



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Identificação de Sinais Interferentes em Rádios utilizando Técnicas de Aprendizado de Máquina

Deyvid Lucas Leite

Orientador: Prof. Dr. Vicente Angelo de Sousa Junior

Co-orientador: Prof. Dr. Pablo Javier Alsina

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Engenharia de Computação) como parte dos requisitos para obtenção do título de Doutor.

Número de ordem PPgEEC: M603

Natal, RN, abril de 2024

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Leite, Deyvid Lucas.

Identificação de sinais interferentes em rádios utilizando técnicas de aprendizado de máquina / Deyvid Lucas Leite. - 2024. 137 f.: il.

Tese (doutorado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Natal, RN, 2024.

Orientação: Prof. Dr. Vicente Angelo de Sousa Junior.

Coorientação: Prof. Dr. Pablo Javier Alsina.

1. Rádios FM - Tese. 2. Detecção de Sinais Interferentes - Tese. 3. Processamento de Sinal de Áudio - Tese. I. Sousa Junior, Vicente Angelo de. II. Alsina, Pablo Javier. III. Título.

RN/UF/BCZM

CDU 654.16(043.2)

Tese de doutorado para Pós-Graduação em Engenharia Elétrica e de Computação da UFRN

Deyvid Lucas Leite

Tese de doutorado composta pela banca examinadora com os seguintes membros:

Prof. Dr. Vicente Angelo de Sousa Junior (Orientador) DCO/UFRN

Prof. Dr. Pablo Javier Alsina (Coorientador) DCA/UFRN

Prof. Dr. Álvaro Augusto Machado de Medeiros UFJF

Prof. Dr. Walter da Cruz Freitas Junior UFC

Prof. Dr. Allan De Medeiros Martins DEE/UFRN

Prof. Dr. Marcio Eduardo da Costa Rodrigues DCO/UFRN

*Aos meus pais, Joailton Eloi Leite e
Telma Lucas Leite, pelo apoio
durante a realização deste trabalho.*

Agradecimentos

Em primeiro lugar, expresso minha gratidão a Deus pela minha vida, pelas bênçãos que foram colocadas em meu caminho e pela oportunidade de concluir este trabalho.

Agradeço aos meus pais pelo apoio, paciência, compreensão e amor que sempre me ofereceram. Foi a educação e a confiança que eles me proporcionaram que me deram a força necessária para chegar onde estou hoje. E para me tornar a pessoa que sou.

Ao meu orientador, Professor Dr. Vicente Angelo de Sousa Junior, que me concedeu a oportunidade de ser seu orientando do mestrado até o doutorado. Sua constante compreensão e disposição para ajudar foram fundamentais para o desenvolvimento deste trabalho.

Ao meu coorientador, Professor Dr. Pablo Javier Alsina, que me concedeu a oportunidade de ser seu coorientando e me guiou em minha jornada acadêmica, desde a iniciação tecnológica até o doutorado. Sou grato pela confiança depositada nesse trabalho e toda orientação.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPgEEC) da UFRN.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

E para todos aqueles que não foram mencionados aqui e colaboraram, direta ou indiretamente, com a conclusão desse trabalho, muito obrigado.

Resumo

Este trabalho oferece uma visão abrangente do papel e da importância da rádio difusão no contexto histórico e comercial brasileiro. Destaca-se a problemática das rádios ilegais, as quais prejudicam as estações legalizadas, diminuindo a qualidade da comunicação e interferindo na capacidade de alcançar mais ouvintes. Para lidar com esse desafio, propõe-se a utilização de métodos de aprendizado de máquina em conjunto com técnicas de extração de características dos sinais de áudio para identificar interferências geradas por outras rádios FM. Neste trabalho, os sinais de interferências não foram tratados apenas como ruído, sendo realizado uma diferenciação clara entre ruído AWGN e interferência de outras rádios. Para isso, foram exploradas técnicas de extração de características únicas, como métodos baseados em sensoriamento espectral devidamente adaptados, método MFCC, métodos estatísticos de primeira ordem e de ordem estendida. Além disso, foram exploradas as estratégias que utilizam redes do tipo *Autoencoder* e as Redes Neurais Convolucionais para classificar os sinais de rádio que chegam aos receptores. Para esse estudo, foram exploradas soluções com sinais em banda base e banda passante, bem como situações com múltiplas fontes de sinais interferentes, para que os modelos propostos possam lidar com cenários desafiadores. Por fim, foram conduzidos testes de validação da capacidade dos métodos propostos em ambientes de simulação computacional e em ambientes reais, dos quais foram utilizados a *Universal Software Radio Peripheral* (USRP) para gerar sinais que se propagam pelo canal de comunicação.

Palavras-chave: rádios FM, detecção de sinais interferentes, processamento de sinal de áudio, sensoriamento espectral, MFCC.

Abstract

This work offers a comprehensive view of the role and importance of radio in the Brazilian historical and commercial context. The problem of illegal radio stations stands out, which harm legal stations, reducing the quality of communication and interfering with the ability to reach more listeners. To deal with this challenge, it is proposed to use machine learning methods in conjunction with feature extraction techniques from audio signals to identify interference generated by other FM radios. In this work, interference signals were not treated simply as noise, with a clear differentiation between AWGN noise and interference from other radios. To this end, unique feature extraction techniques were explored, such as methods based on properly adapted spectral sensing, the MFCC method, first-order and extended-order statistical methods. Furthermore, strategies that use Autoencoder networks and Convolutional Neural Networks to classify radio signals that reach receivers were explored. For this study, under these conditions, solutions with baseband and passband signals were explored, as well as situations with multiple sources of interfering signals, so that the proposed models can deal with challenging scenarios. Finally, tests were carried out to validate the capacity of the proposed methods in computer simulation environments and in real environments, using Universal Software Radio Peripheral to generate signals that propagate through the communication channel.

Keywords: FM radios, detection of interfering signals, audio signal processing, spectral sensing, MFCC (Mel Frequency Cepstral Coefficients).

Sumário

Sumário	i
Lista de Figuras	vii
Lista de Tabelas	xi
Lista de Símbolos e Abreviaturas	xiii
1 Introdução	1
1.1 Proposta da tese	6
1.2 Produtos Tangíveis	8
2 Fundamentação teórica e proposta de solução	11
2.1 Princípios do sistema de comunicação via rádio FM	11
2.1.1 Modulação em frequência: conceitos básicos	12
2.1.2 Desafios e tendências atuais das rádios FM	13
2.2 Métodos de detecção de interferência	15
2.2.1 Métodos manuais e analógicos	15
2.2.2 Algoritmos de processamento de sinal	15
2.2.3 Técnicas de aprendizado de máquina	16
2.2.4 Tendências atuais e futuras	16
2.2.5 Teorias e modelos existentes	17
2.2.6 Oportunidades de Pesquisa na Literatura	18
2.3 Métodos de sensoriamento espectral selecionados	19

2.3.1	Método de Detecção de Energia (ED)	19
2.3.2	Método p -Norm	20
2.3.3	Detecção de Energia Combinada Cegamente (BCED)	20
2.3.4	Teste do Maior Autovalor de Roy (RLRT)	21
2.3.5	Maior e Menor Autovalor da Matriz de Covariância (MMA)	23
2.3.6	Estimação de Correlação (EC)	23
2.4	Métodos selecionados para comparação	25
2.4.1	Coeficientes Cepstrais de Frequência Mel (MFCC)	25
2.4.2	Croma	25
2.4.3	Método Mel	26
2.4.4	Centroide espectral	26
2.4.5	Largura de banda espectral	26
2.4.6	Declínio espectral	26
2.5	Detectores de Interferência Propostos	27
2.5.1	<i>Autoencoder</i> e Redes Neurais Convolucionais	28
2.5.2	<i>Autoencoder</i> como detector de interferência	30
2.5.3	Rede Neural Convolucional como detector de interferência	30
3	Metodologia	33
3.1	Gerando sinais	33
3.1.1	Métodos lineares de identificação	34
3.1.2	Preparação de dados para <i>Autoencoder</i> e CNN	36
3.1.3	Preparação de dados para CNN com múltiplas interferências	38
3.1.4	Treinamento e validação	40
3.2	Otimização dos hiperparâmetros	40
3.3	Metodologia Experimental	42
3.3.1	Simulação de interferência usando USRP	42

3.3.2	Configurações Gerais do esquema GNU Radio	43
3.3.3	Fontes de Áudio	43
3.3.4	Blocos de Processamento de Sinal	44
3.3.5	Modulação e Transmissão FM	44
3.3.6	Monitoramento em Espectro	44
3.3.7	Procedimento de medição	45
3.4	Cálculo das distâncias entre PDFs	47
3.5	Avaliação de Desempenho e Métricas de Decisão	49
4	Resultados do <i>Autoencoder</i> - Banda passante	51
4.1	<i>Autoencoder</i> - Treinamento não supervisionado	51
4.1.1	Treinamento utilizando estatísticas de primeira ordem	52
4.1.2	Treinamento utilizando estatísticas estendidas	53
4.1.3	Treinamento utilizando estatísticas dos métodos lineares - valores T	55
4.1.3.1	Solução individualizada	55
4.1.3.2	Solução combinada	56
4.2	Comparando a solução proposta com métodos lineares	58
4.3	Testes de robustez	61
5	Resultados do <i>Autoencoder</i> - Banda base	65
5.1	<i>Autoencoder</i> - Treinamento não supervisionado	65
5.1.1	Treinamento utilizando estatísticas de primeira ordem	65
5.1.2	Treinamento utilizando estatísticas estendidas	66
5.1.3	Treinamento utilizando estatísticas dos métodos lineares - valores T	68
6	Resultados da CNN - Banda passante	71
6.1	Treinamento com métodos lineares: valores T isoladamente	72
6.2	Treinamento com métodos lineares: valores T combinados	74

6.3	Treinamento utilizando estatísticas de primeira ordem e estendidas	76
6.4	Treinamento com Coeficientes Centrais de Frequência Mel	77
6.5	Treinamento utilizando métodos lineares - Segunda combinação	78
6.6	Comparando os métodos	79
7	Resultados da CNN - Banda Base	81
7.1	Treinamento com métodos lineares: valores T isoladamente	81
7.2	Treinamento com métodos lineares: valores T combinados	84
7.3	Treinamento utilizando estatísticas de primeira ordem e estendido	86
7.4	Treinamento com Coeficientes Centrais de Frequência Mel	88
7.5	Treinamento utilizando métodos lineares - Segunda combinação	89
7.6	Comparando os métodos	90
8	Resultados da CNN - Banda passante - Múltiplas interferências	93
8.1	Treinamento com métodos lineares: valores T isoladamente	93
8.2	Treinamento com métodos lineares: valores T combinados	96
8.3	Treinamento utilizando estatísticas de primeira ordem e estendida	98
8.4	Treinamento com Coeficientes Centrais de Frequência Mel (convencional e agregado)	100
8.5	Treinamento utilizando métodos lineares - Segunda combinação	101
8.6	Comparando os métodos	102
9	Resultados da CNN - Banda base - Múltiplas interferências	105
9.1	Treinamento com métodos lineares: valores T isoladamente	105
9.2	Treinamento com métodos lineares: valores T combinados	108
9.3	Treinamento utilizando estatísticas de primeira ordem e estendido	111
9.4	Treinamento com Coeficientes Centrais de Frequência Mel (Modo convencional e agregado)	112

9.5	Treinamento utilizando métodos lineares - Segunda combinação	113
9.6	Comparando os métodos	114
9.7	Análise Comparativa dos Métodos de Detecção	115
10	Resultados dos testes em ambiente real	119
10.1	Rede CNN treinada com dados de uma única fonte interferente	119
10.2	Rede CNN treinada com dados de uma múltiplas fontes interferente . . .	122
11	Conclusão	129
	Referências bibliográficas	133
	Anexo	137

Lista de Figuras

1.1	Porcentagem de pessoas que ouvem rádio nas 13 regiões metropolitanas pesquisadas.	2
1.2	Tempo médio que cada pessoa consome de áudio nas 13 regiões metropolitanas pesquisadas.	3
1.3	Relação do uso do marketing por meio das rádios.	3
1.4	Número anual de estações de rádio fechadas pela Anatel.	5
2.1	Fluxograma do trabalho desenvolvido	32
3.1	Simulador de sensoriamento espectral.	34
3.2	Distância das PDF normalizada. (a) Menor SIR. (b) Maior SIR.	36
3.3	Gerador de sinais para treinamento das redes <i>Autoencoder</i> e CNN.	37
3.4	Esquema de pré-processamento para treinar as redes <i>Autoencoder</i> e CNN.	37
3.5	Diagrama de blocos no GNU Radio para transmissão de sinal FM com monitoramento em espectro.	43
3.6	Sistema de recepção do celular e computador.	45
3.7	Sistema de recepção do celular e computador.	46
3.8	Esquema do gerador de sinais para treinamento.	46
3.9	Esquema de análise de interferência.	47
3.10	Fluxo de geração das PDF's.	48
3.11	Configurações de PDF.	49
4.1	Distância das PDF normalizada. (a) Utilizando valor máximo e mínimo. (b) Utilizando valor máximo, mínimo e média.	52

4.2	Distância das PDF normalizada. (a) Utilizando valor máximo, mínimo, média e variância. (b) Utilizando valor máximo, mínimo, média, variância e desvio padrão.	53
4.3	Distância das PDF normalizada. (a) Utilizando valor máximo e mínimo. (b) Utilizando valor máximo, mínimo e média.	54
4.4	Distância das PDF normalizada. (a) Utilizando valor máximo, mínimo, média e variância. (b) Utilizando valor máximo, mínimo, média, variância e desvio padrão.	54
4.5	Distância das PDF normalizada. (a) Energia. (b) BCED.	55
4.6	Distância das PDF normalizada. (a) p -Norm. (b) Máximo e mínimo autovalor.	56
4.7	Distância das PDF normalizada. (a) Apenas energia. (b) Energia e BCED.	57
4.8	Distância das PDF normalizada. (a) Energia, BCED e p -Norm. (b) Energia, BCED, p -Norm e MMA.	57
4.9	Taxa de detecção correta para SNR de -15 dB. (a) quando P_{FA} em 5%. (b) quando P_{FA} em 10%.	59
4.10	ROC para diferentes SIR. (a) SIR de 32 dB. (b) SIR de 36 dB.	59
4.11	Taxa de detecção correta para SIR de 32 dB. (a) quando P_{FA} em 5%. (b) quando P_{FA} em 10%.	60
4.12	ROC para diferentes SNRs. (a) ROC para SNR de -16 dB. (b) ROC para SNR de -14 dB.	61
4.13	Matriz de confusão - Teste 1.	62
4.14	Matriz de confusão - Teste 2.	62
4.15	Matriz de confusão - Teste 3.	63
5.1	Distância das PDF normalizada. (a) Utilizando valor máximo e mínimo. (b) Utilizando valor máximo, mínimo e média.	66

5.2	Distância das PDF normalizada. (a) Utilizando valor máximo, mínimo, média e variância. (b) Utilizando valor máximo, mínimo, média, variância e desvio padrão.	66
5.3	Distância das PDF normalizada. (a) Utilizando valor máximo e mínimo. (b) Utilizando valor máximo, mínimo e média.	67
5.4	Distância das PDF normalizada. (a) Utilizando valor máximo, mínimo, média e variância. (b) Utilizando valor máximo, mínimo, média, variância e desvio padrão.	67
5.5	Distância das PDF normalizada. (a) Apenas energia. (b) Energia e BCED.	68
5.6	Distância das PDF normalizada. (a) Energia, BCED e pT -Norm. (b) Energia, BCED, p -Norm e MMA.	69
6.1	Comparando métricas de avaliação dos métodos explorados em banda passante.	80
7.1	Comparando métricas de avaliação dos métodos explorados em banda base.	91
8.1	Comparando métricas de avaliação dos métodos explorados em banda passante.	103
8.2	Comparação de desempenho das soluções para sinais com uma fonte (Capítulo 6) e com múltiplas fontes (Capítulo 8) de interferência em banda passante.	104
9.1	Comparando métricas de avaliação dos métodos explorados em banda base.	114
9.2	Comparando capacidade de detecção simples e múltipla em banda base. .	115
9.3	Comparando resultados de métodos empregados	116
10.1	Resultados experimentais para condições de não interferência.	120
10.2	Resultados experimentais para condições de interferência	120
10.3	Comparando capacidade de detecção simples em banda base.	121

10.4	Resultados experimentais para condições de não interferência.	122
10.5	Resultados experimentais para condições de interferência.	123
10.6	Comparando capacidade de detecção simples e múltipla em banda base. .	124

Lista de Tabelas

2.1	Tabela Comparativa da Evolução da Detecção de Interferência	17
2.2	Métodos de Detecção de Sinais Interferentes	17
2.3	Comparação de Métodos de Detecção de Sinais Interferentes	18
3.1	Configuração das Camadas do Encoder e Decoder com Hiperparâmetros Testados via Grid-Search.	41
3.2	Configuração da CNN com Hiperparâmetros Testados via Grid-Search . .	42
6.1	Testes para rede treinada com método da Energia.	72
6.2	Teste para rede treinada com método BCED.	73
6.3	Teste para rede treinada com método p -Norm.	73
6.4	Teste para rede treinada com método MMA.	74
6.5	Teste para rede treinada com métodos da Energia e BCED.	75
6.6	Teste para rede treinada com métodos da Energia, BCED e p -Norm. . . .	75
6.7	Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA. .	76
6.8	Teste para rede treinada com estatística de Primeira Ordem.	77
6.9	Teste para rede treinada com estatística estendida.	77
6.10	Teste para rede treinada com MFCC convencional.	78
6.11	Teste para rede treinada com MFCC agregado.	78
6.12	Teste para rede treinada com métodos Energia, BCED, p -Norm e RLRT. .	79
6.13	Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia.	79
7.1	Teste para rede treinada com método da Energia.	82

7.2	Teste para rede treinada com método BCED	82
7.3	Teste para rede treinada com método p -Norm.	83
7.4	Teste para rede treinada com método MMA.	83
7.5	Teste para rede treinada com métodos da Energia e BCED.	85
7.6	Teste para rede treinada com métodos da Energia, BCED e p -Norm.	85
7.7	Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA	86
7.8	Teste para rede treinada com estatística de Primeira Ordem.	87
7.9	Teste para rede treinada com estatística estendida.	87
7.10	Teste para rede treinada com MFCC convencional.	88
7.11	Teste para rede treinada com MFCC agregado.	88
7.12	Teste para rede treinada com métodos Energia, BCED, p -Norm e RLRT.	89
7.13	Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia.	90
8.1	Teste para rede treinada com método da Energia.	94
8.2	Teste para rede treinada com método BCED.	95
8.3	Teste para rede treinada com método p -Norm.	95
8.4	Teste para rede treinada com método MMA.	96
8.5	Teste para rede treinada com métodos da Energia e BCED.	97
8.6	Teste para rede treinada com métodos da Energia, BCED e p -Norm	97
8.7	Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA.	98
8.8	Teste para rede treinada com estatística de Primeira Ordem.	99
8.9	Teste para rede treinada com estatística estendida.	99
8.10	Teste para rede treinada com MFCC convencional.	100
8.11	Teste para rede treinada com MFCC agregado.	101
8.12	Teste para rede treinada com métodos Energia, BCED, p -Norm e RLRT.	102

8.13	Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia	102
9.1	Teste para rede treinada com método da Energia.	106
9.2	Teste para rede treinada com método BCED.	107
9.3	Teste para rede treinada com método p -Norm	107
9.4	Teste para rede treinada com método MMA.	108
9.5	Teste para rede treinada com métodos da Energia e BCED.	109
9.6	Teste para rede treinada com métodos da Energia, BCED e p -Norm.	110
9.7	Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA.	110
9.8	Teste para rede treinada com estatística de Primeira Ordem.	111
9.9	Teste para rede treinada com estatística estendida.	111
9.10	Teste para rede treinada com MFCC convencional	112
9.11	Teste para rede treinada com MFCC agregado.	112
9.12	Testes para rede treinada com métodos Energia, BCED, p -Norm e RLRT.	113
9.13	Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia.	113
10.1	Tabela resumindo todos os testes realizados com legenda de cores para os capítulos	126

Lista de Símbolos e Abreviaturas

AE Autoencoder

AM Modulação em Amplitude

ANATEL Agência Nacional de Telecomunicações

AWGN Additive White Gaussian Noise

BCED Blind Combined Energy Detection

CAPES Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CNN Convolutional Neural Network

EC Estimação de Correlação

ED Energy Detection

FFT Fast Fourier Transform

FM Modulação em Frequência

IBOPE Instituto Brasileiro de Opinião Pública e Estatística

LSTM Long Short-Term Memory

MFCC Mel-Frequency Cepstral Coefficients

MMA Maior e Menor Autovalor da Matriz de Covariância

PDF Probability Density Function

RLRT *Roy's Largest Root Test*

SIR *Signal-to-Interference Ratio*

SNR *Signal-to-Noise Ratio*

STFT *Short-Time Fourier Transform*

USRP *Universal Software Radio Peripheral*

WBFM *Wideband Frequency Modulation*

p-Norm *Método baseado na norma p*

Capítulo 1

Introdução

A história da rádio difusão no Brasil é marcada por importantes eventos e transformações ao longo do tempo, tendo iniciado em 7 de setembro de 1922 com sua primeira transmissão oficial (Mendonça, 2007). A sua regulamentação ocorreu em 1964, consolidando-a como um meio importante para a distribuição de informações em um vasto território que abrange 8.516.000 quilômetros quadrados. Além do seu legado histórico, a rádio teve um impacto significativo em todo o país, mantendo os ouvintes informados sobre eventos importantes. Nesse contexto, a concessão de canais a empresas privadas e a aprovação da publicidade comercial aumentaram a influência da rádio, transformando-a em uma poderosa força econômica.

No Brasil, os sistemas de rádio têm um impacto significativo na economia. A empresa Kantar IBOPE Media fornece uma avaliação anual da quantidade de uso de rádio em 13 diferentes áreas metropolitanas do país (*Kantar IBOPE - 2022, 2017-2023*). Essas áreas são a Grande Fortaleza, Grande Salvador, Grande Recife, Belo Horizonte, Rio de Janeiro, Vitória, Campinas, Grande São Paulo, Grande Goiânia, Distrito Federal, Grande Porto Alegre, Grande Florianópolis e Curitiba. Com base no estudo da Kantar IBOPE, a Figura 1.1 apresenta a porcentagem anual de pessoas que sintonizam as rádio FM nas áreas metropolitanas em questão, abrangendo uma população de aproximadamente 50 milhões de indivíduos. Esses dados, extraídos dos relatórios da Kantar IBOPE Media e referentes ao primeiro semestre de cada ano entre 2017 a 2023, fornecem informações

valiosas sobre a penetração e a consistência dos sistemas de rádios como meio de comunicação nessas regiões. A análise dessas informações revela percentual em torno de 82% no uso de rádio pela população (*Kantar IBOPE - 2020, 2017; Kantar IBOPE - 2018, 2018; Kantar IBOPE - 2019, 2019; Kantar IBOPE - 2020, 2020; Kantar IBOPE - 2021, 2021; Kantar IBOPE - 2022, 2022; Kantar IBOPE- 2023, 2023*).




Figura 1.1: Porcentagem de pessoas que ouvem rádio nas 13 regiões metropolitanas pesquisadas.

Além disso, a Figura 1.2 mostra o tempo médio diário dedicado à escuta de rádio nessas mesmas regiões metropolitanas. O tempo alocado à audição de programas de rádio representa um indicador do impacto desse meio na rotina das pessoas, uma vez que a programação pode ser adaptada ao público-alvo, alternando entre a transmissão de música e conteúdo publicitário. Ao longo dos anos de 2017 a 2023, observa-se uma variação significativa no tempo médio diário dedicado às rádios. Esses dados variaram de 4 horas e 40 minutos em 2017 a 3 horas e 55 minutos em 2023, o que mostra a importância de compreender a relação e o envolvimento da população com as programações transmitidas.

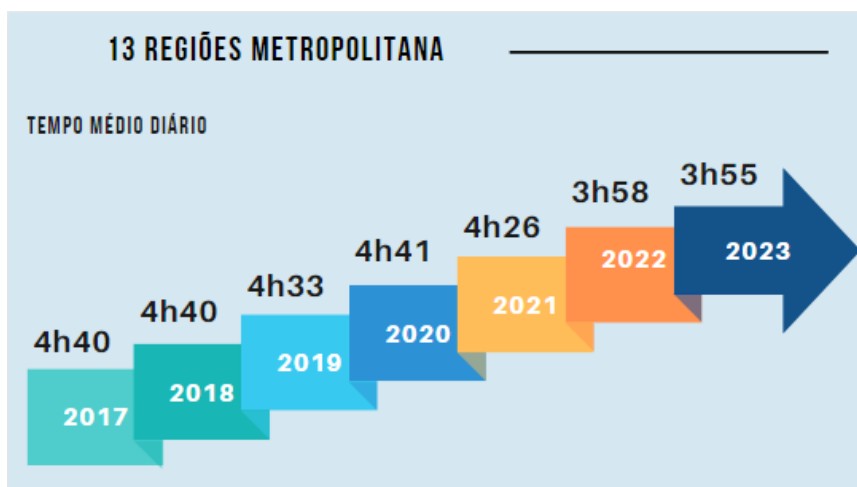


Figura 1.2: Tempo médio que cada pessoa consome de áudio nas 13 regiões metropolitanas pesquisadas.

A Figura 1.3 ilustra o papel das rádios no contexto econômico, ao mostrar a relação entre o uso do marketing e o número de marcas anunciantes, incluindo aquelas que escolhem as rádios como principal meio de divulgação de seus produtos e serviços.




Figura 1.3: Relação do uso do marketing por meio das rádios.

Essas informações mostram como as rádios são importantes para a publicidade e promoção de marcas durante o período analisado. Por exemplo, o eixo Y mostra o número

de marcas anúncios, marcas que usam a rádio e marcas que utilizam exclusivamente as rádios para anunciar seus produtos e serviços; em 2019, houve 7.300 anunciantes e 8.900 marcas fazendo anúncios na rádio, segundo (*Kantar IBOPE - 2019*, 2019). Dessas marcas, 4.753 escolheram usar apenas o rádio para divulgar seus produtos, o que destaca que as rádios têm atraído marcas exclusivas. Essa tendência continuou nos anos de 2020, 2021 e 2022, com um aumento significativo de marcas exclusivas em 2022. Esses dados mostram o quanto as rádios são importantes para o marketing, atraindo anunciantes e marcas que consideram o rádio uma forma fundamental de se conectar com o público.

No contexto econômico mencionado anteriormente, a Agência Nacional de Telecomunicações (Anatel) desempenha um papel fundamental na regulamentação e supervisão do setor de radiodifusão do Brasil. A Anatel é a autoridade reguladora responsável por garantir a conformidade e a legalidade das estações de rádio em operação no país.

Com um grande número de rádios espalhadas pelo país (Pieranti, 2019), o setor de radiodifusão brasileiro enfrenta um desafio persistente: as estações de rádio ilegais, frequentemente conhecidas como rádios piratas. Essas estações operam à margem da lei, perturbando frequentemente o espectro eletromagnético ao utilizar níveis de potência que excedem os limites legais ou faixas de frequências utilizadas por rádios legalizadas, resultando em interferência com as transmissões legítimas de rádio (Crepaldi and others, 2021).

As interferências causadas pelas estações de rádio ilegais resultam em uma série de problemas, incluindo:

- Interferência nas transmissões legais: As estações ilegais perturbam as transmissões legítimas de rádio, tornando-as de qualidade inferior ou até inaudíveis.
- Prejuízo a prestação de serviços: as comunicações tais como ambulância, polícia, comunicações aeronáuticas e rádios licenciadas sofrem de interferência causada por rádios ilegais.

- Prejuízo às emissoras legais: As rádios legais enfrentam perdas financeiras devido à redução de seu público devido à interferência, afetando suas receitas publicitárias.
- Riscos à segurança: A operação de estações ilegais pode levar a riscos de segurança, pois muitas vezes não estão sujeitas às regulamentações de segurança e qualidade que as rádios legais devem seguir.

A Figura 1.4 mostra o número de rádios fechadas pela Anatel em alguns anos divulgados (ANATEL, 2022). Embora não se disponha de dados atualizados sobre o fechamento de estações clandestinas de rádio, relatos da mídia em 2024 sugerem uma tendência consistente de fechamentos mensais.

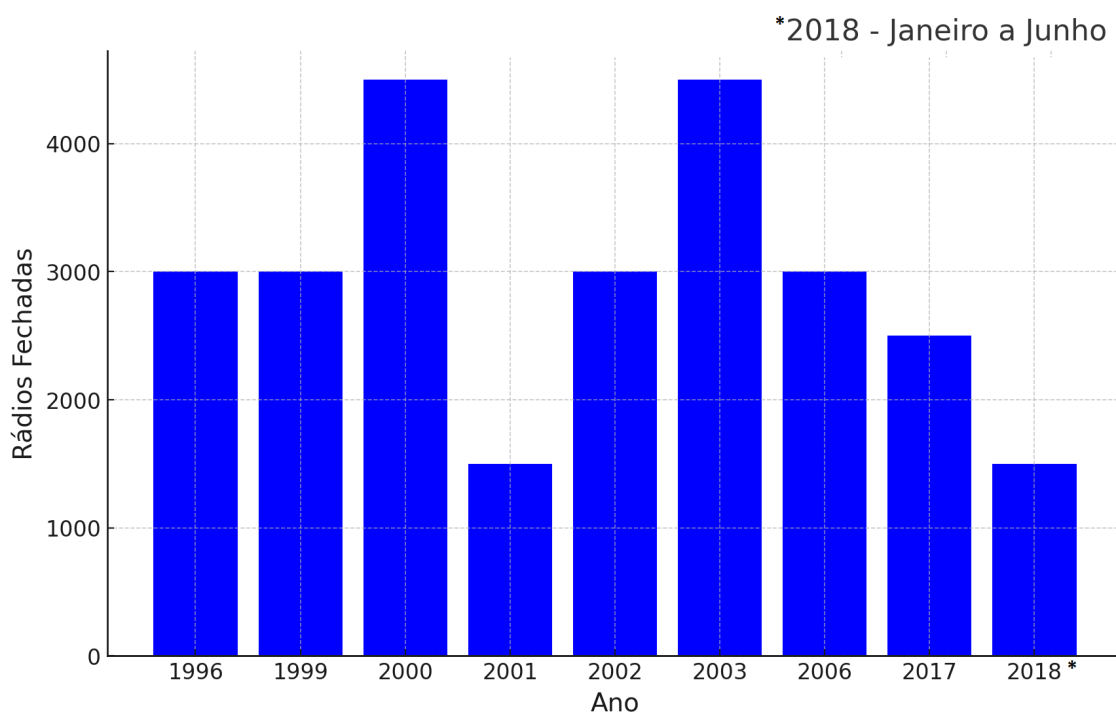


Figura 1.4: Número anual de estações de rádio fechadas pela Anatel.

As ações de fiscalização da Anatel são vitais para garantir um ambiente justo e regulamentado no setor de radiodifusão, promovendo a integridade das transmissões e protegendo os direitos das estações de rádio legais. Elas também contribuem para manter a qualidade das transmissões e assegurar que os ouvintes tenham acesso a conteúdo de

alta qualidade em todo o país. As constantes ações de fiscalização da Anatel demonstram a importância das rádios no Brasil, não apenas como veículos de comunicação, mas também como elemento essencial do panorama econômico e cultural do país.

1.1 Proposta da tese

A importância da radiodifusão no Brasil é incontestável, dada sua longa história e papel vital na disseminação de informações e entretenimento para uma população em um vasto território. Como parte desse contexto, a fiscalização e detecção de rádios ilegais desempenham um papel importante na manutenção da integridade desse meio de comunicação devido os problemas causados com a interferência.

Portanto, a proposta desta tese se edifica na importância crítica da detecção de sinais interferentes durante a comunicação das rádios FM e é dedicada a desenvolver métodos eficazes para identificar interferências. Esta pesquisa corrobora com o papel de manutenção da ordem no espectro eletromagnético, promovendo um ambiente regulamentado e justo para todas as emissoras de rádio.

A hipótese da tese é fundamentada na crença de que a combinação de métodos de aprendizado de máquina com técnicas de extração de características dos sinais de áudio pode ser empregada para identificar ocorrências de interferência em sinais de rádio. É comum que muitos trabalhos tratem todas as formas de interferência e ruído da mesma maneira. Esta tese aborda essa questão de maneira abrangente, diferenciando interferência de ruído AWGN. Neste trabalho, busca-se identificar a interferência causada por uma estação de rádio ilegal, mesmo que com baixa potência, mas que não deve ser confundida com o ruído. Essa distinção é importante para garantir a precisão na detecção de interferências específicas, como as originadas por fontes não autorizadas, que representam uma ameaça significativa à qualidade e integridade das transmissões de rádio.

Para alcançar esse objetivo, a detecção de interferência é investigada utilizando as

seguintes abordagens:

- Aplicação de detectores baseados em métodos de sensoriamento espectral de rádio cognitivo: são explorados métodos de sensoriamento espectral tradicionais para extrair informações dos sinais de áudio e treinar a rede, tais como: detecção por Energia, detecção de Energia Combinada Cegamente, p -Norm, Teste do Maior Autovalor de Roy, Maior e Menor Autovalor da Matriz de Covariância e Estimação de Correlação. Esta etapa traz uma inovação ainda não explorada em outros trabalhos de detecção de interferências, que utiliza métodos de sensoriamento espectral para coletar informações de sinais e treinar as redes.
- Aplicação de estatísticas de primeira ordem em métodos de aprendizado de máquina: são explorados os valores máximos, mínimos, média, variância e desvio padrão como *features* para treinar modelos de redes neurais. Embora esta etapa extraia características comuns de sinais de áudio, ela serve como caso de comparação para os métodos baseados no treinamento da rede com informações provenientes dos métodos de sensoriamento espectral.
- Aplicação de estatísticas de ordem estendida em métodos de aprendizado de máquina: são explorados os métodos de Coeficientes Cepstrais de Frequência Mel, Croma, Método Mel, Centroide Espectral, Largura de Banda Espectral e Declínio Espectral. Esta etapa já foi explorada em trabalhos de detecção de tons, melodias e, de forma subsidiária, na identificação de interferências.
- Detectores baseados em redes *Autoencoder* - (AE) (para sinais em banda base e banda passante): são investigados detectores baseados em redes *autoencoder*, que são capazes de aprender representações eficazes dos sinais de rádio e identificar anomalias que indicam interferência. Essa solução foi testada tanto com sinais em banda passante quanto em banda base. A ideia foi treinar uma rede com sinais FM sem interferência e explorar a capacidade de detecção de anomalias do *autoencoder* para detectar sinais com interferência. Esta etapa apresenta uma nova proposta

utilizando as redes *autoencoder*, ainda não observada na literatura científica.

- Detectores baseados em redes neurais convolucionais (CNN) (para banda Base e banda passante): as CNN são famosas por suas aplicações em reconhecimento de imagem e neste trabalho são empregadas com intuito de permitir a análise detalhada de sinais de FM em banda base e banda passante. Essas redes são treinadas para reconhecer padrões de interferência e realizar detecções de sinais interferente. Aqui, um sinal FM pode ser enxergado com uma imagem que está borrada por interferência, que precisa ser detectada.
- Gerador de sinais sintéticos de áudio para pré-processamento e treinamento: Nesta etapa metodológica, são gerados sinais de áudio sintéticos representativos de situações reais, incluindo sinais legítimos de rádios FM, ruído *Additive white Gaussian noise* (AWGN) e sinais de interferência. Esses sinais são utilizados para preparar adequadamente os dados para o treinamento das redes neurais.
- Testes práticos de detecção utilizando a *Universal Software Radio Peripheral* (USRP): Para validar a capacidade de detecção dos métodos propostos, foram realizados testes práticos de detecção. Para isso, foi usado um aplicativo de rádio FM no *smartphone* como receptor de sinais de rádio FM legítimos, enquanto uma USRP foi empregada para simular um sinal de rádio FM interferente. Durante os testes, foram avaliados diferentes níveis de interferência para verificar a capacidade de identificação dos sinais interferentes.

1.2 Produtos Tangíveis

Durante o doutorado e fruto de seu envolvimento em grupos de pesquisa na UFRN, o autor desta tese publicou os seguintes trabalhos:

- Unmanned Aerial Vehicle Propagation Channel over Vegetation and Lake Areas: First- and Second-Order Statistical Analysis, *SENSORS*, 2022.

- Uso de uma Rede Long-Term Memory (LSTM) para Predizer a Flutuação do Mercado Financeiro. In: II Simpósio de Pesquisa e Inovação em Tecnologia da Informação (SPITI 2020). Natal - Simpósio de Pesquisa e Inovação em Tecnologia da Informação, 2020.

Com a conclusão da tese, se planeja a confecção e submissão dos seguintes artigos:

- FM Broadcasting Piracy Detection: a Machine Learning Approach. Com o conteúdo do Capítulo 3 e 4.
- Expanding FM Broadcasting Piracy Detection: From Spectral Sensing to MFCC and Statistical Techniques. Com o conteúdo dos Capítulos 6 e 7.
- Experimental Evaluation of FM Broadcasting Piracy Detection: Analyzing Multiple Interference Scenarios. Com o conteúdo dos Capítulos 8, 9 e 10.

No próximo capítulo é apresentada a fundamentação teórica que sustenta a solução proposta nesta tese. São apresentados os métodos de sensoriamento espectral utilizados em rádios cognitivos, destacando como eles são empregados para extrair características dos sinais de rádio e treinar as redes neurais. Além disso, são discutidos os métodos mais comumente utilizados para a detecção de interferências, bem como as principais lacunas na literatura que motivaram e orientaram o desenvolvimento desta tese.

Capítulo 2

Fundamentação teórica e proposta de solução

Este capítulo explora os conceitos fundamentais da comunicação via rádio FM, abordando modulação em frequência, desafios atuais, e metodologias de detecção de interferência, incluindo a aplicação de aprendizado de máquina e processamento de sinais.

2.1 Princípios do sistema de comunicação via rádio FM

O sistema de comunicação via rádio, baseado na modulação em frequência (FM), é um dos pilares da radiodifusão devido à sua capacidade de oferecer uma transmissão de áudio de alta qualidade e confiabilidade. A FM envia informações na variação da frequência do sinal portador, o que resulta em uma transmissão mais robusta a variação de amplitude do sinal recebido. Essa qualidade superior em comparação com a modulação em amplitude (AM) é uma das principais razões para a popularidade dos sistemas de radiodifusão de alta-fidelidade utilizando FM (Haykin and Moher, 2011). A resistência a interferências proporcionada por essa modulação permite uma recepção de áudio mais clara, mesmo em áreas onde o sinal pode ser enfraquecido por obstáculos físicos.

2.1.1 Modulação em frequência: conceitos básicos

A modulação em frequência é uma técnica utilizada em sistemas de comunicação para transmitir informações por meio da da variação da frequência de um sinal portador em resposta ao sinal de mensagem. Os princípios básicos da modulação em frequência incluem:

- **Sinal portador (*Carrier Signal*):** Um sinal portador de alta frequência é utilizado como veículo para transportar a informação. Este sinal portador é uma onda senoidal de frequência definida.
- **Sinal de mensagem (*Message Signal*):** O sinal de mensagem é uma onda em banda base que carrega a informação a ser transmitida, e.g., um sinal de áudio.
- **Desvio de frequência (*Frequency Deviation*):** A informação contida no sinal de mensagem modifica a frequência instantânea do sinal portador. O quanto a frequência do portador é desviada em resposta ao sinal de mensagem é chamado de desvio de frequência.
- **Sensibilidade de frequência (k_f):** A sensibilidade de frequência, k_f , é um parâmetro que determina o quão sensível o sinal portador é às mudanças no sinal de mensagem. Quanto maior o valor de k_f , maior será o desvio de frequência em resposta a variações no sinal de mensagem.
- **Equação da modulação FM:** A equação que descreve a modulação em frequência é dada por:

$$s(t) = A_c \cos \left(2\pi f_c t + 2\pi k_f \int m(\tau) d\tau \right),$$

sendo:

- $s(t)$ é o sinal modulado em frequência.
- A_c é a amplitude do sinal portador.

- f_c é a frequência do sinal portador.
 - k_f é a sensibilidade de frequência.
 - $m(t)$ é o sinal de mensagem.
- **Demodulação FM:** Na recepção, é necessário um processo de demodulação para recuperar o sinal de mensagem original. A demodulação FM envolve detectar as variações na frequência do sinal recebido, distorcido pelo canal e perturbado por ruído e interferência, para extrair um sinal mais próximo possível do sinal de mensagem transmitido.

Esses são alguns dos princípios básicos da modulação em frequência, um conceito essencial em sistemas de radiodifusão e em várias formas de comunicação sem fio, bem como para esta tese.

2.1.2 Desafios e tendências atuais das rádios FM

Atualmente, a radiodifusão enfrenta desafios e tendências dinâmicas. A competição por espectro, as mudanças nas preferências do público e o surgimento de novas tecnologias são fatores que moldam o sistema FM. A compreensão desses desafios e tendências é essencial para contextualizar as estratégias de detecção de interferência que serão abordadas posteriormente neste trabalho.

Apesar das vantagens, os sistemas de rádio enfrentam desafios contemporâneos, incluindo a crescente competição com plataformas de transmissão digital e serviços de *streaming online*. A transição para métodos de transmissão mais avançados e a adaptação às preferências do público representam áreas de evolução para os sistemas de rádio (Kantar IBOPE, 2022; MOREIRA, 2001).

A seguir, destacam-se alguns dos desafios e tendências atuais que impactam o cenário das rádios (Kantar IBOPE- 2023, 2023):

- **Competição digital:** O aumento da presença de plataformas de transmissão digital

e serviços de *streaming* desafia a posição tradicional das rádios. A busca por manter a relevância em um ambiente digitalizado é um desafio constante.

- **Adaptação tecnológica:** A transição para tecnologias mais avançadas, como a digitalização da transmissão, impõe desafios de infraestrutura e investimentos para as rádios. A atualização constante é necessária para garantir a qualidade e eficiência das transmissões.
- **Evolução do consumo de mídia:** Mudanças nos hábitos de consumo de mídia, com uma tendência crescente em direção a plataformas *online*, demandam estratégias inovadoras para atrair e manter a audiência tradicional das rádios FM.
- **Diversidade de conteúdo:** A necessidade de oferecer uma ampla variedade de conteúdos para atender a diferentes segmentos da audiência é um desafio. As rádios FM precisam equilibrar a tradição de transmitir música com a demanda por programas informativos e diversificados.
- **Integração multimídia:** A integração de elementos multimídia, como *streaming* de vídeo e interação *online*, torna-se cada vez mais relevante. A adaptação a essas formas de conteúdo é importante para atrair novos públicos.
- **Padrões de publicidade:** O modelo tradicional de publicidade nas rádios FM enfrenta desafios com a evolução das estratégias de *marketing*. A necessidade de inovação na publicidade para manter receitas é um aspecto crítico.
- **Desafios regulatórios:** A conformidade com regulamentações em constante evolução, especialmente no que diz respeito às questões de propriedade e licenciamento, é um desafio burocrático que as rádios FM enfrentam.
- **Segmentação de audiência:** A demanda por uma programação mais personalizada e segmentada requer esforços para compreender as preferências da audiência e adaptar a oferta de conteúdo de acordo.
- **Sustentabilidade ambiental:** Considerações sobre o impacto ambiental das operações de transmissão e a busca por práticas mais sustentáveis estão se tornando

uma preocupação crescente.

- **Concorrência por atenção:** Em um cenário de abundância de opções de entretenimento, a concorrência pela atenção do público exige estratégias inovadoras para destacar as rádios FM.

Apesar desses desafios, as rádios FM continuam a desempenhar um papel importante na comunicação, fornecendo informações e entretenimento em diversas regiões.

2.2 Métodos de detecção de interferência

A detecção de interferência em sinais de rádio é um desafio importante na manutenção da qualidade das transmissões e na garantia de uma experiência de escuta de alta qualidade (CISA, 2020). Esta seção propõe apresentar os métodos empregados para identificar interferências em sistemas de comunicação via rádios FM.

2.2.1 Métodos manuais e analógicos

Nos estágios iniciais, a detecção de interferência era uma tarefa predominantemente manual. Operadores de rádio, muitas vezes, dependiam de técnicas analógicas para identificar a presença de sinais indesejados. Esses métodos envolvem ouvir atentamente o sinal e analisar visualmente um gráfico de espectro, em busca de padrões que indiquem interferência. Embora esses métodos sejam um ponto de partida, eles são limitados em eficiência e capacidade de lidar com interferências de outras rádios (Harrold, 1971).

2.2.2 Algoritmos de processamento de sinal

Com o avanço dos algoritmos de processamento de sinal, a detecção de interferência deu um salto significativo. Algoritmos mais sofisticados foram desenvolvidos para analisar as características dos sinais e identificar padrões que indicassem a presença de

interferência, como nos trabalhos (Tingay et al., 2020) e (Adelabu et al., 2021). Esses métodos proporcionaram uma abordagem mais eficiente e rápida em comparação com os processos manuais. No entanto, ainda enfrentavam desafios na detecção de fontes específicas de interferência.

2.2.3 Técnicas de aprendizado de máquina

A revolução das técnicas de aprendizado de máquina pode promover avanços na área de detecção de interferência. Com a capacidade de treinar algoritmos para reconhecer padrões complexos, os sistemas baseados em aprendizado de máquina tornaram-se mais adaptáveis e eficazes na identificação de interferências em diferentes ambientes (Sajichandrachood and Sethunadh, 2023). Essa evolução permite explorar uma detecção mais precisa de interferência causada por outras fontes de rádios FM.

2.2.4 Tendências atuais e futuras

Atualmente, observa-se uma procura pela convergência de diferentes métodos, combinando algoritmos de processamento de sinal e técnicas de aprendizado de máquina para melhorar a detecção de interferência (Bonet-Solà and Alsina-Pagès, 2021). A tendência futura aponta para sistemas mais autônomos e adaptáveis, capazes de lidar com interferências em tempo real e se ajustar dinamicamente a diferentes ambientes. A Tabela 2.1 destaca os estágios-chave na evolução da detecção de interferência, desde métodos manuais e analógicos até a integração de algoritmos de processamento de sinal e aprendizado de máquina, refletindo a busca por métodos mais eficientes e adaptáveis.

Tabela 2.1: Tabela Comparativa da Evolução da Detecção de Interferência

Era	Métodos Utilizados	Características Principais
Era Inicial	Métodos Manuais e Analógicos	Dependência da análise humana, baixa eficiência.
Era do Processamento de Sinal	Algoritmos de Processamento de Sinal	Automação parcial, melhoria na eficiência, limitações em interferências complexas.
Era do Aprendizado de Máquina	Técnicas de Aprendizado de Máquina	Reconhecimento de padrões complexos, adaptação a ambientes dinâmicos, avanço na precisão.
Era Atual e Futura	Integração de Métodos	Combinação de algoritmos de processamento de sinal e aprendizado de máquina, busca por autonomia e adaptabilidade em tempo real.

2.2.5 Teorias e modelos existentes

A Tabela 2.2 apresenta diversos métodos utilizados para a detecção de sinais interferentes, abrangendo desde abordagens clássicas até técnicas modernas.

Tabela 2.2: Métodos de Detecção de Sinais Interferentes

Método	Descrição
Filtros Passa-Banda	Utilização de filtros para permitir a passagem somente das frequências relevantes, isolando o sinal desejado e reduzindo interferências fora dessa faixa.
Algoritmos de Processamento de Sinal	Aplicação de algoritmos avançados de processamento de sinais para analisar as características do sinal e identificar padrões que indiquem a presença de interferência.
Análise Espectral	Exame da distribuição de energia nas diferentes frequências do espectro para identificar picos ou alterações que possam indicar a presença de interferência.
Métodos Estatísticos	Utilização de técnicas estatísticas para analisar padrões temporais e identificar comportamentos anômalos que correspondam a sinais interferentes.
Aprendizado de Máquina	Treinamento de modelos de aprendizado de máquina com dados de sinais limpos e interferidos para que o sistema possa identificar automaticamente padrões de interferência.
Sensores de Campo Eletromagnético	Utilização de sensores especializados para medir a intensidade do campo eletromagnético, identificando áreas com interferência significativa.
Métodos de Correlação	Comparação de sinais recebidos com modelos de sinais conhecidos para identificar padrões de correlação que indiquem a presença de interferência.
Análise de Características Específicas	Identificação de características específicas de sinais interferentes, como padrões de pulso, amplitude ou modulação, para distingui-los do sinal desejado.
Monitoramento de Integridade do Sinal	Acompanhamento contínuo da qualidade do sinal, observando variações repentinas ou degradações que possam indicar a presença de interferência.
Sensores Inteligentes	Implementação de sensores inteligentes capazes de adaptar dinamicamente suas configurações com base nas condições do ambiente, detectando interferências de forma proativa.

Esses métodos oferecem características distintas que os tornam adequados para diferentes cenários de interferência, demonstrando diversidade de estratégias disponíveis para lidar com sinais interferentes em sistemas de rádio.

2.2.6 Oportunidades de Pesquisa na Literatura

A Tabela 2.3 oferece uma visão comparativa dos principais métodos de detecção de sinais interferentes, destacando tanto suas vantagens quanto suas limitações.

Tabela 2.3: Comparação de Métodos de Detecção de Sinais Interferentes

Método	Vantagens	Desvantagens
Filtros Passa-Banda	Eficiente na redução de interferências fora da faixa desejada.	Pode atenuar sinais desejados se não configurado corretamente.
Algoritmos de Processamento de Sinal	Capacidade de analisar características complexas do sinal.	Requer conhecimento avançado em processamento de sinal.
Análise Espectral	Identificação eficaz de picos ou alterações no espectro.	Pode ser sensível a ruídos e variações benignas.
Métodos Estatísticos	Análise robusta de padrões temporais.	Sensível a variações não relacionadas a interferência.
Aprendizado de Máquina	Adaptação automática a padrões complexos.	Requer conjunto de dados extenso e representativo.
Sensores de Campo Eletromagnético	Medição direta da intensidade do campo.	Pode ser influenciado por fontes não interferentes.
Métodos de Correlação	Comparação eficaz com modelos conhecidos.	Sensível a variações devido a condições de propagação.
Análise de Características Específicas	Foco em características distintivas.	Pode falhar em identificar interferências não convencionais.
Monitoramento de Integridade do Sinal	Detecção de variações repentinas.	Pode ser influenciado por eventos não interferentes.
Sensores Inteligentes	Adaptação dinâmica às condições do ambiente.	Complexidade de implementação e configuração.

Compreender as características dos diversos métodos permite selecionar a abordagem mais adequada às necessidades de cada aplicação, levando em consideração fatores como precisão, robustez, custo e requisitos de implementação. Nesse contexto, é fundamental explorar novas técnicas e aprimoramentos, visando melhorar ainda mais a capacidade de detecção de interferências, garantindo assim uma comunicação estável e livre de problemas para os ouvintes.

Apesar dos progressos alcançados na detecção de interferências, ainda existem lacunas na literatura que justificam a necessidade de métodos mais robustos. Desafios como adaptação a condições dinâmicas, detecção em tempo real e capacidade de identificação continuam a desafiar as abordagens existentes. Além disso, a detecção de outras rádios como fontes de interferência não tem recebido a devida atenção, uma vez que os métodos geralmente se concentram na detecção da presença de ruído, sem considerar o tipo específico de emissor.

2.3 Métodos de sensoriamento espectral selecionados

Foram escolhidos alguns métodos clássicos de sensoriamento espectral para servirem de entrada para a rede *Autoencoder* e a CNN. Tais métodos foram selecionados com base na sua diversidade de características e capacidades. Os detalhes sobre cada método estão apresentados a seguir.

2.3.1 Método de Detecção de Energia (ED)

O método da energia é uma abordagem amplamente empregada na detecção de sinais em rádios cognitivos e pode ser adaptado para identificar sinais sobrepostos. Essa técnica fundamenta-se na medição e comparação da energia total dos sinais recebidos. Ao analisar um sinal $y(i)$, a energia total é calculada por (Steven, 1993):

$$T = E = \sum_{i=1}^N |y[i]|^2$$

A detecção de um sinal de interferência ocorre quando a energia em uma banda de frequência específica ultrapassa um limite predefinido (γ). Assim, se $T > \gamma$, rejeita-se a hipótese nula (H_0), indicando a presença de interferência.

2.3.2 Método p -Norm

O Detector p -Norm, também conhecido como *Energy Detector* aprimorado é uma técnica utilizada em sistemas de comunicação e rádios cognitivos para detectar e estimar sinais em diferentes ambientes. Utilizando a norma p , ele calcula a energia dos sinais recebidos, distinguindo o sinal de interesse do ruído e outros sinais indesejados (Banjade et al., 2014). A escolha do parâmetro p na norma possibilita a adaptação a diferentes tipos de sinais, proporcionando diferentes capacidades de identificação dos sinais desejados em meio ao ruído (Banjade et al., 2015).

É relevante observar que a equação do Detector p -Norm depende diretamente do valor da variância do ruído (σ_n^2), o qual pode ser desafiador de estimar com precisão. Para tal, frequentemente recorre-se à variância do próprio sinal recebido (σ_y^2), pois à medida que o sinal apresenta maior ruído, sua variância também aumenta. Entretanto, essa abordagem tem suas limitações, uma vez que a estimativa direta da variância do ruído pode ser difícil em situações práticas. No caso específico mencionado, adotou-se um valor de $p = 3$ na norma, indicando uma preferência pela sensibilidade a características específicas do sinal em questão.

A equação para o p -Norm é expressa por:

$$T = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i}{\sigma_y} \right|^p$$

em que $y_i \forall i \in \{1, 2, \dots, N\}$ representa a i -ésima amostra do sinal recebido, $p > 0$ é uma constante arbitrária, σ_y é o desvio padrão do sinal recebido e N é o número total de amostras.

2.3.3 Detecção de Energia Combinada Cegamente (BCED)

A Detecção de Energia Combinada Cegamente (BCED) destaca-se como uma técnica eficaz para a detecção de sinais em ambientes nos quais as fontes de sinal misto

apresentam correlação. Uma característica distintiva do BCED envolve a consideração de propriedades estatísticas fundamentais, particularmente as matrizes de covariância estatística $Cov_y = \frac{1}{N}YY^H$, em que Y^H é a Hermitiana da matriz que representa as propriedades estatísticas do sinal recebido Y , e N é o número total de amostras. Essas matrizes oferecem informações sobre a distribuição e correlação do sinal, em que se busca encontrar o seu maior autovetor v correspondente ao maior autovalor R .

Em cenários práticos, devido à falta de conhecimento sobre as matrizes de covariância estatística, recorre-se à utilização da matriz de covariância amostral do sinal recebido $\hat{R} = \frac{1}{N} \sum_{n=1}^N x[n]x^H[n]$ como uma aproximação. O autovetor normalizado \hat{v} , associado ao maior autovalor de \hat{R} , é empregado no BCED. A estatística de teste para o BCED, $T_{\text{BCED}} = |x^H \hat{v}|^2$, é então calculada (Zeng et al., 2008).

Essa estatística de teste é interpretada como uma medida da energia combinada, e a comparação com um limiar predefinido determina a detecção do sinal de interesse. A decisão final considera a relação entre T_{BCED} e o limiar: se $T_{\text{BCED}} > \gamma$, considera-se que o sinal de interferência está presente; caso contrário, é considerado ausente o sinal de interferência.

O BCED, assim como o método ED, baseia-se exclusivamente em amostras do sinal recebido, eliminando a necessidade de informações sobre o sinal transmitido e o canal. Uma das principais vantagens do BCED sobre o p -Norm é a ausência da necessidade de conhecimento da variância do ruído para a decisão, enquanto o BCED também pode apresentar um desempenho superior para sinais altamente correlacionados.

2.3.4 Teste do Maior Autovalor de Roy (RLRT)

O teste do maior autovalor de Roy, também conhecido como teste de detecção baseado no maior autovalor da matriz de covariância, é um método estatístico robusto e amplamente empregado na detecção de sinais em diferentes ambientes (Nasser et al., 2021).

Considerando Y como uma matriz representando os dados das amostras recebidas, em que as linhas são amostras do sinal e as colunas representam as diferentes medições de amostras, o objetivo é avaliar a hipótese nula de que Y é composto exclusivamente por sinal legítimo.

O método fundamenta-se na decomposição espectral da matriz de covariância $Cov_y = \frac{1}{N}YY^H$. O maior autovalor de C é computado e comparado com um limiar crítico estabelecido por métodos estatísticos.

A estatística de teste T é dada pelo maior autovalor de Y e é expressa como:

$$T = \frac{\max(\lambda_i)}{\sigma_n^2}, \quad (2.1)$$

em que $\max(\lambda_i)$ é o maior autovalor de C , e σ_n^2 representa a variância do ruído, embora, na prática, seja comum utilizar a variância do sinal σ_s^2 . Sob a hipótese nula de ausência de sinal de interesse, a distribuição do maior autovalor é determinada, geralmente seguindo a distribuição de Marchenko-Pastur.

Se o valor de T ultrapassa o limiar crítico (γ), calculado a partir de uma distribuição de referência, a hipótese nula (H_0) é rejeitada, sinalizando a presença de sinal de interesse na matriz de dados Y . Esta decisão é tomada com base na comparação entre T e o limiar estabelecido: se $T > \gamma$, rejeita-se H_0 , indicando a detecção do sinal de interferência; caso contrário, mantém-se a hipótese nula, sugerindo a ausência do sinal de interferência.

Este método é empregado em sistemas de detecção de espectro para identificar sinais fracos ou interferências em ambientes ruidosos. Embora sua capacidade possa ser influenciada por diversos fatores, como o tamanho da matriz Y e a presença de ruído não aleatório.

2.3.5 Maior e Menor Autovalor da Matriz de Covariância (MMA)

Este método precisa apenas conhecer os autovalores mais altos e mais baixos da matriz de covariância. Uma vez que os autovalores da matriz de covariância são calculados, os valores máximo e mínimo são extraídos, e T é calculado conforme a Equação 2.2 (Wael et al., 2016):

$$T(Y) = \frac{\lambda_{\max}}{\lambda_{\min}}, \quad (2.2)$$

em que λ_{\max} é o maior autovalor da matriz de covariância, λ_{\min} é o menor. Se o valor de T ultrapassar um limiar crítico γ determinado, a hipótese nula H_0 é rejeitada, indicando a presença de sinais de interferência na matriz de dados Y .

2.3.6 Estimação de Correlação (EC)

O EC representa um importante detector de máxima verossimilhança para sinais (Steven, 1993). Este método requer conhecimento prévio tanto do ruído quanto dos sinais de interferência. O EC utiliza esse conhecimento para correlacionar os sinais previstos com o sinal recebido no receptor, conforme descrito em (Steven, 1993).

O teorema de Neyman-Pearson (NP) é aplicado para determinar a variável T , maximizando a taxa de detecção verdadeira positiva da interferência para uma dada taxa de detecção falsa positiva (Steven, 1993). O NP estabelece que a razão de verossimilhança das hipóteses deve ser maior que γ para rejeitar a hipótese nula H_0 , como escrito na seguinte equação:

$$L(x) = \frac{p(x|H_1)}{p(x|H_0)} > \gamma \quad (2.3)$$

Pressupõe-se que o ruído é estacionário e possui uma variância conhecida σ_n^2 , sem depender do sinal transmitido $x(t)$. O sinal $x(t)$ também é conhecido. Com essas

premissas, o método é derivado detalhadamente no trabalho. Como resultado, a estatística de teste T pode ser expressa da seguinte forma:

$$T(x) = \sum_{n=0}^{N-1} y(t)\hat{s}(t), \quad (2.4)$$

sendo $\hat{s}(t)$ calculado como:

$$\hat{s} = C_s(C_s + \sigma^2 I)^{-1} y^T, \quad (2.5)$$

em que C_s é a matriz de covariância do sinal a ser identificado, I é a matriz identidade com dimensão de C_s , e y^T é a matriz transposta do sinal que chega ao receptor. A Equação pode ser adaptada para identificar interferência. Assim, tem-se $\hat{s}(t)$ como uma função de interferência:

$$\hat{s}_i = C_i(C_i + \sigma^2 I)^{-1} y^T \quad (2.6)$$

em que C_i é a matriz de covariância de um sinal de interferência, e sua medida T é dada por:

$$T(Y) = \frac{1}{m \cdot n} \sum_{i=1}^n \sum_{j=1}^m Y \hat{s}_i(t) \quad (2.7)$$

No entanto, apesar de seus benefícios teóricos, por ser o detector ótimo, sua implementação prática pode ser desafiadora devido à necessidade de informações frequentemente difíceis de obter, neste caso, o sinal interferente. Contudo, ele é geralmente utilizado como referência para comparação de desempenho com outros métodos de detecção.

2.4 Métodos selecionados para comparação

Os métodos a seguir foram empregados no treinamento tanto da rede CNN quanto da *Autoencoder*, a fim de comparação com os métodos de sensoriamento espectral mostrados anteriormente. Esses métodos foram escolhidos por serem amplamente reconhecidos na literatura como padrões de referência em análise de sinais de áudio e porque oferecem uma diversidade de abordagens que permitem avaliar a rede.

2.4.1 Coeficientes Cepstrais de Frequência Mel (MFCC)

Os Coeficientes Cepstrais de Frequência Mel (MFCCs) são uma representação detalhada das características do espectro de um sinal de áudio. Eles são derivados da transformada de cosseno discreto de um logaritmo do espectrograma de potência, semelhante à transformada de Fourier. Os MFCCs são particularmente úteis na representação de características fundamentais do espectro de áudio, capturando aspectos relevantes da percepção humana de som, sendo amplamente empregados em tarefas de reconhecimento de fala e música (Abdul and Al-Talabani, 2022).

2.4.2 Croma

A representação cromática é uma técnica que sumariza o conteúdo harmônico de um sinal de áudio. Ela codifica a presença de diferentes notas musicais, independentemente da oitava em que são tocadas. O objetivo é calcular a representação cromática a partir da Transformada de Fourier de Tempo Curto (STFT) de um sinal de áudio. É particularmente útil em análises de música, identificando padrões de acordes e progressões musicais (Längkvist et al., 2014).

2.4.3 Método Mel

O espectrograma Mel é uma representação do espectro de potência de um sinal de áudio, usando a escala de frequência de Mel. Baseado na percepção humana de frequência, o espectrograma Mel é utilizado em análises musicais e na extração de características para processamento de áudio, permitindo a identificação e a análise de componentes tonais (Abdul and Al-Talabani, 2022).

2.4.4 Centroide espectral

O centroide espectral é uma medida que representa o centro de gravidade do espectro de frequência. Ele indica onde está localizada a massa das frequências no espectro. Uma frequência mais alta do centroide indica que a maior parte da energia está concentrada nessa frequência. A centroide espectral é útil na análise de timbre e na identificação de características tonais (Mehrabi et al., 2017).

2.4.5 Largura de banda espectral

A largura de banda espectral é uma medida da faixa de frequências contidas no espectro de um sinal de áudio. Refere-se à largura em hertz de uma distribuição de frequência, fornecendo informações sobre a dispersão das frequências presentes no sinal (Ghamisi et al., 2014).

2.4.6 Declínio espectral

O declínio espectral é uma medida que descreve a diminuição gradual da energia ou amplitude das componentes de frequência em um sinal ao longo do espectro. Reflete a tendência de redução na intensidade das frequências à medida que a frequência aumenta ou diminui. Esta medida é frequentemente utilizada na análise de sinais de áudio e de

outros tipos de sinais, fornecendo informações importantes sobre a distribuição espectral e a caracterização do conteúdo frequencial de um sinal (Stolar et al., 2018).

2.5 Detectores de Interferência Propostos

Nesta seção, explora-se a aplicação de *Autoencoders* e CNNs para a detecção de interferências em sinais de rádio. Primeiramente, apresenta-se uma introdução aos conceitos básicos dessas técnicas, seguida pela descrição de suas arquiteturas e funcionamento no contexto da detecção de interferências.

A Figura 2.1 apresenta um fluxograma que resume o processo metodológico seguido nesta tese, desde a geração dos sinais de áudio até a análise dos resultados obtidos com as técnicas propostas. O diagrama é dividido em várias seções que se interligam, cada uma representando uma etapa do desenvolvimento dos métodos propostos.

A primeira parte do fluxograma ilustra a geração de sinais de áudio que foi usada para a criação dos conjuntos de dados utilizados nas fases subsequentes. A geração de sinais é dividida em dois cenários: o primeiro considerando um único sinal de interferência, e o segundo envolvendo múltiplos sinais de interferência. Para ambos os cenários, os sinais são sorteados de dois bancos de dados de áudio, passando por um ajuste de potência para controle da SNR e da SIR, conforme necessário.

A fase de extração de características está dividida em quatro principais abordagens: Primeira Ordem, Ordem Estendida, Métodos Lineares e MFCC. Cada abordagem utiliza diferentes técnicas para extrair informações relevantes dos sinais de áudio. As características extraídas são então organizadas em conjuntos isolados ou combinados, servindo como entrada para os modelos de redes neurais.

Como mencionado anteriormente, o fluxograma mostra o treinamento de dois tipos de redes neurais: *Autoencoder* e CNN. O *Autoencoder* é utilizado para detectar anomalias nos sinais, sendo útil para a identificação de interferências, enquanto a CNN é empregada

para a classificação dos sinais com base em padrões identificados nos dados.

A última parte do fluxograma detalha as etapas de análise dos resultados obtidos, em que são comparados os métodos lineares com o *Autoencoder*, seguidos pela análise de desempenho da CNN.

2.5.1 *Autoencoder* e Redes Neurais Convolucionais

Um *Autoencoder* é uma arquitetura de rede neural composta por duas partes principais: o *encoder* e o *decoder*. O *encoder* reduz a dimensionalidade da entrada, transformando-a em uma representação compactada, enquanto o *decoder* reconstrói a entrada original a partir dessa representação reduzida. Matematicamente, o processo pode ser descrito como (Goodfellow et al., 2016):

- **Codificação:**

$$\mathbf{z} = f_{\text{encoder}}(\mathbf{x}) = \sigma(\mathbf{W}_e \mathbf{x} + \mathbf{b}_e), \quad (2.8)$$

em que \mathbf{x} é o vetor de entrada, \mathbf{W}_e e \mathbf{b}_e são os pesos e viés do *encoder*, σ é a função de ativação, e \mathbf{z} é a representação latente.

- **Decodificação:**

$$\hat{\mathbf{x}} = f_{\text{decoder}}(\mathbf{z}) = \sigma'(\mathbf{W}_d \mathbf{z} + \mathbf{b}_d), \quad (2.9)$$

as variáveis \mathbf{W}_d e \mathbf{b}_d são os pesos e viés do *decoder*, σ' é a função de ativação, e $\hat{\mathbf{x}}$ é a reconstrução da entrada.

O objetivo do *Autoencoder* é minimizar a diferença entre a entrada \mathbf{x} e a reconstrução $\hat{\mathbf{x}}$, sendo medido pelo erro quadrático médio:

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|^2, \quad (2.10)$$

em que N é o número de amostras.

As Redes Neurais Convolucionais (CNNs) são especialmente eficazes na análise de dados com estrutura *grid-like*, como imagens e sinais de áudio. Essas redes aplicam filtros convolucionais sobre os dados de entrada para extrair características relevantes, seguidas por camadas de *pooling* para redução da dimensionalidade e camadas totalmente conectadas para a tomada de decisão. O processo de convolução pode ser descrito como (Goodfellow et al., 2016):

$$\mathbf{Y}(i, j) = \sum_m \sum_n \mathbf{X}(i + m, j + n) \cdot \mathbf{K}(m, n) + b, \quad (2.11)$$

em que \mathbf{X} é o dado de entrada (como uma imagem ou espectrograma), \mathbf{K} é o filtro de convolução, b é o viés, e (i, j) são as coordenadas do mapa de características de saída \mathbf{Y} .

Após a convolução, uma função de ativação, como ReLU, é aplicada:

$$\mathbf{Y}'(i, j) = \text{ReLU}(\mathbf{Y}(i, j)) = \max(0, \mathbf{Y}(i, j)). \quad (2.12)$$

As camadas de *pooling* são utilizadas para redução da dimensionalidade, sendo o *max-pooling* um dos métodos mais comuns:

$$\mathbf{P}(i, j) = \max_{(p, q) \in R} \mathbf{Y}'(p, q), \quad (2.13)$$

em que R é a região do filtro de *pooling*.

Finalmente, a saída das camadas convolucionais pode ser passada para camadas totalmente conectadas, com ativação *softmax* para a classificação:

$$\mathbf{o} = \text{softmax}(\mathbf{W}\mathbf{v} + \mathbf{b}), \quad (2.14)$$

em que \mathbf{v} é o vetor achatado das características, \mathbf{W} e \mathbf{b} são os pesos e viés da camada, e \mathbf{o} representa as probabilidades das classes.

Tanto os *Autoencoders* quanto as CNNs oferecem diferentes possibilidades para a

detecção de interferências em sinais de rádio, cada uma com suas próprias características, vantagens e desvantagens. A escolha entre uma e outra depende dos requisitos específicos de cada aplicação, como a disponibilidade de dados, tipos de dados, dados rotulados e a necessidade de generalização.

2.5.2 Autoencoder como detector de interferência

Para a detecção de interferência em sinais de rádio, a rede foi treinada com um conjunto de dados extraídos de sinais de rádio sem interferência, mas com ruído, mantendo a SNR controlada. Após o treinamento, foram realizados testes de validação para medir o quão bem o modelo generaliza dados não utilizados no treinamento.

Assim, quando a rede recebe dados extraídos de um sinal sem interferência, espera-se que a diferença entre o dado de entrada e o dado reconstruído pela parte *decoder* da rede seja pequena. Por outro lado, quando os dados de entrada provêm de sinais com interferência, espera-se que ocorra um erro maior na reconstrução. Essa é a lógica que edifica a proposta desta tese, diferenciar entre os tipos de sinais (com e sem interferência) com base no Erro Médio Quadrático (MSE) entre o dado de entrada e o dado reconstruído pelo *decoder*.

2.5.3 Rede Neural Convolutacional como detector de interferência

Para realizar a detecção de interferência com CNN, a rede foi treinada com um conjunto de dados que incluía sinais de rádio tanto com interferência quanto sem interferência. Todos os sinais continham ruído, e os parâmetros de SNR e SIR foram controlados nos sinais dos quais as características foram extraídas. Após o treinamento, testes de validação foram realizados para verificar a capacidade de classificação da rede. Durante a validação e o uso da rede treinada, quando a rede recebe dados de um sinal sem interferência, a função de ativação *sigmoid* é aplicada. Se a saída da rede CNN for

inferior a 0,5, o sinal é classificado como sem interferência; se a saída estiver entre 0,5 e 1, o sinal é classificado como contendo interferência.

No próximo capítulo é apresentada a metodologia do trabalho, abrangendo a geração dos bancos de dados de sinais, o enquadramento do problema como uma hipótese binária, o cálculo de distâncias entre as funções de densidade de probabilidade (PDFs) e a preparação dos dados para o treinamento das redes Autoencoder e CNN. Também são detalhados o processo de otimização dos hiperparâmetros e a metodologia experimental, incluindo o uso da plataforma USRP para avaliar os resultados teóricos com experimentos práticos.

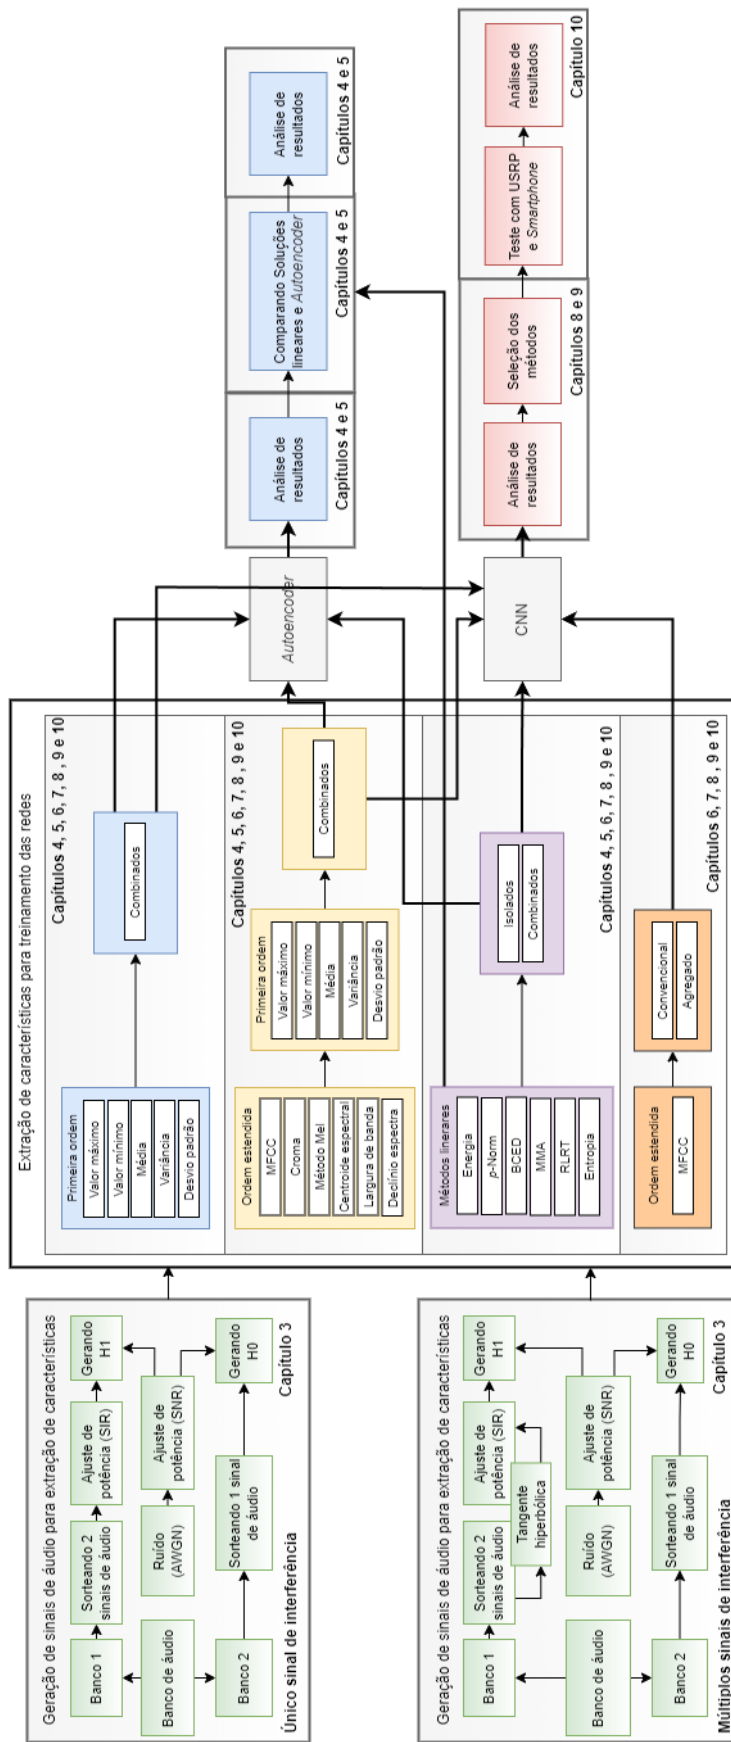


Figura 2.1: Fluxograma do trabalho desenvolvido

Capítulo 3

Metodologia

Neste capítulo, apresenta-se a metodologia da pesquisa, que inclui a geração de sinais em cenários com e sem interferência, em que a interferência, quando presente, varia em diferentes níveis de potência. São exploradas estratégias de detecção de interferência, além do pré-processamento para extrair características dos sinais, preparando os dados para o treinamento das redes *Autoencoder* e Rede Neural Convolucional.

3.1 Gerando sinais

Parte dos arquivos de áudio utilizados neste trabalho foi disponibilizada pelo grupo de pesquisa *Áudio & Multimedia* do Departamento de Ciência da Computação da Technische Universität Dortmund (TU Dortmund), na Alemanha, acessível em: <https://www-ai.cs.tu-dortmund.de/audio.html>. Além disso, foram incluídos mais arquivos de áudio coletados com a USRP. Esses dados foram obtidos sintonizando uma estação de rádio local em Natal-RN, operando na frequência de 98,9 MHz (selecionada devido à melhor SNR observada no local de coleta). Cada arquivo de áudio tem duração de 4 segundos, amostrados a 44100 Hz, e abrange músicas, programas de conversação e toda a programação local. Esses dados foram coletados ao longo de um período de 40 horas, em intervalos aleatórios, para garantir diversidade de informações.

Durante o processo de geração de sinais, duas possibilidades foram estudadas: sinais

em banda passante (modulados em frequência) e sinais em banda base (sinais de áudio puros). Ambas as características foram investigadas em cada etapa, com o objetivo de determinar suas contribuições.

Para o processo de simulação, foi predeterminado intervalos de valores para os parâmetros SNR e SIR. Esses parâmetros são importantes para a modelagem dos cenários de interferência e ruído que podem ser encontrados em ambientes de comunicação via rádio. A escolha dos intervalos de SNR e SIR foi fundamentada em estudos anteriores na literatura, que indicam os valores típicos encontrados em diferentes condições operacionais de sistemas de comunicação (De Piante et al., 2021). Esses intervalos foram selecionados com o objetivo de testar os métodos propostos em diferentes condições. Além disso, eles são importantes para que as redes neurais fossem treinadas em um conjunto de dados com diversidade de condições que garantisse a generalização dos modelos para as diversas condições encontradas na prática.

3.1.1 Métodos lineares de identificação

Nesta etapa, os arquivos de áudio são divididos em dois grupos (Banco 1 e Banco 2): um para gerar novos sinais de áudio com a presença do sinal interferente e outro para gerar sinais sem interferência. A Figura 3.1 ilustra o processo.

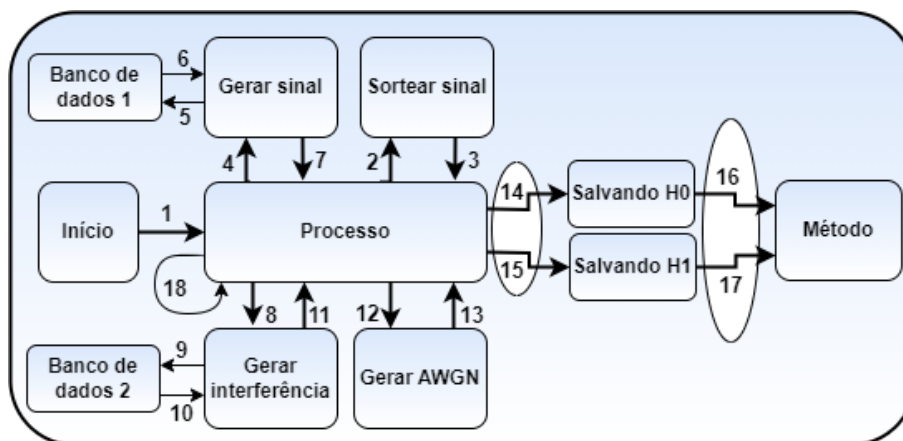


Figura 3.1: Simulador de sensoriamento espectral.

O fluxo de ações é enumerado de 1 a 18, descrevendo a sequência de atividades. Os dois principais blocos dessa figura são chamados de Início e Processo.

No bloco de **Início**, os parâmetros de entrada incluem a faixa e o passo de incremento de SNR e SIR, a seleção entre diferentes métodos de detecção (com 16 opções implementadas), a escolha entre detecção em banda base ou passante, o número de repetições do método Monte Carlo, além da frequência de transmissão e o desvio de frequência (quando sinais em banda passante são analisados).

No bloco denominado **Processo**, uma série de operações é realizada para cada conjunto de valores selecionados. Isso engloba a geração de sinais, modulação, ajuste de potência, geração de interferência e do ruído e a formulação das hipóteses H_0 e H_1 , definidas como na Equação 3.1:

$$H_0 : y(t) = x(t) + w(t), \quad (3.1)$$

$$H_1 : y(t) = x(t) + w(t) + i(t), \quad (3.2)$$

O sinal $y(t)$ é o resultado do processamento, em que a hipótese H_0 consiste no sinal legítimo $x(t)$ somando ao ruído AWGN $w(t)$, mantendo uma SNR controlada. Por outro lado, a hipótese H_1 inclui o sinal legítimo $x(t)$, o ruído $w(t)$, e a interferência $i(t)$, com relações de potência SNR (sinal e ruído) e SIR (sinal e interferência) controladas.

Após gerar um grande volume de dados, resultando em vários sinais para as hipóteses H_0 e H_1 , aplicam-se os métodos de detecção lineares e calculam-se suas estatísticas T . De posse das estatísticas, é possível construir duas Funções de Densidade de Probabilidade (PDF)¹, uma para H_0 e outra para H_1 . Quanto maior a distância entre as PDFs, melhor o

¹De fato, o que foi chamada de PDF aqui é a distribuição empírica de probabilidade. Ela foi construída com as amostras do experimento, respondendo somente a elas, não sendo possível determinar formalmente a PDF da população. Contudo, devido ao elevado número de amostras de sinal (e correspondentes valores de T), a distribuição empírica de probabilidade pode explicar como os dados de uma variável aleatória se adequam a uma equação de distribuição de probabilidade. Esse gráficos são utilizados nesta tese como forma de ilustrar a dificuldade de classificar as duas hipóteses da Equação 3.1.

desempenho do método escolhido, como ilustrado na Figura 3.2.

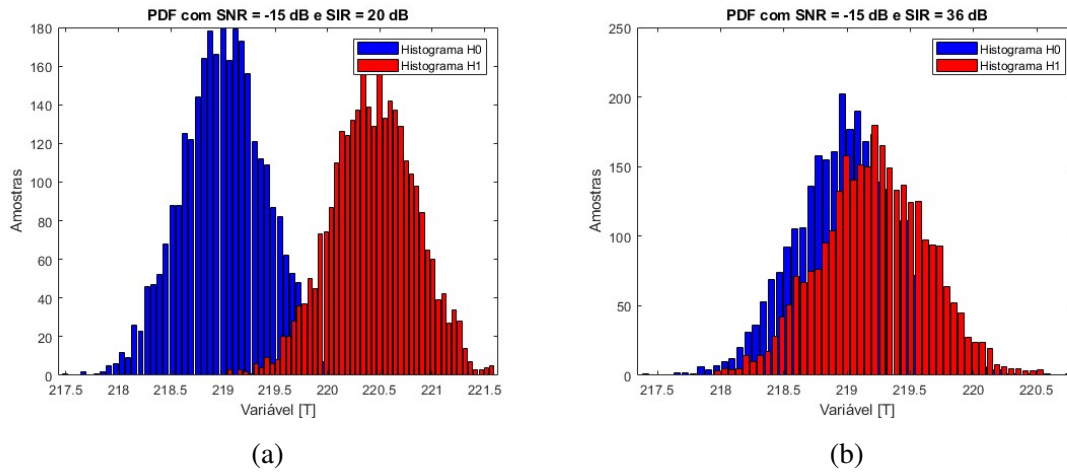


Figura 3.2: Distância das PDF normalizada. (a) Menor SIR. (b) Maior SIR.

A detecção de interferência é mais fácil quando as estatísticas dos sinais (PDF dos valores de T) apresentam menor sobreposição, permitindo que uma simples comparação entre o valor de T e um limiar predefinido² seja uma boa estratégia de detecção. No entanto, em situações em que o método aplicado gera PDFs sobrepostas (como na Fig.3.2b), torna-se mais difícil rejeitar ou não rejeitar uma das hipóteses e detectar corretamente as situações com interferência.

3.1.2 Preparação de dados para *Autoencoder* e CNN

A Figura 3.3 esquematiza o processo de geração de áudio que é pré-processado para o subsequente treinamento das redes *Autoencoder* e CNN. O fluxo de operações está numerado de 1 a 16 para representar as diferentes etapas do processo.

²Por exemplo, o limiar de detecção pode ser predefinido como o valor entre os centros das PDFs de H_0 e H_1 .

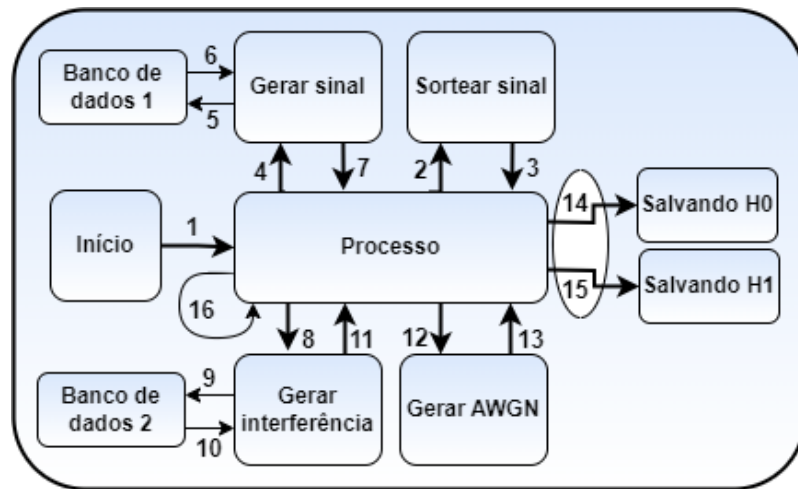


Figura 3.3: Gerador de sinais para treinamento das redes *Autoencoder* e CNN.

O bloco **Início** define parâmetros como as faixas de SNR e SIR, sinal em banda base ou passante, a frequência de transmissão, o desvio de frequência e o número de repetições de Monte Carlo. No bloco **Processo**, as operações envolvem a seleção aleatória de um sinal do banco de dados para se tornar o sinal legítimo, a escolha aleatória do sinal de interferência, a introdução do sinal de ruído, o ajuste de potência (para SNR e SIR desejadas), a modulação dos sinais (quando necessário) e a formação de dois conjuntos de sinais: um para a hipótese H_0 (sinal e ruído) e outro para H_1 (sinal, ruído e interferência).

Antes de iniciar o processo de extração de características dos sinais gerados para treinar as redes, conforme mostrado na Figura 3.4.

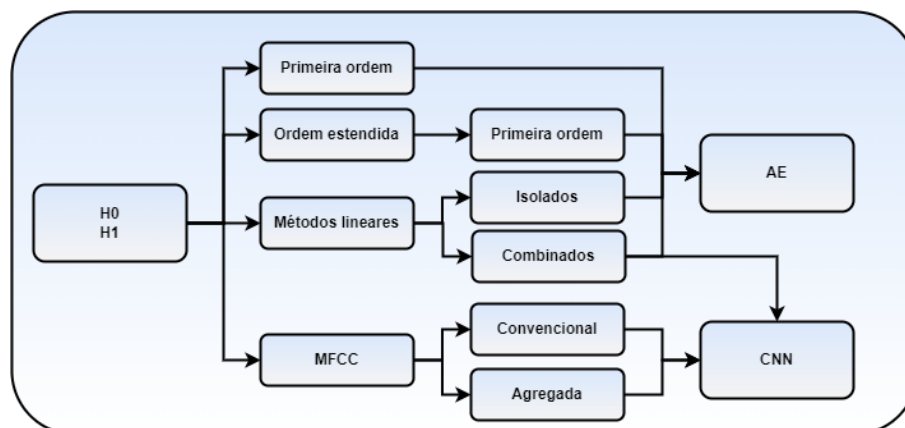


Figura 3.4: Esquema de pré-processamento para treinar as redes *Autoencoder* e CNN.

Em cada um dos blocos (Primeira ordem, Ordem estendida, Métodos lineares e MFCC), ocorre uma etapa em que cada arquivo de áudio que foi gerado passa por uma janela de Hamming, combinada com a pré-ênfase estabelecida em 0,97, realçando as altas frequências do sinal. Essa abordagem divide o sinal em quadros de 25 ms, com um espaçamento de 10 milissegundos entre eles.

Após a aplicação do janelamento dos sinais, o bloco **Primeira ordem** calcula estatísticas básicas, como o maior valor, menor valor, média, variância e desvio padrão dos sinais das hipóteses.

No bloco **Ordem estendida**, são calculados coeficientes como MFCC, Croma, Método Mel, Centroide espectral, Largura de banda espectral e Declive espectral. Em seguida, são computados o valor máximo, mínimo, média, variância e desvio padrão desses métodos para treinar as redes.

No bloco **Métodos lineares**, características como Energia, p -Norm, BCED, máximo e mínimo autovalor, RLRT e entropia são calculadas depois da janela Hamming. Essas características são extraídas de forma isoladas e utilizadas para treinar a rede em duas situações: cada método isoladamente ou em combinação.

O bloco **MFCC** extrai os coeficientes Mel-Frequency Cepstral Coefficients dos sinais de áudio para o treinamento das redes CNN. Nesse caso, a rede é treinada com os 15 primeiros coeficientes do MFCC (método convencional) e de forma agregada (valor máximo, mínimo, média, variância e desvio padrão dos 15 primeiros coeficientes MFCC).

Com isso, a ideia é gerar uma variedade de dados utilizando os sinais gerados (com e sem interferência) e usá-la para o processo de identificação de interferência. Essa etapa do trabalho vai ser explorada nos Capítulos 4, 5, 6 e 7.

3.1.3 Preparação de dados para CNN com múltiplas interferências

Esta etapa é dedicada às situações de comunicação com a presença de múltiplos rádios interferentes, modelando os desafios enfrentados em tais ambientes.

Durante a geração dos sinais, fase que ocorre antes do pré-processamento, utiliza-se a função tangente hiperbólica para introduzir distorções que refletem a presença de múltiplas interferências (Qu et al., 2018). A escolha da *tanh* foi baseada em suas propriedades matemáticas que a tornam particularmente adequada para modelar interferências de maneira controlada. Esta função oferece uma transição suave e entre os níveis de interferência, o que reflete a variabilidade observada em cenários de comunicação reais (Alzubaidi, 2024). O ganho de distorção é ajustado dinamicamente para simular diferentes níveis de intensidade de interferência, que foram aplicadas em cada parte da janela *Hamming*. Esse ajuste dinâmico é realizado por meio da manipulação de um parâmetro que controla o nível de distorção introduzido nos sinais de interferência ou úteis, dependendo do valor do SIR. Quando o SIR é maior ou igual a zero, a distorção é aplicada aos sinais de interferência, enquanto que quando o SIR é menor que zero, a distorção é aplicado aos sinais úteis. Isso permite simular diferentes níveis de intensidade de interferência de forma dinâmica durante a geração dos sinais (Khan et al., 2013). As condições são definidas de acordo com o SIR observado:

- Quando o $SIR \geq 0$, indicando que a interferência é menos dominante em relação ao sinal útil, a função *tanh* é aplicada às interferências, introduzindo distorções que refletem múltiplas interferências menos significativas;
- Quando o $SIR < 0$, indicando que o sinal útil é menos intenso em comparação com a interferência, a função *tanh* é aplicada ao sinal útil, modelando os efeitos de múltiplas interferências mais intensas.

Com isso, é possível gerar uma variedade de sinais que podem estar sofrendo o efeito de múltiplas interferências e que seus dados podem ser utilizados para treinar a rede CNN. Esta etapa do trabalho é explorada nos Capítulos 8, 9 e 10.

3.1.4 Treinamento e validação

As redes *Autoencoder* e CNN foram treinadas com dados (características) extraídas dos sinais de áudio que são compostos por 40 horas de áudio, organizadas em arquivos *wav* com duração de 4 segundos, conforme já descrito anteriormente. Os dados para treinamento foram categorizados em dois grupos distintos:

- **Grupo 1:** Sinais com interferência e ruído. A SIR varia de -20 dB a 40 dB e a SNR de -20 dB a 40 dB;
- **Grupo 2:** Sinais sem interferência, mas com ruído. Para esse grupo, apenas a SNR foi modificada, variando de -20 dB a 40 dB.

Todos os resultados apresentados neste trabalho foram baseados em dados extraídos para testar a capacidade dos algoritmos propostos identificarem sinais com interferência. Para evitar problemas de *overfitting* (Jabbar and Khan, 2015), foram utilizados conjuntos de dados distintos para treinamento, validação (otimização dos hiperparâmetros) e teste (análise de desempenho). Nos testes de avaliação da rede *Autoencoder*, foi utilizado um total de 10 mil arquivos, igualmente divididos entre arquivos com interferência (5 mil) e sem interferência (5 mil), o que corresponde a aproximadamente 11,1 horas de áudio. Para a rede CNN, foram empregados 30 mil arquivos de teste, dos quais metade continha interferência e a outra metade não, resultando em 33,3 horas de áudio em cada um dos testes de avaliação.

3.2 Otimização dos hiperparâmetros

Neste trabalho, a técnica de otimização utilizada para otimização dos hiperparâmetros foi o *Grid Search*, que consiste em uma busca por diversas combinações possíveis de hiperparâmetros, os quais tem desempenho testado e comparado. Essa técnica

foi escolhida devido à sua capacidade de explorar hiperparâmetros, garantindo que as melhores combinações testadas sejam identificadas para cada modelo.

Os hiperparâmetros otimizados incluem a taxa de aprendizado (*learning rate*), o tamanho do lote (*batch size*), o número de filtros nas camadas convolucionais, as unidades nas camadas totalmente conectadas, a taxa de *dropout* e o número de épocas (*epochs*). A escolha desses hiperparâmetros foi guiada tanto pela literatura existente quanto por experimentos preliminares, que indicaram quais parâmetros teriam maior impacto no desempenho dos modelos.

O processo foi executado em paralelo para diferentes configurações de modelos, variando entre CNN e *Autoencoder*. Para cada configuração de hiperparâmetros, os resultados foram avaliados usando métricas de precisão, Recall, F1-Score, e acurácia.

Para a rede *Autoencoders* utilizada, varias combinações de dimensionalidades foram testadas com tamanho do *batch* e número de épocas, como mostra a Tabela 3.1.

Tabela 3.1: Configuração das Camadas do Encoder e Decoder com Hiperparâmetros Testados via Grid-Search.

Camada Encoder	Unidades	Regularização L1	Função de Ativação	Descrição
Camada 1	Variável (grid-search)	0,001	ReLU	Projeta a entrada original em um espaço de características de dimensão diferente
Camada 2	Variável (grid-search)	0,001	ReLU	Projeta a entrada em um novo espaço de características
Camada 3	Variável (grid-search)	0,001	ReLU	Projeta a entrada em outro espaço de características
Camada de Saída (Encoding)	Variável (grid-search)	-	-	Representa o espaço latente ou codificado
Decoder				
Camada 1	Variável (grid-search)	0,001	ReLU	Projeta o espaço latente em um espaço de características para reconstrução
Camada 2	Variável (grid-search)	0,001	ReLU	Projeta as características reconstruídas em um novo espaço
Camada 3	Variável (grid-search)	0,001	ReLU	Projeta as características em um espaço final
Camada de Saída (Decoding)	<i>decoding_dim</i>	-	-	antes da saída Projeta de volta para a dimensão original dos dados de entrada
Hiperparâmetros Testados		Grid - Search (Batch Size, Número de Épocas, Dimensionalidades)		

Os hiperparâmetros otimizados da CNN são mostrados na Tabela 3.2.

Tabela 3.2: Configuração da CNN com Hiperparâmetros Testados via Grid-Search

Camada	Número de Filtros/Neurônios	Tamanho do Filtro	Padding	Função de Ativação	Descrição
Camada Convolução 1	Variável	Variável	Same	ReLU	Inclui Normalização em Lote, Max Pooling (tamanho 2) e Dropout Variável
Camada Convolução 2	Variável	Variável	Same	ReLU	Inclui Normalização em Lote, Max Pooling (tamanho 2) e Dropout Variável
Camada Convolução 3	Variável	Variável	Same	ReLU	Inclui Normalização em Lote, Max Pooling (tamanho 2) e Dropout Variável
Camada de Achatamento		Transforma os dados em um vetor unidimensional			
Camada Totalmente Conectada 1	Variável	-	-	ReLU	Inclui Normalização em Lote e Dropout Variável
Camada Totalmente Conectada 2	Variável	-	-	ReLU	Inclui Normalização em Lote e Dropout Variável
Camada de Saída		Neurônio de Saída com Função de Ativação Sigmoide			
Hiperparâmetros Testados	Learning Rate (0.0001), Número de Filtros, Unidades nas Camadas Totalmente Conectadas, Taxa de Dropout, Otimizador Adam, Loss Function 'binary_crossentropy', Batch Size (32), Número de Épocas (10)				

3.3 Metodologia Experimental

Esta seção apresenta a metodologia experimental desenvolvida para validar os métodos propostos nesta tese, detalhando o planejamento, a execução e a análise dos experimentos realizados, com o objetivo de demonstrar a aplicabilidade das técnicas em condições controladas e práticas.

3.3.1 Simulação de interferência usando USRP

Para gerar sinais de interferência durante os testes reais apresentados no Capítulo 10, utiliza-se o software GNU Radio. A configuração do fluxo de trabalho foi projetada para modular um sinal de áudio em FM interferente, transmiti-lo utilizando um dispositivo USRP³, e monitorar o espectro de frequência da saída em tempo real. A Figura 3.5 apresenta o diagrama de blocos configurado no GNU Radio, detalhado a seguir.

³Para mais informações sobre o dispositivo USRP N210 utilizado, consulte o https://www.ettus.com/wp-content/uploads/2019/01/07495_Ettus_N200-210_DS_Flyer_HR_1.pdf.

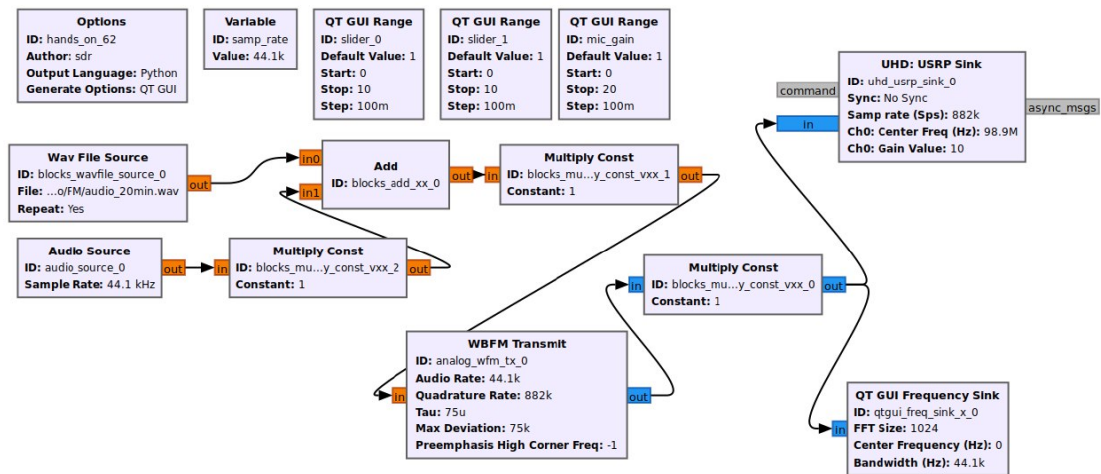


Figura 3.5: Diagrama de blocos no GNU Radio para transmissão de sinal FM com monitoramento em espectro.

3.3.2 Configurações Gerais do esquema GNU Radio

O bloco de *Opções* configura o projeto para gerar código em Python e usar a interface gráfica QT GUI. A taxa de amostragem foi definida como 44,1 kHz, uma escolha compatível com as fontes de áudio utilizadas. Os controles deslizantes (*sliders*) foram incluídos para ajustar parâmetros em tempo real:

- **slider_0** e **slider_1**: controlam o ganho em pontos específicos do fluxo.
- **mic_gain**: ajusta o ganho do microfone.

3.3.3 Fontes de Áudio

O diagrama utiliza uma fonte de áudio para gerar o sinal de entrada:

- **Wav File Source**: lê um arquivo de áudio `audio_20min.wav` e o reproduz continuamente. Esta fonte representa um sinal de áudio predefinido para o experimento.

3.3.4 Blocos de Processamento de Sinal

Os blocos de operações processam o sinal para combinar, ajustar e modular o áudio:

- **Multiply Const:** controla o ganho em diferentes pontos do fluxo:
 - **blocks_multiply_const_vxx_1:** ajusta o ganho do sinal combinado pelo valor de `slider_0`.
 - **blocks_multiply_const_vxx_0:** ajusta o ganho do sinal modulado em FM pelo valor de `slider_1`.

3.3.5 Modulação e Transmissão FM

Após o processamento inicial, o sinal combinado é modulado em frequência e transmitido:

- **WBFM Transmit:** modula o sinal em FM de banda larga com as seguintes configurações: taxa de áudio de 44,1 kHz, taxa de quadratura de 882 kHz, desvio máximo de 75 kHz e pré-ênfase de -1, simulando uma transmissão de rádio FM comercial.
- **UHD: USRP Sink:** envia o sinal modulado para o dispositivo USRP, configurado para transmitir na frequência de 98,9 MHz, com taxa de amostragem de 882 kHz.

3.3.6 Monitoramento em Espectro

Para monitorar o espectro de frequência do sinal transmitido, usa-se um espectrômetro de frequência:

- **QT GUI Frequency Sink:** exibe a visualização em frequência da saída. Configurado com tamanho da FFT de 1024, largura de banda de 44,1 kHz, e frequência central relativa de 0 Hz. Permite observar o espectro do sinal modulado em FM e quaisquer variações causadas pelos ajustes dos *sliders*.

Esta configuração permite modular um sinal de áudio em FM e monitorar visualmente o espectro da saída, com a flexibilidade de ajustar o ganho em vários pontos por meio dos controles deslizantes. Durante os experimentos, foram exploradas variações nos níveis de potência da USRP, que variam de -75 a -30 dBm. A configuração do sistema USRP pode ser observado na Figura 3.6. O objetivo foi permitir que a rede detectasse interferências em diferentes intensidades. Essa abordagem possibilitou a avaliação da capacidade dos métodos de detecção. Os resultados detalhados do estudo prático são apresentados no Capítulo 10.




Figura 3.6: Sistema de recepção do celular e computador.

3.3.7 Procedimento de medição

Para a recepção dos sinais em banda base, adotou-se um sistema composto pelo celular Galaxy A13 com processador *Exynos* 850, com até 2 GHz de capacidade de processamento e 4 GB de memória RAM. Uma antena filamentar foi conectada tanto ao celular quanto ao computador, desempenhando uma dupla função: como saída de áudio para o celular e entrada de áudio para o computador que processa os dados e testa a capacidade das soluções de detecção de interferência propostas. A Figura 3.7 mostra como o celular estava conectado ao computador.




Figura 3.7: Sistema de recepção do celular e computador.

O sistema operou em tempo real, em banda base, com o celular recebendo o sinal de áudio puro da rádio FM 98,9 em duas condições: sem interferência da USRP e com interferência da USRP, conforme ilustrado na Figura 3.8. O sinal recebido no celular e enviado ao computador foi gravado por 4 segundos, em seguida passado pelas etapas de pré-ênfase, de pré-processamento e aplicados as redes neurais já treinadas.

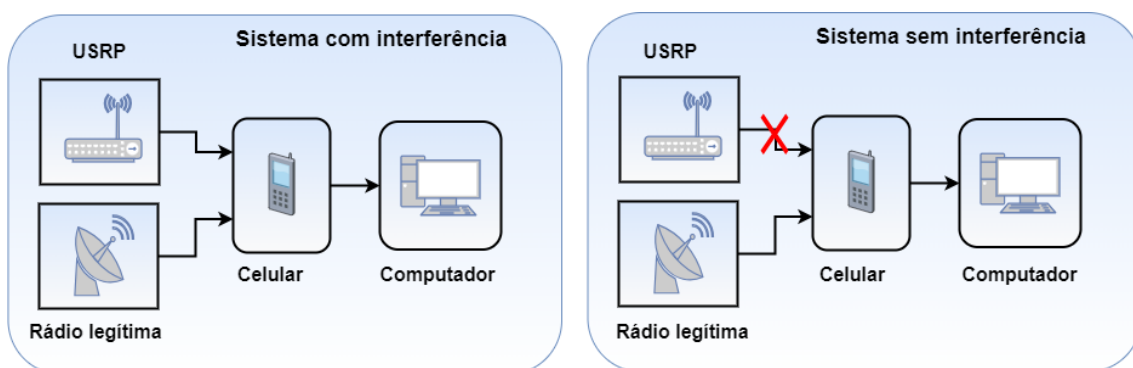


Figura 3.8: Esquema do gerador de sinais para treinamento.

A cada minuto, o sistema coleta 15 segmentos de áudio recebidos no celular, dos quais foram realizadas 15 análises. Foram gerados 15 resultados, um para cada segmento de áudio. Opta-se por determinar a presença ou ausência de interferência com base na maioria dos resultados, conforme a Figura 3.9.




Figura 3.9: Esquema de análise de interferência.

Para cada minuto, foram gerados resultados nomeados como **há interferência** ou **não há interferência**, com base nos 15 segmentos. Cada etapa de teste correspondeu a um período de 30 minutos. Dessa forma, foram gerados 30 resultados que foram expressos em termos de probabilidade. Assim, se uma rede que obteve 30 análises corretas alcançou 100% de acerto.

3.4 Cálculo das distâncias entre PDFs

A Figura 3.10 ilustra o funcionamento de um *autoencoder* e o processo de cálculo da PDF a partir da entrada original e a saída reconstruída. Nesse processo, os dados de entrada são processados pelo *encoder*, que reduz sua dimensionalidade, criando uma representação comprimida. Em seguida, essa representação é enviada para o *decoder*, que tenta reconstruir os dados originais. A diferença entre a entrada e a saída reconstruída é chamada de erro de reconstrução (*loss*), que é obtido por meio do erro quadrático médio (*Mean Squared Error* - MSE). O treinamento da rede *autoencoder* é realizado com sinais

sem interferências, ajustando os hiperparâmetros para obter a menor diferença possível entre a entrada e a saída.

A partir da distribuição das diferenças entre entrada e saída, é gerada uma PDF que descreve a dispersão dos erros de reconstrução. Isso possibilitou a comparação entre diferentes PDFs, gerando métricas que indicam a distância entre duas hipóteses (H_0 e H_1), o qual foi chamada de distância das PDFs normalizada.

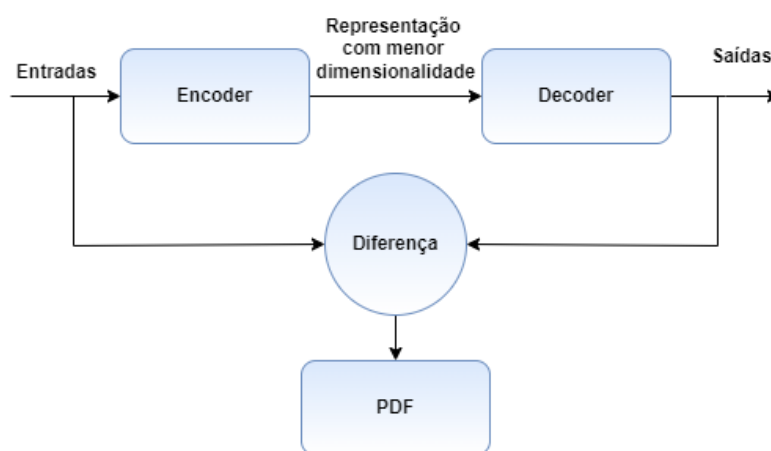


Figura 3.10: Fluxo de geração das PDF's.

A Figura 3.11 apresenta exemplos de PDFs calculadas para duas hipóteses, H_0 e H_1 . Quanto maior a distância entre as PDFs, mais fácil de diferenciar as hipóteses. No entanto, quando a distância é menor ou negativa, há uma sobreposição significativa, e um valor de zero indica completa sobreposição entre as PDFs.

O cenário de identificação de interferência acontece quando o valor de *loss* é alto, pois significa que as PDFs de entrada e saída são diferentes e o sinal de entrada possivelmente tem interferência, pois a rede *autoencoder* não foi treinada para minimizar o erro desse tipo de sinal. Por outro lado, quando o sinal de entrada não tem interferência, se espera um valor pequeno de *loss*, pois a rede *autoencoder* foi treinada para minimizar o erro desse tipo de sinal.

Ao utilizar várias amostras de sinais (com e sem interferência), é possível gerar uma PDF semelhante aos três exemplos ilustrados na Figura 3.11. A PDF de H_0 é construída

com sinais de entrada sem interferência, enquanto que PDF de H_1 é construída com sinais de entrada com interferência. Na primeira figura, é ilustrado o melhor caso, em que há uma clara separação entre as PDFs de H_0 e H_1 . Na figura do meio, observa-se uma situação em que os resultados indicam uma sobreposição, dificultando a distinção entre as duas hipóteses. Por fim, a direita, tem-se um cenário de total sobreposição, pois não existe diferenças entre sinais com interferência e sem interferência para a rede.




Figura 3.11: Configurações de PDF.

A distância entre as PDFs H_0 e H_1 pode ser calculada como a diferença entre o menor valor obtido da PDF H_1 e o maior valor da PDF H_0 , valores ilustrados com linhas verticais na Figura 3.11. Considerando o maior valor de H_0 como $P1$ (linha vertical azul) e o menor valor de H_1 como $P2$ (linha vertical laranja), é possível que o valor de $(P2 - P1)$ assuma valores positivos (não há sobreposição), valores negativos (há sobreposição) e valores nulos (sobreposição total).

3.5 Avaliação de Desempenho e Métricas de Decisão

Na etapa de comparar a solução proposta em relação outras soluções, foi utilizado a métrica de taxa de falso alarme (P_{FA}) e a taxa de detecções corretas (P_D), que são descritas no contexto de hipóteses e probabilidades de decisão entre presença e ausência de interferência. Matematicamente, essas taxas são definidas da seguinte forma:

1. Taxa de Falsos Alarmes (P_{FA}): é a probabilidade de rejeitar a hipótese nula H_0 (sinal legítimo) quando ela é verdadeira. Isso ocorre quando o sistema

detecta interferência erroneamente em uma situação em que não há interferência. Matematicamente, P_{FA} representa a área sob a curva da função de densidade de probabilidade da hipótese H_0 acima de um limiar crítico γ usado para decisão (Prati et al., 2008):

$$P_{FA} = P(T > \gamma | H_0)$$

2. Taxa de Detecção Correta (P_D): é a probabilidade de rejeitar corretamente a hipótese nula H_0 quando a hipótese alternativa H_1 (presença de interferência) é verdadeira. Em outras palavras, P_D representa a eficácia do sistema em detectar a presença de interferência. Matematicamente, P_D é dado pela probabilidade de que a estatística de teste T ultrapasse o limiar γ na presença de interferência (Prati et al., 2008):

$$P_D = P(T > \gamma | H_1)$$

Essas taxas são comumente representadas em gráficos ROC, em que a relação entre P_{FA} e P_D pode ser visualizada para diferentes valores de γ , facilitando a comparação de desempenho entre diferentes métodos de detecção.

No próximo capítulo são apresentados os resultados obtidos pela rede Autoencoder aplicada em sinais em banda passante. Esses resultados incluem a avaliação do desempenho da rede treinada com estatísticas de primeira ordem, estatísticas estendidas e métodos lineares (solução proposta). Além disso, é realizada uma comparação detalhada entre a solução proposta e outros métodos de identificação de interferência, destacando os pontos fortes e as limitações de cada abordagem.

Capítulo 4

Resultados do *Autoencoder* - Banda passante

4.1 *Autoencoder* - Treinamento não supervisionado

Neste capítulo, são discutidos os resultados do Autoencoder na detecção de interferência em sinais de rádio, utilizando dados estatísticos de sinais de áudio modulados em banda passante. O treinamento foi realizado apenas com sinais sintéticos sem interferência. As três estratégias testadas são descritas nas Seções 4.1.1 (primeira ordem), 4.1.2 (ordem estendida) e 4.1.3 (métodos lineares). Todos os resultados foram baseados em sinais do banco de testes sintéticos. Os hiperparâmetros foram previamente selecionados com base nos dados de validação.

Na Seção 4.1.1, a solução de primeira ordem utiliza estatísticas de máximo, mínimo, média, variância e desvio padrão dos sinais de áudio para treinar a rede. Na Seção 4.1.2, o treinamento usa estatísticas estendidas incorporando valores mínimos, máximos, média, variância e desvio padrão dos métodos MFCC, Croma, Método Mel, Centróide espectral, Largura de banda espectral e Declive espectral. Na Seção 4.1.3, os valores de T dos métodos lineares são usados para treinar a rede *autoencoder*, adotando cada método isoladamente ou combinado.

4.1.1 Treinamento utilizando estatísticas de primeira ordem

A Figuras 4.1 mostram as distâncias das PDFs do conjunto de características dos sinais de teste sem interferência (H_0) com a PDF do conjunto de testes com interferência (H_1). A Figuras 4.1a refere-se a rede testada com valores máximo e mínimo dos sinais, a Figura 4.1b refere-se a rede testada com valores máximo, mínimo e média. Estes resultados ilustram a fase de testes da rede com diferentes hiperparâmetros, em que *Batch* é o tamanho do lote, *Dim* é o tamanho da dimensão de cada camada, *LR* é a taxa de aprendizado e o *número Epochs* representa o número de épocas. Os resultados revelam valores negativos de distância entre as PDFs, caracterizando o Exemplo 2 da Figura 3.11, em que existe uma dificuldade de distinção entre as duas hipóteses.

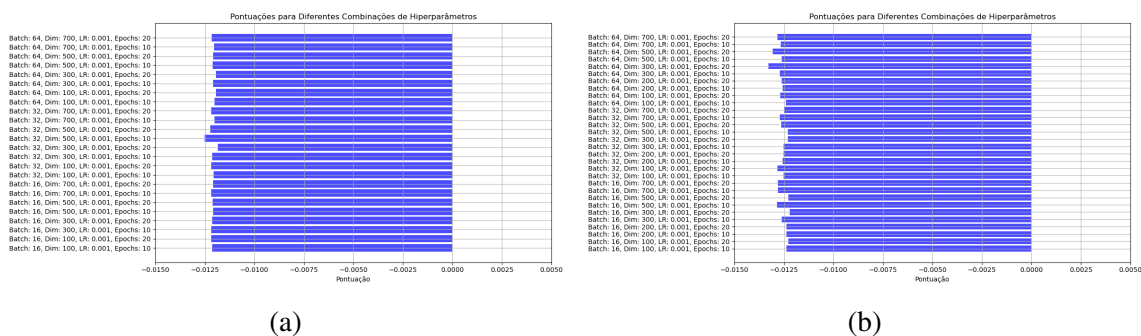


Figura 4.1: Distância das PDF normalizada. (a) Utilizando valor máximo e mínimo. (b) Utilizando valor máximo, mínimo e média.

A Figura 4.2a mostra os resultados quando a rede *autoencoder* é treinada com uma configuração que inclui os valores máximos, mínimos, média e variância dos sinais modulados. É possível observar que, mesmo como as novas estatísticas, os resultados continuam a apresentar dificuldades na diferenciação entre os sinais com e sem interferência, devido aos valores negativos de distância entre as PDFs. Na Figura 4.2b, a rede foi treinada com a incorporação do desvio padrão, mas sem mudança no poder de identificação de interferência.




Figura 4.2: Distância das PDF normalizada. (a) Utilizando valor máximo, mínimo, média e variância. (b) Utilizando valor máximo, mínimo, média, variância e desvio padrão.

Esses resultados sugerem que o uso de estatísticas de primeira ordem são insuficiente para o treinamento da rede *autoencoder* e que a complexidade do problema demanda abordagens diferentes. Essa foi primeira abordagem testada nesta tese e reconhece-se a necessidade de explorar técnicas mais sofisticadas e incorporar informações de ordens superiores para aprimorar a rede *autoencoder*.

4.1.2 Treinamento utilizando estatísticas estendidas

A Figura 4.3 expande a análise ao testar a rede *autoencoder* com uma configuração de dados diferente. Para isso, foram calculados os métodos MFCC, Croma, Método Mel, Centroide espectral, Largura de banda espectral e Declive espectral dos sinais modulados. Em seguida foram extraídos valores máximos, mínimos, média, variância e desvio padrão dos métodos para treinar a rede.

Na Figura 4.3a, os resultados são apresentados para a configuração em que foram utilizados os valores de máximo e mínimo, provenientes da extensão estatística mencionada anteriormente. Mesmo após a exploração de diferentes combinações de hiperparâmetros, a rede demonstra persistir na dificuldade de distinguir os sinais com e sem interferência, conforme indicado pelos valores negativos de distância das PDFs. Na Figura 4.3b, os resultados para a situação em que foram utilizados os valores de máximo, mínimo e média são apresentados. Novamente, observa-se que, independentemente das

variações nos hiperparâmetros, a distância entre as PDFs dos sinais permanece negativa, evidenciando a sobreposição dessas distribuições e a limitação da rede em realizar uma classificação.




Figura 4.3: Distância das PDF normalizada. **(a)** Utilizando valor máximo e mínimo. **(b)** Utilizando valor máximo, mínimo e média.

Na Figura 4.4a, os resultados para a configuração que utiliza os valores de máximo, mínimo, média e variância são apresentados. Mesmo com a incorporação de mais informações, a rede ainda enfrenta desafios na identificação de padrões distintos entre dados com e sem interferência. O mesmo acontece ao adotar os valores de máximo, mínimo, média, variância e desvio padrão, como mostrado na Figura 4.4b. Mais uma vez, verifica-se que a rede, mesmo com a variação de hiperparâmetros, não demonstra capacidade de gerar valores distância positivos.




Figura 4.4: Distância das PDF normalizada. **(a)** Utilizando valor máximo, mínimo, média e variância. **(b)** Utilizando valor máximo, mínimo, média, variância e desvio padrão.

Esses resultados destacam a complexidade de classificar esses tipos de sinais e sugere

a necessidade de considerar novas abordagens para a detecção de interferências em sinais de áudio.

4.1.3 Treinamento utilizando estatísticas dos métodos lineares - valores T

Nesta etapa, a ênfase foi direcionada para a extração de características dos sinais pelo uso dos métodos de sensoriamento espectral de rádio cognitivo modificados, especialmente os métodos apresentados na Seção 2.3.

4.1.3.1 Solução individualizada

A Figura 4.5a exibe os resultados para a configuração em que a rede foi testada com os valores do detector de energia dos sinais de áudio. Os resultados indicam que a rede não foi capaz de gerar diferença entre os dados, evidenciando sua incapacidade de discriminar os dados com e sem interferência quando baseada apenas na energia. Neste caso, há uma sobreposição total dos dados, por isso a figura não apresenta resultados (as distâncias são todas zeros).

Por sua vez, a Figura 4.5b mostra os resultados para a configuração em que a rede foi treinada com dados do método BCED. Os resultados novamente revelam valores negativos, indicando sobreposição das PDFs e a incapacidade da rede em lidar com esse tipo de dados.

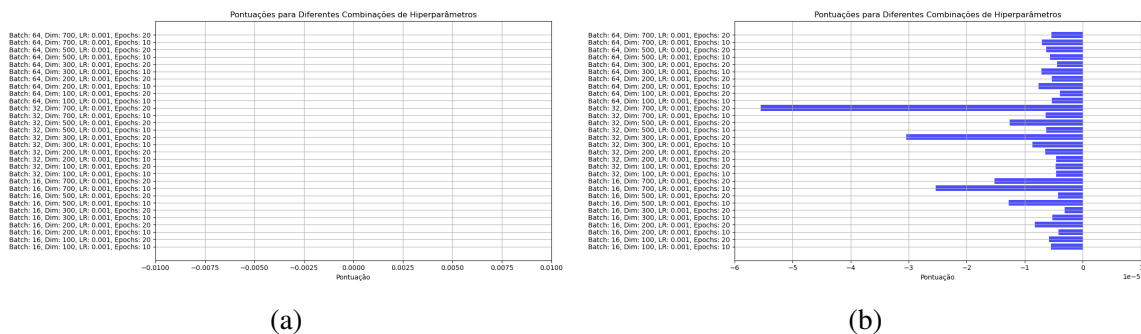


Figura 4.5: Distância das PDF normalizada. (a) Energia. (b) BCED.

A Figura 4.6a representa o resultado do treinamento com o método p -Norm. Nesse caso, os resultados indicam que a rede, ao ser treinada com essas características, não foi capaz de gerar resultados que distingua as PDF dos dados. Da mesma forma, a Figura 4.6b representa o resultado do treinamento com o método de maior e o menor autovalor da matriz de covariância formada pelas amostras do sinal. Da mesma forma, a rede apresenta resultados insatisfatório.

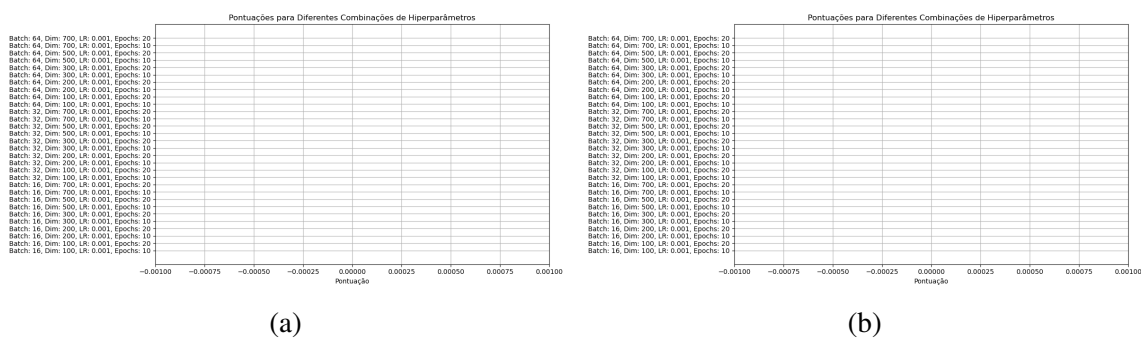


Figura 4.6: Distância das PDF normalizada. (a) p -Norm. (b) Máximo e mínimo autovalor.

Esses resultados destacam a complexidade em adotar um método de detectar e distinguir sinais de áudio com interferência, indicando a necessidade de explorar outras abordagens.

4.1.3.2 Solução combinada

Nesta etapa, as características extraída dos sinais foram combinadas para testar a rede. Na Figura 4.7a, tem-se o detector de energia isolado, o qual já foi analisado anteriormente. A Figura 4.7b mostra os resultados para a combinação dos métodos de energia e BCED. A distância das PDFs se aproximou do valor zero, apesar de ainda serem negativos. Essa combinação de métodos parece proporcionar uma melhoria em relação aos métodos isolados, mas ainda não é suficiente para a rede distinguir adequadamente os sinais de áudio com e sem interferência.

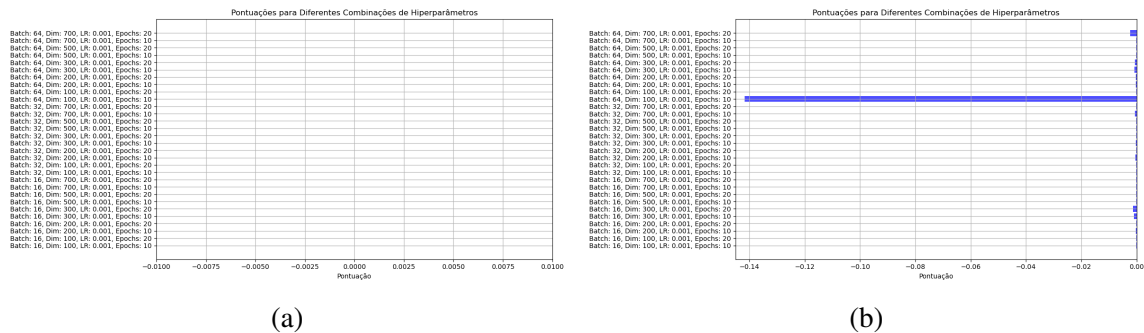


Figura 4.7: Distância das PDF normalizada. (a) Apenas energia. (b) Energia e BCED.

Outras combinações de métodos são mostradas na Figura 4.8. A Figura 4.8a mostra os resultados das combinações do detector de Energia, BCED e p -Norm. Valores de distância positivos sugerem que essa combinação de métodos estatísticos de sensoriamento espectral permitiu à rede distinguir os sinais de áudio quando há ou não interferência. Diferentes hiperparâmetros foram testados, e a rede mostrou consistência em seus resultados com variações de hiperparâmetros. A Figura 4.8b apresenta os resultados quando a rede *autoencoder* é treinada com os valores das combinações do detector de Energia, BCED, p -Norm, máximo e mínimo autovalor da matriz de covariância dos sinais de áudio. Essa combinação apresentou resultados similares de distância entre as PDFs.




Figura 4.8: Distância das PDF normalizada. (a) Energia, BCED e p -Norm. (b) Energia, BCED, p -Norm e MMA.

Esses resultados abrem a possibilidade de aprofundar os testes e comparar os resultados da rede neural com métodos lineares, conforme é discutido posteriormente. Isso possibilitará uma avaliação mais abrangente da capacidade de detectar sinais da

solução proposta em comparação com métodos convencionais de detecção de sinais.

4.2 Comparando a solução proposta com métodos lineares

Nesta etapa, são comparados os testes de detecção de sinais usando a rede *Autoencoder* treinada com combinações dos métodos Energia, BCED, p -Norm e MMA. A Figura 4.9 mostra a taxa de detecção correta (P_D) em função da SIR, para valores fixos de taxa de falsos alarmes (P_{FA}) e SNR.

A primeira análise, mostrada na Figura 4.9a, foi realizada considerando uma taxa de falsos alarmes de 5% e uma SNR fixa de -15 dB. À medida que o valor da SIR diminui, indicando um aumento na intensidade da potência do sinal de interferência, é notório o aumento da facilidade de se perceber essa interferência. Logo, observa-se um aumento na taxa de detecções corretas (P_D). Comparando os métodos lineares, o método de detecção pela Energia apresentou o desempenho mais fraco, seguido pelos métodos MMA, EIG, BCED, RLRT, p -Norm, Solução proposta e EC (solução ótima e de alta complexidade, adotada como referência de melhor caso).

Ao comparar o método proposto com o método p -Norm, que foi o segundo melhor desempenho (desconsiderando a solução ótima), observou-se que, em uma SIR de 28 dB, o método proposto superou em 10% a taxa de detecção do p -Norm. Isso ressalta a capacidade do método proposto em certas condições de interferência.

Na Figura 4.9b, foram comparados os mesmos métodos, mas a figura foi gerada considerando uma taxa de falsos alarmes de 10%. Os resultados revelaram padrões semelhantes, destacando o desempenho marcante do método proposto. O método proposto alcançou uma taxa de 100% de detecções corretas quando SIR igual a 28 dB, enquanto o segundo melhor método p -Norm atingiu a taxa de detecção correta de 94%. O método ótimo atinge 100% de detecção em 30 dB.




Figura 4.9: Taxa de detecção correta para SNR de -15 dB. (a) quando P_{FA} em 5%. (b) quando P_{FA} em 10%.

A Figura 4.10 exibe as Curvas de Características Operacionais do Receptor (ROC), que confronta a taxa de detecção correta P_D e a taxa de falso alarme P_{FA} , para SNR e SIR fixos.

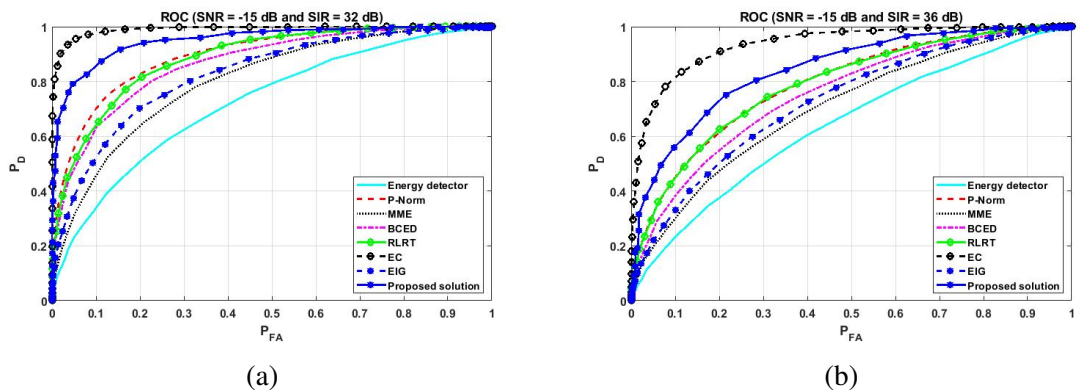


Figura 4.10: ROC para diferentes SIR. (a) SIR de 32 dB. (b) SIR de 36 dB.

A 4.10a apresenta a ROC para uma SNR de -15 dB e uma SIR de 32 dB. Indicando um ambiente com ruído elevado e pouca interferência, o que torna a detecção mais desafiadora. Pode-se observar que o método proposto apresenta uma ROC melhor que os demais métodos. Por exemplo, para uma taxa de falsos alarmes de 10%, a solução proposta apresenta uma taxa de detecção 14% superior em comparação com o método p -Norm. A Figura 4.10b, apresenta um cenário com SNR de -15 dB e SIR de 36 dB, representando condições mais desafiadoras devido a baixa potência do sinal

interferente. Nessas condições, todos os métodos experimentaram uma significativa redução de desempenho, mantendo, no entanto, a ordem de capacidade observado anteriormente.

Os resultados anteriores consideraram uma variação de SIR para uma dada SNR fixa. A partir de agora, exibe-se a comparação entre os métodos de detecção e a solução proposta em função da SNR. A Figura 4.11 apresenta a P_D versus SNR. Observa-se que, à medida que a SNR aumenta, a potência do ruído diminui, facilitando a detecção do sinal interferente. Embora a Figura 4.11a mostre que para uma baixa SNR (ruído elevado) todos os métodos apresentem desempenho insuficientes, a medida que a SNR melhora (ruído diminui), o sistema de detecção proposto supera os demais métodos. Resultado similar é observado na Figura 4.11b, que apresenta os resultados para uma taxa de falsos positivos de 10%.

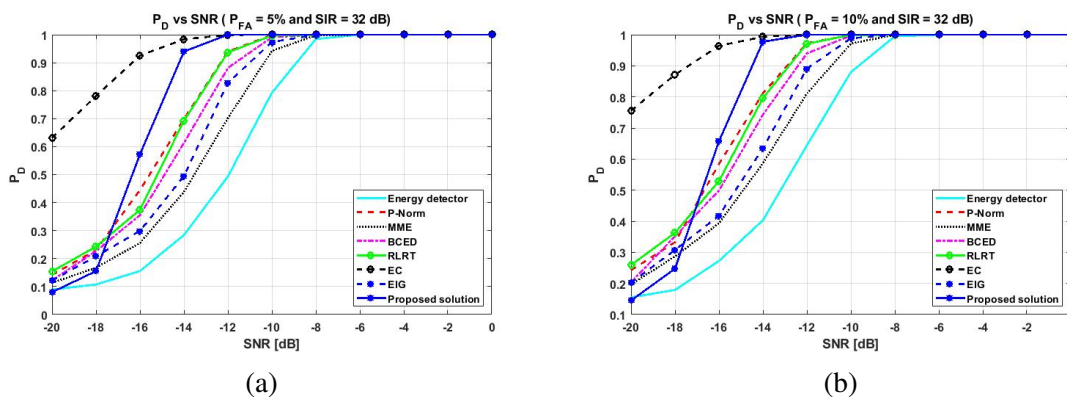


Figura 4.11: Taxa de detecção correta para SIR de 32 dB. (a) quando P_{FA} em 5%. (b) quando P_{FA} em 10%.

As Figuras 4.12a e 4.12b exibem as ROC para diferentes valores de SNR. Na Figura 4.12a, a ROC foi gerada considerando uma SNR de -16 dB e uma SIR de 32 dB, caracterizando um ambiente desafiador com ruído significativo e baixa interferência. Em contextos desafiadores, em que o ruído é elevado e a interferência é baixa, observa-se que o método proposto se distancia do método ótimo, mas supera os métodos na detecção clássicos.

Na Figura 4.12b, a ROC é apresentada considerando uma SNR de -14 dB e uma SIR de 32 dB. Nesse cenário, o ruído foi um menos intenso em comparação com a Figura 4.12a, resultando em uma melhoria na taxa de detecção correta para todos os métodos testados, com o método proposto se aproximando significativamente da solução ótima.




Figura 4.12: ROC para diferentes SNRs. (a) ROC para SNR de -16 dB. (b) ROC para SNR de -14 dB.

Pelo resultados mostrados anteriormente, o método proposto mostra desempenho destacável mesmo em situações desafiadoras de SNR e SIR, em alguns casos se aproximando significativamente da solução ótima.

4.3 Testes de robustez

Na Figura 4.13, é apresentada a matriz de confusão resultante do teste da solução proposta. A rede *autoencoder* foi treinada com uma variação de SIR e SNR de -20 dB a 40 dB, expandindo os testes apresentados até o momento.

Foi realizado testes com 10 mil sinais de áudio, compreendendo 5 mil com interferência e 5 mil sem interferência, sendo que todos possuem ruído. A matriz de confusão (Figura 4.13) revelou que dos 5 mil sinais sem interferência, 4.998 foram identificados corretamente. No caso dos 5 mil sinais com interferência, a rede alcançou uma taxa de acerto de 5.000.

Destaca-se que os dados de teste contemplam variações de SIR e SNR de -10 dB a 20 dB, abrangendo uma faixa inferior em comparação com o conjunto de treinamento.

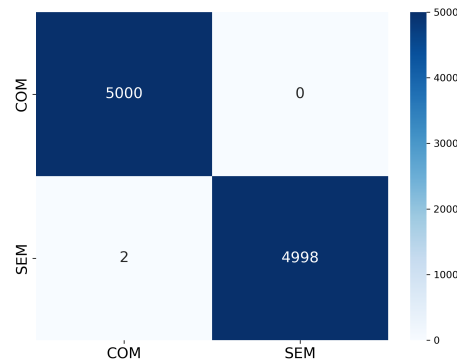


Figura 4.13: Matriz de confusão - Teste 1.

A Figura 4.14 representa um teste adicional para avaliar o desempenho do método proposto em condições ainda mais desafiadoras, com ampliação do efeito do ruído, variando de -20 dB a 20 dB. Nesse cenário mais ruidoso, em relação aos sinais com interferência, houve 11 falsos negativos, indicando que em 11 sinais foram erroneamente identificados.

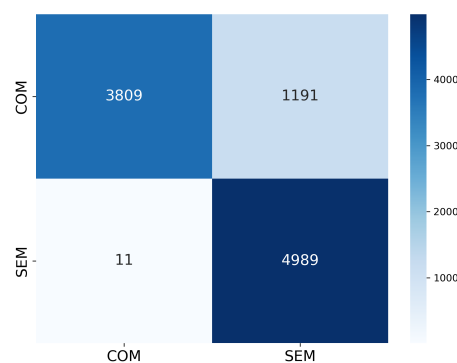


Figura 4.14: Matriz de confusão - Teste 2.

Além disso, a solução proposta registrou 1.191 falsos positivos, identificando incorretamente a ausência de interferência em 1.191 sinais.

Na Figura 4.15, é apresentado outro teste que visa avaliar o desempenho da rede *autoencoder* em condições específicas, ajustando tanto o efeito do ruído quanto a intensidade da interferência. Nesse teste, a SNR e a SIR variaram de -10 a 32 dB, proporcionando um cenário desafiador para a detecção da interferência. Esse cenário resultou em um aumento nos erros na detecção correta. A matriz de confusão revela que, nesse cenário, solução proposta registrou 139 falsos negativos para detecção do sinal sem interferência.




Figura 4.15: Matriz de confusão - Teste 3.

Os resultados evidenciam que os níveis de ruído e intensidade da interferência impactam significativamente a capacidade da solução proposta em detectar corretamente os sinais. O aumento do ruído contribuiu para uma maior taxa de falsos positivos, enquanto a redução da intensidade da interferência resultou em uma maior taxa de falsos negativos. Essa análise incentivou a investigação da extração de características diretamente do sinal de áudio, buscando melhorar as métricas de detecção da solução proposta.

No próximo capítulo, é apresentada a análise dos resultados obtidos com a rede Autoencoder aplicada a sinais em banda base. É dado foco nos testes realizados com estatísticas de primeira ordem, estatísticas estendidas e métodos lineares, incluindo a solução proposta. Além disso, é feita uma comparação detalhada entre os resultados

obtidos e outras abordagens de identificação de interferência, destacando os desafios específicos enfrentados ao lidar com sinais em banda base.

Capítulo 5

Resultados do *Autoencoder* - Banda base

5.1 *Autoencoder* - Treinamento não supervisionado

No capítulo anterior, foi explorada a aplicação de redes *Autoencoder* para a detecção de interferências em sinais em banda passante. Neste capítulo, a análise é direcionada para a utilização da rede com sinais banda base.

5.1.1 Treinamento utilizando estatísticas de primeira ordem

A Figura 5.1a apresenta os resultados dos testes para rede treinada com os valores mínimos e máximos dos sinais de áudio em banda base. Nota-se que os resultados da distância entre as PDFs dos dados com interferência e dos dados sem a presença do sinal interferente são negativos para todas as combinações de hiperparâmetros. Esse padrão indica a dificuldade da rede em distinguir entre os diferentes tipos de dados.

Adicionalmente, na Figura 5.1b, a análise foi estendida ao incorporar o valor médio dos sinais aos valores mínimos e máximos. Mesmo com a adição dessa nova informação, a rede *Autoencoder* permanece incapaz de distinguir os sinais, como evidenciado pelos resultados que continuam sendo menores que zero.

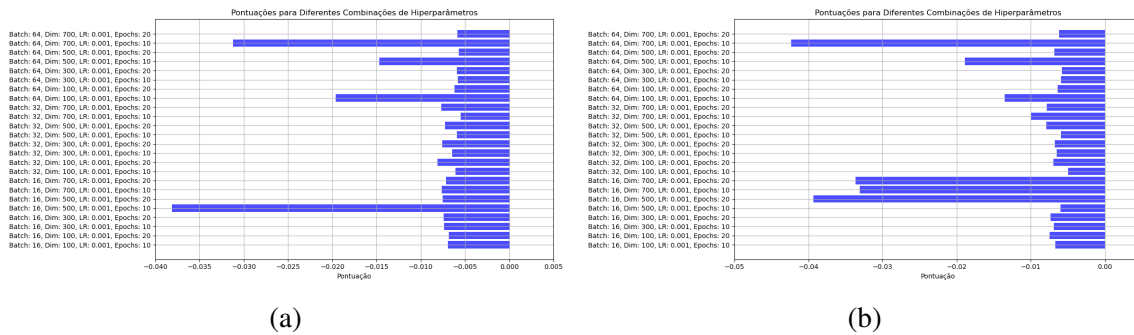


Figura 5.1: Distância das PDF normalizada. **(a)** Utilizando valor máximo e mínimo. **(b)** Utilizando valor máximo, mínimo e média.

Na Figura 5.2a, a rede foi alimentada com informações estatísticas que incluiu valores máximos, mínimos, média e variância dos sinais. Em seguida, na Figura 5.2b, a análise foi estendida ao adicionar os valores de desvio padrão. Apesar da tentativa de aumentar as informações fornecidas à rede *Autoencoder*, ambas as configurações resultaram em desempenho insatisfatório. Os resultados indicam que a rede ainda não tem potencial para diferenciar os sinais com e sem interferência.

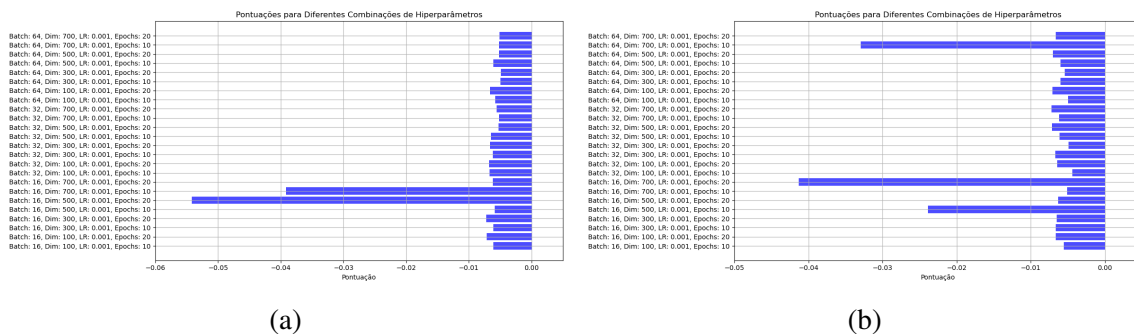


Figura 5.2: Distância das PDF normalizada. **(a)** Utilizando valor máximo, mínimo, média e variância. **(b)** Utilizando valor máximo, mínimo, média, variância e desvio padrão.

5.1.2 Treinamento utilizando estatísticas estendidas

Nesta fase, apresentam-se os resultados provenientes do treinamento da rede utilizando estatísticas que englobam valores mínimos, máximos, média, variância e desvio padrão dos métodos MFCC, Croma, Método Mel, Centroide espectral, Largura

de banda espectral e Declive espectral, calculados para os sinais de áudio em banda base.

A Figura 5.3a mostra os resultados quando a rede *Autoencoder* foi treinada com informações estatísticas que incluem valores máximos e mínimos desses métodos. No entanto, os resultados obtidos indicam que a rede não foi capaz de distinguir os dados. De maneira semelhante, na Figura 5.3b, a abordagem foi alterada para incluir os valores máximos, mínimos e média. No entanto, os resultados permaneceram desfavoráveis.




Figura 5.3: Distância das PDF normalizada. **(a)** Utilizando valor máximo e mínimo. **(b)** Utilizando valor máximo, mínimo e média.

Na Figura 5.4a, são apresentados os resultados do treinamento da rede utilizando valores máximos, mínimos, média e variância dos métodos. Novamente, os resultados indicam que não houve melhorias significativas. De forma semelhante, ao analisar a Figura 5.4b, observam-se os resultados do treinamento com valores máximos, mínimos, média, variância e desvio padrão dos métodos.




Figura 5.4: Distância das PDF normalizada. **(a)** Utilizando valor máximo, mínimo, média e variância. **(b)** Utilizando valor máximo, mínimo, média, variância e desvio padrão.

Esses resultados indicam que, mesmo com uma abordagem que considere mais estatísticas, a rede *autoencoder* enfrentou desafios na tarefa de detecção de interferência em sinais de áudio em banda base. A sobreposição das PDFs sugere a necessidade de investigar estratégias mais sofisticadas.

5.1.3 Treinamento utilizando estatísticas dos métodos lineares - valores T

Nesta abordagem, a ênfase foi direcionada para a extração de característica dos sinais pelo uso dos métodos de Energia, BCED, p -Norm e MMA.

A escolha de iniciar os experimentos com a solução combinada foi baseada nos resultados obtidos em experimentos anteriores, quando os métodos foram analisados isoladamente e verificou-se que a combinação dos métodos apresentou melhores respostas, devido à sua capacidade de abranger aspectos distintos dos sinais de áudio.

Na Figura 5.5a, todos os resultados foram igual a zero. Esse cenário sugere que a rede treinada com base nesse método não gerou PDF diferentes para H_0 e H_1 , tendo uma sobreposição total. Por outro lado, na Figura 5.5b, que demonstra a rede treinada com os métodos de energia e BCED, os resultados foram negativos.




Figura 5.5: Distância das PDF normalizada. (a) Apenas energia. (b) Energia e BCED.

A Figura 5.6 apresentam os resultados da rede *autoencoder* quando foi treinada com as estatísticas T do método da Energia, BCED e p -Norm. Observa-se que os resultados não

melhoraram efetivamente. O mesmo padrão é observado quando a rede foi treinada com a adição do método de máximo e mínimo autovalor, conforme mostrado na Figura 5.6b.




Figura 5.6: Distância das PDF normalizada. (a) Energia, BCED e pT -Norm. (b) Energia, BCED, p -Norm e MMA.

Os resultados apresentados neste capítulo evidenciam a complexidade da tarefa de detecção de interferência em sinais de áudio em banda base, justificando a necessidade de explorar abordagens mais avançadas. Diferente dos resultados utilizando a combinação dos métodos de sensoriamento espectral em banda passante, os resultados em banda base foram insatisfatórios. Os próximos capítulos exploraram uma nova estratégia, utilizando redes CNN, para a identificação de sinais tanto em banda passante quanto na banda base. Essa é uma tentativa de explorar métodos mais sofisticados de inteligência artificial, bem como de mudar a estratégia de uso da rede neural para detecção de interferência e usar novas estatísticas do sinal.

No próximo capítulo, é explorada a aplicação de redes CNN para análise de sinais em banda passante, utilizando uma abordagem supervisionada. São apresentados os resultados do treinamento da rede com diferentes conjuntos de estatísticas, incluindo estatísticas de primeira ordem, estatísticas estendidas e métodos lineares (solução proposta). Além disso, é realizada uma comparação da solução proposta em cenários com uma única interferência e múltiplas interferências, destacando a capacidade das redes CNN em identificar padrões de interferência em condições variadas.

Capítulo 6

Resultados da CNN - Banda passante

Neste capítulo, foi explorada a aplicação de CNNs na análise de sinais em banda passante, adotando uma abordagem de treinamento supervisionado para classificação de sinais com e sem interferência. A seção inicial aborda o treinamento com diferentes estatísticas, incluindo métodos de sensoriamento, estatística de primeira ordem, estatística de ordem estendida, MFCC, e uma nova combinação de métodos de sensoriamento baseado nos métodos da entropia e RLRT.

Conforme apresentado na Seção 2.5.3, a rede CNN foi treinada tanto com sinais com interferência quanto sem interferência. Quando a rede recebe dados de um sinal, se sua saída for inferior a 0,5, o sinal é classificado como sem interferência; se a saída estiver entre 0,5 e 1, o sinal é classificado como contendo interferência.

Os resultados iniciais são apresentados em tabelas, explorando diversas combinações de hiperparâmetros. Foram considerados como hiperparâmetros: a taxa de aprendizado (*Learning Rate*), o número de filtros nas camadas convolucionais *Conv1*, *Conv2* e *Conv3*, o número de unidades nas camadas densas *Dense1*, *Dense2* e a taxa de *dropout*.

Os resultados foram analisados em termos de Precisão, Recall, F1-score e Acurácia. Além disso, foi calculada uma métrica adicional, correspondente à média aritmética dos parâmetros avaliados. É importante destacar que os resultados das tabelas são referentes a dados de testes, que são diferentes dos dados de treinamento e validação da rede.

6.1 Treinamento com métodos lineares: valores T isoladamente

A Tabela 6.1 apresenta os resultados obtidos para diferentes combinações da rede CNN quando treinada com informação da energia dos sinais modulados. Estes resultados evidenciam uma limitação significativa na capacidade da rede em classificar os sinais com e sem interferências, conforme as métricas de resultados apresentadas. A incapacidade de atingir alta precisão sugere a necessidade de uma abordagem alternativa para enfrentar os desafios enfrentados pelo modelo. Observa-se que os valores de acurácia e precisão não ultrapassaram valores de 51% e a métrica de capacidade não supera os 67%, o que indica que a rede classifica todos os dados de teste tendo interferência.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253

Tabela 6.1: Testes para rede treinada com método da Energia.

A Tabela 6.2 apresenta resultados referentes ao treinamento isolado com o método BCED. Observa-se que as dificuldades persistiram, com a rede não alcançando uma precisão satisfatória em classificar os dados de teste.

6.1. TREINAMENTO COM MÉTODOS LINEARES: VALORES T ISOLADAMENTE73

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.2: Teste para rede treinada com método BCED.

A Tabela 6.3 apresenta os resultados para a rede CNN treinada com o método p -Norm. Novamente, os resultados indicam desafios significativos na detecção de interferência.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.3: Teste para rede treinada com método p -Norm.

A Tabela 6.4 apresenta os resultados da rede treinada com os valores máximo e mínimo do autovalor da matriz de covariância. Os dados destacam a necessidade de

melhoramento dos modelos, buscando novas estratégias para lidar com a classificação de sinais interferentes.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.4: Teste para rede treinada com método MMA.

6.2 Treinamento com métodos lineares: valores T combinados

Nesta etapa, os resultados foram obtidos com a combinação de métodos de sensoriamento espectral. Os resultados do treinamento da CNN com a combinação dos dados da energia e BCED dos sinais de áudio em banda passante são apresentados na Tabela 6.5. As métricas de avaliação não alcançaram níveis satisfatórios mesmo com a combinação dos dois métodos.

6.2. TREINAMENTO COM MÉTODOS LINEARES: VALORES T COMBINADOS75

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.5: Teste para rede treinada com métodos da Energia e BCED.

A inclusão do método p -Norm como uma característica adicional não resultou em melhoria significativa, conforme a Tabela 6.6. Isso sugere que, embora a métrica p -Norm tenha um impacto positivo para as redes *autoencoder* (Capítulo 4), outras considerações podem ser necessárias para aprimorar a capacidade da rede CNN.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.6: Teste para rede treinada com métodos da Energia, BCED e p -Norm.

A Tabela 6.7 apresenta os resultados quando a rede CNN foi treinada com o conjunto de dados dos métodos de extração de características Energia, BCED, p -Norm e MMA. Mais uma vez percebe-se a incapacidade da rede treinada em classificar sinais com e sem interferência.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	64	512	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	64	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	1024	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	512	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.3	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	512	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.4	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	256	1024	512	256	0.3	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.4	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.7: Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA.

6.3 Treinamento utilizando estatísticas de primeira ordem e estendidas

Mesmo com o baixo potencial dos métodos lineares, os resultados dos métodos de primeira ordem e de ordem estendida são apresentados nesta seção. A estratégia adotada foi treinar a CNN utilizando estatísticas de primeira ordem do sinal modulado, abrangendo valores máximo, mínimo, média, variância e desvio padrão, conforme os resultados apresentados na Tabela 6.8. Os resultados revelam uma melhoria no desempenho quando comparados aos métodos lineares. No entanto, mesmo com esse melhor resultado, as métricas de precisão e de acurácia são baixas para que a rede tenha validade prática. Uma das características observadas são os valores elevados de *Recall*,

6.4. TREINAMENTO COM COEFICIENTES CENTRAIS DE FREQUÊNCIA MEL77

indicando que o modelo está sendo eficaz em capturar a maioria dos exemplos positivos (detectar sinais com interferência), mas não sendo capaz de identificar os exemplos negativos (detectar sinais sem interferência).

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	128	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	512	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.8: Teste para rede treinada com estatística de Primeira Ordem.

A exploração de características estendidas envolveu o cálculo de valores de MFCC, Croma, Método Mel, Centroide espectral, Largura de banda espectral e Declive espectral a partir do sinal de áudio modulado. Posteriormente, foram extraídas estatísticas (máximo, mínimo, média, variância e desvio padrão) dessas características para o treinamento da rede. Os resultados apresentados na Tabela 6.9 indicam melhorias em algumas métricas, porém, ainda evidenciam desafios persistentes na realização da classificação.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5813	0.5525	0.9519	0.6992	0.6962
0.0001	128	256	1024	512	256	0.5	0.5770	0.5507	0.9381	0.6940	0.6899
0.0001	128	512	512	512	256	0.5	0.5633	0.5435	0.9114	0.6809	0.6748
0.0001	128	512	1024	512	256	0.5	0.5654	0.5446	0.9155	0.6829	0.6771
0.0001	256	256	512	512	256	0.5	0.5659	0.5449	0.9165	0.6834	0.6777
0.0001	256	256	1024	512	256	0.5	0.5628	0.5456	0.8676	0.6699	0.6614
0.0001	256	512	512	512	256	0.5	0.5630	0.5469	0.8477	0.6649	0.6556
0.0001	256	512	1024	512	256	0.5	0.5595	0.5452	0.8355	0.6598	0.6500

Tabela 6.9: Teste para rede treinada com estatística estendida.

6.4 Treinamento com Coeficientes Centrais de Frequência Mel

Dois tipos de resultados usando MFCC são apresentados nesta seção: (i) utilizando diretamente os coeficientes MFCC para treinar a rede CNN (resultados na Tabela 6.10); e (ii) utilizando os valores de máximo, mínimo, média, variância e desvio padrão dos coeficientes MFCC (resultados na Tabela 6.11).

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5659	0.5572	0.7359	0.6342	0.6233
0.0001	128	256	1024	512	256	0.5	0.5681	0.5558	0.7741	0.6470	0.6363
0.0001	128	512	512	512	256	0.5	0.5669	0.5534	0.7930	0.6519	0.6413
0.0001	128	512	1024	512	256	0.5	0.5469	0.5829	0.4003	0.4746	0.5012
0.0001	256	256	512	512	256	0.5	0.5604	0.5663	0.5989	0.5822	0.5770
0.0001	256	256	1024	512	256	0.5	0.5516	0.5751	0.4711	0.5179	0.5289
0.0001	256	512	512	512	256	0.5	0.5660	0.5496	0.8383	0.6639	0.6545
0.0001	256	512	1024	512	256	0.5	0.5460	0.5790	0.4107	0.4806	0.5041

Tabela 6.10: Teste para rede treinada com MFCC convencional.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5779	0.5589	0.7381	0.6362	0.6277
0.0001	128	256	1024	512	256	0.5	0.5803	0.5572	0.7761	0.6490	0.6406
0.0001	128	512	512	512	256	0.5	0.5791	0.5550	0.7950	0.6541	0.6458
0.0001	128	512	1024	512	256	0.5	0.5595	0.5843	0.4027	0.4760	0.5056
0.0001	256	256	512	512	256	0.5	0.5732	0.5691	0.6019	0.5852	0.5823
0.0001	256	256	1024	512	256	0.5	0.5642	0.5778	0.4737	0.5204	0.5340
0.0001	256	512	512	512	256	0.5	0.5781	0.5518	0.8413	0.6673	0.6596
0.0001	256	512	1024	512	256	0.5	0.5589	0.5809	0.4133	0.4839	0.5092

Tabela 6.11: Teste para rede treinada com MFCC agregado.

Mesmo com melhoria, a solução não atingiu desempenho para aplicação prática.

6.5 Treinamento utilizando métodos lineares - Segunda combinação

Nessa abordagem, foram realizadas modificações nos métodos originalmente utilizados (Energia, BCED, p -Norm e MMA) em duas etapas. Na primeira etapa, o método MMA foi substituído pelo Teste do Maior Autovalor de Roy (RLRT), resultando na seguinte combinação: Energia, BCED, p -Norm e RLRT. Na segunda etapa, foi adicionado o detector baseado na entropia do sinal, resultando na seguinte combinação: Energia, BCED, p -Norm, RLRT e Entropia.

As Tabelas 6.12 e 6.13 apresentam os resultados para diferentes combinações. Apesar da estratégia visar a incorporação de novas características, os resultados dos testes não alcançaram níveis satisfatórios, mantendo as métricas avaliadas em patamares insuficientes.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5109	0.5112	0.9964	0.6757	0.6736
0.0001	128	256	1024	512	256	0.5	0.5115	0.5122	0.9366	0.6622	0.6556
0.0001	128	512	512	512	256	0.5	0.4961	0.5261	0.1462	0.2288	0.3493
0.0001	128	512	1024	512	256	0.5	0.5115	0.5114	0.9995	0.6766	0.6747
0.0001	256	256	512	512	256	0.5	0.4896	0.5232	0.0201	0.0387	0.2679
0.0001	256	256	1024	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	256	512	512	512	256	0.5	0.5116	0.5115	0.9997	0.6767	0.6749
0.0001	256	512	1024	512	256	0.5	0.5112	0.5113	0.9964	0.6758	0.6737

Tabela 6.12: Teste para rede treinada com métodos Energia, BCED, p -Norm e RLRT.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.4887	0.0	0.0	0.0	0.1222
0.0001	128	256	1024	512	256	0.5	0.5111	0.5112	0.9995	0.6764	0.6745
0.0001	128	512	512	512	256	0.5	0.4884	0.4643	0.0033	0.0066	0.2406
0.0001	128	512	1024	512	256	0.5	0.5112	0.5113	0.9995	0.6765	0.6746
0.0001	256	256	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	256	1024	512	256	0.5	0.4901	0.6341	0.0066	0.0131	0.2860
0.0001	256	512	512	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748
0.0001	256	512	1024	512	256	0.5	0.5113	0.5113	1.0	0.6767	0.6748

Tabela 6.13: Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia.

6.6 Comparando os métodos

Os resultados obtidos indicam que a solução proposta com a rede CNN não consegue identificar sinais interferentes com boa precisão, quando comparada com a solução proposta no Capítulo 4, que também investigou sinais em banda passante.

A Figura 6.1 mostra o comparativo entre as principais configurações de treinamento da rede escolhidos com base na maior métrica de desempenho, os resultados são expressos em Acurácia, Precisão, Recall e F1-score. Conforme observa-se, os valores de acurácia, precisão e F1-score ficaram entre 50-70%, o que compromete a classificação dos sinais.

Os resultados obtidos indicam que a baixa precisão afeta diretamente a detecção dos verdadeiros positivos, ou seja, a capacidade da rede em identificar corretamente os sinais de interferência. Uma baixa precisão significa que uma proporção significativa dos sinais classificados como interferentes na verdade não são, o que pode resultar em decisões incorretas ou em custos adicionais para investigação.

Quanto ao baixo F1-score, ele é impactado pela combinação da baixa precisão e do elevado Recall. O F1-score é uma métrica que considera tanto a precisão quanto o Recall, fornecendo uma medida do equilíbrio entre essas duas métricas. Portanto, um

baixo F1-score indica não apenas uma baixa precisão, mas também um baixo Recall, ou seja, uma incapacidade da rede em identificar corretamente os verdadeiros positivos e os verdadeiros negativos. Isso implica que a rede não está alcançando um equilíbrio satisfatório na classificação dos sinais, o que compromete sua capacidade.

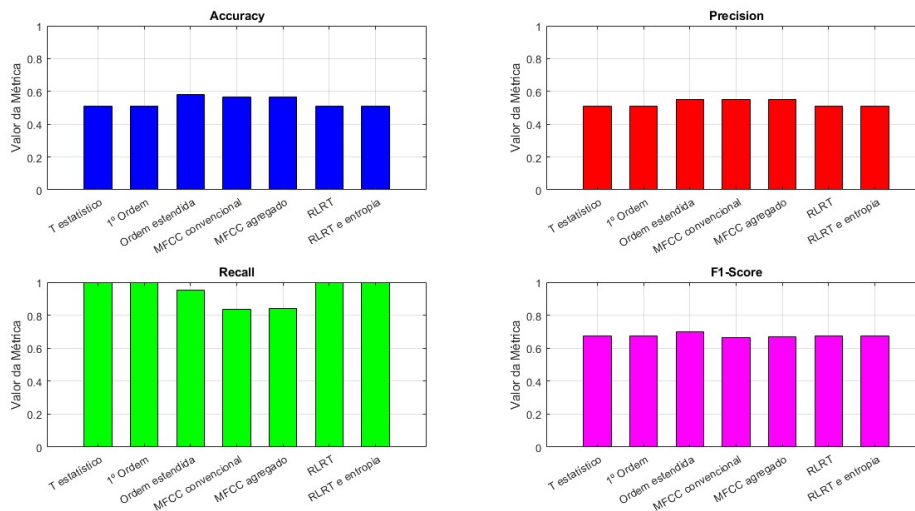


Figura 6.1: Comparando métricas de avaliação dos métodos explorados em banda passante.

No próximo capítulo, é explorada a aplicação da rede CNN na análise de sinais em banda base, utilizando abordagens similares às empregadas em banda passante. São apresentados os resultados obtidos com diferentes métodos de treinamento, incluindo estatísticas de primeira ordem, estatísticas estendidas, coeficientes MFCC e métodos lineares. A motivação para esta análise está na maior praticidade de acesso a sinais em banda base em dispositivos modernos, como *smartphones*, tornando esta abordagem especialmente relevante para aplicações práticas.

Capítulo 7

Resultados da CNN - Banda Base

Neste capítulo, é abordado a aplicação da rede CNN na análise de sinais em banda base, similar ao que foi feito no Capítulo 5 para a rede *autoencoder*. Como continuação do capítulo anterior, explorou-se uma variedade de métodos de treinamento, incluindo o uso de métodos lineares isolados e combinados, estatísticas de primeira ordem, estatísticas de ordem estendida, MFCC e a inclusão do RLRT e entropia. A motivação para propor soluções utilizando sinais em banda base é a facilidade de implementação da técnica de detecção de interferência, pois é mais prático ter acesso ao sinal em banda base em dispositivos comerciais modernos, como os *smart phones*.

7.1 Treinamento com métodos lineares: valores T isoladamente

As Tabelas 7.1, 7.2, 7.3 e 7.4 apresentam os resultados dos testes da rede CNN quando foram treinadas com dados baseado nos métodos da Energia, BCED, p -Norm e MMA, respectivamente. Conforme se observa, diversos hiperparâmetros são testados para encontrar a configuração de melhor desempenho da CNN.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657

Tabela 7.1: Teste para rede treinada com método da Energia.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253

Tabela 7.2: Teste para rede treinada com método BCED

7.1. TREINAMENTO COM MÉTODOS LINEARES: VALORES T ISOLADAMENTE83

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253

Tabela 7.3: Teste para rede treinada com método p -Norm.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253

Tabela 7.4: Teste para rede treinada com método MMA.

Similar a resultados anteriores, a análise dos resultados indica que, isoladamente,

nenhum dos métodos de sensoriamento espectral proporcionou um desempenho robusto na detecção de interferências nos sinais de áudio das rádios FM. Esse resultado pode ser explicado por diversas razões, incluindo a complexidade dos dados, a inadequação dos estatísticas escolhidas ou a necessidade de combinar múltiplas estatísticas para melhor discriminar os dois tipos de sinais. As próximas seções propõem outras estratégias em busca de uma possível melhoria.

7.2 Treinamento com métodos lineares: valores T combinados

Nesta etapa, os métodos foram combinados para treinar a rede CNN e os resultados dos testes são mostrados nas tabelas a seguir. A Tabela 7.5 exibe os resultados quando a rede é treinada com as métricas T dos métodos de Energia e BCED. A Tabela 7.6 traz os resultados ao adicionar as características do método p -Norm, enquanto que a Tabela 7.7 mostra os resultados com a inclusão das características do método MMA.

7.2. TREINAMENTO COM MÉTODOS LINEARES: VALORES T COMBINADOS85

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657

Tabela 7.5: Teste para rede treinada com métodos da Energia e BCED.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	64	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	64	512	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	64	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	256	1024	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	512	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	128	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	128	512	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.4	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	256	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	256	1024	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	512	512	256	0.3	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	512	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	512	512	256	0.5	0.5014	0.0	0.0	0.0	0.1253
0.0001	256	512	1024	512	256	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.0001	256	512	1024	512	256	0.5	0.4986	0.4986	1.0	0.6654	0.6657

Tabela 7.6: Teste para rede treinada com métodos da Energia, BCED e p -Norm.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	16	64	128	256	1	0.4	0.5014	0.0	0.0	0.0	0.1253
0.001	16	64	128	256	1	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.001	16	64	256	256	1	0.3	0.5014	0.0	0.0	0.0	0.1253
0.001	16	64	256	256	1	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.001	16	64	256	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	16	128	128	256	1	0.3	0.5014	0.0	0.0	0.0	0.1253
0.001	16	128	128	256	1	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.001	16	128	128	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	16	128	256	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	16	128	256	256	1	0.4	0.5014	0.0	0.0	0.0	0.1253
0.001	16	128	256	256	1	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.001	32	64	128	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	32	64	128	256	1	0.4	0.5014	0.0	0.0	0.0	0.1253
0.001	32	64	128	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	32	64	256	256	1	0.3	0.5014	0.0	0.0	0.0	0.1253
0.001	32	64	256	256	1	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.001	32	64	256	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	32	128	128	256	1	0.3	0.5014	0.0	0.0	0.0	0.1253
0.001	32	128	128	256	1	0.4	0.5014	0.0	0.0	0.0	0.1253
0.001	32	128	128	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	32	128	256	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	32	128	256	256	1	0.4	0.5014	0.0	0.0	0.0	0.1253
0.001	32	128	256	256	1	0.5	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	64	128	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	64	128	256	1	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	64	128	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	64	64	256	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	64	256	256	1	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	64	256	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	64	128	128	256	1	0.3	0.5014	0.0	0.0	0.0	0.1253
0.001	64	128	128	256	1	0.4	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	128	128	256	1	0.5	0.5014	0.0	0.0	0.0	0.1253
0.001	64	128	256	256	1	0.3	0.4986	0.4986	1.0	0.6654	0.6657
0.001	64	128	256	256	1	0.4	0.5014	0.0	0.0	0.0	0.1253
0.001	64	128	256	256	1	0.5	0.4986	0.4986	1.0	0.6654	0.6657

Tabela 7.7: Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA

Não houve um aumento significativo na acurácia dos modelos em comparação com às propostas anteriores. A acurácia permaneceu em valores pouco expressivos, variando entre 49.86% e 50.14%. Esses resultados sugerem que as combinações de métodos utilizadas no treinamento da CNN não foram eficientes na detecção de sinais de interferência utilizando sinais em banda base oriundo de transmissões das rádios FM.

7.3 Treinamento utilizando estatísticas de primeira ordem e estendido

A Tabela 7.8 exibe os resultados dos testes ao treinar a rede com os valores de máximo, mínimo, média, variância e desvio padrão dos sinais de áudio. Nota-se uma melhoria significativa em comparação aos resultados obtidos com os métodos descritos na Seção 7.2. O treinamento com estatísticas de primeira ordem alcançou uma métrica de desempenho de 73%, enquanto o máximo alcançado anteriormente é de 66%.

7.3. TREINAMENTO UTILIZANDO ESTATÍSTICAS DE PRIMEIRA ORDEM E ESTENDIDO⁸⁷

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.7452	0.7723	0.6935	0.7308	0.7355
0.0001	128	256	1024	512	256	0.5	0.6856	0.6391	0.8487	0.7291	0.7256
0.0001	128	512	512	512	256	0.5	0.6567	0.6074	0.8811	0.7191	0.7160
0.0001	128	512	1024	512	256	0.5	0.6665	0.6201	0.8550	0.7189	0.7151
0.0001	256	256	512	512	256	0.5	0.6748	0.6213	0.8906	0.7320	0.7297
0.0001	256	256	1024	512	256	0.5	0.6483	0.5979	0.9000	0.7185	0.7162
0.0001	256	512	512	512	256	0.5	0.6890	0.6444	0.8393	0.7291	0.7254
0.0001	256	512	1024	512	256	0.5	0.6974	0.6577	0.8198	0.7298	0.7262

Tabela 7.8: Teste para rede treinada com estatística de Primeira Ordem.

A Tabela 7.9 destaca os resultados obtidos ao explorar características estatísticas estendida dos sinais de áudio. Nessa análise, foram calculadas as características de MFCC, Croma, Método Mel, Centroide espectral, Largura de banda espectral e Declive espectral, e, em seguida, foram derivadas estatísticas de máximo, mínimo, média e desvio padrão para cada uma dessas características. Os resultados são apresentados para diferentes combinações de hiperparâmetros.

Observa-se que, em comparação com o treinamento utilizando características de primeira ordem, os resultados obtidos com características estatísticas foram inferiores. A métrica de desempenho atingiu um máximo de 63%, enquanto no treinamento anterior essa métrica alcançou 73%. Portanto, essa diferença indica que não existe ganho de desempenho do modelo ao utilizar características estatísticas mais complexas.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5470	0.5312	0.7798	0.6319	0.6225
0.0001	128	256	1024	512	256	0.5	0.5464	0.5296	0.8072	0.6396	0.6307
0.0001	128	512	512	512	256	0.5	0.5535	0.5341	0.8172	0.6460	0.6377
0.0001	128	512	1024	512	256	0.5	0.5443	0.5275	0.8258	0.6438	0.6353
0.0001	256	256	512	512	256	0.5	0.5620	0.5444	0.7451	0.6291	0.6201
0.0001	256	256	1024	512	256	0.5	0.5611	0.5463	0.7059	0.6159	0.6073
0.0001	256	512	512	512	256	0.5	0.5670	0.5486	0.7430	0.6311	0.6224
0.0001	256	512	1024	512	256	0.5	0.5524	0.5341	0.8016	0.6411	0.6323

Tabela 7.9: Teste para rede treinada com estatística estendida.

Tais resultados mostram como a variação nos conjuntos de dados de treinamento afeta o desempenho do modelo durante os testes. A rede CNN é sensível a essas alterações, destacando a importância de ajustar cuidadosamente os dados de entradas e os hiperparâmetros para cada conjunto de características. Embora os resultados ainda mostrem um desempenho aquém do ideal, é notável a melhoria em comparação com os métodos lineares.

7.4 Treinamento com Coeficientes Centrais de Frequência Mel

Na abordagem utilizando o MFCC convencional, os resultados dos testes da rede treinada são apresentados na Tabela 7.10. Nesta fase, os 15 primeiros valores dos coeficientes MFCC foram calculados para todos os sinais de áudio em banda base, constituindo a entrada para o treinamento da CNN. Os resultados obtidos revelaram um desempenho máximo de 63% da métrica de desempenho, indicando um resultado ainda inferior à rede quando treinada com dados estatísticos de primeira ordem.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.5451	0.5265	0.8692	0.6558	0.6492
0.0001	128	256	1024	512	256	0.5	0.5424	0.5263	0.8245	0.6425	0.6339
0.0001	128	512	512	512	256	0.5	0.5473	0.5311	0.7856	0.6338	0.6244
0.0001	128	512	1024	512	256	0.5	0.5468	0.5297	0.8114	0.6410	0.6322
0.0001	256	256	512	512	256	0.5	0.5476	0.5286	0.8556	0.6535	0.6463
0.0001	256	256	1024	512	256	0.5	0.5495	0.5355	0.7274	0.6169	0.6074
0.0001	256	512	512	512	256	0.5	0.5550	0.5356	0.8098	0.6447	0.6363
0.0001	256	512	1024	512	256	0.5	0.5629	0.5425	0.7882	0.6426	0.6341

Tabela 7.10: Teste para rede treinada com MFCC convencional.

Na abordagem em que foram extraídos os valores máximo, mínimo, médio, variância e desvio padrão dos 15 primeiros coeficientes MFCC para o treinamento da rede, os resultados dos testes são apresentados na Tabela 7.11. Esses resultados indicam uma melhoria na métrica de desempenho, que alcança até 75%. Isso representa uma superação dos resultados obtidos quando a rede foi treinada com dados estatísticos de primeira ordem dos sinais.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.6894	0.6321	0.9019	0.7433	0.7417
0.0001	128	256	1024	512	256	0.5	0.6686	0.6112	0.9219	0.7351	0.7342
0.0001	128	512	512	512	256	0.5	0.6891	0.6299	0.9127	0.7454	0.7443
0.0001	128	512	1024	512	256	0.5	0.6726	0.6125	0.9348	0.7401	0.7400
0.0001	256	256	512	512	256	0.5	0.7034	0.6467	0.8932	0.7502	0.7484
0.0001	256	256	1024	512	256	0.5	0.7058	0.6459	0.9074	0.7546	0.7534
0.0001	256	512	512	512	256	0.5	0.7009	0.6411	0.9090	0.7519	0.7507
0.0001	256	512	1024	512	256	0.5	0.6870	0.6269	0.9198	0.7456	0.7448

Tabela 7.11: Teste para rede treinada com MFCC agregado.

As abordagens com dados estatísticos dos 15 primeiros coeficientes MFCC apresentaram resultados promissores, sugerindo que a representação estatística desses

coeficientes pode ser tão eficaz quanto a utilização direta dos valores de primeira ordem. A escolha entre essas abordagens deve ser orientada pela natureza específica do conjunto de dados e pelos objetivos da tarefa. Uma análise mais aprofundada das métricas de desempenho em um ambiente de simulações em tempo real, como realizada no Capítulo 10, pode determinar qual dos métodos mais promissores alcança melhor desempenho.

7.5 Treinamento utilizando métodos lineares - Segunda combinação

Inicialmente, essa seção explora combinações dos métodos da Energia, BCED, p -Norm e RLRT. Posteriormente, foi adicionado o método da entropia para tentar ganhar em desempenho por meio do grau de incerteza do sinal. Os resultados são apresentados nas Tabelas 7.12 e 7.13, respectivamente.

A Tabela 7.12 revela que os resultados alcançaram um desempenho máximo de 79%, superando todos os métodos de treinamento realizados anteriormente. Essa melhoria foi acarretada pela substituição do método MMA pelo RLRT. Com MMA, a rede CNN atingiu um máximo de 67% da métrica de desempenho, enquanto que com RLRT foi de 79%, um incremento de 12%. Além do melhor desempenho, se nota um melhor balanceamento entre a Acurácia, Precisão, Recall e F1-score.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.8025	0.8765	0.6993	0.7736	0.7882
0.0001	128	256	1024	512	256	0.5	0.7635	0.9222	0.5680	0.6936	0.7378
0.0001	128	512	512	512	256	0.5	0.7915	0.9265	0.6012	0.7191	0.7596
0.0001	128	512	1024	512	256	0.5	0.7673	0.8927	0.5686	0.6974	0.7315
0.0001	256	256	512	512	256	0.5	0.7987	0.8585	0.6902	0.7633	0.7777
0.0001	256	256	1024	512	256	0.5	0.7843	0.8623	0.6672	0.7457	0.7649
0.0001	256	512	512	512	256	0.5	0.8122	0.8818	0.7128	0.7875	0.7986
0.0001	256	512	1024	512	256	0.5	0.7917	0.7878	0.8164	0.8011	0.7993

Tabela 7.12: Teste para rede treinada com métodos Energia, BCED, p -Norm e RLRT.

Na Tabela 7.13, são apresentados os resultados dos testes após a inclusão dos valores de entropia dos sinais no treinamento. Observa-se uma melhoria na métrica de

desempenho, atingindo um valor de 82%, o que representa um aumento de 3% em relação a solução sem entropia. Embora essa diferença não seja significativamente alta, é possível concluir que o acréscimo da informação sobre o grau de incerteza do sinal contribui para melhoria de desempenho da detecção de interferência. No entanto, é importante notar que, apesar da melhora na métrica Recall, que aumentou de 71% para 88% com a inclusão da entropia, houve uma redução na precisão, de 88% para 77%. Isso ressalta a necessidade de considerar com cautela qual método oferece o melhor desempenho global.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	128	256	512	512	256	0.5	0.7548	0.9652	0.5046	0.6640	0.7221
0.0001	128	256	1024	512	256	0.5	0.7916	0.8420	0.7224	0.7532	0.7773
0.0001	128	512	512	512	256	0.5	0.7985	0.8408	0.7346	0.7845	0.7896
0.0001	128	512	1024	512	256	0.5	0.7851	0.8520	0.6884	0.7542	0.7699
0.0001	256	256	512	512	256	0.5	0.7927	0.8261	0.7320	0.7751	0.7815
0.0001	256	256	1024	512	256	0.5	0.7954	0.8229	0.7393	0.7787	0.7841
0.0001	256	512	512	512	256	0.5	0.8089	0.7766	0.8813	0.8254	0.8230
0.0001	256	512	1024	512	256	0.5	0.7864	0.7447	0.9223	0.8221	0.8189

Tabela 7.13: Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia.

Ambas as abordagens demonstram resultados promissores na detecção de sinais de rádio interferente em banda base. A escolha entre as duas pode depender da natureza específica do conjunto de dados e dos requisitos da tarefa. Nesse sentido, é importante validar os dois métodos em um ambiente de detecção ao tempo real, como é apresentado no Capítulo 10.

7.6 Comparando os métodos

Os resultados obtidos revelam que a rede CNN alcançou diferentes níveis capacidade na classificação dos sinais de áudio, tanto na presença quanto na ausência de interferência junto ao sinal legítimo de rádio. A Figura 7.1 mostra a comparação de desempenho dos métodos propostos.

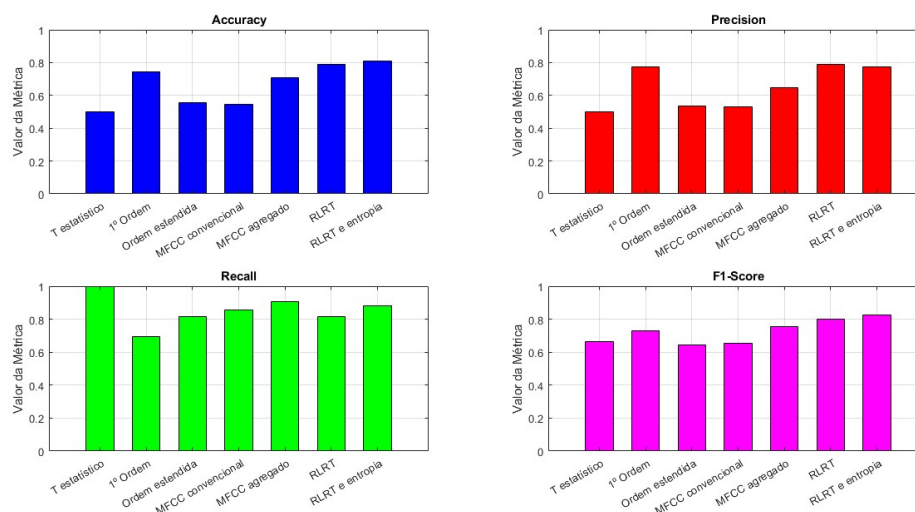


Figura 7.1: Comparando métricas de avaliação dos métodos explorados em banda base.

É possível observar que os métodos que incorporaram somente RLRT e a RLRT juntamente com a entropia alcançaram melhores indicadores de desempenho. De modo geral, essas soluções propostas apresentaram todas as métricas de desempenho por volta de 80% (algumas maiores que 80%). Esses resultados indicam as duas propostas com soluções promissoras para a aplicação prática utilizando sinais de áudios em banda base.

Apesar das outras soluções propostas terem alcançado bons valores de testes em algumas das métricas avaliadas, quando comparadas à Acurácia, Precisão, Recall e F1-score simultaneamente, os resultados não são tão satisfatórios.

No próximo capítulo, é apresentada a análise dos resultados da rede CNN aplicada a sinais em banda passante, com foco em cenários envolvendo múltiplas fontes de interferência. O estudo inclui a avaliação da rede treinada utilizando estatísticas de primeira ordem, estatísticas estendidas, métodos lineares (solução proposta) e coeficientes MFCC. Essa análise busca não apenas demonstrar a robustez da solução proposta, mas também explorar como os diferentes métodos se comportam em condições de maior complexidade.

Capítulo 8

Resultados da CNN - Banda passante - Múltiplas interferências

Até esse momento, as soluções se destinaram a sinais de áudio, em banda base e banda passante, na presença de uma fonte de interferência. Este capítulo estende a investigação para a situação com interferência de múltiplas fontes. Para tal, os sinais com interferência foram modelados de acordo com o exposto na Seção 3.1.3. Essa modelagem incorpora elementos de não linearidade causada por múltiplas fontes de rádio interferente, e foi importante para aprimorar a compreensão do desempenho das soluções propostas em condições mais desafiadoras e aderentes com sistemas práticos.

8.1 Treinamento com métodos lineares: valores T isoladamente

Conforme mostrado na Tabela 8.1, os resultados dos testes da rede CNN baseados no método da Energia não apresentou resultados diferentes dos resultados até o momento testados. Observa-se que, independentemente das configurações dos parâmetros, o desempenho em todas as métricas é baixo.

94CAPÍTULO 8. RESULTADOS DA CNN - BANDA PASSANTE - MÚLTIPLAS INTERFERÊNCIAS

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.1: Teste para rede treinada com método da Energia.

Da mesma forma, ao examinar os resultados apresentados na Tabela 8.2 (BCED), Tabela 8.3 (p -Norm), Tabela 8.4 (MMA), eles não atenderam às expectativas desejadas. Quando treinados isoladamente, os conjuntos de características da Energia, BCED, p -Norm e MMA não demonstram resultados significativos. Em todas as configurações avaliadas, os resultados exibem um desequilíbrio, em que a precisão e a acurácia ficam em torno de 50%, enquanto o Recall recebe valor de 0 ou 1. Esses resultados sugerem que a rede tende a classificar todos os sinais como sendo com ou sem interferência, indicando uma limitação na capacidade de distinguir entre essas classes.

8.1. TREINAMENTO COM MÉTODOS LINEARES: VALORES T ISOLADAMENTE95

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674

Tabela 8.2: Teste para rede treinada com método BCED.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.3: Teste para rede treinada com método p -Norm.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	16	64	128	256	1	0.4	0.5004	0.5004	1.0	0.6670	0.6669
0.001	16	64	128	256	1	0.5	0.4996	0.0	0.0	0.0	0.1249
0.001	16	64	256	256	1	0.3	0.5004	0.5004	1.0	0.6670	0.6669
0.001	16	64	256	256	1	0.4	0.5004	0.5004	1.0	0.6670	0.6669
0.001	16	64	256	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	16	128	128	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	16	128	128	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	16	128	128	256	1	0.5	0.4996	0.0	0.0	0.0	0.1249
0.001	16	128	256	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	16	128	256	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	16	128	256	256	1	0.5	0.4996	0.0	0.0	0.0	0.1249
0.001	32	64	128	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	32	64	128	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	32	64	128	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	32	64	256	256	1	0.3	0.5004	0.5004	1.0	0.6670	0.6669
0.001	32	64	256	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	32	64	256	256	1	0.5	0.4996	0.0	0.0	0.0	0.1249
0.001	32	128	128	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	32	128	128	256	1	0.4	0.5004	0.5004	1.0	0.6670	0.6669
0.001	32	128	128	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	32	128	256	256	1	0.3	0.5004	0.5004	1.0	0.6670	0.6669
0.001	32	128	256	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	32	128	256	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	64	64	128	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	64	64	128	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	64	64	128	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	64	64	256	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	64	64	256	256	1	0.4	0.5004	0.5004	1.0	0.6670	0.6669
0.001	64	64	256	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	64	128	128	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	64	128	128	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	64	128	128	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669
0.001	64	128	256	256	1	0.3	0.4996	0.0	0.0	0.0	0.1249
0.001	64	128	256	256	1	0.4	0.4996	0.0	0.0	0.0	0.1249
0.001	64	128	256	256	1	0.5	0.5004	0.5004	1.0	0.6670	0.6669

Tabela 8.4: Teste para rede treinada com método MMA.

8.2 Treinamento com métodos lineares: valores T combinados

Nesta etapa, os métodos foram combinados para treinar a rede CNN. A Tabela 8.5 exibe os resultados dos testes quando a rede foi treinada com as combinações dos métodos da Energia e BCED dos sinais de áudio em banda passante. Conforme observado anteriormente, esses resultados não atingem o nível desejado, e suas métricas indicam a ineficácia da rede na classificação dos sinais, já que tendem a categorizá-los todos como tendo ou não tendo interferência devido os valores de Recall alcançados.

Na Tabela 8.6, além da Energia dos sinais e BCED, a normalização p foi incorporada ao treinamento da CNN. No entanto, os resultados permanecem insatisfatórios, com valores baixos nas métricas de desempenho. A adição de p -Norm não contribuiu para melhorar a capacidade de classificação dos sinais. Dessa forma, a rede continua com o

8.2. TREINAMENTO COM MÉTODOS LINEARES: VALORES T COMBINADOS97

problema de classificar todos os sinais de testes como tendo ou não tendo interferência.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.5: Teste para rede treinada com métodos da Energia e BCED.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.6: Teste para rede treinada com métodos da Energia, BCED e p -Norm

Além das características mencionadas anteriormente, os valores máximo e mínimo dos autovalores da matriz de covariância dos sinais foram incorporados aos dados de treinamento da rede. No entanto, apesar dessa inclusão de dados adicionais, os resultados dos testes indicam um desempenho insatisfatório, como evidenciado na Tabela 8.7. Nota-se que tanto a acurácia quanto a precisão se aproximam de 50%, o que caracteriza uma baixa probabilidade de acertos.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.7: Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA.

8.3 Treinamento utilizando estatísticas de primeira ordem e estendida

Nesta etapa, foram utilizados os valores máximo, mínimo, média, variância e desvio padrão dos sinais de áudio modulados para treinar a rede CNN. Os resultados são apresentados na Tabela 8.8. Observa-se que essa abordagem também não apresenta resultados satisfatórios para os sinais em banda passante.

8.3. TREINAMENTO UTILIZANDO ESTATÍSTICAS DE PRIMEIRA ORDEM E ESTENDIDA 99

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.8: Teste para rede treinada com estatística de Primeira Ordem.

Por outro lado, a Tabela 8.9 apresenta os resultados dos testes da rede quando treinada com os dados dos valores máximo, mínimo, média, variância e desvio padrão extraídos dos cálculos de MFCC, Croma, Método Mel, Centroide espectral, Largura de banda espectral e Declive espectral. Nessa abordagem, a rede alcançou um desempenho superior em comparação com os métodos combinados e o treinamento utilizando apenas estatísticas de primeira ordem.

Este conjunto de resultados mostra uma melhoria significativa na precisão da classificação, com valores de acurácia de 90%, precisão de 99% e métricas de desempenho, como recall e F1-Score, consistentemente mais altas em comparação com a abordagem anterior. Esses resultados indicam uma boa capacidade da rede quando treinada com características de ordem estendida na diferenciação entre os sinais com e sem interferência.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.8967	0.9955	0.7937	0.8832	0.8922
0.001	32	64	256	256	1	0.5	0.8991	0.9816	0.8102	0.8877	0.8947
0.001	32	128	128	256	1	0.5	0.8984	0.9946	0.7980	0.8855	0.8941
0.001	32	128	256	256	1	0.5	0.9020	0.9776	0.8196	0.8917	0.8977
0.001	64	64	128	256	1	0.5	0.9020	0.9760	0.8211	0.8918	0.8977
0.001	64	64	256	256	1	0.5	0.9013	0.9955	0.8030	0.8890	0.8972
0.001	64	128	128	256	1	0.5	0.9009	0.9938	0.8038	0.8887	0.8968
0.001	64	128	256	256	1	0.5	0.9027	0.9860	0.8139	0.8917	0.8986

Tabela 8.9: Teste para rede treinada com estatística estendida.

Ambas as tabelas anteriores revelam como a variação nos conjuntos de dados de treinamento afeta o desempenho do modelo durante os testes, evidenciando a sensibilidade da rede a essas alterações. Isso destaca a importância de ajustar cuidadosamente os dados de entrada e os hiperparâmetros para cada conjunto de características. Enquanto os resultados do treinamento com estatísticas de primeira ordem demonstram um desempenho aquém do ideal, é notório a melhoria da rede CNN quando

treinada com estatísticas de ordem estendida. Essa evolução sugere que as características de ordem estendida proporcionam à rede uma capacidade mais robusta de diferenciação entre os sinais com e sem interferência.

8.4 Treinamento com Coeficientes Centrais de Frequência Mel (convencional e agregado)

Com em outros capítulos, nesta fase, a rede CNN foi treinada utilizando dois modos distintos dos coeficientes MFCC: o modo convencional, com os 15 primeiros coeficientes, e o modo agregado, que inclui os valores máximo, mínimo, média, variância e desvio padrão desses coeficientes.

Os resultados dos testes para o modo convencional estão apresentados na Tabela 8.10. Observa-se que o método alcançou altos valores de acurácia, precisão, Recall e F1-score, próximos de 100%, o que evidencia uma melhora significativa na estratégia empregada para a classificação dos sinais com e sem interferência. Isso sugere que os MFCCs são capazes de fornecer informações discriminativas eficazes para a detecção de sinais interferentes quando os dados incluem os efeitos não lineares da múltiplas fontes de interferência.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.9798	1.0	0.9589	0.9790	0.9794
0.001	32	64	256	256	1	0.5	0.9808	0.9985	0.9625	0.9802	0.9805
0.001	32	128	128	256	1	0.5	0.9808	0.9985	0.9625	0.9802	0.9805
0.001	32	128	256	256	1	0.5	0.9819	0.9985	0.9646	0.9813	0.9816
0.001	64	64	128	256	1	0.5	0.9801	0.9978	0.9618	0.9794	0.9798
0.001	64	64	256	256	1	0.5	0.9808	0.9985	0.9625	0.9802	0.9805
0.001	64	128	128	256	1	0.5	0.9822	0.9993	0.9646	0.9816	0.9819
0.001	64	128	256	256	1	0.5	0.9815	0.9970	0.9654	0.9809	0.9812

Tabela 8.10: Teste para rede treinada com MFCC convencional.

Na Tabela 8.11, são apresentados os resultados da abordagem agregada do MFCC. Observa-se que os resultados também foram promissores na classificação dos sinais.

8.5. TREINAMENTO UTILIZANDO MÉTODOS LINEARES - SEGUNDA COMBINAÇÃO 101

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.9893	1.0	0.9784	0.9891	0.9892
0.001	32	64	256	256	1	0.5	0.9886	0.9985	0.9784	0.9883	0.9885
0.001	32	128	128	256	1	0.5	0.9897	1.0	0.9791	0.9894	0.9896
0.001	32	128	256	256	1	0.5	0.9890	1.0	0.9776	0.9887	0.9888
0.001	64	64	128	256	1	0.5	0.9901	1.0	0.9798	0.9898	0.9899
0.001	64	64	256	256	1	0.5	0.9876	1.0	0.9747	0.9872	0.9874
0.001	64	128	128	256	1	0.5	0.9897	1.0	0.9791	0.9894	0.9896
0.001	64	128	256	256	1	0.5	0.9897	1.0	0.9791	0.9894	0.9896

Tabela 8.11: Teste para rede treinada com MFCC agregado.

Ambas as tabelas evidenciam a capacidade da CNN em aprender padrões relevantes para distinguir entre os dados dos sinais com interferência e sem interferência, ao utilizar diferentes representações dos MFCCs. Esses resultados destacam a utilidade dos coeficientes MFCC para esta abordagem. No entanto, para o problema em questão desta tese, é possível que não haja uma grande quantidade de rádios FM interferentes, ficando a expectativa sobre seu desempenho em um ambiente real, que pode inserir não linearidades provenientes da própria cadeia de transmissão e recepção. Essa avaliação é feita no Capítulo 10 para sinais em banda base.

8.5 Treinamento utilizando métodos lineares - Segunda combinação

Para esta seção, os experimentos foram feitos em duas fases distintas de treinamento da rede CNN. Na primeira, a rede foi treinada utilizando os métodos de Energia, BCED, p -Norm e RLRT. Na segunda fase, a entropia do sinal modulado foi adicionada aos dados de treinamento, com a rede CNN sendo treinada com os dados de Energia, BCED, p -Norm, RLRT e Entropia. Os resultados são mostrados nas Tabelas 8.12 e 8.13, respectivamente. Eles revelam um desempenho limitado em termos de acurácia, precisão, recall e F1-Score, indicando que a rede CNN, treinada com esses dados, não alcançou resultados satisfatórios.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	128	1	0.5	0.4371	0.4583	0.7893	0.5799	0.5662
0.001	32	128	128	128	1	0.5	0.4506	0.4637	0.7417	0.5706	0.5567
0.001	32	128	256	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	128	1	0.5	0.4631	0.4746	0.8492	0.6089	0.5989
0.001	64	128	128	128	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	128	1	0.5	0.6136	1.0	0.2150	0.3539	0.5456

Tabela 8.12: Teste para rede treinada com métodos Energia, BCED, p -Norm e RLRT.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	128	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	128	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	128	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	128	1	0.5	0.6090	0.7266	0.3297	0.4536	0.5297
0.001	64	128	256	128	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 8.13: Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia

Ambas as tabelas evidenciam que, apesar das tentativas de aprimorar o desempenho da rede CNN ao adicionar informações de métodos que tiveram um bom desempenho quando os sinais não foram submetidos a distorções não lineares, os resultados apresentados neste capítulo mostram que esta estratégia não se mostrou satisfatória.

8.6 Comparando os métodos

A comparação dos métodos utilizados para classificar os sinais de áudio em banda passante revelou diferenças significativas em termos de desempenho, conforme evidenciado na Figura 8.1.

É notável que os métodos baseados em MFCC alcançaram os melhores resultados de forma consistente. Suas taxas de identificação se aproximaram de 100%, indicando uma capacidade elevada de classificação. Além disso, destaca-se que o treinamento da rede com características de ordem estendida também obteve resultados promissores, ultrapassando 80% em diversas métricas, o que sugere uma abordagem que merece ser explorada em ambientes reais.

Por outro lado, as soluções que incluíram RLRT e RLRT juntamente com a entropia

apresentaram os piores desempenhos, com valores em torno de 50% para a maioria das métricas. Esses resultados indicam uma solução pouco promissora para aplicação em ambientes de classificação de sinais de rádio em tempo real.




Figura 8.1: Comparando métricas de avaliação dos métodos explorados em banda passante.

A Figura 8.2 compara o desempenho dos métodos empregados no Capítulo 6 (apenas uma fonte de rádio interferente) com os resultados do Capítulo 8 (com múltiplos sinais de interferência). Observa-se como os métodos baseado em MFCC e estatística estendida tiveram melhoras de desempenho. No entanto, os métodos lineares (estatística T), Primeira ordem, RLRT e RLRT com entropia tiveram acurácia e precisão por volta de 50%, indicando baixo desempenho de classificar os dados de testes. Também é perceptível que as soluções propostas conseguem melhor discriminação de sinais com e sem interferente quando existe não linearidade na interferência. Essa característica é potencialmente atrativa para aplicação de tais métodos em situações reais.




Figura 8.2: Comparação de desempenho das soluções para sinais com uma fonte (Capítulo 6) e com múltiplas fontes (Capítulo 8) de interferência em banda passante.

No próximo capítulo, é apresentada a análise dos resultados obtidos pela rede CNN em banda base, expandindo os cenários para múltiplas fontes de interferência. A investigação abrange o desempenho da rede treinada com diferentes conjuntos de características, como estatísticas de primeira ordem, estatísticas estendidas e métodos avançados como MFCC. Esse estudo busca avaliar como a abordagem em banda base pode oferecer soluções práticas em comparação aos métodos aplicados em banda passante, especialmente em cenários desafiadores.

Capítulo 9

Resultados da CNN - Banda base - Múltiplas interferências

Este capítulo estende a investigação de sinais com interferência de múltiplas fontes, extraindo as entradas da rede CNN dos sinais em banda base.

9.1 Treinamento com métodos lineares: valores T isoladamente

Os resultados para o conjunto de características derivadas do método de Energia são apresentados na Tabela 9.1. Observa-se a dificuldade da rede em distinguir os dados de teste em sinais com interferência e sinais sem interferência corretamente, refletida pelo desequilíbrio nas métricas de avaliação. Como já visto casos anteriores, o resultado do Recall assumiu apenas dois resultados possíveis, zero ou um. Essa disparidade sugere que a rede está inclinada a classificar todas as entradas do conjunto de testes como possuindo interferência ou não, sem realizar distinções precisas entre os dois casos.

106CAPÍTULO 9. RESULTADOS DA CNN - BANDA BASE - MÚLTIPLAS INTERFERÊNCIAS

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	16	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	16	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	16	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	16	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.0001	16	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.0001	16	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.0001	16	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	16	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	32	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.0001	32	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.0001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	32	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.0001	32	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	32	64	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.0001	32	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.0001	32	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	32	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	32	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	32	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	64	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	64	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.0001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.0001	64	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270

Tabela 9.1: Teste para rede treinada com método da Energia.

As Tabelas 9.2, 9.3 e 9.4 apresentam os resultados de teste quando a rede CNN é treinada com características extraídas usando o método BCED, o método p -Norm e o método MMA, respectivamente. É notório a persistência dos problemas de classificação com os dados de teste, pois o Recall oscila entre os valores de um ou zero, enquanto as demais métricas permanecem em torno de 0% ou 50%.

9.1. TREINAMENTO COM MÉTODOS LINEARES: VALORES T ISOLADAMENTE 107

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270

Tabela 9.2: Teste para rede treinada com método BCED.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270

Tabela 9.3: Teste para rede treinada com método p-Norm

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674

Tabela 9.4: Teste para rede treinada com método MMA.

Em todas as tabelas analisadas, foi persistente o desafio da classificação precisa dos dados extraídos dos métodos isoladamente. É importante considerar a possibilidade de combinar múltiplos métodos para obter resultados mais robustos na classificação de sinais, como já ficou evidente em capítulos anteriores. A integração de diferentes técnicas de extração de características e algoritmos de classificação pode permitir uma melhor captura de dados dos sinais de áudio e, conseqüentemente, uma classificação mais precisa.

9.2 Treinamento com métodos lineares: valores T combinados

A Tabela 9.5 apresenta o desempenho ao combinar dados dos métodos de Energia e BCED para treinar a rede CNN. Observa-se que, independentemente das variações nos hiperparâmetros, a rede não obteve resultados satisfatórios, com valores baixos de acurácia, precisão e variações acentuadas do F1-score. Estes resultados mostram que não

9.2. TREINAMENTO COM MÉTODOS LINEARES: VALORES T COMBINADOS 109

houve diferença na capacidade da rede com a combinação do método BCED e Energia em relação aos treinamentos e testes com métodos isolados da seção anterior.

Uma análise mais abrangente dos resultados indica que apesar das combinações de diversos métodos de sensoriamento espectral, a solução com CNN ainda enfrenta desafios na tarefa de classificação de sinais em banda base com múltiplos interferentes, como ilustrado nas Tabelas 9.6 e 9.7. Elas incorporam o método p -Norm e o método e maior e menor autovalor da matriz de covariância à combinação dos dados da entrada da CNN.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	64	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	16	128	256	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	16	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	128	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	32	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	32	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	128	256	1	0.4	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	64	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	64	256	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.3	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	128	256	1	0.5	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.3	0.4922	0.4922	1.0	0.6597	0.6610
0.001	64	128	256	256	1	0.4	0.5078	0.0	0.0	0.0	0.1270
0.001	64	128	256	256	1	0.5	0.4922	0.4922	1.0	0.6597	0.6610

Tabela 9.5: Teste para rede treinada com métodos da Energia e BCED.

110CAPÍTULO 9. RESULTADOS DA CNN - BANDA BASE - MÚLTIPLAS INTERFERÊNCIAS

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	12	64	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	12	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	12	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	12	64	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	12	64	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	12	64	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	12	128	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	12	128	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	12	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	12	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	12	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	12	128	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	128	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	128	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674

Tabela 9.6: Teste para rede treinada com métodos da Energia, BCED e p -Norm.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	16	64	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	16	64	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	64	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	128	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	16	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	16	128	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	64	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	64	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	32	128	256	256	1	0.4	0.5011	0.5011	1.0	0.6676	0.6674
0.001	32	128	256	256	1	0.5	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.3	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	128	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	128	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674
0.001	64	64	256	256	1	0.3	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.4	0.4989	0.0	0.0	0.0	0.1247
0.001	64	64	256	256	1	0.5	0.5011	0.5011	1.0	0.6676	0.6674

Tabela 9.7: Teste para rede treinada com métodos da Energia, BCED, p -Norm e MMA.

9.3 Treinamento utilizando estatísticas de primeira ordem e estendido

Nesta etapa, foram utilizados os valores máximo, mínimo, média, variância e desvio padrão dos sinais de áudio para treinar a CNN. Os resultados desse treinamento foram avaliados com dados de testes, cujos resultados estão apresentados na Tabela 9.8. Observa-se que essa abordagem não apresenta resultados significativamente melhores que os apresentados no Capítulo 7 (sem múltiplas interferências).

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.6760	0.772	0.5015	0.6080	0.6394
0.001	32	64	256	256	1	0.5	0.7196	0.7826	0.6097	0.6854	0.6993
0.001	32	128	128	256	1	0.5	0.7301	0.7320	0.7279	0.7299	0.7300
0.001	32	128	256	256	1	0.5	0.7238	0.7397	0.6927	0.7154	0.7179
0.001	64	64	128	256	1	0.5	0.6905	0.7519	0.5705	0.6488	0.6654
0.001	64	64	256	256	1	0.5	0.6882	0.8036	0.4999	0.6164	0.6520
0.001	64	128	128	256	1	0.5	0.6948	0.7767	0.5488	0.6431	0.6659
0.001	64	128	256	256	1	0.5	0.7209	0.7541	0.6572	0.7023	0.7086

Tabela 9.8: Teste para rede treinada com estatística de Primeira Ordem.

No entanto, a Tabela 9.9 apresenta os resultados dos testes da rede quando treinada com os dados dos valores máximo, mínimo, média, variância e desvio padrão extraídos dos cálculos de MFCC, Croma, Método Mel, Centroide espectral, Largura de banda espectral e Declive espectral. Nessa abordagem, a rede alcançou desempenho superior ao apresentado no Capítulo 7.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.6655	0.6311	0.7713	0.6942	0.6905
0.001	32	64	256	256	1	0.5	0.6641	0.6145	0.8521	0.7140	0.7112
0.001	32	128	128	256	1	0.5	0.6502	0.6047	0.8355	0.7016	0.6980
0.001	32	128	256	256	1	0.5	0.6737	0.6294	0.8196	0.7120	0.7087
0.001	64	64	128	256	1	0.5	0.6648	0.6243	0.8009	0.7016	0.6979
0.001	64	64	256	256	1	0.5	0.6751	0.6263	0.8427	0.7185	0.7157
0.001	64	128	128	256	1	0.5	0.6392	0.5908	0.8687	0.7033	0.7005
0.001	64	128	256	256	1	0.5	0.6420	0.5970	0.8391	0.6977	0.6940

Tabela 9.9: Teste para rede treinada com estatística estendida.

As análises das duas tabelas anteriores destacam como as variações nos conjuntos de dados de treinamento influenciam o desempenho do modelo durante os testes. No entanto, os resultados do treinamento com estatísticas de primeira ordem revelam um desempenho mediano. Também não foi evidenciado uma melhoria notável na rede ao ser treinada com

estatísticas de ordem estendida, que sugere que as características de ordem estendida não concederam à rede uma capacidade mais robusta para classificar os sinais.

9.4 Treinamento com Coeficientes Centrais de Frequência Mel (Modo convencional e agregado)

Similar aos outros capítulos, dois modos distintos dos coeficientes MFCC foram explorados para treinar a rede: (i) o modo convencional, utilizando os 15 primeiros coeficientes; e (ii) o modo agregado, que inclui valores máximo, mínimo, média, variância e desvio padrão desses coeficientes. Os resultados dos testes foram sumarizados nas Tabela 9.10 e 9.11.

Observa-se que esse método resultou em índices de acurácia, precisão, Recall e F1-score muito promissores, com melhor resultado para a estratégia agregada. Outra constatação é que os resultados são superiores aos mostrados no Capítulo 7, que considerou apenas uma fonte de interferência. Essas constatações sugerem que os MFCCs são capazes de fornecer informações discriminativas eficazes na detecção de sinais interferentes.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.7525	0.8169	0.6407	0.7182	0.7321
0.001	32	64	256	256	1	0.5	0.7493	0.7773	0.6876	0.7297	0.7360
0.001	32	128	128	256	1	0.5	0.7596	0.8459	0.6255	0.7192	0.7375
0.001	32	128	256	256	1	0.5	0.7575	0.8443	0.6219	0.7162	0.7350
0.001	64	64	128	256	1	0.5	0.7599	0.8407	0.6320	0.7216	0.7386
0.001	64	64	256	256	1	0.5	0.7624	0.8546	0.6234	0.7209	0.7403
0.001	64	128	128	256	1	0.5	0.7656	0.8438	0.6429	0.7297	0.7455
0.001	64	128	256	256	1	0.5	0.7560	0.8364	0.6270	0.7167	0.7340

Tabela 9.10: Teste para rede treinada com MFCC convencional

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.0001	32	64	128	256	1	0.5	0.8356	0.9610	0.6941	0.8060	0.8242
0.0001	32	64	256	256	1	0.5	0.8491	0.9470	0.7345	0.8273	0.8395
0.0001	32	128	128	256	1	0.5	0.8470	0.9369	0.7388	0.8261	0.8372
0.0001	32	128	256	256	1	0.5	0.8647	0.9212	0.7929	0.8523	0.8578
0.0001	64	64	128	256	1	0.5	0.8494	0.9421	0.7395	0.8286	0.8399
0.0001	64	64	256	256	1	0.5	0.8594	0.9350	0.7677	0.8431	0.8513
0.0001	64	128	128	256	1	0.5	0.8612	0.9300	0.7763	0.8462	0.8534
0.0001	64	128	256	256	1	0.5	0.8580	0.9433	0.7569	0.8399	0.8495

Tabela 9.11: Teste para rede treinada com MFCC agregado.

Os resultados apresentados em ambas as tabelas demonstram como a CNN foi capaz de capturar padrões significativos durante o treinamento para classificar os dados de teste.

9.5 Treinamento utilizando métodos lineares - Segunda combinação

Os experimentos conduzidos nesta seção são propostos em duas fases distintas de treinamento, e são apresentados nas Tabelas 9.12 e 9.13. Na primeira fase, a rede CNN é treinada utilizando métodos de Energia, BCED, p -Norm e RLRT. Na segunda etapa, a entropia do sinal é adicionada aos dados de treinamento, e a rede CNN é treinada com Energia, BCED, p -Norm, RLRT e entropia.

Os testes realizados com e sem considerar a entropia revelam que a rede CNN não conseguiu alcançar um desempenho similar ao utilizar o método MFCC como entrada. No entanto, o desempenho foi superior aos métodos estatísticos de primeira ordem e estendidos, mas mostram uma piora de desempenho em relação aos resultados obtidos no Capítulo 7 (que consideram somente um fonte de interferência).

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.7230	0.7551	0.6472	0.6970	0.7056
0.001	32	64	256	256	1	0.5	0.7006	0.7618	0.5700	0.6521	0.6711
0.001	32	128	128	256	1	0.5	0.7017	0.6967	0.6977	0.6972	0.6983
0.001	32	128	256	256	1	0.5	0.6673	0.7021	0.5628	0.6247	0.6392
0.001	64	64	128	256	1	0.5	0.7145	0.7535	0.6241	0.6827	0.6937
0.001	64	64	256	256	1	0.5	0.6992	0.6537	0.8268	0.7302	0.7275
0.001	64	128	128	256	1	0.5	0.7472	0.7485	0.7323	0.7403	0.7421
0.001	64	128	256	256	1	0.5	0.7589	0.7420	0.7821	0.7615	0.7611

Tabela 9.12: Testes para rede treinada com métodos Energia, BCED, p -Norm e RLRT.

Learning Rate	Conv1 Filter	Conv2 Filter	Conv3 Filter	Dense1 Unit	Dense2 Unit	Dropout Rate	Accuracy	Precision	Recall	F1-Score	Performance Metric
0.001	32	64	128	256	1	0.5	0.6890	0.7025	0.6582	0.6796	0.6823
0.001	32	64	256	256	1	0.5	0.7102	0.7766	0.5920	0.6718	0.6877
0.001	32	128	128	256	1	0.5	0.7334	0.7482	0.7054	0.7262	0.7283
0.001	32	128	256	256	1	0.5	0.7160	0.7370	0.6738	0.7039	0.7077
0.001	64	64	128	256	1	0.5	0.7164	0.7471	0.6560	0.6986	0.7045
0.001	64	64	256	256	1	0.5	0.7214	0.7030	0.7685	0.7343	0.7318
0.001	64	128	128	256	1	0.5	0.7180	0.7697	0.6239	0.6892	0.7002
0.001	64	128	256	256	1	0.5	0.7312	0.7736	0.6553	0.7096	0.7174

Tabela 9.13: Teste para rede treinada com métodos Energia, BCED, p -Norm, RLRT e Entropia.

9.6 Comparando os métodos

A análise comparativa dos métodos empregados na classificação dos sinais de áudio em banda passante revelou diferenças significativas em termos de capacidade, conforme apresentado na Figura 9.1. Nesta figura, são comparados os resultados obtidos nos testes neste capítulo entre os diferentes métodos empregados, os quais foram escolhidos com base na melhor métrica de desempenho.

Observa-se que os métodos baseados em MFCC demonstraram os melhores resultados em relação aos demais. Suas taxas de acurácia e precisão superaram os 80%, indicando uma boa capacidade de diferenciar dados extraídos de sinais com e sem interferência. Por outro lado, os métodos que incorporaram RLRT e RLRT juntamente com a entropia mostraram-se melhores do que os que aplicaram apenas a estatística de primeira ordem e estendida.

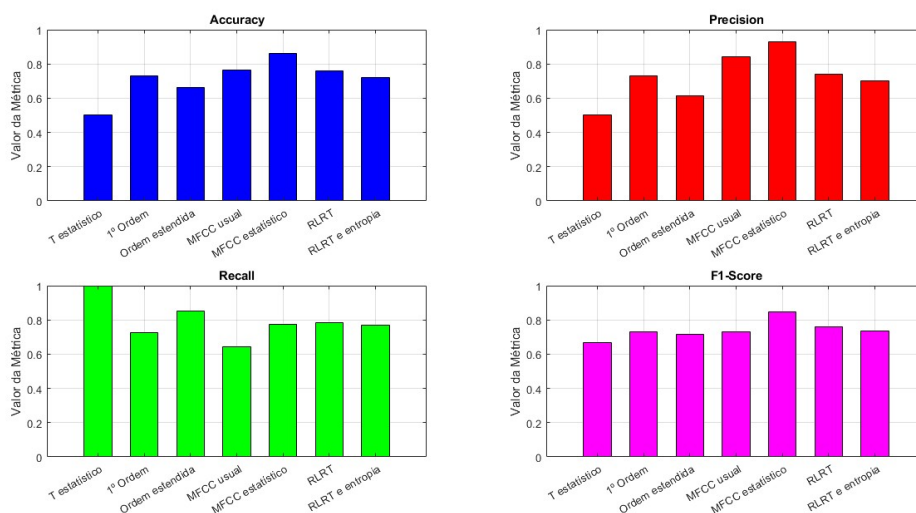


Figura 9.1: Comparando métricas de avaliação dos métodos explorados em banda base.

A Figura 9.2 compara o desempenho dos métodos empregados no Capítulo 7 (apenas uma fonte de rádio interferente) com os resultados do Capítulo 9 (com múltiplos sinais de interferência).




Figura 9.2: Comparando capacidade de detecção simples e múltipla em banda base.

Observa-se que os métodos baseados em MFCC tiveram uma melhoria de desempenho significativa (exceto para métrica Recall) quando aplicados a sinais com múltiplas fontes de interferência. Os métodos baseados em RLRT e entropia apresentaram um resultado levemente inferior quando submetidos à detecção de múltiplas fontes de sinais. Apesar da diminuição do desempenho dos métodos propostos, eles ainda são significativamente mais atrativos em comparação aos métodos básicos estatísticos e suas versões estendidas.

9.7 Análise Comparativa dos Métodos de Detecção

Nesta seção, é realizada uma análise detalhada dos diferentes métodos de detecção de interferências em sinais de rádio, com base nas curvas ROC (Receiver Operating Characteristic) apresentadas na Figura 9.3. As métricas incluem a taxa de verdadeiros positivos (P_D) e a taxa de falsos positivos (P_{FA}), além da área sob a curva (AUC, *Area Under the Curve*), que avalia o desempenho geral de cada método. Os métodos analisados incluem abordagens baseadas em coeficientes MFCC convencionais, agregados, estatísticas de primeira ordem, e combinações mais avançadas, como RLRT

(Likelihood Ratio Test), entropia e combinações de múltiplas características.




Figura 9.3: Comparando resultados de métodos empregados

Os resultados revelam diferenças significativas no desempenho dos métodos avaliados. Os principais pontos observados são:

- MFCC Convencional (Banda Base e Banda Passante): O desempenho dos coeficientes MFCC convencionais apresenta AUC de 0,58 em banda base e 0,60 em banda passante, indicando uma capacidade limitada para diferenciar sinais interferentes. Isso sugere que os MFCC convencionais, quando usados isoladamente, não são suficientemente robustos para cenários complexos;
- MFCC Agregado (Banda Passante - Múltiplas Interferências): A abordagem de MFCC agregado aplicada à banda passante, em um cenário de múltiplas interferências, atinge um desempenho com AUC de 0,99. Este resultado reflete a boa capacidade de combinar informações para treinar a rede;
- Estatística de Primeira Ordem (Banda Base): O uso de estatísticas de primeira

ordem na banda base apresenta um AUC de 0,80, mostrando um desempenho considerável, mas inferior a outros métodos. Essa abordagem é útil em cenários menos complexos, mas suas limitações ficam evidentes quando analisadas com outras combinações;

- Combinações Avançadas (RLRT e Entropia): As combinações envolvendo RLRT e entropia em diferentes cenários demonstram AUCs que variam de 0,80 a 0,85, dependendo das condições (banda base ou múltiplas interferências). Essas abordagens comprovam a importância de integrar múltiplas métricas para melhorar a capacidade de detecção;
- RLRT Agregado (Banda Base - Múltiplas Interferências): A combinação com RLRT para sinais em banda base no cenário de múltiplas interferências alcança um AUC de 0,80, evidenciando sua consistência, embora não supere os resultados obtidos com MFCC agregado.

Os resultados obtidos até este capítulo da teste revelaram que a rede CNN apresentou resultados superiores ao *Autoencoder* em cenários com uma única interferência e banda base. Por outro lado, a rede *Autoencoder* se mostrou superior a CNN em banda passante.

No entanto, não foi possível testar o desempenho do *Autoencoder* em cenários com múltiplas interferências. Por essa razão, não há como realizar uma comparação direta entre os dois métodos nessas condições específicas. Essa limitação ressalta a importância de futuros trabalhos que investiguem o comportamento do *Autoencoder* em ambientes mais complexos, permitindo uma avaliação mais abrangente de sua aplicabilidade.

Os resultados apresentados na Figura 9.3 demonstram que a integração de múltiplas características e abordagens avançadas, como RLRT combinado com entropia, oferecem vantagens claras em termos de desempenho. A CNN, em particular, destacou-se como a solução mais robusta em cenários com uma única interferência, desde que os sinais detectados estejam em banda base, superando consistentemente o *Autoencoder*. Já em cenários com múltiplas interferências, os resultados indicaram que o método MFCC

agregado foi o que apresentou o melhor desempenho. Esses achados reforçam a importância de adotar estratégias que combinem as informações extraídas dos sinais para melhorar a detecção de interferências em diferentes condições.

No próximo capítulo, são apresentados os resultados dos testes práticos realizados com a rede CNN aplicada a sinais em banda base. Esses resultados incluem uma análise detalhada dos cenários em que o sinal recebido não sofre interferência da USRP, bem como daqueles em que a USRP introduz diferentes níveis de potência interferente. Além disso, será explorada a eficácia da rede em condições controladas e desafiadoras, com o objetivo de validar sua aplicabilidade em ambientes reais e compreender melhor suas limitações e potencialidades.

Capítulo 10

Resultados dos testes em ambiente real

Este capítulo apresenta os resultados práticos da identificação interferência utilizando sinais em banda base, obtidos em testes realizados em ambiente real. As soluções dos Capítulos 7 e 9 são alvos deste capítulo.

10.1 Rede CNN treinada com dados de uma única fonte interferente

Na Figura 10.1, são apresentados os resultados obtidos quando o sistema de detecção está sintonizado na rádio FM 98,9 MHz sem interferência intencional gerada pela USRP. Os resultados desta seção estão expressos em termos de porcentagem de acerto e cada um dos métodos recebe os mesmos sinais simultaneamente durante um período de 30 minutos. Na Figura 10.1, cada período de teste é identificado como *Teste 1*, *Teste 2*, *Teste 3* e *Teste 4*, dispostos no eixo inferior da figura. A cada 4 segundos de sinal recebido, a rede CNN é acionada para identificar a presença ou não de interferência. A cada 1 minuto (15 períodos de 4 segundos) é tomada uma decisão final em relação a presença de interferência, baseado em regra majoritária.

Analisando os resultados da Figura 10.1, o método linear apresentou pior desempenho, não sendo capaz de identificar corretamente nenhum sinal como não tendo interferência. No entanto, apesar de variações observadas, todos os demais métodos

tiveram desempenho igual ou superior a 59%.




Figura 10.1: Resultados experimentais para condições de não interferência.




Figura 10.2: Resultados experimentais para condições de interferência

Com a USRP enviando sinais, a forma de análise se basou em diferentes níveis de potência do sinal interferente, como mostra a Figura 10.2. Em cada um nível de potência

10.1. REDE CNN TREINADA COM DADOS DE UMA ÚNICA FONTE INTERFERENTE 121

interferente, o experimento consistiu da mesma lógica dos dados sem interferência, ou seja, foram analisados um intervalo de 30 minutos, com uma decisão parcial em cada 4 segundos e, finalmente, uma decisão final a cada 1 minuto. A porcentagem apresentada é referente a porcentagem de detecção correta de sinais com interferência. Observa-se que para uma interferência muito fraca (-75 dBm), os métodos tiveram dificuldades em detectar a interferência. Como esperado, a medida que a potência do sinal interferente aumenta, os métodos conseguem detectá-la com maior precisão. Isso acontece até o momento que a interferência se torna dominante e passa a ser percebida como sinal legítimo. Nessas situações, o sinal legítimo é visto como um interferente de baixa potência. Assim, quando a diferença entre tais sinais é muito grande, a rede começa ter dificuldades em detectá-los.

A Figura 10.3 mostra outra forma de verificar os resultados, em que os métodos lineares com a adição do RLRT e da entropia atingem resultados superiores aos demais. O melhor método linear combinado (identificado T-estatístico na figura) apresentou 100% de acerto para sinais com interferência, mas 0% para sinais sem interferência. Isso se deve aos resultados de Recall apresentados no Capítulo 7, que indicou que essa solução classificaria o sinal com um dos tipos, independente do sinal de entrada.




Figura 10.3: Comparando capacidade de detecção simples em banda base.

10.2 Rede CNN treinada com dados de uma múltiplas fontes interferente

Os resultados dos testes práticos da rede CNN treinada com dados de sinais com múltiplas interferências estão apresentados nas Figuras 10.4 e 10.5. Os experimentos foram conduzidos com apenas uma fonte de interferência, mesmo a rede sendo treinada para uma multiplicidade de sinais interferentes¹. A ideia é verificar seu desempenho também nessa condição e verificar se essa rede CNN se beneficia de alguma não linearidade dos processos de transmissão e recepção.

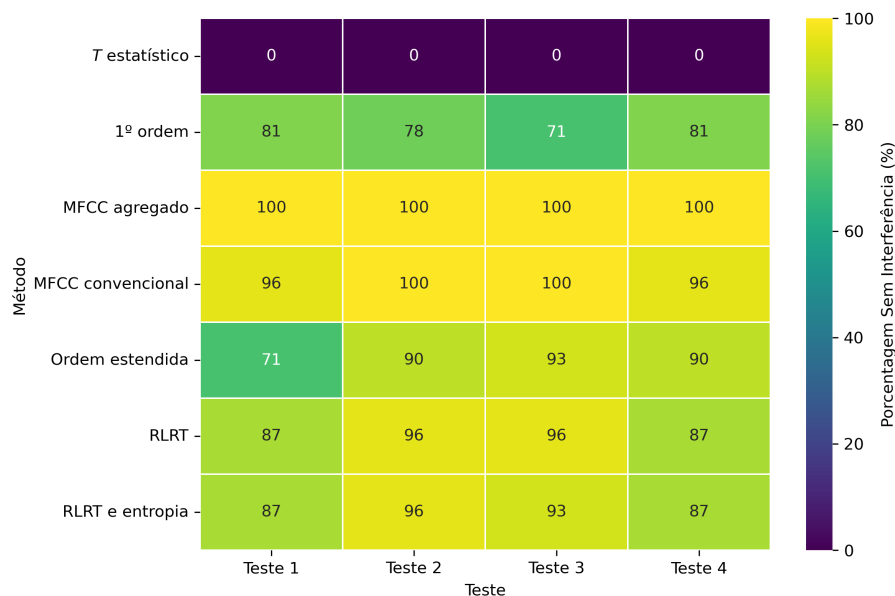


Figura 10.4: Resultados experimentais para condições de não interferência.

¹Não foi possível realizar o *setup* com múltiplos interferentes. Essa investigação é indicada como trabalhos futuros.

10.2. REDE CNN TREINADA COM DADOS DE UMA MÚLTIPLAS FONTES INTERFERENTE123




Figura 10.5: Resultados experimentais para condições de interferência.

Em conformidade com as conclusões apresentadas no Capítulo 9, os métodos baseado no MFCC conseguiram o melhor desempenho, seguindo pelos métodos lineares.

Adicionalmente, ao analisar os resultados na Figura 10.5, que apresenta o desempenho da rede CNN para sinais com interferência, é possível notar uma melhoria significativa dos métodos MFCC em relação ao caso de uma única fonte de interferência. Isso sugere que treinar a rede com sinais com múltiplas fontes de interferência fortalece o poder classificatório da rede CNN, quando treinada com características dos métodos MFCC.

A Figura 10.6 sumariza o que acontece com a taxa de detecção com a variação do sinal interferente. Observa-se como o método MFCC supera os métodos baseados em sensoriamento espectral (métodos lineares). No entanto, tal configuração ainda é superior aos demais métodos investigados.




Figura 10.6: Comparando capacidade de detecção simples e múltipla em banda base.

A Tabela 10.1 resume os resultados obtidos a partir dos testes realizados com diferentes métodos e combinações de características aplicadas à detecção de interferências em sinais de rádio. Os experimentos foram organizados em cenários distintos, considerando sinais em banda passante e banda base, além de situações com uma única interferência ou múltiplas interferências. Essa organização permitiu uma análise de desempenho das abordagens propostas.

Nos cenários com uma única interferência, os métodos baseados em estatísticas de primeira ordem, incluindo mínimo, máximo, média, variância e desvio padrão, apresentaram resultados predominantemente insatisfatórios tanto na banda passante quanto na banda base. Esses resultados indicam que, embora simples de implementar, essas estatísticas não fornecem informações suficientes para uma detecção robusta de interferências. No entanto, em banda passante, combinações mais avançadas, como a utilização de energia, BCED, p -Norm e MMA, demonstraram resultados promissores, destacando a importância de integrar múltiplas métricas na análise.

Para os cenários envolvendo múltiplas interferências, observa-se uma limitação nos testes realizados com o *Autoencoder*, que não foi avaliado nesses casos devido a dificuldades experimentais. Como resultado, não foi possível realizar uma comparação

direta entre o *Autoencoder* e a rede CNN em condições de múltiplas interferências. Por outro lado, métodos como o MFCC agregado, combinados com RLRT e entropia, apresentaram desempenhos superiores tanto em banda passante quanto em banda base.

A rede CNN destacou-se significativamente em vários cenários, demonstrando maior eficácia em comparação ao *Autoencoder*, especialmente na banda base com uma única interferência. Esse desempenho superior reforça a capacidade da CNN de extrair e analisar padrões complexos nos dados de entrada. Adicionalmente, em cenários com múltiplas interferências, a combinação de diferentes métodos, como energia, BCED, p -Norm, RLRT e entropia, foi essencial para alcançar uma detecção robusta, especialmente em sinais de banda passante.

A tabela também ilustra a limitação dos métodos baseados exclusivamente em estatísticas de primeira ordem, evidenciando que abordagens mais avançadas são necessárias para lidar com os desafios impostos por sinais com interferência. Em contrapartida, os métodos que utilizam MFCC agregado e combinações mais complexas apresentam um potencial significativo para aplicações práticas, oferecendo resultados superiores em cenários desafiadores.

Por fim, a legenda de cores presente na tabela foi incluída para facilitar a identificação dos capítulos nos quais os experimentos foram descritos detalhadamente. Essa organização contribui para uma visão mais clara dos resultados, permitindo que o leitor compreenda a evolução das análises e as escolhas metodológicas que levaram às soluções propostas. Esses achados reforçam a importância de integrar características avançadas e técnicas modernas, como redes neurais convolucionais, para otimizar a detecção de interferências em sinais de rádio em condições reais e complexas.

Métodos AutoEncoder	Única Interferência Banda Passante	Única Interferência Banda Base	Múltiplas Interferências Banda Passante	Múltiplas Interferências Banda Base
Primeira ordem mínimo e máximo	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Primeira ordem mínimo, máximo e média	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Primeira ordem máximo, mínimo, média e variância	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Primeira ordem máximo, mínimo, média, variância e desvio padrão	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
-	-	-	-	-
Estatística estendida mínimo e máximo	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Estatística estendida mínimo, máximo e média	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Estatística estendida máximo, mínimo, média e variância	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Estatística estendida máximo, mínimo, média, variância e desvio padrão	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
-	-	-	-	-
Método proposto isolado - Energia	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Método proposto isolado - BCED	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Método proposto isolado - p-Norm	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Método proposto isolado - MMA	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
-	-	-	-	-
Método proposto combinados - Energia e BCED	Resultados não satisfatório	Resultados não satisfatório	Não testado	Não testado
Método proposto combinados - Energia, BCED e p-Norm	Resultados promissores	Resultados não satisfatório	Não testado	Não testado
Método proposto combinados - Energia, BCED, p-Norm e MMA	Resultados promissores	Resultados não satisfatório	Não testado	Não testado
-	-	-	-	-
Primeira ordem máximo, mínimo, média, variância e desvio padrão	Resultados não satisfatório	Resultados promissores	Resultados não satisfatório	Resultados promissores
Estatística estendida máximo, mínimo, média, variância e desvio padrão	Resultados não satisfatório	Resultados não satisfatório	Resultados promissores	Resultados promissores
-	-	-	-	-
MFCC - Convencional	Resultados não satisfatório	Resultados não satisfatório	Resultados promissores	Resultados promissores
MFCC - Agregado	Resultados não satisfatório	Resultados promissores	Resultados promissores	Resultados promissores
-	-	-	-	-
Método proposto (segunda combinação) - Energia, BCED, p-Norm e RLRT	Resultados não satisfatório	Resultados promissores	Resultados não satisfatório	Resultados promissores
Método proposto (segunda combinação) - Energia, BCED, p-Norm, RLRT e Entropia	Resultados não satisfatório	Resultados promissores	Resultados não satisfatório	Resultados promissores
Capítulo 4	Capítulo 5	Capítulo 6	Capítulo 7	Capítulo 8
Capítulo 9				

Tabela 10.1: Tabela resumindo todos os testes realizados com legenda de cores para os capítulos

*10.2. REDE CNN TREINADA COM DADOS DE UMA MÚLTIPLAS FONTES INTERFERENTE*¹²⁷

No próximo capítulo, é apresentada a conclusão deste trabalho, com um resumo dos principais resultados alcançados, as contribuições realizadas e as limitações identificadas. Além disso, são discutidas possíveis direções para trabalhos futuros, destacando oportunidades para aprimoramentos e aplicações das metodologias propostas.

Capítulo 11

Conclusão

Neste trabalho, foram propostas soluções para identificar sinais com interferência em sinais de rádio FM. As soluções são fundamentadas na crença de que a combinação de métodos de aprendizado de máquina com técnicas de extração de características dos sinais de áudio pode ser empregada para identificar ocorrências de interferência.

Essas soluções beneficiam e se somam a importância das rádios FM no contexto da sociedade brasileira, tanto no nível cultural quanto econômico, conforme apresentado nos capítulos iniciais deste documento. As soluções propostas nesta tese foram motivadas pelo problema das rádios ilegais e o impacto que elas causam, incluindo o número de rádios fechadas anualmente, conforme informações da Anatel.

As técnicas de aprendizado de máquina utilizadas foram redes *Autoencoder* e CNN. Os métodos de extração de características incluíram técnicas de processamento de sinal de áudio, como sensoriamento espectral, MFCC, métodos lineares e estatísticos. As soluções de identificação de interferência foram aplicadas ao sinal de áudio em banda base e modulado em banda passante.

As soluções e testes executados incluem:

- Rede *Autoencoder* em banda passante e banda base com uma única fonte de interferência;
- Rede CNN em banda passante e banda base com uma única fonte de interferência;
- Rede CNN em banda passante e banda base com múltiplas fontes de interferência.

Os resultados obtidos com a rede *Autoencoder* com sinais em banda passante apresentaram resultados promissores nos testes executados. No entanto, a rede *Autoencoder* apresentou dificuldades em distinguir os sinais com interferência quando aplicada a sinais em banda base.

Apesar de útil, o método para calcular a distância entre PDFs pode apresentar limitações. Um único valor de H_1 fora do padrão (*outlier*) menor que o maior valor de H_0 pode indicar erroneamente uma sobreposição entre as PDFs, comprometendo a análise da distância. Da mesma forma, um único valor de H_0 maior que o menor valor de H_1 também pode levar a resultados equivocados. Esses problemas ocorrem porque o método considera apenas valores extremos das distribuições, ignorando informações mais completas sobre a dispersão dos dados. Alternativamente, existem métodos que levam em conta o desvio padrão ou métricas baseadas em toda a distribuição das PDFs, como a divergência de Kullback-Leibler ou a distância de Bhattacharyya, que podem oferecer uma análise mais robusta e precisa. Esses métodos ajudam a mitigar os impactos de *outliers* e fornecem uma visão mais completa sobre a separabilidade das hipóteses. Esse é um ponto claro de exploração de trabalhos futuros.

Os primeiros testes da rede CNN com sinais em banda passante não foram encorajadores, com a rede incapaz de distinguir os sinais de áudio nos cenários avaliados. As métricas de acurácia, precisão e F1-score foram as mais comprometidas. No entanto, ao utilizar dados extraídos de sinais em banda base, houve uma melhora significativa da solução proposta. A solução intitulada **Treinamento utilizando métodos lineares - Segunda combinação** apresentou o melhor desempenho em relação aos demais métodos investigados, com métricas de Precisão, Acurácia, Recall e F1-score em torno de 80%.

Nos experimentos envolvendo sinais com múltiplas interferências, os métodos baseados em estatísticas estendidas, MFCC convencional e MFCC agregado superaram os métodos baseados em sensoriamento espectral, quando analisados em banda passante. Em banda base, esses mesmos métodos mantiveram elevados índices de detecção, embora

os métodos de sensoriamento espectral tenham mostrado melhoria.

No último capítulo de resultados, foram realizados experimentos com sinais reais, utilizando dados em banda base provenientes de um *smartphone* como receptor de sinais de rádio FM, enquanto uma USRP foi empregada para gerar sinais interferentes. Esse experimento objetivou testar as soluções propostas em um ambiente prático e verificar a concordância dos resultados simulados.

Os sinais coletados foram processados e utilizados para avaliar os métodos desenvolvidos ao longo da tese para redes CNN. Os testes experimentais comprovaram a aplicabilidade das soluções propostas e a conformidade com as conclusões por simulação.

De maneira geral, os experimentos em campo confirmaram o potencial das técnicas de aprendizado de máquina para a detecção de interferências, abrindo espaço para futuras pesquisas e melhoramentos, especialmente em cenários com detecção de interferência em outros sistemas.

Como trabalhos futuros e que estendem as investigações desta tese, se destacam:

- Avaliar a generalização do modelo para diferentes frequências: Investigar o uso dessas redes com dados de sinais de rádios de diferentes frequências. Testar se a rede neural treinada com dados da rádio sintonizada em 98,9 MHz pode ser utilizada para detectar interferências em rádios operando em outras frequências ou precisará ser treinada com dados de outras rádios;
- Realizar testes com múltiplas fontes de interferência em ambiente prático: Ampliar os experimentos envolvendo múltiplas fontes interferentes para verificar o comportamento do modelo em cenários mais complexos;
- Explorar outras arquiteturas de Redes CNN: Investigar o uso de arquiteturas, como ResNet, DenseNet e EfficientNet como meio de melhorar a robustez das soluções propostas;
- Implementar a solução de detecção de interferência em um dispositivo móvel: Desenvolver uma instância fim-a-fim do sistema em dispositivo *smartphone*,

incluindo as soluções em banda base e banda passante;

- Integrar outros métodos de sensoriamento espectral: Investigar outras combinações de métodos para melhorar a capacidade de detecção;
- Estender a técnica de detecção de interferência: testar a solução concebida para outros sistemas (e.g., comunicação móvel pessoal, sistemas satélites), incluindo outras faixas de frequência e outras modulações;
- Testar o sistema em diversos ambientes: Realizar testes do sistema em diferentes ambientes, como áreas urbanas, rurais e industriais.

Referências Bibliográficas

Abdul, Zrar Kh and Abdulbasit K Al-Talabani (2022), ‘Mel frequency cepstral coefficient and its applications: A review’, *IEEE Access* .

Adelabu, Michael Adedosu, Agbotiname Lucky Imoize and Glory Uzuazobona Ughegbe (2021), Performance evaluation of radio frequency interference measurements from microwave links in dense urban cities, *em* ‘Telecom’, Vol. 2, MDPI, pp. 328–368.

Alzubaidi, Hasan (2024), ‘Exact solutions for travelling waves using tanh method for two dimensional stochastic allen–cahn equation with multiplicative noise’, *Journal of Umm Al-Qura University for Applied Sciences* pp. 1–6.

ANATEL (2022), <https://kantarihopemedia.com/conteudo/estudo/inside-radio-2022/>. Accessed: 15-06-2023.

Banjade, Vesh Raj Sharma, Chintha Tellambura and Hai Jiang (2014), ‘Performance of p-norm detector in awgn, fading, and diversity reception’, *IEEE Transactions on Vehicular Technology* **63**(7), 3209–3222.

Banjade, Vesh Raj Sharma, Chintha Tellambura and Hai Jiang (2015), Spectrum sensing performance of p-norm detector in random network interference, *em* ‘2015 IEEE International Conference on Communications (ICC)’, IEEE, pp. 7474–7479.

Bonet-Solà, Daniel and Rosa Ma Alsina-Pagès (2021), ‘A comparative survey of feature extraction and machine learning methods in diverse acoustic environments’, *Sensors* **21**(4), 1274.

- CISA, SAFECOM (2020), 'Ncswic radio frequency interference best practices guidebook', *Public Saf. Commun. RF Interf* **2020**, 1–12.
- Crepaldi, André et al. (2021), Rádio comunitária oeste fm: Estudo das possibilidades de interação nos meios analógicos e digitais, Dissertação de mestrado.
- De Piante, Marco, Stefano Boscolo, Emanuele Turco, Paolo Gardonio and Michele Midrio (2021), 'Audio quality level vs. signal-to-interference ratio in isofrequency fm broadcasting', *Annals of Telecommunications* pp. 1–11.
- Ghamisi, Pedram, Mauro Dalla Mura and Jon Atli Benediktsson (2014), 'A survey on spectral–spatial classification techniques based on attribute profiles', *IEEE Transactions on Geoscience and Remote Sensing* **53**(5), 2335–2353.
- Goodfellow, Ian, Yoshua Bengio and Aaron Courville (2016), *Deep learning*, MIT press.
- Harrold, RT (1971), 'The spectrum analyzer applied to the measurement of ehv power line radio noise', *IEEE Transactions on Power Apparatus and Systems* (4), 1837–1847.
- Haykin, Simon and Michael Moher (2011), *Sistemas de Comunicação-5*, Bookman Editora.
- Jabbar, H and Rafiqul Zaman Khan (2015), 'Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study)', *Computer Science, Communication and Instrumentation Devices* **70**(10.3850), 978–981.
- Kantar IBOPE* (2022), <https://www.kantaribopemedia.com/wp-content/uploads/2021/11/Tendencias-e-Previsoes-de-Midia-Kantar-2022.pdf>. Accessed: 10-03-2023.
- Kantar IBOPE - 2018* (2018), <https://kantaribopemedia.com/conteudo/infograficos/book-de-radio-2018-2/>. Accessed: 01-02-2020.

Kantar IBOPE - 2019 (2019), https://www.kantaribopemedia.com/wp-content/uploads/2019/09/INSIDERADIO_2019_KANTARIBOPEMEDIA_VF.pdf. Accessed: 01-02-2020.

Kantar IBOPE - 2020 (2017), https://www.kantaribopemedia.com/wp-content/uploads/2017/09/KIM17_bookradio_final-2.pdf. Accessed: 01-02-2020.

Kantar IBOPE - 2020 (2020), <https://www.kantar.com/brazil/inspiration/midia/inside-radio-2020>. Accessed: 01-02-2020.

Kantar IBOPE - 2021 (2021), https://www.kantaribopemedia.com/wp-content/uploads/2021/09/INSIDE-RADIO-2021_Kantar-IBOPE-Media.pdf. Accessed: 12-05-2021.

Kantar IBOPE - 2022 (2017-2023), <https://kantaribopemedia.com/brazil/>. Accessed: 19-11-2022.

Kantar IBOPE - 2022 (2022), <https://kantaribopemedia.com/conteudo/estudo/inside-radio-2022/>. Accessed: 15-06-2023.

Kantar IBOPE- 2023 (2023), https://kantaribopemedia.com/wp-content/uploads/2023/09/InsideAudio_2023_KantarIBOPEMedia_.pdf. Accessed: 13-08-2023.

Khan, Muhammad Ajmal, Raveendra K Rao and Xianbin Wang (2013), Non-linear trigonometric and hyperbolic chirps in multiuser spread spectrum communication systems, *em* ‘2013 IEEE 9th International Conference on Emerging Technologies (ICET)’, IEEE, pp. 1–6.

Långkvist, Martin, Lars Karlsson and Amy Loutfi (2014), ‘A review of unsupervised feature learning and deep learning for time-series modeling’, *Pattern recognition letters* **42**, 11–24.

- Mehrabi, Adib, Simon Dixon and Mark B Sandler (2017), 'Vocal imitation of synthesised sounds varying in pitch, loudness and spectral centroid', *The Journal of the Acoustical Society of America* **141**(2), 783–796.
- Mendonça, Valéria Márcia (2007), 'Educação popular: experiências de rádio-educação no brasil, de 1922 a 1960', *Boletim Técnico do SENAC* **33**(1), 28–41.
- MOREIRA, Sonia Virgínia (2001), 'Tecnologia e legislação para o rádio no século xxi', *Desafios do rádio no século XXI. São Paulo: Intercom* pp. 13–24.
- Nasser, Abbass, Hussein Al Haj Hassan, Jad Abou Chaaya, Ali Mansour and Koffi-Clément Yao (2021), 'Spectrum sensing for cognitive radio: Recent advances and future challenge', *Sensors* **21**(7), 2408.
- Pieranti, Octavio Penna (2019), 'Expansão da radiodifusão: uma análise das 1.833 outorgas do governo temer', *Galáxia (São Paulo)* pp. 0202–0215.
- Prati, Ronaldo Cristiano, GEAPA Batista, Maria Carolina Monard et al. (2008), 'Curvas roc para avaliação de classificadores', *Revista IEEE América Latina* **6**(2), 215–222.
- Qu, Hua, Xiguang Xu, Jihong Zhao, Feiyu Yan and Weihua Wang (2018), Robust spectrum sensing based on hyperbolic tangent in gaussian and non-gaussian noise environments, *em* '2018 Tenth International Conference on Ubiquitous and Future Networks (ICUFN)', IEEE, pp. 283–288.
- Sajichandrachood, OM and R Sethunadh (2023), 'Detection and segmentation of radio frequency interference from satellite images using attention-gans', *Astronomy and Computing* **45**, 100769.
- Steven, M Kay (1993), 'Fundamentals of statistical signal processing', *PTN Prentice-Hall, Englewood Cliffs, NJ* **10**(151045), 148.

- Stolar, Melissa N, Margaret Lech, Shannon J Stolar and Nicholas B Allen (2018), 'Detection of adolescent depression from speech using optimised spectral roll-off parameters', *Biomedical Journal* **2**, 10.
- Tingay, SJ, Marcin Sokolowski, Randall Wayth and Daniel Ung (2020), 'A survey of spatially and temporally resolved radio frequency interference in the fm band at the murchison radio-astronomy observatory', *Publications of the Astronomical Society of Australia* **37**, e039.
- Wael, Chaeriah Bin Ali, Nasrullah Armi and Budiman PA Rohman (2016), Spectrum sensing for low snr environment using maximum-minimum eigenvalue (mme) detection, *em '2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)'*, IEEE, pp. 435–438.
- Zeng, Yonghong, Ying-Chang Liang and Rui Zhang (2008), 'Blindly combined energy detection for spectrum sensing in cognitive radio', *IEEE signal processing letters* **15**, 649–652.