertação (Mestrado em Física) – Universidade Federal de Campina Grande, Centro de Ciências e Tecnologia, 2024.

"Orientação: Prof. Dr. Amílcar de Rabelo Queiroz".

Referências.

1. Cosmologia. 2. Radioastronomia. 3. Telescópio BINGO. 4. Fast Radio Burst (FRBs). 5. Neural Network. 6. Física. I. Queiroz, Amílcar de Rabelo. II. Título.

CDU 523.11(043)



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
POS-GRADUACAO EM FISICA  
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

## FOLHA DE ASSINATURA PARA TESES E DISSERTAÇÕES

**Ana Rafaely Medeiros de Oliveira**

**Uso de redes neurais para busca de transientes de rádio com o telescópio BINGO**

Dissertação (ou Tese) apresentada ao Programa de Pós-Graduação em Física como pré-requisito para obtenção do título de Mestre (ou Doutor) em Física.

Aprovada em: 28/02/2024

Prof. Dr. **Amilcar Rabelo de Queiroz** Orientador PPG - Física - UFCG

Prof. Dr. **João Rafael Lucio dos Santos** Examinador Interno PPG - Física - UFCG

Profa. Dra. **Joseana Macêdo Fchine** Examinadora Externa (UFCG)

Prof. Dr. **Elcio Abdalla** Examinador Externo (USP)



Documento assinado eletronicamente por **AMILCAR RABELO DE QUEIROZ, PROFESSOR 3 GRAU**, em 03/03/2024, às 09:02, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **JOSEANA MACEDO FECHINE, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 04/03/2024, às 10:35, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **JOAO RAFAEL LUCIO DOS SANTOS, PROFESSOR 3 GRAU**, em 05/03/2024, às 09:54, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).

---



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **4234201** e o código CRC **D3CA2BFA**.

---

**Referência:** Processo nº 23096.009057/2024-33

SEI nº 4234201



MINISTÉRIO DA EDUCAÇÃO  
**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE**  
POS-GRADUACAO EM FISICA

Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

REGISTRO DE PRESENÇA E ASSINATURAS

REGISTRO DE PRESENÇA E ASSINATURAS

ATA DA DEFESA PARA CONCESSÃO DO GRAU DE MESTRE EM FÍSICA, REALIZADA EM 28 DE  
FEVEREIRO DE 2024

Aos vinte e oito dias do mês de fevereiro do ano de dois mil e vinte e quatro, reuniram-se em caráter de solenidade pública, os membros da comissão designada para avaliar **Ana Rafaely Medeiros de Oliveira** ao grau de Mestre em Física, área de concentração Física. Foram componentes da Banca Examinadora os especialistas: o professor **Amilcar Rabelo de Queiroz** (Orientador) – Doutor em Física, o professor **João Rafael Lúcio dos Santos** – Doutor em Física, a professora **Joseana Macêdo Fechine** – Doutora em Engenharia Elétrica, o professor **Élcio Abdalla** - Doutor em Física, sendo o primeiro, o segundo e a terceira, integrantes do corpo docente da Universidade Federal de Campina Grande, e o quarto, integrante do corpo docente da Universidade de São Paulo. HORA DE INÍCIO: **10h00min** – LOCAL: **Sala Virtual**. Dando início aos trabalhos, o Presidente da Banca, professor **Amilcar Rabelo de Queiroz**, após declarar os objetivos da reunião, apresentou o(a) candidato(a) **Ana Rafaely Medeiros de Oliveira**, a quem concedeu a palavra para que dissertasse oral e sucintamente sobre o tema apresentado, intitulado **“Uso de redes neurais para busca de transientes de rádio com o telescópio BINGO”**. Após discorrer o referido tema, o(a) candidato(a) foi arguido(a) pelos examinadores na forma regimental. Ato contínuo, passou a Comissão, em caráter secreto, a proceder a avaliação e julgamento do trabalho, concluindo por atribuir-lhe o conceito Aprovado. Face à aprovação, declarou o Presidente estar o(a) avaliado(a), legalmente habilitado(a) a receber o Grau de Mestre em Física, cabendo à Universidade Federal de Campina Grande, providências para a expedição do Diploma a que o(a) mesmo(a) faz jus. Nada mais havendo a tratar, foi lavrada a ata, que será submetida à aprovação da Comissão Examinadora. Campina Grande, 28 de fevereiro de 2024.

**Amilcar Rabelo de Queiroz**  
Presidente da Comissão e Orientador

**João Rafael Lucio dos Santos**  
Examinador Interno

**Joseana Macêdo Fechine**  
Examinadora Externa

**Élcio Abdalla**  
Examinador Externo

**Ana Rafaely Medeiros de Oliveira**  
Candidato(a)

**Francisco de Assis de Brito**  
Coordenador do Programa

## 2 - APROVAÇÃO

2.1. Segue a presente Ata de Defesa de Tese de Mestrado do(a) candidato(a) **Ana Rafaely Medeiros de Oliveira**, assinada eletronicamente pela Comissão Examinadora acima identificada.

2.2. No caso de examinadores externos que não possuam credenciamento de usuário externo ativo no SEI, para igual assinatura eletrônica, os examinadores internos signatários certificam que os examinadores externos acima identificados participaram da defesa da tese e tomaram conhecimento do teor deste documento.



Documento assinado eletronicamente por **FRANCISCO DE ASSIS DE BRITO, COORDENADOR(A)**, em 01/03/2024, às 16:04, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **AMILCAR RABELO DE QUEIROZ, PROFESSOR 3 GRAU**, em 03/03/2024, às 09:00, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **JOSEANA MACEDO FECHINE, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 04/03/2024, às 10:34, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **JOAO RAFAEL LUCIO DOS SANTOS, PROFESSOR 3 GRAU**, em 05/03/2024, às 09:54, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **4234159** e o código CRC **7DF71E54**.

*Em memória de Archidy Tigueiro.*



# Agradecimentos

- Ao Prof. Amílcar Queiroz, pela orientação, sugestão, estímulo, competência e paciência com que conduziu este trabalho.
- Aos Profs. João Rafael, Marcelo Vargas, pela colaboração que recebi durante a fase de preparação desta dissertação.
- A todos os professores desta Unidade Acadêmica que contribuíram com a minha formação.
- Aos meus amigos Victor Hugo, Klecio, Joaquim Segundo, Raiff Hugo, Renato, entre outros da unidade acadêmica de física, que contribuíram com o meu progresso e compartilharam momentos de estudos.
- A minha esposa Raquel, aos meus filhos Bob e Gabriel, em especial, e aos meus familiares pelo apoio incondicional, confiança e incentivo.
- Aos colegas de pós-graduação, a Maria responsável pela limpeza, a Dona Dalva e funcionários da Unidade Acadêmica de Física pela grata convivência durante a minha permanência nesta Unidade.
- À Fapesq pelo suporte financeiro.
- A todos que direta ou indiretamente possibilitaram a conclusão deste trabalho.

*"O universo não só é mais estranho do que imaginamos,  
é mais estranho do que podemos imaginar.  
(Arthur Eddington, "The Nature of the Physical World" (1928))*

# Resumo

Em 2007, um pulso de rádio muito brilhante foi identificado nos dados de arquivo do Telescópio Parkes na Austrália, marcando o início de um novo ramo de pesquisa em astrofísica. Nos primeiros anos, os Fast Radio Bursts ou Rajadas Rápidas de Radio (FRBs) pareciam muito misteriosos porque a amostra de eventos era limitada e não se sabe suas origens. Com o aperfeiçoamento dos instrumentos e técnicas de análise de dados nos últimos cinco anos, centenas de novos FRBs foram descobertos. O campo agora está passando por uma revolução e a compreensão do FRB tem aumentado rapidamente à medida que novos eventos tem sido descobertos. No entanto, a medida que novos dados são recebidos a uma alta taxa de candidatos, deve-se avaliar se são FRB ou transientes, originados de outras fontes. Neste trabalho, utilizamos técnicas de Deep Learning (em português, aprendizagem profunda) para treinar redes neurais profundas para classificação de candidatos FRB e Transientes. As redes neurais convolucionais abordadas, trabalham com dados de frequência e tempo gerando um espectrogramas também conhecido como Waterfall. Treinamos essas redes usando FRBs simulados, e analisamos a sua saída. Apresentamos alguns modelos de aprendizado profundo com uma precisão e recuperação de  $\approx 90\%$  em nosso conjunto de dados de teste composto por dados simulados e pulsos reais ou candidatos a FRB. Atualmente, o uso de algoritmos de aprendizado de máquina para classificação de candidatos é uma necessidade. Esses algoritmos também desempenharão um papel fundamental na construção de gatilhos em tempo real para detecção nos instrumentos do projeto BINGO.

**Palavras-chave:** BINGO, Radio Telescope, Waterfall, Neural Networks, Fast Radio Burst.

# Abstract

In 2007, a very bright radio pulse was identified in archival data from the Parkes Telescope in Australia, marking the beginning of a new branch of research in astrophysics. In the early years, Fast Radio Bursts (FRBs) appeared very mysterious because the sample of events was limited, and their origins were unknown. With the improvement of instruments and data analysis techniques over the last five years, hundreds of new FRBs have been discovered. The field is now undergoing a revolution, and the understanding of FRBs has rapidly increased as new events continue to be uncovered. However, as new data are received at a high rate of candidates, it is necessary to assess whether they are FRBs or transients originating from other sources. In this work, we employ Deep Learning techniques to train deep neural networks for the classification of FRB and transient candidates. The convolutional neural networks used work with frequency and time data to generate spectrograms, also known as Waterfalls. We trained these networks using simulated FRBs and analyzed their output. We present several deep learning models with an accuracy and recall of approximately 90% on our test dataset, which is composed of simulated data and real pulses or FRB candidates. Currently, the use of machine learning algorithms for candidate classification is essential. These algorithms will also play a key role in building real-time triggers for detection in the BINGO project instruments.

**Keywords:**BINGO, Radio Telescope, Waterfall, Neural Networks, Fast Radio Burst.

# Lista de ilustrações

Figura 1 – Antena de Jansky que detectou pela primeira vez radiação de RF extraterrestre. Fonte: [71] . . . . .	4
Figura 2 – Grote Reber junto ao seu radiotelescópio. Fonte: [1] . . . . .	4
Figura 3 – Na figura é possível verificar os campos elétricos e magnéticos que vibram juntos. Nesse esquema podemos verificar as ondas planas eletromagnéticas, onde, o campo elétrico oscila no plano vertical e o campo magnético oscila no plano horizontal [55]. . . . .	8
Figura 4 – Colaboração nacional e internacional. Fonte: Elaborada pelo Autor. . .	12
Figura 5 – Distribuição geográfica das cidades próximas ao radiotelescópio. Fonte: [3]. . . . .	13
Figura 6 – Esquerda: projeto da corneta com detalhes para as corrugações. Direita: corneta vista em perspectiva, onde os anéis verdes são anéis de suspensão. Fonte: [70] . . . . .	13
Figura 7 – Imagens do comprimento e do interior da corneta do radiotelescópio BINGO recém chegada na UFCG. Fonte: [55]. . . . .	14
Figura 8 – Esquemas de projeto óptico conforme apresentado no CDR de julho de 2019. Fonte: [73]. . . . .	14
Figura 9 – A rajada de Lorimer (também conhecida como FRB 010724) foi detectada pelo telescópio Parkes. No painel superior, foi estimado que essa rajada (pulso) apresenta um DM de $375 \text{ cm}^{-3} \text{ pc}$ e foi tão brilhante que saturou o detector, resultando em uma queda abaixo da linha de base nominal do ruído logo após o evento. Já no painel inferior, temos o espectro dinâmico, que mostra a explosão em função da frequência e do tempo. Fonte: [52] . . . . .	16
Figura 10 – As medidas de dispersão (DMs) dos pulsares de rádio Galácticos, dos transientes rotativos de rádio Galácticos (RRATs), dos pulsares de rádio nas Pequenas e Grandes Nuvens de Magalhães (SMC e LMC) e das FRBs publicadas, em relação à DM Galáctica máxima modelada ao longo da linha de visão pelo modelo NE2001 . Fontes com $\frac{DM}{DM_{\max}} > 1$ são consideradas como originárias de distâncias extragalácticas e acumulam DM adicional do meio intergaláctico e de sua galáxia hospedeira. Fonte: [61] . . . . .	17
Figura 11 – Representação de uma analogia entre o funcionamento do cérebro humano, com a rede neural computacional. Fonte: [31]. . . . .	26
Figura 12 – Arquitetura básica das redes neurais. Fonte: Elaborada pelo Autor. . .	27
Figura 13 – Modelo não-linear de um neurônio. Fontes: Adaptação de [33] e [53] . .	27

Figura 14 – Representação visual da função linear. Fonte:[8]. . . . .	29
Figura 15 – Comportamento da função Sigmoide. Fonte: [8]. . . . .	30
Figura 16 – Comportamento da função ReLU. Fonte: [8]. . . . .	30
Figura 17 – Comportamento da função Leaky ReLU. Fonte:[8]. . . . .	31
Figura 18 – Na figura, é possível verificar a função Tanh, onde pode assumir valores negativos centrado na origem. Fonte:[8]. . . . .	32
Figura 19 – Sequência de dígitos. Fonte: [49]. . . . .	33
Figura 20 – A imagem representa um conjunto de dígitos manuscritos dos dados MNIST, separados em 6 imagens diferentes. Fonte: [49]. . . . .	34
Figura 21 – Arquitetura da rede neural do Digit MNIST. Fonte: [49] . . . . .	34
Figura 22 – Na imagem é possível verificar que a fim de treinar nossa rede neural para classificar imagens, primeiro temos que desenrolar o formato de pixel altura largura em um grande vetor - o vetor de entrada. Portanto, seu comprimento deve ser $28 \cdot 28 = 784$ . Mas vamos representar graficamente a distribuição de nossos valores de pixel. Fonte: Pelo autor com base na referencia [39]. . . . .	37
Figura 23 – Histograma da quantidade de pixels relacionados a seus respectivos valores na escada de cinza, deve ser destacado que essa escala varia de 0 a 255. Fonte: Pelo autor com base na referencia [39]. . . . .	38
Figura 24 – Representação da normalização dos dados. Fonte: [20] . . . . .	39
Figura 25 – visualização do conjunto de dados. Fonte: [20] . . . . .	39
Figura 26 – Exemplo de construção de rede, utilizando outra arquitetura, onde teremos 784 entradas, que passará por duas camadas internas de 512 nós, com 10 saídas. Fonte: [39]. . . . .	40
Figura 27 – Essa gráfico representa a precisão (accuracy) e perda (loss) dos dados de treino e testes. Fonte: [49] . . . . .	44
Figura 28 – Nesse grafico verificamos um comparativo entre as previsões geradas pela rede neural treinada, junto, aos seus respectivos valores verdadeiros. Fonte: Elaborada pelo Autor. . . . .	47
Figura 29 – Amostra do banco de dados Galaxy MNIST. Fonte: [2] . . . . .	48
Figura 30 – Resultado do treinamento do modelo, que teve 70% de precisão (accuracy) Galaxy MNIST. Fonte: [2] . . . . .	49
Figura 31 – Resultado plotado na confusion matrix, onde mostra a previsão com os valores verdadeiros. Fonte: [2] . . . . .	50
Figura 32 – Precisão do modelo 2 elaborado. Fonte: Elaborado pelo Autor . . . . .	51
Figura 33 – Dados elaborados simulados, onde os pulsos foram distribuídos de forma aleatória, e foi adicionado o ruído rosa e branco. Fonte: Elaborada pelo Autor. . . . .	53

Figura 34 – Representação visual de como o ficaria a distribuição dos neurônios individuais ficariam distribuídos. Fonte: Elaborada pelo autor. . . . .	53
Figura 35 – Na figura é verificado a rede neural B, onde mostra o processo matemático da rede. Fonte: Elaborada pelo autor. . . . .	54
Figura 36 – Mecanismo de funcionamento da rede neural na prática, demonstração matemática e computacional da rede. Fonte: Elaborada pelo autor. . .	55
Figura 37 – Na figura é destacado a rede neural B, onde mostra toda a logica computacional, como filtros, funções de ativação, flattened entre outros. Fonte: Elaborada pelo autor. . . . .	56
Figura 38 – Em <i>a)</i> é possível verificar um pulso com uma determinada largura, enquanto em <i>b)</i> é verificado a ausência do pulso. Fonte: Elaborada pelo autor. . . . .	56
Figura 39 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são ReLU e Tanh. Fonte: Elaborada pelo Autor. . . . .	58
Figura 40 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são ReLU e Tanh. Fonte: Elaborada pelo Autor. . . . .	59
Figura 41 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são sigmoid e Tanh. Fonte: Elaborada pelo Autor. . . . .	59
Figura 42 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são ReLU e Tanh. Fonte: Elaborada pelo Autor. . . . .	60
Figura 43 – Arquitetura da rede neural E em forma de diagrama. Fonte: Elaborada pelo Autor. . . . .	60
Figura 44 – Estrutura da rede neural. Fonte: Elaborada pelo Autor. . . . .	61
Figura 45 – Arquitetura da rede neural G em forma de diagrama. Fonte: Elaborada pelo Autor. . . . .	61
Figura 46 – Arquitetura da rede neural H em forma de diagrama. Fonte: Elaborada pelo Autor. . . . .	62
Figura 47 – Banco de dados I simulados de pulsos com tamanho (32, 100.000). Fonte: Elaborada pelo autor. . . . .	63
Figura 48 – Banco de dados II simulados de pulsos com tamanho (32, 100.000). Fonte: Elaborada pelo autor. . . . .	64

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>3</b>
<b>2.1</b>	<b>Radioastronomia</b>	<b>3</b>
2.1.1	Breve Historia da Radioastronomia	3
<b>2.2</b>	<b>Radiação Eletromagnética</b>	<b>8</b>
2.2.1	Ondas eletromagnéticas e sua propagação	8
2.2.2	Equações de Maxwell e Ondas eletromagnéticas Planas no Vácuo	9
<b>2.3</b>	<b>Radiotelescópio BINGO</b>	<b>12</b>
<b>2.4</b>	<b>Radio transientes: Fast Radio Bursts (FRB)</b>	<b>15</b>
2.4.1	Uma Breve História dos radio transientes	15
2.4.1.1	Fast Radio Burst (FRB)	15
2.4.1.2	Medida de dispersão	17
2.4.1.3	Largura de Pulso	19
2.4.2	Fluência e Densidade de Fluxo	20
2.4.3	Propriedades Derivadas Básicas	21
2.4.3.1	Restrições de distância	21
2.4.3.2	Fonte de Luminosidade	21
2.4.3.3	Relação DM-fluxo	22
2.4.3.4	Temperatura de Brilho	23
2.4.3.5	Efeitos de propagação	24
<b>2.5</b>	<b>Redes Neurais</b>	<b>26</b>
2.5.1	Estrutura da Rede	27
2.5.1.1	Camada interna	28
2.5.1.1.1	Funções de Ativação	28
2.5.1.1.2	Função de saída: Softmax	32
2.5.2	Usando redes neurais para reconhecer dígitos manuscritos	33
2.5.2.1	Gradiente	35
2.5.3	Implementando nossa rede para classificar dígitos MNIST	35
2.5.3.1	Importação dos dados	36
2.5.3.2	Construindo a Rede	40
2.5.3.3	Compilando e treinando o modelo	42
2.5.3.4	Avalie o desempenho do modelo	45
2.5.3.5	Galaxy MNIST	48
<b>3</b>	<b>CONSIDERAÇÕES FINAIS E PERSPECTIVAS</b>	<b>52</b>



<b>3.1</b>	<b>Aplicação de Rede Neural CNN para Classificação de Transientes de Rádio</b> . . . . .	<b>52</b>
3.1.1	Dados simulados . . . . .	52
3.1.2	Elaboração do pré processamento dos dados . . . . .	56
3.1.3	Arquitetura das redes . . . . .	57
3.1.3.1	Rede Neural A . . . . .	58
3.1.3.2	Rede Neural B . . . . .	58
3.1.3.3	Rede Neural C . . . . .	59
3.1.3.4	Rede Neural D . . . . .	59
3.1.3.5	Rede Neural E . . . . .	60
3.1.3.6	Rede Neural F . . . . .	60
3.1.3.7	Rede Neural G . . . . .	61
3.1.3.8	Rede Neural H . . . . .	61
	<b>REFERÊNCIAS</b> . . . . .	<b>66</b>

# 1 Introdução

O projeto “BINGO” (sigla para “BAO” from Integrated Neutral Gas Observations”) é um experimento científico que visa investigar a história da expansão do Universo e as flutuações na densidade da matéria através da detecção de oscilações acústicas de bárions (BAO - Baryon Acoustic Oscillations) usando o mapeamento de hidrogênio neutro. O BINGO é um radiotelescópio projetado para observar a distribuição de hidrogênio neutro no Universo, aproveitando o fenômeno das BAO para entender melhor a estrutura em grande escala do cosmos e sua expansão ao longo do tempo.

Sua alta sensibilidade, permite observar uma ampla gama de frequências como a detecção dos FRBs. Sua detecção e o estudo de FRBs podem fornecer informações valiosas sobre os processos astrofísicos que ocorrem em locais distantes do Universo.

Em 2007, no radiotelescópio Parkes [5] foi detectado um fenômeno conhecido como Fast Radio Bursts (FRBs), que são transientes de rádio de curta duração, caracterizados por sua medida de dispersão (DMs). Posteriormente, outros FRBs foram detectados em telescópios diferentes, alguns FRBs encontrados foram no telescópio Arecibo [4] localizado em Porto Rico, Green Bank Telescope (GBT) [44], o atualizado Molonglo Synthesis Telescope (UTMOST) [15], e por fim o telescópio ASKAP, [60] a qual mais de 60 FRBs publicado, descobriu-se que dois se repetem: FRB 121102 [62] e FRB 180814.J0422+73. FRB 121102 foi localizado em uma galáxia hospedeira de baixa metalicidade, em um desvio para o vermelho de 0,19, pelo detector Realfast [40] no Karl G. Jansky Very Large Array [18], tornando evidente que alguns, senão todos, FRBs são cosmológicos na origem.

Os FRBs são estudados a partir de ondas de rádio, que são caracterizados pelo tempo e frequência (waterfall), sua principal característica é frequência alta em uma curta duração no tempo, gerando um pulso diferente dos demais. Devido sua particularidade é possível catalogá-los e classificá-los a partir de possíveis candidatos.

Neste trabalho, aplicaremos técnicas de Deep Learning (aprendizagem profunda) com ênfase em redes neurais para a detecção de transientes de rádio, conhecidos como FRBs. Atualmente, a classificação dos FRBs é realizada manualmente, o que limita a rapidez e a eficiência na identificação desse fenômeno.

Nesse contexto, o uso de machine learning pode oferecer uma solução automatizada para o problema. Técnicas dessa abordagem já são amplamente empregadas na classificação de sinais e no reconhecimento de padrões. O deep learning, um ramo do machine learning, foca na aprendizagem de representações de dados, ao invés de depender de algoritmos específicos para cada tarefa. O deep learning já foi utilizado com sucesso na busca por pulsares. [63] produzindo melhorias significativas, demonstrando seu potencial para uso

em pesquisas transitórias. [29]

## 2 Fundamentação teórica

### 2.1 Radioastronomia

#### 2.1.1 Breve Historia da Radioastronomia

O estudo da radioastronomia começou no início de 1900. Antes disso, os astrônomos estudavam o universo apenas em comprimentos de onda visíveis. O estudo da eletricidade e do magnetismo em 1800 ajudou a estabelecer a descoberta da radioastronomia em 1900. Primeiro e acima de tudo, o desenvolvimento das equações de Maxwell revelou que qualquer comprimento de onda da luz é possível, e que aqueles na janela visível na verdade compreendem apenas uma pequena fração do que seria conhecido posteriormente como espectro eletromagnético. Em 1887, Heinrich Hertz produziu com sucesso ondas de rádio em laboratório, inspirando outros a tentar detectar ondas de rádio do espaço. Em 1890, Thomas Edison e Arthur Kennelly propuseram a busca de correlações entre o número de manchas solares e o sinal de rádio detectado por um pedaço de minério de ferro. [38]

O desenvolvimento da radioastronomia demandou a amplificação dos sinais de rádio recebidos pelas antenas. Esse avanço ocorreu em dezembro de 1932, quando Karl Jansky, da Bell Labs, realizou a primeira detecção bem-sucedida de emissão de rádio astronômica. Jansky estava investigando a interferência de estática nas comunicações de rádio de ondas curtas de longa distância. Utilizando uma antena orientável, ele amplificou e converteu as ondas de radiofrequência em sinais sonoros audíveis, que escutou com fones de ouvido na frequência de 20,5 MHz. Durante seus experimentos, Jansky detectou um ruído constante sobreposto a crepitações causadas por tempestades. Notou que a intensidade do ruído variava conforme a direção. Após uma investigação mais aprofundada, descobriu que a origem do ruído era fixa em relação às estrelas, e não à Terra ou ao Sol. Constatou que o sinal vinha do plano da nossa galáxia, com maior intensidade proveniente da região central da galáxia, localizada na constelação de Sagitário. Apesar da importância dessa descoberta, poucos astrônomos a notaram na época, e ela poderia ter sido considerada irrelevante se não fosse pelo trabalho subsequente de Grote Reber, ver figuras 1 e 2.

Grote Reber, um engenheiro com um profundo interesse por astronomia, ficou fascinado pelo trabalho de Karl Jansky. Em 1937, decidido a explorar mais a fundo, Reber construiu sua própria antena de 30 pés em seu quintal, em Wheaton, Illinois, utilizando recursos próprios. Inicialmente, ele enfrentou dificuldades, pois não conseguiu detectar sinais nas frequências de 900 e 3.300 MHz. No entanto, ao ajustar seu equipamento para a frequência de 160 MHz, conseguiu mapear a emissão de rádio da galáxia com uma resolução superior àquela obtida por Jansky.




Figura 1 – Antena de Jansky que detectou pela primeira vez radiação de RF extraterrestre. Fonte: [71]

Reber fez avanços significativos ao identificar vários picos secundários na intensidade do sinal, além da forte emissão proveniente do centro da Via Láctea. Ele localizou esses picos em regiões específicas do céu: um deles na área próxima à estrela Cassiopeia, agora conhecida como Cas A, um remanescente de supernova, e outro na constelação de Cygnus, associado à radiogaláxia Cyg A. Seus resultados, publicados em 1940 e 1944, representaram as primeiras observações de comprimento de onda de rádio a serem divulgadas em uma revista científica de astronomia, marcando um avanço crucial no campo da radioastronomia.



Figura 2 – Grote Reber junto ao seu radiotelescópio. Fonte: [1]

Por motivos militares, durante a Segunda Guerra Mundial, houve importantes avanços tecnológicos evolução da ciência dos radares. J.S. Ei, um cientista civil do Exército Britânico Operacional Research Group, analisou todos os relatórios de bloqueio de radares do exército. Em fevereiro de 1942, houve um número especialmente grande de relatórios de

interferência arquivados. Ei concluiu que a causa estava relacionada a uma grande mancha solar. Isso não foi aceito por unanimidade, mas mais tarde no mesmo ano, Southworth do Bell Labs, observando em frequências de gigahertz, fez a primeira detecção bem-sucedida de emissão de rádio do Sol quiescente <sup>1</sup>. A combinação de estas duas publicações, ocorridas em dois países diferentes, suscitaram o interesse pela desenvolvimento da radioastronomia solar.

Depois da guerra, Hey, em colaboração com S. J. Parson, J. W. Phillips e G. S. Stewart, continuou com estudos de radar e rádio e fez uma série de descobertas. Em 1945, Hey e colegas descobriram que os meteoros deixam rastros de ionização que refletem as ondas de rádio. Em 1946, eles mapearam o céu do rádio com mais detalhes do que o feito por Reber e descobriram que o rádio a emissão observada em Cygnus variou com o tempo. Eles reconheceram Cyg A como uma fonte discreta, distinta da emissão de rádio estendida associada à Via Láctea. Em 1948, eles determinaram que as rajadas de rádio solar estavam associadas a manchas solares e erupções solares. [23]

Em 1946, como marco inicial no longo desenvolvimento da radioastronomia de alta resolução, Sir Martin Ryle e D. D. Vonberg realizaram a primeira observação astronômica com medição precisa utilizando um par de antenas de rádio como um interferômetro. Observações interferométricas posteriores por um número de investigadores produziu medições precisas das posições do brilho das fontes de rádio, suficientes para identificação óptica (de Cyg A, Cass A e a Nebulosa do Caranguejo). No final dos anos 1950, com interferômetros mais avançados, um catálogo das 471 fontes mais brilhantes em 159 MHz foi criado e publicado em 1959. Este catálogo ficou conhecido como o Terceiro Catálogo Cambridge de Fontes de Rádio (3C) (as duas primeiras tentativas tiveram problemas com confusão de fontes). Uma versão revisada, o catálogo 3CR, incluindo observações em 178 MHz, foi produzida alguns anos depois. Na década de 1960, foi criado o catálogo 4C, com um limite de fluxo mínimo menor.

Na década de 1950, houve um avanço significativo na compreensão da natureza das emissões de rádio da Via Láctea e de várias fontes de rádio discretas e brilhantes. Hannes Alfvén e Nicolai Herlofsen, na Suécia, e Iosif Shklovsky, na Rússia, propuseram que a radiação contínua das fontes de rádio mais intensas se deve a um processo exótico chamado radiação síncrotron. Nesse fenômeno, elétrons relativísticos emitem fótons enquanto se movem em espiral ao redor de linhas de campo magnético

Durante a década de 1960, a radioastronomia fez avanços notáveis com a descoberta de quasares, pulsares, o universo cósmico e o fundo de micro-ondas. Essas descobertas resultaram em importantes reconhecimentos, incluindo Prêmios Nobel. Arno Penzias e Robert Wilson foram agraciados com parte do Prêmio Nobel de 1978 pela descoberta do

---

<sup>1</sup> O sol quiescente, é uma parte do ciclo solar, que tem uma duração aproximada de 11 anos. É oposta à fase de máximo solar, quando a atividade solar é mais intensa.

fundo de micro-ondas, e Anthony Hewish recebeu o Prêmio Nobel de 1974 em conjunto com Sir Martin Ryle por suas contribuições à radioastronomia, incluindo a descoberta dos pulsares.

Além desses prêmios, estudos posteriores sobre pulsares e radiação cósmica de fundo renderam mais dois Prêmios Nobel: Joseph Taylor e Russell Hulse foram laureados em 1993, e John Mather e George Smoot receberam o prêmio em 2006. Essas descobertas consolidaram a importância da radioastronomia no avanço do nosso entendimento do universo.

Ao mesmo tempo, Sir Martin Ryle e seus colegas continuaram a aprimorar a interferometria de rádio, desenvolvendo experimentos que incluíam a criação de matrizes de antenas e aproveitando a rotação da Terra. Ryle foi agraciado com parte do Prêmio Nobel de 1974 pelo desenvolvimento da síntese de abertura.

Em 1967, uma equipe liderada pelo radioastrônomo Antony Hewish, em Cambridge, Inglaterra, descobriu um novo tipo de corpo celeste utilizando um radiotelescópio que se assemelhava a uma série de postes alinhados. Jocelyn Bell, uma aluna de Hewish, detectou pulsos extremamente regulares vindos da direção da constelação de Touro, especificamente da Nebulosa do Caranguejo. Inicialmente, as emissões foram erroneamente interpretadas como sinais de uma civilização extraterrestre, mas essa hipótese foi rapidamente descartada. Em vez disso, concluiu-se que os sinais eram gerados por pulsares, estrelas extremamente densas e pequenas que emitem pulsos de radiação enquanto giram rapidamente, devido ao movimento de elétrons ultrarrápidos em torno de linhas de campo magnético intensas.

Não poderíamos deixar de mencionar um pouco da história de um campo de pesquisa bastante discutido: a busca de sinais de vida inteligente. A radioastronomia logo se tornou uma opção bem aceita para este tipo de pesquisa, dada a facilidade de geração de sinais e pelo fato dessas ondas se propagarem com facilidade, podendo ser captada, mesmo a grandes distâncias, por nossos radiotelescópios. A ideia, portanto, era a de que civilizações extraterrestres com nível tecnológico semelhante ao nosso poderiam já ter chegado ao desenvolvimento da Radioastronomia e, desta forma, poderiam tanto receber as nossas radioemissões quanto enviar as suas.

Mais recentemente, os avanços tecnológicos abriram “janelas” astronômicas, uma dessas janelas é a linha de 21 *cm*, em que o gás frio difuso é detectado devido à emissão ou absorção a linha de estrutura hiperfina do hidrogênio neutro. A emissão deste gás não pode ser detectada por nenhum outro meio. Em menor grau, isso é verdade para gás frio mais denso traçado por transições rotacionais permitidas de monóxido de carbono, CO. Esse material é detectado apenas por linhas moleculares ou atômicas e radiação de poeira de banda larga. Embora as interpretações sejam diferentes para cada janela espectral, existe uma única realidade. [68]

O estudo da linha de 21 *cm* foi iniciado em 1944, quando o famoso teórico astrofísico holandês Jan Oort sugeriu a Hendrik van de Hulst que calculasse o comprimento de onda da emissão linha de hidrogênio devido ao spin flip do elétron. Os cálculos de van de Hulst previu que esta transição deveria emitir radiação no comprimento de onda de 21 *cm*. A primeira detecção foi feita em 1951 por Harold Ewen e Edward Purcell em Harvard e confirmado várias semanas depois por grupos na Holanda e na Austrália [38]. Na década de 1950, mapas de gás hidrogênio em toda a Via Láctea foram feitos usando o telescópio de 21 *cm* linha na Holanda e na Austrália. Essa linha ainda é amplamente utilizada para mapear a distribuição dos átomos de hidrogênio no espaço. De fato, alguns dos laboratórios envolvem detecção e análise da linha de 21 *cm*.



## 2.2 Radiação Eletromagnética

### 2.2.1 Ondas eletromagnéticas e sua propagação

Em física, a radiação eletromagnética (EM) consiste em ondas de campo eletromagnético, que se propagam pelo espaço e transportam momento e energia. Exemplo delas são ondas de rádio, micro-ondas, infravermelho, luz (visível), ultravioleta, raios-X e raios gama. Todas essas ondas fazem parte do espectro eletromagnético, que será verificado posteriormente.

Classicamente, a radiação eletromagnética consiste em ondas eletromagnéticas, que são oscilações sincronizadas de campos elétricos e magnéticos. Dependendo da frequência de oscilação, diferentes comprimentos de onda do espectro eletromagnético são produzidos. No vácuo, as ondas eletromagnéticas viajam à velocidade da luz, comumente denotadas pela letra  $c$ . [43]

As ondas eletromagnéticas são geradas por partículas carregadas eletricamente que estão submetidas a acelerações, produzindo variações nos campos elétrico e magnético. Em meios isotrópicos e homogêneos, essas ondas oscilam de forma perpendicular entre si, bem como em relação à direção de propagação da energia, configurando-se como ondas transversais. Esse comportamento pode ser observado na figura 3, que ilustra essa relação entre os campos e a direção de propagação.




Figura 3 – Na figura é possível verificar os campos elétricos e magnéticos que vibram juntos. Nesse esquema podemos verificar as ondas planas eletromagnéticas, onde, o campo elétrico oscila no plano vertical e o campo magnético oscila no plano horizontal [55].

Pensando nisso, James Clerk Maxwell realizando estudos do eletromagnetismo, descobriu que a velocidade das ondas eletromagnéticas prevista pela equação de onda coincidiu com a velocidade medida da luz, logo, concluiu que a própria luz é na verdade

uma onda eletromagnética. Posteriormente, as equações de Maxwell foram confirmadas por Heinrich Hertz através de experimentos com ondas de rádio. [54]

A descrição de Maxwell para o eletromagnetismo é amplamente reconhecida como fundamental e completa. Suas equações, agora universalmente conhecidas como “Equações de Maxwell”, representam a base teórica para o estudo dos fenômenos eletromagnéticos. Elas são amplamente utilizadas na física contemporânea e demonstram a inter-relação entre campos elétricos e magnéticos, desempenhando um papel crucial na compreensão e na previsão de uma ampla gama de fenômenos físicos.

## 2.2.2 Equações de Maxwell e Ondas eletromagnéticas Planas no Vácuo

Em 1831 nasceu na Escócia, James Clerk Maxwell, formou-se na Universidade de Cambridge, em que teve sua formação Matemática. Ele formulou os seus resultados em termos dos operadores vetoriais divergentes ( $\vec{\nabla} \cdot \vec{f}$ ) e rotacionais ( $\vec{\nabla} \times \vec{f}$ ) ( $f$  representa uma função qualquer), que já haviam sido utilizados por Stokes.

As equações de Maxwell resumem todo o conteúdo teórico da eletrodinâmica clássica (exceto por algumas propriedades específicas da matéria) e representam o estado da teoria eletromagnética há mais de um século. Quando ele começou seu trabalho, Maxwell observou que a luz é uma combinação de eletricidade e magnetismo e, portanto, os dois campos devem estar ligados entre si.

De acordo com as equações de Maxwell, um campo elétrico espacialmente variável está sempre associado a um campo magnético que muda ao longo do tempo. Da mesma forma, um campo magnético espacialmente variável está associado a mudanças específicas ao longo do tempo no campo elétrico. Em uma onda eletromagnética, as mudanças no campo elétrico são sempre acompanhadas por uma onda no campo magnético em uma direção e vice-versa. [54]

A equação da onda é uma das equações fundamentais no estudo das ondas eletromagnéticas. Para deduzi-la, é necessário impor certas condições iniciais. Consideramos que as ondas se propagam no vácuo, sem a presença de cargas livres ou correntes elétricas. Sob essas condições, é possível derivar a equação da onda eletromagnética monocromática, conforme mostrado a seguir: [43]

$$\vec{\nabla} \cdot \vec{E} = \frac{\rho}{\epsilon_0}; \quad (2.1)$$

$$\vec{\nabla} \cdot \vec{B} = 0; \quad (2.2)$$

$$\vec{\nabla} \times \vec{E} = -\frac{\partial \vec{B}}{\partial t}; \quad (2.3)$$

$$\vec{\nabla} \times \vec{B} = \mu_0 \epsilon_0 \frac{\partial \vec{E}}{\partial t}. \quad (2.4)$$

Utilizando a equação (2.3) pode-se aplicar o rotacional em ambos os lados, tornando

$$\vec{\nabla} \times (\vec{\nabla} \times \vec{E}) = -\vec{\nabla} \times \frac{\partial \vec{B}}{\partial t}. \quad (2.5)$$

Usando a identidade do cálculo vetorial, chegamos a

$$\vec{\nabla} \times (\vec{\nabla} \times \vec{E}) = \vec{\nabla}(\vec{\nabla} \cdot \vec{E}) - \vec{\nabla}^2 \vec{E}, \quad (2.6)$$

Igualando os resultados das equações (2.5) e (2.6), chegaremos a:

$$\vec{\nabla}(\vec{\nabla} \cdot \vec{E}) - \vec{\nabla}^2 \vec{E} = -\vec{\nabla} \times \frac{\partial \vec{B}}{\partial t}. \quad (2.7)$$

Podemos trocar de posição a derivada parcial temporal pois ela é independente da derivada espacial, e substituindo à equação (2.1) na equação (2.7) obtemos

$$-\vec{\nabla}^2 \vec{E} = -\frac{\partial}{\partial t}(\vec{\nabla} \times \vec{B}). \quad (2.8)$$

Por fim, usaremos à equação (2.4) fazendo a substituição

$$-\vec{\nabla}^2 \vec{E} = -\frac{\partial}{\partial t} \left( \mu_0 \epsilon_0 \frac{\partial \vec{E}}{\partial t} \right), \quad (2.9)$$

$$\vec{\nabla}^2 \vec{E} - \mu_0 \epsilon_0 \frac{\partial^2 \vec{E}}{\partial t^2} = 0. \quad (2.10)$$

Observe que a estrutura desta equação é similar a equação de uma onda, cuja velocidade de propagação é dada por

$$\frac{1}{v^2} = \mu_0 \epsilon_0 \Rightarrow v = \frac{1}{\sqrt{\mu_0 \epsilon_0}} \cong 3 \times 10^8 \text{ m/s}, \quad (2.11)$$

tratando-se da velocidade da luz no vácuo. Note que  $\mu_0$  e  $\epsilon_0$  são valores puramente da natureza eletromagnética. Podemos determinar a equação diferencial para a componente magnética  $\vec{B}$  do campo eletromagnético. Para isso teremos o rotacional da equação (2.4).

$$\vec{\nabla} \times (\vec{\nabla} \times \vec{B}) = \mu_0 \epsilon_0 \vec{\nabla} \times \frac{\partial \vec{E}}{\partial t}. \quad (2.12)$$

Utilizando a identidade (2.6), chegaremos a

$$\vec{\nabla}(\vec{\nabla} \cdot \vec{B}) - \vec{\nabla}^2 \vec{B} = \mu_0 \epsilon_0 \frac{\partial}{\partial t} (\vec{\nabla} \times \vec{B}). \quad (2.13)$$

Empregando as equações (2.2) e (2.3), chegaremos a:

$$-\vec{\nabla}^2 \vec{B} = -\mu_0 \epsilon_0 \frac{\partial}{\partial t} \left( \frac{\partial \vec{E}}{\partial t} \right). \quad (2.14)$$

Assim, a velocidade de propagação do campo magnético é determinada pela equação (2.11), e ambos os campos,  $\vec{E}$  e  $\vec{B}$ , se propagam com a mesma velocidade, que corresponde à velocidade da luz  $c$  [43].

Na época de Maxwell, o valor da velocidade da luz  $c$  já era conhecido a partir de diversas fontes, como as observações astronômicas dos satélites de Júpiter, além das medições realizadas na Terra por Fizeau e Foucault. Essas experiências forneciam uma base sólida para o entendimento da propagação da luz. Ao mesmo tempo, os valores de  $\epsilon_0$  (permitividade do vácuo) e  $\mu_0$  (permeabilidade do vácuo) foram determinados por experimentos puramente eletromagnéticos conduzidos por Kohlrausch e Weber, que também avançaram o conhecimento sobre as propriedades eletromagnéticas fundamentais [50]. Esses avanços experimentais desempenharam um papel crucial no desenvolvimento das teorias de Maxwell, unificando as interações elétricas e magnéticas.

Maxwell observou que, historicamente, a eletricidade e o magnetismo evoluíram de maneira independente, sendo tratadas como áreas distintas da física. No entanto, esse cenário começou a mudar radicalmente com as experiências de Oersted, que demonstraram que correntes elétricas são capazes de gerar campos magnéticos, estabelecendo uma conexão clara entre os dois fenômenos. Posteriormente, as descobertas de Faraday foram ainda mais transformadoras, ao revelar que campos magnéticos que variam no tempo induzem campos elétricos. Essas observações experimentais permitiram a Maxwell formular sua teoria unificada do eletromagnetismo, mostrando que eletricidade e magnetismo são manifestações de um único fenômeno. Assim, ele estabeleceu a base para o entendimento moderno das ondas eletromagnéticas e da propagação da luz.

## 2.3 Radiotelescópio BINGO

O radiotelescópio BINGO tem como objetivo ser pioneiro na detecção de oscilações acústicas de bárions (BAO, Baryonic Acoustic Oscillation) na banda de rádio do espectro eletromagnético, mais especificamente entre  $980\text{ MHz}$  e  $1260\text{ MHz}$ . Nessa faixa de frequência, é produzido o hidrogênio atômico que passa por uma transição eletrônica (será verificado posteriormente)[45], que são gerados mapas de distribuição de hidrogênio neutro em diferentes *redshifts*. [69].

O radiotelescópio BINGO é fruto da colaboração entre instituições de várias nações as principais são: no Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE), a Universidade Federal de Campina Grande (UFCG) e a Universidade de São Paulo (USP). Colaboração no exterior países na Inglaterra, as University of Manchester e University College London; na Suíça, a Eidgenössische Technische Hochschule Zürich (ETH Zürich); na China, a YangZhou University; na França, o Institut d'astrophysique de Paris e, na África do Sul, a University of KwaZulu-Natal.(Figura 4).

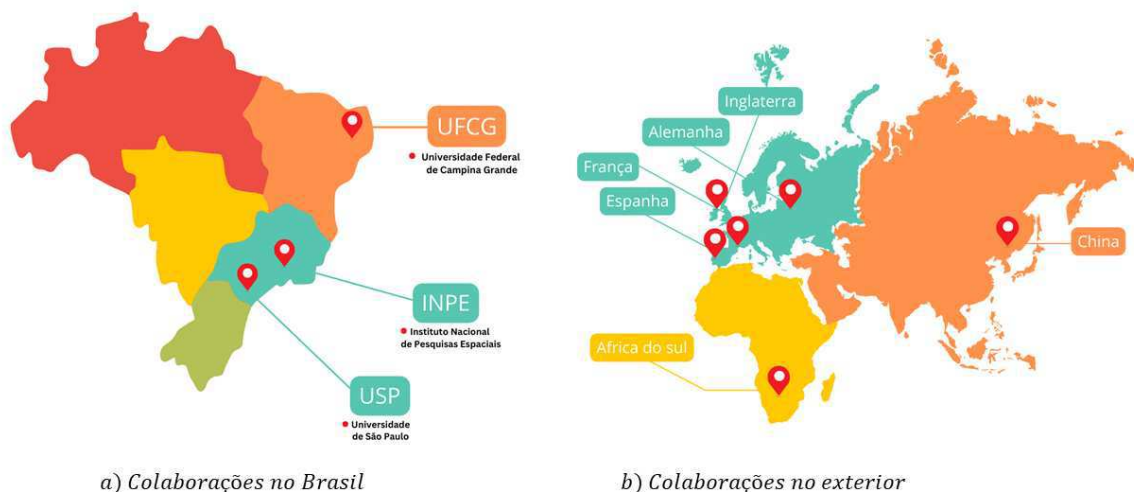


Figura 4 – Colaboração nacional e internacional. Fonte: Elaborada pelo Autor.

O BINGO será instalado no interior do Estado da Paraíba - Brasil (Figura 5), mais especificamente na Serra do Urubu ( $07^{\circ}02'57''S$ ,  $38^{\circ}15'46''W$ ), local onde os níveis de interferência em rádio (RFI, do inglês Radio Frequency Interference) na banda de operação do radiotelescópio foram os mais baixos encontrados durante a campanha de medidas de RFI realizada em 2016 - 2017.

Estruturalmente, o BINGO possui cornetas de aproximadamente 1,7 metro de diâmetro e 4,9 metros de comprimento [73], sua parte mecânica foi construída no Brasil pelo INPE, enquanto a parte eletromagnética foi feita na Universidade de Manchester. As cornetas desenvolvidas para o projeto BINGO são cornetas cônicas corrugadas especificamente para atender os objetivos do equipamento: minimizar os lóbulos laterais e obter

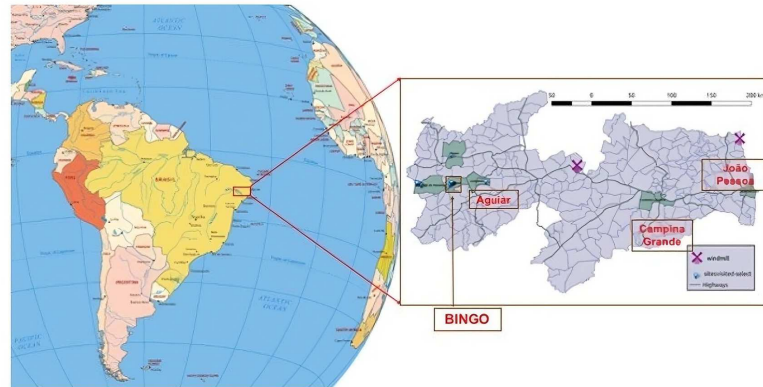


Figura 5 – Distribuição geográfica das cidades próximas ao radiotelescópio. Fonte: [3].

boa performance de polarização, como é verificado na Figura 6.[72]





Figura 6 – Esquerda: projeto da corneta com detalhes para as corrugações. Direita: corneta vista em perspectiva, onde os anéis verdes são anéis de suspensão. Fonte: [70] .

Uma das cornetas está instalada na Universidade Federal de Campina Grande que tem como objetivo de auxiliar estudo referente a calibração e classificação dos sinais uma vez detectados. Esse estudo, faz parte do projeto atualmente conhecido como "Uirapuru" dentro do Projeto líder, BINGO, como pode ser observado na imagem 7.

O BINGO apresenta uma estrutura do tipo Crossed-Dragone, conforme descrito por [22]. Seu design óptico é composto por dois espelhos parabólicos estáticos, cada um com cerca de 40 metros de diâmetro. Um desses espelhos é fixo e ligeiramente inclinado em relação ao solo, enquanto o outro é sustentado por uma estrutura vertical. O telescópio conta com 28 cornetas que, em um período de 24 horas, cobrem uma faixa de  $15^\circ$  do céu. A configuração atual do espelho e do plano focal é encontrada na Figura 8. Como o menor comprimento de onda operacional é em *cm*, o perfil da superfície dos espelhos do



Figura 7 – Imagens do comprimento e do interior da corneta do radiotelescópio BINGO recém chegada na UFCG. Fonte: [55].

telescópio deve ter um erro  $mm$  para permitir a máxima eficiência. O desenho óptico final é descrito no trabalho de [42].




Figura 8 – Esquemas de projeto óptico conforme apresentado no CDR de julho de 2019. Fonte: [73].

## 2.4 Radio transientes: Fast Radio Bursts (FRB)

### 2.4.1 Uma Breve História dos radio transientes

A existência de pulsos de rádio de curta duração foi prevista na década de 70 - Desde supernovas em expansão que vasculham o material circundante em outras galáxias [19] quanto de pequenos buracos negros [57].

Nos anos seguintes, com o avanço no estudo de pulsares, foi observado a emissão de rajadas de rádio nas linhas do campo magnético [69] [45]. Hoje, sabe-se que os campos magnéticos mais afastados, aceleram as partículas de modo que sejam emitidos os pulsos [46]. Esse atraso é quantificado pela medida de dispersão (DM) que é proporcional ao número de elétrons livres ao longo da linha de visão o que possibilita estimar a distância da fonte do pulso [32] [24] [52].

A detecção dos primeiros pulsares foram observados no observatório Mullard Radio Observatory em 1967 [36]. Em 1969, novos pulsos foram detectados conhecidos como Fast Fourier Transforms (FFTs) e Fast Folding Algorithms (FFAs) [14]. Posteriormente, essas buscas permitiram a descoberta de sinais mais fracos, como pulsares com períodos rotacionais de milissegundos [7] e pulsares em sistemas binários relativísticos [64].

Devido ao avanço da pesquisa dos pulsares, uma nova janela se abre na ciência, o estudo de radio-transientes. Em 2001, na Pequena Nuvem de Magalhães com o telescópio Parkes foram observados novos transientes semelhante ao pulsar. No entanto, esse pulso era tão brilhante que saturou o feixe de detecção primário do receptor e foi originalmente estimado para ter um densidade de fluxo de pico de  $> 30 Jy^2$  (Figura 9).

#### 2.4.1.1 Fast Radio Burst (FRB)

Esse pulso, que se popularizou como “explosão de Lorimer”, era notável não apenas por seu incrível brilho, mas também por sua distância. Nele, foi estimado um atraso dispersivo de oito vezes maior do que poderia ser produzido pelos elétrons livres na Via Láctea. Com essa descoberta, surgiu uma população de pulsos de rádio extragalácticos brilhantes denominados “Fast Radio Bursts” (FRBs), do português Rajadas Rápidas de Rádio [41]. Esses pulsos apresentam características semelhantes à explosão de Lorimer e sugerem a existência de uma população desses eventos no universo. Os FRBs despertaram grande interesse devido à sua grande distância e alta energia necessária para produzir tais pulsos brilhantes.

Pesquisas posteriores revelaram mais quatro fontes de FRBs, com características semelhantes à explosão de Lorimer. Estima-se que essas rajadas tenham se originado

<sup>2</sup> O jansky (símbolo: Jy) é uma unidade usada em Astronomia para medir densidade de fluxo. O nome da unidade foi escolhido em homenagem a Karl Jansky, que em 1932 detectou pela primeira vez ondas de rádio emitidas pela Via Láctea.






Figura 9 – A rajada de Lorimer (também conhecida como FRB 010724) foi detectada pelo telescópio Parkes. No painel superior, foi estimado que essa rajada (pulso) apresenta um DM de  $375 \text{ cm}^{-3} \text{ pc}$  e foi tão brilhante que saturou o detector, resultando em uma queda abaixo da linha de base nominal do ruído logo após o evento. Já no painel inferior, temos o espectro dinâmico, que mostra a explosão em função da frequência e do tempo. Fonte: [52]

em distâncias tão grandes quanto  $z = 0,96$  (distância de luminosidade 6 Gpc), com densidades de fluxo de pico de aproximadamente 1 Jy. Isso implica uma energia isotrópica de  $10^{32} \text{ J}$  ( $10^{39} \text{ erg}$ ) em alguns milissegundos ou uma potência total de  $10^{35} \text{ J s}^{-1}$  ( $10^{42} \text{ erg s}^{-1}$ ). As energias envolvidas nesses eventos estão dentro de algumas ordens de magnitude daquelas estimadas para emissão imediata de GRBs e explosões de supernovas, sugerindo mecanismos progenitores extremos, como eventos cataclísmicos e explosões.

A descoberta de Thornton [13] causou uma grande empolgação na comunidade científica e resultou em um aumento significativo nas pesquisas ao redor do mundo [56]. Entre eles, podemos citar o Observatório de Arecibo [61], o Green Bank Telescope ([44],[17]) o Upgraded Molonglo Synthesis Telescope [16], o Australian Square Kilometer Array Pathfinder [60] e o Canadian Hydrogen Intensity Mapping Experiment [10] [6].

Em 2013, foi observado um aumento na taxa de descobertas de FRBs. Devido a isso, uma das descobertas mais significativas, inclui as primeiras duas fontes de FRB que se repetiram, conhecidas como, FRB 121102 e FRB 180814.J0422+73.[62] [59] [18]

Atualmente, os Fast Radio Bursts (FRBs) ainda são pouco compreendidos pela comunidade científica, e não existe um formalismo padronizado para defini-los. Além disso, muitas questões importantes, como a sua origem, permanecem sem respostas conclusivas. No entanto, há tentativas de formalizar e classificar esses eventos [28]. Na prática, para que um sinal ou pulso seja classificado como um FRB, ele precisa atender a certos critérios, definidos com base nos pulsos já identificados. Esses critérios incluem a duração do pulso,

seu brilho e a largura de banda. Um fator determinante é se a medida de dispersão (DM) é maior do que a esperada para uma fonte galáctica. Por conta disso, há ambiguidade quando o DM de um sinal está próximo da contribuição máxima esperada da Galáxia, o que pode levar à incerteza sobre se a fonte é um pulsar ou RRAT galáctico, ou um FRB extragaláctico, como ilustrado na figura 10.




Figura 10 – As medidas de dispersão (DMs) dos pulsares de rádio Galácticos, dos transientes rotativos de rádio Galácticos (RRATs), dos pulsares de rádio nas Pequenas e Grandes Nuvens de Magalhães (SMC e LMC) e das FRBs publicadas, em relação à DM Galáctica máxima modelada ao longo da linha de visão pelo modelo NE2001. Fontes com  $\frac{DM}{DM_{max}} > 1$  são consideradas como originárias de distâncias extragalácticas e acumulam DM adicional do meio intergaláctico e de sua galáxia hospedeira. Fonte: [61]

Até o momento, mais de 60 fontes independentes de FRBs foram detectadas em 10 telescópios diferentes ao redor do mundo [51]. Esses FRBs possuem características como: Medida de dispersão, largura de banda, tempo da duração do pulso, frequência detectada, fluência e densidade de fluxo [6] 2.4.1.2.

#### 2.4.1.2 Medida de dispersão

Para compreendermos como é calculada a medida de dispersão de um FRB, é essencial primeiro entender o processo de dispersão das ondas eletromagnéticas, que se baseia em princípios fundamentais descritos pela teoria do eletromagnetismo. Iremos analisar o caso das ondas monocromáticas, suas superposições, além de explorar sua formação e consequente propagação.

Inicialmente, iremos analisar a equação da onda que é dada por:

$$f(x, t) = \cos(kx - wt). \quad (2.15)$$

A superposição de duas ondas planas é dada pela soma de duas ondas, sendo uma onda  $f_1(x, t) = \cos(k_1x - w_1t)$  e  $f_2(x, t) = \cos(k_2x - w_2t)$ , chegaremos ao resultado:

$$f(x, t) = f_1(x, t) + f_2(x, t) = \cos(k_1x - \omega_1t) + \cos(k_2x - \omega_2t). \quad (2.16)$$

Onde  $k$  e  $w$  são respectivamente, o número de onda e a frequência angular., com alguns ajustes teremos o seguinte resultado

$$f(x, t) = 2 \cos\left(\frac{\Delta k}{2}x - \frac{\Delta \omega}{2}t\right) \cos(\bar{k}x - \bar{\omega}t) = A(x, t) \cos(\bar{k}x - \bar{\omega}t), \quad (2.17)$$

sendo  $\bar{\omega} = \frac{\omega_1 + \omega_2}{2}$ ,  $\bar{k} = \frac{k_1 + k_2}{2}$ ,  $\Delta \omega = \omega_1 - \omega_2$  e  $\Delta k = k_1 - k_2$ .

Sabemos que a onda resultante apresenta a velocidade angular como a média dos números de ondas e velocidades angulares da fonte. Portanto, a velocidade de fase dessa onda é dada por  $v_p = \frac{\bar{\omega}}{\bar{k}}$ <sup>3</sup>. Enquanto isso, a velocidade de grupo<sup>4</sup> é dado por:

$$v_g = \frac{\Delta \omega}{\Delta k}. \quad (2.18)$$

Tendo em mente as definições de velocidades de grupo e fase, podemos agora analisar no contexto de meios de propagação, no nosso caso, precisaremos analisar para o meio interestelar que é o plasma frio, por definição, sabemos que o índice de refração do plasma frio é dado por:

$$\mu = \left[1 - \left(\frac{\nu_p}{\nu}\right)^2\right]^{1/2}. \quad (2.19)$$

Teremos que  $\nu$  é a frequência da onda e  $\nu_p$  é a frequência de plasma, essa frequência é escrita como:

$$\nu = \left(\frac{q_e^2 n_e}{\pi m_e}\right)^{1/2} \simeq 8,5 \text{kHz} \left(\frac{n_e}{\text{cm}^{-3}}\right)^{1/2}. \quad (2.20)$$

Para o caso onde  $\nu > \nu_p$  a frequência da onda é maior do que a velocidade de fase sendo  $v_p = \frac{w}{k} = c\mu$  e velocidade de grupo  $v_g = \frac{\partial w}{\partial k} = c \left[1 - \left(\frac{\nu_p}{\nu}\right)^2\right]^{1/2}$ .

A interação da radiação com o plasma intergaláctico dispersa as frentes de onda, como cada frequência viaja a uma determinada velocidade. Seja  $\Delta t$  a diferença entre o tempo de chegada de uma onda que se propaga no vácuo em relação a uma se propagando no plasma frio do MI (Meio Interestelar), emitida por uma fonte a uma distância  $d$ , para  $\nu \gg \nu_p$  utilizando o principio da minima ação chegaremos a

<sup>3</sup> Velocidade que acompanha a fase da onda

<sup>4</sup> Velocidade que acompanha a envoltura da onda

$$\Delta t = \left( \int_0^d v_g^{-1} dl - \frac{d}{c} \right) \approx \frac{1}{c} \int_0^d \left( 1 + \frac{\nu_p^2}{2\nu^2} \right) dl - \frac{d}{c} = \frac{q_e^2}{2\pi m_e c} \frac{\int_0^d n_e dl}{\nu^2}. \quad (2.21)$$

Onde a DM é dada por

$$\text{DM} = \int_0^d n_e(l) dl. \quad (2.22)$$

Na expressão acima, a variável  $n_e$  representa a densidade numérica de elétrons,  $l$  corresponde ao comprimento do caminho e  $d$  representa a distância até o FRB, que será estimada mais adiante. É importante observar que, na astronomia de pulsares, a DM é comumente expressa em unidades de distância dada em  $\text{cm}^{-3} \text{ pc}$ . Na prática, a medida da DM pode ser realizada com uma precisão de aproximadamente  $0.1 \text{ cm}^{-3} \text{ pc}$ , dependendo da configuração observacional e da relação sinal-ruído (S/N).

Nessa mesma perspectiva a quantidade de dispersão é calculada pela diferença entre as frequências observadas, respectivamente, alta e baixa, que serão chamadas de  $\nu_{hi}$  e  $\nu_{lo}$ , ou seja, pelo atraso do tempo do pulso, veja o cálculo na equação 2.23.

$$\Delta t = \frac{e^2}{2\pi m_e c} (\nu_{lo}^{-2} - \nu_{hi}^{-2}) \text{DM} \approx 4.15 (\nu_{lo}^{-2} - \nu_{hi}^{-2}) \text{DMms}. \quad (2.23)$$

Uma vez que o valor de DM tenha sido otimizado, uma série temporal dispersa pode ser formada em que a relação sinal/ruído (S/N) do pulso é maximizada. Se essa série temporal puder ser calibrada de forma que a intensidade possa ser convertida em densidade de fluxo como função do tempo,  $S(t)$ , o pulso pode ser caracterizado em termos de sua largura e densidade de fluxo máxima,  $S_{peak}$ . Na prática, o processo de calibração é aproximado a partir de uma medição das flutuações quadráticas médias na série temporal dispersa,  $\sigma_S$ . Considerando a interferência do radiômetro de ruído.

$$\sigma_S = \frac{T_{sys}}{G \sqrt{2\Delta\nu t_{samp}}}. \quad (2.24)$$

Em que,  $T_{sys}$  é a temperatura do sistema,  $G$  é o ganho da antena,  $\Delta\nu$  é a largura de banda do receptor e  $t_{samp}$  é o intervalo de amostragem dos dados.

#### 2.4.1.3 Largura de Pulso

Para cada FRB, a largura de pulso observada,  $W$ , é considerada como uma combinação entre um pulso intrínseco de largura  $W_{int}$  e contribuições de alargamento instrumental. Em geral, a largura do pulso é representada pela equação 2.25

$$W = \sqrt{W_{int}^2 + t_{Samp}^2 + \Delta t_{DM}^2 + \Delta t_{DMerr}^2 + \tau_s^2}, \quad (2.25)$$

em que,  $t_{\text{samp}}$  é o tempo de amostragem como descrito acima,  $\Delta t_{DM}$  é o atraso dispersivo através de um canal de frequência individual e  $\Delta t_{DMerr}$  representa o atraso dispersivo devido à dispersão em uma DM ligeiramente incorreta. Os pulsos FRB também podem ser temporalmente ampliados pela propagação de múltiplos caminhos através de um meio turbulento. O chamado “tempo de espalhamento”  $\tau_s$ .

A largura de pulso é frequentemente medida a 50% e 10% do pico [52]; no entanto, para um pulso de formato arbitrário, é comum citar a largura equivalente  $W_{eq}$  de um pulso em formato de chapéu com o mesmo  $S_{\text{peak}}$ . Esse pulso tem uma energia ou fluência.

## 2.4.2 Fluência e Densidade de Fluxo

A determinação dos valores de densidade ou fluência de fluxo de muitos FRBs é complicada pelo fato de que a posição real da fonte no céu não é conhecida com precisão suficiente para identificá-la de maneira única em relação à posição do feixe. Nesse contexto, “feixe” refere-se ao campo de visão do telescópio de rádio, que é tipicamente limitado pela difração. A sensibilidade em todo o feixe não é uniforme, apresentando uma resposta aproximadamente gaussiana em relação à distância angular em relação ao centro, na maioria dos casos. Como resultado, exceto para os FRBs do ASKAP, a maioria dos valores de fluxo e fluência de FRBs determinados até o momento são considerados limites inferiores. Além disso, a resolução angular limitada das buscas de FRBs, até agora, leva a incertezas típicas na ordem de alguns minutos de arco em relação à posição da fonte.

Como é comumente feito para outras fontes de rádio, as medidas do espectro de densidade de fluxo de FRBs, descritas por  $S_\nu \propto \nu^\alpha$ , onde  $\alpha$  é o índice espectral, são tipicamente complicadas pela pequena largura de banda observacional disponível. Uma complicação adicional surge da má localização dos FRBs dentro do feixe do telescópio, em que, o deslocamento posicional incerto e a resposta variável do feixe com a frequência de rádio podem levar a variações significativas nos valores de  $\alpha$  medidos. Também observamos que um modelo espectral simples de lei de potência pode não ser um modelo ideal do processo de emissão intrínseco de FRB (por exemplo, [35]).

$$\mathcal{F} = S_{\text{peak}} W_{\text{eq}} = \int_{\text{pulse}} S(t) dt. \quad (2.26)$$

Uma exceção às limitações de incerteza posicional é a fonte repetitiva FRB 121102. Observa-se que a densidade de fluxo  $S(t)$ , definida anteriormente, é a integral do fluxo por intervalo de frequência sobre uma banda de observação de  $\nu_{lo}$  a  $\nu_{hi}$ . Para os propósitos da discussão a seguir, e na ausência de qualquer informação espectral, assume-se  $\alpha = 0$ , de forma que

$$S(t) = \int_{\nu_{lo}}^{\nu_{hi}} S_\nu d\nu = (\nu_{hi} - \nu_{lo}) S_\nu. \quad (2.27)$$

### 2.4.3 Propriedades Derivadas Básicas

#### 2.4.3.1 Restrições de distância

Começando com a DM observada, seguimos o que agora está se tornando uma prática padrão (ver, por exemplo [21]) e definimos o excesso de medida de dispersão.

$$DM_E = DM - DM_{MW} = DM_{IGM} + \left( \frac{DM_{Host}}{1+z} \right). \quad (2.28)$$

em que,  $DM_{MW}$  é a contribuição Galáctica (ou seja, da Via Láctea) para essa linha de visão, tipicamente obtida a partir de modelos de densidade de elétrons como NE2001 ou YMW16,  $DM_{IGM}$  é a contribuição do meio intergaláctico (IGM) e  $DM_{Host}$  é a contribuição da galáxia hospedeira. O fator  $(1+z)$  leva em conta a dilatação temporal cosmológica para uma fonte com redshift  $z$ . O último termo do lado direito da equação 2.28 poderia ser dividido em termos de elétrons livres da galáxia hospedeira e locais da fonte, conforme necessário. Em qualquer caso,  $DM_E$  fornece um limite superior para  $DM_{IGM}$ , e de forma mais conservadora  $DM_{IGM} < DM_E$ . Observamos que  $DM_{MW}$  provavelmente é incerto pelo menos em níveis de dezenas de por cento, mas em casos raros pode estar bastante longe se houver regiões  $H_{II}$ <sup>5</sup> não modeladas ao longo da linha de visão.

Para encontrar a relação entre DM e  $z$ , podemos assumir que todo barion possui distribuição homogênea e ionizante, com a fração de ionização  $x(z)$ . Neste caso, a média será:

$$\langle DM_{IGM} \rangle = \int n_{e,IGM} dl = K_{IGM} \int_0^z \frac{(1+z)x(z)dz}{\sqrt{\Omega_m(1+z)^3 + \Omega_\Lambda}}. \quad (2.29)$$

#### 2.4.3.2 Fonte de Luminosidade

Na astronomia, a luminosidade é uma medida importante para entendermos a energia emitida por um objeto celeste. No caso de FRBs, é comum utilizarmos a luminosidade equivalente isotrópica, que representa a quantidade de energia que seria emitida por uma fonte de radiação eletromagnética em todas as direções.

Tendo em mente a distância do FRB junto à largura de banda do pulso observado  $\Delta\nu$ , podemos estimar a luminosidade equivalente isotrópica, teremos a luminosidade sendo calculada como na equação (2.30).

<sup>5</sup> A região  $H_{II}$  é uma região de hidrogênio atômico interestelar que é ionizado. É tipicamente uma nuvem molecular de gás parcialmente ionizado na qual ocorreu recentemente a formação de estrelas, com um tamanho que varia de um a centenas de anos-luz e uma densidade de algumas a cerca de um milhão de partículas por centímetro cúbico. A Nebulosa de Órion, agora conhecida como uma região H II, foi observada em 1610 por Nicolas-Claude Fabri de Peiresc por telescópio, o primeiro objeto desse tipo descoberto.

$$\mathcal{L} \leq \frac{4\pi d_L^2 S \Delta\nu}{(1+z)K_{\Delta\nu}}. \quad (2.30)$$

Nessa equação,  $\mathcal{L}$  é a luminosidade equivalente isotrópica,  $d_L$  é a distância luminosa,  $S\Delta\nu$  é o fluxo observado na largura de banda  $\Delta\nu$ ,  $z$  é o desvio para o vermelho e  $K_{\Delta\nu}$  é o fator de correção K, que leva em consideração o espectro de energia da rajada. Essa equação nos permite estimar a luminosidade da rajada a partir de observações limitadas.

Ao chegar nesta expressão, partimos do fluxo diferencial por intervalo de frequência logarítmica,  $S_\nu\Delta\nu$  no caso mais simples de uma fonte com espectro plano (ou seja,  $S_\nu$  constante). O fator  $(1+z)$  leva em conta o desvio para o vermelho das frequências entre o quadro da fonte e o quadro do observador. Também observamos que, substituindo  $S_\nu$  pela fluência  $F$  na expressão acima, obtemos a liberação de energia isotrópica equivalente para uma fonte com espectro plano.

Como exemplo, teremos o FRB 140514 com DM de  $563 \text{ cm}^{-3} \text{ pc}$  e densidade de fluxo de pico de  $0.5 \text{ Jy}$ . A distância limite de luminosidade é  $d_L < 3.3 \text{ Gpc}$ , ou seja,  $z < 0,56$ . A luminosidade limite é  $\mathcal{L} < 44 \text{ Jy Gpc}^2$  por unidade de largura de banda. Supondo uma largura de banda de  $300 \text{ MHz}$ , isso se traduz em uma liberação de luminosidade de aproximadamente  $10^{17} \text{ W}$  ( $10^{24} \text{ erg s}^{-1}$ ).

### 2.4.3.3 Relação DM-fluxo

Como mostrado por [74], para  $z < 1$ , a distância de luminosidade pode ser diretamente relacionada ao  $DM$  do meio intergaláctico da seguinte forma:

$$d_L \propto \langle DM_{\text{IGM}} \rangle / (K_{\text{IGM}}x(z)) \quad (2.31)$$

Com isso é possível verificar a seguinte relação aproximada útil:

$$\langle DM_{\text{E}} \rangle \simeq K \sqrt{L/S} + \langle DM_{\text{Host}} \rangle \quad (2.32)$$

Na análise, a constante K é determinada a partir dos valores assumidos das constantes na equação (2.31) para uma determinada frequência de observação. A partir disso, foi possível observar uma tendência na amostra analisada, mesmo com uma considerável dispersão. A aplicação desse modelo aos FRBs detectados pelo telescópio de Parkes permitiu que os autores estabelecessem limites para as DMs das galáxias hospedeiras, cuja distribuição se mostrou bastante ampla, com um valor médio de  $DM_{\text{Host}} = 270_{-110}^{+170} \text{ cm}^{-3} \text{ pc}$  e  $L \sim 10^{36} \text{ W}$  ( $\sim 10^{43} \text{ erg s}^{-1}$ ).

### 2.4.3.4 Temperatura de Brilho

Seja  $I_\nu$  a intensidade específica de determinada fonte, com unidades em  $Wm^{-2}Hz^{-1}sr^{-1}$ , teremos a energia  $dE$  medida por um radiotelescópio por unidade de área  $dA$  por banda de frequência  $d\nu$  por unidade de ângulo sólido  $d\Omega$ , chegaremos a:

$$dE = I_\nu dA dt d\nu d\Omega. \quad (2.33)$$

Na radioastronomia utilizaremos conceitos de fluxo produzido pela fonte, que são integrados ao longo de uma banda de frequência  $\delta\nu$  para que o fluxo  $S$  incidente no telescópio seja calculado como  $S_\nu$ .

$$S_\nu = \int_\nu \int_{\Omega_{fonte}} I_\nu d\Omega d\nu. \quad (2.34)$$

Sabendo a intensidade específica podemos associar a temperatura. Essa associação pode ser feita devido as ondas de rádio e seus comprimentos de onda serem tais que  $h\nu \ll kT$ , no domínio de Rayleigh-Jeans da distribuição de corpo negro. Sabemos que a Lei de Planck, que descreve um corpo negro, é dada por:

$$I_\nu = \frac{2h\nu^3}{c^2} \frac{1}{e^{\frac{h\nu}{kT}} - 1}. \quad (2.35)$$

Expandiremos o termo da exponencial em apenas dois termos, na equação (2.35) chegaremos ao seguinte resultado

$$e^{\frac{h\nu}{kT}} = \sum_{n=0}^{\infty} \left( \frac{h\nu}{kT} \right)^n \frac{1}{n!} \approx 1 + \frac{h\nu}{kT}. \quad (2.36)$$

Substituindo (2.36) na equação (2.35), chegaremos ao seguinte resultado.

$$I_\nu = \frac{2\nu^2 kT_B}{c^2}. \quad (2.37)$$

Sabemos que  $T_B$  é a temperatura que um corpo negro deve ter para emitir uma intensidade específica  $I_\nu$ , a chamada temperatura de brilho, utilizada como parâmetro de intensidade para fontes de rádio, inclusive quando a emissão não é térmica. Pode-se expressar a temperatura de brilho como

$$T_B = \frac{S\lambda^2}{2k\Omega}, \quad (2.38)$$

em que,  $\Omega$  é o ângulo sólido compreendido pela fonte,  $\lambda$  o comprimento de onda e  $k$  é a constante de Boltzmann. Nesse caso, o ângulo sólido  $\Omega$  da fonte é dada por  $\Omega = \pi R^2/D^2$  onde  $R$  é o raio da fonte e  $D$  a distância até a fonte observada. Teremos:



$$\Omega \leq \frac{\pi c^2 \delta t^2}{4D^2}. \quad (2.39)$$

Portanto, chegaremos a:

$$T_B \geq \frac{2}{k\pi} \frac{SD^2}{(\nu\delta t)^2}. \quad (2.40)$$

Assim como no caso de outras fontes de rádio, onde o mecanismo de emissão é provavelmente de origem não térmica, muitas vezes é útil citar a temperatura de brilho inferida da fonte,  $T_B$ , que é definida como a temperatura termodinâmica de um corpo negro de luminosidade equivalente. Fazendo argumentos semelhantes aos comumente feitos para pulsares, verificando teremos:

$$T_B \simeq 10^{36} \text{ K} \left( \frac{S_{\text{peak}}}{\text{Jy}} \right) \left( \frac{\nu}{\text{GHz}} \right)^{-2} \left( \frac{W}{\text{ms}} \right)^{-2} \left( \frac{d_L}{\text{Gpc}} \right)^2 \quad (2.41)$$

Novamente avaliando isso para o nosso exemplo FRB 140514 da seção anterior, onde a largura de pulso  $W = 2.8 \text{ ms}$ , encontramos  $T_B < 3.5 \times 10^{35} \text{ K}$ .

#### 2.4.3.5 Efeitos de propagação

Como visto anteriormente, em meios dispersivos a velocidade da luz depende da frequência devido a isso, sabemos que os meios interestelares a qual o FRB percorre é dispersivo, como exemplo desse processo temos o FRB com  $DM = 500 \text{ cm}^{-3}\text{pc}$ , teremos que a frequência desse sinal é de  $1.4 \text{ GHz}$ , tendo isso em mente, é verificado o atraso do sinal em alguns segundos. Nesse sentido, a DM de um FRB será dada por:

$$DM_{\text{FRB}} = DM_{\text{Iono}} + DM_{\text{IPM}} + DM_{\text{ISM}} + DM_{\text{IGM}} + \left( \frac{DM_{\text{Host}} + DM_{\text{Local}}}{1+z} \right), \quad (2.42)$$

Variáveis	Tipo	Contribuição da DM ( $\text{cm}^{-3}\text{pc}$ )
$DM_{\text{Iono}}$	Ionosfera da Terra	$\sim 10^{-5}$
$DM_{\text{IPM}}$	Meio interplanetário do Sistema Solar	$\sim 10^{-3}$
$DM_{\text{ISM}}$	Meio interestelar galáctico	$\sim 10^0 - 10^3$
$DM_{\text{IGM}}$	Meio intergaláctico	$\sim 10^2 - 10^3$
$DM_{\text{Host}}$	Meio interestelar do host da galaxia	$\sim 10^0 - 10^3$
$DM_{\text{Local}}$	Ambiente FRB local	$\sim 10^0 - 10^3$

(2.43)

Onde as contribuições para o DM dessas várias regiões ionizadas estão resumidas na tabela acima. Observe que o  $DM_{\text{Host}}$  e o  $DM_{\text{Local}}$  esperados dependem fortemente de

tipo de host da galáxia e ambiente local e, portanto, pode servir para distinguir entre modelos progenitores.

Existem outras propriedades de propagação como Rotação de Faraday e Cintilação, que não serão relevantes para abordar até o momento .

## 2.5 Redes Neurais

Redes Neurais Artificiais (RNAs) são sistemas projetado para modelar a maneira como o cérebro realiza uma tarefa particular, sendo normalmente implementada utilizando-se componentes eletrônicos ou é simulada por propagação em um computador digital. Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples, denominadas de “neurônios” ou unidades de processamento [33].

O surgimento das redes neurais artificiais deu-se com o modelo matemático do neurônio biológico proposto por Warren McCulloch e Walter Pitts em 1943. No entanto, apenas em 1958, Frank Rosenblatt propôs uma topologia de rede denominada de percéptron constituída por neurônios de múltiplas camadas e arranjada em forma de rede composta de duas camadas, a qual possibilitou um aumento de trabalhos relacionados a redes neurais até 1969. Neste mesmo ano, a publicação de Minsky e Papert mostrou deficiências e limitações nesse modelo, provocando um desinteresse pelos estudos relacionados às RNAs. Somente a partir de 1982, com a publicação do trabalho de Hopfield, foi novamente despertado o interesse pelos estudos relacionados às redes neurais [27].

Devido aos conhecimentos de Frank Rosenblatt, sabe-se hoje que os neurônios desempenham um papel fundamental no funcionamento do cérebro humano, permitindo a execução das atividades diárias. Sua principal função consiste em receber e transmitir sinais. Esse processo ocorre dentro do cérebro, quando os dendritos dos neurônios captam os sinais e os transmitem ao longo do axônio as informações denominadas de sinapses, como mostra a figura 11 [33] [12].




Figura 11 – Representação de uma analogia entre o funcionamento do cérebro humano, com a rede neural computacional. Fonte: [31].

A seguir, analisaremos a estrutura das redes neurais e o seu funcionamento, tendo como visão a parte matemática e computacional.

### 2.5.1 Estrutura da Rede

As redes neurais são divididas em camadas, sendo elas: camadas de entrada, internas e saída como pode ser verificado na Figura 12. Cada camada possui características importantes para avaliar o desempenho do modelo.




Figura 12 – Arquitetura básica das redes neurais. Fonte: Elaborada pelo Autor.

Nessa ótica, a camada de entrada recebe as informações, que são processadas e transformadas na camada interna, após o processamento delas são geradas saídas, que serão analisadas. Por outro lado, para ter um entendimento mais profundo sobre essas camadas iremos analisar de um ponto de vista matemático e computacional nos exemplos do Digit MNIST e Galaxy MNIST, como será visto na Figura 13.




Figura 13 – Modelo não-linear de um neurônio. Fontes: Adaptação de [33] e [53]

A partir da Figura 13 é possível verificar um conjunto de *sinapses* ou *elos* de conexão, cada uma é caracterizada por um *peso*. Sabe-se que, um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  que é multiplicado pelo peso chamado de  $w_{kj}$ . [33]

Posteriormente, é realizado a soma de todos os novos sinais de entrada, ponderados pelos respectivos pesos do neurônio. As operações descritas aqui constituem um combinador linear. Por fim, uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

Matematicamente, teremos as seguintes equações:

$$y_k = \varphi \left( \sum_1^k w_{kj} x_j + b_k \right). \quad (2.44)$$

Sabe-se que  $x_1, x_2, \dots, x_j$  são os sinais de entrada com  $w_{k1}, w_{k2}, \dots, w_{kj}$  são os pesos sinápticos do neurônio  $k$ . O  $b_k$  é o bias. O  $\varphi$  é a função de ativação, posteriormente chamada *softmax*, esse sinal será chamado de  $y_k$ .

Podemos reescrever à equação 2.44 como:

$$y_k = \varphi(v). \quad (2.45)$$

### 2.5.1.1 Camada interna

As camadas internas, também conhecidas como camadas ocultas, são componentes fundamentais que processam informações intermediárias entre a entrada e a saída da rede. Cada camada interna é composta por um conjunto de neurônios interconectados que aplicam transformações matemáticas aos dados de entrada, permitindo à rede neural aprender representações complexas e abstratas dos dados, a partir das funções de ativação.

#### 2.5.1.1.1 Funções de Ativação

As funções de ativação são elementos essenciais das redes neurais artificiais, responsáveis por introduzir não-linearidades e regular a saída dos neurônios com base nas entradas recebidas. Essas funções desempenham um papel fundamental na capacidade de modelar relações complexas. Ao aplicar uma função de ativação em cada neurônio da rede, é possível introduzir comportamentos não lineares nas representações e transformações dos dados ao longo das camadas. Isso permite que as redes realizem tarefas mais sofisticadas, como: classificação, regressão e reconhecimento de padrões. Além disso, as funções de ativação também ajudam a regular controle de propagação de informações através de processos de convergências durante o treinamento. Essa diversidade de funções de ativação disponíveis na literatura permite que os projetistas de redes neurais escolham a função mais adequada para o problema em questão, considerando as características desejadas, como linearidade, não linearidade, limites de ativação, entre outros. [30]

Na literatura, sabe-se que existem algumas funções de ativação a qual são representadas por  $\varphi(v)$ . Elas basicamente decidem se um neurônio deve ser ativado ou não.

Ou seja, se a informação que o neurônio está recebendo é relevante para a informação fornecida ou deve ser ignorada, esse processo é puramente matemático, portanto, serão apresentados logo abaixo as funções de ativações a qual foram utilizadas.

- **Função Binária:** A função de ativação binária, converte um valor contínuo em uma saída representada como 0 ou 1. Essa função introduz não-linearidades na rede neural e é comumente usada em problemas de classificação binária, onde o objetivo é atribuir uma das duas classes possíveis a um determinado exemplo de entrada, sua equação é mostrada abaixo (2.46). [34]

$$\varphi(v) = \begin{cases} 1 & v \geq 0 \\ v & v < 0 \end{cases}, \quad (2.46)$$

- **Função Linear:** É uma função que retorna a mesma saída que a entrada, sem introduzir não-linearidades. Ela realiza uma transformação linear simples, onde o valor de saída é proporcional ao valor de entrada. Essa função é frequentemente utilizada em camadas de saída de redes neurais para problemas de regressão, onde se deseja obter uma saída contínua, sua equação é (2.47), graficamente teremos a figura 14. [11].

$$\varphi(v) = av \quad (2.47)$$




Figura 14 – Representação visual da função linear. Fonte:[8].

- **Função Sigmóide:** É uma função de ativação continuamente diferenciável em todos os pontos, entre 0 e 1, seu formato é em S, ver a figura 15. Assim, torna útil para cálculo de gradientes em métodos de otimização como o Gradiente Descendente. [30]

$$\varphi(v) = \frac{1}{1 + e^{-v}} \quad (2.48)$$




Figura 15 – Comportamento da função Sigmoide. Fonte: [8].

- **Função ReLU:** A função de ativação ReLU (Rectified Linear Unit) é uma função não linear utilizada em redes neurais que retorna zero para valores de entrada negativos e mantém os valores positivos inalterados. Essa função introduz não-linearidades na rede neural e é particularmente útil para lidar com problemas de classificação e aprendizado profundo. Ela permite uma ativação esparsa dos neurônios, o que pode ajudar a superar o problema do gradiente desvanecente durante o treinamento. Sua equação é dada pela seguinte expressão. [48]

$$\varphi(v) = \max(0, v) \quad (2.49)$$




Figura 16 – Comportamento da função ReLU. Fonte: [8].

- **Função Leaky ReLU:** Esta é uma modificação da função ReLU, que ao invés de zerar os valores negativos, aplica a eles um fator de divisão, tornando-os muito pequenos (próximos de zero). Leaky significa “vazando”, que é a ideia por trás dessa função. Esse comportamento tende a resolver alguns dos problemas da função ReLU relacionados aos valores zerados.

$$\varphi(v) = a \times \max(0, x) + b \quad (2.50)$$




Figura 17 – Comportamento da função Leaky ReLU. Fonte:[8].

- **Função Tanh:** A função tanh gera valores no intervalo de -1 a +1. Isso significa que ela pode lidar com valores negativos de forma mais eficaz do que a função sigmoide, que tem um intervalo de 0 a 1. (Figura 18 )

Ao contrário da função sigmoide, a tanh é centrada em zero, o que significa que sua saída é simétrica em torno da origem do sistema de coordenadas. Isso geralmente é considerado uma vantagem, pois pode ajudar o algoritmo de aprendizado a convergir mais rapidamente.

Como a saída de tanh varia entre -1 e +1, ela tem gradientes mais fortes do que a função sigmoide. Em que, geralmente, resultam em aprendizado e convergência mais rápidos durante o treinamento porque tendem a ser mais resistentes ao problema de gradientes que desaparecem quando comparados aos gradientes da função sigmoide.






Figura 18 – Na figura, é possível verificar a função Tanh, onde pode assumir valores negativos centrado na origem. Fonte:[8].

#### 2.5.1.1.2 Função de saída: Softmax

A função de softmax que chamaremos  $\sigma$  é uma função utilizada para mapear um vetor de valores de entrada em uma distribuição de probabilidade. Ela é amplamente empregada na camada de saída de redes neurais para problemas de classificação multiclasse, onde o objetivo é atribuir probabilidades para cada classe possível.

Por definição, a função softmax recebe como entrada um vetor  $z$  de  $K$  números reais e o normaliza em uma distribuição de probabilidade que consiste em  $K$  probabilidades proporcionais aos exponenciais dos números de entrada. Ou seja, antes de aplicar a softmax, alguns componentes do vetor podem ser negativos ou maiores que um e podem não somar 1, mas, após aplicar a softmax, cada componente estará no intervalo  $(0, 1)$ , e os componentes serão somados a 1, de modo que possam ser interpretados como probabilidades. Além disso, os componentes de entrada maiores corresponderão a probabilidades maiores.

A função softmax padrão (unitária)  $\sigma : \mathbb{R}^K \mapsto (0, 1)^K$ , na qual  $K \geq 1$  define-se por

$$\sigma(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}, \quad i = 1, \dots, k \quad (2.51)$$

$$\mathbf{z} = (z_1, \dots, z_K) \in \mathbb{R}^K \quad (2.52)$$

Em outras palavras, é aplicada a função exponencial padrão a cada elemento  $z_i$  e esses valores são normalizados dividindo-se pela soma de todos esses exponenciais. A normalização garante que a soma dos componentes do vetor de saída  $\sigma(z)$  seja 1. O termo "softmax" deriva dos efeitos de amplificação do exponencial em qualquer máximo no vetor de entrada

Em geral, em vez de  $e$ , uma base diferente  $b > 0$  pode ser usada. Se  $0 < b < 1$ , componentes de entrada menores resultarão em probabilidades de saída maiores, e a diminuição do valor de  $b$  criará distribuições de probabilidade mais concentradas em torno das posições dos menores valores de entrada.

Por outro lado, como acima, se  $b > 1$  componentes de entrada maiores resultarão em probabilidades de saída maiores, e o aumento do valor de  $b$  criará distribuições de probabilidade mais concentradas em torno das posições dos maiores valores de entrada. Escrever  $b = \exp \beta$ , produz a expressão:

$$\sigma(\mathbf{z})_i = \frac{e^{\beta z_i}}{\sum_{j=1}^K e^{\beta z_j}} \text{ ou } \sigma(\mathbf{z})_i = \frac{e^{-\beta z_i}}{\sum_{j=1}^K e^{-\beta z_j}} \text{ for } i = 1, \dots, K \quad (2.53)$$

Essa fórmula calcula a probabilidade relativa  $p_i$  para cada elemento  $x_i$  da entrada, onde o denominador é a soma exponencial de todos os elementos do vetor de entrada. A função softmax mapeia o vetor de entrada em um novo vetor de saída com valores normalizados representando probabilidades. [30]

## 2.5.2 Usando redes neurais para reconhecer dígitos manuscritos

O conjunto de dados MNIST, são divididos em dois tipos de conjuntos, testes e treinos, o conjunto de treino consiste em 60.000 pequenas imagens de dígitos escritas à mão digitalizadas de 250 pessoas por alunos do ensino médio e funcionários do *US Census Bureau*. As imagens são em escala de cinza e 28 por 28 pixels de tamanho e cada imagem é rotulada com o dígito que representa. Enquanto, o conjunto de teste contém 10.000 imagens a serem usadas como forma de testar o programa.

Para entender melhor esses dados será mostrado com detalhes os dígitos, considere a seguinte sequência de dígitos manuscritos:

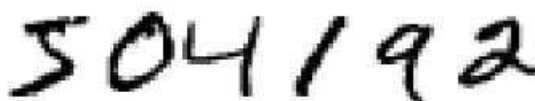


Figura 19 – Sequência de dígitos. Fonte: [49].

A partir da figura 19 identificamos os dígitos "5 0 4 1 9 2", nosso entendimento dos dígitos são facilmente processados com o nosso cérebro, mas como nosso cérebro identifica esses dados?

Em cada hemisfério do nosso cérebro, possui um córtex visual primário, também conhecido como  $V1$ , contendo 140 milhões de neurônios, com dezenas de bilhões de

conexões entre eles. E, no entanto, a visão humana envolve não apenas  $V1$ , mas toda uma série de córtices visuais –  $V2$ ,  $V3$ ,  $V4$  e  $V5$  – fazendo um processamento de imagem progressivamente mais complexo. [49]




Figura 20 – A imagem representa um conjunto de dígitos manuscritos dos dados MNIST, separados em 6 imagens diferentes. Fonte: [49].

Com o conjunto de dados dividido em diferentes imagens, podemos classificá-los por rótulos, onde classificaremos os dados de treino e testes. Posteriormente a isso, iremos elaborar uma rede neural com 3 camadas, como mostra a figura 21.




Figura 21 – Arquitetura da rede neural do Digit MNIST. Fonte: [49]

A camada de entrada da rede contém neurônios que codificam os valores dos pixels de entrada. Conforme discutido na próxima seção, nossos dados de treinamento para a rede consistirão em muitas imagens de 28 por 28 pixels de dígitos manuscritos digitalizados e, portanto, a camada de entrada contém  $784 = 28 \times 28$  neurônios. Para simplificar, omiti a maioria dos 784 neurônios de entrada no diagrama acima. Os pixels de entrada são em tons de cinza, com um valor de 0,0 representando branco, um valor de 1,0 representando preto e valores intermediários representando tons de cinza gradualmente escurecidos.

A segunda camada da rede é uma camada oculta. Denotamos o número de neurônios nessa camada oculta por  $n$  e experimentaremos diferentes valores para  $n$ . O exemplo mostrado ilustra uma pequena camada oculta, contendo apenas  $n = 15$  neurônios. A camada de saída da rede contém 10 neurônios. Se o primeiro neurônio disparar, ou seja, tiver uma saída  $\approx 1$ , isso indicará que a rede pensa que o dígito é 0. Se o segundo neurônio disparar, isso indicará que a rede pensa que o dígito é 1. E assim por diante. Com um pouco mais de precisão, numeramos os neurônios de saída de 0 a 9 e descobrimos qual neurônio tem o maior valor de ativação. Se esse neurônio for, digamos, o neurônio número 6, nossa rede adivinhará que o dígito de entrada é 6. E assim por diante para os outros neurônios de saída.

### 2.5.2.1 Gradiente

Com o intuito de aprofundar o entendimento das redes, teremos várias entradas conhecidas como  $x$ , onde cada entrada no vetor representa escala de cinza para um único pixel na imagem. Denotaremos a saída desejada correspondente por  $y = y(x)$ , onde  $y$  é um vetor de 10 dimensões. Por exemplo, se uma determinada imagem de treinamento,  $x$ , representa um **6**, então  $y(x) = (0, 0, 0, 0, 0, 0, 1, 0, 0, 0)^T$  é a saída desejada da rede. Observe que  $T$  aqui é a operação de transposição, transformando um vetor linha em um vetor comum (coluna).

O objetivo desse estudo é construir um algoritmo que nos permita encontrar pesos e biases para que a saída da rede se aproxime de  $y(x)$  para todas as entradas de treinamento  $x$ . Para quantificar o quão bem estamos alcançando esse objetivo, definimos uma função de custo ou cost function, essa função é escrita como:

$$C(w, b) \equiv \frac{1}{2n} \sum_x \| y(x) - a \|^2 \quad (2.54)$$

## 2.5.3 Implementando nossa rede para classificar dígitos MNIST

Será construído uma rede neural simples com o objetivo de reconhecer dígitos manuscritos usando o conjunto de dados *MNIST*. Nesse sentido, essa seção será dividida por partes para o melhor entendimento do código.

Os dados do *MNIST* contém 60.000 imagens de dígitos manuscritos: 60.000 para treinamento e 10.000 para teste. As imagens são em tons de cinza,  $28 \times 28$  pixels e centralizadas para reduzir o pré-processamento e começar mais rapidamente. O *Keras* é uma *API* de rede neural de alto nível focada na facilidade de uso, prototipagem rápida, modularidade e extensibilidade. Ele funciona com estruturas de aprendizado profundo como *Tensorflow*, *Theano* e *CNTK*. [65] [67]

Será iniciado a ambientação implementando com *Keras* com os pacotes *matplotlib*, *numpy*, e *Tensorflow*. [66] [26] [9]

Nas próximas seções serão apresentadas a codificação que foi utilizada como base na escrita do código do nosso modelo.

### 2.5.3.1 Importação dos dados

```
input:
1 import numpy as np
2 import matplotlib
3 matplotlib.use('agg') #backend
4 import matplotlib.pyplot as plt
5 %matplotlib inline
6
7 import os
8 os.environ['TF_CPP_MIN_LOG_LEVEL']='3'
9
10 import tensorflow
11 from tensorflow.keras.datasets import mnist
12 from tensorflow.keras.models import Sequential, load_model
13 from tensorflow.keras.layers import Dense, Dropout, Activation
14 from tensorflow.keras.utils import to_categorical
15 from tensorflow.keras import Model
```

Posteriormente foi iniciado a implementação dos dados usando a função prática que divide os dados MNIST em conjuntos de treinamento e teste.

```
input:
1 (X_train, y_train), (X_test, y_test) = mnist.load_data()
2 X_train[0];
```

Nesse passo serão apresentado alguns exemplos. O conjunto de dados MNIST contém apenas imagens em tons de cinza. Para conjuntos de dados de imagem mais avançados, teremos os três canais de cores (RGB).

```
input:
1 fig = plt.figure()
2 for i in range(9):
3     plt.subplot(3,3,i+1)
4     plt.tight_layout() #serve para fazer os espaçamentos internos entre
       os plots
5     plt.imshow(X_train[i], cmap='gray', interpolation='none')
6     plt.title("Digit: {}".format(y_train[i]))
7     plt.xticks([])
8     plt.yticks([])
```

Out:

Analisando apenas um caso, com o dígito '5' teremos que:




Figura 22 – Na imagem é possível verificar que a fim de treinar nossa rede neural para classificar imagens, primeiro temos que desenrolar o formato de pixel altura largura em um grande vetor - o vetor de entrada. Portanto, seu comprimento deve ser  $28 \cdot 28 = 784$ . Mas vamos representar graficamente a distribuição de nossos valores de pixel. Fonte: Pelo autor com base na referencia [39].

```
input:
1 fig = plt.figure()
2 plt.subplot(2,1,1)
3 plt.imshow(X_train[0], cmap='gray', interpolation='none')
4 plt.title("Digit: {}".format(y_train[0]))
5 plt.xticks([])
6 plt.yticks([])
7 plt.subplot(2,1,2)
8 plt.hist(X_train[0].reshape(784))
9 plt.title("Pixel Value Distribution")
```

output:

Na imagem 2.5.3.1 é apresentado um histograma que apresenta os dados. Teremos que os valores de pixel variam de 0 a 255: a maioria do plano de fundo próximo a 0 e os próximos a 255 representando o dígito.

A normalização dos dados de entrada ajuda a acelerar o treinamento. Além disso, reduz a chance de ficar preso em ótimos locais, já que estamos usando a descida de gradiente estocástica para encontrar os pesos ideais para a rede.

Vamos remodelar nossas entradas para um único vetor vetorial e normalizar os valores de pixel para ficar entre 0 e 1.

```
input:
1 # let's print the shape before we reshape and normalize
2 print("X_train shape", X_train.shape)
3 print("y_train shape", y_train.shape)
```

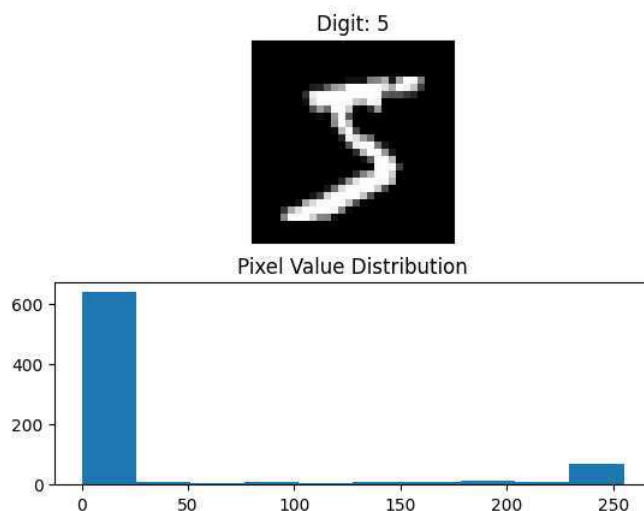


Figura 23 – Histograma da quantidade de pixels relacionados a seus respectivos valores na escala de cinza, deve ser destacado que essa escala varia de 0 a 255. Fonte: Pelo autor com base na referência [39].

```

4 print("X_test shape", X_test.shape)
5 print("y_test shape", y_test.shape)
6
7 # building the input vector from the 28x28 pixels
8 X_train = X_train.reshape(60000, 784)
9 X_test = X_test.reshape(10000, 784)
10 X_train = X_train.astype('float32')
11 X_test = X_test.astype('float32')
12
13 # normalizing the data to help with the training
14 X_train /= 255
15 X_test /= 255
16
17 # print the final input shape ready for training
18 print("Train matrix shape", X_train.shape)
19 print("Test matrix shape", X_test.shape)

```

**Out:**

```

X_train shape (60000, 28, 28)
y_train shape (60000,)
X_test shape (10000, 28, 28)
y_test shape (10000,)
Train matrix shape (60000, 784)
Test matrix shape (10000, 784)

```

Realizando a normalização e transformando em 1 D (dimensão) teremos a seguinte representação como mostra na figura 24.

Portanto, pensando no conjunto dos dados com as 55.000 imagens do MNIST podemos reescrever como um tensor n-dimensional array, como mostra a figura 25.




Figura 24 – Representação da normalização dos dados. Fonte: [20]




Figura 25 – visualização do conjunto de dados. Fonte: [20]

Até agora, a verdade (Y na linguagem de aprendizado de máquina) que usaremos para treinamento ainda contém valores inteiros de 0 a 9.

```
input:
1 print(np.unique(y_train, return_counts=True))
Out:
(array([0, 1, 2, 3, 4, 5, 6, 7, 8, 9], dtype=uint8), array([5923, 6742,
5958, 6131, 5842, 5421, 5918, 6265, 5851, 5949]))
```

Vamos codificar nossas categorias - dígitos de 0 a 9 - usando codificação `one-hot`. O resultado é um vetor com comprimento igual ao número de categorias. O vetor é todo zero, exceto na posição da respectiva categoria. Assim, um '5' será representado por `[0,0,0,0,1,0,0,0,0]`.

```
input:
1 # one-hot encoding using keras' numpy-related utilities
2 n_classes = 10
```



```

3 print("Shape before one-hot encoding: ", y_train.shape)
4 Y_train = np_utils.to_categorical(y_train, n_classes)
5 Y_test = np_utils.to_categorical(y_test, n_classes)
6 print("Shape after one-hot encoding: ", Y_train.shape)

```

Out:

```

Shape before one-hot encoding: (60000,)
Shape after one-hot encoding: (60000, 10)

```

### 2.5.3.2 Construindo a Rede

Vamos recorrer a Keras para construir uma rede neural como pode ser visto na figura 26.




Figura 26 – Exemplo de construção de rede, utilizando outra arquitetura, onde teremos 784 entradas, que passará por duas camadas internas de 512 nós, com 10 saídas. Fonte: [39].

Nosso vetor de pixel serve como entrada. Em seguida, duas camadas ocultas de 512 nós, com complexidade de modelo suficiente para reconhecer dígitos. Para a classificação multiclasse, adicionamos outra camada densamente conectada (ou totalmente conectada) para as 10 classes de saída diferentes. Para esta arquitetura de rede podemos utilizar o Modelo Sequencial Keras. Podemos empilhar camadas usando o método `.add()`.

Ao adicionar a primeira camada no Modelo Sequencial, precisamos especificar a forma de entrada para que Keras possa criar as matrizes apropriadas. Para todas as camadas restantes, a forma é inferida automaticamente.

A fim de introduzir não linearidades na rede e elevá-la além das capacidades de um simples perceptron <sup>6</sup>, também adicionamos funções de ativação às camadas ocultas. A diferenciação para o treinamento via back-propagation está acontecendo nos bastidores sem a necessidade de implementar os detalhes.

Também adicionamos *dropout* como uma forma de evitar overfitting. Aqui, mantemos aleatoriamente alguns pesos de rede fixos quando normalmente os atualizávamos para que a rede não dependa muito de poucos nós.

<sup>6</sup> É um modelo de rede neural artificial que consiste em um único neurônio de processamento.[58]

A última camada consiste em conexões para nossas 10 classes e a ativação *softmax* que é padrão para alvos multiclasse.

```
input:
1 # building a linear stack of layers with the sequential model
2 model = Sequential()
3 model.add(Dense(512, input_shape=(784,)))
4 model.add(Activation('relu'))
5 model.add(Dropout(0.2))
6
7 model.add(Dense(512))
8 model.add(Activation('relu'))
9 model.add(Dropout(0.2))
10
11 model.add(Dense(10))
12 model.add(Activation('softmax'))
13
14 model.summary()
```

Out:

Model: "sequential"

Layer (type)	Output Shape	Param
dense (Dense)	(None, 512)	401920
activation (Activation)	(None, 512)	0
dropout (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 10)	5130
activation_1 (Activation)	(None, 10)	0

Total params: 407,050

Trainable params: 407,050

Non-trainable params: 0

A função *softmax* tem como objetivo preparar a saída a partir de uma regressão que retorna uma lista de valores entre 0 e 1, onde esses valores são representados como probabilidades onde a soma de todos os valores resultam em 1.

Então, podemos imaginar que, se tivermos uma lista com 10 rótulos potenciais de zero a nove, quando aplicamos a *softmax*, obtemos uma lista de 10 probabilidades e quando você soma essas probabilidades o resultado é igual a 1.

Isso significa que basicamente escolheremos qualquer rótulo que tenha a maior probabilidade de está correto. Logo, sabe-se que geralmente não obterá 100% para uma probabilidade, em vez disso, obterá uma probabilidade relativamente alta para um rótulo,

então, talvez a segunda maior probabilidade para um número de aparência semelhante e então todo o resto não terá zero, mas, algo muito próximo a zero, porque nunca é 100%.

### 2.5.3.3 Compilando e treinando o modelo

Agora que o modelo está pronto, configuramos o processo de aprendizado usando `.compile()`. Aqui especificamos nossa função de perda (ou função objetivo). Para nossa configuração, a entropia cruzada categórica é adequada, mas, em geral, outras funções de perda estão disponíveis.

Quanto ao otimizador de escolha, usaremos Adam com configurações padrão. Também poderíamos instanciar um otimizador e definir parâmetros antes de passá-lo para `model.compile()`, mas para este exemplo os padrões servirão.

Também escolhemos quais métricas serão avaliadas durante o treinamento e teste. Podemos passar qualquer lista de métricas - até mesmo criar métricas nós mesmos - e exibi-las durante o treinamento/teste. Vamos nos ater à precisão por enquanto.

```
input:
1 # compiling the sequential model
2 model.compile(loss='categorical_crossentropy', metrics=['accuracy'],
  optimizer='adam')
```

Tendo compilado nosso modelo, podemos agora iniciar o processo de treinamento. Temos que especificar quantas vezes queremos iterar em todo o conjunto de treinamento (épocas) e quantas amostras usamos para uma atualização dos pesos do modelo (tamanho do lote). Geralmente, quanto maior o lote, mais estáveis serão nossas atualizações de descida de gradiente estocástico. Mas cuidado com as limitações de memória da GPU! Estamos indo para um tamanho de lote de 128 e 8 épocas.

Para controlar nosso progresso de treinamento, também representamos graficamente a curva de aprendizado de nosso modelo, observando a perda e a precisão. Enquanto isso, para trabalhar com o modelo treinado e avaliar seu desempenho, salvamos o modelo em `/results/`.

```
input:
1 # training the model and saving metrics in history
2 history = model.fit(X_train, Y_train,
3     batch_size=128, epochs=20,
4     verbose=2,
5     validation_data=(X_test, Y_test))
6
7 # saving the model
8 save_dir = "/results/"
9 model_name = 'keras_mnist.h5'
10 model_path = os.path.join(save_dir, model_name)
```

```
11 model.save(model_path)
12 print('Saved trained model at %s ' % model_path)
13
14 # plotting the metrics
15 fig = plt.figure()
16 plt.subplot(2,1,1)
17 plt.plot(history.history['acc'])
18 plt.plot(history.history['val_acc'])
19 plt.title('model accuracy')
20 plt.ylabel('accuracy')
21 plt.xlabel('epoch')
22 plt.legend(['train', 'test'], loc='lower right')
23
24 plt.subplot(2,1,2)
25 plt.plot(history.history['loss'])
26 plt.plot(history.history['val_loss'])
27 plt.title('model loss')
28 plt.ylabel('loss')
29 plt.xlabel('epoch')
30 plt.legend(['train', 'test'], loc='upper right')
31
32 plt.tight_layout()
33
34 fig
```

**Out:**

Train on 60000 samples, validate on 10000 samples

Epoch 1/20

- 4s - loss: 0.2479 - acc: 0.9258 - val\_loss: 0.1036 - val\_acc: 0.9666

Epoch 2/20

- 3s - loss: 0.0997 - acc: 0.9694 - val\_loss: 0.0812 - val\_acc: 0.9740

Epoch 3/20

- 3s - loss: 0.0734 - acc: 0.9773 - val\_loss: 0.0694 - val\_acc: 0.9790

Epoch 4/20

- 3s - loss: 0.0545 - acc: 0.9820 - val\_loss: 0.0765 - val\_acc: 0.9756

Epoch 5/20

- 3s - loss: 0.0469 - acc: 0.9841 - val\_loss: 0.0671 - val\_acc: 0.9791

Epoch 6/20

- 3s - loss: 0.0389 - acc: 0.9876 - val\_loss: 0.0612 - val\_acc: 0.9820

Epoch 7/20

- 3s - loss: 0.0334 - acc: 0.9884 - val\_loss: 0.0665 - val\_acc: 0.9808

Epoch 8/20

- 3s - loss: 0.0287 - acc: 0.9902 - val\_loss: 0.0618 - val\_acc: 0.9831

Epoch 9/20

- 3s - loss: 0.0291 - acc: 0.9901 - val\_loss: 0.0596 - val\_acc: 0.9828

Epoch 10/20

- 3s - loss: 0.0251 - acc: 0.9917 - val\_loss: 0.0705 - val\_acc: 0.9799

Epoch 11/20

- 3s - loss: 0.0242 - acc: 0.9922 - val\_loss: 0.0708 - val\_acc: 0.9817

```
Epoch 12/20
- 3s - loss: 0.0205 - acc: 0.9932 - val_loss: 0.0751 - val_acc: 0.9810
Epoch 13/20
- 3s - loss: 0.0233 - acc: 0.9923 - val_loss: 0.0668 - val_acc: 0.9842
Epoch 14/20
- 3s - loss: 0.0191 - acc: 0.9940 - val_loss: 0.0887 - val_acc: 0.9791
Epoch 15/20
- 3s - loss: 0.0178 - acc: 0.9944 - val_loss: 0.0794 - val_acc: 0.9834
Epoch 16/20
- 3s - loss: 0.0179 - acc: 0.9941 - val_loss: 0.0707 - val_acc: 0.9836
Epoch 17/20
- 3s - loss: 0.0180 - acc: 0.9947 - val_loss: 0.0873 - val_acc: 0.9801
Epoch 18/20
- 3s - loss: 0.0181 - acc: 0.9938 - val_loss: 0.0723 - val_acc: 0.9836
Epoch 19/20
- 3s - loss: 0.0147 - acc: 0.9954 - val_loss: 0.0786 - val_acc: 0.9834
Epoch 20/20
- 3s - loss: 0.0145 - acc: 0.9956 - val_loss: 0.0741 - val_acc: 0.9822
Saved trained model at /results/keras_mnist.h5
```

Out:

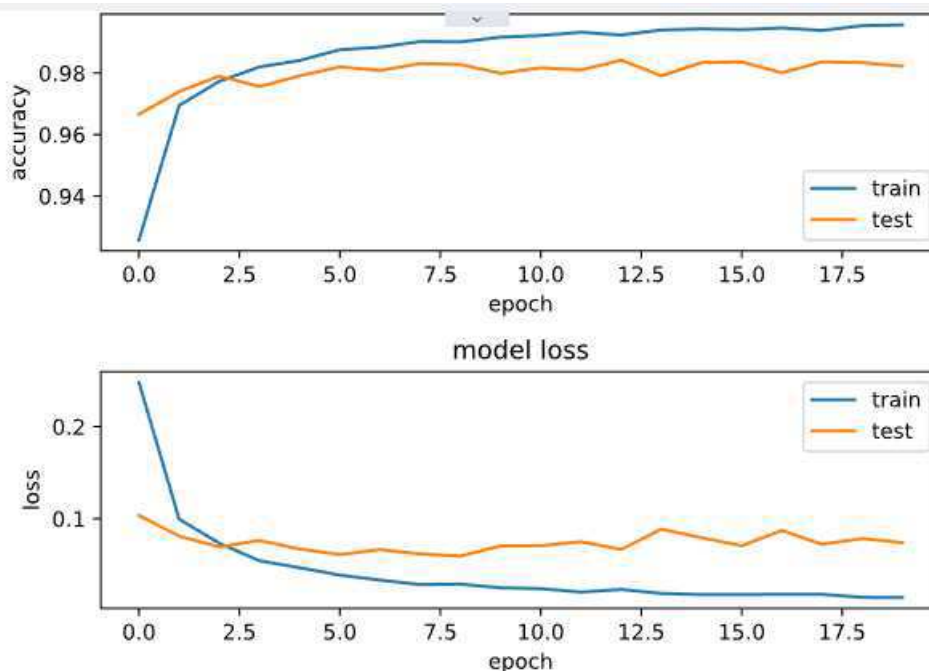


Figura 27 – Esse gráfico representa a precisão (accuracy) e perda (loss) dos dados de treino e testes. Fonte: [49]

Analisando a figura 27, vemos que a perda no conjunto de treinamento está diminuindo rapidamente nas duas primeiras épocas. Isso mostra que a rede está aprendendo a classificar os dígitos rapidamente. Para o conjunto de teste, a perda não diminui tão rápido, mas permanece aproximadamente na mesma faixa da perda de treinamento. Isso significa que nosso modelo generaliza bem para dados não vistos.

### 2.5.3.4 Avalie o desempenho do modelo

Nessa seção iremos analisar o desempenho do modelo no conjunto de teste. O método `model.evaluate()` calcula a perda e qualquer métrica definida ao compilar o modelo. Portanto, em nosso caso, a precisão é calculada nos 10.000 exemplos de teste usando os pesos de rede fornecidos pelo modelo salvo.

input:

```
1 mnist_model = load_model()
2 loss_and_metrics = mnist_model.evaluate(X_test, Y_test, verbose=2)
3
4 print("Test Loss", loss_and_metrics[0])
5 print("Test Accuracy", loss_and_metrics[1])
```

Out:

```
Test Loss 0.07407343140110847
Test Accuracy 0.9822
```

input:

```
1
2 mnist_model = load_model()
3 predicted_classes = mnist_model.predict_classes(X_test)
4
5
6 correct_indices = np.nonzero(predicted_classes == y_test)[0]
7 incorrect_indices = np.nonzero(predicted_classes != y_test)[0]
8 print()
9 print(len(correct_indices), " classified correctly")
10 print(len(incorrect_indices), " classified incorrectly")
11
12
13 plt.rcParams['figure.figsize'] = (7,14)
14
15 figure_evaluation = plt.figure()
16
17
18 for i, correct in enumerate(correct_indices[:9]):
19     plt.subplot(6,3,i+1)
20     plt.imshow(X_test[correct].reshape(28,28), cmap='gray',
21               interpolation='none')
22     plt.title(
23         "Predicted: {}, Truth: {}".format(predicted_classes[correct],
24                                           y_test[correct]))
25     plt.xticks([])
26     plt.yticks([])
27
28 for i, incorrect in enumerate(incorrect_indices[:9]):
29     plt.subplot(6,3,i+10)
```

```
30 plt.imshow(X_test[incorrect].reshape(28,28), cmap='gray',
interpolation='none')
31 plt.title(
32     "Predicted {}, Truth: {}".format(predicted_classes[incorrect],
33                                     y_test[incorrect]))
34 plt.xticks([])
35 plt.yticks([])
36
37 figure_evaluation
```

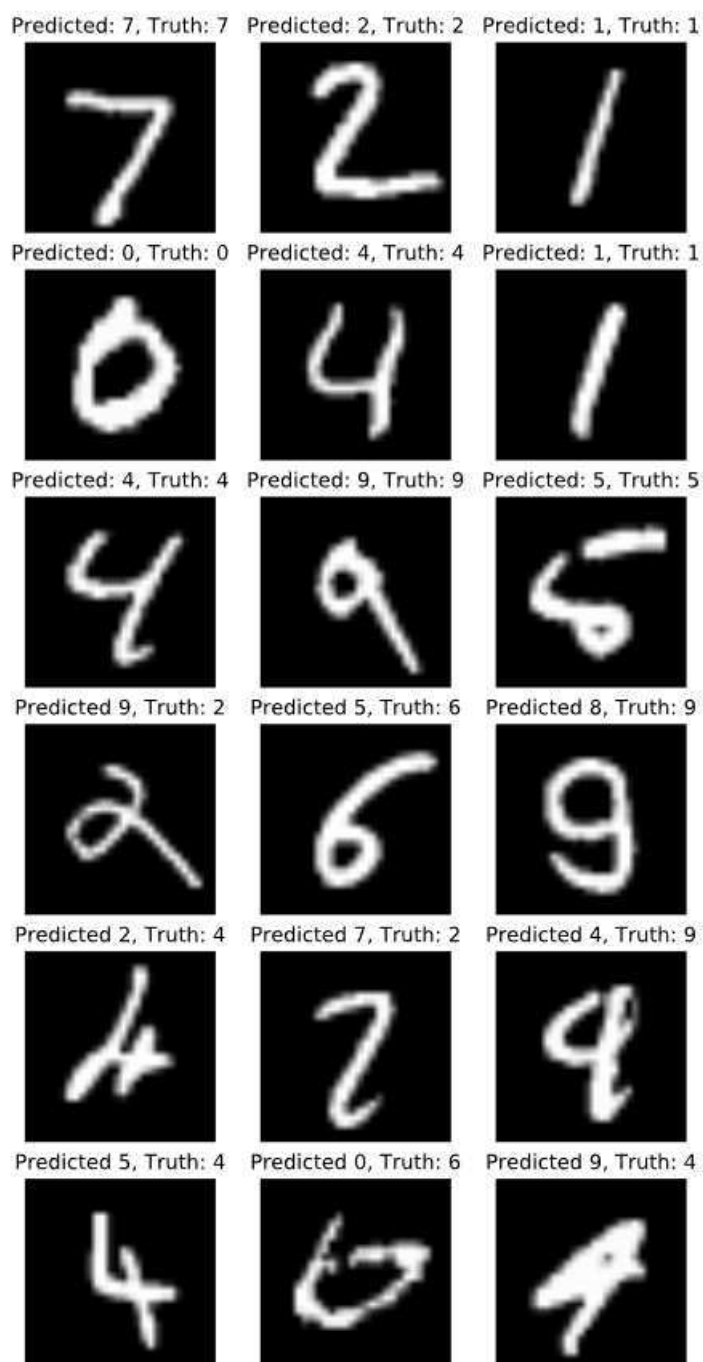


Figura 28 – Nesse grafico verificamos um comparativo entre as previsões geradas pela rede neural treinada, junto, aos seus respectivos valores verdadeiros. Fonte: Elaborada pelo Autor.

**Out:**

```
9822 classified correctly  
178 classified incorrectly
```

Chegaremos ao seguinte resultado, mostrado na figura 28.



### 2.5.3.5 Galaxy MNIST

GalaxyMNIST é um conjunto de dados de 10.000 imagens de galáxias marcadas como pertencentes a uma das quatro classes morfológicas que são: Smooth round, Smooth cigar, Edge on disk e Unbarred spiral que será vista na imagem 29 .




Figura 29 – Amostra do banco de dados Galaxy MNIST. Fonte: [2]

Diferente do Digit Mnist a qual o objetivo principal era classificar dígitos de 0 à 9 visto na seção 2.5.3, no caso do Galaxy Mnist a classificação será dada devido as suas respectivas classes morfológicas, o que resultará em 4 classificações.

Para dar inicio a rede, importaremos os dados onde consiste em 8000 dados de treino e 2000 dados de teste, o conjunto de dados é do tipo (8000, 3, 64 ,64) com 8000 labels. O conjunto de labels é dividido entre de 0 à 3 ('smooth round', 'smooth cigar', 'edge on disk', 'unbarred spiral').

O próximo passo será construir a rede neural, onde sua arquitetura consiste em 3 camadas densas com função de ativação ReLU e uma camada densa com função de ativação Softmax com 4 saídas.

De forma resumida teremos:

$(3, 64, 64) \mapsto (12288) \mapsto (512) \mapsto (512) \mapsto (512) \mapsto (4)$

```
input:
1 model = tf.keras.models.Sequential()
2
3 # Flatten the 3x64x64 array into a a one-dimensional array.
```

```
4 model.add(tf.keras.layers.Flatten(input_shape=(3, 64, 64)))
5
6 # Hidden layers and dropout regularization layers
7 model.add(tf.keras.layers.Dense(units=512, activation='relu'))
8 model.add(tf.keras.layers.Dropout(rate=0.2))
9
10 model.add(tf.keras.layers.Dense(units=512, activation='relu'))
11 model.add(tf.keras.layers.Dropout(rate=0.2))
12
13 model.add(tf.keras.layers.Dense(units=512, activation='relu'))
14 model.add(tf.keras.layers.Dropout(rate=0.2))
15
16 # Output layer, 4 classes
17 model.add(tf.keras.layers.Dense(units=4, activation='softmax'))
18
19 # Create model
20 model.compile(optimizer=tf.keras.optimizers.Adam(lr=my_learning_rate),
21               loss="sparse_categorical_crossentropy",
22               metrics=['accuracy'])
```

Com o treinamento da rede chegamos a precisão da rede melhora à medida que a fase de treinamento avança e parece diminuir após cerca de 50 épocas como mostra na figura

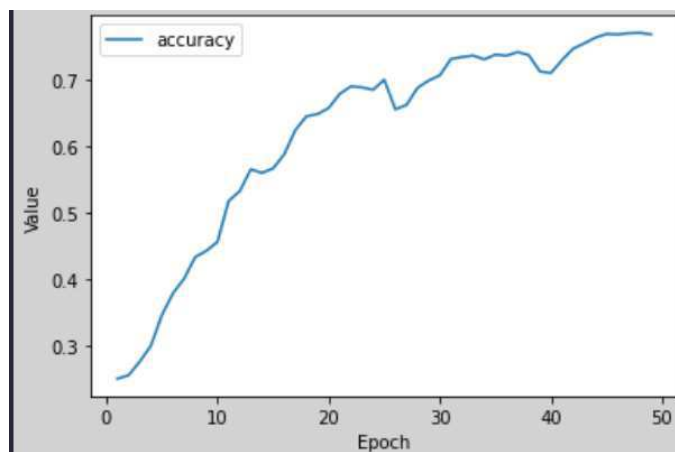


Figura 30 – Resultado do treinamento do modelo, que teve 70% de precisão (accuracy) Galaxy MNIST. Fonte: [2]

A precisão no conjunto de teste é de 70%. Observe que as quatro classes contêm um número semelhante de exemplos (se houvesse um desequilíbrio, a precisão não seria muito informativa).

Por fim, para que possamos visualizar melhor os resultados do treinamento junto com o teste, podemos visualizar a partir da matriz de confusão que nada mais é que uma ferramenta utilizada para avaliar o desempenho de um modelo de classificação. É uma

matriz retangular que mostra a contagem dos resultados corretos e incorretos produzidos pelo modelo em relação a um conjunto de dados de teste conhecidos, como pode ser verificado na figura 32.

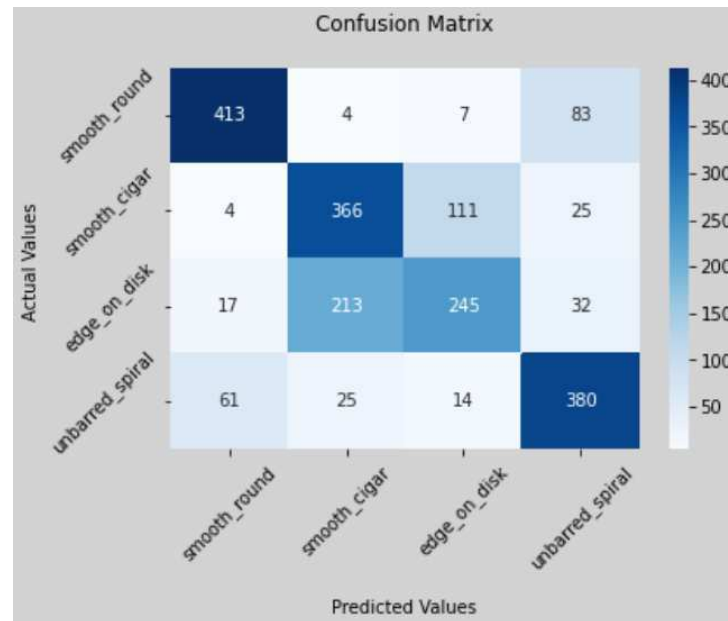


Figura 31 – Resultado plotado na confusion matrix, onde mostra a previsão com os valores verdadeiros. Fonte: [2]

Tendo em mente esses resultado, tomamos a liberdade de verificar outro modelo de arquitetura de treinamento consiste em 4 convoluções com função de ativação ReLU no entanto com tamanhos diferentes, respectivamente, 64,128,256 e 512, por fim uma saída de 4 classes.

input:

```

1 model = tf.keras.models.Sequential()
2
3 # Flatten the 3x64x64 array into a a one-dimensional array.
4 model.add(tf.keras.layers.Flatten(input_shape=(3, 64, 64)))
5
6 # Hidden layers and dropout regularization layers
7 model.add(tf.keras.layers.Dense(units=64, activation='relu'))
8 model.add(tf.keras.layers.Dropout(rate=0.2))
9
10 model.add(tf.keras.layers.Dense(units=128, activation='relu'))
11 model.add(tf.keras.layers.Dropout(rate=0.2))
12
13 model.add(tf.keras.layers.Dense(units=256, activation='relu'))
14 model.add(tf.keras.layers.Dropout(rate=0.2))
15
16 model.add(tf.keras.layers.Dense(units=512, activation='relu'))
17 model.add(tf.keras.layers.Dropout(rate=0.2))

```

```
18
19 # Output layer, 4 classes
20 model.add(tf.keras.layers.Dense(units=4, activation='softmax'))
21
22 # Create model
23 model.compile(optimizer=tf.keras.optimizers.Adam(lr=my_learning_rate),
24               loss="sparse_categorical_crossentropy",
25               metrics=['accuracy'])
```

Encontramos o resultado, loss (perda) = 66,3% e accuracy (precisão) = 70,2%, como é possível ver na figura

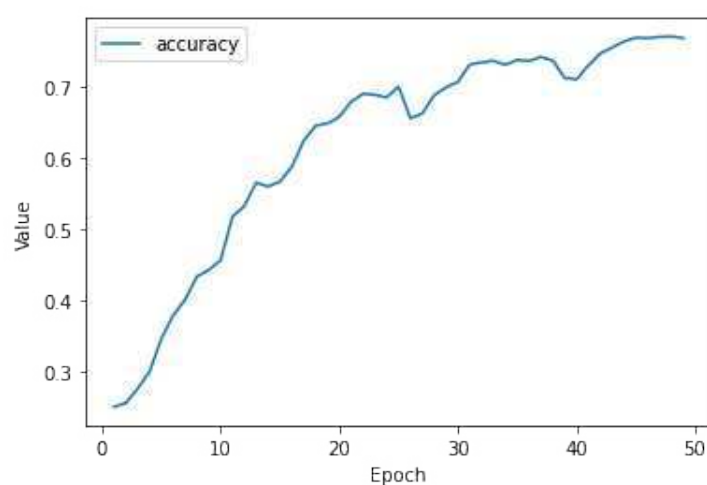


Figura 32 – Precisão do modelo 2 elaborado. Fonte: Elaborado pelo Autor

Com isso, verificou-se que ambas as redes são boas na precisão.

## 3 Considerações finais e Perspectivas

### 3.1 Aplicação de Rede Neural CNN para Classificação de Transientes de Rádio

#### 3.1.1 Dados simulados

Foram gerados bursts a partir de distribuições aleatórias uniformes. Eles foram inseridos em um fundo de ruído composto por uma mistura de ruído rosa e ruído branco (pink noise + white noise), além de interferências de radiofrequência (RFI).

Os bursts em questão foram definidos pelos seguintes parâmetros: a) TOA (time of arrival): poisson dist, b) pulse width (largura): log-normal, c) pulse amplitude (voltagem ou potência): log-normal, d) spectral index: uniform distribution between -4 and 4 e e) initial and final frequency. Eles possuem largura de pulso seguindo a distribuição log-normal com média de  $1.6\text{ ms}$ , resultando em larguras estimadas entre  $0,1 - 50\text{ ms}$ . Além disso, a medida de dispersão foi calculada a partir de log-uniform, de forma que se aproximasse uma de cada cinco bursts, sendo visivelmente dispersada no tempo.

Assim, como resultado teremos um banco de dados com varios bursts uniformemente distribuidos na frequencia em  $GHz$  e tempo  $ms$ , com tamanho (1064, 100.000) como é possível verificar na figura 33. <sup>1</sup> Tendo isso em mente, foram elaborados 3 conjuntos de dados diferentes com tamanhos distintos que será apresentado posteriormente.

---

<sup>1</sup> Para mais informações da elaboração dos dados simulados de pulsos acessar o GitHub: <https://github.com/Rafaely15/Data-simulation>




Figura 33 – Dados elaborados simulados, onde os pulsos foram distribuídos de forma aleatória, e foi adicionado o ruído rosa e branco. Fonte: Elaborada pelo Autor.

Podemos imaginar a figura 33 distribuída em 106.400.000 neurônios, onde cada um representa uma escala de cor do RGB. Com isso, nossa rede deverá varrer mais de 5.320.000.060 parâmetros, ou seja, o tempo de processamento seria muito extenso. Pensando nisso, dividiremos os dados em pequenas frações do tamanho (32,20), mostrado na figura 34 e 35.




Figura 34 – Representação visual de como o ficaria a distribuição dos neurônios individuais ficariam distribuídos. Fonte: Elaborada pelo autor.

Ao dividir os dados teremos cerca de 8000 amostras, onde cada amostra passará por uma rede neural com arquiteturas e processamentos diferentes. Nessa ótica, cada

rede neural processará 3.247 parâmetros, diminuindo consideravelmente o tempo de processamento, gerando melhores resultados.

Para entender melhor o processo matemático, teremos, na figura 35 uma rede neural simples, composta por 2 camadas internas que cada uma passará por 5 filtros, gerando, por fim 2 saídas. Nesse processo, entrarão 640 neurônios, que serão gerados 3.245 pesos, 12 Bias e 3.247 parâmetros.

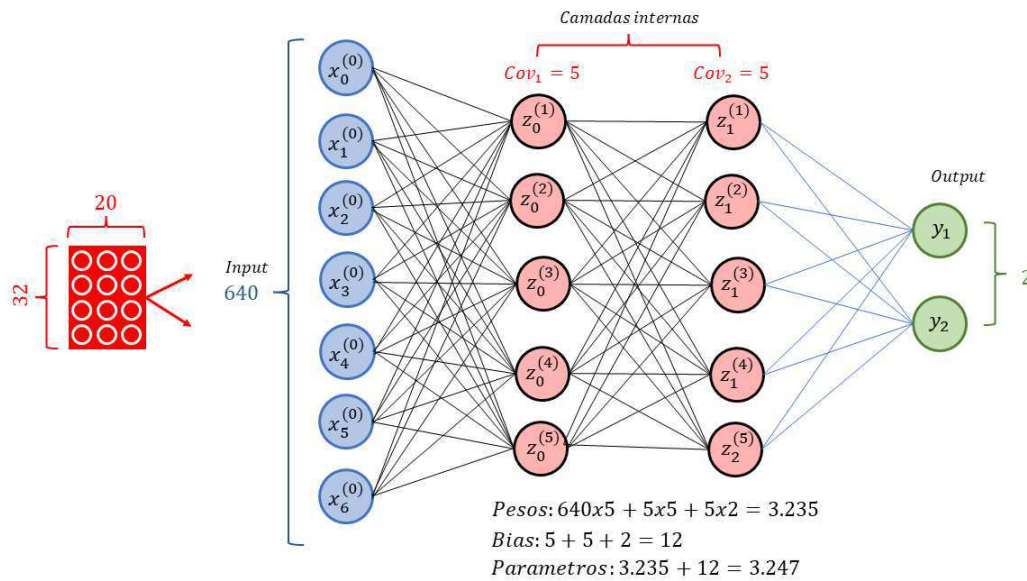


Figura 35 – Na figura é verificado a rede neural B, onde mostra o processo matemático da rede. Fonte: Elaborada pelo autor.

Aprofundando nossos conhecimentos matemáticos, verificaremos que cada neurônio das camadas internas passarão pela equação 2.44, que também podem ser verificadas de forma matricial.

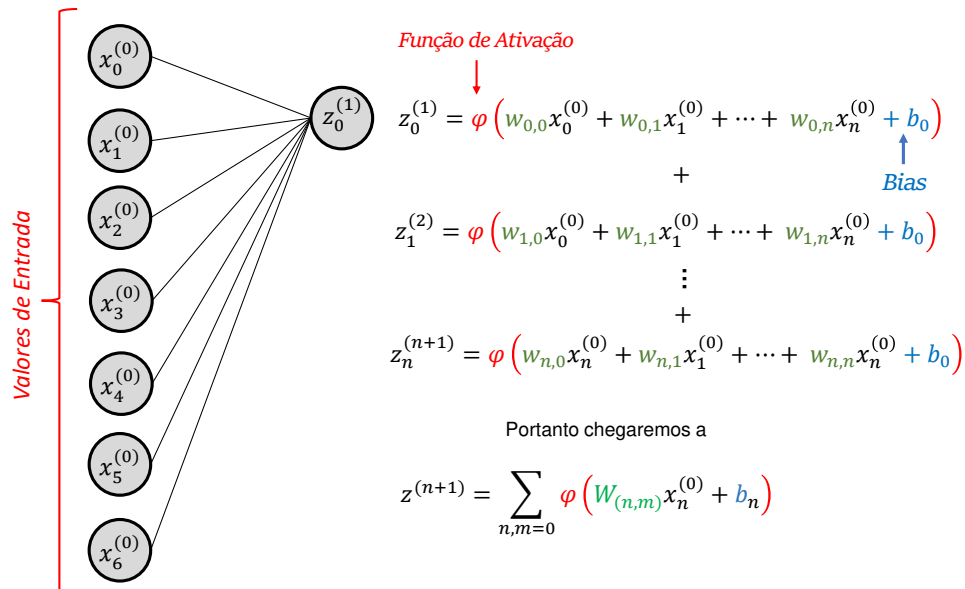


Figura 36 – Mecanismo de funcionamento da rede neural na prática, demonstração matemática e computacional da rede. Fonte: Elaborada pelo autor.

Mudando um pouco o foco, analisaremos a rede neural 35 de um ponto de vista computacional, teremos uma entrada de (32,20,1), que passará pela primeira cada interna onde terá como função de ativação a sigmoid com filtro de  $5 \times 5$  e Pooling  $5 \times 5$ , o mesmo processo ocorrerá passando para a segunda camada interna, que terá a função de ativação tangente, por fim, passará por um Flattened que representa uma vetorização em 1 dimensão. Por fim, passará por uma função que utiliza a probabilidade como base de decisão, a função softmax. Logo, é gerada a saída mostrando o resultado.



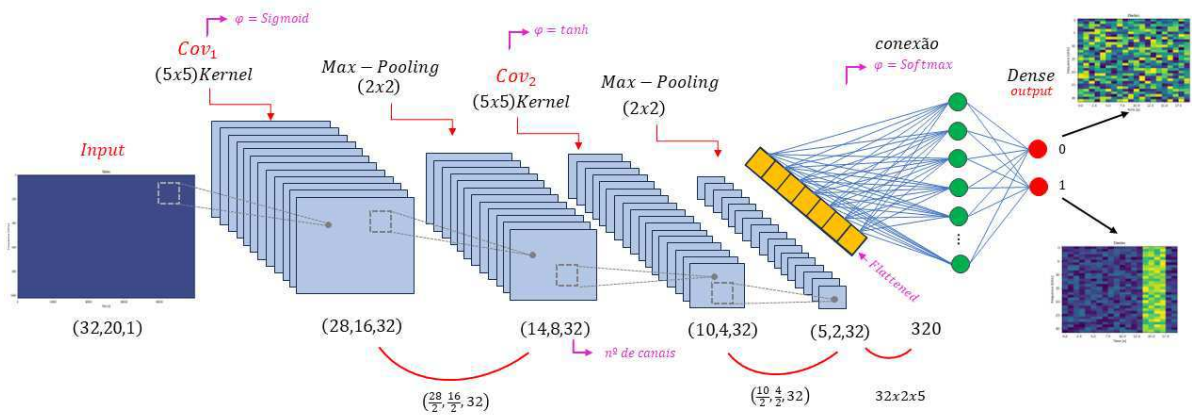


Figura 37 – Na figura é destacado a rede neural B, onde mostra toda a logica computacional, como filtros, funções de ativação, flattened entre outros. Fonte: Elaborada pelo autor.

O objetivo geral de elaboração na nossa rede consiste em classificar burst (pulsos), a partir da sua memorização e processamento na rede, na pratica, nossos resultados sairão da seguinte forma, em *a)* teremos o pulso que está localizado entre 12.5 – 15.0s, enquanto, em *b)* não conseguimos identificar um padrão, portanto, nesse caso não teremos pulso, como vemos a figura 38.




Figura 38 – Em *a)* é possível verificar um pulso com uma determinada largura, enquanto em *b)* é verificado a ausência do pulso. Fonte: Elaborada pelo autor.

É importante ressaltar que o conjunto de dados de treino e teste foram balanceados, a fim de evitar qualquer tendência ou viés na rede, portanto, teremos duas duas saídas, como mostra a figura 38 *a)* e *b)*.

Pensando nisso, outras redes neurais com novas arquiteturas foram montadas, testadas e analisadas, elas serão apresentadas a seguir.

### 3.1.2 Elaboração do pré processamento dos dados

Os pulsos possuem estruturas complexas na frequência e no tempo, para elaboração da rede é preciso ser uma rede de CNN com camadas profundas que possa aprender

recursos com vários níveis de abstração [47].

Hoje, sabe-se que múltiplas camadas são melhores em generalizar, pois aprendem todos os recursos a partir de simples recursos em dados brutos, para classificação de alto nível [25]. No entanto, é preciso verificar a profundidade de cada modelo e se cada modelo possui um grande número de parâmetros treináveis.

Tendo isso em mente, o próximo passo é pré processar os dados para assim entrar na nossa rede neural, para isso foi feita a normalização dos dados usando a equação abaixo 3.1.

$$\hat{\mathbf{A}} = \begin{bmatrix} a_{11}/f_{max}(a_{1n}) & \cdots & a_{1n}/f_{max}(a_{1n}) \\ \vdots & \vdots & \vdots \\ a_{n1}/f_{max}(a_{nm}) & \cdots & a_{nm}/f_{max}(a_{nm}) \end{bmatrix} \quad (3.1)$$

Com os dados normalizados e com os tamanhos corretos, iremos criar a rede neural com diferentes arquiteturas com o objetivo de encontrar uma que se adéque melhor aos nossos dados.

### 3.1.3 Arquitetura das redes

A arquitetura das redes neurais é um tópico fundamental no campo do aprendizado de máquina e tem sido amplamente estudado e aplicado em diversas áreas. Uma rede neural é um modelo computacional composto por unidades interconectadas chamadas neurônios, organizados em camadas. Essas camadas são responsáveis por processar informações e produzir saídas úteis para resolver problemas específicos.

Um aspecto importante da arquitetura de redes neurais é a presença de camadas ocultas. Essas camadas estão localizadas entre a camada de entrada e a camada de saída e são responsáveis por realizar cálculos complexos para aprender representações de alto nível dos dados de entrada. A presença de múltiplas camadas ocultas permite que a rede neural aprenda de forma hierárquica, capturando características abstratas e mais sofisticadas à medida que avança nas camadas.

Diferentes tipos de redes neurais podem ter arquiteturas específicas. Um exemplo relevante é a rede neural convolucional (Convolutional Neural Network - CNN). Essa arquitetura é especialmente adequada para problemas de processamento de imagens e reconhecimento de padrões visuais. Ela é composta por camadas convolucionais, que aplicam filtros espaciais para detectar características locais nas imagens, seguidas por camadas de pooling para reduzir a dimensionalidade. As camadas convolucionais e de pooling são intercaladas com camadas totalmente conectadas, responsáveis por realizar a classificação final com base nas características aprendidas.

A arquitetura da rede neural, incluindo a configuração e a estrutura das camadas ocultas, desempenha um papel crucial no desempenho e na capacidade de generalização da rede. A escolha adequada das camadas ocultas e sua organização dependem do problema específico em questão, do tipo de dados de entrada e das características a serem aprendidas. [30]

Será destacado as estruturas das redes junto com seus resultados de precisão (accuracy) e perda (loss).

### 3.1.3.1 Rede Neural A

A arquitetura da rede consiste em rede duas camadas de convolução de tamanhos, 64 e 32, respectivamente. Posteriormente duas de maxpooling e uma camada Softmax, verificar a figura 39.




Figura 39 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são ReLU e Tahn. Fonte: Elaborada pelo Autor.

Essa rede teve um accuracy de 97.17% e loss de 8.66%, uma ótima precisão agora o objetivo é identificar se existe falsos positivos.

### 3.1.3.2 Rede Neural B

Nessa rede a grande modificação vem das funções de ativação a qual foi atribuído a função sigmoid e posteriormente a Tahn, do tamanho das camadas e dos filtros aplicados, nesse sentido, teremos os seguintes resultados accuracy de 96.97% e loss de 11.79% <sup>2</sup>.

<sup>2</sup> Adaptação do GitHub <https://github.com/HarisIqbal88/PlotNeuralNet>

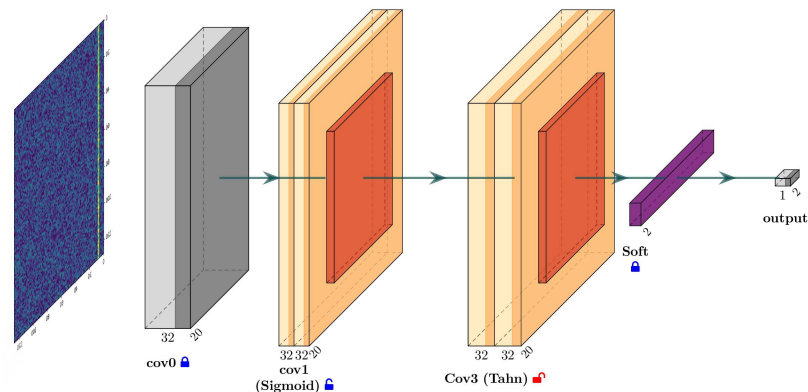


Figura 40 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são ReLU e Tanh. Fonte: Elaborada pelo Autor.

### 3.1.3.3 Rede Neural C

Na rede neural “c” a modificação acontece nas funções de ativação nesse caso colocamos primeiro a Tanh e posteriormente a ReLU, os filtros permanecem os mesmos e as camadas tiveram variação de tamanho. Resultando em accuracy de 99.56% e loss de 1.97%.




Figura 41 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são sigmoid e Tanh. Fonte: Elaborada pelo Autor.

### 3.1.3.4 Rede Neural D

Na rede neural “D” será modificado as funções de ativação com uma função de ativação mais recente, chamada de “likely ReLU”. que foi mostrada anteriormente, com essa modificação, iremos continuar com a segunda configuração sendo Tanh, teremos a seguinte figura 43. Chegaremos ao seguinte resultado accuracy 99,78% e loss de 1,36%.




Figura 42 – Na figura é possível verificar a arquitetura da rede neural onde mostra a as funções de ativação que são ReLU e Tanh.Fonte: Elaborada pelo Autor.

### 3.1.3.5 Rede Neural E

Na rede E é modificado as funções de ativação onde o papel é invertido, com isso teremos o seguinte resultado accuracy 99.93% e loss de 1.10%.




Figura 43 – Arquitetura da rede neural E em forma de diagrama. Fonte: Elaborada pelo Autor.

### 3.1.3.6 Rede Neural F

Na arquitetura da rede “F” foi alterada a segunda função de ativação onde foi inserido outra função de ativação chamada Likely ReLU, portanto, a proposta consiste em colocar duas funções iguais como é mostrado na figura 44.




Figura 44 – Estrutura da rede neural. Fonte: Elaborada pelo Autor.

### 3.1.3.7 Rede Neural G

Já na rede G foi modificado o número de camadas convolucionais, foi adicionado mais uma camada, serão passadas 3 funções de ativações que são elas, respectivamente, duas Likely ReLU e uma ReLU, posteriormente vai passar uma dense para assim chegar a softmax e a saída, os tamanhos das camadas também foram modificados como é possível verificar na imagem 46.




Figura 45 – Arquitetura da rede neural G em forma de diagrama. Fonte: Elaborada pelo Autor.

### 3.1.3.8 Rede Neural H

A proposta da rede H é iniciar com camadas pequenas e ir para camadas maiores, iniciaremos com uma camada de tamanho 32, posteriormente 64 e por fim 128, mantendo

as mesmas funções de ativação. Com isso, chegamos ao seguinte resultado accuracy de 97.53% e loss de 6,96%.




Figura 46 – Arquitetura da rede neural H em forma de diagrama. Fonte: Elaborada pelo Autor.

Com base nas redes neurais, será verificado seus resultados com os parâmetros de accuracy (precisão), loss (perda), acertos e erros. A partir desses resultados será verificado qual melhor modelo para ser aplicado em novos bancos de dados, o objetivo é verificar a confiabilidade da rede.

Label	Accuracy (%)	Loss (%)	Acertos	Erros
A	97,17%	8,66	7746	254
B	96,97%	1,17%	7746	254
C	99,56%	1,97%	7701	299
D	96,24%	21,27%	7699	301
E	99,93%	1,10%	7700	300
F	99,23%	2,63%	7698	302
G	100%	0,0346%	7730	270
H	97,53%	6,96%	7720	280

Após criar e treinar os modelos, iremos aplicar a rede neural treinada em outro dois novos bancos de dados, com o objetivo de verificar o seu overfitting. <sup>3</sup> Aplicando as redes neurais treinadas no banco de dados I e II que pode ser verificado na figura 47 com tamanho (32, 100.000) teremos o seguinte resultados, destacados na tabela abaixo.

<sup>3</sup> É quando o modelo da rede neural aprende demais sobre os dados, gerando erro ao aplicar sua rede em outros dados de teste.




Figura 47 – Banco de dados I simulados de pulsos com tamanho  $(32, 100.000)$ . Fonte: Elaborada pelo autor.

Rede	Pulsos encontrados ( $P$ )	Overfitting ( $O$ )	Acertos ( $P - O$ )
A	186	0	186
B	189	0	189
C	224	45	179
D	251	68	183
E	237	44	193
F	265	77	188
G	219	31	188
H	216	30	186

Para o caso dos dados II visto na figura 48 teremos o seguinte resultados visto 3.1.3.8.






Figura 48 – Banco de dados II simulados de pulsos com tamanho (32, 100.000). Fonte: Elaborada pelo autor.

Rede	Pulsos encontrados ( $P$ )	Overfitting ( $O$ )	Acertos ( $P - O$ )
A	155	0	155
B	165	0	165
C	193	45	148
D	224	63	161
E	228	60	168
F	228	60	168
G	202	36	166
H	196	33	163

Feito essa análise chegamos a conclusão que é preciso ter redes neurais que não tenha overfitting para que a rede seja de fato confiável e possa ser aplicada futuramente em um radiotelescópio real, como o BINGO.

Com o intuito de evitar o overfitting em redes neurais, existe uma rede neural chamada de Rede Neural Recorrente (RNN - Recurrent Neural Network) é um tipo de arquitetura de rede neural projetada para lidar com dados sequenciais, onde a dependência temporal dos elementos são importantes. Ao contrário das redes neurais convolucionais (CNNs), que são mais adequadas para dados rígidos em grades, como imagens, as RNNs são ideais para dados sequenciais, como texto, áudio e séries temporais.

Pensando nisso, elaboraremos modelos de redes do tipo RNNs para aplicação dos dados com o intuito de treinar e testar a rede nos nossos dados, aprofundaremos nossos dados simulados para que fique o mais próximo de um pulso real de FRB, e elaboraremos

outros métodos de classificação sem ser por redes neurais, com o objetivo de comparar qual melhor método de classificação de radio-transientes.

# Referências

- [1] Encyclopædia britannica. <https://www.britannica.com/biography/Grote-Reber#/media/1/493316/171704>. Accessed: 19 de janeiro de 2023. Citado 2 vezes nas páginas 3 e 4.
- [2] Galaxy mnist. <https://albertizard.com/MNIST/>. Accessed: 25 de junho de 2023. Citado 4 vezes nas páginas 4, 48, 49 e 50.
- [3] Projeto bingo firma parceria com empresa chinesa para construção e transferência de tecnologia do radiotelescópio bingo. Citado 2 vezes nas páginas 3 e 13.
- [4] Rápida explosão de rádio descoberta na pesquisa alfa do pulsar de aréibo. Citado na página 1.
- [5] Uma explosão de rádio brilhante em milissegundos de origem extragaláctica. Citado na página 1.
- [6] A second source of repeating fast radio bursts. Nature 566, 7743 (2019), 235–238. Citado 2 vezes nas páginas 16 e 17.
- [7] Abramowicz, M. A., Bejger, M., and Wielgus, M. Collisions of neutron stars with primordial black holes as fast radio bursts engines. The Astrophysical Journal 868, 1 (2018), 17. Citado na página 15.
- [8] Academy, E. Funções de ativação: definição, características, e quando usar cada uma. <https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/>. Acessado em: 20/10/2023. Citado 5 vezes nas páginas 4, 29, 30, 31 e 32.
- [9] BANERJEE, P. “mnist - deep neural network with keras”. <https://www.kaggle.com/code/prashant111/mnist-deep-neural-network-with-keras>, 2020. Accessed: 22 de fevereiro de 2023. Citado na página 36.
- [10] Bell, M., Huynh, M., Hancock, P., Murphy, T., Gaensler, B., Burlon, D., Trott, C., and Bannister, K. A search for variable and transient radio sources in the extended chandra deep field south at 5.5 ghz. Monthly Notices of the Royal Astronomical Society 450, 4 (2015), 4221–4232. Citado na página 16.
- [11] Bishop, C. M. Pattern Recognition and Machine Learning. Springer, 2006. Citado na página 29.

- [12] BSCS. “the brain: Understanding neurobiology through the study of addiction. <https://science.education.nih.gov/supplements/webversions/BrainAddiction/guide/lesson2-1.html>, 2000. Accessed: 06 de fevereiro de 2023. Citado na página 26.
- [13] Burke-Spolaor, S., and Bannister, K. W. The galactic position dependence of fast radio bursts and the discovery of frb011025. *The Astrophysical Journal* 792, 1 (2014), 19. Citado na página 16.
- [14] Burns, W., and Clark, B. Pulsar search techniques. *Astronomy and Astrophysics* 2 (1969), 280–287. Citado na página 15.
- [15] Caleb, M., Flynn, C., Bailes, M., Barr, E., Bateman, T., Bhandari, S., Campbell-Wilson, D., Farah, W., Green, A., Hunstead, R., et al. The first interferometric detections of fast radio bursts. *Monthly Notices of the Royal Astronomical Society* 468, 3 (2017), 3746–3756. Citado na página 1.
- [16] Caleb, M., Flynn, C., Bailes, M., Barr, E., Bateman, T., Bhandari, S., Campbell-Wilson, D., Green, A., Hunstead, R., Jameson, A., et al. Fast radio transient searches with utmost at 843 mhz. *Monthly Notices of the Royal Astronomical Society* 458, 1 (2016), 718–725. Citado na página 16.
- [17] Champion, D., Petroff, E., Kramer, M., Keith, M., Bailes, M., Barr, E., Bates, S., Bhat, N., Burgay, M., Burke-Spolaor, S., et al. Five new fast radio bursts from the htru high-latitude survey at parkes: first evidence for two-component bursts. *Monthly Notices of the Royal Astronomical Society: Letters* 460, 1 (2016), L30–L34. Citado na página 16.
- [18] Chatterjee, S., Law, C., Wharton, R., Burke-Spolaor, S., Hessels, J., Bower, G., Cordes, J., Tendulkar, S., Bassa, C., Demorest, P., et al. A direct localization of a fast radio burst and its host. *Nature* 541, 7635 (2017), 58–61. Citado 2 vezes nas páginas 1 e 16.
- [19] Colgate, S. A., and Noerdlinger, P. D. Coherent emission from expanding supernova shells. *The Astrophysical Journal* 165 (1971), 509. Citado na página 15.
- [20] código fluente. “aula 19 – tensor flow – redes neurais – mnist”. <https://www.codigofluente.com.br/aula-19-tensor-flow-redes-neurais-mnist/>, 2021. Accessed: 17 de fevereiro de 2023. Citado 2 vezes nas páginas 4 e 39.
- [21] Deng, W., and Zhang, B. Cosmological implications of fast radio burst/gamma-ray burst associations. *The Astrophysical Journal Letters* 783, 2 (2014), L35. Citado na página 21.

- [22] Dickinson, C. Bingo-a novel method to detect baos using a total-power radio telescope. arXiv preprint arXiv:1405.7936 (2014). Citado na página 13.
- [23] Editora, M. Normas de apresentação tabular, 1 ed. Portal, 2016. Citado na página 5.
- [24] Eilek, J. A., and Hankins, T. H. Radio emission physics in the crab pulsar. Journal of Plasma Physics 82, 3 (2016), 635820302. Citado na página 15.
- [25] Eldan, R., and Shamir, O. The power of depth for feedforward neural networks. In Conference on learning theory (2016), PMLR, pp. 907–940. Citado na página 57.
- [26] fchollet. “simple mnist convnet ”. [https://keras.io/examples/vision/mnist\\_convnet/](https://keras.io/examples/vision/mnist_convnet/), 2015. Accessed: 22 de fevereiro de 2023. Citado na página 36.
- [27] Fleck, L., Tavares, M. H. F., Eyng, E., Helmann, A. C., and Andrade, M. A. d. M. Redes neurais artificiais: Princípios básicos. Revista Eletrônica Científica Inovação e Tecnologia 1, 13 (2016), 47–57. Citado na página 26.
- [28] Foster, G., Karastergiou, A., Geyer, M., Surnis, M., Golpayegani, G., Lee, K., Lorimer, D., Price, D. C., and Rajwade, K. Verifying and reporting fast radio bursts. Monthly Notices of the Royal Astronomical Society 481, 2 (2018), 2612–2627. Citado na página 16.
- [29] Foster, G., Karastergiou, A., Golpayegani, G., Surnis, M., Lorimer, D. R., Chenamangalam, J., McLaughlin, M., Armour, W., Cobb, J., MacMahon, D. H., et al. Alfaburst: A commensal search for fast radio bursts with arecibo. Monthly Notices of the Royal Astronomical Society 474, 3 (2018), 3847–3856. Citado na página 2.
- [30] Goodfellow, I., Bengio, Y., and Courville, A. Deep Learning. MIT Press, 2016. Citado 4 vezes nas páginas 28, 30, 33 e 58.
- [31] Guy, T. A. Neural Networks. <https://medium.com/nerd-for-tech/neural-networks-68531432fb5>. Acessado em: 22/11/2023. Citado 2 vezes nas páginas 3 e 26.
- [32] Hankins, T., Kern, J., Weatherall, J., and Eilek, J. Nanosecond radio bursts from strong plasma turbulence in the crab pulsar. Nature 422, 6928 (2003), 141–143. Citado na página 15.
- [33] Haykin, S. Redes neurais: princípios e prática. Bookman Editora, 2001. Citado 3 vezes nas páginas 3, 26 e 27.
- [34] Hecht-Nielsen, R. Theory of the simple backpropagation algorithm. Neural Networks 5, 3 (1992), 389–403. Citado na página 29.

- [35] Hessels, J., Spitler, L., Seymour, A., Cordes, J., Michilli, D., Lynch, R., Gourdji, K., Archibald, A., Bassa, C., Bower, G., et al. Frb 121102 bursts show complex time–frequency structure. The Astrophysical Journal Letters 876, 2 (2019), L23. Citado na página 20.
- [36] Hewish, A., Bell, S. J., Pilkington, J. D., Frederick Scott, P., and Collins, R. A. Observation of a rapidly pulsating radio source. In A Source Book in Astronomy and Astrophysics, 1900–1975. Harvard University Press, 1979, pp. 498–504. Citado na página 15.
- [37] Iqbal, H. PlotNeuralNet: PlotNeuralNet. <https://github.com/HarisIqbal88/PlotNeuralNet>, Ano de publicação ou acesso. Nenhuma citação no texto.
- [38] Jonathan M. Marr, R. L. S., and Kurtz, S. E. Fundamentals of Radio Astronomy: Observational Methods, 1rd ed. University of Bristol, CRC Press, 2016. Citado 2 vezes nas páginas 3 e 7.
- [39] Koehler, G. “mnist handwritten digit recognition in keras”. <https://nextjournal.com/gkoehler/digit-recognition-with-keras>, 2020. Accessed: 14 de fevereiro de 2023. Citado 4 vezes nas páginas 4, 37, 38 e 40.
- [40] Law, C., Bower, G., Burke-Spolaor, S., Butler, B., Demorest, P., Halle, A., Khudikyan, S., Lazio, T., Pokorný, M., Robnett, J., et al. realfast: real-time, commensal fast transient surveys with the very large array. The Astrophysical Journal Supplement Series 236, 1 (2018), 8. Citado na página 1.
- [41] Lorimer, D. R., Bailes, M., McLaughlin, M. A., Narkevic, D. J., and Crawford, F. A bright millisecond radio burst of extragalactic origin. Science 318, 5851 (2007), 777–780. Citado na página 15.
- [42] Maartens, R., Abdalla, F. B., Bull, P., Camera, S., Benoit-Levy, A., Joachimi, B., Kirk, D., Klöckner, H.-R., Raccanelli, A., Santos, M. G., et al. Cosmology from hi galaxy surveys with the ska. Citado na página 14.
- [43] Machado, K. D. Teoria do eletromagnetismo: volume 3. UEPG, 2006. Citado 3 vezes nas páginas 8, 9 e 11.
- [44] Masui, K., Lin, H.-H., Sievers, J., Anderson, C. J., Chang, T.-C., Chen, X., Ganguly, A., Jarvis, M., Kuo, C.-Y., Li, Y.-C., et al. Dense magnetized plasma associated with a fast radio burst. Nature 528, 7583 (2015), 523–525. Citado 2 vezes nas páginas 1 e 16.
- [45] McQuinn, M. Locating the “missing” baryons with extragalactic dispersion measure estimates. The Astrophysical Journal Letters 780, 2 (2013), L33. Citado 2 vezes nas páginas 12 e 15.

- [46] Melrose, D. Coherent emission mechanisms in astrophysical plasmas. Reviews of Modern Plasma Physics 1 (2017), 1–81. Citado na página 15.
- [47] Mhaskar, H., Liao, Q., and Poggio, T. Learning functions: when is deep better than shallow. arXiv preprint arXiv:1603.00988 (2016). Citado na página 57.
- [48] Nair, V., and Hinton, G. E. Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th International Conference on Machine Learning (ICML-10) (2010), 807–814. Citado na página 30.
- [49] Nielsen, M. A. Neural networks and deep learning, vol. 25. Determination press San Francisco, CA, USA, 2015. Citado 4 vezes nas páginas 4, 33, 34 e 44.
- [50] Nussenzveig, H. M. Curso de física Básica: Eletromagnetismo, 1rd ed. Editora Edgar Blüecher LTDA, 1997. Citado na página 11.
- [51] Petroff, E., Barr, E., Jameson, A., Keane, E., Bailes, M., Kramer, M., Morello, V., Tabbara, D., and Van Straten, W. Frbcat: the fast radio burst catalogue. arXiv preprint arXiv:1601.03547 (2016). Citado na página 17.
- [52] Petroff, E., Hessels, J., and Lorimer, D. Fast radio bursts. The Astronomy and Astrophysics Review 27 (2019), 1–75. Citado 4 vezes nas páginas 3, 15, 16 e 20.
- [53] Pianucci, M. N., Pitombo, C. S., Cunha, A. L., and Segantine, P. C. L. Previsão da demanda por viagens domiciliares através de método sequencial baseado em população sintética e redes neurais artificiais. TRANSPORTES 27, 4 (2019), 1–23. Citado 2 vezes nas páginas 3 e 27.
- [54] Purcell, E. M., and Morin, D. J. Electricity and Magnetism, 3rd ed. University of Cambridge, Cambridge, 2008. Citado na página 9.
- [55] Queiroz, V. H. C. Pulsar timing: monitorando pulsares com o bingo, 2021. Citado 3 vezes nas páginas 3, 8 e 14.
- [56] Ravi, V., Shannon, R., and Jameson, A. A fast radio burst in the direction of the carina dwarf spheroidal galaxy. The Astrophysical Journal Letters 799, 1 (2015), L5. Citado na página 16.
- [57] Rees, M. J. A better way of searching for black-hole explosions? Nature 266, 5600 (1977), 333–334. Citado na página 15.
- [58] Rosenblatt, F. The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review 65, 6 (1958), 386–408. Citado na página 40.

- [59] Scholz, P., Spitler, L., Hessels, J., Chatterjee, S., Cordes, J., Kaspi, V., Wharton, R., Bassa, C., Bogdanov, S., Camilo, F., et al. The repeating fast radio burst frb 121102: multi-wavelength observations and additional bursts. The Astrophysical Journal 833, 2 (2016), 177. Citado na página 16.
- [60] Shannon, R., Macquart, J.-P., Bannister, K. W., Ekers, R., James, C., Osłowski, S., Qiu, H., Sammons, M., Hotan, A., Voronkov, M. A., et al. The dispersion–brightness relation for fast radio bursts from a wide-field survey. Nature 562, 7727 (2018), 386–390. Citado 2 vezes nas páginas 1 e 16.
- [61] Spitler, L., Cordes, J. M., Hessels, J., Lorimer, D. R., McLaughlin, M., Chatterjee, S., Crawford, F., Deneva, J., Kaspi, V., Wharton, R., et al. Fast radio burst discovered in the arecibo pulsar alpha survey. The Astrophysical Journal 790, 2 (2014), 101. Citado 3 vezes nas páginas 3, 16 e 17.
- [62] Spitler, L., Scholz, P., Hessels, J., Bogdanov, S., Brazier, A., Camilo, F., Chatterjee, S., Cordes, J., Crawford, F., Deneva, J., et al. A repeating fast radio burst. Nature 531, 7593 (2016), 202–205. Citado 2 vezes nas páginas 1 e 16.
- [63] Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. Inception-v4, inception-resnet and the impact of residual connections on learning. In Proceedings of the AAAI conference on artificial intelligence (2017), vol. 31. Citado na página 1.
- [64] Taylor, J. Catalog of 37 pulsars. Astrophysical Letters 3 (1969), 205. Citado na página 15.
- [65] Tensorflow. “tensorflow”. <https://www.tensorflow.org/?hl=pt-br>. Accessed: 22 de fevereiro de 2023. Citado na página 35.
- [66] TensorFlow. “treinando uma rede neural no mnist com keras”. [https://www.tensorflow.org/datasets/keras\\_example?hl=pt-br](https://www.tensorflow.org/datasets/keras_example?hl=pt-br), 2022. Accessed: 22 de fevereiro de 2023. Citado na página 36.
- [67] Theano. “theano 1.0.5”. <https://pypi.org/project/Theano/>, 2020. Accessed: 22 de fevereiro de 2023. Citado na página 35.
- [68] Thomas L. Wilson, Kristen Rohlfs, S. H. Tools of Radio Astronomy, 5rd ed. Springer, 1973. Citado na página 6.
- [69] Vachaspati, T. Cosmic sparks from superconducting strings. Physical Review Letters 101, 14 (2008), 141301. Citado 2 vezes nas páginas 12 e 15.
- [70] Vieira, F. A. S. RotÓtipo de radiÔmetro simples para pesquisa em fast radio burst com o radiotelescÓpio bingo. Master’s thesis, INPE, 2020. Citado 2 vezes nas páginas 3 e 13.



- [71] Wessberg, J., Stambaugh, C. R., Kralik, J. D., Beck, P. D., Laubach, M., Chapin, J. K., Kim, J., Biggs, S. J., Srinivasan, M. A., and Nicolelis, M. A. Real-time prediction of hand trajectory by ensembles of cortical neurons in primates. Nature 408, 6810 (2000), 361–365. Citado 2 vezes nas páginas 3 e 4.
- [72] Wuensche, C., Collaboration, B., et al. The bingo telescope: a new instrument exploring the new 21 cm cosmology window. In Journal of Physics: Conference Series (2019), vol. 1269, IOP Publishing, p. 012002. Citado na página 13.
- [73] Wuensche, C. A., Villela, T., Abdalla, E., Liccardo, V., Vieira, F., Browne, I., Peel, M. W., Radcliffe, C., Abdalla, F. B., Marins, A., et al. The bingo project ii: Instrument description. arXiv preprint arXiv:2107.01634 (2021). Citado 3 vezes nas páginas 3, 12 e 14.
- [74] Yang, Y.-P., Luo, R., Li, Z., and Zhang, B. Large host-galaxy dispersion measure of fast radio bursts. The Astrophysical Journal Letters 839, 2 (2017), L25. Citado na página 22.