

# Redes neurais artificiais paraconsistentes aplicadas no estudo de fraudes à conta de clientes acessadas via “\_internet\_”

**Valdemir Silva Souza<sup>1,3</sup>, Jair Minoro Abe<sup>3</sup>, José Demísio Simões da Silva<sup>1,2</sup>**

<sup>1</sup>UBC-Universidade Braz Cubas, Mogi das Cruzes, SP

<sup>2</sup>Laboratório Associado de Computação e Matemática Aplicada  
Instituto Nacional de Pesquisas Espaciais (INPE) – São José dos Campos, SP

<sup>3</sup>Instituto de Estudos Avançados da USP, São Paulo, 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 da usabilidade e aplicabilidade 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 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 utilizados para ter acesso não autorizado a computadores ou informações. No que se refere à “\_internet\_”, o Comércio Eletrônico e o internet banking, os ataques envolvem várias técnicas inclusive as de engenharia social, algumas destas abordagens 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 (e-mail) ou página de terceiros. Este “\_link\_” pode direcionar o usuário para uma página falsificada, semelhante ao sítio que o usuário realmente deseja acessar. Assim, o atacante pode monitorar as ações do usuário e obter os dados relevantes para a fraude.

2-) O usuário recebe e-mails 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 um e-mail, cujo remetente pode ser um suposto gerente, funcionário, ou até uma pessoa conhecida, sendo que esse e-mail tem um programa anexado. Com o propósito de obter o acesso mais rápido a um sítio de Comércio Eletrônico ou “\_internet banking\_”, esse programa conhecido como cavalo de tróia, tem o objetivo de monitorar as ações do usuário emitindo os dados pessoais referentes aos números de cartões de crédito, senhas e contas do usuário. E isso pode ser feito através da digitação, onde o programa envia as teclas digitadas na entrada dos sítios que geralmente é o ambiente de autenticação do usuário; a posição do cursor na tela, pois muitos sítios de “\_internet banking\_” utilizam do teclado virtual para impedir a fraude.

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.

As respostas dos sítios mediante às ameaças descritas que comprometem à segurança do Comércio Eletrônico e “\_internet banking\_” são dadas através de 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), como citado o teclado virtual e softwares que podem descobrir os perfis do cliente após a execução da fraude e uma reclamação do cliente. Esses softwares são executados, se as transações efetivadas estiverem fora do perfil do cliente, comprova-se a fraude, e daí, pode-se 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 ao sítio do usuário. 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 uma 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 pelo usuário do 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 uma possível tentativa de fraude, através da descoberta e reconhecimento de padrões do perfil do cliente, auxiliando nos processos de tomada de decisão.

## 2 Lógica Paraconsistente

Seja T uma teoria fundada sobre uma lógica L. Suponha-se que a linguagem de T e de L contenha 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, um é a negação do 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.

Analogamente, a mesma definição 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, 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 chama-se Paraconsistente se puder servir de base para teorias inconsistentes, mas não-triviais, ou como diz, uma lógica paraconsistente tem a capacidade de manipular sistemas inconsistentes de informações sem torna-se trivial.

Uma das interpretações válidas da lógica paraconsistente tem-se nas seguintes fórmulas lógicas e modelos matemáticos descritos como:

Seja um conjunto de valores discretos,  $\zeta = \langle \zeta \rangle$ ,  $\leq$  um reticulado finito, onde,  $|\zeta| = [0,1] \times [0,1]$  e  $\leq \{((\rho_1, \mu_1), (\rho_2, \mu_2)) \in ([0,1] \times [0,1])^2 \mid \mu_1 \leq \mu_2 \text{ e } \rho_1 \leq \rho_2 \}$ ; sendo que  $\leq$  é a ordem usual dos números IR.

Seja P, o conjunto dos símbolos proposicionais,  $P = \{\rho\mu\}$ , onde  $\rho$  “grau descrença” e  $\mu$  “grau de crença”, tendo F um conjunto de fórmulas  $F \{A \rightarrow (B \rightarrow A), A \& B \rightarrow A, A \& B \rightarrow B \dots\}$  da lógica L. Uma interpretação “T” para lógica paraconsistente [4] é uma função  $I: P \rightarrow |\zeta|$ . Pode-se atribuir uma valoração “V”, dada a  $VI: F \rightarrow \{0,1\}$  assim definida:

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

1.  $VI(\rho\mu) = 1 \iff I(\rho) \geq \mu$ ;
2.  $VI(\rho\mu) = 0 \iff$  não é o caso que  $I(\rho) \geq \mu$ ;

Pela condição acima nota-se que  $VI(\rho\mu) = 1$  se e somente se  $I(\rho) > \mu$ , ou seja,  $\rho\mu$  é verdadeira, segundo a valoração da interpretação que é dada a  $\rho$ , for maior ou igual ao  $\mu$  com respeito à proposição  $\rho$  ela é falsa [5].

Pode-se mostrar que há interpretações “T” e as proposições  $\rho\mu$ , tais que  $VI(\rho)=1$  e  $VI(\neg\rho\mu)=1$ , ou seja, tem-se contradições verdadeiras nesta lógica. Sendo a valoração da interpretação de  $\rho$   $(\lambda_1, \lambda_2)$ , onde  $\neg\rho$   $(\lambda_2, \lambda_1)$  e  $\rho\sim$   $(\lambda_2, \lambda_1)$ . Assim, de forma intuitiva, se considerar proposições do tipo  $\rho(0,5;0,5)$ . A sua negação  $\neg\rho(0,5; 0,5)$  equivale a  $\rho\sim(0,5; 0,5)$  que é também  $\rho(0,5; 0,5)$ . Ora, se  $\rho(0,5; 0,5)$  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.

**Conclui-se:** O cliente conseguiu 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.

**Conclui-se:** Por um motivo qualquer o cliente não conseguiu efetivar a transação. Problemas no acesso ao sistema do usuário, senha errada, erro na leitura do cartão, entre outros.

### ■ Inconsistência – (1,0;1,0)

O cliente efetivou a transação desejada, com grau de crença total e descrença total.

**Conclui-se:** 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 nulo.

**Conclui-se:** Não se sabe, se houve a efetivação da transação, pois a LP não 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



**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<sub>c</sub> (grau de certeza) = gC - gDc;
- 3-G<sub>ct</sub> (grau de contradição) = gC + gDc -1;
- 4-EEB = (G<sub>c</sub> + 1) /2 (equação estrutural básica);

**Saídas:**

- 1-Se |G<sub>c</sub>| > ftTc, então gCr (grau de crença resultante) = EEB e gCr = 0;
- 2-Se |G<sub>ct</sub>| > ftTCt e |G<sub>ct</sub>| > |G<sub>c</sub>| então gCr = EEB e gCr = |G<sub>ct</sub>|;
- 3-Caso contrário, gCr = 1/2 e gCr = 0;

### 3.2 Algoritmo representativo da CNAPAdm

Essa célula tem a função de aprender após um treinamento um padrão utilizando o método de análise paraconsistente aplicado através do algoritmo descrito abaixo:

**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) - (gC -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, de um histórico disponibilizado em uma base de dados “SQL Server”, que possui 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 grau de crença (gCB), esses valores são discretizados os graus de descrenças são complementares ao de crença. Esses dados representados numa matriz de valores reais no intervalo fechado [0,1], é utilizado para treinar a RNAPRp a aprender [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 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), essa célula é a base de todas as outras, pois utiliza o algoritmo Para-Analisador [5]. Nesse trabalho utiliza-o numa 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 consequentemente suas alterações alteram o comportamento da RNAP. Pois esses valores definem uma faixa de aceitação na análise e tomada de decisão. Assim, a figura 4.1 tem-se: o ftTc, fator de tolerância a certeza; o ftTCt, fator de tolerância a contradição; o ftCt, fator de contradição; ftTd, fator de tolerância a contradição; ftRp, fator de reconhecimento de padrão; o ftA, fator de aprendizagem; ftDa, fator de desaprendizagem e ftM, fator de memorização, onde todos esses fatores são valorizados num intervalo fechado [0,1] dos números reais.

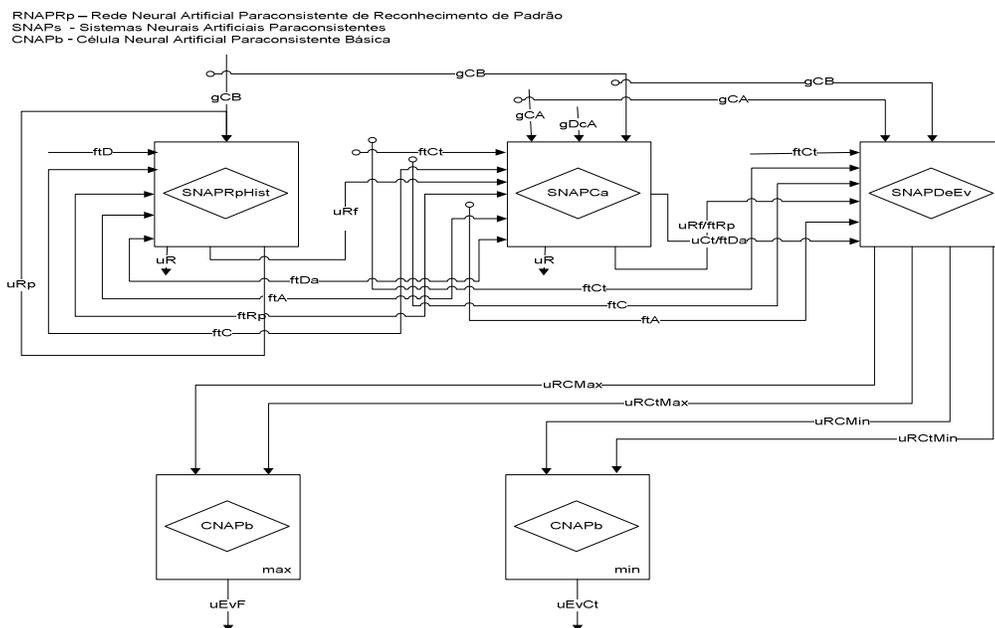


Figura 4.1 Modelo de Rede Neural Artificial Paraconsistente de Reconhecimento de Padrões.

## 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 elaboradas com a lógica de uma exaustiva análise de dados reais.

O resultado dessa pesquisa foi a geração de um arquivo com algumas colunas (que formam tuplas) relevantes a análise do perfil do cliente explicitadas na tabela abaixo 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 acima, 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:

$$Obj\_event = Quant\_obj\_RNAP * Quant\_R\_aprenHist$$

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 das *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 ao sitio do usuário 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 um sítio do “\_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 estocástico e determinístico 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 for mais próximo de um, aferindo assim, uma melhor interpretação, aprendizagem e reconhecimento dos padrões. Portanto, é conclusivo a possibilidade de haver um baixo custo computacional na utilização da RNAP nesse segmento de mercado e pesquisa na descoberta e análise de perfis e tomada de decisão.

## 7 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.