



**Universidade de Brasília**

Instituto de Ciências Exatas  
Departamento de Ciência da Computação

## Previsão de Oportunidades de Acesso Utilizando Redes Neurais Artificiais Recorrentes

Paulo A. L. Ferreira  
Silas S. Fernandes

Monografia apresentada como requisito parcial  
para conclusão do Bacharelado em Ciência da Computação

Orientador  
Prof. Dr. Marcus Vinicius Lamar

Coorientador  
Prof. Dr. Jacir Luiz Bordim

Brasília  
2016



**Universidade de Brasília**

Instituto de Ciências Exatas  
Departamento de Ciência da Computação

## Previsão de Oportunidades de Acesso Utilizando Redes Neurais Artificiais Recorrentes

Paulo A. L. Ferreira  
Silas S. Fernandes

Monografia apresentada como requisito parcial  
para conclusão do Bacharelado em Ciência da Computação

Prof. Dr. Marcus Vinicius Lamar (Orientador)  
CIC/UnB

Prof. Dr. André Costa Drummond    Prof. Msc. Marcos Fagundes Caetano  
Universidade de Brasília                      Universidade de Brasília

Prof. Dr. Rodrigo Bonifácio de Almeida  
Coordenador do Bacharelado em Ciência da Computação

Brasília, 15 de janeiro de 2016

# Dedicatória

Dedicamos este trabalho a um mito que fez parte da nossa vida acadêmica, Kure.

# Agradecimentos

Chega o momento em que precisamos agradecer a todos que nos ajudaram a trilhar esse árduo caminho. Começamos por nossas crenças agradecendo ao ser superior, que nos proporcionou a vida. Obrigado Deus por mais uma conquista.

Agradecemos às nossas famílias por terem nos ajudado a superar vários obstáculos que não conseguiríamos vencer sozinhos. Um agradecimento especial aos nossos pais Afonso, Beatriz, Idalicia e Jaime, e à Laura Mattos, que nos deram suporte durante todo o decorrer desta longa caminhada.

Agradecemos aos nossos orientadores, Jacir Luiz Bordim e Marcus Vinicius Lamar, que nos apoiaram e incentivaram a prosseguir com este trabalho, participando ativamente inclusive em dias de folga como fins de semana e férias. Estendemos este agradecimento ao Rodrigo Rosário, que nos acompanhou nas nossas atividades e ao Rafael Prata, que nos proveu material para revisão teórica e levantou pontos importantes para o trabalho.

E onde estavam nossos amigos? Sim, agradeço a vocês também por estarem sempre ao nosso lado, mesmo quando zoavam a gente por ter escolhido o Lamar como orientador (ops!). Nosso mais sincero agradecimento a todos vocês. Em especial: Heitor, User, Tails, Rodo, Guidinha, Wallace, Ximita e o Tio.

Por fim, agradecemos aos professores da banca Marcos Fagundes Caetano e André Costa Drummond pela disponibilidade e pelos comentários que contribuíram para uma melhora substancial do trabalho e deste documento.

# Resumo

A crescente demanda por tecnologias de comunicação sem fio tem esbarrado em um grande entrave: o modelo de alocação destas frequências é estático, dificultando a alocação para novos serviços. Além disso, a distribuição da ocupação das faixas do espectro não é uniforme, o que torna o modelo estático ineficiente, causando a escassez do espectro. O modelo de alocação dinâmica do espectro visa aumentar a eficiência do espectro a partir da exploração de faixas licenciadas por usuários que não possuem licença, desde que provejam meios de garantir uma interferência mínima com os usuários licenciados. Um dos grandes desafios para implementação de alocação dinâmica do espectro é a previsão correta de oportunidades de transmissão, para que usuários não licenciados possam explorar faixas licenciadas quando estiverem ociosas. Este trabalho propõe uma metodologia de previsão de oportunidades que consiste na aquisição dos sinais, análise por redes neurais recorrentes de Elman e modelagem estatística do ambiente para estimar a probabilidade de oportunidade de transmissão em um dado instante. Foram conduzidos experimentos para avaliar a eficiência e acurácia da metodologia proposta sob ambientes com diferentes configurações de tráfego, ruído e interferência. Os resultados, baseados em capturas de sinais utilizando um Rádio Definido por *Software* para monitoramento de um canal *Wi-Fi*, mostram que em todos os cenários avaliados uma rede neural de apenas 4 neurônios na camada intermediária é capaz de obter uma taxa de acerto média acima de 80%.

**Palavras-chave:** acesso oportunístico, redes neurais, sensoreamento por energia

# Abstract

The demand for wireless technology has been increasing, whereas the allocation policy of these frequency bands is static, which hinders allocation for new services. Furthermore, the distribution of spectrum frequency bands occupation is not uniform and therefore the static model is inefficient, causing spectrum scarcity. The dynamic spectrum allocation model aims to increase spectrum efficiency by the exploitation of licensed bands by unlicensed users assuming that they provide the means for guaranteeing minimum interference with licensed users. One of the major challenges of implementing dynamic spectrum allocation is to correctly forecast transmission opportunities in order to enable secondary users to exploit idle licensed bands. This work proposes a methodology for transmission opportunities forecasting, which consists of the following steps: signal acquisition, neural network analysis and statistical modeling of the environment to estimate the probability of transmission opportunity at a given time. Several experiments were conducted to evaluate the efficiency and accuracy of the proposed methodology over environments with different traffic, noise and interference settings. The results, based on signal acquisition using a Radio Defined Software to monitor a Wi-Fi channel, show that in every setting a neural network with only 4 hidden neurons is capable of obtaining an average correct classification rate of 80%.

**Keywords:** opportunistic access, neural networks, energy spectrum sensing

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Objetivos . . . . .	2
1.2	Metodologia . . . . .	2
1.3	Estrutura do Documento . . . . .	3
<b>2</b>	<b>Revisão Teórica</b>	<b>4</b>
2.1	Alocação do Espectro . . . . .	4
2.2	Sensoriamento do Espectro . . . . .	7
2.3	IEEE 802.11 . . . . .	9
2.4	Redes Neurais Artificiais . . . . .	12
2.4.1	Neurônio . . . . .	13
2.4.2	Estrutura de Redes Neurais . . . . .	14
2.4.3	Rede de Elman . . . . .	17
2.4.4	Treinamento . . . . .	19
2.5	Revisão do Estado da Arte . . . . .	20
2.6	Discussão . . . . .	20
<b>3</b>	<b>Metodologia de Previsão de Oportunidades</b>	<b>22</b>
3.1	Etapa I - Aquisição . . . . .	22
3.2	Etapa II - Processamento dos Sinais . . . . .	24
3.3	Etapa III - Limiarização . . . . .	25
3.4	IV - Classificação e Identificação Utilizando RNRE . . . . .	28
3.4.1	Redes Neurais Recorrentes de Elman de Classificação . . . . .	28
3.4.2	Redes Neurais Recorrentes de Elman de Identificação . . . . .	31
3.5	Etapa V - Previsão de Oportunidades . . . . .	32
<b>4</b>	<b>Resultados Experimentais</b>	<b>35</b>
4.1	Experimento 1 . . . . .	35
4.2	Experimento 2 . . . . .	45
4.3	Experimento 3 . . . . .	52

4.4 Experimento 4 . . . . .	58
4.5 Discussão . . . . .	64
<b>5 Conclusões</b>	<b>68</b>
<b>Referências</b>	<b>70</b>
<b>Anexo</b>	<b>74</b>
<b>I Distribuição de faixas de frequência no Brasil [1]</b>	<b>75</b>

# Lista de Figuras

2.1	Ocupação do espectro em Berkley. . . . .	5
2.2	Ocupação do espectro em Chicago e Nova York. . . . .	6
2.3	Diagrama de blocos de um rádio definido por <i>software</i> . . . . .	9
2.4	Canais no padrão IEEE 802.11. . . . .	9
2.5	Diagrama de diálogo CSMA/CA. . . . .	10
2.6	Exemplo de ciclo de transmissão e <i>Beacon</i> . . . . .	11
2.7	Diagrama de estados do CSMA/CA. . . . .	12
2.8	Modelo matemático de um neurônio artificial. . . . .	13
2.9	Exemplos de funções de ativação. . . . .	14
2.10	Estrutura de uma rede MLP $3 \times 4 \times 2$ . . . . .	15
2.11	Modelo de um neurônio recorrente. . . . .	16
2.12	Estrutura da RNPR de Jordan. . . . .	17
2.13	Estrutura da RNRE. . . . .	18
3.1	Metodologia proposta. . . . .	23
3.2	Processamento do sinal. . . . .	26
3.3	Limiarização da função de energia. . . . .	27
3.4	Particionamento com K-means. . . . .	28
3.5	Limiarização de um sinal sem filtragem. . . . .	29
3.6	Limiarização de um sinal filtrado. . . . .	30
3.7	Estrutura das RNRE de classificação. . . . .	31
3.8	Estrutura das RNRE de identificação. . . . .	32
3.9	Previsão de oportunidades. . . . .	33
3.10	Histograma de oportunidades. . . . .	33
3.11	Probabilidade acumulada de oportunidades. . . . .	34
4.1	Cenário do experimento 1. . . . .	36
4.2	Sinais $I$ e $Q$ com dispositivos ligados. . . . .	37
4.3	Sinais $I$ e $Q$ com dispositivos desligados. . . . .	37
4.4	Sinais $I$ e $Q$ , sinal de energia e espectrograma de parte do experimento 1. . . . .	38

4.5	Taxa de acerto para RNRE de classificação. . . . .	39
4.6	Taxa de acerto para RNRE de identificação. . . . .	39
4.7	Matriz de confusão do experimento 1. . . . .	40
4.8	Histograma de oportunidades após um Ack. . . . .	41
4.9	Probabilidade acumulada de oportunidades após um Ack. . . . .	42
4.10	Histograma de oportunidades após um <i>Beacon</i> . . . . .	43
4.11	Probabilidade acumulada de oportunidades após um <i>Beacon</i> . . . . .	43
4.12	Histograma de oportunidades para a RNREs de identificação. . . . .	44
4.13	Probabilidade acumulada de oportunidade para as RNREs de identificação. . . . .	44
4.14	Cenário do experimento 2. . . . .	45
4.15	Sinais durante a transmissão $A \rightarrow B$ . . . . .	46
4.16	Sinais durante a transmissão inversa $B \rightarrow A$ . . . . .	46
4.17	Sinais $I$ e $Q$ , sinal de energia e espectrograma de parte do experimento 2. . . . .	47
4.18	Espectrograma de uma parte do experimento 2. . . . .	48
4.19	Taxa de acerto para RNREs de classificação. . . . .	48
4.20	Taxa de acerto para RNREs de identificação. . . . .	49
4.21	Matriz de confusão do experimento 2. . . . .	50
4.22	Histograma de oportunidades após um Ack. . . . .	51
4.23	Probabilidade acumulada de oportunidade após um Ack. . . . .	51
4.24	Histograma de oportunidades após um <i>Beacon</i> . . . . .	52
4.25	Probabilidade acumulada de oportunidade após um <i>Beacon</i> . . . . .	52
4.26	Histograma de oportunidades para as RNRE de identificação. . . . .	53
4.27	Probabilidade acumulada de oportunidade para as RNRE de identificação. . . . .	53
4.28	Redes existentes no COMNET. . . . .	54
4.29	Cenário do experimento 3. . . . .	55
4.30	Sinais $I$ e $Q$ do experimento 3. . . . .	55
4.31	Sinais $I$ e $Q$ , sinal de energia e espectrograma de parte do experimento 3. . . . .	56
4.32	Taxas de acertos para RNREs de classificação. . . . .	56
4.33	Taxas de acertos para RNREs de identificação. . . . .	57
4.34	Matriz de confusão do experimento 3. . . . .	58
4.35	Histograma de oportunidades após um Ack. . . . .	59
4.36	Probabilidade acumulada de oportunidades após um Ack. . . . .	59
4.37	Histograma de oportunidades após um <i>Beacon</i> . . . . .	60
4.38	Probabilidade acumulada de oportunidade após um <i>Beacon</i> . . . . .	60
4.39	Histograma de oportunidades para a RNRE de identificação. . . . .	61
4.40	Probabilidade acumulada de oportunidade para a RNRE de identificação. . . . .	61
4.41	Cenário do experimento 4. . . . .	62

4.42	Sinais coletados no experimento 4. . . . .	62
4.43	Sinais $I$ e $Q$ , sinal de energia e espectrograma de parte do experimento 4. .	63
4.44	Taxa de acerto das RNREs de identificação no experimento 4. . . . .	64
4.45	Histograma de oportunidades para a RNRE de identificação. . . . .	64
4.46	Probabilidade acumulada de oportunidade para a RNRE de identificação. .	65
4.47	Taxa de acerto por número de neurônios para os experimentos. . . . .	65
4.48	Taxa de acerto por número de neurônios para os experimentos. . . . .	66
4.49	Desempenho x tempo x número de neurônios. . . . .	67

# Lista de Tabelas

3.1 Tamanho da janela . . . . .	25
3.2 Classes de saída da RNRE de classificação . . . . .	30
3.3 Classes de saída da RNRE de identificação . . . . .	31
4.1 Parâmetros das coletas do experimento 1 . . . . .	35
4.2 Parâmetros das coletas do experimento 2 . . . . .	45
4.3 Parâmetros das coletas do experimento 3 . . . . .	54
4.4 Parâmetros das coletas do experimento 4 . . . . .	62
4.5 Número de oportunidades com 85% de confiabilidade . . . . .	67
4.6 Confiabilidade para 10 oportunidades . . . . .	67

# Lista de Abreviaturas e Siglas

**ACK** *Acknowledgement*.

**ADC** Conversor Analógico-Digital (do Inglês, *Analog-to-Digital Converter*).

**ANATEL** Agência Nacional de Telecomunicação.

**COMNET** Laboratório de Redes de Computadores.

**CSMA/CA** Acesso Múltiplo com Detecção de Portadora Evitando Colisões (do Inglês, *Carrier Sense Multiple Access/Collision Avoidance*).

**DIFS** Espaço Distribuído entre Quadros (do Inglês, *Distributed Interframe Space*).

**DSA** Acesso Dinâmico ao Espectro (do Inglês, *Dynamic Spectrum Allocation*).

**FFT** Transformada Rápida de Fourier (do Inglês, *Fast Fourier Transform*).

**FPGA** *Field-Programmable Gate Array*.

**FSM** Máquina de Estados Finitos (do Inglês, *Finite State Machine*).

**GPL** Licença Pública Geral (do Inglês, *General Public License*).

**HAM** Modelo de Acesso Hierárquico (do Inglês, *Hierarchical Access Model*).

**IF** Frequência Intermediária (do Inglês, *Intermediate Frequency*).

**ISM** Industrial, Científico e Médico (do Inglês, *Industry, Scientific and Medical Band*).

**MLP** Rede *Perceptron* Multicamada (do Inglês, *Multilayer Perceptron*).

**RLA** Realimentação Local de Ativação.

**RLO** Realimentação Local de Saída.

**RLS** Recorrência Local de Sinapse.

**RNA** Rede Neural Artificial.

**RNLR** Rede Neural Localmente Recorrente.

**RNPR** Rede Neural Parcialmente Recorrente.

**RNR** Rede Neural Recorrente.

**RNRE** Rede Neural Recorrente de Elman.

**RNTR** Rede Neural Totalmente Recorrente.

**SDR** Rádio Definido por *Software* (do Inglês, *Software Defined Radio*).

**SIFS** Espaço Curto entre Quadros (do Inglês, *Short Interframe Space*).

**SNR** Razão Sinal-Ruído (do Inglês, *Signal-to-noise ratio*).

**SSA** Alocação Estática do Espectro (do Inglês, *Static Spectrum Allocation*).

**SSID** Identificador do Conjunto de Serviço (do Inglês, *Service Set Identifier*).

**TEF** Transdutor de Estados Finito (do Inglês, *Finite State Transducer*).

**UDP** Protocolo de Datagrama de Usuário (do Inglês, *User Datagram Protocol*).

**UIT** União Internacional de Telecomunicação (do Inglês, *International Telecommunication Union*).

**UnB** Universidade de Brasília.

**USRP** *Universal Software Radio Peripheral*.

**UWB** Banda Ultralarga (do Inglês, *Ultra Wideband*).

**WRC** Conferência Mundial de Radiocomunicações (do Inglês, *World Communication Conferences*).

# Capítulo 1

## Introdução

A demanda por acesso ubíquo inspirou a criação de tecnologias de comunicação por radiofrequência para trafegar informação entre dispositivos sem fio. A evolução destas tecnologias, movida pelo seu crescente uso, expandiu suas aplicações e conseqüentemente amplificou a ocupação do espectro eletromagnético, que é um recurso finito. A política de alocação do espectro vigente é a Alocação Estática do Espectro (do Inglês, *Static Spectrum Allocation*) (SSA) [2], na qual cada faixa de frequência é alocada para uma aplicação específica. Nesta política as faixas de radiofrequência são classificadas como licenciadas, nas quais os usuários devem possuir licença para utilizá-las, e não-licenciadas, nas quais não é necessário licença.

Um problema decorrente do modelo SSA é a ocupação das faixas não uniformemente distribuída, levando à subutilização do espectro. Em geral, as faixas não-licenciadas apresentam um nível de ocupação mais alto que as faixas licenciadas [3, 4]. Este fato motivou a proposição da política Acesso Dinâmico ao Espectro (do Inglês, *Dynamic Spectrum Allocation*) (DSA), um modelo que consiste na exploração dos períodos de inatividade dos usuários que detém licença para transmissão em faixas licenciadas (usuários primários). O DSA propõe que os usuários secundários (que não possuem licença para transmissão) forneçam meios de evitar colisões com os usuários primários, aumentando assim a eficiência do uso do espectro.

Um desafio na implementação do DSA é a previsão do comportamento do usuário primário. Este trabalho trata da classificação e previsão do comportamento do usuário primário na faixa licenciada sensoriada utilizando redes neurais recorrentes. A Seção 1.1 apresenta os principais objetivos do trabalho, a Seção 1.2 descreve a metodologia aplicada para que os objetivos fossem alcançados e a Seção 1.3 é uma referência para a estrutura do documento.

## 1.1 Objetivos

O objetivo deste trabalho é a proposição de uma metodologia de previsão de oportunidades de transmissão em redes sem fio utilizando redes neurais recorrentes. Objetivos específicos incluem a definição de uma metodologia de aquisição de sinais a partir do rádio definido por *software*, a caracterização do tráfego pelas redes neurais treinadas e a definição das configurações dos ambientes de teste e validação dos experimentos.

## 1.2 Metodologia

A metodologia adotada neste trabalho consiste dos seguintes passos:

1. **Estudos em Redes Neurais.** Este projeto se apoia fortemente na utilização de redes neurais, portanto o primeiro passo é a aprendizagem dos seus fundamentos. Além dos conceitos teóricos, pretende-se realizar um estudo sobre o MATLAB e o *Neural Network Toolbox* [5] tendo em vista que ele incorpora um conjunto de redes neurais implementadas com amplo suporte.
2. **Revisão do Estado da Arte.** Consiste em um levantamento do que tem sido publicado na área de sensoriamento do espectro por energia, e utilização de aprendizado de máquina para caracterizar o comportamento do usuário primário e estimar oportunidades de previsão.
3. **Aquisição e processamento dos sinais.** Este processo inclui o planejamento dos ambientes de aquisição, a utilização de Rádio Definido por *Software* (do Inglês, *Software Defined Radio*) (SDR) para capturar efetivamente os sinais, e o processamento e dimensionamento dos dados coletados.
4. **Treinamento das redes neurais.** Esta etapa consiste na seleção de um conjunto de treino e estudo das relações de taxa de acerto e tempo de treinamento para definição de uma configuração ótima para as redes neurais artificiais, que influenciam na generalidade e especialização do sistema.
5. **Construção dos modelos estatísticos.** Os modelos estatísticos construídos são utilizados para estimar a probabilidade de ocorrência de oportunidade em um dado instante.
6. **Validação dos resultados.** Os resultados obtidos nas baterias de teste executadas são analisados com maior profundidade, com o objetivo de mensurar o desempenho do sistema e identificar os pontos que podem ser melhorados.

## 1.3 Estrutura do Documento

Este documento é composto por 5 capítulos, incluindo este. A estrutura dos capítulos restantes desta monografia é descrita a seguir.

- O Capítulo 2 contém uma síntese da fundamentação teórica necessária para compreensão do trabalho desenvolvido. Mais precisamente, este capítulo descreve sobre as técnicas de sensoriamento do espectro, funcionamento, topologia e treinamento de redes neurais artificiais, com destaque à rede de Elman [6], utilizada no trabalho.
- O Capítulo 3 enumera os passos da metodologia proposta para previsão de oportunidades em redes dinâmicas.
- O Capítulo 4 apresenta as configurações dos experimentos e resultados obtidos para validar a metodologia proposta.
- O Capítulo 5 traz as considerações finais deste projeto, apontando as contribuições para a área de sensoriamento do espectro por energia. Além disso, indica quais serão os próximos trabalhos para melhorar e expandir os resultados obtidos.

# Capítulo 2

## Revisão Teórica

Este capítulo discorre sobre os principais métodos de sensoriamento do espectro, além de técnicas utilizadas para aumentar sua eficiência, como aprendizado de máquina. A Seção 2.1 introduz os modelos de alocação do espectro, Seção 2.2 provê uma explicação das técnicas utilizadas no trabalho para detecção de transmissão/ociosidade no canal e a Seção 2.3 detalha o protocolo de comunicação utilizado nos experimentos. A Seção 2.4 revisa os conceitos básicos de redes neurais artificiais e as estruturas utilizadas para caracterizar o meio de transmissão sensoriado. A Seção 2.5 apresenta um levantamento do estado da arte, e uma breve comparação com o presente trabalho.

### 2.1 Alocação do Espectro

A atual política de alocação do espectro segue o modelo de Alocação Estática do Espectro (do Inglês, *Static Spectrum Allocation*) (SSA) [7]. Nesse modelo, o espectro eletromagnético é subdividido em faixas, destinadas a diversas aplicações distintas, como serviço de emergência, televisão e rádio. As faixas podem ser classificadas em licenciadas, nas quais usuários devem ter licença para utilizar, e não-licenciadas, nas quais não é necessário licença para utilização.

A União Internacional de Telecomunicação (do Inglês, *International Telecommunication Union*) (UIT) é o órgão vinculado à Organização das Nações Unidas (ONU) responsável por coordenar o uso compartilhado do espectro de rádio. A UIT organiza conferências responsáveis por discutir assuntos relacionados a tecnologias de comunicação, dentre elas a Conferência Mundial de Radiocomunicações (do Inglês, *World Communication Conferences*) (WRC), na qual representantes de cada país se encontram para discutir e revisar a política de alocação do espectro. O órgão que representa o Brasil e regulamenta a ocupação do espectro é a Agência Nacional de Telecomunicação (ANATEL), segundo o

inciso VIII do artigo 19 da lei de número 9472 de 1997 da legislação da ANATEL [2]. A distribuição das faixas no Brasil é mostrada no Anexo I.

O espectro eletromagnético é um recurso finito [8, 9, 2], logo é possível que o uso sobrecarregado acarrete o congestionamento das faixas. Esta possibilidade motivou trabalhos como os de Čabrić *et al.* [3], que realizaram uma medição do nível de ocupação do espectro em Berkley, e Mubaraq *et al.* [4], que mensuraram a ocupação em Chicago e Nova York. As Figuras 2.1 e 2.2 ilustram estas medições, respectivamente.

A Figura 2.1 mostra no eixo horizontal a frequência em MHz, e no eixo vertical o nível de ocupação correspondente, em dB. A distribuição apresentada contém faixas ociosas, por exemplo entre 4MHz e 5MHz, enquanto as faixas entre 0MHz e 1MHz encontram-se congestionadas. A diferença no nível de ocupação entre uma faixa e outra chega a mais de 50dB, o que evidencia a ineficiência do uso do espectro.

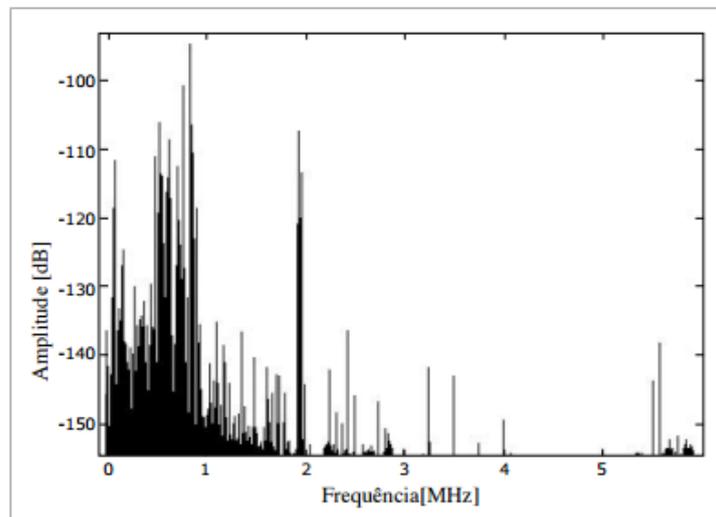


Figura 2.1: Ocupação do espectro em Berkley (Fonte: [3]).

A Figura 2.2 mostra no eixo horizontal a frequência em MHz e no eixo vertical a porcentagem de ocupação correspondente. As barras em azul e vermelho representam, respectivamente, as medições nas cidades de Chicago e Nova York. Assim como na Figura 2.1, é notável a alta variação da ocupação do espectro pela frequência. A ocupação da faixa entre 226MHz e 406MHz em Nova York é mais de 75% maior que a ocupação da faixa entre 174MHz e 216MHz.

Nas Figuras 2.1 e 2.2 é observado o fenômeno conhecido como Escassez do Espectro (do Inglês, *Spectrum Scarcity*) [10] em algumas faixas. De modo geral, as faixas não licenciadas têm ocupação muito superior às licenciadas. Isto ocorre porque modelos SSA não consideram a distribuição da utilização das faixas, e por isso a escassez do espectro é artificial [11, 12].

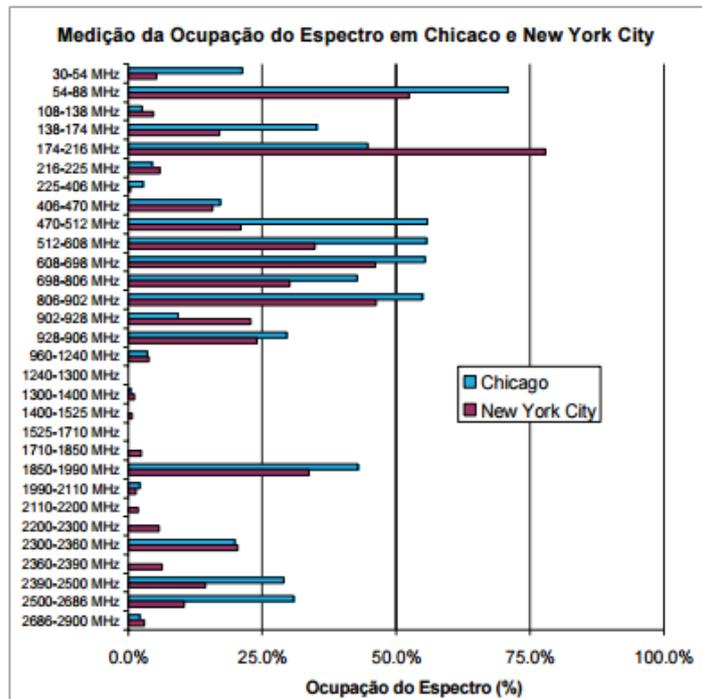


Figura 2.2: Ocupação do espectro em Chicago e Nova York (Fonte: [4]).

A problemática da ineficiência do SSA inspirou trabalhos com o objetivo de otimizar a utilização do espectro. Neste contexto, surgiu o Acesso Dinâmico ao Espectro (do Inglês, *Dynamic Spectrum Allocation*) (DSA) [13]. Dentre as categorias de DSA, o mais compatível com o SSA é o Modelo de Acesso Hierárquico (do Inglês, *Hierarchical Access Model*) (HAM), no qual o espectro licenciado é compartilhado com usuários secundários a partir de mecanismos que limitam a interferência percebida pelo usuário primário. O HAM possui duas abordagens de compartilhamento do espectro: *Spectrum Underlay* e *Spectrum Overlay*.

O *Spectrum Underlay* define restrições à potência de transmissão do usuário secundário, para que esteja abaixo do nível de ruído do usuário primário. A utilização de banda Banda Ultralarga (do Inglês, *Ultra Wideband*) (UWB) permite transmissões em níveis baixos de potência a uma distância curta. Esta abordagem é igualmente eficaz em cenários nos quais os usuários primários têm taxa de transmissão alta e constante.

O *Spectrum Overlay* baseia-se na ideia da identificação e exploração de períodos de ociosidade pelo usuário secundário, aqui definido como “oportunidade” de transmissão, que deve prover mecanismos para garantir que sua comunicação tenha interferência mínima com o usuário primário. Esta abordagem tem a desvantagem de ser dependente da característica de transmissão do usuário primário, ao contrário do *Spectrum Underlay*. Por outro lado, pode-se destacar a vantagem da não restrição da potência de transmissão.

Uma etapa essencial para implementação da abordagem de *Spectrum Overlay* é o sensoriamento do espectro, processo pelo qual o sistema coleta informações sobre o canal de interesse. A próxima seção introduz técnicas e ferramentas para sensoriamento do espectro e processamento dos sinais coletados.

## 2.2 Sensoriamento do Espectro

Sensoriamento do espectro é o conjunto de técnicas que permite capturar os sinais em um local geográfico e intervalo de tempo específicos, e processá-los com o objetivo de encontrar oportunidades de transmissão. Segundo Alom *et al.* [14], existem três principais categorias de detecção: por energia, filtro casado e cicloestacionária.

O método de detecção cicloestacionária explora a propriedade de periodicidade dos sinais, que surge por causa dos diferentes mecanismos utilizados em comunicações como modulação e codificação [15]. Este método funciona bem com relações sinal-ruído baixas, diferenciando o usuário primário do ruído, além de poder também diferenciar os tipos de transmissões presentes no canal.

A detecção por filtro casado maximiza a relação sinal-ruído no canal a partir de um conhecimento prévio sobre o usuário primário, como tipo de modulação ou a forma do sinal [16]. Segundo Yucek *et al.* [17], este é o método com maior taxa de acerto, e menor tempo de execução, mas com o custo da necessidade do conhecimento de características do usuário primário como principal desvantagem.

O método de detecção por energia baseia-se na leitura do sinal recebido para determinar a presença ou ausência do usuário primário. Segundo Medina *et al.* [18], o sinal adquirido pode ser descrito por

$$z(t) = s(t) + r(t) \quad (2.1)$$

em que  $z(t)$  é o vetor sinal recebido,  $s(t)$  é o vetor sinal do usuário primário e  $r(t)$  é o vetor ruído, que pode ter sido ocasionado por multipercurso, interferência de canais adjacentes e interferência co-canal, entre outros fatores.

O usuário secundário não tem informações sobre  $s(t)$  nem sobre  $r(t)$ , e deve determinar em um dado instante  $t$  se a energia de  $s(t)$  é igual a zero, isto é, se o usuário primário está ocupando o canal, ou se o sinal recebido representa apenas ruído. A energia de um sinal, segundo Bhagwandas [19], pode ser definida por

$$E_x = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (2.2)$$

sendo  $x(t)$  um sinal contínuo no tempo  $t$ , e  $E_x$  sua energia. Para um sinal  $z(t) = I(t) + i.Q(t)$ , sendo  $I(t)$  e  $Q(t)$  suas componentes ortogonais, em um intervalo  $[t_1, t_2]$ , então

$$E_z = E_i + E_q \quad (2.3)$$

onde  $E_z$ ,  $E_i$  e  $E_q$  são energias dos sinais  $z(t)$ ,  $I(t)$  e  $Q(t)$  respectivamente. Das Equações (2.2) e (2.3), temos que em um intervalo  $[t_1, t_2]$ , a energia de um sinal com componentes ortogonais pode ser expressa por

$$E_z = \int_{t_1}^{t_2} |I(t)|^2 dt + \int_{t_1}^{t_2} |Q(t)|^2 dt \quad (2.4)$$

Para sinais discretos, a Equação (2.4) pode ser escrita como

$$E_z = \sum_{j=1}^N I(j)^2 + Q(j)^2, \quad (2.5)$$

em que  $j$  é o número da amostra no domínio tempo,  $N$  é a quantidade de amostras no intervalo,  $I$  e  $Q$  são componentes ortogonais do sinal  $z(t)$  e  $E_z$  sua energia. No método de sensoriamento do espectro por energia, um valor  $\lambda$  denominado limiar é definido, e comparado com a energia  $E_z$  no canal. Se  $E_z \geq \lambda$ , considera-se que o sinal do usuário primário está presente no canal. O caso contrário indica a ausência do sinal do usuário primário na amostra  $j$ .

Em alguns cenários, a interferência de canais adjacentes pode fazer com que o sistema de sensoriamento conclua equivocadamente que o usuário primário está presente no canal, o que leva a subutilização do espectro. Para minimizar este efeito, pode-se filtrar o sinal recebido no processo de aquisição.

Neste trabalho, aquisição do sinal e demodulação de suas componentes em fase e em quadratura é feita por Rádio Definido por *Software* (do Inglês, *Software Defined Radio*) (SDR). A capacidade de reconfiguração dos parâmetros do rádio, como potência, frequência e modulação, com base no sensoriamento do ambiente em que se encontra foi primeiramente idealizado por Mitola [20]. Esta concepção básica possibilitou o desenvolvimento dos SDRs, ferramentas fundamentais para a implementação de redes oportunistas.

Em geral um SDR é composto por dois blocos, representados na Figura 2.3. O bloco de *hardware* possui uma antena que capta os sinais eletromagnéticos de uma fonte, e entrega para o módulo de radiofrequência, onde o sinal é convertido para uma Frequência Intermediária (do Inglês, *Intermediate Frequency*) (IF). O Conversor Analógico-Digital (do Inglês, *Analog-to-Digital Converter*) (ADC) transforma o sinal analógico em amostras digitais a uma determinada taxa de amostragem, e o módulo de *software* é responsável por processar o sinal digitalizado, realizando sua demodulação conforme fora programado.

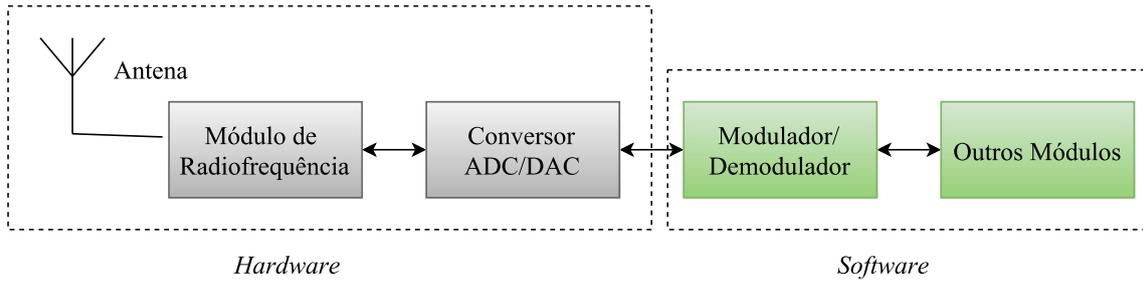


Figura 2.3: Diagrama de blocos de um rádio definido por *software*.

Neste trabalho, por limitações do SDR e também por questões regulatórias, será utilizado a faixa Industrial, Científico e Médico (do Inglês, *Industry, Scientific and Medical Band*) (ISM), de 2.4GHz, na qual o protocolo IEEE802.11 (Wi-Fi) opera.

## 2.3 IEEE 802.11

O padrão IEEE 802.11 define o protocolo de acesso para redes locais (LAN) sem fios. Esse padrão utiliza a banda de frequência reservada internacionalmente para o ISM, que compreende o intervalo de frequência de 2,4GHz a 2,5GHz. Esta faixa é subdividida em 14 canais, cada canal com uma banda de 22MHz. A Figura 2.4 ilustra esta divisão, representando cada canal como um semicírculo, numerados de 1 a 14.

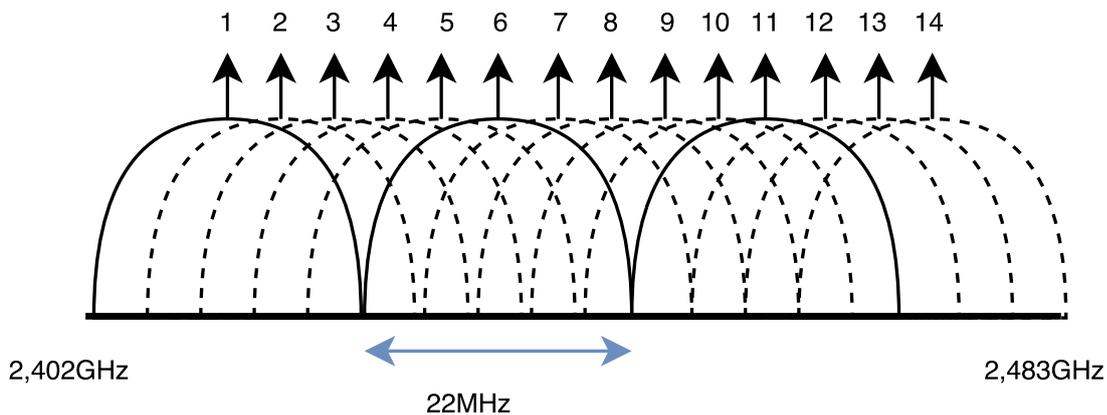


Figura 2.4: Canais no padrão IEEE 802.11.

As bandas dos canais não são completamente isoladas, ou seja, canais adjacentes apresentam certo nível de sobreposição espectral, o que pode causar nas redes IEEE

802.11 problemas de interferências. O canal 13, por exemplo, sofre influências dos canais 9,10,11,12 e 14.

O padrão IEEE 802.11 utiliza o Acesso Múltiplo com Detecção de Portadora Evitando Colisões (do Inglês, *Carrier Sense Multiple Access/Collision Avoidance*) (CSMA/CA) [21] como protocolo de camada de acesso ao meio. O objetivo deste protocolo é evitar possíveis colisões a partir da monitoração da atividade no canal. Este protocolo define o seguinte comportamento para transmissões: a estação espera por um período de tempo Espaço Distribuído entre Quadros (do Inglês, *Distributed Interframe Space*) (DIFS), gera um valor aleatório, denominado *backoff*, e decrementa este valor enquanto o canal estiver ocioso. Quando valor é decrementado até zero, a estação transmite um quadro de dados (Dado).

Após a transmissão de um quadro de dados, o nó transmissor espera por um intervalo de tempo denominado Espaço Curto entre Quadros (do Inglês, *Short Interframe Space*) (SIFS). Este é o tempo máximo definido para recebimento de um quadro de confirmação, denominado *Acknowledgement* (ACK). Caso o quadro de confirmação não seja recebido, o nó transmissor reagenda a transmissão após uma janela de *backoff*. Esta sequência é ilustrada na Figura 2.5, na qual o quadro de dados é expresso em vermelho, o SIFS é expresso em azul e o ACK em amarelo.



Figura 2.5: Diagrama de diálogo CSMA/CA.

Um exemplo do tráfego de comunicação conforme o modelo CSMA/CA é ilustrado na Figura 2.6, que representa os sinais de fase (linha tracejada) e quadratura (linha contínua). No intervalo de tempo entre 3,697 e 3,698 segundos, há um ciclo de transmissão Dado-SIFS-Ack, no qual o Dado é caracterizado pelo segmento de amplitude aproximadamente  $1,5 \times 10^{-3}$  e o Ack é caracterizado pela amplitude  $5 \times 10^{-3}$ . No intervalo de 3,7002 a 3,7011 segundos há um exemplo de *Beacon*, caracterizado por uma amplitude de aproximadamente  $2 \times 10^{-3}$ .

*Beacons* são quadros de gerenciamento utilizados por dispositivos neste padrão [22]. Estes quadros são transmitidos periodicamente para confirmar sua presença na rede. A periodicidade de transmissão do *Beacon* é configurável, tendo seu tempo padrão de 100ms.

O padrão CSMA/CA pode ser modelado a partir de um Transdutor de Estados Finito (do Inglês, *Finite State Transducer*) (TEF). Um TEF é definido como uma 6-upla  $A = (\Sigma, \Gamma, \delta, Q, q_0, \omega)$ , na qual:

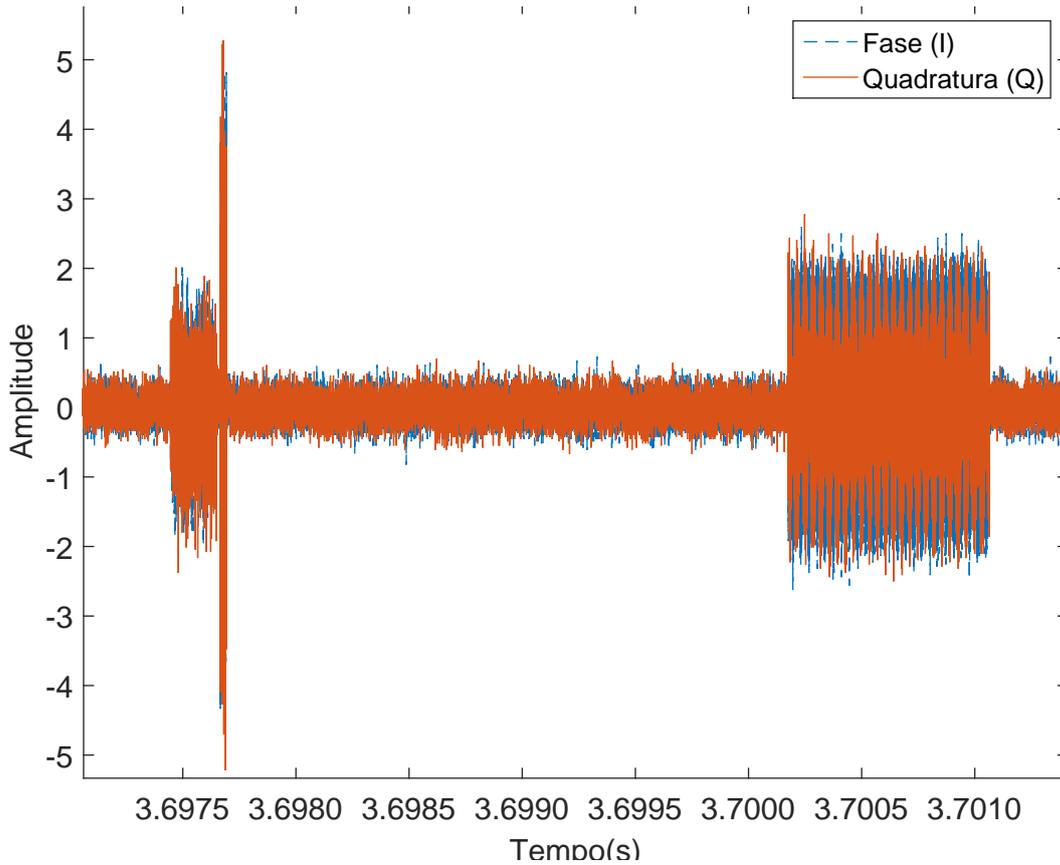


Figura 2.6: Exemplo de ciclo de transmissão e *Beacon*.

1.  $\Sigma$  é um conjunto finito denominado alfabeto
2.  $\Gamma$  é um conjunto finito denominado alfabeto de saída
3.  $Q$  é conjunto finito de estados
4.  $\delta : Q \times \Sigma \rightarrow Q$  é a função de transição
5.  $q_0 \in Q$  é o estado inicial
6.  $\omega : Q \times \Sigma \rightarrow \Gamma$  é a função de saída

A Figura 2.7 ilustra o TEF que modela transmissões no padrão CSMA/CA. Cada círculo na figura indica um estado  $q_i \in Q$ , as setas indicam uma transição da função de transição  $\delta$  e as cores representam a saída  $\gamma_i \in \Gamma$ . Todas as transições não explicitadas voltam para o estado inicial  $q_0$ . O alfabeto é estruturado com  $\Sigma = \{0,1\}$ , sendo que 0 representa ausência de um usuário no canal e 1 representa presença de um usuário. Uma cadeia de entrada inicial de composta por uns, por exemplo, pode ser classificada como Dado a partir do estado  $q_d$ , representado pela cor vermelha sendo d o comprimento

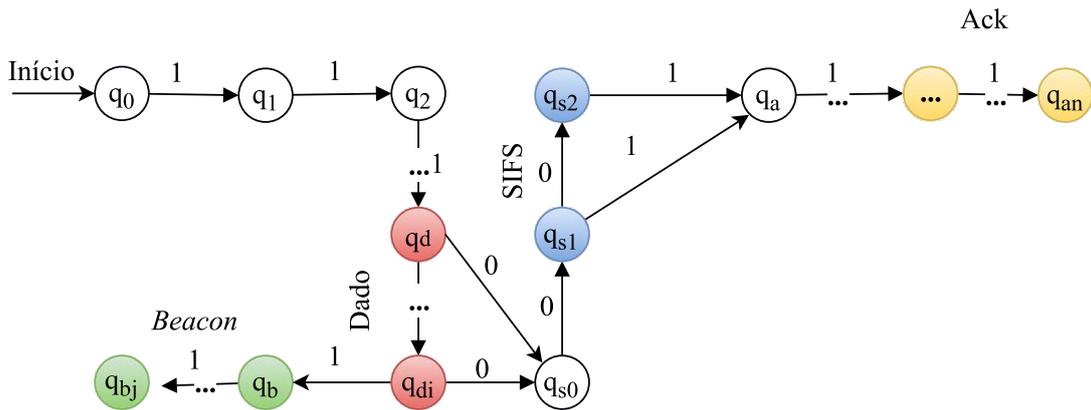


Figura 2.7: Diagrama de estados do CSMA/CA.

mínimo do Dado, e pode ser classificada como *Beacon*, a partir do estado  $q_b$ , representado pela cor verde.

Este trabalho modela os sinais a partir de redes neurais, estruturas que têm a capacidade de se adaptar ao ambiente sensoriado, cujos conceitos são explanados na próxima Seção.

## 2.4 Redes Neurais Artificiais

A capacidade de aprendizagem do cérebro humano antagoniza com o paradigma algorítmico sobre o qual as bases da computação foram desenvolvidas. O surgimento de uma tecnologia que pudesse aprender a partir de exemplos, e modificar a própria estrutura de forma a se adaptar, tornou-se um objetivo em comum de pesquisadores de áreas como química, física, biologia e computação. Neste contexto, surgiu a Rede Neural Artificial (RNA). Segundo Braga [23], RNAs são sistemas paralelos distribuídos compostos por unidades de processamento simples que realizam determinadas funções matemáticas, normalmente não-lineares.

A aplicabilidade de RNAs é muito ampla, pois esta tecnologia pode ser utilizada para classificação, ajuste de dados, reconhecimento de padrões e processamento de séries temporais. Exemplos de aplicações são simulação de voos, reconhecimento de voz, previsão de ações, projeto de próteses, compressão de voz e tradução de idiomas. O poder de processamento das RNAs foi motivação para diversos trabalhos que contribuíram para a evolução dos conceitos e técnicas na área. A próxima Seção trata particularmente do neurônio, unidade de processamento das RNAs.

### 2.4.1 Neurônio

Um neurônio artificial é um modelo matemático primeiramente proposto por McCulloch e Pitts [24], que tenta representar de maneira simplificada o conhecimento que se tinha sobre redes neurais biológicas à época. A Figura 2.8 apresenta este modelo matemático, no qual os sinais de entrada são  $x_1, x_2, \dots, x_n$ , os pesos das conexões sinápticas são representados por  $w_1, w_2, \dots, w_n$ , o *bias* é representado por  $b$ ,  $\Sigma$  o somatório e  $\Phi$  a função de ativação.

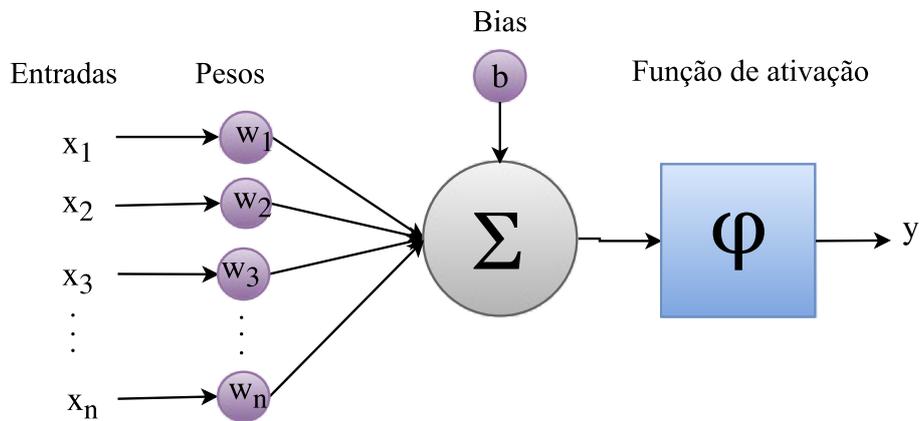


Figura 2.8: Modelo matemático de um neurônio artificial.

A saída  $y$  do neurônio a partir do modelo ilustrado na Figura 2.8 pode ser calculada por

$$y = \varphi \left( \sum_{i=1}^n x_i w_i + b \right) \quad (2.6)$$

A função de ativação  $\varphi$  tem, tipicamente, o papel de limitar a amplitude da saída do neurônio a um intervalo limitado como  $[0,1]$  ou  $[-1,1]$ . A Figura 2.9 ilustra alguns exemplos de funções de ativação: a função segmentalmente linear (linha contínua), expressa pela Equação 2.7, a função degrau (tracejada), expressa pela Equação 2.8, sigmoide (pontilhada), expressa pela Equação 2.9 e tangente hiperbólica (traços e pontos alternados), expressa pela Equação 2.10.

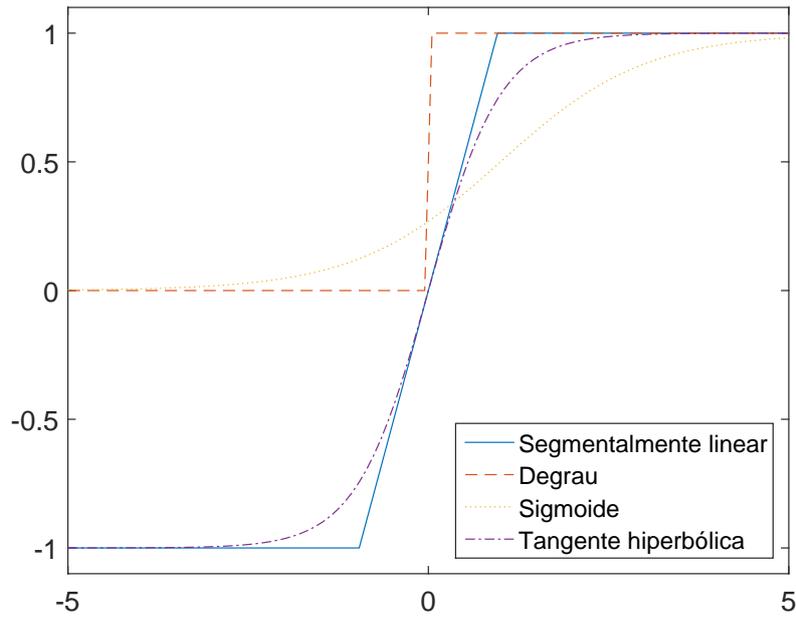


Figura 2.9: Exemplos de funções de ativação.

$$f(x) = \begin{cases} -1, & x < -1 \\ x, & -1 \leq x \leq 1 \\ 1, & x > 1 \end{cases} \quad (2.7)$$

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (2.8)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.9)$$

$$f(x) = \tanh(x) \quad (2.10)$$

Os neurônios artificiais podem se interconectar para compor estruturas de RNAs, que são elencadas a seguir.

## 2.4.2 Estrutura de Redes Neurais

A estrutura, ou arquitetura de uma RNA, é a forma com a qual os neurônios estão conectados na rede neural, o que influencia diretamente na sua capacidade de aprendizagem. As redes neurais podem ser divididas em duas categorias: direta e recorrente.

Redes neurais diretas (do Inglês, *feedforward*) são RNAs em que o sinal se propaga apenas em uma direção. Uma estrutura muito utilizada é a Rede *Perceptron* Multicamada (do Inglês, *Multilayer Perceptron*) (MLP), composta por uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) e uma camada de saída. A MLP é totalmente conectada a nível de camadas, o que significa que todos os neurônios de cada camada tem conexão com todos os neurônios das camadas adjacentes.

A Figura 2.10 apresenta uma rede MLP com três neurônios na camada de entrada, quatro neurônios na camada escondida e dois neurônios na camada de saída.

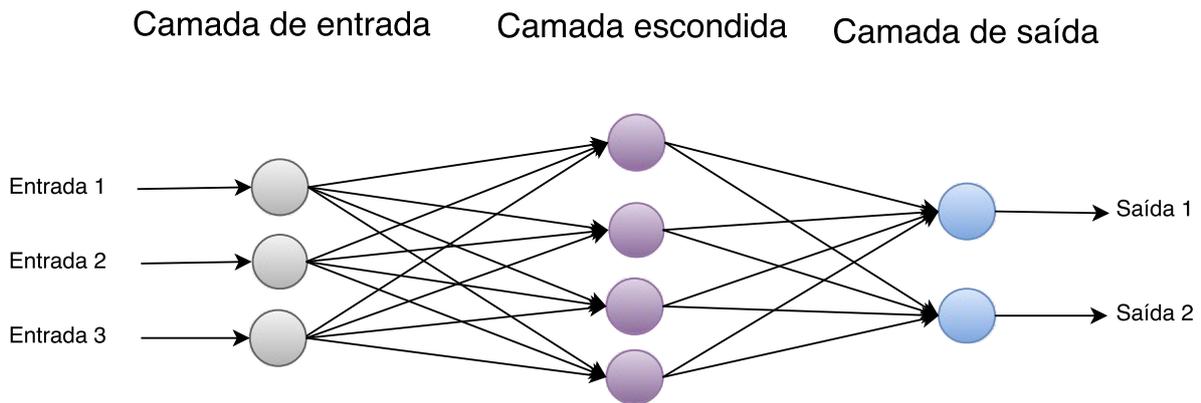


Figura 2.10: Estrutura de uma rede MLP  $3 \times 4 \times 2$ .

O número de neurônios de entrada depende da dimensão do sinal de entrada, e analogamente o mesmo com a saída. O número de neurônios na camada escondida depende da complexidade do problema. Em geral, quanto maior a complexidade do problema, maior deve ser o número de neurônios na camada escondida.

O número de camadas escondidas também é um fator a ser levado em consideração. RNAs simples, que não apresentam camadas intermediárias, por exemplo, resolvem apenas funções linearmente separáveis, segundo Minsky *et al.* [25]. Redes neurais com uma camada intermediária podem implementar qualquer função contínua [26], e redes com duas ou mais camadas intermediárias permitem a implementação de qualquer função [27].

Rede Neural Recorrente (RNR) é uma RNA na qual existe realimentação, isto é, a propagação do sinal não se dá apenas em uma direção. Pode-se classificar RNRs em três categorias, enumeradas a seguir.

1. **Rede Neural Localmente Recorrente (RNLR):** a realimentação é implementada na própria estrutura do neurônio. Isto é, conexões recorrentes são adicionadas ao modelo não recorrente do neurônio apresentado na Figura 2.8. Estas conexões podem ser implementadas em três etapas. A Recorrência Local de Sinapse (RLS), introduzida por Lapedes e Farbes [28], consiste na substituição dos pesos fixos das

sinapses por funções de transferência lineares. A Realimentação Local de Ativação (RLA) e a Realimentação Local de Saída (RLO) são implementadas, respectivamente, pela realimentação do sinal da função de ativação e do sinal de saída, conforme apresentado na Figura 2.11.

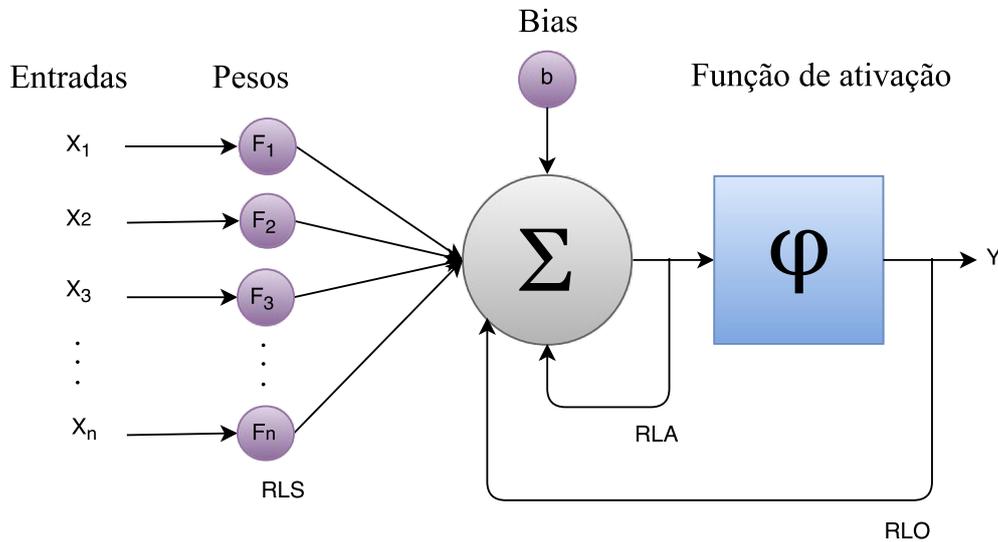


Figura 2.11: Modelo de um neurônio recorrente.

2. **Rede Neural Totalmente Recorrente (RNTR):** aquelas nas quais cada neurônio recebe a saída de todos os outros neurônios. Um exemplo conhecido que utiliza esta estrutura é o modelo proposto por Tank e Hopfield [29]. Os autores propuseram uma estrutura na qual não há realimentação de cada neurônio para ele mesmo, e um conjunto de atrasos unitários. A rede de Hopfield segue o paradigma de manipulação dos atratores, e implementa minimização de energia para solucionar problemas. De acordo com Haykin e Engel [30], pode ser utilizada como memória endereçada por conteúdo ou para resolver problemas de otimização do tipo combinatório. O treinamento de RNTRs ainda é um desafio, pela complexidade da associação de pesos e dificuldade de se garantir sua estabilidade.
3. **Rede Neural Parcialmente Recorrente (RNPR):** são RNRs em que existe realimentação, mas não para todos os neurônios. Um exemplo de importância histórica é a rede proposta por Jordan [31], na qual só existem conexões recorrentes da camada de saída para a camada escondida, a partir de uma camada denominada camada de contexto.

A Figura 2.12 ilustra essa estrutura, na qual o neurônio  $h_{m+i}$  da camada de contexto, representada pelos círculos brancos, recebe o sinal de saída do  $i$ -ésimo neurônio da

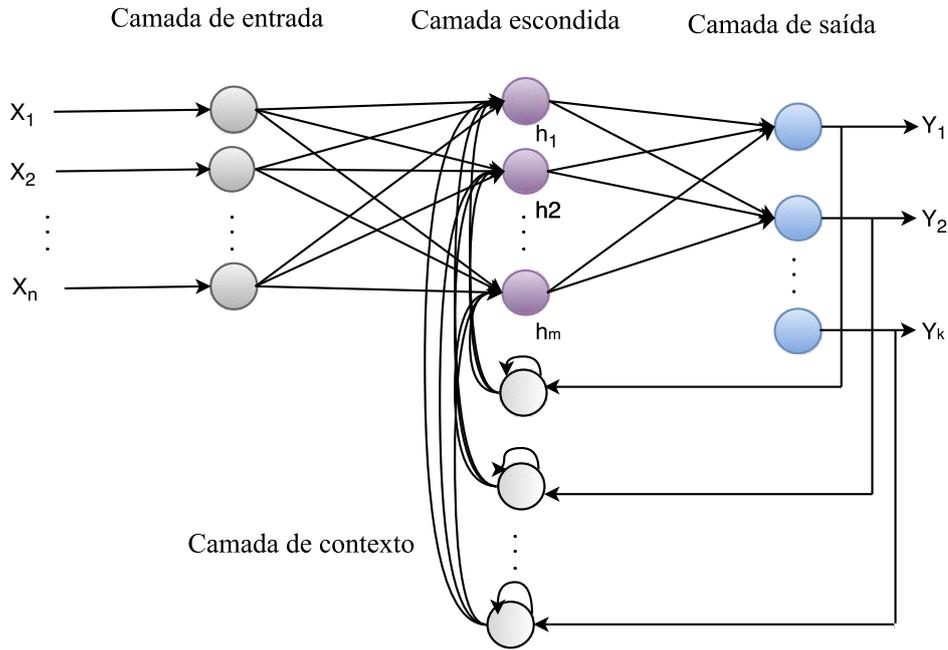


Figura 2.12: Estrutura da RNPR de Jordan.

camada de saída, representada pelos círculos de cor azul. Além disso, existe auto-alimentação em todos os neurônios da camada de contexto. Desta forma, a camada de contexto preserva informações de saídas anteriores.

### 2.4.3 Rede de Elman

Proposta em 1990 por Elman [6], a RNRE é ilustrada no modelo da Figura 2.13. A camada de contexto, representada abaixo pela cor branca, funciona como uma memória, armazenando a saída dos neurônios da camada escondida para uso no instante de tempo seguinte. Para este efeito, as funções de ativação destes neurônios são lineares e os pesos das conexões sinápticas da camada escondida para a camada de contexto são fixadas em 1.

O vetor saída  $Y(t)$  da RNRE em um instante  $t$  é descrito por

$$Y(t) = \Phi(W_o \cdot H(t) + B_o), \quad (2.11)$$

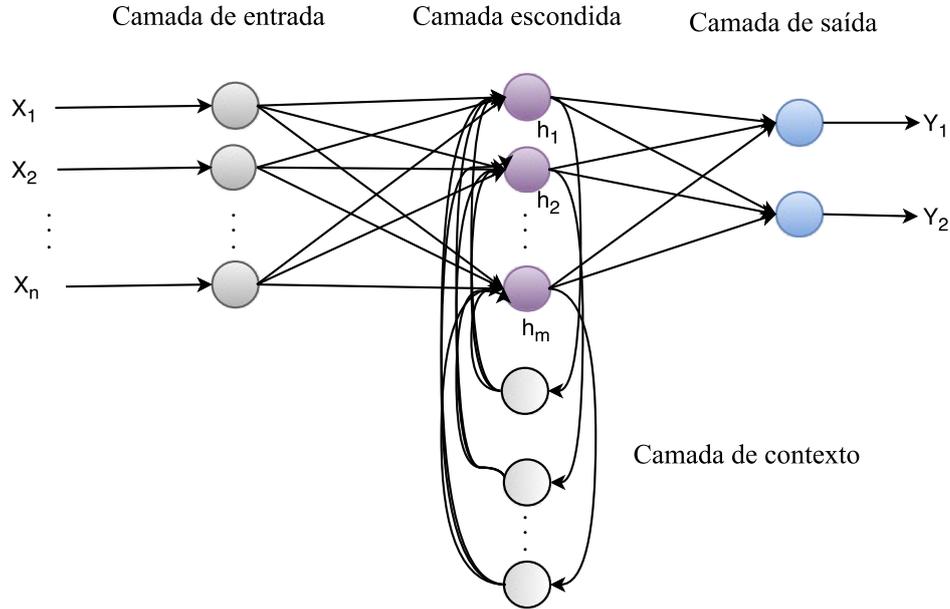


Figura 2.13: Estrutura da RNRE.

em que  $W_o$  é a matriz de peso da camada escondida para a camada de saída,  $B_o$  é o vetor de *bias* dos neurônios de saída e a saída dos neurônios da camada escondida podem ser calculado através de

$$H(t) = \Phi(W_i \cdot X(t) + W_c \cdot H(t-1) + B_h), \quad (2.12)$$

sendo  $X(t) = x_1(t), x_2(t), \dots, x_n(t)$  o vetor entrada no instante de tempo  $t$ ,  $W_i$  a matriz de pesos da camada de entrada para a camada escondida,  $B_h$  o vetor de *bias* dos neurônios escondidos e  $W_c$  a matriz de pesos da camada de contexto  $H(t-1)$  para a camada escondida.

A simplicidade e restritividade da estrutura da RNRE lhe dá a característica de estabilidade, em oposição a RNTRs e algumas RNPRs. Além disso, como demonstrado por Kremer [32], a rede de Elman é poderosa suficiente para modelar qualquer problema que possa ser descrito por uma Máquina de Estados Finitos (do Inglês, *Finite State Machine*) (FSM).

A próxima seção trata do treinamento das RNAs, processo pelo qual os pesos das conexões sinápticas são ajustados para representar o conhecimento adquirido pelas redes neurais a partir dos estímulos apresentados a elas.

## 2.4.4 Treinamento

O treinamento de uma RNA é um processo iterativo de ajuste dos pesos, que representam o conhecimento adquirido pela rede. Este conhecimento pode ser utilizado para fazer interpolações e extrapolações dos exemplos apresentados. Os algoritmos de aprendizagem podem ser divididos em três categorias.

1. **Aprendizagem não-supervisionada:** a RNA recebe apenas a entrada, e a partir da redundância existente nos dados reconhece padrões a partir dos quais consegue agrupar/categorizar o conjunto de entrada.
2. **Aprendizagem supervisionada:** um supervisor monta um conjunto de vetores de exemplos com entradas (*input*) e saídas desejadas (*target*) para a RNA, e o objetivo é encontrar uma função que correlaciona estes pares *input-target*. A cada iteração do algoritmo de treino, a saída obtida pela rede é comparada com a saída desejada, e ajustes são feitos de forma a minimizar o erro. Estes ajustes incrementais devem convergir a uma solução, se houver. O treinamento supervisionado pode ser *offline* ou *online*. O treinamento *offline* ocorre com um conjunto de treino fixo, e uma vez concluído, a solução da RNA não se altera. O treinamento *online* se caracteriza pelo contínuo treinamento da rede em tempo de execução.
3. **Aprendizagem por reforço:** é um caso particular de aprendizado supervisionado no qual, ao invés de um supervisor fornecer um conjunto *target* com as saídas desejadas, é fornecido apenas a indicação se a saída obtida está certa ou errada. Além do reforço, pode ser fornecido como entrada também um mapeamento de ação a ser executada para cada estímulo.

O paradigma de treinamento adotado neste trabalho é supervisionado, a partir da utilização do algoritmo *backpropagation*. O *backpropagation* foi primeiramente proposto por Werbos [33] em 1974, embora não seja mencionado com este nome na tese. A ampla utilização deste algoritmo em RNAs ocorreu após a publicação do trabalho de Rumelhart *et al.* [34] em 1986. A ideia do algoritmo é iterar o vetor de entrada, calculando a função de ativação para cada neurônio e a partir do cálculo do erro na camada de saída, retropropagar ajustes de peso para aproximar a saída obtida da saída correta. Este processo se repete até o resultado convergir, ou até que alguma condição de parada seja satisfeita. Existem várias implementações de *backpropagation*, que diferem no ajuste dos pesos. O algoritmo *Levenberg Marquardt* [35, 36] em geral é o algoritmo de treino mais rápido, com a desvantagem de utilizar mais memória [37].

As RNAs neste trabalho são utilizadas para aprender informações sobre o usuário primário a partir do sensoriamento do espectro. Outros trabalhos já foram publicados nesta área, e serão descritos a seguir.

## 2.5 Revisão do Estado da Arte

A área de sensoriamento do espectro por energia e previsão de oportunidades vem sendo tratada em trabalhos com diferentes abordagens. Alguns destes trabalhos são destacados a seguir.

Elthoth [38] criou um modelo de previsão do espectro baseado no modelo autogressivo *Forward Backward* (FBAR) que utiliza séries binárias temporais, nas quais cada dígito é o estado de um canal em um instante. O autor afirma que a adoção deste método reduz a complexidade computacional da previsão de oportunidades.

Uma outra abordagem que vem sendo amplamente adotada é a utilização de redes neurais. Lan *et al.* [39] e Bai *et al.* [40] propõem otimizações ao algoritmo *backpropagation* através de algoritmos genéticos e *momentum*. Os resultados são uma melhora de 26% e 12,06%, respectivamente.

Além de alterações no algoritmo de treinamento, alguns trabalhos propõem a utilização de estruturas específicas de redes neurais. Huk *et al.* [41] adotaram redes neurais *Sigma-if*, cuja topologia é similar à MLP, com a diferença que há apenas uma camada escondida de neurônios com funções de agregação modificadas, chamados neurônios *Sigma-if*. A modificação da proposta reduziu o tamanho necessário do histórico do canal, cujo tráfego foi simulado a partir da distribuição de Poisson. Zhang *et al.* [42] utilizaram K-means para obter os centros dos neurônios da camada escondida e a função base das redes neurais RBF (k-RBF). Para simular o tráfego no canal, é utilizada *gold sequence*. Os autores afirmam que a utilização do K-means aumenta a probabilidade de previsão correta.

Elrharras *et al.* [43] propõem uma arquitetura híbrida que combina detecção por energia com redes neurais artificiais. Desta forma, a detecção por energia é realizada através de um limiar dinâmico, calculado pelas redes neurais. Os melhores resultados foram obtidos com redes neurais com 40 neurônios na camada escondida: a taxa de acerto para ociosidade foi de 0,97 e a taxa de acerto para presença do usuário primário foi de 0,83. Para baixos valores de Razão Sinal-Ruído (do Inglês, *Signal-to-noise ratio*) (SNR), o método proposto se destacou em relação à detecção de energia clássica: para SNR = -20, a diferença é de aproximadamente 0,9.

## 2.6 Discussão

Este capítulo introduziu os modelos de alocação do espectro estático e dinâmico. A partir destes fundamentos foram citadas as principais técnicas de sensoriamento do espectro, com destaque ao sensoriamento por energia.

Além disso, uma breve explicação sobre o protocolo IEEE 802.11 e o CSMA/CA e uma revisão teórica de redes neurais artificiais recorrentes foram colocadas para servir de subsídio para a compreensão dos experimentos realizados neste trabalho.

Por fim, uma revisão dos últimos trabalhos publicados nesta área foi exposta. Os trabalhos citados em geral utilizam séries binárias para representar o estado de múltiplos canais, cujo tráfego é simulado a partir de sequências ou distribuições conhecidas. Além disso, a estrutura do *MLP* vem sendo amplamente utilizada.

Todos os trabalhos analisados visam previsão de oportunidades em sinais gerados aleatoriamente ou de forma controlada. Este trabalho, por outro lado, propõe a aquisição do sinal através de uma coleta utilizando um SDR. A próxima Seção descreve a metodologia proposta, da aquisição dos sinais pelo SDR à previsão do número de oportunidades em um dado instante.

# Capítulo 3

## Metodologia de Previsão de Oportunidades

Este capítulo apresenta uma descrição da metodologia proposta para previsão de oportunidades de transmissão, que é composta por cinco etapas. As etapas da metodologia estão expostas na Figura 3.1. Na etapa 1 os sinais de fase e quadratura são coletados a partir de um SDR. A etapa 2 consiste na estimativa da função de energia dos sinais coletados. A função de energia é limiarizada na etapa 3 e analisada pelas redes neurais de Elman na etapa 4. A etapa 5 é a estimativa da probabilidade de oportunidades no canal, a partir do histórico de classificação das amostras do sinal de energia.

Estas etapas são executadas *offline*: o sinal é coletado e depois processado em cada uma das etapas. A implementação *online* do sistema, na qual todas as etapas são executadas em tempo real, não está no escopo deste trabalho.

As próximas seções detalham cada uma das etapas que compõem a metodologia, e elencam alguns parâmetros dos experimentos conduzidos para validá-la.

### 3.1 Etapa I - Aquisição

Nesta etapa, o SDR captura o sinal na frequência de interesse e obtém os sinais em fase ( $I$ ) e quadratura ( $Q$ ) a uma determinada frequência de amostragem. A frequência de amostragem é um parâmetro fundamental, pois caso seja definido um valor muito baixo o sistema não terá informações suficientes para caracterizar o tráfego no canal. Por outro lado, uma taxa de amostragem muito alta pode não ser suportada pelo SDR.

Neste trabalho foi utilizado um *Universal Software Radio Peripheral* (USRP) desenvolvido pela *Ettus Research*, mais precisamente o USRP modelo N210 [44]. Este modelo possui um ADC, capaz de realizar a captura de um sinal com frequência de amostragem de até 400MHz, com resolução de 16 bits por amostra. Esta é uma versão modular do



Figura 3.1: Metodologia proposta.

USRP, na qual os componentes de radiofrequência, ou *Daughterboards*, são adquiridos separadamente. O componente utilizado neste projeto foi o modelo *SBX 40*, que opera na faixa de frequências entre 400MHz e 4400MHz, e tem capacidade de analisar canais de até 40MHz de largura de banda.

A plataforma de desenvolvimento utilizada foi o GNU Radio [45], cujo direito autoral pertence à *Free Software Foundation*. O GNU Radio possui filtros, codificação de canais, elementos de sincronização, equalizadores, demoduladores, decodificadores, entre outros *blocos de processamento*. Uma forte vantagem desta plataforma é a componentização, pois o encapsulamento do processamento em blocos simplifica o desenvolvimento e a manutenibilidade do sistema. A plataforma é gratuita sob a Licença Pública Geral (do Inglês, *General Public License*) (GPL), versão 3, o que é um fator favorável para sua adoção. As aplicações podem ser desenvolvidas em *Python* e *C++*.

Os experimentos foram realizados em redes 802.11g em modo *Ad-hoc*. A rede foi configurada para funcionar no modo básico do CSMA/CA [46, 47] especificado pelo padrão IEEE 802.11.

Sendo a largura de banda de um canal no padrão IEEE 802.11 definido como 22MHz, a taxa de amostragem do sistema foi escolhida como  $f_a = 25\text{MHz}$ , pois frequências de amostragem superiores causavam erros de escrita no arquivo no momento da aquisição. O período  $T_a$  entre uma amostra e outra é, portanto,

$$T_a = 1/f_a = 0,04\mu\text{s} \quad (3.1)$$

Tendo em vista que a duração do SIFS, que é o menor intervalo a ser classificado no sinal no IEEE 802.11g é de 9 $\mu$ s, a frequência de amostragem é suficiente para a caracterização do tráfego no canal. A frequência central foi definida em 2,472GHz, o que corresponde ao canal 13 do padrão IEEE 802.11. O canal 13 foi escolhido pois o tráfego no canal é menor e há um menor número de canais laterais sobrepostos.

O sinal discreto é coletado utilizando o dispositivo USRP e, então, gravado em um arquivo no formato binário. Este arquivo armazena os sinais ortogonais  $I(t)$  e  $Q(t)$ , representados por dois números de 4 *bytes* no formato de ponto flutuante precisão simples, segundo o padrão IEEE 754.

## 3.2 Etapa II - Processamento dos Sinais

Os sinais discretos  $I(t)$  e  $Q(t)$  são processados para obter uma estimativa da função de energia presente no canal em um dado intervalo de tempo.

A coleta de um período de tempo de 10 segundos, por exemplo, gera um arquivo de aproximadamente 2 *gigabytes* a uma taxa de amostragem de 25MHz. Com o objetivo de diminuir o número de amostras processadas por tempo pela RNA, a energia é calculada usando janelas temporais. A utilização de janelas temporais reduz a resolução temporal do sinal de energia, mas é possível determinar o tamanho da janela de forma a não perder nenhuma informação essencial. Denominamos *janela* um bloco de amostras a partir do qual é calculada uma amostra do sinal de energia. Portanto, a Equação (2.5) pode ser escrita como

$$E(n) = \frac{1}{N} \sum_{j=t}^{t+N} I(j)^2 + Q(j)^2, \quad (3.2)$$

onde  $n = t/N$  é o número de uma janela de tempo não sobreposta e  $N$  é o tamanho da janela. A frequência de amostragem do sinal de energia obtido pode ser calculada por

$$f_e = f_a/N \quad (3.3)$$

O tamanho  $N$  de uma janela deve ser cuidadosamente definido, considerando não apenas a frequência de amostragem mas também os detalhes do protocolo de transmissão empregado pelo usuário primário. A Tabela 3.1 contém, para  $N \in \{64, 128, 256, 512, 1024\}$ , os parâmetros frequência de amostragem ( $f_e$ ) e período entre amostras ( $T_e$ ) da função de energia  $E(n)$ , a partir do sinal adquirido na etapa anterior com frequência de amostragem  $f_a = 25\text{MHz}$  e período entre amostras  $T_e = 40\text{ns}$ .

Tabela 3.1: Tamanho da janela

$N$	$f_e$	$T_e$
1024	24,41kS/s	40,96 $\mu$ s
512	48,83kS/s	20,48 $\mu$ s
256	97,66kS/s	10,24 $\mu$ s
128	195,31kS/s	5,12 $\mu$ s
64	390,63kS/s	2,56 $\mu$ s

Como os experimentos utilizaram o IEEE 802.11, o sistema deve ser capaz de identificar transições de 9 $\mu$ s, que é a duração do SIFS [47], o menor elemento a ser caracterizado no ambiente em questão. Logo, a janela deve ter no máximo 128 amostras. Por outro lado, quanto menor o tamanho da janela  $N$ , maior o número de amostras por tempo  $f_e$ , requerendo um hardware com maior capacidade de processamento. Por conseguinte, o valor escolhido para o tamanho da janela foi de 128 amostras.

A Figura 3.2 apresenta três gráficos que ilustram o processamento aplicado a 20ms dos sinais adquiridos, desde o tempo inicial 4,606s ao tempo final 4,626s. O primeiro mostra um exemplo dos sinais em fase ( $I$ ), linha contínua, e quadratura ( $Q$ ), linha tracejada. O eixo vertical corresponde à amplitude destes sinais, sendo uma grandeza considerada em Volts. O segundo apresenta o sinal de energia em Watts e o terceiro é o espectrograma, no qual o eixo vertical indica a frequência normalizada em relação à frequência central do canal, onde 1 corresponde a 12,5MHz, e a cor (de azul a vermelho) o nível de energia correspondente em decibéis.

Na Figura 3.2, podemos observar que entre 4,606s e 4,608s são feitas três tentativas consecutivas de envio um Dado, e após a terceira tentativa, um Ack é recebido. Um outro envio de Dado é feito aproximadamente aos 4,615s da coleta, seguido de um Ack em um nível superior de energia, como pode ser verificado no segundo gráfico. Aos 4,622s há a transmissão de um *Beacon*, e a seguir mais uma transmissão de Dado seguida de Ack. Pelo espectrograma, apresentado no terceiro gráfico, podemos observar que a transmissão destes sinais é realizada no canal de transmissão considerado, sem interferências de canais laterais, que são apresentadas mais adiante neste trabalho. O sinal de energia estimado é utilizado para o processo de limiarização, descrito a seguir.

### 3.3 Etapa III - Limiarização

O sinal de energia  $E_n$  é limiarizado, isto é, mapeado para os valores  $H_0$  e  $H_1$ , a partir da definição de um valor denominado limiar. Este processo pode ser expresso por

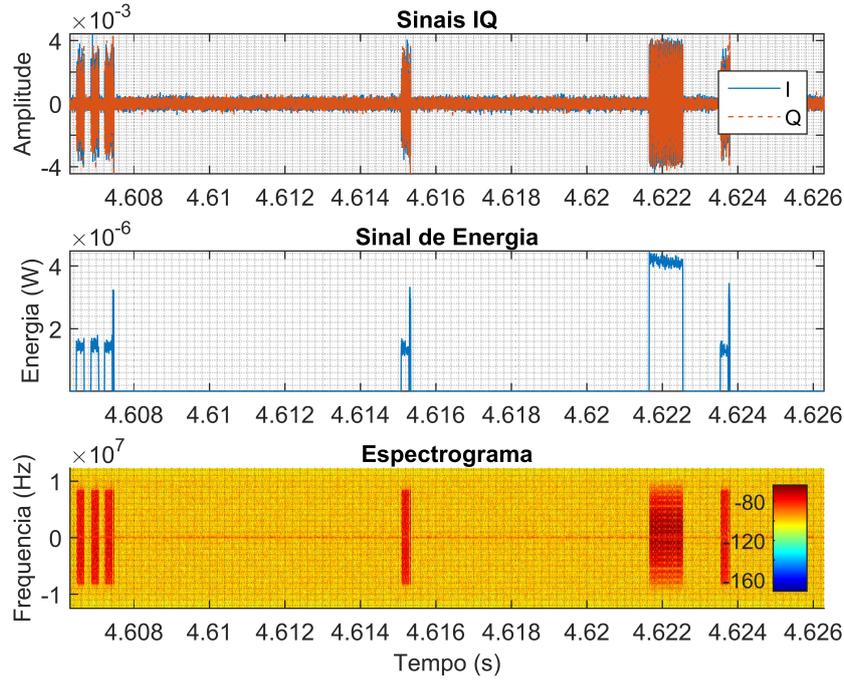


Figura 3.2: Processamento do sinal.

$$H(E_n) = \begin{cases} H_0 & \text{se } E_n(t) < \lambda \\ H_1 & \text{se } E_n(t) > \lambda \end{cases} \quad (3.4)$$

sendo  $H_1$  a hipótese em que a amostra do sinal de energia é maior que o limiar  $\lambda$ , indicando que o usuário primário está presente, e  $H_0$  a hipótese em que a amostra do sinal de energia é menor que  $\lambda$ , indicando a ausência do usuário primário. A Figura 3.3 apresenta um exemplo de limiarização no qual o sinal de energia é representado pela cor laranja e a saída limiarizada é a onda quadrada em azul, processada a partir do limiar  $\lambda = 10^{-7}$ , representado pela linha tracejada.

A definição de  $\lambda$  deve ser dinâmica pois depende do ambiente, visto que os níveis de energia das transmissões presentes no canal, bem como o nível de energia do ruído podem variar ao longo do tempo. Para encontrar um valor ótimo para  $\lambda$  foi utilizado um algoritmo de particionamento de dados iterativo denominado K-means [48], que atribui cada amostra a uma entre  $k$  partições definidas por suas centroides, em que  $k$  é definido antes da execução do algoritmo.

A Figura 3.4 ilustra o funcionamento do K-means, em que o eixo horizontal representa o número da amostra, o eixo vertical a energia, as marcações em vermelho a localização das centroides, e os pontos representam as amostras do sinal de energia. As amostras

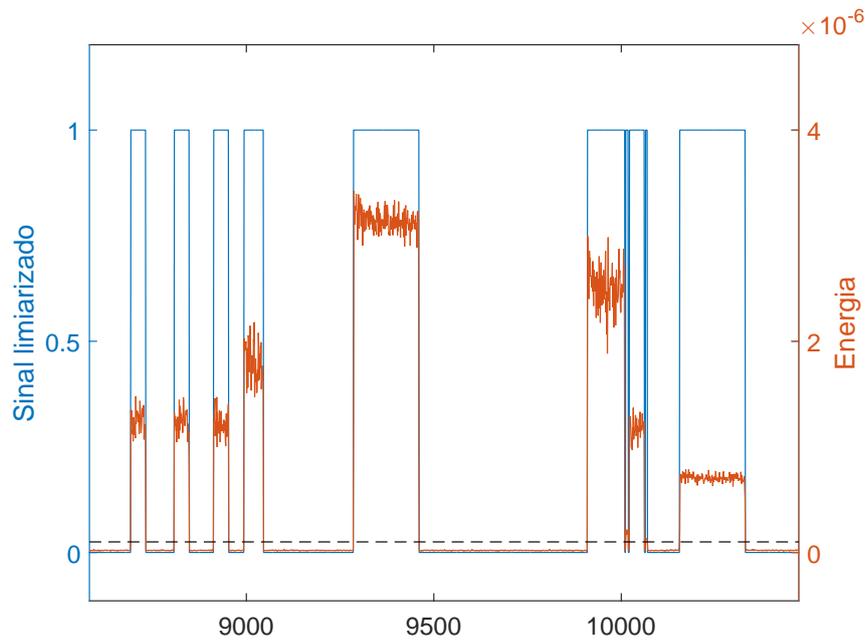


Figura 3.3: Limiarização da função de energia.

classificadas como  $H_0$  estão em azul e amostras classificadas como  $H_1$  em preto. Para melhor visualização do sinal no tempo, as amostras foram interpoladas com segmentos de reta em azul claro.

Quando há interferência lateral, no entanto, a informação da energia pode não ser suficiente para a limiarização correta do sinal. A Figura 3.5 mostra um exemplo de segmento do sinal capturado na qual há interferência lateral.

O espectrograma, último gráfico da figura, mostra que no intervalo de tempo entre 6,6785s e 6,681s existe energia em algum canal adjacente, já que a energia se concentra na porção inferior do espectrograma, e não na parte central. O sinal de energia, representado pelo segundo gráfico, apresenta um nível de energia da banda lateral similar ao sinal presente no canal neste mesmo intervalo, que certamente seria mapeado para  $H_1$  na etapa de limiarização.

Para considerar apenas a energia no canal de interesse, foi realizada uma filtragem a partir da seleção das bandas da Transformada Rápida de Fourier (do Inglês, *Fast Fourier Transform*) (FFT) do sinal de cada janela. Um exemplo de resultado obtido é mostrado na Figura 3.6.

Após o filtro aplicado, apenas a banda de frequência de 2,465GHz a 2,483GHz foi utilizadas para calcular o sinal de energia. Assim, no período entre 6,6785s e 6,681s, o nível de energia do sinal filtrado passa a ser menor ao nível do ruído, sendo assim mapeado para o valor correto  $H_0$  na etapa de limiarização, como indicado pela seta no

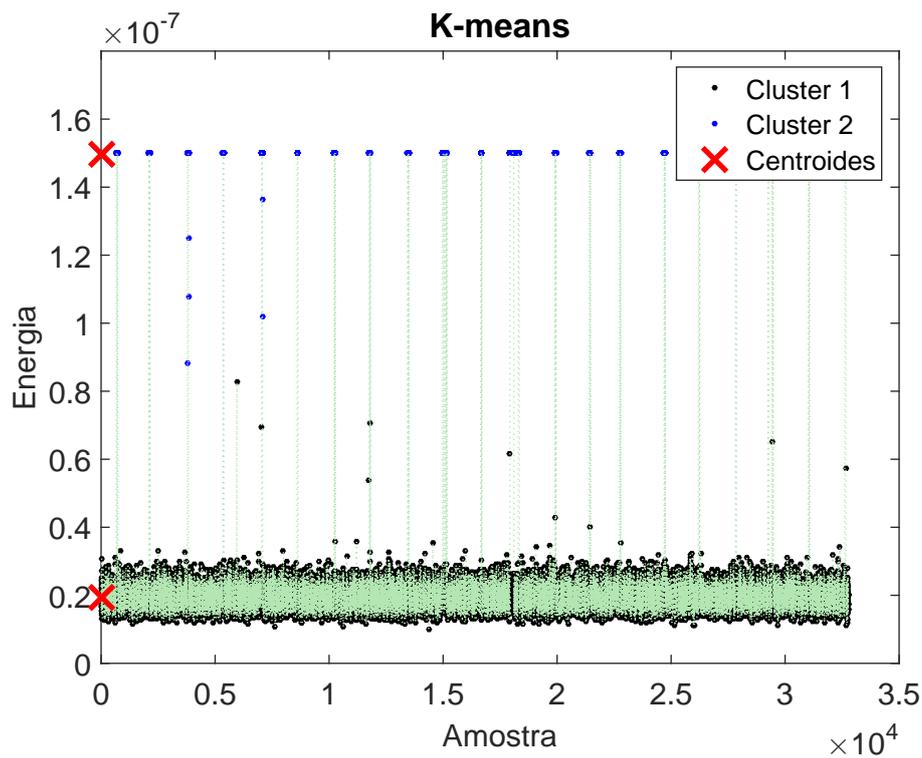


Figura 3.4: Particionamento com K-means.

segundo gráfico.

O sinal de energia filtrado e limiarizado é então entregue para ser analisado por uma rede neural, conforme detalhado na próxima Seção.

## 3.4 IV - Classificação e Identificação Utilizando RNRE

O sinal de energia filtrado e limiarizado é fornecido como entrada para uma RNRE. As unidades de contexto da RNRE proveem sensibilidade ao contexto em sequências temporais, o que possibilita a caracterização do sinal coletado no domínio do tempo.

Para este trabalho foram definidas e avaliadas duas estruturas básicas de RNREs. Seus usos dependem se dispomos do conhecimento *a priori* de detalhes do protocolo que está trafegando na rede sem fio, ou se não dispomos de nenhuma informação sobre os protocolos de comunicação.

### 3.4.1 Redes Neurais Recorrentes de Elman de Classificação

Chamamos aqui de “RNRE de Classificação” a rede neural que classifica cada amostra do sinal de energia filtrado e limiarizado de modo a indicar se pertencente a um quadro de

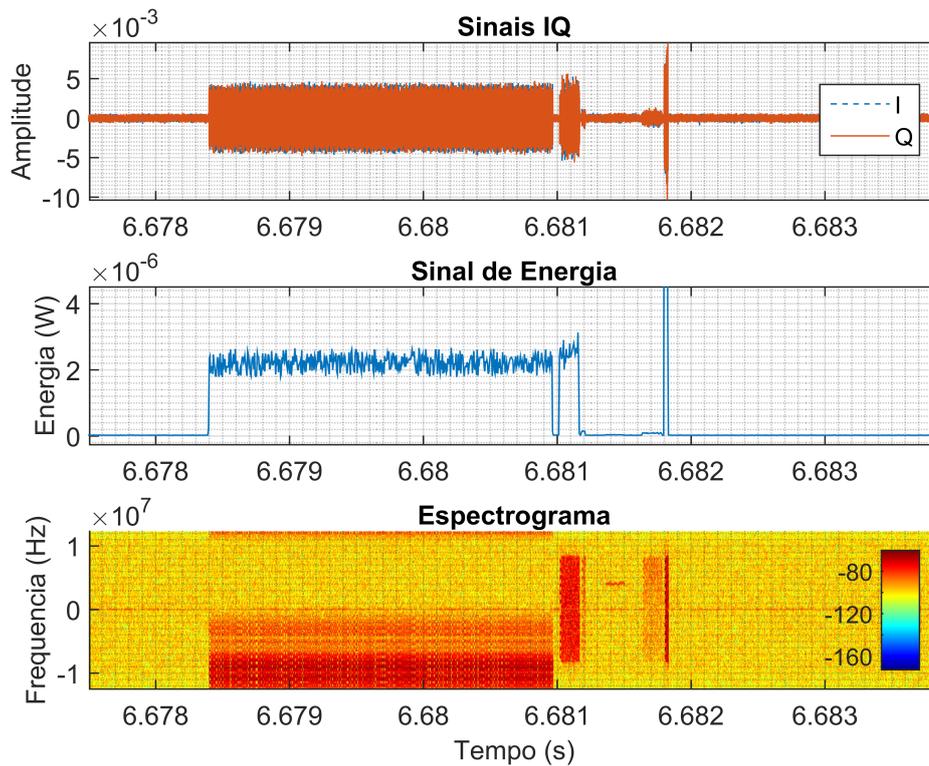


Figura 3.5: Limiarização de um sinal sem filtragem.

Dado, Ack ou *Beacon* e a ausência de energia indicar se pertence a um quadro SIFS ou trata-se realmente de ociosidade do canal.

Algoritmos de treino baseados no *backpropagation* geralmente partem da premissa de que o conjunto de treino é balanceado, ou seja, a quantidade de amostras disponíveis de cada classe no conjunto é semelhante.

No problema abordado neste trabalho, no entanto, temos um conjunto de treino bastante desbalanceado. No caso das redes de classificação, as amostras nos quadros de SIFS, por exemplo, são muito menos frequentes que amostras pertencente a quadros de Dados. Para uma transmissão bem sucedida, um Dado tem aproximadamente 40 amostras do sinal de energia, enquanto o intervalo de SIFS é representado por no máximo 2 amostras de um sinal com energia zero. Isto implica que, caso nenhuma técnica e balanceamento seja usada, a não aprendizagem de classificação de SIFS têm um menor impacto na taxa de acerto, e no algoritmo de treinamento, o que pode afetar no resultado e validação do treino da RNRE.

Para levar este fator em consideração, os erros relacionados a cada classe de saída da RNRE são ponderados inversamente à sua frequência de ocorrência estimada a partir de uma análise estatística dos sinais coletados. A Tabela 3.2 apresenta as classes de saída, e

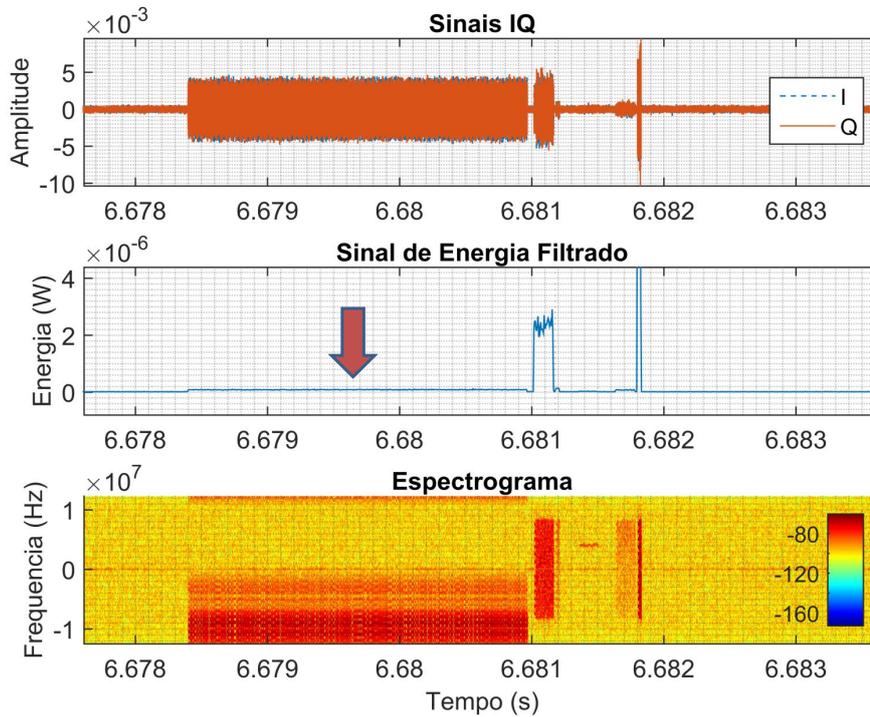


Figura 3.6: Limiarização de um sinal filtrado.

os pesos determinados para rede de classificação.

Tabela 3.2: Classes de saída da RNRE de classificação

Classe	Descrição	Peso
1	Ociosidade	0,0019
2	Dado	0,0627
3	<i>Beacon</i>	0,2588
4	SIFS	1
5	Ack	0,4504

A tabela indica que os erros nos quadros de SIFS devem ser considerados cerca de 500 vezes mais importantes que os erros na classificação de uma amostra do canal em período de ociosidade.

A Figura 3.7 ilustra a arquitetura básica das RNREs de classificação. A camada de entrada é composta por 1 neurônio, indicando que o sinal de energia filtrado limiarizado é processado amostra por amostra. O número de neurônios na camada escondida foi

variado de 2 a 20 nos experimentos para avaliar o desempenho das redes. A RNRE de classificação possui 5 neurônios de saída, cada qual correspondente a uma classe.

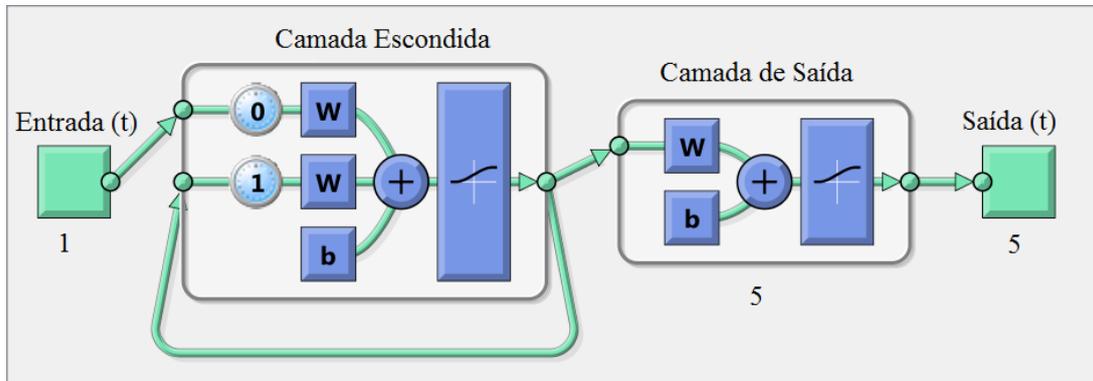


Figura 3.7: Estrutura das RNRE de classificação.

### 3.4.2 Redes Neurais Recorrentes de Elman de Identificação

Chamamos aqui de “RNRE de Identificação” a rede neural que apenas identifica se uma amostra do sinal de energia filtrado e limiarizado como sendo o início de uma oportunidade de transmissão ou não, sem a necessidade de classificar os quadros específicos dos protocolos presentes no canal.

Assim como ocorre com a RNRE de Classificação, no presente caso também nos confrontamos como problema do desbalanceamento das classes. A Tabela 3.3 apresenta as classes de saída e os pesos determinados para RNRE de identificação.

Tabela 3.3: Classes de saída da RNRE de identificação

Classe	Descrição	Peso
1	Não precede oportunidade(s)	0,01
2	Pode preceder oportunidade(s)	1

A tabela indica que o erro de previsão de uma oportunidade deve ser considerado 100 vezes mais importante que um erro na previsão de uma “não-oportunidade”.

A Figura 3.8 ilustra a arquitetura básica das RNREs de Identificação. A camada de entrada é composta por 1 neurônio, indicando que o sinal de energia limiarizado é processado amostra por amostra. O número de neurônios na camada escondida foi variado de 2 a 20 nos experimentos para avaliar o desempenho das redes. A RNRE de identificação possui apenas 2 neurônios de saída, cada qual correspondente a uma classe.

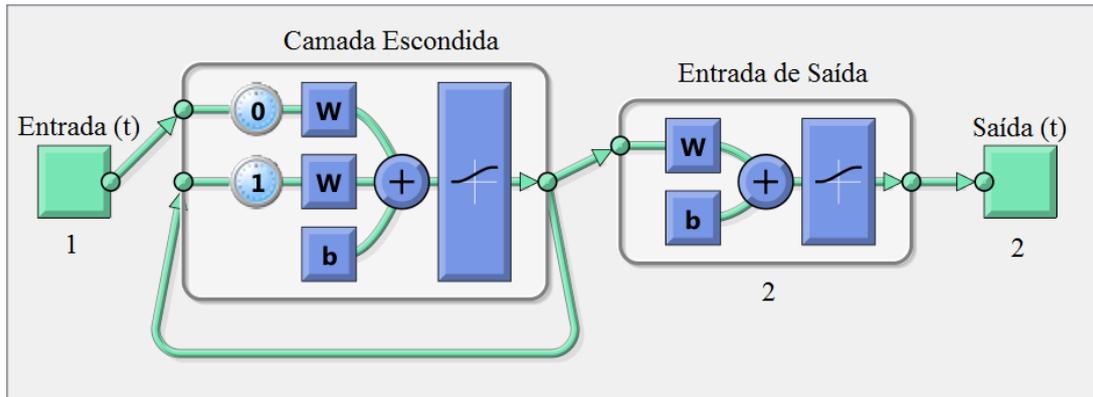


Figura 3.8: Estrutura das RNRE de identificação.

O resultado do processamento neural das amostras de energia filtradas e limiarizadas pelas redes de classificação ou identificação é entregue ao procedimento de previsão de oportunidades.

### 3.5 Etapa V - Previsão de Oportunidades

Esta etapa se caracteriza pela construção de modelos estatísticos para previsão de oportunidades. A Figura 3.9 ilustra este processo. A partir da saída da RNRE, é selecionado um modelo probabilístico. No caso da RNRE de classificação, por exemplo, pode-se haver um modelo probabilístico para estimar oportunidades após um ACK e um para após um *Beacon*.

O modelo probabilístico selecionado a partir da rede neural permite estimar a probabilidade  $p(n, t)$  de haverem  $n$  oportunidades consecutivas a partir de um instante  $t$ . Para os experimentos, define-se oportunidade como uma sequência de 40 amostras de ociosidade consecutivas no sinal de energia.

O número de 40 amostras do sinal de energia para o tamanho de uma oportunidade foi escolhido porque, em todas as coletas realizadas, a duração de um ciclo de comunicação Dado-SIFS-Ack varia entre 22 e 39 amostras. Como o período de amostragem da função de energia é  $5,12\mu\text{s}$ ,  $40 \times 5,12 = 204,8\mu\text{s}$  é um intervalo de tempo suficientemente grande para um usuário secundário transmitir sem colisão, o que está de acordo com o trabalho realizado por Jun *et al.* [47].

A Figura 3.10 apresenta um exemplo de histograma de oportunidades para uma RNRE de identificação. O histograma é uma representação do histórico de oportunidades após cada amostra classificada como 2 (classe que indica que a amostra pode preceder uma ou mais oportunidades). O eixo vertical do histograma representa a porcentagem de amostras classificadas como 2 que precederam um número  $n$  de oportunidades, sendo  $n$  a coordenada

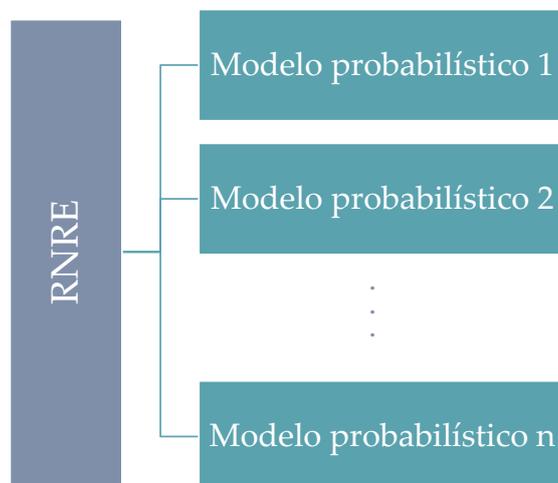


Figura 3.9: Previsão de oportunidades.

no eixo horizontal. Por exemplo, cerca de 20% das amostras precedeu 21 oportunidades, e não houveram 30 oportunidades consecutivas dentre as amostras classificadas.

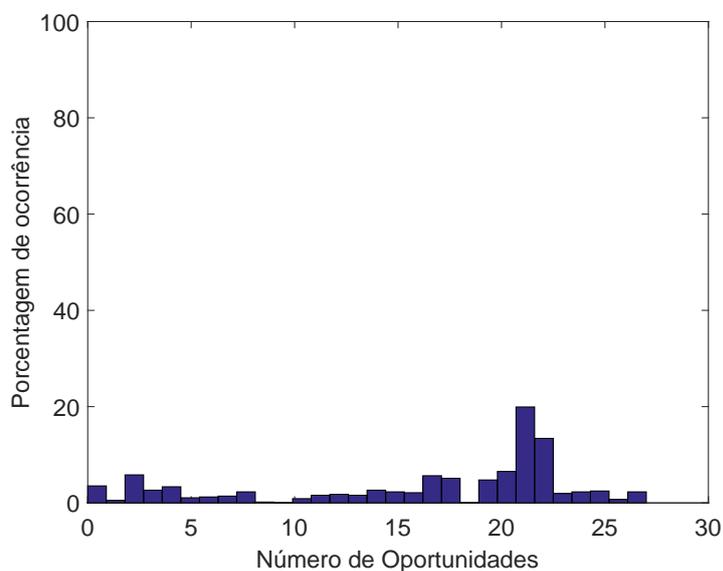


Figura 3.10: Histograma de oportunidades.

O modelo probabilístico a que esta Seção se refere, no entanto, é a probabilidade da amostra preceder  $n$  ou mais oportunidades, denominada *probabilidade acumulada*. A Figura 3.11 apresenta a probabilidade acumulada calculada a partir do histograma da Figura 3.10. O eixo vertical indica a probabilidade de haverem  $n$  ou mais oportunidades

após a amostra, em que  $n$  é a coordenada do eixo horizontal. A probabilidade de haver 0 ou mais oportunidades, por exemplo, é de 100% e a probabilidade de 28 ou mais é de 0%.

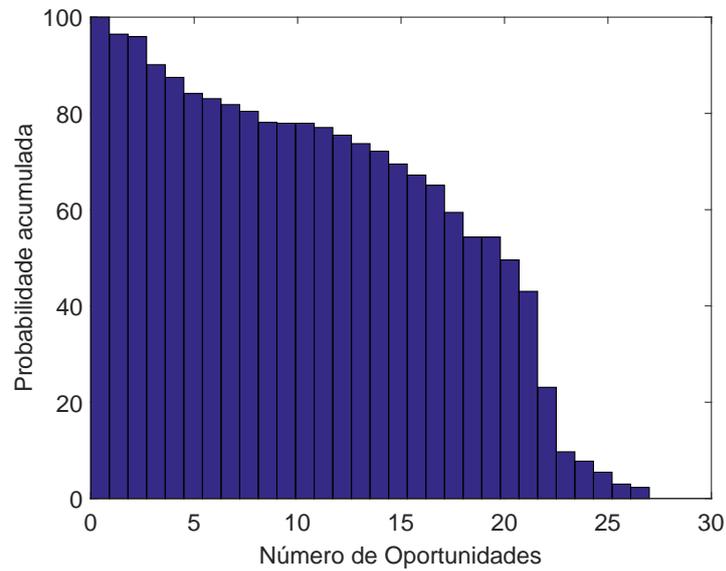


Figura 3.11: Probabilidade acumulada de oportunidades.

O resultado final da aplicação da metodologia proposta neste capítulo é o modelo probabilístico selecionado pela RNRE, a partir do qual é possível fixar uma taxa de confiabilidade e determinar quantas oportunidades devem ser exploradas. O próximo capítulo detalha os experimentos conduzidos para validar esta metodologia.

# Capítulo 4

## Resultados Experimentais

Os experimentos executados para validar a metodologia propostas são descritos neste capítulo. O roteiro de validação foi pensado de forma incremental, ou seja, partindo de um cenário simples para cenários mais complexos. Primeiramente, testamos a metodologia em um ambiente isolado, sem interferência de canais laterais, com nível baixo de ruído e apenas dois nós se comunicando. Em seguida, um segundo par de nós foi adicionado para caracterizar dois diálogos simultâneos em um mesmo canal. Após este teste, realizamos uma coleta de dados em um ambiente mais congestionado, com redes *Wi-Fi* operando em vários canais. Por fim, foi feito um teste introduzindo uma variação no tamanho do pacote transmitido. Estes experimentos são descritos com mais detalhe no que segue.

### 4.1 Experimento 1

O objetivo deste experimento é validar a metodologia em um cenário simples, com o mínimo de interferência possível. As coletas foram realizadas no Jardim Botânico de Brasília, em um ambiente no qual o nível de interferência é minimizado, conforme será verificado adiante.

Para avaliar a influência dos dispositivos de comunicação sem fio (como *smartphone*, *notebook*, etc.) não conectados a uma rede IEEE 802.11, as coletas foram divididas em dois grupos: o primeiro estes equipamentos desligados, e o segundo com os equipamentos ligados. Os parâmetros para as coletas são apresentados na Tabela 4.1: o canal foi sensoriado a uma taxa de amostragem de 25MHz durante 15s, dos quais durante 5s houve transmissão com pacotes de 1024B.

Tabela 4.1: Parâmetros das coletas do experimento 1

Taxa de amostragem	Duração	Transmissão	Tamanho dos Pacotes
25MHz	15s	5s	1024B

A configuração física da rede no momento da captura é ilustrada na Figura 4.1. Os nós *A* e *B* se comunicaram no canal 13 do IEEE 802.11g em modo *Ad-hoc* a uma taxa de comunicação de 1Mb/s utilizando Protocolo de Datagrama de Usuário (do Inglês, *User Datagram Protocol*) (UDP) como protocolo da camada de transporte, enquanto um terceiro nó *C* recebia os dados sensoriados pelo *USRP*. O tráfego neste e nos demais experimentos foi gerado com o auxílio da ferramenta *iPerf* [49], um software livre desenvolvido pela *National Center for Supercomputing Applications* (NCSA) de Illinois.

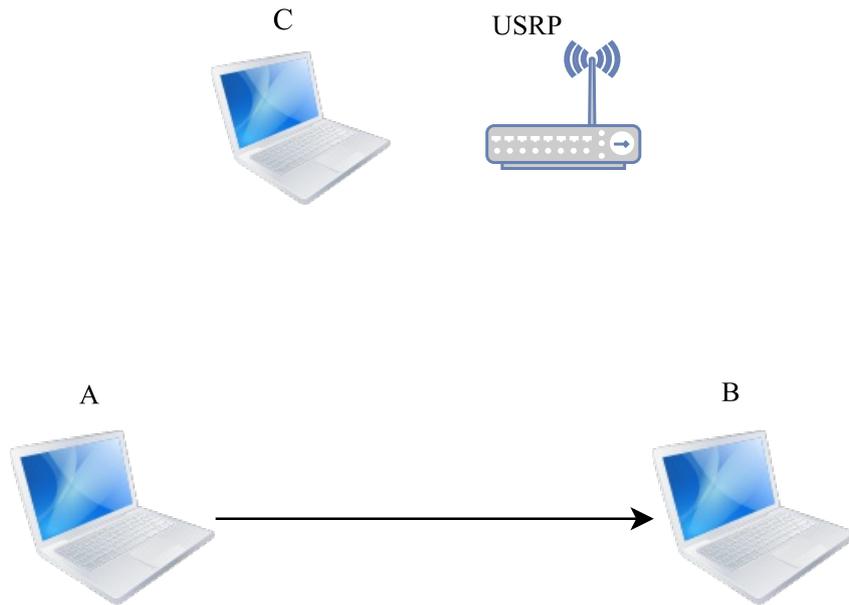


Figura 4.1: Cenário do experimento 1.

Os sinais em fase, representado pela linha tracejada, e em quadratura, representada pela linha contínua, capturados pelo *USRP* em uma coleta do primeiro grupo e uma do segundo grupo são mostrados nas Figuras 4.2 e 4.3. A transmissão dos dados entre os nós *A* e *B* ocorre no intervalo entre 3s e 8s, e não foi identificada nenhuma alteração entre os dois grupos.

No restante da coleta, o padrão de transmissão intervalado mostrado é provavelmente devido aos quadros de *Beacons*, já que o período de ocorrência deles é de aproximadamente 100ms, o que corresponde ao intervalo entre *Beacons* definido no protocolo [22].

A Figura 4.4 contém três gráficos: o primeiro, de cima pra baixo, contém os sinais em fase (*I*), representado pela linha tracejada, e em quadratura (*Q*), representado pela linha contínua. O eixo vertical é a amplitude dos sinais. O segundo apresenta o sinal de energia, com o eixo vertical denotado em Watts. O terceiro é o espectrograma, no qual o eixo vertical indica a frequência, na forma de desvio da frequência central da banda do canal, e a cor (de azul a vermelho) o nível de energia correspondente em dB. Os gráficos

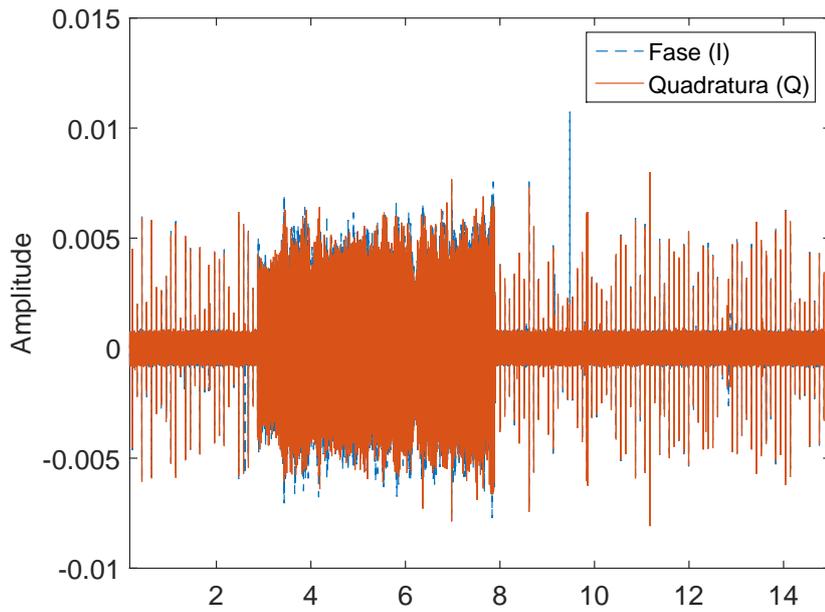


Figura 4.2: Sinais  $I$  e  $Q$  com dispositivos ligados.

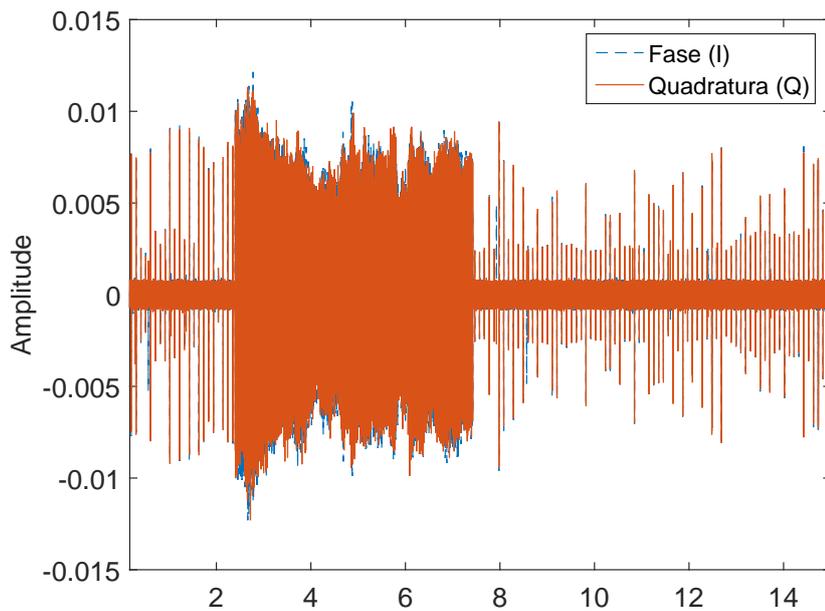


Figura 4.3: Sinais  $I$  e  $Q$  com dispositivos desligados.

possuem eixo horizontal com escala única, que indica o tempo em segundos a partir do início da coleta.

Em relação à Figura 4.4, a razão sinal ruído foi calculada a partir da Equação

$$SNR = 10 \times \log_{10} \left( \frac{E_s}{E_r} \right) \quad (4.1)$$

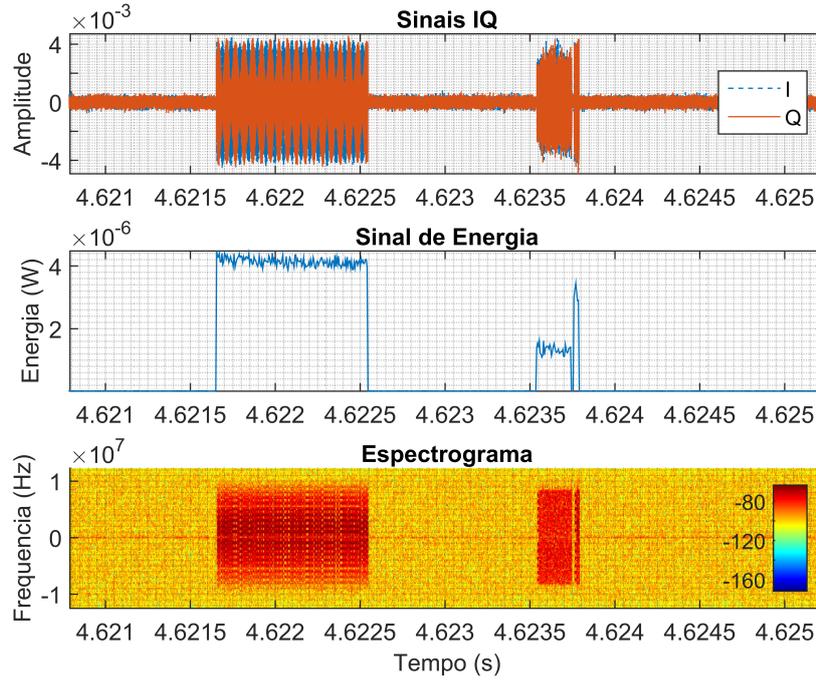


Figura 4.4: Sinais  $I$  e  $Q$ , sinal de energia e espectrograma de parte do experimento 1.

na qual  $E_s$  é o nível de energia do sinal e  $E_r$  o nível de energia do ruído. O valor experimental obtido para SNR foi de 7,64dB, o que permite a diferenciação entre o sinal e o ruído. Além disso, observa-se que não há transmissão em canais laterais, já que energia dos sinais no espectrograma está concentrada na porção central da banda de frequência. No início dos gráficos, o aumento do nível de energia é devido à transmissão de um quadro de *Beacon*, pois a duração, 893 $\mu$ s, e período de transmissão do quadro, a cada 100ms, está de acordo com a definição do protocolo IEEE 802.11, conforme explicado na Seção 2.3. Logo após, no tempo 4,6235s há um diálogo com transmissão de um Dado seguido de um intervalo de SIFS e um quadro de confirmação Ack.

Foram treinadas 400 RNREs de classificação e 450 RNREs de identificação, divididas em grupos de 50, cada grupo com um número de neurônios na camada escondida - 2, 3, 4, 5, 7, 10, 12, 15, 20 neurônios. O algoritmo de aprendizagem utilizado é o *backpropagation* de Levenberg e Marquardt [35, 36] com função de ativação log-sigmoidal para todos os neurônios. As condições de parada são a taxa de erro menor ou igual a  $10^{-5}$ , calculada a partir da distância média euclidiana e o número máximo de 5000 iterações do algoritmo. Estes parâmetros foram mantidos para os treinamentos das RNREs em todos os experimentos.

Uma visão geral dos resultados dos treinamentos das RNREs de classificação e identificação é mostrada nas Figuras 4.5 e 4.6, respectivamente. Cada círculo mostrado corres-

ponde a uma RNRE treinada, o eixo horizontal corresponde ao número de neurônios na camada escondida e o eixo vertical a taxa de acerto ponderada obtida. A linha contínua traçada no gráfico representa a taxa de acerto média para cada conjunto de redes. As taxas de acerto foram calculadas utilizando os pesos definidos nas Tabelas 3.2 e 3.3.

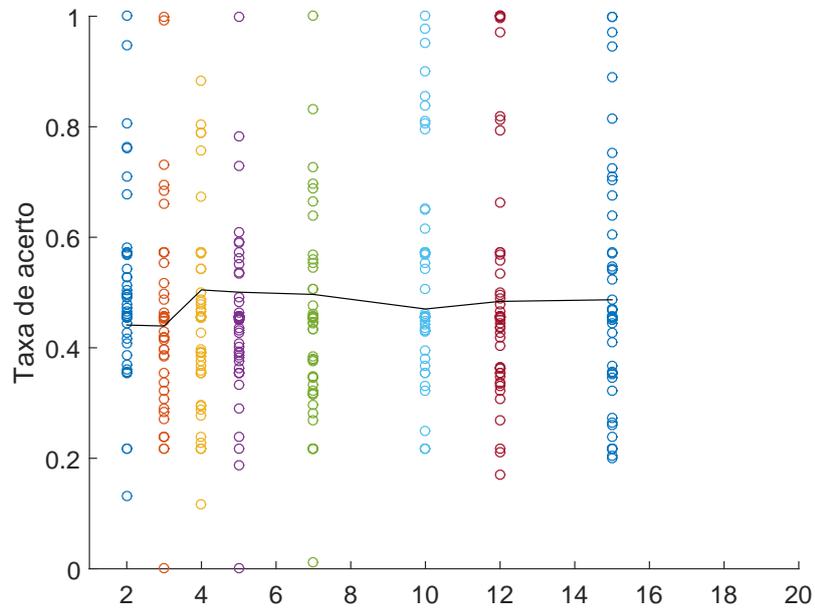


Figura 4.5: Taxa de acerto para RNRE de classificação.

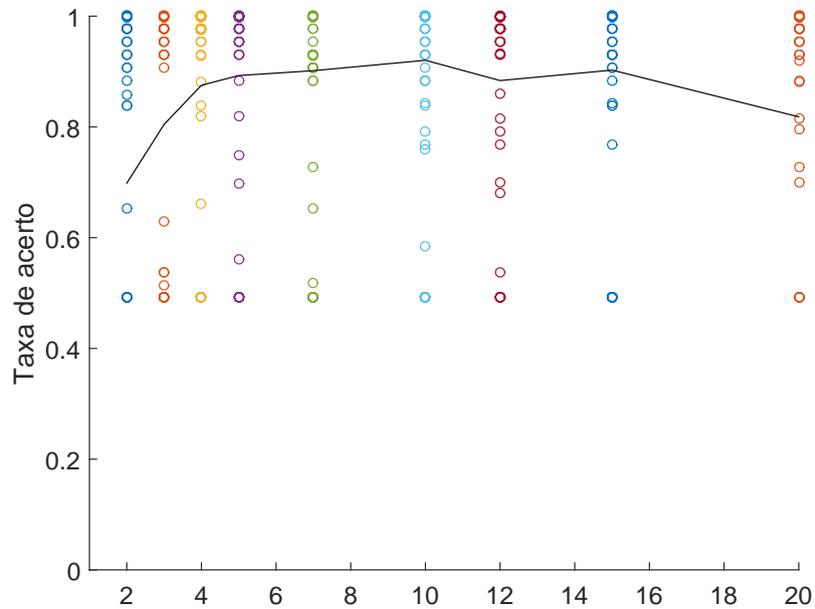


Figura 4.6: Taxa de acerto para RNRE de identificação.

As redes neurais de identificação apresentaram taxas mais elevadas de acerto: 66,44% tiveram desempenho acima de 0,9, e a taxa de acerto médio foi 0,369 maior em comparação às RNREs de classificação, que convergiram para uma taxa de acerto intermediária, em torno de 0,5, com apenas 5% das redes obtendo taxas de acerto acima de 0,9. Observa-se, no entanto, que com o treinamento adequado, todas as estruturas de RNREs são capazes de atingir uma taxa de acertos de 100%.

A matriz de confusão da rede RNRE de classificação com taxa de acerto mediana dentre as 400 RNAs treinadas, correspondente a 0,4555, é apresentada na Figura 4.7. O eixo horizontal representa a classificação correta, o eixo vertical a saída da rede e as linhas e colunas correspondem aos números das classes de saída das redes neurais: 1 para ociosidade, 2 para Dado, 3 para *Beacon*, 4 para SIFS e 5 para Ack, conforme exposto na Tabela 3.2. A diagonal marcada pelas células verdes representam as classificações corretas da rede treinada, e as células vermelhas os erros. O elemento na linha 1 e coluna 1 - (1, 1), por exemplo, indica que 31614 amostras foram corretamente classificadas como ociosidade, e a elemento (4, 1) indica que 53 amostras de SIFS foram equivocadamente classificadas como ociosidade. As células cinza indicam a totalização de cada classe, e a célula azul o resultado final da rede neural, que neste caso classificou corretamente 99,1% das amostras do conjunto de validação.

Ociosidade	1	31614 96.5%	0 0.0%	0 0.0%	53 0.2%	0 0.0%	99.8% 0.2%
Dado	2	0 0.0%	868 2.6%	113 0.3%	0 0.0%	120 0.4%	78.8% 21.2%
Beacon	3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
SIFS	4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
ACK	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
		100% 0.0%	100% 0.0%	0.0% 100%	0.0% 100%	0.0% 100%	99.1% 0.9%
		1	2	3	4	5	
		Resposta correta					

Figura 4.7: Matriz de confusão do experimento 1.

A matriz de confusão indica que a rede neural mensurada acertou todas as amostras das classes 1 e 2, e errou todas as outras. Mesmo tendo aprendido as características de apenas 40% das classes, a taxa de acerto não ponderada é de 99,1%, enquanto o desempenho ponderado é de 0,455. Observa-se que a ponderação é fundamental para representação dos resultados obtidos.

Após execução das redes neurais, foi realizada uma análise das oportunidades para compor um modelo estatístico. A Figura 4.8 apresenta um histograma de oportunidades, no qual o eixo vertical corresponde à porcentagem de diálogos terminados por Ack que precederam um determinado número de oportunidades consecutivas indicado no eixo horizontal. Por exemplo, nenhum diálogo terminado em Ack teve 0 oportunidades, enquanto quase 40% dos diálogos precedeu um período de tempo composto por 22 oportunidades.

A Figura 4.9 apresenta a probabilidade acumulada de oportunidades após um quadro de Ack, na qual para um dado número de oportunidades expresso no eixo horizontal, a dimensão vertical fornece a probabilidade de haver um número maior ou igual de oportunidades. Por exemplo, há uma probabilidade de 100% de haver uma ou mais oportunidades, neste cenário, e 0% de probabilidade para mais de 30 oportunidades.

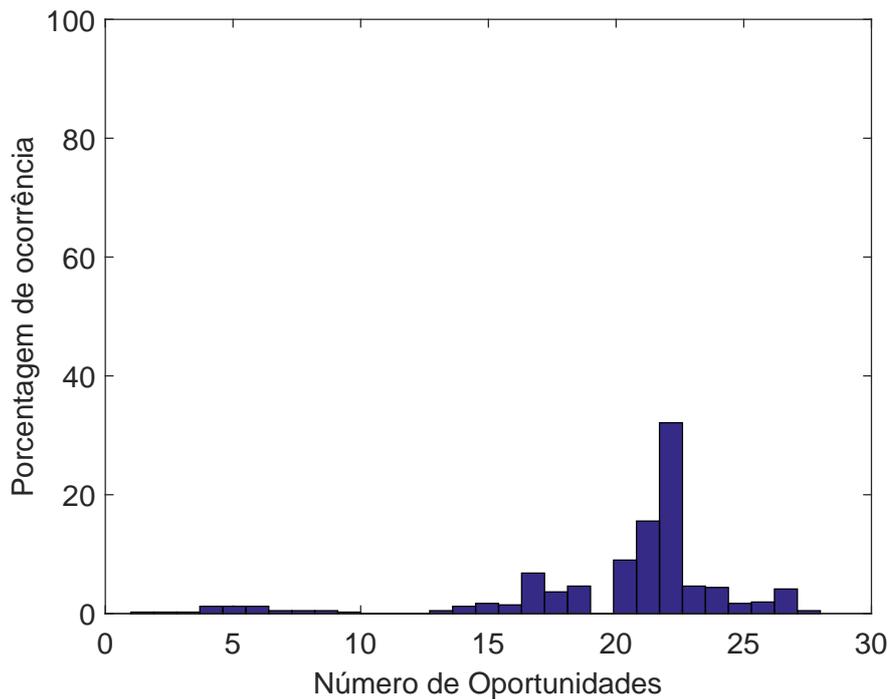


Figura 4.8: Histograma de oportunidades após um Ack.

Esta probabilidade seria utilizada pelo protocolo para determinar quantas oportunidades de transmissão serão exploradas. Uma abordagem mais conservadora, por exemplo,

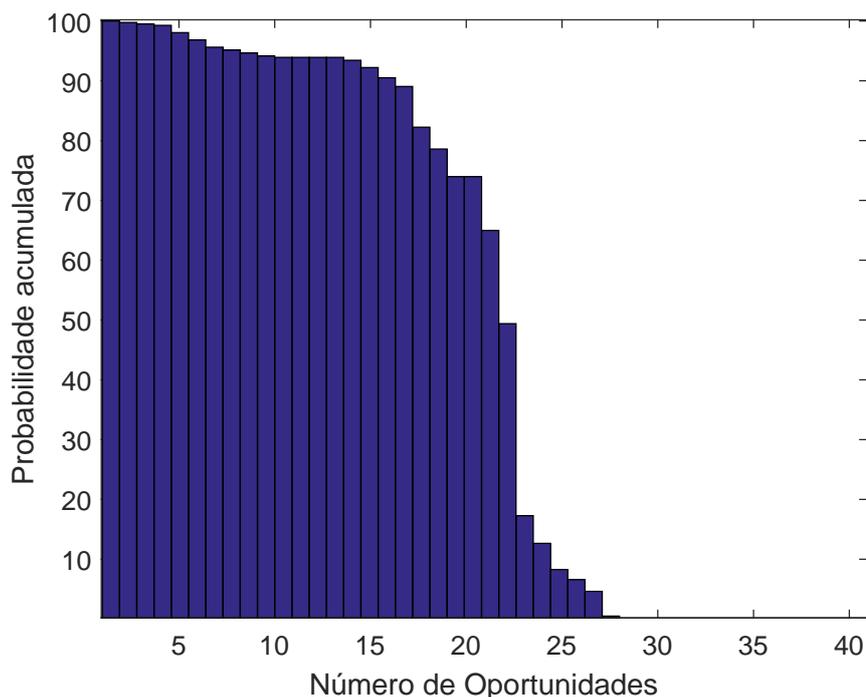


Figura 4.9: Probabilidade acumulada de oportunidades após um Ack.

poderia escolher explorar o intervalo de 3 oportunidades para transmissão por usuários secundários, o que corresponde a uma probabilidade maior que 90%.

As Figuras 4.10 e 4.11, analogamente, apresentam o histograma e a probabilidade acumulada de oportunidades após um *Beacon*. Pode-se afirmar a partir dos gráficos de probabilidade acumulada que após um Ack existe uma probabilidade maior que 90% de haverem pelo menos 15 oportunidades, mas o mesmo não é verdade após um *Beacon*. Logo, a diferenciação dos dois modelos é uma vantagem da RNRE de classificação pois melhor descreve a probabilidade de oportunidades após um *Beacon*, por exemplo.

As Figuras 4.12 e 4.13, apresentam o histograma e probabilidade acumulada de oportunidades a partir das RNREs de identificação. É possível afirmar que há uma similaridade na probabilidade acumulada de oportunidades de transmissão após Ack e para RNREs de identificação. Mais precisamente, a diferença média absoluta é de 4,8%. De fato, como a frequência de ocorrência do Ack é maior que a do *Beacon*, e as redes neurais de classificação e identificação, em um mesmo ambiente, deveriam estimar a mesma probabilidade, esta baixa diferença é esperada.

Conclui-se deste experimento que em um cenário relativamente simples, o sistema proposto executou todos os passos da metodologia com taxas de acerto elevadas, sendo possível treinar um sistema que tenha 0% de erros na previsão de oportunidades mesmo usando redes neurais recorrentes com um número pequeno de neurônios nas camadas

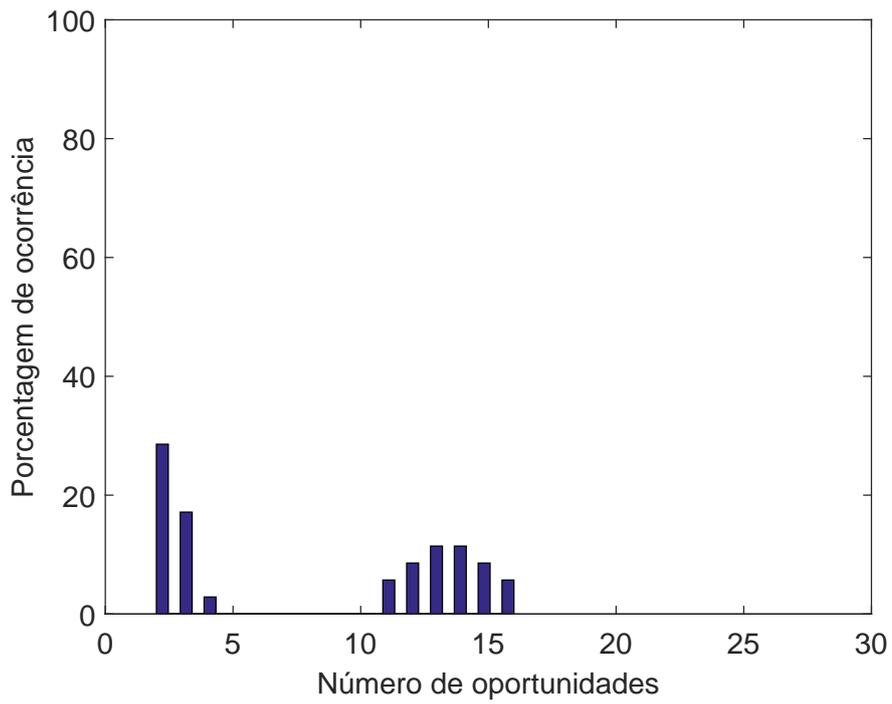


Figura 4.10: Histograma de oportunidades após um *Beacon*.

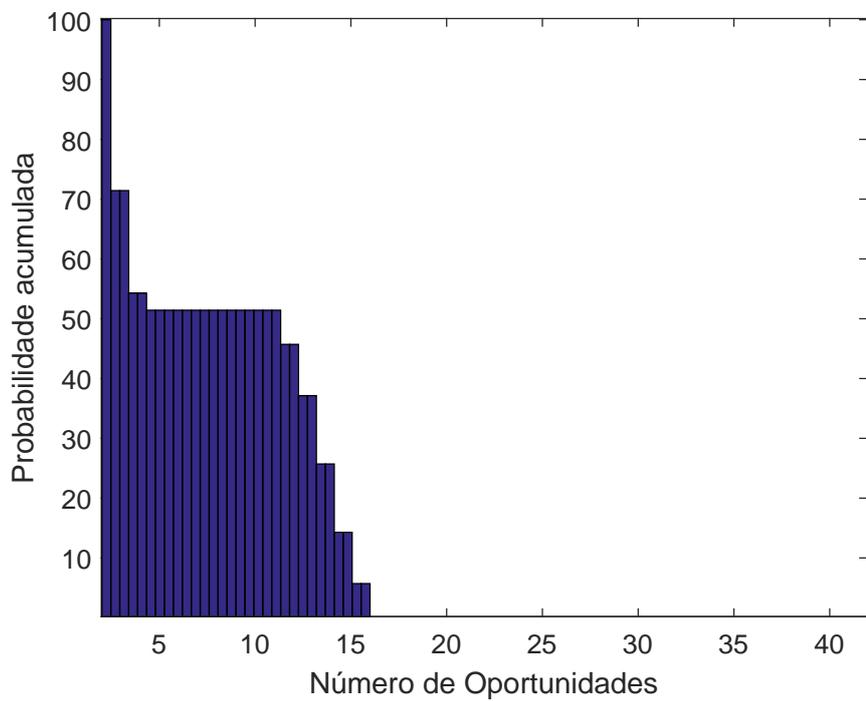


Figura 4.11: Probabilidade acumulada de oportunidades após um *Beacon*.

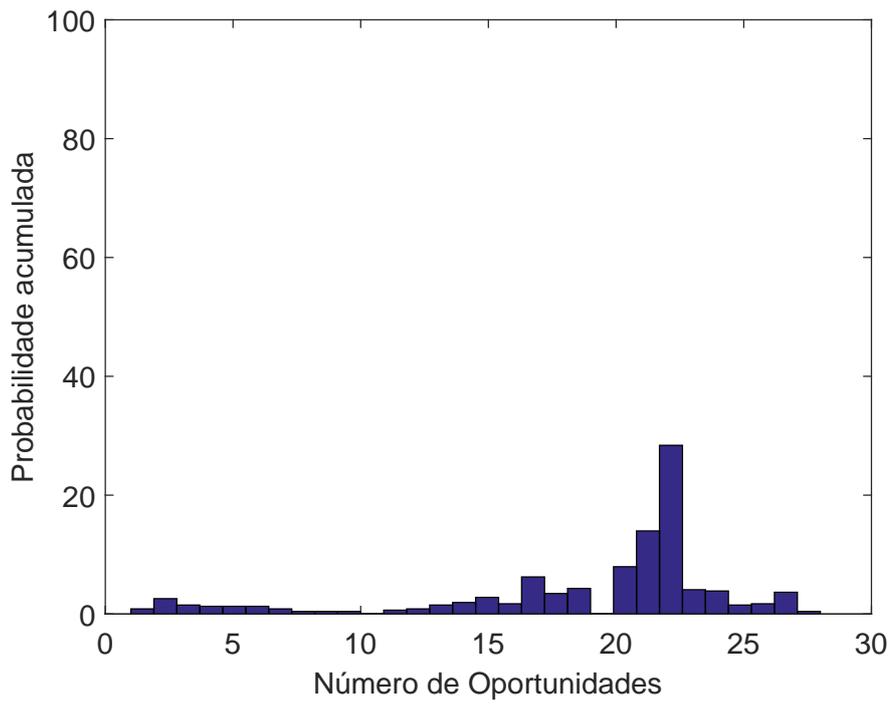


Figura 4.12: Histograma de oportunidades para a RNREs de identificação.

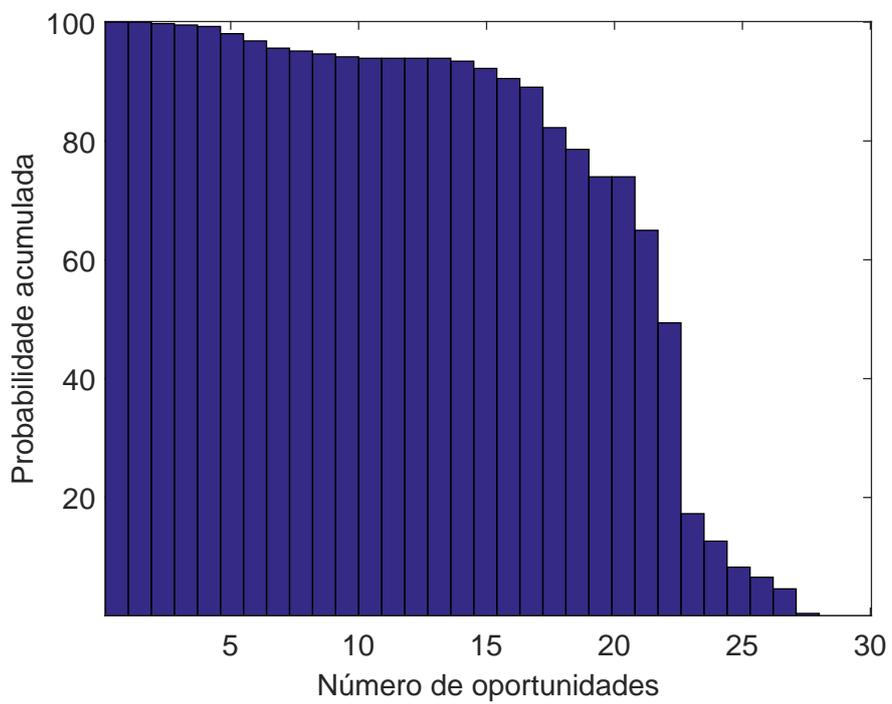


Figura 4.13: Probabilidade acumulada de oportunidade para as RNREs de identificação.

escondida e de contexto. A próxima Seção apresenta os resultados para um cenário mais complexo, no qual foram introduzidos dois nós para transmitir em canal lateral.

## 4.2 Experimento 2

Este experimento foi montado no mesmo local do experimento 1, com o objetivo de avaliar apenas a inclusão de um par de nós transmitindo em um canal adjacente. A configuração física da rede, ilustrada na Figura 4.14, é composta por um par de nós *A* e *B* se comunicando no canal 13 e um par de nós *C* e *D* em um canal adjacente por 15 segundos. Um quinto nó *E* foi conectado ao USRP para persistir e adquirir os dados.

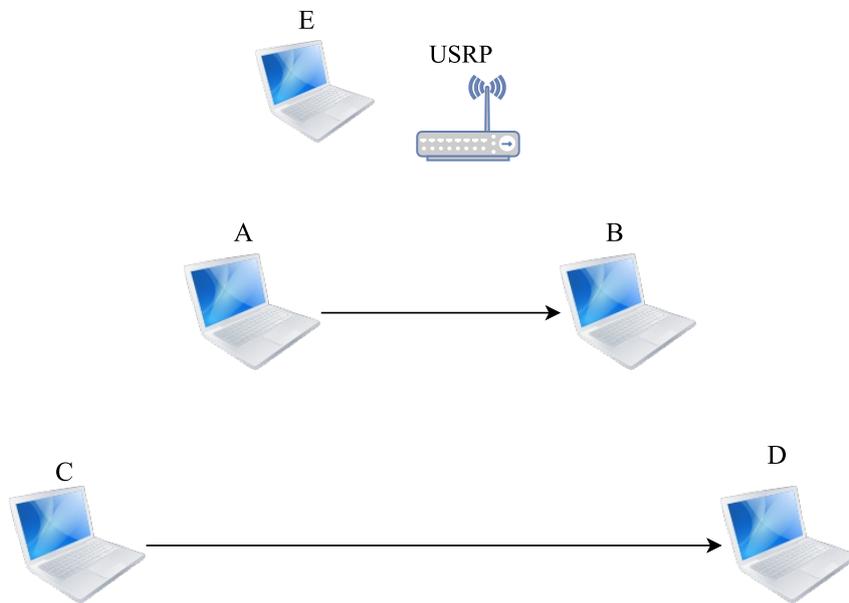


Figura 4.14: Cenário do experimento 2.

As duas primeiras coletas foram realizadas com *A* transmitindo para *B*, e *C* para *D*, e depois outras duas coletas foram executadas com o caminho inverso: de *B* para *A*, e de *D* para *C*. Os parâmetros das coletas realizadas são mostrados na Tabela 4.2.

Tabela 4.2: Parâmetros das coletas do experimento 2

Taxa de amostragem	Duração	Transmissão	Pacotes
25MHz	15s	3s + 3s	1024B

A coleta durou 15s, dos quais cada par de nós transmitiu por 3s pacotes de tamanho 1024B. Estes dados foram capturados a uma taxa de amostragem de 25MHz. As Figuras 4.15 e 4.16 ilustram os sinais adquiridos em uma coleta do grupo 1 e em uma do grupo

2, respectivamente. Em cada coleta, a aproximadamente 2s do início do experimento o primeiro par de nós ( $A, B$ ) começou a transmitir dados, e 1 segundo depois o segundo par ( $C, D$ ) começou sua transmissão.

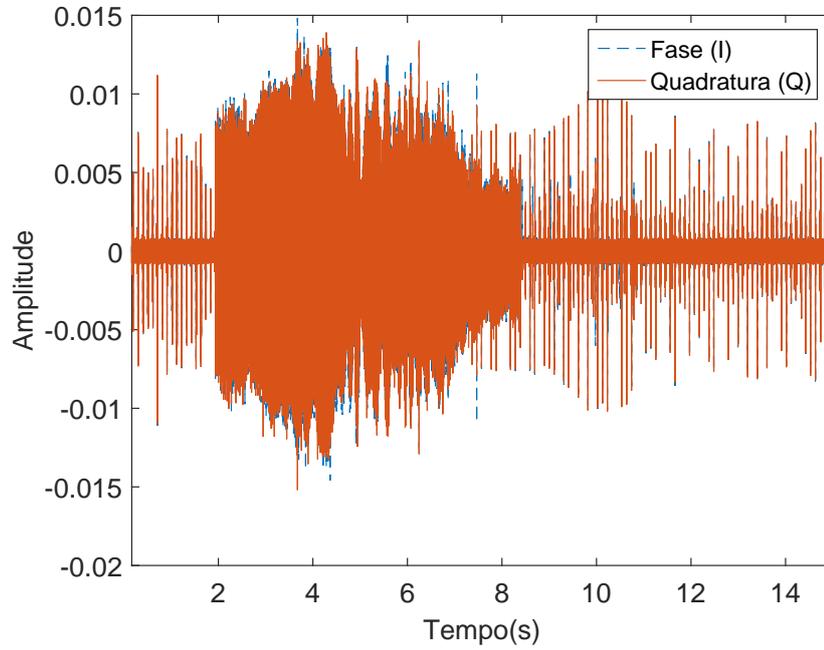


Figura 4.15: Sinais durante a transmissão  $A \rightarrow B$ .

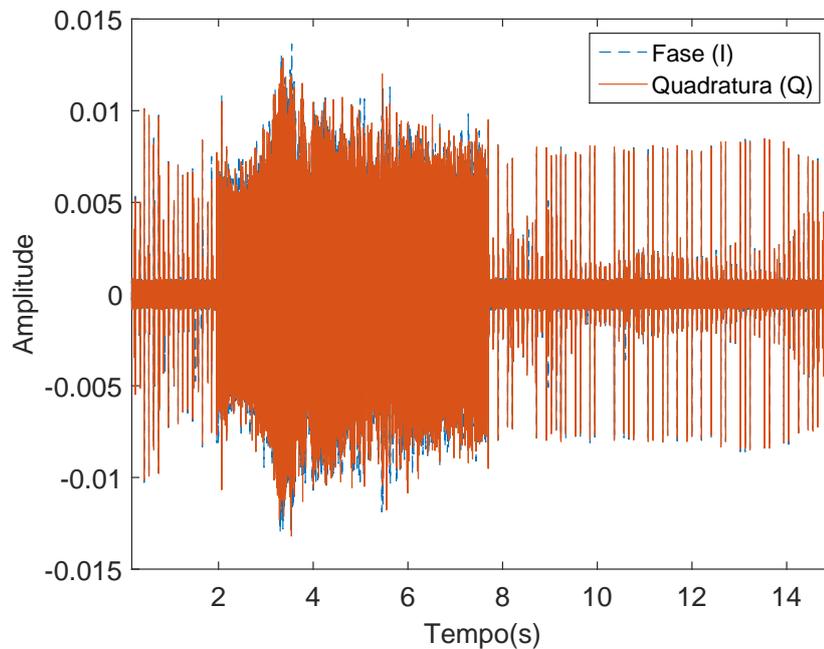


Figura 4.16: Sinais durante a transmissão inversa  $B \rightarrow A$ .

A Figura 4.17 mostra, de cima para baixo, os sinais  $I$  e  $Q$ , o sinal de energia e o espectrograma de uma parte da coleta. No tempo 3,46s identificamos um quadro, possivelmente um *Beacon*, que, conforme mostrado no espectrograma, está em uma faixa de frequência adjacente, e portanto é filtrado para o cálculo do sinal de energia. Isto está de acordo com os parâmetros estabelecidos para coleta, que inclui um par de nós transmitindo no canal lateral. No tempo 3,462s há um diálogo Dado-SIFS-Ack.

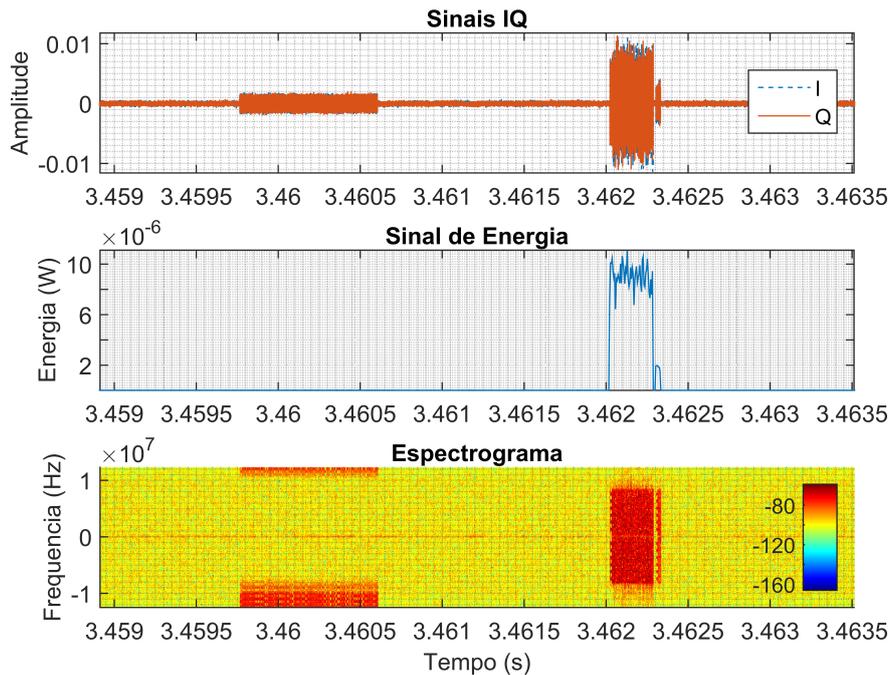


Figura 4.17: Sinais  $I$  e  $Q$ , sinal de energia e espectrograma de parte do experimento 2.

Em algumas partes da coleta, no entanto, houve forte interferência lateral, que não pôde ser completamente filtrada acarretando erros de limiarização. A Figura 4.18 exemplifica este cenário, que pode ser verificado observando-se os níveis de energia acima de 100 decibéis na porção inferior do espectrograma.

Foram treinadas 400 RNREs de classificação e 450 RNREs de identificação, divididas em conjuntos de 50, onde cada conjunto teve um número fixo de neurônios na camada escondida, seguindo o mesmo procedimento adotado no experimento 1. As Figuras 4.19 e 4.20 mostram, para cada conjunto de redes neurais as taxas de acerto, representadas por círculos, e a taxa de acerto média, representada pela linha contínua.

A taxa média de acerto das redes de classificação foi de 0,456, 4% menor que a do experimento 1, o que era esperado pois a interferência introduzida pela comunicação dos nós  $C$  e  $D$  deveria dificultar a classificação pela rede neural. A taxa média de acerto das

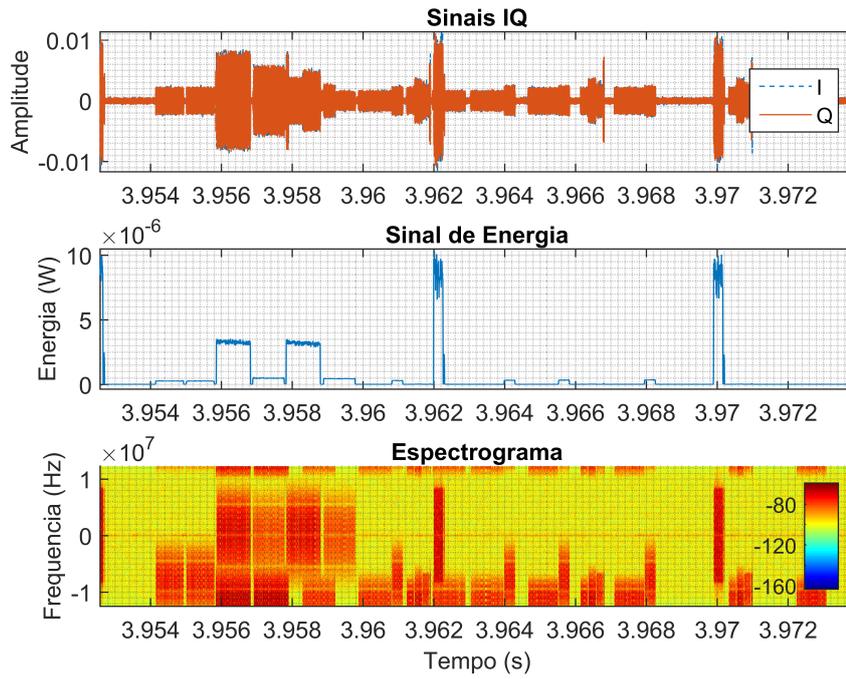


Figura 4.18: Espectrograma de uma parte do experimento 2.

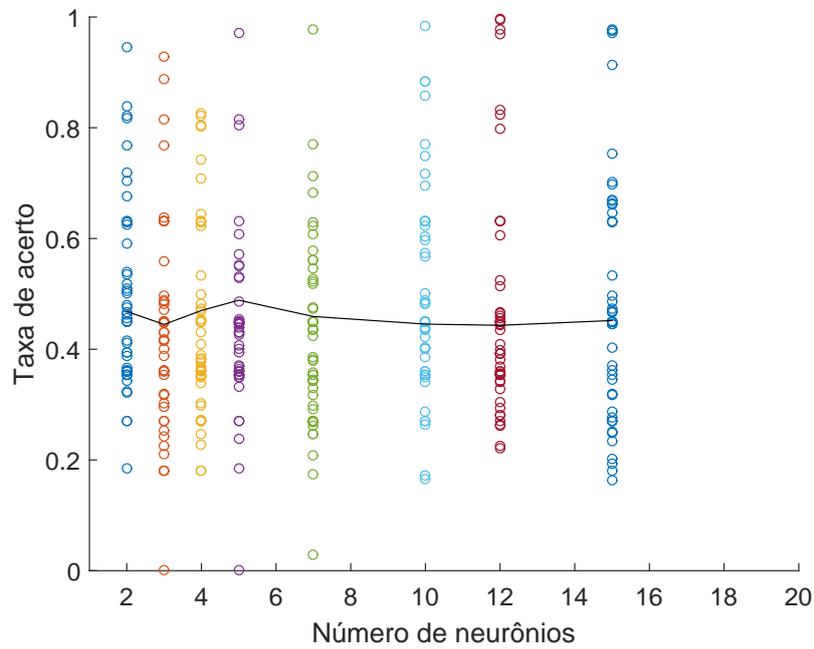


Figura 4.19: Taxa de acerto para RNREs de classificação.

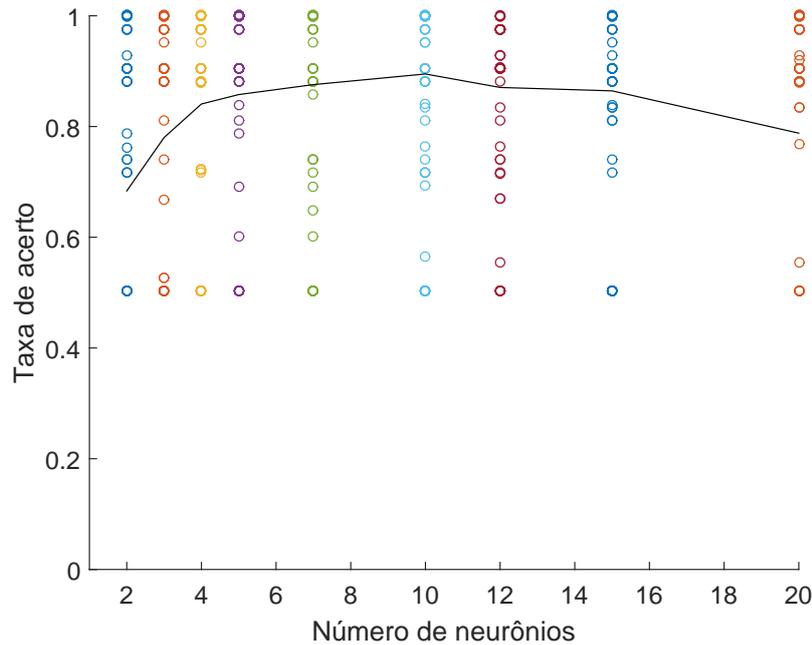


Figura 4.20: Taxa de acerto para RNREs de identificação.

redes de identificação foi de 0,817, 3% menor que a do experimento anterior. A menor taxa de acerto para as redes de identificação foi de 0,4917.

A matriz de confusão da rede neural de classificação com taxa de acerto mediana de 0,445, é apresentada na Figura 4.21. O eixo horizontal representa a classificação correta, o eixo vertical a saída da rede e as coordenadas correspondem aos números das classes de saída das redes neurais, expostas na Tabela 3.2.

A matriz de confusão indica que a RNRE acertou 98,7% das amostras do conjunto de validação, embora saída obtida não tenha apresentado nenhuma amostra classificada como 3 (*Beacon*) e 4 (*SIFS*). Todas as 26 amostras classificadas como Ack eram amostras de Dado.

O histograma e a probabilidade acumulada de oportunidades para diálogos terminados em Ack estão expostos nas Figuras 4.22 e 4.23 respectivamente. O histograma relaciona o número de oportunidades, no eixo horizontal, com a frequência de ocorrência, no eixo vertical. Já o segundo gráfico indica a probabilidade de se ter pelo menos  $n$  oportunidades, sendo  $n$  a coordenada no eixo horizontal.

O experimento 2 apresenta, em média, 20,189 oportunidades, 13% a menos que o experimento 1. Isto pode ser explicado pelo acréscimo dos nós  $C$  e  $D$  e pela interferência lateral presente em alguns momentos da coleta, como ilustrada na Figura 4.18. A probabilidade de haver 15 ou mais oportunidades, por exemplo, é de 75,862%, enquanto no

Ociosidade	1	30955 94.5%	0 0.0%	0 0.0%	64 0.2%	0 0.0%	99.8% 0.2%
Dado	2	0 0.0%	1375 4.2%	227 0.7%	0 0.0%	121 0.4%	79.8% 20.2%
Beacon	3	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
SIFS	4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
ACK	5	0 0.0%	26 0.1%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
		100% 0.0%	98.1% 1.9%	0.0% 100%	0.0% 100%	0.0% 100%	98.7% 1.3%
		1	2	3	4	5	
		Resposta correta					

Figura 4.21: Matriz de confusão do experimento 2.

experimento 1 foi de 90,510%.

As Figuras 4.24 e 4.25 apresentam os mesmos gráficos para oportunidades após um *Beacon*. O número médio de oportunidades após um *Beacon* é de 5,964, 22% a menos que no experimento anterior. 25% dos *Beacons* não precedem nenhuma oportunidade, embora 5% precedam mais de 15 oportunidades.

As Figuras 4.26 e 4.27 apresentam os mesmos gráficos anteriores para as RNREs de identificação. Observa-se que o número médio de oportunidades é de 16,134, 15% a menos que no experimento anterior, o que é esperado tendo em vista a interferência de canal lateral existente neste experimento.

O experimento 2 apresentou erros relacionados à etapa de limiarização causados por interferência lateral, que não estava prevista já que o ambiente de coleta é o mesmo do experimento 1. Por este motivo, o número de oportunidades levantado foi reduzido, dado que a interrupção da contagem de oportunidades é interrompida por ruído limiarizado para  $H_1$ . A próxima Seção descreve um experimento realizado em um ambiente com várias redes *Wi-Fi* operando em canais adjacentes.

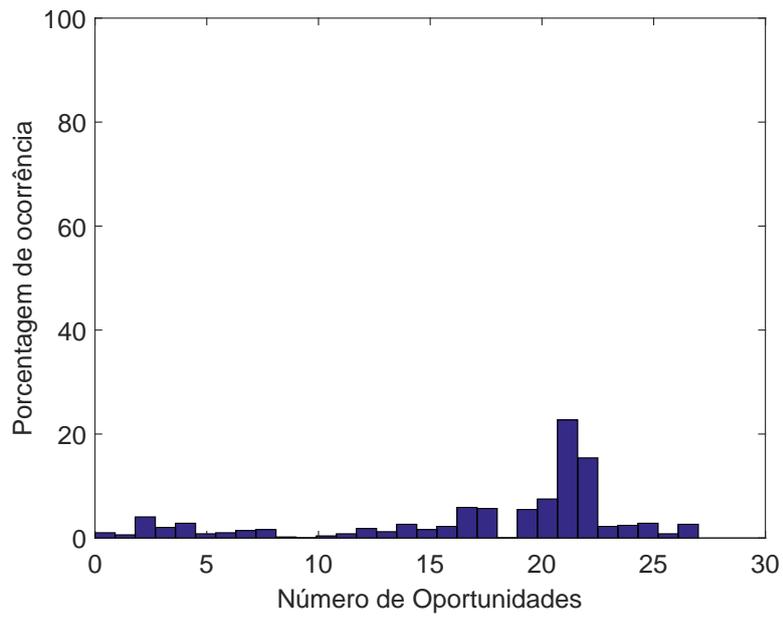


Figura 4.22: Histograma de oportunidades após um Ack.

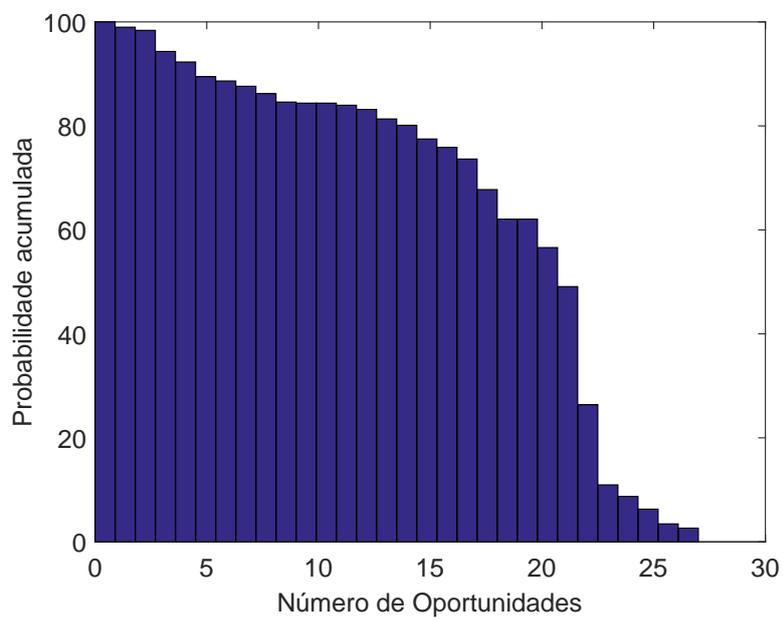


Figura 4.23: Probabilidade acumulada de oportunidade após um Ack.

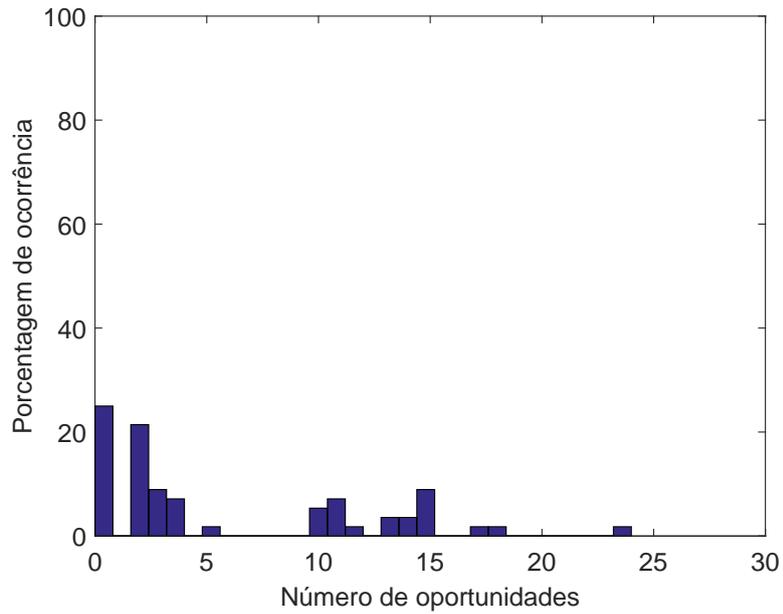


Figura 4.24: Histograma de oportunidades após um *Beacon*.

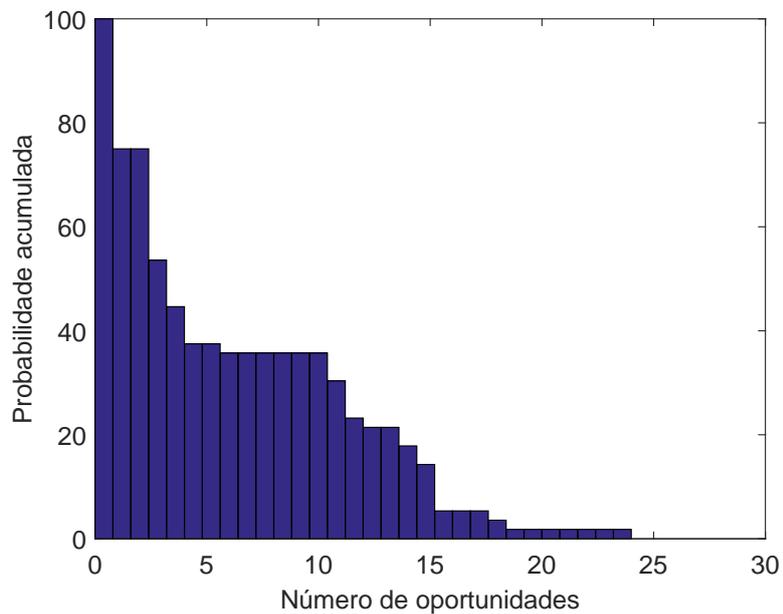


Figura 4.25: Probabilidade acumulada de oportunidade após um *Beacon*.

### 4.3 Experimento 3

O terceiro conjunto de coletas foi realizado no Laboratório de Redes de Computadores (COMNET) da Universidade de Brasília (UnB), para observar como o sistema se com-

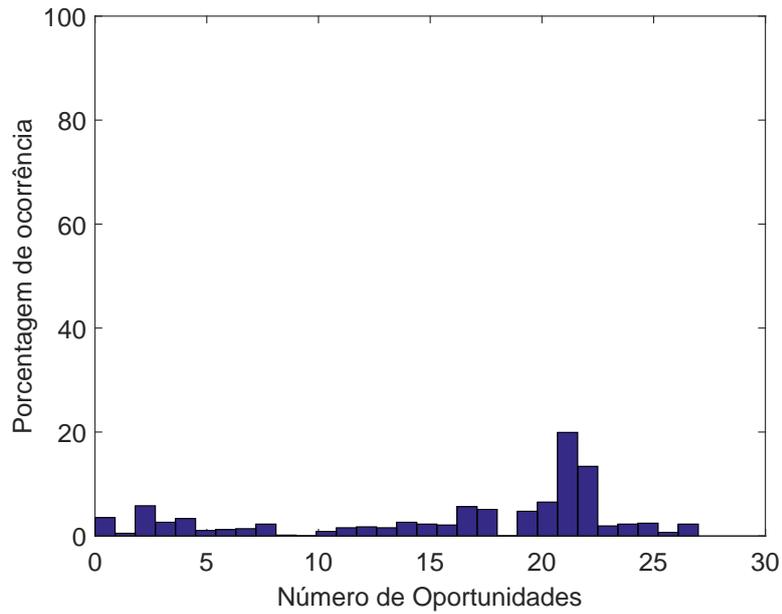


Figura 4.26: Histograma de oportunidades para as RNRE de identificação.

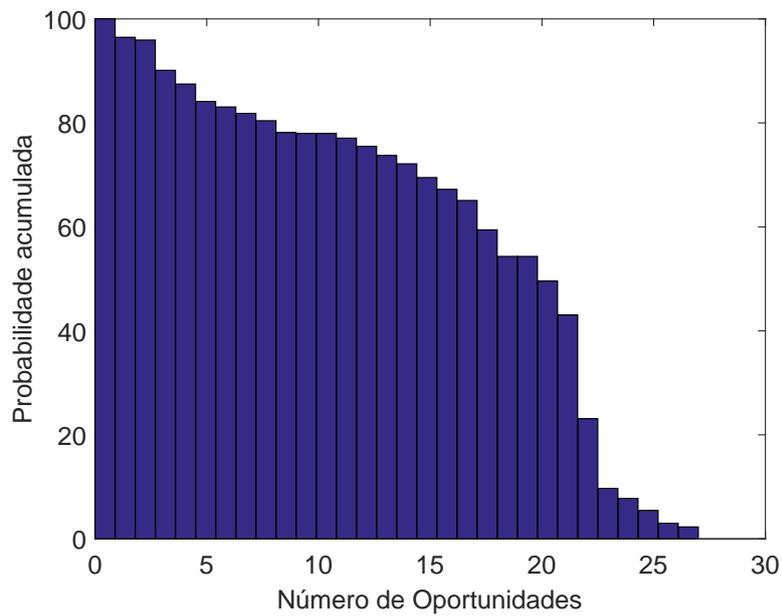


Figura 4.27: Probabilidade acumulada de oportunidade para as RNRE de identificação.

porta sob níveis de interferência e ruído mais altos. O ambiente continha várias redes competindo pelos canais, conforme mostra a Figura 4.28, gerada pelo *WiFi Analyzer*[50], um aplicativo disponibilizado na *Play Store* para a plataforma de dispositivos móveis An-

*droid*. O eixo horizontal da Figura é a potência em dBm, e o eixo horizontal os canais, de 1 a 12. Cada curva representa uma rede IEEE 802.11, e o nome acima de cada curva é o Identificador do Conjunto de Serviço (do Inglês, *Service Set Identifier*) (SSID) da rede. Por este gráfico podemos notar a grande ocupação do espectro neste ambiente.

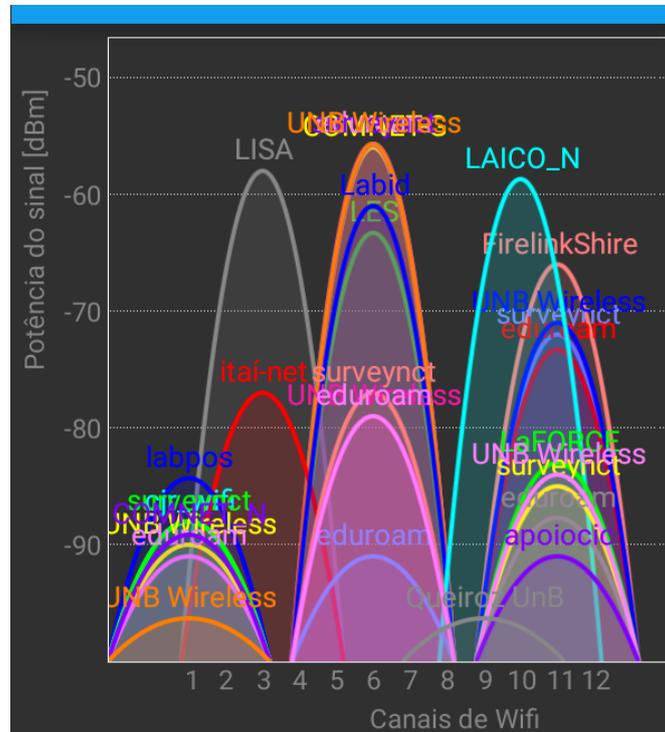


Figura 4.28: Redes existentes no COMNET (Fonte: [50]).

O cenário da coleta é ilustrado pela Figura 4.29, na qual os nós *A* e *B* ocuparam o canal 13 para transmitir dados entre si, enquanto os nós *C* e *D* transmitiam em um canal lateral. Os parâmetros da coleta estão apresentados na Tabela 4.3: os dados foram obtidos a uma taxa de 25MHz por 5s, período no qual os nós *A* e *B* se comunicaram através do canal sensoriado.

Tabela 4.3: Parâmetros das coletas do experimento 3

Taxa de amostragem	Duração	Transmissão	Pacotes
25MHz	5s	5s	1024B

Os sinais *I* e *Q* coletados são mostrados na Figura 4.30, em que o tempo da coleta é apresentado em segundos no eixo horizontal e a amplitude no eixo vertical. Diferente dos gráficos das outras coletas, neste gráfico não é identificável o início e final do período de transmissão de dados porque a transmissão ocorre em toda a duração da coleta

A Figura 4.31 apresenta, para uma parte da coleta, os sinais *I* e *Q*, o sinal de energia e o espectrograma. Os primeiros quadros enviados, aproximadamente no tempo 2,467s, são

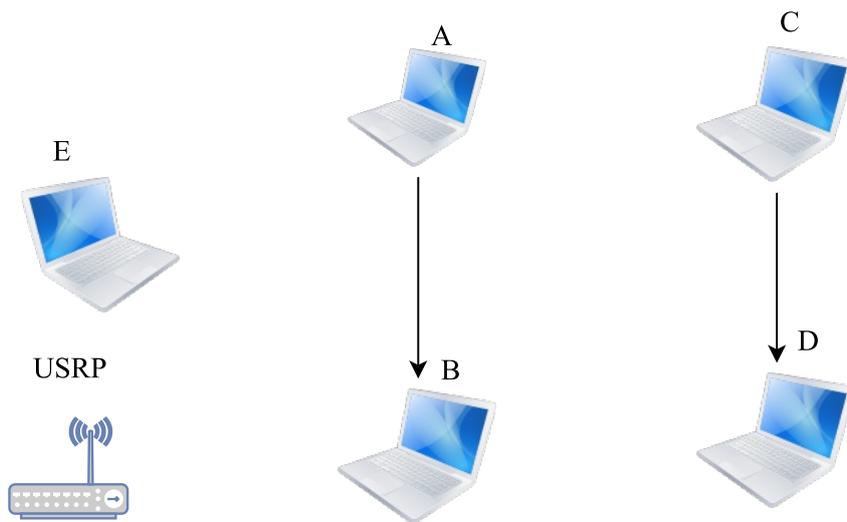


Figura 4.29: Cenário do experimento 3.

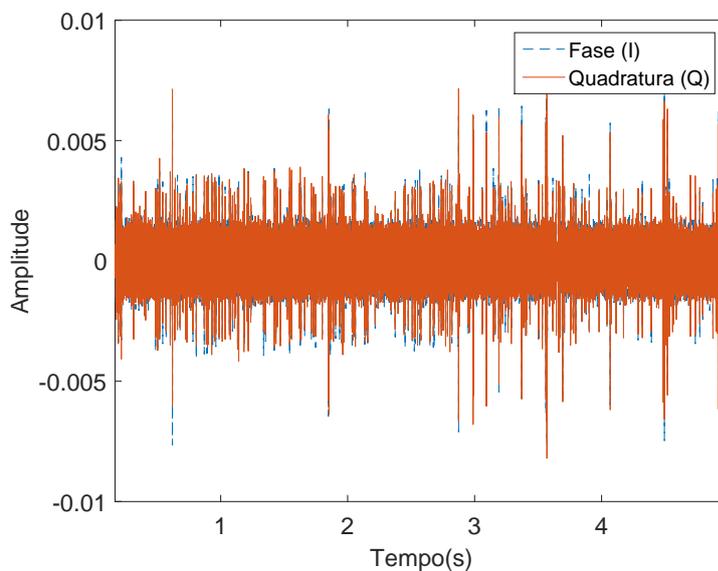


Figura 4.30: Sinais  $I$  e  $Q$  do experimento 3.

tentativas de transmissão de Dado. Logo após, uma terceira tentativa foi feita com nível de energia maior, e desta vez houve um Ack após um intervalo de SIFS. Aproximadamente no tempo 2,65s da coleta, podemos verificar a sobreposição do que parecem ser dois *Beacons*, um no canal de interesse e outro em canal adjacente. Assim como nas coletas anteriores, a filtragem do canal lateral reduziu a razão sinal-ruído o suficiente para que o processo de limiarização ocorresse sem erros. Este fato pode ser verificado no segundo gráfico, Sinal de Energia Filtrado, que apresenta um nível de energia elevado apenas nos intervalos em que o nível de energia do espectrograma é concentrado na parte central.

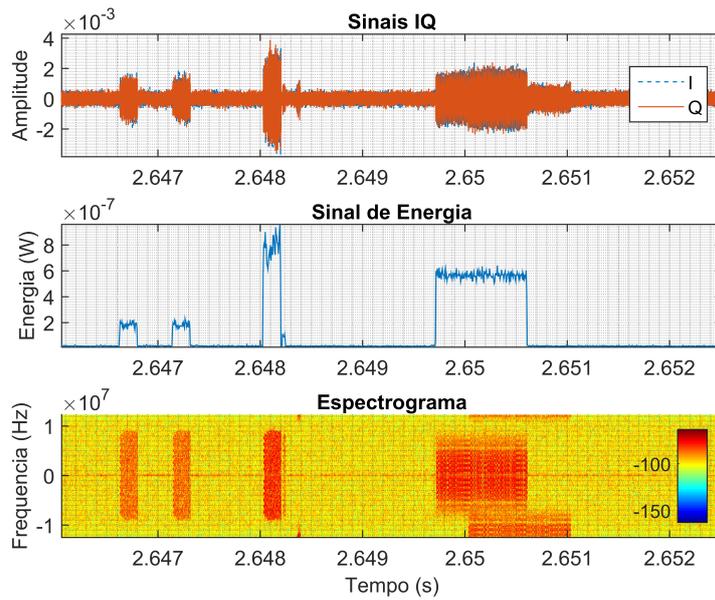


Figura 4.31: Sinais  $I$  e  $Q$ , sinal de energia e espectrograma de parte do experimento 3.

Foram treinadas 350 redes RNREs de classificação e 400 RNREs de identificação, cujo desempenho é apresentado nas Figuras 4.32 e 4.33, nas quais os círculos representam a taxa de acerto para cada rede neural treinada e a linha contínua a taxa de acerta média para um conjunto de redes com número de neurônios na camada escondida fixo, expresso pelo eixo horizontal.

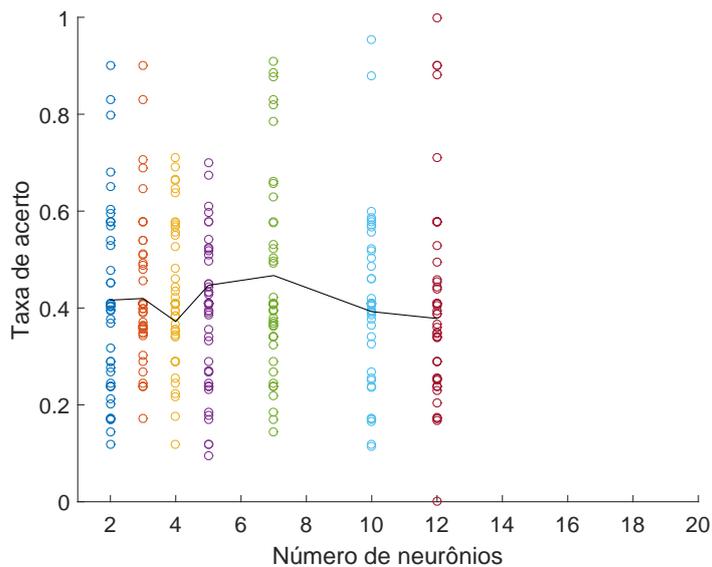


Figura 4.32: Taxas de acertos para RNREs de classificação.

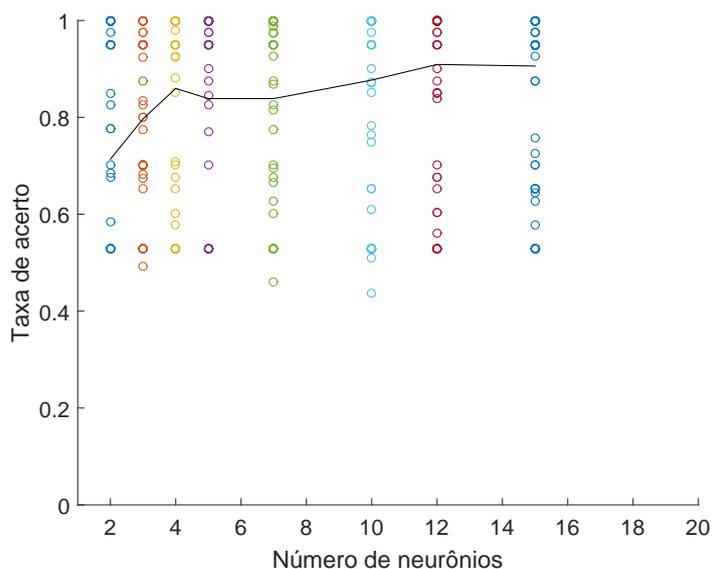


Figura 4.33: Taxas de acertos para RNREs de identificação.

A taxa média de acerto das RNREs de classificação foi de 0,413, 9% menor que a do experimento anterior. Este decremento pode ser explicado pela diferença do nível de ruído do conjunto selecionado para validação das redes neurais a entrada do conjunto de validação do experimento 2 apresenta  $SNR = 22,545$ , e para o experimento 3  $SNR = 8,339$ . A taxa média de acerto das redes de identificação foi de 0,825, 1% maior que a do experimento anterior, o que indica que não há o mesmo aumento de complexidade para o problema de identificação de oportunidades.

A matriz de confusão da rede neural de classificação com taxa de acerto mediana de 0,408, é apresentada na Figura 4.34. A taxa de acerto não ponderada é de 98,6%. Assim como nos outros experimentos, nem todas as classes estão presentes na saída da rede neural: não há nenhuma amostra classificada como 4 (SIFS) e 5 (Ack) na saída da rede. Das 57 amostras classificadas como *Beacon*, 35 eram SIFS e 22 eram ociosidade.

As Figuras 4.35 e 4.36 apresentam o histograma e a probabilidade acumulada de oportunidades para o experimento 3 para diálogos terminados em Ack. A média de oportunidades após um Ack para o experimento 3 é de 18,786, 7% maior que o do experimento anterior. Isto ocorre porque a interferência lateral observada neste experimento é menor.

As Figuras 4.37 e 4.38 apresentam os mesmos gráficos de histogramas e probabilidades acumuladas de oportunidades após quadros de *Beacon*. O número médio de oportunidades após um *Beacon* é de 8,212, 18% a menos que no experimento anterior.

As Figuras 4.26 e 4.27 apresentam o histograma e probabilidade acumulada de oportunidades para as RNREs de identificação. O número médio de oportunidades para as

Ociosidade	1	31002 94.6%	0 0.0%	0 0.0%	65 0.2%	0 0.0%	99.8% 0.2%
Dado	2	0 0.0%	1307 4.0%	226 0.7%	0 0.0%	111 0.3%	79.5% 20.5%
Beacon	3	22 0.1%	0 0.0%	0 0.0%	35 0.1%	0 0.0%	0.0% 100%
SIFS	4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
ACK	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
		99.9% 0.1%	100% 0.0%	0.0% 100%	0.0% 100%	0.0% 100%	98.6% 1.4%
		1	2	3	4	5	
		Resposta correta					

Figura 4.34: Matriz de confusão do experimento 3.

RNREs de identificação é 17,756, 10% a mais que no experimento anterior, o que reflete as diferenças explicitadas nos histogramas das RNREs de classificação.

A próxima seção descreve um experimento no qual múltiplos usuários transmitem pacotes com tamanhos variados, o que representa um aumento de complexidade dos sinais no ambiente sensoriado.

## 4.4 Experimento 4

Este conjunto de coletas foi estruturado com o objetivo de avaliar o desempenho do sistema em um cenário com interferência lateral, múltiplos usuários na rede no mesmo canal e variação no tamanho dos pacotes. A topologia da rede montada é mostrada na Figura 4.41. Os nós *A*, *B*, *C* e *D* se comunicaram no mesmo canal, enquanto o nó *E* apenas coletou os dados através do USRP.

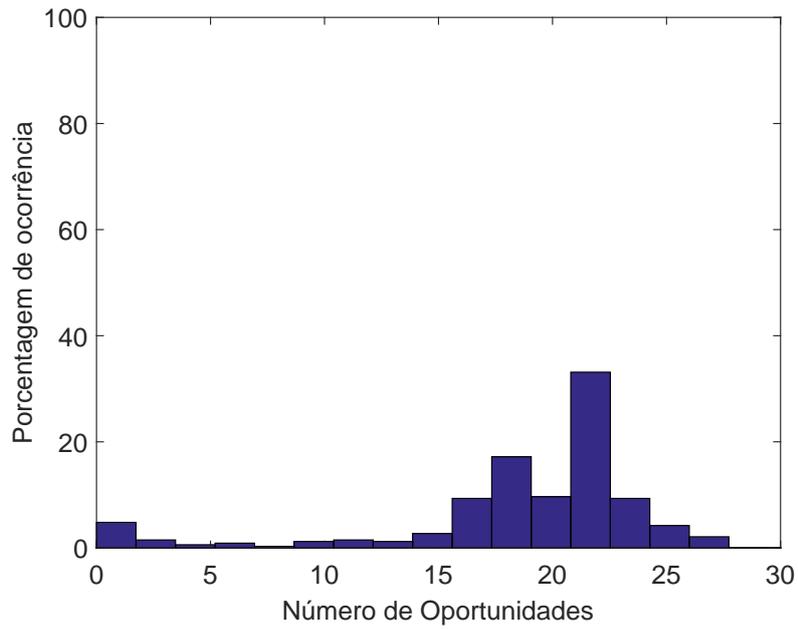


Figura 4.35: Histograma de oportunidades após um Ack.

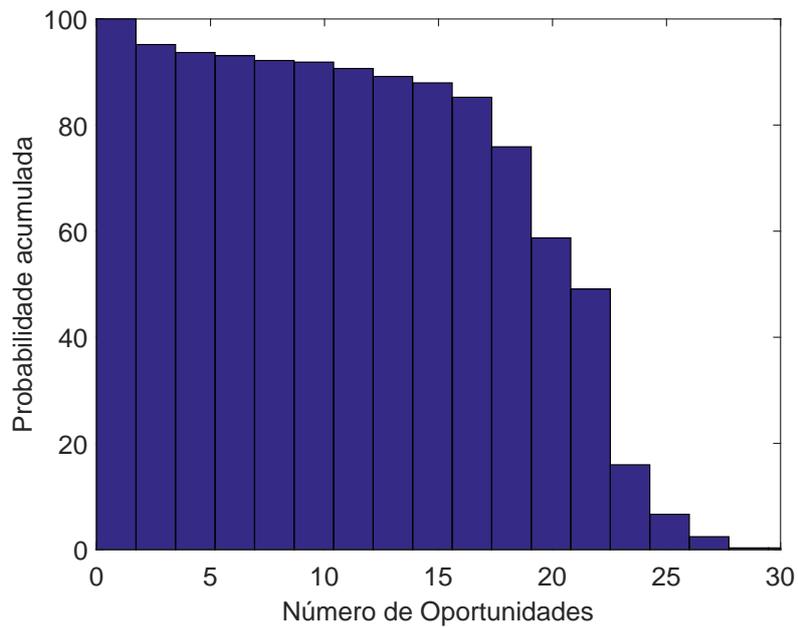


Figura 4.36: Probabilidade acumulada de oportunidades após um Ack.

Os parâmetros da coleta se encontram na Tabela 4.4. Os nós transmitiram durante os 7 segundos da coleta, com o tamanho dos pacotes variando sob uma distribuição normal

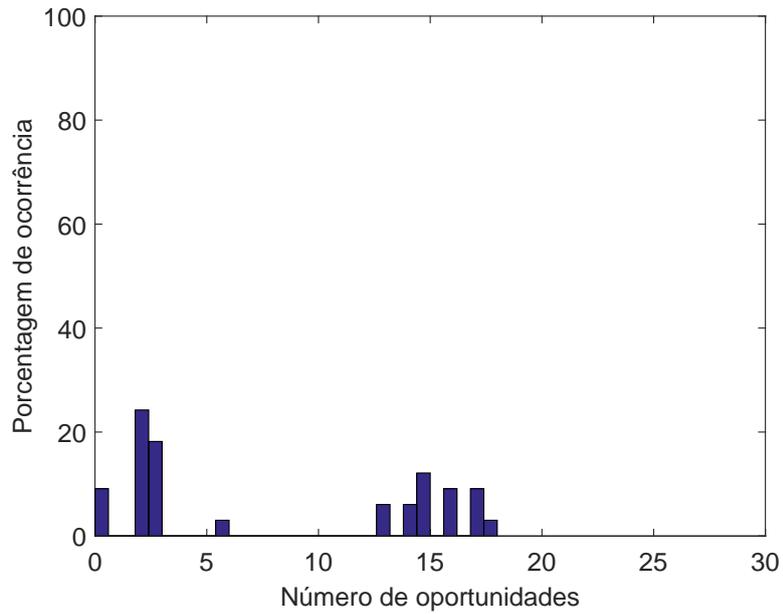


Figura 4.37: Histograma de oportunidades após um *Beacon*.

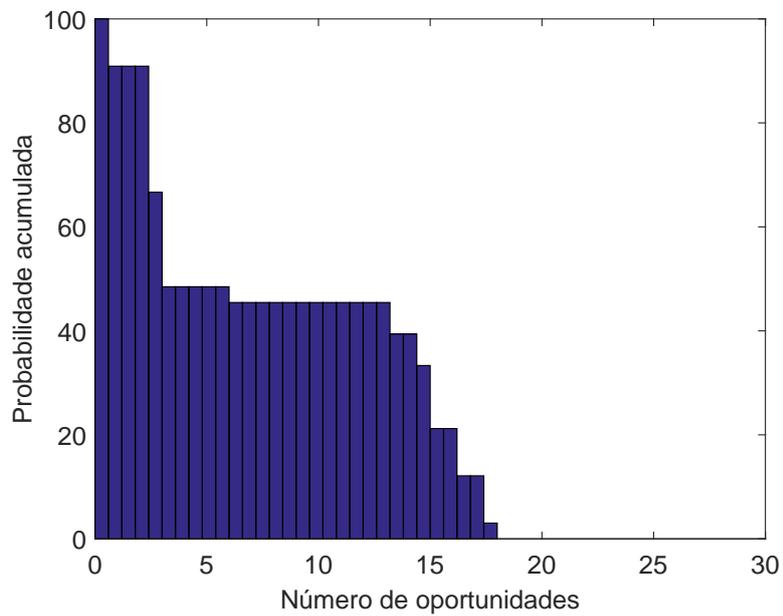


Figura 4.38: Probabilidade acumulada de oportunidade após um *Beacon*.

de 512 a 1024 *bytes*.

A Figura 4.42 apresenta os sinais *I* e *Q* da coleta, na qual há transmissão de pacotes no canal aproximadamente do tempo 3s até o tempo 8s. A Figura 4.43 mostra o os sinais

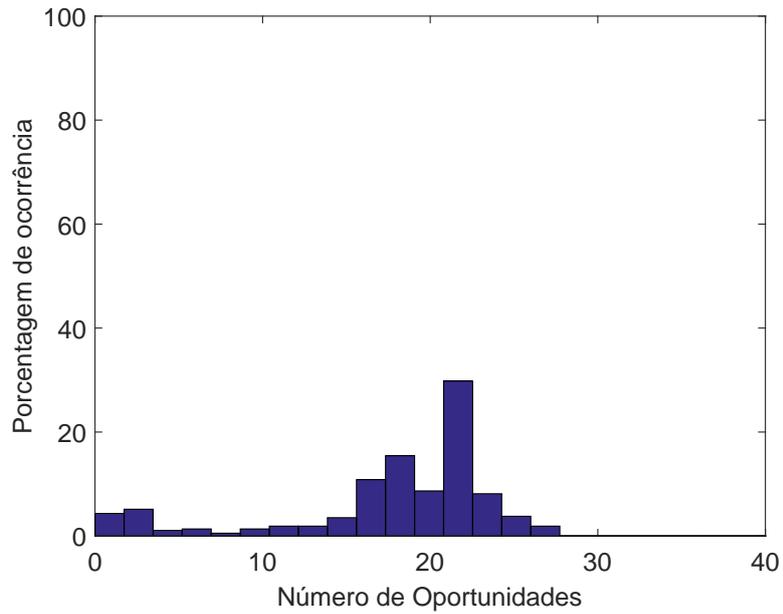


Figura 4.39: Histograma de oportunidades para a RNRE de identificação.

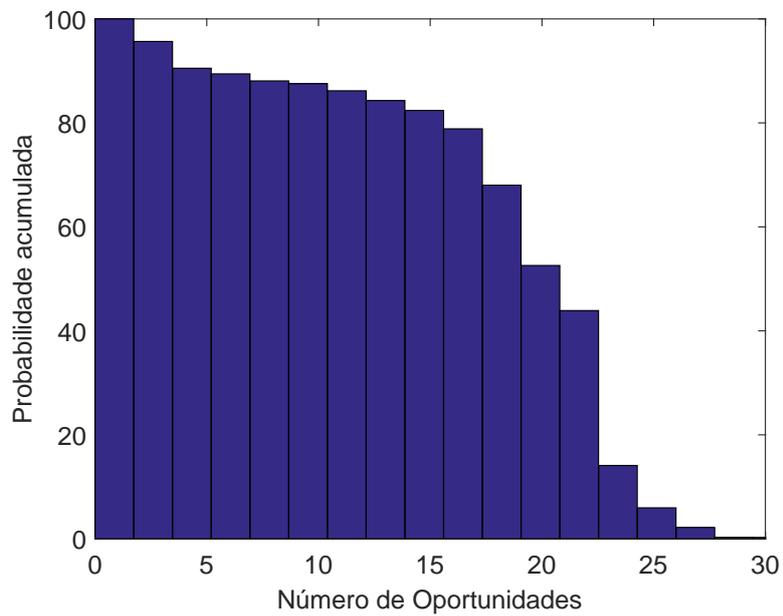


Figura 4.40: Probabilidade acumulada de oportunidade para a RNRE de identificação.

$I$  e  $Q$ , a energia e o espectrograma para um intervalo de um centésimo de segundo da coleta. Aos 4,392s foi enviado um Dado, seguido por um Ack com nível de energia mais baixo. Logo depois são feitas três tentativas de envio de Dado, também com um nível

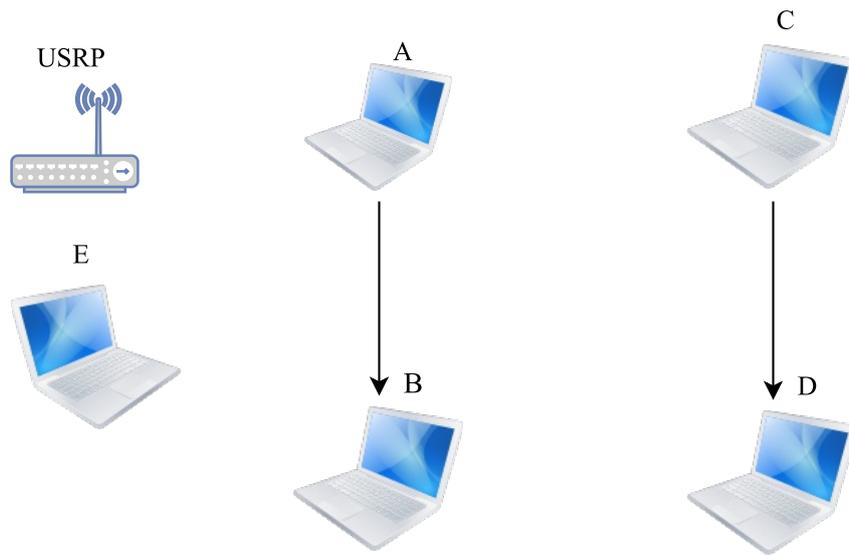


Figura 4.41: Cenário do experimento 4.

Tabela 4.4: Parâmetros das coletas do experimento 4

Taxa de amostragem	Duração	Transmissão	Pacotes
25MHz	10s	5s+5s	1024B

baixo de energia, e um Ack é enviado após a terceira tentativa.

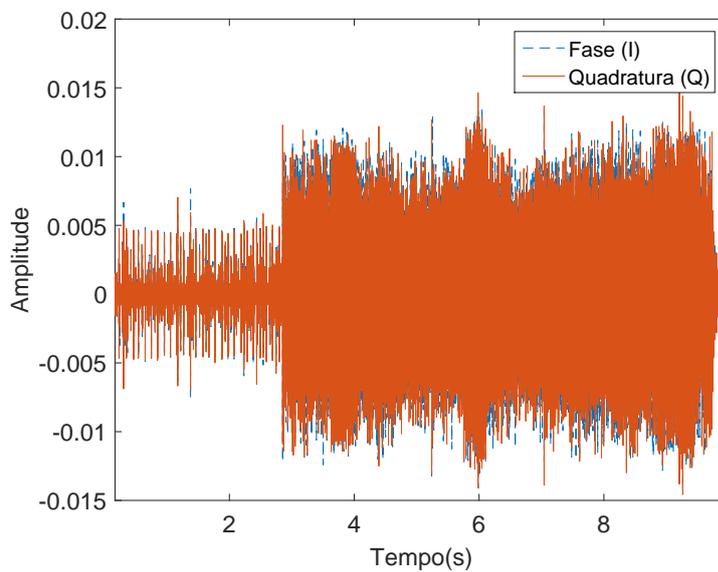


Figura 4.42: Sinais coletados no experimento 4.

O padrão apresentado na Figura 4.43 é repetido diversas vezes no decorrer da coleta, e o processo de limiarização apresentou erros na detecção do primeiro Ack e das três tentativas

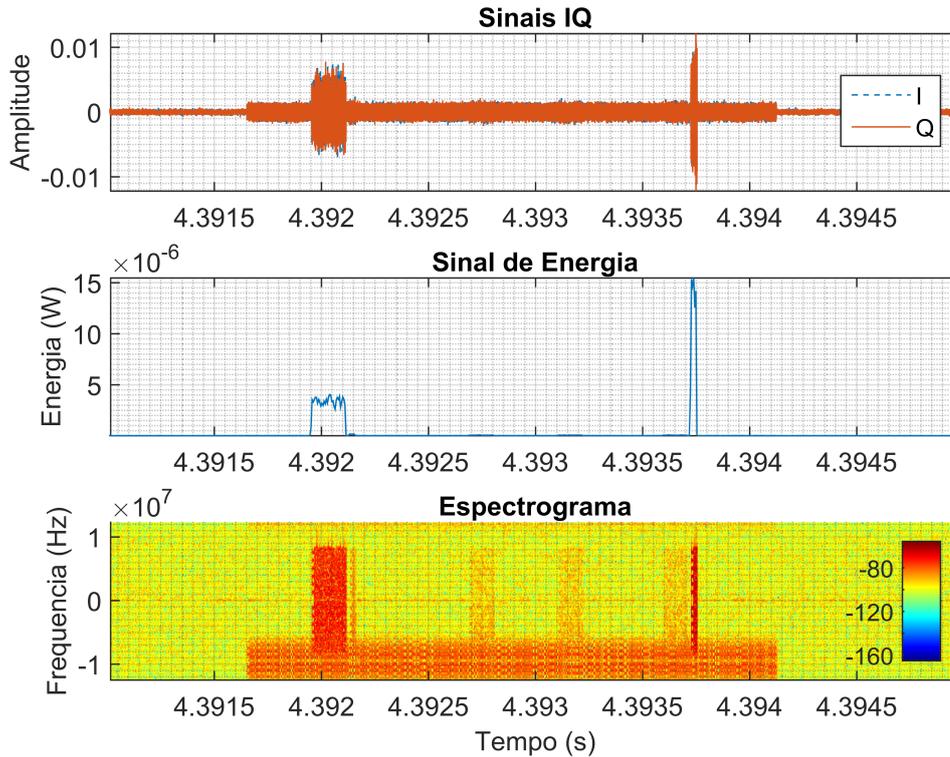


Figura 4.43: Sinais  $I$  e  $Q$ , sinal de energia e espectrograma de parte do experimento 4.

de transmissão de Dado. Para levar isto em consideração, o processo de treinamento deste experimento é diferente dos anteriores. Primeiramente, como nem todos os quadros foram limiarizados corretamente, foram treinadas apenas RNREs de identificação. O conjunto de treino foi composto também por sinais que seguiam o padrão apresentado na Figura, nos quais o *target* apresenta classe 2 (pode preceder oportunidades) apenas após o segundo ACK. O desempenho das 450 RNREs de identificação é apresentado na Figura 4.44.

A taxa média de acerto das redes de identificação foi de 0,8458, 2% maior que a do experimento anterior. Esta diferença pode ser explicada pela modelagem do conjunto de treino, cujas saídas são estruturadas de forma diferente, conforme explicado anteriormente.

As Figuras 4.45 e 4.46 apresentam o histograma e a probabilidade acumulada de oportunidades. A média de oportunidades foi de 4,138, 77% a menos que a do experimento anterior. Esta diferença pode ser explicada pelo aumento da interferência, pelos erros de limiarização e a diferente modelagem do conjunto de treino.

Os resultados experimentais apresentados nesta Seção, tais como desempenho das redes neurais de classificação e identificação, e probabilidade de oportunidades, são analisados e comparados a seguir.

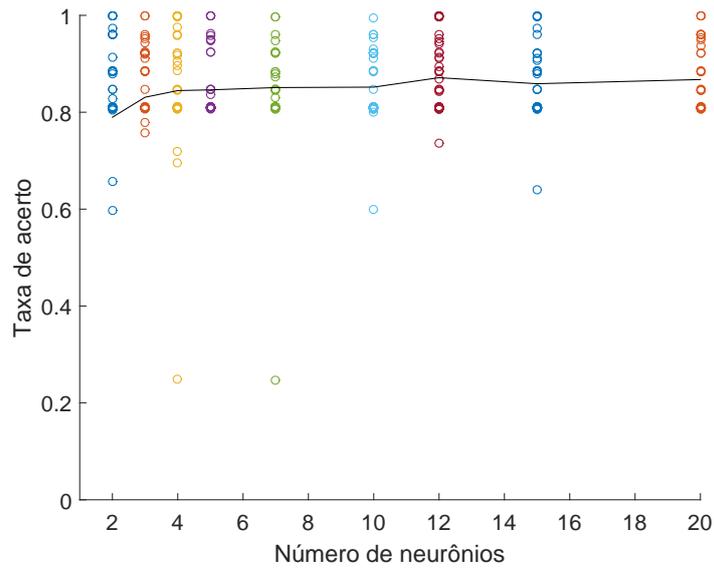


Figura 4.44: Taxa de acerto das RNREs de identificação no experimento 4.

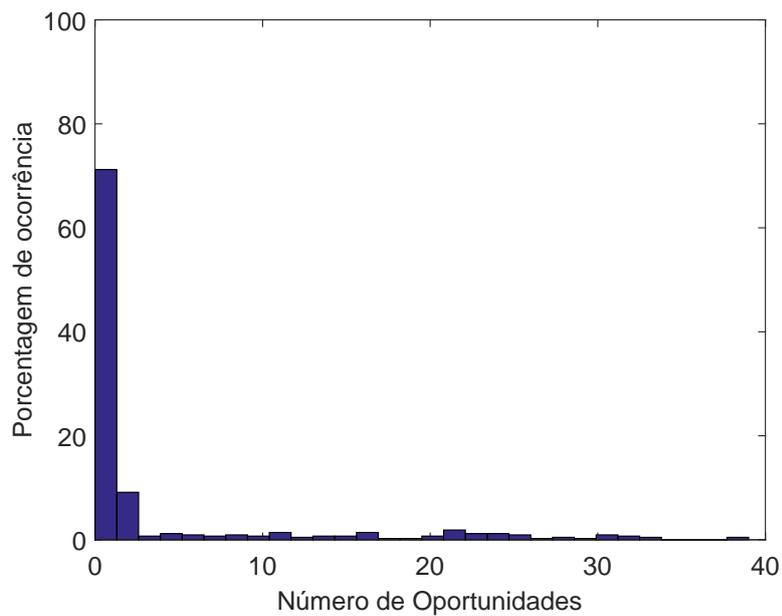


Figura 4.45: Histograma de oportunidades para a RNRE de identificação.

## 4.5 Discussão

Este capítulo apresentou os parâmetros e resultados dos experimentos realizados para avaliar a metodologia proposta. Esta seção resume e compara o desempenho das redes neurais e o número de oportunidades levantado para cada cenário.

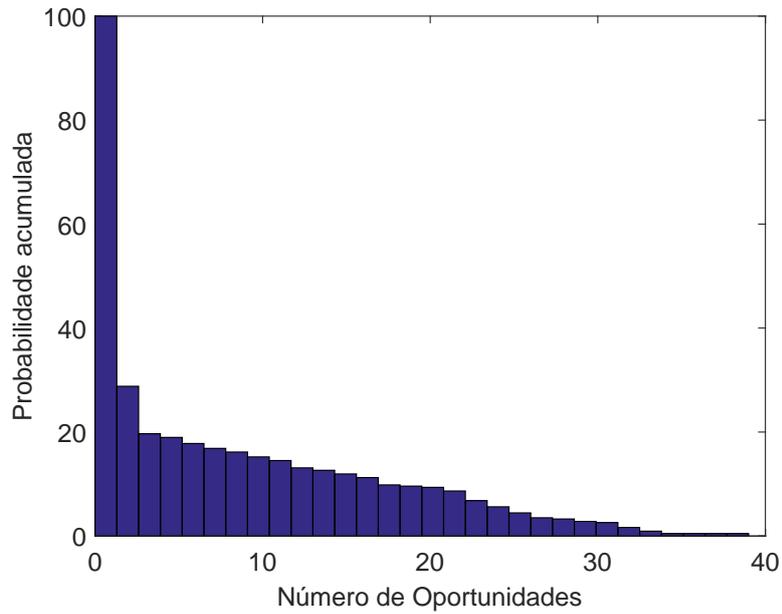


Figura 4.46: Probabilidade acumulada de oportunidade para a RNRE de identificação.

A Figura 4.47 ilustra os desempenhos médios das RNREs de classificação para cada experimento. O eixo horizontal representa o número de neurônios, e o eixo vertical a taxa de acerto média. Por exemplo, a taxa de acerto média das RNREs de 2 neurônios é de 0,441, e para as RNREs de 12 neurônios do mesmo experimento é 0,470.

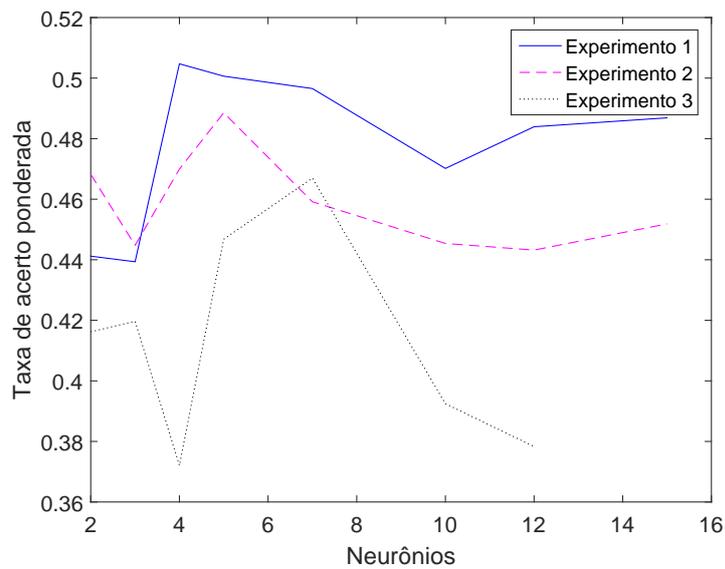


Figura 4.47: Taxa de acerto por número de neurônios para os experimentos.

O nível de interferência lateral e a SNR das coletas impactaram diretamente nas taxas de acerto médias das redes neurais de classificação: do experimento 1 para o experimento 3, há um decréto de 13%.

A Figura 4.48 ilustra os desempenhos médios das RNREs de identificação para cada experimento. Há um incremento não monotônico do desempenho com o aumento do número de neurônios na camada escondida. De maneira geral, conclui-se que uma rede neural de apenas 4 neurônios obtém uma taxa de acerto média acima de 80% para todos os cenários observados.

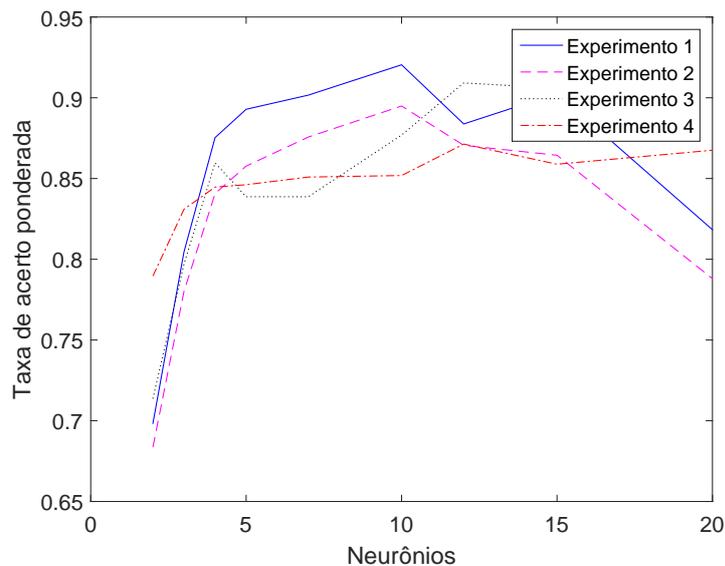


Figura 4.48: Taxa de acerto por número de neurônios para os experimentos.

O tempo de treinamento das estruturas de redes neurais testadas também foram mensurados. A Figura 4.49 mostra um exemplo da influência do número de neurônios na camada escondida no tempo de treinamento, representado pela linha contínua cuja escala se encontra à esquerda. Uma RNA com 20 neurônios atinge um desempenho semelhante a uma RNA com 4 neurônios, mas possui tempo de treinamento mais de 50 vezes maior.

Em relação à probabilidade acumulada de oportunidades, pode-se estabelecer uma confiabilidade de  $p$  e calcular o número de oportunidades  $n$  a serem exploradas. A Tabela 4.5 apresenta, para cada experimento, o número de oportunidades com confiabilidade  $p = 85\%$  após Ack, após Beacon e através das RNREs de identificação. Alternativamente, podemos estabelecer um número de oportunidades  $n$  e calcular  $p$ . A Tabela 4.6 indica a confiabilidade para cada experimento, com número de oportunidades  $n = 10$ .

Conclui-se das Tabelas 4.5 e 4.6 que problemas de limiarização, por interromperem a contagem de oportunidades, podem reduzir substancialmente a probabilidade acumulada calculada.

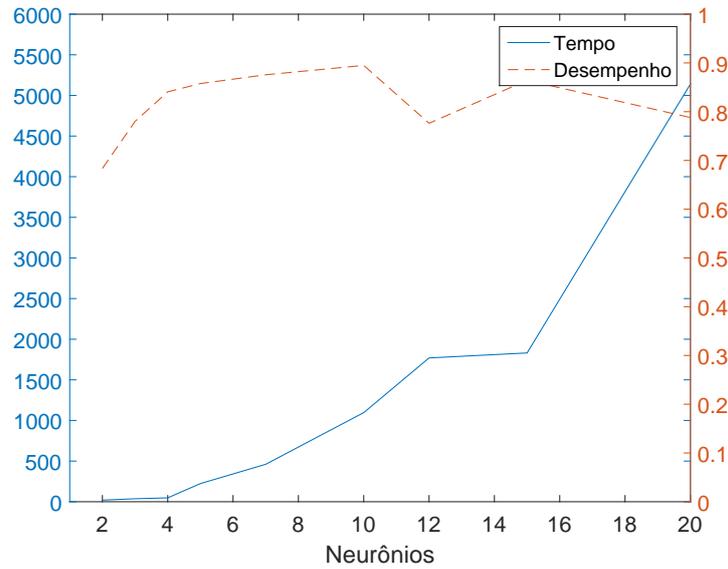


Figura 4.49: Desempenho x tempo x número de neurônios.

Tabela 4.5: Número de oportunidades com 85% de confiabilidade

experimento	RNA de classificação		RNA de identificação
	Após Ack	Após <i>Beacon</i>	
1	16	2	14
2	7	0	4
3	16	2	11
4	N/A	N/A	0

Tabela 4.6: Confiabilidade para 10 oportunidades

Experimento	RNA de classificação		RNA de identificação
	Após Ack	Após <i>Beacon</i>	
1	94%	51%	89%
2	84%	35%	77%
3	91%	45%	87%
4	N/A	N/A	15%

# Capítulo 5

## Conclusões

Este trabalho visou propor uma metodologia de previsão de oportunidades de transmissão, que é um desafio na implementação do DSA. Para tal, propôs uma metodologia que consiste na aquisição e processamento dos sinais, análise dos sinais por RNREs e estimativa da probabilidade acumulada de oportunidades no tempo. Foram introduzidos conceitos de políticas de alocação do espectro, estruturas de redes neurais, e do protocolo IEEE 802.11, que serviram de subsídio para compreensão dos experimentos conduzidos. Os experimentos foram construídos de forma a testar a metodologia sob diferentes cenários, a partir da variação de parâmetros tais como nível de ruído e interferência, quantidade de terminais e tamanho dos pacotes.

Os resultados obtidos mostram que RNREs de identificação de oportunidades com apenas 4 neurônios na camada escondida obtiveram taxa de acerto média ponderada acima de 80% para todos os experimentos, considerando-se um conjunto de 50 redes neurais treinadas com esta estrutura para cada ambiente. Para o experimento com alto nível de interferência e baixa razão sinal ruído, além de múltiplos dispositivos no canal, no entanto, a modelagem do conjunto de treino foi feita de forma diferente para considerar a dificuldade de limiarização neste ambiente, o que resultou numa redução substancial do número de oportunidades a ser explorado. Com confiabilidade 85%, por exemplo, não é possível explorar nenhuma oportunidade, enquanto no experimento com menor nível de interferência podem ser exploradas 14 oportunidades com a mesma confiabilidade.

A metodologia apresentada neste trabalho, bem como parte dos resultados experimentais, foi publicada e apresentada no MASS 2016 (*13th IEEE International Conference on Mobile Ad Hoc and Sensor Systems*), classificado como B1 no Qualis CAPES 2012, e no WPOS/WCOMP do Departamento de Computação da Universidade de Brasília. As discussões promovidas com pesquisadores da área foram proveitosas, e contribuíram para a continuidade do trabalho.

### **Trabalhos Futuros**

A metodologia proposta, assim como os resultados obtidos através da aplicação da metodologia, abrem espaço para trabalhos de melhoria, testes, e expansão de escopo. Os seguintes trabalhos já foram mapeados para execução pelo grupo de pesquisa:

- **Testes em ambientes mais complexos.** A variação dos parâmetros do ambiente se mostrou como um fator chave para o desempenho do sistema proposto. Um passo importante, portanto, é testar a generalidade da solução, para a partir deste levantamento elaborar melhorias.
- **Simulação no *Omnet ++*.** Esta simulação permite ter total controle dos parâmetros das transmissões que ocorrem no ambiente, e uma precisão maior na análise dos resultados.
- **Teste com outras RNAs, como a NARX.** Um comparativo de RNAs tem como objetivo a redução do tempo de treinamento e da taxa de erro na classificação e predição de oportunidades.
- **Melhoria do passo 5, com utilização de RNAs.** A predição da quantidade de oportunidades na atual implementação é puramente estatística, a partir da contagem de amostras de zero energia limiarizadas. A construção de conhecimento a respeito da série temporal de oportunidades com sensibilidade do contexto poderia aprimorar a precisão do sistema.
- **Treinamento *online* das RNREs.** O treinamento até o presente momento ocorreu previamente à execução, o que não aconteceria em um cenário de utilização real do sistema pelo usuário secundário.
- **Implementação do sistema na FPGA do USRP.** Uma vez que o treinamento *online* esteja funcionando, as etapas da metodologia passam a ser executadas paralelamente em um ambiente não simulado. O tempo de execução de cada etapa passa a ser um fator chave da solução.

# Referências

- [1] ANATEL: *Plano de atribuição, distribuição e destinação de radiofrequências*, 2016. <http://www.anatel.gov.br/setorregulado/atribuicao-destinacao-e-distribuicao-de-faixas>, [Último acesso 04-Outubro - 2016]. viii, 76
- [2] ANATEL: *Lei número 9472 atualizada em 26 de agosto de 2016*, 2001. <http://www.anatel.gov.br/legislacao/leis/2-lei-9472#art19>, [Último acesso 01-Outubro - 2016]. 1, 5
- [3] Čabrić, Danijela, Shridhar Mubaraq Mishra, Daniel Willkomm, Robert Brodersen e Adam Wolisz: *A cognitive radio approach for usage of virtual unlicensed spectrum*. Em *In Proc. of 14th IST Mobile Wireless Communications Summit 2005*, 2005. 1, 5
- [4] McHenry, Mark A., Peter A. Tenhula, Dan McCloskey, Dennis A. Roberson e Cynthia S. Hood: *Chicago spectrum occupancy measurements & analysis and a long-term studies proposal*. Em *Proceedings of the First International Workshop on Technology and Policy for Accessing Spectrum*, TAPAS '06, New York, NY, USA, 2006. ACM, ISBN 1-59593-510-X. <http://doi.acm.org/10.1145/1234388.1234389>. 1, 5, 6
- [5] MATLAB: *Neural network toolbox*, 2016. <https://www.mathworks.com/products/neural-network.html>, [Último acesso 20-Dezembro - 2016]. 2
- [6] Elman, Jeffrey L.: *Finding structure in time*. COGNITIVE SCIENCE, 14(2):179–211, 1990. 3, 17
- [7] Tabakovic, Zeljko, Sonja Grgic e Mislav Grgic: *Dynamic spectrum access in cognitive radio*. Em *ELMAR, 2009. ELMAR'09. International Symposium*, páginas 245–248. IEEE, 2009. 4
- [8] Simis, Anita: *A legislação sobre as concessões na radiodifusão*. São Leopoldo: UNIREvista, 1(3), 2006. 5
- [9] Wimmer, Miriam, Octavio Penna Pieranti e Márcio Iorio Aranha: *O paradoxo da internet regulada: a desregulação dos serviços de valor adicionado no brasil*. Revista Eptic, 11(3), 2011. 5
- [10] Ghasemi, N e SM Hosseini: *Comparison of smart grid with cognitive radio: Solutions to spectrum scarcity*. Em *Advanced Communication Technology (ICACT), 2010 The 12th International Conference on*, volume 1, páginas 898–903. IEEE, 2010. 5

- [11] Čabrić, Danijela, Shridhar Mubaraq Mishra, Daniel Willkomm, Robert Brodersen e Adam Wolisz: *A cognitive radio approach for usage of virtual unlicensed spectrum*. Em *Proc. of 14th IST mobile wireless communications summit*, páginas 1–4, 2005. 5
- [12] Cabric, Danijela, Shridhar Mubaraq Mishra e Robert W Brodersen: *Implementation issues in spectrum sensing for cognitive radios*. Em *Signals, systems and computers, 2004. Conference record of the thirty-eighth Asilomar conference on*, volume 1, páginas 772–776. IEEE, 2004. 5
- [13] Zhao, Qing e Brian M Sadler: *A survey of dynamic spectrum access*. *Signal Processing Magazine, IEEE*, 24(3):79–89, 2007. 6
- [14] Alom, M. Z., T. K. Godder e M. N. Morshed: *A survey of spectrum sensing techniques in cognitive radio network*. Em *2015 International Conference on Advances in Electrical Engineering (ICAEE)*, páginas 161–164, Dec 2015. 7
- [15] Shabnam e R. Mahajan: *Performance analysis of cyclostationary and energy detection spectrum sensing techniques*. Em *Signal Processing, Computing and Control (ISPCC), 2015 International Conference on*, páginas 247–251, Sept 2015. 7
- [16] Dalvi, A., P. Swamy e B. B. Meshram: *Challenges of spectrum sensing techniques for cognitive radio*. Em *Proceedings of the International Conference & Workshop on Emerging Trends in Technology, ICWET '11*, páginas 972–973, New York, NY, USA, 2011. ACM, ISBN 978-1-4503-0449-8. <http://doi.acm.org.ez54.periodicos.capes.gov.br/10.1145/1980022.1980232>. 7
- [17] Yucek, T. e H. Arslan: *A survey of spectrum sensing algorithms for cognitive radio applications*. *Commun. Surveys Tuts.*, 11(1):116–130, janeiro 2009, ISSN 1553-877X. <http://dx.doi.org/10.1109/SURV.2009.090109>. 7
- [18] Medina, Apaza e Euler Edson: *Sensoriamento espectral baseado na detecção de energia para rádios cognitivos*. Tese de Doutorado, Universidade de São Paulo, 2014. 7
- [19] Lathi, Bhagwandas P.: *Modern Digital and Analog Communication Systems*. Oxford University Press, Inc., New York, NY, USA, 2nd edição, 1995, ISBN 0030284074. 7
- [20] Mitola III, Joseph: *Software radios: Survey, critical evaluation and future directions*. *Aerospace and Electronic Systems Magazine, IEEE*, 8(4):25–36, 1993. 8
- [21] Ziouva, Eustathia e Theodore Antonakopoulos: *Csma/ca performance under high traffic conditions: throughput and delay analysis*. *Computer communications*, 25(3):313–321, 2002. 10
- [22] Santos, Everton Luiz Ferret dos: *A iee 802.15. 4 como plataforma de comunicação de dados*. *Revista Ilha Digital*, 4:97–105, 2013. 10, 36
- [23] Pádua Braga, A. de: *Redes neurais artificiais: teoria e aplicações*. LTC Editora, 2007, ISBN 9788521615644. <https://books.google.com.br/books?id=R-p1GwAACAAJ>. 12

- [24] McCulloch, Warren S. e Walter Pitts. Em Anderson, James A. e Edward Rosenfeld (editores): *Neurocomputing: Foundations of Research*, capítulo A Logical Calculus of the Ideas Immanent in Nervous Activity, páginas 15–27. MIT Press, Cambridge, MA, USA, 1988, ISBN 0-262-01097-6. <http://dl.acm.org/citation.cfm?id=65669.104377>. 13
- [25] Minsky, M. e S. Papert: *Perceptrons*. MIT Press, Cambridge, MA, 1969. 15
- [26] Cybenko, G.: *Approximation by superpositions of a sigmoidal function*. Mathematics of Control, Signals, and Systems (MCSS), 2:303–314, dezembro 1989. <http://dx.doi.org/10.1007/BF02551274>. 15
- [27] Cybenko, G.: *Continuous Valued Neural Networks with Two Hidden Layers are Sufficient*. Relatório Técnico, 1988. 15
- [28] Lapedes, A. e R. Farber: *Nonlinear signal processing using neural networks: Prediction and system modelling*. Relatório Técnico LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM, 1987. 15
- [29] Hopfield, John J. e David W. Tank: *Computing with neural circuits: A model*. Science, 233:624–633, 1986. 16
- [30] Haykin, S. e P.M. Engel: *Redes neurais: princípios e prática*. Artmed, 2007. 16
- [31] Jordan, Michael I.: *Serial order: A parallel, distributed processing approach*. Em Elman, Jeffrey L. e David E. Rumelhart (editores): *Advances in Connectionist Theory: Speech*. Erlbaum, Hillsdale, NJ, 1989. 16
- [32] Kremer, S. C.: *On the computational power of elman-style recurrent networks*. IEEE Transactions on Neural Networks, 6(4):1000–1004, Jul 1995, ISSN 1045-9227. 18
- [33] Werbos, P. J.: *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Tese de Doutorado, Harvard University, 1974. 19
- [34] Rumelhart, David E., Geoffrey E. Hinton e Ronald J. Williams: *Neurocomputing: Foundations of research*. capítulo Learning Representations by Back-propagating Errors, páginas 696–699. MIT Press, Cambridge, MA, USA, 1988, ISBN 0-262-01097-6. <http://dl.acm.org/citation.cfm?id=65669.104451>. 19
- [35] Levenberg, K.: *A method for the solution of certain problems in least squares*. Quart. Applied Math., 2:164–168, 1944. 19, 38
- [36] Marquardt, Donald W.: *An algorithm for least-squares estimation of nonlinear parameters*. SIAM Journal on Applied Mathematics, 11:431–441, 1963. 19, 38
- [37] Hagan, Martin T., Howard B. Demuth e Mark Beale: *Neural Network Design*. PWS Publishing Co., Boston, MA, USA, 1996, ISBN 0-534-94332-2. 19
- [38] Eltholth, A.: *Forward backward autoregressive spectrum prediction scheme in cognitive radio systems*. Em *2015 9th International Conference on Signal Processing and Communication Systems (ICSPCS)*, páginas 1–5, Dec 2015. 20

- [39] Lan, Kunwei, Hangsheng Zhao, Jianzhao Zhang, Cao Long e Menglin Luo: *A spectrum prediction approach based on neural networks optimized by genetic algorithm in cognitive radio networks*. Em *10th International Conference on Wireless Communications, Networking and Mobile Computing (WiCOM 2014)*, páginas 131–136, Sept 2014. 20
- [40] Bai, S., X. Zhou e F. Xu: *Spectrum prediction based on improved-back-propagation neural networks*. Em *2015 11th International Conference on Natural Computation (ICNC)*, páginas 1006–1011, Aug 2015. 20
- [41] Huk, M. e J. Mizera-Pietraszko: *Contextual neural-network based spectrum prediction for cognitive radio*. Em *2015 Fourth International Conference on Future Generation Communication Technology (FGCT)*, páginas 1–5, July 2015. 20
- [42] Zhang, Shibing, Jinming Hu, Zhihua Bao e Jianrong Wu: *Prediction of spectrum based on improved rbf neural network in cognitive radio*. Em Cabello, Enrique, Maria Virvou, Mohammad S. Obaidat, Hong Ji, Petros Nicopolitidis e Dimitrios D. Vergados (editores): *SIGMAP*, páginas 243–247. SciTePress, 2013, ISBN 978-989-8565-74-7. 20
- [43] Elrharras, A., R. Saadane, M. Wahbi e A. Hamdoun: *Hybrid architecture for spectrum sensing algorithm based on energy detection technique and artificial neural networks*. Em *2014 5th Workshop on Codes, Cryptography and Communication Systems (WC-CCS)*, páginas 40–44, Nov 2014. 20
- [44] Reis, Andre Luiz Garcia, Andre Felipe Barros, Karlo Gusso Lenzi, Luis Geraldo Pedroso Meloni e Silvio Ernesto Barbin: *Introduction to the software-defined radio approach*. IEEE Latin America Transactions, 10(1):1156–1161, 2012. 22
- [45] Foundation, Free Software: *What is gnu radio and why do i want it?*, 2014. <http://gnuradio.org/redmine/projects/gnuradio/wiki/WhatIsGR>, [Último acesso 04-Outubro - 2016]. 23
- [46] Bianchi, Giuseppe: *Performance analysis of the ieee 802.11 distributed coordination function*. IEEE Journal on selected areas in communications, 18(3):535–547, 2000. 23
- [47] Jun, Jangeun, P. Peddabachagari e M. Sichitiu: *Theoretical maximum throughput of ieee 802.11 and its applications*. Em *Network Computing and Applications, 2003. NCA 2003. Second IEEE International Symposium on*, páginas 249–256, April 2003. 23, 25, 32
- [48] Lloyd, S.: *Least squares quantization in pcm*. IEEE Trans. Inf. Theor., 28(2):129–137, setembro 2006, ISSN 0018-9448. <http://dx.doi.org/10.1109/TIT.1982.1056489>. 26
- [49] iPerf: *iperf - the ultimate speed test tool for tcp, udp and sctp*, 2016. <https://iperf.fr/>, [Último acesso 08-Janeiro - 2016]. 36

- [50] farproc: *Wifi analyzer*. <https://play.google.com/store/apps/details?id=com.farproc.wifi.analyzer&hl=en>, 2016. 53, 54



# Anexo I

## Distribuição de faixas de frequência no Brasil [1]

