

**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA - PPGE**

Matheus Silva Pestana

**Análise Multicritério da Qualidade de Imagens PET/CT: Uma
Abordagem Quantitativa Baseada em Análise de Componentes
Principais**

**São Luís - MA
28 de Fevereiro de 2025**

MATHEUS SILVA PESTANA

Análise Multicritério da Qualidade de Imagens PET/CT: Uma
Abordagem Quantitativa Baseada em Análise de Componentes
Principais

**Dissertação submetida à Coordenação
do Programa de Pós-Graduação em En-
genharia Elétrica da Universidade Fe-
deral do Maranhão, como parte dos re-
quisitos à obtenção do título de Mestre
em Engenharia Elétrica na Área de Au-
tomação e Controle.**

São Luís, 28 de Fevereiro de 2025

Matheus Silva Pestana

Análise Multicritério da Qualidade de Imagens PET/CT: Uma Abordagem Quantitativa Baseada em Análise de Componentes Principais / Matheus Silva Pestana. – São Luís – MA, 2025- 99 p.

Prof. Dr. Allan Kardec Duailibe Barros Filho

Projeto de Fim de Curso – Universidade Federal do Maranhão , 28/02/2025.

1. Análise de Componentes Principais. 2. PET/CT. 3. Redução dimensional. 4. Radiofármacos. 5. Qualidade de Imagem I. Allan Kardec Duailibe Barros Filho. II. Universidade Federal do Maranhão. III. Programa de Pós-Graduação em Engenharia Elétrica - PPGEE. IV. Análise Multicritério da Qualidade de Imagens PET/CT: Uma Abordagem Quantitativa Baseada em Análise de Componentes Principais

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGEE

MATHEUS SILVA PESTANA

Dissertação apresentada ao Programa de Programa de Pós-Graduação em Engenharia Elétrica - PPGEE da Universidade Federal do Maranhão, como requisito parcial para obtenção do título de Mestre em Área Automação e Controle, sendo aprovada em sua forma final pela banca examinadora:

Orientador: Prof. Dr. Allan Kardec Duailibe
Barros Filho
Universidade Federal do Maranhão - UFMA

Examinador: Prof. Dr. Ewaldo Eder
Carvalho Santana
Universidade Federal do Maranhão - UFMA

Examinador: Prof^a. Dra. Danúbia Soares
Pires
Instituto Federal de Educação Ciência e
Tecnologia do Maranhão - IFMA

São Luís, 28 de Fevereiro de 2025

Agradecimentos

Agradeço ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Maranhão pelo suporte acadêmico e pela oportunidade de desenvolver este trabalho em um ambiente de excelência, que proporcionou o crescimento profissional e científico necessário para a realização desta pesquisa.

Ao Serviço de Medicina Nuclear do Hospital São Domingos, expresso minha profunda gratidão pelo apoio técnico e pela disponibilização de recursos fundamentais para o desenvolvimento deste estudo. O acesso aos dados e o suporte dos profissionais foram essenciais para a concretização deste trabalho.

A todos que, direta ou indiretamente, contribuíram para esta jornada, meu sincero agradecimento.

Resumo

Na presente dissertação observa-se uma metodologia para a modelagem e análise de imagens médicas no formato DICOM provenientes de exames PET/CT, com ênfase na otimização da qualidade das imagens com doses reduzidas de radiofármacos por meio da Análise de Componentes Principais (PCA). A abordagem proposta permite o processamento e a visualização das imagens, bem como a extração e avaliação quantitativa das características principais dos dados, utilizando métricas como PSNR, SSIM, MSE, MAE e diferença de entropia. Essas métricas possibilitam uma análise abrangente, considerando tanto a similaridade visual quanto a preservação de informações e a redução de erros nas reconstruções realizadas. A redução dimensional promovida pelo PCA mostrou-se eficaz ao preservar as principais características estruturais e estatísticas das imagens, resultando em uma representação mais compacta e eficiente dos dados. O uso integrado das métricas de avaliação em um *ranking* combinado destacou variações de qualidade entre diferentes casos, com resultados superiores a 0,8 em diversos pacientes, evidenciando a alta similaridade na preservação das características das imagens originais. Adicionalmente, a inclusão da diferença de entropia proporcionou uma perspectiva complementar às métricas tradicionais, avaliando mudanças no grau de desordem ou complexidade, um aspecto relevante para a interpretação clínica. Como principais contribuições, esta dissertação apresenta uma abordagem integrando PCA e redução de radiofármacos em imagens PET/CT com base na redução dimensional, a aplicação de métricas normalizadas de avaliação de imagem com a proposta de um *ranking* combinado com pesos individuais e a estimativa de métricas para comparação entre análises computacionais e avaliações profissionais. Os resultados destacam a relevância de uma abordagem quantitativa integrada para a análise de imagens médicas, evidenciando o potencial do PCA como ferramenta para pré-processamento e redução de dimensionalidade em PET/CT. Estudos futuros podem investigar a otimização dos pesos das métricas utilizadas no *ranking* combinado e ampliar a aplicação da metodologia a outros contextos clínicos e modalidades de imagem, consolidando sua relevância no processamento de informações biológicas.

Palavras-chave: Análise de Componentes Principais; PET/CT; Redução dimensional; Radiofármacos; Qualidade de Imagem.

Abstract

In this dissertation, a methodology is presented for modeling and analyzing medical images in the DICOM format obtained from PET/CT scans, with an emphasis on optimizing image quality with reduced radiopharmaceutical doses through Principal Component Analysis (PCA). The proposed approach enables image processing and visualization, as well as the extraction and quantitative evaluation of the principal features of the data, using metrics such as PSNR, SSIM, MSE, MAE, and entropy difference. These metrics allow for a comprehensive analysis, considering both visual similarity and the preservation of information while minimizing errors in reconstructed images. The dimensionality reduction performed by PCA proved effective in preserving the main structural and statistical characteristics of the images, resulting in a more compact and efficient data representation. The integrated use of evaluation metrics in a combined ranking highlighted quality variations across different cases, with results exceeding 0.8 in several patients, demonstrating high similarity in preserving the characteristics of the original images. Additionally, the inclusion of entropy difference provided a complementary perspective to traditional metrics, assessing changes in the degree of disorder or complexity—an important aspect for clinical interpretation. As the main contributions, this dissertation presents an approach that integrates PCA and radiopharmaceutical dose reduction in PET/CT images based on dimensionality reduction, the application of normalized image evaluation metrics with a proposed combined ranking using individual weights, and the estimation of metrics for comparison between computational analyses and professional assessments. The results underscore the relevance of an integrated quantitative approach for medical image analysis, highlighting the potential of PCA as a tool for preprocessing and dimensionality reduction in PET/CT. Future studies may explore the optimization of metric weights in the combined ranking and extend the application of the methodology to other clinical contexts and imaging modalities, further establishing its significance in biological information processing.

Keywords: Principal Component Analysis; PET/CT; Dimensionality Reduction; Radiopharmaceuticals; Image Quality.

Lista de ilustrações

Figura 1 – Princípios da Imagiologia PET esquematicamente: a) decaimento radioativo; b) detecção de fótons de coincidência numa janela temporal; c) e d) radiofármaco injetado no doente; e) obtenção do sinograma com os eventos de aniquilação; f) corte coronal reconstruído com a distribuição do radiofármaco pelo corpo, (VALK et al., 2006)	30
Figura 2 – Tipos de Coincidências em PET: (a) coincidência verdadeira; (b) coincidência aleatória; (c) coincidência de dispersão; (d) coincidência múltipla, (JADVAR; PARKER, 2005)	31
Figura 3 – Ilustração dos modos de aquisição: $2D$ à esquerda (com septos) e $3D$ à direita (sem septos). No modo $3D$ a sensibilidade é aumentada comparando com o modo $2D$ porque existe um maior ângulo de aceitação. No entanto, no $3D$ os eventos aleatórios e o tempo morto são maiores, (TOWNSEND, 2008)	32
Figura 4 – Exemplo das múltiplas projeções em diferentes ângulos de um paciente. (A) Orientação de duas projeções paralelas; (B) Sinograma, em que cada linha representa uma projeção a um ângulo diferente. As duas projeções assinaladas em (A) estão também destacadas em (B), (PAPATHANASSIOU et al., 2009)	34
Figura 5 – Modelo cinético do comportamento do FDG: modelo tri-compartimental (BASU et al., 2011).	36
Figura 6 – Plano coronal dividindo o corpo nas porções anterior (frente) e posterior (costas).	50
Figura 7 – Plano sagital dividindo o corpo nas porções esquerda e direita.	51
Figura 8 – Plano axial dividindo o corpo nas porções cranial (superior) e caudal (inferior)	51
Figura 9 – Imagem original de PET/CT do paciente com lesão cancerígena localizada na região estomacal.	76
Figura 10 – Primeira componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.	77
Figura 11 – Segunda componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.	77
Figura 12 – Terceira componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.	78

Figura 13 – Quarta componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.	78
Figura 14 – Imagem reconstruída após a aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena localizada na região estomacal. . . .	79
Figura 15 – Imagem reconstruída do paciente com lesão cancerígena localizada na região estomacal, obtida por meio da aplicação da técnica ORB.	80
Figura 16 – Imagem original do paciente com lesão cancerígena localizada na região renal.	81
Figura 17 – Primeira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.	82
Figura 18 – Segunda componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.	82
Figura 19 – Terceira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.	83
Figura 20 – Quarta componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.	83
Figura 21 – Imagem reconstruída utilizando a abordagem PCA para o paciente com lesão cancerígena localizada na região renal.	84
Figura 22 – Imagem reconstruída com auxílio da técnica PCA e análise ORB para o paciente com lesão cancerígena localizada na região renal.	85
Figura 23 – Imagem original do paciente com lesão cancerígena localizada na região pulmonar.	86
Figura 24 – Primeira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.	87
Figura 25 – Segunda componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.	87
Figura 26 – Terceira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.	88
Figura 27 – Quarta componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.	88
Figura 28 – Imagem reconstruída utilizando a abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.	89
Figura 29 – Imagem reconstruída com auxílio da técnica PCA e análise ORB para o paciente com lesão cancerígena localizada na região pulmonar.	90

Lista de abreviaturas e siglas

^{18}F -FDG - Fluorodeoxiglicose

ACR - American College of Radiology

CP - Componente Principal

CP1 - Primeira Componente Principal

CP2 - Segunda Componente Principal

CT - Tomografia Computadorizada

IAEA - International Atomic Energy Agency

ICRP - Comissão Internacional de Proteção Radiológica

LOR - Linha de Resposta

LSO - Óxido de Lutécio dopado com Cério

MAE - Erro Absoluto Médio

MIP - Projeção de Máxima Intensidade

MSE - Erro Quadrático Médio

NEMA - National Electrical Manufacturers Association

OSEM - Ordered Subset Expectation Maximization

ORB - Oriented FAST and Rotated BRIEF

PCA - Análise de Componentes Principais

PET - Positron Emission Tomography

PET/CT - Positron Emission Tomography/Computed Tomography

PL - Penalized Likelihood (Penalizada Bayesiana)

PSNR - Relação Sinal-Ruído de Pico

RM - Ressonância Magnética

ROI 3D - Região de Interesse Tridimensional

SIFT - Scale-Invariant Feature Transform

SSIM - Índice de Similaridade Estrutural

SUV - Standard Uptake Value

SURF - Speeded-Up Robust Features

TFM - Tubos Fotomultiplicadores

TOF - Tempo de Voo

Lista de símbolos

keV Mil électrons-volt

dB Decibéis

Sumário

1	INTRODUÇÃO	15
1.1	Caracterização da Proposta de Dissertação	19
1.2	Motivação e Relevância	21
1.3	Contribuições da Pesquisa	23
1.4	Trabalhos Relacionados	24
1.5	Objetivos	26
1.5.1	Objetivos Gerais	26
1.5.2	Objetivos Específicos	27
1.6	Organização da Dissertação de Mestrado	27
2	TOMOGRAFIA POR EMISSÃO DE PÓSITRONS	28
2.1	Definição	28
2.2	Princípio Físico	28
2.3	Formação da Imagem PET	31
2.4	Aplicações do PET em Oncologia	33
2.4.1	Uso do PET com ^{18}F -FDG	33
2.4.2	Reconstrução de Imagens PET/CT	34
2.5	Métodos de Avaliação de Imagens	35
2.5.1	CrITÉrios de Interpretação das Imagens	35
2.5.2	Fontes de Erro e Artefatos nas Imagens	35
2.5.3	Quantificação em PET	36
2.6	Equipamento PET	38
3	ANÁLISE DE COMPONENTES PRINCIPAIS	39
3.1	Definição	39
3.2	Matriz de Dados	40
3.2.1	Matriz de Covariância S	40
3.2.1.1	Padronização com média zero e variância unitária	42
3.2.1.2	Padronização com variância unitária e média qualquer	43
3.2.2	Determinação das Componentes Principais	44
3.2.3	Ordenação por Variância Decrescente	45
3.2.4	Preservação da Variância Total	46
3.2.5	Ortogonalidade	46
3.2.6	Contribuição de cada componente principal	46
3.2.7	Interpretação de cada componente	47

4	METODOLOGIA	48
4.1	Processamento de Imagens Médicas	48
4.2	Metodologia Baseada em PCA para Extração de Características	50
4.3	Avaliação Multicritério da Qualidade de Imagem	53
4.3.1	Erro Quadrático Médio (MSE)	53
4.3.2	Erro Absoluto Médio (MAE)	54
4.3.3	Índice de Similaridade Estrutural (SSIM)	54
4.3.4	Relação Sinal-Ruído de Pico (PSNR)	55
4.3.5	Entropia	55
4.3.6	Oriented FAST and Rotated BRIEF	59
4.4	Análise Visual: Resultados e Interpretações	61
4.4.1	Nitidez	61
4.4.2	Contraste	62
4.4.3	Fidelidade de Cores	62
4.4.4	Deteção de Características	62
5	RESULTADOS	64
5.1	Métricas de Avaliação	64
5.1.1	Erro Quadrático Médio (MSE)	64
5.1.2	Erro Absoluto Médio (MAE)	65
5.1.3	Índice de Similaridade Estrutural (SSIM)	66
5.1.4	Relação Sinal-Ruído de Pico (PSNR)	68
5.1.5	Entropia	69
5.2	Avaliação Multicritério da Qualidade de Imagem	70
5.3	Resultados Avaliativo Visuais	72
5.4	Resultados Computacionais Visuais	73
5.4.1	Análise do Paciente 1	74
5.4.2	Análise do Paciente 2	75
5.4.3	Análise do Paciente 3	75
6	CONCLUSÃO	91
6.1	Considerações Finais	91
6.2	Contribuições da Pesquisa	91
6.3	Propostas para Trabalhos Futuros	92
	REFERÊNCIAS	93

1 Introdução

A Medicina Nuclear (MN) é uma especialidade médica que utiliza materiais radioativos para diagnóstico, tratamento e pesquisa de diversas condições de saúde. Essa área integra princípios da Física, Biologia e Medicina para proporcionar informações funcionais e metabólicas dos órgãos e tecidos, diferentemente de outras modalidades de imagem que se concentram principalmente em aspectos anatômicos. O uso de radiofármacos permite visualizar processos fisiológicos em tempo real, proporcionando uma abordagem única para o diagnóstico e monitoramento de doenças, especialmente em Oncologia, Cardiologia e Neurologia, (DANTAS et al., 2020).

Na MN, os radiofármacos consistem em compostos formados pela associação de um radionuclídeo a uma molécula bioativa. Após serem administrados no organismo, esses compostos se distribuem de acordo com sua afinidade biológica, permitindo sua captação em regiões específicas de interesse. O princípio básico da MN reside na detecção da radiação emitida pelos elementos radioativos introduzidos no paciente. Após a administração do radiofármaco, ele percorre o organismo e se acumula em áreas específicas, cuja atividade metabólica pode ser registrada por meio de detectores especializados, resultando na obtenção de imagens diagnósticas. Essas imagens são fundamentais para identificar condições clínicas como câncer, doenças cardíacas e distúrbios endócrinos, (SAHA, 2018).

A radiação emitida pelos radionuclídeos é captada por equipamentos como a câmera gama e o *Positron Emission Tomography* (PET), que produzem imagens funcionais tridimensionais. A escolha adequada do radionuclídeo é um fator crítico para a eficácia dos exames de MN, sendo isótopos como o tecnécio (99m), o iodo (131) e o flúor (18) amplamente utilizados. Esses isótopos possuem características físicas e biológicas ideais, como meia-vida compatível e emissão de radiação apropriada para os detectores empregados nos procedimentos, (MACHADO et al., 2021).

O exame PET destaca-se como uma técnica avançada de imagem funcional, que utiliza radionuclídeos emissores de pósitrons, como o flúor (18). Após a administração de um radiofármaco específico, como o ^{18}F -FDG (fluorodeoxiglicose marcada com flúor (18)), o PET capta a radiação gerada no processo de aniquilação entre pósitrons e elétrons, possibilitando a reconstrução de imagens tridimensionais que refletem o metabolismo celular em diferentes tecidos.

Na prática clínica, o PET tem especial relevância na oncologia, sendo amplamente empregado para a detecção de neoplasias, avaliação da extensão da doença (estadiamento) e monitoramento da resposta ao tratamento. Além disso, a técnica possui aplicações importantes em cardiologia, como na análise da viabilidade miocárdica, e em neurologia,

especialmente no diagnóstico de doenças neurodegenerativas, como o Alzheimer. A MN tem uma ampla gama de aplicações clínicas, incluindo:

- **Cardiologia:** A MN desempenha um papel crucial no diagnóstico e manejo de doenças cardíacas. Exames como a cintilografia de perfusão miocárdica permitem a avaliação do fluxo sanguíneo coronariano e a identificação de isquemia miocárdica. Além disso, técnicas como o PET cardíaco ajudam a diferenciar áreas de miocárdio viável de tecido cicatricial, auxiliando na definição do prognóstico e na escolha de intervenções terapêuticas apropriadas;
- **Oncologia:** A utilização de radiofármacos na detecção precoce e no estadiamento de câncer tem revolucionado o manejo oncológico. O PET/CT com ^{18}F -FDG é amplamente utilizado para identificar focos de neoplasias malignas, avaliar a extensão da doença e monitorar a resposta ao tratamento. Além disso, radiofármacos específicos, como o ^{68}Ga -DOTATATE, são empregados para detectar tumores neuroendócrinos, proporcionando diagnósticos mais precisos e personalizados;
- **Endocrinologia:** A MN é uma ferramenta essencial na avaliação de distúrbios endócrinos. Exames como a cintilografia de tireoide utilizam o iodo (^{123}I) para avaliar a captação e a função tireoidiana, permitindo a detecção de nódulos, hipertireoidismo e câncer de tireoide. Adicionalmente, o uso de *sestamibi* marcado com tecnécio ($^{99\text{m}}\text{Tc}$) auxilia na localização de adenomas da paratireoide, contribuindo para o diagnóstico de hiperparatireoidismo;
- **Neurologia:** A MN é utilizada no diagnóstico e acompanhamento de doenças neurodegenerativas. O PET com ^{18}F -flutemetamol ou ^{11}C -PIB é empregado para detectar placas de beta-amiloide, auxiliando no diagnóstico precoce da doença de Alzheimer. Além disso, o PET com ^{18}F -FDOPA é utilizado para avaliar a função dopaminérgica em pacientes com suspeita de doença de Parkinson, permitindo uma diferenciação mais precisa entre parkinsonismo e outras condições neurológicas;
- **Nefrologia:** A avaliação da função renal por meio da MN é fundamental para o diagnóstico de doenças renais. Exames como a cintilografia renal com DTPA ou MAG3 permitem a análise da taxa de filtração glomerular e da drenagem urinária, auxiliando no diagnóstico de obstruções e na avaliação de função renal residual em pacientes com doença renal crônica;
- **Pneumologia:** A MN é utilizada no diagnóstico de diversas condições pulmonares. A cintilografia pulmonar de ventilação/perfusão (V/Q) é amplamente empregada para o diagnóstico de embolia pulmonar, especialmente em pacientes que não podem ser submetidos a tomografia computadorizada. Além disso, o

PET/CT é utilizado para avaliar nódulos pulmonares, distinguindo entre lesões benignas e malignas, e para o estadiamento de câncer de pulmão;

- **Gastroenterologia:** A MN também encontra aplicação no diagnóstico de doenças gastrointestinais. Exames como a cintilografia de esvaziamento gástrico ajudam a avaliar distúrbios da motilidade gástrica, enquanto a cintilografia de hemorragia digestiva auxilia na localização de sangramentos ativos. Além disso, o uso de radiofármacos na detecção de tumores gastrointestinais tem se mostrado uma ferramenta valiosa na prática clínica;
- **Ortopedia:** A cintilografia óssea é amplamente utilizada para detectar metástases ósseas, fraturas de estresse e infecções ósseas. O PET/CT com $^{18}\text{F-NaF}$ tem demonstrado alta sensibilidade na identificação de lesões ósseas metastáticas, contribuindo para um manejo mais eficaz de pacientes oncológicos;
- **Infectologia:** A MN tem se mostrado eficaz no diagnóstico de infecções ocultas e inflamações. O PET/CT com $^{18}\text{F-FDG}$ é utilizado para identificar focos de infecção, como endocardite, osteomielite e febre de origem indeterminada, proporcionando um diagnóstico mais rápido e preciso;
- **Reumatologia:** A MN auxilia na detecção de inflamações articulares e ósseas. Exames como a cintilografia óssea e o PET/CT são empregados para avaliar condições inflamatórias crônicas, como artrite reumatoide, permitindo um monitoramento mais eficaz da atividade da doença e da resposta ao tratamento;

Os benefícios proporcionados pelos procedimentos de MN geralmente superam os riscos associados à exposição à radiação. A quantidade de radiação utilizada nesses exames é, em grande parte, considerada segura e comparável à emitida em exames convencionais, como radiografias. De acordo com a *International Atomic Energy Agency* (IAEA, 2020), os procedimentos de MN envolvem doses de radiação que estão dentro dos limites aceitáveis para diagnósticos médicos, garantindo uma relação risco-benefício favorável. No entanto, é importante reconhecer que existem riscos potenciais, incluindo reações alérgicas aos radiofármacos utilizados e uma pequena possibilidade de desenvolvimento de câncer a longo prazo em decorrência da exposição à radiação, (SHIELDS et al., 2014).

Com os avanços tecnológicos, a MN tem experimentado significativas melhorias em precisão diagnóstica e segurança. Um dos avanços mais importantes foi a integração de modalidades de imagem, como PET/CT, que combina a imagem funcional gerada pela PET com a informação anatômica detalhada fornecida pela tomografia computadorizada. Esse avanço permite uma análise mais acurada das condições clínicas do paciente, aumentando a precisão diagnóstica e reduzindo a necessidade de procedimentos adicionais, (KENDALL, 1994).

Outro campo que vem se desenvolvendo rapidamente é o da criação de novos radiofármacos. Pesquisas recentes têm se concentrado na identificação de moléculas bioativas que possam ser ligadas a diferentes radionuclídeos, permitindo a detecção precoce de uma ampla variedade de doenças, desde neoplasias até distúrbios neurológicos, (METTLER; GUIBERTEAU, 2018). A introdução de radiofármacos como o ^{68}Ga -DOTATATE, utilizado na detecção de tumores neuroendócrinos, e o ^{18}F -flutemetamol, empregado em estudos de Alzheimer, demonstra o potencial crescente dessa área para diagnósticos mais específicos e menos invasivos, (AKINC et al., 2019).

A segurança nos procedimentos de MN é uma prioridade e requer a aplicação de protocolos rigorosos que garantam a proteção tanto dos pacientes quanto dos profissionais de saúde envolvidos. Entidades internacionais, como a Comissão Internacional de Proteção Radiológica (ICRP), estabelecem diretrizes que visam minimizar os riscos da exposição à radiação, garantindo que os benefícios dos exames superem os riscos potenciais, ICRP (2016). As recomendações incluem o uso de técnicas de proteção radiológica, como a limitação do tempo de exposição, a manutenção de distâncias seguras e o uso de blindagens adequadas, (FRIEDRICH, 2020). Essas medidas são essenciais para assegurar que a prática da MN continue a ser uma ferramenta valiosa e segura no diagnóstico e tratamento de diversas condições médicas.

A MN destaca-se como uma ferramenta indispensável na prática clínica contemporânea, proporcionando benefícios significativos que, quando adequadamente administrados, superam os riscos associados à exposição à radiação. A adoção de medidas de segurança rigorosas e o uso de tecnologias avançadas têm sido essenciais para assegurar a eficácia e a segurança dos procedimentos. Entre as principais inovações tecnológicas, a integração de modalidades híbridas de imagem, como a tomografia por emissão de pósitrons combinada com a tomografia computadorizada (PET/CT), tem ampliado significativamente o escopo diagnóstico, permitindo uma análise mais precisa e detalhada das condições clínicas dos pacientes.

O contínuo desenvolvimento de radiofármacos constitui um dos pilares do avanço da MN. Novos compostos estão sendo pesquisados com o objetivo de aumentar a especificidade e a eficácia diagnóstica, bem como reduzir os riscos associados à exposição à radiação. Radiofármacos como o ^{18}F -FDG, amplamente utilizado em estudos oncológicos, e o ^{68}Ga -DOTATATE, empregado na detecção de tumores neuroendócrinos, são exemplos de como a pesquisa científica tem ampliado as possibilidades diagnósticas e terapêuticas (AKINC et al., 2019). Essa evolução permite não apenas a identificação precoce de diversas patologias, mas também a possibilidade de tratamentos mais direcionados e eficazes, contribuindo para melhores desfechos clínicos.

O avanço contínuo das tecnologias de imagem funcional e molecular reforça o papel central da MN no diagnóstico e monitoramento de diversas doenças. Técnicas

como o PET/CT, que combinam informações funcionais e anatômicas em uma única aquisição, têm se mostrado fundamentais na Oncologia, Cardiologia e Neurologia. Essas modalidades permitem uma avaliação abrangente do paciente, possibilitando a identificação de processos metabólicos anormais antes mesmo de alterações morfológicas se tornarem evidentes. Além disso, a introdução de novos radiofármacos específicos para diferentes tecidos e condições clínicas tem contribuído para a personalização dos cuidados médicos, oferecendo tratamentos mais eficazes e menos invasivos, (AL-AROUJ et al., 2010).

À medida que a pesquisa científica e tecnológica avança, é esperado que a MN continue a expandir seu papel na prática clínica, tornando-se uma ferramenta cada vez mais relevante para o diagnóstico e tratamento de doenças. As inovações contínuas nesse campo possibilitam diagnósticos mais precoces, intervenções terapêuticas mais eficazes e uma redução significativa nos riscos associados. O futuro da MN aponta para a ampliação do uso de tecnologias híbridas de imagem e o desenvolvimento de radiofármacos personalizados, o que permitirá um cuidado ao paciente cada vez mais preciso e direcionado. Com a implementação de protocolos de segurança estabelecidos por entidades como a Comissão Internacional de Proteção Radiológica (ICRP), a prática da MN pode ser realizada de forma segura, garantindo que os benefícios superem os riscos envolvidos, ((ICRP), 2016) ref.

Em síntese, a MN representa um campo em constante evolução, com impacto direto na melhoria dos cuidados de saúde. A contínua pesquisa e desenvolvimento de novas tecnologias e radiofármacos têm ampliado as possibilidades diagnósticas e terapêuticas, tornando os procedimentos mais seguros, eficazes e personalizados. Assim, a expectativa é que essa área continue a desempenhar um papel fundamental na prática médica, contribuindo significativamente para o diagnóstico precoce, a personalização dos tratamentos e a melhora nos desfechos clínicos.

1.1 Caracterização da Proposta de Dissertação

O exame de PET/CT (*Positron Emission Tomography/Computed Tomography*) é amplamente reconhecido como uma ferramenta indispensável na avaliação de pacientes oncológicos, oferecendo uma abordagem integrada que combina informações metabólicas e anatômicas em um único exame. A tomografia por emissão de pósitrons (PET) permite a detecção de alterações metabólicas através da administração de radiofármacos, enquanto a tomografia computadorizada (CT) fornece imagens anatômicas detalhadas, facilitando a localização precisa das áreas de interesse (BOELLAARD et al., 2015).

Dentre os radiofármacos disponíveis, o ^{18}F -FDG (fluordesoxiglicose marcada com flúor-18) é o mais utilizado na prática clínica. O ^{18}F -FDG é um análogo da glicose que se acumula em células com alta taxa de metabolismo glicolítico, característica de muitos

tipos de tumores malignos. Esse radiofármaco permite a identificação de sítios primários de tumor e metástases, além de apresentar uma distribuição fisiológica em tecidos como o cérebro, coração e rins, (BARRINGTON; O'DOHERTY, 2003). Essa característica torna o PET/CT uma ferramenta valiosa para o diagnóstico, estadiamento e monitoramento de diversas neoplasias, como câncer de pulmão, linfomas, melanoma e câncer de mama, (WEBER, 2005).

A avaliação metabólica realizada no PET/CT pode ser qualitativa e quantitativa. A quantificação é realizada por meio do cálculo do *Standard Uptake Value* (SUV), que representa a fração do radiofármaco presente em uma região específica, corrigida pela dose injetada e pelo peso corporal do paciente. O SUV é amplamente utilizado para diferenciar lesões benignas e malignas, avaliar a extensão da doença e monitorar a resposta ao tratamento oncológico, (TEAM et al., 2011). Entretanto, a quantificação do SUV pode ser influenciada por vários fatores, incluindo o protocolo de aquisição da imagem, o tempo decorrido entre a administração do radiofármaco e a obtenção das imagens, e o algoritmo de reconstrução utilizado, (BOELLAARD, 2009).

Para melhorar a precisão e a consistência das medições de SUV, a tecnologia de reconstrução de imagens PET tem evoluído significativamente. O algoritmo *Q.Clear*, baseado na reconstrução iterativa de probabilidade penalizada bayesiana (*Penalized Likelihood, PL*), representa um avanço significativo em relação ao método tradicional de Expectativa-Maximização por Conjuntos Ordenados, do inglês, *Ordered Subset Expectation Maximization*, (OSEM). Enquanto o OSEM pode produzir artefatos e comprometer a precisão das medições de SUV em lesões pequenas, o *Q.Clear* incorpora informações prévias sobre a qualidade da imagem, permitindo uma reconstrução mais precisa e consistente, (YAU; TEOH; VERMA, 2015). Estudos demonstram que o uso do *Q.Clear* melhora a recuperação do contraste em lesões pequenas, aumenta a precisão da quantificação do SUV e reduz a variabilidade interobservador, facilitando a interpretação das imagens PET/CT, (KHIEWVAN et al., 2017).

A precisão na quantificação do SUV é essencial não apenas para o diagnóstico, mas também para o monitoramento do tratamento oncológico. Mudanças no SUV durante o curso do tratamento podem indicar resposta terapêutica, permitindo ajustes precoces na estratégia terapêutica. Por exemplo, uma redução significativa do SUV após o início do tratamento pode indicar uma resposta positiva, enquanto a persistência de valores elevados pode sugerir resistência ao tratamento ou presença de doença residual, (WAHL et al., 2009). Dessa forma, o PET/CT desempenha um papel crucial na medicina personalizada, contribuindo para a tomada de decisões clínicas baseadas em evidências objetivas.

O exame de PET/CT é uma ferramenta essencial na prática oncológica moderna, oferecendo informações valiosas para o diagnóstico, estadiamento e monitoramento de diversas neoplasias. O desenvolvimento de tecnologias avançadas, como o algoritmo *Q.Clear*,

tem melhorado a precisão das medições de SUV, tornando o exame ainda mais eficaz e confiável. À medida que novas pesquisas continuam a explorar maneiras de aprimorar a tecnologia PET/CT, espera-se que essa modalidade de imagem continue a desempenhar um papel central na Oncologia, contribuindo para diagnósticos mais precisos e tratamentos mais eficazes, (BOELLAARD et al., 2015) e (KHIEWVAN et al., 2017).

1.2 Motivação e Relevância

A produção e distribuição do radiofármaco ^{18}F -FDG é um processo complexo e desafiador, que envolve desde a produção em ciclotrons até a logística de transporte para os serviços de MN. O ^{18}F -FDG é um dos radiofármacos mais utilizados em exames de PET/CT, sendo essencial para o diagnóstico e acompanhamento de diversas condições clínicas, especialmente no campo da Oncologia. Entretanto, a natureza radioativa do ^{18}F -FDG, com sua meia-vida de aproximadamente duas horas, apresenta desafios significativos no que diz respeito à logística de transporte e à garantia de uma atividade radioativa adequada para os exames. Esses fatores tornam a otimização do uso do radiofármaco e a adoção de tecnologias avançadas uma necessidade fundamental para melhorar a eficiência dos serviços de MN.

No Brasil, a produção do ^{18}F -FDG é limitada a poucos centros especializados, localizados principalmente em grandes capitais como Brasília-DF e Belo Horizonte-MG. Isso implica que serviços de MN em regiões distantes desses centros produtores, como o Hospital São Domingos, em São Luís-MA, dependem de uma logística bem ajustada para garantir o recebimento do radiofármaco em tempo hábil e com atividade suficiente para realizar os exames. O transporte, predominantemente aéreo, está sujeito a uma série de fatores externos que podem causar atrasos, como condições climáticas, disponibilidade de voos e procedimentos de segurança aeroportuária. Qualquer atraso no transporte pode resultar em uma redução significativa na atividade radioativa do ^{18}F -FDG, impactando diretamente a quantidade de pacientes que podem ser atendidos e, em casos mais graves, levando ao cancelamento de exames previamente agendados.

A relevância desta pesquisa está diretamente relacionada à necessidade de superar esses desafios logísticos, garantindo que os serviços de MN possam oferecer diagnósticos precisos e em tempo adequado. A otimização da atividade administrada de ^{18}F -FDG, bem como a utilização de parâmetros de aquisição e reconstrução de imagens mais eficientes, são medidas fundamentais para maximizar o uso do radiofármaco disponível. Nesse contexto, a adoção de softwares modernos de reconstrução de imagem, como o *Q.Clear*, surge como uma solução promissora. Esse algoritmo de reconstrução iterativa baseado em probabilidade penalizada bayesiana permite obter imagens com maior qualidade diagnóstica e quantificação mais precisa do SUV, mesmo com doses mais baixas de ^{18}F -FDG, (YAU;

TEOH; VERMA, 2015) e (KHIEWVAN et al., 2017).

Além disso, a otimização do tempo de aquisição e da dose administrada é uma estratégia que pode beneficiar diretamente os pacientes oncológicos, que frequentemente necessitam de exames de PET/CT para o diagnóstico e acompanhamento de suas condições. Com a utilização de doses menores de radiofármaco, é possível atender a um número maior de pacientes com o mesmo volume de ^{18}F -FDG disponível, aumentando a eficiência do serviço e reduzindo o risco de cancelamentos por falta de atividade radioativa suficiente. Essa abordagem também contribui para a redução da exposição à radiação, o que é particularmente relevante em pacientes que necessitam de exames repetidos ao longo do tempo.

A literatura científica tem mostrado resultados promissores em relação à eficácia de softwares como o *Q.Clear* na melhoria da qualidade de imagem e na precisão das medições de SUV. Estudos demonstram que a adoção de algoritmos avançados de reconstrução permite obter imagens com maior contraste e resolução, mesmo em condições de baixa atividade administrada, o que é essencial para garantir diagnósticos confiáveis em pacientes oncológicos, (BOELLAARD et al., 2015) e (TEAM et al., 2011). Além disso, a precisão na quantificação do SUV é fundamental para avaliar a resposta ao tratamento e monitorar a progressão da doença, contribuindo para a tomada de decisões clínicas baseadas em evidências objetivas.

Outro ponto importante a ser considerado é a crescente demanda por exames de PET/CT no Brasil e a necessidade de expandir a capacidade dos serviços de MN para atender a essa demanda. A otimização do uso do ^{18}F -FDG e a adoção de tecnologias avançadas são estratégias que podem contribuir significativamente para ampliar a oferta de exames, especialmente em regiões mais distantes dos grandes centros produtores. Dessa forma, esta pesquisa visa não apenas demonstrar a eficácia de novas tecnologias na prática clínica, mas também contribuir para a melhoria do acesso a diagnósticos de alta qualidade em todo o território nacional.

Portanto, a motivação desta pesquisa reside na busca por soluções que possam melhorar a eficiência dos serviços de MN, garantindo diagnósticos precisos e em tempo adequado para um número maior de pacientes. A relevância do estudo é evidenciada pelo impacto direto que essas melhorias podem ter na prática clínica, especialmente no contexto da Oncologia, onde exames de imagem precisos e rápidos são fundamentais para a definição de estratégias terapêuticas e para o acompanhamento da resposta ao tratamento. A utilização de tecnologias como o *Q.Clear* e a otimização dos protocolos de dose e aquisição de imagem representam um avanço importante nesse sentido, contribuindo para o desenvolvimento contínuo da MN no Brasil.

1.3 Contribuições da Pesquisa

A presente pesquisa tem como principal contribuição a aplicação da Análise de Componentes Principais (PCA) na otimização da qualidade de imagens médicas obtidas por exames de Tomografia por Emissão de Pósitrons (PET) utilizando o software *Q.Clear*. A técnica de PCA permite a identificação e eliminação de redundâncias nas variáveis utilizadas na reconstrução das imagens, possibilitando a obtenção de imagens diagnósticas de alta qualidade mesmo quando são administradas doses inferiores de radiofármacos, contribuindo para a segurança dos pacientes e a eficiência dos procedimentos clínicos.

A utilização do PCA na reconstrução de imagens médicas apresenta um diferencial significativo em comparação com os métodos tradicionais, pois permite a redução da dimensionalidade dos dados adquiridos durante os exames, sem comprometer a qualidade diagnóstica das imagens. Esse processo é particularmente relevante na área da MN, onde a administração de doses elevadas de radiofármacos pode representar riscos adicionais à saúde do paciente. Nesse contexto, a aplicação de métodos de redução de dose, aliados a técnicas avançadas de reconstrução de imagem, representa um avanço significativo no aprimoramento das práticas clínicas e na promoção de exames mais seguros e eficazes.

O uso do *Q.Clear* como ferramenta de reconstrução de imagens associada ao PCA permite a obtenção de um SUV (*Standard Uptake Value*) mais preciso e consistente. Isso é crucial para a prática clínica, uma vez que o SUV é amplamente utilizado para a avaliação de resposta terapêutica em pacientes oncológicos. Estudos anteriores demonstram que algoritmos tradicionais de reconstrução, como o OSEM, podem apresentar variações significativas nas medições do SUV, dependendo do tempo de aquisição e do nível de ruído presente nas imagens, (YAU; TEOH; VERMA, 2015) e (KHIEWVAN et al., 2017). O uso de algoritmos avançados, como o *Q.Clear*, aliado à aplicação de técnicas de PCA, busca minimizar essas variações e fornecer resultados mais confiáveis.

Além disso, a presente pesquisa contribui para a literatura acadêmica ao demonstrar a viabilidade de técnicas estatísticas multivariadas, como o PCA, em um campo predominantemente dominado por abordagens baseadas em algoritmos de reconstrução iterativa. Essa abordagem interdisciplinar pode abrir novas possibilidades para o uso de métodos estatísticos em diversas áreas da imagem médica, promovendo avanços na precisão diagnóstica e na personalização dos tratamentos.

Outro aspecto relevante da pesquisa é a avaliação do impacto da redução da dose de radiofármacos na qualidade das imagens obtidas. A redução da dose administrada é uma preocupação constante na prática clínica, especialmente em pacientes pediátricos e em populações mais vulneráveis. A presente pesquisa propõe uma solução que não apenas reduz a dose de radiação, mas também mantém a qualidade diagnóstica das imagens, promovendo exames mais seguros sem comprometer a acurácia dos diagnósticos.

Por fim, a pesquisa também oferece uma contribuição prática ao demonstrar a aplicabilidade do *Q.Clear* em ambientes clínicos reais. Ao validar o uso desse software aliado à técnica de PCA, espera-se que as instituições de saúde possam adotar práticas de reconstrução de imagem mais eficientes e seguras, promovendo uma melhor experiência para os pacientes e resultados mais confiáveis para os profissionais da saúde. Dessa forma, o estudo contribui tanto para o avanço científico quanto para a melhoria das práticas clínicas em MN.

1.4 Trabalhos Relacionados

A combinação de Tomografia por Emissão de Pósitrons com Tomografia Computadorizada tem se consolidado como uma ferramenta essencial na prática clínica, especialmente em Oncologia e Neurologia. Essa fusão de modalidades permite a obtenção de imagens anatômicas e funcionais de alta resolução, o que aprimora a capacidade de diagnóstico e o monitoramento da progressão de doenças, principalmente em estágios iniciais. No câncer de mama, por exemplo, o PET/CT tem mostrado alta sensibilidade na detecção de tumores e metástases, sendo uma alternativa importante para pacientes com diagnósticos inconclusivos por métodos convencionais, (MOON et al., 2023). Além disso, pesquisas recentes têm explorado o uso de técnicas avançadas de segmentação de imagens, como redes neurais convolucionais siamesas, que permitem rastrear lesões com maior precisão, especialmente em pacientes com câncer de próstata metastático, (LIU et al., 2024). A inovação na área também envolve abordagens de fusão multimodal, como a proposta por (SALEHJAHROMI et al., 2024), que utiliza redes de fusão evidencial para integrar dados do PET e CT, minimizando incertezas e melhorando a confiabilidade dos resultados. Em contextos neurológicos, a aplicação do PET/CT com ^{18}F FDG tem sido amplamente estudada para avaliar doenças neurodegenerativas, como demências e Alzheimer, proporcionando insights cruciais sobre os padrões metabólicos cerebrais, (SOUZA; LUCERO, 2024). No entanto, a precisão das imagens ainda enfrenta desafios, principalmente quando se trata de lesões pequenas ou de difícil visualização. Nesse sentido, a arquitetura *mirror-Unet*, proposta por (MARINOV et al., 2023), surgiu como uma solução promissora para a segmentação de lesões em PET/CT, combinando as vantagens das imagens anatômicas e funcionais. Esses avanços tecnológicos não apenas melhoram a acurácia diagnóstica, mas também têm um impacto significativo na personalização do tratamento, contribuindo para a previsão da resposta terapêutica e acompanhamento da evolução clínica de pacientes.

A PCA continua sendo uma das técnicas mais poderosas e amplamente utilizadas na análise de dados multidimensionais, principalmente em áreas como aprendizado de máquina, processamento de imagens e análise de grandes volumes de dados biológicos. A técnica é fundamental para a redução da dimensionalidade, permitindo a extração das principais variáveis que explicam a maior parte da variação dos dados. Recentemente, alguns

estudos têm explorado melhorias na aplicação do PCA para lidar com conjuntos de dados de alta dimensionalidade e para integrar de maneira eficiente informações de diferentes fontes. Um exemplo relevante é o trabalho de Zhang et al. (2024), que propõe um novo método de PCA robusto para dados com ruído e *outliers*, mostrando melhor desempenho em comparação aos métodos tradicionais. Além disso, a PCA tem sido combinado com técnicas de aprendizado profundo para otimizar o pré-processamento de dados antes da aplicação de modelos de redes neurais. Isso é ilustrado no estudo de (LIU et al., 2024), que integra PCA com *autoencoders* para melhorar a qualidade das representações latentes em problemas de reconhecimento de padrões. Em outra vertente, a utilização da PCA no campo da Biomedicina tem demonstrado avanços significativos, como a utilização em dados de imagens PET/CT, onde a redução de dimensionalidade facilita a visualização e análise de padrões complexos em imagens médicas, (YANG et al., 2024). Um estudo interessante de (WANG et al., 2024) aplica PCA para a análise de dados genômicos, com foco na identificação de padrões que podem prever a resposta a terapias específicas em tratamentos de câncer, abrindo novas possibilidades para a medicina personalizada. Esses estudos evidenciam a flexibilidade e a robustez do PCA, especialmente quando combinado com técnicas modernas de aprendizado de máquina, para enfrentar os desafios da análise de grandes volumes de dados e proporcionar análises mais precisas em diversas áreas.

A PCA tem sido amplamente aplicada em conjunto com a PET para melhorar a análise de imagens médicas, especialmente em casos de câncer e outras patologias. A PCA é uma técnica eficaz para reduzir a dimensionalidade dos dados complexos gerados por imagens de PET, destacando as variáveis mais significativas e, assim, facilitando a interpretação dos resultados. Um exemplo significativo é o estudo de (APRILE et al., 2020), que utilizou PCA *voxel a voxel* em dados dinâmicos de PET com [S-methyl-11C]metionina em pacientes com glioma. Essa abordagem permitiu identificar heterogeneidades intratumorais, oferecendo dados valiosos sobre a agressividade do tumor e contribuindo para um planejamento terapêutico mais preciso. Em Cavalcanti et al. (2017) também é explorado a aplicação de PCA para a técnica de *unmixing* em imagens dinâmicas de PET, a qual foi essencial para lidar com variações não lineares nas curvas de atividade temporal, permitindo uma interpretação mais acurada dos dados em tecidos com ligação específica. Além disso, técnicas de análise de forma e heterogeneidade em imagens PET/CT têm sido investigadas para avaliar a confiabilidade das características funcionais e morfológicas de tumores de câncer de pulmão, embora não envolvam diretamente a PCA, ressaltam a importância de metodologias avançadas para caracterizar tumores de maneira mais precisa. Esses estudos demonstram como a combinação da PCA com PET pode aprimorar o diagnóstico e a avaliação terapêutica, permitindo uma análise mais detalhada e confiável das imagens médicas.

Os estudos recentes na área de PET/CT avançaram significativamente em relação à qualidade de imagem e à eficiência dos sistemas de tomografia por emissão de pósitrons.

O trabalho de (ZHANG et al., 2025) avaliou o desempenho do sistema *DigitMI 930*, destacando sua alta sensibilidade e resolução espacial aprimorada devido ao acoplamento 1:1:1 entre cristal cintilador, fotossensor e canal de leitura eletrônica, além da implementação da técnica *Multi-Voltage Threshold* (MVT) para a extração precisa de informações temporais e energéticas. Por outro lado, (WANG et al., 2025) desenvolveram a MAG-Net, uma rede geradora adaptativa multiescala para sintetizar imagens de CT a partir de PET, abordando uma limitação crítica de sistemas de PET cerebrais que não possuem aquisição simultânea de CT. A abordagem propõe módulos específicos para a extração robusta de características, garantindo imagens sintéticas com alta fidelidade estrutural e textural em relação às imagens reais de CT. Juntos, esses estudos contribuem para o avanço das aplicações de PET/CT, melhorando tanto a aquisição de imagens quanto a reconstrução sintética para otimização do diagnóstico clínico.

Os estudos apresentados contribuem de maneira significativa para o aprimoramento das técnicas de segmentação e reconstrução de imagens médicas, especialmente no contexto de imagens multimodais. (LI et al., 2024), propõe uma rede neural tridimensional equipada com um módulo de atenção cruzada, com o objetivo de realizar a segmentação automática do cérebro a partir de imagens obtidas por PET e RM. A referida abordagem possibilita a integração de informações funcionais e anatômicas, promovendo maior precisão na segmentação e configurando-se como uma ferramenta promissora para o diagnóstico de doenças neurológicas. Enquanto (PINTON et al., 2025), apresenta um modelo generativo multi-ramo baseado em autoencoders variacionais (VAEs) para a reconstrução sinérgica de imagens PET/CT. Tal método viabiliza a reconstrução conjunta de imagens multimodais, elevando a qualidade das imagens geradas e possibilitando, conseqüentemente, a redução da dose de radiação ou do tempo de escaneamento.

Ambos os estudos ressaltam o potencial do aprendizado profundo e da integração de dados multimodais para a evolução das técnicas de aquisição e processamento de imagens médicas, destacando aplicações clínicas promissoras no campo da medicina diagnóstica.

1.5 Objetivos

1.5.1 Objetivos Gerais

- Desenvolver uma abordagem quantitativa para a análise multicritério da qualidade de imagens PET/CT, utilizando Análise de Componentes Principais (PCA) para avaliar e interpretar os principais fatores que influenciam a qualidade das imagens.

1.5.2 Objetivos Específicos

- Identificar e selecionar os principais critérios que influenciam a qualidade de imagens PET/CT, considerando aspectos técnicos e clínicos relevantes.;
- Aplicar a Análise de Componentes Principais (PCA) para reduzir a dimensionalidade dos dados e extrair os principais fatores que contribuem para a variação na qualidade das imagens;
- Comparar e interpretar os resultados obtidos por meio da abordagem quantitativa proposta, avaliando sua eficácia na análise multicritério da qualidade de imagens PET/CT.

1.6 Organização da Dissertação de Mestrado

Esta dissertação apresenta uma Metodologia para a Otimização de Imagens Advindas do *Q.Clear*. No capítulo 2 é apresentada a fundamentação teórica da Tomografia por Emissão de Pósitrons (PET), incluindo seus princípios físicos, formação de imagens, aplicações clínicas e científicas, e o funcionamento do equipamento. No capítulo 3 é apresentada a fundamentação teórica da Análise de Componentes Principais (PCA), técnica estatística para redução de dimensionalidade e identificação de padrões em dados. Abordando os conceitos, formulação matemática, propriedades e aplicações da PCA, visando embasar as análises subsequentes. No capítulo 4 será descrita a metodologia de modelagem da proposta e as etapas para obtenção de imagens otimizadas, considerando a aquisição de dados com redução de doses de radiofármacos via Análise de Componentes Principais. No capítulo, 5 os resultados computacionais e experimentais demonstram a eficiência do método proposto nesta dissertação para modelar imagens médicas otimizadas de casos de pacientes do Hospital São Domingos (São Luís - MA). Finalmente, no capítulo 6 são apresentadas as conclusões desta dissertação, bem como propostas para trabalhos futuros.

2 Tomografia por Emissão de Pósitrons

Neste capítulo, será apresentada a fundamentação teórica acerca da Tomografia por Emissão de Pósitrons, abordando de forma abrangente os princípios físicos que regem o seu funcionamento, os processos envolvidos na formação das imagens, as principais aplicações clínicas e científicas dessa modalidade de imagem molecular, bem como uma descrição detalhada dos componentes e do funcionamento do equipamento utilizado. Essa revisão teórica visa proporcionar uma compreensão aprofundada sobre a técnica, destacando sua relevância na análise de processos biológicos.

2.1 Definição

A Tomografia por Emissão de Pósitrons (PET) é definida como técnica aplicada em imagens médicas que permite a visualização de processos metabólicos no corpo, (METTLER; GUIBERTEAU, 2012). Para isso, utiliza-se de radiofármacos ou marcadores de isótopos radioativos para detecção de alterações metabólicas em células. O *scanner* PET detecta pósitros, partículas subatômicas que têm a mesma massa que os elétrons, mas possuem carga elétrica positiva, emitidos pelo decaimento do radioisótopo, que colidem com elétrons, produzindo raios gama. Esses raios são captados pelo *scanner*, que cria imagens tridimensionais detalhadas, permitindo aos médicos identificar anomalias funcionais antes que mudanças estruturais ocorram.

Enquanto o PET busca examinar funções biológicas, as outras formas de tomografia, como a tomografia computadorizada (TC), examinam somente estruturas corpóreas. Esse diferencial o torna especialmente útil em Oncologia, Neurologia e Cardiologia, (VALK et al., 2006). A combinação de PET com tomografia computadorizada (PET/CT) melhora ainda mais a precisão diagnóstica, fornecendo informações tanto funcionais quanto anatômicas.

2.2 Princípio Físico

O PET utiliza radiofármacos, compostos químicos que contém um isótopo radioativo que emitem radiação a serem detectadas para fins de imagens médicas para diagnóstico ou tratamento em condições especiais. Esses compostos são projetados para serem introduzidos no corpo do paciente, geralmente por injeção, ingestão ou inalação, e se dirigem a órgãos, tecidos ou células específicas, (KRAMER et al., 2008). Quando essas substâncias são administradas aos pacientes, elas acumulam-se em áreas de alta atividade metabólica, como tumores.

Quando um pósitron, a antipartícula de um elétron, é emitida por um núcleo radioativo, o mesmo percorre uma curta distância chocando-se a um elétron. Desse encontro obtém-se um processo denominado de aniquilação, resultando na emissão de dois fótons gama em direções opostas. Esses fótons apresentam a carga de 511 keV , essa energia é proveniente da conversão da massa do complexo de pósitrons em energia, determinada pela equação de Einstein, (KRAMER et al., 2008).

$$E = m \cdot c^2 \quad (2.1)$$

onde m é a massa do complexo elétron-pósitron e c a velocidade da luz no vácuo. A distância percorrida pelo pósitron está relacionada com sua energia. Os detectores ao redor do paciente captam esses fótons gama, a detecção simultânea desses fótons permite determinar o percurso no qual ocorreu a aniquilação e sua localização no corpo do paciente.

A instrumentação do PET é composta por componentes essenciais que combinados são utilizados para detectar os sinais emitidos pelos radiofármacos no corpo do paciente. Dentre esses elementos, os detectores de cintilação são responsáveis por captar os fótons gama emitidos durante a aniquilação dos pósitrons, (VALK et al., 2006) e (SAHA; GOPAL, 2005). A esses detectores utilizam-se cristais de cintilação, como o óxido de lutécio dopado com cério (LSO), que convertem os fótons gama em luz visível. A luz é convertida em sinais elétricos por meio de fotomultiplicadores ou fotodiodos de avalanche, (TURKINGTON, 2001). A linha de resposta (LOR, do inglês, *Line of Response*) indica a localização probabilística do local da aniquilação do pósitron e não a localização da sua emissão, obtendo-se assim uma incerteza de vários milímetros, sendo está a maior limitação da técnica PET, (JADVAR; PARKER, 2005).

Os detectores são organizados de forma circular e equidistante, ao redor de um anel que se localiza ao redor do paciente, essa configuração permite a detecção simultânea de fótons em direções opostas, tal configuração é essencial para a determinação da LOR ao longo da qual ocorreu a aniquilação. O PET dispõe de múltiplos anéis de detectores e quando são detectados dois fótons dentro de uma janela temporal limitada e pré-definida, demonina-se Janela de Tempo de Coincidência, tipicamente de 6 a 20 ns , conforme Figura 1, (VALK et al., 2006).

Em PET utilizando o princípio Tempo de Voo (TOF, do inglês, *Time of Fly*), a localização da aniquilação do pósitron é determinada pela medição precisa da diferença temporal entre as detecções dos dois fótons gama emitidos. Essa informação temporal permite restringir a localização do evento de aniquilação a uma região específica ao longo da LOR, delimitando espacialmente os eventos de coincidência, (SAHA; GOPAL, 2005) e (HOGG; MEADOWS; HEATHCOTE, 2010).

A localização do centro dessa região é diretamente proporcional à diferença de

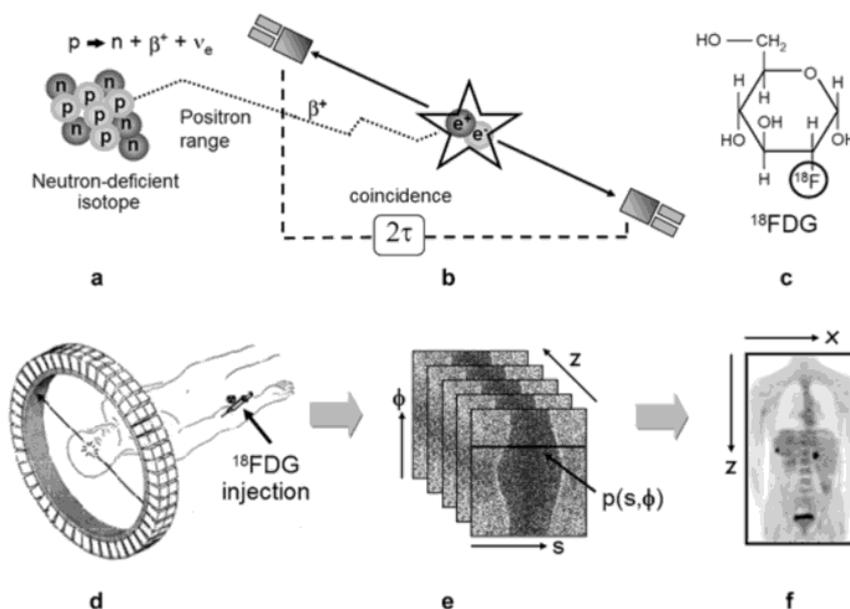


Figura 1 – Princípios da Imagiologia PET esquematicamente: a) decaimento radioativo; b) detecção de fótons de coincidência numa janela temporal; c) e d) radiofármaco injetado no doente; e) obtenção do sinograma com os eventos de aniquilação; f) corte coronal reconstruído com a distribuição do radiofármaco pelo corpo, (VALK et al., 2006)

tempo de voo entre os fótons detectados, enquanto a extensão espacial da região é definida pela resolução temporal intrínseca do sistema PET. Portanto, sistemas com maior resolução temporal permitem uma localização mais precisa do evento de aniquilação, aprimorando a qualidade da imagem e a quantificação da atividade.

O sistema de aquisição de dados coleta os sinais elétricos dos detectores e os converte em sinais digitais, simultaneamente, é realizada a coincidência temporal, garantindo que todas as medições sejam registradas (TURKINGTON, 2001). Com base nos dados adquiridos, por meio de sistemas computacionais, as imagens são reconstruídas e destacando-se a distribuição do radiofármaco no corpo. A janela de tempo vai variar de acordo com o tomógrafo utilizado e é dependente dos circuitos eletrônicos e do tipo de cristal utilizado.

A detecção de pares de fótons provenientes de um único evento de aniquilação é crucial em física de altas energias. Para que um evento seja considerado válido, dois fótons originados da mesma aniquilação devem ser detectados simultaneamente, sem que haja qualquer interação com a matéria antes de atingirem o cristal detector. Este método garante a preservação da LOR, um parâmetro fundamental para a reconstrução da imagem, (JAMAR et al., 2013).

A detecção de apenas um fóton do par, ou a detecção múltipla de fótons provenientes

de diferentes aniquilações, impossibilita a definição precisa da LOR, tornando esses eventos inutilizáveis para a formação da imagem. Tais eventos, classificados como coincidências de fótons únicos e múltiplas, respectivamente, são descartados durante a análise, (METTLER; GUIBERTEAU, 2012).

Dois tipos de eventos contribuem para o ruído da imagem: coincidências aleatórias e de dispersão. As coincidências aleatórias ocorrem quando dois fótons, originados de diferentes aniquilações, são detectados dentro da mesma janela temporal de coincidência. Embora registrados como eventos coincidentes, a LOR definida é incorreta, introduzindo erros na reconstrução da imagem, (WEBB, 1988). As coincidências de dispersão, por sua vez, surgem quando um dos fótons sofre espalhamento Compton ou efeito fotoelétrico antes de atingir o detector. Essa interação altera a trajetória do fóton, resultando em uma LOR errônea, conforme ilustrado na Figura 2, (JADVAR; PARKER, 2005).

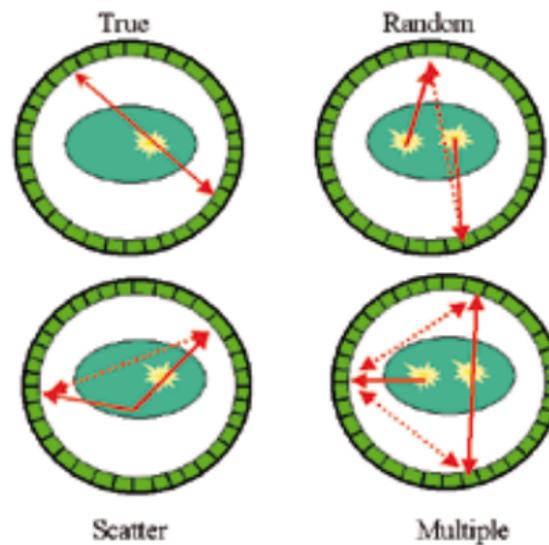


Figura 2 – Tipos de Coincidências em PET: (a) coincidência verdadeira; (b) coincidência aleatória; (c) coincidência de dispersão; (d) coincidência múltipla, (JADVAR; PARKER, 2005)

A presença de coincidências aleatórias e de dispersão impõe a necessidade de técnicas de filtragem e correção para minimizar o ruído e garantir a qualidade da imagem final.

2.3 Formação da Imagem PET

A detecção de eventos de aniquilação de pósitrons em Tomografia por Emissão de Pósitrons (PET) inicia-se com a conversão dos fótons emitidos em energia luminosa. Esta conversão ocorre nos cristais cintiladores, sendo a luz subsequentemente direcionada aos

Tubos Fotomultiplicadores (TFM) através de guias de luz, (GIAMMARILE; HOUZARD, 2011).

Os TFM desempenham um papel crucial na cadeia de processamento de sinal. Primeiramente, convertem a luz incidente em um sinal elétrico, amplificando-o para níveis detectáveis. Além disso, fornecem informações espaciais do evento, determinando as coordenadas X e Y . A coordenada Z , por sua vez, é correlacionada com a energia do sinal, (JOHNSON, 2007).

Após a amplificação pelos TFM, o sinal elétrico é submetido a um estágio de modelagem e amplificação adicional no pré-amplificador e amplificador, respectivamente. O sinal resultante, agora com amplitude adequada, é então direcionado ao analisador de altura de pulsos, onde sua amplitude é classificada. Por fim, os dados processados são enviados a um sistema computacional para armazenamento, reconstrução tomográfica e subsequente visualização da imagem, (SAHA; GOPAL, 2005) e (SLOMKA; PAN; GERMANO, 2016).

Os sistemas PET oferecem duas modalidades principais de aquisição de imagens: bidimensional $2D$ e tridimensional $3D$ (Figura 3). No modo $2D$, a inserção de septos físicos, geralmente compostos por chumbo ou tungstênio, entre os anéis de detectores restringe a detecção de eventos coincidentes a detectores pertencentes ao mesmo anel ou a anéis adjacentes. Esta colimação eletrônica, embora implique em redução da sensibilidade do sistema, proporciona imagens com qualidade superior, (TOWNSEND, 2008) e (GRIFFETH, 2005).

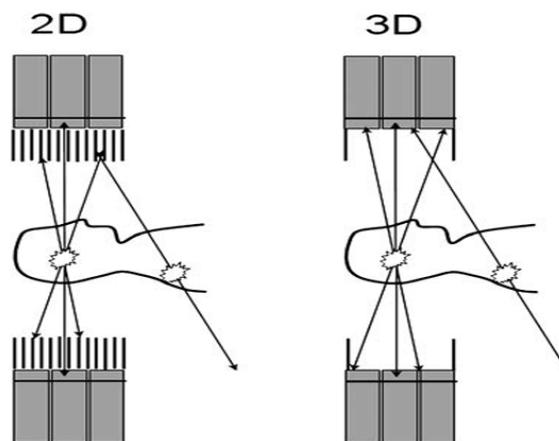


Figura 3 – Ilustração dos modos de aquisição: $2D$ à esquerda (com septos) e $3D$ à direita (sem septos). No modo $3D$ a sensibilidade é aumentada comparando com o modo $2D$ porque existe um maior ângulo de aceitação. No entanto, no $3D$ os eventos aleatórios e o tempo morto são maiores, (TOWNSEND, 2008)

Em contraste, a aquisição $3D$ prescinde dos septos, permitindo a detecção de coincidências entre detectores de diferentes anéis, sem restrições. Essa abordagem resulta em um aumento significativo na sensibilidade, estimada em até cinco vezes a da modalidade

2D, (JOLLIFFE, 2002) e (JADVAR; PARKER, 2005). No entanto, a ausência de colimação acarreta um aumento na detecção de eventos aleatórios e dispersos, além de influenciar o tempo morto do sistema, fatores que podem comprometer a qualidade final da imagem.

Durante a execução do exame, o *scanner* PET realiza a coleta de dados em um intervalo de tempo, registrando os eventos de aniquilação de pósitrons. Esses dados são organizados como projeções que representam diferentes ângulos em torno do paciente.

2.4 Aplicações do PET em Oncologia

A tomografia por emissão de pósitrons emerge como ferramenta de significativa relevância no campo da Oncologia, principalmente devido à sua capacidade de detectar alterações metabólicas precoces, muitas vezes imperceptíveis em exames de imagem convencionais. Essa propriedade singular permite a identificação de processos biológicos característicos de tumores, como o aumento da taxa de metabolismo da glicose, visualizado através da metabolização do radiofármaco ^{18}F -FDG (LONSDALE; BEYER, 2010) e (TOWNSEND, 2016).

A detecção precoce proporcionada pela técnica, aliada à capacidade de determinar a extensão do tumor e avaliar a resposta ao tratamento, torna o PET um aliado crucial no estadiamento do câncer e na personalização terapêutica. Adicionalmente, a possibilidade de detecção de recidiva tumoral, identificando áreas de atividade metabólica sugestivas de recrudescência neoplásica, reforça a importância da técnica no acompanhamento oncológico, impactando diretamente o prognóstico e a qualidade de vida dos pacientes, (BARBOSA et al., 2016) e (BISHOP, 2006).

2.4.1 Uso do PET com ^{18}F -FDG

O estadiamento preciso do tumor é crucial para o prognóstico e manejo terapêutico de pacientes com suspeita de malignidades. O PET destaca-se como uma modalidade de imagem de alta sensibilidade, capaz de mapear a distribuição corporal de biomarcadores emissores de pósitrons, revelando processos moleculares intrínsecos à atividade metabólica tumoral, (POEPPEL et al., 2009) e (WEBB, 1988).

O radiofármaco mais utilizado em PET, o ^{18}F -Fluordesoxiglicose (^{18}F -FDG), é um análogo da glicose que permite visualizar processos glicolíticos. Dada a intensificação da glicólise em células tumorais, o ^{18}F -FDG acumula-se nesses sítios. O ^{18}F -FDG é internalizado por transporte ativo ou difusão facilitada, mediado por proteínas transportadoras de glicose, principalmente GLUT1. Intracelularmente, a enzima hexoquinase fosforila associa-se ao ^{18}F -FDG, formando ^{18}F -FDG-6-fosfato. A glucose-6-fosfatase, enzima ausente em células tumorais, não reconhece o ^{18}F -FDG-6-fosfato, levando ao seu aprisionamento e permitindo a detecção por PET (LYNCH et al., 2007).

A versatilidade química de diversos radionuclídeos utilizados em PET, como ^{18}F -FDG, ^{11}C -Carbono, ^{13}N -Nitrogênio e ^{15}O -Oxigênio, possibilita investigar múltiplos aspectos da biologia tumoral além da glicólise, incluindo proliferação celular, hipoxia, angiogênese e apoptose, (WECHALEKAR; SHARMA; COOK, 2005) e (WADSAK; MITTERHAUSER, 2010).

Entretanto, o uso do ^{18}F -FDG apresenta limitações. A glicólise aumentada não é exclusiva de tecidos malignos, podendo ocorrer em processos benignos e gerar falsos-positivos. Além disso, a captação fisiológica de ^{18}F -FDG em órgãos como intestino, trato urinário, músculos esqueléticos e tecido adiposo marrom pode dificultar a interpretação das imagens, (WECHALEKAR; SHARMA; COOK, 2005).

Em conclusão, a PET com ^{18}F -FDG é uma ferramenta valiosa no estadiamento tumoral e na avaliação da biologia do câncer. No entanto, a interpretação dos resultados exige cautela, considerando as potenciais limitações do método. Nesse sentido, a pesquisa e o desenvolvimento de novos radiofármacos e protocolos PET, tornam-se necessários para o aprimoramento da precisão diagnóstica e a personalização do tratamento oncológico.

2.4.2 Reconstrução de Imagens PET/CT

A reconstrução de imagens PET baseia-se na detecção de eventos de coincidência, que representam a detecção simultânea de dois fótons gama emitidos a partir da aniquilação de um pósitron. Durante a aquisição de dados, o equipamento PET registra esses eventos coincidentes provenientes das LOR, armazenando-os em tempo real, (KRAMER et al., 2008), (PAPATHANASSIOU et al., 2009).

A organização desses dados brutos (contagens por par de detectores) se dá em estruturas matriciais denominadas Sinogramas. Cada linha de um Sinograma corresponde ao conjunto de dados adquiridos em LOR paralelas, conforme ilustrado na Figura 4.

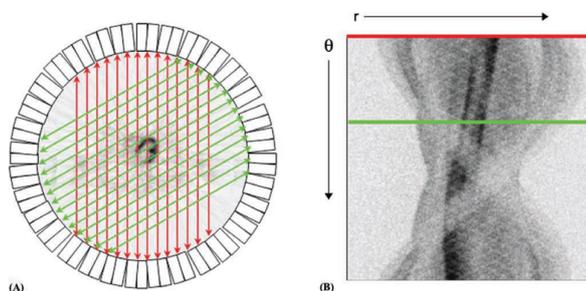


Figura 4 – Exemplo das múltiplas projeções em diferentes ângulos de um paciente. (A) Orientação de duas projeções paralelas; (B) Sinograma, em que cada linha representa uma projeção a um ângulo diferente. As duas projeções assinaladas em (A) estão também destacadas em (B), (PAPATHANASSIOU et al., 2009)

É importante destacar que a aquisição de dados pode ser realizada em modo $2D$ ou

3D. No modo 2D, a informação é restrita aos planos axiais, enquanto o modo 3D incorpora também os planos oblíquos (KRAMER et al., 2008), proporcionando uma reconstrução tomográfica mais completa.

2.5 Métodos de Avaliação de Imagens

2.5.1 Critérios de Interpretação das Imagens

Em equipamentos híbridos de PET/CT, os softwares integrados proporcionam o registro e alinhamento automáticos das imagens, permitindo a visualização simultânea das informações provenientes das modalidades PET e CT em múltiplos planos (axial, coronal e sagital). A técnica de projeção de máxima intensidade (MIP) possibilita a representação tridimensional das estruturas anatômicas e a identificação de áreas de hipermetabolismo.

A interpretação precisa das imagens PET/CT depende de um profundo conhecimento da distribuição fisiológica do radiofármaco ^{18}F -FDG, bem como das variantes anatômicas e patológicas que podem mimetizar processos neoplásicos. A captação fisiológica do ^{18}F -FDG é elevada no cérebro, coração, fígado, baço e trato gastrointestinal, podendo variar de acordo com o estado metabólico do paciente. É fundamental diferenciar essa captação normal daquela observada em processos patológicos, tais como tumores, inflamações e isquemias.

A presença de artefatos, como movimentos do paciente e objetos metálicos, pode comprometer a qualidade das imagens e dificultar a interpretação. Além disso, a correção de atenuação é essencial para quantificar adequadamente a atividade radioativa e evitar falsos positivos (LYNCH et al., 2007).

2.5.2 Fontes de Erro e Artefatos nas Imagens

A qualidade das imagens obtidas em exames PET/CT pode ser comprometida por diversos fatores, que podem levar à geração de artefatos e, conseqüentemente, a interpretações errôneas. Um desses fatores é a administração do radiofármaco. A ocorrência de extravasamento, por exemplo, pode resultar em imprecisões no cálculo do SUV e na indução de falsos positivos, especialmente em relação à detecção de metástases em linfonodos. Recomenda-se, portanto, a administração do radiofármaco no lado contralateral à lesão conhecida.

A utilização de imagens de CT para correção de atenuação dos dados PET pode gerar artefatos de *hot spots* em regiões com alta densidade eletrônica, como implantes metálicos e *stents*. Esses artefatos são causados pela elevada absorção fotônica e podem levar à sobrestimação da atividade metabólica, resultando em falsos positivos. O uso de agentes de contraste iodados, seja por via oral ou intravenosa, também pode contribuir

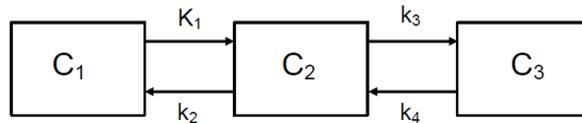


Figura 5 – Modelo cinético do comportamento do FDG: modelo tri-compartimental (BASU et al., 2011).

para a ocorrência desses artefatos. A comparação das imagens com e sem correção de atenuação é fundamental para a identificação e caracterização desses artefatos.

2.5.3 Quantificação em PET

Os métodos de análise de dados provenientes da PET podem ser classificados em três grandes categorias, descritas a seguir: análise qualitativa ou avaliação visual; análise semi-quantitativa, incluindo o cálculo do SUV ou relações entre lesão e fundo; e análise quantitativa absoluta.

Nos últimos anos, tem-se observado um crescente interesse na aplicação dos dados de PET com ^{18}F -FDG (fluorodeoxiglicose marcada com flúor-18) na monitorização da resposta ao tratamento de diversos tumores. Tal interesse decorre dos benefícios desta técnica em relação às modalidades de imagem anatômica, como previamente descrito. Assim, torna-se fundamental adotar métodos mais precisos para a quantificação tumoral. Apesar da avaliação visual desempenhar um papel essencial na interpretação de estudos relacionados à PET, observa-se dependência da subjetividade do observador tornando desejável a utilização de parâmetros quantitativos rigorosos que minimizem tal limitação.

Nesse contexto, têm sido observado esforços para desenvolver técnicas quantitativas objetivas, que sejam práticas para uso clínico rotineiro e, simultaneamente, suficientemente precisas. A análise quantitativa absoluta baseia-se em modelos matemáticos compartimentais os quais descrevem o comportamento dos radiofármacos em diferentes tipos de células. Esses modelos foram originalmente desenvolvidos para estudar a cinética de análogos da glicose, incluindo o FDG, e desempenharam papel pioneiro nessa área.

Os modelos cinéticos geram uma taxa metabólica quantitativa, a qual avalia o metabolismo do FDG e de seus componentes individuais, tais como o transporte e a fosforilação da glicose. O primeiro modelo cinético do FDG foi estruturado em um modelo tri-compartimental: o compartimento 1 (C1) representa a concentração arterial de FDG livre no plasma; o compartimento 2 (C2) corresponde à concentração de FDG no tecido, disponível para fosforilação; e o compartimento 3 (C3) refere-se à concentração de FDG que sofreu fosforilação pela enzima hexoquinase (BASU et al., 2011).

Para a obtenção desses dados, estudos dinâmicos são combinados com coletas de sangue, gerando curvas de atividade *versus* tempo específicas para tumores ou órgãos em

estudo. Contudo, apesar da precisão, a técnica apresenta limitações práticas, como a alta complexidade técnica, o elevado custo e a grande demanda de tempo, que restringe sua aplicação na prática clínica diária.

O cálculo do SUV é o método mais amplamente utilizado na prática clínica para a quantificação do metabolismo da glicose. Este é um parâmetro semi-quantitativo que caracteriza a malignidade ou benignidade de lesões. O SUV é definido como a concentração do radiofármaco em um tecido, medida por um equipamento PET em um momento específico, dividida pela atividade injetada, normalizada pelo peso corporal, superfície corporal ou massa corporal magra, considerando o decaimento radioativo. A fórmula mais comum de cálculo do SUV baseia-se no peso corporal total (*SUVweight*).

$$SUV_{weight} = \frac{MActROI(\frac{mCi}{mL})}{ActInj(mCi) : Peso(g)} \cdot \frac{1}{FatorDecai} \quad (2.2)$$

Como referência, um SUV igual a 1 indica distribuição homogênea do radiofármaco no corpo, independentemente da atividade injetada ou de peso corporal. Para calcular o SUV, define-se uma região de interesse tridimensional (ROI 3D) no alvo (por exemplo, o tumor) utilizando softwares de processamento de imagem. A radioatividade medida na ROI é então normalizada pela concentração média de atividade no corpo.

Os valores de SUV são frequentemente reportados como média ou máximo dos *voxels* dentro da ROI. O SUV médio, que considera múltiplos *voxels*, é menos sensível a ruídos de imagem, mas depende da definição da ROI, estando sujeito a variações intra e interobservador. Por outro lado, o SUV máximo, que reflete o maior valor de voxel dentro da ROI, é menos dependente da definição da ROI, contudo mais suscetível a ruídos. Atualmente, o SUV máximo é mais utilizado pelo maior reprodutibilidade.

Recentemente, foi introduzido o conceito de *SUVpeak*, que calcula o valor médio de SUV em uma região de *voxels* ao redor do *voxel* de maior atividade. Essa abordagem busca melhorar a reprodutibilidade do SUV máximo enquanto reduz sua sensibilidade ao ruído, funcionando como uma suavização adicional da imagem. Apesar de amplamente utilizado, o cálculo de SUV é suscetível a erros técnicos, físicos e biológicos, que podem comprometer sua precisão.

Esses fatores biológicos podem ser: níveis de glicose no sangue; período de Distribuição do Radiofármaco; movimentação do paciente e movimentação involuntária respiratória ou dos órgãos; peso do paciente; infecção/Inflamação ou Quimioterapia.

Em relação aos fatores físicos-técnicos, observam-se: parâmetros de reconstrução de imagem; parâmetros de aquisição; uso de Agentes de Contraste; delimitação de ROI's; calibração do Equipamento PET e do calibrador de doses: atividade residual na seringa; extravasão do Radiofármaco; erros na Correção do Decaimento.

De um modo geral, é importante perceber que a análise do SUV não deve ser o único critério usado para a interpretação das imagens, mas também devem ser levados em consideração a captação visual, o tamanho relativo da lesão em relação à captação, o padrão de captação e o histórico clínico.

2.6 Equipamento PET

O PET/CT GE *Discovery IQ Gen 2* é uma solução avançada em medicina nuclear que combina tomografia por emissão de pósitrons com tomografia computadorizada, proporcionando uma avaliação diagnóstica detalhada e precisa. Este equipamento é projetado para otimizar a detecção de doenças e oferecer suporte no planejamento terapêutico, especialmente em aplicações oncológicas. Ele apresenta avanços tecnológicos significativos, como detectores de alta sensibilidade e o sistema *Q.Clear*, que melhora a qualidade das imagens reconstruídas, reduzindo ruídos e aumentando a precisão da quantificação do sinal metabólico. O *Discovery IQ Gen 2* também suporta protocolos de baixa dose de radiação para o paciente, atendendo às exigências de segurança e conforto.

Uma das principais vantagens do GE *Discovery IQ Gen 2* é a capacidade de produzir imagens de alta resolução com excelente sensibilidade, permitindo identificar lesões metabólicas pequenas e sutis as quais poderiam passar despercebidas em outras modalidades. O equipamento também possibilita tempos reduzidos de aquisição de imagens, o que melhora a experiência do paciente e aumenta a eficiência operacional do serviço de medicina nuclear. Além disso, sua ampla gama de aplicações clínicas torna-o versátil para diferentes especialidades médicas, mas com destaque particular para a Oncologia.

No contexto oncológico, o PET/CT *Discovery IQ Gen 2* desempenha um papel crucial no diagnóstico, estadiamento e acompanhamento terapêutico de diversos tipos de câncer. Por meio da administração de radiotraçadores específicos, como o ^{18}F -FDG, o equipamento permite avaliar a atividade metabólica de tumores malignos, distinguindo tecidos saudáveis de áreas potencialmente neoplásicas. Este recurso é essencial para definir o estágio da doença, monitorar a resposta ao tratamento (como quimioterapia ou radioterapia) e detectar recidivas precoces. A integração das informações anatômicas da CT com as informações metabólicas do PET oferece um panorama abrangente, melhorando a precisão no delineamento de lesões e contribuindo para decisões terapêuticas mais eficazes.

Assim, o PET/CT GE *Discovery IQ Gen 2* apresenta-se como uma ferramenta indispensável na medicina moderna, particularmente na oncologia, oferecendo avanços tecnológicos que potencializam a acurácia diagnóstica e o manejo clínico de pacientes oncológicos.

3 Análise de Componentes Principais

Neste capítulo, será apresentada a fundamentação teórica acerca da Análise de Componentes Principais, uma técnica estatística amplamente utilizada em diversos campos do conhecimento para a redução de dimensionalidade de dados e identificação de padrões relevantes. Serão abordados os principais conceitos que embasam o método, incluindo sua formulação matemática, propriedades e aplicações práticas, com o objetivo de fornecer um embasamento teórico sólido para a compreensão dos resultados e análises subsequentes deste trabalho.

3.1 Definição

A Análise de Componentes Principais, PCA (do inglês *Principal Component Analysis*), se caracteriza como uma técnica estatística usada para simplificar um conjunto de dados complexos. Na qual componentes capturam a maior parte da variação nos dados originais, transformando variáveis potencialmente correlacionadas em um conjunto menor de variáveis. Desta forma, transforma-se um grande conjunto em conjunto um menor de variáveis não correlacionadas reduzindo, a dimensionalidade em conjuntos de dados com muitas informações (JOLLIFFE, 2002).

Cada componente principal (CP) é uma combinação linear das variáveis originais. A primeira componente principal (CP1) que captura a maior parte da variação dos dados, pode ser interpretada como a direção no espaço ao longo da qual os pontos têm a maior parte da variância ou variância mais alta. Quanto maior a variabilidade capturada pela (CP1), maior será a informação contida no conjunto de dados originais. Enquanto a segunda componente principal (CP2) captura a segunda maior parte da variação, e assim por diante. Os coeficientes na combinação linear indicam a contribuição de cada variável original para cada CP. Se um coeficiente é grande, essa variável é importante para o componente. As CPs são ortogonais entre si, o que significa que elas são independentes e não correlacionadas, conforme Figura ?? (COMON, 1994).

Para a análise, os indivíduos são agrupados de acordo com o seu comportamento dentro do conjunto, representado pela variação de suas características. Encontra-se CPs através do cálculo de autovalores e autovetores de uma matriz de covariância do conjunto de dados original, identificam-se as direções ou componentes dos dados que têm a maior variação.

Os autovetores de uma matriz destacam-se como vetores que, ao serem submetidos à aplicação dessa matriz por meio de multiplicação matricial, resultam em um vetor que é um

múltiplo escalar do vetor original. Isto é, a direção do vetor permanece inalterada, podendo apenas sofrer um alongamento ou encurtamento. Por sua vez, os autovalores associados a um autovetor representam o fator de escalonamento, indicando a magnitude pela qual o autovetor é alongado ou comprimido. Formalmente, os autovetores correspondem às direções das CP, enquanto os autovalores quantificam a importância ou a variância explicada por cada componente principal, conforme destacado por (REGAZZI, 2000) e (KHATTREE; NAIK, 2000). A PCA exige que os dados sejam organizados em matrizes, conforme mostrado nas subseções a seguir:

3.2 Matriz de Dados

Seja um conjunto de dados, observam-se p características de n indivíduos de uma população π . As características observadas são representadas pelas variáveis $X_1, X_2, X_3, \dots, X_p$. A matriz da dados é descrita como segue:

$$X = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1p} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2p} \\ x_{31} & x_{32} & x_{33} & \cdots & x_{3p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & x_{n3} & \cdots & x_{np} \end{bmatrix} \quad (3.1)$$

A interdependência entre as variáveis em um conjunto de dados, encapsulada pela matriz de covariância S ou pela matriz de correlação R , pode ser complexa e difícil de interpretar diretamente. A PCA realiza uma transformação estatística, convertendo as variáveis originais $X_1, X_2, X_3, \dots, X_p$ em um novo conjunto de variáveis $Y_1, Y_2, Y_3, \dots, Y_p$, chamadas de componentes principais (JOHNSON R. A.; WICHERN, 1999).

Desta forma, as novas variáveis apresentam duas características importantes, a ortogonalidade, onde $Y_1, Y_2, Y_3, \dots, Y_p$ não são correlacionadas entre si, eliminando assim a redundância presente nas variáveis originais e a variância ordenada, ou seja, para cada CP haverá uma quantidade decrescente na variabilidade dos dados. A comparação entre indivíduos pode então ser realizada utilizando-se apenas as primeiras componentes principais Y_{is} que explicam a maior parte da variância, simplificando a interpretação e potencialmente revelando padrões ocultos nos dados. A implementação da PCA se baseia na decomposição da matriz de covariância S ou da matriz de correlação R dos dados originais (JOHNSON R. A.; WICHERN, 1999).

3.2.1 Matriz de Covariância S

A média aritmética, desvio padrão e variância são medidas fundamentais para a análise descritiva de um conjunto de dados. A média aritmética, representada por \bar{x} , é a

soma de todos os valores observados dividida pelo número total de observações, conforme a expressão

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.2)$$

onde x_i representa os valores individuais e n o número de elementos da amostra. A variância, por sua vez, é uma medida que quantifica a dispersão dos dados em torno da média, sendo definida pela fórmula

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (3.3)$$

para uma população, ou

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (3.4)$$

para uma amostra.

O desvio padrão é a raiz quadrada da variância, indicado por σ ou $\hat{\sigma}$, e expressa a dispersão na mesma unidade dos dados originais. Essas métricas são amplamente utilizadas para avaliar a variabilidade dos dados e são essenciais em diversas áreas, como estatística inferencial, análise de sinais e aprendizado de máquina (WACKERLY; MENDENHALL; SCHEAFFER, 2014).

A covariância é uma medida que quantifica o grau de associação linear entre duas variáveis aleatórias. Sejam X e Y duas variáveis, a covariância populacional é dada pela expressão

$$\geq \text{Cov}(X, Y) = \mathbb{E}[(X - \mu_X)(Y - \mu_Y)] \quad (3.5)$$

denota o valor esperado e μ_X e μ_Y são as respectivas médias. No contexto amostral, a covariância é estimada por

$$\hat{\text{Cov}}(X, Y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}). \quad (3.6)$$

A covariância positiva indica que, em média, as variáveis aumentam ou diminuem conjuntamente, enquanto uma covariância negativa sugere que, quando uma variável aumenta, a outra tende a diminuir. Quando a covariância é próxima de zero, isso sugere que não há uma relação linear clara entre as variáveis. No entanto, a magnitude da covariância é influenciada pelas unidades das variáveis, razão pela qual é comum utilizar o coeficiente de correlação de Pearson como uma medida padronizada de associação (JOLLIFFE, 2002).

A partir da matriz X de dados $n \times p$ pode-se realizar uma estimação de covariância do somatório da população π que representa por S . A matriz S é simétrica e de ordem

$p \times p$ dada por:

$$S = \begin{bmatrix} \hat{\text{Var}}(x_1) & \hat{\text{Cov}}(x_1x_2) & \hat{\text{Cov}}(x_1x_3) & \cdots & \hat{\text{Cov}}(x_1x_p) \\ \hat{\text{Cov}}(x_2x_1) & \hat{\text{Var}}(x_2) & \hat{\text{Cov}}(x_2x_3) & \cdots & \hat{\text{Cov}}(x_2x_p) \\ \hat{\text{Cov}}(x_3x_1) & \hat{\text{Cov}}(x_3x_2) & \hat{\text{Var}}(x_3) & \cdots & \hat{\text{Cov}}(x_3x_p) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \hat{\text{Cov}}(x_px_1) & \hat{\text{Cov}}(x_px_2) & \hat{\text{Cov}}(x_px_3) & \cdots & \hat{\text{Var}}(x_p) \end{bmatrix} \quad (3.7)$$

As características são observadas em unidade de medida diferentes entre si, neste caso, é conveniente padronizar as variáveis X . Para isso, pode-se adotar duas medidas: a média 0 (zero) e variância unitária, ou com variância unitária e média qualquer.

A PCA é uma técnica estatística usada para redução de dimensionalidade, transformação de variáveis correlacionadas em um novo conjunto de variáveis não correlacionadas chamadas componentes principais. Para que os dados sejam corretamente analisados pelo PCA, diferentes padronizações podem ser aplicadas antes da decomposição espectral da matriz de covariância ou correlação.

3.2.1.1 Padronização com média zero e variância unitária

Essa abordagem, também chamada de *standardization* ou z-score normalization, é amplamente utilizada para garantir que todas as variáveis tenham igual importância na análise. A transformação dos dados segue a equação:

$$X_{\text{std}} = \frac{X - \mu}{\sigma} \quad (3.8)$$

onde: X representa os dados originais, organizados em uma matriz $X \in \mathbb{R}^{m \times n}$, onde m é o número de amostras e n o número de variáveis. μ é o vetor de médias das colunas de X , definido como:

$$\mu_j = \frac{1}{m} \sum_{i=1}^m X_{ij} \quad (3.9)$$

onde σ é o vetor de desvios padrão das colunas de X , definido como:

$$\sigma_j = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_{ij} - \mu_j)^2} \quad (3.10)$$

Após essa padronização, cada variável terá média zero e variância unitária ($\mathbb{E}[X_{\text{std}}] = 0$ e $\text{Var}(X_{\text{std}}) = 1$). Essa transformação é útil quando as variáveis possuem diferentes escalas e magnitudes.

3.2.1.2 Padronização com variância unitária e média qualquer

Essa abordagem mantém a média original das variáveis, mas ajusta sua variância para ser unitária. O objetivo pode ser preservar informações sobre a localização central dos dados enquanto normaliza a dispersão. A transformação é dada por:

$$X_{\text{var1}} = \frac{X}{\sigma} \quad (3.11)$$

onde σ é o vetor de desvios padrão das colunas de X , conforme definido anteriormente.

Essa transformação garante que $\text{Var}(X_{\text{var1}}) = 1$, mas mantém as médias das colunas originais, ou seja, $\mathbb{E}[X_{\text{var1}}] = \mu$.

$$\bar{x}_j = \frac{\sum_{j=1}^n x_{ij}}{n} \quad (3.12)$$

e

$$s(x_j) = \sqrt{\hat{\text{Var}}(x_j)}, j = 1, 2, \dots, p \quad (3.13)$$

$$\sqrt{\hat{\text{Var}}(x_j)} = \frac{\sum_{j=1}^n (x_{ij} - \bar{x}_j)^2}{n - 1} \quad (3.14)$$

ou

$$\sqrt{\hat{\text{Var}}(x_j)} = \frac{\sum_{i=1}^n x_{ij}^2 - \frac{(\sum_{i=1}^n x_{ij})^2}{n}}{n - 1} \quad (3.15)$$

Após a padronização obtém-se uma nova matriz de dados Z , descrita por:

$$Z = \begin{bmatrix} z_{11} & z_{12} & z_{13} & \cdots & z_{1p} \\ z_{21} & z_{22} & z_{23} & \cdots & z_{2p} \\ z_{31} & z_{32} & z_{33} & \cdots & z_{3p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ z_{n1} & z_{n2} & z_{n3} & \cdots & z_{np} \end{bmatrix} \quad (3.16)$$

A matriz Z , composta pelas variáveis padronizadas z_{ij} , representa a matriz de correlação dos dados originais presentes na matriz X . Na busca pelos componentes principais, o ponto de partida usual é a matriz de correlação R . Os resultados da análise podem variar significativamente dependendo da matriz utilizada (S ou R). A padronização, representada pela matriz Z , se torna especialmente relevante quando as características analisadas são medidas em unidades distintas. Caso contrário, a análise da matriz de covariância (S) pode ser mais indicada. A padronização se torna crucial quando há unidades de medida

diferentes entre as variáveis, garantindo que a análise não seja enviesada por diferenças de escala (JOHNSON R. A.; WICHERN, 1999).

3.2.2 Determinação das Componentes Principais

A padronização torna-se essencial ao lidar com variáveis que possuem unidades de medida distintas. Isso porque a mesma coloca todas as variáveis na mesma escala, evitando que aquelas com maior magnitude dominem a análise, garantindo que os resultados não sejam distorcidos por diferenças de escala.

$$\det|R - \lambda I| = 0 \quad (3.17)$$

ou

$$|R - \lambda I| = 0 \quad (3.18)$$

então

$$R = \begin{bmatrix} 1 & r(x_1x_2) & r(x_1x_3) & \cdots & r(x_1x_p) \\ r(x_2x_1) & 1 & r(x_2x_3) & \cdots & r(x_2x_p) \\ r(x_3x_1) & r(x_3x_2) & 1 & \cdots & r(x_3x_p) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r(x_px_1) & r(x_px_2) & r(x_px_3) & \cdots & 1 \end{bmatrix} \quad (3.19)$$

Considerando uma matriz R de dimensão p , a condição de posto completo implica na inexistência de colunas linearmente dependentes. Dessa forma, a equação característica, definida por $|R - \lambda I| = 0$, apresentará p soluções, denominadas autovalores ou raízes características, denotadas por $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_p$. A construção da matriz de dados X , que representa as observações das variáveis em estudo, requer atenção especial ao tamanho amostral n . Para garantir a estimação eficiente dos parâmetros do modelo, recomenda-se que n seja, no mínimo, igual a $p + 1$.

Se o objetivo da pesquisa reside na análise de p características de uma população, o delineamento experimental deve contemplar, no mínimo, $p + 1$ tratamentos ou unidades amostrais. Formalmente, sejam $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_p$ as raízes da equação característica da matriz R ou S .

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_p \quad (3.20)$$

Para cada autovalor λ_i existe um autovetor \tilde{a}_i , tal que:

$$\tilde{a}_1 = \begin{bmatrix} a_{i1} \\ a_{i2} \\ \vdots \\ a_{ip} \end{bmatrix} \quad (3.21)$$

Os autovetores \tilde{a}_1 são ortonormais, ou seja, satisfazem as seguintes propriedades: a normalização, onde cada autovetor possui norma unitária, ou seja, significando que a soma dos quadrados de seus componentes é igual a 1 (um); e a ortogonalidade, na qual os autovetores são ortogonais entre si, o que significa que o produto escalar entre quaisquer dois autovetores distintos é nulo. Essas propriedades conferem aos autovetores características importantes como a formação de uma base ortonormal para o espaço vetorial em questão.

$$\sum_{j=1}^p a_{ij}^2 = 1 (\tilde{a}_1' \cdot \tilde{a}_1 = 1) \quad (3.22)$$

e

$$\sum_{j=1}^p a_{ij} \cdot a_{kj} = 0 (\tilde{a}_1' \cdot \tilde{a}_1 = 0 \text{ para } i \neq k) \quad (3.23)$$

Com \tilde{a}_i o autovetor correspondente a λ_i , então o i -ésimo correspondente principal é dado por

$$Y_1 = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p \quad (3.24)$$

As componentes principais, derivadas de um conjunto de dados multivariados, exibem propriedades matemáticas cruciais que sustentam sua utilidade na redução da dimensionalidade e extração de características.

3.2.3 Ordenação por Variância Decrescente

A variância de cada componente principal Y_i é diretamente equivalente ao seu autovalor correspondente λ_i . As componentes principais são ordenadas em ordem decrescente de variância, com a primeira componente principal (CP1) capturando a maior variância nos dados. Esta relação é representada como:

$$\hat{\text{Var}}(Y_1) = \lambda_1 \quad (3.25)$$

O primeiro componente é o que apresenta maior variância e assim por diante:

$$\hat{\text{Var}}(Y_1) > \hat{\text{Var}}(Y_2) > \dots > \hat{\text{Var}}(Y_p) \quad (3.26)$$

3.2.4 Preservação da Variância Total

A soma das variâncias de todas as CP é igual à variância total presente nas variáveis originais. Similarmente, a soma de todos os autovalores corresponde à variância total. Matematicamente, descrito por:

$$\sum \hat{\text{Var}}(X_1) = \sum \lambda_1 = \sum \hat{\text{Var}}(Y_1) \quad (3.27)$$

3.2.5 Ortogonalidade

As componentes principais são ortogonais entre si, implicando que não são correlacionadas. Esta propriedade é crucial para eliminar a redundância nos dados e é expressa por:

$$\hat{\text{Cov}}(Y_i, Y_j) = 0 \quad (3.28)$$

As propriedades matemáticas das componentes principais fornecem uma estrutura robusta para a análise de dados multivariados, permitindo a redução da dimensionalidade, a identificação de padrões de variância e a interpretação simplificada de conjuntos de dados complexos.

3.2.6 Contribuição de cada componente principal

A contribuição individual de cada componente principal, denotada como C_i para o componente Y , é frequentemente expressa em termos percentuais. Esta é obtida através da razão entre a variância explicada pelo componente Y e a variância total dos dados originais.

$$C_i = \frac{\hat{\text{Var}}(Y_1)}{\sum_{j=1}^p \hat{\text{Var}}(Y_1)} \cdot 100 \quad (3.29)$$

$$= \frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \cdot 100 \quad (3.30)$$

$$= \frac{\lambda_i}{\bar{S}} \cdot 100 \quad (3.31)$$

A significância de um componente principal é determinada pela sua capacidade explicativa, expressa pela proporção da variância total que ele representa. A somatória dos primeiros k autovalores indica a quantidade de informação retida na redução dimensional de p para k dimensões. Essa métrica é crucial para a determinação do número ótimo de componentes para a análise, ou seja, quantos componentes serão empregados na discriminação entre os indivíduos.

É importante ressaltar que a escolha do número de componentes é subjetiva e não se baseia em um modelo estatístico rígido. Diversos autores, como (30), argumentam que, em diversas áreas do conhecimento, a prática comum é utilizar um número de componentes que explique 70 % ou mais da variância total. No entanto, essa decisão deve ser ponderada considerando o contexto específico da pesquisa e os objetivos da análise.

$$\frac{\hat{\text{Var}}(Y_1) + \dots + \text{Var}(Y_k)}{\sum_{j=1}^p \hat{\text{Var}}(Y_j)} \cdot 100 \geq 70\% \quad (3.32)$$

onde $k < p$.

3.2.7 Interpretação de cada componente

A presente análise consiste em avaliar o grau de influência exercido por cada variável X_j sobre o componente principal Y_i . Esse grau de influência é mensurado por meio da correlação entre a variável X_j e o componente Y_i em análise. Por exemplo, a correlação entre X_j e o primeiro componente principal Y_1 pode ser expressa como:

$$\text{Corr}(X_j, Y_1) = r_{X_j} \cdot a_{1j} \quad (3.33)$$

$$= a_{1j} \cdot \frac{\sqrt{\hat{\text{Var}}(Y_1)}}{\sqrt{\hat{\text{Var}}(Y_j)}} \quad (3.34)$$

$$= \sqrt{\lambda_1} \frac{a_{1j}}{\sqrt{\hat{\text{Var}}(Y_j)}} \quad (3.35)$$

Com o objetivo de comparar a influência das variáveis X_1, X_2, \dots, X_p sobre o componente Y_1 , analisou-se o coeficiente de ponderação (*loading*) atribuído a cada variável em relação ao referido componente. O valor do *loading* representa a contribuição de cada variável para a formação de um componente específico, sendo definido como:

$$w_1 = \frac{a_{11}}{\sqrt{\hat{\text{Var}}(Y_1)}}, w_2 = \frac{a_{12}}{\sqrt{\hat{\text{Var}}(Y_2)}}, \dots, w_p = \frac{a_{1p}}{\sqrt{\hat{\text{Var}}(Y_p)}} \quad (3.36)$$

sendo w_1 o peso de X_1 .

4 Metodologia

Neste capítulo será apresentada a metodologia baseada em na Análise de Componentes Principais para extração de características de imagens médicas.

4.1 Processamento de Imagens Médicas

Para a implementação deste estudo, foram utilizadas imagens de PET/CT provenientes de 26 pacientes atendidos no Hospital São Domingos, localizado em São Luís – MA. A utilização dessas informações foi aprovada pelo Comitê de Ética da instituição, garantindo que não há interesses financeiros concorrentes ou relações pessoais que possam ter influenciado este trabalho.

A identificação das lesões presentes nas imagens foi realizada por especialistas do Departamento de Medicina Nuclear do Hospital São Domingos, sob a liderança do médico nuclear Dr. Wawryk Mendonça e Dra. Aline Santos Farias.

Para a visualização, processamento e análise das imagens no formato DICOM (*Digital Imaging and Communications in Medicine*), foram empregados softwares específicos, tanto em estações de trabalho locais quanto por meio de acesso remoto. O padrão DICOM é amplamente reconhecido e adotado internacionalmente como referência para o armazenamento, transmissão e visualização de imagens médicas digitais, desempenhando um papel essencial na organização e gestão de dados em ambientes clínicos e de pesquisa (NEMA, 2023).

A padronização promovida pelo DICOM permite a integração eficiente de equipamentos de diferentes fabricantes, garantindo a interoperabilidade entre sistemas de aquisição, processamento e arquivamento de imagens. Essa característica é fundamental para viabilizar o compartilhamento de dados entre instituições de saúde e centros de pesquisa, assegurando a compatibilidade entre diferentes modalidades de imagem, como tomografia computadorizada (CT), ressonância magnética (RM) e tomografia por emissão de pósitrons associada à tomografia computadorizada (PET/CT) (NEMA – National Electrical Manufacturers Association, 2023).

Além da integração entre dispositivos e sistemas, o padrão DICOM possibilita a incorporação de metadados estruturados, contendo informações detalhadas sobre o paciente, os parâmetros de aquisição das imagens e a instituição responsável pelo exame. Esse aspecto é crucial para garantir a rastreabilidade e a reprodutibilidade das análises, permitindo que pesquisadores e profissionais da saúde tenham acesso a um conjunto abrangente de informações para fins de diagnóstico, monitoramento clínico e investigação científica. Dessa

forma, a utilização de softwares especializados para manipulação de imagens no formato DICOM não apenas facilita a análise visual e quantitativa das estruturas anatômicas e funcionais, mas também contribui para a implementação de técnicas avançadas de processamento digital de imagens. Essas técnicas incluem realce de contraste, segmentação, quantificação de biomarcadores e aplicação de métodos computacionais baseados em inteligência artificial, ampliando as possibilidades de extração de conhecimento a partir dos dados adquiridos (BIDGOOD; HORII, 1992).

Na medicina nuclear oncológica, o uso do formato DICOM é particularmente vantajoso, pois combina imagens e metadados clínicos essenciais, como informações do paciente, protocolos de aquisição e parâmetros de dosimetria. Essa integração facilita o diagnóstico preciso, o planejamento terapêutico e o acompanhamento de pacientes oncológicos, permitindo que imagens de tomografia por emissão de pósitrons (PET) ou cintilografias sejam compartilhadas entre diferentes sistemas. Além disso, o formato DICOM garante a segurança e padronização dos dados, possibilitando a rastreabilidade e a comparação de imagens ao longo do tempo, um fator crucial para monitorar a evolução de tumores e avaliar a eficácia dos tratamentos (LIM; KIM; CHUNG, 2010).

Para a análise das imagens, foram utilizados softwares de visualização DICOM, como o *RadiAnt DICOM Viewer*, que suporta múltiplos tipos de arquivos DICOM e oferece ferramentas básicas para manipulação e medição de imagens, incluindo ampliação, ajuste de brilho e contraste, e medições de comprimento e ângulo (KURZ, 2025).

A utilização desses softwares e do padrão DICOM assegura a qualidade e a integridade das imagens médicas, permitindo uma análise detalhada e precisa, essencial para o diagnóstico e tratamento eficazes na medicina nuclear oncológica.

Através do exame de PET, permite-se a aquisição de imagens do corpo completo, sendo ele particionado em intervalos de tempo igual de aquisição de imagens. O procedimento envolve a administração de um radiofármaco, geralmente marcado com *18F-fluordesoxiglicose* ^{18}F -FDG, que se distribui pelo organismo de acordo com o metabolismo celular. Após um período de espera para que o radiofármaco seja absorvido pelos tecidos-alvo, o paciente é posicionado no equipamento de PET/CT, que realiza primeiramente uma tomografia computadorizada para obtenção de imagens anatômicas detalhadas. Em seguida, a detecção da radiação emitida pelos pósitrons permite a formação das imagens funcionais, destacando regiões de maior atividade metabólica. A integração das imagens anatômicas e funcionais facilita a identificação de anomalias, permitindo uma avaliação mais precisa e completa. Quando a dosagem do marcador é reduzida, o tempo de aquisição de imagem é necessário ser elevado como medida de compensação. O presente estudo busca evidenciar a importância de técnicas de processamento de imagens com marcadores e tempo de aquisição reduzido, demonstrando sua eficiência neste tipo de aplicação. Todos os dados dos pacientes selecionados apresentam a capacidade de interpretação nos planos

anatômicos amplamente utilizados em exames de imagem oncológicos: coronal, sagital e axial, descritos nas Figuras 6 - 8, respectivamente. O plano axial (ou transverso) secciona o corpo horizontalmente, fornecendo imagens em cortes superiores e inferiores, sendo crucial para localizar massas tumorais em relação aos órgãos adjacentes. O plano coronal divide o corpo em porções anterior e posterior, permitindo visualizar a extensão de lesões em profundidade e sua relação com estruturas frontais e dorsais. Já o plano sagital separa o corpo em metades esquerda e direita, possibilitando a análise lateral das massas tumorais e sua invasão em tecidos vizinhos. O uso combinado desses planos permite uma avaliação tridimensional das neoplasias, facilitando o planejamento terapêutico, como cirurgias e radioterapias, e o monitoramento da resposta ao tratamento oncológico. Por meio de um diretório, as imagens são armazenadas e, posteriormente, é realizada a separação das áreas em que o radiofármaco se apresentava mais marcante, ou seja, onde há presença de lesão diagnosticada. Uma vez localizadas no diretório individual de cada paciente, as mesmas são reconhecidas pelo algoritmo de aquisição e tratamento de imagens. As imagens originais são agrupadas em uma matriz de dados, resultando em todas com dimensões iguais. Todas as imagens, por padronização, são convertidas em escala cinza, a partir deste ponto é realizada a centralização dos dados para a subtração a média de cada variável do conjunto de dados, garantindo que o novo conjunto de dados tenha uma média zero.

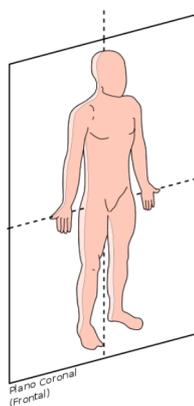


Figura 6 – Plano coronal dividindo o corpo nas porções anterior (frente) e posterior (costas).

4.2 Metodologia Baseada em PCA para Extração de Características

O primeiro passo do processo consiste na definição do diretório onde as imagens no formato DICOM estão armazenadas. Essa etapa é essencial para garantir que o sistema possa acessar corretamente os arquivos de imagem que serão analisados. O diretório deve ser especificado de forma absoluta ou relativa, permitindo que os algoritmos subsequentes processem os dados adequadamente.

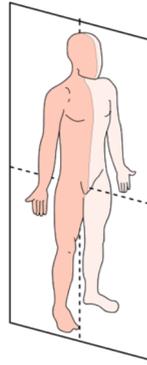


Figura 7 – Plano sagital dividindo o corpo nas porções esquerda e direita.

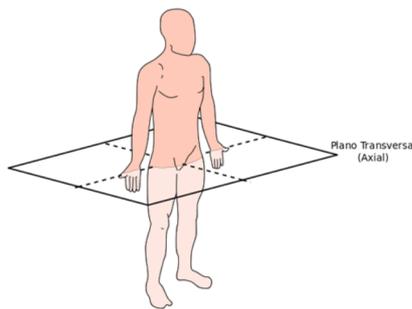


Figura 8 – Plano axial dividindo o corpo nas porções cranial (superior) e caudal (inferior)

Após a definição do diretório, é necessário obter a lista de arquivos DICOM presentes na pasta especificada. Esse procedimento permite identificar as imagens disponíveis para processamento, garantindo que apenas arquivos compatíveis sejam considerados. AO mapeamento detalhado dos arquivos é essencial para viabilizar um carregamento de imagens ágil por meio de processos sistematizados, possibilitando a aplicação dos métodos de análise em um conjunto de dados estruturado.

Com a lista de arquivos DICOM obtida, inicializa-se uma estrutura de dados tridimensional para armazenar as imagens. Cada imagem será representada por uma matriz bidimensional de intensidades de pixel, e o conjunto de todas as imagens será organizado em uma estrutura 3D. Essa abordagem facilita o processamento conjunto das imagens, permitindo a aplicação de métodos matemáticos e estatísticos que operam sobre todas as instâncias simultaneamente.

Nesta etapa, cada arquivo DICOM listado é lido e armazenado no matriz tridimensional previamente inicializada. Esse carregamento garante que os dados estejam disponíveis na memória para as operações subsequentes. A leitura das imagens é realizada iterativamente, assegurando que todas as instâncias sejam corretamente processadas e armazenadas para análise.

Caso as imagens carregadas estejam em formato colorido (RGB, do inglês *red*,

green, blue), é necessário convertê-las para a escala de cinza. Esse procedimento reduz a complexidade dos dados, eliminando a necessidade de processar múltiplos canais de cor e permitindo que os algoritmos operem sobre uma única matriz de intensidades. A conversão para escala de cinza é fundamental para padronizar os dados antes da aplicação de técnicas de análise matemática.

Uma vez que as imagens estejam devidamente carregadas e formatadas, aplica-se a Decomposição em Valores Singulares (SVD). Esse método matemático permite representar os dados em um novo espaço de características, decompondo a matriz de imagens em três componentes principais: *matrizes* U , S e Z (matriz de dados, matriz de mistura e mistura de saída, respectivamente). Essa decomposição facilita a identificação das características mais relevantes do conjunto de imagens, possibilitando a redução de dimensionalidade sem perda significativa de informação.

Com a SVD aplicada, os dados são transformados de acordo com os componentes principais selecionados. Esse processo visa reduzir a dimensionalidade do conjunto de dados, mantendo apenas as informações mais relevantes. A transformação dos dados é uma etapa essencial para compressão de imagens e análise estatística, garantindo que as representações geradas sejam fiéis às imagens originais.

Antes de prosseguir com as análises, é recomendável visualizar a primeira imagem original do conjunto de dados, permitindo validar o carregamento correto das imagens e servindo como referência para comparações futuras. A exibição da imagem original possibilita a avaliação qualitativa dos dados antes da aplicação dos métodos de redução de dimensionalidade.

Para compreender melhor a transformação dos dados, é útil visualizar os primeiros componentes principais extraídos pela SVD. Esses componentes representam as características mais significativas das imagens e fornecem uma interpretação matemática da estrutura dos dados. A visualização dos componentes principais facilita a análise da contribuição de cada dimensão para a reconstrução das imagens.

Por fim, a primeira imagem reconstruída a partir dos componentes principais selecionados deve ser exibida. Essa reconstrução permite avaliar a fidelidade da transformação dos dados e verificar se a redução de dimensionalidade preservou as informações essenciais da imagem original. Além disso, a comparação entre a imagem original e a reconstruída possibilita a quantificação da perda de informação e a validação da eficácia da abordagem utilizada.

Na Tabela 1 são observadas as etapas do fluxo de trabalho de análise de imagens DICOM, as quais foram descritas nessa seção.

A análise de imagens DICOM por meio da Decomposição em Valores Singulares (SVD) oferece uma metodologia robusta para extrair informações valiosas de dados médicos.

Tabela 1 – Fluxo de Trabalho de Análise de Imagens DICOM

Etapa
1. Leitura das imagens DICOM: Lista de arquivos DICOM.
2. Inicialização da Matriz 3D: Array 3D vazio.
3. Carregamento das imagens: Matriz 3D preenchido com as imagens.
4. Conversão para escala de cinza: Matriz 3D com imagens em escala de cinza.
5. Decomposição em valores singulares (SVD): Matrizes U, S e V.
6. Transformação dos dados: Dados transformados usando os componentes principais.
7. Visualização da imagem original: Imagem original exibida.
8. Visualização dos componentes principais: Componentes principais exibidos.
9. Visualização da imagem reconstruída: Imagem reconstruída exibida.

Ao organizar as imagens em um formato tridimensional e aplicar a SVD, é possível decompor as imagens em seus componentes principais, permitindo a identificação de padrões, a redução de dimensionalidade e a reconstrução das imagens com base em informações essenciais. Este processo possibilita a visualização das componentes mais proeminentes das imagens, auxiliando na interpretação e no diagnóstico. Adicionalmente, a reconstrução da imagem original a partir dos componentes principais demonstra a capacidade da SVD em representar as imagens de forma eficiente e concisa, abrindo caminho para aplicações como compressão de imagens e análise de dados em larga escala. Em suma, a análise de imagens DICOM via SVD representa uma ferramenta poderosa no campo da medicina, contribuindo para a melhoria do diagnóstico, tratamento e compreensão de diversas condições médicas.

4.3 Avaliação Multicritério da Qualidade de Imagem

Para avaliação da qualidade das imagens originais e reconstruídas pelo PCA proposto, desenvolveu-se um sistema de ranqueamento baseado nas métricas de avaliação. Essa metodologia de avaliação utiliza métrica na análise de qualidade de imagens: PSNR (*Peak Signal-to-Noise Ratio*), SSIM (*Structural Similarity Index*), MSE (*Mean Squared Error*), MAE (*Mean Absolute Error*) e Entropia.

4.3.1 Erro Quadrático Médio (MSE)

O Erro Quadrático Médio (MSE, do inglês *Mean Squared Error*) constitui uma métrica amplamente empregada na avaliação da discrepância entre duas imagens, com formulação matemática dada por:

$$\text{MSE} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (I(i, j) - K(i, j))^2 \quad (4.1)$$

onde $I(i, j)$ denota o valor de intensidade do pixel na posição (i, j) da imagem original, $K(i, j)$ representa o valor correspondente do pixel na imagem processada, e M e N

correspondem às dimensões da imagem em termos de altura e largura, respectivamente. O MSE quantifica o erro quadrático entre os valores de intensidade dos pixels das duas imagens, atribuindo maior peso a diferenças mais significativas. Um valor reduzido de MSE indica uma maior similaridade entre as imagens, enquanto um valor elevado reflete uma maior divergência entre elas (LEMOS; CAMINHAS; GOMIDE, 2010).

4.3.2 Erro Absoluto Médio (MAE)

O Erro Absoluto Médio (MAE, do inglês *Mean Absolute Error*) constitui uma métrica utilizada para quantificar a diferença média absoluta entre os valores de intensidade dos pixels de duas imagens. A formulação matemática do MAE é expressa pela seguinte equação:

$$MAE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |I(i, j) - K(i, j)| \quad (4.2)$$

em que $I(i, j)$ denota o valor de intensidade do pixel na posição (i, j) da imagem original, $K(i, j)$ corresponde ao valor de intensidade do pixel na mesma posição da imagem processada, e M e N representam as dimensões da imagem em termos de número de linhas e colunas, respectivamente (SZELISKI, 2022).

Diferentemente do MSE, o MAE calcula a diferença absoluta entre os valores de intensidade dos pixels, sem realizar a operação de quadratura. Consequentemente, o MAE é menos sensível a *outliers*, ou seja, a grandes discrepâncias locais entre os valores de intensidade dos pixels. Essa característica faz com que o MAE reflita de maneira mais fidedigna a diferença média real entre as duas imagens analisadas. Valores reduzidos de MAE indicam uma maior similaridade visual entre as imagens, sugerindo que a imagem processada apresenta uma aproximação mais precisa em relação à imagem original (MORETTIN; TOLOI, 2018).

4.3.3 Índice de Similaridade Estrutural (SSIM)

O Índice de Similaridade Estrutural (SSIM, do inglês *Structural Similarity Index*) constitui uma métrica amplamente utilizada para avaliar a similaridade estrutural entre duas imagens, considerando parâmetros fundamentais como luminância, contraste e estrutura (WANG et al., 2004). A formulação matemática do SSIM é expressa da seguinte forma:

$$SSIM(I, K) = \frac{(2\mu_I\mu_K + C_1)(2\sigma_{IK} + C_2)}{(\mu_I^2 + \mu_K^2 + C_1)(\sigma_I^2 + \sigma_K^2 + C_2)}, \quad (4.3)$$

em que μ_I e μ_K representam as médias de intensidade das imagens I e K , respectivamente; σ_I e σ_K denotam as variâncias das imagens; e σ_{IK} corresponde à covariância entre I e K . As constantes C_1 e C_2 são introduzidas na equação com o propósito de garantir estabilidade numérica, evitando instabilidades matemáticas decorrentes de divisões por valores próximos de zero. O valor do SSIM situa-se no intervalo de -1 a 1 , sendo que valores próximos de 1 indicam uma elevada similaridade estrutural entre as imagens analisadas (BOVIK, 2010).

4.3.4 Relação Sinal-Ruído de Pico (PSNR)

A Relação Sinal-Ruído de Pico (PSNR, do inglês *Peak Signal-to-Noise Ratio*) é uma métrica amplamente empregada na avaliação da qualidade de imagens e vídeos, servindo como indicador da diferença entre uma imagem original e sua versão reconstruída ou comprimida. Expresso em decibéis (dB), o PSNR quantifica a relação entre a potência máxima do sinal e a potência do ruído de erro presente na imagem (BOVIK, 2009). A formulação matemática do PSNR é definida pela seguinte equação:

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{(R_{\max})^2}{\text{MSE}} \right), \quad (4.4)$$

em que R_{\max} representa o valor máximo possível de um pixel (tipicamente 255 para imagens com 8 bits por canal) e MSE denota o erro quadrático médio (*Mean Squared Error*) entre as imagens original e reconstruída, conforme descrito na Equação 5.1. O PSNR é amplamente utilizado como métrica de referência para a avaliação da qualidade visual, sendo que valores mais elevados indicam uma menor discrepância entre as imagens e, conseqüentemente, uma melhor qualidade de reconstrução (GONZALEZ; WOODS, 2000).

A aplicação do PSNR é particularmente relevante em contextos de compressão de imagens, como nos padrões JPEG e em codificação de vídeo, nos quais é essencial equilibrar a redução do tamanho do arquivo com a preservação da qualidade visual. No entanto, o PSNR apresenta limitações intrínsecas, especialmente no que diz respeito à capacidade de refletir a percepção humana da qualidade visual. Isso ocorre porque o PSNR não considera aspectos perceptuais, como a sensibilidade do sistema visual humano a detalhes em regiões de alta frequência espacial. Em virtude dessas limitações, métricas alternativas, como o SSIM, têm sido propostas para complementar o PSNR, oferecendo uma avaliação mais alinhada com a percepção subjetiva de qualidade (WANG et al., 2004).

4.3.5 Entropia

A entropia é um conceito que teve origem na Termodinâmica e foi, posteriormente, adaptado à teoria da informação (SHANNON; WEAVER, 1949). No âmbito da ciência de

dados, a entropia é uma medida quantitativa da incerteza ou da quantidade de informação presente em uma fonte de dados. Matematicamente, a entropia $H(X)$ de uma variável aleatória discreta X , com n estados possíveis x_i e probabilidades associadas $P(x_i)$, é definida pela seguinte expressão:

$$H(X) = - \sum_{i=1}^n P(x_i) \log_b P(x_i) \quad (4.5)$$

onde b representa a base do logaritmo, frequentemente escolhida como 2, o que resulta em uma unidade de medida em bits.

No contexto do processamento de imagens, a entropia é empregada para quantificar a complexidade ou o grau de desordem presente em uma imagem. Considerando uma imagem digital como uma matriz de pixels, a entropia pode ser calculada a partir do histograma de intensidades dos pixels, onde $P(x_i)$ denota a probabilidade normalizada de ocorrência da intensidade x_i . Dessa forma, a entropia de uma imagem I pode ser expressa como:

$$H(I) = - \sum_{i=1}^L P(x_i) \log_2 P(x_i) \quad (4.6)$$

sendo L o número de níveis de intensidade (por exemplo, 256 em imagens de 8 bits).

Na área de Medicina Nuclear, particularmente em imagens de PET/CT, a entropia é aplicada para analisar padrões metabólicos e caracterizar anomalias. Por exemplo, a entropia auxilia na distinção entre tecidos normais e cancerígenos com base na distribuição de intensidades e na textura das imagens (HARALICK, 1992). Essa abordagem tem se mostrado valiosa para o diagnóstico e o monitoramento de doenças, contribuindo para a precisão e a eficácia dos procedimentos médicos.

Cada uma dessas métricas é responsável por capturar diferentes aspectos relacionados à fidelidade estrutural, precisão pixel a pixel e riqueza de informações das imagens analisadas. O cálculo do ranking considera pesos individuais atribuídos a cada métrica, refletindo sua importância relativa na análise de qualidade para este estudo.

As métricas MSE, MAE, SSIM e PSNR são amplamente empregadas na avaliação da qualidade de imagens processadas, especialmente no contexto das imagens médicas. O MSE e o MAE são medidas quantitativas de erro entre uma imagem original e sua correspondente processada. Enquanto o MSE calcula a média dos quadrados das diferenças entre os pixels correspondentes, o MAE considera a média das diferenças absolutas, fornecendo uma estimativa direta da magnitude do erro. Essas métricas são frequentemente utilizadas na avaliação de distorções introduzidas por algoritmos de compressão e remoção de ruído (*denoising*); entretanto, sua principal limitação reside no fato de não levarem em

consideração aspectos da percepção visual humana, o que pode comprometer sua eficácia na análise de imagens cuja qualidade perceptual é relevante (GONZALEZ, 2009).

O SSIM, por sua vez, avalia a similaridade estrutural entre duas imagens, incorporando aspectos como luminância, contraste e estrutura. Essa métrica tem-se mostrado particularmente eficaz na análise de imagens médicas, onde a preservação das características estruturais é essencial para diagnósticos precisos (WANG et al., 2024).

O PSNR, expresso em decibéis (dB), quantifica a razão entre o pico do sinal máximo possível e o ruído presente na imagem processada. Valores mais elevados de PSNR indicam menor degradação da imagem e, conseqüentemente, melhor qualidade visual. Embora essa métrica não leve em consideração diretamente a percepção visual humana, ela tem sido amplamente adotada na avaliação da qualidade de imagens reconstruídas devido à sua simplicidade e à correlação razoável com outras métricas objetivas (HORE; ZIOU, 2010).

No âmbito das imagens médicas, como aquelas obtidas por PET, a preservação da integridade das informações estruturais é de fundamental importância. Estratégias de redução da dose de radiofármacos são frequentemente empregadas para minimizar a exposição do paciente à radiação, sem comprometer a qualidade diagnóstica da imagem (ARABI; ZAIDI, 2020). Nesse contexto, a Análise de Componentes Principais (PCA) tem sido aplicada para reduzir ruídos, comprimir dados sem perdas significativas de informação e facilitar a segmentação de estruturas relevantes. A PCA permite a extração de padrões essenciais, mesmo em cenários de aquisição com baixa qualidade, otimizando a relação entre a dose de radiação e a qualidade da imagem (JOLLIFFE; CADIMA, 2016).

A entropia possui uma ampla gama de aplicações no campo do processamento de imagens, desempenhando um papel essencial em diversas técnicas e algoritmos. Dentre as principais aplicações, destacam-se a compressão de imagens, a análise de textura, o realce de contraste e a segmentação e detecção de bordas (COVER, 1999).

A compressão de imagens é uma das aplicações mais relevantes da entropia. Técnicas como o padrão JPEG utilizam a entropia para eliminar redundâncias nos dados, reduzindo o tamanho dos arquivos sem comprometer significativamente a qualidade perceptual da imagem. Esse processo permite a eficiência no armazenamento e transmissão de imagens digitais (WALLACE, 1991).

Na análise de textura, a entropia local é empregada para descrever padrões de textura em imagens, sendo amplamente utilizada na segmentação de imagens biomédicas e na caracterização de tecidos. Esse método possibilita a identificação de regiões homogêneas e a classificação de diferentes estruturas com base em seus padrões texturais (HARALICK; DINSTEN, 1973).

O realce de contraste é outra aplicação importante da entropia no processamento de imagens. Métodos baseados em entropia ajustam os níveis de intensidade dos pixels com o

objetivo de maximizar a informação visual em imagens com baixo contraste. Esse processo é especialmente útil em imagens médicas, onde o aumento da visibilidade de estruturas anatômicas pode contribuir para diagnósticos mais precisos (GONZALEZ, 2009).

Por fim, a segmentação e a detecção de bordas também fazem uso da entropia. Algoritmos de segmentação baseados em entropia são empregados para identificar regiões homogêneas e realçar bordas em imagens, como no método de Otsu. Esse tipo de abordagem é amplamente utilizado em aplicações biomédicas e na análise de imagens naturais (OTSU, 1979).

Em imagens PET, a perda de informações clínicas relevantes pode inviabilizar diagnósticos precisos, tornando-se um desafio crítico. No entanto, estudos indicam que a aplicação de técnicas como a PCA possibilita a atenuação do ruído e a compressão dos dados, preservando características estruturais as quais fundamentais para a interpretação clínica (READER; ZAIDI, 2007). Dessa forma, imagens obtidas com doses reduzidas de radiofármacos, quando processadas adequadamente, podem manter um nível aceitável de qualidade, reforçando a viabilidade da técnica para aplicações médicas.

Essa abordagem de ranqueamento facilita a comparação objetiva entre as imagens originais e reconstruídas, priorizando aquelas que preservam melhor os padrões estruturais e as características informacionais. Além disso, o uso de métricas diversificadas garante uma análise robusta, capaz de captar tanto as diferenças perceptíveis ao olho humano quanto as discrepâncias quantitativas mais sutis, promovendo maior rigor e confiabilidade nos resultados obtidos.

A metodologia desenvolvida foi projetada para receber como entrada as imagens original e reconstruída, além dos pesos previamente atribuídos a cada métrica, permitindo flexibilidade na priorização de diferentes critérios de qualidade de imagem, conforme, o contexto da análise. Após processar os dados, a função retorna o valor do ranking combinado, que serve como uma métrica unificada e quantitativa da qualidade da imagem reconstruída em relação à original. Esse ranking permite uma interpretação mais intuitiva e integrada da similaridade entre as imagens, consolidando as contribuições individuais de cada métrica em uma única saída. Para garantir que todas as métricas estejam em escalas comparáveis, foi realizada uma normalização conforme descrito a seguir:

- PSNR: Foi dividido pelo valor limite de 50 dB, garantindo uma escala normalizada entre 0 e 1 (conforme Equação 4.7);
- SSIM: Já se encontra em uma escala normalizada entre 0 e 1 (conforme Equação 4.8);
- MSE: Foi normalizado pelo valor máximo teórico, definido como $MSE_{\max} = 255^2$ para imagens de 8 bits (conforme Equação 4.8);

- MAE: Foi normalizado pelo valor máximo teórico de 255 (conforme Equação 4.9);
- Diferença de Entropia: Foi normalizada pela entropia máxima teórica de 8 para imagens de 8 bits (conforme Equação 4.10).

Desta forma, as equações de normalização podem ser expressas como:

$$\text{PSNR}_{\text{norm}} = \min \left(\frac{\text{PSNR}}{50}, 1 \right) \quad (4.7)$$

$$\text{MSE}_{\text{norm}} = \min \left(\frac{\text{MSE}}{255^2}, 1 \right) \quad (4.8)$$

$$\text{MAE}_{\text{norm}} = \min \left(\frac{\text{MAE}}{255}, 1 \right) \quad (4.9)$$

$$\text{Entropia}_{\text{norm}} = \min \left(\frac{\Delta E}{8}, 1 \right) \quad (4.10)$$

onde

$$\Delta E = |\text{Entropia}_{\text{original}} - \text{Entropia}_{\text{reconstruída}}| \quad (4.11)$$

O ranking combinado é calculado como uma média ponderada das métricas normalizadas.

$$\text{Ranking} = w_1 \cdot \text{PSNR}_{\text{norm}} + w_2 \cdot \text{SSIM}_{\text{norm}} + w_3 \cdot \text{MSE}_{\text{norm}} + w_4 \cdot \text{MAE}_{\text{norm}} + w_5 \cdot \text{Entropia}_{\text{norm}} \quad (4.12)$$

4.3.6 Oriented FAST and Rotated BRIEF

A técnica ORB (*Oriented FAST and Rotated BRIEF*) constitui um dos métodos mais amplamente empregados na área de visão computacional para a detecção e descrição de pontos de interesse em imagens. Desenvolvida por Rublee et al. (2011), a abordagem combina o detector de cantos FAST (*Features from Accelerated Segment Test*) com o descritor BRIEF (*Binary Robust Independent Elementary Features*), incorporando aprimoramentos que aumentam sua robustez frente a rotações e variações de iluminação. Diferentemente de métodos mais complexos, como o SIFT (*Scale-Invariant Feature Transform*) e o SURF (*Speeded-Up Robust Features*), o ORB apresenta um desempenho computacional significativamente mais eficiente, além de ser invariante a transformações

de escala e rotação, características essenciais para aplicações em tempo real (RUBLEE et al., 2011).

O ORB tem sido amplamente empregado em diversas áreas, incluindo reconhecimento de objetos, reconstrução tridimensional, navegação de robôs autônomos e realidade aumentada (TAREEN; SALEEM, 2018). No contexto de reconhecimento de padrões, sua capacidade de identificar características distintivas em imagens possibilita a correspondência precisa entre diferentes capturas de uma mesma cena, tornando-o uma ferramenta valiosa para aplicações em monitoramento, análise biomédica e inspeção industrial (ROSTEN; DRUMMOND, 2006).

O algoritmo FAST identifica pontos de interesse verificando a intensidade de pixels vizinhos em torno de um pixel candidato p . O critério baseia-se na comparação com um limiar I_p (RUBLEE et al., 2011):

- Seja I_p a intensidade do pixel candidato;
- Seja I_x a intensidade de um pixel vizinho localizado em um círculo de raio fixo (geralmente 3 pixels);
- Um pixel p é considerado um canto se ao menos n pixels consecutivos no círculo forem mais brilhantes que $I_p + t$ ou mais escuros que $I_p - t$, onde t é um limiar ajustável.

Para otimizar essa seleção, o ORB utiliza uma variante chamada FAST em pirâmide, melhorando a robustez contra escala.

Diferentemente do FAST, que não calcula orientação, o ORB emprega momentos de Harris para definir uma orientação dominante θ (HARRIS; STEPHENS, 1988). Esse ângulo é obtido a partir dos momentos de ordem um:

$$m_{10} = \sum xI(x, y), \quad m_{01} = \sum yI(x, y) \quad (4.13)$$

O ângulo de orientação do ponto é definido como:

$$\theta = \arctan\left(\frac{m_{01}}{m_{10}}\right) \quad (4.14)$$

O BRIEF original gera um vetor binário comparando pares de pixels escolhidos aleatoriamente dentro de uma janela ao redor do ponto de interesse. O ORB modifica o BRIEF introduzindo a compensação de rotação:

- Para cada ponto detectado, um conjunto de pares de pixels $(x_i, y_i), (x_j, y_j)$ é rotacionado pelo ângulo θ , resultando em novas posições (CALONDER et al., 2010):

$$x'_i = x_i \cos(\theta) - y_i \sin(\theta), \quad y'_i = x_i \sin(\theta) + y_i \cos(\theta) \quad (4.15)$$

O vetor binário é obtido comparando as intensidades dos pixels rotacionados:

$$f_k = \begin{cases} 1, & I(x'_i, y'_i) < I(x'_j, y'_j) \\ 0, & \text{caso contrário} \end{cases} \quad (4.16)$$

Os vetores ORB podem ser comparados utilizando a distância de Hamming, que é definida como o número de bits diferentes entre dois vetores binários:

$$d_H(A, B) = \sum_{i=1}^n A_i \oplus B_i \quad (4.17)$$

4.4 Análise Visual: Resultados e Interpretações

A avaliação visual das imagens originais e reconstruídas, conduzida pela equipe médica do Hospital São Domingos, foi baseada em um sistema de ranking que varia de 0 a 1, conforme detalhado anteriormente. Esse sistema de classificação foi desenvolvido para fornecer uma análise objetiva da qualidade das imagens, permitindo a categorização das mesmas em diferentes níveis, desde inaceitável até excelente. Cada imagem foi avaliada de acordo com métricas específicas, como nitidez, contraste e fidelidade de cores, que são fundamentais para determinar a adequação das imagens para diagnósticos médicos. A nitidez, por exemplo, foi analisada para verificar a clareza e definição dos detalhes anatômicos, enquanto o contraste foi examinado para garantir a distinção adequada entre áreas de diferentes intensidades, facilitando a identificação de estruturas e anomalias. A fidelidade de cores, por sua vez, foi fundamental para verificar a precisão cromática das imagens, um fator especialmente relevante em exames que exigem alta precisão, como na análise de imagens PET/CT. O sistema de ranking permitiu, assim, a classificação das imagens em cinco categorias distintas, proporcionando uma avaliação abrangente que reflete a qualidade visual e a utilidade das imagens no contexto clínico. Dessa forma, a equipe médica pôde realizar uma análise crítica da metodologia proposta, levando em consideração não apenas a qualidade visual das imagens, mas também sua aplicabilidade e confiabilidade para uso diagnóstico.

4.4.1 Nitidez

A nitidez de uma imagem refere-se à sua clareza e à definição dos detalhes que compõem a cena. Imagens com alta nitidez permitem a visualização precisa de contornos, texturas e estruturas, aspecto essencial para diagnósticos médicos confiáveis. Quando a nitidez é baixa (valores próximos de 0), pode haver dificuldades na identificação de

anomalias ou detalhes sutis. Por outro lado, uma nitidez elevada (valores próximos de 1) facilita a interpretação e análise, tornando possível distinguir melhor entre diferentes estruturas. Em exames médicos, como radiografias e ressonâncias magnéticas, a nitidez desempenha um papel fundamental na diferenciação entre tecidos saudáveis e patológicos (SMITH, 2018).

4.4.2 Contraste

O contraste mede a discrepância entre as regiões claras e escuras da imagem. Um contraste adequado melhora a distinção entre diferentes tecidos e estruturas. Valores baixos de contraste podem resultar em imagens com aparência desbotada, onde os detalhes são pouco perceptíveis, enquanto um contraste excessivo pode mascarar informações importantes ao saturar certas áreas (JONES, 2015). Em imagens médicas, a calibração do contraste é essencial para identificar anomalias, como tumores e lesões, que poderiam passar despercebidos sem um ajuste adequado (LEE, 2020).

4.4.3 Fidelidade de Cores

A fidelidade de cores refere-se à precisão com que as cores da imagem representam as cores reais da cena capturada. No contexto médico, isso envolve a correta representação de tecidos, fluidos e outras estruturas biológicas. Uma baixa fidelidade de cores (valores próximos de 0) pode levar a interpretações errôneas, enquanto uma alta fidelidade (valores próximos de 1) assegura que as cores sejam representadas com exatidão (BROWN, 2019). Exames como endoscopias e imagens patológicas dependem de uma reprodução fiel das cores para a correta identificação de condições médicas (GARCIA, 2021).

4.4.4 Detecção de Características

A detecção de características refere-se à capacidade de identificar e destacar estruturas e padrões relevantes na imagem, sendo um critério essencial para a análise de imagens médicas. Esse aspecto avalia a precisão com que elementos importantes, como lesões, órgãos e tecidos específicos, são identificados (LI, 2017). Uma detecção eficiente de características permite uma identificação clara de anomalias, aumentando a confiabilidade dos diagnósticos médicos. Imagens com baixa precisão na detecção podem induzir interpretações equivocadas, prejudicando a análise clínica (GUPTA, 2019). Em modalidades como tomografia computadorizada (CT) e ressonância magnética (RM), a detecção precisa de características desempenha um papel crucial na diferenciação entre tecidos normais e patológicos, facilitando a identificação de detalhes sutis que poderiam passar despercebidos em imagens de menor qualidade (LIU, 2021).

A escala de avaliação utilizada para classificar a qualidade das imagens reconstruídas é composta por cinco intervalos, cada um representando um nível distinto de adequação visual. No intervalo de 0 a 0,2, a qualidade é considerada mínima, sendo classificada como inaceitável, o que indica que as imagens são inadequadas para qualquer uso diagnóstico ou análise. Entre 0,2 a 0,4, as imagens apresentam uma qualidade abaixo do esperado, considerada insatisfatória, devido a falhas significativas que comprometem sua utilidade. O intervalo de 0,4 a 0,6 reflete uma qualidade moderada, classificada como aceitável, significando que as imagens são utilizáveis, embora possam necessitar de ajustes ou complementação com outras técnicas. No intervalo de 0,6 a 0,8, as imagens são consideradas de qualidade boa e satisfatória, atendendo às expectativas e sendo adequadas para a maioria das aplicações. Finalmente, valores entre 0,8 a 1 correspondem à qualidade máxima, classificada como excelente, indicando que as imagens são de alta qualidade, ideais para diagnósticos precisos e análises detalhadas.

$$\text{Avaliação} = \frac{\text{Nitidez} + \text{Contras} + \text{Fidelidade} + \text{Detecção}}{4} \quad (4.18)$$

A comparação as imagens originais com as reconstruídas, permite uma avaliação quantitativa e qualitativa das imagens. A utilização de métricas como nitidez, contraste, fidelidade de cores e detecção de características oferece uma análise abrangente, essencial para garantir que as imagens atendam aos padrões necessários para aplicações médicas. A equipe médica do Hospital São Domingos pode utilizar essas métricas para validar a eficácia da metodologia proposta e determinar sua viabilidade em um contexto clínico real.

5 Resultados

Neste capítulo serão apresentados os resultados computacionais e experimentais no sentido de evidenciar a eficiência e aplicabilidade apresentada nesta dissertação.

5.1 Métricas de Avaliação

A fim de determinar a avaliação de qualidade de imagem e a eficácia da reconstrução realizada pelo PCA. A comparação entre a imagem original com a imagem reconstruída permite quantificar a perda de informações durante a redução de dimensionalidade. As métricas definidas buscam avaliar a precisão, fidelidade e semelhanças da reconstrução oferecendo uma medida perceptual da qualidade visual, considerando aspectos como luminância, contraste e estrutura.

5.1.1 Erro Quadrático Médio (MSE)

A tabela 2 apresentada mostra os valores de Erro Quadrático Médio (MSE) obtidos entre a imagem original, proveniente da tomografia por emissão de pósitrons associada à PET/CT, e as imagens reconstruídas utilizando a técnica de PCA. O MSE é uma métrica amplamente utilizada para avaliar a qualidade da reconstrução de imagens, uma vez que quantifica a diferença entre as imagens original e reconstruída.

Os valores de MSE variam significativamente entre os diferentes pacientes, com a maior discrepância observada no Paciente 02, que apresenta um valor de MSE de 3504,876, enquanto o valor mais baixo é observado no Paciente 15, com 262,1478. Essa variação sugere uma diferença considerável na qualidade da reconstrução das imagens para os diferentes indivíduos, possivelmente refletindo aspectos específicos das imagens originais, como a intensidade do sinal, a presença de ruído ou outras características da imagem que afetam a eficácia do PCA na reconstrução.

De maneira geral, a maioria dos valores de MSE se concentra em torno de um intervalo moderado, variando entre 250 e 1000. No entanto, alguns valores mais altos, como os registrados para os Pacientes 01, 02, 23 e 24, indicam que a técnica de PCA pode não ser igualmente eficaz para todas as imagens. Esses casos podem sugerir a necessidade de um ajuste fino no processo de reconstrução ou o uso de técnicas adicionais para melhorar a qualidade das imagens em pacientes com características específicas.

A análise dos valores de MSE destaca a variabilidade da eficácia da reconstrução das imagens PET/CT por meio do PCA entre os pacientes analisados. A presença de valores de MSE elevados para alguns pacientes pode ser indicativa de desafios na aplicação

do PCA para reconstrução de imagens com certos padrões ou características. Estudos futuros podem investigar as causas dessa variabilidade, considerando fatores como o ruído nas imagens originais, a complexidade das estruturas anatômicas dos pacientes e o número de componentes principais utilizados no processo de reconstrução. Além disso, pode ser necessário explorar abordagens alternativas ou modificações no método de PCA para obter uma reconstrução de imagem de maior precisão para todos os casos analisados.

Tabela 2 – Valores de MSE obtido entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA.

Paciente Analisado	MSE
Paciente 00	372,5692
Paciente 01	825,1988
Paciente 02	3504,876
Paciente 03	526,6779
Paciente 04	347,0673
Paciente 05	1051,0181
Paciente 06	308,2664
Paciente 07	343,8718
Paciente 08	302,4636
Paciente 09	364,7466
Paciente 10	287,2543
Paciente 11	282,3733
Paciente 12	340,6753
Paciente 13	338,1754
Paciente 14	292,8392
Paciente 15	262,1478
Paciente 16	290,3797
Paciente 17	285,6258
Paciente 18	289,6125
Paciente 19	625,2443
Paciente 20	272,3421
Paciente 21	283,7891
Paciente 22	278,8552
Paciente 23	1567,548
Paciente 24	568,7839
Paciente 25	337,0273

5.1.2 Erro Absoluto Médio (MAE)

A Tabela 3 apresenta os valores do MAE obtidos a partir da comparação entre as imagens originais provenientes do PET/CT e as imagens reconstruídas por meio da PCA. O MAE é uma métrica de erro que quantifica a diferença média, em termos absolutos, entre os valores dos pixels das imagens analisadas, sendo que valores menores indicam maior similaridade entre a imagem original e a reconstruída.

Os valores de MAE variam consideravelmente entre os pacientes analisados, com valores que vão de 1,6064 a 26,616. O paciente com o menor valor de MAE foi o Paciente 15, com 1,6064, enquanto o maior valor foi registrado pelo Paciente 05, com 26,616. Isso sugere que a reconstrução da imagem pelo PCA apresenta um desempenho desigual, com algumas reconstruções sendo mais precisas do que outras.

A distribuição dos valores de MAE mostra que a maioria dos pacientes apresenta resultados bastante favoráveis, com valores abaixo de 10, sugerindo que a técnica de PCA tem se mostrado eficaz na reconstrução das imagens para a maior parte dos casos. Embora haja alguns pacientes, como os Pacientes 01, 02, 05 e 19, que apresentaram valores mais elevados, isso não impede o potencial de aprimoramento da técnica. Esses resultados indicam que fatores como a qualidade da imagem original, a presença de artefatos ou características anatômicas específicas podem influenciar a precisão da reconstrução, mas também abrem a oportunidade para ajustes que podem tornar a técnica ainda mais robusta e personalizada para diferentes perfis de pacientes. Além disso, os valores de MAE próximos a 2 (como os observados nos Pacientes 00, 04, 10, 11 e 20) indicam um desempenho satisfatório da técnica de PCA na reconstrução da imagem, proporcionando resultados bastante precisos para esses casos.

Em resumo, a análise dos valores de MAE mostra que a técnica de PCA pode ser uma abordagem útil para a reconstrução de imagens PET/CT, mas também revela que sua eficácia pode variar consideravelmente entre diferentes pacientes. Para uma avaliação mais precisa do desempenho do PCA, seria necessário investigar as possíveis causas dos valores discrepantes e explorar estratégias para melhorar a consistência e precisão dos resultados. A adoção de métodos adicionais de processamento ou a otimização dos parâmetros do PCA podem ser alternativas viáveis para minimizar as discrepâncias observadas em alguns casos.

5.1.3 Índice de Similaridade Estrutural (SSIM)

A Tabela 4 apresenta os valores do Índice de Similaridade Estrutural (SSIM) obtidos na comparação entre as imagens originais de PET/CT e as imagens reconstruídas pelo método de PCA. O SSIM é uma métrica amplamente utilizada para avaliar a qualidade de reconstrução de imagens, variando entre 0 e 1, onde valores mais próximos de 1 indicam maior similaridade estrutural entre as imagens comparadas.

Os resultados evidenciam uma variação nos valores de SSIM, indicando diferentes níveis de fidelidade entre as imagens originais e as reconstruídas para cada paciente. O valor do SSIM para a maioria dos pacientes se situa em torno de 0,9 ou mais, o que sugere que as imagens reconstruídas pelo PCA mantêm uma boa qualidade estrutural em comparação com as originais. Entre os pacientes analisados, destacam-se os seguintes casos:

Tabela 3 – Valores de MAE obtido entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA.

Paciente Analisado	MAE
Paciente 00	2,9850
Paciente 01	22,7119
Paciente 02	17,3147
Paciente 03	6,7542
Paciente 04	2,0835
Paciente 05	26,616
Paciente 06	4,5191
Paciente 07	3,4715
Paciente 08	4,5475
Paciente 09	9,0091
Paciente 10	2,7324
Paciente 11	2,3421
Paciente 12	4,6388
Paciente 13	8,1516
Paciente 14	3,5934
Paciente 15	1,6064
Paciente 16	4,8790
Paciente 17	4,1467
Paciente 18	2,8179
Paciente 19	18,1498
Paciente 20	2,1030
Paciente 21	2,6910
Paciente 22	2,1599
Paciente 23	14,3372
Paciente 24	4,4522
Paciente 25	4,1793

- Pacientes com alto SSIM (acima de 0,95): Pacientes 00, 04, 10, 11, 15, 20, 21 e 22 apresentaram valores de SSIM superiores a 0,95, indicando uma reconstrução extremamente fiel à imagem original. Esses valores sugerem que o método PCA, para esses casos, foi altamente eficaz em preservar as características estruturais das imagens PET/CT;
- Pacientes com SSIM moderado (entre 0,7 e 0,8): Pacientes como 01, 02, 03, 13 e 23 apresentaram valores de SSIM na faixa de 0,7 a 0,8, o que pode indicar uma degradação significativa na qualidade da reconstrução, com possível perda de detalhes importantes na imagem reconstruída;
- Pacientes com SSIM abaixo de 0,7: O paciente 06 apresentou um valor de SSIM de 0,6611, o que indica que a reconstrução do PCA, embora um pouco distante da imagem original, mostrou áreas de oportunidade para aprimoramento. Esse resultado sugere que o método ainda tem potencial para ser refinado, visando melhorar a

preservação da qualidade da imagem original e oferecer uma reconstrução mais precisa para este indivíduo específico.

Esses resultados indicam que, embora o PCA seja uma ferramenta promissora para reconstrução de imagens PET/CT, sua eficácia pode variar consideravelmente entre diferentes casos, possivelmente devido a características específicas de cada paciente, como a complexidade dos dados ou a presença de ruídos. Assim, é importante que futuras investigações explorem métodos de otimização do PCA para melhorar a precisão das reconstruções, especialmente nos casos em que o SSIM apresenta valores mais baixos.

A análise dos valores de SSIM entre as imagens originais e reconstruídas sugere que, de modo geral, o PCA é eficaz para a reconstrução de imagens PET/CT, com exceção de alguns casos em que o desempenho do método foi inferior. A variação nos valores de SSIM reflete as possíveis limitações do método em determinadas condições, e a continuidade de estudos é essencial para aprimorar as técnicas de reconstrução e garantir sua aplicabilidade em contextos clínicos variados.

5.1.4 Relação Sinal-Ruído de Pico (PSNR)

A Tabela 5 apresenta os valores de PSNR (Peak Signal-to-Noise Ratio) obtidos entre as imagens originais advindas do PET/CT e as imagens reconstruídas pelo PCA para um conjunto de 26 pacientes analisados. O PSNR é uma métrica amplamente utilizada para avaliar a qualidade de reconstrução de imagens, sendo maior valores indicativos de melhor qualidade na reconstrução, pois refletem menores distorções entre a imagem original e a reconstruída.

Ao observar os valores de PSNR dos pacientes, verifica-se uma variação notável entre os valores mais altos e mais baixos. O paciente 15 obteve o maior valor de PSNR (23,9453), indicando uma reconstrução de imagem com alta fidelidade em relação à imagem original. Em contrapartida, o paciente 02 obteve o menor valor de PSNR (12,6841), sugerindo uma maior discrepância entre a imagem original e a reconstruída, o que pode indicar um desempenho inferior da técnica de PCA para esse caso específico. A média dos valores de PSNR apresenta uma tendência geral de boas reconstruções, com a maioria dos pacientes mostrando valores em torno de 22 a 23, sugerindo que o PCA pode ser eficaz na preservação das características das imagens PET/CT.

A distribuição dos valores de PSNR sugere que, embora a maioria dos casos tenha um desempenho satisfatório, o PCA apresenta variação em sua capacidade de reconstrução de acordo com as características das imagens PET/CT de cada paciente.

Os resultados obtidos indicam que o PCA oferece um bom desempenho na reconstrução das imagens PET/CT, embora com variações significativas que podem ser otimizadas em futuras abordagens ou ajustes nos algoritmos de reconstrução.

Tabela 4 – Valores de SSIM obtido entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA.

Paciente Analisado	SSIM
Paciente 00	0,9690
Paciente 01	0,7025
Paciente 02	0,7787
Paciente 03	0,6371
Paciente 04	0,9709
Paciente 05	0,9174
Paciente 06	0,6611
Paciente 07	0,9504
Paciente 08	0,6784
Paciente 09	0,9447
Paciente 10	0,9677
Paciente 11	0,9730
Paciente 12	0,8590
Paciente 13	0,7113
Paciente 14	0,9469
Paciente 15	0,9752
Paciente 16	0,9469
Paciente 17	0,6980
Paciente 18	0,9628
Paciente 19	0,8628
Paciente 20	0,9750
Paciente 21	0,9634
Paciente 22	0,9670
Paciente 23	0,8167
Paciente 24	0,8418
Paciente 25	0,8655

5.1.5 Entropia

A Tabela 6 apresenta os valores de entropia calculados entre a imagem original adquirida por PET/CT e a imagem reconstruída por PCA, com os respectivos percentuais de entropia em relação ao valor máximo observado. A entropia é uma medida que quantifica a incerteza ou a quantidade de informação presente nas imagens, refletindo a complexidade ou a dispersão dos dados.

Observa-se que a maioria dos pacientes apresentou valores baixos de entropia, indicando uma reconstrução eficiente das imagens, com pouca perda de informação no processo. Por exemplo, para os Pacientes 00, 04 e 05, os valores de entropia foram extremamente baixos (0,007351, 0,006031 e 0,0053, respectivamente), com percentuais inferiores a 1%. Esses resultados sugerem que a reconstrução pelo PCA preservou adequadamente as características relevantes das imagens originais.

Além disso, um padrão de valores de entropia intermediários foi identificado, como

Tabela 5 – Valores de PSNR obtido entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA.

Paciente Analisado	PSNR
Paciente 00	22,4187
Paciente 01	18,9652
Paciente 02	12,6841
Paciente 03	20,9154
Paciente 04	22,7267
Paciente 05	17,9147
Paciente 06	23,2415
Paciente 07	22,7668
Paciente 08	23,3241
Paciente 09	22,5109
Paciente 10	23,5481
Paciente 11	23,6226
Paciente 12	22,8074
Paciente 13	22,8394
Paciente 14	23,4645
Paciente 15	23,9453
Paciente 16	23,5011
Paciente 17	23,5728
Paciente 18	23,5126
Paciente 19	20,1703
Paciente 20	23,7787
Paciente 21	23,6008
Paciente 22	23,6770
Paciente 23	18,0226
Paciente 24	21,4694
Paciente 25	23,2752

observado nos Pacientes 01, 06 e 16, cujos percentuais de entropia variam entre 8% e 9%. Embora esses valores indiquem uma certa perda de informação, ainda estão dentro de uma faixa aceitável, sugerindo que a reconstrução do PCA pode ser razoavelmente eficaz, mas com alguma perda de detalhes.

Os resultados indicam que o PCA foi eficaz em reconstruir a maioria das imagens PET/CT, com variações notáveis de desempenho entre os pacientes. A alta entropia observada em alguns casos pode apontar para limitações no processo de reconstrução, que podem estar relacionadas à qualidade ou características específicas das imagens originais ou ao próprio processo de decomposição de componentes principais.

5.2 Avaliação Multicritério da Qualidade de Imagem

Na Tabela 7 são observados os valores do Ranking Combinado obtidos a partir da análise comparativa entre as imagens originais do PET/CT e as imagens reconstruídas

Tabela 6 – Valores de Entropia obtido entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA.

Paciente Analisado	Entropia	Entropia em relação a porcentagem
Paciente 00	0,007351	0,73581 %
Paciente 01	0,093046	9,3046 %
Paciente 02	0,02143	2,134 %
Paciente 03	0,023009	2,3009 %
Paciente 04	0,006031	0,60218 %
Paciente 05	0,0053	0,53 %
Paciente 06	0,81415	8,1415 %
Paciente 07	0,035453	3,5453 %
Paciente 08	0,020046	2,0046 %
Paciente 09	0,018543	1,8543 %
Paciente 10	0,027731	0,7731 %
Paciente 11	0,0038961	0,38961 %
Paciente 12	0,006794	0,6794 %
Paciente 13	0,079763	7,9763 %
Paciente 14	0,079763	7,9763 %
Paciente 15	0,017082	1,7082 %
Paciente 16	0,094374	9,4374 %
Paciente 17	0,012241	1,2241 %
Paciente 18	0,029995	2,9995 %
Paciente 19	0,028975	2,8975 %
Paciente 20	0,0077468	0,77468 %
Paciente 21	0,0088776	0,88776 %
Paciente 22	0,049669	4,9669 %
Paciente 23	0,040609	4,0609 %
Paciente 24	0,011446	1,1446 %
Paciente 25	0,022110,	2,2106 %

por PCA. Os pesos atribuídos a cada métrica foram definidos empiricamente como $w = [0.19, 0.75, 0.005, 0.005, 0.05]$ para PSNR, SSIM, MSE, MAE e diferença de entropia, respectivamente. A entropia, que quantifica a incerteza ou a quantidade de informação em uma imagem, foi calculada para cada paciente, e a porcentagem correspondente foi calculada em relação ao valor máximo de entropia observado.

Os valores de entropia variaram consideravelmente entre os pacientes. O valor mais baixo de entropia foi registrado para o Paciente 05 (0,0053), o que indica uma imagem reconstruída com pouca variação em relação à original. Em contraste, o Paciente 06 apresentou o maior valor de entropia (0,81415), sugerindo que a imagem reconstruída apresenta uma maior dispersão de informações em comparação com a imagem original.

A maioria dos pacientes apresentou valores de entropia abaixo de 0,1, com exceção dos Pacientes 01, 06, 16, e 13, cujos valores de entropia foram mais elevados. Quando analisados os valores percentuais em relação à entropia máxima, os pacientes com maior dispersão de informações nas imagens reconstruídas foram o Paciente 01 (9,3046%) e o

Paciente 06 (8,1415%).

A entropia percentual oferece uma perspectiva adicional sobre a diferença relativa entre as imagens originais e reconstruídas. Para a maioria dos pacientes, os valores percentuais de entropia ficaram abaixo de 1 %, o que indica que as reconstruções pelo PCA geraram imagens com baixas discrepâncias em relação às imagens originais. Porém, os pacientes com valores percentuais mais altos, como o Paciente 01 e Paciente 06, indicam maior variabilidade entre as imagens, o que pode sugerir que a técnica PCA pode não ser tão eficaz para esses casos, ou que características específicas das imagens dos pacientes exigem um ajuste maior na reconstrução.

Os resultados indicam que a reconstrução das imagens por PCA mantém uma boa congruência com as imagens originais, com exceção de alguns casos onde os valores de entropia são mais elevados. Esses casos podem representar imagens mais complexas ou com características que desafiam a técnica PCA. Além disso, a análise percentual da entropia proporciona uma compreensão mais clara das discrepâncias entre as imagens, permitindo identificar áreas que podem exigir aprimoramento no processo de reconstrução.

5.3 Resultados Avaliativo Visuais

A análise dos dados apresentados na Tabela 8, que expõe os valores da avaliação das métricas visuais entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA, revela variações no desempenho da reconstrução das imagens para os diferentes pacientes analisados.

Observa-se que os valores das médias avaliadas pelo Avalista 1 variam de 0 (Paciente 19) a 0,975 (Pacientes 13 e 21). Essa amplitude sugere que, embora a reconstrução pelo PCA tenha proporcionado resultados relativamente positivos em muitos casos, existem discrepâncias significativas que indicam um desempenho inferior para alguns pacientes, como evidenciado pela avaliação do Paciente 19, cujo valor médio foi de 0.

Por outro lado, a maioria dos pacientes apresenta valores médios acima de 0,7, o que indica uma boa qualidade na reconstrução das imagens. Pacientes como 13 e 21, com a avaliação mais alta, sugerem que o PCA conseguiu preservar melhor os detalhes das imagens nesses casos. Essa variação pode ser atribuída a diferentes fatores, como características específicas das imagens PET/CT originais de cada paciente, a complexidade das reconstruções ou a sensibilidade do PCA a diferentes características dessas imagens.

Além disso, os pacientes cujas médias ficam entre 0,7 e 0,8, como os Pacientes 00, 01, 02, 04, 07 e outros, indicam que a reconstrução via PCA oferece um desempenho adequado para a maioria dos casos, embora haja espaço para melhorias.

A análise sugere que o uso do PCA na reconstrução de imagens PET/CT é eficaz

Tabela 7 – Valores de Ranking obtido entre a Imagem Original advinda do PET/CT e a Imagem Reconstituída pelo PCA.

Paciente Analisado	Ranking Combinado
Paciente 00	0,86488
Paciente 01	0,19096
Paciente 02	0,70697
Paciente 03	0,59332
Paciente 04	0,86762
Paciente 05	0,19403
Paciente 06	0,62188
Paciente 07	0,85139
Paciente 08	0,63602
Paciente 09	0,29812
Paciente 10	0,86833
Paciente 11	0,87290
Paciente 12	0,77845
Paciente 13	0,28694
Paciente 14	0,78273
Paciente 15	0,87597
Paciente 16	0,50537
Paciente 17	0,65268
Paciente 18	0,86428
Paciente 19	0,20357
Paciente 20	0,87513
Paciente 21	0,86515
Paciente 22	0,86832
Paciente 23	0,58760
Paciente 24	0,69427
Paciente 25	0,70309

na maioria dos casos, mas apresenta limitações que podem ser mais evidentes em alguns pacientes. A discrepância observada, especialmente nos pacientes com avaliações mais baixas, como o Paciente 19, pode refletir a necessidade de ajustes adicionais no algoritmo de reconstrução, a fim de melhorar a consistência e a qualidade das imagens em uma gama maior de cenários clínicos.

5.4 Resultados Computacionais Visuais

Com base nos resultados obtidos, serão apresentados três casos clínicos distintos de pacientes diagnosticados com lesões cancerígenas em diferentes regiões do corpo, selecionados a partir do banco de dados disponibilizado pelo Hospital São Domingos.

Todos os dados utilizados preservam a privacidade e a confidencialidade dos pacientes, seguindo as diretrizes éticas e legais de proteção das informações pessoais. Esses casos foram selecionados com o objetivo de demonstrar diferentes perfis clínicos e padrões de

Tabela 8 – Valores da Avaliação das métricas visuais entre a Imagem Original advinda do PET/CT e a Imagem Reconstruída pelo PCA.

Paciente Analisado	Média Avalista 1
Paciente 00	0,75
Paciente 01	0,75
Paciente 02	0,75
Paciente 03	0,7
Paciente 04	0,8
Paciente 05	0,7
Paciente 06	0,7
Paciente 07	0,825
Paciente 08	0,875
Paciente 09	0,9
Paciente 10	0,6
Paciente 11	0,725
Paciente 12	0,75
Paciente 13	0,975
Paciente 14	0,95
Paciente 15	0,625
Paciente 16	0,75
Paciente 17	0,8
Paciente 18	0,725
Paciente 19	0
Paciente 20	0,725
Paciente 21	0,975
Paciente 22	0,65
Paciente 23	0,75
Paciente 24	0,75
Paciente 25	0,8

acometimento em órgãos distintos, contribuindo para uma análise abrangente dos processos envolvidos no diagnóstico e tratamento das lesões.

5.4.1 Análise do Paciente 1

Para demonstrar a metodologia apresentada nesta dissertação, foi selecionado o paciente identificado como 04, que apresenta uma lesão localizada na região estomacal. A Figura 9 ilustra a imagem original de PET/CT, no plano axial, servindo como ponto de partida para a análise das componentes principais. O exame de PET/CT do paciente foi segmentado a partir do diretório 37, o qual contém trinta e sete *frames*, abrangendo toda a lesão. Esses dados foram armazenados no formato DICOM, preservando a integridade das informações, a qualidade e a estrutura dos dados originais.

A partir da segmentação, foi iniciada a construção da matriz U , associada ao paciente 04. Esta matriz tridimensional foi dimensionada para a ordem 192×192 , normalizada

para escala de cinza e teve sua média subtraída. A partir da decomposição em valores singulares, os dados foram transformados, resultando nas quatro componentes principais, que são exibidas nas Figuras 10 a 13. A reconstrução da imagem, após a aplicação do método de análise de componentes principais (PCA), é apresentada na Figura 14.

Além disso, as imagens das Figuras 9 e 14 foram processadas utilizando a técnica ORB, conforme ilustrado na Figura 15. Esta abordagem permitiu a detecção e comparação de pontos de interesse entre as imagens, possibilitando a identificação de correspondências. As correspondências entre os pontos de interesse estão evidenciadas na referida figura, o que facilita a análise e validação dos resultados obtidos.

5.4.2 Análise do Paciente 2

De forma análoga, o segundo caso analisado refere-se a uma lesão cancerígena localizada na região renal. A Figura 16 apresenta a imagem original do exame de PET/CT no plano axial, a qual serve como entrada para a análise das componentes principais. Foram segmentados 31 (trinta e um) *frames* do exame de PET/CT, abrangendo a totalidade da lesão, e os dados foram armazenados no formato DICOM, garantindo a preservação integral das informações, qualidade e estrutura dos dados originais.

A partir desses dados, foi construída uma matriz tridimensional com dimensões de 192×192 . Em seguida, a matriz foi normalizada para escala de cinza e a média dos valores foi subtraída. Com a aplicação da decomposição em valores singulares, obteve-se a transformação dos dados e a extração das quatro principais componentes, as quais estão ilustradas nas Figuras 17 a 20. A Figura 21 mostra a imagem reconstruída a partir dessas componentes principais.

As Figuras 16 e 21 foram submetidas a uma rotina de análise da técnica ORB, a qual resultou na Figura 22. Esta análise permite detectar e comparar pontos de interesse, encontrar correspondências e exibir as correspondências entre as imagens.

5.4.3 Análise do Paciente 3

O terceiro caso apresentado na Figura 23 refere-se a uma lesão cancerígena localizada na região pulmonar. A imagem original do exame de PET/CT no plano axial, como ilustrado, serve como entrada para a análise das componentes principais. Foram segmentados 20 (vinte) *frames* provenientes do diretório do exame de PET/CT, abrangendo a totalidade da lesão. Os dados foram armazenados no formato DICOM, preservando integralmente as informações, a qualidade e a estrutura dos dados originais.

A construção da matriz tridimensional foi realizada com dimensões de 192×192 , sendo posteriormente normalizada para a escala de cinza e com a retirada da média dos valores. A decomposição em valores singulares foi aplicada para a transformação dos dados,

resultando nas quatro componentes principais, apresentadas nas Figuras 24 a 27. A Figura 28 ilustra a imagem reconstruída utilizando a primeira componente principal.

As Figuras 23 e 28 também foram submetidas à rotina de análise ORB, resultando na Figura 29. A análise ORB permite detectar, comparar pontos de interesse e exibir as correspondências entre as imagens.

Imagem Original

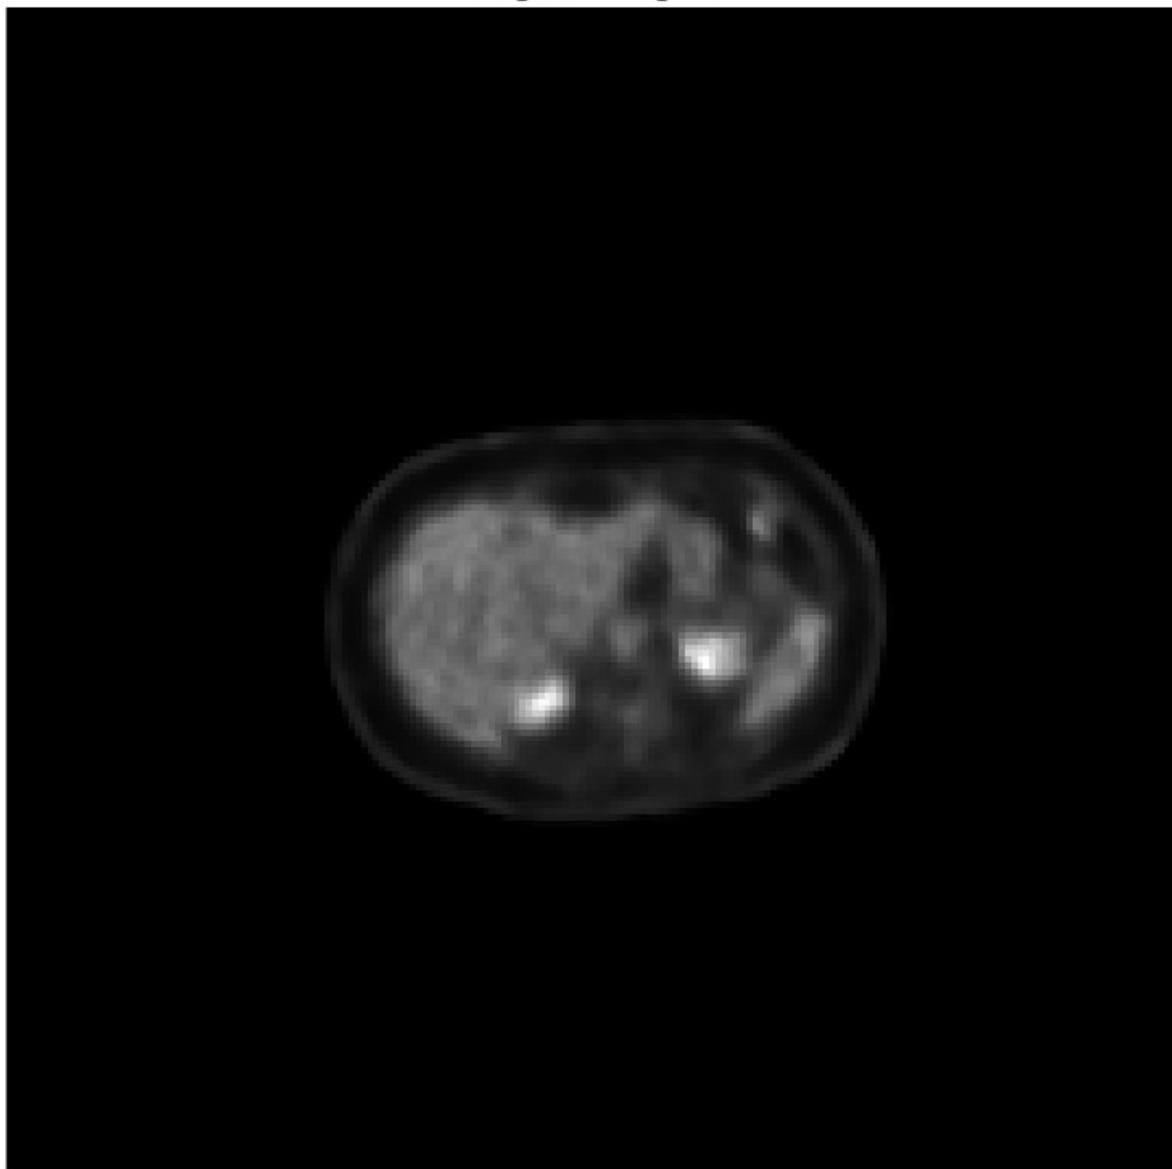


Figura 9 – Imagem original de PET/CT do paciente com lesão cancerígena localizada na região estomacal.

Componente Principal 1



Figura 10 – Primeira componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.

Componente Principal 2

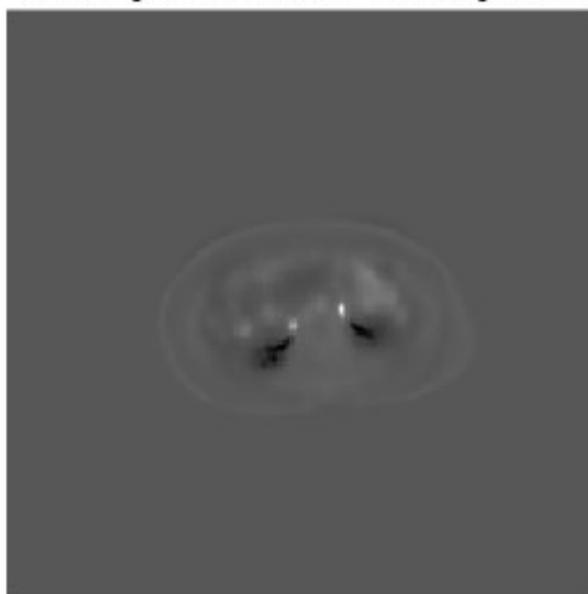


Figura 11 – Segunda componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.

Componente Principal 3



Figura 12 – Terceira componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.

Componente Principal 4

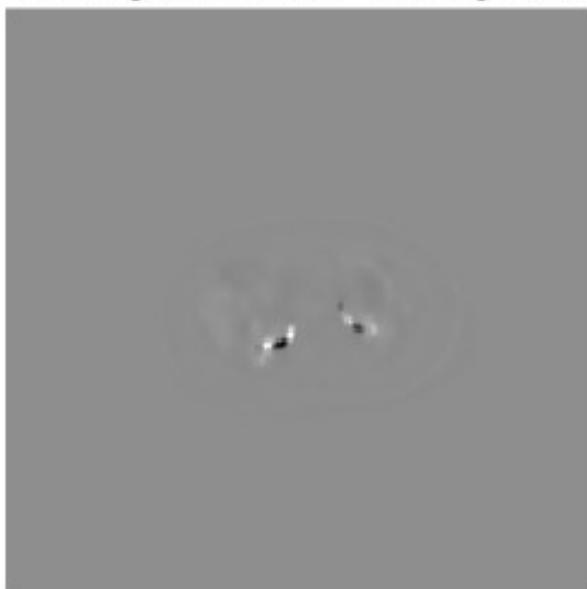


Figura 13 – Quarta componente principal obtida a partir da aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena na região estomacal.

Imagem Reconstruída

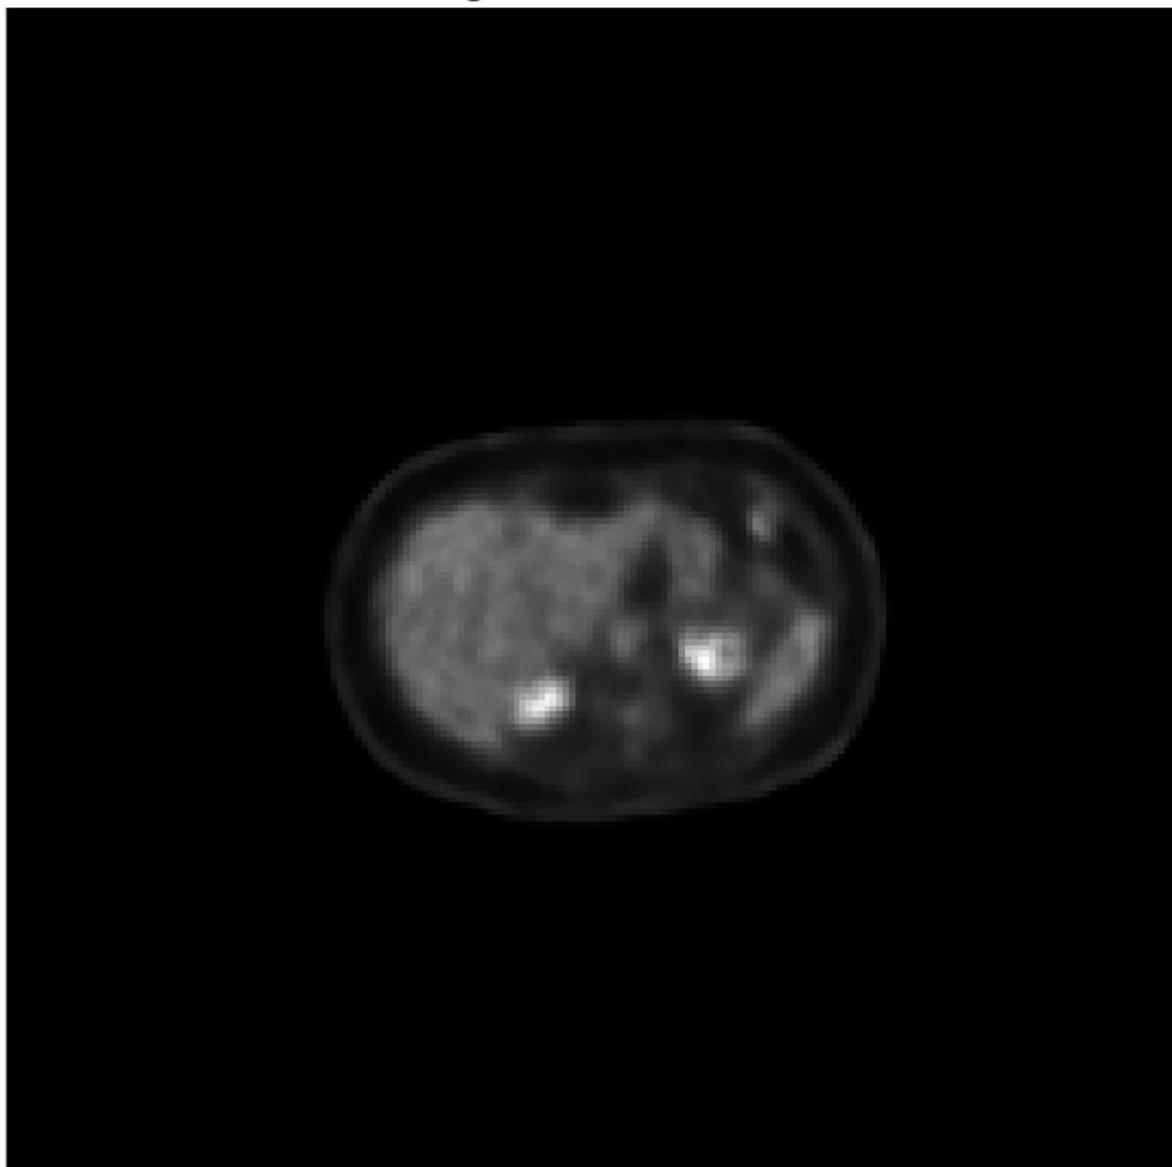


Figura 14 – Imagem reconstruída após a aplicação do PCA no exame de PET/CT do paciente com lesão cancerígena localizada na região estomacal.

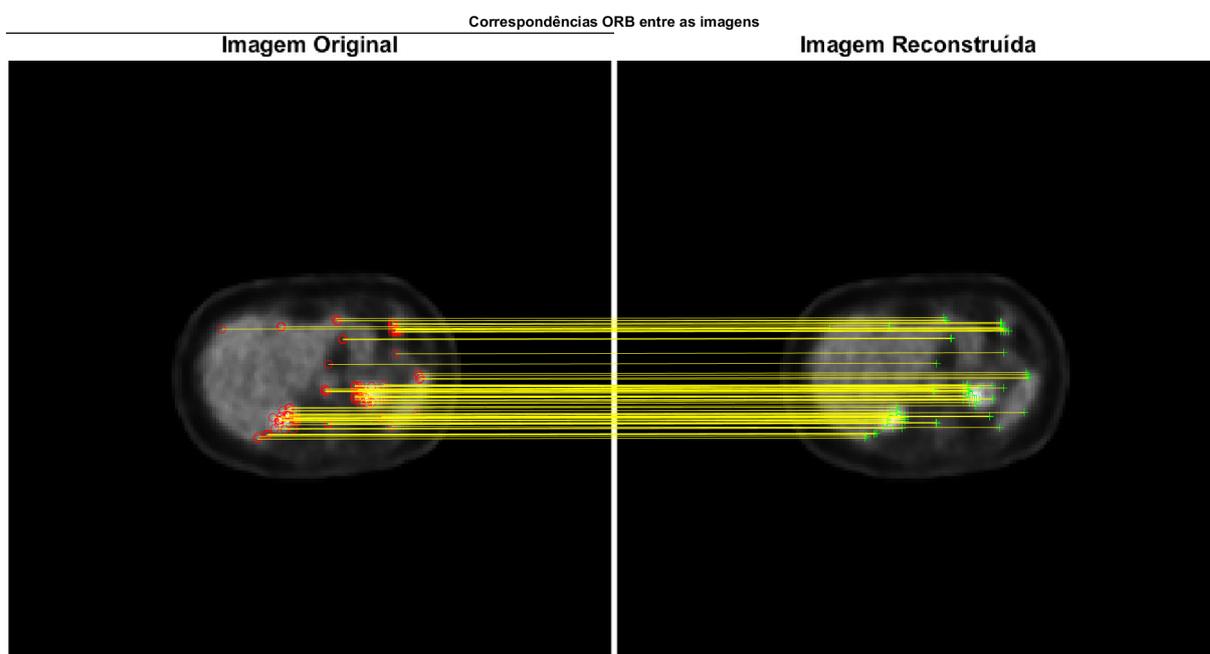


Figura 15 – Imagem reconstruída do paciente com lesão cancerígena localizada na região estomacal, obtida por meio da aplicação da técnica ORB.

Imagem Original

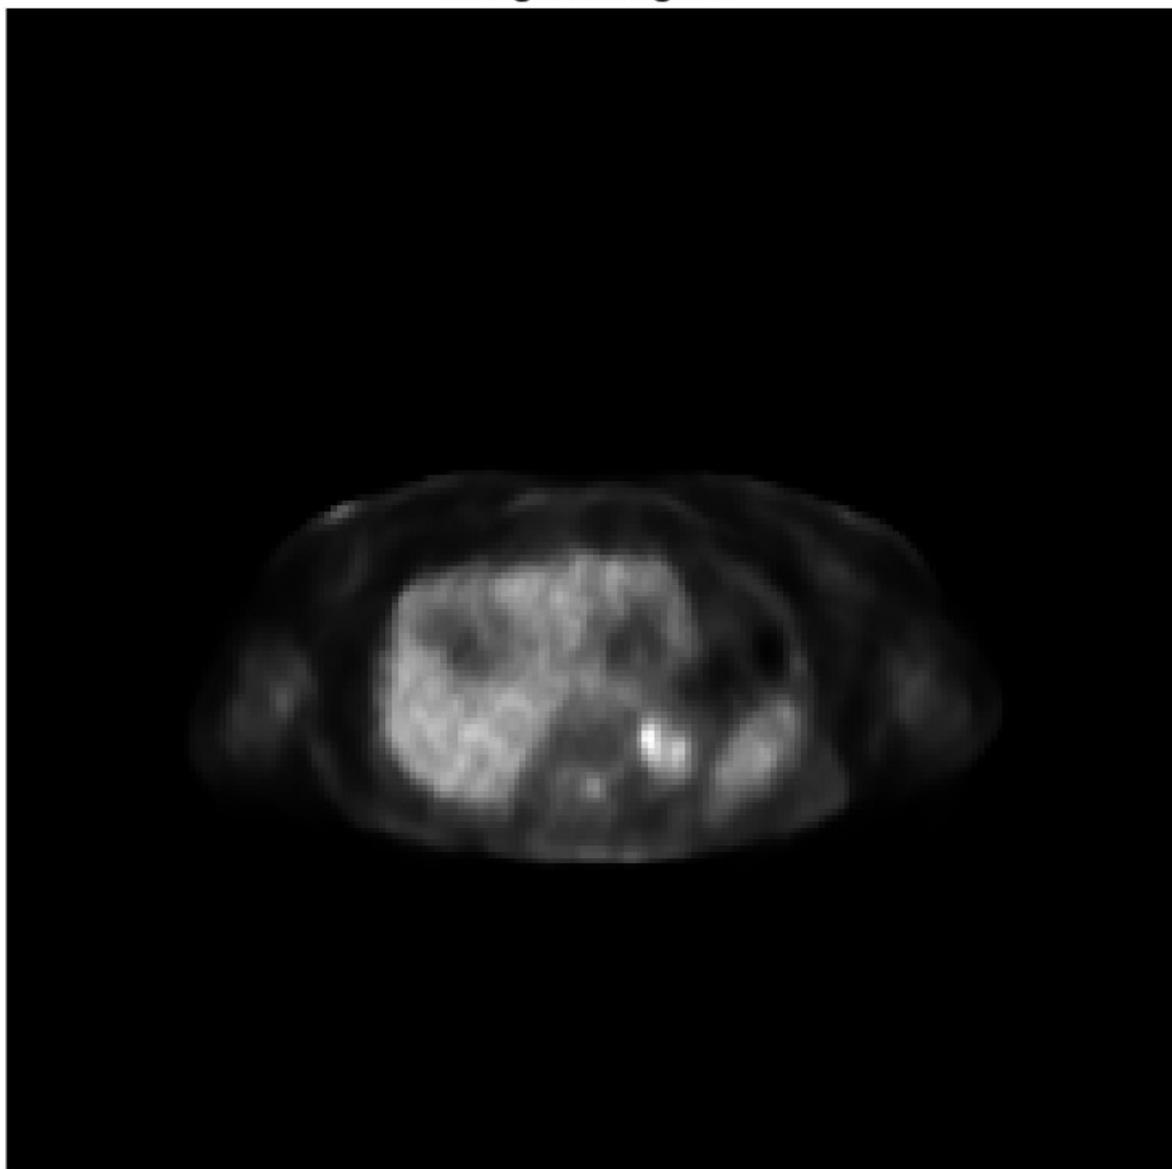


Figura 16 – Imagem original do paciente com lesão cancerígena localizada na região renal.

Componente Principal 1

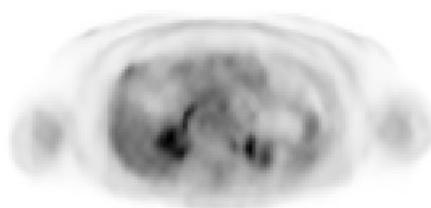


Figura 17 – Primeira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.

Componente Principal 2



Figura 18 – Segunda componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.

Componente Principal 3

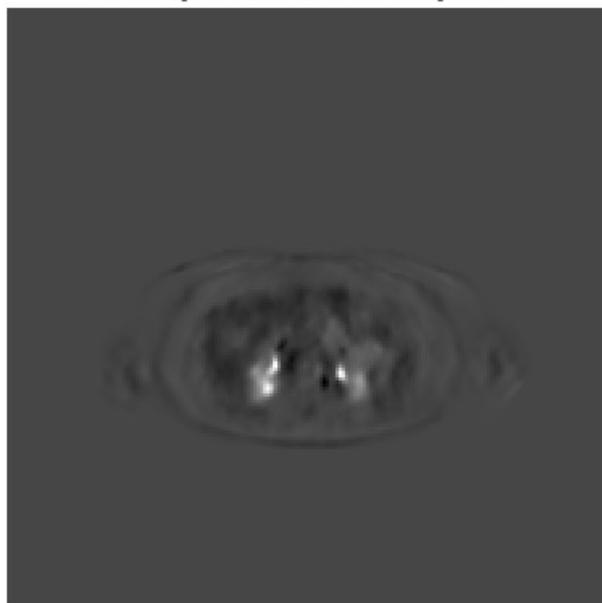


Figura 19 – Terceira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.

Componente Principal 4

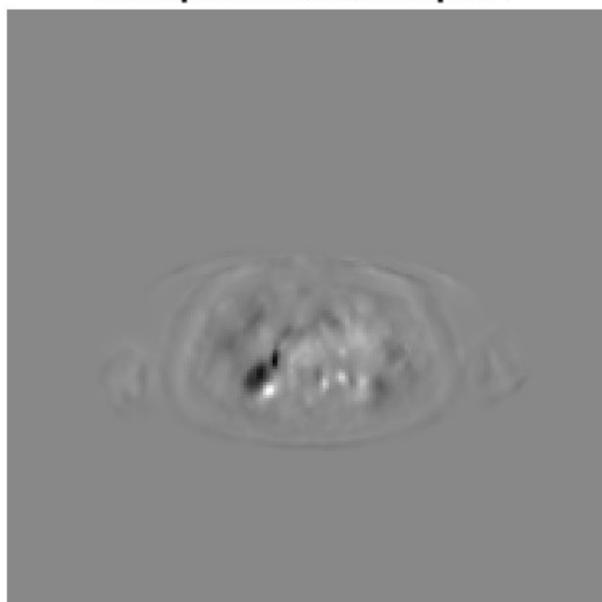


Figura 20 – Quarta componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região renal.

Imagem Reconstruída

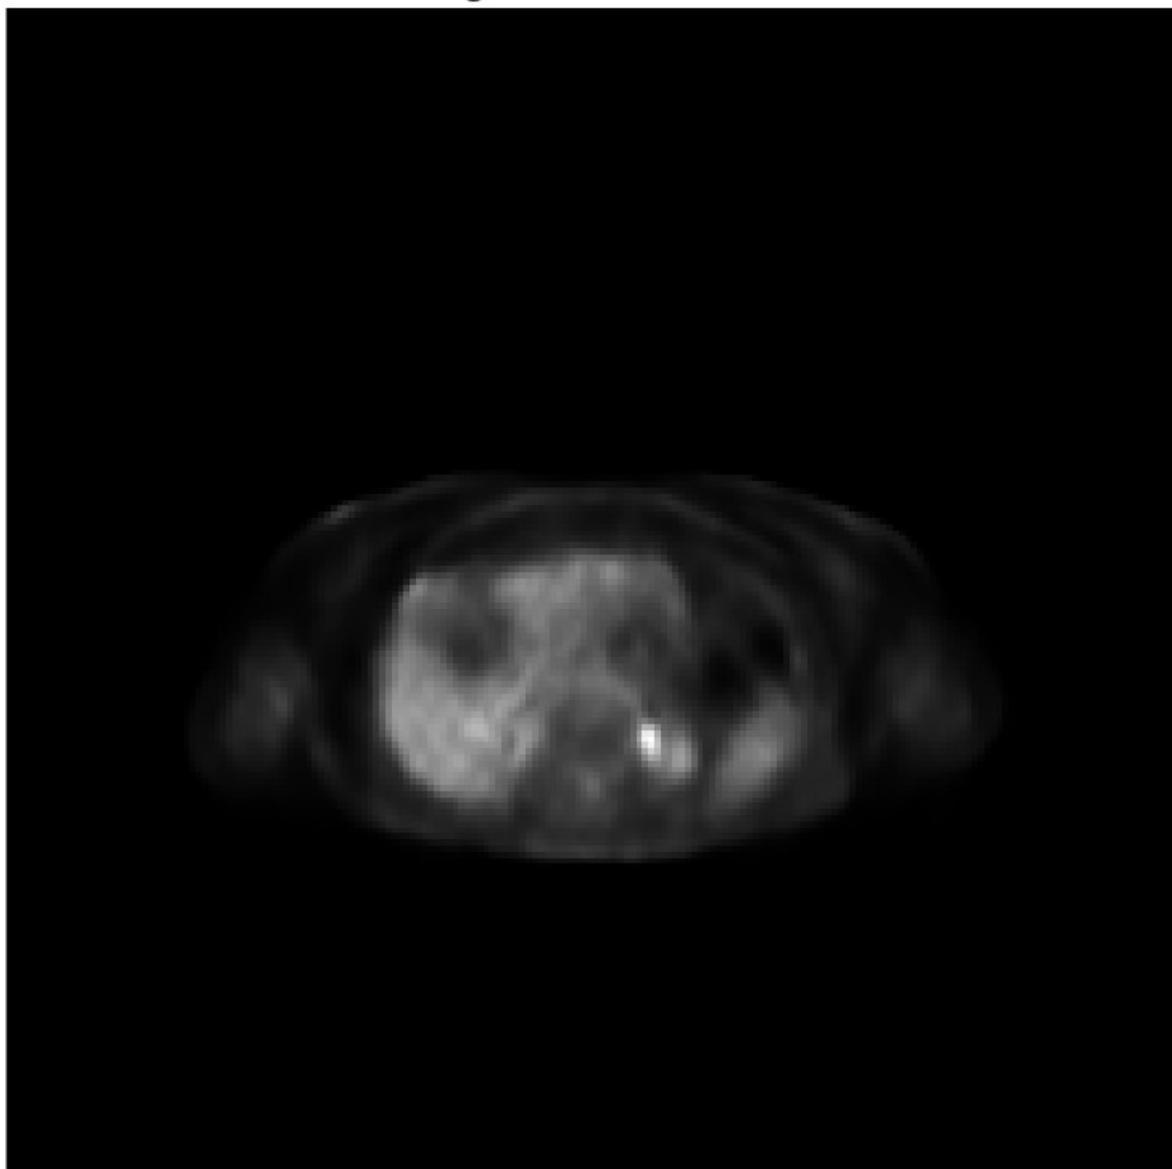


Figura 21 – Imagem reconstruída utilizando a abordagem PCA para o paciente com lesão cancerígena localizada na região renal.

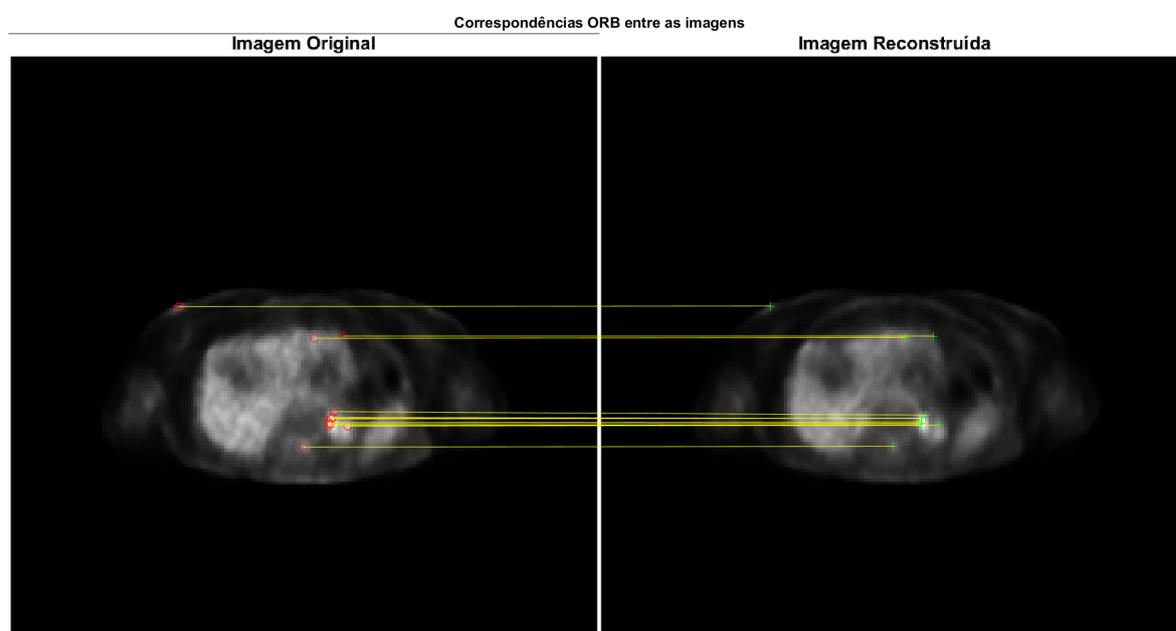


Figura 22 – Imagem reconstruída com auxílio da técnica PCA e análise ORB para o paciente com lesão cancerígena localizada na região renal.

Imagem Original

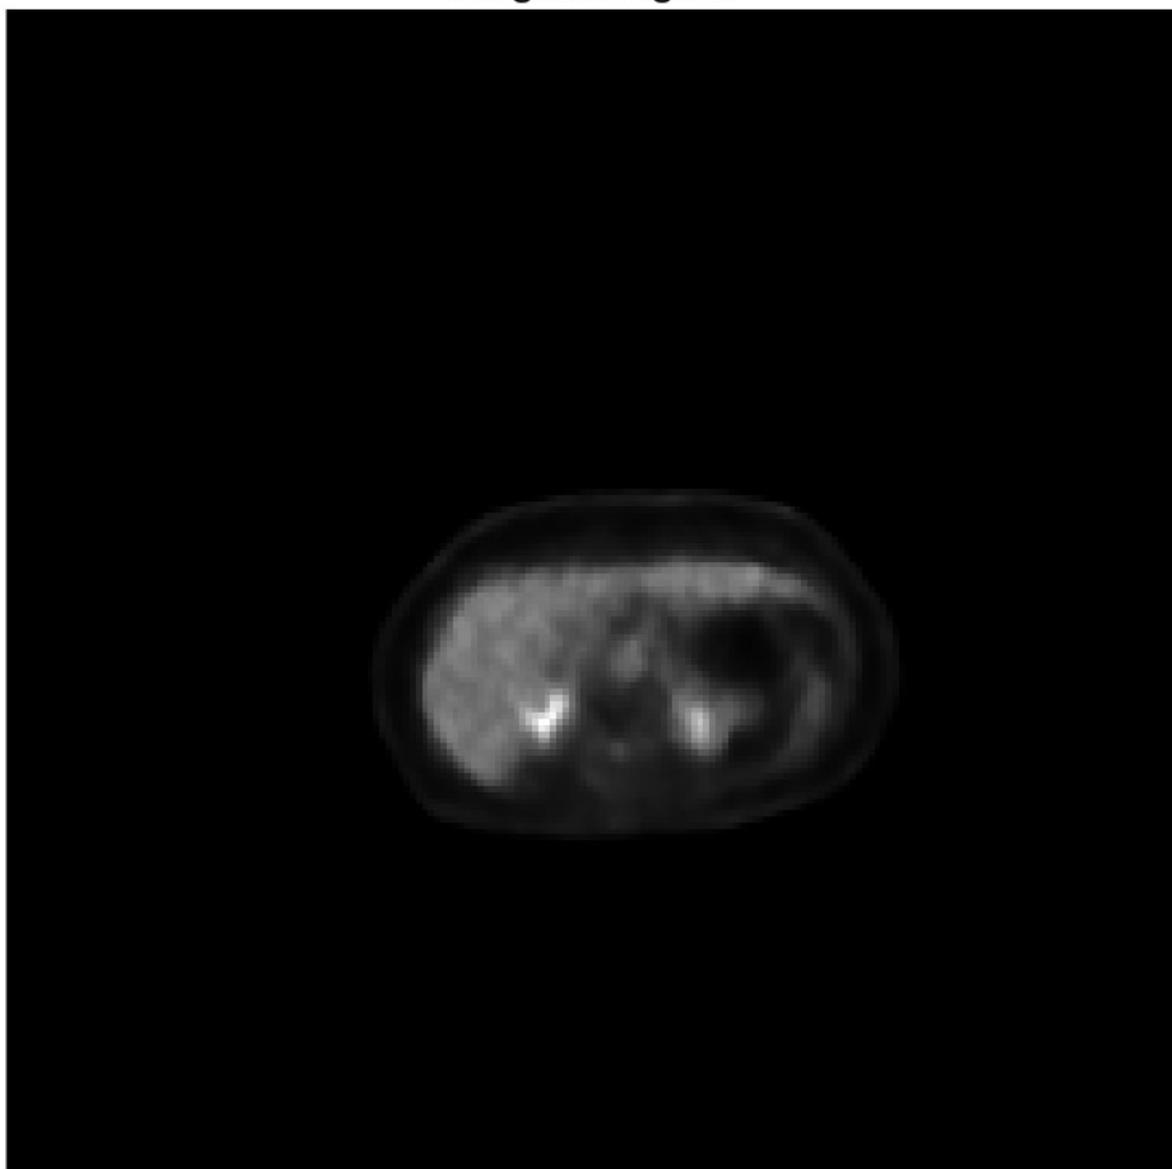


Figura 23 – Imagem original do paciente com lesão cancerígena localizada na região pulmonar.

Componente Principal 1



Figura 24 – Primeira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.

Componente Principal 2

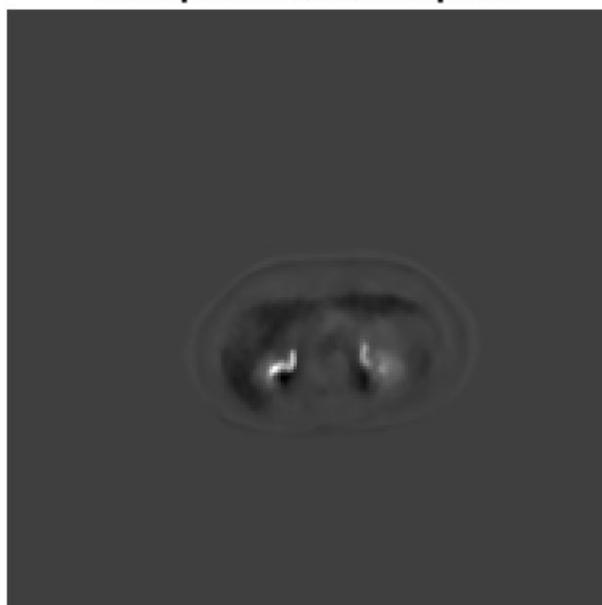


Figura 25 – Segunda componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.

Componente Principal 3



Figura 26 – Terceira componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.

Componente Principal 4

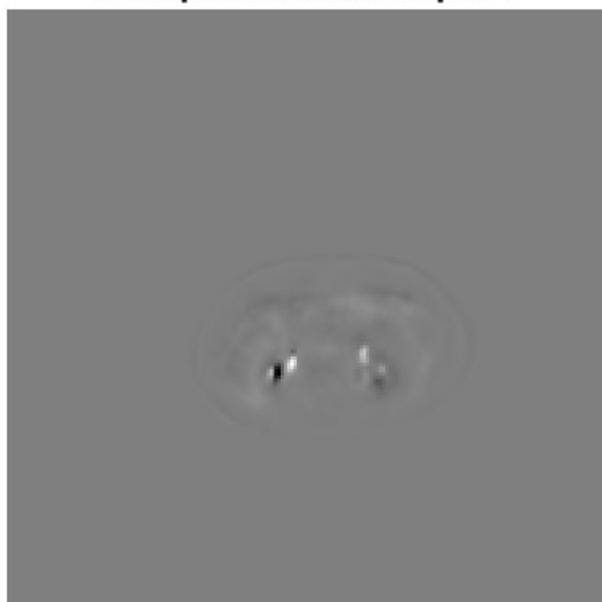


Figura 27 – Quarta componente principal obtida através da abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.

Imagem Reconstruída

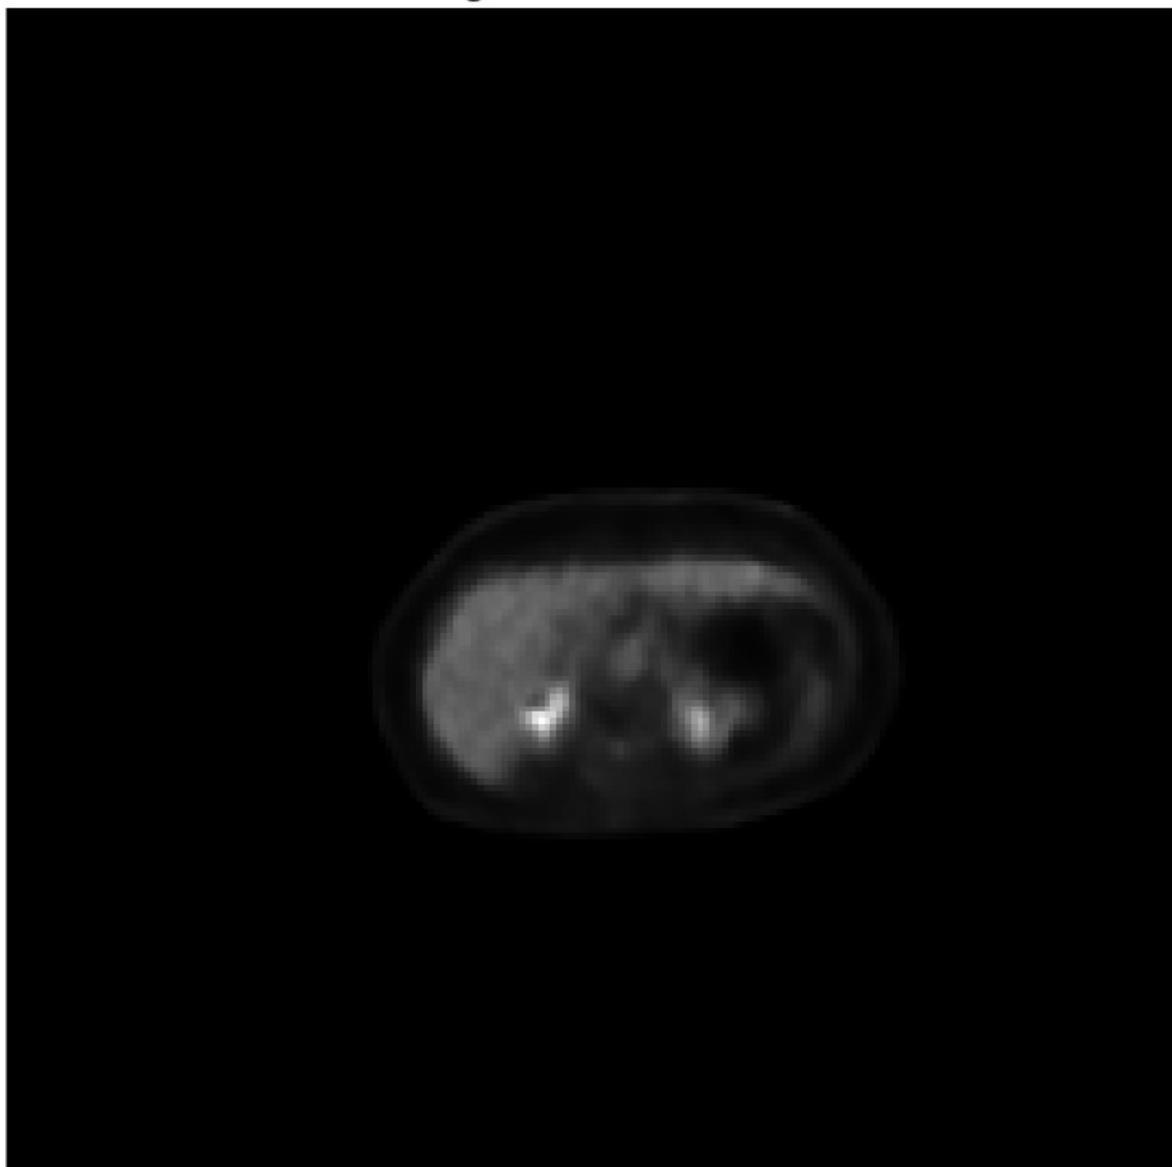


Figura 28 – Imagem reconstruída utilizando a abordagem PCA para o paciente com lesão cancerígena localizada na região pulmonar.

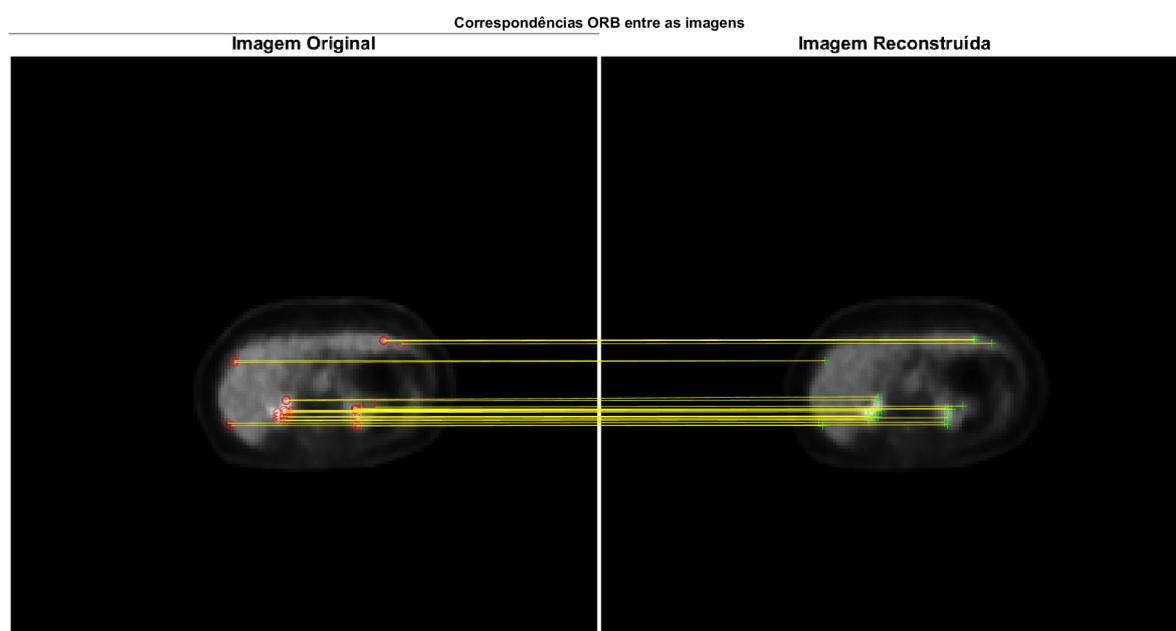


Figura 29 – Imagem reconstruída com auxílio da técnica PCA e análise ORB para o paciente com lesão cancerígena localizada na região pulmonar.

6 Conclusão

6.1 Considerações Finais

A presente dissertação apresentou uma abordagem metodológica para a análise de imagens médicas no formato DICOM, provenientes de exames PET/CT, com ênfase na utilização de doses reduzidas de radiofármacos. A aplicação da Análise de Componentes Principais (PCA) mostrou-se eficaz no processamento e visualização dos exames, permitindo a extração de características fundamentais das imagens e uma avaliação quantitativa rigorosa da qualidade das reconstruções realizadas.

As métricas empregadas, incluindo PSNR, SSIM, MSE, MAE, diferença de entropia e ORB, possibilitaram uma análise abrangente ao capturar diferentes aspectos das propriedades estruturais e estatísticas das imagens. A utilização de um ranking combinado mostrou-se um método eficiente para avaliar a qualidade das reconstruções e comparar diferentes abordagens. Os resultados obtidos demonstraram que a metodologia proposta manteve a estrutura original das imagens, ao mesmo tempo que reduziu a dimensionalidade dos dados, proporcionando uma representação mais compacta e eficiente.

A preservação da qualidade das imagens reconstruídas foi confirmada pelos altos valores de ranking combinado, com ênfase nos casos onde essa métrica ultrapassou 0,8, indicando que a PCA conseguiu preservar com alta fidelidade as características essenciais das imagens. O método mostrou-se promissor como ferramenta de pré-processamento para redução de dimensionalidade em imagens PET/CT, contribuindo para a otimização da análise médica e facilitando a interpretação clínica por especialistas.

Ademais, o uso da diferença de entropia trouxe uma perspectiva complementar às métricas convencionais, permitindo avaliar as alterações na complexidade e na organização da informação presente nas imagens. Esse tipo de análise contribuiu significativamente para a compreensão das diferenças entre as imagens originais e reconstruídas, reforçando a importância de uma abordagem quantitativa integrada para a avaliação de imagens médicas.

6.2 Contribuições da Pesquisa

A partir dos resultados obtidos, as principais contribuições desta dissertação são:

- Desenvolvimento de uma metodologia baseada na PCA para a análise de imagens PET/CT com doses reduzidas de radiofármacos;

- Integração de diferentes métricas de avaliação de qualidade de imagem em um ranking combinado para comparação objetiva dos resultados;
- Proposta de um modelo quantitativo para correlacionar a avaliação computacional com a percepção profissional da qualidade das imagens;
- Aplicação da diferença de entropia como um método complementar às métricas tradicionais, permitindo uma análise mais abrangente das alterações estruturais das imagens reconstruídas.

Essas contribuições reforçam o potencial da PCA como uma ferramenta viável para otimizar o processamento de imagens médicas, reduzindo a necessidade de altas doses de radiofármacos e promovendo análises mais eficazes e acessíveis.

6.3 Propostas para Trabalhos Futuros

A proposta de uma metodologia para o processamento de imagens usando com Análise de Componentes Principais com redução de radiofármaco, apresentada nessa dissertação, tendo em vista os resultados apresentados, abre espaço para a realização de trabalhos futuros, conforme segue:

- Adequação da metodologia para aplicação da Análise de Componentes Independentes (ICA) visando a preservação integral das características das imagens;
- Implementação do modelo proposto como etapa de pré-processamento para Redes Neurais Artificiais na detecção automatizada de lesões;
- Investigação de técnicas avançadas de aprendizado de máquina e deep learning para aprimorar a avaliação quantitativa da qualidade das imagens reconstruídas;
- Exploração do impacto da otimização dos pesos das métricas utilizadas no ranking combinado para ampliar sua aplicação a outros contextos clínicos e modalidades de imagem.

Ao longo desta dissertação, buscou-se apresentar uma abordagem quantitativa inovadora para o aprimoramento da qualidade de imagens PET/CT, contribuindo para avanços na análise médica por meio de técnicas de processamento e redução de dimensionalidade. Os resultados obtidos reforçam a importância da pesquisa em métodos de processamento de imagens, demonstrando o impacto positivo da integração de técnicas estatísticas e computacionais na Medicina Nuclear.

Referências

- AKINC, A. et al. The onpattro story and the clinical translation of nanomedicines containing nucleic acid-based drugs. *Nature nanotechnology*, Nature Publishing Group UK London, v. 14, n. 12, p. 1084–1087, 2019. Citado na página 18.
- AL-AROUJ, M. et al. Recommendations for management of diabetes during ramadan: update 2010. *Diabetes care*, American Diabetes Association, v. 33, n. 8, p. 1895, 2010. Citado na página 19.
- APRILE, E. et al. Projected wimp sensitivity of the xenonnt dark matter experiment. *Journal of Cosmology and Astroparticle Physics*, IOP Publishing, v. 2020, n. 11, p. 031, 2020. Citado na página 25.
- ARABI, H.; ZAIDI, H. Applications of artificial intelligence and deep learning in molecular imaging and radiotherapy. *European Journal of Hybrid Imaging*, Springer, v. 4, n. 1, p. 17, 2020. Citado na página 57.
- BARBOSA, F. de G. et al. Review: Multi-technique hybrid imaging in pet/ct and pet/mr: what does the future hold? *Clin Radiol. Elsevier Ltd*, 2016. Citado na página 33.
- BARRINGTON, S. F.; O'DOHERTY, M. J. Limitations of pet for imaging lymphoma. *European Journal of Nuclear Medicine and Molecular Imaging*, v. 30, n. Suppl 1, p. S117–S127, June 2003. Citado na página 20.
- BASU, S. et al. Quantitative techniques in pet-ct imaging. *Current Medical Imaging*, Bentham Science Publishers, v. 7, n. 3, p. 216–233, 2011. Citado 2 vezes nas páginas 8 e 36.
- BIDGOOD, W. D.; HORII, S. C. Introduction to the acr-nema dicom standard. *RadioGraphics*, v. 12, n. 2, p. 345–355, 1992. Citado na página 49.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. [S.l.]: Springer, 2006. Citado na página 33.
- BOELLAARD, R. Standards for pet image acquisition and quantitative data analysis. *Journal of nuclear medicine*, Soc Nuclear Med, v. 50, n. Suppl 1, p. 11S–20S, 2009. Citado na página 20.
- BOELLAARD, R. et al. Fdg pet/ct: Eanm procedure guidelines for tumour imaging: version 2.0. *European journal of nuclear medicine and molecular imaging*, Springer, v. 42, p. 328–354, 2015. Citado 3 vezes nas páginas 19, 21 e 22.
- BOVIK, A. C. *The essential guide to image processing*. [S.l.]: Academic Press, 2009. Citado na página 55.
- BOVIK, A. C. *Handbook of image and video processing*. [S.l.]: Academic press, 2010. Citado na página 55.
- BROWN, T. Color fidelity in digital imaging. *Optical Society of America*, v. 56, n. 8, p. 876–890, 2019. Citado na página 62.

- CALONDER, M. et al. Brief: Binary robust independent elementary features. In: *European Conference on Computer Vision (ECCV)*. [S.l.: s.n.], 2010. p. 778–792. Citado na página 60.
- COMON, P. Independent component analysis - a new concept. *Signal Processing*, 1994. Citado na página 39.
- COVER, T. M. *Elements of information theory*. [S.l.]: John Wiley & Sons, 1999. Citado na página 57.
- DANTAS, B. M. et al. Avaliação das exposições ocupacionais internas em medicina nuclear – dificuldades e alternativas. *Revista Brasileira de Física Médica*, v. 13, 2020. Disponível em: <<https://www.rbfm.org.br/rbfm/article/view/506>>. Citado na página 15.
- FRIEDRICH, S. *Microcalorimeters for IAEA NML (Annual Report FY2020)*. [S.l.], 2020. Citado na página 18.
- GARCIA, L. Color accuracy in pathological imaging. *Journal of Pathology Informatics*, v. 12, n. 3, p. 234–245, 2021. Citado na página 62.
- GIAMMARILE, F.; HOUZARD, C. L. C. Principles and practice of pet/ct part 2 a technologist’s guide. *European Association of Nuclear Medicine*, p. 50—58, 2011. Citado na página 32.
- GONZALEZ, R. C. *Digital image processing*. [S.l.]: Pearson education india, 2009. Citado 2 vezes nas páginas 57 e 58.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. [S.l.]: Editora Blucher, 2000. Citado na página 55.
- GRIFFETH, L. Use of pet/ct scanning in cancer patients: technical and practical considerations. *Baylor Health Care System*, v. 4, p. 321—330, 2005. Citado na página 32.
- GUPTA, P. Automated feature extraction in medical imaging. *IEEE Transactions on Biomedical Engineering*, v. 66, n. 11, p. 4567–4578, 2019. Citado na página 62.
- HARALICK, K. S. R. M.; DINSTEIN, I. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, SMC-3, n. 6, p. 610–621, 1973. Citado na página 57.
- HARALICK, R. Computer and robot vision. *Addison-Wesley Publishing Company google schola*, v. 2, p. 2061–2068, 1992. Citado na página 56.
- HARRIS, C.; STEPHENS, M. A combined corner and edge detector. In: *Proceedings of the Alvey Vision Conference*. [S.l.: s.n.], 1988. p. 147–151. Citado na página 60.
- HOGG, P.; MEADOWS, A.; HEATHCOTE, A. Principles and practice of pet/ct: part 1: a technologist’s guide. *European Association of Nuclear Medicine*, 2010. Citado na página 29.
- HORE, A.; ZIOU, D. Image quality metrics: Psnr vs. ssim. In: *IEEE. 2010 20th international conference on pattern recognition*. [S.l.], 2010. p. 2366–2369. Citado na página 57.

- (ICRP), I. C. on R. P. *ICRP 2015 Annual Report*. 2016. Hardback. ICRP reference 4828-4042-9106, 11 August 2016, © 2016 ICRP. Disponível em: <<https://www.icrp.org/>>. Citado na página 19.
- JADVAR, H.; PARKER, J. A. *Clinical pet and pet/ct*. Springer, 2005. Citado 4 vezes nas páginas 8, 29, 31 e 33.
- JAMAR, F. et al. Eanm/snm guideline for 18f-fdg use in inflammation and infection. *Journal of Nuclear Medicine*, Soc Nuclear Med, v. 54, n. 4, p. 647–658, 2013. Citado na página 30.
- JOHNSON, R. A. *Applied Multivariate Statistical Analysis*. [S.l.]: Pearson, 2007. Citado na página 32.
- JOHNSON R. A.; WICHERN, D. W. *Applied multivariate statistical analysis*. [S.l.]: Prentice-Hall, 1999. Citado 2 vezes nas páginas 40 e 44.
- JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. *Philosophical transactions of the royal society A: Mathematical, Physical and Engineering Sciences*, the Royal Society publishing, v. 374, n. 2065, p. 20150202, 2016. Citado na página 57.
- JOLLIFFE, I. Principal component analysis. springer.lantos j, mitra e, levin c, iagaru a. standard osem vs. regularized pet image reconstruction: qualitative and semi quantitative comparison. *J Nucl Med*, v. 56, 2002. Citado 3 vezes nas páginas 33, 39 e 41.
- JONES, M. Contrast enhancement techniques for medical imaging. *IEEE Transactions on Medical Imaging*, v. 34, n. 4, p. 1234–1245, 2015. Citado na página 62.
- KENDALL, P. C. Treating anxiety disorders in children: results of a randomized clinical trial. *Journal of Consulting and Clinical Psychology*, v. 62, n. 1, p. 100–110, February 1994. Citado na página 17.
- KHATTREE, R.; NAIK, D. *Multivariate data reduction and discrimination with SAS software*. [S.l.]: SAS Institute Inc., 2000. Citado na página 40.
- KHIEWVAN, B. et al. An update on the role of pet/ct and pet/mri in ovarian cancer. *European journal of nuclear medicine and molecular imaging*, Springer, v. 44, p. 1079–1091, 2017. Citado 4 vezes nas páginas 20, 21, 22 e 23.
- KRAMER, E. L. et al. Positron emission tomography computed tomography: a disease-oriented approach. *Informa Healthcare*, 2008. Citado 4 vezes nas páginas 28, 29, 34 e 35.
- KURZ, T. *RadiAnt DICOM Viewer*. 2025. Acesso em: 11 fev. 2025. Disponível em: <<https://www.radiantviewer.com>>. Citado na página 49.
- LEE, R. Medical image processing and contrast adjustments. *Journal of Biomedical Engineering*, v. 45, n. 2, p. 567–578, 2020. Citado na página 62.
- LEMO, A.; CAMINHAS, W.; GOMIDE, F. Multivariable gaussian evolving fuzzy modeling system. *IEEE Transactions on Fuzzy Systems*, IEEE, v. 19, n. 1, p. 91–104, 2010. Citado na página 54.

- LI, W. et al. Accurate whole-brain segmentation for bimodal pet/mr images via a cross-attention mechanism. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2024. Citado na página 26.
- LI, X. Feature detection in medical image analysis. In: *Medical Image Computing and Computer-Assisted Intervention*. [S.l.: s.n.], 2017. p. 345–356. Citado na página 62.
- LIM, H. J.; KIM, H. J.; CHUNG, J. K. The role of dicom in nuclear medicine imaging: integration and standardization. *European Journal of Nuclear Medicine and Molecular Imaging*, v. 37, n. 12, p. 2253–2260, 2010. Citado na página 49.
- LIU, H. Advanced detection techniques in ct and mri. *Radiology Journal*, v. 78, n. 5, p. 567–580, 2021. Citado na página 62.
- LIU, X. et al. Persistent free radicals on biochar for its catalytic capability: A review. *Water Research*, Elsevier, v. 250, p. 120999, 2024. Citado 2 vezes nas páginas 24 e 25.
- LONSDALE, M.; BEYER, T. ual-modality pet/ct instrumentation—today and tomorrow. *Eur J Radiol*, v. 73, p. 452—460, 2010. Citado na página 33.
- LYNCH, T. et al. Pet/ct in clinical practice. *ET/CT in Clinical Practice*, p. 1—241, 2007. Citado 2 vezes nas páginas 33 e 35.
- MACHADO, M. A. D. et al. Radioproteção aplicada à medicina nuclear. *Revista Brasileira de Física Médica*, v. 14, 2021. Disponível em: <<https://www.rbfm.org.br/rbfm/article/view/97>>. Citado na página 15.
- MARINOV, Z. et al. Mirror u-net: Marrying multimodal fusion with multi-task learning for semantic segmentation in medical imaging. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops*. [S.l.: s.n.], 2023. p. 2283–2293. Citado na página 24.
- METTLER, F. A.; GUIBERTEAU, M. J. Essentials of nuclear medicine imaging. *Essentials of Nuclear Medicine Imaging*, v. 6, 2012. Citado 2 vezes nas páginas 28 e 31.
- METTLER, F. A.; GUIBERTEAU, M. J. *Essentials of Nuclear Medicine and Molecular Imaging*. 7th. ed. [S.l.]: Elsevier, 2018. ISBN 9780323483193. Citado na página 18.
- MOON, G. et al. A dataset of relighted 3d interacting hands. *Advances in Neural Information Processing Systems*, v. 36, p. 17689–17701, 2023. Citado na página 24.
- MORETTIN, P. A.; TOLOI, C. M. *Análise de séries temporais: modelos lineares univariados*. [S.l.]: Editora Blucher, 2018. Citado na página 54.
- NEMA. *Digital Imaging and Communications in Medicine (DICOM) Part 1: Introduction and Overview*. [S.l.], 2023. Accessed: 2025-02-11. Disponível em: <<https://www.dicomstandard.org>>. Citado na página 48.
- NEMA – National Electrical Manufacturers Association. *Digital Imaging and Communications in Medicine (DICOM) – Part 1: Introduction and Overview*. Rosslyn, VA: NEMA, 2023. Citado na página 48.
- OTSU, N. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, v. 9, n. 1, p. 62–66, 1979. Citado na página 58.

- PAPATHANASSIOU, D. et al. Positron emission tomography in oncology: Present and future of pet and pet/ct. *Crit Rev Oncol Hematol*, v. 72, p. 239—254, 2009. Citado 2 vezes nas páginas 8 e 34.
- PINTON, N. J. et al. Multi-branch generative models for multichannel imaging with an application to pet/ct synergistic reconstruction. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2025. Citado na página 26.
- POEPPPEL, T. et al. Et/ct for the staging and follow-up of patients with malignancies. *Eur J Radiol*, v. 70, p. 382—392, 2009. Citado na página 33.
- READER, A. J.; ZAIDI, H. Advances in pet image reconstruction. *PET clinics*, Elsevier, v. 2, n. 2, p. 173–190, 2007. Citado na página 58.
- REGAZZI, A. *Análise multivariada, notas de aula INF 766*. [S.l.]: Departamento de Informática da Universidade Federal de Viçosa, 2000. Citado na página 40.
- ROSTEN, E.; DRUMMOND, T. Machine learning for high-speed corner detection. In: *European Conference on Computer Vision*. [S.l.: s.n.], 2006. p. 430–443. Citado na página 60.
- RUBLEE, E. et al. Orb: An efficient alternative to SIFT or SURF. In: *Proceedings of the IEEE International Conference on Computer Vision*. [S.l.: s.n.], 2011. p. 2564–2571. Citado na página 60.
- SAHA, G. B. *Fundamentals of Nuclear Pharmacy*. 7. ed. Springer International Publishing, 2018. Disponível em: <<https://doi.org/10.1007/978-3-319-57580-3>>. Citado na página 15.
- SAHA, G. B.; GOPAL, B. *Basics of PET imaging: physics, chemistry, and regulations*. [S.l.]: Springer, 2005. Citado 2 vezes nas páginas 29 e 32.
- SALEHJAHROMI, M. et al. Synthetic pet from ct improves diagnosis and prognosis for lung cancer: Proof of concept. *Cell Reports Medicine*, Elsevier, v. 5, n. 3, 2024. Citado na página 24.
- SHANNON, C. E.; WEAVER, W. *The mathematical theory of communication*, 117 pp. Urbana: University of Illinois Press, 1949. Citado na página 55.
- SHIELDS, C. L. et al. Targeted retinoblastoma management: when to use intravenous, intra-arterial, periocular, and intravitreal chemotherapy. *Current Opinion in Ophthalmology*, v. 25, n. 5, p. 374–385, 2014. Citado na página 17.
- SLOMKA, P.; PAN, T.; GERMANO, G. Recent advances and future progress in pet instrumentation. *aaaa*, v. 46, p. 5—19, 2016. Citado na página 32.
- SMITH, J. *Image Quality in Medical Imaging*. [S.l.]: Medical Physics Journal, 2018. Citado na página 62.
- SOUZA, G. G. de; LUCERO, M. J. A importância da espectroscopia por ressonância magnética para avaliação de lesões neoplásicas do sistema nervoso central. *Repositório Institucional do UNILUS*, v. 3, n. 1, 2024. Citado na página 24.

- SZELISKI, R. *Computer vision: algorithms and applications*. [S.l.]: Springer Nature, 2022. Citado na página 54.
- TAREEN, S. A.; SALEEM, Z. A comparative analysis of SIFT, SURF, KAZE, AKAZE, ORB, and BRISK. *International Journal of Computer Applications*, v. 975, n. 8887, p. 1–7, 2018. Citado na página 60.
- TEAM, N. L. S. T. R. et al. Reduced lung-cancer mortality with low-dose computed tomographic screening. *New England Journal of Medicine*, v. 365, n. 5, p. 395–409, 2011. Disponível em: <<https://doi.org/10.1056/NEJMoa1102873>>. Citado 2 vezes nas páginas 20 e 22.
- TOWNSEND, D. Combined positron emission tomography-computed tomography: the historical perspective. *Semin Ultrasound CT MR*, v. 4, 2008. Citado 2 vezes nas páginas 8 e 32.
- TOWNSEND, D. Positron emission tomography/computed tomography. *Semin Nucl Med*, v. 38, p. 152—166, 2016. Citado na página 33.
- TURKINGTON, T. G. Introduction to pet instrumentation. *Journal of nuclear medicine technology*, Soc Nuclear Med, v. 29, n. 1, p. 4–11, 2001. Citado 2 vezes nas páginas 29 e 30.
- VALK, P. E. et al. *Positron emission tomography: clinical practice*. [S.l.]: Springer Science & Business Media, 2006. Citado 4 vezes nas páginas 8, 28, 29 e 30.
- WACKERLY, D.; MENDENHALL, W.; SCHEAFFER, R. *Mathematical Statistics with Applications*. Belmont: Cengage Learning. 2014. Citado na página 41.
- WADSAK, W.; MITTERHAUSER, M. eview: Basics and principles of radiopharmaceuticals for pet/ct. *Eur J Radiol*, v. 73, p. 461—469, 2010. Citado na página 34.
- WAHL, R. L. et al. From recist to percist: evolving considerations for pet response criteria in solid tumors. *Journal of nuclear medicine*, Soc Nuclear Med, v. 50, n. Suppl 1, p. 122S–150S, 2009. Citado na página 20.
- WALLACE, G. K. The jpeg still picture compression standard. *IEEE Transactions on Consumer Electronics*, IEEE, v. 38, n. 1, p. 18–34, 1991. Citado na página 57.
- WANG, H. et al. Mag-net: A multiscale adaptive generation network for pet synthetic ct. *IEEE Transactions on Radiation and Plasma Medical Sciences*, v. 9, n. 1, p. 83–91, 2025. Citado na página 26.
- WANG, J. et al. Enhancing well kick classification in drilling operations using a novel pca-based machine learning approach. In: ARMA. *ARMA US Rock Mechanics/Geomechanics Symposium*. [S.l.], 2024. p. D031S034R001. Citado 2 vezes nas páginas 25 e 57.
- WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, IEEE, v. 13, n. 4, p. 600–612, 2004. Citado 2 vezes nas páginas 54 e 55.
- WEBB, S. *The Physics of Medical Imaging*. [S.l.]: CRC Press, 1988. Citado 2 vezes nas páginas 31 e 33.

WEBER, W. A. Use of pet for monitoring cancer therapy and for predicting outcome. *Journal of Nuclear Medicine*, Soc Nuclear Med, v. 46, n. 6, p. 983–995, 2005. Citado na página 20.

WECHALEKAR, K.; SHARMA, B.; COOK, G. Review: Pet/ct in oncology—a major advance. *Clin Radiol*, v. 11, p. 1143—1155, 2005. Citado na página 34.

YANG, R. et al. Ntire 2024 challenge on blind enhancement of compressed image: Methods and results. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2024. p. 6524–6535. Citado na página 25.

YAU, J. W.; TEOH, H.; VERMA, S. Endothelial cell control of thrombosis. *BMC cardiovascular disorders*, Springer, v. 15, p. 1–11, 2015. Citado 3 vezes nas páginas 20, 22 e 23.

ZHANG, B. et al. Performance evaluation of new pet/ct digitmi 930. *IEEE Transactions on Radiation and Plasma Medical Sciences*, XX, n. XX, p. 1–10, 2025. Citado na página 26.