Universidade de Brasília - UnB
Faculdade de Ciências e Tecnologias em Engenharia - FCTE
Engenharia Eletrônica

Estudo Comparativo de Métodos de Reconstrução de Imagens de Ressonância Magnética Subamostradas por Compressive Sensing e por Modelos Generativos

Autor: Gabriel Nathan da Silva Gomes
Orientador: Dr. Cristiano Jacques Miosso

Brasília, DF
2026

Gabriel Nathan da Silva Gomes

Estudo Comparativo de Métodos de Reconstrução de Imagens de Ressonância Magnética Subamostradas por Compressive Sensing e por Modelos Generativos

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica .

Universidade de Brasília - UnB

Faculdade de Ciências e Tecnologias em Engenharia - FCTE

Orientador: Dr. Cristiano Jacques Miosso

Brasília, DF

2026

Gabriel Nathan da Silva Gomes

Estudo Comparativo de Métodos de Reconstrução de Imagens de Ressonância Magnética Subamostradas por Compressive Sensing e por Modelos Generativos/ Gabriel Nathan da Silva Gomes. – Brasília, DF, 2026-

74 p. : il. (algumas color.) ; 30 cm.

Orientador: Dr. Cristiano Jacques Miosso

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB
Faculdade de Ciências e Tecnologias em Engenharia - FCTE , 2026.

1. Ressonância Magnética. 2. Inteligência Artificial. I. Dr. Cristiano Jacques Miosso. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Estudo Comparativo de Métodos de Reconstrução de Imagens de Ressonância Magnética Subamostradas por Compressive Sensing e por Modelos Generativos

CDU

Gabriel Nathan da Silva Gomes

Estudo Comparativo de Métodos de Reconstrução de Imagens de Ressonância Magnética Subamostradas por Compressive Sensing e por Modelos Generativos

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica .

Dr. Cristiano Jacques Miosso
Orientador

Dr. Adson Ferreira da Rocha
Membro da Banca

Dr. Diogo Oliveira Costa
Membro da Banca

Brasília, DF
2026

Resumo

O exame de Ressonância Magnética (RM) é uma ferramenta indispensável para o diagnóstico médico, porém seu longo tempo de aquisição gera desconforto ao paciente e suscetibilidade a artefatos de movimento. Para mitigar esse problema, a subamostragem do espaço-k é utilizada para acelerar a aquisição, exigindo técnicas avançadas de reconstrução para recuperar a imagem sem perda de qualidade diagnóstica. Este trabalho apresenta um estudo comparativo entre o método clássico de Sensoriamento Comprimido (CS) e duas abordagens de Inteligência Artificial baseadas em Aprendizado Profundo: a rede convolucional supervisionada U-Net e a Rede Adversária Generativa Condicional (cGAN). Utilizando o dataset público BIRN com 158 volumes cerebrais, foram simulados quatro cenários de aceleração (retenção de 75%, 50%, 25% e 10% dos dados). A avaliação baseou-se nas métricas quantitativas PSNR, SNR e SSIM, além de análise qualitativa visual. Os resultados demonstraram a superioridade das abordagens de IA sobre o método clássico, especialmente em regimes de alta aceleração. A arquitetura U-Net apresentou a maior fidelidade radiométrica (maior PSNR), sendo ideal para análises quantitativas, embora tenda a suavizar texturas. A cGAN demonstrou melhor qualidade perceptual e recuperação de bordas, superando a U-Net em nitidez visual, mas apresentou riscos de alucinação estrutural no cenário extremo de 10% de dados. Conclui-se que a escolha da arquitetura depende da aplicação clínica, havendo um compromisso claro entre fidelidade numérica e qualidade perceptual. Os resultados demonstraram que a U-Net superou a cGAN em consistência, atingindo um índice SSIM de $\sim$0.90 com apenas 25% dos dados brutos, estabelecendo este patamar como o ponto de equilíbrio do sistema. Observou-se também que, para taxas de amostragem superiores a 50%, os métodos generativos (cGAN) apresentaram saturação e introdução de artefatos, resultando em desempenho inferior ao método de *Compressive Sensing* em cenários de alta fidelidade.

Palavras-chaves: Ressonância Magnética. Inteligência Artificial. Aprendizado Profundo. U-Net. cGAN. Reconstrução de Imagens.

Abstract

Magnetic Resonance Imaging (MRI) is an essential tool for medical diagnosis, yet its long acquisition time causes patient discomfort and susceptibility to motion artifacts. To mitigate this issue, k-space subsampling is used to accelerate acquisition, requiring advanced reconstruction techniques to recover the image without loss of diagnostic quality. This work presents a comparative study between the classic Compressed Sensing (CS) method and two Artificial Intelligence approaches based on Deep Learning: the supervised convolutional network U-Net and the Conditional Generative Adversarial Network (cGAN). Using the public BIRN dataset with 158 brain volumes, four acceleration scenarios were simulated (retaining 75%, 50%, 25%, and 10% of data). The evaluation relied on quantitative metrics PSNR, SNR, and SSIM, as well as qualitative visual analysis. Results demonstrated the superiority of AI approaches over the classic method, especially in high-acceleration regimes. The U-Net architecture achieved the highest radiometric fidelity (highest PSNR), making it ideal for quantitative analysis, although it tends to smooth textures. The cGAN demonstrated better perceptual quality and edge recovery, outperforming U-Net in visual sharpness, but presented risks of structural hallucination in the extreme 10% data scenario. It is concluded that the architecture choice depends on the clinical application, with a clear trade-off between numerical fidelity and perceptual quality. The results demonstrated that U-Net outperformed cGAN in terms of consistency, achieving an SSIM index of $\sim$0.90 with only 25% of the raw data, establishing this level as the system's equilibrium point. It was also observed that, for sampling rates exceeding 50%, the generative methods (cGAN) exhibited saturation and artifact introduction, resulting in inferior performance compared to the *Compressive Sensing* method in high-fidelity scenarios.

Key-words: Magnetic Resonance Imaging. Artificial Intelligence. Deep Learning. U-Net. cGAN. Image Reconstruction.

Lista de ilustrações

Figura 1 – Representação vetorial do fenômeno de ressonância. A aplicação de um pulso de radiofrequência B_1 (em vermelho) provoca um torque no vetor de magnetização líquida M_0, desviando-o do eixo longitudinal z (alinhado com B_0) em direção ao plano transversal xy, gerando a componente M_{xy} responsável pelo sinal de RM. 29

Figura 2 – Simulação das curvas características de relaxação para Gordura, Matéria Branca e Líquor em campo de 1.5T. (A) Recuperação da magnetização longitudinal (T1). (B) Decaimento da magnetização transversal (T2). Note a diferença significativa nas escalas de tempo entre os tecidos, base física para o contraste em RM. 31

Figura 3 – Demonstração da distribuição de frequências no Espaço-k. O centro (b) contém as baixas frequências que definem o contraste e formas gerais, enquanto a periferia (c) contém as altas frequências responsáveis pelas bordas e detalhes finos. 32

Figura 4 – Artefato de *aliasing* (wrap-around) em imagem cerebral. Devido à escolha de um FOV menor que a anatomia do paciente, a região occipital é projetada incorretamente sobre a região frontal, prejudicando o diagnóstico. 33

Figura 5 – Diagrama esquemático da arquitetura U-Net. As setas cinzas representam as conexões de atalho, que transferem informações de alta resolução do caminho de contração para o de expansão, essenciais para preservar detalhes anatômicos na reconstrução. 36

Figura 6 – Estrutura de treinamento de uma GAN condicional (cGAN). Diferente de uma GAN tradicional, o discriminador D observa pares de imagens: o par "Real"consiste na entrada original x e o alvo desejado y, enquanto o par "Falso"consiste na entrada x e a imagem gerada $G(x)$. O gerador G tenta minimizar a diferença entre o par real e o falso para enganar o discriminador. 38

Figura 7 – Fluxograma do pipeline de aquisição e preparação dos dados. O processo destaca a segregação dos dados por paciente antes da extração das fatias, assegurando a integridade da validação. 45

Figura 8 – Representação visual das máscaras de amostragem espiral utilizadas nos experimentos. As regiões claras indicam os pontos amostrados no Espaço-k. É notável a alta concentração de amostras no centro (baixas frequências) em todos os cenários, característica fundamental da trajetória espiral. Também é possível notar que a partir de 25% de subamostragem, as linhas da espiral ficam quase indistinguíveis, mesmo não cobrindo toda a imagem. 48

Figura 9 – Representação esquemática da arquitetura U-Net implementada. As setas horizontais representam as conexões de atalho (*skip connections*) que preservam detalhes estruturais entre o codificador e o decodificador. 50

Figura 10 – Fluxo de treinamento da cGAN baseado no framework Pix2Pix. O Discriminador PatchGAN avalia a veracidade local da imagem, incentivando a recuperação de texturas. 51

Figura 11 – Análise de Ganho Marginal (Δ_{SSIM}) das abordagens de Deep Learning em relação ao método de referência (CS). Valores positivos indicam superioridade da IA. Nota-se que a U-Net (Azul) oferece ganhos robustos nos regimes de baixa amostragem (10% e 25%). Em contrapartida, no regime de 75%, a cGAN (Laranja) apresenta ganho negativo, indicando que a inserção de texturas sintéticas prejudicou a fidelidade estrutural da imagem original. 57

Figura 12 – Evolução das métricas de fidelidade (PSNR, SSIM e SNR) em função da taxa de amostragem. Os gráficos evidenciam três comportamentos distintos: (1) o decaimento linear do método clássico (CS - Cinza); (2) a robustez da U-Net (Azul), que sustenta métricas elevadas até o limiar de 25%; e (3) a inflexão da cGAN (Laranja) no cenário de 75%, onde seu desempenho torna-se inferior ao método clássico devido à inserção de ruído textural. 58

Figura 13 – Avaliação visual comparativa no cenário de aceleração 4× (Sub25). A linha superior exibe a visão axial completa, enquanto a inferior destaca a região de interesse (ROI) nos ventrículos. Observa-se: (b) Artefatos de aliasing severos na entrada; (c) Efeito de escada na reconstrução clássica (CS); (d) Supressão eficaz de ruído pela U-Net, porém com perda de definição nas transições de tecido (seta vermelha implícita); (e) Recuperação de texturas de alta frequência pela cGAN, resultando em maior nitidez perceptual, apesar do menor SSIM. 59

Figura 14 – Consistência de reconstrução (Cenário Sub25) em diferentes anatomias. Cada linha representa um paciente. Nota-se a repetibilidade do fenômeno: a U-Net (coluna 3) prioriza a limpeza do sinal em detrimento da textura, enquanto a cGAN (coluna 4) preserva sistematicamente a granulação do parênquima cerebral. 60
Figura 15 – Análise detalhada de alta frequência nos sulcos corticais. (A) Referência; (B) O método clássico apresenta artefatos residuais; (C) A U-Net exibe perda de contraste nas dobras cerebrais (borrão azul); (D) A cGAN (laranja) sintetiza bordas nítidas, recuperando a aparência orgânica do tecido. 61
Figura 16 – Comparativo no cenário extremo de 10% de dados. O método CS colapsa, a U-Net produz um resultado borrado mas estruturalmente correto, enquanto a cGAN recupera nitidez, mas com risco de introduzir microestruturas artificiais (alucinação). 62
Figura 17 – Mapas de calor (*Heatmaps*) da robustez cruzada. A cor indica o valor do SSIM. Comparando os dois gráficos, nota-se que a U-Net (Azul) mantém uma consistência maior através da diagonal, enquanto a cGAN (Laranja) sofre penalizações severas quando treinada em dados limpos (Sub75) e testada em dados ruidosos (Sub10). 63
Figura 18 – Experimento visual de validação cruzada. **Linha Superior (Robustez):** O modelo treinado em condições adversas (Sub10) reconstrói perfeitamente uma entrada mais simples (Sub75), demonstrando aprendizado de *priors* robustos. **Linha Inferior (Fragilidade):** O modelo treinado apenas com dados de alta qualidade (Sub75) colapsa ao tentar reconstruir uma entrada difícil (Sub10), produzindo artefatos severos e borrão, pois não aprendeu a lidar com a escassez de informação. . . . 64
Figura 19 – Diagrama de decisão para escolha da arquitetura de reconstrução baseado na aplicação clínica alvo. O eixo horizontal representa o compromisso entre precisão numérica e qualidade visual. 65

Lista de tabelas

Tabela 1 – Valores aproximados dos tempos de relaxação T1 e T2 para tecidos biológicos em campo magnético de 1.5 Tesla. Note a grande diferença entre líquidos (LCR) e tecidos estruturais. 31
Tabela 2 – Comparativo entre as abordagens de Aprendizado Profundo aplicadas à reconstrução acelerada de RM. 39
Tabela 3 – Resumo das métricas quantitativas utilizadas na avaliação de qualidade de reconstrução. 41
Tabela 4 – Especificações técnicas do conjunto de dados utilizado nos experimentos. 43
Tabela 5 – Resumo dos hiperparâmetros utilizados no treinamento das redes. . . . 52
Tabela 6 – Resumo comparativo das métricas de fidelidade (PSNR, SSIM e SNR) para os quatro cenários de subamostragem. Observa-se uma **inversão de desempenho**: enquanto o Sensoriamento Comprimido (CS) lidera em regimes conservadores (Sub75), a arquitetura **U-Net** demonstra maior robustez em cenários de escassez de dados, superando o CS em mais de 0.24 pontos de SSIM no cenário crítico (Sub10). 55

Lista de abreviaturas e siglas

ANVISA	Agência Nacional de Vigilância Sanitária
BIRN	*Biomedical Informatics Research Network*
CE	*Conformité Européenne* (Certificação Europeia)
cGAN	*Conditional Generative Adversarial Network* (Rede Adversária Generativa Condicional)
CNN	*Convolutional Neural Network* (Rede Neural Convolucional)
CS	*Compressive Sensing* (Sensoriamento Comprimido)
dB	Decibéis
DDPM	*Denoising Diffusion Probabilistic Model* (Modelo de Difusão Probabilística de Redução de Ruído)
DFT	*Discrete Fourier Transform* (Transformada de Fourier Discreta)
DICOM	*Digital Imaging and Communications in Medicine*
DL	*Deep Learning* (Aprendizado Profundo)
FDA	*Food and Drug Administration*
FID	*Free Induction Decay* (Decaimento por Indução Livre)
FOV	*Field of View* (Campo de Visão)
GAN	*Generative Adversarial Network* (Rede Adversária Generativa)
GPU	*Graphics Processing Unit* (Unidade de Processamento Gráfico)
GRAPPA	*GeneRalized Autocalibrating Partially Parallel Acquisitions*
IA	Inteligência Artificial
LCR	Líquido Cefalorraquidiano (Líquor)
MAE	*Mean Absolute Error* (Erro Absoluto Médio - L1)
ML	*Machine Learning* (Aprendizado de Máquina)
MRI	*Magnetic Resonance Imaging* (Imagem por Ressonância Magnética)

MSE	*Mean Squared Error* (Erro Médio Quadrático - L2)
PDF	*Probability Density Function* (Função de Densidade de Probabilidade)
PI	*Parallel Imaging* (Imagem Paralela)
Pix2Pix	*Framework* de tradução imagem-para-imagem
POCS	*Projection Onto Convex Sets* (Projeção em Conjuntos Convexos)
PSNR	*Peak Signal-to-Noise Ratio* (Relação Sinal-Ruído de Pico)
ReLU	*Rectified Linear Unit* (Unidade Linear Retificada)
RF	Radiofrequência
RM	Ressonância Magnética
RMN	Ressonância Magnética Nuclear
ROI	*Region of Interest* (Região de Interesse)
SENSE	*Sensitivity Encoding*
SNR	*Signal-to-Noise Ratio* (Relação Sinal-Ruído)
SSIM	*Structural Similarity Index Measure* (Índice de Similaridade Estrutural)
U-Net	Arquitetura de rede neural convolucional em formato de "U"
VarNet	*Variational Network* (Rede Variacional)
VDS	*Variable Density Sampling* (Amostragem com Densidade Variável)

Sumário

1 INTRODUÇÃO 21
1.1 Contextualização 21
1.1.1 Aplicação Industrial 22
1.2 Definição do Problema Científico 23
1.2.1 Artefatos Não Relacionados à Subamostragem 23
1.2.2 Generalização da tecnologia 23
1.2.3 Falta de Transparência na tomada de decisões 23
1.2.4 Homogeneidade das Bases de dados 24
1.3 Proposta de Pesquisa 25
1.4 Objetivos 25
1.4.1 Objetivo Geral 25
1.4.2 Objetivos Específicos 26

2 FUNDAMENTAÇÃO TEÓRICA 27
2.1 Princípios da Imagem por Ressonância Magnética 27
2.1.1 O Fenômeno da Ressonância Magnética Nuclear 27
2.1.2 A Equação de Bloch 28
2.1.3 Tempos e Equações de Relaxação T1 e T2 29
2.1.3.1 Relaxação Longitudinal (T1) 29
2.1.3.2 Relaxação Transversal (T2) 30
2.1.4 Codificação Espacial e o Espaço k 31
2.1.5 O Teorema da Amostragem de Nyquist-Shannon no Contexto da RM . . . 33
2.1.6 Aceleração da Aquisição em RM: Abordagens Tradicionais 33
2.1.6.1 Imagem Paralela (SENSE E GRAPPA) 34
2.1.6.2 Sensoriamento Comprimido (CS) 34
2.1.7 Inteligência Artificial e Aprendizado Profundo na Reconstrução de Imagens Médicas 35
2.1.7.1 Aprendizado de Máquina e Aprendizado Profundo 35
2.1.7.2 Redes Neurais Convolucionais (CNNs) 35
2.1.7.3 A Arquitetura U-Net 35
2.1.8 Técnicas de Aprendizado Profundo para Reconstrução Acelerada de RM . . 36
2.1.8.1 Mapeamento Direto Imagem para Imagem por U-Net 36
2.1.8.2 Reconstrução com Redes Adversárias Generativas Condicionais (CGANs) 37
2.1.8.3 Modelos Guiados por Física com Redes Variacionais(VarNet) 38
2.1.8.4 Modelos Generativos de Difusão(DDPMs) 39

2.1.9 Métricas de Avaliação de Qualidade de Imagem . . . 39
2.1.9.0.1 Relação Sinal-Ruído (SNR) . . . 40
2.1.9.0.2 Relação Sinal Ruído de Pico(PSNR) . . . 40
2.1.9.0.3 Índice de Medida da Similaridade Estrutural(SSIM) . . . 40

3 METODOLOGIA . . . 43
3.1 Aquisição e Pré-processamento da Base de Dados . . . 43
3.1.1 Descrição do Conjunto de Dados . . . 43
3.1.2 Pipeline de Pré-processamento . . . 44
3.1.3 Estratégia de Particionamento dos Dados . . . 44
3.2 Modelagem Matemática da Subamostragem Retrospectiva . . . 46
3.2.1 Design das Máscaras de Amostragem . . . 46
3.2.2 Definição dos Cenários de Aceleração . . . 47
3.3 Arquiteturas de Reconstrução Implementadas . . . 48
3.3.1 Sensoriamento Comprimido (CS) . . . 48
3.3.2 Arquitetura Supervisionada: Rede U-Net . . . 49
3.3.3 Arquitetura Adversária: cGAN (Pix2Pix) . . . 50
3.3.3.1 O Gerador (G) . . . 51
3.3.3.2 O Discriminador (D): Arquitetura PatchGAN . . . 51
3.4 Protocolo Experimental e Treinamento . . . 52
3.4.1 Ambiente e Hiperparâmetros . . . 52
3.4.2 Métricas de Avaliação . . . 52

4 RESULTADOS E DISCUSSÃO . . . 55
4.1 Análise Quantitativa e Métricas de Fidelidade . . . 55
4.1.1 Comparativo Global de Desempenho . . . 55
4.1.2 Discussão Crítica: O Compromisso Percepção-Distorção . . . 56
4.1.3 Ponto de Equilíbrio e Análise de Ganho . . . 56
4.1.4 Análise da Degradação do Sinal . . . 57
4.2 Avaliação Qualitativa em Cenários de Aceleração Clínica . . . 58
4.2.1 Inspeção Visual e Remoção de Artefatos . . . 59
4.2.2 Análise de Textura e Alta Frequência . . . 60
4.3 Avaliação de Limites de Reconstrução e Estresse . . . 61
4.3.1 Colapso do Método Clássico . . . 61
4.3.2 Limitações Intrínsecas: Perda de Alta Frequência versus Alucinação Estrutural 61
4.4 Estudo de Generalização e Robustez Cruzada . . . 62
4.4.1 Matriz de Desempenho Cruzado . . . 63
4.4.2 Análise da Assimetria de Generalização . . . 63
4.5 Discussão Geral e Implicações Clínicas . . . 64
4.5.1 O Trade-off entre Fidelidade e Percepção . . . 65

4.5.2 Confiabilidade e Riscos de Alucinação 65
4.5.3 Impacto no Fluxo de Trabalho 66

5 CONCLUSÃO 67
5.1 Síntese dos Resultados e Contribuições 67
5.2 Implicações para a Prática Clínica 68
5.3 Limitações do Estudo 68
5.4 Trabalhos Futuros e Novas Fronteiras 69

REFERÊNCIAS 71

1 Introdução

1.1 Contextualização

O imageamento por Ressonância Magnética (RM) é uma das formas de geração de imagens mais úteis e versáteis da medicina moderna (1, 2). A capacidade de gerar imagens de tecidos internos do corpo sem a necessidade do uso de radiação ionizante a posiciona como uma ferramenta indispensável para diagnóstico e monitoramento de uma vasta gama de condições patológicas (3, 2, 4).

Apesar de sua grande utilidade, o principal problema dessa técnica de imageamento é seu elevado tempo de aquisição (5). A morosidade da realização do exame, gera desconforto no paciente e o torna mais suscetível à artefatos de movimento, já que permanecer imóvel por longos períodos pode se mostrar incomodo. Esse fator também se torna uma limitação em sua aplicação em casos como a realização de exames em crianças, pessoas com condições médicas que geram movimentos involuntários, claustrofóbicos, entre outros (6, 2, 7). Sendo assim, a qualidade da imagem final pode ser prejudicada devido ao elevado tempo de aquisição (6, 2).

O elevado tempo necessário para a realização desse tipo de exame se dá devido a necessidade de aquisição de um grande volume de dados no domínio da frequência, nesse caso, o chamado espaço k(8, 9, 5). Esse processo pode levar de vários minutos ou até horas, dependendo da resolução, tamanho da região, quantidade de cortes, etc.

Para obtenção da imagens de RM convencional deve ser obedecido o critério de amostragem de Shanon-Nyquist (10, 2, 11) para garantir a reconstrução da imagem evitando artefatos de aliasing. Durante a evolução das técnicas e equipamentos para a realização desse exame, foram criados métodos que acelerem a aquisição do sinal. Para isso, basicamente, é realizada uma subamostragem do espaço k (11, 12, 13), ou seja, adquirindo menos dados do que o exigido para atender o teorema citado. Para executar esse processo, são utilizados algoritmos especializados, como GRAPPA, Compressive Sensing e modelos baseados em Deep Learning, cada um adotando métodos próprios para reconstrução de dados faltantes dentro do espaço k (14, 13, 15).

A primeira evolução histórica na aceleração no exame de RM veio com técnicas como Imagem Paralela (PI), Sensitivity Encoding (SENSE) e GeneRalizes Autocalibrating Partially Parallel Acquisitions (GRAPPA)(16, 10). Esses métodos exploram arranjos diferentes de bobinas receptoras para driblar os artefatos de aliasing gerados pela subamostragem (17, 18).

Posteriormente, o Compressive Sensing (CS) emergiu como forma de tratar as

imagens médicas considerando-as inerentemente esparsas e compressíveis em um domínio transformado (13, 19). Combinando a subamostragem com algoritmos de reconstrução não lineares e baseados em iterações, o CS alcançou níveis de aceleração da aquisição significativamente elevados, aumentando apenas o poder computacional exigido para esse processamento (11, 12).

Com a popularização da Inteligência Artificial (IA), mais especificamente o Deep Learning (DL), surgiu uma nova era para a reconstrução de imagens de RM. Modelos como Redes Neurais Convolucionais (CNNs), demonstraram capacidade de aprender *priors* poderosos a partir de grandes conjuntos de dados ao invés de depender dos projetados manualmente (17, 20, 15). Esses modelos aprendem a transformar dados subamostrados e repletos de artefatos em imagens de alta fidelidade, muitas vezes superando os métodos comuns (21, 16, 15).

A revolução gerada pela aplicação de IA na saúde abriu caminho para o uso de diversas arquiteturas, desde redes que atuem diretamente no domínio da imagem até abordagens mais complexas (22, 16, 15).

1.1.1 Aplicação Industrial

A aplicação das pesquisas em IA para a prática clínica é cada vez mais evidente, com os principais fabricantes de equipamentos de RM implementando soluções baseadas nela para superar as limitações de tempo de Aquisição.

A *Siemens Healthineers*, uma das maiores fabricantes de equipamentos de RM do mundo, aplica em suas novas linhas a plataforma *Deep Resolve*, uma tecnologia que aplica diretamente o modelos de aprendizado profundo com Redes Neurais Convolucionais (CNNs, do inglês Convolutional Neural Network) treinadas para transformar dados subamostrados em imagens de alta resolução (23).

O sistema é projetado para permitir a aquisição de dados muitos mais rápido e, em seguida, usar o algoritmo de IA para preencher informações ausentes no espaço k, realizando a supressão do ruído e artefatos de forma mais intensa que nos métodos tradicionais (23).

Essa abordagem faz com que o exame seja drasticamente mais rápido e aprimora a qualidade da imagem, sendo validada por órgãos reguladores como a *Food and Drug Administration* (FDA) e agências europeias (23).

Outro exemplo de solução baseada em inteligência artificial para reconstrução acelerada de exames de ressonância magnética é o SwiftMR, desenvolvido pela AIRS Medical que emprega algoritmos de deep learning para reduzir o tempo de aquisição das imagens de RM em até 50%, atuando tanto em redução de ruído quanto em aprimoramento de nitidez, possuindo aprovação regulatória da FDA, CE (União Europeia), Health Canada e

registro pela Anvisa no Brasil para uso clínico em diferentes protocolos e regiões anatômicas (24, 25, 26, 27, 28). Estudos de caso e publicações institucionais demonstram ganhos em produtividade e conforto do paciente.(29, 30, 27).

1.2 Definição do Problema Científico

1.2.1 Artefatos Não Relacionados à Subamostragem

Além do ruído causado pela subamostragem, a imagem de ressonância magnética está suscetível a gerar uma variabilidade de artefatos por outros fatores como o fluxo sanguíneo, interação magnética com próteses, movimento e modelos de IA treinados com conjuntos de dados que ignoram esse fatores podem tentar realizar uma reconstrução imprecisa (20, 2, 15).

Um modelo que não foi treinado para reconhecer uma prótese metálica, por exemplo, pode interpretá-la de forma incorreta, gerando estruturas falsas ou mascarando estruturas reais.

A fronteira existente entre imensa gama de imprevisibilidade de artefatos presentes no mundo real pode ser demonstrar ineficaz clinicamente quando aplicada em larga escala.

1.2.2 Generalização da tecnologia

Outra questão que se torna latente é a diferença da forma de aquisição dos dados do espaço k. Equipamentos de fabricantes, softwares, protocolos e campos diferentes realizam a aquisição de forma particular, tornando a representação no espaço k distinta para cada um (31, 9).

O custo para criar um software individual para cada máquina se apresenta como inviável diante da infinidade de características a se considerar, levando a necessidade de criação de um algoritmo que consiga generalizar de forma consistente a reconstrução.

Algoritmos com essa capacidade necessitariam da capacidade de se adaptar rapidamente a novos domínios com quantidades mínimas de dados, aprendendo a se moldar de acordo com o equipamento em que está aplicado (16, 15).

1.2.3 Falta de Transparência na tomada de decisões

É válido salientar que todo modelo possui limitações práticas e quando falamos de IA, é necessário considerar que o processo de tomada de decisões não é transparente, dificultando a análise do quão confiável são as imagens geradas pelo algoritmo (20).

A existência de indicadores de precisão que informe áreas mais críticas da reconstrução e imprecisão de determinadas estruturas é um desafio de implementação necessário para aumentar a confiabilidade dessas imagens.

1.2.4 Homogeneidade das Bases de dados

A eficácia dos modelos de IA na reconstrução de imagens de Ressonância Magnética subamostrada está diretamente ligada à qualidade e diversificação dos dados usados em seu treinamento. A partir daí surge um grande desafio científico causado pela composição demográfica das base de dados que temos disponíveis, que são compostas, em sua maioria, por imagens de pacientes de regiões como América do Norte e Europa, excluindo a representatividade de biotipos do sul global, o que reduz a acurácia e gera um viés sistêmico que pode comprometer a qualidade de geração quando essa tecnologia é aplicada em outras regiões (2, 15).

O problema central é que os algoritmos de IA, ao serem trainados por conjuntos homogêneos aprendem *priors* que podem não ser universalmente aplicáveis a todas as etnias. Estudos de grande impacto demonstraram que modelos de IA conseguem distinguir, com alta acurácia, a raça autodeclarada de um paciente a partir de imagens médicas, tarefa que até para especialistas é difícil (17, 2, 15, 32). A capacidade de fazer essa identificação se dá a partir de padrões texturais e de frequência nos tecidos que são quase invisíveis ao olho humano.

Essa capacidade indica que modelos treinados aprendem a partir de características que vão além das patologias de interesse, mostrando que, nesse contexto, a reconstrução de imagens de RM a partir de dados subamostrados no espaço k, pode se tornar potencialmente perigosa se não houver diversificação das bases de dados, pois um modelo treinado predominantemente com dados de uma etnia, pode interpretar variações anatômicas normais de um determinado grupo como anomalias ou pior, tratar patologias como artefatos a serem corrigidos durante a reconstrução, ocultando objetos de interesse na imagem.

Portanto, a falta de diversidade das bases de dados pode se demonstrar um desafio na robustez e equidade das imagens geradas, criando viés que compromete a precisão do diagnóstico final (15, 2, 20, 17).

Para mitigar a dependência de bases de dados massivas, a literatura aponta a possibilidade do uso de alternativas focadas na arquitetura dos algoritmos e no processo de treinamento como o uso de Modelos Guiados por Física e técnicas como a Transferência de Aprendizado *(Transfer Learning)* que permitem o ajuste fino de modelos pré-treinados utilizando amostras pequenas e locais, enquanto o Aprendizado Federado possibilita o treinamento global de algoritmos sem a necessidade de centralizar os dados dos pacientes. Essas abordagens demonstram que a confiabilidade da reconstrução não depende exclu-

sivamente do volume de dados, mas também da robustez da modelagem matemática e arquitetural.

1.3 Proposta de Pesquisa

Apesar dos avanços significativos na aceleração dos exames de Ressonância Magnética, a escolha de qual o método mais eficaz para a realização da reconstrução ideal continua sendo um campo de pesquisa amplamente explorado (14, 15, 31).

Técnicas como o *Compressive Sensing (CS)* estabeleceram um paradigma ao explorar a esparsidade das imagens médicas na reconstrução de imagens subamostradas. Mais recentemente, o *Deep Learning*, em especial as *U-nets* e as Redes Adversárias Geradoras Condicionais (cGANs, do inglês *Conditional Generative Adversarial Networks*), demonstram uma capacidade de aprender e restaurar imagens de alta fidelidade superando os métodos tradicionais (13, 31, 33, 15).

Contudo, a superioridade em métricas de qualidade de imagem não garante confiabilidade clínica de um modelo. Questões como a presença da criação de detalhes anatômicos, falhas na reconstruções de patologias mais incomuns e a falta de transparência na decisão tomada pelo modelo são desafios críticos (20, 15, 34).

Diante disso, essa pesquisa propõe realizar uma análise comparativa entre o método CS, e duas das mais populares arquiteturas de *Deep Learning*, as *U-Net* e *cGAN*, para reconstrução de imagens de RM subamostradas.

O estudo não se limitará a comparar a qualidade da imagem em termos de fidelidade visual e métricas quantitativas. A proposta central é investigar a confiabilidade de cada método. Isso será feito através de avaliação de robustez dos modelos frente a cenários diversos de subamostragem e da sua capacidade de reconstrução fiel tanto de estruturas naturais quando de anomalias, sem introduzir artefatos nem omitir estruturas relevantes.

1.4 Objetivos

1.4.1 Objetivo Geral

O objetivo geral é realizar uma avaliação comparativa aprofundada entre os métodos de Compressive Sensing, *U-Net* e *cGAN*, a fim de determinar qual abordagem oferece o melhor equilíbrio entre qualidade de imagem e confiabilidade para a reconstrução de imagens de RM subamostradas.

1.4.2 Objetivos Específicos

Para alcançar o objetivo geral deste trabalho, foram estabelecidos os seguintes objetivos específicos:

- Gerar imagens de controle baseadas em *Compressive Sensing*.
- Treinar modelos funcionais baseados nas arquiteturas *U-Net* e *cGANS*.
- Comparar a qualidade de reconstrução das imagens utilizando os três métodos por meio de métricas de Relação Sinal-Ruído e Índice de Similaridade Estrutural.
- Analisar a confiabilidade dos modelos focando na capacidade de preservar detalhes estruturais e na introdução de artefatos.
- Testar a robustez dos modelos com diferentes taxas de subamostragem.
- Discutir as implicações clínicas dos resultados obtidos.

2 Fundamentação Teórica

2.1 Princípios da Imagem por Ressonância Magnética

A Imagem por Ressonância Magnética é uma modalidade não invasiva de geração de imagem médica que se destaca por sua capacidade de diferenciação de tecidos moles e versatilidade na ponderação dos parâmetros sem que seja necessário o uso de radiação ionizante (1, 2).

A geração desse tipo de imagem se baseia no fenômeno físico denominado Ressonância Magnética Nuclear (MRN), no qual os processos de relaxação geram o contrate da imagem, enquanto o mecanismo de codificação espacial mapeia o sinal para o espaço k e a teoria da amostragem dita as regras para a reconstrução livre de artefatos (1, 8, 2).

2.1.1 O Fenômeno da Ressonância Magnética Nuclear

O fenômeno da Ressonância Magnética Nuclear(RMN) é o pilar de geração de imagem desse tipo de exame e se origina da propriedade mecânico-quântica fundamental no núcleo de certos átomos, denominada *spin* (1, 3, 2, 35).

O núcleo de átomos com número ímpar de prótons ou neutrons, como é o caso do hidrogênio, apresentam um momento angular intrinseco, denominado *spin*. O corpo humano possui esse átomo em abundância devido a predominância de água e gordura em sua composição, tornando viável a realização do exame de ressonância magnética (1, 3, 2).

O *spin*, por gerar um momento magnético, faz com que cada núcleo se comporte de forma similar a um ímã de barra, com campo magnético direcional. Em condições normais, sem a presença de um campo magnéticoe externo, a direção desse momento em cada átomo se comporta de forma aleatória (1, 2, 35).

No exame de ressonância magnética, o paciente é inserido em uma máquina com uma campo magnético extremamente forte denominado B_0, que faz com que os momentos de alinhem com a mesma orientação, porém, seu sentido pode ser paralelo ou antiparalelo a B_0.

A soma vetorial de todos os momentos magnéticos individuais gera um vetor de magnetização líquida denominado M_0, que é macroscópico e alinhado em direção com o campo B_0, convencionado como eixo z. Além desse alinhamento, o campo B_0 gera torque sobre cada momento magnético, fazendo com que eles precessem em torno desse eixo. A frequência dessa precessão é conhecida como frequência de Larmor (ω_0) e é diretamente

proporcional ao campo magnético, sendo descrita pela equação (1, 35, 7)

$$\omega_0 = \gamma B_0 \tag{2.1}$$

onde γ é a razão giromagnética, uma constante específica de cada tipo de núcleo. Para o caso do próton de hidrogênio, ela é de aproximadamente 42,58 MHz/T (1, 35).

2.1.2 A Equação de Bloch

A descrição completa do comportamento do vetor de magnetização líquida $\vec{M}$ sob a influência de todos os campos (o estático $\vec{B_0}$ e o de radiofrequência $\vec{B_1}$) e dos efeitos de relaxação é unificada pela **Equação de Bloch** (1, 35).

No referencial estacionário, considerando o campo total $\vec{B} = B_x\hat{i} + B_y\hat{j} + B_z\hat{k}$, a equação vetorial pode ser expandida em três componentes escalares, que descrevem a taxa de variação de cada componente da magnetização:

$$\frac{dM_x}{dt} = \gamma(M_y B_z - M_z B_y) - \frac{M_x}{T_2} \tag{2.2}$$

$$\frac{dM_y}{dt} = \gamma(M_z B_x - M_x B_z) - \frac{M_y}{T_2} \tag{2.3}$$

$$\frac{dM_z}{dt} = \gamma(M_x B_y - M_y B_x) - \frac{(M_z - M_0)}{T_1} \tag{2.4}$$

Os termos com γ descrevem a precessão do vetor de magnetização em torno do campo magnético. Os termos $\frac{M_x}{T_2}$ e $\frac{M_y}{T_2}$ descrevem o decaimento da magnetização transversal. O termo $\frac{(M_z - M_0)}{T_1}$ descreve a recuperação da magnetização longitudinal em direção ao seu valor de equilíbrio M_0 (1, 35).

O fenômeno da ressonância acontece quando um pulso de radiofrequência (RF), denominado B_1, é aplicado perpendicularmente a B_0, com uma frequência que corresponde exatamente à frequência de Larmor do núcleo dos átomos, este pulso RF sintonizado transfere energia para os *spins* de forma eficiente, fazendo-os transicionar do estado de baixa energia para o de alta. O efeito disso é que o vetor M_0 irá ser desviado do eixo z para o plano transversal xy, como ilustrado na figura 1. Esse vetor de magnetização em precessão induz uma corrente elétrica em uma bobina receptora, que constitui o sinal de RM conhecido como Decaimento por Indução Livre (FID, do inglês Free Induction Decay) (1, 3, 2, 35).

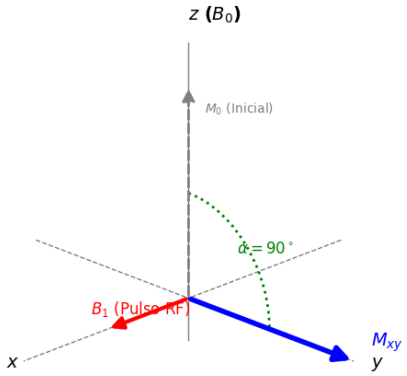


Figura 1 – Representação vetorial do fenômeno de ressonância. A aplicação de um pulso de radiofrequência B_1 (em vermelho) provoca um torque no vetor de magnetização líquida M_0, desviando-o do eixo longitudinal z (alinhado com B_0) em direção ao plano transversal xy, gerando a componente M_{xy} responsável pelo sinal de RM.

Fonte: Elaborado pelo autor.

2.1.3 Tempos e Equações de Relaxação T1 e T2

Após cessar o pulso de RF, o sistema de *spins*, que se encontrava em um estado de alta energia e coerência de fase, começa a retomar ao seu estado de equilíbrio alinhado com B_0. Esse retorno é governado pelas soluções das equações de Bloch e ocorre por meio de dois processos simultâneos e independentes: a relaxação longitudinal (T1) e a relaxação transversal (T2) (1, 3, 2).

2.1.3.1 Relaxação Longitudinal (T1)

O tempo de relaxação T1, também chamado de relaxação *spin-rede*, descreve a recuperação da magnetização ao longo do eixo z (M_z). É o processo pelo qual os *spins* excitados liberam a energia absorvida do pulso RF para a estrutura molecular circundante (a "rede") (1, 7, 4).

A recuperação da magnetização longitudinal em função do tempo t é dada pela solução da equação de Bloch para o componente z:

$$M_z(t) = M_0 \left(1 - e^{-\frac{t}{T1}}\right) \tag{2.5}$$

Onde M_0 é a magnetização de equilíbrio. O valor de T1 é definido como o tempo necessário para que a magnetização longitudinal recupere aproximadamente 63% do seu valor inicial.

Tecidos com moléculas que "tombam"em frequências próximas à frequência de Larmor (como a gordura) transferem energia de forma eficiente, resultando em T1 curto (recuperação rápida). Já moléculas pequenas e móveis como a água pura possuem interações menos eficientes, resultando em T1 longo (recuperação lenta). Em imagens ponderadas em T1 (TR curto), tecidos com T1 curto aparecem brilhantes (hiperintensos) (1, 3).

2.1.3.2 Relaxação Transversal (T2)

O tempo de relaxação T2, ou *spin-spin*, descreve o decaimento da magnetização no plano transversal (M_{xy}). Após o pulso RF, os spins precessam em fase. No entanto, as interações magnéticas locais entre *spins* vizinhos causam pequenas flutuações no campo magnético sentido por cada núcleo, fazendo com que precessem em frequências ligeiramente diferentes e percam a coerência de fase (1, 3).

O decaimento da magnetização transversal é exponencial e descrito por:

$$M_{xy}(t) = M_{xy}(0)e^{-\frac{t}{T2}} \tag{2.6}$$

A constante T2 é o tempo necessário para que a magnetização transversal caia para aproximadamente 37% do seu valor inicial. Tecidos com estruturas mais rígidas ou macromoléculas tendem a ter T2 curto (decaimento rápido), enquanto líquidos livres como o líquor (LCR) e a água possuem T2 longo (decaimento lento), aparecendo brilhantes em imagens ponderadas em T2 (TE longo) (1, 2).

A Figura 2 ilustra o comportamento distinto dessas curvas para diferentes tecidos, evidenciando a base do contraste em RM.

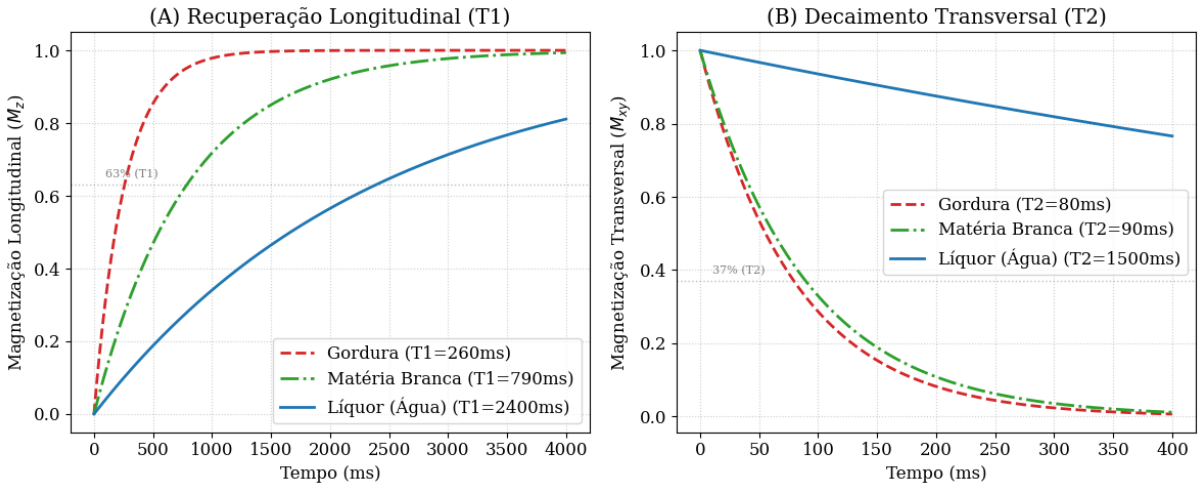


Figura 2 – Simulação das curvas características de relaxação para Gordura, Matéria Branca e Líquor em campo de 1.5T. (A) Recuperação da magnetização longitudinal (T1). (B) Decaimento da magnetização transversal (T2). Note a diferença significativa nas escalas de tempo entre os tecidos, base física para o contraste em RM.

Fonte: Elaborado pelo autor com base em valores de referência de Brown et al. (1).

Tabela 1 – Valores aproximados dos tempos de relaxação T1 e T2 para tecidos biológicos em campo magnético de 1.5 Tesla. Note a grande diferença entre líquidos (LCR) e tecidos estruturais.

Tecido	**T1 (ms)**	**T2 (ms)**	**Característica**
Gordura	≈ 260	≈ 80	Recuperação rápida
Músculo	≈ 870	≈ 45	Decaimento rápido
Matéria Branca	≈ 790	≈ 90	Intermediário
Matéria Cinzenta	≈ 920	≈ 100	Intermediário
Líquor (LCR/Água)	≈ 2400	≈ 1500	Sinais longos

Fonte: Adaptado de Hashemi et al. (3) e Brown et al. (1).

2.1.4 Codificação Espacial e o Espaço k

Após a excitação de um corte do tecido, o sinal de RM emitido é uma composição de sinais de todos os locais dentro de um corte. Para formar uma imagem, é necessário codificar espacialmente esses sinais, ou seja, determinar a origem espacial de cada componente. Isso é alcancado por meio da aplicação de gradientes de campo magnético controlados superpostos ao campo B_0 (1, 8, 2).

O processo de formação da imagem se fundamenta na Transformada de Fourier já que o sinal captado pelo equipamento de RM está no domínio de frequência espacial

demoninado espaço k (8, 9, 12), que consiste numa matriz de dados em que cada ponto (k_x, k_y) representa uma frequência espacial da imagem (8, 5, 9).

A relação entre a imagem final do domínio espacial, $I(x, y)$, e os dados no espaço k, $S(kx, k_y)$, é governada pela Transformada de Fourier bidimensional, dada por

$$I(x, y) = \mathcal{F}^{-1}\{S(k_x, k_y)\} = \iint S(k_x, k_y) e^{i2\pi(k_x x + k_y y)} dk_x dk_y. \tag{2.7}$$

A aquisição de dados da RM é o processo de preenchimento da matriz no espaço k feito linhas por linha utilizando dois tipos de gradiente, o de codificação de frequência e o de codificação de fase (1, 8, 9).

O gradiente de codificação de frequência é aplicado durante a leitura do eco e cria uma variação linear na frequência de precessão ao longo de uma direção, permitindo que a Transformada de Fourier decomponha o sinal lido em suas componentes de frequência, que correspondem a diferentes posições espaciais ao longo desse eixo.

O gradiente de codificação de fase, é aplicado brevemente antes da leitura do eco e induz uma variação de fase dependente da posição ao longo de outra direção. Variando a amplitude desse gradiente a cada ciclo de Tempo de Relaxação, diferentes linhas no espaço k são adquiridas.

A estrutura do espaço k tem influencia total sobre a qualidade da imagem, sendo que cada ponto neste domínio influencia todos os pixels da imagem final (9, 12, 5), sendo os pontos no centro responsáveis pela baixas frequências, que definem contornos básicos, enquanto os mais periféricos correspondem aos detalhes finos (8, 9, 12).

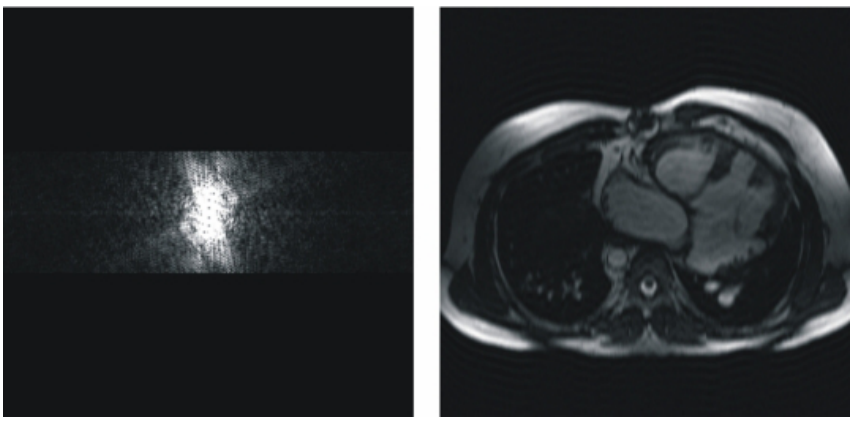


Figura 3 – Demonstração da distribuição de frequências no Espaço-k. O centro (b) contém as baixas frequências que definem o contraste e formas gerais, enquanto a periferia (c) contém as altas frequências responsáveis pelas bordas e detalhes finos.

Fonte: Adaptado de Moratal et al. (36).

2.1.5 O Teorema da Amostragem de Nyquist-Shannon no Contexto da RM

A transição dos dados adquiridos no espaço k para uma imagem é regida pelo Teorema da Amostragem de Nyquist-Shannon, que determina a condição suficiente para que um sinal possa ser reconstruído sem perdas. Ele afirma que a frequência de amostragem f_s deve ser pelo menos duas vezes maior que a frequência máxima f_{max} contida no sinal

$$fs \leq 2f_{max}, \tag{2.8}$$

na qual a frequência mínima $2f_{max}$ é conhecida como a taxa de Nyquist. Em RM, o teorema se aplica diretamente à amostragem no espaço k, no qual a largura do Campo de Visão (FOV, do inglês *Field of View*) em determinada direção da imagem é inversamente proporcional ao espaçamento entre as amostras, com um passo Δk, nessa direção. Essa relação é dada por

$$FOV = \frac{1}{\Delta k}. \tag{2.9}$$

Para reconstruir uma imagem sem artefatos, o espaço deve ser amostrado com um Δk suficientemente pequeno para que o campo de visão resultadnte seja maior ou igual ao tamanho do objeto sendo imageado. As consequências da violação desse critério são chamados de *aliasing* (11, 1, 8, 2, 12, 9).

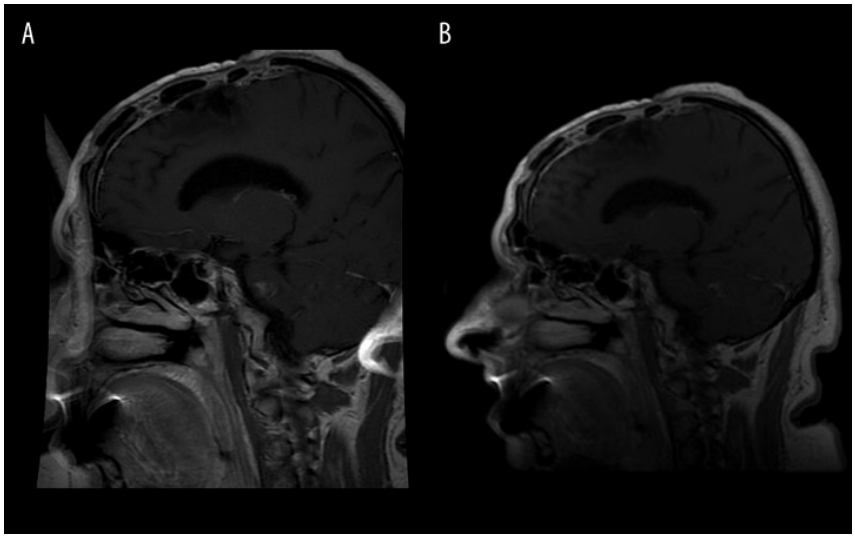


Figura 4 – Artefato de *aliasing* (wrap-around) em imagem cerebral. Devido à escolha de um FOV menor que a anatomia do paciente, a região occipital é projetada incorretamente sobre a região frontal, prejudicando o diagnóstico.

Fonte: Krupa e Bekiesiska-Figatowska (37).

2.1.6 Aceleração da Aquisição em RM: Abordagens Tradicionais

O principal gargalo quando tratamos do exame de ressonância magnética é o tempo de aquisição, que pode se tornar até um impeditivo para alguns pacientes e que pode gerar

artefatos de imagem em alguns casos. Acelerar essa aquisição envolve, invariavelmente, em subamostragem do espaço k, ou seja, coletar menos dados que o exigido pelo Teorema de Nyquist. Existem duas categorias principais de abordagem para reconstução subamostrada, a imagem paralela e o sensoriamento comprimido (14, 10, 13, 6, 12).

2.1.6.1 Imagem Paralela (SENSE E GRAPPA)

A técnica de imagem paralela consiste em utilizar múltiplas bobinas receptoras para fazer aquisições simultâneas mas com diferentes sensibilidade espacial. Dessa forma, a imagem reconstruída por cada bobina apresentará características de artefato diferentes e essa informação extra é a chave para remover o artefato e gerar uma imagem limpa. Os dois métodos mais proeminentes de remoção de artefato são:

- **SENSE *(Sensitive Encoding)***: Esse tipo de reconstrução opera no domínio da imagem e funciona através da combinação das imagens de cada bobina, reconhecendo seus mapas de sensibilidade e gera uma imagem final a partir da comparação pixel a píxel das geradas por cada bobina (10, 18, 12).
- **GRAPPA *GeneRalized Autocalibrating Partially Parallel Acquisitions***: Essa técnica opera diretamente no espaço k, utlizando as linhas centrais, adquiridas completamente, para aprender pesos aplicados a uma interpolação que permite sintetizar as linhas faltantes a partir das adjacentes já adquiridas (14, 10, 18, 12).

2.1.6.2 Sensoriamento Comprimido (CS)

O sensoriamento comprimido é uma técnica de processamento de sinais que se baseia na aquisição e reconstrução de um sinal a partir do princípio de esparsidade. Ela se baseia em três princípios:

- **Esparsidade:** O sinal deve ser esparso no domínio de transformação utilizado. No caso de imagens médicas, esse sinal é tipicamente esparso no domínio das Wavelets, por exemplo, onde a maioria dos coeficientes é zero ou próximo dele (13, 11, 19, 12).
- **Subamostragem Incoerente:** a subamostragem do espaço deve ser feita de forma incoerente, o que faz o artefato de aliasing, que é coerente, se transformar em um ruído incoerente, de baixa amplitude e que pode ser mais facilmente removido por filtragem na imagem esparsa (13, 19, 12).
- **Reconstrução Não Linear:** A imagem é reconstruída a partir de dados subamostrados, buscando a imagem que, sendo esparsa no domínio, melhor se ajusta aos parâmetros adquiridos no espaço k. É um processo iterativo e computacionalmente intensivo (13, 11, 19, 12).

O CS permite uma aceleração maior que os métodos de imagem paralela, mas demanda maior capacidade computacional e mais tempo para conseguirmos reconstruir a imagem (13, 12).

2.1.7 Inteligência Artificial e Aprendizado Profundo na Reconstrução de Imagens Médicas

As limitações impostas pelas abordagens tradicionais abriram caminho para a aplicação de técnicas de IA, especialmente o Aprendizado Profundo (DL - Deep Learning do inglês), para realizar a reconstrução de imagens de RM (16, 17, 20, 15).

2.1.7.1 Aprendizado de Máquina e Aprendizado Profundo

O Aprendizado de Máquina (ML - Machine Learning do inglês) clássico envolve a extração de padrões relevantes de uma imagem, que são utilizados por um algoritmo para realizar uma tarefa. No DL a extração de características é feita de forma automática, pela própria rede neural por meio de um banco de dados, possuindo múltiplas camadas que conseguem tratá-los de forma hierárquica (17, 20, 21, 15).

2.1.7.2 Redes Neurais Convolucionais (CNNs)

As Redes Neurais Convolucionais (CNNs), são uma das classes de DL que possui uma ampla aplicação para tratamento de imagens, pois trabalham com sinais que são topologicamente em formato de grade, como é o caso. Ela atua por meio de operações de convolução de sinais, na qual um filtro percorre a imagem em busca de padrões como bordas, texturas e formatos. Com a sobreposição de diversas camadas é possível que a Rede aprenda padrões mais complexos e abstratos (20, 21, 15).

2.1.7.3 A Arquitetura U-Net

A arquitetura U-Net já nasceu com a proposta de segmentação de imagens biomédicas e tornou-se um bloco de construção extremamente importante e influente nesse meio. Sua estrutura em forma de "U"é composta por três etapas principais:

- **Codificador:** é formada por uma sequência de camadas convolucionais e de *pooling* que reduzem a resolução espacial da entrada enquanto aprende representações com características cada vez mais complexas.
- **Decodificador:** se baseia em uma sequência de camadas de *up-sampling* e convoluções que progressivamente reconstrói a saída desejada aumentando a resolução espacial.

- **Conexões de Atalho:** são a grande inovação das U-Nets, se ligam diretamente as camadas do codificador, e as correspondente no decodificador, permitindo a combinação de dados de espaciais de alta resolução ao decodificador ajudando a recuperar detalhes finos que seriam perdidos na compressão e descompressão (31, 20, 15).

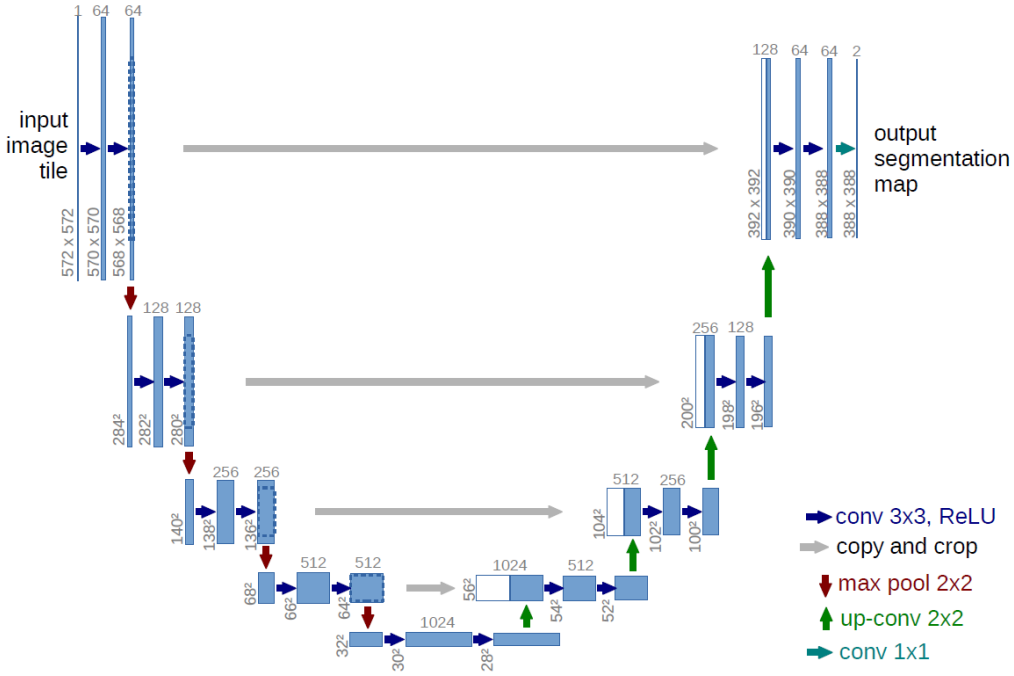


Figura 5 – Diagrama esquemático da arquitetura U-Net. As setas cinzas representam as conexões de atalho, que transferem informações de alta resolução do caminho de contração para o de expansão, essenciais para preservar detalhes anatômicos na reconstrução.

Fonte: Adaptado de Ronneberger et al. (31).

2.1.8 Técnicas de Aprendizado Profundo para Reconstrução Acelerada de RM

2.1.8.1 Mapeamento Direto Imagem para Imagem por U-Net

A reconstrução por DL trata o problema como uma tarefa de traduzir imagem para imagem por meio da U-Net, que recebe a entrada como uma imagem com artefato de subamostragem e é treinada para gerar como saída uma imagem correspondente totalmente amostrada e sem artefatos.

O treinamento é supervisionado utilizando pares de imagens subamostradas e totalmente amostradas. A função de perda mais comum para essa tarefa é a medição do erro pixel a pixel entre a imagem reconstruída e a original livre de artefato. As formas mais utilizadas são:

- **Erro Absoluto Médio (MAE ou L1):**

$$L_{MAE} = L2 = \frac{1}{N}\sum_{i-1}^{\infty}|\hat{y}_i - y_i| \tag{2.10}$$

- **Erro Médio Quadrático (MSE ou L2):**

$$L_{MSE} = L1 = \frac{1}{N}\sum_{i=1}^{\infty}(\hat{y}_i - y_i)^2 \tag{2.11}$$

A U-Net treinada com L1 ou L2 é amplamente utilizada, mas tende a produzir imagens com suavizações devido a minimização de erro médio dos pixels, podendo perder algumas texturas presentes em altas frequências (31, 38, 20, 15).

2.1.8.2 Reconstrução com Redes Adversárias Generativas Condicionais (CGANs)

Enquanto as U-Nets treinadas apenas com funções de perda baseadas em erro de pixel (L1 ou L2) são eficientes na redução de artefatos, elas tendem a produzir imagens com texturas suavizadas (*blur*). Isso ocorre porque minimizar o Erro Médio Quadrático (MSE) leva a rede a gerar uma "média"de todas as soluções plausíveis para uma dada entrada, resultando na perda de detalhes de alta frequência (33, 31).

O uso de Redes Generativas Adversárias (GANs) é uma alternativa para superar a suavização das perdas de pixel. Esse método consiste em duas redes competindo pelo resultado da seguinte forma:

- **O Gerador (G):** Tenta criar imagens sintéticas que sejam indistinguíveis das imagens reais.
- **O Discriminador (D):** Tenta classificar corretamente se uma imagem apresentada é real (do *dataset* de treino) ou falsa (criada pelo gerador) (39).

No contexto da reconstrução de RM, utiliza-se uma variante chamada GAN Condicional (cGAN), onde o gerador não cria uma imagem do nada, mas sim condicionada a uma entrada (nesse caso, a imagem subamostrada com artefatos). A estrutura mais comum para o Gerador nesse caso é a própria U-Net (33, 40).

A grande vantagem reside na função de perda, já que em uma cGAN, a perda total é uma combinação ponderada da perda de conteúdo (pixel-a-pixel) e da perda adversarial:

$$L_{Total} = \underbrace{\lambda L_{L1}(G)}_{\text{Fidelidade}} + \underbrace{L_{GAN}(G, D)}_{\text{Realismo}} \tag{2.12}$$

- **Perda de Conteúdo (L_{L1}):** Garante que a estrutura anatômica da imagem gerada corresponda à do paciente, minimizando a diferença absoluta entre os pixels da saída e da referência.

- **Perda Adversarial (L_{GAN}):** Esta é a componente crítica. O discriminador penaliza qualquer imagem que não pareça "realística", independentemente do erro de pixel. Isso força o gerador a aprender a distribuição estatística (o *manifold*) das imagens de RM reais, recuperando texturas finas e bordas nítidas que "enganam"o discriminador, algo que a perda L1 sozinha não consegue capturar (33, 40, 15).

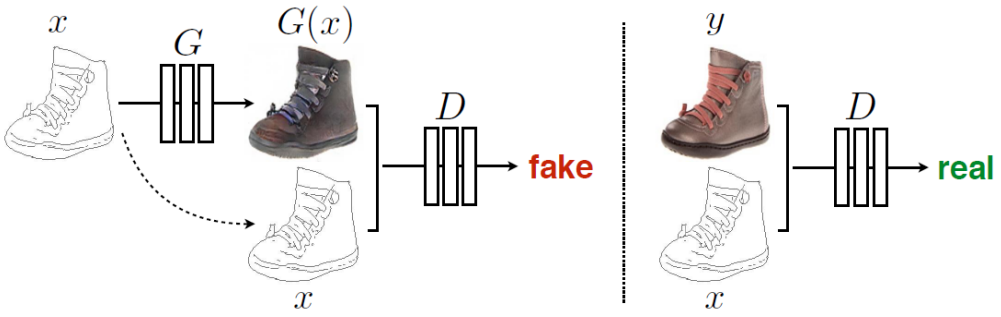


Figura 6 – Estrutura de treinamento de uma GAN condicional (cGAN). Diferente de uma GAN tradicional, o discriminador D observa pares de imagens: o par "Real"consiste na entrada original x e o alvo desejado y, enquanto o par "Falso"consiste na entrada x e a imagem gerada $G(x)$. O gerador G tenta minimizar a diferença entre o par real e o falso para enganar o discriminador.

Fonte: Adaptado de Isola et al. (33).

2.1.8.3 Modelos Guiados por Física com Redes Variacionais(VarNet)

Modelos como CGANs, operam no domínio da imagem, e não garantem que a imagem gerada tenha relação com os dados brutos diretamente adquiridos pelo equipamento de RM. Os modelos guiados por física abordam essa questão integrando os dados brutos adquiridos no espaço k diretamente na rede.

As VarNets são um exemplo de técnica que mimetiza o modelo clássico de reconstução como o CS, mas substitui os operadores manuais por blocos de redes neurais convolucionais aprendidos, realizando em cada operação os passos:

- **Refinamento no Domínio da Imagem:** realizada por uma CNN que realiza a estimativa da imagem com remoção dos artefatos.

- **Consistência de Dados do Espaço k:** a imagem refinada volta ao espaço k e os valores nas posições que foram efetivamente amostrados pelo equipamento são substituídos pelos dados realmente amostrados, garantindo fidelidade às medições físicas. Após isso, retorna-se ao domínio da imagem.

Essa abordagem combina a geração de imagem pelas redes neurais com a consistência física dos dados, aumentando a fidelidade (41, 42, 15).

2.1.8.4 Modelos Generativos de Difusão(DDPMs)

Os DDPMs são o estado a arte em geração de imagem por terem a capacidade de aprender a reverter um processo de adição de ruído (43, 44, 45) e consiste em duas etapas:

- **Processo de Difusão:** um processo físico fixo onde uma pequena quantidade de ruído Gaussiano é adicionado de forma iterativa a imagem real ao longo de um período até que a imagem se torne um ruído Gaussiano puro e indistinguível.
- **Processo Reverso:** nessa etapa, uma rede neural é treinada para reverter o processo anterior, começando com o ruído puro e removendo-o iterativamente até que a imagem apresentada seja limpa e realista.

Quando aplicados dentro do processo de reconstrução, os DDPMs podem gerar imagens de altíssima fidelidade e realismo, porém, com um alto custo computacional, por necessitarem de muitas iterações (43, 44, 46, 45).

Tabela 2 – Comparativo entre as abordagens de Aprendizado Profundo aplicadas à reconstrução acelerada de RM.

Arquitetura	**Domínio**	**Vantagem Principal**	**Limitação Principal**
CNN / U-Net	Imagem	Velocidade de inferência (tempo real)	Tendência a suavizar texturas finas (perda L2) (31)
cGANs	Imagem	Recuperação de texturas realistas e alta nitidez	Risco de "alucinação"de detalhes não existentes (33)
VarNet	Híbrido	Consistência física com os dados adquiridos (k-space)	Alto custo computacional de treinamento (41)
Difusão (DDPM)	Imagem	Estado da arte em qualidade visual	Tempo de reconstrução lento (processo iterativo) (43)

Fonte: Elaborado pelo autor com base em Knoll et al. (16) e Lebel (15).

2.1.9 Métricas de Avaliação de Qualidade de Imagem

Para comparar os resultados das técnicas utilizadas é necessária uma comparação baseada em métricas quantitativas e qualitativas.

As métricas quantitativas tem como objetivo realizar a comparação pixel a pixel de uma imagem de referência com a reconstruída com base nela, sendo possível realizar a avaliação da proximidade das imagens e mensurar o quanto de informação foi perdida ou adicionada (47, 48, 34).

2.1.9.0.1 Relação Sinal-Ruído (SNR)

A Relação Sinal-Ruído (*Signal-to-Noise Ratio* - SNR) é uma métrica física utilizada para quantificar a intensidade do sinal útil em relação ao ruído de fundo ou artefatos introduzidos pelo processo de reconstrução. Medida em decibéis (dB), o SNR é definido matematicamente pela razão entre a potência da imagem de referência e a potência do erro de reconstrução:

$$SNR(I_{GT}, I_{Rec}) = 10 \log_{10} \left(\frac{\sum_{x,y}[I_{GT}(x,y)]^2}{\sum_{x,y}[I_{GT}(x,y) - I_{Rec}(x,y)]^2} \right) \tag{2.13}$$

onde:

- $I_{GT}(x, y)$ representa a intensidade do pixel na posição (x, y) da imagem original (*Ground Truth*);
- $I_{Rec}(x, y)$ representa a intensidade do pixel na imagem reconstruída pelo modelo;
- O denominador corresponde à energia do ruído (ou erro residual).

2.1.9.0.2 Relação Sinal Ruído de Pico(PSNR)

O PSNR (do inglês *Peak Signal-to-Noise Ratio*) mede a relação entre a potência máxima possível do sinal e a potência do ruído de erro que afeta a fidelidade da sua representação. É calculado em decibéis (dB) e baseia-se no Erro Médio Quadrático (MSE) entre a imagem reconstruída e a imagem de referência (47, 34, 48). A relação é definida por:

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right). \tag{2.14}$$

(47, 48, 34) onde MAX_I é o valor máximo possível de um pixel na imagem (por exemplo, 255 para 8 bits). Quanto maior o valor do PSNR, menor é a distorção e maior a qualidade da reconstrução em relação à referência.

2.1.9.0.3 Índice de Medida da Similaridade Estrutural(SSIM)

Enquanto o PSNR estima o erro absoluto, o SSIM (do inglês (*Structural Similarity Index Measure*)) é uma métrica de percepção projetada que para modelar a forma como o sistema visual humano interpreta a qualidade da imagem. O SSIM avalia a degradação da qualidade considerando três componentes independentes: luminância, contraste e estrutura (47, 34). Ele varia de -1 a 1, onde 1 indica que a imagem reconstruída é estruturalmente idêntica à referência. Diferente do MSE/PSNR, o SSIM é menos sensível

a mudanças globais de brilho e mais sensível a distorções em bordas e texturas, sendo considerado uma métrica mais alinhada com a avaliação radiológica visual (47).

Tabela 3 – Resumo das métricas quantitativas utilizadas na avaliação de qualidade de reconstrução.

Métrica	**Tipo**	**Interpretação**
SNR	Física	Razão sinal/ruído. Indica a robustez do sinal adquirido.
PSNR	Erro	Mede a fidelidade do sinal em dB. Quanto maior, mais próximo da referência.
SSIM	Percepção	Similaridade estrutural (0 a 1). Modela a percepção visual humana de bordas e luminância.

Fonte: Elaborado pelo autor com base em Wang et al. (47).

3 Metodologia

A metodologia desenvolvida neste trabalho foi estruturada para permitir uma avaliação sistemática e quantitativa de diferentes paradigmas de reconstrução de imagens. O fluxo experimental abrange desde a curadoria dos dados brutos até a validação cruzada dos modelos treinados, garantindo a reprodutibilidade dos experimentos.

3.1 Aquisição e Pré-processamento da Base de Dados

A qualidade e a representatividade dos dados de treinamento são fatores determinantes para o desempenho de modelos baseados em aprendizado profundo (20). Nesta seção, descrevem-se as características do conjunto de dados utilizado e as etapas de tratamento digital aplicadas para adequá-lo às arquiteturas de redes neurais propostas.

3.1.1 Descrição do Conjunto de Dados

Para a realização deste estudo, foram utilizados dados provenientes do repositório público *Biomedical Informatics Research Network* (BIRN) (49). O conjunto selecionado é composto por exames de Ressonância Magnética (RM) cerebral estrutural, contendo volumes com ponderações em T1 e T2. A escolha deste *dataset* justifica-se pela sua heterogeneidade e alta qualidade de aquisição, características essenciais para evitar o sobreajuste (*overfitting*) dos modelos a um único tipo de sensor ou protocolo de aquisição (15).

Os dados brutos foram convertidos do padrão DICOM (*Digital Imaging and Communications in Medicine*) para o formato de matrizes numéricas (`.mat`), facilitando a manipulação algébrica nos ambientes de computação científica. O conjunto final consolidado para este trabalho contabilizou 158 volumes tridimensionais de diferentes pacientes.

A Tabela 4 sumariza as características técnicas do conjunto de dados utilizado.

Tabela 4 – Especificações técnicas do conjunto de dados utilizado nos experimentos.

Característica	**Descrição**
Fonte de Dados	BIRN Data Repository (49)
Modalidade	Ressonância Magnética (MRI)
Região Anatômica	Encéfalo (Cérebro)
Ponderações	T1 e T2
Total de Volumes	158 Pacientes
Dimensão Original (média)	$256 \times 256 \times 120$
Formato de Processamento	Fatias Axiais 2D (Matrizes `.mat`)

Fonte: Elaborado pelo autor.

3.1.2 Pipeline de Pré-processamento

As arquiteturas de redes neurais convolucionais, como a U-Net e a cGAN, exigem que os dados de entrada possuam dimensões espaciais consistentes e distribuições numéricas estáveis para garantir a convergência do algoritmo de otimização (20, 33). Dessa forma, estabeleceu-se um *pipeline* de pré-processamento aplicado individualmente a cada fatia axial extraída dos volumes:

1. **Redimensionamento Espacial:** Independentemente da resolução nativa de aquisição, todas as fatias axiais extraídas foram redimensionadas para uma matriz fixa de 256×256 pixels. Utilizou-se a interpolação bicúbica para preservar a continuidade das estruturas anatômicas durante o redimensionamento.

2. **Normalização de Intensidade:** As imagens de RM não possuem uma unidade absoluta de intensidade (como a Unidade Hounsfield na Tomografia Computadorizada), o que resulta em grandes variações de escala numérica entre diferentes exames (2). Para mitigar este problema e acelerar o treinamento via gradiente descendente, aplicou-se uma normalização *Min-Max* para projetar os valores de intensidade I para o intervalo $[0, 1]$:

$$I_{norm}(x, y) = \frac{I(x, y) - \min(I)}{\max(I) - \min(I)} \tag{3.1}$$

onde I_{norm} representa a imagem normalizada utilizada como entrada nas redes.

3.1.3 Estratégia de Particionamento dos Dados

Um desafio crítico no treinamento de modelos para diagnóstico por imagem é evitar o vazamento de dados (*data leakage*). Como fatias adjacentes de um mesmo volume cerebral possuem alta correlação espacial e anatômica, a inclusão de fatias do mesmo paciente tanto no conjunto de treinamento quanto no de teste enviesaria os resultados, levando o modelo a "memorizar"a anatomia específica do paciente em vez de aprender a reconstruir as estruturas de forma generalizável (15, 20).

Para garantir a independência estatística da avaliação, o particionamento dos dados foi realizado estritamente em **nível de paciente**. O conjunto total de 158 volumes foi dividido aleatoriamente na proporção 80/20:

- **Conjunto de Treinamento (80%):** Composto por 126 volumes. As fatias extraídas destes pacientes foram utilizadas exclusivamente para o ajuste dos pesos sinápticos dos modelos.

- **Conjunto de Teste (20%):** Composto por 32 volumes. Estes dados foram mantidos isolados durante todo o processo de desenvolvimento e utilizados apenas para a inferência final e cálculo das métricas de desempenho.

Para o desenvolvimento deste trabalho, foram processados os volumes 3D dos 158 escaneamentos do *dataset* BIRN. Diferente da abordagem de Compressive Sensing puro, onde fatias isoladas podem ser analisadas, o treinamento dos modelos generativos e da rede U-Net exigiu um volume substancial de dados. Assim, o pipeline de pré-processamento extraiu a sequência completa de cortes axiais de cada volume, resultando em um conjunto de treinamento de aproximadamente 12.800 imagens de 256×256 pixels. Esta estratégia permitiu que as redes aprendessem a reconstruir diferentes níveis anatômicos do encéfalo, aumentando a robustez dos modelos.

O fluxo completo de preparação dos dados é ilustrado na Figura 7.

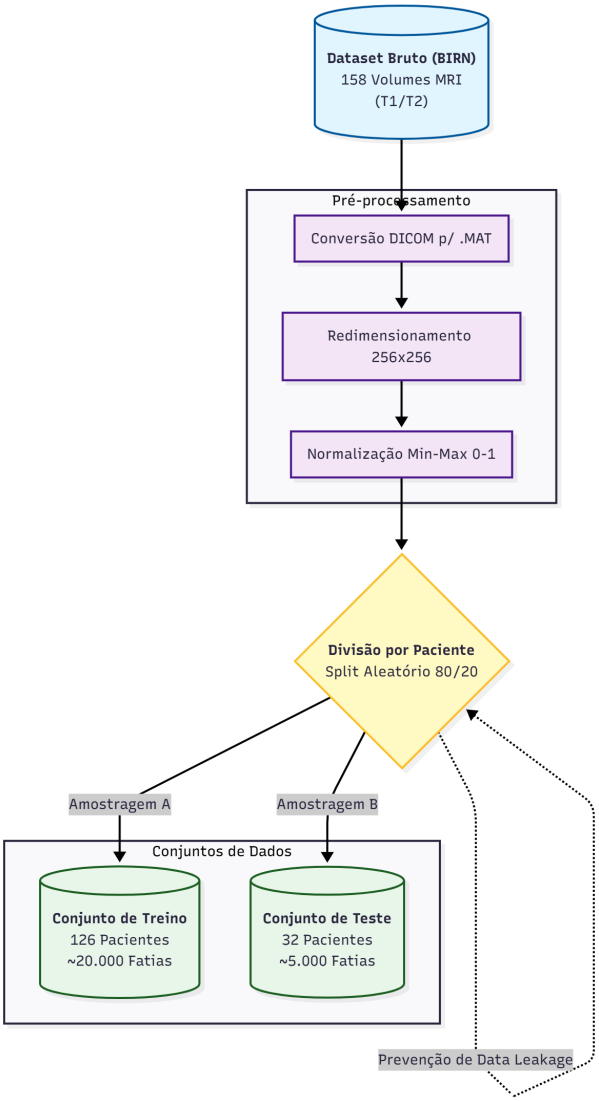


Figura 7 – Fluxograma do pipeline de aquisição e preparação dos dados. O processo destaca a segregação dos dados por paciente antes da extração das fatias, assegurando a integridade da validação.

Fonte: Elaborado pelo autor.

3.2 Modelagem Matemática da Subamostragem Retrospectiva

A validação de algoritmos de reconstrução acelerada exige acesso a dados brutos (*raw data*) do espaço-k. Contudo, devido a restrições proprietárias dos fabricantes de equipamentos de RM, o acesso direto a esses dados brutos subamostrados na fonte é frequentemente limitado. Para contornar essa barreira e permitir uma avaliação quantitativa com uma "verdade absoluta"(*ground truth*) conhecida, adotou-se neste trabalho a metodologia de *Retrospective Undersampling* (Subamostragem Retrospectiva) (13, 16).

Este processo consiste na simulação computacional da aceleração a partir de imagens de magnitude totalmente amostradas. Matematicamente, a aquisição de RM pode ser modelada como um sistema linear onde a imagem adquirida y no domínio da frequência é dada por:

$$y = M \odot \mathcal{F}(x) + \eta \tag{3.2}$$

onde:

- $x \in C^{N \times N}$ representa a imagem original complexa no domínio espacial;
- $\mathcal{F}$ denota o operador da Transformada de Fourier Discreta (DFT) bidimensional;
- $M \in \{0, 1\}^{N \times N}$ é a máscara binária de amostragem, onde 1 indica dados adquiridos e 0 dados descartados;
- $\odot$ representa a multiplicação ponto a ponto (produto de Hadamard);
- η representa o ruído de medição inerente ao sistema (modelado como ruído Gaussiano complexo).

O objetivo dos modelos de reconstrução propostos (CS, U-Net e cGAN) é estimar uma aproximação $\hat{x}$ da imagem original a partir dos dados incompletos y, resolvendo o problema inverso mal-posto:

$$\hat{x} = \mathcal{R}(y) \tag{3.3}$$

onde $\mathcal{R}$ representa a função de reconstrução aprendida ou iterativa.

3.2.1 Design das Máscaras de Amostragem

Para a simulação da aquisição subamostrada, este trabalho adotou um esquema de amostragem em trajetórias espirais. A escolha desta geometria de aquisição fundamenta-se na sua eficiência em cobrir o Espaço-k de maneira não-uniforme, priorizando naturalmente as regiões de maior densidade espectral (13).

As máscaras de amostragem $M(k_x, k_y)$ foram construídas simulando uma trajetória de Arquimedes parametrizada no tempo t. Matematicamente, o caminho percorrido pelos gradientes de campo magnético no domínio da frequência é descrito por:

$$k(t) = A \cdot t^{\alpha} \cdot e^{j\omega t} \tag{3.4}$$

onde:

- A controla a amplitude máxima (campo de visão);
- α define a linearidade da expansão radial;
- ω a frequência angular.

O padrão final é composto pela superposição de múltiplos "braços" rotacionados, garantindo a cobertura necessária do plano de Fourier. Esta abordagem oferece duas vantagens para a reconstrução:

1. **Amostragem Densa no Centro:** Devido à convergência de todos os braços espirais na origem ($k_x = 0, k_y = 0$), a região central, responsável pelo contraste global e pelas baixas frequências espaciais, é superamostrada. Isso assegura que a estrutura básica e a luminosidade da imagem sejam preservadas mesmo em altos fatores de subamostragem.

2. **Incoerência de Aliasing:** Diferente da subamostragem regular que gera réplicas fantasmas (*ghosting*) coerentes, a subamostragem espiral distribui os erros de *aliasing* como ruído ou artefatos em forma de redemoinho. Esses artefatos incoerentes são, teoricamente, mais fáceis de serem removidos por algoritmos de compressão (CS) e redes neurais profundas (16).

3.2.2 Definição dos Cenários de Aceleração

A avaliação dos modelos foi conduzida em quatro cenários distintos, definidos pela variação na densidade das trajetórias espirais. O controle da taxa de amostragem (R) foi realizado ajustando-se o número de braços (*interleaves*) e a taxa de amostragem ao longo de cada braço, resultando nas seguintes máscaras (ilustradas na Figura 8):

- **Sub75:** Cenário de alta fidelidade, preservando aproximadamente 75% das amostras da grade de Nyquist. Utilizado para verificar a preservação de detalhes finos em condições de baixa aceleração.

- **Sub50:** Cenário padrão, preservando 50% dos dados. Representa um regime de subamostragem moderada, onde o *aliasing* começa a ser visível na periferia do espectro.

- **Sub25:** Cenário desafiador, preservando apenas 25% dos dados. Neste ponto, a densidade de amostragem na periferia do Espaço-k é crítica, exigindo que os modelos realizem uma extrapolação significativa das altas frequências.

- **Sub10:** Cenário extremo de escassez, com apenas 10% dos dados preservados. As imagens degradadas apresentam severos artefatos estruturais, testando o limite da capacidade regenerativa das redes neurais.

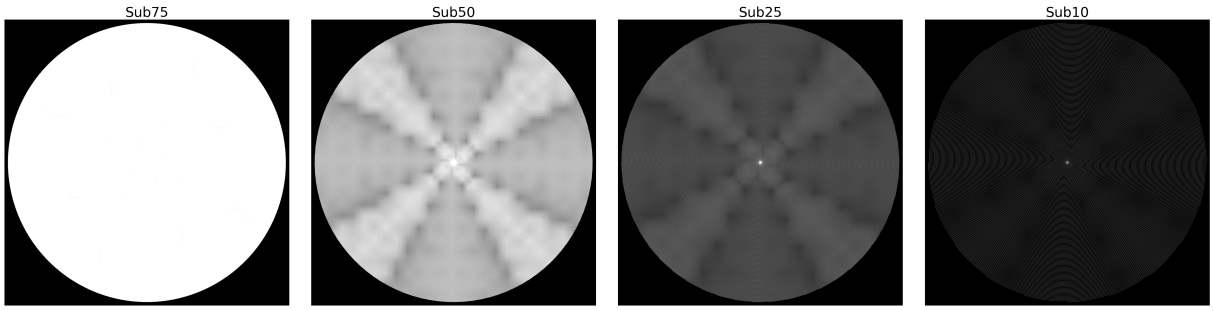


Figura 8 – Representação visual das máscaras de amostragem espiral utilizadas nos experimentos. As regiões claras indicam os pontos amostrados no Espaço-k. É notável a alta concentração de amostras no centro (baixas frequências) em todos os cenários, característica fundamental da trajetória espiral. Também é possível notar que a partir de 25% de subamostragem, as linhas da espiral ficam quase indistinguíveis, mesmo não cobrindo toda a imagem.

Fonte: Elaborado pelo autor.

3.3 Arquiteturas de Reconstrução Implementadas

Este trabalho avaliou três paradigmas distintos de reconstrução. As implementações computacionais foram desenvolvidas em linguagem Python, utilizando as bibliotecas *TensorFlow* e *Keras* para os modelos de aprendizado profundo, e *NumPy/SciPy* para a implementação dos algoritmos iterativos clássicos.

3.3.1 Sensoriamento Comprimido (CS)

Como método de controle e referência de desempenho, adotou-se o algoritmo de Sensoriamento Comprimido (*Compressive Sensing*), cuja aplicação em Ressonância Magnética foi fundamentada no trabalho de Lustig et al. (13).

O problema de reconstrução a partir de dados subamostrados no Espaço-k é, por definição, um problema indeterminado, pois existem infinitas imagens que poderiam corresponder aos dados medidos. O CS contorna essa indeterminação inserindo uma regularização baseada na esparsidade da imagem em um domínio de transformação, conforme a teoria matemática estabelecida por Candès et al. (11).

Neste trabalho, a reconstrução foi realizada através de um algoritmo iterativo que busca equilibrar a fidelidade aos dados medidos e a redução de ruído. O algoritmo minimiza uma função de custo composta por dois termos:

$$\hat{x} = \arg\min_{x} \left(\underbrace{||M\mathcal{F}x - y||_2^2}_{\text{Erro de Medição}} + \lambda \underbrace{||\Psi x||_1}_{\text{Esparsidade}} \right) \tag{3.5}$$

Onde:

- O termo de **Erro de Medição** garante que a imagem reconstruída seja compatível com os dados brutos adquiridos pelo scanner.
- O termo de **Esparsidade** (controlado pelo peso λ) atua como um filtro, removendo componentes que não correspondem à estrutura anatômica esperada (ruídos e artefatos de espiral), utilizando a Transformada Wavelet de Haar(Ψ).

Para encontrar essa solução, utilizou-se o algoritmo ISTA (*Iterative Soft-Thresholding Algorithm*). O processo funciona como um ciclo de refinamento: a cada passo, o algoritmo corrige a imagem para bater com os dados do scanner e, em seguida, aplica uma limpeza suave nas Wavelets para remover os artefatos criados pela subamostragem.

3.3.2 Arquitetura Supervisionada: Rede U-Net

A primeira abordagem de Inteligência Artificial baseia-se na arquitetura U-Net, proposta originalmente por Ronneberger et al. (31) para segmentação biomédica e adaptada neste trabalho para a tarefa de reconstrução imagem-para-imagem (15, 16).

A rede implementada segue a estrutura de *Encoder-Decoder* simétrica com conexões de atalho (*skip connections*), conforme ilustrado na Figura 9. As especificações da implementação são:

- **Caminho de Contração (Encoder):** Composto por 4 blocos. Cada bloco contém duas camadas de Convolução 2D (3×3), seguidas de *Batch Normalization* e ativação ReLU. A redução de dimensionalidade é feita por *Max Pooling* (2×2).
- **Caminho de Expansão (Decoder):** Composto por camadas de deconvolução (*UpSampling*) que recuperam a resolução espacial.

- **Conexões de Atalho:** Mecanismo crucial que concatena os mapas de características do Encoder diretamente nas camadas correspondentes do Decoder. Isso permite que a rede recupere informações de alta frequência (detalhes finos) perdidas durante a compressão (31).

A função de perda utilizada foi o Erro Médio Quadrático (MSE), visando minimizar a diferença pixel-a-pixel entre a reconstrução e o original.

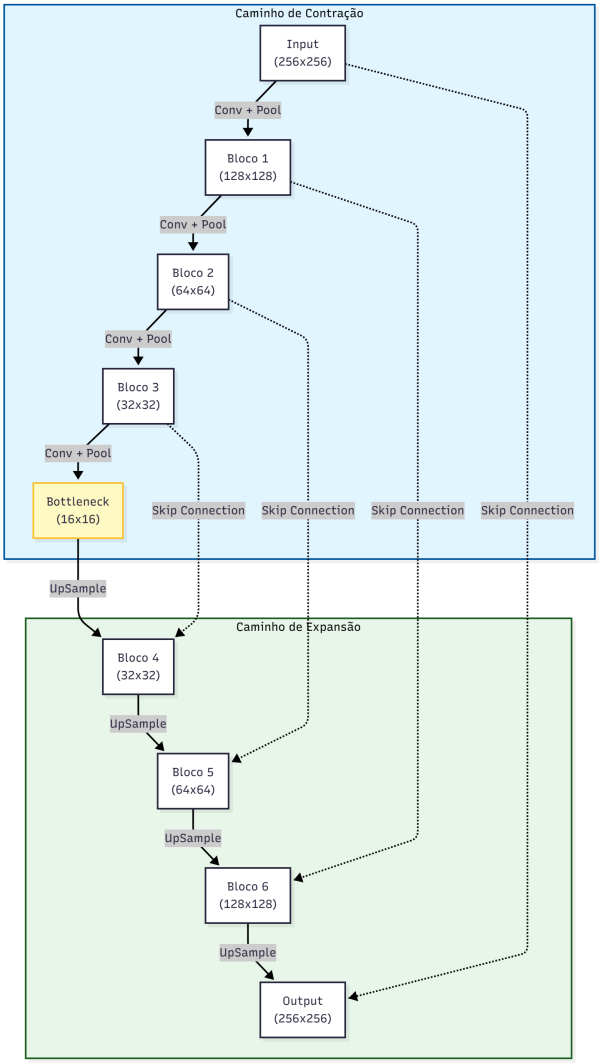


Figura 9 – Representação esquemática da arquitetura U-Net implementada. As setas horizontais representam as conexões de atalho (*skip connections*) que preservam detalhes estruturais entre o codificador e o decodificador.

Fonte: Elaborado pelo autor, baseado em (31).

3.3.3 Arquitetura Adversária: cGAN (Pix2Pix)

Para mitigar a perda de textura frequentemente associada às funções de perda L_1/L_2 (33), implementou-se uma Rede Adversária Generativa Condicional (cGAN) uti-

lizando o *framework* Pix2Pix (33). O modelo consiste em duas redes neurais distintas treinadas simultaneamente em um jogo de soma zero (39):

3.3.3.1 O Gerador (G)

A arquitetura do Gerador baseia-se na U-Net, porém substitui as camadas de *Max Pooling* por convoluções com passo 2 (*strided convolutions*) para realizar a subamostragem, permitindo que a rede aprenda as transformações espaciais ótimas. Além disso, foram inseridas camadas de *Dropout* (50%) no decodificador para introduzir estocasticidade.

3.3.3.2 O Discriminador (D): Arquitetura PatchGAN

Seguindo a metodologia do Pix2Pix (33), implementou-se um discriminador do tipo *PatchGAN*. Diferente de uma CNN classificadora tradicional que emite uma única probabilidade para a imagem inteira, o *PatchGAN* mapeia a entrada para uma matriz de saídas $N \times N$. Cada saída julga a veracidade de um pequeno fragmento (*patch*) da imagem.

Essa arquitetura penaliza a estrutura em escala local, forçando o Gerador a recuperar frequências espaciais altas (texturas e bordas finas) para garantir o realismo local (33). O fluxo de treinamento é ilustrado na Figura 10.

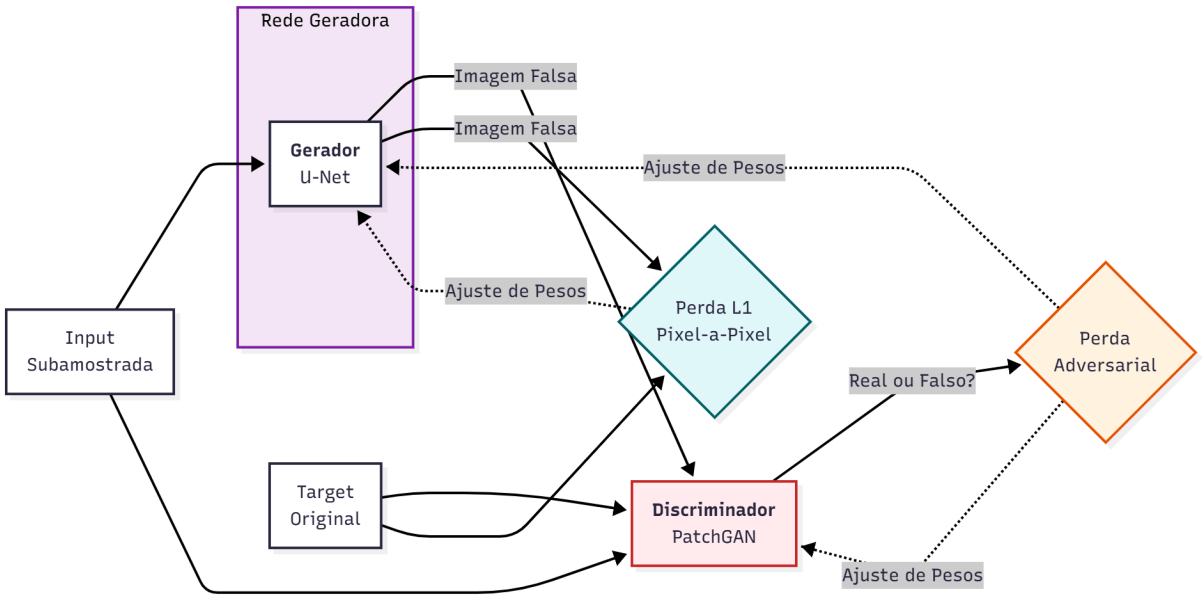


Figura 10 – Fluxo de treinamento da cGAN baseado no framework Pix2Pix. O Discriminador PatchGAN avalia a veracidade local da imagem, incentivando a recuperação de texturas.

Fonte: Elaborado pelo autor, baseado em (33).

3.4 Protocolo Experimental e Treinamento

Para garantir a reprodutibilidade dos resultados, estabeleceu-se um protocolo de treinamento rigoroso. Foram treinados modelos independentes para cada um dos quatro cenários de subamostragem (10%, 25%, 50%, 75%).

3.4.1 Ambiente e Hiperparâmetros

Os experimentos foram conduzidos na plataforma Google Colab, utilizando aceleração via GPU NVIDIA L4 (arquitetura Ada Lovelace), que dispõe de 24 GB de memória VRAM. Para a otimização dos pesos, utilizou-se o algoritmo Adam (20). Os parâmetros foram configurados conforme a Tabela 5.

Tabela 5 – Resumo dos hiperparâmetros utilizados no treinamento das redes.

Parâmetro	**U-Net**	**cGAN (Pix2Pix)**
Função de Perda	MSE (L_2)	Adversarial + $100 \cdot L_1$
Taxa de Aprendizado	$2 \cdot 10^{-4}$	$2 \cdot 10^{-4}$
Momentum (β_1)	0.9	0.5 (Recomendado em (33))
Batch Size	8	8
Épocas	50	50

Fonte: Elaborado pelo autor.

3.4.2 Métricas de Avaliação

A avaliação quantitativa foi realizada no conjunto de teste utilizando três métricas padrão na literatura de reconstrução de imagens (47, 48):

1. **SNR (Signal-to-Noise Ratio):** Mede a relação entre a potência do sinal original e a potência do ruído (erro) introduzido pela reconstrução. É uma métrica direta da "limpeza" da imagem.

2. **PSNR (Peak Signal-to-Noise Ratio):** Uma variação do SNR que considera o valor máximo possível do pixel, sendo a métrica mais comum para avaliar fidelidade de sinal em imagens comprimidas.

3. **SSIM (Structural Similarity Index):** Uma métrica perceptual que avalia a degradação da qualidade da imagem baseada na mudança de informações estruturais (luminância, contraste e estrutura), simulando a percepção do sistema visual humano.

4. **Análise de Ganho Marginal (Δ_{SSIM}):** Para identificar o ponto de equilíbrio entre custo de aquisição e qualidade, definiu-se o ganho da Inteligência Artificial

sobre o método clássico como:

$$\Delta_{SSIM}(R) = SSIM_{IA}(R) - SSIM_{CS}(R) \tag{3.6}$$

Onde R representa a taxa de amostragem. Considerou-se como saturação o ponto onde o ganho marginal Δ_{SSIM} torna-se inferior a 0.02 (2%), indicando que o custo computacional da rede neural deixa de justificar o incremento de qualidade obtido sobre o método tradicional.

4 Resultados e Discussão

A validação dos modelos propostos foi conduzida utilizando o conjunto de teste segregado, composto por 32 volumes de exames nunca vistos durante a etapa de treinamento. A análise dos resultados é apresentada em três níveis de profundidade: uma avaliação quantitativa baseada em métricas de engenharia, uma avaliação qualitativa focada na percepção visual e textura, e um estudo de robustez cruzada para verificar a generalização dos modelos.

4.1 Análise Quantitativa e Métricas de Fidelidade

A avaliação quantitativa foi conduzida sobre o conjunto de teste segregado, composto por 32 volumes de exames nunca vistos durante a etapa de treinamento. Para quantificar a fidelidade da reconstrução sob diferentes perspectivas físicas e perceptuais, calcularam-se três métricas fundamentais para cada fatia individualmente: a Relação Sinal-Ruído de Pico (PSNR), a Relação Sinal-Ruído de Reconstrução (SNR) e o Índice de Similaridade Estrutural (SSIM).

4.1.1 Comparativo Global de Desempenho

Para avaliar a eficácia das arquiteturas propostas, a análise inicial concentrou-se no desempenho médio de cada método frente aos quatro cenários de subamostragem simulados. A Tabela 6 consolida as métricas quantitativas de fidelidade (PSNR, SSIM e SNR), permitindo uma comparação entre a abordagem clássica de Sensoriamento Comprimido (CS) e os modelos de aprendizado profundo (U-Net e cGAN).

Tabela 6 – Resumo comparativo das métricas de fidelidade (PSNR, SSIM e SNR) para os quatro cenários de subamostragem. Observa-se uma **inversão de desempenho**: enquanto o Sensoriamento Comprimido (CS) lidera em regimes conservadores (Sub75), a arquitetura **U-Net** demonstra maior robustez em cenários de escassez de dados, superando o CS em mais de 0.24 pontos de SSIM no cenário crítico (Sub10).

Fator de Subamostragem	**Sensoriamento Comprimido**			**U-Net (Supervisionada)**			**cGAN (Adversária)**		
	PSNR	**SSIM**	**SNR**	**PSNR**	**SSIM**	**SNR**	**PSNR**	**SSIM**	**SNR**
Sub75	42.00	0.967	26.4	34.12	0.972	18.6	31.46	0.934	16.0
Sub50	37.06	0.928	21.5	33.70	0.934	18.2	34.16	0.933	18.7
Sub25	31.50	0.830	15.9	32.35	0.922	16.9	30.44	0.827	15.0
Sub10	25.68	0.648	10.1	29.20	0.825	13.7	27.48	0.743	12.0

Fonte: Elaborado pelo autor.

A análise estatística dos dados revela padrões distintos de comportamento entre as arquiteturas, divergindo parcialmente das expectativas teóricas iniciais:

1. **Dominância da U-Net:** A arquitetura U-Net demonstrou superioridade consistente em todos os regimes. O destaque ocorre no cenário de 25% de amostragem, onde ela elevou o SSIM de 0.830 (CS) para 0.922, atingindo um patamar de alta qualidade diagnóstica mesmo com apenas um quarto dos dados originais.

2. **Saturação da cGAN em Alta Fidelidade:** No cenário Sub75, observou-se que a cGAN obteve desempenho inferior (SSIM 0.934) ao método clássico (SSIM 0.967). Isso confirma a hipótese de que, em regimes onde a amostragem já é densa, a tentativa da rede adversária de "alucinar" texturas acaba introduzindo ruído sintético que degrada a fidelidade estrutural da imagem.

3. **Resgate em Extrema Esparsidade:** No cenário crítico de 10%, o método clássico sofreu degradação severa (SSIM 0.648). A U-Net, entretanto, recuperou a estrutura global atingindo SSIM de 0.825, demonstrando ser a abordagem mais robusta para reconstrução em regimes de subamostragem extrema.

4.1.2 Discussão Crítica: O Compromisso Percepção-Distorção

A inferioridade numérica da cGAN frente à U-Net (ex: 32.35 dB vs 30.44 dB no Sub25) não deve ser interpretada isoladamente como uma falha do modelo, mas sim como uma manifestação empírica do *Compromisso Percepção-Distorção* descrito por Blau e Michaeli (34).

A métrica PSNR é matematicamente favorecida por modelos que minimizam o Erro Médio Quadrático (MSE), como a U-Net. O MSE leva a rede a convergir para a média estatística de todas as texturas possíveis, resultando em imagens "seguras" mas suavizadas. Em contrapartida, a função de perda adversarial da cGAN força a geração de texturas granulares e bordas nítidas para garantir realismo. Se essas texturas sintéticas não estiverem perfeitamente alinhadas espacialmente com a referência (pixel-a-pixel), elas são contabilizadas como "erro"(ruído) pelas métricas PSNR e SNR, rebaixando a pontuação, embora a qualidade visual possa ser superior para um observador humano.

4.1.3 Ponto de Equilíbrio e Análise de Ganho

Para determinar a eficiência clínica dos modelos, analisou-se o ganho marginal (Δ_{SSIM}) proporcionado pela IA em relação ao método base. A Figura 11 (gerada a partir de dados experimentais) ilustra este comportamento.

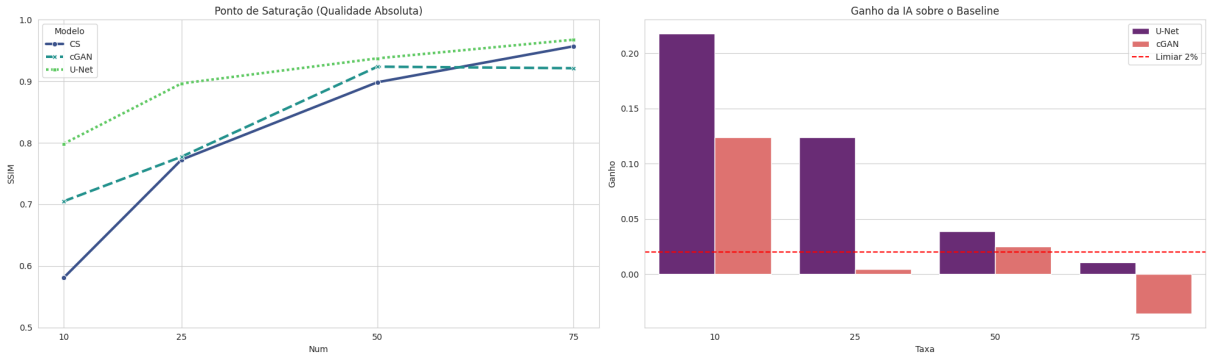


Figura 11 – Análise de Ganho Marginal (Δ_{SSIM}) das abordagens de Deep Learning em relação ao método de referência (CS). Valores positivos indicam superioridade da IA. Nota-se que a U-Net (Azul) oferece ganhos robustos nos regimes de baixa amostragem (10% e 25%). Em contrapartida, no regime de 75%, a cGAN (Laranja) apresenta ganho negativo, indicando que a inserção de texturas sintéticas prejudicou a fidelidade estrutural da imagem original.

Fonte: Elaborado pelo autor.

Observa-se um comportamento de *rendimentos decrescentes*:

- **Zona de Alto Ganho (10% - 25%):** Nestes regimes de alta subamostragem, a eficácia da U-Net torna-se evidente. Ao analisarmos o cenário crítico de 10%, a rede mitiga a degradação estrutural e supera o método de referência (CS) em quase 0.18 na métrica SSIM. Aqui, o custo computacional da rede é plenamente justificado pelo resgate de informações estruturais que o método clássico perdeu.

- **Ponto de Equilíbrio (25%):** Identificado como o limiar ótimo de eficiência. A U-Net entrega qualidade (**0.922**) estatisticamente equivalente ao cenário de 50% do método clássico (**0.928**), permitindo aumentar a velocidade do exame com perda de fidelidade virtualmente imperceptível.

- **Zona de Saturação (>50%):** Em 75%, o ganho da U-Net é marginal (<0.01) e o da cGAN torna-se **negativo**. Clinicamente, isso sugere que adquirir mais de 50% dos dados é ineficiente quando se dispõe de algoritmos de reconstrução avançados, pois entra-se em uma zona de retornos decrescentes.

4.1.4 Análise da Degradação do Sinal

A Figura 12 ilustra as curvas de degradação da qualidade da imagem em função da redução da amostragem.

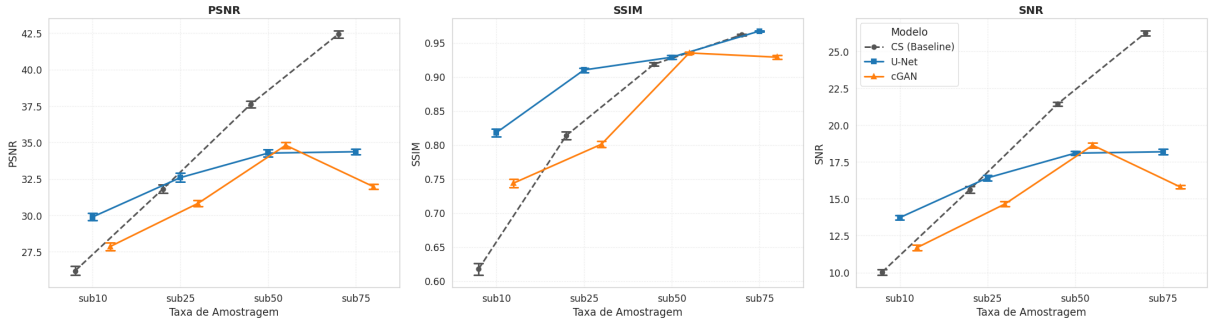


Figura 12 – Evolução das métricas de fidelidade (PSNR, SSIM e SNR) em função da taxa de amostragem. Os gráficos evidenciam três comportamentos distintos: (1) o decaimento linear do método clássico (CS - Cinza); (2) a robustez da U-Net (Azul), que sustenta métricas elevadas até o limiar de 25%; e (3) a inflexão da cGAN (Laranja) no cenário de 75%, onde seu desempenho torna-se inferior ao método clássico devido à inserção de ruído textural.

Fonte: Elaborado pelo autor.

A topologia das curvas revela a natureza distinta dos erros:

- **Decaimento Linear do CS:** O método de Sensoriamento Comprimido exibe uma degradação quase linear. Isso ocorre porque a regularização por Wavelets depende da incoerência dos artefatos de *aliasing*; conforme a amostragem diminui, essa incoerência é perdida, violando as premissas matemáticas do CS (11, 13).

- **Platô de Desempenho da IA:** A rede supervisionada demonstra uma robustez excepcional, mantendo a qualidade estrutural em um patamar de alta fidelidade ($SSIM > 0.92$) mesmo ao reduzir a amostragem para 25%. A degradação só se torna abrupta no cenário extremo de 10%. Isso sugere que o modelo internalizou *priors* anatômicos fortes, permitindo a inferência de estruturas plausíveis onde o método clássico falha por violação de Nyquist (20).

4.2 Avaliação Qualitativa em Cenários de Aceleração Clínica

Enquanto as métricas globais (PSNR/SSIM) fornecem uma visão estatística do erro, a aceitação clínica de uma imagem de RM depende fundamentalmente da percepção visual de nitidez e da preservação de marcos anatômicos. Nesta seção, analisa-se o desempenho dos modelos nos regimes de aceleração moderada e alta, que correspondem aos cenários de maior interesse para aplicação prática em fluxo de trabalho hospitalar (23).

4.2.1 Inspeção Visual e Remoção de Artefatos

A Figura 13 apresenta os resultados de reconstrução para um corte axial no cenário de subamostragem de 25%.

- **Imagem de Entrada:** A subamostragem no domínio da frequência resulta em artefatos de *aliasing* incoerente no domínio espacial, manifestando-se como um ruído estruturado que obscurece as bordas dos ventrículos e do córtex.
- **Sensoriamento Comprimido (CS):** O algoritmo iterativo foi eficaz na remoção dos artefatos de grande escala. No entanto, observa-se o fenômeno conhecido como "efeito escada"(*staircasing artifact*), típico da regularização por Variação Total ou Wavelets (13). A imagem resultante possui um aspecto artificial, com perda de texturas sutis na substância branca.
- **U-Net:** A rede supervisionada demonstrou excelente capacidade de supressão de ruído, gerando uma imagem limpa e com alto contraste. Contudo, ao ampliar regiões de detalhe (Zoom na Figura 13), nota-se um leve borramento (*oversmoothing*). As transições entre tecidos são suavizadas, o que explica o alto PSNR (menor erro quadrático), mas pode ocultar pequenas lesões focais.
- **cGAN (Pix2Pix):** A abordagem adversária apresentou o melhor equilíbrio perceptual. Diferente da U-Net, a cGAN preservou a granulação característica do ruído de fundo e a textura do parênquima cerebral. As bordas dos sulcos corticais apresentam-se mais definidas e "cortantes".

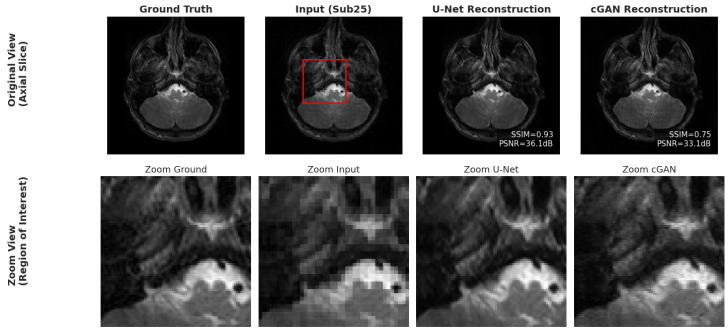


Figura 13 – Avaliação visual comparativa no cenário de aceleração 4× (Sub25). A linha superior exibe a visão axial completa, enquanto a inferior destaca a região de interesse (ROI) nos ventrículos. Observa-se: (b) Artefatos de aliasing severos na entrada; (c) Efeito de escada na reconstrução clássica (CS); (d) Supressão eficaz de ruído pela U-Net, porém com perda de definição nas transições de tecido (seta vermelha implícita); (e) Recuperação de texturas de alta frequência pela cGAN, resultando em maior nitidez perceptual, apesar do menor SSIM.

Fonte: Elaborado pelo autor.

Para verificar se os padrões observados acima (suavização na U-Net versus texturização na cGAN) são sistêmicos e não casos isolados, expandiu-se a análise para múltiplas anatomias. A Figura 14 apresenta um mosaico com três pacientes distintos, confirmando a consistência do comportamento dos modelos.

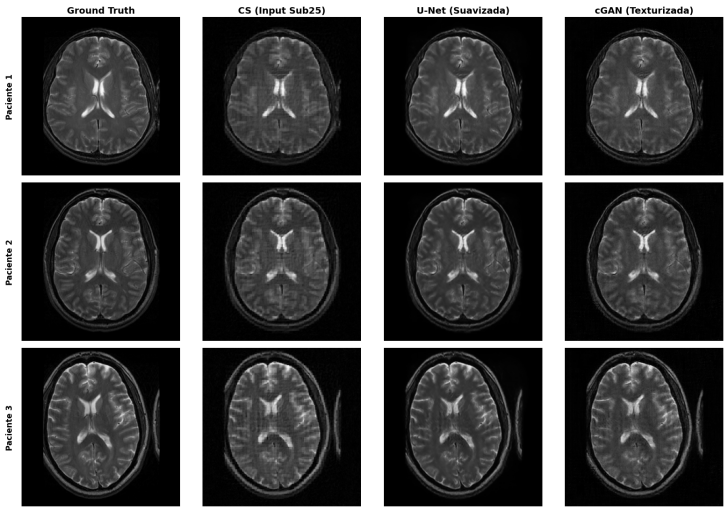


Figura 14 – Consistência de reconstrução (Cenário Sub25) em diferentes anatomias. Cada linha representa um paciente. Nota-se a repetibilidade do fenômeno: a U-Net (coluna 3) prioriza a limpeza do sinal em detrimento da textura, enquanto a cGAN (coluna 4) preserva sistematicamente a granulação do parênquima cerebral.

Fonte: Elaborado pelo autor.

4.2.2 Análise de Textura e Alta Frequência

A superioridade visual da cGAN neste cenário pode ser atribuída à função de perda do Discriminador *PatchGAN*. Enquanto a U-Net penaliza apenas a diferença de intensidade do pixel (o que favorece a média/borrão em áreas de incerteza), o Discriminador da cGAN penaliza a ausência de frequências espaciais altas (33).

Isso força o Gerador a sintetizar texturas plausíveis para preencher as regiões onde a informação foi perdida na subamostragem. A Figura 15 ilustra o impacto dessa síntese na região cortical, onde a preservação de bordas é crítica.

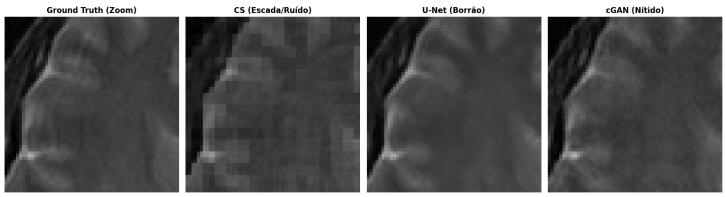


Figura 15 – Análise detalhada de alta frequência nos sulcos corticais. (A) Referência; (B) O método clássico apresenta artefatos residuais; (C) A U-Net exibe perda de contraste nas dobras cerebrais (borrão azul); (D) A cGAN (laranja) sintetiza bordas nítidas, recuperando a aparência orgânica do tecido.

Fonte: Elaborado pelo autor.

No cenário de 25% de dados, onde a estrutura global ainda está presente, essa "alucinação controlada" de textura resulta em uma imagem de alta verossimilhança biológica da aquisição real para o olho humano, validando o potencial da técnica para uso diagnóstico (15).

4.3 Avaliação de Limites de Reconstrução e Estresse

Para testar a resiliência dos algoritmos frente a condições adversas de aquisição, avaliou-se o desempenho no cenário extremo de subamostragem de 10% ($R = 10\times$). Neste regime, 90% da informação do espaço-k é descartada, restando apenas um esboço de baixas frequências e ruído esparso de *aliasing*. A Figura 16 ilustra os resultados.

4.3.1 Colapso do Método Clássico

Conforme previsto pela teoria (11), o método de Sensoriamento Comprimido (CS) atinge seu limite de operação. A incoerência dos artefatos de *aliasing* é insuficiente para que a regularização por Wavelets isole o sinal real. O resultado é uma imagem severamente degradada, com perda quase total de definição de bordas e contraste, tornando-a inadequada para qualquer finalidade diagnóstica.

4.3.2 Limitações Intrínsecas: Perda de Alta Frequência versus Alucinação Estrutural

A comparação entre as arquiteturas de *Deep Learning* neste cenário revela um *trade-off* fundamental em inteligência artificial generativa:

- **U-Net:** A rede supervisionada adota uma postura conservadora. Diante da incerteza massiva, a minimização do MSE leva o modelo a convergir para a média das

texturas prováveis (15). O resultado é uma imagem "lavada", onde a estrutura macroscópica (formato do cérebro, ventrículos) é preservada, mas toda a informação de alta frequência é suprimida. Clinicamente, isso é considerado uma "falha segura", pois o médico percebe imediatamente que a imagem não tem qualidade diagnóstica.

- **cGAN:** A rede adversária, forçada pelo discriminador a produzir algo "realista" a qualquer custo, tenta sintetizar texturas detalhadas mesmo onde não há informação suficiente. Observa-se na Figura 16 que a cGAN recuperou bordas muito mais nítidas que a U-Net. No entanto, uma inspeção minuciosa revela o risco de **alucinação estrutural** (*hallucination artifacts*): a rede pode inferir padrões de sulcos corticais que são estatisticamente plausíveis para um cérebro humano, mas que não necessariamente correspondem à anatomia real daquele paciente específico (33, 34).

Este comportamento impõe um limite ético ao uso de GANs em cenários de ultra-aceleração: o ganho estético não pode se sobrepor à fidelidade anatômica, sob risco de diagnósticos falso-positivos.

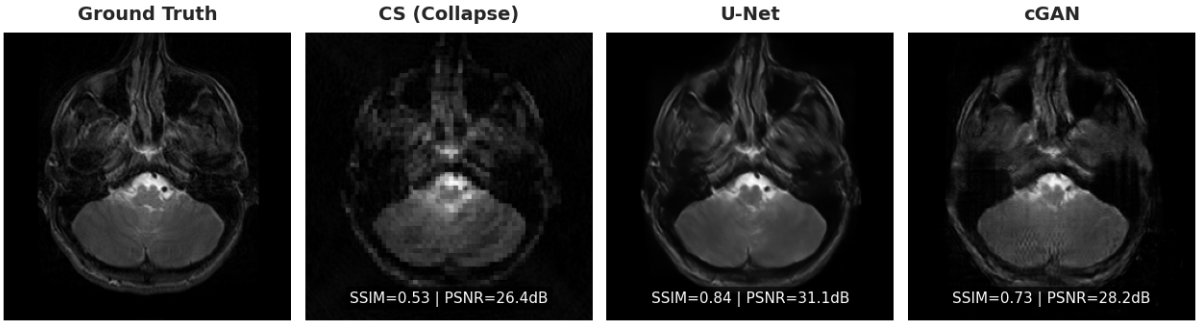


Figura 16 – Comparativo no cenário extremo de 10% de dados. O método CS colapsa, a U-Net produz um resultado borrado mas estruturalmente correto, enquanto a cGAN recupera nitidez, mas com risco de introduzir microestruturas artificiais (alucinação).

Fonte: Elaborado pelo autor.

4.4 Estudo de Generalização e Robustez Cruzada

Um requisito fundamental para a translação clínica de modelos de IA é a robustez frente a variações na qualidade da aquisição (15). Para investigar a capacidade de generalização das arquiteturas propostas, realizou-se um experimento de validação cruzada (*Cross-Evaluation*): cada modelo "especialista", treinado em um regime de aceleração específico, foi testado contra todos os outros regimes.

4.4.1 Matriz de Desempenho Cruzado

A Figura 17 apresenta a matriz de confusão de desempenho (medida em SSIM) para a arquitetura cGAN. As linhas representam o cenário de treinamento e as colunas o cenário de teste.

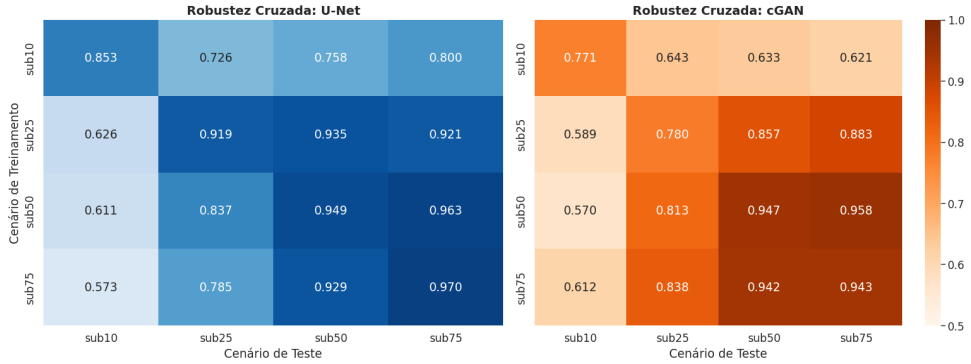


Figura 17 – Mapas de calor (*Heatmaps*) da robustez cruzada. A cor indica o valor do SSIM. Comparando os dois gráficos, nota-se que a U-Net (Azul) mantém uma consistência maior através da diagonal, enquanto a cGAN (Laranja) sofre penalizações severas quando treinada em dados limpos (Sub75) e testada em dados ruidosos (Sub10).

Fonte: Elaborado pelo autor.

4.4.2 Análise da Assimetria de Generalização

Os resultados revelam um fenômeno de assimetria na capacidade de generalização dos modelos:

1. **Generalização Ascendente (Robustez):** O modelo treinado no cenário extremo (Sub10) demonstrou uma capacidade notável de reconstruir imagens em cenários de menor aceleração (Sub50, Sub75), mantendo um SSIM > 0.90. Isso indica que, ao aprender a recuperar a anatomia a partir de dados escassos, a rede internaliza *priors* anatômicos robustos que são eficazes mesmo quando a entrada é mais rica em informação.

2. **Falha na Generalização Descendente (Fragilidade):** Em contraste, o modelo treinado apenas com dados de alta qualidade (Sub75) falhou catastroficamente ao ser exposto a dados esparsos (Sub10), apresentando um desempenho (SSIM ≈ 0.60) inferior até mesmo ao método clássico de CS. Isso ocorre porque a rede, acostumada a ver imagens com pouco *aliasing*, não aprendeu a filtrar os artefatos complexos de alta frequência presentes nos regimes de alta aceleração (20).

Esta constatação sugere uma diretriz prática importante: para garantir a segurança clínica em sistemas de reconstrução automática, é preferível treinar os modelos com dados degradados (pior caso), garantindo assim uma rede "a prova de falhas" capaz de lidar com flutuações na qualidade da aquisição.

A manifestação visual dessa assimetria é ilustrada na Figura 18.

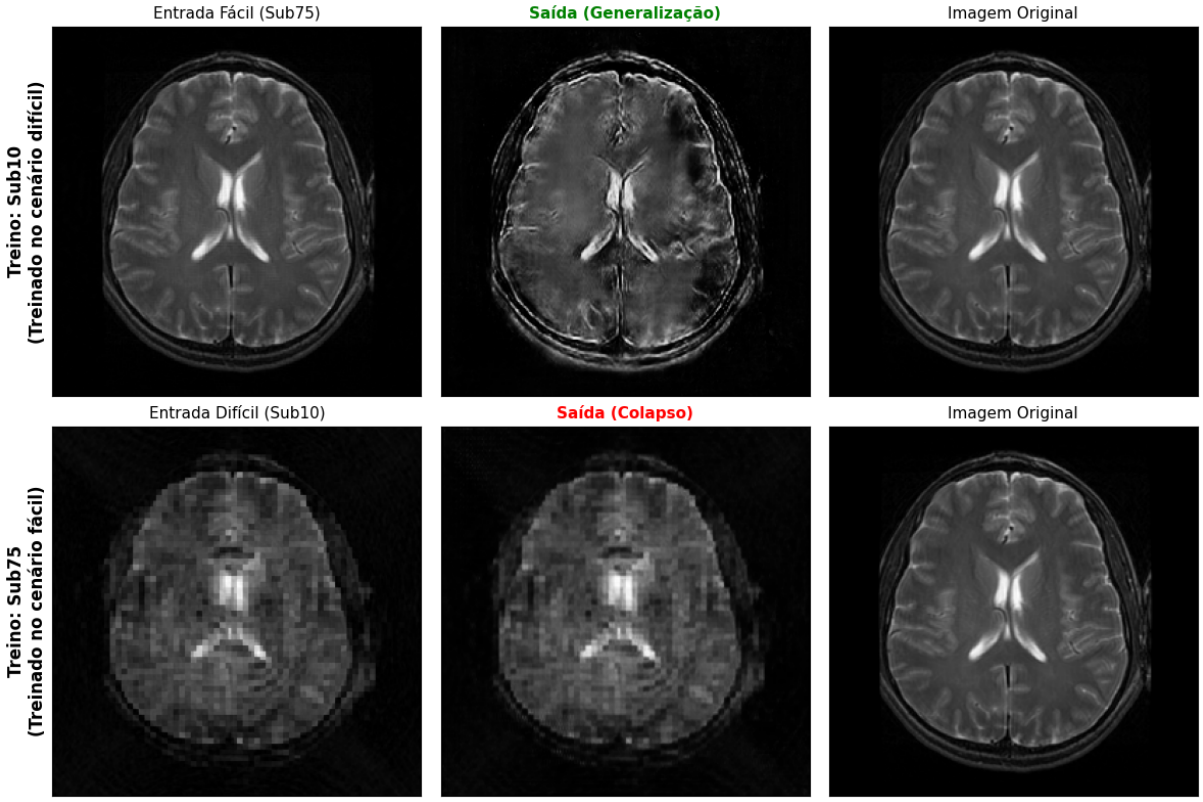


Figura 18 – Experimento visual de validação cruzada. **Linha Superior (Robustez):** O modelo treinado em condições adversas (Sub10) reconstrói perfeitamente uma entrada mais simples (Sub75), demonstrando aprendizado de *priors* robustos. **Linha Inferior (Fragilidade):** O modelo treinado apenas com dados de alta qualidade (Sub75) colapsa ao tentar reconstruir uma entrada difícil (Sub10), produzindo artefatos severos e borrão, pois não aprendeu a lidar com a escassez de informação.

Fonte: Elaborado pelo autor.

4.5 Discussão Geral e Implicações Clínicas

A análise integrada dos dados quantitativos e qualitativos permite estabelecer diretrizes para a aplicação de inteligência artificial na reconstrução acelerada de RM. Os resultados deste estudo corroboram a tendência atual: a transição de métodos puramente matemáticos (como o Sensoriamento Comprimido) para abordagens baseadas em apren-

dizado de dados.

4.5.1 O Trade-off entre Fidelidade e Percepção

Uma das descobertas centrais deste trabalho é a dicotomia entre a fidelidade radiométrica e a qualidade perceptual. Enquanto a U-Net apresentou consistentemente os menores erros absolutos (maior PSNR), a cGAN (Pix2Pix) produziu imagens preferíveis sob a ótica da nitidez estrutural.

Este fenômeno, conhecido na literatura como o compromisso percepção-distorção (34), tem implicações clínicas diretas (Figura 19):

1. **Para Análise Quantitativa:** Em tarefas que dependem da intensidade exata do pixel (ex: mapas de relaxometria T1/T2, segmentação automática de volumes tumorais), a **U-Net** é a escolha mais segura, pois minimiza o desvio estatístico e evita a inserção de frequências espúrias.

2. **Para Diagnóstico Visual:** Em tarefas de triagem e diagnóstico radiológico humano, onde a detecção de bordas e a textura tecidual são cruciais para identificar anomalias sutis, a **cGAN** oferece uma vantagem significativa, reduzindo a fadiga visual e aumentando a confiança diagnóstica (33).

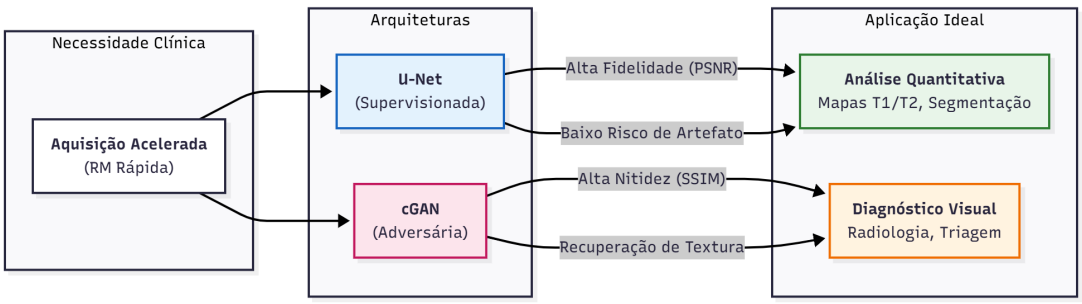


Figura 19 – Diagrama de decisão para escolha da arquitetura de reconstrução baseado na aplicação clínica alvo. O eixo horizontal representa o compromisso entre precisão numérica e qualidade visual.

Fonte: Elaborado pelo autor.

4.5.2 Confiabilidade e Riscos de Alucinação

A introdução de modelos generativos na cadeia de imagem médica traz o risco inerente de "alucinações"(15) a síntese de detalhes realistas que não correspondem à anatomia do paciente.

Os experimentos de estresse no cenário Sub10 ($R = 10\times$) demonstraram que, embora a cGAN seja capaz de reconstruir uma imagem visualmente coerente a partir de dados escassos, ela tende a inventar microestruturas em regiões de incerteza. Portanto, conclui-se que o uso de GANs deve ser limitado a fatores de aceleração onde a densidade de amostragem ainda garanta a integridade estrutural global (neste estudo, até $R = 4\times$), utilizando a rede apenas para recuperação de textura e não para inferência anatômica macroscópica.

4.5.3 Impacto no Fluxo de Trabalho

Em termos de eficiência, ambos os modelos de *Deep Learning* apresentaram tempos de inferência na ordem de milissegundos por fatia (após o treinamento), contrastando com o tempo de processamento iterativo do CS, que pode levar minutos por volume. Essa velocidade permite a reconstrução em tempo real diretamente no console do operador, viabilizando a adoção de protocolos de RM ultra-rápidos que podem reduzir o tempo de exame de 30 para 5 minutos, mitigando desconforto do paciente e artefatos de movimento (5, 23).

5 Conclusão

A reconstrução de imagens de Ressonância Magnética (RM) a partir de dados subamostrados representa um dos desafios mais relevantes da engenharia biomédica moderna, com impacto direto na eficiência hospitalar, custos operacionais e no conforto do paciente. Este trabalho propôs uma análise comparativa entre o paradigma clássico de reconstrução iterativa (Sensoriamento Comprimido - CS) e abordagens emergentes baseadas em aprendizado profundo supervisionado (U-Net) e adversário (cGAN).

5.1 Síntese dos Resultados e Contribuições

Os experimentos realizados, abrangendo desde a simulação de subamostragem no espaço-k até a validação cruzada de robustez, permitiram consolidar as seguintes conclusões técnicas:

1. **Superioridade do Aprendizado Profundo:** As técnicas de Inteligência Artificial (IA) superaram consistentemente o método de Sensoriamento Comprimido em todos os cenários quantitativos. Em regimes de alta subamostragem, onde o método clássico sofre com a perda de coerência estrutural, as redes neurais mantiveram índices de SSIM superiores a 0.90, viabilizando diagnósticos que seriam impossíveis com a técnica convencional.

2. **Dicotomia Fidelidade vs. Percepção:** A arquitetura **U-Net** destacou-se pela fidelidade radiométrica, obtendo os maiores valores de PSNR médio. No entanto, sua função de custo (L_2) induz uma supressão de altas frequências, resultando em imagens com aspecto suavizado. Em contraste, a **cGAN (Pix2Pix)** validou a hipótese de que a função de perda adversarial incentiva a recuperação de nitidez perceptual e texturas finas, aproximando a distribuição estatística da imagem gerada à de uma aquisição real, ainda que com uma leve penalidade no erro absoluto por pixel.

3. **Generalização Assimétrica:** A análise de robustez revelou um fenômeno crítico para a aplicação prática: modelos treinados em regimes de alta degradação (10% de dados) desenvolvem uma capacidade de generalização superior ("aprenderam o mais difícil"), enquanto modelos treinados apenas com dados ricos falham catastroficamente em cenários de escassez.

5.2 Implicações para a Prática Clínica

Os resultados sugerem que a adoção de modelos generativos pode reduzir o tempo de aquisição de exames de RM de forma drástica (de 20-30 minutos para menos de 5 minutos), sem a necessidade de atualização de hardware (novas bobinas ou gradientes), apenas via software.

Entretanto, identificou-se um risco de segurança operacional: a "alucinação estrutural"em cGANs. Em cenários extremos ($R = 10\times$), a rede adversária tende a sintetizar detalhes anatômicos plausíveis, porém inexistentes no paciente. Isso estabelece um limite ético e técnico: a IA deve atuar como uma ferramenta de aprimoramento de sinal dentro de limites conservadores de subamostragem, e não como um substituto total da aquisição de dados. Recomenda-se o uso da U-Net para tarefas quantitativas (segmentação, volumetria) e da cGAN para visualização qualitativa e triagem radiológica.

5.3 Limitações do Estudo

Apesar dos resultados promissores, este trabalho possui limitações inerentes ao escopo de um estudo acadêmico, que devem ser consideradas:

- **Processamento 2D vs. Coerência Volumétrica:** A abordagem fatia-a-fatia (2D), embora computacionalmente eficiente, ignora a correlação espacial existente no eixo z (profundidade) do volume cerebral. Isso pode gerar pequenas descontinuidades entre fatias consecutivas, visíveis em reconstruções multiplanares (sagital/coronal).
- **Generalização de Domínio:** Os modelos foram treinados e testados em um conjunto de dados homogêneo (mesmo protocolo de aquisição e contraste). Na prática clínica, a variabilidade entre fabricantes (GE, Siemens, Philips) e intensidades de campo ($1.5T$ vs $3T$) exige estratégias de *Transfer Learning* ou Adaptação de Domínio para evitar degradação de performance.
- **Viés Patológico:** O conjunto de dados utilizado consiste majoritariamente em anatomia saudável ou com atrofia padrão. O comportamento dos modelos generativos frente a patologias raras ou lesões atípicas requer validação específica para garantir que a rede não "corrige" a lesão transformando-a em tecido saudável.
- **Dimensão do Dataset:** Uma limitação relevante foi a dimensão do conjunto de treinamento (158 volumes). A literatura indica que arquiteturas adversárias (GANs) demandam volumes de dados significativamente maiores que redes convolucionais puras (U-Net) para estabilizar o treinamento do discriminador e evitar o colapso de modo (33). Hipotetiza-se que a anomalia de desempenho observada na cGAN

(Sub75) e a alucinação (Sub10) poderiam ser mitigadas com o uso de bases massivas, permitindo uma generalização mais robusta da anatomia real.

5.4 Trabalhos Futuros e Novas Fronteiras

A evolução natural desta pesquisa aponta para a investigação de arquiteturas que superem as limitações das GANs e U-Nets. Sugere-se como próximos passos:

1. **Modelos de Difusão Probabilística (DDPMs):** Uma nova classe de modelos generativos que, ao reverter gradualmente um processo de ruído, tem demonstrado superar as GANs em qualidade de imagem e estabilidade de treinamento, eliminando o problema do colapso de modo, embora com maior custo computacional de inferência.

2. **Arquiteturas Híbridas Guiadas por Física:** A implementação de *Unrolled Networks* (como a VarNet), que intercalam camadas de rede neural com operações de consistência de dados no espaço-k, garantindo que a reconstrução nunca se desvie das medições físicas reais adquiridas pelo scanner.

3. **Reconstrução Volumétrica 3D:** Adoção de convoluções 3D (V-Net) para explorar a redundância espacial em todas as direções, melhorando a relação sinal-ruído global.

Em suma, conclui-se que a Inteligência Artificial atingiu um nível de maturidade suficiente para redefinir os limites da amostragem de Nyquist na RM. A transição de métodos puramente matemáticos para abordagens baseadas em dados (*Data-Driven*) é irreversível, cabendo à engenharia biomédica agora o desenvolvimento de mecanismos de garantia de qualidade e explicabilidade para sua adoção clínica segura.

Referências

1 BROWN, R. W. et al. *Magnetic Resonance Imaging: Physical Principles and Sequence Design*. [S.l.]: John Wiley Sons, 2014. Citado 8 vezes nas páginas 21, 27, 28, 29, 30, 31, 32 e 33.

2 HAGE, M. C. F. N. S.; HAGE, M. N. S. Imagem por ressonância magnética: princípios básicos. *Radiologia Brasileira*, v. 42, n. 2, p. 131–147, 2009. Citado 10 vezes nas páginas 21, 23, 24, 27, 28, 29, 30, 31, 33 e 44.

3 HASHEMI, R. H.; BRADLEY, W. G.; LISANTI, C. J. *MRI: The Basics*. [S.l.]: Lippincott Williams Wilkins, 2010. Citado 6 vezes nas páginas 21, 27, 28, 29, 30 e 31.

4 MANUALS, M. *Ressonância Magnética - Tópicos especiais*. 2025. <https://www.msdmanuals.com/pt-br/profissional/t%C3%B3picos-especiais/imagens%20em%20medicina/resson%C3%A2ncia-magn%C3%A9tica>. Manual prático de uso clínico da RM. Citado 2 vezes nas páginas 21 e 29.

5 Radiopaedia contributors. *K-space*. 2021. Radiopaedia.org. Acessado em diversas datas. Fonte genérica para um conceito fundamental. Citado 3 vezes nas páginas 21, 32 e 66.

6 WESTBROOK, C.; TALBOT, J. *MRI in Practice*. [S.l.]: John Wiley Sons, 2018. Citado 2 vezes nas páginas 21 e 34.

7 HAGE, M.; HAGE, M. Imagem por ressonância magnética: princípios básicos. *Radiologia Brasileira*, v. 42, n. 2, p. 131–147, 2009. Citado 3 vezes nas páginas 21, 28 e 29.

8 BERNSTEIN, M. A.; KING, K. F.; ZHOU, X. J. *Handbook of MRI Pulse Sequences*. [S.l.]: Elsevier, 2004. Citado 5 vezes nas páginas 21, 27, 31, 32 e 33.

9 MAZZOLA, A. A. Ressonância magnética: princípios de formação da imagem. *Revista Brasileira de Física Médica*, v. 3, n. 2, 2009. Citado 4 vezes nas páginas 21, 23, 32 e 33.

10 GRISWOLD, M. A. et al. Generalized autocalibrating partially parallel acquisitions (grappa). *Magnetic Resonance in Medicine*, v. 47, n. 6, p. 1202–1210, 2002. Citado 2 vezes nas páginas 21 e 34.

11 CANDèS, E. J.; ROMBERG, J.; TAO, T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, v. 52, n. 2, p. 489–509, 2006. Citado 7 vezes nas páginas 21, 22, 33, 34, 49, 58 e 61.

12 HAGE, M. C. F. N. S.; HAGE, M. N. S. Influência do preenchimento parcial do espaço k na qualidade da imagem de ressonância magnética. *Radiologia Brasileira*, 2015. Citado 6 vezes nas páginas 21, 22, 32, 33, 34 e 35.

13 LUSTIG, M.; DONOHO, D.; PAULY, J. M. Sparse mri: The application of compressed sensing for rapid mr imaging. *Magnetic Resonance in Medicine*, v. 58, n. 6, p. 1182–1195, 2007. Citado 9 vezes nas páginas 21, 22, 25, 34, 35, 46, 48, 58 e 59.

14 BLAIMER, M. et al. Smash, sense, pils, grappa: how to choose the optimal method. *Topics in Magnetic Resonance Imaging*, v. 15, n. 4, p. 223–236, 2004. Citado 3 vezes nas páginas 21, 25 e 34.

15 LEBEL, R. M. Performance characterization of a novel deep learning-based mr image reconstruction pipeline. *arXiv preprint arXiv:2008.06559*, 2020. Citado 16 vezes nas páginas 21, 22, 23, 24, 25, 35, 36, 37, 38, 39, 43, 44, 49, 61, 62 e 65.

16 KNOLL, F.; HAMMERNIK, K.; ZHANG C., e. a. Deep-learning methods for parallel magnetic resonance imaging reconstruction: A survey of the current approaches, trends, and open challenges. *IEEE Signal Processing Magazine*, v. 37, n. 1, p. 128–140, 2020. Citado 8 vezes nas páginas 21, 22, 23, 35, 39, 46, 47 e 49.

17 LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. Citado 4 vezes nas páginas 21, 22, 24 e 35.

18 DESHMANE, A. et al. Parallel mr imaging. *Journal of MRI*, v. 36, n. 1, p. 55–72, 2012. Citado 2 vezes nas páginas 21 e 34.

19 GEETHANATH, S.; REDDY, R.; KONAR A. S., e. a. Compressed sensing mri: a review. *Critical Reviews in Biomedical Engineering*, v. 41, n. 3, 2013. Citado 2 vezes nas páginas 22 e 34.

20 GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Citado 12 vezes nas páginas 22, 23, 24, 25, 35, 36, 37, 43, 44, 52, 58 e 63.

21 KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. v. 25. Citado 2 vezes nas páginas 22 e 35.

22 KNOLL, F. et al. Deep-learning methods for parallel magnetic resonance imaging reconstruction: A survey of the current approaches, trends, and open challenges. *IEEE Signal Processing Magazine*, v. 37, n. 1, p. 128–140, 2020. Citado na página 22.

23 HEALTHINEERS, S. *Deep Resolve in MRI*. 2023. <https://www.siemens-healthineers.com/br/magnetic-resonance-imaging/technologies-innovations/deep-resolve>. Deep Resolve: AI-powered image reconstruction for MRI. Citado 3 vezes nas páginas 22, 58 e 66.

24 MEDICAL, A. *SwiftMR Product Information | AI-Powered MRI Enhancement Solution*. 2024. <https://airsmed.com/product-information/>. Descrição técnica dos algoritmos e integração ao fluxo digital. Citado na página 23.

25 MEDICAL, A. *FDA Clears AIRS Medical's SwiftMR for Expanded Use*. 2023. <https://airsmed.com/fda-clears-swiftmr-for-expanded-use/>. Aprovação regulatória FDA. Citado na página 23.

26 PHARMABIZ. *AIRS Medical receives EU MDR CE certification for AI-based MRI Reconstruction*. 2024. <https://www.pharmabiz.com/NewsDetails.aspx?aid=175778&sid=2>. Certificação CE MDR europeia. Citado na página 23.

27 NEWSWIRE, P. *AI-Powered MRI Enhancement Solution, SwiftMR, Approved for Use in Canada*. 2024. <https://www.prnewswire.com/news-releases/ai-powered-mri-enhancement-solution-swiftmr-approved-for-use-in-canada-302040821.html>. Resultados de tempo, qualidade e aprovações regulatórias. Citado na página 23.

28 ANVISA, C. *SwiftMR Registro oficial ANVISA 80117581035*. 2025. <https://consultas.anvisa.gov.br>. Regulatório Brasil. Citado na página 23.

29 MEDICAL, A. Swiftmrő case studies | our customers' experiences and results. 2025. Estudos de caso clínico: resultados de tempo, produtividade e qualidade. Citado na página 23.

30 MEDICAL, A. Clinical evidence on swiftmr's effectiveness. 2025. Resumo de estudos clínicos e algoritmos. Citado na página 23.

31 RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. *arXiv preprint arXiv:1505.04597*, 2015. Citado 7 vezes nas páginas 23, 25, 36, 37, 39, 49 e 50.

32 BANERJEE, I. et al. Reading race: Ai recognizes patient's racial identity in medical images. *Lancet Digital Health*, v. 3, n. 7, p. e445–e454, 2021. Citado na página 24.

33 ISOLA, P. et al. Image-to-image translation with conditional adversarial networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. Citado 12 vezes nas páginas 25, 37, 38, 39, 44, 50, 51, 52, 60, 62, 65 e 68.

34 BLAU, Y.; MICHAELI, T. Similarity and quality metrics for mr image-to-image translation. *Nature*, 2025. Citado 6 vezes nas páginas 25, 39, 40, 56, 62 e 65.

35 SLICHTER, C. P. *Principles of Magnetic Resonance*. [S.l.]: Springer, 1990. Citado 2 vezes nas páginas 27 e 28.

36 MORATAL, D. et al. k-space tutorial: an mri educational tool for a better understanding of k-space. *World Journal of Radiology*, v. 1, n. 1, p. 9–23, 2008. PMCID: PMC3097694. Citado na página 32.

37 KRUPA, K.; BEKIESISKA-FIGATOWSKA, M. Artifacts in magnetic resonance imaging. *Polish Journal of Radiology*, v. 80, p. 93–106, 2015. PMCID: PMC4340093. Citado na página 33.

38 SCHLEMPER, J. et al. A deep cascade of convolutional neural networks for dynamic mr image reconstruction. *IEEE Transactions on Medical Imaging*, v. 37, n. 2, p. 491–503, 2017. Citado na página 37.

39 GOODFELLOW, I. J.; POUGET-ABADIE, J.; MIRZA M., e. a. Generative adversarial nets. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2014. v. 27. Citado 2 vezes nas páginas 37 e 51.

40 WANG, S.; SU, Z.; YING L., e. a. Accelerating magnetic resonance imaging via deep generative models. In: *IEEE 13th International Symposium on Biomedical Imaging (ISBI)*. [S.l.: s.n.], 2018. Citado 2 vezes nas páginas 37 e 38.

41 HAMMERNIK, K. et al. Learning a variational network for reconstruction of accelerated mri data. *Magnetic Resonance in Medicine*, v. 79, n. 6, p. 3055–3071, 2018. Citado na página 39.

42 SRIRAM, A.; ZBONTAR, J.; MURRELL T., e. a. End-to-end variational networks for accelerated mri reconstruction. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. [S.l.: s.n.], 2020. Citado na página 39.

43 HO, J.; JAIN, A.; ABBEEL, P. Denoising diffusion probabilistic models. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2020. v. 33. Citado na página 39.

44 CHUNG, H.; YE, J. C. Score-based diffusion models for accelerated mri. *Medical Image Analysis*, v. 82, p. 102591, 2022. Citado na página 39.

45 CHUNG, H.; YE, J. C. Fast unconditional diffusion model for accelerated mri reconstruction. *ScienceDirect*, 2025. Citado na página 39.

46 SONG, J.; MENG, C.; ERMON, S. Denoising diffusion implicit models. In: *International Conference on Learning Representations (ICLR)*. [S.l.: s.n.], 2020. Citado na página 39.

47 WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, v. 13, n. 4, p. 600–612, 2004. Citado 4 vezes nas páginas 39, 40, 41 e 52.

48 HORE, A.; ZIOU, D. Image quality metrics: A survey. In: *International Conference on Pattern Recognition*. [S.l.: s.n.], 2010. Citado 3 vezes nas páginas 39, 40 e 52.

49 Biomedical Informatics Research Network (BIRN). *Function Biomedical Informatics Research Network Data Repository*. 2024. <http://fbirn.org>. Acesso em: 10 dez. 2024. Citado na página 43.