

# FControl<sup>®</sup>: Sistema Neuro-Nebuloso-Evolutivo Aplicado à Detecção de Fraudes em Operações de Comércio Eletrônico

Leandro dos Santos Coelho<sup>1</sup>, Roberto Tadeu Raittz<sup>2</sup> e Maurício Trezub<sup>3</sup>  
<sup>1</sup> Pontifícia Universidade Católica do Paraná, PUCPR/CCET/PPGEPs/LAS  
Grupo Produtônica, Pós-Graduação em Engenharia de Produção e Sistemas  
Rua Imaculada Conceição, 1155, CEP 80215-901, Curitiba, PR, Brasil  
E-mail: leandro.coelho@pucpr.br

<sup>2</sup> Curso Tecnólogo em Informática, Universidade Federal do Paraná  
Rua Dr. Alcides Vieira Arcoverde, 1225, CEP 81520-260, Curitiba, PR, Brasil  
E-mail: raittz@ufpr.br

<sup>3</sup> CIASHOP E-Commerce, <http://www.ciashop.com.br>  
Rua Alferes Ângelo Sampaio, 301, CEP 80250-120, Curitiba, PR, Brasil  
E-mail: trezub@ciashop.com.br

## Abstract

*The prevention of credit card fraud is an important application for forecasting and computational intelligence approaches. Computational intelligence is an association of computational methodologies that includes as its main member the neural networks, fuzzy systems, evolutionary computation and probabilistic computation approaches. This paper presents an efficient system based on computational intelligence methodologies for fraud detection of real credit card data operations in e-commerce transactions. The new proposed method called Fcontrol<sup>®</sup> of fraud detection and classification integrates concepts of neural networks, fuzzy systems, and evolutionary computation. The proposed method provides quality solutions in terms of efficiency and forecasting successful. The Fcontrol<sup>®</sup> system has been installed on an Intel Pentium IV 2.4 MHz (bi-processor and RAM of 4 Gbytes) at Ciashop E-Commerce company and is currently in use for fraud detection for 250 companies with e-commerce services.*

## 1. Introdução

Em sistemas tecnológicos, atividades fraudulentas têm ocorrido em diversas áreas, tais como redes de comunicação, comunicação móvel, *on-line banking* e comércio eletrônico. As fraudes estão crescendo de forma acentuada com a expansão da tecnologia moderna e comunicação global, resultando em perdas substanciais em negócios [1]. As fraudes virtuais fizeram com que comerciantes perdessem, em 2004, US\$ 2,6 bilhões. O montante representa 1,8% do total das vendas e, além de pagamentos fraudulentos, está relacionado ao medo que os internautas têm de realizar transações on-line. Em 2000, as perdas foram de US\$ 1,5 bilhão, em 2001 chegaram a US\$ 1,7 bilhão e, em

2002, US\$ 2,1 bilhões. Em 2003, houve uma melhora no cenário, e as perdas caíram para US\$ 1,9 bilhão [2].

Conseqüentemente, a detecção de fraudes é uma importante abordagem a ser explorada pelas empresas. A detecção de fraudes envolve a identificação das fraudes, de preferência o mais rapidamente possível. O desenvolvimento de novos métodos computacionais para a detecção e diagnóstico de fraudes em operações de comércio eletrônico é uma área de estudos recentes. A maioria dos trabalhos publicados nesta área está relacionada à detecção de fraudes em operações com cartão de crédito, mas sem uso de comércio eletrônico, usando principalmente redes neurais artificiais e mineração de dados (*data mining*) [3]-[7].

Neste artigo, a principal contribuição é o projeto do sistema FControl<sup>®</sup>, da CIASHOP E-Commerce, para detecção de fraudes em operações de comércio eletrônico. O FControl<sup>®</sup> utiliza uma abordagem híbrida de inteligência computacional baseada em sistema neuro-nebuloso [8]-[9] com otimização (busca local) usando uma estratégia evolutiva [10]-[11].

O artigo é organizado da seguinte forma. A descrição da abordagem neuro-nebulosa e a otimização evolutiva são apresentados na seção 2. Na seção 3 é descrito o problema de classificação vinculado à detecção de fraudes em operações de cartão de crédito para comércio eletrônico e uma análise dos resultados experimentais. A conclusão do trabalho é comentada na seção 4.

## 2. Inteligência computacional

O desenvolvimento da tecnologia de processamento de informação e a inteligência computacional constituem-se em uma solução alternativa para problemas que necessitam aspectos relativos à incorporação de características inspiradas na natureza e na inteligência humana em problemas complexos, a exemplo de previsão do comportamento de sistemas dinâmicos.

Estes sistemas de previsão, ditos “inteligentes”, possuem capacidades de aprendizado e adaptação, motivando a atenção crescente de pesquisadores de diversas áreas. Entre as vantagens potenciais oferecidas por estas técnicas pode-se ressaltar: (i) menor dependência de modelos quantitativos (vantagem dos sistemas nebulosos), (ii) algoritmos estruturados de maneira simples para o auxílio na tomada de decisões, (iii) capacidade de aprendizagem, e (iv) maior grau de autonomia.

Os sistemas de previsão, baseados em algoritmos de inteligência computacional, têm a habilidade de aprendizado, raciocínio e auxiliar na tomada de decisão. No entanto, os sistemas de previsão convencionais apresentam algum grau de inteligência. As características que os diferenciam são os graus de complexidade e a incerteza que estes sistemas ditos “inteligentes” podem lidar.

Em particular, os sistemas de previsão inteligentes devem possuir a habilidade de tratar diversos tipos de incertezas, os aspectos qualitativos da informação, as estruturas de dados complexas, a vasta quantidade de dados não-estruturados e a informação de especialistas. Entretanto, no atual estágio do desenvolvimento tecnológico, os sistemas de previsão ditos inteligentes apresentam, ainda, características rudimentares quanto aos aspectos de autonomia em termos de aprendizado, raciocínio, planejamento e tomada de decisões.

Zadeh [12] e Bezdek [13] de forma independente propuseram a denominação de inteligência computacional para uma coleção de metodologias que visam explorar: a tolerância a falhas, a imprecisão e a incerteza proporcionando robustez e solução de baixo custo. Os principais membros deste consórcio incluem as áreas de redes neurais, computação evolutiva (ou evolucionária), sistemas nebulosos, raciocínio probabilístico (gerenciamento da incerteza e aprendizado de máquina) e a combinação destes (sistemas híbridos inteligentes).

O princípio que guia a inteligência computacional é explorar a tolerância à imprecisão e incerteza visando aspectos de tratabilidade e melhor relação com a realidade. Em síntese, o modelo de regra para a inteligência computacional é o pensamento humano [12], [14].

Os pesquisadores da inteligência computacional objetivam atender a estas necessidades com o desenvolvimento de sistemas que combinam as vantagens de algumas metodologias inteligentes através da configuração de sistemas híbridos inteligentes. Os sistemas híbridos são relevantes quando se considera a natureza variada das aplicações. As formas dos sistemas híbridos inteligentes usualmente analisados na literatura incluem: (i) sistemas evolutivo-nebulosos; (ii) sistemas evolutivo-neurais; (iii) sistemas neuro-nebulosos; e (iv) sistemas neuro-nebuloso-evolutivos [15], [16].

Nas próximas duas subseções é apresentada uma recente abordagem de modelo neuro-nebuloso usando

otimização baseada em estratégia evolutiva para aplicação em detecção de fraudes.

## 2.1 FAN (*Free Associative Neurons*): um modelo neuro-nebuloso para reconhecimento de padrões

Na literatura têm sido propostas diversas variantes de modelos neuro-nebulosos [17]-[19]. A abordagem da FAN [8], [9] consiste no desenvolvimento de uma estratégia de reconhecimento de padrões que garante bom desempenho no aprendizado aliado às vantagens computacionais da clareza na representação dos padrões e portabilidade das unidades de representação que são denominadas *free associative neurons*.

Na abordagem usando FAN, cada padrão de entrada do sistema é expandido em uma vizinhança nebulosa. Cada conjunto suporte dessa vizinhança é a combinação dos valores das características próximos dos originais [9].

O grau de similaridade entre a vizinhança nebulosa e o padrão original de entrada é realizado através de técnicas usadas em conjuntos nebulosos [20]. O aprendizado acontece pela projeção da vizinhança nebulosa no espaço FAN. Há uma unidade FAN para cada classe do domínio do problema. Cada unidade é uma matriz composta por todas as combinações de características observadas em sua classe correspondente [9].

Durante o treinamento, cada combinação é representada por uma célula nebulosa que contém um peso correspondente à sua frequência de ocorrência e grau de pertinência. O treinamento é baseado no reforço nas células projetadas de FAN – se a classificação foi correta – ou em esquecimento (penalização) – se houve uma classificação incorreta.

Em FAN, dois princípios básicos fundamentam o processo de representação de dados: (i) um padrão representa mais que um simples ponto, em termos de informação, assim na modelagem é considerada uma região na vizinhança do padrão analisado, e (ii) cada padrão contém mais informações que vão além dos valores individuais, fazendo a correlação dos valores das características, o desempenho do sistema pode ser aumentado.

Neste contexto, a primeira tarefa está relacionada com a decomposição do padrão, ou seja, a geração de uma vizinhança em torno o padrão de entrada. A vizinhança constitui um conjunto de padrões nebulosos no espaço de entrada, próximos ao padrão original. A tarefa seguinte no procedimento de modelagem dos dados é a projeção de cada vizinhança nebulosa em uma região denominada espaço FAN. Esta região consiste de um conjunto de pontos no espaço  $\mathfrak{R}^{2H}$  (onde  $H$  é o nível de combinação das características) e o algoritmo FAN, neste contexto, calcula a similaridade entre essas projeções e as unidades FAN.

Em síntese, o processo de modelagem neuro-nebulosa usando FAN é realizado pelos seguintes

procedimentos: (i) decomposição do padrão (vizinhança nebulosa) e (ii) projeção da vizinhança nebulosa.

Na decomposição, o padrão de entrada é transformado em um conjunto de padrões nebulosos. Dado um padrão de entrada  $\mathbf{x}$ , a seguinte expressão representa o conjunto de padrões nebulosos:

$$\bar{\mathbf{x}}_z = \mu_{x_i}(v_i(l_i)) / v_i(l_i), \dots, \mu_{x_p}(v_p(l_p)) / v_p(l_p) \quad (1)$$

onde  $z = 1, (2D+1)^p$ ,  $D$  é o raio de decomposição que estabelece o número de inteiros em cada lado da coordenada original  $x_i$  (centro) do vetor de entrada  $\mathbf{x}$ ;  $v_i(l_i)$  é o valor da  $i$ -ésima coordenada inteira, próxima ao valor original  $x_i$ , onde o índice  $l_i=1, 2D+1$ , varia para a vizinhança de cada coordenada;  $\mu_{x_i}(v_i(l_i))$  é a função de pertinência que mede a similaridade entre o valor  $v_i(l_i)$  e o original  $x_i$  ( $i=1, p$ ).

Uma vez gerados os vizinhos nebulosos, o processo de modelagem dos dados dá início à projeção da vizinhança. A idéia é projetar o padrão original  $\mathbf{x}$  sobre o espaço de combinações das características. Sua dimensão é igual ao produto cartesiano nebuloso da vizinhança das características, em que a similaridade em relação aos valores originais é obtida por meio de técnicas nebulosas. Esta etapa é realizada projetando cada vizinho nebuloso  $\bar{\mathbf{x}}_z$ , sobre o espaço cartesiano nebuloso, gerando a projeção  $\mathbf{F}_z$ .

O primeiro parâmetro a ser ajustado é o nível de combinação das características, denominado  $H$ . Este fator tem impacto direto na dimensão do espaço FAN. O escopo de valores de  $H$  é o intervalo  $[1, p]$ , onde  $p$  é dimensão do espaço de entrada.

Desta forma, um fator  $H=2$ , implica que as características serão combinadas em pares. A projeção completa  $\mathbf{F}_z$  é formada por todas as  $C_p^H + p$  combinações de características. Esta combinação é composta pelos índices dos vetores  $\bar{\mathbf{x}}_z$  e pelos valores das coordenadas  $v_j(l_j)$  a serem combinados. Cada combinação é avaliada pelo produto dos graus de pertinência correspondentes  $\mu(v_j(l_j))$ . A projeção de  $\mathbf{F}_z$  é determinada então por:

$$\mathbf{F}_z \in \mathfrak{R}^{2H(C_p^H + p)} = \text{Proj}(\bar{\mathbf{x}}_z) = (f_m^z, \mathbf{a}, \alpha) \quad (2)$$

onde  $\mathbf{a} = (a_1, \dots, a_H)$  é o vetor de índices, com  $1 \leq a_j \leq p$ ,  $\alpha = (v_1(i_1), \dots, v_H(i_H))$  e

$$f_m^z = \prod_{j=1, H} \mu_{x_i}(v_j(a_j)), \quad (3)$$

com  $m = 1, (C_p^H + p)$ .

As expressões (2) e (3) descrevem como um vizinho nebuloso é representado em um subespaço do FAN. Entretanto, na implementação do mecanismo de aprendizado, deve-se considerar não apenas um vizinho. Na expressão abaixo,  $\mathbf{F}_z$  é calculado usando-se todos os vizinhos possíveis para  $H$  e  $D$  definidos para a aplicação. Em alguns casos práticos não é usada a totalidade, mas sim uma quantidade que seja representativa, evitando problemas de explosão combinatorial. O número destas combinações é usado como parâmetro nas aplicações e recebem o nome de *número de combinações das características*. A *projeção da vizinhança nebulosa* é a união dos vizinhos nebulosos projetados de  $\mathbf{F}_z$ :

$$\mathbf{F} = \bigcup_{z=1, (2D+1)^p} \mathbf{F}_z \quad (4)$$

O aprendizado envolve a comparação entre a projeção  $\mathbf{F}$  e todas as unidades  $\mathbf{FAN}^j$  ( $j=1, C$ , onde  $C$  é o número de classes do domínio do problema). A dimensão de  $\mathbf{F}$  é definida pela expansão do padrão de entrada  $\mathbf{x}$  (isto é, depende dos valores das coordenadas  $x_i$  de  $\mathbf{x}$  e dos parâmetros  $D$  e  $H$ ). Entretanto,  $\mathbf{FAN}^j$  possui uma dimensão maior, incluindo as combinações de características que ocorrem para todo  $\mathbf{x}^k \in \mathbf{FAN}^j$ . A comparação é feita avaliando o grau ao qual  $\mathbf{F}$  é um subconjunto de  $\mathbf{FAN}^j$ .

O cálculo da similaridade entre  $\mathbf{F}$  e  $\mathbf{FAN}^j$ , e as expressões usadas para reforço e esquecimento não representam a essência do método proposto, podendo variar de uma aplicação para outra. Neste caso, a similaridade entre  $\mathbf{F}$  e  $\mathbf{FAN}^j$  é calculada por:

$$S(\mathbf{F}, \mathbf{FAN}^j) = 1 - \prod_g \left( 1 - \frac{f_g \cdot \text{fan}_g^j}{\text{fan}^j} \right) \quad (5)$$

onde  $\text{fan}_g^j$  é uma célula do conjunto nebuloso  $\mathbf{FAN}^j$ ,  $f_g$  é uma célula do conjunto nebuloso  $\mathbf{F}$  (obtido pela expressão (3)),  $g$  é o índice que cobre todo o domínio de  $\mathbf{FAN}^j$  que possui um correspondente em  $\mathbf{F}$  e  $\text{fan}^j$  é o número total de ocorrências na unidade  $\mathbf{FAN}^j$ .

A expressão (5) mede a similaridade da projeção  $\mathbf{F}$  em cada unidade FAN,  $\mathbf{FAN}^j$ . A maior similaridade indica a classe associada ao padrão de entrada  $\mathbf{x}$ . Em outras palavras, a saída da rede é  $j$ -ésima classe, onde  $j \in [1, C]$  é o índice da unidade FAN que apresenta maior similaridade,  $\mathbf{FAN}^j$ . Isto é obtido por:

$$S(\mathbf{F}, \mathbf{FAN}^{j^*}) = \max_j S(\mathbf{F}, \mathbf{FAN}^j) \quad (6)$$

Uma vez que a saída da rede neuro-nebulosa é determinada, acontece o aprendizado (*backward*

*computation*). Primeiramente ocorre a verificação do acerto na classificação ( $j^* = j'$ , onde  $j'$  é a classe do domínio associada ao padrão de entrada  $\mathbf{x}$ ) ou erro de classificação (caso contrário). Em ambos os casos a mudança dos valores de pertinência de  $\mathbf{FAN}^*$  é determinada pelo grau de pertinência da célula  $f_g$ .

Quando a saída da rede neuro-nebulosa for correta, o procedimento consiste no reforço (fortalecimento) das células  $\mathbf{FAN}^*$  interceptadas pela projeção  $\mathbf{F}$ .

O reforço consiste em somar ao conteúdo atual da célula  $fan_g^j$  o valor de pertinência  $f_g$ . A pertinência será determinada pelo somatório das funções de pertinência na célula dividida pelo total de ocorrências na unidade  $fan_g^j / fan^j$ .

No caso de ocorrer uma classificação errada, o algoritmo realiza um procedimento de *esquecimento*, diminuindo o valor das células  $\mathbf{FAN}^*$  interceptadas pela projeção  $\mathbf{F}$ . Neste caso, a pertinência  $f_g$  é subtraída do conteúdo da célula, se este conteúdo tornar-se negativo após a subtração, seu valor será definido como sendo zero.

Resumindo, o algoritmo FAN pode ser resumido pelas seguintes etapas (mais detalhes são encontrados em [8] e [9]):

- (i) iniciar  $\mathbf{FAN}^j = 0$  para  $j=1, C$ , onde  $C$  é o número de classes do problema;
- (ii) iniciar o nível de combinações de características  $H$  e o raio de decomposição  $D$ ;
- (iii) realizar a decomposição do padrão;
- (iv) realizar a projeção da vizinhança nebulosa;
- (v) calcular o grau de similaridade;
- (vi) determinar a saída da rede neuro-nebulosa;
- (vii) realizar retroprocessamento.

## 2.2 Otimização usando estratégia evolutiva

Nos algoritmos evolutivos (AEs), um conjunto de soluções (população) é manipulado a cada iteração, em contraste com outros métodos de otimização, onde apenas uma solução para o problema é utilizada a cada iteração. A chance de que um indivíduo da população seja selecionado na próxima geração depende da função de aptidão (*fitness*) do indivíduo (solução a ser otimizada), que consiste, geralmente, de uma função objetivo ou mesmo uma transformação simples desta para o tratamento do problema em questão. Um compromisso entre convergência (*exploitation*) e diversidade dos membros que constituem a população (*exploration*) é um problema constante em AEs e deve ser considerado na configuração de uma metodologia de otimização eficiente.

Muitas das pesquisas relacionadas aos princípios de auto-adaptação em AEs tratam de parâmetros relacionados com operador de mutação. A técnica de auto-adaptação é geralmente empregada com sucesso nos ajustes de variâncias e de covariâncias em relação a uma distribuição normal n-dimensional.

Segundo Angeline [21], é possível adaptar dinamicamente os aspectos de processamento de um AE antecipando as regularidades do ambiente, aprimorando o procedimento de otimização e enfatizando a rapidez na busca dos parâmetros. Os AEs que apresentam mecanismos adaptativos (AEMAs) distinguem-se pela configuração dinâmica dos parâmetros selecionados ou mesmo pelos operadores durante o ciclo evolutivo de otimização. Os AEMAs têm uma vantagem sobre os AEs básicos, pois são mais reativos em antecipar as particularidades do problema, ou mesmo em algumas formulações podem dinamicamente adquirir informação sobre as regularidades no problema e explorá-las. Segundo Angeline (1995), os AEMAs podem ser separados em três níveis onde os parâmetros adaptativos estão presentes, que são:

- (i) *nível populacional*: os métodos adaptativos ajustam dinamicamente os parâmetros, que são globais à população inteira;
- (ii) *nível individual*: os métodos adaptativos modificam a maneira que um indivíduo da população é afetado pelos operadores de mutação;
- (iii) *nível de componente*: os métodos adaptativos alteram a forma pela qual os componentes de cada indivíduo são manipulados independentemente dos outros indivíduos da população.

Os mecanismos de auto-adaptação, no âmbito de componente dos parâmetros da estratégia adaptativa, providenciam uma das características principais do sucesso das estratégias evolutivas (EEs). As EEs utilizam princípios de busca no espaço de variáveis-objeto e estratégia interna de controle dos parâmetros, simultaneamente [22]. A abordagem de EE com adaptação do sistema independente de coordenadas para o operador de mutação, usada neste trabalho para otimizar (busca local) os valores de raio de decomposição da FAN (após a etapa (vii) de retroprocessamento), foi proposta por [10], [11].

A mutação é o operador principal de uma EE e sem a mudança na distribuição do operador de mutação durante a seqüência de gerações do ciclo evolutivo, existe uma diminuição na probabilidade da solução evoluir para uma solução adequada.

O caminho de evolução — “caminho” de distribuição da população no espaço de busca ao longo de um número de gerações — revela informações do ciclo evolutivo, principalmente pelas correlações entre os passos de mutação que são sucessivamente selecionados na seqüência de gerações. Se os passos de mutação selecionados são correlacionados paralelamente (produto escalar maior que zero), ou seja, os passos de evolução estão na mesma direção, o caminho de evolução é comparativamente longo. Se, por outro lado, os passos de mutação são correlacionados de forma anti-paralela (produto escalar menor que zero), o caminho de evolução é comparativamente mais curto. Conseqüentemente, para a realização de passos de mutação mais eficientes é

melhor não possuir uma correlação entre os passos de mutação selecionados no caminho de evolução [11].

Hansen e Ostermeier [11] sugerem o *princípio da adaptação fundamental* para remover a correlação entre os passos de mutação selecionados sucessivamente, que diz: “*uma adaptação aceitável necessita reduzir a diferença entre as distribuições do caminho de evolução atual e um caminho de evolução, através de uma seleção aleatória com relação aos parâmetros adaptados*”.

Uma abordagem baseada no princípio da adaptação fundamental é adotada neste artigo. A abordagem é denominada de adaptação da matriz de covariância e é aplicada a uma  $(\mu, \lambda)$ -EE, onde os  $\lambda$  descendentes competem para sobreviver e o(s)  $\mu$  ancestral(is) é(são) completamente substituído(s) a cada geração.

As equações que regem esta abordagem de  $(\mu, \lambda)$ -EE para  $\mu=1$  são apresentadas de forma detalhada em Hansen e Ostermeier [10]. As regras de atualização desta EE são similares às regras de atualização dos métodos do tipo quase-Newton utilizados em otimização clássica.

### 3. Descrição do problema e resultados

A realização de detecção de fraudes em operações de comércio eletrônico é um campo de estudo confidencial e ainda com pouca divulgação pública dos resultados obtidos por empresas comerciais.

O problema real de detecção de fraudes é realizado pelo sistema FControl<sup>®</sup> (<http://www.ciashop.com.br>) adotando 36 distintas características para classificar se uma operação é normal, suspeita ou fraudulenta. Estas características foram selecionadas de acordo com o conhecimento de um especialista e análise de correlação múltipla.

A FAN utilizada para esta finalidade é novamente treinada de 14 em 14 dias para manter o sistema em alerta para o aparecimento de possíveis padrões novos de fraudes. As técnicas mencionadas nas subseções 2.1 e 2.1 são combinadas de tal forma que a EE é usada para realizar a otimização dos valores de raio de decomposição da FAN, isto realizado após a etapa de retroprocessamento da FAN.

Foi testado com banco de dados com 2916 dados de transações (reais) de comércio eletrônico com os mais diversos padrões de transações legais e fraudulentas. Na figura 1 é apresentada uma representação das transações legais e fraudulentas do banco de dados.

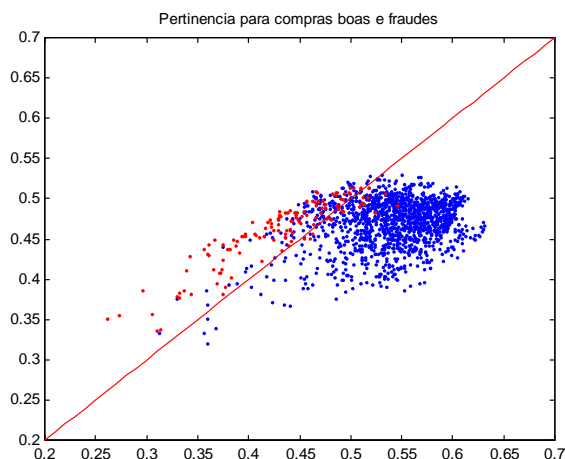


Figura 1: Transações boas e fraudulentas.

A FAN sem o uso de EE obteve uma taxa de classificação com acerto de 89,5432% para as transações legais e 89,8876% para as transações fraudulentas. Entretanto, com a utilização da otimização pela EE o nível de acerto aumentou para 90,1472% para as transações legais e 92,1348% para as transações fraudulentas. EE otimizada foi configurada com  $\mu = 1$ ,  $\lambda=20$  e critério de parada de 500 gerações. Para os procedimentos de treinamento e teste da FAN foram escolhidas, de forma aleatória, cerca de 80% e 20% do total das 2916 transações (boas e fraudulentas) de comércio eletrônico.

### 4. Conclusão

O problema de fraudes em operações de comércio eletrônico é um problema com enorme impacto financeiro nas instituições de crédito, de gerenciamento de comércio eletrônico e os possuidores de cartão de crédito [2], [7].

Neste artigo foi apresentado um panorama do projeto do sistema Fcontrol<sup>®</sup> para detecção de fraudes em operações de comércio eletrônico. O sistema utiliza uma abordagem FAN híbrida que combina conceitos de redes neural, sistemas nebulosos e computação evolutiva. A FAN combina simbioticamente os méritos do tratamento do conhecimento quantitativo das redes neurais, as facilidades de representação do conhecimento e tratamento de incertezas dos sistemas nebulosos e as potencialidades de busca e otimização da computação evolutiva.

Os resultados obtidos pela FAN, com otimização evolutiva, no sistema FControl<sup>®</sup> tem apresentado boa precisão na classificação tanto de operações legais quanto fraudulentas, com taxas de acerto acima de 90%.

Entretanto, alguns estudos quanto aos aspectos de aprimoramento das potencialidades do sistema FControl<sup>®</sup> tem sido abordadas, visando entre outros aspectos à obtenção de um melhor compromisso entre

interpolação, generalização e aprendizado de sistemas híbridos inteligentes na detecção de fraudes.

Atualmente (abril de 2005), o sistema FControl<sup>®</sup> conta com 250 clientes e um banco de dados atual com 45670 transações realizadas.

## Agradecimentos

Os autores agradecem o auxílio financeiro através de Convênio FINEP (projeto número 0.1.02.0184.00) que tornou possível o estudo, implementação e viabilidade comercial do sistema FControl<sup>®</sup> (<http://www.ciashop.com.br>).

## Referências

- [1] Y. Kou, C. -T. Lu, S. Sriwongwattana e Y. -P. Huang, "Survey of fraud detection techniques", *Proceedings of the IEEE International Conference on Networking, Sensing and Control*, Taipei, Taiwan, pp. 749-753, 2004.
- [2] Folha on-line, 15/03/2005.  
[http://jc.uol.com.br/2005/03/15/not\\_85515.php](http://jc.uol.com.br/2005/03/15/not_85515.php)
- [3] J. R. Sorronsoro, F. Ginel, C. Sánchez e C. S. Cruz, "Neural fraud detection in credit card operations", *IEEE Transactions on Neural Networks*, vol. 8, no. 4, pp. 827-834, 1997.
- [4] V. Hanagandi, A. Dhar e K. Buescher, "Density-based clustering and radial basis function modeling to generate credit card fraud scores", *Proceedings of the IEEE/IAFE Conference on Computational Intelligence for Financial Engineering*, pp. 247-251, 1996.
- [5] R. Brause, T. Langsdorf e M. Hepp, "Neural data mining for credit card fraud detection", *11th IEEE International Conference on Tools for Artificial Intelligence*, pp. 103-106, 1999.
- [6] S. -C. Chi, R. -J. Kuo e P. -W. Teng, "A fuzzy self-organizing map neural network for market segmentation of credit card", *Proceedings of IEEE International Conference on Systems, Man, and Cybernetics*, Nashville, TN, USA, pp. 3617-3622, 2000.
- [7] E. Aleskerov, B. Freisleben e B. Rao, "CARDWATCH: a neural network based database mining system for credit card fraud detection", *Proceedings of the IEEE/IAFE of Computational Intelligence for Financial Engineering*, New York, NY, USA, pp. 220-226, 1997.
- [8] R. T. Raittz, "FAN 2002: um modelo neuro-fuzzy para reconhecimento de padrões", Tese de doutorado, Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, SC, 2002.
- [9] R. T. Raittz, J. A. Souza, G. A. Dandolini, R. C. S. Pacheco, A. Martins, F. A. Gauthier e R. M. Barcia, "FAN: learning by means of free associative neurons", *IEEE World Congress on Computational Intelligence*, Anchorage, AK, USA, pp. 425-430, 1998.
- [10] N. Hansen e A. Ostermeier, "Adapting arbitrary normal mutation distributions in evolution strategies", *Proceedings of the IEEE International Conference on Evolutionary Computation*, Nagoya, Japan, pp. 312-317, 1996.
- [11] A. Ostermeier e N. Hansen, "An evolution strategy with coordinate system invariant adaptation of arbitrary normal mutation distributions within the concept of mutative strategy parameter control", *Genetic and Evolutionary Computation Conference*, GECCO, Orlando, FL, USA, pp. 902-909, 1999.
- [12] L. A. Zadeh, "Soft computing and fuzzy logic", *IEEE Software*, vol. 11, no. 6, pp. 48-56, 1994.
- [13] J. C. Bezdek, "What is computational intelligence?", *Computational intelligence imitating life*, J. M. Zurada, R. J. Marks II e C. J. Robinson, IEEE Press, Piscataway, NJ, USA, 1994.
- [14] L. A. Zadeh, "Fuzzy control: issues, contentions and perspectives", *Proceedings of 13th IFAC World Congress*, San Francisco, CA, USA, pp. 35-38, 1996.
- [15] R. Khosla e T. Dillon, *Engineering intelligent hybrid multi-agent systems*, Kluwer Academic Publishers: Boston, USA, 1997.
- [16] A. F. Shapiro, "The merging of neural networks, fuzzy logic, and genetic algorithms", *Insurance: Mathematics and Economics*, vol. 31, pp. 115-131, 2002.
- [17] D. Nauack e R. Kruse, "Neuro-fuzzy systems for function approximation", *Fuzzy Sets and Systems*, vol., 101, pp. 261-271, 1999.
- [18] J. J. Buckley e Y. Hayashi, "Fuzzy neural networks: a survey", *Fuzzy and Systems*, vol. 66, pp. 1-13, 1994.
- [19] S. Mitra e Y. Hayashi, "Neuro-fuzzy rule generation: survey in soft computing framework", *IEEE Transactions on Neural Networks*, vol. 11, no. 3, pp. 748-768, 2000.
- [20] G. J. Klir e B. Yuan, *Fuzzy sets and fuzzy logic – theory and applications*, Prentice Hall, 1995.
- [21] P. J. Angelino, "Adaptive and self-adaptive evolutionary computations", In: *Computational intelligence: a dynamic systems perspective*, edited by M. Palniswami, Y. Attikiouzel, R. Marks, D. Fogel e T. Fukuda, Piscataway, NJ, IEEE Press, pp. 152-163, 1995.
- [22] H. G. Beyer, "Toward a theory of evolution strategies: self-adaptation", *Evolutionary Computation*, vol. 3, no. 3, pp. 311-348, 1995.