

CLASSIFICAÇÃO DE IMAGENS DERMATOSCÓPICAS UTILIZANDO APRENDIZADO PROFUNDO PARA CARACTERÍSTICAS DE BORDA, COR E TEXTURA

ALAN RAFAEL FERREIRA DOS SANTOS*, KELSON RÔMULO TEIXEIRA AIRES*, RODRIGO DE MELO SOUZA VERAS*, CORNÉLIA JANAYNA PEREIRA PASSARINHO*

**Universidade Federal do Piauí - UFPI
Departamento de Computação
Teresina, Piauí, Brasil.*

Emails: alan_rafael18@hotmail.com, kelson@ufpi.edu.br, rveras@ufpi.edu.br, janaynapassarinho@gmail.com

Abstract— The melanoma identification in dermoscopic images is still a task difficult to be achieved by the dermatologists. In this context, this work proposes a new classification method for these images, through a Deep Learning approach with Convolutional Neural Networks. The results of the classification with the proposed method are compared to the ones obtained by a Support Vector Machine and by a Multilayer Perceptron, methods considered traditional to this problem. The suggested methodology extracts the border, color and texture characteristics of the images in the HSV (Hue, Saturation and Value) color space to classify the lesions, unlike other approaches which use classification models similar to the human vision. The PH² dermoscopic image database was used as a test object in this work. The results of the experiments were extracted in the same conditions and the final results found a higher classification with the proposed method for a statistic descriptor in color channels, with 96,4% accuracy, Kappa of 0,94 and an AUC of 0,99.

Keywords— Melanoma , Classification , Deep Learning , Convolutional Neural Networks

Resumo— A identificação do melanoma em imagens dermatoscópicas ainda é uma tarefa difícil de ser realizada pelos dermatologistas. Neste contexto, o presente trabalho propõe um novo método de classificação destas imagens através da abordagem de Aprendizado Profundo com Redes Neurais Convolucionais. A proposta do método é comparar os seus resultados de classificação com a Máquina de Vetor de Suporte e Perceptron Multicamadas. Estes métodos são considerados tradicionais para este problema. A metodologia sugerida faz a extração de características de borda, cor e textura das imagens no espaço de cor HSV (*Hue*, *Saturation* e *Value*) para a classificação das lesões, diferentemente de outras abordagens que usam modelos de classificação semelhantes a visão humana. A base de imagens dermatoscópicas PH² foi utilizada como objeto de testes neste trabalho. Os resultados dos experimentos foram extraídos em mesmas condições e, ao fim, constatou-se uma maior classificação com o método proposto para um descritor Estatístico em Canais de Cores, com uma Acurácia de 96,4%, índice Kappa de 0,94 e AUC de 0,99.

Palavras-chave— Melanoma, Classificação, Aprendizado Profundo, Redes Neurais Convolucionais.

1 Introdução

A incidência do câncer de pele do tipo melanoma é a mais agressiva e letal no Brasil, correspondendo a 9% de todos os casos de câncer registrados (INCA, 2016).

A forma mais utilizada para detectar o melanoma é o exame dermatoscópico. Essa técnica produz imagens de alta qualidade das lesões de pele, que são analisadas e diagnosticadas posteriormente por um médico dermatologista.

Diversos sistemas já foram desenvolvidos para auxiliar o dermatologista no diagnóstico do melanoma, utilizando imagens dermatoscópicas. A maioria dessas ferramentas é inspirada nas formas visuais de detecção, onde as melhores características de identificação desta doença são dadas pelas bordas irregulares, cores variáveis (essas são descritas na regra ABCD (Assimetria, Borda, Cor e Diâmetro)) e texturas rugosas. A classificação destes atributos determina o diagnóstico das lesões (Maglogiannis and Doukas, 2009).

A utilização de Aprendizado Profundo (AP) em redes neurais vem se desenvolvendo para pro-

blemas de classificação que exigem altas taxas de acerto. Uma das suas melhores técnicas são as Redes Neurais Convolucionais (RNC) (Netzer et al., 2011).

Este trabalho propõe um novo método de AP, utilizando uma RNC na classificação dos dados de borda, cor e textura, que são extraídas de imagens dermatoscópicas. A utilização deste método tem o objetivo de produzir melhores resultados de diagnóstico do melanoma.

Os resultados obtidos na identificação das lesões com a RNC são comparados com os dados da Máquina de Vetor de Suporte (*Support Vector Machine* - SVM) e Perceptron Multicamadas (*Multilayer Perceptron* - MLP). Esses são considerados métodos tradicionais de classificação em sistemas de detecção do melanoma (Korotkov and Garcia, 2012).

2 Trabalhos Relacionados

Várias abordagens já foram propostas para o problema de identificação do melanoma em imagens dermatoscópica e a sua maioria sempre busca os

melhores resultados de acerto na identificação das lesões. (Lee and Chen, 2015).

No trabalho de Maglogiannis and Doukas (2009) é apresentado um estudo das principais técnicas de detecção do melanoma para imagens dermatoscópicas. Os dados mostram que 36% das metodologias de classificação utilizam características de cor, 21% características de borda e 9% características de textura na descrição das lesões. Neste contexto, a maioria dos métodos citados fazem a classificação dos dados através das Redes Neurais, Aprendizado Estatístico e SVM. Alguns dos melhores resultados encontrados na literatura para estes descritores são dados pela SVM e o MLP, atingindo uma precisão se até 94% para uma classificação binária (melanoma e não melanoma).

Em Korotkov and Garcia (2012) também é feito uma revisão literária nas formas de detecção do melanoma. No entanto, esta pesquisa levou em consideração apenas os melhores descritores, juntamente com as melhores formas de classificação. Nos dados apresentados, uma parte da literatura utiliza os descritores de *Haralick*, *Gabor* e Padrões Binários Locais para descrever texturas, o Histograma de Orientação Gradiente para bordas e Estatísticas em Canais de Cores para coloração. As características extraídas por estes descritores conseguem descrever com riqueza de detalhes o câncer de pele, oferecendo dados mais precisos para sua identificação.

Trechos da pesquisa de Shi and He (2011) apresentam o poder que as RNC pode oferecer na identificação de imagens cancerígenas. Esta técnica é considerada ótima por conseguir abstrair dados irrelevantes ou confusos na classificação dos dados, proporcionando acurácias de até 100%. Estima-se que este método poderá ajudar de maneira mais precisa, em um futuro próximo, os sistemas de apoio a decisões médicas.

Em Cruz-Roa et al. (2013) é feita uma avaliação da RNC para classificação do câncer de pele em imagens. A proposta implementa em sua arquitetura uma camada de interpretação de dados por padrões visuais de cores. As técnicas de *Bag of Features*, Transformada Discreta de Cossenos e *Wavelet* foram associadas nesta classificação. Os resultados obtidos com a combinação de métodos chegou a uma acurácia de 89,4%.

Nos estudos de Codella et al. (2015) é apresentado uma nova técnica de classificação de imagens dermatoscópicas utilizando RNC's pré-treinadas. O método aborda uma combinação de aprendizado profundo, *Sparse Coding* (SC) e SVM. Um aspecto relevante desta técnica é o seu aprendizado não supervisionado no próprio domínio da imagem. Nesta etapa não é utilizado nenhum descritor de características. Os resultados obtidos nos testes para classificação binária na primeira RNC atingiram uma acurácia de 72,3% e na segunda 65,4%. O resultado final da combinação de téc-

nicas para esta classificação atingiu uma acurácia de 93,1%.

Atualmente, novos métodos na literatura sugerem a utilização da RNC na classificação de imagens dermatoscópicas. Contudo, uma extração prévia de características nas imagens agregadas a esta classificação poderia oferecer melhores resultados de identificação da doença.

3 Descrição do Método Proposto

A partir dos estudos realizados na literatura, esse trabalho propõe uma nova forma de diagnosticar o melanoma em imagens dermatoscópicas, por meio classificação dos dados de borda, cor e textura das lesões com uma RNC.

Os experimentos realizados nesse trabalho propõem o uso da base PH² do Hospital Pedro Hispano (Matosinhos, Portugal), que é composta por 200 imagens dermatoscópicas em RGB (*Red*, *Green* e *Blue*), das quais, 160 imagens são não melanoma e 40 melanoma. (Mendonça et al., 2013). Essa base foi selecionada por possuir imagens diagnosticadas por um dermatologista. Além disso, as regiões de interesse já estão segmentadas, isso facilita o processo de extração de características.

Esse método limitou-se ao o espaço de cor HSV (*Hue*, *Saturation* e *Value*), por ser um dos espaços que armazenam maior quantidade de informações para esse problema (Celebi et al., 2015). Além disso, a sua estrutura é dividida em duas etapas: Extração de Características e Forma de Classificação de Dados. Os próximos tópicos mostram como estas fases foram desenvolvidas.

3.1 Extração de Características

Nesta etapa, os dados foram extraídos em forma de tabela pelos descritores: Histograma de Gradientes Orientados (*Histogram of Oriented Gradients* - HOG) para bordas, Estatísticas em Canais de Cores (ECC) para coloração, Banco de Filtros de *Gabor* (*Gabor Bank Filter* - GBF), *Haralick* e Padrão Binário Local (*Local Binary Pattern* - LBP) para texturas. Estes descritores foram priorizados pelos aspectos relevantes apresentados nos estudos de Korotkov and Garcia (2012) sobre as descrições do melanoma.

O descritor de HOG é baseado em cálculos de orientação dos gradientes no histograma das imagens. O modelo utilizado nesta abordagem seguiu os cálculos apresentados por Barata et al. (2014), que produz uma matriz unidirecional contendo as características das aparências de borda das lesões. Estes cálculos foram realizados com o intuito de detectar variações nas borda em cada componente de cor.

Já o descritor ECC faz uma análise estatística das imagens por canal de cor. A implementação

desse descritor é semelhante a os conceitos apresentados por Vezhnevets et al. (2003). No entanto, os dados estatísticos de correlação por filtragem, desvio padrão unidirecional e covariância entre canais são adicionados às descrições.

O GBF proposto neste método aplica as funções de *Gabor* para frequência, orientação, excentricidade e simetria, formando uma combinação de filtros que descreve os diferentes tipos de texturas nas imagens. Esse descritor possui funções senóides complexas, modeladas por uma gaussiana, que extrai as irregularidades de textura. A implementação desse descritor é sugerida por Mery et al. (2013).

A descrição de Textura de *Haralick* (TH) é focada nas características de segunda ordem contidas em matrizes que são extraídas das imagens. Esses dados são conhecidas como matrizes de co-ocorrências em níveis de cinza. O TH proposto neste método faz operações de combinação direcional (0° , 45° , 90° , 180°) para estes níveis, por meio das sugestões de Haralick (1979). No entanto, a obtenção destes dados é feita através dos canais de cores das imagens, considerando a variação de distâncias entre os vizinhos próximos, que são apresentadas no método de Mery et al. (2013).

A proposta do LBP utilizada neste método realiza uma rotulação de *pixels* nas imagem com uma vizinhança 3×3 , onde cada elemento é comparado com um determinado *pixel* central, resultando em uma binarização da imagem. Após este procedimento, um histograma com partições é gerado, descrevendo características de texturas (Mery et al., 2013).

3.2 Forma de Classificação de Dados

Neste método, a classificação dos dados extraídos das imagens é feita pela RNC. Essa técnica é uma rede neural multicamadas que mantém operações de compartilhamento de pesos para auxiliar na generalização de dados (Bengio et al., 2015).

O aprendizado neste tipo de rede visa criar autoassociações entre dados replicados, por meio do aprendizado não supervisionado, em seguida, agrupar apenas os autoassociáveis com o aprendizado supervisionado (Netzer et al., 2011).

A operação de convolução apresentada na RNC é dada como um operador linear entre duas funções. O resultado disso é uma terceira função, que representa as áreas de superposição dos dados. Em outras palavras, a convolução realiza cálculos de vizinhança retangular das células de uma matriz, com o intuito de compartilhar maiores pesos na rede apenas para os neurônios que representam as melhores características (Bengio et al., 2015).

Na Figura 1 é apresentado um exemplo simples de convolução bidimensional, por meio de uma matriz conhecida como *Kernel*. Essa matriz é utilizada para captar características significativas

dos dados, com cálculos comutativos. Geralmente, o *Kernel* é menor do que conjunto de dados e sua função é apresentar a localização dos atributos de maior relevância (Netzer et al., 2011).




Figura 1: Exemplo de uma convolução bidimensional válida utilizando o Kernel.

A cada operação de convolução, os pesos dos neurônios da rede são alterados, sendo acrescidos e compartilhados conforme a sua relevância. A Figura 2 mostra um exemplo desse compartilhamento, onde mais de um neurônio responde igualmente a características encontradas.




Figura 2: Rede com compartilhamento de pesos.

A explicação matemática para entender esse compartilhamento de pesos considera uma soma ponderada entre um conjunto de dados $C(x, y)$ e uma função $f(x, y)$, onde D_i representa a distância das características do conjunto C em relação a um *Kernel* de convolução, com coordenadas s e t e um conjunto $C(s, t)$, resultante de cada convolução. Essa operação é apresentada na Equação 1.

$$C(x, y) * f(x, y) = \sum_s \sum_t C(s, t) D_i(C(x-s), C(y-t)) \quad (1)$$

Quando as características das imagens entram na camada de convolução, as operações são realizadas em três fases. A primeira fase executa uma

série de operações paralelas com o *Kernel*, gerando um conjunto de dados de ativação. Em cada pico de característica relevante, a rede aprende o seu campo receptivo, ou seja, toda vez que este pico é identificado, uma ativação é gerada. Na segunda fase, cada ativação linear é representada por uma função não-linear. Essa parte da rede é considerada como camada detectora de características. A última operação é concebida pela camada de *Max-pooling* que faz a modificação das saídas. A sequência dessas operações são ilustradas na Figura 3.




Figura 3: Componentes de uma camada convolucional típica.

Na camada detectora, as funções de ativação tangente hiperbólica e sigmóide podem ser usadas para extrair o *pooling* máximo por características relevantes. Nessa situação, a unidade de retificação linear, definida pela Equação 2, é preferível, pois aumenta o desempenho da convolução e mantém as propriedades não saturantes, evitando que os gradientes sejam tendenciados a zero. Isso pode ocorrer na identificação de características em estruturas de rede mais profundas (Oquab et al., 2014).

$$f(x) = \max(0, x) \quad (2)$$

A camada de *Max-pooling* é responsável por aplicar a matriz de saída da convolução uma ativação máxima das regiões regulares sem sobreposição. Essa sobreposição ocorre se o valor de s (tamanho do conjunto de característica) é menor do que a sua vizinhança. O resultados das operações nesta camada reduz o tamanho do conjunto de características, com o intuito de diminuir a sua sensibilidade, por meio de distorções e deslocamentos (Bengio et al., 2015). Neste caso, as características invariantes das imagens são selecionadas para melhorar o desempenho da identificação de classes.

O uso desta camada é considerada um operador de composição, com mecanismos de seleção local, melhorando a eficiência estatística da rede, por aprender características invariantes (Bengio et al., 2015).

A camada *Softmax* faz as regressões logísticas que compõe a classificação (Cruz-Roa et al., 2013). O objetivo desta operação é maximizar o valor mé-

dio de padrões de características, por meio da sua probabilidade de ocorrência. Em outras palavras, esta camada verifica a ocorrência de probabilidades dos maiores pesos em relação às características invariantes. O seu tamanho depende da quantidade de classes e a sua estrutura é totalmente ligada (Bengio et al., 2015).

O maior resultado de probabilidade apresentado na saída da *Softmax* determina a classe a que os dados pertencem. Na Figura 4 é apresentada uma RNC na classificação de dados, que mostra uma maior probabilidade de um conjunto de dados pertencer a classe C1. A soma dessas probabilidades é sempre igual a 1 (Bengio et al., 2015).




Figura 4: RNC com a camada de regressão *Softmax*.

4 Resultados e Discussões

O método desenvolvido considerou a classificação da base PH² em duas classes: melanoma (40 imagens) e não melanoma (160 imagens).

A características extraídas das imagens foram classificadas com os métodos RNC, SVM e MLP, implementados na ferramenta WEKA (Hall et al., 2009).

Nas configurações do SVM, utilizou-se a função de base radial e tamanho de lote igual a 100, no MLP criou-se uma estrutura com duas camadas escondidas. Já na RNC, criou-se uma rede com 100 camadas conetadas, uma camada de convolução de 5×5 , uma camada de *Max-pooling* 2×2 e, por fim, uma camada *Softmax* com 2 saídas. Os valores das camadas de convolução e *Max-pooling* foram sugeridas por Bengio et al. (2015).

A forma dos testes utilizou o método estatístico *K-fold cross-validation*, onde o valor de $K=10$ foi utilizado para gerar os conjuntos de treino e teste em ambos os métodos de classificação.

A base de imagens tem um desbalanceamento aparente, este problema pode influenciar na classificação para a classe de maior quantidade. A solução para corrigir esta falha utilizou a técnica de SMOTE (*Synthetic Minority Over-sampling Tech-*

nique) (Chawla et al., 2002). Este método também está implementado na ferramenta WEKA.

Neste trabalho, os dados de classificação dos métodos sugeridos são comparados utilizando a matriz de confusão. Essa matriz mostra o número de classificações corretas *versus* incorretas. A partir destes valores, são calculadas as taxas de Acurácia (A), Precisão (P), *Recall* (R), *F-Measure* (FM) e índice Kappa (Landis and Koch, 1977).

A Acurácia é a porcentagem que estima o acerto total de classificação. O *Recall* é a taxa de amostras classificadas corretamente em relação às amostras positivas (melanoma). A Precisão é a taxa de amostras classificadas corretamente em relação à quantidade total de amostras verdadeiras. Já *F-Measure* é a média ponderada entre Precisão e *Recall* (Landis and Koch, 1977). O índice Kappa representa a taxa de concordância com as condições dadas (melanoma ou não melanoma). O valor considerado excelente para este índice é dado por $Kappa > 0,8$ (Landis and Koch, 1977).

Outra métrica utilizada neste trabalho é a curvas ROC (*Receiver Operating Characteristic*), que tem o objetivo de avaliar a eficiência de um método classificador na identificação de amostras verdadeira e falsas. A principal informação extraída da ROC é a área sob a curva, conhecida como AUC (*Area Under Curve*), quanto mais próximo o seu valor de 1, melhor é a classificação dos dados ($AUC > 0,9$) (Landis and Koch, 1977).

Na Tabela 1 é apresentada a matriz de confusão para o classificador SVM. Na análise dos dados, o descritor de EEC obteve 21 identificações incorretas. Já o LBP obteve o pior resultado, com 40 identificações incorretas.

Tabela 1: Matriz de confusão do método SVM.

	Melanoma (A)		Não Melanoma (B)	
	(A)	(B)	(A)	(B)
HOG	153	7	17	143
GBF	152	8	13	147
TH	148	12	13	147
LBP	154	6	34	126
ECC	150	10	11	149

Já na Tabela 2 são apresentados os resultados de desempenho para este classificador. O descritor EEC obteve a melhor acurácia, com 93,4%, índice *Kappa* igual a 0,89 e AUC igual a 0,93. Estes resultados são refletidos em taxas próximas de Precisão, *Recall* e AUC. O pior resultado de acurácia é dado ao descritor LBP, com 87,5%, índice *Kappa* igual a 0,83 e AUC igual a 0,87.

Na Tabela 3 é apresentada a matriz de confusão para o método de classificação MLP. O melhor desempenho, comparado ao SVM, é dado ao LBP que reduziu seus erros de classificação de 40 para 21 imagens.

A Tabela 4 apresenta o desempenho obtido pelo MLP. Em contexto geral, a maioria dos descritores obtiveram melhorias nos resultados. No entanto, o ECC manteve o melhor resultado, com

Tabela 2: Desempenho de classificação com o SVM.

	A(%)	FM	R	P	AUC	Kappa
HOG	92,5	0,92	0,92	0,92	0,92	0,85
GBF	93,4	0,93	0,93	0,93	0,93	0,90
TH	92,1	0,92	0,92	0,92	0,92	0,88
LBP	87,5	0,87	0,87	0,87	0,87	0,83
ECC	93,4	0,93	0,93	0,93	0,93	0,86

Tabela 3: Matriz de confusão do método MLP.

	Melanoma (A)		Não Melanoma (B)	
	(A)	(B)	(A)	(B)
HOG	152	8	20	140
GBF	152	8	11	149
TH	151	9	13	147
LBP	150	10	11	149
ECC	154	6	11	149

uma acurácia de 94,6%, índice *Kappa* de 0,89 e AUC igual a 0,98.

Tabela 4: Desempenho de classificação com o MLP.

	A(%)	FM	R	P	AUC	Kappa
HOG	91,2	0,91	0,91	0,91	0,96	0,82
GBF	94,3	0,94	0,94	0,94	0,98	0,88
TH	93,1	0,93	0,93	0,94	0,98	0,86
LBP	93,4	0,93	0,93	0,93	0,98	0,87
ECC	94,6	0,95	0,95	0,95	0,98	0,89

A Tabela 5 apresenta a matriz de confusão da arquitetura proposta com a RNC. Ao comparar estes resultados com métodos anteriores, essa estrutura obteve os melhores resultados de classificação em todos os descritores. O ECC diminuiu sua classificação incorreta de 21 para 11 imagens, em relação ao SVM.

Tabela 5: Matriz de confusão com método RNC

	Melanoma (A)		Não Melanoma (B)	
	(A)	(B)	(A)	(B)
HOG	150	10	11	149
GBF	153	7	10	150
TH	153	7	10	150
LBP	151	9	10	150
ECC	157	3	8	152

Já na Tabela 6 são apresentados os resultados para a arquitetura da RNC proposta. Em relação ao MLP, o ECC teve um aumento na sua acurácia de 94,6% para 96,8%, melhorando o índice *Kappa* de 0,89 para 0,94. Outro fator relevante, é o aumento da acurácia do LBP em relação ao SVM, que partiu de 87,5% para 94%.

Tabela 6: Desempenho de classificação com a RNC

	A(%)	FM	R	P	AUC	Kappa
HOG	93,4	0,93	0,93	0,93	0,98	0,87
GBF	94,6	0,95	0,95	0,95	0,98	0,89
TH	94,5	0,95	0,95	0,95	0,99	0,89
LBP	94	0,94	0,94	0,94	0,99	0,88
ECC	96,4	0,96	0,96	0,96	0,99	0,94

5 Conclusão e Trabalhos Futuros

A partir dos dados analisados, podemos concluir que o método proposto obteve os melhores resultados de classificação para imagens dermatoscópi-

cas. Em síntese, a utilização da etapa de extração de característica configura-se uma boa forma de melhorar os desempenho dos resultados através da RNC.

A melhor taxa apresentada pelo método desenvolvido é dada descritor ECC com uma acurácia 96,4%, índice Kappa de 0,94 e AUC de 0,99. Estes valores são considerados excelentes pela literatura, tornando a RNC uma boa forma de classificar características para este problema.

Em trabalhos futuros, pretende-se aprimorar o método sugerido utilizando outros espaços de cores, juntamente com outros descritores. Além disso, outros métodos de classificação deverão ser comparados a RNC.

Referências

- Barata, C., Ruela, M., Francisco, M., Mendonça, T. and Marques, J. S. (2014). Two systems for the detection of melanomas in dermoscopy images using texture and color features, *Systems Journal, IEEE* **8**(3): 965–979.
- Bengio, Y., Goodfellow, I. J. and Courville, A. (2015). Deep learning, *An MIT Press book in preparation. Draft chapters available at <http://www.iro.umontreal.ca/bengioy/dlbook>*.
- Celebi, M. E., Mendonca, T. and Marques, J. S. (2015). *Dermoscopy Image Analysis*, Vol. 10, CRC Press.
- Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P. (2002). Smote: synthetic minority over-sampling technique, *Journal of artificial intelligence research* pp. 321–357.
- Codella, N., Cai, J., Abedini, M., Garnavi, R., Halpern, A. and Smith, J. R. (2015). Deep learning, sparse coding, and svm for melanoma recognition in dermoscopy images, *Machine Learning in Medical Imaging*, Springer, pp. 118–126.
- Cruz-Roa, A. A., Ovalle, J. E. A., Madabhushi, A. and Osorio, F. A. G. (2013). A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection, *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2013*, Springer, pp. 403–410.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P. and Witten, I. H. (2009). The weka data mining software: an update, *ACM SIGKDD explorations newsletter* **11**(1): 10–18.
- Haralick, R. M. (1979). Statistical and structural approaches to texture, *Proceedings of the IEEE* **67**(5): 786–804.
- INCA (2016). Estimativas do câncer para o ano de 2016, <http://www.inca.gov.br/estimativa/2016/>. Acessado em 01-05-2016.
- Korotkov, K. and Garcia, R. (2012). Computerized analysis of pigmented skin lesions: a review, *Artificial intelligence in medicine* **56**(2): 69–90.
- Landis, J. R. and Koch, G. G. (1977). The measurement of observer agreement for categorical data, *biometrics* pp. 159–174.
- Lee, H. and Chen, Y.-P. P. (2015). Image based computer aided diagnosis system for cancer detection, *Expert Systems with Applications* **42**(12): 5356–5365.
- Maglogiannis, I. and Doukas, C. N. (2009). Overview of advanced computer vision systems for skin lesions characterization, *Information Technology in Biomedicine, IEEE Transactions on* **13**(5): 721–733.
- 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, *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE, IEEE*, pp. 5437–5440.
- Mery, D., Pedreschi, F. and Soto, A. (2013). Automated design of a computer vision system for visual food quality evaluation, *Food and Bioprocess Technology* **6**(8): 2093–2108.
- Netzer, Y., Wang, T., Coates, A., Bissacco, A., Wu, B. and Ng, A. Y. (2011). Reading digits in natural images with unsupervised feature learning, *NIPS workshop on deep learning and unsupervised feature learning*, Vol. 2011, Granada, Spain, p. 4.
- Oquab, M., Bottou, L., Laptev, I. and Sivic, J. (2014). Learning and transferring mid-level image representations using convolutional neural networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1717–1724.
- Shi, Z. and He, L. (2011). Current status and future potential of neural networks used for medical image processing, *Journal of multimedia* **6**(3): 244–251.
- Vezhnevets, V., Sazonov, V. and Andreeva, A. (2003). A survey on pixel-based skin color detection techniques, *Proc. Graphicon*, Vol. 3, Moscow, Russia, pp. 85–92.