



Universidades Lusíada

Viana, Joaquim Mesquita da Cunha, 1954-

Classificação de tumores de pele através da análise de imagens sem restrições : uma visão geral do processo

<http://hdl.handle.net/11067/5221>

Metadata

Issue Date 2010

Abstract A incidência de melanoma cresce rapidamente em indivíduos de raça branca, depois dos 20 anos de idade. Estatísticas dos EUA mostram cerca de 1 milhão de novos casos todos os anos. Os especialistas, através de um simples exame visual, conseguem com bastante precisão, determinar se uma lesão de pele é ou não maligna. Actualmente, não existem sistemas suficientemente fiáveis para classificação automática de sinais de pele. Este artigo apresenta uma visão geral de um novo método para classificação a...

The incidence of melanoma rises rapidly in Caucasians after the age of 20, and US statistics show about 1 million new cases every year. Specialists in the field are rather accurate in determining whether a skin lesion is cancerous or not based solely on a visual inspection. No systems exist for accurately classifying skin spots. This paper presents an overview of a novel method for automatic classification of skin tumours by segmenting the lesion's areas and determining ratios between the values...

Keywords Pele - Tumores - Diagnóstico

Type article

Peer Reviewed No

Collections [ULL-FCEE] LEE, n. 10 (2010)

This page was automatically generated in 2020-11-30T11:55:21Z with information provided by the Repository

**CLASSIFICAÇÃO DE TUMORES DE PELE ATRAVÉS
DA ANÁLISE DE IMAGENS SEM RESTRIÇÕES: UMA VISÃO
GERAL DO PROCESSO**

Joaquim da Cunha Viana

Doutor em Reconhecimento de Padrões (DeMontfort University)

Professor da Universidade Lusíada

Resumo

A incidência de melanoma cresce rapidamente em indivíduos de raça branca, depois dos 20 anos de idade. Estatísticas dos EUA mostram cerca de 1 milhão de novos casos todos os anos. Os especialistas, através de um simples exame visual, conseguem com bastante precisão, determinar se uma lesão de pele é ou não maligna. Actualmente, não existem sistemas suficientemente fiáveis para classificação automática de sinais de pele.

Este artigo apresenta uma visão geral de um novo método para classificação automática de tumores de pele, através da segmentação das áreas lesionadas e da determinação de relações entre os valores das características distintas fundamentais. Os valores calculados são depois testados através da aplicação de vários algoritmos de classificação de modo a obter uma classificação para o tumor: maligno ou benigno.

Abstract

The incidence of melanoma rises rapidly in Caucasians after the age of 20, and US statistics show about 1 million new cases every year. Specialists in the field are rather accurate in determining whether a skin lesion is cancerous or not based solely on a visual inspection. No systems exist for accurately classifying skin spots.

This paper presents an overview of a novel method for automatic classification of skin tumours by segmenting the lesion's areas and determining ratios between the values of the fundamental features. These data are then fed to several well know algorithms in order to achieve a tumour's classification: malignant or benign.

1. Introdução

O cancro de pele é a neoplasia mais frequente nos indivíduos de pele branca. De acordo com a Skin Cancer Foundation, a incidência de melanoma, o mais maligno dos tumores de pele, e a mortalidade dele resultante, têm aumentado exponencialmente durante os últimos 30 anos, e continuam a crescer [1]. Ainda que vulgarmente intratáveis em estados avançados, o cancro de pele em geral e o melanoma em particular, se detectados em estados iniciais, podem ser curados em mais de 95% dos casos [2].

A detecção da doença tão depressa quanto possível é pois crucial, para que se consiga curá-la.

A maior parte dos sistemas de classificação de lesões de pele baseia-se num equipamento de dermatoscopia [3, 4] - fotografia melhorada e ampliada da zona da lesão - apoiado por um perito humano. Mesmo assim e ainda que hajam reivindicações contraditórias, tanto quanto o autor julga saber, os resultados da classificação são ainda imprecisos e precisam de ser verificados através de biopsia da lesão e posterior análise laboratorial do tecido removido.

Os objectivos desta pesquisa foram o desenho e a implementação de um sistema capaz de classificar automaticamente sinais de pele como sendo inofensivos ou perigosos, com uma reduzida margem de erro; se possível, com maior precisão que os resultados conseguidos normalmente por um perito humano e certamente superior a qualquer outro sistema automático existente.

O sistema aqui descrito respeita esses critérios. Consegue extrair um conjunto de características relevantes, representativas dos quatro atributos determinantes para a classificação de lesões de pele - Assimetria, Fronteira (*Border*), Cor e Diâmetro [5, 6] a partir de imagens capturadas praticamente sem quaisquer restrições.

O processo implementado é multi-etapas, começando com a captura de uma imagem digital da lesão, tal como se pode ver na fig. 1. Nesta acção, deve ser garantida uma distância constante entre a lesão a fotografar e a lente da câmara.



Fig. 1 - Imagem Inicial

2. Segmentação

O passo seguinte consistiu na detecção, de forma tão precisa quanto possível, da orla que separa a pele normal da região lesionada [7]. Isto foi conseguido através da conversão da imagem policromática - RGB - para o standard CIELab [8, 9, 13], em tons de cinzento - um espaço de cor mais uniforme - resultando na imagem representada na fig.2.

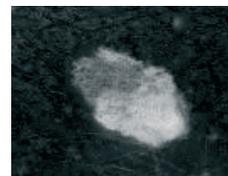


Fig. 2 - Imagem filtrada - CIELab

Tendo esta imagem ainda uma definição “excessiva”, o seu processamento sem quaisquer alterações originaria um número substancial de detecções de pontos de fronteira que seriam falsos positivos e falsos negativos. Para reduzir este número, foi aplicado um filtro de Gauss

$$G(x, y) = G(r) = \frac{1}{2\pi\sigma^2} e^{-\frac{r^2}{2\sigma^2}} \quad (1)$$

- em que $r^2 = \sqrt{x^2 + y^2}$ - à imagem da fig. 2, resultando numa imagem mais “suavizada” - ver fig.3.

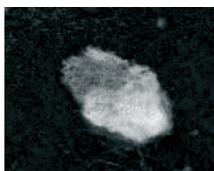


Fig. 3 - Imagem “suavizada” por filtro de Gauss

O passo seguinte no processo teve como objectivo definir, de forma grosseira, a posição da lesão no contexto da imagem. Com isto em mente, a próxima tarefa consistiu em determinar três valores para limiares, T , T_1 e T_2 . Isto conseguiu-se através da criação de um histograma de intensidades dos pontos da imagem. Para T_2 foi escolhido o valor correspondente ao nível de intensidade mais próximo de 255 pontos detectados na imagem. T_1 - parâmetro introduzido manualmente - foi definido como uma percentagem do valor de T_2 . O último valor foi calculado fazendo $T = \frac{T_1 + T_2}{2}$.

Os dois limiares T_1 e T_2 foram então aplicados à imagem anteriormente

“suavizada”. O resultado está patente na fig. 4.



Fig. 4 - Resultado da aplicação dos limiares T_1 e T_2 sobre a imagem suavizada

Por outro lado, a aplicação de um filtro de Sobel [10] à imagem “suavizada” da fig. 3 originou a imagem representada na fig. 5.



Fig. 5 - Resultado da aplicação do filtro de Sobel

A combinação destas duas últimas imagens, tornou possível a selecção de todos os pontos com um valor de gradiente máximo e residente no conjunto de pontos detectados pela aplicação dos limiares de intensidade T_1 e T_2 . Desta acção resultou uma imagem - fig. 6 - com uma orla ainda grosseira mas já muito próxima do objectivo desejado.

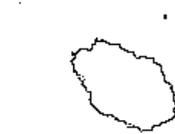


Fig. 6 - Combinação de T_1 , T_2 e Sobel

A aplicação do limiar T à imagem da fig.3 resultou numa nova imagem

que se apresenta na fig. 7.



Fig. 7 - Resultado da aplicação do limiar T

Ambas as imagens das figs. 6 e 7, combinadas, resultaram numa orla, muito mais fina mas ainda não completamente fechada, como se mostra na fig. 8. Os pontos irrelevantes [11] para a definição da orla foram então eliminados. Cada um dos restantes sem qualquer adjacência no conjunto de pontos da orla, foi ligado ao ponto mais próximo contido no conjunto.

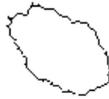


Fig. 8 - Orla mais fina (ainda não totalmente fechada)

Resultante de todo este processo, uma orla foi finalmente desenhada. Ainda que nem sempre com exactamente um ponto de espessura, resultou, ainda assim, suficientemente fina para ser usada neste trabalho. A segmentação final pode ser vista na fig. 9, com a orla detectada sobreposta à imagem inicial.



Fig. 9 - Imagem original segmentada

3. Extração de Atributos

Uma vez definida a fronteira da lesão, as suas principais características puderam então ser extraídas [13]. O primeiro valor a calcular foi o tamanho da lesão. Se todas as imagens processadas tiverem sido capturadas com a mesma resolução e a uma distância uniforme do ponto focal da câmara - o que não é difícil de conseguir - então, este atributo pode ser analisado como uma grandeza relativa e o número de pontos no interior da orla previamente detectada é uma boa aproximação.

Como forma de limitar a interferência do meio ambiente [14] sobre os atributos a extrair, para cada uma das restantes características importantes para a classificação, em vez de usar valores absolutos, foi decidido trabalhar, quase exclusivamente com relações entre valores. O primeiro passo no processo foi a definição de um ponto central da lesão. Um centro provável foi calculado encontrando as coordenadas do ponto em que os dois maiores diâmetros ortogonais se cruzam. Conhecendo estas coordenadas (x_c, y_c) foi possível calcular a distância Euclidean entre este ponto e cada um dos pontos da orla do sinal. Estes dados foram conseguidos fazendo:

$$r_i = \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2} \quad (2)$$

O raio médio - distância do ponto central à orla - foi então calculado:

$$r_{avg} = \frac{2}{N} \sum_{i=1}^N r_i \quad (3)$$

O desvio padrão do raio e o número de mudanças na direcção da orla do tumor permitiram a determinação do seu grau de assimetria.

Para o diagnóstico de tumores de pele malignos, mais importante que a cor do tumor é o número de cores diferentes contidas pela linha de fronteira do sinal. Assim, esta rotina de extracção de atributos concentrou-se, não só no cálculo do desvio padrão das cores dos *pixels*, mas também na medida do desvio padrão das diferenças de cor entre pontos adjacentes – variações de cor. Os valores para Mínima Cor, Máxima Cor e Total Cores devido à sua volatilidade – dependentes de vários factores externos – foram apenas usados para calcular valores derivados, tão independentes quanto possível.

Como alguns dos valores de atributos extraídos parecem ser estreitamente relacionados, foram também calculados valores para as relações entre eles, nomeadamente:

$$TCD_{TC} = \frac{\text{Total Diferença de Cores}}{\text{Total Cores}} \quad (4)$$

garantindo a normalização das diferenças de cor;

$$DC_{EP} = \frac{\text{Mudanças de Direcção}_{\text{orla}}}{\text{Nr. de pontos da orla}} \quad (5)$$

que, em conjunto com:

$$EP_{LF} = \frac{\text{Nr. de pontos da orla}}{\text{Nr. de pontos dentro da lesão}} \quad (6)$$

representam o nível de “suavidade” da linha de fronteira.

4. Classificação

O treino do sistema foi efectuado de forma supervisionada [13, 15, 16] – todas as imagens de lesões foram previamente classificadas por um perito antes de serem sujeitas ao escrutínio do sistema.

Todos os algoritmos previamente descritos foram aplicados a um subconjunto das imagens disponíveis e os resultados foram avaliados de acordo com a classificação prévia de cada uma das imagens – feita por um perito médico. Todos os classificadores foram treinados usando o mesmo subconjunto de imagens e foram posteriormente testados com o mesmo subconjunto de teste. Foram usados subconjuntos de treino com, 50%, 60%, 70% e 80% do total das imagens disponíveis. As restantes foram utilizadas pelo processo de teste do desempenho do sistema.

Os atributos relevantes atrás descritos foram então avaliados quer através de processos estatísticos de Bayes - *Naïve Bayes* e *Tree Augmented Naïve Bayes*- quer ainda através de classificadores do tipo *k-Nearest Neighbour*, *Fuzzy k-Nearest Neighbour*, *Support Vector Machine* e Rede Neuronal, de modo a conseguir classificar o sinal de pele como maligno ou benigno.

As probabilidades *a priori* para o sistema, foram calculadas de acordo com a distribuição de lesões malignas e benignas contidas no conjunto de exemplos. Considerou-se esta abordagem bastante aceitável uma vez que em situações destas, é menos problemática a obtenção de falsos

positivos do que deixar uma lesão maligna passar sem ser detectada.

Tanto o treino como os testes foram executados com o auxílio do pacote de software de código aberto Weka© versão 3.4.12, desenvolvido pela Universidade de Waikato na Nova Zelândia.

Com a utilização de 50% das imagens para treino, os melhores resultados conseguidos ultrapassaram ligeiramente os 82% de classificações correctas e foram obtidos com a *Support Vector Machine*. Embora já aceitáveis quando comparados com os 60% de média conseguidos pela análise visual da lesão por peritos humanos, os resultados são bastante melhorados quando o número de imagens para treino atinge os 80% do total de imagens disponíveis. As imagens classificadas correctamente são agora quase 93% do conjunto de amostras guardadas para o processo de teste. Os melhores classificadores são agora a *Tree Augmented Naïve Bayes* e o *Multilayer Perceptron*.

Tão importantes como as amostras classificadas correctamente – se não mais importantes – são os valores registados para as imagens incorrectamente classificadas. Estes vão dos quase 18% do total de imagens classificadas para a *Support Vector Machine*, até cerca de uns meros 7% para os dois classificadores com melhor desempenho.

Estes são resultados muito encorajadores quando comparados com outras peças de software e/ou equipamento, quer disponíveis no mercado quer em desenvolvimento em instituições académicas.

5. Conclusões

Os atributos seleccionados e utilizados ao longo de todo este trabalho são, tanto quanto é do conhecimento do autor, combinados de um modo totalmente inovador. Em vez de, simplesmente, seleccionar valores absolutos característicos das imagens processadas, esses números foram combinados, resultando em *ratios*, e garantindo assim uma muito maior independência face às condições ambientais durante o processo de captura das imagens.

Os algoritmos desenvolvidos foram implementados como um sistema totalmente funcional, o qual foi extensivamente testado. Conseguiram-se classificações correctas entre 76% e 93% – dependendo da percentagem de imagens usadas para treino do sistema. Em particular, com dois dos classificadores - *k-NN* e *Multilayer Perceptron* - o sistema não detectou quaisquer falsos negativos. Este resultado é crucial uma vez que, caso assim não fosse, os falsos negativos poderiam levar os pacientes a não procurarem tratamento, com consequências desastrosas para a sua saúde.

O autor está convencido de que o presente trabalho é uma contribuição válida para o campo do diagnóstico do cancro de pele. Ainda que o âmbito tenha sido limitado a uma lesão por imagem, os resultados alcançados por esta combinação de segmentação, extracção de atributos e algoritmos de classificação mostrou que este é o caminho correcto no sentido de se conseguir um sistema fiável de

diagnóstico precoce. Se e quando, a todos os dados aqui processados, se puderem adicionar valores para a idade, o género e a evolução temporal, os resultados serão, sem dúvida, ainda mais precisos, permitindo uma melhoria nos índices de sobrevivência dos doentes com cancro de pele.

6. Bibliografia

1. <http://www.skincancer.org/skincancer-facts.php>
2. <http://www.hcanc.org.br/dmeds/pele/pele1.html>
3. Menzies et al. - The Performance of SolarScan - Arch Dermatol. November 2005;141:1388-1396
4. Braun, R., French, L. and Saurat, J.-H. - Dermoscopy of pigmented lesions: a valuable tool in the diagnosis of melanoma - Swiss Med Wkly Number 134, pp. 83-90 - 2004
5. Abbasi et al - Early Diagnosis of Cutaneous Melanoma: Revisiting the ABCD Criteria - The Journal of the American Medical Association - December 8, Volume 292, Number 22, pp. 2771-2776
6. http://www.dermatoscopes.com/ABCDE-melanoma-algorithm.shtml-ABCDE_melanoma_evaluation_algorithm
7. Xu, M, Jackowsky, M., Goshtasby, A., Roseman, D., Bines, S., Yu, C., Dhawan, A. and Huntley, A. - Segmentation of skin cancer images - Image and Vision Computing - Elsevier - 1999
8. Tkalcic, M. and Tasic, I. - Colour Spaces - University of Ljubljana - 2002
9. Powell, M., Sarkar, M., Goldgof, D. and Ivanov, K. - A Methodology for Extracting Objective Color From Images - IEEE Transactions on Systems, Man and Cybernetics - Part B: Cybernetics, Volume 34, No. 5 - October 2004
10. Parker, J. R. - Algorithms for Image Processing and Computer Vision - Wiley Computer Publishing - 1997
11. Helderbrand, J. D., - One-Pixel-Wide Closed Boundary Identification - IEEE Transactions on Image Processing, Vol. 5, Nº 5, 1996
12. Richter, K. - Linear Relationship between CIELAB and Device Coordinates for a new Colorimetric Image Technology (CIT) - BAM and TU Berlin Federal Institute for Materials Research and Testing (BAM) - 2005
13. Theodoridis, S. and Koutroumbas, K. - Pattern Recognition 2nd Ed. - Elsevier Academic Press, 2003
14. Jähne, B. - Digital Image Processing, 5th Ed. - Springer-Verlag, 2002
15. Haykin, S. - Neural Networks and Learning Machines, 3/Ed. - Prentice Hall, 2009
16. Bishop, C.M. - Neural Networks for Pattern Recognition - Oxford University Press, 1995-2003