

PARAMETRIZAÇÃO DE REDE MULTILAYER PERCEPTRON PARA CLASSIFICAÇÃO DE IMPRESSÕES DIGITAIS

¹ **Conrado Henrique Alves Sanches Cardoso Neves**

conradoneves.chn@gmail.com

¹ **Denis Eiras**

denis.eiras@gmail.com

¹ **Maxwell Peretta**

maxwell.peretta@gmail.com

¹ **João Roberto de Moraes**

jrmoraesengenharia@gmail.com

¹ **Reuel Adimar Lopes**

reuellopes@gmail.com

¹ **Paulo Roberto Ferreira**

paulodosax@hotmail.com

¹ **Andrei Testi**

andrei.testi@gmail.com

¹ **Jean Carlos Nascimento**

jean_carloscpv@hotmail.com

¹ **Luis Fernando de Almeida**

luis.almeida@unitau.br

¹ *UNITAU – Universidade de Taubaté, Taubaté, Brasil*

RESUMO

O presente trabalho apresenta a junção de conceitos de processamento digital de imagens e redes neurais artificiais para o reconhecimento de indivíduos a partir de impressão digital. Como principal objetivo, destaca-se o estudo da rede neural *Multilayer Perceptron* para o processo de treinamento e reconhecimento de padrões de impressões digitais. Foi observado o processo para reconhecimento de minúcias em digitais, armazenamento de dados significantes para redes neurais processarem, após coleta de amostras. Além disso, nota-se resultados satisfatórios, com grande taxa de eficácia da rede neural apresentada para a base de dados utilizada. Na primeira seção deste trabalho, Introdução, será apresentada uma contextualização e especificação do que foi proposto; em seguida, em Fundamentação Teórica, é fornecida uma base e explicação de termos para entendimento do trabalho; enquanto que em Metodologia é mencionado como foi realizada a pesquisa para, na sequência, apresentar os Testes e Resultados, e, por fim, em Conclusão, averiguar sucintamente o que foi apresentado, assim como propor estudos futuros.

Palavras-chave: Redes Neurais; Digitais; Reconhecimento; Minúcias; Automação.

ABSTRACT

This paper presents a combination of concepts of digital image processing and artificial neural networks for people recognition using their fingerprint. The main objective here is to study the Multilayer Perceptron neural network for the training process and recognition of fingerprint patterns. In summary, it was observed a process for minutiae recognition presented in fingerprints, storing their significant data for neural network training. Furthermore, satisfactory results were observed as the neural network had a high efficiency rate for Correctly Classified Instances when using the collected data used in this research. In the first section of this work, Introduction, it is given a contextualization and specification of what was proposed; next, in Theoretical Review, it is provided a basis and an explanation of terms for understanding the next sections; in Methodology is presented how the research was done to, in sequence, present its results in Tests and Results and; finally, in Conclusion, there is a briefly ascertain of what was presented, as well as a proposition of future studies.

Keywords: Neural Networks; Fingerprints; Recognition; Minutiae; Automation.

1. INTRODUÇÃO

Biometria (“Bio” = vida; “metria” = medida) refere-se à característica ou métrica que identifica de forma única o indivíduo, conforme Liu e Silverman (2001). Existem várias formas de identificação biométrica, tais quais: o reconhecimento facial, o reconhecimento de voz, o reconhecimento de íris, o reconhecimento de assinatura, o reconhecimento de impressão digital, entre outros.

A impressão digital, segundo Gumz (2002), é compreendida pela reprodução do desenho digital sobre uma superfície. Também conhecida pelo acrônimo ID, a impressão digital é a forma que exibe maior confiabilidade de identificação biométrica, sendo utilizada em tribunais de justiça como prova criminalística, de acordo com Casado e Paiva (2008), por apresentar principalmente a unicidade e a imutabilidade, visto que mesmo irmãos gêmeos possuem IDs diferentes e estas se mantêm durante toda a vida, como evidenciado em Prabhakar (2001).

A identificação de um indivíduo por meio de suas impressões digitais é feita através da classificação e quantificação de suas minúcias. As minúcias podem ser consideradas acidentes nas papilas ou discontinuidades, de acordo com Mazi e Júnior (2009). A Figura 1 demonstra alguns tipos de minúcias.

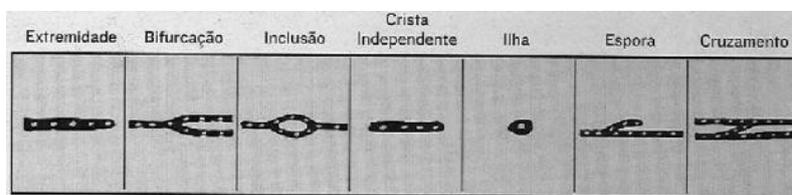


Figura 1 – Alguns exemplos de minúcias. Fonte: CASADO & PAIVA (2008).

Existem diversas formas de extração e classificação das minúcias. Neste trabalho, foram implementados algoritmos de tratamento de imagens e de reconhecimento de minúcias e, para validação das mesmas, utilizou-se redes neurais artificiais por meio do *software* Weka.

As redes neurais artificiais, segundo Gumz (2002), têm por objetivo o aprendizado autônomo similar ao sistema nervoso e usualmente são aplicadas em situações nas quais existem dados confusos, visando principalmente classificá-los, como evidenciado em Tafner (1995). Dessa maneira, percebe-se a viabilidade da utilização destas, pois as minúcias exibem diferentes tamanhos, tipos e posições nas impressões digitais.

O principal objetivo deste trabalho é, portanto, realizar estudo prático de identificação de um indivíduo por meio de sua digital aplicando tratamento de imagens e redes neurais artificiais *Multilayer Perceptron*. Para alcançar tal objetivo, o mesmo precisa ser dividido em objetivos específicos, que seguem: capturar imagens de impressões digitais de diferentes pessoas; realizar tratamento de imagem a fim de extrair características provenientes das minúcias das impressões digitais; construir uma base dos dados coletados dos usuários; treinar uma rede neural *Multilayer Perceptron* capaz de confirmar o usuário identificado com sua digital cadastrada.

Dessa maneira, aplicam-se conceitos de processamento de imagens digitais e de redes neurais artificiais para empregar a automação no reconhecimento de indivíduos. Além disso, é possível observar a existência de sistemas comerciais similares, como em caixas eletrônicos de bancos, smartphones modernos e autenticação em eleições, por exemplo, com a identificação e confirmação da identidade de usuários por meio de impressões digitais.

2. REFERENCIAL TEÓRICO

2.1. Impressão Digital

Os vincos da pele dos dedos das mãos e dos pés formam as Impressões Digitais (ID). A ciência que prova as características de IDs foi chamada de Dactiloscopia, cujo estudos se iniciaram em 1667, segundo Mazi (2009). A pele humana é constituída de duas camadas, a derme, que é a camada mais profunda e apresenta elevações chamadas de papilas dérmicas, as quais aparecem através da epiderme, que é uma camada translúcida que recobre a derme, tornando evidente as elevações das papilas dérmicas. Essas também são conhecidas como cristas e separadas por sulcos, que distinguem uma ID. Algumas características inerentes aos desenhos formados pelas papilas são:

- Unicidade: pessoas diferentes não possuem a mesma identificação;
- Imutabilidade: as características da impressão permanecem a mesma ao longo da vida de cada indivíduo;
- Praticabilidade: os desenhos papilares são fáceis de serem coletados;
- Classificabilidade: só é possível classificar os desenhos papilares, porque esses pertencem a um número de tipos fundamentais, apesar das inúmeras minúcias.

As variâncias das cristas ajudam a identificação do indivíduo; contudo, existem algumas alterações das linhas que podem ser classificadas como: interrompidas, bifurcadas, entre outros. Esses pontos são chamados de minúcias, os quais são utilizados na fase de identificação, e com exemplos na Figura 2.

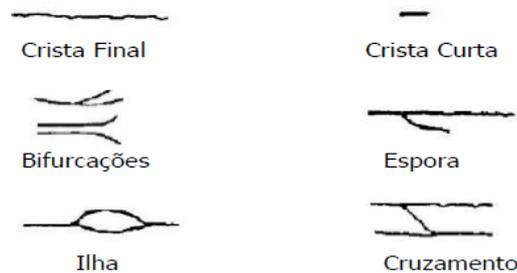


Figura 2 – Outros exemplos de minúcias. Fonte: Mazi e Júnior (2009).

Segundo Terje Kristensen (2012), com o aumento da capacidade dos computadores, o primeiro Sistema Automático de Identificação de Impressões Digitais foi criado em 1991 e, desde então, vem se investindo em pesquisas e desenvolvimento com intuito de diminuir o tempo de processamento para a identificação. Para reduzir esse tempo deve se dividir o banco de dados das impressões em diferentes subclasses, com base em propriedades, ficando apenas uma parte das impressões digitais a serem consideradas para correspondência.

A unicidade das impressões digitais foi exaustivamente testada e ainda não se encontraram digitais idênticas (Pankantietal, 2002). Porém, atualmente os sistemas não utilizam todas as informações discriminatórias inerentes às impressões, aumentando assim a possibilidade de classificar duas impressões idênticas. As técnicas biométricas são as mais utilizadas para a ID, o grande problema é criar algoritmos que eliminem ou amenizem os ruídos, aumentando a precisão.

2.2. Reconhecimento de Minúcias Utilizando Redes Neurais

A utilização de Redes Neurais tem se mostrado bastante promissora no processo de identificação de minúcias de digitais, atingindo um alto grau de acerto. Como exemplo, pode-se citar o trabalho proposto por El-Fegui et al (2011), o qual mostrou que o método utilizado na extração de características atingiu 98% de acerto. Mehran e Kazem (2008) atingiram 99,02% na detecção de minúcias utilizando quatro classes em redes neurais *feed forward*. Anil et al. (1999) utilizaram uma rede *feed forward* multicamadas, com 192 neurônios na camada de entrada, 20 neurônios na camada oculta e 5 neurônios na camada de saída, para classificar 5 classes de minúcias, através do treinamento com um algoritmo rápido do tipo *Backpropagation* para atingir uma taxa de acerto de 86,4%. A mesma rede foi capaz de atingir uma taxa de 92,1% considerando 4 camadas.

Segundo El-Fegui et al. (2011), um sistema completo de reconhecimento de digitais deve conter três estágios: O primeiro estágio deve detectar o local das mais importantes características da imagem de digital, o que é difícil e complicado devido à orientação e escala da imagem. O segundo estágio deve extrair as características pertinentes da imagem e o terceiro estágio envolve a classificação das imagens baseada no vetor de características obtido no segundo estágio. A classificação do terceiro estágio pode ser realizada através de Redes Neurais Artificiais.

A classificação das digitais comumente é feita através da rede neural *Multilayer Perceptron* (MLP), e o treinamento é utilizando o algoritmo de *Backpropagation*. O MLP tem se mostrado rápido na fase de treinamento, atingindo uma ótima eficácia na detecção de minúcias. Os resultados têm mostrado que a acurácia da abordagem de redes neurais é equivalente ou superiora se comparada a outros métodos, além de serem métodos mais simples, generalistas e possuírem uma grande capacidade de aprendizado (EL-FEGUI et al., 2011).

Para exemplificar o uso de redes neurais para identificar minúcias, no trabalho de Gour et al. (2008), a localização dos pontos de minúcias é iniciada através do seu método denominado “Contorno do cume do ponto médio”. A localização é então passada para a rede MLP treinada com o algoritmo *backpropagation*. O resultado foi comparado com o método de afinamento de minúcias, e foi demonstrado que a utilização das redes neurais é mais rápida e não identificou nenhuma falsa minúcia.

O Instituto ANSI (*American National Standard Institute*) propôs a classificação de minúcias baseada em quatro classes: terminações, bifurcações, trifurcações, e uma última classe “não determinada”. O método proposto por Gour et al. (2008) utilizou apenas duas classes: terminações e bifurcações. A rede MLP proposta consiste de 9 neurônios na primeira camada, 5 neurônios na camada oculta e um neurônio na camada de saída, correspondendo às minúcias identificadas. Para identificar uma minúcia, é realizado um pré-processamento de uma área de imagem que é convertida em uma imagem 3x3 pixels contendo a cor branca ou preta. Dependendo do padrão da imagem, ela pode ser considerada uma minúcia de bifurcação ou não, conforme demonstrado na Figura 3.

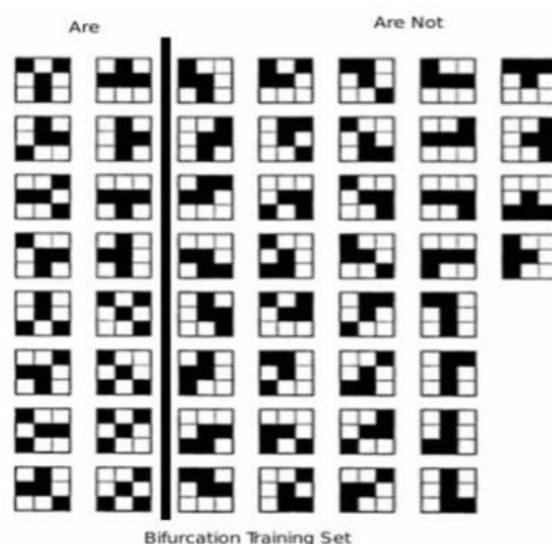


Figura 3 – Conjunto de treinamento de bifurcações agrupados pela saída desejada. Fonte: GOUR et al (2008).

De um total de 100 minúcias, 12 foram utilizadas para se comparar com o método de extração de minúcias por afinamento. A Tabela 1 mostra que o método proposto pode detectar mais minúcias do que o método de afinamento, em menos tempo e sem nenhuma falsa detecção (GOUR et al., 2008).

Tabela 1 – Detecções do método usado por Gour et al (2008).

Imagem de minúcia	Quantidade total de minúcias	Quantidade de minúcias detectadas por afinamento	Quantidade de minúcias detectadas pelo método proposto
1_1.tif	42	36	36
2_1.tif	35	32	34
3_1.tif	38	34	36
4_1.tif	29	27	28
5_1.tif	45	40	43
6_1.tif	35	30	31
7_1.tif	44	39	41
8_1.tif	46	42	44
9_1.tif	37	34	36
10_1.tif	39	32	34
11_1.tif	32	28	30
12_1.tif	41	37	39

Redes neurais têm atraído a atenção para diversos problemas de engenharia: são aproximadores universais, possuem uma topologia compacta e seu aprendizado é bastante rápido devido aos seus neurônios evoluídos (EL-FEGUI et al., 2011).

3. METODOLOGIA

3.1. Metodologia da Pesquisa

Para a realização deste trabalho, foi realizado um estudo de obras referentes ao tema e, em seguida, ao fazer uso de um experimento como método de pesquisa, foi possível abordar quantitativamente o reconhecimento de digitais aplicando redes neurais artificiais do tipo *Multilayer Perceptron*. Previamente, foi necessário aplicar conceitos de processamento de imagens digitais por meio de algoritmos computacionais.

3.2. Solução Proposta

Estudou-se, primeiramente, os conceitos referentes à identificação de digitais ao observar obras de diferentes autores. Em seguida, usando imagens de digitais disponíveis para teste e, foi desenvolvido um algoritmo para processamento das imagens e, logo após, identificação e contagem das minúcias. Tendo armazenada a contagem dos diferentes tipos de minúcias para cada digital de teste, fez-se uso de tais dados para aplicação prática de rede neural artificial e, uma vez calibrado e validado, amostras de digitais foram coletadas de alguns dos próprios autores deste trabalho, verificando o comportamento da rede elaborada.

3.2.1. Etapas de desenvolvimento

O experimento foi dividido em três etapas: coleta das digitais e processamento das imagens, identificação e armazenamento dos atributos e aplicação em rede neural artificial.

3.2.1.1. Coleta das *features*

Tendo em mãos um dispositivo para coleta de digitais, identificado na Figura 4, foram obtidas as imagens das digitais para uso no experimento.



Figura 4 – Dispositivo usado na coleta das digitais: MorphoSmart 300. Imagem disponível em <www.morpho.com/en/biometric-terminals/desktop-devices/fingerprint-devices/morphosmart-300-series>.

Uma vez que, para o processo de aprendizagem e treinamento de uma rede neural é necessário fornecer uma base de dados ampla, foram extraídas 10 amostras de cada indivíduo (Figura 5).



Figura 5 – Amostra de digital coletada.

Em seguida, foi definido o que deveria ser identificado e extraído de cada imagem para que fosse possível utilizar como atributos de entrada em uma rede neural artificial: minúcias do tipo bifurcação (*bifurcation*), extremidade (*ending*), espiral (*whorl*), *loop* e delta.

3.2.1.2. Pré-processamento

Para obter os atributos definidos, foi necessário realizar processamento digital nas imagens, de modo a tornar possível a identificação de minúcias.

Foi implementado, então, código na linguagem Python para tratamento das imagens e extração dos dados definidos, tendo como base conceitos de processamento de imagens digitais, algoritmos de Pastuszka (2012), Howse (2015) e de documentação das bibliotecas OpenCV e Scikit-image.

Dessa maneira, foi realizado primeiramente um filtro de suavização para remover ruídos nas imagens e tornar possível suas binarizações, transformando-as em uma imagem em preto e branco, conforme Figura 6.



Figura 6 – Binarização da amostra disponível na Figura 5.

Em seguida, para melhor identificação das minúcias nas amostras, foi realizada uma redução na largura dos trechos em preto na imagem binarizada, processo o qual conhecido como “esqueletização”, tornando tais trechos com a largura de apenas um pixel (Figura 7).

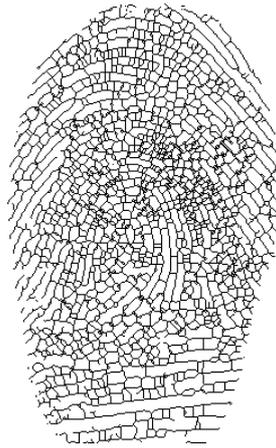


Figura 7 – Esqueletização da amostra binarizada.

Essa transformação é recomendada para facilitar o procedimento de identificação de minúcias e, conseqüentemente, de extração dos dados previamente estabelecidos para utilização como atributos na rede MLP.

A partir dessas amostras, agora “esqueletizadas”, foi realizada a identificação de minúcias do tipo extremidade, aquelas que identificam o início e/ou término de uma linha preta; e as de bifurcação, as quais sinalizam quando uma linha se torna duas. De modo a reduzir o número extenso de minúcias detectadas em primeiros testes, foi ajustada uma margem aceitável de 9 *pixels* de distância entre duas minúcias (Figura 8).

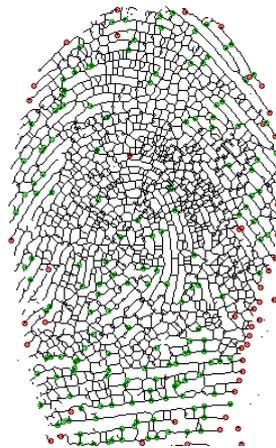


Figura 8 – Identificação de minúcias de bifurcação (em verde) e de extremidade (em vermelho).

Por fim, ainda fazendo uso da imagem esqueletizada, identificou-se minúcias do tipo *whorl*, aquelas com formato espiral; *loop*, as com repetições circulares; e delta, a qual apresenta forma similar a um triângulo (Figura 9).

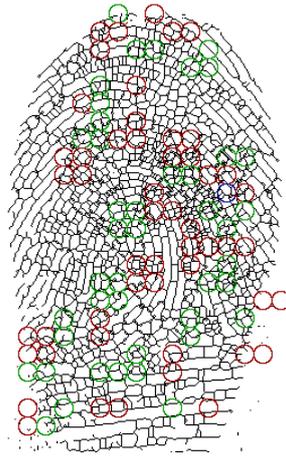


Figura 9 – Identificação de minúcias de *loop* (em vermelho), *delta* (em verde) e de *whorl* (em azul).

Uma vez obtida a quantidade e posições das minúcias, foram realizados testes de treinamento em redes neurais, os quais inicialmente não obtiveram resultados satisfatórios.

Dessa maneira, para melhor diferenciação da quantidade de minúcias em cada digital, dividiu-se cada digitalização em quatro setores, de acordo com o centro da imagem e, dessa maneira, foi armazenada a quantidade de cada tipo de minúcia em cada região para todas as amostras, assim como também quantidade total e a geral de cada uma delas. Uma representação dessa divisão se encontra na Figura 10.

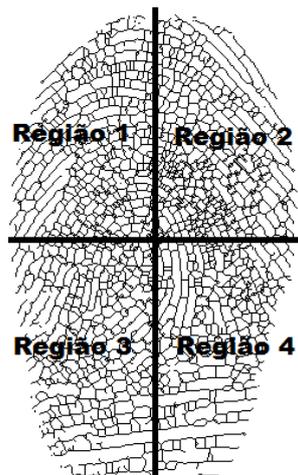


Figura 10 – Divisão da digital em quatro regiões.

3.2.1.3. Rede neural proposta

Conforme apontado por El-Fegui et al. (2011), redes neurais *Multilayer Perceptron* apresentam resultados eficazes para a identificação de indivíduos por meio de impressões digitais.

Com isso, foi proposto estudo da aplicabilidade de MLP com a base de dados coletada, realizando ajustes de parâmetros da rede a fim de observar qual configuração traria melhor resultado.

Com uma quantidade de 10 amostras por indivíduo, realizou-se testes também no processo de validação, por *cross-validation* e *percentage split*.

Para a rede, 38 atributos foram passados para que fosse realizada a aprendizagem e consequente entendimento de como classificar cada amostra. Na realização dos testes, foi usado o *software* Weka.

4. TESTES E RESULTADOS

4.1. Comparação de Classificadores

Apesar de ser de conhecimento a eficiência da aplicação de MLP para a classificação de impressões digitais, foi realizada uma comparação desse tipo de rede neural com outros classificadores, utilizando-se os parâmetros padrões fornecidos pelo *software* Weka.

Para esse teste, além de não se alterar os parâmetros padrões fornecidos pelo *software*, foi utilizado o método de *cross-validation* com 10 *folds* para a validação.

O resultado do comparativo é encontrado na Tabela 2, na qual é possível observar que os melhores resultados foram obtidos por *BayesNet* e *MultilayerPerceptron*.

Tabela 2 – Comparação de classificadores.

Classificador	Eficácia (%)
<i>BayesNet</i>	93.333
<i>NaiveBayes</i>	86.667
<i>Logistic</i>	91.667
<i>MultilayerPerceptron</i>	93.333
<i>SimpleLogistic</i>	85
SMO	86.667
Ibk	86.667
KStar	85
LWL	70
<i>ClassificationViaRegression</i>	86.667
<i>MultiClassClassifier</i>	90
<i>Decision Tree</i>	50
<i>Decision Tree</i>	50
<i>Hoeffding Tree</i>	85
J48	83.333

4.2. Métodos de Validação

Já fazendo uso da MLP, comparou-se a eficiência relacionada aos métodos de validação disponíveis na ferramenta: *Cross-validation* para diferentes quantidades de *folds* e *Percentage split* para diferentes valores de porcentagem (Tabela 3).

Cross-validation é uma técnica de reamostragem que utiliza múltiplas amostras aleatórias para treinamento e teste, tendo como vantagem o uso de todos os dados para teste e a maioria deles para treinar o modelo (Zhang et al, 1999). Por outro lado, *percentage split* é a simples divisão da base de dados, com, preferencialmente, um maior valor percentual de dados para uso em treinamento e o restante para teste.

Para observar esses métodos de validação, novamente manteve-se a configuração padrão fornecida para a rede neural MLP:

- *Learning Rate* = 0.3;
- *Momentum* = 0.2;
- *Number of Epochs* = 500;
- *V (Percentage size of validation set)* = 0;
- *Seed* = 0;
- *E (Threshold of consecutive errors)* = 20;
- *Hidden Layers* = a (média dentre número de atributos e número de classes).

Uma explicação mais detalhada sobre cada parâmetro será realizada no tópico 4.3.

Tabela 3 – Comparação de métodos de validação.

Método de Validação	Eficácia (%)
<i>Cross-validation: 2 folds</i>	90
<i>Cross-validation: 5 folds</i>	95
<i>Cross-validation: 10 folds</i>	93.333
<i>Cross-validation: 15 folds</i>	95
<i>Cross-validation: 20 folds</i>	95
<i>Cross-validation: 25 folds</i>	93.333
<i>Percentage split: 50%</i>	93.333
<i>Percentage split: 60%</i>	91.667
<i>Percentage split: 70%</i>	88.889
<i>Percentage split: 75%</i>	93.333
<i>Percentage split: 80%</i>	91.667
<i>Percentage split: 85%</i>	100
<i>Percentage split: 90%</i>	100

4.3. Parâmetros da Rede *MultiLayer Perceptron*

Tendo comparado os métodos de validação, os parâmetros da rede MLP foram examinados de modo a alterar um por vez, mantendo os demais com seus valores padrões. Para fins de teste, foi utilizado *cross-validation* com 10 *folds* como método de validação.

Após analisar os principais parâmetros da rede MLP, serão realizados testes usando as melhores configurações encontradas, de modo a buscar melhor eficácia possível.

4.3.1. Taxa de aprendizado

A taxa de aprendizado, ou *Learning Rate*, é um número real constante que determina o quanto os pesos da rede neural podem ser alterados quando for observado um erro nos dados de treinamento. Seu valor deve ser selecionado

cuidadosamente, uma vez que, quando for muito baixo, a rede tomará mais tempo para convergir e, quando alto, a rede pode nunca convergir (THOTA e CHANGALASETTY, 2013).

Com a rede neural MLP com os parâmetros padrões mantidos, alterou-se apenas a taxa de *Learning Rate* (Tabela 4), a fim de observar o comportamento da eficiência de aprendizado.

Tabela 4 – Calibração de *Learning Rate*.

<i>Learning Rate</i>	Eficácia (%)
0.01	68.333
0.1	93.333
0.2	93.333
0.3	93.333
0.4	95
0.5	95
0.6	95
0.7	95
0.8	95
0.9	95
0.99	95

4.3.2. *Momentum*

Embora o algoritmo de *Backpropagation* seja comumente usado para o processo de aprendizagem de redes neurais, ele sofre de baixa velocidade para treinamento e, dentre as maneiras de acelerá-lo, é possível incluir um coeficiente denominado *momentum* em uma de suas equações, conforme mostrado por Sheel et al (2007).

Novamente, retornando a MLP à sua configuração padrão com *Learning Rate* em 0.3, verificou-se o comportamento com mudanças de *momentum* (Tabela 5).

Tabela 5 – Calibração de *Momentum*.

<i>Momentum</i>	Eficácia (%)
0.01	93.333
0.1	93.333
0.2	93.333
0.3	93.333
0.4	95
0.5	95
0.6	95
0.7	95
0.8	93.333

<i>Momentum</i>	Eficácia (%)
0.9	88.333
0.99	16.667

4.3.3. Quantidade de épocas

De maneira sucinta, uma época é um ciclo percorrido por toda a base de treinamento (OZA, 2005). Para a configuração padrão da MLP, verificou-se o comportamento da eficiência ao ajustar a quantidade de épocas para realização do processo de treinamento (Tabela 6).

Tabela 6 – Calibração de Épocas.

<i>Epochs</i>	Eficácia (%)
2	18.333
10	51.667
100	93.333
500	93.333
750	93.333
1000	93.333
1500	95
2000	95
2500	95

4.3.4. Quantidade de neurônios ocultos

Neurônios ocultos são aqueles entre os neurônios de entrada e os de saída (Tabela 7). A quantidade de neurônios ocultos não é fácil de se determinar, sendo necessário experimentação, uma vez que esse parâmetro é dependente dos tipos de dados e/ou do problema em si (ZHANG et al 1999).

Tabela 7 – Calibração de Neurônios Ocultos.

<i>Hidden Layers</i>	Eficácia (%)
1	45
5	91.667
10	91.667
15	96.667
25	95
50	93.333
100	95

Verificou-se também o comportamento com a inclusão de uma camada oculta adicional. Na Tabela 8, a vírgula separa a quantidade de neurônios utilizada nas duas camadas.

Tabela 8 – Inclusão de camada oculta adicional.

<i>Hidden Layers</i>	Eficácia (%)
1,1	41.667
5,1	56.667
5,5	85
5,10	88.333
10,1	40
10,5	88.333
10,10	86,667
15,5	85
15,10	90
15,15	86,667
15,25	88.333
25,5	81.667
25,10	88.333
25,15	86,667
25,25	86,667

4.4. Ajustes e Resultados

Realizadas as análises do comportamento de cada parâmetro da MLP, buscou-se verificar o comportamento da mesma ao usar as principais configurações identificadas em *cross-validation* com 15 *folds*, explorando por melhores resultados (Tabela 9).

Tabela 9 – Ajustes e testes.

<i>Learning Rate</i>	<i>Momentum</i>	<i>Epochs</i>	<i>Hidden Layers</i>	Eficácia (%)
0.3	0.2	1500	15	95
0.3	0.3	1500	15	95
0.3	0.4	1500	15	95
0.3	0.5	1500	15	95
0.4	0.3	1500	15	95
0.4	0.4	1500	15	95
0.4	0.5	1500	15	95
0.5	0.3	1500	15	95
0.5	0.4	1500	15	95

<i>Learning Rate</i>	<i>Momentum</i>	<i>Epochs</i>	<i>Hidden Layers</i>	<i>Eficácia (%)</i>
0.5	0.5	1500	15	95

Uma outra maneira de representar os resultados é por meio da denominada Matriz de Confusão, apresentada abaixo na Figura 11.

```

=== Confusion Matrix ===
 a  b  c  d  e  f  <-- classified as
 9  0  0  0  1  0 | a = andrei
 0 10  0  0  0  0 | b = conrado
 0  0 10  0  0  0 | c = denis
 0  0  0 10  0  0 | d = joao
 0  0  1  0  9  0 | e = paulo
 0  0  0  0  1  9 | f = reuel

```

Figura 11 – Matriz de confusão para os resultados da Tabela 9.

Conforme já mencionado, a coletânea de dados é compreendida de 10 amostras de 6 diferentes classes.

A primeira linha da matriz de confusão representa os dados cuja classificação esperada é “andrei”, sendo que, dos 10 dados analisados, 9 foram classificados corretamente e 1 com erro, classificado como “paulo”. Na segunda linha, a classe esperada é “conrado”, sendo corretamente classificada para as 10 amostras. E assim se sucede, sendo perceptível o erro em apenas 3 das 60 classificações realizadas, o que demonstra a eficácia de 95% apresentada na Tabela 9.

5. CONCLUSÃO

Conforme apresentado e analisado neste trabalho, pôde-se verificar a eficácia da aplicação de redes neurais *Multilayer Perceptron* no reconhecimento de indivíduos a partir de impressões digitais.

Com um foco inicial em processamento de imagens e codificação para identificação de minúcias, foram obtidos dados que possibilitam aprendizagem satisfatória de uma rede MLP. Entretanto, recomenda-se expandir esta análise a um espaço amostral maior, ou seja, com uma quantidade maior de indivíduos e, conseqüentemente, de classes disponíveis para a rede neural classificar.

Tendo em vista a matriz de confusão apresentada na Figura 11, verifica-se que há ainda a necessidade de aperfeiçoar o manuseio de atributos para essa rede neural, uma vez que para metade das classes apresentadas, ocorreu uma ocorrência de erro de classificação. Ao lidar com autenticação e identificação de indivíduos, não é correto que um indivíduo seja confundido, mesmo que remotamente, com outro.

Dessa maneira, é possível ainda aperfeiçoar essa implementação, como, por exemplo, identificando o ponto principal de cada digital e armazenando sua distância relativa com outras minúcias encontradas, além de outros atributos adicionais que possam ser incluídos, como ângulos relativos entre minúcias, entre outras possibilidades.

Além das melhorias recomendadas, assim que se obter o melhor resultado possível, sugere-se a aplicação em algum sistema para autenticação de usuários, os quais poderão validar, então, suas identidades por meio das próprias impressões digitais, eliminando, portanto, a necessidade de memorizar senhas de acesso, ao mesmo tempo que passam a ter chaves seguras.

REFERÊNCIAS

- CASADO, R. S.; PAIVA, M. S. V. de. "Extração de Minúcias em Imagens de Impressões Digitais". 2008.
- EL-FEGHI; IDRIS; TAHAR, A.; AHMADI, M. "Efficient features extraction for fingerprint classification with multilayer perceptron neural network." Signals, Circuits and Systems (ISSCS), 2011 10th International Symposium on. IEEE, 2011.
- GOUR, BHUPESH; BANDOPADHYAYA, T. K.; SHARMA, S. "Fingerprint feature extraction using midpoint ridge contour method and neural network." IJCSNS8.7 (2008): 100.
- GUMZ, R. A. "Protótipo de um sistema de identificação de minúcias em impressões digitais utilizando redes neurais artificiais feedforward multicamada". Blumenau, 2002.
- HOWSE, J. Fingerprint Detection using OpenCV3, 2015. Disponível em <https://www.packtpub.com/books/content/fingerprint-detection-using-opencv-3>. Acesso em 7 de agosto de 2017.
- JAIN, A.; PRABHAKAR, S.; HONG, L. "A Multichannel Approach to Fingerprint Classification", IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 21, NO. 4, APRIL 1999, pp 348-359.
- KRISTENSEN, T. Two Different Regimes of Fingerprint Identification – a Comparison. American Journal of Computational and Applied Mathematics 2012, 2(2): 1-9 DOI: 10.5923/j.ajcam.20120202.01
- LIU, S.; SILVERMAN, M. "A Practical Guide to Biometric Security Technology". IT Pro, [S.l.], pp. 27-32, Janeiro/Fevereiro, 2001.
- MAZI, R. C.; JÚNIOR, A. D. P. "Identificação Biométrica através da Impressão Digital Usando Redes Neurais Artificiais". Anais Do XIV ENCITA, (Julho), 2009, 19–22.
- MEHRAN YAZDI, KAZEM GHEYSARI, "A New Approach for Fingerprint Classification Based on Gray-Level Co-occurrence Matrix", World Academy of Science, Engineering and Technology, 2008.
- OZA, N. C. Online Bagging and Boosting. Systems, Man and Cybernetics, IEEE International Conference, 2005.
- PASTUSZKA, P. Fingerprint Recognition Algorithms, Biometrics Methods course, University of Wroclaw, Poland, 2012. Disponível em <https://github.com/rtshadow/biometrics>. Acesso em 7 de agosto de 2017.
- PRABHAKAR, S. "Fingerprint Classification and Matching Using a Filterbank". PhD Thesis, Michigan State University, 2001.
- Scikit-image documentation, Skeletonize. Disponível em http://scikit-image.org/docs/dev/auto_examples/edges/plot_skeleton.html. Acesso em 7 de agosto de 2017.
- SHEEL, S.; VARSHNEY, T.; VARSHNEY, R. Accelerated Learning in MLP using Adaptive Learning Rate with Momentum Coefficient. Second International Conference on Industrial and Information Systems, ICIIIS 2007.
- TAFNER, Maucon; XEREZ, Marcos de; RODRIGUES FILHO, Ilson W. Redes neurais artificiais. Blumenau: Ed. da FURB, 1995.
- THOTA, L. S.; CHANGALASETTY, S. B. Optimum learning rate for classification problem with MLP in data mining. International Journal of Advances in Engineering & Technology, 2013.
- ZHANG, G.; HU, M. Y.; PATUWO, B. E.; INDRO, D. C. Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. European Journal of Operational Research 116, Elsevier, 1999.