

TÉCNICAS DE MELHORIA DE IMAGENS PARA O REALCE DE TUMORES CEREBRAIS EM IMAGENS DE RESSONÂNCIA MAGNÉTICA

IMAGE ENHANCEMENT TECHNIQUES FOR HIGHLIGHTING BRAIN TUMORS IN MAGNETIC RESONANCE IMAGING

KEGLEVICH MORAES, Gabriel¹; ANDRIJAUSKAS, Fabio²;

¹Discente do Curso de Engenharia de Computação, Universidade São Francisco; Campus Bragança Paulista - SP

²Professor Doutor do Curso de Engenharia de Computação, Universidade São Francisco; Campus Bragança Paulista - SP.

fabio.andrijauskas@usf.edu.br

RESUMO. A integração da tecnologia em diversos campos do conhecimento humano, especialmente na intersecção entre medicina e computação, possibilitou a implementação e contribuição para procedimentos relacionados às aquisições de imagens e tratamentos médicos, resultando na melhoria das práticas médicas e conseqüentemente na condição de saúde do paciente. No entanto, a obtenção de imagens, como por meio da ressonância magnética, apresenta diversos desafios, tais como ruídos, distorções e outras características da imagem que podem influenciar a avaliação do exame final. Com a finalidade de mitigar esses problemas, desenvolveu-se neste artigo uma aplicação que recebe imagens de ressonância magnética contendo pacientes com e sem tumores cerebrais. Em seguida, são aplicados métodos de melhoria de contraste como o CLAHE (Contrast Limited Adaptive Histogram Equalization), BCET (Balance contrast enhancement technique) e a equalização de histograma, e então, discute-se quais são as vantagens e desvantagens de utilizar cada método, assim como é explorado a avaliação através da interpretação dos histogramas das imagens resultantes do algoritmo. Ao final, conclui-se que a CLAHE obteve o melhor desempenho entre as técnicas abordadas, destacando os tumores nas imagens, além de ressaltar outras regiões fundamentais para o diagnóstico do paciente.

Palavras-chave: equalização de histograma; melhoria de contraste; CLAHE; BCET; ressonância magnética.

ABSTRACT. The technology integration across many fields of human knowledge, particularly the intersection of medicine and computer science, made possible the implementation and contribution to procedures related to medical imaging acquisition and medical treatments. This has resulted in the enhancement of medical practices and, consequently, in the overall health condition of patients. However, obtaining images, such as magnetic resonance imaging, unveils several challenges, including noise, distortions, and others images characteristics that can influence the medical assessment. In order to relieve these issues, this paper presents an application that receives magnetic resonance images containing patients with and without brain tumors. Subsequently, contrast enhancement methods such as CLAHE (Contrast Limited Adaptive Histogram Equalization), BCET (Balance contrast enhancement technique), and histogram equalization are applied. The advantages and disadvantages of each method are discussed, and the evaluation is explored through the interpretation of histograms from the resulting algorithm-generated images. In conclusion, it is found that CLAHE outperformed the

other techniques, effectively highlighting tumors in the images and emphasizing other crucial regions for patient diagnosis.

Keywords: histogram equalization; contrast enhancement; CLAHE; BCET; magnetic resonance imaging.

INTRODUÇÃO

Segundo a Organização Mundial de Saúde, em 2020, mais de 250 mil pessoas diagnosticadas com tumores malignos no cérebro ou no Sistema Nervoso Central morreram em decorrência de tais enfermidades (FERLAY et al., 2020). Esses tumores, comumente são confundidos com outras doenças, visto que podem afetar diferentes regiões do cérebro podendo causar náuseas, vômitos, como também afetar o sistema visual ou motor, sendo capaz de gerar até crises convulsivas e em uma eventualidade mais grave, levar à óbito.

Quando o tumor está na sua fase inicial, tais sintomas raramente aparecem e em virtude disso o uso de exames de imagem como a ressonância magnética e a tomografia computadorizada são essenciais para que o médico responsável obtenha um diagnóstico mais assertivo e então, possibilita um início imediato do tratamento do paciente. Mesmo que estes equipamentos tenham se modernizado constantemente, ainda estão sujeitos às falhas provenientes de perturbações externas como interferências eletromagnéticas ou pela presença de materiais ferromagnéticos no corpo do paciente, mas especialmente por conta de falhas técnicas ou manuseio inapropriado do equipamento.

Visando tais impasses, e devido ao aumento do poder de processamento, foram desenvolvidas ao longo dos anos diversas técnicas de processamento de imagem como a análise detalhada do espectro e o destaque de regiões de interesse com objetivo de realçar regiões ou eliminar ruídos, da mesma forma que preservam suas características principais como formas de objetos presentes nela e suas cores (GONZALEZ; WOODS, 2018).

Através da análise dos componentes presentes nas imagens, foi desenvolvido e implementado a técnica de Equalização Adaptativa de Histograma (PIZER et al, 1986). Com a análise do histograma e o entendimento da distribuição de intensidade dos pixels na imagem, possibilitou que regiões de pouca luminosidade se tornassem mais visíveis em decorrência da nova distribuição uniforme da intensidade do brilho que tal método proporciona.

Após alguns anos da publicação deste algoritmo, pode-se observar o mesmo sendo implementado em aplicações específicas como em imagens médicas provindas do fundo da retina de pacientes, no trabalho de Sonali et al (2018). Neste, os autores compararam uma sucessão de técnicas de redução de ruído como a aplicação do filtro mediano, removendo tais imperfeições com a substituição de cada *pixel* presente na representação pela média de seus adjacentes em conjunto com a utilização da técnica de equalização de histograma adaptativo. Para validar estes resultados, os responsáveis utilizaram diferentes métricas como a *PSNR* (*Peak Signal to Noise Ratio*), obtendo um resultado significativo de até 7.85% de melhoria na imagem.

Estes e outros algoritmos de equalização do histograma e melhoria de contraste foram utilizados no trabalho de Rahman et al. (2021), que demonstrou resultados proveitosos ao aplicar técnicas de melhoria de balanço de contraste (*BCET - Balance contrast enhancement technique*) e de correção de gama, repassando tais imagens para algoritmos de segmentação e de redes neurais convolucionais.

Desejando realizar um estudo da aplicação de diversos métodos que utiliza a equalização de histograma para a melhoria de contraste, Rajamani (2013) demonstrou em seu trabalho quais as vantagens e desvantagens da utilização de métodos como o *Local Histogram*

Equalization (LHE) ou o *Dynamic Histogram Specification (DHS)*. Pretendendo solucionar alguns dos efeitos adversos que as equalizações tradicionais apresentam como o aspecto desbotado e o contorno falso em decorrência da mudança significativa de brilho, Rajamani (2013) propôs um método de melhoria do *Global Histogram Equalization (GHE)* e conseguiu superar a eficácia de algoritmos estimados de equalização de histograma em termos de percepção visual e valores de *PSNR* (métrica utilizada no projeto).

De forma mais específica, no projeto de Senthilkumaran e Thimmiaraja (2014) foi realizado a aplicação da melhoria de imagens provindas de ressonância magnética com o objetivo de realizar um comparativo entre os algoritmos de equalização de histograma descrito no trabalho, no qual resultou em imagens com um melhor contraste e menos distorções. Para autenticar seu estudo, além da análise de percepção visual e interpretação dos histogramas resultantes, foram empregados conceitos quantitativos como o *Contraste de Weber e Michelson* que são medidas utilizadas na psicofísica e no estudo da visão humana para descrever a percepção de diferenças de luminância em uma imagem.

Com base nos estudos apresentados, desenvolveu-se este projeto com o objetivo de aplicar técnicas de processamento de imagens em exames de ressonância magnética, e por meio de métodos de análise de imagens, além de discutir as vantagens de se utilizar cada procedimento. Para isso, foi projetado um algoritmo capaz de receber tais dados e empregar as técnicas como a equalização adaptativa de histograma e o balanço de contraste.

METODOLOGIA

O presente trabalho foi desenvolvido com ferramentas e bibliotecas que permitiram realizar o controle das versões do programa e de realizar este projeto sem a dependência de computadores de alto desempenho ou de equipamentos e aplicações de difícil acesso. Nos tópicos a seguir serão abordados os componentes e as análises que viabilizaram a concretização deste projeto

DATASET

Tumores no sistema nervoso representam uma categoria diversificada e complexa de crescimentos anormais de células que podem afetar tanto o sistema nervoso central (SNC), que inclui o cérebro e a medula espinhal, quanto o sistema nervoso periférico (SNP), que abrange os nervos que se estendem para fora do SNC e se ramificam por todo o corpo. Essa variedade de localizações dentro do sistema nervoso dá origem a uma ampla gama de tumores, cada um com suas próprias características e implicações clínicas.

Um espectro importante desta distinção é quanto a sua origem. Tumores que são provenientes da região em que foram diagnosticados são nomeados de tumores primários, e aqueles que se procederam de outra região do corpo são designados como tumores secundários ou tumores metastáticos. Os tumores mais comuns encontrados no SNC são aqueles resultantes de irregularidades nas células da glia que são responsáveis por nutrir, revestir e auxiliar na percepção de sinais químicos, sendo tais tumores, nomeados de gliomas (MACHADO; HAERTEL, 2013).


Para realizar o comparativo dos algoritmos de melhoria de imagens, foi utilizado imagens de ressonância magnética provindas de uma base de dados (BHUVAJI et al., 2023) com pacientes que foram classificados com 3 tipos de tumores cerebrais primários, sendo eles provindos da célula da glia (glioma), de revestimentos do encéfalo (meningioma) e da glândula pituitária (localizado na hipófise).

Em decorrência desta base de dados ter sido idealizada para realizar o treinamento e validação de algoritmos de inteligência artificial, o mesmo apresenta também, pacientes que não possuem tumores para que o algoritmo seja capaz de distinguir entre as classes. Nesta base, se encontram 3260 imagens resultantes de ressonância magnética com a aplicação do contraste *T1-Weighted*, divididas entre 4 categorias.

TÉCNICAS

Mesmo considerando que as imagens da base de dados já foram submetidas a uma aplicação de aprimoramento de contraste (*T1-Weighted*), pode-se observar na Figura 1, a opacidade presente em diversas regiões e que as regiões de relevância onde o tumor está situado carecem de destaque, podendo ser desprezada pelo responsável ao analisar a imagem.

Figura 1 – Exemplo de imagens com a melhoria padrão (*T1-Weighted*).



Fonte: BHUVAJI et al. (2023)

Devido à essa possibilidade de melhoria, foi escolhida uma imagem de forma randômica e aplicado as técnicas de Equalização de Histograma, *Contrast Limited Adaptive Histogram Equalization (CLAHE)* e de *Balance contrast enhancement technique (BCET)* e então, analisado as melhorias através do histograma e o *CDF (Cumulative Distribution Function)* para que se possa obter através deste procedimento de representação gráfica, a avaliação da relação de frequência dos *pixels* na imagem com os valores de suas intensidades.

Equalização de Histograma

De acordo com Pizer et al.(1986), o propósito principal desta técnica de processamento de imagem é aprimorar o brilho e o contraste de toda a imagem. Para aplicar a equalização é necessário obter o histograma da imagem e então, redistribuir a intensidade dos *pixels* ao longo do novo histograma para que o mesmo se torne homogêneo. O resultado da equalização de histograma é uma imagem na qual as áreas escuras e claras são mais equilibradas, o que pode tornar os detalhes mais visíveis e elementos da imagem mais perceptíveis. Tal característica pode ser observada quando é aplicado a função de distribuição cumulativa ao longo do histograma em que nesta técnica apresentará uma linearidade em decorrência da distribuição das intensidade de *pixels*.

CLAHE - Contrast Limited Adaptive Histogram Equalization

Assim como visto na equalização de histograma, essa técnica utiliza do histograma para realizar o processamento na imagem, porém, esta realiza a coleta do histograma em pequenas regiões da imagem e então, efetua a equalização somente nesta área. Isso permite com que

imagens que possuem uma grande variação de intensidade possam ter o seu contraste melhorado sem ocorrer distorções ou ruídos. Adicionalmente, essa técnica requer que seja incluído um parâmetro para que se possa limitar a extensão do realce local. A personalização desse parâmetro oferece a capacidade de gerenciar a relação entre o aumento de contraste e a amplificação do ruído, o que se mostra especialmente valioso em contextos de imagens médicas.

BCET - Balance Contrast Enhancement Technique

Diferente das abordagens referenciadas anteriormente, a *Balance Contrast Enhancement Technique* tem como objetivo expandir ou comprimir os valores de intensidade da imagem em um determinado intervalo, preservando a forma original do histograma. Como citado no trabalho de GUO (1991), sua fórmula é definida através de uma função parabólica ou cúbica, sendo que neste trabalho foi utilizado a função parabólica descrita na Equação 1 - BCET.

Equação 1 - BCET

$$y = a(x - b)^2 + c \tag{1}$$

$$b = \frac{h^2(E - L) - s(H - L) + l^2(H - E)}{2[h(E - L) - e(H - L) + l(H - E)]} \tag{2}$$

$$a = \frac{H - L}{(h - l)(h + l - 2b)} \tag{3}$$

$$C = L - a(l - b)^2 \tag{4}$$

$$s = \frac{1}{N} \sum_{i=1}^N x_i^2 \tag{5}$$

A Equação 1 - BCET (1) é uma função parabólica em que a saída (imagem) resultante é obtida na equação. Com o objetivo de encontrar os valores ideais para os parâmetros A, B e C, é realizada a derivação gerando as equações seguintes, como foi descrito pelo autor (GUO, 1991, p. 3):

“A propriedade da função é controlada por três coeficientes: A, B e C. 1/2 A representa a distância entre a diretriz e o ponto focal de uma parábola. Quanto menor

a magnitude de A, mais abertas serão as duas ramificações de uma parábola. [...]” (tradução nossa).¹

Alguns dos parâmetros da equação são definidos pelo usuário, tais como os valores mínimo, médio e máximo, que são declarados para estabelecer o intervalo do histograma da imagem resultante, representados na equação como "L", "E" e "H", respectivamente. Por outro lado, alguns parâmetros podem ser obtidos computacionalmente, como 'l', 'e' e 'h', que representam os valores mínimos, médios e máximos dos *pixels* presentes na imagem, e 's', que denota a soma quadrada média da imagem de entrada.

MÉTRICAS

Um histograma é uma representação gráfica que facilita a visualização da distribuição de valores em um conjunto de observações. Seu propósito central é oferecer uma visão panorâmica da frequência com que cada valor ou faixa de valores se manifesta nesse conjunto de observações. Com isso, a utilização de histogramas no processamento de imagens possibilita compreender a quantidade de *pixels* contida nas imagens antes e depois do processamento como também, a intensidade ou brilho dos mesmos.

Devido às técnicas utilizadas neste projeto trabalharem exclusivamente com a manipulação dos histogramas, a interpretação dos resultados visa obter o histograma e a função de distribuição cumulativa (*CDF*), logo, foi utilizado a biblioteca *numpy* para a manipulação de dados densos e a *matplotlib* para visualização dos dados. Após a obtenção da representação gráfica, realiza-se a análise das mudanças nas imagens após ocorrer a aplicação do filtro, como o deslocamento das concentrações de *pixels* no histograma indicando um aumento ou diminuição de brilho e contraste.

Na Figura 2, o código exibido ilustra um exemplo de como gerar o gráfico do histograma com a função *CDF*. Na primeira linha, utiliza-se a função da biblioteca *numpy*, declarando como parâmetros a imagem em uma única dimensão (vetor unidimensional), a quantidade de intervalos no gráfico e o espaçamento entre os dados, sendo declarados como 256 em decorrência da imagem utilizar *pixels* variando de 0 a 255.

Em seguida, procede-se à soma da Função de Distribuição Cumulativa a partir do histograma, normalizando-a para que esteja na mesma escala que os dados no gráfico. Posteriormente, é realizada a configuração de exibição do gráfico, incluindo o tipo, a legenda e a posição no *layout*.

```
# Calcule o histograma e CDF da imagem
hist1, bins1 = np.histogram(imagem.flatten(), bins=256, range=[0, 256])
cdf1 = hist1.cumsum()
cdf_normalized1 = cdf1 * hist1.max() / cdf1.max()
axes[1, 0].plot(cdf_normalized1, color='b')
axes[1, 0].hist(imagem.flatten(), bins=256, range=[0, 256], color='r', alpha=0.5)
axes[1, 0].legend(['CDF', 'Histograma'], loc='upper left')
axes[1, 0].set_title('Histograma e CDF - Imagem Normal')
```

Figura 2 – Trecho de código utilizado para calcular o histograma e o CDF (*Cumulative Distribution Function*), como também para efetuar a visualização do gráfico gerado.

¹ Cf. original: The property of the function is controlled by three coefficients: A, B and C. $1/2A$ is the distance between the directrix and the focus point of a parabola. The smaller the magnitude of A, the wider open will be the two branches of a parabola (LIU JIAN GUO, 1991)

Fonte: Próprio autor (2023)


RESULTADOS E DISCUSSÃO

Neste projeto, desenvolveu-se um notebook na linguagem de programação *Python*, escolhida devido à capacidade de implementar trechos de códigos e então, analisar os resultados de forma eficiente. Para executar estes notebooks adotou-se o ambiente de desenvolvimento *Anaconda*, possibilitando manter a organização das ferramentas e recursos utilizados, como o *jupyter notebook* para executar os trechos de código, proporcionando também um controle das versões das bibliotecas utilizadas.

Para que fosse possível manipular as imagens e aplicar técnicas de visão computacional, foi empregado a biblioteca de visão computacional *OpenCV* que possui métodos de conversão de formato de cores, como também, filtros para o processamento de imagens já inclusos, facilitando sua utilização. Entretanto, foi necessário desenvolver um trecho de código que conteria a função para realizar a aplicação da técnica *BCET* em decorrência da sua ausência nas bibliotecas padrões. Além disso, para realizar a análise dos dados, manipulação e a visualização de gráficos, foi utilizado a biblioteca *matplotlib* e *numpy*.

Com o dataset disponível e através da aplicação desenvolvida, foi selecionado de maneira arbitrária uma imagem da classe de tumores da glândula pituitária para realizar a aplicação dos filtros, como também, entender o impacto das técnicas nas imagens. Contém na Figura 3, a amostra utilizada como referência para o projeto.

Figura 3 – Imagem utilizada como modelo para a análise dos filtros. BHUVAJI et al. (2023)



Ao analisar a imagem representada na Figura 3, pode-se observar uma predominância de *pixels* escuros ao redor da região de interesse. É uma ocorrência habitual encontrar tais elementos em imagens médicas, visto que toda a informação gerada se localiza no centro da imagem retratando o paciente.

Na utilização da equalização de histograma em imagens com predominância em *pixels* escuros, ocorre o aumento do brilho por toda a imagem, pois tal técnica não se limita a um

grupo específico de *pixels*. Esse fenômeno ocasiona em imagens médicas, o aumento do brilho fora e dentro da região de interesse, podendo gerar incerteza no reconhecimento do tumor ou da irregularidade no paciente. Para a utilização desta técnica, empregou-se a biblioteca *OpenCV* que disponibiliza a implementação através da chamada de função *equalizeHist* (OpenCV, 2023), que recebe como parâmetro apenas a imagem e a retorna no formato *numpy*. Pode-se evidenciar na função cumulativa de distribuição da imagem (*CDF*) presente na Figura 4, que o mesmo não apresenta uma linearidade para os primeiros elementos do histograma, em razão da volumosa quantidade de *pixels* escuros.

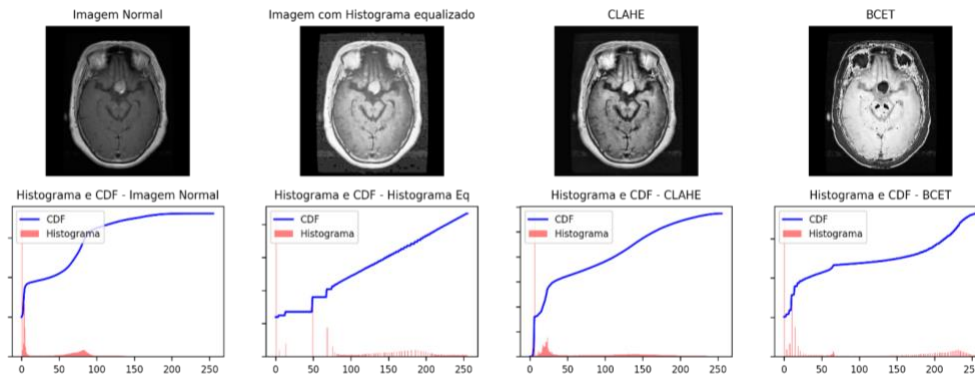
Para realizar a aplicação do filtro *BCET* (Equação 1 - *BCET*), foi necessário desenvolver um trecho de código que recebe alguns parâmetros que são empregados pela fórmula e a imagem a ser modificada. Inicialmente, a imagem foi convertida para tons de cinza e então, com este único componente da imagem (canal de cor) foi realizado a modificação e ao término, o código retorna os dados da imagem em formato de *numpy*, formato este utilizado, para realizar a exibição das imagens com as funções da biblioteca *matplotlib*.

É possível notar que ao utilizar a técnica *BCET*, um grande segmento que representa o cérebro do paciente foi submetido a um aumento de intensidade luminosa, de mesmo modo que outras partes obtiveram o resultado oposto, ocasionando em ruído e na dificuldade de distinguir os limites que demarcam as partes do cérebro.

Na imagem utilizando a *CLAHE*, ocorre o aumento do brilho das regiões onde já possuem *pixels* mais claros, como nos contornos do cérebro do paciente. Isso possibilita que ocorra o realce em regiões onde possua tumores ou outras irregularidades. Por esta técnica limitar o contraste em pequenas regiões isto possibilita que não ocorra ruído fora das regiões de interesse.

Da mesma forma que na técnica de equalização de histograma, a implementação do *Contrast Limited Adaptive Histogram Equalization (CLAHE)* também empregou uma chamada de função provinda da biblioteca *OpenCV* (OpenCV, 2023), sendo necessário fornecer alguns parâmetros como o valor de limite de contraste e o tamanho da matriz onde aplicou-se a equalização adaptativa na região. Foram utilizados os valores que são recomendados na documentação e analisando os resultados de comparação gerados na Figura 4, é possível notar uma maior distribuição de intensidade ao longo do histograma, obtendo uma imagem com um maior contraste.

Figura 4 – Imagem normal e após aplicar a técnica de Histograma equalizador, *CLAHE* e *BCET* junto com os seus respectivos histogramas.

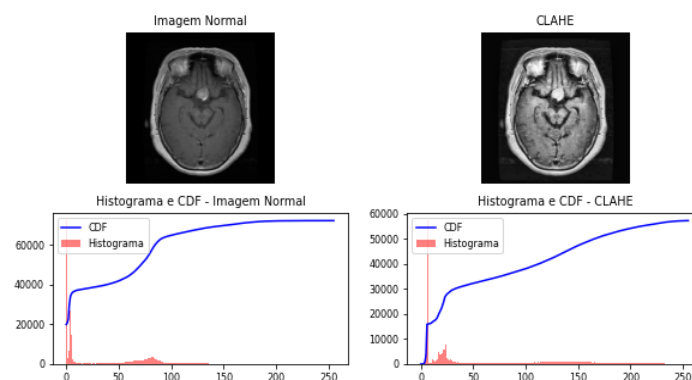


Fonte: Próprio autor (2023)

Mediante a possibilidade de adaptação do parâmetro do limite de contraste que a técnica oferece, com o objetivo de obter uma imagem com maior nível de contraste foi realizado um aprimoramento nos resultados, preservando o contraste característico dessa técnica da mesma forma que evitou o aumento de brilho e ruído na imagem.

Com isso, foi desenvolvido um trecho de código capaz de realizar uma sucessão de aplicações do *CLAHE* na imagem, utilizando diferentes valores do limite de contraste de forma igualmente espaçadas entre um intervalo que foi definido no código. Após obter a melhor configuração, pode-se notar a melhoria no comparativo presente na Figura 5, que apresenta a imagem padrão em conjunto com a imagem após a aplicação do filtro *CLAHE* com seus parâmetros de limite de contraste para 2.9 e a região de referência definida como sendo uma matriz 8x8.

Figura 5 – Imagem normal e após aplicar a técnica de *CLAHE* com os parâmetros ajustados, junto com os seus respectivos histogramas.



Fonte: Próprio autor (2023)

CONCLUSÃO

Através dos resultados obtidos constatou-se que a aplicação de técnicas, como a equalização de histograma em imagens médicas, gerou uma saturação significativa de brilho, devido à notável dispersão dos valores em seu histograma, característica inerente às imagens desse domínio. Essa condição resultou na perda de informações das imagens, podendo levar a interpretações equivocadas de seus elementos. Adicionalmente, a técnica *BCET* gerou ruído e perda de informação em regiões cruciais para a identificação de tumores.

Dentre as técnicas de melhoria de imagens abordadas, a *CLAHE* (*Contrast Limited Adaptive Histogram Equalization*) obteve o melhor resultado em decorrência do destaque das regiões das imagens onde haviam tumores cerebrais, como também, por preservar elementos originais nas imagens minimizando o ruído após realizar a aplicação do filtro. Vale ressaltar que a *CLAHE* oferece a capacidade de efetuar ajustes por meio dos parâmetros do método, possibilitando uma otimização mais precisa dos resultados de acordo com o contexto de sua aplicação.

Em suma, tal técnica alcançou resultados satisfatórios podendo ser empregada em imagens provindas de equipamentos médicos. Sua aplicação é notável na etapa de otimização e processamento das imagens, especialmente quando se aplicam algoritmos de inteligência artificial para a análise e reconhecimento de tumores e/ou irregularidades. Além disso, a sua implementação pode facilitar o trabalho dos profissionais de saúde, permitindo diagnósticos mais precisos e eficientes, contribuindo, assim, para melhorias significativas na área médica e na qualidade dos cuidados prestados aos pacientes.

REFERÊNCIAS

ALAIN H, DJEMEL Z. **Image quality metrics: PSNR vs. SSIM**. International Conference on Pattern Recognition, 2358 - 2369, 2010.

BHUVAJI S, KADAM A, BHUMKAR P, DEDGE S. **Brain Tumor Classification MRI**. Kaggle.

Disponível em:

<<https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>>. Acesso em: 20 de aug de 2023.

Ferlay J, Ervik M, Lam F, Colombet M, Mery L, Piñeros M, Znaor A, Soerjomataram I, Bray F (2020). **Global Cancer Observatory: Cancer Today**. Lyon, France: International Agency for Research on Cancer. Disponível em:

<<https://gco.iarc.fr/today/data/factsheets/cancers/31-Brain-central-nervous-system-fact-sheet.pdf>>. Acesso em: 18 aug. 2023.

GONZALEZ, Rafael; WOODS, Richard. **Digital Imaging Processing**. 4. ed. New York: Pearson Education, 2018. 1168 p.

LIU JIAN GUO. Balance contrast enhancement technique and its application in image colour composition. **International Journal of Remote Sensing**, v.12, n. 10, p. 2133-2151, 1991.

MACHADO, Angelo; HAERTEL, Lucia Machado. **Neuroanatomia funcional**. 3. ed. São Paulo: Atheneu, 2013.

OpenCV. **Histograms - 2: Histogram Equalization**. Disponível em:

<https://docs.opencv.org/4.x/d5/daf/tutorial_py_histogram_equalization.html>. Acesso em: 7 out. 2023.

RAJAMANI V., BABU. P, S.JAIGANESH. A Review of Various Global Contrast Enhancement Techniques for Still Images using Histogram Modification Framework. **International Journal of Engineering Trends and Technology (IJETT)**, v. 4, n. 4, p. 1045-1048, 2013.

SENTHILKUMARAN N, THIMMIARAJA J. Histogram Equalization for Image Enhancement Using MRI brain images. **World Congress on Computing and Communication Technologies**, IEEE, 2014. p. 80-83.

SONALI, SIMA SAHU, AMIT KUMAR SINGH, S.P. GHRERA, MOHAMED ELHOSENY. An approach for de-noising and contrast enhancement of retinal fundus image using CLAHE. **Optics & Laser Technology**, v. 110, p. 87-98, 2019.

STEPHEN M. PIZER, E.PHILIP ARBURN, JOHN D. AUSTIN, ROBERT CROMARTIE, ARI GESELOWITZ, TREY GREER, BART TER HAAR ROMENY, JOHN B. ZIMMERMAN, KAREL ZUIDERVELD. Adaptive Histogram Equalization and Its Variations. **COMPUTER VISION, GRAPHICS, AND IMAGE PROCESSING**. v. 39, n. 3, p. 355-368, 1987.

TAWSIFUR RAHMAN, AMITH KHANDAKAR, YAZAN QIBLAWEY, ANAS TAHIR, SERKAN KIRANYAZ, SAAD BIN ABUL KASHEM, MOHAMMAD TARIQUL ISLAM, SOMAYA AL MAADEED, SUSU M. ZUGHAIER, MUHAMMAD SALMAN KHAN , MUHAMMAD E.H. CHOWDHURY. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. **Computers in Biology and Medicine**, v. 132, p. 104319, 2021.

Submetido em: 28-02-24

Publicado em: 29-05-24