

# Metodologia de Aprendizagem para Sistemas Neuro-difusos

## A Learning Methodology for Neuro-Fuzzy Systems

**Lucimar Fossatti de Carvalho**

Doutoranda em Engenharia Elétrica

UFSC/SC – UPF/RS

*fossatti@upf.br*

**Silvia Modesto Nassar**

*nassar@ufsc.br*

**Fernando Mendes de Azevedo**

*azevedo@ufsc.br*

Doutores em Engenharia Elétrica – UFSC/SC

**Hugo José Teixeira de Carvalho**

Médico Neurologista

HC/HSVP - Passo Fundo/RS

*hugojitc@tpo.com.br*

**Ciciliana Maila Zilio Rech**

*55609@ci.upf.br*

**Lucas Lese Monteiro**

*ciciliana@tpo.com.br*

Alunos de Iniciação Científica - PIBIC/UPF

*(Recebido em 25 de abril de 2006)*

Resumo: Este artigo propõe uma metodologia de aprendizagem que forneça uma ferramenta unificada integrando o paralelismo computacional das redes neurais com o raciocínio dos sistemas difusos. O maior interesse da pesquisa é examinar a aplicabilidade das operações aritméticas difusas t-normas e t-conormas, implementadas através de neurônios difusos. Os resultados mostram que as operações aritméticas difusas Soma/Produto de Einstein E/OU implementadas com

o neurônio difuso proposto por Kwan-Cai obtiveram os melhores índices de acertos do sistema. Os resultados foram analisados considerando os indicadores quantitativos de modelagem. A área de domínio, utilizada para provar a validade da metodologia, é a do diagnóstico de Eventos Paroxísticos, envolvendo os Eventos Epilépticos e os Eventos não Epilépticos.

**Palavras-chave:** Redes Neurais Artificiais; Lógica Difusa; Sistemas Neuro-Difusos; Epilepsia.

**Abstract:** This paper proposes a learning methodology which provides a unified framework for integrating the computational parallelism of neural networks with the reasoning of fuzzy systems. The main interest of the research is to examine the applicability of the t-norms and t-conorms fuzzy arithmetical operations, implemented by fuzzy neurons. The results show that the arithmetical operations of Einstein's Sum/Product OR/AND implemented with the fuzzy neuron proposed by Kwan-Cai has obtained the highest rates of system hits. The results have been analyzed by taking into account the modeling quantitative indicators. The domain area, which is used to prove the methodology validity, is in the diagnosis of Paroxysmal Events involving Epileptic Events and Non Epileptic Events.

**Key words:** Artificial Neural Networks; Fuzzy Logic; Neuro-Fuzzy Systems; Epilepsy.

## 1 Introdução

Nenhum resultado científico pode ter a pretensão de ser definitivo, razão pela qual muitas idéias, opiniões ou, até mesmo, conceitos tornam-se difíceis de serem formulados. O universo das pesquisas possui uma tendência a ser modificado freqüentemente, pois a realidade é dinâmica, os métodos e as técnicas evoluem rapidamente, contribuindo para o surgimento de novos paradigmas de pesquisa. Os sistemas envolvendo técnicas tradicionais de Inteligência Artificial (IA) aplicados no domínio da matemática, física, química, biologia, astronomia, entre outras, estão dando lugar aos chamados sistemas que utilizam Inteligência Computacional (IC), referenciados na literatura como *Soft Computing* pesquisas relacionadas com as máquinas inteligentes.

A área da IC busca, através de técnicas inspiradas na natureza, o desenvolvimento de sistemas inteligentes que possam simular aspectos do comportamento humano, tais como aprendizagem, percepção, raciocínio, evolução e adaptação (VELLASCO, 2006). Características básicas desses sistemas encontram-se na representação do conhecimento inexato, que seria impossível de representar através das técnicas tradicionais de IA. No centro da IC, estão a Lógica Difusa, Neurocomputação, Computação Evolucionária, Computação Probabilística,

Computação Caótica e Aprendizagem de Máquina, áreas que utilizam os princípios da IA (ZADEH, 2006).

Como o objetivo deste artigo é trabalhar com aprendizagem híbrida, existe o interesse em investigar os resultados apresentados pelos Conjuntos Difusos (CDs), utilizando diferentes operações aritméticas difusas na composição das regras, uma vez que o processo de aprendizagem nos Sistemas Neuro-Difusos (SNDs) é caracterizado pela interpretação das regras difusas, o que poderá conduzir a um maior ou menor índice de acertos do sistema.

O artigo está organizado em sete seções, além desta. A segunda seção descreve os materiais e métodos utilizados na pesquisa. Na terceira seção é descrita, de forma resumida, a área de domínio de aplicação. A quarta seção fornece uma introdução aos SNDs, descrevendo as características básicas dos neurônios difusos propostos. A quinta seção é dedicada à apresentação da proposta da Metodologia de Aprendizagem, delineando as principais etapas envolvidas no processo de aprendizagem dos modelos. A sexta seção contém os Resultados e Discussão. Finalmente, a sétima seção traz as conclusões obtidas em cada modelo.

## 2 Materiais e Métodos

Os modelos implementados utilizam o método de inferência Mamdani (MAMDANI, 1974), baseado no modelo *perceptron* multicamada, através do algoritmo de *retropropagação* modificado. As operações produto escalar, entre as entradas da rede e seus pesos ( $x_{ij}w_{ij}$ ), é substituída pela operação **T**, representando a operação Produto Algébrico ou de Einstein e a operação somatório, substituída pela operação **S**, que representa a operação Soma Algébrica ou de Einstein (AZEVEDO, BRASIL, OLIVEIRA, 2000).

As entradas da rede contêm valores quantitativos. A base de casos é composta por duzentos e trinta e um pacientes, escolhidos aleatoriamente. Deste total, cento e vinte e dois pacientes integram a fase de treinamento da rede e cento e nove, a fase de testes<sup>1</sup>. Nesta pesquisa, a base de casos é subdividida em uma base de treinamento e uma base de teste. O processo de treinamento da rede é interrompido quando o sistema alcança o menor *Root Mean Square Error* (RMS)<sup>2</sup>. Foi escolhido o critério de erro fixo porque se optou por não utilizar um conjunto de validação, em razão do pequeno número de exemplos que integram a base de casos.

A rede é treinada a partir de uma base de regras inicial contendo cento e quarenta e nove regras difusas, as quais foram implementadas em conjunto com o médico neurologista que acompanha o desenvolvimento da pesquisa.

---


<sup>1</sup> O motivo que levou à escolha desses tamanhos para os dois conjuntos está relacionado com a representatividade dos sinais e sintomas presentes nos registros dos pacientes.

<sup>2</sup> O critério de parada baseado no valor mínimo do RMS foi sugerido por Haykin (2001).

Os dados dos pacientes utilizados nas fases de treinamento e de teste foram cadastrados de acordo com o questionário de Rastreamento Neurológico para Epilepsia - QRN-E (FERNANDES, 1993). Foi por meio do QRN-E que foram determinadas as variáveis que deveriam integrar o sistema de coleta de dados, descritas na terceira seção.

O processo de aprendizagem da rede consiste em atualizar os pesos sinápticos, pela implementação de dois modelos de neurônios difusos: o proposto por Hirota-Pedrycz (HIROTA e PEDRYCZ, 1992, 1994; PEDRYCZ e GOMIDE, 1998) e o proposto por Kwan-Cai (KWAN e CAI, 1994), por meio das operações aritméticas difusas Soma/Produto Algébrico e Soma/Produto de Einstein, representados nas figuras 1 e 2, respectivamente.

Figura 1. Neurônio difuso proposto por Hirota-Pedrycz



Em que:

$\varphi(\cdot)$  = função de ativação logística;


$\mathbf{T}$  = operação aritmética difusa Produto Algébrico ou de Einstein;

$\mathbf{S}$  = operação aritmética difusa Soma Algébrica de ou Einstein;

$v_{kj}$  = pesos sinápticos;

$x_j$  = valores *fuzzificados* de entrada da rede.

Figura 2. Neurônio difuso proposto por Kwan-Cai



Em que:

$\theta$  = fator de atenuação (equivalente ao valor do termo *bias*).

Observa-se, neste modelo, a ocorrência do produto entre os pesos e os sinais *fuzzificados* de entrada da rede.

Na implementação do SND utiliza-se, no módulo de inferência, uma Rede Neural Artificial (RNA) com quatorze unidades na camada de entrada, as quais correspondem aos sintomas apresentados pelos pacientes; camada escondida contendo cento e quarenta e nove neurônios, os quais representam as regras difusas, e uma camada de saída contendo dois neurônios de saída, as quais representam as classes possíveis de ocorrerem, ou seja, um Evento Epiléptico (EE) ou um Evento Não Epiléptico (ENE).

Na fase de treinamento são utilizados os valores:

- valor e peso do termo *bias* positivo: 1 e 0,1, respectivamente;
- taxa de aprendizagem de 0,01;
- termo momento de 0,85;
- pesos sinápticos aleatórios no intervalo [-0,5 até +0,5].

A análise estatística adotada inclui a validação interna da base de conhecimento, aplicada na fase de testes do sistema, e a avaliação de desempenho dos modelos. Na validação interna, foram utilizadas as medidas de sensibilidade (SEN), especificidade (ESP), valor preditivo positivo (VPP) e valor preditivo negativo (VPN) (NASSAR, 1998). Na avaliação do desempenho dos modelos optou-se pelo teste de hipótese<sup>3</sup>, o qual está fundamentado numa situação experimental, ou

<sup>3</sup> O teste de hipótese para proporções (%) consiste na comparação do percentual de acertos dos modelos implementados, incluindo cada modelo a ser avaliado (DEVORE, 2006).

seja, nos resultados obtidos com as operações aritméticas difusas *t-normas* e *t-conormas*, a um nível de significância ( $\alpha$ ) de 0,05.

Os modelos propostos utilizam a Classificação Clínica e Eletroencefalográfica das Crises Epilépticas – ILAE (ILAE, 1981).

A pesquisa está fundamentada nos principais algoritmos de aprendizagem híbridos encontrados na literatura (VELLASCO, 2004; AGUIAR, MELIN e CASTILLO, 2005; BUCKLEY, 2002; FULLÉR, 2000; GORZALCZANY, 2002; GUPTA e RAO, 1994; INAN, 2005; REZENDE et al., 2003; YU e LIN, 2006), entre outros.

A próxima seção descreve o domínio de aplicação dos modelos implementados.

### 3 Domínio de Aplicação

Os modelos implementados estão relacionados com a área da neurologia, especificamente no Diagnóstico Diferencial de Eventos Paroxísticos (Eps), entre eles os EEs e os ENEs. Busca-se, com a exploração das diferentes operações aritméticas difusas, resultados mais precisos e mais próximos do raciocínio humano.

O primeiro sistema para classificação das convulsões foi apresentado pela ILAE em 1969, composto por quatro divisões: Crises Parciais, Crises Generalizadas, Crises Unilaterais e Crises Não Classificadas. O segundo é a classificação clínica e eletroencefalográfica de crises epiléticas (ILAE, 1981). A terceira classificação, sugerida pela ILAE publicada em 1985 e revisada em 1989, auxilia na classificação de síndromes epiléticas e epilepsias (ILAE, 1989). A proposta de 2001, ainda em estudo (ILAE, 2005; WOLF, 2003), sugerida pela ILAE visa a uma nova metodologia de classificação com o objetivo de ser mais sistêmica, detalhada e precisa. Tanto a classificação de 1981 como a de 1989 são as classificações mais utilizadas e as que atualmente persistem na área médica.

A maior contribuição da ILAE foi o estabelecimento de terminologias e classificações padronizadas para diagnosticar crises e síndromes epiléticas. Ela fornece um vocabulário universal para facilitar a comunicação entre os médicos e também estabelecer uma taxonomia para execução das pesquisas em epilepsia (ILAE, 2006).

Neste artigo é adotada a classificação de 1981, pois a pesquisa envolve o diagnóstico diferencial de crises epiléticas.

A incidência da epilepsia varia de acordo com a localização geográfica. Ocorre com maior frequência nos países em desenvolvimento, nos quais há mais desnutrição, doenças infecciosas e deficiência no atendimento médico. Em países mais desenvolvidos, a incidência é de aproximadamente 1%, subindo para 2% em nações menos desenvolvidas.

Na história da medicina ocidental, Hipócrates (460-377 a.C.) descreveu-a há mais de 2.000 anos como um dos problemas médicos mais antigos da humanidade. Na história da medicina chinesa, o primeiro documento conhecido da epilepsia apareceu no clássico de Medicina Interna do imperador Amarelo Huang Di Nei Ching, escrito por um grupo de médicos aproximadamente de 770-221 a.C. (LAI e LAI, 1991).

Com o passar do tempo, os médicos consideraram os fenômenos epiléticos como psiquiátricos, de modo que pacientes com epilepsia eram frequentemente internados em manicômios (ENGEL, 2006).

Admitem-se os EEs como um grupo de doenças que têm em comum crises epiléticas, que ocorrem na ausência de condição tóxica metabólica ou febril. Crises epiléticas são eventos clínicos que refletem uma disfunção temporária de um conjunto de neurônios de parte do encéfalo, crises focais, ou de uma área mais extensa, envolvendo simultaneamente os dois hemisférios cerebrais, crises generalizadas (GUERREIRO, 2000).

Se as alterações epiléticas ficam restritas a uma parte do cérebro, a crise chama-se parcial; se o cérebro inteiro está envolvido, é uma crise generalizada. Crises parciais simples não ocasionam a perda da consciência e caracterizam-se por distorções na percepção auditiva ou visual, desconforto estomacal, sensação súbita de medo e/ou movimentos estranhos de uma parte do corpo. Se uma crise parcial complexa ocorre a seguir, essas sensações são denominadas *aura*. Crises parciais complexas são crises que, como as parciais simples, iniciam-se num foco determinado no cérebro, mas se espalham para outras áreas, causando perturbação da consciência. A pessoa fica confusa e pode caminhar sem rumo, falar sem coerência, salivar em excesso, morder a língua e realizar automatismos, como puxar a roupa ou virar a cabeça de um lado para outro repetidas vezes (EPILEPSIA, 2006).

Após uma análise nas principais características que envolvem os EPs, realizada em conjunto com o médico neurologista, foram escolhidas, dentre as variáveis que envolvem a definição de EEs e ENEs, quatorze características determinantes, integrando os EEs e os ENEs (GUERREIRO, 2000; COSTA et al., 1998; FERNANDES, 1993; FERNANDES et al., 1992; ILAE, 1981).

As características que acometem os ENEs são: (1) quadros clássicos de conversão, incluindo espasmos da faringe, perturbações digestivas, contraturas, dores no corpo e paralisia; (2) distúrbios de sensibilidade (anestesia) e da atividade sensorial; (3) fatores emocionais e (4) transtornos, incluindo pânico, comportamental, fugas, conversivo, despersonalização, dissociativo, somatização, hipocondria e simulação; (5) síncope e (6) distúrbios, incluindo sono, movimentos arrítmicos, endócrinos e crise febril.

As características que acometem os EEs foram classificados em (7) sinais e sintomas parciais; (8) durante o desmaio viu alguma coisa; (9) durante o desmaio ouviu alguma coisa; (10) durante o desmaio mordeu a língua; (11) durante o desmaio machucou-se; (12) tempo de duração da crise; (13) eventos pós-críticos, incluindo

confusão mental, sonolência, paralisias, vômito e dor no corpo; (14) sinais e sintomas generalizados (tônicos, clônicos, tônico-clônicos, ausência, mioclônicos, atônicos).

A próxima seção descreve, de forma resumida, os princípios básicos relacionados com os SNDs.

#### 4 Sistemas Neuro-Difusos

Historicamente, as primeiras pesquisas envolvendo as RNAs e a Lógica Difusa (LD) foram propostas por Lee e Lee na década de 1970 (LEE e LEE, 1970). Porém, foi no trabalho pioneiro dos pesquisadores H. Takagi e I. Hayashi, na década de 1980, que a teoria se consolidou (RUTKOWSKA, 2002).

Quando são utilizados métodos difusos para intensificar a capacidade de aprendizagem das RNAs e estes métodos são combinados em uma arquitetura homogênea, têm-se os SNDs, os quais podem ser treinados utilizando diferentes métodos de treinamento.

Os SNDs podem explicar o seu comportamento a partir das regras difusas. Para superar o problema da aquisição do conhecimento, as RNAs extraem automaticamente regras difusas a partir de dados numéricos; dessa forma, os métodos difusos são utilizados para intensificar a capacidade de aprendizagem das RNA

Um ambiente computacional utilizado na implementação de SNDs envolve o desenvolvimento do neurônio difuso baseado na estrutura dos neurônios biológicos seguido pelo mecanismo de aprendizagem. A partir desse processo são executadas as etapas: (a) desenvolvimento do modelo neural difuso fundamentado no conhecimento dos neurônios biológicos; (b) modelagem da conexão sináptica, a qual incorpora conceitos difusos em uma RNA; (c) desenvolvimento do algoritmo de aprendizagem.

O principal componente no desenvolvimento de um SND está relacionado à implementação do neurônio difuso, o qual é descrito a seguir.

Neurônios difusos foram introduzidos por LEE no início da década de 1970, os quais representam uma generalização do modelo de neurônio de McCulloch-Pitts (McCULLOCH e PITTS, 1943).

Na literatura são encontrados vários modelos de neurônios difusos, os quais envolvem a manipulação dos operadores lógicos **E/OU** através das *t-normas* e *t-conormas* (KLIR e YUAN, 1995).

Uma classe geral de operadores de intersecção para CDs é definida pelas normas triangulares ou *t-normas*, e uma classe de operadores de união é definida, analogicamente, pelas *t-conormas* ou *S-normas*. As normas triangulares foram introduzidas por Schweizer e Sklar em 1961 com a finalidade de modelar distâncias em espaços probabilísticos. Estas operações são aplicadas na LD como conectivos lógicos **E**; similarmente, as *t-conormas* são utilizadas para modelar os conectivos lógicos **OU**.



O primeiro neurônio difuso implementado é o modelo proposto por Hirota-Pedrycz o qual combina os sinais de entrada e os pesos utilizando uma *t-norma* ou uma *t-conorma* (HIROTA e PEDRYCZ, 1992, 1994).


O segundo modelo de neurônio difuso faz referência aos autores Kwan-Cai, que utilizam, além das funções de agregação e ativação, o produto entre os pesos e os sinais de entrada (KWAN e CAI, 1994).

O próximo capítulo descreve a Metodologia de Aprendizagem proposta.

## 5 Metodologia de Aprendizagem

O processo de aprendizagem dos modelos consiste em atualizar os pesos sinápticos, através de uma operação aritmética *t-norma* Produto Algébrico ou de Einstein, para os neurônios E; nos neurônios OU é utilizada a operação aritmética *t-conorma* Soma Algébrica ou de Einstein, ambas aplicadas na etapa de avaliação das regras difusas, conforme mostra a figura 3.

Figura 3. Modelo de aprendizagem do SND proposto



Na seqüência, faz-se a descrição das camadas que compõem o modelo de aprendizagem.

**Camada 1:** representa os quatorze neurônios de entrada. Cada nodo desta camada representa um valor quantitativo de entrada da rede. É a camada que recebe os dados a partir do ambiente externo;

**Camada 2:** cada nodo dessa camada representa o grau de pertinência de um valor lingüístico, associado a uma variável de entrada de acordo com seus respectivos CDs;

**Camada 3:** nesta camada são implementadas as regras de classificação utilizando o neurônio difuso **E** a partir das operações aritméticas difusas Produto Algébrico e Produto de Einstein na composição das regras, representadas abaixo, respectivamente:

$$\text{Camada}_3 = \mu_{A,i}(x) * \mu_{B,i}(y)$$

$$\text{Camada}_3 = [\mu_{A,i}(x) * \mu_{B,i}(y)] / 2 - [\mu_{A,i}(x) + \mu_{B,i}(y)] - [\mu_{A,i}(x) * \mu_{B,i}(y)]$$

Onde:

$x$  e  $y$  representam as entradas do nodo  $i$ ;

$A, i$  representam as variáveis lingüísticas associadas com o nodo.

**Camada 4:** Cada nodo na camada 4 representa o cálculo do neurônio difuso **OU** utilizando operações aritméticas difusas Soma Algébrica e Soma de Einstein, representadas abaixo, respectivamente:

$$\text{Camada}_4 = [\mu_{A,i}(x) + \mu_{B,i}(y)] - [\mu_{A,i}(x) * \mu_{B,i}(y)]$$

$$\text{Camada}_4 = [\mu_{A,i}(x) + \mu_{B,i}(y)] / -1 + [\mu_{A,i}(x) * \mu_{B,i}(y)]$$

**Camada 5:** esta camada representa a saída do SND, apresentando a possibilidade de ocorrência de um EE ou ENE.

Na seqüência, o processo de aprendizagem utilizado pelo neurônio difuso proposto por Hirota-Pedrycz é descrito.

**O neurônio difuso E é descrito como:**

$$y = \varphi (T (S (w_1, x_1), S (w_2, x_2))) (1)$$

Os valores de  $x_i$  e  $w_i$  são combinados por uma operação *t-conorma* **S** ( $\cup$ ). A seguir esta informação é agregada por uma operação *t-norma* **T** ( $\cap$ ) para produzir a saída “y”.

**O neurônio difuso OU é descrito como:**

$$y = \varphi (S (T (w_1, x_1), T (w_2, x_2))) (2)$$

Os valores de  $x_i$  e  $w_i$  são combinados por uma operação *t-norma* **T** ( $\cap$ ). A seguir esta informação é agregada por uma operação *t-conorma* **S** ( $\cup$ ) para produzir a saída “y”.

A seguir, o processo de aprendizagem utilizado pelo neurônio difuso proposto por Kwan-Cai é apresentado.

**O neurônio difuso E é descrito como:**

No neurônio difuso **E**, o sinal de entrada  $x_i$  interage com o peso sináptico  $w_i$  para produzir o produto ( $p_i = w_i x_i$ ), o qual é agregado por uma *t-norma*  $T (\cap)$ :

$$z = T \{p_1, p_2\} = T \{w_1 x_1, w_2 x_2\} \quad (5)$$

**A saída do neurônio é computada por:**

$$y = \varphi (T (w_1 x_1), (w_2 x_2) - \theta) \quad (6)$$

No neurônio difuso **OU** a operação *t-norma* é substituída pela operação *t-conorma*  $S (\cup)$ , resultando como saída:

$$y = \varphi (S (w_1 x_1), (w_2 x_2) - \theta) \quad (7)$$

**Onde:**

$\varphi(\cdot)$  = função de ativação logística;

$\theta$  = *threshold* de ativação (*bias*).

O próximo capítulo descreve os resultados encontrados após a simulação.

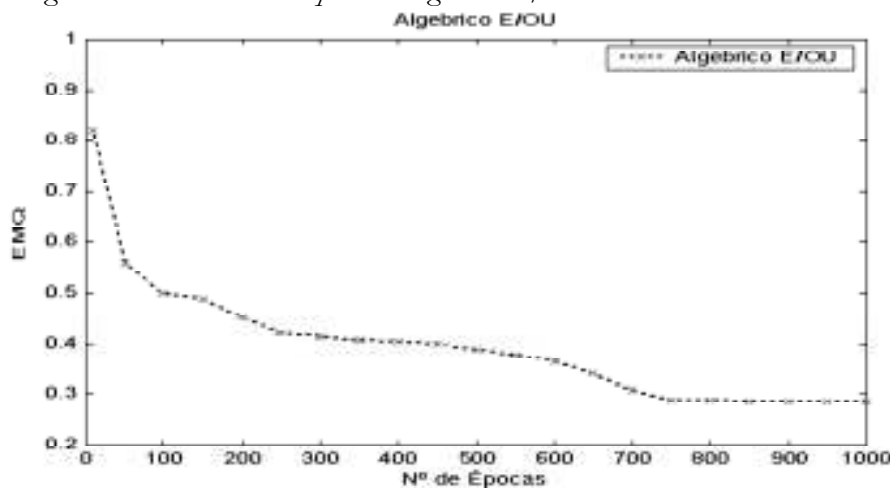
## 6 Resultados

Os resultados foram analisados considerando os indicadores quantitativos de modelagem. Cada modelo foi avaliado a partir das mesmas bases de casos de EEs e ENEs e em ambos os modelos a RNA foi treinada com 1.000 épocas.

Na seqüência, os resultados obtidos nas fases de treinamento e teste incluindo o RMS referente ao modelo Hirota-Pedrycz.

As operações aritméticas Soma/Produto Algébrico E/OU obtiveram os seguintes resultados de acordo com a figura 4.


Figura 4. RMS  $\times$  N° de Épocas - Algébrico E/OU



Observa-se na figura 4 que o RMS permaneceu entre os valores [0.87; 0.28], apresentando um RMS de 0.41, com uma Variação da Taxa Absoluta<sup>4</sup> desse RMS de 0.025. Na fase de teste o RMS foi de 0.50, com 45,87% de classificações corretas.

As operações aritméticas difusas Soma/Produto de Einstein E/OU apresentaram os resultados exemplificados na figura 5.

Figura 5. RMS  $\times$  N° de Épocas - Einstein E/OU



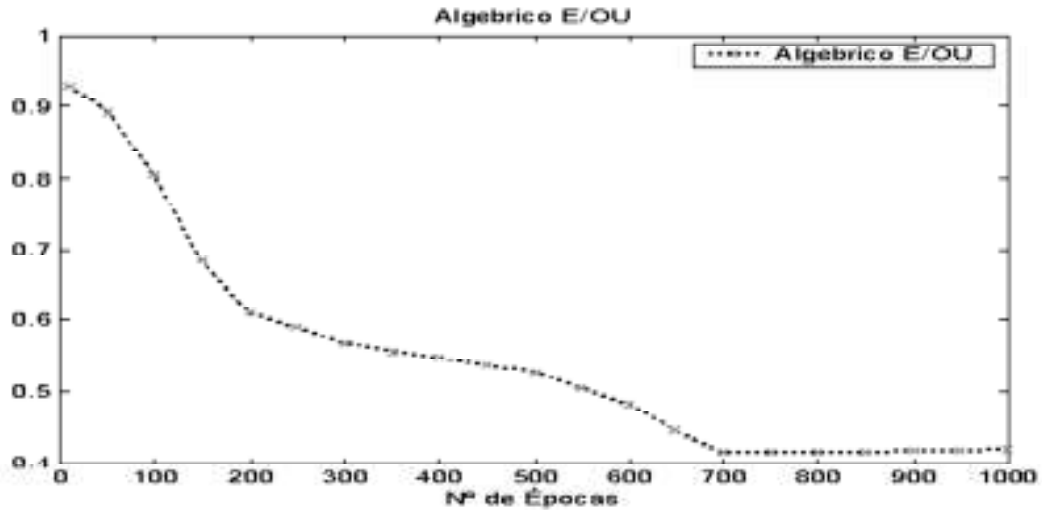
De acordo com a figura 5, o RMS na fase de treinamento permaneceu nos intervalos [0.30; 0.18,] com um RMS de 0.23 e apresentando uma Variação da Taxa Absoluta do RMS Médio em 0,002. Na fase de teste o RMS foi de 0.10 com 91,74% de classificações corretas. A seguir, os resultados obtidos com o modelo Kwan-Cai.

Nas operações aritméticas Soma/Produto Algébrico E/OU, foram observados os seguintes resultados (Figura 6).

---

<sup>4</sup> A Variação da Taxa Absoluta define quanto o RMS variou época por época. Menores índices de variação significam melhores índices de aprendizagem.

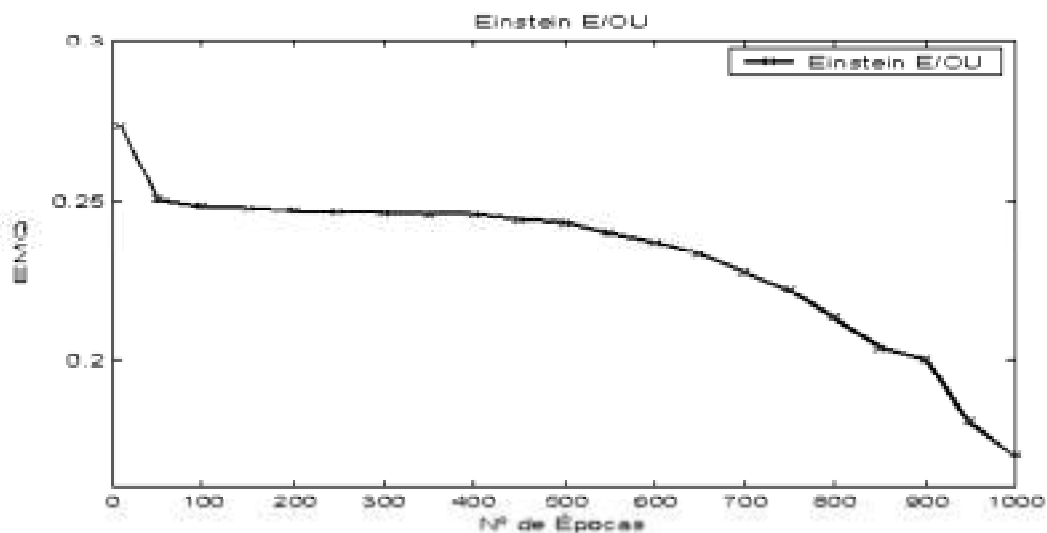
Figura 6. RMS  $\times$  N<sup>o</sup> de Épocas - Algébrico E/OU



De acordo com a figura 6, o RMS da fase de treinamento permaneceu nos intervalos [0.92; 0.41,] com um RMS Total Médio de 0.55 e apresentando uma Variação da Taxa Absoluta do RMS Médio em 0,05. A fase de teste apresentou um RMS de 0.51, com 44,04% de classificações corretas.

As operações aritméticas difusas Soma/Produto de Einstein E/OU apresentaram os resultados exemplificados na figura 7.

Figura 7. RMS  $\times$  N<sup>o</sup> de Épocas - Einstein E/OU



De acordo com a figura 7, o RMS da fase de treinamento permaneceu nos intervalos [0.27; 0.17,] com um RMS Total Médio de 0.23 e uma Variação da Taxa Absoluta do RMS Médio em 0,001. A fase de teste apresentou um RMS de 0.21, com 93,58% de classificações corretas.

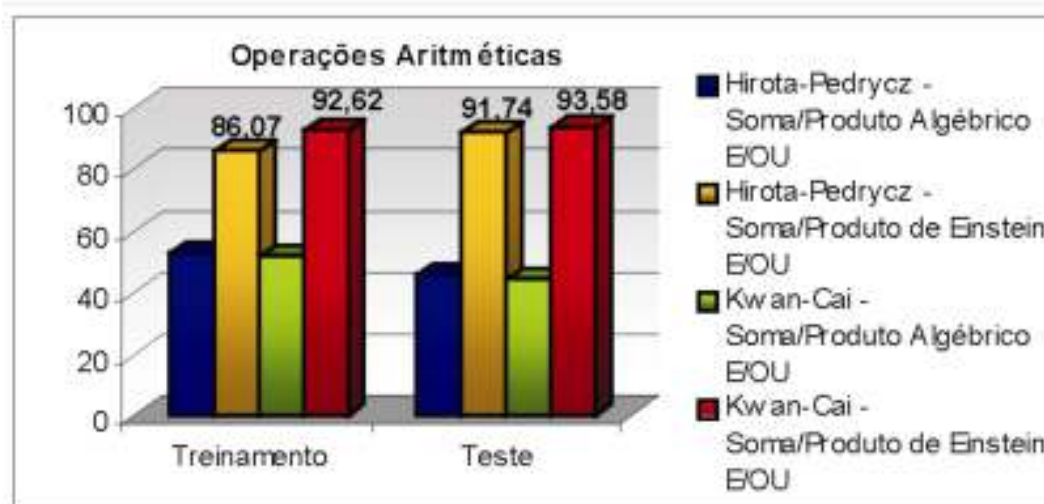
Os melhores percentuais de classificações corretas foram obtidos por meio do modelo Kwan-Cai, utilizando as operações aritméticas Soma/Produto de Einstein E/OU com 93,58%.

Em segundo lugar, com 91,74% de classificações corretas, encontra-se o modelo proposto por Hirota-Pedrycz por meio das operações aritméticas Soma/Produto de Einstein E/OU, ambos na fase de teste.

Na fase de treinamento, os melhores índices de acertos foram obtidos com o modelo Kwan-Cai (92,62%) seguindo do modelo Hirota-Pedrycz, que apresentou 86,07% de classificações corretas.

Com índices menores de acertos nas fases de treinamento e teste encontram-se as operações aritméticas Soma/Produto Algébrico E/OU. No modelo Hirota-Pedrycz obteve-se um percentual de acertos de 52,46% e 45,87%; no modelo Kwan-Cai o percentual foi 51,64% e 44,04% de classificações corretas, respectivamente. Estes resultados podem ser visualizados na figura 8.

Figura 8. Fases de Treinamento e de Teste



De acordo com a figura 8, após aplicado o teste de hipóteses para proporções, ao comparar o neurônio difuso proposto por Kwan-Cai e Hirota-Pedrycz por meio das operações aritméticas Soma/Produto Algébrico com as

operações aritméticas Soma/Produto de Einstein, observou-se que os resultados obtidos a partir das operações aritméticas difusas Soma/Produto de Einstein na fase de teste são estatisticamente melhores do que as operações aritméticas Soma/Produto Algébrico ( $p\_valor (0,13^{-13}) < \alpha$ )<sup>5</sup>, a um nível de significância de 0,05, respectivamente.

Observa-se, também, que os resultados obtidos na fase de teste com as operações aritméticas Soma/Produto de Einstein E/OU foram superiores aos resultados obtidos na fase de treinamento da rede, ambos com os neurônios difusos propostos por Hirota-Pedrycz e Kwan-Cai.

Após a validação interna da base de conhecimentos, o melhor índice de SEN, ou seja, a capacidade do sistema detectar casos positivos, foi obtido com o modelo Kwan-Cai (90,69%), seguido do modelo Hirota-Pedrycz, com 83,72% de sensibilidade.

Em relação à capacidade do sistema de detectar casos negativos da hipótese diagnóstica, ou seja, o índice de ESP, o modelo Kwan-Cai obteve o melhor índice (96,82%) em relação ao índice de 92,06%, utilizado por Hirota-Pedrycz.

Em relação ao grau de certeza de que os registros pertencem à hipótese diagnóstica (VPP), os melhores índices contemplam o modelo Kwan-Cai, com 84,78%, seguido do Hirota-Pedrycz, com 78,26% de certeza.

Finalmente, o VPN, grau de certeza de que os registros não pertencem à hipótese diagnóstica, o melhor índice de 96,82% foi obtido com Kwan-Cai, seguido de Hirota-Pedrycz, com 92,06%.

Após aplicado o teste de hipóteses para proporções, ao comparar os neurônios difusos propostos por Kwan-Cai e Hirota-Pedrycz, observou-se que os resultados obtidos a partir do neurônio difuso Kwan-Cai relacionados com as medidas de SEN, ESP e VPN tendem a ser estatisticamente melhores dos resultados obtidos com o neurônio difuso proposto por Hirota-Pedrycz ( $p\_valor (0,06) \cong \alpha$ ), a um nível de significância de 0,05, respectivamente. Observe-se que o valor de VPP obtido com o neurônio difuso proposto por Kwan-Cai apresentou resultados semelhantes dos do neurônio difuso proposto por Hirota-Pedrycz ( $p\_valor (0,1) > \alpha$ ).

## 7 Conclusões

Os resultados obtidos demonstram a capacidade dos modelos de trabalharem com diferentes configurações de neurônios difusos e operações aritméticas, fornecendo resultados diferenciados no reconhecimento de padrões. O

---

<sup>5</sup>  $p\_valor$  representa a probabilidade de significância, obtido após a realização do teste de hipótese.

comportamento das curvas de aprendizagem nos melhores modelos aprendem o valor correto dos pesos em torno de 300 épocas de treinamento.

Os melhores resultados nas fases de treinamento e teste foram obtidos com o modelo Kwan-Cai seguido do modelo Hirota-Pedrycz, ambos com as operações aritméticas Soma/Produto de Einstein E/OU, respectivamente. Estas operações aritméticas classificaram corretamente os padrões, gerando resultados mais eficientes que as geradas pelas operações Soma/Produto Algébrico E/OU, no modelo de domínio proposto.

Dessa forma, a Metodologia de Aprendizagem proposta inclui o desenvolvimento de neurônios difusos utilizando ambos os modelos Kwan-Cai e Hirota-Pedrycz por meio das operações aritméticas difusas Soma/Produto de Einstein E/OU.

Como trabalhos futuros na área de SNDs, sugere-se utilizar outras operações aritméticas *t-normas* e *t-conormas*, entre elas as operações aritméticas difusas Soma/Produto de Hamacher e a operação aritmética padrão *Max/min*.

## 8 Referências

AGUIAR, L.; MELIN P.; CASTILLO O. Intelligent control of a stepping motor drive using a hybrid neuro-fuzzy ANFIS approach. **Applied Soft Computing**, v. 3, n. 3, p. 209-219, 2003.

AZEVEDO, F. M. de; BRASIL, L. M.; OLIVEIRA, R. C. L. de. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**. Florianópolis: Bookstore, p. 401, 2000.

BUCKLEY, J. J. **An Introduction to Fuzzy Logic and Fuzzy Sets**. Advances in Soft Computing. USA: Physica-Verlag, 2002.

COSTA, J. C. da et al. **Fundamentos Neurobiológicos das Epilepsias**: aspectos clínicos e cirúrgicos. São Paulo: Lemos; 1998.

DEVORE, J. L. **Probabilidade e Estatística para Engenharia e Ciências**. Thomson Pioneira, SP, 2006.

ENGEL J. Psychogenic seizures. Disponível em: <<http://www.medlink.com>>. Acesso em: 04 Jan 2006.

EPILEPSIA. Liga Brasileira de Epilepsia: Manifestações - Sintomas e Incidência. Disponível em: <<http://www.epilepsia.org.br>>. Acesso em: 05 Jan 2006.



FERNANDES, J. G. **Epidemiologia das crises epiléticas em Porto Alegre: um estudo populacional.** Porto Alegre (RS): Universidade Federal do Rio Grande do Sul, 1993.

FERNANDES, J. G. *et al.* **Prevalence of epilepsy: the Porto Alegre study.** *Epilepsia*, v. 3, p. 132-33, 1992.

FULLÉR, R. R. **Introduction to Neuro-Fuzzy Systems.** New York, USA: Physica-Verlag, 2000.

GORZALCZANY, M. B. **Computational Intelligence Systems and Applications.** New York, USA: Physica-Verlag, 2002.

GUERREIRO, C. A. **Diagnóstico Diferencial entre as Crises Tônico - Clônicas Generalizadas e Crises Parciais Secundariamente Generalizadas.** Liga Brasileira de Epilepsia. Rio de Janeiro: Biogalênica Products, 2000.

GUPTA, M. M; RAO, D. H. On the Principles of Fuzzy Neural Networks. **Fuzzy Sets and Systems**, v. 1, p. 18-61, 1994.

HAYKIN, S.; 2001. **Redes Neurais: Princípios e Prática.** 2. ed. Porto Alegre : Bookman.

HIROTA, K.; PEDRYCZ, W. Knowledge-based networks in classification problems. **Fuzzy Sets and Systems**, v. 51, p. 1-27, 1992.

\_\_\_\_\_. OR/AND neuron in modeling fuzzy set connectives. **IEEE Transactions on Fuzzy Systems**, v. 2, p. 151-161, 1994.

ILAE - Commission on Classification and Terminology of International League Against Epilepsy. In: Proposal for Revised Clinical and Electrographic Classification of Epileptic Seizures, **Epilepsia**, v 2, p. 489-501, 1981.

ILAE - Commission on Classification and Terminology of International League Against Epilepsy. In: Proposal for Revised Clinical and Electrographic Classification of Epilepsies and Epileptic Syndromes, **Epilepsia**, v. 30, p. 389-99, 1989.

ILAE - The 2001 Proposal for a Diagnostic Scheme. Disponível em: <<http://www.ilae-epilepsy.org/Visitors/Publications/AnnualReport2003/classification.cfm>>. Acesso em: 13 Nov 2005.

ILAE - A proposed Diagnostic Scheme for People with Epileptic Seizures and with epilepsy: Report of the ILAE Task Force on Classification and Terminology. Disponível em: <<http://www.ilae.org>>. Acesso em: 03 Jan 2006.

INAN et al. Prediction of surface expansion of PC mortar using adaptive neuro-fuzzy methodology. *Building and Environment*, Article in Press, nov. 2005, Science Direct: Elsevier, 2005.

KLIR, G.; YUAN, B. **Fuzzy Sets and Fuzzy Logic: Theory and Applications**. USA: Prentice; 1995.

KWAN, H. K.; CAI, T. A Fuzzy Neural Network and its Application to Pattern Recognition. **IEEE Transactions on Fuzzy Systems**, v. 3, p. 185-93, 1994.

LAI, C. W.; LAI, Y. H. C. History of epilepsy in Chinese traditional Medicine. **Epilepsia**, v. 32, p. 299-302, 1991.

LEE, S. C.; LEE, E. T. Fuzzy neurons and automata. Proceedings of the 4th Princeton **Conference on Information Science Systems**, p. 381-385, 1970.

MAMDANI, E. H. Application of fuzzy algorithm for control of simple dynamic plant. **IEEE Control and Science**, v. 121, p. 1585-1588, 1974.

MELIN, P.; CASTILLO, O. **Hybrid Intelligent Systems for Pattern Recognition Using Soft Computing**. Studies in Fuzziness and Soft Computing, v. 172. Springer Berlin Heidelberg New York, 2005.

McCULLOCH, W. S.; PITTS, W. H. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

NASSAR, S. M. **Estatística e Informática: um processo interativo entre duas ciências**. Florianópolis (SC): Universidade Federal de Santa Catarina, 1998.

PEDRYCZ, W.; GOMIDE, F. **An Introduction to Fuzzy Sets – The MIT Press**, 1998.

REZENDE, S. O. et al. **Sistemas Inteligentes - Fundamentos e Aplicações**. São Paulo: Manole, 2003.

RUTKOWSKA, D. **Neuro-Fuzzy Architectures and Hybrid Learning**. Studies in fuzziness and soft computing. New York: Physica-Verlag, 2002.

VELLASCO, M. M. B. R. et al. Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model. **International Journal of Electrical Power and Energy Systems**, v. 26, p. 131-142, 2004.

VELLASCO, M. M. B. R.; PACHECO, M. A. C. Núcleo de Pesquisa em Inteligência Computacional Aplicada. PUC-RIO. Disponível em: <<http://www.ica.ele.puc-rio.br>>. Acesso em: 03 Jan 2006.

YU, W.; LIN, H. A VaFALCON neuro-fuzzy system for mining of incomplete construction databases. *Automation in Construction*, v. 15, p. 20-32, 2006.

WOLF, P. Of cabbages and kings: Some considerations on classifications, diagnostic schemes, semiology and concepts. **Epilepsia**, v. 44, p. 1-4, 2003.

ZADEH, L. A. The Berkeley Initiative in Soft Computing (BISC). Disponível em: <<http://www.cs.berkeley.edu/~zadeh>>. Acesso em: 02 Jan 2006.