

## SEGMENTAÇÃO POR BLOCOS EM IMAGENS MÉDICAS UTILIZANDO EXTRATORES DE CARACTERÍSTICAS

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

<sup>1</sup>Departamento de Informática/Universidade Federal do Paraná (UFPR), Curitiba, Brasil.

**Resumo:** Com uma boa técnica de segmentação é possível aumentar a acurácia diagnóstica em sistemas de auxílio ao diagnóstico. Objetivo: Este trabalho tem como objetivo propor uma metodologia de segmentação por blocos em imagens de Tomografia de pulmão por meio de extratores de características, utilizando duas classes para a classificação, pulmão e não-pulmão. Métodos: Os extratores testados foram *Local Binary Pattern (LBP)*, *Completed Local Binary Pattern (CLBP)*, Matriz de coocorrência de níveis de cinza (GLCM), Momentos do Histograma, Histograma de níveis de cinza e Transformação *Top-hat*. Foi utilizada uma Máquina de Vetor de Suporte e a validação cruzada *leave-one-patient-out*. Resultados e Conclusão: A melhor classificação entre as duas classes foi obtida com os métodos de *Top-hat* e Histograma com uma acurácia de 98,25% e 98,16%, respectivamente, mostrando uma maior taxa de acerto em relação a literatura existente.

**Palavras-chave:** Tomografia Computadorizada. Doenças Pulmonares Intersticiais. Projeto Auxiliado por Computador.

**Abstract:** *With an effective technique of segmentation it is possible to increase the diagnostic accuracy in computer-aided diagnostic systems. Objectives: This paper proposes a method to evaluate the features extractors used in the pattern classification of lung tissue. Method: The features descriptors used were the Local Binary Pattern (LBP), Completed Local Binary Pattern (CLBP), Gray-Level Co-Occurrence Matrix (GLCM), Histogram Moments, Gray Level Histogram and Top-hat Transformation. The pattern classification was performed using support vector machines (SVM) and a cross validation leave-one-patient out approach. Results and Conclusion: The best lung tissue classification was obtained combining the top-hat and histogram methods, with an accuracy of 98.26% and 98.16% respectively, that represent higher accuracy when compared with the current literature.*

**Keywords:** *Computed Tomography. Lung Diseases. Computer-Aided Design.*

**Resumen:** *Con una buena segmentación técnica es posible aumentar la exactitud diagnóstica de la ayuda a los sistemas de diagnóstico. Objetivos: Este trabajo tiene como objetivo proponer una metodología de segmentación en bloques de imágenes de tomografía pulmonar a través de extractores de características, utilizando dos clases de clasificación, de pulmón y de no pulmón. Métodos: Los extractores se probaron Local Binary Pattern (LBP), Completed Local Binary Pattern (CLBP), matriz de co-ocurrencia de niveles de gris (GLCM), Histograma Destacados, el Histograma de Niveles de Gris y la transformación de sombrero de copa. Se utilizó una máquina de vectores soporte y validación cruzada leave-one-patient-out. Resultados y Conclusiones: La mejor clasificación entre las dos clases se obtuvo a partir de los métodos de sombrero y de histograma con una precisión de 98.25% y 98.16%, respectivamente, que muestran una tasa de éxito mayor en comparación con la literatura existente.*

**Descriptors:** *Tomografía Computarizada. Enfermedades Pulmonares Intersticiales. Diseño Asistido por Computador.*

### Introdução

Um sistema CAD é composto pelas etapas de pré-processamento, segmentação, extração do candidato, extração de características e classificação. As quatro primeiras fases são consideradas

processamento de imagem e a fase final trabalha com padrões que são representados como pontos em um espaço de características<sup>1</sup>. Neste sistema, o reconhecimento de padrões do pulmão em imagens de Tomografia Computadorizada de Alta Resolução (TCAR) é um pré-requisito para o diagnóstico de Doenças Pulmonares Intersticiais (DPIs).

Nesse contexto, o presente trabalho propõem um método de segmentação em blocos por meio de uma análise completa sobre a predição de padrões com diferentes métodos de extração de características. Esta proposta dentro de um sistema computacional visa delimitar as regiões de interesse para as próximas etapas (extração de características e classificação) de um sistema CAD que irá classificar padrões de doenças pulmonares em imagens de TCAR.

### Trabalhos Relacionados

Vários estudos foram feitos para a classificação de padrões em imagens de tecido pulmonar associadas com DPIs<sup>2</sup>. Porém, em nenhum deles a classificação de tecidos pulmonares e não pulmonares para segmentação foi testada, com isso a comparação não pode ser feita de forma direta, pois os escopos são diferentes. Os artigos utilizam a mesma base de imagens deste trabalho<sup>3-7</sup>, porém classificam somente tecidos pulmonares (saudável, enfisema, vidro fosco, fibrose e micronódulos). Os trabalhos (8-15) utilizaram outras bases de imagens, mas são relacionadas a segmentação pulmonar ou a predição de padrões para o desenvolvimento de sistemas CAD, estes trabalhos são listados a seguir.

O primeiro estudo correlacionado com o problema de identificação de padrões pulmonares é o trabalho de (8). Os autores propuseram um método de segmentação pulmonar patológica que leva em conta os vizinhos e gera um sistema de reconhecimento de patologias. Nele foi extraído o parênquima pulmonar da imagem e em seguida foi estimado o volume do pulmão usando informações torácicas. Os extratores de características utilizados foram o Comprimento de Primitiva a Nível de Cinza (GLRLM), a matriz de coocorrência de níveis de cinza (GLCM) e na classificação de padrões foi escolhida a técnica de floresta aleatória. A base de exames utilizada consiste em mais de 400 imagens de TC. Os resultados quantitativos obtidos melhoram a identificação dos padrões devido a sua alta sensibilidade e especificidade.

O trabalho realizado por (9) também aborda o problema de segmentação dos pulmões em tomografias. Nesta pesquisa foi utilizada uma floresta contexto decisão seletiva *Context Selective Decision Forest - CSDF* como um novo classificador discriminativo. Primeiramente foi selecionado o contexto usado para cada órgão e depois adicionados seletivamente rótulos para os dados de treinamento de modo que o classificador aprenda uma aparência distinta e o modelo de localização espacial para cada classe. Essa técnica foi aplicada usando uma base de dados rotulados de 110 pacientes, e outra base de dados de 55 indivíduos com diferentes patologias. O resultado atingido foi de 94% de acerto.

Já na publicação de (10) é proposto um método de classificação usando o *context-sensitive SVM* de aprendizado automático de características. O autor propõe uma técnica de aprendizagem não-supervisionada para construir seu próprio extrator de características por meio de uma rede neural multiescala denominada Gaussiana RBM. O vetor obtido é classificado em 5 categorias empregando o SVM atingindo uma acurácia de 89,68%.

No artigo de (11) foram classificados os padrões normal, enfisema, vidro-fosco, faveolamento, opacidade reticular e consolidação por meio de máquinas de vetores de suporte com arquitetura de árvore binária. Para a extração de características o autor utilizou histograma, gradiente, matriz de comprimento, GLCM, transformação *top-hat* e análise de agrupamentos. A base de imagens foi composta por 600 ROIs e o resultado geral obtido na classificação foi de 92,63%.

Por último, no trabalho de (12), é feita a classificação de cinco categorias de tecidos pulmonares com base em recursos de *image patch approximation*. Os extratores de características utilizados foram os padrões binários locais de Gabor invariantes a rotação (*Rotation-invariant Gabor-Local Binary Patterns - RGLBP*), descritor de textura, e o *multi-coordinate histogram of oriented gradients* (MCHOG) descritor de gradiente e multi coordenadas. A classificação dos diferentes padrões foi

baseada em estimativas probabilísticas. O método proposto é avaliado numa base de dados acessível ao público, mostrando um desempenho de 82,64% de sensibilidade.

## Métodos

O presente trabalho propõe um método de análise de diversos extratores de características na classificação de imagens de padrões de tecido pulmonar e não pulmonar para uma segmentação em blocos que visa separar a região de tecido pulmonar do restante da imagem.

Dada uma base de imagens com blocos de TCAR do pulmão, a metodologia proposta (Figura 1) primeiro extrai as características da base, em seguida, usa um classificador SVM para distinguir padrões pulmão de não-pulmão, posteriormente, avalia os resultados comparando com a base de máscaras do pulmão já segmentadas o que permite uma segmentação em blocos na imagem original de TCAR de acordo com a saída do classificador.

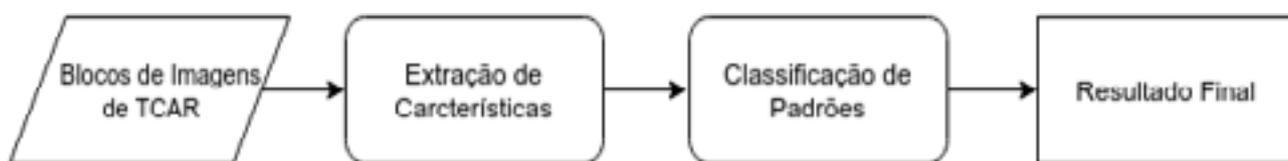


Figura 1: Visão Geral do Método Proposto

### Base de Imagens

Para a realização deste trabalho foi utilizada a base de imagens pública com casos de Doenças Pulmonares Difusas (DPDs) cedida por 13 que contêm imagens de TCAR com uma espessura de corte de 1 mm com casos de doenças pulmonares de 113 pacientes e, cada conjunto possui de 11 a 61 cortes tomográficos. As imagens são disponibilizadas em alta resolução no formato DICOM com tamanho de 512 x 512 *pixels* e cada paciente possui um conjunto de segmentação dos padrões radiológicos encontrados nas imagens.

Destas imagens foram extraídos 16.521 blocos (ROIs - *Region Of Interest*) de tamanho 32x32 com meia sobreposição no eixo x e no eixo y que foram rotulados nas 2 classes estudadas (Figura 2) e pertencem a um conjunto de 103 pacientes. Para ser considerado um bloco válido pelo menos 75% da ROI deveria conter os padrões radiológicos estudados. Dos 16.521 blocos, 2755 pertencem a classe não-pulmão e 13766 pertencem a classe de tecido pulmonar (saudável, enfisema, vidro fosco, fibrose e micronódulos).

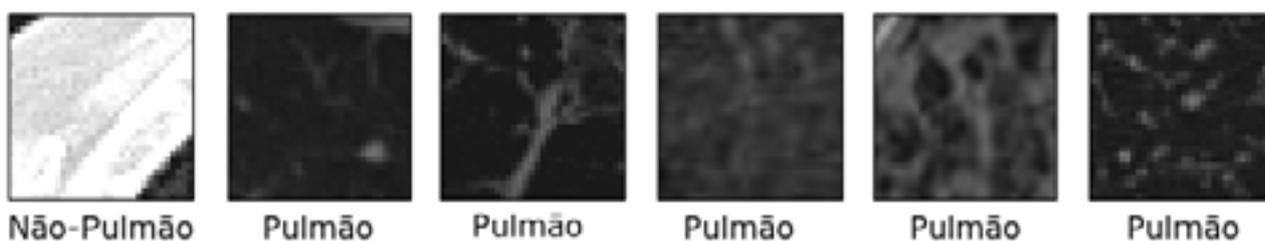


Figura 2: Exemplo de Blocos de Imagem do Pulmão e Não-Pulmão

## Extração de Características

Na etapa de extração de características foram testados seis descritores para verificar qual deles se adaptava melhor ao problema de reconhecimento do padrão pulmão e não-pulmão, sendo eles o LBP, CLBP, GLCM, Momentos de Histograma, Histograma de Níveis de Cinza e Transformação *Top-Hat*.

A quantidade de características provenientes da saída de cada extrator é variada. Na tabela 1 são listadas essas relações para demonstrar a dimensionalidade e o contexto do problema.

Tabela 1: Relação do Descritor, do Número de Características e do Tipo da Característica

Descritor	Número de Características	Tipo de Característica
LBP_u_8_2	59	Textura
LBP_riu_8_2	10	Textura
CLBP_riu_8_2	200	Textura
GLCM	20	Textura
MOM. HISTOGRAMA	4	Textura
HISTOGRAMA	26	Textura
TOP-HAT	4	Forma

Os padrões anormais observados em imagem podem ser analisados com base na forma, textura e informações atenuação vistas em imagens de TC<sup>8, 4-7, 12</sup>. Foram utilizadas duas variações do LBP, o LBP uniforme e o LBP invariante a rotação. Os parâmetros do LBP, número de vizinhos e raio, foram testados com os valores 8 e 2 respectivamente.

As principais preocupações na fase de seleção de características foram manter as informações extraídas associadas ao paciente e fazer a normalização dos dados. Os dados foram transformados para a faixa de valores de [-1, +1].

### Classificação

O classificador *Support Vector Machines* (SVM) que têm sido amplamente aplicado a problemas de classificação padrão e regressões não-lineares<sup>16</sup>. A escolha deste algoritmo foi baseado na comparação de três técnicas de classificação em sistemas CAD do pulmão em que as máquinas de vetor de suporte (SVM) obtiveram o melhor desempenho quando trabalham com textura<sup>16</sup>.

O algoritmo de classificação utilizado foi o SVM, implementado em *Python* com auxílio da ferramenta *Scikit-learn*, o qual é um *framework open-source* de aprendizado de máquina e que utiliza as plataformas *Numpy/Scipy* e *Matplotlib*.

O modelo *leave-one-patient-out* é um caso especial da validação cruzada de *N Folds* onde *N* representa o número de casos e cada bloco consiste no conjunto de todos os exemplos de cada caso individual. Com isso, a separação completa entre o treinamento e a validação é assegurada, e a variabilidade entre pacientes é levada em consideração. Este modelo foi utilizado na metodologia do trabalho, pois ele faz uma avaliação completa sobre a variação do modelo em relação aos dados utilizados, realizando *N* cálculos de erro para cada dado.

Foram testados *N* SVMs, em cada um deles um paciente foi retirado do treinamento e foi testado. Após o término da execução do classificador SVM foram analisados os resultados e identificado qual a melhor predição de acordo com sua taxa de reconhecimento.

## Resultados

As taxas de acerto obtidas na classificação das classes pulmão e não-pulmão deste estudo estão compiladas na Tabela 2, apresentada a seguir.

Tabela 2: Resultado da Classificação do SVM

Descritor	Acurácia
LBP_u_8_2	92,55%
LBP_riu_8_2	86,26%
CLBP_riu_8_2	97,33%
GLCM	81,26%
MOM. HISTOGRAMA	67,44%
HISTOGRAMA	98,18%
TOP-HAT	98,26%

Por meio dos resultados obtidos é possível observar que os extratores histograma e *top-hat* tiveram a taxa de acerto mais alta, ambos acima de 98%.

Para um melhor entendimento das predições dos vetores de características do histograma e do *top-hat*, a Figura 3 apresenta um comparativo da taxa de reconhecimento para cada conjunto de imagens dos pacientes. Pode-se verificar a relação entre a taxa de reconhecimento e cada paciente, os valores estão na faixa de 0.6703 e 1.0, representando em porcentagem uma taxa de acerto de 67% a 100%.

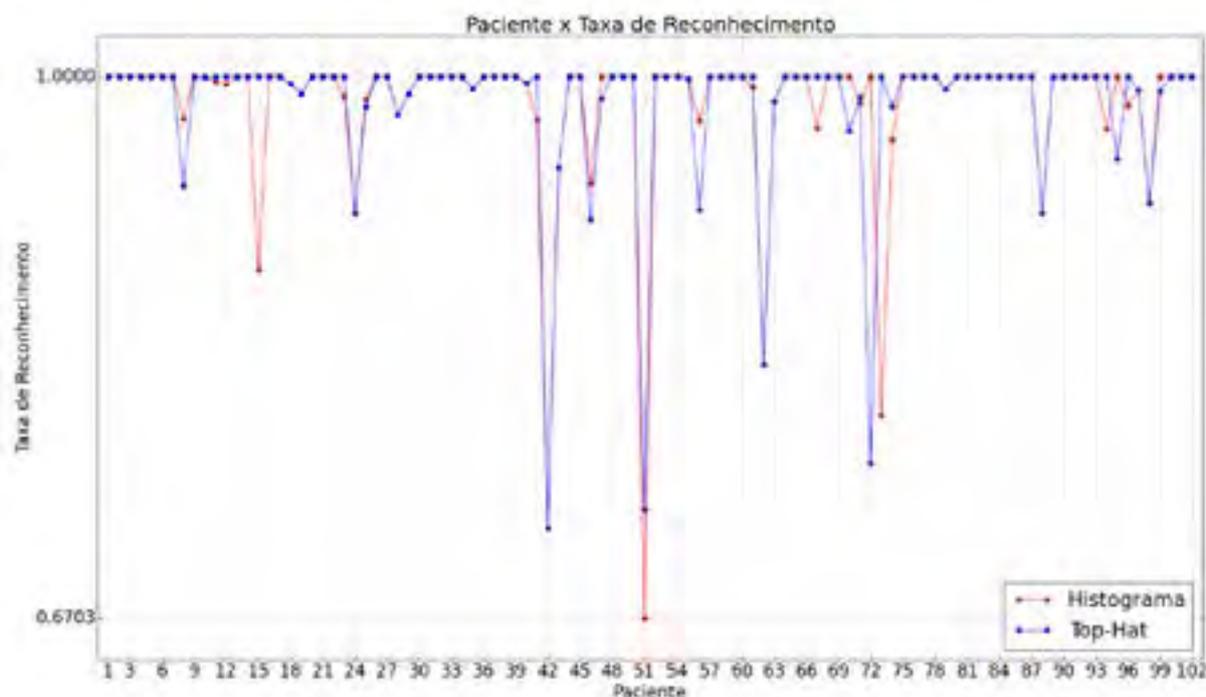


Figura 3: Classificação dos Conjuntos de Imagens por Paciente

## Conclusão

Este estudo buscou diminuir as limitações do uso dos sistemas CAD nos exames de acompanhamento e diagnóstico de doenças. Em uma aplicação CAD, que faz a detecção, classificação e quantificação de DPIs, a segmentação precisa do pulmão é um passo de pré-processamento extremamente importante.

Neste estudo, foi proposto um método de análise de extratores de características para definir quais são as características mais discriminantes na classificação entre tecido pulmonar e outros tipos de tecidos para melhorar os sistemas de auxílio ao diagnóstico de DPIs.

A primeira contribuição do método proposto foi a identificação dos melhores descritores de características para o problema em questão. Outra contribuição deste estudo é a análise dos extratores ser feita por meio de um modelo completo com abordagem *leave-one-patient-out* que está de acordo com a realidade vista na prática clínica onde o diagnóstico não deve depender do conhecimento prévio do histórico clínico do paciente.

Quando comparados os resultados obtidos com a literatura, o presente trabalho mostrou-se uma acurácia maior na classificação dos blocos de imagens. Muito embora, o número de classes utilizadas limita-se somente a pulmão e não-pulmão. Quando aplicada na rotina clínica esta abordagem irá auxiliar na delimitação das regiões de interesse que necessitam ser processadas, sendo essa uma etapa de pré-processamento de extrema importância. A precisão da metodologia em imagens completas segmentadas será feita posteriormente. Também, tamanhos de blocos menores serão testados visando verificar se a precisão com o atual tamanho de 32 x 32 *pixels* se mantém.

## Referências

- [1] Kim TJ, Han DH, Jin KN, Won Lee K. Lung cancer detected at cardiac CT: prevalence, clinico-radiologic features, and importance of full-field-of-view images. *Radiology*. 2010;255(2):369–76.
- [2] Archontogeorgis K, Steiropoulos P, Tzouvelekis A, Nena E, Bouros D. Lung cancer and interstitial lung diseases: a systematic review. *Pulm Med [Internet]*. 2012;2012:315918.
- [3] Depeursinge A, Van De Ville D, Platon A, Geissbuhler A, Poletti P-A, Müller H. Near-Affine-Invariant Texture Learning for Lung Tissue Analysis Using Isotropic Wavelet Frames. *IEEE Trans Inf Technol Biomed*. 2012;16(4).
- [4] Banu SS, Farmhand SS, Prabakaran P, Malathi L. Detection and Classification of Lung Tissue Using Block Based Intensity Features. *J Adv Eng Res*. 2014;1(1):97–101.
- [5] Dash JK, Madhavi V, Mukhopadhyay S, Khandelwal N, Kumar P. Segmentation of interstitial lung disease patterns in HRCT images. *SPIE Med Imaging [Internet]*. 2015;9414:1–6.
- [6] Asherov M, Diamant I, Greenspan H. Lung texture classification using bag of visual words. 2014;9035(Ild):90352K.
- [7] Bagesteiro LD, Oliveira LF, Weingaertner D. Blockwise Classification of Lung Patterns in Unsegmented CT Images. (DId).
- [8] Mansoor A, Bagci U, Xu Z, Foster B, Olivier KN, Elinoff JM, et al. A Generic Approach to Pathological Lung Segmentation. *IEEE Trans Med Imaging*. 2014;33(12).
- [9] Montillo A. Context Selective Decision Forests and their application to Lung Segmentation in CT Images. *MICCAI Work Pulm Image Anal [Internet]*. 2011;
- [10] Q. Li W. Cai DDF. Lung image patch classification with automatic feature learning. 2013.
- [11] Y. Chang J. Lim NK et al. A support vector machine classifier reduces interscanner variation in the HRCT classification of regional disease pattern in diffuse lung disease: Comparison to a Bayesian classifier. 2013.

- [12] Song Y, Cai W, Zhou Y, Feng DD. Feature-based image patch approximation for lung tissue classification. *IEEE Trans Med Imaging*. 2013;32(4):797–808.
- [13] A. Depeursinge A. Vargas AP et al. Building a reference multimedia database for interstitial lung diseases. 2011.
- [14] Fazli S, Jafari M, Safaei A. Automated Lung CT Image Segmentation Using Kernel Mean Shift Analysis. 2013.
- [15] Wang L. Support Vector Machines : Theory and Applications. 2005;
- [16] Yao J, Dwyer A, Summers RM, Mollura DJ. Computer-aided Diagnosis of Pulmonary Infections Using Texture Analysis and Support Vector Machine Classification. *Acad Radiol*. 2011;18(3):306–14.

## **Contatos**

Aline Dartora, Bacharel em Informática  
Biomédica pela Universidade Federal do  
Paraná – UFPR, Curitiba, Paraná, Brasil.  
Email: [adartora@inf.ufpr.br](mailto:adartora@inf.ufpr.br)

### **Autor de contato:**

Lucas Ferrari de Oliveira, Professor Associado  
do Departamento de Informática da  
Universidade Federal do Paraná - DInf/UFPR,  
Curitiba, Paraná, Brasil.  
Email: [lferrari@inf.ufpr.br](mailto:lferrari@inf.ufpr.br)

