

REDES NEURAIS PARA CONSISTENTES APLICADAS NA DESCOBERTA DE FRAUDES À CONTA DE CLIENTES

Valdemir Silva Souza¹, Jair Minoro Abe³, José Demisio Simões da Silva^{1,2,4}

¹Universidade Braz Cubas - UBC, Mogi das Cruzes, SP

²Laboratório Associado de Computação e Matemática Aplicada – LAC
Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, SP

³Instituto de Estudos Avançados

Universidade de São Paulo - USP, São Paulo, SP

⁴Instituto Brasileiro de Tecnologias Avançadas – IBTA, São José dos Campos, SP
E-mails: valdemir.silva@terra.com.br, jairabe@uol.com.br, demisio@lac.inpe.br

Resumo. *Este artigo descreve uma abordagem para detecção de fraudes, baseada em redes neurais paraconsistentes. A lógica paraconsistente descreve as ações lógicas das Redes Neurais que são os conjuntos de modelos Artificiais de Neurônios Paraconsistentes utilizados no treinamento ou aprendizado de padrões. Nesse trabalho ela é revisada e os elementos de processamentos, entradas e saídas da rede são descritos. Os resultados apresentados são oriundos de uma rede neural paraconsistente implementada para detectar fraudes em um banco de dados disponível. Esses resultados mostram a viabilidade do uso e aplicação do raciocínio paraconsistente em tomada de decisão.*

1 Introdução

Segundo o dicionário Aurélio "fraude: é o abuso de confiança". Para ampliar essa definição o termo na Engenharia Social [2] é utilizado para descrever um método de ataque, onde alguém faz uso da persuasão, muitas vezes abusando da ingenuidade ou confiança do usuário, para obter informações que podem ser utilizadas para acessar, sem autorização, computadores ou bancos de informações. No que se refere à “_internet_”, o Comércio Eletrônico e o “_internet banking_”, os ataques envolvem diversas técnicas incluindo as de engenharia social. Algumas destas técnicas são descritas nas seguintes situações:

- 1) O usuário pode ser persuadido a acessar um endereço (sítio) de Comércio Eletrônico ou de “_internet banking_”, através de um “_link_” contido em uma mensagem eletrônica ou página de terceiros. O “_link_” pode direcionar o usuário para uma página falsificada, semelhante à página que o usuário realmente deseja acessar. Assim, o

atacante pode monitorar as ações do usuário e obter dados relevantes para um tipo de fraude.

- 2) O usuário recebe mensagens que contêm páginas “_web_” com aparência semelhante aos das páginas de vários bancos, inclusive ao que o usuário possui conta, com falsas informações sobre promoções de produtos ou novos cadastros. O usuário é persuadido a digitar seus dados que são remetidos para endereços eletrônicos diferentes do desejado.
- 3) O usuário recebe uma mensagem, cujo remetente pode ser um suposto gerente, funcionário ou até uma pessoa conhecida, com um programa anexado. Com o propósito de obter o acesso mais rápido à página de Comércio Eletrônico ou “_internet banking_”, esse programa, conhecido como cavalo de tróia, tem como objetivo o monitoramento das ações do usuário, capturando e transmitindo dados pessoais referentes aos números de cartões de crédito, senhas e contas do usuário.
- 4) O seqüestro relâmpago ou a clonagem de cartões, embora não sendo termos da engenharia social, definem outro tipo de crime, onde o princípio é a intenção de fraudar a conta do cliente.

Na tentativa de inibir o número crescente de ameaças de fraudes, os proprietários de páginas na “_internet_” para realização de transações envolvendo troca de informações, investem nas pesquisas por processos e sistemas que aumentem a segurança de suas transações. As páginas voltadas para aplicações do tipo Comércio Eletrônico e “_internet banking_” têm fornecido informações contra fraudes em meios de comunicações ou nos próprios sítios, incluindo alguns dispositivos para entradas de informações

do usuário (endereço, frases, uma carteira de números de posse do usuário que são exigidos a cada acesso), teclados virtuais e sistemas para análise e descoberta de perfis de clientes após a ocorrência de fraude e reclamação do cliente fraudado. Esses sistemas detectam indícios de fraudes, se as transações efetivadas estiverem fora do perfil do cliente, podendo daí haver o ressarcimento dos valores fraudados.

Acredita-se que seja possível implementar tecnologias para comparar os dados em tempo real do cliente com os dados gerados na formação do perfil em um determinado intervalo de tempo, desde que não haja um comprometimento nos custos existentes de acesso à página do usuário (prestador de serviço). Esses sistemas podem ser desenvolvidos utilizando diferentes técnicas de identificação de padrões.

Neste trabalho é descrito o desenvolvimento de um modelo de sistema baseado em Redes Neurais Artificiais Paraconsistentes [5], para durante uma transação via “_internet_”, realizar a verificação dos dados do cliente em tempo real, permitindo a comparação com os dados a partir do perfil gerado de seu histórico, minerados em um determinado intervalo de tempo configurado no aplicativo.

Os resultados encontrados (seção, 5) demonstram a eficiência das redes neurais artificiais paraconsistentes na identificação de possíveis fraudes à conta de clientes em uma determinada transação via sítio do usuário.

Portanto, um aplicativo desenvolvido com tal técnica pode se antecipar à descoberta de possíveis tentativas de fraude, descobrindo e reconhecendo padrões do perfil do cliente e auxiliando nos processos de tomada de decisão.

Na seção 2 é feita uma breve introdução à lógica paraconsistente utilizada neste trabalho. A seção 3 descreve os fundamentos para formação das redes neurais paraconsistentes. A seção 4 tece comentários sobre a análise de perfil na aplicação proposta no trabalho. A seção 5 apresenta resultados da aplicação do protótipo de sistema desenvolvido, e em seguida são apresentadas algumas conclusões e considerações sobre trabalhos futuros.

2 Lógica Paraconsistente

Uma introdução mais detalhada da lógica paraconsistente pode ser encontrada em [3], [4] e [5]. A seguir tem-se uma breve introdução suficiente para o entendimento das redes neurais paraconsistentes.

Seja T uma teoria fundada sobre uma lógica L e suponha que a linguagem de T e de L contém um símbolo para a negação \neg . Se houver mais de uma negação, uma delas deve ser escolhida pelas suas características lógico-formais.

A teoria T é inconsistente se possuir teoremas contraditórios, isto é, se existirem dois teoremas em que um negação o outro, caso contrário, T é consistente.

A teoria T é trivial se todas as fórmulas da lógica L ou todas as fórmulas fechadas de L forem teoremas de T ; caso contrário, T é não-trivial.

De maneira análoga, a mesma definição de consistência aplica-se a sistemas de proposições, conjunto de informações, etc. (levando-se em conta, naturalmente, o conjunto de suas conseqüências). Na lógica clássica e em muitas categorias de lógica, a consistência desempenha papel importante. Com efeito, em alguns sistemas lógicos usuais, se uma teoria T é trivial, então T será inconsistente reciprocamente, em outras palavras, lógica como essas não separam os conceitos de inconsistências e de trivialidade.

Uma lógica L é paraconsistente se puder servir de base para teorias inconsistentes, mas não-triviais, ou, colocando de outra forma, uma lógica paraconsistente tem a capacidade de manipular sistemas inconsistentes de informações sem torna-se trivial.

Uma das interpretações válidas da lógica paraconsistente pode ser observada nas fórmulas lógicas e modelos matemáticos seguintes, que considera um conjunto de valores discretos, $\zeta = \langle |\zeta|, \leq \rangle$ como reticulado finito denominado reticulado de valores-verdade, onde,

$$|\zeta| = [0,1] \times [0,1] \\ \leq \{ ((\mu_1, \rho_1), (\mu_2, \rho_2)) \in ([0,1] \times [0,1])^2 \mid \mu_1 \leq \mu_2 \text{ e } \rho_1 \leq \rho_2 \}$$

sendo que \leq é a ordem usual dos números reais.

Seja P o conjunto dos símbolos proposicionais, $P = \{p_\mu\}$, onde $\mu = (\mu_1, \mu_2)$ e μ_1 representa “grau descrença” e μ_2 representa “grau de crença”, tendo F como um conjunto de fórmulas da lógica L . Uma interpretação I para lógica paraconsistente [4] é uma função $I : P \rightarrow |\zeta|$. Pode-se atribuir uma valoração V a uma interpretação I , como uma função $V_I : F \rightarrow \{0,1\}$:

Se $p \in P$ e $\mu \in |\zeta|$, então:

1. $V_I(p_\mu) = 1 \iff I(p) \geq \mu$
2. $V_I(p_\mu) = 0 \iff$ não é o caso que $I(p) \geq \mu$

Pelas condições acima nota-se que $V_I(p_\mu) = 1$ se e somente se $I(p) > \mu$, ou seja, p_μ é verdadeira, segundo a interpretação I , se a valoração da interpretação é dada a p , for maior ou igual ao valor de crença μ com respeito à proposição p . Caso contrário, ela é falsa [5].

Pode-se mostrar que há interpretações I e proposições p_μ , tais que $V_I(p) = 1$ e $V_I(\neg p_\mu) = 1$, ou seja, tem-se contradições verdadeiras nesta lógica. Sendo a valoração da interpretação de $p_{(\lambda_1, \lambda_2)}$, onde $\neg p_{(\lambda_1, \lambda_2)}$ é igual a e $p_{\sim(\lambda_1, \lambda_2)}$. Assim, de forma intuitiva, se considerar proposições do tipo $p_{(0,5, 0,5)}$, a negação $\neg p_{(0,5, 0,5)}$ equivale a $p_{\sim(0,5, 0,5)}$ que é também $p_{(0,5, 0,5)}$. Se $p_{(0,5, 0,5)}$ for verdadeira, então é claro que sua negação também é verdadeira. Se ela é falsa, sua negação também é falsa.

Uma representação mais intuitiva relacionada ao contexto desse trabalho, se verifica com os seguintes exemplos:

Verdade – (1,0;0,0) : O cliente efetivou a transação desejada, com grau de crença total e descrença nula.

Conclusão: O cliente consegue efetivar a transação com sucesso.

Falsidade – (0,0;1,0) : O cliente efetivou a transação desejada, com grau de crença nulo e grau de descrença total.

Conclusão: Por um motivo qualquer o cliente não conseguiu efetivar a transação. Problemas no acesso ao sistema, como senha errada, erro na leitura do cartão, etc.

Inconsistência – (1,0;1,0) : O cliente efetivou a transação desejada, com grau de crença total e descrença total.

Conclusão: Houve a tentativa de efetivação da transação com valores contraditórios ao perfil do cliente.

Indeterminação – (0,0;0,0) : O cliente efetivou a transação desejada, com grau de crença nulo e descrença nula.

Conclusão: Não se sabe, se houve a efetivação da transação, pois não se identificou o valor com o perfil do cliente, por motivo de excesso de informação que são: valores idênticos ao perfil do cliente ou falta de informação, que são os valores totalmente fora do perfil do cliente.

3 Redes Neurais Paraconsistentes

As arquiteturas conexionistas [6][8][9] são direcionadas para aprimorar fatores relevantes nos estudos das Redes Neurais das características que diferem o cérebro do computador. O modelo de Rede Neural Artificial Paraconsistente (RNAP)[5] tem a finalidade de possibilitar a construção de unidades artificiais utilizando modelos mais próximos dos neurônios biológicos, efetuando análises e resultados semelhantes aos produzidos pelo cérebro humano. Uma RNAP utiliza a Equação Estrutural Básica (EEB), descrita como:

$$G_r = \frac{G_c - G_{dc} + 1}{2}$$

onde, G_r é o grau resultante, G_c é o grau de crença e G_{dc} é o grau de descrença. A equação computa os sinais dos graus de evidências valorados no intervalo fechado de números reais [0,1]. Os códigos são transmitidos por valores equacionados pela EEB através de células (métodos) implementadas e descritas com a Lógica Paraconsistente.

Quando o grau de crença é 1 considera-se uma confirmação da proposição ou do padrão aplicado na entrada; se o grau de crença é 0 considera-se uma negação lógica da proposição ou do padrão; e quando o grau de crença é $\frac{1}{2}$ (meio) considera-se uma indefinição lógica da proposição ou do padrão aplicado na entrada.

As equações da RNAP são muito simples porque as Células Neurais Artificiais Paraconsistentes (CNAPs), que são os fundamentos lógicos da rede paraconsistente, utilizam a EEB para equacionar os sinais e, a partir do resultado obtido, tomam decisões e as transmitem em forma de graus resultantes às outras CNAPs.

As células com estas características são usadas para formar as Unidades Neurais Artificiais Paraconsistentes (UNAPs), ou Para-Perceptrons simples quando houver apenas uma Célula de Conexão Analítica (CNAPCa) e uma Célula de Aprendizagem, Desaprendizagem e Memorização (CNAPAdm). Por sua vez, conjuntos de UNAPs formam Sistemas Neurais Artificiais Paraconsistentes (SNAPs), que formam uma RNAP. É sabido [5] que as conexões entre os objetos da rede neural paraconsistente não obedecem a nenhuma hierarquia definida, onde a aleatoriedade das interligações desses objetos pode surgir em qualquer instância da RNAP. A Figura 3.1 descreve um neurônio artificial paraconsistente análogo a um neurônio biológico denominado como Para-Perceptron Simples [5].

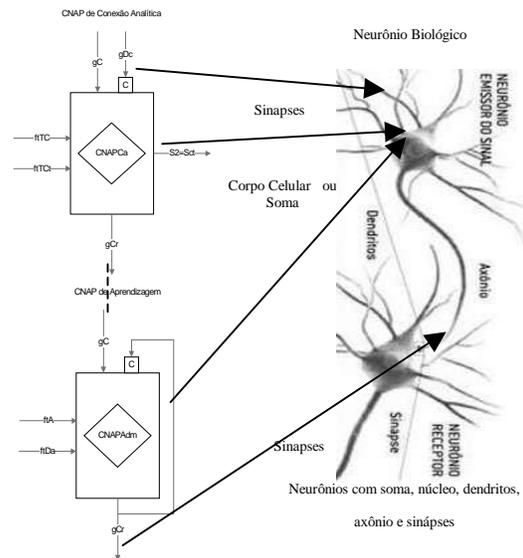


Figura 3.1 – Modelo de Para-Perceptron simples análogo a um neurônio biológico

As interligações (conexões sinápticas) entre os Para-Perceptrons, formam uma rede complexa por onde trafegam sinais representativos de proposições ou padrões que após as análises paraconsistentes, são convertidos em sinais resultantes, que são as saídas resultantes desses objetos paraconsistentes representando os graus de evidências favoráveis ou contrárias como resposta da RNAP. Os algoritmos nas seções 3.1 e 3.2 descrevem as células CNAPCa e CNAPAdm, respectivamente. Os cálculos representam as valorizações das proposições lógicas (seção, 2) contidas nas fórmulas da Lógica Paraconsistente.

3.1 Algoritmo representativo da CNAPCa

Essa célula tem a função de fazer a interligação entre as células da RNAP, associando graus de crença conforme o objetivo da análise. O resultado da análise é um fator de crença único, obtido pela equação estrutural básica, que será uma entrada para CNAPAdm.

Entradas:

1-gC (grau de crença);
2-gDcCo (grau de descrença complementado);

Entradas dos Fatores Externos:

1-ftTc (fator de tolerância a certeza);
2-ftTct (fator de tolerância a contradição);

Cálculos:

1- $gDcCo = 1 - gC$;
2- $G_c(\text{grau de certeza}) = gC - gDc$;
3- $G_{ct}(\text{grau de contradição}) = gC + gDc - 1$;
4- $EEB = (G_c + 1) / 2$ (eq. estrutural básica);

Saídas:

1-Se $|G_c| > ftTc$, então
 gCr (grau de crença resultante) = EEB e $gCr = 0$;
2-Se $|G_{ct}| > ftTct$ e $|G_c| > |G_{ct}|$ então
 $gCr = EEB$ e $gCr = |G_{ct}|$;
3-Caso contrário, $gCr = 1/2$ e $gCr = 0$;

3.2 Algoritmo representativo da CNAPAdm

Essa célula aprende após, um treinamento, um padrão utilizando o método de análise paraconsistente realizado pelo algoritmo a seguir.

Entradas:

1-gC;

Entradas dos Fatores Externos:

1-ftA (fator de Aprendizagem);
2-ftDa (fator de Desaprendizagem);

Cálculos:

1- Se ftA = 0 então
2- Se ftDa <> 0 então
3- $gDcCo = 1 - gC$
4- $gCr = (1 - gDcCo) - (gC - 1/2) * ftDa$
5- Se ($gCr = 1/2$)
6- Desaprendeu
7- ftA = Valor nativo ftA
8- Senão
9- volta ao passo (6)
10- fim-Se
11- fim-Se
10- Senão
11- $gDcCo = 1 - gC$
12- $gCr = (1 - gDcCo) - (gCr - gC) * fta$
13- Se ($gCr = gC$)
14- Aprendeu
15- ftA = 0
16- fim-Se
17- fim-Senão
18- fim-Se

Saídas:

1- gCr;

4 Sistema de Análise de Perfil

O Sistema de Análise de Perfil tem como objetivo comprovar uma forma de analisar o perfil de um cliente, a partir de um histórico disponibilizado em uma base de dados “SQL Server”, com informações de vários clientes num intervalo de tempo determinado.

A Figura 4.1 mostra uma rede neural artificial paraconsistente de reconhecimento de padrão (RNAPRp).

O primeiro objeto da RNAP é o Sistema Neural Artificial Paraconsistente de Reconhecimento de Padrão do Histórico (SNAPRpHist), que possui algumas entradas como fatores externos e uma entrada com o grau de crença (gCB), esses valores são discretizados sendo os graus de descrenças complementares aos de crença. Esses dados, representados numa matriz de valores reais no intervalo fechado [0,1], são utilizados para treinar a RNAPRp [7] e memorizar os valores do perfil do cliente. O segundo objeto define o Sistema Neural Artificial Paraconsistente de Conexão Analítica (SNAPCa), treina-se a RNAP para aprender os valores de entrada em tempo real, com o grau de crença e, utilizando o algoritmo do método dos mínimos quadrados [1] (externo à rede), calcula-se o grau de descrença.

Juntamente com o valor do grau de crença do histórico do perfil aprendido (gCB), são feitas as conexões analíticas que definem as ligações sinápticas e o reconhecimento de padrão. O terceiro objeto define o Sistema Neural Artificial Paraconsistente de Descoberta de Evidências Favoráveis e Contrárias (SNAPDeEv), nesse sistema os valores de saídas tratam de identificar a valorização dos dados memorizados e aprendidos na maximização (evidência favorável) e minimização (evidência contrária).

As saídas do SNAPDeEv são as entradas para as Células Neurais Artificiais Paraconsistentes Básicas (CNAPb). Essas células são a base de todas as outras, pois utilizam o algoritmo Para-Analisador [5] que neste trabalho é apresentado em uma representação simplificada do reticulado de 12 regiões da lógica paraconsistente [4].

Os valores externos utilizados nas análises do perfil do cliente são configurados externamente à rede. Esses valores [0,1] são determinados pelo usuário, onde suas alterações alteram o comportamento da RNAP. Pois esses valores definem uma faixa de aceitação na análise e tomada de decisão. Assim, na Figura 4.1 tem-se o ftTc, fator de tolerância à certeza; o ftTct, fator de tolerância à contradição; o ftCt, fator de contradição; ftTd, fator de tolerância à contradição; ftRp, fator de reconhecimento de padrão; o ftA, fator de aprendizagem; ftDa, fator de desaprendizagem e ftM, fator de memorização. Todos esses fatores são valorados num intervalo fechado [0,1] dos números reais.

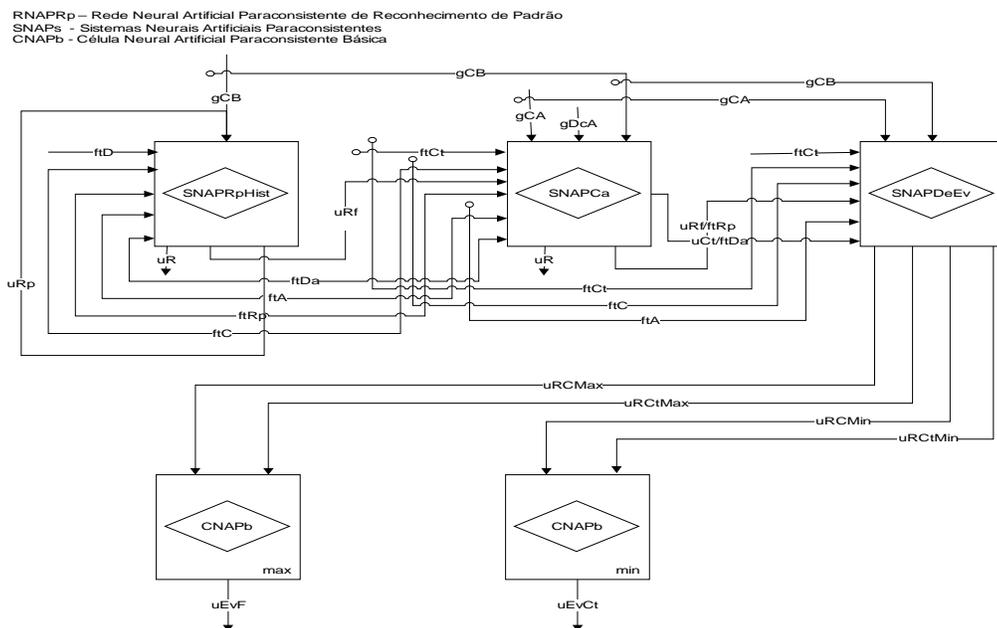


Figura 4.1 Modelo de Rede Neural Artificial Paraconsistente de Reconhecimento de Padrões.

5 Resultados

Os dados utilizados na análise são oriundos da mineração de dados de uma base de dados SQL Server, que se encontra no ambiente de desenvolvimento do usuário do aplicativo. Essas informações são fictícias, mas foram elaborados com a lógica de uma exaustiva análise de dados reais.

A pesquisa resultou na geração de um arquivo com algumas colunas (que formam tuplas) relevantes para a análise do perfil do cliente explicitadas na Tabela 5.1 em: Números de Agências, Contas, IPs, Transações, Horários, Datas, Valores.

Ag	Conta	IP	Trs	Hora	Data	Valor
0262	457244	1234566789	1234	170412	0701	254.89
0262	457244	1234566789	1234	170607	0701	606.71
0262	457244	1234566789	1234	130806	0706	96.93

Tabela 5.1 – Dados originais do ambiente de busca

Os dados da tabela 5.1 representam as características do conjunto de informações do perfil do cliente que serão analisados pelo aplicativo. Mas, especificamente os dados dessa tabela representam o perfil extraído de uma linha do tempo com dimensão em um intervalo de 6 (seis) meses de ações nas efetivações das transações de transferências entre contas de uma mesma instituição financeira.

Objetos_Eventos	SNAPRpHist	SNAPCa e SNAPDeEv	Total RNAP
CNAPs	6x7= 42	17x7= 119	162
UNAPs	1x7= 7	1x7= 7	14
Para-Perceptrons	1x7= 7	3x7= 21	28
Sinápticas	1x7= 7	7x7= 49	56

Tabela 5.2 - Dados de apenas um sinal de entrada à RNAP

A Tabela 5.2 descreve os objetos citados na formação da RNAPRp. Os valores descritos referem-se aos objetos e eventos gerados na RNAP para um vetor de sete colunas (Tabela 5.1) e apenas um sinal de entrada.

Objetos_Eventos	SNAPRpHist	SNAPCa e SNAPDeEv	Total RNAP
CNAPs	10.654.140	30.186.730	40.840.870
UNAPs	1.775.690	1.775.690	3.551.380
Para-Perceptrons	1.775.690	53.270.070	55.045.760
Sinápticas	1.775.690	12.429.830	14.205.520

Tabela 5.3 - Dados de todos os sinais de entrada à RNAP para uma população de 253.670 registros

Os cálculos utilizados na Tabela 5.3 definem a seguinte equação:

$$Obj_event = Quant_obj_RNAP * Quant_R_aprenHisi$$

Onde, *Obj_event* significa Objetos e eventos;

Quant_obj_RNAP significa quantidade de objetos na RNAP (resultado Tabela 1), e *Quant_R_aprenHist* significa quantidade de registros aprendido no histórico.

Descrição	Dados Iniciais	Dados Finais
Linha do Tempo	1	180 (dias)
Padrão → “Horário”	08:49:53h	18:43:55h
Padrão → “Data” (MMDD)	0701	1206
Padrão → “Valor”	R\$ 75,39	R\$ 904,68
Qtde Trasação Tempo Real	1	1
Quantidade Colunas Perfil	1	7
Quantidade Colunas Analisadas	1	3

Tabela 5.4 – Dados referentes aos intervalos de busca

A Tabela 5.4 descreve os dados de análise do perfil do cliente, demonstrando uma análise macro dos intervalos de acessos utilizados na formação do perfil desse cliente. A coluna *Descrição* representa o entendimento e a intuição das informações contidas na análise do perfil. A coluna *Dados Iniciais* representa o início da análise de acordo com sua descrição e a coluna dos *Dados Finais* representa o fim da análise, ou seja, os valores finais dos intervalos de processamento das análises. De forma intuitiva crê-se que as duas últimas colunas são os intervalos descritos no ambiente de análise.

Torna-se de extrema importância a compreensão dessa tabela, pois essa irá direcionar de forma coerente a visualização da eficiência da utilização da RNAP na análise e descoberta da possível fraude.

Descrição	Dados Iniciais	Dados Finais
População (transação)	283.534	283.534
Tempo Aprendizagem	0:00:00h	1:58:00h
Tempo Memorização	1:58:00h	2:00:00h
Reconhecimento de Padrão	2:00:00h	2:00:00h
Tempo total processo	0:00:00h	2:00:00h

Tabela 5.5 - Dados referentes a performance do Sistema de Análise do Perfil

A Tabela 5.5, descreve o custo de aprendizagem e memorização dos perfis do cliente minerados do histórico do cliente, é maior que o custo de reconhecimento dos perfis na RNAP, que é instantâneo, menor que 1 segundo.

Assim, o SNAPHistRp deve ser executado num momento de menor acesso à página do aplicativo.

6 Conclusão

A utilização da Lógica Paraconsistente como elemento e instrumento dos fundamentos lógicos da Rede Neural

Artificial Paraconsistente, foi comprovada em sua utilização na averiguação de possíveis fraudes com dados simulados de uma página de “_internet banking_”. Comprovou-se que o desempenho no quesito velocidade de processamento utilizando a RNAP em ambiente com dados discretizados, se demonstrou eficiente, se considerar tratamentos em tempo real no reconhecimento de padrões a perfis de clientes em sistemas estocásticos e determinísticos com uma aprendizagem rápida, pois possuem valores baixos para o fator externo de tolerância a certeza.

Pôde-se observar que em ambientes, onde a necessidade de resposta não seja em tempo real, tem-se como a RNAP atuar numa forma de aprendizagem mais lenta de acordo com o valor de tolerância a aprendizagem definido externamente seja mais próximo de um, aferindo assim, uma melhor interpretação, aprendizagem e reconhecimento dos padrões. Portanto, conclui-se que há possibilidade de um baixo custo computacional na utilização da RNAP nesse segmento de mercado e pesquisa na descoberta e análise de perfis e tomada de decisão.

Referências

- [1] Da Fonseca, Jairo Simon, entre outros; Estatística Aplicada; 1995. São Paulo, SP, Editora Atlas, 1995, págs 141-154.
- [2] Documentos, Cartilha de Segurança para Internet. NIC BR Security Office; <http://www.nbso.nic.br/docs/cartilha/>
- [3] Prado, João Carlos Almeida. Redes Neurais Artificiais Paraconsistentes e sua utilização para reconhecimento de padrões; Tese de Mestrado, São Paulo, SP, 2002, USP.
- [4] Da Costa, Newton C. A., Abe, Jair Minoro e outros. Lógica Paraconsistente Aplicada; São Paulo, SP, Editora Atlas, 1999, págs 21-117.
- [5] Da Silva Filho, João Inácio, Abe, Jair Minoro. Fundamentos das Redes Neurais Artificiais Paraconsistentes. São Paulo, SP, Editora VillaPress, 2001, págs 85-223, 247-257.
- [6] Fialho, Francisco; Ciências da Cognição; São paulo, SP, Editora Insular, 2001.
- [7] Russel, Stuart e Norvig, Peter; Inteligência Artificial, São Paulo, SP, Editora Campus, 2004, págs 447-559.
- [8] Rezende, Solange Oliveira; Sistemas Inteligentes – Fundamentos e Aplicações; São Paulo, SP, Editora Manole, 2003, págs 89-224.
- [9] Haykin, Simon; Redes Neurais – Princípios e Prática; Porto Alegre, RS, Editora Bookman, 2002, págs 75-273.