



**INSTITUTO
FEDERAL**

Goiano

Campus
Rio Verde

CIÊNCIA DA COMPUTAÇÃO

**FILTRAGEM DE RUÍDOS EM IMAGENS MÉDICAS E DE
SENSORIAMENTO REMOTO POR AUTÔMATOS
CELULARES**

YAGO BRAZ FONSECA

Rio Verde - GO
2021

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
GOIANO - CAMPUS RIO VERDE
CIÊNCIA DA COMPUTAÇÃO

**FILTRAGEM DE RUÍDOS EM IMAGENS MÉDICAS E DE
SENSORIAMENTO REMOTO POR AUTÔMATOS CELULARES**

YAGO BRAZ FONSECA

Trabalho de Curso apresentado ao Instituto Federal Goiano – Campus Rio Verde, como requisito parcial para a obtenção do Grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Heverton Barros de Macêdo

Rio Verde - GO
2021

YAGO BRAZ FONSECA

**FILTRAGEM DE RUÍDOS EM IMAGENS MÉDICAS E DE
SENSORIAMENTO REMOTO POR AUTÔMATOS CELULARES**

Trabalho de Curso DEFENDIDO e APROVADO em 11 de agosto de 2021, pela Banca Examinadora constituída pelos membros:



Prof. Dr. Douglas Cedrim Oliveira
Instituto Federal de Educação, Ciência e
Tecnologia Goiano,
Campus Rio Verde



Prof. Dr. André da Cunha Ribeiro
Instituto Federal de Educação, Ciência e
Tecnologia Goiano,
Campus Rio Verde



Prof. Dr. Heverton Barros de Macêdo
Instituto Federal de Educação, Ciência e Tecnologia Goiano,
Campus Rio Verde

Rio Verde - GO
2021



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Ata nº 119/2021 - GGRAD-RV/DE-RV/CMPRV/IFGOIANO

ATA DE DEFESA DE TRABALHO DE CURSO

Ao(s) 11 dia(s) do mês de agosto de 2021, às 19 horas e 34 minutos, reuniu-se a banca examinadora composta pelos docentes: Heverton Barros de Macêdo (orientador), André da Cunha Ribeiro (membro), Douglas Cedrim Oliveira (membro), para examinar o Trabalho de Curso intitulado “FILTRAGEM DE RUÍDOS EM IMAGENS MÉDICAS E DE SENSORIAMENTO REMOTO POR AUTÔMATOS CELULARES” do(a) estudante Yago Braz Fonseca, Matrícula nº 20171022011910048 do Curso de Bacharelado em Ciência da Computação do IF Goiano – Campus Rio Verde/GO. A palavra foi concedida ao(a) estudante para a apresentação oral do TC, houve arguição do(a) candidato pelos membros da banca examinadora. Após tal etapa, a banca examinadora decidiu pela APROVAÇÃO do(a) estudante. Ao final da sessão pública de defesa foi lavrada a presente ata que segue assinada pelos membros da Banca Examinadora.

(Assinado Eletronicamente)

Heverton Barros de Macêdo

Orientador(a)

(Assinado Eletronicamente)

André da Cunha Ribeiro

Membro

(Assinado Eletronicamente)

Douglas Cedrim Oliveira

Membro

Observação:

() O(a) estudante não compareceu à defesa do TC.

Documento assinado eletronicamente por:

- Douglas Cedrim Oliveira, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/08/2021 22:34:26.
- Andre da Cunha Ribeiro, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/08/2021 22:34:16.
- Heverton Barros de Macedo, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/08/2021 22:32:52.

Este documento foi emitido pelo SUAP em 11/08/2021. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 298749

Código de Autenticação: 23dd5d9b2f



INSTITUTO FEDERAL GOIANO
Campus Rio Verde
Rodovia Sul Goiana, Km 01, Zona Rural, None, RIO VERDE / GO, CEP 75901-970
(64) 3620-5600

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano, a disponibilizar gratuitamente o documento no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| <input type="checkbox"/> Tese | <input type="checkbox"/> Artigo Científico |
| <input type="checkbox"/> Dissertação | <input type="checkbox"/> Capítulo de Livro |
| <input type="checkbox"/> Monografia – Especialização | <input type="checkbox"/> Livro |
| <input checked="" type="checkbox"/> TCC - Graduação | <input type="checkbox"/> Trabalho Apresentado em Evento |
| <input type="checkbox"/> Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Yago Braz Fonseca

Matrícula: 2017102201910048

Título do Trabalho: Filtragem de Ruídos em Imagens Médicas e de Sensoriamento Remoto por Autômatos Celulares

Restrições de Acesso ao Documento

Documento confidencial: Não Sim, justifique: _____

Informe a data que poderá ser disponibilizado no RIIF Goiano: 18/08/2021

O documento está sujeito a registro de patente? Sim Não

O documento pode vir a ser publicado como livro? Sim Não

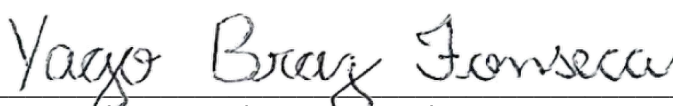
DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Rio Verde
Local

, 18/08/2021.
Data



Assinatura do Autor e/ou Detentor dos Direitos Autorais

Ciente e de acordo:



Assinatura do(a) orientador(a)

Sistema desenvolvido pelo ICMC/USP
Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas - Instituto Federal Goiano

F676f Fonseca, Yago Braz
Filtragem de Ruídos em Imagens Médicas e de
Sensoriamento Remoto por Autômatos Celulares / Yago
Braz Fonseca; orientador Heverton Barros de Macêdo. -
- Rio Verde, 2021.
79 p.

TCC (Graduação em Bacharelado em Ciência da
Computação) -- Instituto Federal Goiano, Campus Rio
Verde, 2021.

1. Autômato Celular. 2. Processamento de Imagens.
3. Filtragem de Ruído. I. Barros de Macêdo, Heverton,
orient. II. Título.

RESUMO

FONSECA, Yago Braz. **Filtragem de Ruídos em Imagens Médicas e de Sensoriamento Remoto por Autômatos Celulares**. 2021. 82 f. Monografia (Curso de Bacharelado em Ciência da Computação). Instituto Federal de Educação, Ciência e Tecnologia Goiano - Campus Rio Verde. Rio Verde - GO, 2021.

Estudos demonstram que autômatos celulares podem ser implementados para realizar o processamento de imagens para os fins de filtragem de ruído. Neste trabalho, pretende-se demonstrar a eficiência de uma implementação de autômato celular realizando filtragem de dois ruídos diferentes, o ruído gaussiano e de sal e pimenta, por meio da comparação dos resultados obtidos pela filtragem realizada pelo autômato celular usando uma regra de múltiplas etapas, e comparando seu resultado com a filtragem realizada por métodos clássicos do filtro da mediana e do filtro gaussiano. Tal estudo irá utilizar de duas categorias de imagens, médicas e de sensoriamento remoto, a fim de demonstrar a eficiência da filtragem nessas categorias, as quais possuem características diferentes de imagens fotográficas comuns, como retratos.

Palavras-chave: Autômato Celular. Processamento de Imagens. Filtragem de Ruídos.

ABSTRACT

FONSECA, Yago Braz. **Noise Filtering on Medical and Remote Sensing Images with Cellular Automata**. 2021. 82 f. Monography (Course of Bachelor of Computer Science). Instituto Federal de Educação, Ciência e Tecnologia Goiano - Campus Rio Verde. Rio Verde - GO, 2021.

Studies show that cellular automata can be implemented to perform image processing through noise filtering in images. This paper intends to show the efficiency of an implementation of a cellular automaton performing noise filtering of two different noise types, Gaussian and “salt-and-pepper”, by comparing the results obtained through the filtering done by the cellular automaton using a novel rule, and comparing these results with the filtering done by classic methods median filter and Gaussian filter. This paper will use two different categories of images, medical images and remote sensing images, to show the efficiency of the filters in these categories, which have different characteristics from other photographic images, such as portraits.

Keywords: Cellular Automaton. Image Processing. Noise filtering.

LISTA DE FIGURAS

Figura 1 – Diagrama ilustrando as etapas do processamento de imagens	5
Figura 2 – Diagrama ilustrando a divisão de processos	6
Figura 3 – Preenchimento da borda de acordo com a vizinhança do pixel	9
Figura 4 – Diagrama de degradação e restauração	9
Figura 5 – Fractais com autômatos celulares	14
Figura 6 – Interação local entre células leva ao surgimento de um comportamento emergente	16
Figura 7 – Representação comum de um autômato celular unidimensional	18
Figura 8 – Regra 30	19
Figura 9 – “Gosper’s Glider Gun”, em que a parte superior é dada como um “gerador”, a partir do qual gera células periodicamente que atravessam o reticulado até encontrarem a borda	20
Figura 10 – Visualização das vizinhanças de von Neumann e Moore	21
Figura 11 – Limite periódico	22
Figura 12 – Limite reflexivo	22
Figura 13 – Limite fixo, com raio de vizinhança $r = 1$	22
Figura 14 – Exemplos demonstrando tipos de imagens	27
Figura 15 – Exemplo de decomposição de uma imagem em limiares diferentes	29
Figura 16 – Tabela dos resultados com a métrica SSIM	38
Figura 17 – Tabela dos resultados com a métrica RMSE	39
Figura 18 – Gráficos de resultados	41
Figura 19 – Resultados da filtragem do AC-mediana com ruído gaussiano e $\sigma = 0,5$, na imagem <code>sat_mixed_close_1</code>	43
Figura 20 – Filtragem pelo AC-mediana na imagem <code>sat_mixed_close_1</code> com ruído gaussiano de $\sigma = 0,5$	44
Figura 21 – Resultados da AC-média em 50% de ruído sal e pimenta	46
Figura 22 – Resultados da AC-média no ruído gaussiano com $\sigma = 0,9$	47
Figura 23 – Resultados da AC-mediana em 50% de ruído sal e pimenta	48
Figura 24 – Resultados da AC-mediana no ruído gaussiano com $\sigma = 0,9$	49
Figura 25 – Exemplo de filtragens na imagem <code>med_chest_ct</code> com forte ruído sal e pimenta	50
Figura 26 – Exemplo de filtragens na imagem <code>med_chest_ct</code> com forte ruído gaussiano	51
Figura 27 – Imagens médicas	52
Figura 28 – Resultados na imagem <code>sat_urban_further_normal_3</code>	53
Figura 29 – Medida RMSE do filtro gaussiano em 5% de ruído sal e pimenta	59
Figura 30 – Medida RMSE do filtro gaussiano em 25% de ruído sal e pimenta	59

Figura 31 – Medida RMSE do filtro gaussiano em 50% de ruído sal e pimenta . . .	60
Figura 32 – Medida RMSE do filtro gaussiano em ruído gaussiano com $\sigma = 0,5$. .	60
Figura 33 – Medida RMSE do filtro gaussiano em ruído gaussiano com $\sigma = 0,9$. .	61
Figura 34 – Medida RMSE do filtro da Mediana em 5% de ruído sal e pimenta . . .	62
Figura 35 – Medida RMSE do filtro da Mediana em 25% de ruído sal e pimenta . .	62
Figura 36 – Medida RMSE do filtro da Mediana em 50% de ruído sal e pimenta . .	63
Figura 37 – Medida RMSE do filtro da Mediana em ruído gaussiano com $\sigma = 0,5$.	63
Figura 38 – Medida RMSE do filtro da Mediana em ruído gaussiano com $\sigma = 0,9$.	64
Figura 39 – Medida RMSE do filtro do AC (regra média) em 5% de ruído sal e pimenta	65
Figura 40 – Medida RMSE do filtro do AC (regra média) em 25% de ruído sal e pimenta	65
Figura 41 – Medida RMSE do filtro do AC (regra média) em 50% de ruído sal e pimenta	66
Figura 42 – Medida RMSE do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,5$	66
Figura 43 – Medida RMSE do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,9$	67
Figura 44 – Medida RMSE do filtro do AC (regra mediana) em 5% de ruído sal e pimenta	68
Figura 45 – Medida RMSE do filtro do AC (regra mediana) em 25% de ruído sal e pimenta	68
Figura 46 – Medida RMSE do filtro do AC (regra mediana) em 50% de ruído sal e pimenta	69
Figura 47 – Medida RMSE do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,5$	69
Figura 48 – Medida RMSE do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,9$	70
Figura 49 – Medida SSIM do filtro Gaussiano em 5% de ruído sal e pimenta	71
Figura 50 – Medida SSIM do filtro Gaussiano em 25% de ruído sal e pimenta . . .	71
Figura 51 – Medida SSIM do filtro Gaussiano em 50% de ruído sal e pimenta . . .	72
Figura 52 – Medida SSIM do filtro Gaussiano em ruído gaussiano com $\sigma = 0,5$. . .	72
Figura 53 – Medida SSIM do filtro Gaussiano em ruído gaussiano com $\sigma = 0,9$. . .	73
Figura 54 – Medida SSIM do filtro da Mediana em 5% de ruído sal e pimenta . . .	74
Figura 55 – Medida SSIM do filtro da Mediana em 25% de ruído sal e pimenta . . .	74
Figura 56 – Medida SSIM do filtro da Mediana em 50% de ruído sal e pimenta . . .	75
Figura 57 – Medida SSIM do filtro da Mediana em ruído gaussiano com $\sigma = 0,5$. .	75
Figura 58 – Medida SSIM do filtro da Mediana em ruído gaussiano com $\sigma = 0,9$. .	76
Figura 59 – Medida SSIM do filtro do AC (regra média) em 5% de ruído sal e pimenta	77

Figura 60 – Medida SSIM do filtro do AC (regra média) em 25% de ruído sal e pimenta	77
Figura 61 – Medida SSIM do filtro do AC (regra média) em 50% de ruído sal e pimenta	78
Figura 62 – Medida SSIM do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,5$	78
Figura 63 – Medida SSIM do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,9$	79
Figura 64 – Medida SSIM do filtro do AC (regra mediana) em 5% de ruído sal e pimenta	80
Figura 65 – Medida SSIM do filtro do AC (regra mediana) em 25% de ruído sal e pimenta	80
Figura 66 – Medida SSIM do filtro do AC (regra mediana) em 50% de ruído sal e pimenta	81
Figura 67 – Medida SSIM do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,5$	81
Figura 68 – Medida SSIM do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,9$	82

LISTA DE TABELAS

Tabela 1 – Número de regras possíveis de diferentes tipos de autômatos celulares .	18
Tabela 2 – Especificação direta	23

LISTA DE ABREVIATURAS E SIGLAS

RMSE	“Root mean square error”
SSIM	“Structural similarity index measure”
DICOM	“Digital Imaging and Communications in Medicine”
AC	Autômato Celular
PI	Processamento de Imagens

SUMÁRIO

1 – INTRODUÇÃO	1
2 – FUNDAMENTAÇÃO TEÓRICA	4
2.1 Processamento de imagens	4
2.1.1 Conceitos e definições básicas	4
2.1.1.1 Aquisição, formatação e representação	4
2.1.1.2 Armazenamento	5
2.1.1.3 Processamento	6
2.1.1.4 Exibição	7
2.1.2 Transformações de intensidade e filtragem espacial	7
2.1.2.1 Conceitos em transformações e filtragem	7
2.1.2.1.1 Vizinhança e borda	8
2.1.3 Métodos de filtragem de ruídos	8
2.1.4 Modelos de ruídos	10
2.1.5 Critérios de fidelidade	11
2.1.5.1 Critério objetivo de fidelidade	12
2.1.5.2 Critérios subjetivo de fidelidade	13
2.2 Autômatos celulares	13
2.2.1 Definição de conceitos	15
2.2.1.1 Espaço e dimensão	17
2.2.1.1.1 Autômato celular unidimensional	18
2.2.1.1.2 Autômato celular bidimensional	19
2.2.2 Classificações	20
2.2.2.1 Vizinhança e contorno	20
2.2.2.2 Estados e regras de transição	22
2.3 Integração de autômatos celulares no processamento de imagens	25
2.3.1 Tipos de imagens	26
2.3.2 Profundidade de cores	27
3 – TRABALHO PROPOSTO	31
3.1 Escolha do conjunto de imagens	31
3.2 Autômatos celulares em filtragem de imagens	31
3.3 Regra do autômato	32
4 – EXPERIMENTO E RESULTADOS	34
4.1 Processo de escolha de imagens	36

4.2	Processo de escolha dos ruídos	36
4.3	Resultados	37
4.4	Observações	42
4.4.1	Filtragem com o AC-média	44
4.4.2	Filtragem com o AC-mediana	47
4.5	Interpretação de resultados	49
4.5.1	Imagens médicas	49
4.5.2	Imagens de sensoriamento remoto	52
5	– CONSIDERAÇÕES FINAIS	54
5.1	Trabalhos futuros	54
	Referências	56
	 Apêndices	 58
	APÊNDICE A–Tabelas - Resultados: Medida RMSE com o filtro gaussiano . .	59
	APÊNDICE B–Tabelas - Resultados: Medida RMSE com o filtro da mediana .	62
	APÊNDICE C–Tabelas - Resultados: Medida RMSE com o filtro do AC (regra média)	65
	APÊNDICE D–Tabelas - Resultados: Medida RMSE com o filtro do AC (regra mediana)	68
	APÊNDICE E–Tabelas - Resultados: Medida SSIM com o filtro gaussiano . . .	71
	APÊNDICE F–Tabelas - Resultados: Medida SSIM com o filtro da mediana . .	74
	APÊNDICE G–Tabelas - Resultados: Medida SSIM com o filtro do AC (regra média)	77
	APÊNDICE H–Tabelas - Resultados: Medida SSIM com o filtro do AC (regra mediana)	80

1 INTRODUÇÃO

Em termos simplísticos, o autômato celular (AC) pode ser definido como um reticulado de células, no qual célula assume um determinado estado, a qual varia de acordo com o tempo a partir da regra que define o AC, ditando qual estado uma célula irá assumir de acordo com a sua vizinhança local.

Apesar de definições e regras simples, um AC pode reproduzir um número considerável de comportamentos interessantes, alguns também apresentando semelhanças com fenômenos orgânicos, isto é, que podem ser observados na natureza, tais como fractais (FRAME; BENOIT; NEGER, 2001).

Estes aspectos do AC, como o surgimento de comportamentos complexos e aparentemente semelhantes a fenômenos naturais a partir de um conjunto simples de regras, foram atrativos para pesquisadores de várias áreas, o que levou a exploração e expansão do mesmo desde a sua introdução (OLIVEIRA, 2003).

Visto que o reticulado de um AC pode se assemelhar a uma representação bidimensional de uma imagem, em que cada célula pode ser considerada um pixel e os valores possíveis de pixel como os estados do AC, outra questão a ser verificada seria na reprodução de efeitos ou ações pelo AC, como o processamento da imagem para um determinado fim. A Seção 2.3 deste trabalho trata sobre esse assunto mais profundamente, demonstrando como pode ser feita a integração de um AC para o processamento de imagens.

No trabalho feito por Popovici e Popovici (2002), foi demonstrado que autômatos celulares bidimensionais são capazes de realizar operações de remoção de ruído e detecção de bordas em imagens digitais binárias, tratando o estado inicial do autômato celular como os valores dos *pixels* da imagem. Em seu estudo, o método proposto, utilizando de uma regra de transição simples, é comparado com um método clássico, o filtro gaussiano.

Ainda neste mesmo trabalho, é demonstrado que o autômato celular é comparável ou melhor do que o método clássico no processo de remoção de ruídos, apresentando imagens tão claras quanto o filtro gaussiano. Também é ressaltada a importância da consideração do paralelismo intrínseco dos autômatos celulares.

Em um estudo por Alves (2015), é realizada uma análise comparativa do uso dos autômatos celulares na filtragem de imagens com métodos clássicos.

Nesse mesmo estudo, como metodologia, é selecionado um conjunto de 9 imagens, com formato de 512x512 pixels e 72 dpi, convertidas para uma configuração binária, para serem utilizadas no estudo de processamento de imagens. As imagens diferenciam-se em número de objetos presentes na imagem e área contínua. O perfil de características que fazem parte dessas imagens contribuem para a diversidade das condições iniciais, e o número de pixels facilita a observação dos resultados.

No mesmo estudo, cada imagem do conjunto foi usada como estado inicial de três

tipos de autômatos celulares bidimensionais: com 5 vizinhos totalísticos e vizinhança de von Neumann; com 5 vizinhos não totalísticos e vizinhança von Neumann; e 9 vizinhos totalísticos, com vizinhança Moore, as quais são exemplificadas na Subsubseção 2.2.2.1. As imagens são salvas em cada evolução dos primeiros 20 passos, e utilizam-se de todos os números de regras possíveis para cada tipo de configuração. Com 5 vizinhos totalísticos e com vizinhança de von Neumann, como visto na Tabela 1 da Subsubseção 2.2.1.1, há $2^{5 \cdot (2-1)+1} = 64$ regras possíveis, as quais todas são testadas. A partir disso, obtém-se $20 \times 64 = 1280$ imagens para este AC totalístico em específico. Esse procedimento é repetido nos demais ACs, e assim, todas as imagens geradas são comparadas com as imagens obtidas por métodos clássicos de filtragem, como o filtro laplaciano, sobel e de mediana.

No estudo de Alves (2015), foram utilizadas apenas imagens capturadas por câmeras fotográficas. Há uma gama de dispositivos os quais são capazes de capturar e digitalizar imagens, as quais são geradas com aspectos diferentes, como imagens médicas, de sensoriamento remoto, biometria etc. Além disso, a representação binária das imagens limita a sua aplicação prática, já que é muito mais comum o uso de imagens ao mínimo em escala-cinza, as quais apresentam um grau de detalhe maior e permitem manipulações mais precisas e apresentação de resultados mais aplicáveis.

Inspirado no trabalho de Alves (2015), a presente proposta também pretende investigar a aplicação de autômatos celulares para remoção de ruídos. O grande diferencial da presente proposta está no processamento de imagens em escala de cinza, visto que o trabalho Alves (2015) contempla apenas imagens binarizadas e aplica o processamento em imagens de origem fotográfica comuns, como imagens retratando pessoas ou animais em um determinado momento.

Dessa forma, será possível expandir o emprego da técnica de eliminação de ruídos, usando autômatos celulares, para um conjunto maior de aplicações, já que elas apresentam um grau de detalhes maior e permite demonstrar a eficiência do processo de filtragem por meio da comparação da imagem de entrada com a imagem filtrada com maior clareza.

Este trabalho tem como principal objetivo implementar um autômato celular, baseados em trabalhos já existentes, para realizar o processamento de imagens com o propósito de reduzir/filtrar ruídos e fazer comparações com métodos clássicos, afim de verificar a eficiência das regras em imagens de natureza diferentes das que são comumente analisadas, tais como retratos fotográficos. Mais especificamente, tem como propostas:

- Identificar e estudar autômatos celulares que são aplicados ao processamento de imagens para filtragem de ruídos;
- Escolher imagens para serem processadas e dividi-las em grupos baseados na fonte de origem. Entre esse grupos, pretende-se obter imagens que se encaixam nas classificações:

- Imagens médicas, obtidas por radiografia, tomografia e ressonância magnética do corpo humano;
- Imagens de sensoriamento remoto, capturadas por satélites e ;
- Efetuar experimentos com a implementação de autômato celular para avaliar a sua eficiência na remoção de ruídos introduzidos artificialmente nas imagens selecionadas;

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Processamento de imagens

A área de processamento de imagens envolve as técnicas voltadas para a análise de dados bidimensionais adquiridos por sensores de captura e processamento de imagens geradas de forma digital. Em outras palavras, é a área que envolve manipulação de uma imagem por um computador de modo onde a entrada e saída do processo são imagens.

Trata-se da área responsável pela manipulação de técnicas para a análise e pesquisa dos aspectos estruturais de uma imagem, afim de aplicar de maneira efetiva o processamento da mesma, como na filtragem de certos aspectos indesejáveis, como ruídos ou artefatos, ou para realçar detalhes, como por meio de operações com o aumento da saturação, nitidez e manipulação de cores, ou então na modificação dos aspectos morfológicos de uma imagem, como por operações de mediana, erosão, dilatação, fechamento e abertura de formas e aspectos presentes numa imagem.

Segundo Filho e Neto (1999), o processamento de dados pictóricos por um computador assume diferentes formas numa variedade de aplicações. Os trabalhos nessa área costumam ser classificados em três áreas, as quais são subáreas da computação gráfica: gráficos, o qual envolve a criação de imagens; processamento de imagens, envolvendo a melhoria e manipulação da imagem; reconhecimento de padrões pictóricos, ou visão computacional, o qual trabalha com a análise do conteúdo da imagem. Devido a isso, a área viabiliza um grande número de aplicações e explica o crescimento de interesse ao decorrer dos anos.

2.1.1 Conceitos e definições básicas

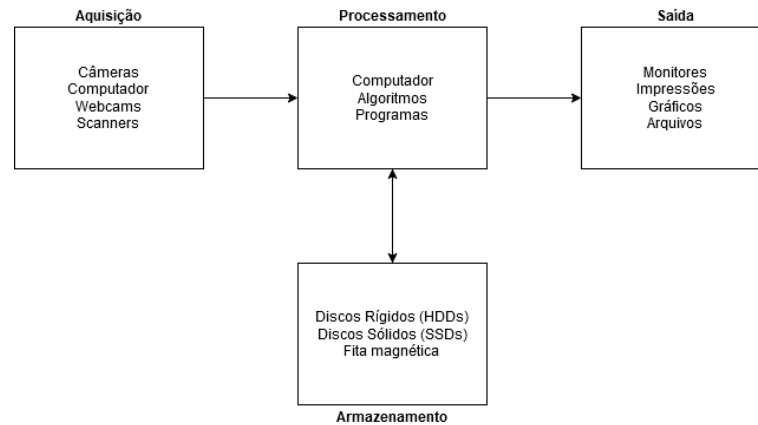
O processamento de imagens pode ser entendido como um sistema constituído de vários componentes, os quais podemos entender como etapas, que levam ao resultado final de uma imagem alterada, ou seja, processada por alguma operação. É comum dividir e classificar essas etapas em: aquisição, armazenamento, processamento e exibição, como demonstrado na Figura 1 (FILHO; NETO, 1999).

2.1.1.1 Aquisição, formatação e representação

A imagem é capturada por um sensor, como uma câmera, por exemplo, e digitalizada, caso a saída da câmera ou sensor não seja do formato digital, utilizando um conversor analógico-digital. Essa etapa garante que a representação da imagem seja adequada para suas manipulações futuras.

A imagem digital capturada é uma representação de forma bidimensional, dada como um conjunto finito de elementos digitais, nomeados pixels, em que seus valores são

Figura 1 – Diagrama ilustrando as etapas do processamento de imagens



Fonte: autoria própria.

usados para representar níveis de cinza, cores, coordenadas ou opacidade, por exemplo. Trata-se de uma aproximação da cena real capturada pelos sensores (GONZALES; WOODS, 2008).

Imagens digitais são denotadas por uma função bidimensional da forma $f(x, y)$, em que (x, y) representam coordenadas espaciais da imagem. Além disso, temos valores F , que representam a amplitude de qualquer par de coordenadas (x, y) , denotando a intensidade ou nível de escala cinza da imagem no determinado ponto.

Na representação de uma imagem, podemos identificá-la como uma matriz $M \times N$ numérica, como exemplificado na Equação (1).

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \dots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & \dots & f(1, N - 1) \\ \dots & \dots & \dots & \dots \\ f(M - 1, 0) & f(M - 1, 1) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (1)$$

Todas as operações realizadas numa imagem levam em consideração a sua formação como uma matriz numérica.

2.1.1.2 Armazenamento

Utiliza-se de uma grande quantidade de bytes que representam uma imagem digitalizada. Formas de armazenamento podem ser divididas em algumas categorias:

- Armazenamento de curta duração, enquanto é utilizada em etapas do processamento. A memória RAM de um computador pode ser utilizada para isso. Outra opção é o uso de “framebuffers”, a memória responsável por armazenar e transferir para uma telas os dados do quadro de uma imagem, presentes em computadores modernos e acessados pela GPU (“graphics processing unit”) durante suas operações;
- Armazenamento em massa, para operações de recuperação. Trata-se da transformação

de uma imagem digitalizada em um formato de armazenamento, incluindo um cabeçalho com informações adicionais, como cores e tamanho da imagem;

- Arquivamento de imagens. Trata-se de armazenamento de longo período, indefinido, o qual a recuperação será feita em uma data futura, em que imagens formatadas são guardadas em uma grande quantidade de bytes dentro de um dispositivo de armazenamento, como discos rígidos.

2.1.1.3 Processamento

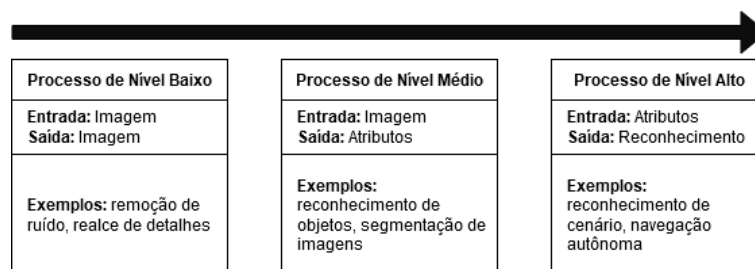
Envolve a manipulação de imagens por meio de operações específicas, com algum objetivo, como filtrar ruídos, transformações morfológicas, tratamento de cores e restauração da imagem. Esses procedimentos podem ser representados na forma de algoritmos implementados por softwares. Em casos específicos, quando há limitações que impedem uma velocidade de transferência de imagens adequada, hardware específico para o processamento de imagens também é utilizado.

O processamento de imagens digitais tem como foco duas tarefas:

- Melhoria de informação pictórica para a interpretação humana;
- Processamento de dados de imagens para armazenamento, transmissão e representação por máquinas autônomas de percepção;

De acordo com Gonzales e Woods (2008), os processos envolvidos num sistema de processamento de imagens podem ser divididos em níveis baixo, médio e alto. O diagrama da Figura 2 ilustra tal divisão.

Figura 2 – Diagrama ilustrando a divisão de processos



Fonte: autoria própria.

Processos de baixo nível são operações primitivas, como a redução de ruído e realce de detalhes, envolvendo manipulação de contraste e nitidez. Processos de nível médio envolvem: segmentação de uma imagem em regiões ou objetos; descrição dos objetos e aspectos da imagem para o processamento computacional; classificação dos aspectos da imagem. Por fim, processos de alto nível envolvem a análise da imagem e visão computacional.

2.1.1.4 Exibição

A saída dada pelo processamento de uma imagem envolve a transmissão da mesma e sua exibição. A transmissão pode ser feita por meio de redes de computadores (pela internet), podendo ser utilizadas técnicas de compressão e descompressão. A exibição é feita através de dispositivos dedicados, comuns no uso diário moderno, como monitores de vídeo, televisões e celulares, por exemplo.

2.1.2 Transformações de intensidade e filtragem espacial

O domínio espacial é definido como o plano da imagem em si, ou seja, o plano bidimensional o qual contém pixels e cada pixel contendo seus valores. Métodos de processamento de imagens são baseados na manipulação direta de pixels de uma imagem (GONZALES; WOODS, 2008).

Geralmente, técnicas desse domínio são relativamente mais eficientes computacionalmente e requerem menos recursos de processamento para serem implementadas, já que lidam diretamente com o plano da imagem. Em contraste, o processamento em um domínio diferente, o qual é necessário transformar a imagem para o domínio de transformação (“transform domain”) e obter seu inverso para obter o resultado no domínio espacial, necessita de mais recursos.

Podemos dividir operações no domínio espacial em duas grandes categorias (GONZALES; WOODS, 2008):

- Transformações de Intensidade: operações diretas em pixels da imagem, geralmente para manipulação de contraste e limiar (“thresholding”);
- Filtragem Espacial: operações como manipulação da nitidez e claridade de uma imagem, a qual envolve trabalho com as vizinhanças de todos os pixels de uma imagem.

2.1.2.1 Conceitos em transformações e filtragem

Como definido por Gonzales e Woods (2008), os processos de transformação do domínio espacial podem ser denotados de acordo com a Equação (2):

$$g(x, y) = T[f(x, y)] \quad (2)$$

onde $f(x, y)$ é a imagem de entrada, $g(x, y)$ é a imagem de saída, e T é um operador em f definido sobre a vizinhança de um ponto (x, y) . Tal operador pode ser aplicado em uma única imagem ou num conjunto de imagens, como na soma de pixel-por-pixel de uma sequência de imagens para a redução de ruído.

2.1.2.1.1 Vizinhaça e borda

Como definido, processos de filtragem levam em consideração a vizinhaça de um pixel para aplicar uma determinada operação. O tipo de operação feito nessa vizinhaça determina a natureza do processo de filtragem, como manipulação da imagem para aprimoramento por meio da modificação de seus níveis de intensidade ou por transformações morfológicas para remoção de ruído.

Uma vizinhaça é definida como um raio r de pixels vizinhos de um determinado pixel numa posição (x, y) . A menor vizinhaça possível é de tamanho 1×1 , em que g depende apenas do valor de f num determinado ponto (x, y) e T , da Equação (3), se torna uma função de transformação do valor de intensidade (como nível de cinza) do pixel, da forma:

$$s = T(r) \quad (3)$$

onde as variáveis s e r denotam, respectivamente, a intensidade de g e f num ponto (x, y) . Tais transformações podem ser aplicadas para transformar o nível de contraste de uma imagem, seja no seu escurecimento, abaixando os níveis de intensidade abaixo de um valor k ou na iluminação da imagem, aumentando os níveis para acima de um valor k .

A transformação envolve a produção de imagens binárias, a qual o processo é chamado de *thresholding function*, ou de transformação de limiares, em que um pixel é transformado em branco ou preto a partir de um determinado nível de cinza (GONZALES; WOODS, 2008).

Quando a origem da vizinhaça, ou seja o pixel central, está na borda da imagem, parte da vizinhaça vai se situar fora da imagem. Para tratar disso, geralmente é ignorado os vizinhos afora na computação especificada pelo processo T , ou a porção fora da borda da imagem é preenchida por valores definidos, sendo que o tamanho desse preenchimento é de acordo com o raio da vizinhaça.

A Figura 3 ilustra como ocorre o processo de preenchimento. Como a vizinhaça tem apenas um raio igual a 1, a profundidade do preenchimento também é de apenas 1.

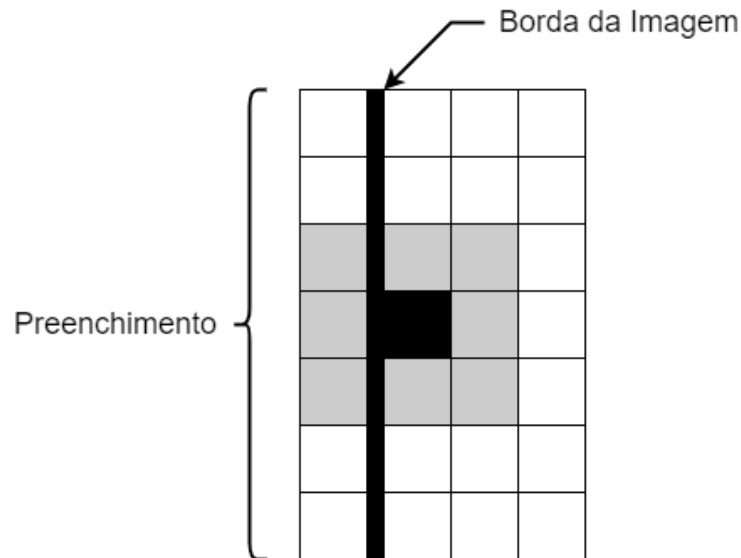
2.1.3 Métodos de filtragem de ruídos

Levando em consideração o domínio espacial de uma imagem a qual há apenas a introdução de ruídos para ser filtrado, ou seja, sem a presença de outras formas de degradação, dada uma imagem de entrada $f(x, y)$ e um termo de ruído $\eta(x, y)$, obtemos uma imagem degradada por apenas o ruído $g(x, y)$, de acordo com a Equação (4).

$$g(x, y) = f(x, y) + \eta(x, y) \quad (4)$$


O diagrama da Figura 4 ilustra o processo de degradação e restauração.

Figura 3 – Preenchimento da borda de acordo com a vizinhança do pixel



Fonte: autoria própria.

Figura 4 – Diagrama de degradação e restauração



Fonte: Gonzales e Woods (2008).

Em que $\hat{f}(x, y)$ é equivalente a uma aproximação da imagem de entrada e a função de degradação H é assumida como o operador de identidade com o propósito de levar em consideração a única degradação da imagem sendo a própria introdução do ruído.

Nessas situações em que há apenas a presença de ruído aditivo na imagem de entrada, em que não sabemos os termos ou parâmetros da geração do ruído, a filtragem espacial é o método utilizado. Um método desse tipo de filtragem é o filtro da mediana, em que a imagem é percorrida por completo, substituindo o valor de cada pixel pela mediana dos valores de sua vizinhança. Podendo ser representada como demonstrado pela Equação (5):

$$\hat{f}(x, y) = \text{mediana}_{(s,t) \in S_{xy}} \{g(x, y)\} \tag{5}$$

Em que S_{xy} representa o conjunto de coordenadas da vizinhança retangular de tamanho $m \times n$ do ponto (x, y) . A filtragem de ruído ocorre pelo embaçamento da imagem (GONZALES; WOODS, 2008).

Tal filtro é particularmente efetivo na remoção de ruídos bipolares, como o ruído sal e pimenta, o qual é dado como a introdução de pixels de valores extremos (como 255 e 0 caso no faixa da escala de cinza) na imagem. A operação da mediana é eficaz na remoção desses valores extremos (também chamados de “outliers”).

Por outro lado, com um filtro de média aritmética, a remoção de ruído é dada pela mesclagem dos valores dos pixels da vizinhança pela operação de média. O filtro é representado pela Equação (6).

$$\hat{f}(x, y) = \frac{1}{mn} \sum_{(s,t) \in S_{xy}} g(x, y) \quad (6)$$

Outra forma de filtragem de ruídos é por meio da filtragem no domínio de frequências. Como citado na Subseção 2.1.2, para esse tipo de filtragem, a imagem é transformada para sua distribuição de frequências pela transformada de Fourier (GONZALES; WOODS, 2008).

O processamento é realizado nessa distribuição e após isso, o resultado é obtido pela transformação inversa, obtendo a imagem filtrada no domínio espacial. Como citado por Gonzales e Woods (2008), filtros nesse domínio são classificados em:

- Passa baixa: permite passar os valores de frequência baixos da distribuição, eliminando os valores altos. Tem o propósito de suavizar a imagem, atenuando transições abruptas;
- Passa alta: permite passar os valores de frequência altos da distribuição, eliminando os valores baixos. Destaca transições entre diferentes regiões da imagem;
- Passa banda: permite passar apenas os valores correspondendo à uma determinada frequência ou faixa de frequência, eliminando os demais valores.

O filtro mais comum no domínio para o propósito de suavização é o filtro de passa baixa Gaussiano. Tal filtro é tão suave quanto o desvio padrão utilizado na distribuição Gaussiana. A distribuição em um plano bidimensional tem a forma dada pela Equação (7):

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (7)$$

Com σ sendo o desvio padrão.

2.1.4 Modelos de ruídos

A presença de ruídos em imagens geralmente aparece durante a sua aquisição ou transmissão, devido a performance ou qualidade de sensores de imagens ou fatores externos que afetam o sinal da imagem durante sua aquisição ou transmissão, como por meio de interferência de outros sinais no ambiente externo.

Modelos comuns de distribuição de ruídos em imagens são geralmente caracterizados por uma função densidade de probabilidade (FDP) de uma variável aleatória contínua, que descreve a verossimilhança, ou seja, a possibilidade da variável aleatória tomar um valor dado. A variável aleatória é contínua quando ela pode tomar valores dentro de uma gama de valores.

Tal função é aplicada no domínio espacial da imagem a fim de atribuir um valor de ruído no pixel baseado em uma variável aleatória. Como descrito por Gonzales e Woods (2008), algumas das funções de densidade de probabilidade mais comuns para distribuição de ruídos em imagens são:

- Ruído gaussiano: dada uma variável aleatória z , podemos ver a FDP na Equação (8):

$$p(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\bar{z})^2}{2\sigma^2}} \quad (8)$$

Em que z representa a intensidade, como um tom de cinza do pixel, \bar{z} a média de z , e σ seu desvio padrão. A FDP é representada pela distribuição normal, ou também chamada de distribuição Gaussiana.

- Ruído de sal e pimenta (“salt and pepper”): A FDP desse tipo de ruído, também chamado de ruído de impulso ou bipolar, é dada pela Equação (9):

$$p(z) = \begin{cases} P_a & \text{para } z = a \\ P_b & \text{para } z = b \\ 0 & \text{caso contrário} \end{cases} \quad (9)$$

Se $b > a$, a intensidade b será um ponto claro. Por outro lado, o nível a será um ponto escuro. Se ambos P_a ou P_b são zero, o ruído é unipolar. Caso não sejam zero, e quando também admitem valores equivalentes, dão a aparência de partículas de sal e pimenta distribuídas sobre a imagem.

Os valores dos pontos claros e escuros geralmente são dados como os extremos da gama de valores da imagem (por exemplo, 0 e 255 na escala de cinza, representando preto e branco respectivamente).

2.1.5 Critérios de fidelidade

A filtragem de ruído ou informação irrelevante numa imagem sempre irá resultar na perda de informações. Devido a isso, é necessário uma maneira de quantificar a perda de informação. Como classificado por Gonzales e Woods (2008), podemos ter duas classificações para esse tipo avaliação: critérios objetivos e subjetivos de fidelidade.

2.1.5.1 Critério objetivo de fidelidade

Trata-se do critério em que a perda da informação é representada por uma função matemática, por exemplo, a raiz do erro quadrático médio (“root mean square error” ou RMSE) entre duas imagens. Como Gonzales e Woods (2008) definem: dada $f(x, y)$ como uma imagem de entrada e $\hat{f}(x, y)$ uma aproximação da imagem de entrada. Para qualquer valor x e y , o erro $e(x, y)$ entre ambas imagens é dado por:

$$e(x, y) = \hat{f}(x, y) - f(x, y) \quad (10)$$

Então, o erro total é dado por:

$$\sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [\hat{f}(x, y) - f(x, y)] \quad (11)$$

com tamanhos das imagens $M \times N$. Assim, o RMSE, ou e_{rms} , entre ambas imagens é a raiz do erro quadrático médio sobre a matriz $M \times N$, dado pela Equação (12):

$$e_{rms} = \left[\frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [\hat{f}(x, y) - f(x, y)]^2 \right]^{1/2} \quad (12)$$

O resultado obtido pelo RMSE de duas imagens, uma sem ruído e outra com ruído filtrado, irá dizer a qualidade da filtragem por meio da quantificação da diferença entre as duas. Para comparações, também pode se obter a diferença entre a imagem sem ruído com a imagem com ruído não filtrado, e comparar o erro anterior com esse, para obter a eficiência da filtragem.

No entanto, a maior deficiência do RMSE é que ele não é altamente indicativo da semelhança perceptível entre duas imagens, já que a análise é feita entre o erro entre cada pixel individualmente e independentemente dos pixels ao seu redor, o que não é como o ser humano percebe imagens. Uma análise melhor seria compreendendo a imagem holisticamente, levando em consideração as partes que a compõem, como objetos presentes, cenários e contornos.

Assim, outra forma de avaliação objetiva entre imagens é por meio do índice de similaridade da estrutura entre imagens (“structure similarity index measure” ou SSIM), a qual resolve, em parte, as deficiências do RMSE, levando em consideração a textura da imagem por meio de uma análise de grupos de pixels, de modo geral.

De acordo com Wang et al. (2004), a informação estrutural de uma imagem é definida como os atributos que representam a estrutura dos objetos em um cenário, independente da luminosidade ou contraste médio. Como luminosidade e contraste variam através de uma imagem, é utilizado luminosidade e contrastes locais para a definição do algoritmo.

A medida obtida pelo SSIM pode ser entendida como o produto de três componentes, como observado na Equação (13).

$$SSIM(A, B) = l(A, B) \cdot c(A, B) \cdot s(A, B) \quad (13)$$

Na equação, A e B representam as imagens a serem comparadas, $l(A, B)$ representa a medida de comparação de luminosidade, $c(A, B)$ representa a medida de comparação de contraste e a $s(A, B)$ a medida de comparação da estrutura. A Equação (14) ilustra o processo mais completamente.

$$SSIM(A, B) = \frac{(2\mu_A\mu_B + C_1) \cdot (2\sigma_{AB} + C_2)}{(\mu_A^2 + \mu_B^2 + C_1) \cdot (\sigma_A^2 + \sigma_B^2 + C_2)} \quad (14)$$

Em que C_1 representa uma constante arbitrária para evitar instabilidade quando $\mu_A^2 + \mu_B^2$ são próximos a zero, tendo a:

$$C_1 = (K_1 \cdot L)^2 \quad (15)$$

com L podendo ser dada como o produto da gama dinâmica (diferença entre o maior e menor valor de intensidade dos pixels. Como exemplo, 255 para uma imagem 8 bits em escala de cinza) de valores de pixel L com uma constante K em que $K \ll 1$. A mesma definição é válida para C_2 . Valores possíveis são $C_1 = (0.01 \times 255)^2$ e $C_2 = (0.03 \times 255)^2$

O índice $SSIM$ é então aplicado localmente por meio de uma função de ponderação Gaussiana simétrica-circular 11×11 , e a média sobre a imagem é utilizada para calcular a medida final de semelhança (ROSIN; SUN, 2011).

Os valores obtidos pela medida $SSIM$ dependem de sua implementação. Geralmente, utiliza-se de valores em que $0 \leq SSIM \leq 1$, com 1 representando semelhança perfeita e 0 representa completa falta de semelhança.

2.1.5.2 Critérios subjetivo de fidelidade

Como imagens são ultimamente capturadas para a visualização pelo ser humano, uma maneira de avaliação de fidelidade seria por meio de um grupo de indivíduos selecionados para realizar da avaliação a qualidade de imagens, como por exemplo, utilizando uma escala de classificação de 0 a 5, com cada valor como uma indicação de qualidade em comparação com a imagem sem ruído, sendo os extremos indicando a melhor e pior avaliação possível.

2.2 Autômatos celulares

A proposição inicial do autômato celular (AC) teve como objetivo projetar mecanismos artificiais capazes de auto-reprodução. Pesquisadores como Stanislaw Ulam, John Conway e Stephen Wolfram investigavam uma variedade de jogos matemáticos dispostos em uma grade bidimensional onde o estado de cada ponto na grade era atualizado de acordo com o seu próprio estado e os estados de seus vizinhos. O “Game of Life” de John

Conway, um exemplo de AC binário bidimensional, foi o resultado da pesquisa extensa desses tipos de jogos matemáticos, com uma regra de transição bastante simples, onde células no estado 0 são interpretadas como mortas e o no estado 1 são dadas como vivas (OLIVEIRA, 2003).


John Conway, quando propôs o “Game of Life”, a partir da aplicação de um AC bidimensional, demonstrou como seu comportamento e reticulados podem ter resultados completamente diferentes e complexos baseados em sua configuração inicial e regras definidas.

Podemos ver essas diferenças de comportamento e resultado de interação entre células do reticulado por meio da configuração inicial do reticulado do próprio “Game of Life”. Como é amplamente utilizado para exemplificação de autômatos celulares em meios didáticos, há várias configurações predispostas e estudadas dentro do próprio “Game of Life”.

Exemplos disso são configurações nomeadas, como *Gosper Glider Gun*, um padrão de células num reticulado com uma parte principal que repete periodicamente e que emite células que aparentam caminhar na direção oposta a parte principal.

Além dessas configurações, ACs já foram aplicados para demonstração de geração de fractais. Como demonstrado por Frame, Benoit e Neger (2001), eles podem produzir uma considerável variedade de comportamentos que se assemelham a fractais que podemos encontrar na natureza, devido a sua aparência semi-aleatória. A Figura 5 mostra uma exemplo de fractal gerado por um AC.

Figura 5 – Fractais com autômatos celulares



Fonte: Frame, Benoit e Neger (2001)

O “Game of Life” foi um dos primeiros exemplos que demonstraram como o potencial de um autômato celular pode ser aplicado em outras áreas. Essa sua aplicação para a demonstração de evolução de modelos estabeleceu um precedente que sua presença poderia ser útil no estudo de modelos que utilizam desse aspecto evolutivo, como algoritmos

genéticos. Esses modelos demonstram como o sistema se assemelha bastante a vida real, em relação a reprodução e comportamento de colônias de células. A partir disso, partiram vários estudos de autômatos e sua implementação com outras áreas (OLIVEIRA, 2003).


2.2.1 Definição de conceitos

De acordo com Oliveira (2003), autômatos celulares são exemplos de sistemas dinâmicos discretos, ou seja, lidam com variáveis, tempo e espaço. São estudados e aplicado em áreas da ciência da computação, matemática, física, biologia teórica e sistemas complexos. Tratam-se de sistemas consistindo de um grande número de componentes simples idênticos, com conectividade local, os quais o resultado da interação entre si leva a emergência de uma diversidade de comportamentos dinâmicos e complexos. Esses sistemas apresentam implementação simples, que permite a manipulação de seus parâmetros para o estudo de seus comportamentos.

Um autômato celular é caracterizado por uma regra de transição de estados, que determina como ocorre a interação entre cada componente, e qual será o próximo estado do reticulado do AC, a partir do seu estado atual.

Apesar da simplicidade das células que compõem o sistema, é a partir da dinâmica e do resultado de suas interações locais, definidas e limitadas pelas regras do sistema e dos atributos das células, que é possível observar o surgimento de comportamentos complexos e dinâmicos e de uma propriedade global, a qual influenciará o comportamento das células do sistema com o passar do tempo. Essa retroalimentação de interações locais que permite emergir uma propriedade global a qual influenciará as próximas interações locais que definem a essência de um sistema de autômatos celulares. O diagrama da Figura 6 ilustra o processo.

Figura 6 – Interação local entre células leva ao surgimento de um comportamento emergente



Fonte: *Autômatos Celulares: Aspectos Dinâmicos Computacionais* (OLIVEIRA, 2003).

Mais especificamente podemos definir um autômato em quatro atributos:

- Estado de espaço: o modelo do mundo, uma coleção de células;
- A vizinhança da célula: células as quais seus estados atuais afetam o estado da próxima célula;
- O número de estado que uma célula pode assumir: mede o nível de detalhe que podemos enxergar com as células;
- A regra do autômato: define como os estados atuais da vizinha determinam o próximo estado de uma célula.

Ainda mais, de acordo com Lima (2007), estes atributos podem ser representados matematicamente da seguinte maneira:

- L , uma grade regular, d -dimensional, em forma de células;
- S é um conjunto finito de estados;
- N , a vizinhança, é um conjunto finito, de tamanho $|N| = n$ e dimensão d , tal que para todo $c \in L \Rightarrow N(c) \in L$. A vizinhança de cada célula deve pertencer a grade L ;
- $f : (S, N) \rightarrow S$ uma função de transição.

Portanto, como definido anteriormente por Lima (2007), (L, S, N, f) representa o conjunto de um autômato celular, onde L representa a discretização do espaço e S o conjunto de diferentes estados os quais uma célula pode assumir. A vizinhança N de uma célula influencia na definição do novo estado da célula a partir da função f , que representa a regra de transição, que a partir da vizinhança e do estado da célula, define o seu próximo estado. Também devemos considerar a definição da condição de contorno e a vizinhança das células do contorno do domínio definido, em outras palavras, devem ser consideradas as interações que ocorrem entre as células próximas as bordas, ou seja, das extremidades da grade regular.

2.2.1.1 Espaço e dimensão

Um autômato celular é discretizado em uma grade regular composta por células. Lima (2007) define essa grade regular como sendo uma discretização do domínio de dimensão d , em que as células preenchem o domínio completamente e ao transladar a grade em d direções independentes, temos a mesma grade. Como dimensão, é comum um autômato celular admitir um formato unidimensional, bidimensional ou tridimensional, porém não se limita a apenas esses espaços.

Um autômato celular unidimensional que apresenta apenas dois estados (0 e 1) e possui vizinhança com $r = 1$, levando em consideração a própria célula, possui no total $2^8 = 256$ regras possíveis. Quanto mais dimensões levamos em consideração, o número de regras cresce exponencialmente.

Wolfram (2002) determina a quantidade de regras que podemos encontrar da maneira demonstrada pela Tabela 1, onde r é o raio e k um número de estados do autômato celular.

Tabela 1 – Número de regras possíveis de diferentes tipos de autômatos celulares


Regras elementares	256
Regras gerais	$k^k 2^{r+1}$
Regras totalísticas gerais - 1D	$k^{(k-1)(2r+1)+1}$
Regras gerais - 2D	$k^{k(2r+1)^2}$
Regras totalísticas 9 vizinhos - 2D	$k^{9(k-1)+1}$
Regras totalísticas 5 vizinhos - 2D	$k^{5(k-1)+1}$
Regras não-totalísticas 5 vizinhos - 2D	$k^{k(4(k-1)+1)}$

Fonte: Wolfram (2002).

2.2.1.1.1 Autômato celular unidimensional

Como definição comum, um autômato celular unidimensional trata-se de uma configuração de células dispostas numa grade configurada como um vetor. É o tipo de autômato celular mais simples, mas que é capaz de gerar comportamentos complexos.

Figura 7 – Representação comum de um autômato celular unidimensional



Fonte: autoria própria.

A Figura 7 mostra uma representação comum de um autômato celular unidimensional, ilustrado por um diagrama de padrão espaço-tempo, nos quais a configuração de estados das células é plotada como uma função do tempo (LIMA, 2007).

O reticulado é mostrado horizontalmente, com as células representadas por $i, i - 1, i + 1$, e o tempo t é incrementado verticalmente.


Um autômato celular, como demonstrado na Figura 7, que possui apenas dois estados possíveis, e raio 1 fornece apenas 2^3 configurações de vizinhança possíveis, um total de $2^{2^{2 \cdot 1 + 1}} = 2^{2^3} = 256$ regras disponíveis para o autômato, como definido pela Tabela 1 na Subsubseção 2.2.1.1. Como definido por Wolfram (2002), este tipo de AC pode ser visto classificado como elementar.

Para a regra de transição f_{AC} do autômato celular elementar, devemos definir uma regra para cada configuração de estados possíveis da vizinhança de uma célula. Utilizando de notação binária, podemos nomear o estado branco de 1 e o preto de 0. Usando disso,

uma vizinhança com raio $r = 1$ e levando em consideração a célula i central, as diferentes configurações de vizinhanças podem ser representadas por um número em binário de 3 bits, com cada bit representando uma célula, variando de $(000)_2 = (0)_{10}$, com as três células brancas, até $(111)_2 = (7)_{10}$, as três células pretas. O número em binário de 3 bits é usado para determinar o estado da célula i na próxima evolução do autômato elementar.

Usando-se disso, cada configuração de vizinhança é normalmente representada ordenando-se essas possíveis configurações, em ordem decrescente. O número, em binário, formado pelo resultado da aplicação dessas regras fornece o nome da função (LIMA, 2007).

Figura 8 – Regra 30



Fonte: autoria própria.

A Figura 8 mostra um exemplo de como é aplicada a nomeação de regras citada anteriormente. Como resultado da aplicação das regras temos o número $(00011110)_2 = (30)_{10}$, que determina o número da regra a ser aplicada.

2.2.1.1.2 Autômato celular bidimensional

Além da representação em um espaço unidimensional, o qual pode ser entendido como um vetor de células, também é comum sua representação num plano bidimensional, em que o reticulado é interpretado como uma matriz de células.


Devido a adição de uma nova dimensão, é elevada consideravelmente a sua complexidade, como na escolha de regras e no número de vizinhanças possíveis. Um exemplo disso pode ser visto novamente pela Tabela 1, em que um AC de raio 1, vizinhança Moore (9 vizinhos incluindo a própria célula central) e com apenas 2 estados, tem $2^{9 \cdot (2-1)+1} = 1024$ regras possíveis.

O aumento no número de estados do AC leva a um crescimento exponencial do número de regras possíveis, dificultando a especificação direta na maioria dos casos.

Devido ao aumento da complexidade, o número de situações as quais podem ser observadas passa a ser muito maior e assim torna-se possível a representação de um número maior de comportamento. Por exemplo, como citado no início da Seção 2.2, a configuração “Gosper’s Glider Gun” possui uma parte central que repete periodicamente, simulando movimento das células que surgem a partir de uma parte central e que viajam através do reticulado.

A Figura 9 mostra uma geração do AC referenciado, em que o passar das gerações mostra os grupos de células viajando diagonalmente através do reticulado.

Figura 9 – “Gosper’s Glider Gun”, em que a parte superior é dada como um “gerador”, a partir do qual gera células periodicamente que atravessam o reticulado até encontrarem a borda



Fonte: Wikipedia (2021).

Essa ilusão de movimento pode ser utilizada para explorar sistemas que envolvem seres vivos e populações e suas gerações com o passar das gerações, por exemplo (LIMA, 2007).

2.2.2 Classificações

Autômatos celulares são incluídos na classe geral de redes iterativas ou rede de autômatos. Os modelos padrões de autômatos celulares se distinguem de outros exemplos desta classe por sua homogeneidade e conectividade local entre as células (OLIVEIRA, 2003).

2.2.2.1 Vizinhança e contorno

A definição de vizinhança é um problema considerável para autômatos celulares definidos em reticulados de duas ou mais dimensões. Em autômatos celulares bidimensionais, os quais utilizam de apenas dois estados binários (0 e 1), admitindo como vizinhança 8 células vizinhas, temos um total de $2^8 = 256$ regras totais, que é o total de combinações possíveis para as configurações da vizinhança.

Quanto mais dimensões adicionamos e mais vizinhos consideramos para cada célula, o número de regras totais cresce exponencialmente.

Como definido por Lima (2007), o conjunto de vizinhos de uma célula c qualquer é formado pela Equação (16):

$$N(c) = \{i \in L; (c + i) \in N\} \quad (16)$$

A definição dos vizinhos de c depende do problema a ser resolvido, e pode ou não levar em consideração a própria configuração da célula c .

Vizinhanças comuns usadas são as vizinhanças de von Neumann e Moore. Shukla e Agarwal (2014) define essas vizinhanças da seguinte maneira:

- von Neumann: uma vizinhança de raio r definida pela seguinte equação:

$$N(x_0, y_0) = \{(x, y) : |x - x_0| + |y - y_0| \leq r\} \quad (17)$$

A vizinhança assume o formato de um diamante que pode ser utilizado para definir um conjunto de células, dada a célula em (x_0, y_0) , que afetará a evolução de um autômato bidimensional numa grade quadrada;

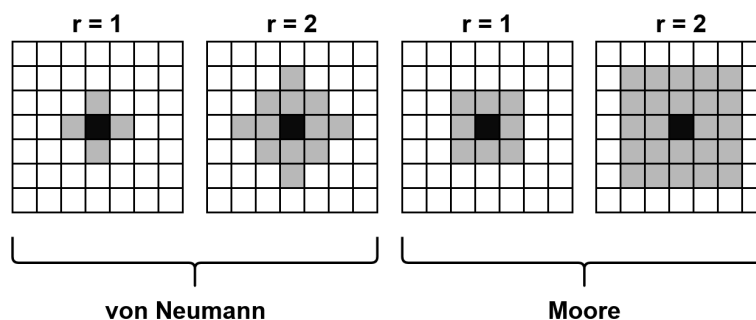
- Moore: uma vizinhança de raio r definida pela equação:

$$N(x_0, y_0) = \{(x, y) : |x - x_0| \leq r, |y - y_0| \leq r\} \quad (18)$$

Assim como a de von Neumann, a vizinhança assume o formato de um quadrado que pode ser utilizado para definir um conjunto de células, dada a célula em (x_0, y_0) , que afetará a evolução de um autômato bidimensional numa grade quadrada.

O raio define a “profundidade” da vizinhança de um dada célula, ou seja, o quanto ela consegue enxergar para suas interações locais e o número de células que podem afetá-la durante a transição de estados ao decorrer da evolução do sistema. O diagrama da Figura 10 ilustra ambas vizinhanças.

Figura 10 – Visualização das vizinhanças de von Neumann e Moore




Fonte: Shukla e Agarwal (2014).

O conceito de vizinhança também é presente no processamento de imagens, quando é necessário conhecer o conjunto de pixels vizinhos de um pixel numa coordenada (x, y) . As vizinhanças de von Neumann e Moore seriam dadas pela vizinhança 4-conectada e 8-conectada, respectivamente, quando ambos assumem $r = 1$.

Para as células que se encontram na “borda” da grade regular, é necessário definir sua vizinhança. De acordo com Lima (2007) e Leite, Lins e Cerqueira (2000), as principais condições de contorno são: periódicas, reflexivas e constantes ou fixas.

Uma **condição periódica** simula um domínio circular, como se o autômato fosse copiado nas bordas, da maneira como ele se encontra num dado instante. Não é copiado todo o autômato, mas apenas uma parte o suficiente para a vizinhança, levando em consideração o raio r .

Figura 11 – Limite periódico




Fonte: autoria própria.

A Figura 11 ilustra o limite periódico, em que C1 e C7 são células presentes nas bordas. Pela definição do limite periódico, C7 é considerado vizinho de C1 e C1 é vizinho de C7;

A condição reflexiva é obtida refletindo-se o autômato em cada limite, como um espelho;

Figura 12 – Limite reflexivo



Fonte: autoria própria.

A Figura 12 demonstra a reflexão, em que o vizinho da borda a esquerda de C1 é seu vizinho a direita, ou seja, é a célula C2. O mesmo acontece para C7.

Na condição constante, todas as células no contorno deverão assumir um determinado estado. Se temos dois estados preto e branco, ou seja, $S = \{ \text{”preto”}, \text{”branco”} \}$, com a condição de contorno constante podemos dizer que as células no contorno da grade irão sempre assumir o estado “preto”, durante o momento de determinação da vizinhança das células na borda.

Figura 13 – Limite fixo, com raio de vizinhança $r = 1$



Fonte: autoria própria.

A Figura 13 exemplifica a condição constante, em que toda célula na borda irá assumir o estado “preto”.

2.2.2.2 Estados e regras de transição

De acordo com Lima (2007) e como já definido na Subseção 2.2.1, S é um conjunto de estados que cada célula de autômato celular pode assumir, sendo este conjunto finito de qualquer tipo de dados ou informações, como cores, números, letras e entre outros. O

valor atribuído a cada célula para iniciar a simulação é o valor inicial do problema e o estado de cada célula após alguns passos será o resultado da simulação.

Como Lima (2007) define, uma configuração $C_t : L \rightarrow S$ é uma função que associa um estado a cada célula da grade. O efeito da função ou regra de transição f_{AC} muda a configuração C_t para uma configuração C_{t+1} de acordo com a seguinte expressão:

$$C_{t+1} = f_{AC}(C_t) \quad (19)$$

Também como definido por Lima (2007) e Bogo, Gramani e Kaviski (2015), uma função de transição pode ser determinística ou probabilística:

- Determinística: dada uma configuração para a vizinhança considerada, existe um único estado possível para a célula analisada. Para esse tipo, ainda podemos classificar em duas categorias:
 - Especificação direta: como definido por Weimar (2000), para todas as configurações de vizinhanças possíveis de um dado AC, é especificado um estado a qual célula irá ter na próxima geração. A Tabela 2 exemplifica uma especificação direta, atribuindo um estado de transição para algumas das vizinhanças de um autômato celular unidimensional com 3 estados (0, 1, 2).

Tabela 2 – Especificação direta

$(0,0,0) \rightarrow 0$	$(1,0,0) \rightarrow 0$	$(2,0,0) \rightarrow 2$
$(0,0,1) \rightarrow 0$	$(1,0,1) \rightarrow 0$	$(2,0,1) \rightarrow 2$
$(0,0,2) \rightarrow 2$	$(1,0,2) \rightarrow 2$	$(2,0,2) \rightarrow 2$
$(0,1,0) \rightarrow 0$	$(1,1,0) \rightarrow 0$	$(2,1,0) \rightarrow 0$
$(0,1,1) \rightarrow 0$	$(1,1,1) \rightarrow 0$	$(2,1,1) \rightarrow 0$
$(0,1,2) \rightarrow 0$	$(1,1,2) \rightarrow 0$	$(2,1,2) \rightarrow 0$
$(0,2,0) \rightarrow 1$	$(1,2,0) \rightarrow 1$	$(2,2,0) \rightarrow 1$
$(0,2,1) \rightarrow 1$	$(1,2,1) \rightarrow 1$	$(2,2,1) \rightarrow 1$
$(0,2,2) \rightarrow 1$	$(1,2,2) \rightarrow 1$	$(2,2,2) \rightarrow 1$

Fonte: Weimar (2000).

Trata-se da forma mais exaustiva e completa de se especificar diretamente a transição de uma célula num dado momento e a configuração de sua vizinhança. Também podemos ver a complexidade e impraticabilidade na especificação de um autômato com um número maior de estados.

Por exemplo, um autômato celular com o mesmo número de estados da Tabela 2, porém bidimensional, em que cada célula tem 8 vizinhos, possui $3^8 = 6561$ configurações de vizinhanças possíveis;

- Regra com múltiplas etapas: como dito por Weimar (2000), é mais conveniente

tanto para especificação quanto para a implementação de um modelo de autômato celular a divisão da regra em várias subetapas. Isso é feito apenas para praticidade, já que, teoricamente, as subetapas podem ser combinadas em uma tabela ou regra para a etapa.

Tais regras geralmente utilizam de cálculos para determinar o próximo estado da célula central, levando em consideração condições, como por exemplo, os valores máximo e mínimo de sua vizinhança, a média dos valores das células vizinhas, o número total de estados presentes na vizinhança e entre outros.

- Probabilística: as regras são definidas pela probabilidade de ocorrência. Ao definir as regras para a vizinhança, existe um conjunto de possibilidades de estados para a célula, os quais são escolhidos com base nessas probabilidades. Devemos lembrar que as probabilidades devem resultar num total de 1, já que um estado deve ser definido para a célula.

Também há o conceito de AC totalístico e não-totalístico, os quais definem os critérios nos quais as regras do AC serão baseadas:

- Totalístico: a regra é baseada no total de células que assumem um determinado estado em sua vizinhança. Como exemplo, o *Game of Life* utiliza de regras totalísticas, determinadas como:
 - Qualquer célula com menos que dois vizinhos passam para o estado morta;
 - Qualquer célula com dois ou três vizinhos continuam “vivas” para a próxima geração;
 - Qualquer célula com três ou mais vizinhos morrem;
 - Qualquer célula com o estado “morta” passam para a próxima geração com o estado viva.
- Não-totalístico: a configuração da vizinhança, ou seja, a posição das células vizinhas assim como seus estados determinam o resultado da célula central na próxima geração.

A definição das regras e da configuração inicial de um autômato celular depende de sua aplicação e do resultado desejado.

Além da definição de regras, a implementação de um autômato celular pode ser feita de duas maneiras:

- Autômato celular uniforme: as células possuem a mesma função de transição de estado. Trata-se da implementação tradicional de um sistema de autômatos celulares;

- Autômato celular não-uniforme: em que cada célula tem uma possível função de transição de estado diferente.

2.3 Integração de autômatos celulares no processamento de imagens

A integração de ambos campos de pesquisa, autômatos celulares e processamento de imagens, é recente e mostra grande potencial em relação a sua aplicação. O principal método de aplicação de autômatos celulares na área é por meio do tratamento da imagem de entrada como o reticulado inicial do autômato celular, e a definição do comportamento do autômato é dado por meio da modificação de suas regras, de acordo com a função de processamento de que será realizada pelo autômato celular.

Devido a semelhança entre os conceitos de vizinhança presente em ambas áreas, a integração de processos de filtragem é uma das áreas mais estudadas.

No trabalho de Popovici e Popovici (2002), demonstra-se bem como é realizado o processo de implementação de um autômato celular para o processamento de imagens na redução de ruídos. No estudo, define-se uma imagem digital como uma matriz bidimensional de $n \times n$ *pixels*. Cada *pixel* pode ser caracterizado por um trio (i, j, k) onde (i, j) representa a posição na matriz e k é associado a cor ou intensidade do pixel, ou seja, o seu estado, como demonstrado na Tabela 1 da Subsubseção 2.2.1.1.

A imagem pode ser considerada como uma configuração particular de estados de um autômato celular que tem um reticulado $n \times n$ definido pela imagem. Cada célula, neste caso, corresponde a um *pixel*.

Ainda no trabalho de Popovici e Popovici (2002), é proposta uma regra dinâmica para a solução do problema de redução de ruídos. A partir de um reticulado determinado por uma imagem com ruído, a regra deve produzir uma trajetória em que a configuração final do reticulado deve levar a uma imagem com ruído reduzido. Essa regra leva em consideração imagens quaisquer, sem distinção de seu perfil cromático, ou seja, pode ser uma imagem monocromática, em escala de cinza ou com cores.

O modelo é baseado num autômato celular bidimensional simétrico não-determinístico da forma (S, N, δ) em que $S = \{\#, 0, 1, \dots, k-1\}$. A cor do *pixel* é representada por um estado $\{0, 1, \dots, k-1\}$, $\#$ é estado inativo das células fora da grade, N é a vizinhança de von Neumann, e δ é a regra de transição baseada num critério de comparação do estado da célula central com aqueles em sua vizinhança. Assim, a regra $\delta : S^5 \rightarrow S$ é definida como:

$$\delta((s_i)_{s_i=1}^5) = \begin{cases} j(\neq \#), & \text{se } s_3 \neq \# \text{ e } |\{i | s_i = j\}| = \max_{l=0}^{k-1} |\{s_i = l\}| \\ \#, & \text{se } s_3 = \# \end{cases} \quad (20)$$

Uma célula que não está no estado inativo $\#$ muda seu estado para o estado da maioria das células em sua vizinhança. Neste caso, células inativas são aquelas que estão

fora do reticulado, para tratar das vizinhanças de células na borda e regra é definida de forma para que essas células continuem com esse estado inativo #.

Trabalhos da área também envolvem a comparação de métodos clássicos, como filtragem gaussiana, com a aplicação de autômatos no processamento direcionado a filtragem de ruídos e detecção de bordas Alves (2015), com a finalidade de analisar a performance da aplicação do sistema de autômatos no meio.

2.3.1 Tipos de imagens

Em grande parte dos trabalhos disponíveis na literatura, o conjunto de imagens costuma ser de origem fotográfica, procurando um foco maior na representação do objeto alvo, por meio da captura de uma imagem com boa composição e ângulo.

Podemos entender como imagens em que o objetivo é a análise da mesma, e para isso procura-se capturar a maior quantidade de informação possível, a fim de compreender amplamente as necessidades da análise.

Exemplos de imagens utilizadas para análise são imagens de satélite e de origem médica, como imagens obtidas por radiografia ou tomografia.

Imagens de satélite caracterizam-se pelo ângulo e composição de suas capturas. Devido a grande altura em que são capturadas, as imagens conseguem compreender vastas regiões com grande densidade de informação. Tais imagens são especialmente úteis para análise em campos como cartografia, planejamento urbano, agricultura, arquitetura paisagista e geologia.

Em relação a imagens médicas, os métodos mais comuns de captura das mesmas são:

- Radiografia: projeção de raios X sobre um objeto, os quais são em partes absorvidos pelo objeto e aqueles que o atravessam são capturados por um detector;
- Tomografia: semelhante a radiografia, porém gera imagens “em fatias” do objeto analisado;
- Ressonância magnética: distingue-se da tomografia por meio da utilização de campos magnéticos fortes para gerar imagens de órgãos de um corpo;

Todas as técnicas mencionadas acima tem como propósito o diagnóstico de pacientes por meio da análise das imagens geradas.

A Figura 14 demonstra os tipos de imagens utilizadas por este trabalho.

Figura 14 – Exemplos demonstrando tipos de imagens



(a) Imagem Fotográfica Normal



(b) Imagem de Radiografia



(c) Imagem Fotográfica de Satélite

Fonte: autoria própria.

2.3.2 Profundidade de cores

Em princípio, é comum o uso de imagens binárias na integração de ACs para realizar PI. Pode-se entender imagens binárias como aquelas em que seus pixels apresentam apenas duas cores: preto e branco, afim de representar os estados das células do AC, indicando se ela está viva ou morta, como na representação utilizada pelo *Game of Life*. A utilização de imagens binárias é para a simplificação da implementação do AC e para redução da complexidade da escolha de regras que podem ser aplicadas no sistema, pela redução do número de configurações de vizinhanças possíveis.

Trabalhar com imagens binárias significa facilitar a interpretação e processamento do autômato na imagem, já que os pixels podem ser tratados diretamente como as células

do autômato, as quais representam apenas dois estados (preto e branco; vivo e morto).

Mesmo assim, a utilização de imagens binárias ainda permite existir $2^{2(4*(2-1)+1)} = 2^{10} = 1024$ regras a serem escolhidas, como demonstrado na Subsubseção 2.2.1.1, quando consideramos um total de 5 células na vizinhança. Assim, alguns métodos surgiram para reduzir esse número de regras possíveis, entre os quais podemos citar o treinamento de autômatos celulares para o processamento de imagens, como demonstrado por Rosin (2005), utilizando de métodos evolutivos com algoritmos genéticos para a escolha de um conjunto de regras ótimas para a operação desejada.

Em geral, para escolha de regras, são considerados o número de configurações que podem existir em uma dada vizinhança, permitindo invariância para certa transformação. Esses padrões correspondem as regras possíveis e esquemas são utilizados para aprender de forma automática um conjunto de regras possíveis a partir de dados de treinamento, como por algoritmos genéticos ou algoritmos gulosos (ROSIN; SUN, 2011).

Para imagens não-binárias, como no caso de imagens em escala cinza, o número de regras possíveis, as quais levam em consideração a criação de uma tabela de definição de configurações que levam a um determinado estado, cresce consideravelmente devido a adição de um outra “dimensão”, na forma de cores ou estados possíveis a serem interpretados. Porém, para o ser humano, a interpretação de imagens não-binárias é muito mais fácil e o processamento dessas é mais atrativo e útil. Uma possível implementação é por meio do uso de transformações de *thresholding* dos níveis de cinza de uma imagem. Nisso, a imagem é dividida num conjunto de imagens binárias em que pode ser aplicada uma transformação de *thresholding* para cada nível de cinza. O tratamento da imagem é feito a partir desse conjunto obtido e para obter o resultado, basta a combinação do conjunto tratado (ROSIN, 2005).

A Figura 15 exemplifica o processo de *thresholding* em três níveis diferentes.

Figura 15 – Exemplo de decomposição de uma imagem em limiares diferentes



(a) Imagem Original



(b) Limiar 100



(c) Limiar 125



(d) Limiar 150

Fonte: autoria própria.

Outra abordagem possível também envolve *thresholding* de valores de pixel, porém, apenas localmente no momento de avaliação da vizinhança de uma dada célula. Assim, cada célula do AC pode levar 255 valores, no caso de uma imagem em escala de cinza, porém, as vizinhanças de uma célula central v_c , são:

$$v'_c = \begin{cases} 0 & \text{se } v_i < v_c \\ 1 & \text{se } v_i = v_c \\ 2 & \text{se } v_i > v_c \end{cases} \quad (21)$$

Assim, podemos ter um AC com configurações de vizinhança representadas por três estados, reduzindo consideravelmente o número de configurações possíveis para uma imagem em escala de cinza.

Ambas abordagens citadas acima são utilizadas com sucesso para realizar a filtragem de tipos diferentes de ruído por meio do treinamento do sistema para o melhor conjunto de regras possível que realiza a melhor filtragem (ROSIN; SUN, 2011).

Abordagens que não envolvem treinamento para um conjunto ótimo de regras para realizar a filtragem são por meio da implementação de uma regra dinâmica, ou seja, que faz a análise dos valores da vizinhança por meio de condições para determinar o próximo estado da célula central, como já mencionado na Subsubseção 2.2.2.2.

Em teoria, como Weimar (2000) explica, é possível montar uma tabela de especificação direta a partir da regra dinâmica ou uma regra para cada subetapa da regra dinâmica.

Exemplo de AC com regras dinâmicas para realizar filtragem são demonstrado por Liu, Chen e Yang (2008) e Dalhoum, Al-Dhamari e Alfonseca (2011), o qual implementa uma versão melhorada do primeiro método citado, porém especificando o tipo de ruído, sendo que o de Liu, Chen e Yang (2008) é generalizado.

Em termos simplificados, os métodos propostos realizam a filtragem obtendo os valores de intensidade máximos e mínimos de um dado pixel. Se a intensidade do valor do pixel estiver entre uma gama de valores, o pixel não é processado, caso contrário ele é.

3 TRABALHO PROPOSTO

O presente trabalho foi realizado por meio da utilização de informações disponíveis em artigos, livros, teses e demais textos acadêmicos, os quais se relacionam ao tema do trabalho, tanto quanto de origem nacional e internacional.

3.1 Escolha do conjunto de imagens

Foram escolhidos dois conjuntos de imagens para serem filtradas, os quais se diferenciam na origem de captura, assim, temos um conjunto de imagens médicas, obtidas por operações de escaneamento do corpo do ser humano, em específico: tomografia, radiografia e ressonância magnética; e um conjunto de imagens obtidas por sensoriamento remoto, capturadas por satélites e aeroplanos.

Ambas imagens médicas e de sensoriamento remoto foram encontradas na internet, disponibilizadas em repositórios e conjuntos de dados públicos.

Os conjuntos utilizados por esse trabalho foram:

- “The Cancer Imaging Archive”: serviço de hospedagem de um grande número de conjunto de dados e coleções de imagens médicas para acesso público. Apesar do nome, o serviço não se restringe apenas a imagens de pacientes com câncer, tendo um grande número de coleções categorizadas (TCIA, 2021);
- “LandCover.ai”: conjunto de dados de imagens fotográficas aéreas de alta qualidade, com imagens em que classifica como: construções, bosques, água e ruas (BOGUSZEWSKI et al., 2021);
- “DOTA”: semelhante ao LandCover.ai, disponibiliza um conjunto de dados de imagens fotográficas aéreas (DING et al., 2021).

3.2 Autômatos celulares em filtragem de imagens

Quanto a integração de ambas áreas de autômatos celulares e processamento de imagens, o estudo de Popovici e Popovici (2002) demonstra a sua utilização na filtragem de ruídos e como o autômato celular é modelado para a tarefa de filtragem. No seu estudo, é demonstrada uma regra de autômato celular condicional, em que a célula central muda para o estado da maioria dos seus vizinhos. A regra referenciada é demonstrada na Seção 2.3.

Estudos como Dalhoum, Al-Dhamari e Alfonseca (2011) e Liu, Chen e Yang (2008) ambos implementam modelos que realizam filtragem com autômatos celulares em imagens em escala de cinza (255 estados possíveis para cada célula) utilizando regras dinâmicas, as quais são referenciadas na Subsubseção 2.2.2.2. Ambos demonstram que a capacidade

do autômato celular na filtragem de imagens é tão boa ou melhor que o processamento realizado por filtros clássicos, utilizando como métricas o cálculo RMSE (“root mean square error”, do inglês, raiz do erro quadrático médio) e SSIM (“structural similarity index measure”, do inglês, medida do índice de semelhança estrutural).

3.3 Regra do autômato

Foram utilizadas duas abordagens de modelos de autômato celular para realizar filtragem das imagens.

Uma das implementações é baseada no modelo de Liu, Chen e Yang (2008). A proposta inicial era de implementar uma regra eficiente para a filtragem de imagens com ruído sal e pimenta. Tal regra pode ser descrita da seguinte maneira:

1. Dados os valores máximo N_{max} e mínimo N_{min} dos estados das células na vizinhança de Moore da célula $C_{i,j}^t$ em tempo t na posição (i,j) do reticulado: caso tal célula satisfaça as condições $N_{min} < C_t < N_{max}$, então $C_{i,j}^{t+1} = C_{i,j}^t$, ou seja, na próxima geração o valor da célula permanecerá o mesmo.

Caso contrário, proceda para o passo 2;

2. Se $N_{max} = N_{min}$ ou os valores da vizinhança são constituídos por apenas 2 estados N_{max} e N_{min} , proceda para o passo 2.a, caso contrário proceda para o passo 3;
 - a) Se $N_{min} \neq 0$, então $C_{i,j}^{t+1} = N_{min}$; se $N_{max} \neq 255$, então $C_{i,j}^{t+1} = N_{max}$; senão $C_{i,j}^{t+1} = C_{i,j}^t$;
3. Dada a vizinhança de Moore da célula central, retire os valores máximos N_{max} e mínimos N_{min} e calcule a média N_{med} em cima dessa nova vizinhança.

Se $|C_{i,j}^t - N_{med}| < T$, dada uma constante T como limiar, então $C_{i,j}^{t+1} = C_{i,j}^t$. Caso contrário $C_{i,j}^{t+1} = N_{med}$.

A regra procura eliminar valores que podem ser considerados ruído, neste caso, são os valores extremos 0 e 255, por meio da eliminação desses valores e retornando a média da vizinhança alterada.

O Valor T é uma constante arbitrária atribuída para ajustar o momento em que não é necessário modificar o valor da célula central após obter a média da vizinhança, caso a diferença entre a média e a célula não sejam tão grandes quanto T define.

Outra implementação é baseado em parte no modelo de Dalhoum, Al-Dhamari e Alfonseca (2011). Esse modelo procurou melhorar a regra implementada por Liu, Chen e Yang (2008). Tal regra também é semelhante a anterior, constituída a partir do passo 2:

1. Se $N_{max} = N_{min}$ ou os valores da vizinhança são constituídos por apenas 2 estados N_{max} e N_{min} , proceda para o passo 1.a, caso contrário proceda para o passo 2;
 - a) Se $N_{min} \neq 0$, então $C_{i,j}^{t+1} = N_{min}$; se $N_{max} \neq 255$, então $C_{i,j}^{t+1} = N_{max}$; senão $C_{i,j}^{t+1} = C_{i,j}^t$;
2. Dada a vizinhança de Moore da célula central, retire os valores máximos N_{max} e mínimos N_{min} e calcule a mediana $N_{mediana}$ em cima dessa nova vizinhança.

O novo valor atribuído a célula será $N_{mediana}$.

Ambos ACs levam em consideração uma vizinhança com raio $r = 1$.

Neste trabalho, o primeiro modelo será referenciado como autômato celular de regra média ou AC-média e o segundo como autômato celular de regra mediana ou AC-mediana, já que possuem condições para retornar valores da média ou mediana de uma dada vizinhança, respectivamente.

4 EXPERIMENTO E RESULTADOS

A implementação do autômato celular foi feita por meio da linguagem *Python*, adaptando um modelo existente, por Faustener (2021), para possibilitar o uso de imagens como o reticulado inicial do autômato celular. A aplicação dos filtros, métodos de avaliação, processamento e comparação entre imagens foram realizadas utilizando as bibliotecas citadas no Capítulo 3. O código fonte do projeto está disponibilizado em um repositório *git*, na plataforma Github (FONSECA, 2021).

A fim de analisar a eficiência de uma filtragem, a imagem filtrada foi comparada com a sua imagem original sem ruído, a fim de obter uma métrica que indicará a semelhança da imagem filtrada com a original. As métricas utilizadas para calcular a eficiência das filtrações foram o RMSE (“root mean square error”, do inglês, raiz do erro quadrático médio) e o SSIM (“structural similarity index measure”, do inglês, medida do índice de semelhança estrutural). Ambas serviram propósitos diferentes, e a partir delas foi possível ter uma visão geral da eficiência da filtragem por meio de suas métricas.

Por meio da linguagem *Python*, foram utilizadas bibliotecas para implementar o modelo do autômato celular, assim como para conduzir o experimento em si:

- *OpenCV*: manipulação de imagens;
- *SciPy*: implementações de métodos de processamento de imagens, como filtros e transformações;
- *scikit-image*: métricas de indicação de semelhança entre imagens e implementação de filtros;

Após obter as imagens filtradas, tanto pelo autômato celular quanto pelos filtros clássicos, os resultados foram tabulados para permitir uma visão clara dos resultados obtidos.

A fim de obter uma variedade de resultados e comparações, os resultados foram alcançados seguindo as seguintes etapas:

1. Introdução de ruído gaussiano com intensidade $\sigma = 0,5$ e $\sigma = 0,9$ nas imagens, com σ referindo-se a intensidade do ruído gaussiano. Assim, teremos dois conjuntos: um com imagens com ruído de intensidade 0,5 e um com ruído de intensidade 0,9;
2. Introdução de ruído sal e pimenta com intensidade $p = 0,05$, $p = 0,25$ e $p = 0,5$ nas imagens, com p indicando o percentual da imagem que será corrompido com o ruído. Assim, temos três conjuntos: um com imagens com 5% de ruído, um com 25% e outro com 50%;
3. Realizar a filtragem pelo autômato celular e pelos métodos clássicos filtragem mediana e gaussiano, variando o número de gerações do AC assim como o *sigma* e raio do

filtro gaussiano e mediana, respectivamente;

4. Comparar cada resultado com as métricas RMSE e SSMI para obter a eficiência do método na filtragem em cada tipo de ruído e intensidade de ruído.

Com as diferentes variações de ruídos foi possível analisar a eficiência dos métodos nessas diferentes intensidades.

Também foi utilizada a linguagem R para auxiliar na análise dos resultados obtidos e na geração dos gráficos para a facilitar visualização dos mesmos dentro do trabalho.

Foram utilizados dois conjuntos de imagens: imagens médicas e imagens de sensoriamento remoto, sendo que o primeiro conjunto será dividido em alguns subconjuntos, classificando o tipo de imagens médica e o de imagens de sensoriamento remoto são classificadas de acordo com o cenário capturado, mais especificamente, temos:

- Imagens médicas:
 - Obtida por ressonância magnética: imagem de seção da análise de um cérebro;
 - Obtida por tomografia: seção de uma imagem de análise do plano coronal do peito do ser humano, e uma seção de uma imagem de análise da transversal do tórax;
 - Obtida por radiografia: uma imagem do tórax e uma imagem de uma mão;
- Imagens de sensoriamento remoto:
 - Capturando uma área menor de um ambiente urbano com natureza: 3 imagens;
 - Capturando uma área maior de um ambiente com predominância de natureza: 3 imagens;
 - Capturando uma área maior de um ambiente com predominância urbana: 3 imagens;

No total, foram escolhidas 5 imagens médicas e 9 de sensoriamento remoto. O número de imagens escolhido baseado procurando variar os tipos de imagens a serem analisadas, sendo que o tipo refere-se a natureza de sua captura.

Para imagens de sensoriamento remoto, foram escolhidas 3 imagens de cada tipo, com cada uma capturando um local diferente, enquanto para imagens médicas, foi observado uma predominância de imagens de ressonância magnética para análise do cérebro e do crânio, assim, foi obtida apenas uma imagem. Para as demais, observou-se maior variação em relação aos membros e órgãos capturados, assim, foram escolhidas duas imagens variando a parte do corpo capturada.

Neste experimento, as imagens em escala de cinza em si são tratadas como o reticulado inicial do autômato celular, utilizando de uma regra dinâmica para tratar da

filtragem do ruído presente na imagem. Em ambos conjuntos, foram introduzidos os ruídos para serem tratados: ruído gaussiano e ruído sal e pimenta.

Com a introdução do ruído, foi possível aplicar o autômato celular em ambos conjuntos de imagens e obter o resultado da eficiência por meio das métricas de critério de qualidade RMSE e SSIM. Também foi aplicado a filtragem por meio de métodos clássicos filtro gaussiano e filtro da mediana, para comparar suas filtrações com o resultado obtido pela evolução do autômato celular.

4.1 Processo de escolha de imagens

Como critério de escolha das imagens médicas, foram selecionadas manualmente procurando seções de imagens de partes diferentes do corpo humano, assim como variando o sensor utilizado para obter a imagem, ficando entre ressonância magnética, tomografia e radiografia.

Todas as imagens médicas escolhidas foram disponibilizadas por meio do formato DICOM, o qual permite agrupar um conjunto de seções da parte capturada pelo sensor e navegar por essas seções de maneira fácil, assim como permite armazenar metadados do método de captura (DICOM, 2021).

Para essas imagens, as seções foram escolhidas de forma arbitrária e manualmente, procurando as seções da parte com maior predominância de detalhes, em que geralmente se tratava das seções do meio. Foi utilizado o software RadiAnt para navegar o conteúdo de cada arquivo DICOM (MEDIXANT, 2021).

Ambas imagens de satélite e médicas foram selecionadas manualmente, procurando variar as imagens para analisar. Assim, para as imagens de satélite, procurou-se escolher: imagens capturando uma área menor, porém com áreas urbanas (ruas, casas, prédios, construções etc) e de natureza (árvores, vegetação etc) misturadas; imagens capturando uma área maior, com predominância de natureza; imagens capturando uma área maior, com predominância urbana. As imagens escolhidas foram capturadas com a mesma perspectiva, em que o ângulo da visão do sensor de captura é de cima para baixo, ou seja, completamente paralelo com o terreno capturado.

As imagens escolhidas foram pré-processadas, passando-os para a escala de cinza e minimizando o tamanho para no máximo 1000x1000 pixels de área da imagem.

4.2 Processo de escolha dos ruídos

Para realizar a análise da eficiência da filtragem de imagens tanto por métodos clássicos quanto pelo autômato celular, foram utilizadas duas formas de ruído: gaussiano e de sal e pimenta.

Como mencionado na Subseção 2.1.4, o ruído gaussiano introduz ruído baseado no sinal da própria imagem, distorcendo-a. Assim, numa imagem em escala de cinza,

haverá regiões que terão pixels com valores de cinza maiores ou menores do que na imagem original.

O ruído sal e pimenta é mais simplístico: ele simplesmente introduz ruído na forma da modificação aleatória de pixels para valores de 255 (branco) ou 0 (preto) numa imagem, dando a impressão que foi espalhado uma camada de partículas de sal e pimenta na mesma.

Os ruídos se diferenciam na gama de valores que distorcem: o gaussiano distorce baseado no sinal, podendo introduzir valores entre 0 a 255, enquanto o ruído sal e pimenta apenas distorce introduzindo valores 255 ou 0.

Como explicado anteriormente, a faixa de ruído escolhido foram as seguintes: ruído gaussiano com $\sigma = 0,5$ e $\sigma = 0,9$. Com o primeiro introduzindo ruído menos severo, enquanto o segundo já corrompe a imagem dando maior variação nos valores dos pixels da imagem; e ruído sal e pimenta com intensidade de porcentagem $p = 0,05$, $p = 0,25$ e $p = 0,50$, correspondendo que cerca de 5%, 25% e 50% dos pixels da imagem, respectivamente, foram corrompidos com a introdução de um pixel de ruído sal (branco, com valor de intensidade 255) ou pimenta (preto, com intensidade 0). A possibilidade de introdução do pixel de ruído é de 50% para sal e 50% para o de pimenta, também podendo ser chamado de ruído de impulso bipolar (GONZALES; WOODS, 2008).

4.3 Resultados

Podemos ver as comparações de acordo com os resultados disponíveis na tabela da Figura 16 e da Figura 17. Nela, os valores possuem duas seções: o valor melhor, o qual indica o melhor resultado obtido pela filtragem, e a variável, que indica a geração, raio ou σ para obter tal resultado, para as filtragens dos ACs, filtro da mediana e filtro gaussiano, respectivamente. As colunas de valores representam imagens, as quais os valores das métricas são coloridos indicando o melhor resultado obtido para aquela imagem, com valores melhores marcados por uma cor mais intensa.

Figura 16 – Tabela dos resultados com a métrica SSIM

Filtro	Ruído	Intensidade	Resultados	Imagens Médicas					Imagens de Sensoriamento Remoto										
				chest_ct	chest_xray	hand_xray	head_mr	thorax_ct	mixed_close_1	mixed_close_2	mixed_close_3	nature_farther_1	nature_farther_2	nature_farther_3	urban_farther_normal_1	urban_farther_normal_2	urban_farther_normal_3		
Filtro Gaussiano	Sal e pimenta	5%	Melhor	0,4703	0,8077	0,816	0,6959	0,5007	0,6615	0,6068	0,6387	0,6247	0,5253	0,5163	0,537	0,6194	0,6316		
			σ	1	3	4	2	1	2	1	1	1	1	1	1	1	1		
		25%	Melhor	0,2549	0,7098	0,4832	0,4207	0,2732	0,5069	0,3959	0,3941	0,4082	0,2982	0,3415	0,3269	0,3631	0,3753		
	σ	2	5	6	3	2	4	2	2	2	2	3	2	1	1				
	Gaussiano	50%	Melhor	0,1737	0,5898	0,3153	0,2583	0,1794	0,4091	0,2765	0,2569	0,2617	0,1889	0,2252	0,211	0,2359	0,2438		
			σ	2	6	9	3	2	6	4	2	2	3	3	2	2	2		
$\sigma = 0,5$		Melhor	0,3536	0,7711	0,6929	0,6522	0,3988	0,6173	0,5525	0,5797	0,5718	0,4514	0,4846	0,4842	0,5757	0,5963			
σ	1	4	4	2	1	2	2	1	1	1	2	1	1	1					
$\sigma = 0,9$	Melhor	0,251	0,6851	0,4468	0,4021	0,2673	0,4781	0,4022	0,3755	0,3986	0,2975	0,3396	0,3113	0,366	0,3667				
σ	2	6	6	3	2	5	3	2	2	3	2	2	2	2					
Filtro da Mediana	Sal e pimenta	5%	Melhor	0,9497	0,9715	0,9841	0,9681	0,8993	0,8901	0,8239	0,8446	0,8653	0,8215	0,8462	0,7424	0,8373	0,8282		
			Raio	3	3	3	3	3	3	3	3	3	3	3	3	3	3		
		25%	Melhor	0,8768	0,9497	0,9691	0,9006	0,7895	0,7918	0,7158	0,7349	0,7544	0,7262	0,7417	0,657	0,7271	0,7216		
			Raio	5	5	5	5	5	4	3	3	3	4	4	3	3	3		
		50%	Melhor	0,7728	0,9129	0,9454	0,8232	0,6852	0,6996	0,6016	0,5573	0,6387	0,6198	0,6545	0,5586	0,5726	0,5533		
			Raio	7	7	7	7	7	6	6	5	7	6	7	6	5	5		
	Gaussiano	$\sigma = 0,5$	Melhor	0,4869	0,7221	0,7822	0,6148	0,4564	0,5529	0,4885	0,4804	0,5086	0,3974	0,4007	0,4262	0,4908	0,5053		
			Raio	7	10	10	7	7	8	5	5	5	7	6	3	3			
		$\sigma = 0,9$	Melhor	0,3421	0,4642	0,5339	0,4251	0,3335	0,385	0,347	0,3245	0,347	0,259	0,3125	0,3165	0,3268	0,3098		
			Raio	9	10	10	10	9	10	10	10	8	9	10	9	7	7		
		AC-mediana	Sal e pimenta	5%	Melhor	0,7736	0,9514	0,9775	0,9527	0,7462	0,8539	0,7769	0,7871	0,8187	0,7892	0,8006	0,7224	0,7812	0,7667
					Geração	2	2	2	1	2	2	2	1	2	2	1	2	1	1
25%	Melhor			0,6583	0,9283	0,9676	0,9207	0,6364	0,8365	0,7621	0,7506	0,7999	0,7753	0,7845	0,7109	0,7539	0,7406		
	Geração		4	3	3	2	4	2	2	2	2	2	2	2	2	2			
Gaussiano	50%		Melhor	0,5157	0,8972	0,9538	0,8712	0,5126	0,7685	0,6798	0,6603	0,7232	0,6952	0,7154	0,6307	0,6655	0,6468		
			Geração	10	6	7	4	10	4	3	3	3	3	4	3	3	3		
	$\sigma = 0,5$	Melhor	0,3569	0,7513	0,7181	0,6711	0,386	0,6343	0,5679	0,551	0,6174	0,5685	0,5987	0,5299	0,5733	0,5616			
Geração	4	10	10	9	4	10	6	4	4	6	9	6	4	2					
$\sigma = 0,9$	Melhor	0,259	0,52	0,411	0,4839	0,277	0,4668	0,4229	0,4006	0,4606	0,4265	0,4509	0,4039	0,4131	0,3858				
Geração	8	10	10	10	10	10	10	10	10	10	10	10	10	10					
AC-média	Sal e pimenta	5%	Melhor	0,8837	0,9598	0,9476	0,9618	0,8786	0,8987	0,87	0,8878	0,9102	0,8966	0,9114	0,848	0,8893	0,8758		
			Geração	9	5	5	4	6	2	2	2	2	2	3	2	2	2		
		25%	Melhor	0,5933	0,8506	0,8395	0,8734	0,632	0,7907	0,7556	0,774	0,83	0,7989	0,8218	0,7416	0,7888	0,7725		
			Geração	10	10	10	10	10	9	7	10	10	9	10	10	6	5		
		50%	Melhor	0,3032	0,5079	0,4715	0,5758	0,3517	0,5362	0,5154	0,5317	0,5966	0,5377	0,5557	0,5062	0,5744	0,5662		
			Geração	10	10	10	10	10	10	10	10	10	10	10	10	10	10		
	Gaussiano	$\sigma = 0,5$	Melhor	0,3158	0,3619	0,3394	0,4571	0,3361	0,4526	0,4509	0,4634	0,5041	0,4222	0,4163	0,4108	0,49	0,4886		
			Geração	7	9	9	8	6	7	6	6	9	8	9	9	7	7		
		$\sigma = 0,9$	Melhor	0,211	0,1972	0,1525	0,2855	0,2192	0,2859	0,2902	0,2925	0,3208	0,252	0,244	0,2567	0,3206	0,3156		
			Geração	10	10	10	10	10	10	10	10	10	10	10	10	10	10		

Fonte: autoria própria.

Figura 17 – Tabela dos resultados com a métrica RMSE

Filtro	Ruído	Inten- sidade	Resul- tados	Imagens Médicas					Imagens de Sensoriamento Remoto								
				chest_ct	chest_xray	hand_xray	head_mr	thorax_ct	mixed_close_1	mixed_close_2	mixed_close_3	nature_farther_1	nature_farther_2	nature_farther_3	urban_farther_normal_1	urban_farther_normal_2	urban_farther_normal_3
Filtro Gaussiano	Sal e pimenta	5%	Melhor σ	247,41	28,22	28,25	183,34	236,37	336,32	436,70	419,70	172,43	144,94	99,85	224,01	336,23	352,72
		25%	Melhor σ	1015,00	301,31	712,20	770,61	899,29	506,93	605,02	638,35	393,89	261,59	184,85	329,93	410,86	406,83
		50%	Melhor σ	3150,45	1049,50	2689,55	2449,24	2737,80	1049,81	1207,94	1373,71	928,89	540,69	320,07	561,25	627,43	594,15
	Gaussiano	$\sigma = 0,5$	Melhor σ	232,82	63,60	133,42	183,26	226,08	227,64	265,53	247,19	160,64	135,10	105,94	193,68	224,09	231,45
		$\sigma = 0,9$	Melhor σ	981,08	377,63	928,22	926,09	911,01	492,39	567,91	605,04	381,88	242,98	183,34	313,61	407,00	411,66
		$\sigma = 0,9$	Melhor σ	2	5	4	2	2	2	2	2	2	4	4	3	2	2
Filtro da Mediana	Sal e pimenta	5%	Melhor Raio	25,80	5,06	2,11	13,93	36,41	100,89	146,78	110,57	46,86	51,37	36,74	85,61	100,44	114,87
		25%	Melhor Raio	107,80	15,55	9,25	62,66	117,25	210,75	293,51	269,72	100,76	96,90	66,70	156,45	216,15	235,49
		50%	Melhor Raio	247,41	28,22	28,25	183,34	236,37	336,32	436,70	419,70	172,43	144,94	99,85	224,01	336,23	352,72
	Gaussiano	$\sigma = 0,5$	Melhor Raio	141,41	56,41	49,14	164,99	174,90	297,40	362,28	347,50	192,03	172,03	130,99	237,02	296,33	312,79
		$\sigma = 0,9$	Melhor Raio	356,18	196,08	153,06	404,16	363,63	526,47	614,10	601,20	360,20	299,57	258,79	374,72	506,95	518,40
		$\sigma = 0,9$	Melhor Raio	7	10	10	9	9	10	9	9	10	10	10	10	9	10
AC-mediana	Sal e pimenta	5%	Melhor Geração	117,16	11,47	11,58	42,91	90,76	136,47	197,37	158,83	68,25	69,67	50,85	113,86	143,07	160,68
		25%	Melhor Geração	225,62	38,07	42,31	159,83	186,26	173,13	236,63	215,35	96,75	91,90	70,92	137,29	179,18	192,98
		50%	Melhor Geração	464,51	76,01	85,21	324,07	354,98	264,50	345,32	324,34	156,85	142,11	108,90	202,16	270,71	285,91
	Gaussiano	$\sigma = 0,5$	Melhor Geração	214,77	64,17	96,40	171,33	210,79	260,48	317,19	300,09	166,16	153,39	119,53	206,00	265,41	278,35
		$\sigma = 0,9$	Melhor Geração	695,34	329,97	574,12	687,12	652,81	514,05	592,56	588,31	386,71	308,45	264,03	367,97	468,69	483,86
		$\sigma = 0,9$	Melhor Geração	7	10	10	10	10	10	9	10	10	10	10	10	10	10
AC-média	Sal e pimenta	5%	Melhor Geração	54,61	10,24	11,13	30,37	54,23	87,15	126,29	97,37	39,57	41,04	28,87	69,87	84,48	98,00
		25%	Melhor Geração	254,56	55,33	54,97	169,06	224,77	168,14	229,27	203,90	90,59	89,92	68,68	133,39	167,96	181,87
		50%	Melhor Geração	1511,44	305,33	297,01	542,37	1174,22	367,70	446,84	441,97	275,49	245,54	202,70	293,89	351,91	364,36
	Gaussiano	$\sigma = 0,5$	Melhor Geração	263,91	190,07	204,88	280,07	277,84	330,70	384,53	360,69	251,45	237,09	216,89	278,00	331,98	340,83
		$\sigma = 0,9$	Melhor Geração	943,62	686,19	994,14	1044,91	927,63	729,02	777,18	791,23	636,12	567,64	547,07	605,33	670,45	680,93
		$\sigma = 0,9$	Melhor Geração	10	10	10	10	10	10	10	10	10	10	10	10	10	10

Fonte: autoria própria.

Além das tabelas anteriores da Figura 17 e Figura 16, no total, foram obtidas 40 gráficos, 20 de análise com a métrica SSIM e 20 com RMSE. Os gráficos podem ser observados no apêndice deste artigo. Nos gráficos, cada valor do eixo x representa uma imagem e o eixo y representa o valor da métrica de semelhança.

Para a métrica RMSE, valores de erro menores indicam maior semelhança da imagem filtrada com a imagem original (sem ruído algum). O contrário é válido para a métrica SSIM, sendo que suas medidas estão entre 0 e 1.

Cada valor do eixo x é representado por um conjunto de 10 colunas. Para as imagens filtradas pelos modelos de autômato celular, cada coluna representa um número de gerações utilizado pelo AC para obter a métrica. Para os filtros da mediana e gaussiano, as colunas representam valores de tamanho (raio) e σ , respectivamente. Tais colunas estão organizadas de forma crescente, com a primeira coluna indicando valor 1 e a última indicando valor 10. Foi utilizado a mesma série de valores de 1 a 10 para representar as gerações do AC assim como os valores de tamanho e σ dos filtros clássicos.


Em relação as imagens representadas por cada valor do eixo x , tomou-se como

valor o próprio nome do arquivo da imagem. Temos as imagens médicas representadas pelo prefixo `med_` e as imagens de sensoriamento remoto pelo prefixo `sat_`. A categoria de cada imagem também é descrita em seu nome, tendo:


- `med_chest_ct` e `med_thorax_ct`: tomografia coronal do peito e tomografia transversal do tórax, respectivamente (sigla CT de “computed tomography”, do inglês, tomografia computadorizada);
- `med_chest_xray` e `med_hand_xray`: radiografia do peito e da mão, respectivamente (“X-ray”, do inglês, raio X);
- `med_head_mr`: ressonância magnética da cabeça (sigla MR de “magnetic resonance”, do inglês, ressonância magnética);
- `sat_mixed_close_1`, `sat_mixed_close_2` e `sat_mixed_close_3`: imagens capturando área menor de ambiente urbano com natureza;
- `sat_nature_farther_1`, `sat_nature_farther_2` e `sat_nature_farther_3`: imagens capturando área maior de ambiente com predominância de natureza;
- `sat_urban_farther_normal_1`, `sat_urban_farther_normal_2` e `sat_urban_farther_normal_3`: imagens capturando área maior de ambiente com predominância urbana;

As imagens na Figura 18 demonstram os gráficos das métricas SSIM e RMSE com filtro AC-mediana em 25% de ruído sal e pimenta.

Figura 18 – Gráficos de resultados



(a) Gráfico com a métrica SSIM



(b) Gráfico com a métrica RMSE

Fonte: autoria própria.

Neste gráfico, tomando como exemplo o arquivo `med_chest_ct`, podemos observar que, na primeira geração, o Figura 18a métrica SSIM dá um valor aproximadamente igual a 0,45, enquanto o Figura 18b da um valor próximo a 1050. Os valores melhoram gradativamente, ou seja, indicam que a imagem está sendo filtrada de maneira efetiva, até a quarta geração, em ambas métricas, assumindo melhor valor de 0,6583 na quarta geração com SSIM e 225,6165 com RMSE. Após essas gerações, as valores vão piorando levemente.

Podemos observar que na métrica RMSE a faixa de valor não tem limite, em comparação ao SSIM o qual é contido entre 0 e 1. Assim, da geração 1 para 2, houve uma mudança súbita da métrica, indicando uma grande melhoria dos valores e assim

uma filtragem considerável. A SSIM, em contrapartida, é mais contida, mostrando uma mudança súbita, porém não proporcional com a métrica RMSE. Visto que houve apenas um aumento de $0,4438 - 0,6089 = 0,1651$, aumentando em 37%, em comparação com a mudança de $1023,9851 - 303,727 = 798,3686$ para a métrica RMSE, a qual diminuiu em 97% de uma geração para a outra.

Lembrando que esses valores são obtidos por meio da comparação da imagem original com a imagem filtrada.

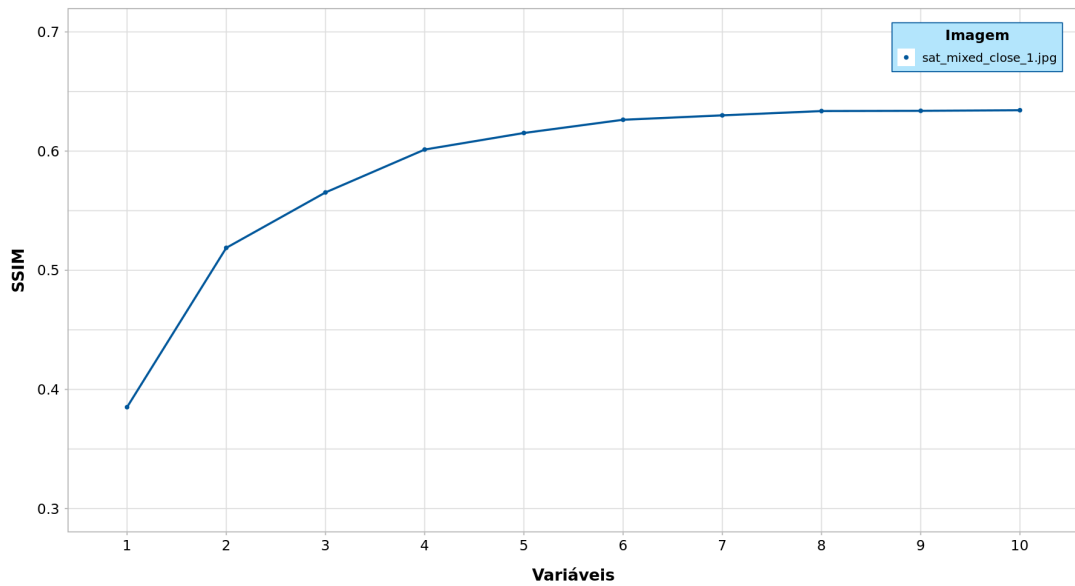
4.4 Observações

Em alguns casos, as métricas RMSE e SSIM constam valores levemente divergentes. Por exemplo, na imagem de sensoriamento remoto `sat_mixed_closed_1`, a filtragem do AC-mediana no ruído gaussiano com $\sigma = 0,5$ apresenta resultado RMSE o qual piora após 4 gerações, porém, os valores do SSIM apenas indicam que após 10 gerações há uma estagnação nos resultados obtidos, em que da 9^a para a 10^a geração há apenas um aumento de 0,0005, ou seja, apenas 0,07% de melhoria. Por outro lado, os valores do RMSE indicam que entre a 4^a e a 10^a geração houve um acréscimo de 19,1734%, indicando que a filtragem piorou ao passar das gerações.


Assim, podemos dizer que de acordo com o RMSE há uma diferença maior de pixels após uma quantidade maior de gerações, porém, a semelhança perceptível permanece, como calculado pelo SSIM. A Figura 19 demonstra os resultados da métrica com o passar das gerações (eixo X, nomeado variáveis no gráfico) em ambas métricas, demonstrando uma leve divergência entre as duas como o passar das gerações.

Ainda na Figura 19 podemos observar o resultado da filtragem após 4 gerações, momento em que a métrica RMSE teve o melhor resultado, e após 10 gerações, quando a métrica SSIM teve um resultado levemente pior que a geração anterior.

Figura 19 – Resultados da filtragem do AC-mediana com ruído gaussiano e $\sigma = 0,5$, na imagem `sat_mixed_close_1`



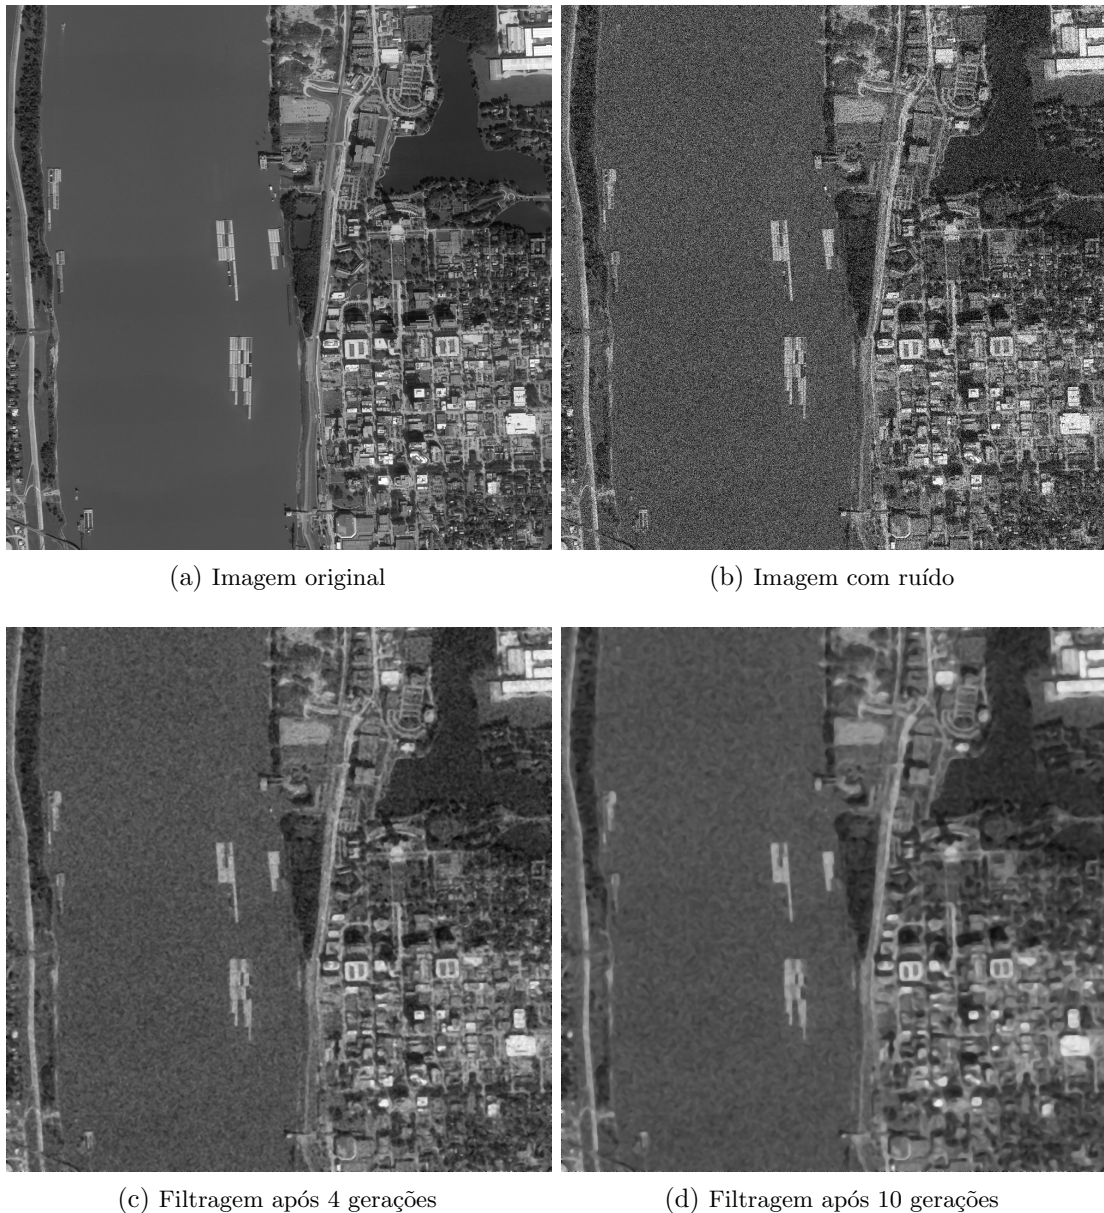
(a) Métrica SSIM



(b) Métrica RMSE

Fonte: autoria própria.

A Figura 20 mostra o resultado da filtragem em gerações diferentes, no momento em que ocorre divergência de resultados nas métricas, a geração 4, e na última geração.

Figura 20 – Filtragem pelo AC-mediana na imagem `sat_mixed_close_1` com ruído gaussiano de $\sigma = 0,5$ 

Fonte: autoria própria.

4.4.1 Filtragem com o AC-média

Para imagens médicas e com baixa quantidade de ruído, ou seja, 5% de ruído sal e pimenta, a melhor filtragem, tanto pela métrica RMSE quanto pela SSIM, foi obtida, em geral, após 3 gerações, com os valores das métricas estagnando ou diminuindo com filtragens após um número maior de gerações.

As melhores filtragens foram obtidas nas imagens de radiografia e ressonância magnética, com as métricas SSIM se aproximando a 0,95 e RMSE próximo a 10, exceto para a imagem de ressonância, com valor próximo a 20. Em comparação, as imagens de tomografia ambas tiveram resultados nas métricas piores, ou seja, a filtragem realizada


nelas não foi efetiva, com SSIM próximo a 0,85 e RMSE próximos a 50 para ambas.

Ainda com 5% de ruído sal e pimenta, as imagens de sensoriamento remoto de área urbana menor com natureza, `sat_mixed_close_1`, `sat_mixed_close_2` e `sat_mixed_close_3`, e área urbana maior, `sat_urban_farther_normal_1`, `sat_urban_farther_normal_2` e `sat_urban_farther_normal_3`, seguem o padrão de melhor resultado após 2 gerações, com valores piorando gradativamente ao aumentar o número de gerações para ambas métricas.

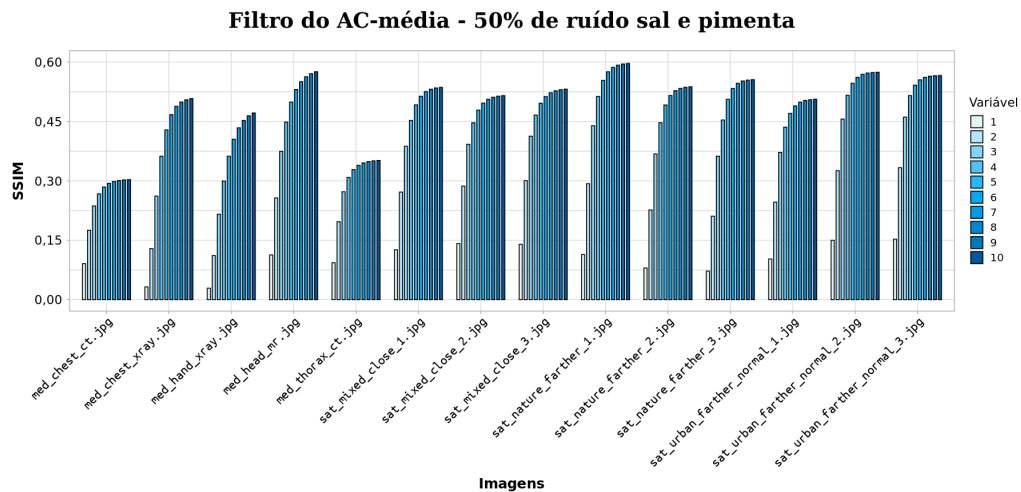
As imagens de área maior de natureza, os arquivos `sat_nature_farther_1`, `sat_nature_farther_2` e `sat_nature_farther_3`, pioram menos com o número de gerações, em comparação com os conjuntos anteriores, com valores de ambas métricas quase estagnando.

Ao aumentar a quantidade de ruído para 25% e 50%, ambas métricas seguem o mesmo padrão: filtragem melhorada de acordo com o aumento no número de gerações, porém com estagnação ao chegar em 5. Os gráficos da Figura 21 os resultados em 50% de ruído sal e pimenta.

Figura 21 – Resultados da AC-média em 50% de ruído sal e pimenta



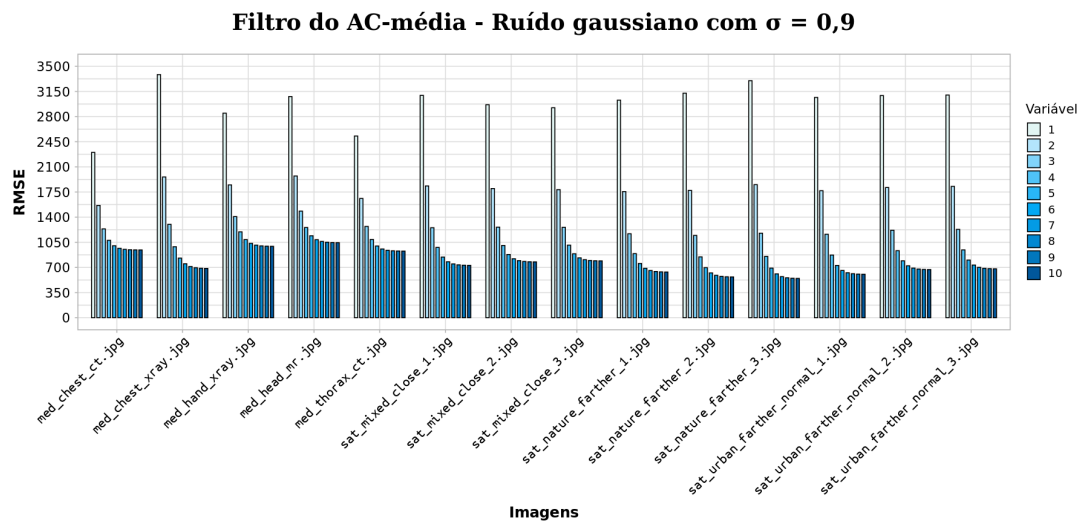

(a) Métrica RMSE



(b) Métrica SSIM

Fonte: autoria própria.

Com ruído gaussiano, para ambos valores de sigma temos os mesmos resultados, com melhoria gradativa dos valores de filtragem e estagnando após 5 gerações, sem alcançar valores que indicam filtragem boa, como próximos a 0,9 ou 0,8 em SSIM ou entre a faixa de 0 a 150 com RMSE, por exemplo. Podemos observar o comportamento da filtragem na Figura 22.

Figura 22 – Resultados da AC-média no ruído gaussiano com $\sigma = 0,9$ (a) Métrica RMSE em $\sigma = 0,9$ (b) Métrica SSIM em $\sigma = 0,9$

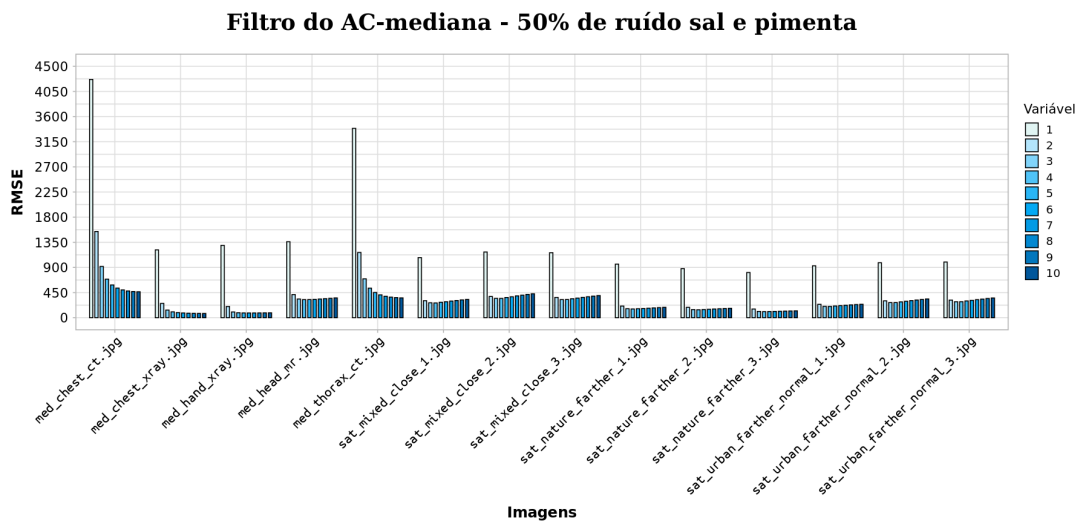
Fonte: autoria própria.

4.4.2 Filtragem com o AC-mediana


Semelhante ao AC-média, com 5% de sal e pimenta, as métricas de filtragem indicam melhoria até 2 gerações, piorando gradativamente após esse número de gerações. As imagens médicas de radiografia alcançaram as melhores métricas de filtragem nessa quantidade de ruído, com valores das métricas ambos piorando após 2 gerações, porém não tão severamente quanto as demais imagens.

Com 25% e 50% de ruído, o mesmo comportamento ocorre. Os diagramas em Figura 23 ilustram alguns dos valores obtidos com 50% de ruído sal e pimenta.

Figura 23 – Resultados da AC-mediana em 50% de ruído sal e pimenta



(a) Métrica RMSE




(b) Métrica SSIM

Fonte: autoria própria.


Com o ruído gaussiano no qual $\sigma = 0,5$, valores RMSE começam a aumentar após 5 gerações, exceto para as imagens de radiografia. Com SSIM, as medidas permanecem estagnadas após cerca de 5 de gerações.

Com valor de $\sigma = 0,9$, valores da métrica RMSE mostram melhoria até 5 gerações, enquanto os valores de SSIM alcançam melhoria gradativa exceto para imagens de tomografia, as quais os valores estagnam após cerca de 5 gerações, como visto na Figura 24.

Figura 24 – Resultados da AC-mediana no ruído gaussiano com $\sigma = 0,9$



(a) Métrica RMSE



(b) Métrica SSIM

Fonte: autoria própria.

4.5 Interpretação de resultados

Foi possível observar algumas diferenças nos resultados das filtragens nas categorias de imagens utilizadas.

4.5.1 Imagens médicas

Em imagens médicas com 5% de ruído sal e pimenta, foi possível observar que os resultados obtidos pelo filtro da mediana são semelhantes aos resultados de ambos ACs.


Com 25% de ruído, os resultados do filtro da mediana são melhores, especialmente nas imagens de tomografia. É possível observar que nelas há uma grande quantidade de

espaço vazio em cores escuras, quase preto. Com o filtro da mediana, ruído nessas áreas desaparece em grande parte, porém na filtragem realizada por ambos ACs, essa regiões não são totalmente filtradas.

O mesmo ocorre com 50% de ruído, com o filtro da mediana, em que seus valores SSIM são entre 0,75 a 0,9, enquanto valores do AC-média estão entre 0,3 a 0,6, e o AC-mediana entre 0,5 a 0,9. Os piores valores obtidos pelos ACs se encontram nas imagens de tomografia.


Com ruído gaussiano, em ambos valores de σ , o filtro da mediana teve resultados levemente melhores, com a filtragem do AC-mediana tendo resultados semelhantes e com a filtragem pelo AC-média tendo a pior filtragem. A Figura 25 demonstra resultados obtidos das filtrações na imagem *med_chest_ct*, demonstrando a semelhança do filtro AC-mediana com o filtro da mediana.

Figura 25 – Exemplo de filtrações na imagem *med_chest_ct* com forte ruído sal e pimenta



(a) Imagem original

(b) Imagem com 50% de ruído sal e pimenta



(c) Filtragem após 5 (d) Filtragem após 5 (e) Filtragem com fil- (f) Filtragem com fil-
gerações de AC- gerações de AC- tro mediana, com tro gaussiano, com
média mediana tamanho 7 $\sigma = 2$

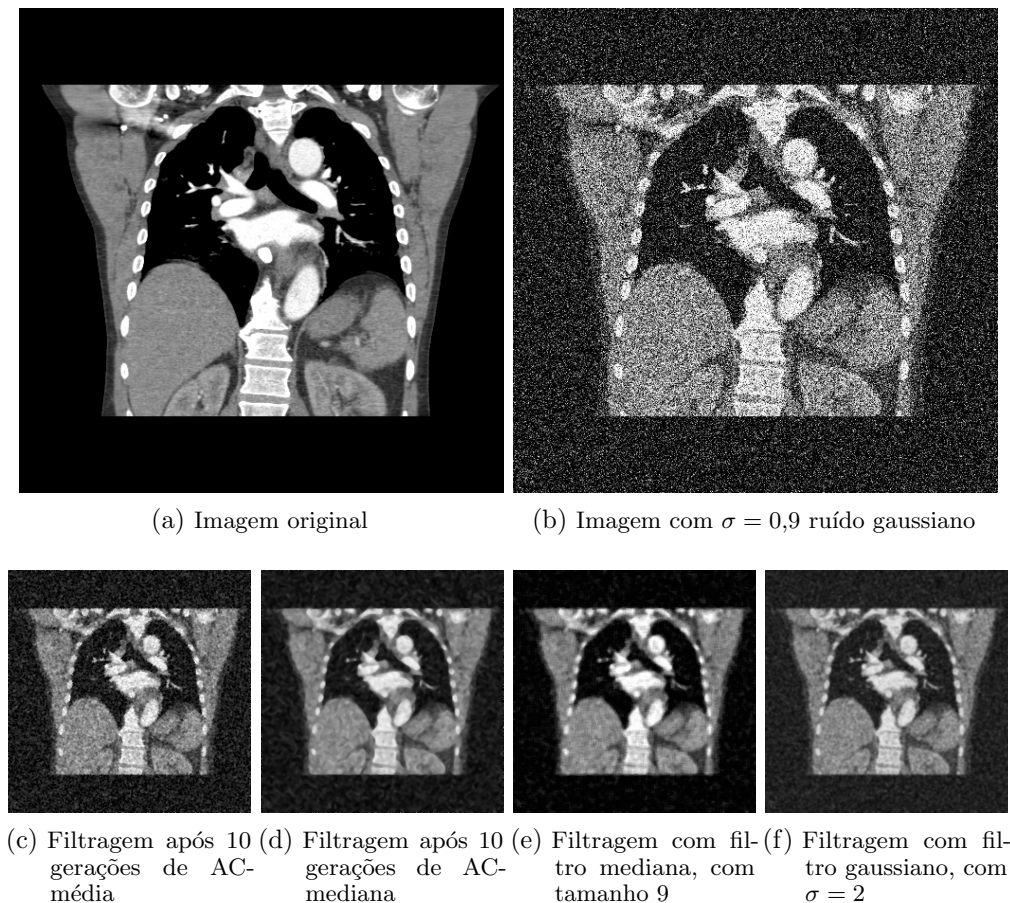
Fonte: autoria própria.

Com o filtro gaussiano no ruído sal e pimenta, ambos ACs, em geral, tiveram resultados melhores, com o AC-mediana se destacando mais.

No ruído gaussiano, com $\sigma = 0,5$, o AC-mediana e o filtro gaussiano tiveram valores semelhantes, enquanto o AC-média teve resultados pobres em comparação. Já com $\sigma = 0,9$, o filtro gaussiano apresenta melhor resultado, com AC-mediana levemente semelhante e

com AC-média novamente o pior resultado. Podemos ver exemplos da filtragem no ruído gaussiano na Figura 26.

Figura 26 – Exemplo de filtragens na imagem `med_chest_ct` com forte ruído gaussiano

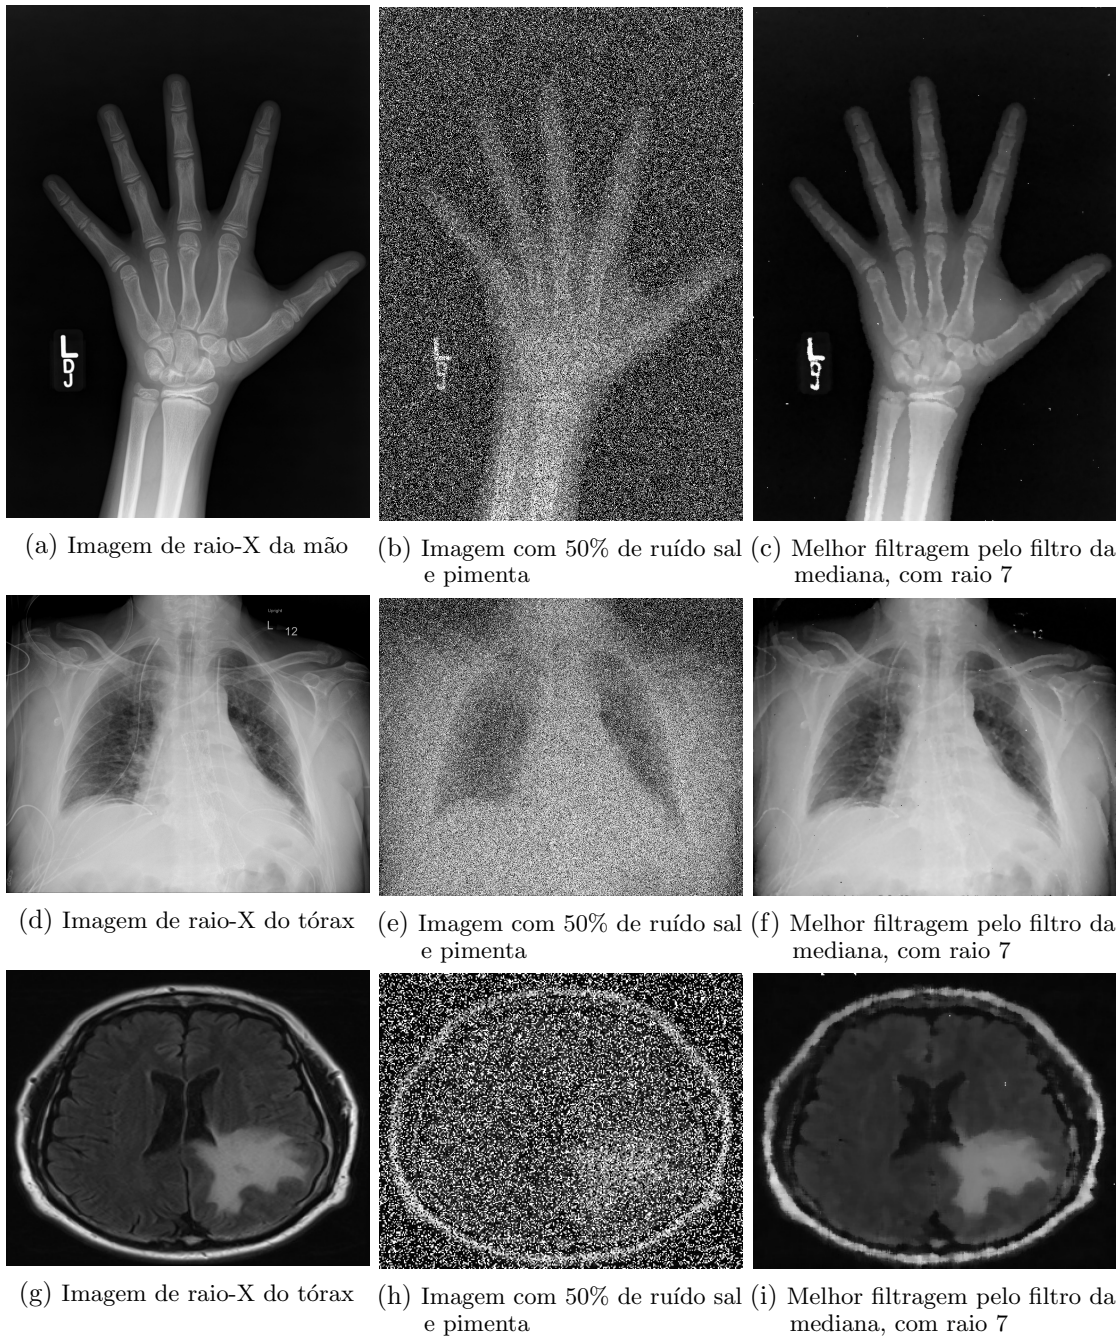


Fonte: autoria própria.

Para essas imagens, o autômato celular que melhor fez filtragem foi o AC-mediana. Ambos ACs tiveram deficiência em imagens de tomografia. Em geral, as imagens médicas que apresentaram grande quantidade de espaço vazio, ou seja, grandes seções da imagem com apenas pixels de uma certa faixa, como partes vazias das imagens de tomografia e de raio-x da mão, tiveram melhores resultados com as filtragens da mediana, justamente por que essa operação, como explicado na Subseção 2.1.3, se especializa na remoção de pixels “outliers”, ou seja, pixels em que, de acordo com sua vizinhança, tem valores de intensidade que se destacam, como um pixel branco com uma vizinhança com predominância de pixels de cor escura.

Por outro lado, na imagem de ressonância magnética, há um espaço vazio menor e os os detalhes e contornos são demonstrados por regiões com pixels com diferenças tênues entre si. Devido isso, a qualidade da filtragem foi pior em comparação as demais. A Figura 27 demonstra o resultado da filtragem feita pelo filtro da mediana.

Figura 27 – Imagens médicas



Fonte: autoria própria.

4.5.2 Imagens de sensoriamento remoto

Em imagens de sensoriamento remoto com 5% de ruído sal e pimenta, o filtro da mediana teve resultados semelhantes a filtragem obtida por ambos ACs em todas as imagens.

Com 25% de ruído, os resultados entre o filtro da mediana também foram semelhantes com ambos ACs, porém com o AC-média tendo resultados levemente melhores.

Com 50% de ruído, os resultados do filtro da mediana variam pouco entre cada tipo de imagem. O AC-mediana tem os melhores resultados, e o AC-média tem resultados

levemente piores que o filtro da mediana.

Com ruído gaussiano, em que $\sigma = 0,5$, o AC-mediana tem os resultados levemente melhores, com o AC-média semelhante aos resultados do filtro da mediana. Em $\sigma = 0,9$, o mesmo se repete, com AC-mediana tendo resultados melhores.

Com o filtro gaussiano, em todos os casos de ruído sal e pimenta, apresenta resultados piores que a filtragem feita por AC.

Em $\sigma = 0,5$, resultados de AC-média e do filtro gaussiano são semelhantes, com o AC-mediana tendo os melhores valores. Já com $\sigma = 0,9$, a filtragem feita pelo AC-mediana é o melhor, com o AC-média tendo resultados pobres e o filtro gaussiano com resultados melhores em imagens de área menor mistas, e pobres nas demais.

Figura 28 – Resultados na imagem `sat_urban_farther_normal_3`



(a) Imagem original

(b) Imagem com 50% de ruído sal e pimenta



(c) Filtragem após 8 gerações de AC-média

(d) Filtragem após 3 gerações de AC-mediana

(e) Filtragem com filtro mediana, com tamanho 5

(f) Filtragem com filtro gaussiano, com $\sigma = 2$

Fonte: autoria própria.

5 CONSIDERAÇÕES FINAIS

Em comparação aos filtros clássicos, filtro da mediana e gaussiano, ambos autômatos celulares conseguem realizar a função de filtragem de ambas imagens médicas e de sensoriamento remoto em escala de cinza com sucesso.

Para as imagens médicas, pode-se observar dificuldade na filtragem de imagens de tomografia pelos autômatos celulares. Nessas imagens, havia uma grande quantidade de espaço vazio, com cor preta, em que foi difícil para ambos AC realizar a filtragem, devido ao raio da vizinhança dificultando distinguir ruídos.

Em imagens de sensoriamento remoto, observou-se que os resultados foram semelhantes e relativamente estáveis, ou seja, reproduzindo filtragem com métricas que não variavam elevadamente de um grupo para outro. Em qualquer filtro, obteve-se resultados de semelhança relativamente baixos, já que em imagens de sensoriamento remoto, cada região da imagem carrega um número elevado de informações, isto é, há uma grande densidade de informação em cada região da imagem. Assim, a filtragem sempre leva a perda de uma grande quantidade de informações, devido a natureza da filtragem sempre levar a mesclagem de pixels com sua vizinhança, gerando uma “borragem” geral do conteúdo.

Em geral, entre as implementações de autômatos celulares, o AC utilizando a regra mediana obteve os melhores resultados, na filtragem de ambos ruídos, como demonstrado pela Figura 17 e Figura 16 já que sua regra se assemelha a filtragem feita pelo filtro da mediana, o qual também obteve resultados bons de filtragem, em comparação aos outros filtros.

Ambas métricas demonstraram correlação nos resultados obtidos, com pouca divergência em que o RMSE apresentava resultado diferente de SSIM.

5.1 Trabalhos futuros

Visto que os ACs conseguem reproduzir efeitos de filtragem relativamente semelhantes por meio de regras de múltiplas etapas baseadas em condições, como dito na Subsubseção 2.2.2.2, tais regras, em teoria, podem ser transformadas para especificação direta.

Visto isso, por meio dessa transformação para especificação direta, também seria possível treinar tal conjunto de especificações, a fim de verificar se é possível obter um conjunto de regras o qual possui resultados melhores baseado nas métricas apresentadas aqui. Rosin (2005) demonstra que tal treinamento também é possível, assim como técnicas para realizar tal treinamento.

Outro possível trabalho seria a investigação do tempo ou memória necessária para cada técnica de filtragem, considerando tanto uma implementação sequencial quanto uma

em paralelo.

Referências

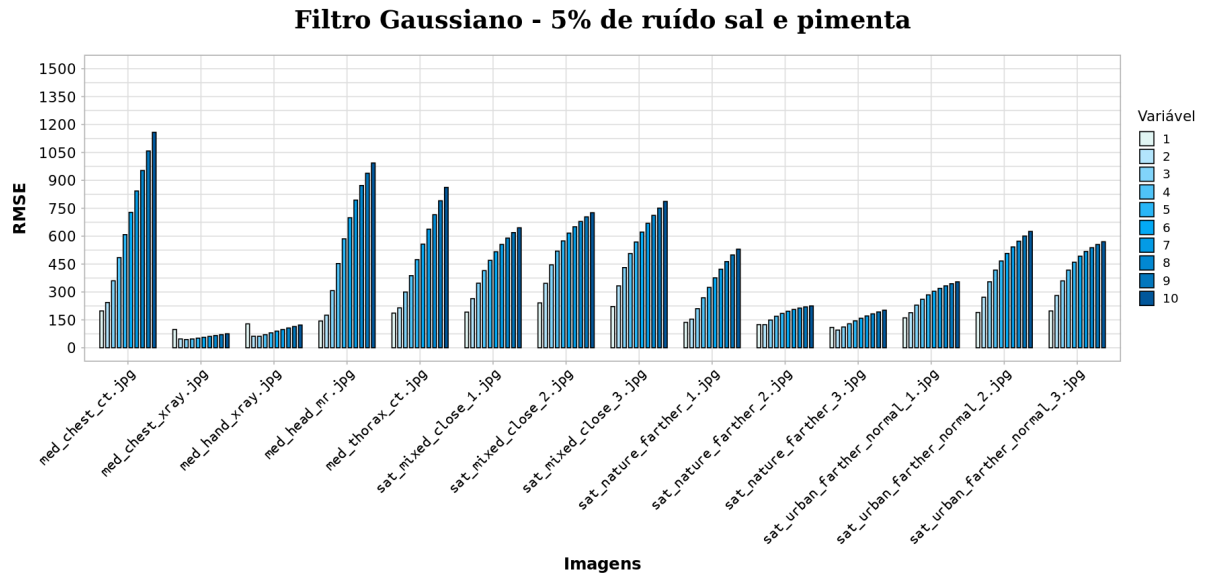
- ALVES, M. L. Análise do uso de autômatos celulares na reprodução de filtros em processamento de imagens. 2015. Citado 3 vezes nas páginas 1, 2 e 26.
- BOGO, R. L.; GRAMANI, L. M.; KAVISKI, E. Modelagem computacional do tráfego de veículos pela teoria microscópica. **Revista Brasileira de Ensino de Física**, v. 37, n. 1, 2015. Citado na página 23.
- BOGUSZEWSKI, A. et al. Landcover.ai: Dataset for automatic mapping of buildings, woodlands, water and roads from aerial imagery. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops**. [S.l.: s.n.], 2021. Disponível em: <<https://landcover.ai/>>. Acesso em: 21 mai. 2021. Citado na página 31.
- DALHOUM, A. L. A.; AL-DHAMARI, I.; ALFONSECA, M. Enhanced cellular automata for image noise removal. 2011. Citado 3 vezes nas páginas 30, 31 e 32.
- DICOM. Dicom ps3.1 2021b - introduction and overview. 2021. Disponível em: <<http://dicom.nema.org/medical/dicom/current/output/pdf/part01.pdf>>. Acesso em: 11 mai. 2021. Citado na página 36.
- DING, J. et al. Object detection in aerial images: A large-scale benchmark and challenges. 2021. Disponível em: <<https://captain-whu.github.io/DOTA/dataset.html>>. Acesso em: 21 mai. 2021. Citado na página 31.
- FAUSTENER, R. A package for 1-x dimensional cellular automata v1.0.8. 2021. Disponível em: <https://gitlab.com/DamKoVosh/cellular_automaton>. Acesso em: 2 abr. 2021. Citado na página 34.
- FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**. [S.l.]: Brasport, 1999. ISBN 8574520098. Citado na página 4.
- FONSECA, Y. B. Cellular automata with python v1.0.0. 2021. Disponível em: <<https://zenodo.org/badge/latestdoi/347530113>>. Acesso em: 20 jul. 2021. Citado na página 34.
- FRAME, M.; BENOIT, M.; NEGER, N. Cellular automata and fractal evolution. 2001. Disponível em: <https://users.math.yale.edu/public_html/People/frame/Fractals/>. Acesso em: 1 jul. 2020. Citado 2 vezes nas páginas 1 e 14.
- GONZALES, R. C.; WOODS, R. E. **Digital Image Processing (3rd edition)**. [S.l.]: Prentice-Hall, Inc., 2008. ISBN 013168728X. Citado 9 vezes nas páginas 5, 6, 7, 8, 9, 10, 11, 12 e 37.
- LEITE, I. O. B.; LINS, J. C. d. S.; CERQUEIRA, M. G. d. C. Autômatos celulares. **Revista Brasileira de Ensino de Física**, 2000. Citado na página 21.
- LIMA, E. B. Modelos microscópicos para simulação do tráfego baseados em autômatos celulares. 2007. Citado 8 vezes nas páginas 16, 17, 18, 19, 20, 21, 22 e 23.

- LIU, S.; CHEN, H.; YANG, S. An effective filtering algorithm for image salt-pepper noises based on cellular automata. **2008 Congress on Image and Signal Processing**, v. 3, p. 294–297, 2008. Citado 3 vezes nas páginas 30, 31 e 32.
- MEDIXANT. Radiant. 2021. Disponível em: <<https://www.radiantviewer.com/>>. Acesso em: 11 mai. 2021. Citado na página 36.
- OLIVEIRA, G. M. B. d. Autômatos celulares: aspectos dinâmicos e computacionais. 2003. Citado 5 vezes nas páginas 1, 14, 15, 16 e 20.
- POPOVICI, A.; POPOVICI, D. Cellular automata in image processing. 2002. Citado 3 vezes nas páginas 1, 25 e 31.
- ROSIN, P. Training cellular automata for image processing. **Lecture Notes in Computer Science**, v. 3540, p. 195–204, 01 2005. Citado 2 vezes nas páginas 28 e 54.
- ROSIN, P.; SUN, X. Cellular automata as a tool for image processing. **Emerging Topics in Computer Vision and its Applications**, p. 233–251, 09 2011. Citado 3 vezes nas páginas 13, 28 e 29.
- SHUKLA, A. P.; AGARWAL, S. An enhanced cellular automata based scheme for noise filtering. **International Journal of Signal Processing, Image Processing and Pattern Recognition**, v. 7, n. 4, p. 231–242, 2014. Citado 2 vezes nas páginas 20 e 21.
- TCIA. The cancer imaging archive. 2021. Disponível em: <<https://wiki.cancerimagingarchive.net/display/Public/Collections>>. Acesso em: 10 mai. 2021. Citado na página 31.
- WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. **IEEE Transactions on Image Processing**, v. 13, n. 4, p. 600–612, 2004. Citado na página 12.
- WEIMAR, J. R. Modeling with cellular automata. 2000. Disponível em: <<http://www.jweimar.de/jcasim/main/>>. Acesso em: 22 dec. 2020. Citado 2 vezes nas páginas 23 e 30.
- WIKIPEDIA. Cellular automaton. 2021. Disponível em: <https://en.wikipedia.org/wiki/Cellular_automaton>. Acesso em: 1 jul. 2020. Citado na página 20.
- WOLFRAM, S. **A New Kind of Science**. [S.l.]: Wolfram Media, 2002. Citado 2 vezes nas páginas 17 e 18.

Apêndices


APÊNDICE A – Tabelas - Resultados: Medida RMSE com o filtro gaussiano

Figura 29 – Medida RMSE do filtro gaussiano em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 30 – Medida RMSE do filtro gaussiano em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 31 – Medida RMSE do filtro gaussiano em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 32 – Medida RMSE do filtro gaussiano em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria


Figura 33 – Medida RMSE do filtro gaussiano em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria


APÊNDICE B – Tabelas - Resultados: Medida RMSE com o filtro da mediana

Figura 34 – Medida RMSE do filtro da Mediana em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 35 – Medida RMSE do filtro da Mediana em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 36 – Medida RMSE do filtro da Mediana em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 37 – Medida RMSE do filtro da Mediana em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria

Figura 38 – Medida RMSE do filtro da Mediana em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria

APÊNDICE C – Tabelas - Resultados: Medida RMSE com o filtro do AC (regra média)

Figura 39 – Medida RMSE do filtro do AC (regra média) em 5% de ruído sal e pimenta




Figura 40 – Medida RMSE do filtro do AC (regra média) em 25% de ruído sal e pimenta


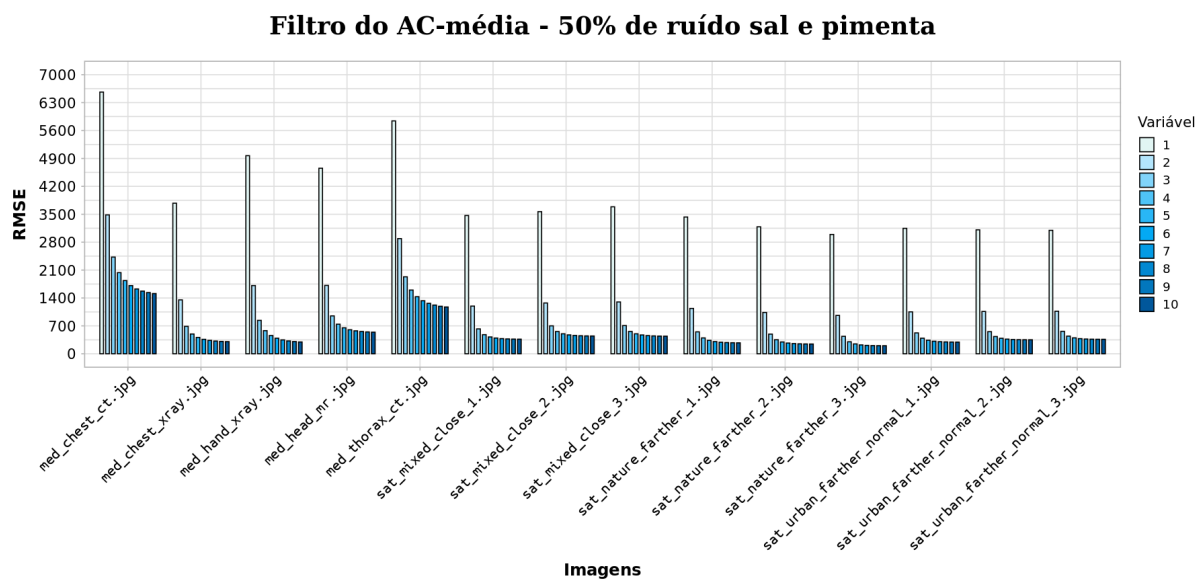



Figura 41 – Medida RMSE do filtro do AC (regra média) em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 42 – Medida RMSE do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria


Figura 43 – Medida RMSE do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria


APÊNDICE D – Tabelas - Resultados: Medida RMSE com o filtro do AC (regra mediana)

Figura 44 – Medida RMSE do filtro do AC (regra mediana) em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 45 – Medida RMSE do filtro do AC (regra mediana) em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 46 – Medida RMSE do filtro do AC (regra mediana) em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 47 – Medida RMSE do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria


Figura 48 – Medida RMSE do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria


APÊNDICE E – Tabelas - Resultados: Medida SSIM com o filtro gaussiano

Figura 49 – Medida SSIM do filtro Gaussiano em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 50 – Medida SSIM do filtro Gaussiano em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 51 – Medida SSIM do filtro Gaussiano em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 52 – Medida SSIM do filtro Gaussiano em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria


Figura 53 – Medida SSIM do filtro Gaussiano em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria


APÊNDICE F – Tabelas - Resultados: Medida SSIM com o filtro da mediana

Figura 54 – Medida SSIM do filtro da Mediana em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 55 – Medida SSIM do filtro da Mediana em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 56 – Medida SSIM do filtro da Mediana em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 57 – Medida SSIM do filtro da Mediana em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria


Figura 58 – Medida SSIM do filtro da Mediana em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria


APÊNDICE G – Tabelas - Resultados: Medida SSIM com o filtro do AC (regra média)

Figura 59 – Medida SSIM do filtro do AC (regra média) em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 60 – Medida SSIM do filtro do AC (regra média) em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 61 – Medida SSIM do filtro do AC (regra média) em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 62 – Medida SSIM do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria


Figura 63 – Medida SSIM do filtro do AC (regra média) em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria


APÊNDICE H – Tabelas - Resultados: Medida SSIM com o filtro do AC (regra mediana)

Figura 64 – Medida SSIM do filtro do AC (regra mediana) em 5% de ruído sal e pimenta




Fonte: autoria própria

Figura 65 – Medida SSIM do filtro do AC (regra mediana) em 25% de ruído sal e pimenta




Fonte: autoria própria

Figura 66 – Medida SSIM do filtro do AC (regra mediana) em 50% de ruído sal e pimenta




Fonte: autoria própria

Figura 67 – Medida SSIM do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,5$



Fonte: autoria própria

Figura 68 – Medida SSIM do filtro do AC (regra mediana) em ruído gaussiano com $\sigma = 0,9$



Fonte: autoria própria