

ANÁLISE DO SNR EM IMAGENS DE RM GERADAS POR DIFERENTES MÉTODOS DE AUMENTO DE DADOS

André de Sousa Araujo¹, Carlos José Andrioli², Lucas Fontes Buzuti³, Carlos Eduardo Thomaz⁴

^{1,4}Departamento de Engenharia Elétrica, FEI

²⁻⁴Programa de Mestrado e Doutorado em Engenharia Elétrica, FEI
unieranaraujo@fei.edu.br; cet@fei.edu.br

Resumo: Este trabalho propõe e implementa uma análise quantitativa de imagens de *phantom* de ressonância magnética de extremidades que tiveram suas amostras de dados aumentadas por meio de um modelo baseado em Processamento de Imagens e outro baseado em Inteligência Artificial (IA), ambas abordagens comumente utilizados para este fim. Mais especificamente, ampliou-se o banco limitado de imagens disponível por meio de um método de transformações afins e de uma Rede Neural Convolutacional; e analisou-se e comparou-se os resultados obtidos utilizando a métrica de referência denominada *Signal-to-Noise Ratio* (SNR). Para as amostras investigadas, o modelo implementado de Redes Neurais se mostrou menos capaz de gerar imagens sintéticas válidas.

1. Introdução

Desde a criação do primeiro equipamento de ressonância magnética (RM), cientistas, médicos e especialistas trabalham para o aumento da qualidade da aquisição e processamento dessas imagens. Esta qualidade é medida principalmente pela relação entre o sinal emitido e a quantidade de ruído obtida na imagem, chamada de SNR (em inglês, *Signal-to-Noise Ratio*).

Em 2021, (ANDRIOLI; THOMAZ, 2021) apresentaram uma análise comparativa entre o SNR e medidas estatísticas de classificação aplicados em imagens de *phantom* de RM de extremidades. A análise mostrou experimentalmente que ao considerar um classificador estatístico tradicional com SNR pode-se melhor categorizar a qualidade dessas imagens.

Este trabalho processou as imagens de *phantom* disponibilizadas em (ANDRIOLI; THOMAZ, 2021) de duas maneiras diferentes: a primeira baseada em transformações afins e a outra utilizando uma rede neural não-supervisionada, calculando o SNR após o processamento por cada técnica e comparando-os quantitativamente.

2. Metodologia

Em uma primeira fase do trabalho as imagens foram geradas utilizando-se a biblioteca *Albumentations* do *Python* como ferramenta para a aplicação de transformações afins, dentre essas: *Shear*, *Rotate* e *Translate_Percent*. Essas transformações foram aplicadas de modo a gerar um banco de dados maior e diverso tendo como base 63 imagens iniciais.

Sendo assim, para cada imagem inicial, aplicou-se o método de aumento de dados que consiste em analisar o valor do pixel e separar matematicamente sinal de ruído, aplicar transformações afins nas imagens contendo

apenas o sinal e unir de volta a imagem transformada com um dos ruídos de fundo escolhido aleatoriamente.

A partir de então, foram escolhidas, também aleatoriamente, 30 imagens do banco de dados aumentado e calculou-se o SNR conforme o procedimento descrito em (ANDRIOLI; THOMAZ, 2021). Por fim, uma imagem com SNR (Figura 1) acima de 105 seria considerada satisfatória, caso contrário, seria não-satisfatória.

Na segunda parte do projeto, utilizou-se um modelo de IA denominado *variational autoencoder* como gerador de novas imagens.

A ideia geral dos *autoencoders* consiste em configurar um codificador e um decodificador como redes neurais e encontrar o melhor par codificação-decodificação usando um processo de otimização iterativo. O objetivo é que ao codificar e decodificar um dado não se perca nenhuma informação, sendo assim o melhor par é aquele que tenha a menor perda durante o processo todo. No momento em que o dado é codificado e tem-se uma redução de sua dimensionalidade, o mesmo sai de seu espaço inicial e passa para o que se chama de espaço latente. Qualquer ponto desse espaço latente que passar pelo decodificador gerará um novo dado, sendo assim, gerar novos dados a partir da navegação no espaço latente é um dos usos dos *autoencoders*, sendo esses considerados modelos generativos.

O *variational autoencoder*, resumidamente, é um *autoencoder* que teve seu espaço latente regularizado. A principal vantagem desse método é que qualquer ponto de seu espaço latente, quando decodificado, gerará um dado relevante.

Esse modelo tem a arquitetura como descrita na Tabela I, somando mais de 92 milhões de pesos em sua arquitetura.

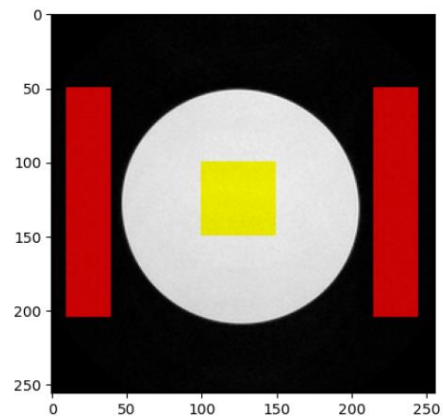


Figura 1– Imagem de *phantom* com regiões destacadas, em amarelo de onde se extrai o valor do sinal e em vermelho o valor do ruído para cálculo do SNR.

Tabela I – Arquitetura da rede neural.

Camada	Tamanho do Kernel	Formato da saída
Conv	[4x4]x2	128x64x64
Conv	[4x4]x2	256x32x32
Conv	[4x4]x2	512x16x16
Conv	[4x4]x2	1024x8x8
Conv	[4x4]x2	2048x4x4
μ	-	32
σ	-	32
Latente	-	32
ConvTransposta	[4x4]x2	1024x8x8
ConvTransposta	[4x4]x2	512x16x16
ConvTransposta	[4x4]x2	256x32x32
ConvTransposta	[4x4]x2	128x64x64
ConvTransposta	[4x4]x2	3x128x128

Vale ressaltar que cada camada convolucional é seguida por uma camada de normalização de lote.

Esse modelo foi treinado com um conjunto maior de imagens sintéticas semelhante às imagens de *phantom* e então passaram por um ajuste fino utilizando-se as imagens verdadeiras.

A partir de então foi seguido o mesmo procedimento da primeira etapa. Um banco de imagens foi gerado, trinta imagens foram escolhidas aleatoriamente e calculou-se o SNR de cada uma dessas imagens sinteticamente geradas.

3. Resultados

O resultado obtido foi plotado em um histograma (Figura 2) a fim de comparar as diferenças entre cada método de aumento de dados.

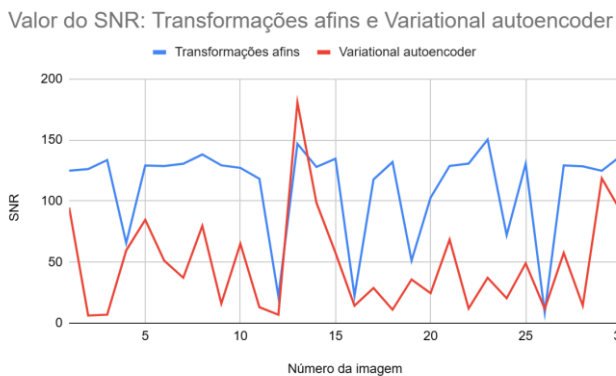


Figura 2 – Histograma do resultado do cálculo do SNR em cada uma das imagens.

A média de SNR das imagens geradas por transformações afins foi de 111.64, enquanto a gerada pela rede neural foi de 48.46.

Os valores de SNR obtidos pela rede neural foram inferiores ao esperado devido ao formato gerado pela reconstrução do decodificador. Sendo assim, algumas das imagens de *phantoms* gerados pelo *autoencoder* se distanciaram do formato ideal (Figura 3).




Figura 3 – Imagem gerada pela rede neural que se distanciou do formato ideal.

4. Conclusões

Conclui-se que, de modo geral, o modelo implementado de Rede Neural não foi capaz de gerar imagens boas do ponto de vista de sinal-ruído.

Ainda assim, vale a pena ressaltar que o cálculo do SNR não leva em conta o formato da imagem. Ou seja, ainda que duas das imagens geradas pela Rede Neural tivessem um SNR superior a 105, se um especialista em RM as avaliasse, provavelmente seriam consideradas imagens não-satisfatórias por não seguirem o padrão de forma.

Como trabalho futuro, sugere-se repetir o experimento usando outra técnica de IA menos sensível ao número original de imagens disponível e o cálculo das componentes principais para melhor entendimento sobre a variância das imagens geradas artificialmente.

5. Referências

[1] VAHDAT, Arash; KAUTZ, Jan. NVAE: A Deep Hierarchical Variational Autoencoder. [S.l.: s.n.], 2021. arXiv: 2007.03898 [stat.ML].

[2] ANDRIOLI, Carlos; THOMAZ, Carlos. Discriminant analysis of background noise in extremity magnetic resonance images. In: ANAIS do XVII Workshop de Visão Computacional. Online: SBC, 2021. P. 64–69. DOI: 10.5753/wvc.2021.18891. Disponível em: <https://sol.sbc.org.br/index.php/wvc/article/view/18891>.

[3] BUSLAEV, Alexander et al. Albumentations: Fast and Flexible Image Augmentations. Information, v. 11, n. 2, 2020. ISSN 2078-2489. DOI: 10.3390/info11020125. Disponível em: <https://www.mdpi.com/2078-2489/11/2/125>.

[4] PYTHON. Python 3.11.4 Documentation. Disponível em: <<https://docs.python.org/3/>>. Acesso em: ago. 2023.

¹ Aluno de IC do Centro Universitário FEI. Projeto com vigência de 09/2022 a 08/2023.