

Proceeding Series of the Brazilian Society of Computational and Applied Mathematics

Estudo sobre classificação de lesões de pele com RNA-MLP

Gilson Saturnino dos Santos¹

Instituto Federal de Educação Ciência e Tecnologia de Mato Grosso do Sul, Campus Coxim, Rua Salime Tanure, s/n, Bairro Santa Tereza, 79400-000 – Coxim, Brazil

Alex F. de Araujo²

Instituto Federal de Educação Ciência e Tecnologia de Mato Grosso do Sul, Campus Três Lagoas, R. Ângelo Melão 790, 79641-162 – Três Lagoas, Brazil

A rápida evolução tecnológica que tem ocorrido nas últimas décadas tem contribuído para que a área de processamento e análise de imagens digitais ganhe destaque nas comunidades acadêmica e científica. Diferentes algoritmos computacionais têm sido propostos na literatura, com aplicações em diferentes áreas [1], destacando-se neste trabalho a classificação de lesões de pele presentes em imagens dermatoscópicas. A partir de estudos da literatura, percebe-se que as aplicações que envolvem processamento de imagens possuem características específicas, exigindo uma metodologia diferenciada para cada aplicação. Nesse contexto, este trabalho busca apresentar um estudo sobre as metodologias de classificação de imagens usando Redes Neurais Artificiais, testando e avaliando os seus resultados quando aplicados para classificar lesões de pele a partir de imagens dermatoscópicas.

A classificação de imagens busca organizar os objetos e estruturas presentes na imagem de entrada em classes distintas. É um processo que extrai informações da imagem, combinando-as com uma base de conhecimento para reconhecer padrões e objetos representados nesta imagem [1]. É uma metodologia que geralmente usa técnicas de Inteligência Artificial (IA) para obter resultados mais eficazes, como as Redes Neurais Artificiais [3].

A IA é um campo da ciência da computação que tem como objetivo tentar compreender a inteligência e construir entidades inteligentes [2]. Russell and Norvig [5] definem o objetivo da IA como compreender e construir entidades inteligentes. O objetivo do Aprendizado de Máquina (AM), área da IA, é desenvolver técnicas que permitam criar sistemas computacionais capazes de adquirir conhecimento de forma automática.

O algoritmo de Redes Neurais Artificiais (RNA) é um exemplo de algoritmo da área de AM, inspirado na rede de neurônios presente no cérebro biológico. No neurônio artificial não linear, as entradas são representadas por x_i . Cada valor de entrada passa por uma sinapse e seu respectivo peso w_i . Na Equação 1 [2], v é o somatório das entradas ponderadas pelos pesos acrescidos do termo *bias*.

$$v = \left(\sum x_i w_i \right) + bias \quad (1)$$

¹gilson.santos@ifms.edu.br

²fa.alex@gmail.com

As quantidades de camadas e os seus respectivos neurônios artificiais compõem a Arquitetura da RNA. Arquiteturas com camadas intermediárias (ocultas) e neurônios baseados no tipo *perceptron* são chamadas de RNA *Multilayers Perceptrons* (MLP) [2]. Para o aprendizado desta rede é utilizado um treinamento supervisionado (saídas da rede comparadas com saídas esperadas) e correções de erros com algoritmo *back-propagation* [2].

Foi utilizada a ferramenta Weka, coleção do estado da arte de implementações de algoritmos de AM [6], para construção e avaliação dos modelos de classificadores RNAs MLP. O conjunto de dados utilizado para treinamento (disponível em [4]), possui 200 exemplos, 14 atributos (incluindo o atributo classe) e 3 classes (Melanoma com 40 instâncias, Common-Nevus e Atypical Nevus com 80 exemplos cada). Foi realizado um experimento usando o RNA MLP com parâmetros padrões da ferramenta Weka e, um segundo experimento com o algoritmo *MultiSearch* [6] para testar configurações diferentes da RNA. No primeiro experimento a RNA utilizou 7 camadas, 0.3 de taxa de aprendizado e 0.2 de *momentum*. Na segunda avaliação o algoritmo *MultiSearch* encontrou a RNA de 10 camadas, 0.05 de taxa de aprendizagem e 0.001 de *momentum*. Para avaliação foi utilizada a metodologia *Stratified Cross-Validation* dividindo o conjunto de dados em 10 partes.

No primeiro experimento a RNA MLP obteve 89% de acurácia, enquanto no segundo foi obtido 90% de acurácia. Além disso, o modelo extraído no segundo experimento errou apenas uma classificação para a classe *Common-Nevus*, contra 4 erros do primeiro experimento. Na classe *Atypical-Nevus* o número de erros foram iguais para os dois modelos de classificação (9 erros). Já a classe *Melanoma* foi classificada de maneira errada 9 vezes no primeiro modelo e 10 vezes no segundo. As classificações incorretas podem ser resultado da quantidade reduzida de instâncias do conjunto de dados [6].

Referências

- [1] R. C. Gonzalez and R. E. Woods. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2006.
- [2] S. Haykin. *Redes Neurais: Princípios e Prática*. Artmed, 2007.
- [3] B. S. Khehra and A. P. S. Pharwaha. Classification of clustered microcalcifications using mlffbp-ann and svm. *Egyptian Informatics Journal*, 17(1):11 – 20, 2016.
- [4] T. Mendonça, P. M. Ferreira, J. S. Marques, A. R. S. Marcal, and J. Rozeira. Ph2 - a dermoscopic image database for research and benchmarking. In *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5437–5440, July 2013.
- [5] S. Russell and P. Norvig. *Inteligência artificial*. CAMPUS - RJ, 2004.
- [6] I. H. Witten, E. Frank, and M. A. Hall. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 3rd edition, 2011.