

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Pedro Luiz Martins Simoni

**Ajuste Evolutivo de um Modelo de Autômatos
Celulares para Simulação de Dinâmica de
Evacuação de Pedestres**

Uberlândia, Brasil

2026

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Pedro Luiz Martins Simoni

**Ajuste Evolutivo de um Modelo de Autômatos Celulares
para Simulação de Dinâmica de Evacuação de Pedestres**

Trabalho de conclusão de curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia, como parte dos requi-
sitos exigidos para a obtenção do título de
Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Luiz Gustavo Almeida Martins

Universidade Federal de Uberlândia – UFU

Faculdade de Computação

Bacharelado em Ciência da Computação

Uberlândia, Brasil

2026

Pedro Luiz Martins Simoni

Ajuste Evolutivo de um Modelo de Autômatos Celulares para Simulação de Dinâmica de Evacuação de Pedestres

Trabalho de conclusão de curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia, como parte dos requi-
sitos exigidos para a obtenção do título de
Bacharel em Ciência da Computação.

Trabalho aprovado. Uberlândia, 07 de agosto de 2026:

**Prof. Dr. Luiz Gustavo Almeida
Martins**
Orientador

Prof. Dr. Claudiney Ramos Tinoco

**Prof. Dr. Paulo Henrique Ribeiro
Gabriel**

Uberlândia, Brasil
2026

Agradecimentos

Agradeço aos meus pais, Juliana Mara Martins e Luiz Gustavo Simoni, e a toda a minha família, especialmente aos meus avós, tios, tias e primas, pelo suporte que tive desde sempre e que me acompanhou de forma contínua por toda a minha jornada na faculdade. Dedico este trabalho a vocês, como resultado de toda a confiança que sempre depositaram em mim.

Agradeço a todos os professores que me auxiliaram e me ensinaram tanto ao longo dessa caminhada, em especial ao Prof. Dr. Luiz Gustavo Almeida Martins, que tornou este trabalho possível e me orientou em sua construção, além de tudo o que me ensinou em sala de aula.

Agradeço também à minha namorada, Julia, e a todos os meus amigos, que me ajudaram a passar pelos momentos mais difíceis da graduação da forma mais leve e feliz possível.

Obrigado por tornarem esses últimos 4 anos inesquecíveis.

Resumo

Situações de emergência em ambientes fechados exigem que um grande número de pessoas evacue em pouco tempo, e observar esse comportamento diretamente é inviável por razões éticas e de custo. A simulação computacional supre essa lacuna, ao permitir reproduzir e estudar tais situações e apoiar o planejamento de medidas de segurança. Entre as técnicas disponíveis, os Autômatos Celulares (ACs) destacam-se por sua natureza leve e rápida, que viabiliza a exploração dinâmica de muitas situações e variáveis. Modelos dessa natureza, porém, dependem de parâmetros comportamentais que raramente podem ser medidos de forma direta, o que transforma sua configuração em um problema de busca em um espaço amplo e não linear, para o qual os Algoritmos Genéticos (AGs) são uma alternativa consolidada. Este trabalho propõe um AG construído para ajustar os parâmetros de um modelo baseado em AC de dinâmica de pedestres que combina dois modelos da literatura, um que introduz a escolha gulosa de movimento e outro que introduz os conceitos de campo de confusão e sinalização. O ajuste de parâmetros do AG é feito por meio da análise de métricas espaciais e temporais da evacuação: densidade, dispersão, fluxo e tempo total. Devido à ausência de dados reais, avaliou-se a eficiência do algoritmo em reproduzir a dinâmica observada em dados gerados artificialmente com o próprio modelo de AC, além do comportamento do modelo em testes normativos de dinâmicas de pedestres. Adicionalmente, o mesmo mecanismo evolutivo foi aproveitado para otimizar essas mesmas métricas por meio do posicionamento de placas de sinalização sobre o modelo já calibrado. Resultados experimentais mostraram que o modelo calibrado pelo AG foi capaz de reproduzir o comportamento espacial de referência nos regimes examinados, assim como a otimização de placas reduziu o tempo de evacuação, sendo esse ganho dependente da topologia do ambiente.

Palavras-chave: autômato celular; algoritmo genético; simulação de evacuação; calibração de parâmetros; identificabilidade; sinalização de emergência.

Abstract

Emergency situations in enclosed spaces require a large number of people to evacuate in a short time, and observing this behavior directly is unfeasible for ethical and cost reasons. Computational simulation fills this gap by allowing such situations to be reproduced and studied, and by supporting the planning of safety measures. Among the available techniques, Cellular Automata (CA) stand out for being lightweight and fast, which makes it feasible to dynamically explore many situations and variables. Models of this kind, however, depend on behavioral parameters that can rarely be measured directly, which turns their configuration into a search problem over a large, non-linear space, one for which Genetic Algorithms (GA) are an established alternative. This work proposes a GA built to adjust the parameters of a pedestrian-dynamics CA-based model that combines two models from the literature, one introducing the greedy movement choice and another introducing the concepts of confusion field and signage. The GA's parameter adjustment is carried out through the analysis of spatial and temporal evacuation metrics: density, dispersion, flow and total time. Due to the absence of real data, the algorithm's efficiency in reproducing the dynamics observed in data artificially generated with the CA model itself was evaluated, along with the model's behavior in normative pedestrian-dynamics tests. Additionally, the same evolutionary mechanism was reused to optimize those same metrics through the placement of emergency signs on the already calibrated model. Experimental results showed that the model calibrated by the GA was able to reproduce the reference spatial behavior across the regimes examined, just as sign optimization reduced evacuation time, with the gain depending on the environment's topology.

Keywords: cellular automaton; genetic algorithm; evacuation simulation; parameter calibration; identifiability; emergency signage.

Lista de abreviaturas e siglas

AC	Autômato Celular
AG	Algoritmo Genético
BLX	Cruzamento Combinado (<i>Blend Crossover</i>)
B&B	Ramificação e Poda (<i>Branch & Bound</i>)
PMX	Cruzamento Parcialmente Mapeado (<i>Partially Mapped Crossover</i>)
RiMEA	<i>Richtlinie für mikroskopische Entfluchtungsanalysen</i> (Diretriz para Análises Microscópicas de Evacuação)

Lista de símbolos

$\mathcal{L}$	Reticulado de células do autômato celular, que representa a planta do ambiente simulado
$\mathcal{S}$	Conjunto finito de estados de uma célula
$\mathcal{N}(c)$	Vizinhança de Moore da célula c
$\mathcal{N}^{\text{livre}}(c)$	Subconjunto das células livres da vizinhança de c
f	Regra de transição do autômato celular
R	Raio da vizinhança
D	Número de execuções independentes do AC por indivíduo do algoritmo genético
$c_{x,y}$	Célula do reticulado na posição (x, y)
$S(c)$	Campo de piso estático: custo mínimo de deslocamento de c até uma saída
S_{max}	Maior custo finito do campo de piso no mapa
$w(c, c')$	Custo de transição entre as células c e c'
c_{adj}	Custo de um deslocamento ortogonal
c_{diag}	Custo de um deslocamento diagonal
c^*	Célula-alvo escolhida sob decisão racional
$C_0(c)$	Confusão base da célula c
$C(c)$	Confusão efetiva da célula c , após o efeito das placas
β	Parâmetro de confusão base (teto da confusão)
π	Taxa de pânico
$d(c)$	Distância da célula c à placa mais próxima
$\mathcal{A}$	Conjunto de áreas monitoradas da planta
a	Uma área monitorada
$ a $	Número de células da área a

$N_t(a)$	Número de pedestres na área a no instante t
ρ_a	Densidade média de ocupação da área a
σ_a	Dispersão espacial normalizada da área a
φ_a	Fluxo de saída acumulado da área a
s_x, s_y	Desvios-padrão das coordenadas dos pedestres em uma área
T	Tempo total de evacuação
T^{ref}	Tempo de evacuação do padrão de referência
$s_{m,a}$	Desvio-padrão da métrica m da área a no padrão de referência
s_T	Desvio-padrão do tempo de evacuação de referência
$\mathbf{x}$	Cromossomo da fase de calibração
$\mathbf{P}$	Cromossomo da fase de otimização: conjunto de posições de placas
M	Número máximo de placas admitidas
$E(\mathbf{x})$	Erro total da configuração $\mathbf{x}$ frente ao padrão de referência
f_{cal}	Função de aptidão da fase de calibração
f_{ot}	Função de aptidão da fase de otimização
w_m, w_T	Pesos das métricas e do tempo na aptidão de calibração
$w_\rho, w_\sigma, w_\varphi, w_s, w_T$	Pesos dos termos da aptidão de otimização
N	Tamanho da população do algoritmo genético
G	Número de gerações
e	Número de indivíduos preservados por elitismo
k	Tamanho do torneio de seleção
p_c	Probabilidade de cruzamento
p_m	Probabilidade de mutação
α	Parâmetro de amplitude do cruzamento BLX- α
σ_g	Desvio-padrão da mutação gaussiana do gene g
n_{mov}	Número de placas relocadas por mutação

Lista de ilustrações

Figura 1 – Diferentes formas e dimensões de um Autômato Celular.	18
Figura 2 – Vizinhança de um Autômato Celular bidimensional em função do raio R , para as vizinhanças de von Neumann e de Moore com $R = 1$ e $R = 2$	19
Figura 3 – Tipos de borda mais comuns em um Autômato Celular unidimensional: periódica, circular ou cíclica (a); reflexiva (b); fixa (c).	19
Figura 4 – Autômato Celular unidimensional Regra 30: regra de transição, reticulado inicial e evolução espaço-temporal ao longo de sete passos de tempo.	21
Figura 5 – Padrões do Autômato Celular Jogo da Vida.	22
Figura 6 – Funcionamento geral de um Algoritmo Genético.	23
Figura 7 – Operadores de cruzamento: um ponto, dois pontos e uniforme.	26
Figura 8 – Mapa de referência.	44
Figura 9 – Ablação dos termos da aptidão de calibração no regime <i>default</i>	49
Figura 10 – Densidade, dispersão e fluxo por área ao longo do tempo, <i>baseline</i> contra modelo calibrado.	50
Figura 11 – Instante médio de esvaziamento por área, <i>baseline</i> contra calibrado.	51
Figura 12 – Posições dos pedestres em quatro instantes, <i>baseline</i> contra calibrado.	52
Figura 13 – Geometrias dos testes RiMEA executados.	55
Figura 14 – Diagrama fundamental do modelo contra as curvas empíricas de referência.	57
Figura 15 – Curva de evacuação (pedestres restantes por passo) no peso máximo, <i>baseline</i> contra otimizado.	60
Figura 16 – Densidade, dispersão e fluxo por área ao longo do tempo, <i>baseline</i> contra solução otimizada.	62
Figura 17 – Campo de confusão nas três topologias, sem placas e sob a solução otimizada.	63
Figura 18 – Efeito da posição das saídas sobre a sinalização escolhida.	64
Figura 19 – Labirinto de múltiplas saídas.	65

Lista de tabelas

Tabela 1 – Regra de transição do Autômato Celular Regra 30.	21
Tabela 2 – Erro de calibração, desfecho de otimização e custo computacional por esquema de áreas.	45
Tabela 3 – Efeito do intervalo de amostragem sobre o erro de calibração e sobre o desfecho da otimização.	46
Tabela 4 – Desvio comportamental do modelo calibrado por regime, em relação ao <i>baseline</i>	48
Tabela 5 – Configuração de π e β obtida pela calibração, por regime.	48
Tabela 6 – Veredito do AC nos testes normativos RiMEA executados.	54
Tabela 7 – Recuperação paramétrica do AG sobre geometrias normativas RiMEA.	58
Tabela 8 – Efeito do peso do tempo de evacuação sobre a solução do AG.	59
Tabela 9 – Aptidão alcançada por cada estratégia de otimização, sob densidade populacional crescente no mesmo mapa.	66
Tabela 10 – Custo e qualidade do AG frente ao ótimo exato da busca por ramificação e poda, nas instâncias em que a busca exata é viável.	67
Tabela 11 – Aptidão e tempo de evacuação dos arranjos de consenso em dois mapas, sobre 30 distribuições de pedestres não vistas no treino.	68

Sumário

1	INTRODUÇÃO	13
1.1	Objetivos	14
1.2	Organização do Trabalho	14
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Autômatos Celulares (AC)	16
2.1.1	Espaço Celular e Dimensão	17
2.1.2	Estado e Vizinhança	17
2.1.3	Condições de Contorno	18
2.1.4	Regras de Transição	19
2.1.5	Autômatos Celulares Estocásticos	20
2.1.6	Evolução Temporal	20
2.1.6.1	A Regra 30	20
2.1.6.2	O Jogo da Vida	21
2.2	Algoritmos Genéticos (AG)	22
2.2.1	Fluxo de Execução	23
2.2.2	Inspiração Biológica e Histórico	23
2.2.3	Representação do Indivíduo	23
2.2.4	Função de Aptidão	24
2.2.5	Seleção	24
2.2.6	Operadores Genéticos	25
2.2.7	Reinserção	26
2.2.8	Critério de Parada	27
3	TRABALHOS CORRELATOS	28
3.1	Modelos de Dinâmica de Pedestres Baseados em ACs	28
3.2	Algoritmos Genéticos no Ajuste de Parâmetros de ACs	29
4	DESENVOLVIMENTO	31
4.1	Modelo de Dinâmica de Pedestres	31
4.1.1	Espaço celular e vizinhança	31
4.1.2	Campo de piso estático	32
4.1.3	Mecanismo de confusão	33
4.1.4	Regra de transição	34
4.2	Motor Evolutivo do Algoritmo Genético	36
4.2.1	Avaliação do indivíduo	36

4.2.2	Operadores evolutivos	37
4.3	Fase 1: Calibração	37
4.3.1	Representação do indivíduo	37
4.3.2	Operadores evolutivos específicos da calibração	38
4.3.3	Função de aptidão	39
4.4	Fase 2: Otimização do Posicionamento de Placas	40
4.4.1	Representação do indivíduo	40
4.4.2	Operadores evolutivos específicos da otimização	41
4.4.3	Função de aptidão	41
5	RESULTADOS E DISCUSSÃO	43
5.1	Ajuste da Configuração do AG	43
5.1.1	Definição do número de áreas de monitoramento	44
5.1.2	Intervalo de amostragem	46
5.2	Calibração e identificabilidade	47
5.2.1	Comportamento do modelo calibrado	49
5.3	O modelo frente aos testes RiMEA	52
5.3.1	O autômato celular	54
5.3.2	O calibrador	57
5.4	Otimização de placas	59
5.4.1	Generalização	63
5.4.2	Comparação com outros solvers	65
5.4.3	Consenso entre execuções	67
5.5	Síntese do capítulo	69
6	CONCLUSÃO	71
	REFERÊNCIAS	74

1 Introdução

A simulação computacional de pedestres é uma área de pesquisa consolidada, com aplicações cruciais na mitigação de riscos em ambientes de alta densidade populacional, como eventos esportivos, sistemas de transporte público e edifícios comerciais (HELBBING et al., 2001). Modelos preditivos do comportamento de multidões são ferramentas valiosas para o planejamento urbano e arquitetônico, permitindo otimizar o posicionamento de sinalizações, validar rotas de fuga e prevenir a formação de gargalos perigosos em situações de emergência, impactando diretamente na segurança de projetos (RICHTER et al., 2013).

O principal desafio científico da área reside na complexidade de modelar o comportamento humano. Estudos empíricos já caracterizaram fenômenos isolados como a dinâmica de grupos (von Krüchten; SCHADSCHNEIDER, 2017), o efeito “*faster-is-slower*” em gargalos (PARISI; SORIA; JOSENS, 2015; GARCIMARTÍN et al., 2014), o comportamento em vias públicas (SISIOPIKU; AKIN, 2003) e as reações em situações de desastre (HELBBING; JOHANSSON; AL-ABIDEEN, 2007), enquanto conjuntos de testes normativos como os da RiMEA (RiMEA e.V., 2025) buscam padronizar a validação de simuladores de evacuação frente a esses cenários. Contudo, a tradução desses comportamentos para modelos computacionais enfrenta duas barreiras significativas: a dificuldade em obter dados de alta qualidade para calibração, e a tendência dos modelos em representar comportamentos de forma fixa e isolada, falhando em capturar a natureza fluida e adaptativa das reações humanas.

Para enfrentar essa complexidade, a literatura apresenta modelos baseados em Autômatos Celulares (ACs) que incorporam características como dinâmica de grupos (LU et al., 2017), interação com obstáculos transponíveis (DAMAZO, 2024), temperamento dos agentes (LI; HAN, 2015) e fatores de pânico (SILVA; DAMAZO; MARTINS, 2025), além de modelos baseados em agentes (SIYAM; ALQARYOUTI; ABDALLAH, 2020). Em paralelo, Algoritmos Genéticos (AGs) têm sido empregados com sucesso para automatizar o ajuste de parâmetros de modelos construídos em AC, a exemplo da propagação de incêndios florestais (MURILO, 2025) e da dinâmica epidemiológica (FRAGA, 2021). No caso específico de simuladores de pedestres, um AG foi utilizado para otimizar a condição inicial de um modelo de evacuação a partir da agressividade dos agentes (CUI; YANAGISAWA; NISHINARI, 2021). Apesar desses avanços, dois pontos seguem pouco explorados: o primeiro é que a maioria das abordagens foca em métricas de otimização globais, como o resultado agregado ou o tempo total de evacuação, e não examina o comportamento espacial interno da simulação ao longo do tempo, principal contribuição de simuladores de dinâmica de pedestres. O segundo é a dificuldade de calibração e validação de simuladores.

Diante desse contexto, este trabalho propõe um modelo de simulação baseado em Autômatos Celulares que combina um campo de piso estático a um campo escalar de confusão, e que incorpora à decisão de movimento dos pedestres uma escolha gulosa e um fator de pânico. Para configurá-lo, é desenvolvido um algoritmo genético que combina métricas espaciais e temporais no ajuste de seus parâmetros, de modo a reproduzir dados sintéticos tomados como referência. Avalia-se, ainda, a eficiência do modelo assim obtido e adapta-se o mesmo mecanismo evolutivo para otimizar essas mesmas métricas por meio do posicionamento de placas de sinalização pelo ambiente.

1.1 Objetivos

O objetivo deste trabalho é construir uma abordagem evolutiva que ajuste os parâmetros de um modelo baseado em ACs para que ele reproduza o comportamento de uma evacuação tomada como referência, de modo a eliminar a fase manual e exaustiva de calibração. O mesmo mecanismo evolutivo é depois aplicado ao posicionamento de placas de sinalização no ambiente já calibrado, agora para otimizar as métricas que descrevem a evacuação, densidade, dispersão, fluxo e tempo total, em vez de aproximá-las de uma referência.

Para atingir esse objetivo, buscaram-se os seguintes objetivos específicos:

- Desenvolver um modelo de AC para simulação de pedestres baseado em modelos da literatura, capaz de representar a dinâmica de movimentação de pessoas em situações de emergência, nas quais estão sujeitas a comportamentos de pânico e confusão;
- Implementar um algoritmo genético que seja capaz de ajustar automaticamente os parâmetros do modelo supracitado de modo a reproduzir de forma adequada a dinâmica de movimentos observada nos dados usados como referência;
- Validar a eficiência do algoritmo implementado frente a um conjunto de testes normativos RiMEA, considerando um conjunto de dados gerados artificialmente pelo modelo de simulação;
- Adaptar o mecanismo evolutivo desenvolvido para otimizar as métricas espaciais avaliadas por meio do posicionamento efetivo de sinalização.

1.2 Organização do Trabalho

O restante do documento está organizado da seguinte maneira:

- Capítulo 2: apresenta a fundamentação teórica sobre Autômatos Celulares, Algoritmos Genéticos e simulação de pedestres;
- Capítulo 3: descreve os trabalhos correlatos que fundamentam as escolhas de modelagem;
- Capítulo 4: descreve o modelo de simulação desenvolvido, incluindo a arquitetura do AC, e as decisões de projeto do algoritmo genético implementado;
- Capítulo 5: apresenta os resultados experimentais alcançados pelo AG tanto no ajuste dos parâmetros do modelo de autômato celular, quanto na otimização da distribuição das placas de sinalização pelo ambiente simulado;
- Capítulo 6: traz as conclusões e as perspectivas para trabalhos futuros.

Durante a elaboração deste trabalho, recursos de inteligência artificial foram utilizados como ferramenta de apoio, tanto no desenvolvimento das ferramentas demonstradas quanto na revisão do texto escrito. As decisões de modelagem, a condução dos experimentos, redação do documento e conclusões permaneceram sob responsabilidade do autor.

2 Fundamentação Teórica

Este capítulo reúne os fundamentos teóricos que sustentam o restante do trabalho: os Autômatos Celulares (ACs), ferramenta de modelagem sobre a qual se constrói o simulador de evacuação, e os Algoritmos Genéticos (AGs), técnica evolutiva empregada tanto na calibração de seus parâmetros comportamentais quanto na otimização do posicionamento das placas de sinalização. A Seção 2.1 apresenta os ACs a partir de sua origem histórica e de sua definição como sistema dinâmico discreto, percorrendo o espaço celular e suas dimensões, o estado e a vizinhança das células, as condições de contorno do reticulado e as regras de transição, e ilustra esses conceitos por meio de dois exemplos clássicos. A Seção 2.2 apresenta os AGs a partir do desafio de calibrar os parâmetros de um modelo dessa natureza, cobrindo sua inspiração biológica, a codificação das soluções, a função de aptidão e os operadores de seleção, reprodução e substituição. A instância concreta desses fundamentos no modelo proposto, com o conjunto de estados do simulador, o campo de piso estático, a regra de decisão do pedestre e o efeito das placas, é apresentada no Capítulo 4.

2.1 Autômatos Celulares (AC)

Um autômato celular constitui um sistema dinâmico discreto no espaço, no tempo e no estado, no qual o espaço é representado por um reticulado regular de células, o tempo avança em passos discretos e cada célula assume, a cada passo, um valor pertencente a um conjunto finito de estados. Uma de suas principais características é a ausência de controle central, visto que seu comportamento global não é modelado explicitamente, mas emerge da aplicação simultânea de uma mesma regra local a todas as células, que depende apenas do estado de cada célula e da sua vizinhança imediata. Justamente por descreverem fenômenos complexos a partir de regras simples que os ACs se firmaram como alternativa de modelagem a abordagens baseadas em equações diferenciais, cuja formulação e cujo custo computacional tendem a ser elevados (FRAGA, 2021).

O conceito foi introduzido por John von Neumann e Stanislaw Ulam na década de 1940. Von Neumann investigava a concepção de uma máquina capaz de autorreprodução, enquanto Ulam, que estudava o crescimento de estruturas sobre uma rede bidimensional cujos pontos eram atualizados em função de sua vizinhança, sugeriu abstrair essa investigação para um espaço discreto de células governadas por uma regra local uniforme. Dessa colaboração resultou o primeiro modelo de autômato celular, mais tarde reunido, com contribuições de Arthur W. Burks, na obra *Theory of Self-Reproducing Automata* (NEUMANN, 1966). O paradigma difundiu-se em 1970 com o *Jogo da Vida* de John

Conway, que, com apenas dois estados por célula e poucas regras de transição, evidenciou de forma didática a emergência de padrões globais complexos a partir de interações locais triviais (GARDNER, 1970). Na década de 1980, Stephen Wolfram sistematizou o estudo empírico dos ACs e classificou seus comportamentos em classes, consolidando a noção de que regras simples bastam para gerar grande complexidade (WOLFRAM, 2002). É essa propriedade, a de um comportamento coletivo complexo que emerge de regras puramente locais, que torna os ACs adequados à modelagem da dinâmica de multidões, fenômeno que não decorre de um controle central, mas das interações locais entre os indivíduos.

Formalmente, um autômato celular é definido pela quádrupla $(\mathcal{L}, \mathcal{S}, \mathcal{N}, f)$, em que $\mathcal{L}$ é o reticulado de células, $\mathcal{S}$ é o conjunto finito de estados que cada célula pode assumir, $\mathcal{N}$ é a vizinhança que determina quais células influenciam a evolução de uma dada célula, e f é a regra de transição que, a partir do estado de uma célula e de sua vizinhança no instante t , determina o estado dessa célula no instante $t + 1$. A dinâmica do sistema resulta da aplicação síncrona dessa regra a todas as células do reticulado, a cada passo de tempo. As subseções seguintes detalham cada um desses quatro elementos.

2.1.1 Espaço Celular e Dimensão

O reticulado $\mathcal{L}$ é o espaço no qual o autômato evolui, formado por um conjunto de células dispostas de maneira regular. Esse arranjo pode ser unidimensional, bidimensional ou tridimensional, e as células que o compõem podem assumir diferentes formatos geométricos, como o quadrado, o triângulo ou o hexágono, afetando o número de vizinhas diretas de cada célula (Figura 1). A escolha da dimensão e do formato é determinada em função da natureza do fenômeno modelado. Adota-se, neste trabalho, à semelhança da maioria dos modelos de dinâmica de pedestres, um reticulado bidimensional de células quadradas, arranjo que representa de forma direta a planta baixa de um ambiente e as posições que os pedestres podem ocupar.

2.1.2 Estado e Vizinhança

Em um autômato celular, cada célula do reticulado possui, a cada instante, um estado definido dentro do conjunto finito $\mathcal{S}$, e todas as células podem mudar de estado ou permanecer inalteradas a cada passo de tempo, em função de seu estado atual e do estado de sua vizinhança. A vizinhança $\mathcal{N}$ é o conjunto de células que, por uma proximidade previamente estabelecida, influenciam a transição de uma dada célula. Em reticulados bidimensionais, os dois tipos de vizinhança são de von Neumann e Moore (Figura 2). Considerando apenas as células adjacentes, a vizinhança de von Neumann (Figura 2a) é formada pela célula central e por suas quatro vizinhas nas direções cardinais, totalizando cinco células, ao passo que a vizinhança de Moore (Figura 2c) acrescenta a essas as quatro células diagonais, totalizando nove células. A vizinhança de Moore admite deslocamentos




Figura 1 – Diferentes formas e dimensões de um Autômato Celular.

Fonte: Retirado de [Murilo \(2025\)](#).

diagonais e aproxima melhor o movimento simulado da locomoção humana em espaço livre. Por essa razão, o modelo desenvolvido neste trabalho, à semelhança do modelo de referência de [Varas et al. \(2007\)](#), adota a vizinhança de Moore tanto no cálculo do campo de piso quanto na regra de movimento dos pedestres.

A extensão de uma vizinhança é controlada por seu raio R , que corresponde ao número de células consideradas vizinhas em cada direção. Em um reticulado unidimensional, um raio $R = 1$ define uma vizinhança de três células, ao passo que $R = 2$ a estende para cinco. Para a vizinhança de Moore em um reticulado bidimensional (Figura 2), a quantidade de células vizinhas, excluída a central, é dada por $|\mathcal{N}| = (2R + 1)^2 - 1$, o que corresponde, para $R = 1$, às oito células que cercam a célula central. Emprega-se, neste trabalho, raio $R = 1$, de modo que cada pedestre considera apenas as células imediatamente adjacentes ao decidir seu movimento.

2.1.3 Condições de Contorno

A definição da vizinhança das células interiores não é suficiente para caracterizar o autômato, pois as células situadas nas bordas do reticulado teriam vizinhas além dos limites do espaço definido. Faz-se necessário, portanto, estabelecer uma condição de contorno que determine como tratar essas vizinhas ausentes. Três condições são as mais comuns (Figura 3): a periódica, também chamada circular ou cíclica, na qual a borda oposta do reticulado é tratada como vizinha, fazendo o espaço comportar-se como um anel ou um toroide; a reflexiva, na qual a própria célula de borda é espelhada como sua




Figura 2 – Vizinhança de um Autômato Celular bidimensional em função do raio R , para as vizinhanças de von Neumann e de Moore com $R = 1$ e $R = 2$.

Fonte: Adaptado de [Fraga \(2021\)](#).

vizinha externa; e a fixa, na qual se atribui às posições além da borda um estado constante e predeterminado, que tipicamente representa uma parede ou um limite intransponível. A escolha da condição de contorno pode influenciar de maneira perceptível a dinâmica simulada, sobretudo em reticulados de pequenas dimensões.




Figura 3 – Tipos de borda mais comuns em um Autômato Celular unidimensional: periódica, circular ou cíclica (a); reflexiva (b); fixa (c).

Fonte: Retirado de [Fraga \(2021\)](#).

2.1.4 Regras de Transição

A regra de transição f conduz a evolução temporal do autômato. Aplicada de forma síncrona a todas as células do reticulado, a cada passo de tempo discreto, ela costuma ser representada por uma tabela que associa a cada configuração possível da célula e de sua vizinhança o estado que a célula assumirá no instante seguinte. O número de configurações possíveis, e portanto o tamanho dessa tabela, cresce exponencialmente com o tamanho da vizinhança e com o número de estados; para um autômato binário de vizinhança com três células, por exemplo, há $2^3 = 8$ configurações a especificar. Nem toda

regra, contudo, precisa enumerar cada configuração individualmente: as chamadas regras totalísticas consideram apenas a quantidade de células vizinhas em cada estado, e não a posição que ocupam, e recebem a designação de totalísticas externas quando o estado da própria célula não integra essa contagem (FRAGA, 2021; MURILO, 2025). Regras desse tipo simplificam a especificação de autômatos com vizinhanças extensas, como se verá no exemplo do Jogo da Vida.

2.1.5 Autômatos Celulares Estocásticos

Nos autômatos celulares clássicos, a regra de transição é determinística: dado o estado de uma célula e de sua vizinhança, o estado seguinte fica univocamente determinado. Em muitos fenômenos naturais, porém, a transição carrega incerteza, e a regra passa a ser probabilística, de modo que, para uma mesma configuração de vizinhança, há mais de um estado resultante possível, sorteado segundo uma distribuição de probabilidade. Esses são os autômatos celulares estocásticos, adequados a fenômenos em que a imprevisibilidade é inerente, como o deslocamento de pedestres em situações de emergência (VARAS et al., 2007; SILVA; DAMAZO; MARTINS, 2025). Como a aleatoriedade produz resultados distintos a cada execução a partir de uma mesma configuração inicial, qualquer medida de saída de um autômato estocástico deve ser avaliada por médias sobre múltiplas execuções independentes, e não por uma realização isolada.

2.1.6 Evolução Temporal

Para ilustrar o comportamento evolutivo das células, são apresentados a seguir dois exemplos de autômato celular, um unidimensional e outro bidimensional, que evidenciam como uma regra local simples produz, ao longo do tempo, um comportamento coletivo complexo.

2.1.6.1 A Regra 30

Proposto por Wolfram no âmbito de seu estudo dos autômatos elementares, o autômato conhecido como Regra 30 é unidimensional e determinístico, com conjunto de estados binário, $\mathcal{S} = \{0, 1\}$, e vizinhança de raio $R = 1$, composta pela própria célula e por suas duas vizinhas imediatas (WOLFRAM, 2002). Como há três células na vizinhança, a regra de transição possui $2^3 = 8$ entradas, uma para cada combinação possível de estados, apresentadas na Tabela 1. A partir de um reticulado inicial com uma única célula no estado 1, a aplicação repetida dessa regra produz, a cada passo de tempo, uma nova configuração; o empilhamento dessas configurações ao longo de sucessivos instantes revela um padrão triangular que combina regiões regulares e regiões aparentemente aleatórias (Figura 4). O exemplo evidencia a propriedade central dos ACs: uma regra

estritamente local, aplicada sem qualquer coordenação central, é suficiente para gerar um comportamento global complexo.

Tabela 1 – Regra de transição do Autômato Celular Regra 30.

Vizinho esquerdo	Célula	Vizinho direito	Resultado ($t + 1$)
1	1	1	0
1	1	0	0
1	0	1	0
1	0	0	1
0	1	1	1
0	1	0	1
0	0	1	1
0	0	0	0

Fonte: Adaptado de Fraga (2021).




Figura 4 – Autômato Celular unidimensional Regra 30: regra de transição, reticulado inicial e evolução espaço-temporal ao longo de sete passos de tempo.

Fonte: Retirado de Fraga (2021).

2.1.6.2 O Jogo da Vida

O Jogo da Vida, proposto por John Conway em 1970, é o autômato celular bi-dimensional mais conhecido (GARDNER, 1970). Ele emprega um reticulado de células binárias, que assumem os estados vivo (1) ou morto (0), e vizinhança de Moore de raio $R = 1$, de modo que cada célula possui oito vizinhas. Sua regra de transição é totalística, pois depende apenas da quantidade de vizinhas vivas, e resume-se a quatro condições: uma célula viva com dois ou três vizinhos vivos permanece viva; uma célula viva com

menos de dois vizinhos vivos morre, por isolamento; uma célula viva com mais de três vizinhos vivos morre, por superpopulação; e uma célula morta com exatamente três vizinhos vivos torna-se viva. Apesar da simplicidade dessas regras, a evolução do reticulado a partir de uma configuração inicial produz uma variedade grande de padrões, entre eles estruturas estáveis, figuras que oscilam com período fixo e formas que se deslocam pelo reticulado, conhecidas como *gliders* (Figura 5). É essa propriedade, a de que regras locais simples geram comportamento coletivo rico sem que ele precise ser programado diretamente, que fundamenta a descrição de uma multidão por regras individuais de movimento, na expectativa de que padrões coletivos plausíveis emergjam por conta própria.




Figura 5 – Padrões do Autômato Celular Jogo da Vida.

Fonte: Retirado de [Murilo \(2025\)](#).

2.2 Algoritmos Genéticos (AG)

A definição da estrutura de um autômato celular resolve apenas parte do problema de modelagem, restando ajustar os parâmetros que fazem o comportamento simulado corresponder a um fenômeno específico. Esse ajuste manual é difícil e pouco confiável, pois o espaço de combinações é vasto, os efeitos dos parâmetros se misturam e uma pequena alteração em um único parâmetro pode modificar de forma expressiva o comportamento coletivo que emerge da simulação. Trata-se de um problema de busca em um espaço de alta dimensão, com frequência não linear e dotado de múltiplos ótimos locais, para o qual foram concebidos métodos de otimização inspirados na natureza, entre eles os Algoritmos Genéticos (AGs), uma classe de algoritmos de busca estocástica baseados nos princípios da evolução biológica e da seleção natural, propostos inicialmente por John Holland ([HOLLAND, 1975](#)).

2.2.1 Fluxo de Execução

Um AG opera sobre uma população de soluções candidatas ao problema, cada uma delas denominada indivíduo, ou cromossomo, cuja qualidade é medida por uma função de aptidão. O funcionamento do algoritmo é iterativo e segue um fluxo bem definido (Figura 6). A partir dos parâmetros de configuração, entre eles o tamanho da população, o número de gerações e as probabilidades de reprodução e de mutação, o processo começa com a geração e a avaliação de uma população inicial. Em seguida, enquanto um critério de parada não é satisfeito, repetem-se as etapas de seleção dos pais, reprodução por cruzamento, mutação dos descendentes, nova avaliação da aptidão e reinserção na população. As subseções seguintes detalham cada uma dessas etapas.




Figura 6 – Funcionamento geral de um Algoritmo Genético.

Fonte: Adaptado de [Murilo \(2025\)](#).

2.2.2 Inspiração Biológica e Histórico

A Computação Evolutiva é um ramo da Inteligência Artificial que propõe resolver problemas de busca e otimização inspirando-se na teoria da evolução de Darwin, segundo a qual os indivíduos mais adaptados ao ambiente têm maior probabilidade de sobreviver e de se reproduzir. Os AGs constituem uma classe particular desses métodos, introduzida por Holland em 1975 e posteriormente aprimorada por David Goldberg ([HOLLAND, 1975](#); [GOLDBERG, 1989](#)). A cada geração, as soluções mais promissoras são selecionadas e recombinadas para gerar descendentes que herdaram suas características, enquanto variações aleatórias, análogas às mutações genéticas, preservam a diversidade da população e permitem explorar novas regiões do espaço de busca ([SIVANANDAM; DEEPA, 2008](#)). Ao contrário de métodos que seguem o gradiente de uma função e podem estagnar em ótimos locais, o AG mantém várias soluções em paralelo, o que o torna adequado a problemas não lineares e com múltiplos picos ([GOLDBERG, 1989](#)). Uma vantagem prática do método reside em sua generalidade, pois o mesmo procedimento aplica-se a problemas de natureza bem distinta, bastando descrever como uma solução é representada e como sua qualidade é avaliada, sem que seja preciso especificar os passos que conduzem ao resultado.

2.2.3 Representação do Indivíduo

O primeiro passo para aplicar um AG consiste em definir como uma solução candidata será representada. Essa representação é denominada cromossomo, ou indivíduo, e

reúne todos os parâmetros a otimizar; cada parâmetro constitui um gene, e o conjunto de indivíduos forma a população (GOLDBERG, 1989). A forma de codificar os genes depende do problema. Na codificação binária, formulação clássica de Holland, cada gene é uma sequência de bits; na codificação inteira, cada gene é um número inteiro; e na codificação de valor real, cada gene é um número de ponto flutuante, o que costuma ser mais natural e eficiente para parâmetros contínuos, como os pesos de um modelo de simulação. Existe ainda a codificação de permutação, empregada em problemas de ordenação, como o do caixeiro-viajante, na qual o cromossomo é uma sequência de inteiros que representa uma ordem (MURILO, 2025). A escolha da representação é decisiva, pois condiciona os operadores que podem ser aplicados e influencia a geração de indivíduos válidos após o cruzamento e a mutação. O processo evolutivo inicia-se com uma população, em geral gerada aleatoriamente para cobrir amplamente o espaço de soluções, embora possa também ser orientada por alguma heurística que assegure, por exemplo, a validade das soluções em problemas com restrições.

2.2.4 Função de Aptidão

A função de aptidão (*fitness*) estabelece o elo entre o problema a resolver e o processo evolutivo. Ela recebe um cromossomo e devolve um valor numérico que mede sua qualidade, valor esse que orienta as etapas seguintes do ciclo, sobretudo a seleção dos pais e a reinserção, e que é recalculado sempre que o indivíduo é alterado (SIVANANDAM; DEEPA, 2008). Seu projeto é um dos pontos mais delicados do método, uma vez que a função precisa refletir com fidelidade o objetivo da otimização e ser computacionalmente barata, pois será avaliada para cada indivíduo, a cada geração. Quando o problema apresenta mais de um objetivo, a aptidão pode combinar várias funções por meio de uma soma ponderada, que privilegia as de maior relevância. No contexto da calibração de modelos, a função de aptidão tipicamente quantifica o erro entre a saída da simulação, obtida com os parâmetros do cromossomo, e um conjunto de dados de referência, de modo que quanto menor o erro, maior a aptidão.

2.2.5 Seleção

A seleção escolhe, entre os indivíduos da população, aqueles que participarão da reprodução. O operador não cria novos indivíduos, apenas realiza uma triagem segundo um critério preestabelecido, simulando a pressão seletiva do ambiente. Em geral, favorece os indivíduos de maior aptidão sem descartar por completo os menos aptos, o que ajuda a preservar a diversidade. A intensidade desse favorecimento é a pressão seletiva: quando elevada, acelera a convergência, mas pode conduzir a população a um ótimo local, caracterizando a convergência prematura; quando reduzida, mantém a diversidade, mas pode tornar a busca lenta. Os métodos mais comuns são a roleta e o torneio. Na seleção por

roleta, proposta por Holland, cada indivíduo recebe uma fatia de uma roleta proporcional à sua aptidão, de forma que a probabilidade de seleção de um indivíduo x , em uma população de n indivíduos, é dada pela Equação 2.1 (HOLLAND, 1975).

$$P(x) = \frac{\text{aptidao}(x)}{\sum_{i=1}^n \text{aptidao}(i)} \quad (2.1)$$

Indivíduos mais aptos ocupam fatias maiores e têm maior chance de ser sorteados, embora os menos aptos ainda possam ser escolhidos, o que preserva parte da diversidade. Na seleção por torneio, sorteia-se aleatoriamente um pequeno grupo de k indivíduos e escolhe-se o mais apto entre eles, repetindo-se o procedimento até completar o número de pais necessário; diferentemente da roleta, não há favorecimento diretamente proporcional à aptidão, mas o vencedor de cada torneio tende a ser um bom indivíduo (MURILO, 2025).

2.2.6 Operadores Genéticos

Após a seleção, novos indivíduos são gerados pelos operadores de cruzamento e mutação, aplicados de acordo com as probabilidades de reprodução e de mutação. O cruzamento recombina o material genético de dois pais, permutando fragmentos de seus cromossomos para produzir descendentes, o que permite combinar blocos promissores de indivíduos distintos. Entre as variantes mais comuns figuram o cruzamento de um ponto (Figura 7a), no qual uma posição de corte é sorteada e os genes são trocados a partir dela; o de dois pontos (Figura 7b), com duas posições de corte; e o uniforme (Figura 7c), no qual uma máscara sorteada define, gene a gene, de qual pai cada valor é herdado. Para cromossomos de valor real, o cruzamento aritmético gera o descendente como uma combinação dos valores dos pais em cada posição, ao passo que codificações de permutação exigem operadores próprios, como o cruzamento parcialmente mapeado (PMX) e o cruzamento cíclico, que recombina os genes preservando a validade da ordem (MURILO, 2025; ENGELBRECHT, 2007).

A mutação, por sua vez, introduz variação aleatória ao alterar um ou poucos genes de um cromossomo, com baixa probabilidade, tendo por função preservar a diversidade genética e evitar a convergência prematura para um ótimo local (GOLDBERG, 1989). A forma da mutação depende da codificação: em representação binária, inverte-se o valor de um bit; em representação de valor real, perturba-se o gene com um valor aleatório; e em representação de permutação, permutam-se dois genes, preservando a validade da ordem. A perturbação pode incidir sobre um único gene sorteado ou sobre cada gene do cromossomo, caso em que tende a ser mais intensa.




Figura 7 – Operadores de cruzamento: um ponto, dois pontos e uniforme.

Fonte: Adaptado de [Engelbrecht \(2007\)](#).

2.2.7 Reinscrição

Ao final de cada geração, a população deve retornar ao seu tamanho original, o que exige decidir quais indivíduos, entre os já existentes e os recém-gerados, permanecerão. Essa etapa, denominada reinscrição ou substituição, admite diferentes critérios ([MURILO, 2025](#)). Na reinscrição pura, ou geracional, os descendentes substituem integralmente a geração anterior, o que pode acarretar a perda de bons indivíduos caso a reprodução gere descendentes piores. Na reinscrição ordenada, o conjunto formado por pais e descendentes é ordenado pela função de aptidão, e os melhores compõem a nova população. Na abordagem de estado estacionário, apenas uma fração da população é renovada a cada passo, e as vagas abertas são preenchidas pelos descendentes gerados pelos operadores de cruzamento e mutação, de modo que os demais indivíduos permanecem e boas soluções sobrevivem por mais tempo.

Por fim, na reinscrição por elitismo, um pequeno conjunto dos indivíduos de maior aptidão da geração anterior é copiado diretamente para a geração seguinte, e as vagas restantes são preenchidas pelos descendentes gerados por cruzamento e mutação. A diferença em relação à abordagem de estado estacionário está no critério que define a permanência. No estado estacionário, o que se fixa é a taxa de renovação, isto é, quantos indivíduos

são trocados a cada passo, sem que a sobrevivência de um indivíduo dependa de ele estar entre os melhores. No elitismo, o que se fixa é uma garantia: os melhores indivíduos permanecem por construção, qualquer que seja o esquema adotado para substituir o restante da população. O elitismo não é, portanto, uma alternativa aos demais critérios, mas uma salvaguarda que pode ser combinada com eles, assegurando que a melhor solução encontrada até então não se perca nos sorteios da seleção nem na variação introduzida pela reprodução.

2.2.8 Critério de Parada

O ciclo evolutivo repete-se até que um critério de parada seja satisfeito. Os mais comuns são atingir um número máximo de gerações, alcançar um valor-alvo para a função de aptidão ou observar um número predefinido de gerações sem melhoria significativa na melhor solução.

3 Trabalhos Correlatos

A Seção 3.1 reúne os modelos de AC de dinâmica de pedestres sobre os quais este trabalho se apoia, percorrendo o modelo de referência da área e as duas extensões das quais o simulador aqui proposto herda sua regra de movimento e seu mecanismo de confusão. A Seção 3.2 percorre trabalhos que empregam AGs no ajuste de parâmetros de modelos em AC, aplicados à propagação de incêndio (MURILO, 2025), à configuração de modelos com abordagens multiestágio (FRAGA, 2021) e à otimização de estratégias de evacuação (CUI; YANAGISAWA; NISHINARI, 2021).

3.1 Modelos de Dinâmica de Pedestres Baseados em ACs

O modelo de Campo de Piso (*Floor Field*) de Schadschneider (2001) é a formulação que consolida a simulação de pedestres por ACs. Nele o ambiente é descrito por dois campos sobrepostos ao reticulado: o campo estático, que atribui a cada célula o custo de deslocamento até a saída e não muda ao longo da simulação, e o campo dinâmico, um rastro que cada pedestre deposita ao caminhar e que se dissipa com o tempo, tornando mais atrativas as células recém-percorridas. Os trabalhos discutidos a seguir, assim como o modelo aqui proposto, herdam o conceito de campo de piso estático.

Um trabalho importante para a fundamentação de vários outros trabalhos é o de Varas (VARAS et al., 2007). Aqui ele define um autômato que serve de base a muitas das dissertações discutidas nesse capítulo, propondo uma célula de tamanho $0,4 \times 0,4$ m e um $\Delta t = 0,4$ s, respeitando referências de espaço ocupado e velocidade média de uma pessoa em uma situação de grande densidade de pessoas; e utilizando a *Vizinhança de Moore* (Figura 2c). O campo estático é calculado pelo modelo de *flooding* (a partir da célula da saída, com valor 1, as subsequentes são calculadas somando 1 a partir de vizinhos diretos ou $1 + \delta$ para vizinhos na diagonal), e é esse mesmo campo, computado neste trabalho por uma busca em largura a partir de todas as saídas, que serve de paisagem de custo ao modelo proposto. Alguns fatores importantes de serem discutidos também são introduzidos aqui: fator de pânico, empate de escolhas e inserção de obstáculos. Fator de pânico, introduzindo estocástica, dá aos pedestres uma chance de 5% de não se moverem. E quando dois pedestres querem ir para uma mesma célula, em uma escolha aleatória, um deles se move e um deles fica parado no lugar. Como resultado obteve-se um modelo que simula bem as situações, interações entre pedestres e obstáculos, porém que em alguns casos se mostra limitado a simular naturalmente o comportamento humano, principalmente no conflito de escolhas. Varas usa seu modelo para avaliar a viabilidade de algumas possibilidades de saídas em caso de emergência, obtendo bons resultados no contexto de

seus experimentos e utilizando o seu modelo.

Partindo do modelo de [Varas et al. \(2007\)](#) para simulação de pedestres, [Damazo \(2024\)](#) propõe duas modificações centrais: a introdução de uma dinâmica de escolha gulosa por células vizinhas vazias e a inclusão de objetos transponíveis, cuja travessia depende de uma taxa z pré-definida. Aplicado à dinâmica coletiva em ambientes internos, o trabalho contribui ao eliminar um comportamento artificial no modelo quando deparado com situações de fila além de alterar o comportamento de obstáculos não-transponíveis no cálculo do reticulado. Como resultado, observou-se uma diminuição no tempo de evacuação em alguns cenários. O principal resultado observado é que a eficácia do modelo mostrou-se dependente da topologia do ambiente, observando-se nas simulações que em alguns casos os pedestres realmente preferem se manter ao caminho natural a se arriscar por passar por algum obstáculo, mas tudo depende do tamanho e formato dos obstáculos.

No trabalho focado na simulação de pedestres em ambientes externos ([SILVA; DAMAZO; MARTINS, 2025](#)), é proposta uma quebra na escolha determinística do autômato por meio de um parâmetro de confusão, que representa a probabilidade de um agente se mover aleatoriamente. A técnica, que também inclui a adição de sinais de trânsito, foi empregada para analisar o fluxo de pedestres em três cenários: labirinto, corte transversal simétrico e assimétrico. A principal contribuição foi demonstrar que a introdução de um comportamento estocástico (confusão) ajuda na prevenção, até certo ponto, de aglomerações próximas à saída. Nos resultados, o modelo proposto reduziu a aglomeração inicial na saída e obteve métricas de evacuação inferiores (melhores) em comparação com o modelo original. Além disso, testes mostraram que a sinalização ajuda a restabelecer esse comportamento, reforçando o melhor caminho para indivíduos que outrora estariam confusos. Este trabalho herda de [Silva, Damazo e Martins \(2025\)](#) a formulação da confusão e do mecanismo de sinalização, e de [Damazo \(2024\)](#) a escolha gulosa de movimento, combinando as duas contribuições sobre o campo estático de [Varas et al. \(2007\)](#).

3.2 Algoritmos Genéticos no Ajuste de Parâmetros de ACs

O trabalho de [Murilo \(2025\)](#) propõe uma abordagem evolutiva para a configuração de parâmetros de um modelo AC de propagação de incêndio. A técnica utiliza um Algoritmo Genético (AG) cujos indivíduos possuem 11 genes, que configuram a direção e intensidade do vento, valores de duração de queima e recuperação e a principal contribuição desse trabalho: a *Sample Rate*. A *Sample Rate* faz a configuração de quantas iterações serão utilizadas para a avaliação dos resultados do algoritmo genético, e, desse modo, dá ao algoritmo mais adaptabilidade e versatilidade em relação aos dados de entrada. Além disso, por meio dos resultados, mostrou-se que uma análise do reticulado dividido em setores, com uma função de FitMax em que cada partição é normalizada em relação ao

seu próprio valor máximo, traz melhores resultados em ambos os modelos Estocásticos e Determinísticos. Este trabalho adota e adapta duas contribuições de [Murilo \(2025\)](#): a análise do reticulado dividido em setores, aqui empregada como o esquema de nove áreas de monitoramento (Seção 5.1), e o conceito de taxa de amostragem, reinterpretado aqui como o parâmetro de intervalo de observação, que controla o espaçamento entre os registros usados na avaliação. Mantém-se, por outro lado, fixo em $D = 15$ o número de réplicas de avaliação de cada indivíduo.

[Fraga \(2021\)](#) propõe uma estratégia multiestágios: os parâmetros a serem ajustados são divididos em subgrupos, e o AG foca em evoluir um subgrupo por vez a cada estágio. A contribuição proposta é um método de configuração mais eficiente: mostrando, por meio de resultados, que a técnica conseguiu atingir um desempenho igual ou superior ao de abordagens tradicionais, mesmo configurando apenas um subgrupo de parâmetros na metade dos estágios evolutivos, o que traz mais flexibilidade e adaptabilidade à proposta. A estratégia multiestágios não é empregada aqui, uma vez que o AG deste trabalho calibra simultaneamente os quatro parâmetros comportamentais do modelo.

Com foco na teoria dos jogos, [Cui, Yanagisawa e Nishinari \(2021\)](#) utiliza um AG para otimizar o tempo de evacuação de pedestres. A técnica proposta configura não apenas a posição inicial de cada pedestre, mas também seu comportamento (agressivo ou paciente). A principal contribuição é demonstrar que o posicionamento estratégico de diferentes tipos de agentes é crucial para a evacuação. Os resultados mostraram que o tempo de simulação reduziu conforme o AG evoluía seus indivíduos (parâmetros), aproximando-se de uma solução ótima de posicionamento e superando um modelo de controle tradicional. A limitação mais evidente da abordagem é seu alto custo computacional, dado que o processo evolutivo requer um número elevado de simulações completas para avaliar cada indivíduo. O atributo de comportamento por agente (agressivo ou paciente) é, por sua vez, um mecanismo que este trabalho não adota, uma vez que todos os pedestres compartilham a mesma regra de decisão.

4 Desenvolvimento

Este capítulo detalha o modelo de simulação construído, conectando a fundamentação teórica e os trabalhos correlatos ao que foi de fato implementado. O simulador foi escrito em Go e organiza-se em dois componentes. O primeiro é um autômato celular (AC), que reproduz a dinâmica de evacuação e é formalizado na Seção 4.1. O segundo é um algoritmo genético (AG), que atua sobre o AC em duas fases. O motor evolutivo comum às duas está na Seção 4.2, a calibração dos parâmetros comportamentais na Seção 4.3 e a otimização do posicionamento de placas na Seção 4.4.

4.1 Modelo de Dinâmica de Pedestres

Esta seção formaliza a implementação do modelo de simulação da movimentação de pedestres baseado em AC. Ela descreve como o problema foi modelado no autômato celular, principalmente em relação à sua estrutura espacial; o campo de piso que orienta os pedestres até as saídas; o mecanismo de confusão que os faz errar o caminho; e a regra de transição adotada, que decide o movimento de cada pedestre a cada passo de tempo do AC.

4.1.1 Espaço celular e vizinhança

O ambiente é representado por um reticulado bidimensional $\mathcal{L}$ de dimensões $W \times H$ (o tamanho de cada dimensão pode variar de acordo com o cenário analisado), composto por células $c_{x,y}$. Cada célula assume exatamente um estado do conjunto de possíveis valores, como segue:

- **Vazia:** espaço livre, transponível;
- **Obstáculo:** parede ou barreira, intransponível;
- **Saída:** célula de destino; o pedestre que a alcança é removido da simulação;
- **Placa:** célula que contém uma placa de sinalização, transponível, conforme detalhado na Subseção 4.1.3;
- **Ocupada:** célula que contém um pedestre, intransponível.

Adota-se a vizinhança de Moore, denotada $\mathcal{N}(c)$: as oito células adjacentes a c , incluindo as diagonais. Cada célula corresponde a uma área física de $0,4 \times 0,4$ m e cada passo de tempo corresponde a $\Delta t = 0,3$ s.

A escala física não é arbitrária: o tamanho de célula de 0,4 m reproduz a área ocupada por um pedestre em pé, e o passo de tempo é escolhido de modo que o deslocamento de uma célula por passo corresponda à velocidade de caminhada livre observada na literatura empírica. Com $\Delta t = 0,3$ s, uma célula por passo equivale a $0,4/0,3 = 1,33$ m/s, essencialmente a velocidade de caminhada livre de 1,34 m/s reportada por [Weidmann \(1993\)](#). Assim, um pedestre desloca-se, no máximo, uma célula por passo de tempo. A velocidade de caminhada livre de Weidmann é a referência empírica mais amplamente adotada para validação de simuladores de dinâmica de pedestres ([BURSTEDDE et al., 2001](#); [HELBING](#); [JOHANSSON](#); [AL-ABIDEEN, 2007](#); [RiMEA e.V., 2025](#)) e, portanto, também é adotada neste trabalho. Ancorar o passo de tempo a ela permite comparar a velocidade simulada diretamente com a curva velocidade-densidade de referência.

Cabe uma ressalva metodológica: a velocidade de caminhada livre é fixa por construção, uma vez que um pedestre se desloca, no máximo, uma célula por passo. Bater com 1,34 m/s de [Weidmann \(1993\)](#) é, portanto, uma consequência direta de como célula e passo de tempo foram mapeados para metros e segundos, e não uma validação do modelo. A validação emergente, que não decorre diretamente da escolha de escala, é o formato da curva velocidade-densidade, tratada no Teste 4 do RiMEA (Seção 5.3).

A atualização do estado das células do AC é realizada de forma paralela. Assim, em cada passo, todos os pedestres declaram simultaneamente sua célula-alvo, podendo gerar conflito de posicionamento. Para resolver esse problema, quando dois ou mais disputam a mesma célula, um único vencedor é sorteado uniformemente entre os concorrentes, permanecendo os demais em suas posições atuais (sem deslocamento).

4.1.2 Campo de piso estático

A orientação espacial dos pedestres é dada por um *campo de piso* estático (*static floor field*), estratégia consolidada na literatura de ACs de pedestres ([VARAS et al., 2007](#); [SILVA; DAMAZO; MARTINS, 2025](#)). Trata-se de um campo escalar $S(c)$ que atribui a cada célula transponível o custo mínimo de deslocamento até uma saída, computado por uma busca em largura com relaxamento a partir de todas as saídas simultaneamente:

$$S(c) = \begin{cases} 1, & \text{se } c \text{ é uma saída,} \\ \infty, & \text{se } c \text{ é obstáculo ou inalcançável,} \\ \min_{c' \in \mathcal{N}(c)} \{S(c') + w(c, c')\}, & \text{caso contrário,} \end{cases} \quad (4.1)$$

onde $\mathcal{N}(c)$ é a vizinhança da célula c , c' é uma célula dessa vizinhança e $w(c, c')$ é o custo de transição de c para c' . Esse custo assume o valor c_{adj} para deslocamentos ortogonais

e c_{diag} para deslocamentos diagonais. Os dois valem, por padrão, 1 e $\sqrt{2}$, mas são livres para configuração e estão sujeitos à calibração descrita na Seção 4.3.

Esse campo é computado uma única vez, antes do início da simulação, e não é atualizado ao longo dela. O modelo não possui campo dinâmico, isto é, a trajetória dos pedestres não realimenta o campo. A interação entre pedestres ocorre exclusivamente na dinâmica de disputa pela ocupação de uma mesma célula livre.

4.1.3 Mecanismo de confusão

A confusão é modelada como a probabilidade de um pedestre abandonar a decisão racional (célula livre com menor distância até a saída) e mover-se de forma aleatória. Ela não é um atributo do pedestre, mas um campo escalar definido sobre o reticulado: o pedestre herda, a cada passo, a confusão da célula que ocupa.

O campo é construído em duas etapas. A primeira estabelece a *confusão base* de cada célula, que cresce com sua distância à saída. Seja $S_{\text{max}} = \max\{S(c) : S(c) < \infty\}$ o maior custo finito do mapa e β a constante de confusão base, então a confusão $C_0(c)$ de uma célula c é definida por:

$$C_0(c) = \begin{cases} 0, & \text{se } c \text{ é obstáculo, saída, placa ou inalcançável,} \\ \beta \cdot \frac{S(c)}{S_{\text{max}}}, & \text{caso contrário.} \end{cases} \quad (4.2)$$

Essa modelagem representa uma hipótese comportamental simples: o pedestre distante da saída, sem referência visual dela, tem maior propensão a errar. À medida que se aproxima ou tem contato visual com a saída ou alguma placa de sinalização, a confusão deixa de existir ($S(c) \rightarrow 1$ e $C_0(c) \rightarrow 0$). O parâmetro β é o teto dessa confusão, atingido apenas na célula mais distante do mapa.

Já a segunda etapa introduz a redução por proximidade de placa, que atua sobre o campo C_0 . Seja $d(c)$ a distância, medida em número de passos na vizinhança de Moore e sem atravessar obstáculos, entre a célula c e a placa mais próxima; a propagação é interrompida em $d = 3$. A confusão efetiva é dada por:

$$C(c) = \begin{cases} 0, & \text{se } d(c) \leq 1, \\ C_0(c)/3, & \text{se } d(c) = 2, \\ C_0(c)/2, & \text{se } d(c) = 3, \\ C_0(c), & \text{se } d(c) > 3 \text{ ou não há placa alcançável.} \end{cases} \quad (4.3)$$

Trata-se, portanto, de um *decaimento em degraus* do grau de confusão em função do raio de visão da placa (limitado a $R = 3$). Em outras palavras, a vizinhança imediata da placa tem sua confusão anulada, e o efeito protetor é suavizado progressivamente até desaparecer além de três células. Tanto a confusão base quanto o decaimento por proximidade de placa, incluindo os fatores de redução ($0, \div 3, \div 2$) e o corte de propagação em três células, foram baseados nas estratégias propostas por [Silva, Damazo e Martins \(2025\)](#) e serviram como base para a formulação do problema de posicionamento de placas. Destaca-se que o foco deste trabalho não está no mecanismo em si, mas na sua calibração e otimização, conforme descrito na Seção 4.2.

A consequência das Equações 4.1 e 4.3 é que a placa, neste modelo, não é um obstáculo, mas um escudo de confusão. Uma célula do tipo Placa é transponível e o campo de piso estático propaga-se através dela normalmente (a Eq. 4.1 não distingue Placa de Vazia). Uma placa não altera, portanto, a rota ótima de nenhum pedestre. Ela afeta apenas a probabilidade dessa rota realmente ser seguida. Esse desacoplamento é deliberado, pois isola o efeito informacional da sinalização do efeito geométrico de um obstáculo, permitindo atribuir qualquer ganho observado exclusivamente à redução de confusão. Essa é uma diferença para a abordagem proposta por [Silva, Damazo e Martins \(2025\)](#). No modelo original, a placa é montada sobre um obstáculo e permanece intransponível, o que a prende às paredes e às bordas do ambiente. Neste trabalho, a célula de sinalização pode ocupar qualquer posição transponível da planta, inclusive o meio de um corredor ou de uma sala. A escolha corresponde a uma sinalização suspensa no teto ou a setas aplicadas ao piso, que orientam sem ocupar o espaço de circulação, e que são justamente o recurso mais eficaz quando a visibilidade é reduzida. A consequência prática é que o espaço de busca da fase de otimização deixa de ser o contorno do ambiente e passa a ser toda a sua área útil.

4.1.4 Regra de transição

A cada passo de tempo, um pedestre situado na célula c escolhe sua célula-alvo de acordo com três regras mutuamente excludentes, avaliadas na ordem apresentada a seguir. Seja π o parâmetro de *taxa de pânico*:

1. **Pânico** (probabilidade π): o pedestre permanece na célula atual sem avaliar alternativas, perdendo o passo. O mecanismo é herdado do modelo de [Varas et al. \(2007\)](#), no qual a taxa de pânico é a probabilidade de um pedestre não se mover em um dado passo de tempo;
2. **Confusão** (probabilidade $C(c)$, avaliada apenas se não houve pânico): o pedestre desloca-se para uma célula livre da vizinhança $\mathcal{N}(c)$, sorteada uniformemente, ignorando o campo de piso;

3. **Decisão racional** (caso contrário): o pedestre observa as células livres de sua vizinhança $\mathcal{N}(c)$ e a própria célula que ocupa, e desloca-se para aquela de menor valor do campo de piso (escolha gulosa), com empates resolvidos por sorteio uniforme.

A decisão racional pode ser descrita de forma compacta. Chamando de c^* a célula-alvo escolhida, a regra apenas seleciona, entre as vizinhas livres e a própria célula atual, aquela que minimiza o campo de piso:

$$c^* = \min_{c' \in \mathcal{N}^{\text{livre}}(c) \cup \{c\}} S(c'). \quad (4.4)$$

A inclusão da própria célula no conjunto de candidatos garante que o pedestre nunca se desloque para uma célula de custo maior, isto é, nunca se afaste da saída sob decisão racional. Quando há vizinhas livres de custo mínimo igual ao da célula atual, o sorteio uniforme entre elas e a própria célula pode produzir um deslocamento lateral entre células de mesmo custo. Isso ocorre, em particular, quando a vizinha de menor custo está ocupada e é descartada pela regra de escolha gulosa, situação em que o pedestre contorna o congestionamento por uma célula de custo equivalente em vez de permanecer imóvel.

A restrição do conjunto de candidatos, na decisão racional, às células *livres* de $\mathcal{N}(c)$ (Eq. 4.4) é uma escolha de projeto adotada de Damazo (2024), que a chama de escolha gulosa: uma célula ocupada nunca é um alvo válido, apenas uma candidata eliminada do conjunto de comparação da Eq. 4.4, de modo que o pedestre contorna o obstáculo dinâmico em vez de aguardar sua liberação. A regra diverge, nesse ponto, da escolha com espera (*choice with waiting*) proposta por Varas et al. (2007) e herdada por Silva, Damazo e Martins (2025).

As três regras são avaliadas em cascata, na forma de sorteios encadeados: a cada passo, o pedestre primeiro sorteia o pânico, que ocorre com probabilidade π ; não havendo pânico, sorteia em seguida a confusão, que ocorre com a probabilidade $C(c)$ da célula que ocupa; e, apenas se nenhum dos dois ocorrer é que o pedestre age de forma racional. Marginalizando essa sequência de sorteios, as probabilidades efetivas de cada comportamento em um dado passo resultam em:

$$\begin{aligned} P(\text{pânico}) &= \pi, \\ P(\text{confusão}) &= (1 - \pi) C(c), \\ P(\text{racional}) &= (1 - \pi)(1 - C(c)). \end{aligned} \quad (4.5)$$

É importante destacar a distinção entre β e $C(c)$: β é um parâmetro do modelo que representa a quantidade máxima de confusão empregada e, portanto, pode ser ajustado pelo AG durante o processo de calibração; enquanto $C(c)$ é a probabilidade calculada

durante a simulação, que efetivamente governa o passo do pedestre. Dois pedestres com o mesmo β , em posições distintas do mapa, têm probabilidades de confusão ($C(c)$) distintas.

O modelo comporta, assim, exatamente quatro parâmetros comportamentais livres: β (confusão base), π (taxa de pânico), c_{diag} e c_{adj} (custos de deslocamento). Não há atributos individuais que diferenciem os pedestres entre si: todos compartilham os mesmos parâmetros, e a heterogeneidade de comportamento emerge exclusivamente da posição de cada um no campo de confusão e do sorteio estocástico da Eq. 4.5.

4.2 Motor Evolutivo do Algoritmo Genético

O AG atua sobre o AC em duas fases sequenciais e independentes, *calibração* (Seção 4.3) e *otimização* (Seção 4.4), descritas cada uma em sua própria seção, por tratarem de problemas de naturezas distintas: a primeira persegue um alvo, a segunda persegue um ótimo. Ambas compartilham, no entanto, o mesmo motor evolutivo, formalizado nesta seção, e diferem na representação do indivíduo, operadores genéticos e função de aptidão.

4.2.1 Avaliação do indivíduo

A escolha das métricas de avaliação se apoia na literatura de simulação de evacuação. Revisões sistemáticas apontam a escassez recorrente de dados empíricos para calibração e a necessidade de métricas que capturem o comportamento espacial interno da simulação, e não apenas indicadores de desfecho (SENANAYAKE et al., 2024; SIYAM; ALQARYOUTI; ABDALLAH, 2020). A densidade mede o grau de ocupação de cada área e é consolidada na literatura para capturar congestionamentos. O fluxo, também consolidado pela literatura, mede a taxa de saída de pedestres e reflete a eficiência da evacuação. O tempo total de evacuação é a métrica de desfecho global, amplamente usada como indicador de eficácia. A dispersão foi incluída como refinamento da densidade: mede quão próximos ou distantes estão os pedestres dentro de uma área monitorada. Maximizar a dispersão ajuda a prevenir aglomerações perigosas e a mitigar o efeito “mais rápido é mais lento”, no qual gargalos congestionados retardam a evacuação coletiva. Mitigar esse efeito é um dos objetivos da etapa de otimização da distribuição das placas de sinalização.

Adicionalmente, o AC é estocástico, ou seja, a mesma configuração de parâmetros pode produzir resultados distintos a cada execução do modelo de simulação. Portanto, avaliar um indivíduo por uma única execução significaria atribuir-lhe uma aptidão enviesada pelo comportamento de uma amostra específica, e não sua aptidão real (mais generalista), sendo a exploração do AG significativamente afetada por esses ruídos de natureza estocástica. Para mitigar isso, a aptidão de cada indivíduo é computada como a média de D execuções independentes do AC ($D = 15$ em ambas as fases), de modo que cada indivíduo é avaliado por sua aptidão média, e não por uma única execução.

4.2.2 Operadores evolutivos

Ambas as fases empregam uma população de $N = 200$ indivíduos evoluída por $G = 100$ gerações, com substituição geracional. A cada geração, a nova população é formada por:

1. **Elitismo:** os $e = 5$ indivíduos de maior aptidão são copiados inalterados para a geração seguinte (GOLDBERG, 1989).
2. **Descendentes:** as $N - e$ vagas restantes são preenchidas selecionando-se dois pais por **torneio** de tamanho $k = 3$ (GOLDBERG, 1989; SIVANANDAM; DEEPA, 2008) e aplicando-se, com probabilidade $p_c = 0,8$, o operador de **cruzamento**; caso o cruzamento não ocorra, o descendente é uma cópia do primeiro pai. O descendente sofre então **mutação** com probabilidade $p_m = 0,15$.

Indivíduos preservados por elitismo não são reavaliados. Como seu genótipo não se alterou, conservam a aptidão já computada, o que evita introduzir ruído de amostragem no topo da população.

Os valores dos hiperparâmetros acima foram definidos com base na literatura, a fim de estabelecer uma configuração de referência para o AG.

4.3 Fase 1: Calibração

Esta é a primeira fase do AG e a contribuição central deste trabalho. Busca-se a configuração de parâmetros comportamentais que faz o AC reproduzir, o mais fielmente possível, um padrão de referência. Esse padrão combina três métricas espaciais por área, que são a densidade, a dispersão e o fluxo, e uma métrica global, que é o tempo de evacuação. A fase de otimização (Seção 4.4) depende da configuração de parâmetros obtida aqui e é descrita em separado.

4.3.1 Representação do indivíduo

A representação do indivíduo é direta. Trata-se de um vetor de quatro genes reais, correspondentes aos quatro parâmetros livres do AC:

$$\mathbf{x} = (\beta, \pi, c_{\text{diag}}, c_{\text{adj}}), \quad (4.6)$$

com cada gene restrito a um intervalo de busca: $\beta \in [0,0, 1,0]$, $\pi \in [0,0, 0,5]$, $c_{\text{diag}} \in [1,0, 2,0]$ e $c_{\text{adj}} \in [0,5, 1,5]$. A população inicial é amostrada uniformemente nesses intervalos. As execuções desta fase ocorrem sobre o mapa *sem placas*.

Os intervalos de β e π diferem em amplitude porque os dois parâmetros agem em escalas distintas. A confusão base é modulada espacialmente, e seu efeito, mesmo no teto do intervalo, concentra-se nas regiões distantes da saída (Eq. 4.3). O pânico é global, aplica-se a todo pedestre em qualquer célula a cada passo, e um valor alto paralisaria a simulação inteira, e não apenas suas regiões críticas. Daí o teto de π em 0,5, metade do adotado para β . O piso em zero, comum aos dois, permite ao AG recuperar uma evacuação sem pânico nem confusão.

Os custos de deslocamento foram tomados em intervalos amplos em torno de seus valores padrão ($c_{\text{adj}} = 1$ e $c_{\text{diag}} = \sqrt{2}$, Seção 4.1.2). A preferência de direção do pedestre é governada pelo quociente entre os dois custos, e os limites adotados permitem que esse quociente vá da preferência por diagonais ao percurso puramente ortogonal. Nenhum dos dois intervalos alcança zero, o que romperia a interpretação do campo de piso como custo mínimo de deslocamento (Eq. 4.1).

4.3.2 Operadores evolutivos específicos da calibração

Além do torneio, elitismo e avaliação do indivíduo descritos na Seção 4.2 e que funcionam como apresentados na Seção 2.2, essa fase acrescenta dois operadores próprios para a codificação baseada em valores reais: o cruzamento BLX- α e a mutação gaussiana.

O cruzamento BLX- α (ESHELMAN; SCHAFFER, 1993) foi escolhido por permitir que os descendentes explorem mais o espaço de busca para genes contínuos. Ele opera o gene da seguinte forma:

Sejam g_1 e g_2 os valores de um mesmo gene nos dois pais e $\Delta = |g_1 - g_2|$ a distância entre eles. O valor do gene no descendente é sorteado uniformemente no intervalo

$$[\min(g_1, g_2) - \alpha\Delta, \max(g_1, g_2) + \alpha\Delta], \quad (4.7)$$

isto é, no intervalo definido pelos pais, alargado em $\alpha\Delta$ para cada lado. O parâmetro α controla o quanto o operador pode extrapolar. Com $\alpha = 0,5$, valor adotado aqui, o descendente pode cair fora do intervalo dos pais, o que preserva a diversidade da população e permite ao AG escapar de mínimos locais. Quanto mais próximos os pais, menor o Δ e menor a extrapolação, de modo que o operador explora menos à medida que a população converge.

A mutação gaussiana adotada, quando aplicada a um indivíduo, perturba os quatro genes de uma vez. A cada gene soma-se um ruído sorteado de uma distribuição normal de média zero e desvio-padrão $\sigma_g = 0,15 \cdot (\max_g - \min_g)$. O desvio é, portanto, proporcional à amplitude do intervalo de busca daquele gene, o que faz a perturbação ter a mesma escala relativa em todos eles, apesar de os quatro parâmetros terem faixas de valores diferentes.

Tanto o cruzamento quanto a mutação podem produzir valores fora dos intervalos de busca. Por isso, após os dois operadores, cada gene é limitado ao valor limite do seu intervalo válido.

4.3.3 Função de aptidão

A função de aptidão mede o quanto o AC configurado por um indivíduo $\mathbf{x}$ do AG se afasta do padrão de referência comportamental. O campo estático é inicialmente dividido em $|\mathcal{A}| = 9$ áreas retangulares e cada área a é monitorada em função das três métricas espaciais $m \in \{\rho, \sigma, \varphi\}$ (densidade, dispersão e fluxo), definidas sobre a sequência de n instantes da simulação (estados das células do reticulado em momentos distintos da evolução do AC), como segue:

$$\rho_a = \frac{1}{n} \sum_{t=1}^n \frac{N_t(a)}{|a|}, \quad \text{densidade média de ocupação;} \quad (4.8)$$

$$\sigma_a = \frac{1}{n} \sum_{t=1}^n \frac{1}{2} \left(\frac{s_x(t)}{\Delta x/2} + \frac{s_y(t)}{\Delta y/2} \right), \quad \text{dispersão espacial normalizada;} \quad (4.9)$$

$$\varphi_a = \frac{1}{n} \sum_{t=1}^n \frac{\max(0, N_0(a) - N_t(a))}{N_0(a)}, \quad \text{fluxo de saída acumulado.} \quad (4.10)$$

onde $N_t(a)$ é o número de pedestres na área a no instante t ; $|a|$ é o número de células da área; e $s_x(t)$ e $s_y(t)$ são os desvios-padrão populacionais das coordenadas dos pedestres presentes na área. As extensões Δx e Δy são as dimensões da área a medidas entre suas coordenadas extremas; $\Delta x/2$ é, portanto, o maior desvio-padrão que uma distribuição de pedestres pode assumir, atingido quando a população se divide em partes iguais nas duas bordas opostas, e é essa normalização que mantém σ_a no intervalo unitário. As três métricas são adimensionais e limitadas ao intervalo $[0, 1]$. A métrica φ_a acumula, a cada instante, a fração da população inicial da área que já saiu dela, e tira a média desses valores ao longo da execução. Quanto mais cedo os pedestres deixam a área, mais instantes contribuem com uma fração alta, e maior fica φ_a . Duas execuções que terminam com a mesma população residual podem, assim, receber valores diferentes conforme a rapidez com que esvaziaram a área.

As três métricas operam em escalas distintas e apresentam variâncias naturais muito diferentes entre si. Somar seus erros absolutos faria a métrica mais volátil dominar a aptidão. O erro de cada métrica é, por isso, normalizado pelo desvio-padrão da própria métrica no padrão de referência ($s_{m,a}$), medido considerando todas as execuções que o produziram. Assim, um erro passa a ser expresso em termos da sua variância natural, e não em unidades brutas. Dessa forma, o erro total de um indivíduo $\mathbf{x}$ é dado por:

$$E(\mathbf{x}) = \sum_{a \in \mathcal{A}} \sum_{m \in \{\rho, \sigma, \varphi\}} w_m \cdot \frac{|\bar{m}_a(\mathbf{x}) - m_a^{\text{ref}}|}{s_{m,a}} + w_T \cdot \frac{|\bar{T}(\mathbf{x}) - T^{\text{ref}}|}{s_T}, \quad (4.11)$$

onde $\bar{m}_a(\mathbf{x})$ é a métrica m da área a medida no AC e calculada em média sobre as D execuções, m_a^{ref} é seu valor de referência, $\bar{T}$ e T^{ref} são os tempos de evacuação simulado e de referência, e s_T é o desvio-padrão do tempo de referência. Todos os pesos w_m e w_T valem 1,0 na configuração adotada. A aptidão é o inverso deslocado do erro:

$$f_{\text{cal}}(\mathbf{x}) = \frac{1}{1 + E(\mathbf{x})}. \quad (4.12)$$

A forma da Eq. 4.12 é conveniente por três razões: é estritamente decrescente em E , de modo que maximizar f_{cal} é minimizar o erro; é limitada ao intervalo $(0, 1]$, atingindo o máximo $f_{\text{cal}} = 1$ apenas na reprodução exata do padrão de referência; e é suave, evitando descontinuidades no relevo de aptidão.

4.4 Fase 2: Otimização do Posicionamento de Placas

Nesta segunda fase, o AG deixa de perseguir um alvo, como na calibração (Seção 4.3), e passa a perseguir um ótimo: o posicionamento de placas que melhor equilibra congestionamento, dispersão, fluxo, uso de poucas placas e tempo de evacuação. O motor evolutivo é o mesmo descrito na Seção 4.2. Mudam apenas a representação do indivíduo, os operadores evolutivos empregados e a função de aptidão, como descrito a seguir.

4.4.1 Representação do indivíduo

Fixados os parâmetros comportamentais na configuração $\mathbf{x}^*$ obtida na Fase 1, o indivíduo deixa de ser um vetor de números e passa a ser um conjunto de posições de placas, de cardinalidade variável:

$$\mathbf{P} = \{p_1, p_2, \dots, p_m\}, \quad 0 \leq m \leq M, \quad (4.13)$$

onde M é o número máximo de placas admitidas ($M = 20$ na configuração adotada) e cada p_i é uma célula do conjunto de posições válidas: toda célula que não seja obstáculo, saída ou posição inicial de um pedestre. Note-se que o cromossomo tem comprimento variável, portanto, o número de placas é, por si só, um objeto de busca, e não um parâmetro fixado *a priori*.

4.4.2 Operadores evolutivos específicos da otimização

Como o cromossomo tem comprimento variável, os operadores desta fase precisam decidir duas coisas ao mesmo tempo. A primeira é onde as placas ficam, e a segunda é quantas placas o indivíduo tem. Por isso tanto o cruzamento quanto a mutação operam em dois níveis: das posições e da quantidade.

O cruzamento acontece em duas etapas. Na primeira, define-se quantas placas o descendente terá. Esse número é sorteado por BLX- α (Eq. 4.7) sobre as cardinalidades dos dois pais, tratadas como se fossem um gene real, e o resultado é arredondado e truncado ao intervalo $[0, M]$. Na segunda etapa, sabendo quantas placas o descendente terá, suas posições são sorteadas sem reposição da união dos conjuntos dos dois pais. O descendente herda, assim, apenas posições que ao menos um dos pais considerava boas. Caso essa união tenha menos posições do que a cardinalidade sorteada, o restante é completado com posições válidas que não estavam em nenhum dos pais, sorteadas uniformemente entre todas as disponíveis, sem preferência por região do mapa.

A mutação combina dois mecanismos independentes, um para cada nível. O primeiro é a relocação, que atua sobre a qualidade das posições sem mexer na quantidade. Um número fixo de placas ($n_{\text{mov}} = 1$ na configuração adotada) é transferido para uma posição válida sorteada uniformemente entre as ainda não ocupadas. É este operador que percorre o espaço de posições. O segundo é a mutação da cardinalidade, que atua sobre a quantidade. Com probabilidade $p_{\pm} = 0,2$, o número de placas sobe ou desce em uma unidade, com igual chance para cada direção, acrescentando-se uma posição livre ou removendo-se uma placa sorteada uniformemente, sempre respeitado o intervalo $[0, M]$. Como cada mecanismo age sobre uma dimensão distinta do problema, a busca explora posição e quantidade de forma desacoplada.

4.4.3 Função de aptidão

A função de aptidão desta fase é uma soma ponderada de cinco termos:

$$f_{\text{ot}}(\mathbf{P}) = \underbrace{w_{\rho}(1 - \bar{\rho})}_{\text{congestionamento}} + \underbrace{w_{\sigma}\bar{\sigma}}_{\text{dispersão}} + \underbrace{w_{\varphi}\bar{\varphi}}_{\text{fluxo}} + \underbrace{w_s\left(1 - \frac{|\mathbf{P}|}{M}\right)}_{\text{economia de placas}} + \underbrace{w_T\left(1 - \frac{\bar{T}}{T^{\text{ref}}}\right)}_{\text{tempo}}, \quad (4.14)$$

onde $\bar{\rho}$, $\bar{\sigma}$ e $\bar{\varphi}$ são as métricas das Equações 4.8 a 4.10 calculadas em média sobre todas as áreas monitoradas e sobre as D execuções, $|\mathbf{P}|$ é o número de placas do indivíduo e $\bar{T}/T^{\text{ref}}$ é o tempo de evacuação normalizado pelo tempo de referência. Os pesos adotados são $w_{\rho} = w_{\sigma} = w_{\varphi} = w_T = 1,0$ e $w_s = 0,2$. O peso reduzido ($w_s = 0,2$) reflete a decisão de tratar a economia de placas como restrição secundária, e não como objetivo de primeira ordem. Os demais pesos foram mantidos iguais entre si porque se pretende que

o AG otimize, possivelmente, todas as métricas em conjunto, e não apenas o tempo de evacuação, que é um fator de grande influência nesse cenário de otimização.

Cada termo codifica um objetivo distinto. A densidade entra *negada*: alta ocupação média nas áreas monitoradas indica congestionamento, e é penalizada. A dispersão entra positivamente: pedestres espalhados pelo espaço disponível são preferíveis a pedestres aglomerados. O fluxo recompensa a saída precoce. O quarto termo, de economia de placas, penaliza o uso de placas proporcionalmente à *fração* consumida do número máximo de placas estipulado: um indivíduo sem placas recebe w_s integral e um indivíduo que utiliza todas as placas disponíveis recebe zero, de modo que placas adicionais só são preservadas pela seleção se o ganho que produzem nos demais termos superar seu custo.

5 Resultados e Discussão

Este capítulo reporta os resultados obtidos com o simulador de Autômato Celular (AC) e com o Algoritmo Genético (AG) de duas fases. O eixo central é a calibração comportamental, isto é, verificar se o AG configura o AC para reproduzir o comportamento observável de um regime de referência, medido pela densidade, pela dispersão, pelo fluxo e pelo tempo de evacuação dos pedestres. Essa verificação é feita duas vezes. Primeiro contra um regime de referência gerado pelo próprio simulador, e depois contra regimes gerados sobre as geometrias normativas RiMEA, o que confronta o AC com um critério externo e, como consequência, com o diagrama fundamental do movimento de pedestres. Sobre o modelo já calibrado, o capítulo apresenta ainda a otimização do posicionamento de placas de sinalização, que aplica o mesmo motor evolutivo a um problema de decisão de projeto. Inicialmente, experimentos foram conduzidos para ajustar a configuração do AG (Seção 5.1). A melhor versão do algoritmo é então validada quanto a sua capacidade de calibração, tanto em relação à reprodução do comportamento, quanto aos testes normativos (Seção 5.2). Em seguida, é avaliada a eficiência do AG na otimização da distribuição das placas de sinalização e a qualidade da heurística (Seção 5.4) e encerra com a síntese dos achados (Seção 5.5).

5.1 Ajuste da Configuração do AG

Antes dos experimentos principais, foram analisadas diferentes configurações do AG. Algumas escolhas iniciais se apoiam em valores adotados em outras abordagens da literatura correlata, por exemplo, a partição do reticulado em nove setores e o conceito de taxa de amostragem, descritos por [Murilo \(2025\)](#), também foram adotados em nossa abordagem como o esquema de nove áreas de monitoramento e como o parâmetro de intervalo de observação. No total, foram realizados onze experimentos com 10 execuções independentes cada, todos sobre o cenário ilustrado na Figura 8. Esse mapa é formado por um reticulado de 50×33 células, 100 pedestres e duas saídas posicionadas nas extremidades inferiores. Ele foi escolhido por ser complexo o bastante, pela densidade de pedestres e pela geometria dos ambientes, possibilitando a aferição de valores significativos de fluxo, densidade e dispersão. Ressalta-se que em cenários com população esparsa, as métricas por área seriam fracas demais para separar de forma confiável uma configuração de outra. Nesse experimento, foram avaliados diferentes esquemas de particionamento das áreas, considerando divisões com quatro, nove, dezesseis e vinte e cinco regiões, além da ausência de particionamento, e intervalos de amostragem de 1 a 25 passos.




Figura 8 – Mapa de referência.

Fonte: Elaborado pelo autor.

5.1.1 Definição do número de áreas de monitoramento

O número de divisões do ambiente analisado influencia a granularidade considerada no cálculo das métricas e, conseqüentemente, afeta diretamente a função de aptidão do AG. Nesse sentido, foram avaliadas cinco formas de particionamento, com quatro, nove, dezesseis e vinte e cinco áreas, além de uma execução sem particionamento nenhum, a fim de determinar aquela que retorna os valores mais precisos para as métricas sem aumentar significativamente o tempo de execução.

A Tabela 2 apresenta os valores das métricas de desempenho alcançados pelo AG, de acordo com a quantidade de partições do cenário consideradas na função de avaliação. Os valores apresentados na tabela representam a média e o desvio-padrão obtidos a partir de 10 execuções do algoritmo, de forma independente. As cinco colunas compartilham a mesma configuração e a mesma *seed*, de modo que todas partem do mesmo regime de referência, cujo tempo médio de evacuação é de 167,6 passos. A granularidade da partição é o único fator que varia entre as colunas.

Os quatro erros da tabela são obtidos por comparação entre o modelo calibrado e o regime de referência. Cada uma das 10 execuções independentes contribui com um valor por erro, medido entre o melhor indivíduo calibrado daquela execução e o regime de referência. Para densidade, dispersão e fluxo, esse valor é a média entre todas as áreas, na escala adimensional descrita na Seção 4.3.3, e para o tempo de evacuação é a diferença em passos de simulação. A tabela reporta a média e o desvio-padrão desses 10 valores. O tempo de evacuação otimizado não mede erro. Em cada execução, o melhor arranjo de placas encontrado pelo AG é simulado 30 vezes com os parâmetros calibrados, e a tabela

reporta a média desses tempos entre as 10 execuções. O tempo de simulação, por sua vez, é o tempo de relógio consumido por uma execução completa do procedimento, da geração do regime de referência até o fim da otimização.

Tabela 2 – Erro de calibração, desfecho de otimização e custo computacional por esquema de áreas.

Métricas	1 área	4 áreas	9 áreas	16 áreas	25 áreas
Erro de densidade [10^{-3}]	$0,46 \pm 0,27$	$0,66 \pm 0,29$	$0,60 \pm 0,14$	$0,71 \pm 0,17$	$0,83 \pm 0,13$
Erro de dispersão [10^{-3}]	$9,4 \pm 7,7$	$6,9 \pm 4,6$	$8,0 \pm 2,1$	$6,2 \pm 1,0$	$4,9 \pm 0,9$
Erro de fluxo [10^{-3}]	$7,5 \pm 4,5$	$10,9 \pm 5,0$	$8,8 \pm 2,4$	$5,8 \pm 1,9$	$4,0 \pm 0,9$
Erro de tempo de evacuação [passos]	$2,91 \pm 2,52$	$3,76 \pm 3,29$	$3,78 \pm 3,56$	$4,09 \pm 2,59$	$5,81 \pm 4,76$
Tempo de evacuação otimizado [passos]	124 ± 5	127 ± 4	114 ± 4	111 ± 5	110 ± 4
Tempo de simulação [s]	321 ± 7	315 ± 5	307 ± 4	299 ± 4	289 ± 5

Fonte: Elaborado pelo autor.

Como pode ser observado, o tempo de execução do procedimento completo varia pouco entre os esquemas, de 321 segundos com uma área a 289 com vinte e cinco. A redução não vem do custo de particionar o mapa na calibração, e sim da fase de otimização, que cai de 145 para 127 segundos entre os dois extremos. Com mais áreas o AG chega a arranjos de placas que evacuam mais rápido, e como o custo de cada simulação de AC acompanha o número de passos simulados, a busca inteira termina antes. O tempo de evacuação otimizado cai de 127 passos com quatro áreas para 114 com nove, e depois estabiliza em 111 e 110 com dezesseis e vinte e cinco áreas.

Sobre os erros, todos são baixos e de magnitude parecida, mas apenas duas das quatro linhas comparam os esquemas de forma direta. A dispersão e o fluxo são calculados por área e dependem de áreas populadas, já que áreas vazias contribuem de forma significativa, levando em consideração que a diferença entre a referência e o calibrado é nula. A densidade e o tempo de evacuação não têm essa dependência. A primeira sobe de 0,46 com uma área para 0,83 com vinte e cinco, e o segundo acompanha, subindo de 2,91 para 5,81 passos. Há, portanto, um indício de que menos divisões replicam melhor o regime de referência, consistente nas duas linhas comparáveis, mas com diferenças que ficam dentro da variação entre execuções desta varredura. Mais divisões, em contrapartida, otimizam melhor, e a diferença é evidente na passagem de quatro para nove áreas. O resultado obtido com poucas áreas é, ainda, menos preciso, e o desvio-padrão do erro de densidade entre execuções cai de 0,27 com uma área para 0,14 já com nove. Com poucos termos, a aptidão fica plana e execuções independentes param em pontos distintos do espaço de busca. O esquema de nove áreas foi adotado por apresentar um bom meio-termo entre essas duas direções, sendo o ponto em que termina o único ganho de otimização claramente medido, o de quatro para nove, e ainda dentro da faixa em que o erro de calibração não cresceu de forma considerável. Cabe registrar que a varredura dispõe de 10 execuções por esquema, o que basta para separar quatro de nove áreas, mas não para distinguir nove

de dezesseis ou de vinte e cinco. Para mapas muito maiores, seria necessário aumentar a granularidade na mesma proporção.

5.1.2 Intervalo de amostragem

O intervalo de amostragem controla a frequência com que o estado da simulação é registrado e utilizado no cálculo das métricas espaciais. Esse parâmetro permite que o sistema opere com diferentes taxas de observação de fontes de dados externas, como quadros de câmera ou leituras periódicas de sensores. Seis níveis foram testados, mantendo os demais parâmetros da configuração fixos e o esquema de nove áreas adotado na subseção anterior. Os resultados dessa análise são descritos na Tabela 3. Os valores apresentados representam a média e o desvio-padrão obtidos a partir de 10 execuções independentes do algoritmo em cada nível, e os erros são calculados da mesma forma descrita na Subseção 5.1.1, com densidade, dispersão e fluxo na escala adimensional de ocupação e o tempo de evacuação como erro absoluto em passos de simulação. A última coluna não mede erro, e reporta o tempo de evacuação do melhor arranjo de placas encontrado em cada execução, simulado 30 vezes com os parâmetros calibrados.

Tabela 3 – Efeito do intervalo de amostragem sobre o erro de calibração e sobre o desfecho da otimização.

Intervalo	Erro de calibração				
	Densidade [10^{-3}]	Dispersão [10^{-3}]	Fluxo [10^{-3}]	Tempo de evac. [passos]	Tempo otimizado [passos]
1	$0,66 \pm 0,30$	$6,2 \pm 3,1$	$9,2 \pm 5,4$	$3,08 \pm 2,04$	115 ± 6
5	$0,54 \pm 0,17$	$6,0 \pm 2,0$	$7,6 \pm 3,1$	$3,94 \pm 2,54$	111 ± 4
10	$0,60 \pm 0,14$	$8,0 \pm 2,1$	$8,8 \pm 2,4$	$3,78 \pm 3,56$	114 ± 4
15	$0,60 \pm 0,22$	$7,3 \pm 2,3$	$8,9 \pm 2,2$	$3,85 \pm 4,26$	115 ± 3
20	$0,57 \pm 0,17$	$7,8 \pm 1,9$	$9,5 \pm 3,0$	$4,92 \pm 3,32$	114 ± 4
25	$0,67 \pm 0,30$	$9,0 \pm 3,1$	$10,1 \pm 5,5$	$6,05 \pm 3,49$	112 ± 6

Fonte: Elaborado pelo autor.

Os seis níveis produzem erros de calibração equivalentes. Nenhuma das quatro colunas de erro ordena os intervalos de forma consistente, e o intervalo de 10 não ocupa o menor valor de nenhuma delas. Comparando cada par de níveis em cada coluna por teste t de Welch, das 60 comparações de erro apenas quatro passam de $|t| = 2$, número compatível com o que o acaso produziria nessa quantidade de testes, e nenhuma delas resiste a uma correção por multiplicidade. Com 10 execuções por nível, a varredura não separa os intervalos entre si. O mesmo vale para o desfecho da otimização, com o tempo de evacuação otimizado variando entre 111 e 115 passos sem relação com o intervalo.

As duas pontas são as únicas que destoam, e por motivos diferentes. O intervalo de 25 é o pior colocado nas quatro colunas de erro ao mesmo tempo, o que não é significativo em nenhuma delas isoladamente, mas é a única regularidade que atravessa a tabela inteira.

Já o intervalo de 1 não reduz erro nenhum e custa quase dez vezes mais registros, pois o número de instantes processados é o número de passos dividido pelo intervalo, o que dá 5057 registros na referência contra 519 do intervalo de 10. Amostragem a cada passo, portanto, paga uma ordem de grandeza a mais pelo mesmo erro. O valor de 10 foi adotado por ficar no meio da faixa em que nada se distingue, afastado das duas pontas.

A ausência de um mínimo não é um resultado desfavorável. O intervalo de amostragem existe para que a calibração aceite fontes de observação com taxas diferentes, como quadros de câmera ou leituras periódicas de sensores, e o que a tabela mostra é que, dentro da faixa medida, essa taxa não precisa ser escolhida com cuidado, já que o procedimento devolve o mesmo erro em qualquer nível. Essa insensibilidade é desejável, porque a taxa de uma fonte externa é imposta pela fonte, e não escolhida por quem calibra. Cabe registrar, porém, que a faixa medida termina em 25 e que o maior erro das quatro colunas está justamente nesse nível, de modo que a direção de piora provavelmente continua com intervalos mais esparsos. A conclusão vale para os níveis testados e não se estende além deles.

5.2 Calibração e identificabilidade

O resultado central da Fase 1 é que o AG configura o AC para reproduzir o comportamento observável de um regime de referência. Dado que a eficiência do ajuste pelo AG é avaliada a partir de dados de referência artificiais, gerados pelo próprio simulador, os testes normativos foram empregados para delimitar até onde nossa abordagem (AG e AC) consegue reproduzir um comportamento real. A calibração foi avaliada em três regimes, definidos por combinações da taxa de pânico (π) e da confusão base (β), medindo-se o desvio entre o comportamento do modelo calibrado e o do *baseline* nas quatro grandezas que compõem a aptidão: densidade, dispersão, fluxo e tempo de evacuação. A Tabela 4 reporta esse desvio por regime, e cada valor é a média e o desvio-padrão sobre as $N = 30$ execuções do regime correspondente. O tempo de evacuação, desfecho global mais direto, aparece como erro relativo, isto é, a diferença entre o tempo do modelo calibrado e o tempo médio do *baseline*, dividida por esse mesmo tempo médio. Um erro de 1% significa que o calibrado evacua em um centésimo a mais ou a menos do tempo da referência. A forma relativa é a que permite comparar regimes cujos tempos absolutos são diferentes. Esse erro cresce com a confusão do regime, de 0,68% no *low* a 3,68% no *high*, com 1,97% no *default*. Já os desvios de densidade, dispersão e fluxo aparecem em diferença absoluta, porque as três métricas já são adimensionais e limitadas ao intervalo $[0, 1]$ por construção (Seção 4.3.3), de modo que a diferença é diretamente legível na escala de ocupação. Cada um dos três é ainda a média das nove áreas de monitoramento do mapa, e nenhum deles ultrapassa poucos centésimos dessa escala.

Tabela 4 – Desvio comportamental do modelo calibrado por regime, em relação ao *baseline*.

Regime	Densidade	Dispersão	Fluxo	Tempo de evac.
<i>low</i> ($n = 30$)	$0,0005 \pm 0,0002$	$0,0037 \pm 0,0011$	$0,0055 \pm 0,0019$	$0,68\% \pm 0,42\%$
<i>default</i> ($n = 30$)	$0,0005 \pm 0,0001$	$0,0062 \pm 0,0016$	$0,0081 \pm 0,0028$	$1,97\% \pm 1,23\%$
<i>high</i> ($n = 30$)	$0,0007 \pm 0,0004$	$0,0085 \pm 0,0042$	$0,0116 \pm 0,0068$	$3,68\% \pm 3,25\%$

Fonte: Elaborado pelo autor.

Essa fidelidade comportamental é acompanhada por uma recuperação paramétrica próxima à referência nos três regimes. A Tabela 5 mostra, por regime, os valores de π e β produzidos pela calibração e sua distância média à referência. A distância permanece pequena e da mesma ordem de grandeza nos três regimes, o que indica que a recuperação paramétrica é consistente e não depende do regime avaliado.

Tabela 5 – Configuração de π e β obtida pela calibração, por regime.

Regime	π calibrado	β calibrado
<i>low</i> ($\pi = 0,05$, $\beta = 0,30$)	$0,0508 \pm 0,0097$	$0,3012 \pm 0,0120$
<i>default</i> ($\pi = 0,15$, $\beta = 0,80$)	$0,1520 \pm 0,0160$	$0,7996 \pm 0,0092$
<i>high</i> ($\pi = 0,40$, $\beta = 0,90$)	$0,3964 \pm 0,0199$	$0,9006 \pm 0,0083$

Fonte: Elaborado pelo autor.

A Tabela 5 não revela gradiente entre regimes: a distância média a π e a β permanece pequena e comparável nos três casos (no máximo 0,0138 em π , no regime *high*, e 0,0094 em β , no regime *low*), sem que nenhum regime se destaque como zona de maior incerteza. A recuperação paramétrica é, portanto, consistente através da faixa de confusão testada, e não apenas no ponto específico usado para gerar o *baseline*. Essa consistência depende diretamente de quais métricas compõem a aptidão, questão tratada a seguir.

Essa consistência não é incidental, e depende de quais componentes compõem a aptidão. Um experimento de ablação no regime *default* comparou três composições, cada uma sob $N = 30$ execuções (Figura 9). A primeira é a aptidão completa, com as métricas espaciais e o tempo de evacuação. A segunda remove o termo de tempo. A terceira mantém apenas o tempo de evacuação, removendo as métricas espaciais. A figura traz um painel para cada parâmetro, com o desvio em relação ao valor verdadeiro de π à esquerda e o de β à direita.

A comparação é feita sobre a dispersão dos valores recuperados, e não sobre sua média. O que interessa não é se a calibração acerta o alvo em média, mas se ela o acerta de forma repetível. A medida usada é a razão entre as variâncias de duas composições, conhecida como estatística F : ela vale 1 quando as duas dispersam igual, e cresce conforme uma dispersa mais que a outra. Valores muito acima de 1 indicam que a composição sem aquele componente perdeu precisão.

Remover o termo de tempo eleva o desvio-padrão de π em 4,28 vezes, com $F = 18,3$, e não altera de forma apreciável o de β , com $F = 1,2$. Manter apenas o tempo de evacuação eleva o desvio-padrão de β em 25,4 vezes, com $F = 644,4$, e o de π em 8,13 vezes, com $F = 66,2$. A leitura é direta. É o termo de tempo que identifica a taxa de pânico, e são as métricas espaciais que identificam a confusão base. Nenhum dos dois componentes, isoladamente, identifica os dois parâmetros comportamentais com igual precisão, e remover qualquer um deles compromete a identificabilidade de ao menos um dos dois, isto é, faz com que valores distintos daquele parâmetro produzam a mesma medida e deixem de ser distinguíveis pela calibração. É o que justifica empiricamente a opção por uma aptidão que combina densidade, dispersão, fluxo e tempo de evacuação.




Figura 9 – Ablação dos termos da aptidão de calibração no regime *default*.

Fonte: Elaborado pelo autor.

5.2.1 Comportamento do modelo calibrado

A Tabela 4 resume o desvio em quatro escalares, mas a evidência mais direta de reprodução está nas figuras desta subseção, que mostram se o modelo calibrado reproduz a *dinâmica espacial* do *baseline*, e não apenas seu agregado. O regime *default* ($\pi = 0,15$, $\beta = 0,80$) ilustra essa verificação: a forma temporal por área e a ordem de esvaziamento não entram na função de aptidão, de modo que sua correspondência com o *baseline* é evidência de reprodução, e não reflexo direto do que foi otimizado.

A Figura 10 sobrepõe as curvas das três métricas espaciais do *baseline* e do modelo calibrado, com uma linha por área de monitoramento e uma coluna para cada métrica, densidade, dispersão e fluxo. Cada curva é a média de 10 execuções independentes, e a faixa em torno dela reúne o desvio-padrão dentro de cada execução e o intervalo de confiança de 95% entre execuções. As curvas praticamente se sobrepõem nas três métricas, inclusive nas áreas cuja densidade exibe pico intermediário (áreas 4, 6, 7 e 9, que recebem fluxo




Figura 10 – Densidade, dispersão e fluxo por área ao longo do tempo, *baseline* contra modelo calibrado.

Fonte: Elaborado pelo autor.

de outras zonas antes de esvaziar), o que mostra que a calibração reproduz a dinâmica espacial, e não só o agregado.

A correspondência estende-se à ordem em que as zonas esvaziam. A Figura 11 mostra, para cada uma das nove áreas, o instante médio em que ela fica vazia, calculado sobre as mesmas 30 execuções independentes e acompanhado do intervalo de confiança de 95%. As áreas aparecem ordenadas pela sequência do *baseline*, e o modelo calibrado preserva essa sequência quase integralmente. A única inversão é entre as áreas 6 e 7, que trocam de posição relativa, e a troca cai dentro dos intervalos de confiança das duas, de modo que não configura uma diferença de comportamento.

O mesmo experimento permite olhar o desfecho global. Além do instante de esvaziamento de cada área, ele registra o tempo total até o último pedestre deixar o mapa, que é de $162,7 \pm 10,8$ passos no modelo calibrado contra 168 passos no *baseline*. A diferença é menor que o desvio-padrão do próprio calibrado, ou seja, a concordância que as curvas de densidade e a ordem de esvaziamento já mostravam se mantém também no tempo total de evacuação.




Figura 11 – Instante médio de esvaziamento por área, *baseline* contra calibrado.

Fonte: Elaborado pelo autor.

Por fim, a Figura 12 compara as posições dos pedestres no *baseline*, na linha superior, e no modelo calibrado, na inferior, em quatro instantes de uma mesma execução, sob a mesma semente. O que ela mostra é o formato da evacuação, e não o seu tempo. Nos primeiros instantes os pedestres ainda ocupam as salas de origem nos dois casos. Em seguida formam-se as mesmas frentes de deslocamento pelos corredores, com a concentração aparecendo nas mesmas passagens. Ao final, o esvaziamento progride pelas mesmas regiões e na mesma ordem.

A figura complementa as comparações anteriores por um caminho diferente. As

curvas de densidade, a ordem de esvaziamento e o tempo total resumem o comportamento em médias sobre trinta execuções, e uma média pode esconder trajetórias distintas que se compensam. O painel mostra que a semelhança também aparece em uma execução isolada, na disposição concreta dos pedestres ao longo do tempo. Os tempos dessa execução específica, por serem de uma única realização de um processo estocástico, situam-se dentro da variação já reportada e não devem ser lidos isoladamente.




Figura 12 – Posições dos pedestres em quatro instantes, *baseline* contra calibrado.

Fonte: Elaborado pelo autor.

Em conjunto, as três vistas mostram que o modelo calibrado reproduz a dinâmica espaço-temporal do *baseline*, e não apenas seus escalares agregados: a correspondência se estende à forma temporal por área e à ordem de esvaziamento, grandezas que não integram a função de aptidão otimizada pelo AG.

5.3 O modelo frente aos testes RiMEA

Os experimentos descritos até aqui medem o simulador contra ele mesmo. Para situá-lo frente a um critério externo, o modelo foi confrontado com a RiMEA, sigla de *Richtlinie für mikroskopische Entfluchtungsanalysen*, um conjunto de diretrizes alemãs para verificação de simuladores de evacuação (RiMEA e.V., 2025). A norma reúne quinze testes, cada um com uma geometria, uma população e um critério de aceitação declarados, de modo que dois simuladores diferentes possam ser submetidos ao mesmo exame.

Sete testes foram executados. Os Testes 1 e 4 usam um corredor reto e avaliam, respectivamente, se um pedestre isolado mantém velocidade constante em fluxo livre e como a velocidade do grupo decai com a densidade, o que produz o diagrama fundamental

do movimento de pedestres. O Teste 6 verifica se vinte pedestres contornam uma esquina sem atravessar parede, isto é, se o reticulado contém o movimento. O Teste 9 mede o efeito de reduzir de quatro para duas as portas de uma sala. O Teste 12 verifica o efeito de um gargalo entre dois ambientes, e o comportamento esperado é que o gargalo produza congestionamento apenas no primeiro ambiente, enquanto no segundo os pedestres devem caminhar livremente. O Teste 11 coloca duas saídas a distâncias diferentes e pergunta se a mais próxima é preferida sem que a outra fique deserta. O Teste 15 compara o tempo de evacuação de três geometrias, um corredor curto, uma esquina e um corredor longo, e exige que a esquina fique entre as duas retas e que o congestionamento se forme antes da curva.

Os oito testes restantes não foram executados, pois envolvem características que não são representadas no modelo de dinâmica de pedestres implementado. Em outras palavras, os testes 2, 3, 8, 13 e 14 dependem de escada, rampa ou múltiplos pavimentos, enquanto nosso modelo trabalha com um reticulado planar de um único piso. O Teste 5 exige uma distribuição de tempos de reação, e aqui todos os pedestres partem no instante zero. O Teste 10 atribui cada pedestre a uma saída específica, enquanto o campo de piso deste modelo é um único gradiente de custo em direção à saída mais próxima, sem a definição prévia de uma rota individual a ser seguida. O Teste 7 exige que os pedestres tenham velocidades de caminhada diferentes entre si, distribuídas conforme idade e sexo sobre uma população de cinquenta pessoas, e verifica se o simulador reproduz essa variedade. O modelo deste trabalho não consegue representá-la, porque a velocidade não é um atributo do pedestre. Ela é uma consequência da escala, já que todo pedestre avança no máximo uma célula por passo de tempo, o que fixa a mesma velocidade de 1,33 m/s para todos.

A construção dos testes seguiu sempre o mesmo caminho: o formato do ambiente descrito na norma, dado em metros, foi convertido para células pelo fator de 0,4 m por célula, conforme definido na Seção 4.1.1, e a população foi posicionada conforme ilustrado na Figura 13. Cada teste roda então em duas variantes, uma sob a regra de escolha gulosa adotada neste trabalho e outra sob a escolha com espera do modelo de referência, o que permite verificar se um veredito depende da regra de movimento ou da estrutura do modelo. O critério de aceitação de cada teste foi transcrito da norma e avaliado sobre trinta execuções independentes, salvo indicação em contrário.

A leitura dos resultados tem duas partes. A primeira verifica se o AC reproduz o comportamento que a norma espera. A segunda verifica se o calibrador recupera os parâmetros comportamentais em geometrias que não são aquela sobre a qual o método foi desenvolvido.

5.3.1 O autômato celular

A Tabela 6 resume os vereditos, e as geometrias aparecem na Figura 13. Cada teste foi avaliado sobre trinta execuções independentes, exceto o Teste 6, avaliado sobre mil. O Teste 6 é uma verificação mecânica do simulador, verificar se algum pedestre atravessa pela parede da esquina. Um evento desse tipo é raro por construção, de modo que sua ausência em trinta execuções informaria pouco, e elevar o número de execuções para mil aumenta a chance de capturar uma falha desse tipo.

Tabela 6 – Veredito do AC nos testes normativos RiMEA executados.

Teste	O que avalia	Veredito
1	Velocidade constante em corredor	Aprovado
4	Diagrama fundamental (velocidade–densidade)	Reprovado
6	Contorno de esquina e contenção do reticulado	Aprovado
9	Redução de 4 para 2 portas	Aprovado
11	Escolha entre saídas concorrentes	Reprovado
12	Efeito de gargalo entre dois ambientes	Aprovado
15	Esquina sob multidão grande	Parcialmente aprovado

Fonte: Elaborado pelo autor.

O modelo comporta-se como esperado nos testes 1, 6, 9 e 12. No Teste 1, com pânico e confusão nulos, o pedestre percorre o corredor livre à velocidade constante de 1,33 m/s, a mesma que a escala do modelo fixa (Seção 4.1.1). No Teste 6, sob mil execuções, os vinte pedestres contornam o canto e evacuam sem atravessar parede em $25,4 \pm 1,9$ s sob a regra gulosa e $30,0 \pm 2,0$ s com espera. No Teste 9, reduzir de quatro para duas portas eleva o tempo de evacuação por um fator de $1,59 \pm 0,05$ sob a regra gulosa e $1,62 \pm 0,03$ com espera, contra o alvo aproximado de duas vezes indicado pela norma. O sentido do efeito é o esperado e sua magnitude fica abaixo do alvo, o que a própria norma admite ao registrar que este teste não deve servir como critério de exclusão. No Teste 12, o pico de densidade se concentra no primeiro ambiente, com $5,53 \pm 0,11$ pessoas por metro quadrado contra $2,24 \pm 0,05$ no segundo sob a regra gulosa, enquanto os pedestres caminham de forma livre no segundo ambiente.

O Teste 4 expõe a principal limitação, e a varredura de parâmetros mostra que ela é estrutural. O erro relativo médio às curvas empíricas foi medido em seis combinações de π e β , tomando π em $\{0,15; 0,30; 0,45\}$ e β em $\{0,50; 0,80\}$, tanto em corredor largo quanto em corredor de fila única. Os dois parâmetros se comportam de maneiras bem diferentes. A taxa de pânico move o erro de forma monotônica nas seis séries medidas: no corredor largo comparado à curva de Weidmann (1993), ele cai de 1,84 em $\pi = 0,15$ para 1,51 em $\pi = 0,45$ sob a regra gulosa, e de 1,39 para 0,82 sob a regra com espera, ambos com $\beta = 0,50$. Em fila única, comparado à curva de Seyfried et al. (2005), o erro cai de 0,69 para 0,24. A direção é informativa, pois a taxa de pânico funciona como o parâmetro de




Figura 13 – Geometrias dos testes RiMEA executados.

Fonte: Elaborado pelo autor.

aleatorização de um modelo de Nagel–Schreckenberg, e aumentá-la aproxima o diagrama do empírico. Mas nenhum valor o alcança, e o melhor caso do corredor largo ainda erra 67%.

A confusão base, por sua vez, quase não desloca o diagrama, e nem sempre na mesma direção. Elevá-la de 0,50 para 0,80 piora o erro sob a regra gulosa nos dois pontos de pânico mais baixos, de 1,84 para 1,99 em $\pi = 0,15$ e de 1,67 para 1,75 em $\pi = 0,30$, e só melhora em $\pi = 0,45$, de 1,51 para 1,39. Em fila única a variação é ainda menor, de 0,69 para 0,77 em $\pi = 0,15$ e de 0,24 para 0,24 em $\pi = 0,45$. Uma variação de 60% no parâmetro produz mudanças de poucos pontos percentuais e de sinal inconsistente, o que mostra que a confusão não é uma alavanca sobre a relação entre velocidade e densidade. A razão é o que ela faz no modelo: a confusão perturba a escolha de direção, e perturbar a direção redistribui pedestres lateralmente sem alterar quantos deles conseguem avançar por passo de tempo, que é a grandeza que o diagrama fundamental mede.

A Figura 14 torna esse quadro visível na condição $\pi = 0,30$ e $\beta = 0,50$. Os painéis da esquerda trazem o corredor de fila única contra a curva de Seyfried et al. (2005), e os da direita o corredor largo de dez metros contra a curva de Weidmann (1993), com a velocidade em função da densidade acima e o fluxo em função da densidade abaixo. Cada ponto é a média de trinta execuções, e as barras marcam um desvio-padrão. No corredor largo a curva do modelo é achatada. Ela parte abaixo da empírica em densidade baixa, onde a escala fixa a velocidade de todos no mesmo valor, e daí em diante cai devagar demais, de modo que em cinco pessoas por metro quadrado os pedestres do modelo ainda avançam a 0,28 m/s, densidade em que a curva de Weidmann (1993) já está próxima de zero. A consequência aparece no fluxo, que atinge 2,0 pessoas por metro e segundo contra 1,22 da curva empírica, e atinge esse máximo perto de 3,4 pessoas por metro quadrado, muito além da densidade crítica observada. O modelo, em resumo, superestima a capacidade do corredor.

O painel de fila única mostra um efeito adicional. As curvas das duas regras de movimento coincidem ponto a ponto, e não apenas se aproximam, porque a regra com espera só difere da gulosa quando há uma célula alternativa a disputar, e o corredor de fila única elimina essa alternativa.

O Teste 11 falha de forma categórica. Sob $\pi = 0,30$ e $\beta = 1,00$, o ponto de operação mais desfavorável à escolha determinística que o modelo admite, os mil pedestres usaram a saída mais próxima em todas as trinta execuções, nas duas regras de movimento, e nenhum recorreu à secundária. Levar os parâmetros ao extremo e ainda assim não observar um único desvio de rota mostra que a causa não é a intensidade da confusão, mas a estrutura do campo de piso, que é um gradiente de custo único sem termo de congestionamento capaz de tornar a alternativa atraente quando a saída principal satura.

O Teste 15 exige que o tempo da esquina fique entre o do corredor curto e o




Figura 14 – Diagrama fundamental do modelo contra as curvas empíricas de referência.

Fonte: Elaborado pelo autor.

do longo. Metade da ordenação se sustenta nas seis combinações de π e β e nas duas regras de movimento, com o corredor curto sempre mais rápido que a esquina, e a outra metade falha sempre pelo mesmo motivo, com a esquina mais lenta que o corredor longo. Daí o veredito parcial. Duas leituras se somam aqui. A primeira é que a esquina em si se comporta como a norma descreve, com a velocidade menor e o gargalo formando-se antes da curva, e não depois dela. A segunda é que os dois corredores retos, que servem de referência da comparação, são justamente onde o Teste 4 mostrou o modelo mais otimista, pois neles o fluxo é livre. A ordenação exigida pelo teste falha, portanto, com o lado frágil da comparação sendo o comportamento do modelo nas retas, e não em curvas.

O quadro delimita o alcance do AC. Ele reproduz o comportamento esperado em mapas com obstáculos e em gargalos, mas falha comparativamente em situações de caminho livre e na repartição entre saídas concorrentes, ambas por falta de resposta à alta densidade de pedestres.

5.3.2 O calibrador

Verificado o AC, resta verificar se o AG consegue recuperar as métricas comportamentais em geometrias em que ele não foi desenvolvido, resposta central para o objetivo do trabalho. Quatro geometrias normativas foram usadas como alvo de calibração, com

o regime de referência gerado em $\pi = 0,15$, $\beta = 0,50$, $c_{\text{diag}} = 1,4142$ e $c_{\text{adj}} = 1,00$, exceto o corredor do Teste 1, cujo pânico e confusão foram gerados em zero. As faixas de busca oferecidas ao AG foram $\pi \in [0; 0,5]$, $\beta \in [0; 1]$, $c_{\text{diag}} \in [1; 2]$ e $c_{\text{adj}} \in [0,5; 1,5]$. A Tabela 7 reporta o que o AG recuperou. Os valores são a média e o desvio-padrão sobre trinta repetições independentes do procedimento completo de calibração, e não sobre execuções do AC, de modo que a dispersão mostrada é a do método, e não a do simulador.

Tabela 7 – Recuperação paramétrica do AG sobre geometrias normativas RiMEA.

Geometria	Pedestres	π	β	c_{diag}	c_{adj}
Teste 1	1	$0,000 \pm 0,000$	$0,000 \pm 0,000$	$1,424 \pm 0,315$	$0,893 \pm 0,244$
Teste 9, 4 portas	1000	$0,147 \pm 0,014$	$0,538 \pm 0,026$	$1,613 \pm 0,209$	$1,007 \pm 0,120$
Teste 9, 2 portas	1000	$0,147 \pm 0,007$	$0,510 \pm 0,015$	$1,581 \pm 0,166$	$1,049 \pm 0,137$
Teste 12	150	$0,151 \pm 0,006$	$0,506 \pm 0,011$	$1,479 \pm 0,136$	$0,949 \pm 0,082$
Teste 15	500	$0,153 \pm 0,009$	$0,508 \pm 0,014$	$1,507 \pm 0,112$	$0,977 \pm 0,051$

Fonte: Elaborado pelo autor.

Os dois parâmetros comportamentais voltam bem nas quatro geometrias. O erro em π fica entre 0,8% e 2,1%, e o erro em β entre 1,2% e 7,6%, com populações que vão de um a mil pedestres. No corredor do Teste 1, que parte de pânico e confusão nulos, os dois voltam exatos e com desvio-padrão zero nas trinta execuções. O que sustenta o método está menos nos valores e mais em onde eles foram obtidos: são plantas normativas de terceiros, com geometria, população e densidade diferentes do mapa denso sobre o qual o esquema de áreas, o intervalo de amostragem e os hiperparâmetros foram fixados.

Os custos de deslocamento são o outro lado do resultado. Eles voltam próximos do alvo na média, mas com dispersão de uma a duas ordens de grandeza acima da dos parâmetros comportamentais: o desvio-padrão de c_{diag} vai de 0,11 a 0,32 sobre uma faixa de busca de largura 1,0, e o de c_{adj} vai de 0,05 a 0,24 sobre faixa de mesma largura. Execuções individuais devolvem valores espalhados por boa parte do intervalo, e a média cair perto do alvo é consequência de sortear muitas vezes dentro de uma faixa aproximadamente simétrica, e não sinal de que o AG tenha encontrado o valor.

Os custos não são identificáveis pelas métricas escolhidas para a aptidão. Densidade, dispersão, fluxo e tempo de evacuação medem para onde os pedestres vão e com que rapidez, e os custos de deslocamento não alteram nenhuma dessas grandezas de forma direta. Eles entram apenas no campo de piso, e escalar os dois pelo mesmo fator não muda qual célula vizinha tem o menor valor, portanto não muda nenhuma decisão de movimento. O corredor do Teste 1 leva o argumento ao extremo, pois nele o caminho até a saída é puramente longitudinal e nenhum deslocamento diagonal chega a ser executado, de modo que c_{diag} não influi em nada do que é observado.

5.4 Otimização de placas

Estabelecida a calibração, uma segunda fase aplica o mesmo motor evolutivo ao problema de posicionamento do mecanismo de placas herdado de [Silva, Damazo e Martins \(2025\)](#), como demonstração complementar da utilidade do modelo calibrado. As placas são modeladas como escudos de confusão. O efeito do peso atribuído ao tempo de evacuação na aptidão foi caracterizado em três configurações de peso: nulo, intermediário (0,5) e máximo (1,0), com 30 execuções cada (Tabela 8). O padrão é monotônico: com peso nulo, o custo de instalar placas domina e a solução ótima não instala nenhuma, mantendo o tempo normalizado em 0,990; à medida que o peso cresce, o uso de placas é ativado ($6,9 \pm 2,26$ placas em peso máximo) e o tempo normalizado cai para 0,759, redução da ordem de 24%. É o peso do tempo que cria o incentivo para instalar placas e regula quantas. Esse incentivo não age sozinho, e é aqui que os termos espaciais da aptidão entram. Quanto maior a confusão e o pânico nas áreas remotas do mapa, mais os pedestres se espalham e menos eles chegam juntos aos pontos de estrangulamento, de modo que portas, corredores e saídas congestionam menos. Confusão alta, portanto, não é apenas prejuízo: ela dispersa a multidão e alivia o gargalo. Uma sinalização que anulasse toda a confusão do mapa levaria todos pelo mesmo caminho ótimo e concentraria a disputa nas mesmas células. O que a aptidão procura é o meio-termo entre esses dois extremos, e por isso os termos de densidade, dispersão e fluxo entram ao lado do tempo, e não em seu lugar. Cabe registrar que o tempo entra na aptidão em forma normalizada, de modo que todas as conclusões desta fase são comparações internas ao mesmo motor de AC e ao mesmo mapa; o viés de modelagem, comum a todas as condições comparadas, cancela-se em primeira ordem e preserva a ordenação entre estratégias.

Tabela 8 – Efeito do peso do tempo de evacuação sobre a solução do AG.

Peso do tempo	Aptidão (AG)	Placas	Tempo norm.
0,0	$1,984 \pm 0,023$	$0,0 \pm 0,0$	$0,990 \pm 0,024$
0,5	$2,011 \pm 0,035$	$1,6 \pm 0,89$	$0,917 \pm 0,051$
1,0	$2,154 \pm 0,061$	$6,9 \pm 2,26$	$0,759 \pm 0,082$

Fonte: Elaborado pelo autor.

Cada valor da tabela é a média e o desvio-padrão sobre as 30 execuções da configuração correspondente. A mesma condição de peso máximo foi submetida à heurística gulosa, que alcança aptidão de 1,600 contra os 2,154 do AG. A diferença é de aproximadamente nove desvios-padrão da distribuição do AG.

A Figura 15 exibe, no peso máximo, quantos pedestres restam no mapa a cada passo, no *baseline* e na solução otimizada. Cada linha é a média de 30 execuções independentes, a região sombreada em torno dela é o intervalo de confiança de 95% dessa média, e as linhas verticais marcam o tempo médio de evacuação de cada série. As duas curvas partem juntas, porque nos primeiros passos os pedestres ainda estão saindo das

salas de origem e nenhuma placa altera esse trecho. Elas se separam no terço intermediário, quando as frentes de deslocamento alcançam os corredores e a confusão passa a produzir desvios de rota. A curva otimizada desce mais rápido nesse trecho e mantém a vantagem até o fim, com o tempo médio de evacuação caindo de 164 para 120 passos. A cauda também encurta, o que importa porque é ela que define o tempo total: no *baseline* os últimos pedestres se arrastam por várias dezenas de passos depois que a maioria já saiu, e com sinalização essa cauda se comprime.

Vale dimensionar o quanto de mapa isso exige. O indivíduo com mais placas de todo o experimento instalou dez delas. Como cada placa age até três células de distância, esse conjunto cobre 260 das 1175 células andáveis da planta, ou seja, cerca de 22% do espaço percorrível. O ganho de tempo, portanto, vem de intervir em pouco menos de um quarto do mapa, e as demais quatro quintas partes seguem com a confusão inalterada.




Figura 15 – Curva de evacuação (pedestres restantes por passo) no peso máximo, *baseline* contra otimizado.

Fonte: Elaborado pelo autor.

A curva agregada, porém, esconde que o ganho não é uniforme entre as áreas. A Figura 16 repete o painel da Figura 10, agora com o *baseline* contra a solução otimizada. Na maior parte das áreas as curvas do otimizado antecipam as da referência, que é o efeito esperado: com menos desvio de rota, a área esvazia antes e o fluxo satura mais cedo. As áreas 3, 6 e 9 são as mais nítidas nesse sentido, com o fluxo alcançando a saturação algumas dezenas de passos à frente. Em outras, contudo, a densidade de pico do otimizado é bem mais alta que a do *baseline*, como nas áreas 4 e 6, onde ela sobe acima da referência antes de cair. A leitura é a mesma que motiva a composição da aptidão: dissipar confusão faz os pedestres convergirem para a rota de menor custo, de modo que chegam mais cedo e mais juntos aos pontos de estrangulamento. O ganho de tempo total convive, portanto,

com aglomeração local mais intensa, e é esse compromisso que os termos de densidade, dispersão e fluxo mantêm sob controle.

O mecanismo que produz esse ganho aparece na Figura 17, que mostra o campo de confusão das três topologias antes e depois da otimização. Os seis painéis compartilham a mesma escala de cor, de modo que os tons podem ser comparados diretamente entre eles. A linha de cima é o campo sem placas, e ela é uma leitura direta da Equação 4.2: a confusão cresce com a distância à saída, de modo que o mapa escurece conforme se afasta dela e clareia em sua vizinhança. Onde as saídas estão muda o desenho inteiro. Com saídas nas pontas, as duas faixas claras nascem nos cantos inferiores. Com saídas no meio, uma única faixa clara sobe pelo centro. Com saída única, a região clara se concentra à direita e o extremo oposto do mapa fica no valor máximo de confusão.

A linha de baixo mostra o que a sinalização faz com esse campo, com as placas da solução otimizada marcadas por estrela. Cada placa abre um halo claro à sua volta, que decai em três degraus até se dissolver, e o conjunto das placas recorta buracos na região escura. O efeito não é uniforme, e é aí que está o interesse. Os halos não se distribuem pelo mapa, eles se alinham com as faixas de tráfego que a Figura 18 revelou. O otimizador está gastando o orçamento de placas onde a confusão é alta e há gente passando, e deixa intacta a confusão das regiões escuras por onde ninguém circula. Uma célula distante da saída e fora de qualquer rota tem confusão máxima e nenhuma placa, porque corrigi-la não compraria nada.




Figura 16 – Densidade, dispersão e fluxo por área ao longo do tempo, *baseline* contra solução otimizada.

Fonte: Elaborado pelo autor.




Figura 17 – Campo de confusão nas três topologias, sem placas e sob a solução otimizada.

Fonte: Elaborado pelo autor.

5.4.1 Generalização

O peso de sinalização penaliza o número de placas e implementa a restrição de economia. No mapa denso da Figura 8, elevar esse peso reduziu o número de placas de 9 para 4 e aumentou o tempo de evacuação, o que materializa o compromisso entre quantidade de sinalização e desfecho.

Para saber se o comportamento do otimizador depende da planta ou da posição das saídas, o mesmo experimento foi repetido em três variantes da mesma geometria, que diferem apenas em onde as saídas ficam. A primeira tem duas saídas nas pontas inferiores, a segunda tem duas saídas no centro inferior, e a terceira tem uma única saída, à direita. Paredes, obstáculos, número de pedestres e posições iniciais são idênticos nas três, de modo que qualquer diferença observada vem da topologia de saída. A Figura 18 reúne o resultado. A linha superior mostra onde o otimizador instalou placas ao longo de cinco execuções independentes de cada variante, sobrepostas em uma única planta, e a inferior mostra a ocupação acumulada do *baseline*, isto é, por onde os pedestres de fato passam quando não há sinalização alguma.

A linha inferior expõe uma característica do AC que vale nomear. O campo de piso é um gradiente de custo único, e todo pedestre que não está sob efeito de confusão desce esse gradiente. O resultado é que a ocupação não se espalha pela planta, mas se concentra em faixas estreitas, que são os caminhos de menor custo até a saída. Nas duas saídas nas pontas formam-se dois funis, um para cada canto. Com as saídas no centro, o padrão vira um V convergindo para o meio. Com saída única à direita, resta um único corredor diagonal. O modelo tem, portanto, um viés forte pela faixa de evacuação ótima,




Figura 18 – Efeito da posição das saídas sobre a sinalização escolhida.

Fonte: Elaborado pelo autor.

e esse viés é uma propriedade do AC, anterior a qualquer otimização.

A linha superior mostra que o AG acompanha esse viés. As placas não se distribuem pelo mapa, elas se alinham às mesmas faixas que a ocupação revela. Nas saídas em pontas, a sinalização ocupa o terço esquerdo e o terço direito e deixa o miolo vazio, porque o miolo é justamente por onde ninguém passa. Com as saídas no centro, as placas descem para a faixa central, que passou a ser a região mais percorrida. Com saída única, elas acompanham o corredor que leva à direita. O otimizador está resolvendo o problema que lhe foi dado, mas o problema que lhe foi dado já vem enviesado pelo AC: ele otimiza as áreas dentro das faixas ótimas, e não o espaço como um todo.

Esse encadeamento também explica a contagem de placas. As duas variantes de saída dupla receberam entre 8 e 11 placas por execução, enquanto a de saída única ficou entre 4 e 6. Sem saídas concorrentes não há ambiguidade de rota cuja confusão valha a pena dissipar, e a economia de placas passa a pesar mais do que o ganho marginal de tempo. A direção do efeito é a esperada, e a diferença entre as topologias é grande o bastante para não se confundir com a variação entre execuções.

A generalização foi avaliada ainda em uma topologia de outra natureza, o labirinto de múltiplas saídas da Figura 19, formado por um reticulado de 36×15 células, com 101 pedestres, oito saídas contíguas e corredores ramificados. Nele o AG reduziu o tempo de evacuação do *baseline* de 63,79 para 57,93 passos, usando em média 2,53 placas. A direção do efeito se mantém, mas a magnitude é bem menor que no mapa denso, com redução de cerca de 9% contra os 24% observados lá.

A razão está na profundidade dos caminhos. Um mapa com oito saídas contíguas




Figura 19 – Labirinto de múltiplas saídas.

Fonte: Adaptado de [Silva, Damazo e Martins \(2025\)](#).

oferece rotas curtas a partir de quase qualquer ponto, e um pedestre confuso que erra o caminho perde pouco, porque logo encontra outra saída. Já em um mapa com poucas saídas e corredores longos, o mesmo erro custa uma travessia inteira. É onde o erro é caro que dissipar confusão rende, e é por isso que o ganho da sinalização depende da topologia do ambiente e não pode ser reportado como um número único.

5.4.2 Comparação com outros solvers

Para verificar a qualidade das escolhas do AG de forma comparativa, foram construídos outros três algoritmos de otimização. Todos usam o mesmo mecanismo de base, que é o AC proposto, e o mesmo mecanismo de avaliação das métricas, de modo que a única diferença entre eles é a estratégia de busca.

O primeiro é um algoritmo **aleatório**. Ele sorteia quantas placas usar e onde colocá-las, avalia o conjunto e guarda o melhor que encontrou ao longo de um número fixo de tentativas. Serve como piso de comparação, pois qualquer estratégia que mereça o nome precisa superá-lo.

O segundo é uma **heurística gulosa**, na forma de subida de encosta. Ela parte do conjunto vazio e, a cada passo, testa individualmente todas as posições ainda livres do mapa, calculando a aptidão que cada uma produziria se fosse acrescentada ao conjunto atual. Adiciona então a única posição que mais melhora a aptidão e repete o processo. O procedimento para quando nenhuma adição melhora o resultado ou quando o teto de placas é atingido. É uma estratégia que nunca reconsidera uma escolha já feita, e essa é sua limitação: uma placa que parecia ótima sozinha pode ser má companheira das seguintes, e o guloso não tem como desfazê-la.

O terceiro é um algoritmo de **busca exata**, do tipo ramificação e poda (*Branch & Bound*). Ele enumera todos os subconjuntos de posições de tamanho até o teto de placas e avalia cada um com uma simulação completa, de modo que o valor que devolve é, por

construção, o ótimo do problema. Só é viável em instâncias pequenas, e é justamente por isso que serve de referência: onde ele consegue rodar, sabemos exatamente o quanto o AG deixou na mesa.

A Tabela 9 evidencia essa análise, com os três algoritmos e o AG sobre o mesmo mapa em três densidades populacionais crescentes. O AG e as duas variantes do aleatório foram avaliados sobre 30 execuções independentes cada, e os valores mostrados são a média e o desvio-padrão dessas execuções. O guloso aparece sem desvio-padrão porque é determinístico, ou seja, devolve sempre a mesma solução para a mesma instância, e por isso uma execução única o descreve por completo.

Tabela 9 – Aptidão alcançada por cada estratégia de otimização, sob densidade populacional crescente no mesmo mapa.

Estratégia	Degrau 1 (62 ped.)	Degrau 2 (123 ped.)	Degrau 3 (185 ped.)
Aleatório (30 sorteios)	$1,3153 \pm 0,0649$	$1,2538 \pm 0,0505$	$1,2612 \pm 0,0632$
Guloso	1,6001	1,5437	1,5929
Aleatório (orçamento igual ao AG)	$1,6058 \pm 0,0056$	$1,5421 \pm 0,0038$	$1,5631 \pm 0,0106$
AG	$2,1431 \pm 0,0036$	$2,0787 \pm 0,0016$	$2,0422 \pm 0,0016$

Fonte: Elaborado pelo autor.

Contra o algoritmo aleatório a diferença é grande e constante. O AG supera a busca aleatória de 30 sorteios em todas as três densidades, o que era esperado. Mais informativo é o controle em que a busca aleatória recebe o mesmo orçamento computacional do AG, isto é, o mesmo número de avaliações do AC. Mesmo assim o AG mantém vantagem de 30,6% a 34,8%, o que mostra que o ganho vem da estratégia de busca, e não de simplesmente avaliar mais candidatos.

Contra o guloso a vantagem também se mantém nos três degraus, mas encolhe conforme a densidade aumenta, de 33,9% para 28,2%. A explicação é o espaço de busca: com mais pedestres no mapa, sobram menos posições válidas para placa, e o conjunto de soluções razoáveis se estreita. Quanto mais estreito ele fica, menos importa a capacidade do AG de recombinar conjuntos inteiros, e mais perto o guloso chega somando as melhores posições isoladas.

Já contra o B&B a pergunta muda. Não se trata mais de saber quem encontra a melhor solução, porque a busca exata encontra a melhor por definição, mas de quanto custa cada uma (Tabela 10). A coluna de lacuna dessa tabela é a distância relativa entre a aptidão do método e a aptidão do ótimo exato. Cabe a ressalva de que cada método foi executado uma única vez em cada instância, sem repetição, de modo que os tempos e as lacunas reportados não vêm acompanhados de medida de dispersão e devem ser lidos como ordem de grandeza. Em $maxSigns = 3$, o AG atinge 98,17% do ótimo do B&B em cerca de 12,5 s, contra 31,7 s do B&B. Em $maxSigns = 4$, o contraste explode: o AG atinge 97,71% do ótimo em 12,7 s, enquanto o B&B consome mais de 16 minutos e 10,34 milhões de avaliações; o AG recupera cerca de 98% da qualidade por aproximadamente 1% do

custo. Em $maxSigns = 5$ o B&B torna-se intratável ($\approx 254,6$ milhões de subconjuntos), o que ilustra a fronteira em que a heurística se torna indispensável.

Tabela 10 – Custo e qualidade do AG frente ao ótimo exato da busca por ramificação e poda, nas instâncias em que a busca exata é viável.

$maxSigns$	Método	Aptidão	Lacuna	Tempo	Avaliações
3	B&B (ótimo)	2,1319	–	31,7 s	333.502
3	AG	2,0928	1,83%	12,5 s	≈ 20.000
4	B&B (ótimo)	2,1595	–	964,4 s	10.342.627
4	AG	2,1101	2,29%	12,7 s	≈ 20.000
5	B&B intratável ($\sum_{k \leq 5} \binom{126}{k} \approx 254,6 \times 10^6$ subconjuntos)				

Fonte: Elaborado pelo autor.

5.4.3 Consenso entre execuções

A calibração converge de forma repetível, e cabe perguntar se o posicionamento de placas também converge. Um experimento dedicado responde a isso. Ele executa 15 otimizações independentes, cada uma sobre uma distribuição inicial de pedestres diferente, e conta quantas vezes cada célula do mapa foi escolhida ao longo dessas execuções. As células mais recorrentes formam então arranjos de consenso, com uma placa, duas, três e assim por diante, e cada arranjo é avaliado sobre 30 distribuições novas, disjuntas das 15 usadas no treino. Para servir de referência, o mesmo conjunto de teste avalia também o arranjo obtido por ajuste direto, isto é, o resultado de uma única otimização conduzida sobre a distribuição de pedestres padrão do mapa, sem nenhuma agregação. Ele representa o procedimento mais simples possível, o de observar o ambiente uma vez e instalar as placas que o AG devolver, e é sobre ele que o consenso precisa mostrar vantagem. O procedimento foi aplicado a dois mapas de topologia bem diferente, um mapa denso de 33×47 células com duas saídas e um labirinto de 15×36 células com oito saídas, sob a mesma configuração e a mesma *seed*, de modo que o mapa é o único fator que varia entre as duas colunas. Cada mapa recebeu uma execução do experimento.

O primeiro resultado é que o consenso espacial não existe. A célula mais escolhida aparece em 4 das 15 execuções no mapa denso e em 5 das 15 no labirinto, e nenhuma célula, em nenhum dos dois mapas, é escolhida em mais de um terço das execuções. As escolhas se espalham por 53 células distintas no mapa denso e 39 no labirinto. O AG não está reencontrando os mesmos lugares.

O segundo resultado é que isso não impede a sinalização de funcionar, e a Tabela 11 mostra por quê. Cada entrada dela é a média e o desvio-padrão, sobre as 30 distribuições de teste, da aptidão do arranjo e do tempo de evacuação que ele produz.

As duas colunas de tempo mostram o efeito que a aptidão atenua. No mapa denso o tempo de evacuação cai de 133,1 passos sem placas para 105,9 com nove, uma redução de

Tabela 11 – Aptidão e tempo de evacuação dos arranjos de consenso em dois mapas, sobre 30 distribuições de pedestres não vistas no treino.

Arranjo	Mapa denso		Labirinto	
	Aptidão	Tempo	Aptidão	Tempo
Sem placas	$2,254 \pm 0,047$	$133,1 \pm 7,9$	$1,981 \pm 0,043$	$63,6 \pm 3,0$
1 placa	$2,289 \pm 0,041$	$125,7 \pm 7,3$	$1,986 \pm 0,039$	$62,8 \pm 2,8$
2 placas	$2,292 \pm 0,042$	$124,4 \pm 7,1$	$2,007 \pm 0,043$	$60,2 \pm 2,9$
3 placas	$2,287 \pm 0,044$	$123,1 \pm 8,0$	$2,036 \pm 0,047$	$56,8 \pm 3,3$
4 placas	$2,288 \pm 0,043$	$121,9 \pm 8,0$	$2,063 \pm 0,043$	$54,2 \pm 3,0$
5 placas	$2,278 \pm 0,041$	$122,0 \pm 8,3$	$2,054 \pm 0,041$	$54,2 \pm 2,9$
6 placas	$2,292 \pm 0,035$	$116,5 \pm 5,9$	$2,051 \pm 0,041$	$53,8 \pm 3,0$
7 placas	$2,287 \pm 0,040$	$114,9 \pm 7,6$	$2,043 \pm 0,036$	$53,7 \pm 2,6$
8 placas	$2,287 \pm 0,044$	$111,9 \pm 7,9$	—	—
9 placas	$2,305 \pm 0,044$	$105,9 \pm 8,4$	—	—
Ajuste direto	$2,288 \pm 0,034$	$106,9 \pm 6,5$	$1,993 \pm 0,044$	$58,9 \pm 3,1$

Fonte: Elaborado pelo autor.

20,4%, e no labirinto cai de 63,6 para 54,2 com quatro placas, 14,9%. Como os 30 arranjos de teste são os mesmos para todos os sujeitos, cada distribuição pode ser comparada com ela mesma, e a queda é inequívoca nos dois mapas, com $t = -20,5$ e $t = -17,0$ em teste t pareado. A aptidão registra esse ganho de forma comprimida porque inclui a penalização por número de placas, com peso 0,2, e portanto desconta parte do benefício de cada placa acrescentada. Ler a tabela apenas pela aptidão levaria a concluir que placas adicionais não servem para nada, o que a coluna de tempo desmente.

O comportamento em função do número de placas, porém, não é o mesmo nos dois mapas. No mapa denso a aptidão fica plana entre 2,278 e 2,292 de uma a oito placas, e uma placa isolada já responde por cerca de dois terços do ganho de aptidão que nove placas produzem. O tempo de evacuação conta outra história no mesmo mapa, pois uma placa recupera 7,4 dos 27,2 passos que nove recuperam. A planura, portanto, é da aptidão, e não do desfecho. No labirinto nem a aptidão é plana. Uma placa não produz efeito distinguível do piso, com $t = +0,68$ na comparação pareada, enquanto quatro placas produzem $t = +11,03$. Em um mapa com duas saídas quase todas as posições cobrem o mesmo tráfego, e em um labirinto com oito saídas existem rotas concorrentes, de modo que cada placa acrescentada atende um fluxo que as demais não atendem.

A linha de ajuste direto responde se agregar as escolhas de execuções independentes custa desempenho. No mapa denso não custa, pois o arranjo de consenso com nove placas evacua em 105,9 passos contra 106,9 do ajuste direto com dez, diferença que o teste pareado não distingue, com $t = -0,60$. No labirinto o consenso é melhor, com 54,2 passos usando quatro placas contra 58,9 usando cinco, e $t = -9,89$. Nos dois mapas o consenso alcança o ajuste direto ou o supera, sempre com uma placa a menos, e sobre distribuições de pedestres que nenhum dos dois viu no treino. É esse resultado, e não a repetição de

posições, que sustenta recomendar uma sinalização mínima.

Os resultados juntos separam duas coisas que o consenso fraco poderia confundir. O que é intercambiável é a posição, não a quantidade. Como o campo de piso concentra os pedestres em faixas estreitas, conforme descrito na Subseção 5.4.1, e o efeito de uma placa alcança três células, posições vizinhas dentro de uma faixa cobrem aproximadamente o mesmo trecho de tráfego, e o AG escolhe entre elas de forma praticamente arbitrária. É isso que produz as 53 e 39 células distintas do mapa de frequências, e o consenso fraco é uma consequência do viés do AC, não um defeito da busca. Quantas placas instalar, por outro lado, importa, e importa mais onde há rotas concorrentes. A ausência de consenso também não impede a generalização, justamente porque agregar posições quase equivalentes produz um arranjo tão bom quanto qualquer uma delas.

Para o projeto de sinalização, a leitura prática tem duas partes. A posição exata importa pouco, porque dentro da faixa de maior tráfego as alternativas são quase equivalentes. A quantidade importa, e de forma diferente conforme o ambiente. No mapa denso cada placa acrescentada continua reduzindo o tempo de evacuação, e uma placa isolada recupera pouco mais de um quarto do que nove recuperam. No labirinto o ganho se concentra nas quatro primeiras placas, uma para cada conjunto de rotas concorrentes, e estabiliza a partir daí.

5.5 Síntese do capítulo

Os resultados deste capítulo respondem, de forma qualificada, à pergunta central: se o AG configura o AC para reproduzir o comportamento observável de um regime de referência. A configuração experimental foi fixada por dados: as nove áreas dão granularidade suficiente sem fragmentar demais os comportamentos, e o intervalo de amostragem de 10 passos reduz o ruído sem perder o comportamento geral.

O achado central da calibração é que o modelo calibrado reproduz a dinâmica espaço-temporal do *baseline* nos três regimes testados, e também nos diversos mapas e situações examinados, com recuperação paramétrica consistente entre eles. A distância média à referência permanece pequena e da mesma ordem de grandeza nos três regimes, e o mesmo vale para as quatro geometrias normativas, cujas plantas e populações nada têm em comum com o mapa sobre o qual o método foi desenvolvido. Essa consistência é condicionada à composição da aptidão: o experimento de ablação mostra que o tempo de evacuação identifica a taxa de pânico e as métricas espaciais identificam a confusão base, de modo que a omissão de qualquer uma dessas classes de métrica compromete a identificabilidade de ao menos um parâmetro. Isso reposiciona o *baseline* sintético como instrumento que valida tanto o processo de calibração quanto o desenho da função de aptidão multi-métrica adotada.

Sobre o modelo calibrado, duas demonstrações complementares atestam sua utilidade. Na otimização de placas, é o peso do tempo de evacuação que ativa o uso de placas, a economia opera como projetada em mapas com rotas concorrentes, e o ganho depende da topologia (de $\sim 24\%$ no mapa denso a $\sim 9\%$ no labirinto). Como heurística, o AG supera a busca gulosa e a aleatória em toda a escada, mantém vantagem sobre a busca aleatória de orçamento igual e atinge cerca de 98% do ótimo exato do B&B a aproximadamente 1% de seu custo, tornando-se indispensável na faixa em que a busca exata deixa de ser viável. O experimento de consenso mostra que as posições escolhidas não se repetem entre execuções independentes, mas que agregá-las produz arranjos que alcançam ou superam o ajuste direto sobre distribuições não vistas, o que sustenta recomendar uma sinalização mínima sem que ela dependa de uma execução afortunada.

Os testes RiMEA delimitam esse alcance. O modelo comporta-se como esperado nos testes determinísticos, de redução de portas e de gargalo, mas falha onde faltaria um termo de fricção ou de congestionamento: superestima o fluxo em duas a três vezes no diagrama fundamental, e não reparte fluxo entre saídas concorrentes. E, por mais que se comporte de forma correta diante de obstáculos, o modelo falha comparativamente em uma situação de caminho livre. O modelo é eficiente em mapas com muitos obstáculos ou muito simples, e é na dinâmica de multidão em espaço desimpedido que o AC e o AG encontram sua fronteira. Como todas as conclusões de otimização são comparações relativas internas ao mesmo motor de AC, esse viés se cancela em primeira ordem e não invalida a ordenação entre estratégias; o que permanece é uma ressalva de validade externa, a ser resolvida pela substituição futura do *baseline* sintético por dados empíricos.

6 Conclusão

Este trabalho desenvolveu um simulador de evacuação de pedestres baseado em Autômato Celular (AC) e um Algoritmo Genético (AG) que atua sobre ele em duas fases, a calibração dos parâmetros comportamentais do modelo e a otimização do posicionamento de placas de sinalização. O AC adota um campo de piso estático como paisagem de custo para o deslocamento e um campo escalar de confusão, composto por uma camada de confusão base (β) e por um efeito de pânico controlado pela taxa de pânico (π). As placas foram modeladas como escudos de confusão transponíveis, que não bloqueiam o caminho dos pedestres e reduzem a confusão conforme a distância até a placa mais próxima. A aptidão apoiou-se em métricas espaciais, que são a densidade, a dispersão e o fluxo, somadas ao tempo de evacuação.

O alvo de calibração foi um regime de referência gerado pelo próprio simulador a partir de parâmetros conhecidos. Essa escolha é o que torna a verificação possível: como os valores que geraram o regime são conhecidos, é possível medir quanto o AG se afasta deles, o que dados de campo não permitiriam. Para que esse alvo não fosse uma realização estocástica isolada, ele foi construído como média sobre execuções independentes, com a variância medida e usada para normalizar os erros que compõem a aptidão.

Três contribuições resultam desse esforço. A principal é a demonstração de que o AG configura o AC para reproduzir densidade, dispersão, fluxo e tempo de evacuação de um regime de referência, com recuperação paramétrica consistente entre os regimes testados. Essa identificação é condicionada à composição da aptidão, pois as métricas espaciais identificam a confusão base e o tempo de evacuação identifica a taxa de pânico. A segunda é a aplicação da mesma estrutura evolutiva à otimização do posicionamento de placas, com ganho contingente ao peso do tempo de evacuação e à topologia do mapa. Todo o *pipeline* foi construído em Go e em ferramentas próprias, aproveitando ao máximo o paralelismo nativo da linguagem, o que viabilizou a execução massiva de simulações estocásticas que as duas contribuições anteriores exigem.

A terceira contribuição é a verificação do alcance do modelo frente aos testes normativos da RiMEA, e ela merece atenção própria porque atua nos dois sentidos. Em um sentido, a norma delimita o simulador. O AC reproduz o comportamento esperado no contorno de esquina, na redução de portas e no gargalo entre ambientes, e falha no diagrama fundamental, na repartição entre saídas concorrentes e na ordenação de tempos da esquina sob multidão. A falha no diagrama fundamental é a mais ampla das três, pois é justamente em regime de caminho livre que o modelo mais superestima a vazão. No outro sentido, a norma valida o calibrador de forma mais exigente do que o regime sintético

consegue. As geometrias normativas são plantas de terceiros, com populações de 150 a 1000 pedestres, e o AG recuperou nelas os parâmetros comportamentais com erro de 1,5% a 6,4% na confusão base e de 0,3% a 3,5% na taxa de pânico. A máquina de calibração não foi ajustada para essas plantas, e ainda assim funcionou nelas.

Quanto ao objetivo principal, os resultados o confirmam de forma qualificada. É possível configurar um simulador de evacuação baseado em autômatos celulares, por meio de um algoritmo genético, para reproduzir métricas espaciais e temporais de situações de evacuação. O modelo calibrado reproduz a distribuição de pedestres pelas áreas ao longo do tempo, a ordem em que as áreas se esvaziam e o tempo total de evacuação, com concordância que se mantém entre execuções independentes e entre plantas de origens diferentes.

A qualificação está em duas condições. A primeira é que a aptidão precisa combinar métricas espaciais e temporais, porque cada classe carrega informação sobre um dos dois parâmetros comportamentais. A segunda é que a reprodução é do comportamento espacial agregado, e não da dinâmica local, que os testes normativos mostraram estar fora do alcance do modelo.

Vale delimitar o que esse resultado significa. Recuperar os valores que geraram um regime é um critério de verificação, não o produto do trabalho. Ele serve para mostrar que a máquina de calibração funciona, e é útil justamente porque, em um regime sintético, a resposta certa é conhecida. O que se entrega, porém, é o procedimento: uma função de aptidão que mede aderência comportamental por área e ao longo do tempo, um motor evolutivo que a otimiza, e um simulador cujo comportamento responde a esse ajuste. Esse procedimento não depende de o alvo ser sintético, e é por isso que ele se aplicou sem modificação às geometrias normativas.

Lido em conjunto, o modelo firma-se como ferramenta útil e calibrável a partir de dados para estudar o comportamento espacial de pedestres e apoiar o planejamento de sinalização. Ele ordena estratégias de posicionamento de forma confiável e aponta onde poucas placas concentram o maior ganho. Cabe registrar que as partes do *pipeline* são independentes entre si e não precisam ser executadas em conjunto. O AC roda sozinho como motor de simulação, a calibração roda sobre um regime de referência descrito nas métricas que a aptidão consome, e a otimização de placas roda sobre parâmetros já calibrados, sem repetir a fase anterior.

Duas limitações delimitam o alcance dessas conclusões. A primeira é que o padrão de referência é sintético, o que valida o procedimento mas não substitui a calibração contra observações reais. A segunda é que o modelo não incorpora regras comportamentais dinâmicas. O pânico e a confusão permanecem constantes, e não há realimentação do congestionamento sobre o campo de piso, o que restringe a fidelidade das dinâmicas locais na caminhada livre em corredor e na repartição de fluxo entre saídas concorrentes.

Como trabalhos futuros, três direções se destacam.

A primeira é estender a geometria para escadas, rampas e desníveis. Além de ampliar os cenários representáveis, essa extensão abre um novo objeto de calibração, pois a velocidade de deslocamento deixa de ser uniforme e passa a depender do tipo de superfície. A razão entre a velocidade em escada, em rampa e em piso plano seria um parâmetro do modelo, ajustável pelo mesmo AG que hoje ajusta a taxa de pânico e a confusão base, e verificável contra os Testes 2, 3, 8 e 13 da RiMEA, hoje fora de alcance.

A segunda é introduzir um rastro virtual com limiar de comportamento. O campo dinâmico do modelo de campo de piso já registra a passagem de pedestres e o utiliza como atrativo, com efeito monotônico, de modo que mais rastro implica maior atratividade. A proposta aqui é romper essa monotonicidade. O rastro seria atrativo enquanto sua intensidade permanecesse abaixo de um limiar, e repulsivo acima dele, com o limiar sendo ele próprio um parâmetro sob calibração. Um único mecanismo passaria a produzir dois efeitos que hoje exigiriam regras distintas, pois a atração em baixa intensidade orienta o pedestre pelas rotas já percorridas por outros, enquanto a repulsão em alta intensidade o afasta das regiões congestionadas. É também o termo de realimentação cuja ausência os testes normativos apontaram como causa das falhas na repartição entre saídas concorrentes.

A terceira é calibrar o modelo contra dados reais de evacuação. Cabe registrar que esses dados não precisam ser trajetórias completas. Podem ser observações esparsas de posicionamento, como fotografias ou registros de passagem, ou já as próprias métricas deste trabalho calculadas a partir de uma observação externa. É a segunda forma que o *pipeline* consome de maneira mais direta, uma vez que a aptidão de calibração compara métricas, e não trajetórias.

Referências

- BURSTEDDE, C.; KLAUCK, K.; SCHADSCHNEIDER, A.; ZITTARTZ, J. Simulation of pedestrian dynamics using a two-dimensional cellular automaton. **Physica A: Statistical Mechanics and its Applications**, v. 295, n. 3–4, p. 507–525, 2001. Disponível em: <[https://doi.org/10.1016/S0378-4371\(01\)00141-8](https://doi.org/10.1016/S0378-4371(01)00141-8)>. Citado na página 32.
- CUI, G.; YANAGISAWA, D.; NISHINARI, K. Incorporating genetic algorithm to optimise initial condition of pedestrian evacuation based on agent aggressiveness. **Physica A: Statistical Mechanics and its Applications**, v. 583, p. 126277, 2021. ISSN 0378-4371. Disponível em: <<https://doi.org/10.1016/j.physa.2021.126277>>. Citado 3 vezes nas páginas 13, 28 e 30.
- DAMAZO, G. S. **Modelo baseado em autômatos celulares para simulação de dinâmica coletiva de pedestres em ambientes internos**. 2024. Trabalho de Conclusão de Curso – Faculdade de Computação, Universidade Federal de Uberlândia, Uberlândia, MG. Disponível em: <<https://repositorio.ufu.br/handle/123456789/41926>>. Citado 3 vezes nas páginas 13, 29 e 35.
- ENGELBRECHT, A. P. **Computational Intelligence: An Introduction**. 2nd. ed. Hoboken, NJ: Wiley Publishing, 2007. ISBN 0470035617. Citado 2 vezes nas páginas 25 e 26.
- ESHELMAN, L. J.; SCHAFFER, J. D. Real-coded genetic algorithms and interval-schemata. In: WHITLEY, L. D. (Ed.). **Foundations of Genetic Algorithms**. San Mateo, CA: Morgan Kaufmann, 1993. v. 2, p. 187–202. Citado na página 38.
- FRAGA, L. M. **Estratégias evolutivas para o ajuste de parâmetros de um modelo epidemiológico baseado em autômatos celulares probabilísticos**. Dissertação (Dissertação de Mestrado) — Universidade Federal de Uberlândia, Uberlândia, MG, 2021. Disponível em: <<https://repositorio.ufu.br/handle/123456789/36370>>. Citado 7 vezes nas páginas 13, 16, 19, 20, 21, 28 e 30.
- GARCIMARTÍN, A.; ZURIGUEL, I.; PASTOR, J.; MARTÍN-GÓMEZ, C.; PARISI, D. Experimental evidence of the “faster is slower” effect. **Transportation Research Procedia**, v. 2, p. 760–767, 2014. ISSN 2352-1465. The Conference on Pedestrian and Evacuation Dynamics 2014 (PED 2014), 22-24 October 2014, Delft, The Netherlands. Disponível em: <<https://doi.org/10.1016/j.trpro.2014.09.085>>. Citado na página 13.
- GARDNER, M. Mathematical games: The fantastic combinations of john conway’s new solitaire game ‘life’. **Scientific American**, 1970. Disponível em: <<https://doi.org/10.1038/scientificamerican1070-120>>. Citado 2 vezes nas páginas 17 e 21.
- GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Addison-Wesley, 1989. Disponível em: <<https://link.springer.com/article/10.1023/A:1022602019183>>. Citado 4 vezes nas páginas 23, 24, 25 e 37.

- HELBING, D.; JOHANSSON, A.; AL-ABIDEEN, H. Z. Dynamics of crowd disasters: An empirical study. **Phys. Rev. E**, American Physical Society, v. 75, p. 046109, Apr 2007. Disponível em: <<https://doi.org/10.1103/PhysRevE.75.046109>>. Citado 2 vezes nas páginas 13 e 32.
- HELBING, D.; MOLNÁR, P.; FARKAS, I. J.; BOLAY, K. Self-organizing pedestrian movement. **Environment and Planning B: Planning and Design**, v. 28, n. 3, p. 361–383, 2001. Disponível em: <<https://doi.org/10.1068/b2697>>. Citado na página 13.
- HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. University of Michigan Press, 1975. Disponível em: <<https://direct.mit.edu/books/monograph/2574/Adaptation-in-Natural-and-Artificial-SystemsAn>>. Citado 3 vezes nas páginas 22, 23 e 25.
- LI, D.; HAN, B. Behavioral effect on pedestrian evacuation simulation using cellular automata. **Safety Science**, v. 80, p. 41–55, 2015. ISSN 0925-7535. Disponível em: <<https://doi.org/10.1016/j.ssci.2015.07.003>>. Citado na página 13.
- LU, L.; CHAN, C.-Y.; WANG, J.; WANG, W. A study of pedestrian group behaviors in crowd evacuation based on an extended floor field cellular automaton model. **Transportation Research Part C: Emerging Technologies**, v. 81, p. 317–329, 2017. ISSN 0968-090X. Disponível em: <<https://doi.org/10.1016/j.trc.2016.08.018>>. Citado na página 13.
- MURILO, L. V. **Ajuste evolutivo de um modelo baseado em autômatos celulares para representar a dinâmica de propagação de incêndios florestais**. Dissertação (Dissertação de Mestrado) — Universidade Federal de Uberlândia, Uberlândia, MG, 2025. Disponível em: <<https://repositorio.ufu.br/handle/123456789/44848>>. Citado 12 vezes nas páginas 13, 18, 20, 22, 23, 24, 25, 26, 28, 29, 30 e 43.
- NEUMANN, J. V. **Theory of Self-Reproducing Automata**. Urbana: University of Illinois Press, 1966. Disponível em: <https://archive.org/details/theoryofselfrepr00vonn_0/>. Citado na página 16.
- PARISI, D.; SORIA, S.; JOSENS, R. Faster-is-slower effect in escaping ants revisited: Ants do not behave like humans. **Safety Science**, v. 72, p. 274–282, 2015. ISSN 0925-7535. Disponível em: <<https://doi.org/10.1016/j.ssci.2014.09.014>>. Citado na página 13.
- RICHTER, K.-F.; SHI, M.; GAN, H.-S.; WINTER, S. Decentralized evacuation management. **Transportation Research Part C: Emerging Technologies**, v. 31, p. 1–17, 2013. ISSN 0968-090X. Disponível em: <<https://doi.org/10.1016/j.trc.2013.02.013>>. Citado na página 13.
- RiMEA e.V. **Richtlinie für Mikroskopische Entfluchtungsanalysen**. 2025. Disponível em: <<https://rimea.de/de/rimea-projekt/richtlinie-fuer-mikroskopische-entfluchtungsanalysen/>>. Citado 3 vezes nas páginas 13, 32 e 52.
- SCHADSCHNEIDER, A. **Cellular Automaton Approach to Pedestrian Dynamics - Theory**. 2001. Disponível em: <<https://arxiv.org/pdf/cond-mat/0112117>>. Citado na página 28.

- SENANAYAKE, G. P.; KIEU, M.; ZOU, Y.; DIRKS, K. Agent-based simulation for pedestrian evacuation: A systematic literature review. **International Journal of Disaster Risk Reduction**, v. 111, p. 104705, 2024. Disponível em: <<https://doi.org/10.1016/j.ijdr.2024.104705>>. Citado na página 36.
- SEYFRIED, A.; STEFFEN, B.; KLINGSCH, W.; BOLTES, M. The fundamental diagram of pedestrian movement revisited. **Journal of Statistical Mechanics: Theory and Experiment**, v. 2005, n. 10, p. P10002, 2005. Disponível em: <<https://doi.org/10.1088/1742-5468/2005/10/P10002>>. Citado 2 vezes nas páginas 54 e 56.
- SILVA, E. C.; DAMAZO, G. S.; MARTINS, L. G. A. Cellular automata-based model for simulation of collective pedestrian dynamics in open-air environments with stochastic transitions and traffic signs. In: **2025 IEEE Congress on Evolutionary Computation (CEC)**. Hangzhou, China: IEEE, 2025. p. 1–8. Disponível em: <<https://doi.org/10.1109/CEC65147.2025.11043033>>. Citado 8 vezes nas páginas 13, 20, 29, 32, 34, 35, 59 e 65.
- SISIOPIKU, V.; AKIN, D. Pedestrian behaviors at and perceptions towards various pedestrian facilities: an examination based on observation and survey data. **Transportation Research Part F: Traffic Psychology and Behaviour**, v. 6, n. 4, p. 249–274, 2003. ISSN 1369-8478. Disponível em: <<https://doi.org/10.1016/j.trf.2003.06.001>>. Citado na página 13.
- SIVANANDAM, S. N.; DEEPA, S. N. **Introduction to Genetic Algorithms**. Springer, 2008. Disponível em: <<https://link.springer.com/book/10.1007/978-3-540-73190-0>>. Citado 3 vezes nas páginas 23, 24 e 37.
- SIYAM, N.; ALQARYOUTI, O.; ABDALLAH, S. Research issues in agent-based simulation for pedestrians evacuation. **IEEE Access**, v. 8, p. 134435–134455, 2020. Disponível em: <<https://doi.org/10.1109/ACCESS.2019.2956880>>. Citado 2 vezes nas páginas 13 e 36.
- VARAS, A.; CORNEJO, M. D.; MAINEMER, D.; TOLEDO, B.; ROGAN, J.; MUÑOZ, V.; VALDIVIA, J. A. Cellular automaton model for evacuation process with obstacles. **Physica A: Statistical Mechanics and its Applications**, v. 382, n. 2, p. 631–642, 2007. Disponível em: <<https://doi.org/10.1016/j.physa.2007.04.006>>. Citado 7 vezes nas páginas 18, 20, 28, 29, 32, 34 e 35.
- von Krüchten, C.; SCHADSCHNEIDER, A. Empirical study on social groups in pedestrian evacuation dynamics. **Physica A: Statistical Mechanics and its Applications**, v. 475, p. 129–141, 2017. ISSN 0378-4371. Disponível em: <<https://doi.org/10.1016/j.physa.2017.02.004>>. Citado na página 13.
- WEIDMANN, U. **Transporttechnik der Fussgänger: Transporttechnische Eigenschaften des Fussgängerverkehrs**. Zürich, 1993. Citado 3 vezes nas páginas 32, 54 e 56.
- WOLFRAM, S. **A New Kind of Science**. Wolfram Media, 2002. Disponível em: <<https://www.wolframscience.com/nks/>>. Citado 2 vezes nas páginas 17 e 20.