

CARACTERIZAÇÃO DE LESÕES DE PELE EM IMAGENS DIGITAIS A PARTIR DA MÁQUINA DE VETOR DE SUPORTE

OLIVEIRA, Roberta Barbosa
Universidade Estadual Paulista (UNESP)
roboliveira1@gmail

GUIDO, Rodrigo Capobianco
Universidade Estadual Paulista (UNESP)
guido@ibilce.unesp.br

MARRANGHELLO, Norian
Universidade Estadual Paulista (UNESP)
norian@ibilce.unesp.br

ARAUJO, Alex F. de
Faculdade de Engenharia da Universidade do Porto (FEUP)
fa.alex@gmail.com

TAVARES, João Manuel R. S.
Faculdade de Engenharia da Universidade do Porto (FEUP)
tavares@fe.up.pt

ROSSETTI, Ricardo Baccaro
Clínica DERM
rbrossetti2010@hotmail.com

PEREIRA, Aledir Silveira
Universidade Estadual Paulista (UNESP)
aledir@ibilce.unesp.br

RESUMO: Este trabalho apresenta um método para a caracterização das lesões de pele, a partir das características da regra ABCD (assimetria, borda, cor e diâmetro) e análise de textura. As características ABCD são obtidas de acordo com o dermatologista e a textura das imagens é definida pela sua dimensão fractal, por meio do método *box-counting*. As características de assimetria e textura extraídas das imagens são utilizadas como entradas para o classificador SVM (Máquina de Vetor de Suporte), que é uma técnica baseada em aprendizado estatístico, utilizada para o reconhecimento de padrões em imagens. O SVM classifica a assimetria das lesões em simétrica ou assimétrica e a textura das lesões em lisa ou rugosa. Todas as informações referentes as características extraídas da lesão são passadas ao dermatologista com o intuito de auxiliá-lo no diagnóstico.

PALAVRAS-CHAVE: lesões de pele, filtro mediana, Chan-Vese, SVM, dimensão fractal, *box-counting*.

ABSTRACT: *This paper presents a method for the characterization of skin lesions, from the characteristics of the ABCD rule (asymmetry, border, color and diameter) and texture analysis. The ABCD characteristics are obtained according to the dermatologist and the texture of images is defined by its fractal dimension through the box-counting method. The asymmetry and texture features extracted from the images are used as inputs to the SVM classifier (Support Vector Machine) which is a technique based on statistical learning, used for recognizing patterns in images. The SVM classifies the asymmetry of lesions in symmetrical or asymmetrical and the texture of lesions in smooth or rough. All information related the extracted features of the lesion are available to the dermatologist in order to assist in his diagnosis.*

KEYWORDS: *skin lesions, Chan-Vese, SVM, fractal dimension, box-counting.*

INTRODUÇÃO

O número de casos de cânceres tem aumentado cada vez mais, conforme apresentado na estimativa de incidência de câncer no Brasil, para ano de 2012 e também em 2013, realizada pelo Instituto Nacional de Câncer (INCA) (MINISTÉRIO DA SAÚDE, 2011). O câncer de pele corresponde a 29% dos tumores malignos registrados no país, sendo o de maior incidência. O grande número de casos de câncer motivaram a construção de sistemas computadorizados para auxiliar os dermatologistas no diagnóstico de lesões de pele. Estes sistemas tem como o objetivo principal analisar as lesões benignas, para evitar o seu desenvolvimento, ou diagnosticar as lesões malignas em seu estágio inicial, para serem tratadas precocemente, período onde tem mais chances de cura.

No diagnóstico dermatológico as lesões são examinadas clinicamente, utilizando primeiramente a técnica de análise das características ABCD (assimetria, borda, cor e diâmetro) e textura, para então diagnosticá-las e tratá-las (WOLFF et al., 2006). Para facilitar este processo, os dermatologistas podem dispor de sistemas computacionais, que analisam as características das lesões de forma mais precisa, utilizando imagens digitais, obtidas pelo mesmo, para auxiliar no seu diagnóstico. Para a construção destes sistemas são muito utilizadas técnicas de processamento de imagens digitais e sistemas inteligentes, tais como, filtro mediana, para diminuir o efeito dos ruídos nas imagens, o modelo Chan-Vese para identificar a área doente e a máquina de vetor de suporte (SVM) para classificar as lesões de pele. O uso destas técnicas possibilitam uma análise mais rápida e informações mais precisas sobre as características das lesões e por essa razão são temas de diversos trabalhos para detecção e classificação de lesões de pele [2, 7, 12, 15, 17 e 20].

Um sistema automático para análise de lesões pigmentadas e diagnóstico de melanoma a partir de imagens adquiridas por câmera digital foi descrito por Alcón et.


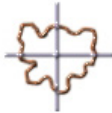






al. (2009). Essa combinação obteve 86% de precisão. Cudek et. al. (2010) apresenta um método para identificar lesões de pele a partir de imagens digitais usando a regra ABCD. A segmentação proposta obteve 92% de detecção correta. Maglogiannis e Doukas (2009) apresentam sistemas de visão computacional para caracterização de lesões de pele. Na classificação entre melanoma e nevo displásico a SVM obteve 100% de precisão. Na classificação entre nevos displásicos e lesões não displásicas, a SVM obteve 76,08%. Na classificação entre esses três tipos de lesões a SVM obteve 77,06% de precisão. Um método para detecção de borda em imagens dermatoscópicas de lesões melanocíticas e não melanocíticas é proposto por Norton e Colaboradores (2010). A avaliação deste método foi de 84,5% de acerto para as lesões não melanocíticas e 93,9% para as lesões melanocíticas. Rahman, Bhattacharya e Desai (2008) combinaram diferentes classificadores para o reconhecimento de melanoma em imagens dermatoscópicas. A SVM combinada com a probabilidade máxima gaussiana e o k vizinhos mais próximos obteve 62,50% de acerto para os nevos comuns, 77,14% de acerto para os nevos displásicos e 83,75% de acerto para os melanomas.

Com o objetivo de auxiliar o dermatologista no seu diagnóstico, este trabalho apresenta um método para caracterizar lesões de pele a partir de imagens fotográficas, tais como nevos, ceratose seborréica e melanoma, utilizando máquina de vetor de suporte (SVM).

1. Características das lesões de pele

As lesões de pele podem ser diferenciadas em benigna ou maligna, conforme suas características, analisadas pelos dermatologistas. A regra ABCD (assimetria, borda, cor e diâmetro) e a análise de textura são muito utilizadas pelos dermatologistas para analisar lesões de pele a partir de imagens fotográficas, contribuindo para o diagnóstico clínico. A demonstração desta regra é apresentada na Tabela 1.

Tabela 1. Demonstração da regra ABCD [adaptado de 18].

Características		Lesões benignas		Lesões malignas	
A	Assimetria	Simétrica		Assimétrica	
B	Borda	Regular		Irregular	
C	Cor	Única tonalidade		Várias tonalidades	
D	Diâmetro	Menor que 6 mm		Acima de 6 mm	

Na característica de assimetria (A) listada na linha “A” considera-se a maior distância entre os pontos do contorno da lesão e traça-se uma reta sobre a mesma, para que possa ser analisada a similaridade entre as duas partes divididas. Quando essas partes são semelhantes, a característica de assimetria é considerada simétrica, que geralmente representa as lesões benignas. No caso destas partes serem muito diferentes, esta característica é assimétrica, caracterizando lesões malignas. A borda (B) considerada regular representa lesões benignas e a borda irregular geralmente definem as lesões malignas, assim como mostrado na linha “B”. No caso da característica de Cor (C), as lesões benignas geralmente possuem apenas uma tonalidade e já as malignas possuem várias tonalidades, como pode ser visto na linha “C”. A característica de Diâmetro (D), especificada na linha “D”, das lesões benignas são menores, até 6 mm e das malignas são iguais ou maiores que 6 mm.

No caso da textura, as lesões do tipo ceratose seborréica (lesão benigna) são muito irregulares, sendo sua principal característica, e já os nevos melanocíticos (lesão benigna) e melanoma (lesão malig-

na) não são tão irregulares (CUCÉ et al., 2001).

2. Caracterização das lesões

O método desenvolvido tem por objetivo auxiliar o dermatologista no seu diagnóstico. São disponibilizadas informações referentes às principais características das lesões de pele. Na Figura 1 pode ser vista a estrutura do método desenvolvido neste trabalho.

A primeira etapa do método desenvolvido é a suavização das imagens por meio do filtro mediana, para eliminar os ruídos presentes nas mesmas. Depois é realizada a segmentação, utilizando o modelo de contorno ativo sem borda Chan-Vese (CHAN; VESE, 2001), para detectar a lesão. Para suavizar a borda e eliminar ruídos resultantes do processo de segmentação, são aplicados filtros morfológicos nas imagens. A partir da detecção da lesão, as características da regra ABCD e a textura são extraídas. As características de assimetria e textura são passadas ao SVM para as lesões serem classificadas em suas determinadas classes, simétrica ou assimétrica e regular ou irregular, respectivamente.

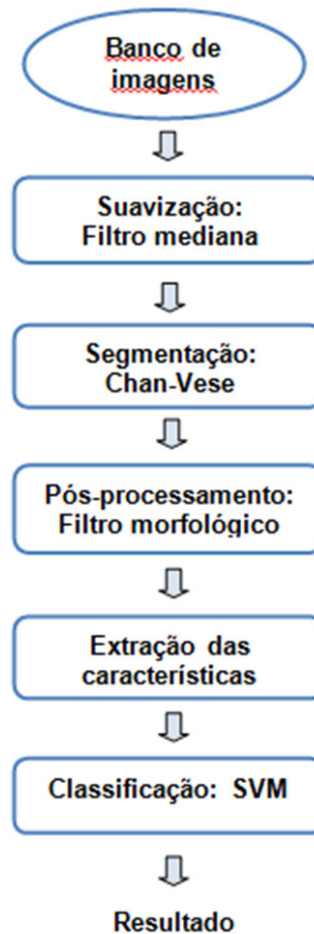


Figura 1: Diagrama do método desenvolvido para caracterização de lesões de pele.

2.1 Suavização

Nesta etapa foi realizada a suavização nas imagens da base, com o intuito de amenizar os efeitos dos ruídos presentes, como pelos e linhas da pele, que podem atrapalhar no resultado da segmentação. Foi utilizado o filtro mediana, que é considerado um método não-linear, ou seja, além de suavizar a imagem, também realça os contornos (GONZALEZ; WOODS, 2002). A aplicação deste filtro consiste em definir a intensidade de cada elemento da imagem, pela mediana da sua vizinhança de acordo com a máscara, definida com dimensão 7 X 7, que obteve melhor resultado de suavização. Nas imagens da Figura 2(b) pode ser visto o resultado da suavização aplicada em imagens originais, conforme a Figura 2(a), contendo lesões do tipo melanoma. A presença dos ruídos (pelos) foi amenizada.

2.2. Segmentação

A técnica utilizada para a segmentação das imagens neste trabalho é o modelo de contorno ativo sem borda, proposto por Chan e Vese (CHAN; VESE, 2001), que é aplicado por meio da minimização de energia da curva sobreposta à imagem. A segmentação deste modelo é baseada em região, e utiliza conceitos das técnicas de (MUMFORD; SHAH, 1989) e *Level Set* (OSHER; SETHIAN, 1988) para separar a região doente da região saudável.

São várias as vantagens deste método, que permite que seu uso tenha bons resultados: a detecção de diferentes objetos com variadas intensidades e ainda com fronteiras borradas; mudança topológica da curva; detecção de objetos onde o contorno não possui gradiente, isso não é possível com a utilização do modelo de contorno ativo tradicional (KASS et al., 1988); e tem-se um bom resultado na detecção dos objetos em imagens com ruídos.




Figura 2: Resultado da aplicação do método desenvolvido: (a) imagem original, (b) imagem suavizada, (c) imagem segmentada, (d) imagem pós-processada e (e) detecção do contorno da lesão.

Para a aplicação deste modelo a imagem suavizada em RGB é transformada em níveis de cinza e então definida uma curva sobre a mesma. A forma inicial da curva é quadrada com dimensão 140×140 , posicionada próxima ao centro da imagem, desta forma são realizadas menos iterações para a curva envolver completamente a lesão. Foram definidas 500 iterações para a evolução da curva, ou seja, a minimização da mesma ocorrerá até o número de iterações ou quando a curva estiver localizada sobre o objeto. O resultado da aplicação do modelo Chan-Vese possibilita a binarização da imagem, como pode ser visto nas imagens da Figura 2(c).

2.3. Pós-processamento

Filtros morfológicos são aplicados nas imagens binarizadas para tratá-las, eliminando ruídos internos e externos a lesão. Esses ruídos são provenientes das imagens com pelos, que não foram eliminados no processo de suavização, ou reflexos. Mas no caso dos reflexos, pode ser considerado que não estarão presentes nas imagens quando forem adquiridas corretamente.

Os filtros utilizados neste trabalho

foram a abertura seguida do fechamento, utilizando um elemento estruturante em forma de elipse, com os dois raios iguais a quatro, parâmetros que permitiram melhores resultados na etapa de pós-processamento. A aplicação desses filtros tem como intuito suavizar a borda, além de eliminar os ruídos. O resultado do pós-processamento pode ser visto nas imagens da Figura 2(d) a partir das imagens segmentadas da Figura 2(c). A borda foi suavizada e os ruídos externos a lesão foram eliminados. Os ruídos internos da lesão não foram eliminados completamente nos casos onde o elemento estruturante era menor que os ruídos, acarretando a definição de bordas falsas.

Depois de realizado este processo, o contorno é definido, como apresentado na Figura 2(e). O contorno (linha branca) representa as delimitações e irregularidades da borda, sendo importante para que as características da lesão possam ser extraídas, sem influência da pele.

2.4. Extração das características ABCD e textura

A partir do contorno da região segmentada pode-se extrair as características

ABCD (assimetria, borda, cor e diâmetro) e textura da lesão associada, que são muito utilizadas pelos dermatologistas para diferenciar lesões benignas das malignas.

2.4.1. Assimetria

Para extrair as características da assimetria foram utilizados apenas os pon-

tos que fazem parte da borda da lesão. A distância euclidiana (GONZALEZ; WOODS, 2002) foi aplicada para calcular as distâncias entre todos os pares de pixels da borda da lesão, para definir a maior diagonal D , representada pela reta amarela na imagem da Figura 3(a). Desta forma a lesão é dividida em duas partes (ARAUJO, 2010).




Figura 3: Características de lesões de pele: (a) representação da Assimetria e (b) representação da assinatura da borda.

Foram encontradas as perpendiculares de cada ponto da diagonal D com o seu determinado ponto do contorno, para as duas partes da lesão. Foram estabelecidas duas retas, perpendicular a diagonal, como no exemplo apresentado na Figura 3(a), que são representadas pela linha azul $P1$ e a linha vermelha $P2$. A quantidade de perpendiculares de cada imagem é diferente, dependendo do tamanho da diagonal da lesão. Considerando que as informações referentes as perpendiculares formam o vetor de característica utilizada pela SVM para classificar a característica de assimetria, o vetor deve possuir a mesma quantidade de características para todas as imagens. Desta forma, para estabelecer uma única quantidade de perpendiculares, foi calculado o número de saltos de pontos na diagonal maior, conforme a quantidade de perpendiculares desejadas. Sendo:

$$S = \text{perp} / A \quad (1)$$

onde S é o número de saltos ao percorrer a diagonal maior para encontrar as perpendiculares, perp é o total de perpendiculares encontradas anteriormente e A representa a quantidade de perpendiculares desejadas, formando uma conjunto de amostras de perpendiculares. Para cada perpendicular do conjunto de amostras é calculado a distância das retas do ponto da diagonal até

ponto da borda perpendicular a ele. Então, a característica que representa cada perpendicular é definida pela razão entre a distância menor sobre a maior. Estas características são passadas ao SVM para assim serem classificadas.

2.4.2. Borda

Para extrair informações da borda, primeiramente foram encontrados somente os pontos da mesma, utilizando a vizinhança de 8, a partir do primeiro ponto encontrado. Tendo a sequência correta dos pixels da borda, foi gerada a sua assinatura, representação unidimensional do contorno (GONZALEZ; WOODS, 2002), como demonstrado na Figura 3(b), onde a lesão é apresentada em vermelho. Considerando a assinatura da lesão, as informações referentes a irregularidade da borda são definidas pelo produto vetorial, que fornece a quantidade de picos, vales e retas que a borda possui (ARAUJO, 2010).

O produto vetorial utiliza três pontos (p_1, p_2 e p_3) do contorno para definir sua direção, com variação de i pixels, sendo calculado conforme a Equação 2. A aplicação do produto vetorial permite definir se o segmento do contorno formado por tais pontos é um pico, vale ou reta.

$$P = (x_2 - x_1)(y_3 - y_1) - (y_2 - y_1)(x_3 - x_1) \quad (2)$$

Assim, são considerados três pontos do contorno (x_1, y_1), (x_2, y_2) e (x_3, y_3), com um intervalo de quatro *pixels* ($i = 4$), para definir os picos, vales e retas menores e também com um intervalo de quinze *pixels* ($i = 15$), para representar os maiores. Posteriormente, calcula-se o produto vetorial para todos os pontos que representam o contorno. Associa-se um pico quando o valor é maior que zero ($P > 0$), um vale quando é menor que zero ($P < 0$) ou uma reta quando é igual a zero ($P = 0$). A quantidade de vales pequenos e grandes do contorno da região lesionada é então disponibilizado ao dermatologista para que ele possa analisar o quanto irregular é a borda.

2.4.3. Cor

A quantidade de tonalidades é a principal característica da regra de cor. A imagem RGB pode conter milhares de cores. Por esse motivo foi realizado a quantização da mesma para reduzir a sua quantidade em 10 cores, ou seja, o espaço de cores é dividido em 10 e os *pixels* com cores semelhantes são representados por uma única tonalidade. A contagem das cores é realizada somente na área da lesão. Considerando que a mesma pode conter alguns ruídos como pelos e reflexos, são descartadas as cores que possuem um grupo de até 100 *pixels* (ARAUJO, 2010). A quantidade de tonalidades encontradas na lesão é disponibilizada ao dermatologista para que ele possa definir se a lesão é uniforme ou não.

2.4.4. Diâmetro

Considerando que as imagens do

banco não possuem informações referentes ao diâmetro das lesões, a mesma é representada pela quantidade de *pixels* que compõem a diagonal maior, calculada pela distância euclidiana. São analisados todos os pontos do contorno, para definir quais pares de pontos possuem maior distância (GONZALEZ; WOODS, 2002). Uma demonstração da maior diagonal é vista na Figura 3(a) representada pela reta amarela D .

2.4.5. Textura

O método de extração das informações referentes à textura das lesões de pele é obtida pela dimensão fractal das imagens em níveis de cinza, que quantifica o seu nível de auto-similaridade. Existem diversas técnicas para este fim. Neste artigo a dimensão é obtida por meio do método box-counting (BCM), devido sua simplicidade (AL-AKAIDI, 2004). A dimensão fractal é aplicada para sinais 1D (voz, áudio e outros), mas também pode ser aplicada em imagens (sinais 2D). No caso de imagens, é encontrada a dimensão de cada linha e coluna da imagem separadamente e depois é feito o somatório de todas as dimensões, dividindo-se o valor pela quantidade total de dimensões da imagem. O valor resultante é somado com 1, obtendo-se um valor entre 2 e 3 (Equação 3).

$$D = \left(\frac{\sum D_i}{\text{quant}} \right) + 1 \quad (3)$$

Cada imagem é representada por um vetor com 18 características, utilizadas para gerar um conjunto de amostras, que serão utilizadas pelo SVM, tanto para o processo de treinamento como para o de testes (Figura 4(b)).

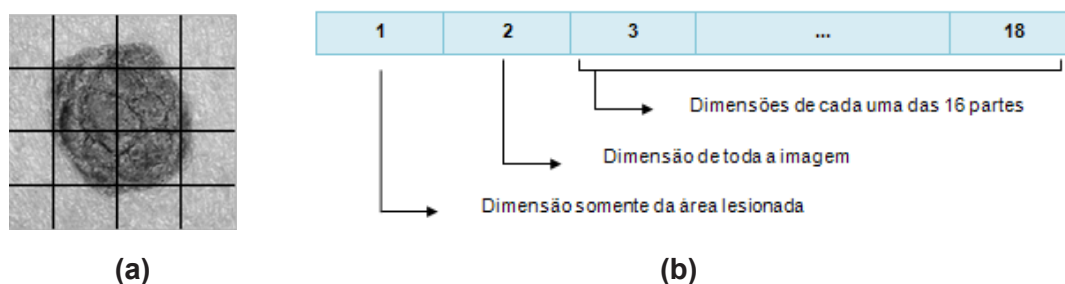


Figura 4: Características da textura das lesões de pele: (a) divisão da imagem em 16 partes iguais e (b) vetor com 18 características.

A primeira característica é a dimensão fractal somente da área lesionada, determinada na segmentação. A segunda característica representa a dimensão de toda a imagem. O restante das características (3 - 18) é composta da dimensão de cada uma das 16 partes iguais a qual a imagem é dividida (Figura 4(a)), com o objetivo de analisar o nível de auto-similaridade de diferentes partes da imagem separadamente. Essa divisão permite representar pelo menos quatro regiões diferentes da lesão, quantidade aqui utilizada para analisar sua textura separadamente. As características de textura extraídas das imagens são utilizadas como entradas para o classificador SVM (Máquina de Vetor de Suporte), para que sejam classificadas.

2.5 Classificação da assimetria e textura

O SVM é uma técnica baseada em aprendizado estatístico, utilizada para o reconhecimento de padrões em imagens (BURGES, 1988). O algoritmo deste traba-

lho é baseado no aprendizado supervisionado e utiliza a função de Kernel gaussiana, conforme a Equação 4.

$$K(x_i, x_j) = \exp(-\sigma \|x_i - x_j\|^2) \quad (4)$$

onde x_i e x_j são dois pontos do espaço de entrada e σ é um parâmetro informado.

As características de assimetria (A) e textura extraídas são utilizadas como entradas para o classificador SVM para identificar se a lesão é: simétrica ou assimétrica; lisa ou rugosa, respectivamente. Essa informação pode ser utilizada pelo dermatologista para auxiliá-lo em seu diagnóstico.

Considerando que o SVM é um método binário, o sistema é composto por uma máquina, responsável por classificar assimetria da lesão em simétrica, quando obter resultado +1, ou em assimétrica, tendo como resultado -1. Para a classificação, a máquina recebe as características de assimetria, conforme a quantidade de razões de perpendiculares estabelecidas, como pode ser visto na Figura 5.




Figura 5: Máquina de classificação de assimetria.

No caso da textura, a máquina, representada pela Figura 6, recebe como entrada as características de textura extra-

ídas. O resultado sendo +1 define a lesão como lisa e -1 define a lesão como rugosa.




Figura 6: Máquina de classificação de textura.

As informações estabelecidas pela extração de características e a Máquina de Vetor de Suporte para a regra ABCD e textura são disponibilizadas ao dermatologista com o objetivo de auxiliá-lo no seu diagnóstico.

3. Testes e resultados

A base experimental deste trabalho é formada por 408 imagens fotográficas, compostas por imagens do tipo nevo melanocítico, ceratose seborréica e melanoma, dos seguintes bancos: DermAtlas (2000), DermIS (2012) e Saúde total (2006). Há duas classes de textura: lesões lisas e as lesões rugosas. Sendo 224 imagens com textura lisa e 184 imagens com textura rugosa. No caso da assimetria, há 137 lesões simétricas e 271 assimétricas. As imagens da base utilizadas nos testes foram convertidas de JPG para BMP com 16 bits e para dimensão 200 x 200, para facilitar o processamento das mesmas. Na classificação utilizando o SVM foram utilizadas 50% das imagens para treinamento e os outros 50% para testes.

A partir da análise dos resultados obtidos na segmentação pelo método Chan-Vese, pode se concluir que o método desenvolvido é promissor, permitindo a extração das características para sua caracte-

rização, apesar de 1,93% das imagens contendo lesões do tipo melanoma, 6,45% das imagens de nevos e 5,81% das imagens representando a ceratose seborréica não terem sido detectadas.

Para a regra de assimetria foram realizados três testes com vetores de características diferentes (V1, V2 e V3) de entrada para o classificador SVM. Foi alterada a quantidade de perpendiculares, no termo A da Equação 1, para 10, 20 e 30 amostras desejadas. O primeiro vetor (V1) é formado por um conjunto de 10 características, o segundo vetor (V2) é composto por 20 características e o terceiro vetor (V3) corresponde 30 características, com coeficientes entre 0 e 1, que correspondem a razão das perpendiculares.

Na Tabela 2 podemos observar os resultados obtidos para a assimetria. Para classificar as imagens em simétrica ou assimétrica, o SVM obteve melhores resultados utilizando como entrada o vetor com 30 características. Com precisão de 73,04% para as duas classes correspondentes. No caso da simétrica o número de acertos foram maiores do que a assimétrica, tendo 84,06% de acerto. O resultado da precisão é calculado pela média, considerando a quantidade de acertos de cada classe e sua quantidade de imagens.

Tabela 2. Resultados da classificação da assimetria.

Testes	Simétrica		Assimétrica		Precisão
	Acertos	Erros	Acertos	Erros	
V1	63,77%	36,23%	73,33%	26,67%	70,10%
V2	63,77%	36,23%	71,11%	28,89%	68,63%
V3	84,06%	15,94%	67,41%	32,59%	73,04%

Para a análise de textura foram passadas para o SVM as 18 características extraídas da imagem, para classificar as lesões em lisa ou rugosa. O classificador obteve 72,84% de precisão para as duas

classes. As lesões lisas obtiveram um melhor resultado de acerto do que as rugosas, tendo 74,16% de acertos, como pode ser visto na Tabela 3.

Tabela 3. Resultados da classificação da textura.

Textura	Acertos	Erros	Precisão
Lisa	74,16%	25,04%	72,84%
Rugosa	71,23%	28,77%	

Os resultados tanto da segmentação como os da classificação se mostraram promissores na caracterização das lesões de pele. São disponibilizadas ao dermatologista as informações referentes a assimetria (simétrica ou assimétrica), borda (quantidade de vales pequenos e grandes do contorno), cor (quantidade de tonalidades), diâmetro (quantidade de *pixel* da maior diagonal) e textura (lisa ou rugosa) para auxiliá-lo no diagnóstico.

CONSIDERAÇÕES FINAIS

Neste artigo apresentou-se um método de caracterização de lesões de pele em imagens digitais a partir da máquina de vetor de suporte (SVM). Para minimizar os efeitos dos ruídos foi utilizado o filtro mediana, que eliminou parcialmente a presença dos ruídos, permitindo uma melhor segmentação das imagens muito ruidosas.

O modelo Chan-Vese se mostrou uma animadora técnica para segmentação de lesões de pele, apesar de não conseguir detectar corretamente as lesões quando existem regiões na imagem com uma área grande de sombra. Outro problema é a definição de bordas falsas devido aos reflexos com extensão muito grandes, não permitindo sua eliminação pela aplicação dos filtros morfológicos, considerando que o elemento estruturante não pode ser muito grande para não prejudicar a irregularidade da borda.

O resultado da caracterização das lesões com a utilização da máquina de vetor de suporte (SVM) se mostrou promissor na extração das características ABCD e textura; e na classificação das lesões simétricas e assimétricas; e também com texturas lisas e rugosas. Mas deve ser considerado que os resultados obtidos na classificação da assimetria e textura devem ser melhorados.

Uma outra etapa a ser desenvol-

vida futuramente neste trabalho é a classificação dos tipos de lesões de pele, tais como melanoma, ceratose seborréica e nevos melanocíticos. Todas essas informações reunidas são importantes para o dermatologista, porque pode auxiliá-lo no seu diagnóstico.

REFERÊNCIAS BIBLIOGRÁFICAS

AL-AKAIDI, M. **Fractal speech processing**. New York: Cambridge University Press, 2004.

ALCÓN, J. F.; CIUHU, C.; KATE, W. T.; HEINRICH, A.; UZUNBAJAKAVA, N. Automatic imaging system with decision support for inspection of pigmented skin lesions and melanoma diagnosis. **IEEE Journal of Selected Topics in Signal Processing**, v. 3, n. 1, p. 14-25, 2009.

ARAUJO, A. F. **Método para extração e caracterização de lesões de pele usando difusão anisotrópica, crescimento de regiões, watersheds e contornos ativos**. Tese de Mestrado, UNESP, São José do Rio Preto, 2010.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge**, v. 2, p. 121-167, 1998.

CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266-277, 2001.

CUCÉ, L. C.; FESTA NETO, C. (Org.) et al. **Manual de dermatologia**. 2 ed. São Paulo: Atheneu, 2001, 660 p.

CUDEK, P.; GRZYMALA-BUSSE, J. W.; HIPPE, Z. S. **Melanocytic skin lesion image classification**. Part I: Recognition of skin lesion. In: Conference on Human System Interactions (HSI). 3rd, Rzeszow, Poland, 2010, p. 251-257.

DERMATLAS. B. A. Cohen; C. U. Lehmann. Johns Hopkins University, **DermaAtlas**. Disponível em Dermatology Image Atlas: <<http://dermatlas.med.jhmi.edu/>> (Acesso em: 2012).

DERMIS. Diepgen TL, Yihune G et al. Dermatology Information System, **DerMIS**. Disponível em Atlas Dermatológico Online: <<http://www.dermis.net/>>. (Acesso em: 2012).

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 2. ed. New Jersey: Prentice Hall, 2002. 793 p.

KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **International Journal of Computer Vision**, v. 1, n.4, p. 321-331, 1988.

[12] MAGLOGIANNIS, I; DOUKAS, C. N. Overview of advanced computer vision systems for skin lesions characterization. **IEEE Transactions on Information Technology in Biomedicine**, v. 13, n. 5, p. 721-733, 2009.

MINISTÉRIO DA SAÚDE; INSTITUTO NACIONAL DE CÂNCER. **Estimativa 2012**: incidência de câncer no Brasil. Instituto Nacional de Câncer José Alencar Gomes da Silva, Coordenação Geral de Ações Estratégicas, Coordenação de Prevenção e Vigilância. Rio de Janeiro: INCA, 2011. 118 p.

MUMFORD, D. SHAH, J. Optimal approximations by piecewise smooth functions and associated variational problems. **Communications on Pure and Applied Mathematics**, v. XLII, p. 577-685, 1989.

NORTON, K. -A.; IYATOMI, H.; CELEBI, M. E.; SCHAEFER, G.; TANAKA, M.; OGAWA, K. Development of a novel border detection method for melanocytic and non-melanocytic dermoscopy images. In: **Annual In-**

ternational Conference of the IEEE EMBS, 32nd. Buenos Aires, Argentina, 2010, p. 5403-5406.

OSHER, S.; SETHIAN, J. A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton-Jacobi formulations. **Journal of Computational Physics**, v. 79, p. 12-49, 1988.

RAHMAN, M. M.; BHATTACHARYA, P.; DESAI, B. C. A multiple expert-based melanoma recognition system for dermoscopic images of pigmented skin lesions. *Bioinformatics and BioEngineering*, 2008. **IEEE International Conference on**. 8th, BIBE, p. 1-6, 2008.

SAÚDE TOTAL. **Câncer da Pele**: fotoproteção. Vida saudável com o sol. Disponível em <<http://www.saudetotal.com.br/prevencao/topicos/default.asp>>. Acesso em: 2012.

WOLFF, K.; JOHNSON, R. A.; SUURMONS, D. **Dermatologia**: atlas e texto. 5 ed. Rio de Janeiro: McGraw-Hill Interamericana do Brasil, 2006, 1092 p.

ZHAO, J.; SHAO, F.; XU, Y.; ZHANG, X.; HUANG, W. **An improved Chan-Vese model without reinitialization for medical image segmentation**. In: *International Congress on Image and Signal Processing (CISP 2010)*, 3rd. Yantai, 2010, p. 1317-1321.

Roberta Barbosa Oliveira possui graduação em Sistemas de Informação desde 2008 pela Fundação Educacional de Fernandópolis (FEF). Obteve o grau de mestre em Ciência da Computação, na linha de pesquisa de Processamento de Imagens e Visão Computacional pela Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP) - Campos de São José do Rio Preto / SP, Instituto de Biociências, Letras e Ciências Exatas (IBILCE) em 2012.

Rodrigo Capobianco Guido possui graduação em Ciência da Computação pela UNESP - câmpus de São José do Rio Preto-SP, graduação em Engenharia de Computação pela Fundação Educacional de Votuporanga - FEV. Obteve o grau de Mestre em Engenharia Elétrica pela Faculdade de Engenharia Elétrica e de Computação da UNICAMP e de Doutor em Física Aplicada Computacional pelo Instituto de Física de São Carlos da USP. Obteve título de Livre-docente na área de Processamento Digital de Sinais pelo Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos da USP.

Norian Marranghello possui graduação em Engenharia Eletrônica pela Pontifícia Universidade Católica do Rio Grande do Sul (1982), mestrado em Engenharia Elétrica pela Universidade Estadual de Campinas (1987), doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (1992), pós-doutorado em Sistemas de Computação pela Universidade de Aarhus na Dinamarca (1998) e livre-docência em Sistemas Digitais pela Universidade Estadual Paulista (1998). Atualmente é Professor Titular da Universidade Estadual Paulista.

Alex F. de Araujo graduou-se em Ciências da Computação na Universidade Federal de Goiás/Catalão em 2007. Obteve o grau de mestre em Ciências da Computação na Universidade Estadual Paulista "Júlio de Mesquita Filho"/São José do Rio Preto em 2010. Atualmente é doutorando em Engenharia Informática na Faculdade de Engenharia da Universidade do Porto.

João Manuel R. S. Tavares licenciou-se em Engenharia Mecânica na Faculdade de Engenharia da Universidade do Porto (FEUP) em 1992. Obteve os graus de Mestre e de Doutor em Engenharia Electrotrônica e de Computadores, também na FEUP, em 1995 e 2001, respectivamente. Desde 2001, é Investigador sênior e Coordenador de Projeto no Laboratório de Óptica e Mecânica Experimental (LOME), do Instituto de Engenharia Mecânica e Gestão Industrial (INEGI). É Prof. Auxiliar do Departamento de Engenharia Mecânica (DEMec) da FEUP desde 2001 até 2011 e Prof. Associado do mesmo departamento desde 2011.

Aledir Silveira Pereira é graduado em Engenharia Elétrica, sendo engenheiro Eletrônico e Eletrotécnico. Tendo obtido o título de mestre em Engenharia Elétrica pela USP - Universidade de São Paulo e título de doutor em Física Aplicada Computacional pela USP em 1995. Atualmente é professor assistente doutor pela UNESP - Universidade Estadual Paulista junto

OLIVEIRA, R. B.; GUIDO, R. C.; MARRANGHELLO, N.; ARAUJO, A. F.; TAVARES, J. M. R. S.; ROSSETTI, R. B.; PEREIRA, A. S.

O primeiro autor agradece a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES pela sua bolsa de Mestrado. Os autores são gratos à Fundação para a Ciência e Tecnologia - FCT, em Portugal. Também agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnologia - CNPq e à Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP pelo suporte financeiro.