



## Extração e Seleção de Atributos para Análise de Imagens Médicas

Ana Paula Benetti Grezzana (PIBIC/CNPq/Unioeste), Huei Diana Lee (Orientadora),  
Newton Spolaôr, Wu Feng Chung, e-mail: ana.grezzana@unioeste.br.

Universidade Estadual do Oeste do Paraná  
Centro de Engenharias e Ciências Exatas/Foz do Iguaçu, PR.

**Área/subárea:** Ciências Exatas e da Terra/Ciência da Computação

**Palavras-chave:** câncer de pele, validação cruzada, processamento de imagens

### Resumo

Métodos computacionais auxiliam cada vez mais em investigações da área médica, especialmente naquelas destinadas ao diagnóstico precoce de doenças, contribuindo para maior efetividade no tratamento delas. Assim, a análise de imagens dermatoscópicas pode ser apoiada pelo uso de tecnologias de caracterização e de classificação dessas imagens. Visando isso, o objetivo principal deste trabalho é pesquisar e aplicar métodos de segmentação, extração de características e seleção de atributos para auxiliar no diagnóstico de lesões de pele. Para alcançar esse objetivo foram usados os descritores de textura de Haralick e *Neighborhood Grey Tone Difference Matrix* e os algoritmos *Correlation-based Feature Selection*, árvore de decisão J48 e Random Forest. Uma avaliação experimental, embasada por teste estatístico de hipótese, sugere que alguns classificadores gerados levaram a resultados promissores na diferenciação entre dermatoscopias com lesões benignas e malignas.

### Introdução

Uma lesão de pele pode ser definida como benigna ou maligna por meio de características específicas como cor e diâmetro, entre outras. O diagnóstico precoce dessas lesões é essencial para um tratamento ou prevenção bem-sucedida do câncer, uma doença com uma grande quantidade anual de novos casos (American Cancer Society, 2021).

Para apoiar essa tarefa, o desenvolvimento e a aplicação de abordagens computacionais para análise de imagens vêm se ampliando em distintos domínios da área médica.

Um exemplo dessas técnicas computacionais são os métodos de extração de características de imagens e de aprendizado de máquina, os quais podem contribuir para a criação de modelos que auxiliam na diferenciação de lesões de pele (Lee et al., 2018). O bom desempenho desses modelos depende, entre outros fatores, de



aspectos como um pré-processamento apropriado e a aquisição de características de qualidade de dermatoscopias.

Nesse contexto, estratégias de segmentação de imagens e de Seleção de Atributos (SA) importantes para a predição do tipo de lesão têm sido empregadas na literatura (Rastgoo *et al.*, 2015; Seeja & Suresh, 2019).

A partir desse cenário, o objetivo desse trabalho é contribuir para a diferenciação de lesões de pele por meio do estudo e da aplicação de técnicas de segmentação, extração e seleção de características de dermatoscopias. A avaliação dessas técnicas foi realizada por meio da construção de modelos de classificação e análise de seus desempenhos comparados usando teste estatístico apropriados.

## Material e Métodos

Os materiais utilizados para o desenvolvimento deste projeto foram:

- Ambiente e linguagem de programação para cálculo numérico MathWorks MATLAB versão 2011 (<https://www.mathworks.com/>).
- Ambiente e linguagem de programação científica GNU Octave versões 6.2 e 6.3 (<https://www.gnu.org/software/octave/index>).
- Software de aprendizado de máquina Weka versão 3.8.5 (Witten *et al.*, 2016);
- Ambiente para análise de dados GraphPad Prism (<https://www.graphpad.com/scientific-software/prism/>);
- Computador pessoal do tipo *notebook*:
  - Processador Intel Core i5;
  - Memória RAM de 6GB;
  - Sistema operacional Windows 10.
- Linguagem de programação Java;
- Ferramenta de acesso remoto TeamViewer (<https://www.teamviewer.com/pt-br/>).
- Conjunto de 274 imagens médicas de lesões de pele extraídas do repositório do projeto *International Skin Imaging Collaboration* (ISIC Archive, 2021), das quais 48 e 226 são lesões do tipo melanoma e nevos, respectivamente.

O desenvolvimento deste projeto foi composto por cinco fases: (1) investigação de métodos de apoio e coleta do conjunto de imagens; (2) pré-processamento das imagens; (3) extração de características; (4) seleção de características (atributos) e construção de classificador; e (5) realização de experimentos e análise dos resultados.

Os algoritmos e ferramentas de suporte para o conhecimento do tema e desenvolvimento do projeto foram estudados na Fase (1). Nessa mesma fase foram adquiridas imagens dermoscópicas do repositório ISIC e as máscaras (anotações) de lesões correspondentes definidas por especialistas e de modo semi-automático.

Para a Fase (2) foram utilizadas as imagens e máscaras no desenvolvimento



de uma segmentação justa simples. A segmentação consistiu no recorte de cada imagem no trecho delimitado pelas coordenadas mínimas e máximas da máscara relacionada. A ideia foi obter a região mais importante de cada dermatoscopia para análise da lesão contida nela.

Na Fase (3) as imagens pré-processadas passaram pela extração de características de Haralick (Haralick *et al.*, 1973) – 14 atributos –, e de *Neighborhood Grey Tone Difference Matrix* (NGTDM) (Amadasun & King, 1989) – 5 descritores.

A Fase (4) iniciou-se com a divisão das imagens em 10 *folds* conforme a estratégia de validação cruzada estratificada. Em seguida, um Subconjunto de atributos Inicial (SI) foi selecionado em cada um dos *folds* de treinamento pelo método *Correlation-based Feature Selection* (CFS) (Witten *et al.*, 2016). Foram então identificados os atributos que apareceram pelo menos uma vez em cada aplicação do CFS, *i. e.*, foi obtida a união dos 10 SI. A seleção dos atributos resultantes da união foi realizada, de acordo com a ocorrência deles, em quatro subconjuntos finais: 25%, 50%, 75% e 100% dos atributos mais frequentes dentre os SI. Ainda nesta fase, foi realizada a construção de modelos a partir dos algoritmos de classificação J48 (Witten *et al.*, 2016) e Random Forest (RF) (Ho, 1998), que receberam como entradas (1) todos os atributos – *Baseline* (B) – e (2) apenas os atributos selecionados previamente em cada subconjunto final. Foram calculadas a acurácia e especificidade para cada uma dessas configurações.

Para prover embasamento à comparação dos modelos construídos, na Fase (5) foi realizado o teste estatístico de Friedman sobre as acurácias obtidas pelos classificadores J48 e RF com e sem o uso de SA.

## Resultados e Discussão

Na Tabela 1 são apresentados os resultados de cada entrada (*Baseline* e os quatro subconjuntos finais) e suas Acurácia (A) e Especificidade (E) médias, bem como seus respectivos desvios padrão entre parênteses.

**Tabela 1** – Resultados da aplicação dos algoritmos de classificação sobre dermatoscopias

Entrada		J48		Random Forest	
		A	E	A	E
<b>Todos os atributos (<i>Baseline</i>)</b>		80,28 (3,98)	0,93 (0,08)	83,93 (5,85)	0,96 (0,05)
<b>Com seleção de atributos e união</b>	<b>25%</b>	83,17 (7,52)	0,96 (0,07)	78,80 (8,22)	0,88 (0,10)
	<b>50%</b>	83,18 (6,39)	0,96 (0,07)	82,80 (3,22)	0,94 (0,04)
	<b>75%</b>	80,69 (6,84)	0,93 (0,10)	83,20 (4,68)	0,93 (0,05)
	<b>100%</b>	80,28 (5,57)	0,93 (0,10)	82,83 (5,80)	0,95 (0,06)



O teste estatístico de Friedman aplicado sobre as acurácias não detectou diferença estatisticamente significativa na comparação entre todas as configurações de entradas e algoritmos J48 e RF. Pode-se observar que todos os modelos gerados apresentaram uma acurácia média acima de 78%. Além disso, ambos algoritmos exibem um resultado satisfatório geral, pois levaram a cenários em que a acurácia média foi maior que o complemento do erro da classe majoritária:  $1-48/(48+226) = 82,48\%$ . Esse achado é considerado positivo, pois indica que mesmo modelos gerados usando apenas 3 atributos (25% dos atributos da união) são competitivos em relação ao *Baseline* – 19 descritores. Nota-se ainda que várias configurações atingem acurácia e especificidade médias próximas das atingidas por Lee *et al.* (2018), onde foram empregados método e conjunto de imagem dermatoscópicas distintos.

Em relação à especificidade, os valores médios relativamente altos encontrados indicam que a probabilidade de se predizer uma lesão como sendo benigna é também bastante alta.

Em geral, foi possível alcançar resultados satisfatórios com o método desenvolvido neste trabalho. Isso se deve especialmente ao uso de técnicas como a segmentação justa, ilustrada na Figura 1, e à união entre SI selecionados a partir dos *folds*, que resultou em nove atributos – seis de Haralick e três de NGTDM.



**Figura 1** – À esquerda, uma imagem original de um melanoma do repositório ISIC; e à direita, a mesma imagem com a aplicação da segmentação justa

A adoção da segmentação justa em 274 imagens foi importante devido ao maior enfoque que ela oferece à análise de imagens. Em particular, os métodos de extração de características podem priorizar a descrição de lesões e localidades próximas, ao invés de regiões que podem conter artefatos irrelevantes, como pelos.

### Conclusões

O método desenvolvido neste trabalho cumpriu o objetivo, auxiliando na classificação de imagens médicas. O desempenho dos melhores modelos em um repositório importante na dermatoscopia foi considerado promissor. Trabalhos futuros incluem a análise mais aprofundada da influência das técnicas aplicadas do ponto de vista de especificidade e sensibilidade, bem como a utilização das técnicas



destacadas em mais bases de imagens médicas. Além disso, a aplicação de algoritmos de classificação alternativos, como redes neurais rasas e profundas, também fará parte da continuidade deste projeto.

## Agradecimentos

À UNIOESTE e ao CNPq pela concessão da bolsa de iniciação científica.

## Referências

American Cancer Society. (2021). Cancer facts and figures. <https://encurtador.com.br/fuBE8>. Acesso em 13 de Setembro de 2021.

Amadasun, M. & King, R. (1989). Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man, and Cybernetics* **19**, 1264-1274.

Haralick, R.M., Shanmugam, K. & Dinstein, I. (1973). Textural features for image classification. *IEEE Transaction on System, Man and Cybernetics* **3**, 610-621.

Ho, T.K. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **20**, 832-844.

ISIC Archive. (2021). The International Skin Imaging Collaboration. <https://www.isic-archive.com/>. Acesso em 9 de Setembro de 2021.

Lee, H.D., Mendes, A.I., Spolaôr, N., Oliva, J.T., Parmezan, A.R.S., Wu, F.C. & Fonseca-Pinto, R. (2018). Dermoscopic assisted diagnosis in melanoma: Reviewing results, optimizing methodologies and quantifying empirical guidelines. *Knowledge-Based Systems* **158**, 9-24.

Rastgoo, M., Garcia, R., Morel O. & Marzani, F. (2015). Automatic differentiation of melanoma from dysplastic nevi, *Computerized Medical Imaging and Graphics* **43**, 44-52.

Seeja, R.D. & Suresh, A. (2019). Melanoma segmentation and classification using deep learning. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)* **8**, 2667-2672.

Witten, I.H., Frank, E., Hall, M.A. & Pal, C.J. (2016). *Data mining: practical machine learning tools and techniques*. Cambridge: Morgan Kaufmann.