

CLASSIFICAÇÃO DE TUMORES UTILIZANDO IMAGENS HIPERSPECTRAIS E REDES NEURAIS CONVOLUCIONAIS

David de Melo Almeida dos Reis, Daniel Vitor de Lucena,

Arthur Ricardo de Sousa Vitoria, Arlindo Rodrigues Galvão Filho,

Clarimar José Coelho

2021

Resumo

O uso de imagem hiperespectral (hyperspectral image, HSI), junto a modelos de classificação que utilizam de informações espaciais, ainda é uma abordagem pouco explorada. Este trabalho propõe um modelo de aprendizado profundo, que utiliza tanto de informações espaciais quanto espectrais, presentes na HSI. A faixa de comprimento de onda, dos espectros analisados, estão na região do infravermelho de Ondas Curtas (Short Wave InfraRed, SWIR). Foram analisadas amostras de tecido epitelial humano divididas entre: Melanoma, Nevo Displásico e Pele Saudável. Os resultados obtidos, mostram que o tecido epitelial humano é sensível ao SWIR, e que é possível utilizar modelos de aprendizado profundo, junto com imagens HSI-SWIR, na diferenciação de tecidos saudáveis e tecidos contendo Melanoma. Essa diferenciação possibilita a utilização de uma ferramenta automatizada, como método complementar para diagnóstico precoce de tecidos tumorais.

Palavras-chaves: Aprendizado Profundo. Imagem HiperSpectral. Infravermelho de Ondas Curtas. SWIR.

Introdução

As células do corpo humano vivem em um sistema complexo e interdependente, regulando a proliferação uma das outras. Enquanto as células saudáveis se reproduzem apenas quando instruído por outras células vizinhas, células tumorais seguem um ritmo próprio de reprodução. O câncer é uma célula tumoral com rápida proliferação e que

possui a habilidade de migrar pelo corpo, podendo interromper o funcionamento de órgãos (WEINBERG, 1996).

O melanoma é o tipo de câncer de pele mais agressivo, devido sua alta possibilidade de metástase e mortalidade. Dado este fator, um diagnóstico precoce da doença é vital para o aumento da chance de sobrevivência do paciente (FIGUEIREDO et al., 2003).

Dentre os fatores que contribuem para o desenvolvimento deste câncer, estão: A exposição à radiação solar, idade, sexo e susceptibilidade individual. Outro fator que influencia no desenvolvimento de melanoma, é a presença de nevo displásico. Ao contrário do melanoma, o nevo displásico é um nevo melanocítico benigno, e pode ser identificado como manchas irregulares ou pintas (AUTIER, 1998; SOCIETY, 2017; REZZE, 2010).

A forma tradicional de detecção de Melanoma parte da identificação de manchas suspeitas, avança para detalhamento de características, como: tamanho, forma, cor, textura e origem da mancha. Após este processo, manchas suspeitas são selecionadas e submetidas a biopsia, e exames de sangue (CARLI, 2000; SCHADENDORF, 2015; SOCIETY, 2016). Pela dificuldade de identificar certas lesões na pele, métodos de diagnóstico automatizado que provém do processamento e análise de imagens estão sendo cada vez mais empregados (KUCHERYAVSKI, 2007). Sendo possível citar, como exemplo, a imagem de ressonância magnética, tomografia computadorizada, ultra-sonografia ou raio-X

Nas últimas duas décadas, a HSI tem sido utilizada em diversas aplicações médicas, pelo seu potencial de diagnóstico de doenças de forma não invasiva, e orientações cirúrgicas (AFROMOWITZ, 1988; BAMBERY, 2004; CALIN, 2014; LU, 2014; KOH, 2009; MALKOFF, 2000; SCHULTZ, 2001; ZONIOS, 1999). Halicek et al. (2017) e Manni et al. (2020) propuseram modelos de aprendizado profundo para a detecção de câncer, utilizando imagens hiperespectrais (HSI). Halicek et al. (2017) utilizou uma CNN com 6 camadas convolutivas, classificando câncer de tireoide e obteve uma acurácia de 80%. Enquanto Manni et al. (2020) obtém uma acurácia de 82%, ao utilizar a arquitetura HybridSpectraNet para classificar câncer de cólon. De acordo com Cheng e Sun (2014), a imagem hiperespectral é uma técnica que combina a espectroscopia tradicional com imagem digital ou visão computacional, para se obter tanto informação espacial quanto espectral, de uma amostra (SOCIETY, 2016).

Os resultados alcançados ao utilizar técnicas baseadas em aprendizagem profunda, em problemas de reconhecimento visual, são comparáveis a cognição humana. Estes resultados inspiraram a utilização destas técnicas em HSI (ESTEVA et al., 2017; SCHMIDHUBER, 2015; CHEN et al., 2014).

Para elevar as chances de sobrevivência de um paciente com melanoma, um diagnóstico precoce do tecido tumoral é vital. Visto que quando detectados nos estágios iniciais, as chances de cura são melhores. Desta forma, este estudo propõe a utilização de um modelo automatizado para o diagnóstico de Melanoma em tecidos epiteliais.

1 MATERIAIS E METODOS

As amostras utilizadas são de tecido humano. A extração foi feita de pacientes por procedimentos laboratoriais realizados por médicos. Os conjuntos de amostras foram divididos entre: Melanoma, Nevo Displásico e Pele Saudável.

Enquanto uma análise usando espectroscopia, tem como resultado um espectro $I(\lambda)$. Uma outra análise, usando imagem digital, retorna uma distribuição bidimensional de

intensidade $I(x, y)$. Desta forma, uma imagem hiperespectral combina essas duas técnicas e gera um cubo descrito por $I(\lambda, x, y)$. Podendo ser entendida como diferentes imagens $I(x, y)$ em cada comprimento de onda (λ) ou diferentes espectros $I(\lambda)$ em cada pixel $I(x, y)$ (CHENG; SUN, 2014 apud SUN, 2010).

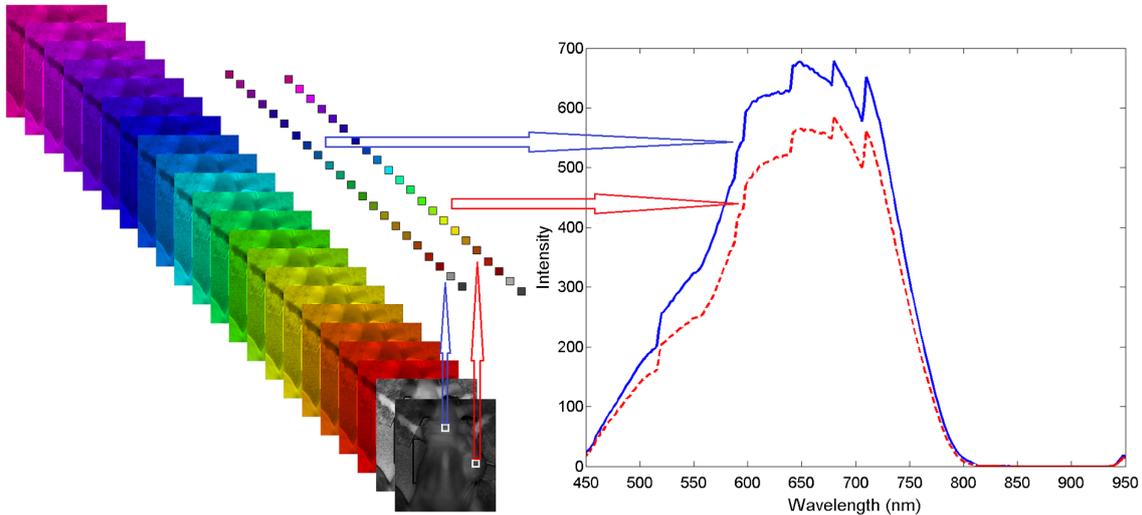


Figura 1 – Representação da estrutura do HSI e seu o arranjo de pixels-vetores. Adaptado de Akbari et al.

A HSI utilizada está na região do SWIR. Esta ainda é uma região pouco explorada para aplicações médicas (ZEVON et al., 2015). A aquisição foi feita pela câmera hiperespectral SisuCHEMA, que trabalha com ondas que variam entre 1000nm e 2500nm, com uma resolução espectral de 6nm. Os dados obtidos provem da absorbância calculada a partir da refletância medida, denotada de pseudo absorbância (SPECIM, 2015).

Entretanto, a HSI gera uma grande quantidade de dados irrelevantes ou redundantes (KUMAR, 2016). Isto provoca o aumento do tempo de computação, complexidade e escala de modelos de previsão que mapeiam os dados para semântica (classificação, por exemplo) e a necessidade de uma grande quantidade de dados rotulados para treinamento (SU et al., 2017). Para reduzir essa massa de dados, VARELLA (2008) propõe o uso da Análise de Componentes Principais (PCA). A PCA é um procedimento que utiliza uma transformação ortogonal para converter um conjunto de informações de variáveis originais a um conjunto de valores de variáveis de mesma dimensão, chamadas de Componentes Principais, e está associada a ideia de redução de massa de dados, com menor perda possível de informação (VARELLA, 2008).

Neste trabalho, foi avaliado a hipótese de um padrão relevante na disposição espacial dos pixel-vetores da HSI. A atenção desta hipótese se dá na presença de pixel-vetores heterogêneos nas amostras. Portanto, para fazer uma avaliação tanto dos padrões espectrais quanto dos espaciais, este trabalho utiliza um procedimento denominado Treinamento e Classificação por Região Pixel-Vetores. Este procedimento trata a imagem HSI como uma imagem de n cores, sendo n o número de comprimento de ondas, e rotula cada região preenchida pela amostra.

O processo de treino foi feito em uma implementação da ResNet50, utilizando os frameworks TensorFlow e Keras. A ResNet ou rede residual, é uma rede neural profunda, que usa de funções residuais no final de blocos convolucionais, que reintroduzem os resultados

de blocos anteriores aos atuais, de forma a reduzir a degradação da informação que acontece em redes neurais profundas (HE et al., 2016).

Primeiramente, as regiões de interesse são cortadas em formato de retângulos. O corte foi feito, dividindo cada HSI em partes preenchidas com as amostras, de forma a reduzir o fundo das HSI resultantes. Posteriormente, foi feito a extração das dimensões de todas as HSI resultantes dos cortes. Processo necessário para definir o tamanho de imagem que a ResNet50 irá trabalhar. Visto que, para não executar um redimensionamento nos dados, evitando interpolações e conseqüentemente, a perda de informações espectrais, é necessário estabelecer os maiores tamanhos de largura e altura das regiões de interesse e posteriormente, usar estas dimensões para todas as imagens de entrada na rede, deixando possíveis espaços vazios em cada imagem.

O terceiro passo é a execução da PCA na matriz de pixel-vetores dos dados de treino. Este passo é necessário para reduzir a massa de dados e viabilizar o treino da rede, visto que a alta dimensionalidade que existe em imagens HSI, podem gerar custos elevados de tempo de computação e espaço em memória. Ao realizar a PCA, foi possível obter uma representatividade de 99% usando as duas primeiras componentes principais. Com posse dos dados da PCA, os dados de treino, validação e teste são transformados, reduzindo a dimensionalidade dos dados.

Em seguida, foi feito o treino com 50% dos dados de cada classe utilizando o otimizador Adam, com uma taxa de aprendizagem de 0.0001, 500 passos por época e um tamanho de batch igual a 8.

2 TRABALHOS RELACIONADOS

O estado da arte na classificação de tecidos epiteliais utilizando modelos de aprendizado profundo, utiliza um modelo com detecção de objetos, chamado RetinaNet. Entretanto, em poucos casos houve uma falha na detecção da região contendo o tecido tumoral. Os resultados apresentados foram: 11 acertos, 2 erros e 3 partes não classificadas em Melanoma. Tendo uma precisão de 68,8%; 29 acertos, 5 erros e 5 partes não classificadas em Nevo Displasico. Tendo uma precisão de 72,5%; já os resultados para Pele Saudável foram inconclusivos, devido pouca quantidade de amostras (LUCENA, 2020).

3 RESULTADOS

As regiões usadas no processo de corte, para a formação de subamostras, feita para a diminuição de fundo e ruído em cada exemplo para rede, geraram as divisões de classe representadas na Tabela 1.

Conjunto da amostra	Treinamento	Teste
Melanoma	6 amostras, 6 cortes	6 amostras, 6 cortes
Nevo Displasico	9 amostras, 36 cortes	9 amostras, 36 cortes
Pele Saudável	3 amostras, 9 cortes	2 amostras, 8 cortes

Tabela 1 – Configuração dos conjuntos de treino e teste.

Ao realizar a PCA, foi possível obter uma representatividade de 99% usando as duas primeiras componentes principais. Verificando os maiores valores de largura e altura,

entre todos os cortes, foi obtido respectivamente 820 e 1594, deixando as amostras de entrada para rede com as dimensões: 820x1594x2.

Foram adicionados aos conjuntos, um contraexemplo, contendo tudo aquilo que a rede deveria identificar como não-amostra. Sendo esse contraexemplo regiões da HSI sem tecido. Essas novas amostras tem o objetivo de forçar os neurônios da rede a diferenciar as amostras utilizando as regiões preenchidas pelo tecido, deixando de usar o fundo como parâmetro de classificação.

No processo de classificação de amostras de teste: A rede classificou corretamente 6 das 6 amostras de Melanoma; classificou corretamente 35 as 36 amostras de Nevo Displasico; classificou corretamente 6 das 8 amostras de Pele Saudável.

4 CONCLUSÃO

Com a implementação do modelo proposto, foi possível classificar as amostras entre: Melanoma, Nevo Displasico e Pele Saudável. Desta forma, é possível confirmar que a junção da análise espacial e espectral, utilizando SWIR-HSI, pode ser utilizado para a construção de novos modelos de classificação de tumores em tecidos epiteliais.

Comparando as abordagens deste trabalho com a literatura, observamos que o modelo utilizado apresenta uma arquitetura mais simples. Por não trabalhar com detecção de objetos, a precisão do modelo proposto não é penalizada com a falha em localizar um objeto. Entretanto, esta cria a necessidade de recortes de regiões contendo a amostra. E embora o estudo apresentado também sofra com a falta de amostras de Pele Saudável, ainda foi possível identificar 6 das 8 amostras apresentadas. Também houve uma melhora na classificação de Melanoma, em que a rede acertou 6 das 6 amostras apresentadas.

Trabalhos futuros, dando continuidade a este estudo são: Novos experimentos contendo um número maior de amostras; gerar uma segmentação semântica ao final do procedimento de detecção; aplicar a solução proposta em amostras *in vivo*.

5 REFERENCIAS

AUTIER, P.; FOR EPIMEL, D.; EORTC MELANOMA COOPERATIVE GROUP, J.-F. Influence of sun exposures during childhood and during adulthood on melanoma risk. *International Journal of Cancer*, 77(4):533–537, 1998.

Akbari, H., et al.: Hyperspectral imaging and quantitative analysis for prostate cancer detection. *J. Biomed. Opt.* 17(7), 076005-1–076005-10 (2012). <https://doi.org/10.1117/1.JBO.17.7.076005>. <http://dx.doi.org/10.1117/1.JBO.17.7.076005>

AFROMOWITZ, M. A.; CALLIS, J. B.; HEIMBACH, D. M.; DESOTO, L. A.; NORTON, M. K. Multispectral imaging of burn wounds: a new clinical instrument for evaluating burn depth. *IEEE transactions on biomedical engineering*, 35(10):842–850, 1988.

BAMBERY, K. R.; WOOD, B. R.; QUINN, M. A.; MCNAUGHTON, D. Fourier transform infrared imaging and unsupervised hierarchical clustering applied to cervical biopsies. *Australian Journal of Chemistry*, 57(12):1139–1143, 2004.

CALIN, M. A.; PARASCA, S. V.; SAVASTRU, D.; MANEA, D. Hyperspectral imaging in the medical field: Present and future. *Applied Spectroscopy Reviews*, 49(6):435–447, 2014

CARLI, P.; DE GIORGI, V.; SOYER, H.; STANTE, M.; MANNONE, F.; GIANNOTTI, B. Dermatoscopy in the diagnosis of pigmented skin lesions: a new semiology for the dermatologist. *Journal of the European Academy of Dermatology and Venereology*, 14(5):353–369, 2000.

CHEN, Y.; LIN, Z.; ZHAO, X.; WANG, G.; GU, Y. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected topics in applied earth observations and remote sensing*, 7(6):2094–2107, 2014.

ESTEVA, A.; KUPREL, B.; NOVOA, R. A.; KO, J.; SWETTER, S. M.; BLAU, H. M.; THRUN, S. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639):115–118, 2017.

FIGUEIREDO, L. C.; CORDEIRO, L. N.; ARRUDA, A. P.; CARVALHO, M. D. F.; RIBEIRO, E. M.; COUTINHO, H. D. M. Câncer de pele: estudo dos principais marcadores moleculares do melanoma cutâneo. *Rev Bras de Cancerologia*, 49(3):179–183, 2003.

HALICEK, M.; LU, G.; LITTLE, J. V.; WANG, X.; PATEL, M.; GRIFFITH, C. C.; ELDEIRY, M. W.; CHEN, A. Y.; FEI, B. Deep convolutional neural networks for classifying head and neck cancer using hyperspectral imaging. *Journal of Biomedical Optics*, 22:22 – 22 – 4, 2017.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 770–778, 2016.

KOH, K. R.; WOOD, T. C.; GOLDIN, R. D.; YANG, G.-Z.; ELSON, D. S. Visible and near infrared autofluorescence and hyperspectral imaging spectroscopy for the investi-

gation of colorectal lesions and detection of exogenous fluorophores. In: Proc. SPIE, volume 7169, p. 71691E, 2009.

KUCHERYAVSKI, S. Using hard and soft models for classification of medical images. *Chemometrics and Intelligent Laboratory Systems*, 88(1):100–106, 2007.

LU, G.; FEI, B. Medical hyperspectral imaging: a review. *Journal of Biomedical Optics*, 19(1):010901, 2014

D. V. d. Lucena, A. d. S. Soares, C. J. Coelho, I. J. Wastowski and A. R. G. Filho, "Detection of Tumoral Epithelial Lesions Using Hyperspectral Imaging and Deep Learning," in *Computational Science – ICCS 2020*, Amsterdam, The Netherlands, 2020.

MALKOFF, D. B.; OLIVER, W. R. Hyperspectral imaging applied to forensic medicine. In: Proc. SPIE, p. 0277–786X, 2000.

MANNI, F.; FONOLLÀ, R.; VAN DER SOMMEN, F.; ZINGER, S.; SHAN, C.; KHO, E.; DE KONING, S. B.; RUERS, T.; DE WITH, P. H. Hyperspectral imaging for colon cancer classification in surgical specimens: towards optical biopsy during image-guided surgery. In: *2020 42nd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, p. 1169–1173. IEEE, 2020.

REZZE, G. G.; LEON, A.; DUPRAT, J. A. Nevo displÃsico (nevo atÃpico). *Anais Brasileiros de Dermatologia*, 85:863 – 871, 12 2010.

SCHADENDORF, D.; FISHER, D. E.; GARBE, C.; GERSHENWALD, J. E.; GROB, J.-J.; HALPERN, A.; HERLYN, M.; MARCHETTI, M. A.; MCARTHUR, G.; RIBAS, A.; OTHERS. Melanoma. *Nature reviews Disease primers*, 1(1):1–20, 2015.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. *Neural networks*, 61:85–117, 2015.

SCHULTZ, R. A.; NIELSEN, T.; ZAVALETA, J. R.; RUCH, R.; WYATT, R.; GARNER, H. R. Hyperspectral imaging: a novel approach for microscopic analysis. *Cytometry Part A*, 43(4):239–247, 2001.

SOCIETY, A. C. Cancer facts and figures 2017. <<http://www.cancer.org/acs/groups/content/@editorial/documents/document/acspc-048738.pdf>>, 2017.

SOCIETY, A. C. Tests for melanoma skin cancer. <<https://www.cancer.org/cancer/melanoma-skin-cancer/detection-diagnosis-staging/how-diagnosed.html>>, 2016.

SPECIM. SisuCHEMA - Chemical Imaging Analyzer. <[http://www.specim.fi/downloads/SisuCHEMA\protect\relax\\$\spacefactor\@m{}@underline{\hbox{}}\mathsurround@\\$\relax2\protect\relax\\$\spacefactor\@m{}@underline{\hbox{}}\mathsurround@\\$\relax2015.pdf](http://www.specim.fi/downloads/SisuCHEMA\protect\relax$\spacefactor\@m{}@underline{\hbox{}}\mathsurround@$\relax2\protect\relax$\spacefactor\@m{}@underline{\hbox{}}\mathsurround@$\relax2015.pdf)>, 2015.

Weinberg, Robert A. "How Cancer Arises." *Scientific American*, vol. 275, no. 3, Scientific American, a division of Nature America, Inc., 1996, pp. 62–70.

ZEVON, M.; GANAPATHY, V.; KANTAMNENI, H.; MINGOZZI, M.; KIM, P.; ADLER, D.; SHENG, Y.; TAN, M. C.; PIERCE, M.; RIMAN, R. E.; OTHERS. Cxcr-4 targeted, short wave infrared (swir) emitting nanoprobe for enhanced deep tissue Referências Bibliográficas 83 imaging and micrometastatic cancer lesion detection. *Small*, 11(47):6347–6357, 2015.

ZONIOS, G.; PERELMAN, L. T.; BACKMAN, V.; MANOHARAN, R.; FITZMAURICE, M.; VAN DAM, J.; FELD, M. S. Diffuse reflectance spectroscopy of human adenomatous colon polyps in vivo. *Applied Optics*, 38(31):6628–6637, 1999.