



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
UNIDADE ACADÊMICA DO CABO DE SANTO AGOSTINHO
BACHARELADO EM ENGENHARIA ELETRÔNICA

Alessandra Nunes Costa

Análise de Desempenho de Métodos de Compressão para Imagens de Light Field: Um Estudo
Comparativo entre a Transformada Discreta do Cosseno 4D e a Transformada de Fourier
sobre Grafos

Cabo de Santo Agostinho - PE
2025

Alessandra Nunes Costa

Análise de Desempenho de Métodos de Compressão para Imagens de Light Field: Um Estudo Comparativo entre a Transformada Discreta do Cosseno 4D e a Transformada de Fourier sobre Grafos

Monografia apresentada ao curso de Graduação em Engenharia Eletrônica da Unidade Acadêmica do Cabo de Santo Agostinho, Universidade Rural de Pernambuco, como requisito para obtenção do grau de Bacharel em Engenharia Eletrônica.

Orientador (a): Prof. Dr. Felipe Alberto Barbosa Simão Ferreira

Cabo de Santo Agostinho - PE

2025

Dados Internacionais de Catalogação na Publicação
Sistema Integrado de Bibliotecas da UFRPE
Bibliotecário(a): Denize Souza – CRB-4 2046

C838a Costa, Alessandra Nunes.
Análise de Desempenho de Métodos de Compressão para Imagens de Light Field: Um estudo comparativo entre a transformada discreta do cosseno 4D e a transformada de Fourier sobre grafos / Alessandra Nunes Costa. – Cabo de Santo Agostinho, 2026.
79 f.; il.

Orientador(a): Felipe Alberto Barbosa Simão Ferreira.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal Rural de Pernambuco, Unidade Acadêmica Cabo de Santo Agostinho - UACSA, Bacharelado em Engenharia Eletrônica, Cabo de Santo Agostinho, BR-PE, 2026.

Inclui referências e apêndice(s).

1. Compressão de imagens. 2. *Light Field*. 3. 4D-DCT. 4. Transformada de Fourier sobre grafos 5. Eficiência computacional. I. Ferreira, Felipe Alberto Barbosa Simão, orient. II. Título

CDD 621.3

ALESSANDRA NUNES COSTA

Análise de Desempenho de Métodos de Compressão para Imagens de *Light Field*: Um Estudo Comparativo entre a Transformada Discreta do Cosseno 4D e a Transformada de Fourier sobre Grafos

Monografia apresentada ao Curso de Graduação em Engenharia Eletrônica da Universidade Federal Rural de Pernambuco, como requisito parcial para a obtenção do grau de Bacharel em Engenharia Eletrônica.

Aprovada em: 09/01/2026.

BANCA EXAMINADORA

Prof. Dr. Felipe Alberto Barbosa Simão Ferreira, UFRPE – UACSA
Orientador

Profa. Dra. Amanda Souza de Paula, UFRPE – UACSA
Examinadora

Prof. Dr. Elias Marques Ferreira de Oliveira, UFRPE – UACSA
Examinador

AGRADECIMENTOS

Aos meus pais, Simone Nunes Costa e Alexsandro Costa, por serem a base fundamental de toda a minha trajetória. Agradeço o incentivo e por todos os sacrifícios realizados para que eu pudesse chegar até aqui.

Ao meu orientador, Professor Felipe Ferreira, pela orientação, suporte e paciência ao longo do desenvolvimento deste trabalho. Agradeço por compartilhar seu conhecimento, pelas contribuições técnicas e por me guiar com excelência.

Aos professores que participaram da minha formação acadêmica, expresso minha gratidão por transmitirem seus conhecimentos e experiências, contribuindo de forma significativa para a construção do meu pensamento crítico e para a minha formação profissional.

Aos meus amigos, que estiveram ao meu lado nos momentos de cansaço e nas conquistas.

A todos que, de forma direta ou indireta, contribuíram para a conclusão deste trabalho, o meu sincero agradecimento.

Newton's third law. You've got to leave something behind.

Joseph Cooper (*Interstellar*)

RESUMO

A tecnologia de *light field* representa um avanço expressivo na captura visual ao registrar não apenas a intensidade, mas também a direção dos raios de luz, habilitando aplicações como refocagem digital e percepção de profundidade. Contudo, essa riqueza informacional resulta em um volume massivo de dados quadridimensionais, impondo desafios de armazenamento e transmissão que exigem técnicas eficientes de redução de dimensionalidade. Este trabalho propõe uma análise comparativa entre duas abordagens distintas para a compressão desses dados: a Transformada Discreta do Cosseno em quatro dimensões (4D-DCT, do inglês *Four-Dimensional Discrete Cosine Transform*), que estende os padrões clássicos de codificação explorando a redundância espacial e angular, e a Transformada de Fourier sobre Grafos (GFT, do inglês *Graph Fourier Transform*), uma técnica emergente que modela a imagem como um sinal sobre uma estrutura topológica irregular adaptável. A metodologia compreendeu a implementação e simulação dos algoritmos utilizando o banco de dados JPEG Pleno. Para a GFT, desenvolveu-se uma topologia dinâmica em que a matriz de adjacência é construída com base na similaridade local de intensidade, permitindo que a base da transformada se molde ao conteúdo de cada bloco. O estudo investigou a relação entre a qualidade de reconstrução, medida por meio da Relação Sinal-Ruído de Pico (PSNR, do inglês *Peak Signal-to-Noise Ratio*) e do Índice de Similaridade Estrutural (SSIM, do inglês *Structural Similarity Index*), e a complexidade computacional de cada método. Os resultados evidenciaram comportamentos complementares: a 4D-DCT consolidou-se como a solução mais robusta para aplicações gerais, unindo alta fidelidade e baixo tempo de execução. Em contrapartida, a GFT demonstrou superioridade na preservação da estrutura visual em regimes de alta compressão, sustentando a coerência da imagem de forma mais robusta do que os métodos clássicos, embora sua aplicação prática seja restringida por um custo de processamento significativamente superior. Conclui-se que a 4D-DCT é ideal para requisitos de tempo real, enquanto a GFT se posiciona como alternativa especializada para cenários onde a preservação estrutural sob severa restrição de dados é prioritária.

Palavras-chave: Compressão de Imagens; *Light Field*; 4D-DCT; Transformada de Fourier sobre Grafos; Eficiência Computacional.

ABSTRACT

Light field technology represents a significant advancement in visual capture by recording not only the intensity but also the direction of light rays, enabling applications such as digital refocusing and depth perception. However, this informational richness results in a massive volume of four-dimensional data, imposing storage and transmission challenges that require efficient dimensionality reduction techniques. This work proposes a comparative analysis between two distinct approaches for compressing this data: the Four-Dimensional Discrete Cosine Transform (4D-DCT), which extends classical encoding standards by exploiting spatial and angular redundancy, and the Graph Fourier Transform (GFT), an emerging technique that models the image as a signal on an adaptable irregular topological structure. The methodology comprised the implementation and simulation of the algorithms using the JPEG Pleno database. For GFT, a dynamic topology was developed in which the adjacency matrix is constructed based on local intensity similarity, allowing the basis of the transform to adapt to the content of each block. The study investigated the relationship between reconstruction quality, measured by the Peak Signal-to-Noise Ratio (PSNR) and the Structural Similarity Index (SSIM), and the computational complexity of each method. The results showed complementary behaviors: 4D-DCT established itself as the most robust solution for general applications, combining high fidelity and low execution time. In contrast, GFT demonstrated superiority in preserving visual structure in high compression regimes, maintaining image coherence more robustly than classical methods, although its practical application is restricted by a significantly higher processing cost. It is concluded that 4D-DCT is ideal for real-time requirements, while GFT is positioned as a specialized alternative for scenarios where structural preservation under severe data constraints is a priority.

Keywords: Image Compression; Light Field; 4D-DCT; Graph Fourier Transform; Computational Efficiency.

LISTA DE FIGURAS

Figura 1 – Representação esquemática da captura plenóptica de uma cena por meio de uma câmera <i>pinhole</i> que realiza o escaneamento. Os raios luminosos que atravessam o orifício da câmera codificam os valores da função plenóptica (P), que é parametrizada em sete dimensões, incluindo a posição (x, y, z) , ângulo (θ, ϕ) , comprimento de onda (λ) e tempo (t)	19
Figura 2 – Exemplo de um sistema de <i>array</i> de câmeras.	20
Figura 3 – Esquema de uma câmera de <i>light field</i> baseada em arranjo de microlentes. O conjunto de imagens elementares resultante exemplifica o padrão visual conhecido como <i>fly eye</i>	21
Figura 4 – Visualização de todas as vistas de uma imagem de <i>light field</i> capturada por um dispositivo com microlentes (<i>lenslet</i>), em que cada vista é referenciada por um sistema de coordenadas (s, t) , e a vista central expandida, em que cada pixel é referenciado por um sistema de coordenadas (u, v)	26
Figura 5 – Exemplo de (a) uma sub-imagem de uma <i>light field</i> e (b) coordenadas us e tv fixas.	27
Figura 6 – Espectro da 4D-DCT de uma imagem de <i>light field</i> calculado com blocos de tamanho $8 \times 8 \times 8 \times 8$ com (a) 100% dos coeficientes mantidos e (b) 1% dos coeficientes mantidos	35
Figura 7 – Espectro de magnitude da GFT para um bloco de <i>light field</i> utilizando topologia em <i>grid</i> regular	41
Figura 8 – (a) Imagem de <i>light field</i> na estrutura <i>fly eye</i> e (b) Imagem de <i>light field</i> organizada numa matriz de 8×8 sub-imagens.	43
Figura 9 – Representação visual do (a) Padrão JPEG para imagens comuns com a 2D-DCT e (b) Padrão análogo ao do JPEG para imagens de <i>light field</i> com a 4D-DCT.	44
Figura 10 – Estrutura da imagem de <i>light field</i> reorganizada em 8×8 sub-imagens de 32×32 pixels.	45
Figura 11 – Comparação entre topologias de grafo para um (a) bloco 4×4 com padrão de intensidades intercaladas: (b) topologia <i>grid</i> com conectividade restrita a vizinhos imediatos e (c) topologia dinâmica baseada em similaridade de intensidade.	47
Figura 12 – Curvas de PSNR da 4DC-DCT em função da porcentagem de coeficientes retidos para as imagens <i>Red_White_Building</i> e <i>Parc_du_Luxembourg</i>	48
Figura 13 – Curvas de SSIM da 4D-DCT em função da porcentagem de coeficientes retidos para as imagens <i>Red_White_Building</i> e <i>Parc_du_Luxembourg</i>	49

Figura 14 – Imagem de <i>light field Red_White_Building</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	50
Figura 15 – Imagem de <i>light field Parc_du_Luxembourg</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	50
Figura 16 – Curvas de PSNR da GFT em função da porcentagem de coeficientes retidos para as imagens <i>Red_White_Building</i> e <i>Parc_du_Luxembourg</i>	51
Figura 17 – Curvas de SSIM da GFT em função da porcentagem de coeficientes retidos para as imagens <i>Red_White_Building</i> e <i>Parc_du_Luxembourg</i>	52
Figura 18 – Imagem de <i>light field Red_White_Building</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	53
Figura 19 – Imagens de <i>light field Red_White_Building</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	54
Figura 20 – Imagem de <i>light field Parc_du_Luxembourg</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	55
Figura 21 – Imagens de <i>light field Parc_du_Luxembourg</i> reconstruídas com a GFT com os valores de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	55
Figura 22 – Comparativo do PSNR médio da 4D-DCT e da GFT em função da porcentagem de coeficientes retidos	56
Figura 23 – Comparativo do SSIM Médio da 4D-DCT e da GFT em função da porcentagem de coeficientes retidos	57
Figura B.1 – Imagem de <i>light field Broken_Mirror</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	70
Figura B.2 – Imagem de <i>light field Color_Chart_1</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	70
Figura B.3 – Imagem de <i>light field Desktop</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	70
Figura B.4 – Imagem de <i>light field Friends_1</i> (a) original comparada com as imagens	

reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	71
Figura B.5 – Imagem de <i>light field Game_Board</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	71
Figura B.6 – Imagem de <i>light field Houses_&_Lake</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	71
Figura B.7 – Imagem de <i>light field Poppies</i> (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%	72
Figura B.8 – Imagem de <i>light field Broken_Mirror</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	72
Figura B.9 – Imagens de <i>light field Broken_Mirror</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	73
Figura B.10 – Imagem de <i>light field Color_Chart_1</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	73
Figura B.11 – Imagens de <i>light field Color_Chart_1</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	74
Figura B.12 – Imagem de <i>light field Desktop</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	74
Figura B.13 – Imagens de <i>light field Desktop</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	75
Figura B.14 – Imagem de <i>light field Friends_1</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	75
Figura B.15 – Imagens de <i>light field Friends_1</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	76
Figura B.16 – Imagem de <i>light field Game_Board</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%	76

Figura B.17 – Imagens de <i>light field Game_Board</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	77
Figura B.18 – Imagem de <i>light field Houses_&_Lake</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%.....	77
Figura B.19 – Imagens de <i>light field Houses_&_Lake</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%.....	78
Figura B.20 – Imagem de <i>light field Poppies</i> (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%.....	78
Figura B.21 – Imagens de <i>light field Poppies</i> reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%	79

LISTA DE TABELAS

Tabela 1 – Comparativo de eficiência computacional (média global do banco de dados)	58
Tabela A.1 – Resultados detalhados da compressão da imagem <i>Broken_Mirror</i> via 4D-DCT	63
Tabela A.2 – Resultados detalhados da compressão da imagem <i>Broken_Mirror</i> via GFT	63
Tabela A.3 – Resultados detalhados da compressão da imagem <i>Color_Chart_1</i> via 4D-DCT	63
Tabela A.4 – Resultados detalhados da compressão da imagem <i>Color_Chart_1</i> via GFT	64
Tabela A.5 – Resultados detalhados da compressão da imagem <i>Desktop</i> via 4D-DCT	64
Tabela A.6 - Resultados detalhados da compressão da imagem <i>Desktop</i> via GFT.....	65
Tabela A.7 – Resultados detalhados da compressão da imagem <i>Friends_1</i> via 4D-DCT	65
Tabela A.8 – Resultados detalhados da compressão da imagem <i>Friends_1</i> via GFT.....	65
Tabela A.9 – Resultados detalhados da compressão da imagem <i>Game_Board</i> via 4D-DCT ..	66
Tabela A.10 – Resultados detalhados da compressão da imagem <i>Game_Board</i> via GFT	66
Tabela A.11 – Resultados detalhados da compressão da imagem <i>Houses_&_Lake</i> via 4D-DCT	66
Tabela A.12 – Resultados detalhados da compressão da imagem <i>Houses_&_Lake</i> via GFT ..	67
Tabela A.13 – Resultados detalhados da compressão da imagem <i>Parc_du_Luxembourg</i> via 4D-DCT	67
Tabela A.14 – Resultados detalhados da compressão da imagem <i>Parc_du_Luxembourg</i> via GFT.....	68
Tabela A.15 – Resultados detalhados da compressão da imagem <i>Poppies</i> via 4D-DCT	68
Tabela A.16 – Resultados detalhados da compressão da imagem <i>Poppies</i> via GFT	68
Tabela A.17 – Resultados detalhados da compressão da imagem <i>Red_White_Building</i> via 4D-DCT	69
Tabela A.18 – Resultados detalhados da compressão da imagem <i>Red_White_Building</i> via GFT.....	69

LISTA DE ABREVIATURAS E SIGLAS

1D	Unidimensional
2D	Bidimensional
3D	Tridimensional
4D	Quadrimensional
7D	Heptadimensional
1D-DCT	Transformada Discreta do Cosseno em Uma Dimensão <i>1-Dimensional Discrete Cosine Transform</i>
2D-DCT	Transformada Discreta do Cosseno em Duas Dimensões <i>2- Dimensional Discrete Wavelet Transform</i>
3D-DCT	Transformada Discreta do Cosseno em Três Dimensões <i>3-Dimensional Discrete Cosine Transform</i>
3D-DWT	Transformada Discreta de Wavelet em Três Dimensões <i>3-Dimensional Discrete Wavelet Transform</i>
4D-DCT	Transformada Discreta do Cosseno em Quatro Dimensões <i>4-Dimensional Discrete Cosine Transform</i>
4D-DWT	Transformada Discreta de Wavelet em Quatro Dimensões <i>4-Dimensional Discrete Wavelet Transform</i>
CCD	Dispositivo de Carga Acoplada <i>Charge-Coupled Device</i>
CODEC	Codificador/Decodificador
DCT	Transformada Discreta do Cosseno <i>Discrete Cosine Transform</i>
DFT	Transformada Discreta de Fourier <i>Discrete Fourier Transform</i>
DVD	<i>Digital Versatile Disc</i>
DWT	Transformada Wavelet Discreta <i>Discrete Wavelet Transform</i>
GB	Gigabyte
GFT	Transformada de Fourier sobre Grafos

Graph Fourier Transform

GPU	Unidade de Processamento Gráfico <i>Graphics Processing Unit</i>
GSO	Operador de Deslocamento de Grafo <i>Graph Shift Operator</i>
GSP	Processamento de Sinais em Grafos <i>Graph Signal Processing</i>
HDCA	Matriz de Câmeras de Alta Densidade <i>High Density Camera Array</i>
ICME	International Conference on Multimedia and Expo
IDCT	Transformada Discreta Inversa do Cosseno <i>Inverse Discrete Cosine Transform</i>
IGFT	Transformada Inversa de Fourier sobre Grafos <i>Inverse Graph Fourier Transform</i>
ISO	Organização Internacional de Normalização <i>International Organization for Standardization</i>
JPEG	<i>Joint Photographic Experts Group</i>
KLT	Transformada de Karhunen-Loève <i>Karhunen-Loève Transform</i>
LZW	Lempel-Ziv-Welch
PSNR	Relação Sinal-Ruído de Pico <i>Peak Signal-to-Noise Ratio</i>
RAM	Memória de Acesso Aleatório <i>Random Access Memory</i>
SD	Definição Padrão <i>Standard Definition</i>
SfM	Estrutura a partir do Movimento <i>Structure from Motion</i>
SSIM	Índice de Similaridade Estrutural <i>Structural Similarity Index</i>
VS Code	Visual Studio Code

WHT Transformada de Walsh-Hadamard
Walsh-Hadamard Transform

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Contextualização	18
1.2	Objetivo Geral	23
1.3	Objetivos Específicos	23
2	FUNDAMENTAÇÃO TEÓRICA.....	23
2.1	Imagens Digitais 2D	23
2.2	Imagens de <i>Light Field</i>	25
2.3	Técnicas de Compressão de Imagens	29
2.4	Transformada Discreta do Cosseno (DCT)	33
2.5	Fundamentos da Teoria dos Grafos	36
2.6	Processamento de Sinais sobre Grafos (GSP)	38
2.7	Transformada de Fourier sobre Grafos (GFT)	39
3	MATERIAIS E MÉTODOS.....	42
3.1	Ambiente experimental	42
3.2	Implementação do Método Baseado na 4D-DCT.....	43
3.3	Implementação do Método Baseado na GFT	45
3.4	Critérios de Avaliação e Comparação	47
4	RESULTADOS E DISCUSSÕES	47
4.1	Análise de Desempenho da Compressão com a 4D-DCT	47
4.2	Análise de Desempenho da Compressão com a GFT.....	51
4.3	Análise Comparativa	56
4.3.1	Desempenho Médio em Qualidade (PSNR e SSIM)	56
4.3.2	Análise de Tempo de Processamento.....	58
4.3.3	Comparação Global entre os Métodos	58
5	CONCLUSÃO	59
	REFERÊNCIAS	61
	APÊNDICE A – Tabelas de Resultados Quantitativos	63
	APÊNDICE B – Resultados Visuais Complementares	70

1 INTRODUÇÃO

1.1 Contextualização


A compressão de dados desempenha um papel fundamental na redução da quantidade de informação necessária para representar um conjunto de dados, removendo redundâncias e elementos de menor relevância. Nesse contexto, “dados” dizem respeito ao meio pelo qual as informações são transmitidas ou armazenadas. Diversas técnicas são aplicadas para alcançar essa redução, como ocorre no formato .jpg, amplamente associado ao padrão do *Joint Photographic Experts Group* (JPEG). Em compressão de imagens, o desafio central é diminuir o tamanho dos dados sem degradar a qualidade perceptível, preservando as informações essenciais (Gonzalez; Woods, 2010; Marques Filho; Vieira Neto, 1999). Atualmente, há uma variedade de métodos capazes de realizar essa tarefa com alta eficiência, permitindo reduzir significativamente o espaço de armazenamento sem perda das características importantes. Entre os algoritmos mais utilizados destacam-se a transformada discreta do cosseno (DCT, do inglês *Discrete Cosine Transform*) e a transformada *wavelet* discreta (DWT, do inglês *Discrete Wavelet Transform*). A relevância da compressão decorre de seus benefícios diretos, como economia de espaço, menor necessidade de processamento e redução dos custos energéticos e computacionais (Yu et al., 2024).

A compressão de imagens é essencial em aplicações que envolvem tanto o armazenamento de fotos digitais em alta resolução quanto a transmissão eficiente de imagens pela *internet*. Um exemplo ilustrativo apresentado por Gonzalez e Woods (2010a) destaca a enorme quantidade de dados necessária para armazenar um filme de duas horas com resolução 720x480x24 bits. Considerando uma taxa de 30 quadros por segundo, o conteúdo digital em definição padrão (SD) alcançaria cerca de 224 GB, o que demandaria 27 DVDs de camada dupla (8,5 GB cada) para ser armazenado. Esse exemplo evidencia a relevância de técnicas de compressão para tornar viável o uso de imagens e vídeos em escala ampla.

A função plenóptica é um conceito central na representação visual, pois descreve a intensidade luminosa observada a partir de qualquer ponto de vista ou posição dentro do espaço tridimensional. Essa função engloba informações sobre direção angular, espectro de comprimentos de onda e variações temporais (Ferreira, 2020). Em uma câmera *pinhole*, por exemplo, os raios de luz que atravessam o orifício podem ser parametrizados pelas coordenadas esféricas $P(\theta, \phi)$, como mostrado na Figura 1. No caso de câmeras coloridas, essa modelagem pode ser estendida para $P(\theta, \phi, \lambda, t)$, incorporando o comprimento de onda (λ) e o tempo (t)

em cenas dinâmicas. Uma descrição plenóptica abrangente é obtida ao considerar todas as posições possíveis no espaço tridimensional (x, y, z) , resultando em uma representação 7D: $P(x, y, z, \theta, \phi, \lambda, t)$ (Ebrahimi et al., 2016).

Figura 1 – Representação esquemática da captura plenóptica de uma cena por meio de uma câmera *pinhole* que realiza o escaneamento. Os raios luminosos que atravessam o orifício da câmera codificam os valores da função plenóptica (P), que é parametrizada em sete dimensões, incluindo a posição (x, y, z) , ângulo (θ, ϕ) , comprimento de onda (λ) e tempo (t).




Fonte: Ebrahimi et al., 2016

Diferentemente das imagens tradicionais e das técnicas convencionais de representação visual, a função plenóptica expande de forma significativa as possibilidades de captura e análise, oferecendo uma descrição mais rica e fiel da cena. Ao permitir representar detalhes sobre a distribuição da luz em diversas direções e posições, essa abordagem proporciona uma visão mais completa do espaço tridimensional. Entretanto, essa abundância de informações implica um aumento substancial no volume de dados gerados, criando desafios tanto para armazenamento quanto para processamento. Para que esse conceito seja aplicável de maneira eficiente, é necessário adotar estratégias que reduzam a dimensionalidade sem sacrificar a fidelidade visual ou a qualidade da representação. Nesse cenário, surgiram formatos de imagem inspirados pela função plenóptica, como as imagens de *light field*, que procuram equilibrar a riqueza de detalhes com a viabilidade prática de uso (Ferreira, 2020).

As imagens de *light field* fornecem uma representação visual mais rica do ambiente ao

descreverem como os raios de luz se distribuem no espaço. Essa abordagem supera a captura bidimensional convencional ao registrar simultaneamente informações espaciais e angulares. Há dois métodos principais para adquirir esse tipo de imagem: por meio de um *array* denso de câmeras ou utilizando uma câmera com microlentes (*lenslets*). No caso do *array* de câmeras, ilustrado na Figura 2, cada dispositivo registra uma perspectiva distinta da cena, produzindo um conjunto de imagens em que cada uma corresponde a uma visão e angulação específicas. Esse tipo de captura é especialmente eficaz para reconstruções sob diferentes pontos de observação, possibilitando aplicações como refocagem e geração de efeitos tridimensionais. Já quando as imagens de *light field* são obtidas por câmeras com microlentes, o resultado inicial apresenta o padrão conhecido como “olho de mosca” (*fly eye*). A Figura 3 ilustra o esquema óptico desse processo de captura. Nesse arranjo, as microlentes registram amostras dos raios de luz provenientes de diversas direções, permitindo que informações angulares e espaciais sejam capturadas em um único sensor compacto (Ferreira, 2020).

Figura 2 – Exemplo de um sistema de *array* de câmeras.




Fonte: Wilburn et al., 2005

A representação de imagens de *light field* é estruturada em quatro dimensões, em que duas correspondem ao plano de vistas e as outras duas ao plano espacial. Essa organização multidimensional torna insuficientes muitas das técnicas tradicionais aplicadas a imagens bidimensionais, exigindo abordagens específicas para lidar com a maior complexidade envolvida. Estudos realizados por Alves et al., (2018) demonstraram que tanto os conjuntos de dados obtidos por câmeras com microlentes quanto aqueles capturados por matrizes de câmeras de alta densidade (HDCA, do inglês *High Density Camera Array*) apresentam uma estrutura

quadrimensional com redundância significativa, possibilitando uma exploração mais eficiente do que suas versões 2D. Com base nessa constatação, Carvalho et al., (2018) propuseram um CODEC (codificador/decodificador) específico para imagens *lenslet* fundamentado na Transformada Discreta do Cosseno em quatro dimensões (4D-DCT), evidenciando o potencial dessa abordagem para compressão. Assim, a combinação entre a natureza quadrimensional das imagens de *light field* e sua alta redundância abre espaço para métodos avançados de processamento e compressão, consolidando a 4D-DCT como uma alternativa promissora nesse contexto (Ferreira, 2020).

Figura 3 – Esquema de uma câmera de *light field* baseada em arranjo de microlentes. O conjunto de imagens elementares resultante exemplifica o padrão visual conhecido como *fly eye*.



Fonte: Lafruit et al., 2016

Paralelamente ao desenvolvimento de métodos baseados em transformadas clássicas, como a 4D-DCT, o campo do processamento de sinais tem explorado novas formas de modelar as interdependências complexas presentes em sinais de alta dimensionalidade. Uma abordagem que vem ganhando destaque é o processamento de sinais em grafos, que permite representar dados não apenas por sua posição em uma grade regular, mas pelas relações estruturais entre seus componentes. Nesse sentido, grafos constituem estruturas matemáticas amplamente utilizadas para modelar relações entre elementos, com aplicações em áreas como redes sociais, biologia, transporte e processamento de sinais e imagens. Um grafo é definido por $G = (V, E)$, em que V representa o conjunto de vértices e E o conjunto de arestas que conectam pares de vértices. A forma como esses elementos são organizados define sua topologia, que pode ser

estática, mantendo uma estrutura fixa para diferentes dados, ou dinâmica, adaptando-se ao conteúdo processado. No contexto de imagens plenópticas, o uso de topologias dinâmicas permite representar de maneira mais fiel as relações locais entre as sub-imagens do *light field*, o que é relevante para tarefas como filtragem, análise espectral e compressão (Ferreira, 2020; Shuman et al., 2013).

A transformada de Fourier sobre grafos (GFT, do inglês *Graph Fourier Transform*) utiliza a estrutura do grafo para analisar sinais definindo frequências a partir do espectro da matriz Laplaciana. Nesse contexto, componentes associados a autovalores baixos representam variações suaves ao longo do grafo, enquanto autovalores altos correspondem a variações abruptas. Essa interpretação espectral possibilita aplicações em compressão, em que coeficientes de alta frequência pode ser removidos para reduzir redundâncias mantendo a informação essencial (Sandryhaila; Moura, 2013; Shuman et al., 2013). Ao permitir que a topologia seja adaptada ao conteúdo dos dados, abordagens baseadas em grafos tornam-se especialmente relevantes para sinais de alta dimensionalidade, como as imagens de *light field*, que apresentam correlações complexas entre seus múltiplos pontos de vista.

Em paralelo às abordagens baseadas em grafos, a DCT permanece como uma ferramenta consolidada em sistemas de compressão com perdas. Desde sua formulação clássica para imagens 2D (Ahmed; Hein, 1978; Ahmed; Natarajan, 1977), a DCT tornou-se a base do padrão JPEG, além de ser empregada em compressão de vídeo e em diversos tipos de sinais (Ahmed; Milne; Harris, 1975; Wang; Mukherjee, 2023). Considerando que imagens de *light field* possuem uma estrutura naturalmente quadridimensional, a extensão da DCT para quatro dimensões (4D-DCT) torna-se uma escolha coerente e eficiente, sendo inclusive explorada em trabalhos anteriores (Carvalho et al., 2018; Ferreira, 2020). A importância dessa linha de pesquisa é reforçada pelo projeto JPEG Pleno, que busca estabelecer novos padrões específicos para dados plenópticos e incentiva a avaliação de metodologias capazes de alcançar alta eficiência de compressão com baixo custo computacional.

Diante dessas perspectivas, este trabalho propõe uma análise comparativa entre duas abordagens distintas de compressão de imagens de *light field*: a 4D-DCT, representando uma extensão natural das técnicas consagradas de compressão baseadas em transformadas, e a GFT, que explora a estrutura gráfica associada aos dados por meio de topologias dinâmicas. Ambas as técnicas serão aplicadas a imagens da base JPEG Pleno, seguindo um fluxo comum de pré-processamento e redução dimensional. A comparação será conduzida por meio de métricas quantitativas, como o *Peak Signal-to-Noise Ratio* (PSNR) e o *Structural Similarity Index* (SSIM), e pela avaliação da complexidade computacional, de modo a identificar as vantagens,

limitações e potencial de cada abordagem na compressão de imagens plenópticas.

1.2 Objetivo Geral

Realizar uma análise comparativa entre a transformada discreta do cosseno em quatro dimensões (4D-DCT) e a transformada de Fourier sobre grafos (GFT) aplicadas à compressão de imagens de *light field*, avaliando a qualidade das imagens reconstruídas, a eficiência de compactação de energia e a complexidade computacional de cada método.

1.3 Objetivos Específicos

- Estudar os conceitos teóricos de imagens de *light field*, da Transformada Discreta do Cosseno em quatro dimensões (4D-DCT) e da Transformada de Fourier sobre Grafos (GFT);
- Desenvolver algoritmos para compressão de imagens de *light field* utilizando a 4D-DCT e a GFT;
- Realizar simulações de compressão e reconstrução de imagens de *light field* com ambas as técnicas, variando taxas de retenção de coeficientes;
- Avaliar a qualidade das imagens reconstruídas por meio das métricas objetivas PSNR (*Peak Signal-to-Noise Ratio*) e SSIM (*Structural Similarity Index*);
- Analisar a complexidade computacional de cada método, considerando o tempo de execução e custo de processamento;
- Comparar os resultados obtidos, destacando vantagens, limitações e potenciais cenários de aplicação para cada abordagem.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Imagens Digitais 2D

A formação de uma imagem resulta da interação entre uma fonte de iluminação e os elementos de uma determinada cena. Essa interação pode envolver não apenas luz visível, mas também outras formas de energia, como radiação infravermelha, raios X ou ultrassom, dependendo do tipo de aplicação e do sistema de aquisição utilizado. O processo de captura dessas informações é realizado por sensores, que podem estar organizados de três formas principais: por sensor único, por varredura de linha ou em arranjos matriciais.

O sistema de sensor único exige deslocamentos relativos nas direções x e y entre o

sensor e a cena. Esse método é eficiente para aplicações em que o movimento pode ser controlado com precisão, como em sistemas de microscopia ou digitalização. Os sensores de varredura de linha, por sua vez, são amplamente empregados em imageamento aéreo e em equipamentos industriais de inspeção, capturando uma linha por vez e utilizando o deslocamento mecânico para formar a imagem completa. Já os sensores matriciais, como as matrizes de dispositivos de carga acoplada (CCD, do inglês *Charge-Coupled Device*), são amplamente utilizados em câmeras digitais e outros instrumentos que utilizam sensores de luz, pois permitem capturar toda a cena de forma simultânea, convertendo a energia refletida pelos objetos em sinais elétricos que representam a intensidade luminosa de cada ponto da imagem (Gonzalez; Woods, 2010).

A aquisição de imagens digitais tem como objetivo transformar os sinais físicos provenientes do ambiente em informações numéricas manipuláveis por sistemas computacionais. Os sensores geralmente produzem sinais contínuos de tensão ou corrente, cuja amplitude e comportamento espacial estão diretamente relacionados ao fenômeno físico captado. A conversão desses sinais para o domínio digital ocorre por meio de dois processos fundamentais: amostragem e quantização (Gonzalez; Woods, 2010).

Na etapa de amostragem, são selecionados valores discretos ao longo da imagem contínua, tanto em relação às coordenadas espaciais quanto à amplitude do sinal. Já a quantização consiste em converter esses valores contínuos em níveis discretos, normalmente representados por números inteiros. O resultado é uma matriz numérica que descreve a imagem em termos de intensidade luminosa de cada ponto. O método de amostragem depende diretamente da arquitetura do sistema de captura. Em dispositivos que utilizam movimento mecânico, a resolução espacial é controlada pelo número de incrementos possíveis no deslocamento, sendo limitada por fatores ópticos e eletrônicos. Em sistemas de varredura de linha, o número de sensores define a resolução em uma direção, enquanto o deslocamento define a outra. Nos sensores matriciais, o número de elementos da matriz determina a resolução nas duas direções, dispensando o uso de mecanismos móveis (Gonzalez; Woods, 2010).

Matematicamente, uma imagem digital é representada por uma função $f(x, y)$, onde x e y são coordenadas espaciais discretas, e o valor de f em cada ponto corresponde ao nível de intensidade ou brilho associado a esse pixel. Essa função é obtida a partir da amostragem e quantização de uma função contínua $f(s, t)$. As imagens digitais podem ser expressas por diferentes formas de representação, como uma visualização gráfica, uma exibição em monitor ou uma matriz numérica bidimensional. É convencional adotar a origem da imagem digital no canto superior esquerdo, com o eixo x orientado para baixo e o eixo y para a direita, padrão

amplamente utilizado em monitores e dispositivos de exibição (Gonzalez; Woods, 2010).

A qualidade de uma imagem digital está diretamente relacionada à densidade de amostragem e ao número de níveis de quantização empregados. Esses parâmetros definem a resolução espacial e o detalhamento tonal da imagem, influenciando tanto a fidelidade visual quanto o volume de dados necessários para o armazenamento e a transmissão. Dessa forma, o número total de bits exigido para representar uma imagem é função do número de linhas e colunas da matriz e do número de níveis de intensidade possíveis. O equilíbrio entre resolução, qualidade e eficiência de armazenamento é um fator essencial em qualquer sistema de processamento e compressão de imagens digitais (Gonzalez; Woods, 2010).

2.2 Imagens de *Light Field*

As imagens de *light field* representam um avanço expressivo na forma como as informações visuais são capturadas e processadas. Essa tecnologia permite registrar não apenas a intensidade luminosa proveniente de cada ponto de uma cena, como ocorre na fotografia convencional, mas também as direções dos raios de luz que compõem essa cena. Essa capacidade de registrar o comportamento angular da luz torna possível obter representações muito mais completas do ambiente, o que explica o crescente interesse da comunidade científica nesse campo (Ihrke; Restrepo; Mignard-Debise, 2016; Wu et al., 2017).


Enquanto uma câmera tradicional registra uma projeção bidimensional da luz incidente em um plano, as imagens de *light field* armazenam informações que descrevem a radiação luminosa sob múltiplas direções e posições espaciais. Dessa forma, detalhes angulares que seriam perdidos na captura convencional são preservados, possibilitando uma reconstrução mais fiel do espaço tridimensional. Essa estrutura multidimensional fornece uma base robusta para o desenvolvimento de técnicas avançadas em visão computacional, permitindo a realização de tarefas como refocagem após a captura, estimativa de profundidade, segmentação de objetos e estabilização de vídeo. Além dessas aplicações, a natureza informacional das imagens de *light field* também favorece a análise de materiais e o aprimoramento de técnicas de renderização e reconstrução de cenas (Wu et al., 2017).

A representação matemática de uma imagem de *light field* ocorre em um espaço de quatro dimensões, no qual os raios de luz são parametrizados por suas interseções com dois planos distintos. O primeiro plano é definido pelas coordenadas (u, v) e o segundo pelas coordenadas (s, t) . Assim, um raio luminoso que passa pelo primeiro plano em (u, v) e cruza o segundo em (s, t) é representado por $L(u, v, s, t)$. Essa notação descreve de forma concisa a

trajetória e o comportamento angular da luz. A Figura 4 ilustra graficamente essa parametrização, evidenciando como cada vista de uma imagem de *light field* é organizada a partir dessas coordenadas (Wu et al., 2017).


A estrutura de uma *light field* pode ser interpretada como um conjunto de sub-imagens organizadas em uma matriz de vistas. Cada sub-imagem corresponde a um ponto de vista específico dentro da cena capturada. Fixando as coordenadas (u, v) , é possível extrair uma única sub-imagem, como mostrado na Figura 5a. De maneira análoga, ao manter constantes as coordenadas (u, s) ou (t, v) , obtém-se uma linha ou coluna dessa matriz, representando um recorte específico da estrutura quadrimensional da *light field* (Figura 5b). Essa organização permite explorar a informação angular e espacial de forma independente, o que é fundamental para técnicas de compressão, reconstrução e manipulação de dados visuais (Wu et al., 2017).

Figura 4 – Visualização de todas as vistas de uma imagem de *light field* capturada por um dispositivo com microlentes (*lenslet*), em que cada vista é referenciada por um sistema de coordenadas (s, t) , e a vista central expandida, em que cada pixel é referenciado por um sistema de coordenadas (u, v) .



Fonte: Ferreira, 2020

Figura 5 – Exemplo de (a) uma sub-imagem de uma *light field* e (b) coordenadas us e tv fixas.



Fonte: Wu et al., 2017

A avaliação da qualidade das imagens de *light field* envolve múltiplos critérios, considerando tanto os aspectos espaciais quanto os angulares. A resolução espacial-angular é um dos parâmetros principais e pode ser mensurada com base em padrões como o ISO 12233, que utiliza métodos de borda inclinada. As câmeras de *light field*, por sua capacidade de refoco pós-captura, tendem a apresentar desempenho superior nesse quesito quando comparadas aos sensores convencionais (Wu et al., 2017).

Além da resolução, outros fatores importantes são a qualidade espacial e a consistência angular. A qualidade espacial é geralmente avaliada por métricas objetivas como o PSNR e o SSIM, que medem o grau de preservação dos detalhes e a fidelidade perceptual entre a imagem original e a reconstruída. Já a consistência angular, que avalia a coerência entre diferentes pontos de vista da mesma cena, pode ser analisada tanto por avaliações subjetivas quanto pelo SSIM estendido a um contexto tridimensional. Essas métricas são essenciais para o desenvolvimento e validação de métodos de compressão e de super-resolução, além de servirem como referência na comparação de diferentes abordagens de processamento de *light field* (Wu et al., 2017).

No contexto da compressão, técnicas com perdas (*lossy*) e sem perdas (*lossless*) são amplamente investigadas. Entre os métodos com perdas, destacam-se as abordagens baseadas

em codificação progressiva, codificação preditiva e pseudo-sequência. A codificação por transformada é uma das estratégias mais eficazes, utilizando transformadas como a DCT e a DWT para reduzir a redundância nos dados. Versões expandidas dessas técnicas, como 3D-DCT, 3D-DWT e 4D-DWT, aproveitam as correlações espaciais e angulares de forma mais profunda, resultando em maior eficiência de compressão (Wu et al., 2017).

Outro aspecto importante é a compensação de disparidade, que busca corrigir desalinhamentos entre diferentes pontos de vista, aumentando a coerência entre as sub-imagens. Abordagens como transformadas de pacotes de *wavelets* e decomposições compensadas por disparidade ampliam o desempenho da compressão ao explorar as similaridades intervisuais, o que é especialmente útil em aplicações que exigem alta fidelidade visual (Wu et al., 2017).

A natureza de alta dimensionalidade das imagens de *light field* impõe desafios práticos para armazenamento, transmissão e exibição. Entretanto, o uso de técnicas de compressão eficientes tem permitido avanços significativos na viabilidade dessas imagens em aplicações reais. Projetos e eventos recentes, como a iniciativa JPEG Pleno e o ICME 2016 Grand Challenge on Light-Field Image Compression (Grande Desafio de Compressão de Imagens de *Light Field* do ICME 2016), têm impulsionado o desenvolvimento de esquemas mais otimizados. As técnicas atuais já permitem reduções superiores a 80% na taxa de bits para compressão com perdas e cerca de 60% para compressão sem perdas. Ainda assim, persiste o desafio de equilibrar a qualidade visual e a eficiência computacional, sobretudo em métodos lossy, nos quais a preservação da estrutura angular e espacial da cena é determinante para o desempenho de tarefas como estimativa de profundidade e super-resolução (Wu et al., 2017).

As origens das imagens de *light field* na computação gráfica remontam à década de 1980, quando foram inicialmente utilizadas em síntese de visão inovadora. Com a evolução do poder computacional, seu uso expandiu-se para aplicações mais complexas em visão computacional. Hoje, as imagens de *light field* são utilizadas em uma ampla gama de tarefas, como geração de imagens com abertura sintética, segmentação, efeitos de matriz, detecção e reconhecimento de objetos, manipulação de superfícies refrativas e transparentes, odometria visual, localização e SfM (*Structure from Motion*), além de estabilização e desfocagem de imagens (Wu et al., 2017).

Graças à sua estrutura única, que combina propriedades espaciais e angulares, as *light fields* têm se mostrado uma ferramenta poderosa para a solução de problemas clássicos da visão computacional e da computação gráfica. A exploração de suas características espaço-temporais abre novas possibilidades para o desenvolvimento de vídeos baseados em *light field*, rastreamento de movimento e captura de dinâmicas espaciais. Também é promissora sua

integração com outras modalidades de imagem, como as hiperespectrais, que permitem uma análise mais profunda das propriedades físicas e ópticas dos objetos observados (Wu et al., 2017).

O crescente interesse por essa tecnologia se deve à sua versatilidade e ao potencial de representar cenas complexas de forma rica e detalhada. Avanços em hardware tornaram a captura de *light fields* mais acessível, permitindo sua utilização em sistemas de diferentes escalas, desde dispositivos especializados de alto custo até câmeras portáteis, como Raytrix, Lytro e PiCam. Se antes as aplicações se restringiam à refocagem digital e à visualização sintética, hoje as imagens de *light field* são empregadas em aprimoramento de imagens, segmentação, percepção de profundidade e visualização tridimensional. Apesar dos desafios ligados à resolução e à complexidade computacional, os progressos recentes em compressão e integração tecnológica apontam para um futuro no qual as *light fields* ocuparão um papel central em áreas como multimídia, biologia, realidade virtual e aumentada. Sistemas de captura avançados, como o Lytro Cinema, reforçam essa tendência ao permitir a reconstrução precisa de cenas dinâmicas e uma compreensão mais profunda de ambientes complexos (Wu et al., 2017).

2.3 Técnicas de Compressão de Imagens

A compressão de dados consiste em um conjunto de técnicas voltadas à redução do volume de informações necessárias para representar um conteúdo digital, eliminando redundâncias presentes nos dados originais. Esse processo é essencial para otimizar o armazenamento e a transmissão de imagens, tornando possível a utilização mais eficiente dos recursos computacionais e da largura de banda disponível (Gonzalez; Woods, 2010).

A eficiência da compressão é normalmente expressa pela redundância relativa dos dados R , definida por

$$R = 1 - \frac{1}{C} \quad (1)$$

onde C representa a taxa de compressão, calculada por

$$C = \frac{b}{b'} \quad (2)$$

em que b é o número de bits da imagem original e b' o número de bits da imagem comprimida. Por exemplo, quando $C = 10$ (ou 10:1), significa que a imagem original contém

10 bits para cada 1 bit da versão comprimida, resultando em uma redundância de 90% ($R = 0,9$) (Gonzalez; Woods, 2010).

No contexto da compressão digital de imagens, b corresponde à quantidade de bits necessária para representar uma imagem como uma matriz bidimensional de intensidades. Esses arranjos de intensidade 2D apresentam três formas principais de redundância, cuja eliminação é o foco das técnicas de compressão: redundância de codificação, redundância espacial/temporal e informações irrelevantes (Gonzalez; Woods, 2010).

1. Redundância de codificação: Ocorre quando a atribuição de códigos aos eventos não explora adequadamente suas probabilidades de ocorrência. Essa situação é comum em representações binárias naturais, nas quais as intensidades de uma imagem são codificadas sem considerar a distribuição estatística dos valores de pixel. Como os histogramas de imagens reais geralmente não são uniformes, há uma ineficiência na representação, resultando em redundância. A compressão busca corrigir isso por meio de métodos que ajustam o código às probabilidades de ocorrência, reduzindo o número médio de bits por símbolo.
2. Redundância espacial e temporal: Em imagens bidimensionais, os pixels tendem a ser altamente correlacionados com seus vizinhos, tanto no espaço quanto no tempo (no caso de sequências de vídeo). Essa correlação permite prever o valor de um pixel a partir de outros já conhecidos, o que abre espaço para a remoção de informações repetitivas. Estratégias como diferenças entre pixels adjacentes, codificação de comprimento de execução (*run-length*) ou transformações específicas são utilizadas para reduzir essa dependência e aumentar a eficiência da representação.
3. Informações irrelevantes: Nem todos os dados presentes em uma imagem são essenciais para sua percepção visual ou para o objetivo da aplicação. Em muitos casos, partes homogêneas ou detalhes imperceptíveis ao olho humano podem ser descartados sem afetar significativamente a qualidade percebida. A remoção desses elementos contribui para uma compressão mais eficiente, sobretudo em sistemas com perda controlada.

A compressão de imagens, portanto, busca eliminar informações redundantes e irrelevantes, reduzindo o volume de dados sem comprometer de forma significativa a qualidade visual. Esses sistemas são compostos por codificadores e decodificadores, que têm como função, respectivamente, transformar a imagem original em uma forma compacta e reconstruí-la. Dependendo do grau de fidelidade desejado, a compressão pode ser livre de perdas, quando a imagem reconstruída é idêntica à original; com perdas controladas, quando pequenas diferenças são introduzidas em troca de uma maior taxa de compressão; ou ainda híbrida,

quando combina características de ambas as abordagens (Gonzalez; Woods, 2010).

Os formatos de arquivo e padrões de compressão determinam como os dados serão estruturados e reduzidos, garantindo a interoperabilidade entre sistemas e a eficiência na troca de informações. Entre as técnicas mais utilizadas estão as codificações de Huffman, Golomb, aritmética, Lempel-Ziv-Welch (LZW), *run-length*, codificação baseada em símbolos, planos de bits, transformadas em blocos, predição e *wavelets*, cada uma com suas próprias vantagens em termos de complexidade e desempenho (Gonzalez; Woods, 2010).

Dentre essas abordagens, destaca-se a compressão baseada em transformadas em blocos, que é amplamente empregada em padrões de imagens estáticas e vídeos. Nesse método, a imagem é dividida em blocos menores, como segmentos de 8×8 pixels, processados de forma independente por uma transformada bidimensional, como a transformada discreta de Fourier (DFT, do inglês *Discrete Fourier Transform*) ou outras transformadas discretas 2D. A aplicação da transformada converte os valores espaciais dos pixels em coeficientes que representam a distribuição de energia da imagem no domínio transformado (Gonzalez; Woods, 2010).

Após a transformação, a maioria desses coeficientes apresenta valores de pequena magnitude, podendo ser simplificados ou até mesmo eliminados com pouca perda de informação perceptível. Essa característica é explorada durante a quantização, etapa responsável por introduzir compressão efetiva ao reduzir o número de bits usados na representação dos coeficientes. Assim, a compressão ocorre essencialmente na quantização, e não durante a etapa de transformação em si (Gonzalez; Woods, 2010).

A transformada direta de uma sub-imagem $g(x, y)$ de dimensão $n \times n$ pode ser expressa de forma geral por

$$T(u, v) = \sum_{x=0}^{n-1} \sum_{y=0}^{n-1} g(x, y) r(x, y, u, v) \quad (3)$$

Para $u, v = 0, 1, 2, \dots, n - 1$. Dada $T(u, v)$, a sub-imagem $g(x, y)$ pode ser obtida utilizando a forma geral da transformada inversa discreta

$$g(x, y) = \sum_{u=0}^{n-1} \sum_{v=0}^{n-1} T(u, v) s(x, y, u, v) \quad (4)$$

Para $x, y = 0, 1, 2, \dots, n - 1$. Os termos $r(x, y, u, v)$ e $s(x, y, u, v)$ são referidos como os *kernels* da transformada direta e inversa, respectivamente, também conhecidos como funções de base ou imagens de base. Os $T(u, v)$ são os coeficientes da transformada, que representam

a contribuição de cada função de base $s(x, y, u, v)$ na composição da imagem $g(x, y)$ (Gonzalez; Woods, 2010).

Quando um *kernel* é dito separável, ele pode ser expresso como

$$r(x, y, u, v) = r_1(x, u)r_2(y, v) \quad (5)$$

Essa propriedade é computacionalmente valiosa, pois permite que a transformada 2D seja calculada eficientemente por meio de passes de linha-coluna (ou coluna-linha) da transformada 1D correspondente (Gonzalez; Woods, 2010).

A escolha da transformada, isto é, dos *kernels* utilizados para representar o sinal em outro domínio, desempenha papel central na compactação de energia, na complexidade computacional e no erro de reconstrução. Embora transformadas amplamente utilizadas em sistemas de compressão por blocos, como a DFT, a WHT e a DCT, apresentem diferentes compromissos entre simplicidade e eficiência, a transformada considerada ótima do ponto de vista de compactação é a de Karhunen-Loève (KLT, do inglês *Karhunen-Loève transform*). A KLT maximiza a concentração de energia ao diagonalizar diretamente a matriz de covariância do sinal, mas sua aplicação prática é limitada, pois exige o cálculo das bases específicas para cada conjunto de dados, elevando substancialmente o custo computacional (Gonzalez; Woods, 2010).

Por esse motivo, transformadas de base fixa, como a DFT, WHT ou DCT, permanecem predominantes em aplicações reais. Transformadas não senoidais, como a WHT, tendem a ser computacionalmente mais simples, enquanto transformadas senoidais, como DFT e DCT, alcançam desempenho mais próximo ao da KLT em termos de compactação energética. Entre elas, a DCT é particularmente destacada por conciliar boa eficiência de compressão com implementação viável, o que explica seu uso consolidado em padrões como o JPEG (Gonzalez; Woods, 2010).

Em síntese, as técnicas de compressão de imagens evoluíram com o objetivo comum de otimizar a representação dos dados, aproveitando redundâncias estatísticas, estruturais e perceptuais. A escolha da abordagem adequada depende do tipo de aplicação, do nível de qualidade aceitável e dos recursos computacionais disponíveis. Com isso, a compressão de imagens se consolida como uma etapa indispensável em qualquer sistema moderno de aquisição, processamento e transmissão de dados visuais (Gonzalez; Woods, 2010).

2.4 Transformada Discreta do Cosseno (DCT)

A transformada discreta do cosseno é uma das ferramentas matemáticas mais influentes no campo da compressão de sinais e, desde sua introdução, passou a constituir a base de grande parte dos padrões de compressão de imagens e vídeos. A DCT é uma transformada de base fixa, aplicável a sequências de comprimento finito, e é amplamente utilizada por permitir a decorrelação dos dados e a compactação de energia, características desejáveis em sistemas de codificação por transformada (Gonzalez; Woods, 2010; Wang; Mukherjee, 2023).

Do ponto de vista prático, a KLT representa o referencial teórico ótimo para decorrelação completa e máxima compactação de energia, porém sua aplicação é limitada pela dependência do sinal: as funções de base da KLT variam conforme os dados e, portanto, demandam o cálculo de uma base específica para cada imagem ou bloco, o que impõe um custo computacional elevado. Em contraste, a DCT oferece funções de base fixas e um desempenho que se aproxima do ótimo da KLT para sinais fortemente correlacionados, como é comum em imagens naturais, tornando-a a solução prática preferida em muitos sistemas de compressão (Gonzalez; Woods, 2010; Wang; Mukherjee, 2023).

Matematicamente, para um vetor de sinal s contendo N amostras $s(n)$, com $n = 0, 1, \dots, N - 1$, a reconstrução pela transformada discreta inversa do cosseno (IDCT, do inglês *Inverse Discrete Cosine Transform*) pode ser escrita como uma combinação linear dos vetores de base b_k

$$s(n) = \sum_{k=0}^{N-1} t(k) b_k(n) \quad (6)$$

Os elementos do vetor de base são dados por

$$b_k(n) = \alpha_k \cos\left(\frac{(2n+1)k\pi}{2N}\right), \quad n = 0, 1, \dots, N-1 \quad (7)$$

em que os fatores de normalização α_k são definidos por

$$\alpha_0 = \sqrt{\frac{1}{N}}, \quad \alpha_k = \sqrt{\frac{2}{N}}, \quad k = 0, 1, \dots, N-1 \quad (8)$$

Os coeficientes da transformada direta $t(k)$ são obtidos pela projeção do sinal sobre cada vetor de base, isto é, pelo produto interno entre s e b_k

$$t(k) = \sum_{n=0}^{N-1} s(n)b_k(n) \quad (9)$$

Embora originalmente formulada para sinais unidimensionais, a DCT admite extensão natural a sinais bidimensionais, apropriada para imagens. No caso de uma imagem de dimensão $N \times N$, as imagens de base bidimensionais $B_{k,l}$ são construídas pelo produto vetorial dos vetores de base unidimensionais, $B_{k,l} = b_k b_l^T$, e a imagem S pode ser representada como uma combinação dos termos da transformada 2D

$$S = \sum_{k=0}^{N-1} \sum_{l=0}^{N-1} t(k,l) B_{k,l} \quad (10)$$

Na prática, a propriedade de separabilidade permite implementar a 2D-DCT de maneira eficiente aplicando-se a 1D-DCT a cada linha da matriz de pixels e, em seguida, a cada coluna da matriz resultante, reduzindo o custo computacional em relação a uma implementação 2D direta (Gonzalez; Woods, 2010).

A interpretação física e prática dos coeficientes facilita o uso da DCT em compressão. O coeficiente $t(0,0)$, denominado coeficiente DC, representa o valor médio de intensidade do bloco, enquanto os demais coeficientes $t(k,l)$, com $k,l \neq 0$, representam as componentes de alta frequência espacial, responsáveis pelos detalhes de textura e bordas. A propriedade de compactação de energia observada em blocos de imagens naturais indica que a maior parte da energia está concentrada no coeficiente DC e nos coeficientes de baixa frequência próximos a ele. Já os coeficientes de alta frequência tendem a assumir valores muito próximos de zero. Essa distribuição de energia é explorada na etapa de quantização, que descarta ou reduz a precisão dos coeficientes de alta frequência com impacto visual reduzido, possibilitando altas taxas de compressão sem perda perceptível significativa (Gonzalez; Woods, 2010).


A capacidade de estender a DCT para dimensões maiores, aliada ao seu balanço entre eficiência de compactação e custo computacional, explica sua ampla adoção em sistemas de codificação por transformada e sua consolidação como um padrão prático em compressão visual (Wang; Mukherjee, 2023). A separabilidade da DCT também viabiliza sua extensão para dimensões superiores, como 3D em aplicações de vídeo e, conforme o escopo deste trabalho, 4D para a aplicação em imagens de *light field*. Da mesma forma que ocorre na transição do domínio unidimensional para o bidimensional, a DCT admite uma extensão natural para sinais de dimensões superiores, como é o caso das imagens de *light field*. Nesse contexto específico,

a 4D-DCT permite explorar de forma conjunta as correlações espaciais (u, v) e angulares (s, t) . Para um volume plenóptico quadridimensional, as funções de base 4D são construídas pelo produto dos vetores de base unidimensionais em cada uma das direções, e o sinal original L pode ser representado como uma combinação linear dos termos da transformada 4D

$$L(s, t, u, v) = \sum_{k_s=0}^{N_s-1} \sum_{k_t=0}^{N_t-1} \sum_{k_u=0}^{N_u-1} \sum_{k_v=0}^{N_v-1} t(k_s, k_t, k_u, k_v) B_{k_s, k_t, k_u, k_v}(s, t, u, v) \quad (11)$$

Nesta formulação, os coeficientes $t(k_s, k_t, k_u, k_v)$ são obtidos pela projeção do volume de *light field* sobre as bases quadridimensionais, seguindo a lógica de separabilidade apresentada anteriormente. Na prática, essa propriedade permite que a 4D-DCT seja implementada de forma eficiente através da aplicação sucessiva da 1D-DCT em cada uma das quatro dimensões (as duas dimensões angulares s, t e as duas dimensões espaciais u, v), o que reduz drasticamente a complexidade computacional se comparada a uma operação quadridimensional direta. Essa característica é explorada em arquiteturas de compressão como a proposta por Dlabaja (2019), que adapta o fluxo de processamento do padrão *JPEG baseline* para lidar com a estrutura volumétrica do *light field*.

Figura 6 – Espectro da 4D-DCT de uma imagem de *light field* calculado com blocos de tamanho $8 \times 8 \times 8 \times 8$ com
(a) 100% dos coeficientes mantidos e (b) 1% dos coeficientes mantidos



Fonte: Elaborada pela autora

A Figura 6 exemplifica o espectro de magnitude da 4D-DCT para uma imagem de *light field* do tipo *lenslet*, comparando os cenários de retenção de 100% e 1% dos coeficientes. Conforme observado por Ferreira (2020), o espectro quadridimensional, quando visualizado de forma bidimensional, apresenta um aspecto similar ao caso 2D, com os coeficientes de maior magnitude concentrados no canto superior esquerdo. Essa concentração ocorre tanto no plano

angular (st), observado pela posição dos blocos na grade global, quanto no plano espacial (uv), observado dentro de cada sub-bloco individual. Na imagem com apenas 1% de retenção, a esparsidade torna-se extrema, restando apenas as frequências mais baixas, localizadas preferencialmente no *frame* de posição $s = 0$ e $t = 0$ (Ferreira, 2020; Reřábek; Ebrahimi, 2016).

Segundo estudos de Alves et al. (2018), embora ambos os formatos apresentem correlação quadridimensional, o conjunto de dados obtidos por câmeras de microlentes possui uma redundância 4D significativamente superior ao conjunto HDCA. Essa diferença reside na natureza da captura, visto que no formato *lenslet* a redundância entre as visões (angular) é predominante, enquanto no HDCA a esparsidade concentra-se na dimensão intra-vista (espacial). Visualmente, o espectro das imagens de microlentes é caracterizado por um rápido decaimento da magnitude dos coeficientes, concentrando a informação visual relevante em uma fração mínima do volume total. Esse comportamento justifica a alta eficiência da 4D-DCT na compressão de dados plenópticos do tipo *lenslet*, como os utilizados neste trabalho, permitindo descartar componentes de alta frequência com impacto visual mínimo na reconstrução da cena (Carvalho et al., 2018; Dlabaja, 2019; Reřábek; Ebrahimi, 2016).

2.5 Fundamentos da Teoria dos Grafos

A Teoria dos Grafos oferece uma estrutura matemática poderosa para modelar relações e interconexões entre elementos de um sistema. Um grafo é formado por um conjunto de vértices (ou nós) e um conjunto de arestas que representam as ligações entre esses vértices. Formalmente, um grafo é definido como $G = (V, E)$, em que V é o conjunto de vértices e E o conjunto de arestas que conectam pares de vértices. Quando cada aresta possui um valor associado, representando a intensidade ou relevância da conexão, o grafo é dito ponderado. Esses valores são fundamentais na modelagem de sistemas complexos, pois expressam o grau de similaridade, correlação ou dependência entre os elementos representados (Feofiloff; Kohayakawa; Wakabayashi, 2011).

A forma mais comum de representação algébrica de um grafo é por meio da matriz de adjacência A , na qual cada elemento a_{ij} assume um valor diferente de zero quando há uma conexão entre os vértices i e j . Essa matriz descreve de forma compacta toda a estrutura topológica do grafo. A partir dela, é possível derivar outras matrizes relevantes, como a matriz grau D , que contém em sua diagonal principal o somatório dos pesos das arestas conectadas a cada vértice. Essas duas matrizes, A e D , permitem a definição de um dos operadores mais

importantes da teoria: a matriz Laplaciana (Lima et al., 2021).

A matriz Laplaciana, dada por $L = D - A$, é um operador essencial na análise espectral de grafos. Ela expressa a diferença entre a conectividade local de cada vértice e as conexões estabelecidas com os demais, desempenhando papel análogo ao operador diferencial de segunda ordem no domínio contínuo. Em termos físicos, a Laplaciana captura a variação de um sinal ao longo das conexões do grafo, sendo amplamente empregada em problemas de difusão, segmentação e, mais recentemente, em processamento de sinais em grafos (GSP, do inglês *Graph Signal Processing*). A decomposição espectral dessa matriz fornece autovalores e autovetores que definem a base harmônica do grafo, permitindo analisar variações de sinais em termos de frequência sobre estruturas não euclidianas (Shuman et al., 2013).

No contexto da GFT, a Laplaciana desempenha um papel central. Os autovetores da Laplaciana constituem as bases da transformada, enquanto seus autovalores representam as frequências associadas a cada modo de variação. Dessa forma, sinais definidos sobre os vértices podem ser projetados nesse domínio espectral, revelando componentes de baixa e alta frequência de acordo com a estrutura do grafo. Essa abordagem possibilita uma interpretação análoga à da transformada de Fourier clássica, porém adaptada a dados definidos em domínios irregulares (Ferreira, 2020).

Algumas variações da Laplaciana são frequentemente utilizadas em trabalhos de GSP, como a Laplaciana normalizada simétrica

$$\mathcal{L} = D^{-1/2} L D^{-1/2} \quad (12)$$

Essa forma é especialmente útil quando há grande variação no grau dos vértices, pois promove uma análise espectral mais equilibrada e invariável em relação à escala dos pesos. A escolha entre a Laplaciana combinatória e a normalizada depende do tipo de dado e da aplicação, sendo comum optar pela forma mais adequada ao problema considerado (Lima et al., 2021; Shuman et al., 2013).

De modo geral, o estudo dos grafos permite compreender sistemas complexos sob a ótica das relações e interdependências, e não apenas dos elementos isolados. O avanço do processamento de sinais em grafos expandiu significativamente o campo de aplicação da Teoria dos Grafos, consolidando-a como ferramenta teórica essencial em áreas como análise de redes, modelagem de dados e compressão de imagens. Assim, o uso de representações gráficas e operadores como a Laplaciana tem se mostrado versátil e robusto para a análise de dados estruturados, permitindo a generalização de conceitos clássicos de processamento de sinais para

domínios complexos e irregulares (Feofiloff; Kohayakawa; Wakabayashi, 2011; Ferreira, 2020; Lima et al., 2021; Shuman et al., 2013).

2.6 Processamento de Sinais sobre Grafos (GSP)

O processamento de sinais sobre grafos é uma extensão do processamento de sinais clássico, desenvolvida para lidar com dados definidos em estruturas irregulares, como redes sociais, sistemas biológicos, redes de sensores e representações espaciais complexas. Essa abordagem generaliza conceitos tradicionais do domínio temporal ou espacial para dados modelados por grafos, permitindo análises em domínios onde a estrutura subjacente é não euclidiana (Ortega et al., 2018; Shuman et al., 2013).

No GSP, um sinal sobre o grafo é definido como uma função que associa um valor real a cada vértice, $f: V \rightarrow \mathbb{R}$. Considerando um grafo com N vértices, esse sinal pode ser representado como um vetor $f \in \mathbb{R}^N$, onde a i -ésima entrada f_i corresponde ao valor do sinal no vértice v_i (Lima et al., 2021; Shuman et al., 2013). Diferente do processamento clássico, no GSP o domínio do sinal é determinado pela topologia do grafo, descrita por operadores como a matriz de adjacência A e a matriz laplaciana L , conforme definido na Seção 2.5. Esses operadores codificam as relações de conectividade e são essenciais para modelar a variação ou suavidade dos sinais sobre o grafo (Ortega et al., 2018).

Assim como o processamento de sinais contínuos utiliza o operador diferencial para modelar variações no tempo ou no espaço, o GSP utiliza o operador laplaciano como um análogo discreto, permitindo quantificar como o valor de um sinal em um vértice difere dos seus vizinhos. Essa relação é explorada na filtragem de sinais sobre grafos, um conceito central no GSP. Um filtro linear sobre um grafo é definido como uma função polinomial do operador laplaciano

$$y = h(L)f = \left(\sum_{k=0}^K h_k L^k \right) f \quad (13)$$

onde y é o sinal filtrado e h_k são os coeficientes do filtro (Sandryhaila; Moura, 2013). A ordem K define a localidade do filtro, isto é, quantos “saltos” no grafo são considerados para a agregação de informações. Essa formulação permite projetar filtros passa-baixa, passa-alta ou banda, respeitando a estrutura irregular do grafo (Shuman et al., 2013).

Outra forma de interpretar esse processo é por meio do Operador de Deslocamento de Grafo (GSO, do inglês *Graph Shift Operator*), que generaliza o conceito de deslocamento

temporal. Aplicar o operador A ou L a um sinal f (por exemplo, Af) resulta em um novo sinal onde o valor em cada vértice é uma combinação dos valores de seus vizinhos, representando um “deslocamento” de informação através das conexões do grafo (Ortega et al., 2018).

O GSP é aplicado em diversas áreas, como compressão de dados, segmentação de imagens e análise de redes complexas. No contexto de imagens plenópticas, ele se mostra especialmente promissor, pois permite explorar a redundância existente entre os múltiplos pontos de vista. Grafos podem ser construídos para conectar pixels não apenas pela proximidade espacial, mas também pela semelhança entre raios de luz ao longo das dimensões espaciais e angulares, possibilitando uma compressão mais eficiente e adaptada à estrutura quadridimensional da *light field* (Ferreira, 2020; Lima et al., 2021).

2.7 Transformada de Fourier sobre Grafos (GFT)

A transformada de Fourier sobre grafos estende o conceito clássico de análise espectral para sinais definidos em estruturas irregulares representadas por grafos $G = (V, E)$. Em domínios clássicos, a transformada de Fourier utiliza funções senoidais como bases ortogonais; já na GFT, as bases precisam refletir a conectividade e a estrutura não euclidiana do grafo. Seu objetivo fundamental é projetar um sinal f , definido nos N vértices do grafo, para um domínio espectral em que suas componentes de frequência e sua distribuição de energia possam ser analisadas. Essa formulação permite lidar com dados cuja organização depende de relações de vizinhança não triviais, algo comum em aplicações modernas como redes, sensores, imagens e representações multidimensionais (Lima et al., 2021; Shuman et al., 2013).

O operador fundamental que estabelece a base da GFT é a Matriz Laplaciana L do grafo, definida como $L = D - A$, onde D é a matriz diagonal dos graus e A é a matriz de adjacência. Esse operador funciona como o análogo discreto do Laplaciano contínuo, capturando diferenças de segunda ordem e refletindo como o sinal varia ao longo da conectividade do grafo. Por ser real e simétrica, L admite uma decomposição espectral completa, expressa por

$$L = U\Lambda U^T \quad (14)$$

Os autovetores u_k formam a base ortogonal da GFT, compondo a matriz U , enquanto os autovalores λ_k , ordenados crescentemente na matriz diagonal Λ , indicam os níveis de variação do sinal sobre o grafo, isto é, suas “frequências”. Esses elementos fornecem a estrutura necessária para analisar sinais em domínios irregulares, onde as noções clássicas de suavidade e oscilação precisam ser adaptadas à topologia do grafo (Lima et al., 2021).

A GFT de um sinal $f \in \mathbb{R}^N$ é obtida pela projeção deste sinal sobre os autovetores da Laplaciana, resultando no vetor espectral

$$\hat{f} = U^T f \quad (15)$$

Cada coeficiente $\hat{f}(\lambda_k)$ representa a contribuição do modo harmônico u_k para o sinal e é calculado por

$$\hat{f}(\lambda_k) = \sum_{i=1}^N f(v_i)u_k(v_i) \quad (16)$$

A transformada inversa de Fourier sobre grafos (IGFT, do inglês *Inverse Graph Fourier Transform*) reconstrói o sinal sem perdas por meio da combinação linear dos modos harmônicos ponderados pelos coeficientes espectrais, dada por

$$f = U\hat{f} \quad (17)$$

A forma expandida dessa reconstrução é

$$f(v_i) = \sum_{k=1}^N \hat{f}(\lambda_k)u_k(v_i) \quad (18)$$

Essa formulação mantém a equivalência conceitual entre domínio espacial e domínio espectral, preservando a completa reversibilidade da transformação (Shuman et al., 2013).

Os autovalores λ_k permitem interpretar as frequências do grafo. O menor autovalor $\lambda_0 = 0$ está associado a um autovetor constante que representa o coeficiente DC. Autovalores pequenos correspondem a autovetores que variam suavemente ao longo do grafo, caracterizando componentes de baixa frequência, que indica que o sinal f tem valores altamente correlacionados em vértices conectados. Por outro lado, autovalores com valores altos correspondem a autovetores altamente oscilatórios, ou seja, de alta frequência, relacionados a variações abruptas ou ruído. Essa ordenação espectral torna possível identificar regiões de maior ou menor variação do sinal e fundamenta a análise de suavidade no domínio do grafo (Shuman et al., 2013).


Nas aplicações envolvendo imagens de *light field*, a GFT tem se mostrado particularmente eficaz por capturar a redundância estrutural presente nos múltiplos pontos de vista. Ao representar as relações espaciais e angulares por meio de um grafo, torna-se possível

concentrar grande parte da energia do sinal nas primeiras componentes espectrais, favorecendo representações mais compactas sem perda significativa de informação (Ferreira, 2020).

A compactação de energia é uma das propriedades centrais que tornam essa abordagem eficiente para compressão. Sinais suaves no domínio do grafo, isto é, com alta correlação entre vértices vizinhos, como ocorre nas estruturas de *light field* modeladas por grafos adequados, concentram a maior parte da energia nos coeficientes $\hat{f}(\lambda_k)$ associados aos baixos autovalores. Consequentemente, coeficientes vinculados a autovalores de valores elevados podem ser descartados ou quantizados com maior intensidade sem comprometer significativamente a qualidade da reconstrução visual, possibilitando altas taxas de compressão. Essa característica torna a GFT uma ferramenta eficiente para reduzir redundâncias espaciais e angulares presentes na estrutura quadridimensional de imagens de *light field* (Ferreira, 2020).

Para ilustrar o impacto da topologia no domínio da frequência e exemplificar essa propriedade de compactação, a Figura 7 apresenta o espectro de magnitude da GFT aplicado a um bloco de *light field* (coordenadas espaciais $u \in [0, 8]$ e $v \in [16, 24]$) utilizando uma topologia em *grid*. Nessa configuração, os nós do grafo são conectados exclusivamente aos seus vizinhos espaciais imediatos. O espectro resultante, visualizado em função dos autovalores da matriz Laplaciana analogamente ao observado em transformadas clássicas como a DCT. Essa similaridade fundamenta-se na premissa de que os autovalores e autovetores da Laplaciana do grafo fornecem uma noção de frequência equivalente à do cenário clássico, em que os componentes de baixa frequência estão associados a variações suaves sobre a estrutura do grafo.

Figura 7 – Espectro de magnitude da GFT para um bloco de *light field* utilizando topologia em *grid* regular



Fonte: Elaborada pela autora

Conforme destacado por Shuman et al. (2013), sinais suaves em relação à estrutura intrínseca do grafo apresentam coeficientes espectrais que decaem rapidamente, o que justifica a concentração de magnitude observada nos primeiros autovalores do exemplo². Esse caso demonstrativo serve como um referencial para observar que a escolha da topologia impacta diretamente a esparsidade do sinal, visto que, na grade regular, as funções de base são independentes do conteúdo da imagem. Nota-se uma concentração significativa de magnitude nos primeiros autovalores, que representam as baixas frequências do grafo, seguida por uma distribuição gradual de energia ao longo das frequências mais elevadas. Esse exemplo demonstrativo serve como um referencial para observar que a escolha da topologia impacta diretamente a esparsidade do sinal, visto que, na grade regular, as funções de base são independentes do conteúdo da imagem.

Apesar de sua fundamentação teórica sólida, a GFT enfrenta um obstáculo significativo: a decomposição espectral completa da Laplaciana apresenta complexidade cúbica em relação ao número de vértices, o que torna sua aplicação inviável em grafos de grande escala. Esse desafio é particularmente relevante em bases de dados de *light field*, cuja dimensionalidade elevada impede a obtenção explícita dos autovetores. Para mitigar essa limitação, diversas abordagens aproximadas têm sido desenvolvidas no contexto do GSP, incluindo filtros polinomiais e métodos baseados em informações locais, que reduzem a dependência da autodecomposição completa e viabilizam operações espectrais aproximadas em grafos de milhares de vértices (Shuman et al., 2013).

3 MATERIAIS E MÉTODOS

3.1 Ambiente experimental

A execução dos métodos baseados em 4D-DCT e GFT foi realizada em um notebook equipado com processador Intel® Core™ i5-7200U (2,50 GHz, 7ª geração), 8 GB de memória RAM e GPU integrada Intel® HD Graphics 620, operando em um sistema operacional de 64 bits.

O desenvolvimento e a execução dos experimentos foram conduzidos em Python, utilizando o Visual Studio Code (VS Code) como ambiente de programação. A escolha dessa linguagem se deve ao seu ecossistema consolidado para computação científica e processamento de sinais. Entre as bibliotecas utilizadas, destacam-se:

- **NumPy**, responsável pela manipulação eficiente de matrizes e pelo suporte às operações de álgebra linear envolvidas nas transformadas multidimensionais e na construção das

matrizes de adjacência;


- **Scikit-Image**, empregada no pré-processamento das imagens de *light field*, incluindo o redimensionamento necessário para padronização dos blocos, além do cálculo das métricas PSNR e SSIM;
- **Matplotlib**, utilizada na análise e visualização dos espectros transformados, gráficos comparativos e resultados quantitativos.

Esse conjunto de ferramentas forneceu o suporte necessário para implementar, testar e analisar todas as etapas do método proposto.

3.2 Implementação do Método Baseado na 4D-DCT

As imagens de *light field* utilizadas nos experimentos foram obtidas do banco de imagens *lenslet* do *Multimedia Signal Processing Group*, disponível no repositório do JPEG Pleno (<https://plenodb.jpeg.org/lf/epfl> (Reřábek; Ebrahimi, 2016)), o qual disponibiliza os dados em formato bruto, organizado de maneira semelhante à estrutura *fly eye*, vide Figura 8a. Como esse formato contém regiões sem sub-imagens e para simplificar o processamento, as imagens passaram por um ajuste dimensional que reorganiza o conteúdo para formar blocos regulares de 8×8 sub-imagens, eliminando as áreas vazias. Após o ajuste as imagens foram salvas em formato .png, resultando em uma representação bidimensional.

Figura 8 – (a) Imagem de *light field* na estrutura *fly eye* e (b) Imagem de *light field* organizada numa matriz de 8×8 sub-imagens.




Fonte: Elaborada pela autora

Após o pré-processamento, para possibilitar a aplicação da 4D-DCT, cada imagem de *light field* foi convertida de sua representação bidimensional para a sua estrutura natural quadridimensional, isto é, formando a matriz de sub-imagens que descreve as duas dimensões espaciais e as duas dimensões angulares, resultando numa imagem com dimensões

$8 \times 8 \times 432 \times 624$. Essa etapa é necessária para capturar de maneira direta as redundâncias estruturais presentes ao longo das quatro dimensões da imagem de *light field*.

A compressão baseada em 4D-DCT segue um procedimento análogo ao utilizado pelo padrão JPEG em duas dimensões: no JPEG, a imagem é dividida em blocos 8×8 e cada bloco é transformado individualmente pela 2D-DCT, conforme exemplificado na Figura 9a. No caso da imagem de *light field*, como o sinal é quadridimensional, a divisão em blocos ocorre em todas as quatro dimensões, resultando em blocos $8 \times 8 \times 8 \times 8$. A Figura 9b apresenta a representação visual desse bloco, o qual captura de forma integrada uma região espacial de 8×8 pixels em cada uma das 8×8 visões angulares.

Figura 9 – Representação visual do (a) Padrão JPEG para imagens comuns com a 2D-DCT e (b) Padrão análogo ao do JPEG para imagens de *light field* com a 4D-DCT



Fonte: Elaborada pela autora


Assim, a 4D-DCT é aplicada diretamente sobre cada bloco 4D, com o objetivo de concentrar a energia do sinal em um conjunto reduzido de coeficientes. A compressão com perdas foi simulada por meio da retenção de diferentes porcentagens de coeficientes transformados. Foram testadas taxas de retenção variando de 100% até 1% dos coeficientes, reduzindo progressivamente a quantidade de informação armazenada. Os coeficientes não retidos foram zerados, simulando a etapa de codificação com perdas.

Após a retenção, cada bloco foi reconstruído pela aplicação da transformada inversa, retornando a *light field* ao domínio espacial-angular. As imagens reconstruídas foram então avaliadas por meio das métricas PSNR e SSIM, permitindo quantificar o impacto da taxa de retenção sobre a fidelidade visual. Esse procedimento estabelece a linha de base para comparação direta com o método baseado em GFT.

3.3 Implementação do Método Baseado na GFT

A GFT foi aplicada às imagens de *light field* após uma reorganização na sua estrutura formando uma matriz de 8×8 sub-imagens, cada uma com dimensões de 32×32 pixels. Esse arranjo, descrito anteriormente na Seção 3.2, é obtido após o redimensionamento inicial das imagens brutas, resultando numa imagem de *light field* de dimensões $8 \times 8 \times 32 \times 32$ que é utilizada em todos os experimentos com a GFT. A Figura 10 ilustra essa organização.

Figura 10 – Estrutura da imagem de *light field* reorganizada em 8×8 sub-imagens de 32×32 pixels.



Fonte: Elaborada pela autora

A compressão baseada em GFT adota uma estratégia de particionamento análoga à utilizada na 4D-DCT. A imagem é segmentada nas mesmas unidades de processamento, ou seja, blocos de dimensão $8 \times 8 \times 8 \times 8$ que agrupam a informação espacial e angular. No entanto, o tratamento desse sinal difere. Enquanto a 4D-DCT opera diretamente sobre as quatro dimensões, na GFT esse volume de dados é reorganizado em um vetor de sinal único associado a um grafo, permitindo explorar a conectividade adaptativa entre os pixels em vez de frequências fixas.


A aplicação da GFT exige a definição de uma estrutura que modele as relações de similaridade. Cada pixel é tratado como um vértice e as arestas representam o grau de conexão entre eles. Para construir o grafo, adotou-se uma abordagem de topologia dinâmica onde a conectividade é adaptada em função dos próprios dados. O algoritmo percorre os pares de pixels dentro da unidade de processamento e cria uma aresta quando a diferença absoluta entre seus valores de intensidade é inferior a um limiar pré-definido ($|valor_1 - valor_2| < limiar$). Essa regra torna o grafo sensível a estruturas locais e tolerante a pequenas variações de iluminação ou textura.

Neste trabalho foi utilizado $limiar=2$ por testes empíricos, pois apresentou o melhor compromisso entre fidelidade de reconstrução. A diagonal principal da matriz de adjacência é mantida zerada para evitar laços. Como cada bloco de processamento corresponde a uma região espacial de 8×8 pixels considerada em todas as 8×8 vistas angulares, gera-se uma representação de 4.096 nós. O resultado é uma matriz de adjacência de dimensão 4.096×4.096 , refletindo com precisão regiões homogêneas e transições locais.

Para exemplificar o impacto dessa escolha, a Figura 11 apresenta uma comparação entre a topologia fixa em grade e a topologia dinâmica aplicada a um bloco sintético de 4×4 pixels com padrão de intensidades intercaladas. Enquanto a topologia em grade estabelece conexões apenas entre vizinhos espaciais independentemente do conteúdo, a topologia dinâmica utiliza o limiar de similaridade para agrupar vértices com valores idênticos, mesmo quando estes não são vizinhos imediatos, ao mesmo tempo em que isola regiões de intensidades contrastantes.

A partir da matriz de adjacência, calcula-se a matriz Laplaciana e realiza-se sua decomposição espectral, obtendo-se os autovalores e autovetores que definem a base da GFT. O vetor de intensidades correspondente aos 4.096 pixels de cada bloco é então transformado para o domínio espectral do grafo. A compressão é realizada de forma *lossy* por meio do descarte de coeficientes espectrais, sendo avaliadas taxas de retenção entre 100% e 1%. Em seguida, o sinal é reconstruído via iGFT e reposicionado na estrutura $8 \times 8 \times 32 \times 32$, resultando na imagem de *light field* comprimida.

Figura 11 – Comparação entre topologias de grafo para um (a) bloco 4×4 com padrão de intensidades intercaladas: (b) topologia *grid* com conectividade restrita a vizinhos imediatos e (c) topologia dinâmica baseada em similaridade de intensidade



Fonte: Elaborada pela autora

3.4 Critérios de Avaliação e Comparação

A comparação entre os métodos de compressão baseados em 4D-DCT e GFT foi realizada a partir de métricas quantitativas de qualidade de imagem, permitindo avaliar a fidelidade da reconstrução após diferentes níveis de compressão. As métricas utilizadas foram o PSNR e o SSIM, ambas amplamente empregadas na análise de imagens.

O PSNR quantifica a relação entre o sinal original e o erro introduzido pela compressão, sendo expresso em decibéis. Valores mais elevados indicam menor distorção e maior preservação dos detalhes da imagem. O SSIM, por sua vez, avalia a similaridade estrutural entre a imagem original e a reconstruída, considerando luminância, contraste e padrões locais; seus valores variam de 0 a 1, e quanto mais próximo de 1, maior a similaridade percebida. Ambas as métricas foram calculadas utilizando funções da biblioteca scikit-image.

Para cada método, os valores de PSNR e SSIM foram obtidos ao longo de diferentes taxas de retenção de coeficientes, variando de 100% até 1%. Isso permitiu analisar o comportamento de cada abordagem sob níveis crescentes de compressão, garantindo uma comparação consistente entre a 4D-DCT e as três metodologias de construção de grafos empregadas na GFT. Os resultados dessas análises servem de base para as discussões apresentadas no Capítulo 4.


4 RESULTADOS E DISCUSSÕES

4.1 Análise de Desempenho da Compressão com a 4D-DCT

Nesta seção, avalia-se a eficácia da 4D-DCT na compactação de energia de imagens de *light field*. Foram selecionadas 9 imagens do banco de dados do JPEG Pleno para os testes;

desta amostra, duas representativas, *Parc_du_Luxembourg* e *Red_White_Building*, foram escolhidas para ilustrar o comportamento do método em cenários com características distintas de textura e geometria. Os resultados completos referentes às demais imagens do conjunto de dados encontram-se detalhados no APÊNDICE A. A Figura 12 apresenta as curvas de PSNR para as duas imagens selecionadas. Observa-se o decaimento esperado da qualidade numérica conforme a quantidade de coeficientes é reduzida: quanto menor a fração de coeficientes retidos, maior a perda de informação e menor o PSNR.

Figura 12 – Curvas de PSNR da 4DC-DCT em função da porcentagem de coeficientes retidos para as imagens *Red_White_Building* e *Parc_du_Luxembourg*




Fonte: Elaborada pela autora

Analisando a Figura 12, nota-se que a imagem *Red_White_Building* apresentou desempenho superior em toda a faixa de compressão. Mesmo com apenas 1% dos coeficientes retidos, essa imagem manteve um PSNR de 39,04 dB, enquanto a *Parc_du_Luxembourg* atingiu 34,12 dB no mesmo nível de retenção. Esse comportamento pode ser atribuído à natureza das cenas: *Red_White_Building* possui estruturas geométricas definidas e áreas mais homogêneas, que são eficientemente representadas pelas funções de base da DCT; já *Parc_du_Luxembourg* apresenta texturas finas e detalhes de alta frequência (como folhagens), cuja energia se espalha por mais coeficientes, dificultando a compactação.

Observa-se, na faixa inicial de compressão, uma queda mais acentuada do PSNR entre 100% e 90% dos coeficientes retidos. Isso indica a transição da representação quase idêntica para uma representação comprimida, onde a eliminação dos primeiros 10% de coeficientes menos significativos já provoca impacto mensurável na métrica numérica. Para avaliar a degradação da estrutura visual, utilizou-se a métrica SSIM, apresentada na Figura 13.

Figura 13 – Curvas de SSIM da 4D-DCT em função da porcentagem de coeficientes retidos para as imagens *Red_White_Building* e *Parc_du_Luxembourg*



Fonte: Elaborada pela autora

Os resultados de SSIM indicam que a 4D-DCT preserva efetivamente a estrutura perceptual das cenas. A imagem *Red_White_Building* manteve SSIM igual a 1,00 até 20% de coeficientes retidos e decaiu gradualmente para 0,97 com apenas 1% dos coeficientes. A *Parc_du_Luxembourg* seguiu padrão semelhante, com SSIM acima de 0,99 até cerca de 10% de retenção e atingindo 0,94 no caso extremo de 1%. Esses valores indicam que, apesar da perda de informações finas (refletida no PSNR), a 4D-DCT preserva a estrutura global das cenas, o que é consistente com seu papel de concentrar a energia do sinal nas componentes de baixa frequência. A fim de corroborar as métricas objetivas, as Figuras 14 e 15 apresentam as imagens reconstruídas com os níveis de retenção de coeficientes de 90%, 50%, 30%, 10%, 5%, 2% e 1%. Os resultados visuais completos para todas as 9 imagens do banco de dados encontram-se disponíveis no APÊNDICE B.

A inspeção visual das reconstruções confirma a alta correlação com as métricas quantitativas (PSNR e SSIM) discutidas anteriormente. Observa-se que a integridade visual das cenas é mantida de forma consistente, mesmo nos cenários de compressão severa onde apenas 1% dos coeficientes foram preservados.

Embora a avaliação visual não permita identificar diferenças evidentes lado a lado, especialmente em áreas de baixa textura ou variação suave de intensidade, é importante notar que essa ausência de distorções perceptíveis não implica necessariamente perda zero. Em vez disso, indica que as perdas introduzidas se concentram majoritariamente em componentes de alta frequência, cuja contribuição para a percepção humana é limitada. Essa característica decorre da forte compactação de energia oferecida pela 4D-DCT, que concentra a maior parte da informação relevante da *light field* nos coeficientes de baixa frequência.

Figura 14 – Imagem de *light field Red_White_Building* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%



Fonte: Elaborada pela autora

Figura 15 – Imagem de *light field Parc_du_Luxembourg* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%



Fonte: Elaborada pela autora

Assim, a remoção dos 99% coeficientes restantes tende a descartar detalhes finos e redundâncias pouco perceptíveis ao Sistema Visual Humano, o que explica os valores de SSIM superiores a 0,94 obtidos na análise quantitativa. Essa convergência entre avaliação visual e métricas objetivas reforça que, para o conjunto de dados utilizado, a maior parcela da estrutura espacial e angular da cena permanece preservada mesmo em regimes de compressão severos.

Em síntese, a 4D-DCT mostrou elevada capacidade de compactação de energia para imagens de *light field*, preservando a estrutura perceptual mesmo em níveis significativos de redução de coeficientes. A eficiência observada é maior em cenas com predominância de estruturas homogêneas e formas geométricas simples, enquanto cenas ricas em texturas requerem maior parcela de coeficientes para manter níveis elevados de PSNR. Esses resultados


estabelecem uma linha de comparação robusta para a análise subsequente da GFT e a comparação direta entre métodos, que serão apresentados nas Seções 4.2 e 4.3.

4.2 Análise de Desempenho da Compressão com a GFT

Nesta seção, analisa-se em profundidade o desempenho da GFT na compressão de imagens de *light field*. Para assegurar comparabilidade direta com os resultados obtidos para a 4D-DCT, foram utilizadas as mesmas duas cenas representativas do conjunto de dados: *Parc_du_Luxembourg* e *Red_White_Building*. A adoção desse par de imagens permite observar o comportamento da transformada sob condições distintas de textura, geometria e padrões de variação espacial. Os resultados completos envolvendo todas as imagens do banco de dados encontram-se organizados no APÊNDICE A.

A Figura 16 apresenta as curvas de PSNR obtidas pela GFT, considerando diferentes porcentagens de coeficientes retidos após a etapa de compressão. De forma semelhante ao observado na abordagem anterior, a diminuição do número de coeficientes preservados implica redução progressiva da qualidade numérica da imagem reconstruída. Entretanto, nota-se que os valores produzidos pela GFT são consistentemente superiores ao longo de toda a faixa analisada, indicando maior capacidade de compactação de energia.

Figura 16 – Curvas de PSNR da GFT em função da porcentagem de coeficientes retidos para as imagens *Red_White_Building* e *Parc_du_Luxembourg*



Fonte: Elaborada pela autora

A partir das curvas da Figura 16, verifica-se que a imagem *Red_White_Building* obteve novamente desempenho superior. Mesmo em um cenário extremo, com apenas 1% dos coeficientes espectrais preservados, o PSNR alcançou 47,75 dB, representando um nível relativamente elevado de fidelidade considerando o grau de compressão aplicado. A imagem


Parc_du_Luxembourg apresenta um comportamento mais sensível à redução de coeficientes, mas ainda assim mantém 38,05 dB na mesma condição.

Essas diferenças podem ser atribuídas às características estruturais das cenas. A *Red_White_Building* apresenta regiões extensas de baixa variação espacial, como paredes, janelas e áreas homogêneas, que favorecem a concentração de energia nos componentes espectrais de baixa frequência do grafo. Por outro lado, *Parc_du_Luxembourg* possui áreas com vegetação, sombras e texturas finas, que exigem maior quantidade de coeficientes para preservar nuances de alta frequência.

A vantagem da GFT torna-se mais evidente ao considerar sua natureza adaptativa. Enquanto a DCT utiliza uma base fixa independente do conteúdo da imagem, a GFT constrói sua base espectral a partir da matriz de adjacência que modela relações de similaridade local entre pixels. Em outras palavras, a estrutura do grafo molda diretamente a forma dos autovetores utilizados para representar o sinal. Isso resulta em maior alinhamento entre as propriedades do dado e os componentes espectrais iniciais, favorecendo a compactação de energia e reduzindo o impacto da eliminação de coeficientes.

A Figura 17 apresenta as curvas de SSIM obtidas para as mesmas condições experimentais, fornecendo uma análise complementar voltada para a preservação estrutural.

Figura 17 – Curvas de SSIM da GFT em função da porcentagem de coeficientes retidos para as imagens *Red_White_Building* e *Parc_du_Luxembourg*



Fonte: Elaborada pela autora


Os resultados de SSIM mostram que praticamente toda a estrutura perceptual das cenas é mantida mesmo sob compressão extrema. A imagem *Red_White_Building* apresenta SSIM igual a 1,00 em praticamente toda a faixa de retenção avaliada, o que indica que a reconstrução permanece estruturalmente indistinguível da imagem original para a maioria dos cenários. A

imagem *Parc_du_Luxembourg* mantém SSIM igual a 1,00 até a faixa de 2% dos coeficientes e apresenta uma redução mínima para 0,99 quando apenas 1% é retido. Tais valores evidenciam que a GFT preserva bordas, formas e transições visuais relevantes, mesmo com descarte massivo de informação.

Para complementar a análise numérica, as Figuras 18 a 21 apresentam as reconstruções obtidas com diferentes porcentagens de coeficientes preservados: 90%, 50%, 30%, 10%, 5%, 2% e 1%.


A opção metodológica adotada nesta etapa difere da utilizada na análise da 4D-DCT. Ao invés de apresentar as sub-imagens, o que prejudicaria a interpretação devido às dimensões reduzidas delas (32×32 pixels), as imagens completas reconstruídas são exibidas. Essa decisão facilita a verificação da continuidade espacial e permite avaliar se a remontagem dos blocos preserva a consistência global da cena, evitando artefatos de borda ou descontinuidades perceptíveis.

Figura 18 – Imagem de *light field Red_White_Building* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%



Fonte: Elaborada pela autora

Figura 19 – Imagens de *light field Red_White_Building* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

A inspeção visual das imagens reforça o comportamento evidenciado pelas métricas quantitativas. Mesmo em configurações de compressão severa, a reconstrução retém a maior parte da estrutura global da cena, sem a introdução evidente de artefatos ou distorções perceptuais. Esse desempenho está diretamente relacionado à construção da matriz de adjacência utilizada pelo método. O limiar de similaridade adotado ($\text{limiar}=2$) estabelece conexões entre pixels com pequenas diferenças de intensidade, promovendo grafos que representam de forma adequada regiões homogêneas. A base espectral resultante concentra os componentes relevantes nos autovetores associados aos menores autovalores, favorecendo sua preservação nas etapas subsequentes da compressão.


O descarte dos coeficientes restantes atua principalmente sobre componentes de alta frequência, tipicamente associados a variações rápidas, ruídos ou detalhes de menor relevância perceptual. Como consequência, a perda de informação introduzida durante o processo afeta apenas aspectos pouco perceptíveis do sinal, resultando em reconstruções cujas diferenças em relação às imagens originais são, na prática, de difícil detecção.

Figura 20 – Imagem de *light field* *Parc_du_Luxembourg* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%



Fonte: Elaborada pela autora

Figura 21 – Imagens de *light field* *Parc_du_Luxembourg* reconstruídas com a GFT com os valores de: (a) 10%, (b) 5%, (c) 2% e (d) 1%



Fonte: Elaborada pela autora

De modo geral, os resultados obtidos demonstram que a GFT apresenta desempenho superior à abordagem baseada na 4D-DCT em termos de compactação de energia e preservação estrutural. Além disso, a adaptabilidade da transformada à geometria do sinal permite alcançar níveis de compressão nos quais transformadas tradicionais tendem a apresentar degradação perceptível. A comparação quantitativa consolidada entre as duas transformadas será apresentada na seção seguinte.


4.3 Análise Comparativa

Nesta seção, consolidam-se os dados obtidos nos experimentos para comparar o desempenho das transformadas 4D-DCT e GFT. Para evitar a dispersão da análise, o texto a seguir foca nas médias aritméticas e no comportamento global dos algoritmos. As informações detalhadas, separadas por imagem, estão disponíveis nas Tabela A.1 a Tabela A.18 no APÊNDICE A.

4.3.1 Desempenho Médio em Qualidade (PSNR e SSIM)

Para fins de comparação entre os métodos aplicados foi realizada a média das métricas quantitativas da 4D-DCT e da GFT de todas as 9 imagens utilizadas neste trabalho. As Figuras 22 e 23 apresentam as curvas de PSNR e SSIM médio em função dos coeficientes retidos.

Figura 22 – Comparativo do PSNR médio da 4D-DCT e da GFT em função da porcentagem de coeficientes retidos



Fonte: Elaborada pela autora


Os valores de PSNR mostram que a 4D-DCT mantém desempenho superior nas taxas mais altas de retenção. Em 90%, por exemplo, a 4D-DCT atinge 85,24 dB, enquanto a GFT registra 70,63 dB. A mesma tendência aparece em 80% e 60%, com diferenças sistemáticas em

favor da DCT. Isso confirma a capacidade da transformada em concentrar energia quando há ampla disponibilidade de coeficientes.

À medida que a taxa de retenção é reduzida, a diferença entre os métodos diminui. Em 30%, os valores são mais próximos: 57,40 dB para a 4D-DCT e 56,53 dB para a GFT. O ponto de cruzamento ocorre em 20%, quando a GFT obtém 54,42 dB e supera ligeiramente os 54,30 dB da 4D-DCT. A partir desse ponto, a GFT mantém uma pequena vantagem. Em 10%, o PSNR passa para 50,59 dB contra 50,32 dB e, na taxa mais extrema de 1%, a diferença se amplia para 43,12 dB contra 40,48 dB. Esses resultados indicam que a base adaptativa do grafo preserva melhor o conteúdo essencial quando poucos coeficientes são mantidos.

É importante destacar que esses resultados não indicam perda de eficácia da 4D-DCT em compressões severas. Mesmo com apenas 1% dos coeficientes, valores próximos de 40 dB ainda representam alta qualidade. A vantagem obtida pela GFT decorre principalmente de sua topologia dinâmica, que se adapta melhor ao conteúdo local da imagem de *light field*, permitindo preservar um pouco mais da energia essencial nesses cenários de retenção mínima.

Figura 23 – Comparativo do SSIM Médio da 4D-DCT e da GFT em função da porcentagem de coeficientes retidos



Fonte: Elaborada pela autora

O comportamento do SSIM é mais estável ao longo das taxas. Ambos os métodos mantêm valores arredondados de 1,00 até 10% de retenção, o que indica preservação adequada das estruturas perceptuais. As diferenças surgem apenas nas compressões mais agressivas. Em 5%, a 4D-DCT cai para 0,99 enquanto a GFT permanece em 1,00. Em 1%, a 4D-DCT atinge 0,97 e a GFT mantém 0,99. Isso sugere que, mesmo com perda de energia espectral em alta compressão, a topologia do grafo sustenta melhor a coerência estrutural da imagem.

Em conjunto, os resultados mostram três regiões claras. A 4D-DCT é superior entre

100% e 40%, os métodos se igualam entre 30% e 20% e a GFT se destaca abaixo de 10%, apresentando melhor desempenho tanto no PSNR quanto no SSIM em compressões severas.

4.3.2 Análise de Tempo de Processamento

O custo computacional foi avaliado a partir do tempo médio necessário para processar uma imagem completa. A Tabela 1 apresenta os valores médios, os desvios padrão e o fator de aumento (*speedup*) entre os métodos.

Tabela 1 – Comparativo de eficiência computacional (média global do banco de dados)

Método de Compressão	Tempo Médio (s)	Desvio Padrão (s)	Fator de Aumento (<i>SpeedUp</i>)
4D-DCT	17,38	0,32	1,0x
GFT	442,12	47,34	25,44x

Fonte: Elaborada pela autora

A 4D-DCT registrou tempo médio de 17,38 s, com desvio padrão de 0,32 s, indicando execução consistente entre as imagens. Como utiliza bases fixas, o tempo de processamento permanece praticamente constante e depende apenas do tamanho dos dados.

A GFT apresentou tempo médio de 442,12 s, com desvio padrão de 47,34 s. A comparação direta dos tempos resulta em um fator de aumento de 25,44 vezes em favor da 4D-DCT. O custo maior da GFT está associado à construção da matriz de adjacência e à decomposição espectral realizada em cada bloco.

Os resultados mostram que a 4D-DCT é substancialmente mais eficiente. É importante notar que o tempo da GFT foi medido em imagens com resolução espacial reduzida (estrutura $8 \times 8 \times 32 \times 32$), totalizando um volume de dados significativamente menor que o processado pela 4D-DCT. Esta última operou sobre as dimensões de 3456×4992 pixels (estrutura $8 \times 8 \times 432 \times 624$). Essa diferença de escala indica que o custo computacional intrínseco da GFT é elevado, o que representa um desafio para sua aplicação em imagens de alta resolução sem estratégias de otimização, apesar dos ganhos de qualidade observados em compressões severas.

4.3.3 Comparação Global entre os Métodos

A comparação integrada dos resultados permite identificar claramente os cenários de melhor aplicabilidade para cada método. A análise conjunta do PSNR, SSIM e do tempo de processamento mostra que os dois métodos apresentam comportamentos distintos, embora ambos garantam níveis elevados de reconstrução.

Em termos de fidelidade de sinal, medida pelo PSNR médio, a 4D-DCT apresenta desempenho superior na maior parte da faixa analisada, especialmente entre 100% e 30% de coeficientes retidos. A GFT destaca-se nas compressões mais agressivas (abaixo de 10%), onde a adaptabilidade da sua base permite superar os índices da transformada clássica. Vale notar que, mesmo nesse extremo, a 4D-DCT sustenta valores de qualidade muito satisfatórios. Portanto, a vantagem da GFT reside em oferecer um refinamento adicional na preservação do sinal quando a largura de banda é severamente restrita.

A preservação estrutural, avaliada pelo SSIM médio, permanece elevada em ambos os métodos para a maior parte das taxas de retenção. No entanto, nas compressões extremas, a GFT mantém valores próximos de 1,00, enquanto a 4D-DCT apresenta uma leve queda, chegando a 0,97 na menor taxa testada. Esse comportamento indica maior estabilidade estrutural da GFT quando há pouca informação disponível.

O fator que mais diferencia os métodos, entretanto, é o custo computacional. A 4D-DCT apresentou tempo médio de 17,38 s por imagem, enquanto a GFT alcançou 442,12 s em média, representando um aumento de aproximadamente 25 vezes no tempo de processamento. Esse resultado reforça que, apesar do ganho incremental de qualidade da GFT em compressões reduzidas, seu custo operacional é significativamente superior, sobretudo devido às etapas de construção da matriz de adjacência e à decomposição espectral aplicadas em cada bloco.

De forma geral, os resultados indicam que a 4D-DCT oferece a melhor relação entre qualidade e eficiência para aplicações práticas, entregando reconstruções de alto nível com baixo tempo de execução. A GFT, por outro lado, posiciona-se como uma solução para cenários de alta compressão onde se busca maximizar cada decibel de qualidade e preservar a estrutura visual, justificando o maior custo computacional pela adaptação superior à topologia da imagem.

5 CONCLUSÃO

Este trabalho teve como objetivo realizar uma análise comparativa entre a 4D-DCT e a GFT aplicadas à compressão de imagens de *light field*, considerando simultaneamente a qualidade de reconstrução, a eficiência de compactação de energia e a complexidade computacional. A partir dos resultados obtidos, pode-se afirmar que os objetivos foram plenamente alcançados e que o problema de pesquisa proposto foi adequadamente esclarecido.

Os objetivos específicos foram atendidos a partir do estudo dos fundamentos teóricos das imagens de *light field*, da 4D-DCT e da GFT, bem como do desenvolvimento dos algoritmos de compressão correspondentes. As simulações realizadas, considerando diferentes taxas de

retenção de coeficientes, possibilitaram caracterizar o comportamento dos métodos sob distintos níveis de compressão. A avaliação objetiva por meio das métricas PSNR e SSIM evidenciou que a 4D-DCT apresenta desempenho superior em cenários de alta fidelidade, mantendo valores elevados de qualidade quando há maior disponibilidade de coeficientes. Por sua vez, a GFT demonstrou desempenho ligeiramente superior em cenários de compressão agressiva, especialmente abaixo de 10% de coeficientes retidos, preservando melhor a estrutura visual da imagem devido à adaptação da topologia do grafo aos dados.

É importante ressaltar que, mesmo nas taxas mais extremas de compressão, a 4D-DCT apresentou valores de PSNR elevados, da ordem de 40 dB com apenas 1% de coeficientes retidos, indicando que sua eficácia não é comprometida de forma significativa. A vantagem observada da GFT nesses cenários reflete principalmente sua capacidade de adaptação à geometria do sinal, resultando em ganhos marginais de qualidade em situações específicas, e não uma limitação da transformada clássica.

A análise da complexidade computacional revelou uma diferença expressiva entre os métodos. A 4D-DCT apresentou tempo médio de processamento de aproximadamente 17 segundos, com baixa variabilidade entre as imagens, enquanto a GFT demandou, em média, mais de 400 segundos por imagem, configurando um fator de aumento superior a 25 vezes. Esse elevado custo computacional está diretamente associado às etapas de construção da matriz de adjacência e à decomposição espectral da matriz Laplaciana, o que impôs limitações práticas à aplicação da GFT e exigiu o redimensionamento das imagens de teste durante a pesquisa.

Como contribuição para a comunidade científica, este trabalho estabelece uma comparação sistemática e equilibrada entre duas abordagens de compressão com naturezas distintas, delimitando de forma clara seus cenários de aplicação. Conclui-se que a 4D-DCT permanece como a alternativa mais adequada para aplicações gerais e sensíveis a tempo de processamento, oferecendo elevado desempenho e eficiência computacional. A GFT, por sua vez, configura-se como uma abordagem especializada, indicada para contextos de alta compressão nos quais a preservação da estrutura visual é prioritária, mesmo à custa de maior complexidade computacional.

Como perspectivas para trabalhos futuros, sugere-se a investigação de estratégias para redução do custo computacional da GFT, incluindo métodos mais eficientes de construção de grafos dinâmicos, técnicas de aproximação espectral e implementações paralelas em GPU. Além disso, a exploração de abordagens híbridas que combinem a eficiência da 4D-DCT com a adaptabilidade da GFT pode representar um caminho promissor para equilibrar qualidade e desempenho em sistemas de compressão de imagens de *light field*.

REFERÊNCIAS

AHMED, Nasir; HEIN, D. On a Real-Time Walsh-Hadamard/Cosine Transform Image Processor. **IEEE Transactions on Electromagnetic Compatibility**, [S. l.], v. EMC-20, n. 3, p. 453–457, 1978. Disponível em: <https://ieeexplore.ieee.org/document/4091201>. Acesso em: 08 set. 2025.

AHMED, Nasir; MILNE, Paul J.; HARRIS, Stanley G. Electrocardiographic Data Compression Via Orthogonal Transforms. **IEEE Transactions on Biomedical Engineering**, [S. l.], v. BME-22, n. 6, p. 484–487, 1975. Disponível em: <https://ieeexplore.ieee.org/document/4120976>. Acesso em: 10 set. 2025.

AHMED, Nasir; NATARAJAN, T. On Interframe Transform Coding. **IEEE Transactions on Communications**, [S. l.], v. 25, n. 11, p. 1323–1329, 1977. Disponível em: <https://ieeexplore.ieee.org/document/1093769>. Acesso em: 10 set. 2025.

ALVES, Gustavo *et al.* A Study on the 4D Sparsity of JPEG Pleno Light Fields Using the Discrete Cosine Transform. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (ICIP), 25., 2018, Athens. **Proceedings** [...]. Athens: IEEE, 2018. p. 1148–1152. Disponível em: <https://ieeexplore.ieee.org/document/8451583>. Acesso em: 10 set. 2025.

CARVALHO, Murilo B. *et al.* A 4D DCT-Based lenslet light field codec. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (ICIP), 25., 2018, Athens. **Proceedings** [...]. Athens: IEEE, 2018. p. 435–439. Disponível em: <https://ieeexplore.ieee.org/document/8451583>. Acesso em: 10 set. 2025.

DLABAJA, Drahomir. 4D-DCT Based Light Field Image Compression. In: EXCEL@FIT, 2019, Brno. **Proceedings** [...]. Brno: Brno University of Technology, 2019. Disponível em: <https://excel.fit.vutbr.cz/submissions/2019/021/21.pdf>. Acesso em: 21 out. 2025.

EBRAHIMI, Touradj *et al.* JPEG Pleno: Toward an Efficient Representation of Visual Reality. **IEEE Multimedia**, [S. l.], v. 23, n. 4, p. 14–20, out. 2016. Disponível em: <https://ieeexplore.ieee.org/document/7742781>. Acesso em: 10 set. 2025.

FEOFILOFF, P.; KOHAYAKAWA, Y.; WAKABAYASHI, Y. **Uma Introdução Sucinta à Teoria dos Grafos**. São Paulo: IME-USP, 2011.

FERREIRA, Felipe Alberto Barbosa Simão. **Técnicas de marca d'água no domínio da transformada para imagens plenópticas**. 2020. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Pernambuco, Recife, 2020. Disponível em: <https://repositorio.ufpe.br/handle/123456789/39370>. Acesso em: 10 set. 2025.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

IHRKE, Ivo; RESTREPO, John; MIGNARD-DEBISE, Lois. Principles of Light Field Imaging: Briefly revisiting 25 years of research. **IEEE Signal Processing Magazine**, [S. l.], v. 33, n. 5, p. 59–69, set. 2016. Disponível em: <https://ieeexplore.ieee.org/document/7559962>. Acesso em: 10 set. 2025.

LAFRUIT, G. *et al.* **Technical report of the joint ad hoc group for digital representations of light/sound fields for immersive media applications**. Geneva: ISO/IEC JTC1/SC29/WG1, 2016.

LIMA, Juliano Bandeira *et al.* **Processamento de Sinais sobre Grafos: Fundamentos e Aplicações**. São Carlos: SBMAC, 2021. v. 92

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

ORTEGA, Antonio *et al.* Graph Signal Processing: Overview, Challenges, and Applications. **Proceedings of the IEEE**, [S. l.], v. 106, n. 5, p. 808–828, maio 2018. Disponível em: <https://ieeexplore.ieee.org/document/8347162>. Acesso em: 10 set. 2025.

ŘEŘÁBEK, Martin; EBRAHIMI, Touradj. New Light Field Image Dataset. *In*: INTERNATIONAL WORKSHOP ON QUALITY OF MULTIMEDIA EXPERIENCE (QOMEX), 8., 2016, Lisbon. **Proceedings [...]**. Lisbon: IEEE, 2016. Disponível em: <https://infoscience.epfl.ch/server/api/core/bitstreams/000cd08c-2deb-477c-8cdb-al6211e02b6a/content>. Acesso em: 11 set. 2025.

SANDRYHAILA, Aliaksei; MOURA, José M. F. Discrete signal processing on graphs. **IEEE Transactions on Signal Processing**, [S. l.], v. 61, n. 7, p. 1644–1656, 2013. Disponível em: <https://ieeexplore.ieee.org/document/6409473>. Acesso em: 10 set. 2025.

SHUMAN, David I. *et al.* The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains. **IEEE Signal Processing Magazine**, [S. l.], v. 30, n. 3, p. 83–98, 2013. Disponível em: <https://ieeexplore.ieee.org/document/6494675>. Acesso em: 10 set. 2025.

WANG, Yao; MUKHERJEE, Debargha. The Discrete Cosine Transform and Its Impact on Visual Compression: Fifty Years From Its Invention [Perspectives]. **IEEE Signal Processing Magazine**, [S. l.], v. 40, n. 6, p. 14–17, set. 2023. Disponível em: <https://ieeexplore.ieee.org/document/10243458>. Acesso em: 10 set. 2025.

WILBURN, Bennett *et al.* High performance imaging using large camera arrays. **ACM Transactions on Graphics**, [S. l.], v. 24, n. 3, p. 765–776, jul. 2005. Disponível em: <https://dl.acm.org/doi/10.1145/1073204.1073259>. Acesso em: 10 set. 2025.

WU, Gaochang *et al.* Light Field Image Processing: An Overview. **IEEE Journal of Selected Topics in Signal Processing**, [S. l.], v. 11, n. 7, p. 926–954, out. 2017. Disponível em: <https://ieeexplore.ieee.org/document/8022901>. Acesso em: 10 set. 2025.

YU, Haotian *et al.* VLSI design for adjustable compression rate in lossless/lossy compression of EEG signal. **Microelectronics Journal**, [S. l.], v. 148, p. 106193, abr. 2024. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0026269224001058>. Acesso em: 10 set. 2025.

APÊNDICE A – Tabelas de Resultados Quantitativos

Tabela A.1 – Resultados detalhados da compressão da imagem *Broken_Mirror* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	315,09	1,00	14,96
90	85,59	1,00	15,65
80	76,50	1,00	19,75
70	71,05	1,00	15,88
60	67,06	1,00	16,25
50	63,79	1,00	16,87
40	60,91	1,00	17,23
30	58,15	1,00	17,46
20	55,20	1,00	18,57
10	51,35	1,00	18,75
5	48,14	0,99	18,74
2	44,37	0,98	18,96
1	41,78	0,97	19,74

Fonte: Elaborada pela autora

Tabela A.2 – Resultados detalhados da compressão da imagem *Broken_Mirror* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	297,32	1,00	486,40
90	71,57	1,00	470,00
80	70,07	1,00	473,40
70	65,79	1,00	484,60
60	65,65	1,00	475,80
50	62,87	1,00	473,90
40	59,05	1,00	475,10
30	56,41	1,00	475,00
20	54,10	1,00	475,50
10	47,15	0,99	474,30
5	46,19	0,99	473,70
2	44,51	0,99	473,50
1	43,75	0,99	474,10

Fonte: Elaborada pela autora

Tabela A.3 – Resultados detalhados da compressão da imagem *Color_Chart_1* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	309,16	1,00	14,83
90	85,85	1,00	15,03
80	76,75	1,00	15,68
70	71,31	1,00	16,08
60	67,32	1,00	16,71
50	64,07	1,00	17,18
40	61,20	1,00	17,62

30	58,52	1,00	18,24
20	55,75	1,00	19,06
10	52,49	1,00	19,24
5	50,07	0,99	19,69
2	46,93	0,99	19,76
1	43,68	0,98	20,18

Fonte: Elaborada pela autora

Tabela A.4 – Resultados detalhados da compressão da imagem *Color_Chart_1* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	295,77	1,00	398,90
90	64,78	1,00	399,10
80	64,63	1,00	399,10
70	63,69	1,00	399,10
60	63,05	1,00	416,50
50	57,87	1,00	410,20
40	57,08	1,00	397,00
30	53,50	1,00	398,80
20	52,04	1,00	400,10
10	49,35	1,00	400,40
5	47,35	1,00	404,00
2	44,82	1,00	400,40
1	41,75	1,00	400,60

Fonte: Elaborada pela autora

Tabela A.5 – Resultados detalhados da compressão da imagem *Desktop* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	304,41	1,00	14,82
90	85,47	1,00	14,65
80	76,35	1,00	15,14
70	70,85	1,00	15,80
60	66,77	1,00	16,37
50	63,36	1,00	16,69
40	60,27	1,00	17,29
30	57,23	1,00	17,93
20	53,93	1,00	18,21
10	49,67	1,00	18,64
5	46,31	0,99	18,78
2	42,45	0,99	19,20
1	39,59	0,98	19,90

Fonte: Elaborada pela autora

Tabela A.6 - Resultados detalhados da compressão da imagem *Desktop* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	294,03	1,00	539,40
90	68,64	1,00	511,60
80	67,83	1,00	514,00
70	67,23	1,00	514,50
60	66,39	1,00	512,20
50	62,87	1,00	524,80
40	60,34	1,00	498,10
30	58,70	1,00	523,00
20	57,82	1,00	530,60
10	56,19	1,00	522,90
5	52,65	1,00	516,70
2	51,69	1,00	522,80
1	46,62	1,00	514,60

Fonte: Elaborada pela autora

Tabela A.7 – Resultados detalhados da compressão da imagem *Friends_I* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	306,90	1,00	14,26
90	85,88	1,00	14,60
80	76,78	1,00	15,13
70	71,31	1,00	15,45
60	67,28	1,00	16,11
50	63,95	1,00	16,70
40	60,97	1,00	17,18
30	58,06	1,00	17,59
20	54,87	1,00	18,12
10	50,59	1,00	18,81
5	47,04	0,99	18,93
2	42,89	0,99	19,00
1	39,84	0,98	20,11

Fonte: Elaborada pela autora

Tabela A.8 – Resultados detalhados da compressão da imagem *Friends_I* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	289,83	1,00	404,80
90	69,97	1,00	391,40
80	67,49	1,00	391,30
70	60,91	1,00	394,00
60	59,28	1,00	396,10
50	58,51	1,00	402,60
40	57,01	1,00	396,90
30	54,90	1,00	397,10
20	52,32	1,00	398,60

10	48,87	1,00	398,00
5	46,35	1,00	398,30
2	44,82	1,00	397,30
1	42,62	1,00	397,40

Fonte: Elaborada pela autora

Tabela A.9 – Resultados detalhados da compressão da imagem *Game_Board* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	314,77	1,00	14,96
90	85,66	1,00	14,82
80	76,56	1,00	15,37
70	71,11	1,00	16,42
60	67,12	1,00	16,34
50	63,85	1,00	16,74
40	60,95	1,00	17,39
30	58,19	1,00	17,93
20	55,27	1,00	18,36
10	51,60	1,00	18,85
5	48,57	0,99	20,89
2	44,80	0,98	19,69
1	42,04	0,97	19,24

Fonte: Elaborada pela autora

Tabela A.10 – Resultados detalhados da compressão da imagem *Game_Board* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	297,36	1,00	507,70
90	62,49	1,00	507,20
80	62,13	1,00	508,70
70	61,10	1,00	507,80
60	60,92	1,00	509,80
50	60,12	1,00	508,70
40	59,47	1,00	518,10
30	58,23	1,00	510,80
20	56,82	1,00	508,90
10	53,60	1,00	510,80
5	52,29	1,00	511,50
2	48,76	1,00	509,20
1	45,89	0,99	510,60

Fonte: Elaborada pela autora

Tabela A.11 – Resultados detalhados da compressão da imagem *Houses_&_Lake* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	310,17	1,00	15,48
90	86,30	1,00	14,98

80	77,22	1,00	15,55
70	71,79	1,00	15,84
60	67,84	1,00	16,48
50	64,62	1,00	17,77
40	61,82	1,00	19,10
30	59,21	1,00	18,26
20	56,53	1,00	19,64
10	53,29	1,00	19,03
5	50,80	0,99	19,28
2	47,89	0,99	19,75
1	45,59	0,98	19,39

Fonte: Elaborada pela autora

Tabela A.12 – Resultados detalhados da compressão da imagem *Houses_&_Lake* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	288,48	1,00	448,30
90	66,14	1,00	431,20
80	64,73	1,00	432,80
70	63,77	1,00	431,60
60	62,49	1,00	432,50
50	58,66	1,00	433,00
40	56,04	1,00	433,20
30	53,78	1,00	434,40
20	51,05	1,00	435,10
10	45,28	0,99	438,00
5	42,61	0,99	436,90
2	39,59	0,98	435,50
1	37,27	0,97	452,20

Fonte: Elaborada pela autora

Tabela A.13 – Resultados detalhados da compressão da imagem *Parc_du_Luxembourg* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	308,92	1,00	14,07
90	83,15	1,00	14,42
80	73,98	1,00	14,95
70	68,40	1,00	15,49
60	64,22	1,00	15,96
50	60,67	1,00	16,34
40	57,38	1,00	17,05
30	54,07	1,00	17,65
20	50,38	1,00	18,25
10	45,50	0,99	18,80
5	41,55	0,99	18,69
2	37,07	0,97	19,26
1	34,12	0,94	19,18

Fonte: Elaborada pela autora

Tabela A.14 – Resultados detalhados da compressão da imagem *Parc du Luxembourg* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	292,77	1,00	403,00
90	77,99	1,00	403,30
80	73,99	1,00	404,30
70	66,22	1,00	406,50
60	62,77	1,00	406,50
50	59,94	1,00	406,20
40	57,20	1,00	404,30
30	55,97	1,00	407,10
20	52,73	1,00	407,00
10	48,03	1,00	403,50
5	44,67	1,00	407,10
2	39,66	1,00	406,30
1	38,05	0,99	407,00

Fonte: Elaborada pela autora

Tabela A.15 – Resultados detalhados da compressão da imagem *Poppies* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	310,75	1,00	14,45
90	84,22	1,00	14,51
80	75,07	1,00	15,02
70	69,56	1,00	15,78
60	65,47	1,00	16,44
50	62,06	1,00	16,59
40	58,97	1,00	17,10
30	55,96	1,00	17,46
20	52,70	1,00	18,67
10	48,55	1,00	18,54
5	45,21	0,99	19,14
2	41,31	0,98	18,94
1	38,65	0,97	18,87

Fonte: Elaborada pela autora

Tabela A.16 – Resultados detalhados da compressão da imagem *Poppies* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	291,35	1,00	428,30
90	74,28	1,00	415,00
80	68,50	1,00	413,50
70	64,32	1,00	416,00
60	63,36	1,00	419,50
50	61,76	1,00	416,50
40	59,36	1,00	414,20
30	57,83	1,00	417,10
20	55,87	1,00	413,60

10	51,64	1,00	414,80
5	48,69	1,00	416,50
2	46,90	1,00	417,70
1	44,36	1,00	416,60

Fonte: Elaborada pela autora

Tabela A.17 – Resultados detalhados da compressão da imagem *Red_White_Building* via 4D-DCT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	309,12	1,00	15,31
90	85,03	1,00	19,36
80	75,93	1,00	16,82
70	70,45	1,00	15,68
60	66,43	1,00	16,10
50	63,11	1,00	16,61
40	60,13	1,00	17,29
30	57,22	1,00	18,30
20	54,05	1,00	18,38
10	49,83	1,00	19,24
5	46,32	0,99	19,13
2	42,11	0,98	19,20
1	39,04	0,97	19,50

Fonte: Elaborada pela autora


Tabela A.18 – Resultados detalhados da compressão da imagem *Red_White_Building* via GFT

Coefficientes Retidos	PSNR	SSIM	Tempo (s)
100	300,53	1,00	432,40
90	79,84	1,00	413,90
80	77,90	1,00	419,30
70	74,27	1,00	416,50
60	66,35	1,00	413,90
50	62,99	1,00	412,80
40	60,57	1,00	412,50
30	59,43	1,00	413,70
20	56,99	1,00	414,30
10	55,18	1,00	415,40
5	54,09	1,00	413,20
2	49,81	1,00	418,70
1	47,75	1,00	417,10

Fonte: Elaborada pela autora


APÊNDICE B – Resultados Visuais Complementares

Figura B.1 – Imagem de *light field Broken_Mirror* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%




Fonte: Elaborada pela autora

Figura B.2 – Imagem de *light field Color_Chart_1* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%



Fonte: Elaborada pela autora

Figura B.3 – Imagem de *light field Desktop* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%




Fonte: Elaborada pela autora

Figura B.4 – Imagem de *light field Friends_1* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%




Fonte: Elaborada pela autora

Figura B.5 – Imagem de *light field Game_Board* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%




Fonte: Elaborada pela autora

Figura B.6 – Imagem de *light field Houses_&_Lake* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%




Fonte: Elaborada pela autora

Figura B.7 – Imagem de *light field Poppies* (a) original comparada com as imagens reconstruídas com a 4D-DCT com os valores de coeficientes retidos de: (b) 90%, (c) 50%, (d) 30%, (e) 10%, (f) 5%, (g) 2% e (h) 1%




Fonte: Elaborada pela autora

Figura B.8 – Imagem de *light field Broken_Mirror* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%




Fonte: Elaborada pela autora

Figura B.9 – Imagens de *light field Broken_Mirror* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

Figura B.10 – Imagem de *light field Color_Chart_1* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%




Fonte: Elaborada pela autora

Figura B.11 – Imagens de *light field Color_Chart_1* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

Figura B.12 – Imagem de *light field Desktop* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%




Fonte: Elaborada pela autora

Figura B.13 – Imagens de *light field Desktop* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

Figura B.14 – Imagem de *light field Friends_1* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%




Fonte: Elaborada pela autora

Figura B.15 – Imagens de *light field Friends_I* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

Figura B.16 – Imagem de *light field Game_Board* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%




Fonte: Elaborada pela autora

Figura B.17 – Imagens de *light field Game_Board* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

Figura B.18 – Imagem de *light field Houses_&_Lake* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%




Fonte: Elaborada pela autora

Figura B.19 – Imagens de *light field Houses_&_Lake* reconstruídas com a GFT com os valores de coeficientes retidos de: (a) 10%, (b) 5%, (c) 2% e (d) 1%




Fonte: Elaborada pela autora

Figura B.20 – Imagem de *light field Poppies* (a) original comparada com as imagens reconstruídas com a GFT com os valores de coeficientes retidos de: (b) 90%, (c) 50% e (d) 30%



Fonte: Elaborada pela autora

Figura B.21 – Imagens de *light field Poppies* reconstruídas com a GFT com os valores de coeficientes retidos de:
(a) 10%, (b) 5%, (c) 2% e (d) 1%



Fonte: Elaborada pela autora