

Diagnóstico de Melanoma através de Padrões Binários Locais e Decomposição Espacial

Pedro Thiago Cutrim dos Santos¹, Lucas Bezerra Maia¹,
Geraldo Braz Junior¹, João Dallyson Sousa de Almeida¹, Anselmo Cardoso de Paiva¹

¹ Núcleo de Computação Aplicada - Laboratório de Mídias Interativas
Universidade Federal do Maranhão (UFMA) – São Luís, MA – Brazil

{thiagocutrim, lucas.maia, paiva}@nca.ufma.br, {geraldo.braz, joao.dallyson}@ufma.br

Abstract. *Skin cancer is the cancer form with the highest incidence in the population, and although melanoma is a small fraction of these incidences, it is usually the most severe type of skin cancer. Several types of approaches in the area of automatic detection and diagnosis of this type of disease are being explored as pattern recognition techniques along with machine learning. This work aims to study binary local patterns associated with the spatial decomposition of the lesion region for the automatic detection of melanoma. The study, which compares the performance of the application of three different classifiers to the problem, achieves the best 0.88 result of accuracy and accuracy for the PH2 base demonstrating the methodology's efficiency to the problem of melanoma detection.*

Resumo. *O câncer de pele é a modalidade de câncer com maior incidência na população, e, apesar do melanoma ser uma pequena fatia dessas incidências, costuma ser o tipo de câncer de pele mais severo. Diversos tipos de abordagens na área de detecção e diagnósticos automáticos desse tipo de doença estão sendo exploradas como técnicas de reconhecimento de padrões juntamente com aprendizado de máquina. Este trabalho busca estudar padrões locais binários associados a decomposição espacial da região da lesão para a detecção de melanoma em imagens dermatoscópicas. O estudo, que compara o desempenho da aplicação de três classificadores diferentes ao problema, atinge como melhor resultado 0,88 de precisão e acurácia para a base PH2, demonstrando a eficiência do método ao problema de detecção de melanoma.*

1. Introdução

O melanoma é um tipo de câncer que surge a partir dos melanócitos, células responsáveis pela fabricação da melanina, substância que confere cor à pele [Soares 2008]. Sua letalidade vem do seu grande potencial em produzir metástases, enviando células tumorais para outro órgãos, onde se desenvolverão. Apesar de ser o tipo de câncer de pele mais letal, pode apresentar altos índices de cura se for diagnosticado em seu estágio inicial. Sua manifestação é caracterizada pelo surgimento de uma pinta com tonalidade escura e bordas irregulares, podendo também apresentar coceira e descamação, porém, também pode se manifestar através de uma lesão pigmentada pré-existente, apresentando mudanças de cores que variam de marrom ao preto e também aumentos da área da lesão.

Este trabalho tem como objetivo o estudo de variantes de *Local Binary Patterns* (LBP e CLBP) juntamente com decomposições espaciais para extração de características relevantes para a detecção automática de melanoma em imagens de dermatoscopia. Comparou-se o desempenho de cada abordagem usando três classificadores, *Support Vector Machines* (SVM), *Random Forest* e *Logistic Regression*. A contribuição desse estudo consiste em gerar um método que tenha a capacidade de descrever o padrão do melanoma, mesmo em imagens que possuam grande variações ou em que este padrão esteja oculto, a ser disponibilizada principalmente como mecanismo de triagem para identificação precoce de lesões que podem levar ao melanoma.

O restante deste trabalho está organizado em mais 3 seções, sendo elas Metodologia, Resultados e Conclusão.

2. Metodologia

Esta seção apresenta a metodologia para utilização das duas variantes de LBP's como extratores de características juntamente com as abordagens de extração espacial. A Figura 1 apresenta as etapas do estudo: Pré-processamento, Decomposição Espacial, Extração de Características e Reconhecimento de padrões.

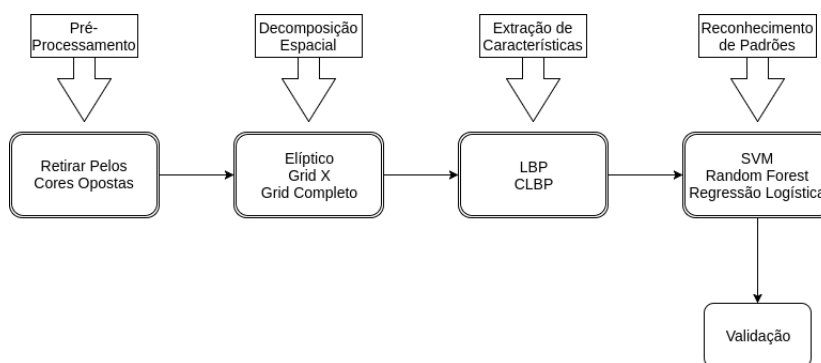


Figura 1. Etapas da metodologia proposta

2.1. Pré-processamento

Nas imagens, os pelos existentes podem vir a ser um fator externo que atrapalhe na classificação, sendo assim, é executado uma técnica de remoção dos mesmos na etapa de pré-processamento.

Cada imagem inicialmente é pré-processada para remoção de pelos, usando operações de fechamento morfológico, interpolação bilinear e suavização. Primeiro, é executado em cada canal de cor uma operação de fechamento morfológico, conforme [Masters et al. 2009]. Em seguida, cada subimagem é rotacionada nos ângulos 0°, 45° e 90° para localizar o sentido dos pelos. A generalização da escala de cinza é obtida através da resposta máxima das operações de fechamento morfológico em cada um dos ângulos.

$$G_C = |O_c - \max(O_C \bullet S_0, O_C \bullet S_{45}, O_C \bullet S_{90})| \quad (1)$$

Uma mascara binária é computada com base nas imagens $M(x, y)$, usando um valor T que representa um limiar definido.

$$M(x, y) = \begin{cases} 1, & \text{se } G_C(x, y) \geq T \\ 0, & \text{se outro valor} \end{cases} \quad (2)$$

Logo após, é gerada a máscara final dada pela união das máscaras de cada canal. Por fim aplica-se uma interpolação bilinear.

$$M = M_R \cup M_G \cup M_B \quad (3)$$

O espaços de cor mais utilizados em imagens é o RGB, que é formado pela união das cores vermelho, verde e azul. O problema é que este não é perceptivelmente uniforme [Bratkova et al. 2009]. Para contornar isso existe a teoria das cores opostas [Hering 1880], com o intuito de evidenciar características da imagem (exemplificada na Figura 2. O objetivo consiste em realçar padrões presentes em lesões de melanoma e ajudar tanto na segmentação aproximada da lesão quanto na descrição de textura.




Figura 2. Resultado da aplicação das cores opostas em uma imagem de dermatoscopia, sendo imagem original seguida respectivamente por O1, O2 e O3.

Finalmente, o *Otsu's Method* [Otsu 1979] é utilizado segmentar a região de lesão. Para retirar algumas áreas que passam pelo *threshold* que não sejam o melanoma, é realizada a segmentação aproximada da lesão usando *image moments* [Teague 1980] estimando o elemento com o centroide mais ao meio que possua uma área significativa.

2.2. Decomposição Espacial

A decomposição espacial tem como finalidade proporcionar localização da característica e, por conseguinte, ajudar na captura de padrões ocultos ou pouco frequentes na imagens, mas que são muito discriminatórios. As abordagens tratadas neste trabalho foram a *Elliptic*, *Grid X* e *Complete Grid*.

A abordagem elíptica gera elipses concêntricas, parametrizadas pelo valor de n , onde n é a quantidade de elipses concêntricas a serem geradas, sendo o centro dessas elipses o centro da ROI (Figura 3(a) com $n = 2$). A abordagem *Grid X* divide a ROI, utilizando as suas duas diagonais principais e gera 4 triângulos. A Figura 3(b) exemplifica a abordagem *Grid X*. A *Complete Grid* divide a ROI em 8 triângulos e não é parametrizada. A Figura 3(c) representa a abordagem *Complete Grid*.

2.3. Extração de Características

As técnicas utilizadas neste trabalho para extração de características foram a *Local Binary Pattern* (LBP) [Ojala et al. 1996] e *Compound Local Binary Pattern* (CLBP) [Ahmed et al. 2011], junto com todas as abordagens descritas na Seção 2.2. O




Figura 3. Decomposições espaciais. Em (a) Elliptic, em (b) Grid X e em (c) Complete Grid.

primeiro codifica o padrão binário ao redor do pixel num novo espaço correlacionado com a homogeneidade. O segundo oferece um complemento em relação ao primeiro que consiste na magnitude da diferença entre o pixel central e o seu vizinho.

A primeira técnica, LBP, foi aplicada em sua forma padrão, cujo cálculo é feito em uma janela 3×3 , ou seja, raio(R) = 1 e número de vizinhos(N) = 8. A segunda técnica, CLBP, foi calculada em janela 3×3 e o limiar T utilizado no cálculo foi a média dos módulos das diferenças entre o centro e os valores de nível de cinza vizinhos.

2.4. Reconhecimento e Validação

Para o reconhecimento, foram aplicados os classificadores *Support Vector Machine* (SVM) [Cortes and Vapnik 1995], *Random Forest* [Breiman 2001] e *Logistic Regression* [Ng and Jordan 2002]. Os três classificadores são conhecidos na literatura por apresentarem bons resultados, capacidade de tratar dados não lineares e otimizar o modelo gerado de maneira estatística e estrutural. A ideia de comparar os classificadores consiste em verificar qual deles possui a maior capacidade de generalização numa base desbalanceada e com grande quantidade de características.

A base de características foi normalizada entre -1 e 1. Após a etapa de normalização, utilizou-se *validação cruzada*, para verificar o desempenho e estabilidade do classificador, dividindo em n grupos de tamanho k . Destes n grupos, $n-1$ serão escolhidos para treino e o restante é usado para validação, este processo se repetirá até que todos os grupos tenham sido usados para validação. O parâmetro k escolhido foi 10. A validação dos testes foi realizada usando as métricas de acurácia e precisão médias. A acurácia verifica o acerto geral em toda a base de testes. Enquanto que a precisão média informa o acerto médio na classe melanoma.

3. Resultados

Os testes foram realizados sobre a base PH² [Mendonça et al. 2013]. A base contém 200 imagens de dermatoscopia, sendo 40 delas de melanomas e as 160 restantes de não-melanomas.

Cada combinação entre as abordagens e as técnicas de extração foram usadas junto com 3 classificadores. A Tabela 1 apresenta os resultados obtidos.

Pelo resultados apresentados na Tabela 1, verificou-se que a abordagem com LBP obteve o melhor resultado, atingindo 0,88 de precisão quando combinado com *Elliptic* e *Random Forest*.

Tabela 1. Resultados obtidos na combinação de variantes de LBP, decomposição espacial e classificadores em termos de precisão de acurácia

Método	Decomposição	SVM		<i>Random Forest</i>		Logistic Regression	
		Acurácia	Precisão	Acurácia	Precisão	Acurácia	Precisão
LBP	Elliptic	0,85	0,81	0,88	0,88	0,8	0,64
	Grid X	0,8	0,5	0,85	0,85	0,8	0,64
	Complete Grid	0,9	0,81	0,87	0,86	0,8	0,65
CLBP	Elliptic	0,85	0,66	0,86	0,85	0,86	0,85
	Grid X	0,82	0,57	0,84	0,83	0,85	0,83
	Complete Grid	0,82	0,58	0,87	0,86	0,86	0,85

Verifica-se o CLBP, mesmo ao codificar duplamente o padrão local, não foi capaz de superar o LBP tradicional. É provável, neste caso, que a separação das informações de textura não ajudam no processamento do padrão do melanoma.

Em termos de abordagem espacial, os melhores resultados foram obtidos usando o *Complete Grid* e *Elliptic*, que apresentam praticamente todos os melhores resultados com os classificadores. Em ambas características centrais recebem muito destaque em relação às demais, mas também características da borda são melhores capturadas. Esse resultado vem de encontro com a técnica comumente utilizada pelo especialista, a regra ABCD [Rosado 2009], que procura analisar entre outras características a borda e forma. Assim, pode-se destacar que essas duas abordagens de decomposição podem auxiliar no processo de melhoria de características de textura na borda de lesões.

Analisando em termos de classificador, verificou-se que o *Random Forest* se comportou de maneira mais uniforme do que os demais, independentemente do método de extração de características utilizado. O SVM atingiu altos resultados de acurácia, todavia com baixa precisão, verificando um claro problema de desbalanceamento da base, o qual o classificador não foi capaz de lidar. Em relação ao *Logistic Regression*, os valores de precisão são bem mais baixos do que os de acurácia, quando utilizado LBP, entretanto mostrou ser robusto ao usar CLBP como características.

4. Conclusão

Para o especialista, a análise de muitas imagens pode ser um processo enfadonho e repetitivo. O processo ainda requer um nível alto de atenção, pois as características do melanoma podem estar escondidas não só em características globais de cor, borda, assimetria e diâmetro. Este trabalho apresenta uma abordagem complementar que analisa características de textura locais, de forma espaciais, de maneira a propiciar a melhoria da descrição e desempenho.

O objetivo deste estudo foi, dado a dificuldade de análise de textura, realizar um estudo comparativo utilizando exclusivamente técnicas de análise de textura, de modo a fornecer uma segunda opinião ao especialista quando se depara com imagens que não apresentem características geométricas bem definidas.

Das técnicas utilizadas, o LBP apresentou resultados ligeiramente melhores que o CLBP, principalmente quando utilizado com *Random Forest*, que foi o classificador que mais se destacou, mantendo robustez em seus resultados. Já a Regressão Logística

mostrou melhores resultados, quando utilizado CLBP. O melhor resultado obtido foi do LBP, quando usado decomposição elíptica.

Verificou-se que o método ainda possui pontos a melhorar, tratados em trabalhos futuros, como por exemplo tratar do desbalanceamento da base que pode provocar tendenciamento do classificador, explorar outras maneiras de decomposição espacial, inclusive ponto a ponto usando semivariograma e ainda buscar variantes de LBP's que tratem a informação de cor de forma 3D e assim capturar a relacionamento conjunto da cor.

Referências

- Ahmed, F., Hossain, E., Bari, A., and Shihavuddin, A. (2011). Compound local binary pattern (clbp) for robust facial expression recognition. In *Computational Intelligence and Informatics (CINTI), 2011 IEEE 12th International Symposium on*, pages 391–395, Obuda University, Budapest, Hungary. IEEE.
- Bratkova, M., Boulos, S., and Shirley, P. (2009). orgb: a practical opponent color space for computer graphics. *IEEE Computer Graphics and Applications*, 29(1).
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Cortes, C. and Vapnik, V. (1995). Support vector machine. *Machine learning*, 20(3):273–297.
- Hering, E. (1880). *Zur Erklärung der Farbenblindheit aus der Theorie der Gegenfarben*, volume 1. Tempsky.
- Masters, B. R., Gonzalez, R. C., and Woods, R. (2009). Digital image processing. *Journal of biomedical optics*, 14(2):029901.
- Mendonça, T., Ferreira, P. M., Marques, J. S., Marcal, A. R., and Rozeira, J. (2013). Ph 2-a dermoscopic image database for research and benchmarking. In *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*, pages 5437–5440. IEEE.
- Ng, A. Y. and Jordan, M. I. (2002). On discriminative vs. generative classifiers: A comparison of logistic regression and naive bayes. In *Advances in neural information processing systems*, pages 841–848.
- Ojala, T., Pietikäinen, M., and Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1):51–59.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1):62–66.
- Rosado, L. F. C. M. G. (2009). Sistema automático para diagnóstico de lesões cutâneas baseado em imagens dermoscópicas. *Universidade do Estado do Rio Grande do Norte, Biblioteca Central Orlando Teixeira, BR-RN*.
- Soares, H. B. (2008). Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte.
- Teague, M. R. (1980). Image analysis via the general theory of moments. *JOSA*, 70(8):920–930.