

Diagnóstico de Melanoma Utilizando Rede de Cápsulas

Gabriel M. Cardoso¹, Thamila Fontenele¹, Matheus Boaro², Geraldo Braz¹

¹VipLab – Universidade Federal do Maranhão (UFMA)

Av. dos Portugueses, 1966 – Bacanga – 65080-805 – São Luis, MA – Brasil

²Núcleo de Computação Aplicada (NCA) – Universidade Federal do Maranhão (UFMA)

Av. dos Portugueses, 1966 – Bacanga – 65080-805 – São Luis, MA – Brasil

{gabrielcardoso, thamila.fontenele, geraldo, boaro}@nca.ufma.br

1. Introdução

O câncer de pele pode ser classificado em dois tipos, melanomas e não melanomas, o melanoma apesar de ser diagnosticado em apenas 4% dos casos é o mais agressivo e com maior taxa de mortalidade com cerca de 79% das mortes, porém se for diagnosticado de forma precoce e tratado corretamente durante as fases iniciais a chance de cura é de aproximadamente 90%[Brazil 2009]. O objetivo deste trabalho é propor uma metodologia para o diagnóstico de melanoma utilizando uma rede de cápsula otimizada.

2. Trabalhos Relacionados

[Li and Shen 2018] propuseram duas estruturas de deep learning para abordar os desafios principais de classificação do melanoma, utilizando a base de dados ISIC, eles conseguiram 85,7% de acurácia, 49% de sensibilidade e 96,1% de especificidade na classificação das amostras, [Codella et al. 2017] realizaram um sistema de segmentação e classificação do melanoma utilizando redes neurais usando a mesma base de dados conseguindo atingir 76% de acurácia e 62% de especificidade.

3. Metodologia

A base utilizada para testar a metodologia foi a ISIC Archive(International Skin Imaging Collaboration), no total, são 27.485 imagens divididas em 5 splits e separadas em 2 classes sendo 12.815 melanoma e 14.670 não melanoma.

Introduzidas em 2017 por Geoffrey Hinton e a sua equipe, as redes de cápsulas são redes cujo o vetor de atividade representa os parâmetros de instanciação de um tipo específico de entidade, como um objeto ou parte de um objeto, elas se mostraram promissoras em relação às redes neurais convolucionais quando se trata de classificação de imagens médicas, além de serem boas em detectar características como perspectiva, tamanho e orientação as redes de cápsula também conseguem aprender as relações espaciais entre as entidades presentes nos dados, conseguindo generalizar de maneira mais eficaz do que outras soluções quando essas entidades são apresentadas em diferentes orientações. As redes de cápsula utilizam cápsulas locais que realizam processos computacionais nas suas entradas, e então, encapsulam o resultado desses processos em um pequeno vetor de saídas altamente informativas que captura não só os parâmetros, mas também a probabilidade de uma característica específica estar presente[Sabour et al. 2017][Jiménez-Sánchez et al. 2018].

A arquitetura da rede de cápsula proposta por Geoffrey Hinton possui três camadas principais: uma camada convolucional, uma cápsula primária e uma camada completamente conectada. A camada convolucional é responsável pela extração de características dos dados recebidos, no caso dessa rede de cápsulas a entrada é a imagem e a saída é um mapa de características que a camada consegue identificar. A cápsula primária aplica uma convolução a todos os canais e então concatena todas as cápsulas. A camada completamente conectada recebe vetores de cápsula como entrada que passam por um algoritmo de roteamento por concordância, onde as características de maior probabilidade são identificadas e as de menor são punidas [Sabour et al. 2017]. Com o objetivo de refinar os detalhes das imagens e melhorar na extração de características, foi feita uma alteração nessa arquitetura, incluindo duas camadas convolucionais que são somadas à primeira. A cápsula primária passa a receber o resultado da soma das três camadas convolucionais. Ao adicionar mais camadas foi possível extrair mais características. A cada nova camada aplicou-se *dropout* ou diluição para reduzir o excesso de ajustes na rede neural e consequentemente evitar "superestimação" dos dados.

4. Resultados

Treinando o modelo com a arquitetura proposta por Hinton sem alteração, foram obtidos em média 85,63% de acurácia, 94,66% de especificidade e 68,50% de sensibilidade, treinando o modelo otimizado foram obtidos em média 86,13% de acurácia, 95,65% de especificidade e 68,89% de sensibilidade. O modelo otimizado gerado pela alteração na rede de cápsula clássica aprimorou os resultados.

5. Conclusão

Pode-se concluir que a metodologia proposta neste trabalho conseguiu alcançar desempenho competitivo em comparação com trabalhos relacionados. Para trabalhos futuros pretende-se utilizar uma rede com a arquitetura híbrida para a extração de características das imagens em uma rede convolucional VGG16 com o objetivo de aprimorar a metodologia e obter melhores resultados.

Referências

- Brazil, S. M. i. (2009). Melanoma cutâneo no Brasil. *Arquivos Catarinenses de Medicina*, 38(Suplemento 01):14.
- Codella, N. C., Nguyen, Q.-B., Pankanti, S., Gutman, D. A., Helba, B., Halpern, A. C., and Smith, J. R. (2017). Deep learning ensembles for melanoma recognition in dermoscopy images. *IBM Journal of Research and Development*, 61(4/5):5–1.
- Jiménez-Sánchez, A., Albarqouni, S., and Mateus, D. (2018). Capsule networks against medical imaging data challenges. In *Intravascular Imaging and Computer Assisted Stenting and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis*, pages 150–160. Springer.
- Li, Y. and Shen, L. (2018). Skin lesion analysis towards melanoma detection using deep learning network. *Sensors*, 18(2):556.
- Sabour, S., Frosst, N., and Hinton, G. E. (2017). Dynamic routing between capsules. In *Advances in neural information processing systems*, pages 3856–3866.