

**UNIVERSIDADE DE SÃO PAULO  
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

**Mateus Pascoalín Bonati**

**Método baseado em aprendizado de máquina para  
redução de artefatos gerados por objetos metálicos em  
imagens de tomografia computadorizada**

**São Carlos**

**2020**



**Mateus Pascoalín Bonati**

**Método baseado em aprendizado de máquina para  
redução de artefatos gerados por objetos metálicos em  
imagens de tomografia computadorizada**

Monografia apresentada ao Curso de Engenharia Elétrica com Ênfase em Eletrônica, da Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Engenheiro Eletricista.

Área de concentração: Processamento de Imagem

Orientador: Prof. Dr. Marcelo Andrade Costa Vieira

**São Carlos  
2020**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,  
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS  
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da  
EESC/USP com os dados inseridos pelo(a) autor(a).

B697m      Bonati, Mateus Pascoalim  
              Método baseado em aprendizado de máquina para  
redução de artefatos gerados por objetos metálicos em  
imagens de tomografia computadorizada / Mateus  
Pascoalim Bonati; orientador Marcelo Andrade da Costa  
Vieira; coorientador Rodrigo de Barros Vimieiro. São  
Carlos, 2020.

              Monografia (Graduação em Engenharia Elétrica com  
ênfase em Eletrônica) -- Escola de Engenharia de São  
Carlos da Universidade de São Paulo, 2020.

              1. Tomografia computadorizada. 2. Artefatos  
metálicos. 3. CNN. I. Título.

# FOLHA DE APROVAÇÃO

Nome: Mateus Pascoalín Bonati

Título: “Método baseado em aprendizado de máquina para redução de artefatos gerados por objetos metálicos em imagens de tomografia computadorizada”

Trabalho de Conclusão de Curso defendido e aprovado  
em 04 / 12 / 2020,

com NOTA 9,5 ( NOVE, CINCO ), pela Comissão  
Julgadora:

Prof. Associado Marcelo Andrade da Costa Vieira - Orientador  
SEL/EESC/USP

Prof. Dr. Valdir Grassi Junior - SEL/EESC/USP

Mestre Rodrigo de Barros Vimieiro - Doutorando  
SEL/EESC/USP

Coordenador da CoC-Engenharia Elétrica - EESC/USP:  
Prof. Associado Rogério Andrade Flauzino



*Aos amores da minha vida: Antonio, Vanda e Yara*



## **AGRADECIMENTOS**

Gostaria de agradecer a Deus pela oportunidade de ter acesso ao ensino público gratuito e de qualidade que me foi oferecido ao longo desses cinco anos.

Agradecer ao meus pais, Vanda e Antonio, que nunca mediram esforços para que eu tivesse toda a base necessária para me desenvolver profissionalmente e pessoalmente.

Agradecer à pessoa com quem escolhi passar a vida, ao meu amor, Yara Souza, pelo companheirismo, carinho e convivência durante todos os dias e por todos os dias que virão.

Agradecer a todos os amigos que conheci na Elétrica, em especial, ao Marcos, Paulo, Anderson e Leonardo que sempre me acompanharam nas atividades, laboratórios e desafios.

Agradecer ao Coral da USP de São Carlos, que fez com que minha rotina fosse mais musical e alegre, proporcionando a melhor experiência extra-curricular que tive durante esses anos.

Por fim, agradecer ao Professor Marcelo e ao Rodrigo pela paciência, dedicação e esforço em realizar este trabalho, e aproveitar para dizer que aprendi muito com vocês.

Muito Obrigado!



## RESUMO

BONATI, M. P. **Método baseado em aprendizado de máquina para redução de artefatos gerados por objetos metálicos em imagens de tomografia computadorizada.** 2020. 78p. Monografia (Trabalho de Conclusão de Curso) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2020.

A tomografia computadorizada (CT- *Computed Tomography*) é um método de diagnóstico por imagem que utiliza raios X para obter uma reprodução de uma secção do corpo humano. A visualização desse exame se dá pela aplicação de métodos de reconstrução, os quais utilizam os sinais recebidos por sensores para convertê-los em uma imagem digital. No entanto, se os raios X atravessam um material muito denso durante o exame, tais como implantes metálicos, tem-se a geração de artefatos na imagem reconstruída, que podem prejudicar o diagnóstico médico. Estes artefatos são faixas luminosas resultantes da interação dos fótons de raios X com objetos metálicos, que acabam por degradar a imagem. Devido à evolução das técnicas de aprendizado de máquina e inteligência artificial, nos últimos anos, houve um aumento expressivo no desenvolvimento de algoritmos na busca de redução de artefatos em imagens de CT. O objetivo deste trabalho é desenvolver um método para a redução de artefatos metálicos utilizando redes neurais convolucionais aplicadas diretamente no senograma das imagens a serem reconstruídas. O método proposto foi avaliado em imagens sintéticas geradas com o *Phantom Shepp-Logan* e os resultados obtidos com a rede proposta foram comparados com os resultados dos métodos tradicionais de substituição de valores corrompidos no senograma por valores vizinhos e por interpolação. Os resultados sugerem que o método proposto produz imagens melhores que as outras abordagens avaliadas para redução de artefatos, em termos de erro quadrático médio, relação sinal-ruído de pico e índice de similaridade estrutural. Conclui-se que a utilização deste método com redes neurais convolucionais para complementação do senograma pode ser uma alternativa viável para a redução de artefatos metálicos, aprimorando as imagens geradas pela tomografia computadorizada.

**Palavras-chave:** Tomografia computadorizada, artefatos metálicos, CNN.



## ABSTRACT

BONATI, M. P. . 2020. 78p. Monografia (Trabalho de Conclusão de Curso) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2020.

Computed tomography (CT) is a diagnostic imaging method that uses X-rays to obtain a reproduction of a section of the human body. The exam is retrieved by applying reconstruction methods, which use the signals received by the detector to convert them into a digital image. However, if the X-rays pass through a very dense material during the examination, such as metal implants, artifacts are generated in the reconstructed image, which can impair the medical diagnosis. These artifacts are luminous bands resulted from the interaction of X-ray photons with metallic objects, which end up degrading the image. Due to the evolution of machine learning techniques and artificial intelligence, in the last few years, there has been a significant increase in the development of algorithms to reduce artifacts in CT images. The objective of this work is to develop a method to reduce metal artifacts using convolutional neural networks applied directly into the sinogram. The proposed method was evaluated on the Shepp-Logan phantom and the results were compared with the results of the traditional methods such as interpolations. The results indicated that the proposed method produces better images than the other approaches evaluated for artifact reduction, in terms of mean squared error, peak signal-to-noise ratio and structural similarity index. In conclusion, the proposed method may be a viable alternative to reduce metal artifacts, improving the images generated by the CT exam.

**Keywords:** Computed tomography, metal artifacts, CNN.



## LISTA DE FIGURAS

Figura 2.1 – Imagens radiológicas da cabeça: comparação entre radiologia convencional (a) e imagens obtidas a partir da tomografia computadorizada (b) e (c). . . . .	25
Figura 2.2 – Um tomógrafo típico. . . . .	26
Figura 2.3 – Detectores do estado sólido. . . . .	28
Figura 2.4 – Diferentes geometrias de amostragem: (a) feixe paralelo, (b) feixe em leque, (c) feixe em cone. . . . .	28
Figura 2.5 – (a) Região plana mostrando um objeto simples. (b) a (e) reconstrução usando 1, 2, 3, e 4 projeções com distância de $45^\circ$ . (f) reconstrução com 32 projeções com distância de $5,625^\circ$ . . . . .	31
Figura 2.6 – A geometria das linhas e projeções. . . . .	32
Figura 2.7 – Ilustração do mapeamento entre o espaço do objeto (lado direito da Figura) e o espaço do senograma (lado esquerdo da Figura). . . . .	33
Figura 2.8 – (a) Retângulo uniforme, (b) senograma do Retângulo uniforme, (c) <i>phantom de Shepp-Logan</i> , (d) senograma do <i>phantom de Shepp-Logan</i> . . . . .	34
Figura 2.9 – Ilustração do Teorema da Fatia de Fourier . . . . .	37
Figura 2.10 – Ilustração de Simetria dos Raios Paralelos. . . . .	39
Figura 2.11 – Geometria do feixe em Formato de leque. . . . .	40
Figura 3.1 – (a) artefato de movimento, (b) artefato gerado por objeto metálico, (c) artefato em anel, (d) artefato por efeito de endurecimento do feixe . . . . .	44
Figura 3.2 – Total de publicações sobre métodos MAR na CT no período de 1995 a 2015. . . . .	46
Figura 3.3 – Arquitetura da rede RED-Net . . . . .	49
Figura 4.1 – (a) <i>Phantom Shepp-Logan</i> original, (b) senograma do <i>phantom Shepp-Logan</i> original. . . . .	53
Figura 4.2 – Exemplo de imagens geradas via <i>Matlab</i> . . . . .	56
Figura 4.3 – Base de imagens para a rede. . . . .	56
Figura 4.4 – Fluxograma do desenvolvimento do <i>dataset</i> utilizado para treinar a rede. . . . .	57
Figura 4.5 – Fluxo de criação das imagens para exemplo visual. . . . .	57
Figura 4.6 – Arquitetura do Encoder. . . . .	58
Figura 4.7 – Arquitetura do Decoder. . . . .	59
Figura 5.1 – Gráfico Erro x Épocas das seguintes funções custo: (a) MSE, (b) MSE + PL e (c) SSIM . . . . .	61
Figura 5.2 – Projeções para $\theta = 90^\circ$ do senograma c/ metal e senograma s/ metal . . . . .	62
Figura 5.3 – Projeções para $\theta = 90^\circ$ do senograma corrigido pelos métodos comparado ao senograma sem metal . . . . .	63

Figura 5.4 – São apresentados os seguintes senogramas (a) do <i>phantom</i> com metais circulares, (b) do <i>phantom</i> referência s/ metal, (c) corrigido por substituição dos valores vizinhos,(d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM	64
Figura 5.5 – São apresentados os seguintes <i>phantoms</i> : (a) com metais circulares, (b) referência s/ metal, (c) corrigido por substituição dos valores vizinhos,(d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM	65
Figura 5.6 – São apresentados os seguintes senogramas (a) do <i>phantom</i> com metais elípticos, (b) do <i>phantom</i> referência s/ metal, (c) corrigido por substituição dos valores vizinhos,(d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM	66
Figura 5.7 – São apresentados os seguintes <i>phantoms</i> : (a) com metais elípticos, (b) referência s/ metal, (c) corrigido por substituição dos Valores Vizinhos,(d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM	67

## LISTA DE TABELAS

Tabela 4.1 – Divisão do banco de imagens . . . . .	54
Tabela 4.2 – Representação das colunas do vetor responsável por gerar elipses do <i>phantom</i>	54
Tabela 4.3 – Representação das colunas do vetor responsável por gerar metais no <i>phantom</i>	55
Tabela 5.1 – MSE entre as reconstruções corrigidas e a reconstrução de referência. . . .	68
Tabela 5.2 – PSNR entre as reconstruções corrigidas e a reconstrução de referência. . . .	69
Tabela 5.3 – SSIM entre as reconstruções corrigidas e a reconstrução de referência. . . .	69



## LISTA DE ABREVIATURAS E SIGLAS

CT	<i>Computed Tomography</i>
MAR	<i>Metal Artifact Reduction</i>
ART	<i>Algebraic Reconstruction Technique</i>
BP	<i>Back Projection</i>
FBP	<i>Filtered Back Projection</i>
FDK	<i>Feldkamp-Davis-Kress</i>
EM	<i>Expectation Maximization</i>
IPC	Interpolação da Projeção por Contornos
NMAR	<i>Normalized Metal Artifact Reduction</i>
CNN	<i>Convolutional Neural Network</i>
RCNN	<i>Recurrent Convolutional Neural Network</i>
DGDN	<i>Deep Generative Deconvolutional Network</i>
MSE	<i>Mean Squared Error</i>
PL	<i>Perceptual Loss</i>
SSIM	<i>Structural Similarity Index</i>
GAN	<i>Generative Adversarial Networks</i>
RED-Net	<i>Residual Encoder-Decoder Networks</i>
ML	<i>Machine Learning</i>
DL	<i>Deep Learning</i>



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>21</b>
1.1	Objetivo	22
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>25</b>
2.1	Tomografia Computadorizada	25
2.2	Princípios de Formação de Imagens	29
2.3	Reconstrução de imagens	30
2.4	Senograma	33
2.5	Reconstrução: O teorema da Fatia de Fourier	34
2.6	Reconstrução: Filtered Back Projection	37
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>43</b>
3.1	Geração de Artefatos	43
3.2	Métodos para redução de artefatos metálicos	45
3.3	Uso de redes neurais para diminuição de artefatos metálicos	48
3.4	Funções Custo	50
3.4.1	Erro Quadrático Médio	50
3.4.2	MSE com <i>Perceptual Loss</i>	50
3.4.3	SSIM	50
3.5	Métricas de avaliação de imagens	51
3.5.1	PSNR	51
<b>4</b>	<b>MATERIAIS E MÉTODOS</b>	<b>53</b>
4.1	Materiais	53
4.1.1	<i>Phantom Shepp-Logan</i>	53
4.1.2	Banco de imagens para a rede	54
4.2	Métodos	58
4.2.1	Rede Neural Convolucional	58
4.2.2	Substituição por valores vizinhos e interpolação linear	59
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>61</b>
5.1	Treinamento da Rede	61
5.2	Análise das Projeções para um ângulo fixo	62
5.3	Senogramas corrigidos e reconstruções	63
5.4	Métricas de qualidade	68
<b>6</b>	<b>CONCLUSÃO</b>	<b>71</b>

**REFERÊNCIAS** ..... 73

## 1 INTRODUÇÃO

Resultados eficientes e precisos na representação de aspectos anatômicos do corpo humano têm sido alguns dos fatores para o aumento significativo no uso de diagnóstico por imagens (RIBEIRO-ROTTA, 2004). Dentre as técnicas de aquisição de imagens, a tomografia computadorizada, do inglês: *Computed Tomography* (CT), apresenta algumas vantagens sobre a radiografia convencional, posto que: resulta em uma boa representação de estruturas tridimensionais, minimizando a sobreposição de tecidos; é sensível na diferenciação de estruturas próximas promovendo uma observação mais rigorosa entre diferentes tecidos do corpo humano; e comparativamente, apresenta um melhor delineamento das estruturas ósseas da base do crânio e esqueleto facial (RODRIGUES; VITRAL, 2007).

A CT é realizada utilizando-se um tomógrafo, aparelho que contém uma fonte de raios X que rotaciona circularmente em torno de uma região de interesse, como por exemplo, a cabeça do paciente. Esta fonte emite raios X em direção a uma série de detectores localizados no lado oposto da fonte, os quais transformam a radiação recebida em sinais elétricos (JÚNIOR; YAMASHITA, 2001). Esses sinais passam por processos de quantização, originando no computador uma imagem bidimensional representada em níveis de cinza, os quais variam de acordo com o coeficiente de atenuação linear médio do tecido em análise (RODRIGUES; VITRAL, 2007).

O coeficiente de atenuação linear é um parâmetro que varia de material para material. Obturações dentárias, quadris artificiais, implantes de coluna, cirurgias grampo e implantes dentários são exemplos de materiais metálicos que apresentam coeficientes de atenuação muito maiores do que ossos ou tecidos moles (ZHANG et al., 2007). Estes objetos bloqueiam quase totalmente a passagem de fótons, fazendo com que não chegue informação nenhuma, ou quase nenhuma, no detector. Essa ausência de dados faz com que sejam gerados artefatos na reconstrução que degradam gravemente a qualidade da imagem (GJESTEBY et al., 2016).

Artefatos são estruturas observadas nas imagens reconstruídas (como listras claras ou escuras) que não representam corretamente as estruturas reais (KUTEKEN et al., 2017). Esses erros na reconstrução afetam a capacidade de diagnóstico e impedem a distinção precisa dos tipos de tecido. No planejamento da radioterapia para o tratamento do câncer isso é prejudicial pois, a localização inexata do tumor e a caracterização errada dos tecidos circundantes podem resultar em erros de cálculos que afetam gravemente o sucesso do tratamento (KILBY; SAGE; RABETT, 2002). Um outro exemplo onde os artefatos metálicos afetam o diagnóstico é na ortopedia pois, é exigida uma alta qualidade de imagem perto dos implantes metálicos (ROBERTSON et al., 1988).

Visando melhorar a qualidade da imagem para recuperar informações sobre todas as estruturas em análise no exame de tomografia, muitos métodos e algoritmos de redução de artefatos metálicos foram propostos e testados. Pode-se classificar as técnicas de redução de artefatos metálicos, do inglês: *Metal Artifact Reduction* (MAR), em diferentes categorias: otimização de implantes metálicos; melhorias físicas nos equipamentos; algoritmos mais avançados de reconstrução; técnicas de pós-processamento; e técnicas de pré-processamento, como por exemplo a complementação da projeção (GJESTEBY et al., 2016).

Uma abordagem bastante utilizada para a redução de artefatos metálicos diz respeito à correção e/ou substituição dos dados diretamente sobre o senograma da imagem (GJESTEBY et al., 2016). O senograma corresponde a uma composição de diversas projeções obtidas no processo de tomografia, representando um conjunto de dados que servem de partida para o processo de reconstrução através de um método analítico chamado de retroprojeção filtrada, do inglês: *Filtered Back-Projection* (FBP) (SCARFE; FARMAN, 2008).

Existem diversos métodos matemáticos para a complementação do senograma, como por exemplo a substituição por valores vizinhos ao metal (KALENDER, 2011) e interpolação linear. Apesar de computacionalmente simples, o sucesso da interpolação linear varia de acordo com o caso, apresentando uma maior eficácia quando uma pequena fração da projeção é oca, a densidade distribuição é simétrica ou a projeção não muda muito na seção interpolada (GJESTEBY et al., 2016). Uma outra abordagem corresponde a métodos baseados em aprendizagem profunda para a correção dos dados que geram artefatos por meio de redes neurais convolucionais, tratando a imagem do senograma em todo o seu domínio (GHANI; KARL, 2018).

Dentre as técnicas de complementação do senograma a partir do uso de aprendizagem profunda, pode-se citar: uso de redes neurais para estimar os dados perdidos no domínio do senograma (CLAUS et al., 2017); correção dos dados a partir da utilização de uma rede totalmente convolucional, do inglês: *Fully Convolutional Network* (FCN), a partir de análises dos dados antes da reconstrução, trabalhando totalmente no domínio do senograma (GHANI; KARL, 2018); uso de redes neurais convolucionais, do inglês *Convolutional Neural Network* (CNN), que funde as informações das imagens originais e corrigidas para suprimir artefatos (ZHANG; YU, 2018); uso de aprendizagem profunda com operações residuais para complementar a correção de artefatos metálicos após uma passagem inicial em um processo de interpolação (GJESTEBY et al., 2018); dentre outros.

## 1.1 Objetivo

Este estudo tem como objetivo: a) desenvolver um método de redução de artefatos metálicos nas imagens reconstruídas com FBP, utilizando redes neurais convolucionais aplicadas em senogramas; b) testar diferentes funções custo para a rede; c) avaliar o método proposto em imagens sintéticas baseadas no *phantom Shepp-Logan*; d) comparar os resultados obtidos com os métodos de complementação do senograma (substituição pelos valores vizinhos do metal e

interpolação linear) utilizando métricas de erro quadrático médio, relação sinal-ruído de pico e o índice de similaridade estrutural.

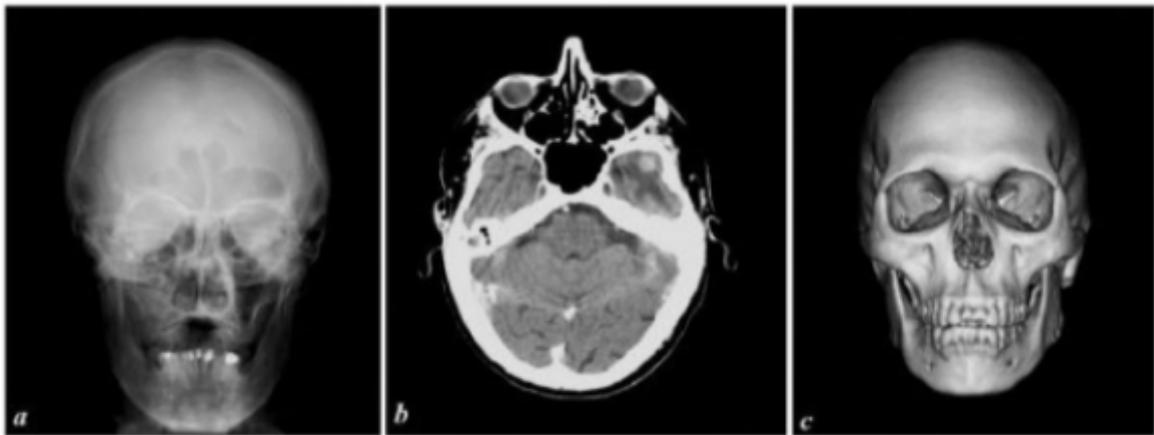


## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Tomografia Computadorizada

A CT é um método de diagnóstico por imagens cada dia mais utilizado na prática clínica, sendo que a visualização do exame é possível devido aos diferentes índices de absorção pelos tecidos aos feixes de raios X emitidos pela máquina. Historicamente, sua utilização diagnóstica ocorreu pela primeira vez em 1971 visualizando um tumor cerebral em uma mulher de 41 anos. O interesse inicial da aplicação deste exame foi em regiões cerebrais e se deve ao fato de que o tecido cerebral apresenta uma baixa atenuação dos feixes de raios X se comparada ao osso cortical do crânio, sendo que uma boa visualização desta área era impossível até a invenção da CT (MOURÃO, 2018). A Figura 2.1 demonstra uma comparação entre imagens obtidas a partir da radiologia convencional e da CT, confirmando que a visualização dessa área craniofacial apresenta um melhor delineamento nas imagens obtidas com a CT.

Figura 2.1 – Imagens radiológicas da cabeça: comparação entre radiologia convencional (a) e imagens obtidas a partir da tomografia computadorizada (b) e (c).



Fonte: Adaptada de (MOURÃO, 2018)

A matemática fundamental para o funcionamento da CT remonta à Johann Radon que desenvolveu em 1917 um método para projetar um objeto 2-D ao longo de raios paralelos através de seu trabalho com integrais de linhas (GONZALEZ; WOODS, 2000). O método conhecido como Transformada de Radon contribuiu para que em 1964, Allan M. Cormack demonstrasse os primeiros resultados de reconstrução de imagens de raios X obtidas em diferentes direções angulares (GONZALEZ; WOODS, 2000). Em 1971, Godfrey Hounsfield, inventou e apresentou o aparelho de CT como método diagnóstico. Em 1979, o Prêmio Nobel de medicina foi entregue aos dois precursores da pesquisa de aparelhos de CT: Cormack e Hounsfield (MOURÃO, 2018).

O primeiro aparelho de CT foi utilizado no Hospital Atkinson Morley em Londres, o qual acomodava somente a cabeça do paciente e apresentava um tempo elevado tanto para escanear uma fatia (cerca de 5 minutos) quanto para reconstruir a imagem no computador (cerca de 2 minutos) (PARKS, 2000). A CT sofreu muitas evoluções, tendo como grandes resultados a redução do tamanho dos aparelhos e do tempo de aquisição, a melhora da qualidade das imagens, o surgimento de novas aplicações e uma maior flexibilidade no trato de dados (MOURÃO, 2018).

O aparelho de tomografia computadorizada tradicional possui três componentes principais: O *gantry*, que apresenta em seu interior o tubo de raios X e um anel de detectores de radiação, o qual é constituído de cristais de cintilação; a mesa, que corresponde a parte onde o paciente permanece deitado, sendo que este é movimentado para o interior do *gantry* durante o exame; e o computador, responsável por reconstruir a imagem a partir dos dados recebidos nos detectores (GARIB et al., 2007). A Figura 2.2 demonstra as partes de um tomógrafo típico, apresentando o *gantry* e a mesa.

Figura 2.2 – Um tomógrafo típico.



Fonte: Adaptada de (PRINCE; LINKS, 2006)

O aparelho de CT passou por diversas modificações ao longo dos anos, trazendo alterações nos parâmetros de aquisição, formato dos detectores, tamanho dos tomógrafos, tempo de aquisição, dentre outros (PRINCE; LINKS, 2006). Para a CT que emite feixes em formato de leque, o exame ocorre da seguinte maneira: A fonte de raios X emite um feixe colimado e fil-

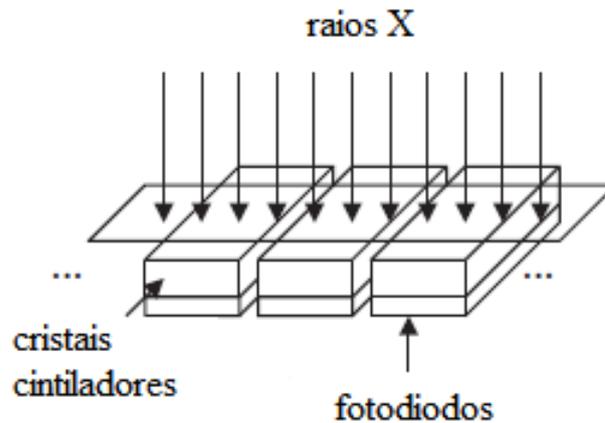
trado em direção a um anel estacionário com diversos detectores. No interior do *gantry*, o tubo de raios X gira dentro deste anel. Os detectores emitem sinais que variam proporcionalmente à intensidade dos feixes de raios X que recebem. Esta intensidade varia de acordo com o índice de atenuação dos tecidos pelos quais o feixe passa. São feitas múltiplas projeções no percurso de 360° em torno do paciente, sendo que posteriormente todos esses dados são recebidos pelo computador, o qual fica responsável por reconstruir a imagem de uma secção do corpo humano (LANGLAIS; LANGLAND; NORTJÉ, 1995).

Uma parte dos tomógrafos utilizam uma única fonte de raios X já que isso reduz o custo de manutenção do aparelho. Em geral, os tubos de raios X são iguais aos utilizados em uma radiografia convencional, sendo necessários períodos de resfriamento entre as varreduras para que danos sejam evitados por calor excessivo. Uma característica dos raios X gerados na CT de feixe em leque é que estes requerem colimação e filtração. A colimação se deve ao fato da necessidade de projetar o feixe de raios X em formato de leque, sendo que este é feito ao atravessar uma fenda gerada por duas peças de chumbo. O processo de filtração, por sua vez, serve para garantir que o feixe seja o mais monoenergético possível, sendo que uma dessas filtragens é feita com o uso de cobre seguido de alumínio, estreitando o espectro de energia do feixe de raios X (PRINCE; LINKS, 2006).

Alguns tomógrafos apresentam, por exemplo, detectores do estado sólido. Esses detectores possuem um cristal cintilante, sendo que ao ser atingido por raios X ocorre o efeito fotoelétrico, sendo produzido fotoelétrons. Este processo de cintilação resulta em uma explosão de luz, sendo esta convertida em corrente elétrica através de um fotodiodo de estado sólido conectado ao cintilador. Comumente, utilizam-se para essa função materiais como cádmio, tungstato, germanato de bismuto ou iodeto de cézio (PRINCE; LINKS, 2006). A Figura 2.3 demonstra a arquitetura desses detectores do estado sólido.

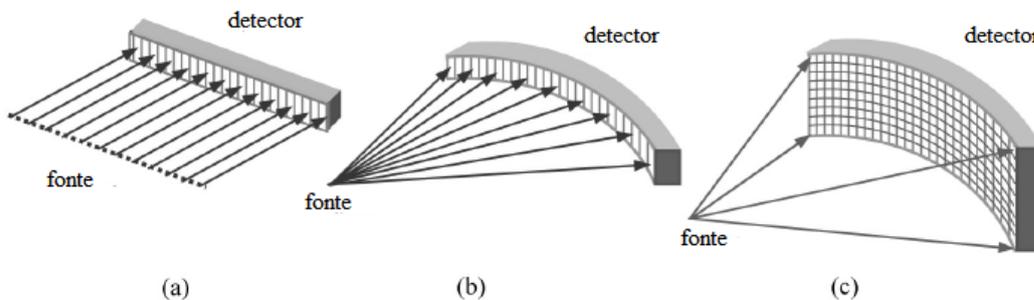
Dentre as evoluções que ocorreram nos aparelhos de CT, uma importante diz respeito às alterações que ocorreram tanto na emissão dos raios X como nos detectores. Os tomógrafos conhecidos como 1ª ou 2ª geração possuem dados coleados a partir de raios paralelos, conforme mostra a Figura 2.4 (a). A 3ª ou 4ª geração compartilham nas amostras de um único foco de projeção para um ponto. Esse tipo de coleta de dados é chamada de projeção em leque, conforme mostrado na Figura 2.4 (b). Por fim, o terceiro modo de coleta de dados diz respeito à projeção de feixe cônico, representado pela Figura 2.4 (c). É possível perceber que nessa modalidade vários planos de feixe em leque são coletados simultaneamente para cobrir um volume. Nota-se que, apesar disso, apenas um plano é perpendicular ao eixo de rotação, sendo o restante inclinados em relação à este eixo. A partir dessa análise, é possível afirmar que conforme o tempo passa, mais complexo se torna o padrão de amostragem (PRINCE; LINKS, 2006).

Figura 2.3 – Detectores do estado sólido.



Fonte: Adaptada de (PRINCE; LINKS, 2006)

Figura 2.4 – Diferentes geometrias de amostragem: (a) feixe paralelo, (b) feixe em leque, (c) feixe em cone.



Fonte: Adaptada de (PRINCE; LINKS, 2006)

As vantagens de utilizar o exame de CT é de se obter imagens de tecidos e órgãos internos do corpo humano minimizando os efeitos da sobreposição de estruturas. Além disso, para o caso de CT de cabeça, é possível obter um melhor delineamento das estruturas ósseas da base do crânio e esqueleto facial comparado à radiografia convencional. O seu poder de apresentar uma melhor resolução e minimizar as sobreposições de tecidos resultam em significativas vantagens na avaliação de lesões neoplásicas e traumáticas, apresentando bons resultados na região da cabeça e pescoço. A CT também foi o primeiro exame que permitiu a obtenção de imagens diretas dos tecidos moles, ainda que deficientes. Como desvantagens deste exame, é importante ressaltar a dose de radiação mais alta do que em exames convencionais e a formação de artefatos

causados por fatores como as estruturas ósseas compactas (especialmente na base do crânio) e estruturas metálicas (restaurações e dispositivos dentários) (RIBEIRO-ROTTA, 2004)

## 2.2 Princípios de Formação de Imagens

A aquisição de imagens por meio da CT é possível pois durante o exame, os feixes de raios X emitidos pelo tubo sofrem distintas atenuações ao atravessarem o corpo do paciente. Essas atenuações são resultantes das interações dos fótons de raios X com os tecidos (RIBEIRO-ROTTA, 2004). Para entender melhor o processo de aquisição de imagens, é necessário estudar sobre o processo de interações dos raios X com a matéria. Como dito na Seção 2.1, o feixe é filtrado para se tornar o mais monoenergético possível. A partir disso, é possível afirmar que as intensidades de raios X mensuradas na entrada e saída de um material uniforme, seguem a lei de Beer-Lambert (HSIEH, 2003) representada matematicamente pela Equação 2.1:

$$I = I_0 e^{-\mu \Delta x} \quad (2.1)$$

onde  $I_0$  representa a intensidade do feixe de raios X de entrada,  $I$  a intensidade de saída,  $\Delta x$  a espessura e  $\mu$  corresponde ao coeficiente de atenuação linear do material. O coeficiente de atenuação depende da energia do feixe, e o feixe de raios X normalmente não é totalmente monoenergético. Para contornar este problema, é utilizado o valor da energia eficaz. A partir da Equação 2.1, fica evidente o fato de que para a mesma espessura de material, quanto maior o coeficiente linear do material, mais atenuada será a intensidade de saída. Para materiais não uniformes, tem-se a representação da intensidade de saída através da Equação 2.2:

$$I = I_0 e^{-\mu_1 \Delta x} e^{-\mu_2 \Delta x} e^{-\mu_3 \Delta x} = I_0 e^{-\sum_{n=1}^N \mu_n \Delta x} \quad (2.2)$$

Ou seja, a atenuação resultante para um material não uniforme pode ser calculada dividindo-se o material em elementos menores. Dividindo-se ambos os lados da equação pela intensidade inicial  $I_0$  e tomando o negativo do logaritmo da intensidade, tem-se a Equação 2.3:

$$-\ln\left(\frac{I}{I_0}\right) = \sum_{n=1}^N \mu_n \Delta x \quad (2.3)$$

Por fim, quando  $\Delta x$  tende a zero, a Equação 2.3 se torna uma integração sobre a espessura do objeto:

$$-\ln\left(\frac{I}{I_0}\right) = \int_L \mu(x) dx \quad (2.4)$$

A Equação 2.4 demonstra que o logaritmo da proporção da intensidade dos raios X de entrada sobre a intensidade dos raios X de saída representam a integral de linha dos coeficientes

de atenuação ao longo do caminho percorrido pelos raios X (HSIEH, 2003). Em um CT real, a intensidade de referência  $I_0$  deve ser medida para cada detector, sendo esta uma parte importante da etapa de calibração (PRINCE; LINKS, 2006).

Como dito na seção 2.1, cada tomógrafo possui um tubo responsável por gerar o feixe de raios X utilizado no exame. Sabe-se que cada tubo possui uma própria energia eficaz. Ou seja, para padronizar os dados de diferentes tubos em diferentes *scanners*, foi desenvolvido o número de CT ( $h$ ), sendo este definido pela Equação 2.5 (PRINCE; LINKS, 2006):

$$h = 1000 \left( \frac{\mu - \mu_{\text{agua}}}{\mu_{\text{agua}}} \right), \quad (2.5)$$

onde  $\mu$  é o coeficiente de atenuação de um material qualquer e  $\mu_{\text{agua}}$  é o coeficiente de atenuação linear da água. A Equação 2.5 tem seu resultado expresso na escala Hounsfield (HU), a qual foi construída através da atenuação no ar seco e na água pura a 25°C, sendo estes valores respectivamente iguais a -1000 HU e 0 HU (RIBEIRO-ROTTA, 2004).

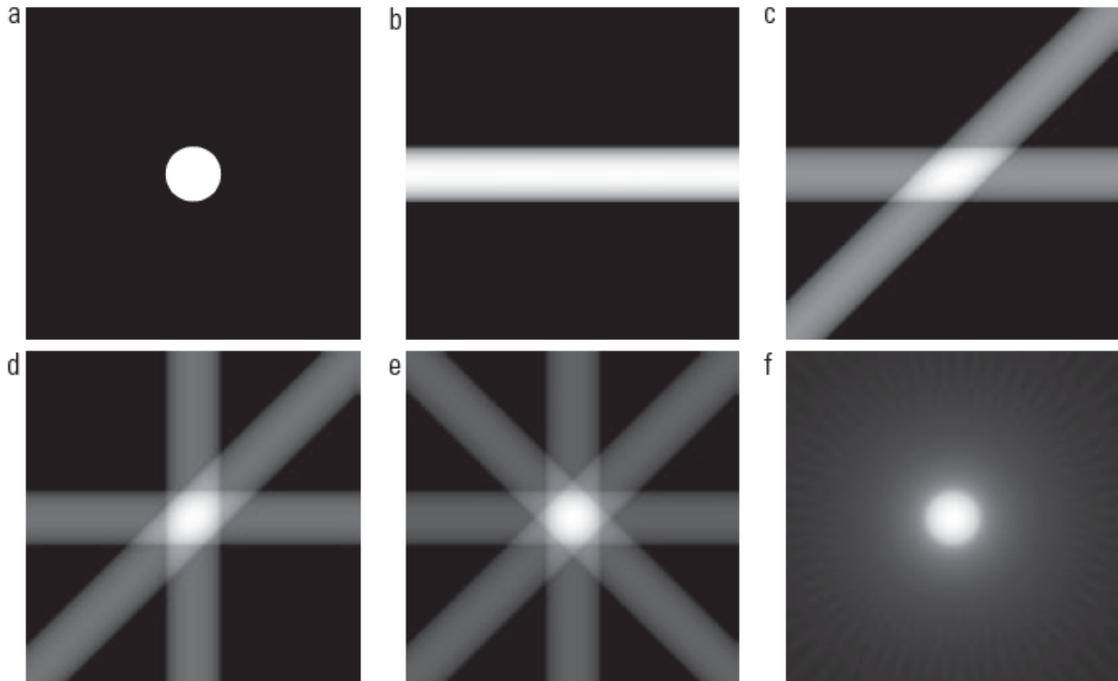
## 2.3 Reconstrução de imagens

Para melhor entender o processo de reconstrução de imagens a partir de projeções, propõem-se a análise de um fundo uniforme que contém um objeto com maior índice de atenuação, como mostra a Figura 2.5(a). Dado o caminho em que certa projeção foi adquirida, se tomarmos seu caminho reverso, temos um feixe como ilustrado na Figura 5(b). Conforme aumenta o número de projeções, a intensidade das retroprojeções que não se cruzam diminui se comparada à das regiões nas quais as múltiplas retroprojeções se cruzam. Ou seja, as regiões mais claras irão dominar o resultado e as retroprojeções com pouca ou nenhuma intersecção desaparecerão no plano de fundo (GONZALEZ; WOODS, 2000).

Nota-se que apesar do formato do objeto ficar mais evidente conforme aumenta-se o número de projeções, é perceptível também a formação de um borramento em torno do objeto, sendo este efeito chamado de "*halo*", fenômeno corrigido por processos de filtragens (GONZALEZ; WOODS, 2000) que serão explicados posteriormente. Em resumo, já foi determinado que é possível reconstruir uma imagem a partir de um conjunto de integrais de linhas dos coeficientes de atenuação dos materiais. Para entender o processo matemático, consideram-se que  $x$  e  $y$  são coordenadas em um plano. Uma linha reta em coordenadas cartesianas pode ser descrita na sua representação normal por:

$$x \cos(\theta) + y \sin(\theta) = l \quad (2.6)$$

Figura 2.5 – (a) Região plana mostrando um objeto simples. (b) a (e) reconstrução usando 1, 2, 3, e 4 projeções com distância de  $45^\circ$ . (f) reconstrução com 32 projeções com distância de  $5,625^\circ$ .



Fonte: Adaptada de (GONZALEZ; WOODS, 2000)

sendo  $l$  a posição lateral de uma linha e  $\theta$  o ângulo de uma unidade normal à linha. A projeção de um feixe de raios paralelos pode ser formada por um conjunto dessas linhas. Um ponto arbitrário no sinal da projeção é dado pela soma de raios ao longo da linha:

$$x \cos(\theta_k) + y \sin(\theta_k) = l_j \quad (2.7)$$

para valores contínuos, a soma de raios é dada por

$$g(l_j, \theta_k) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x \cos(\theta_k) + y \sin(\theta_k) - l_j) dx dy \quad (2.8)$$

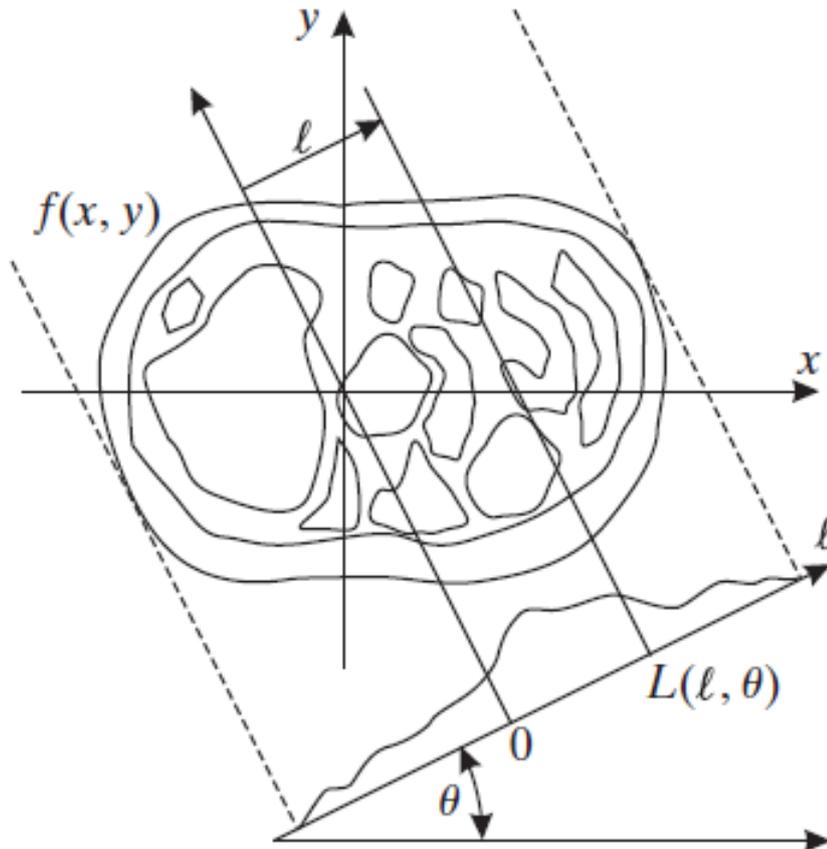
sendo que  $\delta$  representa as propriedades da função impulso. Se for considerado todos os valores de  $l$  e  $\theta$ , a Equação 2.8 é generalizada como:

$$g(l, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x \cos(\theta) + y \sin(\theta) - l) dx dy \quad (2.9)$$

Para um  $\theta$  fixo,  $g(l, \theta)$  é chamado de projeção; para todos os valores de  $l$  e  $\theta$ ,  $g(l, \theta)$  é conhecido como a Transformada 2-D de Radon de  $f(x, y)$ . Esse processo matemático é ilustrado

pela Figura 2.6, onde  $f(x, y)$  representa o objeto com diferentes níveis de atenuação sendo a projeção para um valor de  $\theta$  fixo representada na parte inferior da Figura.

Figura 2.6 – A geometria das linhas e projeções.



Fonte: Adaptada de (PRINCE; LINKS, 2006)

No caso discreto, a Equação 2.9 passa a ser

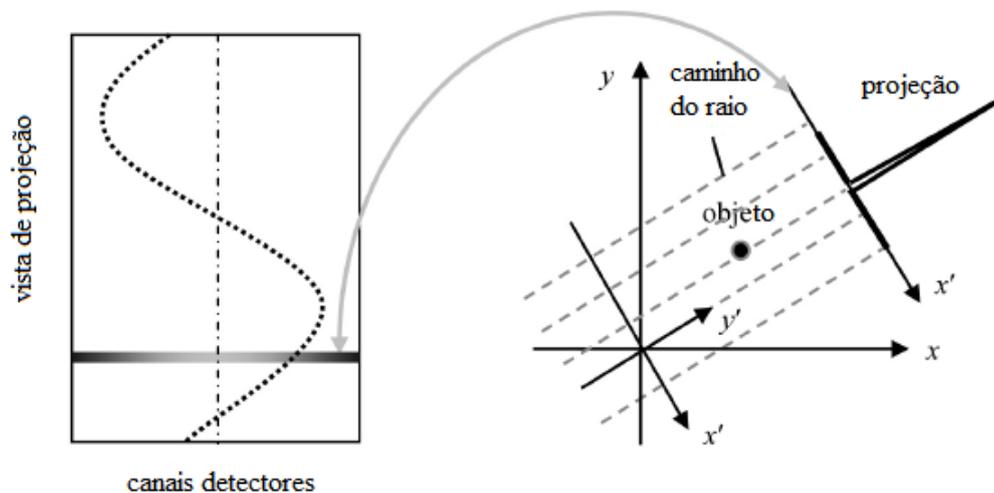
$$g(l, \theta) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \delta(x \cos(\theta) + y \sin(\theta) - l) \quad (2.10)$$

na qual  $x, y, l$  e  $\theta$  agora são variáveis discretas. Ou seja, se mantido um valor de  $\theta$  fixo e variar o valor de  $l$ , será perceptível que a Equação 2.10 realiza uma soma dos *pixels* de  $f(x, y)$  ao longo da linha definida pelos valores especificados desses dois parâmetros. Por outro lado, se passar por todos os valores de  $l$  com um  $\theta$  fixo, tem-se como resultado uma projeção, sendo estes dados fundamentais para a reconstrução da imagem de CT.

## 2.4 Senograma

Quando a transformada de Radon  $g(l, \theta)$  é exibida como uma imagem com  $l$  e  $\theta$  sendo coordenadas retilíneas, o resultado é chamado de senograma. Um senograma é uma representação da transformada de Radon que contém os dados necessários e suficientes para reconstruir  $f(x, y)$  (GONZALEZ; WOODS, 2000). Um senograma é formado pelo empilhamento de todas as projeções de diferentes vistas, de modo que uma projeção única é representada por uma linha horizontal. A projeção de um único ponto forma uma curva sinusoidal no espaço do senograma (HSIEH, 2003). Isto pode ser observado através da Figura 2.7.

Figura 2.7 – Ilustração do mapeamento entre o espaço do objeto (lado direito da Figura) e o espaço do senograma (lado esquerdo da Figura).



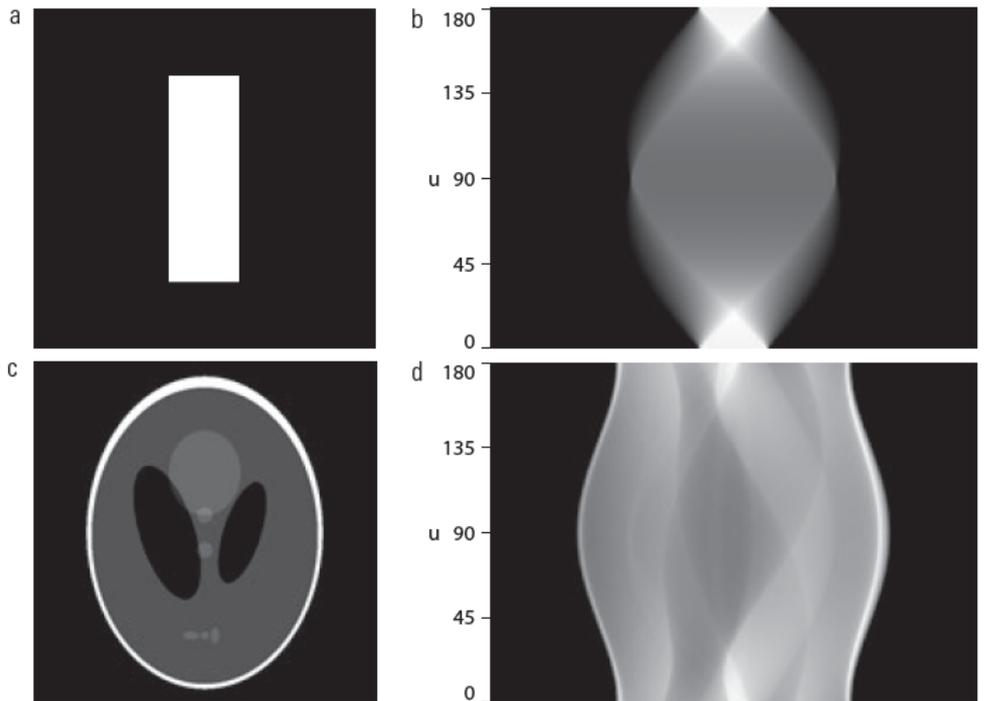
Fonte: Adaptada de (HSIEH, 2003)

Um senograma pode ser usado para análise dos dados de projeção, como por exemplo na detecção de anormalidades do aparelho de CT. Um mau funcionamento momentâneo do tubo de raios X irá produzir uma interrupção em linhas na formação da imagem do senograma, já que cada linha representa a projeção em um determinado tempo (HSIEH, 2003). O Senograma é utilizado também para desenvolvimento de algoritmos tanto de reconstrução quanto para melhorar a visualização do exame, tendo como exemplo algoritmos para a redução de artefatos (LEAO; MACEDO, 2014).

Um senograma pode ser facilmente interpretado quando este representa figuras simples, mas isto se torna mais difícil conforme a complexidade do objeto aumenta. Para ilustrar essa diferença, consideram-se os objetos da Figura 2.8 (a) e 2.8 (c). Esses objetos são respectivamente um retângulo uniforme e uma imagem sintética amplamente utilizada para simulações da área cerebral chamada de *Phantom de Shepp-Logan* (GONZALEZ; WOODS, 2000). As Figuras 2.8 (b) e 2.8(d) representam os senogramas do retângulo e do *Shepp-Logan*, respectivamente. Os eixos verticais do senograma correspondem à  $\theta$  e os horizontais à  $l$ . Deduz-se facilmente na

Figura 2.8 (b) que a linha inferior é a projeção do retângulo na direção horizontal e a linha do meio é a projeção na direção do vertical, sendo estes valores para  $\theta = 0^\circ$  e  $\theta = 90^\circ$  respectivamente. Com o senograma do *phantom* representado pela Figura 2.8 (d), só é possível deduzir um pouco de simetria da imagem original e nada mais que isso (GONZALEZ; WOODS, 2000).

Figura 2.8 – (a) Retângulo uniforme, (b) senograma do Retângulo uniforme, (c) *phantom de Shepp-Logan*, (d) senograma do *phantom de Shepp-Logan*.



Fonte: Adaptada de (GOLDMAN, 2007)

O exame de CT tem como objetivo obter uma representação 3-D de um volume a partir de suas projeções 2-D. Isso representa a necessidade de realizar a retroprojeção de cada projeção, somá-las para gerar uma imagem (fatia) 2-D e empilhá-las para a produção do volume (GONZALEZ; WOODS, 2000). A partir dos dados obtidos do senograma, o próximo passo é processá-los para que se pareçam com o objeto de onde foram criados. Este processo é chamado de reconstrução, e embora existam diversos métodos para isso, serão detalhados neste projeto dois fundamentais: O Teorema da Fatia de Fourier e a FBP.

## 2.5 Reconstrução: O teorema da Fatia de Fourier

Para deduzir um resultado fundamental de reconstrução é importante relacionar a transformada de Fourier 1-D de uma projeção e a transformada de Fourier 2-D da região a partir da qual a projeção foi obtida. Esta corresponde à base dos métodos de reconstrução tendo como

resultado a eliminação do efeito de *halo* comentado na Seção 2.3. Inicialmente, toma-se a transformada de Fourier 1-D de uma projeção em relação à  $l$  como:

$$G(w, \theta) = \mathcal{F}_{1D}\{g(l, \theta)\} = \int_{-\infty}^{\infty} g(l, \theta) e^{-j2\pi w l} dl \quad (2.11)$$

onde  $w$  é uma variável de frequência. O próximo passo é substituir a expressão analítica para  $g(l, \theta)$  mostrado na Equação 2.10 o que resulta na Equação 2.14 após as manipulações mostradas nas Equações 2.12 e 2.13:

$$G(w, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x \cos(\theta) + y \sin(\theta) - l) e^{-j2\pi w l} dx dy dl \quad (2.12)$$

$$G(w, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \int_{-\infty}^{\infty} \delta(x \cos(\theta) + y \sin(\theta) - l) e^{-j2\pi w l} dx dy dl \quad (2.13)$$

$$G(w, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j2\pi w (x \cos(\theta) + y \sin(\theta))} dx dy \quad (2.14)$$

Antes de continuar a tratativa na Equação 2.14, é fundamental entender as propriedades da função impulso para 2-D. Seja um impulso  $\delta(t, z)$  de duas variáveis contínuas  $t$  e  $z$  definidos pela Equação 2.15 (GONZALEZ; WOODS, 2000):

$$\delta(t, z) = \begin{cases} \infty & \text{se } t = z = 0 \\ 0, & \text{c.c.} \end{cases} \quad (2.15)$$

e

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \delta(t, z) dt dz = 1 \quad (2.16)$$

Assim como conhecido para 1-D, o impulso em 2-D apresenta a propriedade de peneiramento em relação à integração:

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(t, z) \delta(t, z) dt dz = f(0, 0) \quad (2.17)$$

se considerado na origem, ou de maneira geral, um impulso localizado nas coordenadas  $(t_0, z_0)$ :

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(t, z) \delta(t - t_0, z - z_0) dt dz = f(t_0, z_0) \quad (2.18)$$

Quando olha-se para variáveis discretas  $x$  e  $y$ , o impulso discreto 2-D é definido como:

$$\delta(x, y) = \begin{cases} 1 & \text{se } x = y = 0 \\ 0, & \text{c.c.} \end{cases} \quad (2.19)$$

Relembrada a propriedade do impulso e considerando:

$$\begin{cases} u = w \cos(\theta) \\ v = w \sin(\theta) \end{cases} \quad (2.20)$$

A expressão final para  $G(w, \theta)$  é uma reminiscência da Transformada 2-D de Fourier para  $f(x, y)$  sendo definida como:

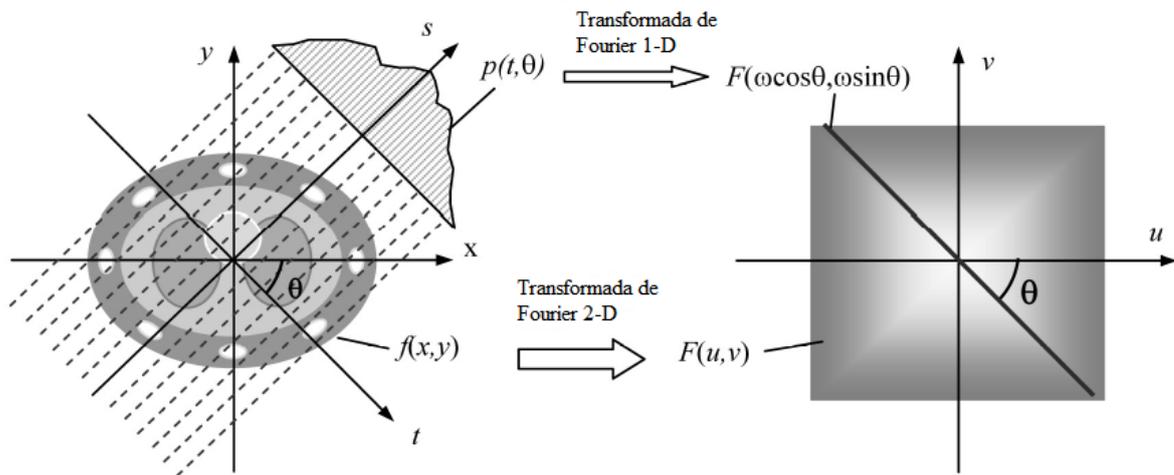
$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j2\pi(xu+yv)} dx dy \quad (2.21)$$

a qual para os valores definidos anteriormente de  $u$  e  $v$  é traduzida como:

$$G(w, \theta) = F(w \cos(\theta), w \sin(\theta)) \quad (2.22)$$

A Equação 2.22 é conhecida como o teorema da fatia de Fourier, o qual afirma que a transformada de Fourier de uma projeção é uma fatia da transformada de Fourier 2-D da região a partir da qual a projeção foi obtida (PRINCE; LINKS, 2006). Ou seja, de cada projeção obtém-se uma linha na transformada de Fourier 2D do objeto executando a Transformada de Fourier na projeção. Se coletarmos um número suficiente de projeções no intervalo de 0 a  $\theta$ , pode-se obter a reconstrução do objeto através da transformada inversa de Fourier (HSIEH, 2003). A representação gráfica que deriva do Teorema da Fatia de Fourier está representada na Figura 2.9.

Figura 2.9 – Ilustração do Teorema da Fatia de Fourier



Fonte: Adaptada de (HSIEH, 2003)

O Teorema da Fatia de Fourier entrega uma solução simples e direta para a reconstrução da imagem tomográfica. No entanto, existem alguns desafios para sua implementação. Um dos problemas diz respeito ao fato de que o espaço de Fourier não é Cartesiano, o que faz com que as amostras das projeções caiam em uma grade de coordenadas polares. Para ser feita a reconstrução, é necessário realizar a inversa da transformada de Fourier 2-D, sendo necessário fazer um processo de interpolação. Essa interpolação no domínio da frequência é complexa de ser feita, e qualquer erro nesse processo afeta na aparência de toda a imagem reconstruída. Tendo em vista essa dificuldade, fez-se necessário o desenvolvimento de outros métodos de reconstrução (HSIEH, 2003).

## 2.6 Reconstrução: Filtered Back Projection

Um dos métodos de reconstrução alternativos ao método da Teoria da Fatia de Fourier mais utilizado é chamado de retroprojeção filtrada, do inglês: *Filtered Back-Projection* (FBP) (KAK; SLANEY; WANG, 2002). O método FBP é uma abordagem analítica de reconstrução de imagem, sendo este método vastamente utilizado por aparelhos de CT por um longo tempo (DEÁK et al., 2013). Este método utiliza a Transformada de Radon como modelo matemático básico para as projeções, retroprojeções e reconstruções da imagem (GONZALEZ; WOODS, 2000). Para a dedução do método FBP, parte-se inicialmente do fato de que a Transformada de Fourier e a Inversa da Transformada de Fourier são operadores conjugados. Dessa forma, a função de imagem dada por  $f(x, y)$  pode ser recuperada de sua transformada de Fourier  $F(u, v)$  pela inversa de Fourier, conforme a Equação 2.23:

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) e^{j2\pi(xu+yv)} du dv \quad (2.23)$$

A transformação de coordenadas cartesianas para coordenadas polares pode ser representada por:

$$\begin{cases} u = w \cos(\theta) \\ v = w \sin(\theta) \end{cases} \quad (2.24)$$

e

$$dudv = \begin{bmatrix} \frac{\partial u}{\partial w} & \frac{\partial u}{\partial \theta} \\ \frac{\partial v}{\partial w} & \frac{\partial v}{\partial \theta} \end{bmatrix} dw d\theta = w dw d\theta \quad (2.25)$$

Substituindo as Equações 2.23 e 2.24 na Equação 2.25, tem-se:

$$f(x, y) = \int_0^{2\pi} d\theta \int_0^{\infty} F(\omega \cos(\theta), \omega \sin(\theta)) e^{j2\omega(x \cos(\theta) + y \sin(\theta))} \omega d\omega \quad (2.26)$$

A partir do uso do Teorema da Fatia de Fourier, pode-se trocar  $F(\omega \cos(\theta), \omega \sin(\theta))$  por  $P(\omega, \theta)$  sendo resultante a seguinte relação:

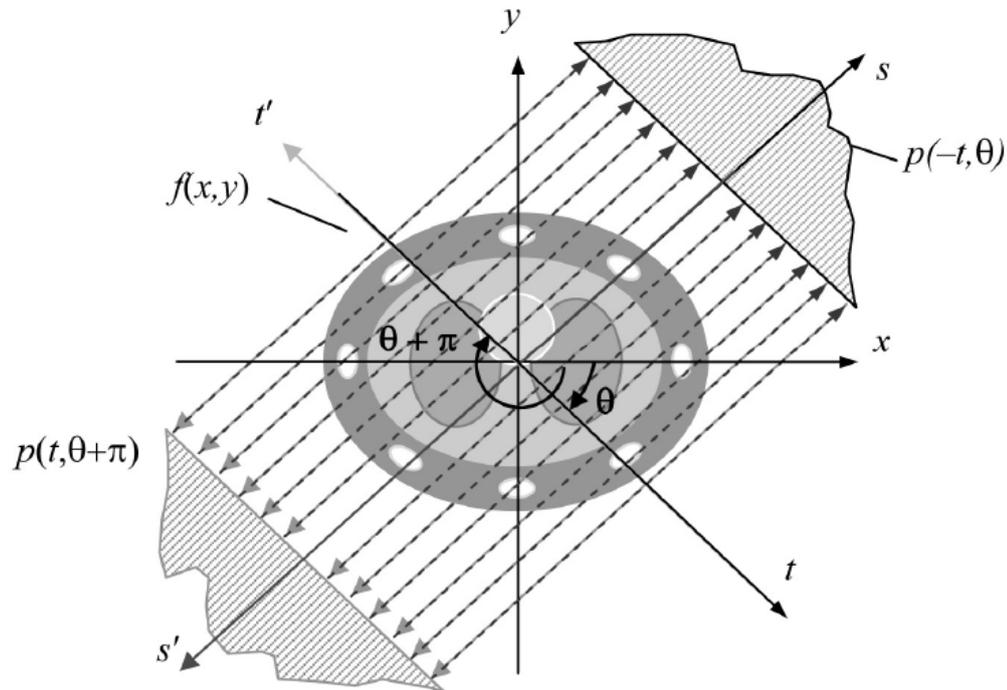
$$f(x, y) = \int_0^{2\pi} d\theta \int_0^{\infty} P(\omega, \theta) e^{j2\omega(x \cos(\theta) + y \sin(\theta))} \omega d\omega \quad (2.27)$$

Se considerar a geometria de feixes paralelos, existe uma propriedade de simetria entre as amostras da projeção dada por:

$$p(t, \theta + \pi) = p(-t, \theta) \quad (2.28)$$

Isso está representado na Figura 2.10, que demonstra que projeções distanciadas de 180° representam o mesmo conjunto de raios.

Figura 2.10 – Ilustração de Simetria dos Raios Paralelos.



Fonte: Imagem adaptada de (HSIEH, 2003)

Com isso, uma relação semelhante existe para o par correspondente na transformada de Fourier (HSIEH, 2003):

$$P(\omega, \theta + \pi) = P(-\omega, \theta) \quad (2.29)$$

Sendo possível chegar na seguinte relação:

$$f(x, y) = \int_0^\pi d\theta \int_{-\infty}^{\infty} P(\omega, \theta) |\omega| e^{j2\pi\omega(x\cos(\theta) + y\sin(\theta))} d\omega \quad (2.30)$$

Passando a Equação 2.30 para o sistema de coordenadas  $(s, t)$ , chega-se na seguinte equação:

$$f(x, y) = \int_0^\pi d\theta \int_{-\infty}^{\infty} P(\omega, \theta) |\omega| e^{j2\pi\omega t} d\omega \quad (2.31)$$

Na Equação 2.31,  $P(\omega, \theta)$  é a transformada de Fourier da projeção no ângulo  $\theta$ . A integral interna é a inversa da transformada de Fourier da quantidade  $P(\omega, \theta) |\omega|$ . No domínio do espaço, representa uma projeção filtrada por uma função cujo domínio da resposta em frequên-

cia é  $|\omega|$  sendo portanto, chamada de "Projeção Filtrada". Se a notação da projeção filtrada no ângulo  $\theta$  por  $g(t, \theta)$  representa a integral interna da Equação 2.31, então:

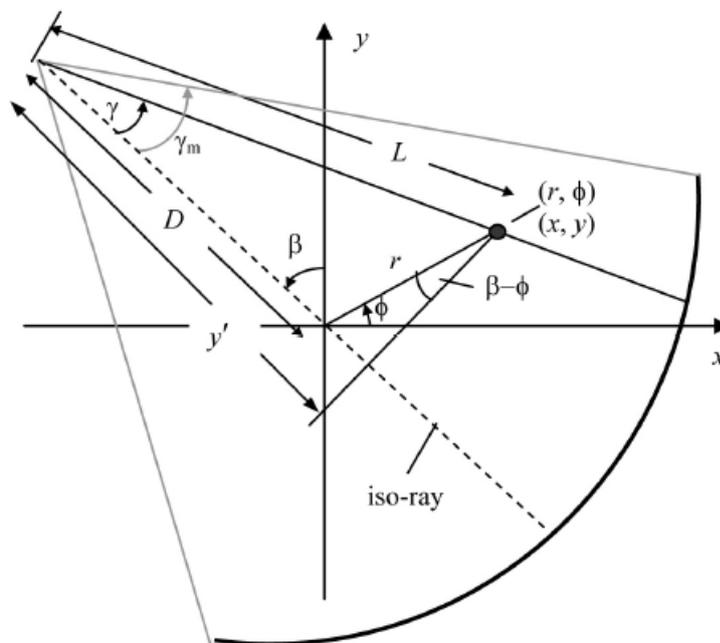
$$g(t, \theta) = g(x\cos(\theta) + y\sen(\theta)) = \int_{-\infty}^{\infty} P(\omega, \theta)|\omega|e^{j2\pi\omega(x\cos(\theta)+y\sen(\theta))} d\omega \quad (2.32)$$

A Equação 2.31 pode ser rescrita como:

$$f(x, y) = \int_0^\pi g(x\cos(\theta) + y\sen(\theta))d\theta \quad (2.33)$$

A Equação 2.33 demonstra que a imagem reconstruída  $f(x, y)$  no local  $(x, y)$  é a soma de todas as amostras de projeção filtradas que passam por este ponto (HSIEH, 2003). Toda essa tratativa remete a utilização de feixes paralelos, devido à simplicidade do equacionamento. No entanto, existem outros aparelhos de CT que utilizam feixes em formato de leque. Em seguida, segue uma breve tratativa das equações utilizadas no processo FBP. Para facilitar, toma-se como base a Figura 2.11.

Figura 2.11 – Geometria do feixe em Formato de leque.



Fonte: Adaptada de (GONZALEZ; WOODS, 2000)

Inicialmente, sabe-se que uma amostra  $q(\gamma, \beta)$  em uma projeção de feixes em leque pertenceria a uma amostra  $p(t, \theta)$  em uma projeção paralela se as seguintes condições forem

satisfeitas:

$$\begin{cases} \theta = \beta + \gamma \\ t = D\text{sen}(\gamma) \end{cases} \quad (2.34)$$

sendo D a distância a partir do centro da fonte até a origem do plano  $xy$ . Sabe-se que pelo teorema da convolução a Equação 2.33 pode ser reescrita como:

$$f(x, y) = \int_0^\pi d\theta \int_{-t_m}^{t_m} p(t', \theta)h(t - t')dt' \quad (2.35)$$

A partir da equação 2.35, pode-se deduzir que:

$$f(x, y) = \int_0^\pi d\theta \int_{-t_m}^{t_m} p(t', \theta)h(x\cos(\theta) + y\text{sen}(\theta))dt' \quad (2.36)$$

Modificando-se a equação para incluir todas as projeções sobre  $2\pi$  e expressando em coordenadas polares  $(r, \varphi)$  tem-se:

$$f(r, \varphi) = \frac{1}{2} \int_0^{2\pi} d\theta \int_{-t_m}^{t_m} p(t', \theta)h(r\cos(\theta - \varphi) - t')dt' \quad (2.37)$$

Na Equação 2.37 é utilizada a relação  $r\cos(\theta - \varphi) = r\cos(\varphi)\cos(\theta) + r\text{sen}(\varphi)\text{sen}(\theta)$ . Para que toda a Equação seja escrita em termos de  $(\gamma, \beta)$  ao invés de  $(t, \theta)$ , substitui-se a Equação 2.34 na Equação 2.37, resultando então:

$$f(r, \varphi) = \frac{1}{2} \int_{-\gamma}^{2\pi-\gamma} d\beta \int_{-\gamma_m}^{\gamma_m} q(\gamma, \beta)h(r\cos(\beta + \gamma - \varphi) - D\text{sen}\gamma)D\cos(\gamma)d\gamma \quad (2.38)$$

Sendo finalmente a Equação 2.38 a representação fundamental da reconstrução por feixes em formato de leque baseada em retroprojeções filtradas (HSIEH, 2003). Em resumo, pode-se descrever o processo de geral de FBP nesta ordem: aplicar a transformada de Fourier nas linhas paralelas à trajetória do tubo; aplicar filtro de rampa; aplicar filtro de janela para redução de ruído; aplicar transformada inversa de Fourier; e por fim, projetar novamente os dados no domínio espacial (VIMIEIRO; BORGES; VIEIRA, 2019).



## 3 REVISÃO BIBLIOGRÁFICA

### 3.1 Geração de Artefatos

Um problema que afeta a qualidade das imagens reconstruídas por CT é a criação de artefatos. Os artefatos podem afetar estruturas importantes e podem fazer com que o exame seja interpretado de forma equivocada, além de prejudicar a detecção correta e caracterização de recursos de interesse. Existem diversos tipos de artefatos, os quais podem ser reconhecidos a partir de suas origens, conforme será descrito a seguir (PRINCE; LINKS, 2006).

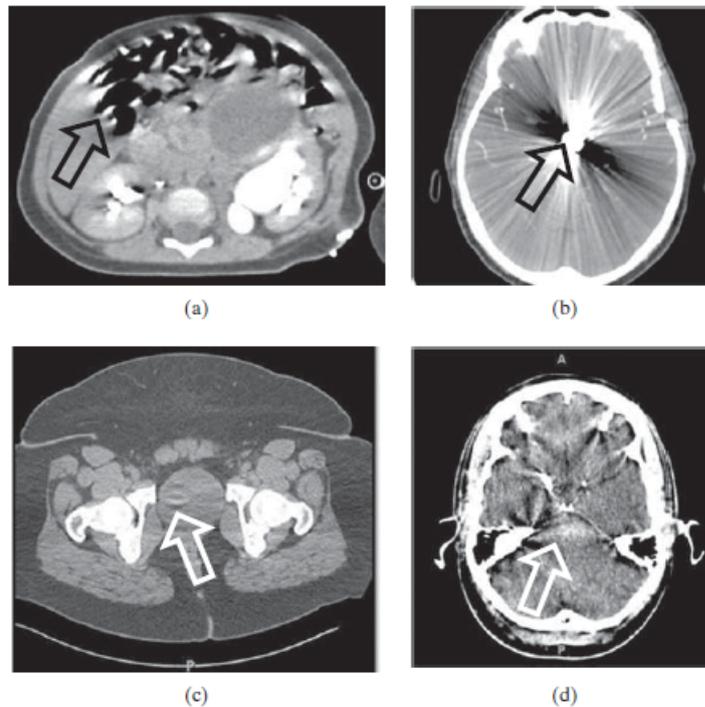
O termo artefato na CT é aplicado a qualquer discrepância sistemática entre os números na imagem reconstruída e os verdadeiros coeficientes de atenuação do objeto. As imagens de CT são mais propícias a apresentarem artefatos se comparada às radiografias convencionais, pois a imagem é reconstruída a partir de milhares de medições de detectores independentes. Dessa forma, qualquer erro nessa medição refletirá como um erro na imagem reconstruída (BARRETT; KEAT, 2004). Diferentes artefatos geram diferentes problemas nas imagens resultantes do exame, sendo possível conhecê-los a partir de suas origens. Destacam-se: artefatos de movimento, artefatos em anel, artefatos de ruído, artefatos de dispersão, artefatos de extinção, artefatos gerados por materiais muito densos, dentre outros (RUPRECHT, 2008). Exemplos de diferentes tipos de artefatos podem ser visualizados na Figura 3.1

Artefatos de movimento são gerados devido à movimentos do paciente durante o exame. Isto pode ser amenizado colocando um apoio para a cabeça do paciente e/ou reduzindo o tempo de exposição, já que a probabilidade do paciente permanecer estático durante o exame é maior (SCARFE; FARMAN, 2008). Artefatos em anel recebem este nome pois aparecem nas imagens como ruídos circulares e são causados devido a uma calibração incorreta do detector do tomógrafo. Este efeito pode ser reduzido com uma calibração adequada no detector (SCHULZE et al., 2011). Artefatos de ruído são gerados pelo fato de cada área do sensor absorver uma diferente quantidade real de fótons, já que os processos de atenuação e espalhamento são estocásticos (LOUBELE et al., 2008).

Artefatos de dispersão são causados por fótons difratados de seus trajetos originais mas que também acabam atingindo o receptor, aumentando erroneamente a intensidade de uma determinada área medida. Isto pode ser minimizado diminuindo o tamanho do detector (DRANERT et al., 2007). Diferentemente da superestimação do número de fótons em uma área, existem os artefatos de extinção, que correspondem a valores próximos de zeros nos receptores, fato que ocorre em processos no qual o objeto em questão possui um número grande de materiais absorvedores (BELEDELLI; SOUZA, 2012). Por fim, os artefatos gerados por objetos muito densos ocorrem pelo fato de que os fótons de menor energia são absorvidos por esses materiais e os fótons de maior energia acabam atingindo os receptores. Este fenômeno é conhecido como

efeito de endurecimento do feixe, e pode ocorrer por exemplo na presença de objetos metálicos (YAZDI; BEAULIEU, 2008).

Figura 3.1 – (a) artefato de movimento, (b) artefato gerado por objeto metálico, (c) artefato em anel, (d) artefato por efeito de endurecimento do feixe



Fonte: Adaptada de (PRINCE; LINKS, 2006)

Existem protocolos que devem ser seguidos antes do procedimento do exame realizado pela CT. Neste protocolo, uma das etapas é a retirada de todos os adornos metálicos para evitar a interação dos feixes de raios X com esses, fato que faz com que sejam gerados artefatos (MIKI et al., 2016). No entanto, sabe-se que há casos que esse procedimento é inviável, tendo como exemplos pacientes com: próteses ortopédicas; restaurações dentárias; clips cerebrais; implantes cocleares; clips de aneurismas; ou qualquer outro objeto metálico (SILVA, 2019).

Os objetos metálicos possuem um coeficiente de atenuação muito mais alto do que ossos e tecidos (ZHANG et al., 2007). Quando o objeto metálico interage com os raios X, ocorre um endurecimento do feixe, ou seja, os fótons de menor intensidade são absorvidos resultando em um feixe de fótons mais energéticos. Pode ocorrer também uma insuficiência de fótons, já que os índices de absorção de materiais densos são altos (GUILFOILE; RAMPANT; HOUSE, 2017).

Os feixes que atravessam os objetos metálicos geram sinais fracos ao atingir o detector, resultando em sombras na projeção bruta de dados (ZHANG et al., 2007). Esta perda de informações sobre a composição original da anatomia faz com que, na reconstrução da imagem, sejam geradas faixas brilhantes que se sobrepõem às regiões em torno do objeto metálico, dificultando a visualização destas áreas. Esses artefatos representam regiões na imagem final que

possuem valores de níveis de cinza saturados e distintos da densidade real do tecido (GUILFOILE; RAMPANT; HOUSE, 2017).

Os artefatos gerados por endurecimento do feixe em CT odontológico são bem comuns, principalmente quando a região de interesse possui implantes (DRAENERT et al., 2007). Este fato faz com que a qualidade da imagem adquirida seja baixa, dificultando o diagnóstico correto nas áreas adjacentes aos implantes (AZEVEDO et al., 2008). Para corrigir os artefatos gerados por endurecimento do feixe, os fabricantes dos tomógrafos utilizam estratégias que podem ser divididas em quatro diferentes classes: filtragem de hardware; energia dupla; reconstrução policromática estatística e linearização (GOMPEL et al., 2011).

### 3.2 Métodos para redução de artefatos metálicos

O surgimento de artefatos metálicos foi descrito na Seção 3.1, no entanto, deve-se ressaltar que dependendo da forma e da densidade do objeto de metal, a aparência deste tipo de artefato pode ter uma variação significativa. Basicamente, o objeto de metal pode produzir o efeito de endurecimento do feixe, do inglês: *beam hardening*, subfaixas nas aquisições de dados ou extrapolar a faixa dinâmica no processo de reconstrução (HSIEH, 2003). Os métodos para redução de artefatos metálicos cresceram com o passar dos anos já que este é um problema relevante no ramo da CT. Diversos estudos e abordagens se desenvolveram, buscando diferentes maneiras de redução desses artefatos. Isso pode ser observado na Figura 3.2, que representa um gráfico evolutivo do número de publicações relacionados a métodos de MAR de 1995 à 2015 (GJESTEBY et al., 2016).

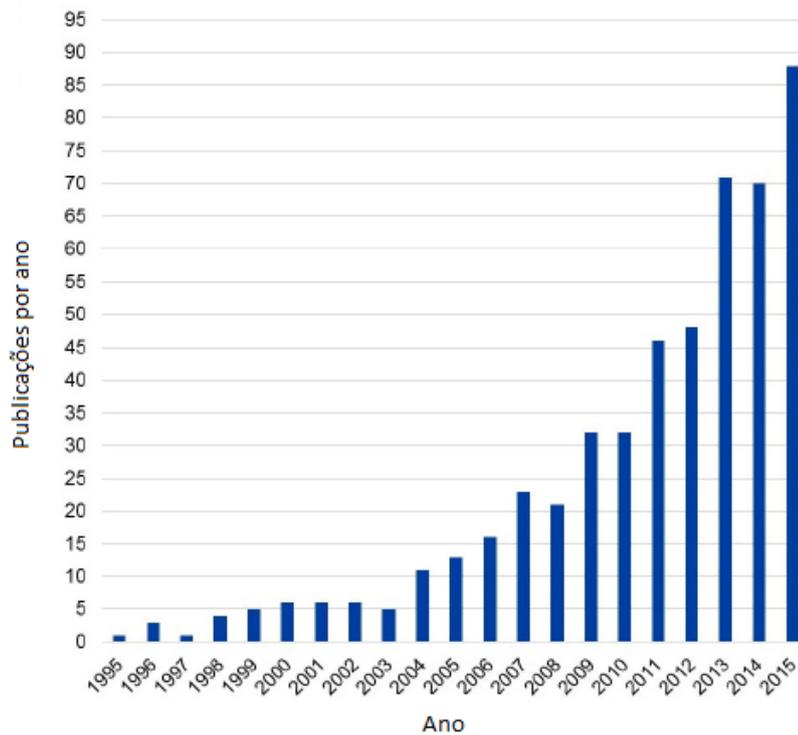
Pode-se dividir as técnicas de MAR em seis grupos diferentes de acordo com o enfoque de suas tratativas. São elas: otimização de implantes metálicos; melhora nos parâmetros de aquisição; técnicas de pré-processamento baseados nos efeitos físicos resultantes (como por exemplo *beam hardening*); reconstruções iterativas; técnicas de pós-processamento e complemento da projeção.

O grupo de técnicas correspondentes à otimização de implantes metálicos, tem como principal objetivo a remoção do objeto metálico durante o exame, tratativa que muitas vezes é inviável devido a necessidade de algum procedimento cirúrgico invasivo (GJESTEBY et al., 2016). Dentro deste grupo, existem também linhas de pesquisa para medir e comparar níveis de atenuação dos metais, como por exemplo, o titânio apresentar uma qualidade de imagem superior ao uso do cromo-cobalto em regiões próximas ao osso (HARAMATI et al., 1994).

Quando se fala na melhora dos parâmetros de aquisição, tem-se a estratégia de que mudar parâmetros como valores da tensão, corrente do tubo de raios X e dimensão do plano de varredura reduzem a geração de artefatos (GJESTEBY et al., 2016). Como exemplo, a técnica de aumentar a tensão e/ou corrente do tubo para que fótons de energia mais altas sejam gerados para penetrar nos objetos de metal, melhora a qualidade dos dados brutos em alguns casos.

(MOON et al., 2008). O uso de CT com dupla energia, do inglês: *dual energy* também obtém resultados satisfatórios, tendo como exemplo o fato de que  $130keV$  apresenta melhores resultados para redução de artefatos metálicos comparado a valores inferiores como  $40keV$  e  $100keV$  (ZHOU et al., 2011).

Figura 3.2 – Total de publicações sobre métodos MAR na CT no período de 1995 a 2015.



Fonte: Adaptada de (GJESTEBY et al., 2016)

A linha de pesquisa das técnicas de pré-processamento baseado nos efeitos físicos diz respeito a modelar a causa física dos artefatos gerados para ser aplicado correções no domínio da projeção antes do processo de reconstrução. Dentre as tratativas, tem-se a modelagem de ruído local com um filtro adaptativo médio (HSIEH, 1998), a qual também pode ser combinada com técnicas algébricas de reconstrução, do inglês: *Algebraic reconstruction technique* (ART), para suprimir artefatos em listras (RANGAYAN; GORDON, 1982). Tem também o estudo de técnicas avançadas de interpolação para redução do efeito de *beam hardening* e o desenvolvimento de algoritmos de correção de dispersão (MEYER et al., 2012).

As reconstruções iterativas tem como objetivo reduzir a quantidade de artefatos a partir de comparações entre uma projeção base e os dados obtidos a partir da CT, buscando minimizar o erro entre os senogramas. Nesta abordagem, existem: algoritmos de remoção de manchas a partir de uma maximização de expectativa, do inglês *Expectation Maximization* (EM) e a ART (WANG et al., 1996); criação de uma máscara de metal para isolar projeções que necessitam de correção (AUGUST; KANADE, 2004); algoritmo baseados na transmissão da máxima ve-

rossimilhança que otimiza a probabilidade de dados de Poisson (MAN et al., 2000); algoritmo iterativo de reconstrução policromática também baseada na verossimilhança (MAN et al., 2001); dentre outros.

O grupo de técnicas menos popular corresponde aos métodos de pós processamento. Esses métodos buscam reduzir artefatos após a reconstrução da imagem, sem depender dos dados brutos de aquisição (projeções). Dentre essas técnicas, existem: normalização dos dados para um determinado nível de vinza (HENRICH, 1980); aplicação de filtros passa-baixa após identificar os valores das listras de artefatos através da aplicação de um valor *Threshold* (SOLTANIANZADEH; WINDHAM; SOLTANIANZADEH, 1996); aplicação de filtros adaptativos radial em imagens com baixo nível de artefatos (BAL et al., 2005). Dentro desta perspectiva, existem também a utilização de métodos de pós-processamento para melhorar o resultado de etapas iniciais aplicadas por outro grupo. Por exemplo, a combinação do método de interpolação linear simples e o método de filtragem adaptativa multidimensional (WATZKE; KALENDER, 2004).

Por sua vez, o grupo de técnicas mais utilizado são os métodos para complementar a projeção. Em situações de presença de metal nos exames de CT, os dados dessa região são adquiridos incompletos ou até mesmo com valores totalmente corrompidos. Para corrigir isso, deve-se sintetizar novos dados para a correção do senograma. Uma maneira de se conseguir isso é através de métodos de interpolação através dos dados vizinhos ou de algum modelo matemático (GJESTEBY et al., 2016). Dentre desses métodos tem como exemplo: a interpolação linear (KALENDER, 2011); a interpolação de projeções por contorno (IPC), onde se tem um aumento do número de projeções para reconstrução da imagem (BRUYANT; SAU; MALLET, 2000); aplicação de método de reconhecimento de padrões (MORIN; RAESIDE, 1981); interpolação em duas dimensões, utilizando informações em um eixo radial (MAHNKEN et al., 2003); a utilização da técnica conhecida como *Total Variation Inpainting* para complementar dados faltantes no senograma (XUE et al., 2009), dentre outros.

Uma abordagem complementar às técnicas citadas anteriormente corresponde à normalização dos dados. Inicialmente, foram feitos estudos analisando inicialmente reconstruções de imagens não corrigidas para encontrar os objetos de metal e depois normalizando as projeções a partir do resultado obtido (MÜLLER; BUZUG, 2009). Foi então desenvolvida uma técnica conhecida como MAR normalizado, os quais normaliza os dados da projeção original de acordo com os dados da projeção anterior. Esta imagem anterior sem artefatos é obtida por uma segmentação da imagem original, após o efeito de suavização para definir regiões de osso, ar e tecido mole. Essa normalização feita sobre o senograma aumenta a homogeneidade das regiões onde a interpolação linear será aplicada, levando a resultados mais precisos (MEYER et al., 2010)

Em suma, algoritmos matemáticos para redução de artefatos gerados por objetos metálicos que buscam complementar a projeção do senograma pode-se resumir em quatro etapas: a correção de pixels aplicando um limiar na escala Hounsfield; a projeção (senograma) para

identificar os pixels corrompidos; a remoção dos pixels corrompidos e a interpolação com estimativas apropriadas; e a retroprojeção do senograma interpolado gerando uma imagem correta (KATSURA et al., 2018). Embora existam muitos métodos, eles deixam a desejar no quesito da retirada total de artefatos nas imagens, em alguns casos, criando novos artefatos devido aos métodos implementados. Nos últimos anos, uma forte linha de pesquisa utilizando aprendizado profundo, do inglês: *Deep Learning* (DL), para melhorar métodos existentes, tem ganhado força e apresenta resultados promissores (MAI; WAN, 2020).

### 3.3 Uso de redes neurais para diminuição de artefatos metálicos

A área de aprendizado de máquina, do inglês: *Machine Learning* (ML), e o DL tem ganhado grande popularidade como uma solução eficaz para problemas em diversos campos. Na área de imagens médicas, as técnicas de DL tem ganhado grande destaque na parte de processamento e análise de imagens, sendo também uma nova abordagem para a redução de artefatos metálicos em imagens de CT (GJESTEBY et al., 2017). Uma classe de rede bastante utilizada na área de processamento de imagens são as redes neurais convolucionais, do inglês: *Convolutional Neural Networks* (CNN), apresentando poderosos resultados e uma grande capacidade de extrair detalhes em um grande conjunto de dados (KRIZHEVSKY; SUTSKEVER; HINTON, 2017).

A CNN foi proposta pela primeira vez em 1947 e diferia dos estudos com redes neurais existentes até então pois adicionava em sua arquitetura um algoritmo de retropropagação para aprender os campos receptivos de unidades simples (LIANG; HU, 2015). A CNN se caracteriza por apresentar conexões locais, compartilhamento de pesos e *pooling* local. As duas primeiras fazem com que o modelo descubra padrões visuais locais com menos parâmetros ajustáveis. O *pooling* local incorpora a rede um pouco de invariância à translação (LIANG; HU, 2015).

Nos últimos anos, muitas técnicas têm sido desenvolvidas para melhorar o desempenho das CNN. A exemplo disso, pode-se citar: diversos estudos na área da melhor função de ativação, sendo a função linear retificada (Relu) a mais comumente usada por ser resistente ao desaparecimento do gradiente no algoritmo de retropropagação (GLOROT; BORDES; BENGIO, 2011); utilização de técnicas eficazes para evitar que as redes neurais se ajustem excessivamente ao treinamento (SRIVASTAVA et al., 2014); uso de *pooling* máximo para melhorar a capacidade do modelo que evita o ajuste excessivo (GOODFELLOW et al., 2013); incorporação de uma classe recorrente (RCNN) para reconhecimento de objeto incorporando conexões em cada camada convolucional (LIANG; HU, 2015); o acoplamento de classes como a recente desenvolvida *Deep Generative Deconvolutional Network* (DGDN) como um aprendizado semi-supervisionado (PU et al., 2016), dentre outros.

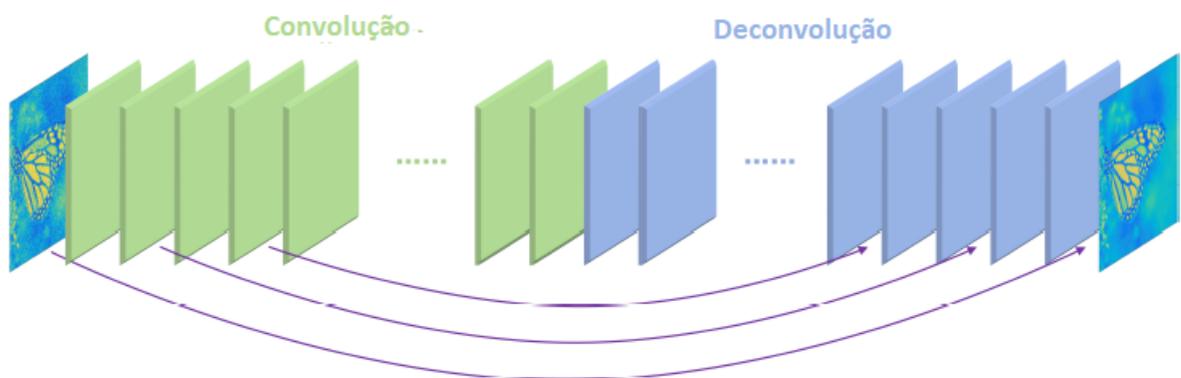
Apesar de existirem há muito tempo, as CNN apresentam algumas limitações. O uso típico dessas redes é em tarefas de classificação, onde a saída para uma imagem é apenas um rótulo de classe única. No entanto, áreas como processamento de imagens médicas apresentam

a necessidade de identificar partes específicas da imagem, ou seja, atribuir um rótulo de classe a cada *pixel* (RONNEBERGER; FISCHER; BROX, 2015). Para acelerar a convergência da rede foi desenvolvida uma arquitetura com conexões *skip-layer*, conhecida como RED-Net, do inglês: *very deep Residual Encoder-Decoder Networks* (MAO; SHEN; YANG, 2016).

Um exemplo da arquitetura RED-Net pode ser visto na Figura 3.3. As camadas convolucionais agem são extratores de recursos que codificam os componentes primários do conteúdo da imagem, eliminando as partes corrompidas. As camadas deconvolucionais então decodificam a abstração da imagem para recuperar os detalhes. As conexões de salto, do inglês: *skip connections* entre as conexões convolucionais e deconvolucionais auxiliam na retropropagação dos gradientes para as camadas inferiores e passam os detalhes para as camadas superiores (MAO; SHEN; YANG, 2016).

Na literatura existem diversas abordagens do uso de ML para melhorar e desenvolver técnicas de MAR: técnicas desenvolvida utilizando DL com operações residuais para corrigir artefatos remanescentes de um primeiro passo de interpolação (GJESTEBY et al., 2018); métodos que utilizam as projeções das partes próximas das corrompidas para o treinamento do modelo (MAI; WAN, 2020); aplicação de DL para fazer estimativas dos dados faltantes em um senograma, utilizando uma rede com poucas camadas seguidas por um mapeamento de recursos, tendo na última camada uma síntese mapeada dos dados ausentes (CLAUS et al., 2017); estudo para eliminar o efeito de *beam hardening* durante a formação do senograma utilizando a arquitetura U-net para reparar as perdas de dados geradas por materiais metálicos (PARK et al., 2018); dentre outros.

Figura 3.3 – Arquitetura da rede RED-Net



### 3.4 Funções Custo

O crescimento da utilização de algoritmos de DL ao longo dos anos requer técnicas mais avançadas para contribuir com a eficácia destes métodos. A função custo é um dos fatores mais significativos no quesito de desempenho dos algoritmos, apresentando resultados bem diferentes em uma mesma arquitetura. Com isso, são destacadas três funções (NIE; HU; LI, 2018):

#### 3.4.1 Erro Quadrático Médio

O erro quadrático médio, do inglês: *Mean Squared Error* (MSE) é uma função custo que calcula o erro pixel a pixel entre a imagem de saída  $\tilde{Y}_i$  e a imagem alvo  $Y_i$ :

$$\zeta_{MSE} = \frac{1}{N} \sum_{i=1}^N \left\| \tilde{Y}_i - Y_i \right\|^2 \quad (3.1)$$

onde  $N$  é o número de amostras de treinos e  $i$  representa uma amostra do treino (GJESTEBY et al., 2018).

#### 3.4.2 MSE com *Perceptual Loss*

O uso da função custo MSE pode resultar em perdas devido a uma possível suavização excessiva. A função custo *Perceptual Loss* (PL) busca preservar a textura da imagem (GJESTEBY et al., 2018). A PL é uma função pré-treinada da rede VGG((SIMONYAN; ZISSERMAN, 2014)) sendo também utilizada na área de processamento de imagens. A função custo PL pode ser definida pela Equação 3.2 a qual, neste caso, utiliza o erro quadrático médio para medir as diferenças:

$$\zeta_{PL} = \frac{1}{N} \sum_{i=1}^N \left\| \phi(\tilde{Y}_i) - \phi(Y_i) \right\|^2 \quad (3.2)$$

onde  $\phi$  é a VGG treinada (GJESTEBY et al., 2018). A função custo combinada se dá pela soma da função custo MSE com a função custo PL, sendo esta multiplicada por um fator  $\alpha = 1.17e^{-5}$ , conforme mostra a Equação 3.3:

$$\zeta_{(MSE+PL)} = \zeta_{MSE} + \alpha \zeta_{PL} \quad (3.3)$$

#### 3.4.3 SSIM

Em casos em que a rede tenha objetivo de apresentar imagens visualmente parecidas, a função custo chamada de Índice de Similaridade Estrutural, do inglês: *Structural Similarity*

*Index* (SSIM), tem apresentado bons resultados (ZHAO et al., 2016). O SSIM está representado pela Equação 3.4:

$$SSIM(\tilde{Y}, Y) = \frac{2\mu_{\tilde{Y}}\mu_Y + c_1}{\mu_{\tilde{Y}}^2 + \mu_Y^2 + c_1} \frac{2\sigma_{\tilde{Y}Y} + c_2}{\sigma_{\tilde{Y}}^2 + \sigma_Y^2 + c_2} \quad (3.4)$$

onde  $\mu_{\tilde{Y}}$ ,  $\mu_Y$ ,  $\sigma_{\tilde{Y}}$  e  $\sigma_Y$  são as médias e as variâncias de  $\tilde{Y}$  e  $Y$  e  $\sigma_{\tilde{Y}Y}$  é a covariância de  $\tilde{Y}$  e  $Y$  (ZHAO et al., 2016). A função custo SSIM é definido por

$$\zeta_{SSIM} = 1 - SSIM(\tilde{Y}, Y) \quad (3.5)$$

### 3.5 Métricas de avaliação de imagens

A medida de qualidade é um parâmetro importante para verificar a eficácia de funcionalidades. Quando trata-se de analisar imagens, a qualidade é o critério principal, podendo esta ser avaliada através do uso de métricas. Dentro das diversas métricas usadas para mensurar a qualidade de imagens, o MSE, o Pico da Relação Sinal-Ruído, do inglês: *Peak Signal-to-Noise Ratio* (PSNR), e o SSIM são frequentemente citados na literatura e classificados como métricas de referência completa, pois consideram como referência a imagem original (SARA; AKTER; UDDIN, 2019). O MSE e a SSIM foram definidos nas seções 3.4.2 e 3.4.3, respectivamente.

#### 3.5.1 PSNR

O PSNR é uma métrica derivada do erro quadrático médio e demonstra a razão entre a intensidade máxima do pixel e a potência da distorção. O cálculo da PSNR é dada pela Equação 3.6:

$$PSNR(\tilde{Y}, Y) = 10 \cdot \log \left( \frac{max^2}{MSE(\tilde{Y}, Y)} \right) \quad (3.6)$$

onde  $max$  representa o máximo valor dentre todos os *pixels* da imagem. Para o PSNR, quanto maior o valor, melhor será sua qualidade (LEAO; MACEDO, 2014).



## 4 MATERIAIS E MÉTODOS

Propõem-se um método para redução de artefatos metálicos através da adaptação de uma rede neural CNN com uma arquitetura RED-Net para complementação dos dados corrompidos no senograma, sendo que serão testados três diferentes funções custo: MSE, MSE combinada com PL e SSIM.

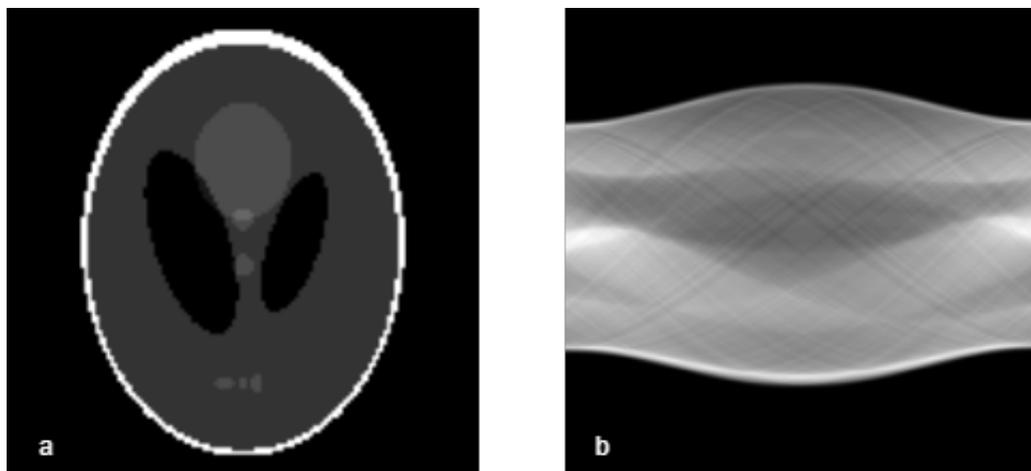
### 4.1 Materiais

#### 4.1.1 *Phantom Shepp-Logan*

As imagens foram geradas artificialmente através do *Software Matlab*, com a função *phantom*, a qual retorna a imagem de um *Shepp-Logan*. A escolha deste *phantom* é devido a sua ampla utilização para imagens médicas pois simula vários níveis de atenuação, conforme visto na seção 2.4. As imagens foram geradas no tamanho 128x128 e então foram aplicadas nelas a Transformada de Radon, com um ângulo de varredura de  $0^\circ$  a  $179^\circ$  em passos de  $1^\circ$ , a qual retorna o senograma desta imagem. Neste trabalho, para aproximar os senogramas da ideia de um gráfico sinusoidal, será assumido que o eixo-x corresponde aos valores de  $\theta$  e o eixo-y à  $l$ . Os pares *phantom* original e senograma podem ser vistos pela Figura 4.1.

Quando se aplica a transformada de Radon em um *phantom* de tamanho 128x128 é gerado um senograma 185x180. No entanto, para facilitar os procedimentos de divisão que ocorrem na rede, essas imagens foram modificadas para 180x180. Esse procedimento corresponde a eliminar as 5 linhas iniciais do vetor, as quais em todos os casos eram contidas apenas por zeros. Essas linhas são adicionadas posteriormente para realizar a reconstrução.

Figura 4.1 – (a) *Phantom Shepp-Logan* original, (b) senograma do *phantom Shepp-Logan* original.



#### 4.1.2 Banco de imagens para a rede

Para o desenvolvimento do método foi necessário elaborar um banco de imagens sintéticas. A rede possui uma imagem 180x180 de entrada e uma imagem 180x180 de saída. Cada exemplo utilizado corresponde a um par de imagens, constituído por um senograma corrompido por artefatos metálicos e um outro sem. Foram geradas 60 mil amostras e a divisão do banco de imagens está descrita na Tabela 4.1. Neste trabalho não foi feita validação cruzada.

Tabela 4.1 – Divisão do banco de imagens

Número de amostras	Conjunto
33.500	treino
16.500	validação
10.000	teste

Fonte: Elaborada pelo Autor (2020).

Como os exemplos de senogramas devem ser distintos, foi necessário variar os parâmetros de entrada da função *phantom*. Esses parâmetros correspondem a um vetor 1x6, onde cada coluna corresponde a uma alteração nas elipses contidas no interior do *phantom*. Vale ressaltar que, para manter a forma do *Shepp-Logan*, não foram alteradas as duas elipses externas da imagem. A quantidade de novas elipses internas foi determinada em cada iteração, sendo escolhida por um número inteiro aleatório entre um e oito. Os valores utilizados para desenhar estas elipses estão representados na Tabela 4.2.

A primeira coluna do vetor representa o valor de intensidade aditiva da elipse. Para qualquer *pixel* da imagem de saída, o valor do *pixel* é igual à soma dos valores de intensidade aditiva de todas as elipses das quais o pixel faz parte. Se um *pixel* não faz parte de nenhuma elipse, seu valor é zero. O valor de intensidade aditiva para uma elipse pode ser positivo ou negativo; se for negativo, a elipse será mais escura do que os *pixels* circundantes. Os valores da segunda até a quinta coluna são coordenadas dentro do domínio  $[-1, 1]$  dos eixos x e y. A sexta coluna por sua vez, apresenta os valores em graus.

Tabela 4.2 – Representação das colunas do vetor responsável por gerar elipses do *phantom*

Coluna	Parâmetro	Valor Min.	Valor Max.
1°	Altera o nível de atenuação do material	-0.5	0.2
2°	Altera largura no eixo-x	0.01	0.4
3°	Altera altura no eixo-y	0.01	0.4
4°	Altera posição no eixo-x	-0.5	0.5
5°	Altera posição no eixo-y	-0.5	0.5
6°	Rotação da figura	0°	360°

Fonte: Elaborada pelo Autor (2020).

O *phantom* gerado aleatoriamente a partir dos dados da Tabela 4.2 será então acrescido de metal. O princípio de adição do metal ao *phantom* é praticamente o mesmo da adição de elipses, sendo diferente os valores mínimos e máximos utilizados. O número de metais adicionados corresponde à um valor inteiro aleatório entre um e cinco gerado em cada iteração. Os valores utilizados para desenhar estes metais estão representados na Tabela 4.3.

Tabela 4.3 – Representação das colunas do vetor responsável por gerar metais no *phantom*

Coluna	Parâmetro	Valor Min.	Valor Max.
1°	Altera o nível de atenuação do material	0.5	6.5
2°	Altera largura no eixo-x	0.01	0.1
3°	Altera altura no eixo-y	0.01	0.1
4°	Altera posição no eixo-x	-0.5	0.5
5°	Altera posição no eixo-y	-0.8	0.8
6°	Rotação da figura	0°	360°

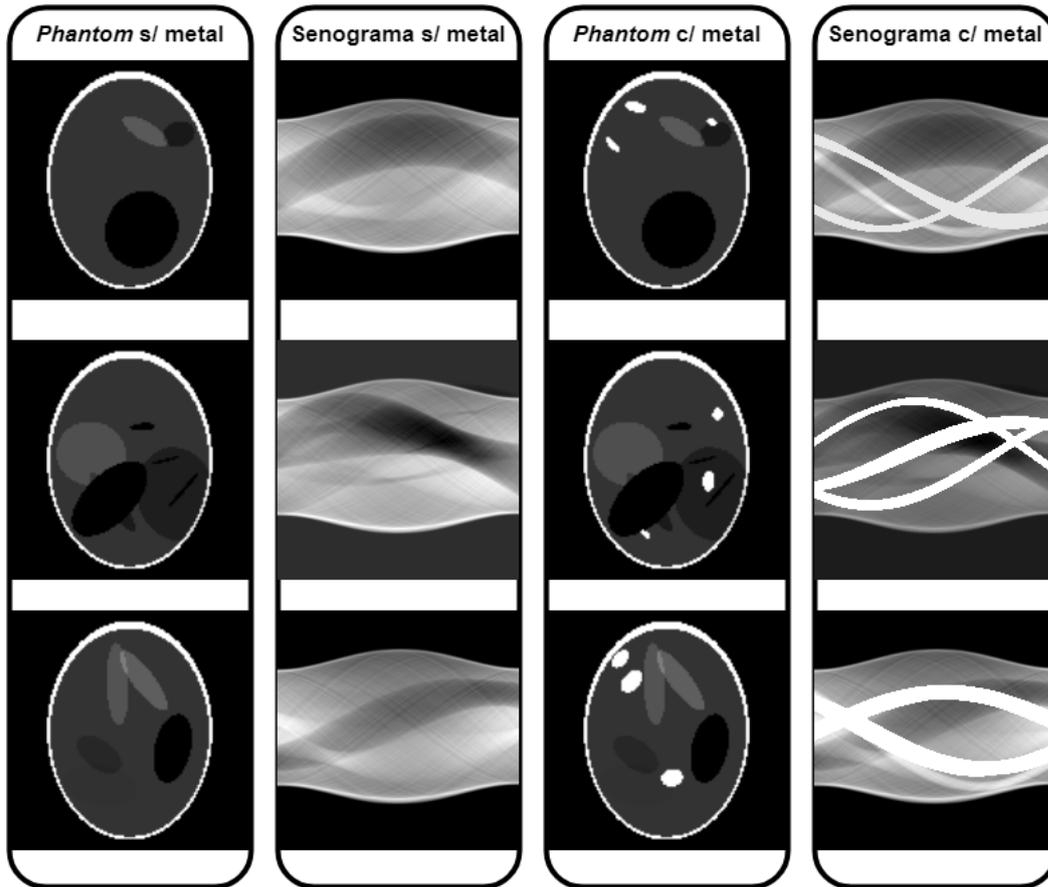
Fonte: Elaborada pelo Autor (2020).

Por fim, é necessária uma etapa de simulação do artefato metálico no senograma corrompido. Em uma situação real de aquisição de dados, os objetos metálicos fazem com que não cheguem informações suficientes nos detectores para fazer uma reconstrução perfeita. No caso simulado, o *phantom* apresenta todas as informações necessárias para a reconstrução. É necessário então, localizar o local que o metal foi inserido e eliminar a informação em volta deste metal, o que fará com que sejam gerados artefatos na etapa de reconstrução. Dessa forma, o senograma (corrompido) irá responder corretamente no processo de reconstrução, simulando a falta de informação daquele ponto onde está o objeto metálico independente do ângulo de projeção (KUBICEK et al., 2015).

A Figura 4.2 apresenta exemplos das imagens geradas. A figura 4.3 apresenta uma pequena amostra da base de imagens utilizada na rede. O processo de geração das imagens mostradas está descrito no fluxograma representado pela Figura 4.4.

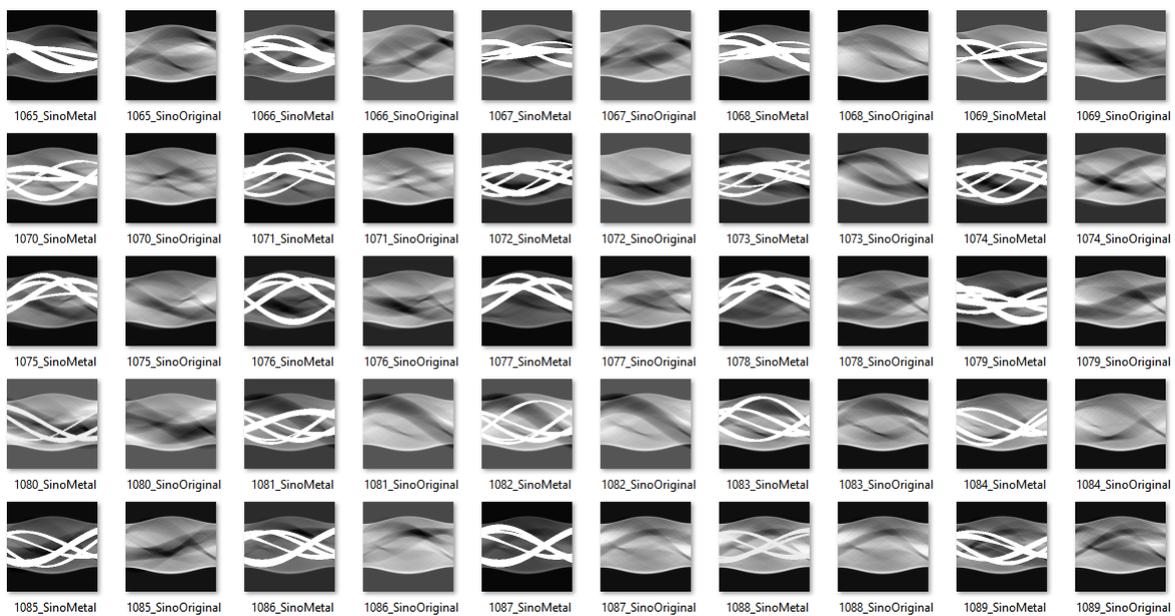
Para fins de visualização, foram geradas imagens a partir da adição do metal em um *phantom Shepp-Logan*. Foram gerados três *phantoms*, sendo um não corrompido e dois com presença de metais. Em um *phantom* os metais são circulares e em outro são em formato elíptico. Para visualizar a eficácia dos métodos de redução de artefatos, deve-se comparar as reconstruções realizadas com a reconstrução dos *phantoms* de exemplo. Para isso, foi aplicado a inversa da Transformada de Radon em cada senograma, conforme mostra a Figura 4.5.

Figura 4.2 – Exemplo de imagens geradas via *Matlab*.



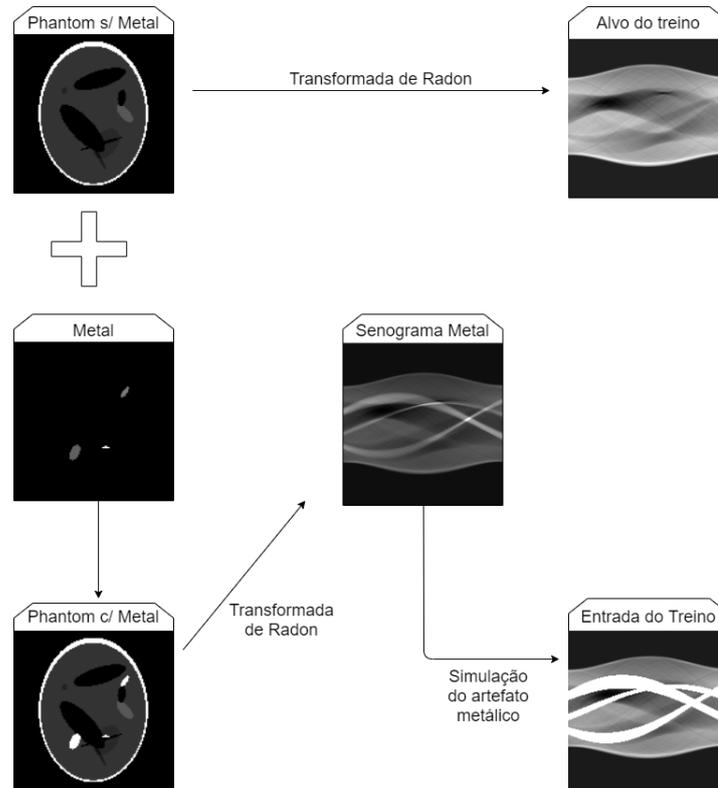
Fonte: Elaborada pelo Autor (2020).

Figura 4.3 – Base de imagens para a rede.



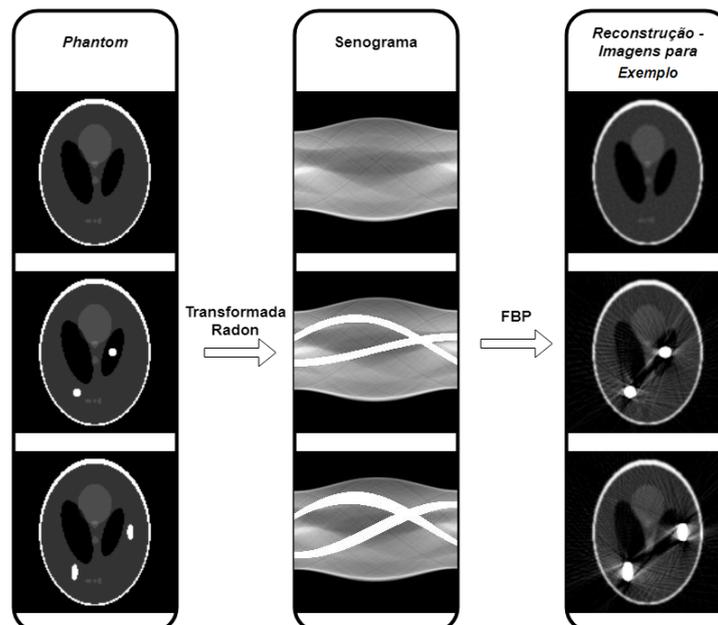
Fonte: Elaborada pelo Autor (2020).

Figura 4.4 – Fluxograma do desenvolvimento do *dataset* utilizado para treinar a rede.



Fonte: Elaborada pelo Autor (2020).

Figura 4.5 – Fluxo de criação das imagens para exemplo visual.



Fonte: Elaborada pelo Autor (2020).

## 4.2 Métodos

### 4.2.1 Rede Neural Convolutacional

Uma CNN com arquitetura RED-Net foi utilizada para a redução dos artefatos metálicos. A rede possui como entrada uma imagem corrompida de tamanho 180x180, a qual corresponde a um senograma com artefatos metálicos. Esses dados corrompidos são faixas brancas que serão preenchidas pela rede. A rede proposta teve sua construção baseada em um *Autoencoder* para remoção de ruído e está disponível em <https://github.com/LAVI-USP/DMAR2dCT>, sendo esta adaptada para retornar um senograma 180x180 corrigido.

A rede possui uma arquitetura RED-Net. O *encoder* tem cinco camadas convolucionais com trinta e dois filtros em cada. O *decoder* apresenta cinco camadas de-convolucionais com trinta e dois filtros nas quatro primeiras e uma na última. Nesta arquitetura, existem *skip-connections* entre algumas camadas e a utilização de operações residuais. A rede possui 103.329 parâmetros treináveis. As Figuras 4.6 e 4.7 apresentam um resumo da arquitetura da rede

Para treino, foram utilizados pares de imagens 180x180, sendo um senograma corrompido por metal e o outro não. Foi utilizado um *batchsize* = 16 e *learning rate* =  $2 \times 10^{-4}$ . O modelo foi treinado três vezes utilizando diferentes funções custos, são elas: MSE; MSE + PL; e SSIM. O erro da validação era avaliado em cada época e se houvessem vinte épocas sem este variar mais do que  $1 \times 10^{-3}$ , o treinamento era parado de forma automática.

Figura 4.6 – Arquitetura do Encoder.

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	[(None, 180, 180, 1)]	0
conv2d (Conv2D)	(None, 176, 176, 32)	832
re_lu (ReLU)	(None, 176, 176, 32)	0
conv2d_1 (Conv2D)	(None, 172, 172, 32)	25632
re_lu_1 (ReLU)	(None, 172, 172, 32)	0
conv2d_2 (Conv2D)	(None, 168, 168, 32)	25632
re_lu_2 (ReLU)	(None, 168, 168, 32)	0
conv2d_3 (Conv2D)	(None, 164, 164, 32)	25632
re_lu_3 (ReLU)	(None, 164, 164, 32)	0
conv2d_4 (Conv2D)	(None, 160, 160, 32)	25632
re_lu_4 (ReLU)	(None, 160, 160, 32)	0
Total params: 103,360		
Trainable params: 103,360		
Non-trainable params: 0		

Fonte: Elaborada pelo Autor (2020).

Figura 4.7 – Arquitetura do Decoder.

Layer (type)	Output Shape	Param #	Connected to
input_6 (InputLayer)	[(None, 160, 160, 32) 0		
conv2d_transpose (Conv2DTranspo	(None, 164, 164, 32) 0	25632	input_6[0][0]
input_5 (InputLayer)	[(None, 164, 164, 32) 0		
add_1 (Add)	(None, 164, 164, 32) 0		conv2d_transpose[0][0] input_5[0][0]
re_lu_5 (ReLU)	(None, 164, 164, 32) 0		add_1[0][0]
conv2d_transpose_1 (Conv2DTrans	(None, 168, 168, 32) 0	25632	re_lu_5[0][0]
re_lu_6 (ReLU)	(None, 168, 168, 32) 0		conv2d_transpose_1[0][0]
conv2d_transpose_2 (Conv2DTrans	(None, 172, 172, 32) 0	25632	re_lu_6[0][0]
input_4 (InputLayer)	[(None, 172, 172, 32) 0		
add (Add)	(None, 172, 172, 32) 0		conv2d_transpose_2[0][0] input_4[0][0]
re_lu_7 (ReLU)	(None, 172, 172, 32) 0		add[0][0]
conv2d_transpose_3 (Conv2DTrans	(None, 176, 176, 32) 0	25632	re_lu_7[0][0]
re_lu_8 (ReLU)	(None, 176, 176, 32) 0		conv2d_transpose_3[0][0]
conv2d_transpose_4 (Conv2DTrans	(None, 180, 180, 1) 0	801	re_lu_8[0][0]
input_3 (InputLayer)	[(None, 180, 180, 1) 0		
weighted_add (WeightedAdd)	(None, 180, 180, 1) 0		conv2d_transpose_4[0][0] input_3[0][0]
re_lu_9 (ReLU)	(None, 180, 180, 1) 0		weighted_add[0][0]
Total params: 103,329			

Fonte: Elaborada pelo Autor (2020).

#### 4.2.2 Substituição por valores vizinhos e interpolação linear

Para fins de comparação, foram utilizados outros dois métodos de redução de artefatos. A literatura mostra que os métodos mais utilizados para a redução de artefatos metálicos correspondem aos métodos de complementação do senograma, conforme descrito na Seção 3.2. Dentre estes, pode-se citar modelos matemáticos de substituição dos valores vizinhos corrompidos pelo metal (GJESTEBY et al., 2016) e o método de interpolação linear (KALENDER, 2011). Neste trabalho, o método matemático de substituição de valores vizinhos utilizado corresponde a capturar em cada projeção valores maiores que um *Threshold*, sendo este igual a 2,5 vezes o valor médio entre todas as atenuações naquela projeção, juntar os valores sequenciais em um vetor e substituí-los pela média aritmética entre os três valores anteriores e os três valores posteriores a este vetor.



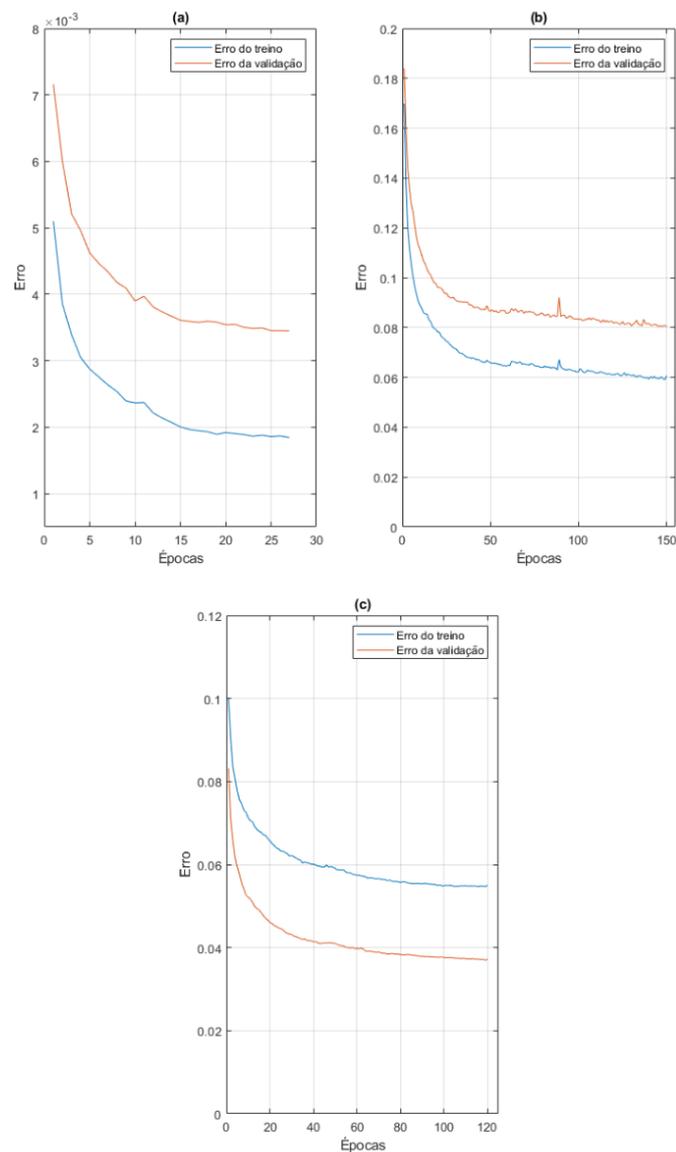
## 5 RESULTADOS E DISCUSSÕES

Neste trabalho são apresentados resultados experimentais de um método proposto para redução de artefatos gerados por objetos metálicos em CT.

### 5.1 Treinamento da Rede

A partir do treinamento da rede, obteve-se os gráficos de Erro x Épocas para as três funções custos utilizadas: MSE, MSE + PL, SSIM, conforme demonstrado na Figura 5.1.

Figura 5.1 – Gráfico Erro x Épocas das seguintes funções custo: (a) MSE, (b) MSE + PL e (c) SSIM



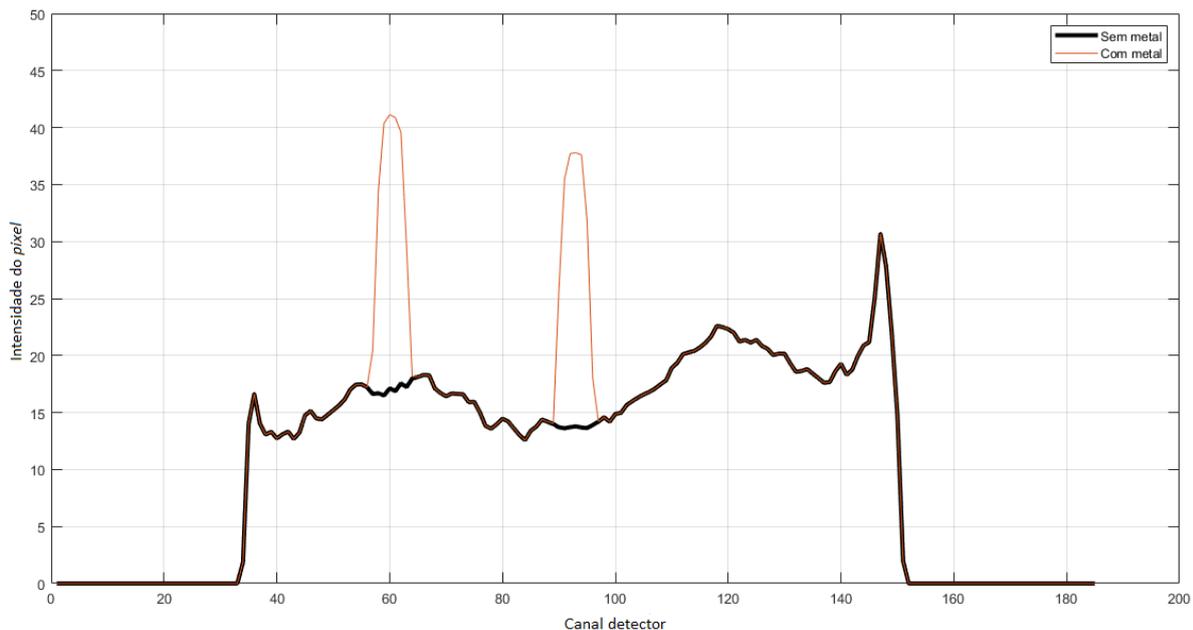
Fonte: Elaborada pelo Autor (2020).

A partir dos gráficos obtidos pode-se perceber que os treinos convergiram com quantidades de épocas diferentes. Para a função custo MSE, convergiu com 27 épocas, MSE + PL em torno de 150 épocas e SSIM com 120 épocas. O gráfico épocas x erro foi construído utilizando a média da *loss* em um *Batch* no treino e um *Batch* na validação. É possível observar que o modelo melhorou ao longo do treino, e que os pesos utilizado para os testes seguintes foram salvos quando o erro do treino e o erro da validação estavam estáveis, excedendo o critério de parada determinado na Seção 4.2.1.

## 5.2 Análise das Projeções para um ângulo fixo

Para analisar melhor a ação dos métodos de redução de artefatos metálicos no senograma, é interessante observar as projeções para um determinado valor fixo, nesse caso, para  $\theta = 90^\circ$ . A Figura 5.2 representa a comparação entre o senograma com metal circular e o senograma sem metal.

Figura 5.2 – Projeções para  $\theta = 90^\circ$  do senograma c/ metal e senograma s/ metal



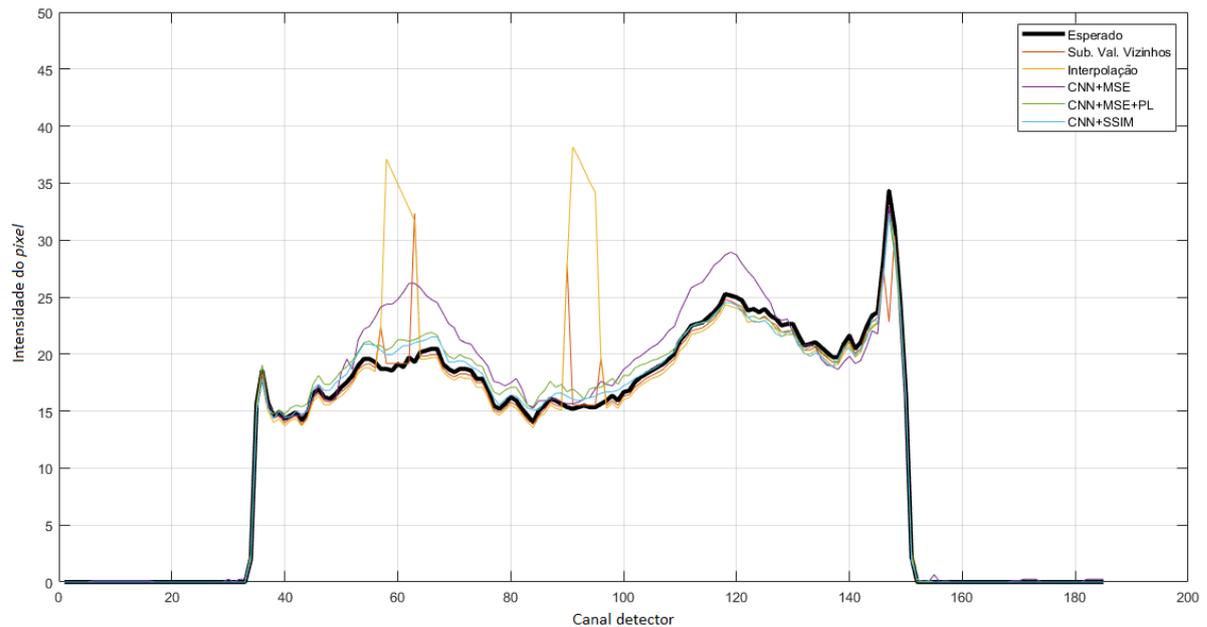
Fonte: Elaborada pelo Autor (2020).

Esses picos observados em torno dos canais 60 e 90 representam a presença de metal. A Figura 5.3 mostra as projeções para o mesmo valor de  $\theta = 90^\circ$  nos senogramas corrigidos pelos métodos comparando ao senograma sem metal.

A partir da comparação entre os gráficos com correções pelos métodos propostos e o gráfico de referência do senograma sem metal, é possível observar que os senogramas corrigidos pela rede neural apresentaram um melhor resultado. Tanto o método de substituição por valores vizinhos quanto o método de interpolação, reduziram um pouco a intensidade do metal, mas

apresentam valores ruidosos nesses canais. A substituição de uma quantidade de valores acima do *threshold* por um único valor irá gerar alterações bruscas nas projeções. Um outro motivo para esses "impulsos" que apareceram na Figura 5.3 pode ser o fato de que o *threshold* pode não ter englobado todos os valores que representam projeções metálicas.

Figura 5.3 – Projeções para  $\theta = 90^\circ$  do senograma corrigido pelos métodos comparado ao senograma sem metal



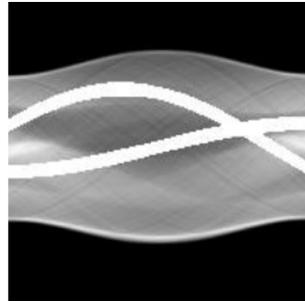
Fonte: Elaborada pelo Autor (2020).

As correções no senograma pela rede neural se aproximam mais da imagem de referência, apresentando curvas mais suaves e valores de projeções mais próximos do esperado. Dentre elas, a MSE fica um pouco mais distante das redes com MSE + PL e SSIM, sendo estas detentoras do melhor resultado. Este resultado é visualmente muito parecido e ficará mais claro quando aplicadas as métricas de qualidade presentes nas próximas sessões. Vale ressaltar também que o resultado é apenas para o senograma com metais circulares, já que para o senograma com metais elípticos as diferenças nas respostas foram mínimas.

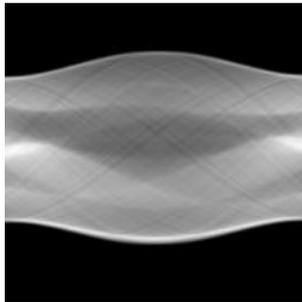
### 5.3 Senogramas corrigidos e reconstruções

Essa seção apresenta os senogramas corrigidos pelos métodos propostos e os *phantoms* com metais circulares e elípticos reconstruídos. As figuras 5.4 e 5.6 apresentam os (a) senogramas que geram artefato, (b) senogramas do *phantom sem metal* e os senogramas resultantes dos métodos propostos. As Figuras 5.5 e 5.7 demonstram os resultados das aplicações do método de reconstrução FBP nos senogramas apresentados.

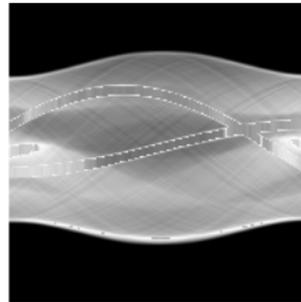
Figura 5.4 – São apresentados os seguintes senogramas (a) do *phantom* com metais circulares, (b) do *phantom* referência s/ metal, (c) corrigido por substituição dos valores vizinhos, (d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM



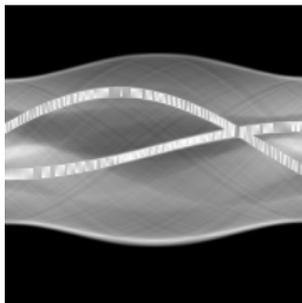
(a) Corrompida



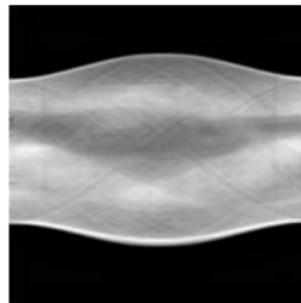
(b) Referência



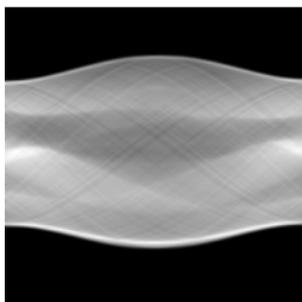
(c) Sub. Val. Vizinhos



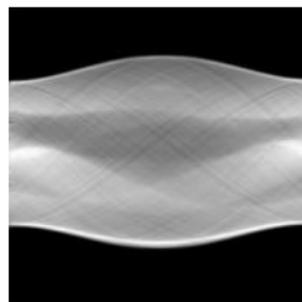
(d) Interpolação



(e) CNN + MSE

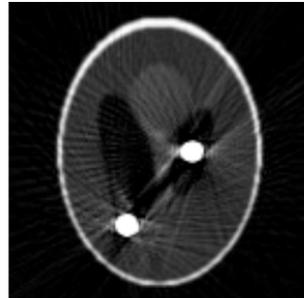


(f) CNN + MSE + PL

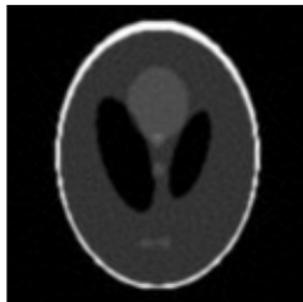


(g) CNN + SSIM

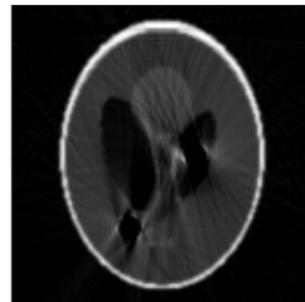
Figura 5.5 – São apresentados os seguintes *phantoms*: (a) com metais circulares, (b) referência s/ metal, (c) corrigido por substituição dos valores vizinhos, (d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM



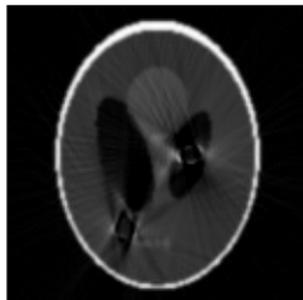
(a) Corrompida



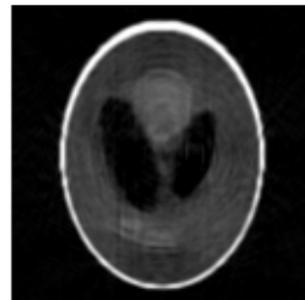
(b) Referência



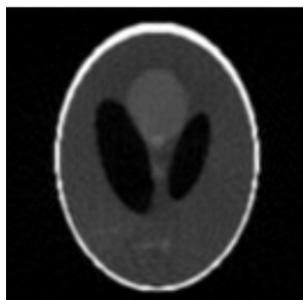
(c) Sub. Val. Vizinhos



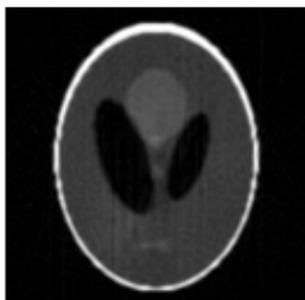
(d) Interpolação



(e) CNN + MSE

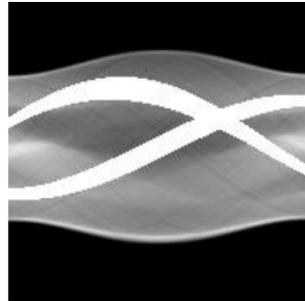


(f) CNN + MSE + PL

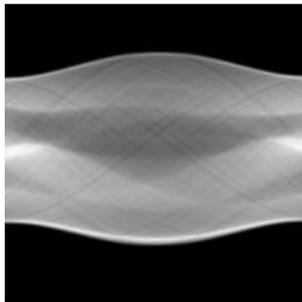


(g) CNN + SSIM

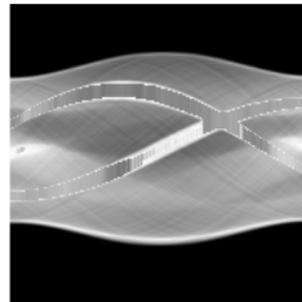
Figura 5.6 – São apresentados os seguintes senogramas (a) do *phantom* com metais elípticos, (b) do *phantom* referência s/ metal, (c) corrigido por substituição dos valores vizinhos, (d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM



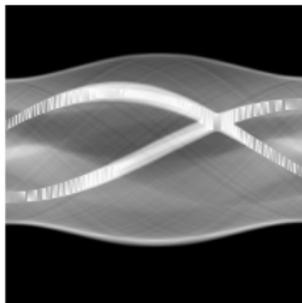
(a) Corrompida



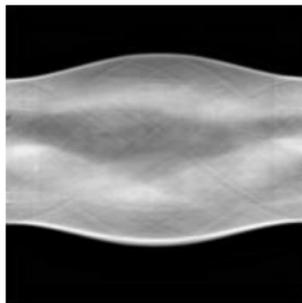
(b) Referência



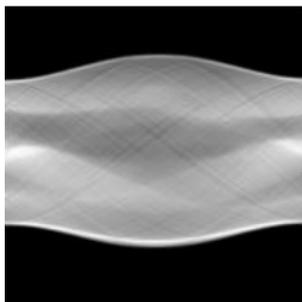
(c) Sub. Val. Vizinhos



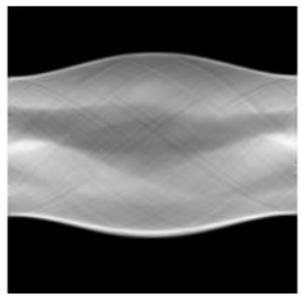
(d) Interpolação



(e) CNN + MSE

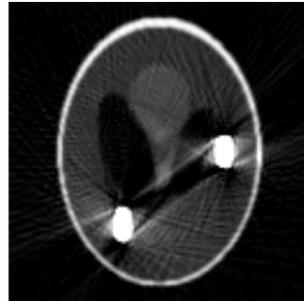


(f) CNN + MSE + PL

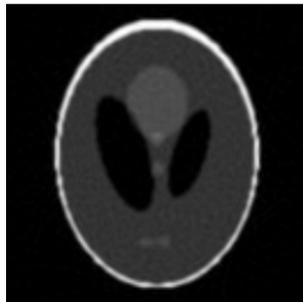


(g) CNN + SSIM

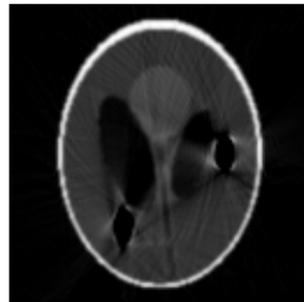
Figura 5.7 – São apresentados os seguintes *phantoms*: (a) com metais elípticos, (b) referência s/ metal, (c) corrigido por substituição dos Valores Vizinhos, (d) corrigido por interpolação, (e) corrigido pela rede c/ MSE, (f) corrigido pela rede c/ MSE + PL, (g) corrigido pela rede c/ SSIM



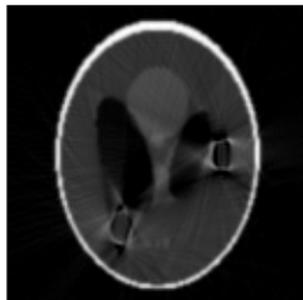
(a) Corrompida



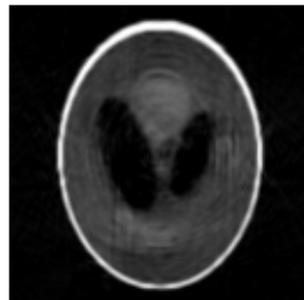
(b) Referência



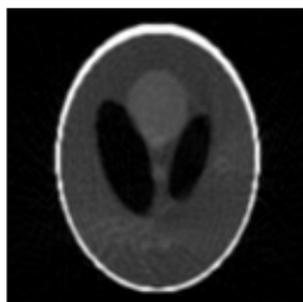
(c) Sub. Val. Vizinhos



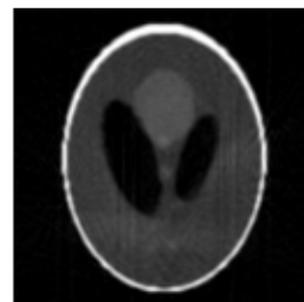
(d) Interpolação



(e) CNN + MSE



(f) CNN + MSE + PL



(g) CNN + SSIM

A partir das Figuras apresentadas é possível fazer algumas análises visuais. Os senogramas que apresentaram mais resquícios dos metais que estavam ali presentes foram os corrigidos pelos métodos de substituição de valores por vizinhança e interpolação, independente do formato do metal do *phantom*. Consequentemente, as reconstruções desse método estão visualmente corrompidas por ausência de informação nos lugares em que havia o metal. Em torno desses locais é possível ainda notar a presença de alguns artefatos metálicos. No lugar em que o metal estava presente, há ausência de informação, sendo predominantemente dominado pela cor preta no método de substituição e por níveis de cinza variados nos métodos de interpolação.

Analisando os senogramas corrigidos pelas redes neurais é possível afirmar que a função custo MSE, apesar de remover as listras brancas referente ao metal, acabou "borrando" o senograma e consequentemente, sua reconstrução apresentou um resultado mais distante da figura de referência. Quando combinado com a função custo PL, o resultado se torna muito mais próximo do esperado. Resultado este também observado na imagem corrigida pela rede com SSIM, sendo visualmente complicado de diferenciar qual imagem apresentou o melhor resultado. Os senogramas referentes à estes dois métodos citados anteriormente estão praticamente sem nenhuma listra de metal e, visualmente, suas reconstruções não apresentam artefatos.

É interessante ressaltar que, os metais circulares e elípticos apresentaram resultados distintos nas metodologias sem o uso da rede neural, sendo que os metais elípticos estão mais presentes nos senogramas e reconstruções. A rede apresentou praticamente os mesmos resultados independente do formato do metal presente.

## 5.4 Métricas de qualidade

As Tabelas 5.1, 5.2 e 5.3 mostram os resultados obtidos das métricas entre as reconstruções corrigidas pelos métodos e a reconstrução do *phantom* de referência. Nas três tabelas, a primeira linha refere-se às métricas aplicadas entre a reconstrução do *phantom* corrompido por metal e a imagem de referência, apenas para facilitar a visualização dos resultados. As tabelas apresentam o valor da média e do intervalo de confiança considerando um nível de confiança de 95%. A Tabela 5.1 corresponde aos valores MSE, a Tabela 5.2 aos valores de PSNR e a Tabela 5.3 aos valores de SSIM:

Tabela 5.1 – MSE entre as reconstruções corrigidas e a reconstrução de referência.

Método	Média	Intervalo de confiança
<i>Phantom</i> com Metal	0,2313	[0.2277; 0.2348]
Subst. Val. Vizinhança	0,0179	[0.01763; 0.01817]
Interpolação	0,0169	[0.01665; 0.01715]
CNN + MSE	0,0027	[0.00267; 0.00273]
CNN + MSE + PL	0,0021	[0.00205; 0.00215]
CNN + SSIM	<b>0,0015</b>	[0.00146; 0.00154]

Fonte: Elaborada pelo Autor (2020).

Tabela 5.2 – PSNR entre as reconstruções corrigidas e a reconstrução de referência.

Método	Média [dB]	Intervalo de confiança
<i>Phantom</i> com Metal	7,82	[7.743; 7.897]
Subst. Val. Vizinhança	18,72	[18.663; 18.777]
Interpolação	18,73	[18.671; 18.789]
CNN + MSE	26,06	[26.025; 26.094]
CNN + MSE + PL	28,29	[28.222; 28.359]
CNN + SSIM	<b>29,58</b>	[29.518; 29.642]

Fonte: Elaborada pelo Autor (2020).

Tabela 5.3 – SSIM entre as reconstruções corrigidas e a reconstrução de referência.

Método	Média	Intervalo de confiança
<i>Phantom</i> com Metal	0,2339	[0.23083; 0.23497]
Subst. Val. Vizinhança	0,4634	[0.46094; 0.46586]
Interpolação	0,4949	[0.49278; 0.49702]
CNN + MSE	0,7014	[0.70019; 0.70261]
CNN + MSE + PL	0,8020	[0.80057; 0.80343]
CNN + SSIM	<b>0,8246</b>	[0.82324; 0.82596]

Fonte: Elaborada pelo Autor (2020).

A partir da análise da tabela é possível confirmar que os valores corroboram com a análise visual feita anteriormente. A partir da tabela 5.1, é possível afirmar que todos os métodos conseguiram reduzir os artefatos na reconstrução, sendo que o método proposto obteve os melhores resultados. Dentre as funções custo, a MSE combinada com a PL obteve um resultado melhor do que a MSE sozinha. A melhor média foi obtida a partir da rede com SSIM.

A mesma análise que a anterior pode ser observada nas Tabelas 5.2 e 5.3, sendo que estas demonstram que os métodos utilizados na literatura melhoram a qualidade da imagem, mas o método proposto apresenta resultados mais significativos. Uma observação é que, os métodos de substituição por valores vizinhos e interpolação sofriam grandes alterações quando variava-se a quantidade e o coeficiente de absorção dos metais. No método proposto, independente da função custo, a complementação do senograma não passava por grandes alterações variando-se essas características, sendo este um possível fator resultante nesses valores.

Por apresentarem valores de média muito próximos, foi feito um teste *t-student* entre os valores de CNN + MSE + PL e CNN + SSIM. A hipótese nula correspondente é de que, estatisticamente, as médias apresentam valores iguais. O teste feito no *matlab* com a função *ttest* retornou, para as três métricas, um valor igual a 1, rejeitando a hipótese nula. Ou seja, a partir dos dados obtidos, é possível observar que a rede com a função custo SSIM apresentou a melhor performance em todas as métricas utilizadas, apesar destes valores serem muito pró-

ximos dos resultados obtidos pela rede com MSE + PL. Por fim, vale ressaltar que todos os métodos apresentaram resultados melhores do que os observados entre a imagem de referência e a imagem corrompida, comprovando que os artefatos metálicos podem ser reduzidos através da aplicação de métodos de complementação do senograma.

## 6 CONCLUSÃO

Este trabalho propõe desenvolver um método para redução de artefatos gerados por objetos metálicos em imagens de TC. A justificativa do projeto se dá pelo fato de que artefatos metálicos degradam a qualidade das imagens, podendo gerar exames não diagnosticáveis, sendo este um grande problema na área de processamento de imagem e tomografia computadorizada.

Anteriormente, diversos estudos foram realizados para reduzir artefatos. Dentre essas abordagens, existem os métodos que buscam remover o metal e complementar os dados faltantes do senograma com diferentes tratativas, tais como a substituição destes por valores vizinhos, substituição por interpolação e, mais recente, uso de redes neurais para preencher os espaços vazios nas projeções adquiridas.

Os métodos existentes na literatura: por substituição de valores vizinhos e interpolação são simples de serem implementados e apresentaram uma boa redução dos artefatos metálicos. No entanto, a dificuldade de achar um bom valor de *threshold* e a geração de locais de alta frequência nos gráficos das projeções faz com que sejam gerados novos artefatos e/ou não sejam removidos totalmente os valores em torno do metal. Vale ressaltar que estes métodos apresentam uma grande diferença variando um pouco o tamanho do metal. Isto pode ser um problema para imagens que apresentem um número maior de metais com formatos variados.

O método proposto com o uso de redes neurais apresenta resultados satisfatórios, removendo totalmente as listras brancas do senograma. É interessante notar que a função custo altera fortemente os resultados, comprovada por exemplo da função custo MSE apresentar um resultado abaixo das outras duas. No entanto, quando combinada com a PL, apresentou melhores resultados podendo comparar-se com a SSIM. Importante também citar o fato de que os resultados não tiveram grandes variações com a mudança do formato do metal, fator que pode ser importante para aplicações em outras imagens.

Apesar da melhora obtida nos resultados, é difícil determinar ao certo qual função custo utilizar e qual a significância clínica dos métodos empregados. Isso pelo fato de que, para treinar a rede, é necessário um volume muito grande de imagens. Um outro problema é que, nos métodos de complementar as projeções, por remover totalmente o metal da imagem, perde-se quaisquer informações sobre ele no exame, podendo este ser um dado importante para a aplicação clínica em questão.

Como trabalhos futuros, sugerem-se: uma investigação mais aprofundada nas diversas funções custos e suas combinações para o treino da rede neural, visto que é evidente a diferença de resultado que isto acarreta; trabalhar o desenvolvimento de imagens sintéticas que representem cada vez mais uma reprodução fiel dos tecidos do corpo; um estudo nas novas arquiteturas de redes neurais propostas; estudo utilizando a rede adversária generativa, do inglês: *Generative*

*Adversarial Networks* (GAN); e por fim, treinar a rede proposta com imagens clínicas, inserindo metal artificialmente em imagens não corrompidas e aplicar a rede treinada em imagens reais.

## REFERÊNCIAS

- AUGUST, J.; KANADE, T. Fast streaking artifact reduction in ct using constrained optimization in metal masks. In: SPRINGER. **International Conference on Medical Image Computing and Computer-Assisted Intervention**. [S.l.], 2004. p. 1044–1045.
- AZEVEDO, B.; LEE, R.; SHINTAKU, W.; NOUJEIM, M.; NUMMIKOSKI, P. Influence of the beam hardness on artifacts in cone-beam ct. **Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology and Endodontology**, v. 4, n. 105, p. e48, 2008.
- BAL, M.; CELIK, H.; SUBRAMANYAN, K.; ECK, K.; SPIES, L. A radial adaptive filter for metal artifact reduction. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Medical Imaging 2005: Image Processing**. [S.l.], 2005. v. 5747, p. 2075–2082.
- BARRETT, J. F.; KEAT, N. Artifacts in ct: recognition and avoidance. **Radiographics**, Radiological Society of North America, v. 24, n. 6, p. 1679–1691, 2004.
- BELEDELLI, R.; SOUZA, P. H. C. O que são e como se formam os artefatos nas imagens da tomografia computadorizada de feixe cônico. **Revista ABRO**, v. 13, n. 1, p. 2–15, 2012.
- BRUYANT, P. P.; SAU, J.; MALLET, J.-J. Streak artifact reduction in filtered backprojection using a level line–based interpolation method. **Journal of Nuclear Medicine**, Soc Nuclear Med, v. 41, n. 11, p. 1913–1919, 2000.
- CLAUS, B. E.; JIN, Y.; GJESTEBY, L. A.; WANG, G.; MAN, B. D. Metal-artifact reduction using deep-learning based sinogram completion: Initial results. **Fully3D 2017 Proceedings**, p. 631–635, 2017.
- DEÁK, Z.; GRIMM, J. M.; TREITL, M.; GEYER, L. L.; LINSENMAIER, U.; KÖRNER, M.; REISER, M. F.; WIRTH, S. Filtered back projection, adaptive statistical iterative reconstruction, and a model-based iterative reconstruction in abdominal ct: an experimental clinical study. **Radiology**, Radiological Society of North America, Inc., v. 266, n. 1, p. 197–206, 2013.
- DRAENERT, F.; COPPENRATH, E.; HERZOG, P.; MULLER, S.; MUELLER-LISSE, U. Beam hardening artefacts occur in dental implant scans with the newtom® cone beam ct but not with the dental 4-row multidetector ct. **Dentomaxillofacial Radiology**, British Institute of Radiology, v. 36, n. 4, p. 198–203, 2007.
- GARIB, D. G.; JR, R. R.; RAYMUNDO, M. V.; RAYMUNDO, D. V.; FERREIRA, S. N. Tomografia computadorizada de feixe cônico (cone beam): entendendo este novo método de diagnóstico por imagem com promissora aplicabilidade na ortodontia. **Revista Dental Press de Ortodontia e Ortopedia Facial**, SciELO Brasil, v. 12, n. 2, p. 139–156, 2007.
- GHANI, M. U.; KARL, W. C. Deep learning based sinogram correction for metal artifact reduction. **Electronic Imaging**, Society for Imaging Science and Technology, v. 2018, n. 15, p. 472–1, 2018.
- GJESTEBY, L.; MAN, B. D.; JIN, Y.; PAGANETTI, H.; VERBURG, J.; GIANTSOUDI, D.; WANG, G. Metal artifact reduction in ct: where are we after four decades? **Ieee Access**, IEEE, v. 4, p. 5826–5849, 2016.

GJESTEBY, L.; SHAN, H.; YANG, Q.; XI, Y.; CLAUS, B.; JIN, Y.; MAN, B. D.; WANG, G. Deep neural network for ct metal artifact reduction with a perceptual loss function. In: **In Proceedings of The Fifth International Conference on Image Formation in X-ray Computed Tomography**. [S.l.: s.n.], 2018. v. 1.

GJESTEBY, L.; YANG, Q.; XI, Y.; CLAUS, B.; JIN, Y.; MAN, B. D.; WANG, G. Reducing metal streak artifacts in ct images via deep learning: Pilot results. In: **The 14th international meeting on fully three-dimensional image reconstruction in radiology and nuclear medicine**. [S.l.: s.n.], 2017. v. 14, n. 6, p. 611–614.

GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: **Proceedings of the fourteenth international conference on artificial intelligence and statistics**. [S.l.: s.n.], 2011. p. 315–323.

GOLDMAN, L. W. Principles of ct: radiation dose and image quality. **Journal of Nuclear Medicine technology**, Soc Nuclear Med, v. 35, n. 4, p. 213–225, 2007.

GOMPEL, G. V.; SLAMBROUCK, K. V.; DEFRISE, M.; BATENBURG, K. J.; MEY, J. de; SIJBERS, J.; NUYTS, J. Iterative correction of beam hardening artifacts in ct. **Medical Physics**, Wiley Online Library, v. 38, n. S1, p. S36–S49, 2011.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. [S.l.]: Editora Blucher, 2000.

GOODFELLOW, I.; WARDE-FARLEY, D.; MIRZA, M.; COURVILLE, A.; BENGIO, Y. Proceedings of the 30th international conference on machine learning. 2013.

GUILFOILE, C.; RAMPANT, P.; HOUSE, M. The impact of smart metal artefact reduction algorithm for use in radiotherapy treatment planning. **Australasian physical & engineering sciences in medicine**, Springer, v. 40, n. 2, p. 385–394, 2017.

HARAMATI, N.; STARON, R. B.; MAZEL-SPERLING, K.; FREEMAN, K.; NICKOLOFF, E. L.; BARAX, C.; FELDMAN, F. Ct scans through metal scanning technique versus hardware composition. **Computerized Medical Imaging and Graphics**, Elsevier, v. 18, n. 6, p. 429–434, 1994.

HENRICH, G. A simple computational method for reducing streak artifacts in ct images. **Computerized tomography**, Elsevier, v. 4, n. 1, p. 67–71, 1980.

HSIEH, J. Adaptive streak artifact reduction in computed tomography resulting from excessive x-ray photon noise. **Medical Physics**, Wiley Online Library, v. 25, n. 11, p. 2139–2147, 1998.

\_\_\_\_\_. **Computed tomography: principles, design, artifacts, and recent advances**. [S.l.]: SPIE press, 2003. v. 114.

JÚNIOR, E. A.; YAMASHITA, H. Aspectos básicos de tomografia computadorizada e ressonância magnética. **Brazilian Journal of Psychiatry**, SciELO Brasil, v. 23, p. 2–3, 2001.

KAK, A. C.; SLANEY, M.; WANG, G. **Principles of computerized tomographic imaging**. [S.l.]: Wiley Online Library, 2002.

KALENDER, W. A. **Computed tomography: fundamentals, system technology, image quality, applications**. [S.l.]: John Wiley & Sons, 2011.

- KATSURA, M.; SATO, J.; AKAHANE, M.; KUNIMATSU, A.; ABE, O. Current and novel techniques for metal artifact reduction at ct: practical guide for radiologists. **Radiographics**, Radiological Society of North America, v. 38, n. 2, p. 450–461, 2018.
- KILBY, W.; SAGE, J.; RABETT, V. Tolerance levels for quality assurance of electron density values generated from ct in radiotherapy treatment planning. **Physics in Medicine & Biology**, IOP Publishing, v. 47, n. 9, p. 1485, 2002.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Communications of the ACM**, ACM New York, NY, USA, v. 60, n. 6, p. 84–90, 2017.
- KUBICEK, J.; REHACEK, T.; PENHAKER, M.; BRYJOVA, I. Software simulation of ct reconstructions and artifacts. In: SPRINGER. **ICCASA**. [S.l.], 2015. p. 428–437.
- KUTEKEN, F.; PENHA, N.; SIMÕES, A. C.; GOISMAN, S. Artefato metálico em tomografia computadorizada de feixe cônico. **Revista de Odontologia da Universidade Cidade de São Paulo**, v. 27, n. 3, p. 220–228, 2017.
- LANGLAIS, R.; LANGLAND, O.; NORTJÉ, C. Decision making in dental radiology. **Diagnostic Imaging of the Jaws**. Baltimore: Williams & Wilkins, p. 1–17, 1995.
- LEAO, M.; MACEDO, V. Comparação entre os métodos analítico e iterativo na reconstrução de imagens tomográficas. In: **XXIV Congresso Brasileiro de Engenharia Biomédica**. Uberlândia: Canal. [S.l.: s.n.], 2014. v. 6.
- LIANG, M.; HU, X. Recurrent convolutional neural network for object recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2015. p. 3367–3375.
- LOUBELE, M.; MAES, F.; JACOBS, R.; STEENBERGHE, D. van; WHITE, S.; SUETENS, P. Comparative study of image quality for msct and cbct scanners for dentomaxillofacial radiology applications. **Radiation protection dosimetry**, Oxford University Press, v. 129, n. 1-3, p. 222–226, 2008.
- MAHNKEN, A. H.; RAUPACH, R.; WILDBERGER, J. E.; JUNG, B.; HEUSSEN, N.; FLOHR, T. G.; GÜNTHER, R. W.; SCHALLER, S. A new algorithm for metal artifact reduction in computed tomography: in vitro and in vivo evaluation after total hip replacement. **Investigative Radiology**, LWW, v. 38, n. 12, p. 769–775, 2003.
- MAI, Q.; WAN, J. W. Metal artifacts reduction in ct scans using convolutional neural network with ground truth elimination. In: **IEEE. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)**. [S.l.], 2020. p. 1319–1322.
- MAN, B. D.; NUYTS, J.; DUPONT, P.; MARCHAL, G.; SUETENS, P. Reduction of metal streak artifacts in x-ray computed tomography using a transmission maximum a posteriori algorithm. **IEEE Transactions on Nuclear Science**, IEEE, v. 47, n. 3, p. 977–981, 2000.
- \_\_\_\_\_. An iterative maximum-likelihood polychromatic algorithm for ct. **IEEE transactions on medical imaging**, IEEE, v. 20, n. 10, p. 999–1008, 2001.
- MAO, X.; SHEN, C.; YANG, Y.-B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2016. p. 2802–2810.

MEYER, E.; RAUPACH, R.; LELL, M.; SCHMIDT, B.; KACHELRIESS, M. Normalized metal artifact reduction (nmar) in computed tomography. **Medical Physics**, Wiley Online Library, v. 37, n. 10, p. 5482–5493, 2010.

\_\_\_\_\_. Frequency split metal artifact reduction (fsmar) in computed tomography. **Medical Physics**, Wiley Online Library, v. 39, n. 4, p. 1904–1916, 2012.

MIKI, K.; MORI, S.; HASEGAWA, A.; NAGANAWA, K.; KOTO, M. Single-energy metal artefact reduction with ct for carbon-ion radiation therapy treatment planning. **The British Journal of Radiology**, The British Institute of Radiology., v. 89, n. 1062, p. 20150988, 2016.

MOON, S. G.; HONG, S. H.; CHOI, J.-Y.; JUN, W. S.; KANG, H.-G.; KIM, H.-S.; KANG, H. S. Metal artifact reduction by the alteration of technical factors in multidetector computed tomography: a 3-dimensional quantitative assessment. **Journal of Computer Assisted Tomography**, LWW, v. 32, n. 4, p. 630–633, 2008.

MORIN, R. L.; RAESIDE, D. A pattern recognition method for the removal of streaking artifact in computed tomography. **Radiology**, v. 141, n. 1, p. 229–233, 1981.

MOURÃO, A. P. **Tomografia computadorizada: tecnologias e aplicações**. [S.l.]: Difusão Editora, 2018.

MÜLLER, J.; BUZUG, T. M. Spurious structures created by interpolation-based ct metal artifact reduction. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Medical Imaging 2009: Physics of Medical Imaging**. [S.l.], 2009. v. 7258, p. 72581Y.

NIE, F.; HU, Z.; LI, X. An investigation for loss functions widely used in machine learning. **Communications in Information and Systems**, International Press of Boston, v. 18, n. 1, p. 37–52, 2018.

PARK, H. S.; LEE, S. M.; KIM, H. P.; SEO, J. K.; CHUNG, Y. E. Ct sinogram-consistency learning for metal-induced beam hardening correction. **Medical Physics**, Wiley Online Library, v. 45, n. 12, p. 5376–5384, 2018.

PARKS, E. T. Computed tomography applications for dentistry. **Dental Clinics of North America**, v. 44, n. 2, p. 371–394, 2000.

PRINCE, J. L.; LINKS, J. M. **Medical imaging signals and systems**. [S.l.]: Pearson Prentice Hall Upper Saddle River, 2006.

PU, Y.; GAN, Z.; HENAO, R.; YUAN, X.; LI, C.; STEVENS, A.; CARIN, L. Variational autoencoder for deep learning of images, labels and captions. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2016. p. 2352–2360.

RANGAYYAN, R. M.; GORDON, R. Streak preventive image reconstruction with art and adaptive filtering. **IEEE Transactions on Medical Imaging**, IEEE, v. 1, n. 3, p. 173–178, 1982.

RIBEIRO-ROTTA, R. F. Técnicas tomográficas aplicadas à ortodontia: a evolução do diagnóstico por imagens. **Revista Dental Press de Ortodontia e Ortopedia Facial**, SciELO Brasil, v. 9, n. 5, p. 102–156, 2004.

- ROBERTSON, D. D.; WEISS, P. J.; FISHMAN, E. K.; MAGID, D.; WALKER, P. S. Evaluation of ct techniques for reducing artifacts in the presence of metallic orthopedic implants. **Journal of computer assisted tomography**, LWW, v. 12, n. 2, p. 236–241, 1988.
- RODRIGUES, A. F.; VITRAL, R. W. F. Aplicações da tomografia computadorizada na odontologia. **Pesquisa Brasileira em Odontopediatria e Clínica Integrada**, Universidade Estadual da Paraíba, v. 7, n. 3, p. 317–324, 2007.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. **International Conference on Medical image computing and computer-assisted intervention**. [S.l.], 2015. p. 234–241.
- RUPRECHT, A. Oral and maxillofacial radiology: then and now. **The Journal of the American Dental Association**, Elsevier, v. 139, p. S5–S6, 2008.
- SARA, U.; AKTER, M.; UDDIN, M. S. Image quality assessment through fsim, ssim, mse and psnr comparative study. **Journal of Computer and Communications**, Scientific Research Publishing, v. 7, n. 3, p. 8–18, 2019.
- SCARFE, W. C.; FARMAN, A. G. What is cone-beam ct and how does it work? **Dental Clinics of North America**, Elsevier, v. 52, n. 4, p. 707–730, 2008.
- SCHULZE, R.; HEIL, U.; GRO, D.; BRUELLMANN, D.; DRANISCHNIKOW, E.; SCHWANECKE, U.; SCHOEMER, E. Artefacts in cbct: a review. **Dentomaxillofacial Radiology**, The British Institute of Radiology. 36 Portland Place, London, W1B 1AT, v. 40, n. 5, p. 265–273, 2011.
- SILVA, D. d. S. M. Desenvolvimento e avaliação de um algoritmo de redução de artefatos metálicos em tomografia computadorizada para planejamentos radioterápicos. 2019.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.
- SOLTANIAN-ZADEH, H.; WINDHAM, J. P.; SOLTANIANZADEH, J. Ct artifact correction: an image-processing approach. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Medical Imaging 1996: Image Processing**. [S.l.], 1996. v. 2710, p. 477–485.
- SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: a simple way to prevent neural networks from overfitting. **The Journal of Machine Learning Research**, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014.
- VIMIEIRO, R. B.; BORGES, L. R.; VIEIRA, M. A. Open-source reconstruction toolbox for digital breast tomosynthesis. In: SPRINGER. **XXVI Brazilian Congress on Biomedical Engineering**. [S.l.], 2019. p. 349–354.
- WANG, G.; SNYDER, D. L.; O’SULLIVAN, J. A.; VANNIER, M. W. Iterative deblurring for ct metal artifact reduction. **IEEE transactions on medical imaging**, IEEE, v. 15, n. 5, p. 657–664, 1996.
- WATZKE, O.; KALENDER, W. A. A pragmatic approach to metal artifact reduction in ct: merging of metal artifact reduced images. **European Radiology**, Springer, v. 14, n. 5, p. 849–856, 2004.

XUE, H.; ZHANG, L.; XIAO, Y.; CHEN, Z.; XING, Y. Metal artifact reduction in dual energy ct by sinogram segmentation based on active contour model and tv inpainting. In: IEEE. **2009 IEEE Nuclear Science Symposium Conference Record (NSS/MIC)**. [S.l.], 2009. p. 904–908.

YAZDI, M.; BEAULIEU, L. Artifacts in spiral x-ray ct scanners: problems and solutions. **International Journal of Biological and Medical Sciences**, Citeseer, v. 4, n. 3, p. 135–139, 2008.

ZHANG, Y.; YU, H. Convolutional neural network based metal artifact reduction in x-ray computed tomography. **IEEE Transactions on Medical Imaging**, IEEE, v. 37, n. 6, p. 1370–1381, 2018.

ZHANG, Y.; ZHANG, L.; ZHU, X. R.; LEE, A. K.; CHAMBERS, M.; DONG, L. Reducing metal artifacts in cone-beam ct images by preprocessing projection data. **International Journal of Radiation Oncology\* Biology\* Physics**, Elsevier, v. 67, n. 3, p. 924–932, 2007.

ZHAO, H.; GALLO, O.; FROSIO, I.; KAUTZ, J. Loss functions for image restoration with neural networks. **IEEE Transactions on Computational imaging**, IEEE, v. 3, n. 1, p. 47–57, 2016.

ZHOU, C.; ZHAO, Y. E.; LUO, S.; SHI, H.; ZHENG, L.; ZHANG, L. J.; LU, G. Monoenergetic imaging of dual-energy ct reduces artifacts from implanted metal orthopedic devices in patients with fractures. **Academic radiology**, Elsevier, v. 18, n. 10, p. 1252–1257, 2011.