

SKAN – Skin Scanner: software para o reconhecimento de câncer de pele utilizando técnicas adaptativas

(21 Janeiro 2010)

H. S. Ganzeli, J. G. Bottesini, L. O. Paz e M. F. S. Ribeiro

Resumo — Este artigo tem como objetivo apresentar o sistema SKAN: Skin Scanner, um software que procura distinguir imagens de câncer de pele de imagens que contenham outros tipos de lesões cutâneas. A identificação de imagens de melanoma se baseia na regra ABCDE, que é utilizada comumente por dermatologistas para o diagnóstico por inspeção visual de uma mancha. O sistema, a partir da utilização de filtros de imagens e extração de atributos, avalia de forma independente os fatores da regra e decide, com o uso de técnicas adaptativas, o diagnóstico da mancha. A contribuição relaciona-se, portanto, ao sistema de pré-diagnóstico de câncer de pele com o uso de processamento de imagem e técnicas adaptativas na tomada de decisão. Além disso, o artigo apresenta um algoritmo de análise da borda da mancha que pode ser utilizado em outras aplicações, ou adaptado para outros fins. Esse sistema foi proposto pelos autores como projeto de formatura do curso de Engenharia Elétrica com Ênfase em Computação da Escola Politécnica da Universidade de São Paulo.

Palavras chave — Câncer, dermatologia, dispositivos adaptativos, melanoma, oncologia, pele, processamento de imagem.

I. INTRODUÇÃO

ESTE documento tem como objetivo apresentar um projeto de formatura do curso de Engenharia Elétrica com ênfase em Computação desenvolvido junto ao Laboratório de Tecnologias Adaptativas (LTA). O trabalho propõe, a partir do reconhecimento de imagem, discernir fotografias que contenham câncer de pele do tipo melanoma de outras que apresentem manchas de pele comuns. Esse sistema alia os conceitos de computação com a dermatologia e oncologia.

O artigo apresenta primeiramente um resumo dos conceitos médicos sobre câncer de pele envolvidos no desenvolvimento do projeto. A seguir, detalham-se as características técnicas do sistema desenvolvido, apresentando sua arquitetura e funcionamento, além de mostrar onde e como a utilização de técnicas adaptativas foi importante para a obtenção de resultados. Por fim, são apresentados os resultados atingidos e uma seção de trabalhos futuros, explicitando algumas possibilidades para a melhoria e continuidade deste trabalho.

II. CÂNCER DE PELE DO TIPO MELANOMA

O melanoma cutâneo é um tipo de câncer que tem origem nos melanócitos e tem predominância em adultos brancos.

Embora só represente 4% dos tipos de câncer de pele [4], o melanoma é mais grave devido à sua alta possibilidade de metástase – formação de nova lesão tumoral a partir da primeira.

Existem três tipos principais de câncer de pele: o carcinoma basocelular, o carcinoma de células escamosas e o melanoma, que é o menos comum, porém mais agressivo [3]. O carcinoma basocelular, mais comum dos três, acontece quando as células da camada germinativa se reproduzem descontroladamente. Ele costuma aparecer em áreas da pele que ficam mais expostas ao sol, e é facilmente tratável, causando a morte em pouquíssimas ocasiões. Já o carcinoma de células escamosas é um pouco mais raro, embora ainda seja relativamente comum. O mais raro destes três, e também o mais preocupante, é o melanoma. O melanoma ocorre quando os melanócitos começam a se reproduzir de forma desordenada [3]. A identificação de melanomas utiliza uma regra bastante simples, que é efetiva na maior parte das vezes: a regra ABCDE. Este recurso, baseado na inspeção visual, consiste em analisar algumas características da mancha na pele: a assimetria, as bordas, a coloração, diâmetro e evolução ou elevação [3]. Com a combinação destas características, é possível diferenciar, para a maior parte dos casos, um melanoma de manchas comuns e outros tipos menos agressivos de câncer.

O tratamento de melanoma é eficiente quando diagnosticado e retirado cirurgicamente na fase inicial. Se não for notado a tempo, pode evoluir para o estado invasivo. As células cancerosas podem espalhar-se para outras partes do corpo, invadindo e destruindo órgãos vitais e causando a morte [5].

A. Assimetria

Lesões benignas são simétricas, ou seja, suas metades são praticamente iguais. Por outro lado, as lesões malignas podem ser assimétricas. A Fig. 1 mostra uma comparação entre duas lesões quanto ao aspecto de simetria.




Fig. 1. Lesões simétrica (esquerda) e assimétrica (direita).

B. Borda

Lesões benignas apresentam bordas regulares, enquanto as

Este artigo é baseado em um projeto de formatura desenvolvido pelos alunos Heitor de S. Ganzeli, Julia G. Bottesini, Leandro de O. Paz e Matheus F. S. Ribeiro sob a orientação do Prof. Dr. João José Neto, no Laboratório de Linguagens e Técnicas Adaptativas (LTA EP/USP).

malignas podem tê-las irregulares, conforme a Fig. 2.



Fig. 2. Lesões com borda regular (esquerda) e irregular (direita).

C. Cor

Lesões benignas normalmente têm coloração marrom uniforme. As malignas podem apresentar variadas tonalidades de marrom ou preto, além de tons avermelhados, azulados e brancos. A Fig. 3 mostra um exemplo de mancha com apenas uma tonalidade (lesão da esquerda) e duas cores (lesão da direita).




Fig. 3. Lesões monocromática (esquerda) e policromática (direita).

D. Diâmetro

Lesões malignas geralmente apresentam diâmetro maior que 6 milímetros. A Fig. 4 compara o tamanho de duas lesões, ilustrando esse caso.




Fig. 4. Lesões com diâmetro menor que 6 milímetros (esquerda) e maior que 6 milímetros (direita).

E. Evolução ou elevação

As lesões malignas apresentam uma alteração de tamanho (aumento ou elevação) ao longo do tempo. Por ora, essa característica da mancha não é levada em consideração na análise feita pelo software.

III. ARQUITETURA DO SISTEMA

O sistema recebe uma imagem com uma mancha e tem como objetivo identificar características que indiquem a possibilidade de ser um melanoma. Não é responsabilidade do sistema filtrar imagens de entrada, bem como descartar figuras que não sejam manchas de pele, ou que não possuam as características de entrada adequadas. A Fig. 5 ilustra a arquitetura do sistema.

Neste esquema nota-se a presença de um módulo externo ao

SKAN, o “Validador da imagem”, cuja finalidade é realizar uma triagem das imagens, separando figuras válidas para submissão ao sistema. As imagens válidas devem conter uma mancha no centro da pele em uma área lisa do corpo humano, sem excesso de pelos ou outros inconvenientes que dificultem a localização da mancha. Também são descartadas fotos que não tenham a resolução mínima permitida ou que não sejam suficientemente nítidas.

O sistema, por sua vez, contém três módulos, cada um responsável por uma etapa no diagnóstico da lesão.

A. Tradutor da imagem

Este módulo traduz a imagem para um formato que possa ser facilmente interpretado pelo identificador de irregularidades. Para isso, foram utilizadas diversas técnicas de processamento de imagem, tais como a aplicação de filtros e outras técnicas para extrair valores de interesse. O módulo extrai os atributos da mancha, como contorno da borda, simetria e coloração, e repassa para o próximo módulo na forma de números. Os algoritmos para extração das características da mancha serão detalhados posteriormente.

B. Identificador de irregularidades

Este módulo procura interpretar os dados que recebe do “Tradutor da imagem”. Nessa etapa, os atributos extraídos são efetivamente analisados. Aplicam-se diversas técnicas a fim de se obter informações a respeito do formato da borda, simetria e coloração da mancha. Este módulo não associa essas características de forma a conseguir diagnosticar a doença.

C. Tomador de decisão

Módulo que analisa as informações fornecidas pelo identificador de irregularidades a respeito da mancha, e decide se ela é um melanoma ou não. Para isso, ele possui um conjunto de regras, implementadas na forma de árvore de decisão adaptativa. Caso a decisão tomada esteja errada, o paramédico poderá avisar o programa que o diagnóstico era equivocado. Assim, com a teoria adaptativa, esse módulo irá acrescentar ou modificar seu conjunto de regras para tomar a decisão correta, caso volte a encontrar uma entrada similar. Logo, se uma foto semelhante for submetida ao sistema novamente, as chances de um diagnóstico correto aumentam, tornando o sistema mais robusto.




Fig. 5. Arquitetura do software com os três principais módulos.

IV. ALGORITMOS PARA EXTRAÇÃO DE ATRIBUTOS

Para o processamento da imagem, e conseqüente extração de atributos, foram utilizados três filtros: o filtro preto e branco, filtro de contraste e o SRM, *Statistical Region Merging* [7].

O primeiro filtro aplicado na imagem é o SRM, que delimita regiões com coloração parecida e faz com que todos os pixels de uma mesma região sejam reduzidos à mesma cor [6]. A aplicação desse filtro é essencial para obter-se um resultado razoável na detecção de bordas porque ele localiza e delimita a mancha. A Fig. 6 mostra o resultado desse filtro ao ser submetido a uma imagem com uma lesão.

Fig. 6. Imagem de entrada (esquerda), resultado da aplicação do filtro com o algoritmo de segmentação *Statistical Region Merging* (centro) e resultado da aplicação do algoritmo de detecção de borda Canny (direita).

A detecção de borda diretamente na imagem original pode produzir resultados insatisfatórios, pois o filtro pode detectar bordas internas à mancha, devido a irregularidades na pele do paciente ou variações de iluminação. Assim, torna-se preciso eliminar os elementos da imagem que são irrelevantes para a detecção de borda, sendo essencial a aplicação do SRM.

O próximo passo do “Tradutor da imagem” é a delimitação da borda da lesão. Primeiramente, antes de passar pelo algoritmo de detecção de borda, a imagem do SRM é submetida a um filtro que separa os pixels da imagem em preto ou branco, de acordo com um limiar de cor. A submissão da mancha ao filtro preto e branco ressalta sua forma, separando-a da pele e tornando o cálculo da borda mais preciso.

As bordas em uma imagem são o resultado de mudanças

bruscas em alguma propriedade física ou espacial entre duas regiões adjacentes de superfícies iluminadas. A maioria das técnicas de detecção de bordas baseia-se na aplicação de operadores diferenciais de primeira ou de segunda ordem. Esses operadores ressaltam os contornos das bordas mas também amplificam o ruído da imagem. Grande parte dos operadores de borda utiliza algum tipo de suavização da imagem antes da operação diferencial. [8]

O Canny é um operador gaussiano de primeira derivada que suaviza os ruídos e localiza as bordas de uma imagem [9]. O detector tem como uma de suas principais características a dualidade entre a detecção e a precisão de localização das bordas, ou seja, quanto mais se privilegia a precisão de localização, menor é a razão sinal/ruído e, conseqüentemente, a detecção se torna cada vez mais sensível aos detalhes espúrios da imagem, e vice-versa [9]. Assim sendo, para cada imagem é necessária a escolha de um valor particular para o fator de escala do núcleo de convolução gaussiano. No software, essa variação do parâmetro é desnecessária devido à aplicação do filtro preto e branco anteriormente, que fornece um alto contraste entre a mancha e a pele.

A Fig. 6 também mostra o resultado do algoritmo de Canny aplicado à imagem de entrada. Pode-se notar que a borda é extraída com bastante precisão, embora dependa fortemente da qualidade da imagem de entrada. A aplicação do Canny não garante que a borda da mancha será um contorno fechado. Se a borda for uma linha contínua, o módulo “Identificador de irregularidades” irá realizar uma interpolação entre pontas da borda, a fim de fechá-la.

A partir da borda extraída pelo algoritmo de Canny, utilizou-se outro algoritmo para calcular as coordenadas de cada pixel da borda, primeiro em coordenadas retangulares, e em seguida, transformando-as para coordenadas polares. É feito um processamento de modo a obter um único valor de raio para cada ângulo inteiro. Em seguida, utilizando os pontos em coordenadas retangulares e uma rotina de regressão elíptica, aproxima-se a mancha pela elipse cujo erro quadrático seja o menor possível. Os pontos da elipse encontrada são novamente transformados para coordenadas polares, obtendo-se um raio para cada ângulo. O raio da elipse é subtraído do raio da borda. Assim, elimina-se a variação da borda em função do formato da mancha, ficando-se apenas com as flutuações relativas à irregularidade da borda. Obtém-se um gráfico, como mostrado na Fig. 7, que representa as saliências e reentrâncias da borda. Pode-se imaginar que as manchas são elípticas e essa flutuação é uma textura aplicada a elas. Cabe ressaltar que esse algoritmo proposto não é afetado pela posição da mancha, nem sua direção.




Fig. 7. Borda em coordenadas polares. A linha em vermelho representa a borda da lesão, a linha em azul mostra a melhor elipse que se aproxima do formato da lesão e a linha verde representa a diferença entre a borda da mancha e da elipse.

A área dessa função de flutuação é extraída, e sua grandeza indicará o quão irregular é a borda da mancha. Esse parâmetro não é suficiente para fazer tal afirmação; por isso, calcula-se a ondulação da borda tomando-se o maior e o menor picos, e fazendo-se a diferença entre eles. Em seguida, essa diferença é dividida pelo maior raio da mancha, obtendo-se assim um número representativo da amplitude de variação da borda. Esse número é utilizado como outro parâmetro para determinar se a borda é ou não irregular.

Para extração das cores internas à mancha, decidiu-se por utilizar dois métodos. Primeiro, a partir da imagem original, aplica-se o filtro SRM a fim de detectar na mancha diferentes regiões de cores. Depois, separa-se a mancha do restante da imagem, verificando-se todas as cores presentes na borda da imagem e transformando todos os pixels com essas cores em preto. Assim, a mancha fica isolada, com um fundo preto. Cabe ressaltar que esse método considera que a mancha está centralizada na figura e que não encosta na borda da imagem. A partir da imagem SRM, com a mancha isolada, é extraída a quantidade de cores diferentes presentes na mancha, além das porcentagens das duas maiores regiões em relação à área da mancha. Além disso, percebeu-se que, ao aplicar um filtro de contraste na imagem, diferentes cores ficavam mais exacerbadas. Decidiu-se então repetir o mesmo procedimento após a aplicação do filtro de contraste, e adicionar esse dado como um atributo extra para a análise das cores. A Fig. 8 apresenta a aplicação do filtro de contraste.




Fig. 8. - Imagem com contraste (esquerda) e após filtro SRM (direita).

Assim, o analisador de cores possui como parâmetros o número de cores presentes nas manchas, tanto com a aplicação do contraste quanto sem, e a área das maiores regiões da mancha comparada à área total da mancha. Ele considera o número de cores para a mancha com e sem contraste separadamente, sendo que quanto mais cores, maiores serão as

chances de que a mancha possua mais de um tom. Para as áreas extraídas, o valor da primeira maior área é somado à da segunda maior, e tanto o primeiro valor sozinho quanto a soma dos dois são comparados com a área total. Considera-se que quanto maiores forem essas áreas, mais chances a mancha tem de ser homogênea.

A extração da simetria utiliza um algoritmo que, a partir de uma máscara branco e preto da mancha, identifica o baricentro da mancha e traça círculos concêntricos a esse baricentro para identificar eixos de simetria. Com isso diz-se que quanto mais eixos de simetria a mancha tiver, mais simétrica ela será.

Por fim, o diâmetro da mancha é inserido manualmente no software pelo usuário. No momento não há uma forma de extrair o diâmetro automaticamente pois as fotos não trazem informação de escala.

V. ÁRVORE DE DECISÃO ADAPTATIVA

As árvores de decisão são dispositivos que representam funções discretas sobre um conjunto de variáveis de natureza hierárquica [1]. Elas facilitam a inspeção e uso por seres humanos. Os nós internos de uma árvore de decisão são responsáveis por realizar testes sobre alguma variável V , e de cada nó parte uma aresta para cada possível valor assumido pela variável [1]. O tomador de decisão do SKAN é formado por uma árvore de decisão adaptativa, que pode criar e excluir nós dinamicamente de forma a se adaptar e melhorar seu índice de acertos [10].

O treinamento é a etapa inicial do processo de decisão do SKAN. Um conjunto de imagens com manchas de melanomas e não-melanomas é submetido ao sistema para que ele possa montar suas árvores de decisão. Os atributos extraídos de cada imagem do treinamento são confrontados com sua classificação, previamente feita pelo especialista. Esse processo está dividido em duas fases: a primeira consiste na criação de quatro árvores de decisão básicas, uma para cada regra ABCD; e a segunda consiste na modificação e adaptação dessas árvores, submetendo-se a elas imagens de treinamento, de forma que adquiram uma maior capacidade de diferenciação dos resultados encontrados.

Dado um parâmetro P_i , que pode assumir valores no intervalo $]L_0, L_n[$, podemos representar um nó da árvore como mostra a Fig. 9.




Fig. 9. Representação de um nó da árvore adaptativa.

O nó é formado por um parâmetro e um conjunto de valores possíveis que esse parâmetro pode atingir. Essa faixa é dividida por valores, chamados de limiares, que determinam as arestas da árvore. Cada intervalo $]L_i, L_{i+1}[$ é um ponteiro que indica o próximo nó da árvore. O sistema pode alterar a faixa de limiares acrescentando e removendo intervalos, a fim de mudar o comportamento da árvore.




Fig. 10. Adaptatividade aplicada à árvore de decisão

A Fig. 10 mostra uma árvore binária com dois parâmetros de teste. Se o especialista ou o sistema perceber que o seu comportamento não é satisfatório, poderá alterar a estrutura da árvore criando ou excluindo nós. No exemplo, o sistema criou um novo intervalo na faixa de limiares do parâmetro P_1 com uma aresta para um novo ramo da árvore. Esse ramo irá tratar de um caso particular que o sistema incorporou. Analogamente, o mesmo raciocínio pode ser aplicado ao parâmetro P_2 . Cabe observar que a faixa de limiares não é única para o mesmo parâmetro, ou seja, a árvore poderá conter nós do parâmetro P_2 com faixas de limiares diferentes, dando mais flexibilidade à decisão dependendo do caminho que a análise seguiu na árvore.

O número de níveis da árvore também pode ser alterado, caso seja necessária a inserção ou remoção de parâmetros extras. Por fim, as folhas contêm informações que indicam o resultado da análise.

A segunda fase consiste em resubmeter as imagens de treinamento para adaptação da árvore.

Quando uma imagem que está percorrendo a árvore chega a uma folha, é feita uma comparação com a classificação original da mancha, dada pelo especialista. O resultado dessa comparação é registrado na folha, rotulando-a como positiva, indicando característica de câncer, ou negativa, caso contrário. Assim, cada folha representa uma combinação de resultados dos testes realizados nos nós pelos quais passou. Mesmo as folhas que antes eram consideradas indecisas passam a ter uma característica de decisão, embora ainda sejam diferenciadas das que já eram positivas ou negativas por apresentarem todos os testes com resultados negativos ou todos com resultados positivos. Uma vez realizada essa segunda fase, outras imagens que incidam nessa mesma folha poderão ser

diagnosticadas como sendo também de característica positiva ou negativa.

Além disso, há a possibilidade de existirem folhas sobre as quais não incidiram imagens, e que, portanto, não servem como dado para a conclusão de um diagnóstico, gerando um resultado de indecisão com relação à característica avaliada. Quando duas imagens, uma positiva e uma negativa, incidem sobre a mesma folha há a necessidade de adaptação da árvore, a fim de conseguir diferenciar imagens similares.

A ideia do algoritmo é percorrer em ordem ascendente os nós que levaram até aquela folha, procurando um parâmetro para o qual o valor do atributo da imagem divergente esteja afastado do valor do mesmo atributo para as outras imagens, que incidiram previamente sobre a folha. Achado esse parâmetro, divide-se esse limiar em dois, de forma a separar a imagem divergente das outras, e criar uma nova sub-árvore.

Caso em nenhum dos parâmetros o valor do atributo da imagem divergente esteja isolado dos outros, retorna-se para o nó mais próximo da folha em que o problema foi detectado e divide-se o limiar que aponta para a folha em três, de modo que o valor do atributo para a imagem divergente fique na faixa central. Cria-se, então, a nova sub-árvore a partir dessa faixa intermediária.

Após a montagem da árvore adaptativa na etapa de treinamento, o programa está apto a realizar diagnósticos. Os atributos extraídos das manchas de teste são submetidos às quatro sub-árvores de decisão, uma a uma, de forma a obter um diagnóstico de resultado para cada uma das quatro primeiras regras do método ABCDE. Cada um desses resultados pode ser: positivo, indicando que a mancha contém o problema que a regra se dispõe a identificar, como borda irregular ou heterogeneidade de cores; negativo, indicando o oposto; ou indeciso, indicando que até o momento o programa não possui condições para produzir um resultado com relação a essa imagem. Tendo esses resultados para cada uma das regras, o SKAN decide se a imagem tem chance ou não de ser câncer, com base nos resultados do treinamento, nos diagnósticos realizados previamente, e conceitos teóricos do método ABCDE.

Portanto, o diagnóstico se baseia nos dados históricos utilizando uma estrutura de dados que armazena os resultados de manchas já diagnosticadas. Assim, o software pode procurar nesta estrutura uma imagem com as mesmas características que já tenha sido diagnosticada. Em caso positivo, o diagnóstico será o mesmo. Caso contrário, apresenta-se a interface de correção de diagnóstico para que o especialista indique ao programa as características da mancha.

Essa correção irá alterar a topologia da árvore de decisão, de forma que ela se ajuste ao novo caso. Se o erro tiver acontecido por má interpretação dos atributos extraídos da imagem, as informações fornecidas pelo médico permitirão ao sistema identificar esse erro na árvore, corrigindo-o espontaneamente.

VI. RESULTADOS E CONTRIBUIÇÕES

A Tabela I ilustra os resultados finais com 20 imagens de teste, sendo 10 melanomas e 10 não-melanomas. O treinamento foi realizado considerando a mesma quantidade de imagens e evitando um banco de dados com amostras viciadas.

TABELA I
RESULTADOS DOS TESTES

	Acertos sem adaptação do diagnóstico	Acertos com adaptação do diagnóstico
Assimetria	11/20	9/20
Borda	13/20	15/20
Cor	12/20	13/20
Diâmetro	20/20	20/20
Melanoma	13/20	18/20

Com relação à assimetria, pode-se concluir que somente a análise do número de eixos de simetria não é suficiente para um bom diagnóstico dessa característica. Além disso, algumas manchas têm o mesmo número de eixos, porém diagnósticos diferentes. Nesse caso, o resultado é impreciso e demanda mais parâmetros de análise para casos dessa natureza. Sugere-se que a assimetria tenha outros parâmetros de decisão, como por exemplo, o nível de precisão usado pelo algoritmo na extração dos eixos.

A análise da borda apresentou um bom resultado devido ao tratamento matemático envolvido no cálculo da potência e da ondulação. Isso prova que o algoritmo desenvolvido nesse projeto foi consistente e apropriado para as análises.

A análise de cor se mostrou um pouco ineficiente, e considera-se que o método para extração das cores deve ser refinado.

O diâmetro permite uma decisão bastante simples quando comparado às demais características e, aliado ao fato de ser inserido manualmente pelo usuário, permitiu que o programa sempre acertasse o seu diagnóstico.

Os testes de adaptatividade foram feitos com as mesmas imagens e na mesma seqüência, corrigindo-se os diagnósticos indecisos. A inserção da adaptatividade aumentou a assertividade do programa diminuindo a quantidade de casos com respostas inconclusivas. Os casos antes indecisos são solucionados para que os próximos que forem similares sejam facilmente resolvidos.

A principal contribuição desse trabalho é a criação de um sistema de pré-diagnóstico de melanoma com a aplicação da tecnologia adaptativa. A adaptatividade interfere positivamente na tomada de decisão conferindo uma base de conhecimento mais consistente para o software. Portanto, o nível de precisão dos diagnósticos pode aumentar com o aprendizado fornecido pela adaptatividade nas tomadas de decisão. Outra importante contribuição, dentro do âmbito interdisciplinar, é o algoritmo de extração de bordas das manchas, que pode ser estendido a diversas aplicações como um reconhecedor de formas fechadas.

VII. TRABALHOS FUTUROS

De um modo geral, o sistema de reconhecimento do SKAN não faz uso de todas as características visuais possíveis para a avaliação da imagem. Sugere-se uma análise mais detalhada das cores internas da mancha; adição de outras características que a regra ABCDE não leve em conta; e a utilização de métodos paralelos para caracterização de cada irregularidade da mancha, buscando um resultado mais refinado. A evolução

da mancha não é analisada devido a falta de material para testes, mas pode ajudar na precisão dos diagnósticos.

Quanto à adição de características que a regra ABCDE não considera, tem-se a coceira, sangramento, e outras características visuais, muitas das quais podem ser percebidas com auxílio de um dermatoscópio [2]. A coceira e o sangramento dependeriam de informações clínicas sobre cada uma das fotos, e não se tem acesso a essas informações. Já outras características visíveis por meio de um dermatoscópio exigem que se tenham fotos feitas com o aparelho, que é pouco usado no Brasil, e torna esse tipo de imagem muito difícil de adquirir. No entanto, a adição desses parâmetros poderia ajudar e muito na identificação dos casos de melanoma, fornecendo ainda mais atributos para a análise e diferenciação entre os diversos casos.

Outro parâmetro a ser mais cuidadosamente considerado é a dimensão da mancha, de forma que seja possível sua extração automática. Propõe-se uma solução para esse problema, baseada em tamanhos relativos, na qual, ao fotografar a mancha, o operador insira no campo da foto um objeto de tamanho conhecido e de fácil aquisição, como uma moeda. Desse modo, seria possível obter por meio de software o tamanho da mancha relativo ao objeto, e conhecendo-se as dimensões do objeto, extrair diversas dimensões em valores absolutos, como maior e menor raio, entre outros.

Seria também interessante expandir as implementações de algoritmos para extração dos atributos. Não é preciso que uma característica seja analisada apenas por um algoritmo. Aliás, quanto mais diversificadas forem as informações extraídas para a avaliação de uma característica, e quanto mais processos analisarem essas informações, maior será a confiabilidade do resultado da análise para determinada característica.

Além de implementações que beneficiem diretamente a extração e análise de atributos e características, um conjunto de imagens estatisticamente representativo do que ocorre na população, utilizado para treinamento, poderia melhorar o desempenho do programa. Desse modo, os pesos de cada característica na determinação de um diagnóstico positivo seriam mais realistas.

A ordem de análise dos parâmetros pode influenciar nos resultados na tomada de decisão. Por isso, a adaptatividade [11] também pode ser aplicada na ordem de testes dos parâmetros. Acredita-se que a adaptatividade no módulo de extração de atributos possa também contribuir o aumento do índice de acertos. Na calibração dos parâmetros dos filtros, ela poderia ajudar na extração ótima das características da mancha, facilitando a análise e tomada de decisão.

É importante ressaltar que o pequeno número de amostras limitou as conclusões baseadas nos testes realizados. Os dados precisariam de tratamento estatístico de modo que se possa descobrir a função de distribuição dessas amostras. Com um número elevado de imagens, a melhora com a inserção da adaptatividade se tornaria mais visível.

Finalmente, para que o projeto alcance seu objetivo como quando da sua concepção, implementações equivalentes à feita para melanomas deveriam ser integradas ao SKAN. Desse modo, não apenas seria possível diagnosticar entre melanoma e não melanoma, mas entre diferentes tipos de câncer, ou outras doenças de pele. Quanto mais completo for o repertório

de análises que o programa executa, mais confiável será seu diagnóstico.

VIII. CONCLUSÕES

Este artigo apresenta um software desenvolvido como projeto de formatura e detalha os resultados alcançados pelo mesmo. O sistema extrai os principais atributos da lesão de pele e transforma-os em valores que podem ser submetidos ao dispositivo de decisão para diagnosticar um possível melanoma.

Uma outra aplicação do núcleo desse sistema fora do âmbito médico é o reconhecimento de contornos de formas, como folhas de vegetais, ou países. Há a possibilidade de adaptar o sistema para o reconhecimento de espécies de folhas a partir de seu formato. Também é possível identificar países, continentes ou outros territórios. Nesse caso, o reconhecimento torna-se ainda mais fácil, já que o contorno das fronteiras é constante. Já para folhas, exige-se um pouco mais de flexibilidade, embora essa possa ser provida pela árvore de decisão adaptativa. Todas essas aplicações envolvem uma abstração dos métodos e algoritmos de extração e comparação da borda previamente apresentados. Assim, pode-se perceber que esse projeto possui muito a contribuir nos campos de reconhecimento de imagens e tomada de decisão, além dessa aplicação para a área médica

REFERÊNCIAS

- [1] PISTORI, H. e NETO, J.J. *AdapTree - Proposta de um Algoritmo para Indução de Árvores de Decisão Baseado em Técnicas Adaptativas*. Anais Conferência Latino Americana de Informática - CLEI 2002. Montevideo, Uruguai, novembro, 2002.
- [2] EHRSAM, E. (2009). *Dermoscopy*. Acesso em 13 de junho de 2009, disponível em <http://dermoscopic.blogspot.com>.
- [3] RIVITTI, E., & SAMPAIO, S. A. (2007). *Dermatologia* (3ª ed.). Editora Artes Médicas.
- [4] INCA – Instituto Nacional do Câncer. *Câncer de Pele – melanoma*. Acesso em 01 de novembro de 2009, disponível em http://www.inca.gov.br/conteudo_view.asp?id=335.
- [5] ALVES, G. (2008). *Conheça o "ABCD" para diferenciar lesões de pele e câncer*. Acesso em 01 de novembro de 2009, publicado em <http://www.belezaestetica.com/content/detail.asp?iArt=539&iType=2&iChannel=1>.
- [6] CELEBI, M. E. (s.d.). *Fast and Accurate Border Detection in Dermoscopy Images Using Statistical Region Merging*. Acesso em setembro de 2009, disponível em [http://www1bpt.bridgeport.edu/~jelee/\[11\]pubs/SPIE-MI07.pdf](http://www1bpt.bridgeport.edu/~jelee/[11]pubs/SPIE-MI07.pdf).
- [7] LENSONE, E. d., POZ, A. P., & Nogueira, J. R. (setembro de 2009). *Detector de Bordas de Canny*. Acesso em 01 de novembro de 2009, disponível em [http://www.sbmec.org.br/eventos/cnmac/cd_xxvii_cnmac/\[12\]cd_cnmac/files_pdf/10348a.pdf](http://www.sbmec.org.br/eventos/cnmac/cd_xxvii_cnmac/[12]cd_cnmac/files_pdf/10348a.pdf).
- [8] BUENO, M. L. (s.d.). *Detecção de Bordas através de Algoritmo Canny*. Acesso em Setembro de 2009, disponível em http://www2.prudente.unesp.br/area_doc/imai/pdi/ufsc_notas/Canny_ufsc.htm.
- [9] SOUZA, J. B. (s.d.). *Apontamentos Sobre Processamento Digital de Sinais*. Acesso em Setembro de 2009, disponível em http://www.deetc.isel.ipl.pt/comunicacoes/disciplinas/pds/modulo3_20070103_1743.pdf.
- [10] TCHEMRA, A. H. (novembro de 2007). *Aplicação da Tecnologia Adaptativa em Sistemas de Tomada de Decisão*. Revista IEEE América Latina, Volume 5 (número 7), pp. 552-556.
- [11] NETO, J. J. (2001). *Adaptive Rule-Driven Devices - General Formulation and Case Study*. (B. W. Watson, & D. Wood, Eds.) *Implementation and Application of Automata 6th International Conference, CIAA 2001*, Vol. 2497, pp. 234-250.