
**Ajuste Evolutivo de Parâmetros de Autômatos
Celulares Probabilísticos em Modelos de
Propagação de Incêndios**

Maria Eugênia de Ávila Ferreira



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Uberlândia
2023

Maria Eugênia de Ávila Ferreira

**Ajuste Evolutivo de Parâmetros de Autômatos
Celulares Probabilísticos em Modelos de
Propagação de Incêndios**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dra. Gina Maira Barbosa de Oliveira

Coorientador: Prof. Dr. Luiz Gustavo Almeida Martins

Uberlândia

2023

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

F383 Ferreira, Maria Eugenia de Avila, 1994-
2023 Ajuste evolutivo de parâmetros de autômatos celulares
probabilísticos em modelos de propagação de incêndios
[recurso eletrônico] / Maria Eugenia de Avila Ferreira.
- 2023.

Orientadora: Gina Maira Barbosa de Oliveira.
Coorientador: Luiz Gustavo Almeida Martins.
Dissertação (Mestrado) - Universidade Federal de
Uberlândia, Pós-graduação em Ciência da Computação.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2023.192>
Inclui bibliografia.
Inclui ilustrações.

1. Computação. I. Oliveira, Gina Maira Barbosa de,
1967-, (Orient.). II. Martins, Luiz Gustavo Almeida,
1974-, (Coorient.). III. Universidade Federal de
Uberlândia. Pós-graduação em Ciência da Computação. IV.
Título.

CDU: 681.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Ciência da Computação
 Av. João Naves de Ávila, 2121, Bloco 1A, Sala 243 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4470 - www.ppgco.facom.ufu.br - cpgrafacom@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ciência da Computação				
Defesa de:	Dissertação de Mestrado 1/2023, PPGCO				
Data:	30 de março de 2023	Hora de início:	14:00	Hora de encerramento:	16:05
Matrícula do Discente:	12012CCP007				
Nome do Discente:	Maria Eugênia de Ávila Ferreira				
Título do Trabalho:	Ajuste Evolutivo de Parâmetros de Autômatos Celulares Probabilísticos em Modelos de Propagação de Incêndios				
Área de concentração:	Ciência da Computação				
Linha de pesquisa:	Inteligência Artificial				
Projeto de Pesquisa de vinculação:	-				

Reuniu-se, por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Laurence Rodrigues do Amaral - FACOM/UFU, Luiz Gustavo Almeida Martins - FACOM/UFU (coorientador), Luiz Henrique Alves Monteiro - Mackenzie e Gina Maira Barbosa de Oliveira - FACOM/UFU, orientadora da candidata.

Os examinadores participaram desde as seguintes localidades: Luiz Henrique Alves Monteiro - São Paulo - SP, Laurence Rodrigues do Amaral - Patos de Minas - MG, Luiz Gustavo Almeida Martins e Gina Maira Barbosa de Oliveira - Uberlândia - MG. A discente participou da cidade de Uberlândia/MG.

Iniciando os trabalhos a presidente da mesa, Prof.^a Dr.^a Gina Maira Barbosa de Oliveira, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público, e concedeu a Discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir a senhora presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir a candidata. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando a candidata:

Aprovada

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Luiz Henrique Alves Monteiro, Usuário Externo**, em 05/04/2023, às 09:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Gina Maira Barbosa de Oliveira, Professor(a) do Magistério Superior**, em 05/04/2023, às 18:26, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luiz Gustavo Almeida Martins, Professor(a) do Magistério Superior**, em 10/04/2023, às 15:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Laurence Rodrigues do Amaral, Professor(a) do Magistério Superior**, em 11/04/2023, às 09:37, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4382004** e o código CRC **04ABF11A**.

*Este trabalho é dedicado ao meu avô, Hélio Martins de Ávila,
visto que de todo o amor que eu tenho, metade foi ele quem me deu,
salvando minh'alma da vida, sorrindo e fazendo meu eu.*

Agradecimentos

A Deus porque d'Ele, por meio d'Ele, e para Ele são todas as coisas.

À minha orientadora, professora Dra. Gina Maira Barbosa de Oliveira, pelas valorosas contribuições, dedicação, encorajamento, e por confiar em mim e nesse trabalho inclusive nas vezes em que eu duvidei.

Ao meu co-orientador, professor Dr. Luiz Gustavo Almeida Martins, pelas sugestões fundamentais e pelas contribuições ao longo desse trabalho e pelo acolhimento nos momentos necessários.

À minha mãe, Maria Tereza, por ter me amado como as flores amam, por segurar minha mão e meu coração e às vezes esquecer-se dela para cuidar de mim. Ao meu tio Dedé pelo incentivo aos meus estudos desde sempre e para sempre.

Ao meu namorado, Kayque, pela sorte de um amor tranquilo, pelo companheirismo e por me apoiar nos momentos necessários e nunca desistir de mim.

Ao Theo, que esteve ao meu lado me energizando com o seus ronronados.

Ao meu amigo e irmão de alma, Renato Emanuel, pela serenidade, pelos comentários pertinentes e por ser uma referência e inspiração quando eu penso no papel transformador de um professor. À minha grande amiga, Danielli Lima, por todo o incentivo, pelas colaborações cruciais no desenvolvimento deste trabalho e por me inspirar como pesquisadora.

Aos meus amigos, em especial a Camila, Fred, Mariana, Nicolle e Regiane por entenderem minha ausência e por me fazerem rir nos momentos mais tortuosos.

À minha companheira nessa jornada do Mestrado, Janayna, por dividir comigo o peso das disciplinas, por compartilharmos as mesmas expectativas e as madrugadas em claro.

Ao meu amigo de longa data e agora colega de LCBio, Eduardo Cassiano por estar ao meu lado, mesmo que nos momentos mais caóticos nos respondêssemos a cada trimestre. Aos meus parceiros do LCBio, em especial ao Claudiney, Heitor e André, pelas contribuições diretas na construção deste trabalho.

Aos professores do Programa de Pós-Graduação da Faculdade de Computação por contribuírem significativamente para à minha formação. Ao Erisvaldo Fialho, pela presteza e dedicação nos momentos necessários.

“Great minds discuss ideas, average minds discuss events, small minds discuss people.”
(Eleanor Roosevelt)

Resumo

Incêndios florestais causam os mais distintos danos, sejam ambientais ou socioambientais. Eles têm aumentado significativamente como resultado das mudanças climáticas, que afetam diversos biomas. A fim de ajudar especialistas na contenção desses fenômenos, a propagação de um incêndio florestal pode ser simulada por meio de modelos computacionais. A modelagem da propagação do fogo é essencial na prevenção e controle dos danos causados pelos incêndios em áreas com vegetação nativa. Autômatos celulares (ACs) são modelos discretos que representam um reticulado de células que interagem entre si. Seu uso tem sido investigado na modelagem de diversos fenômenos naturais, inclusive na propagação de incêndios. Entretanto, para uma modelagem satisfatória, devem-se considerar características do bioma como tipo de vegetação, solo, clima, vento e topografia do terreno. Ajustar os vários parâmetros envolvidos nessa modelagem, costuma ser uma tarefa bastante árdua e complexa. Nesse contexto, este trabalho propõe um método evolutivo, baseado em Algoritmos Genéticos, para o ajuste dos parâmetros de modelos de propagação de incêndios baseados em regras de autômatos celulares probabilísticos. A fim de avaliar a efetividade da abordagem proposta e sua sensibilidade à variação nos dados a serem modelados, vários experimentos foram realizados, considerando cenários com vegetações homogêneas e heterogêneas e diferentes características do bioma. Nesse processo, devido à falta de dados reais de incêndio, empregaram-se dados gerados a partir do AC e por outros dois modelos disponíveis na literatura. Os resultados alcançados mostram que o algoritmo evolutivo é capaz de ajustar de forma automática os parâmetros de um modelo de propagação de incêndio.

Palavras-chave: Algoritmos genéticos. Autômatos celulares. Modelo de propagação de incêndios. Computação evolutiva. Ajustes de parâmetros.

Abstract

Forest fires cause diverse damages, whether environmental or socio-environmental. They have significantly increased as a result of climate change, which affects various biomes. In order to assist experts in containing these phenomena, the spread of a forest fire can be simulated through computational models. Modeling the spread of fire is essential in preventing and controlling the damage caused by fires in areas with native vegetation. Cellular automata (CA) are discrete models that represent a lattice of cells that interact with each other. Their use has been investigated in modeling various natural phenomena, including the spread of fires. However, for satisfactory modeling, characteristics of the biome such as vegetation type, soil, climate, wind, and terrain topography should be considered. Adjusting the various parameters involved in this modeling can be a challenging and complex task. In this context, this study proposes an evolutionary method based on Genetic Algorithms to adjust the parameters of fire spread models based on probabilistic cellular automata rules. In order to evaluate the effectiveness of the proposed approach and its sensitivity to variations in the data to be modeled, several experiments were carried out, considering scenarios with homogeneous and heterogeneous vegetation and different biome characteristics. In this process, due to the lack of real fire data, data generated from CA and two other models available in the literature were employed. The results achieved show that the evolutionary algorithm is capable of automatically adjusting the parameters of a fire spread model.

Keywords: Genetic algorithms. Cellular automata. Fire propagation model. Evolutionary computing. Parameters adjustments.

Lista de ilustrações

Figura 1 – Principais dimensões para o espaço celular de um autômato celular. . .	32
Figura 2 – Formatos possíveis para as células de um autômato celular.	33
Figura 3 – Estratégias de definição da vizinhança das células de borda em um autômato celular: periódicas (célula mais à direita é vizinha da célula mais à esquerda); reflexivas (células da borda são replicadas); e fixas (um mesmo estado é utilizado para complementar a vizinhança das bordas).	34
Figura 4 – Evolução temporal de um AC unidimensional.	35
Figura 5 – Vizinhanças de um AC bidimensional.	35
Figura 6 – Vizinhanças em um AC tridimensional	36
Figura 7 – Evolução temporal do AC “O Jogo da Vida”.	36
Figura 8 – Ciclo de um algoritmo genético.	39
Figura 9 – Possíveis representações de um indivíduo.	40
Figura 10 – Representação de uma população.	40
Figura 11 – Funcionamento do método de seleção da roleta.	42
Figura 12 – Aplicação do método de torneio com <i>tour</i> de 3.	43
Figura 13 – <i>Crossover</i> simples (um ponto de corte).	44
Figura 14 – <i>Crossover</i> duplo (dois pontos de corte).	44
Figura 15 – <i>Crossover</i> uniforme.	45
Figura 16 – <i>Crossover</i> aritmético.	45
Figura 17 – Exemplo de mutação binária.	46
Figura 18 – Exemplo de mutação por permutação.	46
Figura 19 – Exemplo de mutação em indivíduos numéricos (mutação aritmética). .	46
Figura 20 – Comportamento do modelo Louzada e Junior (2008).	53
Figura 21 – Matriz de preferências para raio 1 utilizada no modelo Lima e Lima (2014).	53
Figura 22 – Comportamento do modelo Lima e Lima (2014).	54
Figura 23 – Comportamento do modelo Tinoco et al. (2022).	55

Figura 24 – Exemplos de matrizes de preferências que representam o veto em cenários homogêneos.	60
Figura 25 – Vetores de forças das matrizes de preferências de cenários homogêneos.	61
Figura 26 – Cenário homogêneo com o vento na direção oeste.	62
Figura 27 – Cenário homogêneo com o vento na direção leste.	62
Figura 28 – Cenário homogêneo com o vento na direção sul.	63
Figura 29 – Cenário homogêneo com o vento na direção noroeste.	63
Figura 30 – Vetores representando o vento dos cenários heterogêneos.	64
Figura 31 – Cenário heterogêneo com dois tipos de vegetação.	65
Figura 32 – Cenário heterogêneo com três tipos de vegetação.	65
Figura 33 – Cenário heterogêneo com quatro tipos de vegetação.	66
Figura 34 – Representação do Indivíduo do AC para um modelo com uma única vegetação.	68
Figura 35 – Representação do Indivíduo do AC heterogêneo com duas vegetações. .	68
Figura 36 – Representação do Indivíduo do AC heterogêneo com três vegetações. .	69
Figura 37 – Representação do Indivíduo do AC heterogêneo com quatro vegetações.	69
Figura 38 – Evolução temporal completa de um incêndio simulado a partir do autômato celular com o vento para o oeste.	74
Figura 39 – Configuração usada como referência: (a) parâmetros; (b) força vetorial resultante dos valores da matriz de preferências que representa a direção a intensidade do vento; (c) evolução temporal da propagação de fogo. .	77
Figura 40 – Configurações encontradas pelo algoritmo genético e os respectivos vetores de força que representam a intensidade e direção dos ventos modelados, de acordo com a função de aptidão adotada: cenário de referência ((a) e (b)); reticulado único ((c) e (d)); 4 partições ((e) e (f)); 9 partições ((g) e (h)); e células individuais ((i) e (j)).	79
Figura 41 – Evolução temporal de um incêndio simulado a partir do autômato celular configurado com os parâmetros encontrados pelo algoritmo genético, de acordo com a função de aptidão: (a) referência; (b) reticulado único (1R); (c) 4 partições (4P); (d) 9 partições (9P); e (e) células individuais.	80
Figura 42 – Configurações encontradas pelo algoritmo genético e os respectivos vetores de força que representam a intensidade e direção dos ventos modelados, de acordo com o <i>crossover</i> adotado: cenário de referência ((a) e (b)); dois pontos de corte ((c) e (d)); uniforme ((e) e (f)); e aritmético ((g) e (h)).	84
Figura 43 – Evolução temporal de um incêndio simulado a partir do autômato celular configurado com os parâmetros encontrados pelo algoritmo genético, de acordo com o <i>crossover</i> : (a) referência; (b) dois pontos de corte; (c) uniforme; (d) e aritmético.	85

Figura 44 – Configurações encontradas pelo algoritmo genético e os respectivos vetores de força que representam a intensidade e direção dos ventos modelados, de acordo com a mutação adotada: cenário de referência ((a) e (b)); aleatória ((c) e (d)); máscara ((e) e (f)); e aleatória suavizada ((g) e (h)).	87
Figura 45 – Evolução temporal de um incêndio simulado a partir do autômato celular configurado com os parâmetros encontrados pelo algoritmo genético, de acordo com a mutação: (a) referência; (b) aleatória suavizada; (c) máscara; (d) e suavizada.	88
Figura 46 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o sul: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG.	91
Figura 47 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o sul: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.	92
Figura 48 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o oeste: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG	93
Figura 49 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o oeste: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.	94
Figura 50 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o leste: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG	95
Figura 51 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o leste: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.	96
Figura 52 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o noroeste: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG	97

Figura 53 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o noroeste: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.	98
Figura 54 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção sul: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	99
Figura 55 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção sul: (a) modelo de referência; e (b) modelo configurado pelo AG.	100
Figura 56 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	101
Figura 57 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG.	102
Figura 58 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção leste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	103
Figura 59 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção leste: (a) modelo de referência; e (b) modelo configurado pelo AG.	104
Figura 60 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	105
Figura 61 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG.	106
Figura 62 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com deslocamento inferior esquerdo das diferentes posições para o início do fogo	107

Figura 63 – Evolução temporal do autômato celular considerando o deslocamento inferior esquerdo das diferentes posições para o início do fogo no cenário homogêneo com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG.	108
Figura 64 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com deslocamento superior direito das diferentes posições para o início do fogo	109
Figura 65 – Evolução temporal do autômato celular considerando o deslocamento superior direito das diferentes posições para o início do fogo no cenário homogêneo com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG.	110
Figura 66 – Evolução do melhor indivíduo a cada geração do algoritmo genético: (a) evolução dos valores da matriz de preferencias ($V_{3 \times 3}$); e (b) evolução dos valores de LQ, LR e aptidão.	111
Figura 67 – Variação no <i>Fit9P</i> em função do deslocamento temporal dos reticulados na evolução do autômato celular.	113
Figura 68 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	115
Figura 69 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG	116
Figura 70 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção leste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	117
Figura 71 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção leste: (a) modelo de referência; e (b) modelo configurado pelo AG	118
Figura 72 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção sul: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	119

Figura 73 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção sul: (a) modelo de referência; e (b) modelo configurado pelo AG	120
Figura 74 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	121
Figura 75 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG	122
Figura 76 – Conjuntos de parâmetros e vetores de forças usados no cenário de três vegetações com a Veg3 dominante: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	124
Figura 77 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de três vegetações com a Veg3 dominante: (a) modelo de referência; e (b) modelo configurado pelo AG.	125
Figura 78 – Conjuntos de parâmetros e vetores de forças usados no cenário de três vegetações com a Veg2 dominante: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	126
Figura 79 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de três vegetações com a Veg2 dominante: (a) modelo de referência; e (b) modelo configurado pelo AG.	127
Figura 80 – Conjuntos de parâmetros e vetores de forças usados no cenário de três vegetações com a Veg1 dominante: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	128
Figura 81 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de três vegetações com a Veg1 dominante: (a) modelo de referência; e (b) modelo configurado pelo AG.	129
Figura 82 – Conjuntos de parâmetros e vetores de forças usados no primeiro cenário de quatro vegetações com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	130

Figura 83 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no primeiro cenário de quatro vegetações com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG	131
Figura 84 – Conjuntos de parâmetros e vetores de forças usados no segundo cenário de quatro vegetações com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	132
Figura 85 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no segundo cenário de quatro vegetações com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG)	133
Figura 86 – Região do Parque Estadual do Pau Furado representada no primeiro cenário avaliado.	135
Figura 87 – Conjuntos de parâmetros e vetores de forças usados no primeiro cenário representando região do Parque Estadual do Pau Furado: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	136
Figura 88 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no primeiro cenário representando a região do Parque Estadual do Pau Furado: (a) modelo de referência; e (b) modelo configurado pelo AG.	137
Figura 89 – Região do Parque Estadual do Pau Furado representada no segundo cenário avaliado.	137
Figura 90 – Conjuntos de parâmetros e vetores de forças usados no segundo cenário representando região do Parque Estadual do Pau Furado: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.	139
Figura 91 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no segundo cenário representando a região do Parque Estadual do Pau Furado: (a) modelo de referência; e (b) modelo configurado pelo AG.	140
Figura 92 – Mapa de Calor que analisa a tendência de fogo no modelo de propagação baseado em AC	141
Figura 93 – Configurações e a representação vetorial do vento resultante do primeiro cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.	144

Figura 94 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).	145
Figura 95 – Configurações e a representação vetorial do vento resultante do segundo cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.	146
Figura 96 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).	147
Figura 97 – Configurações e a representação vetorial do vento resultante do terceiro cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.	148
Figura 98 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).	149
Figura 99 – Configurações e a representação vetorial do vento resultante do quarto cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.	150
Figura 100 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).	151
Figura 101 – Configurações e a representação vetorial do vento resultante do quinto cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG	152
Figura 102 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).	153
Figura 103 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário homogêneo gerado a partir do modelo (TINOCO et al., 2022).	154
Figura 104 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.	155

Figura 105–Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com duas vegetações gerado a partir do modelo (TINOCO et al., 2022)	156
Figura 106–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.	156
Figura 107–Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com três vegetações gerado a partir do modelo (TINOCO et al., 2022)	157
Figura 108–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.	158
Figura 109–Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 20$ e redução de 80% da matriz de preferências.	159
Figura 110–Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 20$ e redução de 80% da matriz de preferências.	160
Figura 111–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 15$ e 20 , $LR = 1000$ e redução das matrizes de preferências para 70% (Veg1) e para 80% (Veg2)	161
Figura 112–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 7$ e 10 , $LR = 100$ e redução das matrizes de preferências para 70% (Veg1) e para 80% (Veg2)	162
Figura 113–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 13$, 16 e 20 , $LR = 1000$ redução das matrizes de preferências para 50% (Veg1) e para 80% (Veg2 e Veg3)	163

Figura 114–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 6, 9$ e 10 , $LR = 1000$ e redução das matrizes de preferências para 50% (Veg1) e para 80% (Veg2 e Veg3)	164
Figura 115–Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário homogêneo gerado a partir do modelo (TINOCO et al., 2022).	165
Figura 116–Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.	165
Figura 117–Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com duas vegetações gerado a partir do modelo (TINOCO et al., 2022)	166
Figura 118–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.	167
Figura 119–Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com três vegetações gerado a partir do modelo (TINOCO et al., 2022)	168
Figura 120–Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.	169

Lista de siglas

AG Algoritmo Genético

AC Autômato Celular

CE Computação Evolutiva

DCT tarefa de classificação de Densidade

IA Inteligência Artificial

Sumário

1	INTRODUÇÃO	24
1.1	Motivação	26
1.2	Objetivos	27
1.3	Questões de Pesquisa	28
1.4	Contribuições	28
1.5	Organização da Dissertação	28
2	FUNDAMENTAÇÃO TEÓRICA	30
2.1	Inteligência Artificial e Computação Bioinspirada	30
2.2	Autômatos Celulares	31
2.2.1	Breve Contexto Histórico	31
2.2.2	Definição de Autônomo Celular	32
2.2.3	Autômatos Celulares Unidimensionais	34
2.2.4	Autômatos Celulares Bidimensionais	35
2.2.5	Autômatos Celulares Probabilísticos	36
2.3	Algoritmos Genéticos	37
2.3.1	Representação do Indivíduo e Geração da População Inicial	39
2.3.2	Função de Aptidão	40
2.3.3	Métodos de Seleção	41
2.3.4	Métodos de Recombinação	43
2.3.5	Métodos de Mutação	45
2.3.6	Reinserção	47
2.3.7	Critério de Parada	47
2.3.8	Parâmetros Genéticos	47
3	TRABALHOS CORRELATOS	49
3.1	Modelos de Propagação de Incêndios	49
3.1.1	Modelo Louzada e Ferreira Junior (2008)	52

3.1.2	Modelo Lima e Lima (2014)	53
3.1.3	Modelo Tinoco et al. (2022)	54
3.2	Computação Evolutiva na Configuração de Autômatos Celulares	55
4	MODELO DE PROPAGAÇÃO DE INCÊNDIOS	58
4.1	Modelo de Propagação de Incêndios em Cenários Homogêneos	58
4.2	Representação do Vento	60
4.3	Adaptação do Modelo para Cenários Heterogêneos	63
5	ABORDAGEM EVOLUTIVA PROPOSTA	67
5.1	Representação de Indivíduo	67
5.2	Função de Avaliação	70
5.2.1	<i>Fitness</i> Homogêneo	70
5.2.2	<i>Fitness</i> Heterogêneo	71
5.3	Configuração do AG	72
6	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	73
6.1	Uso de Bases de Dados	73
6.2	Método para a Avaliação	75
6.3	Experimentos Preliminares	76
6.3.1	Definição da Função de Aptidão	77
6.3.2	Seleção dos Operadores Genéticos	82
6.4	Análise de Desempenho em Cenários Homogêneos	89
6.4.1	Simulações com um Único Ponto Inicial de Fogo	90
6.4.2	Simulações com Vários Pontos Iniciais de Fogo	98
6.4.3	Impacto do Deslocamento Espacial dos Dados	107
6.4.4	Análise da Evolução dos Parâmetros do Modelo	110
6.4.5	Impacto do Deslocamento Temporal no Cálculo da Aptidão	113
6.5	Análise de Desempenho em Cenários Heterogêneos	113
6.5.1	Simulações dos Cenários com Duas Vegetações	114
6.5.2	Simulações dos Cenários com Três Vegetações	122
6.5.3	Simulações dos Cenários com Quatro Vegetações	129
6.5.4	Cenários baseados nas Vegetações do Parque Estadual Pau Furado . . .	134
6.6	Mapa de Calor: análise das áreas com maior probabilidade de combustão	140
6.7	Análise da Sensitividade	142
6.7.1	Análise de Sensitividade considerando dados de referência gerados pelo modelo Lima e Lima (2014)	143
6.7.2	Análise de Sensitividade considerando os dados de referência gerados pelo modelo Tinoco e Freitas et al. (2022)	153

7	CONCLUSÕES	170
7.1	Trabalhos Futuros	171
7.2	Produção Bibliográfica Resultante da Pesquisa	172
	REFERÊNCIAS	173

Introdução

Em geral, incêndios rompem com o equilíbrio vigente e o desenvolvimento tanto vegetal quanto animal. Considerando a importância dos ambientes naturais, como aqueles de fitofisionomias florestais, seja ecológica, econômica e social, a questão dos incêndios assume contornos ainda mais graves com repercussões cada vez mais difíceis de serem mitigadas (MAIA; OLIVEIRA; SILVA, 2019).

No Brasil, o aumento das queimadas florestais é notório nos últimos anos, principalmente no Pantanal, na Amazônia e no Cerrado. Estes são biomas que apresentam nos períodos de estiagem uma séria susceptibilidade às queimadas, agravadas pela ausência de uma fiscalização ambiental séria e de trabalhos de conscientização daqueles que ocupam estas áreas. Em alguns biomas, como no Cerrado e no Pantanal, existem os chamados fogos naturais. Esses incêndios são necessários para o desenvolvimento de algumas sementes (COUTINHO, 2006). Quando a queimada não é natural, esse desenvolvimento é prejudicado, uma vez que os incêndios provocados pelo homem atrapalham os ciclos de fogo natural dos chamados pirobiomas.

Esse cenário é diretamente associado às mudanças climáticas, como períodos de estiagem maiores e aumento da temperatura, afetando direta ou indiretamente a vida de milhões de pessoas. Ademais, os danos à fauna e a flora são, por vezes, irreversíveis e podem causar a extinção de diversas espécies, devido à redução dos habitats. Além disso, podem surgir outros problemas como a grilagem de terra e o isolamento de áreas verdes (MOREIRA; FILHO; GUARALDO, 2021).

Entre os esforços ligados a prevenção e combate dos incêndios estão aqueles relativos à ampliação do entendimento de como esses fenômenos, uma vez iniciados, propagam sobre diferentes paisagens. Esta é, de fato, uma questão complexa uma vez que entre as dificuldades no combate a incêndios estão justamente a falta de acesso às áreas atingidas e o entendimento dos elementos como relevo, vegetação, solo e ventos na definição das direções com maior potencial de serem tomadas por aquele episódio de queima (MOREIRA; FILHO; GUARALDO, 2021). Sendo assim, as investigações pautadas nestas questões precisam se valer das mais modernas técnicas de modelagem e simulação para construção

de cenários que permitam uma melhor compreensão desses ambientes susceptíveis aos incêndios.

Autômatos celulares (ACs) são sistemas dinâmicos, discretos no tempo, no espaço e em suas variáveis. O uso de ACs tem sido estudado em diversas áreas como na criptografia (LIMA et al., 2012) e no escalonamento de tarefas (CARNEIRO; OLIVEIRA, 2011). Os ACs também têm sido utilizados como uma ferramenta de modelagem de fenômenos naturais, sendo que a propagação de incêndios é uma das principais investigações de modelos de simulação baseados em ACs. Para ajudar na prevenção e na redução de danos, é necessário compreender esse fenômeno. Nesse contexto, autômatos celulares vêm sendo estudados como uma ferramenta de modelagem de sistemas complexos. Com uma implementação relativamente simples a propagação de incêndios pode ser simulada com resultados satisfatórios, desde que os parâmetros envolvidos em tais modelos sejam ajustados adequadamente (CHOPARD; DROZ, 1998).

O modelo de propagação de incêndios baseado em autômatos celulares pode ser aplicado em grandes áreas, sendo capaz de simular a propagação do fogo em uma região de interesse, como uma floresta, uma área rural ou mesmo uma cidade. Essa simulação permite estimar a trajetória do incêndio e a sua velocidade de propagação em diferentes pontos da área, levando em consideração fatores como a topografia do terreno, a direção e velocidade do vento, a umidade do solo e a densidade da vegetação. A partir dessas informações, é possível identificar áreas mais propensas à propagação do fogo e direcionar ações preventivas, como a limpeza da vegetação, a instalação de barreiras físicas ou a criação de pontos de acesso para as equipes de combate a incêndios. Também é possível identificar áreas de risco, como locais com maior concentração de edifícios ou infraestruturas críticas, permitindo ações mais direcionadas para a proteção desses pontos.

Várias pesquisas têm investigado abordagens que adotam computação evolutiva para configurar de forma automática e eficiente os parâmetros de um sistema (MONTEIRO; GANDINI; SCHIMIT, 2020) (FRAGA; OLIVEIRA; MARTINS, 2021). Nesse sentido, algoritmos genéticos (AG) (HOLLAND, 1968) são meta-heurísticas que se baseiam na teoria da evolução de Darwin (1956), sendo propícias para a resolução de problemas de busca e otimização. Esse tipo de algoritmo bioinspirado trabalha com a evolução simultânea de várias soluções, o que garante uma vantagem significativa em relação às técnicas sequenciais. Além disso, a partir da definição de forma de representação do problema e avaliação como possível solução, os AGs são robustos e flexíveis e podem ser aplicados na solução de problemas complexos.

Neste trabalho, foi desenvolvida uma abordagem evolutiva baseada em algoritmos genéticos para a configuração automática de modelos de incêndios baseados em autômatos celulares. Para isso, o modelo (FERREIRA et al., 2022b), baseado em (LOUZADA; JUNIOR, 2008) e (LIMA; LIMA, 2014), foi estudado e aprimorado para que pudesse ser aplicado em vegetações homogêneas e heterogêneas. O ajuste automático desse modelo

foi feito utilizando algoritmos genéticos. O ajuste consiste na busca de dez parâmetros, para cada tipo de vegetação, que representam direção e intensidade do vento, tempo de queima e tempo de recuperação da matéria orgânica. O melhor conjunto de valores é o que é capaz de gerar uma simulação que se assemelha a simulações utilizadas como referência. Para validar o comportamento da ferramenta evolutiva, foram realizados experimentos nos mais diversos cenários, incluindo vegetações homogêneas e heterogêneas. Para avaliar a sensibilidade do ajuste evolutivo, os dados utilizados como base de referência foram gerados por dois outros modelos de propagação de incêndios: um mais simples (LIMA; LIMA, 2014) e um mais complexo (TINOCO et al., 2022).

1.1 Motivação

Os incêndios florestais são notadamente prejudiciais ao ecossistema, resultando em impactos ambientais, econômicos e sociais. No Brasil, foi observado um aumento considerável das queimadas florestais nos últimos anos, principalmente nos biomas conhecidos como Amazônia, Pantanal e Cerrado. Esse cenário está diretamente associado às mudanças climáticas que incluem longos períodos de seca e aumento da temperatura média, afetando direta ou indiretamente a vida de milhões de pessoas. Além disso, os danos à fauna e à flora são, na maioria das vezes, irreversíveis e podem causar a extinção de diversas espécies, devido à redução dos habitats.

Para prevenir e combater os incêndios, é necessário compreender como o fogo se propaga em diferentes ambientes. Também é necessária a compreensão de como fatores relacionados a vegetação, umidade, topografia, clima e direção e intensidade de ventos têm impacto nessa propagação. Além disso, é importante a escolha de uma abordagem de modelagem adequada, capaz de reproduzir o fenômeno satisfatoriamente, ao mesmo tempo que permita um ajuste dos parâmetros do modelo, através de implementações relativamente simples.

Diversos modelos de propagação de incêndios baseados em autômatos celulares foram propostos na literatura. A maioria desses modelos utiliza regras de transição probabilísticas aplicadas em reticulados bidimensionais de células, que representam os ambientes onde o incêndio é propagado. Uma simulação de incêndio florestal deve levar em consideração diferentes características do ambiente o que leva a um número considerável de parâmetros no modelo resultante. Assim, esses modelos são fortemente dependentes desses parâmetros, que influenciam o comportamento dinâmico observado. Além disso, determinar os valores de parâmetros de um modelo de propagação de incêndio é uma tarefa crítica. Além disso, mesmo que um modelo tenha sido previamente ajustado para uma determinada região, sua aplicabilidade em outras áreas pode depender de um ajuste adequado dos parâmetros que levem em consideração as diferenças entre os ambientes.

O ajuste automático dos parâmetros de um modelo pode ser definido como encontrar

um conjunto de valores que na simulação produzem um resultado o mais parecido possível com o comportamento real do fenômeno, nesse caso, a propagação de incêndios florestais. Nesse sentido, pode-se identificar esses parâmetros utilizando problemas inversos (VELHO, 2001), isto é, determinar as causas a partir da observação dos seus efeitos. Isso pode ser feito utilizando algoritmos genéticos (TOMINAGA; KOGA; OKAMOTO, 2000) e observando as características de um incêndio é possível descobrir quais os valores dos parâmetros produziram efeitos semelhantes aos desejados.

Algoritmos genéticos são robustos, podem ser aplicados a uma grande variedade de problemas, possuem fácil implementação e são flexíveis ao problema a ser resolvido. Além disso, os algoritmos genéticos não utilizam apenas informação local, então, não ficam presos a ótimos locais como alguns métodos de busca, o que faz com que a técnica seja adequada para problemas de comportamento complexo, como é o caso de simulação de fenômenos naturais (LINDEN, 2008).

1.2 Objetivos

O principal objetivo desta pesquisa consiste no desenvolvimento de uma abordagem para a simulação de incêndios florestais, que integra um modelo de propagação do fogo baseado em autômato celular e um algoritmo genético capaz de ajustar automaticamente os parâmetros desse modelo, de acordo com os dados históricos de incêndios.

Esta pesquisa possui como objetivos específicos:

- ❑ Desenvolver um modelo de propagação de incêndio baseado em autômato celular bidimensional, que combine as características de dois modelos estudados na literatura (LOUZADA; JUNIOR, 2008) (LIMA; LIMA, 2014). Esse modelo será usado como referencial para a avaliação do algoritmos de ajuste de parâmetros.
- ❑ Implementar um algoritmo genético capaz de ajustar automaticamente os parâmetros do modelo de propagação de incêndios baseado em AC a partir de dados históricos.
- ❑ Avaliar a eficiência do método em ajustar o modelo de AC para reproduzir o comportamento de diferentes cenários de incêndios, considerando uma única vegetação.
- ❑ Adaptar o método desenvolvido para lidar com cenários com tipos distintos de vegetação, possibilitando sua utilização em ambientes mais complexos e realísticos, como os observados nas regiões do Cerrado.
- ❑ Validar a sensibilidade do método de ajuste, utilizando dados gerados por outros modelos de propagação de incêndios baseados em autômatos celulares.
- ❑ Simular computacionalmente tipos de vegetação referentes à área do Parque Estadual do Pau Furado, localizado em Uberlândia, Minas Gerais.

1.3 Questões de Pesquisa

Neste trabalho, busca-se responder duas questões de pesquisa principais:

- É possível aplicar um algoritmo genético para efetuar ajustes automáticos dos parâmetros de um modelo de propagação de incêndios que utiliza autômatos celulares?
- Um modelo de propagação de incêndio baseado em autômato celular é capaz de representar efetivamente o comportamento observado em dados históricos de incêndios florestais?

A investigação principal deste trabalho, portanto, é verificar se a partir da utilização de autômatos celulares bidimensionais é possível criar um modelo eficiente de simulação de propagação de incêndios florestais. Ademais, investiga-se se os parâmetros do modelo como direção do vento, tempo de queima, tempo de recuperação e tipo de vegetação podem ser ajustados automaticamente mediante a utilização de algoritmos genéticos. Por fim, verifica-se a possibilidade de utilização do modelo resultante na simulação eficiente de incêndios florestais em regiões com um ou mais tipos de vegetação.

1.4 Contribuições

Esse trabalho propõe a criação de um modelo de simulação de propagação de incêndios que utiliza autômatos celulares bidimensionais para reproduzir e simular dados de ambientes com diferentes tipos de vegetação e com isso contribuir para que as entidades responsáveis pela preservação de florestas, em especial o bioma do Cerrado, sejam auxiliadas no processo de prevenção e redução de danos de incêndios provocados. Além disso, ao desenvolver um algoritmo genético capaz de adaptar o modelo de automato celular a dados reais dos ambientes monitorados, o modelo de propagação de incêndios poderá ser adaptado a diferentes biomas. Por fim, a análise da robustez do modelo à variações nos dados históricos, que foi realizada a partir da validação do algoritmo na reprodução de dados gerados por outros modelos e da análise de sensibilidade do modelo a deslocamentos temporais nos dados.

1.5 Organização da Dissertação

O restante do documento está organizado da seguinte maneira:

No Capítulo 2 são apresentados os fundamentos e conceitos relacionados as técnicas de computação bio-inspirada investigadas neste trabalho, a saber: autômatos celulares e algoritmos genéticos. Esses conceitos são fundamentais para o entendimento modelo proposto.

No Capítulo 3 são apresentados alguns trabalhos correlatos a abordagem proposta.

No Capítulo 4 é descrito, de forma detalhada, o modelo de propagação de incêndios baseado em autômatos celulares desenvolvido neste trabalho.

No Capítulo 5 é descrita a estratégia evolutiva e as configurações utilizadas para atingir o objetivo proposto.

No Capítulo 6 são apresentados os resultados alcançados nos experimentos efetuados, bem como suas respectivas análises.

E, por fim, no Capítulo 7 serão apresentadas as considerações adicionais, conclusões e perspectivas futuras.

Fundamentação Teórica

Esta seção apresenta alguns conceitos necessários à compreensão das técnicas estudadas e utilizadas nesta pesquisa. A Seção 2.1 introduz os conceitos de inteligência artificial e computação evolutiva. A Seção 2.2 traz uma descrição geral sobre os conceitos de autômatos celulares e modelos de propagação de incêndios que utilizam essa técnica. Finalmente, a Seção 2.3 apresenta conceitos relacionados a algoritmos genéticos.

2.1 Inteligência Artificial e Computação Bioinspirada

A Inteligência Artificial (IA) é uma área da computação que investiga técnicas que buscam reproduzir aspectos associados à "inteligência", tais como: capacidade cognitiva, funcionamento do cérebro, comportamentos coletivos de alguns animais (inteligência coletiva), entre outros. Ela engloba uma variedade de subáreas, como aprendizagem de máquina, processamento de linguagem natural, robótica e percepção, computação evolutiva, dentre outras (NORVIG; RUSSELL, 2004).

A computação bioinspirada é uma área de pesquisa da computação, inspirada em processos biológicos ou naturais, empregada na resolução de problemas complexos através do uso de sistemas inteligentes. A origem da computação bioinspirada está relacionada à necessidade de modelagem de sistemas e processos naturais para compreender os padrões encontrados na natureza. Posteriormente, a computação bioinspirada foi aplicada na resolução de problemas e no desenvolvimento de novas tecnologias (NORVIG; RUSSELL, 2004).

Dentre as principais técnicas da computação bioinspirada, destacam-se a computação evolutiva, autômatos celulares, e a inteligência de enxames.

A Computação Evolutiva (CE) propõe uma abordagem inspirada na teoria evolutiva de Charles Darwin para a resolução de problemas (LINDEN, 2008). Esta área destaca-se devido a sua capacidade para resolução de problemas complexos ou que levariam um tempo elevado através de meios convencionais, como os problemas NP-Completo.

A CE teve suas origens a partir da década de 50, quando cientistas inspirados por pro-

cessos naturais buscaram por modelos de sistemas genéricos capazes de propor soluções viáveis computacionalmente para problemas de difícil resolução (RUSSELL et al., 2010). Como consequência, foram propostas as mais variadas técnicas que buscam simular os processos naturais de sobrevivência e reprodução das espécies. A CE pode ser dividida nas técnicas: programação evolutiva, estratégias evolutivas, algoritmos genéticos e programação genética (GOLDBERG; HOLLAND, 1988).

A abordagem proposta neste trabalho utiliza autômatos celulares e algoritmos genéticos. Portanto, essas duas técnicas bioinspiradas serão descritas com mais detalhes a seguir.

2.2 Autômatos Celulares

Um Autômato Celular (AC) típico pode ser definido como um sistema dinâmico e discreto no tempo, espaço e estado. O espaço do autômato celular é delimitado por uma malha de células (reticulado) identificadas por estados que evoluem, a cada passo de tempo, de acordo com suas iterações locais e com a regra de transição adotada (MITCHELL et al., 2005). Dentre as principais vantagens do uso de autômatos celulares é o fato de serem modelos discretos, fáceis de implementar e altamente paralelizáveis (TOFFOLI; MARGOLUS, 1987). Os autômatos celulares têm capacidade de, a partir da aplicação de regras simples, gerar padrões complexos que podem ser observados na natureza (computação emergente). Assim, os ACs tornaram-se objetos de estudos de diversos pesquisadores nos últimos anos.

2.2.1 Breve Contexto Histórico

Ao estudar modelos de crescimento artificiais e autorreprodução, Von Neumann e Ulam proueram os conceitos de autômatos celulares, no início dos anos 50 (NEUMANN; BURKS et al., 1966). Posteriormente, na década de 70, Conway investigou a possibilidade da criação de um autômato celular simples com computabilidade universal (CONWAY et al., 1970). O resultado dessa investigação foi um dos mais conhecidos modelos de ACs: “O Jogo da Vida” que mostrou a capacidade de um AC reproduzir padrões complexos, resultando em estruturas semelhantes a organismos artificiais, simulando o processo de nascimento, sobrevivência e morte. Por meio de regras simples, as células de estado 1 (chamadas de células vivas) e as células de estado 0 (chamadas de células mortas) nascem, morrem ou sobrevivem de acordo com a sua vizinhança.

Na década de 80, Wolfram estudou o comportamento dinâmico dos autômatos celulares e demonstrou que mesmo os modelos mais simples de ACs eram capazes de exibir padrões com comportamento emergente e, baseando-se no padrão espaço-temporal, desenvolveu uma teoria de classificação de autômatos celulares (WOLFRAM, 1982). Os

trabalhos de Wolfram tornaram-se referência para estudos posteriores nessa área.

ACs têm sido aplicados em diferentes áreas da computação, tais como: criptografia (WOLFRAM, 1985) (LIMA et al., 2012), escalonamento de tarefas (SWIECICKA; SEREDYNSKI; ZOMAYA, 2006), (CARNEIRO; OLIVEIRA, 2011), robótica autônoma (IOANNIDIS; SIRAKOULIS; ANDREADIS, 2011), (LIMA; TINOCO; OLIVEIRA, 2016), (OLIVEIRA et al., 2019), dentre outras. Uma das principais aplicações de ACs é na modelagem de fenômenos naturais que produzem um comportamento complexo a partir de interações locais, tais como: a propagação de epidemias (WHITE; REY; SÁNCHEZ, 2007), (MONTEIRO; GANDINI; SCHIMIT, 2020), tráfego urbano (TONGUZ; VIRIYA-SITAVAT; BAI, 2009), conflito de veículos (LI; LIU; CEN, 2021), dinâmica populacional de insetos e vetores de doenças (SLIMI et al., 2009), (FRAGA; OLIVEIRA; MARTINS, 2021) e a propagação de incêndios (CHOPARD; DROZ, 1998) (TINOCO et al., 2022), que também é investigada no presente trabalho.

2.2.2 Definição de Autônomo Celular

Formalmente, pode-se definir um autômato celular A como:

$$A = (\Sigma, \phi, f, D) \quad (1)$$

em que Σ representa um conjunto finito de estados que podem ser assumidos pelas células, ϕ representa a vizinhança de uma célula, f representa as regras que definem como os estados da célula mudarão ao longo do tempo t e D denota a dimensão do reticulado (OLIVEIRA; OLIVEIRA; OMAR, 2001).

A forma como as células estão dispostas pelo reticulado definem as dimensões do seu espaço celular. A Figura 1 ilustra as três formas possíveis de reticulado para um AC, que correspondem, respectivamente, aos espaços unidimensional, bidimensional e tridimensional. Todas as células desse espaço devem possuir o mesmo tamanho, isto é, o reticulado deve possuir uma geometria regular (LIMA et al., 2012).

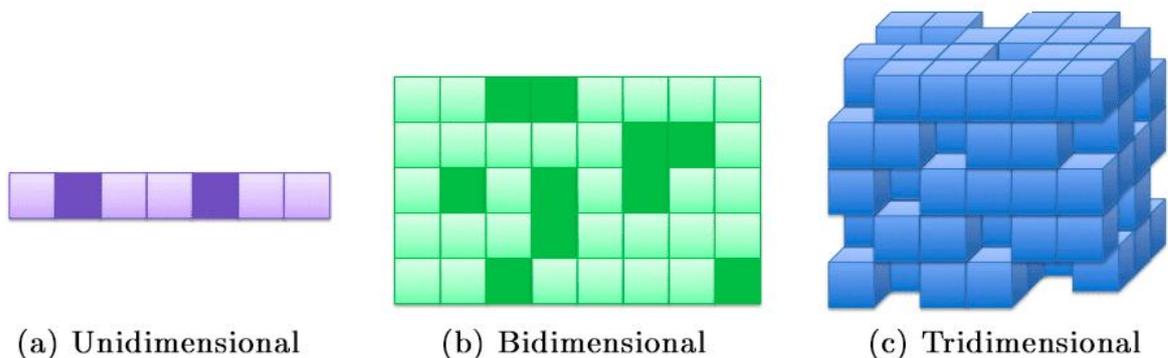


Figura 1 – Principais dimensões para o espaço celular de um autômato celular.

O formato das células do espaço celular também pode variar entre os modelos. Entretanto, todas as células de um reticulado possuem a mesma forma geométrica. A Figura 2 apresenta os formatos mais comuns: o quadrangular (Figura 2(a)), o hexagonal (Figura 2(b)) e triangular (Figura 2(c)). Durante a evolução de um autômato celular, o estado

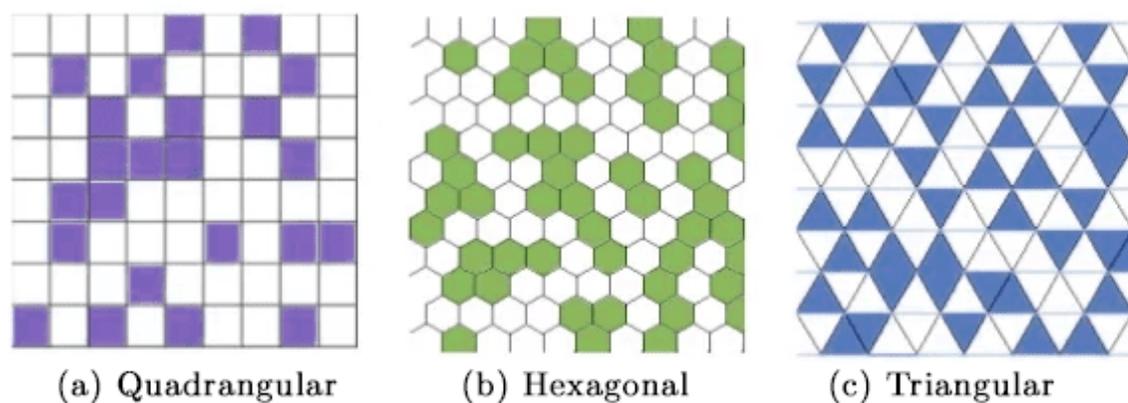


Figura 2 – Formatos possíveis para as células de um autômato celular.

de uma célula no instante $t+1$ depende diretamente do seu estado e dos estados das células em sua vizinhança no instante t (MITCHELL et al., 1996). O estado de cada célula do reticulado é determinado por meio das regras de transição do autômato celular. A fim de delimitar o reticulado, os autômatos celulares tem tamanho finito e definem-se as regiões de borda (LIMA et al., 2012). A forma como é definida a vizinhança das células na região de borda influencia na evolução do autômato celular. A Figura 3 apresenta as estratégias mais comuns usadas na definição da vizinhança das células de borda. As células brancas não fazem parte do reticulado, mas são mostradas apenas para representar a vizinhança empregada em cada estratégia. Quando as extremidades do reticulado estão conectadas, tem-se as chamadas bordas cíclicas ou bordas periódicas (Figura 3(a)), em que célula mais à direita do reticulado é considerada vizinha da célula mais à esquerda. Nas bordas reflexivas (Figura 3 (b)), as células das bordas são replicadas para complementar a vizinhança. Finalmente, nas bordas fixas (Figura 3 (c)), um mesmo estado é utilizado em todas as células que complementam a vizinhança das bordas.

As regras de transição são aplicadas em todo o espaço celular em intervalos de tempo discretos. Quando regras de transição determinam um único estado de saída para cada vizinhança possível, elas são denominadas regras deterministas. Por outro lado, há modelos que utilizam regras de transição não determinísticas nos quais há mais de um estado possível para determinada vizinhança. Quando a saída de uma regra de transição não determinística é determinada por um processo estocástico, elas são chamadas de regras probabilísticas. Os autômatos celulares probabilísticos são comumente utilizados na modelagem de fenômenos complexos e naturais, como a propagação de incêndio investigada

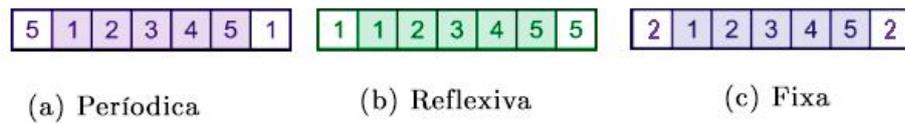


Figura 3 – Estratégias de definição da vizinhança das células de borda em um autômato celular: periódicas (célula mais à direita é vizinha da célula mais à esquerda); reflexivas (células da borda são replicadas); e fixas (um mesmo estado é utilizado para complementar a vizinhança das bordas).

nesta pesquisa.

2.2.3 Autômatos Celulares Unidimensionais

Os ACs unidimensionais representam os modelos mais simples desses sistemas. Computacionalmente, o reticulado unidimensional pode ser representado através de um vetor. Nos ACs unidimensionais, a vizinhança de cada célula é definida a partir de um raio r . O tamanho da vizinhança da célula central é dado por $n = (2r + 1)$. Quanto maior é o raio de um AC unidimensional, maior é a quantidade de regras distintas que podem ser geradas.

Os autômatos celulares elementares, que são unidimensionais, binários e possuem vizinhança de raio 1, resultando em regras definidas por 8 bits. Existem 256 regras elementares possíveis (OLIVEIRA, 2003). A Figura 4 ilustra um exemplo de AC elementar. A vizinhança de raio 1 é formada pela própria célula, a célula à direita, e a célula à esquerda. O AC é binário, ou seja, cada célula tem apenas dois estados possíveis (0 ou 1). A regra de transição é mostrada na Figura 4(a) que indica o estado da célula central (bit de saída) para todas as vizinhanças de raio 1 ($2^{2r+1} = 2^3 = 8$ vizinhanças possíveis). Essa regra é conhecida com regra 120, pois é o número decimal obtido a partir do binário formado pelos bits de saída da regra (01111000). Nesse exemplo, foi adotada a borda periódica, logo, a célula mais à esquerda é vizinha da mais à direita e vice-versa. A Figura 4 demonstra a evolução de um AC unidimensional nos primeiros três intervalos de tempo. A configuração inicial do reticulado é mostrada em $t = 0$. A cada iteração, cada célula atualiza seu estado, a partir do seu valor atual e de suas vizinhas. Nesse reticulado inicial também é destacada a vizinhança da quarta célula: 111. Portanto, em $t = 1$, de acordo com a regra de transição, o estado da quarta célula é atualizado para 0. A regra deve ser aplicada para todo o reticulado, resultando na configuração mostrada em $t = 1$. No próximo instante de tempo ($t = 2$), após todo o reticulado atualizado o estado da quarta célula é atualizado para 1.

000	001	010	011	100	101	110	111
0	1	1	1	1	0	0	0

(a) Regra de Transição do AC

t = 0	1	0	1	1	1	0
t = 1	1	0	1	0	0	0
t = 2	1	0	1	1	0	1

(b) Evolução do AC por 2 passos de tempo

Figura 4 – Evolução temporal de um AC unidimensional.

2.2.4 Autômatos Celulares Bidimensionais

Nos autômatos celulares bidimensionais, normalmente, são utilizadas duas vizinhanças: von Neumann e Moore (OLIVEIRA, 2003). A vizinhança de Von Neumann considera as células cardinais associadas a célula central. A Figura 5(a) ilustra essa vizinhança para o raio 1, que é formada pela célula central e por quatro outras que estão imediatamente à esquerda, à direita, acima e abaixo. Já na vizinhança de Moore, todas as células vizinhas à célula central são consideradas, ou seja, considerando o raio 1, essa vizinhança é formada pela célula central e as outras 9 que a rodeiam, conforme ilustrado na Figura 5(b).

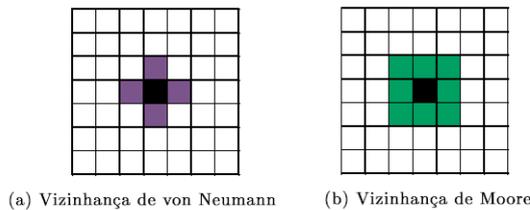


Figura 5 – Vizinhanças de um AC bidimensional.

As vizinhanças de von Neumann e Moore podem ser generalizadas para os autômatos celulares definidos no espaço tridimensional, como mostra a Figura 6. Os estudos com ACs tridimensionais são mais raros, uma vez que se trata de uma implementação mais complexa. Alguns exemplos são a aplicação na criptografia (LIMA et al., 2012) e na simulação de explosão de partículas (WANG; XU; XU, 2012).

O “Jogo da Vida”, proposto por Conway, é um dos modelos de AC bidimensionais mais conhecidos (CONWAY et al., 1970). Nele, há uma simulação da sobrevivência de organismos. Na implementação do autômato celular é adotada uma vizinhança de Moore e cada célula pode assumir por dois estados: vivo (1) e morto (0). As regras de transição são as seguintes:

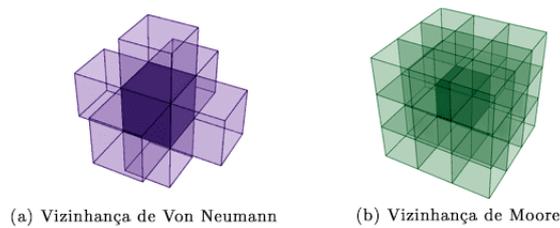


Figura 6 – Vizinhanças em um AC tridimensional

- Uma célula no estado 1 permanece em 1, se duas ou três vizinhas também estiverem em 1. Caso contrário, torna-se 0.
- Uma célula 0 torna-se 1 se três vizinhas estão em 1. Caso contrário, permanece em 0.

Dessa forma, um organismo precisa de outros organismos vivos para sobreviver e se multiplicar, mas o excesso de organismos vivos causa superpopulação, levando-os a morte. A ausência de organismos vivos traz a escassez, também levando os organismos a morte (CONWAY et al., 1970).

Ao serem aplicadas, as regras de transição, podem gerar distintos padrões. Um dos padrões são os chamados *gliders*, que apresentam ciclos fechados que se deslocam na grade celular. Com a evolução temporal, estruturas de ciclo fechado tendem a se repetir (OLIVEIRA, 2003). A Figura 7 mostra a evolução de um *glider* em cinco passos de tempo. Pode-se perceber que o padrão mostrado em $t = 1$ repete-se em $t = 5$, mas com a posição deslocada na direção da diagonal inferior direita da grade.

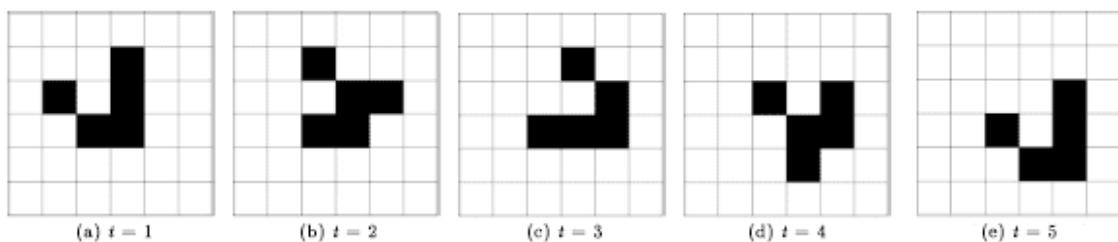


Figura 7 – Evolução temporal do AC “O Jogo da Vida”.

2.2.5 Autômatos Celulares Probabilísticos

Diferentemente de um autômato celular determinístico, no autômato celular probabilístico a atualização de cada célula não é determinada apenas pelos estados das células vizinhas, mas também por uma distribuição de probabilidade que especifica a probabilidade de cada possível estado da célula após a atualização. Essa distribuição de pro-

babilidade pode ser influenciada por fatores aleatórios, como ruído aditivo ou interações estocásticas com o ambiente, ou por informações prévias sobre o sistema, como histórico de estados anteriores ou parâmetros físicos. O uso de probabilidades introduz uma incerteza na evolução do autômato celular, o que pode resultar em comportamentos complexos e não lineares que não podem ser previstos apenas a partir das regras locais de atualização. (GRINSTEIN; JAYAPRAKASH; HE, 1985) Autômatos celulares probabilísticos têm sido amplamente utilizados em várias áreas da ciência, como física, biologia, ciência da computação e engenharia, para modelar sistemas complexos, como reações químicas, processos de difusão, dinâmicas de populações e redes neurais (LOZANO, 2017).

O modelo de Ising probabilístico é um exemplo de AC probabilístico que é usado para descrever a dinâmica de sistemas magnéticos em física. O modelo consiste em uma grade de células que representam um sistema magnético, onde cada célula pode ter um estado de spin para cima ou para baixo. A evolução do sistema é determinada por uma função de energia, que depende dos estados de spin das células vizinhas. No entanto, ao contrário do modelo de Ising determinístico, onde cada célula é atualizada com base nas regras determinísticas, o modelo de Ising probabilístico leva em conta a aleatoriedade na evolução do sistema (GRINSTEIN; JAYAPRAKASH; HE, 1985). A probabilidade de cada célula assumir um estado específico é determinada por uma distribuição de probabilidade de Boltzmann (FREYHULT; MOULTON; CLOTE, 2007), que depende da função de energia do sistema e da temperatura. À medida que a temperatura diminui, a distribuição de probabilidade se torna mais concentrada em torno dos estados de menor energia, o que leva a uma ordem no sistema, como a formação de domínios magnéticos. Por outro lado, quando a temperatura é alta, a distribuição de probabilidade se torna mais uniforme, o que leva a um comportamento mais aleatório e desordenado no sistema. Esse exemplo ilustra como o uso de probabilidades pode levar a comportamentos complexos e dependentes do tempo em um autômato celular.

2.3 Algoritmos Genéticos

Algoritmo Genético (AG) consiste em uma técnica de busca e otimização baseada nos mecanismos da seleção natural e da genética (GOLDBERG; HOLLAND, 1988). Na teoria da Evolução, proposta por Darwin (1956), os indivíduos com melhor adaptação têm mais chance de sobrevivência, apresentando, assim, uma vantagem evolutiva sobre os outros. O trabalho de Holland (1968) introduziu os conceitos evolutivos hoje conhecidos como Algoritmos Genéticos. Mais tarde, esses conceitos foram aprimorados por Goldberg (GOLDBERG; HOLLAND, 1988).

Os algoritmos genéticos baseiam-se num processo de aprendizagem coletiva, em que dentro de uma população de indivíduos, cada um deles representa um ponto no espaço de soluções para determinado problema (RUSSELL et al., 2010). A principal vantagem da

implementação de algoritmos genéticos é a generalização da técnica: a aplicação de um AG é feita a partir de uma descrição matemática da solução desejada, o que lhe proporciona flexibilidade e robustez, tornando possível sua aplicação no tratamento de diferentes tipos de problemas complexos.

AGs têm sido empregados em diversos problemas da literatura, tais como o problema da mochila (LAFETÁ; OLIVEIRA, 2020) e o problema do caixeiro viajante (POTVIN, 1996), entre outros problemas conceituais. Com diversas aplicações mais práticas, os algoritmos genéticos já foram utilizados na medicina (MAULIK, 2009), na música (MATIĆ, 2016), na otimização de funções matemáticas (CHEN; KOU; MA, 2015), no processamento e detecção de imagens (AYALA-RAMIREZ et al., 2006), na bioinformática (MANNING; SLEATOR; WALSH, 2013), no escalonamento de tarefas (MORAIS; OLIVEIRA; CARVALHO, 2019), no roteamento de pacotes (LAFETÁ et al., 2018) e na mineração de dados (OLIVEIRA; MARTINS; TAKIGUTI, 2008). Além disso, os algoritmos genéticos se mostraram eficientes no ajuste de parâmetros de controle por matriz dinâmica (DMC) (ALMEIDA; SALLES; FILHO, 2007), controladores PID (JAYACHITRA; VINODHA, 2014), redes neurais (LEUNG et al., 2003), (TSAI; CHOU; LIU, 2006). Mais relacionado ao objetivo desse trabalho, os AGs já foram empregados no ajuste de parâmetros de autômatos celulares (FRAGA; OLIVEIRA; MARTINS, 2021), (TINOCO; VIZZARI; OLIVEIRA, 2020).

Por meio de uma busca não-determinista, os AGs permitem uma aproximação das soluções aos resultados ideais conhecidos como pontos de ótimos (MITCHELL, 1998). O indivíduo é a parte que apresenta o código genético, através de seus cromossomos. Os indivíduos representam soluções potenciais para o problema em questão. Sua representação varia de acordo com o problema. Indivíduos podem ser representados por vetores binários, sendo 1 a presença de uma característica e 0 a sua ausência (LINDEN, 2008).

Nos AGs, populações de indivíduos são criadas de forma aleatória e submetidas aos operadores genéticos de seleção, reprodução e mutação (LINDEN, 2008). Estes operadores utilizam uma quantificação da qualidade de cada indivíduo, obtida durante o processo de avaliação ou *fitness*, classificando-o de acordo com sua aptidão para solucionar o problema investigado. A partir dos indivíduos iniciais, a população passa por um processo de adaptação que emula o processo de evolução natural até atingir a solução ótima ou próxima dela (MITCHELL, 1998). O cálculo do *fitness* é uma etapa crucial para todo o funcionamento de um algoritmo genético, embora não haja um método geral para a sua definição, uma vez que a função de aptidão depende exclusivamente do problema (GOLDBERG; HOLLAND, 1988).

Os AGs possuem estruturas denominadas operadores genéticos que simulam fatores naturais que ocorrem durante o processo da evolução. Computacionalmente, estes processos são métodos que, aplicados na população, aprimoram e diversificam o seu material genético, garantindo que os genes dos indivíduos mais adaptados perpetuem ao longo das

gerações, direcionando a busca para alcançar uma solução ótima (GOLDBERG; HOLLAND, 1988).

O ciclo de um AG pode ser definido da seguinte maneira. Inicialmente uma população de indivíduos, gerada aleatoriamente, é avaliada de acordo com seu material genético. Aqueles indivíduos que possuem uma estrutura cromossômica favorável à resolução do problema proposto recebem melhores notas e conseqüentemente são os mais aptos a perpetuarem os seus genes através do processo de reprodução. Os indivíduos então se recombinam, gerando uma nova população que pode ou não sofrer mutações. Então, todo o processo se repete a partir dessa nova população. Esse ciclo tem como objetivo aprimorar os indivíduos, combinando os que possuem boas características para gerar indivíduos ainda melhores. Novas gerações continuam a ocorrer, até que algum dos critérios de parada seja satisfeito, por exemplo, atingir um número máximo de gerações ou encontrar uma solução satisfatória (GOLDBERG; HOLLAND, 1988). A Figura 8 mostra o funcionamento típico de um algoritmo genético.

Uma descrição mais detalhada de cada etapa do algoritmo genético é apresentada a seguir.

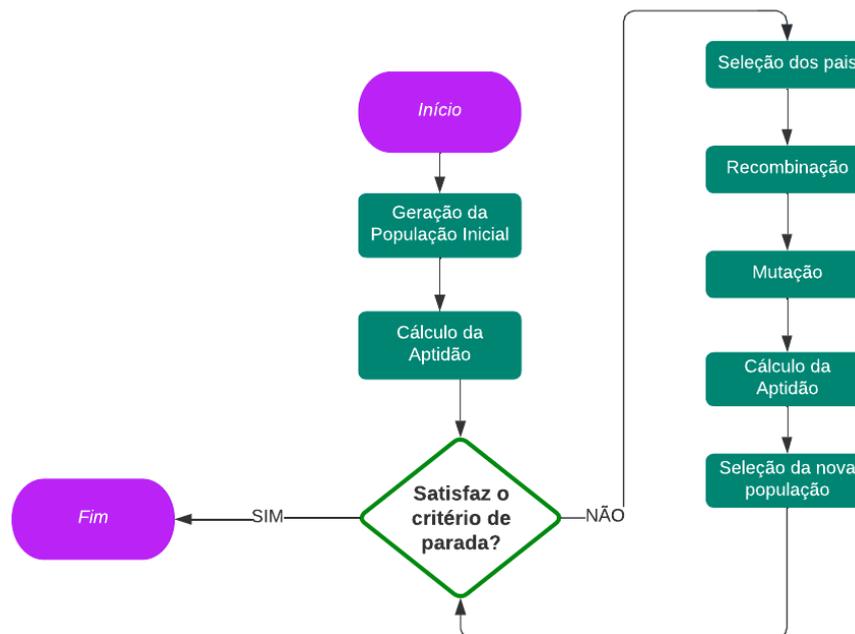


Figura 8 – Ciclo de um algoritmo genético.

2.3.1 Representação do Indivíduo e Geração da População Inicial

A fim de utilizar um AG na busca da solução de um problema, o primeiro e importante passo é definir exatamente como esse problema será representado. Um indivíduo

é um modelo de uma possível solução para o problema. Usualmente, os indivíduos são implementados como vetores de tamanho fixo. Do ponto de vista evolutivo, cada posição dessa representação da solução equivale a um gene, enquanto o indivíduo equivale a um cromossomo (GOLDBERG; HOLLAND, 1988). A Figura 9 mostra as principais representações unidimensionais (vetoriais) encontradas na literatura: binária, inteira e real. Esses valores compõem a informação genética do indivíduo, e é por meio dela que conceitos do processo evolutivo, como hereditariedade e adaptação, são aplicados.

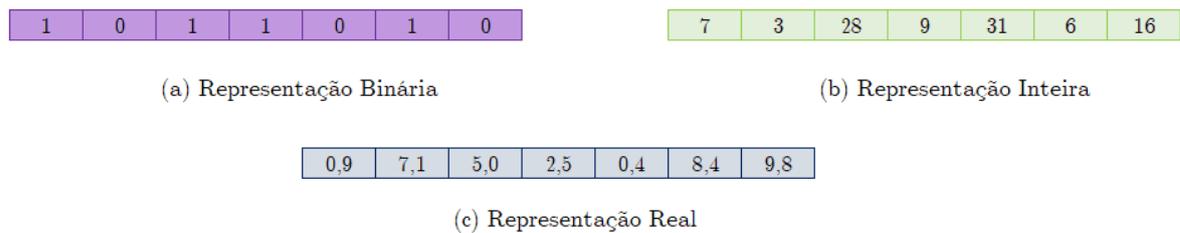


Figura 9 – Possíveis representações de um indivíduo.

A população é formada por uma coleção de indivíduos que passam pelos processos evolutivos a cada geração do AG. A evolução começa com a criação de uma população inicial, onde cada indivíduo dessa população é um candidato a uma solução. Essa geração inicial pode acontecer de forma puramente aleatória ou ser guiada por alguma abordagem heurística. No caso de problemas restritos, esta geração pode garantir que apenas soluções válidas possam ser geradas, ou deixar soluções inválidas que serão rejeitadas ao longo das gerações (HOLLAND, 1968). A Figura 10 mostra que um cromossomo é composto por genes e uma população é composta por cromossomos.

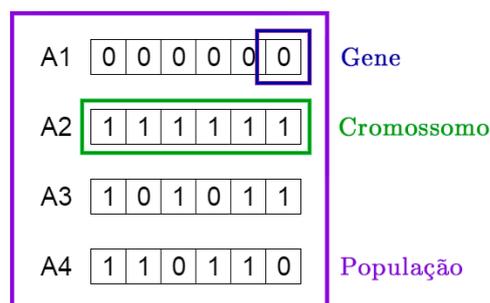


Figura 10 – Representação de uma população.

2.3.2 Função de Aptidão

O algoritmo genético necessita de alguma métrica que seja capaz de refletir o quão bom um indivíduo é definido como solução de um problema. Assim, a função de aptidão

(ou *fitness*) tem o papel de orientar o processo de evolução do algoritmo genético, dado que ela é responsável por avaliar o desempenho de um indivíduo como possível solução do problema. Essa métrica é o principal índice relacionado à otimização provida pelo processo evolutivo. Ela busca mapear o desempenho de um indivíduo em um valor numérico que quantifique sua aptidão, avaliando quão bem ele otimiza a função objetivo (HOLLAND, 1968).

A função de aptidão também é utilizada como critério classificatório nos operadores genéticos de seleção de pais para cruzamento (*crossover*) e de sobrevivência (reinscrição na população). Em problemas de maximização, soluções de maior *fitness* são às mais aptas. Já em problemas de minimização, um valor menor para o *fitness* indica que ele é melhor como solução. O *fitness* é recalculado sempre que um indivíduo é gerado ou modificado. Em algumas implementações, o *fitness* é recalculado a cada nova geração, isto é, a cada vez que o indivíduo sobrevive para a próxima geração (XAVIER et al., 2013).

Em problemas multiobjetivo, que visam otimizar simultaneamente dois ou mais objetivos, geralmente conflitantes, a função de aptidão pode ser composta por uma combinação de pesos entre as funções. Nesses casos, a otimização visa determinar um balanceamento entre os objetivos. Existem casos em que os problemas apresentam uma alteração de objetivo durante o processo de busca (problemas dinâmicos), assim, a função de aptidão também muda durante a evolução (FONSECA; FLEMING et al., 1993).

2.3.3 Métodos de Seleção

O método de seleção envolve a escolha dos indivíduos (pais) para o cruzamento, de modo a perpetuar seus genes após a troca de material genético. Esse processo não deve ser determinístico, ou seja, simplesmente escolher os indivíduos com melhor aptidão, uma vez que isso resultaria em uma população com pouca diversidade genética, com os cruzamentos produzindo filhos idênticos ou muito próximos entre si. Além disso, um indivíduo com baixa aptidão pode ter um gene muito bom que ao ser combinado com outro indivíduo gera uma excelente solução. Assim, os métodos de seleção costumam ser probabilísticos. (GOLDBERG; HOLLAND, 1988). Portanto, esse processo é o responsável por selecionar os indivíduos, sem comprometer a diversidade genética da população, ao mesmo tempo que busca aprimorar a qualidade de seus genes (LINDEN, 2008).

Uma importante característica dos operadores de seleção é a sua pressão seletiva. Quanto mais um operador tende a selecionar os melhores indivíduos da população corrente, maior é a pressão seletiva imposta por ele. Uma alta pressão seletiva pode acarretar em uma convergência prematura, ou seja, um cenário em que o AG fica preso em um mínimo local. Por outro lado, se a pressão seletiva for baixa, a população torna-se mais diversa, o que pode fazer com que o AG leve mais tempo para convergir e encontrar uma solução considerada ótima (XAVIER et al., 2013).

Na ausência de um método específico, a seleção pode ser feita utilizando um processo

puramente aleatório para selecionar os candidatos à reprodução. Entretanto, as técnicas mais comuns de seleção são a roleta e o torneio. Independentemente do método, os indivíduos selecionados são chamados de pais e os indivíduos gerados são chamados de filhos.

Proposta por Holland (1968), a roleta é definida como uma probabilidade cumulativa de seleção. Basicamente, uma roleta é composta por diversos intervalos, os quais são atribuídos aos indivíduos da população corrente. Cada indivíduo ocupa um intervalo de tamanho proporcional a sua aptidão. Depois da construção da roleta, um número é gerado aleatoriamente que indica qual intervalo (indivíduo) será selecionado. Assim, os melhores indivíduos têm uma maior probabilidade de serem selecionados. O processo não exclui indivíduos com baixo *fitness*, possibilitando que toda a população participe do sorteio. A Figura 11 mostra o funcionamento de uma roleta formada por 5 indivíduos e seus respectivos valores de *fitness* (XAVIER et al., 2013).

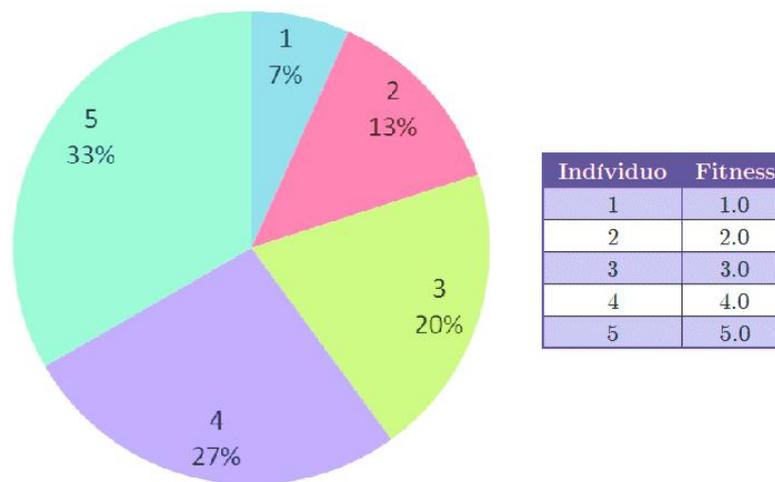


Figura 11 – Funcionamento do método de seleção da roleta.

No torneio, um número de indivíduos (*tour*) é selecionado na população aleatoriamente. Em seguida, escolhe-se o indivíduo que possui a melhor aptidão entre os membros do grupo *tour* como vencedor (LINDEN, 2008). Um esquema do torneio com *tour* de 3 aplicado a um problema de maximização é mostrado na Figura 12. Conforme pode ser observado, na primeira rodada do torneio foram selecionados aleatoriamente os indivíduos A, G e H. Considerando as respectivas aptidões, o indivíduo A é então selecionado por possuir o maior valor. O processo se repete, e novamente são escolhidos três indivíduos de forma aleatória (B, C e E). Dentre eles, o indivíduo C é o que possui a maior aptidão e, portanto, é também selecionado.

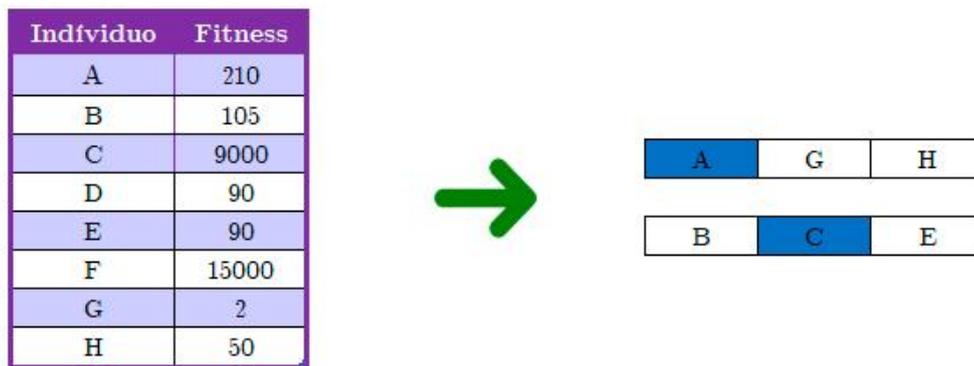


Figura 12 – Aplicação do método de torneio com *tour* de 3.

No torneio estocástico, a execução é dividida em duas etapas. Primeiramente, são selecionados *tour* indivíduos utilizando o método da roleta. Na segunda etapa, os indivíduos selecionados pela roleta competem entre si e aquele com a melhor aptidão é considerado o vencedor. Dentre outros métodos de seleção, pode-se destacar o ranking, o truncamento e a amostragem estocástica (ALVES et al., 2017).

2.3.4 Métodos de Recombinação

Os métodos de seleção são utilizados para determinar quais indivíduos terão seu material genético recombinado. Um par de indivíduos escolhidos durante o processo de seleção misturam seus genes num processo conhecido como cruzamento (*crossover*), ou recombinação. Nessa etapa, os indivíduos filhos são criados a partir dos indivíduos pais (XAVIER et al., 2013).

Diversos métodos são capazes de realizar a operação de *crossover*, dependendo da forma de representação do indivíduo. O *crossover* simples consiste na troca de material genético entre dois pais a partir de um ponto de corte – posição escolhida aleatoriamente que determina a parte do indivíduo a ser recombinada. Esse cruzamento é feito para simular a reprodução de genes em células. Trechos genéticos, com características de um indivíduo, são trocados por um trecho equivalente do outro, resultando em um indivíduo que combina as características dos ambos os pais (GOLDBERG; HOLLAND, 1988). Esse processo é mostrado na Figura 13.

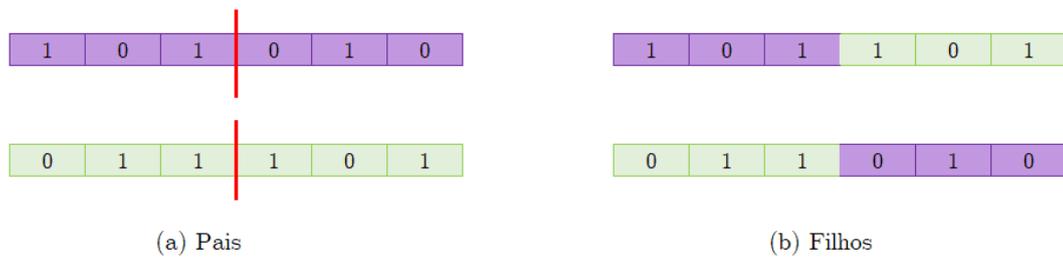


Figura 13 – *Crossover* simples (um ponto de corte).

A Figura 14 apresenta o processo de recombinação conhecido como *crossover* duplo. Nesse método, dois pontos de corte são escolhidos aleatoriamente, de modo a gerar três fragmentos do código genético de cada cromossomo pai. Então, os indivíduos filhos são gerados a partir da troca do fragmento central, conforme ilustrado na Figura 14(b).

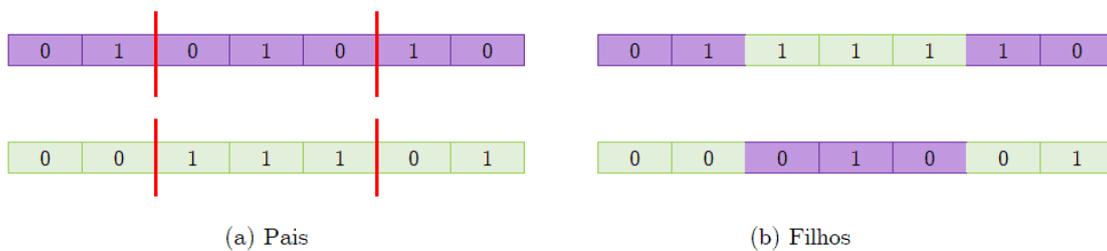


Figura 14 – *Crossover* duplo (dois pontos de corte).

A Figura 15 ilustra o processo do *crossover* uniforme. Nesse método de recombinação, há o sorteio de uma estrutura que define os pontos de corte denominada “máscara”. A máscara tem o tamanho exato do cromossomo e define quais as posições serão transmitidas pelo primeiro pai e quais serão transmitidas pelo segundo pai. Para gerar o primeiro filho, as posições que assumem o valor 0 na máscara correspondem aos genes do primeiro pai e as de valor 1 correspondem aos genes do segundo pai. O segundo filho é gerado com a carga genética complementar, ou seja, genes do pai 1 para as posições da máscara com valor 1 e do pai 2 para as demais.

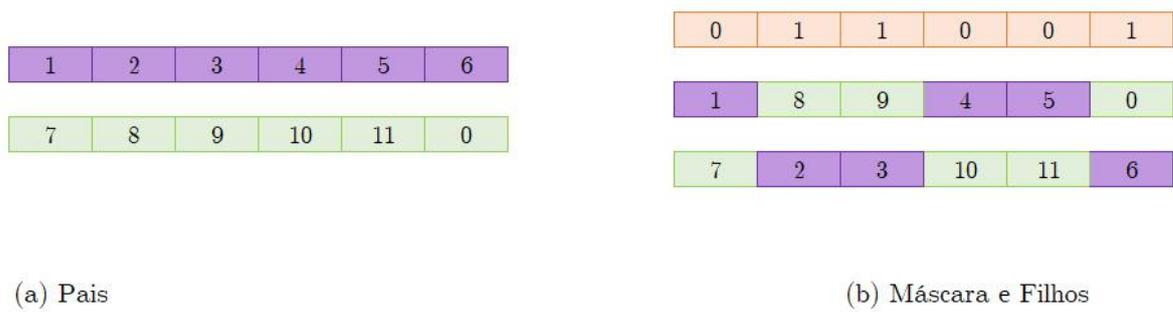


Figura 15 – *Crossover* uniforme.

Um dos métodos de *crossover* para indivíduos com valores reais é o aritmético. Dados dois pais (P_1 e P_2), um valor no intervalo $[0, 1]$ é sorteado para β (MICHALEWICZ; FOGEL, 2004). Os filhos (C_1 e C_2) são gerados através das equações:

$$C_1 = \beta P_1 + (1 - \beta)P_2 \tag{2}$$

$$C_2 = (1 - \beta)P_1 + \beta P_2 \tag{3}$$

A Figura 16 mostra um exemplo de aplicação do *crossover* aritmético com $\beta = 0.4$.

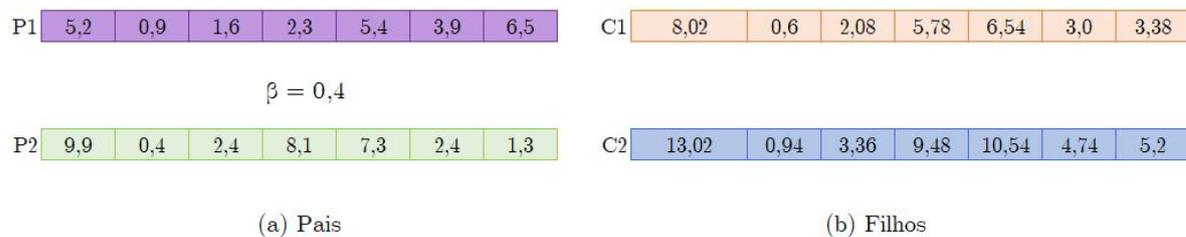


Figura 16 – *Crossover* aritmético.

2.3.5 Métodos de Mutação

A mutação é uma operação genética que modifica, aleatoriamente, alguma característica genética do indivíduo em que é aplicada (LINDEN, 2008). A importância dessa modificação dá-se pela possibilidade de criar novas características que não existiam ou apareciam em pequena quantidade na população em análise. O operador de mutação é necessário para a introdução e manutenção da diversidade genética da população.

Desta forma, a mutação assegura que a probabilidade de se chegar a qualquer ponto do espaço de busca não será zero. O operador de mutação é aplicado aos indivíduos através

de uma taxa de mutação geralmente pequena (GOLDBERG; HOLLAND, 1988).

Uma das formas mais simples de mutação é a aplicada em indivíduos com representação binária (HOLLAND, 1968). Nela, uma posição do cromossomo é sorteada e o valor binário dessa posição é invertido. Assim, 1 passa a ser 0 e 0 passa a ser 1. A Figura 17 ilustra a aplicação desse tipo de mutação no quarto gene (destacado em vermelho) de um indivíduo. Nesse exemplo, o gene possui o valor 0 originalmente e, após a mutação, passa a valer 1.

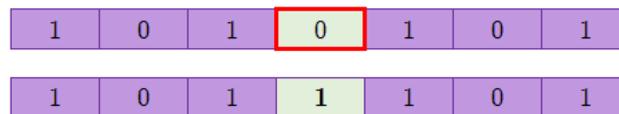


Figura 17 – Exemplo de mutação binária.

Outra forma de mutação muito comum é a permutação, em que dois ou mais genes são sorteados e trocados de posição. Ela é muito utilizada quando é necessário manter restrições na representação dos indivíduos, como nos casos em que não deve haver genes com o mesmo valor (XAVIER et al., 2013). A Figura 18 mostra uma simulação da permutação em que os genes 7 e 4 são invertidos.

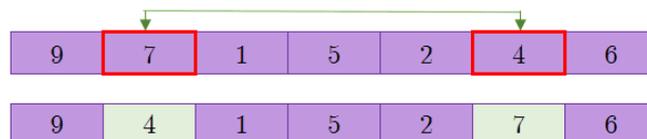


Figura 18 – Exemplo de mutação por permutação.

Em indivíduos com representação real, uma mutação utilizada é a soma de um valor aleatório (positivo ou negativo) ao gene sorteado para sofrer mutação (MICHALEWICZ; FOGEL, 2004). A Figura 19 mostra um exemplo desse tipo de mutação, no qual o valor do quarto gene, escolhido aleatoriamente, é acrescido ao valor sorteado (+0,6).

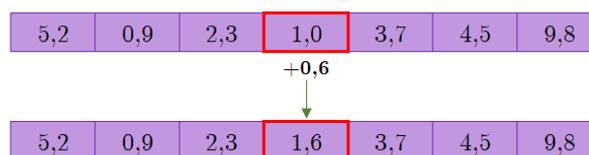


Figura 19 – Exemplo de mutação em indivíduos numéricos (mutação aritmética).

2.3.6 Reinservação

A escolha dos indivíduos que sobreviverão para a próxima geração é o último processo do ciclo iterativo do AG. Diversos métodos podem ser empregados para selecionar os indivíduos mais aptos a formarem a nova população, tais como: o elitismo, e reinservações pura ou ordenada. O elitismo consiste em preservar determinada quantidade dos melhores indivíduos da população mais antiga, completando a população com os melhores filhos da geração atual. Na reinservação pura, todos os pais são descartados e apenas os filhos são mantidos para a próxima geração. Esse método pode dificultar a convergência do AG, porque na população corrente podem haver pais mais aptos que os filhos e eles são descartados. Na reinservação ordenada ou uniforme, a população corrente formada por pais e filhos é ordenada de acordo com os valores do *fitness* e os n melhores indivíduos são mantidos, sendo n o tamanho da população (XAVIER et al., 2013).

2.3.7 Critério de Parada

O critério de parada define o momento em que o processo evolutivo do AG será interrompido (XAVIER et al., 2013). Quando é possível identificar um indivíduo como solução ótima, a execução do AG pode ser interrompida. Caso contrário, existem outras formas de determinar a parada do ciclo evolutivo do algoritmo genético. Usualmente, isso pode ser feito de três maneiras: (i) predefinir um número específico de gerações; (ii) interromper quando não há melhoria significativas na aptidão após um determinado número de gerações; ou (iii) predefinir um valor específico que deve ser atingido pelo *fitness*.

2.3.8 Parâmetros Genéticos

Os parâmetros utilizados na configuração do algoritmo genético influenciam no seu desempenho e comportamento. Os principais parâmetros genético são: o tamanho da população (T_p), a taxa de *crossover* (T_c), a taxa de mutação (T_m) e o número de gerações (N_{ger}) (LINDEN, 2008). Para definir esses parâmetros, faz-se uma análise das necessidades do problema e dos recursos computacionais disponíveis.

O tamanho da população afeta diretamente o desempenho global e a eficácia do AG. Em uma população muito grande, há maior cobertura no domínio do problema, o que pode evitar as convergências prematuras. Entretanto, um tamanho maior de população exige mais recursos computacionais ou um maior tempo de execução. Por outro lado, se a população é muito pequena, há uma menor cobertura no espaço de busca do problema e o desempenho do AG pode ser afetado.

A taxa de *crossover* está relacionada ao número de pais da população corrente que serão escolhidos para o processo de reprodução. Quando a taxa é mais alta, mais indivíduos são gerados, mas o custo computacional é maior. Por exemplo, se $T_p = 100$ e $T_c = 90\%$, 90 filhos serão gerados durante a reprodução.

A probabilidade de o indivíduo ter algum de seus genes alterados é definida pela taxa de mutação. Se a taxa de mutação for muito alta, a busca pode tornar-se essencialmente aleatória. Mas, uma taxa muito baixa pode atrapalhar o processo de diversidade genética e afetar a heterogeneidade dos cromossomos.

Por fim, o número de gerações equivale ao número de iterações completas que o AG executa. Esse número deve ser considerado cuidadosamente para que o AG seja capaz de encontrar uma solução ótima em um tempo viável.

Trabalhos Correlatos

Neste capítulo serão abordados os trabalhos relacionados aos modelos de simulação de incêndios baseados em autômatos celulares e a utilização de algoritmos genéticos para ajustes de parâmetros de autômatos celulares. Primeiramente, a Seção 3.1 traz um levantamento dos principais modelos de simulação da propagação de incêndios encontrados na literatura. Destacam-se os modelos Louzada e Júnior (2008), Lima e Lima(2014), utilizados como base para construção do modelo e Ferreira et al. (2022b). Os modelos (LIMA; LIMA, 2014) (TINOCO et al., 2022) são utilizados para gerar as bases de dados artificiais a fim de avaliar a sensibilidade da ferramenta evolutiva. A Seção 3.2 apresenta uma revisão acerca dos principais trabalhos que utilizam algoritmos evolutivos no ajuste de regras, comportamentos ou parâmetros de modelos de autômatos celulares.

3.1 Modelos de Propagação de Incêndios

Diversos modelos de propagação de incêndios baseados em autômatos celulares foram propostos na literatura. A maioria desses modelos utiliza regras de transição probabilísticas aplicadas em reticulados bidimensionais de células, que representam os ambientes onde o incêndio é propagado. Essa modelagem pode considerar diferentes parâmetros que afetam a dinâmica das chamas, como clima, tipo de vegetação e topografia do terreno.

O modelo descrito em (ROTHERMEL, 1972) é um dos primeiros estudos matemáticos para a investigação da dinâmica de incêndios florestais. Nesse modelo, baseado em equações diferenciais, a quantidade de árvores em uma área é um dos parâmetros utilizados para modelar o comportamento das chamas, uma vez que a cobertura vegetal é o combustível para propagação dos incêndios. Diferentes regras foram formuladas, considerando a intensidade e a velocidade de propagação das chamas, além da quantidade de árvores. O modelo proposto em (CHOPARD; DROZ, 1998) também é um dos pioneiros nessa temática e utiliza a abordagem baseada em ACs. O modelo proposto consiste em um autômato celular probabilístico com três estados: árvore viva, árvore queimando e solo exposto. O autômato celular é bidimensional e utiliza vizinhança de Moore. Esses

trabalhos são considerados os precursores e serviram como referência para modelos posteriores de propagação de incêndios utilizando autômatos celulares.

Em (DILÃO, 1992) é apresentado um modelo baseado em autômatos celulares para a simulação da propagação de incêndios. O modelo proposto adota um reticulado de células quadradas, que podem assumir três estados possíveis: viva, em chamas ou morta. A modelagem considera que o vento é um fator decisório no espalhamento do fogo ao longo do reticulado. O estudo descrito em (CLARKE; BRASS; RIGGAN, 1994) considerou os dados de uma queimada em uma floresta de San Dimas, California para o ajuste do modelo preditivo baseado em ACs. O modelo de simulação considerou vizinhanças aleatórias, direção e magnitude do vento, além de temperatura e umidade relativa do ar. A técnica de Monte Carlo foi utilizada para o cálculo de probabilidade em áreas conhecidas. O modelo tem capacidade de vincular dados de sensoriamento remoto em tempo real obtidos de detectores infravermelhos de aeronaves, o que combinado com a capacidade preditiva, auxilia diretamente no combate e prevenção de incêndios florestais.

O modelo discutido em (ENCINAS et al., 2007) propôs a utilização de autômatos celulares com células hexagonais com uma estrutura baseada na transferência fracionária da área em chamas. Esse modelo considerou tanto cenários com florestas homogêneas, quanto heterogêneas. Fatores como topografia e vento também foram considerados no cálculo da probabilidade de queima. Os estados de cada célula são definidos por meio da transferência fracionária da área queimada, considerando diferentes taxas de velocidade. O modelo foi aplicado em oito casos com variações nas condições climáticas, topográficas e de velocidade. Os autores destacam que os resultados obtidos correspondem com a propagação de fogo em florestas reais.

Outra modelagem de propagação de incêndios foi apresentada em (ALEXANDRIDIS et al., 2008), simulando um incêndio que ocorreu em 1990 na Ilha de Septses e destruiu grande parte da floresta nativa. Nesse modelo são considerados o tipo e densidade da vegetação, além da direção e a velocidade do vento e uma topografia montanhosa. Para o ajuste de parâmetros do modelo, uma otimização não linear foi utilizada incorporando dados disponíveis do incêndio real. Ao comparar os resultados da simulação com os dados reais, o modelo proposto foi capaz de prever as características de evolução no espaço e tempo. Assim, o modelo descrito poderia ser utilizado como uma ferramenta de gestão de riscos.

O modelo descrito em (KARAFYLLIDIS; THANAILAKIS, 1997) utiliza cenários com florestas homogêneas e heterogêneas, considerando condições climáticas e a topografia da área. Os cenários de incêndio utilizados pelo modelo de simulação foram condizentes com a experiência de propagação de fogo em cenários reais. Os autores destacam que o modelo pode ser utilizado para o planejamento de estratégias de mitigação de incêndios e também como suporte à decisão em tempo real. Além disso, mediante ao paralelismo dos autômatos celulares, o modelo podem, potencialmente, ser executados em um computador

paralelo.

A modelagem proposta em (YONGZHONG et al., 2004) utilizou bases de dados artificiais e reais e o modelo com células hexagonais mostrou-se eficiente na simulação de incêndios em locais com vegetações heterogêneas. Inicialmente, foi utilizado um modelo de AC hexagonal. Posteriormente, características do modelo de Rothermel (1972) foram incorporadas ao modelo. Os autores utilizaram dados obtidos no sul da província de Gansu na China e ao compararem os dados reais com os simulados, perceberam que as simulações foram satisfatórias. O modelo desenvolvido pode ser utilizado como uma ferramenta de mitigação de incêndios em florestas heterogêneas.

Em (SANTOS, 2007) autômatos celulares foram empregados na simulação de propagação de incêndios no Parque Natural da Serra da Arrabida, reserva localizada na península de Setúbal, em Portugal. O modelo de simulação tenta reproduzir o comportamento da vegetação mediterrânea, integrando topografia, clima e padrão de realidade. Para a avaliação da simulação, foram considerados distintos pontos iniciais de incêndios. O modelo também considera a direção e velocidade do vento, uma vez que um incêndio com maior intensidade e velocidade de vento pode causar uma devastação maior. Através da simulação, foi possível perceber uma tendência a incêndios catastróficos na área estudada, o que reforça a facilidade de ocorrência de fogos de difícil controle. O modelo, então, mostrou-se uma importante ferramenta para o combate e controle dos incêndios reais.

Recentemente, trabalhos ressaltaram a importância do uso de autômatos celulares como modelagem de propagação de incêndios. Em (XUEHUA et al., 2016), fatores como temperatura, vento, topologia e materiais combustíveis foram considerados na modelagem do modelo de incêndios baseado em autômatos celulares e desenvolvido na plataforma Matlab. Os autores classificaram os materiais combustíveis de acordo com a os tipos de vegetação e espécies de árvores. Destaca-se que, segundo o trabalho, o vento e topologia foram fatores chaves para simular satisfatoriamente o incêndio. O modelo mostrou-se capaz de simular e prever as tendências de propagação das chamas. Entretanto, ainda é necessário discutir outros fatores que podem influenciar diretamente no comportamento de um incêndio, além de coletar dados reais mais abrangentes para aprimorar o modelo. Para melhorar a precisão da modelagem em relação a velocidade da propagação de chamas, o modelo proposto em (SUN et al., 2021) aprimorou um modelo de AC existente e construiu um modelo de propagação de incêndios que calcula a taxa de velocidade do incêndio, baseando-se nos fatores meteorológicos, o ambiente real da localização do incêndio corrente. Dessa forma, o modelo ajusta adaptivamente a evolução do AC, através da taxa de mudança de velocidade, simulando a propagação de incêndio de acordo com tendências reais, sendo mais preciso. Dados reais de um incêndio de 2020 em Liangshan, condado da China, foram utilizados e o modelo teve precisão de 96,6% na simulação deste incêndio.

As subseções a seguir apresentam em maiores detalhes três modelos da literatura

(LOUZADA; JUNIOR, 2008), (LIMA; LIMA, 2014), (TINOCO et al., 2022) que foram utilizados como base do modelo aqui investigado e como modelos de validação da ferramenta evolutiva de ajuste automático de parâmetros.

3.1.1 Modelo Louzada e Ferreira Junior (2008)

O modelo proposto por Louzada e Ferreira Jr. (2008) utiliza um autômato celular bidimensional com vizinhança de Moore, que emprega dois parâmetros principais: LQ e LR. O número de graduações de queima é representado por LQ, sendo que cada estágio representa uma diferente temperatura do fogo em uma célula do reticulado. A idade da floresta é representada por LR que indica a quantidade matéria orgânica seca presente naquela célula do reticulado. Florestas mais antigas tendem a possuir um maior acúmulo de matéria orgânica seca, que é combustível para a queima. O estado de cada célula é expressa pelo par (Tipo, Idade), com Tipo $\in \{Fogo, Floresta\}$ e Idade $\in [1..Lim]$, sendo $Lim = LQ$, se Tipo = *Fogo*; ou $Lim = LR$, se Tipo = *Floresta*. As regras de transição são as seguintes:

- Uma célula *Fogo* se torna *Floresta* se sua idade corresponde ao valor de LQ.
- Uma célula do Tipo *Floresta* tem uma probabilidade P de se tornar *Fogo*, calculada por:

$$P = \frac{Idade}{LR} \times \frac{MediaV}{LQ} \quad (4)$$

em que $MediaV$ representa a média de idade das células queimadas vizinhas. A probabilidade de uma célula queimar é, portanto, maior com aumento de LQ e LR dos vizinhos.

A Figura 20 mostra o comportamento do modelo de Louzada e Ferreira Júnior(2008). Visualmente, diversas tonalidades de cor representam as idades de cada célula: quanto mais escuro, mais perto do limite de Idade do Tipo. Os valores utilizados nesse exemplo para LQ e LR são 3 e 30, respectivamente. Nessa implementação, o modelo é um toróide, ou seja, a parte superior da matriz é conectada com a parte inferior, assim como a parte mais à esquerda é conectada a parte mais à direita.

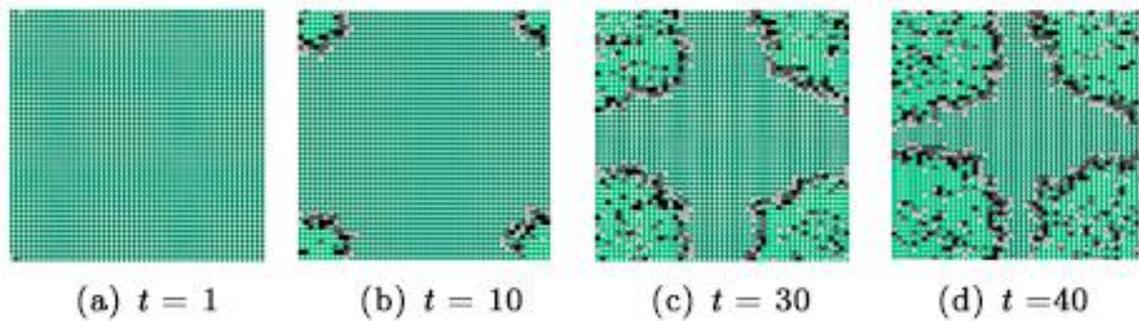


Figura 20 – Comportamento do modelo Louzada e Junior (2008).

3.1.2 Modelo Lima e Lima (2014)

O modelo de propagação de incêndios proposto em (LIMA; LIMA, 2014) é representado por um autômato celular bidimensional que utiliza vizinhança de Moore e é inspirado em (KARAFYLLIDIS; THANAILAKIS, 1997) e (ENCINAS et al., 2007). Existem seis estados possíveis para cada célula: *Árvore*, *Fogo1*, *Fogo2*, *Fogo3*, *Fogo4* e *Cinzas*.

O modelo tem uma matriz de preferências P ($m \times m$) que representa a velocidade e a direção do vento. A velocidade do vento é definida em função do raio de vizinhança adotado. Por exemplo, para um raio igual a 1, a velocidade máxima do vento é 1. As regras de transição do modelo são:

- ❑ células $Fogo(i)$ mudam para $Fogo(i + 1)$;
- ❑ células $Fogo4$ (último estágio de queima) mudam para o estado de *Cinzas*;
- ❑ células *Cinzas* permanecem nesse estado;
- ❑ células *Árvore* mudam para $Fogo1$ com probabilidade P , sendo P definida de acordo com as células do tipo $Fogo(i)$ da vizinhança com a matriz de preferências que representa o vento.

No modelo, a matriz de preferências depende do tamanho do raio. A Figura 21 apresenta a matriz de preferências para raio 1. O círculo verde representa uma árvore intacta.

0,075	0,05	0,05
0,14	●	0,05
0,42	0,14	0,075

Figura 21 – Matriz de preferências para raio 1 utilizada no modelo Lima e Lima (2014).

A Figura 22 demonstra o comportamento do modelo. Visualmente, a cor verde representa o estado *Árvore*, quatro tonalidades de vermelho representam a árvore queimando (*Fogo1*, *Fogo2*, *Fogo3*, *Fogo4*) e o cinza representa o estado *Árvore Queimada*. É possível perceber que o espalhamento do fogo não é radial, e ocorre no sentido leste do reticulado. A matriz de preferências utilizada é a de raio 1 e influencia na propagação do fogo ao mesmo tempo em que inibe a propagação na direção oposta.

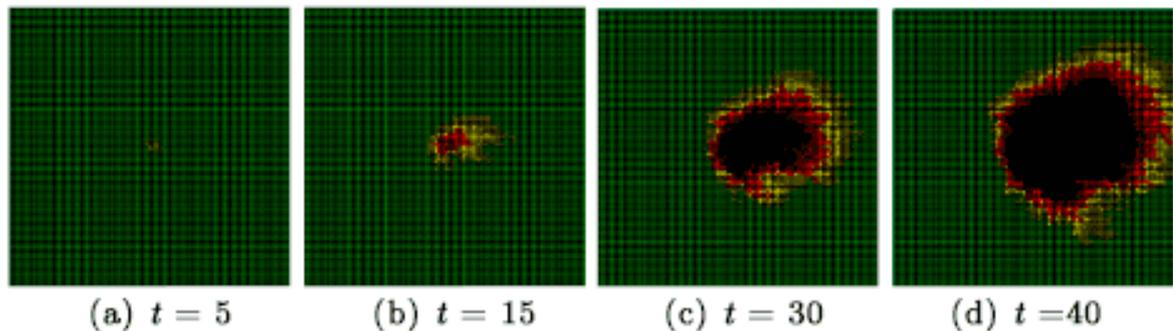


Figura 22 – Comportamento do modelo Lima e Lima (2014).

3.1.3 Modelo Tinoco et al. (2022)

O modelo de propagação proposto em (TINOCO et al., 2022) utiliza um autômato celular com vizinhança de Moore. O modelo possui seis estados. O estado *Vegetação* representa células que possuem material orgânico capaz de queimar. Os estados *Fogo inicial*, *Fogo estável* e *Fogo em brasa* representam o fogo, cada um com uma intensidade diferente. O estado *Cinza* representa as células que já queimaram e podem voltar a ser combustível para fogo. E o estado *Água* que não interage diretamente com nenhum outro estado, mas é uma barreira que impede o fogo de tomar uma determinada direção.

Uma característica importante do modelo é a presença de uma matriz de combustão que representa o vento. Além disso, o modelo também apresenta uma função de recuperação, baseada em uma probabilidade exponencial, que determina as chances das células queimadas se recuperarem, se tornando suscetíveis a novas queimadas. Para ajustar o comportamento do fogo, o modelo tem dois coeficientes: o calórico (λ) que representa a intensidade global do fogo; e o coeficiente de vento (δ) que representa um valor cardinal que indica a direção do vento. O modelo apresenta as seguintes regras de transição:

- Células no estado *Vegetação* mantêm-se no mesmo estado se não houver células em fogo na vizinhança.
- Células no estado *Vegetação* têm uma probabilidade de tornarem-se *Fogo inicial* se na vizinhança há pelo menos uma célula em estado de fogo.

- ❑ Células em *Fogo Inicial* mudam para *Fogo Estável* após três passos de tempo.
- ❑ Células em *Fogo Estável* mudam para *Brasa* após três passos de tempo.
- ❑ Células em *Brasa* mudam para *Cinza* após dez passos de tempo.
- ❑ Células em *Cinza* podem se tornar *Vegetação* de acordo com a função de recuperação.

Na Figura 23, pode-se perceber o comportamento do modelo (TINOCO et al., 2022). O fogo se espalha na direção sudoeste do reticulado.



Figura 23 – Comportamento do modelo Tinoco et al. (2022).

3.2 Computação Evolutiva na Configuração de Autômatos Celulares

O uso de algoritmos genéticos aliados à autômatos celulares já foi descrito em diversos estudos na literatura, seja no ajuste de parâmetros dos modelos, ou mesmo na especificação de regras.

Em (SZABÓ; TÓKE, 1998), os AGs são utilizados na definição de estratégias para o Dilema dos Prisioneiros. O uso de um algoritmo genético para evoluir as regras de autômatos celulares na tarefa de classificação de Densidade (DCT) foi proposto em (PACKARD, 1988). A tarefa de DCT também foi estudada em (MITCHELL; CRUTCHFIELD; HRABER, 1994) e (OLIVEIRA; OLIVEIRA; OMAR, 2001), nos quais os AGs também foram utilizados na busca das regras.

A utilização da busca evolutiva foi aplicada em problemas clássicos da computação como o escalonamento (CARNEIRO; OLIVEIRA, 2013) e a criptografia (SZABAN; SEREDYNSKI; BOUVRY, 2006). A abordagem de busca evolutiva também foi aplicada em modelos baseados em regras de ACs para simulação de fenômenos naturais e biológicos. No estudo descrito em (D'AMBROSIO et al., 2007) algoritmos genéticos paralelos foram utilizados na configuração de um modelo de deslizamento de terra baseado em autômatos celulares. Para realizar a calibração, foram utilizados dados de um período de chuvas em 1998, na Itália. Nesse trabalho, os autores também avaliaram o paralelismo em *hardware* para a implementação do modelo, uma vez que a avaliação do AG é uma das etapas

que mais exige recursos computacionais. Os autores concluíram que o modelo, após a calibração utilizando a abordagem evolutiva, teve melhorias em relação a versão anterior. O trabalho apresentado em (D'AMBROSIO; SPATARO, 2007) também utiliza essa abordagem evolutiva na configuração de modelos de fluxo de detritos e lava. Os autores não conseguiram dados reais para comparação, mas a utilização do AG no modelo de AC apresentou uma melhoria no desempenho.

Em (GARCÍA-DURO et al., 2018), investigou-se a modelagem da recuperação da vegetação após a ocorrência de queimadas naturais. Foram considerados fatores como o número de espécies de plantas e a dispersão de sementes no modelo baseado em regras de ACs. O elevado número de parâmetros e o uso de um reticulado de dimensões grandes justificam o alto custo computacional do modelo. Dessa maneira, ao propor uma alteração nas regras, ou no tamanho do reticulado, o impacto no custo computacional era exponencial. A fim de auxiliar esse processo, os autores utilizaram uma abordagem evolutiva. Foi proposto um modelo baseado em programação genética para definir as funções para a taxa de propagação de cada espécie. Posteriormente, um algoritmo genético foi utilizado para definir a melhor combinação das espécies, simulando de forma mais realista os dados.

A abordagem evolutiva também foi utilizada para o ajuste do modelo de crescimento urbano em (SHAN; ALKHEDER; WANG, 2008). Algoritmos genéticos foram utilizados para identificar valores de regras de transição do autômato celular. A calibração com algoritmos genéticos provou ser eficaz na produção de regras de transição adequadas. O algoritmo de calibração proposto foi implementado para modelar o crescimento urbano histórico de Indianápolis, EUA. Os resultados do crescimento urbano mostram uma correspondência próxima tanto da contagem quanto do padrão urbano com a realidade.

No modelo para gerenciamento de águas subterrâneas descrito em (SIDIROPOULOS; TOLIKAS, 2008), algoritmos genéticos foram utilizados para a definição de poços para bombeamento de água e gerenciamento dos aquíferos.

Em (MONTEIRO; OLIVEIRA; CHAU-BERLINCK, 2009), um modelo epidemiológico baseado em autômatos celulares probabilísticos foi proposto para simular a epidemia de varicela que ocorreu no Arizona entre 1994 e 2004. Tal modelo utiliza algoritmos genéticos para calcular as probabilidades de transição de estados. O estudo proposto por (GERARDI; MONTEIRO, 2011) utiliza de dados de incidência da dengue, registrados no Rio de Janeiro durante os anos de 2007 e 2008, com o intuito de construir um arcabouço epidemiológico baseado em autômatos celulares probabilísticos. Através da utilização de algoritmos genéticos, foram encontradas as probabilidades de transição de estados, viabilizando a previsão acurada da epidemia ocorrida em 2008.

Em (MONTEIRO; GANDINI; SCHIMIT, 2020), modelos baseados em autômatos celulares e algoritmos genéticos foram usados para avaliar a influência de indivíduos imunes nos processos de contágio e recuperação de doenças contagiosas, nesse caso, a varicela. O modelo epidêmico foi baseado em autômatos celulares e probabilísticos e um algoritmo

genético otimizou os valores de três parâmetros do modelo de AC. O trabalho utilizou dados de prevalência da varicela de dois países europeus: a Bélgica e a Itália.

Em (TINOCO; VIZZARI; OLIVEIRA, 2020) a aplicação de uma técnica evolutiva para otimizar os parâmetros de um modelo de coordenação para enxames de robôs, chamado o IACA-DI. O modelo visa coordenar enxames de robôs e é baseado em autômatos celulares e sistema inverso de formigas. Nessa abordagem, os autores observaram melhorias significativas no desempenho do IACA-DI após uma otimização dos seus parâmetros. O modelo proposto em (LOPES; LIMA, 2022) utilizou algoritmos genéticos para otimizar os parâmetros de um controlador de navegação robótica de enxame de partículas. O modelo também empregava autômatos celulares, busca Tabu e sistema inverso de formigas.

O estudo descrito em (FRAGA; OLIVEIRA; MARTINS, 2021) utilizou algoritmos genéticos no ajuste de parâmetros do modelo baseado em ACs de proliferação de insetos vetores da doença de Chagas. Os autores utilizaram os AGs multi-estágios para a encontrar a configuração ideal do modelo baseado em autômatos celulares, a partir de uma série de dados sintéticos gerados por um modelo previamente descrito na literatura (SLIMI et al., 2009). Essa abordagem foi necessária para validar o ajuste evolutivo dos parâmetros do modelo, uma vez que os autores não tinham acesso aos dados reais. Essa abordagem também foi utilizada no presente trabalho para validar a eficiência do algoritmo genético em encontrar parâmetros adequados para o modelo de propagação de incêndio.

Modelo de Propagação de Incêndios

O modelo utilizado neste trabalho começou a ser desenvolvido na iniciação científica do aluno André Luiz Moraes Peres Quinta, membro do LCBio (Laboratório de Computação Bio-inspirada). Ele foi concebido para combinar as características observadas nas abordagens propostas em (LOUZADA; JUNIOR, 2008) e (LIMA; LIMA, 2014), a fim de simular a propagação de incêndios em áreas com uma único tipo de vegetação (cenários homogêneos). Esse modelo foi refinado e, então, integrado ao algoritmo evolutivo responsável pelo ajuste automático de seus parâmetros. Devido à ausência de dados reais, ele também foi empregado para gerar dados artificiais de diferentes cenários de incêndios, os quais foram utilizados na validação da abordagem evolutiva proposta. Posteriormente, visando representar computacionalmente o bioma do cerrado mineiro, o modelo foi adaptado para lidar com diferentes tipos de vegetação (cenários heterogêneos), aumentando, assim, a sua complexidade e, conseqüentemente, do espaço de busca a ser explorado pelo algoritmo evolutivo. Uma descrição mais detalhada do modelo investigado nesta pesquisa, bem como alguns cenários simulados a partir dele, é apresentada a seguir.

4.1 Modelo de Propagação de Incêndios em Cenários Homogêneos

Em (FERREIRA et al., 2022b) foi apresentado um modelo para simulação de incêndios baseado em regras de autômatos celulares, elaborado a partir das características identificadas nas modelagens propostas em (LOUZADA; JUNIOR, 2008) e (LIMA; LIMA, 2014). O modelo proposto integra os parâmetros LQ e LR, utilizados em (LOUZADA; JUNIOR, 2008), com uma adaptação da matriz de preferências $W_{3 \times 3}$, que representa o vento, proposta em (LIMA; LIMA, 2014).

O modelo utiliza um autômato celular bidimensional, com reticulado 100×100 e vizinhança de Moore, e a condição de contorno é reflexiva, isto é, cada célula da borda é refletida para ser utilizada como parte do limite do AC. O estado de cada célula é definido

pelo par (Tipo, Idade). O campo Tipo pode assumir os valores Fogo, Árvore ou Água, indicando se aquela célula representa uma área com incêndio, vegetação ou um corpo d'água, respectivamente. A informação representada no campo Idade depende do tipo da célula.

Quando a célula está pegando fogo, $Idade \in [1..LQ]$, e representa o tempo de queima da árvore, ou a temperatura das chamas. Portanto, uma célula do tipo *Fogo* passará por LQ estágios diferentes de temperatura de fogo enquanto queima. Sempre que uma célula muda para o tipo Fogo, ela inicia com $Idade = 1$, e a cada passo de tempo subsequente, esse campo é incrementado em um, até atingir o valor máximo LQ. No próximo instante de tempo, uma célula do tipo Fogo e Idade igual a LQ, uma célula do tipo *Fogo* é alterada para o tipo *Árvore* com $Idade = 1$, representando uma área que acabou de ser queimada e vai começar a sua regeneração.

Para células com vegetação (Tipo = *Árvore*), $Idade \in [1..LR]$ e representa tempo de recuperação da árvore, ou a quantidade de material orgânico (combustível) disponível para a queima). Isto é, uma célula do tipo *Árvore* passará por até LR estágios diferentes de recuperação. A idade da célula em recuperação representa a quantidade de matéria orgânica seca presente naquela área do reticulado que pode ser combustível para a queima. Uma célula do tipo *Árvore*, inicia com $Idade=1$ e, a cada passo de tempo subsequente em que ela se mantiver nesse estado, o valor do campo é incrementado em um até atingir valor máximo igual a LR.

A cada iteração, uma célula do tipo *Árvore* tem uma probabilidade P de se tornar *Fogo*, que pode ser calculada por:

$$P = \frac{Idade}{LR} \times \frac{\overline{IW}_{fogo}}{LQ} \quad (5)$$

onde $\overline{IW}_{fogo} = \sum_{ab}^n Estado_{ab} \times w_{ab}$, em que $\forall x_{ab} \in \eta_{ij}^8$ vizinhas da célula x_{ij} que estão no estado *Fogo*. O \overline{IW}_{fogo} é saturado em 1.

A probabilidade de uma célula *Árvore* começar a queimar é diretamente proporcional ao tempo de recuperação da célula (Idade) e a média do produto entre o tempo de queima e a influência do vento em sua vizinhança (\overline{IW}_{fogo}). Vale destacar que, quanto maior o tempo de recuperação de uma célula do tipo *Árvore*, maior é a quantidade de matéria orgânica para combustível que ela tem temperatura do fogo. Valores elevados para a temperatura do fogo das células vizinhas e para a intensidade do vento oriundo daquela região, aumentam a probabilidade da célula central pegar fogo. Uma vez calculada a probabilidade de queima (P) de uma célula do tipo *Árvore*, o método da roleta é usado para determinar se a célula pegará fogo. Esse método consiste em sortear aleatoriamente um número entre 0 e 1 e, caso ele seja menor ou igual a P, a célula passa para o primeiro estágio de queima (Tipo = *Fogo* e Idade = 1). Caso contrário, ela permanece como *Árvore* e sua idade de recuperação é incrementada (limitada a LR).

Para células com corpos d'água (Tipo = *Água*), $Idade = 0$. As células desse tipo

funcionam como uma barreira. Ou seja, entende-se que um rio ou um corpo d'água, na maioria das vezes, impede a propagação do fogo.

4.2 Representação do Vento

A matriz de preferências $W_{3 \times 3}$, representa uma vizinhança de Moore com raio $r = 1$, que modela a influência do vento na propagação do incêndio daquela vizinha para a célula central, ou seja, é a decomposição espacial da intensidade e da direção do vento entre a vizinhança. Cada posição da matriz W assume um valor entre 0 e 1. Similar à matriz utilizada em modelos de dinâmicas de partículas (SCHADSCHNEIDER, 2001), a matriz $W_{3 \times 3}$ indica uma maior preferência de uma chama existente em uma das oito células vizinhas ($\vec{V}_N, \vec{V}_S, \vec{V}_L, \vec{V}_R, \vec{V}_{NE}, \vec{V}_{NW}, \vec{V}_{SE}, \vec{V}_{SW}$) se propagar para a célula central. Dessa forma, ela modela a direção e intensidade do vento. A Figura 24 traz alguns exemplos de matrizes de preferências.

0.140	0.500	0.850	0.850	0.500	0.140	0.850	1.000	0.850	0.000	0.140	0.500
0.000	0.000	1.000	1.000	0.000	0.000	0.500	0.000	0.500	0.140	0.000	0.850
0.140	0.500	0.850	0.850	0.500	0.140	0.140	0.000	0.140	0.500	0.850	1.000
(a)	(b)	(c)	(d)	(e)	(f)	(g)	(h)	(i)	(j)	(k)	(l)
0.560	0.333	0.093	1.000	0.850	0.500	0.425	0.500	0.425	0.120	0.000	0.120
0.666	0.000	0.000	0.850	0.000	0.140	0.250	0.000	0.250	0.072	0.000	0.072
0.560	0.333	0.093	0.500	0.140	0.000	0.014	0.122	0.014	0.193	0.233	0.193
(e)	(f)	(g)	(h)	(i)	(j)	(k)	(l)	(m)	(n)	(o)	(p)

Figura 24 – Exemplos de matrizes de preferências que representam o vento em cenários homogêneos.

Para demonstrar como os valores da matriz de preferências modelam o vento e facilitar a visualização, criou-se um vetor de forças que representa a influência do vento. Esse vetor é composto por todas as células que estão na vizinhança e a célula central, sendo que a intensidade do vento (i) e o ângulo da sua direção θ são calculados, respectivamente, por:

$$i = \sqrt{\left(\sum\left(\frac{W_{(ij)x}}{\sqrt{2}}\right)\right)^2 + \left(\sum\left(\frac{W_{(ij)y}}{\sqrt{2}}\right)\right)^2} \quad (6)$$

$$\theta_1 = \arctan\left(\frac{\sum\frac{W_{ijx}}{\sqrt{2}}}{\sum\frac{W_{ijy}}{\sqrt{2}}}\right) \quad (7)$$

$$\theta_2 = \frac{\pi}{2} + |\theta_1|$$

$$\theta_3 = \frac{3\pi}{2} - |\theta_1|$$

$$\theta_4 = \frac{3\pi}{2} + |\theta_1|$$

em que $W_{2 \times 2}$ representa a origem, isto é, a célula central da matriz, $W_{i \times j}$ representa a célula atual da matriz, $W_{i_x \times j_x}$ representa o componente horizontal do vetor da célula e $W_{i_y \times j_y}$ o componente vertical da célula. Leva-se em consideração a célula central como origem do plano cartesiano e cada célula foi considerada como um vetor. Assim, foram somadas suas componentes vetoriais considerando direção e intensidade. Para o cálculo da intensidade, encontrou-se a hipotenusa do triângulo formado tendo os vetores resultantes como catetos, como citado no Teorema de Pitágoras. O cálculo do ângulo θ depende de qual quadrante do plano cartesiano, o vetor está plotado. A representação vetorial (vetores de forças) das matrizes de preferências apresentadas na Figura 24 é mostrada na Figura 25.

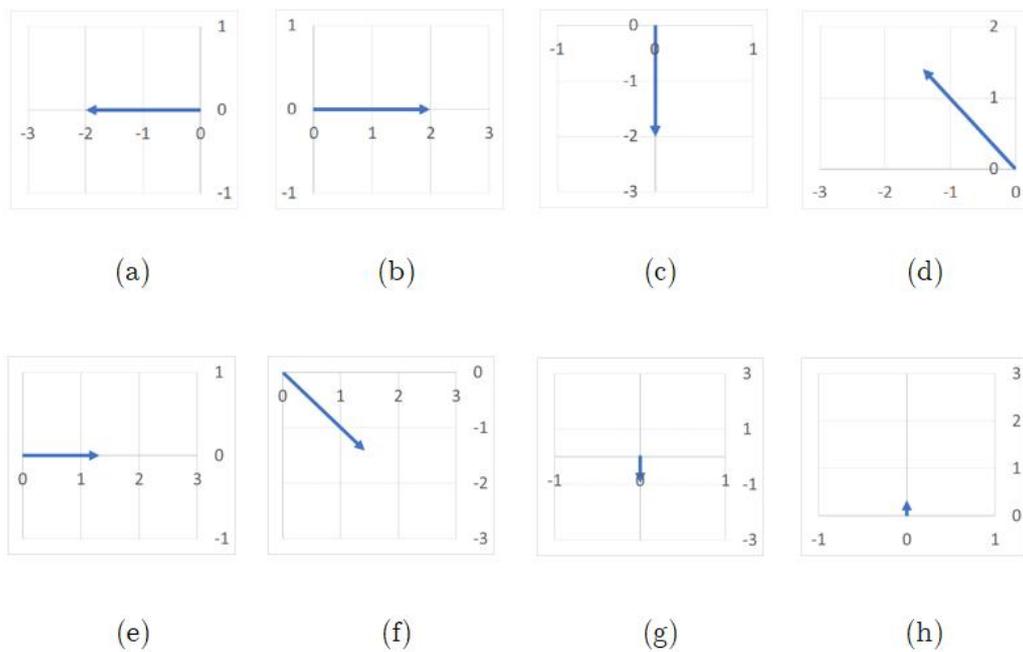


Figura 25 – Vetores de forças das matrizes de preferências de cenários homogêneos.

A Figura 26 mostra um exemplo de cenário gerado pelo modelo de propagação de incêndios estudado. A configuração que resultou nesse cenário emprega $LQ = 3$, $LR = 30$ e a matriz de preferências $W_{3 \times 3}$ apresentada na Figura 24(a). Como a maior preferência ($v_{max}=1$) é da célula posicionada a leste na vizinhança (VL), significa que a chance da chama se propagar dessa célula para o centro é a maior possível e, portanto, essa matriz representa um vento que sopra para oeste, ou seja, que propaga o incêndio da direita para

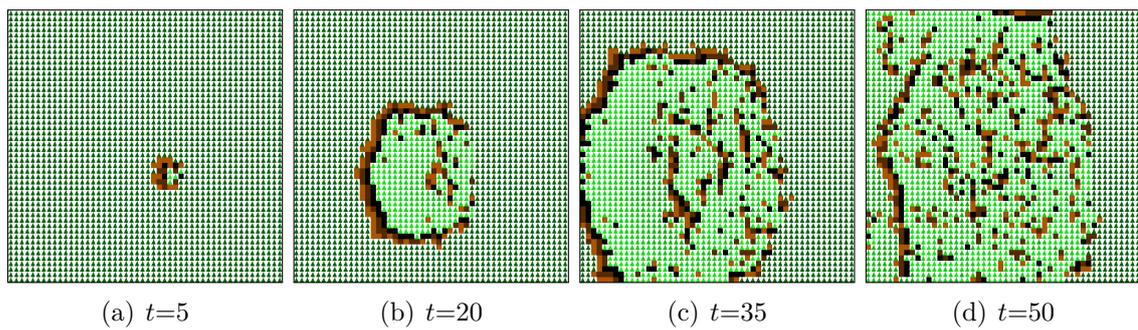


Figura 26 – Cenário homogêneo com o vento na direção oeste.

a esquerda do reticulado. A força vetorial mostrada na Figura 25(a) representa a direção do vento e sua intensidade, nesse caso é 2.0.

Ao rotacionar a matriz de preferências, é possível alterar o sentido do vento, de acordo com a rosa dos ventos. Na Figura 27, é apresentado cenário, em que a propagação do incêndio ocorre na direção contrária (da esquerda para a direita), ou seja, no sentido leste do reticulado. A matriz que representa o vento na direção leste é mostrada a Figura 24(b) e sua força vetorial resultante é apresentada na Figura 25(b).

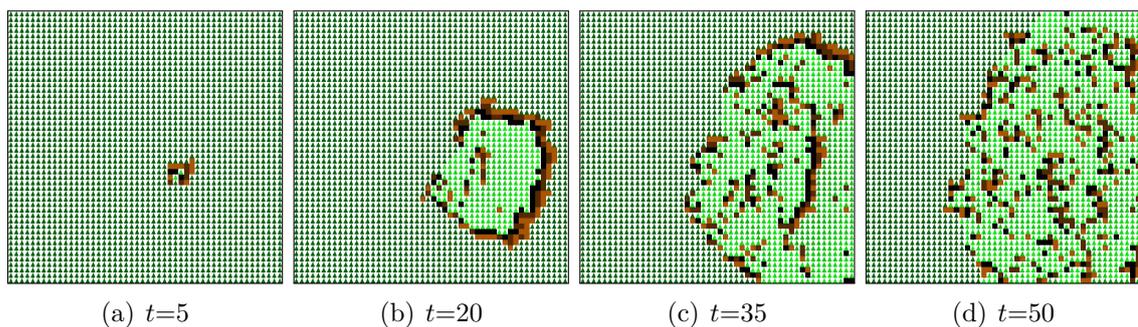


Figura 27 – Cenário homogêneo com o vento na direção leste.

A Figura 25(c) mostra o vetor resultante da matriz (presente na Figura 24(c)) que indica que o vento propaga do norte para o sul do reticulado. Essa evolução temporal é mostrada na Figura 28.

Outro exemplo de cenário possível é a propagação do fogo na diagonal. A força vetorial da Figura 25(d) demonstra que a direção do vento da matriz, mostrada na Figura 24(d), está para o noroeste. Conforme a evolução temporal presente na Figura 29, é possível perceber a propagação do fogo do para o noroeste do reticulado.

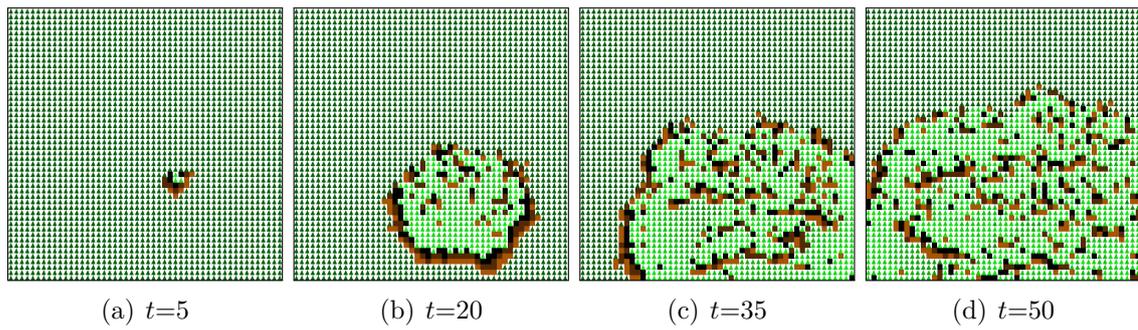


Figura 28 – Cenário homogêneo com o vento na direção sul.

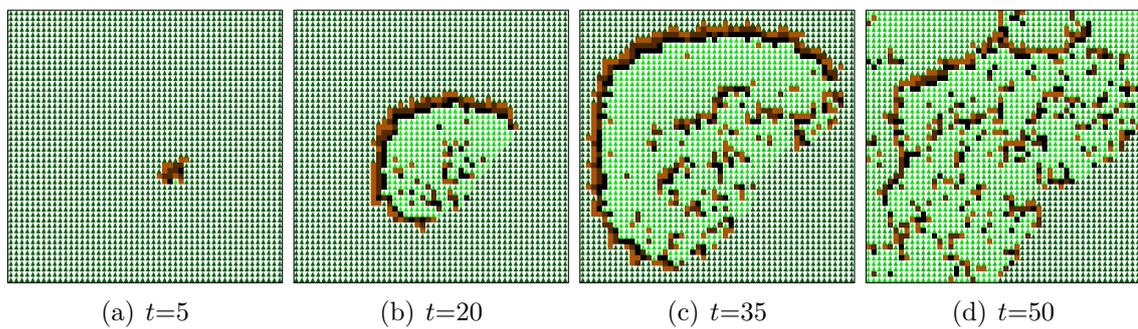


Figura 29 – Cenário homogêneo com o vento na direção noroeste.

4.3 Adaptação do Modelo para Cenários Heterogêneos

O modelo foi, posteriormente, modificado para considerar diferentes tipos de vegetações na área do reticulado (vegetações heterogêneas), sendo, assim, capaz de representar computacionalmente cenários mais próximos aos encontrados no bioma do cerrado. Basicamente, essa adaptação consiste em adotar um conjunto de parâmetros (LQ , LR e $W_{3 \times 3}$) para cada nova vegetação modelada. Nesta pesquisa, foram estudados modelos com até quatro tipos de vegetação. Isto é, além daquela usada no cenário homogêneo descrito anteriormente, foram criadas configurações hipotéticas para representar outras três vegetações com características distintas, conforme apresentado na Tabela 1.

Vegetação	Matriz			LQ	LR
1 (Base)	0.142	0.488	0.900	3	30
	0.003	0.000	0.987		
	0.206	0.500	0.881		
2	0.067	0.250	0.450	2	90
	0.006	0.000	0.500		
	0.039	0.241	0.405		
2	0.009	0.437	0.550	6	20
	0.010	0.430	0.749		
	0.058	0.299	0.500		
4	0.000	0.099	0.104	8	60
	0.000	0.000	0.255		
	0.081	0.024	0.200		

Tabela 1 – Valores das vegetações usadas nos cenários heterogêneos.

A Figura 30 mostra os vetores de força resultantes das matrizes de preferências adotadas para as vegetações apresentadas na Tabela 1. Como pode ser observado, o vento tem a mesma direção em todos os tipos de vegetação, mas com intensidades diferentes. Embora o modelo permita representar direções de vento distintas entre as vegetações, entende-se que essa propriedade não é influenciada pelo tipo de vegetação, mas por outros fatores geográficos (ex: pressão atmosférica) que estão fora do escopo deste trabalho.

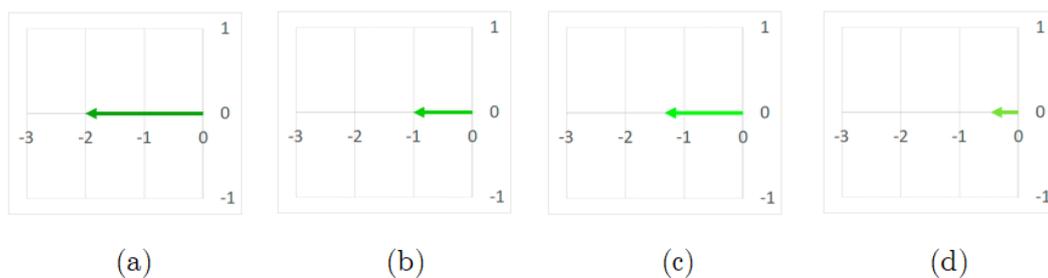


Figura 30 – Vetores representando o vento dos cenários heterogêneos.

Comparando os valores dos parâmetros da Veg2 com a vegetação base (Veg1), é possível notar que ela queima por menos tempo ($LQ2 = 2$ contra $LQ1 = 3$) e demora mais recuperar ($LR2 = 90$ contra $LR1 = 30$). Por adotar valores mais baixos na matriz de preferências, o vento representado pela matriz da Veg2 também possui uma intensidade menor que o da Veg1 (1,0 vs. 2,0). Essa intensidade menor influencia diretamente na velocidade de propagação do incêndio, conforme demonstrado na Figura 31 mostra a propagação de incêndio em um cenário heterogêneo formado por esses dois tipos de vegetação, sendo a Veg1 na parte inferior e a Veg2 na parte superior do reticulado.

A intensidade do vento resultante da matriz de preferências da Veg3 é de 1,5, conforme

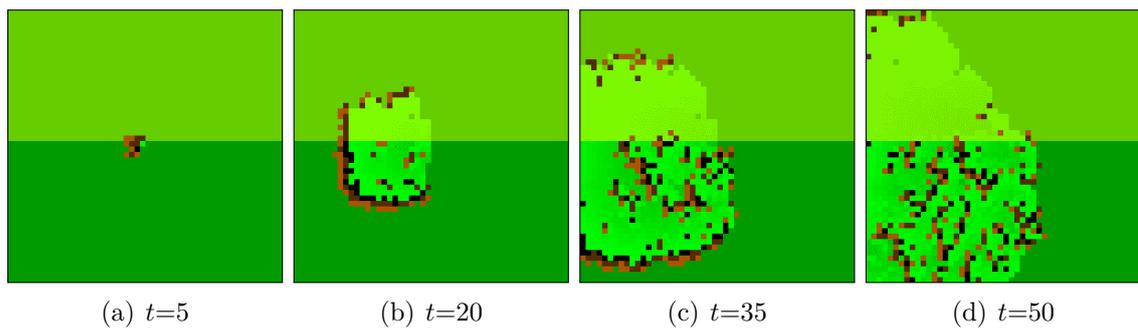


Figura 31 – Cenário heterogêneo com dois tipos de vegetação.

apresentado na Figura 30(c). Essa intensidade do vento faz com que esse espalhamento não seja tão rápido quanto a Veg1. Os valores de LQ e LR influenciam para que essa vegetação queime mais (as células do tipo Fogo permanecem nesse estado por mais tempo) e se recupere mais rápido, ou seja, acumula material orgânico mais facilmente. A Figura 32 mostra o comportamento do incêndio em um cenário heterogêneo com os três tipos de vegetação.

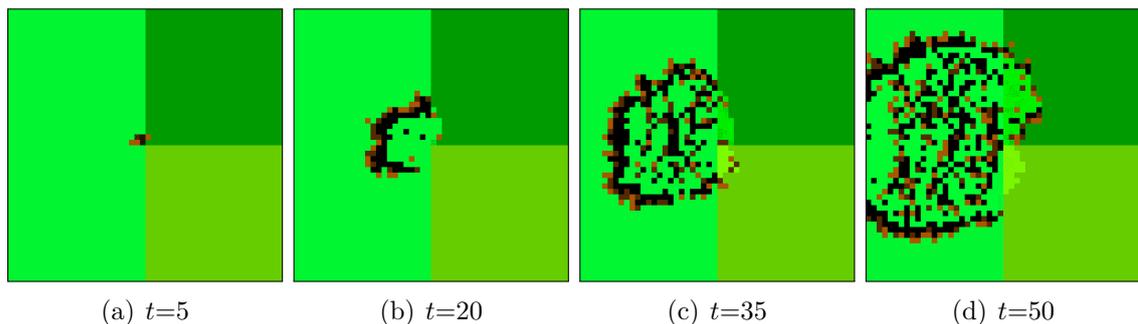


Figura 32 – Cenário heterogêneo com três tipos de vegetação.

Por fim, a Veg4 possui a matriz de preferências que representa o vento com a menor intensidade (cerca de 0,5), conforme o vetor de forças apresentado na Figura 30(d). Ela também apresenta o maior tempo de queima ($LQ = 8$) e a segunda recuperação mais lenta ($LR = 60$), sendo melhor apenas que a Veg2. Essa configuração propicia uma característica interessante para a vegetação, pois apesar de queimar por mais tempo, a baixa intensidade do vento e o maior tempo de recuperação fazem com que a propagação de incêndios em áreas com esse tipo de vegetação seja mais difícil. A Figura 33 mostra um cenário heterogêneo, onde o incêndio é iniciado na intersecção entre as quatro vegetações modeladas (ponto central do reticulado).

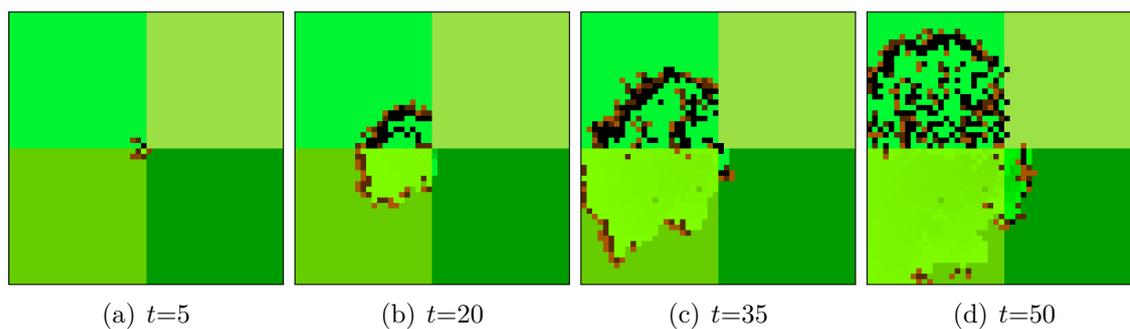


Figura 33 – Cenário heterogêneo com quatro tipos de vegetação.

Com a inclusão de novas vegetações, também aumenta a quantidade de parâmetros do modelo e, conseqüentemente, a complexidade de encontrar seus valores para reproduzir, de forma adequada, o comportamento dos dados coletados a partir de incêndios florestais. No Capítulo 5 é apresentada a abordagem evolutiva desenvolvida neste trabalho para ajustar os parâmetros do modelo de propagação de incêndio em áreas com um ou mais tipos de vegetação.

Abordagem Evolutiva Proposta

Nesta pesquisa foi desenvolvida uma busca, baseada em algoritmo genético (AG), a fim de especificar os valores dos parâmetros do modelo de propagação de incêndios, descrito no Capítulo 4, de forma a se obter uma simulação bastante próxima ao comportamento observado a partir de dados de incêndios em áreas florestais. Em uma etapa inicial, diferentes especificações do AG foram avaliadas até se chegar a uma configuração eficiente para o problema, a qual é apresentada a seguir.

5.1 Representação de Indivíduo

O ajuste do modelo de propagação de incêndios consiste em determinar valores para os parâmetros que configuram cada tipo de vegetação presente no ambiente de simulação (cenário), o qual é uma representação da área estudada. Como apresentado anteriormente, nesta pesquisa investigou-se cenários com até quatro tipos distintos de vegetação. Para cada uma, os principais parâmetros extraídos do modelo de propagação de incêndios e que devem ser especificados pelo AG são: LQ (tempo máximo de queima), LR (tempo máximo de recuperação) e os valores das oito células vizinhas que compõem a matriz de preferências, representando a direção e intensidade do vento.

Portanto, em nossa abordagem, um indivíduo (cromossomo) do AG é representado por um arranjo de N elementos, sendo N a quantidade de vegetações representadas na simulação, ou seja, um valor entre $[1,4]$. Por sua vez, cada elemento é composto por dez campos (genes), sendo oito valores reais e dois valores inteiros. Os campos reais são relativos às oito posições da matriz de preferências (NO, N, NE, O, L, SO, S, SE) e armazenam um valor entre $[0, 1]$, com uma precisão de 3 casas decimais. Os campos inteiros representam, respectivamente, os parâmetros LQ e LR. Enquanto LQ é limitado ao intervalo de 1 a 10, LR varia de 1 a 100.

No contexto de cenários homogêneos, isto é, com um único tipo de vegetação, o cromossomo é composto por dez genes: 8 genes que formam a matriz de preferências e 2 genes que representam respectivamente LQ e LR. A Figura 34 mostra a representação gráfica do

No contexto de cenários homogêneos.

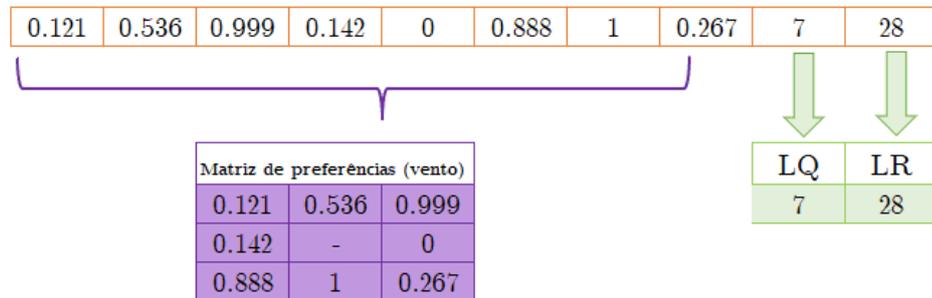


Figura 34 – Representação do Indivíduo do AC para um modelo com uma única vegetação.

Em cenários heterogêneos, o número de genes varia de acordo com a quantidade de vegetações representadas. Por exemplo, em ambientes com duas vegetações, o cromossomo tem 20 genes, 10 para cada tipo de vegetação, conforme ilustrado na Figura 35. Analogamente, as configurações dos cenários com 3 e 4 vegetações são representados por cromossomos com 30 e 40 genes, respectivamente. As Figuras 36 e 37 ilustram a composição desses indivíduos.

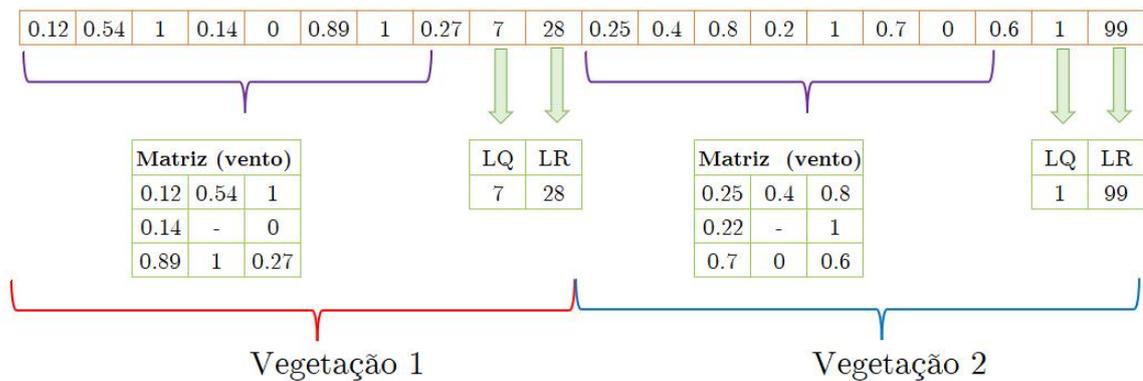


Figura 35 – Representação do Indivíduo do AC heterogêneo com duas vegetações.

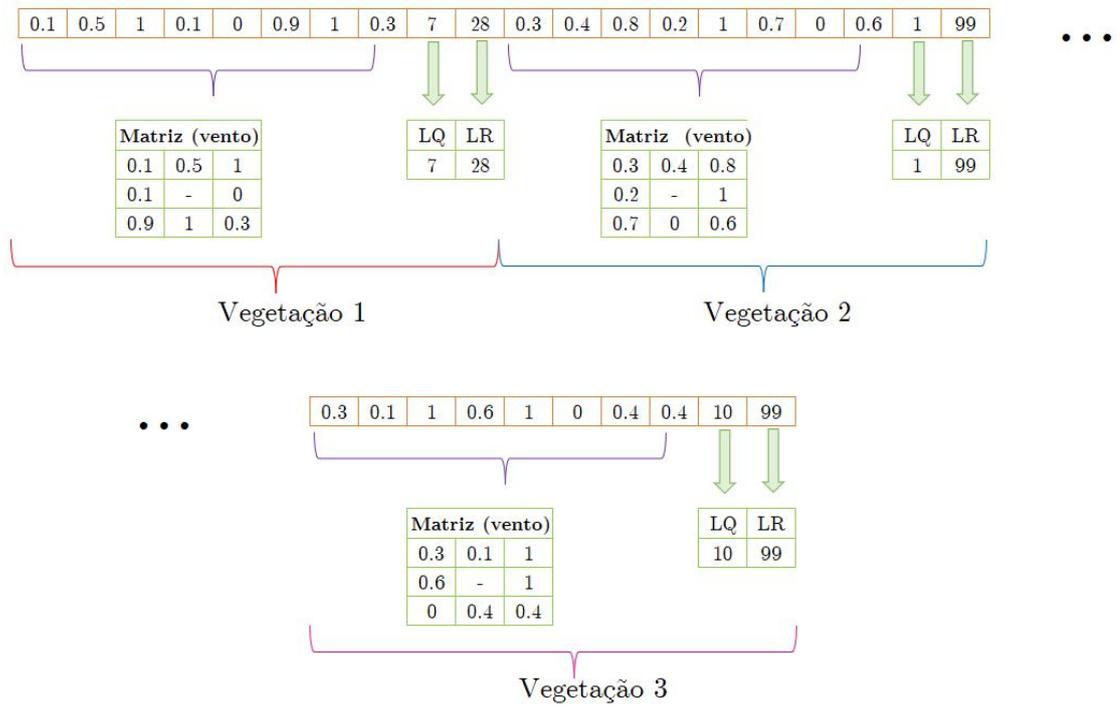


Figura 36 – Representação do Indivíduo do AC heterogêneo com três vegetações.

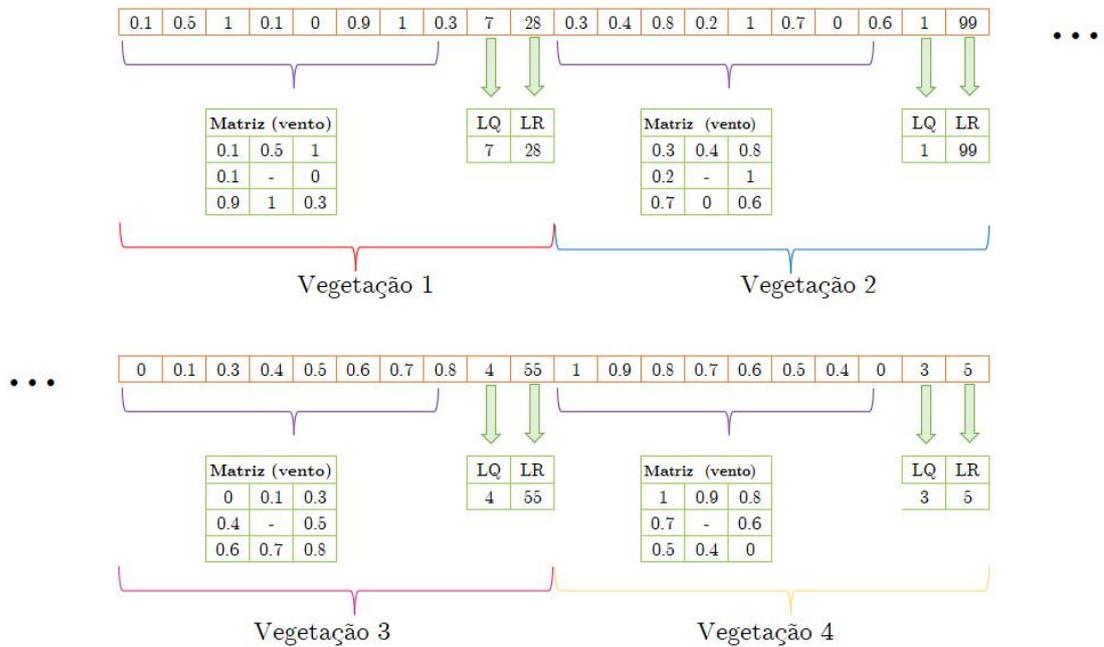


Figura 37 – Representação do Indivíduo do AC heterogêneo com quatro vegetações.

5.2 Função de Avaliação

O cálculo da aptidão de cada indivíduo da população começa com a simulação do modelo de propagação de incêndio, configurado com os parâmetros definidos pelo cromossomo. Então, a evolução do incêndio observada nos reticulados ao longo do tempo é comparada, imagem a imagem, com o conjunto de 50 reticulados presentes na base de referência referente ao cenário escolhido. Neste trabalho, cada execução do modelo consiste na evolução do autômato celular por 10.000 passos de tempo. A cada 200 passos de evolução temporal do modelo do AC (configurado com os parâmetros do indivíduo), uma imagem do progresso do incêndio é capturada como reticulado, resultando nos 50 reticulados analisados por cada indivíduo. Devido a indisponibilidade de dados reais de incêndios, esse mesmo processo também foi usado para gerar os dados artificiais de referência utilizados nos experimentos. Entretanto, para a base de referência, adotou-se os valores dos parâmetros de cada vegetação definida no Capítulo 4 (Tabela 1).

A série de reticulados associada ao indivíduo é então pareada com a base de referência investigada (um par para cada um dos 50 instantes capturados) e o indivíduo é avaliado, basicamente, pela diferença na quantidade de células no estado *Fogo* a cada par de reticulados (indivíduo, referência), tanto em cenários homogêneos, quanto heterogêneos.

5.2.1 *Fitness* Homogêneo

Em uma etapa inicial de nossos experimentos, uma avaliação ingênua era dada pela simples somatória das diferenças na quantidade de células *Fogo* calculadas nos 50 instantes de captura. Entretanto, dois requisitos se mostraram importantes para uma boa avaliação dos indivíduos: considerar a distribuição espacial das diferenças e buscar atenuar a característica estocástica da simulação, em que cada simulação resulta em uma série de 50 reticulados diferentes.

Para atender ao primeiro requisito, o reticulado é dividido em sub-regiões de mesmo tamanho (partições) e a diferença na quantidade de células *Fogo* é calculada por partição separadamente, considerando todo o conjunto de reticulados (diferença por partição nos 50 instantes). Então, a avaliação do indivíduo é dada pela média das diferenças calculadas para todas as partições. Nesse contexto, a aptidão de um indivíduo do AG pode ser formalizada como:

$$DPart = \frac{\sum_{j=1}^Q \sum_{i=1}^{50} Indi_{ij} - Ref_{ij}}{Q} \quad (8)$$

$$Fit = \sum_{k=1}^5 \overline{DPart_k} \quad (9)$$

em que *Indi* e *Refi* são as quantidades de células do tipo *Fogo* no instante *i*, *Q* o número de partições e *DPart* é a diferença entre calculada para as partições *Q*.

Em uma etapa inicial dos experimentos, a avaliação de um indivíduo, chamada de

$Fit1R$, era dada pela simples somatória das diferenças na quantidade de células *Fogo* calculadas nos 50 instantes de captura. O cálculo de $Fit1R$ é dado por:

$$Fit1R = Ind_i - Ref_i \quad (10)$$

sendo, Ind_i e Ref_i as quantidades de células do tipo *Fogo* no reticulado i , considerando a simulação do modelo a partir dos parâmetros do indivíduo do AG e os dados de referência, respectivamente.

Posteriormente, a fim de considerar a distribuição espacial do reticulado, investigou-se a adoção de uma avaliação regional, na qual cada reticulado é dividido em sub-regiões de mesmo tamanho, chamadas neste trabalho por partições, e as diferenças são computadas por partição, considerando todos os reticulados analisados. Por fim, a aptidão do indivíduo é dada pela média aritmética das diferenças das partições. Neste trabalho, foram investigadas três variações na quantidade de partições por reticulado. Na primeira delas, cada reticulado é dividido em quatro partições, como em um plano cartesiano bidimensional. Essa forma de avaliação, denominada $Fit4P$, pode ser obtida por:

$$Fit4P = \frac{\sum_{q=1}^4 \sum_{i=1}^{50} Ind_{iq} - Ref_{iq}}{4} \quad (11)$$

Na segunda variação, em o reticulado é dividido em nove partições e a diferença na quantidade de células *Fogo* é calculada para cada partição, considerando todos os 50 reticulados analisados. Essa avaliação é chamada de $Fit9P$ e pode ser calculada por:

$$Fit9P = \frac{\sum_{q=1}^9 \sum_{i=1}^{50} Ind_{iq} - Ref_{iq}}{9} \quad (12)$$

Por fim, implementou-se o *fitness* individualizado que calcula a diferença de células com fogo nos 50 reticulados para cada célula.

Durante os experimentos, avaliou-se a precisão da função de aptidão considerando diferentes quantidades de partições, sendo que a divisão do reticulado em 9 partes, fazendo uma analogia à rosa dos ventos, foi a que retornou os melhores resultados (menores erros).

5.2.2 *Fitness* Heterogêneo

O *fitness* 9P mostrou-se mais eficiente para o cenário homogêneo e, portanto, também foi utilizado nos cenários com mais de uma vegetação. Entretanto, para lidar com a heterogeneidade presente nesses cenários, optou-se por calcular o $Fit9P$ para cada vegetação individualmente. Após o cálculo individual, os valores de *fitness* são normalizados, usando min-max e a aptidão do indivíduo é obtida a partir da média aritmética do *fitness* normalizado de cada vegetação.

5.3 Configuração do AG

O algoritmo genético implementado neste estudo possui uma população inicial é formada por 100 indivíduos, os quais são gerados aleatoriamente, respeitando os intervalos preestabelecidos para cada gene ($[0,1]$ para os genes referentes às matrizes de preferência, $[1,10]$ para os genes LQ, e $[1,100]$ para os genes LR). A seleção dos pais a cada geração é feita através de um torneio simples com *Tour* de 3, com uma taxa de *crossover* de 90%. Durante os experimentos, foram avaliados três tipos de operadores de recombinação: o *crossover* de dois pontos de corte, o *crossover* uniforme e o *crossover* aritmético.

No *crossover* de dois pontos de corte, dois pontos distintos são selecionados aleatoriamente. Para a definição da máscara do *crossover* uniforme, um vetor binário de mesmo tamanho que o indivíduo é gerado aleatoriamente, o valor 0 corresponde ao primeiro pai e o 1 corresponde ao segundo. Por fim, no *crossover* aritmético, o valor de β é definido por um sorteio.

A mutação é aplicada sobre o cromossomo dos filhos gerados a partir da recombinação, a uma taxa de 20%. Uma vez definido que um indivíduo sofrerá mutação, escolhe quais genes serão alterados. Foram avaliadas duas técnicas para a escolha dos genes: o sorteio do gene e uso de máscara. A primeira abordagem consiste em definir, por meio de sorteio, quais os genes sofrerão mutação. Para definir a máscara, é utilizado uma estratégia semelhante a do *crossover* uniforme, em que sorteia-se um vetor binário de tamanho do cromossomo. Caso o valor seja 0, o gene não sofrerá mutação, e caso o valor seja 1, o gene é mutado. Cada gene selecionado é então submetido ao operador de mutação, que consiste em adicionar um valor aleatório ao parâmetro. Para os parâmetros inteiros, (LQ e LR), o valor do parâmetro é submetido a um incremento ou decremento unitário, enquanto que para os parâmetros reais, correspondentes às matrizes de preferências, o valor adicionado varia entre $[-0,2; 0,2]$.

A seleção dos indivíduos que sobreviverão é feita pelo método de reinserção pura com elitismo de 25%. Isto é, ao final de cada geração, seleciona-se com base nas aptidões (*fitness*), os 25 melhores pais (indivíduos da população corrente) e os 75 melhores filhos (indivíduos gerados a partir dos operadores de recombinação e mutação). O algoritmo genético evolui por 100 gerações (critério de parada).

Experimentos e Análise dos Resultados

Neste capítulo são descritos os experimentos realizados para validar a eficiência da estratégia evolutiva desenvolvida para o ajuste automático dos parâmetros usados nos modelos de propagação de incêndios baseados em regras de autômatos celulares. A Seção 6.1 descreve o uso das bases de dados. A Seção 6.2 descreve a metodologia experimental adotada nesta pesquisa. A partir de uma versão inicial do algoritmo genético, implementada em JavaScript, experimentos preliminares foram realizados com o intuito de escolher uma boa configuração de seus hiperparâmetros do AG e selecionar a função de avaliação e os operadores genéticos que resultaram nas melhores simulações (menor erro) para o cenário de incêndio investigado. Em seguida, avaliou-se o desempenho da abordagem desenvolvida, considerando diferentes cenários homogêneos e heterogêneos. Por fim, realizou-se um estudo mais profundo do comportamento das simulações, bem como analisou-se a sensibilidade do AG às perturbações nos parâmetros do modelo.

6.1 Uso de Bases de Dados

Na etapa inicial do trabalho foram utilizadas bases de dados artificiais geradas por simulações de incêndios, utilizando-se os modelos (FERREIRA et al., 2022b), (LIMA; LIMA, 2014) e (TINOCO et al., 2022) com diferentes configurações de parâmetros, a fim de obter diferentes cenários de incêndios. Dessa forma, é possível avaliar a capacidade do AG em especificar um conjunto adequado de parâmetros, a partir de sequências temporais de reticulados, que representem as imagens capturadas da área durante a evolução de um incêndio. Para cada cenário avaliado, o modelo foi configurado com um conjunto de parâmetros específico que foi simulado para gerar uma base com 50 reticulados que representam a evolução temporal do incêndio, simulando uma base de imagens tomadas em 50 intervalos de tempo. Cada intervalo de tempo corresponde a 200 passos de evolução do autômato celular. Cada conjunto de 50 reticulados registrados (simulação representativa de cada cenário de incêndio) é chamado de base de reticulados de referência, ou simplesmente, base de referência, conforme mostrado na Figura 38.

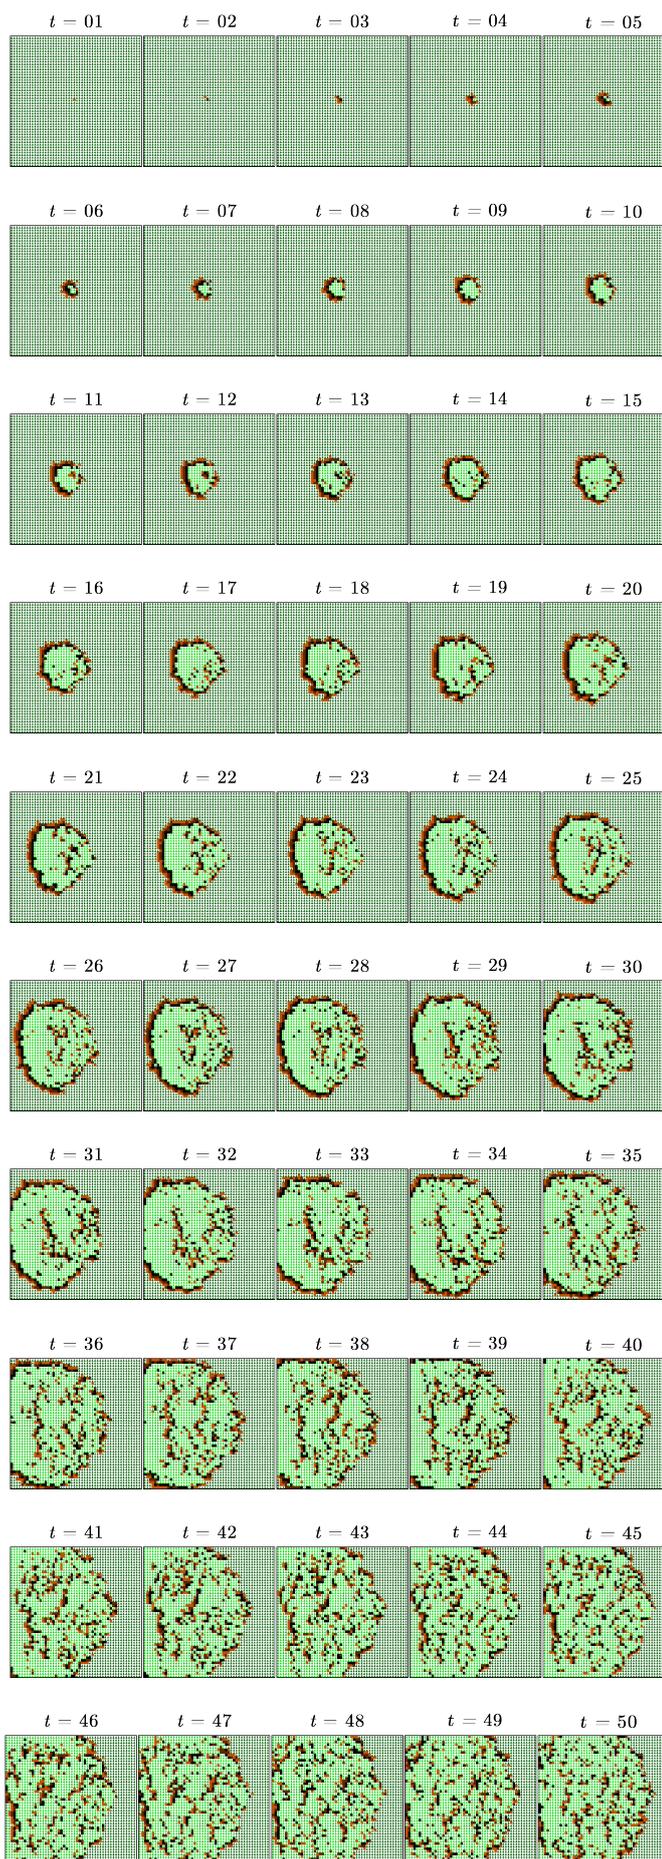


Figura 38 – Evolução temporal completa de um incêndio simulado a partir do autômato celular com o vento para o oeste.

Essa figura ilustra uma evolução temporal completa do AC. As Figuras 26, 27, 28 e 29 apresentadas no Capítulo 4 ilustram a evolução temporal de quatro simulações diferentes. Em cada simulação ilustrada foi utilizado um conjunto diferente de parâmetros, resultando em quatro cenários de simulação distintos. Cada figura apresenta as configurações do reticulado (estados das células representados por cores) em quatro instantes da simulação ($t= 5, 20, 35$ e 50), dentre os 50 passos de tempo, para que se possa observar a evolução do reticulado ao longo da evolução temporal do AC.

Para lidar com a estocasticidade da simulação, deixando a abordagem evolutiva menos suscetível a eventuais enviesamentos nos dados gerados a partir das simulações do modelo de referência, adotou-se a seguinte estratégia: Para cada cenário, a base de referência armazena o valor de cada célula a cada passo de tempo para uma simulação completa. Além dessa execução, foram realizadas 100 execuções a cada cenário e foram registradas as quantidades médias de células *Fogo* em cada partição, considerando-se as 100 execuções, para cada um dos 50 reticulados registrados. No cálculo das diferenças entre cada simulação e a referência, é considerada a diferença entre o valor médio obtido nas 100 execuções de referência e o valor obtido a cada simulação do indivíduo.

6.2 Método para a Avaliação

Durante a pesquisa, avaliou-se a capacidade do algoritmo em evoluir os valores dos parâmetros de forma parcial (apenas LQ e LR ou apenas a matriz de preferências) e completa. Nas evoluções parciais, os demais parâmetros eram fixados com os valores de referência usados na geração da base de dados do cenário a ser simulado. Os resultados parciais foram importantes para o refinamento do algoritmo genético, pois permitiram identificar eventuais dificuldades da abordagem em cada experimento. Entretanto, considerando que o objetivo é avaliar a capacidade da abordagem evolutiva em ajustar adequadamente os parâmetros do modelo de incêndio baseado em AC, neste capítulo serão apresentados apenas os resultados alcançados a partir da evolução completa do conjunto de parâmetros.

Para cada experimento, o algoritmo genético foi executado dez vezes e o melhor indivíduo encontrado (conjunto de parâmetros que retorna o menor erro médio) é usado para configurar o modelo de simulação para o cenário de incêndio investigado. Durante a evolução do AG, os indivíduos da população são reavaliados a cada geração. Como o autômato celular é estocástico, simulações com os mesmos valores de parâmetros resultam em evoluções temporais diferentes. Assim, na avaliação de cada indivíduo são realizadas cinco simulações diferentes utilizando os valores de parâmetros especificados no cromossomo, obtendo o valor médio. Além disso, para a geração da base de referência, o autômato celular foi executado 100 vezes e um valor médio de células de fogo foi obtido. Assim, foi possível reduzir o ruído decorrente da estocasticidade do autômato celular probabilístico.

Como configuração padrão do AG, a população inicial de 100 indivíduos foi gerada

aleatoriamente. Para a seleção de pais, o torneio simples com *tour* de 3 foi utilizado. O *crossover* utilizado foi o de dois pontos de corte com taxa de 90%. Na mutação, um valor aleatório era adicionado ao gene do cromossomo, também escolhido de forma aleatória. A taxa de mutação utilizada foi de 20%. Para reinserção dos indivíduos na população, foi utilizado o elitismo de 25%. O critério de parada foi o número máximo de gerações, nesse caso, 100.

Para avaliar o desempenho da abordagem evolutiva, comparou-se os dados obtidos a partir do melhor conjunto de parâmetros encontrado pelo algoritmo genético, em cada cenário testado (homogêneo e heterogêneo), e aqueles gerados com a configuração do modelo de referência para os respectivos cenários. Nessa análise comparativa, considerou-se os seguintes aspectos: a) os valores dos parâmetros (LQ, LR e os valores usados na matriz de preferências); b) os vetores de forças resultantes das respectivas matrizes de preferências, os quais representam a direção e a intensidade do vento que impulsiona o fogo; c) a semelhança entre o comportamento do incêndio simulado e aquele observado nos dados de referência, a partir da comparação visual dos reticulados (evolução temporal) do autômato celular nos instantes de tempo 5, 20, 30 e 50.

6.3 Experimentos Preliminares

Nessa seção são apresentados os experimentos iniciais realizados para guiar as decisões do projeto do algoritmo evolutivo descrito no Capítulo 5, de modo a aprimorar sua capacidade em encontrar parâmetros que reproduzissem o comportamento do incêndio representado pelos dados de referência. Após experimentos que visaram a escolha dos valores para os hiperparâmetros do algoritmo genético, avaliou-se algumas variações dos operadores genéticos de *crossover* e mutação, bem como variações na forma de cálculo da função de aptidão. Nesta etapa, a base de dados utilizada como referência foi gerada pelo próprio modelo. Na construção dessa base de referência, foi utilizado um cenário com valores de LQ e LR iguais a 3 e 30, respectivamente. A matriz de preferências adotada, que é mostrada na Figura 39(a), representa vento com intensidade 2,0 ilustrado pelo vetor de forças da Figura 39(b).

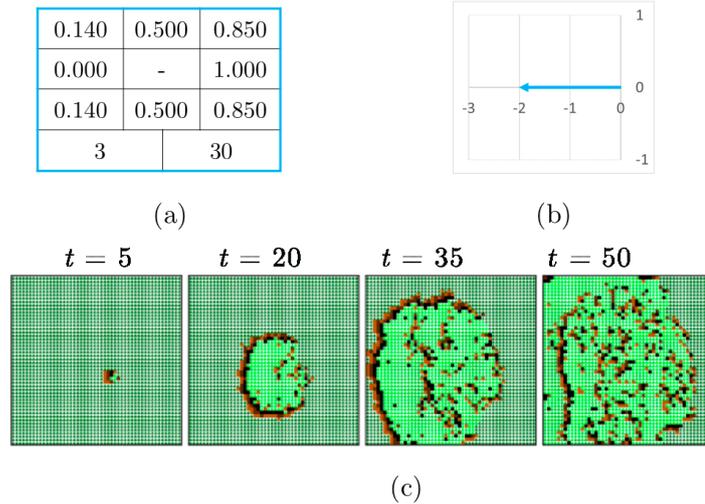


Figura 39 – Configuração usada como referência: (a) parâmetros; (b) força vetorial resultante dos valores da matriz de preferências que representa a direção a intensidade do vento; (c) evolução temporal da propagação de fogo.

A Figura 39(c) representa a evolução temporal da propagação das chamas neste cenário, considerando que o foco inicial do incêndio foi a célula do centro do reticulado do AC.

6.3.1 Definição da Função de Aptidão

Nesta subseção são apresentados os experimentos realizados para escolher a função de aptidão utilizada na avaliação dos indivíduos do algoritmo genético, visando aprimorar a qualidade da simulação gerada pelo autômato celular.

Neste trabalho foram avaliados quatro tipos diferentes de *fitness*, os quais variam basicamente pelo tamanho das sub-regiões do reticulado, usadas no cálculo da função de aptidão (Equação 9). No *Fit1R*, o reticulado inteiro é considerado e calcula-se a somatória simples das diferenças da quantidade de células *Fogo* nos 50 instantes de captura (Equação 10). No *Fit4P*, o reticulado é dividido em 4 sub-regiões de mesmo tamanho (Equação 11), chamada de partições, e as diferenças são calculadas por partições; a aptidão do indivíduo é calculada pela média aritmética das diferenças das partições. Em uma analogia à rosa dos ventos, o *Fit9P* subdivide o reticulado em nove partições (Equação 12). Por fim, no *fitness individualizado* as diferenças entre a quantidade de células *Fogo* é calculada levando em consideração cada célula do reticulado. O cenário homogêneo utilizado para a análise comparativa entre os *fitness* é descrito na Figura 39.

Como base nesse modelo de referência, cada variação da função de aptidão (1R, 4P, 9P e individualizado) foi avaliada e os resultados obtidos são apresentados na Tabela 2. Além da configuração e do valor de *fitness* do melhor indivíduo, essa tabela também apresenta os valores dos parâmetros de referência, o valor médio do *fitness* dos melhores indivíduos

encontrados nas 10 execuções do AG e o respectivo desvio padrão.

Tipo	Matriz de Preferências			LQ	LR	Melhor Fitness	Fitness Médio	Desvio Padrão
Valores de Referência	0.140	0.500	0.850	3	30	-	-	-
	0.000	-	1.000					
	0.140	0.500	0.628					
Fit1R	0.611	0.232	0.365	4	46	15.70	16.22	1.39
	0.260	-	0.955					
	0.560	0.842	0.519					
Fit4P	0.085	0.404	0.868	3	32	7.82	8.17	1.04
	0.138	-	0.854					
	0.168	0.386	0.990					
Fit9P	0.808	0.122	0.888	3	30	3.81	4.06	0.86
	0.000	-	0.961					
	0.044	0.628	0.821					
Fitness Individualizado	0.049	0.058	0.913	6	48	85.24	88.41	3.90
	0.204	-	0.990					
	0.121	0.748	0.860					

Tabela 2 – Resultados Obtidos nos experimentos de definição da função de aptidão.

Para facilitar a comparação entre as variações do AG, a Figura 40 mostra os parâmetros obtidos e vetor de forças resultante da matriz de preferências do melhor indivíduo encontrado para cada função de aptidão avaliada.

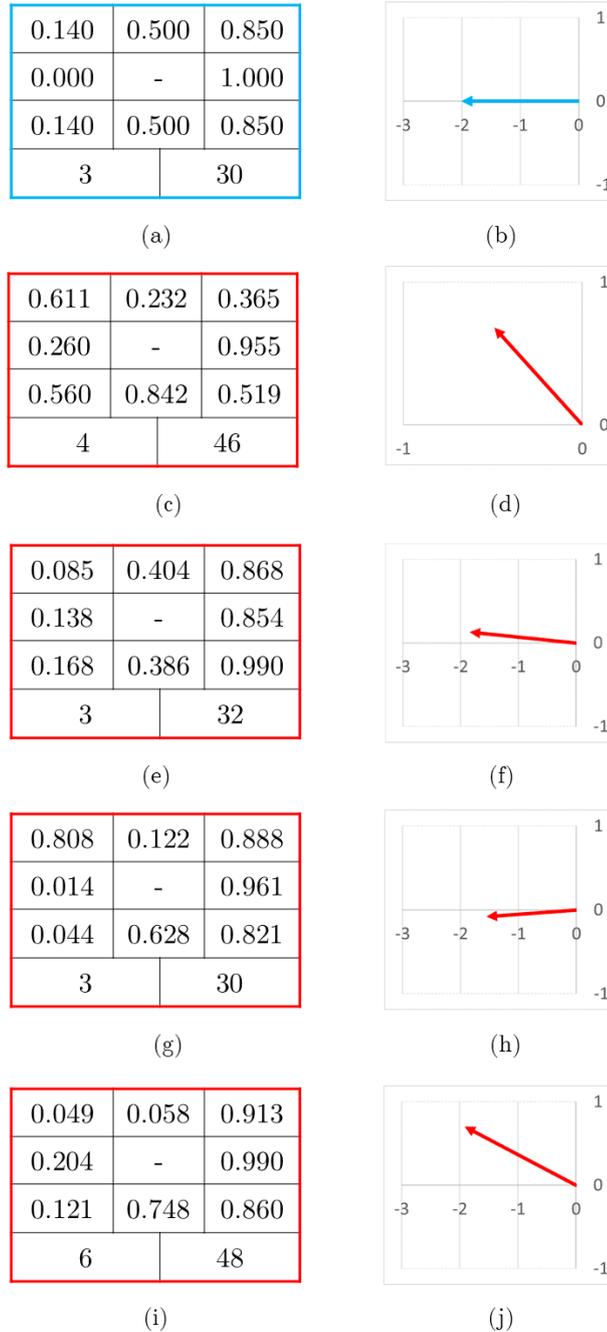
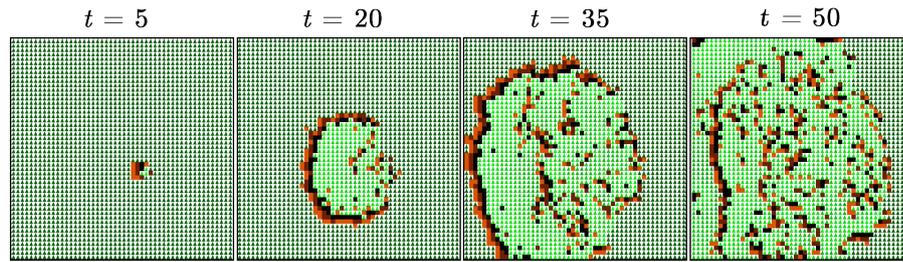
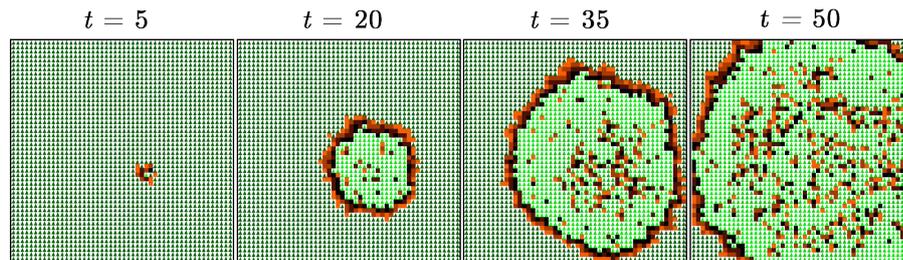


Figura 40 – Configurações encontradas pelo algoritmo genético e os respectivos vetores de força que representam a intensidade e direção dos ventos modelados, de acordo com a função de aptidão adotada: cenário de referência ((a) e (b)); reticulado único ((c) e (d)); 4 partições ((e) e (f)); 9 partições ((g) e (h)); e células individuais ((i) e (j)).

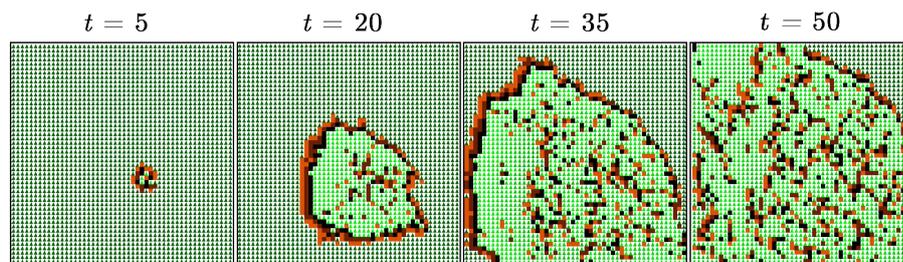
Também são apresentados os reticulados resultantes das simulações com cada conjunto de parâmetros (Figura 41), possibilitando verificar o impacto do *fitness* no comportamento do incêndio.



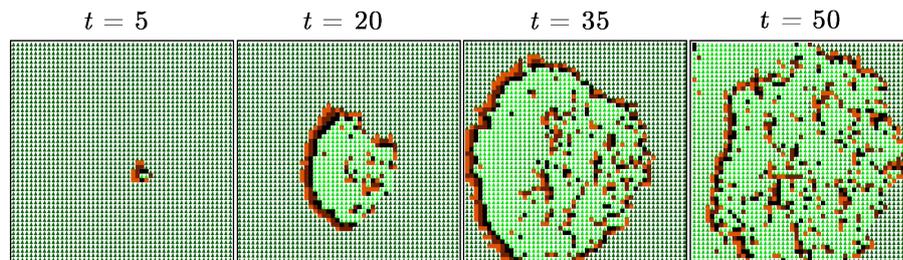
(a) Referência



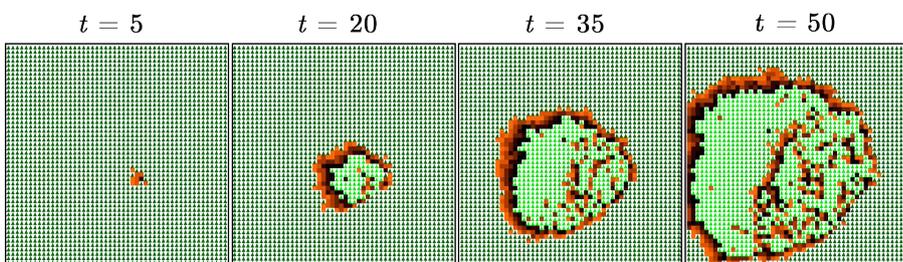
(b) 1R



(c) 4P



(d) 9P



(e) Individualizado

Figura 41 – Evolução temporal de um incêndio simulado a partir do autômato celular configurado com os parâmetros encontrados pelo algoritmo genético, de acordo com a função de aptidão: (a) referência; (b) reticulado único (1R); (c) 4 partições (4P); (d) 9 partições (9P); e (e) células individuais.

No *Fit1R* a diferença média das células *Fogo* é calculada considerando o reticulado inteiro. Na Figura 40 são mostrados os valores obtidos pelo melhor indivíduo, com menor erro, em 10 execuções do AG (Figura 40(c)) e a força vetorial obtida a partir de sua matriz de preferências (Figura 40(d)). Considerando as 10 execuções do AG considerando esse *fitness* (única região, considerando todas as células do reticulado), o melhor indivíduo encontrado obteve uma aptidão de 15,70, o *fitness* médio foi de 16,22, com desvio padrão de 1,39. É possível notar, analisando a Figura 40(d) que a matriz obtida pelo AG gera um vento com intensidade 0,8 direção para o noroeste do reticulado, enquanto a matriz de referência (Figura 40(a)), representa um vento na direção oeste e intensidade de 2. Além disso, o melhor indivíduo do AG (Figura 40(c)) também resultou em tempos maiores de queima (LQ=4) e de recuperação (LR=46), quando comparado com o modelo de referência (LQ=3 e LR=30). A Figura 41(a) mostra a propagação do incêndio simulado pelo autômato celular com os parâmetros de referência, enquanto a Figura 41(b) mostra a evolução das chamas quando adota-se os valores obtidos pelo AG. É possível perceber que o fogo se espalha mais lentamente no reticulado na simulação do modelo configurado a partir do AG. A definição de valores mais próximos e distribuídos de forma mais simétrica pelas posições da matriz de preferências do AG, resultou em uma propagação mais radial e um vento com menor intensidade. O maior valor de LQ faz com que as células passem mais tempo queimando. O comportamento do fogo é pouco similar, em relação a referência.

No *Fit4P*, o reticulado foi dividido em quatro partições e a diferença média de células de fogo em cada partição era comparada ao final de cada instante de tempo t entre indivíduo do AG e na base de referência. Após as 10 execuções do AG utilizando o *fitness* 4P, o melhor indivíduo encontrado obteve uma aptidão de 7,82, o *fitness* médio foi de 8,17, com desvio padrão de 1,04. A Figura 40(e) apresenta os valores obtidos pelo indivíduo com menor erro. A matriz obtida resultou em uma força vetorial com intensidade de 1,8 (40(f)). Destaca-se que a força vetorial obtida através da matriz é mais parecida com a referência, com direção para o oeste, mas com uma inclinação de 176° . O valor de LQ nesse *fitness* é 3, igual ao da referência. Já o valor de LR é 32, ou seja, ligeiramente maior que a referência. A Figura 41(c) apresenta a propagação do incêndio quando adota-se os valores de parâmetros definidos no melhor indivíduo encontrado pelo AG utilizando o *Fit4P*. É possível perceber que o padrão de propagação do fogo é semelhante ao da referência (Figura 41(a)), com o incêndio propagando predominantemente para o oeste do reticulado. A diferença no valor de LR interfere na recuperação das células, que demoram um pouco mais para se recuperar. Entretanto, a evolução temporal do autômato celular configurado pelo AG é semelhante ao comportamento observado no modelo de referência.

Em uma analogia à rosa dos ventos, para o cálculo do *Fit9P*, o reticulado foi dividido em nove partições e as médias da diferença das partições foi comparada com a referência. Na Figura 40(g) são apresentados os valores obtidos pelo indivíduo com menor erro, em 10 execuções do AG. A força vetorial obtida a partir dos valores da matriz de preferências é

mostrada na Figura 40(h) Diante das 10 execuções, o melhor indivíduo obteve um *fitness* foi de 3,81, o *fitness* médio de 4,06 e o desvio padrão de 0,86. Os valores encontrados para LQ e LR são os mesmos usados no modelo de referência (3 e 30, respectivamente). A matriz de preferências resultante também aponta para o oeste, com uma inclinação de 183° graus oeste, e apresenta uma intensidade do vento de 1,61, sendo, portanto, menor que a referência. A Figura 41(d) mostra a evolução temporal do AC configurado com os valores de parâmetros obtidos pelo AG. É possível perceber que o padrão de propagação do fogo também é para o oeste, como no modelo de referência (Figura 41(a)).

Por fim, o *fitness* individualizado, considera a diferença entre as células de fogo do indivíduo e da referência para cada célula do reticulado A aptidão do melhor indivíduo foi de 85,24, o *fitness* médio de 88,41 e o desvio padrão de 3,90, considerando as 10 execuções do AG ao utilizar este *fitness*. Na Figura 40(i) são mostrados os valores obtidos pelo melhor indivíduo, com menor erro e a força vetorial obtida a partir de sua matriz de preferências (Figura 40(j)). É possível perceber que a matriz obtida pelo AG gera um vento com intensidade menor (1,55), que sopra para o oeste do reticulado, com uma ligeira inclinação de 159 graus. Além disso, obteve-se um valor de LQ de 6, sendo o dobro do valor de referência. O valor de LR obtido é 48, ou seja, 1,6 vezes a referência (LR=30). O comportamento do incêndio simulado a partir dos parâmetros encontrados pelo AG é ilustrado na Figura 41(e). Nota-se que a intensidade menor e os valores da matriz resultam em uma propagação mais arredondada (radial). O maior valor de LQ faz com que as células passem mais tempo queimando, como observado através das bordas de fogo mais largas e avermelhadas na direção do vento (oeste). Portanto, no geral, o comportamento do fogo é pouco similar em relação ao modelo de referência.

Comparando o desempenho do AG em relação às quatro estratégias de avaliação, aquelas que dividem o reticulado em 4 e 9 partições foram as que alcançaram os melhores resultados. Dentre elas, optou-se pelo o *Fit9P*, porque, além de obter uma simulação com evolução temporal mais próxima ao modelo de referência com o fogo na direção oeste do reticulado, foi a única estratégia de avaliação a encontrar, em todos os experimentos, os mesmos valores de LQ e LR adotados no modelo de referência.

6.3.2 Seleção dos Operadores Genéticos

O objetivo principal deste experimento é testar outras configurações para o algoritmo genético, através de alterações em seus operadores genéticos, visando melhorar a qualidade das simulações resultantes. O *fitness* escolhido foi o 9P, em que o cálculo da diferença das células de fogo entre o indivíduo e a referência é feito considerando uma divisão do reticulado em nove partições, em analogia a rosa dos ventos.

Inicialmente, avaliou-se o impacto da adoção de outros operadores de *crossover* na qualidade das simulações geradas a partir da configuração sugerida pelo AG. Nessa etapa, em vez de usar o *crossover* de dois pontos de corte, foram utilizados dois outros tipos

de *crossover*: o uniforme e o aritmético. No *crossover* de dois pontos de corte, duas posições para cruzamento são escolhidas e as informações genéticas dos pais são trocadas. No *crossover* uniforme, uma máscara de bits aleatórios é gerada e a recombinação dos trechos de material genético dos pais é feita de acordo com essa máscara. Por fim, no *crossover* aritmético, os filhos são gerados através de operações aritméticas sobre os pais. Nesse trabalho, o valor de β é definido por um sorteio.

Como base nesse modelo de referência, cada variação do *crossover* (dois pontos de corte, uniforme e aritmético) foi avaliada e a Tabela 3 apresenta os resultados obtidos, incluindo o conjunto de parâmetros, valor de *fitness* do melhor indivíduo, o valor médio do *fitness* dos melhores indivíduos encontrados nas 10 execuções do AG e o desvio padrão.

Tipo de <i>Crossover</i>	Vento			LQ	LR	Melhor Fitness	Fitness Médio	Desvio Padrão
Dois Pontos de Corte	0.808	0.122	0.888	3	30	3.81	4.06	0.86
	0.014	-	0.961					
	0.044	0.628	0.821					
Uniforme	0.228	0.195	0.933	3	31	4.32	4.76	0.14
	0.406	-	0.807					
	0.051	0.427	0.880					
Aritmético	0.084	0.826	0.854	3	43	5.47	6.38	0.71
	0.757	-	0.990					
	0.720	0.270	0.750					

Tabela 3 – Resultados Obtidos nos experimentos de seleção do operador de *crossover*.

Na Figura 42 são apresentados os parâmetros obtidos e vetor de forças resultante da matriz de preferências do melhor indivíduo encontrado para cada *crossover*. O resultado do *crossover* de dois pontos de corte é o mesmo descrito para o *Fit9P* na subseção anterior e é reapresentado para facilitar a comparação.

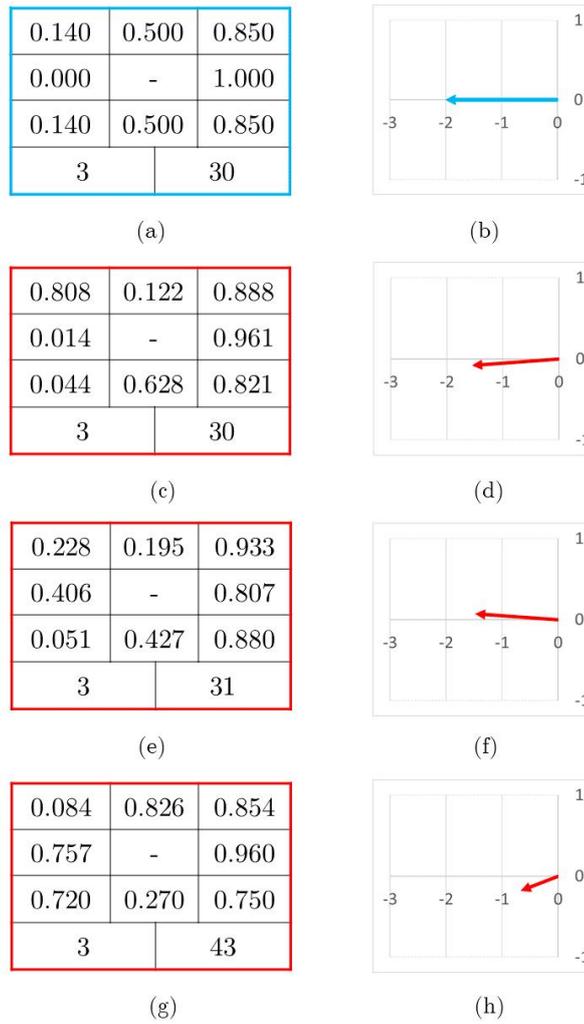
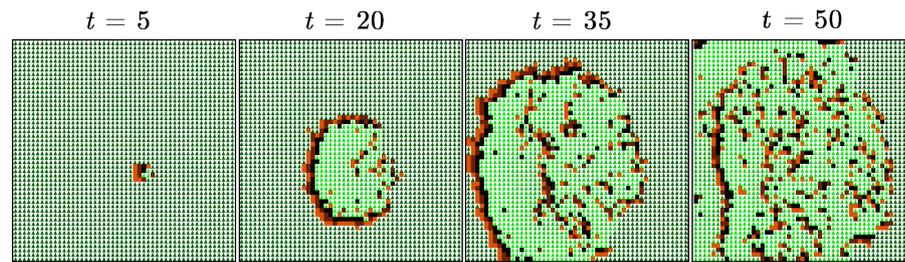
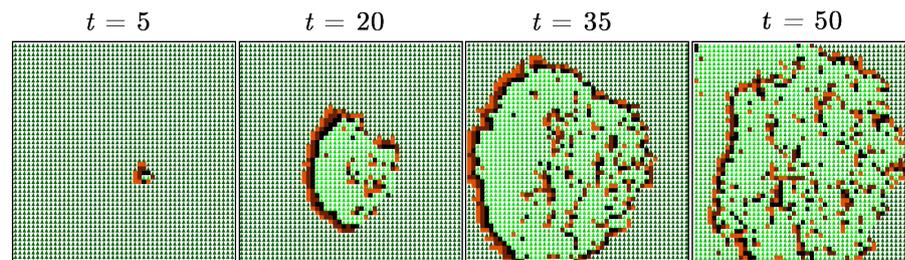


Figura 42 – Configurações encontradas pelo algoritmo genético e os respectivos vetores de força que representam a intensidade e direção dos ventos modelados, de acordo com o *crossover* adotado: cenário de referência ((a) e (b)); dois pontos de corte ((c) e (d)); uniforme ((e) e (f)); e aritmético ((g) e (h)).

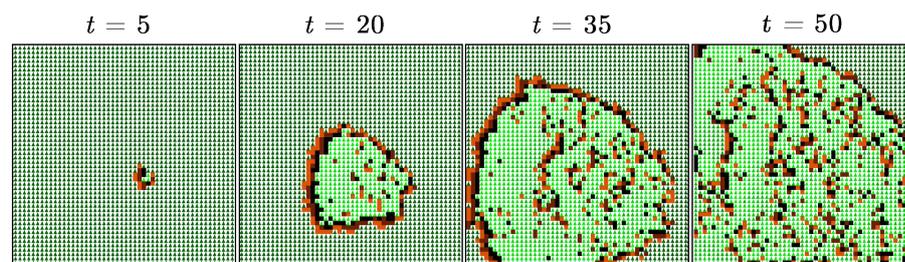
Para avaliar o impacto do método de *crossover* empregado no comportamento do incêndio, na Figura 43 são apresentados os reticulados resultantes das simulações com cada conjunto de parâmetros.



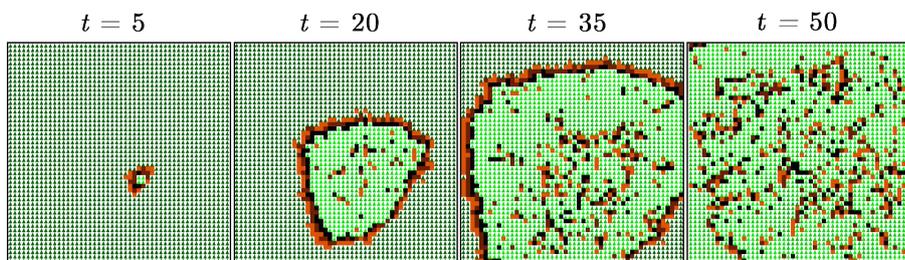
(a) Referência



(b) Dois Pontos de Corte



(c) Uniforme



(d) Aritmético

Figura 43 – Evolução temporal de um incêndio simulado a partir do autômato celular configurado com os parâmetros encontrados pelo algoritmo genético, de acordo com o *crossover*: (a) referência; (b) dois pontos de corte; (c) uniforme; (d) e aritmético.

Após as 10 execuções do AG, utilizando o *crossover* uniforme, o *fitness* do melhor indivíduo foi 4,2, enquanto o *fitness* foi 4,76, com desvio padrão de 0,14. Considerando a matriz de preferências obtida a partir do *crossover* uniforme (Figura 42(e)), as células com maior (canto superior direito) e menor (canto inferior esquerdo) valores indicam um vento na direção sudoeste. Entretanto, os demais valores da matriz foram definidos de modo a criar uma força para noroeste, buscando, assim, neutralizar a tendência para o

sul, sem afetar o direcionamento para oeste. Apesar desse esforço, o vetor de forças resultante (Figura 42(f)) apresenta um ângulo de inclinação de 177 graus. Por outro lado, a célula central direita da matriz tem o valor de 0,807, enquanto a sua oposta tem o valor de 0.406. Essa configuração afeta a intensidade do vento, resultando em um valor de 1,49, contra 1,61 do *crossover* de 2 pontos e 2,00 do modelo de referência (Figura 42(b)). Por fim, os valores de LQ e LR foram 3 e 31, ou seja, bem próximos dos valores de referência. Analisando a evolução temporal do AC, é possível perceber que tanto na referência (Figura 43(a)), tanto no *crossover* de dois pontos referência (Figura 43(b)) o fogo se espalha para o oeste do reticulado. Já na evolução com a configuração obtida pelo *crossover* uniforme por ter uma intensidade de vento menor, o incêndio se propaga mais para o leste do reticulado (Figura 43(c)).

Outra variação avaliada foi a utilização do *crossover* aritmético, resultando em um *fitness* de 5,47 para o melhor indivíduo, enquanto o *fitness* médio foi 6,38 e o desvio padrão foi 0,71. Os valores de LQ e LR são 3 e 43. A matriz de preferências obtida tem vários valores mais altos, conforme pode ser observado na Figura 42(g). As Figuras 42(b) e 42(h) apresentam, respectivamente, os vetores de forças que ilustram a intensidade e direção dos ventos representados nos modelos de referência e configurados com o AG usando *crossover* aritmético. Como pode ser observado, os valores encontrados pelo AG resultaram em um vento com intensidade bastante reduzida (0,79) e com um desvio de direção de 193 graus em relação à referência. Analisando as evoluções temporais das simulações de incêndio apresentadas na Figura 43, é possível perceber que o comportamento do autômato celular com os parâmetros obtidos pelo AG com o *crossover* aritmético (Figura 43(d)) é o menos semelhante à referência (Figura 43(a)). O fogo se espalha para o sul do reticulado, devido a maior inclinação do vetor do vento. Além disso, o fogo toma o reticulado por completo no último instante de tempo.

Dentre os três tipos de *crossover*, o de dois pontos de corte teve o melhor desempenho. Além de ter valores mais baixos para o *fitness* do melhor indivíduo e o *fitness* médio, foi o único *crossover* que obteve os valores de LQ e LR iguais à referência. Nas evoluções temporais, a configuração do AC com os parâmetros obtidos por esse *crossover* é a mais semelhante à referência e propagação das chamas se dá para o oeste do reticulado.

Após a escolha do tipo de *crossover*, foram avaliadas algumas variações nas operações de mutação. Nos experimentos anteriores, a mutação era realizada sorteando um valor aleatório entre -1 e 1 para ser adicionado a genes aleatórios. Nesse experimento, considerou-se a mutação com máscara, sorteando uma máscara binária para definir quais genes seriam mutados e um valor aleatório seria adicionado a esses genes. Uma suavização da mutação aleatória foi considerada, e o valor aleatório estava no intervalo -0,2 a 0,2.

A Tabela 4 apresenta os resultados obtidos, incluindo o conjunto de parâmetros, valor de *fitness* do melhor indivíduo, o valor médio do *fitness* dos melhores indivíduos encontrados nas 10 execuções do AG e o desvio padrão.

Tipo de Mutação	Vento			LQ	LR	Melhor Fitness	Fitness Médio	Desvio Padrão
Aleatória	0.808	0.122	0.888	3	30	3.81	4.06	0.86
	0.014	-	0.961					
	0.044	0.628	0.821					
Máscara	0.243	0.786	0.924	3	30	3.96	4.04	0.08
	0.087	-	0.881					
	0.265	0.656	0.773					
Aleatória suavizada	0.195	0.410	0.827	3	30	3.59	3.68	0.1
	0.000	-	0.945					
	0.009	0.622	0.846					

Tabela 4 – Resultados Obtidos nos experimentos de seleção do operador de mutação.

A Figura 44 mostra o conjunto de parâmetros obtidos por cada variação da mutação e o vetor de forças resultante das suas respectivas matrizes de preferências

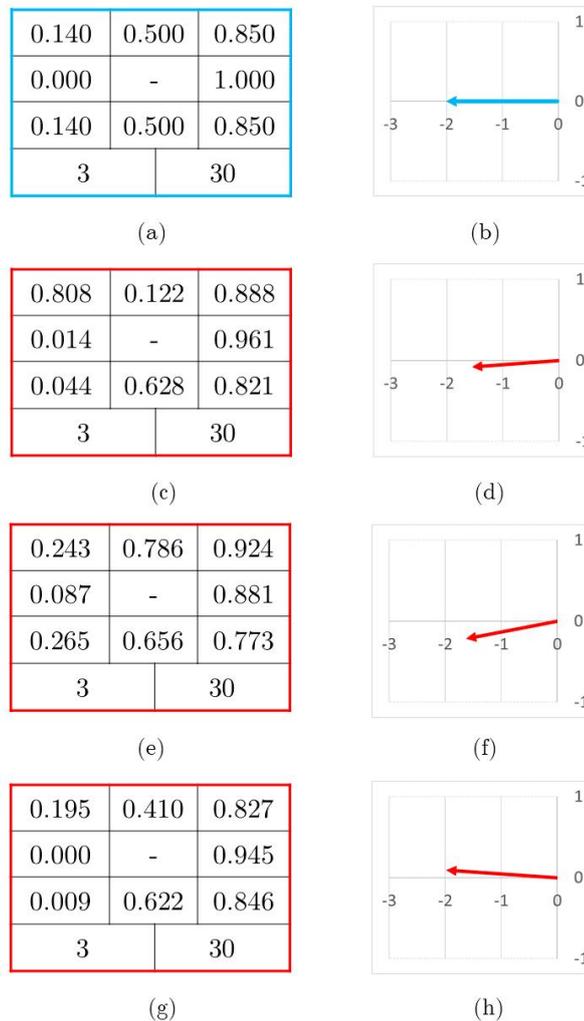


Figura 44 – Configurações encontradas pelo algoritmo genético e os respectivos vetores de força que representam a intensidade e direção dos ventos modelados, de acordo com a mutação adotada: cenário de referência ((a) e (b)); aleatória ((c) e (d)); máscara ((e) e (f)); e aleatória suavizada ((g) e (h)).

A Figura 45 apresenta os reticulados resultantes das simulações com cada conjunto de

parâmetros, incluindo a evolução temporal do cenário de referência.

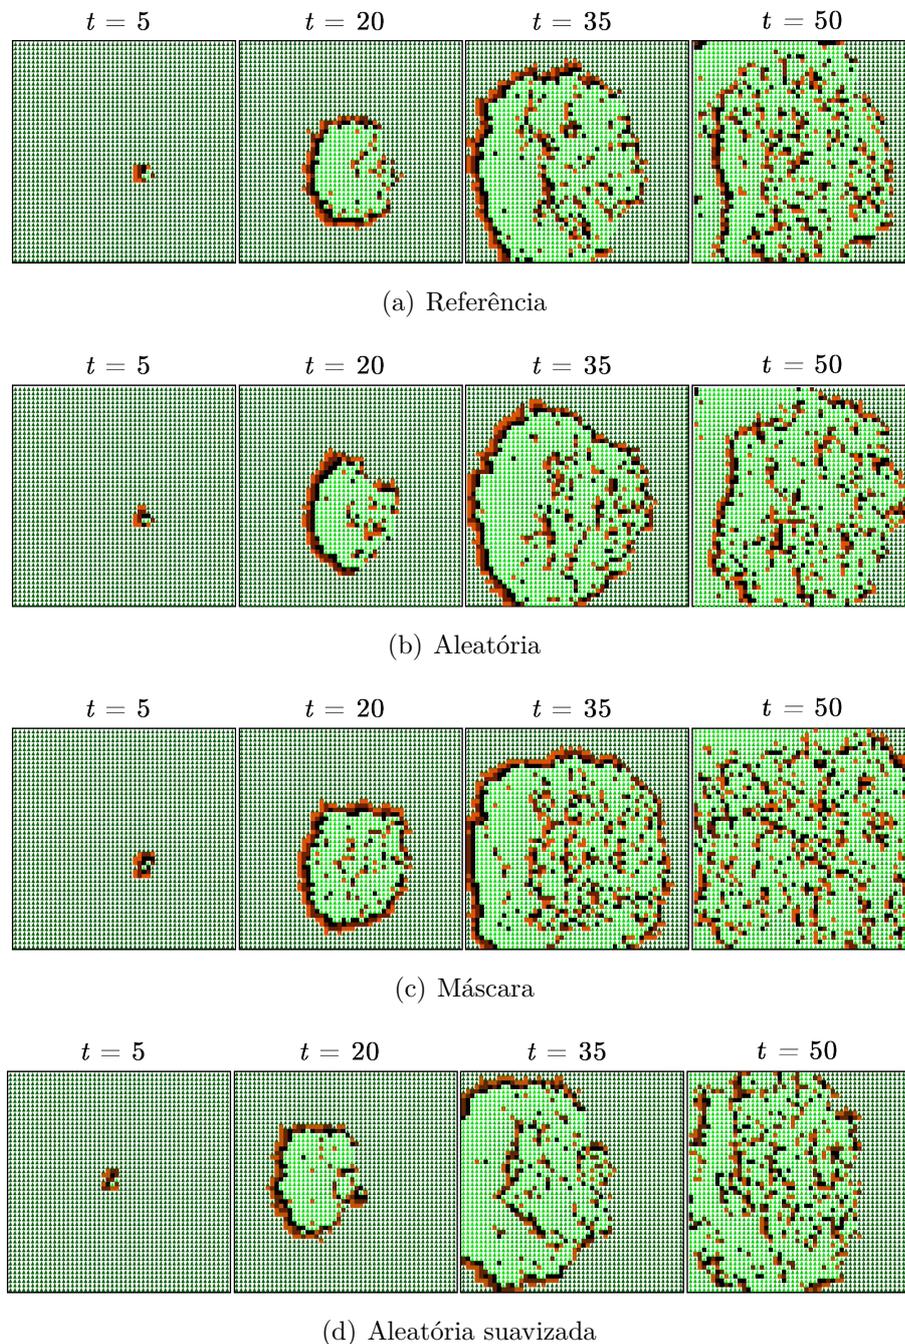


Figura 45 – Evolução temporal de um incêndio simulado a partir do autômato celular configurado com os parâmetros encontrados pelo algoritmo genético, de acordo com a mutação: (a) referência; (b) aleatória suavizada; (c) máscara; (d) e suavizada.

Na mutação com uma máscara para definir quais genes sofreriam mutação, resultou em *fitness* do melhor indivíduo de 3,96, enquanto o *fitness* médio foi 4,04 e o desvio padrão foi 0,08, após 10 execuções do AG. Nesse caso, os valores de LQ e LR obtidos pelo algoritmo genético foram iguais a referência, como mostra a Figura 44(e). Em relação ao vetor que representa o vento representado pela matriz obtida com o uso da mutação de máscara

(Figura 44(f)), há um ângulo de 187 graus e uma intensidade de 1,85. Quanto à mutação aleatória (operador inicial), a mudança propiciou uma representação ligeiramente melhor. A Figura 45 mostra a evolução temporal do modelo de referência e daqueles configurados com os parâmetros gerados pelo AG, considerando as diferentes formas de mutação. Como é possível perceber, no modelo de referência (Figura 45(a)) o fogo se espalha para a direção oeste do reticulado. O autômato celular com os parâmetros obtidos a partir da mutação de máscara (Figura 45(c)), tem um comportamento semelhante ao da referência, com o vento propagando o fogo para à esquerda do reticulado. Entretanto, percebe-se que o incêndio modelado possui uma propagação mais agressiva, de modo que no instante $t = 50$, o fogo se espalhou por praticamente todo o reticulado. Isso ocorre justamente pela menor intensidade do vento modelado, o que permite o maior avanço das chamas na direção contrária ao vento (leste).

Também foi avaliada a adoção de uma mutação mais suave, na qual mantém-se o operador de mutação original (escolha aleatória dos genes submetidos a mutação), mas empregando valores menores na alteração dos seus valores. Isto é, enquanto a mutação original seleciona um valor aleatório entre $[-1, 1]$, nessa nova versão, escolhe-se um valor entre $[-0,2, 0,2]$. Como apresentado na Tabela 4, a aptidão do melhor indivíduo encontrado pelo AG usando essa mutação foi 3,59, com um *fitness* médio de 3,68 e desvio padrão de 0,10. Assim como na mutação de máscara, os valores de LQ e LR do melhor indivíduo são idênticos aos usados no modelo de referência. Os valores da matriz de preferências também apresentam uma distribuição mais próxima da referência. Tal comportamento é refletido pelo vetor de forças apresentado na Figura 44(h), o qual representa um vento com intensidade (2,09) e direção muito próximos ao modelado na referência (Figura 44(a)), apresentando um desvio de apenas 177 graus para o norte. A Figura 45 apresenta a evolução temporal dos incêndios simulados a partir do modelo de referência e pelos modelos configurados com os parâmetros encontrados pelo AG, considerando as três estratégias de mutação (máscara e aleatórias normal e suave). Como pode ser observado, a propagação do incêndio simulado com os parâmetros obtidos com o uso da mutação aleatória suavizada, apresenta um comportamento mais próximo do modelo de referência.

Com base nos comportamentos observados em todas as configurações do AG, aquela que adota o *crossover* de 2 pontos e mutação aleatória suavizada foi a que atingiu o menor valor de *fitness*, além de uma evolução temporal bastante parecida com a referência. Portanto, foi empregada nos demais experimentos deste trabalho.

6.4 Análise de Desempenho em Cenários Homogêneos

Essa seção descreve os experimentos realizados com o modelo de autômato celular que representa cenários com uma única vegetação (cenário homogêneo), em que o algoritmo

genético evolui um conjunto formado por 10 parâmetros. Além da análise do desempenho da abordagem evolutiva em encontrar um conjunto adequado de parâmetros, também é feita uma investigação mais aprofundada, na qual avalia-se a evolução dos parâmetros ao longo das gerações do algoritmo genético, bem como a influência do deslocamento temporal entre os dados de referência e simulados no desempenho do modelo. Os resultados desses experimentos são apresentados a seguir.

6.4.1 Simulações com um Único Ponto Inicial de Fogo

Neste experimento foram avaliados 4 cenários homogêneos que, embora tenham sido gerados a partir de matrizes de vento diferentes, o fogo foi iniciado a partir do mesmo ponto. Em todos os cenários LQ e LR tiveram seus valores fixados em 3 e 30, com variações apenas na direção do vento: sul, oeste, leste e noroeste.

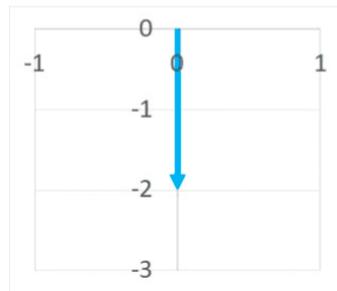
O primeiro cenário apresenta uma matriz de preferências com valores mais altos na parte superior, conforme mostra a Figura 46(a). A força vetorial resultante (Figura 46(c)) mostra que o vento nesse cenário sopra para o sul. Considerando todas as 10 execuções do AG, o melhor indivíduo encontrado apresenta uma aptidão de 2,63, enquanto que o *fitness* médio das execuções foi de 2,72, com um desvio padrão de 0,008. Esses valores indicam uma boa estabilidade nas soluções encontradas pelo algoritmo. A matriz obtida pelo melhor indivíduo do AG (Figura 46(b)) resulta em um vento predominantemente para o sul, e uma intensidade menor que a referência (1,6 contra 2,0). Nota-se uma ligeira inclinação para leste (271 graus), que é provocada pelo desbalanceamento entre os valores da direita e da esquerda na matriz encontrada pelo AG. Os valores de LQ e LR são iguais aos da referência.

0.850	1.00	0.850
0.500	-	0.500
0.140	0.000	0.140
3	30	

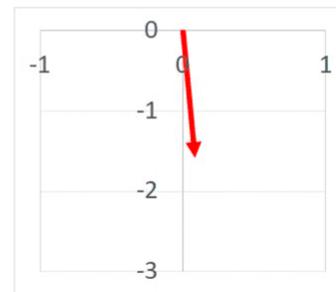
(a) Parâmetros de Referência

0.853	1.000	0.956
0.461	-	0.814
0.742	0.159	0.010
3	30	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 46 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o sul: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG.

A Figura 47 mostra a evolução temporal dos incêndios simulados pelos modelos de referência e configurado pelo AG. Apesar das diferenças entre as matrizes, o comportamento nas duas simulações é semelhante, ou seja, o fogo se propaga para o sul do reticulado e as bordas (inferior e lateral direita) são alcançadas entre $t = 20$ e $t = 35$. No modelo configurado pelo AG, a propagação do fogo foi um pouco mais intensa. Além do ligeiro desvio para leste, que provoca um maior avanço do incêndio nessa direção, a menor intensidade do vento também aumenta as chances do incêndio se alastrar em direções contrárias ao vento.

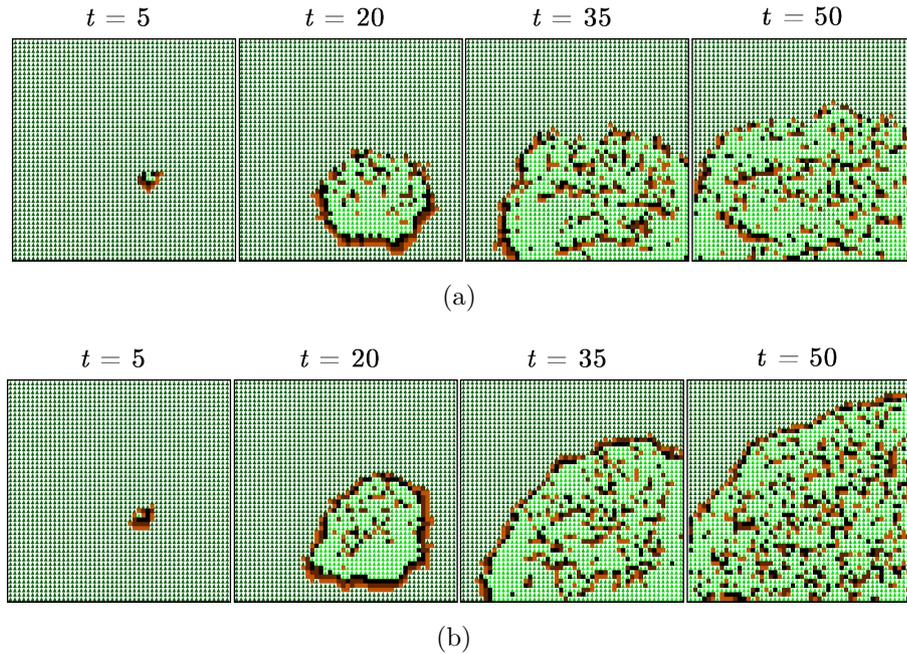


Figura 47 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o sul: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.

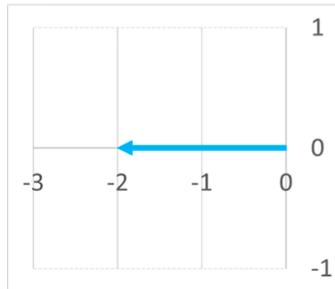
O segundo cenário adota a mesma configuração do primeiro, apenas com a rotação da matriz de preferências, conforme apresentado na Figura 48(a). Dessa forma, o vento resultante tem a mesma intensidade $(2,0)$, mas sopra na direção oeste, como mostrado na Figura 48(c). Para esse cenário, a melhor configuração encontrada apresenta uma aptidão de 3,60, enquanto o *fitness* médio e desvio padrão das execuções do AG foi de $3,81 \pm 0,12$. Como descrito na Figura 48(b), os valores dos parâmetros LQ e LR obtidos pelo AG também são iguais aos da referência. Embora os valores da matriz de preferências resultante não sejam iguais, eles apresentam um balanceamento similar ao da matriz de referência. Como consequência, a direção do vento é a mesma, conforme mostra o vetor de forças apresentado na Figura 48(d). É possível perceber que o vento modelado possui características muito próximas da referência, com intensidade de 2,07 e direção predominante para oeste, com um ligeiro desvio (184 graus) para sul.

0.140	0.500	0.850
0.000	-	1.000
0.140	0.500	0.850
3	30	

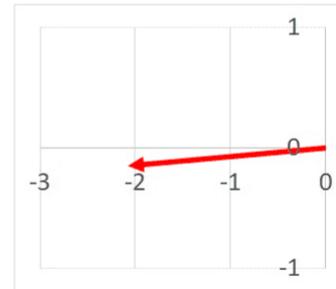
(a) Parâmetros de Referência

0.189	0.751	0.912
0.000	-	1.000
0.158	0.591	0.963
3	30	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 48 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o oeste: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG

A similaridade da força vetorial também é refletida nas evoluções temporais do autômato celular apresentadas na Figura 49. Enquanto a Figura 49(a) mostra o comportamento do incêndio simulado a partir do modelo de referência, a Figura 49(b) ilustra a simulação resultante do modelo configurado com os parâmetros encontrados pelo AG. Nas duas simulações, o fogo se alastra para o oeste do reticulado. Como a matriz de preferências definida pelo AG possuem valores maiores em praticamente todas as posições que aqueles utilizados no modelo de referência, o fogo se espalha um pouco mais rápido, como é possível perceber nos reticulados do AC. Entretanto, o comportamento da propagação é semelhante.

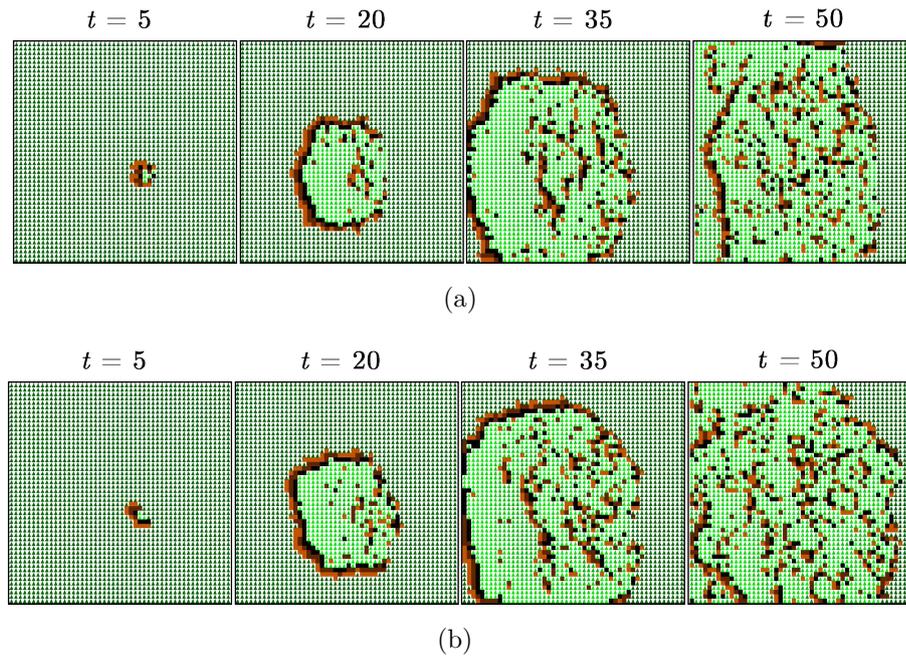


Figura 49 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o oeste: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.

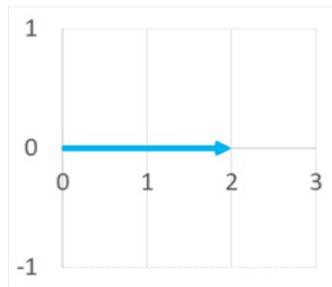
O terceiro cenário estudado é o reflexo do segundo, ou seja, a matriz de preferências é espelhada, propiciando um vento na direção leste. Dessa maneira, os campos com maior valor na matriz de preferências são os da esquerda, tanto na referência (Figura 50(a)) quanto no indivíduo obtido pelo AG (Figura 50(b)), com os mesmos valores de LQ e LR em ambas as configurações. A aptidão do melhor indivíduo encontrado foi de 2,06, sendo que o *fitness* médio das execuções do AG foi de $2,18 \pm 0,007$. Na comparação dos vetores de forças resultantes, o vento modelado pelo melhor indivíduo do AG (Figura 50(d)) tem uma intensidade de 1,79, ligeiramente menor que a da referência (Figura 50(c)). Por outro lado, ambas as configurações apresentam praticamente a mesma direção do vento, com um desvio insignificante para o sul no vetor que representa o vento do AG.

0.850	0.500	0.140
1.000	-	0.000
0.850	0.500	0.140
3	30	

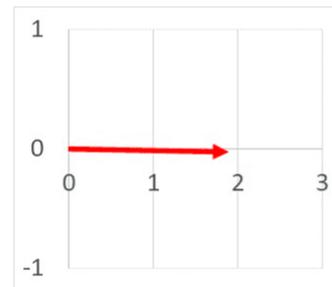
(a) Parâmetros de Referência

0.713	0.979	0.000
0.940	-	0.147
0.915	0.777	0.064
3	30	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 50 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o leste: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG

Essa semelhança também pode ser observada nos comportamentos dos incêndios modelados a partir do modelo de referência e aquele configurado pelo AG, como mostrado na Figura 51. O fogo se propaga para o leste do reticulado e as bordas inferior e lateral direita são alcançados entre $t = 20$ e $t = 35$.

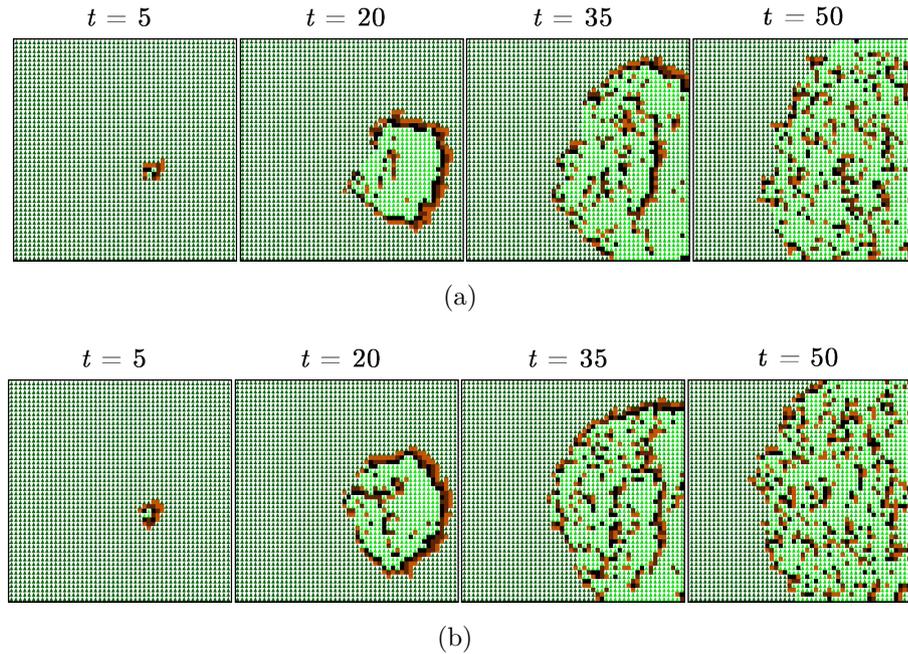


Figura 51 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o leste: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.

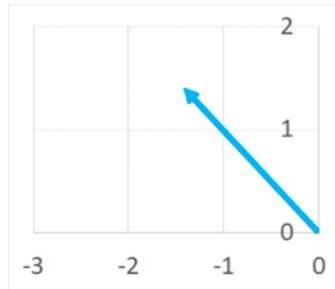
No quarto cenário, foi criado um ambiente com o vento na direção noroeste, ou seja, com os maiores valores posicionados no canto inferior direito da matriz de preferências, como pode ser observado na configuração de referência (Figura 52(a)). Na matriz obtida pelo AG, os valores não são exatamente os mesmos da referência, mas sua distribuição espacial é bem próxima, com os maiores valores localizados na diagonal inferior direita, conforme mostra a Figura 52(b). Assim como nos cenários anteriores, o AG também foi capaz de encontrar os mesmos valores de LQ e LR do modelo de referência. O melhor indivíduo atingiu uma aptidão de 2,92, enquanto o *fitness* médio das execuções do AG foi de $3,07 \pm 0,16$. Os ventos resultantes de ambos os modelos (referência e configurados pelo AG) possuem uma dinâmica bem similar. O vento obtido a partir dos parâmetros encontrados pelo AG (Figura 52(d)) sopra para noroeste com uma intensidade de 2,06, enquanto que o gerado pelo modelo de referência (Figura 52(c)) possui a mesma direção e uma intensidade ligeiramente menor (2,00).

0.000	0.140	0.500
0.140	-	0.850
0.500	0.850	1.00
3	30	

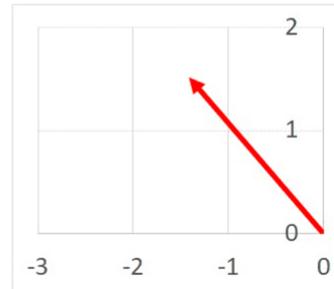
(a) Parâmetros de Referência

0.009	0.006	0.570
0.313	-	0.837
0.347	0.969	1.000
3	30	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 52 – Configurações usadas na simulação do cenário homogêneo com um único ponto inicial de fogo e vento para o noroeste: (a) parâmetros de referência; (b) parâmetros encontrados pelo AG; (c) vetor de forças do modelo de referência; e (d) vetor de forças do modelo do AG

A Figura 53 compara a referência (a) e o melhor indivíduo obtido pelo AG (b) e o comportamento é semelhante. A propagação do fogo ocorreu nos dois casos para o noroeste. A simulação do modelo com os parâmetros ajustados pelo AG conseguiu reproduzir um comportamento muito similar ao modelo com os parâmetros de referência. Entretanto, uma característica distinguiu esse cenário em relação aos 3 anteriores. Nesse caso, tanto na referência quanto no modelo ajustado pelo AG, o número de passos necessário para atingir as bordas é maior. É possível perceber que essa característica é favorável à evolução do AG, pois enquanto o fogo não atinge as bordas, os reticulados possuem propriedades mais específicas que auxiliam na obtenção de um valor adequado de *fitness*. De uma forma geral, o número de passos “úteis” na evolução temporal do reticulado é maior, para a comparação entre a referência e o modelos em evolução. Isso ocorre porque depois que o fogo atinge as bordas, as informações do reticulado não ajudam tanto a discernir entre uma simulação e outra.

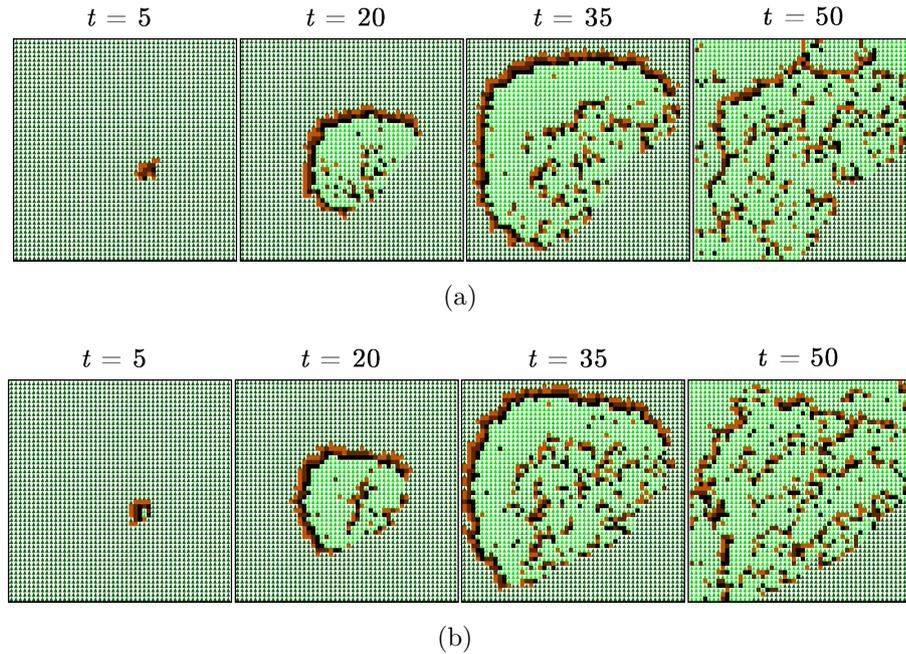


Figura 53 – Evolução temporal do autômato celular que modela incêndios em um cenário homogêneo com único ponto inicial de fogo e vento para o noroeste: (a) simulação do modelo de referência; e (b) simulação do modelo configurado pelo algoritmo genético.

Nos três primeiros cenários, o ponto adotado como início do incêndio não é o mais favorável, uma vez que o fogo atinge as bordas do reticulado entre os instantes de tempo $t = 20$ e $t = 35$. Em contrapartida, no último cenário, o fogo demora mais passos de tempo do autômato celular para atingir as bordas do reticulado (entre $t = 35$ e $t = 50$), possibilitando um melhor refinamento dos parâmetros. Essa constatação nos levou a um novo tipo de experimento que é descrito na próxima sub-seção.

6.4.2 Simulações com Vários Pontos Iniciais de Fogo

Com base nos indícios identificados no experimento anterior, novas execuções foram realizadas a fim de investigar o impacto da posição de foco inicial no desempenho do AG. Neste novo experimento, o modelo configurado com os parâmetros do algoritmo genético é simulado 5 vezes, adotando-se uma posição diferente no reticulado como foco inicial do incêndio. Na avaliação de todos os indivíduos do AG são utilizados os mesmos pontos para o início do Fogo, os quais foram distribuídos pelo cenário simulado. Basicamente, o reticulado é dividido em quatro partes e no centro de cada uma é colocado um ponto inicial de fogo, resultando em quatro reticulados iniciais. Além desses, também se evoluiu o autômato celular, considerando o ponto central do cenário como o foco inicial do incêndio (quinto reticulado inicial). Nesse estudo, foram utilizados os mesmos cenários do experimento anterior, que representam o vento nas direções sul, oeste, leste e noroeste. Entretanto, os valores de LQ e LR usados como referência variaram entre os cenários, a fim

de verificar a capacidade da abordagem evolutiva em ajustar esses parâmetros em função dos comportamentos observados nos dados de incêndio.

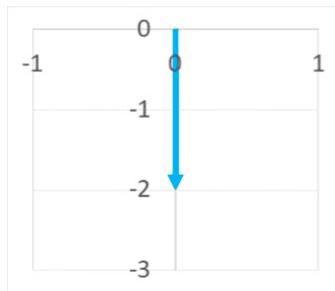
No primeiro cenário (vento para o sul), a abordagem evolutiva obteve seu pior desempenho nos experimentos relatados na seção anterior. Por isso, foram mantidos os mesmos valores tanto para a matriz de preferências, quanto para LQ e LR (3 e 30, respectivamente). Nesse cenário, o *fitness* médio das dez execuções do AG foi de 3,07, com desvio padrão de 0,08, e o melhor indivíduo teve uma aptidão de 2,99. A Figura 54 apresenta sua configuração, bem como a usada como referência para facilitar a comparação. Como esperado, o algoritmo encontrou os mesmos valores da referência para LQ e LR. A Figura 54(b) também mostra que os valores da matriz também são bem próximos da referência (Figura 54(a)), sendo que os maiores valores estão localizados na parte superior (primeira linha), resultando em um vento na direção sul. Conseqüentemente, também existe uma grande semelhança entre os vetores de forças mostrados nas Figuras 54(c) e 54(d), os quais representam, respectivamente, o vento do modelo de referência e do AG. A intensidade do vento obtido pelo AG é um pouco maior que da referência (2,11 e 2,00), enquanto que a angulação dos vetores é semelhante, com um insignificante desvio para leste no caso do vetor obtido pelo AG.

0.850	1.00	0.850
0.500	-	0.500
0.140	0.000	0.140
3		30

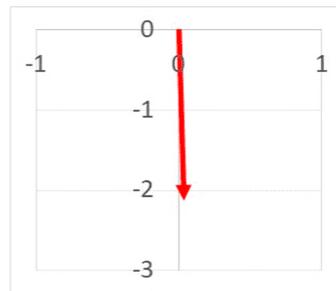
(a) Parâmetros de Referência

0.841	1.000	0.849
0.509	-	0.507
0.101	0.010	0.000
3		30

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 54 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção sul: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 55 apresenta as simulações dos modelos de referência (Figura 55(a)) e configurado pelo AG (Figura 55(b)), considerando os diferentes reticulados iniciais. Cada linha da figura representa a evolução temporal do AC a partir de uma posição diferente para o início do incêndio, na seguinte ordem: noroeste, nordeste, sudoeste, sudeste e centro.

Em todas as simulações, tanto de referência quanto do AG, o fogo se propaga para o sul do reticulado. As duas primeiras linhas apresentam os pontos mais favoráveis para esse cenário, pois os pontos iniciais do fogo estão na parte superior do reticulado, levando, assim, mais tempo para a fronteira do incêndio atingir as bordas do reticulado. Por consequência, os pontos menos favoráveis são aqueles em que o fogo começa na parte inferior do reticulado. Comparando-se esses resultados com aqueles obtidos no experimento anterior para o mesmo cenário a partir de um único ponto inicial (Figuras 46 e 47), é possível observar que a adoção de diferentes pontos iniciais de incêndio na avaliação dos indivíduos possibilitou um melhor refinamento dos parâmetros encontrados pelo AG, resultando em uma melhor qualidade das simulações.

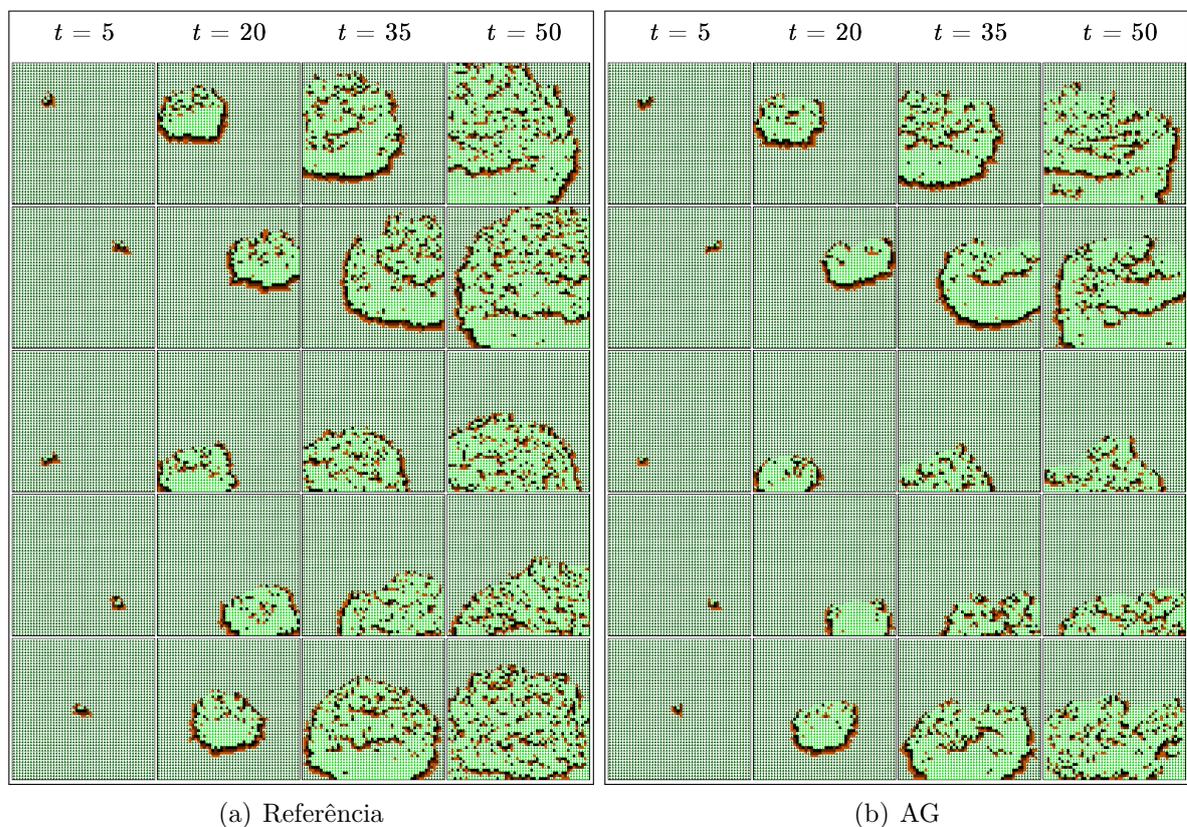


Figura 55 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção sul: (a) modelo de referência; e (b) modelo configurado pelo AG.

Nos outros três cenários, procurou-se também investigar o impacto da alteração dos parâmetros LQ e LR. No cenário que representa o vento na direção oeste, manteve-se LR com 30, alterando o valor de LQ para 6. A Figura 56 apresenta os parâmetros (Figura 56(a)) e força vetorial de referência desse cenário (Figura 56(c)), bem como aqueles e obtidos pelo melhor indivíduo do AG ((Figura 56(b) e (d))). Como pode ser observado, mesmo com a alteração no parâmetro LQ, o AG foi capaz de encontrar os mesmos valores da referência para LQ e LR. A matriz de preferências resultante também apresenta valores

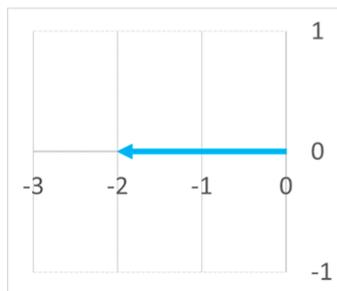
próximos em todas as posições, resultando em um vento com intensidade (2,03 vs. 2,00) e direção bem similares ao da referência. Nesse cenário, a aptidão do melhor indivíduo foi de 3,20, com um *fitness* médio de $3,32 \pm 0,15$.

0.140	0.500	0.850
0.000	-	1.000
0.140	0.500	0.850
6		30

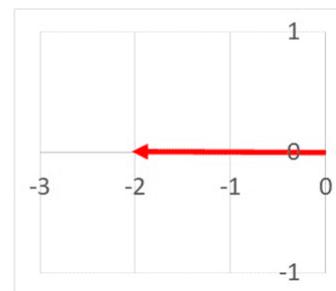
(a) Parâmetros de Referência

0.094	0.499	0.823
0.000	-	1.000
0.084	0.514	0.817
6		30

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 56 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 57 apresenta as simulações do modelo configurado pelo AG (Figura 57(b)) e o de referência (Figura 57(a)), considerando os diferentes reticulados iniciais. A ordem utilizada é a mesma do cenário inicial. Em todas as simulações, independentemente do reticulado inicial, o modelo do AG apresentou um comportamento bem similar ao modelo de referência. Percebe-se que nas simulações onde o fogo começou mais à direita, houve uma maior variação no espalhamento do incêndio, principalmente nos reticulados finais. Acredita-se que isso ocorreu por haver mais espaço para a propagação do incêndio, aumentando o ruído proveniente do processo estocástico do AC. Por outro lado, as simulações com o foco inicial do incêndio mais à esquerda apresentam uma propagação bem parecida. Esse comportamento é esperado, uma vez que o incêndio alcança a borda oeste do reticulado (direção do vento) mais rapidamente, reduzindo a sua propagação e, conseqüentemente, o impacto do fator estocástico do modelo. Quanto à alteração do valor de LQ, percebe-se que tanto na referência quanto no indivíduo do AG, existem células em um tom de laranja mais forte, o que indica que o fogo permanece por mais tempo no reticulado e que há mais células no estado *Fogo*.

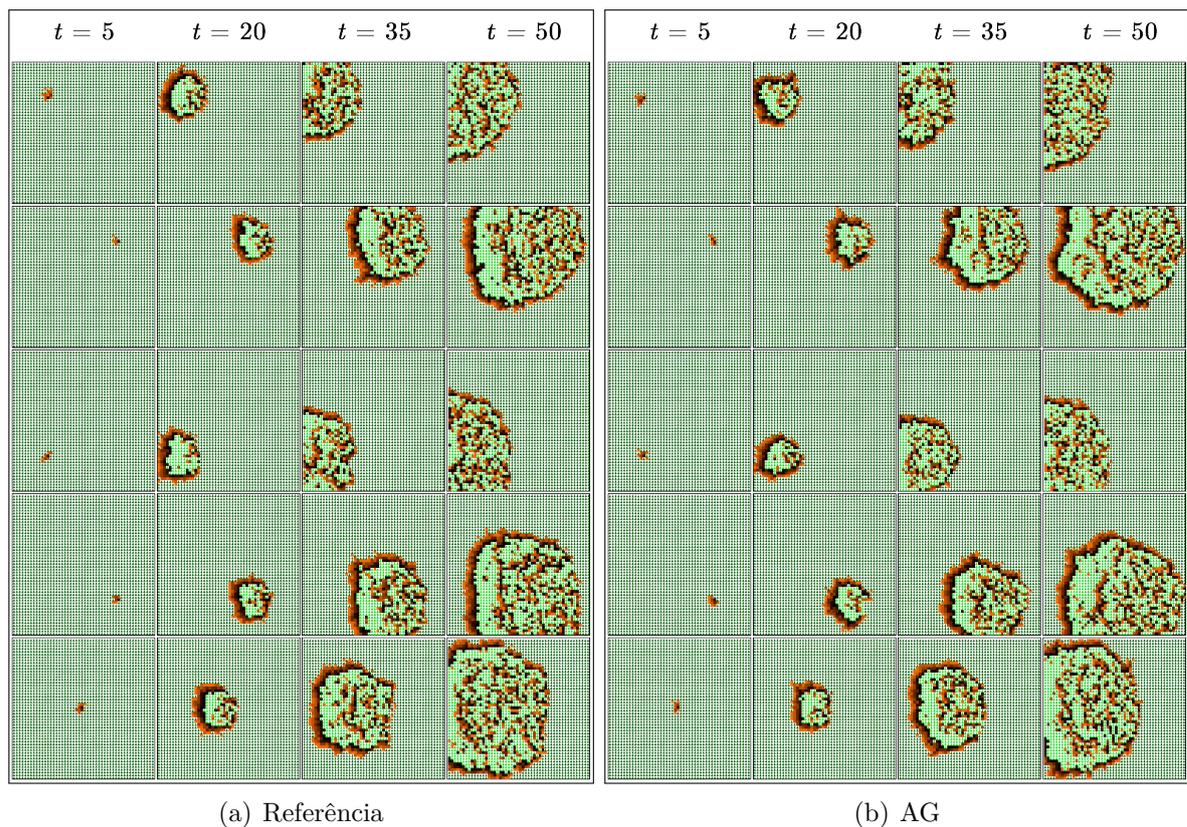


Figura 57 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG.

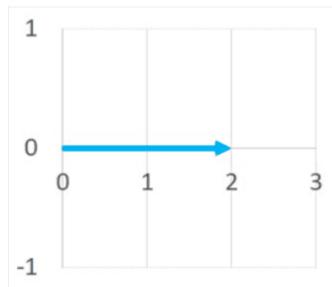
No terceiro cenário (vento para o leste), o valor de LQ foi mantido em 3 enquanto o valor de LR foi alterado para 90. Nesse cenário, o *fitness* médio das dez execuções do AG foi de 2,31, com desvio padrão de 0,13, e o melhor indivíduo teve uma aptidão de 2,21. A Figura 58 apresenta a configuração do cenário de referência e do melhor indivíduo. O AG foi capaz de encontrar os mesmos valores de referência para LQ e LR, mesmo com a alteração no parâmetro LR. A matriz de preferências obtida (Figura 58(b)) tem valores próximos aos da referência (Figura 58(a)), resultando em um vento na direção leste. A intensidade do vento obtido é ligeiramente menor que a de referência (1,83 e 2,0).

0.850	0.500	0.140
1.000	-	1.000
0.850	0.500	0.140
3		90

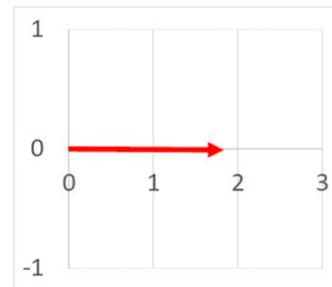
(a) Parâmetros de Referência

0.823	0.408	0.350
1.000	-	0.000
0.850	0.526	0.140
3		90

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 58 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção leste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 59 apresenta as simulações dos modelos de referência (Figura 59(a)) e configurado pelo AG (Figura 59(b)), considerando os diferentes reticulados iniciais. Em todas as simulações, tanto de referência quanto do AG, o fogo se propaga para o leste do reticulado. No geral, os comportamentos dos incêndios são bem parecidos entre as simulações de referência e do AG. Analisando a evolução temporal, percebe-se que o modelo configurado pelo AG apresenta uma propagação um pouco mais intensa do fogo, a partir do instante $t=35$. Quanto a alteração do valor de LR, percebe-se que tanto na referência quanto no indivíduo do AG, as células demoram mais tempo para se recuperar e voltarem a pegar fogo.

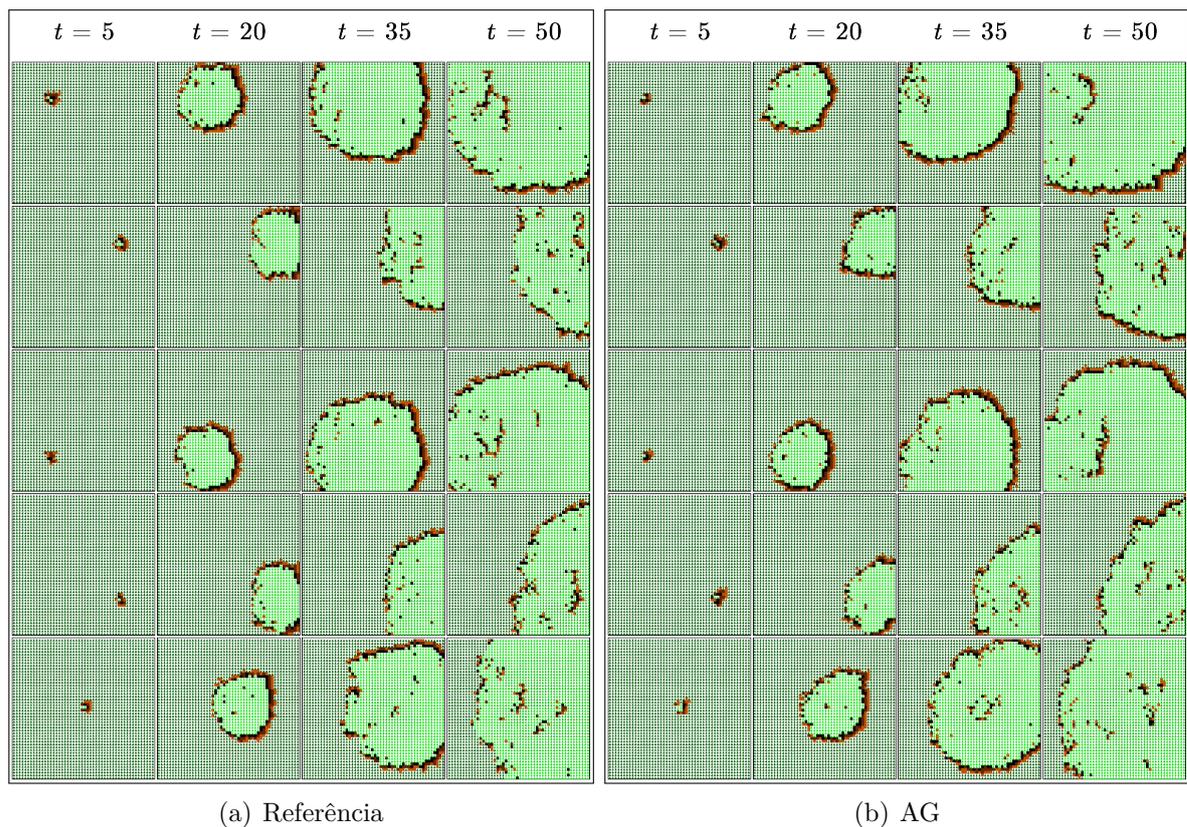


Figura 59 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção leste: (a) modelo de referência; e (b) modelo configurado pelo AG.

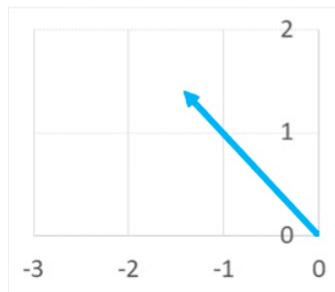
No cenário com o vento para o noroeste, os valores de LQ e LR foram alterados para 4 e 40, respectivamente. Nesse cenário, o *fitness* médio das dez execuções do AG foi de 3,41, com desvio padrão de 0,16, e o melhor indivíduo teve uma aptidão de 3,27. A Figura 60 apresenta os parâmetros (Figura 60(a)) e a força vetorial de referência desse cenário (Figura 60(c)), bem como aqueles e obtidos pelo melhor indivíduo do AG ((Figura 60(b) e (d)). Como pode ser observado, o AG encontrou os valores de LQ e LR. A matriz obtida pelo AG (Figura 60(b)) apresenta valores semelhantes aos da referência (Figura 60(a)) e os maiores valores também estão localizados na diagonal inferior esquerda, resultando em um vento para o noroeste. A intensidade do vento obtido pelo AG é um pouco maior que da referência (2,06 e 2,00), enquanto que a angulação dos vetores é semelhante.

0.000	0.140	0.500
0.140	-	0.850
0.500	0.850	1.00
4	40	

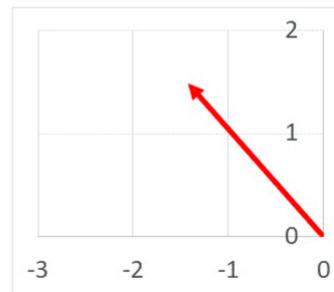
(a) Parâmetros de Referência

0.000	0.006	0.490
0.149	-	0.862
0.461	0.910	1.000
4	40	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 60 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 61 mostra as simulações de incêndio obtidas pelos modelos de referência e configurado pelo AG, a partir de cada reticulado inicial investigado. Apesar de sutil, a mudança nos valores de LQ e LR influenciaram no comportamento de propagação do fogo. Devido ao incremento de LQ, as células passam mais tempo queimando. Além disso, o LR mais alto provoca uma recuperação mais lenta da matéria orgânica da célula e, conseqüentemente, demanda mais tempo para ela voltar a ser suscetível a novas queimadas. Comparando as evoluções dos incêndios simulados pelos modelos de referência e configurado pelo AG, é possível observar dinâmicas bem similares, com pequenas variações decorrentes da estocasticidade do modelo.

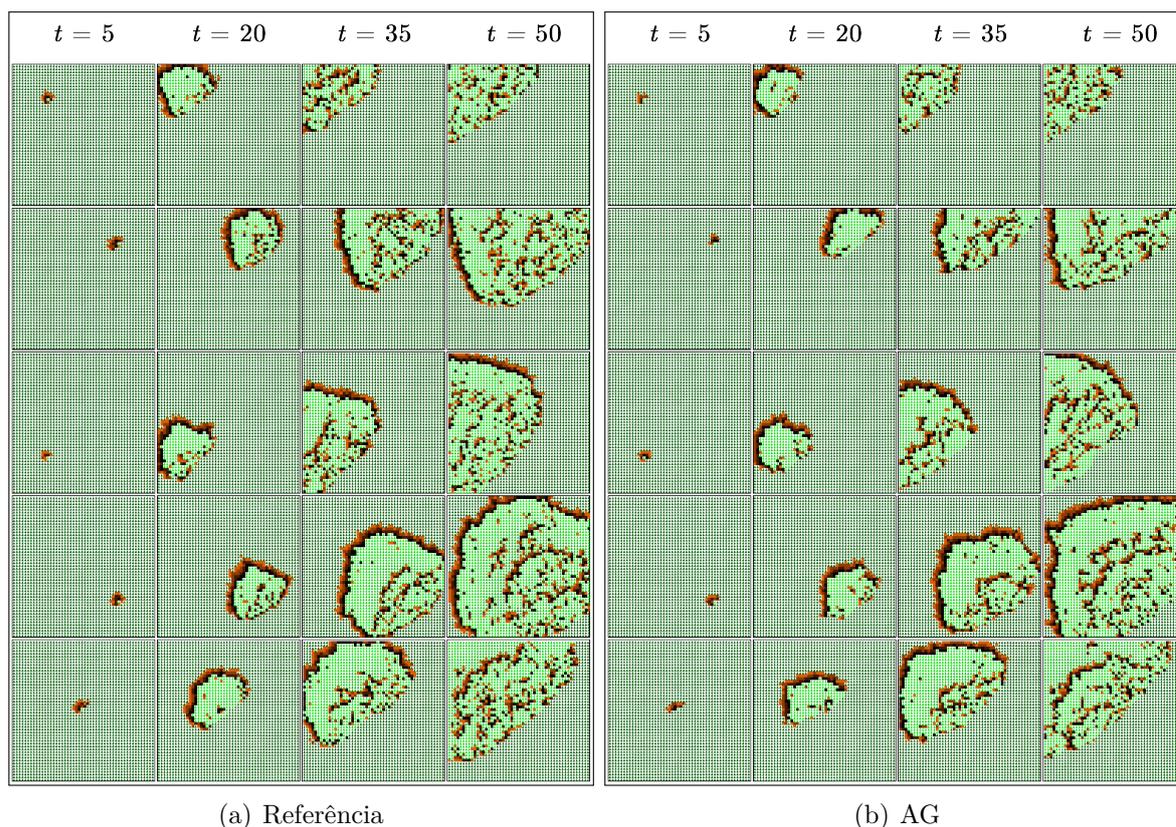


Figura 61 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário homogêneo com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG.

No geral, foi possível perceber que a posição inicial do incêndio impacta no ajuste do conjunto de parâmetros do modelo. Enquanto os pontos que favorecem a observação da propagação do fogo auxiliam na definição dos valores dos parâmetros, aqueles em que o incêndio atinge rapidamente as bordas do reticulado prejudicam a identificação da dinâmica e, conseqüentemente, no ajuste. Portanto, adotar uma estratégia avaliativa baseada em diferentes pontos iniciais de incêndio se mostrou eficiente para o refinamento do conjunto de parâmetros, em especial da matriz de preferências que modela o comportamento do vento. Tal conclusão é corroborada pelos resultados obtidos com o cenário com vento na direção sul. Ao adicionar novos reticulados com diferentes posições iniciais na estratégia de avaliação, observou-se uma melhoria considerável na qualidade de ajuste obtida pelo algoritmo genético, em relação aos resultados obtidos a partir de um único reticulado inicial (fogo iniciando no ponto central). Nos demais cenários, o AG também foi capaz de minimizar a diferença de comportamento para as simulações a partir do modelo de referência. Do ponto de vista prático, no futuro ao usar imagens reais de incêndio para evoluir os parâmetros do modelo, pode-se enfatizar a importância de capturar seqüências de imagens de diferentes perspectivas da área. Também foi possível perceber que o AG foi capaz de encontrar os valores exatos para LQ e LR, em todos os cenários.

6.4.3 Impacto do Deslocamento Espacial dos Dados

Para analisar a sensibilidade do modelo, optou-se por verificar se as configurações iniciais do AC afetam a capacidade do AG em reproduzir o comportamento do incêndio. Isso foi feito alterando-se a posição inicial dos focos de fogo, mas nas simulações realizadas pelo AG no cálculo do *fitness* usando o banco de dados gerado para o cenário com vento na direção oeste, no experimento anterior (diferentes reticulados iniciais).

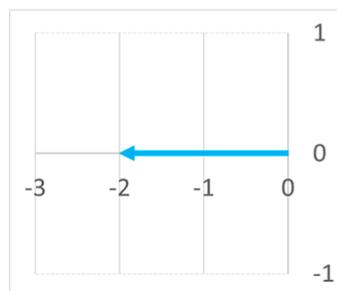
Inicialmente, os cinco focos iniciais de fogo foram movidos células posições para a esquerda e cinco células para baixo. Para o melhor indivíduo ainda foi possível a encontrar os valores de LQ e LR iguais aos da referência (6 e 30, respectivamente). Nesse cenário, o *fitness* da melhor configuração foi de 3,89, enquanto o *fitness* médio de $3,81 \pm 0,04$. A configuração usada como referência e encontrada pelo algoritmo são apresentadas na Figura 62. Pode-se perceber que, assim como na configuração de referência (Figura 62(a)), a matriz obtida pelo algoritmo também concentra os maiores valores no lado direito (Figura 62(b)). Entretanto, há um desbalanceamento entre os parâmetros da matriz, com valores mais altos na parte superior (principalmente entre as células da esquerda), o que provoca um pequeno desvio na direção do vento para sudoeste (Figura 62(d)), enquanto o vento representado na referência é somente na direção oeste (Figura 62(c)). Na configuração de referência, mostrada na Figura 62(a), os maiores valores estão no lado esquerdo, da matriz de preferências, representando um vento que sopra para leste (Figura 62(c)).

0.140	0.500	0.850
0.000	-	1.000
0.140	0.500	0.850
6	30	

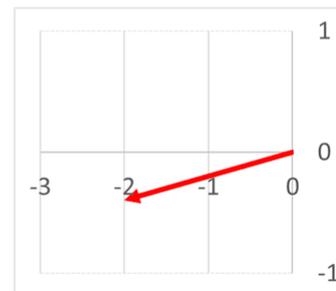
(a) Parâmetros de Referência

0.089	0.604	0.859
0.000	-	1.000
0.002	0.416	0.652
6	30	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial de Referência



(d) Força Vetorial Obtida pelo AG

Figura 62 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com deslocamento inferior esquerdo das diferentes posições para o início do fogo

As evoluções temporais resultantes do autômato celular configurado com esses parâmetros (referência e AG) são mostradas na Figura 63. Cada linha da figura apresenta a propagação do incêndio simulada pelo modelo a partir de uma posição diferente para o início do fogo. Tanto nas simulações com o modelo de referência (Figura 63(a)), quanto nas evoluções temporais obtidas com os parâmetros do AG (apresentadas Figura 63(b)), o fogo se propaga para o oeste do reticulado. A intensidade do vento é menor na evolução obtida pelo AG (1,90) e, dessa maneira, o fogo se propaga com menor velocidade. O comportamento da propagação do fogo ainda pode ser considerado semelhante, embora o fogo se espalhe com menos intensidade e menos velocidade.

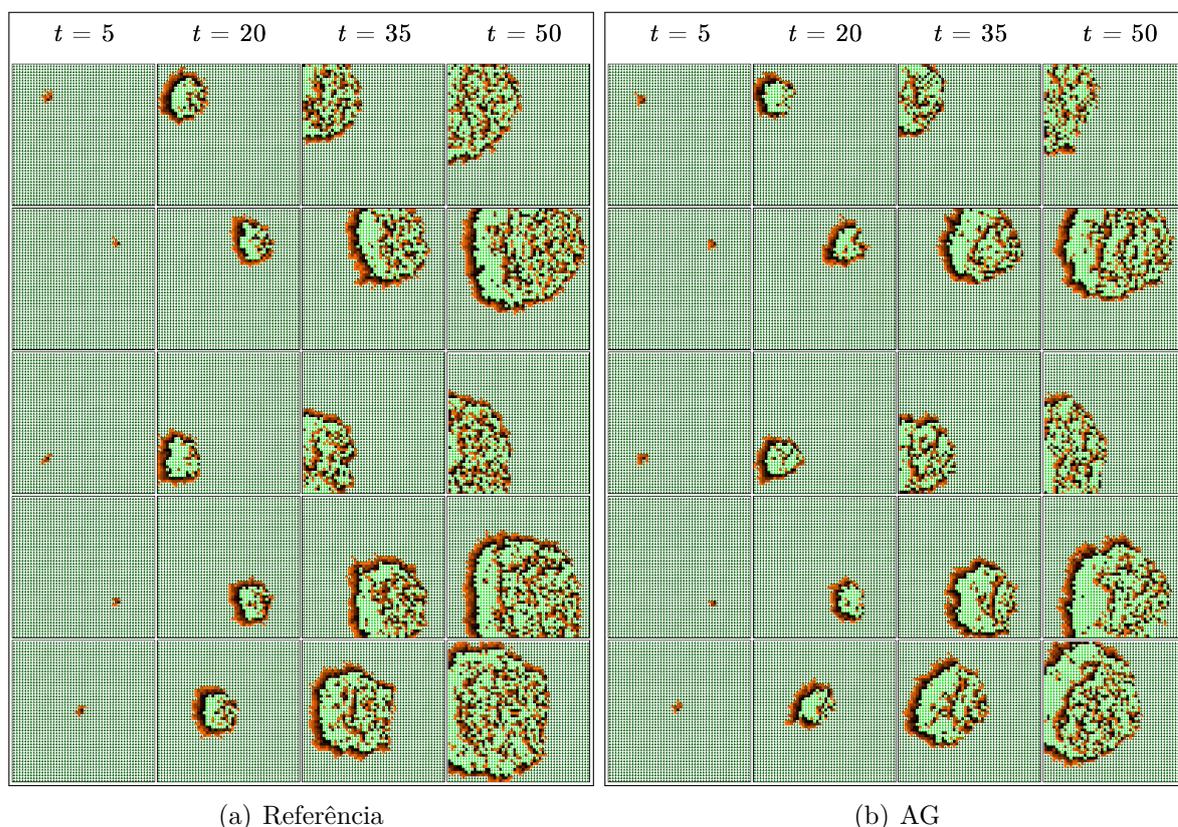


Figura 63 – Evolução temporal do autômato celular considerando o deslocamento inferior esquerdo das diferentes posições para o início do fogo no cenário homogêneo com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG.

Em um segundo experimento, um novo cenário foi elaborado no qual os cinco focos de fogo inicial foram movidos cinco células para cima e cinco células para a esquerda. Nesse cenário, o melhor indivíduo do AG obteve um *fitness* de 4,15, sendo que o *fitness* médio de todas as execuções foi de 4,23, com um desvio padrão de 0,13. A Figura 64 apresenta a configuração utilizada como referência e o melhor conjunto de parâmetros encontrado pela abordagem evolutiva, bem como os respectivos vetores de forças que representam o vento modelado em cada configuração. Como pode ser observado, o AG continua encontrando os

valores de LQ e LR iguais aos da referência. A matriz de preferências obtida pelo algoritmo genético, mostrada na Figura 64(b), tem os maiores valores no seu lado direito, de forma similar à configuração de referência (Figura 64(a)). Entretanto, novamente percebe-se um desbalanceamento entre seus parâmetros. Embora os valores nas extremidades direita e esquerda apresentem valores maiores na parte superior, provocando uma tendência ao sul, a maior diferença é observada na porção central, onde o maior valor está localizado na parte inferior, gerando um desvio para o norte. Assim, embora o vento de referência sopre para oeste, a configuração encontrada pelo AG tem uma tendência para noroeste.

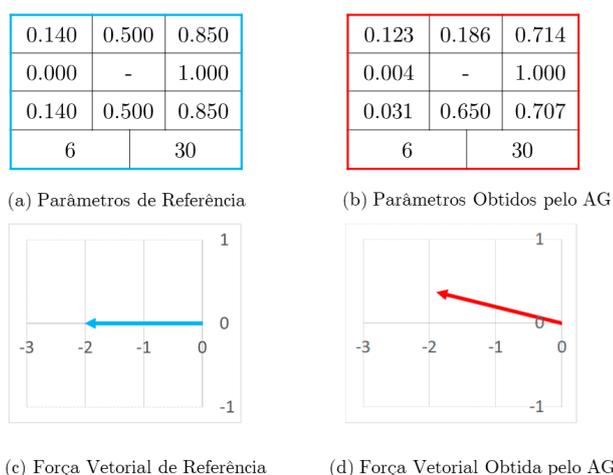


Figura 64 – Conjuntos de parâmetros e vetores de forças usados no cenário homogêneo com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com deslocamento superior direito das diferentes posições para o início do fogo

A Figura 65 apresenta as simulações de incêndio geradas a partir dos diferentes reticulados iniciais. Ao analisar as evoluções temporais, nota-se algumas pequenas variações na dinâmica dos incêndios entre o modelo de referência (Figura 65(a)) e aquele configurado pelo AG (Figura 65(b)). A maior diferença ocorre na simulação com o fogo iniciando na partição inferior direita. Essa posição inicial aumenta o impacto do desvio observado nos vetores de forças, pois possibilita o fogo propagar por mais tempo no reticulado, sem atingir suas bordas na direção do vento (oeste e norte). Entretanto, mesmo com as diferenças apontadas, acredita-se que, no geral, o algoritmo genético ainda conseguiu modelar um comportamento satisfatório, mantendo uma razoável similaridade com os dados de referência. O fogo obtido com os valores do melhor indivíduo do AG se propaga predominantemente para o oeste do reticulado, mas em uma velocidade e intensidade menores que nas simulações de referência.

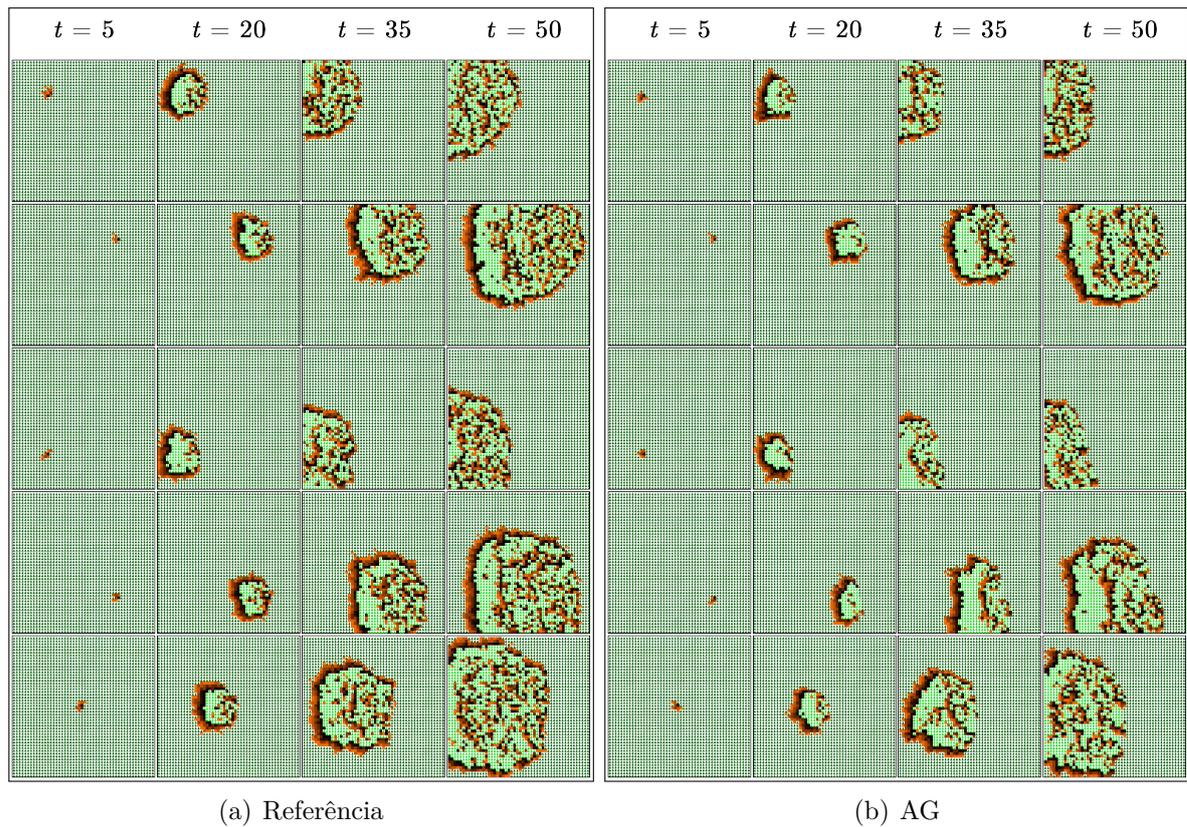


Figura 65 – Evolução temporal do autômato celular considerando o deslocamento superior direito das diferentes posições para o início do fogo no cenário homogêneo com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG.

Apesar das posições iniciais de fogo serem diferentes das usadas na geração dos dados de referência, no geral, o resultado dos cenários alterados na evolução do AG é bastante satisfatório. O AG foi capaz de identificar os valores dos parâmetros LQ e LR e uma direção semelhante para o vento, embora as matrizes não sejam equilibradas como na configuração de referência. Os desvios observados nos vetores de forças são provenientes do deslocamento na posição inicial do fogo, o que afeta diretamente o cálculo da aptidão. Mesmo assim, considera-se que a abordagem evolutiva conseguiu encontrar parâmetros capazes de reproduzir, de forma aproximada, a propagação do incêndio em todas as simulações, considerando-se uma alteração da posição inicial do foco de incêndio em aproximadamente 7% do tamanho total da largura do reticulado quadrado (100 células).

6.4.4 Análise da Evolução dos Parâmetros do Modelo

Para uma investigação mais aprofundada acerca da convergência do algoritmo genético, foi mapeada a evolução da melhor configuração (indivíduo) encontrada pelo AG a cada geração e sua respectiva aptidão. Por questão de simplicidade, essa análise foi realizada apenas sobre o cenário com vento para oeste e que considera os cinco pontos iniciais

de incêndio no cálculo da aptidão (Figura 57(a)). A Figura 66 apresenta a evolução dos parâmetros do algoritmo genético e do *fitness* do melhor indivíduo ao longo das gerações.

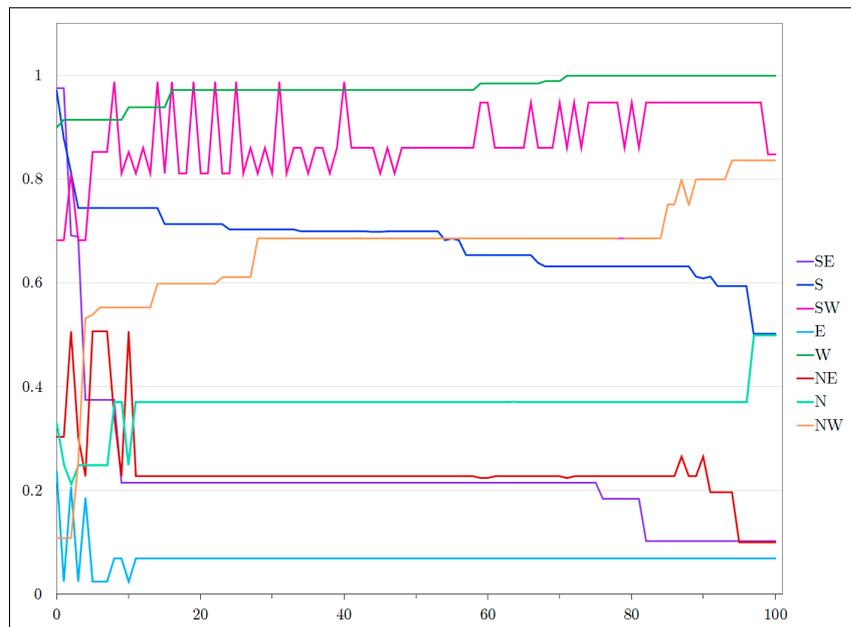
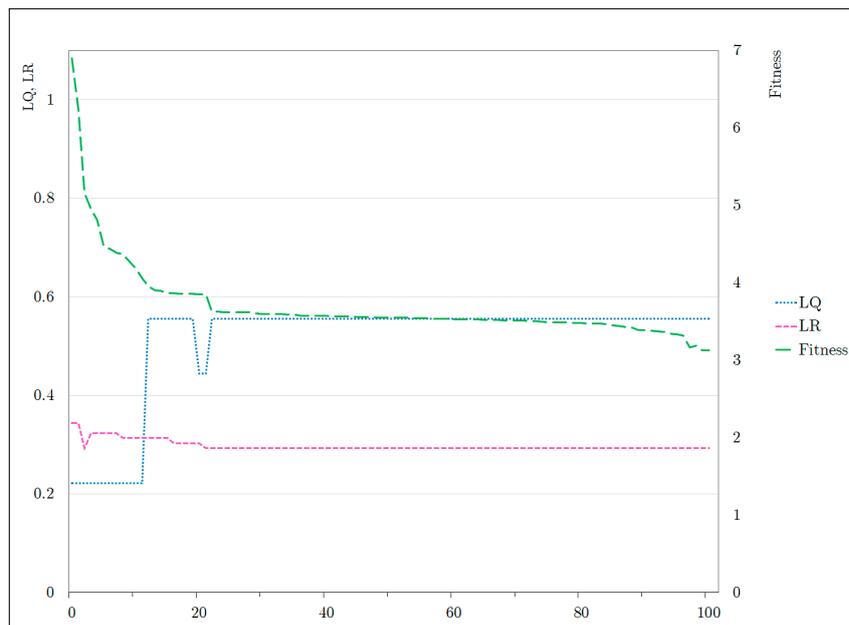
(a) $V_{3 \times 3}$ (b) LQ, LR e *Fitness*

Figura 66 – Evolução do melhor indivíduo a cada geração do algoritmo genético: (a) evolução dos valores da matriz de preferências ($V_{3 \times 3}$); e (b) evolução dos valores de LQ, LR e aptidão.

Como pode ser observado na Figura 66(a) que apresenta o comportamento dos parâmetros que compõem a matriz de preferências, a célula que representa o vento para oeste (v_W) possui um valor superior a 0,8 já nas primeiras gerações. Suas vizinhas, que representam o vento para noroeste (v_{NW}) e sudoeste (v_{SW}), também evoluem para valores

elevados. A célula v_{NW} inicia com um valor baixo (0,109), cresce para 0,553 já na sexta geração e continua a aumentar gradativamente até atingir seu valor máximo (0,836), na 94ª geração. A célula v_{SW} começa com um valor intermediário (0,682) e, já na décima geração, atinge o valor de 0,988. Nas gerações subsequentes, esse parâmetro é refinado pelo AG, atingindo seu valor final de 0,848 na penúltima geração. Vale destacar que esse valor é similar ao da célula v_{NW} , mantendo o equilíbrio entre as forças para norte e sul e reduzindo seu efeito no desvio do vento.

A célula que representa o vento para leste (v_E), tem seu valor estabilizado próximo a zero antes da vigésima geração. Da mesma forma, suas vizinhas (v_{NE} e v_{SE}) também são ajustadas para valores baixos, reduzindo drasticamente a força de propagação para leste, como desejado. Após iniciar com o valor 0,304, a célula v_{NE} apresenta um ligeiro crescimento até a décima geração, onde atingiu o valor de 0,507, seguido de uma considerável queda na geração seguinte (0,228). Esse valor fica estável até a nonagésima geração, quando volta a ser refinado, até atingir seu valor final de 0,101 na 95ª geração. A célula v_{SE} é iniciada com um valor alto (0,975), que decresce para 0,375, já na quarta geração, e 0,215 na 11ª geração. Esse valor se mantém-se estável até a 75ª geração, quando volta a ser ajustado pelo algoritmo, atingindo seu valor final (0,103) na 82ª geração. A proximidade entre os valores de v_{NE} e v_{SE} visa reduzir o efeito de suas forças no desvio do vento para o norte e sul, respectivamente. O parâmetro que representa a força para o norte (v_N) é iniciado com 0,349 e, após um ligeiro aumento (0,371) na 11ª geração, mantém-se estável até a 96ª geração, quando atinge o seu valor final de 0,499. Por outro lado, a célula que representa a força para o sul (v_S) começa com um valor alto (0,971) e vai decaindo ao longo das gerações até atingir o valor final de 0,502.

Ao analisar o gráfico, nota-se que durante a execução do AG, a matriz de preferências é ajustada e seus valores seguem uma tendência ascendente ou descendente, até se estabilizarem, resultando em uma matriz equilibrada. Isto é, o AG foi capaz de encontrar valores similares (bem próximos) entre os parâmetros da parte superior (força para o sul) e seus equivalentes na parte inferior (força para o norte), minimizando, assim, o efeito de forças indesejadas na direção do vento resultante.

A Figura 66(b) apresenta a evolução normalizada dos parâmetros LQ e LR e da aptidão da melhor configuração a cada geração do algoritmo genético. A normalização dos valores LQ e LR foi feita para melhorar a visualização gráfica, utilizando min-max, com os valores dos domínios dos parâmetros (1 a 10 para LQ e 1 a 100 para LR). Como pode ser observado, os valores desses parâmetros são estabilizados a partir da vigésima geração, indicando a capacidade do algoritmo em ajustar rapidamente e com precisão esses parâmetros aos padrões observados nos dados de referência. O *fitness* sofre um declínio contínuo à medida que o AG evolui, mostrando que o algoritmo consegue refinar o conjunto de parâmetros ao longo das gerações.

6.4.5 Impacto do Deslocamento Temporal no Cálculo da Aptidão

Este experimento visa investigar o quão sensível o *fitness* é em função de eventuais deslocamentos temporais nos dados usados como referência. Em outras palavras, considerando a situação hipotética em que o modelo reproduz fielmente os dados de referência, mas com deslocamento na série temporal (atraso ou antecipação) dos reticulados gerados, a ideia é verificar o impacto desse ruído no processo de avaliação. Esta investigação foi novamente baseada no cenário com o vento na direção oeste e empregou os mesmos parâmetros adotados no modelo de referência. A Figura 67 mostra a mudança no valor de *fitness* em função da janela do deslocamento temporal. Nesse processo, os atrasos e antecipações na evolução dos reticulados ocorreram em janelas de até 4 intervalos de tempo, sendo que cada intervalo corresponde a 200 passos do AC. Dado que o modelo de propagação é baseado em um autômato celular probabilístico, mesmo quando não há qualquer deslocamento, existem diferenças na quantidade de células com fogo entre os reticulados. Esse comportamento está representado no gráfico através do valor médio do *fitness* quando o deslocamento é zero (2,56). Isso indica que indivíduos com *fitness* próximos a esse valor podem ser consideradas soluções ótimas. Ao aplicar um atraso de 4 intervalos de tempo (800 passos do AC), há um aumento de 1,72 no *fitness*. Com a antecipação em 4 intervalos de tempo, a aptidão aumenta em aproximadamente 0.59. Dessa maneira, percebe-se que a função de *fitness* adotada (baseada em 9 partições) é afetada pelos deslocamentos temporais, sendo mais sensível aos atrasos nos dados.

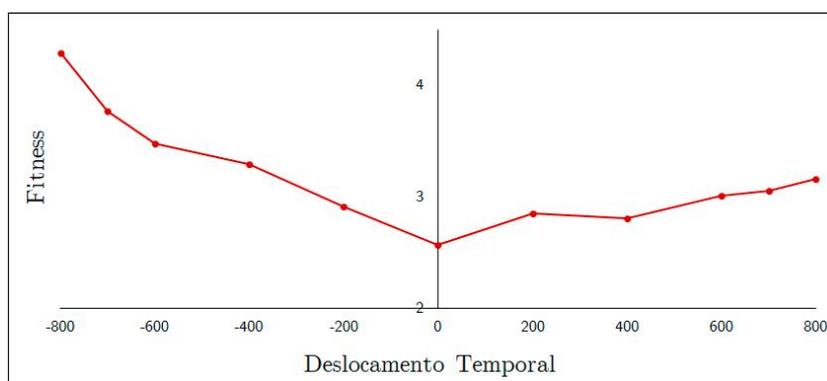


Figura 67 – Variação no *Fit9P* em função do deslocamento temporal dos reticulados na evolução do autômato celular.

6.5 Análise de Desempenho em Cenários Heterogêneos

Essa seção descreve os experimentos realizados com o modelo de autômato celular que permite a representação de diferentes tipos de vegetação (cenários heterogêneos). A

cada nova vegetação modelada, a quantidade de parâmetros aumenta, tornando o ajuste automático ainda mais complexo. Nos cenários investigados durante os experimentos, o algoritmo genético evolui 20, 30 ou 40 parâmetros, quando o número de regiões com vegetação distinta é 2, 3 ou 4, respectivamente. Os resultados desses experimentos são apresentados a seguir.

6.5.1 Simulações dos Cenários com Duas Vegetações

Nesta etapa, buscou-se aprimorar o ajuste evolutivo do modelo de propagação de incêndios baseado em AC para considerar ambientes cobertos por vegetação heterogênea. Para isso, primeiro foi necessário modificar o modelo anterior para lidar com cenários envolvendo dois tipos de vegetação (denominadas de Veg1 e Veg2, por simplicidade). Também foi necessário adaptar a função de aptidão do AG para lidar com cenários heterogêneos. Essa adaptação consiste em calcular um *fitness* para cada vegetação. Em seguida, os valores são normalizados usando min-max e aplica-se a média aritmética simples para obter a aptidão do indivíduo.

Nos quatro cenários investigados neste experimento, o reticulado é dividido igualmente entre as duas vegetações. Os dados de referência dos cenários foram gerados pelo próprio modelo de propagação de incêndio, usando a configuração definida para cada vegetação e variando apenas a direção do vento entre os cenários (oeste, leste, sul e noroeste). A Veg1 está localizada na parte inferior do reticulado e adota os mesmos valores de referência (LQ, LR e matriz de preferências) utilizados nos experimentos anteriores, resultando em um vento de intensidade 2,0. A parte superior do reticulado representa a Veg2 com menor tempo de queima (LQ = 2) e maior tempo de recuperação (LR = 90). Os parâmetros da matriz de preferências dessa vegetação foram definidos com a metade dos respectivos valores de referência originais, representando um vento de intensidade 1,0.

O cenário foi gerado a partir dos parâmetros mostrados na Figura 68(a). Como pode ser observado na Figura 68(b), a melhor execução do AG encontrou os mesmos valores para os 4 parâmetros LQ e LR e uma configuração bem próxima em ambas as matrizes de preferências, apresentando a mesma distribuição e equilíbrio entre os campos, com valores mais altos posicionados à direita, indicando um vento na direção oeste. A aptidão desse conjunto de parâmetros foi de 0,259 enquanto o desempenho médio do AG foi de $0,298 \pm 0,0085$. Essa similaridade também é percebida nos vetores de forças que representam os ventos modelados (Figuras 68(c) e 68(d)).

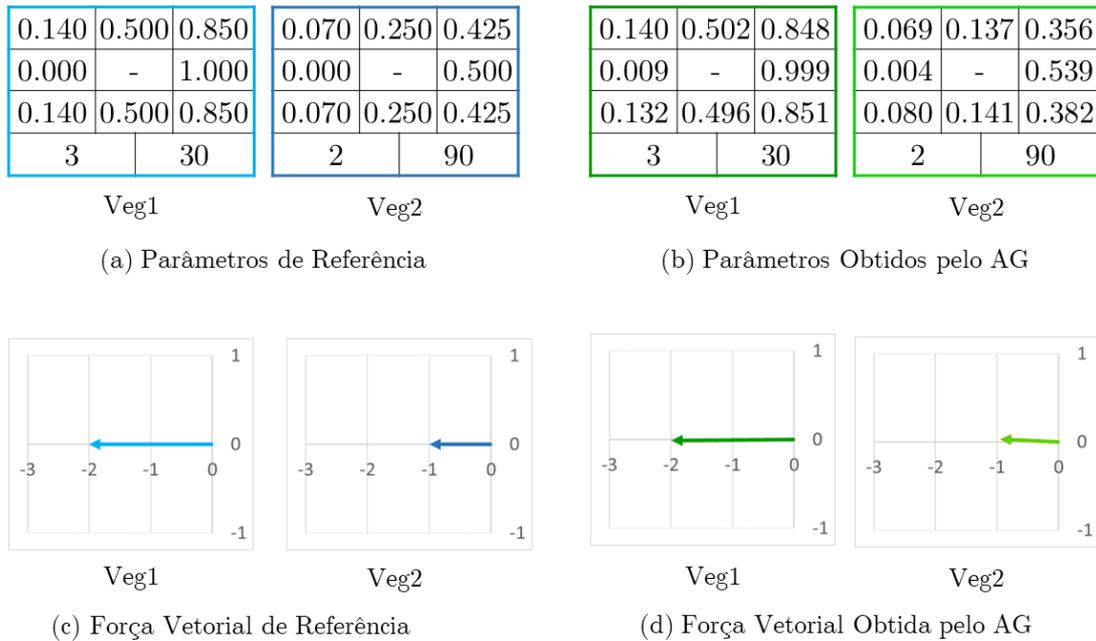


Figura 68 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 69 mostra as simulações de incêndio geradas para este cenário heterogêneo, considerando os cinco pontos distintos para o início do fogo. Em geral, a propagação do fogo na Veg1 com a configuração obtida pelo AG (Figura 69(b)) é mais semelhante a referência (Figura 69(a)) do que a Veg2. Dessa maneira, as piores reproduções são àquelas em que o fogo se inicia justamente na Veg2, uma vez que ele tende a permanecer na Veg2 e, apenas entre $t = 20$ e $t = 35$ atinge a outra vegetação, nesse caso, a Veg1. A pior reprodução foi observada na simulação onde o início do fogo está na partição superior direita. Também é possível perceber que o espalhamento do fogo pela Veg2 apresenta mais variações que na Veg1. Aparentemente, o modelo de referência tende a apresentar uma propagação um pouco mais acentuada nas demais direções. Isso pode ser justificado pela matriz de preferências obtida para a Veg2 que tem valores menores que os da referência nas posições mais à esquerda, o que resulta num vento com uma tendência levemente para o noroeste.

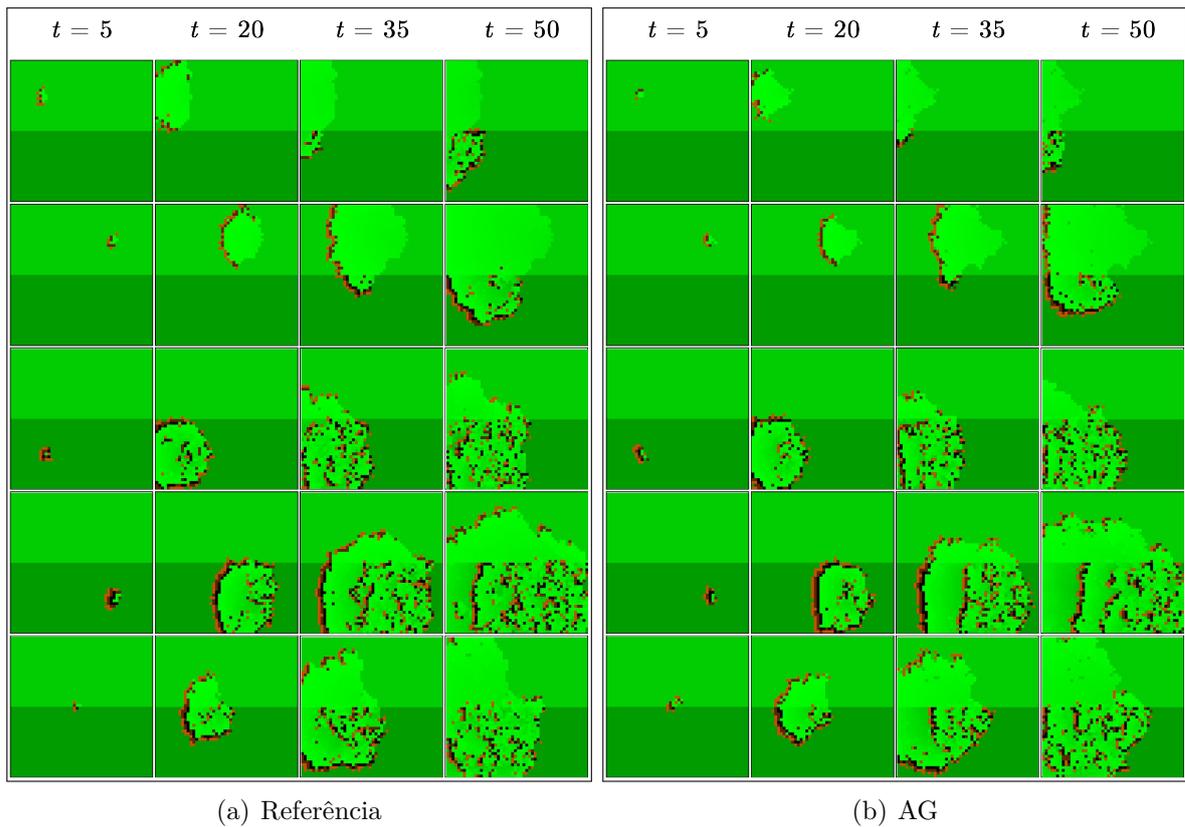


Figura 69 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG

O segundo cenário apresenta a mesma configuração de reticulado, isto é, a *Veg2* na parte superior e a *Veg1* na parte inferior. As matrizes de preferências foram rotacionadas, resultando em um vento para o leste. A Figura 70 mostra os parâmetros utilizados como referência e a melhor configuração obtida. O *fitness* do melhor indivíduo foi de 0,213, enquanto o *fitness* médio foi de $0,232 \pm 0,0005$. Conforme apresentado na Figura 70(b), os parâmetros encontrados para LQ e LR foram iguais aos do cenário de referência. As matrizes encontradas pelo AG apresentam valores semelhantes aos da referência (Figura 70(a)), com os campos equilibrado e os valores mais altos posicionados à esquerda, o que resulta um vento direcionado para o leste. Os vetores de forças (Figuras 70(c) e 70(d)) também apresentam intensidade semelhante. O vento da *Veg2* apresenta intensidade (0.95 vs 1.0) e ângulos (178 vs 180 graus) ligeiramente menores que a referência.

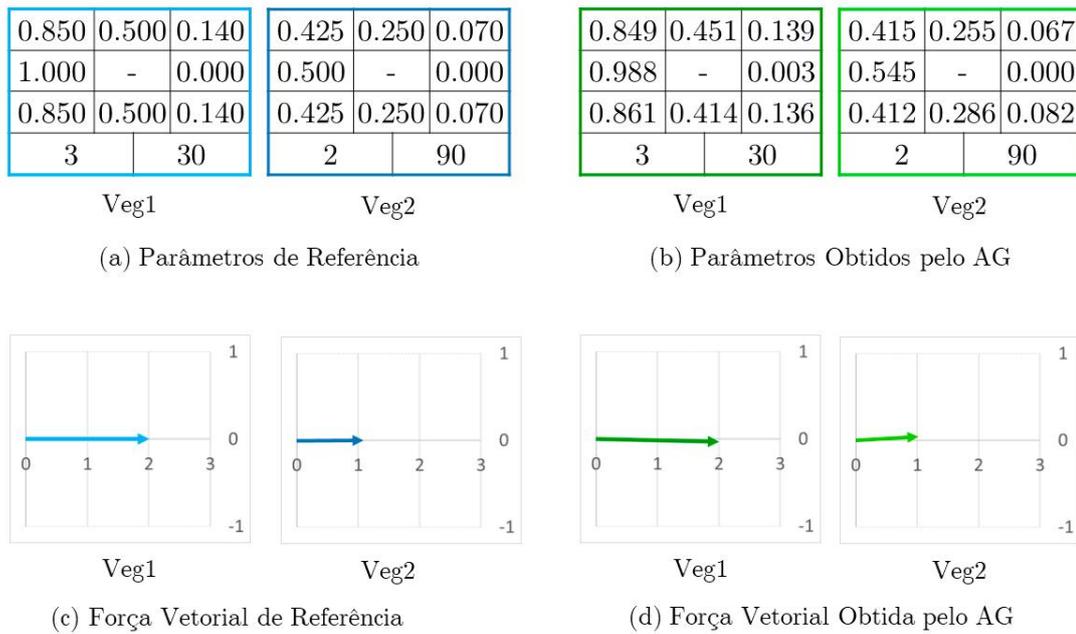


Figura 70 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção leste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 71 apresenta as simulações do modelo configurado pelo AG (Figura 71(b)) e o de referência (Figura 71(a)). Em todas as simulações, o modelo do AG apresentou uma propagação do fogo sentido leste do reticulado, independente do fogo inicial ou do tipo de vegetação. A pior simulação é aquela em que o fogo se inicia no ponto superior direito do reticulado. Nela, o fogo se espalha apenas pela Veg2 e não atinge a Veg1 como acontece na referência. Acredita-se que isso deve porque o vento da Veg2 tem uma angulação que o aponta levemente para o nordeste. Dessa maneira, o fogo se espalha nessa direção e distancia-se da Veg2. Por outro lado, nas simulações com o foco inicial de incêndio na Veg1, a propagação é mais semelhante.

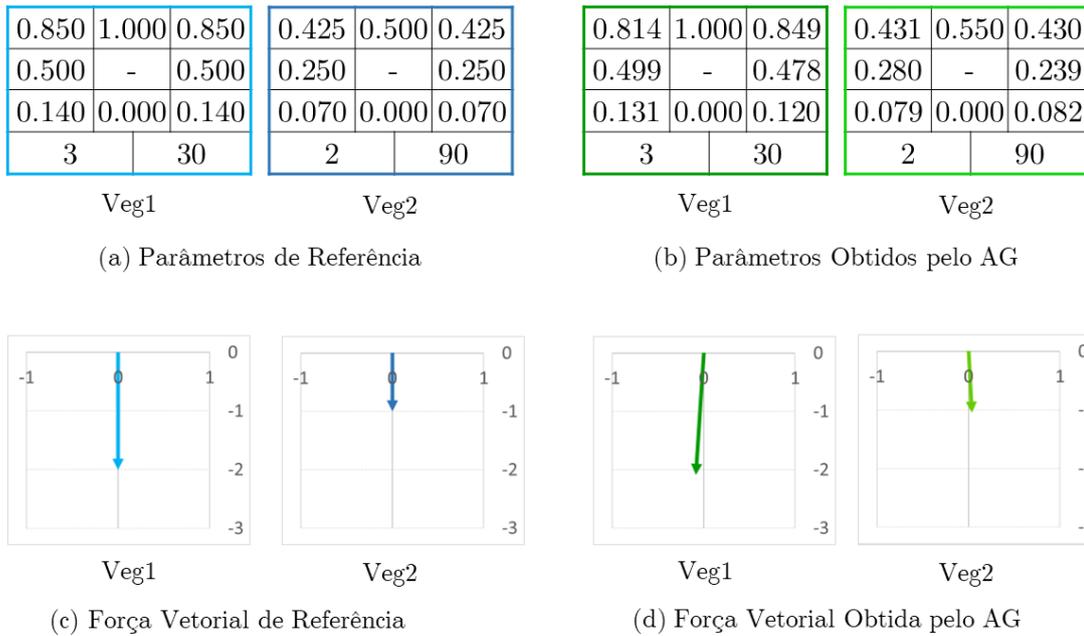


Figura 72 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção sul: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 73 apresenta as simulações de incêndio geradas a partir dos diferentes reticulados iniciais. É possível notar algumas alterações nas dinâmicas dos incêndios entre o modelo configurado pelo AG (Figura 73(b)) e o seu cenário de referência (Figura 73(a)). O fogo obtido com os valores do melhor indivíduo do AG se propaga predominantemente para o sul do reticulado, embora em uma velocidade menor que nas simulações de referência. Em relação aos tipos de vegetação, tanto na referência quanto nas simulações obtidas pelo AG, a Veg2 tem a propagação do fogo apenas nas simulações em que o fogo se inicia nessa vegetação. O fogo vai para a Veg1 entre $ot = 20$ e $t = 35$. Isso ocorre devido ao sentido de propagação do fogo, na direção sul. Na Veg1 por sua vez o fogo apresenta algumas alterações, indo para o sudoeste, devido a direção do vetor de forças. Apesar das diferenças apontadas, no geral, é possível concluir que o comportamento obtido pelo AG é semelhante.

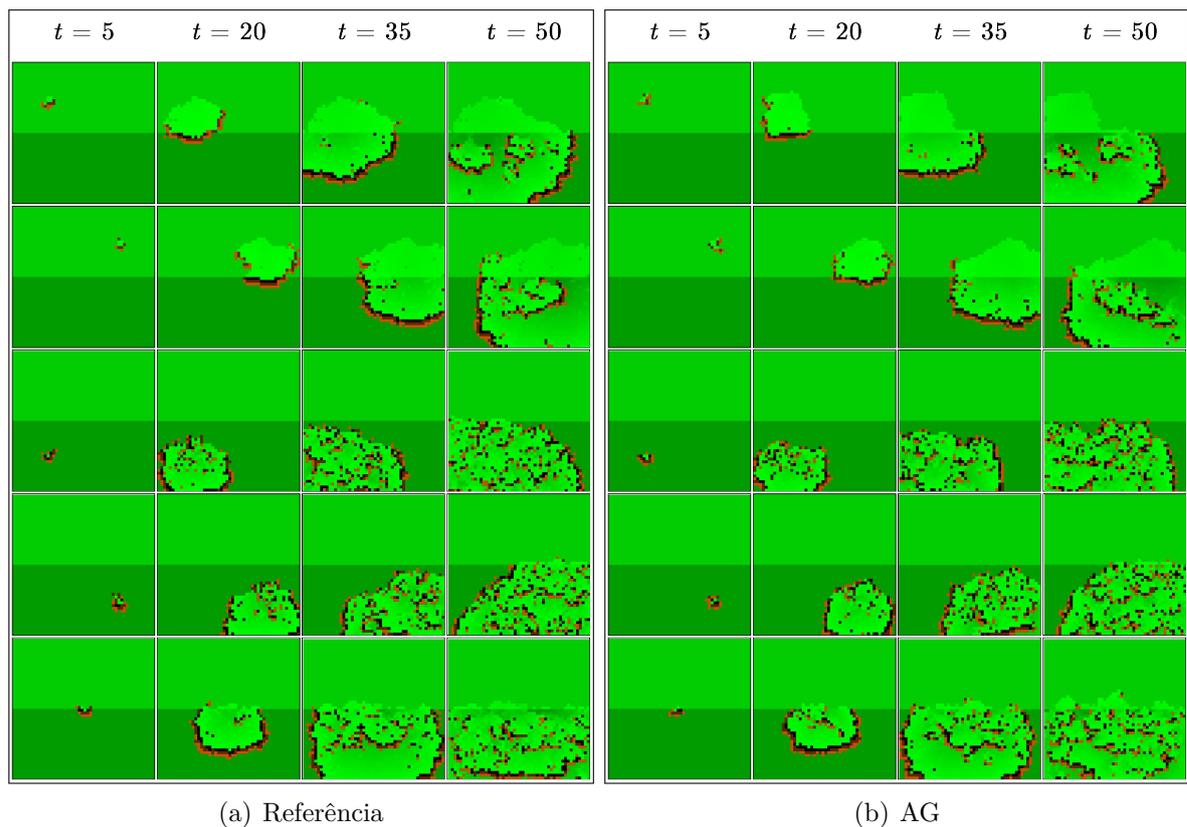


Figura 73 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção sul: (a) modelo de referência; e (b) modelo configurado pelo AG

Por fim, a Veg2 foi mantida na parte inferior do reticulado e a Veg1 na parte superior, mas o vento foi direcionado para o noroeste. Nesse cenário, o *fitness* médio das dez execuções do AG foi de 0,293, com desvio padrão de 0,008, e o melhor indivíduo teve uma aptidão de 0,0259. A Figura 74 apresenta os parâmetros (Figura 74(a)) e forças vetoriais de referência desse cenário (Figura 74(c)), bem como aqueles e obtidos pelo melhor indivíduo do AG ((Figura 74(b) e (d)). É possível perceber que o AG encontrou os valores LQ e LR. Ambas as matrizes obtidas pelo AG apresentam um balanceamento similar ao da referência, com os maiores campos na diagonal inferior esquerda. A intensidade do vento da Veg1 é um pouco maior que a da referência (2,1 vs 2.0), enquanto a Veg2 tem uma força vetorial com a mesma intensidade que a referência (1,0). A angulação é semelhante para as duas vegetações.

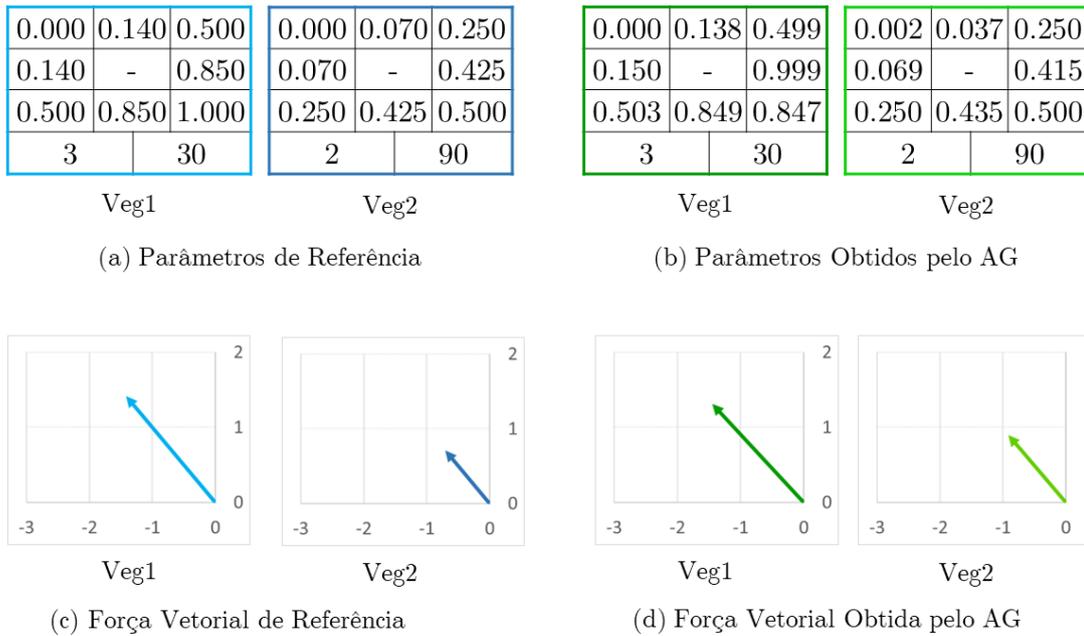


Figura 74 – Conjuntos de parâmetros e vetores de forças usados no cenário de duas vegetações com vento na direção noroeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 75 mostra as simulações de incêndio obtidas pelos modelos de referência e configurado pelo AG. Comparando as evoluções dos incêndios simulados pelos modelos de referência (Figura 75(a)) e configurado pelo AG (Figura 75(b)), é possível observar dinâmicas bem similares. O fogo se espalha na Veg1 com mais velocidade e intensidade, o que é provocado pela maior intensidade do vento. Assim, como o sentido da propagação é noroeste, quando o fogo se inicia na Veg1, ele atinge a parte superior do reticulado (Veg2) um pouco mais rápido do que no cenário de referência.

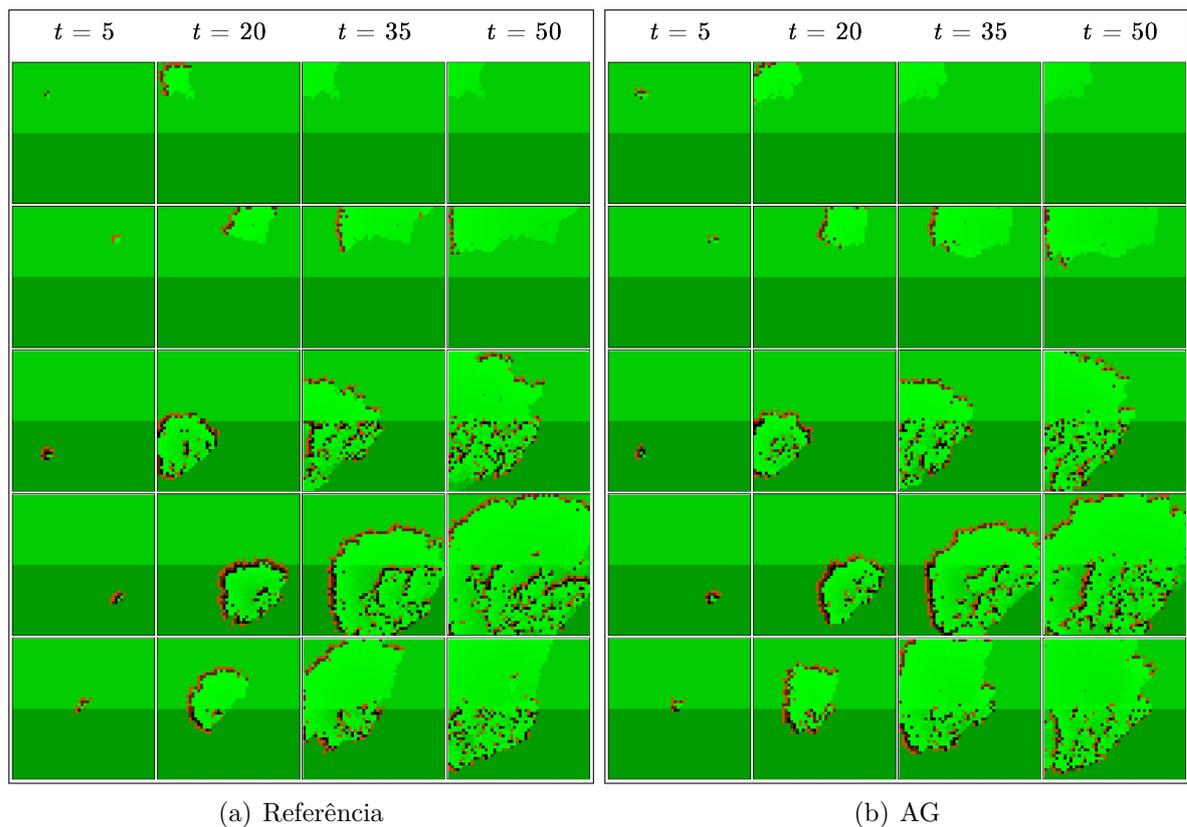


Figura 75 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de duas vegetações com vento na direção noroeste: (a) modelo de referência; e (b) modelo configurado pelo AG

No geral, o algoritmo genético foi capaz de ajustar automaticamente os parâmetros das matrizes de vento e de LQ, LR, resultando em dinâmicas similares de propagação do fogo em todos os cenários heterogêneos com duas vegetações distintas. Nos experimentos dessa seção, foi possível notar que o AG apresentou um erro um pouco maior em relação aos experimentos da seção 6.4 realizados com uma única vegetação, principalmente na direção do vento. Apesar dessas diferenças, é possível concluir que o AG conseguiu apresentar um bom desempenho, apesar do número de parâmetros a ser ajustado ter dobrado passando de 10 para 20 parâmetros.

6.5.2 Simulações dos Cenários com Três Vegetações

O objetivo deste experimento é analisar o comportamento do algoritmo genético ao ajustar 30 parâmetros (10 por vegetação) do modelo ao empregar cenários heterogêneos formados por regiões com três vegetações distintas. Cada vegetação modelada neste experimento possui tempos diferentes de queima e recuperação. Os valores de LQ utilizados foram (3, 2, 6), respectivamente, enquanto LR foi configurado com os valores (30, 90, 20). Nesta etapa, as matrizes de preferência definiram um vento para o oeste e apenas a intensidade foi alterada, já que em um ambiente real o tipo de vegetação afeta a intensidade e

a velocidade de propagação do fogo, mas não necessariamente altera a direção de propagação do incêndio. Além das vegetações descritas no experimento anterior, foi adicionada uma terceira vegetação (Veg3) no cenário (Veg3), a qual apresenta o maior tempo queima ($LQ=6$) e o menor tempo de recuperação ($LR=20$). Nesse experimento, o posicionamento das vegetações no reticulado variou entre os três cenários.

No primeiro cenário, a Veg3 é a vegetação dominante e ocupa a metade esquerda do reticulado. As outras vegetações ocupam igualmente a outra metade, sendo que a Veg2 ocupa a partição superior direita, enquanto a Veg1 ocupa a partição inferior direita. Esse cenário foi gerado a partir dos parâmetros mostrados na Figura 76(a). O melhor indivíduo uma aptidão de 0,0509 e seus valores são mostrados na Figura 76(c). O *fitness* médio foi de $0,0521 \pm 0,0006$. Como é possível observar, o indivíduo obtido pelo AG encontrou os valores de LQ e LR iguais aos do cenário de referência. Para cada vegetação as matrizes de preferências tem os maiores valores nos campos localizados a direita, resultando em ventos para o oeste (Figura 76(d)), assim como na referência (Figura 76(b)). Para todas as vegetações, há uma angulação levemente maior no indivíduo obtido pelo AG. A intensidade do vento é a mesma na Veg1, mas menor na Veg2 (0,96) e maior na Veg3 (1,17).

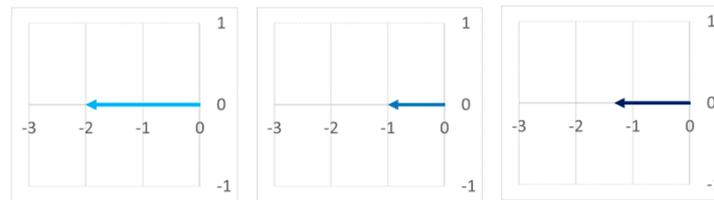
0.140	0.500	0.850	0.070	0.250	0.425	0.093	0.333	0.560
0.000	-	1.000	0.000	-	0.500	0.000	-	0.666
0.140	0.500	0.850	0.070	0.250	0.425	0.093	0.333	0.560
3	30	2	90	6	20			

Veg1

Veg2

Veg3

(a) Parâmetros de Referência



Veg1

Veg2

Veg3

(b) Forças Vetoriais de Referência

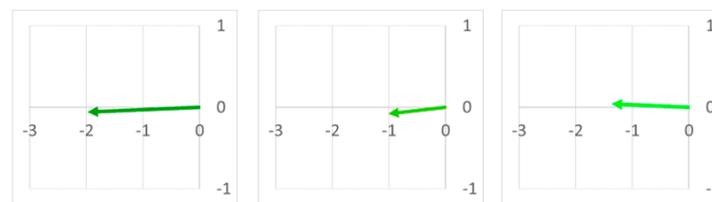
0.100	0.559	0.790	0.090	0.240	0.415	0.092	0.218	0.579
0.000	-	1.000	0.000	-	0.509	0.000	-	0.700
0.099	0.494	0.800	0.010	0.228	0.400	0.080	0.299	0.537
3	30	2	90	6	20			

Veg1

Veg2

Veg3

(c) Parâmetros Obtidos pelo AG



Veg1

Veg2

Veg3

(d) Forças Vetoriais Obtidas pelo AG

Figura 76 – Conjuntos de parâmetros e vetores de forças usados no cenário de três vegetações com a Veg3 dominante: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 77 mostra as simulações de incêndio geradas para o cenário com dominância da Veg3. Na Veg1, em geral, a propagação de fogo com a configuração obtida pelo AG (Figura 77(b)) é mais semelhante à referência (Figura 77(a)) do que a Veg2 e a Veg3. Na reprodução em que o fogo se inicia no noroeste (segunda simulação), é possível observar mais similaridades com a referência. Pode-se perceber também que a pior simulação é aquela em que o fogo se inicia na posição central do reticulado. Ou seja, próximo à fronteira entre as três regiões distintas. Na simulação obtida com a configuração do AG, o fogo na Veg3 se espalha mais em direção ao noroeste do reticulado, o que pode ser justificado pelo vetor de forças que apresenta essa angulação.

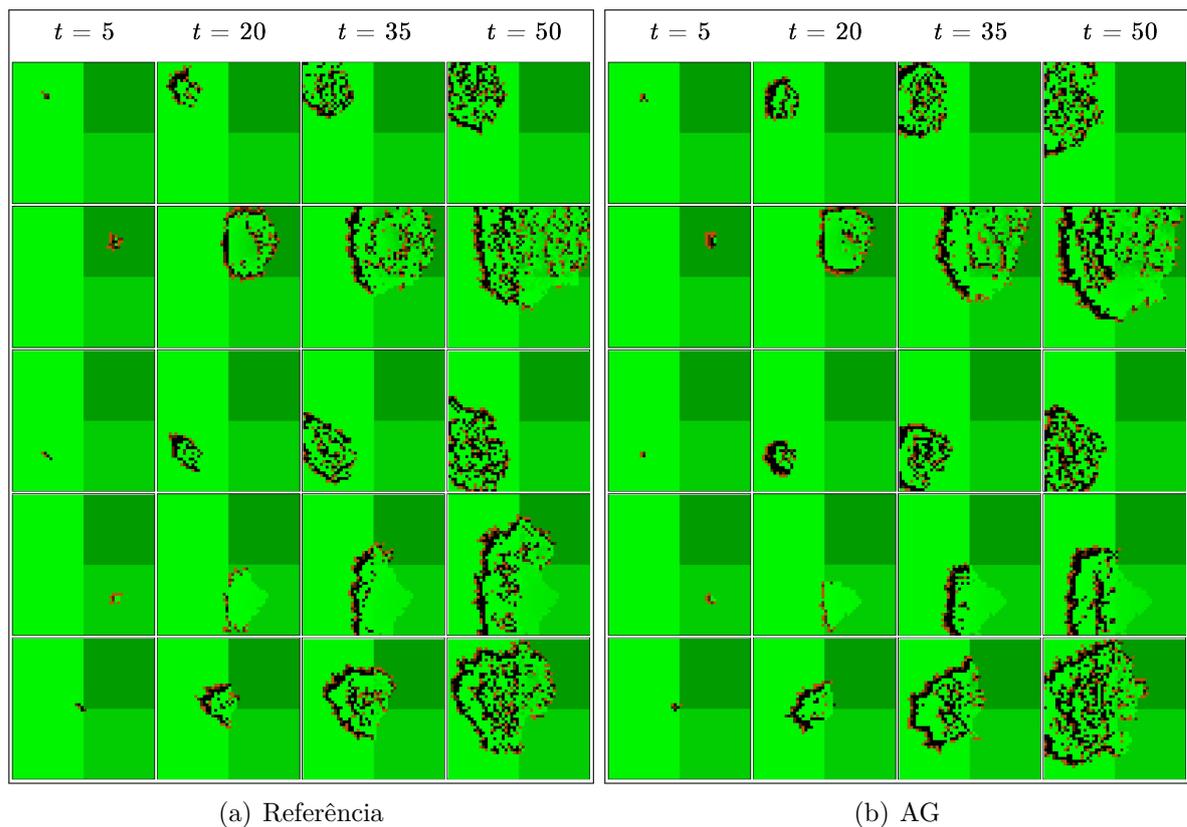


Figura 77 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de três vegetações com a Veg3 dominante: (a) modelo de referência; e (b) modelo configurado pelo AG.

No segundo cenário, a vegetação dominante foi a Veg2, ocupando toda a parte direita do reticulado, enquanto a Veg1 ocupou a parte superior esquerda e a Veg3 a parte inferior esquerda. A Figura 78 apresenta os parâmetros (Figura 78(a)) e forças vetoriais de referência desse cenário (Figura 78(b)), bem como aqueles e obtidos pelo melhor indivíduo do AG ((Figura 78(c) e (d)). O melhor indivíduo obteve uma aptidão de 0,509, *fitness* médio de 0,059 e desvio padrão de 0,0005. O AG obteve matrizes de preferências de todas as vegetações com os maiores valores à direita assim como na referência. Essas matrizes apresentam um leve desequilíbrio nas posições que correspondem ao nordeste e sudeste, o que faz com que as forças vetoriais apresentem uma angulação (178 graus pra a Veg1, 177 para a Veg2 e 182 para a Veg3). A intensidade é semelhante para todas as vegetações. Neste cenário, o AG também encontrou os valores de LQ (3, 2 e 6, respectivamente) e LR (30, 90 e 20, respectivamente).

0.140	0.500	0.850
0.000	-	1.000
0.140	0.500	0.850
3	30	

0.070	0.250	0.425
0.000	-	0.500
0.070	0.250	0.425
2	90	

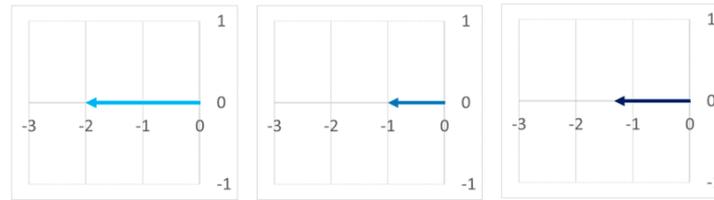
0.093	0.333	0.560
0.000	-	0.666
0.093	0.333	0.560
6	20	

Veg1

Veg2

Veg3

(a) Parâmetros de Referência



Veg1

Veg2

Veg3

(b) Forças Vetoriais de Referência

0.144	0.489	0.819
0.003	-	0.990
0.135	0.445	0.950
3	30	

0.061	0.214	0.429
0.000	-	0.500
0.059	0.251	0.437
2	90	

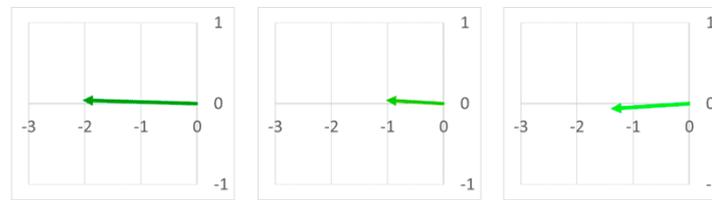
0.023	0.346	0.562
0.000	-	0.655
0.010	0.311	0.521
6	20	

Veg1

Veg2

Veg3

(c) Parâmetros Obtidos pelo AG



Veg1

Veg2

Veg3

(d) Forças Vetoriais Obtidas pelo AG

Figura 78 – Conjuntos de parâmetros e vetores de forças usados no cenário de três vegetações com a Veg2 dominante: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 79 apresenta as simulações do modelo configurado pelo AG (Figura 79(b)) e o de referência (Figura 79(a)). Em todas as simulações o fogo se propaga para a direção oeste de reticulado. Apesar das propagações não serem exatamente iguais, o comportamento é bastante semelhante, comparado com as simulações de referência. Na simulação em que o fogo se inicia no centro do reticulado, este se espalha inicialmente para a Veg1 e em $t = 20$ atinge a Veg3. Na referência, a Veg2 é atingida pelo fogo em $t = 50$, mas no indivíduo configurado pelo AG isso não ocorre e nesse instante de tempo na referência a propagação na Veg2 é mais arredondada, enquanto na do AG o fogo atinge o sul do reticulado. Acredita-se que isso pode ser justificado pela angulação diferente da força vetorial.

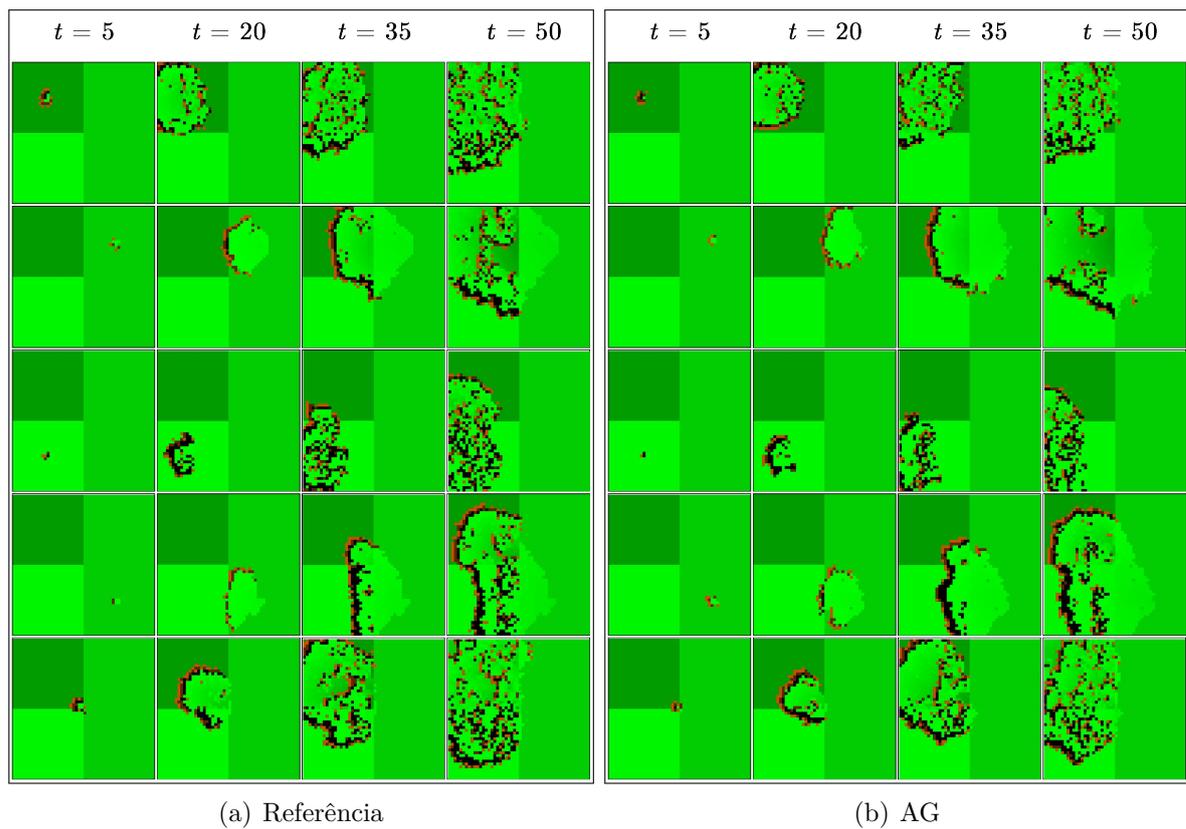


Figura 79 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de três vegetações com a Veg2 dominante: (a) modelo de referência; e (b) modelo configurado pelo AG.

No último cenário, a vegetação dominante foi a Veg1, posicionada na posição inferior do reticulado. A Veg2 ocupou a parte superior esquerda e a Veg3 a parte superior direita. Considerando todas as 10 execuções do AG, o melhor indivíduo encontrado apresenta uma aptidão de 0,0553, enquanto que o *fitness* médio das execuções foi de 0,0563, com um desvio padrão de 0,0005. Como mostrado na Figura 80(c), os valores dos parâmetros LQ e LR obtidos pelo AG também são iguais aos da referência. As matrizes de preferências apresentam um balanceamento similar aos da referência (Figura 80(a)), embora os valores não sejam iguais. Os maiores valores estão na esquerda. Na Veg1 e na Veg2 há um leve desequilíbrio entre a posição superior esquerda e a inferior esquerda, o que resulta em uma angulação de 177 graus nas forças vetoriais (Figura 80(b)) que é menor que a referência (Figura 80(d)).

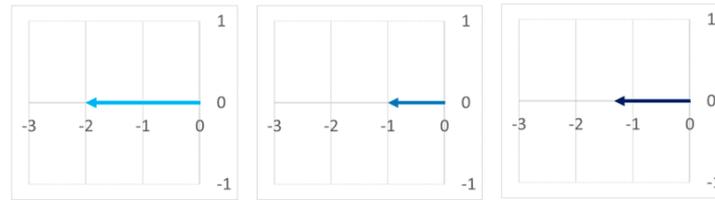
0.140	0.500	0.850	0.070	0.250	0.425	0.093	0.333	0.560
0.000	-	1.000	0.000	-	0.500	0.000	-	0.666
0.140	0.500	0.850	0.070	0.250	0.425	0.093	0.333	0.560
3	30	2	90	6	20			

Veg1

Veg2

Veg3

(a) Parâmetros de Referência



Veg1

Veg2

Veg3

(b) Forças Vetoriais de Referência

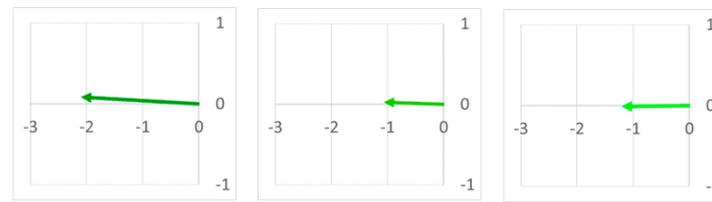
0.141	0.400	0.966	0.000	0.247	0.400	0.094	0.400	0.488
0.000	-	1.000	0.000	-	0.494	0.000	-	0.621
0.108	0.594	0.841	0.010	0.250	0.421	0.072	0.398	0.500
3	30	2	90	6	20			

Veg1

Veg2

Veg3

(c) Parâmetros Obtidos pelo AG



Veg1

Veg2

Veg3

(d) Forças Vetoriais Obtidas pelo AG

Figura 80 – Conjuntos de parâmetros e vetores de forças usados no cenário de três vegetações com a Veg1 dominante: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

Enquanto a Figura 81(a) mostra o comportamento do incêndio simulado a partir do modelo de referência, a Figura 81(b) ilustra a simulação resultante do modelo configurado com os parâmetros encontrados pelo AG. Nas duas simulações, o fogo vai para o oeste do reticulado. Como as matrizes de preferências definidas pelo AG possuem valores maiores nas posições da esquerda, a angulação do vento não leva o fogo apenas para o oeste do reticulado, mas também para o noroeste. Todavia, o comportamento da propagação é similar.

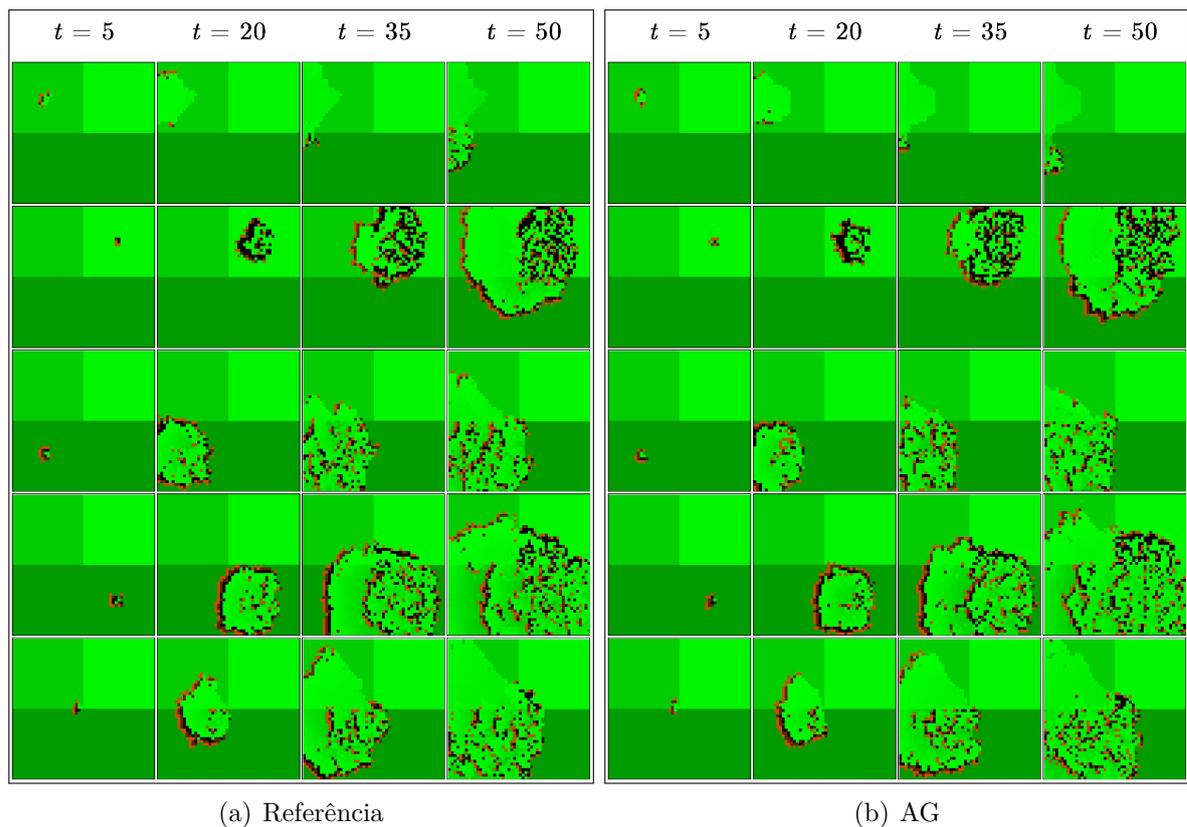


Figura 81 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no cenário de três vegetações com a Veg1 dominante: (a) modelo de referência; e (b) modelo configurado pelo AG.

Nesse experimento, houve o aumento de parâmetros evoluídos pelo AG. Embora, o AG não tenha reproduzido com exatidão os valores dos 24 parâmetros das matrizes de vento, a intensidade e direção do vento foram encontradas, independentemente da configuração de cada tipo de vegetação no reticulado. Além disso, os 6 parâmetros de LQ e LR foram encontrados pelo algoritmo genético. No geral, a propagação de fogo em todos os cenários apresentou similaridade com a referência.

6.5.3 Simulações dos Cenários com Quatro Vegetações

Os experimentos descritos nesta seção objetivam analisar o comportamento do algoritmo genético em ajustar os 40 parâmetros (10 para cada tipo de vegetação) de um modelo que representa um cenário mais complexo, com 4 tipos de vegetações. Na definição da configuração de referência de cada vegetação modelada, os valores de LQ e LR foram fixados nos seguintes pares: (3, 30), (2, 90), (6, 20) e (8, 60). Além disso, todas as matrizes de preferências resultaram em vento com direção ao oeste, alterando apenas a intensidade, uma vez que em um ambiente real, o tipo de vegetação afeta a intensidade e velocidade de propagação do fogo, mas não necessariamente altera a sua direção.

No primeiro cenário, o reticulado foi configurado da seguinte maneira: Veg2 na partição

superior esquerda, Veg4 na partição superior direita, Veg1 na partição inferior esquerda e Veg3 na partição inferior direita. Esse cenário foi gerado a partir dos parâmetros apresentados na Figura 82(a). A configuração obtida pelo melhor indivíduo (Figura 82(c)) teve aptidão de 0,0803, enquanto o desempenho médio do AG foi de $0,0844 \pm 0,0023$. O AG encontrou os mesmos valores para os 8 parâmetros de LQ e LR e uma configuração similar para as matrizes de preferências com um equilíbrio entre os campos e os maiores valores à direita, resultando em um vento direcionado para o oeste. Como mostra a Figura 82(d), nas vegetações Veg1 e Veg2 há campos à direita com valores mais altos, o que resulta em forças vetoriais com maior angulação que a de referência (Figura 82(b)).

0.140	0.500	0.850	0.070	0.250	0.425	0.093	0.333	0.560	0.030	0.072	0.193
0.000	-	1.000	0.000	-	0.500	0.000	-	0.666	0.000	-	0.233
0.140	0.500	0.850	0.070	0.250	0.425	0.093	0.333	0.560	0.030	0.072	0.193
3	30	2	90	6	20	8	60				

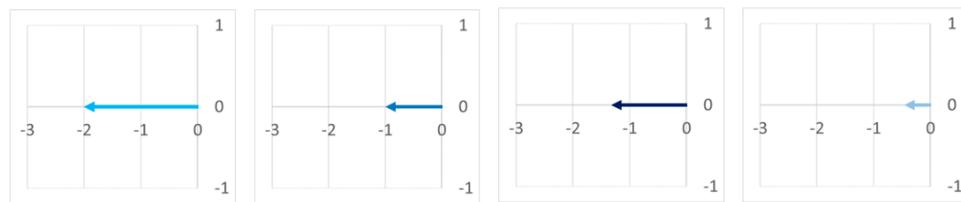
Veg1

Veg2

Veg3

Veg4

(a) Parâmetros de Referência



Ve1g1

Veg2

Veg3

Veg4

(b) Forças Vetoriais de Referência

0.159	0.539	0.944	0.073	0.188	0.410	0.063	0.249	0.480	0.080	0.103	0.201
0.040	-	0.981	0.000	-	0.509	0.000	-	0.688	0.010	-	0.311
0.130	0.554	0.798	0.053	0.268	0.388	0.053	0.204	0.525	0.080	0.083	0.214
3	30	2	90	6	20	8	60				

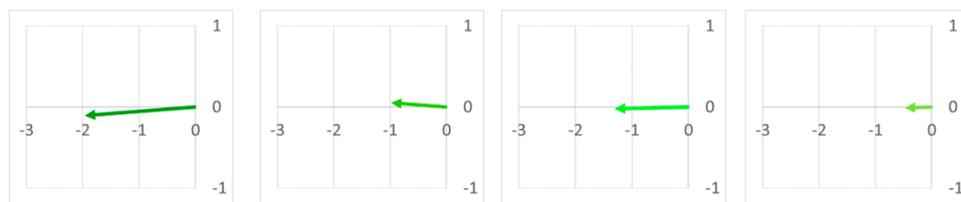
Veg1

Veg2

Veg3

Veg4

(c) Parâmetros Obtidos pelo AG



Ve1g1

Veg2

Veg3

Veg4

(d) Forças Vetoriais Obtidas pelo AG

Figura 82 – Conjuntos de parâmetros e vetores de forças usados no primeiro cenário de quatro vegetações com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 83 mostra as simulações de incêndio geradas para este cenário heterogêneo, considerando os cinco pontos distintos para o início do fogo. A estratégia de evolução em vários pontos do reticulado é fundamental nessa etapa uma vez que em alguns pontos iniciais o fogo tende a permanecer em partes do reticulado que são ocupadas por uma ou duas vegetações, como na terceira e primeira simulações. Em geral, o comportamento da configuração obtida pelo AG (Figura 83(b)) é semelhante a referência (Figura 83(a)). É possível perceber que os espalhamentos nas vegetações Veg1 e Veg2 apresentam mais variações, o que pode ser justificado pela angulação das forças vetoriais.

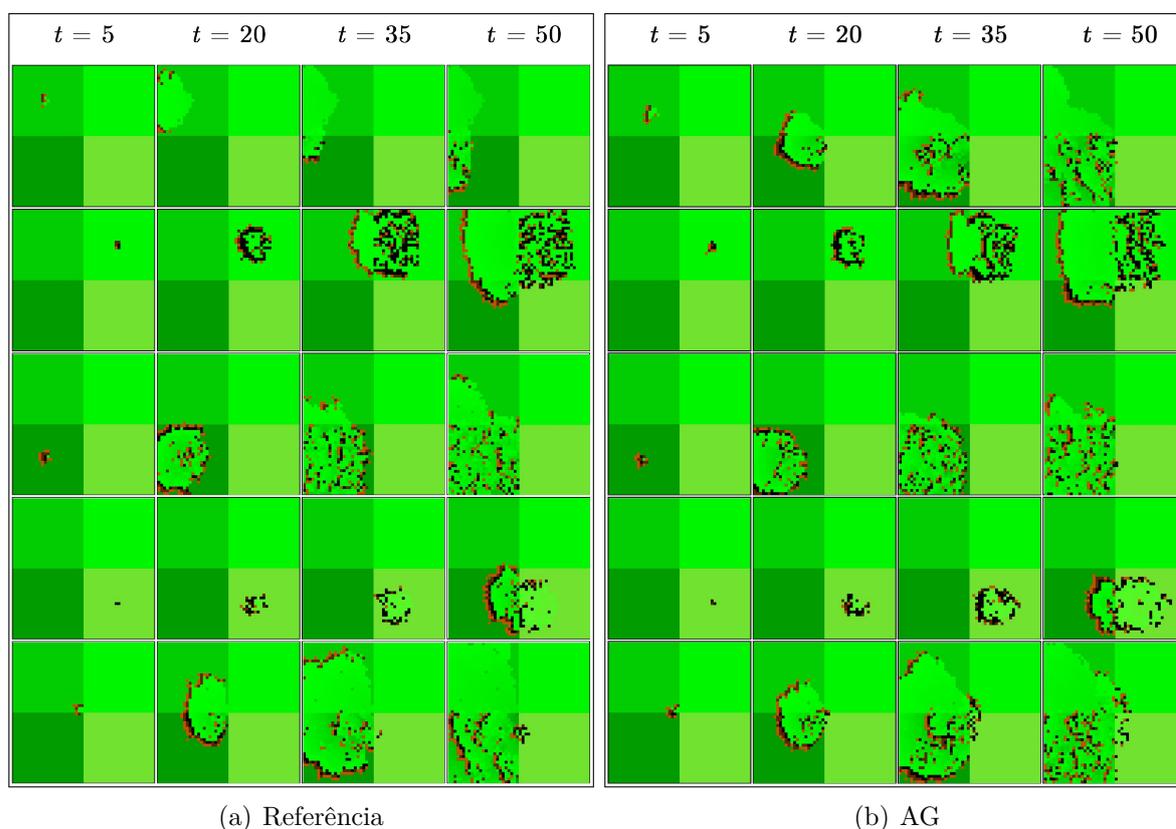
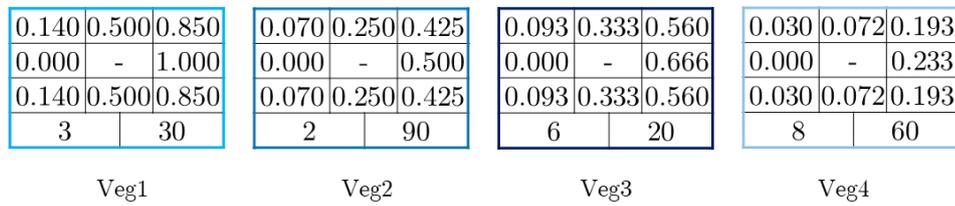


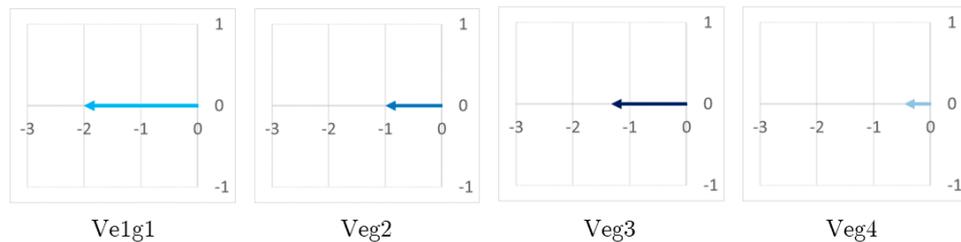
Figura 83 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no primeiro cenário de quatro vegetações com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG

No segundo cenário, a disposição das vegetações pelo reticulado foi alterada para Veg1 na partição superior esquerda, Veg2 na partição superior direita, Veg3 na partição inferior esquerda e Veg4 na partição inferior direita. A Figura 84(a) mostra os parâmetros de referência e a Figura 84(c) a melhor configuração obtida pelo AG, que teve como aptidão 0,0957, enquanto o *fitness* médio foi de $0,983 \pm 0,00052$. O indivíduo obtido pelo AG encontrou os valores de LQ e LR iguais aos do cenário de referência. Para cada vegetação as matrizes de preferências têm os maiores valores nos campos localizados a direita, resultando em ventos para o oeste (Figura 84(d)), assim como na referência (Figura 84(b)). Nas vegetações Veg1 e Veg3, as posições inferior direita e

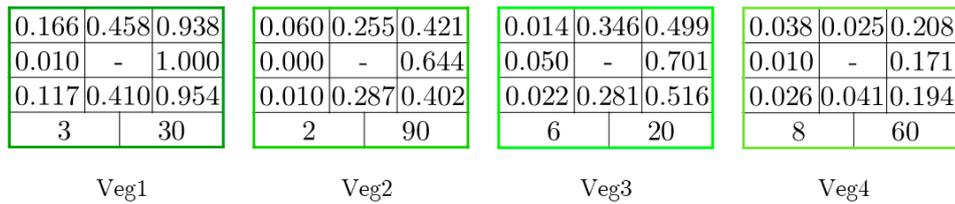
superior direita apresentam valores levemente mais altos, o que resulta em uma angulação levemente maior (181 e 182 graus, respectivamente) que a referência (180 graus).



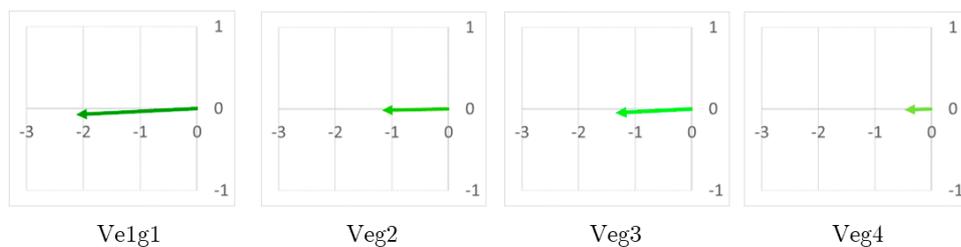
(a) Parâmetros de Referência



(b) Forças Vetoriais de Referência



(c) Parâmetros Obtidos pelo AG



(d) Forças Vetoriais Obtidas pelo AG

Figura 84 – Conjuntos de parâmetros e vetores de forças usados no segundo cenário de quatro vegetações com vento na direção oeste: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 85 mostra as simulações de incêndio geradas para o segundo cenário. Os espalhamentos nas vegetações Veg1 e Veg3 apresentam mais variações, o que pode ser justificado pela angulação das forças vetoriais. Nesse cenário, na terceira e quarta simulações, o fogo também permanece em apenas uma vegetação, o que volta a destacar a importância da avaliação em vários pontos. Todavia, no geral, o comportamento da propagação é similar.

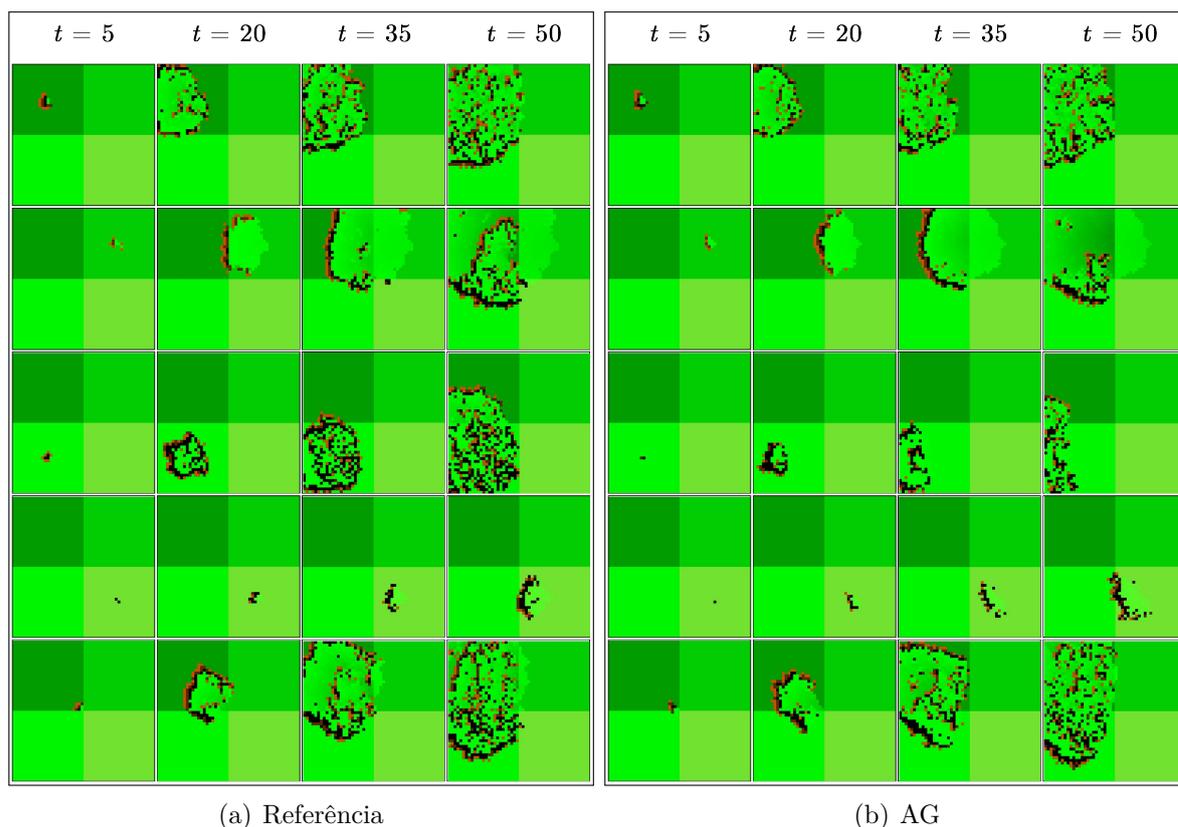


Figura 85 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no segundo cenário de quatro vegetações com vento na direção oeste: (a) modelo de referência; e (b) modelo configurado pelo AG)

Nos experimentos com 4 vegetações, a quantidade de parâmetros evoluída pelo AG é 40. Nesse cenário, o algoritmo genético conseguiu acertar os 8 valores de LQ e LR, além de encontrar matrizes de preferências com intensidade e direção similares às utilizadas para gerar a base de referência. Nesse sentido, destaca-se que a dificuldade do problema aumenta consideravelmente com o acréscimo de mais uma vegetação e ainda assim o algoritmo genético conseguiu reproduzir o comportamento da referência, independentemente da localização de cada vegetação no reticulado. Esse experimento mostra que a utilização de um número maior de regiões com vegetações com características distintas torna a reprodutibilidade das simulações uma tarefa mais complexa. De fato, ainda que se faça uma nova simulação utilizando exatamente os mesmos parâmetros utilizados na geração da base de dados de referência, o aumento na complexidade dos cenários faz com que a diferença visual entre as simulações seja acentuada. Isso ocorre pela própria natureza estocástica do modelo e porque as simulações passam a ser mais dependentes dos estados das células nas fronteiras entre as regiões. Entretanto, a despeito dessa dificuldade de reprodutibilidade da dinâmica da propagação, foi possível observar que o AG foi capaz de capturar as principais características dos ambientes, ajustando parâmetros com valores próximos aos utilizados na geração das bases. Ou seja, apesar do aumento da complexi-

bilidade. o AG foi capaz de fazer um ajuste aceitável dos parâmetros das 4 regiões.

6.5.4 Cenários baseados nas Vegetações do Parque Estadual Pau Furado

Os experimentos descritos nessa seção objetivam analisar o comportamento do algoritmo genético diante de um reticulado com distribuição irregular das vegetações, reproduzindo um cenário real, similar ao encontrado no bioma do Cerrado.

Para gerar cenários aproximados, foram selecionados trechos específicos de vegetação do Parque Estadual do Pau Furado, localizado em Uberlândia, Minas Gerais. Esses trechos foram extraídos do mapa de vegetação dessa reserva ambiental. O mapa utilizado (IEF, 2011) foi gerado com base nas imagens de satélite da região.

Os processos de captura e de processamento de dados das imagens reais de satélite de uma determinada região, bem como sua conversão automática para a representação das vegetações em um modelo de autômato celular não faz parte do escopo deste trabalho, que busca desenvolver um mecanismo evolutivo de ajuste automático de modelos de propagação de incêndios baseados em autômatos celulares. Dessa maneira, para gerar a configuração do reticulado, dois trechos com quatro tipos de vegetações foram selecionados manualmente e, por meio do *software* de edição Photoshop, fez-se uma reprodução aproximada da região. As imagens geradas foram processadas utilizando o *software* Matlab, gerando uma representação tridimensional, com as cores RGB (ROCHA, 2010), para cada tipo de vegetação. Por fim, um programa escrito em JavaScript constrói os reticulados do autômato celular a partir dessas estruturas 3D. Esse processo possibilita capturar a distribuição espacial das vegetações. Entretanto, ele não fornece qualquer informação acerca dos incêndios na região. Portanto, assim como nos demais experimentos, a base de referência também foi gerada artificialmente a partir de uma configuração arbitrária das vegetações de cada cenário.

A Figura 86 ilustra a região usada no primeiro cenário com vegetação heterogênea. A figura apresenta a imagem satélite e o mapa de vegetação do Parque Estadual do Pau Furado, bem como destaca a região modelada, com suas 4 vegetações distintas, representadas nas cores verde, amarelo, roxo e marrom.

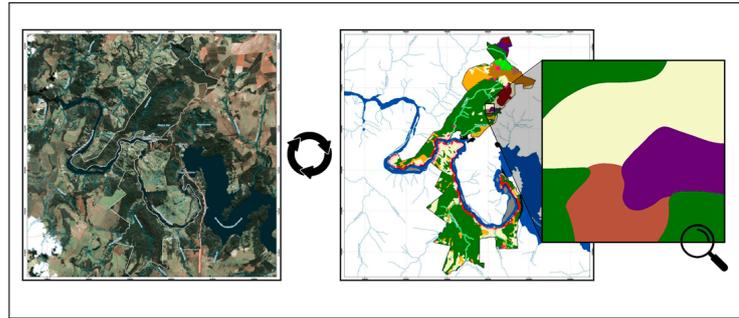


Figura 86 – Região do Parque Estadual do Pau Furado representada no primeiro cenário avaliado.

Os parâmetros de LQ e LR utilizados foram os mesmos empregados nos experimentos com 4 vegetações ((3,30), (2,90), (6,20) e (8,60)). Também foram utilizados os mesmos valores para as matrizes de preferência, mas com uma rotação no sentido horário. Dessa forma, os ventos resultantes mantém as mesmas intensidades, mas sopram na direção noroeste.

A Figura 87 mostra os parâmetros de referência (Figura 87(a)) e os obtidos na execução do AG (Figura 87(c)). É possível perceber que mesmo não obtendo exatamente os mesmos parâmetros para as quatro matrizes de preferências, o AG resultou em forças vetoriais (Figura 87(d)) semelhantes, tanto na intensidade, quanto na direção, que aquelas geradas a partir da configuração de referência (Figura 87(b)). O melhor indivíduo do AG obteve uma aptidão de 0,093, enquanto o *fitness* médios das execuções foi de $0,094 \pm 0,0009$.

0.000	0.140	0.500	0.000	0.070	0.250	0.000	0.093	0.333	0.000	0.030	0.072
0.140	-	0.850	0.070	-	0.425	0.093	-	0.560	0.030	-	0.193
0.500	0.500	1.000	0.250	0.425	0.500	0.333	0.560	0.666	0.072	0.193	0.233
3	30		2	90		6	20		8	60	

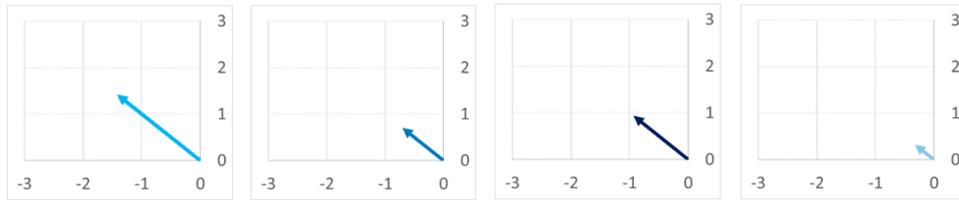
Veg1

Veg2

Veg3

Veg4

(a) Parâmetros de Referência



Ve1g1

Veg2

Veg3

Veg4

(b) Forças Vetoriais de Referência

0.000	0.024	0.300	0.011	0.061	0.014	0.002	0.061	0.140	0.002	0.074	0.324
0.127	-	0.888	0.000	-	0.411	0.000	-	0.434	0.010	-	0.600
0.569	0.846	1.000	0.227	0.409	0.499	0.053	0.409	0.499	0.301	0.516	0.600
3	30		2	90		6	20		8	60	

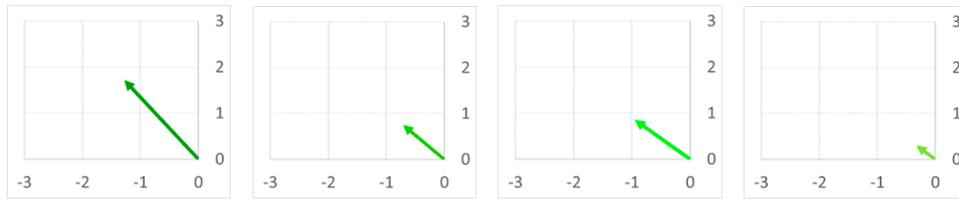
Veg1

Veg2

Veg3

Veg4

(c) Parâmetros Obtidos pelo AG



Ve1g1

Veg2

Veg3

Veg4

(d) Forças Vetoriais Obtidas pelo AG

Figura 87 – Conjuntos de parâmetros e vetores de forças usados no primeiro cenário representando região do Parque Estadual do Pau Furado: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

Como é possível perceber, na evolução temporal mostrada na Figura 88, o comportamento das simulações relativas aos parâmetros obtidos pelo AG é aos obtidos a partir do modelo de referência, com o fogo se espalhando do foco inicial em direção ao noroeste do reticulado. O comportamento que apresenta menos similaridade com a base de referência é o da quarta simulação (Figura 88(b)), em que fogo não se espalha na Veg3 (representada de marrom) com a mesma intensidade da referência ((Figura 88(a))).

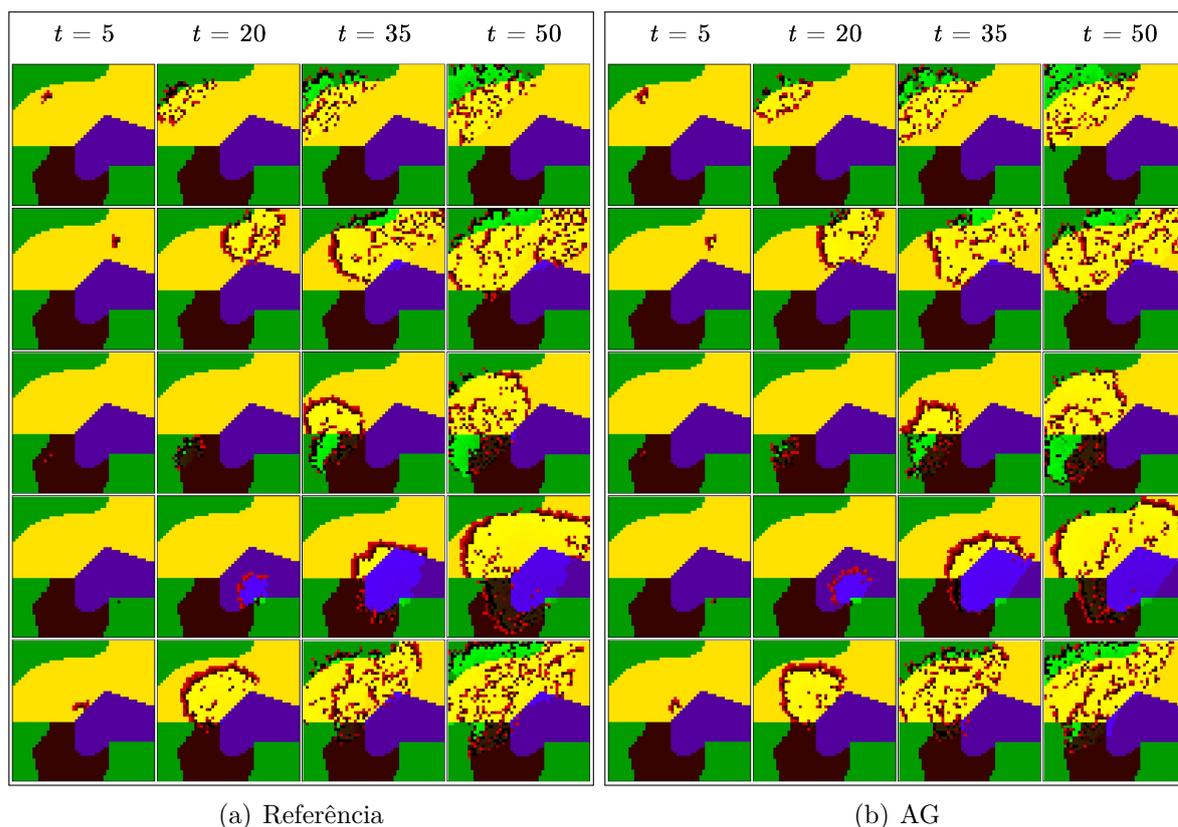


Figura 88 – Evolução temporal do autômato celular considerando diferentes posições para o início do fogo no primeiro cenário representando a região do Parque Estadual do Pau Furado: (a) modelo de referência; e (b) modelo configurado pelo AG.

A Figura 89 apresenta o segundo cenário e utilizou-se a mesma configuração do cenário anterior, com a reflexão das matrizes de preferência tanto na horizontal, quanto na vertical. Dessa forma, os ventos resultantes possuem a mesma intensidade, mas propagam o incêndio para sudeste. Como é possível perceber, a região selecionada apresenta um rio. Nesse caso, um estado novo foi criado representando a água que atua como barreira, impedindo a propagação do fogo. Entretanto, por se tratar de uma barreira, o algoritmo genético não evoluiu os parâmetros desse estado.

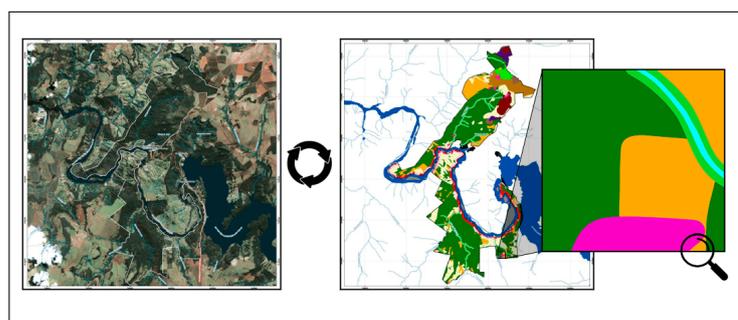


Figura 89 – Região do Parque Estadual do Pau Furado representada no segundo cenário avaliado.

Para esse cenário, o melhor indivíduo do AG obteve uma aptidão de 0,124, enquanto o *fitness* médio das execuções foi $0,125 \pm 0,0002$. A Figura 90 mostra os parâmetros obtidos na execução do AG (Figura 90(c)) e os de referência (Figura 90(a)). Apesar de não obter os mesmos valores para as matrizes de preferências, as forças vetoriais foram semelhantes na direção e intensidade. Algumas diferenças podem ser notadas, como na matriz de preferências da Veg1 cuja célula direita central é menor que a referência, o que resulta em uma força vetorial com um ângulo maior (317 vs 315 graus). Na Veg2, a célula inferior central da matriz é menor que a referência, resultando em uma força vetorial menos intensa (0,88 vs 1,0) e levemente menos inclinada (314 vs 315 graus). Já na Veg3, as células da esquerda possuem valores menores que a referência, resultando em uma força vetorial com uma inclinação (310 vs 315 graus) menor. Na Veg4, o valor da célula superior direita da matriz é levemente superior que da referência, o que é refletido na força vetorial, cuja intensidade é semelhante, mas apresenta uma inclinação menor (300 vs 315 graus).

1.000	0.850	0.500	0.500	0.425	0.250	0.666	0.560	0.333	0.233	0.193	0.072
0.850	-	0.140	0.425	-	0.070	0.560	-	0.093	0.193	-	0.030
0.500	0.140	0.000	0.250	0.070	0.000	0.333	0.093	0.000	0.072	0.030	0.000
3	30		2	90		6	20		8	60	

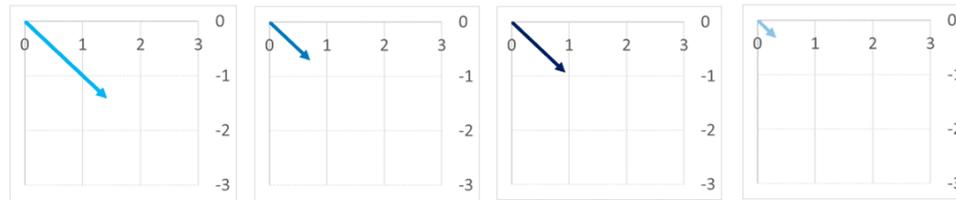
Veg1

Veg2

Veg3

Veg4

(a) Parâmetros de Referência



Ve1g1

Veg2

Veg3

Veg4

(b) Forças Vetoriais de Referência

0.999	0.720	0.545	0.445	0.413	0.247	0.800	0.542	0.336	0.200	0.174	0.172
0.831	-	0.027	0.434	-	0.059	0.555	-	0.081	0.180	-	0.003
0.500	0.100	0.000	0.147	0.162	0.003	0.200	0.080	0.001	0.055	0.000	0.000
3	30		2	90		6	20		8	60	

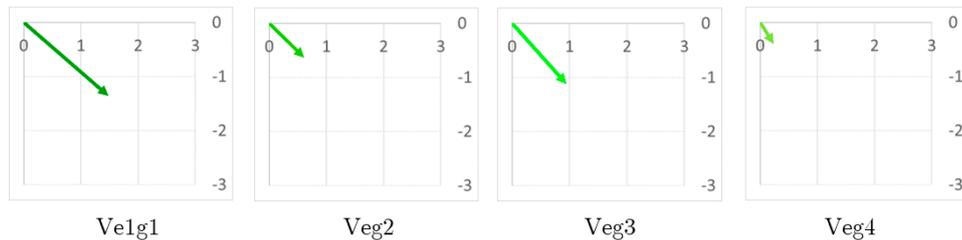
Veg1

Veg2

Veg3

Veg4

(c) Parâmetros Obtidos pelo AG



Ve1g1

Veg2

Veg3

Veg4

(d) Forças Vetoriais Obtidas pelo AG

Figura 90 – Conjuntos de parâmetros e vetores de forças usados no segundo cenário representando região do Parque Estadual do Pau Furado: (a) referência; e (b) obtido pelo algoritmo genético a partir de simulações com diferentes posições para o início do fogo.

A Figura 91 apresenta a evolução temporal de incêndios no cenário 2, considerando o modelo configurado pelo algoritmo genético e de referência. O comportamento das simulações com os parâmetros obtidos pelo AG indica que o fogo se espalha para o sudeste do reticulado, como mostra a Figura 91(b), ou seja, no mesmo sentido das simulações com o modelo de referência (Figura 91(a)). O rio funciona como barreira de propagação do fogo, impedindo-o de propagar para o outro lado. Entre as vegetações, a Veg2 (representada pela cor roxa) foi a que apresentou as maiores divergências, com uma propagação ligeiramente mais discreta nas simulações do AG em comparação com o modelo de referência, como pode ser notado nas simulações onde o fogo iniciou no ponto central ou nas partições

Para cada cenário, o modelo de autômato celular, ajustado com os parâmetros encontrados pelo AG, foi executado 1000 vezes e foram computadas quantas vezes cada células encontrava-se no estado Fogo naquele instante de tempo. A Figura 92 a evolução temporal da simulação de cada cenário investigado, considerando o ponto de ignição do fogo na célula central do reticulado, bem como os respectivos mapas de calor gerados em cada instante de tempo t ($t = 5, 20, 35$ e 50). As cores do mapa de calor são dadas pela quantidade de Fogo naquela célula durante as mil execuções. Quanto mais quentes as cores, mais vezes a célula pegou fogo e quanto mais frias, menos vezes a célula tornou-se Fogo. É importante destacar que o mapa de calor não reflete os cenários de referência a esquerda e sim a média das 1000 simulações.

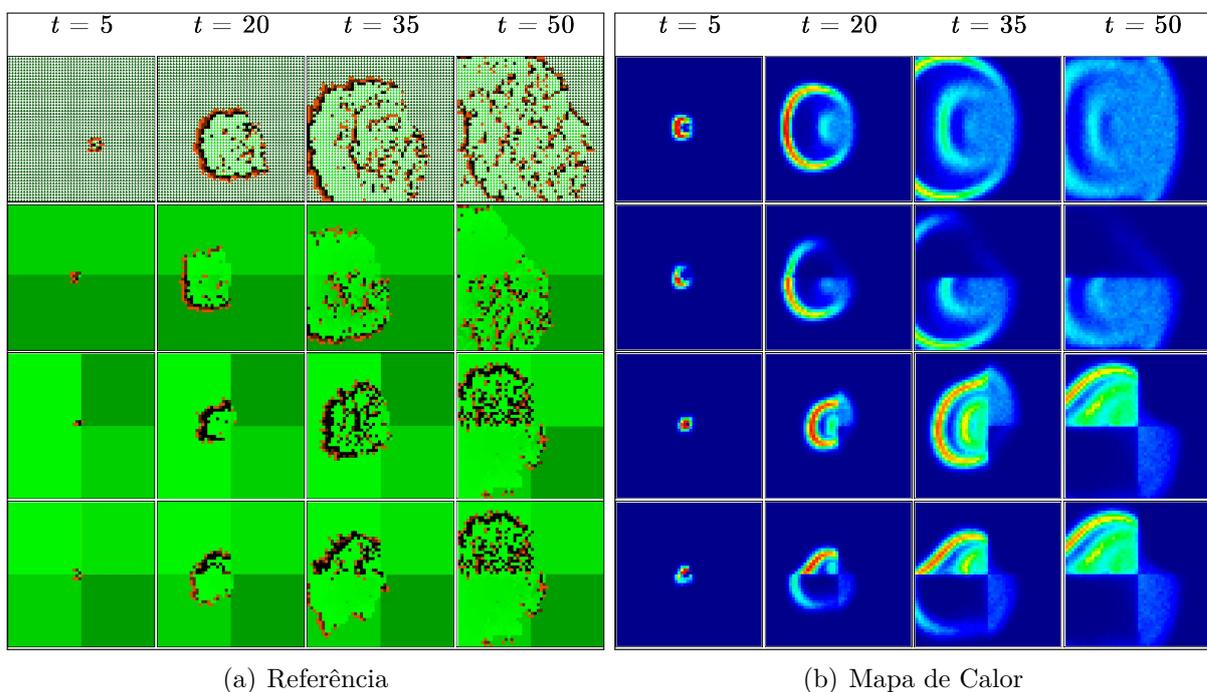


Figura 92 – Mapa de Calor que analisa a tendência de fogo no modelo de propagação baseado em AC

Em relação a vegetação homogênea (primeira simulação da Figura 92), percebe-se que o fogo espalha-se para o oeste do reticulado, em uma faixa circular. Nas 1000 execuções, no intervalo de tempo $t = 5$ há a maior probabilidade de pegar fogo no centro do reticulado, o ponto inicial do fogo. No intervalo $t = 20$, também há a maior incidência de fogo que se espalha em direção as bordas do reticulado. O fogo atinge as bordas no intervalo $t = 35$ e até o $t = 50$ a incidência das células de fogo diminui. As células em azul mais claro representam também que as células que já atingiram o valor de LR voltaram a queimar.

Analisando o cenário com duas vegetações, segunda simulação da Figura 92, pode-se notar que a parte inferior do reticulado tem mais presença de células de fogo, indicando que a Veg1 é mais combustível que a Veg2.

A terceira simulação corresponde ao cenário com três vegetações. A vegetação localizada na partição superior direita do reticulado (Veg1) é atingida a partir do instante $t=35$ e propaga o fogo novamente para o oeste, em direção a Veg3. A parte esquerda do reticulado, dessa maneira, tem mais incidência de fogo.

Por fim, a simulação no cenário heterogêneo com quatro vegetações, percebe-se que as vegetações Veg1 (partição superior esquerda) e Veg3 (partição inferior direita) são mais combustíveis que as demais (Veg2 na partição superior direita e Veg4 na partição inferior esquerda).

O mapa de calor apresenta a tendência de propagação de fogo. Assim, quando os parâmetros do AC forem ajustados pela abordagem evolutiva para reproduzir o comportamento de incêndios, o mapa de calor é uma alternativa para avaliar a frequência que uma determinada área ou uma determinada vegetação pega fogo, o que também pode auxiliar na predição e combate à incêndios florestais. A análise dos mapas de calor gerados pelo modelo permitiu a identificação de regiões mais propensas a incêndios. Em um cenário que utilize dados reais de incêndios, essas áreas devem ser monitoradas com maior atenção. Além disso, a análise dos mapas de calor permitiu a identificação de padrões espaciais e temporais de incêndios. Os mapas de calor podem ser usados para orientar a implementação de medidas preventivas e de combate a incêndios florestais. Por exemplo, as áreas com maior risco de combustão podem ser monitoradas com maior frequência, e as políticas públicas podem ser direcionadas para essas áreas, a fim de minimizar o risco de incêndios. Ademais, os mapas de calor podem ser usados para identificar as áreas com maior potencial para regeneração natural após um incêndio, o que é essencial para a recuperação da biodiversidade.

6.7 Análise da Sensitividade

O objetivo dos experimentos descritos a seguir é analisar a sensibilidade do algoritmo de ajuste do modelo de simulação aos dados utilizados como referência. Em todos os experimentos descritos nas seções anteriores, o AG evoluiu os parâmetros do modelo descrito no Capítulo 5 buscando reproduzir dados de simulações utilizadas como base de referência e que foram gerados com esse mesmo modelo. Durante a submissão do primeiro artigo publicado (FERREIRA et al., 2022b), fomos questionados pelo(a) revisor(a) anônimo(a) do artigo se o modelo de ajuste de fato teria um bom desempenho se os dados fossem gerados por imagens de incêndios reais ou mesmo dados gerados por modelos distintos do nosso. A partir desse questionamento, nos propusemos a investigar qual a capacidade de nossa abordagem evolutiva de ajuste de parâmetros em conjunto com o modelo de simulação apresentado no Capítulo 5 encontrar um boa reprodutibilidade do comportamento geral de incêndios gerados por outros modelos da literatura. Para isso, adotou-se modelos de propagação de incêndio diferentes daquele usado pelo algoritmo evolutivo na avaliação

dos indivíduos, para a geração dos dados artificiais dos incêndios. Nesse contexto, os modelos (LIMA; LIMA, 2014) e (TINOCO et al., 2022) descritos anteriormente foram escolhidos para a geração dos dados de referência.

6.7.1 Análise de Sensitividade considerando dados de referência gerados pelo modelo Lima e Lima (2014)

Nessa etapa, o modelo apresentado em (LIMA; LIMA, 2014) foi utilizado para gerar os dados de referência para quatro cenários diferentes, os quais representam a propagação de fogo para noroeste, sudoeste, nordeste e sudeste. Cada cenário foi simulado 10 vezes e o melhor resultado é apresentado. Para analisar os resultados, os valores encontrados pelo algoritmo genético para a matriz de preferências serão comparados com os valores de referência. O modelo de referência não possui os parâmetros LQ e LR, logo, foram analisados como os valores desses parâmetros influenciaram o resultado obtido pelo AG. Também é feita a comparação da evolução temporal do modelo de referência com aquele configurado com os parâmetros obtidos pelo AG.

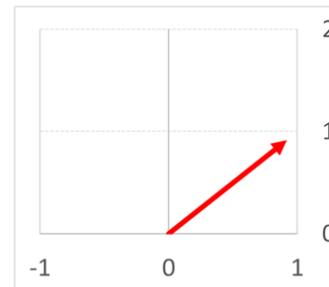
No primeiro cenário, a matriz de referência apresenta os maiores valores no canto inferior esquerdo, conforme mostra a Figura 93(a), resultando em uma propagação para o nordeste. O *fitness* do melhor indivíduo encontrado pelo AG (Figura 93(b)) foi de 4,77, enquanto o *fitness* médio das 10 execuções foi de $4,99 \pm 0,129$. No modelo (LIMA; LIMA, 2014), as células queimam em quatro estágios de fogo. No modelo usado pelo AG (padrão), o parâmetro que reproduz esse comportamento de estágios de queima é o LQ. O valor do LQ obtido para este cenário foi de 7. No modelo de referência, as células queimadas tornam-se *Cinza*, enquanto no modelo do AG, as células queimadas têm um tempo de recuperação (LR) para se tornarem material orgânico e poderem queimar novamente. O valor encontrado para LR foi de 90. Considerando que na modelagem, o valor máximo que LR pode assumir é 100, o valor definido pelo AG está próximo ao limite, mas as células queimam novamente, o que pode ser visto na Figura 94(b). Na Figura 93(b) é possível perceber que matriz obtida pelo AG também tem os maiores valores no canto inferior esquerdo. Por se tratar de modelos diferentes, a forma como os parâmetros da matriz de preferências influenciam na evolução do incêndio também divergem. No modelo utilizado como referência, a intensidade do vento modelado pela matriz é influenciada pelo raio de vizinhança adotado no autômato celular (neste trabalho foi usado $r=1$). No modelo padrão usado pelo AG, a intensidade do vento é definida pela própria matriz. Dessa forma, os valores obtidos para a matriz são superiores à referência e a intensidade do vento resultante é de a 1,0, como mostra o vetor de forças da Figura 93(c).

0.075	0.050	0.050
0.140	-	0.050
0.420	0.140	0.075

(a) Parâmetros de Referência

0.300	0.200	0.213
0.560	-	0.198
0.999	0.559	0.300
7	90	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial Obtida pelo AG

Figura 93 – Configurações e a representação vetorial do vento resultante do primeiro cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.

A Figura 94 mostra as simulações da propagação de incêndio no cenário modelado, considerando que o fogo iniciou célula central do reticulado do AC. Como pode ser observado, a dinâmica do modelo padrão configurado pelo AG para o espalhamento do fogo (Figura 94(b)) é semelhante àquela apresentada pelo modelo de referência (Figura 94(a)). A grande diferença está nos novos focos de incêndio na área já queimada. Como descrito anteriormente, isso ocorre porque o modelo de referência não prevê a possibilidade de áreas já queimadas voltarem a pegar fogo, enquanto o modelo padrão possui um componente de recuperação. Mesmo assim, percebe-se que o AG buscou minimizar o efeito desse parâmetro ao retornar um valor próximo ao limite máximo. Dessa forma, entende-se que o algoritmo foi capaz de ajustar os parâmetros para reproduzir o padrão apresentado nos dados.

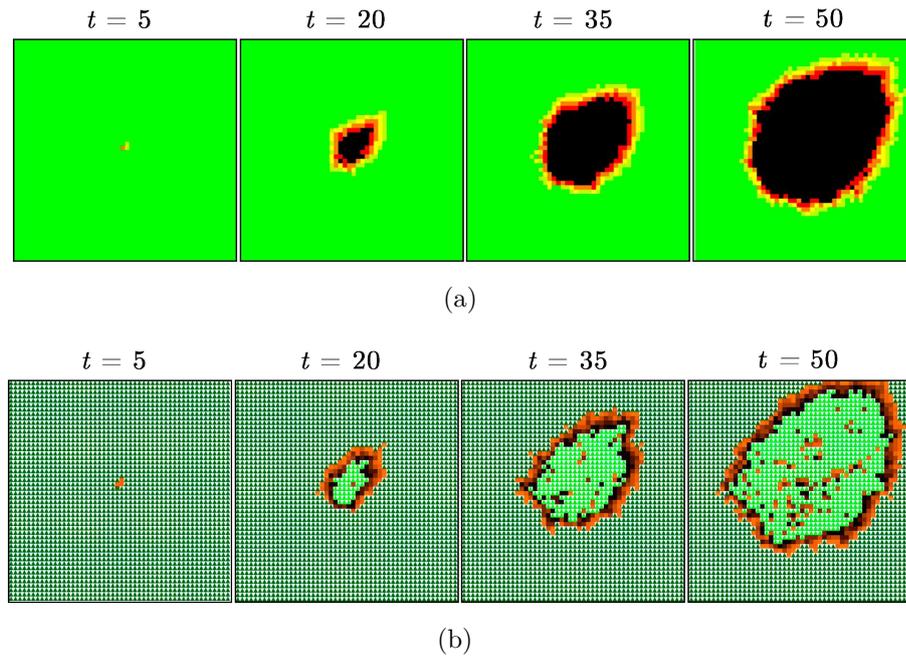


Figura 94 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).

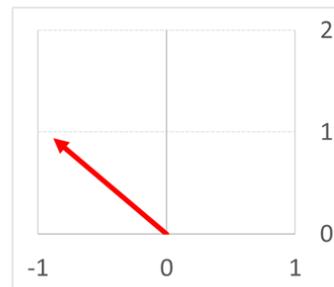
O segundo cenário adota a mesma configuração do primeiro, apenas com a rotação da matriz de preferências, conforme apresentado na Figura 95(a). Dessa forma, o vento sopra na direção noroeste. É possível perceber na Figura 93(b) que matriz obtida pelo AG também tem os maiores valores no canto inferior esquerdo, resultando em um vento (Figura 95(c)) direcionado para o noroeste, mas com intensidade de 1,0. O valor encontrado para LQ foi de 7 e o valor de LR foi de 100, o maior valor possível. Para esse cenário, a melhor configuração encontrada apresenta uma aptidão de 6,21, enquanto o *fitness* médio das execuções do AG foi de $6,36 \pm 0,074$.

0.050	0.050	0.075
0.050	-	0.140
0.075	0.140	0.420

(a) Parâmetros de Referência

0.180	0.199	0.200
0.204	-	0.579
0.299	0.498	0.987
7		100

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial Obtida pelo AG

Figura 95 – Configurações e a representação vetorial do vento resultante do segundo cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.

A Figura 96 mostra as simulações da propagação de incêndio no de referência ((Figura 96(a)) e a configurada pelo AG (Figura 96(b)), considerando que o fogo iniciou célula central do reticulado. A propagação do fogo é similar nas duas simulações e a principal diferença é o fato de que, devido ao valor de LR, na simulação configurada pelo AG, as áreas queimadas pegam fogo novamente.

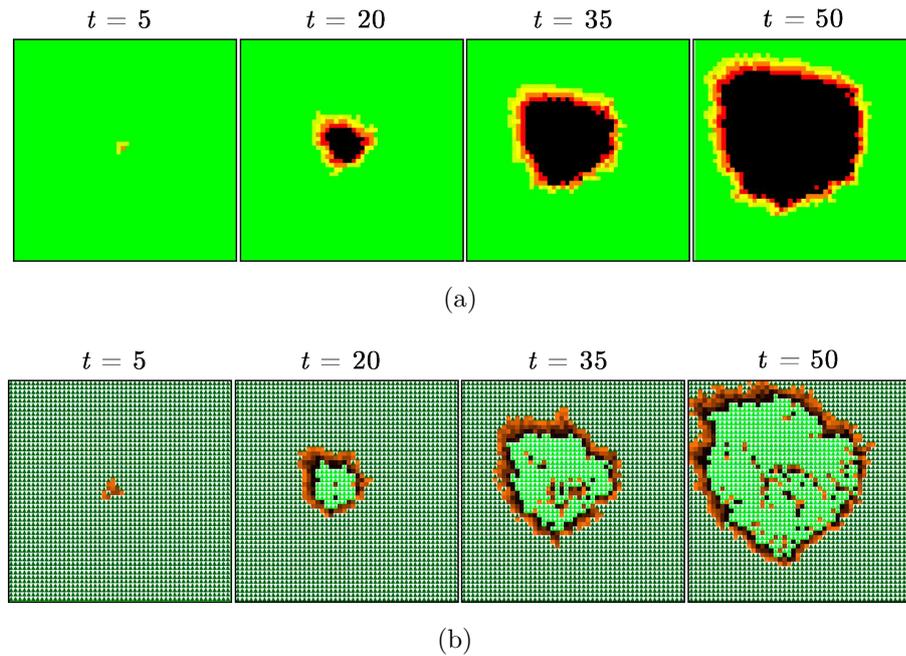


Figura 96 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).

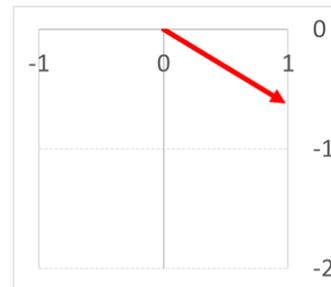
O terceiro cenário apresenta uma matriz de preferências com valores mais altos na parte superior esquerda, conforme mostra a Figura 98(a). Nesse cenário, o vento nesse cenário sopra na direção sudeste. Considerando todas as 10 execuções do AG, o melhor indivíduo encontrado apresenta uma aptidão de 4,10, enquanto que o *fitness* médio das execuções foi de $4,23 \pm 0,056$. Na configuração obtida pelo AG (Figura 98(b)), o valor de LQ é 9 e de LR é de 100. A matriz de preferências obtida tem os maiores valores nas posições superiores à esquerda, conforme mostra a Figura 98(b), assim como na referência. Esses valores são mais altos e modelam um vento (Figura 98(c)) para o sudeste com uma intensidade de 1,0.

0.420	0.140	0.075
0.140	-	0.050
0.075	0.050	0.140

(a) Parâmetros de Referência

1.000	0.411	0.200
0.600	-	0.187
0.308	0.210	0.300
9	100	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial Obtida pelo AG

Figura 97 – Configurações e a representação vetorial do vento resultante do terceiro cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.

A Figura 98 mostra a evolução temporal dos incêndios simulados pelos modelos de referência (Figura 98(a)) e configurado pelo AG (Figura 98(b)). O comportamento das duas simulações é semelhante, ou seja, o fogo se espalha para o sudeste do reticulado. A principal diferença é que no modelo configurado pelo AG, a área queimada volta a queimar.

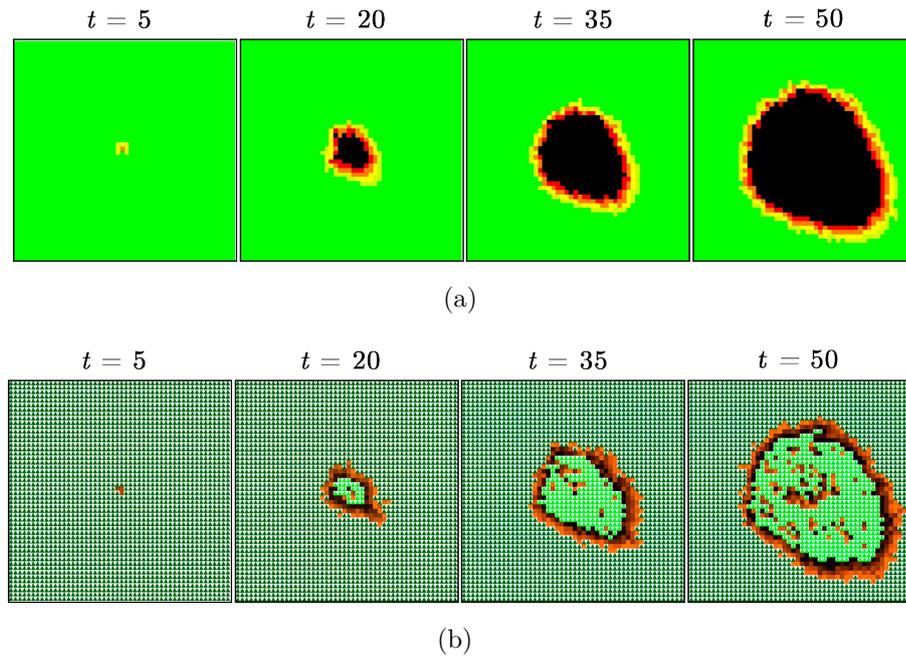


Figura 98 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).

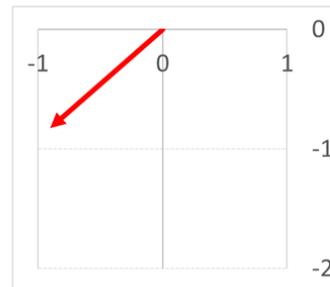
No quarto cenário, o vento sopra para a direção sudoeste, ou seja, com os maiores valores posicionados no canto superior direito da matriz de preferências, como pode ser observado na configuração de referência (Figura 99(a)). Na matriz obtida pelo AG, os valores não são iguais à referência, mas sua distribuição espacial é bem próxima, com os maiores valores localizados na diagonal superior direita, conforme mostra a Figura 99(b). O vento obtido a partir dos parâmetros encontrados pelo AG (Figura 99(c)) sopra para sudoeste com uma intensidade de 1,6. Assim como nos cenários anteriores, o AG encontrou um valor próximo ao limite para LR (98). O valor de LQ foi 9. O melhor indivíduo atingiu uma aptidão de 4,43, enquanto o *fitness* médio das execuções do AG foi de $4,55 \pm 0,07$.

0.075	0.140	0.420
0.050	-	0.140
0.050	0.050	0.075

(a) Parâmetros de Referência

0.300	0.450	0.993
0.203	-	0.550
0.200	0.189	0.295
9	98	

(b) Parâmetros Obtidos pelo AG



(c) Força Vetorial Obtida pelo AG

Figura 99 – Configurações e a representação vetorial do vento resultante do quarto cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG.

A Figura 100 apresenta a evolução temporal dos incêndios simulados pelos modelos de referência (Figura 100(a)) e configurado pelo AG (Figura 100(b)), considerando o foco inicial de incêndio na célula central. A principal diferença é que no modelo configurado pelo AG, as células queimadas voltam a pegar fogo. Todavia, o comportamento das duas simulações é semelhante e o fogo se espalha para o sudoeste do reticulado.

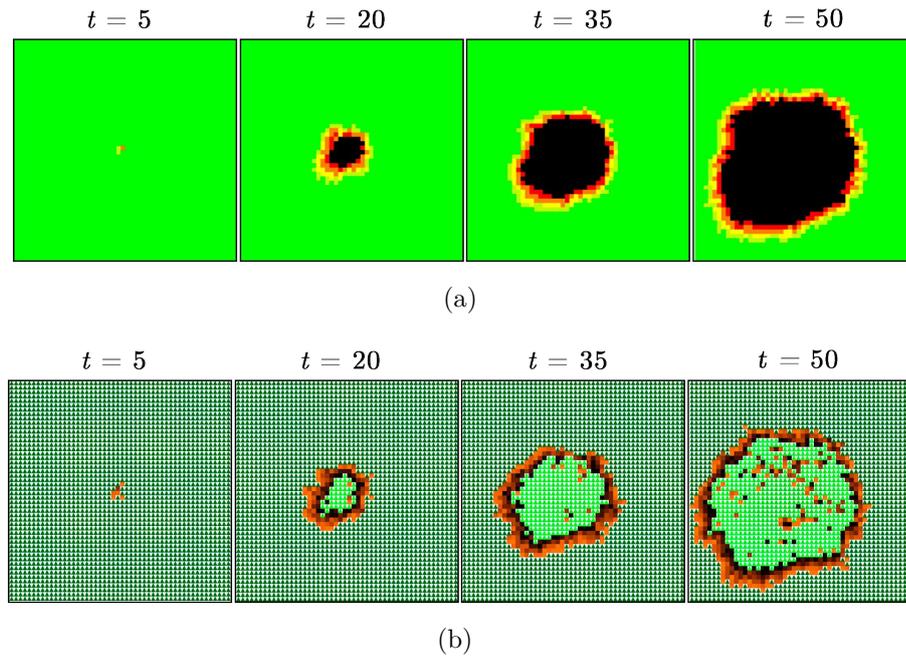


Figura 100 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).

O algoritmo genético mostrou-se eficiente ao tentar reproduzir o comportamento de um incêndio gerado por outro modelo. Foi possível perceber que o AG retornou valores mais elevados para a matriz de preferências para reproduzir a intensidade do vento observada nos dados de referência. Também foi possível notar o que o algoritmo conseguiu realizar o ajuste dos parâmetros LQ e LR para reproduzir o tempo de queima do modelo de referência. No modelo usado pelo AG, há o tempo de recuperação, LR, que representa o tempo em que uma célula leva para se tornar matéria orgânica, ou seja, combustível para uma nova queima. Como no modelo de referência, não há recuperação, os valores de LR foram elevados, muito próximos ou atingindo o limite máximo permitido, a fim de reduzir o efeito desse parâmetro nas simulações. Então, optou-se por testar aumentar o limite de LR, até 1000 e observar o comportamento do AG.

Um novo experimento foi realizado a fim de verificar se o surgimento dos novos focos de incêndio nas áreas já queimadas seria mitigado, caso esse limite fosse maior. O algoritmo evolutivo foi novamente executado para todos os cenários investigados, mas por simplificação, serão apresentados apenas os resultados para o cenário com vento para sudoeste. Entretanto, destaca-se que resultados similares foram obtidos para os demais cenários.

A Figura 101 apresenta as configurações encontradas pelo AG e usadas no modelo de referência (LIMA; LIMA, 2014). Como esperado, a alteração do limite de LR não interferiu no valor de LQ, nem no ajuste da matriz de preferências, que representa o vento (intensidade e direção). Percebe-se que os valores são muito próximos daqueles descritos

na Figura 99. Por outro lado, o valor de LR foi ajustado para o novo valor máximo (1000).

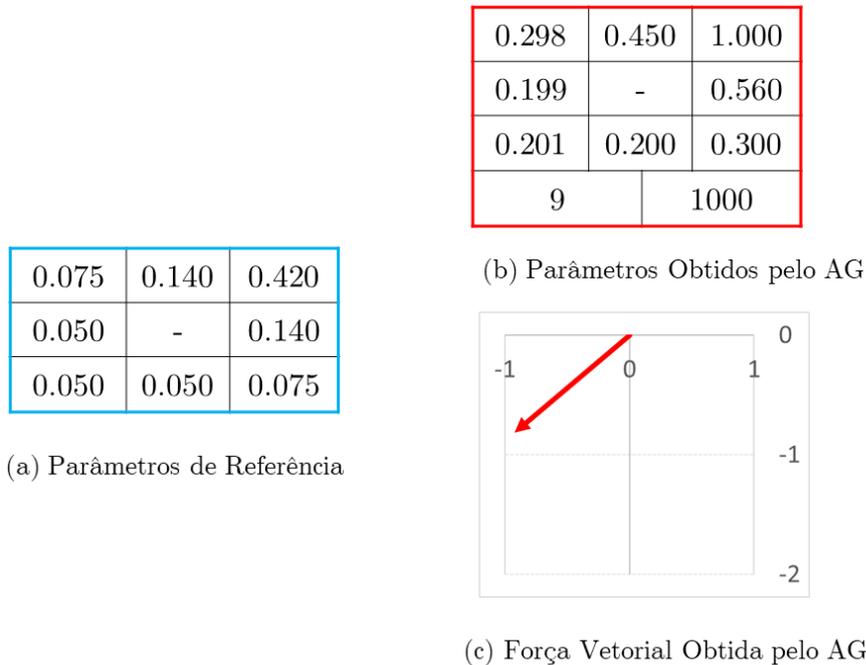


Figura 101 – Configurações e a representação vetorial do vento resultante do quinto cenário, de acordo com o modelo de propagação de incêndio: (a e c) modelo de referência (LIMA; LIMA, 2014) e (b e d) modelo padrão configurado pelo AG

Assim, na evolução temporal do incêndio mostrada na Figura 102(b), obtida pela simulação do modelo configurado pelo AG, pode-se notar que com a elevação no valor de LR, poucas células voltaram a queimar, praticamente tornando-o um modelo sem recuperação de vegetação, similar ao modelo utilizado para a geração de dados de referência (LIMA; LIMA, 2014). Portanto, o comportamento obtido pelo algoritmo genético foi ainda mais semelhante ao observado nos dados de referência, quando comparado à simulação anterior apresentada na Figura 99.

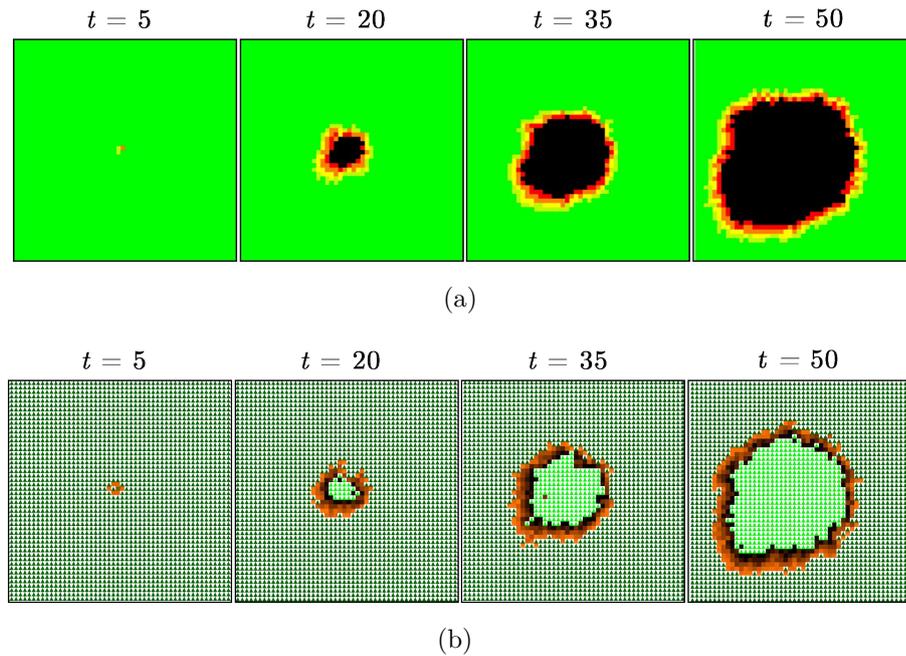


Figura 102 – Evolução temporal do autômato celular, de acordo com o modelo de propagação de incêndio adotado: (a) modelo de referência (LIMA; LIMA, 2014); (b) modelo configurado pelo AG (padrão).

6.7.2 Análise de Sensitividade considerando os dados de referência gerados pelo modelo Tinoco e Freitas et al. (2022)

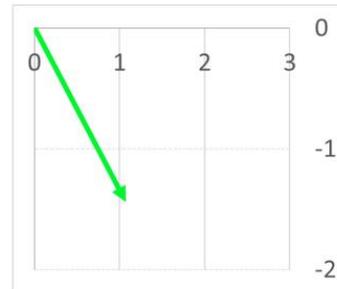
Para utilizar uma base de referência gerada pelo modelo (TINOCO et al., 2022), foi necessário modificar o tamanho do reticulado do modelo descrito no Capítulo 4, de forma a compatibilizar as simulações. Dessa forma, tanto o modelo de simulação utilizado pelo AG, quanto o o modelo de referência tiveram os tamanhos alterados para 64×64 (isto é, com 4096 células). Tanto o algoritmo genético, como o modelo de referência foram executados por 50 intervalos de tempo. Cada experimento foi executado 10 vezes e é apresentada a simulação de menor *fitness*, isto é, a simulação do indivíduo encontrado pelo AG que obteve a menor taxa de erro, quando comparado aos dados de referência.

Inicialmente, avaliou-se o desempenho da abordagem evolutiva em um cenário homogêneo, que representa apenas uma vegetação do tipo savânica. A Figura 103 apresenta os parâmetros obtidos pelo algoritmo genético e o vetor que representa a direção e intensidade do vento. A matriz de preferências não é mostrada, uma vez que o modelo (TINOCO et al., 2022) adota uma forma diferente de calcular a intensidade do vento, que envolve a composição de um conjunto de parâmetros durante a execução do autômato celular. A direção do vento, entretanto, é sudeste. Essa configuração (melhor indivíduo do AG) obteve uma aptidão de 4,821, enquanto o *fitness* médio das 10 execuções foi de 5,026, com um desvio padrão de 0,098. O vetor de forças obtido a partir dos parâmetros do AG indicam um vento na direção sudeste e com intensidade de 1,6. O valor de LQ é 6

e o valor de LR obtido é 100. Nas simulações desta subsecção, o tempo de recuperação do modelo (TINOCO et al., 2022) é muito alto. Dessa forma, assim, como nos experimentos com o modelo de (LIMA; LIMA, 2014), o AG evoluiu o parâmetro LR com o valor máximo permitido, buscando reproduzir essa dinâmica ou, nesse caso, aproximar a simulação ao comportamento observado nos dados.

1.000	0.176	0.511
0.898	-	0.240
0.261	0.176	0.167
6		100

(a) Parâmetros Obtidos pelo AG



(b) Força Vetorial Obtida pelo AG

Figura 103 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário homogêneo gerado a partir do modelo (TINOCO et al., 2022).

A Figura 104 mostra a evolução temporal das simulações de incêndio, considerando o modelo de referência (Figura 104(a)) e o modelo configurado pelo AG (Figura 104(b)). Cada simulação considera um ponto diferente para o início do fogo. Neste experimento, foram utilizados os mesmos 5 pontos iniciais adotados na Seção 6.4.3, ou seja, um em cada partição e um na célula central do reticulado. É possível perceber que, embora o vento direcione o fogo para a mesma direção (sudeste), o fogo se espalha com mais intensidade e velocidade no modelo ajustado pelo AG.

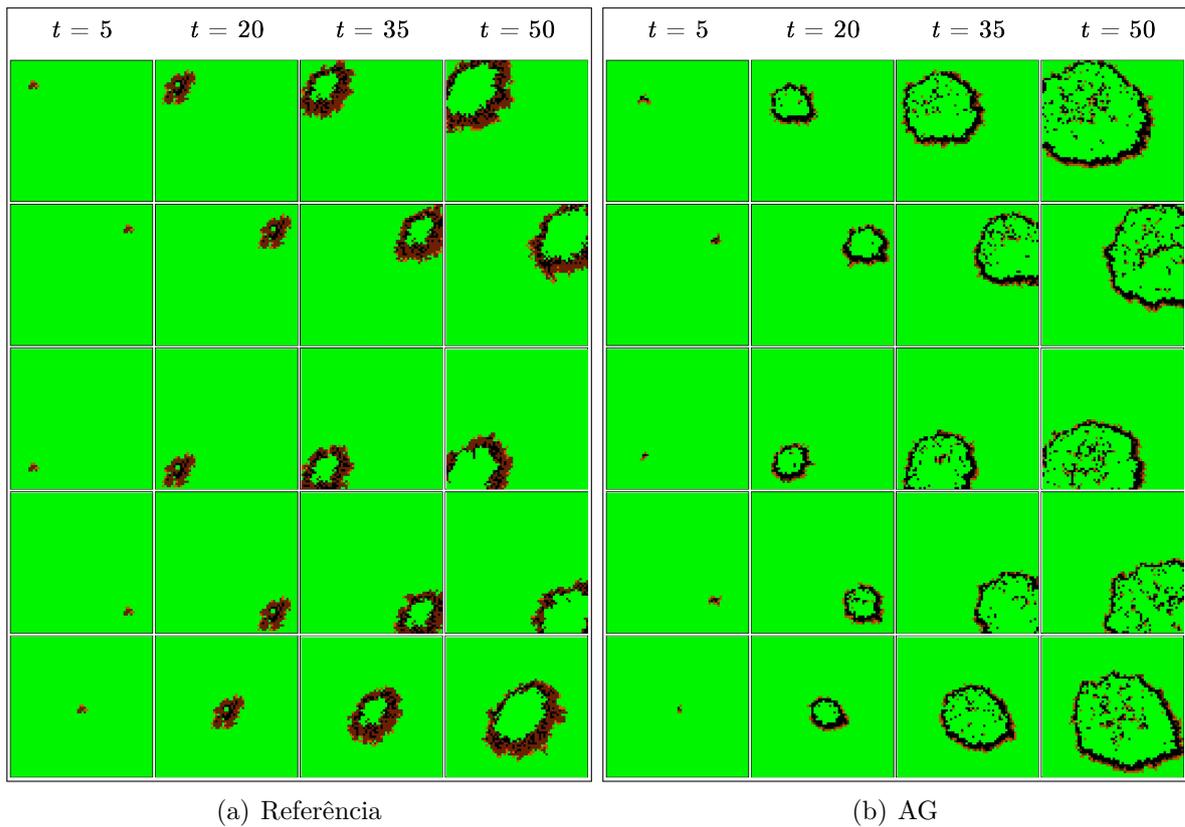


Figura 104 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.

No segundo cenário investigado foram utilizados dois tipos de vegetação na base de referência, representando as vegetações campestre e florestal. A Figura 105(a) mostra o melhor conjunto de parâmetros encontrado pelo algoritmo genético, enquanto a Figura 105(b) apresenta os vetores que representam a direção e intensidade dos ventos resultantes. Essa configuração (melhor indivíduo do AG) obteve uma aptidão de 0,0947, enquanto o *fitness* médio das 10 execuções foi de $0,960 \pm 0,0080$. As duas matrizes direcionam o vento para o sudeste, conforme representado pelos respectivos vetores de forças. Como pode ser observado, os valores de LR também se aproximaram do valor máximo (94 para Veg1 e 99 para Veg2). Diferentes valores foram encontrados para o tempo de queima ($LQ=9$ para Veg1 e $LQ=6$ para Veg2), o que pode ser justificado pelo fato do algoritmo evolutivo tentar reproduzir os comportamentos diferentes de cada tipo de vegetação. Em outras palavras, com base nos dados de referência, o AG identificou que Veg2 queima por mais tempo que Veg1.

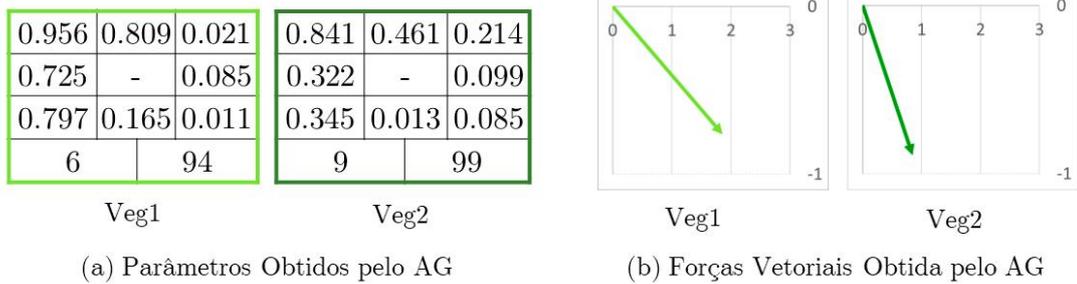


Figura 105 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com duas vegetações gerado a partir do modelo (TINOCO et al., 2022)

A Figura 106 mostra as simulações de incêndio obtidas a partir do modelo de referência (Figura 106(a)) e do modelo configurado pelo AG (Figura 106(b)). Percebe-se que o vento se espalha na mesma direção, tanto na referência como nas simulações obtidas pelo AG. Novamente, a maior intensidade de propagação em nosso modelo faz com que fogo atinja as bordas do reticulado mais rapidamente, principalmente na vegetação à direita do reticulado (Veg2).

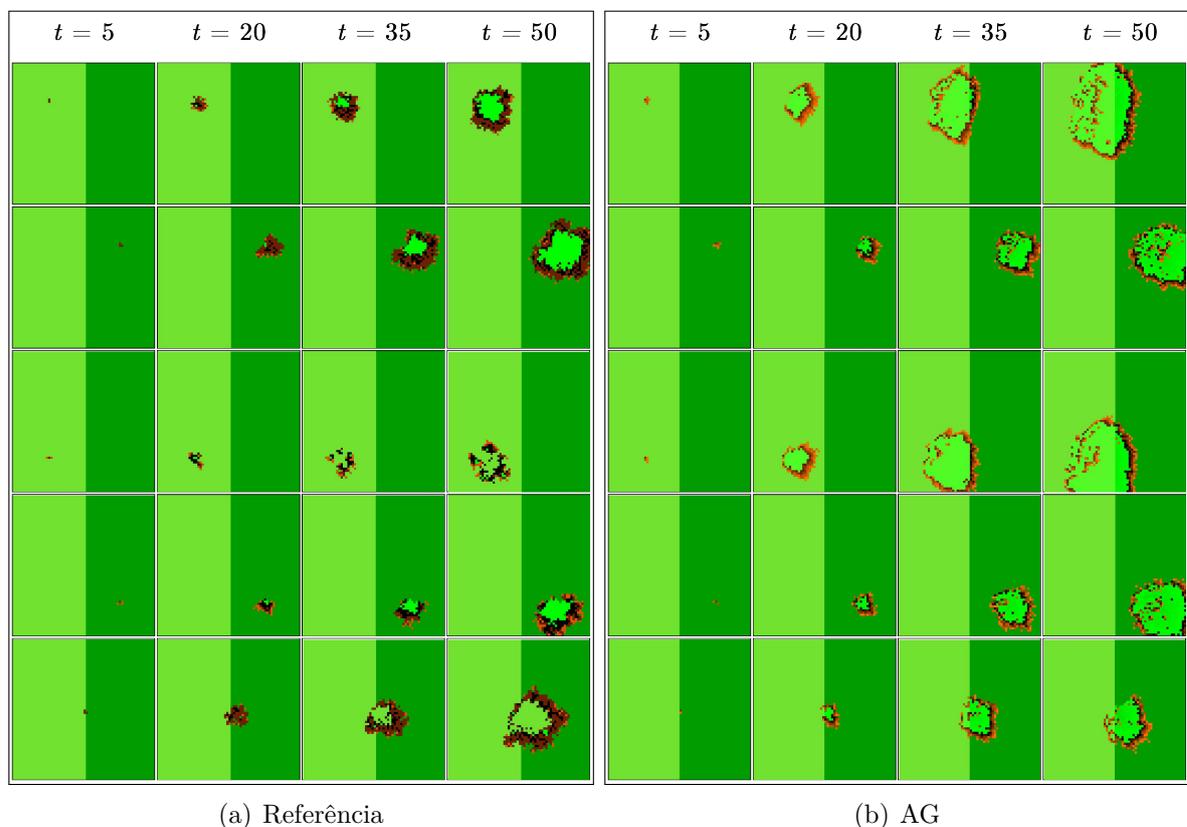


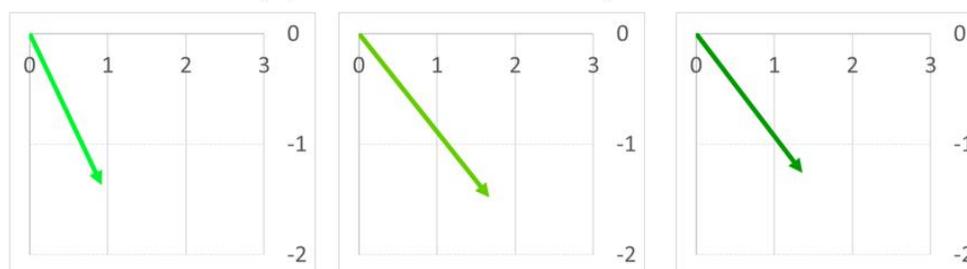
Figura 106 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.

A Figura 107 apresenta os parâmetros obtidos pelo algoritmo genético e os vetores que representam a direção e intensidade do vento no terceiro cenário, com as vegetações campestre, savânica e florestal. A aptidão do melhor indivíduo foi de 0,11320, enquanto o *fitness* médio das execuções foi de $0,11742 \pm ,0079$. As três matrizes (Figura 107(a)) direcionam o vento para o sudeste, conforme as forças vetoriais obtidas (Figura 107(b)). Para as três vegetações, os valores de LR também se aproximaram do valor máximo (100 para a Veg1, e Veg2 e 99 para a Veg3). Todavia, o valor de LQ é o mesmo para todas as vegetações (LQ = 6).

0.697	0.777	0.499	0.980	0.991	0.511	0.840	1.000	0.409
1.000	-	0.442	1.000	-	0.000	0.976	-	0.326
0.317	0.029	0.000	0.478	0.222	0.000	0.637	0.124	0.068
6	100		6	100		6	99	

Veg1 Veg2 Veg3

(a) Parâmetros Obtidos pelo AG



(b) Forças Vetoriais Obtidas pelo AG

Figura 107 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com três vegetações gerado a partir do modelo (TINOCO et al., 2022)

A Figura 108 apresenta as simulações de incêndio do modelo de referência (Figura 108(a)) e do modelo padrão (Figura 108(b)). Apesar da direção do vento ser a mesma, o padrão de espalhamento do fogo possui diferenças mais significativas. No modelo configurado pelo AG, o fogo se espalha com mais intensidade e velocidade em todas as vegetações.

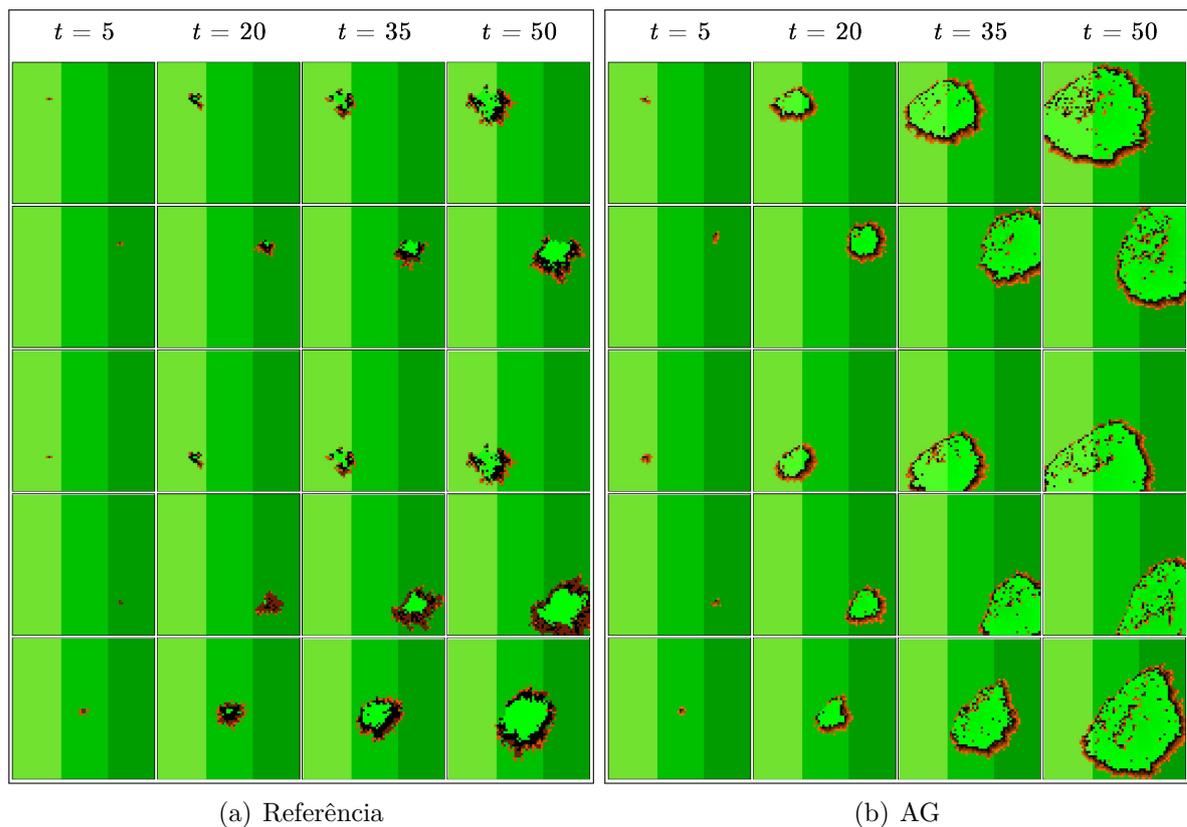


Figura 108 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.

Embora o ajuste efetuado pelo algoritmo genético tenha se mostrado eficiente para a direção do vento e os tempos de queima (LQ) e de recuperação (LR) a partir dos dados de referência, a intensidade de propagação do fogo foi maior em nosso modelo para todas as vegetações, influenciando diretamente na forma de espalhamento do incêndio nos cenários investigados. Acredita-se que essa diferença de comportamento ocorre pelo fato do modelo adotado como referência ser mais complexo, considerando várias características que não estão presentes em nosso modelo (ex: umidade do ar), bem como pelo ajuste que se fez necessário para adequar o nosso modelo às diferenças no tamanho do reticulado e na periodicidade de evolução do autômato. Com base nessas ponderações, considera-se que, embora a abordagem evolutiva não tenha reproduzido com exatidão o comportamento das simulações, ela foi capaz de identificar algumas características importantes presentes nos dados.

Realizamos alguns testes adicionais para buscar compreender se a abordagem evolutiva teve dificuldades de convergência para os valores adequados dos parâmetros do modelo ou se as diferenças observadas se devem a uma limitação do modelo de autômato celular probabilístico adotado nesse estudo, que é mais simples que o apresentado em (TINOCO et al., 2022). Para tal, alteramos diretamente os parâmetros do autômato celular, a partir

dos valores obtidos pelo AG. Ou seja, realizamos alterações nos valores evoluídos de forma a obter uma simulação mais próxima à gerada pelo modelo (TINOCO et al., 2022) nos três cenários investigados e apresentados nas Figuras 104, 106 e 108.

É importante lembrar que, no AG, o domínio para LQ é $[1.. 10]$ e para LR é $[1.. 100]$. No cenário homogêneo, primeiramente, o valor de LQ foi alterado para 20, o dobro do valor máximo permitido durante a evolução do AG. Além disso, a matriz de preferências evoluída (Figura 103) teve seus valores reduzidos para 80%. A Figura 109 mostra a evolução temporal de referência (Figura 109(a)) (repetida na Figura 109(a) para facilitar a comparação) e a obtida alterando o valor de LQ (Figura 109(b)). É possível perceber que o comportamento do incêndio é mais próximo ao apresentado na Figura 104(a), quando comparado ao apresentado na Figura 104(b). O fogo se alastra com menos velocidade e as bordas do fogo são mais intensas e maiores, assim como na referência.

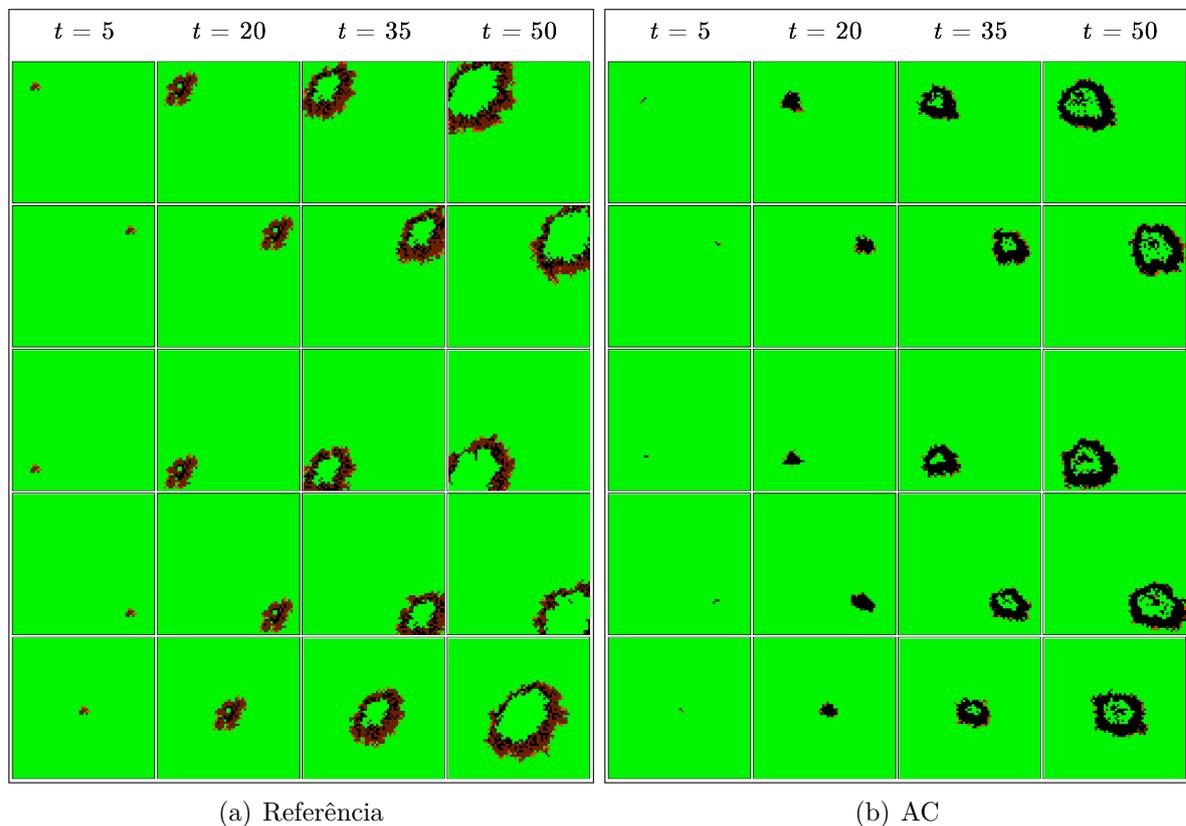


Figura 109 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 20$ e redução de 80% da matriz de preferências.

Uma vez que essa simulação não poderia ser obtida pelo AG, devido ao domínio de LQ, outra simulação foi realizada, alterando o valor desse parâmetro para 10, um valor que seria possível para o AG encontrar. Além disso, a matriz de preferências (Figura 103) obtida teve seus valores reduzidos para 80%. A Figura 110 mostra a evolução temporal

de referência (Figura 110(a)) e a obtida alterando o valor de LQ (Figura 110(b)) para 10. O comportamento é mais similar ao gerado pelo modelo de referência que o obtido pelo AG, na Figura 104(b)). Manualmente, foi calculada a aptidão dessa configuração de parâmetros e foi ligeiramente maior que a da configuração obtida pelo AG (4,953 vs 4,821). Embora o valor não seja consideravelmente maior, a diferença não se traduz na evolução temporal, já que, visualmente, essa simulação é mais próxima à referência.

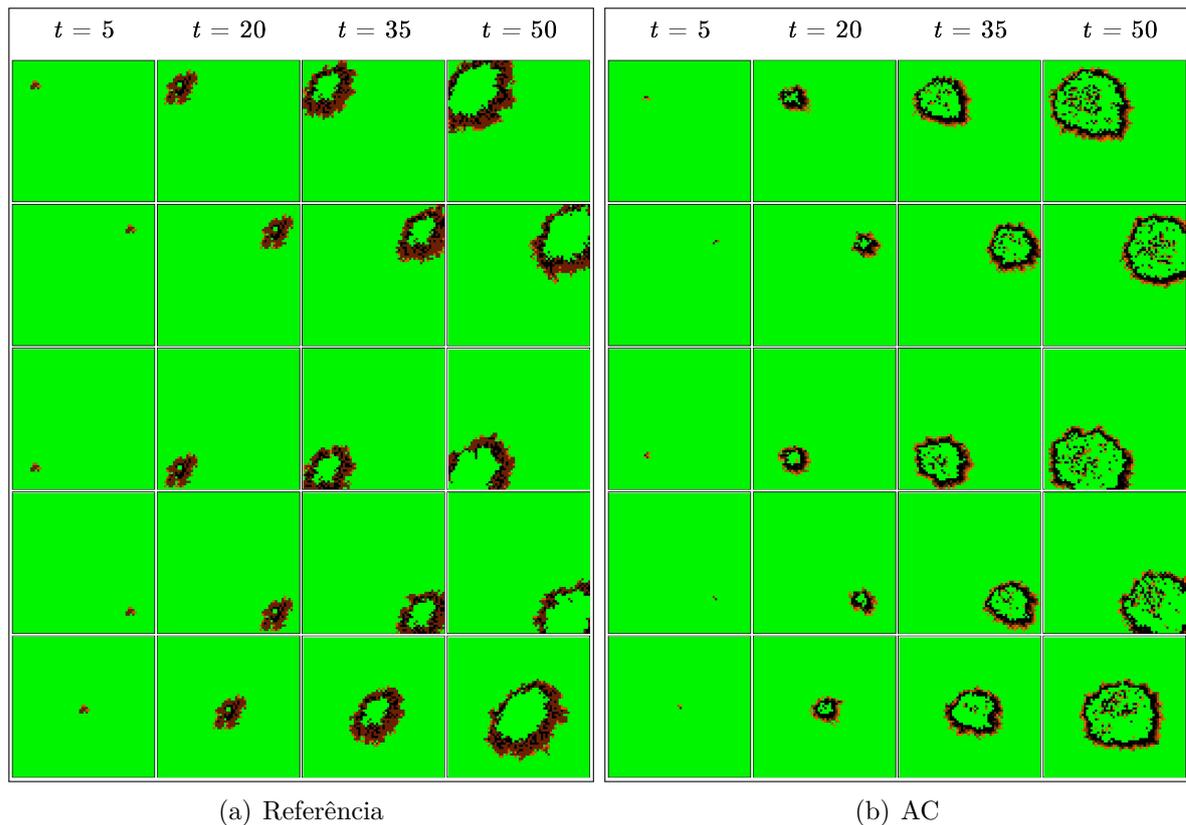


Figura 110 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 20$ e redução de 80% da matriz de preferências.

Para o cenário heterogêneo com duas vegetações, aumentamos os valores de LQ para 15 (Veg1) e 20 (Veg2). Os valores de LR foram alterado para 1000 nas duas vegetações. A matriz de preferências da Veg1 foi reduzida para 70% e a da Veg2 para 80% (Figura 105). Essas alterações também foram além do domínio do AG para esses parâmetros. A Figura 111 apresenta a evolução temporal. O comportamento do incêndio obtido com esses valores de parâmetros (Figura 111(b)) é mais semelhante à referência (Figura 111(a)) que o obtido pelo AG (apresentado na Figura 106(b)).

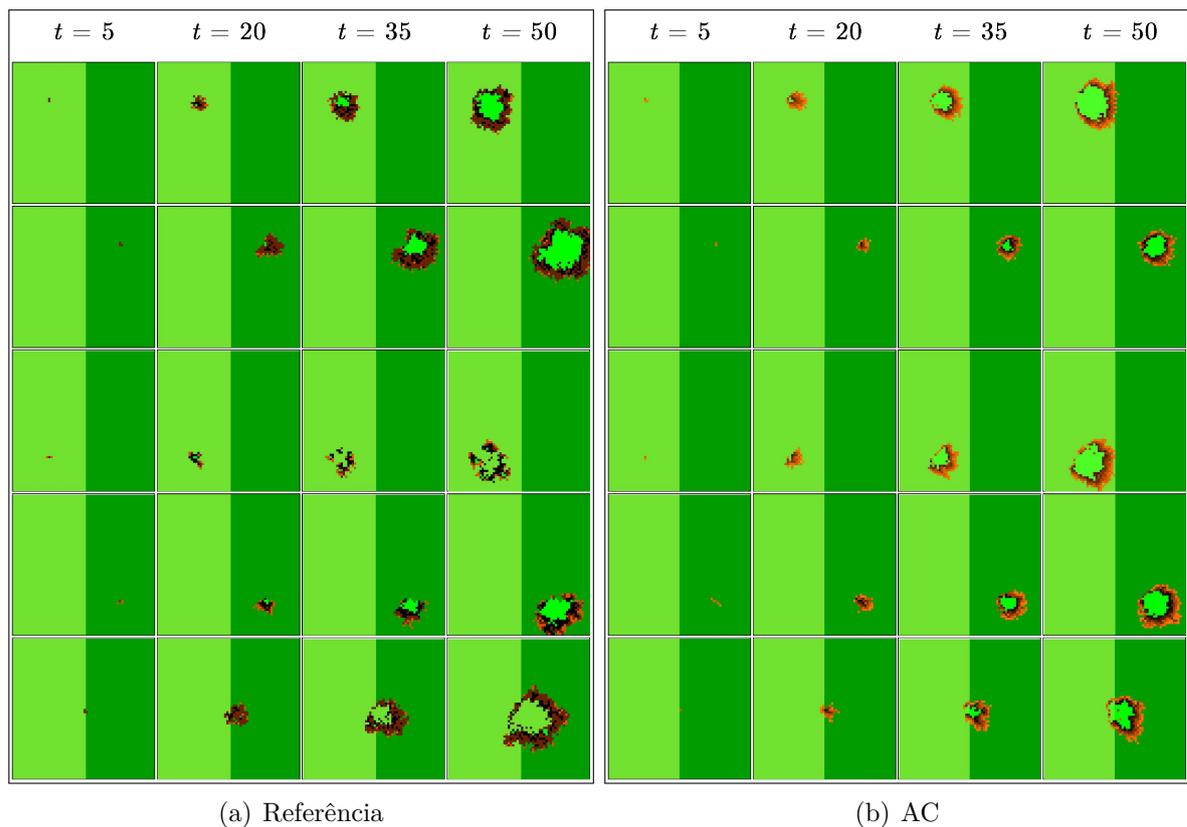


Figura 111 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 15$ e 20 , $LR = 1000$ e redução das matrizes de preferências para 70% (Veg1) e para 80% (Veg2)

Essa configuração de parâmetros não poderia ser obtida pelo AG, devido ao domínio de LQ e LR . Assim, em outra simulação, os valores de LQ foram alterados para 7 (Veg1) e 10 (Veg2) e 100 para LR em ambas as vegetações. A matriz de preferências da Veg1 foi reduzida para 70% e a da Veg2 para 80% (Figura 105). A aptidão, calculada manualmente, para essa configuração de parâmetros é de 0,09716, ligeiramente maior que a obtida pelo AG (0,0947). Na evolução temporal, pode-se perceber que a configuração obtida manualmente (Figura 112(b)) é mais parecida com a referência (Figura 112(a)) do que a obtida pelo AG (Figura 106(b)), o que o *fitness* não foi capaz de mensurar.

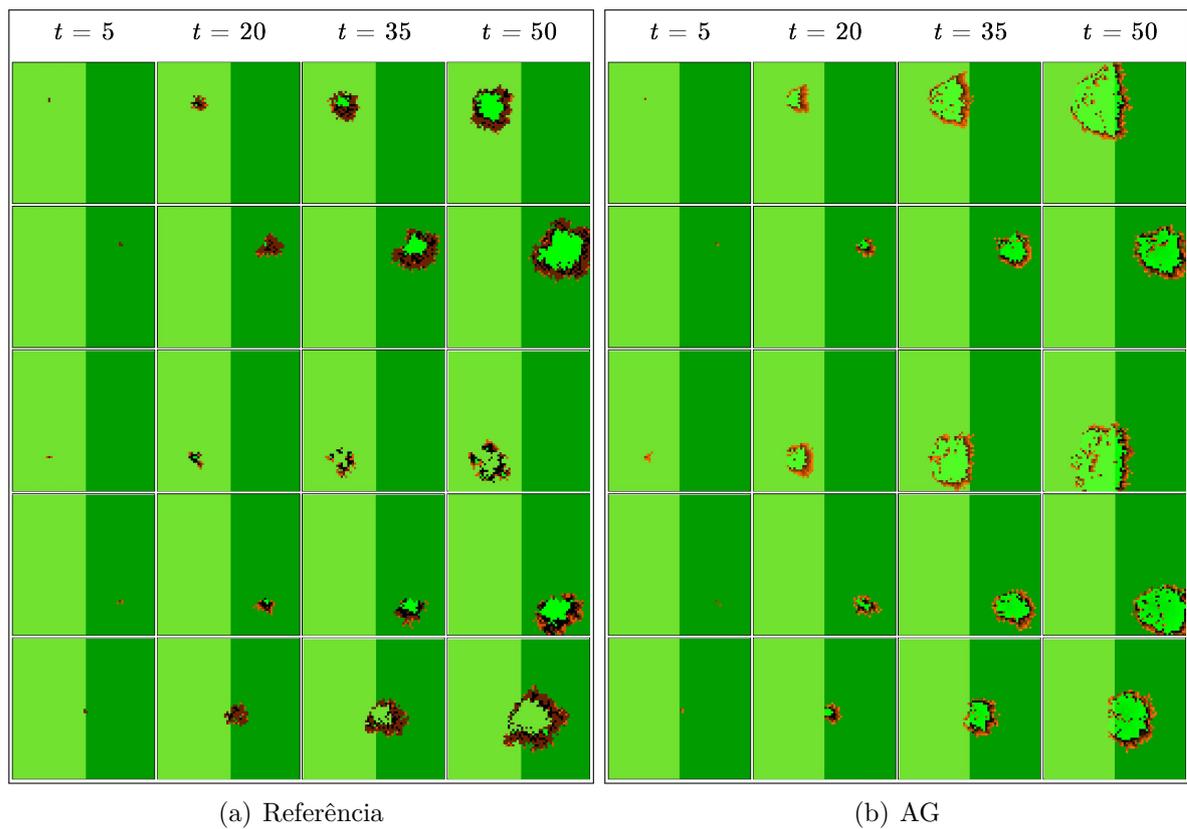


Figura 112 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 7$ e 10 , $LR = 100$ e redução das matrizes de preferências para 70% (Veg1) e para 80% (Veg2)

No cenário heterogêneo com três vegetações, os valores de LR foram alterado para 1000 em todas as vegetações. Também aumentamos os valores de LQ para 13 (Veg1) e 16 (Veg2) e 20 (Veg3). A matriz de preferências da Veg1 foi reduzida para 50%, e as matrizes da Veg2 e Veg3 foram reduzidas para 70% (Figura 107). A Figura 113 apresenta a evolução temporal da simulação obtida com essa configuração de parâmetros (Figura 113 (b)) e a simulação de referência (Figura 113(a)). O comportamento do incêndio obtido com esses valores de parâmetros apresenta mais similaridades com a referência do que o obtido pelo AG (Figura 108(b)). A propagação do fogo é menos intensa e as bordas do incêndio são maiores.

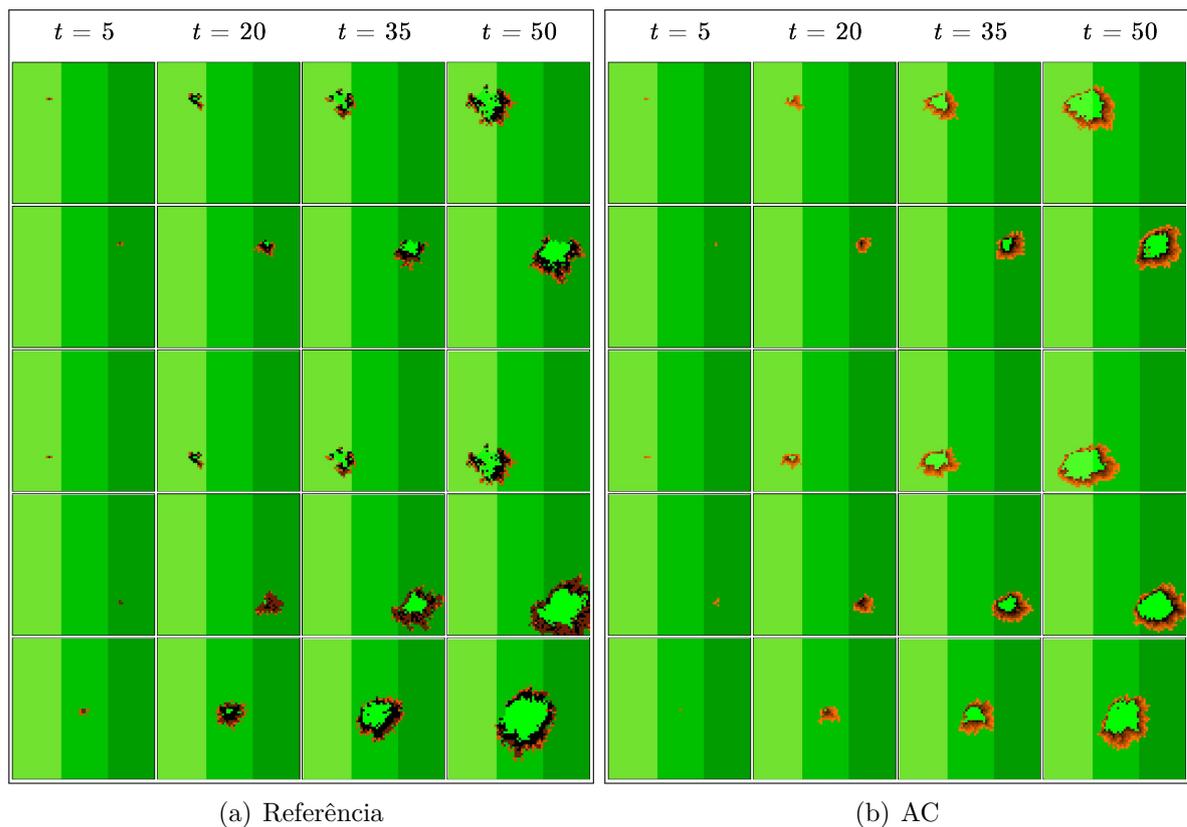


Figura 113 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 13, 16$ e 20 , $LR = 1000$ redução das matrizes de preferências para 50% (Veg1) e para 80% (Veg2 e Veg3)

Como essa simulação não poderia ser obtida pelo AG, devido ao domínio de LQ e LR , outra simulação foi realizada, alterando os valores desses parâmetros para valores dentro do domínio, isto é, possíveis de serem obtidos pelo AG. Os valores de LR foram alterado para 100 em todas as vegetações e os valores de LQ para 6 (Veg1) e 9 (Veg2) e 10 (Veg3). A matriz de preferências da Veg1 foi reduzida para 50%, e as matrizes da Veg2 e Veg3 foram reduzidas para 70% (Figura 107). Manualmente, foi calculada a aptidão dessa configuração de parâmetros e foi ligeiramente maior que a da configuração obtida pelo AG (0,1175 vs 0,1132). A Figura 114 mostra a evolução temporal de referência (Figura 114(a)) e a obtida alterando o valor de LQ (Figura 114(a)) para 10. O comportamento é mais similar que o obtido pelo AG, apresentado na Figura 108(b)).

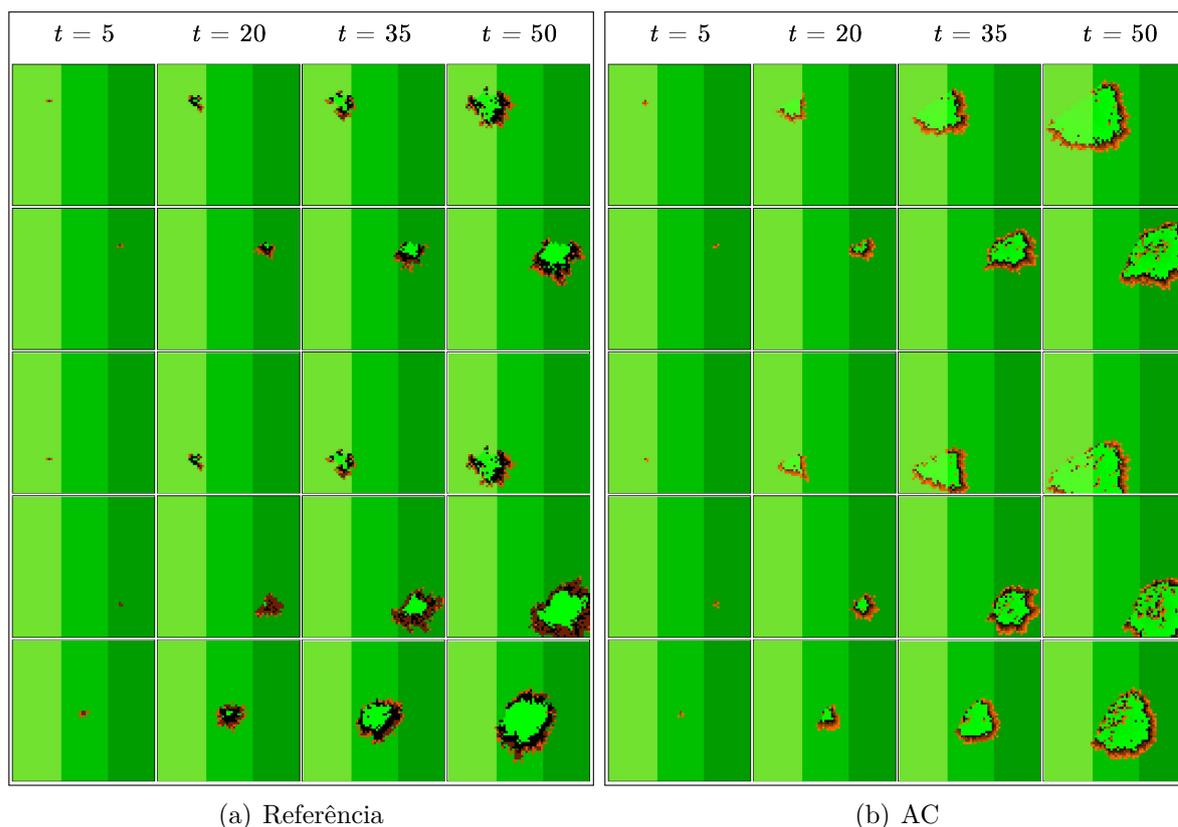
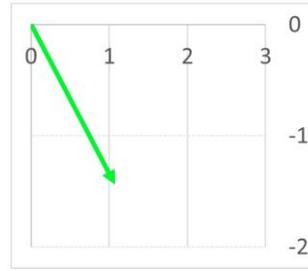


Figura 114 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) AC com $LQ = 6, 9$ e 10 , $LR = 1000$ e redução das matrizes de preferências para 50% (Veg1) e para 80% (Veg2 e Veg3)

Por fim, alguns experimentos finais foram realizados para avaliar se o desempenho da abordagem evolutiva alterando os valores de domínio de LQ ($[1...30]$) e LR ($[1...1000]$). A Figura 115 apresenta os parâmetros obtidos pelo algoritmo genético e o vetor que representa a direção e intensidade do vento para o cenário homogêneo. Essa configuração obteve uma aptidão de 4,936, enquanto o *fitness* médio das 10 execuções foi de 5,142, com um desvio padrão de 0,091. O valor de LQ é 24 e o valor de LR obtido é 986. O vetor de forças obtido a partir dos parâmetros do AG indicam um vento na direção sudeste e com intensidade de 2,02.

Por fim, alguns experimentos finais foram realizados para avaliar se o desempenho da abordagem evolutiva seria superior aos resultados evoluídos anteriormente alterando-se os valores de domínio de LQ ($[1...30]$) e LR ($[1...1000]$). A Figura 115 apresenta os parâmetros obtidos pelo algoritmo genético e o vetor que representa a direção e intensidade do vento para o cenário homogêneo. Essa configuração obteve uma aptidão de 4,936, enquanto o *fitness* médio das 10 execuções foi de 5,142, com um desvio padrão de 0,091. O valor de LQ é 24 e o valor de LR obtido é 986. O vetor de forças obtido a partir dos parâmetros do AG indicam um vento na direção sudeste e com intensidade de 2,02.

1.000	0.176	0.511
0.898	-	0.240
0.261	0.176	0.167
6		100

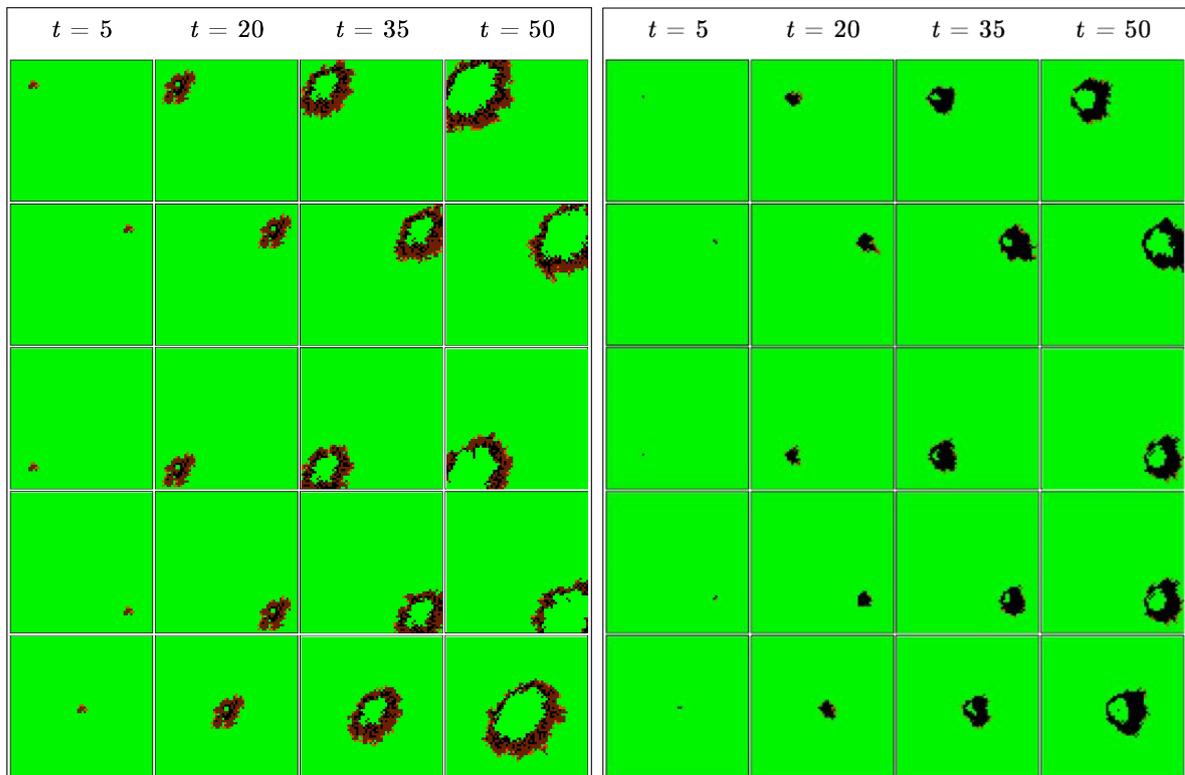


(a) Parâmetros Obtidos pelo AG

(b) Força Vetorial Obtida pelo AG

Figura 115 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário homogêneo gerado a partir do modelo (TINOCO et al., 2022).

A Figura 116 mostra a evolução temporal de das simulações de incêndio, considerando o modelo de referência (Figura 116(a)) e o modelo configurado pelo AG (Figura 116(b)). É possível perceber que a simulação obtida pelo AG é mais próxima a referência do que a simulação obtida anteriormente (Figura 104(b)): as bordas de fogo são maiores e a velocidade da propagação do fogo é maior.



(a) Referência

(b) AG

Figura 116 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário homogêneo, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.

O segundo cenário é heterogêneo, com dois tipos de vegetação, a campestre e florestal. O *fitness* foi de 0,80421, o *fitness* médio de 0,91119 e o desvio padrão de 0.000102. A Figura 117(a) mostra o melhor conjunto de parâmetros encontrado pelo algoritmo genético, enquanto a Figura 117(b) apresenta os vetores que representam a direção e intensidade dos ventos resultantes. As duas matrizes direcionam o vento para o sudeste, conforme representado pelos respectivos vetores de forças. Como pode ser observado, os valores de LR também se aproximaram do valor máximo (999 para Veg1 e 1000 para Veg2). Diferentes valores foram encontrados para o tempo de queima (LQ=30 para Veg1 e 19 para Veg2).

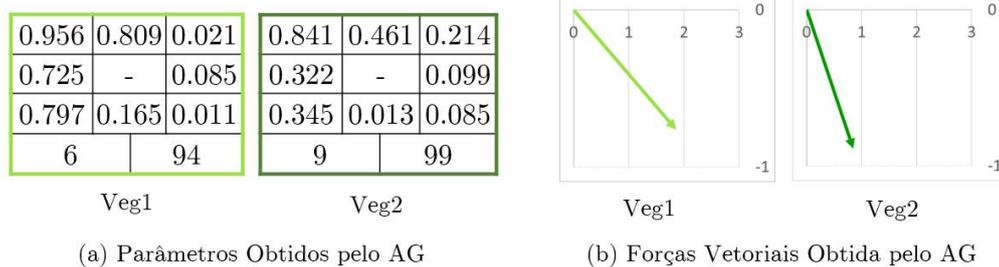


Figura 117 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com duas vegetações gerado a partir do modelo (TINOCO et al., 2022)

A Figura 118 apresenta as simulações de incêndio obtidas a partir do modelo de referência (Figura 118(a)) e do modelo configurado pelo AG (Figura 118(b)). Em relação as simulações obtidas anteriormente (Figura 106(b)), percebe-se que neste caso, o fogo se espalha com menos velocidade para o sudeste do reticulado, um comportamento mais semelhante à referência e que pode ser justificado pelos valores de LQ e LR obtidos pelo AG.

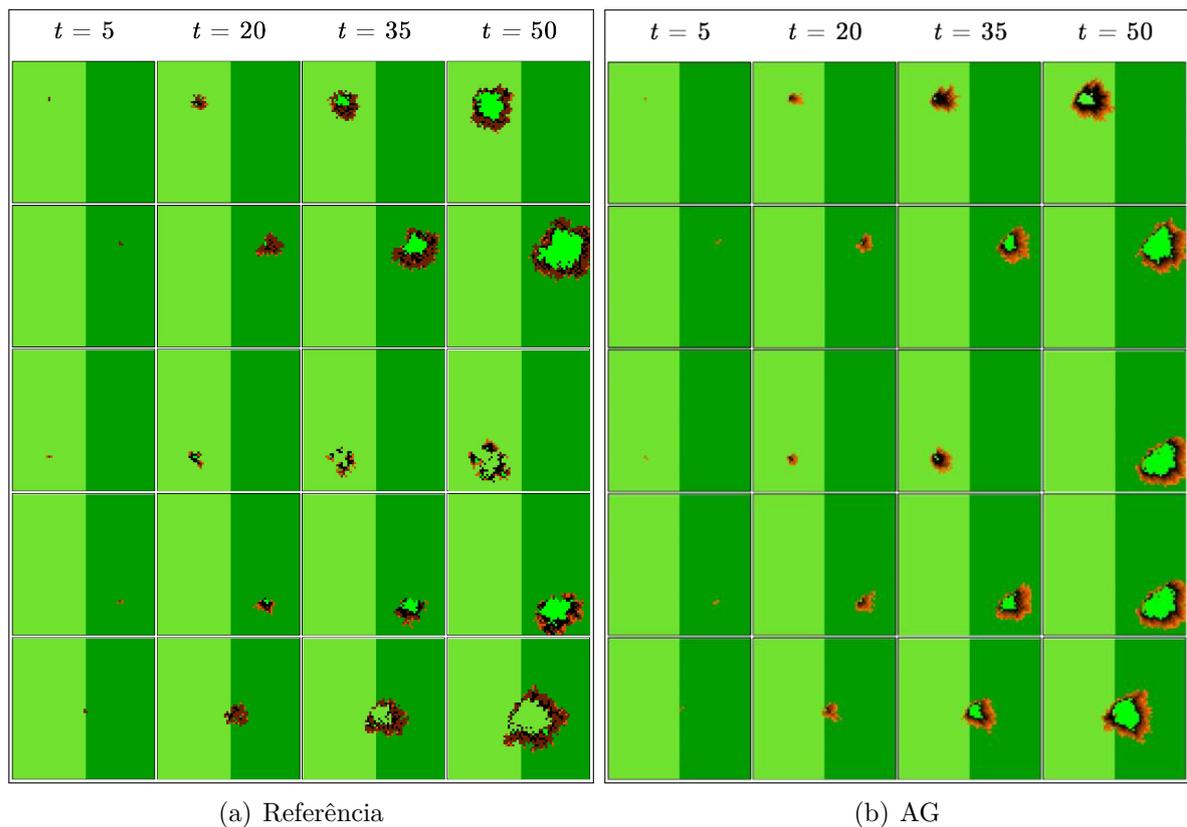


Figura 118 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com duas vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.

A Figura 119 apresenta os parâmetros obtidos pelo algoritmo genético e os vetores que representam a direção e intensidade do vento no cenário heterógeno, com as vegetações campestre, savânica e florestal. A aptidão do melhor indivíduo foi de 0,12094, enquanto o *fitness* médio das execuções foi de $0,124160 \pm ,.0098$. Para as três vegetações, os valores de LR se aproximaram do valor máximo (999 para a Veg1, 999 para a Veg2 e 992 para a Veg3). Os valores de LQ é distinto para cada vegetação (12 para a Veg1, 9 para a Veg2 e 26 para a Veg3). As três matrizes (Figura 119(a)) direcionam o vento para o sudeste, conforme as forças vetoriais obtidas (Figura 119(b)).

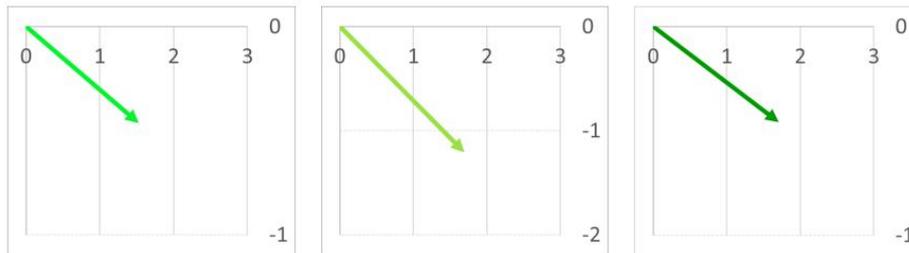
1.000	0.449	0.000
0.449	-	0.000
0.308	0.180	0.099
12	999	

0.971	1.000	0.137
0.749	-	0.000
0.501	0.222	0.000
9	999	

0.999	1.000	0.217
0.911	-	0.123
0.528	0.441	0.006
26	992	

Veg1
Veg2
Veg3

(a) Parâmetros Obtidos pelo AG



(b) Forças Vetoriais Obtidas pelo AG

Figura 119 – Configuração encontrada pelo AG e a representação vetorial do vento resultante para o cenário heterogêneo com três vegetações gerado a partir do modelo (TINOCO et al., 2022)

A Figura 120 apresenta as simulações de incêndio do modelo de referência (Figura 120(a)) e do modelo padrão (Figura 120(b)). As simulações configuradas pelo AG com os novos valores de domínio para LQ e LR (Figura 120(b)) são mais semelhantes à referência do que as evoluídas anteriormente com os valores mais restritos de domínio para esses parâmetros (Figura 108(b)): o fogo se espalha com menos velocidade pelo reticulado.

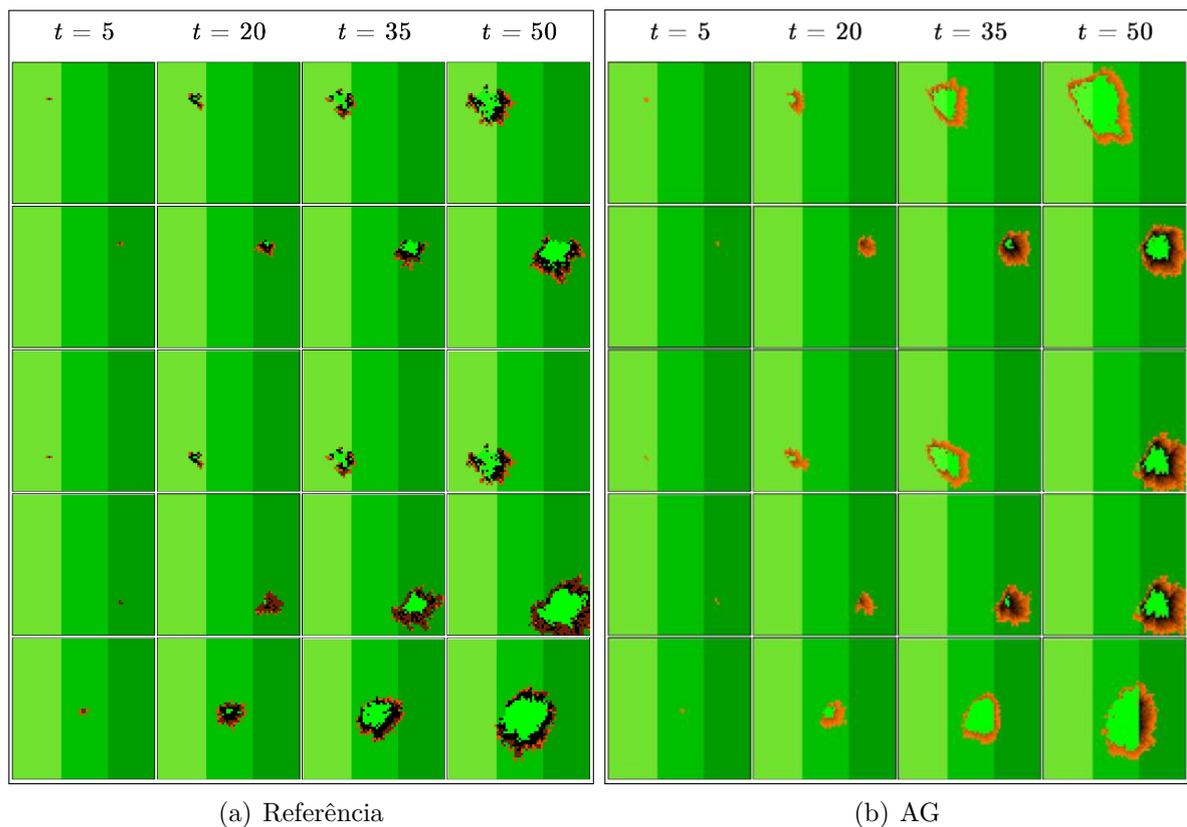


Figura 120 – Evolução temporal do autômato celular nas simulações de incêndio em um cenário heterogêneo com três vegetações, de acordo com o modelo empregado: (a) referência (TINOCO et al., 2022); e (b) configurado pelo AG.

Embora o comportamento do autômato celular probabilístico tenha diferenças significativas, tais diferenças não se refletem na função de aptidão do algoritmo genético, uma vez que os valores de *fitness* obtidos são muito próximos aos previamente obtidos. O *fitness* é diretamente dependente da estocasticidade do processo, o que pode justificar essas variações pouco significativas, mas que resultam em uma pressão seletiva insuficiente para modelos mais complexos. Para esses casos, torna-se necessário investigar no futuro uma função de aptidão mais sensível às diferenças entre as simulações para que o algoritmo genético possa otimizar os ajustes de forma a obter uma reprodutibilidade maior em relação ao modelo mais complexo descrito em (TINOCO et al., 2022).

Conclusões

Este trabalho propôs uma abordagem evolutiva para o ajuste automático dos parâmetros de um modelo de propagação de incêndios baseado em autômato celular probabilístico.

Os resultados experimentais mostraram que é possível desenvolver um algoritmo genético capaz de definir valores adequados para o conjunto de parâmetros do modelo, de modo que as simulações resultantes apresentem um comportamento de espalhamento similar àquele observado nos dados artificiais usados como referência.

Resultados iniciais mostraram que o desempenho do algoritmo é afetado quando o início do fogo ocorre em uma posição desfavorável à observação da dinâmica do incêndio. Por exemplo, se o vento tende para o sul e o fogo é simulado de um ponto próximo à base do reticulado, as chamas atingem rapidamente a borda sul, sem gerar informações suficientes para que o AG capture com precisão a dinâmica e ajuste a matriz de preferências corretamente. Entretanto, a estratégia de avaliação baseada em diferentes simulações, cada qual adotando um ponto distinto para o início do fogo, tornou a abordagem evolutiva mais robusta, resultando em simulações muito próximas das dinâmicas observadas nos dados de referência. Do ponto de vista prático, ao usar imagens reais de incêndio para evoluir os parâmetros do modelo, tal estratégia pode ser implementada a partir da captura de sequências de imagens com diferentes perspectivas da área monitorada.

Os experimentos também mostram que foi possível adaptar o algoritmo genético para ajustar os parâmetros de um modelo de propagação de fogo baseado em vegetação heterogênea. Mesmo em cenários mais complexos, em que o número de parâmetros a serem obtidos pelo AG aumenta consideravelmente, a estratégia evolutiva teve êxito em encontrar matrizes de preferências com intensidade e direção similares às observadas nos dados de referência. Mesmo em um cenário heterogêneo formado por quatro tipos de vegetações distribuídas de forma irregular (representações baseadas em áreas do Parque Estadual do Pau Furado), a estratégia evolutiva mostrou-se eficiente em reproduzir o comportamento da referência.

De forma geral, a abordagem proposta foi capaz de reproduzir com similaridade o com-

portamento de incêndios a partir de dados gerados com o mesmo modelo de propagação utilizado na avaliação dos indivíduos. Por outro lado, a reprodução do comportamento foi mais desafiadora quando os dados gerados como referência para o AG foram gerados por modelos de propagação diferentes do modelo empregado pelo AG no ajuste dos parâmetros. Entretanto, mesmo que a similaridade do comportamento obtido pelo modelo ajustado pelo AG nesse caso não seja tão próxima, ainda assim foi possível observar que o método evolutivo se adaptou buscando se aproximar do comportamento registrado pelos dados de referência. Foi possível notar que o algoritmo genético buscou por valores de LQ e LR a fim de mimetizar as características dos modelos investigados [(LIMA; LIMA, 2014); (TINOCO et al., 2022)]. Em relação às matrizes de vento, foi possível observar que os parâmetros encontrados resultaram em dinâmicas do fogo semelhantes às observadas nos diferentes cenários investigados no modelo (LIMA; LIMA, 2014). No geral, a direção principal do vento foi captada com precisão e a intensidade também se aproximou daquela representada nos dados de referência do modelo mais simples (LIMA; LIMA, 2014). Entretanto, quando os dados de referência foram gerados por um modelo de propagação de incêndio mais complexo (TINOCO et al., 2022), os parâmetros foram ajustados pelo AG de forma que a característica da direção do vento foi captada com maior precisão, enquanto a intensidade do vento ficou em geral maior que a observada nos dados de referência. Como resultado, a propagação do incêndio no modelo ajustado se mostrou mais veloz e ampla do que a observada nos dados de referência. Em modelos de simulação de incêndios florestais mais complexos, como é o caso do modelo (TINOCO et al., 2022) onde há uma grande quantidade de variáveis interdependentes, a função de aptidão pode não ser suficiente para capturar todas as nuances do problema. É fundamental buscar formas de melhorar a função de aptidão da ferramenta evolutiva aplicada em modelos mais complexos de simulação de incêndios. Isso pode envolver a inclusão de novas variáveis, a consideração de interações entre variáveis existentes e a utilização de técnicas mais avançadas de modelagem e simulação. Esses experimentos são importantes pois antecipam uma dificuldade de ajuste do modelo a partir de dados ou imagens de incêndios reais.

7.1 Trabalhos Futuros

Como trabalho futuros, almeja-se aumentar a complexidade do modelo, de modo a representar novas características da vegetação (combustão espontânea), e da região (umidade do ar, topografia, relevo, densidade de biomassa e outras características que aumentam a probabilidade de combustão). Outros modelos de vento podem ser explorados, seja representando a matriz de preferências simetricamente ou diretamente o vento vetorial decomposto em matriz, como no modelo (TINOCO et al., 2022).

Em relação à estratégia evolutiva, pretende-se buscar novas estratégias para avaliação, a fim de eliminar ou reduzir as diferenças de propagação observadas em modelos mais

complexos. Em cenários heterogêneos, por exemplo, uma estratégia seria evolução multi-estágio para aprimorar a otimização dos parâmetros do AC. Uma análise interessante sobre o modelo proposto seria a investigação da sensibilidade da eficiência do ajuste evolutivo de parâmetros em relação ao tamanho do reticulado (MONTEIRO; OLIVEIRA; CHAUI-BERLINCK, 2009). Considerando os resultados em cenários mais complexos, como os obtidos utilizando a base de referência do modelo (TINOCO et al., 2022) é necessário aprimorar a função de avaliação utilizada pelo AG. Ela deve ser capaz de identificar as diferenças entre a simulação baseada no indivíduo do AG e a série histórica representada pela base de referência em relação não só à distribuição do fogo pelo reticulado, mas também em relação ao tempo de queima e de recuperação e à velocidade da propagação das chamas. A utilização de funções que levem em consideração as tendências das séries históricas além das diferenças absolutas nas células, pode nos auxiliar nesse aprimoramento, como na função de avaliação adotada em (MONTEIRO; OLIVEIRA; CHAUI-BERLINCK, 2009).

Também pretende-se validar a abordagem evolutiva usando dados de incêndios reais no do Cerrado brasileiro. Nesse sentido, será necessário realizar o processamento das imagens de satélite, gerando as bases de referência e adaptando o modelo em reticulados que correspondam a cenários reais. Dessa forma, a incorporação de novas características da vegetação e da região, bem como a busca por novas estratégias de avaliação e a validação com dados reais, são passos importantes para aumentar a eficácia e precisão dos modelos de previsão de incêndios florestais, visando proteger a biodiversidade e minimizar os impactos negativos causados por esses eventos.

7.2 Produção Bibliográfica Resultante da Pesquisa

Este trabalho resultou em dois artigos em eventos científicos internacionais (FERREIRA et al., 2022b) e (FERREIRA et al., 2022a)).

Em (FERREIRA et al., 2022b) é apresentado o modelo de propagação de incêndio baseado em autômato celular usado em nossa pesquisa, assim como a abordagem evolutiva para ajuste automático dos parâmetros do modelo, a partir de dados de referência que apresentem a evolução espaço-temporal de um incêndio florestas. O artigo apresenta os resultados alcançados na simulação de cenários com vegetação homogênea.

Em (FERREIRA et al., 2022a) é apresentada a adaptação do modelo de autômato celular para lidar com mais de um tipo de vegetação (cenário heterogêneo), bem como os resultados obtidos pelo algoritmo genético no ajuste dos parâmetros para esse tipo de cenário, considerando dados artificiais gerados pelo próprio modelo e pelo modelo (LIMA; LIMA, 2014). O artigo também apresenta a análise da evolução dos parâmetros e da robustez do método ao deslocamento espacial dos dados.

Referências

- ALEXANDRIDIS, A.; VAKALIS, D.; SIETTOS, C. I.; BAFAS, G. V. A cellular automata model for forest fire spread prediction: The case of the wildfire that swept through spetses island in 1990. **Applied Mathematics and Computation**, Elsevier, v. 204, n. 1, p. 191–201, 2008. Disponível em: <<https://doi.org/10.1016/j.amc.2008.06.046>>.
- ALMEIDA, G. M.; SALLES, J. L. F.; FILHO, J. D. Using genetic algorithm to optimize the tuning parameters of dynamic matrix control. In: SOCIEDADE BRASILEIRA DE INTELIGÊNCIA COMPUTACIONAL. **Proc. Brazilian Symp. Comput. Intell.** 2007. p. 1–5. Disponível em: <https://sbic.org.br/eventos/sbic_2007/60100038-2/>.
- ALVES, R. M. de F.; SILVA, F. N. R. da; MOTA, D. P.; MYSMAR, D.; ALVES, S. M. de F. Seleção de pessoas por meio de algoritmos genéticos. **Revista de Administração da Universidade Federal de Santa Maria**, v. 10, n. 2, p. 307–317, 2017. Disponível em: <<https://doi.org/10.5902/1983465910047>>.
- AYALA-RAMIREZ, V.; GARCIA-CAPULIN, C. H.; PEREZ-GARCIA, A.; SANCHEZ-YANEZ, R. E. Circle detection on images using genetic algorithms. **Pattern Recognition Letters**, Elsevier, v. 27, n. 6, p. 652–657, 2006. Disponível em: <<https://doi.org/10.1016/j.patrec.2005.10.003>>.
- CARNEIRO, M. G.; OLIVEIRA, G. M. B. Um modelo baseado em autômatos celulares síncronos para o escalonamento de tarefas em multiprocessadores. In: SBC. **Anais do X Congresso Brasileiro de Inteligência Computacional.** 2011. Disponível em: <<http://dx.doi.org/10.21528/CBIC2011-40.4>>.
- _____. Synchronous cellular automata-based scheduler initialized by heuristic and modeled by a pseudo-linear neighborhood. **Natural Computing**, Springer, v. 12, n. 3, p. 339–351, 2013. Disponível em: <<https://doi.org/10.1007/s11047-013-9375-8>>.
- CHEN, L.; KOU, C.; MA, S.-W. Genetic algorithm combining operation tree (gaot) for concrete performance. In: ATLANTIS PRESS. **5th International Conference on Information Engineering for Mechanics and Materials.** 2015. p. 445–450. Disponível em: <<https://doi.org/10.2991/icimm-15.2015.84>>.
- CHOPARD, B.; DROZ, M. **Cellular automata modeling of physical systems.** Cambridge: Cambridge University Press, 1998. Disponível em: <<https://doi.org/10.1017/cbo9780511549755.003>>.

- CLARKE, K. C.; BRASS, J. A.; RIGGAN, P. J. A cellular automaton model of wildfire propagation and extinction. **Photogrammetric Engineering & Remote Sensing**, 1994.
- CONWAY, J. et al. The game of life. **Scientific American**, v. 223, n. 4, p. 4, 1970.
- COUTINHO, L. M. O conceito de bioma. **Acta botanica brasílica**, SciELO Brasil, v. 20, p. 13–23, 2006. Disponível em: <<https://doi.org/10.1590/s0102-33062006000100002>>.
- D'AMBROSIO, D.; IOVINE, G.; SPATARO, W.; MIYAMOTO, H. A macroscopic collisional model for debris-flows simulation. **Environmental Modelling & Software**, Elsevier, v. 22, n. 10, p. 1417–1436, 2007. Disponível em: <<https://doi.org/10.1016/j.envsoft.2006.09.009>>.
- DARWIN, C. **The origin of species: by means of natural selection or the preservation of favoured races in the struggle for life**. Oxford, 1956. Disponível em: <<https://doi.org/10.1093/owc/9780199580149.003.0005>>.
- DILÃO, R. Autômatos celulares, máquinas de turing ou a natureza como máquina de cálculo. Fundação Calouste Gulbenkian, 1992.
- D'AMBROSIO, D.; SPATARO, W. Parallel evolutionary modelling of geological processes. **Parallel Computing**, 2007. Disponível em: <<https://doi.org/10.1016/j.parco.2006.12.003>>.
- ENCINAS, L. H.; WHITE, S. H.; REY, A. M. D.; SÁNCHEZ, G. R. Modelling forest fire spread using hexagonal cellular automata. **Applied mathematical modelling**, Elsevier, v. 31, n. 6, p. 1213–1227, 2007. Disponível em: <<https://doi.org/10.1016/j.apm.2006.04.001>>.
- FERREIRA, M. E. A.; LIMA, D. A.; MARTINS, L. G. A.; OLIVEIRA, G. M. B. Refining a parameter setting evolutionary approach for fire spreading models based on cellular automata. 2022.
- FERREIRA, M. E. A.; QUINTA, A. L. M. P.; LIMA, D. A.; MARTINS, L. G. A.; OLIVEIRA, G. M. B. Automatic evolutionary adjustment of cellular automata model for forest fire propagation. In: **Cellular Automata**. Cham: Springer International Publishing, 2022. p. 235–245. Disponível em: <https://doi.org/10.1007/978-3-031-14926-9_21>.
- FONSECA, C. M.; FLEMING, P. J. et al. Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization. In: CITESEER. **Fifth International Conference on Genetic Algorithms (ICGA)**. 1993. v. 93, n. July, p. 416–423. Disponível em: <<https://doi.org/110.5555/645513.657757>>.
- FRAGA, L. M.; OLIVEIRA, G. M. B.; MARTINS, L. G. A. Multistage evolutionary strategies for adjusting a cellular automata-based epidemiological model. In: IEEE. **IEEE Congress on Evolutionary Computation (CEC)**. 2021. Disponível em: <<https://doi.org/10.1109/CEC45853.2021.9504738>>.
- FREYHULT, E.; MOULTON, V.; CLOTE, P. Boltzmann probability of rna structural neighbors and riboswitch detection. **Bioinformatics**, Oxford University Press, v. 23, n. 16, p. 2054–2062, 2007. Disponível em: <<https://doi.org/10.1093/bioinformatics/btm314>>.

- GARCÍA-DURO et al. Hidden costs of modelling post-fire plant community assembly using cellular automata. 2018. Disponível em: <http://dx.doi.org/10.1007/978-3-319-99813-8_6>.
- GERARDI, D.; MONTEIRO, L. System identification and prediction of dengue fever incidence in rio de janeiro. **Mathematical Problems in Engineering**, Hindawi, v. 2011, 2011. Disponível em: <<https://doi.org/10.1155/2011/720304>>.
- GOLDBERG, D. E.; HOLLAND, J. H. Genetic algorithms and machine learning. Kluwer Academic Publishers-Plenum Publishers; Kluwer Academic Publishers, 1988.
- GRINSTEIN, G.; JAYAPRAKASH, C.; HE, Y. Statistical mechanics of probabilistic cellular automata. **Physical review letters**, APS, v. 55, n. 23, p. 2527, 1985. Disponível em: <<https://doi.org/10.1103/physrevlett.55.2527>>.
- HOLLAND, J. H. **Hierarchical descriptions, universal spaces and adaptive systems**. Michigan, 1968.
- IEF, I. E. d. F. **Caderno de mapas do Pau Furado**. 2011. Disponível em: <<http://www.ief.mg.gov.br/component/content/article/205>>.
- IOANNIDIS, K.; SIRAKOULIS, G. C.; ANDREADIS, I. A path planning method based on cellular automata for cooperative robots. **Applied Artificial Intelligence**, Taylor & Francis, v. 25, n. 8, p. 721–745, 2011. Disponível em: <<https://doi.org/10.1080/08839514.2011.606767>>.
- JAYACHITRA, A.; VINODHA, R. Genetic algorithm based pid controller tuning approach for continuous stirred tank reactor. **Advances in Artificial Intelligence (16877470)**, 2014. Disponível em: <<https://doi.org/10.1155/2014/791230>>.
- KARAFYLLIDIS, I.; THANAILAKIS, A. A model for predicting forest fire spreading using cellular automata. **Ecological Modelling**, 1997. Disponível em: <[https://doi.org/10.1016/s0304-3800\(96\)01942-4](https://doi.org/10.1016/s0304-3800(96)01942-4)>.
- LAFETÁ, T. F. d. Q.; BUENO, M. L. d. P.; BRASIL, C.; OLIVEIRA, G. M. B. Meands: A many-objective evolutionary algorithm based on non-dominated decomposed sets applied to multicast routing. **Applied Soft Computing**, Elsevier, v. 62, p. 851–866, 2018. Disponível em: <<https://doi.org/10.1016/j.asoc.2017.09.017>>.
- LAFETÁ, T. F. d. Q.; OLIVEIRA, G. M. B. Applying dynamic evolutionary optimization to the multiobjective knapsack problem. In: SPRINGER. **Brazilian Conference on Intelligent Systems (BRACIS)**. 2020. p. 49–63. Disponível em: <https://doi.org/10.1007/978-3-030-61377-8_4>.
- LEUNG, F. H.-F.; LAM, H.-K.; LING, S.-H.; TAM, P. K.-S. Tuning of the structure and parameters of a neural network using an improved genetic algorithm. In: . IEEE, 2003. v. 14, n. 1, p. 79–88. Disponível em: <<https://doi.org/10.1109/TNN.2002.804317>>.
- LI, C.; LIU, S.; CEN, X. Safety and efficiency impact of pedestrian–vehicle conflicts at non signalized midblock crosswalks based on fuzzy cellular automata. **Physica A: Statistical Mechanics and its Applications**, Elsevier, v. 572, p. 125871, 2021. Disponível em: <<https://doi.org/10.1016/j.physa.2021.125871>>.

- LIMA, D.; LIMA, H. Autômatos celulares estocásticos bidimensionais aplicados à simulação de propagação de incêndios em florestas homogêneas. In: SBC. **Anais do V Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais**. 2014. p. 15–24. Disponível em: <<https://sol.sbc.org.br/index.php/wcama/article/view/10907>>.
- LIMA, D. A. et al. Modelo criptográfico baseado em autômatos celulares tridimensionais híbridos. 2012. Disponível em: <<https://doi.org/10.14393/ufu.di.2012.341>>.
- LIMA, D. A.; TINOCO, C. R.; OLIVEIRA, G. M. B. A cellular automata model with repulsive pheromone for swarm robotics in surveillance. In: IEEE. **International Conference on Cellular Automata for Research and Industry (ACRI)**. 2016. Disponível em: <http://dx.doi.org/10.1007/978-3-319-44365-2_31>.
- LINDEN, R. **Algoritmos genéticos**. Rio de Janeiro: Brasport, 2008.
- LOPES, H. J.; LIMA, D. A. Surveillance task optimized by evolutionary shared tabu inverted ant cellular automata model for swarm robotics navigation control. **Results in Control and Optimization**, Elsevier, v. 8, p. 100141, 2022. Disponível em: <<https://doi.org/10.2139/ssrn.3962774>>.
- LOUZADA, V. H. P.; JUNIOR, W. Incêndios florestais em autômatos celulares, simples e grandes queimadas. **Biomatemática-Unicamp**, v. 18, p. 15–26, 2008.
- LOZANO, K. K. C. Autômatos celulares probabilísticos com aplicações a sistemas biológicos. Universidade Federal do Rio de Janeiro, 2017.
- MAIA, J. P. S.; OLIVEIRA, V. A.; SILVA, A. N. Os aspectos sociais, emocionais e econômicos como danos secundários do incêndio florestal. **Biodiversidade Brasileira-BioBrasil**, n. 1, p. 82–82, 2019.
- MANNING, T.; SLEATOR, R. D.; WALSH, P. Naturally selecting solutions: the use of genetic algorithms in bioinformatics. **Bioengineered**, Taylor & Francis, v. 4, n. 5, p. 266–278, 2013. Disponível em: <<https://doi.org/10.4161/bioe.23041>>.
- MATIC, D. A genetic algorithm for composing music. **Yugoslav Journal of Operations Research**, v. 20, n. 1, 2016. Disponível em: <<https://doi.org/10.2298/yjor1001157m>>.
- MAULIK, U. Medical image segmentation using genetic algorithms. **IEEE Transactions on information technology in biomedicine**, IEEE, v. 13, n. 2, p. 166–173, 2009. Disponível em: <<https://doi.org/10.1109/titb.2008.2007301>>.
- MICHALEWICZ, Z.; FOGEL, D. B. Constraint-handling techniques. In: **How to Solve It: Modern Heuristics**. Berlin: Springer, 2004. p. 231–270. Disponível em: <<https://doi.org/10.1002/9781119490616.ch12>>.
- MITCHELL, M. **An introduction to genetic algorithms**. Michigan: MIT press, 1998.
- MITCHELL, M.; CRUTCHFIELD, J. P.; DAS, R. et al. Evolving cellular automata with genetic algorithms: A review of recent work. In: MOSCOW. **Proceedings of the First International Conference on Evolutionary Computation and Its Applications (EvCA'96)**. 1996. v. 8. Disponível em: <<https://csc.ucdavis.edu/~evca/Papers/evca-review.pdf>>.

MITCHELL, M.; CRUTCHFIELD, J. P.; HRABER, P. T. Evolving cellular automata to perform computations: Mechanisms and impediments. **Physica D**, 1994.

MITCHELL, M. et al. **Computation in Cellular Automata: a selected review**. 2005. Disponível em: <<https://doi.org/10.1002/3527602968.ch4>>.

MONTEIRO, L.; OLIVEIRA, D.; CHAUÍ-BERLINCK, J. The effect of spatial scale on predicting time series: a study on epidemiological system identification. **Mathematical Problems in Engineering**, Hindawi, v. 2009, 2009. Disponível em: <<https://doi.org/10.1155/2009/137854>>.

MONTEIRO, L. H. A.; GANDINI, D.; SCHIMIT, P. H. The influence of immune individuals in disease spread evaluated by cellular automaton and genetic algorithm. **Computer methods and programs in biomedicine**, Elsevier, v. 196, p. 105707, 2020. Disponível em: <<https://doi.org/10.1016/j.cmpb.2020.105707>>.

MORAIS, B. W. D.; OLIVEIRA, G. M. B. de; CARVALHO, T. I. de. Evolutionary models applied to multiprocessor taskscheduling: Serial and multipopulation genetic algorithm. **Revista de Informática Teórica e Aplicada**, v. 26, n. 1, p. 11–25, 2019. Disponível em: <<https://doi.org/10.22456/2175-2745.82412>>.

MOREIRA, A. P.; FILHO, A. C. P.; GUARALDO, E. Mapeamento dos incêndios florestais no bioma pantanal e bacia do alto paraguai entre 2018 e 2019. **Revista de Ciências Ambientais**, v. 15, n. 2, p. 01–13, 2021. Disponível em: <<https://doi.org/10.18316/rca.v15i2.6898>>.

NEUMANN, J. V.; BURKS, A. W. et al. Theory of self-reproducing automata. **IEEE Transactions on Neural Networks**, v. 5, n. 1, p. 3–14, 1966.

NORVIG, P.; RUSSELL, S. Inteligência artificial. **Editora Campus**, v. 20, 2004.

OLIVEIRA, G. M. Autômatos celulares: aspectos dinâmicos e computacionais. **III Jornada de Mini-cursos em Inteligência Artificial (MCIA)**, v. 8, p. 297–345, 2003.

OLIVEIRA, G. M. B.; MARTINS, L. G. A.; TAKIGUTI, M. C. Mo-miner: A data mining tool based on multi-objective genetic algorithms. IntechOpen, 2008. Disponível em: <<https://doi.org/10.5772/5522>>.

OLIVEIRA, G. M. B.; OLIVEIRA, P. P. D.; OMAR, N. Definition and application of a five-parameter characterization of one-dimensional cellular automata rule space. **Artificial life**, MIT Press, v. 7, n. 3, p. 277–301, 2001. Disponível em: <<https://doi.org/10.1162/106454601753238645>>.

OLIVEIRA, G. M. B.; SILVA, R. G.; FERREIRA, G. B.; COUCEIRO, M. S.; AMARAL, L. R. D.; VARGAS, P. A.; MARTINS, L. G. A. A cellular automata-based path-planning for a cooperative and decentralized team of robots. In: IEEE. **2019 IEEE Congress on Evolutionary Computation (CEC)**. 2019. p. 739–746. Disponível em: <<https://doi.org/10.1109/CEC.2019.8790205>>.

PACKARD, N. H. Adaptation toward the edge of chaos. **Dynamic patterns in complex systems**, World Scientific, v. 212, p. 293–301, 1988.

- POTVIN, J.-Y. Genetic algorithms for the traveling salesman problem. **Annals of Operations Research**, Springer, v. 63, n. 3, p. 337–370, 1996. Disponível em: <<https://doi.org/10.1007/bf02125403>>.
- ROCHA, J. C. Cor luz, cor pigmento e os sistemas rgb e cmy. **Revista Belas Artes**, v. 3, n. 2, 2010.
- ROTHERMEL, R. C. **A mathematical model for predicting fire spread in wildland fuels**. Ogden, Utah: University of Minnesota, 1972.
- RUSSELL, S.; RUSSELL, S.; NORVIG, P.; DAVIS, E. **Artificial Intelligence: A modern approach**. Prentice Hall, 2010. (Prentice Hall series in artificial intelligence). ISBN 9780136042594. Disponível em: <<https://aima.cs.berkeley.edu/>>.
- SANTOS, J. P. d. C. M. d. **Aplicação de um modelo de autómatos celulares à propagação de fogos no Parque Natural da Serra da Arrábida**. Tese (Doutorado), 2007.
- SCHADSCHNEIDER, A. Cellular automaton approach to pedestrian dynamics-theory. **arXiv preprint cond-mat/0112117**, 2001.
- SHAN, J.; ALKHEDER, S.; WANG, J. Genetic algorithms for the calibration of cellular automata urban growth modeling. **Photogrammetric Engineering & Remote Sensing**, American Society for Photogrammetry and Remote Sensing, v. 74, n. 10, p. 1267–1277, 2008. Disponível em: <<https://doi.org/10.14358/pers.74.10.1267>>.
- SIDIROPOULOS, E.; TOLIKAS, P. Genetic algorithms and cellular automata in aquifer management. **Applied Mathematical Modelling**, Elsevier, v. 32, n. 4, p. 617–640, 2008. Disponível em: <<https://doi.org/10.1016/j.apm.2007.01.005>>.
- SLIMI, R.; YACOUBI, S. E.; DUMONTEIL, E.; GOURBIERE, S. A cellular automata model for chagas disease. **Applied mathematical modelling**, 2009. Disponível em: <<https://doi.org/10.1016/j.apm.2007.12.028>>.
- SUN, L.; XU, C.; HE, Y.; ZHAO, Y.; XU, Y.; RUI, X.; XU, H. Adaptive forest fire spread simulation algorithm based on cellular automata. **Forests**, MDPI, v. 12, n. 11, p. 1431, 2021. Disponível em: <<https://doi.org/10.3390/f12111431>>.
- SWIECICKA, A.; SEREDYNSKI, F.; ZOMAYA, A. Y. Multiprocessor scheduling and rescheduling with use of cellular automata and artificial immune system support. **IEEE Transactions on Parallel and Distributed Systems**, IEEE, v. 17, n. 3, p. 253–262, 2006. Disponível em: <<https://doi.org/10.1109/tpds.2006.38>>.
- SZABAN, M.; SEREDYNSKI, F.; BOUVRY, P. Evolving collective behavior of cellular automata for cryptography. In: IEEE. **MELECON 2006-2006 IEEE Mediterranean Electrotechnical Conference**. 2006. p. 799–802. Disponível em: <<https://doi.org/10.1109/MELCON.2006.1653219>>.
- SZABÓ, G.; TÓKE, C. Evolutionary prisoner's dilemma game on a square lattice. **Physical Review E**, APS, v. 58, n. 1, p. 69, 1998. Disponível em: <<https://doi.org/10.1103/physreve.58.69>>.

TINOCO, C. R.; FERREIRA, H. F.; MARTINS, L. G. A.; OLIVEIRA, G. M. B. Wildfire simulation model based on cellular automata and stochastic rules. In: SPRINGER. **International Conference on Cellular Automata for Research and Industry**. 2022. v. 15. Disponível em: <https://doi.org/10.1007/978-3-031-14926-9_22>.

TINOCO, C. R.; VIZZARI, G.; OLIVEIRA, G. M. B. Parameter adjustment of a bio-inspired coordination model for swarm robotics using evolutionary optimisation. In: SPRINGER. **International Conference on Cellular Automata for Research and Industry (ACRI)**. 2020. p. 146–155. Disponível em: <https://doi.org/10.1007/978-3-030-69480-7_15>.

TOFFOLI, T.; MARGOLUS, N. **Cellular automata machines: a new environment for modeling**. Cambridge, 1987. (MIT Press series in scientific computation). ISBN 9780262200608. Disponível em: <<https://ieeexplore.ieee.org/book/6267503>>.

TOMINAGA, D.; KOGA, N.; OKAMOTO, M. Efficient numerical optimization algorithm based on genetic algorithm for inverse problem. In: ASSOCIATION FOR COMPUTING MACHINERY NEW YORK NY UNITED STATES. **Proceedings of the 2nd Annual Conference on Genetic and Evolutionary Computation**. 2000. p. 251–258. Disponível em: <<https://dblp.org/rec/conf/gecco/2000.bib>>.

TONGUZ, O. K.; VIRIYASITAVAT, W.; BAI, F. Modeling urban traffic: a cellular automata approach. **IEEE Communications Magazine**, IEEE, v. 47, n. 5, p. 142–150, 2009. Disponível em: <<https://doi.org/10.1109/mcom.2009.4939290>>.

TSAI, J.-T.; CHOU, J.-H.; LIU, T.-K. Tuning the structure and parameters of a neural network by using hybrid taguchi-genetic algorithm. **IEEE Transactions on Neural Networks**, IEEE, v. 17, n. 1, p. 69–80, 2006. Disponível em: <<https://doi.org/10.1109/tnn.2005.860885>>.

VELHO, H. F. de C. Problemas inversos: conceitos básicos e aplicações. **Anais do Encontro de Modelagem Computacional. Mini-curso**, p. 63–79, 2001.

WANG, L.; XU, W.; XU, A. Three-dimensional cellular automata based particle flow simulations of mechanical properties of talus deposit. **Journal of Rock Mechanics and Geotechnical Engineering**, v. 4, n. 4, p. 375–384, 2012. Disponível em: <<https://doi.org/10.3724/sp.j.1235.2012.00375>>.

WHITE, S. H.; REY, A. M. D.; SÁNCHEZ, G. R. Modeling epidemics using cellular automata. **Applied mathematics and computation**, Elsevier, v. 186, n. 1, p. 193–202, 2007. Disponível em: <<https://doi.org/10.1016/j.amc.2006.06.126>>.

WOLFRAM, S. Cellular automata as simple self-organizing systems. **Caltech**, 1982.

WOLFRAM, S. a. **Cryptography with cellular automata**. Princeton, 1985. 429–432 p. Disponível em: <<https://doi.org/10.1201/9780429494093-17>>.

XAVIER, C. R.; SANTOS, E. P. dos; VIEIRA, V. da F.; SANTOS, R. W. dos. Genetic algorithm for the history matching problem. **Procedia Computer Science**, Elsevier, v. 18, p. 946–955, 2013. Disponível em: <<https://doi.org/10.1016/j.procs.2013.05.260>>.

XUEHUA, W.; CHANG, L.; JIAQI, L.; XUEZHI, Q.; NING, W.; WENJUN, Z. A cellular automata model for forest fire spreading simulation. In: IEEE. **2016 IEEE Symposium Series on Computational Intelligence (SSCI)**. 2016. p. 1–6. Disponível em: <<https://doi.org/10.1109/SSCI.2016.7849971>>.

YONGZHONG, Z.; FENG, Z.-D.; TAO, H.; LIYU, W.; KEGONG, L.; XIN, D. Simulating wildfire spreading processes in a spatially heterogeneous landscapes using an improved cellular automaton model. In: IEEE. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**. 2004. v. 5, p. 3371–3374. Disponível em: <<http://dx.doi.org/10.1109/IGARSS.2004.1370427>>.