

ANTECIPANDO O FUTURO EM TECNOLOGIA DA INFORMAÇÃO COM INTELIGÊNCIA ARTIFICIAL E WEB SEMÂNTICA

*Arildo Dirceu Cordeiro*¹

*Rogério Cid Bastos*²

RESUMO

Este artigo apresenta uma ferramenta que permite ao usuário gerar sistemas inteligentes. Inicialmente é mostrado um sistema Multi-Agentes denominado “SMAGS”, com capacidade de integrar sistemas informatizados diferentes e gerenciar, em tempo real, as informações inerentes ao projeto de interesse, podendo atuar também como um “Gerente Virtual”. Na seqüência, são incorporadas novas técnicas de Inteligência Artificial (IA), com interpretação semântica e testes métricos de Ontologias, com o objetivo de fornecer ao usuário uma ferramenta CASE (Computer Aided Software Engineering) com capacidade de gerar sistemas de informações informatizados inteligentes que podem aprender a partir de informações oriundas de buscas inteligentes em servidores de Ontologias, banco de casos, especialistas na área e mesmo dados fragmentados na Internet.

Palavras-chave: Redes Neuro-Fuzzy, Mineração de Dados e Textos, Web Semântica, Ontologias, Agentes Inteligentes e UNL(Universal Networking Language).

ABSTRACT

This article presents a tool which allows the user to generate intelligent systems. Initially a Multi-Agent system named “SMAGS” is shown, which is able to integrate different information systems and to manage, in real time, the inherent

¹. Professor do Centro Federal de Educação Tecnológica do Paraná, mestre em Engenharia da Produção com ênfase em Mídia e Conhecimento/Inteligência Artificial/Tecnologia da Informação pela Universidade Federal de Santa Catarina e doutor na mesma área, e-mails: arildodc@brturbo.com e arildo@cefetpr.br.

² É Doutor em Engenharia da Produção pela UFSC; professor do Programa de Pós-Graduação em Engenharia da Produção da UFSC. e-mail: rogerio@inf.ufsc.br.

information for the target project, while it is also able to act as a “Virtual Manager”. Following this, new techniques of Artificial Intelligence (AI) are introduced, with semantic interpretation and Ontology metric tests, with the aim of supplying a CASE tool (Computer Aided Software Engineering) with the capacity to generate computerised intelligent information systems which are able to learn from information out of from intelligent searches of Ontology servers, cases databank, specialists in the area and even from fragmented data on the Internet.

Keywords: Neural/Fuzzy Networks, Data and Text Mining, Semantic Web, Ontologies, Intelligent Agents, UNL (Universal Networking Language).

I. INTRODUÇÃO

Decisões gerenciais inteligentes de assuntos complexos necessitam de informações organizadas em tempo real, para evitar perda de tempo na busca de dados, cerca de 80%, para subsidiar as tomadas de decisões[2]. O trabalho desenvolvido em [17], propõe uma solução para o problema através de um sistema multiagentes que executa automaticamente, de forma inteligente e autônoma inúmeras tarefas de caráter genérico. O modelo de [17] é capaz de reconhecer comandos de voz, extrair dados de bancos de dados genéricos, executar programas e extrair dados a distância, em qualquer das estações sob seu monitoramento em uma intranet e/ou Internet. Entretanto, estes sistemas não são capazes de identificar relações lógicas derivadas do processo de raciocínio humano. A incorporação de conceitos derivados de Web Semântica e Ontologias, bem como o uso de ferramentas como redes *neuro-fuzzy*, mineração de dados e textos e UNL, ampliam os recursos no modelo proposto [17].

Os padrões de entrada são expandidos em uma vizinhança difusa, de forma que cada conjunto suporte dessa vizinhança é a combinação dos valores das características próximos dos originais. Assim, dados localizados nessa região de vizinhança se transformam em informações relevantes a partir de Ontologias pré-definidas.

As Ontologias a serem avaliadas devem ser adicionadas sucessivamente para comparação, e um mecanismo de teste métrico é acionado. A valoração obtida é armazenada para uso em futuras avaliações. Como resultado é possível criar uma Ontologia de acordo com os conhecimentos adquiridos sobre um determinado assunto, que pode ser por exemplo: uma disciplina ou um conjunto de disciplinas de um determinado curso, cujos conhecimentos são avaliados metricamente em relação a uma Ontológica de domínio de uma área específica.

Este documento está estruturado da seguinte forma: na seção II é

apresentado um resumo da literatura, destacando a Web Semântica, as Ontologias, as *Redes Neuro-Fuzzy* e a UNL, sem apresentar as demais técnicas de IA utilizadas, por serem conhecidas do público interessado. Na seção III são apresentados os conceitos, a estrutura e a arquitetura do SMAGS. Na seção IV estão os conceitos, a estrutura e a arquitetura do GISAAGIC, na seção V, um exemplo de aplicação e na seção VI, as conclusões.

II. RESUMO DA LITERATURA

A. Web Semântica

Semântica é o estudo do significado das palavras, estudo das mudanças que, no espaço e no tempo, sofre o significado das palavras. Entretanto, em sistemas que permitem o acesso à informação, o termo se torna mais amplo. O objetivo da web semântica é estruturar o conteúdo que está “solto” na internet, criando um ambiente no qual *agentes* poderão perambular de página em página para executar tarefas de interesse para seus usuários. Esses agentes serão capazes de identificar não apenas o exato significado de uma palavra, como também as relações lógicas entre várias palavras. A questão que se coloca é a do entendimento de conteúdo. Para isso é necessário ler dados estruturados que são informações colocadas em campos fixos de um arquivo, além de ter acesso a conjunto de regras que ajudem a conduzir seus raciocínios. Neste sentido as páginas web terão que ser escritas em uma nova linguagem de forma que possam ser compreendidas por diferentes sistemas.

Como os padrões ainda não estão definidos, algumas tecnologias ganham espaço. Entre elas o XML (eXtensible Markup Language) em [16], que permite que os usuários criem *tags* que são marcações de dados inseridos em arquivos e que podem com esta tecnologia serem personalizados. Outra tecnologia é o RDF (Resource Description Framework) em [16], que forma trios de informações que expressam o significado das tags do XML. Sendo que cada unidade do trio tem sua própria função, como sujeito, verbo e objeto de uma frase, recebendo uma identificação URI (Universal Resource Identifier) em [16], que foi a tecnologia usada para criar as conhecidas URLs (Uniform Resource Locator). Com tudo isso, parece ser muita complicação; acontece que na linguagem humana uma palavra pode assumir vários significados, causando grandes confusões nos sistemas. A solução é usar uma URI diferente para cada conceito. Nesta fase chega-se ao maior desafio da web semântica porque pode acontecer de dois bancos de dados usarem URIs diferentes para um mesmo conceito e neste caso é necessário que o software que vai pesquisar saiba quando está tratando da mesma coisa. Uma proposta para este problema é o uso de *Ontologias* que permitem definir relações entre conceitos de diferentes sistemas e vão fornecer o vocabulário necessário para a comunicação entre os agentes e as páginas, bem como mostrar as relações entre os

conceitos. A arquitetura da Web Semântica proposta está ilustrada na figura 1.

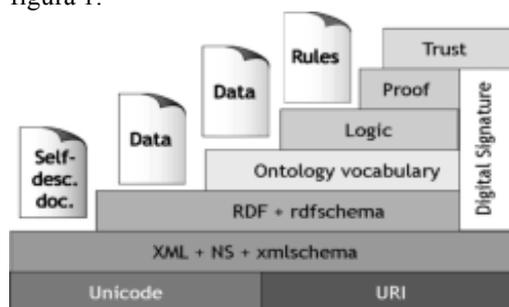


Figura 1 – Arquitetura da Web Semântica proposta pelo W3C

Fonte: disponível em: <http://www.w3.org/>

B. Ontologias

Em filosofia, o termo Ontologia se define como “a parte da metafísica que trata do ser em geral e suas propriedades transcendentais” [20]. Em Inteligência Artificial, ele tem diferentes conotações. SWARTOUT, BERNARA e outros, em [20], definem Ontologia como “uma especificação explícita e formal

sobre uma conceitualização consensuada”. A interpretação desta definição, segundo o autor, é que as Ontologias definem seus conceitos, propriedades, relações, funções, restrições e axiomas de forma “explícita” em alguma linguagem de implementação capaz de conter este conhecimento. Sendo que o termo “conceitualização” se refere a um modelo abstrato de algum fenômeno no mundo. As Ontologias são estabelecidas para serem usadas de forma consensuada e compartilhada por diferentes sistemas. O termo “formal” se refere ao fato de que a Ontologia deve ser implementada em alguma linguagem computável pela máquina. Uma Ontologia pode ser definida como “um conjunto de termos estruturados hierarquicamente que descrevem um domínio”. As Ontologias proporcionam a estrutura taxionômica de um domínio, a qual será especializada com os conhecimentos específicos necessários para a aplicação.

Atualmente, muito tempo é perdido na busca de dados, informações e/ou Ontologias disponíveis para utilizar em sua aplicação e, ainda, não se tem a certeza de que a informação serve para o seu projeto e se não esta ultrapassada, de forma que o usuário acaba tomando uma decisão com base na experiência [2], não sendo possível justificar a sua escolha. O trabalho de [20] propõe um método que permite ao usuário determinar a idoneidade de Ontologias existentes com respeito as necessidades de seu projeto, motivo pelo qual seus princípios serão utilizados no presente trabalho.

C. Redes Neuro-Fuzzy

Uma Rede *Neural Artificial* (RNA) é uma estrutura que processa informação de forma paralela e distribuída, procurando se assemelhar à estrutura dos neurônios humanos.

A comunicação e aprendizagem em um sentido amplo envolve, entre outras coisas, relações humanas e como tal: “*As relações humanas são, em sua gênese, relações difusas*” BASTOS (1994) [18]. Partindo deste princípio, para que seja possível melhorar, aperfeiçoar, agilizar, modernizar e automatizar sistemas de comunicações utilizando as novas tecnologias da informação, é necessário trabalhar também com técnicas que sejam capaz de entender a lógica do raciocínio humano e para isto é necessário trabalhar com incertezas, grau de pertinência e inferências.

Os conjuntos *Fuzzy* são utilizados para representar conceitos vagos, imprecisos ou incertos [1]. Os sistemas Fuzzy podem ser usados como sistemas de apoio a tomada de decisões, podem representar o conhecimento de especialistas sobre um determinado assunto e interpolar decisões a partir de entradas contaminadas com incertezas. Os sistemas Fuzzy permitem a representação de algumas características do raciocínio humano e podem ser usados para o desenvolvimento de sistemas de bases de conhecimento.

Considerando as características destes dois importantes paradigmas, [1], [19] e outros têm procurado unir os potenciais de sistemas Fuzzy e Redes Neurais, resultando os chamados sistemas *Neuro-Fuzzy*. Sendo que estes sistemas podem incorporar conhecimentos empíricos e ter seus parâmetros adaptados através de algoritmos eficientes.

III. “SMAGS”

O SMAGS ou Sistema Multi-Agentes para Gestão de Sistemas é um software dotado de recursos para gerenciar, de forma autônoma, serviços especiais normalmente desenvolvidos por seres humanos, tais como: análise, pesquisa e classificação de informações, em um ambiente informatizado. O SMAGS atuará sobre o meio através da execução de aplicações especializadas, modificação automática de bancos de dados, geração de consultas, gráficos e relatórios, bem como a comunicação de mensagens visuais ou sonoras, refletindo as percepções e ações sobre o sistema gerenciado. A figura 2 mostra a arquitetura do SMAGS.

Os módulos desempenham as seguintes funções:

- A. Aplicações Específicas – As aplicações específicas funcionam na rede, no ambiente gerenciado, consultando e modificando os dados de bancos de

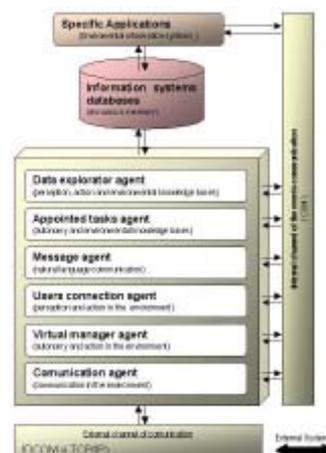


Figura 2 – Arquitetura do “SMAGS”

dados, bem como realizando operações não dedicadas a bancos de dados.

- B. Agente Explorador de Dados – É a aplicação de comunicação com bancos de dados, responsável pela extração, modificação e comunicação de informações dos bancos de dados.
- C. Agente de Tarefas Agendadas – É o agente especialista responsável por organizar a agenda de eventos, bem como realizar eventos de acordo com a prévia programação. Este subsistema poderá operar em uma única estação, em geral no servidor, ou em várias estações do sistema gerenciado.
- D. Agente de Mensagens – É o agente especialista responsável por elaborar, armazenar, classificar e entregar mensagens de usuários na rede. Este subsistema é análogo a um cliente, integrado a um servidor de e-mail da internet. Porém, este subsistema deverá realizar funções adicionais especializadas, para operar em cooperação com o SMAGS, devendo atuar em todas as estações do ambiente gerenciado.
- E. Agente de Conexão de Usuários – É o agente especialista responsável por ativar e monitorar as conexões de usuários na rede.
- F. Agente Gerente de Aplicações – Este é o agente principal do sistema, responsável por integrar as aplicações e outros agentes que fazem parte do sistema. Este agente pode ser aperfeiçoado em nível de “inteligência”. Ele é constituído de uma base de conhecimento, que por sua vez foi montada através de regras lógicas e um dispositivo de inferência, que analisará as regras, de modo a reagir automaticamente aos eventos que estiverem trafegando no sistema.
- G. Agente de Comunicação – É o agente especialista responsável por converter e entregar eventos entre aplicações e outros agentes na rede. Este subsistema funciona em segundo plano, de modo autônomo e transparente, em todos os pontos do ambiente gerenciado, embora, apenas um destes pontos seja configurado como servidor de comunicação. Todos os pontos podem receber eventos locais e propagá-los para que o servidor os entregue ao destinatário.

IV. Gerador de Sistemas “GISAAGIC”

O GISAAGIC (Gerador Inteligente de Sistemas com Auto-Aprendizagem para Gestão de Informações e Conhecimento), proposto, é uma ferramenta CASE que integra outras ferramentas e incorpora várias técnicas de IA e WS, tornando-a capaz de gerar sistemas inteligentes. Esta ferramenta especialista possui uma modelagem orientada a objetos com conceitos de Web Semântica, Ontologias e UML – Unified Modeling Language. A UML possui elementos de expansão que permite acomodar novos sistemas e novos

elementos na modelagem, permitindo no caso em foco, a construção de uma ferramenta que integra várias técnicas de Inteligência Artificial (IA), cuja arquitetura está representada na figura 3.

O GISAAGIC utiliza uma modelagem orientada a objetos e *code template*. As aplicações geradas incorporam metodologias do GEDI e o núcleo extrator de informações utilizam os modelos de Redes *Neuro-Fuzzy* ANFIS (Adaptive-Network-Based Fuzzy Inferência System) [14] e *Neuro-Fuzzy* FAN (Free Associative Neurons) [19], por apresentarem performance positiva em regras de inferência, controles e aprendizado. Importantes dados localizados em uma vizinhança difusa são aproveitados, além da clareza na representação dos padrões. Essas redes extraem informações importantes para a tomada de decisões, de forma autônoma (em relação a eventos no ambiente) ou através de um estímulo verbal que é dado pelo usuário através de uma linha de busca.

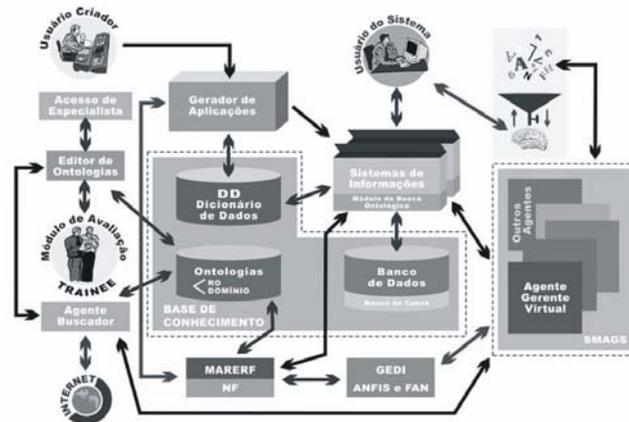


Figura 3 – Arquitetura do “GISAAGIC”

As ferramentas estão sendo implementadas na filosofia multiplataforma, podendo operar com diversos bancos de dados e sistemas operacionais, Oracle, Sql Server, Interbase, Ms-Access e outros, nos sistemas Windows e Linux.

O buscador GEDI, integrado ao SMAGS e ao Sistema de Informações como um todo, pode efetuar buscas parametrizadas, cujos dados poderão ser reutilizados. Um agente inteligente está envolvido diretamente na obtenção de listas de documentos que atendam certas palavras ou frases-chave, estes documentos podem vir também de engenhos de buscas na WEB, como Google, Alta Vista e outros.

O buscador inteligente poderá trazer, além das páginas escritas em HTML, documentos em formato PDF, DOC, PPT, entre outros, utilizando conversores.

Os dados brutos são refinados, utilizando conceitos de *Data e Text Mining*, para que fiquem apenas os dados pertinentes ao assunto de interesse

Os links das páginas HTML também são explorados e valorados de acordo com a frequência de busca (Link Frequency, ou LF). De forma que, se considerar dentro de um documento HTML, o parâmetro HREF da tag A, bem como no código JavaScript, o uso do parâmetro URL da função windows.open, podem fornecer links para serem utilizados pelo buscador.

As palavras não relevantes *stopwords* são extraídas do texto, de acordo com uma valoração prévia de especialistas.

Após a limpeza e extração de *stopwords*, calcula-se a Frequência de Termos (*term frequency* ou TF), conforme [1], no sentido de que os termos que aparecem poucas vezes não são significativos. Calcula-se também a Frequência Inversa de Termos (IDF) que fornece um parâmetro a mais para classificar documentos, agora no sentido de que os termos que aparecem poucas vezes em um documento (em relação a um conjunto de documentos) são significativos para a classificação em um vetor de documentos que irá, posteriormente, servir de conjunto de treinamento para uma rede *Neuro-Fuzzy*.

O passo seguinte consiste na elaboração do *vocabulário*. Dentro do conjunto de documentos, os termos que se repetem nos documentos são destacados e considerados para a montagem do vocabulário. Um vocabulário pode ser extenso, de maneira que alguns tipos de *podas* de termos são necessárias para se reduzir o espaço de representação dos documentos para a entrada da rede *Neuro-Fuzzy*. Os *vocabulários* são comparados com a Ontologia de domínio do problema considerado para o sistema gerado, com a finalidade de agregar conhecimento.

Os métodos denominados tradicionais TF e IDF em [8], [11], [13], [15], são usados de forma conjunta com uma representação de Ontologia UNL e trazem aspectos significativos para as buscas. Uma Ontologia em RDF, DAML+OIL, ou mesmo em UNL, que represente um domínio da busca, agregará mais informação ao processo, além de refinar a busca. Neste caso, trata-se da combinação das técnicas tradicionais e da Ontologia com a técnica de LF. A contagem e valoração relativa dos conceitos de acordo com seus links será então multiplicada pelo parâmetro TFIDF e também pelo parâmetro LF, de forma a obtermos um indicador para os termos considerados no vocabulário que servirão para a entrada da rede no processo de treinamento. O escore para o vetor de representação é obtido a partir da multiplicação direta da frequência inversa IDF, denominado TFIDF.

Após o uso dos métodos tradicionais, faz-se a verificação de cada documento com relação à Ontologia do domínio de interesse. Assim, a partir de uma Ontologia definida, faz-se a valoração dos termos presentes na mesma. Esta valoração irá ponderar os termos comuns no documento, aproximando um determinado documento do seu domínio conforme mais próximo ele esteja da Ontologia.

No processo, para cada termo presente em um documento, é verificada a sua existência na Ontologia. Caso esteja presente, o peso respectivo é acumulado no “fator de ganho semântico” do documento. Se não estiver presente, este fator de ganho semântico será penalizado por um fator constante.

Em [13] é indicado um método para valorar relações entre termos de um documento UNL. Como em UNL tem-se uma variedade de relações que pode existir para as “universal words”, desde que se considere um documento UNL como sendo uma Ontologia, cada relação pode vir a aumentar ou não ter efeito na valoração de um conceito dentro da Ontologia.

Finalmente, o fator de ganho semântico é multiplicado para cada escore obtido pelo termo do documento na composição da TF mais a IDF (ou mais considerando a LF) e, assim, obtém-se o vetor do documento que o irá representar na coleção.

Uma forma de fazer a medição de “o quanto bom” (*goodness*) é o vetor (ou a qualidade do mesmo), utiliza-se o método da informação mútua indicado em [13], [15], que se baseia na teoria da informação. O valor da informação mútua entre considerar o conteúdo total de um documento e, num passo seguinte, um vetor do documento que o represente, fornece o ganho de informação, sendo este ganho maior quanto mais representativo for tal vetor.

V. UM EXEMPLO

Considere a Ontologia descrita na figura 4. Ela se refere ao conjunto de termos relacionados com as palavras “infecção hospitalar”. Os conceitos desta Ontologia são representados pelos termos, e os links são as relações entre tais conceitos.

Para valorar os termos presentes nesta Ontologia, tomam-se os *links* que conectam cada conceito e executa-se o somatório, fazendo este total pertencer ao conceito.

De forma hierárquica, o processo acontece indo dos nós mais externos à Ontologia, até chegar no conceito principal. A tabela 1 mostra como fica tal somatório. Na última coluna efetua-se o cálculo inverso de cada total, e o resultado significa o peso de cada termo da Ontologia.

Se, por exemplo, destacarmos o termo “comissão” da Ontologia da figura 4, verificamos que todos os links relacionados a este conceito totalizam 9 (nove) links. O peso a ser considerado para este termo será então o valor inverso (0,1111). Cada vez que o termo aparece no documento, este valor irá acumulado para o fator de ganho semântico. O fator de ganho semântico é normalizado, para que possa ser aplicado posteriormente ao vetor do documento.

A idéia por trás desta ponderação da Ontologia é fazer com que os termos que aparecem um número menor de vezes tenham uma valoração maior, de forma semelhante à IDF (frequência inversa de termos), reforçando assim a

TABELA 1 – Pesos atribuídos aos conceitos existentes na Ontologia do Exemplo

Conceito	Total de Links	Peso
infecção hospitalar	39	0,0256
agente	9	0,1111
comissão	9	0,1111
procedimento de risco	6	0,1667
fator de risco	6	0,1667
indicador	5	0,2000
unidade	4	0,2500
componente	4	0,2500
escherichia coli	2	0,5000
atuação	2	0,5000
normativa	1	1,0000
vigilância	1	1,0000
CCIH	1	1,0000
CIH	1	1,0000
biologista	1	1,0000
médico	1	1,0000
enfermeiro	1	1,0000
cirurgia	1	1,0000
cateter	1	1,0000
sonda	1	1,0000
cânula	1	1,0000
idade avançada	1	1,0000
prematuidade	1	1,0000
terapia avançada	1	1,0000
diabetes	1	1,0000
câncer	1	1,0000
enterococcus	1	1,0000
alcaligenes	1	1,0000
cândida	1	1,0000
enterobacter	1	1,0000
coli	1	1,0000
centro obstétrico	1	1,0000
centro cirúrgico	1	1,0000
UTI	1	1,0000
TMIH	1	1,0000
TIH	1	1,0000
taxa de infecção hospitalar	1	1,0000
taxa de mortalidade por infecção hospitalar	1	1,0000
infecção nosocomial	1	1,0000

A seguir, uma classificação *a priori* do usuário é necessária num primeiro momento de uso do sistema gerado, quando uma pesquisa é efetuada

com um conjunto de termos-chave. Os documentos retor-nados pelo agente de busca são classificados pelo usuário de acordo com a importância subjetiva para o mesmo.

TABELA 2 – Valores obtidos para o ganho de informação nos diferentes métodos

Método	Ganho de Informação
TF	2,2873
TF com ponderação ontológica	2,5252
TFIDF (TF mais IDF)	2,4935
TFIDF com ponderação ontológica	2,5874

Essa pré-classificação serve para formar o conjunto inicial de treinamento da rede *Neuro-Fuzzy*. A partir deste passo, o sistema tem condições de fazer a tomada de decisão, interpretando o raciocínio do usuário e passando a processar automaticamente as informações. As novas informações relevantes, agora classificadas pelo sistema e validadas pelo usuário, vão sendo agregadas ao sistema, em um processo contínuo de aprendizagem. Na classificação são atribuídos valores, considerando-se um grau de pertinência de valores *fuzzy* de acordo com as prioridades requeridas pelo vocabulário e pela Ontologia de domínio.

Na figura 5 temos uma rede ANFIS utilizada para a classificação do exemplo, mostrando as camadas da rede processando um vetor de documento. Na camada de entrada são dispostos os valores deste vetor. A rede possui 94 entradas e uma saída. A seguir, na camada de funções de pertinência os valores produzem as saídas *fuzzy* que, por sua vez, são processadas na camada do produto, normalizadas e alimentam na seqüência a camada dos parâmetros do conseqüente. Os dados de entrada são processados também nesta camada e produzem o valor de saída. A rede é treinada (através do método híbrido) com os vetores selecionados pelo usuário, sendo atribuído ao neurônio de saída o

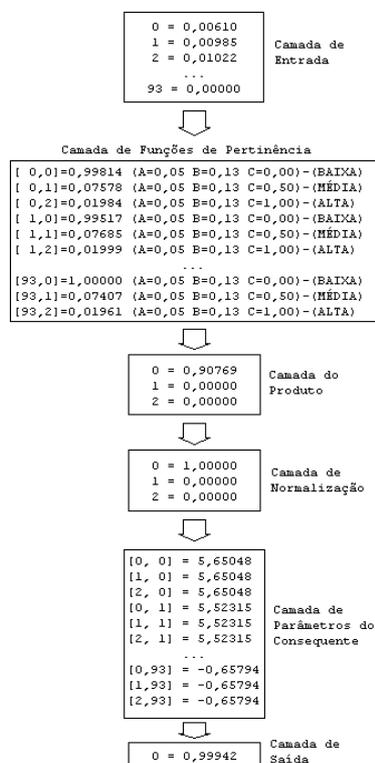


Figura 5 – Camadas da Rede Neuro-Fuzzy ANFIS processando um determinado vetor de documento

valor 1 (um) se o documento é relevante ou 0 (zero) em caso contrário. O teste na figura 5 indica então um documento relevante com valor de saída 0,99942.

Outro aspecto a considerar é o aparecimento de novos termos nas buscas inteligentes que não fazem parte da Ontologia de domínio. Após o processamento do GEDI, termos com a relevância aumentada pelo fator de ganho semântico serão disponibilizados como novos conceitos a serem validados pelo usuário para fazer parte da Ontologia.

VI. CONCLUSÃO

O artigo apresenta a estrutura e partes principais do GISAAGIC. A aplicação de técnicas de IA mais UNL combinadas com Ontologias de domínio, na busca inteligente de informações, proporcionam ganhos e aumentam a qualidade da representação dos vetores dos documentos para sua classificação pelo sistema. Embora esses ganhos sejam relativamente pequenos em um primeiro momento, o processo acontece de forma contínua.

No processo de classificação, estão sendo testados e usados outros tipos de redes *neuro-fuzzy*. A utilização contínua do sistema irá demonstrar qual tipo de rede será mais apropriado para uso na classificação.

A aplicação para a área médica demonstra a importância da ferramenta. A Ontologia do exemplo está sendo melhorada de forma a abranger um número maior de conceitos e *links*.

Estuda-se para esta implementação formas automáticas de agregação de novos conceitos a uma Ontologia e, assim, evitar a interferência do usuário para editar a Ontologia.

Como a ferramenta é genérica, O GISAAGIC pode gerar sistemas para outras áreas de domínio.

VI. REFERÊNCIAS

Livros:

- [1] A. G. Evsukoff & P. E. M. Almeida, *Sistemas Neuro-Fuzzy*, em S. O. Rezende, *Sistemas Inteligentes, Fundamentos e Aplicações*. Barueri: Manole, 2003.
- [2] B. Liautaud and M. Hammond, “*Inteligência em e-business*”, *Transformando Informações em Conhecimento e Conhecimento em Lucro*. Rio de Janeiro: Qualitymark, 2002, pp. 123-125.
- [3] C. L. Nascimento Jr e T. Yoneyama, *Inteligência artificial em controle e automação*, São Paulo: Edgard Blücher, 2000.
- [4] G. Salton, “*Editor. automatic text processing: The transformation, analyses and retrieval of information by computer*”. Addison Wesley, 1989.

- [5] F. A. Azevedo, F. M. Brasil & R. C. L. Oliveira. *Redes neurais com aplicações em controle e em sistemas especialistas*. Florianópolis: Visual Books, 2000.
- [6] F. A. Cummins, *Integração de sistemas*, tradução autorizada de J. Wiley & Sons, Inc. Rio de Janeiro: Campus, 2002.
- [7] H. Simon, “*Redes neurais – princípios e prática*”. 2ª. ed. São Paulo: Bookman, 2001.
- [8] S. O. Rezende, *Sistemas de inteligentes, fundamentos e aplicações*. São Paulo: Manole, 2003.
- [9] J. E. Z. Deboni, *Modelagem orientada a objetos com a UML*. São Paulo: Futura, 2003.
- [10] N. F. F. Ebecken, M. C. S. Lopes e M. C. A. Costa, Mineração de Textos, em S. O. Rezende, *Sistemas inteligentes, fundamentos e aplicações*. Barueri: Manole, 2003.

Artigos de Conferências e Revistas:

- [11] B. Choudhary e P. Bhattacharyya, Text clustering using semantics. Em *The Eleventh International World Wide Web Conference*, 2002.
- [12] DARPA. *DARPA Agent Markup Language (DAML)*. 2003. [Online]. Available: <http://daml.org/>.
- [13] C. Shah, B. Choudhary e P. Bhattacharyya, *Constructing better document vectors using universal networking language (UNL)*. Proceedings of International Conference on Knowledge-Based Computer Systems (KBCS), 2002.
- [14] J. S. R. Jang, ANFIS: adaptative-network-based fuzzy inference system, *IEEE Trans. On Systems, Man & Cybernetics*, 23(3): 665-685, 1993.
- [15] R. Jin, C. Falusos e A. G. Hauptmann. Meta-scoring: automatically evaluating term weighting schemes in IR without precision-recall. Em *Proceedings of the 24th annual international ACM SIGIR conference on Research and development in information retrieval*, p.83-89. ACM Press, 2001.
- [16] T. Berners-Lee, J. Hendler e O. Lassila, “*The semantic Web*”. Scientific American, May 2001.

Teses / Dissertações / Artigos de Conferências e Revistas:

- [17] A. D. Cordeiro, “Gerador Inteligente de Sistemas com Auto-Aprendizagem para Gestão de Informações e Conhecimento”. Tese de Doutorado, PPGEP, Universidade Federal de Santa Catarina, Florianópolis, 2005.
- [18] R. C. Bastos, “Avaliação de desempenho em sistemas educacionais: uma abordagem utilizando conjuntos difusos”. Tese de Doutorado, PPGEP, Universidade Federal de Santa Catarina, Florianópolis, 1994.
- [19] R. Raittz, “FAN 2002: Um Modelo neuro-fuzzy para reconhecimento de padrões”. Tese de Doutorado, Florianópolis, 2002.
- [20] A. L. Tello, “Métrica de idoneidade de ontologias”. Tese de Doutorado, Universidade Politécnica de Madri, 2002.