

**Brazilian Journal of Forensic Sciences,  
Medical Law and Bioethics**

Journal homepage: [www.ipebj.com.br/forensicjournal](http://www.ipebj.com.br/forensicjournal)



**Uma Ferramenta Computacional Forense para Verificação de  
Autenticidade de Assinaturas Manuscritas Através de  
Processamento Digital de Imagens e Redes Neurais Artificiais**

**A Forensic Tool for Signature Authenticity Verification Through  
Digital Image Processing and Artificial Neural Networks**

Deivison Pinheiro Franco<sup>1</sup>, Nágila Magalhães Cardoso<sup>2</sup>

*1 Mestrando em Inovação Tecnológica (UNAMA), Especialista em Ciências Forenses (Ênfase em Computação Forense) (CESUPA), em Suporte a Redes de Computadores e Tecnologias Internet (UFPA) e Graduado em Tecnologia em Processamento de Dados (UNAMA)*

*2 Especialista em Segurança Computacional (IESAM) e Graduada em Tecnologia em Redes de Computadores (FCAT)*

<sup>a</sup> E-mail: [deivison.pfranco@gmail.com](mailto:deivison.pfranco@gmail.com)

Received 18 November 2013

**Resumo.** Este artigo tem como objetivo propor uma ferramenta computacional forense capaz de verificar a autenticidade de assinaturas manuscritas de forma automatizada, a fim de auxiliar e otimizar esse processo e funcionar como um instrumento de apoio à decisão. A metodologia desta proposta baseou-se na utilização de técnicas de processamento digital de imagens e de redes neurais através do algoritmo de aprendizagem de backpropagation com as abordagens 500 e 901. Os resultados demonstraram um percentual médio de erro de 20% na primeira e de 5,83% na segunda, sendo que o desempenho de um profissional treinado para verificar autenticidade de assinaturas apresenta, em média, 6,67% de erro. Dessa forma, pôde-se observar a eficiência da ferramenta proposta, bem como a diferença e evolução das abordagens através da relevância dos resultados.

**Palavras-Chave:** Verificação de Autenticidade; Assinaturas Manuscritas; Grafoscopia, Redes Neurais; Processamento Digital de Imagens.

**Abstract.** This paper aims to propose a computational forensics tool able to verify the authenticity of handwritten signatures in an automated way, to help and optimize this process

and act as a tool for decision support. The methodology of this proposal was based on the use of techniques of digital image processing and neural networks through the backpropagation learning algorithm with 500 and 901 approaches. The results showed an average percentage error of 20% in the first and of 5.83% in the second, and the performance of a trained professional to verify the authenticity of signatures has an average error of 6.67%. Thus, we could observe the efficiency of the proposed tool, as well as the difference and evolution of approaches through the relevance of the results.

**Keywords:** Authenticity Verification; Handwritten Signatures; Graphoscopy; Neural Networks, Digital Image Processing.

## 1. Introdução

As assinaturas manuscritas ainda figuram como uma das formas utilizadas para a validação de autenticidade de documentos devido a sua intensa característica individualizadora aliada ao seu baixo custo e praticidade, apesar do surgimento de várias tecnologias relacionadas a esse campo como, por exemplo, a certificação digital e a biometria<sup>1</sup>. Assim, a fraude de assinaturas é um crime muito praticado no Brasil e gera prejuízos milionários a pessoas e instituições fraudadas.

Em 2009 a empresa KPMG fez uma pesquisa com o intuito de investigar e avaliar o cenário de fraudes organizacionais de uma forma geral no país e mostrou que, na época, 68% das empresas entrevistadas sofreram fraudes. Dessas organizações, 77% tiveram perdas de até 1 milhão de reais, e para 5% delas os prejuízos superaram os 10 milhões de reais. Sendo que o tipo de fraude de maior incidência detectado (29%) foi a falsificação de cheques e documentos, do qual faz parte a falsificação de assinaturas<sup>2</sup>. Entretanto, o número de casos de fraudes organizacionais no Brasil é bem maior do que se é divulgado publicamente, pois as empresas vítimas têm receio da exposição pública negativa, o que geraria danos à reputação e à imagem, e perdas financeiras ainda maiores por conta disso<sup>3</sup>.

A grafoscopia é a disciplina que certifica um profissional para realizar a verificação de autenticidade de assinaturas através de conceitos e técnicas que servem de base para se executar conferências de forma segura e com resultados eficazes<sup>4</sup>. Dessa forma, a atuação do grafoscopista abrange as áreas de perícia criminal e processos judiciais, além de bancos, seguradoras, cartórios e demais instituições financeiras. Sendo inquestionável a relevância de sua atuação, visto que está diretamente ligado à segurança das mais variadas instituições onde atua, bem como à de seus usuários/clientes, além de poder figurar como prova determinante na resolução de crimes e contravenções. Porém, aliado ao intenso volume de trabalho, esse profissional está sujeito a diversos fatores externos no exercício de suas atribuições, como cansaço, *stress* e problemas pessoais, os quais podem comprometer seus resultados.

O cansaço físico pode resultar em observações equivocadas e o cansaço mental favorece o esquecimento, a repetição desnecessária ou a omissão de algum exame. Tais falhas podem trazer perdas e constrangimentos, tanto para o profissional e para a organização onde trabalha, quanto para seus usuários e clientes, ou ainda inocentar culpados ou até mesmo incriminar inocentes em processos judiciais<sup>4</sup>.

A fim de automatizar o processo de análise de autenticidade de assinaturas manuscritas e auxiliar o profissional em grafoscopia com um instrumento de apoio à tomada de decisão, o presente trabalho propõe a criação de uma ferramenta forense computacional que consiga fazer essa verificação de forma automatizada com a utilização de técnicas de processamento digital de imagens e de redes neurais artificiais através do algoritmo de aprendizagem de *backpropagation*, que é capaz de extrair padrões de “assinaturas-modelo” para comparação com uma ou mais assinaturas de teste e definição do seu grau de autenticidade. Também foram utilizados conceitos de grafoscopia para classificação das assinaturas, análise e interpretação dos resultados.

## 2. Metodologia para a Construção da Ferramenta

As Redes Neurais Artificiais (RNAs) constituem um dos ramos da Inteligência Artificial (IA) que visa o processamento de informações de forma similar ao cérebro humano<sup>5</sup>. Já o *backpropagation* é um algoritmo supervisionado por correções de erros para treinamento de redes neurais artificiais multicamadas que minimiza o erro através da execução do gradiente decrescente na superfície de erros do espaço de pesos, onde a altura para qualquer ponto no espaço de pesos corresponde à medida do erro<sup>6</sup>. Sendo que os pesos começam a ser ajustados nas unidades de saída, onde a medida do erro é conhecida, e continua com a retro propagação desse erro entre as camadas, ajustando os pesos até chegar à camada das unidades de entrada.

Como nas unidades de saída os valores desejados e obtidos são conhecidos, o ajuste dos pesos sinápticos é relativamente simples. Entretanto, para as unidades das camadas ocultas, o processo não é tão simples assim. Os pesos para um neurônio particular, nas unidades ocultas, devem ser ajustados proporcionalmente ao erro da unidade de processamento a qual está conectado. Dessa forma, se consegue distinguir duas fases no processo de aprendizagem do *backpropagation*: a fase propagação (*forward*), na qual as entradas se propagam entre as camadas da rede (da entrada à saída); e a fase retro propagação (*backward*), cujos erros são propagados em sentido contrário ao fluxo de entrada<sup>6</sup>.

Diante do exposto, e para atender a proposta do emprego do algoritmo de *backpropagation*, a construção da ferramenta seguiu sequencialmente as seguintes etapas: Aquisição das Assinaturas, as quais foram digitalizadas em um aparelho *scanner* comum; Pré-Processamento e Processamento Digital das Imagens, cujos resultados são as

características extraídas para a análise; Criação, Treinamento e Teste das Redes Neurais Artificiais, de onde surgiram os resultados.

Em virtude da necessidade de revisão nas etapas de processamento digital de imagens e definição da arquitetura de redes neurais artificiais, o estudo foi dividido em duas abordagens, que serão descritas a seguir, já que a abordagem inicial não atendeu às expectativas de melhoria nas taxas de acerto.

## 2.1. Banco de Imagens

Aplicando os conceitos de processamento digital de imagens, o processo foi desenvolvido a partir da coleta de assinaturas de três autores distintos (Eric, Felipe e Rodrigo)<sup>7</sup>. Cada autor assinou vinte vezes sua própria assinatura, falsificou vinte vezes a do segundo autor, e falsificou também vinte vezes a do terceiro autor. O que resultou em um total de sessenta assinaturas de cada e um total geral de cento e oitenta amostras, como mostrado na Tabela 1. Sendo assim, utilizou-se um único banco de imagens, visto que seu processo de aquisição foi o mesmo para ambas as abordagens.

A digitalização das amostras foi realizada a partir de um aparelho *scanner* comum. Em seguida, cada imagem foi redimensionada, gerando imagens com o tamanho dentro da faixa de, no máximo, 731 *pixels* de largura por 180 de altura e, no mínimo, 650 *pixels* de largura por 117 de altura, todas no formato “.png”.

**Tabela 1.** Assinaturas coletadas por autor.

<b>Assinaturas</b>	<b>Com o nome do Autor 1 (Eric)</b>	<b>Com o nome do Autor 2 (Felipe)</b>	<b>Com o nome do Autor 3 (Rodrigo)</b>
<b>Escritas pelo Autor 1 (Eric)</b>	20 (autênticas)	20 (falsas)	20 (falsas)
<b>Escritas pelo Autor 2 (Felipe)</b>	20 (falsas)	20 (autênticas)	20 (falsas)
<b>Escritas pelo Autor 3 (Rodrigo)</b>	20 (falsas)	20 (falsas)	20 (autênticas)

## 2.2. Abordagens

Foram utilizadas duas abordagens: a Abordagem 500 e a Abordagem 901 – ambas com características de processamento de imagens e configurações de rede diferentes, sendo que a segunda surgiu como uma evolução da primeira.

As duas abordagens utilizadas na elaboração da ferramenta possuem *scripts* e funções para automatização do processo e, além disso, baseiam-se na ideia de se utilizar, a partir da matriz de *pixels*, características de dimensão única para a camada de entrada nos

algoritmos de reconhecimento de assinaturas através de projeção vertical (soma dos *pixels* de cada coluna) e de projeção horizontal (soma dos *pixels* de cada linha da matriz).

Em ambas as abordagens utilizou-se a ferramenta *Matlab* na versão R2008a para executar os procedimentos de pré-processamento, segmentação e extração de características das imagens; e de criação, treinamento e testes das RNAs.

A diferença entre as características das abordagens torna-se mais evidente a partir deste tópico, as quais se distinguem nas etapas de pré-processamento e de extração de características; arquiteturas de rede; e exemplos de assinaturas apresentados às RNAs em um mesmo conjunto de treinamento.

Considerando que as arquiteturas são bem distintas e que cada uma define quantidades diferentes de nós nas camadas sensoriais das RNAs, a abordagem inicial foi chamada de Abordagem 500, por instituir quinhentas entradas e a subsequente chamada de Abordagem 901, ao delimitar novecentas e uma entradas. Tais abordagens são melhores descritas a seguir com seus respectivos processos inerentes à construção da ferramenta.

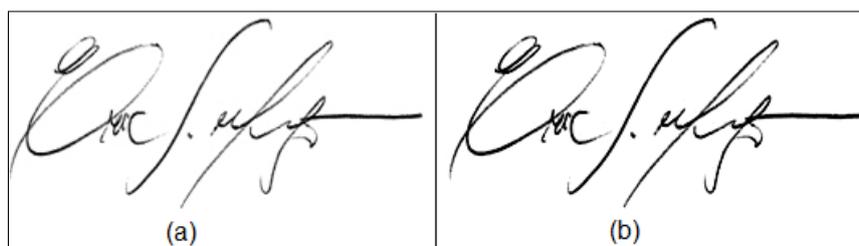
### **2.2.1. Abordagem 500**

#### **Rotinas de pré-processamento das imagens**

Rotinas de pré-processamento das imagens:

1. Capturar a amostra reconhecida como matriz tridimensional, representando a escala RGB de cores;
2. Transformação em escala de cinza, cujo formato matricial se torna bidimensional, facilitando a manipulação, por envolver menos variáveis para os cálculos necessários, tanto no processamento, quanto em treinamento;
3. Ajuste de contraste, onde os *pixels* da imagem são realçados e é destacada a diferença de intensidade entre as tonalidades mais escuras e as mais claras;
4. Ajuste na equalização do histograma, produzindo aumento na intensidade de brilho e também de contraste;
5. Redimensionamento, o qual reduz a imagem para o tamanho pré-definido de 400 *pixels* de largura por 100 *pixels* de altura;
6. Binarização através de uma operação de lógica, com o objetivo de fazer a remoção do fundo e das tonalidades mais claras, ou seja, a segmentação, de modo que a região da assinatura se torne preta e as regiões restantes brancas.

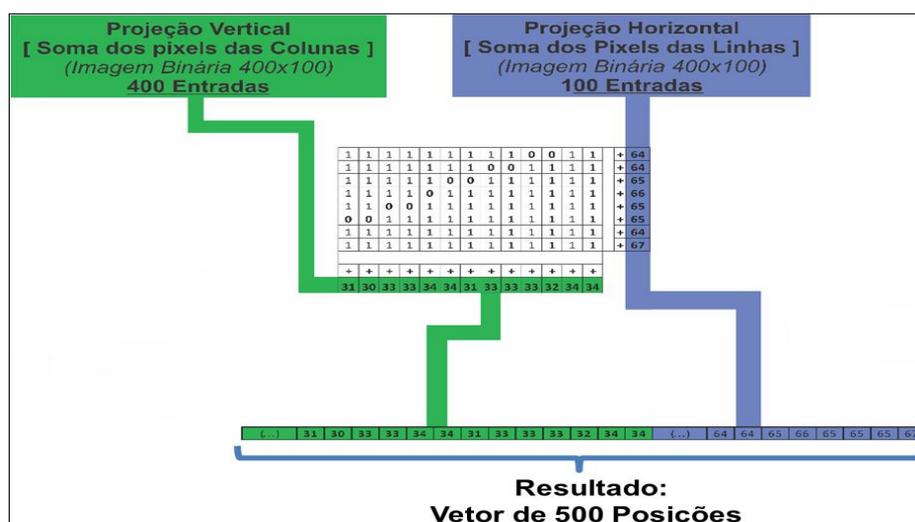
Diante do exposto, a Figura 1, a seguir, mostra imagens de uma mesma assinatura em relação à equalização de histograma.



**Figura 1.** Equalização de histograma: (a) assinatura capturada sem equalização; (b) assinatura capturada com equalização.

### Extração das características

Esta etapa consiste na geração de um vetor concatenado de 500 posições para cada assinatura, onde as 400 primeiras são referentes à soma das colunas (projeção vertical) e as outras 100 correspondem à soma das linhas (projeção horizontal) da imagem, como é mostrado na Figura 2. Esse vetor representa as características extraídas da imagem da assinatura a que corresponde, e funciona como exemplo de entrada no conjunto de treinamento ou de teste da RNA da Abordagem 500.



**Figura 2.** Extração das características de assinaturas na Abordagem 500.

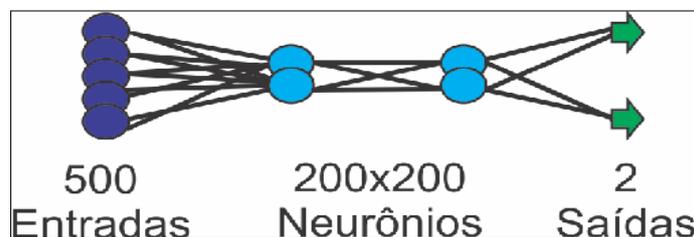
### Rede Neural Artificial

De maneira geral, houve vários treinamentos, contudo, foi destacada na Abordagem 500 apenas uma RNA, denominada de “Eric45”, por ter sido a rede que apresentou melhores resultados nesta abordagem. O nome atribuído a essa rede é composto pelo primeiro nome do autor analisado seguido do número de exemplos apresentados a essa RNA em seu conjunto de treinamento. Dessa forma, a arquitetura da rede “Eric45” foi composta de:

- ✓ 1 rede direta, multicamadas e totalmente conectada;
- ✓ 500 entradas, correspondente ao vetor de 500 posições;
- ✓ 2 camadas intermediárias com 200 neurônios em cada;

- ✓ 2 neurônios na camada de saída, dos quais um é ativado em caso de autenticidade, e o segundo em caso de falsidade.

Uma melhor visualização da arquitetura da rede “Eric45” na Abordagem 500 pode ser vista na Figura 3, a seguir.



**Figura 3.** Forma da arquitetura da rede “Eric45” na Abordagem 500.

Diante do exposto, pode-se observar e atribuir as seguintes configurações e características da RNA “Eric45”:

- ✓ Possui até 1000 épocas para realizar o aprendizado;
- ✓ O erro médio quadrático a ser alcançado é  $10^{-3}$ ;
- ✓ Utiliza o algoritmo de *backpropagation* por possuir grande capacidade de generalização e possibilitar o aprendizado supervisionado;
- ✓ O treinamento é feito com aprendizado supervisionado, uma vez que se conhecem as classes que a rede deve distinguir;
- ✓ A taxa de aprendizagem é adaptativa;
- ✓ Utiliza-se o *momentum*;
- ✓ Utiliza-se a função de ativação logística, onde os valores de resposta previstos estão no intervalo aberto entre 0 e 1.

### Conjunto de treinamento

Para a Abordagem 500, o conjunto de treinamento foi criado com 45 assinaturas, no intuito de reconhecer a assinatura do autor Eric. De cada um dos três autores foram utilizadas 15 assinaturas com o nome de Eric, sendo as 15 primeiras autênticas, ativando o 1º neurônio da camada de saída; e as outras 30 falsificações por imitação servil (grafadas por Felipe e Rodrigo), ativando o 2º neurônio da camada de saída.

### 2.2.2. Abordagem 901

A Abordagem 901 surgiu a partir da necessidade de correção dos erros da Abordagem 500, além da tentativa de melhoria de desempenho. Muitos parâmetros foram alterados conforme se pode observar na descrição das etapas a seguir.

## Rotina de pré-processamento das imagens

A rotina de pré-processamento das imagens é sequenciada abaixo.

1. Captura da imagem em formato RGB;
2. Transformar em escala de cinza;
3. O ajuste de contraste sofreu modificações no que diz respeito à intensidade do ajuste. A função utilizada foi a mesma, entretanto alterou-se manualmente a intensidade, ao contrário da forma automática da abordagem anterior;
4. Não se utilizou o ajuste na equalização de histograma, visto que essa prática acentuava a presença de ruídos na imagem, os quais poderiam interferir no aprendizado da rede;
5. Devido à detecção de alguns pontos de ruído nas amostras apresentadas ao algoritmo de processamento, fez-se uma varredura com intuito de transformar em branco todos os *pixels* na região das bordas da imagem;
6. Após a remoção manual dos *pixels* indesejados, tornou-se possível o recorte da amostra, reduzindo a imagem à área do retângulo exato que delimita o tamanho da assinatura;
7. Criou-se uma cópia da imagem, a qual foi reduzida, para o tamanho de 40 *pixels* de largura e 10 *pixels* de altura, e posteriormente binarizada, de modo que cada *pixel* pudesse ser utilizado como entrada para a RNA;
8. Com a imagem original, realizou-se o cálculo da razão entre largura e altura (Largura/Altura), de modo que o resultado fosse utilizado como uma entrada da rede;
9. E, por fim, foram realizados os procedimentos de binarização e redimensionamento dessa amostra para o tamanho de 400 *pixels* de largura por 100 *pixels* de altura, retirando-se a somatória de cada uma das linhas e das colunas.

A Figura 4, a seguir, apresenta os procedimentos principais do pré-processamento das imagens.



**Figura 4.** Procedimentos do pré-processamento das imagens.

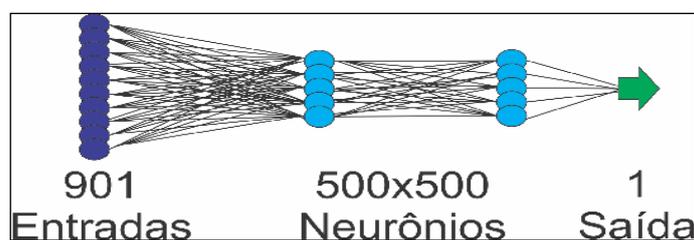
## Extração das características

Diferente da abordagem anterior, o vetor resultante na Abordagem 901, que é utilizado nos processos posteriores de treinamento e testes, é composto por 901 posições, sendo:



- ✓ De 1 a 400, o valor mínimo é 0 e o máximo é 1, visto que cada entrada corresponde a um pixel da matriz binária de pixels da imagem 40x10;
- ✓ De 401 a 800, o valor mínimo é 0 e o máximo é 100, pois correspondem à projeção vertical da assinatura em formato 400x100;
- ✓ De 801 a 900, mínimo de 0 e máximo de 400, considerando a projeção horizontal da matriz 400x100;
- ✓ Na posição 901, o valor mínimo é 0 e o máximo é 10, de acordo com os tamanhos originais das imagens adquiridas.

Uma melhor visualização da arquitetura das redes “Eric45”, “Felipe40”, “Rodrigo40” e “Eric40” na Abordagem 901 podem ser vistas na Figura 6, a seguir.



**Figura 6.** Forma da arquitetura das redes “Eric45”, “Felipe40”, “Rodrigo40” e “Eric40” na Abordagem 901.

Diante do exposto, pode-se observar e atribuir as seguintes configurações e características das RNAs “Eric45”, “Felipe40”, “Rodrigo40” e “Eric40”:

- ✓ Compreenderam 15.000 épocas para o treinamento;
- ✓ Utilizaram o algoritmo de *backpropagation* com taxa de aprendizado adaptativa e *momentum*;
- ✓ As saídas dentro do intervalo entre 0 e 1, utilizaram função de ativação logística;
- ✓ Erro médio mínimo quadrático atingido de  $10^{-3}$ .

### Conjunto de Treinamento

Para a Abordagem 901, os conjuntos de treinamento utilizados possuíam distinções quanto à quantidade de amostras utilizadas, conforme apresenta a Tabela 2.

Diante do exposto, pôde-se observar que na Abordagem 901 o conjunto de treinamento de cada rede é formado pelas amostras originais mais as falsas e mais os nomes dos outros autores. Sendo que as primeiras foram formadas por dez assinaturas genuínas do autor analisado, exceto na rede “Eric35” - composta de cinco assinaturas.

Enquanto que os conjuntos de amostras falsas são compostos por dez falsificações por imitação servil da assinatura do autor analisado, sendo cinco de cada um dos dois outros autores, os conjuntos de amostras com os nomes dos outros autores são formados

por: cinco assinaturas autênticas de um segundo autor; cinco assinaturas autênticas de um terceiro autor; cinco falsificações por imitação servil da assinatura do segundo autor; e cinco falsificações deste último tipo da assinatura do terceiro autor. De modo que todas elas se comportam como falsificações sem imitação do autor analisado.

**Tabela 2.** Conjuntos de treinamentos na Abordagem 901.

Rede	Autor analisado	Amostras originais	Amostras falsas	Amostras com os nomes dos outros autores	Total de exemplos
<b>Eric35</b>	Eric	5	10	20	35
<b>Felipe40</b>	Felipe	10	10	20	40
<b>Rodrigo40</b>	Rodrigo	10	10	20	40
<b>Eric40</b>	Eric	10	10	20	40

### 3. Análise e discussão dos resultados

Neste item serão apresentados os resultados dos testes aplicados nas redes que compõem a ferramenta proposta, sendo exibidas as taxas de erro e acerto de cada uma. Também serão descritos os percentuais dos dois tipos de erro encontrados, tais como: aceitação de assinaturas falsas (falso positivo) e rejeição de assinaturas autênticas (falso negativo).

#### 3.1. Abordagem 500

Os resultados da rede “Eric45” foram adquiridos a partir da criação de um conjunto de teste com 25 assinaturas (diferentes das utilizadas no conjunto de treinamento), definido da seguinte forma:

- ✓ 5 assinaturas autênticas do autor Eric ;
- ✓ 5 falsificações por imitação servil grafadas pelo autor Felipe;
- ✓ 5 falsificações por imitação servil produzidas pelo autor Rodrigo;
- ✓ 5 assinaturas autênticas do autor Felipe, funcionando neste contexto como falsificações sem imitação;
- ✓ 5 assinaturas autênticas do autor Rodrigo, também funcionando como falsificações sem imitação.

O aprendizado da rede “Eric45” resultou em 80% de taxa de acerto nos testes, ou seja, 20 assinaturas do espaço amostral apresentado. Os gráficos da Figura 7, abaixo, resumem as informações sobre os resultados obtidos para essa rede. O primeiro apresenta os acertos e erros para a rede em questão, enquanto que o segundo ilustra a separação dos tipos de erros de aprendizado verificados para a mesma.

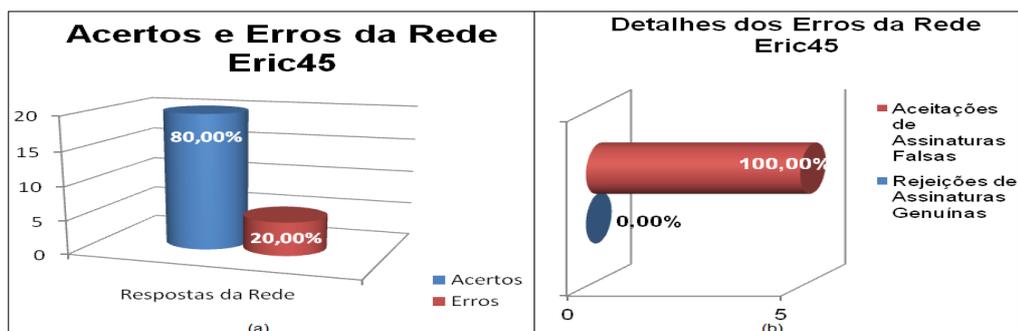


Figura 7. Resultados obtidos para a rede “Eric45”: (a) Acertos e erros; (b) Tipos de erros.

### 3.2. Abordagem 901

A Tabela 3, a seguir, sintetiza os resultados dos testes efetuados em todas as redes treinadas nesta abordagem (“Eric45”, “Felipe40”, “Rodrigo40” e “Eric40”), apresentando seus acertos e erros, bem como os valores referentes à aceitação de amostras não autênticas e rejeição de assinaturas originais.

Tabela 3. Resultados dos testes aplicados às redes da Abordagem 901.

Amostras no conjunto de testes	Rede	Acertos	% de acertos	Erros	% de erros	Rejeições de assinaturas originais	Aceitação de assinaturas falsas
60	Eric35	55	91,67	5	8,33	5	0
60	Felipe40	52	86,67	8	13,33	2	6
60	Rodrigo40	59	98,33	1	1,67	1	0
60	Eric40	60	100	0	0	0	0

### 3.3. Teste com um profissional de grafoscopia

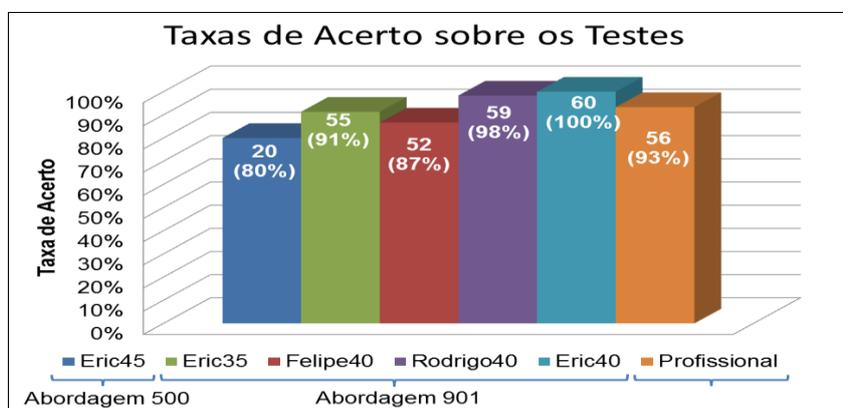
Foram realizados testes com um profissional da área de grafoscopia efetivo do Banco do Brasil, com 15 anos de experiência como conferente de assinaturas, de modo a comparar seu desempenho com o da rede “Eric35”, devido esta ser a única rede implementada no momento da disponibilidade do profissional. Portanto, neste procedimento foram utilizadas apenas as amostras dos conjuntos de treinamento (consulta aos padrões) e de testes (assinaturas questionadas) dessa RNA. Os resultados dos testes realizados com o profissional estão detalhados a seguir na Tabela 4.

**Tabela 4.** Resultados dos testes aplicados ao grafoscopista.

Amostras analisadas	Acertos	% de acertos	Erros	% de erros	Rejeições de assinaturas originais	Aceitação de assinaturas falsas
60	56	93,33	4	6,67	3	1

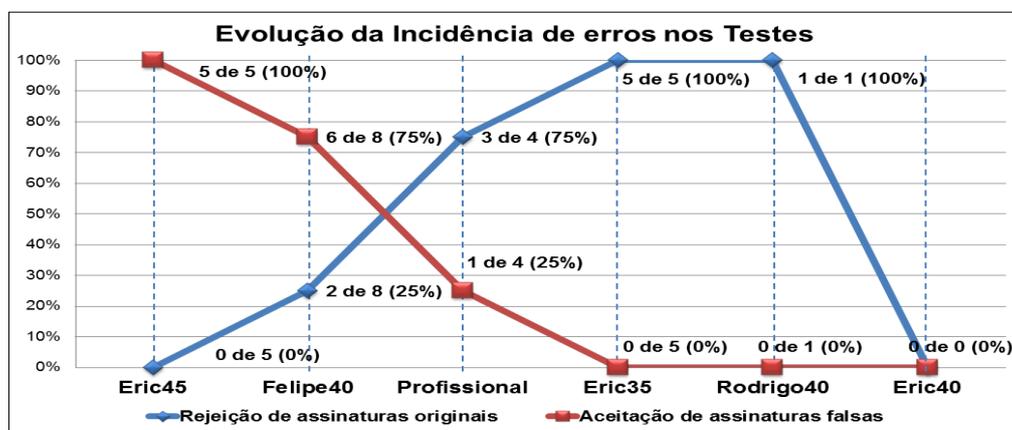
### 3.4. Comparação dos resultados

De posse dos resultados dos testes de todas as redes das Abordagens 500 e 901, bem como do grafoscopista, traçou-se a comparação das taxas de acerto, como mostrado na Figura 8, a seguir.



**Figura 8.** Gráfico das taxas de acerto das redes e do grafoscopista.

Também foi observada a evolução dos tipos de erros incididos nos testes das redes e do grafoscopista, como mostra o gráfico da Figura 9, que apresenta a porcentagem de aceitação de respostas falsas e de rejeição de respostas verdadeiras.



**Figura 9.** Evolução do percentual de tipos de erro apresentados pelas redes estudadas e pelo grafoscopista consultado.

Diante dos resultados expostos, verificou-se que na Abordagem 500, apesar da considerável taxa de acerto, 100% dos erros da rede foram casos de aceitação de falsificações, o que constitui falha grave na verificação de autenticidade de assinaturas, uma vez que causa danos maiores em relação à rejeição de assinaturas autênticas. Esses fatores levaram à conclusão de que as técnicas utilizadas naquele momento exigiam alterações em relação ao formato, quantidade e variedade dos exemplos, bem como modificações nas quantidades de neurônios nas três camadas da rede, a fim de que houvesse melhores soluções. Logo, os esforços foram direcionados à reformulação do método de resolução, justificando a existência da Abordagem 901.

Na Abordagem 901, os tempos de treinamento cresceram exponencialmente, bem como o número de épocas necessárias; as saídas passaram a serem menos difusas, uma vez que a análise foi realizada com base apenas no único neurônio da camada de saída.

Ao traçar um paralelo entre as redes “Eric45” e “Eric35”, cujo treinamento foi para reconhecimento da assinatura do autor Eric, nota-se considerável melhoria, uma vez que a RNA inicial possuía taxa de erro de 20%, dentre os quais, 100% eram caracterizados por aceitação de assinaturas falsas. Já a rede “Eric35” apresentou 8,67% de erro, onde este conjunto era apenas composto por rejeição de assinaturas originais.

Comparando-se a rede “Eric35” com o grafoscopista, percebe-se que os resultados da RNA estão aquém deste em quantidade de acertos. Entretanto, a qualidade da implementação mostrou-se superior, por consequência do único erro do profissional incluído no conjunto de aceitação de assinaturas não autênticas.

A rede “Felipe40”, treinada para a assinatura do autor Felipe, apresentou a maior quantidade de erros da Abordagem 901, além de aceitar amostras não autênticas.

Os testes na rede “Rodrigo40” retornaram apenas 1,67% de acerto, na Abordagem 901, apresentando bastantes rejeições de assinaturas originais, o que possibilitou a conclusão de que ainda há dificuldade de reconhecimento do padrão de assinaturas, de modo que existem diferenças dentro do conjunto de exemplos autênticos que podem ser visivelmente percebidas. Um exemplo disso é o resultado da análise do grafoscopista, que também errou exemplos verossímeis.

A rede “Eric40”, cujos resultados foram os melhores, apresentou 100% de acerto sobre o conjunto de testes. No entanto, devido à constatação das distinções entre as assinaturas autênticas, não há garantia de que a rede irá se comportar da mesma forma no caso de testes para quaisquer outros exemplos, mesmo que eles sejam enquadrados nos padrões adotados para a formação do banco de imagens.

O fato de a rede “Felipe40” apresentar menor taxa de acerto entre as três redes de mesma arquitetura e configuração de conjunto de treinamento (“Felipe40”, “Eric40” e “Rodrigo40”), pode ser atribuído à cultura gráfica mediana das assinaturas-padrões de Felipe.

As redes “Rodrigo40” e “Eric40”, cujas assinaturas padrões são de alta cultura gráfica, obtiveram maiores taxas de acerto. Contudo, a rede “Eric40” apresentou taxa maior porque as assinaturas-padrões de Eric possuem mais zonas de facilidade que as de Rodrigo. Dessa forma, pressupôs-se que a taxa de acerto dos testes sobre as redes é diretamente proporcional ao nível da cultura gráfica das assinaturas-padrões do autor analisado.

#### **4. Considerações finais**

No desenvolvimento da ferramenta houve pouca variedade de assinaturas-padrões de autores distintos, além de considerável influência sobre a qualidade das amostras, uma vez que o aparelho utilizado para a digitalização e a estratégia de redação das assinaturas adaptou o ambiente para facilitar as coletas e análises.

O projeto não levou em consideração fatores externos como: cor, materiais (lápiz ou caneta), forma do papel e alterações psicológicas de humor ou disposição dos autores. Além disso, a combinação de características extraídas ainda pode estar aquém do necessário para possibilitar grande generalização sem perder a confiabilidade de reconhecimento de cada padrão de assinatura. De maneira que as conclusões inferidas sobre os resultados obtidos podem não apresentar o mesmo comportamento em todos os ambientes e padrões de assinaturas existentes, mesmo que as respostas apresentadas sejam consideradas perfeitamente aplicáveis.

Para trabalhos futuros, propõe-se: coleta de exemplos de outros autores, tanto para o conjunto de treinamento quanto para o de testes; adição de novas características extraídas das imagens às redes; validação cruzada das amostras do banco de imagens para extração dos melhores conjuntos de treinamento e de testes a fim de otimizar os resultados; considerar fatores externos como cor, materiais (lápiz ou caneta), forma do papel e alterações psicológicas de humor ou disposição dos autores; e a implementação de uma aplicação comercial para a ferramenta.

Por fim, a ferramenta pode ser considerada perfeitamente válida e viável, visto que alcançou resultados relevantes na verificação de autenticidade de assinaturas. Cabendo ressaltar que não existe, até então, um modelo consolidado, e sim um grande crescimento em estudos de técnicas relacionadas ao assunto. Portanto, esta proposta visa colaborar com o amadurecimento da temática que gira em torno do uso da Inteligência Artificial como apoio à decisão em situações que apresentem um elevado grau de complexidade, como é o caso da verificação de autenticidade de assinaturas.

## Referências Bibliográficas

1. Queiroz F, Sousa A. Exames Periciais a Documentos Manuscritos. Disponível em: <[www.queirozportela.com/psicologiadadaescrita/pericias.pdf](http://www.queirozportela.com/psicologiadadaescrita/pericias.pdf)>. Acessado em Novembro de 2012.
2. KPMG. Relatório de Pesquisa Sobre Fraudes no Brasil. Disponível em: <[www.kpmg.com.br/publicacoes/forensic/Fraudes\\_2009\\_port.pdf](http://www.kpmg.com.br/publicacoes/forensic/Fraudes_2009_port.pdf)>. Acessado em Maio de 2009.
3. Theodoro A. Fraude Manuscrita: Um Risco Iminente. Disponível em: <[www.peritocontador.com.br/artigos/Adriano\\_Theodoro/fraude.htm](http://www.peritocontador.com.br/artigos/Adriano_Theodoro/fraude.htm)>. Acessado em Maio de 2013.
4. Gomide F. Manual de Grafoscopia. 2ª edição. São Paulo: Livraria e Editora Universitária de Direito, 2008.
5. Carvalho A. Redes Neurais Artificiais – Teoria e Aplicações. 2ª edição. São Paulo: LTC, 2007.
6. Rumelhart D, Chauvin Y. *Backpropagation: Theory, Architectures, and Applications*. 1ª edição. São Paulo: Wiley, 2000.
7. Gonzalez R, Woods R. Processamento Digital de Imagens. 3ª edição. São Paulo: Pearson, 2010.