



## PREDIÇÃO DE CRISES EPILÉPTICAS UTILIZANDO REDE NEURAL SEM PESO WISARD

Kleber de Aguiar

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia de Sistemas e Computação, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia de Sistemas e Computação.

Orientadores: Felipe Maia Galvão França  
Valmir Carneiro Barbosa

Rio de Janeiro  
Maio de 2014

PREDIÇÃO DE CRISES EPILÉPTICAS UTILIZANDO REDE NEURAL SEM  
PESO WISARD

Kleber de Aguiar

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO  
ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE  
ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE  
JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A  
OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA DE  
SISTEMAS E COMPUTAÇÃO.

Examinada por:

---

Prof. Felipe Maia Galvão França, Ph.D.

---

Prof. Valmir Carneiro Barbosa, Ph.D.

---

Prof. Priscila Machado Vieira Lima, Ph.D.

---

Prof. José Antonio dos Santos Borges, D.Sc.

RIO DE JANEIRO, RJ – BRASIL  
MAIO DE 2014

Aguiar, Kleber de

Predição de Crises Epilépticas Utilizando Rede Neural Sem Peso WiSARD/Kleber de Aguiar. – Rio de Janeiro: UFRJ/COPPE, 2014.

XIII, 60 p.: il.; 29, 7cm.

Orientadores: Felipe Maia Galvão França

Valmir Carneiro Barbosa

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia de Sistemas e Computação, 2014.

Referências Bibliográficas: p. 59 – 60.

1. Predição de Crises Epilépticas. 2. Rede Neural Sem Peso. 3. WiSARD. I. França, Felipe Maia Galvão *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Sistemas e Computação. III. Título.

*“Filho, se prestares atenção  
aprenderás; se aplicares teu  
espírito, serás prudente. Se  
gostares de ouvir, receberás a  
instrução; se inclinares teu  
ouvido serás sábio.”  
(Eclesiástico 6, 33-34)*

*Ao meu irmão Paulo, por ter  
sido a minha inspiração nessa  
dissertação.*

# Agradecimentos

Dou graças ao Senhor Deus por Ele ter me ungido com o Espírito Santo! Sua misericórdia infinita me livrou dos perigos do Rio, através de São Miguel Arcanjo e de toda a Milícia Celeste.

À Nossa Senhora, Maria Santíssima, por ter me dado colo de mãe nas noites solitárias que passei nessa cidade e por ter me conduzido aos braços de Jesus Cristo, quando eu mais precisei Dele durante esse Mestrado.

À minha mãe Elisa, pelo apoio financeiro e emocional, e por sempre ter acreditado na minha capacidade. Sei que esse sonho não era só meu.

Ao meu pai Nicanor, por ter provido todos os computadores que tive nessa minha vida acadêmica e, à sua maneira muito singular, ter torcido por mim.

Ao meus irmãos, Queila e Paulo, pelo amor fraterno. Queila, conte sempre comigo. Paulo, sua luta frente à epilepsia é exemplo de perseverança para mim.

À minha amada Paula Domingues, pela paciência e compreensão nos momentos em que o estresse me dominou nesses anos de Mestrado. Contigo estou em paz.

À minha “filha de coração” Luiza Domingues, fonte infinita de carinho, dona de um abraço com poderes curativos capaz de curar as feridas da alma.

Aos meus familiares, por terem torcido pelo meu sucesso. Tia Maria Elisa, obrigado por se importar. Primo-irmão Juliano, obrigado pelo apoio incondicional.

Aos meus Irmãos de Caminhada, pelas orações. Especialmente à Amanda Teles Facco e Marcelle Ramos Roça Novo, por serem bênçãos do Céu em minha vida.

Aos meus orientadores, professores Valmir e Felipe, pelo apoio, paciência, ensinamentos e por terem aberto as portas da Pesquisa Científica para mim! Não há palavras para expressar a minha gratidão.

Aos colegas do Laboratório de Inteligência Artificial do PESC: Daniel Alves, Daniel Nunes, Danilo Carvalho, Douglas Cardoso, Fábio Vieira, Hugo Cesar Carneiro, João Antônio Amarante e Paulo Felipe Brandt, pela amizade acadêmica. Douglas, obrigado por ter me doado parte significativa do seu tempo.

Ao Rodrigo Rodovalho, pela prestimosa ajuda na execução dos meus experimentos no ambiente do Grid-IA.

Ao CNPQ, pelo fomento à essa pesquisa e à COPPE\UFRJ, pela dádiva de ter sido aluno de tão respeitável instituição de ensino.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

## PREDIÇÃO DE CRISES EPILÉPTICAS UTILIZANDO REDE NEURAL SEM PESO WISARD

Kleber de Aguiar

Maio/2014

Orientadores: Felipe Maia Galvão França  
Valmir Carneiro Barbosa

Programa: Engenharia de Sistemas e Computação

De acordo com a Organização Mundial de Saúde (OMS) , a epilepsia é uma das doenças primárias do sistema nervoso central mais comuns no mundo. A Epilepsia afeta gravamente a rotina de uma pessoa acometida por ela, visto que causa restrições às atividades diárias desenvolvidas por esta, impactando sua vida de maneira negativa. Tal fato agrava-se pelo caráter repentino que caracteriza a ocorrência de um evento epiléptico.

A possibilidade de se prever um episódio de crise epiléptica aparece como um elemento atenuante para os efeitos desagradáveis decorrentes deste acontecimento. Tal fato se daria pela eliminação da característica súbita destes eventos, dando aqueles que são portadores dessa desordem, uma chance para tomar decisões e atitudes que venham resguardar sua integridade física. Ou pelo menos, que estas pessoas tenham a possibilidade de minimizar os danos que uma crise pode acarretar.

Nesse contexto, a presente dissertação apresenta um método capaz de prever a iminência de uma crise epiléptica com um certo período de antecedência, baseado na avaliação da atividade neuronal do paciente, acrescida de registros de seus batimentos cardíacos, movimentos oculares e musculares. Para atingir este fim, além de um devido tratamento dos dados, uma rede neural do tipo sem peso foi implementada para análise e classificação dos padrões formados por estes dados, tornando possível a predição de uma crise propriamente dita. O modelo de rede neural sem peso presente na metodologia de predição desta dissertação é o modelo WiSARD. Nos experimentos realizados com redes WiSARD personalizadas para cada paciente, os altos percentuais de acerto alcançados na predição de crises epilépticas sugerem seu uso em aplicações assistivas.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

## PREDICTION OF EPILEPTIC SEIZURES USING WEIGHTLESS NEURAL NETWORK WISARD

Kleber de Aguiar

May/2014

Advisors: Felipe Maia Galvão França  
Valmir Carneiro Barbosa

Department: Systems Engineering and Computer Science

According to World Health Organization (WHO), epilepsy is one of the most common primary diseases of the central nervous system worldwide, affecting in a hard way, the routine of a person affected by it. This is because epilepsy causes restrictions to daily activities carried out by those who suffer from this disturb, impacting their lives negatively. This fact is aggravated by the sudden factor that characterizes the occurrence of an epileptic event.

The ability to predict an episode of seizure appears as a mitigating factor to the unpleasant effects arising from this event. And would eliminate the abrupt feature of it, giving those who are carriers of this disorder, a chance to make decisions and attitudes that will hopefully safeguard their physical integrity. Or at least, provide to the those people with epilepsy, a chance to minimize the harms that a seizure can bring about.

In this context, this master's thesis presents a method to predict the imminence of an epileptic seizure with a period of antecedence, which is based on the evaluation of the neuronal activity of the patient, plus records about his heart rate and his movements from eyes and muscles. To achieve this purpose, including a proper treatment of the patients data, a weightless neural network has been implemented, in order to analyse these data and perform classification of patterns formed by data previously mentioned, making possible the prediction of a future crisis. The weightless neural network present in the prediction methodology of this dissertation is the WiSARD model. In the experiments performed with WiSARD networks customized for each patient, the high percentages of success achieved in the prediction of epileptic seizures suggest its use in assistive applications.

# Sumário

<b>Lista de Figuras</b>	<b>xi</b>
<b>Lista de Tabelas</b>	<b>xii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Motivação . . . . .	1
1.2 Trabalhos Correlatos . . . . .	2
1.2.1 Detecção de Crises Epilépticas a partir de Sinais Eletroencefalográficos . . . . .	2
1.2.2 Detecção e Caracterização de Crises Epilépticas Através de Estimulação Elétrica . . . . .	3
1.3 Estrutura da Dissertação . . . . .	4
<b>2 Epilepsia</b>	<b>5</b>
2.1 Conceito . . . . .	5
2.2 Classificação das Crises Epilépticas . . . . .	6
2.2.1 Crises Parciais (ou Focais) . . . . .	6
2.2.2 Crises Generalizadas (desde o início) . . . . .	6
2.2.3 Crises Não-Classificáveis . . . . .	7
2.3 Etiologia . . . . .	7
2.4 Eletroencefalograma . . . . .	8
2.5 Banco de Dados EPILEPSIAE . . . . .	8
2.5.1 Coleta dos dados . . . . .	9
2.5.2 Arquivos Binários . . . . .	9
<b>3 Redes Neurais e o Modelo WiSARD</b>	<b>10</b>
3.1 Redes Neurais Com Peso . . . . .	10
3.2 Wisard - Um Modelo de Rede Neural Sem Peso . . . . .	11
3.2.1 Arquitetura da WiSARD . . . . .	11
3.2.2 Fase de Treinamento . . . . .	15
3.2.3 Fase de Teste . . . . .	16
3.2.4 Bleaching . . . . .	18



3.3	Utilização da WiSARD em Outras Aplicações . . . . .	20
3.3.1	Classificação Gramatical com Índice de Síntese . . . . .	20
3.3.2	Agrupamento de Dados em Fluxo Contínuo . . . . .	21
3.3.3	Categorização de Subtipos do HIV-I . . . . .	21
<b>4</b>	<b>Método Utilizado para Predição de Crises Epilépticas</b>	<b>23</b>
4.1	Metodologia . . . . .	23
4.1.1	Pré-Processamento dos Dados . . . . .	24
4.1.1.1	Conversão dos Arquivos de Dados Binários Originais em Arquivos Textos . . . . .	24
4.1.1.2	Conversão dos Dados dos Arquivos Textos de Deci- mal para Inteiros Representando Valores Binários . . . . .	24
4.1.1.3	Criação dos Arquivos de <i>Input</i> com as Entradas a serem submetidas à WiSARD . . . . .	28
4.1.2	A WiSARD como Preditor de Crises Epilépticas . . . . .	28
4.1.2.1	Agrupamento das Entradas dos Arquivos Textos de Dados em <i>Folds</i> . . . . .	29
4.1.2.2	Mapeamento dos Valores dos Arquivos Textos de Da- dos em Números Binários . . . . .	29
4.1.2.3	Predição de Crises Através da Classificação das En- tradas . . . . .	30
4.2	Considerações Gerais . . . . .	31
<b>5</b>	<b>Base Experimental, Resultados e Análise</b>	<b>33</b>
5.1	Base Experimental . . . . .	33
5.1.1	Características dos Sub-Conjuntos de Dados . . . . .	33
5.1.1.1	Paciente N° 100102 . . . . .	34
5.1.1.2	Paciente N° 11000102 . . . . .	34
5.1.1.3	Paciente N° 7300102 . . . . .	35
5.1.1.4	Paciente N° 8900102 . . . . .	35
5.1.2	Balanceamento das Entradas por Classe . . . . .	36
5.2	Resultados . . . . .	38
5.2.1	Resultados Globais . . . . .	39
5.2.2	Resultados da Classe de Maior Interesse: <i>NonIctal-Ictal</i> . . . . .	43
5.3	Análise dos Resultados . . . . .	48
5.3.1	Relação dos Resultados com o Parâmetro Janela de Tempo de Observação . . . . .	48
5.3.2	Relação dos Resultados com o Parâmetro Intervalo de Predição	49
5.3.3	Avaliação dos Resultados dos Experimentos . . . . .	49

<b>6</b>	<b>Conclusões</b>	<b>55</b>
6.1	Resumo . . . . .	55
6.2	Discussão . . . . .	56
6.3	Trabalhos Futuros . . . . .	57
	<b>Referências Bibliográficas</b>	<b>59</b>

# Lista de Figuras

3.1	Rede Neural com Peso - Arquitetura Multi-Camadas . . . . .	11
3.2	Discriminador e Arquitetura da WiSARD . . . . .	13
3.3	Endereçamento de Grupos de Bits em um Neurônio (Nó-RAM) Wi- SARD [1] . . . . .	14
3.4	Visão dos Neurônios (Nós-RAM) na Fase de Treinamento [1] . . . . .	16
3.5	Medida de Similaridade de um Discriminador Após Teste . . . . .	17
3.6	Cálculo do Grau de Confiança de uma Resposta da Rede . . . . .	18
3.7	Classificação de uma Entrada com Cálculo da Confiança . . . . .	18
3.8	Técnica de <i>bleaching</i> com $B = 1$ [1] . . . . .	19
3.9	Técnica de <i>bleaching</i> com $B = 2$ [1] . . . . .	20
4.1	Fórmula da Conversão de Inteiro para Binário . . . . .	25
4.2	Exemplo de Conversão de Inteiro para Binário . . . . .	26
5.1	Intervalo de Coletas de Entradas . . . . .	37
5.2	Situações Transitórias e Não-Transitórias no Intervalo de Coleta . . . . .	38
5.3	Resultados - Paciente N° 100102 - <i>Input</i> =2 Segundos . . . . .	50
5.4	Resultados- Paciente N° 100102 - <i>Input</i> =3 Segundos . . . . .	51
5.5	Resultados - Paciente N° 11000102 - <i>Input</i> =2 Segundos . . . . .	51
5.6	Resultados - Paciente N° 11000102 - <i>Input</i> =3 Segundos . . . . .	52
5.7	Resultados - Paciente N° 7300102 - <i>Input</i> =2 Segundos . . . . .	52
5.8	Resultados - Paciente N° 7300102 - <i>Input</i> =3 Segundos . . . . .	53
5.9	Resultados - Paciente N° 8900102 - <i>Input</i> =2 Segundos . . . . .	53
5.10	Resultados - Paciente N° 8900102 - <i>Input</i> =3 Segundos . . . . .	54

# Lista de Tabelas

4.1	Classes do Problema de Predição de Crises Epilépticas . . . . .	31
5.1	Avaliação Cognitiva do Paciente N° 100102 . . . . .	34
5.2	Avaliação Cognitiva do Paciente N° 11000102 . . . . .	35
5.3	Avaliação Cognitiva do Paciente N° 7300102 . . . . .	36
5.4	Avaliação Cognitiva do Paciente N° 8900102 . . . . .	36
5.5	Resultados do Paciente N° 100102 - Todas as Classes - <i>Input</i> = 2 Segundos . . . . .	39
5.6	Resultados do Paciente N° 100102 - Todas as Classes - <i>Input</i> = 3 Segundos . . . . .	40
5.7	Resultados do Paciente N° 11000102 - Todas as Classes - <i>Input</i> = 2 Segundos . . . . .	40
5.8	Resultados do Paciente N° 11000102 - Todas as Classes - <i>Input</i> = 3 Segundos . . . . .	41
5.9	Resultados do Paciente N° 7300102 -Todas as Classes - <i>Input</i> = 2 Segundos . . . . .	41
5.10	Resultados do Paciente N° 7300102 -Todas as Classes - <i>Input</i> = 3 Segundos . . . . .	42
5.11	Resultados do Paciente N° 8900102 - Todas as Classes - <i>Input</i> = 2 Segundos . . . . .	42
5.12	Resultados do Paciente N° 8900102 - Todas as Classes - <i>Input</i> = 3 Segundos . . . . .	43
5.13	Resultados do Paciente N° 100102 - Classe <i>nonIctal-ictal</i> - <i>Input</i> = 2 Segundos . . . . .	44
5.14	Resultados do Paciente N° 100102 - Classe <i>nonIctal-ictal</i> - <i>Input</i> = 3 Segundos . . . . .	44
5.15	Resultados do Paciente N° 11000102 - Classe <i>nonIctal-ictal</i> - <i>Input</i> = 2 Segundos . . . . .	45
5.16	Resultados do Paciente N° 11000102 - Classe <i>nonIctal-ictal</i> - <i>Input</i> = 3 Segundos . . . . .	45

5.17 Resultados do Paciente N° 7300102 - Classe <i>nonIctal-ictal</i> - <i>Input=</i> 2 Segundos . . . . .	46
5.18 Resultados do Paciente N° 7300102 - Classe <i>nonIctal-ictal</i> - <i>Input=</i> 3 Segundos . . . . .	46
5.19 Resultados do Paciente N° 8900102 - Classe <i>nonIctal-ictal</i> - <i>Input=</i> 2 Segundos . . . . .	47
5.20 Resultados do Paciente N° 8900102 - Classe <i>nonIctal-ictal</i> - <i>Input=</i> 3 Segundos . . . . .	47

# Capítulo 1

## Introdução

De acordo com a OMS<sup>1</sup>, a epilepsia corresponde a 1% da carga global de doenças (*global burden of disease*) [2], podendo ser definida como um conjunto de distúrbios neurológicos de natureza crônica que pode ocorrer em qualquer idade [3]. Um fator socioeconômico relevante acerca desse mal é a maneira como ele influencia de forma grave a qualidade de vida dos indivíduos que são acometidos por ele, pois estes ficam privados de atividades corriqueiras, como por exemplo a direção de veículos automotores. A predição de crises epiléticas surge como uma opção para minimizar os possíveis danos aos portadores desse mal, avisando-os com antecedência da eminência de uma crise, possibilitando a estes tomar as medidas precatórias necessárias para sua segurança.

### 1.1 Motivação

Dado o caráter súbito e imprevisível da ocorrência de crises e surtos epiléticos, uma tentativa para minimizar esse fato seria diagnosticar atividades elétricas cerebrais que sinalizassem para a ocorrência eminente de uma crise epilética. Dessa forma, poderia-se melhorar a qualidade de vida dos indivíduos que sofrem desse distúrbio, com a implementação de algum mecanismo preditor desenvolvido para esse fim. A predição de crises epiléticas é um tema de pesquisa recorrente na comunidade científica, sendo que várias tentativas nesse sentido já foram feitas, utilizando diversos recursos, inclusive técnicas de Inteligência Artificial.

O objetivo da presente dissertação é apresentar um método computacional capaz de prever com uma boa acurácia, a ocorrência de crises epiléticas com um certo intervalo de tempo. Basicamente, o método objeto deste trabalho se divide em duas partes: o tratamento adequado dos dados oriundos de registros eletroencefalográficos, acrescidos de leituras de batimentos cardíacos, movimentos oculares e

---

<sup>1</sup>Organização Mundial de Saúde

contrações musculares, para posterior uso destes como entradas em uma rede neural artificial; e o uso de uma arquitetura de rede sem peso baseada no modelo WiSARD [4] para a predição das crises propriamente ditas. Quatro conjuntos de dados (registros de quatro pacientes distintos) provenientes do Banco de Dados EPILEPSIAE [5], um esforço conjunto de centros de pesquisa de Portugal (Coimbra), França (Paris) e Alemanha (Freiburg), obtidos de forma gratuita, formam a base de dados utilizada neste trabalho.

## 1.2 Trabalhos Correlatos

Nesta Seção abordaremos dois trabalhos que tem como tema a predição de crises epiléticas, utilizando recursos da Inteligência Artificial, assunto desta dissertação.

### 1.2.1 Detecção de Crises Epiléticas a partir de Sinais Electroencefalográficos

O trabalho citado nesta subseção visou melhorar a identificação dos sinais de crises epiléticas, a partir da construção de alguns sistemas baseados no uso de técnicas de processamento de sinais e de inteligência artificial. O problema enfrentado foi a característica dos registros electroencefalográficos (EEG) não invasivos em apresentar distúrbios que dificultam a sua análise. Enquanto que a motivação do trabalho foi a grande importância que uma correta avaliação clínica, baseada no exame electroencefalográfico (EEG), tem no diagnóstico e na concepção do tratamento adequado da epilepsia sofrida por um paciente.

O sistema de análise multi-resolução apresentado no trabalho objeto desta Subseção, de certa forma se correlaciona com a proposta de metodologia para predição de crises epiléticas desta dissertação de Mestrado, pelo uso de sinais electroencefalográficos como fonte de dados. A arquitetura deste sistema utiliza duas famílias wavelet (WT) para a extração de características, redes neurais artificiais e sistema especialista para o reconhecimento dos sinais de crise. Esse sistema teve sua constituição embasada na transformada wavelet discreta (DWT) integrada com o modelo de rede neural com peso PNN, um modelo probabilístico de rede neural.

O sistema de análise de multi-resolução funciona da seguinte forma: o sinal é decomposto, através de uma técnica de decomposição utilizando diversos níveis da DWT e o Teorema de Parseval para a extração das características da distribuição da energia do sinal em diferentes níveis (13 níveis), e a medida de duração do distúrbio. Essas características então são submetidas à PNN para que esta possa classificar o tipo de distúrbio ocorrido como crise epilética, não-crise e artefato (outros tipos de distúrbios neurais de origem não-epilética).

Os resultados obtidos com o uso dessa arquitetura apresentaram uma taxa de acerto em torno de 80% no reconhecimento dos sinais patológicos associados à crises epilépticas, onde o conjunto de testes contou com 20 entradas (chamadas de segmentos no trabalho em questão) e o de treinamento com 35. Em um segundo cenário, com 20 entradas destinadas aos testes e 70 entradas destinadas à fase de treinamento da rede, o resultado foi de 90% de acerto. Diante desses números, o autor do trabalho referenciado nesta subseção afirmou que o sistema de análise multi-resolução apresentou resultados coerentes com os fenômenos demarcados pelos especialistas em eletroencefalografia [6].

### **1.2.2 Detecção e Caracterização de Crises Epilépticas Através de Estimulação Elétrica**

Nesta Subseção, o trabalho abordado apresenta preliminarmente estudos sobre o processamento dos dados proveniente de exames eletroencefalográficos (EEG) de ratos submetidos a um protocolo de crise epiléptica induzida, através da droga Pentilenotetrazol (PTZ), concomitantemente à estimulação elétrica. O segundo passo foi a validação dos grupos de controle utilizados, ou seja, confirmar que a estimulação elétrica não altera a evolução e o tipo de crise epiléptica apresentada (grupo de animais submetidos ao PTZ), nem provoca uma crise por si só (grupo de animais tratados com outra droga, o EE). Os animais utilizados eram saudáveis e não-epilépticos, suas crises foram induzidas pela ministração de PTZ; trata-se de uma das práticas mais comuns para estimular crises, visando testes de drogas convulsivantes em ratos. De acordo com a dosagem ministrada de PTZ (doses que variam de 40 a 120mg/kg), crises diferentes (mínimas e máximas) são obtidas.

As crises mínimas são induzidas por doses de até 40mg/kg, e suas manifestações, como espasmos, automatismos faciais, mastigação e clonias (movimentos pulsados) de cabeça e membros anteriores, são sutis e estruturas prosencefálicas, como o sistema límbico, são envolvidas na expressão motora dessas crises ditas mínimas, sendo este o motivo do PTZ em doses baixas ser tido como modelo induzido de epilepsia de lobo temporal. Já as crises máximas são obtidas pela ministração de doses maiores que 60mg/kg e suas manifestações são de forma motora em convulsões tônico-clônicas generalizadas (a Seção 2.2 trata da classificação das crises epilépticas), que por sua vez são precedidas por crises mínimas. Tais crises máximas envolvem estruturas do prosencéfalo e do tronco encefálico de maneira simultânea. O modelo de crises obtidas no trabalho de que trata esta Subseção é, portanto, generalizada (mínimas e máximas, de acordo com a dosagem do PTZ), o que caracteriza o PTZ como um modelo geral indutor de crises.

Após a validação desses grupos de controle, os resultados obtidos sinalizaram a



ocorrência de forte sincronização dos disparos interictais (descargas elétricas neurais em momento de ausência de crise epiléptica) com a estimulação elétrica momentos antes da crise, funcionando como um sinalizador inequívoco da iminência de uma crise. Outro dado interessante obtido foi a visualização da organização gradativa da rede cerebral até o momento da crise, através da caracterização da evolução dos diversos circuitos neurais ao longo do registro eletroencefalográfico. Apesar da não comprovação de sua eficiência, segundo o autor pelas limitações do estudo feito, o método apresentado mostrou-se potencialmente capaz de integrar um sistema para previsão e até mesmo supressão de crises epilépticas.

A correlação do trabalho citado nesta Subseção com o trabalho desta dissertação de Mestrado, fica a cargo do uso e investigação dos registros de eletroencefalografia para a tentativa de se caracterizar um momento de pré-crise que venha a ser um indicador da ocorrência futura de uma crise epiléptica, em um certo intervalo de tempo. Como nota vale salientar que embora os registros tenham sido obtidos junto a ratos e não a seres humanos, a metodologia do uso de dados provindos do EEG, como base de dados do trabalho referenciado nesta Subseção se assemelha com a metodologia utilizada nesta dissertação de Mestrado, no que se refere à forma de coleta de dados. [7]

### 1.3 Estrutura da Dissertação

No tocante à sua organização, esta dissertação está estruturada da seguinte forma: o Capítulo 2 destina-se a uma melhor compreensão da epilepsia, assim como a sua etiologia [8], a exposição dos tipos de crises epilépticas, de acordo com a classificação adotada pela *International League Against Epilepsy* (ILAE) [9], a importância do eletroencefalograma (EEG) em relação ao diagnóstico de epilepsia, e discorre sobre o banco de dados EPILEPSIAE (fonte da base de dados utilizada nos experimentos realizados) [5]; o Capítulo 3 introduz as redes neurais artificiais, com ênfase nas redes neurais do tipo sem peso e no seu modelo original, a WiSARD [4]; o Capítulo 4 dedica-se a explicação do método preditor desenvolvido para lidar com o problema de detecção de crises epilépticas; os experimentos realizados e a análise de seus resultados se encontra no Capítulo 5; no Capítulo 6 encontra-se o resumo do trabalho realizado, uma breve discussão sobre pontos específicos a serem melhorados e os trabalhos a serem desenvolvidos futuramente como forma de extensão e aperfeiçoamento da metodologia de predição de crises aqui exposta; por fim, são citadas as referências que serviram de base bibliográfica para esta dissertação de Mestrado.

# Capítulo 2

## Epilepsia

Nesta Seção será abordado alguns dos princípios básicos da epilepsia, tais como o conceito acerca deste tema, uma breve explanação sobre os tipos de crises epiléticas, sua etiologia e a importância do exame de encefalografia no diagnóstico e identificação dos tipos de crises. Além desses tópicos, será apresentado o banco de dados EPILEPSIAE [5], base de dados dos experimentos desta dissertação.

### 2.1 Conceito

Epilepsia é um transtorno crônico caracterizado por episódios recorrentes de disfunção cerebral paroxística (aparecem e desaparecem subitamente) , devido à repentina descarga neuronal excessiva e desordenada, usualmente associada com alteração do estado de consciência [10]. Tais descargas se originam de correntes elétricas que são fruto da movimentação iônica através da membrana celular [8]. Dado que a comunicação entre os neurônios se dá por meio de impulsos ou sinais elétricos, quando esses sinais são transmitidos de maneira irregular durante um episódio de crise epilética, surgem então os sintomas da epilepsia.

Somente há a caracterização da existência da epilepsia, quando o paciente desenvolve mais de um episódio de crise epilética, sendo que essas crises não podem estar associadas a fatores externos, tais como drogas, medicamentos, traumas e febres. As manifestações clínicas da crise epilética podem variar de alterações complexas do comportamento à alterações discretas e momentâneas do nível de consciência, e sua duração possui natureza variável. Distúrbios episódicos ou paroxísticos podem simular crises epiléticas e além disso, há de se considerar também a possibilidade da ocorrência de outras condições não-epiléticas, como enxaqueca, distúrbios do sono, hiperventilação, síncope, entre outros. Portanto, para a definição do diagnóstico de epilepsia, é necessário primeiramente identificar se os episódios de crise são realmente epiléticos [8].

Em síntese, apesar do conceito aqui exposto, não há uma definição satisfatória

de epilepsia. Epilepsia não é, naturalmente, uma doença específica ou uma única síndrome. Sob a denominação epilepsia, compreende-se uma ampla categoria de sintomas complexos, decorrentes de funções cerebrais alteradas que podem ser secundárias a um grande número de processos patológicos.

## 2.2 Classificação das Crises Epilépticas

A Classificação das Crises Epilépticas de 1981 é ainda a classificação oficialmente aceita pela *International League Against Epilepsy* (ILAE) [9]. De acordo com essa classificação, a crise epiléptica está relacionada de maneira geral, à localização das alterações nas descargas neuronais. Estas podem compreender um dos hemisférios cerebrais, ou podem ser difusas, quando ambos hemisférios são atingidos.

Assim, de acordo com a classificação de 1981, temos os seguintes tipos de crise epiléptica:

- Crises Parciais (ou Focais)
- Crises Generalizadas (desde o início)
- Crises Não-Classificáveis

### 2.2.1 Crises Parciais (ou Focais)

São definidas dessa forma, as crises nas quais, em geral, as manifestações clínicas e eletroencefalográficas indicam que a descarga neuronal limitou-se apenas à uma região de um hemisfério cerebral. Crises parciais podem ser subdividas em três tipos: simples, complexa e secundariamente generalizada [8].

O que distingue uma crise parcial simples da crise parcial complexa é que no caso desta última, há o comprometimento da consciência do indivíduo sofrendor da crise. Nesse ínterim, consciência é compreendida como a capacidade de percepção consciente e interação com o ambiente de maneira adequada. Durante uma crise parcial complexa, é comum o indivíduo conseguir manter a capacidade de perceber e interagir, porém a forma como essa interação e percepção ocorrem é inadequada [8]. Ambas as crises parciais, simples e complexas, podem evoluir para uma crise generalizada, caracterizando-se assim como uma crise parcial secundariamente generalizada.

### 2.2.2 Crises Generalizadas (desde o início)

Configuram-se assim, as crises nas quais as descargas neuronais alteradas atingem, desde o seu início, ambos os hemisférios cerebrais. Outro detalhe, é que nessa

ocorrência epiléptica há o comprometimento da consciência do indivíduo, o que provavelmente pode ser a manifestação inicial desse tipo de crise. Crises Generalizadas (desde o início) são também caracterizadas em outros subtipos: tônico-clônicas, mio-clônicas, tônicas, clônicas e atônicas (que possuem características similares); de ausência típica e ausência atípica, que também possuem semelhanças em comum.

Nas crises tônico-clônicas, usualmente ocorre a perda da consciência com queda ao solo, endurecimento do corpo (crises tônicas) e abalos musculares generalizados (crises clônicas). Enquanto que no caso de crises atônicas, há uma súbita perda do tônus muscular que pode levar à queda do paciente, caso essa perda de tonicidade não fique restrita a apenas alguns músculos específicos. Já as crises mioclônicas tem breve duração e manifestam-se principalmente ao despertar, com movimentos bruscos de todo o corpo, similares ao recebimento de um choque ou susto, principalmente dos braços [11].

Em relação às crises de ausência típica, ocorrem breves episódios de comprometimento de consciência acompanhados por manifestações motoras muito discretas. Essas manifestações motoras se apresentam como automatismos orais e manuais, piscamento, aumento ou diminuição do tônus muscular e sinais autonômicos. O que difere as crises de ausência típica, das de ausência atípica, é que nestas últimas o comprometimento da consciência é menor, o início e término são menos abruptos e o tônus muscular mostra-se frequentemente alterado [11].

Vale enfatizar que os comportamentos acima descritos devem ocorrer desde o início da descarga neuronal alterada, para que então possa ser estabelecida a diferenciação dessa crise, de uma crise parcial secundariamente generalizada.

### **2.2.3 Crises Não-Classificáveis**

Incluem-se aqui, todas as crises que não puderam ser classificadas em um dos tipos anteriormente descritos, devido à informações incompletas ou inadequadas.

## **2.3 Etiologia**

Crises epiléticas são sintomas de uma função anormal do cérebro, cuja definição do que a causa é uma questão central no que concerne ao tratamento médico dos indivíduos que sofrem desse mal. Existem três fatores causais das crises, a saber: predisposição individual, presença de lesão epileptogênica cerebral, que pode ser local ou generalizada, e alterações cerebrais bioquímicas ou elétricas [8]. Ainda em relação aos agentes causadores das crises epiléticas, podemos citar fatores genéticos e perinatais, distúrbios do desenvolvimento, doenças infecciosas, fatores tóxicos, traumas, distúrbios vasculares, distúrbios metabólicos, distúrbios nutricionais e doenças de-

generativas e hereditárias.

Além do exposto acima, cite-se também que a grande maioria das doenças que atingem a substância cinzenta do cérebro, algumas patologias da substância cerebral branca (por exemplo, doenças metabólicas) e inúmeras doenças sistêmicas podem também causar crises epiléticas [8].

## 2.4 Eletroencefalograma

O eletroencefalograma (EEG) é um dos mais relevantes procedimentos laboratoriais em relação à epilepsia, senão o mais importante nesse sentido, dado que as informações contidas nele são de extrema importância no tocante ao estabelecimento do diagnóstico desse transtorno e contribuem de maneira significativa para a diferenciação entre crises epiléticas parciais e generalizadas, e podem revelar ainda, padrões característicos que indicam a existência de determinada síndrome epilética [8]. Notadamente, há de se frisar que importantes avanços na epileptologia foram alcançados graças ao uso de uma técnica avançada de EEG, a vídeo-encefalografia (vídeo-EGG); mais precisamente, pela difusão dos estudos obtidos com esse tipo de procedimento. O vídeo-EGG permite um melhor diagnóstico dos tipos de crises epiléticas, assim como das síndromes, além de ser bastante útil no processo de quantificação do número de crises e da localização da área epileptogênica.

No entanto, vale ressaltar que a interpretação incorreta dos traçados eletroencefalográficos é a maior causadora de um diagnóstico errôneo de epilepsia. Porém, nem o caráter interpretativo de seus resultados diminui o valor que o EEG tem no tratamento e diagnóstico de epilepsia. Isto posto, frise-se que apenas especialistas não cometeriam o equívoco de confundir as variantes normais de padrões cerebrais com alterações epileptiformes.

## 2.5 Banco de Dados EPILEPSIAE

Em termos de base de dados da presente dissertação, foi utilizado o banco de dados EPILEPSIAE [5]. Esse banco de dados faz parte de um projeto de pesquisa homônimo sobre epilepsia financiado pela União Européia. O objetivo deste projeto EPILEPSIAE é o desenvolvimento de algoritmos de predição de crises epiléticas visando identificar padrões precursores de crises, através do monitoramento do eletroencefalograma.

O gerenciamento e disponibilização à comunidade científica de um banco de dados contendo, entre outros dados, eletroencefalogramas de longa duração (*long-term EEG*), foi fruto de um esforço coletivo de centros de epilepsia em Coimbra (Portugal), Paris (França) e Freiburg (Alemanha). Além dos dados provenientes dos eletro-

encefalogramas dos pacientes, também faz parte do banco de dados EPILEPSIAE outras informações, como exames de imagem e informações clínicas suplementares acerca dos pacientes em questão. O banco de dados EPILEPSIAE é composto de dados acerca de trezentos pacientes epiléticos.

### 2.5.1 Coleta dos dados

Os dados eletroencefalográficos dos pacientes foram obtidos através de eletrodos não-invasivos colocados no couro cabeludo (eletrodos de superfície). Em adição a esses dados, a taxa de batimento cardíaco dos pacientes foi coletada a partir de um eletrodo utilizado para este fim. Movimentos oculares dos pacientes, assim como as suas contrações musculares, captados igualmente através de eletrodos, complementam a base de dados coletada.

Teoricamente, o eletroencefalograma (EEG) seria gravado de forma contínua, durante todo o período de coleta a qual os pacientes foram submetidos, porém, na prática, houve situações em que o EEG teve que ser interrompido e reiniciado. Algumas das causas dessas interrupções foram a necessidade de se adicionar eletrodos de superfície suplementares, realizar outras formas de investigação clínica e problemas técnicos no sistema de gravação dos dados do EEG. Nessas situações de interrupção do exame, a solução adotada pelos responsáveis variou entre começar uma nova gravação do início ou continuar a gravação corrente, apesar do intervalo causado pela interrupção da gravação [5].

Os dados gravados pelo sistema de gravação do EEG foram divididos em blocos e armazenados em discos rígidos e seus meta-dados disponibilizados em uma tabela específica do banco de dados. Cada leitura do aparelho de EEG foi chamada de *sample*.

### 2.5.2 Arquivos Binários

Os blocos de dados provenientes das gravações do EEG são compostos de *samples*, que refletem os valores calculados a partir das leituras obtidas dos eletrodos do EEG em um determinado período de gravação. Esses dados não foram armazenados no banco de dados relacional utilizado e sim em arquivos binários em formato próprio desenvolvido pelo projeto EPILEPSIAE. Esses arquivos são do tipo *m-file*, arquivos de comandos do *MatLab/Octave*.

# Capítulo 3

## Redes Neurais e o Modelo

### WiSARD

Uma rede neural artificial (RNA) representa uma analogia às redes neurais biológicas (RNBs) e tem como principal função simular computacionalmente o funcionamento destas, com o intuito de solucionar tarefas em que a capacidade de inferência, o aprendizado e o reconhecimento de padrões sejam requisitos necessários. Assim, as RNAs tem sua forma estrutural composta por neurônios e sinapses ou simplesmente ligações inter-neuronais, onde o fluxo de informação é processado de forma paralela entre os seus diversos neurônios. Basicamente, os neurônios são agrupados, constituindo assim uma rede neuronal cuja complexidade estrutural é variável, dependendo da arquitetura utilizada. Dessa forma, tarefas dos mais diversos graus de complexidade podem ser executadas por uma RNA.

### 3.1 Redes Neurais Com Peso

As redes neurais do tipo com peso armazenam o conhecimento nas sinapses, as ligações entre os neurônios. Cada sinapse possui um peso associado, sobre o qual os valores transmitidos por ela é ponderado. Aos neurônios cabe determinar o valor de saída de uma determinada entrada na rede (soma ponderada dos sinais de entrada), por meio da aplicação de uma função de ativação [12].

Em relação aos pesos sinápticos, eles podem ser negativos ou positivos, numa clara representação computacional dos caracteres inibitórios e excitatórios de um neurônio biológico. A definição dos pesos das sinapses é feita durante a fase de treinamento da rede, visando encontrar um ajuste que permita a correta execução do trabalho a ser realizado pela rede neural. Os pesos sinápticos podem, e frequentemente são, reajustados (e a rede retreinada), caso os testes não apresentem uma boa acurácia.

A arquitetura de uma rede neural desse tipo é definida pelo padrão de ligações (sinapses) entre seus neurônios, enquanto que a determinação dos pesos sinápticos fica a cargo do algoritmo de treinamento ou aprendizado utilizado. Isto posto, pode-se caracterizar uma rede neural com peso pelos seus aspectos mais relevantes: a sua arquitetura, o seu algoritmo de treinamento e a sua função de ativação. A Figura 3.1 apresenta a estrutura básica de uma rede neural com peso, do tipo de arquitetura multi-camadas.

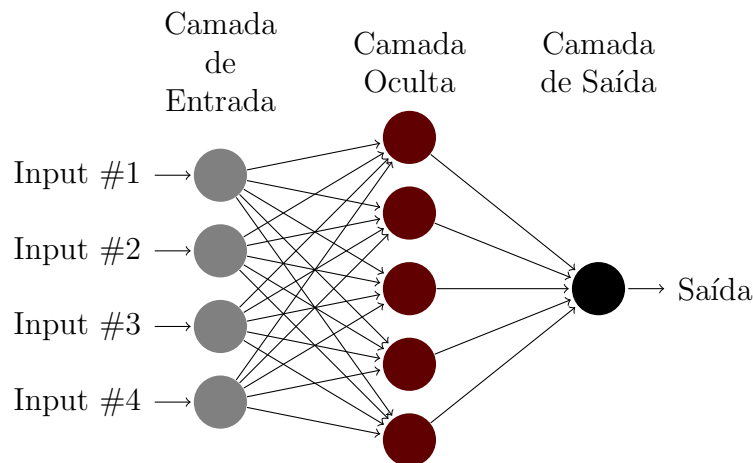


Figura 3.1: Rede Neural com Peso - Arquitetura Multi-Camadas

## 3.2 Wisard - Um Modelo de Rede Neural Sem Peso

A WiSARD (Wilkie, Stonham & Aleksander's Recognition Device) [4] é um modelo de rede neural sem peso. Criada originalmente para lidar com a tarefa de reconhecimento de imagens, ela possui um caráter booleano, onde as entradas admitidas são cadeias ou conjunto de bits. Pelo fato da WiSARD ser um modelo booleano, padrões que não tenham uma natureza binária deverão forçosamente ser convertidos para esse formato.

### 3.2.1 Arquitetura da WiSARD

É correto afirmar que a WiSARD é um sistema formado por vários discriminadores, onde cada um desses discriminadores está associado à uma das possíveis classes



do conjunto de padrões apresentados à rede para reconhecimento. Dessa forma, considere-se o discriminador como o elemento básico da WiSARD, sendo este composto por um grupo de nós-RAM (*Random Access Memory*) ou neurônios, e um dispositivo de soma  $\Sigma$  [13]. Para cada classe existente haverá um discriminador associado à ela, cujos neurônios (nós-RAM) são os responsáveis por armazenar as informações aprendidas durante a fase de treinamento, ou seja, os dados referentes às entradas submetidas à rede.

O dispositivo de soma  $\Sigma$  dos discriminadores é o responsável por fornecer a medida de similaridade de uma entrada em relação à classe a qual um discriminador está associado. Quanto à aferição do valor dessa medida de similaridade, ela nada mais é que o somatório das saídas dos neurônios após uma entrada ser submetida à WiSARD para reconhecimento. A constatação de quão similar é uma entrada em relação à classe de um discriminador, baseia-se no valor da medida de similaridade obtida; quanto maior for este valor, maior a similaridade da entrada referente à classe do discriminador em questão.

Quando uma entrada é apresentada à WiSARD, ocorre um mapeamento de forma aleatória dessa entrada, para que cada um de seus bits seja associado à um e somente um neurônio (nó-RAM). Esse mapeamento uma vez aleatoriamente definido, será utilizado em todas as entradas submetidas à rede e consiste em particionar os bits de cada uma das entradas em grupos menores, de modo que haja um grupo de bits para cada neurônio existente no discriminador. Além de definir a que grupo cada bit de entrada será alocado, o mapeamento também define a ordem dos bits nos grupos.

Todos os grupos de bits obtidos no mapeamento tem tamanho igual, garantindo assim que não haja uma hierarquia de relevância entre os grupos e com isso, que todos os grupos sejam igualmente importantes. Esse tipo de mapeamento tem também como objetivo impedir que endereços de posições de escrita sejam formados por bits que estejam a priori próximos na entrada. E como bits próximos tendem a ter o mesmo valor nas entradas apresentadas à rede, a formação de endereços com esses bits para um mesmo neurônio (nó-RAM), acarretaria em redundância de informação nesse nó.

Os neurônios possuem  $2^n$  endereços de escrita, onde  $n$  é o número de bits que existem em cada um dos grupos de bits gerados pelo particionamento das entradas. Um discriminador dotado de poucos neurônios (nós-RAM) fará com que cada um de seus neurônios tenha muitos endereços, ou seja, neurônios muito esparsos; acarretando que entradas de uma classe sejam corretamente classificadas pelo discriminador referente àquela classe, caso elas sejam muito similares ao padrão aprendido durante o treinamento. Desse modo, temos então uma rede muito especialista.

De maneira análoga, muitos neurônios em um discriminador garante que esses

neurônios terão poucas posições de escrita endereçáveis. Nessa configuração neuronal, pode ocorrer que entradas não muito similares a um padrão aprendido por um discriminador possam ser reconhecidas por este discriminador, como sendo pertencente à classe a qual ele representa. Nesse caso, temos uma rede muito generalista.

Dependendo do problema lidado e o que a WiSARD se propõe a fazer, o número de discriminadores pode variar. Vale ressaltar que nem uma rede especialista demais (perde a capacidade de generalização), nem tampouco uma rede excessivamente generalista (pode reconhecer uma entrada de uma classe como pertencente à outra com mais facilidade) são desejáveis. A Figura 3.2 (a) e (b) mostra o esquema de um discriminador WiSARD e a Arquitetura Multi-Discriminador desta Rede Neural.

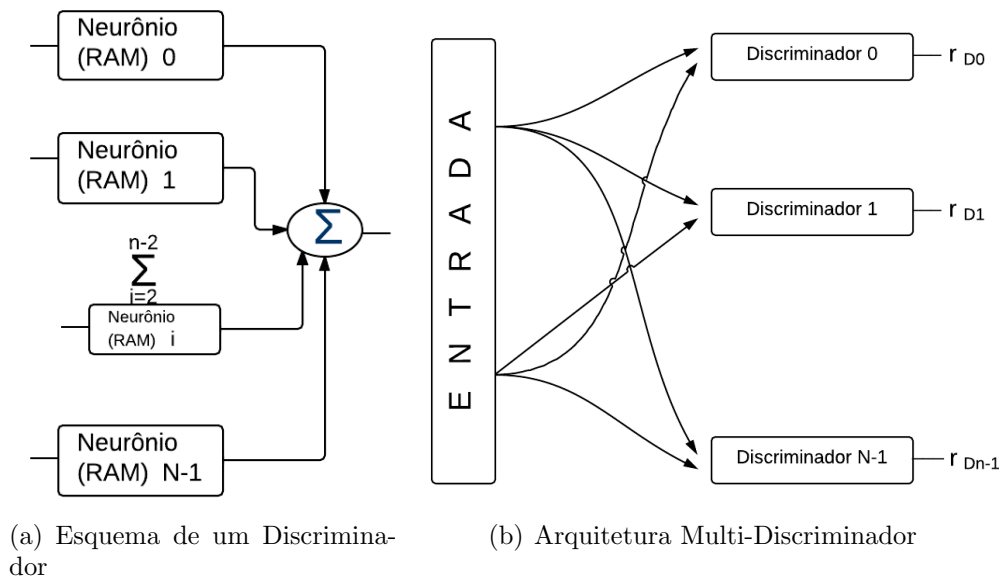


Figura 3.2: Discriminador e Arquitetura da WiSARD

O princípio da casa dos pombos ou das gavetas de Dirichlet [14], afirma que havendo  $k$  pombos e  $q$  casas, sendo  $k > q$ , então haverá pelo menos 1 casa com mais de um pombo. Matematicamente falando, isto quer dizer que se o número de elementos de um conjunto finito  $A$  é maior do que o número de elementos de um outro conjunto finito  $B$ , então uma função de  $A$  em  $B$  não pode ser injetiva. De forma análoga, sendo  $k$  muito menor do que  $q$ , o número de casas habitadas por pombos será muito pequeno.

Partindo do princípio exposto, pode-se afirmar que sendo  $N$  o número de posições

de escrita endereçáveis em um neurônio (nó-RAM) e  $E$  o número de posições que foram de fato endereçadas durante a fase de treinamento da rede, e sendo  $N$  extremamente maior do que  $E$  (neurônios esparsos com um número pequeno de posições de escrita endereçados em relação ao número total de posições de escrita disponíveis, após o aprendizado dos padrões pela rede), pode-se afirmar que a probabilidade  $p$  de uma nova entrada  $e$ , durante o reconhecimento de um padrão, ser endereçada para um das posições  $E$  é pequena, pois  $p$  é expresso pelo resultado da divisão  $E/N$ . Tal situação faria com que a saída dos neurônios durante o reconhecimento de um novo padrão apresentado à rede tendesse a ser 0, a menos que a entrada referente a esse padrão fosse extremamente similar à alguma entrada (padrão) aprendida pela WiSARD durante o seu treinamento(aprendizado). Para evitar a ocorrência desse tipo de situação é necessário admitir que um discriminador tenha uma quantidade razoável de nós-RAM (neurônios), com uma quantidade também razoável de posições de escrita, garantindo assim que a rede tenha um poder de generalização adequado e com isso, a capacidade de classificar novos padrões (entradas) de uma maneira satisfatória.

Com o intuito de mostrar o funcionamento da WiSARD, será exemplificada a execução da tarefa de reconhecimento de imagens, tarefa para qual a WiSARD foi a princípio criada. A Figura 3.3 ilustra o endereçamento dos grupos de bits nos nós-RAM(Neurônios).

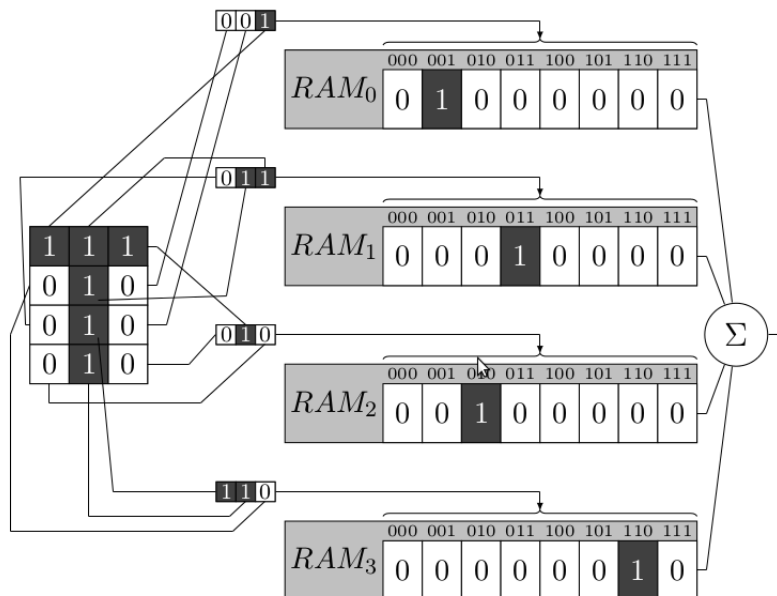


Figura 3.3: Endereçamento de Grupos de Bits em um Neurônio (Nó-RAM) WiSARD [1]

### 3.2.2 Fase de Treinamento

Durante a fase de treinamento ocorre efetivamente o aprendizado dos padrões (entradas) associados às classes existentes no conjunto de entradas. Para o treinamento dos discriminadores da WiSARD, primeiramente é preciso que todas as posições de escrita de todos os seus neurônios sejam inicializadas com o valor 0, sendo que após feito isso, um conjunto de entradas para treinamento (conjunto de treino) é formado dentre o conjunto de entradas disponíveis. Então essas entradas, uma por vez, são mapeadas para os neurônios (nós-RAM) da WiSARD, de acordo com o mapeamento aleatório definido na arquitetura da rede, ou seja, cada neurônio de um discriminador receberá um grupo de bits específico de cada entrada submetida à rede neural.

A entrada de uma determinada classe somente endereça posições de escrita dos neurônios do discriminador correspondente à sua classe. Desse modo, o discriminador aprende as características das entradas da classe a qual ele representa, permitindo assim que ele possa reconhecer novas entradas como sendo ou não pertencentes à sua classe. Ou seja, em uma rede bem treinada seus discriminadores irão gerar um valor de saída alto para as entradas que forem da mesma classe que eles representam e valores de saída baixos caso contrário.

O aprendizado gerado pelo treinamento da rede é feito alterando o valor para "1" das posições de escrita dos neurônios que forem endereçadas durante essa fase de treinamento. O grupo de bits destinado a um nó-RAM (neurônio) representa o endereço de sua posição de escrita que terá o valor alterado para "1". O treinamento finda após todos os padrões do conjunto de treino terem sido submetidos à rede neural.

A simplicidade desse processo de treino/aprendizado, a simples submissão das entradas à rede, é um dos pontos mais positivos de uma rede neural sem peso. As Figuras 3.4(a) e (b) mostram a configuração dos nós-RAM (neurônios) de um discriminador antes e depois da realização da fase de treinamento.

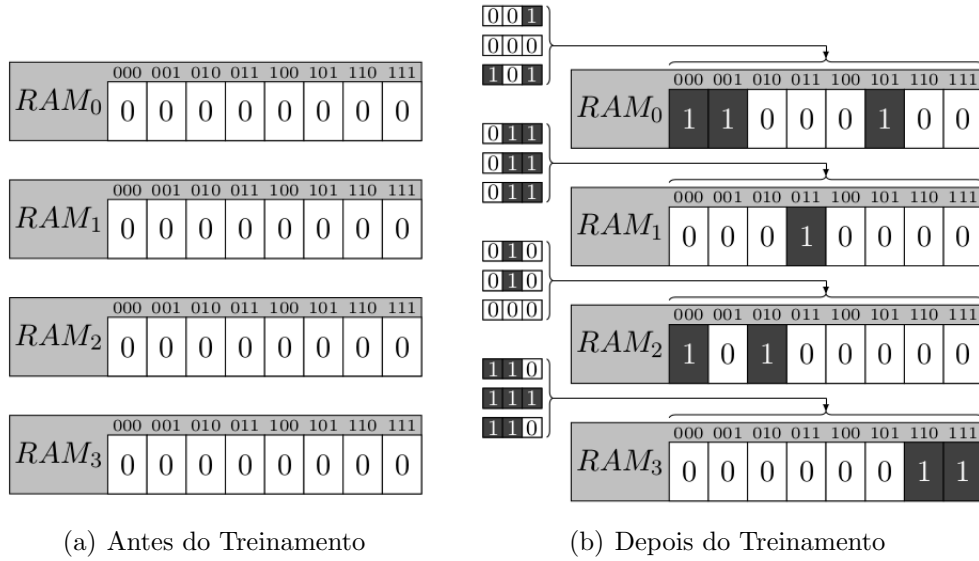


Figura 3.4: Visão dos Neurônios (Nós-RAM) na Fase de Treinamento [1]

### 3.2.3 Fase de Teste

A fase de teste tem como objetivo aferir a acurácia da rede em classificar corretamente novas entradas. Essa fase é executada ao se submeter à rede entradas que ainda não tenham sido anteriormente submetidos à ela. O conjunto dessas entradas a serem testadas recebe o nome de conjunto de teste.

Quando a entrada inédita é apresentada, ela é então subdivida em grupos de bits de acordo com o já citado mapeamento aleatório da rede e após isso, cada grupo de bits é endereçado à um neurônio específico. Esse procedimento é aplicado a todos os discriminadores da WiSARD. Depois do endereçamentos dos grupos de bits aos neurônios da rede, cada um dos discriminadores irá produzir sua medida de similaridade em relação à entrada (padrão) apresentada para teste, que é na verdade o número de seus neurônios (nós-RAM) que tiveram como saída o valor "1".

A Figura 3.5 demonstra a medida de similaridade de um discriminador da WiSARD após a submissão de uma entrada, durante a fase de teste.

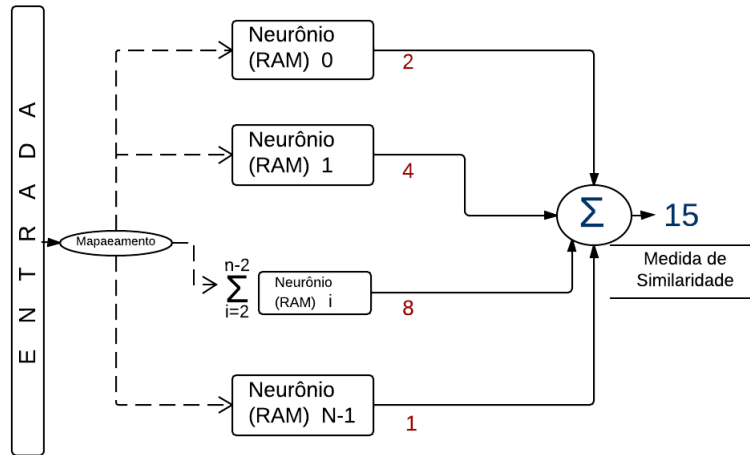


Figura 3.5: Medida de Similaridade de um Discriminador Após Teste

O discriminador que obtiver a medida de similaridade mais alta ( $rMAX$ ) será aquele que irá rotular o padrão apresentado com a sua classe. A classificação dada pela rede à entrada submetida é então comparada com a classe real da entrada em questão, caso a classe atribuída pela rede seja a classe real da entrada, considera-se que a rede teve um acerto de classificação. Ao final da submissão de todas as entradas do conjunto de teste, verifica-se o percentual de acertos obtidos pela rede em relação à quantidade de entradas (padrões) testadas. Quanto mais alto for esse percentual, melhor terá sido o desempenho da WiSARD em classificar novos padrões.

Outra medida que pode ser utilizada para se analisar o desempenho da rede no processo de classificação de novos padrões é a Confiança da Resposta. O valor de Confiança varia de 0 à 1, sendo que quanto mais próximo de 1 ele for, maior será a chance da classificação fornecida pela WiSARD estar correta. Para se obter o grau de Confiança ( $\varphi$ ) de uma resposta, basta efetuar o cálculo demonstrado na fórmula expressa na Figura 3.6, onde  $rMAX$  e  $rMAX-1$  são respectivamente, a medida de similaridade de maior valor e a de segundo maior valor; e  $\alpha$  a diferença entre esses dois valores.

A Figura 3.7 mostra o processo de classificação de um nova entrada (padrão) pela WiSARD e a forma como o grau de Confiança da resposta é obtido.

$$\varphi = \frac{\alpha}{R_{max}} = \frac{R_{max} - R_{max-1}}{R_{max}}$$

Figura 3.6: Cálculo do Grau de Confiança de uma Resposta da Rede

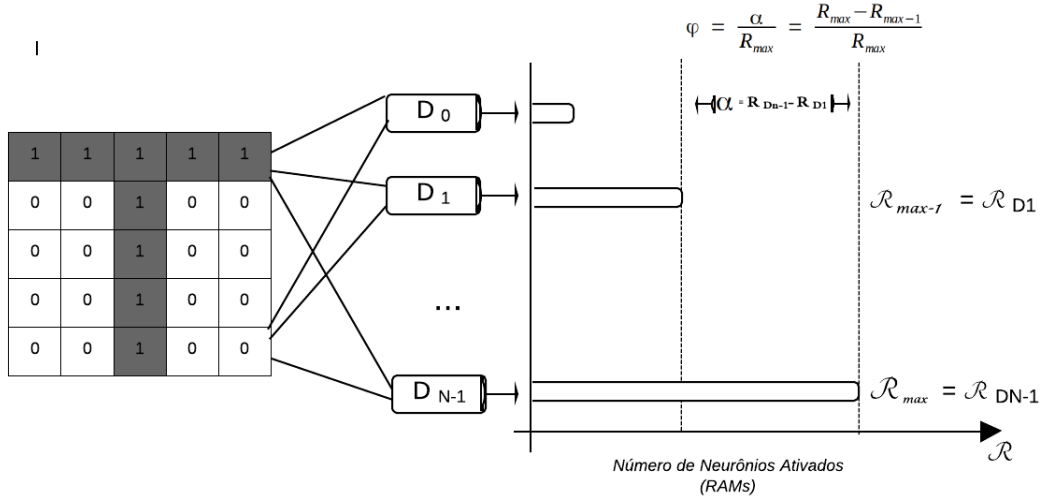


Figura 3.7: Classificação de uma Entrada com Cálculo da Confiança

### 3.2.4 Bleaching

Após a fase de treinamento da WiSARD, um problema que pode ocorrer é o da saturação dos neurônios. Isto ocorre quando um número significativamente grande de entradas é usada como conjunto de treino da rede, o que faz com que a maioria das posições de escrita dos neurônios estejam marcadas (valor 1). A saturação dos neurônios (nós-RAM) pode acarretar em uma classificação errônea de novas entradas apresentadas à WiSARD para reconhecimento, pois neurônios saturados de um discriminador tendem a reconhecer entradas (padrões) de classes similares à classe a qual o discriminador desses neurônios pertence, como entradas da classe desse discriminador.

Durante o treinamento da rede, várias entradas são submetidas para que a rede possa marcar com o valor "1" as posições dos neurônios dos discriminadores que tiverem sido acessadas através dos grupo de bits, nos quais a entrada foi subdividida. Entretanto, após essa fase de treinamento algumas posições podem ter sido mais acessadas do que as outras. Ou seja, pode ter ocorrido que posições tenham sido sobrescritas com o valor "1" diversas vezes, enquanto outras podem ter sido escritas apenas uma ou poucas vezes.

Uma maneira prática de se resolver o problema da saturação consiste em aplicar a técnica de *bleaching* [15]. Essa técnica consiste em estabelecer um *threshold*  $b$ ,  $b > /1$ , para que então todas as posições dos neurônios que tiverem sido escritas por um número de vezes igual ou menor do que  $b$  sejam apagadas, ou seja, tenham

o seu valor alterado para "0". O *bleaching* resolve de maneira eficiente o problema da saturação dos neurônios, à medida que ele faz com que a quantidade de escritas sofridas pelos neurônios seja diminuída.

A definição do valor de  $b$  varia de acordo com o que se deseja da rede, maior generalização ou especificidade. Quanto maior valor de  $b$ , menos generalista a rede será. Para a implementação da técnica de *bleaching* é necessária uma alteração na arquitetura dos neurônios dos discriminadores, para que eles guardem a informação de quantas vezes sofreram escritas durante o treinamento da rede, além do valor "0" ou "1" em suas posições de escrita.

As Figuras 3.8 e 3.9 demonstram a aplicação do *bleaching* com  $b = 1$  e  $b = 2$ , respectivamente.

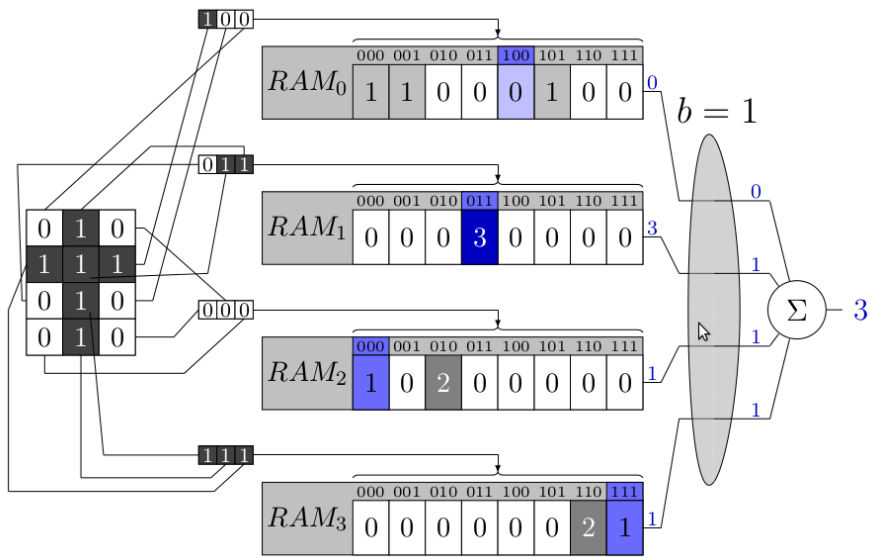


Figura 3.8: Técnica de *bleaching* com  $B = 1$  [1]



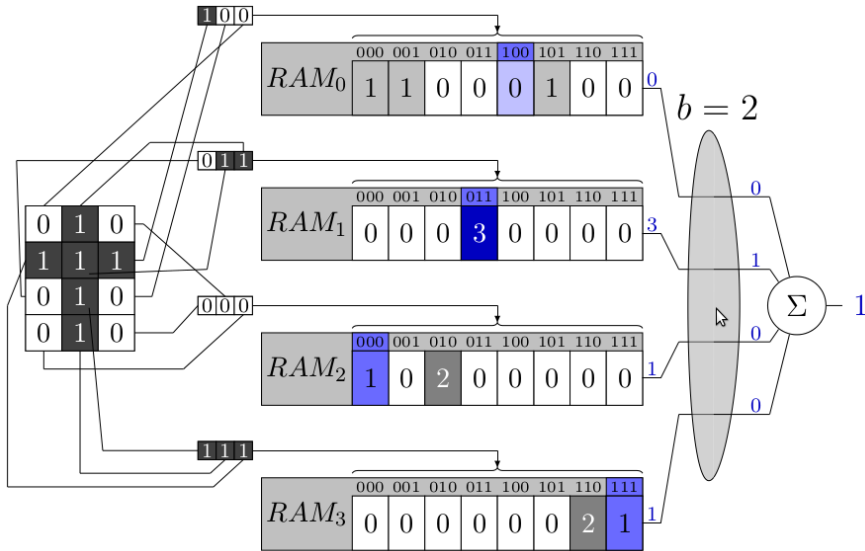


Figura 3.9: Técnica de *bleaching* com  $B = 2$  [1]

### 3.3 Utilização da WiSARD em Outras Aplicações

As subseções seguintes apresentam o uso da WiSARD em algumas tarefas interessantes.

#### 3.3.1 Classificação Gramatical com Índice de Síntese

O trabalho citado nesta Subseção tem como objetivo agilizar a fase de treinamento de classificadores gramaticais. A importância de um classificador gramatical é dada pela sua capacidade de resolver possíveis ocorrências de ambiguidades na execução da tarefa de classificação gramatical, que é uma tarefa fundamental na linguística computacional e no processamento de linguagens naturais.

Sendo a tarefa de classificação gramatical um passo inicial para a resolução de tarefas de maior grau de complexidade, como a tarefa de inferência de gramáticas, o trabalho mencionado nesta Subseção opta pela WiSARD como modelo de rede neural a ser adotado. A justificativa por essa escolha advém do fato da WiSARD não necessitar atingir convergência alguma em sua fase de treino (como já mencionado nesta dissertação, o treinamento consiste apenas na submissão das entradas e o mapeamento desta em grupos de bits para os neurônios de cada um de seus discriminadores). O fato das ferramentas mais usadas para a resolução do problema de classificação gramatical necessitarem do uso de processos iterativos que tornam a fase de treino lenta, torna inviável a tarefa de classificação gramatical multilíngue, que é o objetivo do trabalho do autor referenciado nesta Subseção, o que não ocorre com o uso da WiSARD nesse sentido, pois o seu treinamento é considerado rápido.

Além disso, o trabalho em questão cita o fato de haver uma relação direta entre

os valores do índice de síntese e os parâmetros da configuração ótima de uma rede neural para classificação gramatical em uma dada linguagem. Nesse cenário, pontua-se que no caso da WiSARD, os experimentos realmente comprovaram a eficácia do uso dos valores do índice de síntese para a obtenção da melhor configuração deste modelo de rede visando as classificações gramaticais em uma língua. Segundo os mesmos experimentos, a WiSARD apresentou acurácia e precisão maiores do que as redes encontradas na literatura até então. [1]

### 3.3.2 Agrupamento de Dados em Fluxo Contínuo

De acordo com o que expõe o trabalho aqui mencionado (3.2.2), o agrupamento em fluxo contínuo difere do agrupamento clássico, pelo fato de que a definição dos agrupamentos no primeiro ocorre em um instante de tempo e considera os dados mais recentes como mais relevantes dos que os mais antigos para a formação dos grupos. Um fator complicador nesse agrupamento de dados, provenientes de um fluxo contínuo seria o fato do processamento dos dados precisar ser mais veloz do que a velocidade com que os dados são recebidos, além da necessidade de percepção de alguma eventual alteração durante a tarefa de análise do fluxo de dados. O autor do trabalho referido nesta Subseção propôs uma variação da rede neural WiSARD, adaptada para trabalhar com dados em fluxo contínuo, e deu à essa variante da WiSARD tradicional, o nome de *StreamWiSARD*.

A *StreamWiSARD* foi capaz de lidar com o agrupamento de dados em fluxo contínuo com um percentual baixo de consumo de memória. Esse baixo consumo deve-se ao fato da *StreamWiSARD* manter durante o seu funcionamento um pequeno número de microgrupos, sendo este o seu maior diferencial em relação às demais alternativas existentes para lidar com esse problema, pois estas buscam gerenciar o maior número de microgrupos possível. Cite-se também o uso dos discriminadores WiSARD como unidades básicas de sintetização de dados e as propriedades interessantes que este uso gerou durante os experimentos realizados pelo autor do trabalho aqui citado. [16]

### 3.3.3 Categorização de Subtipos do HIV-1

Além da categorização dos diferentes subtipos do vírus HIV-1, a identificação da existência ou não, de mutações genéticas do vírus capazes de resistir ao tratamento clínico, através de antiretrovirais, também foi considerada no trabalho em questão. Os dados usados foram essencialmente provenientes de pacientes infectados pelos subtipos *B*, *C* e *F* do HIV-1, sob falha terapêutica. Por falha terapêutica, entenda-se como a situação onde houve resistência ao tratamento à base de antiretrovirais, pela ocorrência de mutações genéticas do vírus.

As redes neurais sem peso, em geral, se mostraram eficientes, tanto na classificação dos subtipos do HIV-1, quanto no reconhecimento das mutações de resistência aos antiretrovirais. De todos os modelos sem peso utilizados, a WiSARD foi a que se mostrou mais eficiente. Após a realização de diversos experimentos, concluiu-se que, para o problema aqui exposto, o emprego da técnica de *bleaching* foi indispensável para a obtenção de bons resultados pela WiSARD. [17]

# Capítulo 4

## Método Utilizado para Predição de Crises Epilépticas

Este Capítulo se destina a explicitar o Método Preditor utilizado para a realização da tarefa de predição de crises epilépticas. A metodologia do trabalho pode ser basicamente dividida em duas partes: a adequação dos dados recebidos da base de dados utilizada (Banco de Dados EPILEPSIAE [5]), para o uso destes pela rede neural sem peso WiSARD [4]; e a implementação da WiSARD, sob uma arquitetura e parâmetros apropriados, visando fazer com que ela funcione como um preditor de crises epilépticas. Também são citadas considerações gerais acerca das aplicações desenvolvidas para a presente dissertação, seja para o pré-processamento dos dados, como para a efetiva predição das crises.

### 4.1 Metodologia

Duas aplicações computacionais foram desenvolvidas para a execução das duas etapas do método preditor criado, uma para cada fase do trabalho, como anteriormente exposto. A linguagem de programação utilizada foi a linguagem Python, por ser uma linguagem de alto nível e possuir um grande número de bibliotecas computacionais(módulos) nativas ao seu interpretador, e que foram de grande valia na construção dos algoritmos da presente dissertação. Cada fase do trabalho será detalhada nas subseções seguintes.

Os dados usados como base de dados da aplicação construída para o trabalho de predição de crises epilépticas foram gentilmente cedidos pelo projeto EPILEPSIAE [5]. Tratam-se de gravações (registros), em sua grande maioria eletroencefalográficas, acrescidas de registros de batimentos cardíacos, de captura de movimentos oculares e de tensionamento muscular. Como mencionado na Subseção 2.5.1 (Coleta dos dados), as gravações de cada paciente (*dataset*) foram divididas em blocos.

### 4.1.1 Pré-Processamento dos Dados

Os dados de cada um desses blocos foram gravados em arquivos binários em um formato plano próprio, desenvolvido pelos responsáveis pelo banco de dados EPILEPSIAE. O pré-processamento dos dados obtidos, de maneira a convertê-los para um formato adequado e conveniente para uso na rede neural WiSARD criada para a presente dissertação, abrangeu três etapas distintas a saber:

- Conversão dos arquivos de dados binários originais (formato binário plano próprio do EPILEPSIAE) em arquivos textos
- Conversão dos dados dos arquivos textos, passando-os de valores decimais para inteiros representando a quantidade de bits “1” destes em binário
- Criação dos arquivos de *input*, cujas linhas representariam as entradas a serem submetidas para a WiSARD

#### 4.1.1.1 Conversão dos Arquivos de Dados Binários Originais em Arquivos Textos

Apesar do maior consumo de memória no armazenamento de arquivos textos se comparados a arquivos binários tradicionais, foi decidido converter os arquivos originais em arquivo textos. Essa a decisão foi tomada considerando a maior facilidade de manuseio de arquivos desse tipo e também pelo fato da visualização do conteúdo desses arquivos poder ser feita de maneira não dispendiosa, computacionalmente falando. Um script na linguagem usada pelo MATLAB © foi escrito para essa tarefa de conversão dos arquivos binários originais.

#### 4.1.1.2 Conversão dos Dados dos Arquivos Textos de Decimal para Inteiros Representando Valores Binários

Nos arquivos com os dados referentes às gravações realizadas nos pacientes para obtenção de suas leituras de EEG (mais os dados de batimentos cardíacos, movimentos oculares e musculares), cada linha desses arquivos representa um intervalo de tempo de uma gravação, chamado de *sample*. O número de atributos (valores) de uma *sample* corresponde ao número de eletrodos utilizados para a leitura dos impulsos elétricos (cerebrais e cardíacos) e comportamento ocular e muscular dos pacientes. À exceção de um dos pacientes (paciente nº 8900102, com 27 eletrodos), o número de eletrodos usados na obtenção dos dados foi 29, ou seja, as *samples* das gravações dos pacientes continham 29 ou 27 atributos.

O valor de uma *sample* corresponde à quantidade de *hertz* lida por um eletrodo. Estes valores foram gravados nos arquivos de dados, após terem sido convertidos de

valores decimais (referentes aos *hertz* lidos) para inteiros pelo projeto EPILEPSIAE, baseado em fórmula de conversão própria. Apesar da possibilidade de reverter a conversão destes valores, ficou decidido que trabalhar com os dados das *samples* em valores inteiros seria mais apropriado para fins de reconhecimento de padrões.

Como explicitado na Seção 3.2 (Wisard - Um Modelo de Rede Neural Sem Peso), a WiSARD, por ser um modelo booleano, só admite como entradas padrões que estejam configurados como conjuntos de bits. Por esse motivo, os valores inteiros dos arquivos textos de dados foram codificados para o sistema numérico binário, através do método do "termômetro". De acordo com esse método, define-se um valor  $X$  de bits para a conversão de cada valor inteiro para binário, através da fórmula expressa na Figura 4.1, onde  $E_i S_j$  corresponde ao elemento na posição  $i$  de uma *sample*  $j$ ,  $Nb$  corresponde ao número de bits a ser atribuído na conversão dos valores de inteiro para binário (20 bits no presente trabalho) e  $VMAX$  corresponde ao maior valor presente na faixa de valores dos dados a serem convertidos, no caso do presente trabalho, o valor 32767.

Foram testados outros valores para a conversão de números inteiros para binários, como 10, 30 e 40 bits. No entanto, objetivando não elevar o gasto de memória, foi preferível trabalhar com o menor valor possível, desde que esse valor não ocasionasse um mapeamento de um grupo muito grande de valores inteiros para um intervalo reduzido de valores binários, e com isso garantir a preservação da diferença entre valores de leituras neuronais de situações distintas dos pacientes (crise e não-crise). O valor 20 foi o menor valor que atendeu a esses requisitos.

Ainda sobre o método do "termômetro", os valores obtidos pela sua aplicação indicam quantos bits "1", o número binário referente ao número inteiro convertido irá receber. Intuitivamente, a quantidade de bits "0" será a diferença entre o número de bits total a ser usado e a quantidade de bits "1" definida. A Figura 4.2 mostra um exemplo de conversão de um número inteiro para o seu correspondente em binário.

Os valores binários referentes aos valores inteiros originais foram armazenados em um novo arquivo texto de dados. Porém, esses valores foram gravados sob a forma de números inteiros que expressam a quantidade de bits "1" que cada número binário possui. Exemplo, se um número inteiro foi convertido para o número binário **00000000001111111111** (10), então o valor armazenado correspondente a esse número binário no novo arquivo texto de dados será 10.

$$V_{bin} = \frac{E_i S_j \cdot Nb}{V_{max}} \Rightarrow \frac{16384 \cdot 20}{32767} \Rightarrow \approx 10$$

Figura 4.1: Fórmula da Conversão de Inteiro para Binário




Figura 4.2: Exemplo de Conversão de Inteiro para Binário

Mesmo tendo havido o cuidado em não escolher um número muito reduzido de bits para a representação dos valores binários convertidos, após as conversões dos primeiros arquivos de dados notou-se que a maior parte dos valores inteiros compreendidos no intervalo  $[-32768, 32767]$  foi mapeado para um intervalo muito restrito e centralizado na faixa de valores binários  $[-20, 20]$ , o que acarretou na perda de dessemelhança entre entradas de padrões diferentes. Por exemplo, padrões de situações de futura ocorrência de crise (*nonIctal-ictal*) e situações normais (*nonIctal-nonIctal*) receberam representações binárias muito semelhantes. Constatou-se que essa situação foi ocasionada pelo fato de que, apesar da abrangência da faixa de valores inteiros dos arquivos de dados ser ampla  $[-32768, 32767]$ , a maior parte destes valores estava concentrada em um sub-intervalo significativamente menos amplo. Logo, dada a aplicação da fórmula do "termômetro", o valor máximo dessa faixa de valores inteiros ( $V_{MAX} = 32767$ ) fazia com que os elementos que estavam agrupados inicialmente nesse sub-intervalo citado fossem mapeados para um intervalo mais restrito na faixa de valores binários após a conversão, sendo essa a causa para a perda de dessemelhança já mencionada.

Constatado esse fato, foi proposto a criação de um modo próprio para a conversão dos valores inteiros para binários, na verdade, uma sutil alteração do método do "termômetro" com a adição de um passo preliminar, que foi a aplicação de uma função logarítmica sobre os valores, antes que estes fossem de fato convertidos para binário. É demonstrado a seguir o pseudocódigo referente ao método do "termômetro" utilizado nesta dissertação, com o passo preliminar representado pela aplicação do logaritmo natural sobre o módulo dos valores inteiros, acrescidos de 1; em caso de valores inteiros negativos provenientes dos arquivos de dados, o resultado do cálculo logarítmico é multiplicado por  $-1$ . A necessidade da adição do valor 1 aos valores inteiros deveu-se pela existência do valor 0 entre os valores presentes nos arquivos de dados.

---

**Algoritmo 1:** Conversão de Inteiros para Binários

---

**Entrada:** Lista L com Número dos Arquivos Textos

**Saída:** Arquivos Textos Convertidos para Binário

**início**

```
bin= número de bits a ser recebido por cada número binário;
para  $i \leftarrow 1$  a  $N$  faça
  nomeArquivo= "arquivo"+L[i]+".txt";
  matrix= carrega dados de nomeArquivo em forma de uma matriz;
  lin= quantidade de linhas de matrix;
  col= quantidade de colunas de matrix;
  para  $l \leftarrow 1$  a  $lin$  faça
    para  $c \leftarrow 1$  a  $col$  faça
      /* aplicação da Função Logarítmica */
      se  $matrix[l,c] \geq 0$  então
        | matrix[l,c]= arredonda (logaritmo natural de ( $|matrix[l,c]|$ 
        | + 1));
      fim
      senão
        | matrix[l,c]= arredonda (-1 * (logaritmo natural de
        | ( $|matrix[l,c]| + 1)));$ 
      fim
    fim
  fim
  min= módulo do menor valor de matrix ;
  max= maior valor de matrix ;
  /* Método de Conversão do ''Termômetro'' */
  para  $l \leftarrow 1$  a  $lin$  faça
    para  $c \leftarrow 1$  a  $col$  faça
      | matrix[l,c]= arredonda(((min + matrix[l,c]) * bits) / max) ;
    fim
  fim
  Escreve-Novo-Arquivo(matrix, nomeArquivo);
fim
```

---

A alteração feita no método do "termômetro" resolveu o problema do mapeamento dos valores inteiros das *samples* para valores binários. Depois de realizada a aplicação da função logarítmica (logaritmo natural), a nova faixa de valores dos dados [-10.397238225511654, 10.39720770839918] possuía um valor máximo bem menor ( $VMAX = 10.39720770839918$ ), constituindo-se de uma nova representação



da faixa de valores original em escala reduzida, todavia tendo sido preservada a distância anterior que existia entre os elementos, inicialmente. Assim, dado o novo  $V_{MAX}$  possuir valor igual à 10.39720770839918 e os valores estarem melhores distribuídos, a aplicação da conversão dos valores inteiros para binários não mais mapeava um grande conjunto de números inteiros para um mesmo valor binário, como anteriormente ocorria.

#### 4.1.1.3 Criação dos Arquivos de *Input* com as Entradas a serem submetidas à WiSARD

Resolvido o problema da conversão dos valores das *samples* de inteiros para binários, restou apenas a tarefa de estruturação desses dados em arquivos de entrada (*input*) a serem usados na WiSARD. Para a criação de um arquivo de *input* eram necessários dois parâmetros, referentes à Janela de Tempo de Observação dos dados dos pacientes (*input*) e ao Intervalo de Tempo para predição de uma possível crise (*delta*). Ambos os parâmetros definidos tiveram suas grandezas expressas em segundos.

Feita a definição destes dois parâmetros, *input* e *delta*, bastou então posicionar a Janela de Tempo de Observação no início do arquivo de dados dos pacientes e rotular esse instante de tempo com o rótulo da classe da última *sample* pertencente à esta janela, mais o rótulo da classe da *sample* que estava *delta* segundos à frente dessa posição, criando-se assim uma entrada (padrão) a ser usado na WiSARD, que representaria a situação do paciente naquele intervalo de tempo e a situação futura em que este paciente se encontraria. Depois, seguiu-se movendo a janela, de uma em uma *sample*, até que todas as entradas possíveis do paciente fossem coletadas, como em uma série temporal. Este procedimento foi realizado apenas nos arquivos de dados referentes aos blocos de gravação dos pacientes em que de fato havia a ocorrência de uma crise epiléptica, desprezando os demais blocos para evitar uma predominância excessiva de entradas que representassem a situação de normalidade dos pacientes (*nonIctal-nonIctal*).

Para cada possível configuração dos parâmetros *input* (Janela de Tempo de Observação) e *delta* (Intervalo de Tempo de Predição) de um paciente a ser usado na WiSARD, um arquivo de entradas foi criado.

### 4.1.2 A WiSARD como Preditor de Crises Epilépticas

Neste Capítulo, será explicado como foi desenvolvido a segunda parte do método de predição de crises epilépticas, tema da presente dissertação, que constitui-se de:

- Agrupamento das entradas provenientes dos arquivos de dados dos pacientes em grupos denominados *folds*, onde cada um desses *folds* recebe uma deter-

minada quantidade dessas entradas para as tarefas de treinamento e teste da rede neural utilizada, a WiSARD;

- Mapeamento dos valores dos arquivos textos contendo os dados dos pacientes, valores inteiros expressando a quantidade de bits "1" destes em binário, em números binários propriamente ditos;
- Predição da ocorrência de crise ou não, através da classificação das entradas, em uma das quatro classes existentes. Cada uma destas classes estará se referindo a uma possível situação do momento atual do paciente agregada a situação em que ele estará em um determinado espaço de tempo (*delta*) futuro.

#### **4.1.2.1 Agrupamento das Entradas dos Arquivos Textos de Dados em *Folds***

Dada a realização de um experimento, por exemplo a predição de crises do paciente nº 8900102, com Janela de Tempo de Observação igual à 3 segundos e Tempo de Predição de 15 segundos, o algoritmo acessa o arquivo de dados (*input*) correspondente, verifica a quantidade de entradas existente e a partir dessa informação cria os *fold*s a serem usados na rede. Estes *fold*s nada mais são do que conjuntos compostos pelos índices das entradas (posição das entradas no arquivo), que foram resultados da ação do algoritmo ao embaralhar e dividir tais índices de entradas em grupos distintos e de tamanho aproximado. Feito isto, durante o treino e teste da rede neural, as entradas de cada *fold* são acessadas de forma gradual pela aplicação, por motivos de gerenciamento de memória, e seus dados são então disponibilizados como entradas a serem usadas gradativamente na WiSARD.

#### **4.1.2.2 Mapeamento dos Valores dos Arquivos Textos de Dados em Números Binários**

A medida que uma entrada de um arquivo de *input* é recebida, seus dados (valores inteiros que expressam a quantidade de bits "1" que um número binário receberá) são então efetivamente mapeados para números binários. Esse mapeamento funciona de forma bastante simples, consistindo em formar números binários de 20 bits (valor escolhido como parâmetro de conversão), onde cada um destes números recebe a quantidade de bits "1" relativa ao seu valor oriundo do arquivo de *input*, sendo atribuído o valor "0" aos bits restantes. Pelo exemplo citado na Subseção 4.1.1.2, o dado que contém o valor 10, resulta no número binário **00000000001111111111**.

Após o mapeamento de todos os dados de uma entrada (conjunto de  $S$  *samples*), esta consistirá de um encadeamento de  $E$  números binários do tipo exemplificado anteriormente. Assim, o tamanho em bits de uma entrada será dado pela expressão

$J \times S \times E \times B$ , onde  $J$  é o tempo em segundos da Janela de Observação,  $S$  o número de *samples* que são coletadas em um segundo,  $E$  o total de eletrodos usados na gravação do registro de um paciente à qual a entrada em questão pertença, e  $B$  a quantidade de bits que cada número binário terá. Lembrando que uma entrada é uma cadeia de números binários.

#### 4.1.2.3 Predição de Crises Através da Classificação das Entradas

Estando as entradas já em formato binário, o treinamento ou teste (a depender do estágio em que a rede neural se encontre) é então realizado. Como o acesso aos arquivos é feito gradualmente, tanto a fase de treino, quanto a fase de teste, são também realizadas de modo gradual. Esta gradualidade é definida de acordo com a frequência com que os dados são acessados.

Na fase de treinamento da WiSARD, as entradas são enviadas aos seus respectivos discriminadores, para que estes possam "aprender" os padrões das classes que eles representam. Para a tarefa de predição de crises, do que trata a presente dissertação, foram definidas quatro classes. Cada uma dessas classes, como já dito, representa a situação do paciente no presente e a situação em que o paciente se encontrará, após decorrido um certo período de tempo.

A predição consiste na resposta obtida pela WiSARD, já treinada e testada, de uma nova entrada submetida à ela. Caso a resposta da WiSARD à esta nova entrada apresentada seja *nonIctal-nonIctal*, *ictal-ictal* ou *ictal-nonIctal*, nenhuma situação de ocorrência futura de crise epilética terá sido definida, já no caso da resposta ser *nonIctal-ictal*, uma crise terá sido predita. As classes e os seus significados são objeto da Tabela 4.1.

Em caso de empates na resposta da WiSARD, foi utilizado um mecanismo de desempate que se baseia no exame de todos os neurônios dos discriminadores responsáveis pela ocorrência do empate, ou seja, os discriminadores que tiveram a mesma medida de similaridade em relação à uma entrada apresentada, sendo esta medida a mais alta dentre todas as medidas de similaridade obtidas. Esse exame consiste em verificar o valor de saída dos neurônios desses discriminadores, sendo esses neurônios ordenados em ordem crescente de valor de saída, logo examinando os neurônios de mais baixo valor de saída de cada discriminador e assim sucessivamente até que o desempate ocorra. O discriminador responsável pelo neurônio com o maior valor de saída dentre os neurônios analisados irá rotular a entrada apresentada com a sua classe.

Situação do Presente	Situação Futura	CLASSE
<i>interictal</i> (não-crise)	<i>interictal</i> (não-crise)	<i>nonIctal-nonIctal</i>
<i>interictal</i> (não-crise)	<i>ictal</i> (crise)	<i>nonIctal-ictal</i>
<i>ictal</i> (crise)	<i>interictal</i> (não-crise)	<i>ictal-nonIctal</i>
<i>ictal</i> (crise)	<i>ictal</i> (crise)	<i>ictal-ictal</i>

Tabela 4.1: Classes do Problema de Predição de Crises Epilépticas

## 4.2 Considerações Gerais

A WiSARD implementada no presente trabalho não utilizou a técnica de *bleaching* [15], nem no sentido de se evitar um possível *overtraining* (treinamento excessivo e desnecessário da rede), nem como mecanismo para resolver possíveis empates durante a classificação dos padrões (entradas) submetidos à rede, já que estes não ocorreram em nenhum dos experimentos realizados, devido à natureza dos dados usados. Caso houvessem ocorrido empates, a proposta de desempate adotada neste trabalho foi a de examinar individualmente o valor de saída (número de escritas) de cada um dos neurônios dos discriminadores, em ordem crescente de valor de saída, ou seja, começando a comparação pelos neurônios de pior resposta de cada discriminador e seguindo sucessivamente até os neurônios de melhor resposta, enquanto o desempate não fosse resolvido. O desempate se daria pelo neurônio, dentre os comparados, que tivesse o maior número de escritas, sendo este a fornecer o rótulo de seu discriminador para a entrada que tenha provocado o empate na WiSARD.

Em relação à natureza dos dados, as leituras encefalográficas dos pacientes em um momento de crise (*ictal*) e de não-crise (*interictal* ou *non-ictal*) são bem distintos. Portanto se o problema a ser solucionado fosse apenas o de classificar os padrões referentes à essas situações, isto teria sido feito de maneira simples até, pois o grau de dificuldade que a WiSARD teria ao reconhecer esses padrões, tão distintos entre si, seria muito pequeno. No entanto, dado uma leitura encefalográfica atual, prever o que irá ocorrer em um instante futuro é uma tarefa bem mais complexa de se realizar, pois para isso seria necessário definir corretamente a fase *pre-ictal*, o momento que antecede a ocorrência de uma crise epiléptica.

Diante do que foi exposto, o que a aplicação que implementa o método preditor apresentado no presente Capítulo faz, é observar por um período determinado de tempo os dados de um paciente e verificar o que ocorre com este, após decorrido este período. Tenta-se desta forma, perceber o comportamento dos sinais (EEG [maioria], batimentos cardíacos, contrações musculares e movimentos oculares) desse paciente em diversos momentos distintos, para então ser capaz de compreender como os sinais dele se comportam em intervalos de tempo que precedam uma crise e como é o comportamento desses mesmos sinais em períodos de não-crise, chamado pelos

especialistas de período *interictal*. Assim, com parâmetros apropriados de tempo de observação e tempo de predição, a WiSARD, por sua capacidade de generalização e reconhecimento de padrões, mostrou-se capaz de prever, com um bom percentual de acerto, a manifestação ou não de crises epiléticas para os pacientes testados, em instante de tempo futuro à observação dos seus dados.

# Capítulo 5

## Base Experimental, Resultados e Análise

O presente Capítulo abordará em detalhes a base de dados usada nos experimentos desta dissertação, as especificidades clínicas de cada paciente que compõe esta referida base de dados, o balanceamento das amostras (entradas) de cada classe por experimento, os resultados obtidos e a análise dos mesmos.

### 5.1 Base Experimental

A base de dados, como mencionado na Seção 2.5, foi o banco de dados EPILEPSIAE. Para ser mais preciso, uma amostra desse banco de dados perfazendo o total de quatro sub-conjuntos de dados, referentes a quatro pacientes distintos, portadores de epilepsia. Obviamente, os pacientes são identificados por um código, visando manter sob sigilo a identidade dos mesmos.

#### 5.1.1 Características dos Sub-Conjuntos de Dados

Os pacientes cujos dados clínicos serviram como fonte para a criação do banco de dados EPILEPSIAE e, conseqüentemente, como base de dados para os experimentos desta dissertação, tem em comum o fato de sofrerem de alguma forma de epilepsia. No entanto, os pacientes apresentaram formas variadas de crises epilépticas durante a gravação dos seus sinais clínicos, sendo que essas crises se diferenciaram uma das outras pelos locais de origem das descargas elétricas cerebrais anormais que as causaram e pelas demais áreas do cérebro que foram posteriormente afetadas por essas descargas. Houve também uma investigação preliminar sobre a frequência e o tipo de crises epilépticas sofridas por esses pacientes, durante o período de seis meses antes do início da gravação dos dados de cada um deles.

Além dos registros obtidos com as gravações de cada paciente, outras características foram igualmente armazenadas para fins de se entender melhor o tipo de epilepsia desses indivíduos. Tais características foram a quantidade e a localização das lesões que estes possuem no tecido cerebral e o estado de vigília em que eles se encontravam no momento do início de suas crises epiléticas, sendo que estes dados serviram como elementos que ajudaram a entender melhor o tipo de epilepsia de cada um deles. A seguir, informações personalizadas sobre os pacientes que foram usados como base de dados dos experimentos desta dissertação.

#### 5.1.1.1 Paciente N° 100102

O paciente número 100102, sexo masculino e 13 anos de idade, possui dois focos epiléticos em seu cérebro, sendo que o mais significativo foco está localizado no sulco central do cérebro, no hemisfério esquerdo, enquanto o outro foco se encontra no lobo parietal, no hemisfério direito. O tipo de crise epilética que acometeu este paciente durante a fase de pesquisa que antecedeu à gravação de seus sinais clínicos foi a Crise Parcial Complexa, com uma frequência de 6 crises por mês. A etiologia da epilepsia aponta para a má-formação de seu cérebro como fator causador desse mal.

Foram usados 29 eletrodos durante a gravação dos sinais clínicos e o paciente manifestou 11 crises epiléticas nesse período, sendo 8 do tipo Parcial Complexa, 1 Crise Parcial Secundariamente Generalizada e 2 Crises do tipo Não-Classificáveis. A Tabela 5.1 mostra o resultado da avaliação cognitiva do paciente em questão.

<b>Função Cognitiva</b>	<b>Resultado</b>
Data da Avaliação	08/10/2002
Atenção	Acima da Média
Memória Declarativa Verbal	Muito Abaixo da Média
Memória Declarativa Não-Verbal	Abaixo da Média
Linguagem	Acima da Média
Funções Visuo-Espaciais	Acima da Média

Tabela 5.1: Avaliação Cognitiva do Paciente N° 100102

#### 5.1.1.2 Paciente N° 11000102

O paciente número 11000102, sexo masculino e 21 anos de idade, possui apenas um foco epilético localizado em seu lobo temporal, no hemisfério esquerdo de seu cérebro. Durante a fase de pesquisa, o paciente apresentou crises epiléticas do tipo parcial, simples e complexa, com uma frequência mensal de 9 crises parciais

complexas e 1 crise parcial simples, em um período de 6 meses. Sobre a epilepsia deste paciente, sua etiologia indica a presença de esclerose hipocampal e meningite bacteriana aos 3 meses de idade.

Foram usados 29 eletrodos durante a gravação dos sinais clínicos, tendo o paciente apresentado 4 Crises Parciais Complexas, 2 Crises Parciais Simples e 2 Crises Não-Classificáveis, perfazendo um total de 8 crises sofridas. A Tabela 5.2 exibe o resultado da avaliação cognitiva do paciente nº 11000102, respectivamente.

<b>Função Cognitiva</b>	<b>Resultado</b>
Data da Avaliação	22/05/2003
Atenção	Acima da Média
Memória Declarativa Verbal	Acima da Média
Memória Declarativa Não-Verbal	-
Linguagem	Acima da Média
Funções Visuo-Espaciais	Acima da Média

Tabela 5.2: Avaliação Cognitiva do Paciente Nº 11000102

#### 5.1.1.3 Paciente Nº 7300102

O paciente número 7300102, sexo feminino e 1 ano de idade, possui três focos epiléticos, um foco no lobo frontal na parte referente ao hemisfério esquerdo e os demais no lobo temporal em sua porção relativa ao hemisfério direito. O paciente apresentou apenas um tipo de crise epilética, a Crise Parcial Simples, com uma frequência de 3 crises ao mês, durante a fase de pesquisa. Em termos de etiologia da epilepsia deste paciente, cite-se a questão da presença de inflamação dos tecidos cerebrais.

Foram usados 29 eletrodos durante a gravação dos sinais clínicos e o paciente sofreu 8 crises durante essa fase, sendo 6 do tipo Parcial Simples, 1 Parcial Secundariamente Generalizada e 1 do tipo Não-Classificável. A Tabela 5.3 mostra o resultado de sua avaliação cognitiva.

#### 5.1.1.4 Paciente Nº 8900102

O paciente número 8900102, sexo feminino e 23 anos de idade, possui um único foco epilético, localizado no lobo temporal, no hemisfério esquerdo do seu cérebro. Com uma frequência de 2 crises ao mês durante a fase de pesquisa que precedeu à



<b>Função Cognitiva</b>	<b>Resultado</b>
Data da Avaliação	26/03/2003
Atenção	Abaixo da Média
Memória Declarativa Verbal	Na Média
Memória Declarativa Não-Verbal	Muito Abaixo da Média
Linguagem	Acima da Média
Funções Visuo-Espaciais	Abaixo da Média

Tabela 5.3: Avaliação Cognitiva do Paciente N° 7300102

gravação de seus sinais clínicos, o tipo de crise epiléptica que acometeu este paciente foi a Crise Parcial Complexa. A etiologia da epilepsia indica a existência de epilepsia criptogênica, que é definida como uma epilepsia de natureza presumidamente sintomática na qual a causa não tenha sido identificada.

Foram usados 27 eletrodos durante a gravação dos sinais clínicos. 5 crises acometeram este paciente, sendo 4 do tipo Parcial Complexa e 1 do tipo Não-Classificável. A Tabela 5.4 mostra o resultado da avaliação cognitiva do paciente em questão.

<b>Função Cognitiva</b>	<b>Resultado</b>
Data da Avaliação	07/05/2003
Atenção	Na Média
Memória Declarativa Verbal	Acima da Média
Memória Declarativa Não-Verbal	Abaixo da Média
Linguagem	Abaixo da Média
Funções Visuo-Espaciais	-

Tabela 5.4: Avaliação Cognitiva do Paciente N° 8900102

### 5.1.2 Balanceamento das Entradas por Classe

A duração das crises dos pacientes que serviram como base de dados da metodologia de predição de crises epilépticas, objeto da presente dissertação de Mestrado, girou em torno de 1 à 2 segundos na maior parte dos casos. Para exemplificar como foi feita a coleta das entradas, tomemos como exemplo uma crise epiléptica sofrida pelo paciente n° 100102 e que teve início na *sample* de número 675248 e término na *sample* 689365. Relembrando que a gravação dos pacientes é dividida em blocos (cada bloco gera um arquivo em formato binário plano), sendo cada um destes blocos composto por *samples*. *Sample* é o período de tempo correspondente à uma leitura dos eletrodos (em 1 segundo são lidas 265 *samples*).

No caso da crise epiléptica citada como exemplo, o seu tempo de duração de 14118 *samples* corresponde ao número de *samples* observadas enquanto o paciente estava em crise. De maneira análoga e objetivando visualizar um espaço equitativo de *samples* em períodos tanto de crise como de não-crise, foi observado o mesmo número de *samples* para ambas as situações do paciente, considerando períodos que antecederam e sucederam a crise (7059 *samples* para ambos os casos). Assim, o intervalo de tempo a ser usado para coleta das entradas (amostras) iniciou-se na *sample* 668190 e teve o seu término na *sample* 696423, com *samples* referentes a períodos de crise e de períodos de não-crise anteriores e posteriores à essa crise sofrida pelo paciente. A Figura 5.1 detalha esse intervalo de coleta de entradas.




Figura 5.1: Intervalo de Coletas de Entradas

Porém, mesmo com a preocupação em se observar um intervalo de tempo igual em termos do estado do paciente (crise e não-crise), a quantidade de entradas coletadas apresentou distorções em relação ao total de entradas obtidas para cada uma das classes deste trabalho. Os números de entradas das classes *nonIctal-ictal* e *ictal-nonIctal* foram bem menores, se comparados aos números de entradas das classes *nonIctal-nonIctal* e *ictal-ictal*. Isto ocorreu, porque o tempo de transição de uma situação de não-crise para crise (e vice-versa) é bem inferior ao tempo em que o paciente se encontra em uma situação não transitória, ou seja, quando a situação em que ele se encontra em um determinado momento se manterá inalterada após decorrido um certo período de tempo (*delta*). A Figura 5.2 retrata essa situação.




Figura 5.2: Situações Transitórias e Não-Transitórias no Intervalo de Coleta

Para evitar que esse desbalanceamento no número de entradas por classe, conhecido como *Class Imbalance* [18], e o consequente uso de um conjunto de entradas não balanceadas (predominância de entradas de uma ou mais classes em detrimento de outras) afetasse o desempenho da WiSARD, prejudicando a sua capacidade de reconhecimento das classes com menos entradas, foi adotada a estratégia de *under-sampling* [18]. Essa estratégia consiste em usar um número igual de entradas para cada classe nas fases de treinamento e testes de uma rede neural, reduzindo o número de entradas das classes com mais entradas ao mesmo número de entradas da classe com menor número. As classes *nonIctal-ictal* e *ictal-nonIctal* possuíam menos entradas, por serem classes de transição de uma situação para outra (não-crise para crise e crise para não-crise), e pelo fato desses momentos de transição serem invariavelmente menores do que os momentos de estabilidade (crise para crise e não-crise para não-crise).

## 5.2 Resultados

Os resultados obtidos com a realização dos experimentos dessa dissertação serão apresentados nesta Seção. Os resultados globais representam a acurácia da WiSARD em reconhecer entradas de todas as quatro classes (*nonIctal-nonIctal*, *nonIctal-ictal*, *ictal-ictal* e *ictal-nonIctal*). Além desses resultados, serão também expostos os resultados da classe de maior interesse, de acordo com o propósito do presente trabalho, a classe *nonIctal-ictal*, pois essa classe representa a situação em que o paciente não está em crise, mas será acometido por uma crise em um instante de tempo futuro.

### 5.2.1 Resultados Globais

Os resultados globais indicam que a WiSARD conseguiu reconhecer de maneira satisfatória as entradas das classes submetidas à ela, em todos as configurações dos experimentos realizados. Por configurações entenda-se os valores dos parâmetros referentes à duração do tempo de observação dos sinais do paciente (Janela de Tempo de Observação) e com que antecedência de tempo seriam previstos a ocorrência ou não-ocorrência de uma crise epiléptica (Intervalo de Predição). A concatenação desses dois parâmetros define o tipo de experimento realizado.

Os testes dos pacientes nº 11000102 e 8900102 apresentaram uma pequena melhora na acurácia das respostas da rede neural, à medida que o parâmetro Intervalo de Predição crescia. Enquanto que os testes dos pacientes nº 100102 e 7300102 apresentaram uma estabilidade no grau de acurácia das respostas, com pequenas variações, independentemente do valor deste parâmetro. Apenas estes dois últimos pacientes apresentaram crises do tipo Parcial Secundariamente Generalizada.

As tabelas a seguir mostram os valores dos resultados dos testes realizados em cada um dos pacientes, referentes às métricas de acurácia da resposta (média de acertos), desvio padrão (foi utilizado o *crossvalidation* na aferição dos resultados) e grau de confiança dos testes. Os valores de **Delta** estão expressos em segundos.

Delta	Acurácia	Desvio Padrão	Grau de Confiança
2	91.0163%	0.372	0.0144
3	89.7141%	0.4968	0.0129
4	89.6334%	0.567	0.01055
5	89.0566%	0.4062	0.0092
6	93.2123%	0.1896	0.0126
7	92.3369%	0.2598	0.0217
8	92.0059%	0.3009	0.0236
9	91.6991%	0.3225	0.0301
10	91.2719%	0.2264	0.035
15	90.014%	0.3517	0.0443
20	89.6169%	0.2238	0.0388
25	89.7511%	0.2766	0.0176
30	90.9338%	0.1794	0.0158

Tabela 5.5: Resultados do Paciente Nº 100102 - Todas as Classes - *Input*= 2 Segundos

<b>Delta</b>	<b>Acurácia</b>	<b>Desvio Padrão</b>	<b>Grau de Confiança</b>
2	91.0806%	0.3684	0.0105
3	90.5260%	0.4125	0.0086
4	90.7247%	0.4285	0.0056
5	90.4237%	0.4897	0.0062
10	88.3023%	0.2774	0.0274
20	86.718%	0.238	0.0310
30	87.2157%	0.2207	0.0237

Tabela 5.6: Resultados do Paciente N° 100102 - Todas as Classes - *Input*= 3 Segundos

<b>Delta</b>	<b>Acurácia</b>	<b>Desvio Padrão</b>	<b>Grau de Confiança</b>
2	94.1568%	0.4999	0.0146
3	94.7524%	0.2543	0.0168
4	95.0708%	0.3480	0.0103
5	95.8939%	0.2280	0.0089
6	96.1753%	0.2608	0.0046
7	96.4084%	0.2457	0.0035
8	96.4195%	0.1581	0.0024
9	96.6326%	0.2025	0.0007
10	96.8278%	0.1918	0.0015
15	97.3451%	0.1513	0.0104
20	97.7029%	0.1292	0.0153
25	97.3226%	0.1821	0.0153
30	97.01%	0.1616	0.0255

Tabela 5.7: Resultados do Paciente N° 11000102 - Todas as Classes - *Input*= 2 Segundos

<b>Delta</b>	<b>Acurácia</b>	<b>Desvio Padrão</b>	<b>Grau de Confiança</b>
2	96.1242%	0.5204	0.0035
3	95.9696%	0.3183	0.0101
4	97.3664%	0.2535	0.0097
5	96.5566%	0.223	0.0036
10	99.0519%	0.1242	0.0025
20	98.2866%	0.0929	0.0078
30	97.4311%	0.0910	0.0147

Tabela 5.8: Resultados do Paciente N° 11000102 - Todas as Classes - *Input*= 3 Segundos

<b>Delta</b>	<b>Acurácia</b>	<b>Desvio Padrão</b>	<b>Grau de Confiança</b>
2	95.5542%	0.3155	0.0057
3	95.4599%	0.4645	0.0024
4	94.9705%	0.3822	0.0022
5	95.3774%	0.3552	0.0002
6	95.245%	0.2962	0.0025
7	94.6783%	0.2514	0.0147
8	94.3390%	0.2542	0.0164
9	94.047%	0.3781	0.0275
10	93.3187%	0.3208	0.0495
15	94.3197%	0.2603	0.0439
20	94.8105%	0.2711	0.0507
25	95.7704%	0.2432	0.0181
30	95.7475%	0.2368	0.0072

Tabela 5.9: Resultados do Paciente N° 7300102 -Todas as Classes - *Input*= 2 Segundos

<b>Delta</b>	<b>Acurácia</b>	<b>Desvio Padrão</b>	<b>Grau de Confiança</b>
2	95.7783%	0.8422	0.0106
3	95.9002%	0.3467	0.0037
4	95.8933%	0.5264	0.0038
5	95.5510%	0.8048	0.0078
10	93.6768%	0.2526	0.0591
20	95.4681%	0.2831	0.0523
30	96.2760%	0.2714	0.0074

Tabela 5.10: Resultados do Paciente N° 7300102 -Todas as Classes - *Input= 3* Segundos

<b>Delta</b>	<b>Acurácia</b>	<b>Desvio Padrão</b>	<b>Grau de Confiança</b>
2	94.2925%	0.6674	0.0008
3	95.2767%	0.5769	0.0018
4	95.9717%	0.6078	0.0021
5	96.6717%	0.2072	0.0080
6	97.0314%	0.2981	0.0081
7	96.9137%	0.343	0.008
8	97.4410%	0.2456	0.0047
9	97.7317%	0.2506	0.0034
10	97.9151%	0.2946	0.0022
15	97.5987%	0.2839	0.0011
20	98.1208%	0.244	0.0002
25	98.3057%	0.2247	0.0002
30	98.4610%	0.1252	0.0005

Tabela 5.11: Resultados do Paciente N° 8900102 - Todas as Classes - *Input= 2* Segundos

Delta	Acurácia	Desvio Padrão	Grau de Confiança
2	94.6887%	0.5661	0.0023
3	95.8113%	0.4590	0.0018
4	96.7547%	0.3749	0.0051
5	97.0264%	0.4019	0.0116
10	98.2566%	0.1526	0.0026
20	98.5153%	0.2953	0.01
30	98.8057%	0.0925	0.0001

Tabela 5.12: Resultados do Paciente N° 8900102 - Todas as Classes - *Input*= 3 Segundos

### 5.2.2 Resultados da Classe de Maior Interesse: *NonIctal-Ictal*

Os resultados relativos à classe *nonIctal-ictal* indicam que a WiSARD conseguiu reconhecer as entradas referentes à essa classe, com um nível de acurácia que variou dependendo do parâmetro Intervalo de Predição adotado. A acurácia dos resultados do experimento foi piorando à medida que o intervalo de predição aumentava. Quanto maior a antecedência de tempo para a previsão de uma ocorrência ou não, de uma crise epiléptica, maior foram os erros de classificação das entradas dessa classe pela rede neural.

Os testes dos pacientes n° 100102 e 7300102, pacientes com o maior número de crises (11 e 10, respectivamente) e os únicos que desenvolveram crises do tipo Parcial Secundariamente Generalizada, mostraram uma queda maior na qualidade das respostas da WiSARD, conforme se aumentava o valor do parâmetro Intervalo de Predição, principalmente no caso do paciente n° 100102. Enquanto que nos testes dos pacientes n° 11000102 e 8900102, esse declínio na acurácia das respostas foi menor. Esses dois últimos pacientes manifestaram menos crises durante o registro de seus dados (8 e 5, respectivamente), se comparados aos demais pacientes (n° 100102 e 7300102).

As tabelas a seguir mostram os valores dos resultados dos testes realizados em cada um dos pacientes, referentes às métricas de acurácia da resposta (média de



acertos), considerando apenas as entradas da classe *nonIctal-ictal*. Os valores de **Delta** estão expressos em segundos.

<b>Delta</b>	<b>Acurácia</b>
2	88.4391%
3	82.0583%
4	80.3259%
5	77.6535%
6	84.5346%
7	81.8383%
8	80.5802%
9	78.8586%
10	77.6204%
15	72.5846%
20	69.0417%
25	66.7843%
30	67.7123%

Tabela 5.13: Resultados do Paciente N° 100102 - Classe *nonIctal-ictal* - *Input*= 2 Segundos

<b>Delta</b>	<b>Acurácia</b>
2	88.5935%
3	82.8473%
4	82.0412%
5	79.9039%
10	70.7927%
20	61.1466%
30	57.6488%

Tabela 5.14: Resultados do Paciente N° 100102 - Classe *nonIctal-ictal* - *Input*= 3 Segundos

<b>Delta</b>	<b>Acurácia</b>
2	98.4906%
3	97.8616%
4	97.6061%
5	97.4811%
6	97.2327%
7	96.7318%
8	96.1498%
9	95.4088%
10	95.1462%
15	94.7013%
20	94.8845%
25	94.9162%
30	94.1260%

Tabela 5.15: Resultados do Paciente N° 11000102 - Classe *nonIctal-ictal* - *Input=* 2 Segundos

<b>Delta</b>	<b>Acurácia</b>
2	99.6541%
3	98.9518%
4	99.0094%
5	98.5094%
10	98.3774%
20	95.9481%
30	94.4181%

Tabela 5.16: Resultados do Paciente N° 11000102 - Classe *nonIctal-ictal* - *Input=* 3 Segundos

<b>Delta</b>	<b>Acurácia</b>
2	99.8585%
3	98.9308%
4	97.5354%
5	97.8679%
6	98.3779%
7	96.9153%
8	96.983%
9	96.0193%
10	93.9881%
15	94.4871%
20	93.4446%
25	92.7328%
30	89.6129%

Tabela 5.17: Resultados do Paciente N° 7300102 - Classe *nonIctal-ictal* - *Input= 2* Segundos

<b>Delta</b>	<b>Acurácia</b>
2	99.9057%
3	98.978%
4	98.4788%
5	97.7534%
10	93.3881%
20	93.8416%
30	90.1840%

Tabela 5.18: Resultados do Paciente N° 7300102 - Classe *nonIctal-ictal* - *Input= 3* Segundos

<b>Delta</b>	<b>Acurácia</b>
2	99.9245%
3	99.8239%
4	99.7925%
5	99.1849%
6	98.4403%
7	96.8086%
8	97.3208%
9	97.8784%
10	96.9887%
15	93.5547%
20	94.7962%
25	94.7985%
30	95.4491%

Tabela 5.19: Resultados do Paciente N° 8900102 - Classe *nonIctal-ictal* - *Input= 2* Segundos

<b>Delta</b>	<b>Acurácia</b>
2	99.7736%
3	99.8239%
4	99.4717%
5	98.8226%
10	96.3774%
20	95.3054%
30	96.078%

Tabela 5.20: Resultados do Paciente N° 8900102 - Classe *nonIctal-ictal* - *Input= 3* Segundos

## 5.3 Análise dos Resultados

Nesta Seção será feita uma sucinta análise sobre os resultados dos experimentos realizados, correlacionando-os com as diversas configurações utilizadas dos parâmetros Janela de Tempo de Observação e Intervalo de Predição.

### 5.3.1 Relação dos Resultados com o Parâmetro Janela de Tempo de Observação

O valor do parâmetro Janela de Tempo de Observação significa por quanto tempo foram observados os dados provenientes do registro dos sinais (EEG, batimentos cardíacos, contração muscular, movimentos oculares) dos pacientes. Foram utilizados dois valores para esse parâmetro nos experimentos do presente trabalho, 2 e 3 segundos. A Janela de Tempo de Observação inicialmente usada foi a de 2 segundos.

A configuração da Janela de Tempo de Observação em 2 segundos foi utilizada para diversos valores de *delta* (Intervalo de Predição), a saber: 2, 3, 4, 5, 6, 7, 8, 9, 10, 15, 20, 25 e 30 segundos. Após realizados esses primeiros experimentos, o parâmetro Janela de Tempo de Observação foi alterado para 3 segundos, numa tentativa de verificar se haveria alguma melhora na acurácia das respostas a partir de um tempo de observação de dados maior, tendo sido escolhidos os valores mais interessantes de *delta* (Intervalo de Predição) para serem testados com essa nova Janela de 3 segundos (*delta* = 2, 3, 4, 5, 10, 20 e 30 segundos). Não houve nenhuma alteração significativa nos resultados dos experimentos com o uso da Janela de Tempo de Observação de 2 ou 3 segundos.

A análise dessa inalteração dos resultados dos experimentos, nos faz crer que a tarefa de predição de crises está intimamente ligada com a questão da identificação do comportamento das descargas neuronais desordenadas de um paciente com epilepsia em momentos que antecedem uma crise, ou seja, na identificação do seu período pré-ictal. Assim, o período de observação que antecede uma crise deverá ser limitado a esse período de pré-crise epiléptica, sendo desnecessário observar o comportamento da atividade neuronal do paciente por mais tempo do que isso. Portanto, pode-se assumir que o tempo pré-ictal dos pacientes que serviram como base de dados do presente trabalho estava compreendido dentro da faixa de 2 ou menos segundos anteriores às manifestações das crises, e que por isso, os resultados dos experimentos com 3 segundos de Janela de Tempo de Observação não apresentaram alterações relevantes em relação aos resultados obtidos com a Janela de Tempo de Observação de 2 segundos, pois as descargas observadas além dos 2 segundos anteriores ao início de uma crise não correspondiam ao período pré-ictal e sim ao período interictal, período este onde as descargas neuronais são consideradas normais. Dessa forma,

pode-se deduzir que observar os dados dos pacientes além do período pré-ictal não acarretará em melhora na qualidade das entradas a serem analisadas pelo método preditor de crises desta dissertação.

### 5.3.2 Relação dos Resultados com o Parâmetro Intervalo de Predição

Diversas tentativas de predição de crises foram testadas com o método apresentado neste trabalho, tendo o parâmetro relativo à antecedência com a qual o método seria capaz de prever uma crise, recebido o nome de *delta*, como já foi diversas vezes exposto ao longo desta dissertação. Os valores de *delta* testados foram de 2, 3, 4, 5, 6, 7, 8, 9, 10, 15, 20 e 30 segundos, a partir de um tempo de observação dos dados de 2 segundos, enquanto que os valores de *delta* iguais à 2, 3, 4, 5, 10, 20 e 30 segundos foram novamente testados, porém com um tempo de observação maior (3 segundos). Dado os resultados obtidos nos experimentos feitos, constatou-se que quanto maior antecedência for feita uma tentativa de predição de uma crise, menor será a acurácia nas respostas oriundas do método preditor, objeto deste trabalho. Método este, cuja tarefa de predição é feita por uma rede neural sem peso WiSARD.

Os pacientes nº 100102 e 7300102, os únicos com manifestação de crises do tipo Parcial Secundariamente Generalizada, e também os que mais desenvolveram crises (11 e 10, respectivamente) durante os registros dos dados feito pelo projeto EPILEP-SIAE, apresentaram um declínio maior na média de acertos durante os experimentos feitos, conforme o parâmetro Intervalo de Tempo de Predição aumentava. Os experimentos com os dados dos pacientes nº 11000102 e 8900102 também tiveram sua acurácia diminuída nessa mesma situação, porém a queda de acurácia ocorrida foi em menor grau. A conclusão a que se chega é de que quanto maior a heterogeneidade de tipos de crises manifestas por um paciente, menor será a acurácia das respostas da WiSARD, principalmente em intervalos de predição maiores.

### 5.3.3 Avaliação dos Resultados dos Experimentos

A avaliação geral que se faz dos testes realizados com os dados dos pacientes, em suas diversas configurações de Janela de Tempo de Observação e Intervalo de Predição, é que independentemente da duração de 2 ou 3 segundos do tempo de observação dos dados, o que realmente altera a acurácia da predição de crises é a quantidade de tempo com que se deseja prevê-las. Sendo que quanto menor for esse intervalo de predição, maior será o percentual de acertos da WiSARD, arquitetura de rede neural que é a base do Método Preditor desta dissertação, em realizar essas previsões de ocorrência de crises epilépticas a partir da análise das informações provenientes do exame EEG (acrescido de sinais de batimentos cardíacos, musculares

e oculares). Esse fato, provavelmente nos transmite a ideia de que dado uma menor proximidade da janela de observação ao início de uma crise epiléptica, menor será a diferença entre leituras que antecedam um período ictal ou não, ou seja, ambas as leituras terão comportamento elétrico neuronal semelhantes.

O paciente cujos experimentos apresentaram acurácia menor em relação aos demais foi o paciente nº 100102. A conclusão para esse fato, pode ser as características das crises que esse paciente sofreu, já que em nenhuma das ocasiões este paciente manifestou o tipo mais simples de crise: Crise Parcial Simples, tendo apresentado Crises Parciais Complexas (8), Crises Parciais Secundariamente Generalizadas (2) e uma crise do tipo Não-Classificável. Logo, crises onde a atividade neuronal apresenta um maior comportamento desordenado.

Os gráficos abaixo (Figuras 5.7 e 5.8, paciente nº 100102; Figuras 5.9 e 5.10, paciente nº 7300102; Figuras 5.11 e 5.12, paciente nº 7300102; Figuras 5.13 e 5.14, paciente nº 8900102) demonstram de forma geral, os resultados dos experimentos feitos com Janela de Tempo de Observação de 2 e 3 segundos para cada paciente, e como esses resultados se comportam ao longo da variação do Intervalo de Tempo de Predição.




Figura 5.3: Resultados - Paciente Nº 100102 - *Input*=2 Segundos




Figura 5.4: Resultados- Paciente N° 100102 - *Input*=3 Segundos

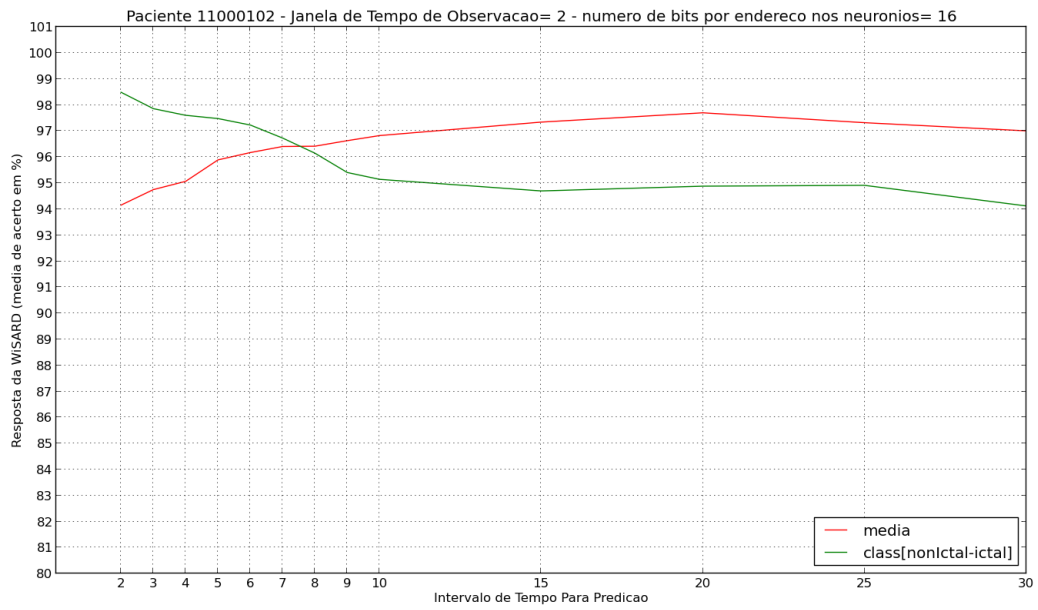


Figura 5.5: Resultados - Paciente N° 11000102 - *Input*=2 Segundos



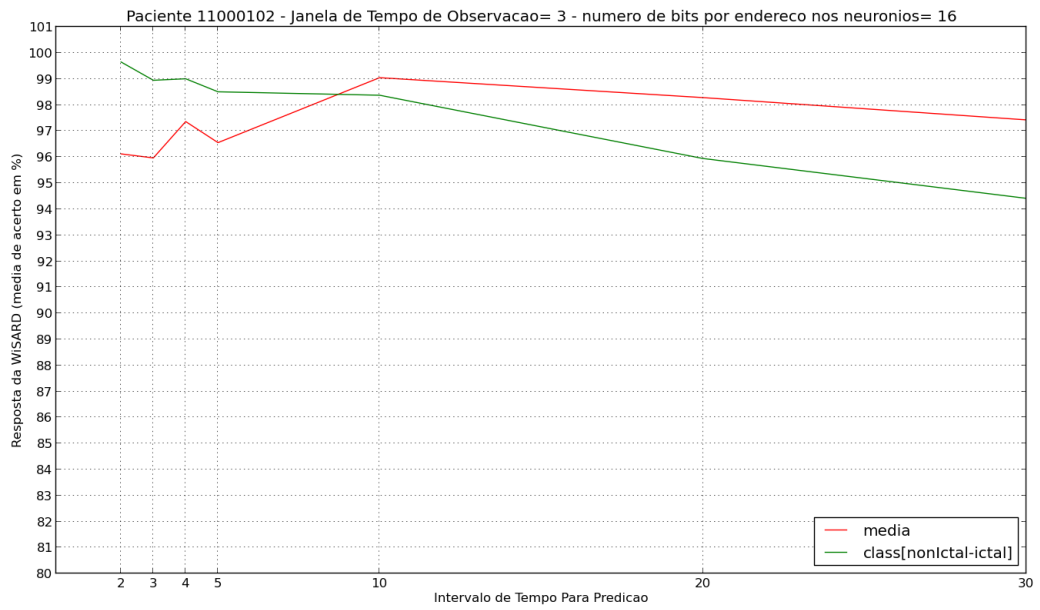


Figura 5.6: Resultados - Paciente N° 11000102 - *Input*=3 Segundos




Figura 5.7: Resultados - Paciente N° 7300102 - *Input*=2 Segundos




Figura 5.8: Resultados - Paciente N° 7300102 - *Input*=3 Segundos




Figura 5.9: Resultados - Paciente N° 8900102 - *Input*=2 Segundos




Figura 5.10: Resultados - Paciente N° 8900102 - *Input*=3 Segundos

# Capítulo 6

## Conclusões

Esta Seção apresenta um resumo analítico sobre o trabalho apresentado, uma breve discussão sobre os pontos mais relevantes e propostas para trabalhos futuros relacionados ao Método Preditor implementado para a tarefa de predição de crises epiléticas.

### 6.1 Resumo

A proposta do presente trabalho foi a de utilizar dados de registros eletroencefalográficos (maior fonte de dados) , acrescidos de registros de batimentos cardíacos, de movimentos oculares e musculares, para a tentativa de caracterizar padrões neuronais provenientes dessas fontes (eletrodos) que pudessem representar , e dessa forma prever, a ocorrência de crises epiléticas com uma certa antecedência de tempo. Esperava-se que as descargas elétricas cerebrais de momentos anteriores à uma crise epilética tivessem comportamento diferente daquelas que não antecedessem à uma crise e assim, a identificação de uma crise eminente seria possível. Essa abordagem baseou-se no fato de que como uma crise epilética é fruto de descargas neuronais desordenadas, descargas neuronais anteriores à uma crise também pudessem ter algum grau de desordem ou pelo menos, dessemelhança em relação à descargas neuronais interictais.

A respeito do eletroencefalograma (EEG), o seu uso para se estabelecer um prognóstico da ocorrência de crises é controverso, pelo motivo do EEG se tratar de um exame funcional e por isso, capaz apenas de perceber alterações nos padrões elétricos cerebrais de forma correlacionada com a etiologia da doença, e com fatores como a idade do paciente e a frequência das crises. Entretanto, esse exame ainda assim é uma excelente forma de obtenção das alterações nas descargas elétricas do cérebro responsáveis por desencadear as crises epiléticas. Tal característica fez do EEG o maior provedor dos sinais clínicos oriundos do banco de dados EPILEPSIAE [5], base de dados utilizada pelo Método Preditor desta dissertação de Mestrado.

A opção pelo tipo de arquitetura de rede neural levou em consideração a necessidade de rapidez, tanto no processamento dos dados para treinamento, quanto na classificação dos padrões submetidos à rede, e por essas serem características intrínsecas da WiSARD, esse modelo neural sem peso foi o escolhido. Tal necessidade originou-se do paradigma adotado em lidar com os dados estáticos da base de dados, como se eles estivessem sendo submetidos à rede em tempo real, como em uma série temporal. Tal decisão foi feita já visando treinar a rede para situações de implementação real dos algoritmos que compõem o mecanismo de predição aqui desenvolvidos, logo, uma rede com excelente acurácia, mas com a restrição de lidar apenas com dados estáticos, não seria interessante.

A WiSARD mostrou-se eficiente em reconhecer os padrões das diferentes classes de situações (presentes e futuras) abordadas nesse trabalho. Tais situações foram o momento de não-criese que levaria a manutenção do estado presente em um instante futuro (classe *nonIctal-nonIctal*); a incidência de crise epilética, após um certo período de tempo (classe *nonIctal-ictal*) ou a situação de crise que futuramente se normalizará ou não (classes *ictal-nonIctal* e *ictal-ictal*, respectivamente). O padrão um pouco menos facilmente reconhecido foi justamente o padrão de maior interesse, a classe *nonIctal-ictal*, por motivos óbvios, ou seja, pela alteração dos valores das leituras das descargas elétricas neuronais em instantes anteriores à uma crise ser sutil, especialmente quando se tenta prevê-la com uma antecendência razoável de tempo.

Em termos de pré-processamento dos dados crus originais obtidos junto ao EPILEPSIAE, o mapeamento usado pelo Método Preditor visou reduzir o espaço amostral desses dados, sem comprometer a dessemelhança entre leituras de crise e não-criese. Para tal, o método aplica uma função logarítmica associada ao método de conversão binária do "termômetro" sobre os dados. Essa abordagem mostrou-se eficiente no cumprimento desse propósito.

Considerando a complexidade da tarefa de predição de crises epiléticas, devido à ampla variedade das classes de epilepsia e do caráter heterogêneo dos tipos de crises epiléticas, o trabalho aqui apresentado mostrou ser capaz de prever futuras crises com um nível relativamente alto de acurácia e confiabilidade, para o universo de pacientes testados, universo este composto por dados acerca de quatro pacientes epiléticos. Porém o tempo de antecendência foi da ordem de poucos segundos, ou seja, um intervalo de predição reduzido.

## 6.2 Discussão

Na Seção 3.2.4 discorremos sobre o *bleaching* e de como esse mecanismo é eficiente para solucionar o problema de *overtraining* (treinamento excessivo da rede

neural). O conceito de *bleaching* está latente no critério de desempate entre discriminadores com medidas de similaridade iguais (fase de teste da WiSARD) utilizado no método preditor desse trabalho. O quão eficiente esse mecanismo de desempate é na realidade, ainda carece de uma avaliação mais profunda, preferencialmente utilizando-o na classificação e reconhecimento de entradas de outras naturezas, já que no reconhecimento de padrões do presente trabalho não ocorreram empates.

Outro ponto a ser aqui discutido é a questão do tamanho ótimo em segundos da Janela de Tempo de Observação. Por questões de gerenciamento e limitação de memória disponível, foram utilizados os valores de 2 e 3 segundos, tendo ficado a dúvida se havendo um aumento no tamanho da janela, haveria uma melhora na acurácia da WiSARD, partindo da premissa de que com um tempo de observação mais longo, e que possivelmente contivesse toda a fase pré-ictal, as variações no comportamento das descargas elétricas cerebrais de um paciente epilético poderiam ser melhor percebidas. Talvez um tempo de observação nessas condições possa permitir que a previsão de crises epiléticas seja feita com uma antecedência de tempo maior, do que o tempo máximo experimentado nesta dissertação (30 segundos).

Como exposto na Seção 4.1.2.2, o tamanho de uma entrada submetida à WiSARD era dado pelo tamanho da Janela de Tempo de Observação vezes a taxa de *samples* lidas por segundo pelos eletrodos, vezes a quantidade de atributos (eletrodos) usados no registro dos sinais clínicos do paciente, multiplicado pela quantidade de bits usados na codificação dos valores inteiros para binários. Logo, para um aumento do tempo de observação sem que este cause um aumento no gasto de memória, seria necessário diminuir a quantidade de atributos das *samples*, descartando os que contribuem menos significativamente para a tarefa de reconhecimento de padrões. Ou então, diminuir a quantidade de bits utilizada para a codificação dos valores provenientes dos atributos menos significativos.

Outra questão seria, de alguma forma, tentar melhorar a qualidade dos dados usados como entradas para a rede neural. Tal tentativa poderia se dar através da identificação dos ruídos presentes nesses dados, que em sua grande maioria são obtidos com o recurso do exame de eletroencefalografia(EEG). Uma vez identificados, esses dados ruidosos poderiam ser eliminados ou de alguma forma, ter seu grau de importância reduzido.

### 6.3 Trabalhos Futuros

O método preditor construído para a tarefa de predição das crises epiléticas, assunto dessa dissertação, trabalhou com dados eletroencefalográficos, acrescidos de dados provenientes de batimentos cardíacos, contração muscular e movimentos oculares de quatro pacientes do banco de dados EPILEPSIAE [5], mantidos em

arquivos textos. Porém, como trabalho futuro, seria interessante analisar o comportamento da metodologia aqui empregada em um universo maior de pacientes, apenas a título de se comprovar a relativa eficiência demonstrada nos experimentos do presente trabalho. Lembrando que os subconjuntos de dados do EPILEPSIAE utilizados foram adquiridos de forma gratuita e que a obtenção da base de dados completa junto ao EPILEPSIAE não seria a custo zero.

Outro avanço seria modificar os algoritmos que compõem o método preditor de crises, para o uso real deste com dados oriundos de fluxo contínuo de tempo (séries temporais), intencionando uma posterior implementação em algum dispositivo físico, com o intuito de testar seu uso efetivo em pessoas que sofram de epilepsia. Nesse cenário, o tratamento dos sinais elétricos obtidos em tempo real para uso em uma rede neural sem peso seria outro ponto a ser considerado. Talvez até com a elaboração de uma nova arquitetura de rede ou adaptação da WiSARD, caso isso se mostre necessário.

Além do exposto até aqui, uma experiência cabível seria tentar desenvolver o presente método para que ele tivesse eficiência na previsão de crises com um intervalo de tempo de predição maior do que 30 segundos (tempo máximo utilizado neste trabalho). Para isso, poderia se lançar mão de técnicas de seleção de atributos (*feature selection*) sobre as entradas (padrões) a serem utilizadas na WiSARD (ou outro modelo de rede neural sem peso que venha a ser escolhido). O objetivo seria tentar diminuir ou eliminar a presença de dados ruidosos e diminuir o gasto de memória do Método Preditor apresentado, tendo como meta uma maior flexibilização no uso deste em dispositivos que não disponham de muitos recursos de memória computacional.

Outro detalhe a ser revisto seria o de tentar melhorar a forma de mapeamento dos valores das entradas de inteiro para binário. Poderia-se distribuir os bits de acordo com o grau de qualidade dos atributos das entradas, tentando assim aumentar a relevância dos atributos mais significativos. Uma métrica eficiente para a aferição desse grau de qualidade dos atributos também teria que ser desenvolvida para que esse fim fosse atingido.

# Referências Bibliográficas

- [1] CARNEIRO, H. C. C. *A Função do Índice de Síntese das Linguagens na Classificação Gramatical com Redes Neurais Sem Peso*. Tese de M.Sc., UFRJ, Rio de Janeiro, RJ, Brasil, 2012.
- [2] WHO. *Atlas: Epilepsy Care in the World*. Programme for Neurological Diseases and Neuroscience, Department of Mental Health and Substance Abuse - WORLD HEALTH ORGANIZATION, 2005. ISBN: 92-4-156303-6.
- [3] FRANCISCO, A. M. A. *Estudo da Lamotrigina em Doentes Epilépticos Submetidos à Monitorização Vídeo Eletroencefalográfica*. Tese de D.Sc., Coimbra, Portugal, 2008.
- [4] ALEKSANDER, I., GREGORIO, M. D., FRANCA, F. M. G. “A Brief Introduction to Weightless Neural Systems”, *ESANN*, 2009.
- [5] HLE, M., FELDWISCH-DRENTROP, H., TEIXEIRA, C. A. “EPILEPSIAE A European Epilepsy Database”, *Computer Methods and Programs in Biomedicine*, v. 106, pp. 127–138, 2012.
- [6] PARREIRA, F. J. *Deteção de Crises Epilépticas a partir de Sinais Eletroencefalográficos*. Tese de D.Sc., UFU, Uberlândia, MG, Brasil, 2006.
- [7] ALMEIDA, L. B. *Deteção e Caracterização de Crises Epilépticas através de Estimulação Elétrica*. Tese de D.Sc., UFMG, Belo Horizonte, MG, Brasil, 2013.
- [8] GUERREIRO, C. A. M., GUERREIRO, M. M., CENDES, F., et al. *Epilepsia*. São Paulo, SP, Brasil, 2000. ISBN: 85-7450.
- [9] BERG, A. T., BERKOVIC, S. F., BRODIE, M. J., et al. *Terminologia e Conceitos Revisitos para Organização de Crises e Epilepsias*. Relatório da comissão da ilae de classificação e terminologia, 2005-2009.
- [10] WESTMARIANA. “Síndrome de West”, *On line.*, 2014. Disponível em: <http://www.westmariana.com/sindromewest.htm> : acessado em 26 de Fevereiro de 2014.



- [11] NEEPI. “Classificação Básica das Crises Generalizadas”, *Núcleo de Estudo sobre Epilepsia da Faculdade de Medicina do Triângulo Mineiro. On line.*, 2013. Disponível em: <http://nucleoepilepsia.tripod.com/id20.html>: acessado em 28 de Fevereiro de 2014.
- [12] HAYKIN, S. *Redes Neurais: Princípios e Prática*. Editora Bookman, 2001. ISBN: 97-8-85730771-8.
- [13] LUDEMIR, T. B., CARVALHO, A., BRAGA, A. P. B., et al. “Weightless Neural Models: A Review of Current and Past Works”, *Neural Computing Surveys*, , n. 2, pp. 41–61, 1999.
- [14] FONSECA, R. V. *Teoria dos Números*. 1 ed. Belém, Pará , Brasil, UEPA. ISBN: 978-85-88375-66-6.
- [15] CARVALHO, D. S., CARNEIRO, H. C. C., FRANCA, F. M. G. “B-bleaching: Agile Overtraining Avoidance in the WiSARD Weightless Neural Classifier”, *ESSAN*, 2013.
- [16] CARDOSO, D. O. *Uma Arquitetura para Agrupamento de Dados em Fluxo Contínuo Baseada em Redes Neurais Sem Peso*. Tese de M.Sc., UFRJ, Rio de Janeiro, RJ, Brasil, 2012.
- [17] SOUZA, C. R. *Redes Neurais Sem Peso Aplicadas na Categorização de subtipos do HIV-1*. Tese de M.Sc., UFRJ, Rio de Janeiro, RJ, Brasil, 2011.
- [18] ALEJO, R., SOTOCA, J. M., CASAN˜, G. A. “An Empirical Study for the Multi-Class Imbalance Problem with Neural Networks”, *CIARP*, v. LNCS 5197, pp. 479–486, 2008.