

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

Cristiano Rodrigo Azevedo

**ESTUDO DO RECONHECIMENTO AUTOMÁTICO DE
EVENTOS EPILEPTIFORMES EM SINAIS DE
ELETROENCEFALOGRAFIA UTILIZANDO REDES DE
KOHONEN**

Florianópolis

2014

Cristiano Rodrigo Azevedo

**ESTUDO DO RECONHECIMENTO AUTOMÁTICO DE
EVENTOS EPILEPTIFORMES EM SINAIS DE
ELETROENCEFALOGRAFIA UTILIZANDO REDES DE
KOHONEN**

Dissertação submetida ao Programa
de Pós-Graduação em Engenharia
Elétrica da Universidade Federal de
Santa Catarina para a obtenção do
Grau de Mestre em Engenharia
Elétrica.

Orientador: Prof. Fernando Mendes
de Azevedo, D.Sc.

Florianópolis

2014

Cristiano Rodrigo Azevedo

**ESTUDO DO RECONHECIMENTO AUTOMÁTICO DE
EVENTOS EPILEPTIFORMES EM SINAIS DE
ELETROENCEFALOGRAFIA UTILIZANDO REDES DE
KOHONEN**

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração Engenharia Biomédica, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.

Florianópolis, 11 de Agosto de 2014.

Prof. Carlos Galup Montoro, Dr.

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica.

Banca Examinadora:

Prof. Fernando Mendes de Azevedo, D.Sc.

Orientador

Universidade Federal de Santa Catarina.

Banca Examinadora (continuação):

Prof. Dr Gustavo Amadeu Micke
Universidade Federal de Santa Catarina

Profa. Dra. Ana Carolina de Oliveira Costa
Universidade Federal de Santa Catarina

Profa. Dra. Daniela Ota Hisayasu Suzuki
Universidade Federal de Santa Catarina

AGRADECIMENTOS

A todos os meus familiares, mesmo estando distante, sei que estão sempre torcendo por mim.

A minha esposa Mônia, que está sempre ao meu lado apoiando em todos os momentos.

A Profa. Dra. Ana Carolina de Oliveira Costa e ao Prof. Dr. Gustavo Amadeu Micke pela oportunidade e amizade.

Ao Prof. Dr. Fernando Mendes de Azevedo por todo o apoio e orientação para a realização deste estudo.

A Christine Boos por todo o auxílio no desenvolvimento deste estudo.

Ao Geovani Scolaro pela sua contribuição ao estudo.

A todos os amigos que apoiaram essa jornada.

À PGEEL, ao IEB-UFSC e à CAPES pela oportunidade e apoio financeiro para o desenvolvimento dos trabalhos realizados.

RESUMO

O presente estudo propõe a viabilidade da utilização de Mapas Auto-organizáveis de Kohonen (MAK) para o processo de detecção e classificação de eventos epileptiformes (EE) para o apoio ao diagnóstico de epilepsia, para tanto optou-se pelo desenvolvimento de um protótipo de sistema automatizado, utilizando técnicas de Inteligência Artificial baseado em MAK. O sistema protótipo proposto chamado de Sistema Classificador Kohonen para Eventos Epileptiformes (SCKEE) foi desenvolvido com o objetivo de obter um *software* protótipo com capacidade de realizar o processamento dos sinais de forma eficiente e classificar automaticamente EE em sinais de eletroencefalografia de longa duração. O SCKEE é composto por dois módulos (treinamento e teste), nos quais são utilizados uma camada de entrada com 512 neurônios e uma camada de saída com 3 possibilidades de tamanhos (100, 225 e 400 neurônios), e quatro funções de ativação de vizinhança (Discreta, Gaussiana, “Chapéu Mexicano” e “Chapéu Francês”), o qual seu funcionamento segue da seguinte forma, primeiramente, no módulo de treinamento é realizada a separação das classes de padrões apresentado ao sistema, gerando o conjunto de pesos treinados, no módulo de teste é utilizado o conjunto de pesos treinados para a classificação dos padrões a serem testados. A avaliação dos dados de classificação gerados pelo SCKEE foi realizada com base nos índices de desempenho obtidos através da análise dos resultados gerados por este. Concluiu-se que a função de ativação de vizinhança “Chapéu Mexicano”, no tamanho de rede de 225 neurônios, obteve os melhores resultados para os índices de desempenho avaliados: Sensibilidade de 100%, Especificidade de 91%, Seletividade Positiva e Seletividade Negativa de 90% e 100%, respectivamente e Eficiência de 95%. Com a utilização de MAK com apenas uma rede neural artificial na camada de saída, foi possível a separação e classificação dos EE com resultados promissores, no qual pode-se atribuir os excelentes resultados alcançados, ao desenvolvimento de um *software* exclusivo para a classificação dos EE em sinais de EEG, o que pode confirmar a viabilidade da utilização do MAK para apoio ao diagnóstico.

Palavras-chave: EEG, Epilepsia, Espícula, Mapas Auto-organizáveis de Kohonen, Transformada Wavelet, IA, Redes Neurais Artificiais.

ABSTRACT

This study proposes the feasibility of using of Self-Organized Map (SOM) for process of detection and classification of epileptiform events (EE) to support the diagnosis of epilepsy, and opted for the development of a prototype automated system using artificial intelligence techniques based on SOM. The proposed prototype system called Kohonen Classifier System for Events Epileptiform (KCSEE) was development with the goal obtaining a prototype software capable of performing signal processing quickly and automatically classify EE in signals of electroencephalogram (EEG) of long-term. The KCSEE consists of two modules (training and test), in which are used an input layer with 512 neurons and an output layer with 3 sizes different (100, 225 and 400 neurons) and four neighborhood activation functions (Discrete, Gaussian, "Mexican Hat" and "French Hat"), which its operation is given as follows, first, in the training module is made the separation of the classes of patterns presented to the system, generating a set of trained weights, in the test module is used the set of trained weights for classification of the patterns that will be tested. The evaluation of date of classification obtained by KCSEE was performed based on the performance indices obtained by analyzing of the results generated from this. Was concluded that the "Mexican Hat" neighborhood activation function, with network size of 225 neurons, obtained the best results for performance indices evaluated: Sensitivity 100%, Specificity 91%, Positive Selectivity and Negative Selectivity 90% and 100%, respectively, and Efficiency 95%. Using SOM with only an artificial neural network in the output layer, was possible the separation and classification of EE with promising results, which can attribute the good results to the development of an exclusive software for classification of EE in signals of EEG, which can confirm the feasibility of using SOM to support the diagnosis.

Keywords: Electroencephalogram signal, Epilepsy, Spike, Self-Organizing Maps of Kohonen, Wavelet Transform, AI, Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1 - Estrutura celular do neurônio e sentido de propagação da excitação sináptica.....	26
Figura 2 – Fração de membrana e concentração iônica dos meios intracelular e extracelular.....	26
Figura 3 – Exemplo de um potencial de ação.....	27
Figura 4 – Exemplos de padrões cerebrais presentes no sinal de EEG.....	29
Figura 5 – Sistema 10-20 para o posicionamento de eletrodos.....	30
Figura 6 – Método de medição de EEG, bipolar a) e referencial b).....	31
Figura 7 – Morfologia da onda aguda seguida por onda lenta com duração de 153 ms. Evento epileptiforme encontrado em registros de sinais de EEG.....	32
Figura 8 – Morfologia da espícula com duração de 35 ms. Evento epileptiforme encontrado em registros de sinais de EEG.....	32
Figura 9 – Divisões dos hemisférios cerebrais.....	34
Figura 10 – Estrutura de um neurônio típico.....	35
Figura 11 – Modelo do Neurônio Artificial.....	37
Figura 12 – Representação da área de ativação frente a estímulo visual.....	38
Figura 13 – Representação da área de ativação frente a estímulo auditivo.....	39
Figura 14 – Mapa topológico em formato bidimensional.....	40
Figura 15 – Funções de vizinhança do tipo gaussiana a) e discreta b).....	43
Figura 16 – Funções de vizinhança do tipo <i>Wavelet</i> : “Chapéu Mexicano” a) e “Chapéu Frances” b).....	43
Figura 17 - Vizinhança geométrica do tipo quadrada a) e hexagonal b).....	44
Figura 18 – Exemplo de mapa formado por U-Matriz.....	46
Figura 19 – Exemplo de mapa de densidade.....	47
Figura 20 – Exemplo de Mapa contextual.....	48
Figura 21- Morfologia apresentada nos conjuntos de eventos: a) epileptiformes, b) piscadas, c) atividade de fundo normal, e d) ruídos/artefatos.....	54
Figura 22 – Tela do SCKEE com rede de tamanho 225 neurônios na camada competitiva.....	57

Figura 23 – Tela de configurações do módulo de treinamento do SCKEE:.....	58
Figura 24 – Tela de visualização da camada competitiva do módulo de treinamento do SCKEE : a) lista de padrões, b) visualização de mapas, c) visualização de erro topológico e d) visualização de padrões normalizados.	59
Figura 25 – Tela de visualização de mapa de densidade do módulo de treinamento do SCKEE: a) mapa de densidade, b) ativação de neurônio.	60
Figura 26 – Tela de classificação do módulo de teste do SCKEE: a) lista de padrões e visualização de normalização, b) configurações, c) mapa bidimensional e d) análise do classificador.	61
Figura 27 – Conjunto de Sinais normalizados.	62
Figura 28 – Rede com tamanho 10x10 e formação do mapa de contexto.....	63
Figura 29 – Mapa de densidade gerado pelo SCKEE.	64
Figura 30 – Mapas gerados pelo SCKEE com redes de tamanho 100 neurônios.....	65
Figura 31 – Mapas gerados pelo SCKEE com redes de tamanho 225 neurônios.....	65
Figura 32 – Mapas gerados pelo SCKEE com redes de tamanho 400 neurônios.....	66
Figura 33 – Ferramentas de confirmação e visualização de sinais: a) Lista de padrões; b) Gráfico de padrões e c) Mapa bidimensional. ..	69
Figura 34 – Gráfico de Sensibilidade percentual para as funções de vizinhança e tamanho de rede avaliados.	73
Figura 35 – Gráfico de Especificidade percentual para as funções de vizinhança e tamanho de rede avaliados.	74
Figura 36 – Gráfico de Valor Preditivo Positivo percentual para as funções de vizinhança e tamanho de rede avaliados.	75
Figura 37 – Gráfico de Valor Preditivo Negativo percentual para as funções de vizinhança e tamanho de rede avaliados.	76
Figura 38 – Gráfico de Eficiência percentual para as funções de vizinhança e tamanho de rede avaliados.	77
Figura 39 – Gráfico dos resultados obtidos para a função de vizinhança “Chapéu M.” de tamanho 15x15.....	78
Figura 40 - Comparação entre os valores obtidos para os índices de desempenho entre SCKEE e Scolaro (2009).	81

LISTA DE TABELAS

Tabela 1: Tabela de contingência.....	49
Tabela 2 – Número de padrões utilizados nos experimentos do estudo.	55
Tabela 3 – Tabela de contingência adaptada para classes de Eventos Epileptiforme (EE) e Eventos Não Epileptiforme (ENE).	67
Tabela 4 - Valores dos parâmetros (VP, VN, FP e FN) avaliados nos testes.	71
Tabela 5 –Valores obtidos dos índices de desempenho.	72

LISTA DE ABREVIATURAS E SIGLAS

EE – Evento Epileptiforme
EEG – Eletroencefalografia/Eletroencefalograma
EMG – Eletromiografia
ENE -Evento Não Epileptiforme
EQ - Erro de Quantização
FN – Falso Negativo
FP – Falso Positivo
IA – Inteligência Artificial
IEB-UFSC – Instituto de Engenharia Biomédica da Universidade Federal de Santa Catarina
MAK – Mapas Auto-organizáveis de Kohonen
NA – Neurônios Artificiais
OMS – Organização Mundial da Saúde
PMC – *Perceptron* de Múltiplas Camadas
RNA – Redes Neurais Artificiais
SCKEE – Sistema Classificador Kohonen para Eventos Epileptiformes
SN – Sistema Nervoso
UFSC – Universidade Federal de Santa Catarina
VN – Verdadeiro Negativo
VP – Verdadeiro Positivo
VPN – Valor Preditivo Negativo
VPP – Valor Preditivo Positivo

SUMÁRIO

1 INTRODUÇÃO	21
1.1 OBJETIVOS	22
1.1.1 Objetivos Específicos	23
2 FUNDAMENTAÇÃO TEÓRICA	25
2.1 EPILEPSIA	25
2.2 ORIGEM DO SINAL ELÉTRICO CEREBRAL.....	25
2.3 ELETROENCEFALOGRAFIA	28
2.4 POSICIONAMENTO DOS ELETRODOS	30
2.4.1 Elementos Eletrográficos	31
2.5 CLASSIFICAÇÃO AUTOMÁTICA DE PAROXISMOS	33
2.6 REDES NEURAIS	33
2.6.1 Cérebro.....	33
2.6.2 Neurônio.....	34
2.7 REDES NEURAIS ARTIFICIAIS.....	36
2.7.1 Neurônio Artificial	36
2.8 MAPAS AUTO-ORGANIZAVEIS DE KOHONEN	38
2.8.1 Critério De Parada.....	45
2.9 VISUALIZAÇÃO DE MAPAS GERADO PELOS MAK	46
2.9.1 U-Matriz.....	46
2.9.2 Mapa De Densidade	47
2.9.3 Mapa De Contexto	48
2.10 AVALIAÇÃO DE DESEMPENHO	48
2.11 TraBALHOS DESENVOLVIDOS NA ÁREA.....	51
3 METODOLOGIA	53
3.1 BANCO DE SINAIS DE EEG.....	53
3.2 CONJUNTO DE PADRÕES DE EEG	55
3.3 DESENVOLVIMENTO DO MAK	56
3.4 TREINAMENTO	61
3.5 TESTES.....	66
4 RESULTADOS E DISCUSSÕES.....	69
5 CONCLUSÃO	83
6 PERSPECTIVAS	85

REFERÊNCIAS..... 87

1 INTRODUÇÃO

Segundo a Organização Mundial da Saúde (OMS), a epilepsia é uma das doenças cerebrais graves mais comuns, afetando aproximadamente 50 milhões de pessoas em todo o mundo. O termo epilepsia é utilizado para definir um grupo de condições neurológicas crônicas caracterizado por crises epiléticas, que são alterações na atividade elétrica normal do cérebro, podendo ocorrer descargas elétricas excessivas de grupos de células cerebrais em diferentes regiões do cérebro (ENGEL *et al.*, 2005).

A análise de sinais de eletroencefalografia (EEG) é uma importante técnica que mede a distribuição espacial dos campos de tensão no couro cabeludo e sua variação ao longo do tempo. Esta técnica é utilizada para a confirmação clínica do diagnóstico de epilepsia, uma vez que a ocorrência de algumas manifestações eletrográficas neste sinal é um forte indicativo desta patologia. Estas manifestações eletrográficas, que podem ser do tipo paroxismos (manifestações intensas, súbitas, com início e fim determinados), são chamadas de eventos epileptiformes, sendo as espículas e as ondas agudas os mais frequentes destes eventos presentes nos sinais de EEG de pacientes comprovadamente epiléticos (HIRSCH *et al.*, 2010).

Conforme Wilson e Emerson (2002), além do diagnóstico da epilepsia, é importante que haja uma maneira de realizar a detecção automática das espículas, pois o método de marcação prescrita visual é uma técnica laboriosa que exige um abrangente estudo. Diante do baixo desempenho da técnica descrita anteriormente, surge a necessidade de automatização da análise dos sinais de EEG. Apesar de já existirem trabalhos desenvolvidos nesta área, ainda não há um sistema único que apresente os valores de parâmetros de avaliação com eficiência satisfatória. Este fato foi analisado em um estudo comparativo de diversos métodos de detecção de espículas, registrados de 1976 a 2002, que apontaram progresso desde 1985, com o crescimento da capacidade de processamento e de utilização de Redes Neurais Artificiais (RNA).

Um dos primeiros estudos com o objetivo de detectar eventos epileptiformes em sinais de EEG com a utilização de técnicas de Inteligência Artificial (IA), foi com o uso de RNA *Perceptron* de Múltiplas Camadas (PMC), no qual este foi publicado por Webber *et al.* (1995). Além das RNA há outras técnicas empregadas para a detecção de eventos epileptiformes, tais como a Transformada *Wavelet*, métodos

estatísticos, entre outras. Dentre as várias técnicas de IA, as RNAs são as técnicas que baseiam-se na simulação do sistema nervoso dos seres vivos, as RNAs vêm sendo objeto de estudo para o reconhecimento de muitos tipos de padrões, como o reconhecimento de eventos epileptiformes. As RNA mais comumente utilizadas para este tipo de reconhecimento são do tipo PMC, porém, há também trabalhos e o grande interesse na utilização de RNA chamada de Mapas Auto-organizáveis de Kohonen (MAK), também conhecida como Redes Auto-organizáveis de Kohonen, ou simplesmente, Redes de Kohonen, que foi idealizada por Kohonen em 1982 (SILVA; SPATTI; FLAUZINO, 2010). Esta rede foi utilizada para o estudo de detecção de espículas em EEG no trabalho de Kurth *et al.* (2000) e Sala (2005); até o ano de 2014 não foram observados nas principais bases de dados, registros de trabalhos que tenham utilizado o MAK para a classificação de eventos epileptiformes e não epileptiformes, utilizando apenas uma única rede de treinamento.

As RNA, PMC e MAK têm sido objeto de estudo do Instituto de Engenharia Biomédica da Universidade Federal de Santa Catarina (IEB-UFSC) em diversas pesquisas realizadas para a detecção e classificação automática de eventos em sinais de EEG, como por exemplo, nos trabalhos de Pereira (2003), Sala (2005), Scolaro (2009) e Boos (2011).

Este trabalho propõe-se avaliar a utilização de Redes Kohonen, que apresentam como uma das principais características, o treinamento não supervisionado; para tanto, foi desenvolvido um *software* protótipo para realizar o processamento de sinal de EEG e possibilitar a identificação automática de eventos epileptiformes. Os resultados estatísticos serão realizados com o uso de ferramentas de análise matemática utilizando o *software* Excel®.

1.1 OBJETIVOS

Avaliar a viabilidade das Redes Kohonen para automatização da classificação de eventos epileptiformes e eventos não epileptiformes em sinais de EEG.

1.1.1 Objetivos Específicos

- Definir o conjunto de sinais de EEG para utilização no treinamento das Redes Kohonen utilizadas;
- Desenvolver o algoritmo de Redes Kohonen para a classificação automática de paroxismos;
- Desenvolver um *software* protótipo para o processamento dos sinais de eletroencefalografia.
- Avaliar as diferentes funções de ativação de vizinhança;
- Avaliar os diferentes tamanhos de camada competitiva;
- Avaliar o desempenho da metodologia das redes utilizadas;
- Validar a metodologia e o *software* desenvolvido.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 EPILEPSIA

A epilepsia já era relatada desde o início das primeiras escritas conhecidas, seus primeiros relatos são de gravações em cuneiforme babilônico (escrita feitas com auxílio de *glifos* em formato de cunha) datada de cerca de 1050 a.C., que continham descrições surpreendentes de crises epilépticas e convulsões. Por volta de 400 a.C., Hipócrates declarou em um de seus trabalhos que a epilepsia era uma doença como as outras, já que a epilepsia comumente era atribuída ao sobrenatural. Ao longo dos séculos seguintes, muito foi escrito sobre aspectos da epilepsia, mas houve pouco progresso conceitual significativo até início do século XIX (BLADIN & EADIE, 2010).

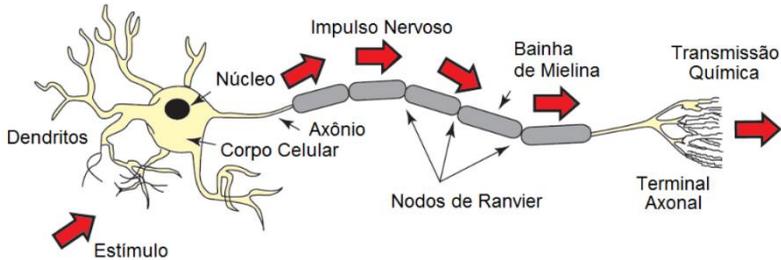
Segundo a OMS, a epilepsia é uma das doenças cerebrais graves mais comuns, afetando aproximadamente 50 milhões de pessoas em todo o mundo. A epilepsia é uma doença cerebral referente a um grupo de condições neurológicas caracterizada por gerar crises epilépticas recorrentes, isto é, uma ocorrência transitória de sinais e/ou sintomas devidos as alterações na atividade elétrica normal do cérebro, podendo ocorrer descargas elétricas excessivas de grupos de células cerebrais em diferentes regiões do cérebro (ENGEL *et al.*, 2005). Um dos principais sintomas das crises epilépticas é a convulsão, estas são breves episódios de tremores involuntários parciais ou generalizados, e por vezes ainda acompanhadas de perda de consciência, podendo variar de lapsos breves de atenção ou espasmos musculares, à convulsões graves e prolongadas com frequência variada, podendo não ocorrer nenhuma crise no período de um ano à várias vezes ao dia (OMS, 2014).

2.2 ORIGEM DO SINAL ELÉTRICO CEREBRAL

O neurônio é a unidade funcional do sistema nervoso (SN) sendo a menor estrutura que pode realizar funções em um sistema; essas células sinalizadoras geram o sinal elétrico cerebral no SN e são responsáveis pela troca de informações entre si e com outras células. Para ocorrer o sinal elétrico os dendritos recebem sinais de entrada (excitação sináptica) ativando o neurônio e produzindo corrente elétrica conduzida através do axônio, esta gera um campo elétrico mensurável por eletromiografia

(EMG), e um campo secundário sobre o couro cabeludo mensurável por EEG (SANEI & CHAMBERS, 2007; SILVERTHORN, 2010). Na Figura 1 ilustra-se o neurônio e o sentido da propagação da atividade sináptica.

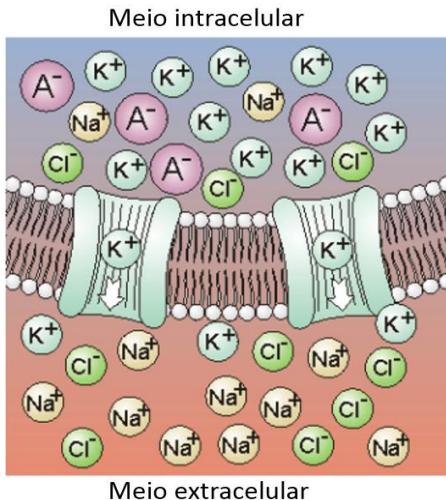
Figura 1 - Estrutura celular do neurônio e sentido de propagação da excitação sináptica.



Fonte: Modificado de Sanei & Chambers (2007).

O Potencial de Membrana ou Potencial de Repouso, é determinado pelo gradiente de concentração do potássio (K^+) e pela permeabilidade da célula em repouso ao sódio (Na^+), potássio (K^+) e ao cloreto (Cl^-), estes são ilustrados na Figura 2.

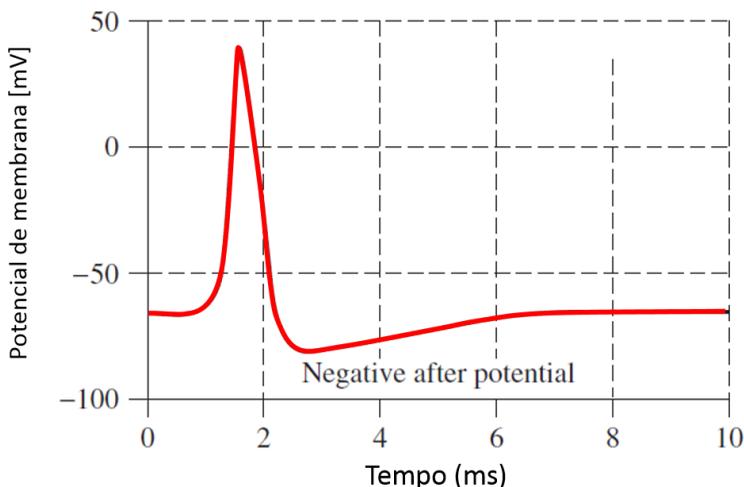
Figura 2 – Fração de membrana e concentração iônica dos meios intracelular e extracelular.



Fonte: Modificado de Malmivuo & Plonsey (1995).

A Figura 2 ilustra a composição iônica dos meios intracelular e extracelular, a mudança tanto no gradiente de concentração do K^+ ou nas permeabilidades iônicas alteram o potencial de membrana gerando corrente elétrica. O movimento dos íons positivos, Na^+ e K^+ e negativo, Cl^- , através de canais abertos na membrana do meio extracelular para o meio intracelular também geram corrente elétrica, ocorrendo a inversão de potencial da membrana. O ânion intracelular A^- é importante para a realização da eletroneutralidade, no entanto, A^- não contribui para o fluxo iônico. Quando as células excitáveis são ativadas, o potencial sai do “repouso elétrico” mudando seu valor, invertendo sua polaridade e, por um breve período de microssegundos, o interior da célula torna-se positivo, e o exterior, negativo; rapidamente a membrana da célula recupera seu potencial de repouso. Este processo com as fases de despolarização e repolarização, ocorre em aproximadamente um milissegundo, no qual envolve as correntes elétricas iônicas, com íons fluindo para dentro e para fora em diferentes etapas, este mecanismo é chamado de Potencial de Ação (Figura 3). Os potenciais de ação propagam-se ao longo da membrana celular. (MALMIVUO & PLONSEY, 1995; SANEI & CHAMBERS, 2007).

Figura 3 – Exemplo de um potencial de ação



Fonte: Modificado de Sanei & Chambers (2007).

2.3 ELETROENCEFALOGRAFIA

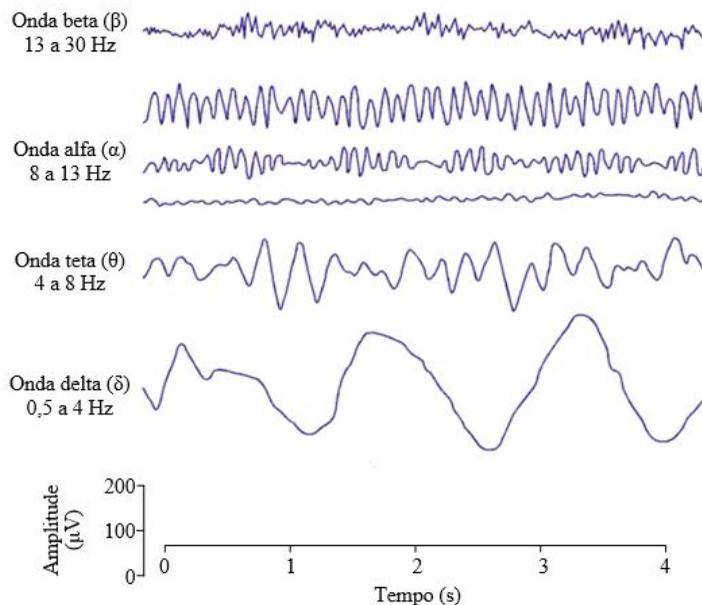
A primeira evidência de sinais elétricos na atividade cerebral foi registrada pelo cientista inglês Richard Caton em 1875, que utilizou um galvanômetro¹ e dois eletrodos para aquisição do sinal elétrico. Desde então, o conceito de eletroencefalograma ou eletroencefalografia (EEG) tem sido amplamente utilizado para designar a atividade neural elétrica do cérebro. A aquisição do sinal de EEG pode ser realizada através de eletrodos introduzidos no interior do tecido cerebral, posicionando eletrodos diretamente na superfície do córtex cerebral ou posicionando eletrodos na superfície do couro cabeludo de forma não invasiva (SANEI & CHAMBERS, 2007).

A análise de sinal de EEG é uma técnica importante e comumente utilizada para auxiliar na confirmação clínica do diagnóstico de epilepsia e na definição do tipo de síndrome epiléptica, fornecer informações necessárias ao planejamento da terapia, além de auxiliar na tomada de decisão sobre a viabilidade de intervenções cirúrgicas. O EEG apresenta características físicas que possibilitam a extração de sinais, tais como a banda de frequência de 0 a 100 Hz e faixa de amplitude de 2 a 200 μV , o qual o sinal de interesse de eventos epileptiformes encontra-se entre 0,5 e 60 Hz, com amplitude média de 50 μV . Estas características de amplitude e frequência do sinal podem ser influenciadas por vários fatores, tais como idade do indivíduo, estado físico (sono, vigília, coma, dentre outros) e artefatos (ruídos) de várias fontes (SANEI & CHAMBERS 2007; WILLIAMS & WILKINS, 2001).

Conforme Sanei & Chambers (2007), o EEG é normalmente subdividido em faixas de frequências ilustradas na Figura 4.

¹ Galvanômetro instrumento que pode medir correntes elétricas de baixa intensidade, ou a diferença de potencial elétrico entre dois pontos.

Figura 4 – Exemplos de padrões cerebrais presentes no sinal de EEG.



Fonte: Modificado de Sanei & Chambers (2007).

As ondas que compõem o EEG apresentam característica específica de frequência e amplitude, o qual foram descritas abaixo conforme Sanei & Chambers (2007).

- Onda Delta (δ), de 0,5 a 4 Hz: são ondas que estão associadas principalmente ao sono profundo e podem estar presente no estado de vigília (ritmo habitual do cérebro), podendo confundir-se com artefatos (causados pelos músculos do pescoço e da mandíbula);
- onda Teta (θ), de 4 a 8 Hz: onda frequente em crianças, é típica de estágio inicial do sono, também estando associada com inspiração criativa e meditação profunda;
- onda Alfa (α), de 8 a 13 Hz: é o ritmo mais comum em indivíduos com atividade cerebral normal, indicando uma consciência relaxada, sem qualquer atenção ou concentração;
- onda Beta (β), de 14 a 26 Hz: onda encontrada em adultos com atividade cerebral normal durante o estado de vigília, associada

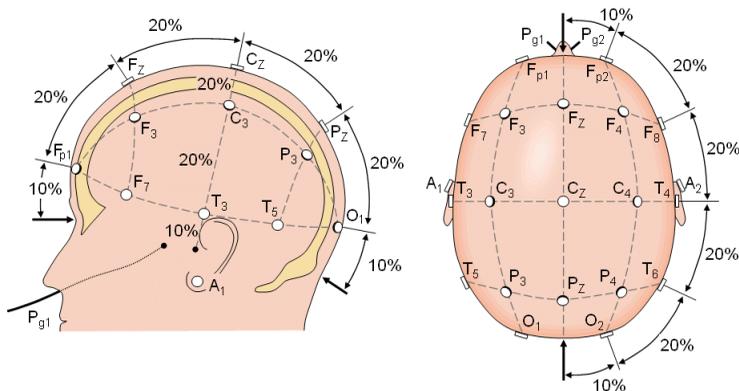
ao pensamento ativo, atenção, foco no mundo exterior ou para resolver problemas.

O registro de EEG é uma importante ferramenta para o auxílio ao diagnóstico, podendo ser utilizado para investigação de epilepsia e localização do foco de crises, dentre outras. A ocorrência de tipos específicos de elementos eletrográficos no sinal de EEG são denominados eventos epileptiformes (EE), o qual são forte indicadores da presença de epilepsia. (SANEI & CHAMBERS, 2007).

2.4 POSICIONAMENTO DOS ELETRODOS

Durante o Primeiro Congresso Internacional de EEG, ocorrido em Londres, em 1947, Dr. Herbert H. Jasper recomendou a padronização da colocação de eletrodos de EEG. A padronização gerou o modelo que passou a ser conhecido como Sistema Internacional de Posicionamento de Eletrodos 10-20 ilustrado na Figura 5. Esse modelo segue regras estabelecidas para o posicionamento no crânio, como medidas específicas e cobertura adequada da cabeça. (KLEM *et al*, 1999; MALMIVUO & PLONSEY, 1995).

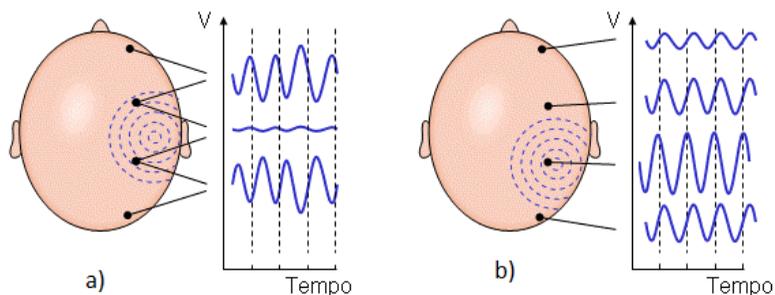
Figura 5 – Sistema 10-20 para o posicionamento de eletrodos.



Fonte: Modificado de Malmivuo & Plonsey (1995).

Os dois métodos de montagem de eletrodos comumente utilizados na aquisição de sinais de EEG são o bipolar e o unipolar (referencial); no primeiro método a diferença de potencial é medida entre um par de eletrodos ilustrado na Figura 6 (a); no método referencial compara-se o potencial de cada eletrodo a um eletrodo de referência ou a média de todos os eletrodos, como ilustrado na Figura 6 (b). Nota-se na Figura 5 (a) e (b) que a forma de onda do EEG depende do local da medição. (MALMIVUO & PLONSEY, 1995).

Figura 6 – Método de medição de EEG, bipolar a) e referencial b).

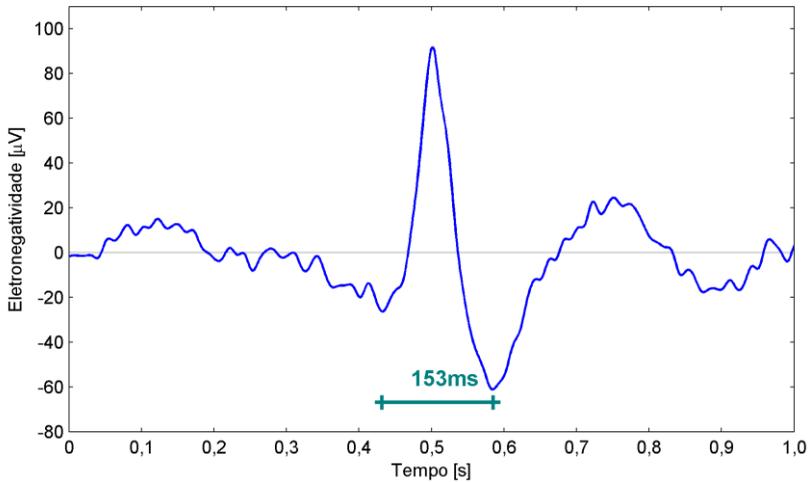


Fonte: Modificado de Malmivuo & Plonsey (1995).

2.4.1 Elementos Eletrográficos

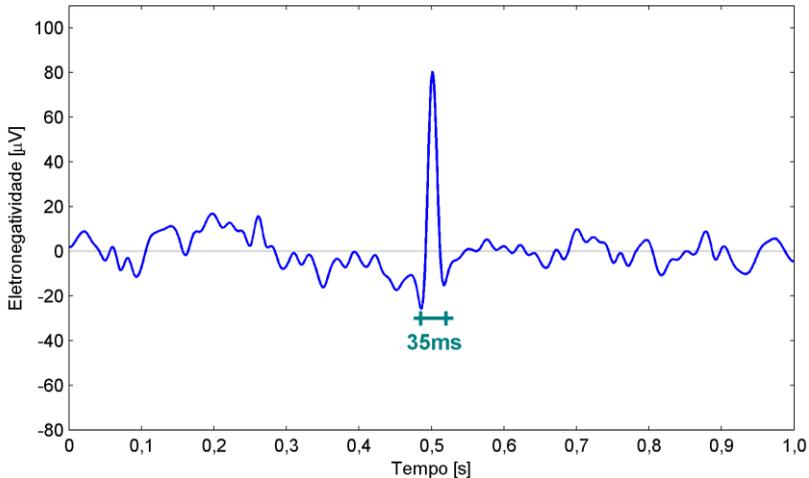
Os elementos eletrográficos que são caracterizados como eventos epileptiformes, são descritos como uma espícula ou onda aguda, sendo que suas características morfológicas básicas podem ser relacionadas à sua amplitude, geralmente encontrada entre 20 e 200 μV e a duração do evento de 20 a 200 ms. As espículas apresentam o potencial de ação mais rápido que as ondas agudas, podendo variar de 20 a 70 ms e de 70 a 200 ms, respectivamente. Estes elementos eletrográficos podem ser identificados em registro de EEG (GUERREIRO & GUERREIRO, 1993). Nas Figuras 7 e 8 são ilustrados os eventos epileptiformes.

Figura 7 – Morfologia da onda aguda seguida por onda lenta com duração de 153 ms. Evento epileptiforme encontrado em registros de sinais de EEG.



Fonte: Modificado de Sanei & Chambers (2007).

Figura 8 – Morfologia da espícula com duração de 35 ms. Evento epileptiforme encontrado em registros de sinais de EEG



Fonte: Modificado de Sanei & Chambers (2007).

2.5 CLASSIFICAÇÃO AUTOMÁTICA DE PAROXISMOS

Há registros de trabalhos com objetivo de classificação automática de espículas desde 1975, a detecção automática é tida como difícil de ser obtida por várias razões: as definições que caracterizam uma espícula fornecida pelos especialistas muitas vezes podem ser simplistas; pode ocorrer de dois especialistas humanos não marcarem um mesmo evento como espícula; o número de eventos que podem ser considerados como espículas, são normalmente muito grande; a morfologia das espículas e das atividades de fundo variam muito entre os pacientes e para desenvolver um conjunto de treinamento bem definido demanda tempo e alto custo (WILSON & EMERSON, 2002).

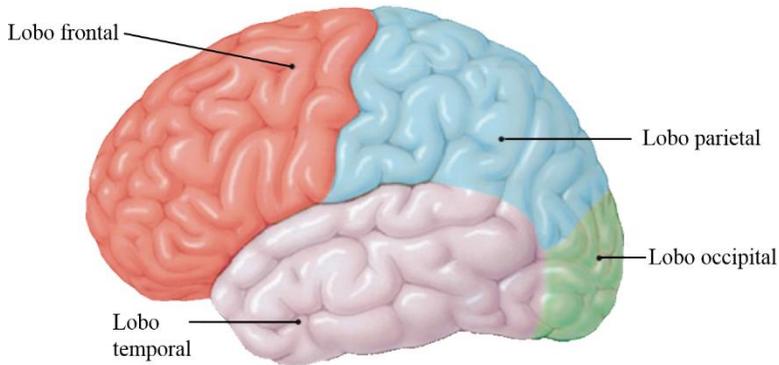
2.6 REDES NEURAIAS

Para a compreensão da lógica de funcionamento das Redes Neurais Artificiais é necessário alguns conceitos básicos sobre o funcionamento do cérebro humano.

2.6.1 Cérebro

O cérebro é uma grande estrutura biológica dividida em hemisférios esquerdo e direito, que se interligam através do corpo caloso. Os hemisférios possuem duas partes cerebrais distintas: córtex cerebral, camada externa fina composta de substância cinzenta, e a substância branca, camada abundante situada abaixo do córtex. Os hemisférios cerebrais encontram-se divididos em quatro lobos cerebrais ilustrados na Figura 9. O cérebro possui habilidade de desenvolver regras através de experiências, com capacidade de reconhecer padrões e relacioná-los, armazenar conhecimento através de experiência e interpretar informações. É um sistema distribuído e paralelo, capaz de realizar processamento mais rapidamente que qualquer sistema computacional (HAYKIN, 2001; SILVERTHORN, 2010).

Figura 9 – Divisões dos hemisférios cerebrais.



Fonte: Modificado de Marques (2012).

Os lobos cerebrais recebem o nome dos ossos que os protegem e estes desempenham funções específicas conforme descrito abaixo (SILVERTHORN, 2010):

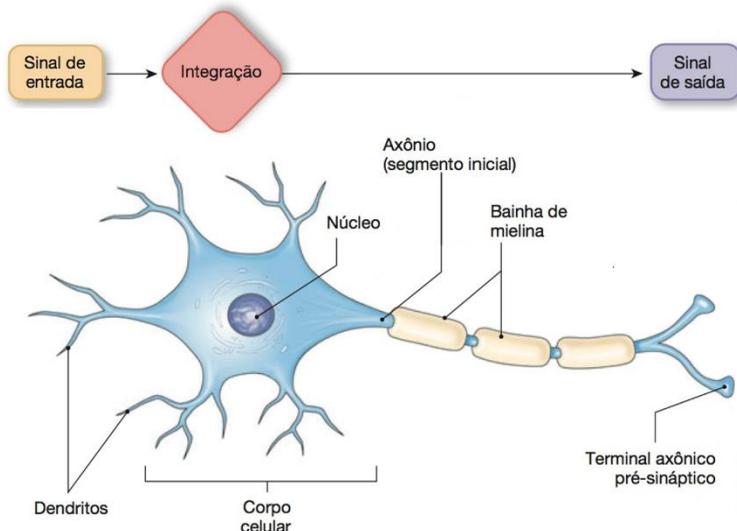
- Lobo temporal – área de memória, audição e interpretação da linguagem;
- Lobo frontal – área da fala, responsável pelo planejamento consciente, controle motor e sensorial somático;
- Lobo parietal – área de associação sensorial responsável pelos sentidos corporal e espacial;
- Lobo occipital – área interpretativa do sentido da visão.

2.6.2 Neurônio

Os neurônios biológicos são unidades funcionais (menor estrutura que pode realizar junções de um sistema) fundamentais do sistema nervoso, são de cinco a seis vezes de magnitude mais lento que as portas lógicas de um sistema computacional construído em silício; nestes sistemas a velocidade dos eventos ocorre na ordem de nanossegundos (10^{-9} s), enquanto que no sistema neural biológico a velocidade dos eventos ocorre na ordem dos milissegundos (10^{-3} s), entretanto, o cérebro compensa a taxa de velocidade mais lenta com um número estimado de 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou

conexões. As conexões formam circuitos com funções específicas chamadas de redes neurais, nos quais as mais complexas são as do encéfalo. Se cada conexão dos neurônios for considerada como um bit de informação binária, pode-se estimar a capacidade máxima de memória do cérebro humano, com cerca de 11,37 Tb de capacidade (HAYKIN, 2001; LUDWIG & MONTGOMERY, 2007). Na Figura 10 é ilustrado um neurônio típico.

Figura 10 – Estrutura de um neurônio típico.



Fonte: Modificado de Silverthorn (2010).

O neurônio possui os dendritos, que são responsáveis por receber o sinal de entrada das células vizinhas e aumentar a área de comunicação do neurônio, permitindo que este se comunique com vários outros neurônios; o corpo celular (soma celular), que é o centro de controle da célula ou centro integrador, acumula os sinais recebidos pelos dendritos até atingir um limiar e, após atingir este limiar, o núcleo dispara um sinal para o axônio que apresenta a função primária de transmissão dos sinais elétricos do centro integrador para a extremidade (SILVERTHORN, 2010).

2.7 REDES NEURAIS ARTIFICIAIS

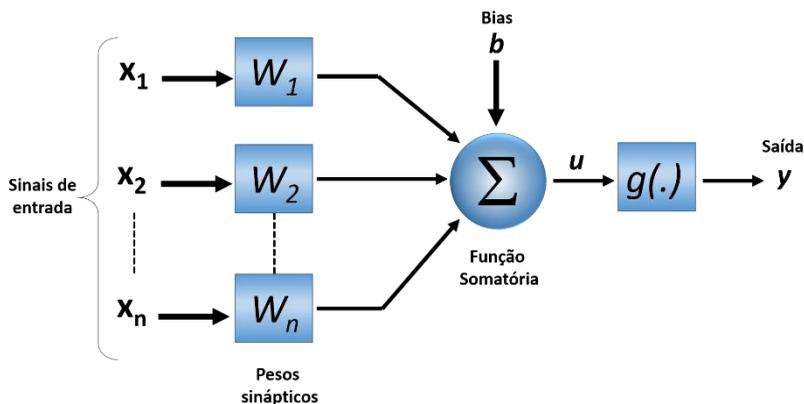
RNA são modelos computacionais inspirados no sistema nervoso dos seres vivos e têm o objetivo de apresentar características similares ao conhecimento humano. As RNA são baseadas em processamento de informações, possuem capacidade de generalização das atribuições da cognição humana ou estrutura neural. Podem ser definidas como um conjunto de unidades de processamento constituídas de neurônios artificiais interligados por conexões sinápticas artificiais e são representadas por vetores ou matrizes de pesos sinápticos (SILVA; SPATTI; FLAUZINO, 2010).

2.7.1 Neurônio Artificial

A estrutura das RNA foram desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos. Estas são compostas por elementos computacionais denominados neurônios artificiais (NA), estes são modelos simplificados do neurônio biológico. Os modelos de NA foram inspirados a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios biológicos (HODGKIN & HUXLEY, 1952).

O modelo de NA mais simples e que abrange as principais características de uma rede neural biológica, paralelismo e alta conectividade, foi proposto por McCulloch & Pitts (1943), sendo este o modelo mais utilizado nas diferentes arquiteturas de RNA, este modelo é apresentado na Figura 11.

Figura 11 – Modelo do Neurônio Artificial



Fonte: Modificado de Haykin (2001).

Conforme Silva; Spatti e Flauzino (2010), o modelo de NA é constituído por sete partes/elementos básicos apresentados a seguir:

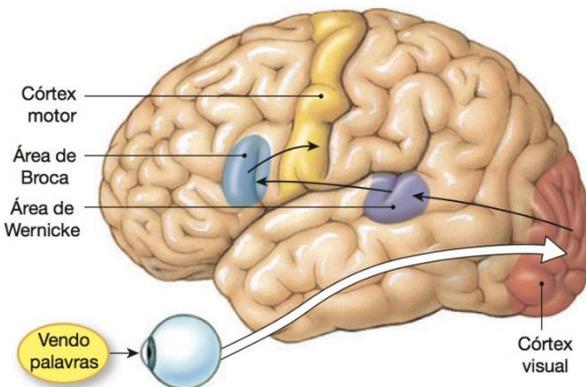
- sinais de entrada: sinais vindos do meio externo e representam valores atribuídos a uma variável de alguma aplicação específica;
- pesos sinápticos: são valores utilizados para ponderar cada variável de entrada da rede;
- função somatória: esta função agrega os sinais de entrada ponderados pelos seus respectivos pesos sinápticos com o objetivo de produzir um valor de potencial de ativação;
- *bias*: é o limiar de ativação que especifica qual será o valor apropriado para que o resultado da função somatória gere um valor de disparo em direção à saída;
- potencial de ativação: é o resultado da diferença do valor gerado entre o *bias* e a função somatória. Se o valor gerado for positivo, $u \geq 0$, o neurônio produz um potencial excitatório, caso contrário, o potencial será inibitório;
- função de ativação: função que limita a saída do neurônio dentro de um determinado intervalo de valores.
- saída: o sinal de saída consiste em um valor final em relação ao conjunto de sinais de entrada.

O funcionamento do NA pode ser resumido em: apresentação do conjunto de valores à entrada do neurônio; multiplicação de cada entrada pelo seu respectivo peso sináptico; obtenção do potencial de ativação; aplicação de uma função de ativação apropriada e pôr fim a interpretação do sinal de saída gerado.

2.8 MAPAS AUTO-ORGANIZAVEIS DE KOHONEN

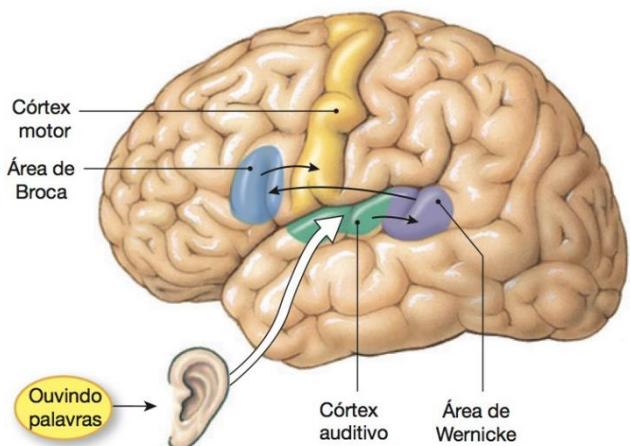
Os MAK, são redes neurais artificiais com características neurofisiológicas baseadas no funcionamento do córtex cerebral, o qual este possui áreas específicas que respondem ou são ativadas por diferentes tipos de estímulos. Quando apresentado um padrão ou estímulo, um neurônio é excitado e ao redor deste, uma área entre 50 e 100 μm , também recebe excitação, e outra área ao redor sofre inibição para impedir a propagação do sinal à áreas não relacionadas; este mecanismo é chamado de inibição lateral e conforme Kohonen *et al.* (1977) uma das características da inibição lateral é a melhoria do contraste nos contornos de imagens. As áreas que tendem a responder ao estímulo tornam a região correspondente ativa, formando mapeamentos topológicos capazes de preservar as relações de vizinhança dos dados de entrada. As regiões ativadas por estímulo visual e estímulo auditivo são apresentadas nas Figuras 12 e 13, respectivamente (RITTER *et al.*, 1992; SILVA; SPATTI; FLAUZINO, 2010).

Figura 12 – Representação da área de ativação frente a estímulo visual.



Fonte: Modificado de Silverthorn (2010).

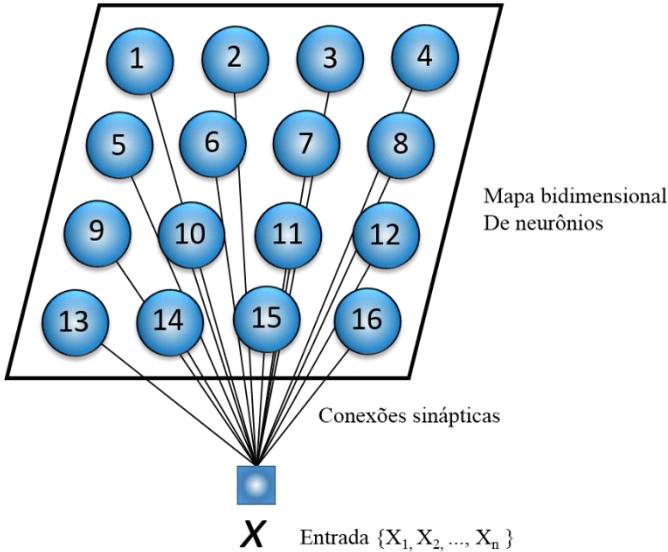
Figura 13 – Representação da área de ativação frente a estímulo auditivo.



Fonte: Modificado de Silverthorn (2010).

O funcionamento nos mapas auto-organizáveis de Kohonen ocorre semelhante ao do córtex cerebral, ou seja, ativando regiões quando recebe estímulos, com arquitetura composta de duas camadas, uma camada de entrada (estímulo) na qual ocorre a apresentação dos padrões/estímulos e a camada de saída (competitiva), que tem como principal característica apresentar áreas de ativação correspondente aos estímulos transferidos pela camada de entrada. As áreas ativadas são formadas pelo agrupamento dos padrões semelhantes, estas representam classes (*clusters*). Uma das principais áreas de aplicações dos mapas auto-organizáveis de Kohonen que pode ser citada, é a classificação de padrões (SILVA; SPATTI; FLAUZINO, 2010). A arquitetura dos mapas auto-organizáveis é demonstrada na Figura 14, que ilustra o mapa topológico constituído de 16 neurônios distribuídos em linhas e colunas.

Figura 14 – Mapa topológico em formato bidimensional.



Fonte: Modificado de SILVA *et al* (2010).

As regras para o aprendizado dos MAK seguem uma ordem de funcionamento que inicia com: ajuste dos pesos da camada competitiva atribuindo valores de forma aleatória; seleção de um padrão do vetor de entrada para ser apresentado a RNA, que deve ser realizada de modo aleatório; especificar a taxa de aprendizagem $\eta(t)$, sendo desejável que esta decresça gradualmente com o tempo, ou seja, conforme o número de iterações (t) aumenta, a taxa de aprendizagem diminui. Em particular, deve-se iniciar (η_0) com valores preferencialmente pequenos. Uma forma de decrescimento pode ser satisfeita pela equação 1 (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

$$\eta(t) = \eta_0 \exp\left(-\frac{t}{T}\right) \quad \text{onde } t = \langle 1, 2, \dots, \rangle \quad (1)$$

Enquanto (T) é uma constante de tempo do algoritmo MAK.

Também é desejável que sejam normalizados todos os vetores de pesos e de amostras, visando obter mais eficiência no processo de

aprendizagem, podendo-se aplicar a normalização unitária conforme descrito na equação 2 (SILVA; SPATTI; FLAUZINO, 2010).

$$\hat{u} = \frac{u}{\|u\|} \quad \text{onde } u = \langle 1, \dots, n \rangle \quad (2)$$

$$\|u\| = \sqrt{\sum_{i=1}^n (i)^2} \quad \text{onde } i = \langle 1, \dots, n \rangle$$

A escolha do neurônio vencedor é realizada através de uma função discriminante, de forma que o vetor desse neurônio tenha a maior semelhança com o padrão apresentado, ou seja, esse vetor vai apresentar a menor distância entre os neurônios (HAYKIN, 2001). Uma das regras normalmente utilizadas como função discriminante para determinar a proximidade dos neurônios é a distância euclidiana representada na equação 3 (SILVA; SPATTI; FLAUZINO, 2010).

$$d_{i,j} = \sqrt{\sum_{i=1}^n (x_i - w_{i,j})^2} \quad \text{onde } j = 1, \dots, n \quad (3)$$

onde $d_{ij}^{(k)}$, representara a distância euclidiana em relação ao vetor de entrada da amostra k e ao vetor dos neurônios da camada competitiva.

Após ocorrer a escolha do neurônio vencedor, primeiramente deve-se recompensar o vencedor de forma que este aproxime-se ainda mais da amostra apresentada, de forma que este seja atualizado com um maior valor que os restantes, após a atualização do neurônio vencedor são definidos quais os neurônios que terão seus pesos sinápticos atualizados, além do neurônio vencedor, ou seja, os neurônios adjacentes que pertençam a mesma vizinhança. Os MAK utilizam o critério de vizinhança de interneurônios ou topológica para determinar que os neurônios cooperem em relação aos seus vizinhos. Uma forma para a determinação do tamanho da vizinhança é determinar um raio R topológico de vizinhança unitária a partir do neurônio vencedor, visando determinar o conjunto de neurônios vizinhos ao vencedor. Há várias

maneiras para a definição da vizinhança, como por exemplo, através de funções topológicas discreta e gaussiana conforme apresentado na Figura 15 (a) e (b). A função de vizinhança discreta é representada na Equação 4 (HAYKIN, 2001; KANGAS; KOHONEN, 1996; SILVA; SPATTI; FLAUZINO, 2010).

$$h(i) = \begin{cases} 1, & \text{se } i \in V(i) \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

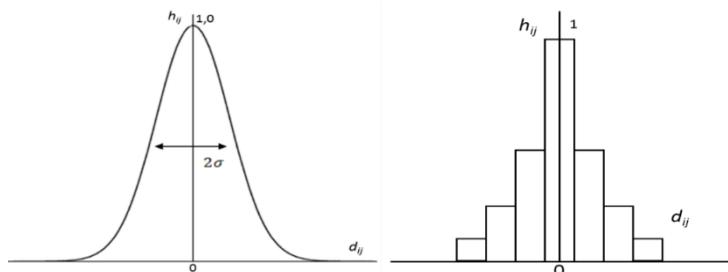
onde: (i) é o índice dos neurônios pertencentes a vizinhança e $V(i)$ é o conjunto de vizinhança.

A função Gaussiana fica em torno do neurônio vencedor e, à medida que a distância lateral aumenta, a amplitude da vizinhança tende a zero, apresentando um decaimento mais acentuado; essa função é representada pela equação 5:

$$h(d, t) = \exp\left(-\frac{d_{ij}^d}{2\sigma^2(t)}\right) \quad (5)$$

onde: $h(d, t)$ é a função de vizinhança em torno do neurônio vencedor, $d^2 = (l_i - l_j)^2$ é a distância lateral entre o neurônio vencedor (i) e o neurônio excitado (j) e (σ^2) representa o raio topológico no mapa; inicialmente o raio deve cobrir todo o mapa e deve decrescer com o número de iterações até que reduza a vizinhança a zero (KANGAS & KOHONEN, 1996).

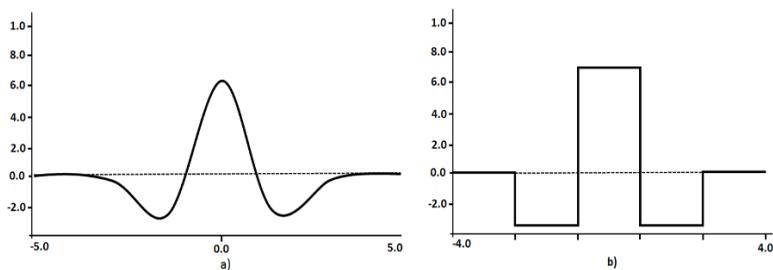
Figura 15 – Funções de vizinhança do tipo gaussiana a) e discreta b).



Fonte: Modificado de Haykin (2001) e Montgomery *et al.* (2004).

Funções de vizinhança mais complexas que as citadas anteriormente, como as do tipo Transformada *Wavelet*, são apresentadas nas Figuras 16 (a) 16 (b).

Figura 16 – Funções de vizinhança do tipo *Wavelet*: “Chapéu Mexicano” a) e “Chapéu Francês” b).



Fonte: Modificado de Dvorak & Henrard (1993).

Na função do tipo “Chapéu Mexicano” e “Chapéu Francês” o neurônio vencedor estimula lateralmente uma pequena região da vizinhança ao seu redor e, à medida que a distância aumenta em relação ao vencedor, a estimulação torna-se inibição. Estas funções são descritas nas equações 6 e 7.

$$h(d, t) = \exp\left(-\frac{d^2}{2\sigma^2(t)}\right)\left(1 - \frac{2}{2\sigma^2(t)} d^2\right) \quad (6)$$

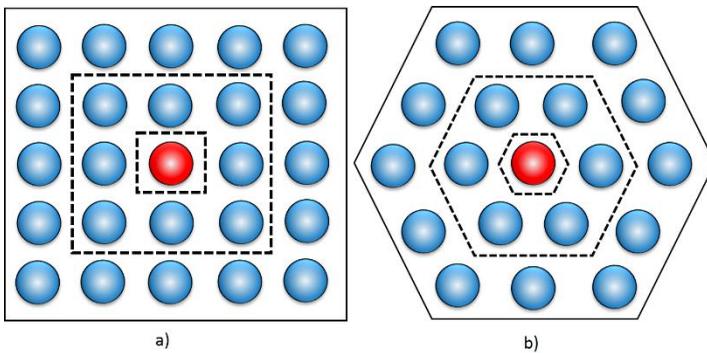
onde: $h(d, t)$ é a função de vizinhança em torno do vencedor.

$$h(d) = \begin{cases} 1, & |d| \leq r, \\ -\frac{1}{3}, & r < |d| < 3r, \\ 0, & |d| > 3r \end{cases} \quad (7)$$

onde: $h(d)$ é a função de vizinhança em torno do vencedor.

Funções de vizinhança do tipo geométrica podem ser definidas de qualquer forma, nas funções desse tipo os neurônios ficam organizados em torno do neurônio vencedor. Alguns dos formatos geométricos utilizados no MAK são de forma quadrada, conforme a ilustração da Figura 17 (a), ou de forma hexagonal, conforme ilustrado na Figura 17 (b). Como nas funções de vizinhanças matemáticas que decrescem com o número de iterações, a vizinhança geométrica também deve decrescer monotonicamente (com variação constante) (KOHONEN, 1990; SILVA; SPATTI; FLAUZINO, 2010).

Figura 17 - Vizinhança geométrica do tipo quadrada a) e hexagonal b).



Fonte: Modificado de Siqueira (2010).

2.8.1 Critério De Parada

O critério de parada utilizado para o treinamento de Redes Kohonen é o alcance de valores pré-determinados para erro mínimo desejável, número máximo de iterações ou valor mínimo para a taxa de aprendizagem. Existem várias medidas de erro que podem ser utilizadas para determinar a qualidade de um MAK, dentre estas, há a medida de erro denominada Erro Topológico (KIVILUOTO, 1996), definida pela equação 8.

$$E_T = \frac{1}{v} \sum_{k=1}^v u_k \quad (8)$$

$$\text{onde: } u_k = \begin{cases} 1, & \text{se } i^{**} \notin \bar{V}_{i^*} \\ 0, & \text{caso contrário} \end{cases}$$

Onde i^{**} é o segundo neurônio vencedor para o padrão k e \bar{V}_{i^*} é o conjunto de neurônios vizinhos imediatos do vencedor i^* .

O valor do Erro Topológico representa o percentual de neurônios vencedores que não possuem o segundo vencedor em uma vizinhança de raio centrada no neurônio vencedor. Este erro mede quanto o mapa aproxima os padrões de entrada com vetores peso próximos.

Outra medida para erro mínimo é o erro de quantização (EQ) de um vetor (v_i) do conjunto original, que é definido pela distância entre esse vetor (v_i) e a sua versão quantizada $q(v_i)$, ou seja, para cada vetor de entrada (v_i), deseja-se minimizar o erro de quantização definido pela equação 9.

$$Q_i = d(v_i, q(v_i)) \quad (9)$$

onde: $d(v_i, q(v_i))$ representa a distância euclidiana entre o vetor de entrada e o vetor do neurônio vencedor, no qual o objetivo é a minimização do EQ para cada vetor de entrada (v_i) o que é proporcional ao EQ médio conforme a equação 10 (MACIEL, 2014; SIMÕES *et al*, 2009).

$$Q_N = \frac{1}{N} \sum_{i=1}^N Q_i \quad (10)$$

onde: N representa o número de valores contido no conjunto de entrada.

2.9 VISUALIZAÇÃO DE MAPAS GERADO PELOS MAK

A visualização dos mapas gerados pelos MAK é uma das características que fazem que os MAK sejam muito utilizados. Algumas formas de visualização de mapas serão apresentadas nesta seção.

2.9.1 U-Matriz

A matriz de distância unificadas (U-Matriz), foi desenvolvida por Ultsch nos anos 80 para detectar visualmente as regiões formadas pelas relações topológicas dos neurônios, a Figura 18 ilustra um exemplo de mapa gerado pela técnica de Matriz-U (SASSI, 2006; SIQUEIRA, 2010).

Figura 18 – Exemplo de mapa formado por U-Matriz.



Fonte: Modificado de Siqueira (2010).

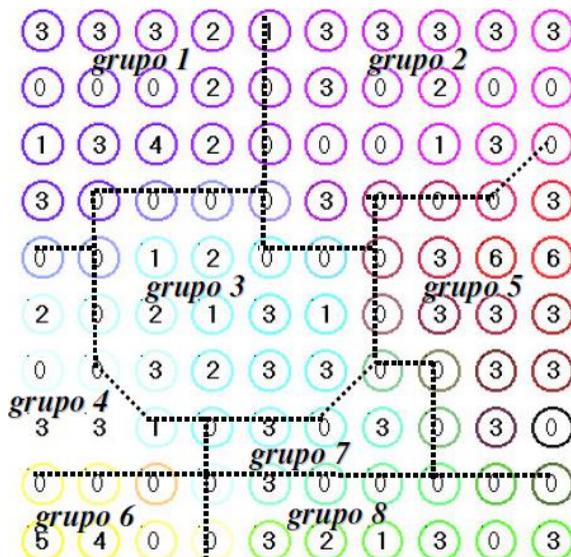
A Matriz-U é um método de segmentação de mapa que utiliza conceitos de processamento de imagem para representar as classes

formadas pelo treinamento, utilizando matrizes de distância de cada neurônio no mapa topológico e sua vizinhança para representar as cores correspondentes (SASSI, 2006; SIQUEIRA, 2010).

2.9.2 Mapa De Densidade

O mapa de densidade é uma técnica que baseia-se no princípio de densidade do mapa, no qual cada neurônio apresenta um nível de atividade. Para cada neurônio, o nível de atividade é calculado com o número de padrões associados ao mesmo e a atividade associada a cada neurônio, forma o mapa de densidade. As regiões de separação das classes também chamadas de “fronteiras” ou “vales”, são criadas utilizando-se neurônios com um número de atividade reduzido, isso possibilita determinar as fronteiras topológicas no mapa. (SIQUEIRA, 2010; ZHANG & LI, 1993). Na Figura 19 é ilustrado o mapa de densidade.

Figura 19 – Exemplo de mapa de densidade.

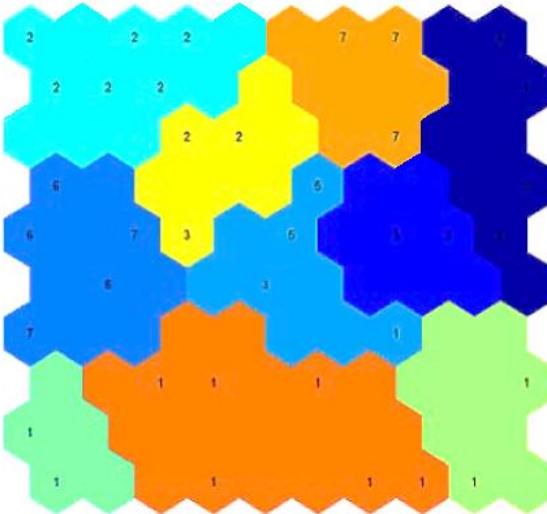


Fonte: Modificado de Siqueira (2010).

2.9.3 Mapa De Contexto

No mapa de contexto deve-se assumir que, além de haver informações disponíveis referentes aos padrões, também deve haver informações das classes que eles pertencem, assim é possível a atribuição de rótulo aos neurônios vencedores, cujo as classes eles representam. Pressupondo que as condições corretas foram seguidas para o desenvolvimento de um mapa característico bem ordenado, o resultado gerado será um mapa particionado em conjuntos distintos coerente aos dados de entrada, (RITTER & KOHONEN, 1989 *apud*. HAYKIN, 2001). A Figura 20 ilustra um exemplo de mapa contextual, no qual utilizou-se o contraste de cores para a representação de 10 grupos rotulados conforme informações das classes (SASSI, 2006).

Figura 20 – Exemplo de Mapa contextual.



Fonte: Modificado de Sassi (2006).

2.10 AVALIAÇÃO DE DESEMPENHO

A avaliação de desempenho no processamento de sinais biomédicos é um processo que visa avaliar o algoritmo através da

habilidade de diferenciar grupos de sinais diferentes através de índices de desempenho. Os índices mais comuns utilizados para avaliação são: sensibilidade, especificidade, eficiência, valor preditivo positivo e valor preditivo negativo. Dentre os índices citados, a Sensibilidade e Especificidade são os índices com maior nível de importância, sendo que o resultado dos outros estão relacionados diretamente a estes, então o objetivo é alcançar o maior valor de acerto possível para Sensibilidade e Especificidade. Para realização dos cálculos dos índices de desempenho são utilizados quatro propriedades (MYATT & JOHNSON, 2009):

- Verdadeiro Positivo (VP): é o número de observações definidas como verdadeiras e que são verdadeiramente verdadeiras;
- Verdadeiro Negativo (VN): é o número de observações definidas como falsas e que são verdadeiramente falsas.
- Falso positivo (FP): é o número de observações que são incorretamente definidas como positivas, mas que são, de fato, negativas.
- Falso Negativo (FN): é o número de observações que são incorretamente definidas como negativas, mas que são, de fato, positivas.

Essas quatro propriedades podem ser ilustradas em forma de uma tabela de contingência conforme a Tabela 1.

Tabela 1: Tabela de contingência.

		Resposta Real	
		Positivo	Negativo
Predição	Positivo	VP	FP
	Negativo	FN	VN

Fonte: Modificado de Myatt & Johnson (2009).

A sensibilidade indica o valor percentual de VP, ou seja, é a razão entre o número de observações identificadas como VP e o número de observações indicadas como positivas, ou seja, é a capacidade que o teste tem de diagnosticar corretamente os doentes, esta é calculada conforme a Equação 11.

$$\text{sensibilidade}(\%) = \frac{VP}{VP + FN} \times 100 \quad (11)$$

A Especificidade indica o valor percentual de VN, ou seja, é a razão do número de VN pelo número de observações indicadas como negativas, ou seja, é a capacidade que o teste tem de diagnosticar corretamente os sadios, esta é calculada conforme a equação 12.

$$\text{especificidade}(\%) = \frac{VN}{VN + FP} \times 100 \quad (12)$$

A eficiência total percentual de um sistema pode ser calculada através da razão entre o número de classificações corretas pelo número total de observações, esta é a probabilidade do teste fornecer resultados corretos, ou seja, ser positivo nos doentes e negativo nos não doentes. é calculada conforme a equação 13.

$$\text{eficiência}(\%) = \frac{VN + VN}{VP + FP + FN + VN} \times 100 \quad (13)$$

O valor preditivo positivo (VPP) percentual, também chamado de precisão ou seletividade positiva, é a razão entre o número de observações preditivas positivas corretamente classificados pelo número total de observações preditivas positivas indicados, conforme a equação 14.

$$VPP(\%) = \frac{VP}{VP + FP} \times 100 \quad (14)$$

O valor preditivo negativo (VPN) percentual, também chamado de seletividade negativa, é a razão entre o número total de observações preditivas negativas corretamente classificados pelo número de predições negativas indicadas, esta é calculada conforme a equação 15.

$$VPN(\%) = \frac{VN}{VN + FN} \times 100 \quad (15)$$

2.11 TRABALHOS DESENVOLVIDOS NA ÁREA

Ghosh-Dastidar & Adeli (2009) propuseram a utilização de um modelo de RNA utilizando aprendizado supervisionado para classificação de eventos em sinais de EEG; foi utilizado um banco de sinais com 300 segmentos de sinais de EEG considerados todos EE, sendo utilizado 30 eventos para o treinamento e não foi especificado o número de eventos para o teste. O resultado obtido para eficiência foi de 90 a 94%.

Scolaro & Azevedo (2010) propuseram um sistema classificador de EE e ENE em sinais de EEG utilizando processamento de sinais com Transformada *Wavelet* em conjunto com RNA. O estudo utilizou um banco de sinais de EEG com 685 segmentos classificados em EE e ENE divididos em 3 grupos: treinamento com 200 padrões, validação com 200 padrões e teste com 285 padrões. O resultado obtido para eficiência foi de 96%.

Abibullaev *et al.*, (2010) propuseram a utilização da Transformada *Wavelet* contínua em conjunto com RNA para o reconhecimento de EE. O estudo utilizou um conjunto de 100 segmentos de sinal de EEG para treinamento e 500 para teste, não havendo mais informações sobre os conjuntos. O resultado obtido para eficiência foi de 94%.

Igasaki *et al.*, (2011) propuseram a utilização de RNA para o reconhecimento de EE utilizando um conjunto de 400 segmentos de sinal de EEG (normal e EE) para treinamento e 200 para teste, não havendo maiores informações sobre os conjuntos de padrões utilizados. O resultado obtido para eficiência foi de 81%.

Anusha *et al.*, (2012) propuseram a utilização de RNA para o reconhecimento de padrões em sinal de EEG com o uso de 100 segmentos de EEG sendo utilizado 50 segmentos para o treinamento e 50 para teste (25: normal, 25: EE). O resultado obtido para eficiência foi de 93%.

Shen *et al.*, (2013) apresentaram a utilização de Transformada *Wavelet* com RNA para a classificação de EE utilizando um conjunto de 712 segmentos de sinal de EEG (normal e EE) divididos em 356 segmentos para treinamento e 356 para teste, não havendo informações detalhadas sobre os conjuntos de padrões utilizados. O resultado obtido para eficiência foi de 99%.

Artameeyanant *et al.*, (2013) apresentaram a utilização da Transformada *Wavelet* com RNA para o reconhecimento de EE, porém não havendo informações acerca do conjunto de eventos utilizados. Os resultados obtidos para sensibilidade, especificidade e eficiência foram 76, 81 e 89%, respectivamente.

O estudo de Asha *et al.*, (2013) propuseram a classificação automática de EE com a utilização de máquina de vetores de suporte em conjunto com RNA *feedforward*. O estudo utilizou um conjunto de 1600 segmentos de sinais de EEG para o treinamento e o mesmo conjunto foi utilizado para o teste. O resultado obtido para eficiência foi de 75%.

O estudo de Gopika *et al.*, (2013) propuseram a utilização de decomposição *Wavelet* em conjunto com um sistema *Neuro-fuzzy* adaptativo para classificação de eventos em sinais de EEG. Neste estudo foram utilizados 500 segmentos de sinal de EEG (normal e EE), o qual 400 foram utilizados para o treinamento e 100 para o teste, não havendo especificação acerca do número de eventos de cada classe. O resultado obtido para eficiência foi de 100%.

O estudo de Sharanreddy & Kulkarni (2013) propuseram a utilização da combinação de Transformada *Multi-Wavelet* com RNA, não havendo porém, informações acerca do conjunto de padrões utilizados para treinamento e teste. O resultado obtido para eficiência foi de $\cong 80\%$.

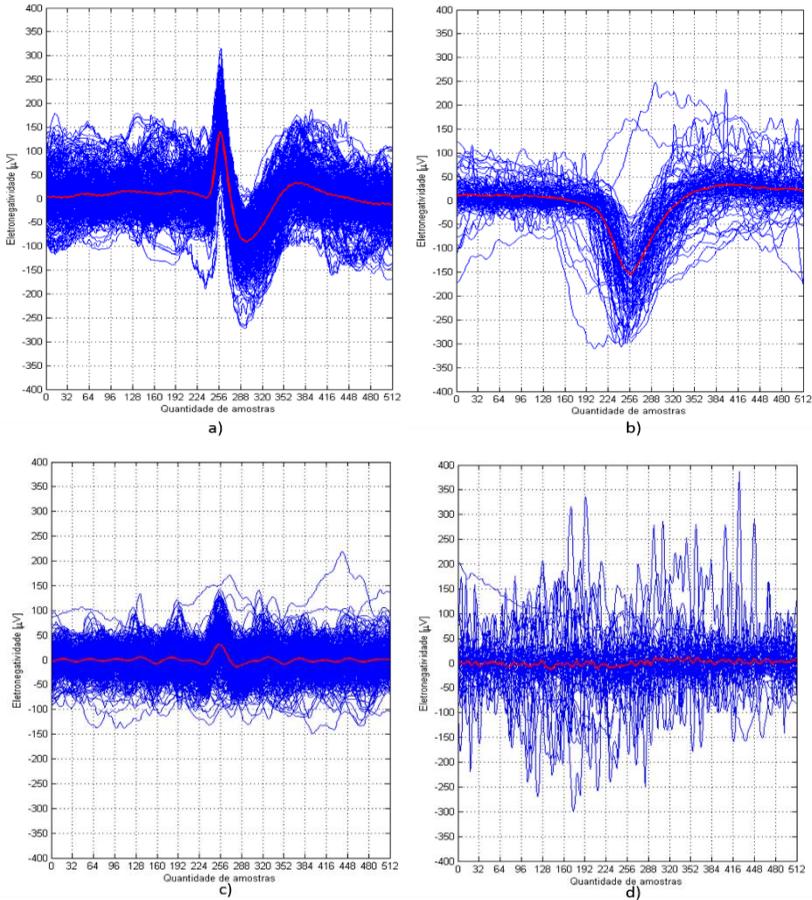
3 METODOLOGIA

3.1 BANCO DE SINAIS DE EEG

Os sinais de EEG utilizados neste estudo foram fornecidos pelo CEPESC ao IEB-UFSC, fazendo-se necessário a aprovação de um projeto junto ao comitê de ética por se tratar de seres humanos, no qual foi submetido e aprovado pelo comitê de ética em pesquisa com seres humanos da Universidade Federal de Santa Catarina. Os sinais adquiridos são de pacientes diagnosticados epiléticos, e são os mesmos utilizados por Scolaro (2009) em seu estudo. O conjunto de registros contém 1132 sinais, que foram adquiridos com frequência de amostragem de 512 Hz utilizando 32 canais com montagem referencial (referência do equipamento). Os sinais foram registrados pelo sistema CEEgraph Vision EEG®, passando por um processamento de filtragem que utilizou-se filtros passa-altas de 1 Hz e filtro passa-baixa de 35 Hz.

Primeiramente para a realização das análises e simulações desenvolvidas neste trabalho, foram selecionados 1132 segmentos de sinal de EEG com duração de 4 segundos, sendo que foi utilizado apenas um segundo central como entrada da RNA. Estes segmentos formam quatro classes distintas de padrões, eventos epileptiformes, atividade de fundo normal, piscadas e ruídos/artefatos (gerados a partir de atividade muscular, interferência eletromagnética, entre outros). Os conjuntos dos grupos de eventos analisados foram centralizados no período do segmento e estão representados na Figura 21.

Figura 21- Morfologia apresentada nos conjuntos de eventos: a) epileptiformes, b) piscadas, c) atividade de fundo normal, e d) ruídos/artefatos.



Fonte: Próprio autor.

A Figura 21 apresenta o segmento de sinal de um segundo com o evento centralizado na janela, sua amplitude, quantidade de amostras e o ponto médio entre todos os padrões de cada classe.

A etapa seguinte foi o desenvolvimento da RNA, para a qual optou-se pelo desenvolvimento de um *software* protótipo chamado Sistema Classificador Kohonen para Eventos Epileptiformes (SCKEE). Após a conclusão do protótipo iniciou-se a fase de treinamento das redes, onde realizou-se inúmeras simulações para determinar quais seriam as

configurações de parâmetros ideais para a fase de treinamento. Optou-se pelo treinamento das redes utilizando tanto a parada antecipada, quanto a parada por número de épocas. A avaliação do classificador neural foi através do método que utiliza índices de desempenho como Sensibilidade, Especificidade, Seletividade Positiva, Seletividade Negativa e Eficiência.

Ao longo desse capítulo serão abordados detalhadamente os procedimentos descritos anteriormente.

3.2 CONJUNTO DE PADRÕES DE EEG

Para a realização dos experimentos os conjuntos de segmentos de sinais foram separados em dois grupos, grupo 1 de treinamento e grupo 2 de testes, de modo que a divisão dos grupos fosse a mais balanceada possível. Para a separação destes seguiu-se alguns procedimentos descritos a seguir: primeiramente adotou-se a seleção de padrões de modo aleatório, no qual os grupos foram ordenados em ordem alfabética; após foi realizada a separação dos grupos em duas partes, considerando a primeira parte a partir do primeiro elemento até aproximadamente 50% do número total de segmentos de cada grupo para o conjunto de treinamento e o restante dos segmentos foram destinados ao conjunto de teste. Durante o processo de separação não houve elementos duplicados nos diferentes grupos, mantendo-se a distinção entre estes. Na Tabela 2 é apresentado o número de padrões de cada grupo utilizados no presente estudo.

Tabela 2 – Número de padrões utilizados nos experimentos do estudo.

Grupo de padrões	Paroxismos	Atividade de fundo	Piscadas	Ruídos	Total
Treinamento	236	245	54	35	570
Teste	239	248	54	21	562
Total	475	493	108	56	1132

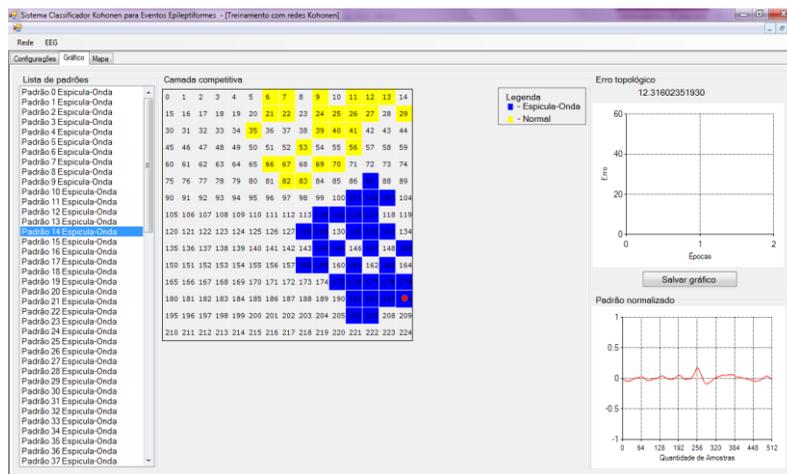
Fonte: Próprio autor.

3.3 DESENVOLVIMENTO DO MAK

A escolha pelo desenvolvimento de um *software* específico para o processamento de sinais de EEG partiu da premissa que, ao optar pela utilização de sistemas como MatLab®, NetBeans® ou outros que possuem implementação de ferramentas de RNA, a utilização destes poderia limitar algumas possibilidades de configurações de parâmetros, desempenho e principalmente de otimização do algoritmo de RNA, como descrito no trabalho de Sala (2005). Então, realizou-se o estudo para escolha da linguagem de programação para o desenvolvimento do protótipo, no qual foi analisado os paradigmas Programação Estruturada e Orientação a Objetos, optando-se pela Programação Orientada a Objetos, por apresentar algumas características como generalidade para programação e a capacidade de evitar a escrita de códigos similares repetidamente, o qual consome tempo e recursos em programar novas rotinas similares as que já foram desenvolvidas. Na Programação Orientada a Objetos os códigos desenvolvidos podem ser reutilizados, facilitando a continuidade da programação por outros pesquisadores. Assim optou-se pela utilização da linguagem de programação C#, que é totalmente Orientada a Objetos (KIANG, 2001; LINDEN, 2008). Após a etapa da escolha da linguagem de programação foi desenvolvido o algoritmo MAK conforme descrito na seção 2.8, no qual este foi incorporado no *software* protótipo SCKEE.

O código desenvolvido foi verificado por meio de testes de forma independente dos componentes específicos e comparando os resultados gerados pelo computador com cálculos manuais. Os experimentos do protótipo foram realizados em um computador com processador Core 2 duo de 2.0 GHz; os cálculos estatísticos foram realizados pelo *software* Excel®. Para o formato das redes optou-se por desenvolver redes retangulares de quatro tamanhos, $10 \times 10 = 100$ neurônios, $15 \times 15 = 225$, $20 \times 20 = 400$ neurônios e $30 \times 30 = 900$ neurônios, conforme ilustrado na Figura 22, que apresenta a rede de tamanho 225.

Figura 22 – Tela do SCKEE com rede de tamanho 225 neurônios na camada competitiva.



Fonte: Próprio autor.

O módulo de treinamento apresentado na Figura 23 possui parâmetros de configurações agrupados por áreas. A Figura 23 (a) apresenta as seguintes opções de configurações:

- número de épocas – parâmetro para treinar de 1 a 10.000 épocas;
- critério de parada – parâmetro que utiliza o erro topográfico para determinar o tempo de parada antecipada quando o valor estipulado é alcançado;
- camada competitiva – parâmetro de escolha do tamanho da camada competitiva que será utilizada no treinamento;
- funções de ativação de vizinhança – parâmetro de escolha entre as funções Discreta, Gaussiana, “Chapéu Mexicano” e “Chapéu Francês”, implementadas conforme as equações: 4, 5, 6 e 7, respectivamente.

Na Figura 23 (b) são apresentadas as configurações relacionadas a manipulação de arquivos:

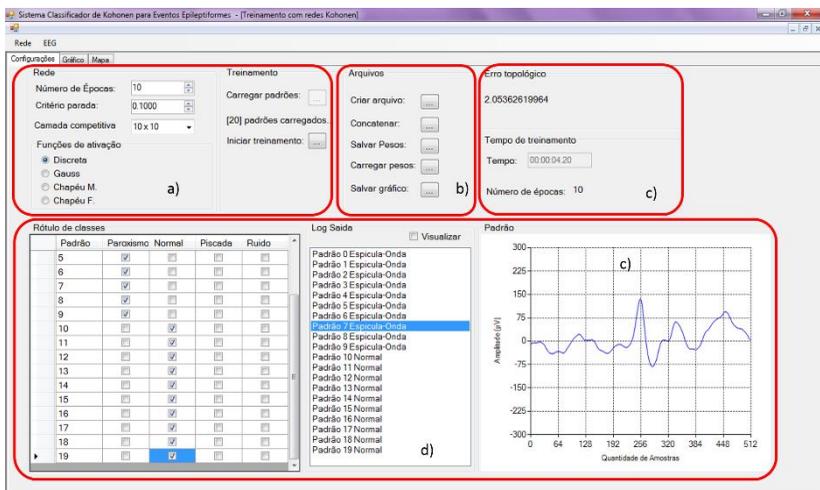
- carregar arquivo – opção que carrega os segmentos de sinais para apresentação na rede;

- criar arquivo – opção que cria um novo arquivo para montagem;
- concatenar – opção que cria o padrão de montagem dos segmentos;
- salvar pesos – opção para salvar os pesos da rede após o treinamento;
- carregar pesos – opção para carregar arquivo de pesos;
- salvar gráfico – opção para salvar em arquivo os gráficos visualizados.

A Figura 23 (c) apresenta as informações de número de épocas percorridas durante o treinamento, contagem do tempo e erro topológico da rede durante o treinamento; na Figura 23 (d) é apresentada a configuração de rótulos, lista e visualização de padrões.

Figura 23 – Tela de configurações do módulo de treinamento do SCKEE:

a) configurações de rede, b) configurações de arquivos, c) informações do sistema, d) configurações e visualização de padrões.

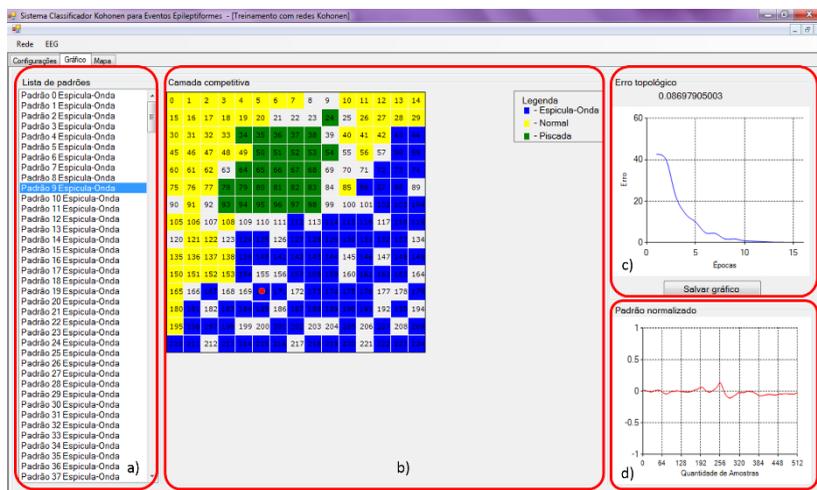


Fonte: Próprio autor.

A tela de visualização da camada competitiva (Figura 24) possibilita a visualização da formação dos mapas em tempo de execução,

ou seja, a cada época percorrida do algoritmo é ilustrado no mapa bidimensional os neurônios vencedores.

Figura 24 – Tela de visualização da camada competitiva do módulo de treinamento do SCKEE : a) lista de padrões, b) visualização de mapas, c) visualização de erro topológico e d) visualização de padrões normalizados.



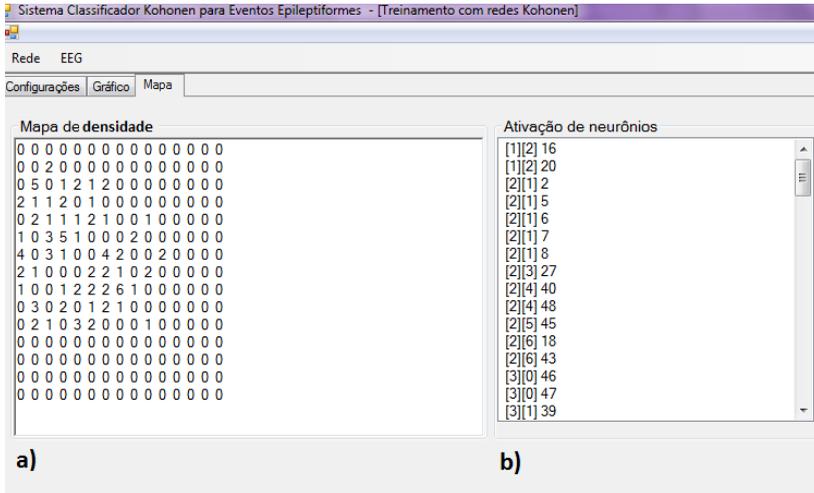
Fonte: Próprio autor.

Para o desenvolvimento da tela de visualização da camada competitiva, os algoritmos seleção de padrões e mapas de contexto foram desenvolvidos conforme o item 2.9.3 e estão ilustrados na Figura 24 (a) e (b); estes têm a função de confirmar a localização dos padrões com sua posição topológica nos mapas bidimensionais gerados pelo treinamento. A confirmação para verificar se o padrão foi organizado corretamente conforme a sua classe é realizada ao selecionar um padrão na lista de padrões, o qual mostrará simultaneamente a posição (linha x coluna) correspondente do padrão, com a posição do neurônio vencedor no mapa bidimensional e, ainda, sua morfologia normalizada conforme a equação 2, (Figura 24 (d)). A Figura 24 (c) ilustra o gráfico de erro topográfico do treinamento da rede implementado conforme a equação 9.

O algoritmo de mapa de densidade foi desenvolvido conforme descrito no item 2.9.2 e pode ser visualizado através da Figura 24 (a), o qual além da função de mostrar a atividade dos neurônios da camada competitiva, também tem função de confirmar juntamente com o mapa de contexto, o número de neurônios vencedores e o número de associação de

padrões a estes. Na Figura 24 (b) é ilustrada a lista de ativação de neurônio com a função de validar os valores gerados pelo mapa de densidade.

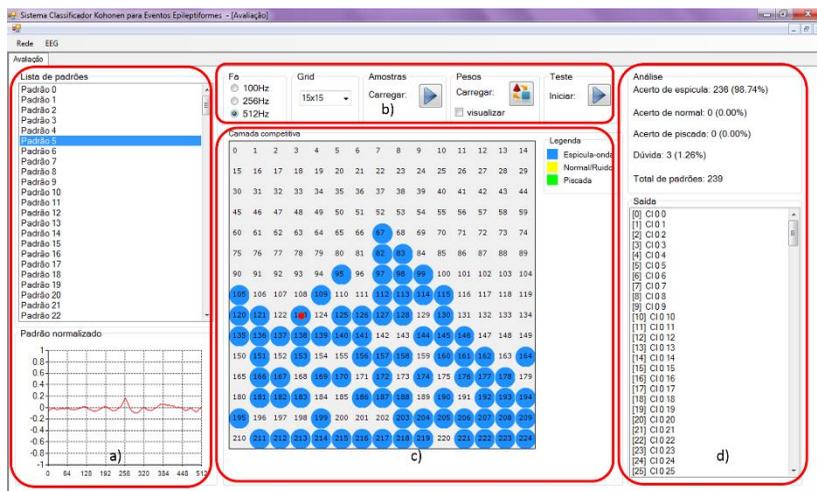
Figura 25 – Tela de visualização de mapa de densidade do módulo de treinamento do SCKEE: a) mapa de densidade, b) ativação de neurônio.



Fonte: Próprio autor.

O módulo de teste apresentado na Figura 26 possui as seguintes ferramentas: (a) lista de padrões e a visualização de padrões normalizados; (b) são ilustradas os parâmetros de configurações de frequência de amostragem, tamanho da camada competitiva, carregamento do conjunto de padrões, visualização de pesos e o botão de inicialização de teste; (c) apresenta o mapa bidimensional de classificação de padrões; (d) é apresentado os parâmetros de análise estática com o cálculo de porcentagem de acerto do classificador e a lista dos neurônios vencedores, os padrões associados aos vencedores e a classe pertencente a cada neurônio vencedor. Para realizar a classificação dos padrões conforme a sua classe correspondente, o módulo de teste utiliza o cálculo da distância euclidiana e o conjunto de pesos treinados.

Figura 26 – Tela de classificação do módulo de teste do SCKEE: a) lista de padrões e visualização de normalização, b) configurações, c) mapa bidimensional e d) análise do classificador.



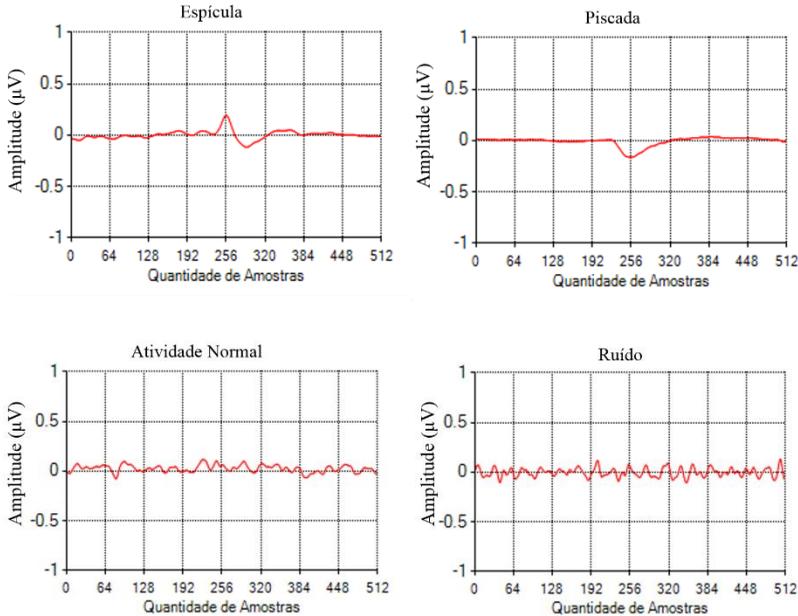
Fonte: Próprio autor.

3.4 TREINAMENTO

Para o treinamento do SCKEE foram selecionados três tamanhos de redes, 100, 225 e 400 neurônios, no qual cada tamanho foi testado com as quatro funções de vizinhança implementadas, resultando em 12 redes treinadas. O treinamento foi realizado com a taxa de aprendizado (α) iniciada com valor 0,5 decaindo com o tempo conforme descrita no item 2.8, na fase de refinamento ou convergência a taxa de aprendizagem foi fixada em 0,01. O critério utilizado para finalizar o treinamento foram dois: parada antecipada conforme a equação 8, no qual o valor de erro mínimo foi fixado em 0,001 e a parada por número máximo de épocas, na qual todas as redes tiveram configuradas para parar com 1000 épocas de treinamento, o critério de parada estabelecido foi o qual ocorresse primeiro. A apresentação dos padrões para o treinamento realizou-se de modo aleatório utilizando uma função randômica disponível da linguagem de programação utilizada e aplicada a normalização unitária nos conjuntos de padrões conforme a equação 2. Na Figura 27 é ilustrado

quatro tipos de sinais de entrada após a aplicação da normalização unitária.

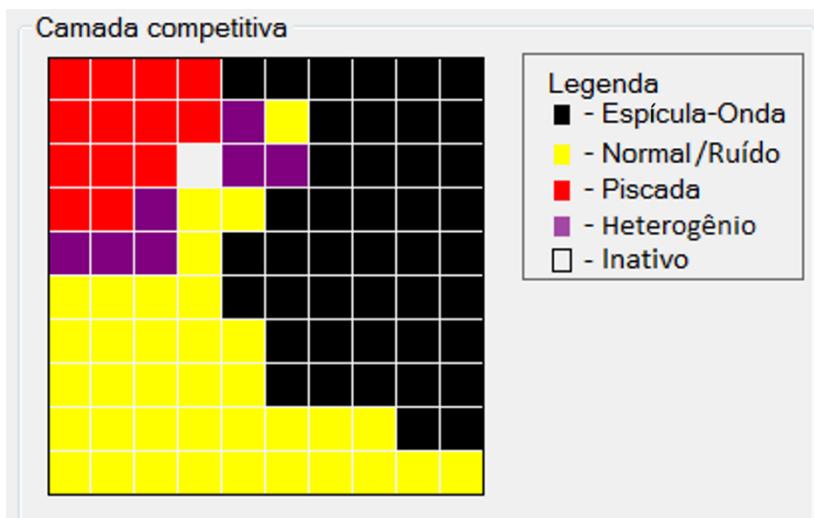
Figura 27 – Conjunto de Sinais normalizados.



Fonte: Próprio autor.

Para realizar a geração dos mapas na fase de treinamento, foi utilizado duas técnicas, Mapa de Contexto e Mapa de Densidade descritas no item anterior. Na figura 28 é ilustrada a separação das classes no SCKEE em eventos epileptiformes, piscadas, atividades de fundo e normal/ruído; as classes pertencentes a atividade normal e ruído foram agrupadas pela conveniência de gerar um mapa mais distinto, já que as duas classes sempre ocupam a área restante da piscada e dos eventos epileptiformes. No exemplo utilizou-se a rede de tamanho 10x10 com a técnica de Mapa de Contexto, no qual cada classe recebeu um rótulo de cor correspondente a sua classe.

Figura 28 – Rede com tamanho 10x10 e formação do mapa de contexto.

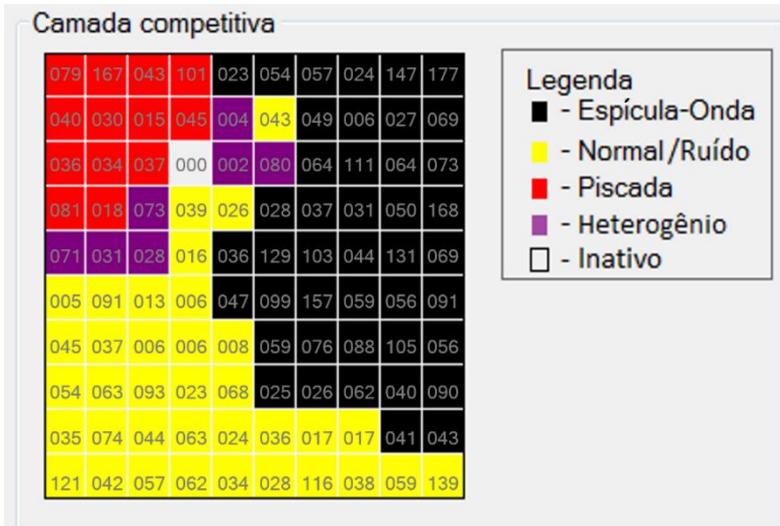


Fonte: Próprio autor.

Na Figura 28 além das classe formadas com os seus rótulos correspondentes, ainda pode-se observar os neurônios heterogêneos de cores roxas que não são rotulados pelo especialista, e sim pelo SCKEE; os neurônios heterogêneos são formados quando um mesmo neurônio foi declarado vencedor para padrões de classes diferentes. O neurônio vencedor heterogêneo foi utilizado para definir as fronteiras entre as classes juntamente com os neurônios inativos, aqueles que não participaram do treinamento.

Conforme apresentado no mapa de densidade na Figura 29, é possível visualizar além da formação das classes separadas correspondentes aos padrões apresentados à rede, o nível de atividade correspondente a cada neurônio da rede pelo Mapa de Densidade, no qual utilizou-se para confirmar a atividade dos neurônios vencedores e aqueles que tiveram pouca ou nenhuma atividade nas regiões. Os neurônios que obtiveram nível de atividade baixo ou nulo também foram utilizados para definir as fronteiras entre as classes.

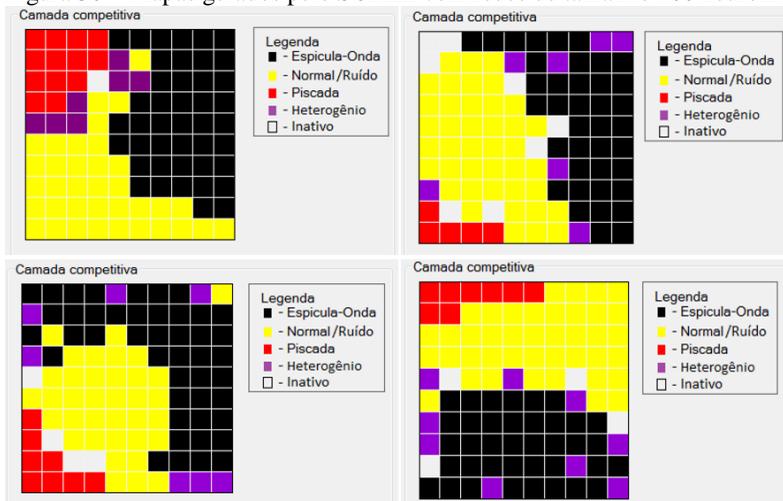
Figura 29 – Mapa de densidade gerado pelo SCKEE.



Fonte: Próprio autor.

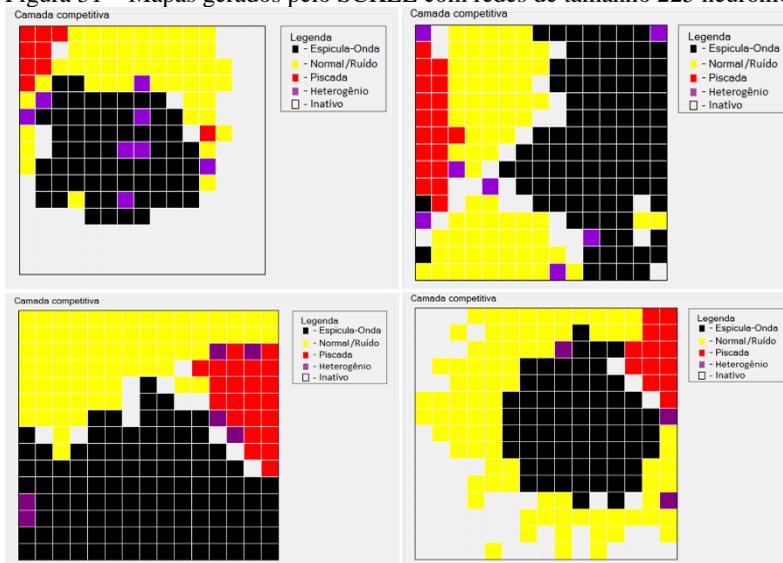
Nas Figuras 30, 31 e 32 são ilustrados os mapas gerados pelo SCKEE através dos algoritmos desenvolvido na fase de treinamento, com 4 mapas para cada tamanho de rede treinada (10x10, 15,15 e 20x20), em cada tamanho de rede foram selecionados 4 redes treinadas com cada função de vizinhança implementada totalizando as 12 redes, nas quais estas foram utilizados na fase de testes para a classificação dos padrões.

Figura 30 – Mapas gerados pelo SCKEE com redes de tamanho 100 neurônios.



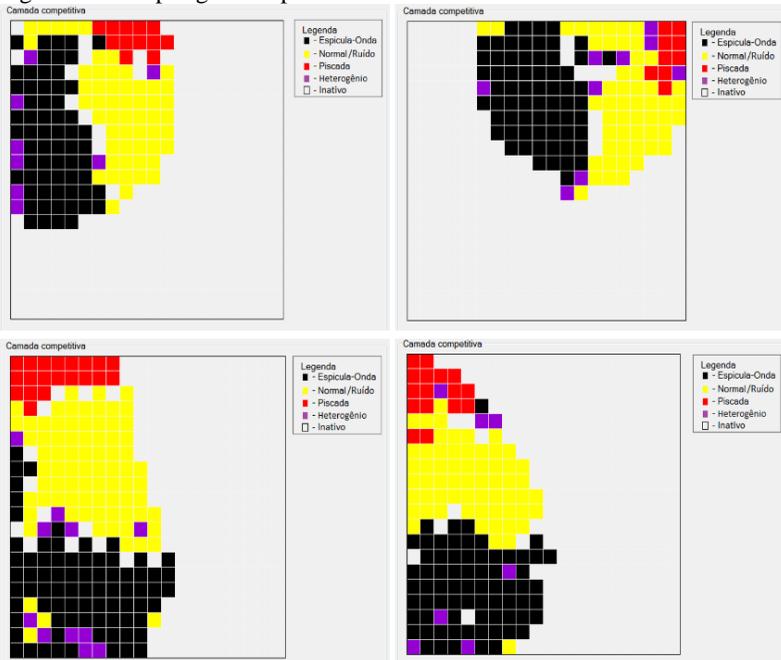
Fonte: Próprio autor.

Figura 31 – Mapas gerados pelo SCKEE com redes de tamanho 225 neurônios.



Fonte: Próprio autor.

Figura 32 – Mapas gerados pelo SCKEE com redes de tamanho 400 neurônios.



Fonte: Próprio autor.

3.5 TESTES

A avaliação do SCKEE foi realizada utilizando o conjunto de sinais do Grupo 2 para testes conforme a Tabela 2, no qual cada conjunto foi submetido em cada uma das 12 redes treinadas (Figuras 30, 31 e 32). Os critérios de avaliação seguiram o método de teste de diagnóstico, baseado na comparação da tabela de contingência (Tabela 3), no qual é realizada a comparação entre os resultados obtidos pelo sistema e a definição do especialista.

Os valores obtidos de certo ou errado na classificação pelo sistema, levaram em consideração os valores classificados na região caracterizada como duvidosa, ou seja a qual onde os neurônios vencedores são heterogêneos, assim para cada grupo de eventos testados, aqueles eventos que foram classificados nestes neurônios, foram considerados como sendo falsos.

Os parâmetros utilizados para a avaliação do sistema foram Sensibilidade, Especificidade, Valor Preditivo Positivo, Valor Preditivo Negativo e Eficiência. Através dos valores de classificação (certo ou errado) gerados pelo SCKEE, pôde-se calcular as propriedades necessárias (VP, VN, FP e FN) para o cálculo dos índices de desempenho.

Tabela 3 – Tabela de contingência adaptada para classes de Eventos Epileptiforme (EE) e Eventos Não Epileptiforme (ENE).

		SCKEE	
		EE	ENE
Especialista	EE	VP	FP
	ENE	FN	VN

Fonte: Próprio autor.

Os indicadores VP e VN indicam concordância na classificação das decisões corretas do SCKEE com o especialista, enquanto os indicadores FP e FN indicam discordância na classificação.

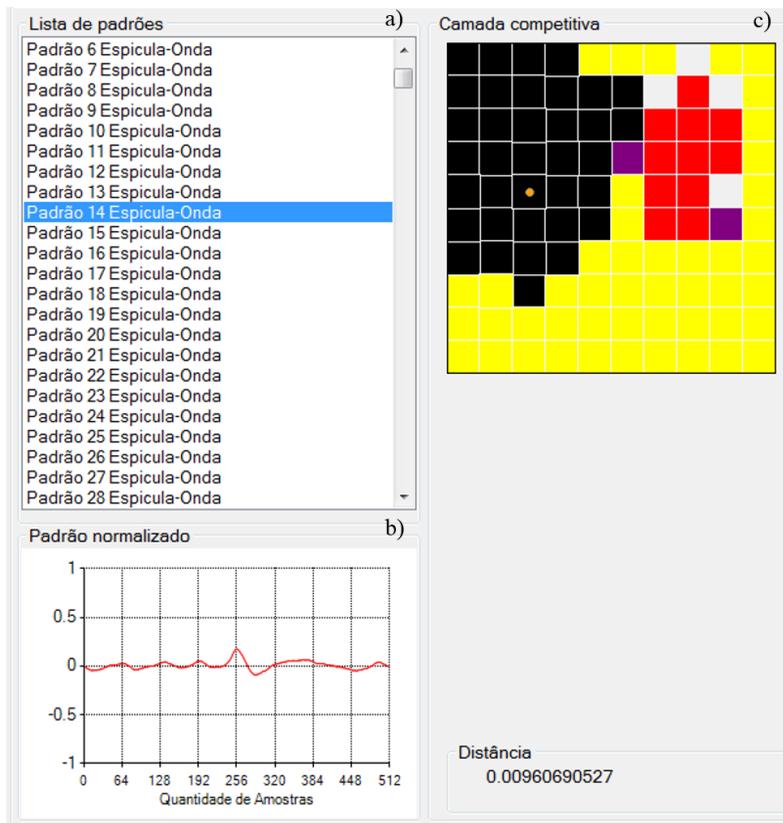
A sensibilidade, especificidade, eficiência, valor preditivo positivo e valor preditivo negativo foram calculadas conforme as equações 11, 12, 13, 14 e 15.

4 RESULTADOS E DISCUSSÕES

Os resultados obtidos com o desenvolvimento do algoritmo MAK, quando comparados com a utilização de ferramentas que utilizam redes prontas, proporciona algumas vantagens, tais como melhor desempenho de processamento, generalização de sinais de entrada, interpretação e visualização de dados e flexibilidade de configuração.

Um exemplo do conjunto de ferramentas para visualização e confirmação de sinais testados é apresentado na Figura 32.

Figura 33 – Ferramentas de confirmação e visualização de sinais: a) Lista de padrões; b) Gráfico de padrões e c) Mapa bidimensional.



Fonte: Próprio autor.

Na Figura 32 é apresentado o conjunto de ferramentas desenvolvido para a confirmação e visualização dos padrões de entrada e suas classes pertencentes. Observar a seleção de um padrão para análise na lista de padrões (a), no qual é apresentado de forma simultânea o gráfico correspondente em (b), juntamente com a posição do neurônio vencedor do padrão selecionado para análise no mapa bidimensional em (c). O conjunto destas ferramentas auxiliam na análise dos padrões de modo que esta possa ser realizada visualmente, facilitando a confirmação e a compreensão dos resultados gerados pelo MAK.

O sistema protótipo desenvolvido com redes de Kohonen obteve características de generalização para identificação de padrões. Além do treinamento e teste para reconhecimento de eventos em sinais de EEG, a rede pode ser facilmente adaptada para reconhecer outros sinais, para tanto, a entrada do sistema pode aceitar outros tipos de sinais, como por exemplo: eventos em sinais de eletrocardiograma que possam caracterizar doenças cardíacas, também pode-se ampliar a sua utilização não somente para identificação de doenças mas para a classificação geral de qualquer tipo de padrões em qualquer área, como por exemplo: classificação de proteínas, aminoácidos, imagens etc.; desta forma para a sua utilização para outros padrões, basta adequar a taxa de amostragem na entrada da rede conforme a necessidade, assim será possível a realização da classificação e interpretação dos dados.

A característica de flexibilidade obtida no SCKEE, proporciona a não possuir limitação de ajustes de parâmetros (taxa de aprendizagem, números de épocas, tamanho de rede, critério de parada e função de ativação de vizinhança). Quanto a importância de ter desenvolvido o mapa de visualização bidimensional, este pode ser utilizado como ferramenta de auxílio para tomada de decisão, pois permite uma visualização mais clara dos neurônios vencedores, auxiliando na explicação sobre os padrões que estão sendo analisados.

O SCKEE utilizado para o treinamento e testes das redes foi avaliado através da metodologia que utiliza os índices de desempenho de sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e eficiência, apresentados na tabela 5. Os valores obtidos para os parâmetros (VP, VN, FP e FN) utilizados para o cálculo dos índices de desempenho são apresentados na Tabela 4.

Tabela 4 - Valores dos parâmetros (VP, VN, FP e FN) avaliados nos testes.

Rede	Função	Tam.	VP %	VN %	FP %	FN %	TOTAL %	Nº de padrões testados
1	Discreta	100	42.67	50.48	5.52	1.33	100	562
2	Gaussiana	100	40.94	25.85	29.06	4.15	100	562
3	Chapéu M.	100	42.40	48.30	8.94	0.36	100	562
4	Chapéu F.	100	38.67	30.47	22.85	8.01	100	562
5	Discreta	225	40.42	49.23	6.13	4.21	100	562
6	Gaussiana	225	41.36	28.86	27.21	2.57	100	562
7	Chapéu M.	225	43.54	51.11	4.80	0.55	100	562
8	Chapéu F.	225	45.75	48.46	5.60	0.19	100	562
9	Discreta	400	41.38	49.09	9.33	0.20	100	562
10	Gaussiana	400	42.89	48.33	6.90	1.88	100	562
11	Chapéu M.	400	42.61	47.67	8.75	0.97	100	562
12	Chapéu F.	400	45.01	47.89	5.99	1.11	100	562

Legenda: Tam.: Tamanho; VP%: Verdadeiro Positivo; VN%: Verdadeiro Negativo; FP%: Falso Positivo; FN%: Falso Negativo.
 Fonte: Próprio autor.

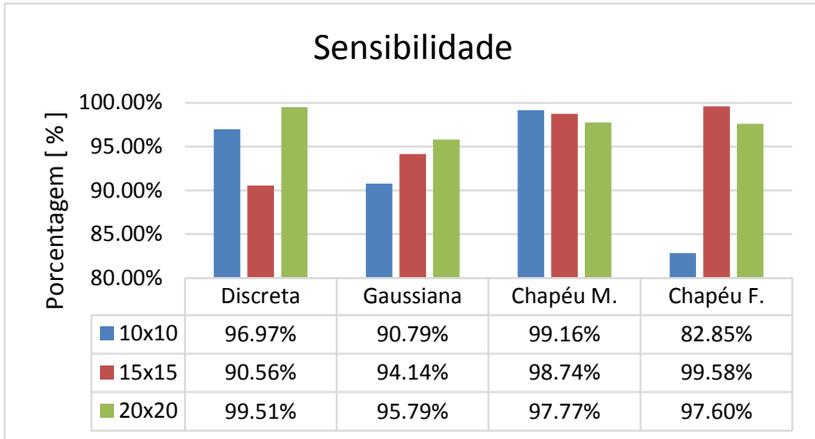
Tabela 5 –Valores obtidos dos índices de desempenho.

Rede	Sensibilidade %	Especificidade %	VPP %	VPN %	Eficiência %	Nº de padrões testados
1	96.97	90.14	88.54	97.43	93.14	562
2	90.79	47.08	58.49	86.16	66.79	562
3	99.16	84.38	82.58	99.26	90.70	562
4	82.85	57.14	62.86	79.19	69.14	562
5	90.56	88.93	86.83	92.11	89.66	562
6	94.14	51.48	60.32	91.81	70.22	562
7	98.74	91.42	90.08	98.93	94.65	562
8	99.58	89.64	89.10	99.60	94.21	562
9	99.51	84.03	81.60	99.59	90.47	562
10	95.79	87.50	86.13	96.25	91.21	562
11	97.77	84.48	82.95	98.00	90.27	562
12	97.60	88.89	88.26	97.74	92.90	562

Legenda: VPP – Valor Preditivo Positivo; VPN – Valor Preditivo Negativo. Fonte: Próprio autor.

Com base nos valores apresentados na tabela 5, foram elaboradas as Figuras 34, 35, 36, 37 e 38 para ilustrar os índices de desempenho para avaliação do SCKEE.

Figura 34 – Gráfico de Sensibilidade percentual para as funções de vizinhança e tamanho de rede avaliados.

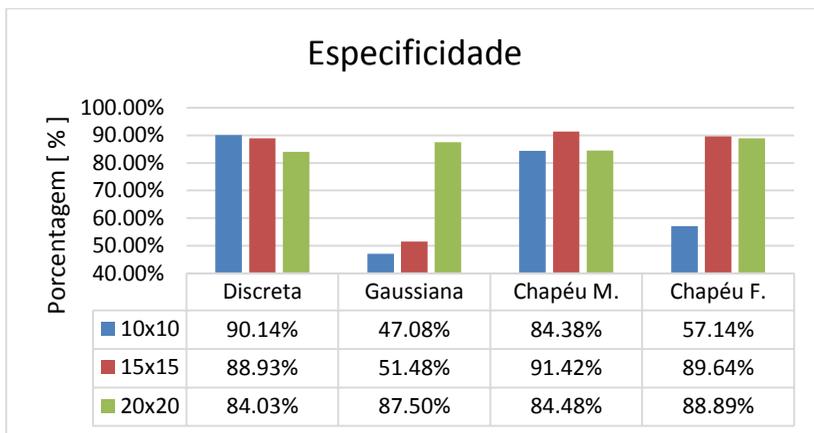


Fonte: Próprio autor.

Na Figura 34 são apresentados os valores percentuais obtidos para Sensibilidade, com destaque para a função do tipo “Chapéu Mexicano”, na qual obteve-se Sensibilidade de 98,74% para a rede de tamanho 15x15; para rede de tamanho 10x10, 99,16%, e para rede de tamanho 20x20 obteve-se Sensibilidade de 97,16%. Podendo-se observar que houve ganho de Sensibilidade para a rede de tamanho 10x10 e perda para o tamanho de 20x20, quanto para a rede de tamanho 20x20 nas funções “Chapéu Mexicano” e “Chapéu Francês”, obtiveram Sensibilidade similares.

A função “Chapéu Francês” apresentou o menor valor percentual de Sensibilidade para a rede de tamanho 10x10, com 82,85%, e obteve Sensibilidade de 99,58% para rede de tamanho 15x15; A função Gaussiana obteve Sensibilidade de 95,79% na rede de tamanho 20x20, sendo que o valor percentual de Sensibilidade diminuiu para rede de tamanho 10x10 e 15x15; A função Discreta obteve o melhor resultado de Sensibilidade na rede de tamanho 20x20 com percentual de 99,51%, já na rede de tamanho 15x15 obteve a menor Sensibilidade de 90,56% e na rede de tamanho 10x10 obteve Sensibilidade de 96,97%.

Figura 35 – Gráfico de Especificidade percentual para as funções de vizinhança e tamanho de rede avaliados.

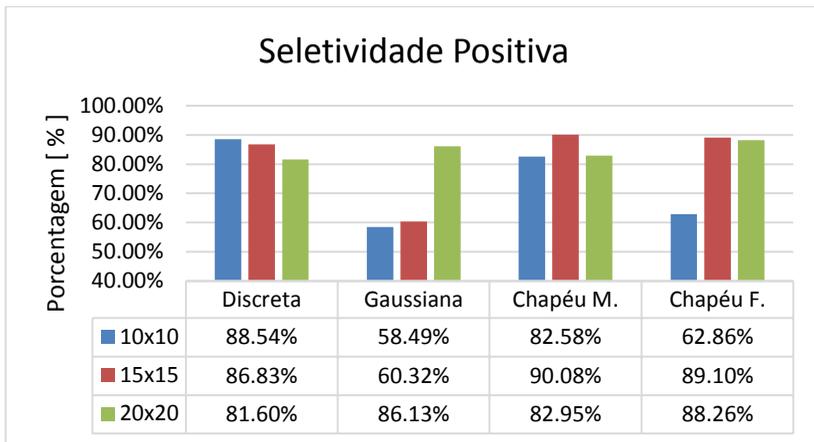


Fonte: Próprio autor.

Na Figura 35 são apresentados os valores percentuais obtidos para Especificidade, destacando as funções do tipo “Chapéu Mexicano” e Discreta, que obtiveram a maior percentagem. Na função “Chapéu Mexicano” obteve-se Especificidade de 91,42% para a rede de tamanho 15x15, e para função Discreta obteve-se 90,14% para rede de tamanho 10x10, além disto, pode-se destacar que ambas apresentaram perda de especificidade com o aumento do tamanho da rede para 20x20. Já a função do tipo “Chapéu Francês” obteve Especificidade de 89,64% para a rede de tamanho 15x15, apresentando perda de Especificidade com a diminuição e aumento de tamanho da rede, porém pode-se observar que a função tem perda menor quando comparada com as funções Gaussiana.

A função Gaussiana obteve o menor valor percentual entre as funções, com Especificidade de 47,08% para rede de tamanho 10x10 e especificidade de 51,48% para a rede 15x15, também pode-se observar o comportamento crescente da especificidade conforme o aumento do tamanho da rede, chegando a 87,50% de especificidade na rede de tamanho de 20x20, sendo estes valores inferiores aos alcançados pelas redes de tamanho 15x15 com as funções Discretas, “Chapéu Mexicano” e “Chapéu Francês”.

Figura 36 – Gráfico de Valor Preditivo Positivo percentual para as funções de vizinhança e tamanho de rede avaliados.

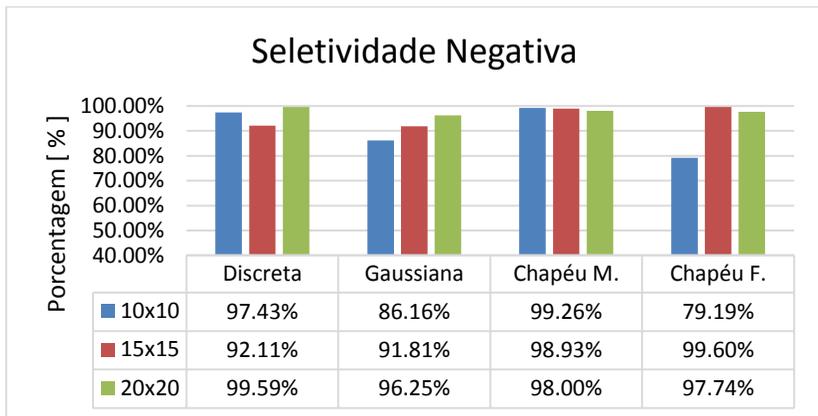


Fonte: Próprio autor.

Na Figura 36 são apresentados os valores percentuais obtidos para o VPP, destacando-se a função do tipo “Chapéu Mexicano”, na qual obteve-se seletividade positiva de 90,08% para a rede de tamanho 15x15, e a função do tipo “Chapéu Francês” que obteve seletividade positiva de 89,10% para a rede de tamanho 15x15; as funções Discreta e Gaussiana obtiveram o menor resultado entre as funções, obtendo Seletividade Positiva de 81,60% para rede de tamanho 20x20 e 58,49% para rede de tamanho 10x10, respectivamente. A função do tipo “Chapéu Francês” obteve o segundo melhor resultado de seletividade positiva com 89,10% para rede de tamanho 15x15.

A função Gaussiana obteve os menores valores percentual entre as funções, com VPP de 58,49% para rede de tamanho 10x10 e de 60,32% para a rede 15x15, também pode-se observar o comportamento crescente da seletividade positiva conforme o aumento do tamanho da rede, chegando a 86,13 de VPP na rede de tamanho de 20x20.

Figura 37 – Gráfico de Valor Preditivo Negativo percentual para as funções de vizinhança e tamanho de rede avaliados.

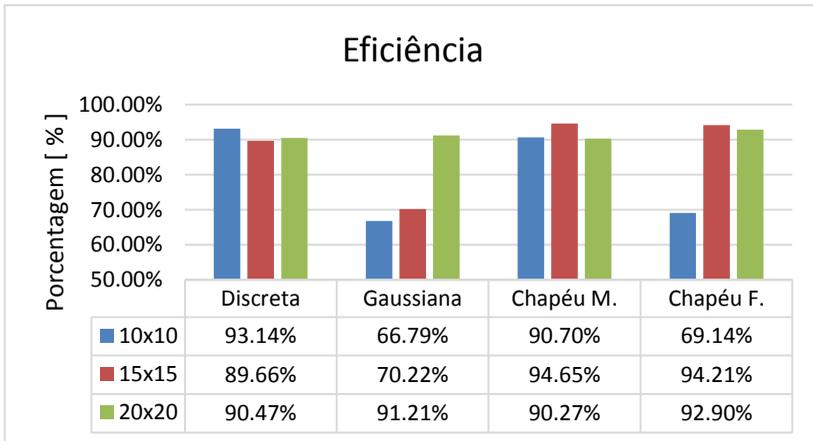


Fonte: Próprio autor.

Na Figura 37 são apresentados os valores percentuais obtidos para o VPN, com destaque para a função do tipo “Chapéu Francês”, na qual obteve-se seletividade negativa de 99,60% para a rede de tamanho 15x15; para rede de tamanho 10x10, 79,19%, e para rede de tamanho 20x20 obteve-se seletividade negativa de 97,74%, podendo-se observar que houve perda de seletividade negativa tanto para a rede de tamanho 10x10, quanto para a rede de tamanho 20x20; Na função “Chapéu Mexicano” com a rede de tamanho 10x10 obteve 99,26% seguido de $\cong 98,00\%$ dos tamanhos de redes 10x10 e 20x20.

A função Discreta apresentou valor percentual de seletividade negativa para as redes de tamanho 10x10 e 15x15, com 97,43% e 92,11% respectivamente, e obteve seletividade negativa de 99,59% para rede de tamanho 20x20. A função Gaussiana obteve seletividade negativa de 86,16% na rede de tamanho 10x10, sendo que o valor percentual de seletividade negativa aumentou para as redes de tamanho 15x15 e 20x20.

Figura 38 – Gráfico de Eficiência percentual para as funções de vizinhança e tamanho de rede avaliados.

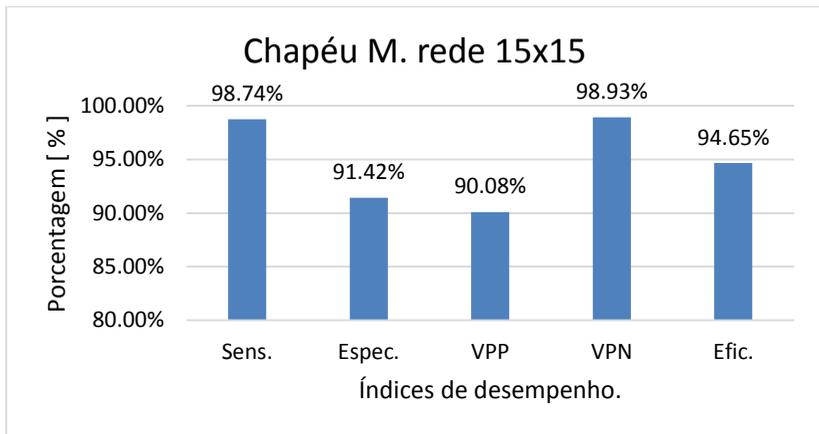


Fonte: Próprio autor.

Na Figura 38 são apresentados os valores percentuais obtidos para Eficiência, destacando-se a função do tipo “Chapéu Mexicano”, na qual obteve-se Eficiência de 94,65% para a rede de tamanho 15x15; para a rede 10x10 com 90,70% e a rede 20x20 com 90,27%; a função “Chapéu Francês”, obteve Eficiência para o tamanho de rede 15x15, 94,21%, 20x20 de 92,90% e o menor valor obtido com a rede de tamanho 10x10 com 69,14%. A função Discreta obteve Eficiência de 93,14% para a rede de tamanho 10x10 e obteve Eficiência de 89,66% e 90,47% para as redes de tamanho 15x15 e 20x20, respectivamente.

Observando os gráficos analisados acima, constata-se que o melhor resultado para os índices de desempenho de Sensibilidade e Seletividade Negativa, foi a função do tipo “Chapéu Francês” com 99,58% e 99,60%. Especificidade, Seletividade Positiva, e Eficiência, foram obtidos pela função de ativação de vizinhança do tipo “Chapéu Mexicano” na rede de tamanho 15x15, Assim a rede com melhor desempenho foi aquela que teve a melhor eficiência, índice que leva em conta todos os parâmetros analisados sendo a rede do tipo “Chapéu Mexicano” com tamanho 15x15, estes valores são apresentados na Figura 39.

Figura 39 – Gráfico dos resultados obtidos para a função de vizinhança “Chapéu M.” de tamanho 15x15.



Fonte: Próprio autor.

A Figura 39 apresenta os melhores resultados obtidos quanto aos índices de desempenho referente à função de ativação de vizinhança “Chapéu Mexicano” com tamanho de rede de 225 neurônios na camada de saída. Os resultados deve-se a capacidade de concordância entre os sinais classificados como eventos epileptiformes e não epileptiformes pelo SCKEE e o especialista. O resultado de 98,74% de Sensibilidade deve-se a alta capacidade de generalização dos sinais classificados como eventos epileptiformes e conseqüentemente, uma melhor distinção dos grupos formados, este índice é responsável pela capacidade que o teste tem de diagnosticar corretamente os sinais que representam um indivíduo doente. A Especificidade obtida de 91,42%, sendo esta responsável pela capacidade que o teste tem de diagnosticar corretamente os sinais que representam um indivíduo sadio. Para a seletividade positiva o resultado alcançado de 90,08% é considerado satisfatório, uma vez que este índice está diretamente relacionado com a especificidade do sistema. O resultado de 98,93% de seletividade negativa confirma a concordância do sistema com o especialista em prever que a classificação de eventos epileptiformes classificados como não sendo epileptiforme foi muito baixa, num total de 3 eventos classificados erroneamente dos 239 eventos epileptiformes testados. O resultado de 94,65% de Eficiência está relacionado a capacidade de que o SCKEE a cada 100 eventos

epileptiformes e não epileptiformes classificados, identifique 94 destes corretamente.

Em relação a taxa de falsos negativos ocorridos no teste de sensibilidade, pode-se destacar que este ocorre quando os eventos epileptiformes são classificados como não sendo epileptiformes, a taxa obtida pelo classificador foi muito baixa, num total de apenas 3 eventos (1,26%) dos 239 eventos epileptiformes testados foram classificados erroneamente, isto é, houve discordância entre o classificador desenvolvido e o especialista humano em apenas 3 eventos. A importância de ter um sistema classificador que seja sensível, ocorrerá que este raramente deixará de encontrar a doença em indivíduos doentes.

O número de 26 ou 8% de eventos falsos positivos do total de 323 eventos não epileptiforme, ocorridos no teste de especificidade, também pode ser considerado baixo, pois a concordância foi de 92% entre o classificador desenvolvido e o número marcado pelo especialista humano. O índice de desempenho de especificidade é de fundamental importância, pois um classificador que seja específico, raramente vai dizer que um indivíduo sadio seja doente.

Com relação aos resultados obtidos na Figura 39, pode-se fazer inferência ao tamanho da rede, pois quanto maior a rede, maior é o processamento necessário para análise de sinais, ficando evidenciado que com a rede de tamanho 15x15 foi suficiente para obtenção do melhor resultado para a análise dos sinais de EEG, o que descarta a necessidade de utilização de redes muito maiores que a de 225 neurônios.

Os resultados obtidos no presente estudo não foram comparados com alguns trabalhos citados neste estudo, em função de características de redes e/ou banco de sinais utilizados diferenciados.

Diferentemente do trabalho de Sala (2005) e Pereira (2003) que afirmam que a utilização de uma única rede na camada de saída para treinamento de eventos epileptiforme e não epileptiforme é insuficiente, o SCKEE obteve a classificação de todas as classes com apenas uma rede de treinamento, o que vai de acordo com a afirmação de Scolaro (2009) que também afirmou ser possível a classificação destes eventos com uma única rede, ainda Scolaro (2009) pode observar que a maior dificuldade encontrada na separação dos eventos ocorreu em alguns sinais de atividade normal que apresentaram similaridade com outros padrões, tanto na morfologia quanto na amplitude acima da faixa característica destes, já que estes sinais de atividade normal podem ter algumas semelhanças morfológicas com eventos epileptiformes. Ainda deve-se ressaltar que não foi aplicado filtros adicionais nos conjuntos de dados

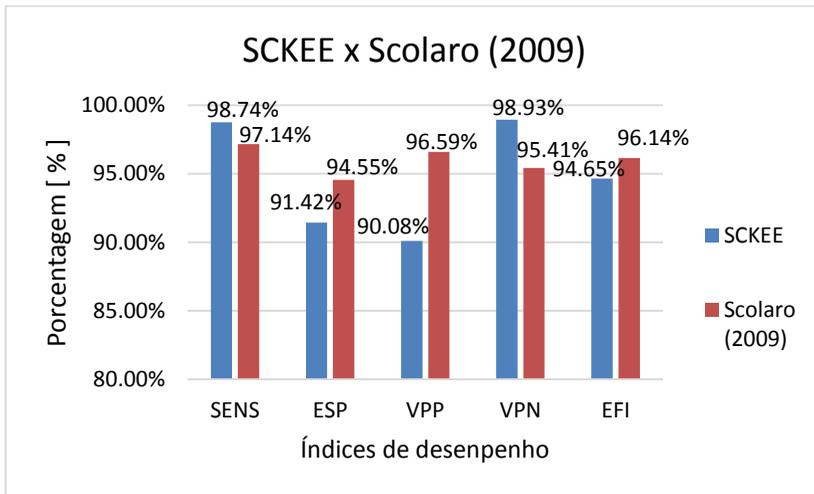
testados, os sinais foram testados apenas com a filtragem do equipamento de aquisição.

O SCKEE quando comparado com outros sistemas que utilizaram MAK, demonstrou uma performance bem acima destes, por exemplo o treinamento de todas as redes do SCKEE tiveram parada antecipada, o que não necessitou que as redes treinassem até o final dos 1000 ciclos inicialmente especificados; diferentemente do trabalho de Sala (2005), o qual sugeriu 20.000 ciclos para o melhor resultado, no que demandou pelo menos 20.000 vezes mais processamento que o pior caso do SCKEE. Já no trabalho de Kurth *et al.* (2000) foram sugeridos 90.000 ciclos de treinamento, sendo este um número muito acima daquele utilizado pelo SCKEE.

Com relação ao tamanho das redes dos trabalhos anteriormente citados, o trabalho de Kurth *et al.* (2000) obteve melhor resultado com rede de tamanho 60x60, enquanto Sala (2005) obteve melhor desempenho com rede de tamanho 35x35, porém, com quatro redes individuais totalizando um tamanho de 140x140; já o SCKEE apresentou o melhor desempenho apenas com a rede de tamanho 15x15, caracterizando a não necessidade de um alto tempo processamento.

Para a avaliação dos índices de desempenho não foi possível a comparação entre os trabalhos citados acima com os resultados deste, pois o conjunto de sinais utilizados não apresentam as mesmas características em relação a montagem, resolução e frequência de amostragem. No entanto, foi possível a comparação com o trabalho de Scolaro (2009), que utilizou o mesmo banco de sinais que foram analisados neste trabalho. Porém deve-se destacar que ainda que no trabalho de Scolaro (2009) tenha sido utilizado o mesmo banco de sinais, este utilizou uma abordagem com PMC para a classificação de padrões, o que implica em uma metodologia totalmente diferente da utilizada neste trabalho, já que este foi utilizado MAK para a classificação. Sendo assim, a comparação não envolve as metodologias desenvolvidas e sim os resultados alcançados por estas. Esta comparação entre os valores obtidos para os índices de desempenho pode ser visualizada na Figura 40.

Figura 40 - Comparação entre os valores obtidos para os índices de desempenho entre SCKEE e Scolari (2009).



Fonte: Próprio autor.

Para os índices de desempenho avaliados, Scolari (2009) obteve Sensibilidade de 97,14%, Especificidade de 94,55%, seletividade positiva de 96,59%, seletividade negativa de 95,41% e eficiência 96,14%, contra Sensibilidade de 98,74%, Especificidade de 91,42%, seletividade positiva de 90,08%, seletividade negativa de 98,93% e eficiência 94,65% obtido pelo SCKEE.

Avaliando os resultados do SCKEE com o trabalho de Scolari (2009), pode-se verificar que ambos os resultados obtidos apresentam similaridades na avaliação dos índices de desempenho, apesar de os dois trabalhos terem utilizados metodologias diferentes. O classificador SCKEE obteve melhores resultados para sensibilidade e seletividade negativa, enquanto que o trabalho de Scolari (2009) apresentou melhores resultados para especificidade, seletividade positiva e eficiência, ressaltando que este utilizou filtros adicionais nos segmentos de sinais além dos utilizados na aquisição, o que pode justificar este melhor resultado.

5 CONCLUSÃO

O treinamento e testes foram realizados com utilização do banco de sinais do IEB-UFSC.

Foi desenvolvido o algoritmo de MAK para a classificação automática de eventos Epileptiformes (espícula e onda aguda) e não Epileptiformes (piscada, atividade normal e ruído).

Foi desenvolvido um sistema protótipo classificador neural chamado SCKEE composto de várias ferramentas para a análise e classificação de sinais, no qual este foi integrado o algoritmo MAK implementado.

Os resultados gerados pelo SCKEE foram avaliados através dos índices de desempenho (Sensibilidade, Especificidade, Seletividade Positiva, Seletividade Negativa e Eficiência), nos tamanhos de rede 10x10, 15x15 e 20x20 o qual concluiu-se que a função de ativação de vizinhança “Chapéu Mexicano” no tamanho de rede 15x15 obteve os melhores resultados para os índices de desempenho avaliados com Sensibilidade de 98,74%, Especificidade de 91,42%, seletividade positiva de 90,08%, seletividade negativa de 98,93% e Eficiência 95%.

Com a utilização de apenas uma rede neural artificial MAK na camada de saída, foi possível realizar a separação e classificação dos eventos Epileptiformes e não Epileptiformes obtendo resultados promissores. Podendo-se atribuir os bons resultados ao fato do desenvolvimento de um sistema classificador exclusivo para os sinais de EEG.

Os resultados obtidos podem confirmar a viabilidade da utilização do MAK para classificação de eventos epileptiforme e não epileptiforme, consequentemente poderá vir a servir ao apoio a diagnóstico.

6 PERSPECTIVAS

Com base nos resultados obtidos neste trabalho sugere-se para a continuidade deste estudo:

- A utilização de registros contínuos completos de sinais de EEG para a classificação de eventos.
- O *software* protótipo SCKEE poderá servir para o desenvolvimento de sistemas automáticos de classificação de eventos epileptiformes em sinais de EEG para apoio ao diagnóstico, já que este é uma versão protótipo.
- Inclusão da aplicação de filtros como *Wavelet*, a fim de minimizar a quantidade de neurônios heterogêneos, podendo vir a influenciar na melhoria da formação dos “vales”, e conseqüentemente, minimizando a quantidade de FP e melhorando o desempenho da Especificidade.
- Desenvolvimento de um sistema de mapas 3D, visando a facilitação da visualização e compreensão dos arranjos de sinais analisados.
- Automatizar a definição dos mapas gerados pelo SCKEE.

REFERÊNCIAS

ABIBULLAEV, B.; SEO, H. D.; KIM, M. S. Epileptic spike detection using continuous wavelet transforms and artificial neural networks. *International Journal of Wavelets, Multiresolution and Information Processing*, v. 8, p. 22-48, 2010.

ANUSHA, K. S.; MATHEW, T. M.; SUBHA, D. P. Classification of normal and epileptic EEG signal using time & frequency domain features through artificial neural network. *2012 International Conference on Advances in Computing and Communications*. IEEE, P. 98-101, 2012.

ARTAMEEYANANT, P.; CHIRACHARIT, W.; CHAMNONGTHAI, K. Spike and epileptic seizure detection using wavelet packet transform based on approximate entropy and energy with artificial neural network. *The 2012 Biomedical Engineering International Conference (BMEiCON-2012)*. IEEE, p. 1-5, 2012.

ASHA, S. A. et al. Automated Seizure Detection from Multichannel EEG Signals using Support vector Machine and Artificial neural Networks. In: *Automation, Computing, Communication, Control and Compressed Sensing (iMac4s)*, 2013 International Multi-Conference on IEEE, p. 558-563, 2013.

BLADIN, P. F.; EADIE, M. J.; *Atlas of Epilepsies: Medical Aspects of the History of Epilepsy*. London: Springer-Verlag, 2010. p. 27-32.

BOOS, C. F. Avaliação de descritores morfológicos de eventos epileptiformes utilizando análise de componentes principais. *Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2011.*

COIMBRA, A. J. F.; MARINO J.; FREITAS, C. G.; AZEVEDO, F. M., BARRETO, J. M. Automatic Detection of Sleep-Waking States Using Kohonen Neural Networks. *Anais do 1º Congresso Brasileiro de Redes Neurais*, Itajubá, 1994, p. 327-331.

DVORAK, R.; HENRARD, J. Qualitative and quantitative behaviour of panetary systems. Holland: Kluwer Academic Publishers, 1993. 396 p.

ENGEL, J. et al. Epilepsy: Global Issues for the Practicing Neurologist. New York: Demos, 5a. ed., 2005. 140 p.

GHOSH-DASTIDAR, S.; ADELI, H. A new supervised learning algorithm for multiple spiking neural networks with application in epilepsy and seizure detection. Neural Networks, v. 22, p. 1419-1431, 2009.

GONÇALVES, M.; NETTO, A.; ZULLO, M.L.; COSTA, J. A. F.. Explorando as Propriedades do Mapa Auto-organizável de Kohonen na Classificação de Imagens de Satélite, Congresso da Sociedade Brasileira de Computação - CSBC 2007, Trabalho Completo.

GOPIKA, G. K. et al. Adaptive neuro-fuzzy classifier for 'Petit Mal' epilepsy detection using mean teager energy. In: 2013 International Conference on Advances in Computing, Communications and Informatics (ICACCI). IEEE, p. 752-757, 2013.

GUERREIRO, C. A. M., GUERREIRO, M.M. Epilepsia, 2. ed. Lemos Editorial, 1996.

HAYKIN, S. Neural Networks: A Comprehensive Foundation. 2nd ed. New Jersey: Prentice Hall, 2001. 842 p.

HIRSCH. L.J; BRENDER. R.P.; Atlas of EEG in critical care. John Wiley & Sons, Ltd Oxford, p.348, 2010.

HODGKIN, A. L.; HUXLEY, A. F. A quantitative description of membrane current and its application to conduction and excitation in nerve. The Journal of Physiology, v. 117, p. 500-544, 1952.

IGASAKI, T. et al. Proposal for patient-specific automatic on-line detection of spike-and-wave discharges utilizing an artificial neural network. In: 2011 4th International Conference on Biomedical Engineering and Informatics (BMEI). IEEE, p. 813-817, 2011.

KANGAS, J.; KOHONEN, T., Developments and applications of the self-organizing maps and related algorithms. *Mathematics and Computers in Simulation*, Amsterdam, v. 41, n. 1-2, p. 3-12, jun. 1996.

KIANG, M. Y. Extending the Kohonen self-organizing map networks for clustering analysis. *Computational Statistics & Data Analysis*, v. 38, p. 161-180, 2001.

KIVILUOTO, K., Topology Preservation in Self-Organizing Maps. In: *International Conference on Neural Networks*, 1996, New Jersey: IEEE Neural Networks Council, p. 294-299.

KLEM, G. H.; LUDERS, H.O.; JASPER, H.H.; ELGER, C., The twenty electrode system of the International Federation. In: *Guidelines of the International Federation of Clinical Physiology*, 1999, Cleveland, p. 19-23.

KOHONEN, T. The self-organizing map. In *Proceedings of the Institute of Electrical and Electronics Engineers*, vol. 78, pp 1464-1480, 1990.

KOHONENE, T. et al.; A principle of neural associative memory. *Neuroscience*, v. 2, p. 1065-1076, 1977.

KURTH, C.; GILLIAM, F.; STEINHOFF, B. J. EEG spike detection with a Kohonen feature map. *Ann. Biomed. Eng.*, vol. 28, no. 11, pp. 1362-1369, 2000.

LASSALA, C., Programação Orientada a Objetos em .NET. Disponível em: <http://msdn.microsoft.com/pt-br/library/cc580626.aspx>, acessado em 24/07/2013.

LINDEN, R. Algoritmos genéticos: uma importante ferramenta da inteligência computacional. 2 ed. Rio de Janeiro: Brasport, 2008, 400 p.

LIU, H.S.; ZHANG, T.; YANG, F.S. A multistage, multimethod approach for automatic detection and classification of epileptiform EEG. *IEEE Transactions on Biomedical Engineering*, v. 49, n. 12, Dec. 2002, p. 1557-1566.

LUDWIG Jr., O.; MONTGOMERY, E. Redes Neurais: Fundamentos e Aplicações com Programas em C. Rio de Janeiro: Ciência Moderna, 2007. 125 p.

MACIEL, A.; COUTINHO, P.; CORADINE, L.; VIEIRA, R.; ARAUJO, J. Técnicas de mineração de dados baseadas em redes SOM e PCA na classificação de arritmia cardíaca. Disponível em <http://www.sbis.org.br/cbis11/arquivos/972.pdf>, acessado em 12/12/2013.

MALMIVUO, J.; PLONSEY, R. Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields. New York: Oxford University Press, 1995. 512 p.

MARQUES, D. M. Análise Espectral com Wavelets do ECoG em Crises Epilépticas. Florianópolis, 2012, 88 p. Dissertação (Mestrado em Engenharia Biomédica) – Universidade Nova de Lisboa.

MCCULLOCH, W.S., A Logical Calculus of the Ideas Immanent in Nervous Activity, New Jersey: Bulletin of Mathematical Biophysics, V. 5, p. 115-133, 1943.

MONTGOMERY, D. C.; RUNGER, G. C.; HUBELE, N.F. Estatística Aplicada à Engenharia. Rio de Janeiro: LTC, 2a ed., 2004, 333 p.

MYATT, G. J.; JOHNSON, W. P. Making Sense of Data II: A practical Guide to Data Visualization, Advanced Data Mining Methods, and Applications. Nova Jersey: Wiley, 2009. 291 p.

OMS. Organização Mundial da Saúde. Epilepsia. Disponível em <http://www.who.int/mediacentre/factsheets/fs999/es/> Acessado em 02/05/2014.

PEREIRA, M. C. V. Avaliação de técnicas de pré-processamento de sinais do EEG para detecção de eventos epileptogênicos utilizando redes neurais artificiais. Tese de Doutorado (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2003.

PEREIRA, M. C. V.; AZEVEDO, F.M.; ARGOUD, F. I. M.
Investigation About Pre-Processing in the Input of an Artificial Neural Network for Analysis of Epileptogenic Events in EEG Signals. Proceedings of the World Congress on Medical Physics and Biomedical Engineering, 2003, p.103-103.

RITTER H.; MARTINETZ T.; SCHULTEN K.; 1992. Neural Computation and Self-Organizing Maps, An Introduction, Reading, MA: Addison-Wesley.

SALA, F. A. Mapas de Kohonen na detecção de eventos epileptogênicos. Florianópolis, 2005, 112 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Santa Catarina: UFSC.

SANEI, S.; CHAMBERS, J.A. *EEG Signal Processing*. West Sussex: Wiley, 2007. 312 p.

SASSI, R. J. Uma arquitetura híbrida para descoberta de conhecimento em base de dados: Teoria dos *Rough Sets* e Redes Neurais Artificiais Mapas Auto-Organizáveis. São Paulo, 2006, 169 p.

SCOLARO, G. R. Classificação de eventos epileptiformes em sinais de EEG utilizando classificador neural. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2009.

SCOLARO, G. R.; AZEVEDO, F. M. Classification of epileptiform events in raw EEG signals using neural classifier. Proceedings of the 3rd IEEE International Conference on Computer Science and Information Technology. V.5, p. 368-372, 978-1-4244-5537-9, Chengdu, Sichuan, China, IEEE Press, 2010.

SHARANREDDY, M.; KULKARNI, P. K. An improved approximate entropy based epilepsy seizure detection using multi-wavelet and artificial neural networks. Int. J. Biomedical Engineering and Technology, v. 11, n. 1, p. 81-95, 2013.

SHEN, C. et al. High-performance seizure detection system using a wavelet-approximate entropy-fSVM cascade with clinical validation. Clinical EEG and Neuroscience, v. 44, p. 247-256, 2013.

- SILVA, I. N.; SPATTI, D. N.; FLAUZINO, R. A. *Redes Neurais Artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010, 399 p.
- SILVERTHORN, D. U. *Fisiologia humana: uma abordagem integrada*. 5a ed. Porto Alegre: Artmed, 2010. 989 p.
- SIMÕES, F. O.; NETO, M. U.; MACHADO, J. B.; NAGLE, E. J.; RUNSTEIN, F. O.; GOMES, L. C. T. Compreensão de fala utilizando quantização vetorial e redes neurais não supervisionadas. *Cad.CPqD Tecnologia*, v. 5, n. 1, p. 33-48, 2009.
- SIQUEIRA, P.H. Uma nova abordagem na resolução do problema do caixeiro viajante. Curitiba, 2005, 102 p. Tese (Doutorado em Engenharia Elétrica) – Escola Politécnica da Universidade de São Paulo: USP.
- ULTSCH, A. Maps for the visualization of high-dimensional data Spaces. In: *Workshop on Self-Organizing Maps, Kyushu: Proceedings of Workshop on Self-Organizing Maps - WSOM*, p. 225-230, 2003.
- WEBBER, W. R. S.; LITT, B.; WILSON, K.; LESSER, R. P. Practical Detection of Epileptiform Discharges (EDs) in the EEG Using an Artificial Neural Network: a Comparison of Raw and Parameterized EEG Data. *Electroencephalography and Clinical Neurophysiology*, v. 91, n. 3, Sep. 1994, p. 194-204.
- WILLIAMS & WILKINS, 2001. *Neurociências: Desvendando o Sistema Nervoso*, 2. ed. Artmed Editora S.A..
- WILSON, S. B.; EMERSON, R. Spike Detection: a Review and Comparison of Algorithms. *Clinical Neurophysiology*, v. 113, n. 12, Dec. 2002, p. 1873-1881.
- ZHANG, X.; LI, Y., Self-Organizing Map as a new method for clustering and data analysis. In: *International Joint Conference on Neural Networks, 1993, Nagoya: Proceedings of International Joint Conference on Neural Networks – IJCNN'93*, p. 2448 -2451.