

# Aprendizado, Computação e Medicina: Um Estudo sobre Detecção de Doenças Torácicas

Gustavo Roberth Cruz Gomes<sup>1</sup>, Pedro Arthur Freitas Dias<sup>2</sup>, Anselmo Cardoso de Paiva<sup>3</sup>, Geraldo Braz Junior<sup>4</sup>

<sup>1 2 3 4</sup>Departamento de Informática – Universidade Federal do Maranhão (UFMA)  
65080-805 – São Luís – MA – Brazil

gustavoroberthc@gmail.com<sup>1</sup>, pedroarthur@nca.ufma.br<sup>2</sup>, paiva@nca.ufma.br<sup>3</sup>,  
gerald@nca.ufma.br<sup>4</sup>

***Resumo.** Este artigo discute sobre o desenvolvimento de aplicações e as variadas técnicas para a diagnóstico de imagem, dando enfoque a aplicações direcionadas a solução de complicações torácicas perceptíveis em imagens médicas. Esta é organizada por uma listagem de resultados obtidos por avaliação destes modelos. Também realizamos a implementação de um modelo mais simples, que nos permitiu melhorar o campo comparativo e experimental dentre os trabalhos disponíveis na literatura.*

## 1. Introdução

As doenças pulmonares são uma das maiores preocupações da saúde, sendo responsável por um sexto do total óbitos no mundo. O impacto das doenças pulmonares continua a ser grande hoje em dia, tal como era no início do século, e é provável que assim permaneça durante várias décadas [ELF 2020]. Além disso, a alta taxa de variabilidade de doenças pulmonares resulta num retardo para a busca do diagnóstico, tendo em vista os sintomas semelhantes para diversas patologias.

Desta forma, este estudo tem por objetivo realizar a análise e investigação de implementações para geração automática de laudos médicos do tórax com o apoio de Aprendizado de Máquina e *Image Captioning*.

## 2. Trabalhos Relacionados

Pesquisas recentes têm investigado o emprego de técnicas de aprendizado de máquina para a geração automática de laudos médicos a partir de imagens. Alguns trabalhos como o de e.g. Vinyals (2015) e Karpathy and Fei-Fei (2015), que geram legendas de imagens genéricas não médicas, utilizando o VGG16 como modelo de codificação de imagens em uma rede CNN-LSTM para processamento.

Trabalhos como o de e.g. Kougia (2019) comparam diversas implementações de modelos existentes na literatura, afim de alcançar o entendimento sobre estas arquiteturas e sobre como modelos tão distintos entre si alcançam estes resultados.

## 3. Metodologia

O presente estudo consiste em uma pesquisa bibliográfica e documental, reunindo conjuntos de dados sobre detecção preventiva de doenças torácicas por sintomas presentes em exames médicos. Estudamos os trabalhos e.g. Shin (2016), e.g. Jing (2018), e.g. Li (2019) e e.g. Liu (2019) e a base Indiana University Chest X-Ray Collection (IU X-Ray). O método de comparação foi o BLEU, uma métrica que tende a avaliar a qualidade de traduções automáticas, utilizando os textos de referência ou originais. Para fins de comparação, também foi realizada uma implementação referência usando conceitos dos

trabalhos relacionados. Optou-se pela análise de caráter quantitativo, o que fez necessária a utilização de metadados disponibilizados na rede mundial de computadores.

#### 4. Resultados preliminares

Os trabalhos analisados implementaram variados tipos de modelos, alguns com arquiteturas mais comuns, com aplicação de *Visual Attention* [e.g Jing 2018] para leitura de regiões de interesse de características, modelos GRU RNN [e.g Shin 2016] para processamento de reports e imagens (paralelo ao LSTM), outros implementaram arquiteturas mais avançadas, como técnicas particulares KERP [e.g Liu 2019] de codificação e decodificação de reports em rede. O trabalho GALME é de nossa autoria. Os trabalhos analisados compreendem seus resultados na seguinte Tabela 1:

Modelos	Dataset	BLEU-1	BLEU-2	BLEU-3	BLEU-4
GALME	IU X-RAY	0.135	0.094	0.089	0.048
e.g. Jing (2018)		0.517	0.386	0.306	0.247
e.g. Shin (2016)		0.785	0.144	0.047	0.000
e.g. Li (2016)		0.482	0.325	0.226	0.162
e.g. Liu (2019)		0.369	0.246	0.171	0.115

Tabela 1: comparação de implementações com a base IU X-Ray.

#### 5. Conclusões e Perspectivas Futuras

Neste artigo é apresentado o trabalho desenvolvido. Foi estudada a implementação de uma base médica em variados modelos de solução, revelando que muitas destas apresentaram resultados próximos, pois alguns dos relatórios gerados são mais complexos e outros apenas em termos médicos em sequência.

Finalmente, este trabalho procurou colaborar com a melhor maneira possível para a compreensão das implementações de *Image Captioning* no auxílio de diagnóstico prático através de imagens de exames de raio-x.

Para trabalhos futuros, o desenvolvimento de reais aplicações com arquiteturas que desempenham resultados mais avançados, em codificação e decodificação de reports, como localização de regiões de interesse, que garantem melhores resultados.

#### Referências

- ELF, E. L. F. (2020). “Doenças Pulmonares”. Disponível em: <https://www.europeanlung.org/pt/doen%C3%A7a-pulmonar-e-informa%C3%A7%C3%A3o/doen%C3%A7as-pulmonares/>. Último acesso em 17/06/2020.
- Vinyals, O., Toshev, A., Bengio, S. and Erhan, D. (2015). “Show and tell: A neural image caption generator”. In CVPR, Boston, MA, USA, p. 3156–3164.
- Karpathy, A. and Fei-Fei, L. (2015). “Deep visualsemantic alignments for generating image descriptions”. In CVPR, Boston, MA, USA, p. 3128–3137.
- Kougia, V., Pavlopoulos, J. and Androutsopoulos, I. (2019) “A Survey on Biomedical Image Captioning”. Department of Informatics, Athens University of Economics and Business, Greece.
- Jing, B., Xie, P. and E. Xing. 2018. On the automatic generation of medical imaging reports. In ACL, pages 2577–2586, Melbourne, Australia.
- Shin, H.-C., Roberts, K., Lu, L., Demner-Fushman, D., Yao, J. and Summers, R. M. 2016. “Learning to read chest X-rays: Recurrent neural cascade model for automated image annotation”. In CVPR, Las Vegas, USA, p. 2497–2506.
- Li, C. Y., Liang, X., Hu, Z. and Xing, E. P. (2019). “Knowledge-Driven Encode, Retrieve, Paraphrase for Medical Image Report Generation”. The Thirty-Third AAAI Conference on Artificial Intelligence. Duke University, Carnegie Mellon University, Petuum.
- Liu, G., Hsu, T.-M. H., McDermott, M., Boag, W., Weng, W.-H., Szolovits, P. and Ghassemi, M. (2019). “Clinically Accurate Chest X-Ray Report Generation”. Machine Learning for Healthcare Conference 2019.