

Classificação de Padrões Radiológicos por Blocos em Imagens Não Segmentadas de Tomografia Computadorizada

Aluna: Luiza Dri Bagesteiro

Orientador: Prof. Dr. Daniel Weingaertner

Co-orientador: Prof. Dr. Lucas Ferrari de Oliveira

Sumário

- Introdução
- Achados radiológicos
- Tomografia Computadorizada
- Trabalhos relacionados
- Metodologia
 - Base de imagens
 - Extração dos blocos de imagens
 - Extração de características
 - Classificação
 - Fusão dos classificadores
- Resultados e discussão
- Considerações finais
- Trabalhos futuros

Introdução

- Doenças pulmonares intersticiais (DPIs) – mais de 180 patologias
- Diagnóstico: histórico do paciente, exames, aspectos visuais nas imagens
 - Tomografia Computadorizada de Alta Resolução (TCAR)
- Alterações na TCAR: achados radiológicos
 - “lesões, anormalidades ou alterações na estrutura normal de um tecido observado nas imagens médicas de exames radiológicos”¹
- Importância de identificar os padrões radiológicos:
 - A combinação de achados pode fornecer um possível diagnóstico

¹ Ponciano-Silva, M. (2009). Processamento de consultas por similaridade em imagens médicas visando à recuperação perceptual guiada pelo usuário. Dissertação de mestrado, Instituto de Ciências Matemáticas e de Computação - USP.

Introdução

Motivação

- Análise de imagens:
 - Reduz as indicações de biópsias pulmonares aos pacientes
 - Detecta doenças em seu estágio inicial
 - Obtém uma perspectiva sobre o grau da gravidade da patologia
- A interpretação dos exames de TC depende do especialista
- Há uma grande quantidade de cortes tomográficos por paciente
- Necessidade de uma ferramenta que forneça ao especialista uma “segunda opinião” sobre a presença de padrões radiológicos

Introdução

Objetivos

- Reconhecer automaticamente padrões radiológicos em blocos de imagens não segmentadas de TCAR
 - Classificar os padrões: tecido normal, enfisema, vidro-fosco, fibrose e micronódulos, bem como áreas externas ao pulmão
 - Avaliar métodos de extração de características
 - Utilizar blocos de imagens do pulmão que representem os aspectos visuais de cada padrão

Desafios


- Aumentar as variações interclasse e diminuir as variações intraclasse
- Desenvolver método que não dependa da prévia segmentação pulmonar

Introdução


Contribuições do trabalho

- Método de classificação que não depende de uma imagem segmentada
- Análise de diversos métodos de extração de características
- Método de classificação de blocos de imagens de TCAR que pode ser integrado a uma ferramenta de auxílio ao diagnóstico
- Artigo aceito e apresentado em:
28th IEEE International Symposium on Computer-Based Medical Systems
“Blockwise Classification of Lung Patterns in Unsegmented CT Images”
Luiza Dri Bagesteiro, Lucas Ferrari de Oliveira e Daniel Weingaertner.

Achados radiológicos




Normal




Enfisema



Vidro-fosco




Fibrose




Micronódulos

Tomografia Computadorizada

- Imagens em tons de cinza de “cortes” de partes do corpo ou de órgãos
- Valor dos pixels medido em Unidades Hounsfield (Hounsfield Unit - HU)



Tomografia computadorizada



Osso	+400 → +1000
Tecidos moles	+40 → +80
Água	0
Gordura	-60 → -100
Pulmão	-400 → -600
Ar	-1000

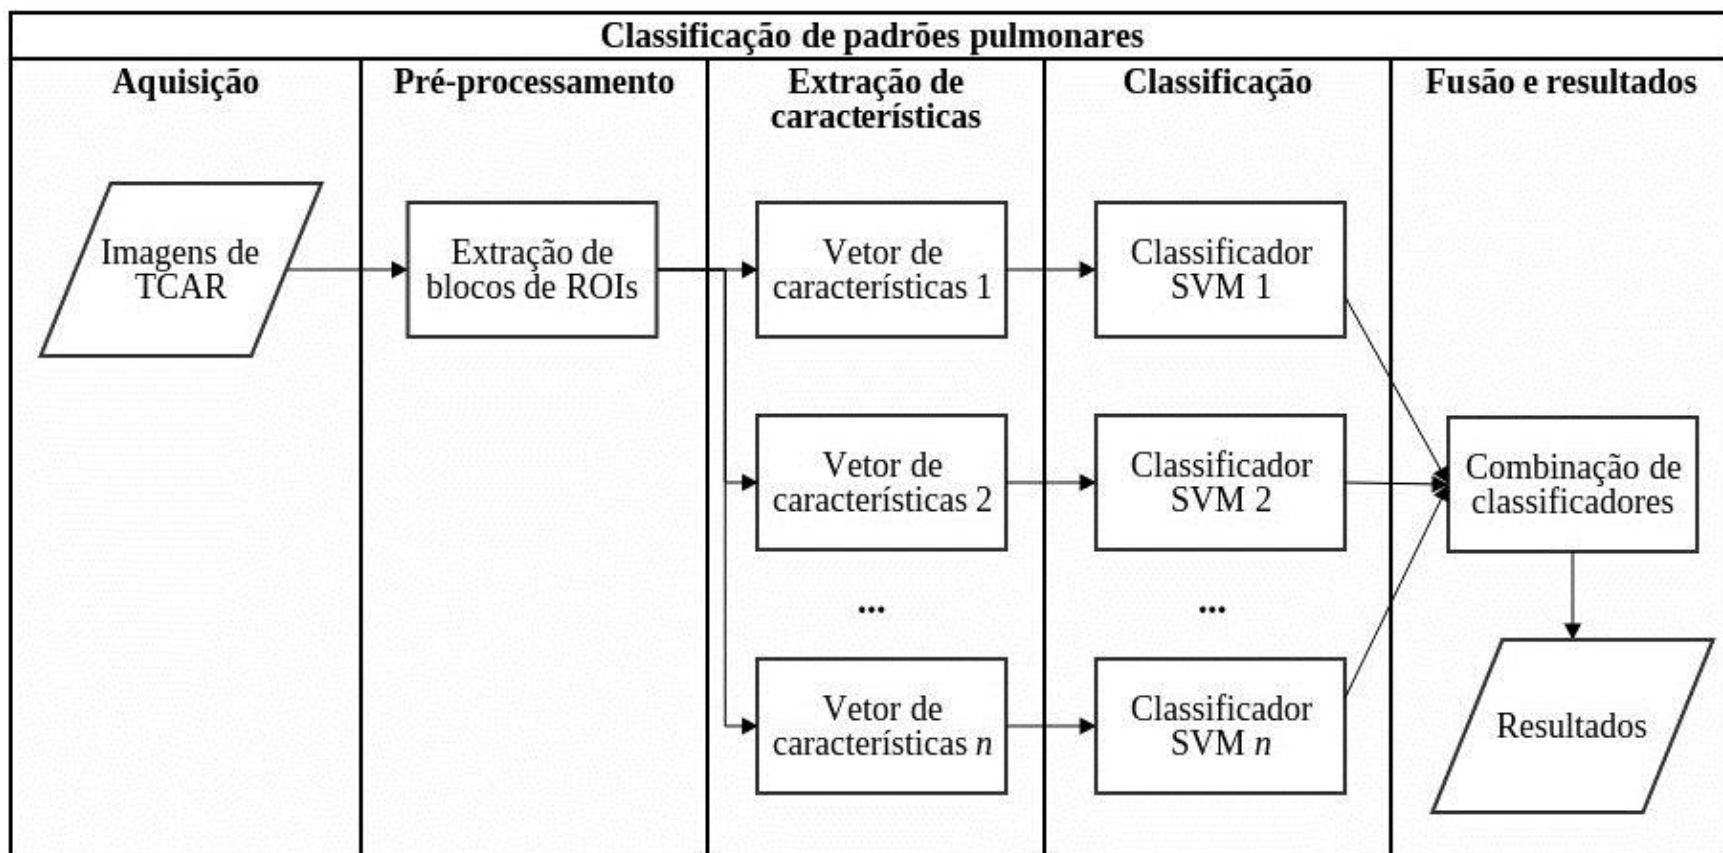
Trabalhos relacionados

Síntese dos trabalhos de análise e classificação de padrões pulmonares

Trabalho	Imagens	% média
Park et al. (2009)	Privadas - 600 ROIs	89% de acurácia
Vo and Sowmya (2010)	Privadas – 73.000 ROIs	94,16% de sensibilidade
Lim et al. (2011)	Privadas - 900 ROIs	89,88% de acurácia
Depeursinge et al. (2012)	Públicas – 17.848 ROIs	75,81% de sensibilidade
Chang et al. (2012)	Privadas - 600 ROIs	92,63% de acurácia
Song et al. (2013)	Públicas – 23.731 ROIs	82,64% de sensibilidade
Zhao et al. (2013)	Privadas – 2.360 VOIs	95,4% de acurácia
Li et al. (2013)	Públicas – 16.220 ROIs	74,2% de sensibilidade
Anthimopoulos et al. (2014)	Públicas – 2.503 ROIs	89% de f-score
Dash et al. (2014)	Privadas – 100 ROIs	95% de acurácia
Pereyra et al. (2014)	Privadas - 3.252 ROIs	82,6% de sensibilidade

Metodologia

- Para atingir os objetivos:



Sequência de etapas do método proposto

Base de imagens


- Base de imagens de Depeursinge et al.²
- Contém conjuntos de TCAR de 113 pacientes
 - TC de alta resolução em formato DICOM
 - 512x512 pixels e níveis de cinza no intervalo [-1024, 3071]
- *Ground truth*
 - Máscaras dos pulmões
 - Marcação de ROIs (Regions of Interest) de 17 padrões pulmonares
 - Normal, enfisema, vidro-fosco, fibrose, micronódulos, além de áreas externas ao pulmão

² Depeursinge, A., Vargas, A., Platon, A. a. A., Poletti, P.-A., and Muller, H. (2011). Building a Reference Multimedia Database for Interstitial Lung Diseases. *Computerized Medical Imaging and Graphics*.

Extração de blocos de imagens

Extração de blocos de tecido pulmonar

- Para cada ROI pulmonar:
 - Extrai blocos de 32x32 pixels
 - Janela com meia sobreposição em x e y
 - Mínimo de 75% dos pixels pertencentes ao padrão da ROI



Exemplo de extração de bloco de ROI de tamanho 32x32 pixels

Extração de blocos de imagens

Extração de blocos externos ao pulmão


- Dilatação morfológica aplicada na máscara pulmonar
- A ROI não-pulmonar é a área dilatada que não pertence ao pulmão
- Para cada ROI não-pulmonar:
 - Extrai blocos de 32x32 pixels
 - Janela não sobreposta em x e y
 - Mínimo de 75% dos pixels pertencentes ao padrão da ROI




Imagem original



Máscara pulmonar



Máscara pulmonar
dilatada




A área cinza representa
a ROI não pulmonar

Extração de blocos de imagens


Quantidade de blocos de ROIs extraídos

Padrão pulmonar	Quantidade de blocos
Não-pulmão	3.000
Normal	5.733
Enfisema	1.014
Vidro-fosco	1.942
Fibrose	2.736
Micronódulos	6.112


- Exemplos de blocos extraídos:




Não-pulmão




Normal




Enfisema



Vidro-fosco



Fibrose



Micronódulos

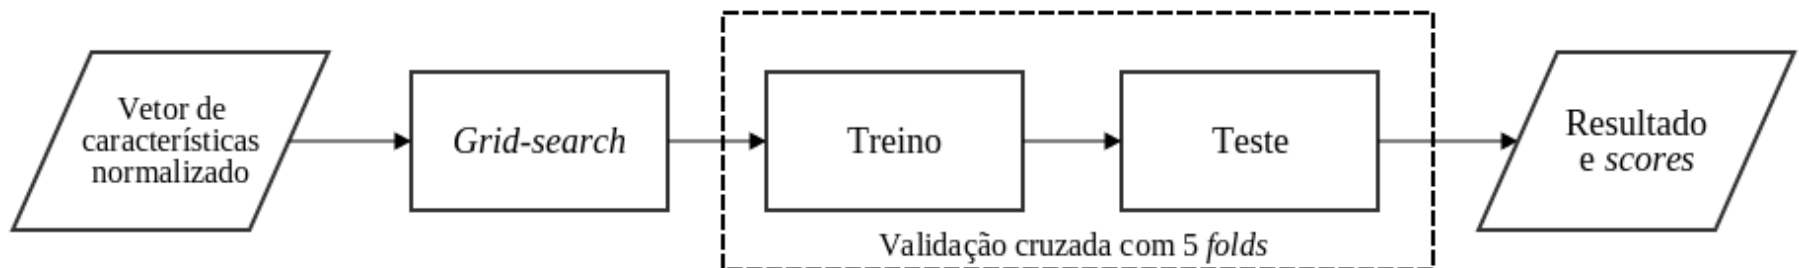
Extração de características

- Objetivo: analisar a variedade de descritores para extrair características distintas das imagens, buscando uma complementaridade entre eles

Descritor	Tamanho do vetor
$LBP_{(8,1)}^{u2}$	59
$LBP_{(8,2)}^{u2}$	59
$LBP_{(8,1)}^{riu2}$	10
$LBP_{(8,2)}^{riu2}$	10
$CLBP_S/M/C_{(8,1)}^{u2}$	200
$CLBP_S/M/C_{(8,2)}^{u2}$	200
$CLBP_S/M/C_{(8,1)}^{riu2}$	200
$CLBP_S/M/C_{(8,2)}^{riu2}$	200
$LPQ_{(8,1)}^u$	256
$LPQ_{(8,1)}^g$	256
$LPQ_{(8,1)}^{gd}$	256
GLCM	20
Histograma	25
Medidas estatísticas do histograma	4
Transformação <i>top-hat</i>	4

Classificação

- Treinar um classificador para cada descritor
- Total de 15 classificadores
- Support Vector Machine (SVM)
- Validação cruzada com 5 *folds*
- Divisão dos *folds* com base nos pacientes
- Adotada a estratégia de estimar probabilidades para as saídas geradas pelo SVM



Processo de classificação para cada característica extraída

Classificação

Número de pacientes e blocos por *fold*

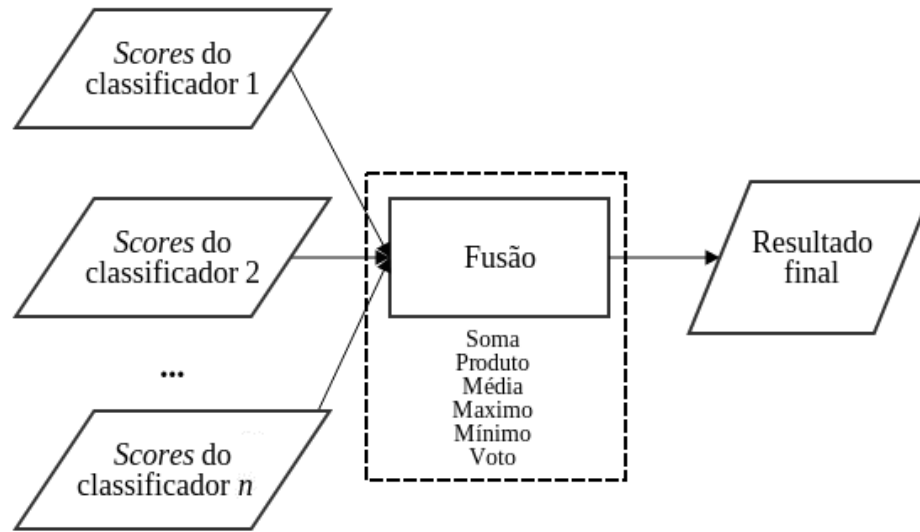
Fold	Nº de pacientes	Nº de blocos
1	43	4.044
2	19	4.214
3	21	3.991
4	17	3.962
5	12	4.329

Número de exemplos de cada classe por *fold*

Fold	Não-pulmão	Normal	Enfisema	Vidro-fosco	Fibrose	Micronódulos
1	1.160	668	58	559	444	1.155
2	620	2.305	175	682	352	80
3	546	203	0	390	494	2.358
4	389	226	111	311	1.195	1.730
5	285	2.331	673	0	251	789

Fusão dos classificadores

- Cada classificador gerou probabilidades *a posteriori*
- Combinar classificadores por meio de métodos de fusão
- Gerar todas as possíveis combinações de respostas
- $\sum_{r=2}^n \frac{n!}{r!(n-r)!} = 32.752$ combinações para os 15 classificadores



Processo de fusão de respostas dos classificadores

Resultados e discussão

- Resultados individuais (15 classificadores)
- Resultados das fusões (10 melhores)

- Medidas:

- $sensibilidade = \frac{VP}{VP+FN}$

- $precisão = \frac{VP}{VP+FP}$

- $especificidade = \frac{VN}{VN+FP}$

- $acurácia = \frac{VP+VN}{VP+FP+FN+VN}$

- VP – verdadeiro positivo
- FP – falso positivo
- FN – falso negativo
- VN – verdadeiro negativo

Resultados e discussão

Resultados gerais dos 15 classificadores individuais (em %)

Classificador	Sensibilidade	Precisão	Especificidade	Acurácia
$CLBP_{S/M/C_{(8,2)}^{riu2}}$	78,99	75,95	95,55	93
$CLBP_{S/M/C_{(8,1)}^{riu2}}$	75,29	70,84	94,82	91,76
$CLBP_{S/M/C_{(8,2)}^u2}$	74,18	70,76	94,51	91,39
$CLBP_{S/M/C_{(8,1)}^u2}$	72,06	67,89	94,12	90,69
Transformação <i>top-hat</i>	69,63	61,86	93,5	89,88
Histograma	67,47	63,44	93,05	89,16
$LBP_{(8,2)}^{u2}$	66,97	64,31	92,88	88,99
$LPQ_{(8,1)}^g$	66,76	61,31	92,95	88,92
$LBP_{(8,1)}^{u2}$	66,58	62,27	92,84	88,86
$LBP_{(8,2)}^{riu2}$	66,01	62,79	92,7	88,67
$LPQ_{(8,1)}^u$	63,53	55,98	92,33	87,84
$LBP_{(8,1)}^{riu2}$	62,57	58,28	91,96	87,52
$LPQ_{(8,1)}^{gd}$	62,1	53,45	92,05	87,37
GLCM	55	53,36	90,51	85
Medidas estatísticas do histograma	41,42	42,82	87,04	80,47

Resultados e discussão

Matriz de confusão da melhor configuração do CLBP ($CLBP_{(8,2)}^{riu2}$) (em %)

	NP	N	E	VF	F	M
NP	97,5	0,7	0,17	1,37	0,23	0,03
N	0,68	79,98	0,78	7,01	0,72	10,83
E	2,46	19,96	57,13	5,51	10,91	4,03
VF	3,5	24,46	0,26	39,8	23,43	8,55
F	0,58	1,1	1,86	15,1	77,6	3,76
M	0,02	9,62	0,44	1,42	2,81	85,68

- Reconhece as classes normal, fibrose e micronódulos com taxas próximas à da literatura
- Ótima taxa de reconhecimento para não-pulmão
- Problemas em identificar enfisema e vidro-fosco

Resultados e discussão

Resultados gerais das 10 melhores combinações (em %)

Combinação	Sensibilidade	Precisão	Especificidade	Acurácia	TOP 2
(a)	81,65	79	96,06	93,88	92,62
(b)	81,56	79,82	96,05	93,85	92,89
(c)	81,51	79,36	96,06	93,84	93,08
(d)	81,51	78,47	96,07	93,84	92,87
(e)	81,42	78,94	96,03	93,81	92,74
(f)	81,3	79,64	96	93,77	92,83
(g)	81,3	79,35	95,99	93,77	92,59
(h)	81,23	78,93	95,99	93,74	92,71
(i)	81,09	78,99	95,97	93,7	92,69
(j)	81,03	79,07	95,94	93,68	92,63

- (a) $CLBP_{(8,2)}^{riu2}$, top-hat
- (b) $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,2)}^{u2}$, top-hat
- (c) $CLBP_{(8,1)}^{riu2}$, $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,2)}^{u2}$, top-hat
- (d) $CLBP_{(8,1)}^{riu2}$, $CLBP_{(8,2)}^{riu2}$, top-hat
- (e) $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,1)}^{u2}$, top-hat
- (f) $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,1)}^{u2}$, $CLBP_{(8,2)}^{u2}$, top-hat
- (g) $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,2)}^{u2}$, top-hat, $LPQ_{(8,1)}^u$
- (h) $CLBP_{(8,1)}^{riu2}$, $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,2)}^{u2}$, top-hat, $LPQ_{(8,1)}^u$
- (i) $CLBP_{(8,1)}^{riu2}$, $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,1)}^{u2}$, $CLBP_{(8,2)}^{u2}$, top-hat
- (j) $CLBP_{(8,2)}^{riu2}$, $CLBP_{(8,1)}^{u2}$, $CLBP_{(8,2)}^{u2}$, top-hat, $LPQ_{(8,1)}^u$

- Melhor regra:
- Produto

Resultados e discussão

Matriz de confusão da melhor combinação de classificadores ($CLBP_{(8,2)}^{riu2}$ e transformação *top-hat*) (em %)

	NP	N	E	VF	F	M
NP	99,2	0,03	0,5	0,2	0,03	0,03
N	0,16	85,92	1,53	4,76	0,4	7,22
E	1,47	32,35	44,64	0,79	8,55	12,19
VF	2,11	29,71	0	51,29	13,65	3,24
F	1,46	1,39	1,28	11,15	79,57	5,15
M	0,03	9,21	0,29	0,74	3,96	85,77

- Aumento de sensibilidade em todas as classes, exceto na classe enfisema
 - Não pulmão: de 97,5% para 99,2%
 - Normal: de 79,98% para 85,92 %
 - Enfisema: de 57,13% para 44,64%
 - Vidro-fosco: de 39,8 % para 51,29 %
 - Fibrose: de 77,6 % para 79,57 %
 - Micronódulos: de 85,68% para 85,77 %

Resultados e discussão

- Maioria das confusões:
 - enfisema e normal
 - vidro-fosco e normal
 - vidro-fosco e fibrose
- Problemas interclasse:
 - enfisema e normal – possuem aparência escura
 - vidro-fosco e fibrose – altas densidades
- Problemas intraclasse:
 - Enfisema e fibrose – estruturas locais irregulares
 - Normal – não possui textura uniforme única

Resultados e discussão

- Necessidade de uma etapa de verificação
 - Reavaliar determinada amostra, extraíndo características específicas
- Aumento em todas as medidas gerais, do melhor classificador individual para a melhor combinação de classificadores
- TOP 2 pode fornecer ao especialista duas respostas em forma de probabilidades
- Desvantagem: diversos erros de classificação
 - regiões pulmonares não possuem textura homogênea
 - perda de propriedades globais de textura na classificação por blocos

Resultados e discussão

Comparativo com os resultados obtidos na literatura (em %)

Trabalho	Sensibilidade	Acurácia
Park et al. (2009)	92,5	89
Vo and Sowmya (2010)	94,16	-
Lim et al. (2011)*	-	89,88
Depeursinge et al. (2012)*	75,81	90,76
Chang et al. (2012)	-	92,63
Song et al. (2013)*	82,64	-
Zhao et al. (2013)	-	95,4
Li et al. (2013)*	74,2	-
Dash et al. (2014)	-	95
Pereyra et al. (2014)	82,6	-
Método proposto*	81,65	93,88

* Utilizaram a base de imagens pública de Depeursinge et al. (2011)

Considerações finais

- Método que identifica seis padrões radiológicos em blocos de imagens de TCAR: não-pulmão, normal, enfisema, vidro-fosco, fibrose e micronódulos
- Melhor classificador individual: $CLBP_{(8,2)}^{riu2}$
- Melhor combinação de classificadores: $CLBP_{(8,2)}^{riu2}$ e transformação *top-hat*
- Possibilidade de inserção do método desenvolvido em uma ferramenta de auxílio ao diagnóstico
- Resultados preliminares já publicados em artigo

Trabalhos futuros

- Novas configurações para extrair características da transformação *top-hat*
- Seleção de atributos dos vetores de características
- Classificação hierárquica
- Novas regras para a fusão de classificadores
- Testar o método como um pré-segmentador para os pulmões
- Avaliação da imagem pulmonar
 - Informações de vizinhança
 - Distribuição das anormalidades

Classificação de Padrões Radiológicos por Blocos em Imagens Não Segmentadas de Tomografia Computadorizada

Luiza Dri Bagesteiro

ldbagesteiro@inf.ufpr.br

<http://web.inf.ufpr.br/vri/alumni/2015-LuizaDriBagesteiro-Msc>

Prof. Dr. Daniel Weingaertner

danielw@inf.ufpr.br

Prof. Dr. Lucas Ferrari de Oliveira

lferrari@inf.ufpr.br