



UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

LUCAS PEREIRA DE LIRA

**PROPOSTA DE UM NOVO DESCRITOR DE IMAGENS BASEADO EM  
AUTÔMATOS CELULARES**

**DISSERTAÇÃO DE MESTRADO**

**CORNÉLIO PROCÓPIO**  
2023

LUCAS PEREIRA DE LIRA

## **PROPOSTA DE UM NOVO DESCRITOR DE IMAGENS BASEADO EM AUTÔMATOS CELULARES**

### **Proposal for a New Images Descriptor Based on Cellular Automaton**

Dissertação apresentada ao Programa de Pós-Graduação em Informática da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para obtenção do título de Mestre em Informática.

Orientador: Prof. Dr. Silvio Ricardo Rodrigues Sanches

Coorientador: Prof. Dr. Pedro Henrique Bugatti

CORNÉLIO PROCÓPIO  
2023



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



LUCAS PEREIRA DE LIRA

**PROPOSTA DE UM NOVO DESCRITOR DE IMAGENS BASEADO EM AUTÔMATOS CELULARES**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Informática da Universidade Tecnológica Federal do Paraná (UTFPR).  
Área de concentração: Computação Aplicada.

Data de aprovação: 14 de Agosto de 2023

Dr. Pedro Henrique Bugatti, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Silvio Ricardo Rodrigues Sanches, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Claiton De Oliveira, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Cleber Gimenez Correa, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Valdinei Freire Da Silva, Doutorado - Usp-Universidade de São Paulo

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 16/08/2023.

## RESUMO

Pereira, Lucas. PROPOSTA DE UM NOVO DESCRITOR DE IMAGENS BASEADO EM AUTÔMATOS CELULARES. 47 f. Dissertação – Programa de Pós-Graduação em Informática, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2023.

O processo de extração de características de imagens é fundamental na resolução de diversos problemas computacionais. Esta dissertação apresenta uma nova abordagem para análise e descrição de imagens baseada em autômatos celulares. Tal abordagem permite modelar a relação discreta local entre pixels, considerando, forma, intensidade e relação entre objetos da imagem. Tomando como base o Jogo da Vida de Conway, foram criados quatro métodos para analisar a relação entre pixels de uma imagem e extrair suas características. Além disso, foram propostas diferentes combinações dos resultados de cada um dos métodos o que permitiu obter melhores resultados durante os experimentos. Para validar a abordagem proposta os experimentos foram realizados utilizando bases de dados públicas que foram submetidas ao método proposto e os resultados comparados com os resultados das principais abordagens de extração de características, amplamente utilizadas e conhecidas no estado da arte. Para medir o desempenho de cada abordagem o cálculo da acurácia foi utilizado em diferentes classificadores. Após os experimentos a abordagem proposta apresentou um desempenho considerável, atingindo acurácia de até 83,90% e 73,30% para os conjuntos de dados Corel-1K e Pap-smear respectivamente. Os resultados atestam que a abordagem proposta supera as abordagens de última geração e pode ser aplicada com sucesso na extração de características de imagens.

**Palavras-chave:** Autômatos Celulares, Aprendizado de Máquina, Visão Computacional, Processamento de Imagens, Jogo da Vida, Extração de Características.

## ABSTRACT

Pereira, Lucas. Proposal for a New Images Descriptor Based on Cellular Automaton. 47 f. Dissertação – Programa de Pós-Graduação em Informática, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2023.

The feature extraction process from images is fundamental in solving several computational problems. This research presents a new image analysis and description approach based on cellular automata. This approach allows modeling the discrete local relationship between pixels, considering shape, intensity, and relationship between objects in the image. Based on Conway's Game of Life, we created four methods to analyze the relationship between pixels in an image and extract their features. In addition, we proposed different combinations of the results of each method, which allowed us to obtain better results during the experiments. To validate the proposed approach, we used public databases to compare our results with the results of the state-of-the-art feature extraction approaches. We used accuracy to measure the performance of the methods. After the experiments, the proposed approach presented an accuracy of up to 83.90% and 73.30% for Corel-1K and Pap-smear datasets, respectively. The results show that the proposed approach outperforms state-of-the-art approaches and can be successfully applied in image feature extraction.

**Keywords:** Cellular Automata, Machine Learning, Computer Vision, Image Processing, Game of Life, Feature Extraction.

## LISTA DE FIGURAS

FIGURA 1	– Etapas do Processamento de Imagens. ....	17
FIGURA 2	– Processo de Discretização de uma Imagem .....	21
FIGURA 3	– Formato da célula: a) quadrada; b) triangular; c) hexagonal .....	26
FIGURA 4	– a) Unidimensional, b) Bidimensional e c) Tridimensional. ....	26
FIGURA 5	– a) Vizinhança de von Newmann, b) Vizinhança de Moore e c) Vizinhança de Moore Estendida .....	27
FIGURA 6	– Exemplo de Transição do “jogo da vida”. ....	29
FIGURA 7	– (a) Bloch; (b) Beehive; (c) Boat; (d) Loaf e (e) Ship. ....	30
FIGURA 8	– Exemplos: a) Blinker; b) Toad. ....	30
FIGURA 9	– Fluxograma do método proposto .....	34
FIGURA 10	– Exemplo do método proposto iterando sobre um fragmento de uma imagem. ....	36
FIGURA 11	– Exemplos de cada classe de imagem no conjunto de dados Corel-1k. ....	37
FIGURA 12	– Exemplos de cada classe de imagem no conjunto de dados PapSmear. ....	37

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	Considerações Iniciais	13
1.2	Objetivos	14
1.3	Organização do Documento	14
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>16</b>
2.1	Processamento de Imagens	16
2.1.1	Aquisição de Imagens	17
2.1.2	Pré-processamento	18
2.1.3	Segmentação	18
2.1.4	Extração de Características	19
2.1.5	Reconhecimento e Interpretação	20
2.2	Imagem Digital	20
2.2.1	Amostragem e Quantização	21
2.3	Autômatos Celulares	22
2.3.1	Definição Formal	25
2.3.2	Células	25
2.3.3	Grade e Vizinhança	26
2.3.4	Estados, Regras e Interações	27
2.3.5	O Jogo da Vida	28
2.3.6	Regras	28
2.3.7	Gliders, Objetos Estáveis e Oscilatórios	30
2.4	Descritores de Imagens	30
<b>3</b>	<b>MÉTODO PROPOSTO</b>	<b>32</b>
3.1	Proposta	32
3.2	Experimentos	36
3.2.1	Resultados e Discussões	38
<b>4</b>	<b>CONCLUSÃO</b>	<b>43</b>
	<b>REFERÊNCIAS</b>	<b>44</b>

# 1 INTRODUÇÃO

## 1.1 CONSIDERAÇÕES INICIAIS

O processo de extração de características de dados complexos (imagens, vídeos, sons etc.) tornou-se fundamental para o reconhecimento e interpretação dos dados. Em especial na visão computacional esse conceito possibilita alcançar diferentes primitivas, utilizadas pelo sistema de reconhecimento visual humano, como características de cor, textura e forma.

Atualmente as redes neurais convolucionais (CNN) são fortemente utilizadas como um processo único para extrair características e classificar imagens. Embora técnicas baseadas em aprendizado profundo sejam ferramentas poderosas e apresentem excelentes resultados para análise de dados, podem apresentar alguns problemas, incluindo o alto consumo de energia, alta complexidade computacional, falta de escalabilidade e flexibilidade (PONTES-FILHO et al., 2020). Portanto, CNNs puras não são sempre a melhor escolha em diversos problemas.

Em contrapartida, modelos de autômatos celulares têm sido utilizados com sucesso em diversas tarefas, especialmente em cenários de processamento de imagens, como detecção de bordas, filtragem de ruído, detecção de saliência e segmentação de imagens (TANGSAKUL; WONGTHANAVASU, 2023). Autômatos celulares são modelos matemáticos criados com o objetivo de modelar sistemas biológicos que se reproduzem fazendo cópias de si mesmo, assim como plantas, doenças e os próprios animais. São considerados ferramentas poderosas, capazes de representar sistemas dinâmicos, compostos por propriedades discretas, considerando espaço e tempo e que possuam um conjunto finito de regras e estados. Inúmeros sistemas se enquadram nessa definição o que proporciona um vasto campo de



aplicação para essas técnicas (ULAM, 1950; NEUMANN, 1951; CASTRO; CASTRO, 2008; MARTINS, 2010).

Um dos autômatos celulares de duas dimensões mais conhecidos é o Jogo da Vida (*Game of Life*), desenvolvido pelo matemático John Horton Conway em 1970. O Jogo da Vida é um autômato celular composto por um conjunto finito de regras relativamente simples que simula o processo de evolução de células biológicas, mais especificamente o nascimento, a sobrevivência ou a morte das células (MELOTTI, 2009).

Considerando esse contexto, este trabalho propõe um novo extrator de características de imagens baseado no Jogo da Vida, para resolver problemas utilizando menores custo e complexidade computacional que os demandados pelas CNNs.

## 1.2 OBJETIVOS

Esse trabalho tem como objetivo desenvolver um novo extrator de características de imagens baseado no Jogo da Vida de Conway. O método agrega e extrai características baseadas em intensidade dos pixels, forma, textura e componentes conectados. Os conceitos de autômatos celulares tal como as regras de transição de estado do Jogo da Vida são considerados no contexto das imagens e de seus pixels.

## 1.3 ORGANIZAÇÃO DO DOCUMENTO

No atual capítulo, são apresentados as considerações iniciais e os objetivos a serem atingidos, utilizados como base para o desenvolvimento e organização do trabalho, que está estruturado da seguinte forma:

- No capítulo 2 é apresentada a fundamentação teórica em que são abordados conceitos relevantes de processamento de imagens e autômatos celulares;
- No capítulo 3 é apresentado o método proposto, bem como os resultados obtidos;

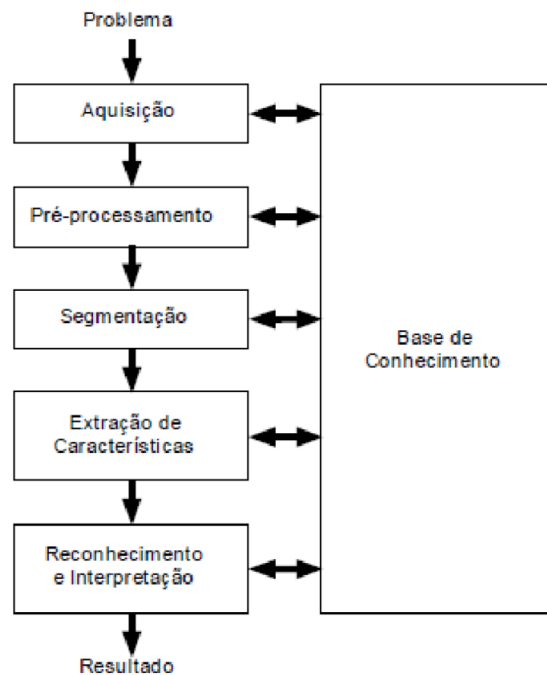
- No capítulo 4 são apresentadas as conclusões.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo apresenta-se o embasamento teórico necessário para o entendimento e desenvolvimento das etapas relacionadas à proposta do trabalho.

### 2.1 PROCESSAMENTO DE IMAGENS

Segundo GONZALEZ e WOODS (2008), o processamento de imagens digitais considera três níveis de processos computacionais: processos de nível baixo, médio e alto. Processos de nível baixo englobam operações primitivas, como por exemplo, aquisição de imagem, pré-processamento, realce e aguçamento, caracterizados pelo fato de tanto a entrada quanto a saída serem imagens. Os processos de nível médio envolvem tarefas como segmentação (identificação de regiões ou objetos) e a descrição das regiões ou objetos visando obter uma representação mais adequada para o processamento e classificação. Tais processos são caracterizados pelo fato de as entradas, em geral, serem imagens, enquanto que as saídas são características extraídas das imagens de entrada. Finalmente, os processos de nível alto envolvem “dar sentido” a um conjunto de objetos/características extraídas, como por exemplo, realizar as funções cognitivas normalmente associadas à visão humana. A Figura 1 ilustra as etapas do processamento de imagens.



**Figura 1: Etapas do Processamento de Imagens (MARQUES FILHO; VIEIRA NETO, 1999).**

### 2.1.1 AQUISIÇÃO DE IMAGENS

Grande parte das imagens geradas atualmente consiste na combinação entre uma fonte de iluminação (visível) e o grau de reflexão ou absorção de energia da fonte de iluminação pelos elementos presentes no campo visual cuja imagem está sendo gerada. Embora seja a situação mais comum, em algumas situações não existe uma luz visível iluminando uma cena 3D (tridimensional).

Existem, por exemplo, fontes de iluminação que tem origem de uma fonte de energia eletromagnética, como um sistema de raios X, um radar ou infravermelho. Assim como as fontes de iluminação podem ser menos tradicionais, os elementos da cena poderiam ser objetos comuns, mas também poderiam ser moléculas, formações rochosas subterrâneas ou um cérebro humano.

Dependendo da natureza da fonte de iluminação, a energia emitida poderia ser refletida ou transmitida através deles. Com base nisso, a aquisição de uma imagem representa a conversão de uma cena real em uma imagem analógica ou digital. A energia recebida é transformada em tensão por meio do material do sensor, que por sua vez é sensível a um tipo específico de energia. Após processar o sinal

de entrada os sensores formatam uma onda de tensão de saída e uma quantidade digital é obtida de cada sensor por meio da digitalização dessa resposta (GONZALEZ; WOODS, 2008).

### 2.1.2 PRÉ-PROCESSAMENTO

Na maioria das vezes, as imagens resultantes do processo de aquisição podem apresentar diversas imperfeições, como ruído, contraste e/ou brilho inadequados, objetos, símbolos e formas incompletas. Dessa forma, dependendo da aplicação na qual a imagem será utilizada o resultado obtido pode não estar de acordo com os requisitos necessários. A função do pré-processamento de imagens é aprimorar a qualidade da imagem para as etapas subsequentes. As operações efetuadas nesta etapa são ditas de baixo nível pois trabalham diretamente com os valores de intensidade dos pixels, resultando em uma imagem com qualidade superior a original (MARQUES FILHO; VIEIRA NETO, 1999).

### 2.1.3 SEGMENTAÇÃO

O processo de segmentação consiste em dividir uma imagem em suas unidades significativas, ou seja, nos objetos de interesse que a compõem (MARQUES FILHO; VIEIRA NETO, 1999). Embora possa parecer simples, a segmentação de imagens não triviais é uma das tarefas mais difíceis no processamento de imagens. A segmentação precisa é fator que em muitas aplicações determina o sucesso ou o fracasso final dos procedimentos de análise computadorizada (GONZALEZ; WOODS, 2008).

Existem duas categorias básicas de algoritmos que são frequentemente utilizados na segmentação de imagens monocromáticas. Ambas estão relacionadas às propriedades dos valores de intensidade, como descontinuidade e similaridade. A primeira categoria pressupõe que as fronteiras entre um elemento e outro são suficientemente diferentes entre si e em relação ao fundo da imagem, o que permite a detecção desse limite baseando-se nas transições locais de intensidade. A técnica de segmentação principal dessa categoria é a baseada nas bordas. A segunda

categoria apresenta técnicas de segmentação que visam encontrar regiões de forma direta. Um exemplo desse tipo de técnica é denominado Crescimento de Região que é um procedimento que agrupa os pixels ou as sub-regiões em regiões maiores com base em critérios predefinidos para o crescimento, ou seja, realiza a divisão da imagem em regiões que se assemelham, tomando como base um conjunto de critérios predefinidos (GONZALEZ; WOODS, 2008).

#### 2.1.4 EXTRAÇÃO DE CARACTERÍSTICAS

A extração de características é um processo importante usado para identificar informações relevantes para qualquer classificador. Existem diversas abordagens para extração de características; Recursos em nível de pixel que determinam os recursos do pixel na imagem, recursos globais que são usados para descrever a imagem inteira e recursos locais que são usados apenas para descrever a parte interessante da imagem (TANGSAKUL; WONGTHANAVASU, 2023). Após segmentar as imagens tomando como base as abordagens mencionadas na seção anterior, é necessário então descrevê-las. Uma prática comum é utilizar esquemas que concentram os dados dos elementos segmentados a fim de facilitar os cálculos por trás dos descritores (GONZALEZ; WOODS, 2008).

Esta etapa visa extrair características das imagens resultantes do processo de segmentação por meio de algoritmos capazes de caracterizar com precisão a "essência" da imagem segundo aspectos específicos, como por exemplo, cor, textura, formas dos elementos e a relação entre eles. Tais técnicas são consideradas de nível médio, pois, ao contrário dos algoritmos de segmentação que recebem uma imagem como entrada e geram uma imagem como saída, os descritores recebem imagens e geram um conjunto de características geralmente representadas por meio de um vetor de características. A partir desse momento, a imagem passa a ser representada por este vetor de características. Ressalta-se que a estrutura utilizada para descrever os dados depende da natureza do problema e o objetivo a ser atingido.

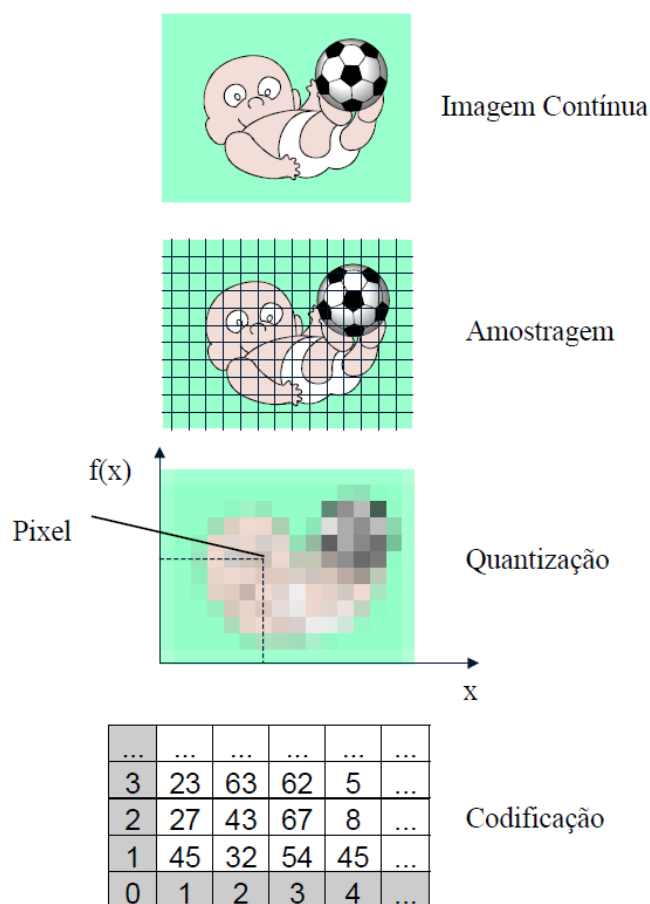
### 2.1.5 RECONHECIMENTO E INTERPRETAÇÃO

A última etapa remete ao reconhecimento ou rotulação de um elemento da imagem baseado em suas características, obtidas por seus descritores. Além disso, a interpretação, que consiste em atribuir o significado a um conjunto de elementos reconhecidos (MARQUES FILHO; VIEIRA NETO, 1999).

Os algoritmos de aprendizado de máquina são os mais utilizados na etapa de reconhecimento e interpretação. De forma resumida, a maioria dos algoritmos de aprendizagem de máquina podem ser divididos nas categorias de aprendizado supervisionado e não supervisionado. Dois exemplos de algoritmos para o aprendizado supervisionado são Máquina de vetor de suporte (SVM) e Árvores de decisão. Em contrapartida, pode-se citar o agrupamento k-means que divide o conjunto de treinamento em um número  $k$  de diferentes aglomerados, considerando a proximidade entre cada elemento onde sua posição é delimitada por seus atributos ou características (GOODFELLOW et al., 2016).

## 2.2 IMAGEM DIGITAL

Conforme apresentado na seção anterior, a aquisição de imagens tem como objetivo gerar imagens digitais a partir de dados captados por sensores. Na maioria das vezes as saídas dos sensores são emitidas em forma de onda de tensão contínua onde sua amplitude e comportamento no espaço estão diretamente relacionados ao fenômeno físico que está sendo captado pelos sensores. Para que uma imagem digital seja obtida, é necessário converter esses dados contínuos para uma forma discreta em formato digital, tornando necessário realizar dois novos processos: amostragem e quantização (GONZALEZ; WOODS, 2008). A Figura 2 ilustra o processo abordado.



**Figura 2: Processo de Discretização de uma Imagem (SCURI, 1999).**

### 2.2.1 AMOSTRAGEM E QUANTIZAÇÃO

A amostragem é a digitalização dos valores contínuos em relação às coordenadas  $x$  e  $y$ . Para realização da amostragem é necessário coletar amostras dos valores contínuos que representam a imagem real. Isso geralmente é realizado considerando amostras igualmente espaçadas, de tal forma a obter uma imagem o mais semelhante possível com a imagem real, entretanto, representada por um conjunto discreto de valores (GONZALEZ; WOODS, 2008).

A quantização, por outro lado, representa a digitalização dos valores contínuos em relação a amplitude da imagem, ou seja, converte os valores das intensidades em quantidades discretas. De forma resumida, é definido um conjunto discreto de intensidades que melhor se adapta aos valores de intensidade contínuos da imagem. A intensidade de um determinado pixel em valores contínuos será substituída



pelo valor que melhor se adapta, considerando os valores discretos estabelecidos (GONZALEZ; WOODS, 2008).

### 2.3 AUTÔMATOS CELULARES

Autômatos celulares são modelos matemáticos descobertos na década de 1940 por John Von Neumann e Stanislaw Ulam (ULAM, 1950; NEUMANN, 1951). Seu objetivo principal é modelar sistemas biológicos que se reproduzem fazendo cópias de si mesmo, assim como plantas, doenças e os próprios animais. São considerados ferramentas poderosas capazes de representar sistemas dinâmicos compostos por propriedades discretas, considerando espaço e tempo e que possuem um conjunto finito de regras e estados (CASTRO; CASTRO, 2008; MARTINS, 2010).

Inúmeros sistemas se enquadram nessa definição, como o processo de surgimento de um cristal de gelo em que cada molécula traz suas próprias informações locais e agrupam-se baseadas nas construções das moléculas vizinhas (REITE, 2005), ou mesmo um conjunto de moléculas durante uma reação química.

Na biologia matemática, a dinâmica de reprodução celular desenfreada também pode ser representada por meio de um autômato celular. Martins (2010) utiliza um modelo de autômato celular para análise do comportamento macroscópico do câncer através da utilização de características microscópicas. Foram observados aspectos da dinâmica do desenvolvimento do câncer apresentados por um autômato celular. Analisou-se também a metástase que é a formação de uma nova lesão tumoral a partir de outra, mas sem continuidade entre as duas, partindo de um autômato celular primário para um autômato celular secundário variando os parâmetros do sistema.

Em trabalho semelhante, Paul-Gilloteaux et al. (2017) combinaram abordagens de autômatos com algoritmos de processamento de imagem para simular a resposta celular de tumores expostos à radiação ionizante. O método modela a alteração da permeabilização de oxigênio nos vasos sanguíneos contra doses repetidas e introduz a catástrofe mitótica (em oposição à morte celular tardia arbitrária) como um meio de modelar a morte celular induzida por radiação. Essa

estratégia possibilita obter uma caracterização estatística adequada dos resultados dos experimentos de forma que possa fornecer subsídios para que novos protocolos de radiação possam ser considerados em tratamentos reais, reduzindo o risco de obter resultados que possam prejudicar ainda mais os pacientes.

Segundo Tangsakul e Wongthanasu (2023), as redes neurais convolucionais (CNN) revolucionaram a classificação de imagens em visão computacional por meio da utilização de uma camada de convolução para realizar a extração de recursos promissores das imagens. Apesar da sua crescente utilização por parte dos pesquisadores da área, essa técnica pode apresentar problemas como *overfitting* e alta complexidade computacional, devido a sua estrutura que possui um grande número de camadas.

Para contornar esse problema, Tangsakul e Wongthanasu (2023) propõem um método de extração profunda de características baseado em um modelo de autômato celular (CA) para a classificação de imagens. O método é baseado em uma abordagem de aprendizado profundo e CA multicamadas com dois processos principais. O primeiro é o processo de extração de características, onde, CAs multicamadas são criados com regras específicas para atuar como um modelo de extração profunda de recursos. O modelo visa extrair recursos multicamadas, chamados de matrizes de recursos. Em seguida essas matrizes de recursos são usadas para gerar matrizes de pontuação para o modelo de recursos profundo treinado pelas regras de CA.

O segundo é o processo de decisão em que as matrizes de pontuação são achatadas e alimentadas na camada totalmente conectada de uma rede neural artificial (RNA) para classificação. Para avaliar seu desempenho o método foi testado empiricamente no BreakHis, um conjunto de dados público de imagens de câncer de mama utilizado em vários estudos que representam o estado-da-arte. Os resultados do trabalho mostraram que o método proposto alcança melhores resultados, em média, até 7,95% de melhoria quando comparado com os métodos da literatura.

Tangsakul e Wongthanasu (2020) propõem um método de aprendizado baseado na combinação da abordagem profunda de aprendizado com um modelo de autômato celular (DeepCA) para a remoção de neblina em imagens. O aprendizado do

DeepCA é dividido em duas partes principais. A primeira parte é a extração profunda de características baseada em autômato celular. Para isso, autômatos celulares multicamadas com suas respectivas regras são usados para extrair as matrizes de características dos dados de imagem gerando matrizes que podem ser divididas em várias camadas. Em seguida as matrizes de pontuação são geradas conforme o modelo no qual foi treinado.

A segunda parte é a de decisão onde as matrizes de pontuação são utilizadas para o mapeamento dos dados. Para demonstração, a tarefa de remoção de neblina da imagem foi utilizada com a finalidade de confirmar a capacidade do método. O modelo dicromático é escolhido como o principal para remover a névoa da imagem. Os autômatos celulares multicamadas funcionam como um extrator mecânico de características da fonte de luz da imagem nebulosa.

O estágio de decisão do DeepCA atua como um reconhecedor para prever adequadamente a fonte de luz global para que seja possível desembaçar a imagem. Para avaliar o desempenho do método, foram aplicadas medidas quantitativas e qualitativas de avaliação. Para o desempenho qualitativo da remoção de neblina, o DeepCA não causou o efeito de artefato de halo (TANGSAKUL; WONGTHANAVASU, 2020) que ocorreu em outros algoritmos de remoção de neblina. Os resultados empíricos em medidas quantitativas mostram que o DeepCA melhorou a intensidade, a qualidade da saturação de cor e o artefato de halo quando comparado com os métodos de última geração.

No trabalho de Cooper et al. (2020) um autômato celular baseado no Game of Life (GoL) é utilizado para analisar as mudanças de regime, consideradas mudanças grandes, persistentes e muitas vezes inesperadas em ecossistemas relativamente estáveis. No GoL bidimensional, cada célula pode representar um de dois estados possíveis: 'vivo' ou 'morto'. A cada passo de tempo, cada célula verifica o estado de si mesma e de seus vizinhos e, em seguida, define-se como viva ou morta com base nos estados de seus vizinhos.

Esse tipo de abordagem tem se mostrado promissora e vem despertando o interesse de diversos pesquisadores. Segundo Edelstein-Keshet (2017), um autômato celular não representa apenas um conceito abstrato, mas reproduz um processo

resultante da evolução biológica. Devido a sua maturidade, adquirida após vários anos desde sua concepção, tornou-se, finalmente, um mecanismo de formação que tem relevância biológica, podendo ser utilizado em diversas áreas de pesquisa.

### 2.3.1 DEFINIÇÃO FORMAL

Segundo Melotti (2009), uma das formas de representar um autômato celular pode ser descrita em quatro partes, de acordo com a equação:

$$U = (\mathbb{L}, \mathbb{Q}, \mathbb{R}, f), \quad (1)$$

onde  $\mathbb{L}$  é uma grade regular conhecida como “lattice”,  $\mathbb{Q}$  representa o conjunto de estados que uma célula pode assumir,  $\mathbb{R}$  representa a vizinhança de uma determinada célula, e  $f$  é a função de transição local.  $C_t : \mathbb{L} \rightarrow \mathbb{Q}$  é uma configuração que representa uma função de transição que associa um estado com uma célula da grade. Tal função tem como objetivo trocar a configuração  $C_t$  por uma nova configuração  $C_{t+1}$  dada pela equação:

$$C_{t+1}(r) = f(\{C_t(i) \mid i \in \mathbb{R}(r)\}) \quad (2)$$


onde  $\mathbb{R}(r)$  é o conjunto de células vizinhas de  $r$ . A Equação 2 define o próximo estado a ser associado à célula e este só depende dos estados atuais de sua vizinhança.

### 2.3.2 CÉLULAS

As células são as unidades básicas de um autômato celular e funcionam como variáveis discretas que assumem diferentes estados durante certos espaços de tempo. A mudança de estado, entretanto, depende diretamente das regras que estabelecem o funcionamento evolutivo do autômato celular. Portanto, o estado geral de um autômato celular é definido pelo conjunto de valores das células, sendo que, o valor da célula em um passo de tempo posterior será afetado pelos valores das células vizinhas no passo de tempo anterior (MARTINS, 2010).

A forma geométrica de cada célula pode variar dependendo do número de vizinhos e do número de dimensões da grade. Em uma grade de duas dimensões, a célula pode assumir geometrias regulares, como quadrada, triangular e hexagonal. A


Figura 3 ilustra algumas dessas formas (MELOTTI, 2009).



**Figura 3: Formato da célula: a) quadrada; b) triangular; c) hexagonal (MELOTTI, 2009).**


### 2.3.3 GRADE E VIZINHANÇA

Um autômato celular consiste em uma grade uniforme com uma variável discreta em cada célula. A grade pode ser representada por um vetor ou matriz de comprimento infinito ou não. A Figura 4 apresenta os possíveis formatos de um autômato celular, que pode ser representado por um vetor (uma dimensão) ou uma matriz (duas ou três dimensões), além das células que compõe cada estrutura (MELOTTI, 2009).



**Figura 4: a) Unidimensional, b) Bidimensional e c) Tridimensional (MELOTTI, 2009).**

A vizinhança de uma célula tem relação direta com a alteração do seu estado e conseqüentemente com a evolução do autômato celular. Portanto, as regras aplicadas à vizinhança de uma determinada célula define seu estado no próximo instante. A Figura 5 mostra a célula base (células brancas centrais) e sua vizinhança (células escuras) com base em algumas técnicas (MELOTTI, 2009).



**Figura 5: a) Vizinhança de von Neumann, b) Vizinhança de Moore e c) Vizinhança de Moore Estendida (MELOTTI, 2009).**

Dentre as abordagens apresentadas, as vizinhanças de Newmann e Moore são as mais comuns, entretanto, abordagens diferentes podem ser utilizadas a depender da necessidade ou natureza do problema. A escolha da vizinhança também interfere na velocidade de propagação do fenômeno a ser simulado. A Figura 5a apresenta a vizinhança de Newmann que considera apenas quatro células vizinhas da célula que será atualizada. A Figura 5b apresenta a vizinhança de Moore que considera oito células vizinhas da célula que será atualizada. Finalmente, a Figura 5c, conhecida como vizinhança de Moore Estendida, considera uma vizinhança de raio dois, possui duas camadas de linhas e colunas a partir da célula base, diferente das abordagens de Newmann e Moore que possuem um raio de vizinhança um (MELOTTI, 2009).

#### 2.3.4 ESTADOS, REGRAS E INTERAÇÕES

Segundo GONCALVES et al. (2003), os estados são o conjunto dos possíveis valores que uma célula pode assumir. Portanto, para que o autômato funcione de forma adequada é importante se atentar a alguns detalhes. Em primeiro lugar, o conjunto de possíveis estados não deve ser muito grande pois o número de configurações possíveis por um autômato celular com  $s$  estados e  $n$  células de vizinhança (levando em conta a célula que será atualizada) é  $s^n$ . Os estados podem ser estabelecidos de acordo com a simulação que se pretende realizar, entretanto, cada célula só poderá representar um único estado em um determinado instante de

tempo.

As regras de transição definem qual estado uma determinada célula assumirá no próximo instante de tempo e estão diretamente relacionadas com o tipo da simulação realizada. Cada regra atua como uma função que define o próximo estado da célula com base no valor da célula da sua vizinhança. A configuração a ser adotada reflete diretamente no resultado obtido (GONCALVES et al., 2003). Os estados de todas as células da grade são simultaneamente atualizados com base nas regras utilizadas. Quando toda a grade de células partilha das mesmas regras, o autômato celular é chamado de uniforme ou homogêneo (VILLELA; CARVALHO, 2003).

Uma interação é concluída quando as regras estabelecidas para o autômato celular são aplicadas por toda a grade e o estado de cada célula é atualizado. Dessa forma, o autômato celular evolui em passos discretos de tempo, ou seja, as interações ocorrem a cada unidade de tempo (CASTRO; CASTRO, 2008). O processo de evolução dos autômatos depende dos valores de cada célula, portanto, antes que esse processo tenha início é necessário definir os estados iniciais das células da grade (MELOTTI, 2009).

### 2.3.5 O JOGO DA VIDA

O jogo da vida é um autômato celular bidimensional idealizado pelo matemático John Horton Conway em 1970. Seu objetivo é simular processos de evolução de células biológicas, mais especificamente o nascimento, a sobrevivência ou a morte das células (MELOTTI, 2009). O jogo é governado por um conjunto de regras simples, utilizadas para definir um de dois estados possíveis (vivo ou morto) das células no espaço bidimensional (MARTINS, 2010).

As seções a seguir apresentam em detalhes as regras e conceitos fundamentais do jogo da vida. Em todos os exemplos será considerada a vizinhança de Moore.

### 2.3.6 REGRAS


Segundo Castro e Castro (2008), o jogo da vida é composto por quatro regras:

1. Uma célula viva com 2 ou 3 vizinhos vivos, permanece viva;
2. Uma célula viva com apenas 1 ou 0 vizinhos vivos, morre por solidão;
3. Uma célula viva com 4 ou mais vizinhos vivos, morre sufocada;
4. Uma célula morta com exatamente 3 vizinhos vivos, renasce.

As premissas essenciais que devem ser satisfeitas por tais regras são:

1. Não deve haver nenhuma possibilidade de que qualquer configuração inicial possa crescer de maneira desenfreada e sem qualquer limite;
2. Deve haver configurações iniciais que aparenta crescer sem limites;
3. É necessário que haja configurações iniciais que no decorrer do tempo cheguem a um resultado que pode ser:
  - Sumir completamente (por solidão ou sufocamento);
  - Assumir uma configuração estável;
  - Entrar em ciclo por dois ou mais períodos de tempo.

A Figura 6 apresenta várias grades, cada uma representando o conjunto de estados das células em um determinado instante de tempo. Os números nelas apresentados são apenas para exemplificar a regra que justifica determinada mudança de estado:



**Figura 6: Exemplo de Transição do “jogo da vida” (CASTRO; CASTRO, 2008)**


As seções a seguir apresentam comportamentos que foram mapeados ao longo do tempo tomando como base diversos testes realizados.



### 2.3.7 GLIDERS, OBJETOS ESTÁVEIS E OSCILATÓRIOS

Os gliders são conjuntos de células dentro da grade em que seu formato se repete de forma cíclica, porém em posições diferente na grade e algumas vezes rotacionado (CASTRO; CASTRO, 2008). Tal comportamento pode ser observado na Figura 6 a qual exemplifica as transições envolvidas em um ciclo de glider.


Os objetos estáveis são conjuntos de células dentro da grade que tendem a não sofrer modificações em seu formato durante um longo período de tempo (MARTINS, 2010). Alguns exemplos desse tipo de objeto pode ser observado na Figura 7, são eles: Bloch; Beehive; Boat; Loaf e Ship.



**Figura 7: (a) Bloch; (b) Beehive; (c) Boat; (d) Loaf e (e) Ship.**

(MARTINS, 2010)

Os objetos oscilatórios são conjuntos de células dentro da grade que, dado um determinado período de tempo, voltam a suas formas originais. Dois exemplos desse tipo de forma são blinker (Figura 8a) e Toad (Figura 8b).



**Figura 8: Exemplos: a) Blinker; b) Toad (CASTRO; CASTRO, 2008).**

## 2.4 DESCRITORES DE IMAGENS

Descritores de imagens são usados para descrever características inerentes de uma determinada imagem. Os processos de descrição são baseados em informações de baixo nível, como, cor, textura e forma. Os parágrafos a seguir apresentam alguns dos extratores de características mais conhecidos.

O primeiro e um dos mais simples é o histograma global de cores (GCH) que gera um histograma para cada canal da imagem. O BIC (Border/Interior Pixel Classification) é um descritor de cor baseado em região. O algoritmo de extração classifica os pixels da imagem em pixels de borda ou interior. Um pixel é classificado como interior quando os seus vizinhos (acima, abaixo, esquerdo e direito) têm a mesma intensidade. Caso contrário, o pixel será classificado como um pixel de borda. Esse processo resulta em dois histogramas, um para pixels de borda e outro para pixels internos, e são armazenados como um único histograma com 128 posições (NIXON; S., 2013; LIU et al., 2021; STEHLING et al., 2002; PONTI; PICON, 2015).

Os momentos de cor de primeira ordem (FOMC) extraem valores estatísticos de cada canal do histograma, como média, desvio padrão, assimetria e curtose. A abordagem do Threshold Adjacency Statistics (TAS) cria uma pilha de imagens e os pixels acima de um determinado limite são contados, considerando o limite determinado (NIXON; S., 2013; GILIK et al., 2018; HAMILTON et al., 2007; TAHIR et al., 2018).

O Haralick é um descritor baseado em medidas estatísticas de segunda ordem que são calculadas a partir de matrizes de co-ocorrência para extrair características de textura (HARALICK et al., 1973; GHEISARI et al., 2018). De forma semelhante, o Local Binary Pattern (LBP) é um descritor utiliza uma máscara em toda a imagem para buscar diferentes padrões de textura (GUO et al., 2010; NGUYEN; NGUYEN, 2021). Os momentos de Zernike extrai características baseando-se na aplicação dos polinômios de Zernike em uma determinada imagem (KHOTANZAD; HONG, 1990; ZHANG; BAAN, 2022).

Existem extratores que se baseiam nas redes neurais convolucionais (CNNs). Várias CNNs foram propostas para descrever imagens, no entanto, essas abordagens exigem muitos dados e nem sempre é possível obtê-los. Algumas medidas podem amenizar esse e outros problemas, entretanto, para alcançar resultados satisfatórios o custo computacional pode aumentar consideravelmente, exigindo longas horas de treinamento. Exemplos de tais arquiteturas são Xception (CHOLLET, 2017), ResNet50V2 (HE et al., 2016), InceptionV3 (SZEGEDY et al., 2015) e InceptionResNetV2 (SZEGEDY et al., 2017).

### 3 MÉTODO PROPOSTO

Tomando como base o objetivo do trabalho e visando atingi-lo, este capítulo apresenta o método proposto bem como os detalhes intrínsecos envolvidos.

#### 3.1 PROPOSTA

Levando em conta o Jogo da Vida de Conway, esse trabalho tem como objetivo o desenvolvimento de um novo descritor de imagens (GofDesc). Para que isso seja possível, o trabalho propõe uma adaptação das regras particulares do jogo da vida no campo do processamento de imagens, de forma a extrair as características da imagem durante o processo.

A partir dos conceitos de processamento de imagens e autômatos celulares apresentados nas seções anteriores, este trabalho trata ambos os conceitos de maneira integrada considerando-os da seguinte forma:

- **Célula/Pixel:** Cada pixel da imagem será tratado como uma célula da grade;
- **Grade/Matriz de Pixels:** A grade será a matriz de pixels da imagem;
- **Estado/Intensidade:** Baseando-se no jogo da vida, cada célula possui apenas dois estados (vivo e morto). Esta proposta estende o conceito de estado, considerando a intensidade do pixel como um complemento para a análise. O pixel central da vizinhança (janela deslizante) sempre terá seu estado associado ao estado inicial estabelecido e sua intensidade definirá o estado dos pixels que fazem parte da vizinhança, ou seja, se o estado do pixel central é vivo e sua intensidade é 45, considerando apenas um canal, todos os vizinhos com intensidade 45 serão considerados vivos. O mesmo se aplica se o estado inicial

do pixel central é morto, neste caso, todos os vizinhos com a mesma intensidade serão considerados mortos. Dessa forma é possível contabilizar os pixels vivos e mortos e aplicar as regras do jogo da vida. Note que todo o processo é feito de forma separada para cada canal da imagem e por fim concatenados se houver mais de um canal.

- **Regras:** As regras do algoritmo são baseadas no jogo da vida, onde será considerada a vizinhança de Moore e as intensidades dos pixels para sua aplicação. Após a aplicação das regras, o comportamento obtido, ou seja, as transições de estado de cada célula serão armazenadas em seu respectivo vetor, representando as características da imagem. Apenas dois vetores são gerados por interação e qual deles será gerado depende do estado inicial estabelecido, conforme apresentado a seguir.

#### **Inicialmente Vivo**

- **IV-V (inicialmente vivo e permanece vivo):** estrutura composta pelo número de pixels inicialmente vivos e que permanecem vivos após a aplicação das regras;
- **IV-M (inicialmente vivo e torna-se morto):** estrutura composta pelo número de pixels inicialmente vivos e que tornaram-se mortos após a aplicação das regras;

#### **Inicialmente Morto**

- **IM-V (inicialmente morto e torna-se vivo):** estrutura composta pelo número de pixels inicialmente mortos e que se tornaram vivos após a aplicação das regras;
- **IM-M (inicialmente morto e permanece morto):** estrutura composta pelo número de pixels inicialmente mortos e que permaneceram mortos após a aplicação das regras.

O vetor representa o comportamento do pixel após a aplicação da regra e seu índice representa as possíveis intensidades que os pixels podem assumir. Quando as regras são aplicadas a um pixel, seu comportamento é observado e

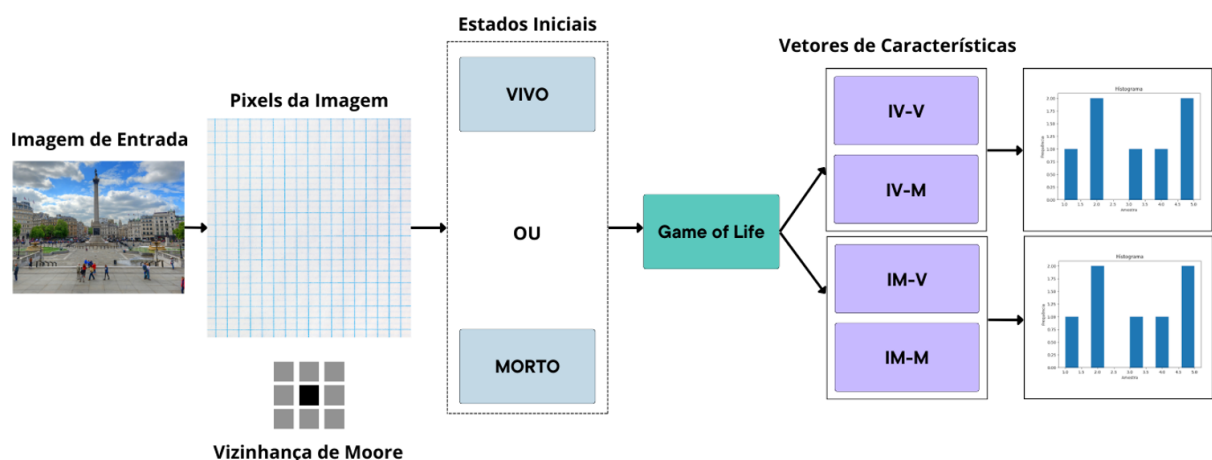
o vetor adequado é selecionado, após a seleção a intensidade do pixel definirá qual será a posição no vetor onde essa transição de estado deve ser registrada e então o valor nessa posição é incrementado.

- **Interações:** Diferente dos autômatos celulares que possuem várias interações para que uma determinada simulação possa ser observada o método proposto é realizado em uma única interação visando apenas a extração das características.

Antes de iniciar a etapa de extração de características é necessário se atentar a algumas variáveis que fazem parte do funcionamento do método ou mesmo que podem influenciar no resultado obtido.

O primeiro a ser mencionado é a vizinhança, embora os exemplos a seguir e experimentos sejam baseados na vizinhança de Moore (MELOTTI, 2009), nada impede que outras configurações sejam utilizadas. Vale lembrar que a escolha da vizinhança interfere diretamente no tempo de execução e desempenho do algoritmo.

O segundo é o estado inicial das células. O algoritmo só é capaz de trabalhar com base em um estado inicial por vez, portanto, em uma interação do algoritmo para um conjunto específico de imagens só serão gerados os vetores de características que representam a transição de estado considerando o estado inicial para seu estado alvo. A Figura 9 apresenta um fluxograma que ilustra as etapas envolvidas na extração das características.



**Figura 9: Fluxograma do método proposto**

Após definir a vizinhança e o estado inicial para aquela interação, as imagens

são submetidas ao GofDesc, o qual percorrerá toda a matriz de pixels das imagens e utilizando a vizinhança de Moore aplicará as regras do jogo da vida, resultando nos respectivos vetores de características (histogramas).

O método realiza a descrição de imagens com base na modificação do Jogo da Vida de Conway (um autômato celular bidimensional). Apesar de sua simplicidade, a abordagem proposta pode atingir uma alta complexidade comportamental.

Seja  $I(x,y) = p_i$  a intensidade do pixel com coordenadas cartesianas  $x$  e  $y$ , o intervalo de  $p_i$  é dado pela profundidade da imagem  $L = 2^b$  (por exemplo,  $b = 8$  leva a  $p_i = 0, \dots, 255$ ). O método modifica as regras do jogo da vida de Conway para considerar as informações de intensidade do pixel em cada iteração de transição de estado. Considera-se a seguinte notação para rotular cada pixel:

- $\phi_{estadoFinal}$  - quando o estado inicial é “vivo”;
- e  $\psi_{estadoFinal}$  - quando o estado inicial for “morto”.

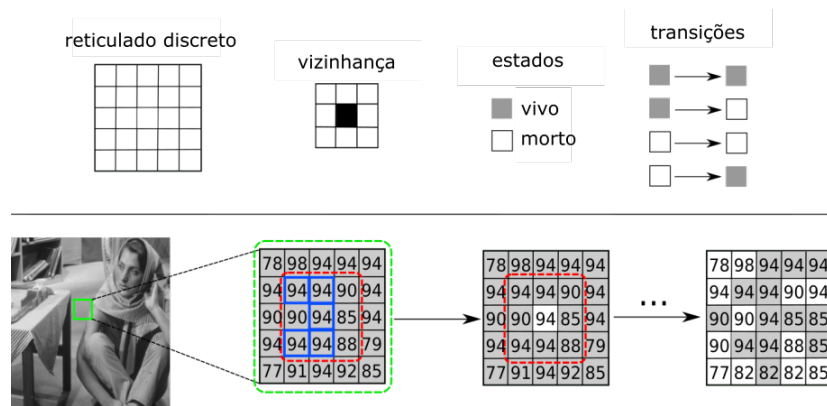
onde *estadoFinal* denota o estado obtido após a aplicação das regras do Jogo da Vida. A abordagem rotula um pixel como  $\phi_{Morto}$  quando seu estado inicial é “vivo” e o próximo estado (obtido após a aplicação das regras modificadas do Jogo da Vida) é “morto”. É possível combinar os vetores de características, gerando combinações de vetores de características diferentes. As Equações 3 e 5 ilustram algumas dessas combinações.

$$\vec{\Phi} = [\vec{\phi}_{Vivo}, \vec{\phi}_{Morto}] \quad (3)$$

$$\vec{\Psi} = [\vec{\psi}_{Vivo}, \vec{\psi}_{Morto}] \quad (4)$$

$$\vec{\Gamma} = [\vec{\Phi}_{Vivo}, \vec{\Psi}_{Morto}] \quad (5)$$

A Figura 10 mostra um exemplo da aplicação da abordagem proposta sobre um fragmento de imagem, considerando que todas as células estão inicialmente “vivas”.



**Figura 10: Exemplo do método proposto iterando sobre um fragmento de uma imagem.**

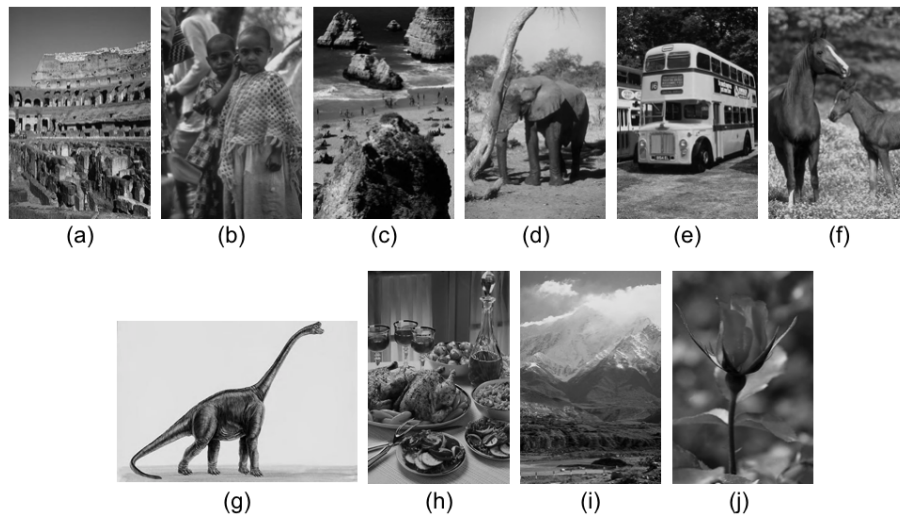
### 3.2 EXPERIMENTOS

Os experimentos foram baseados em dois *datasets* (conjuntos de dados) de imagens públicas, denominados Corel1k e PapSmear. O Corel-1k é composto por 1000 imagens naturais, compreendendo dez classes balanceadas (100 imagens por classe), com uma dimensão média de 384x256 pixels e uma profundidade de 8 bits. A Tabela 1 apresenta as classes e o número de amostras por classe para o Corel-1k, e a Figura 11 mostra alguns exemplos de imagens de cada classe: (a) Edifício, (b) África, (c) Praia, (d) Elefante, (e) Ônibus, (f) Cavalo, (g) Dinossauro, (h) Comida, (i) Montanha e (f) Flor.

**Tabela 1: Descrição do conjunto de dados Corel-1k.**


Classes	Images
Edifício	100
África	100
Praia	100
Elefante	100
Ônibus	100
Cavalo	100
Dinossauro	100
Comida	100
Montanha	100
Flor	100

O repositório PapSmear consiste em 907 imagens de células de Papanicolau para detectar câncer de colo do útero. O método de Papanicolaou é um exame para detectar células cancerosas no colo do útero. As imagens foram capturadas com resolução de 0,201 $\mu$ m/pixel e tamanho médio de 150x140 pixels. Elas foram



**Figura 11: Exemplos de cada classe de imagem no conjunto de dados Corel-1k.**

classificadas de acordo com sua categoria (normal ou anormal) e tipos de células (7 classes) por médicos e citotécnicos do Hospital Universitário de Herlev. Em caso de discordância entre os médicos com relação à classificação, a imagem era descartada. A Tabela 2 apresenta a categoria, os tipos de células e o número de amostras para cada problema de classificação (ou seja, categoria e tipo de célula). A Figura 12 ilustra exemplos de imagens do conjunto de dados PapSmear: (a) Epitélio Escamoso Superficial, (b) Epitélio Escamoso Intermediário, (c) Epitelial Colunar, (d) Displasia Escamosa não Queratinizante Leve, (e) Displasia Escamosa não Queratinizante Moderada, (f) Displasia Escamosa não Queratinizante Grave e (g) Carcinoma de Células Escamosas in Situ Intermediário.



**Figura 12: Exemplos de cada classe de imagem no conjunto de dados PapSmear.**

Com o objetivo de comparar a solução proposta com o estado-da-arte, foram selecionados os descritores mostrados na Tabela 3. Tais descritores utilizam diferentes abordagens para extrair as características da imagem. Os parâmetros iniciais de alguns métodos foram obtidos de arquiteturas pré-treinadas no *dataset* ImageNet usando a técnica de transferência de aprendizado.

No processo de avaliação, os recursos obtidos de diferentes extratores foi



**Tabela 2: Descrição do conjunto de dados do PapSmear.**

<b>Categoria</b>	<b>Tipo de Célula</b>	<b>Num. Imagens</b>	<b>Total de Imagens por Categoria</b>
Normal	Epitélio Escamoso Superficial	74	242
	Epitélio Escamoso Intermediário	70	
	Epitelial Colunar	98	
Abnormal	Displasia Escamosa não Queratinizante Leve	182	675
	Displasia Escamosa Moderada não Queratinizante	146	
	Displasia Escamosa não Queratinizante Grave	197	
	Carcinoma Espinocelular in Situ Intermediário	150	

**Tabela 3: Propriedades de cada extrator de características aplicado aos conjuntos de dados.**

<b>Extratores de Características</b>	<b>Categoria</b>	<b>#Features</b>
GCH (Global Color Histogram) (NIXON; S., 2013)	Color	768
Border-Interior Classification (STEHLLING et al., 2002)	Color	128
First Order Color Moments(NIXON; S., 2013)	Texture	24
Threshold Adjacency Statistics(HAMILTON et al., 2007)	Texture	162
Haralick (HARALICK et al., 1973)	Texture	13
Rotation Invariant LBP (GUO et al., 2010)	Texture	352
Zernike Moments (KHOTANZAD; HONG, 1990)	Shape	72
Xception (CHOLLET, 2017)	Generic	2048
ResNet50V2 (HE et al., 2016)	Generic	2048
InceptionV3 (SZEGEDY et al., 2015)	Generic	2048
InceptionResNetV2 (SZEGEDY et al., 2017)	Generic	1536
Método Proposto	Color, Texture, Shape	768;1536

aplicado a diferentes classificadores supervisionados (kNN, BayesNet, J4.8 e Random Forest). Considerando as fases de treinamento e teste, foi utilizada a estratégia de validação cruzada estratificada de 10 vezes para obter uma validação estatística e a generalização do modelo de aprendizado. Foram executados todos os classificadores com seus parâmetros padrão de acordo com suas publicações originais. Todas as imagens foram processadas considerando o espaço de cores RGB.

### 3.2.1 RESULTADOS E DISCUSSÕES

As Tabelas 4 e 5 mostram os resultados considerando os *datasets* Corel-1k e Papsmear. De acordo com a Tabela 4, é possível observar que o método proposto apresenta os melhores resultados não apenas de acordo com cada classificador, mas também a melhor acurácia (83,90%). O método apresenta ganhos de até 36% quando comparados às características profundas (*deep features*). Além disso, o vetor de

características obtido apresentou, nesse caso, 1536 dimensões, enquanto as *deep features* geralmente têm 2048 dimensões ou mais. Esse mesmo comportamento foi observado em relação às características handcrafted, em que o descritor proposto obteve ganhos de até 83%.

A combinação  $\phi_{Morto}$  com o classificador KNN, obteve melhores resultados que GCH, BIC, Haralick, LBP, Zernike, Xception, InceptionV3, InceptionResNetV2 e resultado similar à ResNet50V2, considerando o mesmo classificador. Além disso, essa combinação fornece um vetor de características com 768 dimensões (256 recursos para cada canal de cor - espaço de cor RGB). Considerando os classificadores BayesNet, J4.8 e Random Forest, a combinação simples  $\psi_{Morto}$  também apresentou bons resultados, superiores a todos as outras características profundas e handcrafted.

Comparando os resultados de cada classificador, o método proposto alcançou precisão de 77,40% com o BayesNet, enquanto as melhores características handcrafted (GCH) e profundas (Xception) alcançaram 68,10% e 62,10%, respectivamente. Portanto, a abordagem proposta supera as características handcrafted e profundas, considerando todos os classificadores.

A Tabela 5 ilustra os resultados obtidos com o *dataset* Papsmear. A abordagem proposta com a combinação  $\vec{\phi}_{Morto} \oplus \vec{\psi}_{Vivo}$  apresentou os melhores resultados considerando todos os classificadores. Com o Random Forest, por exemplo, foi obtida precisão de 73,30%, enquanto os melhores extratores handcrafted (GCH) e profundos (ResNet50V2) alcançaram, respectivamente, precisões de 58,81% e 53,54%.

Considerando o melhor resultado geral da abordagem proposta (73,30%), os ganhos de acurácia obtidos foi de até 73% e 51% em relação às características handcrafted e profundas, respectivamente. Além disso, de acordo com os resultados, a precisão alcançada foi 55,90% com o classificador J4.8, contra 45,36% das melhores características handcrafted (FOMC) e 35,11% das melhores características profundas (ResNet50V2).

A análise da combinação  $\psi_{Vivo}$  com o classificador BayesNet mostra 53,35%

**Tabela 4: Resultados do Corel-1k. Os valores em negrito representam os melhores resultados de acordo com cada classificador, e o valor sublinhado mostra o melhor resultado geral.**

		Accurácia (%)			
		Combinação	kNN	BayesNet	J4.8
Método Proposto	$\vec{\Psi}_{Morto}$	68.30	74.40	<b>66.90</b>	81.60
	$\vec{\Psi}_{Vivo}$	57.40	65.00	53.60	73.80
	$\vec{\phi}_{Morto}$	68.40	73.00	66.90	82.30
	$\vec{\phi}_{Vivo}$	60.20	67.60	54.10	75.90
	$\vec{\phi}_{Morto} \oplus \vec{\Psi}_{Morto}$	68.30	73.50	66.50	82.00
	$\vec{\phi}_{Morto} \oplus \vec{\Psi}_{Vivo}$	<b>70.30</b>	77.20	63.00	<b>83.90</b>
	$\vec{\phi}_{Vivo} \oplus \vec{\Psi}_{Morto}$	68.90	75.80	63.80	<b>83.90</b>
	$\vec{\phi}_{Vivo} \oplus \vec{\Psi}_{Vivo}$	59.60	67.90	55.20	76.20
	$\vec{\phi}_{Morto} \oplus \vec{\phi}_{Vivo}$	69.30	<b>77.40</b>	64.50	83.50
	$\vec{\phi}_{Morto} \oplus \vec{\Psi}_{Morto}$	69.50	76.30	65.40	83.30
	$\vec{\phi}_{Vivo} \oplus \vec{\Psi}_{Morto}$	68.90	76.00	64.70	83.20
	Handcrafted Features	GCH	65.60	68.10	61.50
BIC		55.70	69.60	56.30	75.10
FOMC		63.60	58.10	59.30	70.80
TAS		67.50	62.50	59.60	73.80
Haralick		54.70	51.90	55.40	62.70
LBP		67.20	51.30	52.50	71.70
Zernike		10.50	15.40	12.60	14.50
Deep Features	Xception	61.60	62.10	51.30	68.90
	ResNet50V2	56.40	55.10	45.40	60.50
	InceptionV3	49.20	37.60	37.00	56.10
	InceptionResNetV2	45.90	36.10	39.40	53.50

de acurácia, superior a todos os outros extratores handcrafted e profundos. Obteve-se o mesmo comportamento com a combinação de  $\vec{\phi}_{Morto}$  e o classificador RF, apresentando acurácia de 58,62%, desempenho similar ao GCH.

Ao analisar os extratores de características, o GCH apresentou resultados relevantes considerando o BayesNet, o J4.8 e o Random Forest. O classificador KNN em conjunto com o TAS também apresentou bons resultados, no entanto, inferiores aos obtidos pela abordagem proposta.

Considerando apenas as características profundas e o *dataset* Corel-1k, a arquitetura Xception obteve bons resultados para todos os classificadores. Analisando os resultados obtidos com o Papsmear, a arquitetura ResNet50V2 obteve bons resultados. No entanto, esses resultados foram inferiores aos obtidos pela abordagem proposta.

Considerando o *dataset* Corel-1k (Tabela 5), o novo descritor com a combinação  $\psi_{Morto}$  atingiu 74,40% de precisão com o classificador BayesNet, enquanto a arquitetura Xception apresentou precisão de 62,10%. A combinação  $\psi_{Morto}$  compreende um vetor de recursos com apenas 768 dimensões, enquanto a arquitetura Xception apresenta um vetor de recursos com 2048 características. Resultados similares foram observados em relação às características handcrafted.

A solução apresentada neste trabalho baseia-se na criação de histogramas com base nas políticas de autômato celular modificadas para análise de pixels. Dessa forma, o algoritmo tem complexidade de tempo linear ( $O(n)$ ), considerando  $n$  pixels de uma determinada imagem.

Para obter uma comparação justa, nos experimentos, foi utilizada uma instância com vizinhança de 8 para analisar os pixels, como o LBP e o BIC. Entretanto, destaca-se que a abordagem permite o uso de diferentes vizinhanças (por exemplo, vizinhança de 4). O novo descritor também pode considerar um limite de similaridade para aplicar as políticas propostas. Nos experimentos, foram considerados a extração de características rígida (comparação absoluta entre a intensidade do pixel e as intensidades de sua vizinhança) para fazer uma comparação justa com os outros extratores de características.

Tabela 5: Resultados do exame de Papanicolau. Os valores em negrito representam os melhores resultados de acordo com cada classificador, e o valor sublinhado mostra o melhor resultado geral.

		Accurácia (%)				
		Combinação	kNN	BayesNet	J4.8	RF
Método Proposto	$\vec{\Psi}_{Morto}$		45.15	45.24	43.92	58.34
	$\vec{\Psi}_{Vivo}$		38.64	53.35	40.34	55.70
	$\vec{\Phi}_{Morto}$		45.33	45.33	45.15	58.62
	$\vec{\Phi}_{Vivo}$		41.28	48.07	43.54	56.27
	$\vec{\Phi}_{Morto} \oplus \vec{\Psi}_{Morto}$		45.15	45.52	43.45	58.15
	$\vec{\Phi}_{Morto} \oplus \vec{\Psi}_{Vivo}$		<b>54.40</b>	<b>66.10</b>	<b>55.90</b>	<b>73.30</b>
	$\vec{\Phi}_{Vivo} \oplus \vec{\Psi}_{Morto}$		45.62	50.14	44.77	60.04
	$\vec{\Phi}_{Vivo} \oplus \vec{\Psi}_{Vivo}$		42.22	52.97	42.41	57.49
	$\vec{\Phi}_{Morto} \oplus \vec{\Phi}_{Vivo}$		44.58	52.87	42.41	60.89
	$\vec{\Phi}_{Morto} \oplus \vec{\Psi}_{Morto}$		44.96	51.18	42.79	59.28
	$\vec{\Phi}_{Vivo} \oplus \vec{\Psi}_{Morto}$		45.81	52.03	42.70	61.55
	Handcrafted Features	GCH		44.86	47.31	45.33
BIC			44.49	45.03	43.94	56.92
FOMC			49.83	44.92	45.36	55.50
TAS			53.21	47.98	40.56	56.92
Haralick			38.28	30.20	35.00	40.45
LBP			38.27	41.65	36.64	46.89
Zernike			17.88	23.22	16.68	20.17
Deep Features	Xception		36.20	35.33	27.26	39.69
	ResNet50V2		45.36	39.14	35.11	53.54
	InceptionV3		40.13	29.22	34.35	46.12
	InceptionResNetV2		30.75	24.31	26.71	36.31

## 4 CONCLUSÃO

Este trabalho apresenta uma abordagem que aplica a teoria do autômato celular para extrair recursos de imagens. Para isso, a descrição da imagem ocorre com base no Jogo da Vida de Conway (um autômato celular bidimensional). Apesar de sua simplicidade, a abordagem foi capaz de atingir alta complexidade comportamental devido às propriedades intrínsecas dos CAs.

Com base nos experimentos, observa-se que a abordagem proposta aumenta a precisão do processo de classificação de imagens. A precisão alcançada (83%) supera as obtidas por soluções que representam o estado-da-arte. Como perspectivas de trabalhos futuros, pretende-se realizar experimentos com outras arquiteturas e aplicar outras técnicas de pré-processamento. Além disso, a abordagem proposta pode ser avaliada em imagens com diferentes graus de quantização e métricas.

## REFERÊNCIAS

- CASTRO, M.; CASTRO, R. Autômatos celulares: implementações de von neumann, conway e wolfram. In: . [S.l.]: Revista de Ciências Exatas e Tecnologia, 2008. v. 3.
- CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. In: **IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2017. p. 1800–1807.
- COOPER, G.; WILLCOCK, S.; DEARING, J. Regime shifts occur disproportionately faster in larger ecosystems. In: . [S.l.]: Nature Communications 11, 2020.
- EDELSTEIN-KESHET, L. How the lizard gets its speckled scales. In: . [S.l.]: Nature 544, 2017. p. 170–171.
- GHEISARI, S.; CATCHPOOLE, D. R.; CHARLTON, A.; MELEGH, Z.; GRADHAND, E.; KENNEDY, P. J. Computer aided classification of neuroblastoma histological images using scale invariant feature transform with feature encoding. **Diagnostics**, v. 8, n. 3, 2018.
- GILIK, A.; DEMIR, K.; OZMEN, A. Rgb color based occupancy rate detection of indoor spaces. In: **26th Signal Processing and Communications Applications Conference**. [S.l.: s.n.], 2018. p. 1–4.
- GONCALVES, R.; CENTENO, T.; CELLERON, G. Modelagem preditiva a partir de uma sequência de imagens de satélite utilizando autômatos celulares. In: . [S.l.]: XI Simpósio Brasileiro de Sensoriamento Remoto, 2003. v. 1, p. 975–981.
- GONZALEZ, R.; WOODS, R. **Processamento Digital de Imagens**. [S.l.]: Pearson Education, 2008.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, MA, USA: MIT Press, 2016. <http://www.deeplearningbook.org>.
- GUO, Z.; ZHANG, L.; ZHANG, D. Rotation invariant texture classification using LBP variance (LBPV) with global matching. **Pattern Recognition**, Elsevier, v. 43, n. 3, p. 706–719, 2010.
- HAMILTON, N.; PANTELIC, R.; HANSON, K.; TEASDALE, R. Fast automated cell phenotype classification. **BMC bioinformatics**, v. 8, p. 110, 03 2007.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-3, n. 6, p. 610–621, 1973. ISSN 0018-9472.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Identity mappings in deep residual networks. In: LEIBE, B.; MATAS, J.; SEBE, N.; WELLING, M. (Ed.). **European Conference on Computer Vision**. [S.l.: s.n.], 2016. p. 630–645.

KHOTANZAD, A.; HONG, Y. H. Invariant image recognition by zernike moments. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 12, n. 5, p. 489–497, 1990.

LIU, B.; ZHONG, H.; XIAO, Y. New multi-view classification method with uncertain data. **ACM Transactions on Knowledge Discovery from Data**, Association for Computing Machinery, v. 16, n. 1, p. 1–23, 2021.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**. [S.l.]: Brasport, 1999.

MARTINS, C. Autômato celular aplicado no crescimento de câncer. In: . [S.l.]: Dissertação (Mestrado em Física) - UNIVERSIDADE ESTADUAL DE PONTA GROSSA, Ponta Grossa, 2010.

MELOTTI, G. Aplicação de autômatos celulares em sistemas complexos: Um estudo de caso em espalhamento de epidemias. In: . [S.l.: s.n.], 2009. v. 23, n. 4.

NEUMANN, J. von. The general and logical theory of automata. In: . [S.l.]: Cerebral Mechanisms in Behavior: The Hixon Symposium, 1951. p. 1–41.

NGUYEN, T. T.; NGUYEN, T. P. A comprehensive taxonomy of dynamic texture representation. **ACM Computing Surveys**, Association for Computing Machinery, New York, NY, USA, v. 55, n. 1, 2021.

NIXON, M. S.; S., A. A. **Feature extraction & image processing for computer vision**. [S.l.]: Elsevier, 2013.

PAUL-GILLOTEAUX, P.; POTIRON, V.; DELPON, G.; SUPIOT, S.; CHIAVASSA, S.; PARIS, F.; COSTES, S. Optimizing radiotherapy protocols using computer automata to model tumour cell death as a function of oxygen diffusion processes. In: . [S.l.]: Sci Rep 7, 2017.

PONTES-FILHO, S.; LIND, P.; YAZIDI, A.; ZHANG, J.; HAMMER, H.; MELLO, G.; SANDVIG, I.; TUFTE, G.; NICHELE, S. A neuro-inspired general framework for the evolution of stochastic dynamical systems: Cellular automata, random boolean networks and echo state networks towards criticality. In: **Cognitive Neurodynamics**. [S.l.: s.n.], 2020.

PONTI, M.; PICON, C. T. Color description of low resolution images using fast bitwise quantization and border-interior classification. In: **IEEE International Conference on Acoustics, Speech and Signal Processing**. [S.l.: s.n.], 2015. p. 1399–1403.

REITE, A. C. A local cellular model for snow crystal growth. In: . [S.l.]: Chaos, Solitons & Fractals, Easton - PA, 2005. v. 23, n. 4, p. 1111–1119.

SCURI, A. Fundamentos da imagem digital. 01 1999.

STEHLING, R. O.; NASCIMENTO, M. A.; FALCÃO, A. X. A compact and efficient image retrieval approach based on border/interior pixel classification. In: **International Conference on Information and Knowledge Management**. [S.l.: s.n.], 2002. p. 102–109.



SZEGEDY, C.; IOFFE, S.; VANHOUCKE, V.; ALEMI, A. A. Inception-v4, inception-resnet and the impact of residual connections on learning. In: **Proceedings of the 31st AAAI Conference on Artificial Intelligence**. [S.l.]: AAAI Press, 2017. p. 4278–4284.

SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCKE, V.; RABINOVICH, A. Going deeper with convolutions. In: **IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2015. p. 1–9.

TAHIR, M.; JAN, B.; HAYAT, M.; SHAH, S. U.; AMIN, M. Efficient computational model for classification of protein localization images using extended threshold adjacency statistics and support vector machines. In: **Computer Methods and Programs in Biomedicine**. [S.l.: s.n.], 2018. v. 157, p. 205–215.

TANGSAKUL, S.; WONGTHANAVASU, S. Single image haze removal using deep cellular automata learning. In: . [S.l.: s.n.], 2020. v. 8, p. 103181–103199.

TANGSAKUL, S.; WONGTHANAVASU, S. Deep cellular automata-based feature extraction for classification of the breast cancer image. In: . [S.l.: s.n.], 2023.

ULAM, S. Random processes and transformations. In: . [S.l.]: In Proceedings of the International Congress of Mathematicians, 1950. p. 264–275.

VILLELA, S.; CARVALHO, L. O resfriamento simulado no projeto ótimo de autômatos celulares para a geração de chaves em criptografia de fluxo. In: . [S.l.]: XXVII Congresso da Sociedade Brasileira de Computação, 2003. p. 1082–1091.

ZHANG, C.; BAAN, M. van der. Seismic signal matching and complex noise suppression by zernike moments and trilateral weighted sparse coding. **IEEE Transactions on Geoscience and Remote Sensing**, v. 60, p. 1–10, 2022.

