

DETECÇÃO AUTOMÁTICA DE OBJETOS ESTRANHOS NA REGIÃO DAS PERNAS EM IMAGENS DE SCANNER HUMANO UTILIZANDO TEXTURAS E CLASSIFICADORES

THOMAZ. M. ALMEIDA¹, DANIEL F. COLAÇO², TARIQUE. S. CAVALCANTE², VICTOR H. F. ALENCAR¹, LUIZ. A. L. NETO¹, JOHN H. S. FELIX³

1. *Megatech Controls Indústria, Comércio e Serviço Ltda*

R. Dr. Ernesto Monteiro, 2909 - Sapiranga - Fortaleza - CE, 60833-272

E-mails: thomaz@megatechcontrols.com.br, victorhugo@megatechcontrols.com.br, luiz@megatechcontrols.com.br

2. *Instituto Orion de Ciência e Tecnologia - IOCT*

R. Dr. Ernesto Monteiro, 2909 - Alagadiço Novo - Fortaleza - CE, 60833-710

E-mails: colaco@ioct.com.br, tariquesc@gmail.com

3. *Universidade da Integração Internacional da Lusofonia Afro-Brasileira - UNILAB*

Campus dos Palmares, Rodovia CE 060 – km51 – Acarape-CE, 62785-000

E-mails: johnfelix@unilab.edu.br

Abstract— In this article we introduce a new method for automatic identification of suspicious objects in body scanner's images in the leg's regions. The method is based on a combination of texture and a classifier, which may be the KNN, K-means or the MLP neural network. The methods are applied on 20 body scanner's images, in the leg's regions of volunteers. The accuracy of the method is verified by the hit rate presented in graphical form and the presence of false positives. The results indicate that the method that combines textures with MLP provides a hit of 0.91 and 0.08 false positives, the KNN classifier hits 0.89 and provides 0.01 of false-positive while K-means obtained a hit of 0.81 and 0.03 of false positives. Given the results, it is concluded that the method that combines texture and MLP achieved the identification of suspicious objects more effective than the other classifiers used in this work.

Keywords— body scanner image, KNN, K-means, MLP.

Resumo— Neste trabalho apresentamos um novo método de identificação automática de objetos estranhos em imagens de body scanner nas regiões das pernas. O método é formado pela combinação de textura e um classificador, que poder ser o KNN, K-médias ou a rede neural MLP. Os métodos são aplicados em 20 imagens de body scanner, nas regiões das pernas, de voluntários. A precisão do método é verificada por meio da taxa de acerto apresentado em forma de gráfico e pela presença de falsos-positivos. Os resultados indicam o método que combina texturas e com a MLP obteve 0,91 de acerto e 0,08 de falsos-positivos, enquanto o classificador KNN obteve 0,89 de acerto e 0,01 de falsos-positivos e o K-médias obteve 0,81 de acerto e 0,03 de falsos-positivos. Diante dos resultados apresentados, conclui-se que o método que combina textura e MLP obteve a identificação de objetos estranhos mais efetiva em relação aos demais classificadores utilizados neste trabalho.

Palavras-chave — imagens de body scanner, KNN, K-médias, MLP.

1 Introdução

Os Raios-x são utilizados em diversos equipamentos, que têm sido aplicados na indústria, medicina, segurança, dentre outras áreas. Na segurança os raios-X são aplicados para examinar as bagagens em aeroportos para se verificar a presença de armas, bombas e substâncias ilícitas. Nas fronteiras, as cargas também são examinadas de forma semelhante para evitar o trânsito ilegal de mercadorias (Ahmed *et al.*, 2011).

Os equipamentos de raios-X possibilitam a identificação de objetos e substâncias ilícitas levadas por pessoas, sejam em bagagens, sejam fixados no próprio corpo ou até mesmo em seu interior como no caso de drogas.

Por outro lado, estes equipamentos requerem um especialista treinado para o reconhecimento de tais objetos e substâncias ilícitas. A análise visual do especialista é suscetível a subjetividade e limitações relacionadas a cada observador (Coxson, *et al.*, 2001; Felix *et al.*, 2008). Além disso, há a fadiga visual ocasionada pela inspeção de várias imagens.

Os métodos computacionais têm contribuído significativamente para os avanços em diagnósticos médicos, reconhecimento por sinais biométricos, imagens de satélites, dentre outros. A segurança é uma área que tem investido principalmente no desenvolvimento de equipamentos, tais como: raios-X para cargas, body scanner (Scanner de pessoas), dentre outros.

Apesar dos investimentos na área de segurança, até o presente momento, não foi identificado na literatura, trabalhos que mencionem métodos/técnicas de segmentação e/ou detecção de objetos e substâncias ilícitas em corpos humano utilizando imagens de body scanner.

Diante do exposto, o objetivo deste trabalho é apresentar um método de detecção automática de objetos estranhos ao corpo em imagens de body scanner (Scanner de pessoas). Para tal, são utilizadas medidas de texturas. Além disso, são avaliados o classificador dos k-vizinhos mais próximos, o classificador k-médias e a rede neural perceptron multicamadas.

2 Materiais e Métodos

2.1 Aquisição de imagens

Neste trabalho são utilizadas 20 imagens de Scanner de pessoas voluntárias em pé. Essas imagens fazem parte de um banco de imagens de raios-X do fabricante do equipamento, utilizadas para fins de treinamento dos operadores. Cada uma dessas 20 imagens apresenta algum tipo de objeto estranho ao corpo humano na região dos membros inferiores, tais como pistolas, facas, canetas, chaveiros, dentre outros.

2.2 Textura

A textura é uma importante característica na percepção visual de imagens naturais, pois contém informações importantes. Ela é geralmente utilizada pelo ser humano para a interpretação e análise de vários tipos de imagens, podendo ser analisada como relações espaciais e arranjos de elementos básicos de uma imagem (Christodoulou *et al.*, 2003).

Geralmente texturas são utilizadas para indicar propriedades intrínsecas de superfícies ou regiões, especialmente para aquelas que não possuem uma variação suave de intensidade, sendo tão pequenas que não conseguem separar objetos na resolução observada (Sabino *et al.*, 2004).

Na literatura, são encontrados diversos sistemas de Visão Artificial que utilizam texturas para fornecer informações importantes na identificação de superfícies ou objetos em diferentes tipos de imagens. Apesar da vasta usabilidade e importância não existe uma abordagem formal para definição de textura (Haralick *et al.*, 1973). Logo, esta é representada por propriedades intuitivas como rugosidade, granulação e regularidade dentre outras.

Em Processamento Digital de Imagens (PDI), texturas podem ser definidas como um conjunto de propriedades de uma determinada região da imagem (Livens, 1998).

Os métodos para extrair textura são diversos, refletindo em diferentes conceitos originados nas áreas de aplicação da mesma. Neste trabalho é abordada a extração das características de texturas por meio de estatísticas de segunda ordem, baseado na repetição de pares de pixels proposto por Haralick, Shanmugam e Dinstein (Haralick *et al.*, 1973).

As estatísticas de segunda ordem são calculadas a partir da função de probabilidade da co-ocorrência de dois pares de

pixels na imagem. Esta função de probabilidade é também definida como matriz de co-ocorrência.

A matriz de co-ocorrência é definida como:

$$P(i, j | d, \theta) = \left[\begin{array}{c} I(k, l) = i \\ I(m, n) = j \\ \{\bar{u}(k, l), \bar{v}(m, n)\}; \quad (k, l); (m, n) \in M \times N \\ \bar{d} = d \angle \theta = (d \cos \theta, d \sin \theta) \\ \bar{v} = \bar{u} + \bar{d} \end{array} \right] \quad (1)$$

(M - dx)(N - dy)

em que i e j são, respectivamente, a intensidade de dois pixels localizados em (k, l) e (m, n), separados por uma distância d na orientação de θ com a horizontal.

Desta forma, é possível definir a matriz S de dependência espacial do nível de cinza (SGLDM - Spatial Gray Level Dependence Matrix) como:

$$S = \frac{S_0 + S_{45} + S_{90} + S_{135}}{4} \quad (2)$$

em que,

$$\begin{aligned} S_0(i, j | d) &= \frac{P(i, j | d, 0^\circ) + P(i, j | d, 0^\circ)'}{2} \\ S_{45}(i, j | d) &= \frac{P(i, j | d, 45^\circ) + P(i, j | d, 45^\circ)'}{2} \\ S_{90}(i, j | d) &= \frac{P(i, j | d, 90^\circ) + P(i, j | d, 90^\circ)'}{2} \\ S_{135}(i, j | d) &= \frac{P(i, j | d, 135^\circ) + P(i, j | d, 135^\circ)'}{2} \end{aligned} \quad (3)$$

De posse desta matriz, é possível calcular as texturas a seguir (Haralick, 1979):

- Contraste (C)

$$C = \sum_{ij} (i - j)^2 S(i, j) \quad (4)$$

- Homogeneidade (H)

$$H = \sum_{ij} \frac{S(i, j)}{1 + (i - j)^2} \quad (5)$$

- Energia (En)

$$En = \sum_{ij} S(i, j)^2 \quad (6)$$

- Máxima Probabilidade (MAX)

$$MAX = \max(S(i, j)) \quad (7)$$

- Entropia (Ent)

$$Ent = - \sum_{ij} S(i, j) \cdot \log_2(S(i, j)) \quad (8)$$

- Correlação (Corr)

$$Corr = \frac{\sum_{ij} i \cdot j \cdot S(i, j) - \mu_i \cdot \mu_j}{\sigma_i \sigma_j} \quad (9)$$

- Autocorrelação (A)

$$A = \sum_{ij} i \cdot j \cdot S(i, j) \quad (10)$$

- Covariância (Cov)

$$Cov = \sum_{ij} (i - \mu_i)(j - \mu_j) \cdot S(i, j) \quad (11)$$

- Proeminência (P)

$$P = \sum_{ij} (i - \mu_i + j - \mu_j)^3 \cdot S(i, j) \quad (12)$$

- Sombra (S)

$$S = \sum_{ij} (i - \mu_i + j - \mu_j)^4 \cdot S(i, j) \quad (13)$$

2.3 Classificadores

A classificação é uma etapa fundamental no reconhecimento de padrões. É nesta etapa que os dados são submetidos a um sistema (classificador), para que este os classifique de acordo com o conhecimento alcançado por experiência nas observações e análises de exemplos de treinamento num prévio processo de aprendizagem. Esta classificação visa atribuir a uma determinada região da imagem, baseado nos valores das medidas de textura dos pixels daquela região, a qual classe ela tem maior probabilidade de pertencer, dentre as três classes definidas: osso, músculo, objetos estranhos.

O sucesso na etapa de classificação depende de qual classificador é utilizado na solução do problema em questão. Para tanto, são necessários testes de classificadores visando o melhor resultado da classificação de objetos estranhos. Os classificadores testados são: KNN, K-médias e MLP.

2.3.1 Classificador k-Vizinhos mais Próximos

O classificador dos k-vizinhos mais próximos (KNN: k-nearest neighbor) é, sem dúvida, um dos mais simples e antigo método utilizado no reconhecimento e classificação de padrões (Cover; Hart, 1967). Seja um conjunto de dados D composto por N amostras, em que $D = X_1, X_2, X_3, \dots, X_n$ e y um novo elemento, que não pertence ao conjunto D . Este método consiste em atribuir a mesma classificação para o elemento desconhecido y à classe da maioria dos k vizinhos mais próximos.

A fim de classificar o novo elemento y procuram-se as k amostras mais próximas contidas no conjunto D . A classe mais frequente é atribuída à y . Este algoritmo se baseia em uma métrica de distância entre dois elementos, calculada no espaço de atributos, dada, por exemplo, pela distância euclidiana:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y)^2} \quad (14)$$

2.3.2 Classificador k-Médias

A técnica de classificação k-médias utiliza o algoritmo de agrupamento de dados por k-médias (*k-means clustering*) para classificar dados (MacQueen, 1967). Assim como o KNN, este método atribui uma classe a um elemento desconhecido baseado em uma métrica de distância. Esta técnica consiste em particionar um conjunto de dados $D = X_1, X_2, X_3, \dots, X_n$ em k grupos de elementos semelhantes. O centroide de cada grupo, ou partição, é calculado baseado em seus atributos, que, nesse caso, é dado pela média dos valores de textura:

$$c(k_i) = \frac{\sum_{j=1}^t x_j}{n_k} \quad (15)$$

em que k_i é o k -ésimo centroide do conjunto de dados, x_j é o j -ésimo valor dentre t atributos de texturas e n_k é o número de elementos daquela partição do conjunto de dados.

Dado um novo elemento desconhecido y , a classe a que esse elemento pertence é estimada mediante um cálculo de distância (euclidiana, por exemplo) entre esse novo elemento e os k centroides do conjunto de dados. A classe de y é atribuída àquele centroide onde ocorreu a menor distância. Logo, o centroide deste grupo é atualizado com as novas informações do novo elemento y (Duda *et al.*, 2001).

2.3.3 Rede Neural MLP

A MLP (Multilayer Perceptron) é uma técnica baseada em Redes Neurais Artificiais (RNA) que surgiu com o intuito de superar algumas limitações do perceptron simples. Esse tipo de classificador é indicado para modelagem caixa-preta de mapeamentos não-lineares a partir de treinamento supervisionado, tornando-se atrativa para aplicações complexas (Medeiros, 2008). Este classificador consiste de uma camada de neurônios na entrada, camadas intermediárias (ocultas) e uma camada de saída, conforme descrito na Figura 1.

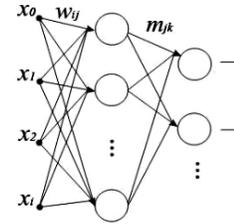


Figura 1. Representação típica de uma rede MLP com uma camada oculta.

O treinamento desse tipo de classificador é realizado através do algoritmo de retropropagação de erros (backpropagation), cujo princípio é calcular as saídas de todos os neurônios das camadas ocultas por meio de uma estimativa do efeito que estas camadas causam no erro dos neurônios da camada de saída (Rocha Neto, 2006). Dessa forma, o erro na camada de saída do classificador é retroalimentado para as camadas ocultas, possibilitando o aperfeiçoamento dos valores dos pesos entre as camadas.

2.4 Etapas para Avaliação dos Métodos

O processo de identificação de objetos estranhos em imagens de raio-X é dividido em quatro etapas. A primeira etapa é a etapa de rotulação de regiões. Esta etapa é de fundamental importância para o bom funcionamento dos classificadores, pois durante a rotulação vários pixels são classificados manualmente dentre as três classes possíveis: Osso, Tecido/Músculo e Outros (objetos estranhos ao corpo humano). Estes pixels e suas vizinhanças são utilizados no cálculo da textura de regiões da imagem. Esses valores de texturas servem como exemplos para que o classificador diferencie as classes Osso, Tecido/Músculo e Outros entre si.

Ao final desta etapa obtém-se um banco de rótulos contendo as coordenadas dos pixels rotulados e a classe a qual eles pertencem. Este processo é repetido em cada uma das 20 imagens utilizadas neste trabalho.

De posse do banco de rótulos é possível gerar o banco de dados com as texturas de cada região rotulada em cada imagem. Esta é a etapa de geração de bancos, onde são combinadas as 10 texturas entre si agrupando-as uma a uma e gerando um banco diferente para cada combinação:

$$C_{10,1} + C_{10,2} + C_{10,3} + C_{10,4} + C_{10,5} + C_{10,6} + C_{10,7} + C_{10,8} + C_{10,9} + C_{10,10} = 10+45+120+210+252+210+120+45+10+1 \quad (16)$$

Ao final, totalizam-se 1023 bancos de texturas diferentes. Cada linha do banco representa uma amostra de região que é composta por n texturas e, ao final, a classe daquela região. Cada banco gerado é utilizado para treinar e testar cada classificador na etapa seguinte. Este processo destina-se a encontrar a combinação ideal com as texturas que produzem maiores taxas de acerto.

A terceira etapa é a etapa de classificação. Nesta etapa, cada um dos 1023 bancos de texturas é dividido em treino e teste: 70% das n amostras é reservada para treino e 30% para teste. Depois de dividido, o banco é treinado e testado com cada um dos três classificadores. Após cada teste as taxas de acerto são salvas para, ao final, serem ordenadas. São necessários dois tipos de ordenação: ordenação decrescente da taxa de acerto geral e ordenação crescente da taxa de falso-positivo da classe “Outros”.

A última etapa destina-se a testar os classificadores com as configurações de texturas encontradas após a etapa de classificação. Esta etapa se resume em segmentar os membros inferiores nas imagens de raio-X do corpo humano, aplicar a combinação de texturas ideal e classificar os pixels entre as três classes existentes. Um diagrama contendo o fluxo das etapas é mostrado na Figura 2.

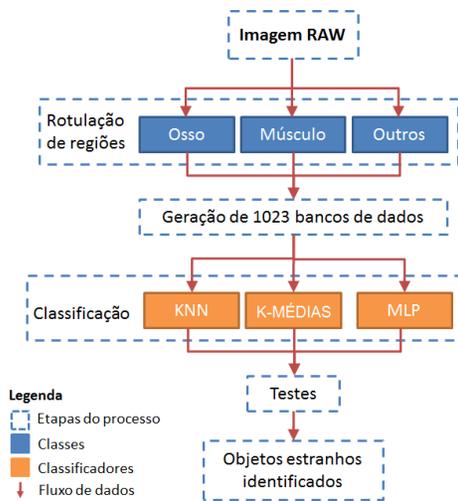


Figura 2. Fluxograma das etapas de classificação e identificação de objetos estranhos, nas pernas, em imagens de Scanner de pessoas.

3 Resultados e Discussões

Para avaliar a eficácia dos classificadores utilizados nesse trabalho, os resultados obtidos são divididos em duas partes: quanto à maior taxa de acerto geral e quanto à menor taxa de falsos-positivos da classe “Outros”, que são regiões da imagem

onde não há a presença de objetos estranhos, mas mesmo assim foram classificadas como tal. A segunda parte de análise é importante porque apesar de serem rotuladas três classes nesse trabalho, a classe “Outros” é a única que traz resultados significativos reais, não importando se o classificador confunde a classe “Osso” com a classe “Tecido/Músculo”.

Visando a análise da taxa de acerto, é computado o acerto de cada técnica na etapa de classificação, após o banco de texturas ser dividido em treino e teste de maneira aleatória. Cada uma das 1023 combinações de texturas produz uma taxa de acerto diferente. Estas taxas são mostradas na Figura 3 para cada classificador.

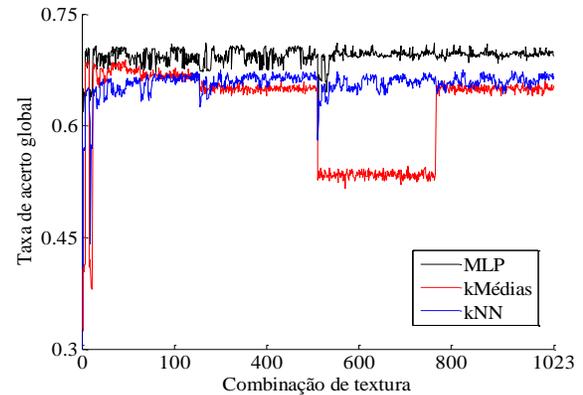


Figura 3. Taxas de acertos dos classificadores: kNN, kMédias e MLP.

A taxa de acerto é ordenada de maneira decrescente. Desta forma, têm-se as cinco melhores configurações de textura em termos de taxa de acerto global para cada classificador, conforme é mostrado na Tabela 1.

Tabela 1. Configurações de texturas para cada classificador

Classificação	KNN	K-médias	MLP
1ª	Energia; Entropia; Autocorrelação; Máxima Probabilidade; Contraste; Proeminência; Correlação	Entropia; Uniformidade; Autocorrelação; Máxima Probabilidade; Covariância	Energia; Autocorrelação; Contraste; Correlação
2ª	Energia; Uniformidade; Autocorrelação; Contraste; Proeminência	Entropia; Uniformidade; Autocorrelação	Entropia; Uniformidade; Autocorrelação; Proeminência
3ª	Energia; Uniformidade; Contraste; Sombra; Proeminência; Correlação	Energia; Autocorrelação, Máxima Probabilidade, Covariância	Uniformidade; Autocorrelação; Máxima Probabilidade; Contraste; Covariância; Sombra; Correlação
4ª	Uniformidade; Autocorrelação; Contraste; Sombra; Proeminência; Correlação	Energia; Entropia; Autocorrelação; Máxima Probabilidade; Covariância	Energia; Entropia; Uniformidade; Autocorrelação; Contraste; Covariância; Proeminência; Correlação
5ª	Uniformidade; Autocorrelação;	Máxima Probabilidade;	Energia; Entropia; Covariância;

	Contraste; Covariância; Sombra; Proeminência; Correlação	Covariância	Sombra
--	--	-------------	--------

A análise da quantidade de falsos-positivos leva em consideração primeiramente, a taxa de acerto da classe “Outros”, que está ilustrada na Figura 4, e a quantidade de falsos-positivos da mesma classe, ilustrado na Figura 5.

Nesta análise excluem-se todas as combinações de texturas que geraram taxas de acerto inferiores a 0,7. Dentre as que permaneceram, ordenam-se os arquivos de acordo com a maior taxa de acerto e o menor falso-positivo para, enfim, se obter as cinco melhores configurações de textura (Ver Tabela 2).

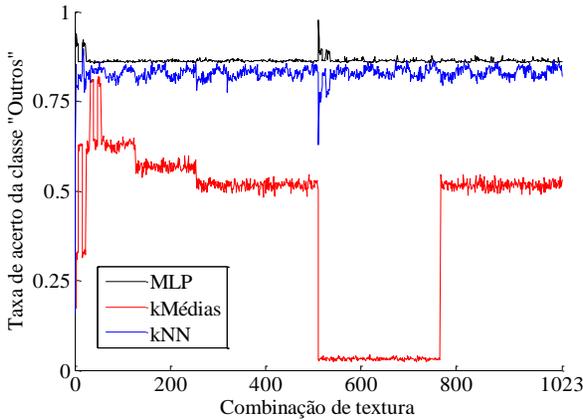


Figura 4. Taxas de acertos obtidos pelos classificadores: kNN, kMédias e MLP. Para a classe “Outros”.

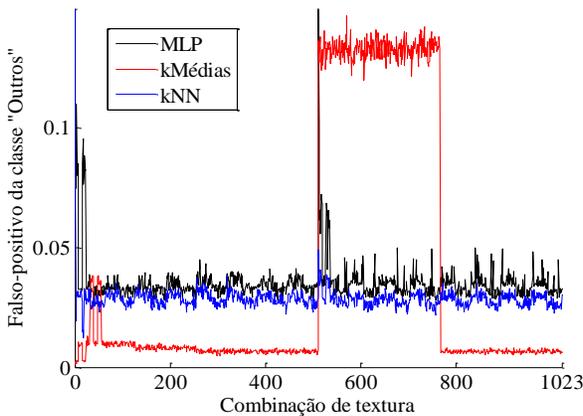


Figura 5. Quantidades de falsos-positivos obtidos pelos classificadores: kNN, kMédias e MLP. Para a classe “Outros”.

Tabela 2. Cinco melhores configurações de texturas para cada classificador

Classifi- cação	KNN	K-médias	MLP
1ª	Energia; Entropia; Máxima Probabilidade	Energia; Máxima Probabilidade; Contraste	Energia; Uniformidade; Máxima probabilidade
2ª	Máxima Probabilidade	Uniformidade; Máxima Probabilidade; Contraste	Máxima Probabilidade
3ª	Entropia; Máxima probabilidade	Energia; Entropia; Máxima	Energia; Máxima

		Probabilidade; Contraste	Probabilidade
4ª	Energia; Máxima probabilidade	Energia; Uniformidade; Contraste	Energia; Entropia; Uniformidade
5ª	Máxima Probabilidade; Contraste; Covariância; Sombra; Proeminência; Correlação	Energia; Entropia; Uniformidade; Contraste	Entropia

Ao analisar os valores das cinco maiores taxas de acerto global para os três classificadores, apresentados na Tabela 3, percebe-se uma variação da ordem de, no máximo, 1% entre as combinações de textura e de 4% entre os classificadores. Isso mostra significável semelhança entre as técnicas com o classificador MLP sobressaindo em relação aos demais.

Tabela 3. Taxa de acerto global obtida por cada classificador

KNN	K-médias	MLP
0,6748	0,6879	0,7112
0,6748	0,6874	0,7106
0,6738	0,6866	0,7105
0,6729	0,6863	0,7092
0,6729	0,6855	0,7091

A situação em relação à segunda análise, da taxa de acerto da classe “Outros” e da quantidade de falso-positivo, de acordo com a Tabela 4, é semelhante à taxa de acerto global. Há pouca diferença entre as cinco melhores combinações de texturas. Analisando cada classificador separadamente, percebe-se, novamente, o classificador MLP com as maiores taxas de acerto em relação à classe “Outros” e o classificador k-NN com as menores quantidades de falsos-positivos.

Tabela 4. Taxa de acerto da classe “Outros” e da quantidade de falsos-positivos (FP) obtidos por cada classificador

KNN		K-médias		MLP	
Acertos	FP	Acertos	FP	Acertos	FP
0,8974	0,0121	0,8187	0,0384	0,9144	0,0885
0,8782	0,0149	0,8162	0,0352	0,9115	0,0857
0,8763	0,0155	0,8135	0,0346	0,9115	0,0857
0,8709	0,0152	0,8119	0,0382	0,9110	0,0852
0,862	0,0226	0,8116	0,0377	0,9109	0,0850

Desta maneira, as combinações de textura que geraram a maior taxa de acerto global, a maior taxa de acerto da classe “Outros” e a menor quantidade de falso-positivo são testadas nas imagens durante a etapa de testes em identificação de objetos estranhos. Na Fig. 6a é apresentada uma imagem original com objetos estranhos na região das pernas (indicado por círculos vermelhos), enquanto na Fig. 6b é mostrado um exemplo de classificação automática de regiões, sendo as regiões verdes os objetos estranhos (classe “Outros”) e as regiões azuis e vermelhas (classe “Osso” e “Tecido/Músculo”) pertencentes ao corpo humano. O método utilizado é a combinação de texturas com MLP.

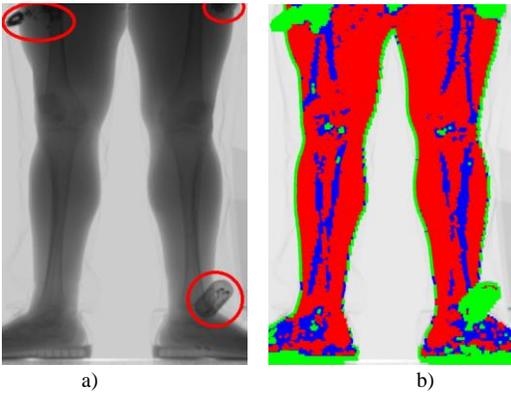


Figura 6. Resultado de classificação automática de objetos estranhos nas pernas. Em a) imagem original e b) segmentação das classes: “Outros” (cor verde), “Ossos” (cor azul) e “Tecido/Músculo”.

Na Fig. 7a é apresentado outro exemplo de imagem com objetos estranhos circulosados em vermelho. As regiões classificadas automaticamente como regiões estranhas ao corpo humano estão isoladas e mostradas na Fig. 7b. É possível perceber a incidência de falsos-positivos em regiões recorrentes como, por exemplo, nas bordas das pernas e na região da rótula.

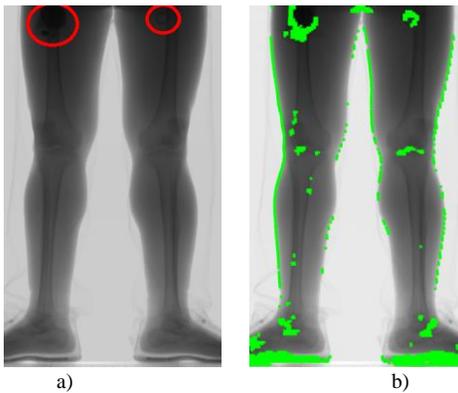


Figura 7. Resultado de classificação automática de objetos estranhos nas pernas. Em a) imagem original e em b) a classes “Outros” (cor verde).

4 Conclusão

Neste trabalho é apresentado um novo método de identificação automática de objetos estranhos em imagens de Scanner de pessoas, nas regiões das pernas. Este método é formado pela combinação de medidas de texturas e um classificador. Foram testados os classificadores KNN, K-médias e a MLP.

Os resultados obtidos com o método, que combina textura com a rede neural MLP, foram mais efetivos em relação aos classificadores KNN e K-médias testados. Uma restrição deste método é a presença de falsos-positivos nas bordas das pernas e na região da rótula.

Como trabalho futuros se pretende minimizar ou eliminar a presença de falsos-positivos, principalmente, nas bordas das pernas em uma etapa de pós-processamento.

5 Agradecimentos

Os autores agradecem ao CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro.

6 Referencias

- Ahmed, W.M.; Zhang, M. and Al-Kofahi, O. Historical comparison of vehicles using scanned x-ray images. *IEEE Workshop on WACV*, pp.288,293, 5-7 Jan. 2011
- Coxson, H.O.; Rogers, R.M.; Whittall, K.P.; D'yachkova, Y.; Paré, P.D.; Sciruba, F. C. et al, A quantification of the lung surface area in emphysema using computed tomography. *American Journal of Respiratory and Critical Care Medicine*, vol. 159, no. 3, pp. 851-856, 1999. Erratum in: *American Journal of Respiratory and Critical Care Medicine*, vol. 163, no. 6, pp.1500-1, 2001.
- Felix, J.H.S.; Cortez, P.C.; Rebouças-Filho, P.P.; Alexandria, A.R.; Costa, R.C.S. and Holanda, M.A. Identification and Quantification of Pulmonary Emphysema through Pseudocolors. *Lecture Notes in Computer Science*, vol. 5317, pp. 957-964, 2008.
- Christodoulou, C. I. S. C. Michaelides, C. S. Pattichis, “Multifeature texture analysis for the classification of clouds in satellite imagery”, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, no. 11, pp. 2662-2668, 2003.
- Sabino, D.M.U. et al. A texture approach to leukocyte recognition. *Real-Time Imaging*, vol. 10, pp. 205 - 216, 2004.
- Haralick, R.M.; Shanmugam, K. and Dinstein, I. Textural features for image classification”. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 3, no. 6, pp. 610 - 621, 1973.
- S. Livens, “Image Analysis for Material Characterization”. Tese (Doutorado)-Departamento de Física, Universidade de Antwerpia, Bélgica, 1998.
- Haralick, R.M. Statistical and Structural Approaches to Texture. *Proceedings of IEEE*, vol. 67, no. 5, pp. 786 - 804, 1979.
- Cover, T.M. and Hart, P.E. Nearest neighbor pattern classification”, *IEEE Transc. on Information Theory*, vol.13, pp. 21–27, 1967.
- MacQueen, J.B. Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability, 1, pp. 281-297. University of California Press, 1967.
- Duda, R.O. Hart, P.E. and Stork, D.G. *Pattern Classification*, New York: John Wiley & Sons, 2001, pp. xx + 654, ISBN: 0-471-05669-3. *J. Classif.* 24, 2 (Sept. 2007), 305-307.
- Medeiros, C.M.S. Uma Contribuição ao Problema de Seleção de Modelos Neurais Usando Princípio de Máxima Correlação dos Erros. Tese (Doutorado), Universidade Federal do Ceará, 2008.
- Rocha Neto, A.R. SINPATCO – Sistema Inteligente para Diagnóstico de Patologias da Coluna Vertebral. Dissertação (Mestrado), Universidade Federal do Ceará, 2006.