



UNIVERSIDADE FEDERAL DE ALAGOAS - UFAL
CAMPUS DE ARAPIRACA
CIÊNCIA DA COMPUTAÇÃO – BACHARELADO

ÉMERSON JOSÉ DA SILVA

**TÉCNICAS DE REDES NEURAS CONVOLUCIONAIS PARA IDENTIFICAÇÃO
DE NÓDULOS PULMONARES**

ARAPIRACA

2019

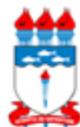
Émerson José da Silva

Técnica de redes neurais convolucionais para identificação de nódulos pulmonares

Trabalho de Conclusão de Curso (Artigo Científico)
apresentado ao Curso de Ciência da Computação da
Universidade Federal de Alagoas – UFAL, *Campus*
de Arapiraca, como requisito parcial para obtenção
do Grau de Bacharelado em Ciência da computação.

Orientador: Prof. Dr. Rodolfo Carneiro Cavalcante.

Arapiraca
2019



Universidade Federal de Alagoas – UFAL
Campus Arapiraca
Biblioteca *Campus* Arapiraca - BCA

S586t Silva, Êmerson José da
Técnicas de redes neurais convolucionais para identificação de nódulos pulmonares / Êmerson José da Silva. – Arapiraca, 2022.
9 f.: il.

Orientador: Prof. Dr. Rodolfo Carneiro Cavalcante
Trabalho de Conclusão de Curso / Artigo Científico (Bacharelado em Ciência da Computação) - Universidade Federal de Alagoas, *Campus* Arapiraca, Arapiraca, 2022.

Disponível em: Universidade Digital (UD) – UFAL (*Campus* Arapiraca).
Referências: f. 8.

1. Aprendizado profundo. 2. Detecção nodular. 3. Principal Component Analysis (PCA). I. Cavalcante, Rodolfo Carneiro. II. Título.

CDU 004

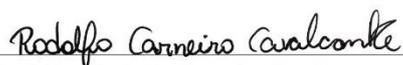
Émerson José da Silva

Técnica de redes neurais convolucionais para identificação de nódulos pulmonares

Trabalho de Conclusão de Curso (Artigo Científico) apresentado ao Curso de Ciência da Computação da Universidade Federal de Alagoas - UFAL, *Campus* de Arapiraca, como requisito parcial para obtenção do Grau de Bacharel em Ciência da Computação.

Data de Aprovação: 05/11/2019

Banca Examinadora



Prof. Dr. Rodolfo Carneiro Cavalcante
Universidade Federal de Alagoas
Campus Arapiraca
(Orientador)



Prof. Dr. Elthon Alex da Silva Oliveira
Universidade Federal de Alagoas
Campus Arapiraca
(Examinador)



Prof. Dr. Tácito Trindade de Araújo Tiburtino Neves
Universidade Federal de Alagoas
Campus Arapiraca
(Examinador)

TÉCNICAS DE REDES NEURAI CONVOLUCIONAIS PARA IDENTIFICAÇÃO DE NÓDULOS PULMONARES

CONVOLUTIONAL NEURAL NETWORKS TECHNIQUES FOR IDENTIFICATION OF PULMONARY NODULES

Émerson José da Silva ¹
Rodolfo Carneiro Cavalcante ²

RESUMO: O câncer de pulmão é o tipo de câncer que mais causa mortes no mundo e sua principal manifestação ocorre devido ao aparecimento de lesões no tecido pulmonar. Dada a sua taxa de mortalidade, é muito importante que esse tipo de câncer seja identificado e diagnosticado o mais rápido possível. Esse diagnóstico tipicamente é realizado por especialistas através da análise de imagens de tomografia computadorizada (TC) do tórax do paciente. A maior dificuldade nesta tarefa está em distinguir nódulos verdadeiros de outras estruturas pulmonares do parênquima, ou de outros órgãos e tecidos. Aliado a isso, aspectos humanos podem interferir da identificação dos nódulos por parte dos especialistas, como cansaço, pressa ou outros fatores psicológicos. Neste contexto, algoritmos e técnicas de visão computacional podem ser capazes de auxiliar na identificação e diagnóstico de nódulos em imagens de TC. Atualmente, algumas técnicas de aprendizado de máquina, como o aprendizado profundo (*deep learning*) têm sido aplicadas com relativo sucesso em tarefas de análise de imagens médicas e auxílio ao diagnóstico. Tais técnicas são capazes de avaliar vários aspectos da imagem sem a interferência de fatores humanos. Este projeto tem como objetivo principal o desenvolvimento de técnicas computacionais que assistam um médico no processo de detecção de nódulos pulmonares em imagens de TC. O estudo consistirá em: (i) da coleta de imagens de TC já previamente rotuladas com a presença ou ausência de nódulos pulmonares por especialistas; (ii) do estudo e aplicação de técnicas de visão computacional e aprendizado de máquina profundo a fim de detectar de forma automática possíveis nódulos presentes nas imagens; (iii) análises quantitativas relativas à acurácia dos métodos desenvolvidos. Espera-se com esse projeto que uma técnica automática de identificação de nódulos pulmonares seja desenvolvida para auxiliar um especialista ou um sistema automatizado de classificação no posterior diagnóstico dos nódulos identificados em maligno ou benigno.

Palavras-Chave: aprendizado profundo; pca (*principal component analysis*); detecção nodular.

ABSTRACT: Lung cancer is the type of cancer that causes the most deaths in the world and its main manifestation occurs due to the appearance of lesions in the lung tissue. Given its mortality rate, it is very important that this type of cancer is identified and diagnosed as soon as possible. This diagnosis is typically made by specialists through the analysis of computed tomography (CT) images of the patient's chest. The greatest difficulty in this task is in distinguishing true nodules from other pulmonary structures in the parenchyma, or from other organs and tissues. Allied to this, human aspects can interfere with the identification of nodules by specialists, such as tiredness, haste or other psychological factors. In this context, algorithms and computer vision techniques may be able to assist in the identification and diagnosis of nodules in CT images. Currently, some machine learning techniques, such as deep learning,

¹ Graduando em Bacharelado em Ciência da Computação pela Universidade Federal de Alagoas – Campus Arapiraca. E-mail: emersonjose877@gmail.com

² Professor Dr. em Ciência da Computação pela Universidade Federal de Alagoas – Campus Arapiraca. E-mail: rodolfo.cavalcante@arapiraca.ufal.br

have been applied with relative success in medical image analysis and diagnostic aid tasks. Such techniques are capable of evaluating various aspects of the image without the interference of human factors. The main objective of this project is the development of computational techniques that assist a doctor in the process of detecting pulmonary nodules on CT images. The study will consist of: (i) the collection of CT images previously labeled with the presence or absence of pulmonary nodules by specialists; (ii) the study and application of computer vision and deep learning techniques in order to automatically detect possible nodules present in the images; (iii) quantitative analyzes related to the accuracy of the developed methods. It is expected with this project that an automatic technique for the identification of pulmonary nodules will be developed to assist a specialist or an automated classification system in the subsequent diagnosis of nodules as malignant or benign.

Keywords: deep learning; pca (*principal component analysis*); nodule detection

1 INTRODUÇÃO E OBJETIVOS

O câncer de pulmão é o tipo de câncer que mais causa mortes no mundo e sua principal manifestação ocorre devido ao aparecimento de lesões no tecido pulmonar. Desta forma a nossa pesquisa propõe o desenvolvimento de um sistema capaz de identificar regiões com nódulos pulmonares com o auxílio de técnicas de Aprendizado Profundo.

O objetivo geral desse projeto é desenvolver um método computadorizado automático para detecção de nódulos pulmonares em imagens de tomografia computadorizada da região torácica do paciente. A saída produzida pelo método consiste na indicação da localização da região da imagem que contém um nódulo, caso exista, para posterior diagnóstico por um especialista ou um sistema de auxílio ao diagnóstico (do inglês *computer-aided diagnosis*, CAD). Os objetivos específicos do projeto são:

Objetivo 1: Estudo e aplicação de métodos de pré-processamento sobre as imagens de tomografia computadorizada (TC), a fim de obter uma melhoria da qualidade da imagem e acentuação dos seus objetos de interesse para facilitar o processo de detecção de tais objetos;

Objetivo 2: Estudo dos métodos de aprendizado profundo, com foco em redes neurais convolucionais de duas dimensões.

Objetivo 3: Implementação, treino, validação e teste do modelo de identificação de nódulos pulmonares na base pública de imagens de TC do *Lung Nodule Analysis 2016* (LUNA16).

Objetivo 4: Estudo e implementação de técnicas de transferência de aprendizado para que o método desenvolvido possa ser aplicado em cenários reais. Além do citado, pretende-se formar recursos humanos de alto nível por intermédio da orientação de alunos de graduação, bem como consolidar um grupo de pesquisa em visão computacional e aprendizado de máquina no estado de Alagoas e integrá-lo com outros grupos do Brasil e do exterior, contando com a colaboração tanto de jovens pesquisadores quanto de pesquisadores de reconhecida produtividade.

2 METODOLOGIA

Com a finalidade de diminuição do espaço de busca, a eliminação de regiões ou tecidos irrelevantes para a detecção dos nódulos (parte externa ao parênquima pulmonar) usamos da U-Net (RONNEBERGER, 2015, p. 234-241) para extração de tais regiões. A U-Net é uma rede convolucional para segmentação de imagens biomédicas, e para poder usá-la, além das imagens originais, é necessário prover a máscara da região a ser treinada. A máscara consiste na

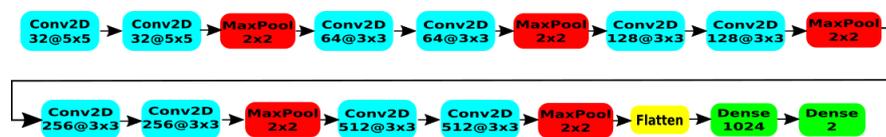
substituição do valor real dos pixels pela sua classe, também conhecido como segmentação semântica. Nesse contexto queremos identificar apenas a região pulmonar interna ao parênquima, logo será um problema binário (região externa e interna ao parênquima).

A base de dados usada, o LUNA16 (Lung Nodule Analysis 2016), não disponibiliza a segmentação do parênquima, dados isso, utilizamos como abordagem, a segmentação manual de uma amostra de 1000 imagens apenas para o treinamento da U-Net. Com o treinamento obtivemos uma acurácia de 98.8% na sobreposição dos pixels na segmentação da região do parênquima. Com o modelo treinado foi realizada uma seleção em toda a base de dados, por exames que possuíam ao menos uma imagem com nódulo, que posteriormente foram usadas para a extração do parênquima e criação de patches (pedaços).

Devido às dimensões dos nódulos (maior ou igual que 3 mm), utilizamos como abordagem a divisão em grid da imagem, com regiões de dimensão (patch) 64 x 64 pixels, e foram selecionados apenas os patches que fazem parte da região pulmonar interna e usá-los como entrada para uma CNN que irá prever a probabilidade de existir nódulo no patch em questão. Ocorre uma intersecção da máscara gerada pela U-Net e esse grid, para a diminuição tanto da região de busca quanto da possibilidade de *overfitting*. Para fins de balanceamento, foram selecionados o mesmo número de patches que não possuem nódulo, juntamente com os restantes que possuem nódulos.

Criamos uma rede neural convolutiva para a análise da probabilidade de existência de nódulo para cada patch da imagem. A arquitetura da CNN se deu por empirismo, e ela é mostrada na Figura 1:

Figura 1 - Arquitetura da CNN



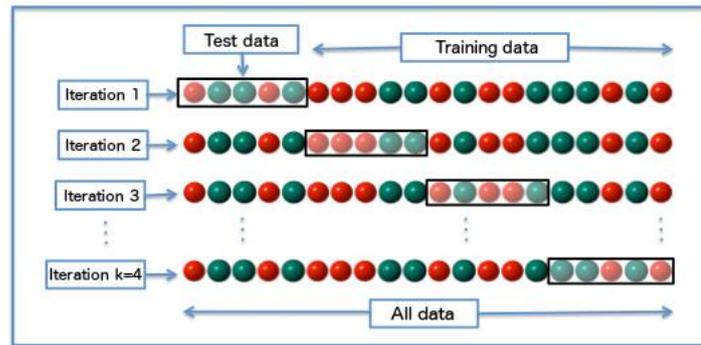
Fonte: O autor (2019).

Em todas as camadas de convolução foi usado ReLU como função de ativação e sem *padding*, nas camadas de *MaxPooling* foi usado *stride* de 2 x 2. Na primeira camada densa foi usado ReLU como função de ativação, entre ela a próxima camada foi usado uma camada de *Dropout* com a probabilidade de 25% de permanência dos neurônios, e na última camada densa foi usado *softmax* para previsão da probabilidade de existência de nódulo.

O processo de *Data Augmentation* foi realizado nos patches que contêm nódulo em duas vertentes, uma simples: rotacionando cada em 90°, 180° e 270°, assim resultando em um número de patches 6776 com nódulo. E outra usando GAN (*Generative Adversarial Networks*), sendo que GANs tem a capacidade de gerar qualquer quantidade de imagens artificiais após treinada, assim geramos a mesma quantidade que foi gerada com a simples rotação dos patches, para a consistência do experimento.

Com relação à metodologia dos testes, foi realizado *10-Fold validation*, como mostrado na Figura 4, é uma técnica que divide toda a base de dados em K grupos, geralmente com a mesma quantidade de instâncias, e a cada iteração um grupo é escolhido como conjunto de validação ou teste e o restante como conjunto de treinamento.

Figura 2 - Modelo representativo do *k-Fold validation*.



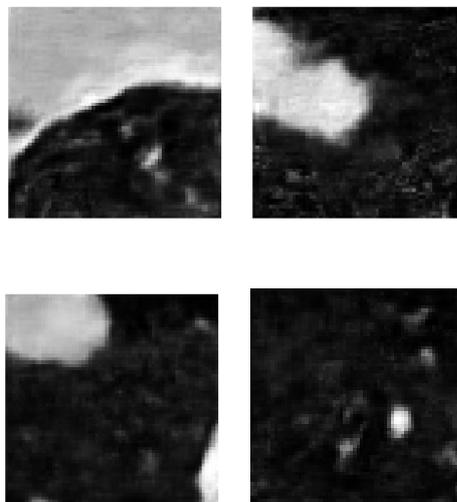
Fonte: WIKIPEDIA FOUNDATION (2019).

3 RESULTADOS E DISCUSSÕES

Nos experimentos foi usado como base de dados o LUNA16, e a acurácia como métrica de desempenho, que é a razão da soma de todos os casos de predições corretas pelo número total de predições, como parâmetros de treinamento da CNN foi usado o *Adam* como algoritmo de otimização, com uma taxa de aprendizado fixo de $10e-5$, entropia-cruzada binária como função de erro e *batch size* de tamanho 20 e sendo executado 300 iterações para cada *fold*.

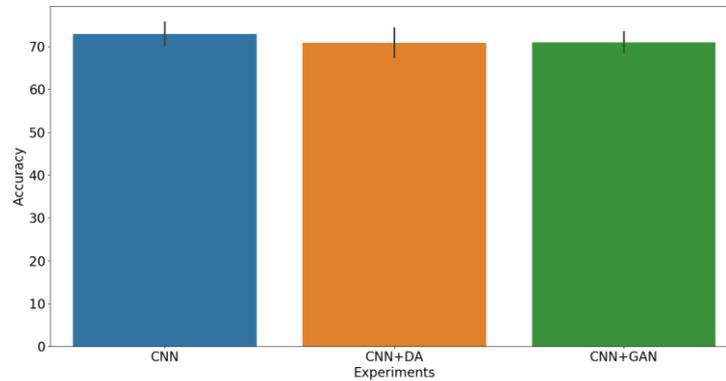
Na figura 5 mostra os experimentos ocorridos com a CNN da Figura 1, pode-se analisar que mesmo com um aumento da base dados com DA (*Data Augmentation*) simples, que consiste apenas em rotacionar o patch, não se conseguiu uma melhora na acurácia, isso ocorre devido à características redundantes extraídas pela CNN, e mesmo com um aumento de exemplos para treinamento não foi possível uma melhora. Mesmo com o crescimento da base de dados tanto artificialmente com GANs, em específico uma arquitetura conhecida como DCGAN (RADFORD, 2015), não resultou em um aumento da acurácia, devido à qualidade das imagens artificiais geradas tendo uma presença alta de ruído em algumas dessas imagens, como é mostrado na Figura 3.

Figura 3 - Imagens artificialmente geradas pela DCGAN



Fonte: O autor (2019)

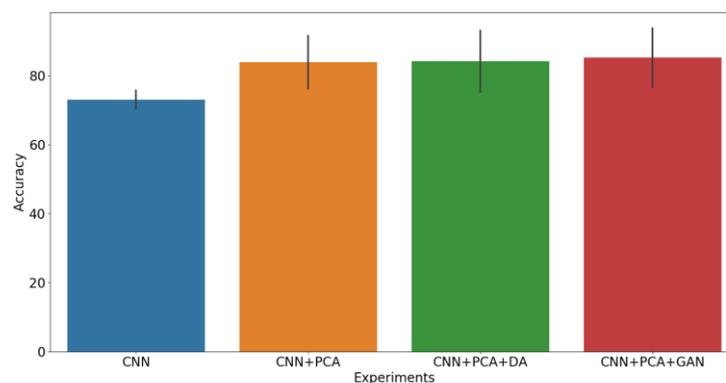
Figura 5 - Resultados dos experimentos com CNN



Fonte: O autor (2019).

Foi realizado a aplicação do PCA (*Principal Component Analysis*), uma técnica clássica de redução de dimensionalidade, que também foi usado por Chen (2014, p. 2094-2107) juntamente com técnicas de Aprendizado Profundo. Analisando comparativamente a aplicação do PCA com a CNN, como mostrado na Figura 6, percebe-se que com a simples aplicação do PCA sem DA já se obtém um aumento considerável da acurácia, aproximadamente 10% de diferença, que foi possibilitada pela eliminação de características redundantes ou baixa relevância pelo PCA. Novamente com a aplicação de DA e GAN para o aumento da base dados usando PCA, não se notou um aumento considerável na acurácia, apenas 1% aproximadamente, para cada caso respectivamente. As causas desse comportamento são a qualidade das imagens geradas pela GAN e um número de imagens não suficiente para um aumento considerável da acurácia no caso da DA simples.

Figura 6 - Resultados dos experimentos com PCA



Fonte: O autor (2019).

4 CONCLUSÕES

Mesmo o nosso método não superando a acurácia do estado-da-arte em identificação de nódulos pulmonares, obtivemos resultados que demonstram que a aplicação de método clássicos de redução de dimensionalidade (PCA) pode contribuir consideravelmente para a

performance de um modelo de Aprendizado Profundo. Além de trabalharmos com imagens 2D, o que torna mais complicado a identificação dos nódulos, mas em compensação ganha-se velocidade na identificação em um contexto prático com relação à imagens 3D. Também deve se destacar o fato de que não foi usado nenhuma técnica de Processamento de imagens em todo o processo, exceto pelo janelamento, que é uma prática quase unânime em imagens médicas para o realce de tecidos ou estruturas morfológicas

Como alternativas para trabalhos futuros, a aplicação de técnicas de Processamento de Imagens pode vir a melhorar o desempenho do modelo, o uso de outras métricas para análise de desempenho como o F1-score e sensibilidade podem dar uma visão maior da performance. Com relação a técnicas de Aprendizado Profundo, pode-se aplicar *Autoencoders* como alternativa à CNN e o PCA, e outras técnicas de aumento artificial de base dados (*Data Augmentation*) que possibilitem a geração de imagens com melhor qualidade.

REFERÊNCIAS

CHEN, Yushi *et al.* Deep learning-based classification of hyperspectral data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 6, p. 2094-2107, 2014.

LUNG Nodule Analysis 2016. **Grand Challenge**, 2016. Disponível em: <https://luna16.grand-challenge.org/>. Acesso em: 12 ago. 2019.

RADFORD, Alec; METZ, Luke; CHINTALA, Soumith. Unsupervised representation learning with deep convolutional generative adversarial networks. **arXiv**, 7 jan. 2015. Disponível em: <https://arxiv.org/abs/1511.06434>. Acesso em: 13 ago. 2019.

RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-net: convolutional networks for biomedical image segmentation. *In: INTERNATIONAL CONFERENCE ON MEDICAL IMAGE COMPUTING AND COMPUTER-ASSISTED INTERVENTION*, 18., 2015, Munique. **Proceedings** [...]. Munich: Springer, 2015. p. 234-241.

WIKIPEDIA FOUNDATION. Diagram of K-Fold cross-validation with k=4. San Francisco, EUA: Wikipédia Foundation, 2019. Disponível em: [https://en.wikipedia.org/wiki/Cross-validation_\(statistics\)#/media/File:K-fold_cross_validation_EN.jpg](https://en.wikipedia.org/wiki/Cross-validation_(statistics)#/media/File:K-fold_cross_validation_EN.jpg). Acesso em: 13 ago. 2019.

AGRADECIMENTOS

Lembre-se de olhar para as estrelas e não para os seus pés. Tente entender o que você vê e se pergunte sobre o que faz o universo existir. Ser curioso. E por mais difícil que a vida possa parecer, sempre há algo que você pode fazer e ter sucesso.
Stephen Hawking

Quero agradecer aos meus pais, Eliege e Edimilson, que sempre me fortaleceram nessa jornada e pelos sacrifícios feitos por ambos, desde a minha infância até hoje, para a realização do meu sonho da graduação, na área que tanto amo. E também toda a minha família que esteve sempre do meu lado e me ajudou quando mais precisei, tanto financeiramente quanto psicologicamente.

Ao professor Rodolfo, pelo grande mentor que foi, não somente na graduação, mas como inspiração para a vida. Ao professor Thiago, pela minha primeira oportunidade de atuar profissionalmente. Também a todo o corpo docente que faz manter a excelência desse curso.

Com grande carinho a pessoa que me fez ver com outros olhos as tecnologias e suas aplicações, um grande mentor, parceiro e conselheiro: Luís Eduardo. Também aos amigos que conheci durante todo esse percurso, que sempre me escutavam quando eu precisava desabafar, e pelas risadas que compartilhamos: Gabriel, Gilvo, Karlisson, Bruno e Gerson. Aos companheiros do LICA e dos outros laboratórios do NCex: Jadson, Francisco, Lucas, João Gabriel, Roque, João Vitor, Igor, Matheus e Wellington. E a todos os outros, que de alguma forma, marcaram presença nessa história. Essa vitória não é só minha, mas também de todos vocês que ajudaram em tornar ela real.