

ARIMURA, H. et al. Computerized scheme for automated detection of lung nodules in low-dose computed tomography images for lung cancer screening. **Academic Radiology**, v. 11, n. 6, p. 617–629. 2004.

ARMATO, S. G.; GIGER, M. L.; MACMAHON, H. Automated detection of lung nodules in CT scans: preliminary results. **Medical Physics**, v. 28, n. 8, p. 1552–1561. 2001.

ARMATO, S. G. et al. Computerized detection of pulmonary nodules on CT scans. **Radiographics**, v. 19, n. 5, p. 1303–1311. 1999.

ARMATO, S. G. et al. Lung cancer: performance of automated lung nodule detection applied to cancers missed in a CT screening program. **Radiology**, v. 225, n. 3, p. 685–692. 2002.

ARMATO, S. G. et al. Lung Image Database Consortium: developing a resource for the medical imaging research community. **Radiology**, v. 232, p. 739-748. 2004.

ARMATO, S. G.; SENSÁKOVIC, W. F. Automated lung segmentation for thoracic CT. **Academic Radiology**, v. 11, n. 9, p. 1011–1021. 2004.

AWAI, K. et al. Pulmonary nodules at chest CT: effect of computer-aided diagnosis on radiologists' detection performance. **Radiology**, v. 230, n. 2, p. 347–352. 2004.

BAATZ, M. et al. **eCognition Professional**: User Guide 4. Definiens Imaging. Germany, 2000a.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In Strobl, Blaschke & Greisebener (Edts): *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT-Symposium Salzburg 2000*. Karlsruhe. Herbert Wichmann Verlag. 2000b.

BEIGELMAN-AUBRY, C. et al. Computer-aided detection of solid lung nodules on follow-up MDCT screening: evaluation of detection, tracking, and reading time. **American Journal of Roentgenology**, v. 189, n. 4, p. 948-55. 2007.

BLASCHKE, T.; LANG, S.; MÖLLER, M. S. Object-based analysis of remote sensing data for landscape monitoring. Recent developments. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, INPE, p. 2879-2885. 2005.

BROWN, M. S. et al. Patient-specific models for lung nodule detection and surveillance in CT images. **IEEE Transactions on Medical Imaging**, v. 20, n. 12, p. 1242–1250. 2001.

CHANG, S. et al. Pulmonary micronodule detection from 3-D chest CT. **Medical**

Image Computing and Computer-Assisted Intervention, p. 821–828. 2004.

COSTA, G. A. O. P. et al. Genetic adaptation of segmentation parameters. In: T. Blaschke, S. Lang, G. Hay (Eds.), *Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications*, Springer-Verlag. ISBN: 3540770577, 2008.

CRISTIANINI, N.; SHAWE-TAYLOR, J. **An introduction to support vector machines and other kernel-based learning methods**. Cambridge University Press, 2000. ISBN:0521780195.

DAVIS, L. **Handbook of Genetic Algorithms**. VNR Comp. Library, 1990.

DIEDERICH, S. et al. Screening for early lung cancer with low-dose spiral CT: prevalence in 817 asymptomatic smokers. **Radiology**, v. 222, n. 3, p. 773–781. 2002.

DOLEJSI, M. et al. The Lung TIME: annotated lung nodule dataset and nodule detection framework. *Medical Imaging 2009: Computer-Aided Diagnosis. Proceedings of SPIE*, v. 7260, p. 72601U-72601U-8. 2009. DOI: 10.1117/12.811645.

DUIN, R.P.W. et al. *PRTools4.1, A Matlab Toolbox for Pattern Recognition. Delft University of Technology*, 2007.

DUIN, R.P.W. et al. **PRTools4.1: A Matlab Toolbox for Pattern Recognition**, Delft University of Technology. 2007.

ENQUOBAHRIE, A. A. et al. Automated detection of pulmonary nodules from whole lung helical CT scans: performance comparison for isolated and attached nodules. **Proceedings of SPIE**, v. 5370, p. 791–800. 2004.

EZOE, T. et al. An automatic detection method of lung cancers including ground glass opacities from chest X-ray CT images. **Proceedings of SPIE**, v. 4684, p. 1672–1680. 2002.

FARAG, A. et al. Automatic detection and recognition of lung abnormalities in helical CT images using deformable templates. In *Lecture Notes in Computer Science*. Berlin, Germany: Springer-Verlag, v. 3217, **Medical Image Computing and Computer-Assisted Intervention**, pp. 856–864. 2004.

FETITA, C. I. et al. 3-D automated lung nodule segmentation in HRCT. *Lecture Notes in Computer Science*. Berlin, Germany: Springer-Verlag, v. 2878, **Medical Image Computing and Computer-Assisted Intervention**, p. 626–634. 2003.

GE, Z. et al. Computer-aided detection of lung nodules: false positive reduction using a 3D gradient field method and 3D ellipsoid fitting. **Medical Physics**, v. 32, n. 8, p. 2443-2454. 2005.

GOLDBERG, D. **Genetic algorithms in search, optimization and machine learning**. Addison-Wesley. 1989.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**, 2.ed. MA: Addison-Wesley. 2002.

GURCAN, M. N. et al. Lung nodule detection on thoracic computed tomography images: preliminary evaluation of a computer-aided diagnosis system. **Medical Physics**, v. 29, n. 11, p. 2552–2558. 2002.

GURNEY, J. Determining the likelihood of malignancy in solitary pulmonary nodules with Bayesian analysis. part I. Theory, **Radiology**, vol. 186, no. 2, pp. 405–413, 1993.

GURNEY, J.; LYDDON, D.; MCKAY, J. Determining the likelihood of malignancy in solitary pulmonary nodules with Bayesian analysis. Part II. Application, **Radiology**, v. 186, n. 2, p. 415–422. 1993.

HARALICK, R.; SHANMUGAM, K.; DINSTEIN, I. Textural features for image classification. **IEEE Transactions on System, Man and Cybernetics**, v. 3, n. 6, p. 610-621. 1973.

HOLLAND, J. H. **Adaptation in natural and artificial system**, Ann Arbor, The University of Michigan Press. 1975.

HU, S.; HOFFMAN, E. A.; REINHARDT, J. M. Automatic lung segmentation for accurate quantitation of volumetric X-ray CT images. **IEEE Transactions on Medical Imaging**, v. 20, n. 6, p. 490–498. 2001.

INCA. Estimativa 2008: incidência de câncer no Brasil. Ministério da Saúde. Secretaria de Atenção à Saúde. **Instituto Nacional de Câncer**. Coordenação de Prevenção e Vigilância de Câncer. Rio de Janeiro: INCA, 2007. ISBN 978-85-7318-126-5.

INCA. Estimativa 2010: incidência de câncer no Brasil. Ministério da Saúde. **Instituto Nacional de Câncer**. Rio de Janeiro: INCA, 2009. ISBN 978-85-7318-161-6.

KANAZAWA, K. et al. Computer-aided diagnosis for pulmonary nodules based on helical CT images. **Computerized medical imaging and graphics**, v. 22, n. 2, p. 157–167. 1998.

KO, J. P.; BETKE, M. Chest CT: automated nodule detection and assessment of change over time – preliminary experience. **Radiology**, v. 218, n. 1, p. 267–273, 2001.

KO, J. P.; NAIDICH, D. P. Lung nodule detection and characterization with multi-slice CT. **Radiologic Clinics of North America**, v. 41, n. 3, p. 575–597. 2003.

KOZA, J. **Genetic programming: on the programming of computers by means of natural selection**. MIT Press, 1992.

KUBO, M. et al. A CAD system for lung cancer based on low dose single-slice CT image. **Proceedings of SPIE**, v. 4684, p. 1672–1680. 2002.

LEADER, J. K. et al. Automated lung segmentation in X-ray computed tomography, **Academic Radiology**, v. 10, n. 11, p. 1224–1236. 2003.

LEE, S.L.A.; KOUZANI, A.Z.; HU, E.J. Automated identification of lung nodules. **Multimedia Signal Processing**, IEEE 10th Workshop on , p. 497-502, 2008.

LEE, Y. et al. Automated detection of pulmonary nodules in helical CT images based on an improved template-matching technique. **IEEE Transactions on Medical Imaging**, v. 20, n. 7, p. 595–604. 2001.

LEE, Y. et al. Improvement in automated detection of pulmonary nodules on helical X-ray CT images. **Proceedings of SPIE**, v. 5370, p. 824–832. 2004.

LI, Q.; DOI, K. New selective enhancement filter and its application for significant improvement of nodule detection on computed tomography. **Proceedings of SPIE**, v. 5370, p. 1–9. 2004.

LI, Q.; LI, F.; DOI, K. Computerized detection of lung nodules in thin-section ct images by use of selective enhancement filters and an automated rule-based classifier. **Academic Radiology**, v. 15, n. 2, p. 165-175. 2008.

LO, S. et al. Classification of lung nodules in diagnostic CT: an approach based on 3-D vascular features, nodule density distributions, and shape features. In: **Presented at the Society of Photo-Optical Instrumentation Engineers (SPIE) Conference, Proceedings...** The International Society for Optical Engineering, p. 183- 189. 2003.

LU, X.; WEI, G.; QIAN, J. Learning-based pulmonary nodule detection from multislice CT data. In: **International Congress of Cars, Proceedings...** p. 1356. 2004.

MATLAB 7.6: The Language of Technical Computing. Mathworks corporation, 2008.

MCCULLOCH, C. C. et al. Model-based detection of lung nodules in computed tomography exams. **Academic Radiology**, v. 11, n. 3, p. 258-266. 2004.

MCNITT-GRAY, M. F. et al. The effects of co-occurrence matrix based texture parameters on the classification of solitary pulmonary nodules imaged on computed tomography. **Computerized medical imaging and graphics**, v. 23, n. 6, p. 339-48. 1999.

MEKADAA, Y. et al. Detection of small nodules from 3-D chest X-ray CT images based on shape features. **Computer assisted radiology and surgery**, v. 1256, p. 971–976. 2003.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. Springer-Verlag, 1994.

MOUSA, W. A. H.; KHAN, M. A. U. Lung nodule classification utilizing support vector machines. **IEEE International Conference on Image Processing**, p. 153-156. 2002.

ODA, T. et al. A detection algorithm of lung cancer candidate nodules on multi-slice CT images. **Proceedings of SPIE**, v. 4684, p. 1354-1361. 2002.

OHANIAN, P. P.; DUBES, R. C. Performance evaluation for four classes of textural features. **Pattern Recognition**, v. 25, n. 8, p. 819-833. 1992.

OPFER, R.; WIEMKER, R. Performance analysis for computer-aided lung nodule detection on LIDC data. Medical Imaging 2007: Image Perception, Observer Performance, and Technology Assessment. **Proceedings of SPIE**, v. 6515, p. 65151C. 2007. DOI:10.1117/12.708210.

OSMAN, O.; OZEKES, S.; UCAN; O. N. Lung nodule diagnosis using 3D template matching. **Computers in Biology and Medicine**, v. 37, n. 8, p. 1167-1172, ISSN: 0010-4825. 2007.

OST, D.; FEIN, A. Evaluation and management of the solitary pulmonary nodule. **American journal of respiratory and critical care medicine**, v. 162, n. 3, p. 782–787. 2000.

- OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62-66. 1979.
- OZEKES, S.; OSMAN, O.; UCAN, O. N. Nodule detection in a lung region that's segmented with using genetic cellular neural networks and 3D template matching with fuzzy rule based thresholding. **Korean Journal of Radiology**. v. 9, n. 1, p. 1–9. 2008. doi: 10.3348/kjr.2008.9.1.1.
- ÖZEKES, S. Rule-Based Lung Region Segmentation And Nodule Detection Via Genetic Algorithm Trained Template Matching. **İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi Yıl**. 2007.
- PAIK, D. S. et al. Surface normal overlap: a computer-aided detection algorithm with application to colonic polyps and lung nodules in helical CT. **IEEE Transactions on Medical Imaging**, v. 23, n. 6, p. 661-675. 2004.
- PELDSCHUS, K. et al. Computer-aided diagnosis as a second reader: spectrum of findings in CT studies if chest interpreted as normal. **Chest**, v. 123, p. 1517-1523. 2005.
- Pratt, W. K. **Digital Image Processing**, 4.ed., John Wiley & Sons, Inc., Los Altos, California, 2007.
- PU, J. et al. An automated CT based lung nodule detection scheme using geometric analysis of signed distance field. **Medical Physics**, v. 35, n. 8, p. 3453–3461. DOI: 10.1118/1.2948349. 2008.
- RETICO, A. et al. Lung nodule detection in low-dose and thin-slice computed tomography. **Computers in Biology and Medicine**, v. 38, n. 4, p. 525-534, ISSN:0010-4825, 2008.
- SAITA, S. et al. Nodule detection algorithm based on multi-slice CT images for lung cancer screening. **Proceedings of SPIE**, v. 5370, p. 1083–1090. 2004.
- SILVA, A. C. Algoritmos para diagnóstico assistido de nódulos pulmonares solitários em imagens de tomografia computadorizada. **Tese de Doutorado**, Pontifícia Universidade Católica do Rio de Janeiro – Brasil, 2004.
- SILVA, A. C. et al. Diagnosis of lung nodule using the semivariogram function. **Lecture Notes in Computer Science**, v. 3138, p. 242-250. 2004.
- SILVA, E. C. et al. Diagnosis of Lung Nodule using Moran's Index and Geary's Coefficient in Computerized Tomography Images. **Pattern Analysis and Applications**, v. 11, p. 89-99. 2008.
- SLUIMER, I. et al. Computer Analysis of Computed Tomography Scans of the Lung: A Survey. **IEEE Transactions on Medical Imaging**, v. 25, n. 4. 2006.
- SOUSA, J. R. F. S. Metodologia para detecção automática de nódulos pulmonares. **Dissertação de Mestrado**, Universidade Federal do Maranhão – Brasil, 2007b.
- SOUSA, J. R. F. S.; SILVA., A. C.; PAIVA, A. C.; Lung structure classification using 3D geometric measurements and SVM. **Iberoamerican Congress on Pattern Recognition**, CIARP, p. 783-792. 2007a.
- SUZUKI, K. et al. Massive training artificial neural network (MTANN) for reduction of false positives in computerized detection of lung nodules in low-dose computed tomography, **Medical Physics**, v. 30, n. 7, p. 1602–1617. 2003.

- SWENSEN, S. J. et al. Screening for lung cancer with low dose spiral computed tomography. **American journal of respiratory and critical care medicine**, v. 20, p. 911–920. 2002.
- TANINO, M. et al. A detection method of ground glass opacities in chest x-ray CT images using automatic clustering techniques. **Proceedings of SPIE**, v. 5032, p. 1728–1737. 2003.
- TONG, J. et al. Automated detection of pulmonary nodules in HRCT images. **Bioinformatics and Biomedical Engineering**, ICBBE. p. 833-836, ISBN 1-4244-1120-3, DOI 10.1109/ICBBE.2007.217. 2007.
- WANG, L. **Support vector machines: theory and applications**. Springer-Verlag Berlin Heidelberg, 2005. ISBN: 978-3-540-24388-5.
- WAY, T. et al. Computer-aided diagnosis of pulmonary nodules on CT scans: Segmentation and classification using 3D active contours. **Medical Physics**, v. 33, n. 7, p. 2323-2337. 2006.
- WEI, G. Q.; FAN, L.; QIAN, J. Automatic detection of nodules attached to vessels in lung CT by volume projection analysis. **In Lecture Notes in Computer Science**. Berlin, Germany: Springer-Verlag, v. 2488, Medical Image Computing and Computer-Assisted Intervention, p. 746–752. 2002.
- WHITE, C. S. et al. Lung nodule CAD software as a second reader: a multicenter study. **Academic Radiology**, v. 15, n. 3, p. 326-333, DOI 10.1016/j.acra.2007.09.027, 2008.
- WIEMKER, R. et al. Computer aided lung nodule detection on high resolution CT data, **Proceedings of SPIE**, v. 4684, p. 677–688. 2002.
- YAMADA, N. et al. ROI extraction of chest CT images using adaptive opening filter. **Proceedings of SPIE**, v. 5032, p. 869–876. 2003.
- YANKELEVITZ, D. F.; HENSCHKE, C. I. Lung cancer: small pulmonary nodules. **Radiologic Clinics of North America**, v. 38, p. 1–9. 2000.
- YE, X. et al. Efficient computer-aided detection of ground-glass opacity nodules in thoracic ct images. **In Engineering in Medicine and Biology Society**, EMBS, p 4449-4452, ISBN: 978-1-4244-0787-3. 2007.
- ZHANG, X. et al. Computerized detection of pulmonary nodules using cellular neural networks in CT images. **Proceedings of SPIE**, v. 5370, p. 30-41. 2004.
- ZHAO, B. et al. Application of the LDM algorithm to identify small lung nodules on low-dose MSCT scans. **Proceedings of SPIE**, v. 5370, p. 818–823. 2004.
- ZHENG, B. et al. A simple method for automated lung segmentation in X-ray CT images. **Proceedings of SPIE (Medical Imaging)**, v. 5032, p. 1455–1463. 2003.
- ZHONG, C. et al. Multi-scale segmentation of the high resolution remote sensing image. **In: Proceedings of the IGARSS Symposium**. Seoul, Korea. July 25-29, 2005.

Apêndice I

Limiarização Global pelo Algoritmo de Otsu

Limiarização é um importante método para segmentação de imagens. Seja I uma imagem em níveis de cinza composta por objetos claros sobre um fundo escuro (ou o contrário, objetos escuros em um fundo claro), a limiarização busca um limiar L tal que separe I nos dois grupos desejáveis (objetos e o fundo).

A segmentação é, portanto, definida classificando cada pixel da imagem como sendo do objeto ou do fundo, dependendo se o nível de cinza do respectivo pixel for menor ou maior que o limiar L . Sendo assim, uma imagem limiarizada g é definida como:

$$g(x, y) = \begin{cases} 0 & \text{se } I(x, y) < L \\ 1 & \text{se } I(x, y) \geq L \end{cases} \quad (1-A1)$$

onde (x, y) refere-se à posição de um pixel na imagem.

Neste caso, pixels rotulados como 1 correspondem aos objetos enquanto que aqueles rotulados como 0 correspondem ao fundo.

O sucesso deste tipo de segmentação depende, portanto, completamente da escolha do limiar. Desta forma, a maior dificuldade deste método é a escolha do limiar.

Otsu (1979) propôs uma abordagem para encontrar um limiar L de forma que a variância intraclasse dos grupos de pixels encontrados seja minimizada. A seguir, é apresentado este algoritmo.

Seja I uma imagem em níveis de cinza, para cada nível de cinza Z de I , efetue os seguintes passos:

Gere dois grupos G_1 e G_2 , tal que G_1 é formado por todos os pixels em I com nível de cinza menor que Z e G_2 , pelos demais.

Calcule a proporção (p) e a variância (σ^2) de cada grupo.

Calcule a variância intraclasse σ_w^2 dada pela equação abaixo.

$$\sigma_w^2 = p_1\sigma_1^2 + p_2\sigma_2^2 \quad (2-A1)$$

onde p_1 e p_2 são proporções dos grupos G_1 e G_2 , e σ_1^2 e σ_2^2 são as variâncias de G_1 e G_2 , respectivamente.

O limiar ótimo é o valor encontrado de Z que correspondente ao menor valor de variância intraclasse.

Apêndice II

Cálculo da Área Superficial e do Volume de um Objeto

As imagens fornecidas por tomógrafos são, muitas vezes, formadas por diversas fatias paralelas uniformemente espaçadas. A menor unidade destas imagens tridimensionais é chamada *voxel*. O tamanho do voxel pode variar em diferentes exames o qual influencia em medidas de forma que dependem da área superficial e do volume de um objeto da imagem. Com o propósito de ajustar estes valores de acordo com a dimensão do voxel, este apêndice descreve uma abordagem para calcular uma aproximação de tais medidas.

A Figura 29 representa um voxel cujas dimensões são dadas por l_x , l_y e l_z . A dimensão l_z é dada pela distância entre as fatias enquanto que l_x e l_y são as medidas dos pixels em cada fatia.

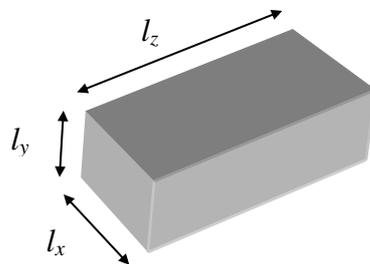


Figura 29 – Dimensões de um voxel.

A contribuição v de um voxel para o volume de um objeto em qualquer fatia pode ser aproximada em:

$$(1-A2)$$

Assim, o volume total do objeto é dado por:

$$(2-A2)$$

onde n_{obj} é o número de voxels pertencentes ao objeto.

A área superficial a de um objeto é dada pela soma de parte da área superficial de cada voxel pertencente à fronteira do objeto:

$$a = \sum_{i=1}^t c_i \quad (3-A2)$$

onde t é número de voxels na fronteira do objeto e c_i é a contribuição do i -ésimo voxel na área superficial do objeto.

Se c' é a contribuição aproximada de qualquer voxel da fronteira para a área superficial do objeto, então:

$$a = tc' \quad (4-A2)$$

A contribuição de um voxel no cálculo da área superficial de um objeto é dada de acordo com o número de faces do voxel fazendo parte da superfície externa do objeto. São apresentadas abaixo as possibilidades existentes:

- 1 face: há três possibilidades:

$$c = l_x l_y \quad (5-A2)$$

$$c = l_x l_z \quad (6-A2)$$

$$c = l_y l_z \quad (7-A2)$$

Neste caso, a contribuição do voxel é aproximadamente:

$$(8-A2)$$

Considerando

$$(9-A2)$$

então

$$c' = \frac{1}{3}B \quad (10-A2)$$

- 2 faces: há três possibilidades:

$$c = l_x l_y + l_x l_z \quad (11-A2)$$

$$c = l_x l_y + l_y l_z \quad (12-A2)$$

$$c = l_x l_z + l_y l_z \quad (13-A2)$$

Neste caso, a contribuição do voxel é aproximadamente:

$$c' = \frac{1}{3}[(l_x l_y + l_x l_z) + (l_x l_y + l_y l_z) + (l_x l_z + l_y l_z)] \quad (14-A2)$$

Portanto:

$$c' = \frac{2}{3}B \quad (15-A2)$$

- 3 faces: há uma possibilidade:

$$c = l_x l_y + l_x l_z + l_y l_z \quad (16-A2)$$

$$c = B \quad (17-A2)$$

- 4 faces: há três possibilidades:

$$(18-A2)$$

$$(19-A2)$$

$$(20-A2)$$

Neste caso, a contribuição do voxel é aproximadamente:

$$c' = \frac{4}{3}(l_x l_y + l_x l_z + l_y l_z) \quad (21-A2)$$

$$c' = \frac{4}{3}B \quad (22-A2)$$

- 5 faces: há três possibilidades:

$$c = 2l_x l_y + 2l_x l_z + l_y l_z \quad (23-A2)$$

$$c = 2l_x l_y + l_x l_z + 2l_y l_z \quad (24-A2)$$

$$c = l_x l_y + 2l_x l_z + 2l_y l_z \quad (25-A2)$$

Neste caso, a contribuição do voxel é, em média:

$$c' = \frac{5}{3}(l_x l_y + l_x l_z + l_y l_z) \quad (26-A2)$$

$$c' = \frac{5}{3}B \quad (27-A2)$$

- 6 faces: há apenas uma possibilidade:

$$c = 2l_x l_y + 2l_x l_z + 2l_y l_z \quad (28-A2)$$

$$c = 2B \quad (29-A2)$$

Desta forma, a contribuição do voxel na área superficial de um objeto deve ser próxima por alguma média envolvendo os casos citados.

$$(30-A2)$$

$$(31-A2)$$

Portanto, a contribuição do voxel é aproximadamente:

$$c' = \frac{7}{6}(l_x l_y + l_x l_z + l_y l_z) \quad (32-A2)$$

Sendo assim, a área superficial aproximada de um objeto é dada por:

$$a = \frac{7}{6}t(l_x l_y + l_x l_z + l_y l_z) \quad (33-A2)$$

onde t é número de voxels na fronteira do objeto.

Apêndice III

Medidas Descritivas dos Objetos

Este apêndice apresenta como são calculados os atributos de classificação de objetos candidatos a nódulo.

AIII.1. Descritores geométricos

Nesta seção, são apresentadas as propriedades dos objetos quanto à sua forma. O volume e área superficial de um objeto, cujos valores são necessários em algumas medidas apresentadas nesta seção, são calculados conforme apresentado no apêndice II.

AIII.1.1. Compacidade

A compacidade indica o quão reduzido está o objeto de maneira que ocupe menos espaço ou dimensão sem que se tenha seu volume reduzido. Esta propriedade é medida pela equação:

$$C = \frac{\sqrt{a}}{\sqrt[3]{v}} \quad (1-A3)$$

onde a é a área superficial do objeto e v é o volume do objeto.

AIII.1.2. Desproporção esférica

A desproporção esférica mede a regularidade das bordas de um objeto. É dada pela eq. (2-A3):

$$D = \frac{a}{4 \cdot \pi \cdot R^2} \quad (2-A3)$$

onde a é a área superficial do objeto e R é o raio estimado para uma esfera com o mesmo volume do objeto original.

$$R = \sqrt[3]{\frac{3 \cdot v}{4 \cdot \pi}} \quad (3-A3)$$

onde v é o volume do objeto.

AIII.1.3. Densidade esférica

A densidade esférica mede a compacidade do objeto. É dada pela eq. (4-A3), onde n é o número de voxels pertencentes ao objeto que satisfazem a eq. (5-A3), v é o volume do objeto, R é o raio estimado (eq. (3-A3)) e c_x , c_y e c_z são as coordenadas do centro de massa do objeto.

$$De = \frac{100 \cdot n}{v} \quad (4-A3)$$

$$(x - c_x)^2 + (y - c_y)^2 + (z - c_z)^2 \leq R^2 \quad (5-A3)$$

AIII.1.4. Distância radial ponderada

A distância radial ponderada mede o grau de achatamento de um objeto, dada pela eq. (6-A3):

$$(6-A3)$$

$$(7-A3)$$

onde $\alpha_{x,y,z}$ é o coeficiente de ponderação aplicado a cada voxel e $r_{x,y,z}$ é a distância radial do voxels de coordenadas x, y, z .

AIII.1.5. Esfericidade

A esfericidade mede o quanto a forma do objeto se aproxima da forma esférica.

$$Es = \frac{(6 \cdot \pi^3 \cdot \sqrt[3]{v^2})}{a} \quad (8-A3)$$

onde v é o volume e a é a área superficial do objeto.

AIII.1.6. Elongação

A elongação mede o grau de alongamento ou assimetria do objeto. É calculado através da eq. (9-A3).

$$E = \frac{Ar_{\min}}{Ar_{\max}} \quad (9-A3)$$

onde Ar_{\min} e Ar_{\max} são, respectivamente, os tamanhos da menor e maior aresta da caixa mínima (*bounding box*).

AIII.2. Medidas de densidade

Aqui são apresentadas as propriedades dos objetos medidas a partir dos valores indicados pelos voxels dos respectivos objetos.

AIII.2.1. Média das densidades

Dada pela média aritmética dos valores de todos os voxels pertencentes ao

objeto:

$$\mu = \frac{1}{n} \cdot \sum_{i=1}^n d_i \quad (10-A3)$$

onde d_i é o valor da densidade do i -ésimo voxel e n o número de voxels no objeto.

AIII.2.2. Variância das densidades

É uma medida de dispersão dos valores de densidade dos voxels do objeto dada pela a seguir.

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (d_i - \mu)^2 \quad (11-A3)$$

onde σ^2 é a variância dos valores de densidade, d_i é o valor de densidade do i -ésimo voxels, n é o número de voxels no objeto e μ é a média dos valores de densidade.

AIII.2.3. Desvio padrão das densidades

É a medida de dispersão dos valores de densidade dos voxels do objeto dada pela eq. (12-A3).

$$(12-A3)$$

onde σ é a variância dos valores de densidade.

AIII.2.4. Obliquidade

A obliquidade calculada através da eq. (13-A3), onde M_3 é o terceiro momento angular.

$$O = \frac{M_3}{\sigma^3} \quad (13-A3)$$

$$M_3 = \frac{1}{n} \sum_{i=1}^n (d_i - \mu)^3 \quad (14-A3)$$

AIII.2.5. Curtose

A curtose é dada pela eq. (15-A3), onde M_4 é o quarto momento angular.

$$Cur = \frac{M_4}{\sigma^4} \quad (15-A3)$$

$$M_4 = \frac{1}{n} \sum_{i=1}^n (d_i - \mu)^4 \quad (16-A3)$$

AIII.2.6. Energia

A energia é calculada pela eq. (17-A3).

$$Ene = \sum_{j=1}^L \left(\frac{z_j}{n} \right)^2 \quad (17-A3)$$

onde z_j é número de voxels no objeto com densidade igual ao j -ésimo tom de cinza e L é número total de níveis de cinza.

AIII.2.7. Entropia

A entropia é dada por:

$$(18-A3)$$

onde z_j é número do voxels no objeto com densidade igual ao j -ésimo nível de cinza e L é número total de níveis de cinza.

AIII.3. Medida espacial

AIII.3.1. Posição relativa

A posição relativa do objeto é dada pela distância euclidiana entre o centro de massa do objeto e o centro da fatia:

$$Pos = \sqrt{(c_x - e_x)^2 + (c_y - e_y)^2} \quad (19-A3)$$

onde c_x e c_y são as coordenadas do centro de massa do objeto e e_x e e_y são as coordenadas do centro de massa de uma fatia.

AIII.4. Medidas de textura

Haralick et al. (1973) determinou 13 medidas de textura baseadas na matriz de coocorrência apresentada a seguir.

Matriz de coocorrência de níveis de cinza (GLCM – *gray-level co-occurrence matrix*)

GLCM é uma matriz contendo a frequência com que diferentes combinações de valores de intensidades ocorrem na imagem de acordo com uma determinada distância entre voxels. A GLCM é uma matriz quadrada já que o número de linhas deve ser igual ao número de colunas que por sua vez é igual ao número de níveis de cinza na imagem. Um elemento $m(i,j|d)$ é a frequência com que dois voxels, separados por uma distância $d(\Delta x, \Delta y, \Delta z)$ ocorrem com intensidades i e j . Neste trabalho, as matrizes de coocorrência foram montadas somente dentro dos segmentos.

A Figura 30 exemplifica uma matriz GLCM com distância $d(2,0,1)$ para

uma imagem I com 4 níveis de cinza de dimensão $5 \times 5 \times 4$. O elemento (1,3) da matriz GLCM contém o valor 3, porque existem 3 ocorrências na imagem onde o valor 1 e 3 estão distantes 2 posições verticalmente, na mesma posição horizontal e distantes em uma fatia. Em outras palavras, $m(1,3|\Delta x=2,\Delta y=0,\Delta z=1) = 3$ já que:

- $I(1,3,1) = 1$ e $I(1+2,3+0,1+1) = I(3,3,2) = 3$
- $I(1,1,3) = 1$ e $I(1+2,1+0,3+1) = I(3,1,4) = 3$
- $I(3,5,3) = 1$ e $I(3+2,5+0,3+1) = I(5,5,4) = 3$

Desta mesma forma, são calculados todos os elementos da matriz GLCM.

| | | | | |
|---|---|---|---|---|
| 3 | 2 | 1 | 3 | 4 |
| 2 | 3 | 2 | 4 | 1 |
| 3 | 3 | 4 | 1 | 3 |
| 1 | 3 | 1 | 2 | 3 |
| 3 | 2 | 3 | 1 | 4 |

(a) fatia 1 da imagem

| | | | | |
|---|---|---|---|---|
| 1 | 4 | 4 | 3 | 2 |
| 2 | 2 | 3 | 2 | 1 |
| 2 | 2 | 3 | 3 | 2 |
| 3 | 1 | 1 | 2 | 2 |
| 2 | 1 | 4 | 1 | 2 |

(b) fatia 2 da imagem

| | | | | |
|---|---|---|---|---|
| 1 | 2 | 2 | 4 | 2 |
| 4 | 4 | 2 | 4 | 3 |
| 4 | 2 | 2 | 3 | 1 |
| 2 | 1 | 1 | 1 | 1 |
| 2 | 3 | 1 | 2 | 2 |

(c) fatia 3 da imagem

| | | | | |
|---|---|---|---|---|
| 3 | 2 | 2 | 3 | 3 |
| 3 | 3 | 3 | 2 | 3 |
| 3 | 2 | 3 | 2 | 3 |
| 2 | 3 | 1 | 2 | 3 |
| 3 | 2 | 4 | 2 | 3 |

(d) fatia 4 da imagem

| | 1 | 2 | 3 | 4 |
|---|---|---|---|---|
| 1 | 2 | 1 | 3 | 1 |
| 2 | 5 | 6 | 4 | 1 |
| 3 | 4 | 5 | 3 | 0 |
| 4 | 0 | 7 | 2 | 1 |

(e) GLCM de $d(2,0,1)$

Figura 30 – Exemplo de GLCM em uma imagem 3D.

A dimensão final da GLCM depende do número de valores de níveis de

cinza presentes na imagem. De modo a diminuir o espaço de memória da GLCM, diminuir a sensibilidade a ruídos da imagem original e a esparsidade da GLCM, geralmente faz-se uso da quantização da imagem reduzindo, assim, o número de níveis de cinza.

Dentre as texturas propostas por Haralick et al. (1973), Ohanian & Dubes (1992) mostraram que apenas um pequeno grupo de medidas é suficiente para caracterizar a textura as quais são calculadas a partir da matriz M que nada mais é que a GLCM normalizada de forma que a soma de seus elementos é igual a 1.

Essas medidas são descritas a seguir.

AIII.4.1. Contraste

Mede a variação local de níveis de cinza do objeto, ou seja, o contraste de intensidade entre cada voxel e seus vizinhos em todo o objeto. O Contraste é 0 para um objeto constante.

$$TCon = \sum_{i=1}^L \sum_{j=1}^L M(i, j) \cdot (i - j)^2 \quad (20-A3)$$

onde L é número de níveis de cinza da imagem e $M(i,j)$ é o valor da matriz normalizada de GLCM na linha i e coluna j .

AIII.4.2. Energia

Retorna a soma dos quadrados dos elementos de M :

$$(21-A3)$$

O valor de energia varia entre 0 e 1, sendo 1 para uma imagem constante.

AIII.4.3. Entropia

Mede a dispersão local dos níveis de cinza no objeto. A entropia é calculada da seguinte forma:

$$TEnt = \sum_{i=1}^L \sum_{j=1}^L -M(i, j) \cdot \log(M(i, j)) \quad (22-A3)$$

AIII.4.4. Homogeneidade

Mede a proximidade da distribuição dos elementos em GLCM da diagonal principal:

$$THom = \sum_{i=1}^L \sum_{j=1}^L \frac{M(i, j)}{1 + |i - j|} \quad (23-A3)$$

A homogeneidade é 1 para uma matriz GLCM diagonal.

AIII.4.5. Correlação

É uma medida de o quão correlato é um voxel de seus vizinhos.

$$TCorr = \sum_{i=1}^L \sum_{j=1}^L \frac{(i - \mu_i) \cdot (j - \mu_j) \cdot M(i, j)}{\sigma_i \cdot \sigma_j} \quad (24-A3)$$