

TRABALHO DE CONCLUSÃO DE CURSO

**Sistema Baseado em Rede Neural para Predição da
Ocupação Espectral em Sistemas do
Tipo Rádio Cognitivo**

Carlos Henrique de Carvalho Rocha

Brasília, julho de 2019

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE TECNOLOGIA

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**SISTEMA BASEADO EM REDE NEURAL PARA
PREDIÇÃO DA OCUPAÇÃO ESPECTRAL EM
SISTEMAS DO TIPO RÁDIO COGNITIVO**

CARLOS HENRIQUE DE CARVALHO ROCHA

ORIENTADOR: JOÃO PAULO LEITE

TRABALHO DE CONCLUSÃO DE CURSO

BRASÍLIA/DF: JULHO – 2019

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**SISTEMA BASEADO EM REDE NEURAL PARA PREDIÇÃO
DA OCUPAÇÃO ESPECTRAL EM SISTEMAS DO TIPO
RÁDIO COGNITIVO**

CARLOS HENRIQUE DE CARVALHO ROCHA

**RELATÓRIO SUBMETIDO AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA DA
FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE ENGENHEIRO
ELETRICISTA.**

APROVADO POR:

**Prof. João Paulo Leite, Dr., ENE/UnB
(Orientador)**

**Prof. Alexandre Ricardo Soares Romariz, Dr., ENE/UnB
(Examinador Interno)**

**Prof. Paulo Henrique Portela de Carvalho, Dr., ENE/UnB
(Examinador Interno)**

BRASÍLIA/DF, 05 DE JULHO DE 2019

FICHA CATALOGRÁFICA

ROCHA, CARLOS HENRIQUE DE CARVALHO
Sistema Baseado em Redes Neurais para Predição da Ocupação Espectral em Sistemas do Tipo Rádio Cognitivo [Distrito Federal] 2019. xviii, 80p., 210 x 297 mm
(ENE/FT/UnB, Bacharel, Engenharia Elétrica, 2019)

Trabalho de Graduação – Universidade de Brasília. Faculdade de
Tecnologia. Departamento de Engenharia Elétrica.

1. Aprendizado de Máquina
Ocupação Espectral

ENE/FT/UnB

2. Rádio Cognitivo
4. Sistemas de Comunicação

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

ROCHA, C. H. C. (2019). Sistema Baseado em Redes Neurais para Predição da Ocupação Espectral em Sistemas do Tipo Rádio Cognitivo Trabalho de Conclusão de Curso em Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 80p.

CESSÃO DE DIREITOS

AUTOR: Carlos Henrique de Carvalho Rocha.

TÍTULO: Sistema Baseado em Redes Neurais para Predição da Ocupação Espectral em Sistemas do Tipo Rádio Cognitivo.

GRAU: Bacharel ANO: 2019

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de graduação e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de graduação pode ser reproduzida sem autorização por escrito do autor.

Dedicatória

Dedico este trabalho aos meus pais e às minhas irmãs, que me incentivam todos dias a ser uma pessoa melhor.

Carlos Henrique de Carvalho Rocha

Agradecimentos

Agradeço aos meus pais, Alda e Carlos, por todo apoio, suporte e orientação ao longo dessa jornada, e às minhas irmãs, Leticia e Laura, que sempre apoiaram e contribuíram com entusiasmo.

Ao professor João Paulo Leite, pela oportunidade de trabalho e pela orientação, fundamentais ao meu desenvolvimento.

Ao amigos do curso de Engenharia Elétrica, Ana Luíza, Henrique, Josué, Lucas e Pedro por todos os momentos e conhecimentos compartilhados.

Aos professores e funcionários do Departamento de Engenharia Elétrica (ENE) que contribuíram para as minhas percepções do universo.

Aqueles que me permitiram, a cada dia, novos desafios e oportunidades, e que me estimularam pensar sob novas perspectivas.

Aos que nunca deixaram de acreditar.

Carlos Henrique de Carvalho Rocha

RESUMO

O acesso dinâmico ao espectro de frequência utilizando sistemas do tipo rádio cognitivo surge como alternativa ao gerenciamento dos recursos espectrais, de forma a se obter maior eficiência na utilização espectral, fundamental em um ambiente de escassez de espectro. A implementação de técnicas de sensoriamento espectral torna possível a identificação de oportunidades de acesso ao espectro, favorecendo o compartilhamento do recurso espectral.

Nesse contexto, técnicas de aprendizado de máquina podem ser utilizadas para predição da ocupação espectral. Neste trabalho, avaliou-se o desempenho das redes neurais do tipo *perceptron* de múltiplas camadas para o problema de predição de ocupação espectral. As análises de desempenho são realizadas sob condições de tráfego estacionário e não-estacionário e utilizam os critérios de probabilidade de falso alarme e falsa detecção para comparar a abordagem baseada em redes neurais com técnicas clássicas de sensoriamento.

Resultados de simulação mostram que a predição do estado de ocupação do canal reduz a energia necessária ao sensoriamento espectral em, pelo menos, 54% e incrementa a utilização do espectro de frequência em até 150%.

ABSTRACT

Dynamic spectrum access using cognitive radio networks arises as an alternative to manage the spectral resources, in order to obtain efficient spectral utilization, which is necessary in a spectrum scarcity environment. The implementation of spectral sensing techniques make it possible to identify opportunities for spectrum access, that enables the spectrum share.

In this context, machine learning techniques can be used to predict spectrum occupancy. In this work, the performance of multilayer perceptron (MLP) networks was evaluated for the spectrum prediction problem. The performance evaluation are taken under stationary and non-stationary traffic conditions and the accuracy of the MLP spectrum prediction is evaluated in terms of wrong prediction probability of busy and idle states to compare the approach based on neural networks with classical sensing techniques.

Simulation results shows that channel status prediction save the spectral sensing energy at least 54% and the percentage of improvement in spectrum utilization increases up to 150%.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	CONTEXTUALIZAÇÃO.....	1
1.2	DEFINIÇÃO DO PROBLEMA.....	3
1.3	OBJETIVOS	4
1.4	APRESENTAÇÃO DO TRABALHO	4
2	RÁDIO COGNITIVO	6
2.1	INTRODUÇÃO	6
2.2	RÁDIO COGNITIVO.....	6
2.2.1	CICLO COGNITIVO.....	8
2.3	SENSORIAMENTO DO ESPECTRO	9
2.4	OPORTUNIDADE DE TRANSMISSÃO	10
2.5	CONCEITOS BÁSICOS DE DETECÇÃO	11
2.6	CONCLUSÃO	13
3	REDES NEURAIS	14
3.1	INTRODUÇÃO	14
3.2	REDE NEURAL.....	14
3.2.1	Processo de Aprendizagem.....	15
3.2.2	Modelo de Neurônio.....	15
3.3	PERCEPTRON DE MÚLTIPLAS CAMADAS	16
3.3.1	Conceitos Gerais.....	17
3.3.2	Algoritmo de Retropropagação.....	19
3.3.2.1	Parâmetros Adaptativos	23
3.3.2.2	Taxa de Aprendizado	23
3.3.3	Constante de Momento.....	23
3.4	CONCLUSÃO	24
4	MODELO DE TRÁFEGO	25
4.1	INTRODUÇÃO	25
4.2	PROCESSOS ESTOCÁSTICOS.....	25
4.3	MODELO DE TRÁFEGO	28
4.3.1	Tráfego de Dados	29
4.4	PROCESSO DE POISSON	30
4.4.1	Tráfego de Poisson	30
4.5	SIMULAÇÕES DE TRÁFEGO	32
4.5.1	Realizações de Eventos.....	32
4.5.2	Distribuição de Ocorrência dos Eventos	33
4.5.3	Decaimento Exponencial	34
4.5.4	Duração dos Eventos.....	36
4.6	CONCLUSÃO	37
5	UTILIZAÇÃO DE REDES NEURAIS PARA PREDIÇÃO DE OCUPAÇÃO ESPECTRAL.....	38
5.1	INTRODUÇÃO	38
5.2	PARÂMETROS DE SIMULAÇÃO.....	38
5.3	CRITÉRIO DE AVALIAÇÃO DO DESEMPENHO.....	40
5.4	RESULTADOS DE SIMULAÇÃO.....	42
5.4.1	Desempenho Sob Tráfego Estacionário	42

5.4.2	<i>Desempenho Sob Tráfego Não-Estacionário</i>	45
5.4.3	<i>Incremento na Utilização do Espectro</i>	48
5.4.4	<i>Redução da Energia Espectral</i>	52
5.5	<i>SIMULAÇÕES COMPLEMENTARES</i>	53
5.5.1	<i>Análise Comparativa de Desempenho: Algoritmo de Treinamento</i>	53
5.5.2	<i>Análise Comparativa de Desempenho: Quantidade de Amostras de Treinamento</i>	54
5.5.3	<i>Análise Comparativa de Desempenho: Proporção entre Treinamento/Validação/Teste</i>	56
5.6	<i>CONCLUSÕES</i>	57
6	CONCLUSÕES	58
6.1	<i>PROPOSTAS DE TRABALHOS FUTUROS</i>	60
	REFERÊNCIAS BIBLIOGRÁFICAS	61

LISTA DE FIGURAS

1.1	Medições de eficiência de uso do espectro no Rio de Janeiro [2].....	2
2.1	Região de oportunidades de acesso à usuário secundário.....	7
2.2	Ciclo Cognitivo	8
2.3	Representação dos estados de transmissão do canal na etapa de sensoriamento espectral.....	10
2.4	Ilustração do acesso dinâmico ao espectro em instantes de tempo $t_1 < t_2 < t_3$	11
2.5	Padrão de ocupação do espectro eletromagnético.....	12
3.1	Gráfico do fluxo de sinal do neurônio – <i>Perceptron</i>	16
3.2	Gráfico arquitetura de um <i>perceptron</i> de múltiplas camadas com duas camadas ocultas.....	17
3.3	Gráfico do modelo não-linear do <i>perceptron</i>	18
3.4	Gráfico sinal de erro no caminho reservo - <i>Backward Patch</i>	22
3.5	Gráfico função de ativação do tipo sigmoide.....	23
4.1	Representação do Processo de Contagem para 1000 eventos consecutivos	27
4.2	Contagem de Eventos Consecutivos na janela de tempo [0,8] ms	28
4.3	Alternância entre eventos de T_{ON} e T_{OFF}	29
4.4	Realizações do Processo Aleatório de T_{ON} e T_{OFF} com intensidade de tráfego (a) $\rho = 0,50$ e (b) $\rho = 0,70$	33
4.5	Histograma dos Eventos de T_{ON} que ilustra distribuição da ocorrência dos eventos em torno de λ , para $t_{INTER} = 10$ slots.....	34
4.6	Decaimento exponencial prático e teórico do tempo de duração de T_{ON}	35
4.7	Decaimento exponencial prático e teórico do intervalo de tempo entre chegadas.....	35
4.8	Tempo de Duração T_{ON}	36
4.9	Tempo de Duração T_{OFF}	36
5.1	Arquitetura da Rede Neural MLP com duas camadas ocultas com 15 e 20 neurônios, respectivamente, implementada em simulação.	40
5.2	Realizações de Processo Aleatório de T_{ON} e T_{OFF} com representação da janela $\delta = 0,10$ ms.. ..	43
5.3	Desempenho da predição do estado ocupado da rede MLP em diferentes cenários de tráfego.....	44
5.4	Desempenho da predição da rede MLP em diferentes cenários de tráfego.	45

5.5	Desempenho de predição do estado desocupado da rede MLP em diferentes cenários de tráfego.....	46
5.6	Intensidade de Tráfego por Canal.....	52
5.7	Número de Eventos de seleção aleatória do canal e quantidade comparativa de slots desocupados, I_{Predict}	52
5.8	Gráfico comparativo entre diferentes algoritmos de treinamento.....	55
5.9	Gráfico comparativo entre diferentes tamanho de amostra.....	56
5.10	Gráfico comparativo entre diferentes Proporções de Divisão das Amostras.....	58

LISTA DE TABELAS

4.1	Parâmetros utilizados nas simulações de tráfego	30
5.1	Parâmetros de Tráfego	39
5.2	Parâmetros de Treinamento	39
5.3	Parâmetros de Tráfego Não-Estacionário	47
5.4	Resultados Simulação Tráfego Não-Estacionário Probabilidade de Erro Geral	47
5.5	Resultados Simulação Tráfego Não-Estacionário Probabilidade de Erro Ocupado	48
5.6	Resultados Simulação Tráfego Não-Estacionário Número de Épocas de Treinamento.....	49
5.7	Parâmetros de Canais para Diferentes Cenários de Tráfego.....	49
5.8	Resultados Incremento na Utilização Espectral.....	50
5.9	Número de Vezes em que cada canal foi selecionado para análise I_{predict}	50
5.10	Porcentagem de Redução da Energia de Sensoriamento	53
5.11	Parâmetros de Simulação: Avaliação do Algoritmo de Treinamento	54
5.12	Parâmetros de Simulação: Avaliação Quantidade de Amostras	56
5.13	Parâmetros de Simulação: Avaliação Proporção de Divisão da Amostras	57

LISTA DE SIGLAS

ANATEL	<i>Agência Nacional de Telecomunicações.</i>
MLP	<i>Multilayer Perceptron.</i>
SVM	<i>Support Vector Machines</i>
LSTM	<i>Long Short-Term Memory</i>
RF	<i>Radiofrequência</i>
TX	<i>Transmissor</i>
LMS	<i>Least-Mean-Square</i>
MSE	<i>Mean-Square-Error</i>

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Nos últimos anos, a alocação do recurso espectral é realizada para sistemas de comunicação tendo por princípio atender a demanda de usuários licenciados, usuário este que possui prioridade no acesso e transmissão em determinada área geográfica. Esta política fixa de alocação do espectro representada pela exclusividade na utilização das bandas de frequência por parte de um único sistema implica limitações ao melhor aproveitamento do recurso espectral.

A agência regulatória ANATEL, Agência Nacional de Telecomunicações, que atua a nível nacional no gerenciamento do espectro radiofrequência, regula o setor de telecomunicações a partir da atribuição, destinação e distribuição de faixas de frequência no Brasil. Visando ampliar a utilização do espectro de frequência a ANATEL, em 2016, iniciou o desligamento do sinal analógico da TV aberta nas principais cidades do país, viabilizando, assim, a destinação da faixa de 700 MHz à operação de serviços móveis, aumentando a faixa destinada a Internet banda larga [1].

A fim de gerenciar o espectro de frequência no Brasil, além da realocação dos recursos espectrais, como as faixas destinadas ao sinal analógico de TV, a agência realiza leilões de radiofrequência, o que possibilita, portanto, a ampliação do setor de telecomunicações. Embora necessária ao desenvolvimento do setor, a modernização e expansão das redes móveis e fibra óptica exige grandes investimentos em infraestrutura e tecnologia.

A utilização do espectro eletromagnético tem sofrido modificação contínua devido, principalmente, à crescente evolução das tecnologias de comunicação. No cenário brasileiro, o número de acessos de todos os serviços foi de 323,6 milhões no ano de 2017, crescimento de 1200% há 20 anos, enquanto que o acesso à banda larga no Brasil, ao final de 2017, foi de 217,5 milhões, incremento de 3,5% em comparação com o ano de 2016 [1]. O aumento na utilização do recurso espectral é, portanto, investigado por agências, atua a nível internacional, pela União Internacional de Telecomunicações e, a nível nacional, pela Agência Nacional de Telecomunicações, com objetivo de regulamentar e propor a aplicação de novas tecnologias para aprimorar o gerenciamento desse recurso.

Embora a demanda por bandas de frequência tenha aumentado nos últimos anos, pode-se observar, quando na análise dos sistemas licenciados, que as faixas de frequência abaixo de 3 MHz estão ociosas na maior parte do tempo. A Fig.1.1 [2] mostra as medições do uso do espectro de frequência na cidade de Rio de Janeiro por parte do usuário licenciado. É possível observar que a faixa de frequência 1785-1850 MHz é a única no gráfico da Fig. 1.1 que ultrapassa

a utilização de 70%, ou seja, esta faixa permanece ociosa apenas 24% do tempo. Contudo, esse padrão de ocupação não é observado nas demais faixas apresentadas, em que 78% possuem ocupação do espectro inferior a 20%, permanecendo a maior parte do tempo desocupada.

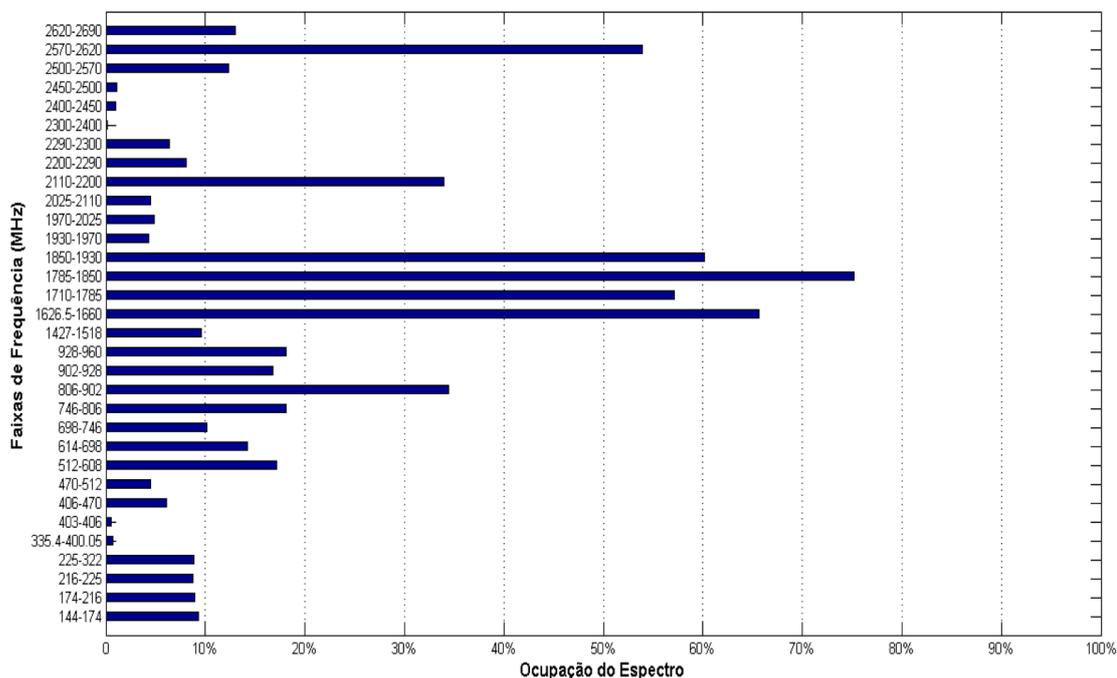


Figure 1.1 - Medições de eficiência de uso do espectro no Rio de Janeiro [2].

Nesse contexto, surgem propostas tecnológicas que buscam otimizar a utilização do espectro de frequência a partir do compartilhamento do recurso espectral com usuário não licenciado, usuário secundário, isto é, que não detém prioridade no acesso. A regulamentação da alocação da banda espectral considerada subutilizada ao acesso oportunista, de forma que não interfira na atividade do usuário primário, é fundamental à implementação de políticas de acesso dinâmico ao espectro o que possibilita o aumento da eficiência na utilização do espectro de frequência.

Técnicas como o rádio cognitivo [3] são introduzidas como solução ao problema do compartilhamento do espectro a partir da identificação de oportunidade de acesso dinâmico às bandas de frequência. O acesso oportunista deve desempenhar as capacidades de detecção de lacunas espectrais, ou seja, porções do espectro que não são utilizadas, podendo ser disponibilizadas à usuários secundário.

O ciclo cognitivo, isto é, sequência de etapas desempenhadas no rádio cognitivo, em que essa confere a capacidade cognitiva deste, é composto pelas etapas de sensoriamento espectral, de análise do espectro e de gerenciamento do espectro. Na primeira etapa do ciclo, o rádio monitora o espectro de frequência e detecta a presença de transmissores atuando na rede, assim, é possível a identificação de oportunidades de acesso, as lacunas espectrais. Em seguida, na segunda etapa do ciclo cognitivo, são analisados os sinais de radiofrequência e o estado de ocupação do canal bem como sua capacidade são estimados. A terceira etapa do ciclo desempenha a avaliação dos dados obtidos nas duas primeiras etapas e decide pela ocupação ou não do canal.

A possibilidade de adequação dos parâmetros e estado de funcionamento do rádio é uma característica fundamental em um cenário de acesso dinâmico ao espectro. A alteração dos parâmetros de transmissão do rádio cognitivo, como potência de transmissão, modulação e frequência de operação, favorece a utilização mais eficiente do espectro radiofrequência.

1.2 DEFINIÇÃO DO PROBLEMA

A implementação do rádio cognitivo proposto por Haykin, que pode ser utilizada para aumentar a utilização do espectro eletromagnético, se mostra favorável diante do cenário de escassez espectral [4]. Entre as habilidades desempenhadas pelo rádio cognitivo de observação, adaptação, raciocínio e aprendizagem, tem-se que o sensoriamento espectral, referente à habilidade de observação, desempenha papel principal nos estudos do rádio cognitivo [5].

O sensoriamento do espectro de frequência é uma etapa fundamental do rádio cognitivo. O processo de sensoriamento tem por objetivo identificar oportunidades de transmissão, que é realizado a partir da detecção dos períodos de atividade de transmissão por parte do usuário primário e períodos de ociosidade na utilização da banda de frequência. A partir do mapeamento do padrão de utilização do espectro do usuário licenciado é possível identificar as oportunidades de acesso oportunista.

Diante do exposto, técnicas de aprendizado de máquinas e redes neurais podem ser implementadas no rádio cognitivo para predição da ocupação do espectro eletromagnético. Além disso, o acesso dinâmico, de modo a não causar interferência no usuário primário, pode ser avaliado em termos probabilísticos quanto a detecção de lacunas espectrais e falso alarme [4]. Nesse sentido, as técnicas de inteligência artificial são indicadas como métodos para a predição do estado de ocupação do espectro.

A capacidade cognitiva para realização do sensoriamento espectral em sistemas do tipo rádio cognitivo é implementada a partir da utilização de algoritmos de aprendizado de máquina e redes neurais artificiais. Dentre as técnicas de aprendizado mais difundidas na literatura para solução de problemas, no contexto de sistemas de telecomunicações, tem-se o aprendizado supervisionado e o aprendizado não supervisionado.

Dos métodos de aprendizado supervisionado, tem-se a implementação de algoritmos de treinamento do tipo *perceptron* de múltiplas camadas, o MLP (*multilayer perceptron*), como uma abordagem convencional à solução de problemas de predição espectral [6,7,8]. A partir da utilização das redes MLP para predição do estado de ocupação e padrão de tráfego do canal, é possível obter resultados com probabilidade de erro da mesma ordem de grandeza dos resultados obtidos por técnicas mais robustas e que exigem maior complexidade computacional, por exemplo, máquina de vetor de suporte, SVM (*support vector machines*) [9].

Técnicas não supervisionadas de aprendizado, como o modelo oculto de Markov (*hidden markov model*), são utilizadas para avaliação do desempenho na predição de tráfego na etapa de sensoriamento espectral no rádio cognitivo [10]. Resultados mostram que o modelo markoviano

possui desempenho 54,5% superior e seu tempo de operação é 200 vezes menor se comparado à rede do tipo máquina de vetor de suporte.

A predição espectral nas tecnologias de rádio cognitivo são desenvolvidas, além das técnicas de aprendizado supervisionado e não supervisionado, por algoritmos de aprendizado profundo (*deep learning*). Algoritmos desse tipo conseguem captar correlações inerentes aos padrões de tráfego que as redes neurais mais simples não são capazes de identificar. A aplicação da técnica de aprendizado profundo como LSTM (*long short-term memory*) apresenta desempenho na avaliação da predição espectral superior às redes neurais MLP [11], sendo, portanto, uma técnica de aprendizado de máquina mais acurada em comparação às redes do tipo *perceptron* de múltiplas camadas.

Ainda que algoritmos de aprendizado de máquina sejam utilizados para realizar o sensoriamento espectral, é possível realizar esse tipo de análise por meio da abordagem por detecção de energia [4,12,13]. Contudo, a utilização desta técnica tem por objetivo a análise dos níveis de potência presentes em determinado canal, e se mostra pouco robusta à incerteza do ruído.

1.3 OBJETIVOS

Neste trabalho será abordado análise da predição da ocupação espectral a partir da utilização de técnicas de aprendizado de máquina para redes do tipo *perceptron* de múltiplas camadas, conforme apresentado em [6]. A arquitetura da rede neural e o tráfego de Poisson, utilizado para modelar a ocupação espectral, implementados neste manuscrito, tiveram suas motivações em [6] e o principal objetivo de projeto será a avaliação de desempenho da rede neural para diferentes condições de tráfego, estacionário e não estacionário, e verificar a redução da energia de sensoriamento espectral e o incremento da utilização do espectro de frequência.

Portanto, o trabalho tem como principal objetivo avaliar o desempenho da predição de tráfego e ocupação espectral em sistemas de transmissão oportunista baseado na aplicação de redes neurais do tipo *perceptron* de múltiplas camadas. Para tanto, será desenvolvida a avaliação a partir dos dados de ocupação espectral que seguem uma distribuição do tipo Poisson.

O desempenho da implementação será avaliado quanto à probabilidade de falsa detecção, ou seja, possibilidade de ocorrer erro na predição do estado ocupado do canal, além da avaliação em termos da probabilidade de erro na detecção do estado desocupado, caso este tratado como probabilidade de falso alarme.

1.4 APRESENTAÇÃO DO TRABALHO

Inicialmente, no capítulo 1, é apresentada a motivação ao estudo da predição espectral e a vantagem da utilização de redes neurais na avaliação do padrão de tráfego.

No capítulo 2, são apresentados os conceitos de rádio cognitivo. A etapa de sensoriamento do

ciclo cognitivo é abordada com maior detalhamento, além dos critérios de avaliação de desempenho.

No capítulo 3 são expostos os principais conceitos de redes neurais. São apresentadas as definições e formalização matemática do *perceptron*, *perceptron* de múltiplas camadas e o algoritmo de retropropagação (do inglês, *backpropagation*).

O modelo de tráfego utilizado para alimentação da rede neural é apresentado no capítulo 4. Neste é realizada uma breve abordagem dos processos estocásticos e formalização dos modelos de tráfego. São ainda apresentados os resultados de simulação do tráfego poissoniano.

Em seguida, no capítulo 5, são apresentados os resultados e avaliação de desempenho da rede neural do tipo *perceptron* de múltiplas camadas para a abordagem do problema de predição da ocupação espectral. Os critérios de avaliação de desempenho são as probabilidades de falso alarme e falsa detecção, nas condições em que a rede neural MLP é alimentada com dados que seguem a distribuição de Poisson, em cenários de tráfego estacionário e não estacionário. Tem-se por objetivo a avaliação da redução da energia necessária ao sensoriamento espectral e o aumento na utilização do espectro de frequência para diferentes condições de tráfego.

Finalmente, no capítulo 6 são apresentadas as conclusões e sugestões de trabalhos futuros.

2 RÁDIO COGNITIVO

2.1 INTRODUÇÃO

Este capítulo tem por objetivo apresentar os principais conceitos de rádio cognitivo e sua importância e aplicabilidade. Será apresentado o funcionamento do ciclo cognitivo e suas etapas componentes na seção 2.2.

Na seção 2.3 é apresentado o processo de sensoriamento do espectro, que é a etapa do ciclo cognitivo de grande interesse para o presente trabalho e tem por finalidade a análise e previsão do padrão de utilização do espectro de frequência.

Por fim, será apresentado o conceito envolvido na identificação de oportunidades de transmissão e os conceitos básicos da detecção espectral e os conceitos de ocupação e desocupação do canal.

2.2 RÁDIO COGNITIVO

Atualmente, a busca pelo aumento da eficiência de utilização do espectro eletromagnético tem, como principal proposta, a aplicação do rádio cognitivo [4, 9]. Neste contexto, a técnica do rádio cognitivo surge como proposta a realização do acesso dinâmico ao espectro de frequência, dadas suas características de observação, adaptação, raciocínio e aprendizagem.

Os espectros de frequência atuais são gerenciados e utilizados de maneira ineficiente. Conforme apresentado em [16], o espectro de RF (rádiofrequência) nas áreas urbanas tem suas bandas de frequência descritas como desocupadas na maior parte do tempo ou parcialmente ocupadas. Assim, o rádio cognitivo surge como uma tecnologia que busca a otimização da alocação e utilização do espectro de frequência.

A Fig. 2.1 representa uma região em que o espectro de frequência se encontra em diferentes estados de ocupação. Os círculos em azul escuro representam a zona de transmissão de sinal de telecomunicação por parte do usuário licenciado, em que no centro do circuito temos uma torre de transmissão. Nessa região a prioridade de transmissão é alta e intermitente, como exemplo os sinais de televisão. Ao redor das zona de transmissão, TX 1, 2 e 3, são representadas as lacunas espectrais, que indicam a não utilização do espectro de frequência. As zonas em azul rachurado representam a regiões do espaço em que podem ocorrer o acesso oportunista, isto é, compartilhamento do espectro de frequência.

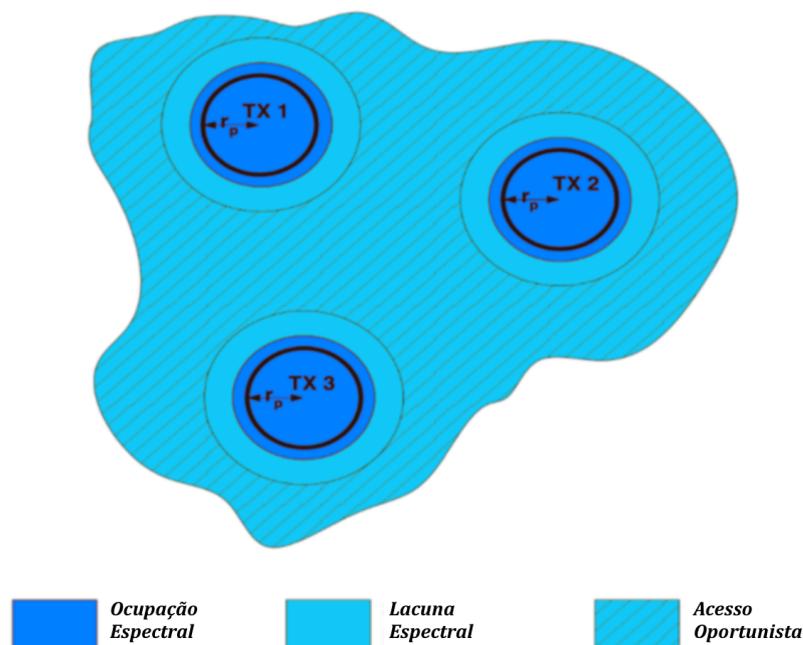


Figure 2.1 – Região de oportunidades de acesso à usuário secundário.

Idealizado primeiramente por Mitola [14], o rádio cognitivo interage com o seu ambiente de RF e é capaz de alterar seus parâmetros de transmissão conforme necessidade. Segundo Haykin [3], o rádio cognitivo é definido como: "Rádio Cognitivo é um sistema de comunicação sem fio que está atento ao ambiente externo e (...) adapta seus estados internos às variações estatísticas nos estímulos de RF, através da alteração dos respectivos parâmetros (potência de transmissão, frequência da portadora, modulação), em tempo real, com dois objetivos principais: comunicação altamente confiável, onde e quando for necessário, e utilização eficiente do espectro de radio". O rádio cognitivo, conforme proposto por Mitola e Haykin no início dos anos 2000, é uma tecnologia que tem por principal objetivo a melhora da utilização do espectro eletromagnético de rádio.

No rádio cognitivo, conforme definido por Haykin, é possível inferir tanto a capacidade cognitiva quanto a capacidade de reconfigurabilidade. Dessa forma, como o rádio cognitivo é uma tecnologia que utiliza do rádio definido por software, logo aquele possui grande capacidade de reconfiguração. A tarefa de reconfiguração é executada quando, a partir da análise do sinais de rádiofrequência do meio, são identificados novos estímulos de RF e que, sob essas novas condições, seja necessário realizar a atualização dos parâmetros do sistema, como modulação, potência e frequência de transmissão, adaptando às novas condições do ambiente. A característica cognitiva, por sua vez, é relacionada à capacidade de percepção e análise dos sinais de RF no ambiente de forma a observar o padrão de tráfego, em seguida, adaptar os parâmetros de maneira a otimizar a utilização do espectro de frequência, aumentando sua eficiência e confiabilidade.

Dado o objetivo de compartilhamento do espectro por um usuário secundário, a técnica de acesso oportunisto ao espectro pode ser adotada. Este tipo de acesso oportunisto tem por princípio

analisar o padrão de utilização do usuário primário, ou seja, usuário licenciado e que detém maior prioridade no acesso ao espectro, por parte do usuário secundário, isto é, não licenciado, que buscar a utilização do espectro apenas nos momentos em que o usuário primário não está transmitindo de modo a não causar interferência para o usuário de maior prioridade.

A tecnologia do rádio cognitivo busca habilitar usuários secundários a compartilhar a mesma banda ou canal do espectro de frequência com usuários primários de modo a não causar interferência.

2.2.1 CICLO COGNITIVO

O processo cognitivo desempenhado pelo rádio cognitivo conta com um conjunto de etapas comumente apresentadas no ciclo cognitivo. Neste, é representada a sequência de etapas realizadas pelo rádio em tempo real com o objetivo de interagir com o meio e identificar o estímulo das ondas de radiofrequência (RF), de forma a identificar oportunidades de transmissão, buracos no espectro, e, em seguida, realizar a adaptação dos parâmetros do software. Nesse contexto, temos que as três principais etapas desempenhadas pelo rádio inteligente são o sensoriamento espectral, a análise do espectro e o gerenciamento do espectro.

O ciclo cognitivo proposto inicialmente por Mitola é representado de forma simplificada na Fig. 2.2, em que é ilustrada as três principais etapas do ciclo cognitivo desempenhadas no rádio, sendo as duas primeiras etapas executadas no receptor, e a terceira, no transmissor.

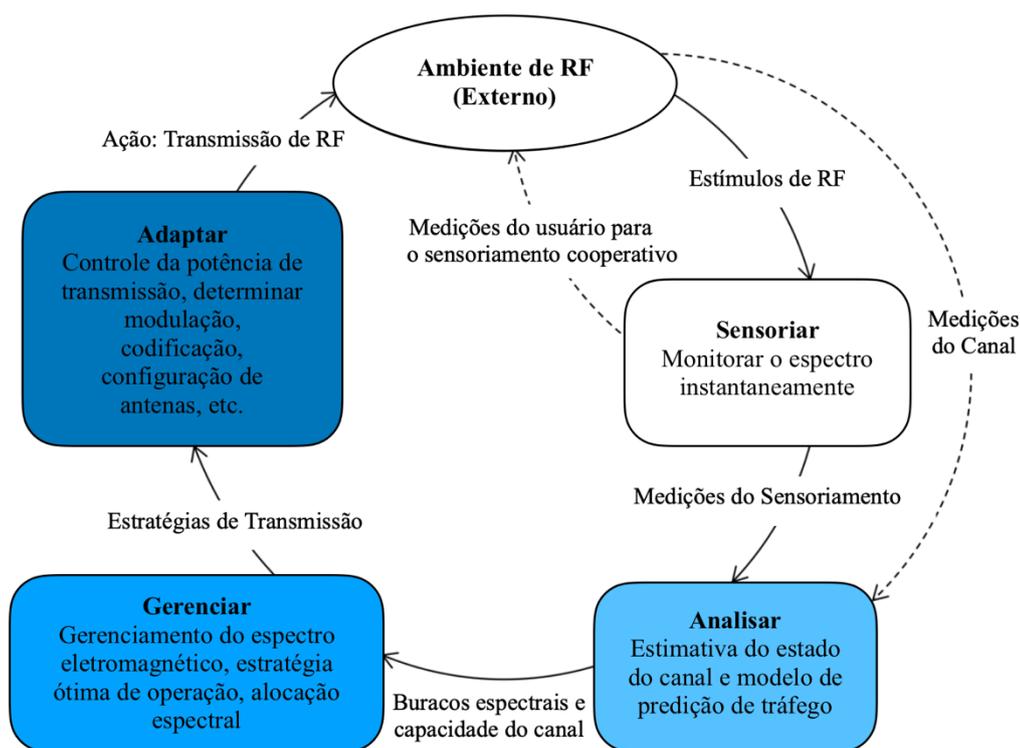


Figura 2.2 - Ciclo Cognitivo.

O ciclo cognitivo aprensetado na Fig 2.2 é composto por três etapas principais, que são: sensoriamento do espectral, análise do espectro e gerenciamento do espectro. Na primeira etapa do ciclo o rádio cognitivo realiza o sensoriamento do ambiente de radiofrequência de forma a obter as características de tráfego e o padrão de transmissão de dados que ocorre no meio. Em seguida é realizada a etapa de análise do ambiente espectral com o objetivo de identificar possibilidades de acesso oportunista. Ainda na etapa de análise são identificadas as características dos canais disponíveis, tais como capacidade e ganho do canal. Na etapa de gerenciamento espectral é tomada a decisão de acessar ou não o canal. Por fim, na etapa de adaptação, os parâmetros do rádio (potência de transmissão, modulação, frequência de transmissão) podem ser adaptados de forma a se obter maior eficiência e utilização do espectro de frequência.

2.3 SENSORIAMENTO DO ESPECTRO

O sensoriamento do espectro eletromagnético, primeira etapa do ciclo cognitivo, tem por finalidade a análise dos sinais de radio frequência do ambiente com o objetivo de identificar oportunidades de transmissão, que são as faixas subutilizadas do espectro. Portanto, é necessário que o algoritmo de sensoriamento do espectro seja rápido, robusto e acurado [12].

Neste contexto, o algoritmo implementado no rádio cognitivo deve ser rápido para que as alterações do espectro eletromagnético sejam percebidas e que ações de ocupação oportunista do canal ocorram, dado que a utilização do espectro é bastante variável ao longo do tempo. Além disso, é fundamental que o rádio seja capaz de identificar com precisão o estado do canal sensoriado, de forma a não interferir nos sistemas primários. Outra característica essencial ao rádio cognitivo é sua robustez, visto que, para evitar interferências em usuários primários, o sistema deve ser capaz de identificar e perceber ondas de radiofrequência mesmo em situações de baixas condições de propagação, sombreamento e desvanecimento [12].

A habilidade de observação do ambiente desempenhado pelo rádio cognitivo é fundamental para melhor desempenho na identificação das oportunidades de acesso dinâmico ao espectro. Assim, o usuário oportunista consegue detectar o padrão de ocupação do espectro, a partir do seu monitoramento, e identificar faixas de frequência favoráveis à utilização.

Tendo em vista o acesso oportunista de usuários secundários, é fundamental que sejam atendidas duas premissas básicas [4, 17]: proteção dos usuários primários de interferências e maximização da utilização do espectro. Quanto à primeira, a tentativa de acesso ao espectro pelo usuário não licenciado deve ocorrer apenas quando o canal está desocupado, ou seja, quando não há transmissão por parte do usuário licenciado, proporcionando confiabilidade ao sensoriamento. Com relação ao segundo compromisso, o acesso ao espectro deve ser realizado de forma a maximizar a taxa de transmissão dos usuários secundários, aumentando a eficiência de utilização do recurso espectral.

2.4 OPORTUNIDADE DE TRANSMISSÃO

O sensoriamento e análise do espectro é necessário para identificar e detectar a atividade dos sistemas primários, e, a partir do monitoramento dos sinais de RF, identificar oportunidades de acesso dinâmico ao espectro. Assim, são detectadas as lacunas espectrais (do inglês, *spectrum holes*), cuja oportunidade de transmissão pode ocorrer nas dimensões de tempo, espaço e código.

As oportunidades de transmissão, lacunas espectrais, indicam oportunidades potenciais de acesso dinâmico ao espectro de modo seguro, sem interferência ao usuário primário, em regiões multidimensionais na frequência, tempo, espaço [16], além de código e ângulo [12]. A proposta de utilização das lacunas espectrais tem sua motivação pelo fato de grande parte das bandas de frequência ser subutilizada na maior parte do tempo [16]. Uma banda de frequência é considerada subutilizada caso exista a possibilidade de alocar um sistema secundário para realizar transmissão em regiões de espaço, tempo e frequência desocupados.

As lacunas espectrais são caracterizadas pela ausência de transmissão por parte do sistema primário. É possível alocar recursos a um segundo usuário nos períodos de tempo, regiões do espaço e frequência em que não ocorre a utilização do canal pelo usuário principal licenciado. Conforme ilustrado na Fig. 2.3, os retângulos em azul escuro indicam a ocupação do canal por parte do usuário primário, enquanto os retângulos em azul claro indicam as oportunidades de acesso e compartilhamento do espectro por parte do sistema secundário. Os retângulos em gradiente de azul indicam a ocupação oportunista do canal.

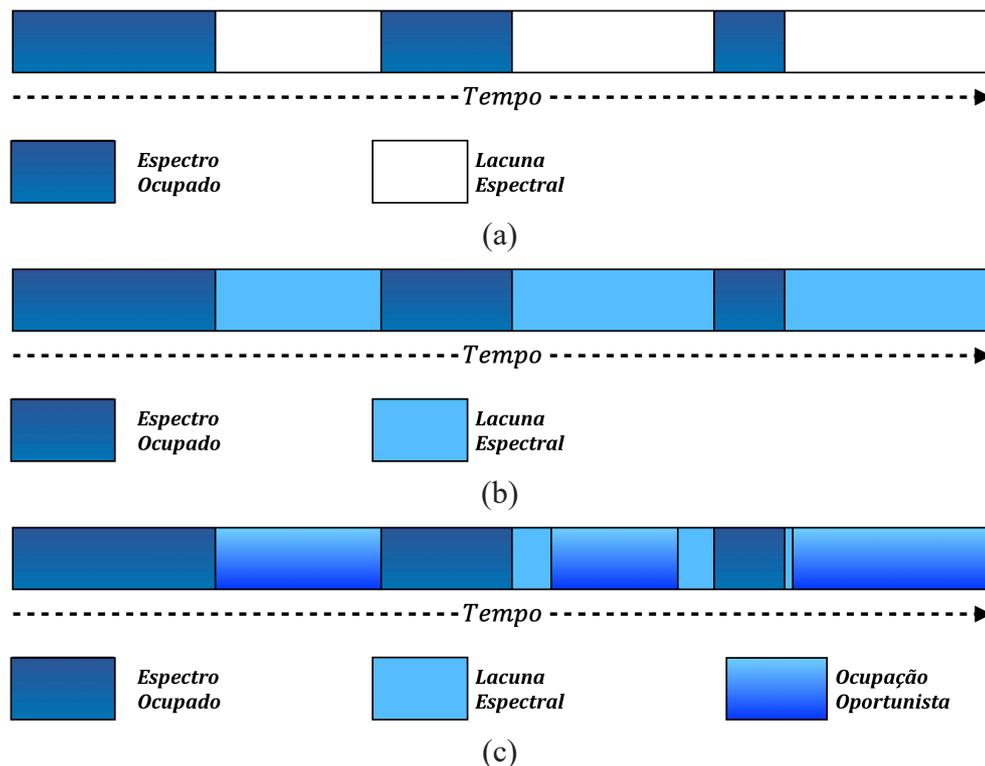


Figura 2.3 - Representação dos estados de transmissão do canal na etapa de sensoriamento espectral.

Na Fig. 2.3 apresenta a etapa de sensoriamento espectral. Na primeira etapa apresentada na Fig. 2.3(a) é identificado o padrão de tráfego e ocupação do usuário primário, sendo o período de tempo de atividade representado pelos retângulos em azul escuro. Em seguida, ocorre a identificação das lacunas espectrais, representada na fig. 2.3(b). Por fim, na etapa de gerenciamento, ilustrada na Fig 2.3(c), é tomada a decisão de ocupar ou não o canal para transmissão oportunista. Esta ocupação oportunista do canal pode ocorrer durante todo o intervalo de tempo da lacuna espectral ou em apenas em uma porção do intervalo conforme apresentado em Fig 2.3(c).

O acesso dinâmico ao espectro pode ser representado na Fig. 2.4 a seguir, em que são representadas as oportunidades de acesso, indicado pelas setas, e a ocupação do canal representado pelos retângulos azuis. Assim, para instantes de tempo $t_1 < t_2 < t_3$, as características de ocupação do canal são modificadas e, portanto, a alocação do usuário secundário também é alterada de forma a obter maior eficiência de utilização.

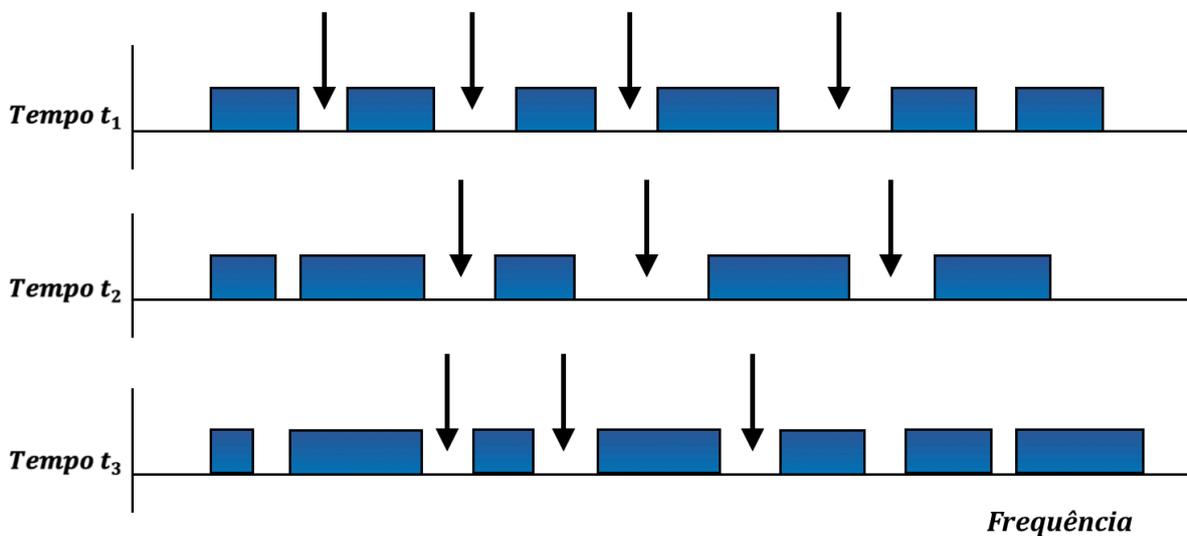


Figura 2.4 - Ilustração do acesso dinâmico ao espectro em instantes de tempo $t_1 < t_2 < t_3$.

2.5 CONCEITOS BÁSICOS DE DETECÇÃO

O desempenho da etapa de sensoriamento do espectro é comumente avaliado a partir de critérios estatísticos. A partir da avaliação da probabilidade condicional podemos definir dois critérios de avaliação: probabilidade de falso alarme e de falsa detecção.

Considerando um sistema primário de comunicação e um sistema secundário composto por rádios cognitivos, a decisão de acessar ou não o espectro de maneira oportunista depende diretamente do estado do estado de ocupação do canal no tempo t . Assim, definimos a hipótese

do canal estar ocupado, denominado \mathcal{H}_1 , isto é, o usuário primário realiza transmissão, e a hipótese em que o usuário principal está ocioso, denominado \mathcal{H}_0 , em que o sistema primário não realiza transmissão.

Dessa forma, o modelo de ocupação do canal k pode ser representado como uma escolha entre o estado de desocupado, $\mathcal{H}_{0,k}$, em nível lógico 0, que representa a ausência de sinal por parte do sistema primário, e o estado de ocupado, $\mathcal{H}_{1,k}$, representado em nível 1, que indica a presença de sinal do sistema primário, conforme ilustrado na Fig. 2.5.

A representação da ocupação do canal é formulada pelos sinais binários 0 e 1 representando o estado de ocupação do canal k em determinado instante de tempo t , que indicam, a possibilidade de acesso oportunista ou proibição de acesso ao espectro, respectivamente.

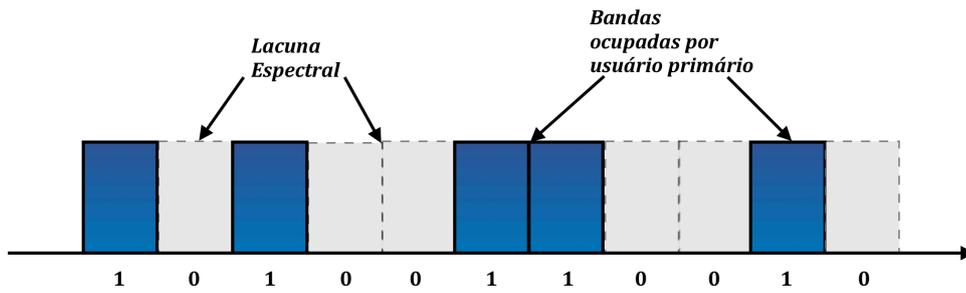


Figura 2.5 - Padrão de ocupação do espectro eletromagnético.

A partir do sinal percebido pelo rádio cognitivo do sistema secundário de comunicação, este decide entre as hipóteses \mathcal{H}_1 e \mathcal{H}_0 . Para o caso do usuário secundário decidir por \mathcal{H}_0 , ou seja, não é identificado sinal de transmissão de usuário primário, então há uma oportunidade de acesso. Caso seja identificada transmissão por parte do usuário primário então ocorre bloqueio no acesso ao espectro.

Será considerado no presente trabalho como critério avaliativo de desempenho do sensoriamento espectral as probabilidades de falso alarme e falsa detecção, definidas a seguir.

A probabilidade de detecção da lacuna espectral é definida em [6] por:

$$P_{DBE} = Pr(u = \mathcal{H}_0 | y = \mathcal{H}_0). \quad (2.1)$$

em que u representa a predição da rede neural quanto ao estado de ocupação do canal e y , o real estado de ocupação do canal.

A probabilidade de erro na detecção do estado ocupado do canal, $Prob_{erro}(Ocupado)$, é definida dado que o real status do canal é ocupado, \mathcal{H}_1 , enquanto o sensoriamento identifica o canal como desocupado, \mathcal{H}_0 . Uma vez identificado como desocupado, o usuário secundário fará a tentativa de acesso ao espectro. A análise dessa probabilidade indica a o nível de interferência causado no usuário principal.

$$P_{PD} = Pr(u = \mathcal{H}_0 | y = \mathcal{H}_1). \quad (2.2)$$

A probabilidade de erro geral $Prob_{erro}(Geral)$ representa a probabilidade de erro de detecção por parte do usuário secundário. Deve buscar minimizar essa probabilidade para melhor aproveitamento do acesso ao espectro e reduzir as chances de interferência no canal.

$$P_G = (P_{PD} + P_{FA}). \quad (2.3)$$

A probabilidade de detecção do estado desocupado ou falso alarme, $Prob_{erro}(Desocupado)$, indica uma perda de oportunidade de acesso ao espectro, visto que o canal estava de fato desocupado, $y = \mathcal{H}_0$, e o usuário secundário identificou o como canal ocupado $u = \mathcal{H}_1$.

$$P_{FA} = Pr(u = \mathcal{H}_1 | y = \mathcal{H}_0) = 1 - P_{DBE}. \quad (2.4)$$

2.6 CONCLUSÃO

No presente capítulo foram apresentados os principais conceitos do rádio cognitivo e o ciclo cognitivo e suas diferentes etapas. Foram também apresentadas as principais características de interesse no estudo e utilização do rádio cognitivo, capacidade cognitiva e reconfigurabilidade.

De particular interesse para o presente trabalho, foi discutido a etapa de sensoriamento espectral como sendo a capacidade de observação do rádio cognitivo, bem como a utilização oportunista do espectro eletromagnético, dado as oportunidades de acesso, ou seja, os buracos espectrais.

3 REDES NEURAIS

3.1 INTRODUÇÃO

Este capítulo apresenta os principais conceitos referente às redes neurais artificiais de forma a expor, primeiramente, o contexto histórico e motivação pela aplicação e implementação de algoritmos de treinamento com processamento não-linear e paralelo. Em seguida é apresentado o princípio de funcionamento da unidade base de processamento e cálculo, o *perceptron*, e sua formalização matemática. Por fim, na Seção 3.4, é apresentado a arquitetura e funcionamento do *perceptron* de múltiplas camadas, bem como o algoritmo de *backpropagation*, a partir do qual as análises de desempenho e simulações do presente trabalho foram realizadas, e, portanto, será abordado com maior grau de detalhamento.

3.2 REDE NEURAL

A motivação primeira do estudo de estruturas de redes neurais artificiais é a criação de algoritmos que consigam reproduzir de forma similar o processo de aprendizagem do cérebro humano, com processamento não-linear e paralelo.

A idealização das redes neurais artificiais teve início com Warren McCulloch e Walter Pitts em 1943 a partir da introdução de conceitos e modelos de neurônios simples que eram capazes de calcular operações aritméticas básicas [23]. Deste então, o interesse pelo desenvolvimento de algoritmos que utilizam dos conceitos de redes neurais e suas principais características têm sido pesquisados.

De particular interesse para o entendimento do presente trabalho, a idealização do *perceptron*, e implementação do teorema de convergência do *perceptron*, que serão abordados com mais detalhes na próxima seção, desenvolvido por Frank Rosenblatt a partir de 1958 [23], são os princípios o qual os algoritmos de treinamento e a arquitetura da rede neural abordados ao longo do manuscrito são fundamentados.

A complexidade do cérebro humano, geralmente atribuída a sua grande rede neuronal e interconexões entre os neurônios, é uma das características principais a qual o alto desempenho e eficiência no reconhecimento de padrões e aprendizado é associado. A principal diferença e vantagem das redes neurais é a grande capacidade de realizar cálculos rapidamente [23].

Comparativamente aos tradicionais algoritmos, os quais têm seu modo de processamento dos sinais de maneira sequencial, e, por isso, possuem menor capacidade de adaptação e eficiência de processamento se comparado aos novos modelos de redes neurais propostos atualmente, a implementação de redes neurais apresenta grande vantagem sobre os modelos tradicionais.

Neste contexto, as redes neurais artificiais possuem características que favorecem a adaptação e aprendizado em comparação aos algoritmos tradicionais. O processo de aprendizagem desenvolvido pelas redes neurais é desenvolvido a partir da interação com o ambiente, isto é, os dados são tratados pela rede artificial de forma que o comportamento do algoritmo possa ser alterado sem que exista interferência do programador. Dessa forma, o aprendizado desenvolvido pela rede neural é armazenado em forma de pesos sinápticos e o elevado grau de interconexões entre os neurônios favorece a resolução de problemas complexos. Esta forma de aprendizado torna possível a aplicação desse tipo de rede para entradas indeterminadas e distintas, favorecendo a aplicação dessa ferramenta em diversos campos do conhecimento. Outra característica fundamental às redes artificiais e que possibilita o aprendizado de forma mais rápida e eficiente é a forma de processamento paralelo [20].

3.2.1 Processo de Aprendizagem

O processo de aprendizagem dos algoritmos pode se do tipo aprendizado supervisionado (do inglês, *supervised learning*), ou aprendizado não-supervisionado (do inglês, *unsupervised learning*) [24]. Este, não conta com o conhecimento de informações do meio para treinamento da rede neural, e dessa forma não trabalha com o gradiente do erro, visto que, para este tipo de aprendizado, informações de saída desejada são inexistentes, enquanto, aquele, tem por objetivo a utilização de informações de entradas e saídas desejadas do ambiente, de forma que é possível verificar, a cada iteração, a resposta da rede neural com relação a informação desejada.

A aprendizagem supervisionada tem conhecimento prévio de informações do ambiente, ou seja, informações do meio são conhecidas e utilizadas para treinamento da rede neural. Os dados iniciais utilizados para treinamento da rede neural são representadas por meio de entradas e suas correspondentes saídas desejadas.

O presente trabalho é elaborado e desenvolvido tendo por objetivo a aplicação da técnica supervisionada de aprendizado de máquinas para a predição e classificação dos dados e informações de ocupação do canal de comunicação. Tal escolha do processo de aprendizado é devido ao melhor desempenho quanto a classificação e caracterização de padrões ser melhor representada por esse tipo de aprendizado [21].

3.2.2 Modelo de Neurônio

As redes neurais são compostas por uma grande quantidade de nós, os quais, analogamente ao cérebro humano, são chamados de neurônios. Cada neurônio recebe informações de outros neurônios e suas conexões são realizadas a partir dos pesos sinápticos e, a partir de associações com referências da rede, é gerado um sinal de informação de saída.

Cada neurônio é representado por elos sinápticos e um elo de ativação não-linear. Os elos sinápticos de um neurônio ponderam os seus respectivos sinais de entrada. A soma ponderada dos sinais de entrada define o campo local induzido e em seguida o elo de ativação limita o campo local induzido do neurônio para produzir uma saída (geralmente entre 0 e 1). A relação existente

entre as partes componentes do modelo do neurônio podem ser observadas na Fig 3.1 a seguir.

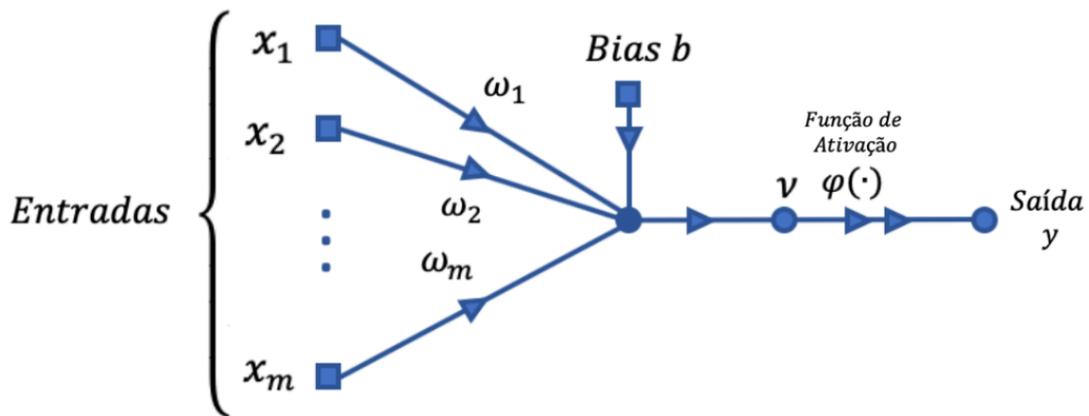


Figura 3.1 - Gráfico do fluxo de sinal do neurônio – *Perceptron*.

Nesse contexto, temos que o modelo de um neurônio é caracterizado pelas entradas múltiplas ponderadas pelos pesos sinápticos e *bias*, fator de ajuste, os quais armazenam o aprendizado da máquina, que em seguida são somados de forma a produzir o campo local induzido. O valor do campo local induzido passa por uma função de ativação, que é responsável pela ativação do neurônio.

3.3 PERCEPTRON DE MÚLTIPLAS CAMADAS

A estrutura, célula base, de classificação de padrões desenvolvida e pela primeira vez formalizada em termos de algoritmos, o *perceptron*, tem seu surgimento em 1958 com Rosenblatt. Historicamente, o *perceptron* de camada única, ou simplesmente *perceptron*, é o primeiro algoritmo de treinamento desenvolvido e utilizado no âmbito das redes neurais [26]. O *perceptron* é a forma mais simples de implementação de rede neural, único neurônio, dado que, através da adequação dos pesos sinápticos, tem a capacidade de classificar dados de entrada da rede em duas classes distintas, desde que estas sejam linearmente separáveis.

O *perceptron* de múltiplas camadas, ao contrário do *perceptron* de camada única, devido principalmente a sua maior complexidade e conectividade entre os neurônios, representado pelas relações entre os pesos sinápticos entre as camadas neuronais, possui maior aplicabilidade para problemas que não são linearmente independentes. Essa propriedade do MLP pode ser utilizada para classificação e regressão para funções não lineares [22].

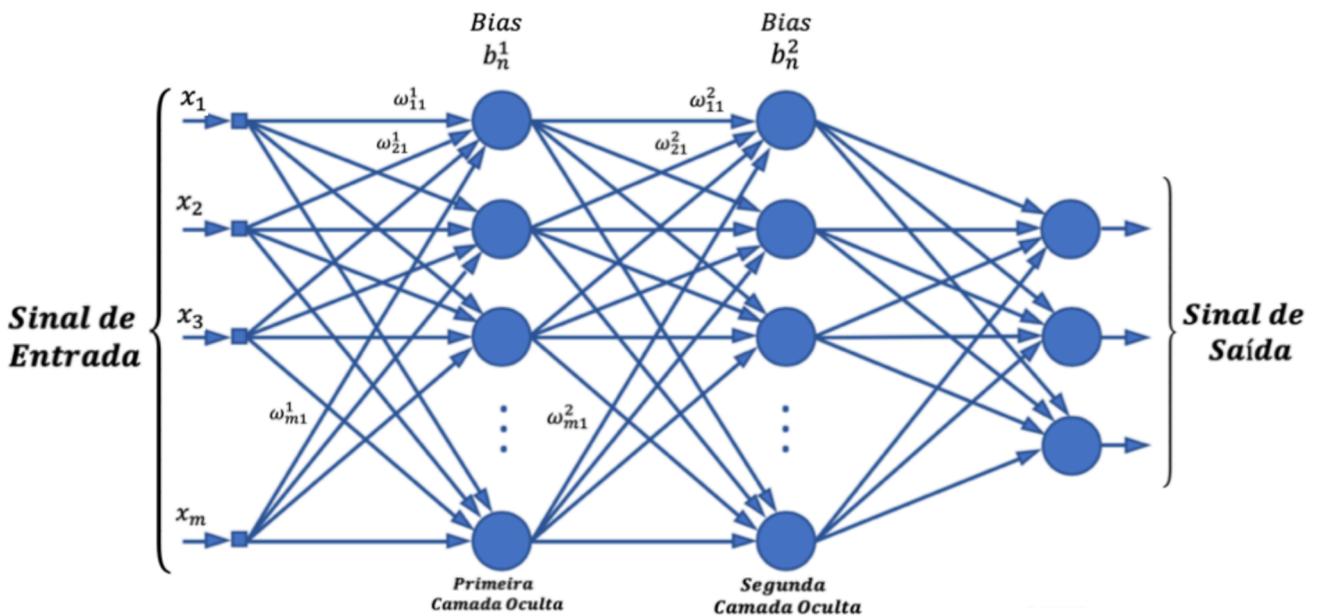


Figura 3.2 - Gráfico arquitetura do *perceptron* de múltiplas camadas com duas camadas ocultas.

A arquitetura do *perceptron* de múltiplas camadas é composta por sinais de entradas, camadas ocultas e sinais de saída. Cada camada oculta constitui de um conjunto de *perceptrons* que juntos realizam o processo de aprendizagem. A Fig. 3.2 ilustra a arquitetura de um MLP composta por m sinais de entrada, duas camadas ocultas e três sinais de saída. A conexão entre os neurônios é representada pelas setas e os pesos sinápticos $\omega_{ji}^{(l)}$. Dessa forma, conforme ilustrado na imagem acima, a rede é totalmente conectada, o que indica que um neurônio i na camada j está conectado com neurônios das camadas $j - 1$ e $j + 1$. Pode-se avaliar os pesos sinápticos do primeiro neurônio da primeira camada oculta, em que é possível perceber que as entradas x_1 , x_2 e x_m contribuem com os pesos ω_{11}^1 , ω_{21}^1 e ω_{m1}^1 , respectivamente, indicando a conectividade entre os elementos da rede neural.

3.3.1 Conceitos Gerais

A implementação do *perceptron* de camada única é composta por um vetor de entrada $\mathbf{x}(n) = [+1, x_1(n), x_2(n), \dots, x_m(n)]^T$, um vetor de pesos adaptativos $\boldsymbol{\omega}(n) = [b, x_1(n), x_2(n), \dots, x_m(n)]^T$, além do sinal de *bias* b_k como fator de ajuste. O *perceptron* realiza a combinação linear das entradas ponderadas pelos pesos adaptativos e o *bias*, gerando um sinal de saída $y(n) = \mathbf{x}^T(n)\boldsymbol{\omega}(n) + b$, o qual é processado após passagem pela função de ativação, conforme ilustrado na Fig 3.3.

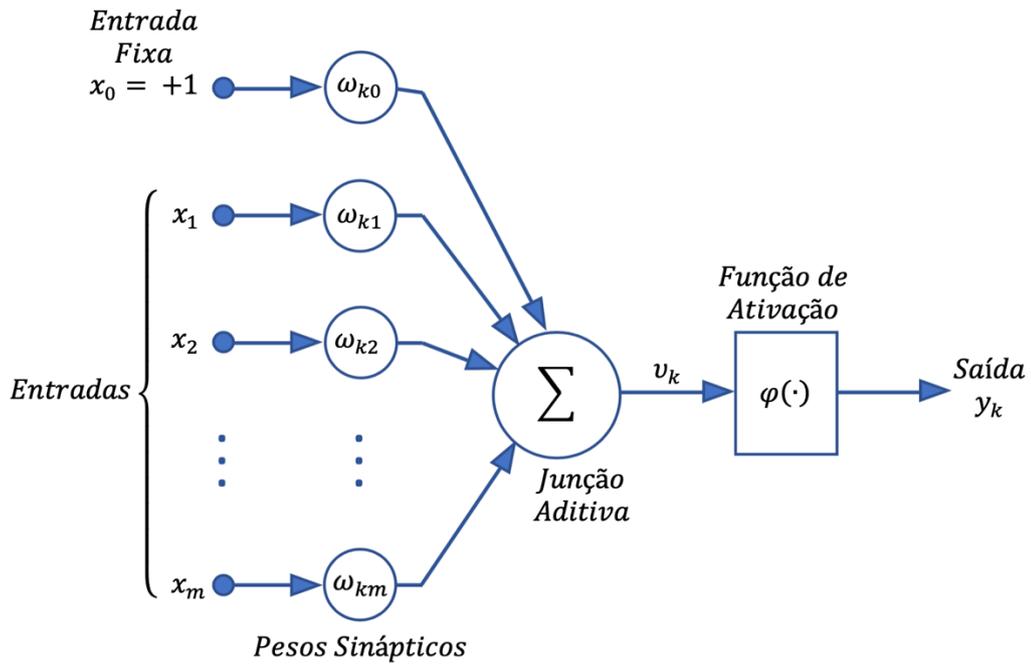


Figura 3.3 - Gráfico do modelo não-linear do *Perceptron*.

Conforme ilustrado na Fig. 3.3, a combinação linear entre o vetor de entrada $\mathbf{x}(n)$ e *bias* com os pesos sinápticos produz, para um neurônio k , uma saída u_k dada pela combinação linear das entradas:

$$u_k = \sum_{j=1}^m \omega_{kj} x_j. \quad (3.1)$$

A saída y_k do neurônio k , proveniente da passagem pela função de ativação, é da forma:

$$y_k = \varphi(u_k + b_k). \quad (3.2)$$

A aplicação do parâmetro *bias* b_k diretamente ao neurônio k tem como efeito o deslocamento dos valores de u_k , em um gráfico v_k versus u_k , de maneira que este não assume valores nulos, ou seja, $v_k \neq 0$ para $u_k = 0$. É interessante notar ainda que, conforme Fig. 3.3, o valor da entrada *bias* $x(0) = 1$ e o respectivo peso sináptico $\omega_{k0} = b_k$.

$$v_k = u_k + b_k. \quad (3.3)$$

A combinação das Eq. (3.2) e Eq. (3.3) gera a seguinte equação:

$$v_k = \sum_{j=0}^m \omega_{kj} x_j. \quad (3.4)$$

De maneira geral, a saída y_k é dado por:

$$y_k = \varphi(v_k). \quad (3.5)$$

O algoritmo dos mínimos quadrados (em inglês, *least-mean-square*, LMS) é um método de descida de gradiente que utiliza do ajuste dos pesos sinápticos do *perceptron* de forma a se obter o valor mínimo do erro quadrático médio (do inglês, *mean-square-error*, MSE) [1].

O sinal de erro na saída do neurônio j , é definido por:

$$e_j(n) = d_j(n) - o_j(n). \quad (3.6)$$

Assim, o sinal de erro $e_j(n)$ é a diferença entre a saída desejada $d_j(n)$ e a saída $o_j(n)$ produzida pela rede neural para um neurônio de saída j .

O erro quadrático instantâneo para o neurônio j é dado por:

$$\frac{1}{2} e_j^2(n). \quad (3.7)$$

Para a análise da energia total do erro $E(n)$ observado na saída da rede neural dada uma camada de neurônios, temos que a energia acumulada de todos os neurônios é:

$$E(n) = \frac{1}{2} \sum e_j^2(n). \quad (3.8)$$

O sinal de treinamento $d(n)$, sinal de resposta desejada, é utilizado para treinamento do perceptron na medida em que apresenta à rede, de forma antecipada, a resposta que a rede deve obter na saída $y(n)$. Ou seja, da forma de aprendizado supervisionado, conforme visto anteriormente.

3.3.2 Algoritmo de Retropropagação

O algoritmo comumente utilizado para realizar o treinamento de redes de múltiplas camadas é o *backpropagation*.

O algoritmo de *backpropagation* é dividido em 5 partes, conforme exposto em [21]:

- Inicialização dos pesos sinápticos com valor zero;
- Apresentação de vetores de treinamento a rede neural;
- Cálculo dos parâmetros do caminho direto (*Forward patch*);
- Cálculo dos parâmetros do caminho inverso (*Backward patch*);
- Iteração e repetição dos passos 3 e 4.

Inicialmente é apresentado a rede neural um conjunto de dados de treinamento composto pelo vetor de entrada $\mathbf{x}(n)$ e a correspondente resposta desejada $d(n)$. Assim, temos o vetor de entrada $\mathbf{x}(n)$ aplicado na entrada da rede e o vetor de resposta desejada $\mathbf{d}(n)$ é apresentado na saída da rede neural.

O campo local induzido é calculado a partir da propagação do sinal de entrada através das camadas da rede neural e após passagem pela função de ativação, caracterizando, portanto, a propagação pelo caminho direto. O campo local induzido $v_j^{(l)}(n)$ para o neurônio j na camada l é dado por:

$$v_j^{(l)}(n) = \sum_i \omega_{ji}^{(l)}(n) y_i^{(l-1)}(n). \quad (3.15)$$

em que $y_i^{(l-1)}(n)$ é o sinal de saída do neurônio i da camada $l - 1$ imediatamente anterior para a iteração n , e $\omega_{ji}^{(l)}(n)$ é o peso sináptico do neurônio j na camada l o qual é proveniente do neurônio i da camada anterior $l - 1$.

Para a análise do campo local induzido após apresentada a rede o sinal de entrada, tem-se que $i = 0$ e portanto $y_0^{(l-1)}(n) = +1$ e $\omega_{j0}^{(l)}(n) = b_j^{(l)}(n)$, em que $b_j^{(l)}(n)$ é o *bias* aplicado ao neurônio j da camada l .

Para a função de ativação do tipo função sigmoide, temos que o sinal de saída do neurônio j na camada l é dado por:

$$y_j^{(l)} = \varphi_j(v_j(n)). \quad (3.16)$$

Caso o neurônio j seja a primeira camada oculta, ou seja $l = 1$, temos

$$y_j^{(0)}(n) = x_j(n). \quad (3.17)$$

Que representa a aplicação direta do vetor de entrada a primeira camada oculta da rede.

Se o neurônio j é a camada de saída, então valor da saída $y_j^{(l)}$ será o próprio utilizado para o cálculo do erro, definidos por:

$$y_j^{(l)} = o_j(n). \quad (3.18)$$

E o erro como:

$$e_j(n) = d_j(n) - o_j(n). \quad (3.19)$$

A característica principal do algoritmo de Backpropagation é a avaliação do sinal de erro a partir do caminho inverso. Assim, a partir do cálculo do gradiente local da rede é possível realizar o ajuste dos pesos sinápticos de forma a reduzir o erro final.

O fluxo do sinal do caminho inverso pode ser observado na Fig. 3.4, na qual o sinal de erro $e_j(n)$ na iteração n propaga de forma a calcular o valor do gradiente local para um neurônio j .

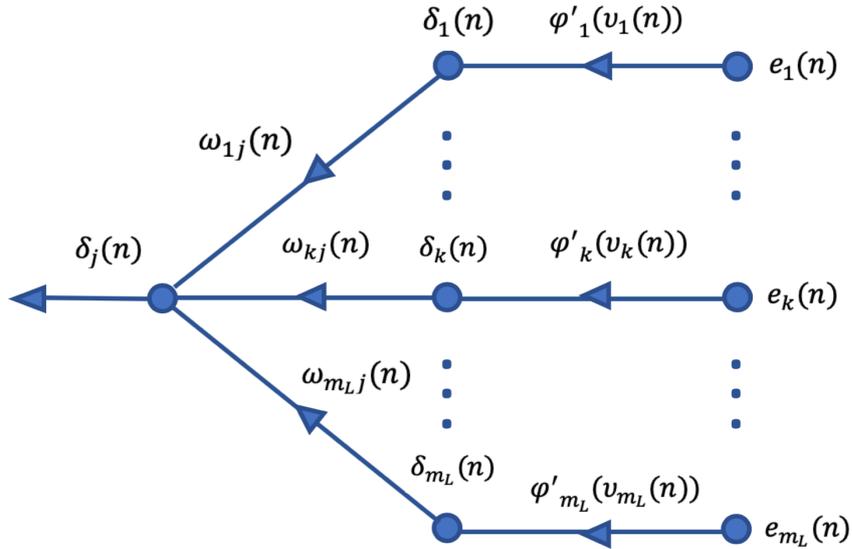


Figura 3.4 - Gráfico sinal de erro no caminho reservo - *Backward Patch*.

O cálculo do gradiente local para um neurônio j presente na camada oculta l é definido como:

$$\delta_j^{(l)}(n) = \varphi'_j(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) \omega_{kj}^{(l+1)}(n). \quad (3.20)$$

em que:

$$\varphi'_j(v_j(n)) = \frac{a \exp(-av_j(n))}{[1 + \exp(-av_j(n))]^2}. \quad (3.21)$$

é a derivada da função de ativação associada ao neurônio j aplicada ao campo local induzido do neurônio j . Tem-se para a função de ativação não-linear sigmoide, a sua forma geral é definida da seguinte forma:

$$\varphi_j(v_j(n)) = \frac{1}{1 + \exp(-av_j(n))}, \quad a > 0. \quad (3.22)$$

A função de ativação sigmoide assume valores entre 0 e 1 e sua representação gráfica é conforme gráfico abaixo:

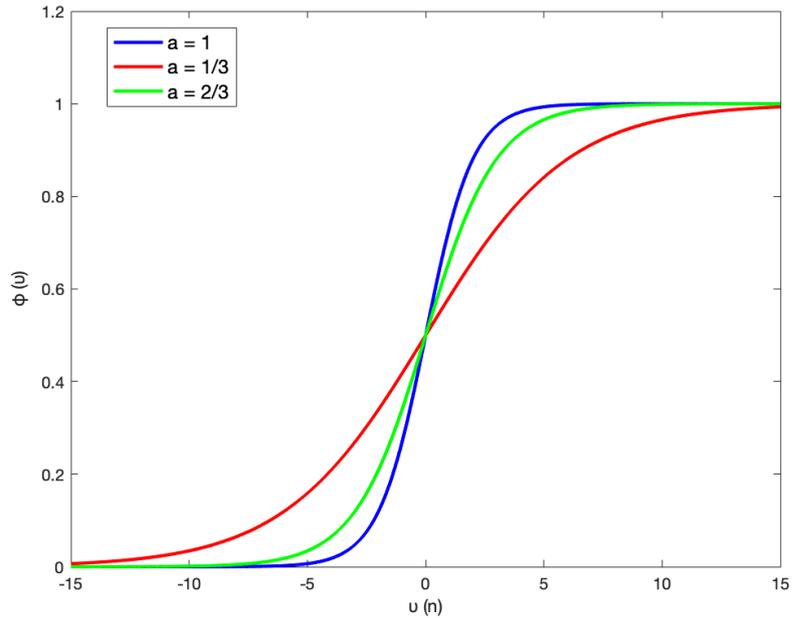


Figura 3.5 - Gráfico função de ativação do tipo sigmoide.

É importante notar que o gradiente local $\delta_j^{(l)}(n)$ do neurônio j da camada l depende diretamente dos valores do gradiente da camada imediatamente a frente $\delta_k^{(l+1)}(n)$ da camada oculta k no processo de propagação reversa. Dessa forma, caso a camada $l + 1$ à frente for a própria camada de saída, então o cálculo do gradiente do erro é realizado utilizando o valor do sinal de erro da última camada oculta:

$$\delta_j^{(l)}(n) = e_j^{(L)}(n) \varphi'_j(v_j^{(L)}(n)). \quad (3.23)$$

sendo L a camada de saída.

Assim, o ajuste dos pesos sinápticos da rede neural na camada L de acordo com a regra delta geral é definido por:

$$\omega_{ji}^{(l)}(n + 1) = \omega_{ji}^{(l)}(n) + \alpha [\Delta \omega_{ji}^{(l)}(n - 1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n). \quad (3.24)$$

em que η representa o parâmetro de taxa de aprendizado e α a constante de momento.

O ajuste dos pesos ω é influenciado pelos parâmetros α e η na medida em que estes parâmetros implicam um ajuste mais rápido dos pesos sinápticos, ou seja, se o valor dos parâmetros forem mais próximos de 1, então os ajustes que ocorrem entre iterações serão maiores, implicando maior variação dos valores do peso. Este é um ponto crítico na escolha dos parâmetros visto que se forem muito pequenos a convergência será demorada, e caso sejam muito grandes é possível que os valores diverjam e que o algoritmo não consiga alcançar o erro mínimo.

A partir desse ponto, uma sequência de iterações é necessária a fim de que pequenos ajustes

sejam feitos nos pesos sinápticos de forma a reduzir o erro observado na camada de saída de maneira que a resposta da rede neural se aproxime cada vez mais da resposta desejada $d(n)$.

3.4.2.1 Parâmetros Adaptativos

A utilização do algoritmo de treinamento que realiza o ajuste dos pesos a partir da análise da descida do gradiente de forma a buscar uma direção de maneira a minimizar o valor do erro $E(n)$ pode ser otimizado usando-se parâmetros de correção como η , taxa de aprendizado, e α , constante de momento. Essas constantes possuem função principal de acelerar a convergência e melhorar a performance do cálculo do gradiente do erro [23].

Nas fórmulas a seguir podemos observar a aplicação desses parâmetros com o objetivo de obter a variação dos pesos sinápticos $\Delta\omega_{ji}(n)$ de forma mais rápida e confiável se comprado com a equação $\omega(n)$ anteriormente mostrada.

$$\Delta\omega_i^t = -\eta \frac{\partial E^t}{\partial \omega_j} + \alpha \Delta\omega_i^{t-1}. \quad (3.25)$$

$$\Delta\omega_{ji}(n) = -\eta \frac{\partial E(n)}{\partial \omega_{ji}(n)}. \quad (3.26)$$

3.4.2.2 Taxa de Aprendizado

A taxa de aprendizado η determina a magnitude dos ajustes a serem aplicados a variação do erro $e(n)$ a cada iteração n . Dessa forma, aplicando um valor a η , entre 0 e 1, porém, geralmente utilizado como valor constante de 0,2, temos que o erro entre saída desejada e a saída $y(n)$ da rede neural é amplificada e assim, a correção e atualização dos valores dos pesos sinápticos, acelera a convergência do algoritmo. As representações de $\omega(n)$ e $\mathbf{x}(n)$ são referentes aos vetores de pesos sinápticos e entradas da rede neural, respectivamente.

$$\omega(n+1) = \omega(n) + \alpha[d(n) - y(n)]\mathbf{x}(n). \quad (3.27)$$

3.3.3 Constante de Momentum

A constante de momento α é um parâmetro de ajuste aplicado que leva em consideração alguma porcentagem, geralmente de 0,5 a 1, dos valores calculados anteriormente da variação dos pesos sinápticos. Isto é, é considerado uma taxa das variações de $\Delta\omega_{ji}(n)$ para o tempo $t - 1$ de forma a evitar que grandes oscilações dos valores de $\Delta\omega_i^t$ sejam observadas e assim acelerar a convergência do algoritmo.

$$\Delta\omega_i^t = -\eta \frac{\partial E^t}{\partial \omega_j} + \alpha \Delta\omega_i^{t-1}. \quad (3.28)$$

3.4 CONCLUSÃO

Este capítulo apresentou os principais conceitos relacionados as redes neurais, com relação a funcionalidade básica do *perceptron* e do *perceptron* de múltiplas camadas e a formalização matemática dos algoritmos de convergência e retropropagação. Nos próximos capítulos, serão abordados os conceitos aqui desenvolvidos quando da análise de dados e estudos de simulação.

4 MODELO DE TRÁFEGO

4.1 INTRODUÇÃO

As medições de tráfego de dados em redes de comunicação, embora necessárias para obter as características e padrões de determinado fluxo de dados, apresentam limitações quanto à avaliação e teste de sistemas para eventos com baixa probabilidade de ocorrência. Para tanto, o desenvolvimento de modelos de tráfego de dados [12] é relevante para testar a viabilidade e eficiência de determinado sistema de comunicação sob diferentes condições de tráfego.

Assim, a partir de modelos matemáticos que representam e reproduzem as características do tráfego real de interesse, é possível a realização de simulações e testes de forma a observar o comportamento de determinado sistema, sem a necessidade de realizar medições empíricas para cada característica de tráfego distinta. Dessa forma, a avaliação do comportamento de sistemas de comunicação se torna mais rápida e confiável [12].

No presente capítulo serão abordados os principais conceitos necessários à implementação de modelos de tráfego. Inicialmente na seção 4.2 são apresentados a definição e conceitos dos processos estocásticos. Em seguida, são expostas as características necessárias a implementação de um modelo de tráfego e o processo do tráfego poissoniano. Por fim, a seção 4.5 traz os resultados de simulação da implementação do tráfego de Poisson para modelar o padrão de ocupação espectral.

4.2 PROCESSOS ESTOCÁSTICOS

Os processos estocásticos têm por princípio a utilização de variáveis aleatórias para definição de um evento. Eventos que possuem incerteza e imprevisibilidade quanto a sua ocorrência em determinado período de tempo têm seus modelos definidos pelos processos aleatórios.

Como exemplo, temos que a quantidade de dados transmitida por um canal, denominada pacote de dados, varia de forma contínua no tempo de maneira aleatória, dependente da intensidade de tráfego de dados em determinado instante de tempo, de forma a definir a utilização do canal. Assim, a modelagem desse tipo de sistema, em que o tamanho do pacote de dados é não-determinístico em dado período de tempo, é feita utilizando-se o formalismo de processos aleatórios.

O processo aleatório em tempo contínuo é uma família de variáveis aleatórias X_t em que t

varia dentro de uma faixa específica de valores em um intervalo de tempo $[0, T]$ [27]. Podemos definir o processo de contagem de eventos N_t , para $t > 0$, como sendo a quantidade de ocorrências de determinado evento até o tempo t . Portanto, o processo de contagem N_t é um processo aleatório que conta quantas vezes um evento aconteceu do tempo 0 ao tempo t de análise.

Na Fig. 4.1 é representado o processo de contagem dos eventos para uma análise de 1000 eventos sucessivos. Interessante observar o incremento do valor de N_t , número de eventos, ao longo do tempo de análise, indicado graficamente pela função crescente.

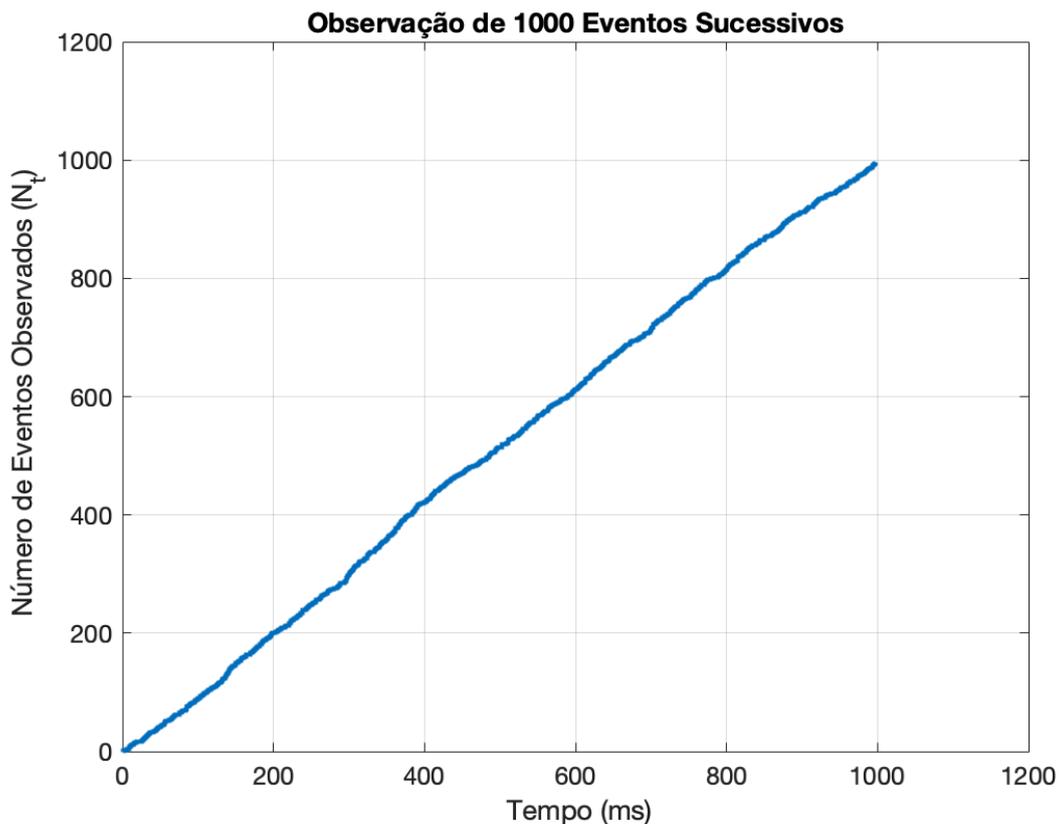


Figura 4.1 - Representação do Processo de Contagem para 1000 eventos consecutivos.

O processo de contagem de eventos é representado a partir do recorte do gráfico da Fig. 4.1 para faixa de tempo $t \in [0, 8]$ ms. No gráfico da Fig. 4.2 pode-se observar a sequência de eventos que ocorrem no canal, como a transmissão de pacote de dados, na janela de tempo de 8 ms. A sequência de eventos de acesso ao canal são computados e determinados por N_t . Para o caso de $t = 5$ ms, podemos observar a ocorrência de $N_t = 3$ eventos, ou seja, no intervalo de tempo de 0 a 5 ms ocorreram 3 eventos aleatórios no canal. Durante o período da janela de análise do gráfico podemos observar a ocorrência acumulada de $N_t = 5$ eventos, sendo que o primeiro evento ocorreu em $t = 0,7$ ms.

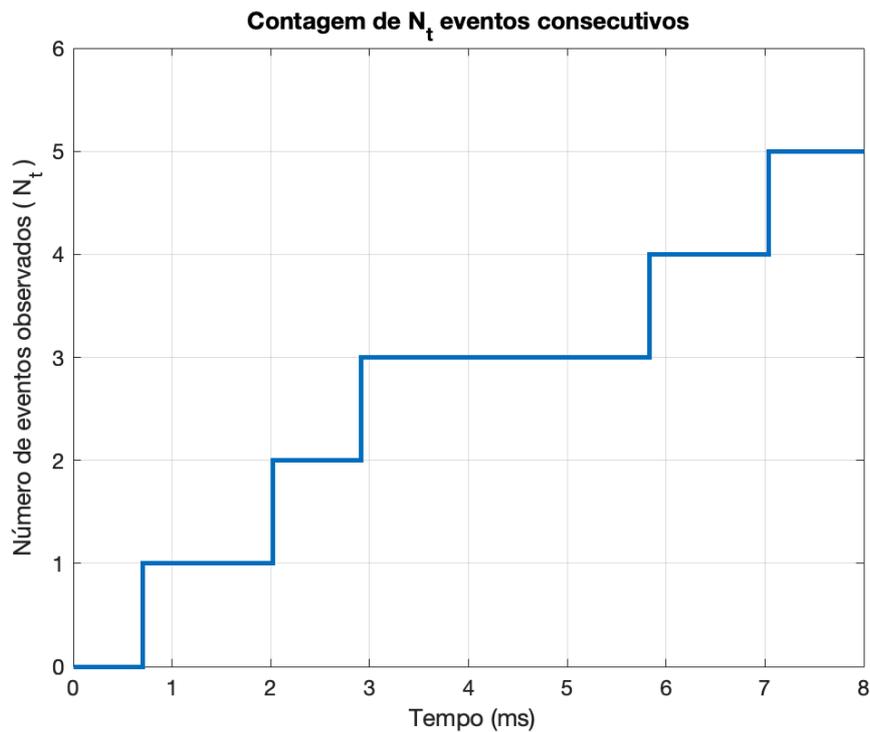


Figura 4.2 - Contagem de Eventos Consecutivos na janela de tempo $[0, 8]$ ms.

A partir do processo de contagem dos eventos de acesso ao canal, transmissão de pacote de dados, é possível avaliar a ocupação e utilização de determinado canal. É por meio da análise do número de eventos N_t que é possível definir a quantidade e duração dos eventos de acesso ao canal e com isso traçar análises com relação ao tráfego e disponibilidade do canal. O processo de contagem, portanto, é importante na realização das análises e definição das características do tráfego de dados presentes em um canal de comunicação.

Os eventos da contagem N_t seguem um padrão de alternância entre eventos de T_{ON} e T_{OFF} . Os eventos definidos por T_{ON} são os períodos de tempo em que o canal realiza transmissão, enquanto que o tempo T_{OFF} é referente ao período em que o canal não realiza transmissão. Na Fig. 4.3 é possível observar a alternância dos eventos para o cenário em que a intensidade de tráfego $\rho = 0,70$, ou seja, o período de tempo em que o canal se encontra ocupado realizando transmissão, $T_{ON} = 0,6452$, e o tempo que o canal permanece desocupado, $T_{OFF} = 0,3292$.

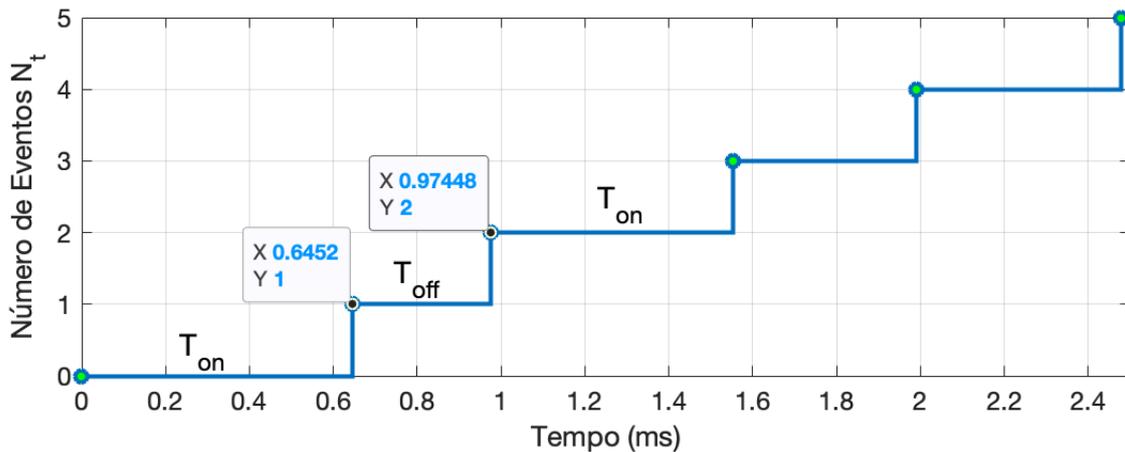


Figure 4.3 - Alternância entre eventos de T_{ON} e T_{OFF} .

4.3 MODELO DE TRÁFEGO

A utilização de modelos de tráfego como forma de representação matemática das características do tráfego real tem diferentes objetivos conforme indicado em [28]. Contudo, o principal destes é permitir a implementação de parâmetros, dados valores ótimos, com o objetivo de verificar e analisar a máxima eficiência de um sistema de rede.

A compreensão das características de tráfego é de profundo interesse no desenvolvimento de redes de comunicação confiáveis e robustas. A partir da análise detalhada do comportamento e das principais propriedades dos diferentes tipos de tráfego podemos realizar a modelagem matemática de forma a reproduzir as principais qualidades encontradas no tráfego real por meio de simulações computacionais.

A análise do tráfego em redes de comunicação fornece características que são utilizadas para modelar matematicamente o comportamento do fluxo de dados analisado. A partir da modelagem confiável dos tráfegos de internet e voz, por exemplo, podemos avaliar e desenvolver sistemas de rede cada vez mais eficientes. Sendo assim, os modelos de tráfego buscam simular as características do tráfego de dados real de forma confiável e acurada, tornando possível a previsão do desempenho e capacidade da rede de comunicação.

Faz-se necessário, portanto, um estudo das características e padrões observados nos tráfegos de dados de interesse. No presente trabalho será abordado o tráfego de Poisson e suas características, na Seção 4.4, como modelo do tráfego de voz e dados, observados em uma comunicação via dispositivos móveis. O modelo de tráfego de Poisson e chegadas serão utilizados neste trabalho para modelar os dados do padrão de ocupação espectral em um canal de comunicação.

4.3.1 Tráfego de Dados

O estudo das características comumente presentes em tráfego de voz é a presença de períodos de transmissão de dados e em seguida recepção dos dados. Na análise prática do comportamento do tráfego de voz é observada a alternância entre períodos de transmissão e ausência de transmissão. Os períodos de transmissão de um sinal de voz real têm sua média de tempo distribuída em torno de uma variável fixa λ . Logo, embora exista períodos que a transmissão pode durar mais ou menos tempo, pode ser observado que o tempo de transmissão varia em torno de uma média λ .

A caracterização do padrão de tráfego presente em um canal de comunicação é definida em termos do período de tempo em que o canal se encontra em atividade. Assim, definiremos o período em que há atividade presente no canal, seja ela de transmissão ou recepção de dados, como T_{ON} . Ou seja, o período de tempo em que o canal está ocupado, impossibilitado de realizar outra ação senão aquela já presente em atividade no canal. De modo análogo, definiremos o período de tempo em que não existe atividade no canal, em outras palavras, que o status do canal é desocupado, sendo possível realizar atividades de transmissão/recepção, como T_{OFF} .

Dada a alternância entre eventos de atividade T_{ON} e não atividade do canal T_{OFF} , característico do tráfego de voz, é possível definirmos o tempo de chegada da atividade ao canal, que é o momento no qual o canal é identificado com estado ocupado, como tempo de chegada $t_{ARRIVAL}$. Partindo da análise entre eventos, podemos definir também o tempo entre dois eventos consecutivos de atividade do canal por t_{INTER} , sendo, portanto o valor resultante do intervalo de tempo entre dois eventos de chegada $t_{ARRIVAL}$ consecutivos. Assim, podemos definir o tempo entre chegadas como:

$$t_{INTER} = T_{ON} + T_{OFF} \quad (4.1)$$

A intensidade de tráfego ρ presente no canal de comunicação é definido em termos da atividade do canal. Dessa forma, quanto maior o tempo que o canal está ocupado realizando transmissão de dados, maior será o tráfego de dados existente no canal. Portanto, definimos a intensidade de tráfego em termos dos períodos de atividade do canal como:

$$\rho = \frac{\text{média } T_{ON}}{\text{média } T_{ON} + T_{OFF}} = \frac{t_{SERV}}{t_{INTER}}, \quad (4.2)$$

em que t_{SERV} é o tempo de serviço, período de tempo este em que o canal possui estado ocupado e é definido pelo valor médio do tempo de atividade T_{ON} .

4.4 PROCESSO DE POISSON

O processo aleatório de Poisson é comumente aplicado para modelagem de sistemas em que os eventos ocorrem de modo sequencial com base em incrementos independentes. Assim, é geralmente utilizado para a análise e modelagem de tráfego de dados em sistemas de telecomunicações.

O modelo de tráfego de Poisson é bastante utilizado para modelagem de redes de voz. Este considera que os tempo entre eventos possui decaimento exponencial e são independentes entre si. Embora existam modelos com melhor desempenho para descrever o comportamento desse tipo de tráfego [29,30], no presente trabalho a análise da aleatoriedade dos eventos presente no tráfego de Poisson é suficiente para realização e teste das redes neurais para predição dos cenários de tráfego.

4.4.1 Tráfego de Poisson

O processo de Poisson é definido pela ocorrência de eventos em instantes de tempo aleatórios com taxa média de λ eventos a cada intervalo de tempo. Para definir o processo poissoniano algumas condições devem ser satisfeitas em um determinado intervalo de tempo. Dado um intervalo de tempo $[0, t]$ dividido em n subintervalos de duração $\delta = t/n$, temos que a probabilidade de ocorrência de mais de um evento em um subintervalo é desconsiderada quando comparado as probabilidades de ocorrência de um ou zero eventos. Além disso, temos que a ocorrência ou não de eventos em um subintervalo independe dos valores de ocorrência observado em outros subintervalos, ou seja, os eventos são independentes entre si [31].

Se a probabilidade de um evento ocorrer em cada subintervalo for definida como p , então a quantidade de eventos esperados em um intervalo de tempo $[0, t]$ é np , onde n representa a quantidade de intervalos. Dado que os eventos ocorrem a uma taxa λ de eventos por intervalo de tempo δ , temos que o número médio de eventos no intervalo $[0, t]$ é dado por λt . Assim, temos que:

$$\lambda t = np, \text{ para } [0, t]. \quad (4.3)$$

A quantidade de eventos $N_t(t)$ em um intervalo $[0, t]$ segue um distribuição de Poisson com taxa média de ocorrência λt :

$$P[N_t(t) = k] = \frac{(\lambda t)^k}{k!} e^{-\lambda t}, \quad \text{para } k \geq 0. \quad (4.4)$$

O processo de Poisson é caracterizado por três condições básicas [27]. A primeira afirma que, dado o tempo inicial $t_0 = 0$, então o número de ocorrências $N_0 = 0$, ou seja, a contagem de eventos é nula para o tempo inicial t_0 . Além disso, temos que, para intervalos de tempo $(t_1, t_2], (t_2, t_3], \dots, (t_n, t_{n+1}]$, os incrementos são independentes, isto é, dado N_1 como o número de ocorrências computadas até o tempo t_1 e N_2 o número de ocorrências computadas até o tempo

t_2 , então o incremento é definido como a diferença entre N_2 e N_1 . Dessa forma, sendo os incrementos independentes para intervalos de tempo disjuntos, logo o número de ocorrências N_t são independentes para tempos disjuntos.

Outra característica do processo de Poisson é que, em um intervalo de tempo $0 \leq s < t < \infty$, o incremento $N_t - N_s$ é um processo de Poisson com parâmetro $\lambda(t - s)$ caso:

$$P(N_t - N_s = k) = \frac{[\lambda(t - s)]^k e^{-\lambda(t-s)}}{k!}, \quad k \geq 0, \quad (4.5)$$

sendo λ a taxa de incremento do processo.

Os eventos no processo de Poisson são definidos a partir do tempo de ocorrência de cada evento. Temos que o tempo em que determinado evento ocorre é diretamente relacionado com o número de eventos N_t , para um tempo $t > 0$. Assim, sendo o parâmetro de distribuição λ , podemos representar o tempo em que o evento ocorre por:

$$P(T_n > t) = P(N_t < n) = \sum_{k=0}^{n-1} \frac{(\lambda t)^k}{k!} e^{-\lambda t}. \quad (4.6)$$

O tempo entre a ocorrências de dois eventos, também chamado de tempo entre chegadas t_{INTER} , pode ser definido da seguinte forma:

$$X_1 = T_1, \quad (4.7)$$

$$X_n = T_n - T_{n-1}, \quad n \geq 2. \quad (4.8)$$

Seja X_1, X_2, \dots, X_n relacionado ao tempo de ocorrência do primeiro evento ao n ésimo evento. Assim temos que a diferença entre os tempos de ocorrência de $T_n - T_{n-1}$, para $n = 2, 3, \dots$, é exatamente o tempo de duração entre os eventos. Dessa forma, a soma de todos os tempos entre chegadas dentro do período de tempo $[0, T_n]$ é o próprio valor do T_n do intervalo.

Cada intervalo entre chegadas possui uma distribuição exponencial com parâmetro λ . Assim, tem-se para X_i , para $i = 1, 2, \dots, n$, que a função densidade de probabilidade é:

$$f_{X_i}(x) = \lambda e^{-\lambda x}, \quad x \geq 0. \quad (4.9)$$

4.5 SIMULAÇÕES DE TRÁFEGO

A implementação do modelo de tráfego de Poisson tem por objetivo gerar um padrão de tráfego de dados e modelar os tempos de ocupação do espectro. Dessa forma, alguns parâmetros são fundamentais a essa implementação.

Inicialmente, temos a intensidade de tráfego ρ variando entre 50 a 80%. A janela de tempo δ possui valor fixo de 0,1 ms. O tempo entre chegadas t_{INTER} pode assumir os valores de 10, 16, 18, 20 e 22 janelas de tempo (*slots*). Por fim, temos o parâmetro λ da distribuição de Poisson definido como o inverso do tempo entre chegadas, $\lambda = 1/t_{INTER}$. Os parâmetros da simulação são apresentados na Tabela 4.1.

Tabela 4.1 - Parâmetros utilizados nas simulações de tráfego.

Parâmetro	Valor
Intensidade de Tráfego ρ	50% a 80%
Janela de tempo δ (<i>slots</i>)	0,1 ms
Tempo entre chegadas t_{INTER}	10, 16, 18, 20 e 22 <i>slots</i>

As principais características do tráfego de Poisson simulado podem ser analisadas na Seção 4.5.1 a seguir.

4.5.1 Realizações de Eventos

Na Fig 4.4 verificam-se realizações do processo aleatório de T_{ON} e T_{OFF} no intervalo de tempo $[0, 4]$ ms para as condições de $t_{INTER} = 10$ *slots* e intensidade de tráfego $\rho = 0,50$ e $\rho = 0,70$, referente ao gráfico da Fig. 4.4(a) e Fig. 4.4(b). É possível observar que o tempo de duração dos eventos de T_{ON} e T_{OFF} são proporcionais a intensidade de tráfego e que seus variam em torno do valor médio teórico de $T_{ON} = 0,50$ ms e $T_{OFF} = 0,50$ ms para a simulação apresentada na Fig. 4.4(a) e os valores de $T_{ON} = 0,70$ ms e $T_{OFF} = 0,30$ ms para a simulação apresentada na Fig. 4.4(b). A representação de t_{INTER} também é variável ao longo das 4 transições observadas em cada um dos gráfico e apresenta média de 1 segundo.

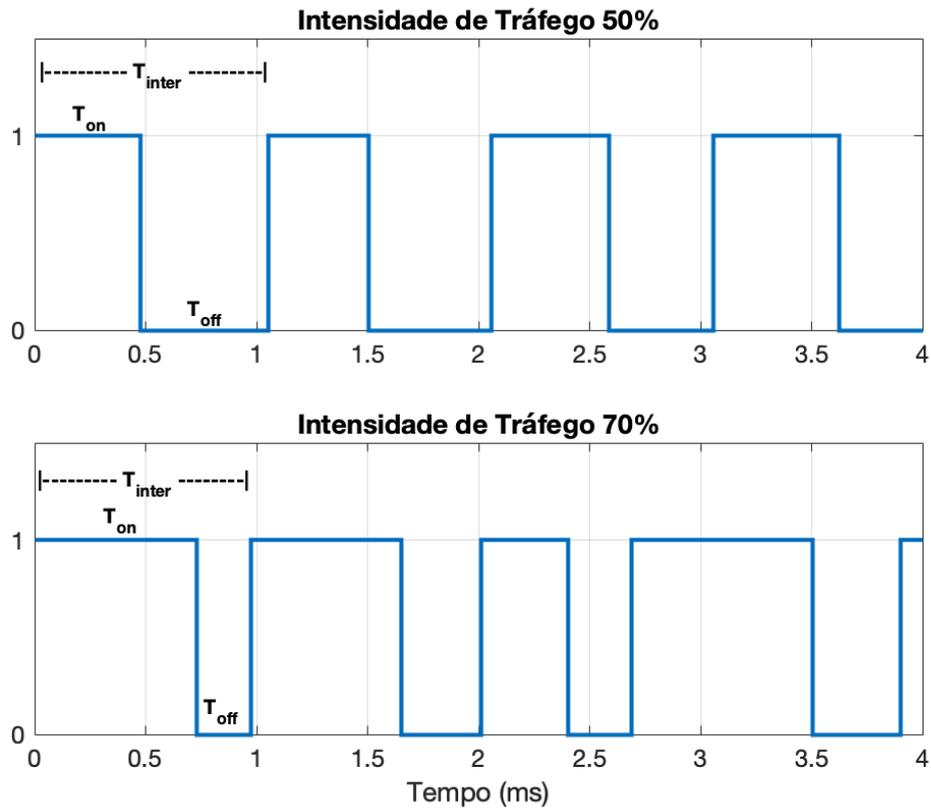


Figura 4.4 – Realizações do Processo Aleatório de T_{ON} e T_{OFF} com intensidade de tráfego (a) $\rho = 0,50$ e (b) $\rho = 0,70$.

4.5.2 Distribuição de Ocorrência dos Eventos

A distribuição dos valores do tempo de duração dos eventos, conforme apresentado na seção 4.4, devem possuir média em torno do valor λ . Esta característica pode ser constatada no gráfico da Fig 4.5. Para o caso em que $t_{INTER} = 10 \text{ slots}$, temos que o parâmetro da distribuição, $\lambda = 0,1$, é justamente o valor onde é observado o maior número de ocorrências dos eventos de T_{ON} . Na Fig 4.5, por exemplo, são observados 206 eventos com tempo de duração T_{ON} entre $[0, 0,1] \text{ ms}$.

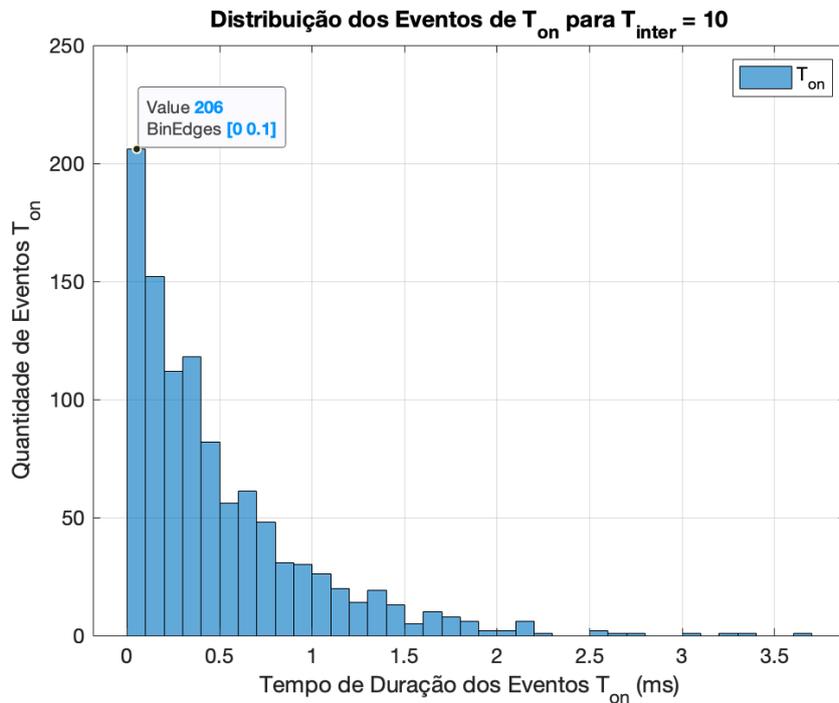


Figura 4.5 – Histograma dos Eventos de T_{ON} que ilustra distribuição da ocorrência dos eventos em torno de λ , para $t_{INTER} = 10 \text{ slots}$.

4.5.3 Decaimento Exponencial

O tráfego de Poisson é também caracterizado pelo decaimento exponencial do tempo de duração entre eventos. Analisaremos os valores das variáveis tempo de ocupação T_{ON} e os valores de tempo entre eventos de chegada t_{INTER} . As Fig. 4.6 e Fig. 4.7 apresentam os resultados de decaimento exponencial obtidos em simulações computacionais e curva teórica de decaimento exponencial teórica. As simulações dessa seção foram implementadas utilizando $t_{INTER} = 10 \text{ slots}$ e tráfego $\rho = 0,5$. Nesse contexto, a distribuição exponencial de T_{ON} e t_{INTER} possuem parâmetro teóricos $\lambda_{ON} = 0,5$ e $\lambda_{INTER} = 1$, respectivamente, referentes ao gráfico em vermelho. A avaliação dos parâmetros da distribuição de T_{ON} e t_{INTER} experimentais retorna valores $\lambda_{ON} = 0,5013$ e $\lambda_{INTER} = 0,9720$, podendo variar dentro da faixa de valores $0,4716 \leq \lambda_{ON} \leq 0,5339$ e $0,8927 \leq \lambda_{INTER} \leq 1,0625$. Portanto, os valores observados experimentalmente são aproximadamente os valores teóricos da distribuição de Poisson.

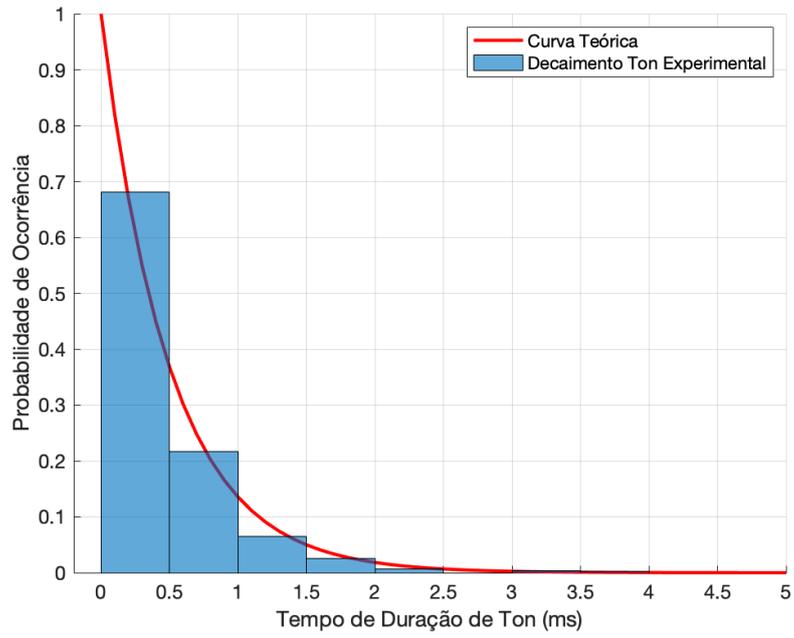


Figura 4.6 - Decaimento exponencial prático e teórico do tempo de duração de Ton.

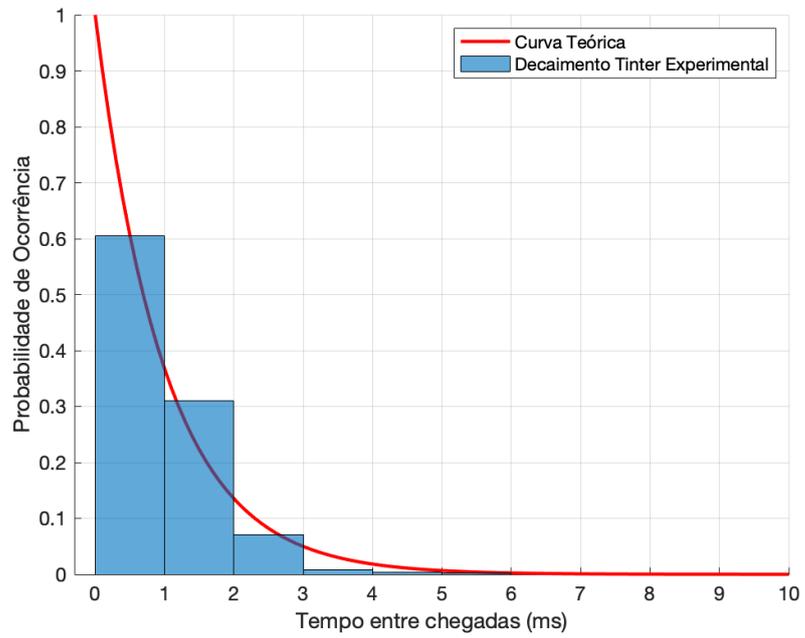


Figura 4.7 - Decaimento exponencial prático e teórico do intervalo de tempo entre chegadas.

4.5.4 Duração dos Eventos

O aleatoriedade do tempo de duração dos eventos de ocupação, T_{ON} , e disponibilidade, T_{OFF} , do canal são apresentados nos gráficos das Fig. 4.8 e Fig. 4.9, respectivamente. Em ambas é possível observar a independência e aleatoriedade do tempo de duração dos eventos, representados pelas linhas verticais azuis. Para um cenário de tráfego com intensidade $\rho = 0,7$ e $t_{INTER} = 10 \text{ slots}$, temos que, embora os eventos assumam valores distintos ao longo do tempo, o valor médio de duração, graficamente ilustrado pela linha vermelha, é aproximadamente o valor médio teórico, que para este caso é $T_{ON} = 0,7 \text{ ms}$ e $T_{OFF} = 0,3 \text{ ms}$.

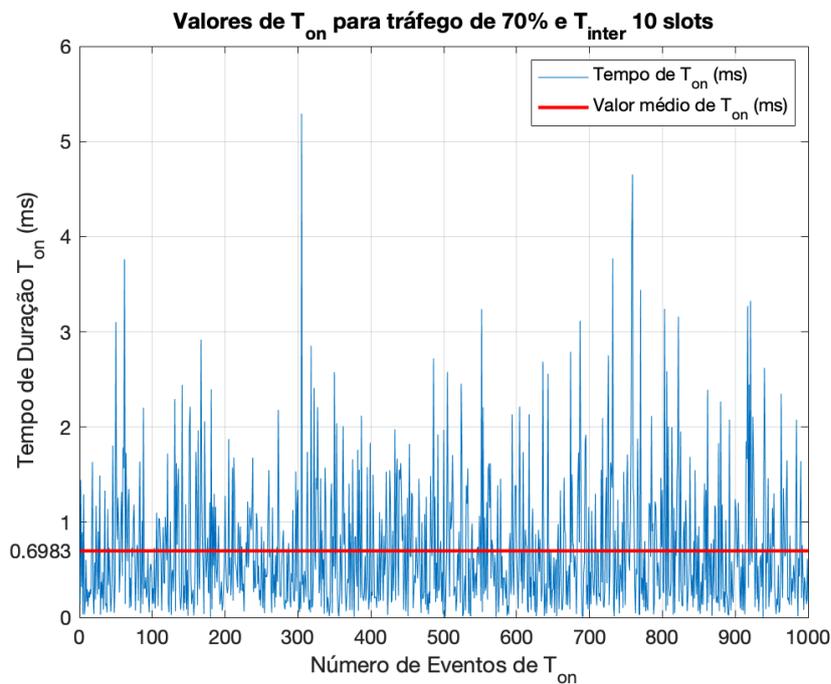


Figura 4.8 - Tempo de Duração T_{ON} .

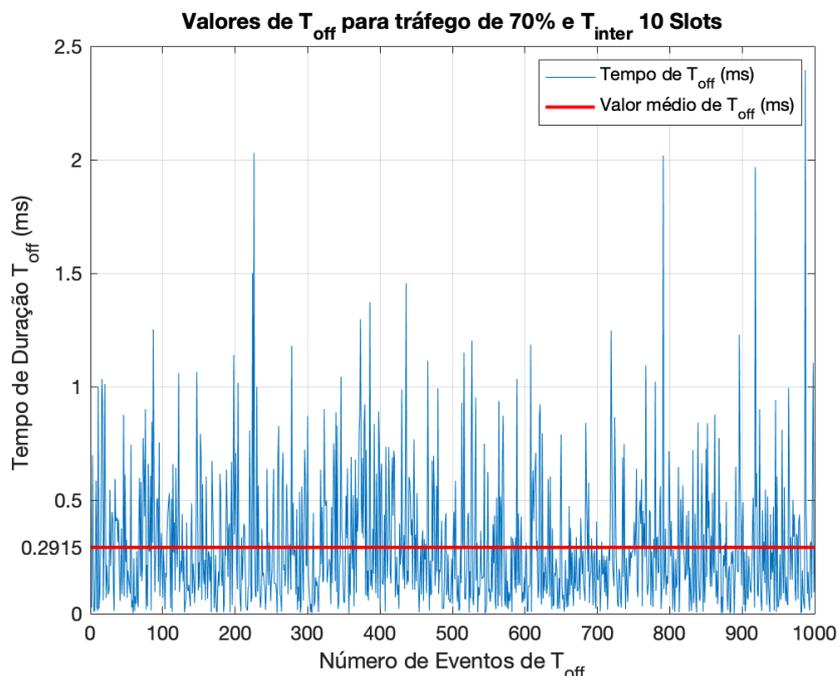


Figura 4.9 - Tempo de Duração T_{OFF} .

4.6 CONCLUSÃO

Neste capítulo foram apresentados os principais conceitos envolvidos na modelagem de tráfego real. A abordagem da formalização matemática do tráfego de Poisson desenvolvida na Seção 4.4 teve por objetivo apresentar como a modelagem é realizada e, em seguida, na última seção deste capítulo, como a implementação em algoritmo das equações implica uma caracterização do tráfego dados. Foi mostrada a implementação e resultados que caracterizam os parâmetros de tráfego como tempo entre chegadas, intensidade de tráfego, o comportamento exponencial de T_{ON} e T_{OFF} .

5 UTILIZAÇÃO DE REDES NEURAIS PARA PREDIÇÃO DE OCUPAÇÃO ESPECTRAL

5.1 INTRODUÇÃO

Conforme exposto nos capítulos anteriores, a subutilização dos canais de comunicação implica perda da eficiência na alocação de recursos e aproveitamento de bandas de frequência. Assim, a proposta de avaliação do problema a partir da aplicação de redes neurais do tipo *perceptron* múltiplas camadas surge como uma alternativa à questão da predição de ocupação espectral.

A arquitetura e funcionamento da rede neural do *perceptron* de múltiplas camadas, abordado no Capítulo 3, e a modelagem do tráfego de dados, apresentado no Capítulo 4, agora são tratados de forma conjunta para avaliação do desempenho da rede neural quando alimentada pelos dados gerados pelo modelo de tráfego. O desenvolvimento das análises e métodos avaliativos implementados neste capítulo tem como base os artigos [6, 9], em que são desenvolvidos estudos da predição da ocupação espectral utilizando redes neurais do tipo MLP e tráfego de Poisson.

Neste capítulo, será apresentada inicialmente uma revisão dos principais parâmetros necessários à implementação do *perceptron* de múltiplas camadas e sua arquitetura base implementada em simulação. Em seguida, serão definidos os critérios de avaliação do desempenho da rede neural. Finalmente, serão apresentados os resultados de simulação para avaliação do desempenho quanto a predição do estado de ocupação do canal.

5.2 PARÂMETROS DE SIMULAÇÃO

Os parâmetros e arquitetura da rede neural utilizados nas simulações são resumidos nesta seção. A Fig. 5.1 apresenta a arquitetura padrão da rede neural implementada nas simulações e possui estrutura organizada em uma entrada com quatro sinais de entradas, uma saída com dois sinais de saída e duas camadas ocultas [6]. A quantidade de neurônios nas camadas ocultas foi estabelecida como 15 e 20 neurônios, referentes à primeira e segunda camada, respectivamente [6].

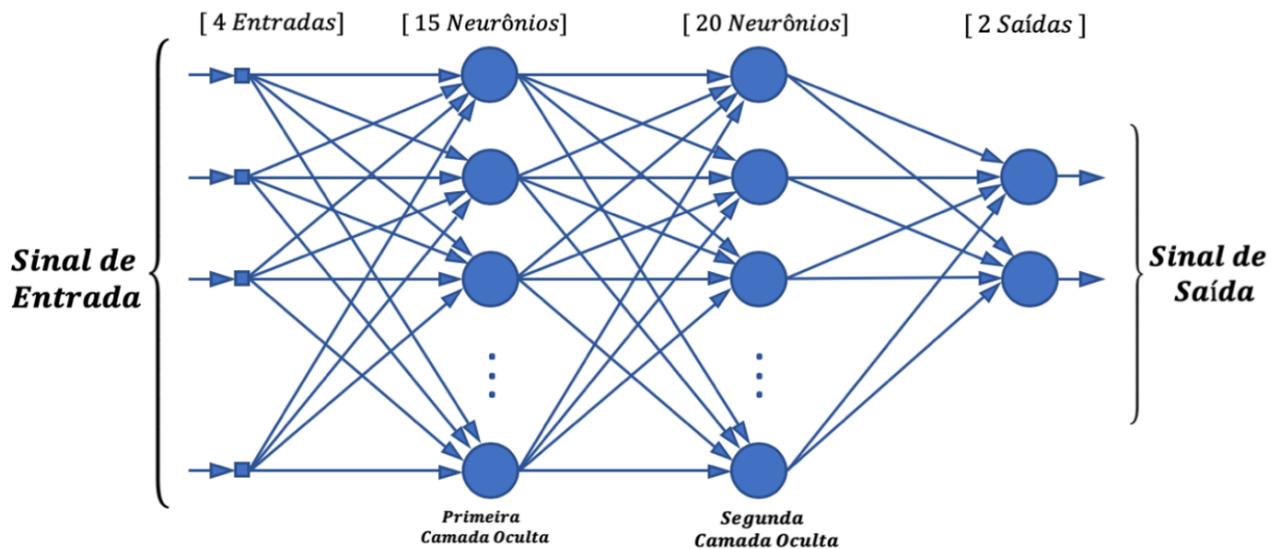


Figura 5.1 - Arquitetura da Rede Neural MLP com duas camadas ocultas com 15 e 20 neurônios, respectivamente, implementada em simulação.

A Tabela 5.1 apresenta as configurações implementadas para os parâmetros de tráfego. O tamanho do vetor de entrada estipulado em 4 *slots* é conveniente, para uma análise do padrão de tráfego do usuário primário tendo por objetivo o acesso oportunista ao espectro, dado que a resposta quanto a ocupação ou não do canal deve ocorrer no menor intervalo de tempo possível, caso contrário a utilização do espectro por parte do usuário secundário pode ser comprometida, reduzindo assim a eficiência na utilização do recurso espectral. Contudo, análises com vetor de entrada de 10 *slots* foram implementadas e apresentaram desempenho similar ao vetor com 4 janelas de tempo. A janela de tempo δ é definida igual a 0,1 ms, ou seja, o tempo total da simulação é dividido em pequenos *slots*, conforme definido no Capítulo 4, e os vetores de dados, assim como o número de amostras, são definidos em termos de janelas de tempo, ou seja, o número de amostras utilizadas são 50000 *slots*.

Os parâmetros de treinamento da rede neural são apresentados na Tabela 5.2. O critério de parada estipulado nas simulações é o gradiente do erro igual a 10^{-6} , isto é, o treinamento da rede converge quando o erro entre o sinal de saída desejada e o sinal de saída da rede neural é inferior a 10^{-6} . Os parâmetros número de épocas e número de erro na validação são estabelecidos em 10000 épocas, de forma que estes parâmetros nunca acionem a pausa do treinamento. O tamanho do vetor de amostras implementado é dividido proporcionalmente e de forma não aleatória entre vetores de treinamento, validação e teste. A proporção referente a cada um das etapas de treinamento da rede é estipulada pelos valores [0,70, 0,15, 0,15], por exemplo.

Tabela 5.1 - Parâmetros de Tráfego.

Parâmetro	Valor/Nome
Tamanho do Vetor de Entrada	4 slots
Janela de tempo δ (slots)	0,1 ms
Número de Amostras	50000
Intensidade de Tráfego ρ	50% a 80%
Tempo entre chegadas t_{INTER}	10, 16, 18, 20 e 22 slots

Tabela 5.2 - Parâmetros de Treinamento.

Parâmetro	Valor/Nome
Número de Camadas Ocultas	2
Número de Neurônios na Camadas Ocultas	[15 20]
Número de Épocas	10000
Número de Erros na Validação	10000
Função de Transferência	tansig
Gradiente do Erro	10^{-6}
Algoritmo de Treinamento	trainsecg
Proporção Treinamento/Validação/Teste	[0,70, 0,15, 0,15]
Critério de Parada	Gradiente do Erro

5.3 CRITÉRIO DE AVALIAÇÃO DO DESEMPENHO

A avaliação de desempenho do aprendizado da rede neural e da predição do estado de ocupação do canal para diferentes condições de tráfego será realizada a partir dos critérios de probabilidade de falsa detecção do estado ocupado, $Prob_{erro}(Ocupado)$, ou seja, quando o algoritmo de treinamento prevê o estado do canal como desocupado enquanto o canal de fato está ocupado. Esse critério, conforme mencionado no Capítulo 2 – Rádio Cognitivo, é de grande relevância para a avaliação de desempenho do algoritmo de treinamento uma vez que o erro na detecção do estado ocupado pode causar interferência no canal caso o usuário secundário tente acessar a banda de frequência. Será utilizada ainda a avaliação da probabilidade de falsa detecção do estado desocupado do canal, dado que a eficiência de utilização do canal, nesse caso, é reduzida, visto que uma falsa detecção diminui a utilização e possibilidades de acesso ao espectro. Será avaliado também a performance da rede neural para cenários de tráfego estático, isto é, invariante no tempo, e para cenários de tráfego dinâmico, onde a intensidade de tráfego varia no tempo.

A probabilidade de falsa detecção do estado ocupado é definido por:

$$Prob_{erro}(Ocupado) = Pr(u = \mathcal{H}_0 | y = \mathcal{H}_1). \quad (5.1)$$

em que \mathcal{H}_0 é a hipótese de detecção do estado desocupado e \mathcal{H}_1 a hipótese do canal estar ocupado. Assim, a probabilidade de erro na detecção do estado ocupado do canal é definido em termos do estado real de ocupação do canal com relação a predição do estado pela rede neural.

Inicialmente será avaliado o desempenho da rede neural sob cenário de tráfego estacionário. Os parâmetros, intensidade de tráfego ρ e t_{INTER} , são mantidos constantes nas simulações que envolvem tráfego estacionário, ou seja, o padrão de utilização do canal por parte do usuário primário permanece constante ao longo de toda simulação. A análise do desempenho quando se mantém inalterada as características de intensidade de tráfego e intervalo de tempo entre chegadas do usuário primário durante o processo de simulação é importante para avaliar o aprendizado da rede neural a partir dos valores de $Prob_{erro}(Ocupado)$ e $Prob_{erro}(Geral)$, isto é, avaliar o erro da rede neural na predição do estado do canal. Em seguida, avaliaremos o comportamento da rede neural sob condições de tráfego não estacionário, em que a intensidade de tráfego ρ e t_{INTER} do usuário primário varia no tempo. Será avaliado quanto a eficiência na detecção do padrão de comportamento de utilização por parte do usuário secundário e predição do estado do canal é influenciado nas condições não estacionárias de tráfego.

A probabilidade de erro geral de detecção do estado de ocupação do canal é definida conforme Eq. 5.2 e representa a probabilidade de ocorrer erro na predição do estado de ocupação do canal, ou seja, a predição de ocupação realizada pela rede neural não corresponde ao real estado de ocupação do canal.

$$Prob_{erro}(Overall) = Pr(u = \mathcal{H}_0 | y = \mathcal{H}_1) + Pr(u = \mathcal{H}_1 | y = \mathcal{H}_0). \quad (5.2)$$

Será avaliado também o desempenho do treinamento da rede neural para predição espectral de estados desocupados em termos do incremento na utilização do espectro, SU_{imp} , e redução da energia de sensoriamento, SE_{red} . A utilização do espectro de frequência é analisado a partir de dois tipos de usuários, I_{sense} e $I_{predict}$. O primeiro tipo de usuário seleciona aleatoriamente um canal dentre os N_{ch} canais, com diferentes características de ρ e t_{INTER} , e verifica o estado de um slot de tempo, ou seja, verifica qual o estado, ocupado ou desocupado, do *slot* do canal analisado. Quanto ao segundo tipo de usuário, que este escolhe aleatoriamente um canal dentre aqueles que o slot teve seu estado previsto como desocupado pela rede neural. As avaliações dos estados dos slots são realizadas de forma sequencial varrendo todo o vetor de amostras. Já a redução da energia de sensoriamento será avaliada a partir da quantidade de slots preditos com estado ocupado, $B_{predict}$. Se for considerado que uma unidade de energia de sensoriamento é necessária para avaliar o estado de ocupação de um slot, então o total de energia utilizada para sensoriar vetor de amostras é proporcional a quantidade de slots ocupados presentes nessa amostra, isto é, para um usuário secundário a tentativa de utilização do canal somente é possível para os casos

em que o canal está desocupado. Assim, para as janelas de tempo previstas com estado ocupado, $B_{Predict}$, o sensoriamento não será necessário, e portanto, a energia de sensoriamento será reduzida se comparado a energia necessária para avaliação do estado de todos os slots da amostra.

5.4 RESULTADOS DE SIMULAÇÃO

Esta seção apresenta os resultados de simulação obtidos para os critérios estabelecidos na Seção 5.3 deste capítulo. Os parâmetros alterados nas simulações serão apresentados em tabelas.

5.4.1 Desempenho Sob Tráfego Estacionário

O desempenho da rede neural do tipo *perceptron* de múltiplas camadas é inicialmente avaliado para o cenário de tráfego estacionário e tem por objetivo avaliar o seu desempenho quanto da predição do estado de ocupação do canal em termos de $Prob_{erro}(Ocupado)$, $Prob_{erro}(Geral)$ e $Prob_{erro}(Desocupado)$. Na Fig. 5.2 são apresentadas realizações dos eventos de T_{ON} e T_{OFF} com intensidade de tráfego $\rho = 50\%$ nas condições de $t_{INTER} = 10 slots$ e $t_{INTER} = 20 slots$. O vetor de entrada utilizado nas simulações tem tamanho de 4 slots, ou seja, 4 janela de tempo δ (slots). Na Fig. 5.2 pode-se analisar quando $t_{INTER} = 20 slots$ o período de T_{ON} é aproximadamente 1 segundo, enquanto que na condição de $t_{INTER} = 10 slots$ o tempo de atividade do canal $T_{ON} = 0,5 ms$. Assim, sendo o tamanho do vetor de entrada 4 slots, ou seja, 0,4 ms, quanto menor o tempo entre chegadas t_{INTER} , maior será a probabilidade de erro na predição do estado de ocupação do canal, visto que variações da ocupação do canal ocorrem com maior frequência no tempo, representadas pela alternância entre eventos de T_{ON} e T_{OFF} .

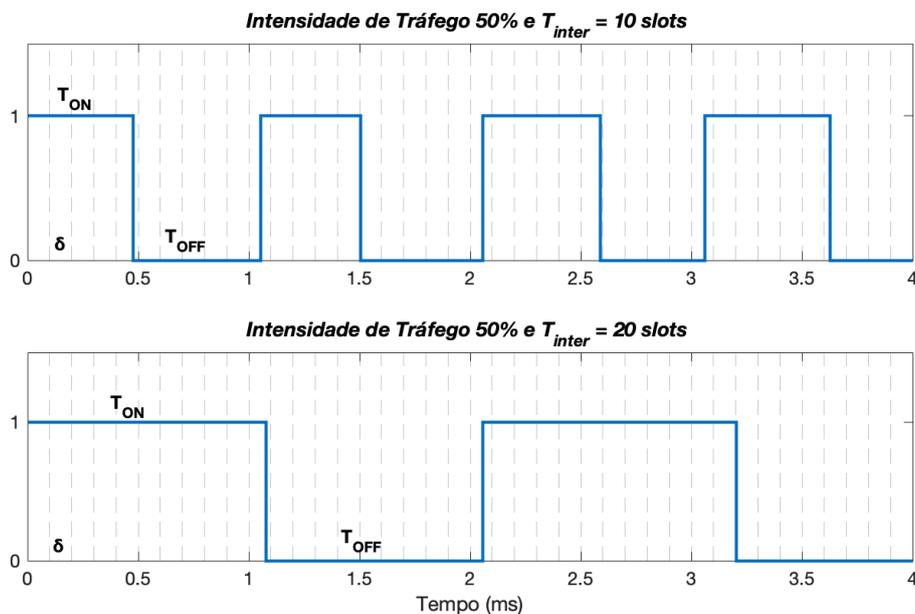


Figure 5.2 - Realizações de Processo Aleatório de T_{ON} e T_{OFF} com representação da janela $\delta = 0,10 ms$.

A avaliação do desempenho da rede MLP é apresentada na Fig. 5.3, para diferentes cenários de tráfego em que a intensidade de tráfego varia de 50% a 80% para cada valor distinto de tempo médio entre chegadas. Podemos observar que o melhor desempenho da rede é na condição de tempo médio entre chegadas $t_{INTER} = 22 \text{ slots}$. Neste caso, a probabilidade de erro na predição do estado ocupado do canal pode chegar a valores abaixo de 4%, para intensidade de tráfego de 80%. Já para o caso em que o tempo entre chegadas é de 10 *slots* a probabilidade de falsa detecção, $Prob_{erro}(Ocupado)$, é de 5,61%. Dessa forma, pode-se perceber que quanto maior a intensidade de tráfego e maior tempo médio entre dois eventos de chegada, melhor é o desempenho na predição do estado ocupado do canal, visto que as variações de estado de ocupação não ocorrem na mesma escala de tempo vetor de entrada, de 0,4 *ms*.

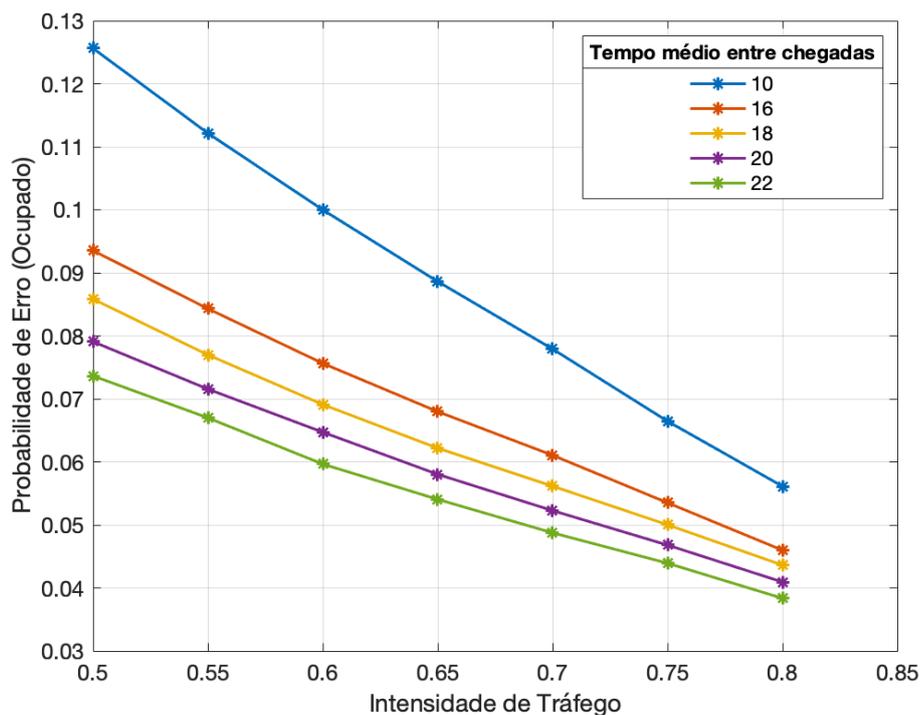


Figura 5.3 - Desempenho da predição do estado ocupado da rede MLP em diferentes cenários de tráfego.

A Fig. 5.4 apresenta os resultados referentes a probabilidade de erro geral, $Prob_{erro}(Geral)$, sob diferentes características de tráfego. A probabilidade de erro geral avalia a probabilidade da rede MLP errar a predição do estado de ocupação do canal em determinado instante δ . Da análise do gráfico é possível perceber que os valores de probabilidade de erro geral tem sua variação máxima de 2,3% com relação a probabilidade de erro do estado ocupado para intensidade de tráfego $\rho = 0,5$ e $t_{INTER} = 10 \text{ slots}$. Neste caso, em que a média dos tempos de T_{ON} e T_{OFF} é igual a 5 *slots*, a rede MLP é mais suscetível a erro. Dado que o tamanho do vetor de entrada é 4 *slots* e a predição da ocupação espectral é referente ao *slot* imediatamente seguinte ao vetor de entrada, a baixa intensidade de tráfego e pequeno intervalo médio entre chegadas t_{INTER} implica a rede neural alternância frequente entre os estados de ocupação do canal, dificultando o

aprendizado e, conseqüentemente, a predição espectral.

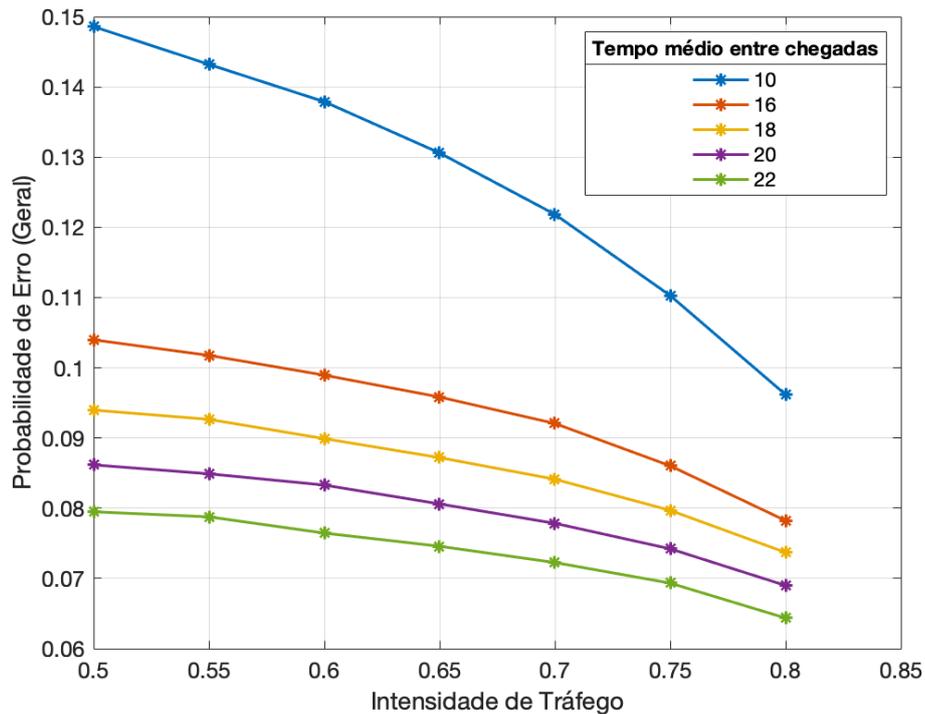


Figura 5.4 - Desempenho de predição da rede MLP em diferentes cenários de tráfego.

Os gráficos das Fig. 5.3 e Fig. 5.4 apresentam comportamento de decaimento da probabilidade de erro na predição da ocupação espectral a medida que a intensidade de tráfego aumenta. Os valores de probabilidade de erro geral apresentados na Fig. 5.4 são mais elevados em comparação com os valores de probabilidade de erro do estado ocupado apresentados na Fig. 5.3 devido a contabilização dos valores de probabilidade de erro do estado desocupado do canal.

A avaliação da probabilidade de erro geral é definida pela relação entre número total de erro de predição e tamanho do vetor de amostra, ou seja, esta probabilidade de erro leva em consideração tanto a probabilidade de erro do estado ocupado quanto a probabilidade de erro do estado desocupado do canal, enquanto que a probabilidade de erro do estado ocupado é definida pela relação entre número total de erro de predição do estado ocupado e tamanho do vetor de amostra.

A Fig. 5.5 apresenta os dados de $Prob_{erro}(Desocupado)$ da rede neural do *perceptron* de múltiplas camadas. Esta probabilidade é definida pela relação entre o número total de erros do estado desocupado e a quantidade de *slots* de fato desocupados presente na amostra de tráfego. Dessa forma, como pode ser observado no gráfico, quanto maior a intensidade de tráfego, maior é o erro na detecção do estado desocupado, visto que, a proporção de *slots* desocupados na amostra de tráfego é cada vez menor, ou seja, o universo de análise da probabilidade de erro é reduzido a medida que a intensidade de tráfego ρ se aproxima de 80%. Os valores de $Prob_{erro}(Desocupado)$, para tráfego de 50%, variam de 4,33% a 9,11% para intervalo médio entre chegadas de 22 a 10 janelas de tempo, respectivamente.

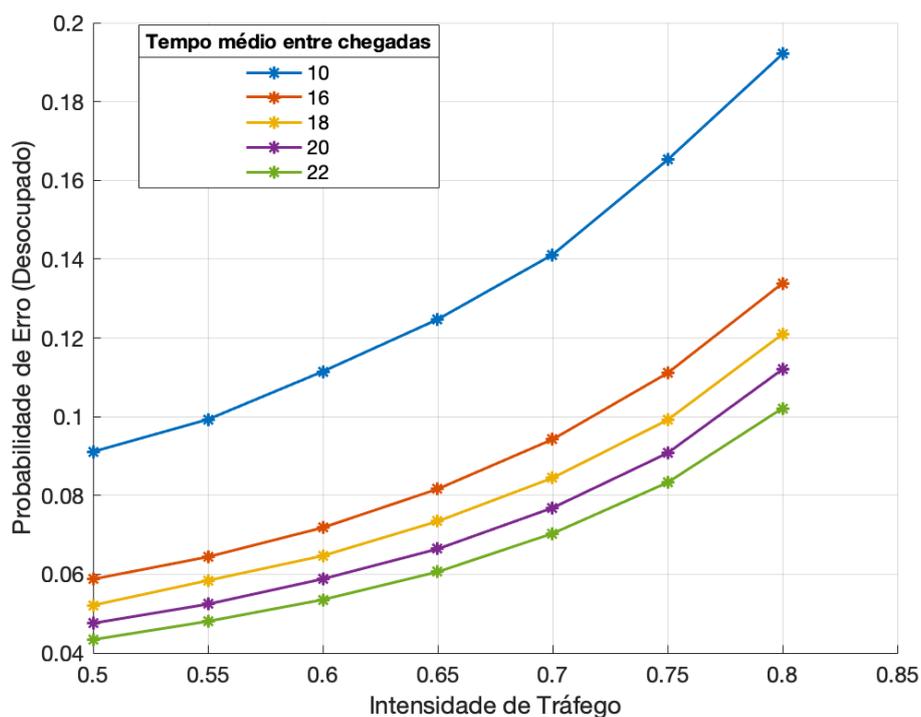


Figura 5.5 - Desempenho de predição do estado desocupado da rede MLP em diferentes cenários de tráfego.

5.4.2 Desempenho Sob Tráfego Não-Estacionário

A análise do desempenho da rede neural sob condições de tráfego não-estacionário será abordada nesta seção.

O tráfego não-estacionário do usuário primário implementado em simulação tem seus parâmetros apresentados na Tabela 5.3. Cada intervalo de tempo é composto por 6000 *slots*. No período de tempo $[t_0, t_6]$ o usuário primário tem suas características de tráfego alteradas e é sob estas condições que o desempenho da rede será avaliado.

Primeiramente é proposto a avaliação do desempenho quanto a porcentagem de erro do estado ocupado realizando apenas um treinamento da rede durante o intervalo de tempo $[t_0, t_1]$. Nesta condição tem-se que a probabilidade de erro geral é igual a 9,91% e $Prob_{erro}(Ocupado) = 8,90\%$. A segunda avaliação é desenvolvida submetendo a rede a 1000 *slots* de treinamento adicionais a cada subintervalo de $[t_1, t_6]$, isto é, a rede é novamente treinada a partir dos valores dos pesos sinápticos obtidos ao final de cada intervalo de tempo utilizando os primeiros 1000 *slots* de cada intervalo de tempo. Esta segunda avaliação retornou valor de probabilidade de erro de detecção do estado ocupado de 7,96%, muito próximo do valor observado quando realizado apenas um único treinamento durante o primeiro intervalo de tempo. Embora os valores de erro final seja proximamente iguais, pode ser observado que o número de épocas necessárias para o gradiente do erro ser menor que 10^{-6} é menor para o segundo caso, indicando que o treinamento a partir dos pesos sinápticos obtidos na primeira etapa do treinamento ocorre.

Contudo, a descida do gradiente do erro para valores abaixo de 10^{-3} é muito rápido, ou seja, é observado em menos de 3 épocas. Este fato pode contribuir para os valores aproximadamente iguais nas duas simulações.

Os resultados das simulações sob tráfego não-estacionário para a condição de tráfego 01 são apresentados na Tabela 5.4 e Tabela 5.5. Pode-se observar no intervalo de tempo $[t_1, t_2]$ o maior valor de erro na predição do estado do canal. Este desempenho, como visto anteriormente no gráfico da Fig. 5.4, que é o pior entre os analisados, é diretamente influenciado pelos padrões de tráfego apresentado pelo usuário primário, intensidade de tráfego e intervalo entre chegadas, 50% e 10 *slots*, respectivamente.

Tabela 5.3 - Parâmetros de Tráfego Não-Estacionário.

Intervalo de Tempo	t_{INTER}	ρ
$[t_0, t_1]$	20	0,70
$[t_1, t_2]$	10	0,50
$[t_2, t_3]$	18	0,667
$[t_3, t_4]$	16	0,625
$[t_4, t_5]$	22	0,50
$[t_5, t_6]$	18	0,50

Tabela 5.4 - Resultados Simulação Tráfego Não-Estacionário Probabilidade de Erro Geral.

Intervalo de Tempo	$Prob_{erro}(Geral)$	
	Treinamento Único	Treinamento Sequencial
$[t_0, t_1]$	0,0775	0,0800
$[t_1, t_2]$	0,1503	0,1443
$[t_2, t_3]$	0,0884	0,0894
$[t_3, t_4]$	0,0993	0,0954
$[t_4, t_5]$	0,0807	0,0822
$[t_5, t_6]$	0,0985	0,0941
$[t_0, t_6]$	0,0991	0,0976

Table 5.5 - Resultados Simulação Tráfego Não-Estacionário Probabilidade de Erro Ocupado.

Intervalo de Tempo	<i>Prob_{erro}(Ocupado)</i>	<i>Prob_{erro}(Ocupado)</i>
	Treinamento Único	Treinamento Sequencial
$[t_0, t_1]$	0,0553	0,0537
$[t_1, t_2]$	0,1295	0,1241
$[t_2, t_3]$	0,0628	0,0639
$[t_3, t_4]$	0,0747	0,0715
$[t_4, t_5]$	0,0749	0,0774
$[t_5, t_6]$	0,0879	0,0870
$[t_0, t_6]$	0,0809	0,0796

Na Tabela 5.6 é apresentada a quantidade de épocas de treinamento para a condição de tráfego da Tabela 5.3. Nesta condição de tráfego, tem-se que o treinamento único converge para valores de gradiente do erro abaixo de 10^{-6} em 571 épocas, sendo observado o melhor desempenho da rede neural na etapa de validação na época 23, ou seja, nesta o erro de validação atinge seu valor mínimo. Quando aplicado o treinamento sequencial, sob a mesma condição de tráfego, tem-se que o treinamento converge em 573 épocas. A análise de 50 treinamentos sequencial mostra que, para o primeiro intervalo de tempo $[t_0, t_1]$, apenas 4 treinamentos apresentaram erro de validação mínimo em menos de 10 épocas, representado na quarta coluna da Tabela 5.6, enquanto que no intervalo de tempo $[t_1, t_6]$, em que ocorre o treinamento adicional de 1000 *slots* no início de cada subintervalo, é observado em 60% dos treinamentos a ocorrência da melhor época na etapa de validação, ou seja, erro de validação mínimo, em menos de 10 épocas. Embora a probabilidade de falsa detecção e erro geral na predição do estado de ocupação do canal para os casos de treinamento único e treinamento sequencial apresentarem resultados com diferença inferior a 2%, tem-se que a implementação do treinamento sequencial favorece a ocorrência da melhor época logo no início da etapa de validação, isto é, alcançar erro de validação mínimo em menor quantidade de épocas.

Table 5.6 - Resultados Simulação Tráfego Não-Estacionário Número de Épocas de Treinamento.

Intervalo de Tempo	Máximo de Épocas Treinamento Sequencial	Melhor Época Treinamento Sequencial	Quantidade de Melhores Épocas < 10 Treinamento Sequencial
$[t_0, t_1]$	590	29,22	4
$[t_1, t_2]$	457	21,90	17
$[t_2, t_3]$	620	13,04	34
$[t_3, t_4]$	598	10,86	38
$[t_4, t_5]$	596	14,38	26
$[t_5, t_6]$	578	12,74	34
$[t_0, t_6]$	573	17,02	25,5

5.4.3 Incremento na Utilização do Espectro

A análise do incremento observável na utilização do espectro é desenvolvida a partir da diferença entre o número de slots desocupados sensoriados por dois tipos de usuários, I_{Sense} e $I_{Predict}$. Na Tabela 5.7 são apresentados os dados para cada um dos N_{ch} canais. A simulação é elaborada de forma que os dois usuários escolhem aleatoriamente um slot dentre os canais, sendo que, para o usuário I_{Sense} , este pode selecionar qualquer dos N_{ch} canais, enquanto o usuário $I_{Predict}$ tem seu universo de escolha dos canais reduzido àqueles que têm seus slots previamente identificados como desocupados. Assim, a porcentagem de incremento de utilização do espectro é definida por:

$$SU_{imp}(\%) = (I_{Predict} - I_{Sense})/I_{Sense} \quad (5.1)$$

Tabela 5.7 - Parâmetros de Canais para Diferentes Cenários de Tráfego.

Número do Canal	t_{INTER}	ρ
1	16	0,5625
2	18	0,6667
3	10	0,50
4	22	0,6818
5	20	0,50
6	10	0,70
7	18	0,50
8	22	0,50

Os resultados da simulação dos usuários I_{sense} são apresentados na Tabela 5.8. O tamanho da amostra analisada é de 9951 slots. O valor de I_{sense} é referente a quantidade de slots desocupados verificados para cada um dos canais. Podemos perceber que o valor total de $I_{sense} = 3640$, o que representa um tráfego médio experimental $\rho = 57,67\%$ analisando a intensidade de tráfego média de todos os canais, e $\rho = 63,5\%$ de tráfego médio teórico. Dessa forma, para a escolha aleatória dos canais, temos os valores de I_{sense} igualmente distribuídos em torno do seu valor médio de 455 slots desocupados, a exceção dos canais número 2, 4 e 6, visto que estes possuem maior intensidade de tráfego e, portanto, menor quantidade de slots desocupados serão detectados.

Tabela 5.8 - Resultados Incremento na Utilização Espectral.

N_{ch}	I_{sense}	$I_{predict}$	$SU_{imp}(\%)$
1	472	1090	130.90
2	358	774	116.20
3	513	1125	119.29
4	346	764	120.81
5	565	1387	145.48
6	266	487	83.08
7	552	1356	145.65
8	569	1420	149.56
Total N_{ch}	3640	8404	130.88

Tabela 5.9 - Número de Vezes em que cada canal foi selecionado para análise $I_{predict}$.

Número do Canal	Quantidade
1	1290
2	930
3	1428
4	898
5	1561
6	705
7	1547
8	1588

Os resultados da simulação $I_{Predict}$, que leva em consideração a predição do estado de ocupação do canal, são apresentados na Tabela 5.8. Os valores de $I_{Predict}$ neste caso são significativamente maiores quando comparamos à primeira simulação apresentada nesta seção. Quando há avaliação do estado do slot apenas quando este é previamente detectado como desocupado, podemos constatar que a porcentagem de incremento na utilização do espectro é de no mínimo 83,08%, chegando a valores de quase 150% de melhoria. Embora significativamente superiores, os valores de $I_{Predict}$ são, de fato, possíveis. O número de vezes que cada um dos canais foi selecionado na análise de $I_{Predict}$ são apresentados na Tabela 5.9. De forma a se obter uma representação visual dos valores encontrados, temos os gráficos das Fig. 5.8 e Fig. 5.9.

A Fig. 5.8 mostra a intensidade de tráfego por canal, tal qual apresentado na Tabela 5.5. Já na Fig. 5.9 os valores de $I_{Predict}$ da Tabela 5.8 e os valores da quantidade de vezes em que cada canal foi selecionado, apresentado na Tabela 5.9, são dispostos conjuntamente. É possível analisarmos que, quanto maior a intensidade de tráfego, porcentagem de T_{ON} na Fig. 5.8, menores são os valores de $I_{Predict}$ observados na Fig. 5.9. Ainda nesta Figura, é possível analisar que a diferença entre os valores de $I_{Predict}$ e seleção de cada canal é justificado pela probabilidade de erro na detecção de estado desocupado do canal, isto é, embora determinado canal tenha seu estado previsto como desocupado, quando do sensoriamento do estado real do *slot*, este é identificado como ocupado, e portanto, o valor de $I_{Predict}$ não é incrementado.

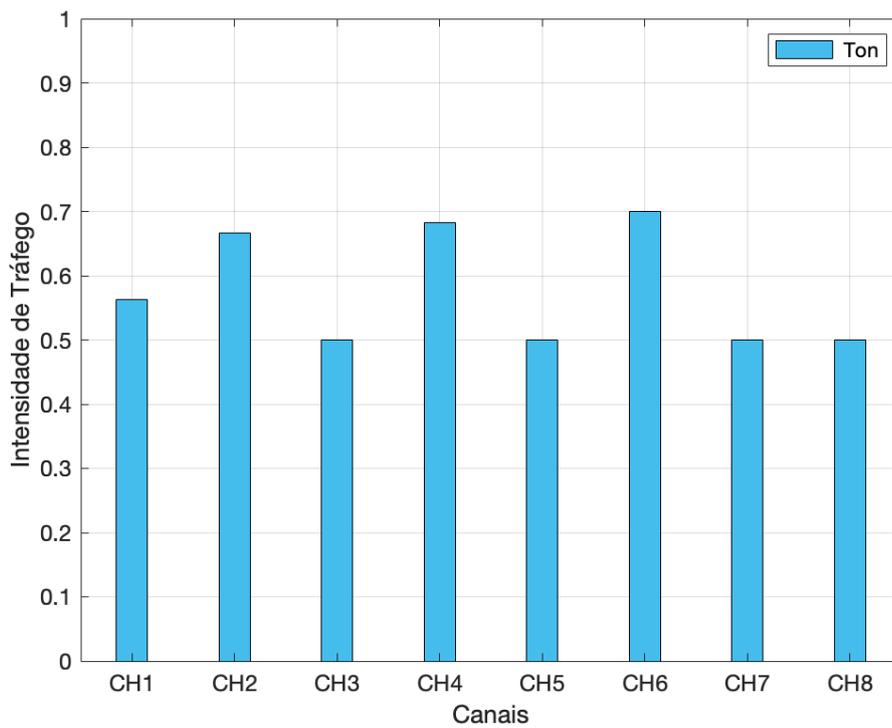


Figura 5.6 - Intensidade de Tráfego por Canal.

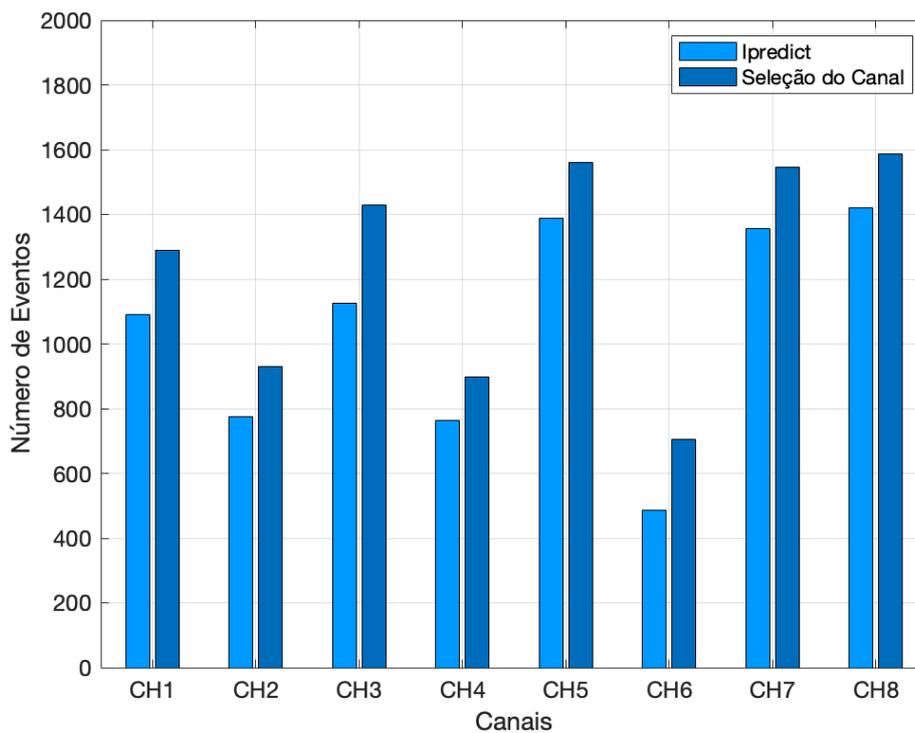


Figura 5.7 - Número de eventos de seleção aleatória do canal e quantidade comparativa de slots desocupados, $I_{predict}$.

5.4.4 Redução da Energia Espectral

A análise da redução da energia de sensoriamento do espectro é analisada em termos da quantidade de *slots* identificados como ocupado. Se considerarmos como uma unidade energética a energia necessária para sensoriar um *slot* da amostra, temos que, para um usuário secundário, em que o acesso ao espectro somente é possível na situação em que o canal encontra-se desocupado, então haverá redução na energia de sensoriamento do espectro. Assim, é definido a porcentagem de redução da energia de sensoriamento por:

$$SE_{red}(\%) = \frac{B_{Predict}}{\text{Tamanho da Amostra}}, \quad (5.2)$$

em que $B_{Predict}$ a quantidade de slots detectados como ocupados.

Os dados são apresentados na Tabela 5.10 a seguir. Os dados foram gerados a partir da simulação de tráfego com intensidade de 50% e 9990 *slots* no vetor de amostra. Assim, é possível perceber que a implementação do algoritmo de predição reduz a utilização da energia de sensoriamento do espectro em no mínimo 54,44%.

Tabela 5.10 - Porcentagem de Redução da Energia de Sensoriamento.

t_{INTER}	$B_{Predict}$	$SE_{red}(\%)$
10	5898	59,04
16	5579	55,85
18	5528	55,34
20	5470	54,75
22	5438	54,44

5.5 SIMULAÇÕES COMPLEMENTARES

Nesta seção, as simulações apresentadas tem por objetivo avaliar o desempenho da rede neural MLP quanto ao erro na predição do estado ocupado do canal nas condições de alteração do algoritmo de treinamento, quantidade de amostras de treinamento e proporção de divisão das amostras em treinamento, validação e teste. As Fig. 5.8, Fig. 5.9 e Fig. 5.10 apresentam os resultados de simulação quando realizada a alteração de apenas um parâmetro de treinamento em três cenários diferentes.

5.5.1 Análise Comparativa de Desempenho: Algoritmo de Treinamento

O desempenho da rede neural quanto ao algoritmo de treinamento utilizado pode ser observado na Fig. 5.8 e os parâmetros utilizados em simulação são apresentados na Tabela 5.11. Foi realizado o treinamento da rede neural utilizando-se os algoritmos *trainscg*, *trainlm* e *traingdx*. O algoritmo *trainscg* utiliza o método do gradiente conjugado para realiza a atualização dos pesos sinápticos, enquanto que o algoritmo *trainlm* realiza a atualização dos pesos sinápticos a partir da implementação do otimização de Levenberg-Marquardt. A utilização do algoritmo *traingdx* foi motivada pela possibilidade de definir parâmetros de incremento e decremento da taxa de aprendizado, ou seja, regular a taxa de aprendizado a cada iteração.

Tabela 5.11 - Parâmetros de Simulação: Avaliação do Algoritmo de Treinamento.

Parâmetro	Valor/Nome
Número de Amostras	30000
Intensidade de Tráfego ρ	50%
Tempo entre chegadas t_{INTER}	18 slots
Número de Neurônios na Camadas Ocultas	[15 20]
Número de Épocas	10000
Número de Erros na Validação	10000
Função de Transferência	tansig
Gradiente do Erro	10^{-6}
Algoritmo de Treinamento	<i>trainscg</i> , <i>trainlm</i> , <i>traingdx</i>
Proporção Treinamento/Validação/Teste	[0,70, 0,15, 0,15]
Critério de Parada	Gradiente do Erro

Pode-se observar na Fig. 5.8 que não existe diferenças significativas no desempenho da rede neural quanto ao erro na predição do estado ocupado do canal quando diferentes algoritmos de treinamento do tipo *backpropagation* são utilizados. Contudo, o tempo de treinamento da rede é três vezes maior para o algoritmo *trainlm* quando em comparação com *trainscg* e *traingdx*. Para o caso de intensidade de tráfego $\rho = 80\%$ é possível observar que a simulação é insensível ao tipo de treinamento utilizado.

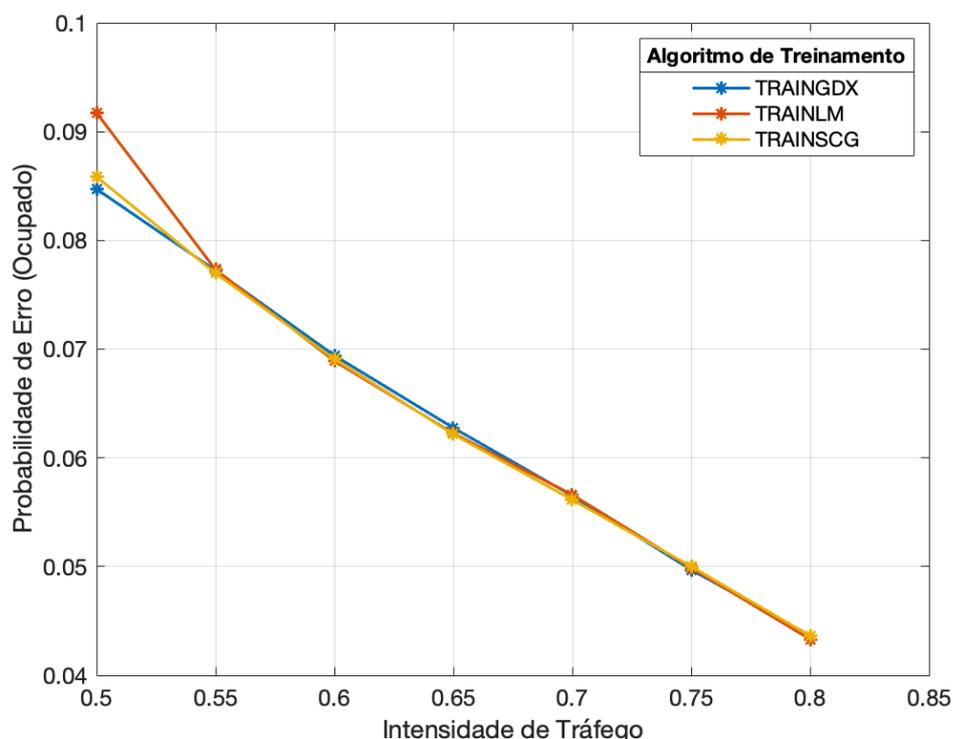


Figura 5.8 - Gráfico comparativo entre diferentes algoritmos de treinamento.

5.5.2 Análise Comparativa de Desempenho: Quantidade de Amostras de Treinamento

Nesta seção foi avaliado o desempenho da rede neural MLP utilizando o algoritmo de treinamento *trainscg* alimentado com amostras de diferentes tamanhos apresentadas na Tabela 5.12. O resultado de treinamento da rede apresentado na Fig. 5.9 indica diferença do desempenho entre as condições de 20000, 30000 e 50000 amostras inferior a 0,5%. A $Prob_{erro}(Ocupado)$ é inferior a 4,5% para os cenários analisados. É possível observar para a condição de número de amostras acima de 100000 *slots* que o valor da probabilidade de erro na detecção aumenta para valores acima de 35%, caracterizando o treinamento excessivo da rede neural (*overtraining*). Assim, a utilização de 30000 amostras para alimentação da rede MLP apresenta melhor desempenho quanto a $Prob_{erro}(Ocupado)$.

Tabela 5.12 - Parâmetros de Simulação: Avaliação Quantidade de Amostras.

Parâmetro	Valor/Nome
Número de Amostras	20000, 30000, 50000
Intensidade de Tráfego ρ	50%
Tempo entre chegadas t_{INTER}	18 slots
Número de Neurônios na Camadas Ocultas	[15 20]
Número de Épocas	10000
Número de Erros na Validação	10000
Função de Transferência	tansig
Gradiente do Erro	10^{-6}
Algoritmo de Treinamento	trainscg
Proporção Treinamento/Validação/Teste	[0,70, 0,15, 0,15]
Critério de Parada	Gradiente do Erro

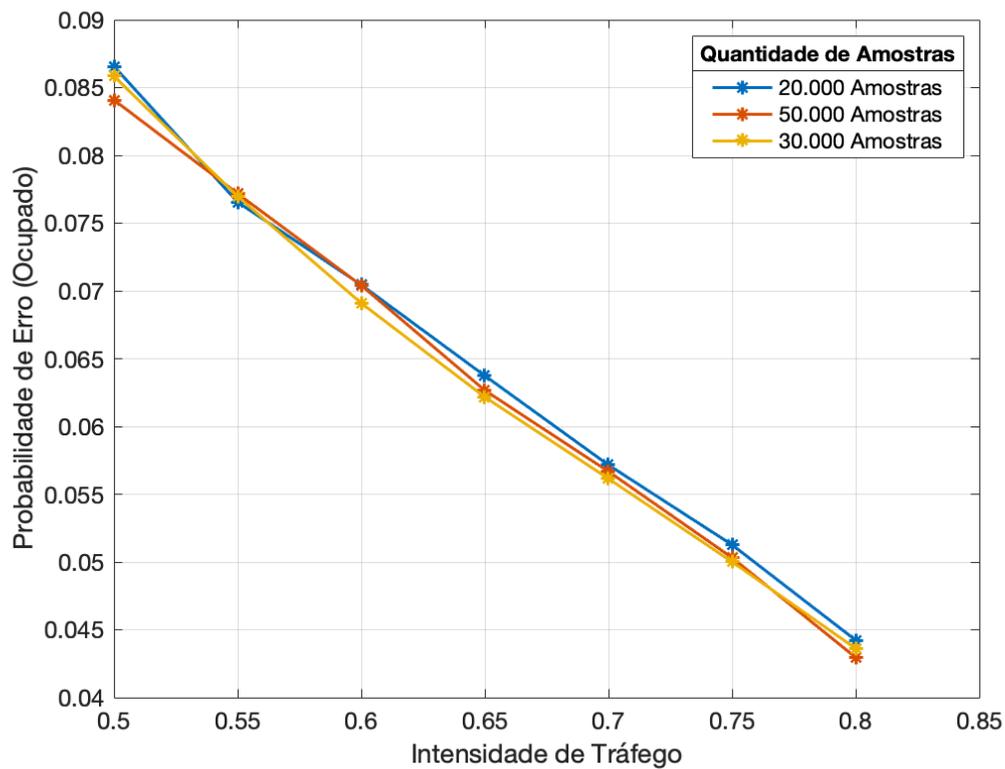


Figura 5.9 - Gráfico comparativo entre diferentes tamanho de amostra.

5.5.3 Análise Comparativa de Desempenho: Proporção entre Treinamento/Validação/Teste

A divisão do vetor de amostra para alimentar a rede neural pode ser realizada de forma a se obter diferentes proporções da amostra para cada uma das etapas: treinamento, validação e teste. Nas simulações a amostra foi dividida em três partes referentes as etapas de treinamento, validação e teste de forma sequencial, ou seja, dada um proporção $[0,70, 0,15, 0,15]$ de divisão das amostras, tem-se que o vetor utilizado para treinamento é correspondente a 70% dos primeiros valores do vetor de amostra, enquanto o vetor de teste corresponde aos últimos 15% dos valores da amostra. Os parâmetros implementados em simulação são apresentados na Tabela 5.13. Resultados de simulação apresentados na Fig. 5.10 mostram que não há diferenças significativas quanto ao desempenho da rede neural para $Prob_{erro}(Ocupado)$. Contudo, neste trabalho optou-se pela utilização da proporção $[0,70, 0,15, 0,15]$ de divisão da amostra devido ao melhor desempenho quanto a probabilidade $Prob_{erro}(Ocupado)$ nas condições de tráfego $\rho = 50\%$ e $\rho = 80\%$ em comparação com outras proporções de divisão da amostra.

Tabela 5.13 - Parâmetros de Simulação: Avaliação Proporção de Divisão da Amostras.

Parâmetro	Valor/Nome
Número de Amostras	30000
Intensidade de Tráfego ρ	50% a 80%
Tempo entre chegadas t_{INTER}	18 slots
Número de Neurônios na Camadas Ocultas	[15 20]
Número de Épocas	10000
Número de Erros na Validação	10000
Função de Transferência	tansig
Gradiente do Erro	10^{-6}
Algoritmo de Treinamento	trainscg
Proporção Treinamento/Validação/Teste	$[0,60, 0,20, 0,20]$, $[0,70, 0,15, 0,15]$, $[0,90, 0,05, 0,05]$.
Critério de Parada	Gradiente do Erro

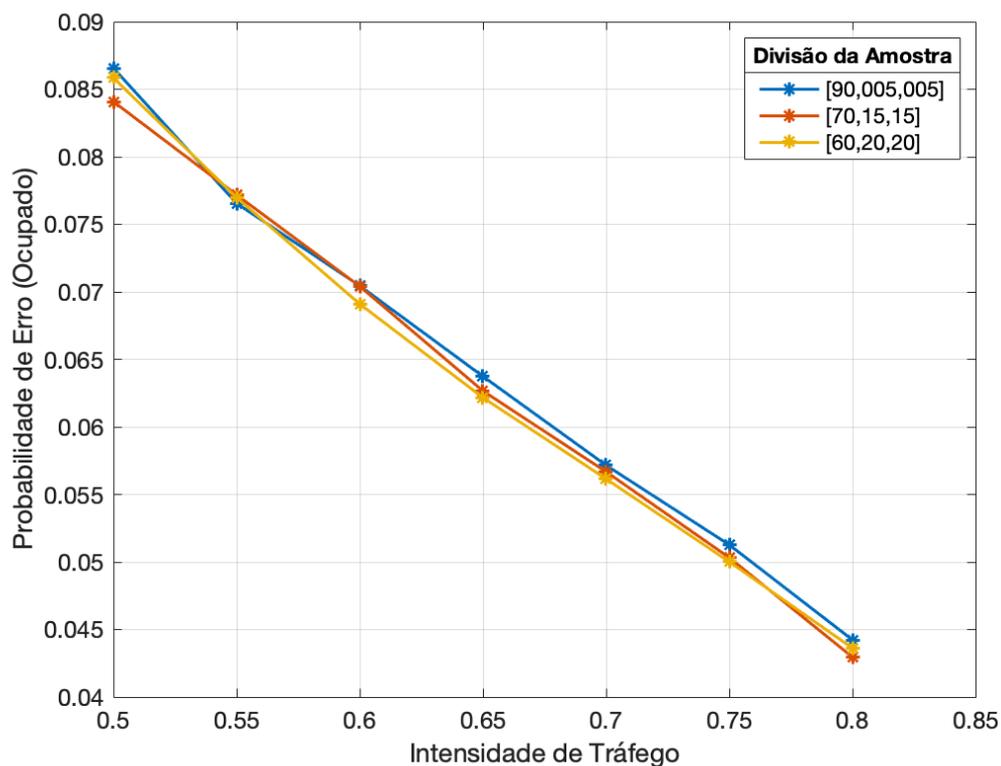


Figura 5.10 - Gráfico comparativo entre diferentes Proporções de Divisão das Amostras.

5.6 CONCLUSÕES

Neste capítulo foram apresentados os resultados de simulação para avaliação do desempenho da rede neural do tipo *perceptron* de múltiplas camada em diferentes cenários utilizando o tráfego de Poisson para modelar a ocupação espectral. Foi possível analisar o desempenho da rede MLP sob cenário de tráfego estacionário, em que apresenta melhor performance quanto o erro na predição do estado ocupado do canal inferior a 4% para a condição de tráfego de 80% e tempo entre chegadas de 10 *slots*. Em seguida avaliou-se o desempenho da rede MLP na condição de tráfego não estacionário, em que foi possível analisar a baixa influência do treinamento único e treinamento sequencial no desempenho da predição espectral, com valores de probabilidade de erro geral de 9,91% e 9,76%, respectivamente. Tal comportamento é justificado principalmente à descida do gradiente do erro à 10^{-3} em três épocas. Resultados de simulação mostram que a predição do estado de ocupação do canal reduz a energia necessária ao sensoriamento espectral em, pelo menos, 54% e incrementa a utilização do espectro de frequência em até 150%. E finalmente na seção 5.5 de resultados, observou-se que mesmo alterando os algoritmos de treinamento e os parâmetros de quantidade de amostras e proporção de divisão das amostras as redes neurais apresentam desempenho semelhante, o que é um indício que a rede neural implementada esteja ajustada em seu melhor desempenho para as condições analisadas.

6 CONCLUSÕES

Este trabalho teve por objetivo a análise do desempenho da utilização de redes neurais do tipo perceptron de múltiplas camadas para predição de tráfego e ocupação espectral em sistemas de transmissão oportunistas para aplicação em um cenário do tipo rádio cognitivo.

No capítulo introdutório, foi apresentado o problema de escassez de recursos espectrais. Atualmente, o espectro de frequência é alocado tendo por princípio atender a demanda de usuários licenciados, o que implica subutilização das bandas de frequência. Neste contexto, surge as propostas de rádio cognitivo, com ênfase na etapa de sensoriamento espectral, para a solução do problema em questão.

Em seguida, foram apresentados os conceitos envolvidos no sistema de rádio cognitivo. O ciclo cognitivo e suas etapas de sensoriamento, análise espectral, gerenciamento espectral e adaptação dos parâmetros de rádio são introduzidas brevemente, bem como capacidades cognitiva e de reconfigurabilidade do rádio cognitivo. No capítulo 2, tem-se por objetivo analisar com maior detalhamento a etapa de sensoriamento espectral, em que foram definidas as oportunidades de transmissão, lacunas espectrais, e os critérios de avaliação de desempenho da rede neural do tipo perceptron de múltiplas camadas por meio da probabilidade de falso alarme e falsa detecção.

O capítulo 3 apresentou os conceitos mais importante referente às redes neurais. Neste, foi abordado a motivação primeira do estudo de estruturas de redes neurais artificiais, o processo de aprendizagem dos algoritmos e a formalização matemática da célula base, o *perceptron*. O *perceptron*, estrutura de classificação de padrões que desempenha papel fundamental na implementação de algoritmos de treinamento, tem sua formalização matemática apresentada juntamente com os conceitos de pesos sinápticos, função de ativação e teorema de convergência. Em seguida, foi apresentado o *perceptron* de múltiplas camadas, MLP, o qual tem sua arquitetura de rede composta por maior quantidade de neurônios, que são dispostos em camadas, divididas entre camadas de entrada, ocultas e de saída, e possuem entre si ligações realizadas pelos pesos sinápticos, atuando, portanto, como uma rede de neurônios interligada, sendo atribuído a esse tipo de rede alta conectividade entre as células neuronais. Ainda no capítulo 3, o algoritmo de retropropagação (*backpropagation*), comumente utilizado para realizar o treinamento de redes neurais do tipo MLP foi apresentado e seu formalismo matemático, definido.

No capítulo 4 foram apresentados os conceitos necessários à implementação de modelos de tráfego. As características e padrões do tráfego real de dados e voz foram modeladas matematicamente e foram definidas pelos processos estocásticos, eventos que possuem incerteza e imprevisibilidade quanto a sua ocorrência. O padrão de tráfego de dados, seguindo a distribuição de Poisson, implementado em código neste capítulo, foi então analisado e suas principais características constatadas computacionalmente. Resultados de simulação mostraram que o tráfego poissoniano implementado possui caráter não determinístico, em que os eventos de T_{ON} são distribuídos em torno do parâmetro λ e possuem decaimento exponencial, conforme definição

do tráfego de Poisson.

Finalmente, analisou-se o desempenho de redes neurais do tipo perceptron de múltiplas camadas para predição de ocupação espectral. Inicialmente, foi definida uma arquitetura base de rede neural, para então utilizar do padrão de ocupação espectral que segue uma distribuição do tipo Poisson para alimentação da rede. A arquitetura base da rede foi composta por quatro neurônios na camada de entrada, 15 e 20 neurônios na primeira e segunda camada oculta, respectivamente, e dois neurônios na camada de saída. Foi avaliado o desempenho da rede MLP para diferentes condições de tráfego em que a intensidade de tráfego pode variar de 50 a 80%, ou seja, simulação do período de tempo que o canal encontra-se ocupado. O tempo entre chegadas t_{INTER} , definido pelo intervalo de tempo entre dois eventos consecutivos de T_{ON} , pode assumir valores de 10, 16, 18, 20 e 22 *slots*, sendo cada *slot* = 0,1 *ms*.

Resultados de simulação mostraram que, sob condições de tráfego estacionário, em que foram avaliados o desempenho da rede neural quanto a probabilidade de falsa detecção para cada um dos valores de t_{INTER} aplicado à diferentes intensidades de tráfego, que quanto maior a intensidade de tráfego, isto é, quando a utilização do canal tende a 80%, menor é a probabilidade de erro na detecção do estado ocupado, podendo chegar a erro na predição inferior a 4%. Foi possível observar que o caso crítico na predição espectral ocorre quando $t_{INTER} = 10$ *slots* e intensidade de tráfego de 50%, pois nesse caso o erro na probabilidade de detecção do estado ocupado do canal chega ao valor de 12,6%, sendo este o pior caso na avaliação de desempenho.

A avaliação de desempenho para cenário de tráfego não-estacionário, em que foi gerado um padrão de ocupação do canal variante no tempo, foi desenvolvido a partir da análise dos resultados da probabilidade de erro geral para os casos de treinamento único e treinamento sequencial. O intervalo de tempo $[t_0, t_6]$ foi subdividido igualmente em subintervalos menores com 6000 vetores de treinamento cada. Para o caso da implementação de único treinamento durante o intervalo de tempo $[t_0, t_1]$ e em seguida utilizar dos pesos sinápticos gerados desta etapa para avaliação e teste do comportamento da rede neural nos demais intervalos de tempo, observou-se que a probabilidade de erro geral é de 9,91%. Já para o caso em que há a realização de treinamento sequencial de 1000 amostras no início de cada subintervalo, além do treinamento inicial de 6000 vetores de treinamento no período $[t_0, t_6]$, mantendo a atualização dos pesos sinápticos a cada treinamento, foram obtidos nos resultados de simulação valor de probabilidade de erro geral de 9,76%. Pode-se então avaliar que para as condições de único treinamento e treinamento sequencial os valores da probabilidade de erro geral não apresentam diferenças significativas, inferior a 2%, devido principalmente a rápida descida do gradiente do erro no algoritmo de treinamento, podendo-se observar valor de 10^{-3} para o gradiente do erro em três épocas de treinamento.

Para cenários de tráfego estacionário distintos em oito canais de comunicação, em que é realizada a escolha aleatória dos canais a partir de dois critérios avaliativos, sendo: I_{sense} e $I_{predict}$. O primeiro avalia a quantidade de slots identificados como estado do canal desocupado, a partir da escolha aleatória de um entre todos os oito canais, e o segundo critério avalia o estado do canal apenas dentre aqueles em que a predição de ocupação foi estimada como desocupado. Resultados de simulação mostram que, o incremento na utilização do espectral pode chegar a

150% quando aplicadas técnicas de predição da ocupação do estado do canal.

Por fim, resultados de simulação mostraram que, quanto a energia necessária ao sensoriamento espectral, considerando a unidade de energia de sensoriamento igual à energia necessária para o sensoriamento espectral de um slot, esta pode ser reduzida em, pelo menos, 54%. Essa redução da energia de sensoriamento é possível dada as predições do estado de ocupação do canal, que na condição de ocupado, o sistema não realiza o sensoriamento do espectro, reduzindo, portanto, a energia de sensoriamento.

6.1 PROPOSTAS DE TRABALHOS FUTUROS

Neste trabalho, as simulações foram realizadas com o objetivo de avaliar o desempenho das redes neurais do tipo *perceptron* de múltiplas camadas quando alimentadas pelo tráfego de Poisson.

A implementação de simulações e avaliação de desempenho podem ser tratadas em trabalhos futuros a partir das análises quanto a utilização de técnicas de redes neurais tais como máquina de vetor de suporte [9] e aprendizado por reforço [34], utilização de modelos de tráfego do tipo Poisson interrompido e auto-similar [9], utilização de tráfego real de dados obtidos com equipamentos de laboratório [33], além da utilização de técnicas de redes neurais artificiais de aprendizado profundo [11]. É possível também realizar a avaliação de desempenho da predição da ocupação do canal em condições de presença de ruído e incerteza quanto ao processo de sensoriamento e assim, verificar o impacto no desempenho da rede neural.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ANATEL. Relatório anual: 2018. 2018. Disponível em <http://www.anatel.gov.br/institucional/noticias-destaque/2001-relatorio-anual-de-2017-esta-disponivel-no-portal-da-anatel>, acessado em 25 de junho de 2019 às 19:00.
- [2] QUALCOMM. Seminário de gestão do espectro – ANATEL. Acesso ao espectro radioelétrico por meio de compartilhamento, 2015.
- [3] HAYKIN, Simon. Cognitive radio: brain-empowered wireless communications. *IEEE journal on selected areas in communications*, v. 23, n. 2, p. 201-220, 2005.
- [4] CHAVES, Daniel Sant'Anna. Análise do sensoriamento espectral por detecção de energia. ENE/Universidade de Brasília, Brasília, 2012.
- [5] LEITE, João Paulo. Aplicação de técnicas de aprendizado por reforço à alocação de recursos e ao escalonamento de usuários em sistemas de telecomunicações, 2014.
- [6] TUMULURU, Vamsi Krishna; WANG, Ping; NIYATO, Dusit. A neural network based spectrum prediction scheme for cognitive radio. In: 2010 IEEE International Conference on Communications. IEEE, 2010. p. 1-5.
- [7] YIN, Liang, et al. Spectrum behavior learning in cognitive radio based on artificial neural network. In: 2011-MILCOM 2011 Military Communications Conference. IEEE, 2011. p. 25-30.
- [8] WINSTON, Ojenge; THOMAS, Afullo; OKELLODONGO, William. Comparing performance of MLP and RBF neural networks for TV idle channel prediction in Cognitive Radio. In: 2013 Pan African International Conference on Information Science, Computing and Telecommunications (PACT). IEEE, 2013. p. 122-126.
- [9] AGARWAL, Anirudh, et al. Learning based primary user activity prediction in cognitive radio networks for efficient dynamic spectrum access. In: 2016 International Conference on Signal Processing and Communications (SPCOM). IEEE, 2016. p. 1-5.
- [10] YU, Ling, et al. Spectrum prediction based on Taguchi method in deep learning with long short-term memory. *IEEE Access*, 2018, 6: 45923-45933.
- [11] AZMAT, Freeha; CHEN, Yunfei; STOCKS, Nigel. Analysis of spectrum occupancy using machine learning algorithms. *IEEE transactions on vehicular technology*, 2015, 65.9: 6853-6860.
- [12] ALMEIDA, Erika Portela Lopes de. Desenvolvimento de técnica de sensoriamento do espectro embasada em detecção de energia para aplicações em sistemas rádio-cognitivos. 2010.

- [13] TANG, Wuchen; IMRAN, Muhammad Ali; TAFAZOLLI, Rahim. Spectrum utilization efficiency analysis in cognitive radio networks. In: European Wireless 2013; 19th European Wireless Conference. VDE, 2013. p. 1-5.
- [14] J. MITOLA et al., "Cognitive radio: Making software radios more personal," *IEEE Pers. Commun.*, vol. 6, no. 4, pp. 13–18, Aug. 1999.
- [15] YÜCEK, H. A. T. A survey of spectrum sensing algorithms for cognitive radio applications. *IEEE In Communications Surveys Tutorials*, v. 11, n. 1, p. 116–130, 2009.
- [16] TANDRA, R.; MISHRA, S.; SAHAI, A. What is a spectrum hole and what does it take to recognize one? *Proceedings of the IEEE, Citeseer*, 2009.
- [17] LIANG, Y.-C. et al. Sensing-Throughput Tradeoff for Cognitive Radio Networks. *IEEE International Conference on Communications (ICC)*, vol., no., pp.5330-5335, 24-28 June 2007.
- [18] Z. QUAN, S. Cui, A. H. Sayed, and H. V. Poor, "Wideband Spectrum Sensing in Cognitive Radio Networks," in *Proc. of the IEEE International Conference on Communications (ICC)*, May 2008, pp. 19–23.
- [19] T. KIM and T. Adali, "Fully Complex backpropagation for constant envelope signal processing," in *Neural Networks for Signal Processing X. Proceedings of the 2000 IEEE Signal Processing Society Workshop (Cat. No.00TH8501)*, vol. 1, pp. 231–240 vol.1, Dec 2000.
- [20] HAYKIN, S., *Redes Neurais: Princípios e Práticas*. Bookman, Porto Alegre, RS, Brasil, 2008.
- [21] HAYKIN, Simon S., and Simon S. Haykin. *Neural Networks and Learning Machines*. New York: Prentice Hall/Pearson, 2009.
- [22] FLACH, P., *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*. Cambridge University Press, Nova Iorque, E.U.A, 2012.
- [23] ALPAYDIN, E., *Introduction to Machine Learning*. The MIT Press, Cambridge, Massachussets, E.U.A, 2014.
- [24] ALEKSANDER, Igor. *Neural systems engineering: towards a unified design discipline?*. Imperial College of Science. Technology and Medicine.
- [25] M.T. HAGAN, H.B. Demuth, M. Beale, *Neural Network Design*, PWS Publishing Company, Boston, 1995.
- [26] DEMUTH, Howard B., and Mark H. Beale. *Neural Network Toolbox for Use with MATLAB: User's Guide*. Natick, Mass: MathWorks, 2010.
- [27] J. A. GUBNER, *Probability and Random Processes for Electrical and Computer Engineers*. New York: Cambridge Univ. Press, 2006.

- [28] B. Chandrasekaran, "Survey of network traffic models," IEEE Commun. Mag., Mar. 1994.
- [29] BARRETO, P. A. S. Uma Metodologia de Engenharia de Tráfego Baseada na Abordagem Auto-Similar para a caracterização de parâmetros e a otimização de redes multimídia. Universidade de Brasília -UNB, 2007.
- [30] LIJI, P.I.; Dipin, A. Real time data traffic analysis using poisson process in next generation network. // Control, Instrumentation, Communication and Computational Technologies (ICCICCT), 2014 International Conference on , vol., no., 10-11 July 2014 - pp.289-293
- [31] A. LEON-GARCIA, Probability, Statistics, and Random Processes for Electrical Engineering. Pearson/Prentice Hall, 2008.
- [32] RADEV, D. (2005). Stochastic process generation for traffic flow simulation. Proc. of the IEEE Conference on Telecommunications in Modern Satellite, Cable and Broadcasting Services TELSIKS'2005, vol. 2, Nis, Serbia, 559-562.
- [33] RAMIREZ, David A. Arista, et al. Spectrum Occupancy Measurements in the Sub-6 GHz Band for Smart Spectrum Applications. In: 2018 IEEE 10th Latin-American Conference on Communications (LATINCOM). IEEE, 2018. p. 1-6.
- [34] RUPASINGHE, Nadisanka; GÜVENÇ, İsmail. Reinforcement learning for licensed-assisted access of LTE in the unlicensed spectrum. In: 2015 IEEE Wireless Communications and Networking Conference (WCNC). IEEE, 2015. p. 1279-1284.