

Detecção do Acidente Vascular Cerebral Hemorrágico em Imagens de Tomografia Computadorizada Utilizando Limiarização

Cecília Burle de Aguiar, Walisson da Silva Soares, Marília Gabriela Alves Rodrigues Santos, Marina de Oliveira Alencar, Severino Aires Araújo Neto e Carlos Danilo Miranda Regis

Resumo— Este artigo apresenta uma técnica de limiarização para detecção de acidente vascular cerebral hemorrágico (AVCh) em imagens de tomografia computadorizada (TC) de cérebro. Foram utilizados operadores morfológicos, limiarizações e operações entre imagens simples no processamento, com o objetivo de realizar essa detecção com o menor tempo de processamento possível e um baixo custo computacional. Assim, criando uma ferramenta computacional (CAD - *Computer-Aided Detection/Diagnostic*) viável para auxiliar profissionais da saúde na detecção do AVCh sobretudo em serviços de saúde não especializados em radiologia. Foram obtidos ótimos resultados, como uma sensibilidade e acurácia de 100% para a base de dados utilizada.

Palavras-Chave— AVCh, Limiarização, Tomografia Computadorizada, Processamento de Imagem.

Abstract— This article presents a thresholding technique to detect hemorrhagic stroke in computed tomography images of head. Were used morphological operators, thresholding and easy operations between images on processing. Aiming execute this detection with as smaller time as possible and low computational cost. Thus, creating a viable computational tool (CAD - *Computer-Aided Detection/Diagnostic*) to help health professionals on the hemorrhagic stroke detection, mainly on health services do not specialize in radiology. Excellent results were obtained, as a sensitivity and accuracy 100 % for the database used.

Keywords— Hemorrhagic stroke, Thresholding, Computed Tomography, Image processing.

I. INTRODUÇÃO

O acidente vascular cerebral (AVC) é a doença neurológica mais frequente e responsável pelo maior número de mortes no Brasil [1]. O AVC pode ser classificado em dois tipos: hemorrágico (AVCh), decorrente da ruptura de vasos sanguíneos que causa um extravasamento de sangue para o cérebro; e isquêmico (AVCi), decorrente da insuficiência de suprimento sanguíneo cerebral. Os sintomas clínicos dos dois são extremamente similares, porém o tratamento é completamente diferente. Assim, a diferenciação entre os dois tipos é de essencial importância [2].

Segundo a Organização Mundial de Saúde (OMS), estima-se uma tendência ao aumento progressivo do número de óbitos atribuídos às doenças cerebrovasculares, que provavelmente

alcançarão 12,1% da mortalidade mundial até 2030 [3]. Cerca de 10% de todos os AVCs são do tipo hemorrágico e normalmente ocorrem mais cedo que os AVCi, e os principais fatores de risco para o acometimento do AVCh são a hipertensão arterial e o aumento da idade [4].

A TC e a ressonância magnética (RM) são as duas modalidades utilizadas regularmente para visualização cerebral. A TC é mais utilizada, pois há uma maior disponibilidade do equipamento e menor custo para realização desse exame. Na maioria dos casos, a TC fornece informações necessárias para se realizar decisões durante os atendimentos de emergência [5].

O AVCh é representado na TC como uma hiperdensidade (branco) dentro dos tecidos cerebrais sadios, e a sua detecção é uma das primeiras tarefas na interpretação de TCs de cérebro em pacientes que sofrem de distúrbios neurológicos agudos ou de lesões na cabeça. Apesar de normalmente haver um rápida detecção da hemorragia, a interpretação pode ser difícil quando a lesão é pequena ou o profissional da saúde que observa o exame é inexperiente, pois existem outras patologias e outras estruturas cerebrais que se apresentam de forma semelhante, hiperdensa, na TC [6].

O método padrão para identificação das lesões hemorrágicas é a delimitação manual dos tecidos anormais do cérebro por profissionais da radiologia treinados, porém isso demanda muito tempo, e o método manual pode gerar variabilidade de acordo com o operador [7]. Essa detecção da lesão é importante não só para o diagnóstico, como também para a recuperação da área afetada [8].

Uma detecção automática realizada por um CAD da região hiperdensa pode reduzir o tempo de delimitação, remover a variabilidade na detecção em relação ao operador [7]. Dessa forma, como também existem muitos serviços de saúde no interior do Brasil que não possuem especialistas em radiologia, essa identificação automática e rápida das áreas de hemorragia pode auxiliar os profissionais de saúde a fazer o diagnóstico e intervirem com um tratamento adequado, melhorando o prognóstico dos pacientes [9].

Existem poucos métodos propostos para detecção de áreas de AVC por imagens de TC, a maior parte desses são para detecção exatamente das áreas de hemorragia. Existem vários trabalhos que implementam algoritmos que utilizam diversas transformadas nas imagens [8], ou técnicas de lógica *fuzzy* [6], descritores de Haralick [10], entre outras operações que terminam por aumentar muito o tempo de processamento e o custo computacional dessa ferramenta de CAD.

Cecília Burle de Aguiar, Walisson da Silva Soares, Marília Gabriela Alves Rodrigues Santos, Marina de Oliveira Alencar, Severino Aires Araújo Neto e Carlos Danilo Miranda Regis, Coordenação de Engenharia Elétrica, Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, João Pessoa-PB, Brasil, E-mails: burlececilia@gmail.com, walissonsilva10@gmail.com, gmarilialves@gmail.com, marina.alencar.93@gmail.com, danilo.regis@ifpb.edu.br.

Este artigo tem como objetivo elaborar um algoritmo para detectar as áreas de hemorragia cerebral causadas por AVC utilizando técnicas de limiarização simples, sinalizando-as em verde para destacar sua existência. Dessa forma, auxiliando o profissional da saúde no diagnóstico do AVC da forma mais rápida possível, visando a diminuição do tempo de processamento e do custo computacional.

II. IMAGENS MÉDICAS

O padrão *DICOM* (*Digital Imaging and Communication in Medicine*) é utilizado na maioria das áreas médicas que utilizam imagens digitais, como a cardiologia, endoscopia, mamografia, oftalmologia, radiologia, cirurgia, etc., também se estendendo a medicina veterinária. As imagens médicas utilizadas neste trabalho foram as de tomografia computadorizada do cérebro, todas elas seguindo o padrão *DICOM*.

Esse padrão é um conjunto de normas, que surgiu para facilitar e unificar a comunicação e o armazenamento de informações e imagens geradas pelas máquinas médicas. Um dos diferenciais desse padrão é que em um único arquivo se tem a imagem e as informações adicionais, como dados da instituição que realizou o exame, a identificação e os dados antropométricos do paciente e especificações técnicas do equipamento médico utilizado [11].

A TC armazena imagens no padrão *DICOM* que é uma imagem composta por 16 bits, 4 bits de informação textual e 12 bits de exibição. O valor de atenuação de um *pixel* localizado em (i, j) é expresso em unidades de Hounsfield (*UH*), que é relacionado com o nível de cinza da imagem *DICOM* pela equação 1. A configuração do redimensionamento de inclinação (m) e de interceptação (a) encontram-se nas informações textuais da imagem *DICOM* [12]. O intervalo dinâmico em *UH* é amplo, de -1000 até 1000.

$$UH(i, j) = m \times Y(i, j) + a \quad (1)$$

A TC consegue medir a atenuação do feixe de raios X que passa em uma seção do corpo em diferentes ângulos. E depois, com essas medições um computador é capaz de reconstruir imagens do interior do corpo. As imagens obtidas são baseadas em uma examinação separada de uma série de seções transversais contínuas, separação em finos cortes [13].

Essa atenuação é expressa em *UH*, nomeada em homenagem ao cientista que desenvolveu a tomografia computadorizada [14]. Para elevar as pequenas diferenças entre diferentes tipos de tecidos, é utilizada uma transformação linear do coeficiente real de atenuação medido. Essa transformação é definida pela Equação 2.

$$UH = 1000 \times \frac{\mu_X - \mu_{agua}}{\mu_{agua} - \mu_{ar}} \quad (2)$$

em que μ_X é atenuação linear do tecido do material X , e μ_{agua} e μ_{ar} são os coeficiente de atenuação da água e do ar, respectivamente. Por definição, a água na escala Hounsfield é definida como $0UH$, o ar tem valores mais negativos, como $-1000UH$, e os ossos, os mais positivos, cerca de $1000UH$ [13].

Na Tabela I são ilustrados os valores de atenuação de todos os tecidos e estruturas presentes nas imagens de TC do crânio, lembrando ainda que a aparência de cada um desses componentes nessas imagens é realizada da seguinte forma, quanto maior o valor de atenuação relativa do tecido na TC, sua representação é mais branca. E quanto menor o valor, mais preta é realizada a representação desse tecido.

TABELA I
CLASSIFICAÇÃO DOS RESULTADOS.

Tecido	Valores de atenuação
Metal	1.000
Osso/Cálcio	100 a 1.000
Sangue Agudo	80 a 85
Sangue Subagudo	25 a 50
Sangue Crônico	0 a 25
Substância Cinzenta	35 a 40
Substância Branca	25 a 30
Água	0
Gordura	-100
Ar	-1.000

III. LIMIAZIZAÇÃO

A segmentação por intensidade ou limiarização (*thresholding*) é uma das técnicas mais simples e uma das mais utilizadas na segmentação, devido a sua facilidade de implementação e sua velocidade de processamento. A divisão da imagem em regiões é feita diretamente com base no valor da intensidade do *pixel* e/ou propriedades desse valor [15].

A limiarização é uma técnica que separa os *pixels* de uma imagem em duas classes, determinando-se um limiar de intensidade para eles. Assim, os *pixels* que possuem uma determinada faixa de valores representam uma classe, e os demais *pixels* representam outra classe. Esse limiar pode ser aplicado de forma global ou local [16].

Em uma limiarização global há a identificação do objeto e do fundo comparando os *pixels* com um limiar definido (*threshold*) e utiliza a binarização para segmentar a imagem. Os *pixels* que apresentam maiores intensidades do que o limiar global são considerados objeto e são atribuídos a eles o valor binário 1; aos outros, são atribuídos valor binário 0, e são definidos como fundo da imagem. Essa técnica é extremamente rápida, não possui quase nenhum custo computacional, podendo ser usada até em aplicações em tempo real [16] e dada por:

$$g(x, y) = \begin{cases} 1, & \text{se } i(x, y) \geq T \\ 0, & \text{se } i(x, y) < T \end{cases} \quad (3)$$

em que $g(x, y)$ é a imagem de saída, $i(x, y)$ a imagem de entrada e T o limiar definido. Quando esse T é uma constante aplicada a toda imagem esse processo é o de limiarização global. Se o valor de T não permanece igual em toda imagem, trata-se de uma limiarização variável. Se o valor do limiar depender das propriedades da vizinhança (x, y) , ocorre uma limiarização local [15].

IV. MATERIAIS E MÉTODOS

Nesta seção é apresentada a base de dados utilizada, a metodologia aplicada neste trabalho, o detalhamento do algoritmo desenvolvido e uma avaliação estatística desse algoritmo. É feita a descrição das etapas do processamento digital feito nas imagens de tomografia computadorizada disponíveis.

Neste trabalho foi desenvolvida uma técnica para a detecção das áreas de hemorragia nas imagens de TC do crânio. O algoritmo foi desenvolvido utilizando-se a biblioteca *OpenCV*, na linguagem *C++*, e baseia-se na simples utilização de limiares para detecção dessas áreas que apresentam hemorragia, prezando por um baixo tempo de processamento.

A. Base de Dados

A base de dados utilizada neste trabalho é composta por imagens de tomografia computadorizada de crânio de 307 pacientes. Desses 307, foram selecionados apenas 37 pacientes, pois esses exames não foram obtidos de um serviço de emergência e a maior parte deles eram normais ou com doenças crônicas.

Dos 37 pacientes 7 deles apresentam-se dentro da normalidade, 3, com AVCh, 12, com AVCi, 1, com hemorragia subaracnoidea, e 14, com outras patologias, como perda volumétrica, leucoaraiose, tumor, aneurisma, calcificações, entre outras. Essa base de dados foi disponibilizada pelo Núcleo de Estudos e Pesquisa em Imaginologia (NEPI) da Universidade Federal da Paraíba (UFPB).

Todas as imagens seguem o padrão *DICOM* de imagens médicas e possuem dimensões de 512×512 . Cada exame de TC de cada paciente possui cerca de 20 imagens, com o espaçamento de 8 mm entre os cortes axiais da cabeça. Os laudos de cada paciente foram realizados por um médico especialista na área de radiologia, que são utilizados como padrão ouro de comparação. Este trabalho utiliza imagens obtidas de exames com seres humanos, portanto, obtivemos a aprovação do Comitê de Ética em Pesquisa do IFPB para o nosso projeto, cujo número de registro é: 1.293.095.

B. Metodologia

O algoritmo de detecção de AVCh utilizando limiarização, é baseado em um limiar ótimo, e a partir da análise da intensidade de nível de cinza de cada *pixel* é realizada a decisão dele pertencer à região de hemorragia. Após a detecção da área de provável AVCh é realizada a etapa de correlação entre os resultados do processamento das imagens com os achados descritos pelo médico radiologista nos laudos, para a análise estatística do algoritmo. O fluxograma do processamento realizado nas imagens de TC de cérebro é mostrado na Figura 1.

O processamento das imagens é iniciado com a aquisição das imagens no padrão *DICOM* da TC do paciente da base de dados. Porém as imagens *DICOM* possuem uma quantidade de informações que exigem um número de *bits* superior ao que a biblioteca do *OpenCV* suporta. Em outras palavras, cada *pixel* das imagens *DICOM* é formado por 16 *bits*, e cada *pixel* das imagens suportadas pelo *OpenCV* é constituído por, no máximo, 8 *bits*.

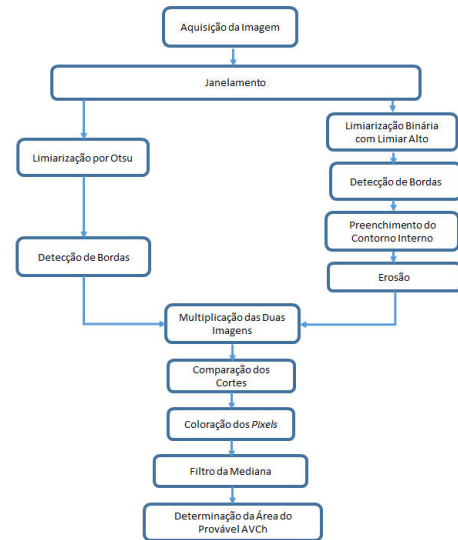


Fig. 1. Fluxograma do algoritmo desenvolvido.

Para solucionar essa incompatibilidade foi realizado o janelamento da imagem. Sendo essa técnica, um recurso computacional que permite a escala de cinza possa ser modificada, aumentada ou diminuída, de forma a melhorar a diferenciação entre certas estruturas, dependendo da necessidade. A sensibilidade pode ser melhorada, reduzindo a largura da janela, pois a tomografia pode gerar cerca de 2000 tons de cinza, enquanto o olho humano tem a capacidade de diferenciação de escala de cinza de apenas 10 a 60 tons [13].

Dessa forma, uma imagem *DICOM* que pode conter uma faixa de intensidades de cinza de -2048 a 2048 (normalmente essa faixa só varia de -1000 a 1000) foi janelada para formar uma imagem com uma nova faixa de intensidades possíveis, de 0 a 255. O intervalo dos valores dos *pixels* que são importantes para definir os tecidos moles do cérebro da imagem são transformados em 256 tons distintos. A definição do janelamento é definida pela Equação 4, e essa janela é uma forma de mostrar apenas a faixa de tons de cinza que é interessante, de forma a adaptar a capacidade de visualização dos dados obtidos [13].

$$F(i, j) = 255 \times \frac{[UH(i, j) - (C - \frac{W}{2})]}{W} \quad (4)$$

Os valores para o centro (C) e a largura da janela (W) foram 50 e 82, respectivamente. Pois foi observado que esses valores melhor definiram os tecidos moles do cérebro [12]. A nova imagem formada possui *pixels* representados por apenas 8 *bits*, ou seja, 256 intensidades de tons de cinza, que variam de 0 a 255.

Após o janelamento, o processamento é separado em duas partes, para que haja a exclusão da parte externa ao tecido cerebral, pois como o AVCh é o extravasamento de sangue nesse tecido, então as áreas que são externas a ele não são necessárias para o processamento. E também a posterior indicação da área de hemorragia causada por AVCh.

Na primeira parte é realizada uma limiarização para zero utilizando Otsu que resulta um limiar ótimo de segmentação de imagens em duas classes, assim os *pixels* que possuem

intensidade menor que o limiar são definidos como 0, são representados em preto, e aqueles *pixels* com intensidade maior que o limiar, prosseguem com suas próprias intensidades. Depois dessa etapa é obtida uma imagem com todo o crânio e algumas lesões hiperdensas, como AVCh, calcificações, hematoma subdural, entre outros.

Ainda na primeira parte do processamento, sob essa imagem com o crânio e lesões hiperdensas é realizada uma detecção de bordas. Essa imagem é chamada de imagem 1.

A imagem 2 é obtida a partir da segunda parte do processamento desse algoritmo. Nessa parte, é realizada uma limiarização binária com um limiar muito alto (230 *UH*) na imagem após o janelamento. Dessa forma, essa todos os *pixels* com intensidade acima desse limiar são definidos como 1, e representados em branco. E os *pixels* com intensidade menor que esse limiar são definidos como 0, e representados como preto. Assim, apenas o osso e as outras patologias exceto o AVCh são deixadas em branco. Depois disso, é realizada uma detecção de bordas nessa imagem e após é definido como branco todos os *pixels* desde o centro até a primeira borda. Depois de preenchido apenas a borda interior é realizada uma operação morfológica de erosão sobre essa imagem, que exclui a borda mais externa do crânio e determina a imagem 2 como a que corresponde apenas ao tecido cerebral, excluindo o crânio e as calcificações.

Depois de obtidas as duas imagens é realizada a multiplicação da imagem 1 e 2, e a imagem obtida depois dessa multiplicação é em sua maior parte exatamente a parte que corresponde à área de hemorragia do AVCh. Dessa imagem, sabe-se então a posição dos *pixels* que podem ser do AVCh, então é realizada uma comparação dos *pixels* de mesma posição no corte anterior, atual e posterior, pois a área de hemorragia pode acontecer apenas em alguns cortes, e dependendo do seu volume pode aparecer nos cortes adjacentes. Se nas três imagens o *pixel* estiver segmentado pelo processamento, ele é colorido em verde.

A imagem resultante depois dessa parte do processamento possui ainda diversos pontos verdes sozinhos e dispersos pela imagem, para diminuir a dispersão e fazer com que apenas a área com uma maior densidade de pontos verdes continuasse sinalizada, pois essa corresponde exatamente a área do provável AVCh, foi aplicado um filtro de mediana bidimensional 11×11 . Após a aplicação desse filtro é determinado exatamente a área do provável AVCh na imagem de TC de crânio.

C. Análise estatística do algoritmo

A análise do desempenho do algoritmo desenvolvido foi realizada, utilizando três medidas: sensibilidade, especificidade, e eficiência [17], [18]. A sensibilidade (*S*) indica o quanto o algoritmo identifica corretamente a patologia quando ela realmente está presente, ou seja, o quão sensível ele é. Ela é calculada pela relação entre o número de pacientes com AVCh corretamente identificados pelo algoritmo e o número total de pacientes com essa patologia identificados pelo padrão ouro, que é o laudo médico, dada na Equação 5.

$$S = \frac{VP}{VP+FN} \quad (5)$$

Em que *VP* represente o número de verdadeiros positivos, ou seja, os pacientes identificados corretamente pelo algoritmo. E *FN*, os falsos negativos, que são os pacientes que possuem a patologia em questão, mas esta não foi detectada pelo algoritmo.

A especificidade (*Esp*) determina a capacidade do algoritmo de excluir corretamente os pacientes que realmente não apresentam a patologia. É a relação entre os pacientes que o algoritmo não detectou o AVCh e o número de pacientes que realmente não possuem essa doença, seu cálculo é feito pela Equação 6.

$$Esp = \frac{VN}{VN+FP} \quad (6)$$

Em que *VN* identifica os verdadeiros negativos, ou seja, quando não há detecção da patologia e ela realmente não está presente. E *FP*, os falsos positivos, ou quando há a detecção da patologia, mas ela não está presente.

A eficiência (*Ef*) determina a taxa global de correta classificação da detecção de AVCh do algoritmo, ou seja, a competência do algoritmo de detectar corretamente quando há e quando não há a presença da patologia. A Equação 7 define como se dá o cálculo da acurácia, que é a proporção de tudo que foi corretamente detectado e o número total de pacientes avaliados.

$$Ef = \frac{VP+VN}{VP+VN+FP+FN} \quad (7)$$

O padrão-ouro utilizado neste trabalho, como já mencionado anteriormente, foi o laudo fornecido por um radiologista especialista. As imagens que foram detectadas pelo algoritmo que possuíam a patologia foram analisadas uma a uma, a fim de definir se aquela área detectada realmente correspondia ao AVCh. Verificando a correlação caso a caso do laudo e com a imagem de resultado do algoritmo proposto.

V. RESULTADOS

As imagens obtidas após o processamento de todas as imagens dos pacientes que possuíam AVCh são mostrados na Figura 2, 3 e 4, e o processamento do conjunto de 20 imagens de TC de cada paciente foi realizado em cerca de 8 segundos. É possível observar que existem áreas assinaladas em verde, que representam exatamente as áreas de hemorragia causadas pelo AVCh.




Fig. 2. Resultado: imagem de saída do Paciente 1 com AVCh.

Na Tabela II são mostrados os números de casos classificados como verdadeiro positivo (*VP*), verdadeiro negativo (*VN*), falso positivo (*FP*) e falso negativo (*FN*) pelo algoritmo desenvolvido. É possível perceber que não houve detecção da doença incorreta pelo algoritmo, mesmo com uma




Fig. 3. Resultado: imagem de saída do Paciente 2 com AVCh.




Fig. 4. Resultado: imagem de saída do Paciente 3 com AVCh.

grande amostra de outras doenças que existiam na base de dados, inclusive que poderiam ser confundidas por especialistas na TC.

TABELA II
CLASSIFICAÇÃO DOS RESULTADOS.

VP	VN	FP	FN
3	34	0	0

A Tabela III apresenta os resultados da análise estatística do algoritmo de detecção de AVCh desenvolvido. É possível salientar que além dos pacientes que apresentavam o AVCh, haviam outras patologias que se assemelham a essa patologia em imagens de TC na base de dados, devido a intensidade de tons de cinza apresentado, e mesmo assim não foram identificadas pelo algoritmo.

TABELA III
ANÁLISE ESTATÍSTICA DOS RESULTADOS.

S (%)	Esp (%)	Ef (%)
100%	100%	100%

VI. CONCLUSÕES

Neste trabalho foi possível detectar as áreas de hemorragia causadas por AVCh utilizando-se um processamento extremamente simples, sem a utilização de transformada, obtendo-se uma acurácia e uma sensibilidade de 100%. Além disso, o processamento do conjunto de 20 imagens de TC de cada paciente foi realizado em cerca de 8 segundos. Sendo assim, o algoritmo implementado obteve um ótimo resultado para a base de dados utilizada não produzindo nenhum erro e o processamento foi realizado em um curtíssimo intervalo de tempo.

Dessa forma, esse algoritmo pode ser embarcado e usado em serviços de saúde não especializados em radiologia para auxiliar o diagnóstico dessa patologia, a fim de acelerar esse diagnóstico, tornando possível uma intervenção terapêutica

mais rápida, melhorando assim o prognóstico dos pacientes acometidos.

É necessário a realização de testes utilizando outras bases de dados, para validar de forma concreta o algoritmo desenvolvido. E ainda é preciso uma melhor identificação da área acometida pela hemorragia, para que não haja apenas uma detecção, e sim uma ferramenta que auxilie também no entendimento dos problemas clínicos que podem ser apresentados pelos pacientes acometidos, de acordo com a área exata que foi atingida.

REFERÊNCIAS

- [1] J. J. F. de Carvalho, M. B. Alves, G. Á. A. Viana, C. B. Machado, B. F. C. dos Santos, A. H. Kanamura, C. L. Lottenberg, M. C. Neto, and G. S. Silva, "Stroke epidemiology, patterns of management, and outcomes in fortaleza, brazil a hospital-based multicenter prospective study," *Stroke*, vol. 42, no. 12, pp. 3341–3346, 2011.
- [2] G. A. Donnan, M. Fisher, M. Macleod, and S. M. Davis, "Stroke," *The Lancet*, vol. 371, no. 9624, pp. 1612–1623, Maio 2008.
- [3] W. H. Organization, *World health statistics 2008*. World Health Organization, 2008.
- [4] R. M. C. d. Oliveira and L. A. F. d. Andrade, "Acidente vascular cerebral," *Rev. bras. hipertens*, vol. 8, no. 3, pp. 280–290, 2001.
- [5] R. E. Latchaw, M. J. Alberts, M. H. Lev, J. J. Connors, R. E. Harbaugh, R. T. Higashida, R. Hobson, C. S. Kidwell, W. J. Koroshetz, V. Mathews *et al.*, "Recommendations for imaging of acute ischemic stroke a scientific statement from the american heart association," *Stroke*, vol. 40, no. 11, pp. 3646–3678, 2009.
- [6] T. Chan, "Computer aided detection of small acute intracranial hemorrhage on computer tomography of brain," *Computerized Medical Imaging and Graphics*, vol. 31, no. 4, pp. 285–298, 2007.
- [7] C. R. Gillebert, G. W. Humphreys, and D. Mantini, "Automated delineation of stroke lesions using brain ct images," *NeuroImage: Clinical*, vol. 4, pp. 540–548, 2014.
- [8] R. Liu, C. L. Tan, T.-Y. Leong, C. K. Lee, B. C. Pang, C. T. Lim, Q. Tian, S. Tang, and Z. Zhang, "Hemorrhage slices detection in brain ct images," in *ICPR*. Citeseer, 2008, pp. 1–4.
- [9] A. P. D. Binotto, M. S. Torres, I. Sachpazidis, R. Gomes, and C. E. Pereira, "T@ lemed: um estudo de caso de tele-saúde baseado em imagens de ultra-som," in *X Congresso Brasileiro de Informática em Saúde*, 2006, pp. 1273–1277.
- [10] E. D. G. de Freitas, S. E. N. Correia, and C. D. M. Regis, "Classificação de textura em imagens com redes neurais artificiais para segmentação de regiões de avci em tomografias computadorizadas," in *Anais do 12 Congresso Brasileiro de Inteligência Computacional*, C. J. A. Bastos Filho, A. R. Pozo, and H. S. Lopes, Eds. Curitiba, PR: ABRICOM, 2015, pp. 1–5.
- [11] N. E. M. Association, A. C. of Radiology *et al.*, *Digital imaging and communications in medicine (DICOM)*. National Electrical Manufacturers Association, 1998.
- [12] T.-L. Tan, K.-S. Sim, and A.-K. Chong, "Contrast enhancement of ct brain images for detection of ischemic stroke," in *Biomedical Engineering (ICoBE), 2012 International Conference on*. IEEE, 2012, pp. 385–388.
- [13] G. N. Hounsfield, "Computed medical imaging," *Journal of computer assisted tomography*, vol. 4, no. 5, pp. 665–674, 1980.
- [14] A. C. Silva, "Algoritmos para diagnostico assistido de nodulos pulmonares solitarios em imagens de tomografia computadorizada," *Rio de Janeiro: PUC*, 2004.
- [15] R. C. Gonzalez and R. E. Woods, *Processamento de Imagens Digitais*, 3rd ed. São Paulo: Pearson Prentice Hall, 2010.
- [16] S. Nagabhushana, *Computer vision and image processing*. New Age International, 2005.
- [17] W. C. de Almeida Costa, S. L. d. N. C. Costa, F. M. de Assis, and B. G. A. Neto, "Classificação de sinais de vozes saudáveis e patológicas por meio da combinação entre medidas da análise dinâmica não linear e codificação preditiva linear," *Rev. Bras. Eng. Biom*, vol. 29, no. 1, pp. 3–14, 2013.
- [18] A. K. Akobeng, "Understanding diagnostic tests 1: sensitivity, specificity and predictive values," *Acta paediatrica*, vol. 96, no. 3, pp. 338–341, 2007.