

Análise do impacto de diferentes operações aritméticas aplicadas em um Sistema Neuro-Difuso

Lucimar Fossatti. de Carvalho

Ciência da Computação, Universidade de Passo Fundo - UPF, Passo Fundo/RS

Silvia M. Nassar e Fernando M. de Azevedo

Universidade Federal de Santa Catarina -UFSC, Florianópolis/SC

Hugo J. Teixeira de Carvalho

Hospital São Vicente de Paulo, Passo Fundo/RS

Candice A.S. Dani

Ciência da Computação, Universidade Federal de Santa Catarina - UFSC,
Florianópolis/SC

L. L. Monteiro

Ciência da Computação, Universidade de Passo Fundo - UPF, Passo Fundo/RS

(Recebido: 23 de junho de 2004)

Resumo: Esta pesquisa tem como objetivo a análise de modelos de aprendizagem utilizando diferentes operações aritméticas aplicadas em um Sistema Neuro-Difuso (SND). A pesquisa integra os conceitos envolvendo as Redes Neurais Artificiais (RNAs) e a Teoria dos Conjuntos Difusos (TCDs). Descreve diferentes combinações de operações aritméticas utilizadas na composição das regras difusas utilizando expressões de entrada lingüísticas e numéricas. Para avaliar a validade da proposta, um Sistema Neuro-Difuso (SND) é proposto para diagnosticar Eventos Paroxísticos envolvendo os Eventos Epilépticos (EEs) e os Eventos não Epilépticos (ENEs). A principal contribuição do trabalho encontra-se na análise do desempenho de diferentes operações aritméticas aplicadas em um SND. Após uma simulação realizada, constatou-se que as operações aritméticas Min/Max, nas quatro simulações, se distanciaram a partir da visão do especialista de domínio. As operações aritméticas Produto/Soma Algébrica e Produto/Soma de Hamacher apresentaram um valor final mais próximo em relação ao valor fornecido pelo especialista de domínio. Portanto, o desenvolvimento de um SND, baseado na utilização destas operações aritméticas, justifica-se levando a uma maior ou menor taxa de acertos do sistema.

Palavras-chave: *Redes Neurais Artificiais, Teoria dos Conjuntos Difusos, Sistemas Neuro-Difusos*

Abstract: *The goal of this research is the analysis of learning models by using various arithmetic operations applied in a Neuro-Fuzzy System (NFS). The research integrates the concepts between Artificial Neural Networks (ANN) and the Fuzzy Sets Theory (FST). It describes various combinations of arithmetic operations in order to compose the fuzzy rules by using expressions of linguistic and numerical input. In order to assess the validity of the proposal, an NFS is proposed to diagnose Paroxysmal Events involving Epileptic Events (EE) and Non Epileptic Events (NEE). After a simulation had been performed, one has verified that the arithmetic operations Product/Algebraic Sum and Product/ and Hamache's Sum present a closer final value compared to the value supplied by the mastering expert.*

Key words: *Artificial Neural Networks, Neuro-Fuzzy Systems, Fuzzy Set Theory*

1 Introdução

As pesquisas mostram uma tendência na utilização de técnicas de raciocínio impreciso baseadas na ação simultânea entre RNAs e a TCDs. Algoritmos de aprendizagem, envolvendo o processamento híbrido entre estas duas abordagens, são encontrados na literatura utilizando diferentes algoritmos de desenvolvimento.

A partir de meados da década de 1980, diversos autores têm desenvolvem pesquisas com SND. Dentre os trabalhos mais recentes destacam-se: um estudo realizado sobre a extração de conhecimento de RNAs na forma de regras difusas aplicado ao problema da previsão da estrutura secundária de proteínas (BATTISTELLA, 2004); uma Proposta de Modelagem de Conhecimentos sobre Glaucoma por um Sistema Híbrido Neuro-Fuzzy (APPEL, 2004); um Sistema Neuro Fuzzy de Monitoramento e Diagnóstico de Falhas em Reatores Nucleares (BRANCO & EVSUKOFF, 2003); um sistema híbrido utilizando uma combinação de RNAs e TCDs aplicado à robótica (WAGNER, 2003); um modelo neuro-fuzzy para reconhecimento de padrões implementado no problema de classificação de cromossomas no grupo de Denver (RAITTZ, 2002); uma ferramenta para análise fundamentalista de investimentos em empresas utilizando sistemas neuro-nebulosos (RAPOSO, 2001); desenvolvimento de um sistema inteligente utilizando uma abordagem neuro-difusa no reconhecimento de padrões (VIANNA, 2000).

Lógica Fuzzy e Redes Neurais são inspiradas nas habilidades computacionais humanas, não requerem modelos matemáticos e possuem a capacidade de trabalhar com incerteza e imprecisão. São complementares entre si, ou seja, sistemas que trabalham com Lógica Fuzzy necessitam de um conjunto de regras, as quais são obtidas por especialistas humanos e não aprendem por exemplos; Redes Neurais podem aprender, generalizando o conhecimento (IBRAHIM, 2004).

Em várias situações rotineiras envolvendo a tomada de decisões, as pessoas se defrontam com conhecimentos imprecisos. Como proceder para que a decisão a ser tomada seja a mais próxima do objetivo a ser alcançado? Ou para que o raciocínio sobre um determinado evento seja o mais próximo do raciocínio humano? Na tentativa de estudar os diferentes métodos de representação do conhecimento, uma questão importante a ser analisada está relacionada com a modelagem de grandes bases de conhecimento associadas às informações imprecisas. Uma das principais dificuldades, ao se projetar um Sistema Especialista (SE), está relacionada com a escolha de técnicas de inferência que melhor represente o domínio escolhido. Por exemplo, um médico especialista, ao formular uma hipótese diagnóstica, utiliza diferentes técnicas de raciocínio ao descrever o diagnóstico final, entre elas, o raciocínio dedutivo, indutivo, abduutivo e raciocínio causal (GIARRATANO, 1989).

Portanto, se o objetivo é implementar sistemas que utilizam Inteligência Computacional deve-se priorizar as pesquisas que envolvam o trabalho conjunto entre diferentes técnicas de inferência. Sabe-se que a lógica difusa fornece métodos de inferência, para representar variáveis lingüísticas que representam informações imprecisas. E, uma das grandes vantagens das RNAs, encontra-se na sua capacidade de aprendizagem, a partir de uma massa de dados oriundos de domínios diversos e sua posterior generalização. Portanto, ao se projetar um SE, envolvendo o trabalho conjunto de métodos de inferência, o resultado do sistema poderá se aproximar do processo de raciocínio humano, pois enquanto as RNAs possuem um bom desempenho na classificação de padrões, são deficientes para explicarem como atingiram um determinado objetivo. Em contrapartida, sistemas que utilizam a lógica difusa podem explicar como o objetivo foi alcançado. A partir da justificação destas técnicas, resultam os Sistemas Híbridos Neuro-Difusos.

Uma das principais dificuldades que apresentam os SEs, para apoio à tomada de decisão na área médica, é a imprecisão nos dados relatados pelos pacientes ou obtidos em exames e que são utilizados na investigação do diagnóstico e na escolha do tratamento. A incerteza e a imprecisão dos dados podem ser consideradas como a falta de informação adequada para a tomada de decisão. Na área médica, esta incerteza poderá impedir o melhor tratamento para um paciente ou mesmo fornecer uma terapêutica incorreta.

O domínio de aplicação, escolhido para validar o SE, foi no Diagnóstico de Eventos Paroxísticos, envolvendo os EEs e os ENEs. Sendo assim, o presente trabalho tem por objetivo investigar os resultados de diferentes técnicas utilizadas no tratamento das informações imprecisas. Os resultados obtidos servirão como parâmetro na escolha do tipo de operação aritmética a ser utilizada quando da definição de um SND.

O trabalho está organizado da seguinte forma: a primeira seção contém uma introdução ao tema proposto. Na segunda seção, são descritos os materiais e métodos utilizados na pesquisa, o domínio de aplicação escolhido e uma descrição das tecnologias envolvidas (RNA e a TCD). A terceira seção descreve o modelo proposto de SND. Na seqüência, os resultados obtidos por meio de simulações, conclusões e uma lista de referências consultadas e referenciadas no texto.

2 Materiais e métodos

No desenvolvimento do sistema, é utilizado o modelo de inferência Mamdani (MANDANI, 1974) baseado no perceptron multicamada, utilizando o algoritmo de retropropagação modificado o qual é utilizado na classificação de padrões e na geração das regras difusas. O algoritmo modificado incorpora os pesos sinápticos pela escolha dos operadores **E/OU** na camada intermediária e dos operadores **OU/E** na camada de saída, no lugar da soma dos pesos e funções sigmoidais. As operações do produto escalar, entre as entradas da rede e seus pesos ($x_{ij}w_{ij}$), são substituídas pela operações **T** que representa o *min* e a operação somatório substituída pela operação **S** que representa o *max*.

As entradas da rede contêm valores qualitativos (expressões lingüísticas) e quantitativos (numéricos). A base de dados é composta por cento e onze pacientes, escolhidos aleatoriamente e, quando se tratar de criança, o termo de consentimento deve ser assinado pelos pais ou responsáveis. Deste total, setenta e cinco pacientes integram a fase de treinamento da rede e trinta e seis pacientes integram a fase de testes. O número de pacientes, que integram a base de treinamento, está relacionado com a representatividade dos principais sintomas apresentados pelos pacientes. A rede é treinada a partir de uma base de regras inicial, contendo cinqüenta e sete regras difusas, as quais foram implementadas em conjunto com o médico neurologista que acompanha o desenvolvimento da pesquisa¹.

Os dados dos pacientes, utilizados no treinamento da rede, são cadastrados de acordo com o questionário de Rastreamento Neurológico para Epilepsia (QRN-E) (FERNANDES, 1993). Foi através do QRN-E que se determinou quais variáveis deveriam integrar o sistema de coleta de dados. O Sistema Especialista proposto utiliza a **Classificação Clínica e Eletroencefalográfica das Crises Epiléticas - ILAE/81** (COMMISSION, 1981).

O processo de aprendizagem da rede consiste em atualizar os pesos sinápticos, pela operação *t-norma* utilizando os operadores Produto Algébrico, Produto de Hamacher e operação *Softmin* para os neurônios **E** e da operação *t-conorma*, através dos operadores Soma Algébrica, Produto de Hamacher e a operação *Softmax* para os neurônios **OU**.

Na implementação do SND utiliza-se, no módulo de inferência, uma RNA com quatorze unidades na camada de entrada, as quais representam os sintomas apresentados pelos pacientes; uma camada escondida contendo cinqüenta e sete neurônios, os quais representam as regras difusas e uma camada de saída contendo três neurônios de saída, os quais representam as três classes possíveis de ocorrerem, ou seja, EE, ENE e ENC. A máquina de inferência recebe valores difusos, provenientes da camada de entrada e realiza o processamento das regras gerando um Conjunto Difuso (CD) de saída, a partir de todas as regras disparadas. Este processo transforma informações qualitativas em informações quantitativas, e constitui o processo de generalização, conhecido como "*fuzzificação*".

¹O médico especialista é Hugo José Teixeira de Carvalho, residente na cidade de Passo Fundo/RS. O projeto foi aprovado pelo Comitê de Ética da Universidade de Passo Fundo/RS.

O sistema integra o módulo de “fuzzificação”, inferência e aprendizagem, no qual neurônios do modelo original de uma RNA são substituídos por regras e conjuntos difusos. O algoritmo de aprendizagem do SND é baseado no algoritmo de retropropagação modificado. O sistema é capaz de aprender regras difusas a partir de dados, reduzindo o número de nós (regras) na camada escondida da rede. Para cada característica de entrada \mathbf{x}_i existe \mathbf{n}_i CDs e a base de regras será composta por \mathbf{K} regras difusas. O objetivo está concentrado em encontrar o número suficiente de regras difusas, que podem classificar corretamente um conjunto de padrões de entrada.

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

Para avaliar a validade da proposta, um SND é proposto para diagnosticar Eventos Paroxísticos envolvendo os EEs e os ENEs, em especial as crises históricas. Optou-se por estudar as crises históricas, uma vez que segundo WHO (1993) os tipos mais frequentes de ENEs correspondem às crises históricas, denominadas crise convulsiva conversiva e crise dissociativa. Nos próximos parágrafos é descrito uma visão geral envolvendo os temas propostos.

O diagnóstico diferencial entre Eventos Paroxísticos encontra diversas dificuldades, sendo que o problema fundamental é o de diferenciar um EE de um ENE. Porém, o diagnóstico poderá ser realizado por meio de uma anamnese completa e, se possível, realizar o exame de Eletroencefalograma.

Epilepsia e as doenças mentais são conhecidas desde a antiguidade. A história das duas doenças é repleta de associações com a religião e a superstição. As conseqüências do não reconhecimento dos ENEs podem ser catastróficas. Pacientes não epiléticos podem ser submetidos erroneamente a regimes terapêuticos com anticonvulsivantes. O verdadeiro desafio diagnóstico e de conduta são os chamados pacientes mistos, portadores de EEs e de ENEs. O volume deste último contingente não pode ser desprezado, uma vez que responde de 10% a 60% da população (GATES, 1993).

A Organização Mundial da Saúde (OMS) definiu epilepsia como “um distúrbio do cérebro, de etiologias variadas, caracterizado pelas crises recorrentes conseqüentes à descarga excessiva dos neurônios cerebrais”. Existe uma diferença importante entre epilepsia e crise epilética. A crise epilética é um fenômeno elétrico cerebral com manifestações clínicas diversas (MIN, 1994). A prevalência da epilepsia é estimada no país entre 1 a 2% da população. Calcula-se que, aproximadamente, 50% dos pacientes que procuram os serviços de neurologia sejam portadores de epilepsia. Dessa forma é importante a realização de diagnósticos de epilepsia corretamente (GUERREIRO, 1993).

A histeria é uma anomalia do sistema nervoso. Sua sintomatologia é extremamente rica e compõe-se de uma série de sintomas que incluem os seguintes: ataques convulsivos, zonas heterogêneas, distúrbios da atividade sensorial, paralisias e contraturas.

Charcot sustenta com firmeza, a opinião de que a histeria é um quadro bem definido, que pode ser reconhecido com bastante clareza, nos casos extremos daquilo que se conhece como grande histeria ou histeroepilepsia (FREUD, 1998).

Nesta pesquisa, para caracterizar um EE de um ENE, são utilizados quatorze valores qualitativos, os quais estão descritos na seção 3 - Modelo Proposto. Os valores foram definidos juntamente com o médico neurologista que acompanha o desenvolvimento da pesquisa.

2.1 Tecnologias envolvidas (RNA e TCD)

Os SNDs utilizam técnicas oriundas a partir das RNAs para aprender CDs. Pelo processamento híbrido entre estes dois paradigmas, são construídos sistemas mais robustos e mais flexíveis. Segue nos próximos parágrafos uma definição envolvendo as RNAs e a TCDs.

As RNAs são também conhecidas como neurocomputadores, redes conexionistas, sistemas de processamento paralelo e distribuído. Mais recentemente, as RNAs estão sendo vistas como grafos orientados constituídos de nós com elos de interligação sinápticos e de ativação (AZEVEDO, 1993). As pesquisas envolvendo as RNAs iniciaram no campo da neurobiologia matemática, embora os modelos atuais estejam caminhando na direção da área estatística, principalmente aplicados à área do comércio, gerenciamento de informações, marketing, sistemas de apoio à decisão, sistemas de informação na produção industrial e engenharia (VELLIDO e CERQUIDES, 2002).

Uma RNA é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. A rede é implementada utilizando-se componentes eletrônicos ou poderá ser simulada por programação em um computador digital, ou seja, uma RNA consiste de um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples com a capacidade de armazenar conhecimento tornando-o disponível para o uso (HAYKIN, 2001).

O primeiro modelo artificial de um neurônio biológico foi idealizado por fisiologista e psiquiatra McCULLOCH (1943), juntamente com o seu aluno, o matemático Walter Pitts, o qual ficou conhecido como modelo MCP, como mostra a Figura 1.

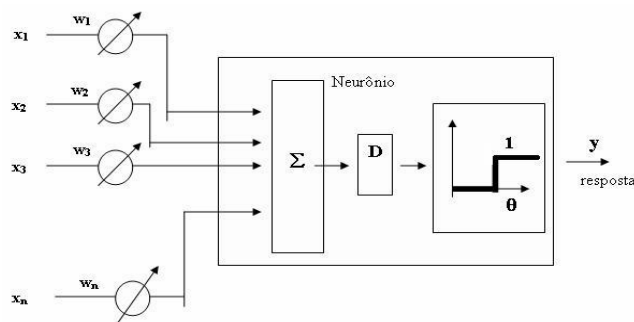


Figura 1 - Modelo de Neurônio de McCulloch e Pitts

O modelo de MCP é simplificado, ou seja, existem n terminais de entrada x_1, x_2, \dots, x_n e apenas um terminal de saída γ que assume um valor igual à 1 ou igual à 0; w_i é o peso associado à entrada x_i e θ é o limiar do neurônio.

A partir do modelo MCP, outros modelos surgiram, apresentando diferentes saídas, diferentes funções de ativação e diferentes arquiteturas.

A TCDs, formalizada por Zadeh (1965), apresenta como objetivo a formalização de um raciocínio aproximado, o qual é utilizado na representação e manipulação de dados, que apresentam informações definidas sem exatidão e de forma não clara, como por exemplo a manipulação de números difusos: acerca de 1500, próximo de 300, menor do que 20, etc.. A TCDs procura, de maneira aproximada, raciocinar de acordo com o raciocínio humano.

L.A. Zadeh e R. Bellman, após pesquisa no Laboratório da IBM, verificaram a necessidade de criar uma teoria que trabalhasse com incerteza e imprecisão em sistemas dinâmicos. A TCDs distingue-se da Teoria Clássica dos Conjuntos por permitir a utilização de um intervalo de valores de pertinência entre os limites 0 e 1, e não apenas estes, como no caso binário, onde são aceitos apenas 0 e 1. Através dos CDs pode-se trabalhar com todos os valores do intervalo entre $[0,1]$, a qual utiliza valores contínuos e não discretos na representação da incerteza, então torna-se necessária uma representação de conjuntos descritos por suas funções de pertinência.

Um CD é formado por um ou mais conjuntos identificados pelos seus respectivos valores lingüísticos, como por exemplo, o “CD Mordeu a Língua”, possui os valores lingüísticos (às_vezes, freqüentemente e sempre), o qual é definido através do seu grau de pertinência no intervalo real entre $[0,1]$. Como exemplo tem-se: o CD Mordeu a Língua poderá apresentar um valor lingüístico = “às_vezes” com um grau de pertinência igual à 0,2 e um valor lingüístico = “frequentemente”, porém com um grau de pertinência igual à 0,6. Este exemplo mostra que pode não existir um valor exato, mas um intervalo de valores de graus de pertinência associados a cada CD.

Enquanto os Sistemas Difusos (SDs) trabalham com mecanismos de inferência que manuseiam a imprecisão das informações, as RNAs trabalham com aprendizagem, sistemas de tolerância à falhas, paralelismo e generalização. Um Sistema Híbrido extrai as propriedades existentes nos dois sistemas, o qual é conhecido como SND. Existem vários métodos que utilizam diferentes técnicas de inferência, Rezende et al. (2003) enfatiza que o foco das pesquisas tem sido combinar técnicas baseadas em dados (RNAs) com técnicas que utilizam conhecimento (TCDs) na implementação de SNDs.

De acordo com Gorzalczany (2002), quando se implementa um SND, uma rede neural é inserida na modelagem do SD, enquanto na implementação de um Sistema Difuso-Neural (SDN) inicialmente é utilizada a TCDs, como uma ferramenta inserida na rede neural, ou seja, é a própria “fuzzificação” da arquitetura da rede neural convencional.

Um SND apresenta como objetivo fornecer uma modelagem difusa como uma ferramenta de refinamento de seus parâmetros e estruturas sem, contudo, alterar sua estrutura funcional. Os processos de “fuzzificação/defuzzificação”, mecanismo de inferência e bases de regras difusas também podem fazer parte de um SND. Métodos de RNAs, neste modelo, são utilizados no processamento dos CDs, por exemplo, podem trabalhar na extração das funções de pertinência e/ou das regras difusas, transformando uma informação quantitativa em uma informação qualitativa.

Na abordagem que envolve os SDNs, são preservadas as propriedades básicas das arquiteturas presentes nas RNAs. A idéia da utilização dos CDs é possibilitar um aperfeiçoamento no desempenho da RNA. São introduzidos conceitos de neurônios difusos e regras de aprendizagem para alterar o coeficiente de aprendizagem. Outras aplicações envolvendo a TCDs e RNAs são encontradas em (FULLÉR, 2002).

As primeiras arquiteturas de SNDs, encontradas na literatura, citam os trabalhos de (JANG, 1993) no desenvolvimento do primeiro SND para aproximação de função baseada em regras através do sistema ANFIS (*Adaptative Network based Fuzzy Inference Systems*); o sistema NEFCLASS (*Neuro-Fuzzy Classification*) e NEFPROX (*Neuro-Fuzzy Approximation*) (NAUCK e KRUSE, 1997). A autora Brasil (1999) propõe um SE híbrido, com capacidade de aprender a extrair conhecimento a partir de uma base de conhecimento inicial e um conjunto de exemplos; Gupta e Rao (1994) descrevem uma arquitetura neural difusa baseada nos operadores *t-normas* e *t-conormas*. Na literatura, são encontrados vários trabalhos descrevendo algoritmos de aprendizagem envolvendo os SNDs. Uma descrição atualizada envolvendo este tema está referenciado no trabalho de Carvalho (2004).

3 Modelo proposto

O objetivo principal desta pesquisa é analisar o desempenho de SNDs, por meio da aplicação de diferentes modelos de aprendizagem na tentativa de diagnosticar com mais precisão os EEs e os ENEs. O modelo proposto está relacionado com a utilização das operações aritméticas difusas *t-normas* (Produto Algébrico e Produto de Hamacher); *t-conormas* (Soma Algébrica e soma de Hamacher) (KLIR e YUAN, 1995) e as operações *Softmin* e *Softmax* (BERENJI e KHEDKAR, 1992) baseados no algoritmo de retropropagação² modificado conforme mostra a Figura 2, composta por cinco camadas.

Após uma análise nas principais características que envolvem os Eventos Paroxísticos, realizada em conjunto com o médico neurologista e consulta bibliográfica, foram definidos quatorze valores qualitativos de entrada. Para diferenciar um ENE, são utilizadas as seguintes expressões lingüísticas: quadros clássicos de conversão; distúrbios da sensibilidade; contraturas; alucinações e; ou delírios; quadros somatoformes; sintomas dos nervos.

²Foram escolhidas as operações *Softmin* e *Softmax* em razão da não derivabilidade das funções *Min/Max*.

Na diferenciação dos EEs são utilizadas as expressões lingüísticas: sinais e sintomas parciais; viu alguma coisa; ouviu alguma coisa; mordeu a língua, tempo de duração da crise; sonolência após; paralisia após e vômito. Estas variáveis integrarão a primeira camada do modelo proposto, as quais serão descritas a seguir.

Camada 1: representa os quatorze neurônios de entrada. Cada nodo, desta camada, representa um valor qualitativo ou quantitativo de entrada da rede. É a camada que recebe os dados a partir do ambiente externo, responsável pela definição dos comandos lingüísticos, através dos seus respectivos universos de discurso;

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

Camada 3: cada nodo, na Camada 3, representa a parte **SE** das regras difusas. A parte **SE** do antecedente da regra é composta pela união das variáveis lingüísticas de entrada, cada uma associada a um valor lingüístico (*grau de pertinência*). Nesta camada, são utilizadas as operações Produto Algébrico, Produto de Hamacher e a operação *Softmin* na composição do valor final das regras, representados a baixo, respectivamente:

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

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

$$\text{Camada}_3 = \text{softmin}_k(x_1, x_2, \dots, x_n) = \sum_{i=1}^n x_i e^{-kx_i} / \sum_{i=1}^n e^{-kx_i}$$

Nas quais:

x e y representam as entradas do nodo i ;

A, i representa as variáveis lingüísticas associadas com o nodo;

k é uma variável incrementada ao infinito.

Camada 4: Cada nodo, na Camada 4, representa a parte **ENTÃO** das regras difusas. Esta operação é utilizada para integrar as regras difusas que possuem o mesmo conseqüente, utilizando as operações Soma Algébrica, Soma de Hamacher e a operação *Softmax*, representados a baixo, respectivamente:

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

$$\text{Camada}_4 = [\mu_{A,i}(x) + \mu_{B,i}(y)] - [2\mu_{A,i}(x) * \mu_{B,i}(y) / 1 - \mu_{A,i}(x) * \mu_{B,i}(y)]$$

$$\text{Camada}_4 = \text{softmax}_k(x_1, x_2, \dots, x_n) = \sum_{i=1}^n x_i e^{kx_i} / \sum_{i=1}^n e^{kx_i}$$

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

O valor quantitativo utilizado faz referência à frequência da crise, ou seja, o número de crises que o paciente apresenta em um determinado mês. Este valor é utilizado como parâmetro principal na definição do percentual, utilizado para fazer a “fuzzificação” das variáveis qualitativas.

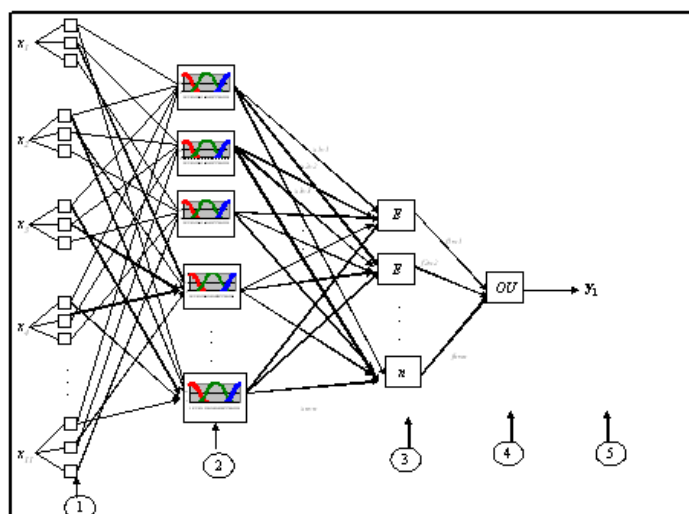


Figura 2 - Modelo do SND proposto

4 Resultados

Até o momento, foram realizadas simulações utilizando as diferentes operações aritméticas³. Para efeitos de simulação, em relação à implementação das diferentes operações aritméticas propostas nesta pesquisa, foram realizadas quatro simulações divididas em dois grupos para cada Tipo de Evento, ou seja, ENE e EE: (1) a primeira simulação envolve a inferência a partir de duas regras difusas na demonstração do Tipo de Evento = ENE e a (2) envolve a inferência a partir de três regras difusas na demonstração do Tipo de Evento = EE.

Para fins de comparação com os resultados alcançados, o especialista de domínio informou os graus de certeza, obtidos a partir das regras que fazem referência aos tipos de sintomas apresentados pelos pacientes, ou seja, **SE** o paciente apresentar um determinado sintoma, **ENTÃO** ele apresenta um EE ou um ENE com um determinado grau de certeza. Em contrapartida o sistema implementado obteve, pelas operações aritméticas *Min/Max*, Soma e Produto Algébrico e Soma e Produto de Hamacher os graus de pertinência obtidos a partir das simulações realizadas nas regras difusas.

No primeiro conjunto de simulações, composto de duas regras, o especialista concluiu que seria um ENE com um grau de certeza de 80% e 75%, respectivamente. Estes resultados podem ser visualizados na Figura 3.

³Não foi implementado o SND proposto, apenas foram testadas as diferentes operações aritméticas a partir das regras difusas.




Figura 3 -Primeira Simulação do Modelo de Regras Difusas

A partir destas simulações podem-se observar os seguintes resultados:

1. a operação aritmética Produto/Soma de Hamacher se aproxima mais da visão do especialista de domínio;
2. a operação aritmética Produto/Soma Algébrica apresenta uma pequena diferença em relação ao especialista;
3. a operação aritmética *Min/Max* se distancia a partir da visão do especialista.

A seguir, é descrito o resultado da simulação realizada a partir do segundo conjunto de simulações, composto por três regras difusas. Neste segundo conjunto de regras, o especialista concluiu que seria um EE com um grau de certeza de 90% e 95%, respectivamente conforme mostra a Figura 4.

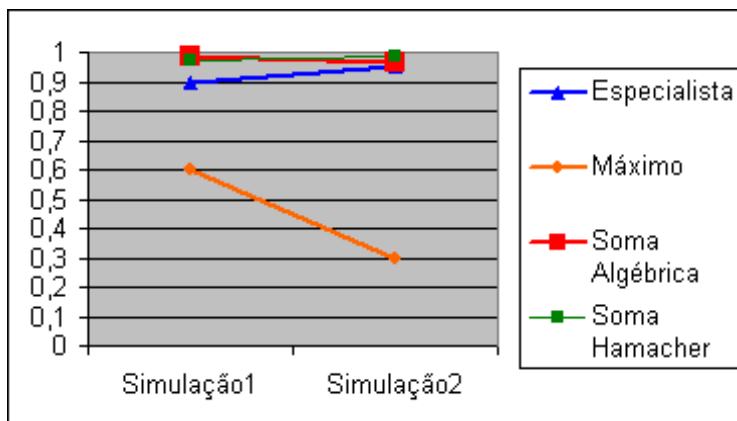


Figura 4 - Segunda Simulação do Modelo de Regras Difusas

A partir destas simulações, pode-se observar que a operação aritmética Produto/Soma Algébrica e Produto/Soma de Hamacher se aproximam mais da visão do especialista de domínio, enquanto que o resultado da operação aritmética *Min/Max* se distanciam a partir da visão do especialista.

5 Conclusões

A utilização de operações aritméticas na composição das regras difusas constitui a base da TCDs. As taxas de acertos de um sistema estão relacionadas com a aplicação adequada das regras difusas. Uma das operações aritméticas mais utilizadas e descritas na literatura científica, ao se projetar um SND, é a operação padrão *Min/Max*. No entanto, após uma validação e análise aplicadas em 04 (quatro) simulações, envolvendo modelos de aprendizagem e, utilizando diferentes operações aritméticas, verificou-se que as operações aritméticas *Min/Max*, nas quatro simulações, distanciaram-se a partir da visão do especialista de domínio. Utilizando outras operações aritméticas, concluiu-se, a partir do resultado das simulações, que as operações Produto/Soma Algébrica e Produto/Soma de Hamacher apresentaram um valor final mais próximo em relação ao valor fornecido pelo especialista de domínio. Portanto, o desenvolvimento de um SND, baseado na utilização destas operações aritméticas, justifica-se, dada a importância que envolve a manipulação de diferentes operações na base de regras difusas, levando a uma maior ou menor taxa de acertos do sistema.

Pretende-se aumentar a base de treinamento dos pacientes cadastrados, na tentativa de obter um número mais expressivo de situações que ocorrem na prática médica, possibilitando dessa forma, que o sistema implementado, seja o mais próximo da realidade.

Referências

- APPEL, E. *Uma Proposta de Modelagem de Conhecimentos sobre Glaucoma por um Sistema Híbrido Neuro-Fuzzy*. Porto Alegre. Tese (Doutorado), Universidade Federal do Rio Grande do Sul UFRGS/RS, 2004.
- 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, nov., p. 209-219, 2003.
- AZEVEDO, F. M.de. *Contribution to the Study of Neural Networks in Dynamical Expert System*. Bélgica. Tese (Doutorado) Institut d 'Informatique - Namur, 1993.
- AZEVEDO, F. M.de; BRASIL, L. M.; OLIVEIRA, R. C. L. de. *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*. Florianópolis: Bookstore, 2000.

- BATTISTELLA, E. *Extração de Regras de Redes Neurais Artificiais Aplicadas ao Problema da Previsão da Estrutura Secundária de Proteínas*. Dissertação (Mestrado em Computação Aplicada), Universidade do Vale do Rio dos Sinos - UNISINOS, São Leopoldo-RS. 2004.
- BERENJI H. R.; KHEDKAR, P. Learning and Tuning fuzzy logic controllers through reinforcements. *IEEE Transaction Neural Networks*, v. 3, n. 5, p. 724-740, 1992.
- BRASIL, L. M. *Proposta de Arquitetura para Sistema Especialista Híbrido e a Correspondente Metodologia de Aquisição do Conhecimento*. Tese (Doutorado em Engenharia Elétrica). Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina - UFSC, Florianópolis-SC. 1999.
- BRANCO, A. C. S. & EVSUKOFF, A. G. Sistema Neuro Fuzzy de Monitoramento e Diagnóstico de Falhas em Reatores Nucleares. Em REZENDE et al., *Sistemas Inteligentes Fundamentos e Aplicações, Parte II - Aplicações de Sistemas Inteligentes nos Setores Produtivos*, 2003.
- BUCKLEY, J. J. *An Introduction to Fuzzy Logic and Fuzzy Sets*. Advances in Soft Computing. USA: Physica-Verlag, 2002.
- CARVALHO, L. F. de. *Sistema Neuro-Difuso: Modelos de Aprendizagem*. Exame de Qualificação apresentado no Programa de Pós-Graduação em Engenharia Elétrica (Doutorado), Universidade Federal de Santa Catarina - UFSC, Março, 2004.
- COMMISSION On Classification and Terminology of the International League Against Epilepsy. Proposal for revised clinical and electroencephalographic classification of epileptic seizures. *Epilepsia*. v. 22, p. 489 - 501, 1981.
- FERNANDES, J. G. *Epidemiologia das crises epilépticas em Porto Alegre. Um estudo populacional*. Tese (Doutorado em Medicina), Universidade Federal do Rio Grande do Sul -UFRGS, Porto Alegre-RS.1993.
- FREUD, S. *Histeria: primeiros artigos*. Tradução de José Luís Meurer, Rio de Janeiro: Ed. Imago,1998.
- FULLÉR, R, R. *Introduction to Neuro-Fuzzy Systems*. New York, USA: Physica-Verlag, 2000.
- GATES, J. R. Classification and differential diagnosis. In: *Non Epileptic Events, Pseudoseizures*. New York: Syllabus of the American of Neurology, 1993.
- GIARRATANO, J. *Experts Systems Principles and Programing.*. Boston: PWS-KENT Publishing Company, 1989.
- 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, 1983.
- GUPTA, M. M.; RAO, D. H. On the Principles of Fuzzy Neural Networks. *Fuzzy Sets and Systems*, v. 61, p. 1-18, Elsevier Science, 1994.
- HAYKIN, S. *Redes Neurais: Princípios e Prática*. 2. ed. Porto Alegre:Bookman, 2001.
- IBRAHIM, A. M. *Fuzzy Logic for Embedded Systems Applications*. USA:Elsevier Science, 2004.
- JANG, J. -S. R. Adaptative-network-based fuzzy inference systems. *IEEE Transactions on Systems, Man and Cybernetics*, v. 23, n. 3, p. 665-658, 1993.
- KLIR, G.; YUAN, B. *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. USA: Prentice, May, 1995.
- MAMDANI, E. H. Application of fuzzy algorithm for control of simple dynamic plant. *IEEE Control and Science*, v. 121, n. 12, p. 1585-1588, 1974.
- McCULLOCH, W. S.; PITTS, W. H. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, v. 5, n. 1, p. 115-133, 1943.
- MIN, L. S. *Sistema Baseado em Conhecimentos para Detecção e Classificação de Crises Epilépticas*. Dissertação Mestrado em Medicina Interna. Florianópolis: UFSC, 1994.
- NAUCK, D.; KRUSE, R. A Neuro-Fuzzy method to learn fuzzy classification rules from data. *Fuzzy Sets and Systems*, v. 89, p. 277-288, 1997.
- RAITTZ, R. T. FAN 2002: *Um Modelo Neuro-Fuzzy para Reconhecimento de Padrões*. Tese (Doutorado), Universidade Federal de Santa Catarina -UFSC, Florianópolis. 2002.
- RAPOSO, R. de C. T. *Uma Ferramenta para Análise Fundamentalista de Investimentos em Empresas Utilizando Sistemas Neuro-Nebulosos*. Dissertação (Mestrado), Universidade Federal do Rio de Janeiro - UFRJ/RJ, Rio de Janeiro, 2001.
- REZENDE, S. O.; EVSUKOKK, A. G.; GARCIA, A. C. B. et al. *Sistemas Inteligentes -Fundamentos e Aplicações*. São Paulo : Editora Manole, 2003.
- VELLASCO, M. M. B. R.; PACHECO, M. A. C.; NETO, L. S. R.; SOUZA, F. J.; Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model.*International Journal of Electrical Power & Energy Systems*. Published by Elsevier Science Ltda, v. 26, n. 2, p. 131-142, 2004.
- VELLIDO, A.; CERQUIDES, J. Neural Networks For B2C E-Commerce Analysis: some elements of best practice. In: *Proceedings of Fourth International Conference on Enterprise Information Systems*, April, Ciudad Real, Spain, p. 439-445, 2002.

- VIANNA, G. K. *Sistemas Inteligentes de Arquitetura Híbrida Neuro-Difusa para Reconhecimento de Padrões*. Dissertação (Mestrado), Universidade Federal do Rio de Janeiro - UFRJ, Rio de Janeiro-RJ. 2000.
- WAGNER, A. *Extração do Conhecimento a partir de Redes Neurais aplicada ao Problema da Cinemática Inversa na Robótica*. Dissertação (Mestrado em Computação Aplicada), Universidade do Vale do Rio dos Sinos - UNISINOS, São Leopoldo- RS, 2003.
- WHO, *The CID-10 Classification of Mental and Behavioural Disorders: clinical descriptions and diagnostic guidelines*. Geneve: Division of Mental Health, 1993.
- ZADEH, L. Information and Control. *Fuzzy Sets*. v. 8, p.338 - 353, 1965.