

Detecção de Câncer de Pele com Redes Neurais Artificiais

Wysterlândia K. P. Barros, Daniel S. Morais and Marcelo A. C. Fernandes

Departamento de Computação e Automação (DCA)
Universidade Federal do Rio Grande do Norte (UFRN)
w.kyury@live.com, danielmorais@outlook.com.br.
mfernandes@dca.ufrn.br

Resumo Este trabalho tem como objetivo o desenvolvimento de uma técnica para detecção de câncer de pele utilizando redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) treinada com o algoritmo do *Backpropagation* (BP). A técnica proposta realiza um pré-processamento na imagem fonte retirando nove descritores que então são passados para MLP-BP. Resultados de validação utilizando um banco de dados público de imagens de câncer de pele são apresentados neste trabalho. As respostas apresentadas pela técnica proposta apresentaram resultados bastante satisfatórios quando comparados com a literatura, viabilizando a técnica para aplicações práticas e testes em outras bases.

Keywords: Câncer de pele, detecção de câncer, Multilayer Perceptron, Backpropagation

1 Introdução

A utilização de Inteligência Artificial (IA) aliada às técnicas de Processamento Digital de Imagem (PDI) vem sendo utilizada em diferentes áreas do conhecimento, incluindo a área médica, onde o uso destas novas tecnologias podem melhorar a obtenção de diagnósticos e torná-los mais precisos. A utilização de Redes Neurais Artificiais (RNAs) e PDI na detecção de tipos de câncer é objeto de estudos de vários grupos e trabalhos na literatura [5,6,8].

Os trabalhos apresentados em [2,7,9,10,12,13] propõem técnicas de detecção de câncer de pele utilizando RNAs e PDI. O trabalho apresentado em [12] propõe uma técnica de IA baseada em árvores na distinção entre imagens que apresentam câncer de pele do tipo melanoma de outras que apresentam manchas comuns. Os descritores extraídos das imagens em relação ao sinal foram a assimetria, bordas e coloração. Neste método a precisão foi de 65% sem adaptação do diagnóstico e de 90% com adaptação do diagnóstico. Já o trabalho apresentado em [2] propõe a distinção entre imagens que apresentam melanoma de outros casos benignos. São utilizados sete descritores da imagem, sendo estes o contraste, correlação, homogeneidade, ASM (*Angular Second Moment*) e a variância de cores RGB. Neste trabalho foi utilizado RNAs e se obteve uma precisão de 88%.

Um sistema que classifica automaticamente melanomas é proposto em [7], no qual os descritores da imagem são obtidos utilizando o método RSurf, LBP (*Local Binary Patterns*) e *Convolutional Neural Network*. Para a classificação utiliza-se a técnica de *Support Vector Machine* (SVM). No treinamento foram utilizadas 900 imagens, enquanto que para a validação utilizou-se 379 imagens. Este método obteve uma precisão de 82,6%. No caso do trabalho descrito em [9] é apresentado um sistema de diagnóstico automático de melanoma. As imagens a serem classificadas passam por um pré-processamento, em que há a correção da iluminação, a segmentação para obtenção do campo apenas do sinal e a aplicação de um filtro gaussiano. A técnica de IA utilizada para a classificação é a *Convolutional Neural Network*, que também é responsável pela extração das características da imagem. Esse método obteve uma precisão de 81%.

O artigo descrito em [13] descreve um sistema de diagnóstico automático de melanoma. As imagens a serem classificadas são segmentadas utilizando *Convolutional Residual Network*. A técnica de IA utilizada para a classificação é a *Very Deep Residual Network*. Para o treinamento da rede são utilizadas 900 imagens e para a validação 350 imagens, esse método obteve uma precisão de 85,5%. Finalmente, o trabalho apresentado em [10] apresenta uma proposta de um sistema de apoio à decisão clínica que classifica imagens com lesões suspeitas na pele para gerenciar uma lista de referência ao especialista. Serve como uma segunda opinião sobre a lesão em estudo. São utilizados o método dos K vizinhos mais próximos, um classificador paramétrico baseado na teoria da decisão de Bayes, um Perceptron Multicamada (MLP) e a combinação destes três métodos em um sistema colaborativo de classificação. Foram usados como descritores a variação da nitidez, média da componente R e G, homogeneidade da cor e média da luminosidade de cor HSL. Em relação ao MLP, verificou uma precisão de 87,76%.

Assim, com base nos trabalhos apresentados na literatura, este trabalho propõe uma técnica que utiliza um pré-processamento para extrair nove descritores da imagem original, os quais foram denominados de simetria em x , simetria em y , diâmetro, variância e média no canal R , variância e média no canal G e variância e média no canal B . Após a obtenção dos descritores, uma RNA é treinada para classificar duas classes chamadas de melanoma e a outra referente a não-melanoma. Os resultados mostram que, diferentemente das técnicas apresentadas na literatura, o método proposto neste trabalho atingiu uma precisão de 90%. Mostrando-se bastante eficaz frente aos outros trabalhos.

2 Descrição Geral da Técnica Proposta

A Figura 1 descreve em detalhes o esquema de detecção proposto no qual, a partir de uma base de dados de imagens dermatoscópicas, há a classificação de

sinais de pele. Uma dada imagem, \mathbf{V}^k , de $N \times M$ pixels expressa como

$$\mathbf{V}^k = \begin{bmatrix} v_{00}^k & \cdots & v_{0j}^k & \cdots & v_{0M}^k \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ v_{i0}^k & \cdots & v_{ij}^k & \cdots & v_{iM}^k \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ v_{N0}^k & \cdots & v_{Nj}^k & \cdots & v_{NM}^k \end{bmatrix}, \quad (1)$$

onde v_{ij}^k corresponde a um pixel de b bits da imagem, é processada por um bloco chamado de Módulo de Pré-processamento (MPP), no qual cria a imagem binarizada de \mathbf{V}^k , chamada de \mathbf{P}^k contornando o local do sinal. Com a informação da imagem \mathbf{P}^k , a imagem original \mathbf{V}^k passa por um bloco chamado de Módulo Extrator de Características (MEC) que possui como meta gerar um conjunto de nove descritores, expresso como $\mathbf{d}^k = [d_0^k, \dots, d_8^k]$. O conjunto de descritores é então processado por uma rede neural artificial do tipo MLP-BP com três camadas de neurônios, sendo duas camadas escondidas e uma camada de saída, nove entradas e duas saídas, expressas como $\mathbf{u}^k = [u_0^k, u_1^k]$. Os detalhes de cada etapa estão detalhados nas próximas subseções.




Figura 1: Estrutura geral do esquema de detecção proposto.

Neste artigo foi utilizada a base de dados PH² *Database* disponibilizada pelo ADDI Project [1]. O banco contém 200 imagens dermatoscópicas, as quais possui especificação de resolução de 768×560 pixels, mesma distância em que os sinais foram fotografados e ampliação de $20\times$. Também é disponibilizada a máscara em imagem binária que delimita a região do sinal. As imagens diagnosticadas por especialista se dividem em 80 nevos comuns, 80 nevos atípicos e 40 melanomas. A figura 2 mostra algumas imagens utilizadas.

3 Módulo de Pré-processamento (MPP)

Este módulo tem como objetivo gerar um imagem binarizada, \mathbf{P}^k , com o contorno do sinal de pele para servir como máscara na extração dos descritores. O processo de binarização é realizado a partir do histograma da \mathbf{C}^k , que é uma




Figura 2: Amostras de imagens utilizadas.

cópia da imagem original, \mathbf{V}^k , convertida na escala de cinza. Com base no histograma de \mathbf{C}^k é possível determinar um limiar, a , para gerar a imagem binarizada, \mathbf{P}^k . Assim, dado que \mathbf{C}^k pode ser expresso como

$$\mathbf{C}^k = \begin{bmatrix} c_{00}^k & \cdots & c_{0j}^k & \cdots & c_{0M}^k \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ c_{i0}^k & \cdots & c_{ij}^k & \cdots & c_{iM}^k \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ c_{N0}^k & \cdots & c_{Nj}^k & \cdots & c_{NM}^k \end{bmatrix}. \quad (2)$$

A imagem \mathbf{P}^k pode ser definida como

$$\mathbf{P}^k = \begin{bmatrix} p_{00}^k & \cdots & p_{0j}^k & \cdots & p_{0M}^k \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ p_{i0}^k & \cdots & p_{ij}^k & \cdots & p_{iM}^k \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ p_{N0}^k & \cdots & p_{Nj}^k & \cdots & p_{NM}^k \end{bmatrix}, \quad (3)$$

onde

$$p_{ij}^k = \begin{cases} 1 & \text{se } c_{ij}^k \geq a \\ 0 & \text{se } c_{ij}^k < a \end{cases}. \quad (4)$$

As Figuras 3, 4 e 5 exemplificam as etapas descritas acima, onde representam a imagem em escala de cinza, \mathbf{C}^k , e a imagem binarizada, \mathbf{P}^k , da amostra apresentada na Figura 2a. A Figura 4 ilustra o histograma da imagem em escala de cinza \mathbf{C}^k .

Para melhorar a qualidade da segmentação foram utilizadas operações morfológicas de abertura e fechamento. A abertura permite suavizar o contorno e eliminar as saliências finas. O fechamento também permite suavizar contornos, mas, ao contrário da abertura, funde as discontinuidades e preenche lacunas em um contorno [4].




Figura 3: Imagem em escala de cinza, C^k , da amostra apresentada na Figura 2a.




Figura 4: Histograma da imagem em escala de cinza, C^k , da amostra apresentada na Figura 2a.

4 Módulo Extrator de Características (MEC)

Na literatura existem vários métodos de classificação de Melanomas, como apresentados em [3], dos quais os mais comuns são os métodos chamados de ABCD, método de Pontuação de Menzies e lista dos Sete Pontos. Estes métodos têm como objetivo a diferenciação dermatoscópica entre lesões melanocíticas benignas e melanomas.

O método ABCD é utilizado por dermatologistas em todo o mundo, no qual observa alterações nos sinais de pele. Cada letra do método corresponde a um determinado aspecto de sinal de pele, sendo a letra A referente a assimetria, B referente a borda da região de sinal, C referente as cores no sinal e D referente a estruturas dermoscópicas. Essas características podem auxiliar o diagnóstico para saber se há chances do sinal ser um melanoma, uma vez que assimetria,




Figura 5: Imagem binarizada, \mathbf{P}^k , da amostra apresentada na Figura 2a

bordas irregulares, diferentes cores presentes e determinadas estruturas dermatoscópicas, podem ser um indicativo de câncer [3].

Já o método de Pontuação de Menzies consiste na diferenciação dermatoscópica entre lesões melanocíticas benignas e melanoma. Esse método consiste na identificação de características dermatoscópicas do sinal que podem indicar diagnóstico negativo ou positivo de melanoma. Para a lesão ser diagnosticada como melanoma, ela deve ter nenhuma das duas características negativas e uma ou mais das nove características positivas. Semelhante ao método ABCD, essas duas características negativas são: o padrão de simetria e a presença de uma única cor; enquanto as características positivas são: véu azul esbranquiçado, múltiplos pontos marrons, pseudópodes, transmissão radial, despigmentação como cicatriz, glóbulos negros periféricos, múltiplas cores, múltiplos pontos azul/cinza e rede ampliada [3].

Finalmente, o método da lista de Sete Pontos faz uma simples adição das pontuações individuais, uma pontuação total mínima de 3 é necessária para o diagnóstico de melanoma, ao passo que uma classificação total de menos do que 3 é um indicativo de não melanoma. Os pontos utilizados por esse método são: rede de pigmentação atípica, véu azul-esbranquiçado, padrão vascular atípico, estrias irregulares, glóbulos irregulares, manchas irregulares e estruturas de regressão. Cada item tem uma pontuação específica [3].

Os três métodos apresentados acima são para reconhecimento de melanoma com base em imagens dermatoscópicas, porém há também uma regra para detecção a olho nu, a qual é chamada de ABCDE. Essa regra é bastante semelhante ao método ABCD e nela cada letra indica uma característica do sinal a ser analisada, sendo o A referente à assimetria, o B à borda, o C à cor, o D ao diâmetro e o E à evolução [11].

Assim, com base na análise destes métodos, foi definido um conjunto de nove descritores, os quais foram denominados como simetria em x , simetria em y , diâmetro, variância e média no canal R , variância e média no canal G e variância e média no canal B que são representados pelas variáveis, d_0, \dots, d_8 , respectivamente. Assim, para uma dada imagem \mathbf{V}^k existirá um vetor $\mathbf{d}^k = [d_0^k \dots, d_8^k]$

de descritores. O cálculo para a obtenção de cada descritor é detalhado nas Subseções seguintes.

4.1 Cálculo da Simetria

O cálculo das simetrias em x e y para uma dada imagem k é representada pelos descritores d_0^k e d_1^k , os quais são expressos como

$$d_0^k = \left| \sum_{\substack{i=0 \\ i < c_x}}^{N-1} \sum_{j=0}^{M-1} p_{ij}^k - \sum_{\substack{i=0 \\ i \geq c_x}}^{N-1} \sum_{j=0}^{M-1} p_{ij}^k \right| \quad (5)$$

e

$$d_1^k = \left| \sum_{i=0}^{N-1} \sum_{\substack{j=0 \\ j < c_y}}^{M-1} p_{ij}^k - \sum_{i=0}^{N-1} \sum_{\substack{j=0 \\ j \geq c_y}}^{M-1} p_{ij}^k \right| \quad (6)$$

onde c_x^k e c_y^k são os valores do centro de massa da imagem binarizada, \mathbf{P}^k . O centro de massa pode ser calculado facilmente extraindo os pontos de contorno da imagem binarizada, \mathbf{P}^k .

O contorno é obtido utilizando uma função da biblioteca OpenCV, a *findContours()*. Através da imagem em preto e branco, essa função nos retorna o seu contorno. Para encontrar o centro de massa, em seguida utilizamos a função *moments()*, que calcula os momentos do contorno da imagem obtida anteriormente.

Basicamente, as Equações 5 e 6 calculam a simetria a partir de uma divisão da imagem em quatro quadrantes no centro de massa c_x^k e c_y^k . As Figuras 6a e 6b ilustram em detalhes a divisão da imagem, apresentada na Figura 2a, em quadrantes a partir do centro de massa.

4.2 Cálculo do Diâmetro

O cálculo do diâmetro, representado pelo descritor d_2^k , é realizado através do contorno a uma circunferência a partir de um vetor de s de S pontos de contorno da imagem binarizada, \mathbf{P}^k , no qual $\mathbf{s} = [s_0, \dots, s_{S-1}] \in \mathbf{P}^k$. O método localiza um círculo de área mínima a partir do vetor \mathbf{s} e o diâmetro do câncer terá o valor deste círculo. Para desenhar o círculo, foi utilizada a função da biblioteca OpenCV *minEnclosingCircle()*, que localiza um círculo de área mínima a partir do conjunto de pontos 2D, que no caso é o contorno. Essa função tem como saída o raio do círculo. A figura 7 mostra o resultado da obtenção do diâmetro na imagem binarizada apresentada na Figura 5.




Figura 6: a) Imagem original com o contorno do sinal e centro de massa. b) Imagem sendo dividida nos quadrantes com intersecção dos eixos no centro de massa.




Figura 7: Circunferência em torno da mancha.

4.3 Cálculo da Média e Variância

Finalmente, os últimos descritores obtêm a informação relativa a variação de cores associada a mancha de pele. Neste último são obtidos seis descritores que correspondem ao valor da média e variância de cada canal RGB da imagem original \mathbf{V}^k . A média e variância do canal R é representada pelos descritores d_3^k e d_4^k , para o canal G os descritores d_5^k e d_6^k e para o canal B os descritores d_7^k e d_8^k . O cálculo de cada descritor pode ser expresso como

$$d_3^k = \frac{1}{L} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} R(v_{ij}^k) \times p_{ij}^k \quad (7)$$

e

$$d_4^k = \frac{1}{L} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (\mathbf{R}(v_{ij}^k) - d_3^k)^2 \times p_{ij}^k \quad (8)$$

onde L é o número de pixels iguais a 1 na matriz binarizada, \mathbf{P}^k , $\mathbf{R}(\cdot)$ é uma função que retira o canal R do pixel v_{ij}^k . Seguindo a mesma linha o valor dos descritores para os outros canais podem ser expressos como

$$d_5^k = \frac{1}{L} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} \mathbf{G}(v_{ij}^k) \times p_{ij}^k, \quad (9)$$

$$d_6^k = \frac{1}{L} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (\mathbf{G}(v_{ij}^k) - d_5^k)^2 \times p_{ij}^k, \quad (10)$$

$$d_7^k = \frac{1}{L} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} \mathbf{B}(v_{ij}^k) \times p_{ij}^k, \quad (11)$$

e

$$d_8^k = \frac{1}{L} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (\mathbf{B}(v_{ij}^k) - d_7^k)^2 \times p_{ij}^k. \quad (12)$$

5 MLP-BP

Buscando resolver o problema de classificação de Melanoma, foi utilizada uma MLP-BP com nove entradas (os descritores), duas camadas escondidas e duas saídas. A quantidade de neurônios nas camadas escondidas foram determinadas através de testes, sendo o mais adequado o emprego de 10 neurônios na primeira camada escondida e 24 na segunda. A função de ativação utilizada nas camadas foi a função sigmoide e o coeficiente de aprendizagem foi definido como 0,01 e o erro quadrático mínimo como 0,000001.

A rede é submetida a 9 entradas, \mathbf{d}^k , sendo cada uma referente a um descritor extraído da imagem. Todos os descritores das imagens foram normalizados entre 0 e 1, objetivando melhorar a convergência da rede. A normalização de cada descritor foi realizada através da divisão de todos os elemento de um descritor pelo maior valor daquele descritor, levando-se em consideração o maior valor para o descritor entre as 200 imagens utilizadas.

A rede neural possui duas saídas, $\mathbf{u}^k = [u_0^k \ u_1^k]$, sendo uma referente a melanoma, u_0^k , e outra referente a não-melanoma, u_1^k . Como não-melanoma consideramos os nevos atípicos e comuns. Quando $\mathbf{u}^k = [0 \ 1]$ o sinal classificado é não melanoma e quando $\mathbf{u}^k = [1 \ 0]$ indica que o sinal é melanoma.




Figura 8: Estrutura geral da MLP utilizada.

6 Resultados

Tendo como objetivo validar a utilização do método e avaliar sua confiabilidade, foram realizados testes com a base de dados PH² *Database* disponibilizado pelo ADDI Project (*Automatic computer-based Diagnosis system for Dermoscopy Images*). Os resultados foram obtidos a partir de implementações próprias e também com auxílio da biblioteca OpenCV no processamento das imagens. Durante a etapa de treinamento da rede foram utilizadas 170 imagens do banco selecionadas aleatoriamente, sendo essas divididas em 138 não-melanomas e 32 melanomas. A partir de testes exaustivos foram encontradas as especificações da rede para sua melhor convergência, conforme já apresentado na seção 5. A MLP convergiu para um erro de 10^{-6} , como apresentado na Figura 9, que ilustra o erro quadrático médio da rede em função do número de épocas.

Após o treinamento da rede foi realizada a validação utilizando 30 imagens, sendo essas divididas em 22 não-melanomas e 8 melanomas. Realizada a validação, foram obtidos apenas 3 erros, sendo um falso negativo e dois falso positivo.

Com o propósito de avaliar o desempenho do sistema proposto, foram calculadas três medidas de uso comum em diversos trabalhos com problemas de classificação semelhantes a esse [7,9,10,13], sendo elas precisão, especificidade e especialidade. Havendo 27 diagnósticos corretos diante de 30 casos, obteve-se uma precisão de 90%. Com 20 não-melanomas reconhecidos corretamente diante de 22 casos de não-melanoma, foram obtidos uma especificidade de 90.9%. Finalmente, com 7 melanomas reconhecidos corretamente diante de 8 casos de melanoma, a sensibilidade foi de 87.5%.

Através do exposto na Tabela 1, a qual apresenta os resultados obtidos juntamente aos encontrados em literatura, podemos constatar que nossos resultados foram satisfatórios. Como pode ser observado, obtivemos o melhor valor de pre-

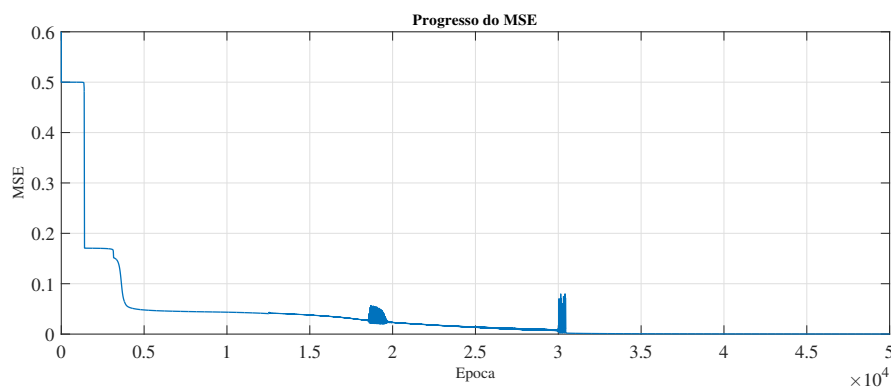


Figura 9: Curva de Aprendizagem da MLP.

Tabela 1: Comparação do método proposto com a literatura

Método	Precisão	Especificidade	Sensibilidade
Majtner, T. et al. [7]	82.6%	89.8%	53.3%
Nasr-Esfahani, E. et al.[9]	81%	80%	81%
Ruiz, D. et al. [10]	87.8%	97.9%	78.4%
Yu, L. et al. [13]	85.85%	93.1%	54.7%
Método Proposto	90%	90.9%	87.5%

cisão e sensibilidade quando comparados aos demais resultados em literatura. E o valor obtido de especificidade se manteve dentro da faixa de valores dos resultados relatados em literatura.

7 Conclusões

Este trabalho apresentou uma proposta de técnica de detecção de câncer de pele utilizando redes neurais artificiais do tipo MLP treinada com o algoritmo do backpropagation. A proposta fez uso de técnicas de processamento de imagem para se obter nove descritores a partir da imagem original, os quais são utilizados posteriormente para realizar a classificação do sinal pela rede neural. Foram obtidos resultados de treinamento e validação da técnica utilizando uma base de dados pública de imagens de sinais e manchas de câncer de pele. Os resultados apresentaram uma precisão de 90%, mostrando a eficácia da técnica. Com base nestes resultados, serão realizados novos testes em outras bases objetivando a consolidação da técnica proposta.

Referências

1. ADDI PROJECT: PH² Database. <https://www.fc.up.pt/addi/ph2%20database.html> (2017)

2. Aswin, R.B., Jaleel, J.A., Salim, S.: Hybrid genetic algorithm x2014; artificial neural network classifier for skin cancer detection. In: 2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (IC-CICCT). pp. 1304–1309 (July 2014)
3. Bologna, J.L., Jorizzo, J.L., Schaffer, J.V.: *Dermatologia*, vol. 1. Elsevier, Rio de Janeiro (2015)
4. Gonzalez, R.C., Woods, R.E.: *Processamento Digital de Imagens*. Pearson, São Paulo, 3 edn. (2010)
5. Hosseini, M.S., Zekri, M.: Review of medical image classification using the adaptive neuro-fuzzy inference system. *J Med Signals Sens* 2(1), 49–60 (Aug 2012), <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3592505/>, jMSS-2-49[PII]
6. Korotkov, K., Garcia, R.: Computerized analysis of pigmented skin lesions: A review. *Artificial Intelligence in Medicine* 56(2), 69 – 90 (2012), <http://www.sciencedirect.com/science/article/pii/S0933365712001108>
7. Majtner, T., Yildirim-Yayilgan, S., Hardeberg, J.Y.: Combining deep learning and hand-crafted features for skin lesion classification. In: 2016 Sixth International Conference on Image Processing Theory, Tools and Applications (IPTA). pp. 1–6 (Dec 2016)
8. Masood, A., Ali Al-Jumaily, A.: Computer aided diagnostic support system for skin cancer: A review of techniques and algorithms. *International Journal of Biomedical Imaging* 2013, 1–22 (2013), <http://dx.doi.org/10.1155/2013/323268>
9. Nasr-Esfahani, E., Samavi, S., Karimi, N., Soroushmehr, S.M.R., Jafari, M.H., Ward, K., Najarian, K.: Melanoma detection by analysis of clinical images using convolutional neural network. In: 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). pp. 1373–1376 (Aug 2016)
10. Ruiz, D., Berenguer, V., Soriano, A., Sánchez, B.: A decision support system for the diagnosis of melanoma: A comparative approach. *Expert Systems with Applications* 38(12), 15217 – 15223 (2011), <http://www.sciencedirect.com/science/article/pii/S0957417411008633>
11. SOCIEDADE BRASILEIRA DE DERMATOLOGIA: Câncer de Pele. <http://www.sbd.org.br/doenca/cancer-da-pele/> (2017)
12. de Souza Ganzeli, H., Bottesini, J.G., de Oliveira Paz, L., Ribeiro, M.F.S.: Skan: Skin scanner - system for skin cancer detection using adaptive techniques. *IEEE Latin America Transactions* 9(2), 206–212 (April 2011)
13. Yu, L., Chen, H., Dou, Q., Qin, J., Heng, P.A.: Automated melanoma recognition in dermoscopy images via very deep residual networks. *IEEE Transactions on Medical Imaging* 36(4), 994–1004 (April 2017)