

# Representações Esparsas Através de Dicionários para Processamento e Análise de Imagens Macroscópicas de Lesões Melanocíticas

Eliezer Soares Flores<sup>1,2</sup>, Jacob Scharcanski<sup>1</sup>

<sup>1</sup> Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)  
Porto Alegre – RS – Brasil

<sup>2</sup> Universidade Federal do Pampa (UNIPAMPA)  
Alegrete – RS – Brasil

{esflores, jacobs}@inf.ufrgs.br

**Abstract.** *Melanoma is the most lethal type of skin cancer, since it is most prone to metastasis. Specifically, the rate of patients who survive at least five years after early stage diagnosis of this disease is over 99%. However, this rate decreases to about 25% if detection occurs only at the last stage. In this context, systems that assist in the early diagnosis of melanoma can play an extremely important role, especially in regions where access to dermatologists is poor. However, differentiating melanoma from benign melanocytic lesions can be a challenging task, even for experienced specialists. To address this problem, in this thesis, an automatic system is proposed for melanoma detection from a simple digital photograph, which is based on sparse representation models. The results presented by the proposed system are promising and suggest that it can potentially outperform state-of-the-art alternatives and even trained dermatologists.*

**Resumo.** *O melanoma é o tipo mais letal de câncer de pele, uma vez que é mais propenso à metástase. Especificamente, a taxa de pacientes que sobrevivem pelo menos cinco anos após o diagnóstico dessa doença no estágio inicial é superior a 99%. No entanto, essa taxa diminui para cerca de 25% se a detecção ocorre somente no último estágio. Nesse contexto, sistemas que auxiliem no diagnóstico precoce do melanoma podem desempenhar um papel de extrema importância, especialmente em regiões nas quais o acesso a dermatologistas é precário. Contudo, diferenciar um melanoma de lesões melanocíticas benignas pode ser uma tarefa desafiadora, mesmo para especialistas experientes. Para lidar com esse problema, nesta tese, propõe-se um sistema automático para detecção de melanoma a partir de uma simples fotografia digital, o qual baseia-se em modelos de representações esparsas. Os resultados apresentados pelo sistema proposto são promissores e sugerem que o sistema proposto pode potencialmente superar alternativas estado-da-arte e até mesmo médicos treinados.*

## 1. Caracterização do Problema e Motivação da Pesquisa


O melanoma, um tumor maligno que começa nos melanócitos (i.e., uma lesão melanocítica maligna), embora possua um prognóstico favorável se detectado nos estágios

iniciais, é o tipo mais letal de câncer de pele, uma vez que é mais propenso à metástase. Por isso, o diagnóstico precoce do melanoma é essencial não só para reduzir o número de vítimas como também os custos envolvidos com o tratamento da doença [Ministério da Saúde 2019].

Neste contexto, vários sistemas têm sido propostos para classificar lesões melanocíticas a partir de uma simples fotografia digital (i.e., uma imagem macroscópica ou clínica) [Scharcanski and Celebi 2014]. Esses sistemas podem ser aplicados em diferentes cenários tais como: no acompanhamento teledermatológico de pacientes que já tiveram melanoma ou possuem a síndrome do nevo atípico; na triagem de pacientes em unidades básicas de saúde ou em consultas com um clínico geral; como ferramenta didática em cursos de dermatologia; para auxiliar o diagnóstico de um dermatologista.

Contudo, projetar um sistema que seja capaz de distinguir melanomas de determinadas lesões melanocíticas benignas, conhecidas como nevos atípicos, é uma tarefa complexa de processamento e análise de imagens. A Figura 1, a qual apresenta três amostras da classe “nevo atípico” (Subfiguras 1a até 1c) e três amostras da classe “melanoma” (Subfiguras 1d até 1f), está disposta de uma maneira que deve evidenciar ao leitor que resolver o problema em questão não é trivial, mesmo para um especialista, não só por causa da variabilidade entre imagens de uma mesma classe, mas também pelas similaridades visuais entre imagens das diferentes classes.

**Figura 1. Exemplos de imagens macroscópicas de lesões melanocíticas [Alcón et al. 2009].**




Recentemente, diversos sistemas de classificação de lesões melanocíticas baseados em aprendizado profundo têm sido propostos na literatura, geralmente, combinando aprendizado por transferência com outras abordagens tais como o aumento de dados (do inglês, *data augmentation*), a incorporação de metadados, o uso de mecanismos de atenção e a composição de modelos múltiplos preditivos com redes neurais convolucionais profundas (do inglês, *Deep Convolutional Neural Networks – DCNNs*). Contudo, a maioria desses sistemas foram projetados para operar com base em imagens dermatoscópicas (logo, possuem uma gama de aplicações mais restrita), principalmente, pelos motivos delineados nos parágrafos a seguir.

A tarefa de processar e analisar uma imagem macroscópica de lesão melanocítica,

em vez de uma imagem dermatoscópica, é mais desafiadora não só porque a classificação da lesão deve ser realizada com base em uma imagem que contém menos informações sugestivas, mas também porque é necessário elaborar etapas de processamento de imagens mais robustas para lidar com complicações adicionais (e.g., iluminação irregular e maior quantidade de artefatos indesejáveis), conforme exemplificado na Figura 2, onde cada linha apresenta uma determinada lesão melanocítica capturada pelas duas modalidades de imageamento. Concretamente, na primeira linha (i.e., Subfiguras 2a até 2c), essas lesões são apresentadas em imagens macroscópicas. Na segunda linha (i.e., nas Subfiguras 2d até 2f), por sua vez, essas mesmas lesões são apresentadas em imagens dermatoscópicas.

**Figura 2. Exemplos de imagens dermatoscópicas de lesões melanocíticas em comparação com as imagens macroscópicas correspondentes [Kawahara et al. 2018].**



A existência, desde 2016, de uma competição anual, organizada pelo ISIC (*International Skin Imaging Collaboration*) [Codella et al. 2018], a qual atualmente disponibiliza uma base pública com mais de 70 mil imagens dermatoscópicas, ou seja, duas ordens de magnitude maior que as bases de imagens macroscópicas públicas propostas em [Amelard et al. 2014, Giotis et al. 2015, Brinker et al. 2019].

Cabe ainda mencionar que a maior parte dos sistemas baseados em aprendizado profundo propostos para classificar imagens de lesões melanocíticas não incorpora uma etapa própria de segmentação das lesões, embora métodos baseados em aprendizado profundo especificamente projetados para a segmentação possam ser encontrados na literatura, por exemplo, em [Al-Masni et al. 2018] e [Hasan et al. 2020].

## 2. Objetivos e Contribuições do Trabalho

O objetivo geral desta tese é o desenvolvimento de um sistema de processamento e análise de imagens macroscópicas de lesões melanocíticas, com base em métodos de representações esparsas através de dicionários, que possa alcançar um desempenho preditivo equiparável aos desempenhos observados em alternativas apresentadas recentemente na literatura, mesmo sendo treinado com uma quantidade relativamente limitada de exemplos. Por isso, ao longo deste trabalho, foi realizado um estudo aprofundado sobre métodos de representações esparsas através de dicionários. Com base nesse estudo, foram desenvolvidos dois métodos principais:

**Método de Segmentação.** Um método não supervisionado de segmentação de lesões melanocíticas, baseado no particionamento das representações dos blocos quadrados da imagem de entrada em um dicionário obtido empregando uma versão adaptativa e não supervisionada do método ITDL (*Information-Theoretic Dictionary Learning*) [Qiu et al. 2014]. Esse método foi apresentado à comunidade na nossa publicação no periódico *Expert Systems With Applications* (Qualis A1; *CiteScore*: 12,2; fator de impacto: 8,665) [Flores and Scharcanski 2016], a qual foi citada por aproximadamente 50 trabalhos até o momento da elaboração deste documento.

**Método de Classificação.** Um método supervisionado de classificação, o qual é baseado em uma representação esparsa da imagem de teste em um “dicionário de características profundas” e que pode ser visto como uma versão modificada, mais escalável e robusta para lidar com o problema do desbalanceamento entre classes, do método SRC (*Sparse Representation-based Classification*) [Wright et al. 2009]. Esse método foi apresentado à comunidade na nossa publicação no periódico *Pattern Recognition* (Qualis A1; *CiteScore*: 15,5; fator de impacto: 8,518) [Flores et al. 2019], a qual foi citada por aproximadamente 30 trabalhos até o momento da elaboração deste documento.

Esses métodos, por sua vez, serviram de base para o desenvolvimento de um sistema completo de pré-triagem de lesões melanocíticas a partir de imagens macroscópicas, o qual foi projetado para lidar com os seguintes problemas encontrados nas alternativas estado-da-arte: a maioria dos sistemas propostos recentemente foram desenvolvidos para operar com base em imagens dermatoscópicas e, conseqüentemente, podem não desempenhar a sua função da maneira esperada quando a entrada é uma imagem macroscópica; os sistemas existentes, geralmente, foram treinados com uma quantidade de imagens maior do que as quantidades de imagens disponíveis nas bases públicas de imagens macroscópicas; os sistemas existentes, normalmente, não incluem uma etapa específica de segmentação, o que eleva os riscos de problemas como aqueles reportados em [Bissoto et al. 2019]; a avaliação dos sistemas existentes costuma basear-se em validações cruzadas sobre uma mesma base de imagens (ao invés de basear-se em testes do tipo *cross-dataset*) e, por conseguinte, pode resultar em previsões de desempenho pouco realistas.

### 3. Resultados Obtidos e Discussão

O sistema proposto, como um todo, foi comparado com alternativas representativas do estado-da-arte em classificação automática de imagens de lesões melanocíticas: os métodos *Attention Residual Learning* (ARL) [Zhang et al. 2019] e *Dynamic Weights* (DW) [Pacheco et al. 2020]; a abordagem vencedora do desafio de classificação do ISIC 2020 – *ISIC Winner* (IW) [Ha et al. 2020] – e a solução web *Skin Lesion Analyzer* (SLA) [Woza 2018].

Nos testes *cross-dataset*<sup>1</sup> realizados com as imagens da base proposta no trabalho de [Brinker et al. 2019], o sistema proposto apresentou uma AUC de 85%, enquanto os métodos ARL, DW, IW e SLA apresentaram AUCs de 63%, 77%, 70% e 78%, respectivamente. Nos testes com a base de [Alcón et al. 2009], por sua vez, o sistema proposto apresentou uma AUC de 89%, enquanto os métodos ARL, DW, IW e SLA apresenta-

---

<sup>1</sup>O treinamento e a validação do sistema proposto basearam-se em amostragem cruzada  $5 \times 2$  sobre a base de [Amelard et al. 2014].

ram AUCs de 63%, 86%, 67% e 78%. De fato, o desempenho do sistema proposto, em termos da métrica AUC, não somente supera o desempenho das abordagens estado-da-arte, mas também o desempenho reportado por alguns dermatologistas especializados em [Brinker et al. 2019].

Por fim, cabe mencionar que o resultados obtidos com os métodos desenvolvidos nesta tese não só motivam investigações futuras que explorem modelos baseados em representações esparsas através de dicionários, mas também podem vir a beneficiar diretamente diferentes sistemas de processamento e análise de imagens médicas. Algumas questões importantes que não foram tratadas nesta tese, por exemplo, a integração dos métodos de segmentação e classificação em uma única rede que possa ser treinada de maneira unificada, bem como a adaptação do sistema para fornecer uma predição mais interpretável, podem vir a ser investigadas em extensões deste trabalho.

## Referências

- Al-Masni, M. A., Al-Antari, M. A., Choi, M.-T., Han, S.-M., and Kim, T.-S. (2018). Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks. *Computer Methods and Programs in Biomedicine*, 162:221–231.
- Alcón, J. F., Ciuhu, C., ten Kate, W., Heinrich, A., Uzunbajakava, N., Krekels, G., Siem, D., and de Haan, G. (2009). Automatic imaging system with decision support for inspection of pigmented skin lesions and melanoma diagnosis. *IEEE Journal of Selected Topics in Signal Processing*, 3(1):14–25.
- Amelard, R., Glaister, J., Wong, A., and Clausi, D. A. (2014). High-level intuitive features (HLIFs) for intuitive skin lesion description. *IEEE Transactions on Biomedical Engineering*, 62(3):820–831.
- Bissoto, A., Fornaciali, M., Valle, E., and Avila, S. (2019). (de) constructing bias on skin lesion datasets. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pages 2766–2774.
- Brinker, T. J., Hekler, A., Hauschild, A., Berking, C., Schilling, B., Enk, A. H., Haferkamp, S., Karoglan, A., von Kalle, C., Weichenthal, M., et al. (2019). Comparing artificial intelligence algorithms to 157 german dermatologists: the melanoma classification benchmark. *European Journal of Cancer*, 111:30–37.
- Codella, N. C. F., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., Kalloo, A., Liopyris, K., Mishra, N., Kittler, H., and Halpern, A. (2018). Skin lesion analysis toward melanoma detection: a challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), hosted by the International Skin Imaging Collaboration (ISIC). In *Proceedings of the IEEE International Symposium on Biomedical Imaging (ISBI)*, pages 168–172.
- Flores, E. and Scharcanski, J. (2016). Segmentation of melanocytic skin lesions using feature learning and dictionaries. *Expert Systems with Applications*, 56:300–309.
- Flores, E., Zortea, M., and Scharcanski, J. (2019). Dictionaries of deep features for land-use scene classification of very high spatial resolution images. *Pattern Recognition*, 89:32–44.

- Giotis, I., Molders, N., Land, S., Biehl, M., Jonkman, M. F., and Petkov, N. (2015). MED-NODE: a computer-assisted melanoma diagnosis system using non-dermoscopic images. *Expert Systems with Applications*, 42(19):6578–6585.
- Ha, Q., Liu, B., and Liu, F. (2020). Identifying melanoma images using efficientnet ensemble: Winning solution to the SIIM-ISIC melanoma classification challenge. Disponível em: <https://arxiv.org/pdf/2010.05351.pdf>. Último acesso em: 09 set. 2022.
- Hasan, M. K., Dahal, L., Samarakoon, P. N., Tushar, F. I., and Martí, R. (2020). DSNet: Automatic dermoscopic skin lesion segmentation. *Computers in Biology and Medicine*, 120:103738.
- Kawahara, J., Daneshvar, S., Argenziano, G., and Hamarneh, G. (2018). Seven-point checklist and skin lesion classification using multitask multimodal neural nets. *IEEE Journal of Biomedical and Health Informatics*, 23(2):538–546.
- Ministério da Saúde (2019). *Terapia-alvo (vemurafenibe, dabrafenibe, cobimetinibe, trametinibe) e imunoterapia (ipilimumabe, nivolumabe, pembrolizumabe) para o tratamento de primeira linha do melanoma avançado não-cirúrgico e metastático*. CONITEC.
- Pacheco, A. G., Trappenberg, T., and Krohling, R. A. (2020). Learning dynamic weights for an ensemble of deep models applied to medical imaging classification. In *Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.
- Qiu, Q., Patel, V. M., and Chellappa, R. (2014). Information-theoretic dictionary learning for image classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 36(11):2173–2184.
- Scharcanski, J. and Celebi, M. E. (2014). *Computer Vision Techniques for the Diagnosis of Skin Cancer*. Springer.
- Woza, M. (2018). Skin lesion analyzer. Disponível em: <http://skin.test.woza.work/>. Último acesso em: 09 set. 2022.
- Wright, J., Yang, A. Y., Ganesh, A., Sastry, S. S., and Ma, Y. (2009). Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2):210–227.
- Zhang, J., Li, W., Ogunbona, P., and Xu, D. (2019). Recent advances in transfer learning for cross-dataset visual recognition: A problem-oriented perspective. *ACM Computing Surveys*, 52(1):1–38.