
**Abordagem evolutiva para o ajuste automático
dos parâmetros de um modelo de propagação de
incêndios baseado em autômatos celulares**

Victor Hugo Martins Alves



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
BACHARELADO EM SISTEMAS DE INFORMAÇÃO

Uberlândia
2024

Victor Hugo Martins Alves

**Abordagem evolutiva para o ajuste automático
dos parâmetros de um modelo de propagação de
incêndios baseado em autômatos celulares**

Trabalho de Conclusão de Curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia como parte dos requisi-
tos para a obtenção do título de Bacharel em
Sistemas de Informação.

Área de concentração: Sistemas de Informação

Orientador: Luiz Gustavo Almeida Martins

Uberlândia

2024

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
BACHARELADO EM SISTEMAS DE INFORMAÇÃO

Os abaixo assinados, por meio deste, certificam que leram e recomendam para a Faculdade de Computação a aceitação da monografia intitulada “**Abordagem evolutiva para o ajuste automático dos parâmetros de um modelo de propagação de incêndios baseado em autômatos celulares**” por **Victor Hugo Martins Alves** como parte dos requisitos exigidos para a obtenção do título de **Bacharel em Sistemas de Informação**.

Uberlândia, ___ de _____ de _____

Orientador: _____
Prof. Dr. Luiz Gustavo Almeida Martins
Universidade Federal de Uberlândia

Banca Examinadora:

Prof. Dr. Claudiney Ramos Tinoco
Universidade Federal de Uberlândia

Prof. Dr. Thiago Fialho de Queiroz Lafeta
Universidade Federal de Uberlândia

Esse trabalho é dedicado aos meus avós que, enquanto em vida, me apoiaram de todas as maneiras possíveis e aos meus pais que me incentivaram e deram oportunidade de crescimento.

Agradecimentos

Gostaria de expressar minha gratidão ao meu orientador Luiz Gustavo, que não apenas me forneceu o apoio necessário, mas também compartilhou comigo grande parte do conhecimento essencial para a construção e evolução deste trabalho.

À minha mãe Claudia, que esteve ao meu lado em todos os momentos, oferecendo suporte e motivação incondicionais.

Ao meu pai Hudson, cuja orientação e apoio foram fundamentais durante grande parte dessa jornada.

À minha irmã Andressa, que está me apoiando em todos os momentos.

À minha namorada Nicole, que sempre que precisava, me acalmava e me ajudava a enxergar um caminho para seguir.

Aos meus amigos, em especial ao Pedro Henrique e Guilherme Dias, que estiveram comigo desde a primeira semana de aula, compartilhando cada matéria e desafio.

E ,por fim, aos professores da FACOM-UFU, cuja dedicação e ensinamentos foram essenciais para moldar o profissional e a pessoa que me tornei.

*“Se o conhecimento pode criar problemas, não é através da ignorância que podemos
solucioná-los.”
(Isaac Asimov)*

Resumo

Os incêndios florestais representam uma crescente preocupação global, afetando o meio ambiente e a saúde pública. Para diminuir seus impactos, é essencial compreender a dinâmica de propagação do fogo e desenvolver estratégias eficazes para o seu combate. Este trabalho aborda a construção de um algoritmo genético para o ajuste automático dos parâmetros de um modelo de propagação de incêndio baseado em autômatos celulares, visando replicar padrões observados em dados históricos de incêndios florestais. O estudo se fundamenta na reprodução do modelo de propagação de incêndios presente na literatura, e na implementação de um algoritmo genético capaz de otimizar os parâmetros do modelo de simulação, que é uma tarefa bastante complexa para ser realizada manualmente. Os resultados obtidos validaram a eficácia dessa abordagem evolutiva, demonstrando que, mesmo quando os valores ótimos não eram totalmente alcançados, as simulações mantinham uma representação fiel da dispersão do fogo. A análise do desempenho do algoritmo revelou que o método pode ser aplicado em diversas situações reais, contribuindo para a elaboração de estratégias de combate a incêndios mais eficazes. Este trabalho aponta direções claras para futuras investigações sobre a simulação de incêndios, e propõe melhorias como o aprimoramento da definição dos tipos de células e dos parâmetros de recuperação, visando uma modelagem ainda mais precisa e eficaz.

Palavras-chave: Incêndios Florestais. Autômato Celular. Algoritmo Genético. Computação Evolutiva. Ajustes de Parâmetros. Otimização.

Abstract

Wildfires are a growing global concern, impacting both the environment and public health. To mitigate these effects, it is crucial to understand the dynamics of fire spread and to develop effective firefighting strategies. This study presents the construction of a genetic algorithm for the automatic adjustment of parameters in a wildfire propagation model based on cellular automata, with the goal of replicating patterns observed in historical wildfire data. The research builds on a wildfire propagation model from the literature and implements a genetic algorithm capable of optimizing simulation parameters, an otherwise highly complex task to perform manually. The results validated the effectiveness of this evolutionary approach, demonstrating that, even when optimal values were not fully achieved, the simulations produced a faithful representation of fire spread. The analysis of the algorithm's performance indicates that this method can be applied to a range of real-world scenarios, contributing to the design of more effective firefighting strategies. This work outlines clear directions for future research on wildfire simulation, including proposed enhancements such as refining cell type definitions and recovery parameters to achieve even greater accuracy and efficacy in modeling.

Keywords: Wildfires. Cellular Automata. Genetic Algorithm. Evolutionary Computation. Parameter Adjustment. Optimization.

Lista de ilustrações

Figura 1 – Exemplos de Dimensões do Reticulado (WOLFRAM et al., 2002). . . .	28
Figura 2 – Exemplo de vizinhanças em um Autômato Celular (AC) Bidimensional.	29
Figura 3 – Regra 30 (WOLFRAM et al., 2002).	30
Figura 4 – Exemplo de regra de transição Probabilística (WOLFRAM et al., 2002).	31
Figura 5 – Fluxograma geral de Algoritmo Genético.	32
Figura 6 – Exemplo de propagação de um incêndio [Extrado de Tinoco et al. (2022)].	39
Figura 7 – Exemplo de propagação de um incêndio [Extraído de Louzada e Junior (2008)].	40
Figura 8 – Representação de dois indivíduos [Extraído de Ferreira (2023)].	41
Figura 9 – Representação de um indivíduo [Adaptado de Fraga, Oliveira e Martins (2021)].	43
Figura 10 – Estados do AC.	46
Figura 11 – Matriz com vento Noroeste.	47
Figura 12 – Execução da simulação base.	49
Figura 13 – Representação do Indivíduo.	51
Figura 14 – Execução com a Base de Referência.	58
Figura 15 – Execução com o Indivíduo (Avaliação 10 <i>Time Steps</i> ou Passos de Tempo (TS)).	59
Figura 16 – Execução com o Indivíduo (Avaliação 1 TS).	59
Figura 17 – Valores do Indivíduo Base.	59
Figura 18 – Valores do Indivíduo (Avaliação 10 TS).	59
Figura 19 – Valores do Indivíduo (Avaliação 1 TS).	59
Figura 20 – Execução da Base de Referência.	60
Figura 21 – Execução do Indivíduo (Avaliação 1 TS com células queimadas).	60
Figura 22 – Valores do Indivíduo Base.	61
Figura 23 – Valores do Indivíduo (Avaliação 1 TS células queimada).	61
Figura 24 – Execução da Base de Referência.	62
Figura 25 – Execução do Indivíduo (Avaliação Média Geométrica).	62

Figura 26 – Valores do Indivíduo Base.	62
Figura 27 – Valores do Indivíduo (Avaliação Média Geométrica).	62
Figura 28 – Execução do Indivíduo Base (Análise 1).	63
Figura 29 – Execução do Indivíduo (Análise 1).	63
Figura 30 – Execução do Indivíduo Base (Análise 2).	64
Figura 31 – Execução do Indivíduo (Análise 2).	64
Figura 32 – Execução do Indivíduo Base (Análise 3).	65
Figura 33 – Execução do Indivíduo (Análise 3).	65

Lista de tabelas

Tabela 1 – Dados da Execução - Periodicidade.	57
Tabela 2 – Dados da Execução - Tipos de Células.	60
Tabela 3 – Dados da Execução - Média Geométrica.	61

Lista de siglas

AC Autômato Celular

AG Algoritmo Genético

TS *Time Steps* ou Passos de Tempo

Sumário

1	INTRODUÇÃO	23
1.1	Motivação	25
1.2	Objetivos	25
1.3	Justificativa	26
1.4	Método	26
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Autômato Celular	27
2.1.1	Células e Reticulado	28
2.1.2	Vizinhança	29
2.1.3	Estados	29
2.1.4	Regras de Transição	30
2.2	Algoritmo Genético	31
2.2.1	Indivíduo	32
2.2.2	Função de Aptidão	33
2.2.3	Seleção	33
2.2.4	Recombinação	34
2.2.5	Mutação	34
2.2.6	Reinserção	35
2.2.7	Critério de Parada	35
3	TRABALHOS CORRELATOS	37
3.1	Modelos de Propagação de Incêndio	37
3.1.1	Modelo Tinoco et al. (2022)	38
3.1.2	Modelo Louzada e Ferreira Junior (2008)	39
3.2	Algoritmos Genéticos no Ajuste Automático de Autômatos Ce- lulares	40
3.2.1	Modelo Ferreira (2023)	41

3.2.2	Modelo FRAGA, OLIVEIRA e MARTINS (2021)	42
4	MODELO DE PROPAGAÇÃO DE INCÊNDIOS	45
4.1	Estados do Modelo	45
4.2	Regras de Transição	46
4.3	Matriz de Combustão	47
4.4	Função de Recuperação	47
4.5	Parâmetros a serem ajustados pelo AG	48
4.6	Execução com os Parâmetros Base	48
5	ABORDAGEM EVOLUTIVA PROPOSTA	51
5.1	Indivíduo	51
5.2	Função de Avaliação	51
5.2.1	Cálculo do <i>Fitness</i>	52
5.3	Configuração do AG	53
6	EXPERIMENTOS E ANÁLISES	55
6.1	Base de Dados de Referência	55
6.2	Experimentos Preliminares	56
6.3	Análise da Configuração do AG	57
6.3.1	Avaliação da Periodicidade	57
6.3.2	Avaliação de Tipos de Células	59
6.3.3	Avaliação da Melhor Média	61
6.4	Análise de Desempenho do AG	62
7	CONCLUSÃO	67
	REFERÊNCIAS	69

Introdução

Os incêndios florestais são fenômenos naturais que auxiliam na manutenção de muitos ecossistemas (PAUSAS; KEELEY, 2019). Entretanto, nos últimos anos, as mudanças climáticas e os desmatamentos provenientes da intervenção humana, intensificaram significativamente a quantidade de incêndios, ocasionando problemas para o meio ambiente e a saúde pública (TINOCO et al., 2022). Para lidar com essa adversidade, é fundamental o conhecimento da dinâmica de propagação do fogo, a fim de desenvolver estratégias eficazes e capazes de mitigar seus impactos.

Os ecossistemas, como o cerrado, pradarias, chapadas e florestas, possuem como parte do seu processo natural o fogo para regeneração do habitat. Ele permite que sementes germinem, outras plantas brotem e, conseqüentemente, os animais dependentes delas tenham oportunidades de perpetuar no meio. Isso acontece, principalmente, pelo fogo aumentar a biodiversidade através de um processo evolutivo, por seleção natural e ecológico, via ampliação da heterogeneidade do habitat (PAUSAS; KEELEY, 2019).

As queimadas não naturais, por sua vez, quando não controladas, podem se espalhar para grandes áreas e se tornarem de longa duração (MEDEIROS; FIEDLER, 2004). Elas provocam a diminuição na quantidade de chuva devido à fuligem que se junta às nuvens, o que aumenta a absorção da radiação e acelera o processo de evaporação, fazendo com que não se atinja o ponto de saturação necessário para a precipitação (ARTAXO et al., 2006). Além disso, esse tipo de incêndio é nocivo ao habitat, deixando o ambiente sem vida, prejudicando as plantas e os animais. Já para os seres humanos que moram nas proximidades, ela pode intensificar os problemas respiratórios, como bronquite, asma e infecções, problemas no coração, alergias, intoxicações e aumentar a incidência de câncer (GONÇALVES; CASTRO; HACON, 2012).

Para combater incêndios florestais, podem ser utilizados desde processos mais simples, como lançar areia e água, até técnicas mais sofisticadas, como a utilização do iodeto de prata para induzir nuvens de chuva na região (MALIK et al., 2018). Além disso, podem ser criados aceiros que impedem o fogo de se espalhar pelo material vegetal (MEDEIROS; FIEDLER, 2004). Durante esse processo, a brigada anti-incêndio e a equipe aérea devem

se aproximar da região para a realizar o combate. Para identificar o local de atuação que seja efetivo e seguro, é de extrema importância conhecer como o fogo se espalha na área. Devido a incompreensão dessa dinâmica, já ocorreram tragédias com a equipe de combate, como a morte de bombeiros florestais que, durante uma incursão, perderam a comunicação, ficaram desorientados e foram tomados pelo fogo (ROTHERMEL, 1993).

Autômato Celular (AC) é um sistema dinâmico discreto que pode ser utilizado para modelar diversos fenômenos, como a propagação de vetores de doenças (FRAGA; OLIVEIRA; MARTINS, 2021), a dinâmica de fluidos na física (ROTHMAN; KELLER, 1988) e até mesmo o crescimento urbano (ABURAS et al., 2016). Ele é formado por um reticulado de células, cujo os valores são definidos a partir de um conjunto finito de estados. A dinâmica do AC é determinada por regras de transição, as quais determinam como ocorre a mudança do estado de uma célula, a cada passo de tempo, com base no seu estado atual e das células vizinhas. Para representar a estocasticidade presente em fenômenos naturais, como a propagação de incêndios, normalmente são utilizados ACs probabilísticos (FRAGA; OLIVEIRA; MARTINS, 2021) (TINOCO et al., 2022). Nesse contexto, a escolha dos valores para os parâmetros presentes nas regras de transição do AC influenciam significativamente na qualidade da dinâmica modelada, possibilitando aproximar ou distanciar a simulação do comportamento observado nos dados reais.

Normalmente, o ajuste dos parâmetros do AC são realizados manualmente pelo projetista do modelo. Entretanto, essa tarefa é complexa, requer um conhecimento prévio do sistema modelado e costuma demandar um tempo considerável (GREFENSTETTE, 1993). Para auxiliar nesse processo, um Algoritmo Genético (AG) pode ser empregado para encontrar, de forma automática, valores adequados para os parâmetros do modelo, tornando o processo mais eficiente e rápido. AG é um método de otimização baseado na teoria da evolução de Darwin, que busca implementar os princípios de seleção natural, hereditariedade, recombinação e mutação, assim como observado na natureza (TAN, 2004). O AG trabalha com uma população de possíveis soluções, as quais são avaliadas em função de sua aptidão para resolver o problema investigado. Com base nessa avaliação, operadores genéticos são aplicados sobre indivíduos selecionados, a fim de construir soluções mais aptas a cada geração (processo iterativo). Dessa forma, o algoritmo direciona a exploração do espaço de busca para as regiões com maior potencial.

Neste contexto, este trabalho busca desenvolver um algoritmo genético para o ajuste dos parâmetros do modelo de propagação de incêndio baseado em autômato celular proposto em Tinoco et al. (2022). Espera-se que a abordagem evolutiva implementada seja capaz de aproximar o comportamento das simulações ao padrão existente nos dados históricos de incêndios de uma área monitorada, tornando o modelo mais eficaz e preciso para simular cenários específicos, como tipo de vegetação e condições climáticas. Tal abordagem pode ser útil para o desenvolvimento de estratégias mais efetivas para a prevenção e controle de incêndios.

1.1 Motivação

Os incêndios florestais, quando não naturais, sobretudo os de longa duração, afetam o meio ambiente, a biodiversidade, as áreas rurais e urbanas próximos a ele de maneira negativa. Nos últimos anos houve um aumento significativo desse fenômeno devido as mudanças climáticas provenientes da intervenção humana (JONES et al., 2020), o que torna sua prevenção e controle ainda mais importantes. Com esse propósito, é fundamental o desenvolvimento de instrumentos eficazes para a simulação e previsão da propagação de incêndio a fim de mitigar seus efeitos.

Os ACs são uma ferramenta de grande valor para modelar o comportamento do fogo nos incêndios, pois com ele é possível descrever comportamentos complexos por meio de regras locais aplicadas a células individuais, que representam diferentes estados do ambiente. Porém, é fundamental a escolha adequada dos valores dos parâmetros dos modelos de simulação baseados em AC, de modo que eles sejam capazes de representar corretamente a propagação do fogo em condições ambientais variadas, que integrados com a informação da posição do fogo e as condições da região monitorada, obtidas por meio de sensores meteorológicos e imagens satélite, permitem a simulação precisa do comportamento do incêndio (KARAFYLLIDIS; THANAILAKIS, 1997). Esse tipo de ferramenta pode ser útil na formação das estratégias e na tomada de decisão durante o controle do incêndio.

Portanto, o desenvolvimento de um AG para ajustar automaticamente os valores dos parâmetros do AC, é de grande importância. Por meio dessa abordagem evolutiva, espera-se ser possível adaptar o modelo de propagação de incêndios a diferentes condições e cenários, sem a necessidade de ajustes manuais, que podem ser complexos, custosos e demandarem conhecimento especializado (GREFENSTETTE, 1993). Assim, mesmo com as variações nas características da vegetação e clima, o modelo se torna eficaz no controle de incêndios florestais.

1.2 Objetivos

Construção de um algoritmo genético para o ajuste automático dos parâmetros de um modelo de propagação de incêndio baseado em AC, de modo a reproduzir o comportamento observado nos dados históricos de incêndios florestais.

Para alcançar essa meta, é necessário atingir os seguintes objetivos específicos:

- ❑ Estudar e reproduzir o modelo de propagação de incêndios, baseado no AC probabilístico, proposto por Tinoco et al. (2022).
- ❑ Desenvolver um AG capaz de ajustar o conjunto de parâmetros do modelo de AC implementado, a partir de dados históricos de incêndios florestais.

- Avaliar o desempenho da abordagem evolutiva desenvolvida no ajuste dos parâmetros a partir de um conjunto de dados de referência, gerados através das simulações do modelo de propagação de incêndio, configurado manualmente com diferentes parâmetros.

1.3 Justificativa

Incêndios florestais são um problema crescente ao redor do mundo, com impactos no meio ambiente e na saúde pública. Para lidar com essa adversidade é fundamental o conhecimento da dinâmica de propagação do fogo, a fim de desenvolver estratégias eficazes, capazes de mitigar seus impactos. Nesse âmbito, a utilização de modelos baseados em AC, têm grande valor devido a sua capacidade de representar problemas complexos de maneira simples com boa correspondência com a realidade. Para isso, os parâmetros devem estar devidamente ajustados, o que pode ser feito de maneira eficiente e automática utilizando a abordagem evolutiva dos AGs, permitindo que o modelo se adapte a diversas áreas e situações, que seriam complexas de modelar manualmente.

1.4 Método

Será feito um estudo inicial sobre ACs e AGs para aprofundar no funcionamento dessas técnicas. Então será feito um levantamento bibliográfico sobre os modelos de propagação de incêndio baseado em AC, e de AGs usados no ajuste dos parâmetros de modelo de propagação, para entender qual o estado da arte desse tema.

Posteriormente, será implementado o modelo proposto em Tinoco et al. (2022), o qual será utilizado como o modelo de propagação da abordagem evolutiva e também para a geração da base de dados artificial.

Depois do modelo de simulação implementado, passamos para o desenvolvimento do AG. Nessa etapa, será definida qual a representação do indivíduo, a forma de avaliação das soluções para o cálculo da aptidão, bem como a escolha e desenvolvimento dos métodos e dos operadores genéticos.

Por fim, serão realizados experimentos a fim de verificar a eficiência da abordagem desenvolvida em ajustar os parâmetros do modelo de simulação de incêndios de acordo com a dinâmica observada nos dados artificiais.

Fundamentação Teórica

Neste capítulo serão apresentados os conceitos fundamentais de Autômato Celulars (ACs) e Algoritmo Genéticos (AGs) que são a base para o desenvolvimento do trabalho e o cumprimento dos objetivos propostos.

Os ACs são sistemas dinâmicos discretos utilizados para simular e analisar sistemas complexos. Em sua seção serão abordados os conceitos de células, reticulado, vizinhança, estados e regras de transição.

Além disso, os AGs são um método de otimização baseado na teoria da evolução de Darwin, tem em sua seção a definição dos conceitos de indivíduo, função de aptidão, seleção, recombinação, mutação, reinserção e critério de parada.

2.1 Autômato Celular

Um AC pode ser definido como um sistema dinâmico discreto composto por um reticulado de células, no qual cada célula possui um conjunto finito de estados. O comportamento global do AC é determinado pela interação entre as células a cada passo de tempo, seguindo regras de transição previamente definidas. (CHOPARD; DROZ, 1998).

Os ACs se destacam pela capacidade de representar problemas complexos a partir de interações locais simples (WOLFRAM et al., 2002). Tal abordagem permite a representação de diversos fenômenos naturais, sociais e computacionais, como a dinâmica de fluidos na física (ROTHMAN; KELLER, 1988), o crescimento urbano (ABURAS et al., 2016) e a criptografia (WOLFRAM, 1986).

As principais propriedades de um AC são a estruturação do reticulado, a definição da vizinhança e das regras de transição, tais aspectos definem o comportamento do modelo e podem gerar padrões globais, como oscilações, pontos fixos e estruturas complexas, até mesmo quando seguem regras simples (WOLFRAM et al., 2002).

2.1.1 Células e Reticulado

As células são os elementos básicos do AC, onde cada uma representa uma entidade particular no modelo e possui um estado associado. É importante ressaltar que as células podem assumir 3 formatos de polígonos regulares, o triângulo equilátero, o quadrado e o hexágono, oferecendo flexibilidade na representação de problemas variados (WOLFRAM et al., 2002).

Essas células são organizadas em uma estrutura denominada reticulado, que possibilita a interação entre elas. O reticulado pode ter uma, duas, três ou mais dimensões, dependendo da natureza do problema que está sendo abordado. Em um AC unidimensional, as células são alinhadas sequencialmente. Em um AC bidimensional, as células são organizadas em uma grade retangular. Já em AC tridimensionais ou de maior dimensionalidade, a estrutura é estendida para além das duas dimensões, permitindo a representação de sistemas mais complexos, e podem ser vistos na Figura 1 (WOLFRAM et al., 2002).

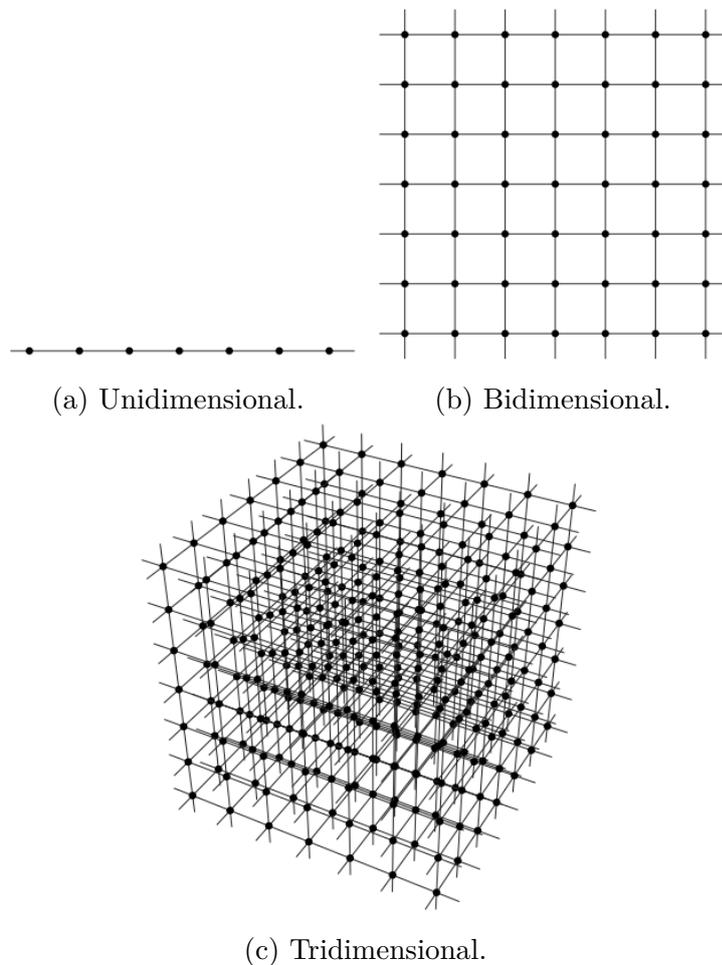


Figura 1 – Exemplos de Dimensões do Reticulado (WOLFRAM et al., 2002).

Essa organização é fundamental para a interação entre as células, visto que a conexão entre elas varia de acordo com a topologia do reticulado. Logo, essa definição é essencial para o início de uma boa representação do problema.

2.1.2 Vizinhança

A vizinhança de uma célula define o grupo de células que estão ligadas a ela no reticulado e que vão influenciar em suas regras de transição e conseqüentemente em seu estado.

A vizinhança está diretamente ligada à topologia do autômato celular. Em ACs unidimensionais, a vizinhança de uma célula pode ser composta pelas células adjacentes a ela na esquerda e na direita. Já em autômatos celulares bidimensionais, são amplamente utilizados dois tipos de vizinhança: a vizinhança de von Neumann e a vizinhança de Moore (WOLFRAM et al., 2002), podendo ser de raio 1 ou com raios maiores.

Na vizinhança de von Neumann, considera-se como vizinhos as células adjacentes nas direções norte, sul, leste e oeste em relação ao elemento central, i.e., um total de quatro vizinhos, visto na Figura 2a. Por outro lado, na vizinhança de Moore, além das células nas direções cardinal, também são incluídas as quatro células adjacentes nas diagonais, totalizando oito vizinhos, como demonstrado na Figura 2b (ILACHINSKI, 2001).

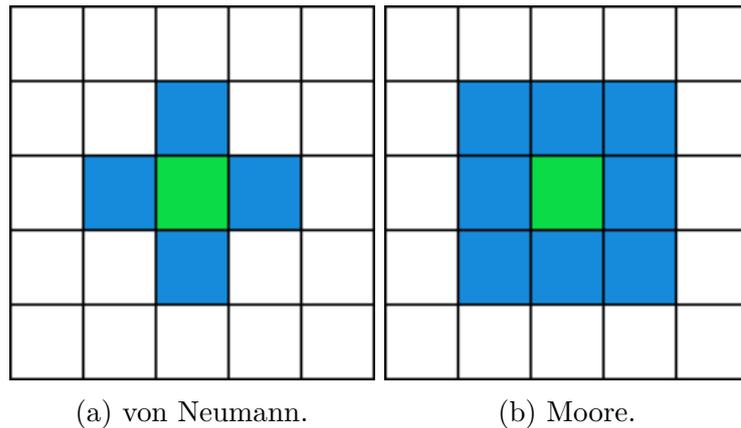


Figura 2 – Exemplo de vizinhanças em um AC Bidimensional.

2.1.3 Estados

O estado de uma célula em um AC indica a condição associada a ela dentro do modelo, em um passo de tempo específico. Cada elemento do AC pode assumir um estado específico a cada passo de tempo, selecionado a partir de um conjunto finito pré-determinado. Essa definição é essencial para determinar a dinâmica do AC como um todo (WOLFRAM et al., 2002).

A quantidade de possíveis estados do AC depende do problema a ser representado. Pode ser representado de maneira binária, como 0 e 1, utilizado no Game of Life (IZHIKEVICH; CONWAY; SETH, 2015), ou com mais possibilidades, representando, por exemplo, condições de uma vegetação, utilizado em modelos de propagação de incêndio (TINOCO et al., 2022).

O estado é atualizado a cada passo de tempo com base nas regras de transição definidas. Esse processo é o que dá ao AC o dinamismo necessário para representar problemas complexos, revelando propriedades emergentes sobre o comportamento do sistema em estudo.

2.1.4 Regras de Transição

As regras de transição do AC são responsáveis por definir como o estado da célula evolui ao longo do tempo com base no estado das células vizinhas (WOLFRAM et al., 2002).

A cada iteração do AC, cada célula pode alterar seu estado com base em uma regra determinística ou probabilística. Na abordagem determinística, a transição de estado de uma célula é determinada por uma função específica que leva em consideração apenas os estados das células vizinhas. Essa função é definida de forma fixa, garantindo que o próximo estado da célula seja previsível (ILACHINSKI, 2001). Esse modelo permite o surgimento de alguns padrões que podem ser replicados, como na regra 30 definida por Wolfram. No caso de um AC unidimensional que inicia com apenas uma célula de valor 1, é sempre gerado o padrão mostrado na Figura 3.

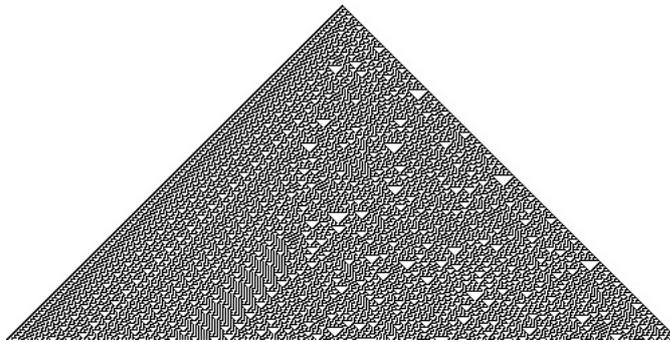


Figura 3 – Regra 30 (WOLFRAM et al., 2002).

Por outro lado, na abordagem probabilística, além de considerar os estados das células vizinhas, a transição de estado de uma célula é governada por probabilidades. Cada possível estado resultante possui uma probabilidade associada. Isso permite que o AC modele fenômenos estocásticos, nos quais as transições de estado podem ocorrer com certa incerteza ou aleatoriedade. Como demonstrado na Figura 4, para a mesma regra de transição e configuração inicial, diferentes padrões são formados. Em interações biológicas, por exemplo, onde fatores ambientais aleatórios podem influenciar a dinâmica do sistema, esse método pode ser amplamente utilizado (FRAGA; OLIVEIRA; MARTINS, 2021) (TINOCO et al., 2022).

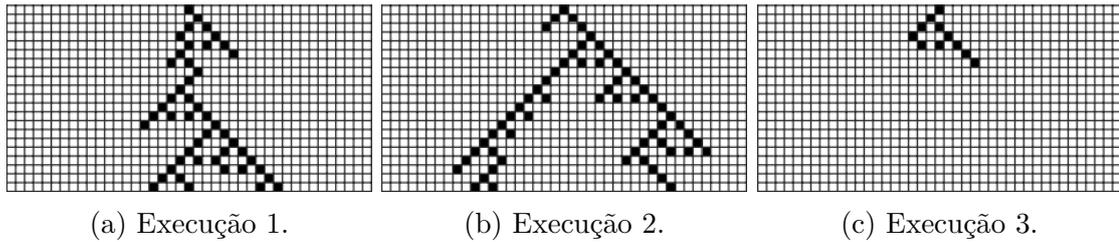


Figura 4 – Exemplo de regra de transição Probabilística (WOLFRAM et al., 2002).

Portanto, uma boa definição das regras de transição, é fundamental para garantir uma representação precisa e significativa do fenômeno desejado, permitindo simulações mais acuradas e análises mais profundas dos processos complexos que ocorrem no modelo.

2.2 Algoritmo Genético

Algoritmos Genéricos são técnicas de busca baseadas na mecânica de seleção natural e genética natural. Pertencem ao campo dos algoritmos evolutivos e utilizam técnicas heurísticas de otimização global para uma função objetivo (GOLDBERG, 1989). São inspirados no processo de evolução biológica, na qual os indivíduos mais adaptados tem maior probabilidade de perdurar e transmitir suas características para as próximas gerações.

No AG, inicialmente é definida a composição de um indivíduo que representa a possível solução do problema. Tais indivíduos são submetidos aos processos de seleção, recombinação e mutação até chegarem a um critério de parada. Dessa maneira, eles conseguem percorrer um grande espaço de busca e se aproximar da solução ótima global (LINDEN, 2012).

A execução do AG consiste de alguns passos, que são ilustrados na Figura 5. A princípio, são definidos os parâmetros do modelo, como tamanho da população, a taxa de *crossover*, taxa de mutação, função de aptidão e o critério de parada. Então, é gerada a primeira geração de maneira aleatória. Após isso, para cada indivíduo é calculado a função objetivo, e caso não tenha alcançado nenhum dos critério de parada, com base nessa avaliação e nas técnicas de seleção, são selecionados os indivíduos pais para a reprodução. Então, eles são recombinados, gerando novos descendentes com o objetivo de reunir características promissoras. Esses novos indivíduos então podem passar por mutações aleatórias que permitem explorar o espaço de busca de maneira mais ampla e evitar a estagnação em ótimos locais. Em seguida, parte da população atual é substituída pelos descendentes recém gerados, formando assim a nova população. Após isso, é feita a verificação para identificar se algum dos critérios de parada foi satisfeito. Caso tenha atingido, o algoritmo é finalizado e a melhor solução é retornada, caso contrario, uma nova geração da população é criada (GOLDBERG, 1989).

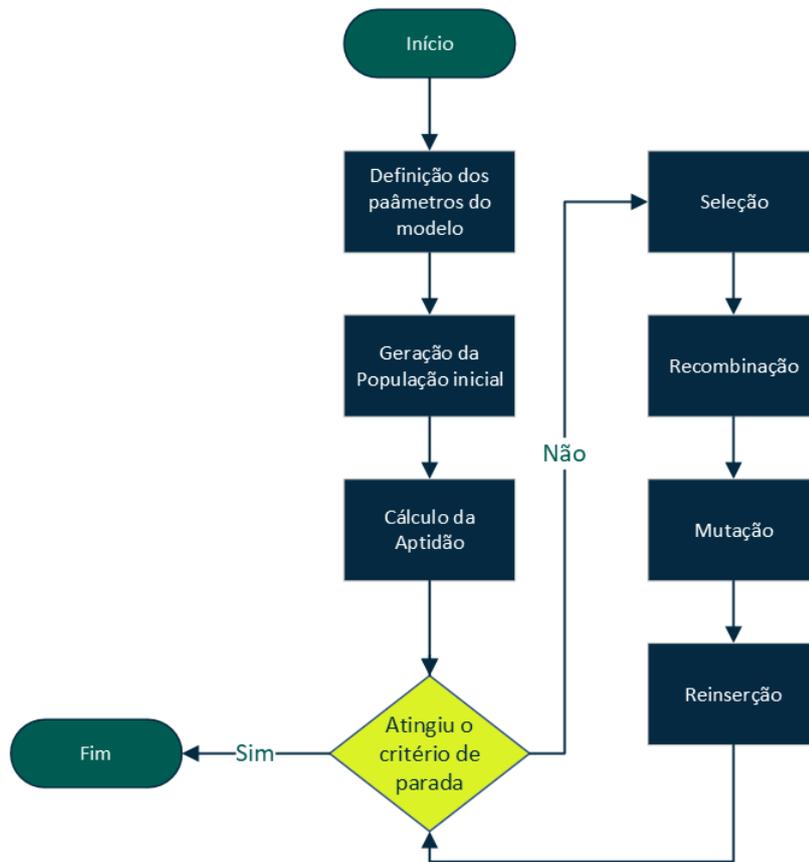


Figura 5 – Fluxograma geral de Algoritmo Genético.

2.2.1 Indivíduo

No AG, um indivíduo corresponde a uma possível solução para o problema estudado. Ele é representado por meio de uma estrutura chamada cromossomo, que é uma sequência de genes. Cada um desses genes é uma parte da solução, como um parâmetro ou uma característica a ser determinada (HOLLAND, 1992).

A composição do cromossomo varia de acordo com a natureza do problema, mas a principal maneira de representá-los é por meio de vetores, nos quais os valores de cada posição (genes) podem ser binários (0 ou 1), inteiros ou reais.

O significado de cada gene e a forma que são combinados são específicas para cada problema estudado. Por exemplo, no problema do caixeiro-viajante, o cromossomo pode representar a ordem das cidades visitadas (GREFENSTETTE et al., 2014), e em problemas matemáticos de otimização, podem representar os valores numéricos correspondentes a parâmetros do modelo (GOLDBERG, 1989).

Portando, ao projetar o AG, é fundamental o cuidado na codificação dos genes, considerando a natureza do problema, o tipo de informação e as restrições que serão representadas. Assim, torna-se possível alcançar os resultados esperados.

2.2.2 Função de Aptidão

A função de aptidão ou *fitness* é uma medida que avalia o desempenho de um indivíduo em relação a sua capacidade de resolver o problema estudado, e é fundamental para conduzir a busca evolutiva a encontrar soluções mais promissoras (HOLLAND, 1992).

Ela é estabelecida de maneira específica para cada problema e, normalmente, o seu resultado é um valor numérico que mensura o quão bem aquele indivíduo otimiza a função objetivo (GOLDBERG, 1989). Em problemas de maximização, quanto maior o valor da função *fitness*, melhor é o desempenho daquele indivíduo, em contrapartida, em problemas de minimização, quanto menor o resultado, melhor é aquele indivíduo.

O *fitness* é calculado para cada indivíduo, assim que o indivíduo é gerado, e esse valor pode ser utilizado por outros métodos do AG para tomar as decisões relacionadas à seleção e substituição na população.

2.2.3 Seleção

Os métodos de seleção dos pais no AG tem como objetivo definir os indivíduos que participarão da reprodução, permitindo que suas características sejam transmitidas para as gerações posteriores.

A pressão seletiva é fundamental para garantir o avanço na busca pela solução ótima. Se for muito baixa, o AG pode demorar muito tempo para evoluir, mas também, caso seja muito alta, i.e., escolher apenas aqueles com alto grau de aptidão, é muito provável que o AG chegue prematuramente em ótimos locais (LINDEN, 2012).

A Seleção pelo Método de Amostragem Estocástica Uniforme, utiliza um segmento contínuo de linha ou uma roleta ponderada para selecionar indivíduos, cuja probabilidade ou tamanho de cada elemento é proporcional à sua aptidão. Para sua construção, primeiro calcula-se a aptidão de cada indivíduo da população. Em seguida divide-se esse valor pela somatória das aptidões para descobrir a distribuição de probabilidade relativa. Após isso, preenche-se a reta ou a roleta com essas probabilidades e gera-se um número aleatório que representa a posição do indivíduo selecionado. Então, o indivíduo selecionado é removido, as proporções são calculadas novamente e o processo se repete até que sejam selecionados as quantidades desejadas de indivíduos para a reprodução (LINDEN, 2012). Dessa maneira, existe a oportunidade de indivíduos menos aptos serem escolhidos, preservando a diversidade na população.

A Seleção por torneio (*Tournament Selection*) foi apresentada por Goldberg e se propõe a realizar uma disputa entre um subgrupo da população escolhida aleatoriamente. No primeiro momento, é definido o tamanho do subgrupo, denominado "tamanho do torneio". Após isso, os indivíduos são selecionados aleatoriamente para entrarem no subgrupo e, dentro desse, aquele que obtiver a maior aptidão é selecionado. Esse processo se repete até que sejam selecionados as quantidades desejadas de indivíduos para a reprodução.

O tamanho do torneio influencia a pressão seletiva do AG, quanto maior o tamanho do grupo, maior a probabilidade de serem escolhidos indivíduos mais aptos, enquanto grupos menores tendem a favorecer uma maior diversidade (LINDEN, 2012).

2.2.4 Recombinação

Os métodos de recombinação, cruzamento ou também chamados de *crossover*, têm o objetivo de combinar as informações genéticas de dois ou mais indivíduos para gerar novos indivíduos para a população. A taxa de *crossover*, um parâmetro essencial nesse processo, define a probabilidade de que a recombinação ocorra entre dois indivíduos selecionados.

Um dos métodos mais utilizados é o cruzamento com um ponto de corte (*One-Point Crossover*) que consiste na escolha de um ponto de corte aleatório nos cromossomos dos pais, dividindo-os em duas partes. Então, os genes antes do corte do primeiro pai são combinadas com o genes do segundo pai após o ponto de corte, e vice-versa. Apesar de aumentar a variabilidade genética, esse método ainda é limitado e, conforme o tamanho do gene ou da regra presente no problema, pode se tornar inviável (COPPIN, 2010).

Outro método proposto por Goldberg é o de cruzamento uniforme (*Uniform Crossover*). Esse método consiste na troca de informações genéticas entre os pais com base em uma máscara formada por um vetor de bits 0 e 1 que determina de qual pai o gene será herdado. Para fazer a definição dessa máscara, é utilizada uma probabilidade de cruzamento pré-definida. Em suma, para cada posição do cromossomo a máscara estabelece se o gene vira do primeiro ou segundo pai. Feito isso, os genes são permutados gerando dois descendentes que podem ser inseridos na população. O cruzamento representa a busca local do AG, uma vez que informações genéticas de várias posições do cromossomo podem ser trocadas (GOLDBERG, 1989).

2.2.5 Mutação

A mutação é um operador genético que introduz a busca global no AG, fazendo com que um indivíduo possa representar qualquer ponto no espaço de busca. Através dela os genes dos indivíduo tem a chance de se alterarem, gerando novas combinações e explorando espaços de busca antes não alcançados (HOLLAND, 1992).

Esse processo ocorre de maneira individual e pode ser aplicado a mais de um gene do cromossomo. A decisão sobre sua ocorrência depende de uma probabilidade definida com base na taxa de mutação, i.e., trata-se de um operador estocástico.

Em AGs com codificações binárias, a mutação pode significar a troca do valor 0 por 1 ou 1 por 0. Por outro lado, em codificações nas quais o cromossomo possui números reais, pode ser somado ou subtraído um valor aleatório do gene (GOLDBERG, 1989).

A capacidade desse operador de gerar novas soluções é fundamental para a exploração de diferentes regiões do espaço de busca, e seu ajuste afeta diretamente a eficácia do

AG. Caso haja mutação excessiva, é provável que o AG perca boas soluções que já foram encontradas e, caso tenha pouca mutação, é provável que se alcance ótimos locais e não seja possível superá-los. Portanto, a mutação permite a procura por novas soluções e evita a convergência para ótimos locais.

2.2.6 Reinscrição

A reinscrição é a escolha dos indivíduos que passarão para a próxima geração, seu objetivo é selecionar os indivíduos que proporcionarão a preservação das melhores características e a exclusão daqueles sem atributos promissores.

Uma das maneiras de alcançar isso é através do método chamado de elitismo, no qual alguns dos melhores indivíduos da geração corrente são mantidos inalterados e são preservados para a próxima geração, garantindo a preservação de indivíduos ou genes promissores. Uma outra abordagem que pode ser utilizada é a reinscrição pura que substitui todos os pais pelos filhos provenientes da recombinação, o que pode acarretar na perda de bons indivíduos, contudo, em casos de modelos com funções de aptidão não fixas, pode ser uma boa escolha.

2.2.7 Critério de Parada

O critério de parada estabelece quando o AG deve finalizar sua execução, indicando que o algoritmo alcançou seu objetivo ou chegou a um limite.

Existem diferentes formas de mensurar o critério de parada, sendo os principais: (i) o número máximo de gerações, no qual, quando se alcança um número pré-determinado de gerações, a execução é encerrada e pode ser utilizado quando se tem o conhecimento da quantidade necessária para alcançar bons resultados; (ii) a convergência da população, que finaliza a execução quando verifica que a população convergiu para um resultado estável; (iii) o alcance de um valor de aptidão, que finaliza a execução quando algum indivíduo atinge ou supera o valor previamente definido; (iv) o tempo máximo de execução, que encerra a execução após um determinado tempo de relógio (HOLLAND, 1992).

Trabalhos Correlatos

Existem diversos modelos de propagação de incêndio que utilizam Autômato Celulares (ACs), os quais variam em relação aos diferentes parâmetros e formas de representação. A seguir, são apresentados trabalhos relevantes na área, assim como dois dos principais modelos estudados para a realização deste trabalho, que foram descritos em Tinoco et al. (2022) e em Louzada e Junior (2008).

Existem também, vários modelos na literatura que buscam uma abordagem evolutiva para o ajuste automático dos parâmetros de um AC. Dentre esses, os dois principais que foram usados como base de estudo para a realização desse trabalho foram os trabalhos propostos em Ferreira (2023) e em Fraga, Oliveira e Martins (2021) que são descritos nas seções subsequentes.

3.1 Modelos de Propagação de Incêndio

O modelo proposto por Clarke, Brass e Riggan (1994) buscou prever o comportamento espacial e temporal de incêndios florestais usando ACs. Os autores utilizaram parâmetros como direção e força do vento, umidade e temperatura, com o objetivo de empregar informações em tempo real para simulações rápidas do comportamento de incêndios controlados. O modelo apresentado por Chopard e Droz (1998) serviu de base para diversos outros trabalhos na área. Ele propõe em seu trabalho um modelo de propagação de incêndios baseado em ACs com três estados, regras de transição para simular o dinamismo do fogo e uma função de recuperação.

A representação proposta por Karafyllidis e Thanailakis (1997) conseguiu prever a dispersão do fogo em florestas homogêneas e heterogêneas, incorporando condições climáticas e a topografia do terreno. Os autores utilizaram um reticulado bidimensional com vizinhança de Moore, onde o estado das células varia no intervalo entre 0 e 1, sendo 0 uma célula não queimada e 1 uma célula totalmente queimada. Os resultados do estudo permitiram concluir que é possível construir algoritmos utilizando esse modelo para si-

mular incêndios em florestas reais, executando de maneira rápida devido ao potencial de paralelismo dos ACs.

O estudo de Sun et al. (2021) propôs um modelo aprimorado de propagação de incêndios florestais, que combina conceitos fundamentais de ACs com uma taxa de mudança de velocidade baseada em dados meteorológicos para ajustar a passagem de tempo do AC, o que proporciona maior precisão à simulação. Ao ser aplicado para analisar um incêndio real ocorrido em Mianning County, obteve uma precisão de 96,9%, o que mostra sua utilidade no auxílio à tomada de decisão no momento de formular os planos de contenção.

3.1.1 Modelo Tinoco et al. (2022)

O trabalho de Tinoco et al. (2022) propôs um modelo de propagação de incêndio utilizando ACs e regras estocásticas. O objetivo é simular o comportamento do fogo para melhorar o processo de tomada de decisão e a eficiência dos esforços no combate ao incêndio.

O modelo utiliza a vizinhança de Moore e possui uma matriz de combustão que representa a probabilidade de propagação do fogo entre as células, considerando fatores como as correntes de vento e obstáculos. O modelo também inclui uma função de recuperação que permite que as células queimadas se recuperem e voltem ao estado de vegetação, assim como ocorre na natureza. Além disso, ele pode ser ajustado de acordo com dois coeficientes, o calórico (λ) que é usado para produzir diferentes escalas de incêndios e o coeficiente de vento (δ) representado por um valor cardinal/colateral que indica a direção do vento.

O modelo possui seis possíveis estados, o estado **vegetação** representa a célula que possui material combustível, e não é capaz de influenciar os outros estados, mas pode ser influenciado pelos estados de fogo. Os estados **fogo-inicial**, **fogo-estável** e **brasa** representam os estados de fogo no qual cada um possui diferentes intensidades de fogo. Por sua vez, quando o fogo extingue, a célula muda para o estado **cinza**, que não possui chance de propagar fogo para outras células ou de se incendiar novamente a menos que retorne ao estado de vegetação. Por fim, o estado **água** que não interage com nenhum outro estado e funciona apenas como uma barreira para o fogo.

As regras de transição do modelo são as seguintes:

- ❑ Se a célula central está no estado vegetação e não existe nenhuma célula no estado fogo na vizinhança, mantém o mesmo estado;
- ❑ Se a célula central está no estado vegetação e existe alguma célula na vizinhança que esta no estado fogo, há a possibilidade de mudar para o estado fogo-inicial;
- ❑ Se a célula central está no estado fogo-inicial, ela não é influenciada por outras células, mantém esse estado por 3 passos de tempo e então muda para o estado

fogo-estável;

- ❑ Se a célula central está no estado fogo-estável, ela não é influenciada por outras células, mantém esse estado por 3 passos de tempo e então muda para o estado brasa;
- ❑ Se a célula central está no estado brasa, ela não é influenciada por outras células, mantém esse estado por 3 passos de tempo e então muda para o estado cinza;
- ❑ Se a célula central está no estado cinza, ela não é influenciada por outras células, mas pode mudar para o estado vegetação de acordo com a função de recuperação;
- ❑ Se a célula central é do estado água, ela não interage com os outros estados.

Na Figura 6, está um exemplo dos passos da propagação do fogo no modelo, demonstrando também a interação com o estado água.

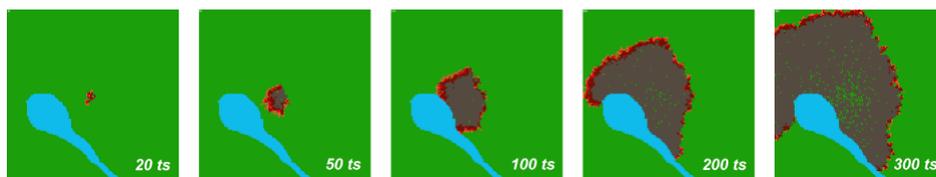


Figura 6 – Exemplo de propagação de um incêndio [Extradio de Tinoco et al. (2022)].

No geral, o modelo visa fornecer uma simulação realista de incêndios florestais e contribuir para o desenvolvimento de estratégias eficazes de prevenção e supressão de incêndios florestais.

3.1.2 Modelo Louzada e Ferreira Junior (2008)

O modelo de Louzada e Junior (2008) busca obter o comportamento da propagação de queimadas florestais utilizando as regras de transição de um AC.

Para isso, é utilizado um reticulado bidimensional, com vizinhança Moore e toróide, no qual a parte superior se conecta com a parte inferior, assim como o lado esquerdo com o direito. Os parâmetros do modelo são a QuantQueima que representa a quantidade de pontos iniciais de queima, LQ o número de graduações de queima no sistema, importante para a propagação do fogo, e LR que simboliza o número de graduações para a idade de uma floresta, uma vez que nas florestas mais antigas o acúmulo de combustível é maior em comparação com florestas jovens.

O estado da célula é expresso pelo par (Tipo, Idade), com o tipo podendo ser Floresta ou Fogo e a Idade $\in [1..lim]$.

No qual $lim = LQ$ se $Tipo = 1$ (Fogo), ou $lim = LR$ se $Tipo = 0$ (Floresta).

As regras de transição do modelo são as seguintes:

- Para células do tipo 1, se sua idade equivale ao valor de LQ, elas se tornarão células do tipo 0 com Idade = 1, caso contrário sua idade será incrementada em 1.
- Para células do tipo 0, elas se tornarão células do tipo 1, dado uma probabilidade, em que:

$$P = \frac{Idade}{LR} \cdot \frac{MediaV}{LQ} \quad (1)$$

Onde a MediaV representa a média de idade das queimas vizinhas à célula central.

Na Figura 7, está um exemplo da dispersão de um incêndio que se tornou estável, com novas gerações de queimadas substituindo as antigas, sem dar a oportunidade para o crescimento da vegetação.

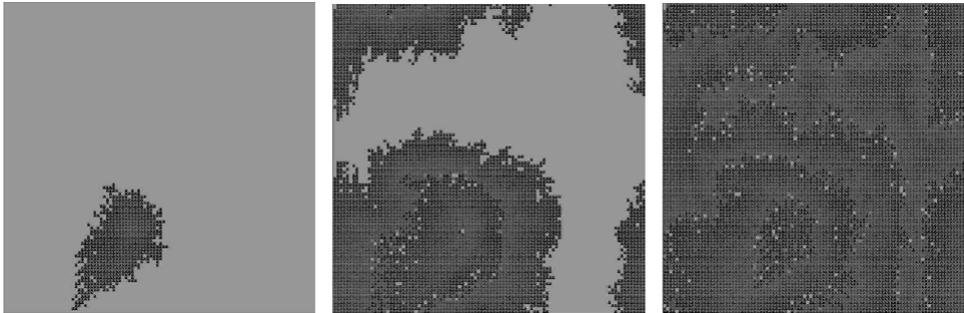


Figura 7 – Exemplo de propagação de um incêndio [Extraído de Louzada e Junior (2008)].

Por fim, o trabalho destaca a dificuldade em obter resultados sobre incêndios florestais e indica que, mesmo sem a interferência humana, pequenos focos de incêndio podem surgir aleatoriamente, assim como eventuais queimadas de médio porte, que controlam a quantidade de matéria orgânica no ambiente.

3.2 Algoritmos Genéticos no Ajuste Automático de Autômatos Celulares

Os AGs já foram utilizados para resolver diversos problemas, como aqueles que envolvem otimização. Em Grefenstette et al. (2014) um AG foi usado para resolver o problema do caixeiro-viajante (*Traveling salesman problem*) que tenta determinar a menor rota para percorrer uma série de cidades, posteriormente retornando a cidade de origem. O problema de roteamento de veículos (*Vehicle routing problem*) que resume-se em atender um conjunto de consumidores por meio de uma frota de veículos (PRINS, 2004). Também em sistemas de fabricação (*Manufacturing system*) para encontrar a melhor combinação de ações e processos durante a fabricação (ONWUBOLU; MUTINGI, 2001).

Além disso, na área de tecnologia, pode ser utilizado para mineração de dados, que consiste na exploração de quantidades massivas de dados na busca por relacionamentos e padrões (MUKHOPADHYAY et al., 2013). Em redes neurais artificiais, o AG pode auxiliar

a encontrar a melhor configuração de parâmetros do modelo para o reconhecimento de padrões (NICULESCU, 2003). E, para *Wireless sensor networks*, os AGs podem ser aplicados na busca pela melhor combinação da distribuição dos nós que reflete o quão bem um campo é coberto (YOON; KIM, 2013).

3.2.1 Modelo Ferreira (2023)

O trabalho de Ferreira (2023), busca desenvolver uma abordagem que simule incêndios florestais. Com base em um modelo de propagação de incêndio que utiliza ACs e um AG para ajustar automaticamente os valores dos parâmetros do modelo de modo a se aproximar de dados históricos.

O AC utilizado pelos autores é baseado no trabalho de Louzada e Junior (2008), e foi modificado para considerar diferentes tipos de vegetação, buscando se aproximar do bioma cerrado. Além disso, adota um conjunto de parâmetros (LQ, LR e $W_{3 \times 3}$) para cada vegetação modelada.

O estado da célula é dada pelo par (Tipo, Idade). O Tipo pode assumir os valores Fogo, Árvore ou Água e com a idade $\in [1..LQ]$ quando do tipo Fogo e representa o tempo de queima da árvore ou a temperatura das chamas. E, Idade $\in [1..LR]$ quando do tipo Árvore e representa o tempo de recuperação da árvore ou a quantidade de material orgânico presente na vegetação. A cada iteração, uma célula do tipo árvore tem uma chance de se tornar fogo, calculada por meio de uma probabilidade. Além disso, a vizinhança de Moore é representada pela matriz $W_{3 \times 3}$, que modela a influência do vento na propagação do incêndio das células vizinhas para a célula central.

A abordagem evolutiva proposta utiliza como base um AG. Onde o indivíduo é composto pelas oito posições da matriz de preferência, que representam a direção do vento, além de dois parâmetros representando LQ e LR. Para cada nova vegetação adicionada, esses dez parâmetros são replicados, com valores específicos para cada tipo de vegetação, conforme demonstrado na Figura 8.

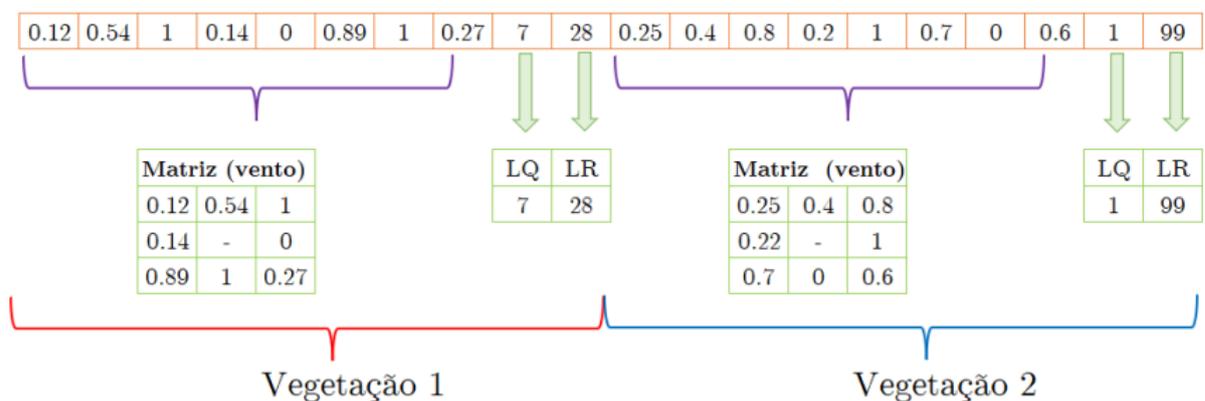


Figura 8 – Representação de dois indivíduos [Extraído de Ferreira (2023)].

Os indivíduos são avaliados pela função de aptidão, que compara a série de reticulados associada a cada indivíduo com a base de dados de referência. Essa comparação calcula a diferença na quantidade de células no estado de fogo para cada par de reticulados (indivíduo, referência).

De acordo com os resultados apresentados pelos autores, foi possível concluir que o AG é capaz de definir os valores adequados para os parâmetros do modelo. Isso resulta em simulações que apresentam um comportamento de propagação do fogo similar aos dados artificiais usados como referência. No entanto, o desempenho do algoritmo é afetado quando o fogo começa em uma posição desfavorável para a observação da dinâmica do incêndio, ou quando os dados gerados como referência são produzidos por modelos diferentes.

3.2.2 Modelo FRAGA, OLIVEIRA e MARTINS (2021)

O trabalho de Fraga, Oliveira e Martins (2021) descreve um modelo de automato celular utilizado para estudar a doença de Chagas, que possui como seu vetor um inseto. Além disso, os autores utilizaram um AG para fazer o ajuste dos parâmetros desse modelo.

O AC usado nas simulações é composto por um reticulado bidimensional no qual cada célula pode estar vazia ou ocupada por um inseto adulto ou uma larva, e apresenta dois processos: demografia e dispersão.

No processo de demografia, o número de insetos em cada célula é determinado pela reprodução, sobrevivência e desenvolvimento. Os insetos adultos têm uma determinada probabilidade de se reproduzirem, gerando um número de larvas em cada célula. O estágio de sobrevivência define quantos adultos e larvas sobrevivem na célula com base em probabilidades de sobrevivência. No estágio de desenvolvimento, as larvas têm uma probabilidade de se tornarem adultas.

No processo de dispersão, os insetos adultos se deslocam de acordo com determinadas regras. Durante o período de infestação, há uma chance de os insetos migrarem da floresta para a vila, sendo escolhida uma das células vizinhas como destino para o inseto. Fora desse período, os insetos não migram.

Os parâmetros do modelo são: a probabilidade de reprodução de um inseto adulto (p_r), probabilidade de sobrevivência de uma larva (p_{sy}), probabilidade de sobrevivência de um inseto adulto (p_{sa}), probabilidade de desenvolvimento de uma larva para se tornar um inseto adulto (p_d), coeficiente de dispersão durante o período de infestação (D_i), coeficiente de dispersão durante o período sem infestação (D_{ni}) e o número de insetos que chegam à vila por dia durante o período de infestação (Q_f). Esses parâmetros estão representados pelo indivíduo descrito na Figura 9.

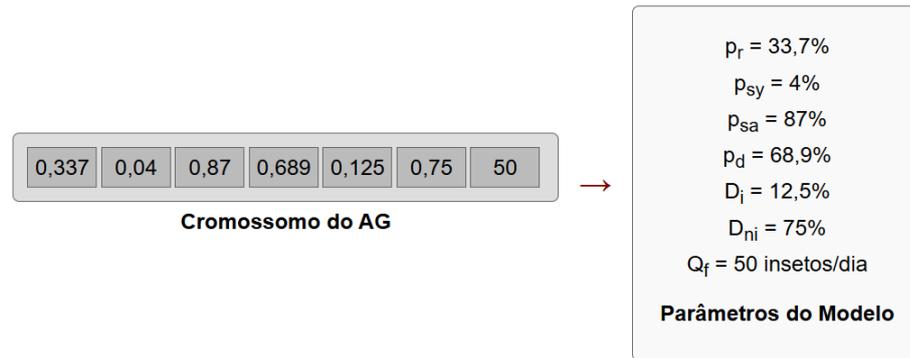


Figura 9 – Representação de um indivíduo [Adaptado de Fraga, Oliveira e Martins (2021)].

Para otimizar o modelo, foi proposta uma abordagem que utiliza um AG a fim de encontrar soluções ótimas ou aproximadas para a configuração dos parâmetros. O AG possui uma população de indivíduos que, por sua vez, representam a configuração dos parâmetros do AC. A aptidão de cada um deles é medida comparando o indivíduo com o modelo de referência, e são utilizados operadores de seleção, recombinação e mutação para evoluir a população ao longo das gerações.

Além disso, é utilizada uma estratégia evolutiva de múltiplos estágios, que divide os parâmetros em subgrupos e evolui cada um desses subgrupos em diferentes estágios. O objetivo é refinar gradualmente a configuração dos parâmetros, focando em subgrupos específicos e tornando o processo de otimização mais direcionado.

Por fim, os autores destacam que as simulações obtiveram resultados satisfatórios após a sua configuração com os melhores parâmetros encontrados pelo AG, com uma distribuição espacial e do número de larvas e adultos muito próximos do esperado, mesmo que ainda não tenham alcançado os valores exatos do modelo de referência. Além disso, a abordagem de múltiplos estágios conseguiu se aproximar mais dos valores do modelo base do que o AG simples adotado em um trabalho anterior.

Modelo de propagação de incêndios

Este trabalho reproduz o modelo de simulação de incêndios florestais proposto por Tinoco et al. (2022) a fim de otimizar seus parâmetros através de computação evolutiva. Esse modelo, baseado em Autômato Celulares (ACs) e regras estocásticas, visa simular o comportamento de incêndios, melhorando o processo de tomada de decisão e a eficiência dos esforços no combate às chamas. O modelo utiliza a vizinhança de Moore em um reticulado de tamanho 90×90 e possui uma probabilidade de propagação do fogo entre as células, considerando fatores como correntes de vento, o fogo ao redor da célula central e obstáculos. Além disso, o modelo inclui uma função de recuperação que permite que células queimadas se recuperem e voltem ao estado de vegetação, refletindo a regeneração natural das áreas queimadas. As principais características desse modelo são descritas nas próximas seções.

4.1 Estados do Modelo

Os estados possíveis do modelo são:

- ❑ Vegetação: Representa células que possuem material combustível. Estas células não influenciam outras, mas podem ser influenciadas por células em estado de fogo;
- ❑ Fogo-Inicial: Representa o início do fogo na célula, com uma intensidade local específica;
- ❑ Fogo-Estável: Representa um estado de fogo mais intenso e duradouro;
- ❑ Brasa: Representa um estado de fogo enfraquecido, próximo à extinção;
- ❑ Cinza: Representa células que foram completamente queimadas e não possuem chance de espalhar fogo, a menos que retornem ao estado de vegetação e posteriormente ao estado de fogo;

- ❑ Água: Representa uma barreira natural ao fogo, não interagindo com outros estados e impedindo a propagação do incêndio.

Para facilitar a visualização e a interpretação dos resultados da simulação, a seguir estão as cores associadas aos diferentes estados do AC:

Cor	Estado	Descrição
	Vegetação	Representa células com material combustível. Este estado pode ser influenciado por células em algum estado de fogo.
	Fogo Inicial	Estado inicial do fogo, com intensidade de queima inicial.
	Fogo Estável	Estado de queima estável, com intensidade de fogo moderada.
	Brasa	Estado de queima reduzida, próximo à extinção do fogo.
	Cinza	Representa células que foram queimadas, sem chance de propagação de fogo.
	Água	Barreira natural ao fogo, não interage com os outros estados.

Figura 10 – Estados do AC.

4.2 Regras de Transição

As regras de transição do modelo são definidas da seguinte forma:

- ❑ Vegetação sem fogo na vizinhança: Se uma célula está no estado de vegetação e não há nenhuma célula no estado de fogo na vizinhança, ela mantém o estado de vegetação;
- ❑ Vegetação com fogo na vizinhança: Se uma célula está no estado de vegetação e há uma célula na vizinhança em estado de fogo, há uma probabilidade de transição para o estado de fogo-inicial, determinada pela matriz de combustão, a intensidade de fogo nas células vizinhas e o coeficiente calórico;
- ❑ Fogo-Inicial: Uma célula no estado de fogo-inicial mantém esse estado por uma certa quantidade de passos de tempo e então transita para o estado de fogo-estável. Este estado não é influenciado por outras células;
- ❑ Fogo-Estável: Uma célula no estado de fogo-estável mantém esse estado por uma certa quantidade de passos de tempo e então transita para o estado de brasa. Este estado não é influenciado por outras células;
- ❑ Brasa: Uma célula no estado de brasa mantém esse estado por uma certa quantidade de passos de tempo e então transita para o estado de cinza. Este estado não é influenciado por outras células;

- Cinza: Uma célula no estado de cinza pode transitar de volta para o estado de vegetação de acordo com a função de recuperação, independentemente da influência de outras células.
- Água: Uma célula no estado de água não interage com células em outros estados e funciona como uma barreira natural para o fogo.

4.3 Matriz de Combustão

A matriz de combustão, organizada em uma estrutura 3×3 , permite a visualização do impacto do vento em cada célula ao redor de uma posição central. Cada célula dessa matriz contém um valor numérico que corresponde à intensidade relativa do vento naquela direção.

A matriz de vento é composta por nove células organizadas em três linhas e três colunas, conforme o exemplo abaixo:

0,125	0,25	0,5
0,25	0,0	0,75
0,5	0,75	1,0

Figura 11 – Matriz com vento Noroeste.

Essa matriz representa o quanto o vento influencia o fogo nas posições adjacentes a um ponto central e ela rotaciona de acordo com a direção do vento.

4.4 Função de Recuperação

A função de recuperação permite que células no estado de cinza voltem ao estado de vegetação após um determinado período, refletindo a regeneração natural das áreas queimadas. Este processo é estocástico e pode ser ajustado para simular diferentes taxas de recuperação da vegetação. A equação que define essa probabilidade é dada a seguir:

$$p = \frac{(cellAge)^2}{10^a} \quad (2)$$

Onde, o parâmetro a é o coeficiente de recuperação passível de ser ajustado pelo AG, enquanto a idade da célula ($cellAge$) representa a quantidade de passos de tempo desde que a célula passou para o estado Cinzas.

4.5 Parâmetros a serem ajustados pelo AG

Os parâmetros do modelo que influenciam diretamente a propagação do fogo e a recuperação das células são:

- ❑ **Coefficiente Calórico:** ajusta a intensidade do fogo, permitindo a simulação de diferentes escalas de incêndios. Este coeficiente influencia a probabilidade de transição das células de vegetação para o estado de fogo-inicial. No intervalo de $[0, 1]$.
- ❑ **Coefficiente de Vento:** representa a direção do vento e ajusta a probabilidade de propagação do fogo nas direções cardinais e colaterais, influenciando a matriz de combustão, essa matriz rotaciona de acordo com a direção do vento. Os possíveis valores são $[N, NE, E, SE, S, SW, W, NW]$, referentes a abreviação das direções da rosa dos ventos, em inglês;
- ❑ **Intensidade do Fogo Inicial:** determina a força do fogo inicial e influencia a probabilidade de propagação de fogo para as células vizinhas. No intervalo de $[0, 1]$;
- ❑ **Intensidade do Fogo Estável:** determina a força do fogo estável e influencia a probabilidade de propagação de fogo para as células vizinhas. No intervalo de $[0, 1]$;
- ❑ **Intensidade da Brasa:** determina a força da brasa e influencia a probabilidade de propagação de fogo para as células vizinhas. No intervalo de $[0, 1]$;
- ❑ **Tempo de ativação do Fogo Inicial:** ajusta quantos passos de tempo são necessários para o fogo ir de Fogo Inicial para Fogo Estável. No intervalo de $[0, 10]$.
- ❑ **Tempo de Ativação do Fogo Estável:** ajusta quantos passos de tempo são necessários para o fogo ir de Fogo Estável para Brasa. No intervalo de $[0, 10]$;
- ❑ **Tempo de Ativação da Brasa:** ajusta quantos passos de tempo são necessários para ir da Brasa para Cinza. No intervalo de $[0, 10]$;
- ❑ **Coefficiente de recuperação:** O parâmetro a ajusta a distribuição da probabilidade, controlando a rapidez com que a probabilidade de recuperação aumenta ao longo do tempo. No intervalo de $[0, 10]$.

4.6 Execução com os Parâmetros Base

Para os testes e avaliação do indivíduo, foram definidos os dados de referência do AC da seguinte maneira: $[0,24; NW, 0,6; 1,0; 0,2; 3; 3; 10; 6]$ seguindo a ordem apresentada na seção 4.5.

A Figura 12 apresenta os resultados da simulação de um incêndio florestal com os parâmetros apresentados.

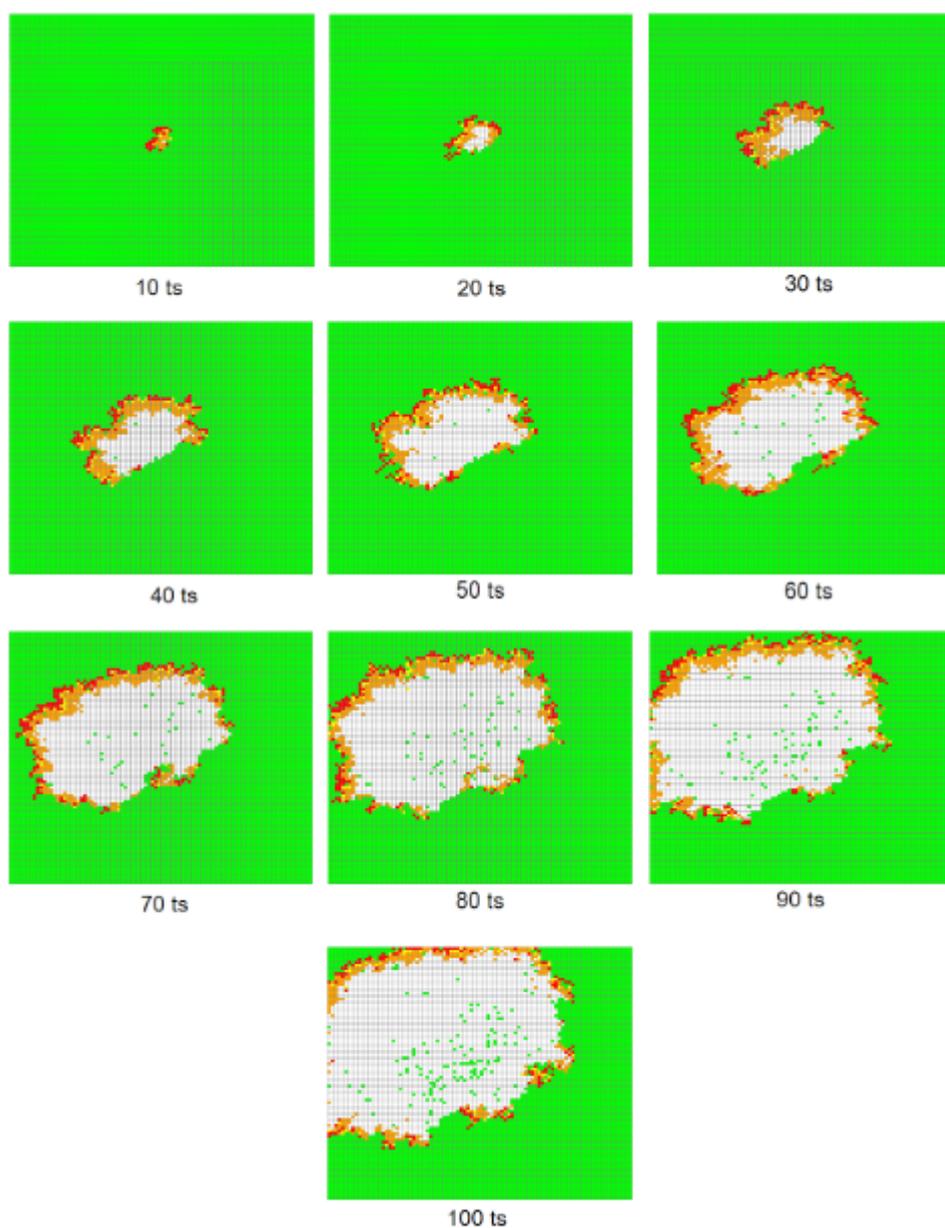


Figura 12 – Execução da simulação base.

Abordagem Evolutiva Proposta

Neste estudo, utilizou-se um Algoritmo Genético (AG) para ajustar os parâmetros do modelo de propagação de incêndios descrito no Capítulo 4. O objetivo é obter uma simulação que reflita com precisão o comportamento observado dos incêndios em áreas florestais. Inicialmente, diferentes configurações do AG foram testadas e empiricamente avaliadas a fim de se identificar a mais eficiente, que será apresentada a seguir.

5.1 Indivíduo

No contexto da simulação de propagação de incêndios, um indivíduo representa uma configuração específica dos parâmetros que influenciam a dinâmica do fogo no ambiente. Cada indivíduo é um vetor de características que determina como o fogo se comporta em diferentes condições. Sendo assim, a representação do indivíduo utilizado no AG implementado, é um vetor com os seguintes elementos: Coeficiente Calórico; Coeficiente de Vento; Intensidade do Fogo Inicial; Intensidade do Fogo Estável; Intensidade da Brasa; Tempo de ativação do Fogo Inicial; Tempo de Ativação do Fogo Estável; Tempo de Ativação da Brasa; e, Coeficiente de Recuperação.

Cada indivíduo é uma combinação desses parâmetros, permitindo ao AG explorar diferentes configurações para otimizar a propagação do fogo no ambiente simulado. A seguir, segue uma representação gráfica dessa combinação:

0,24	NW	0,6	1,0	0,2	3	3	10	6
------	----	-----	-----	-----	---	---	----	---

Figura 13 – Representação do Indivíduo.

5.2 Função de Avaliação

O processo começa com a construção de uma base de referência, que é estabelecida por meio de simulações realizadas para gerar um comportamento esperado da propagação

do incêndio. Esses resultados são registrados em um arquivo contendo a média das 100 execuções da simulação e os dados das células de fogo em cada uma das 9 seções em que o reticulado foi dividido, e servirá como referência para comparações futuras. Com a base de referência gerada, a simulação é configurada de acordo com os parâmetros específicos de cada indivíduo.

Após a configuração, a simulação é executada cinco vezes para cada indivíduo, para gerar dados sobre a propagação do incêndio, na mesma estrutura utilizada para a base de referência. Esses dados são coletados em intervalos regulares de tempo (a depender da base utilizada, podendo ser de 10 em 10 passos de tempo ou em todos os passos de tempo, como descrito na seção 6.1), possibilitando a avaliação da simulação ao longo de diferentes fases. Então, os resultados obtidos são comparados com aqueles armazenados na base de referência.

A aptidão do indivíduo é calculada com base na diferença média entre os resultados esperados e os resultados simulados. Este cálculo é realizado em múltiplas execuções da simulação para garantir uma avaliação mais precisa. Além disso, a comparação é feita em intervalos regulares, permitindo uma análise detalhada do comportamento do incêndio tanto em seus estágios iniciais quanto nos tardios.

Dessa forma, a função de aptidão mede a precisão com que o modelo de propagação de incêndio gerado por cada indivíduo se aproxima dos dados de referência. Ao minimizar o valor de *fitness*, o AG é direcionado a identificar os parâmetros que melhor reproduzem o comportamento esperado do incêndio. Assim, indivíduos com menores valores de *fitness* tendem a representar a propagação do incêndio de forma mais fiel e precisa.

5.2.1 Cálculo do *Fitness*

O primeiro cálculo do *fitness* utilizado é dado pela média aritmética da diferença absoluta entre os valores esperados e os valores simulados. Esse valor representa o *fitness* do indivíduo, e pode ser descrito de acordo com a equação a seguir:

$$Fitness = \frac{1}{n} \sum_{i=1}^n x_i \quad (3)$$

Onde, n é o número total de seções analisadas e x_i é a diferença absoluta entre o valor esperado e o valor atual para cada seção i .

Para o valor simulado e o valor esperado, são utilizadas duas abordagens: uma que leva em consideração apenas as células de fogo e outra que leva em consideração também as células queimadas, como descrito na subseção 6.3.2.

O segundo cálculo do *fitness*, apresentado na subseção 6.3.3, adota a média geométrica com o objetivo de minimizar o impacto desproporcional que a inclusão das células queimadas pode causar no cálculo da diferença entre as simulações. Para evitar problemas de precisão e *overflow* (quando um cálculo excede o limite do tipo de dado, gerando um

valor incorreto.) ao calcular a média geométrica, foi utilizada a somatória dos logaritmos dos valores, o que se mostrou mais estável. A fórmula utilizada para o cálculo da média geométrica é descrita a seguir:

$$FitnessGeo = exp\left(\frac{1}{n} \sum_{i=1}^n \log(x_i)\right) \quad (4)$$

Onde, n é o número total de seções analisadas e x_i é a diferença absoluta entre o valor esperado e o valor atual para cada seção i .

5.3 Configuração do AG

Para a configuração do AG, foram realizados testes preliminares utilizando a parametrização empregada no trabalho de Ferreira (2023). Após as primeiras execuções e ajustes, foram realizados testes adicionais, modificando os parâmetros um a um, e fixando os melhores resultados encontrados.

A melhor configuração encontrada foi uma população inicial de 200 indivíduos, gerados aleatoriamente dentro dos limites de cada gene. O algoritmo é executado por 100 gerações, com a seleção dos pais sendo realizada através de um torneio de 3. A taxa de *crossover* é de 90%, e o *crossover* é realizado através de uma máscara binária para definir de qual pai o gene será derivado.

A mutação, por sua vez, é realizada a uma taxa de 50% para definir se o indivíduo será escolhido para mutação. Após isso, para definir se o gene será mutado, aplica-se mais uma máscara binária. Os genes selecionados para mutação sofrem uma alteração de $[-0,2; 0,2]$ se são compostos por valores reais e de $[-1; 1]$ se são compostos por valores inteiros.

Para formar a população da próxima geração, é aplicado um processo de elitismo que mantém os 25% melhores indivíduos, enquanto o restante da população é preenchido com os filhos gerados através do *crossover*.

Experimentos e Análises

Este capítulo tem como objetivo validar, por meio de experimentação, a otimização dos parâmetros do modelo de propagação de incêndios proposto por Tinoco et al. (2022) (ver Seção 4). Inicialmente, serão descritos a base de dados e os experimentos preliminares que levaram as configurações utilizadas na simulação. Em seguida, os resultados obtidos são apresentados e analisados, com destaque para as configurações de parâmetros que geraram os melhores desempenhos. A análise dos resultados permitirá não apenas avaliar a eficácia da abordagem, mas também identificar possíveis áreas de aprimoramento no modelo.

6.1 Base de Dados de Referência

Neste trabalho, foi utilizada uma base de dados artificial gerada com os parâmetros de referência, empregando o modelo de simulação de incêndios proposto por Tinoco et al. (2022). Essa base de dados foi projetada para servir como referência na avaliação dos resultados obtidos pelos indivíduos gerados pelo Algoritmo Genético (AG), com o objetivo de ajustar os parâmetros do modelo de propagação de incêndios.

A primeira base de dados consiste na média de 100 execuções da simulação de incêndio, onde, a cada 10 passos de tempo, a quantidade de células em chamas em cada uma das 9 seções do reticulado é armazenada. Essa abordagem permite capturar a evolução do incêndio em intervalos regulares, fornecendo um panorama geral do comportamento do fogo ao longo do tempo.

A segunda base de dados mantém a mesma lógica da primeira, mas, desta vez, os dados são armazenados a cada passo de tempo, oferecendo uma resolução temporal mais refinada. A média de 100 execuções ainda é utilizada para suavizar as variações estocásticas inerentes ao processo de simulação, assegurando que os resultados reflitam de forma mais fiel o comportamento esperado do modelo.

A terceira base de dados segue a mesma lógica da segunda, porém, com a adição do número de células queimadas na soma dos resultados. Essa modificação visa capturar informações adicionais sobre o impacto do incêndio na paisagem ao longo do tempo, e

consequentemente a recuperação das células após o incêndio. A inclusão desse parâmetro na base de dados é discutida em mais detalhes na seção 6.3.2.

Por fim, para a análise de desempenho, foram geradas outras bases de dados para simular comportamentos específicos de incêndios, mas, que ainda seguem a mesma lógica apresentada nas outras bases.

Para reduzir variações estocásticas e minimizar o viés nos dados, todas as bases de dados foram construídas a partir da média de 100 execuções da simulação. A diferença entre os resultados da simulação e os valores de referência é calculada com base nessa média, garantindo uma avaliação mais consistente do desempenho dos indivíduos gerados pelo AG.

6.2 Experimentos Preliminares

Para configurar o AG, foram realizados testes preliminares com o objetivo de ajustar os seus parâmetros de maneira eficiente. Devido à inviabilidade de testar todas as combinações possíveis de parâmetros, considerando o tempo necessário para tal, optou-se por um processo iterativo de ajuste, baseado na abordagem apresentada por Ferreira (2023), começando os valores utilizados no trabalho como base. Neste processo, ajustamos um parâmetro por vez, mantendo fixos os valores que resultaram em melhor desempenho do *fitness* em cada etapa.

Inicialmente, o parâmetro ajustado foi a quantidade de gerações do AG. Foram testadas duas configurações: 100 e 200 gerações como critério de parada. Observou-se que o algoritmo não apresentava melhorias significativas após 100 gerações, levando à decisão de fixar esse valor como o parâmetro ideal.

Em seguida, testamos a quantidade de indivíduos por geração, comparando populações de 100 e 200 indivíduos. Verificou-se que, embora o uso de 200 indivíduos por geração tenha reduzido a performance do algoritmo devido ao maior tempo de execução, ele proporcionou um ganho significativo em termos de qualidade das soluções.

Para o tipo de *crossover*, avaliamos três métodos: ponto de corte simples, duplo e máscara binária. Os testes indicaram que o *crossover* por máscara binária ofereceu os melhores resultados. Adicionalmente, testamos diferentes taxas de *crossover* (85%, 90% e 95%), com a taxa de 90% se destacando como a mais eficiente.

Quanto à taxa de mutação, foram testadas as configurações de 25% e 50%. Os melhores resultados foram alcançados com uma taxa de mutação de 50%, combinada com o uso de uma máscara binária. Essa máscara, após determinar se um indivíduo sofrerá mutação, seleciona de forma aleatória qual ou quais genes específicos irão sofrer alterações.

Para a seleção dos pais, utilizamos o método de Torneio de 3, amplamente reconhecido na literatura por sua eficácia em balancear a exploração e a exploração do espaço de busca durante a busca por soluções ótimas. Esse balanceamento refere-se à capacidade

de explorar diferentes partes do espaço de soluções ao mesmo tempo em que foca nas soluções de maior qualidade. Por fim, para a reinserção, adotamos uma taxa de elitismo de 25%, garantindo que os melhores indivíduos de cada geração sejam preservados na população da geração seguinte.

6.3 Análise da Configuração do AG

A avaliação do AG foi realizada com o objetivo de mitigar os efeitos da estocasticidade inerente ao processo de simulação, mas ainda se preocupando em deixar o processo com um tempo viável para várias execuções. Por isso, cada indivíduo foi submetido a 5 execuções da simulação, com a média dos resultados sendo utilizada para comparação com os dados de referência. Essa abordagem visa garantir que o *fitness* refletisse de maneira mais precisa a qualidade da solução do que apenas uma simulação. Para os indivíduos com melhor desempenho em termos de *fitness*, foi conduzida uma análise visual das imagens do reticulado, para uma avaliação qualitativa adicional da solução.

6.3.1 Avaliação da Periodicidade

Inicialmente, a comparação foi realizada utilizando a base de referência que armazena os valores das células em estado de fogo a cada 10 TS e posteriormente a cada 1 TS.

Foram realizadas 30 execuções do AG, e em sua totalidade os indivíduos geraram os dados referentes ao *fitness*, presentes na Tabela 1.

	10 TS	1 TS
Maior	3,26	3,89
Menor	2,23	2,51
Mediana	2,66	2,91
Média	2,67	3,00
Desvio Padrão	0,25	0,34

Tabela 1 – Dados da Execução - Periodicidade.

Os resultados estatísticos da execução com 10 TS indicam que o AG apresentou um desempenho consistente na maioria das execuções, com valores de *fitness* concentrados em torno de uma média e mediana muito próximas. Entretanto, a presença de um valor maior de *fitness* um pouco mais elevado sugere que, em algumas execuções, o algoritmo pode ter sido influenciado por variações estocásticas ou por limitações na exploração do espaço de soluções, resultando em soluções subótimas. Por sua vez, o baixo desvio padrão reforça a ideia de consistência no desempenho, indicando uma baixa variação nos resultados e maior confiabilidade nas soluções geradas.

Após a análise do *fitness* e a análise gráfica, verificou-se que o melhor indivíduo do processo foi capaz de representar adequadamente a direção de propagação do fogo, no caso,

um vento com sentido Noroeste. No entanto, observou-se uma dificuldade em replicar com precisão o tipo de célula de fogo presente na referência, como é possível observar na Figura 15, o que sugere limitações na capacidade do AG em capturar nuances no comportamento do incêndio.

Para melhorar a precisão na definição dos tipos de células em estado de fogo e refinar a qualidade da solução, foi feita a comparação dos resultados com a base de referência a cada passo de tempo. Essa mudança trouxe um aumento no custo computacional do algoritmo, mas, ainda assim, manteve-se viável para a aplicação.

Os dados estatísticos mostram que o AG demonstrou um desempenho consistente, com a média e a mediana indicando que, na maioria das execuções, o algoritmo conseguiu ajustar adequadamente os parâmetros do modelo de propagação de incêndios. No entanto, a variação entre o valor máximo e o valor mínimo, juntamente com um desvio padrão um pouco mais alto que no experimento anterior, sugerem que, embora o AG produza soluções eficazes na maioria das vezes, ele ainda pode gerar resultados subótimos em algumas execuções. Isso acontece, principalmente, pelo fato da quantidade de comparações a serem feitas ser bem maior com essa base.

Apesar disso, com essa modificação, o melhor indivíduo continuou a representar bem a dispersão do fogo para o sentido Noroeste e demonstrou uma melhora na definição das células em estado de fogo, especialmente nas bordas do incêndio, como é possível observar na Figura 16. Entretanto, identificou-se uma área que poderia ser aprimorada: a recuperação das células na região central, onde o fogo já havia passado e as células estavam no estado de cinza.

A seguir, são apresentadas graficamente as execuções das simulações de incêndios a partir da base de referência, na Figura 14, e, com os parâmetros encontrados pelos dois métodos de avaliação, respectivamente na Figura 15 e Figura 16. Para facilitar a visualização os reticulados foram mostrados a cada 25 TS.

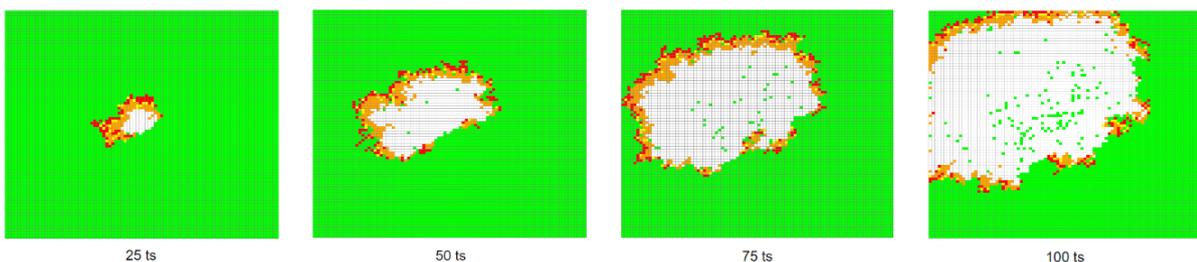


Figura 14 – Execução com a Base de Referência.

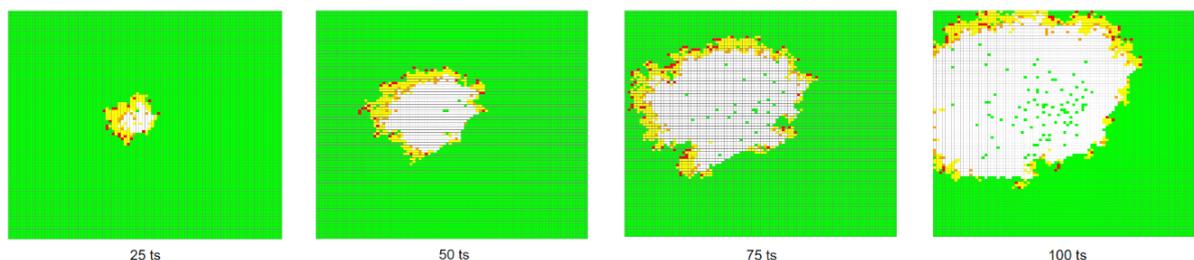


Figura 15 – Execução com o Indivíduo (Avaliação 10 TS).

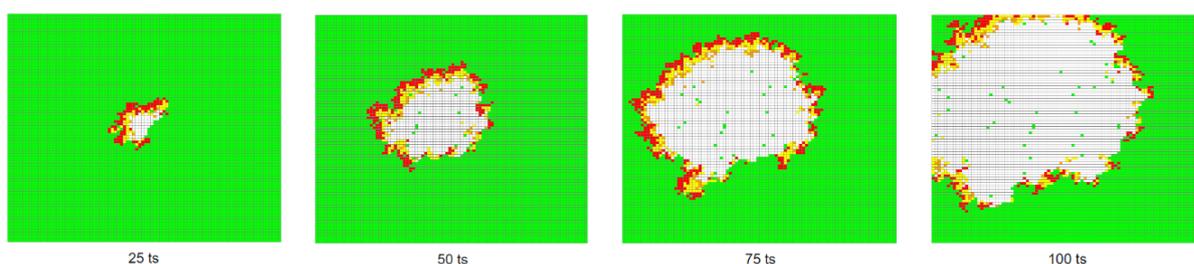


Figura 16 – Execução com o Indivíduo (Avaliação 1 TS).

Os valores dos parâmetros dos indivíduos encontrados foram os seguintes:

0,24	NW	0,6	1,0	0,2	3	3	10	6
------	----	-----	-----	-----	---	---	----	---

Figura 17 – Valores do Indivíduo Base.

0,27	NW	0,63	0,41	0,0	0	9	4	6
------	----	------	------	-----	---	---	---	---

Figura 18 – Valores do Indivíduo (Avaliação 10 TS).

0,22	NW	0,65	0,29	0,09	5	9	5	10
------	----	------	------	------	---	---	---	----

Figura 19 – Valores do Indivíduo (Avaliação 1 TS).

6.3.2 Avaliação de Tipos de Células

Com o intuito de abordar a questão da recuperação celular na região central mencionada anteriormente, passou-se a incluir, na soma das células em estado de fogo, as células em estado de cinza.

Após as 30 execuções do AG, os indivíduos geraram os dados apresentados na Tabela 2 referentes ao *fitness*.

A análise indica uma maior variação no desempenho do AG, a diferença significativa entre o valor máximo e o valor mínimo, juntamente com um desvio padrão, evidencia uma variabilidade maior nos resultados, o que pode indicar uma sensibilidade do AG

	Com Queimadas
Maior	6,54
Menor	3,60
Mediana	4,89
Média	4,88
Desvio Padrão	0,65

Tabela 2 – Dados da Execução - Tipos de Células.

às condições iniciais ou a possíveis nuances adicionais no comportamento das células queimadas. Essa dispersão nos valores de *fitness* sugere que, embora a inclusão das células queimadas tenha potencial para melhorar a acurácia do modelo, ela também aumenta a complexidade do problema, necessitando de refinamentos adicionais para melhorar a consistência e a precisão das simulações geradas pelo AG.

Apesar disso, a modificação proporcionou uma representação correta da dispersão do fogo no sentido Noroeste. Adicionalmente, o melhor indivíduo foi capaz de identificar com precisão o parâmetro associado à recuperação da vegetação nas áreas afetadas. Essa melhoria levou a uma recuperação da vegetação, que se aproximou ainda mais do comportamento registrado na base de referência. Contudo, observou-se que o formato geral da dispersão do fogo se distanciou ligeiramente da referência original. Visando diminuir essa discrepância e manter uma representação mais precisa da dispersão do fogo, foi desenvolvida uma avaliação utilizando a média geométrica, conforme descrito na subseção 6.3.3.

O *fitness* do melhor indivíduo foi de 3,6 e a seguir está apresentado graficamente a execução da simulação do incêndio com os dados de base, na Figura 20 e com os parâmetros encontrados pelo AG, na Figura 21.

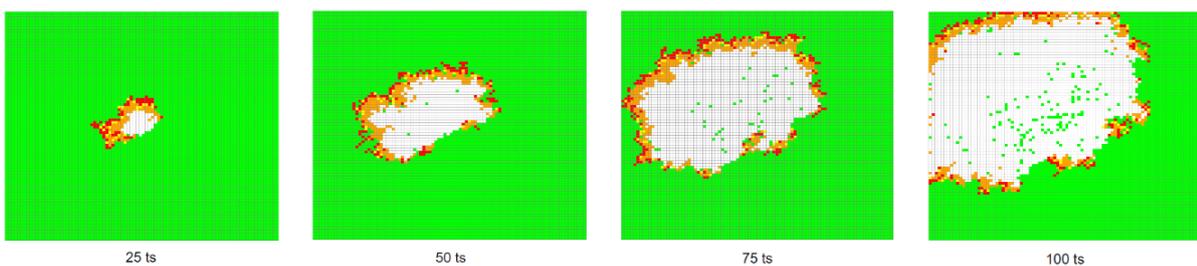


Figura 20 – Execução da Base de Referência.

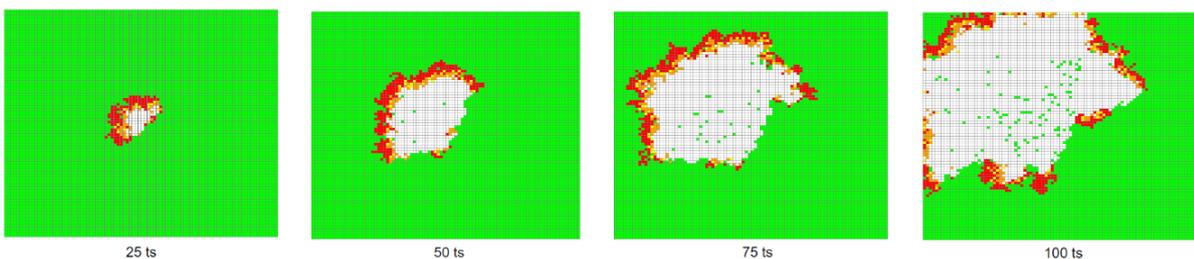


Figura 21 – Execução do Indivíduo (Avaliação 1 TS com células queimadas).

Os valores dos parâmetros do indivíduo encontrado foram os seguintes:

0,24	NW	0,6	1,0	0,2	3	3	10	6
------	----	-----	-----	-----	---	---	----	---

Figura 22 – Valores do Indivíduo Base.

0,33	NW	0,43	0,24	0,03	6	4	10	6
------	----	------	------	------	---	---	----	---

Figura 23 – Valores do Indivíduo (Avaliação 1 TS células queimada).

6.3.3 Avaliação da Melhor Média

Com o objetivo de aprimorar a análise da média e aumentar a precisão na avaliação do modelo, foi introduzida a comparação utilizando a média geométrica, na expectativa de capturar nuances mais sutis na recuperação da vegetação e na propagação do fogo, devido a discrepância entre a quantidade de células em estado cinza e a quantidade de células nos estados de fogo.

Após as 30 execuções do AG, os indivíduos geraram os dados referentes ao *fitness* presentes na Tabela 3.

	Média Geométrica ($\times 10^{-5}$)
Maior	9,45
Menor	3,33
Mediana	4,97
Média	5,31
Desvio Padrão	0,000015

Tabela 3 – Dados da Execução - Média Geométrica.

A análise resultante indicou que, assim como nas tentativas anteriores, a dispersão do fogo foi corretamente direcionada para o noroeste, como é possível ver na Figura 25. No entanto, o melhor indivíduo não foi capaz de identificar com precisão o parâmetro de recuperação da vegetação, e persistiu o problema observado anteriormente na subseção 6.3.2. Esse problema se refere à incapacidade do algoritmo de replicar o formato exato da dispersão de fogo conforme registrado na base de referência, o que limitou a eficácia dessa abordagem. Em certos aspectos, os resultados obtidos também não alcançaram a mesma precisão observada nos experimentos descritos na Seção 6.3.1.

A seguir, estão apresentadas graficamente a execução da simulação do incêndio a partir da base de referência, na Figura 24 e com os parâmetros encontrados pelo AG, na Figura 25.

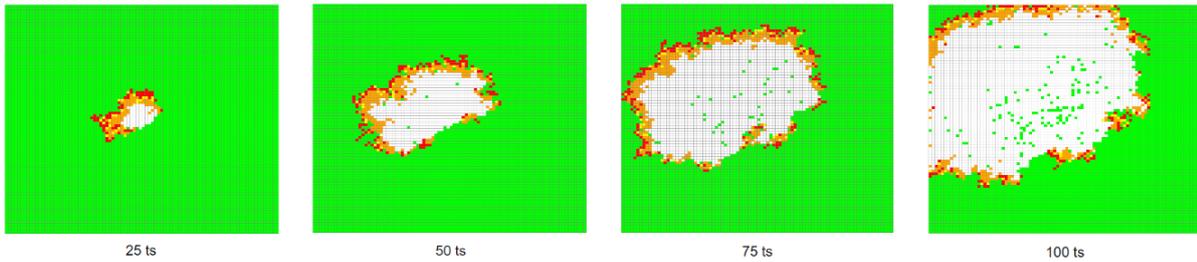


Figura 24 – Execução da Base de Referência.

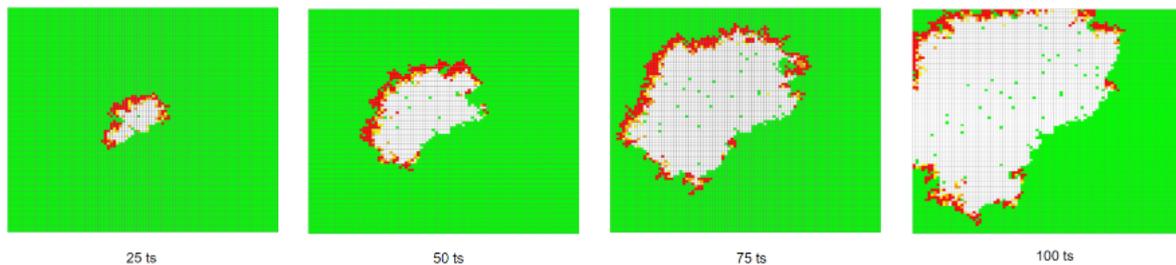


Figura 25 – Execução do Indivíduo (Avaliação Média Geométrica).

Os valores dos parâmetros do indivíduo encontrado foram os seguintes:

0,24	NW	0,6	1,0	0,2	3	3	10	6
------	----	-----	-----	-----	---	---	----	---

Figura 26 – Valores do Indivíduo Base.

0,19	NW	0,74	0,66	0,30	5	4	6	10
------	----	------	------	------	---	---	---	----

Figura 27 – Valores do Indivíduo (Avaliação Média Geométrica).

Dado que a avaliação com a média geométrica não trouxe melhorias significativas na modelagem da recuperação da vegetação e na precisão da propagação do fogo, optou-se por não prosseguir com essa abordagem nas análises posteriores.

6.4 Análise de Desempenho do AG

Esta seção tem como objetivo avaliar a otimização alcançada no modelo de simulação em diferentes configurações de incêndios, como foco na precisão da propagação do fogo em cenários variados. Foi adotado o método de avaliação que calcula a diferença a cada passo de tempo e considera apenas as células em fogo. Isso se deve ao fato de que, após a análise dos experimentos realizados na Seção 6.3 foi possível verificar que essa avaliação é a que traz maior precisão na captura dos padrões de propagação do incêndio, que é o objetivo deste trabalho.

É importante destacar que, em cenários reais, o foco não é ajustar os parâmetros exatos do modelo, como ocorre nos dados artificiais utilizados nos experimentos. Em situações práticas, o objetivo principal é garantir que a dispersão do incêndio seja corretamente representada, visto que os parâmetros corretos não existem em uma base de dados reais. Nos experimentos, conseguimos ajustar os parâmetros porque a base de dados utilizada foi gerada artificialmente, a partir do mesmo modelo que foi empregado para treinar o AG.

A seguir, são apresentadas as execuções realizadas para diferentes cenários de propagação do fogo, com base na referência utilizada e no melhor indivíduo encontrado pelo AG. As variações nos experimentos incluíram a direção do vento e a intensidade do incêndio, com o objetivo de avaliar o comportamento do modelo sob diferentes condições ambientais e analisar o ajuste dos parâmetros de propagação e recuperação.

Na primeira execução, foi simulado um incêndio com propagação na direção nordeste, com uma alta intensidade de fogo, como pode ser visto na Figura 28. O objetivo era testar a capacidade do modelo em representar uma situação de propagação rápida e intensa. A dispersão do fogo foi bem representada, com a direção do vento corretamente capturada e o formato geral da dispersão se aproximando da base de referência, como é possível ver na Figura 29. No entanto, a análise mais detalhada mostrou que, nas bordas do fogo, as células do tipo Brasa eram predominantes na base, enquanto na simulação do indivíduo gerado pelo AG predominavam células do tipo Fogo Inicial. Além disso, o parâmetro de recuperação da vegetação também não foi ajustado de maneira ideal, o que impacta a regeneração das áreas queimadas.

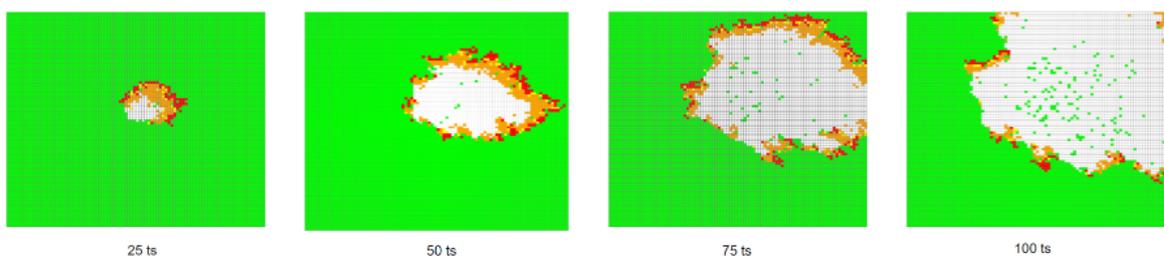


Figura 28 – Execução do Indivíduo Base (Análise 1).

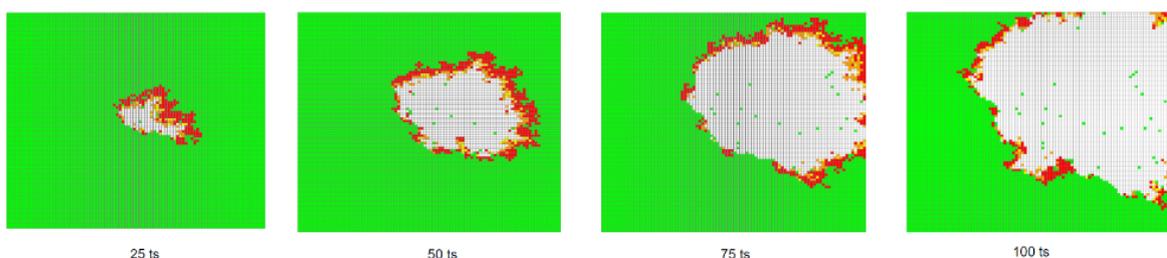


Figura 29 – Execução do Indivíduo (Análise 1).

Na segunda execução, foi simulada a propagação na direção sudoeste, mas com uma intensidade de fogo moderada, menor do que na primeira simulação, como pode ser visto

na Figura 30. Este cenário permitiu avaliar o comportamento do modelo em condições menos severas. Visualmente, a direção do vento foi novamente bem capturada, e a área queimada resultante apresentou um formato circular, consistente com a base de referência, como é possível ver na Figura 31. Contudo, mais uma vez, o parâmetro de recuperação da vegetação apresentou discrepâncias, e os tipos de células de fogo não foram adequadamente representados. Na base de referência, a transição para células de Brasa era mais evidente, enquanto a execução do indivíduo produzido pelo AG mostrou uma predominância de células do tipo Fogo Estável.

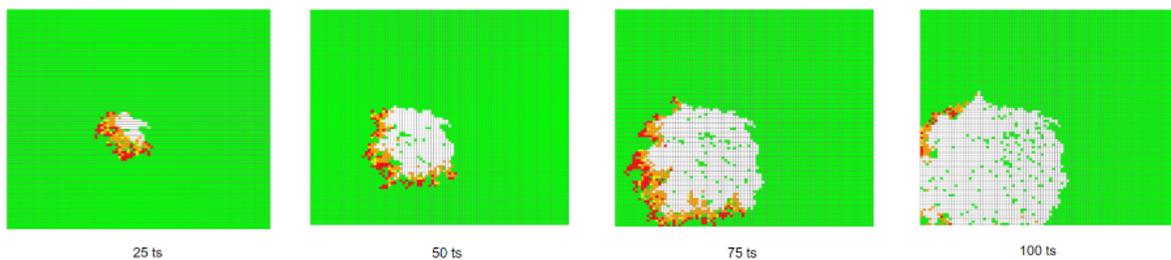


Figura 30 – Execução do Indivíduo Base (Análise 2).

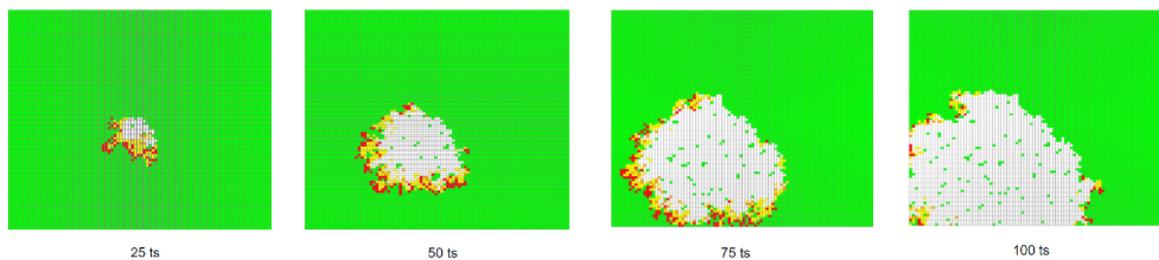


Figura 31 – Execução do Indivíduo (Análise 2).

Na terceira execução, a propagação foi novamente simulada na direção noroeste, mas desta vez com uma intensidade de fogo significativamente menor, como pode ser visto na Figura 32. O objetivo era verificar se o modelo poderia representar incêndios de menor escala de forma consistente. Embora a direção do fogo tenha sido bem capturada, o formato da dispersão se afastou mais da base de referência do que nas execuções anteriores, sugerindo que o modelo necessita de ajustes adicionais para capturar com precisão incêndios de menor intensidade. Ainda assim, houve uma melhora na representação do parâmetro de recuperação da vegetação, embora os tipos de células de fogo continuem a apresentar diferenças em relação à base. Mais uma vez, células do tipo Brasa eram mais comuns na base de referência, enquanto o indivíduo gerado apresentou uma predominância de Fogo Inicial.

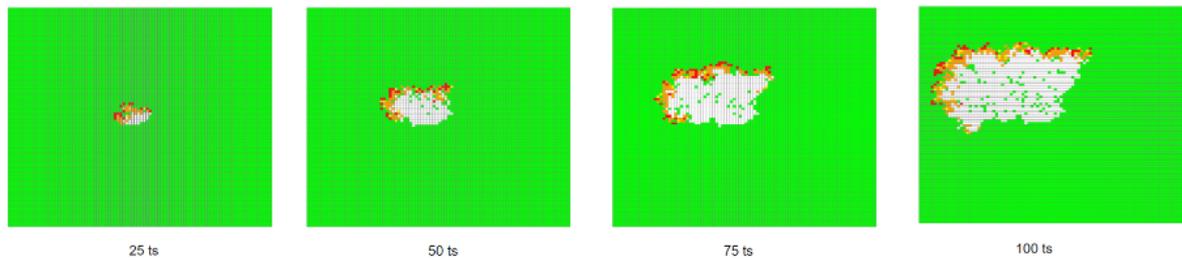


Figura 32 – Execução do Indivíduo Base (Análise 3).

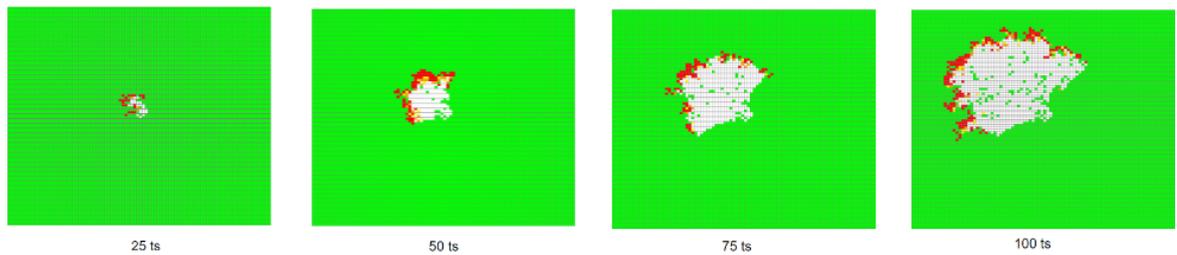


Figura 33 – Execução do Indivíduo (Análise 3).

Em resumo, as simulações realizadas com os parâmetros otimizados pelo AG para diferentes cenários de propagação do fogo demonstraram que, embora o modelo tenha sido eficaz em capturar a direção do vento e a intensidade do fogo, ainda há ajustes necessários para aprimorar a representação dos tipos de células de fogo e do parâmetro de recuperação da vegetação. A direção correta do fogo foi consistentemente alcançada, mas a transição entre os estágios de incêndio e a regeneração das áreas afetadas apresentaram discrepâncias em relação à base de referência. Esses resultados indicam que o modelo possui potencial para representar com precisão cenários de incêndio de maior escala, mas precisa de melhorias para capturar com maior fidelidade incêndios de menor intensidade e a dinâmica de recuperação pós-incêndio. Assim, as futuras iterações deverão focar nesses ajustes para aprimorar a robustez e a precisão do modelo em diversos contextos.

Conclusão

Este trabalho apresentou uma abordagem evolutiva para o ajuste automático dos parâmetros de um modelo de propagação de incêndios florestais, baseado em autômatos celulares probabilísticos. O objetivo principal foi desenvolver um algoritmo genético capaz de ajustar os parâmetros do modelo a partir dos dados de incêndios e conseguir simular a dispersão do fogo em um incêndio real.

Através dos experimentos realizados, foi validada a eficácia dos algoritmos genéticos em identificar valores próximos aos ótimos para os parâmetros do modelo. Mesmo nos casos em que os valores exatos não foram plenamente atingidos, as simulações resultantes apresentaram uma representação fiel da dispersão do fogo em relação à base de referência, especialmente em termos de direção do vento e formato geral da propagação. Isso demonstra a força do método desenvolvido, que conseguiu capturar de maneira consistente o comportamento de propagação do incêndio em diferentes cenários, variando a intensidade e a direção do fogo.

Entretanto, algumas limitações ainda foram observadas, como a dificuldade do AG em ajustar com precisão o parâmetro de recuperação da vegetação e os tipos de células de fogo ao longo do processo de propagação, devido a incapacidade da função de avaliação de captar essas nuances. Esses aspectos indicam que o algoritmo pode ser refinado para alcançar um ajuste mais preciso em cenários complexos.

Em resumo, os resultados obtidos demonstram que a abordagem evolutiva desenvolvida é promissora para o ajuste automático de parâmetros em modelos de propagação de incêndios, contribuindo para a simulação de cenários mais realistas e auxiliando na tomada de decisões em situações de risco de incêndios florestais.

Diante dos resultados obtidos, uma das principais áreas para trabalhos futuros é a definição mais precisa dos estados das células fogo durante a simulação. A identificação correta de estados fogo inicial, fogo estável e brasa ainda apresenta inconsistências em relação à base de referência, o que afeta a precisão da simulação. Para melhorar esse aspecto, uma investigação de novas funções de avaliação pode auxiliar na captura mais precisa dessas nuances, garantindo maior fidelidade na representação da propagação do

fogo.

Além disso, outro foco importante é a melhoria na definição dos parâmetros de recuperação das células afetadas pelo fogo. Nos experimentos atuais, o ajuste desses parâmetros não foi totalmente otimizado, o que impactou a fidelidade do comportamento de regeneração da vegetação após o incêndio. Uma abordagem alternativa na função de avaliação também pode auxiliar na obtenção desse ajuste de maneira mais precisa.

E, por fim, a incorporação de fatores ambientais adicionais, como a variação da umidade, temperatura, pode melhorar a precisão do modelo na simulação de incêndios em condições mais realistas. Esses fatores poderiam proporcionar uma representação mais detalhada e fiel do comportamento do fogo em diferentes situações.

Referências

- ABURAS, M. M. et al. The simulation and prediction of spatio-temporal urban growth trends using cellular automata models: A review. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 52, p. 380–389, 2016. ISSN 1569-8432. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2016.07.007>>.
- ARTAXO, P. et al. Efeitos climáticos de partículas de aerossóis biogênicos e emitidos em queimadas na amazônia. **Revista brasileira de meteorologia**, v. 21, n. 3a, p. 168–22, 2006.
- CHOPARD, B.; DROZ, M. **Cellular Automata Modeling of Physical Systems**. Cambridge University Press, 1998. ISBN 9780511549755. Disponível em: <<http://dx.doi.org/10.1017/cbo9780511549755>>.
- CLARKE, K. C.; BRASS, J. A.; RIGGAN, P. J. A cellular automation model of wildfire propagation and extinction. **Photogrammetric Engineering and Remote Sensing**, [Falls Church, Va.] American Society of Photogrammetry., v. 60, n. 11, p. 1355–1367, 1994.
- COPPIN, B. **Inteligência Artificial**. LTC, 2010. ISBN 9788521617297. Disponível em: <<https://books.google.com.br/books?id=Z3UURQAACAAJ>>.
- FERREIRA, M. E. de Á. **Ajuste evolutivo de parâmetros de autômatos celulares probabilísticos em modelos de propagação de incêndios**. Tese (Doutorado) — EDUFU - Editora da Universidade Federal de Uberlândia, 2023. Disponível em: <<http://dx.doi.org/10.14393/ufu.di.2023.192>>.
- FRAGA, L. M.; OLIVEIRA, G. M. de; MARTINS, L. G. Multistage evolutionary strategies for adjusting a cellular automata-based epidemiological model. In: **IEEE. 2021 IEEE Congress on Evolutionary Computation (CEC)**. Kraków, Poland, 2021. p. 466–473. Disponível em: <<http://dx.doi.org/10.1109/cec45853.2021.9504738>>.
- GOLDBERG, D. E. Genetic algorithms in search, optimization, and machine learning. **Choice Reviews Online**, American Library Association, n. 02, 1989. ISSN 1523-8253. Disponível em: <<http://dx.doi.org/10.5860/choice.27-0936>>.
- GONÇALVES, K. d. S.; CASTRO, H. A. d.; HACON, S. d. S. As queimadas na região amazônica e o adoecimento respiratório. **Ciência & Saúde Coletiva**, SciELO Public Health, v. 17, p. 1523–1532, 2012. ISSN 1413-8123. Disponível em: <<http://dx.doi.org/10.1590/s1413-81232012000600016>>.

- GREFENSTETTE, J. et al. Genetic algorithms for the traveling salesman problem. In: PSYCHOLOGY PRESS. **Proceedings of the first International Conference on Genetic Algorithms and their Applications**. 2014. p. 160–168. ISBN 9781317760252. Disponível em: <<http://dx.doi.org/10.4324/9781315799674>>.
- GREFENSTETTE, J. J. Genetic algorithms and machine learning. In: **Proceedings of the sixth annual conference on Computational learning theory - COLT '93**. ACM Press, 1993. (COLT '93), p. 3–4. Disponível em: <<http://dx.doi.org/10.1145/168304.168305>>.
- HOLLAND, J. H. **Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence**. MIT Press, 1992. (Bradford book). ISBN 9780585038445. Disponível em: <<https://books.google.com.br/books?id=cyV7nQEACAAJ>>.
- ILACHINSKI, A. **Cellular Automata: A Discrete Universe**. WORLD SCIENTIFIC, 2001. ISBN 9789812386519. Disponível em: <<http://dx.doi.org/10.1142/4702>>.
- IZHIKEVICH, E. M.; CONWAY, J. H.; SETH, A. Game of Life. **Scholarpedia**, v. 10, n. 6, p. 1816, 2015. ISSN 1941-6016. Disponível em: <<http://dx.doi.org/10.4249/scholarpedia.1816>>.
- JONES, M. W. et al. Climate change increases the risk of wildfires. **ScienceBrief Review**, v. 116, p. 117, 2020.
- KARAFYLLIDIS, I.; THANAILAKIS, A. A model for predicting forest fire spreading using cellular automata. **Ecological Modelling**, Elsevier, v. 99, n. 1, p. 87–97, 1997. ISSN 0304-3800. Disponível em: <[http://dx.doi.org/10.1016/s0304-3800\(96\)01942-4](http://dx.doi.org/10.1016/s0304-3800(96)01942-4)>.
- LINDEN, R. **Algoritmos genéticos**. CIENCIA MODERNA, 2012. ISBN 9788539901951. Disponível em: <<https://books.google.com.br/books?id=SrKouQAACAAJ>>.
- LOUZADA, V. H. P.; JUNIOR, W. Incêndios florestais em autômatos celulares, simples e grandes queimadas. **Biomatemática-Unicamp**, v. 18, p. 15–26, 2008.
- MALIK, S. et al. Cloud seeding; its prospects and concerns in the modern world—a review. **Int. J. Pure App. Biosci**, v. 6, n. 5, p. 791–796, 2018. ISSN 2320-7051. Disponível em: <<http://dx.doi.org/10.18782/2320-7051.6824>>.
- MEDEIROS, M. B. d.; FIEDLER, N. C. Incêndios florestais no parque nacional da serra da canastra: desafios para a conservação da biodiversidade. **Ciência Florestal**, SciELO Brasil, v. 14, p. 157–168, 2004. ISSN 0103-9954. Disponível em: <<http://dx.doi.org/10.5902/198050981815>>.
- MUKHOPADHYAY, A. et al. A survey of multiobjective evolutionary algorithms for data mining: Part i. **IEEE Transactions on Evolutionary Computation**, IEEE, v. 18, n. 1, p. 4–19, 2013. ISSN 1941-0026. Disponível em: <<http://dx.doi.org/10.1109/tevc.2013.2290086>>.
- NICULESCU, S. P. Artificial neural networks and genetic algorithms in qsar. **Journal of molecular structure: THEOCHEM**, Elsevier, v. 622, n. 1-2, p. 71–83, 2003. ISSN 0166-1280. Disponível em: <[http://dx.doi.org/10.1016/s0166-1280\(02\)00619-x](http://dx.doi.org/10.1016/s0166-1280(02)00619-x)>.

- ONWUBOLU, G. C.; MUTINGI, M. A genetic algorithm approach to cellular manufacturing systems. **Computers & industrial engineering**, Elsevier, v. 39, n. 1-2, p. 125–144, 2001. ISSN 0360-8352. Disponível em: <[http://dx.doi.org/10.1016/s0360-8352\(00\)00074-7](http://dx.doi.org/10.1016/s0360-8352(00)00074-7)>.
- PAUSAS, J. G.; KEELEY, J. E. Wildfires as an ecosystem service. **Frontiers in Ecology and the Environment**, Wiley Online Library, v. 17, n. 5, p. 289–295, 2019. ISSN 1540-9309. Disponível em: <<http://dx.doi.org/10.1002/fee.2044>>.
- PRINS, C. A simple and effective evolutionary algorithm for the vehicle routing problem. **Computers & operations research**, Elsevier, v. 31, n. 12, p. 1985–2002, 2004. ISSN 0305-0548. Disponível em: <[http://dx.doi.org/10.1016/s0305-0548\(03\)00158-8](http://dx.doi.org/10.1016/s0305-0548(03)00158-8)>.
- ROTHERMEL, R. C. **Mann Gulch fire: A race that couldn't be won**. U.S. Department of Agriculture, Forest Service, Intermountain Research Station, 1993. Disponível em: <<http://dx.doi.org/10.2737/int-gtr-299>>.
- ROTHMAN, D. H.; KELLER, J. M. Immiscible cellular-automaton fluids. **Journal of Statistical Physics**, Springer, v. 52, p. 1119–1127, 1988. ISSN 1572-9613. Disponível em: <<http://dx.doi.org/10.1007/bf01019743>>.
- SUN, L. et al. Adaptive forest fire spread simulation algorithm based on cellular automata. **Forests**, MDPI, v. 12, n. 11, p. 1431, 2021. ISSN 1999-4907. Disponível em: <<http://dx.doi.org/10.3390/f12111431>>.
- TAN, K. C. Book review: The design of innovation: Lessons from and for competent genetic algorithms. **Genetic Programming and Evolvable Machines**, Springer Science and Business Media LLC, v. 5, n. 1, p. 107–110, mar. 2004. ISSN 1389-2576. Disponível em: <<http://dx.doi.org/10.1023/b:genp.0000017054.24706.3b>>.
- TINOCO, C. R. et al. Wildfire simulation model based on cellular automata and stochastic rules. In: SPRINGER. **Cellular Automata**. Springer International Publishing, 2022. p. 246–256. ISBN 9783031149269. Disponível em: <http://dx.doi.org/10.1007/978-3-031-14926-9_22>.
- WOLFRAM, S. Cryptography with cellular automata. In: SPRINGER. **Advances in Cryptology—CRYPTO'85 Proceedings 5**. 1986. p. 429–432. Disponível em: <<https://content.wolfram.com/sw-publications/2020/07/cryptography-cellular-automata.pdf>>.
- WOLFRAM, S. et al. **A new kind of science**. Wolfram media Champaign, 2002. Disponível em: <<https://www.wolframscience.com/nks/>>.
- YOON, Y.; KIM, Y.-H. An efficient genetic algorithm for maximum coverage deployment in wireless sensor networks. **IEEE Transactions on Cybernetics**, IEEE, v. 43, n. 5, p. 1473–1483, 2013. ISSN 2168-2275. Disponível em: <<http://dx.doi.org/10.1109/tcyb.2013.2250955>>.