Helder Frederico da Silva Lopes

Aplicação de redes neurais artificiais paraconsistentes como método de auxílio no diagnóstico da doença de Alzheimer

Dissertação apresentada à Faculdade de Medicina da Universidade de São Paulo para a obtenção do título de Mestre em Ciências

Área de Concentração: Neurologia

Orientador: Dr. Renato Anghinah

São Paulo

2009

Helder Frederico da Silva Lopes

Aplicação de redes neurais artificiais paraconsistentes como método de auxílio no diagnóstico da doença de Alzheimer

Dissertação apresentada à Faculdade de Medicina da Universidade de São Paulo para a obtenção do título de Mestre em Ciências

Área de Concentração: Neurologia

Orientador: Dr. Renato Anghinah

São Paulo

2009

Dados Internacionais de Catalogação na Publicação (CIP)

Preparada pela Biblioteca da
Faculdade de Medicina da Universidade de São Paulo

©reprodução autorizada pelo autor

Lopes, Helder Frederico da Silva
Aplicação de redes neurais artificiais paraconsistentes como método de auxílio no diagnóstico de doença de Alzheimer / Helder Frederico da Silva Lopes. -- São Paulo, 2008.
Dissertação(mestrado)--Faculdade de Medicina da Universidade de São Paulo.

Departamento de Neurologia.
Área de concentração: Neurologia.
Orientador: Renato Anghinah.

Descritores: 1.Eletroencefalografia/utilização 2.Eletroencefalografia/métodos 3.Lógica 4.Redes neurais (computação) 5.Doença de Alzheimer 6.Reconhecimento automatizado de padrão

USP/FM/SBD-421/08

AGRADECIMENTOS

Primeiramente, agradeço a Deus por sua iluminação em minha vida.

A meus pais, Francisco e Suzete, e ao meu irmão, Heler, que sempre me apoiaram em minhas jornadas.

À minha esposa Ana Luiza, que com seu amor e carinho me ajudou em todos os momentos, desde o início deste trabalho.

Ao meu orientador, Dr. Renato Anghinah, que me conduziu até aqui, me ensinando o verdadeiro sentido da pesquisa científica e confiando em meu trabalho.

Aos meus amigos e colegas da Autobyte e do CEREDIC que me ajudaram no desenvolvimento deste trabalho.

Um agradecimento especial ao Prof. Dr. Jair Abe, que com sua paixão e devoção à ciência, me acolheu como aluno, me ensinando, ajudando e chamando minha atenção quando necessário, da mesma maneira que um bom pai educa um filho.

Esta dissertação está de acordo com as seguintes normas, em vigor no momento desta publicação:

Referências: adaptado de *International Committee of Medical Journals Editors* (Vancouver)

Universidade de São Paulo. Faculdade de Medicina. Serviço de Biblioteca e Documentação. Guia de apresentações de dissertações, teses e monografias. Elaborado por Annelise Carneiro da Cunha, Maria Júlia de A. L. Freddi, Maria F. Crestana, Marinalva de Souza Aragão, Suely Campos Cardoso, Valéria Vilhena. 2ª ed. São Paulo: Serviço de Biblioteca e Documentação; 2005.

Abreviaturas dos títulos dos periódicos de acordo com *List of Journals Indexed in Index Medicus*.

SUMÁRIO

RESUMO
ABSTRACT
1. INTRODUÇÃO 1
1.1. Doença de Alzheimer 1
1.2. Eletroencefalograma 3
1.2.1. EEG quantitativo 5
1.3. Lógica Paraconsistente 6
1.3.1. Lógica Paraconsistente Anotada Evidencial Eτ 7
1.4. Redes Neurais Artificiais 15
1.5. Redes Neurais Artificiais Paraconsistentes 18
1.5.1. Célula Neural Artificial Paraconsistente de conexão analítica 21
1.5.2. Célula Neural Artificial Paraconsistente de conexão lógica simples para maximização 22
1.5.3. Célula Neural Artificial Paraconsistente de conexão lógica simples de minimização 22
1.5.4. Célula Neural Artificial Paraconsistente de conexão lógica seletiva de maximização 23
1.5.5. Célula Neural Artificial Paraconsistente de conexão lógica seletiva de minimização 24
1.5.6. Célula Neural Artificial Paraconsistente de complementação 24
1.5.7. Célula Neural Artificial Paraconsistente de decisão 25
1.5.8. Célula Neural Artificial Paraconsistente de aprendizagem, desaprendizagem e memorização. 26
1.5.9. Unidades Neurais Artificiais Paraconsistentes. 27
1.5.10. Sistemas Neurais Artificiais Paraconsistentes 27
1.5.10.1. Sistemas Neurais Artificiais Paraconsistentes de aprendizado condicionado 28
1.5.10.2. Sistemas Neurais Artificiais Paraconsistentes de tratamento de contradições 29
2. OBJETIVOS 30
2.1. Objetivos gerais 30
2.2. Objetivos específicos 30
3. CASUÍSTICA E MÉTODOS 31
3.1. Casuística 31
3.2. Métodos 33

3.2.1. Aquisição de dados 33
3.2.2. Análise de EEG baseado na RNAP 35
3.2.2.1. Definição de padrões de análise 37
3.2.2.2. Processamento do exame 38
3.2.3. Procedimentos para a análise de EEG baseada em RNAP 38
3.2.3.1. Captura de dados 39
3.2.3.2. Redução de valores para a exibição do exame pelo SAP-EEG 39
3.2.3.3. Eliminação do ciclo negativo 40
3.2.3.4. Normalização de valores para análise 40
3.2.3.5. Sistema especialista para análise de frequência e formato da onda 40
3.2.3.5.1. Análise morfológica 41
3.2.3.6. Análise dos dados utilizando a RNAP 47
3.2.3.6.1. Sistema especialista de detecção de nível de diminuição de frequência média 48
3.2.3.6.2. Sistema especialista de detecção de concentração de ondas rápidas 49
3.2.3.6.3. Sistema especialista de detecção de concentração de ondas lentas 49
3.2.3.6.4. Análise da RNAP 49
4. RESULTADOS 54
5. DISCUSSÃO 58
6. CONCLUSÕES 62
7. REFERÊNCIAS BIBLIOGRÁFICAS 63
8. Apêndice

RESUMO

Lopes HFS. *Aplicação de redes neurais artificiais paraconsistentes como método de auxílio no diagnóstico da doença de Alzheimer* [dissertação]. São Paulo: Faculdade Medicina, Universidade de São Paulo; 2009.

A análise visual do eletroencefalograma (EEG) tem se mostrado útil na ajuda diagnóstica da doença de Alzheimer (DA), sendo indicado em alguns protocolos clínicos quando o diagnóstico permanece em aberto após a avaliação inicial. Porém, tal análise está sujeita naturalmente à imprecisão inerente de equipamentos, movimentos do paciente, registros elétricos e variação da interpretação da análise visual do médico. A teoria das Redes Neurais Artificiais (RNA) tem-se mostrado muito apropriado para tratar problemas como predição e reconhecimento de padrões de sinais em outras áreas do conhecimento.

Neste trabalho utilizou-se uma nova classe de RNA, a Rede Neural Artificial Paraconsistente (RNAP), caracterizada pela manipulação de informações incertas, inconsistentes e paracompletas, destinada a reconhecer padrões predeterminados de EEG e de avaliar sua aplicabilidade como método auxiliar para o diagnóstico da DA.

Trinta e três pacientes com DA provável e trinta e quatro pacientes controles foram submetidos ao registro de exames de EEG durante a vigília em repouso. Considerou-se como padrão normal de um paciente, a atividade de base entre 8,0 Hz e 12,0 Hz (com uma frequência média de 10 Hz), permitindo uma variação de 0.5 Hz.

A RNAP foi capaz de reconhecer ondas de diferentes bandas de frequência (teta, delta, alfa e beta) aplicadas ao uso clínico do EEG, levando a uma

concordância com o diagnóstico clínico de 82% de sensibilidade e 61% de especificidade.

Com estes resultados, acredita-se que a RNAP possa vir a ser uma ferramenta promissora para manipular análise de EEG, tendo em mente as seguintes considerações: o interesse crescente de especialistas em análise visual de EEG e a capacidade da RNAP tratar diretamente dados imprecisos, inconsistentes e paracompletos, fornecendo uma interessante análise quantitativa e qualitativa.

Palavras Chave: Eletroencefalografia, Lógica Paraconsistente, Redes Neurais Artificiais, doença de Alzheimer, reconhecimento de padrões.

ABSTRACT

Lopes HFS. *Application of artificial neural networks paraconsistents as a method of aid in the diagnosis of Alzheimer disease* [dissertation]. São Paulo: “Faculdade Medicina, Universidade de São Paulo”; 2009.

The visual analysis of EEG has shown useful in helping the diagnosis of Alzheimer disease (AD) when the diagnosis remains uncertain, being used in some clinical protocols. However, such analysis is subject to the inherent equipment imprecision, patient movement, electrical records, and physician interpretation of the visual analysis variation. The Artificial Neural Network (ANN) could be a helpful tool, appropriate to address problems such as prediction and pattern recognition.

In this work, it has use a new class of ANN, the Paraconsistent Artificial Neural Network (PANN), which is capable of handling uncertain, inconsistent, and paracomplet information, for recognizing predetermined patterns of EEG and to assess its value as a possible auxiliary method for AD diagnosis.

Thirty three patients with Alzheimer's disease and thirty four controls patients of EEG records were obtained during relaxed wakefulness. It was considered as normal patient pattern, the background EEG activity between 8.0 Hz and 12.0 Hz (with an average frequency of 10 Hz), allowing a range of 0.5 Hz.

The PANN was able to recognize waves that belonging to their respective bands of clinical use (theta, delta, alpha, and beta), leading to an agreement with the clinical diagnosis at 82% of sensitivity and at 61% of specificity.

Supported with these results, the PANN could be a promising tool to manipulate EEG analysis, bearing in mind the following considerations: the growing

interest of specialists in EEG analysis visual and the ability of the PANN to deal directly imprecise, inconsistent and paracomplet data, providing an interesting quantitative and qualitative analysis.

Keywords: Electroencephalography, Paraconsistent Logic, Artificial Neural Networks, Alzheimer disease, partner recognition.

1. INTRODUÇÃO

1.1. Doença de Alzheimer

A Doença de Alzheimer é uma desordem cerebral caracterizada por uma alteração cognitiva, que leva a uma demência progressiva, ocorrendo na meia idade ou na senectude (McKhann at al., 1984). Como característica anatomo-patológica encontra-se uma degeneração difusa, específica das células nervosas, cuja etiologia é complexa e heterogênea, com presença de placas neuríticas e emaranhados neurofibrilares (Hardy, 1997). Caracteriza-se, também, por alterações que afetam inicialmente o sistema colinérgico predominantemente, porém não exclusivamente, podendo acometer também outros neurotransmissores (McKhann at al., 1984).

A DA corresponde cerca de 50% de todos os casos de demências (Berger et al., 1994; Herrera et al., 1998) e mostra um aumento de prevalência com o avanço da idade. É mais prevalente entre as mulheres (Fratiglioni et al., 1997) e na população com idade entre 65 a 85 anos. A incidência é de aproximadamente de 14 vezes maior em pessoas com 85 anos comparadas às de 65 anos (Herbert et al., 1995).

Há evidências da participação genética como fator contribuinte da DA cujo fator causal estaria vinculado a mutações genéticas com padrões de herança autossômicas dominantes, identificadas por causar ou predispor o indivíduo para a doença (mutações nos cromossomos 21, 14, 1). Estas formas raras da doença, denominadas de forma familial, estão associadas a um início mais precoce, maior agressividade e êxito letal mais rápido. Por outro lado, a DA que não apresenta este padrão de hereditariedade, é denominada como forma esporádica e constituem mais de 90% dos casos. São fatores de risco para a DA esporádica idade avançada, história

familiar e genótipo com presença da apolipoproteina E (alelo ε4 da APOE) do cromossomo 19. Outros fatores de risco relativo são: sexo feminino, trauma crânio-encefálico, história familiar de Síndrome de Down, baixa escolaridade e exposição a estrógeno (Jelic, 1999).

Continuam, contudo, desconhecidos os mecanismos etiológicos da doença, devendo ser considerados desde fatores ambientais até os fatores endógenos do indivíduo.

O diagnóstico definitivo da DA ainda não pode ser estabelecido sem a análise histológica do cérebro (biópsia ou necropsia), no qual se observa uma degeneração específica no tecido cerebral, em especial nos neurônios piramidais, com marcada presença intracelular de emaranhados neurofibrilares e placas senis no extra-celular, acompanhadas de outras alterações estruturais, tais como degeneração granulovacuolar, atrofia dendrítica e perda de sinapses neurais (Terry, 1994). A evolução do acometimento neuropatológico pode ser subdividida em vários estágios, iniciando no período pré-sintomático com o envolvimento do córtex transentorrinal, progredindo para as estruturas límbicas e do hipocampo, finalmente envolvendo o isocórtex, mais intensamente as áreas associativas neocorticais (Braak et al.,1991). Este modelo de estado neuropatológico está de acordo com o quadro que se observa em relação à seqüência específica de achados do declínio cognitivo no curso da DA, que se inicia com alterações na memória de longa duração, principalmente episódica, funções vísuo-espaciais e atenção. Seguem-se alterações nas funções verbais e na memória de curta-duração (Almkvist et al., 1993).

Vários sistemas de neurotransmissores são afetados pela doença, mas as alterações mais consistentes são os dos neurônios colinérgicos (Coyle et al., 1983).

Demonstrou-se que a gravidade da deficiência colinérgica está diretamente associada com a intensidade do quadro demencial que juntamente com os achados de estudos que bloqueiam a transmissão colinérgica levando ao comprometimento cognitivo, a partir do que se aventou a teoria da "hipótese colinérgica" para explicar os achados da DA (Nordberg, 1996; Francis et al., 1999).

1.2. Eletroencefalograma

Os neurônios têm a habilidade de se comunicar de forma extremamente rápida e precisa, por longos trajetos. Em média, um neurônio forma mil sinapses e recebe mais de 10 mil conexões. A integração sináptica neuronal ocorre por meio de dois mecanismos, elétrico e químico. No sistema nervoso, sinapses elétricas são usadas primeiramente para produzir despolarização e não tem ação inibitória ou prolongada. Na sinapse elétrica ocorre o fluxo de corrente através da membrana pré-sináptica e de canais que conectam as células pré e pós-sinápticas (Kandel e Siegelbaum, 1995).

De forma geral, o registro de eletroencefalograma (EEG) consiste na captação de atividade elétrica cerebral pelos eletrodos, a qual é transmitida para os amplificadores de aparelho de EEG. Os amplificadores não só aumentam a amplitude da atividade que vai ser registrada, mas, também, excluem os potenciais semelhantes presentes nos eletrodos pela rejeição do modo comum. Isso permite que potenciais que não interessam na análise da atividade elétrica cerebral, como do eletrocardiograma, sejam excluídos do registro (Montenegro et al., 2001).

O registro gráfico do sinal do EEG pode ser interpretado como flutuações de voltagem com mistura de ritmos podendo ter freqüentemente aparência sinusoidal, com frequência entre 0,1 Hz a 70 Hz. Na prática clínico-fisiológica, estas frequências são agrupadas em bandas: delta (0,1 Hz a 4,0 Hz), teta (4,1 Hz a 8,0 Hz), alfa (8,1 Hz a 12,5 Hz) e beta (maior que 13 Hz) (Montenegro et al., 2001).

Durante a vigília relaxada, o EEG normal em adultos é predominantemente composto por frequências pertencentes à banda alfa, as quais são geradas por interações dos sistemas cortico-cortical e tálamo–cortical (Steriade et al., 1990; Lopes da Silva, 1991).

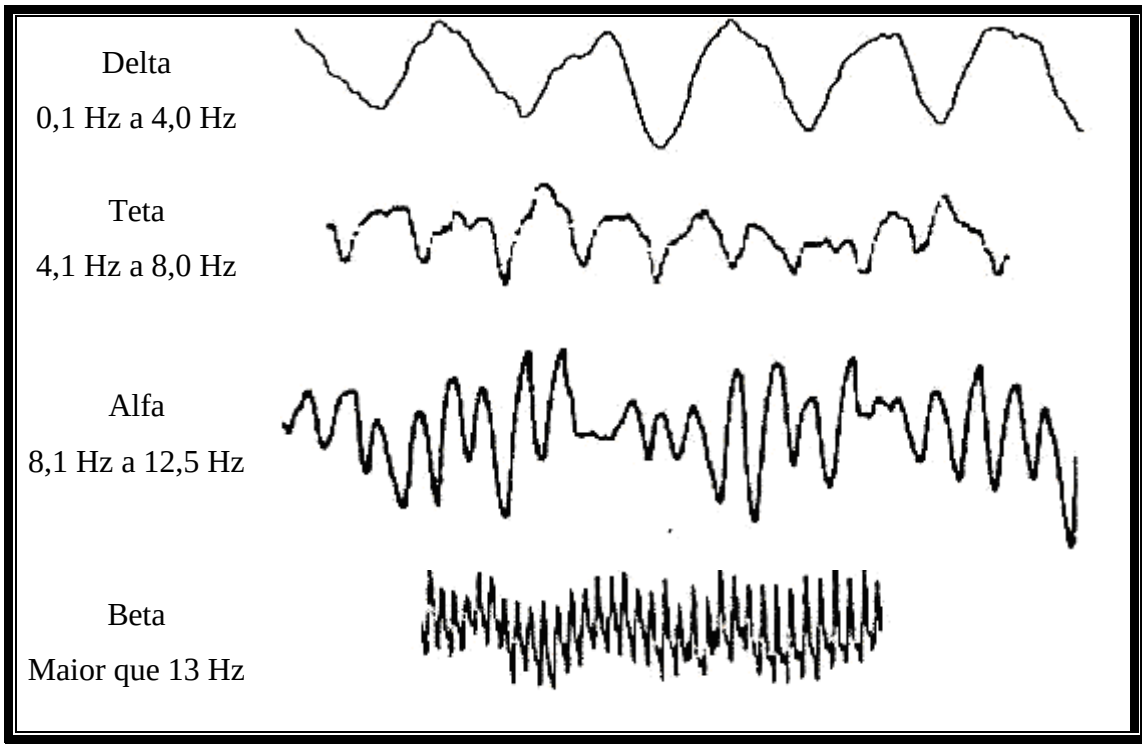

Figura 1 - Bandas de frequências clinicamente estabelecidas e habitualmente encontradas no EEG (Montenegro et al., 2001).

Vários estudos mostraram que a análise visual dos padrões de EEG pode ser útil no auxílio ao diagnóstico da DA, sendo indicada em alguns protocolos clínicos para o diagnóstico desta doença (Claus et al., 1999; Crevel et al., 1999).

Nos quadros de DA, os achados mais comuns à análise visual do traçado do EEG são o alentecimento da atividade elétrica cerebral de base por predomínio dos ritmos delta e teta e a diminuição ou ausência do ritmo alfa. Entretanto, esses achados são mais comuns e evidentes em pacientes nos estágios moderados ou avançados da doença (Silva et al., 1995; Alexander et al., 2006; Kwak, 2006).

1.2.1. EEG quantitativo

O método tradicional de interpretação de um exame de EEG consiste em uma análise visual do traçado, que é denominado de análise no domínio do tempo, pois esta análise estude a morfologia das ondas conforme foram captadas. Neste tipo de análise é importante distinguir entre atividade cerebral e artefatos.

Artefatos têm características que podem ser, relativamente, fáceis de serem identificadas, tais como movimentos oculares, movimentos musculares e até mesmo por interferência externa eletromagnética (Aminoff , 2003; Anghinah et al., 2006).

Contudo, técnicas computacionais, denominada Eletroencefalograma quantitativo (EEGq), auxiliam na quantificação dos traçados de EEG, com o objetivo de agilizar e aumentar a precisão das interpretações da análise do EEG.

O EEGq pode ser considerado um acessório do EEG, pois utiliza-se das informações do EEG e os transformam em dados quantitativos através de algoritmos

matemático-computacionais, tal como a transformada rápida de Fourier (FFT – *Fast Fourier transform*).

Atualmente o EEGq é utilizado para a criação de um mapa topográfico que mostra a distribuição e a intensidade da atividade elétrica cerebral que, comparado a um padrão de normalidade, pode detectar anomalias e interpreta-las como achados eletroencefalograficos, ou seja, características na distribuição da atividade cerebral que indicam alguma patologia (AANACNS, 1997; Anghinah, 2003; Chabot, 2005).

Diversos estudos comprovam que o EEGq é uma eficiente ferramenta e sua utilização em protocolos clínicos vem sendo paulatinamente utilizada.

1.3. Lógica Paraconsistente

Os precursores da Lógica Paraconsistente foram o lógico polonês J. Lukasiewicz e o lógico russo N. A. Vasilév, por volta de 1910, embora seus estudos ocorressem de forma independente. Nenhum deles tinha, na época, uma vista ampla da Lógica Clássica, tal como hoje se conhece, eles a tratavam de forma aproximada do prisma de Aristóteles, de conformidade com as tendências então dominantes na época (Abe, 2006a).

O primeiro lógico a estruturar um cálculo proposicional paraconsistente foi o polonês S. Jáskowski, discípulo de Lukasiewicz, publicando suas idéias sobre lógica e contradição em 1948. Posteriormente, a partir de 1954, N. C. A. Da Costa descreveu os primeiros sistemas de Lógica Paraconsistente, contendo todos os níveis lógicos conhecidos: cálculo proposicional, cálculo de predicado, cálculo de descrição e teorias de conjunto.

Ficou provado, em decorrência da elaboração da Lógica Paraconsistente, que se torna possível a manipular sistemas informacionais inconsistentes sem cair em trivialização (Da Silva Filho, 2001).

Uma lógica como paraconsistente, paracompleta e não-alético pode ser definida como: seja *L* uma lógica e *L'* a sua linguagem, que se supõe conter o símbolo de negação ~.

Uma teoria *T,* que tem por base *L*, é um conjunto de sentenças fechado pelas inferências aceitas por *L;* ou seja, *T* contêm todas as conseqüências (via *L)* de suas sentenças e as sentenças de *T* são seus teoremas.

Diz-se que a teoria *T* é inconsistente, se existir uma sentença *A* tal que *A* e ~*A* sejam teoremas de *T;* caso contrário, denomina-se consistente. *T* é trivial, se qualquer sentença de *L'* for teorema; em hipótese contrária, *T* chama-se não-trivial.

Define-se Lógica Paraconsistente como uma lógica que serve de base para teorias que sejam inconsistentes e não-triviais.

A Paracompleteza define-se como sendo a inexistência de um teorema referente a *A* e a ~*A*, ou seja, a sentença *A* existe, mas nada se pode afirmar sobre ela.

Uma Lógica Paraconsistente e Paracompleta denomina-se não-Alética (Da Costa et al., 1999).

1.3.1. Lógica Paraconsistente Anotada Evidencial Eτ

Os primeiros estudos sobre os fundamentos da lógica paraconsistente anotada foram realizados por N. C. A. Da Costa em 1991 (Da Costa et al., 1991).

Em 1992, J. M. Abe apresentou estudos sistemáticos dessas lógicas, demonstrando teoremas de correlações e de completeza para as lógicas de primeira

ordem correspondente. Estes estudos mostram também que a teoria anotada geral de conjuntos envolve como caso particular, a teoria dos conjuntos difusos, estudados por L. Zadeh em 1973 e C. V. Negoita em 1975 (Abe, 1992).

As proposições da Lógica Paraconsistente Anotada Evidencial Eτ são do tipo $p_{(\mu,\ \lambda)}$ onde p é uma proposição no sentido comum e μ, $\lambda \in [0, 1]$ (intervalo real unitário fechado). Intuitivamente, μ indica o grau de evidência[1] favorável de p e λ o grau de evidência contrária de p. A leitura dos valores μ e λ depende das aplicações consideradas e podem sofrer mudanças: com efeito, μ pode ser o grau de crença[2] favorável e λ poder ser o grau de crença contrária da proposição p. As proposições atômicas $p_{(\mu,\ \lambda)}$ da lógica Eτ podem ser intuitivamente ser lidas como: creio em p com o grau de crença favorável μ e o grau de crença contrária λ, ou o grau de evidência favorável de p é μ e o grau de evidência contrária de p é λ (Abe, 1992; Abe, 2006b).

Desse modo, têm-se algumas leituras interessantes:

- $p_{(1.0,\ 0.0)}$ pode ser lida como uma proposição verdadeira (evidência favorável total e evidência contrária nula).
- $p_{(0.0,\ 1.0)}$ pode ser lida como uma proposição falsa (evidência favorável nula e evidência contrária total).
- $p_{(1.0,\ 1.0)}$ pode ser lida como uma proposição inconsistente (evidência favorável total e evidência contrária total).
- $p_{(0.0,\ 0.0)}$ pode ser lida como uma proposição paracompleta (evidência favorável nula e evidência contrária nula).

---

1) O termo evidencia se encontra empregado num sentido não rigoroso, podendo intuitivamente ser “certeza” manifesta ou dados e informações que suportam opiniões. O termo “grau de evidência” significa o que se está explanado no curso do trabalho.

2) O termo crença também se encontra empregado em um sentido não rigoroso. Convém ressaltar que usualmente possui certa subjetividade.

- $p_{(0.5,\ 0.5)}$ pode ser lida como uma proposição indefinida (evidência favorável igual à evidência contrária de 0.5).

  Note que o conceito de paracompleteza é o dual da de inconsistência.

Exemplos:

Seja a proposição p ≡ O paciente está com doença de Alzheimer.

- $p_{(1.0,\ 0.0)}$ pode ser lida como: O paciente está com DA com evidência favorável total e evidência contrária nula. Intuitivamente, trata-se de uma proposição verdadeira.
- $p_{(0.0,\ 1.0)}$ pode ser lida como: O paciente está com DA com evidência favorável nula e evidência contrária total. Intuitivamente, trata-se de uma proposição falsa.
- $p_{(1.0,\ 1.0)}$ pode ser lida como: O paciente está com DA com evidência favorável total e evidência contrária também total. Intuitivamente, trata-se de uma proposição contraditória.
- $p_{(0.0,\ 0.0)}$ pode ser lida como: O paciente está com DA com evidência favorável nula e evidência contrária também nula. Intuitivamente, trata-se de uma proposição paracompleta.
- $p_{(0.5,\ 0.5)}$ pode ser lida como: O paciente está com DA com evidência favorável idêntica á evidência contrária e é 0.5. Intuitivamente, temos aí uma indefinição.

Uma propriedade interessante que a lógica paraconsistente anotada evidencial $E\tau$ apresenta é quando se analisa negações de proposições. Qual é a negação de $p_{(0.5,\ 0.5)}$? Intuitivamente tem-se que é a própria proposição $p_{(0.5,\ 0.5)}$, ou seja, $\neg p_{(0.5,\ 0.5)} \leftrightarrow p_{(0.5,\ 0.5)}$.

Agora, suponha-se que $p_{(0.5,\ 0.5)}$ seja verdadeira. Logo temos a situação: $p_{(0.5,\ 0.5)}$ verdadeira e $\neg p_{(0.5,\ 0.5)}$ também verdadeira. Assim, lógica em questão admite intuitivamente contradições verdadeiras. Caso semelhante se passa quando $p_{(0.5,\ 0.5)}$ for falsa. Tem-se $p_{(0.5,\ 0.5)}$ falsa e $\neg p_{(0.5,\ 0.5)}$ também falsa, ou seja, $E\tau$ é também paracompleta. Daí, $E\tau$ é não-alética.

De modo geral $\neg p_{(\mu,\ \lambda)} \leftrightarrow p_{(\lambda,\ \mu)}$. O fato de a negação lógica ser "absorvido" na anotação faz com que a lógica $E\tau$ tenha propriedades de fundamental importância nas implementações físicas, bem como propriedades de extrema fecundidade em programação lógica paraconsistente.

O par (μ, λ) denomina-se constante de anotação. Tal par é um elemento de $[0,1] \times [0,1]$ que algumas vezes indicamos por $[0,1]^2$. Tal conjunto está munido de uma relação de ordem assim definida: $(\mu_1, \lambda_1) \leq (\mu_2, \lambda_2) \Leftrightarrow \mu_1 \leq \mu_2$ e $\lambda_1 \leq \lambda_2$. Tal quadrado unitário com a relação de ordem constitui um reticulado que simbolizamos por τ (Abe, 1992; Abe, 2006b).

No reticulado τ existem quatro pontos que nortearão nossas perquirições. Denominemos de pontos ou estados cardeais. Tais são elas:

$A \equiv (1.0, 0.0) \equiv$ estado verdadeiro

$B \equiv (0.0, 1.0) \equiv$ estado falso

$C \equiv (1.0, 1.0) \equiv$ estado inconsistente

$D \equiv (0.0, 0.0) \equiv$ estado paracompleto

Embasados nos estados cardeais, e pelo uso das propriedades dos números reais, vamos cuidadosamente erigir uma estrutura matemática com o fito de materializar nossas idéias de como queremos manipular mecanicamente o conceito de incerteza, contradição e de paracompleteza, entre outros. Tal mecanismo embarcará, naturalmente, de algum modo os estados verdadeiro e falso, tratados dentro do escopo da lógica clássica, com todas as suas conseqüências (Abe, 1992; Abe, 2006b).

Para tanto, se introduz diversos conceitos "intuitivos" para a finalidade descrita acima.

Segmento perfeitamente definido AB: $\mu + \lambda - 1 = 0;\ 0 \leq \mu, \lambda \leq 1$

Segmento perfeitamente indefinido DC: $\mu - \lambda = 0;\ 0 \leq \mu, \lambda \leq 1$

Introduzimos as aplicações: $G_{ic}:[0, 1]\times[0, 1] \rightarrow [0, 1]$, $G_{pa}:[0, 1]\times[0, 1] \rightarrow [-1, 0]$, $G_{ve}:[0, 1]\times[0, 1] \rightarrow [0, 1]$, $G_{fa}:[0, 1]\times[0, 1] \rightarrow [-1, 0]$ definidas por:

Grau de Inconsistência: $G_{ic}(\mu, \lambda) = \mu + \lambda - 1$, desde que $\mu + \lambda - 1 \geq 0$

Grau de Paracompleteza: $G_{pa}(\mu, \lambda) = \mu + \lambda - 1$, desde que $\mu + \lambda - 1 \leq 0$

Grau de Veracidade: $G_{ve}(\mu, \lambda) = \mu - \lambda$, desde que $\mu - \lambda \geq 0$

Grau de Falsidade: $G_{fa}(\mu, \lambda) = \mu - \lambda$, desde que $\mu - \lambda \leq 0$

Vê-se que o Grau de Inconsistência "mede"[1] o quão uma anotação (μ, λ) "distancia" do segmento perfeitamente indefinido e quão se "aproxima" do estado inconsistente e o Grau de Paracompleteza "mede" o quão uma anotação (μ, λ) "distancia" do segmento perfeitamente indefinido e quão se "aproxima" do estado paracompleto.

Chama-se Grau de Contradição G_{ct} (μ, λ) de uma anotação (μ, λ) a qualquer um dos graus de inconsistência ou de paracompleteza. Por exemplo, o grau de Incerteza é máximo no estado inconsistente, ou seja, $G_{ic}(1, 1) = 1$.

De modo similar, o Grau de Veracidade "mede" [1] o quão uma anotação (μ, λ) "distancia" do segmento perfeitamente definido e quão se "aproxima" do estado verdade e o Grau de Falsidade "mede" o quão uma anotação (μ, λ) "distancia" do segmento perfeitamente definido e quão se "aproxima" do estado falso.

Chama-se Grau de Certeza G_c (μ, λ) de uma anotação (μ, λ) a qualquer um dos graus de verdade ou de falsidade. Por exemplo, o grau de verdade da anotação (½, ¼) é ¼, ou seja, $G_{ve}(½, ¼) = ¼$.

Com os conceitos expostos acima, podemos trabalhar com "faixas" de verdade ao invés de apenas um "ponto" de verdade (Abe, 1992; Abe, 2006b).

A seguir, introduzam-se, também, os seguintes conceitos:

Quatro valores limites externos:

$V_{cve} = C_1$ = Valor de controle de veracidade; $0 \leq V_{cve} \leq 1$

$V_{cfa} = C_2$ = Valor de controle de falsidade; $-1 \leq V_{cfa} \leq 0$

---

1) Convém ressaltar que não se trata de medida métrica.

$V_{cic} = C_3$ = Valor de controle de inconsistência; $0 \leq V_{cic} \leq 1$

$V_{cpa} = C_4$ = Valor de controle de paracompleteza; $-1 \leq V_{cpa} \leq 0$

Esses valores nortearão quando uma proposição é considerada, por exemplo, "verdadeira" no sentido de tomarmos uma decisão positivamente, e assim por diante. A Figura 2 e a Figura 3 nos ajudam a introduzir conceitos suplementares.

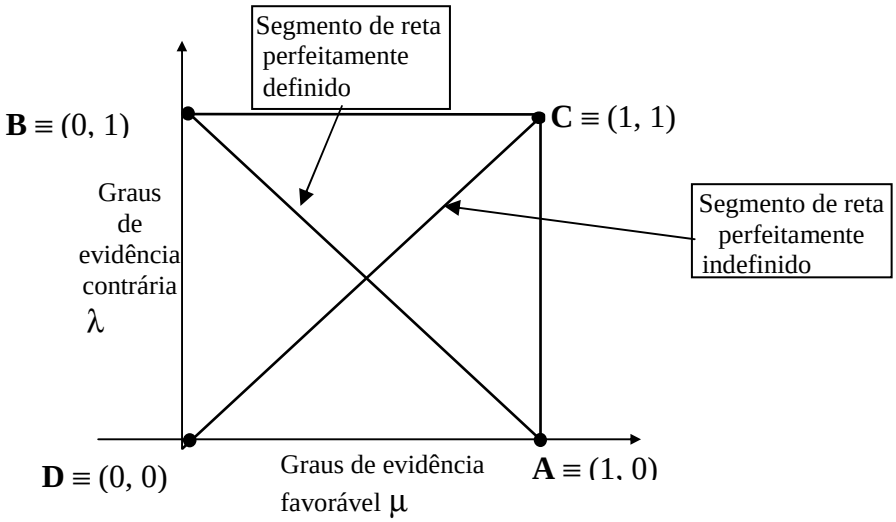

Figura 2 – Esquema de posições do reticulado. Ponto A corresponde ao extremo verdadeiro; Ponto B corresponde ao extremo falso; Ponto C corresponde ao extremo inconsistente e o ponto D corresponde ao extremo paracompleto.

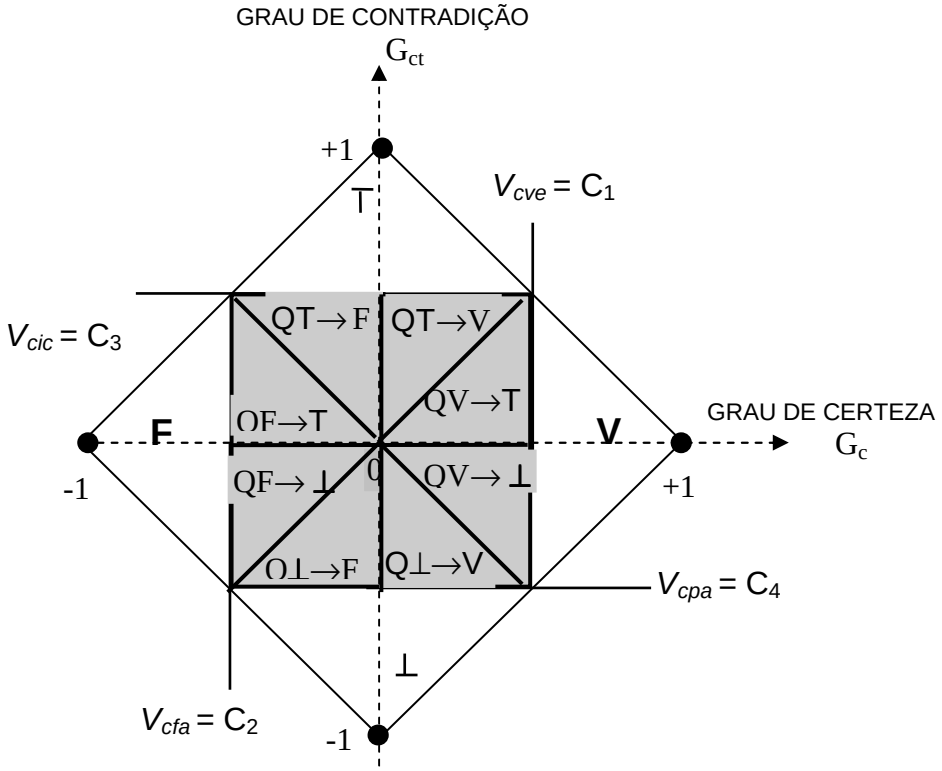

Figura 3 - Diagrama com os graus de incerteza e de certeza, com valores ajustáveis de controle limite indicados nos eixos. Observe também as regiões consideradas, conforme Tabela 1 e Tabela 2.

Estados Extremos	Símbolo
Verdadeiro	V
Falso	F
Inconsistente	T
Paracompleto	⊥

Tabela 1 - Estados lógicos extremos do reticulado.

Estados Não-Extremos	Símbolo
Quase-verdadeiro tendendo ao Inconsistente	QV→T
Quase-verdadeiro tendendo ao Paracompleto	QV→⊥
Quase-falso tendendo ao Inconsistente	QF→T
Quase-falso tendendo ao Paracompleto	QF→⊥
Quase-inconsistente tendendo ao Verdadeiro	QT→V
Quase-inconsistente tendendo ao Falso	QT→F
Quase-paracompleto tendendo ao Verdadeiro	Q⊥→V
Quase-paracompleto tendendo ao Falso	Q⊥→F

Tabela 2 - Estados lógicos não-extremos do reticulado.

As regiões de estados lógicos do reticulado são facilmente caracterizáveis através dos graus de incerteza e de certeza (Da Costa et al., 1999) e sua subdivisão é ajustável de acordo com as característica e peculiaridades de cada aplicação.

1.4. Redes Neurais Artificiais

Atualmente há múltiplas teorias e técnicas muito desenvolvidas na área de Inteligência Artificial nas mais variadas aplicações. Grande parte deste impulso se deve naturalmente à complexidade de se descrever partes de nossa realidade e também ser necessário manipular mecanicamente tais sistemas de informações.

A fim de "modelar" porções da realidade que são dinâmicos, exigem-se teorias que se adaptem às mudanças, "aprendendo" novas etapas e "adaptando-se" às novas configurações que enfrentam.

As teorias das redes neurais artificiais são paradigmas computacionais baseados em modelos matemáticos que a despeito das tradicionais computações possuem uma estrutura e operação que, grosso modo, tentam "imitar" o funcionamento do neurônio biológico humano e assim, "simule" de algum modo como o cérebro humano "funciona" frente a determinadas situações.

Tais redes também são conhecidas como sistemas conexionistas, sistemas paralelos distribuídos ou sistemas adaptativos, pois são compostos por uma série de elementos de processamento interconectados que operam em paralelo.

As redes neurais artificiais clássicas carecem de controle centralizado em sentido clássico, porquanto todos os elementos de processamentos interconectados

mudam ou se “adaptam” simultaneamente com o fluxo de informação e regras adaptativas.

Um dos objetivos originais das redes neurais artificiais é entender e modelar as características funcionais e propriedades computacionais do cérebro quando executa processos cognitivos tais como percepção sensorial, categorização de conceitos, associação de conceitos e aprendizado. Entretanto, um grande esforço está direcionado nas aplicações que envolvem reconhecimento e classificação de padrões, compressão de dados e otimização de processos.

Uma rede neural artificial genérica pode ser definida como um sistema computacional consistindo de um conjunto de elementos de processamento altamente interconectados, denominados neurônios artificiais, o qual processa uma informação como resposta a um estímulo externo. Um neurônio artificial é uma representação simplificada que emula a integração de sinais e dispara no limiar comportamento dos neurônios biológicos por meio de equações matemáticas.

Como em sua contraparte biológica, neurônios artificiais são limitados conjuntamente por conexões que determinam o fluxo de informações entre os neurônios. Estímulos são transmitidos de um processamento a outro, via sinapses ou interconexões, que podem ser excitatórios ou inibitivos. Se o input a um neurônio é excitatório, é mais provável que este neurônio transmita um sinal excitatório aos outros neurônios a ele conectados. Um input inibitório provavelmente se propagará como inibitório Abe, 2008.

Redes neurais artificiais dispõem-se tipicamente em “camadas”. Cada camada em uma rede neural constitui um arranjo de elementos processadores ou neurônios. Informações fluem através de cada elemento na forma de input-output. Em outras

palavras, cada elemento recebe um sinal de input, manipula-o e encaminha um sinal de output a outros elementos conectados na camada adjacente (Figura 4), desta maneira, é possível realizar processamento paralelo, ou seja, executar vários processamentos interligados simultaneamente.

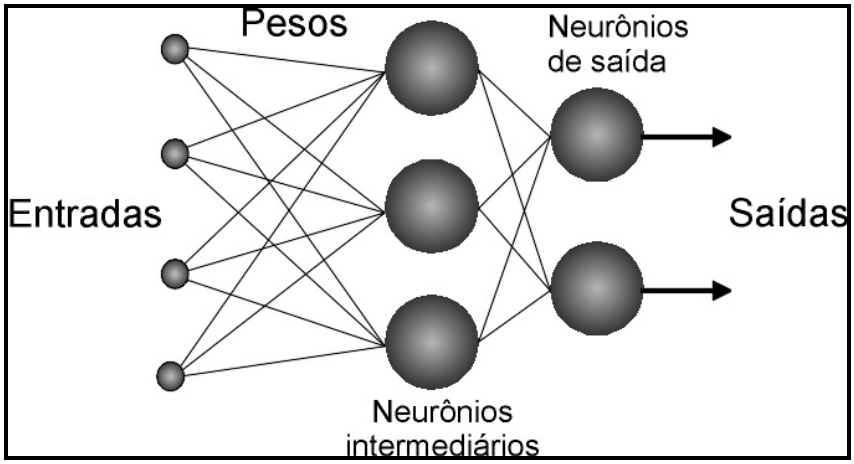

Figura 4 - Esquema básico da RNA clássica. Entradas: são os sinais de entradas (input); Pesos: balanceiam os dados de input de acordo com sua relevância; Neurônios intermediários: realizam os cálculos do processamento; Neurônios de saída – preparam os dados processados para a saída. Saídas: são os valores resultantes do processamento (output).

Um aspecto diferenciador das redes neurais artificiais sobre as programações convencionais reside em sua habilidade em resolver problemas que não possuem solução algorítmica ou a solução disponível é complexa para ser obtida.

As redes são poderosas para enfrentar problemas que são características mais de seres humanos: predição e reconhecimento de padrões Abe, 2008.

Seguir será apresentado a Rede Neural Artificial Paraconsistente, que se trata da construção de uma nova rede neural artificial baseado nas lógicas paraconsistentes anotadas.

1.5. Redes Neurais Artificiais Paraconsistentes

A Rede Neural Artificial Paraconsistente (RNAP), apresenta algumas características distintas das demais redes estudadas na literatura. Inicialmente, sua construção se assenta em idéias baseadas na Lógica Paraconsistente Anotada Evidencial Eτ (Da Silva Filho, 2001).

Por ter novo embasamento, a construção das células artificiais segue idéias distintas também das usuais, bem como todo o seu funcionamento.

A unidade neural mais básica consiste de duas entradas (inputs) e uma saída (output) e denomina-se como Célula Artificial Paraconsistente básica (CAPb) (Da Silva Filho, 2001). A Figura 5 mostra sua representação gráfica.

A primeira entrada da CAPb é o grau de evidência favorável (ou grau de crença favorável, ou μ) à proposição analisada.

A segunda entrada da CAPb é o grau de evidência contrário (ou grau de crença desfavorável, ou λ).

A saída da CAPb é a resultante calculada (ou μ_r) pelos grau de certeza (G_c) e grau de contradição (G_{ct}) com base nos valores de entrada (μ e λ), conforme visto no tópico 1.3.1 .

Uma outra característica importante é quanto ao desempenho da rede. Esperamos que com o novo embasamento, o comportamento da rede seja promissor com respeito a desempenho, rapidez de processamento, e outros aspectos esperados ou desejáveis das redes neurais artificiais.

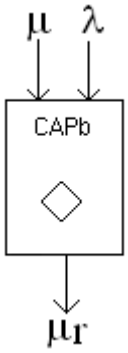

Figura 5 - Célula artificial paraconsistente básica.

Agregando-se mais algumas características à CAPb, cria-se a Célula Neural Artificial Paraconsistente (CNAP).

A primeira característica é a normalização das saídas, pois, como se pode identificar a saída resultante (μ_r) pertencentes ao intervalo real [-1, 1]. Define-se então a saída u_r somente em função das entradas, chegando-se ao resultado:

$$\mu_r = (\mu - \lambda + 1) / 2$$

Outra característica é a tolerância. Os fatores de tolerância servem para simplificar o funcionamento da CAPb, pois não são em todos os níveis da RNAP que se utiliza o reticulado completo. Em alguns níveis da RNAP são necessárias apenas as respostas Verdadeira (V), Falsa (F) e Indefinida (I).

No caso de indefinição, é necessário informar se a indefinição existe por insuficiência de informações, ou por alta contradição. Define-se então:

- Fator de tolerância à contradição (Ft_{ct}): Define a tolerância ao grau de contradição: $0 \leq Ft_{ct} \leq 1$. A partir disto, se $|G_{ct}| < Ft_{ct}$, então, $\mu_r = (\mu - \lambda + 1) / 2$ e o sinal de resposta à contradição é $S_{ct} = 0$; caso contrário, $\mu_r = ½$ e $S_{ct} = |G_{ct}|$.

- Fator de tolerância à certeza (Ft_c): Define a tolerância ao grau de certeza: $0 \leq Ft_c \leq 1$. A partir disto se $| G_c | > Ft_c$ então $\mu_r = (\mu - \lambda + 1) / 2$; caso contrário $\mu_r = ½$.

A partir destes fatores apresentados, tem-se o controle completo da CNAP, simplificando ou mantendo o reticulado.

Para que se possam efetuar operações lógicas entre as proposições A: $P_a(\mu_a, \lambda_a)$, onde μ_a é o grau de crença da proposição A, e λ_a é o grau de descrença da proposição A; e B**:** $P_b(\mu_b, \lambda_b)$ onde μ_b é o grau de crença da proposição B, e λ_b é o grau de descrença da proposição B; e sendo μ_{r1} o grau de crença resultante e μ_{r2} o grau de descrença resultante, definem-se:

- Maximização (ou disjunção, OR) entre A e B:

  Se $\mu_a < \mu_b$ então $\mu_{r1} = \mu_b$; caso contrário, $\mu_{r1} = \mu_{a.}$

  Se $\lambda_a < \lambda_b$ então $\mu_{r2} = \lambda_b$; caso contrário, $\mu_{r2} = \lambda_{a.}$

- Minimização (ou conjunção, AND) entre A e B:

  Se $\mu_a > \mu_b$ então $\mu_{r1} = \mu_b$; caso contrário, $\mu_{r1} = \mu_{a.}$

  Se $\lambda_a > \lambda_b$ então $\mu_{r2} = \lambda_b$; caso contrário, $\mu_{r2} = \lambda_{a.}$

- Negação (NOT) de A:

  $\mu_{r1} = \mu_b$ e $\mu_{r2} = \mu_a$ (Vale a pena ressaltar que a negação de A também se poderia calcular por: $\mu_{r1} = 1-\mu_a$ e $\mu_{r2} = 1-\mu_b$).

- O complemento (COMP) de A:

  $\mu_{r1} = 1 - \mu_a$ e $\mu_{r2} = 1- \mu_b$

A partir deste estudo prévio, a seguir será apresentada a família das Células Neurais Artificiais Paraconsistentes (CNAP), onde cada uma das CNAPs serão detalhadas em suas entradas, que são os sinais recebidos, seus cálculos, que são efetuados internamente, e suas saídas, que são fornecidas para as células seguintes ou interpretadas por camada de decisão final.

1.5.1. Célula Neural Artificial Paraconsistente de conexão analítica

A Célula Neural Artificial Paraconsistente de conexão analítica (CNAPca) é a principal célula de toda RNAP, obtendo-se o grau de crença (G_c) e o grau de contradição (G_{ct}) a partir das entradas e dos fatores de tolerância.

- Entradas: μ, λ, Ft_c, Ft_{ct}.
- Cálculos: $\lambda_c = 1 - \lambda$, $G_{ct} = \mu + \lambda_c - 1$, $G_c = \mu - \lambda_c$, $\mu_r = (G_c + 1) / 2$.
- Saídas: se $|G_c| > Ft_c$ então $S_1 = \mu_r$ e $S_2 = 0$; Se $|G_{ct}| > Ft_{ct}$ e $|G_{ct}| > |G_c|$ então $S_1=\mu_r$ e $S_2 = |G_{ct}|$, caso contrário, $S_1=½$ e $S_2= 0$.

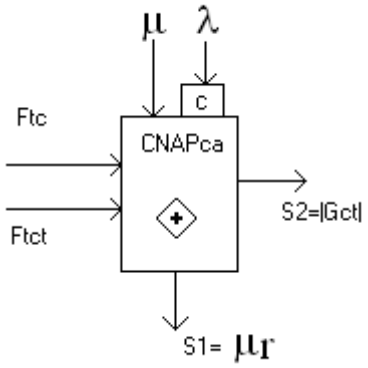

Figura 6 - Representação gráfica da CNAPca

1.5.2. Célula Neural Artificial Paraconsistente de conexão lógica simples para maximização

A Célula Neural Artificial Paraconsistente de conexão lógica simples para maximização (CNAPclsmax) permite a seleção do valor máximo entre as entradas.

- Entradas: μ, λ.
- Cálculos: Não há.
- Saídas: se $\mu > \lambda$ então $S_1 = \mu$, caso contrário, $S_1 = \lambda$.

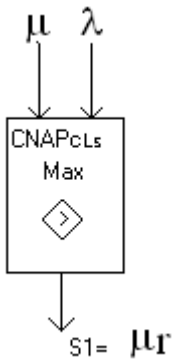

Figura 7 - Representação gráfica da CNAPclsmax.

1.5.3. Célula Neural Artificial Paraconsistente de conexão lógica simples de minimização

A Célula Neural Artificial Paraconsistente de conexão lógica simples de minimização (CNAPClsmin) permite a seleção do valor mínimo entre as entradas**.**

- Entradas: μ, λ.
- Cálculos: Não há.
- Saídas: se $\mu < \lambda$ então $S_1 = \mu$, caso contrário, $S_1 = \lambda$.

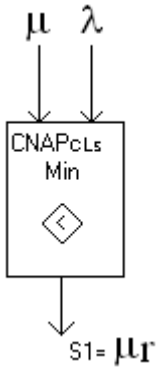

Figura 8 - Representação gráfica da CNAPClsmin.

1.5.4. Célula Neural Artificial Paraconsistente de conexão lógica seletiva de maximização

A Célula Neural Artificial Paraconsistente de conexão lógica seletiva de maximização (CNAPClsemax) permite, além da seleção do valor máximo entre as entradas, escolher o caminho que a informação segue, desviando o fluxo do processamento para uma camada diferente da Rede.

- Entradas: μ, λ.
- Cálculos: Não há.
- Saídas: se $\mu > \lambda$ então $S_1 = \mu$ e $S_2 = ½$; caso contrário, $S_1 = ½$ e $S_2 = \lambda$.

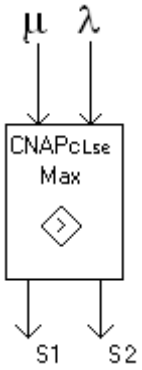

Figura 9 - Representação gráfica da CNAPClsemax.

1.5.5. Célula Neural Artificial Paraconsistente de conexão lógica seletiva de minimização

A Célula Neural Artificial Paraconsistente de conexão lógica seletiva de minimização (CNAPclsemin) permite, além da seleção do valor mínimo entre as entradas, escolher o caminho que a informação segue, desviando o fluxo do processamento para uma camada diferente da RNAP.

- Entradas: μ, λ.
- Cálculos: Não há.
- Saídas: se $\mu < \lambda$ então $S_1 = \mu$ e $S_2 = ½$, caso contrário, $S_1 = ½$ e $S_2 = \lambda$.

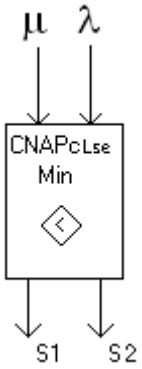

Figura 10 - Representação gráfica da CNAPclsemin.

1.5.6. Célula Neural Artificial Paraconsistente de complementação

A Célula Neural Artificial Paraconsistente de complementação (CNAPco) permite efetuar o cálculo do complemento da entrada, considerando o Fator de tolerância à complementação (Ft_{co}) que define se a saída é indefinida ou pode conter o complemento da entrada.

- Entradas: μ, Ft_{co}.
- Cálculos: $\mu_c = 1-\mu$.
- Saídas: $\mu_r = (\mu_c - \mu + 1) / 2$ se $\mu_r \geq Ft_{co}$, caso contrário, $\mu_r = ½$.

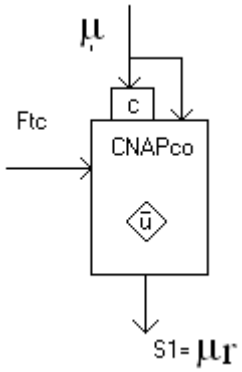

Figura 11 - Representação gráfica da CNAPco.

1.5.7. Célula Neural Artificial Paraconsistente de decisão

A Célula Neural Artificial Paraconsistente de decisão (CNAPd) permite identificar a interpretação do valor obtido, podendo ser verdadeiro, falso ou outro valor qualquer, de acordo com a tabela de constantes anotacionais definida.

- Entradas: μ, λ, Ft_d.
- Cálculos: $Vl_f = (1- Ft_d) / 2$, $Vl_v = (1 + Ft_d) / 2$, $\mu_r = (\mu - \lambda + 1) /2$.
- Saídas: se $\mu_r \geq Vl_v$, então S1 = 1 (V)**,** se $\mu_r \leq Vl_f$ então $S_1 = 0$ (F), caso contrário, deve seguir a tabela de constantes anotacionais exemplificada no tópico 1.3.1 (Figura 3).

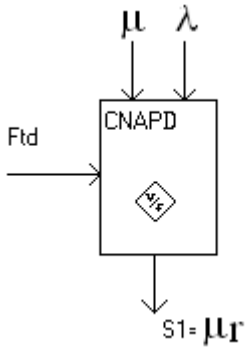

Figura 12 - Representação gráfica da CNAPd.

1.5.8. Célula Neural Artificial Paraconsistente de aprendizagem, desaprendizagem e memorização.

A Célula Neural Artificial Paraconsistente de aprendizagem, desaprendizagem e memorização (CNAPadm) foram definidas de forma a poder aprender, desaprender ou memorizar um padrão.

A CNAPadm é uma célula capaz de armazenar um sinal apresentado na entrada, se o Fator de aprendizagem (F_a) for diferente de 0, e retornar para 0, se o Fator de desaprendizagem (F_{da}) for diferente de zero; estes fatores nunca podem ser diferentes de zero simultaneamente.

Seu funcionamento interno pode ser alterado dependendo das necessidades de cada aplicação.

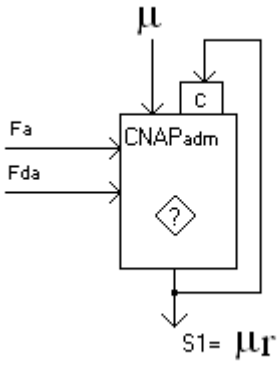

Figura 13 - Representação gráfica da CNAPadm.

1.5.9. Unidades Neurais Artificiais Paraconsistentes.

Uma Unidade Neural Artificial Paraconsistente (UNAP) se caracteriza pela associação ordenada de CNAPs, visando um objetivo, tais como tomada de decisão, seleção, aprendizado, ou algum outro tipo de processamento.

Ao se criar uma UNAP, obtenha-se um componente de processamento de dados capaz de simular o funcionamento de um neurônio (Da Silva Filho, 2001).

1.5.10. Sistemas Neurais Artificiais Paraconsistentes

Sistemas clássicos baseados na lógica binária encontram dificuldades para processarem dados ou informações provenientes de conhecimento incerto. Estes dados que são informações captadas ou recebidas de vários especialistas, geralmente, vêm em forma de evidências que trazem muitas contradições.

Os Sistemas Neurais Artificiais Paraconsistentes (SNAP's) são módulos configurados e construídos exclusivamente por UNAP's, cuja função é proporcionar

o tratamento de sinais de forma semelhante ao processamento que ocorre no cérebro humano (Da Silva Filho, 2001).

Dependendo de como foram construídas as interligações e as combinações das UNAP's, pode-se formar dois tipos de SNAP's:

- Sistemas Neurais Artificiais Paraconsistentes de aprendizado condicionado (SNAPac).
- Sistemas Neurais Artificiais Paraconsistentes de tratamento de contradições (SNAPtc).

1.5.10.1. Sistemas Neurais Artificiais Paraconsistentes de aprendizado condicionado

Sistemas Neurais Artificiais Paraconsistentes de aprendizado condicionado (SNAPac) é configurado de maneira a processar dados conforme as leis de aprendizado de Hebb (Hebb, 1949) que diz:

- Quando um axônio de uma célula *A* está próximo o suficiente para excitar uma célula *B*, e, repetitivamente ou persistentemente, toma parte da ativação desta, algum processo de crescimento ou mudança metabólica acontece em uma ou ambas as células, tal que a eficiência de *A*, como uma célula capaz de disparar *B*, é aumentada.

As CNAP's são condicionadas a apresentarem certos padrões na saída obtidos através de repetições de coincidências.

1.5.10.2. Sistemas Neurais Artificiais Paraconsistentes de tratamento de contradições

Sistemas Neurais Artificiais Paraconsistentes de tratamento de contradições (SNAPtc) promovem o tratamento de contradições, de modo contínuo, entre sinais de informações, com base na Lógica Paraconsistente Anotada (tópico 1.3).

Tal sistema neural artificial paraconsistente recebe três sinais na entrada e apresenta como resultado um valor que representa o consenso entre as três informações. As contradições existentes e entre dois valores são agregadas ao terceiro o valor, de tal forma que na saída predomina o valor proposto pela maioria.

A análise é feita de forma instantânea procedendo todo o processamento em tempo real, semelhante ao funcionamento dos neurônios biológicos.

2. OBJETIVOS

2.1. Objetivos gerais

- Classificação, análise e identificação de padrões de EEG por meio de metodologias computacionais.
- Avaliação, através de uma nova metodologia computacional baseado na lógica paraconsistente, de uma ferramenta de auxílio à predição e acompanhamento da DA.

2.2. Objetivos específicos

- Implementar uma Rede Neural Artificial Paraconsistente adequada à aprendizagem, armazenagem e classificação de padrões obtidos a partir de dados de EEG disponibilizado pelo Grupo de Neurologia Cognitiva e do Comportamento (GNCC) da divisão de Clinica Neurológica do Hospital das Clinicas da Faculdade de Medicina da Universidade de São Paulo.
- Ao receber dados de um exame, a rede deverá ser capaz de classificar as características do mesmo e sugerir sua tendência de acometimento de DA.

3. CASUÍSTICA E MÉTODOS

3.1. Casuística

Foram avaliados 67 pacientes, divididos em grupo controle e grupo DA respecticamente, conforme Tabela 3.

	Indivíduos Normais Grupo Controle	**Indivíduos DA provável Grupo DA**
Homens	8	6
Mulheres	26	27
Idade média	61,38	68
Escolaridade	8,12	6,21
MEEM	24,53	20,58

Tabela 3 - Grupo de indivíduos selecionados para o estudo. Homens: Pacientes do gênero masculino; Mulheres: Pacientes do gênero feminino; Idade média: Média das idades dos pacientes; Escolaridade: Média dos anos de estudos dos pacientes; MEEM: Média da pontuação do mini exame de estado mental.

Na tabela a seguir é apresentada a casuística utilizadas neste estudo (Tabela 4).

N	P	M	G	I	E	D	C	P	M	G	I	E	D
1004	ON	26	1	70	4	1	8102	ABS	18	0	72	4	2
1103	DO	30	0	19	13	1	5801	TCS	14	0	73	0	1
1201	E	20	0	80	4	1	1504	CLD	30	0	19	12	1
1202	RA	29	1	38	22	1	8001	BLW	12	0	74	8	1
1302	MM	19	0	78	4	1	1703	CLD	19	0	19	12	2
1303	DO	30	0	20	12	1	1801	ZSA	17	0	48	4	2
1404	RA	29	1	38	22	1	2801	CRSV	21	0	52	4	2
1503	ACP	20	0	78	4	2	4301	NGP	17	0	69	4	1
1604	MLSD	19	0	71	4	2	7501	IOG	29	0	72	15	1
1605	DO	29	0	20	12	1	43901	AVB	17	0	69	4	2
1704	JSM	14	1	87	2	1	2101	MW	22	0	78	11	2
1802	DO	27	0	20	13	1	44001	ASS	17	0	71	1	2
1902	ILM	28	0	86	4	1	1701	LHO	20	1	18	13	2
2001	LBA	18	0	72	4	1	1102	MLCM	12	0	74	2	2
2102	DYT	26	0	21	12	1	1702	RF	23	1	74	6	2
2103	MRA	23	0	79	1	1	1301	MGC	16	0	62	15	2
2201	MHA	26	0	73	4	1	1606	OSP	8	0	77	4	2
2202	GM	18	0	63	10	2	3201	GBS	13	0	86	0	2
2302	GAA	25	0	28	11	1	1203	CLD	16	0	79	13	2
2401	NAG	26	1	76	4	1	4201	MAP	22	0	71	3	1
2501	YVG	21	0	74	0	1	1803	ABM	14	0	82	1	2
2701	AEJO	30	1	77	11	1	3101	JCS	15	1	76	4	2
2901	LFM	21	0	76	0	1	2601	RPS	22	0	81	4	2
3001	AB	29	1	70	15	2	7801	JIS	25	1	75	3	1
4001	TANB	23	0	68	4	2	4101	MTRS	25	0	64	3	2
5401	EC	26	1	64	5	2	6001	EGT	26	0	69	4	2
5901	DG	20	0	76	10	1	7901	AMNT	27	0	70	6	1
6101	EFRC	26	0	74	5	2	5701	ABC	28	0	66	4	2
6501	LANG	27	0	65	15	1	2203	JPNF	14	1	75	1	2
7101	JTBT	28	0	73	15	1	6201	ESE	27	0	74	8	2
7201	OTWNV	28	0	75	11	1	6301	MF	29	0	72	15	2
7601	JS	28	1	73	4	1	7301	AOFFS	30	0	70	11	1
7701	RKG	29	0	64	4	2	5501	TMOG	22	0	78	2	2
6401	RRS	28	0	76	15	2							

Tabela 4 – Casuística utilizada neste trabalho. N: número do exame; P: paciente; M: pontuação do mini exame de estado mental; G: gênero, onde 1 – Masculino, 0 – Feminino; I: idade do paciente; E: escolaridade (anos de estudo) D: diagnóstico, onde 1 – Nomal, 2 – DA provável.

Todos os pacientes foram acompanhados no Ambulatório de Neurologia Cognitiva e do Comportamento (GNCC) da Divisão de Clínica Neurológica do Hospital das Clínicas – Faculdade de Medicina da Universidade de São Paulo (HC - FMUSP).

Os pacientes do grupo DA foram submetidos à avaliação ambulatorial de rotina do GNCC, constituída de exame físico e neurológico, avaliação laboratorial, incluindo exames de hemograma completo, T4 livre, TSH, glicemia de jejum, uréia, creatinina, dosagem de vitamina B12 sérica, dosagem de ácido fólico sérico, VDRL e FTA-ABS séricos, avaliação neuropsicológica e exame de imagem (tomografia computadorizada de crânio ou ressonância nuclear magnética) (Nitrini et al., 2005).

Os exames de eletroencefalografia também foram realizados no mesmo ambulatório do HC-FMUSP. Foram excluídos do presente estudo indivíduos com antecedentes de diabetes mellitus, nefropatias, tireoideopatias, alcoolismo, hepatopatias, doenças pulmonares e carência de vitamina B12 (Anghinah, 2003).

3.2. Métodos

3.2.1. Aquisição de dados

Para os registros de EEG quantitativo utilizou-se equipamento digital da marca EMSA – Equipamentos Médicos Ltda, com 32 canais, processador de 12 bits e frequência amostral de 200 Hz, com programa de análise capacitado a realizar estudos quantitativos do EEG e análise de coerência por Transformação Rápida de Fourier (FFT).

A colocação dos eletrodos de escalpo (Fp1, Fp2, Fz, F3, F4, F7, F8, C3, C4, Pz, P3, P4, T5, T6, O1 e O2), seguiu as normas da Sociedade Brasileira de Neurofisiologia Clínica, utilizando o sistema 10-20, conforme esquema da Figura 14 (Jasper, 1958; Luccas at al., 1998).

Os registros foram obtidos com os indivíduos em vigília durante o repouso, e com olhos fechados. O tempo de aquisição do exame foi de, no mínimo, 20 minutos com filtros passa alta e passa baixa com frequências de corte entre 0,5 e 30 Hz (Anghinah, 2003).

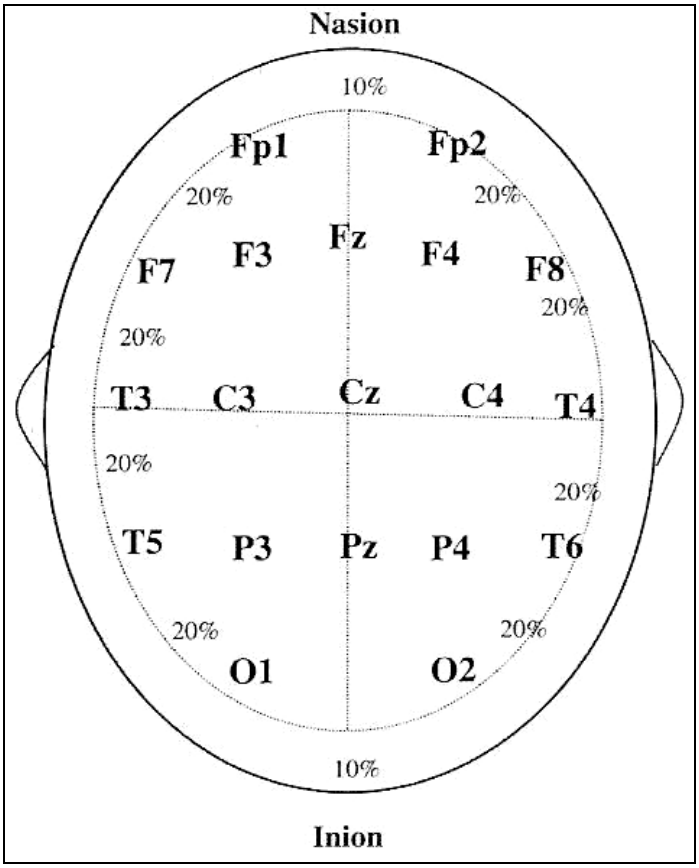

Figura 14 - Diagrama do sistema 10-20 para colocação de eletrodos no escalpo. Números ímpares correspondem aos eletrodos do hemisfério cerebral esquerdo. Números pares correspondem aos eletrodos do hemisfério cerebral direito. A letra Z indica eletrodos da linha média. As regiões são definidas pelas letras: Fp – fronto-polar; F – frontal; C – central; T – temporal; P – pariental; O – occipital (Montenegro et al., 2001).

Selecionou-se vinte épocas de 2,56 segundos de duração por exame, que à análise visual estavam livres de achados transitórios, paroxismos e artefatos porém os artefatos por movimentos palpebrais e oculares são de difícil exclusão do traçado, por mais rigorosos que sejam os cuidados técnicos. Deste modo foram escolhidas as épocas em que a análise visual demonstrava estar livre de artefatos.

Cada indivíduo realizou um registro de EEGq, que foi analisado visualmente e as vinte épocas selecionadas de cada exame foram, para cada indivíduo, submetidas ao cálculo do espectro de potência, que gerou o espectro da atividade elétrica cerebral para cada exame e, posteriormente, a análise do sinal eletroencefalográfico nos domínios do tempo e da frequência baseada nos estudos da amplitude espectral máxima de cada indivíduo (Anghinah, 2003). Desta maneira pode-se agrupar os indivíduos, de maneira válida, em dois grupos: normais (controle) e com DA provável (Anghinah, 2003).

3.2.2. Análise de EEG baseado na RNAP

A metodologia de análise de EEG, baseado em conceitos de Lógica Paraconsistente Anotada Evidencial Eτ e RNAP, consiste em realizar comparações de pequenos trechos do exame de EEG com padrões de ondas pré-definidas e processar os dados gerados por essas comparações. Após o processamento dos dados, a RNAP terá como resposta um possível diagnóstico do indivído: normal ou DA provável.

O diagnóstico realizado pela RNAP terá como base apenas os dados referente ao exame de EEG.

Para testar a metodologia desenvolveu-se um *software* para realizar a leitura e o processamento dos dados, denominado Sistema de Análise Paraconsistente de EEG (SAP-EEG).

O SAP-EEG foi desenvolvido utilizando-se a linguagem de programação Delphi e banco de dados Firebird 1.0.

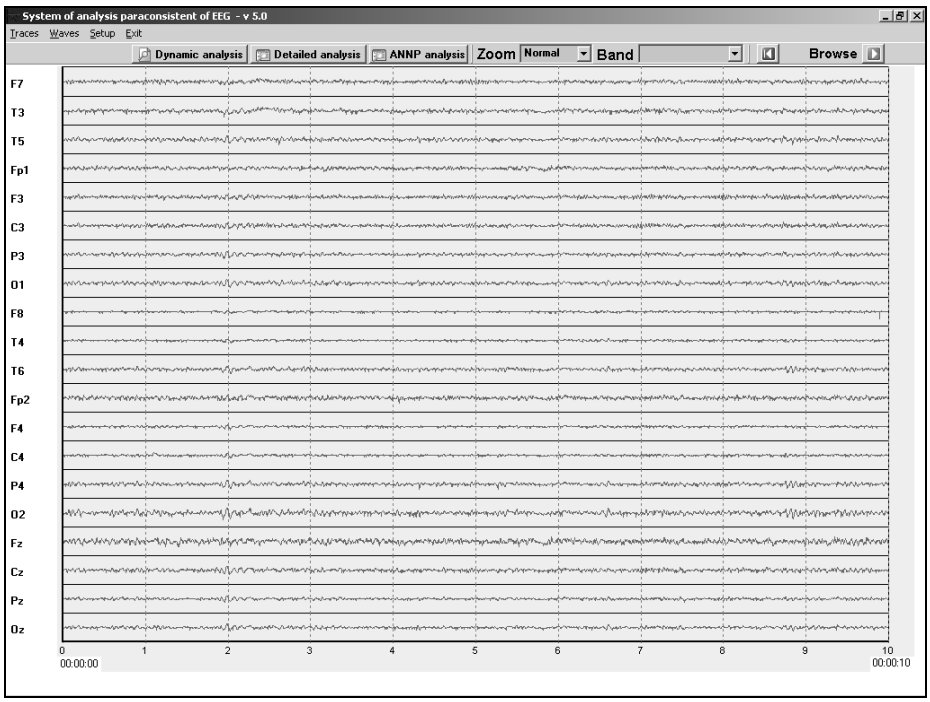

Figura 15. Tela do SAP-EEG com um exame lido. No lado esquerdo é apresentado os canais de leitura do exame, ao centro o traçado do EEG, na parte inferior a escala do traçado (em trechos de 1 segundo) e na parte superior os botões que ativam as análises do exame.

O funcionamento básico do SAP-EEG consiste em duas etapas distintas: definição de padrões de análise e processamento do exame.

3.2.2.1. Definição de padrões de análise

Conforme já foi abordado, a metodologia de análise paraconsistente de EEG tem como base a comparação de padrões. Para tanto, é necessário que o SAP-EEG armazene tais padrões.

Como padrão, foram armazenadas ondas com formato senoidal de modo que suas frequências se assemelhem com as bandas de frequências do EEG (Figura 1), as quais foram criadas utilizando o software MATLAB (software de simulação de ambientes e de processamentos matemáticos) e importadas pelo SAP-EEG, onde foram agrupadas, conforme suas frequências, seguindo a mesma classificação das bandas de frequência do EEG (Tabela 5).

Banda de frequência	**Faixa de frequência (Hz)**	
	Mínimo	**Máximo**
Delta	0,1	4,0
Teta	4,5	7,5
Alfa	8,0	12,0
Beta	12,5	>23,0

Tabela 5. Classificação de frequência das ondas para padrão de análise.

Foram armazenadas no SAP-EEG 129 ondas, com variação de 1,0 Hz cada, sendo 65 ondas com ciclo positivo e 64 com ciclo negativo abrangendo todas as habituais bandas de frequências de EEG.

Desta maneira, tem-se como padrão de normalidade ondas de frenqüência e formas pré-definidas e que serão utilizadas nas comparações dos trechos dos exames.

3.2.2.2. Processamento do exame

O processamento do exame consiste na leitura do EEG digital, seleção de períodos e a análise baseada em RNAP.

Para este processo, selecionou-se dez épocas de dois segundos de duração por exame. As épocas selecionadas, em análise visual, estavam livres de artefatos.

Como o objetivo é detectar o alentecimento de frequência na região occipital, selecionou-se apenas os eletrodos O1 e O2 para o processamento.

Os testes realizados neste estudo foram duplo–cego, ou seja, as análises realizadas utilizando a metodologia de análise por Lógica Paraconsistente e RNAP foram validades de forma que o diagnóstico real de cada indivíduo não fosse revelada ao responsável pelo teste.

3.2.3. Procedimentos para a análise de EEG baseada em RNAP

O processo de reconhecimento de padrões utilizando a RNAP passa por quatro fases de preparação de dados antes que estes sejam manipulados pela RNAP:

- Captura de dados
- Redução de valores para exibição do exame pelo SAP-EEG
- Eliminação de ciclo negativo
- Normalização de valores para análise

Vale lembrar que estes métodos de normalização de dados buscam o objetivo de facilitar a manipulação numérica do vetor, sem fazer com que o formato essencial da onda perca suas características.

Após esses processos, os valores serão submetidos aos sistemas especialistas e a RNAP para análise.

3.2.3.1. Captura de dados

A captura de dados ocorre pela leitura destes dados em arquivos magnéticos, onde os exames foram gerados previamente por outro aplicativo (no caso de EEG digitais, onde um software já realiza a captura física dos sinais e gera o arquivo magnético com o registro do exame para posterior análise). Outra maneira de captura de dados é manualmente (arquivos TXT - ASCII) com o intuito de realizar alguns ensaios e/ou testes.

3.2.3.2. Redução de valores para a exibição do exame pelo SAP-EEG

Como os valores reais de um exame de EEG podem variar, em módulo, algo entre 10 μV até 1500 μV (Montenegro et al., 2001), realiza-se uma normalização dos valores entre 100 e –100 (valores proporcionais à voltagem do sinal), para facilitar a manipulação dos dados para que os mesmos possam ser exibidos pelo SAP-EEG, utilizando a razão:

$$x = \left(\frac{100.a}{m} \right)$$

Onde: *pm* é o ponto máximo do exame (o ponto de maior valor).

pa é o ponto atual do exame.

x é o ponto atual normalizado

3.2.3.3. Eliminação do ciclo negativo

A eliminação de ciclo negativo consiste em definir um valor mínimo e padrão para a onda, verifica-se seu menor valor presente. Com base neste valor, a onda é transladada até que seu menor valor seja igualado a zero.

3.2.3.4. Normalização de valores para análise

A normalização faz a onda a se manter na faixa entre zero e cem. O valor mínimo já foi estipulado pela eliminação do ciclo negativo, mantendo-se sempre no valor zero. O valor máximo é normalizado de modo que não ultrapasse o cem.

3.2.3.5. Sistema especialista para análise de frequência e formato da onda

Com o sinal do EEG devidamente preparado para análise, pode-se iniciar o processo de reconhecimento de padrões. Para realizar este processo, torna-se interessante à implementação de um sistema especialista: o sistema de análise morfológica.

Este sistema especialista objetiva a análise do comportamento do sinal no aspecto morfológico, que visa verificar o formato apresentado na onda, onde é possível verificar “anormalidades” no sinal, tais como espículas e artefatos. Esta

análise também permite verificar a frequência dominante da onda, verificando de qual banda ela pertence (delta, teta, alfa e beta), pelo simples fato de que as ondas de controle (padrão de normalidades) estão armazenadas com frequências bem definidas, conforme visto anteriormente (tópico 3.2.2.1).

O sistema especialista fornecerá dois valores de saída. Um valor será a evidência favorável (μ) e o outro será a evidência contrária (λ).

Com esses dois valores é possível obter uma análise resultante, utilizando-se da lógica paraconsistente para o tratamento desses dados.

A seguir serão apresentadas as características das análises realizadas.

3.2.3.5.1. Análise morfológica

O processo da análise morfológica trata-se do reconhecimento de padrões que é realizado comparando-se cada ponto da onda com todas as ondas armazenadas no banco de dados de controle (ondas com padrão de normalidade).

A onda que apresentar a maior evidência favorável e a menor evidência contrária será escolhida como a onda mais similar à onda que está sendo analisada.

A seguir, é apresentado um exemplo do processo de reconhecimento, onde serão consideradas três ondas (Figura 16) de 20 elementos, com amplitude máxima de 11 pontos (de 0 a 10) e com valores hipotéticos (Tabela 6).

Este exemplo tem o objetivo de explicar, de forma minuciosa, o processo de reconhecimento de padrões utilizando esta metodologia.

Onda analisada	Onda aprendida 1	Onda aprendida 2
1	2	1
8	8	3
1	2	7
8	6	1
1	2	3
8	6	7
1	2	1
8	6	3
1	2	7
8	6	1
1	2	3
8	6	7
1	2	1
8	6	3
1	2	7
8	6	1
1	2	3
8	6	7
1	2	1
8	6	3

Tabela 6. Valores do exemplo do processo de reconhecimento de ondas. Suas formas podem ser visualizadas na Figura 16.

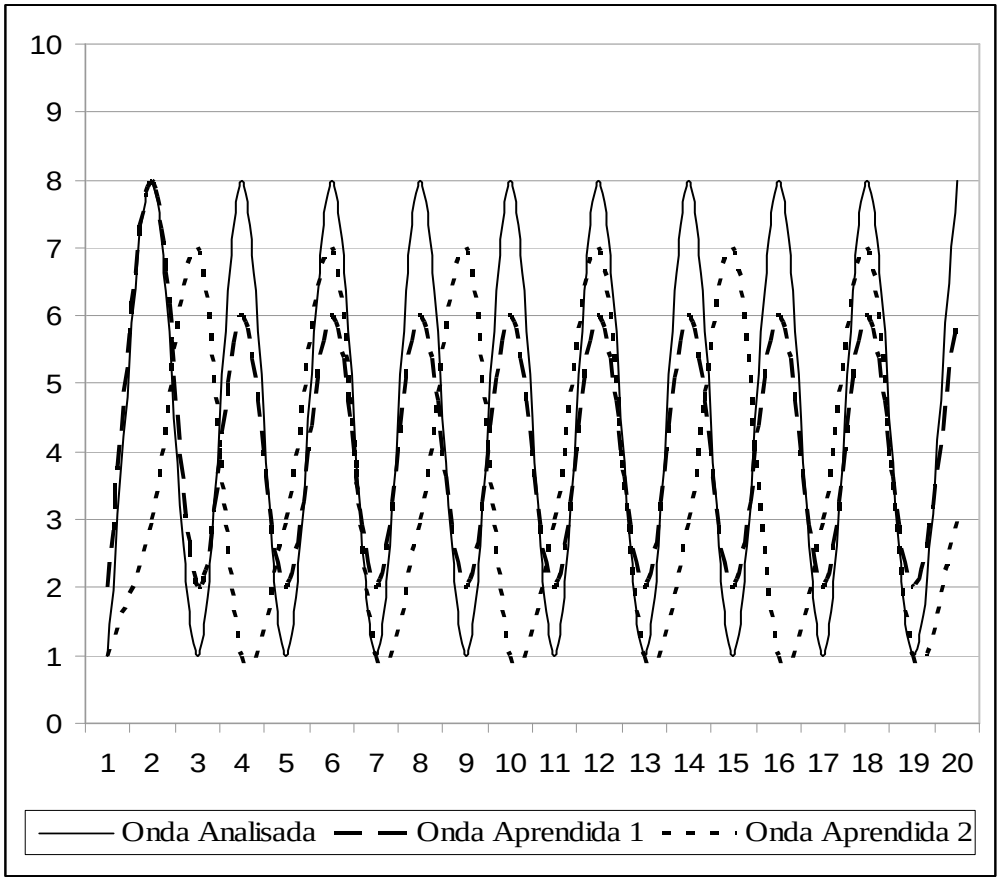

Figura 16. Exemplo visual de ondas usada na análise morfológica. Os valores dessas ondas são apresentados na Tabela 6.

A Onda analisada é a onda que será submetida à RNAP para reconhecimento. As Onda aprendida 1 e Onda aprendida 2 são duas ondas que foram previamente armazenadas no banco de dados controle (padrão de normalidade).

A evidência favorável é definida pelo complemento da somatória da quantidade de picos normalizado pela somatória da quantidade de picos:

$$Ef = 1 - \left(\frac{\left(|bd - vt| \right)}{\left(bd + vt \right)} \right)$$

Onde: *vt* é o números de picos da onda.

bd é o número de picos da onda armazenada no banco de dados.

Ef é a Evidencia favorável

A evidência contrária é definida pela somatória da diferença, em módulo, dos pontos (posições) diferentes, normalizado pela amplitude máxima e o total de elementos da onda:

$$Ec = \frac{\sum_{j=1}^{n} \left(\frac{\left| x_j - y_j \right|}{a} \right)}{n}$$

Onde: *n* é o total de elementos.

a é a amplitude máxima permitida.

j é o ponto atual.

EC é a Evidencia contrária.

O comparativo entra a Onda analisada e a Onda aprendida 1 pode ser acompanhado pela tabela a seguir (Tabela 7).

Onda analisada	**Onda aprendida 1**	**Diferença em móldudo**	**Normalização da diferença pela amplitude máxima**
1	2	1	0,1
8	8	0	0
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
1	2	1	0,1
8	6	2	0,2
Somatória das diferenças normalizadas: 2,8			
Evidencia Contrária (EC) (Normalizada pelo total de elementos): 0,14			

Tabela 7. Comparativo entre a Onda analisada e a Onda aprendida 1.

O comparativo entra a Onda analisada e a Onda aprendida 2 pode ser acompanhado pela tabela a seguir (Tabela 8):

Onda analisada	**Onda aprendida 2**	**Diferença em móludo**	**Normalização da diferença pela amplitude máxima**
1	2	1	0,1
8	8	5	0,5
1	2	5	0,5
8	6	5	0,5
1	2	1	0,1
8	6	1	0,1

1	2	1	0,1
8	6	3	0,3
1	2	5	0,5
8	6	5	0,5
1	2	1	0,1
8	6	1	0,1
1	2	1	0,1
8	6	3	0,3
1	2	5	0,5
8	6	5	0,5
1	2	1	0,1
8	6	1	0,1
1	2	1	0,1
8	6	3	0,3
Somatória das diferenças normalizadas: 5,4			
Evidencia Contrária (EC) (Normalizada pelo total de elementos): 0,27			

Tabela 8. Comparativo entre a Onda analisada e a Onda aprendida 2.

A seguir, realiza-se a comparação entra as ondas para analisar as diferenças entre a quantidade de picos (Tabela 9):

Ondas	**Onda Analisada**	**Onda Aprendida 1**	**Onda Aprendida 2**
Picos	9	9	6
Diferença entre as quantidades de picos, normalizado pela somatória da quantidade de picos da comparação das ondas:		0	0,2
Evidência Favorável (EF) Complementada:		1	0,8

Tabela 9. Normalização das evidências favoráveis e contrárias.

Com os valores de evidência favorável (μ) e da evidência contrária (λ) calculados, tem-se a seguinte condição:

Caso	Evidência Favorável (μ)	Evidência Contrária (λ)
Onda analisada X Onda aprendida 1	1,00	0,14
Onda analisada X Onda aprendida 2	0,8	0,27

Tabela 10. Normalização das evidências favoráveis e contrárias.

Logo, percebe-se que a onda com a maior evidência favorável e a menor evidência contrária é a Onda aprendida 1, ou seja, esta é a onda mais similar à Onda analisada.

Em termos práticos, pode-se dizer que ao analisarmos os picos das ondas, estamos analisando as frequências das ondas e quando analisamos os pontos diferentes das ondas, estamos analisando sua forma. Combinando os dois dados, tem-se a informação de quanto uma onda é similar à outra onda.

Ao final da análise morfológica, os valores de evidência favorável e evidência contrária são submetidos ao reticulado de estados lógicos (Figura 17) onde será definido seu estado lógico de saída, ou seja, se a similaridade entre as ondas é verdadeira ou não.

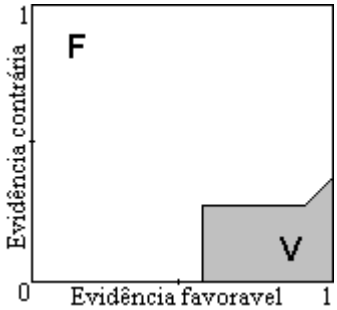

Figura 17. Reticulado para tomada de decisão utilizada na análise morfológica. F: Estado lógico falso (interpreta-se como onda não similar); V: Estado lógico verdadeiro (interpreta-se como onda similar).

Limite das áreas do reticulado	
Verdadeiro	0,60 <= Ef <= 0,90 Ec <= 0,28 Ef > 0,90 Ec < 0,28 0,62 <= G_c <= 0,72 0,28 < Ec <= 0,37
Falso	Ef < 0,60 Ec > 0,37 G_c < 0,62 Ec > 0,28

Tabela 11. Limites das áreas do reticulado para tomada de decisão utilizada na análise morfológica (Figura 17). Ec: evidência contrária; Ef: evidência favorável; G_c: grau de certeza;

3.2.3.6. Análise dos dados utilizando a RNAP

Após o processamento do sistema especialista de análise morfológica, os dados serão submetidos à análise da RNAP.

Neste momento, têm-se informações diversas do exame de EEG analisado, tais como a frequência média de uma determinada banda de frequência e quantidade de cada tipo de banda de frequência. Essas informações isoladamente não demonstram nenhuma conclusão importante, são apenas dados.

Para transformar esses dados em informações conclusivas, utiliza-se as RNAPs como método de tomada de decisão.

Como sinais de entrada da RNAP, são utilizados três sistemas especialistas que possuem a função e informar à RNAP informações quantificadas e relevantes à análise.

3.2.3.6.1. Sistema especialista de detecção de nível de diminuição de frequência média

Através de um parâmetro externo, este especialista verifica a frequência média de ondas alfas do exame e o compara com uma frequência média.

Como frequência média de comparação, utilizou-se uma média populacional de 10,0 Hz (Herrera et al., 1998).

Esta frequência média passada como parâmetro de comparação pode ser uma média populacional, tão como a frequência média do último exame do paciente. A segunda opção se torna mais interessante, visto que se pode fazer um acompanhamento do paciente, verificando possíveis alterações de frequência.

Este sistema vai gerar dois valores de saída:

- A evidência favorável (μ): terá seus valores normalizados em 0 (o que corresponde a 100% - ou mais - de perda de frequência) até 1 (o que corresponde a 0% de perda de frequência).
- A evidência contrária (λ): será o complemento da evidência favorável (μ), ou seja, $\lambda = 1 - \mu$.

3.2.3.6.2. Sistema especialista de detecção de concentração de ondas rápidas

Este especialista será utilizado para verificar a concentração de ondas rápidas no exame. Para tal, considera-se o quociente da somatória das ondas de frequências rápidas (alfa e beta) pelas ondas de frequências lentas (delta e teta), gerando duas saídas:

- Evidência favorável (μ): (alfa + beta) / (delta + teta)
- Evidência contrária (λ): será o complemento da evidência favorável (μ), ou seja, $\lambda = 1 - \mu$.

3.2.3.6.3. Sistema especialista de detecção de concentração de ondas lentas

Este especialista será utilizado para verificar a concentração de ondas lentas no exame. Para tal, considera-se o quociente da somatória das ondas de frequências lentas (delta e teta) pelas ondas de frequências rápidas (alfa e beta), gerando duas saídas:

- Evidência favorável (μ): (delta + teta) / (alfa + beta)
- Evidência contrária (λ): será o complemento da evidência favorável (μ), ou seja, $\lambda = 1 - \mu$.

3.2.3.6.4. Análise da RNAP

Conforme visto anteriormente, a RNAP utiliza-se de um ou mais Sistemas Neurais Artificiais Paraconsistentes para realizar o processamento de dados. Neste trabalho, utiliza-se um SNAPtc (tópico 1.5.10.2), para realizar o processamento final dos dados obtidos dos três sistemas especialistas (Figura 18).

Como estradas do SNAPtc têm-se:

- PA: A evidência favorável (μ) do sistema especialista de detecção de nível de diminuição de frequência média.
- PB: A evidência favorável (μ) do sistema especialista de detecção de concentração de ondas alfas.
- PC: A evidência favorável (μ) do Sistema especialista de detecção de concentração de ondas tetas.

As entradas PA, PB e PC são os valores reais no intervalo entre 0 (zero) e 1 (um) que representam em informações a respeito de uma mesma proposição. Quando o padrão apresenta o um valor 1 (um) significa que a informação é a representativa de uma proposição verdadeira. Quando o padrão vem com o valor 0 (zero) significa que é um sinal representativo da proposição falso. Uma proposição indefinida é representada por um padrão de valor 0,5 (meio).

Quando os três um sinais se apresentam com valor um 1 (um), significa que as informações a respeito de uma proposição estão dando uma conotação de verdade, sem existência de contradições. Se os três sinais se apresentam com valor 0 (zero), as informações a respeito da proposição darão uma conotação de falsidade. Na existência de diferença de valores entre dois sinais, significa que existe contradição, portanto, deve-se consultar um terceiro especialista, cuja informação ajudará na tomada de decisão.

No Sistema Neural Artificial Paraconsistente de tratamento de contradição, a consulta ao terceiro especialista é instantânea e contínua. Neste modo de análise, todas as informações, tanto as contraditórias como a do terceiro especialista são relevantes e, portanto, consideradas no resultado.

A primeira camada do sistema é composta por três células de conexão analítica: C1, C2 e C3 cujos sinais são analisados através da Equação Estrutural Básica (EBB) resultando nos sinais de saída SA, SB e SC:

$$S = \left(\frac{(\mu - (1 - \lambda) + 1)}{2} \right)$$ Onde: *S* é o sinal de saída.

Nas camadas internas, as células C4 e C6 constituem uma Unidade Neural de maximização e as células C5 e C7 uma Unidade de Neural de minimização.

Na Unidade de maximização, o maior valor entre as saídas SA, SB e SC, obtido pelas análises efetuadas nas células da primeira camada, vai aparecer na saída SG.

Na unidade Neural de minimização o valor resultante na saída SE será o menor que apresentar nas saídas SA, SB e SC. A célula C8 utiliza a EBB para fazer a última análise entre os sinais SF e SG (Da Silva Filho, 2001).

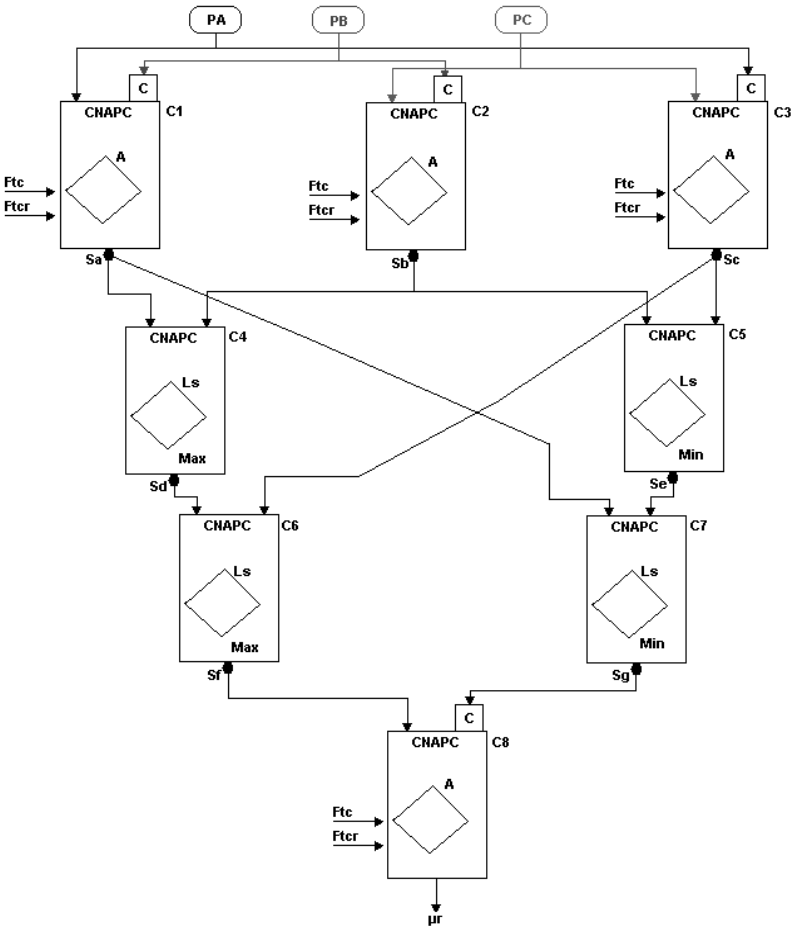

- **CNAPC A**: Célula neural artificial paraconsistente de conexão analítica.

- **CNAPC Ls Max**: Célula neural artificial paraconsistente de conexão lógica simples de maximização.

- **CNAPC Ls Min**: Célula neural artificial paraconsistente de conexão lógica simples de minimização.

- **Ftc**: Fator de tolerância à certeza.

- **Ftcr**: Fator de tolerância à contradição.

- **C**: Valor de entrada complementado.

- **μ_r**: Valor de saída da RNAP.

Figura 18. Esquema da SNAPtc. PA: Entrada do sistema especialista de detecção de diminuição de frequência média populacional; PB: Entrada do sistema especialista de detecção de bandas de baixa frequência; PC: Entrada do sistema especialista de detecção de bandas de alta frequência.
C1: conectado aos dados de entrada de PA e PB.
C2: conectado aos dados de entrada de PB e PC.
C3: conectado aos dados de entrada de PC e PA.
C1, C2 e C3 constituem a primeira camada da rede.
C4: calcula a máxima evidência entre as células C1 e C2.
C5: calcula a mínima evidência entre as células C2 e C3.
C4 e C5 constituem a segunda camada da rede.
C6: calcula a máxima evidência entre as células C4 e C3.
C7: calcula a mínima evidência entre as células C5 e C1.
C6 e C7 constituem a terceira camada da rede.
C8: Fornece o valor de decisão resultante.

Ao término da análise realizada pela RNAP, o valor resultante (μ_r) e complementa-lo, geram um valor resultante complementado (λ_r). Dessa forma têm-se uma evidência favorável resultante (μ_r) e uma evidência contrária resultante (λ_r).

Em seguida, submetem-se esses valores resultantes à lógica paraconsistente, utilizando-se de um reticulado para a tomada de decisão final (Figura 19).

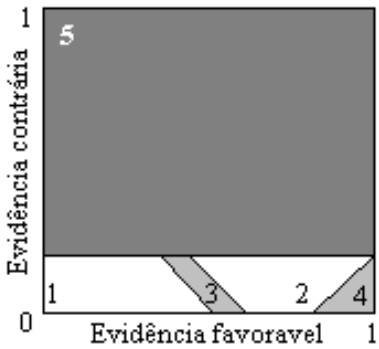

Figura 19. Reticulado para tomada de decisão utilizada no processo de análise da RNAP. Área 1: Estado lógico Falso (DA provável abaixo da média populacional); Área 2: Estado lógico Quase-verdadeiro (DA provável acima da média populacional); Área 3: Estado lógico Quase-falso (normal abaixo da média populacional); Área 4: Estado lógico Verdadeiro (normal acima da média populacional); Área 5: Estado lógico de indefinição (área não utilizada no estudo).

Limite das áreas do reticulado	
Falso	$G_c <= 0,1999$ $G_c >= 0,5600$ $\| G_{ct} \| < 0,3999$ $\| G_{ct} \| >= 0,4501$
Quase–verdadeiro	$0,1999 < G_c < 0,5600$ $0,3999 <= \| G_{ct} \| < 0,4501$ $Ef > 0,5000$
Quase-falso	$0,2799 < G_c < 0,5600$ $0,3099 <= \| G_{ct} \| < 0,3999$ $Ef < 0,5000$
Verdadeiro	$G_c > 0,7999$ $\| G_{ct} \| < 0,2000$

Tabela 12. Limite das áreas do reticulado para tomada de decisão utilizada no processamento da análise da RNAP (Figura 19). Ec: evidência contrária; Ef: evidência favorável; G_c: grau de certeza;

4. RESULTADOS

O método proposto obteve uma sensibilidade de 82% e especificidade de 61% (Tabela 14).

	Doente	**Não doentes**	**Total**
Negativo	13	6	19
Positivo	20	28	48
Total	33	34	67

Tabela 13. Tabela de frequência absoluta de diagnóstico: Pacientes com DA provável (Doente) e pacientes normais (Não doentes).

	Doente	**Não doentes**	**Total**
Negativo	19,40%	8,96%	28,36%
Positivo	29,85%	41,79%	71,64%
Total	49,25%	50,75%	100,00%
Sensibilidade: 82%			
Especificidade: 61%			

Tabela 14. Tabela de frequência relativa, sensibilidade e especificidade de diagnóstico: Pacientes com DA provável (Doente) e pacientes normais (Não doentes).

Exame	Paciente	DELTA	TETA	ALFA	BETA	MEDIA	EF	EC	DIAG
7601	JS	7	152	111	0	6,9184	0,4813	0,1404	1
7701	RKG	0	100	215	24	8,475	0,4813	0,0712	2
5401	EC	4	157	108	12	7,025	0,4959	0,1377	2
7801	JIS	1	91	209	39	8,5	0,5191	0,0603	1
6501	LANG	4	86	222	25	8,425	0,5207	0,0548	1
7101	JTBT	0	89	243	12	8,6	0,5419	0,0594	1
7201	OTWNV	0	74	249	13	8,4	0,5896	0,0301	1
1202	RA	6	44	194	164	10,2	0,8162	0,0613	1
2102	DYT	7	66	101	579	18,825	0,8546	0,0485	1
1802	DO	0	32	269	105	10,15	0,8818	0,0394	1
6101	EFRC	0	31	261	106	10,1986	0,8832	0,0389	2
1902	ILM	3	26	242	136	10,4842	0,8931	0,0356	1
3001	AB	10	27	40	584	16,525	0,9580	0,0280	2
1605	DO	0	21	308	88	10,425	0,9622	0,0252	1
1303	DO	2	12	308	74	10,1644	0,9735	0,0177	1
2202	GM	0	39	93	1064	29,9	0,9755	0,0163	2
2001	LBA	2	19	82	508	17,075	0,9769	0,0154	1
5901	DG	0	13	181	258	11,8833	0,9784	0,0144	1
1103	DO	0	12	259	150	10,8131	0,9786	0,0143	1
2401	NAG	2	7	285	108	10,075	0,9833	0,0112	1
1004	ON	0	14	102	562	16,95	0,9845	0,0103	1
2302	GAA	0	11	168	429	16,31	0,9864	0,0090	1
1404	RA	0	7	316	78	10,025	0,9869	0,0087	1
2901	LFM	2	15	87	923	26,7026	0,9876	0,0083	1
2701	AEJO	2	12	99	995	29,9444	0,9905	0,0063	1
1604	MLSD	3	7	141	720	25,98125	0,9914	0,0057	2
2201	MHA	0	0	101	941	26,05	1,0000	0,0000	1
2501	YVG	0	0	0	1347	34,3026	1,0000	0,0000	1
4001	TANB	15	135	98	26	6,85	0,5107	0,1162	2
1201	E	4	32	175	238	11,5	0,8797	0,0401	1
1704	JSM	0	25	231	195	11,275	0,9584	0,0277	1
2103	MRA	0	30	108	407	14,3421	0,9587	0,0275	1
1503	ACP	4	5	327	39	9,375	0,9664	0,0193	2
1302	MM	4	0	161	474	15,975	0,9953	0,0031	1
4301	NGP	15	153	103	0	6,775	0,4544	0,1487	1
7501	IOG	13	161	71	37	7,05	0,4635	0,1610	1
3201	GBS	4	40	264	50	8,95	0,7631	0,0090	2
1203	CLD	3	42	286	26	9,1605	0,7690	0,0211	2
2601	RPS	6	47	141	291	12,5671	0,8361	0,0546	2
3101	JCS	0	46	223	134	10,075	0,8288	0,0571	2
2101	MW	7	75	196	68	8,65	0,5770	0,0510	2

Tabela 15. Grupo de indivíduos classificados como normais. DELTA: Frequência média de ondas pertencentes a banda delta; TETA: Frequência média de ondas pertencentes a banda teta; ALFA: Frequência média de ondas pertencentes a banda alfa; BETA: Frequência média de ondas pertencentes a banda beta; MEDIA: Frequência média do exame; EF: Evidência favorável resultande da análise da RNAP; EC: Evidência contrária resultande da análise da RNAP; DIAG: Diagnóstico real do exame, onde, 1 – normal e 2 – DA provável.

Exame	Paciente	DELTA	TETA	ALFA	BETA	MEDIA	EF	EC	DIAG
4101	MTRS	6	104	168	24	7,55	0,3311	0,0596	2
6001	EGT	8	177	40	0	5,921	0,4373	0,2072	2
7901	AMNT	5	71	162	147	9,625	0,6851	0,0800	1
5701	ABC	6	55	202	120	9,575	0,7398	0,0584	2
2203	JPNF	11	142	94	0	6,175	0,1204	0,1185	2
6201	ESE	0	144	146	12	7,55	0,1623	0,1159	2
6301	MF	0	137	162	0	7,475	0,1865	0,1028	2
7301	AOFFS	10	117	144	27	7,45	0,2332	0,0856	1
5501	TMOG	16	155	62	13	6,15	0,2352	0,1551	2
6401	RRS	4	176	72	0	6,3	0,2564	0,1721	2
8102	ABS	0	123	168	27	7,95	0,3173	0,0909	2
5801	TCS	15	177	47	13	6,3	0,3279	0,1960	1
1504	CLD	11	96	203	0	7,75	0,3698	0,0601	1
8001	BLW	4	114	174	40	8,3	0,3819	0,0927	1
1703	CLD	4	104	208	0	7,9	0,3823	0,0659	2
1801	ZSA	4	101	187	16	7,8907	0,3832	0,0650	2
2801	CRSV	8	89	213	13	8,075	0,4533	0,0539	2
43901	AVB	8	152	114	12	7,15	0,5092	0,1372	2
44001	ASS	40	165	8	0	5,4552	0,6709	0,2540	2
1701	LHO	4	64	242	59	9,225	0,6848	0,0534	2
1102	MLCM	6	67	202	107	9,55	0,6909	0,0730	2
1702	RF	0	65	227	81	9,325	0,7049	0,0534	2
1301	MGC	7	66	148	216	11,5	0,7494	0,0835	2
1606	OSP	0	63	214	121	10,1723	0,7626	0,0791	2
4201	MAP	8	43	221	115	9,675	0,7861	0,0496	1
1803	ABM	4	54	191	171	10,5	0,7929	0,0690	2

Tabela 16. Grupo de indivíduos classificados como DA provável. DELTA: Frequência média de ondas pertencentes a banda delta; TETA: Frequência média de ondas pertencentes a banda teta; ALFA: Frequência média de ondas pertencentes a banda alfa; BETA: Frequência média de ondas pertencentes a banda beta; MEDIA: Frequência média do exame; EF: Evidência favorável resultande da análise da RNAP; EC: Evidência contrária resultande da análise da RNAP; DIAG: Diagnóstico real do exame, onde, 1 – normal e 2 – DA provável.

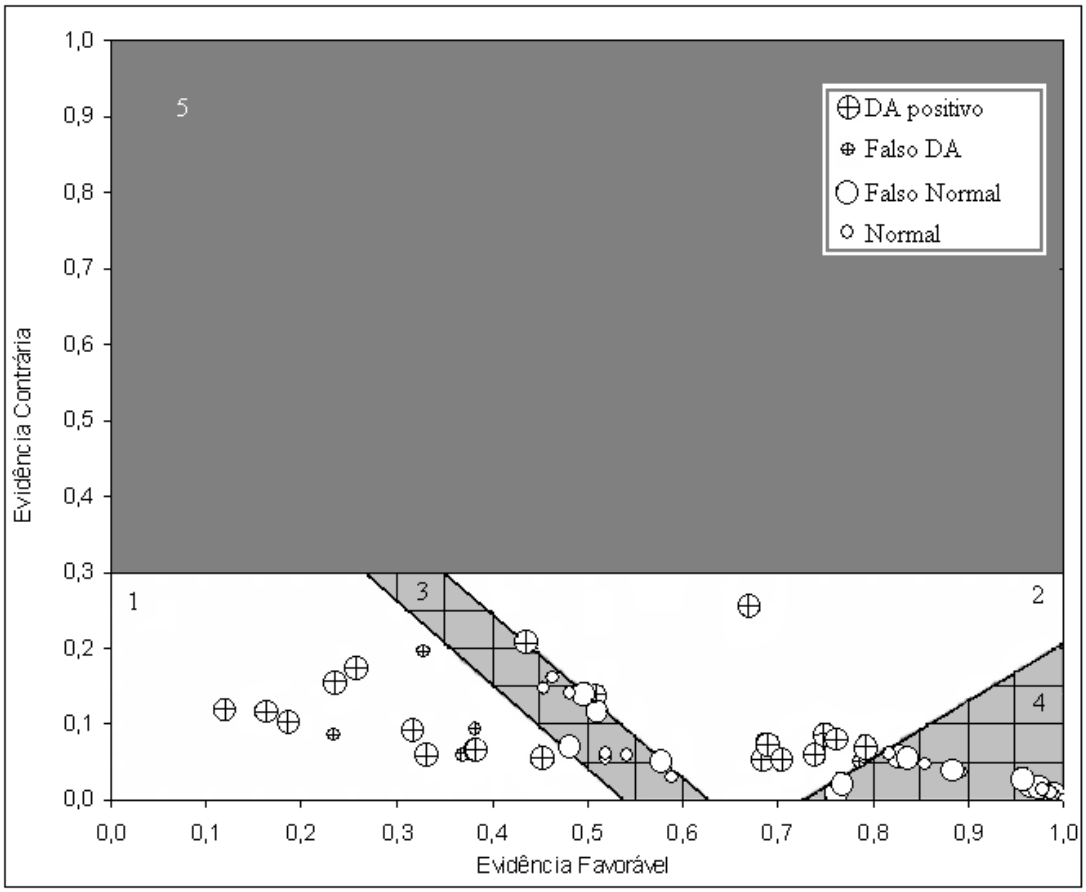

Figura 20. Reticulado de decisão final do processo de análise da RNAP com o resulto dos 67 exames. Área 1: Estado lógico Falso (DA provável abaixo da média populacional); Área 2: Estado lógico Quase-verdadeiro (DA provável acima da média populacional); Área 3: Estado lógico Quase-falso (Normal abaixo da média populacional); Área 4: Estado lógico Verdadeiro (Normal acima da média populacional); Área 5: Estado lógico de indefinição (área não utilizada no estudo).

5. DISCUSSÃO

Foram testadas diversas configurações de análises até ser encontrada a melhor configuração da RNAP e dos reticulados de análise da Lógica Paraconsistente, prevalecendo a configuração com a melhor sensibilidade e especificidade até o momento.

Todas as análises foram realizadas por meio de testes duplo-cego, ou seja, a validação diagnóstica não foi divulgada até que a melhor configuração da RNAP tivesse sido escolhida, utilizando como critério a concordância entre os resultados obtidos e o dignóstico clínico.

Conforme os dados armazenados no banco de dados de padrões e sua classificação (Tabela 5), o método de análise morfológica da onda conseguiu reconhecimento médio de evidência favorável de 0,65 e de evidência contrária de 0,20. Esses valores médios demonstram, de acordo com as regiões definidas no reticulado utilizado para o processamento das informações, que o método utilizado pela análise morfológica foi satisfatoriamente eficiente para o reconhecimento de ondas pertencentes à mesma banda de frequência, apesar da grande variabilidade do sinal biológico estudado.

Com o processo de análise morfológica, torna-se possível a quantificação de frequências médias do indivíduo sem perder sua referência temporal. Tendo a quantificação das frequências, os sistemas especialistas são capazes de mensurar diferenças entre bandas rápidas e lentas, assim como o alentecimento de frequência média comparada à frequência da média populacional.

Estes especialistas alimentam a RNAP que analiza essas informações de forma a balancear os dados entre si, fornecendo um valor de evidência favorável e evidência contrária que são subetidos a um reticulado para a interpretação desses valores, que fornece o diagnóstico provável.

Utilizando a metodologia deste trabalho, foi possível não só diferenciar indivíduos com DA provável e indivíduos normais, mas também detectar 4 subgrupos de indivíduos, conforme Figura 20: indivíduos com DA Provável, com frequência média abaixo da média populacional (Área 1 – Estado lógico falso); indivíduos com DA Provável, com frequência média acima da média populacional (Área 2 – Estado lógico quase-verdadeiro); indivíduos Normais, com frequência média abaixo da média populacional (Área 3 – Estado lógico quase-falso); indivíduos Normais, com frequência média acima da média populacional (Área 4 – Estado lógico verdadeiro) (Figura 20).

Essa distinção demonstra que a RNAP foi capaz de perceber diferenças entre os exames, possibilitando aplicar este método na automação do processo de análise de exames de EEG aplicados ao auxílio do diagnóstico da DA. Em poucos minutos se poderia obter um pré-diagnóstico do exame, tendo como resposta se o indivídio é normal ou não (DA provável).

Analisando os valores de sensibilidade e especificidade (Tabela 14) obtidos pelo método proposto, pode-se considerar a RNAP é uma ferramenta potencialmente útil com um bom valor de sensibilidade. Porém, sua baixa especificidade demonstra que a metodologia ainda possui alguns pontos que devem ser melhorados.

Realizar melhorias no método de análise de EEG utilizando Lógica Paraconsistente e RNAP pode tornar-se viável devido a flexibilidade do método em

ajustar seus parâmetros sem alterar sua estrura de análise e realizando um novo estudo utilizando um número maior de exames para refinarmos não só os parâmetros em cada processo de análise como também as áreas de interpretação do reticulado (Figura 20).

Um ponto que pode ajudar a melhorar a especificidade do método seria a implementação de uma RNAP na análise morfológica (tópico 3.2.3.5.1), deixando-a mais precisa. Tal implementação poderia ser feita considerando mais aspectos da onda, tal como a combinação entre número de picos, distância de pontos diferentes e quantidade de pontos iguais.

A detecção automática de artefatos também pode se tornar possível, desde que o banco de dados seja carregado com modelos de artefatos, sendo posteriormente processado pela análise morfológica. Este processo pode proporcionar uma maior agilidade e padronização nas análises dos exames.

O conceito da análise morfológica é a comparação do formato da onda o que a torna potencialmente apta a detectar qualquer tipo de forma de onda, desde que o padrão seja previamente armazenado.

Outra questão interessante é a limitação gerada pelos exames de EEG. Como a base principal da metodologia é a verificação do alentecimento de frequência, uma comparação apenas com a média populacional chega ser deficiente, pois podemos ter casos onde o paciente, com DA clinicamente diagnosticado, teve uma frequência média alta por toda sua vida e o alentecimento não chega a valores abaixo da frequência média populacional.

Uma possível solução a este problema seria a comparação do indivíduo não só com a média populacional, mas sim com sua própria média, obtida por exames anteriores e futuros, por meio de um estudo longitudinal.

Vale ressaltar que em nossa metodologia, utilizamos uma nova classe de RNA, a RNAP. Por se tratar uma teoria com novos recursos que ampliam o funcionamento das RNAs clássicas justifica-se, como uma primeira abordagem, a utilização de apenas um tipo de técnica de análise para avaliação de todo o seu potencial.

Comparando a correlação clínica obtida neste estudo com outros existentes na literatura, podemos perceber uma promissora vantagem em relação aos níveis de processamento dos métodos. Enquanto outros pesquisadores utilizam RNAs clássicas, aliadas à outras ferramentas matemáticas de análise de sinais, tais como as teorias de Wavelet e transformada rápida de Foruier, para se chegar à uma correlação clínica de 90%, a metodologia deste estudo conseguiu um valor de correlação clínica satisfatória empregando apenas um tipo de análise.

Porém, a combinação de técnicas de análise de sinais é uma possibilidade interessante para a melhoria da metodologia deste estudo.

6. CONCLUSÕES

A metodologia de reconhecimento de padrões utilizando a análise morfológica apresentou-se como uma promissora ferramenta, conseguindo reconhecer padrões de ondas similares aos padrões armazenados no banco de dados, possibilitando a quantificação e a qualificação dos dados do exame de EEG para que sejam utilizados pela RNAP em seu processo de análise do exame.

O desempenho da análise da RNAP apresentou-se com satisfatória eficiencia na distinção dos exames analisados, classificando-os com boa sensibilidade, mas com baixa especificidade.

As possibilidades de configuração da RNAP permite a realização de novos estudos com maior quantidade de pacientes, onde podemos utilizar os valores obtidos como valores base para realizar novas comparações.

As funcionalidades da Lógica Paraconsistente e das RNAPs demonstram-se promissoras para reconhecimeto de padrões e os resultados aqui obtidos podem se estender a outros estudos de ondas, tais como identificação de artefatos e reconhecimento de padrões em outras doenças onde o EEG é utilizado como procedimento clínico.

7. REFERÊNCIAS BIBLIOGRÁFICAS

(AANACNS, 1997) American Academy of Neurology and the American Clinical Neurophysiology Society. Assessment of digital EEG, quantitative EEG, and EEG brain mapping. Neurology 1997;49:277-92.

(Abe, 1992) Abe JM. Fundamentos da lógica anotada. Tese de doutorado, Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo, São Paulo, Brasil, 1992.

(Abe, 1997) Abe JM. Some Aspects of Paraconsistent Systems and Applications. Logique et Analyse, 1007: 157; 83-96.

(Abe, 2006a) Abe JM. Lógica Paraconsistente. Seleção Documental, 2006: 1;1;5-10.

(Abe, 2006b) Abe JM. Introdução à Lógica Paraconsistente Anotada. Seleção Documental, 2006: 1;1;11-17.

(Abe et al., 2007) Abe JM, Lopes HFS, Anghinah R. Paraconsistent Artificial Neural Network and Alzheimer Disease: A Preliminary Study. Dementia & Neuropsychologia, 2007: 3; 241-247.

(Abe, 2008) Abe JM. Raciocinando Consistentemente sobre o Inconsistente e a Imprecisão: Redes Neurais Artificiais Paraconsistentes, capítulo de livro, ALMANAQUE REFLEXIVO: uma visão cognitiva de mundo a partir do que

sabemos sobre neurônios e linfócitos, Sinopse preliminar, Organizadores: Cláudio Tadeu Daniel Ribeiro (IOC, FIOCRUZ) e Luiz Carlos de Lima Silveira (NMT, UFPA), Rio de Janeiro, 2008.

(Abe et al., 2008) Abe JM, Lopes HFS, Nakamatsu K. Improving EEG Analysis by Using Paraconsistent Artificial Neural Networks. Knowledge-Based Intelligent Information and Engineering Systems, 2008: 5178; 466-473.

(Alexander et al., 2006) Alexander DM, Arns MW, Paul RH, Rowe DL, Cooper N, Esser AH, Fallahpour H, Stephan BCM, Heesen E, Breteler R, Williams LM, Gordon E. EEG markers for cognitive decline in elderly subjects with subjective memory complaints. Journal of Integrative Neuroscience, 2006: 5; 1; 49, 74.

(Almkvist et al., 1993) Almkvist O, Backman L. Detection and staging of early clinical dementia. Acta. Neurol. Scand. 1993;88.

(Aminoff , 2003) Aminoff MJ. Electrophysiology. In: Gotez CG. Texto f Clinical Neurology. 2nd ed. Chicago: IL: W. B. Saunders Company; 2003.

(Anghinah, 2003) Anghinah R. Estudo da densidade espectral e da coerência do eletroencefalograma em indivíduos normais e com doença de Alzheimer provável. Tese de doutorado. Faculdade de Medicina da Universidade de São Paulo – Departamento de Neurologia. São Paulo. 2003.

(Anghinah et al., 2006)

Anghinah R. Basile LI, Schmidt MT, Sameshima K, Gattaz WF. Artefatos biológicos no EEG Quantitativo. Arq. Neuropsiquiatr. 2006; 64(2-A): 264-268.

(Argoud et al., 2006) Argoud FIM, Azevedo FM, Neto JM, Grillo E . SADE[3]: an effective system for automated detection of epileptiform events in long-term EEG based on context information. Medical and Biological Engineering and Computing. 2006; 44;6: 459-470.

(Bierer et al., 1995) Bierer LM, Haroutunian V, Gabriel S. Neurochemical correlates of dementia severy in DA: relative importance of the colinergic deficits. J. Neurochem 1995; 64:740-760.

(Braak et al.,1991) Braak H, Braak E. Neuropathological staging of Alzheimer: related changes. Acta – Neuropathol. 1991; 82:239-259.

(Berger et al., 1994) Berger L, Morris JC. Diagnosis in Alzheimer Diasease. Terry RD, Katzman R, Bick KL, eds.: New York: Reaven Press, Ltd. 1994; 9-25.

(Claus et al., 1999) Claus JJ, Strijers RLM, Jonkman EJ, Ongerboer De Visser BW, Jonker C, Walstra GJM, Scheltens P, Gool WA. The diagnostic value of EEG in mild senile Alzheimer´s disease. Clin. Neurophysiol. 1999; 18:15-23.

(Chabot, 2005) Chabot RJ, Michele F, Prichep L. The role of quantitative

electroencephalography in child and adolescent psychiatric disorders. Child Adolesc Psychiatr Clin N Am. 2005; 14(1):21-53, v-vi.

(Coyle et al., 1983) Coyle JT, Price DL, DeLong MR. Alzheimer disease: a disorder of cortical cholinergic innervation. Science 1983; 219:1184-1190.

(Crevel et al., 1999) Crevel H. Gool WA, Walstra GJM. Early diagnosis of dementia: Which tests are indicated ? What are their costs: J. Neurol. 1999; 246:73-78.

(Da Costa et al., 1991) Da Costa NCA, Abe JM, Subrahmanian VS. Remakers on annotated logic. Zeitschr. f. Math. Logik und Grundlagen d. Math.. 1991; 37: 561-570.

(Da Costa et al., 1999) Da Costa NCA, Abe JM, Silva Filho JI, Murolo AC, Leite CFS. Lógica Paraconsistente Aplicada. 1ª. ed. ISBN 8522422184. São Paulo, Editora Atlas, 1999.

(Da Silva Filho, 2001) Da Silva Filho, J.I.; Abe, J.M. Fundamentos das Redes Neurais Artificiais Paraconsistentes. 1ª. ed. ISBN 8574730424. São Paulo, Editora Villipress, 2001.

(Dayle et al., 1990) Dayle DD, Pedley TA. Current Practice of Clinical Eletroencephalography. 2nd ed., Raven Press, New York. 1990; 107-137.

(Deslandes, 2004) Deslandes A, Veiga H, Cagy M, Fiszman A, Piedade R, Ribeiro P. Eletroencefalografia quantitativa (EEGq) na discriminação entre demência degenerativa primária e transtorno depressivo maior (depressão). Arquivos de Neuro-Psiquiatria, 2004: 62; 1.

(Francis et al., 1999) Francis PT, Palmer AM, Snape M, Wilcock GK. The cholinergic hypothesis of AD: a review of progress. J. Neurol. Neurosurg Psychiatry 1999; 66:137-147.

(Fratiglioni et al., 1997) Fratiglioni L, Viitanen M, von Strauss E, Tontodonai V, Herlitz A, Wimblad. Very old women at highest risk of demencia and AD: Incidence data from Kungsholmen project, Stockhom. Neurology 1997; 48:132-138.

(Hardy,1997) Hardy J. The Alzheimer family of disease: many etiologies, one pathogenesis ? Proc. Natl. Acad. Sci. USA 1997; 94:2095-2097.

(Hebb, 1949) Hebb D. Organization of Behaviour: a Neurophysiological Approach Princeton Univ. Press, Princeton, New York, USA, 1949.

(Herbert et al., 1995) Herbert LE, Scherr PA, Beckett LA. Age-specific incidence of AD in a community population. JAMA 1995; 273:1359.

(Herrera et al., 1998) Herrera JE, Camarelli P, Nitrini R. Estudo epidemológico

populacional de demência na cidade de Catanduva, estado de São Paulo, Brasil. Rev. Psiquiatria Clínica. 1998; 25:70-73.

(Jasper, 1958) Jasper HH. The ten-twenty electrode system of the International Federation. Electroencephalogr. clin. Neurophysiol., 1958; 10:371-373.

(Jasper, 1983) Jasper HH. The ten-twenty electrode system of the International Federation. In: International Federation of Societies for Electroencephalography and Clinical Neurophysiology: recommendations for practice of neurophysiology. Amsterdam: Elservier, 1983.

(Jelic, 1999) Jelic V. Early diagnosis of AD. Phd Thesis. Karolinska Institutet, Stockholm 1999; 1-14.

(Kandel e Siegelbaum, 1995) Kandel ER, Siegelbaum S. An introduction to synaptic transmission. In: Kandel ER, Schwartz JH, Jessel TM (eds). Essentials of Neural Sciense and Behavior. London: Appleton & Lange 1995: 183-96.

(Kocyigit et al., 2008) Kocyigit Y, Alkan A, Erol H. Classification of EEG Recordings by Using Fast Independent Component Analysis and Artificial Neural Network. Journal of Medical Systems (Springer Netherlands), 2008: 32;1;17-20.

(Kwak, 2006) Kwak YT. Quantitative EEG findings in different stages of Alzheimer's disease. J Clin Neurophysiol (Journal of clinical neurophysiology:

official publication of the American Electroencephalographic Society), 2006: 23; 5; 456-61.

(Lehmann, 2007) Lehmann C, Koenig T, Jelic V, Prichep L,John RE, Wahlund LO, Dodge Y,Dierks T. Application and comparison of classification algorithms for recognition of Alzheimer's disease in electrical brain activity (EEG).. J Neurosci Methods (Journal of neuroscience methods). 2007: 161; 2; 342-50.

(Lesser, 1994) Lesser RP. Guidelines Committes Of American Eletroencephalographic Society. J. Clin. Neurophysiol. 1994; 11: 9-11.

(Lopes da Silva, 1991) Lopes da Silva F. Neural mechanisms underlying brain waves: from neural membranes to network. Electroencephalogr. Clin. Neutophysiol. 1991; 79:81-93.

(Luccas at al., 1998) Luccas FJC, Braga NIO, Silvado CRS. Recomendações técnicas para o registro de eletroencefalograma (EEG) na suspeita de morte encefálica. Arq. Neuropsiq. 1998; 56: 697-702.

(Mario, 2006) Mario MC. Modelo de análise de variáveis craniométricas através das Redes Neurais Artificiais Paraconsistentes. Tese de doutorado, Faculdade de Medicina da Universidade de São Paulo, São Paulo, Brasil, 2006.

(Mattia et al., 2003) Mattia D, Babiloni F, Romigi A, Cincotti F, Bianchi L, Sperli F,

Placidi F, Bozzao A, Giacomini P, Floris R, Grazia Marciani M. Quantitative EEG and dynamic susceptibility contrast MRI in Alzheimer's disease: a correlative study. Clin. Neurophysiol. 2003; 144; 7: 1210-6.

(McCulloch et al., 1943) McCulloch W, Pitts W. A Logical Calculus of the Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, 1943.

(McKhann et al., 1984) McKhann G, Drachman D, Folstein M, Katzman R, Price D, Stadlan EM. Clinical diagnosis of AD: report of the NINCDS-ADRDA work group under the auspices of Deparment of health and human services task force on AD. Neurology. 1984;34: 939-944.

(Montenegro et al., 2001) Montenegro MA, Cendes F, Guerreiro NM, Guerreiro CAM, editors. EEG na prática clínica, São Paulo: Lemos Editorial; 2001.

(Negoita et al., 1975) Negoita CV, Ralesco DA.Applications of Fuzzy Sets to Systems Analysis. John Wiley & Sons; 1975.

(Nitrini et al., 2005) Nitrini R, Caramelli P, Bottino CMC, Damasceno BP, Brucki SMD, Anghinah R. Diagnóstico de doença de Alzheimer no Brasil – Critérios diagnósticos e exames complementares – Recomendações do Departamento Científico de Neurologia Cognitiva e do Envelhecimento da Academia Brasileira de Neurologia. Arq Neuropsiquiatr, 2005;63(3-A):713-719.

(Nordberg, 1996) Nordberg A. Pharmacological tretment of cognitive dysfunction in dementia disorders. Acta. Neurol. Scand. 1996; Suppl. 168:87-92.

(Orrison et al., 1995) Orrison WW, Lewine JD, Sanders JÁ, Hartshore MF. Functional Brain Imaging. St. Louis: Mosby; 1995; 327-368.

(Prado , 2002) Prado JCA. Redes Neurais Artificiais Paraconsistentes e sua utilização para reconhecimento de padrões. Dissertação de Mestrado. Escola Politécnica da Universidade de São Paulo; São Paulo, SP, BR; 2002.

(Prado , 2007) Prado JCA. Constelação fônica e redes neurais artificiais: aplicabilidade na análise computacional da produção da fala. Tese de Doutorado. Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo; São Paulo, SP, BR; 2007.

(Rosenblatt , 1962) Rosenbratt F. Principles of Neurodynamics: Perceptrons and the theory of brain mechanisms, Spartan Books, NY, 1962.

(Silva et al., 1995) Silva DF, Lima MM, Anghinah R, Lima JGC. Mapeamento cerebral. Rev. Neurociências 1995; 3:11-18.

(Steriade et al., 1990) Steriade M, Gloor P, Llinás R, Lopes da Silva F, Mesulan M. Basic mechanisms of cerebral rhytmic activities. Electroencephalogr. Clin. Neurophysiol. 1990; 76:481-508.

(Terry, 1994) Terry RD. Chapter 29. Neuropathological changes in AD. In L. Svennerholm, AK. (Ed) Elservier Science BV, Progress in Brain Research, 1994; 101:383-390.

(van der Hiele, 2008) van der Hiele K, Bollen EL, Vein AA, Reijntjes RH, Westendorp RG, van Buchem MA, Middelkoop HA, van Dijk JG. EEG Markers of Future Cognitive Performance in the Elderly. J Clin Neurophysiol (Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society), 2008; 25:2;83-89.

(Vialatte at al., 2005) Vialatte F, Cichocki A, Dreyfus G, Musha T, Shishkin SL, Gervais R**.** Early Detection of Alzheimer's Disease by Blind Source Separation, Time Frequency Representation, and Bump Modeling of EEG Signals**.** Lecture Notes in Computer Science. 2005; 3696; 683-692.

(Woon at al., 2007) Woon WL, Cichocki A, Vialatte F, Musha T**.** Techniques for early detection of Alzheimer's disease using spontaneous EEG recordings**.** Physiol Meas (Physiological measurement). 2007; Ed. 28; 4:335-47.

(Zadeh,1973) Zadeh L. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. IEEE Transaction on Systems, Mam and Cybernectics; 1973. SMC-3; 1 28-44.

(Zhao et al., 2007) Zhao P, Van-Eevelt P, Goh C, Hudson N, Wimalaratna S, Ifeachor EC. Characterization of EEGs in Alzheimer's Disease Using Information Theoretic Methods. Proceedings of the 29th IEEE EMBS Annual International Conference, August 23-26, 2007, Cité Internationale, Lyon, France.