

# Classificação de Textura em Imagens com Redes Neurais Artificiais para Segmentação de Regiões de AVCi em Tomografias Computadorizadas

Emmanuel Diego G. de Freitas, Suzete Elida N. Correia, Carlos Danilo M. Regis  
Programa de Pós-graduação em Engenharia Elétrica  
Instituto Federal de Educação Ciência e Tecnologia da Paraíba – Campus João Pessoa  
João Pessoa, Paraíba  
diego@ifce.edu.br, suzete@ifpb.edu.br, carlos.regis@ifpb.edu.br

**Resumo**— Imagens de Tomografia Computadorizada (TC) são frequentemente utilizadas como instrumentos de auxílio ao diagnóstico médico, a exemplo do Acidente Vascular Cerebral (AVC). A análise da imagem do crânio é realizada pelo médico de forma visual, o qual localiza a lesão, diferencia o AVC isquêmico do hemorrágico e realiza a segmentação manualmente. Neste artigo é proposto um método de segmentação da região cerebral atingida por AVC isquêmico em imagens de TC simples, baseado na classificação de informações de textura extraídas da imagem, utilizando para isso uma RNA MLP. Nos testes realizados o sistema obteve, em média, 98% de acurácia e 77% de precisão, mostrando-se capaz de segmentar a região cerebral atingida pelo AVC com precisão. Um contorno é delineado automaticamente em volta da região segmentada sem a necessidade de uma intervenção humana.

**Palavras Chave**— *Processamento Digital de Imagens; Acidente Vascular Cerebral; Análise de Texturas; Redes Neurais Artificiais.*

## I. INTRODUÇÃO

Sistemas computacionais concebidos por meio da associação com o conhecimento médico têm possibilitado o desenvolvimento de equipamentos com importantes contribuições para a identificação de doenças e seus tratamentos. Atualmente, o uso desses equipamentos está eminentemente presente na medicina, em aplicações que vão desde simples exames laboratoriais até exames de elevada complexidade [1].

O impacto dessas tecnologias é tão grande que a abordagem diagnóstica médica sofre relevantes influências e vem sendo progressivamente modificada, como por exemplo, com o uso de equipamentos radiológicos cada vez mais sofisticados que geram sinais de qualidade suficiente para evidenciar informações com mínimos detalhes [2], tais como a Tomografia Computadorizada (TC), considerada pelos profissionais do meio uma das inovações médicas mais importantes desde a descoberta dos raios-X [3]. Movidas pela importância desse contexto, diversas empresas têm buscado desenvolver os mais variados tipos de equipamentos médicos, com o propósito de oferecer ferramentas de auxílio ao diagnóstico capazes de diminuir a subjetividade dos resultados, bem como o tempo de recebimento dos mesmos para início do tratamento.

Segundo Silva [4], anualmente, 15 milhões de pessoas em todo o mundo são vítimas de Acidente Vascular Cerebral (AVC), dos quais 5 milhões morrem e outros 5 milhões ficam permanentemente incapacitados, caracterizando o AVC como uma das patologias que mais incapacitam para a realização das atividades cotidianas [5]. Haja vista o grande número de casos e as graves consequências dos AVCs, pesquisas para desenvolvimento de sistemas que auxiliem o diagnóstico do médico especialista, especificamente na análise de imagens de TC simples do cérebro, podem contribuir com a oferta de meios para avaliação do desenvolvimento da doença, bem como a resposta da mesma ao tratamento adotado

Oliveira [6], afirma que existem várias síndromes neurológicas vasculares que permitem um diagnóstico topográfico (localização da lesão no sistema nervoso) relativamente preciso. A definição correta da etiologia vascular e ainda, a diferenciação entre um evento isquêmico (AVCi) e hemorrágico (AVCh) só é possível com estudo da imagem do crânio, obtida através de TC, sem a utilização de contraste. Tal técnica pode evidenciar, dependendo do tempo de evolução, o tipo do AVC e o território envolvido.

Normalmente a análise das imagens é realizada de forma visual por um profissional da área médica, o qual destaca a presença da patologia manualmente na imagem [1]. Neste artigo é proposto um método computacional baseado em classificação de informações de textura para segmentação de regiões de AVCi em imagens de TC obtidas sem contraste, capaz de oferecer algum nível de automação ao diagnóstico. São empregadas na descrição das texturas três descritores de Haralick: soma das médias, homogeneidade e correlação. Na classificação é empregada uma Rede Neural Artificial (RNA) MLP com três pontos de entrada, uma camada oculta com três neurônios escondidos e um neurônio da camada de saída, treinada segundo o algoritmo *backpropagation*.

## II. MATERIAIS E MÉTODOS

### A. Base de Dados

A base de imagens utilizada para os testes é composta por 10 imagens de Tomografia Computadorizada de 512 x 512 s, obtidas seguindo o protocolo crânio rotina sem contraste. Nessa base encontram-se sete imagens de pacientes com ACVi

e 3 imagens de pacientes sem AVC. Na Fig. 1 são ilustradas as imagens utilizadas.

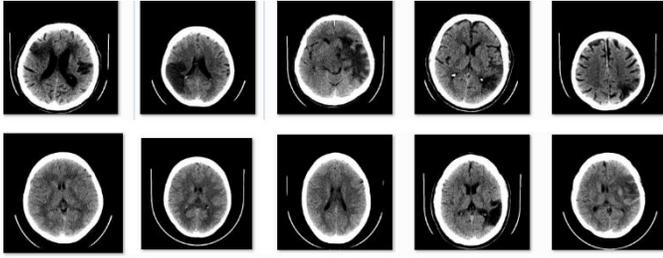


Fig. 1. Imagens utilizadas para teste do sistema.

Cada imagem pertence a um exame de TC completo que contém um conjunto de 21 fatias de cada paciente, codificadas segundo o padrão DICOM para imagens médicas. No entanto, para este estudo optou-se por selecionar as fatias medianas, que foram convertidas ao formato JPEG utilizando uma técnica de janelamento [3], com o objetivo de realçar os níveis de cinza dos *pixels* associados aos tecidos do cérebro. A janela nada mais é que uma estratégia para equalizar o histograma da imagem dentro de uma faixa de valores que torne possível a distinção dos níveis de cinza em uma análise visual humana.

### B. Descritores de Haralick

Em um trabalho pioneiro Haralick *et al* [7] estabelecem métricas de textura para uma imagem digital, ou parte dela, extraídas a partir de uma matriz de co-ocorrência obtida através dos níveis de cinza da imagem analisada. Essas métricas, denominadas descritores de Haralick, são obtidas através de cálculos de domínio espacial e na abordagem estatística de segunda ordem, e baseiam-se na ideia de que toda a informação de textura de uma imagem está contida total ou parcialmente em relações espaciais entre os seus tons de cinza. No total foram propostas catorze medidas, das quais três são empregadas neste trabalho como atributos para a classificação das texturas que representam tecidos cerebrais na TC. São elas:

$$\text{Correlação} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j) \cdot \left[ \frac{(i-\mu_i)(j-\mu_j)}{\delta_i \delta_j} \right] \quad (1)$$

$$\text{Homogeneidade} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{p(i,j)}{1+(i-j)^2} \quad (2)$$

$$\text{Soma das Médias} = \sum_{i=2}^{2N_g} i \cdot p_{x+y}(i) \quad (3)$$

Todas as funções de Haralick são calculadas a partir de uma matriz de co-ocorrência dos tons de cinza da imagem, em que  $p(i,j)$  indica o número de vezes que um *pixel* com nível de cinza  $i$  aparece na posição especificada pelo par  $(d, \theta)$  em relação a um *pixel* de tonalidade  $j$ . É definido que:

- $d$  é a distância em *pixels* entre um nível de cinza  $i$  (*pixel* de referência) e um nível de cinza  $j$  na imagem;
- $\theta$  define a posição do nível de cinza  $j$  dentro de uma vizinhança de *pixels*, que pode assumir as direções  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ou  $135^\circ$ .

Na Fig. 2 é mostrado um teste para avaliação da eficácia de classificação desses descritores, onde se percebe classes separadas para os diferentes tipos de textura analisadas.

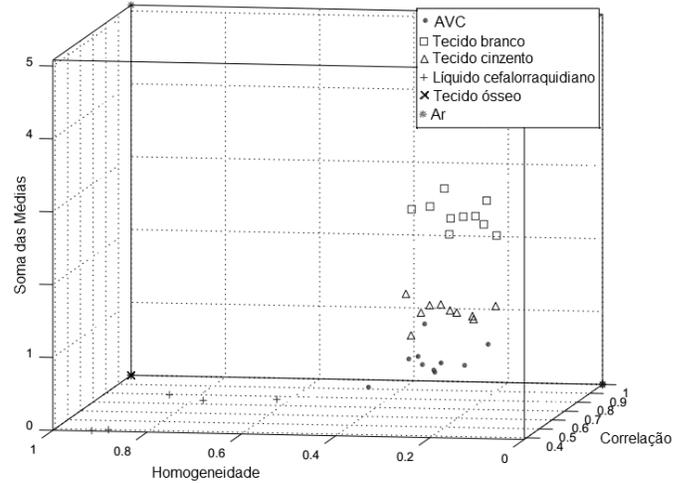


Fig. 2. Teste dos descritores escolhidos para a classificação.

Os pontos mostrados na Fig. 2 foram retirados de uma única imagem, na qual observou-se as medidas dos três descritores em dez amostras de cada uma das regiões que representam: o AVC, tecido branco, tecido cinzento, tecido ósseo, líquido cefalorraquidiano e ar (região negra externa ao crânio – fundo da imagem).

### C. Classificação

O sistema proposto é baseado na classificação de cada *pixel* de uma TC a partir da avaliação da textura caracterizada por sua vizinhança. Esta classificação fica a cargo de uma RNA MLP, cuja única saída deverá informar se o nível de cinza do *pixel* corresponde ou não a uma região de AVCi.

A RNA foi desenvolvida em linguagem C++ e emprega o algoritmo *backpropagation*, na fase de treinamento, para ajustes dos pesos. A topologia da rede neural implementada pode ser observada na Fig. 3, por meio da qual é possível perceber o uso de uma camada de entradas contendo três neurônios (um para cada descritor de textura calculado), uma camada escondida com três neurônios e uma camada de saída com um único neurônio, que fornecerá o nível de cinza para o *pixel* central de uma vizinhança analisada. Para todos os neurônios foi empregada uma função de ativação do tipo sigmoide.

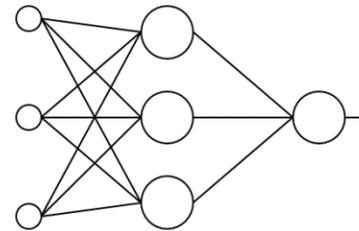


Fig. 3. Representação da topologia adotada para a RNA.

Na fase de treinamento, após a leitura da imagem de TC, são escolhidos através de cliques do *mouse*, pontos na imagem (*pixels*) para representar os tecidos cerebrais, os quais servirão

de amostras para treinamento da RNA. Após a conclusão das escolhas, são armazenadas as orientações ( $x$  e  $y$ ) de cada um dos *pixels* selecionados, que por sua vez receberão um valor de saída desejada como, por exemplo, 1 (um) para os pontos de regiões com AVCi e 0 (zero) para *pixels* de outras regiões. Na Fig. 4 é ilustrado o diagrama em blocos do algoritmo empregado para treinamento da rede neural artificial.

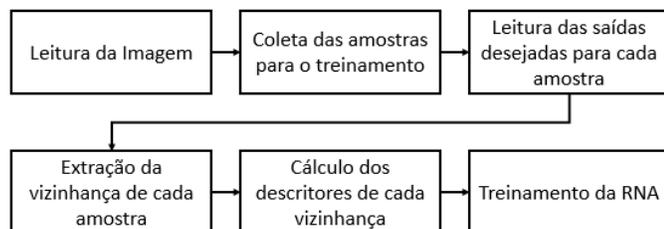


Fig. 4. Algoritmo para treinamento da RNA.

Para cada *pixel* selecionado é criada uma vizinhança, uma matriz 9x9, da qual calcula-se a matriz de co-ocorrência normalizada e dela obtém-se os três descritores de Haralick descritos anteriormente. Esses descritores são apresentados como entradas para a RNA, que por sua vez será treinada seguindo o algoritmo *Backpropagation*. Os valores dos pesos são salvos em arquivo de texto e poderão ser carregados pelo módulo de execução da RNA. O algoritmo de teste, realizado para cada um dos *pixels* selecionados, pode ser observado na Fig. 5.

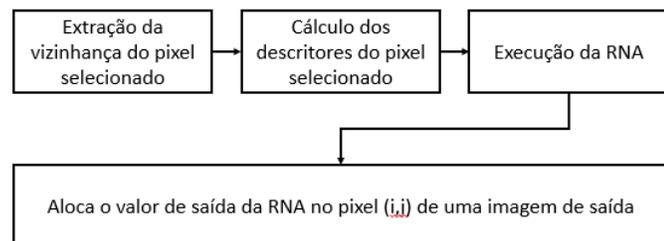


Fig. 5. Processo realizado em cada *pixel* da imagem a ser segmentada.

Para o teste, uma imagem de TC é colocada na entrada do sistema. Para cada *pixel* dessa imagem é considerada uma vizinhança 9x9 e extraídos os descritores de Haralick. O resultado do algoritmo de teste da RNA é uma imagem em que cada *pixel* é a resposta do neurônio de saída aos descritores apresentados. Como a função de ativação da camada de saída é uma sigmoide, a imagem de saída dessa etapa não é binarizada, ao invés disso cada *pixel* recebe um nível de cinza da RNA. Para garantir uma região melhor segmentada, a imagem de saída da RNA é processada por uma função de binarização que segue o método de Otsu [8] para determinação do limiar. A Fig. 6 ilustra o processo de segmentação da região de AVC através da RNA.

Como forma de eliminar falsos positivos, oriundos de regiões cuja textura se assemelha a do AVC, é realizado uma etapa de pós-processamento, onde as regiões segmentadas são analisadas e, por meio dos momentos invariantes de Hu [9], são calculados seus centroides (coordenadas de centro de massa,  $x_c$  e  $y_c$ ) e suas áreas (momento de ordem zero,  $m_{00}$ ), de forma que, com esses valores quantificados, uma filtragem é realizada com o propósito de desconsiderar regiões de área

muito pequena ou com centroide muito próximo ao centro. O resultado desse pós-processamento pode ser observado na Fig. 6 (c).

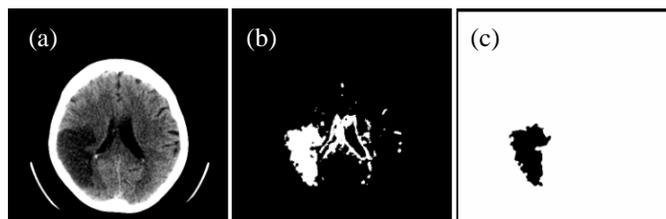


Fig. 6. (a) TC utilizada para teste. (b) resultado obtido com a binarização da saída oferecida pela RNA (c) pós processamento sobre a saída obtida.

### III. RESULTADOS

Os resultados fornecidos pela RNA, foram aproveitados de forma que a segmentação obtida fosse utilizada para dar destaque ao AVCi na imagem de TC. Para tanto, as bordas da região segmentada foram sobrepostas aos pontos da imagem original não processada, criando um efeito de contorno na área com AVCi. Esse contorno, dado em linhas vermelhas (visualiza-se branca neste artigo), pode ser observado na Fig. 7.

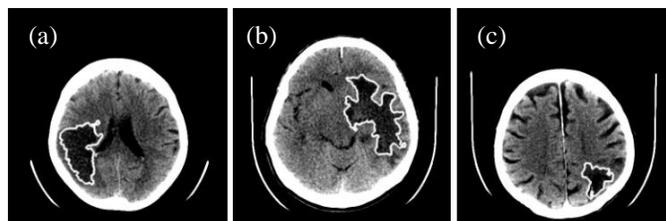


Fig. 7. Exemplos de imagens obtidas ao final do processamento.

Para a realização dos testes a RNA foi treinada com uma das imagens da base e testada com as demais. A imagem utilizada no treinamento é de um paciente com AVCi. Foram coletados 10 pontos para representar as regiões contendo o AVC isquêmico e 25 pontos para as outras regiões. O ajuste dos pesos foi feito sob uma taxa de aprendizagem de 0,35 e o critério utilizado para o treinamento foi o número de épocas, definido para 7000 iterações após diversos testes de desempenho da rede neural.

Na Tabela I são mostrados os valores obtidos, a partir do classificador proposto, para cada uma das imagens de 512 x 512 *pixels* analisadas. Para a obtenção desses dados, uma base com regiões segmentadas manualmente foi criada, e uma rotina de software simples foi desenvolvida para comparar os *pixels* da cor utilizada na segmentação manual com os *pixels* pretos das imagens obtidas no pós-processamento (ex. Fig. 6 (c)). Esta comparação permitiu o levantamento automático dos valores de verdadeiros positivos (VP), falsos positivos (FP), verdadeiros negativos (VN) e falsos negativos (FN).

A amostras da Fig. 8(f), Fig. 8(g) e Fig. 8(h) são de pacientes sadios, portanto, sem verdadeiros positivos quanto a presença de *pixels* de uma região de AVCi. Na Tabela II, são apresentados os resultados da sensibilidade, precisão e

acurácia, obtidas através do teste de validação proposto (treinamento com uma imagem e teste com as demais).

TABELA I. RESULTADOS OBTIDOS APÓS O PROCESSO DE SEGMENTAÇÃO.

Amostra	Verdadeiros positivos	Falsos positivos	Verdadeiros negativos	Falsos negativos
Imagem 0	2583	1	258634	926
Imagem 1	8031	303	251003	2807
Imagem 2	12485	687	243018	5954
Imagem 3	5635	4710	246835	4964
Imagem 4	2814	473	257982	875
Imagem 5	0	0	262144	0
Imagem 6	0	0	262144	0
Imagem 7	0	769	261375	0
Imagem 8	4155	4404	253172	413
Imagem 9	1231	151	259621	1141

Na Fig. 8 são mostrados os resultados visuais obtidos com o método proposto (a ordem das imagens relativa ao seu índice identificador é feita de maneira crescente da esquerda para a direita e de cima para baixo).

TABELA II. MEDIDAS USADAS PARA AVALIAÇÃO DO CLASSIFICADOR.

Amostra	Sensitividade	Precisão	Acurácia
Imagem 0	0,7361	0,9996	0,99646
Imagem 1	0,7410	0,9636	0,9881
Imagem 2	0,6770	0,9478	0,9746
Imagem 3	0,5316	0,5447	0,9630
Imagem 4	0,7628	0,8560	0,9948
Imagem 5	1	1	1
Imagem 6	1	1	1
Imagem 7	1	0	0,9970
Imagem 8	0,9095	0,4854	0,9816
Imagem 9	0,5189	0,8907	0,9950

Segundo Nassar [10], a precisão, ou valor preditivo positivo do sistema, refere-se ao grau de certeza o caso pertence à hipótese diagnóstica quando o diagnóstico oferecido pelo sistema é positivo, ou seja, é a proporção de indivíduos verdadeiramente positivos em relação aos diagnosticados positivos (verdadeiros e falsos) apresentados pelo teste. A acurácia, por sua vez, é a proporção de acertos, ou seja, o total de verdadeiramente positivos e verdadeiramente negativos, em relação a amostra estudada. Portanto, a acurácia está relacionada a uma medida de exatidão, enquanto que a precisão ao número de algarismos significativos do valor medido.

A sensibilidade é a capacidade de um teste diagnóstico identificar os verdadeiros positivos nos indivíduos verdadeiramente doentes, portanto, quanto maior a sensibilidade de um teste, maior a chance de detectar a doença [11].

Foram vistos como erros importantes aqueles percebidos na Fig. 8(d), onde uma região central escura é vista como AVCi, a Fig. 8(h), onde percebe-se a marcação de uma área de AVCi um exame de paciente sadio e na Fig. 8(i), onde uma região central é confundida com AVCi. Na Fig. 8(j), é possível

perceber a demarcação de uma região menor que aquela ocupada pelo AVCi.

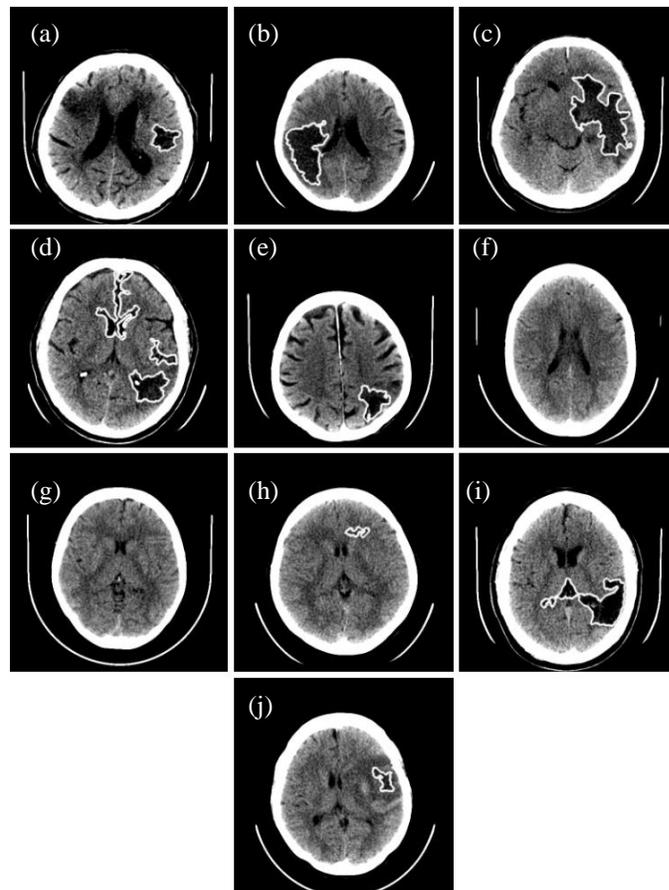


Fig. 8. Resultados visuais obtidos: (a) Imagem 0, (b) Imagem 1, (c) Imagem 2, (d) Imagem 3, (e) Imagem 4, (f) Imagem 5, (g) Imagem 6, (h) Imagem 7, (i) Imagem 8, (j) Imagem 9.

#### IV. CONCLUSÕES

Este artigo descreveu um método desenvolvido com o propósito de segmentar regiões de AVCi em imagens de TC, baseando-se na classificação, com uma rede neural artificial e análise de texturas através dos descritores de Haralick.

Os resultados obtidos para os ajustes feitos no classificador foram satisfatórios, atingindo, em média, 98% de acurácia e 77% de precisão, bem como 77% de sensibilidade. A partir destes resultados é possível afirmar que a técnica consegue, de forma relativamente precisa, classificar as diferentes texturas encontradas nas imagens de TC do cérebro e diferenciar uma área com AVCi de áreas que não correspondem a essa situação.

É importante ressaltar que um contorno é delineado automaticamente em volta da região segmentada sem a necessidade de uma intervenção humana, mostrando-se uma interessante ferramenta de auxílio para o diagnóstico, cujos resultados serão validados pelo médico usuário, não sendo ainda possível ser utilizada como equipamento para diagnóstico médico automatizado.

## REFERENCIAS

- [1] J. G. Webster, *Medical Instrumentation Application*, Wiley, 2009.
- [2] S. C. Salomão, “Integrando Sistemas de Auxilio ao Diagnostico no Sistema Gerenciador de Imagens Médicas,” *Dissertação de Mestrado, Salomão, S. C. Integrando Sistemas de Auxilio ao Diagnostico no Sistema Gerenciador de Imagens Médicas, Escola de Engenharia de São Carlos/ Faculdade de Medicina de Ribeirão Preto*, 2010.
- [3] D. N. B. Monteiro, “Estudo sobre a Visualização de Imagens Médicas Obtida por Exames Virtuais,” *Dissertação de Mestrado, Programa de Pós-Graduação em Computação, Universidade Federal Fluminense*, 2005.
- [4] E. J. A. Silva, “Reabilitação após o AVC,” *Dissertação de Mestrado, Faculdade de Medicina/ Universidade do Porto*, 2010.
- [5] HCI, “ANGIOPLASTIA PARA A PORÇÃO PETROSA DA ARTÉRIA CARÓTIDA INTERNA,” *Boletim Informativo do Hospital*, nº 18, pp. 2-3, 2010.
- [6] M. S. d. Oliveira, “Análise de Textura em Imagens Cerebrais: aplicações em Acidente Vascular Cerebral Isquêmico, Epilepsia Mioclônica Juvenil, Doença de Machado-Joseph, Déficit Cognitivo Leve e Doença de Alzheimer,” em *Tese de Doutorado, Universidade Federal de Campinas/ Instituto de Física “Gleb Watghin”*, Campinas/SP, 2010.
- [7] R. M. Haralick, K. Shanmugam e I. Dinstein, “Textural Features for Image Classification,” *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 3, nº 6, pp. 610-621, 1973.
- [8] N. Otsu, “A Threshold Selection Method from Gray-Level Histograms,” *IEEE Trans. Systems, Man and Cybernetics*, vol. 9, nº 1, pp. 62-66, 1979.
- [9] M. K. Hu, “Visual Pattern Recognition by Moment Invariants,” *IRE Transactions on Information Theory*, vol. 8, nº 2, pp. 179-187, 1962.
- [10] S. M. Nassar, “SISTEMAS ESPECIALISTAS PROBABILÍSTICOS - MATERIAL DIDÁTICO DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA,” 01 junho 2012. [Online]. Available: [http://www.inf.ufsc.br/~silvia/disciplinas/sep/material\\_didatico/MaterialDidatico.pdf](http://www.inf.ufsc.br/~silvia/disciplinas/sep/material_didatico/MaterialDidatico.pdf). [Acesso em 14 junho 2015].
- [11] A. M. B. Menezes e I. d. S. d. Santos, “Curso de epidemiologia básica para pneumologistas: 4ª parte – Epidemiologia clínica,” *Jornal de Pneumologia*, vol. 25, nº 6, pp. 321-326, 1999.
- [12] A. C. Kihana, B. U. Unisto, R. P. Trombini, R. P. Setti, F. S. Amorim e A. F. Souza Jr., ““ Raios-x” a grande descoberta da medicina e a revolução mediante tecnologias,” *Anais da I Jornada de Radiologia da UNIP Campinas*, vol. I, nº 1, p. 15, 2011.
- [13] M. C. Alegro e R. d. D. Lopes, “Aplicação de Análise de Textura na Segmentação de Tumores de Cérebro em Imagens por Ressonância Magnética,” *Congresso Brasileiro de Informática em Saúde*, 29 Novembro 2008.