

# Aprendizado Profundo para a classificação de blocos de tecidos pulmonares em imagens de Tomografia Computadorizada de Alta Resolução

Aline Dartora<sup>1</sup>, Lucas Ferrari de Oliveira<sup>1</sup>

<sup>1</sup>Laboratório de Visão, Robótica e Imagem (VRI)  
Programa de Pós-Graduação em Informática (PPGInf)  
Universidade Federal do Paraná (UFPR)  
Curitiba - PR, Brasil

dartoraline@gmail.com.br, lferrari@inf.ufpr.br

**Resumo.** Doenças pulmonares intersticiais (DPI) envolvem vários padrões de imagem anormais observados em exames de tomografia computadorizada de alta resolução. A caracterização automatizada de tecidos é um componente essencial de um sistema de auxílio ao diagnóstico por computador deste tipo de doença. As redes neurais convolucionais profundas aprendem características diretamente dos dados de treinamento em vez de extraí-los manualmente evitando a necessidade de otimização de extratores de características. Nesse contexto, o presente trabalho busca investigar um método de classificação utilizando aprendizado profundo para melhorar o desempenho de sistemas CAD no diagnóstico de DPIs. Resultados preliminares atingiram uma taxa de reconhecimento geral de 74,9% na classificação das cinco classes de DPIs em estudo.

**Palavras-chave:** Tomografia computadorizada de alta resolução (TCAR). Doença Pulmonar Intersticial (DPIs). Classificação de Tecido. Redes Neurais. Aprendizado profundo.

**Abstract.** Interstitial lung disease (ILD) involves several imaging patterns that are observed in high resolution computed tomography (HRCT). The automated tissue characterization is an essential component of a computer aided diagnostic (CAD) system for ILD research. Deep convolutional neural networks learns features directly from training data rather than extracting them manually, avoiding the need for feature extractor optimization. In this context, the present work investigate about a classification method using a deep learning program, in order to improve the performance of CAD systems for the diagnosis of ILDs. Preliminary results achieved a general recognition rate of 74.9 % in the classification of the five classes of ILD refered in this study.

**Keywords:** High-resolution computed tomography (HRCT). Interstitial Lung Diseases (ILDs). Tissue classification. Neural networks. Deep-learning.

## 1. Introdução

A classificação de padrões de tecidos pulmonares em imagens de tomografia computadorizada de alta resolução (TCAR) é significativa para a prática clínica, porém, é uma tarefa difícil quando envolve padrões anormais de doenças graves. A partir de uma

boa predição de tecidos pulmonares é possível utilizá-la como uma etapa do desenvolvimento de sistemas de auxílio ao diagnóstico (CAD) aumentando a precisão diagnóstica [A. Depeursinge 2011].

Recentemente, os trabalhos do estado da arte apresentam técnicas utilizando algoritmos para predizer os diferentes padrões radiológicos de forma automática em vez de aprendê-los manualmente [Gao and et al. 2015]. A partir de tais observações, o presente trabalho propõe explorar os métodos de classificação para a predição dos padrões radiológicos utilizando um modelo de arquitetura profunda conhecido como Rede Neural Convolutiva (CNN). As arquiteturas de CNNs são projetadas para reconhecer padrões diretamente a partir dos pixels das imagens, incorporando a extração de características e a classificação [Lecun et al. 2015].

## **2. Metodologia**

### **3. Base de Imagens**

A realização deste trabalho tem como referência uma base de imagens pública com casos de Doenças Pulmonares Difusas (DPDs) cedida por [A. Depeursinge 2011] que contém imagens de TCAR com uma espessura de corte de 1 mm. A base é composta por conjuntos de TCAR com casos de doenças pulmonares de 113 pacientes.

Uma segunda base de imagens extraída da base citada anteriormente e disponibilizada por [Bagesteiro 2015], foi utilizada neste trabalho. Essa base é composta por blocos de imagens com meia-sobreposição no eixo x e y de  $32 \times 32$  pixels que contém pelo menos 75% dos pixels pertencente ao padrão da ROI. A base citada contém 20540 blocos de imagens de 90 pacientes que estão rotulados em 6 classes que são: não pulmão (NP), normal (N), enfisema (E), vidro-fosco (GG), fibrose (F) e micronódulos (M). No presente trabalho foi removida a classe não-pulmão (3.000 blocos) para que fosse possível a comparação dos resultados com a literatura existente.

## **4. Pré-Processamento**


### **4.1. Produção de Dados sintéticos**

Inicialmente, todas as imagens em formato DICOM foram convertidas para o formato PNG de modo que as amostras fossem compatíveis com a entrada do classificador utilizado. No momento da conversão 688 imagens das classes normal, fibrose e micronódulos foram corrompidas, não sendo possível recuperá-las, o que resultou na redução do número de pacientes. A distribuição das classes por base de imagem é mostrada na Tabela 1. Para corrigir o desbalanceamento das classes nos blocos de imagens e também para suprir a necessidade de uma base de dados maior para o aprendizado da rede, foi necessário a criação de dados sintéticos. Para isso, foi utilizada a técnica de geração de dados sintéticos que consiste na ampliação, de forma artificial, do número de amostras originais [Krizhevsky et al. 2012].


A técnica consiste em aplicar filtros de transformações geométricas nas imagens [Krizhevsky et al. 2012]. Os filtros utilizados foram os de rotação (ângulos:  $90^\circ$ ,  $180^\circ$  e  $270^\circ$ ), espelhamento (horizontal e vertical) e a combinação deles. Justifica-se o uso destes filtros por eles não causarem alterações na textura das imagens devido ao problema estudado ser centrado na classificação de textura.

	N	E	GG	F	M	Total	Nº Pacientes
Base Original (DICOM)	5733	1017	1942	2736	6112	17540	90
Base Aumentada (PNG)	17121	15255	17478	16164	16476	82494	88

Cada filtro é aplicado sobre as imagens originais de acordo com a classe, de modo que todas as classes atinjam um tamanho semelhante ao conjunto de imagens da classe menos rara. Abaixo é mostrado um exemplo da ampliação de uma amostra (Figura 1) em outras 4 amostras (Figura 2) após aplicação da técnica de geração de dados artificiais.



**Figura 1. Bloco Original**



**Figura 2. Blocos resultantes da geração de dados sintéticos**

#### 4.2. Rede Neural Convolutacional - CNN

Foi projetada uma estrutura de aprendizado de máquina neural automática para extrair características discriminantes de amostras de treinamento e executar classificação ao mesmo tempo [Lecun et al. 2015]. A Rede Neural Convolutacional (CNN) foi construída por meio do *framework* Caffe na linguagem Python.

Para o uso da CNN foi dividido em conjuntos de pacientes para compor os grupos de treinamento, teste e validação, garantindo que as imagens de um mesmo paciente não pertencessem ao mesmo grupo. Foram selecionadas aproximadamente 70% das imagens para treinamento, 20% para teste e 10% para validação (Tabela 2).

	Treino	Teste	Validação	Total
Imagens	56943	17079	8472	82494

A arquitetura base utilizada foi a LeNet-5 e baseando-se nesta arquitetura foram variados os parâmetros de *learning rate*, número de neurônios, número de camadas convolucionais, número de *pooling*, número filtros, tamanho do kernel e stride. Os parâmetros definidos foram escolhidos de acordo com estudos anteriores de CNN [Hafemann et al. 2014] que tiveram bons resultados para a classificação de textura em outros contextos, os quais, foram ajustados por meio de testes empíricos para a problemática apresentada.

A arquitetura construída consiste nas seguintes camadas, com os seguintes parâmetros:

- Camada de entrada: parâmetros de acordo com a resolução da imagem de  $32 \times 32$  pixels;
- Duas combinações de camadas convolucionais e de *pooling*: cada camada convolutacional com 64 filtros, com tamanho de filtro definido para cada problema e *stride* definido igual a 1. O *pooling* possui 34 filtros de tamanho  $3 \times 3$  e *stride* 2;

- Duas camadas localmente conectadas: 32 filtros de tamanho  $3 \times 3$  e *stride* igual a 1;
- Camada de saída altamente conectada com 5 saídas equivalente ao número de classes do problema.

## 5. Resultados Parciais

Os experimentos foram conduzidos de acordo com a metodologia apresentada na seção anterior. Os resultados obtidos foram calculados por meio de uma matriz de confusão e são apresentados na tabela 3.

**Tabela 3. Matriz de Confusão**

	C1	C2	C3	C4	C5
C1	<b>74,40%</b>	3,18%	7,11%	5,96%	9,32%
C2	21,05%	<b>76,26%</b>	0,00%	0,67%	2,02%
C3	0,03%	0,03%	<b>90,39%</b>	7,24%	0,05%
C4	2,81%	5,56%	6,17%	<b>81,17%</b>	4,29%
C5	25,53%	22,06%	0,00%	0,06%	<b>52,34%</b>

## 6. Considerações Finais e Próximos Passos

Neste trabalho foram classificadas cinco classes de DPIs atingindo-se uma taxa de reconhecimento geral de 74,9%. A taxa de reconhecimento obtida ainda é menor que o estado da arte sendo necessário revisar a construção da arquitetura da rede neural proposta. Além disso, as confusões observadas na matriz de confusão podem estar relacionadas com a dificuldade de classificação devido a aparência similar dos diferentes padrões. Outro fator, influenciador na baixa acurácia de classificação, talvez ainda se dê pela pouca quantidade de imagens em comparação com a quantidade de amostras normalmente usada nos trabalhos de redes neurais. Como continuação deste trabalho, será aprofundado o estudo sobre redes neurais complexas buscando eliminar a tarefa de seleção de regiões de interesse em imagens radiológicas.

## Referências

- A. Depeursinge, A. Vargas, A. P. e. a. (2011). *Building a reference multimedia database for interstitial lung diseases*. Computerized Medical Imaging and Graphics.
- Bagesteiro, L. D. (2015). *Classificação de Padrões Radiológicos por Blocos em Imagens não Segmentadas de Tomografia Computadorizada*. Universidade Federal do Paraná.
- Gao, M. and et al. (2015). Holistic Classification of CT Attenuation Patterns for Interstitial Lung Diseases via Deep Convolutional Neural Networks. *Workshop on Deep Learning in Medical Image Analysis (MICCAI)*.
- Hafemann, L. G., Oliveira, L. S., and Cavalin, P. R. (2014). An analysis of deep neural networks for texture classification.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances In Neural Information Processing Systems*, pages 1–9.
- Lecun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(1):436–444.